

Klasyfikacja gatunków drzewiastych Karkonoskiego Parku Narodowego z użyciem lotniczych danych hiperspektralnych APEX oraz Support Vector Machines

Edwin Raczek¹⁾, Bogdan Zagajewski¹⁾, Adrian Ochtyra¹⁾, Adriana Adriana Marcinowska-Ochtyra¹⁾, Anna Jarocińska¹⁾ & Marek Dobrowolski²⁾

¹⁾ Uniwersytet Warszawski, Wydział Geografii i Studiów Regionalnych, Zakład Geoinformatyki, Kartografii i Teledetekcji, ul. Krakowskie Przedmieście 30, 00-927 Warszawa, edwin.raczko@student.uw.edu.pl

²⁾ Karkonoski Park Narodowy, ul. Chałubińskiego 23, 58-570 Jelenia Góra

WSTĘP

Metody oceny stanu kondycyjnego lasów są ważnym elementem monitoringu obszarów chronionych (NAGENDRA i in. 2013), jak i oceny potencjalnych korzyści ekonomicznych wynikających z użytkowania terenów leśnych (ASHUNTOSH 2012). Wydajne zarządzanie lasem wymaga pozyskania wielu informacji dotyczących drzewostanu, z których znajomość powierzchniowego udziału poszczególnych gatunków drzew jest jedną z najważniejszych (SHEN i in. 2010). Obecnie stosowane metody polegające na klasyfikacji drzewostanu z użyciem wysokorozdzielczych zobrażeń i fotointerpretacji są bardzo pracochłonne szczególnie, kiedy trzeba opracować duży obszar (JONES i in. 2010). Jednym z obszarów chronionych, który został uszkodzony w wyniku antropopresji są Karkonosze. Ponad 30 lat temu gwałtowny rozwój przemysłu w tzw. „czarnym trójkącie” oraz uwarunkowania środowiskowe (rzeźba terenu) spowodowała kwaśne deszcze, które uszkodziły duże połacie lasów (JADCZYK 2009). Osłabione drzewa szybko padły ofiarą szkodników, co tylko miało decydujący wpływ na rozmiary poniesionych szkód. Stopień

zniszczenia drzewostanów KPN nie okazał się tak duży, jak go początkowo oceniano, jednak sama katastrofa stanowi przykład złych decyzji oraz błędnego podejścia do zagadnienia ochrony obszarów cennych przyrodniczo (MAZURSKI 2009). Z tego powodu dokładna informacja na temat drzewostanu oraz jego kondycji jest bardzo potrzebna w zarządzaniu zasobami przyrodniczymi Parku Narodowego. Stosując zaawansowane technicznie sensory hiperspektralne możliwe jest dokonanie dokładniejszych analiz, niż jest to możliwe w przypadku zastosowania danych wielospektralnych. Teledetekcja hiperspektralna to technologia rejestrująca i przetwarzająca dane pozyskane w sposób zdalny w wąskich zakresach ciągłego widma elektromagnetycznego, w co najmniej 40 ciągłych spektralnie kanałach (GOETZ 2009). Tego rodzaju dane pozwalają na dokładniejsze analizy stanu kondycyjnego i klasyfikację roślin.

Jednymi z pierwszych badań dotyczącym klasyfikacji gatunków drzewiastych z wykorzystaniem danych hiperspektralnych było badanie przeprowadzone przez amerykańską służbę geologiczną USGS¹ w 2003 roku (KOKALY i in. 2003). Sklasyfikowano osiem klas pokrycia terenu w lasach Parku

¹USGS — United States Geological Survey

Narodowego Yellowstone wykorzystując dane z hiperspektralnego skanera lotniczego AVIRIS. Dokonano klasyfikacji zbiorowisk modrzewia, świerka, sosny i osiki. Wynikiem prac była mapa drzewostanu wybranego fragmentu Parku Narodowego Yellowstone o dokładności całkowitej 74,1%, i współczynnika kappa 0,62. Najlepsze wyniki osiągnięto dla sosny wydumowej. Badania zespołu SHEN (2010) potwierdziły wysoką skuteczność metody SAM² w klasyfikowaniu obszarów leśnych oraz wysoką przydatność klasyfikatora SVM. Stwierdzono również znaczącą przewagę SVM³ nad innymi algorytmami klasyfikacji w przypadku klasyfikowania roślin na różnych etapach cyklu fenologicznego (SHEN i in. 2010). Badania przeprowadzone przez Zagajewskiego w 2010 roku na obszarze Tatrzańskiego Parku Narodowego z wykorzystaniem danych z sensora hiperspektralnego DAIS 7915 pozwoliły na sklasyfikowanie 42 różnych zbiorowisk roślinnych i typów pokrycia terenu z dokładnością całkowitą powyżej 85%. Praca ta zaprezentowała przydatności wysokorozdzielczych danych hiperspektralnych w klasyfikacji różnicowanych zbiorowisk roślinności górskiej (ZAGAJEWSKI 2010). Wysoka przydatność danych hiperspektralnych została również dowiedziona przez MARCINKOWSKĄ i in. (2014). Autorzy sklasyfikowali roślinność nieleśną Karkonoskiego Parku Narodowego z wykorzystaniem SVM i danych hiperspektralnych APEX, które również wykorzystano w tej pracy (MARCINKOWSKA i in. 2014).

Celem niniejszej pracy jest sklasyfikowanie sześciu wybranych gatunków drzewiastych rosnących na dwóch obszarach badawczych znajdujących się na terenie Karkonoskiego Parku Narodowego. W pracy wybrano obszary charakteryzujące się najbardziej zróżnicowanym pod względem składu gatunkowego drzew. Z tego powodu wybrano dwa obszary znajdujące się w środkowej części KPN. Jako obszar pierwszy wybrano enklawę KPN Góra Chojnik. Obszar drugi znajduje się kilka kilometrów na południe i obejmuje północne części

KPN w pobliżu wsi Jagniątków (Ryc.1). Oba obszary są porośnięte głównie przez drzewostany bukowe i świerkowe. Obszar Góry Chojnik jest porośnięty przez nieliczne grupy sosny głównie na południowym stoku.

METODY BADAŃ

Dane wykorzystane w tej pracy zostały pozyskane 10 września 2012 roku w trakcie kampanii lotniczej przeprowadzonej w ramach projektu HyMountEcos⁴. Wykorzystano nowoczesny lotniczy skaner hiperspektralny APEX⁵ (Tab. 1, ITTEN i in. 2008). Zobrazowanie wykorzystane w pracy posiada 288 kanałów spektralnych w zakresie 380-2500 nm oraz rozdzielczość przestrzenną 1,75 m. Dane zostały przetworzone przez firmę VITO, która zajęła się ich przetworzeniem, korekcją oraz przygotowaniem do analizy. W ramach przetworzeń wykonano korekcję radiometryczną, geometryczną oraz topograficzną danych. Dane nie zostały poddane korekcji atmosferycznej.


Dane hiperspektralne ze względu na dużą ilość informacji wynikającą z dużej ilości kanałów oraz szerokiego zakresu zbierania spektrum są trudniejsze w przetwarzaniu. Mnogość kanałów znacznie wydłuża proces klasyfikacji oraz dostarcza wielu problemów sprzętowych z tym związanych. Z tego względu zdecydowano się na procedurę zmniejszenia liczby kanałów bez znacznego zmniejszenia ilości informacji. W tym celu przeprowadzono analizę informacyjności kanałów zobrazowania. Polegała ona na wielokrotnych klasyfikacjach obszaru Góra Chojnik. Liczba klasyfikacji odpowiadała liczbie kanałów w zobrazowaniu APEX. Za każdym razem zabierano z klasyfikowanego obrazu jeden kanał tak, by ocenić, jaki wpływ na całkowitą dokładność klasyfikacji ma brak danego kanału. Spadek dokładności danej klasyfikacji oznacza, że dany kanał zawiera istotne dane z punktu widze-

² SAM – Spectral Angel Mapper

³ SVM – Support Vector Machines

⁴ Hyperspectral Remote Sensing for Mountains Ecosystems

⁵ APEX - Airborne Prism Experiment. Jest to wysokorozdzielczy skaner przemiatający powstały w wyniku współpracy RSL (Uniwersytet w Zurichu, Szwajcaria), DLR oraz firmy VITO, które uzyskały wsparcie finansowe od European Space Agency. Skaner ukończono w 2008 roku po trwającym 15 lat procesie planowania i projektowania nowego skanera hiperspektralnego




Ryc. 1. Obszar badań (białymi kwadratami zaznaczono obszary badawcze Góra Chojnik oraz Jagniątków).

nia pracy. W wyniku tej procedury wybrano 40 najlepszych kanałów (powodujących największy spadek dokładności ogólnej podczas analizy informacyjności). Wybranymi kanałami były (numer kanały APEX, długość fali): 64 (0.7248 μm); 59 (0.7061 μm); 139 (1.2575 μm); 62 (0.7172 μm); 73 (0.7623 μm); 146 (1.3256 μm); 196 (1.7846 μm); 6 (0.4711 μm); 60 (0.7098 μm); 63 (0.7210 μm); 108 (0.9689 μm); 134 (1.2090 μm); 136 (1.2284 μm); 138 (1.2478 μm); 141 (1.2769 μm); 159 (1.4509 μm); 8 (0.49 μm); 10 (0.5092 μm); 11 (0.5181 μm); 13 (0.5336 μm); 14 (0.5473 μm); 23

(0.5866 μm); 27 (0.6041 μm); 30 (0.6183 μm); 35 (0.6323 μm); 40 (0.6458 μm); 43 (0.6544 μm); 45 (0.6602 μm); 65 (0.7288 μm); 68 (0.7408 μm); 70 (0.7492 μm); 77 (0.7807 μm); 122 (1.0945 μm); 132 (1.1897 μm); 140 (1.2672 μm); 158 (1.4413 μm); 177 (1.6184 μm); 195 (1.7761 μm); 224 (2.0083 μm); 225 (2.0159 μm). Liczba wybranych kanałów została umotywowana badaniami Pal i Mather (2006) w trakcie których uznano 40 kanałów za najlepszy kompromis pomiędzy czasem klasyfikacji, a jej dokładnością.

W pracy wykorzystano Support Vector Machines (SVM) jako



Ryc. 2. Obszar badawczy 1 (Góra Chojnik). Obszary poza terenem KPN wymaskowano.

algorytm klasyfikacyjny zaimplementowany w oprogramowaniu ENVI 5. Wybór SVM został podyktowany umiejętnością generalizacji, wysoką dokładnością klasyfikacji (w porównaniu z innymi metodami), umiejętnością znajdowania optymalnych rozwiązań i stosunkowo niewielkim wysiłkiem podczas etapu projektowania i trenowania. SVM osiąga najlepsze wyniki dla danych o bardzo wysokiej rozdzielczości przestrzennej (DALPONTE i in. 2009). Zdecydowano się zastosować *linear kernel* podczas klasyfikacji ze względu na najlepsze wyniki, co potwierdzają też inne badania (MARCINKOWSKA i in. 2014). Do wyznaczenia poligonów wzorcowych i walidacyjnych posłużono się mapą roślinności potencjalnej KPN, wykonanej przez BULIGL oraz wynikami badań terenowych przeprowadzonych w sierpniu 2013 roku. Wyznaczone poligony miały od 150 do 1000 pikseli. W przypadku drzew rzadziej występujących (brzoza, sosna, modrzew, olcha) mała powierzchnia występowania uniemożliwiła uzyskanie większej liczby pikseli wziętych do klasyfikacji. W pracy skupiono

się na sześciu gatunkach drzew, którymi były: świerk, buk, brzoza, modrzew, olcha oraz sosna.

WYNIKI

W wyniku przeprowadzonych klasyfikacji uzyskano dwa obrazy poklasyfikacyjne. Klasyfikacja terenu Góra Chojnik użyła (Ryc. 2) dokładność całkowitą na poziomie 83% oraz współczynnik kappa 0,77. Najlepiej sklasyfikowanymi klasami były 'świerk' oraz 'olcha'. Oba gatunki sklasyfikowano z dokładnością powyżej 90% (Tab. 2). Warty uwagi jest fakt znacznie większej liczby poligonów klasyfikacyjnych dla klasy 'świerk', co czyni łatwiejszym uzyskanie większej dokładności klasyfikacji dla tej klasy. Wynika to z większej próbki danych do uczenia, co przekłada się na lepsze wyuczenie, a zatem większą szansę na poprawne sklasyfikowanie danej klasy. Liczba poligonów klasyfikacyjnych jest podyktowana stosunkiem występowania sklasyfikowanych gatunków

	VNIR	SWIR
Zakres obrazowania	380 – 971,7 nm	941,2 – 2501,5 nm
Liczba kanałów spektralnych	Do 334	198
Rozdzielczość spektralna	0,6 – 6,3 nm	6,2 – 11 nm
Pole widzenia (FOV)	28°	
Chwilowe pole widzenia (IFOV)	0,028° (≈ 0,5 mrad)	
Rozdzielczość terenowa	1,75metra	

Tab. 1. Charakterystyki skanera APEX (za Poop i in. 2012)

oraz dostępnością danych pozyskanych podczas prac terenowych. Najgorzej sklasyfikowano klasę ‘buk’ dla której uzyskano dokładność 70%. Analiza wyników poklasyfikacyjnych sklasyfikowano klasy ‘modrzew’ i ‘brzoza’. Wynika to z niewielkiej liczby dostępnych poligonów klasyfikacyjnych oraz sporadyczności występowania w przypadku modrzewia. Po-

	Świerk	Buk	Modrzew	Olcha	Brzoza	Sosna
Świerk	91,65	15,61	6,63	1,22	0,00	3,65
Buk	4,87	70,00	1,06	0,00	3,10	12,42
Modrzew	3,48	2,44	79,84	5,31	0,00	2,65
Olcha	0,00	1,95	5,04	90,61	11,63	0,41
Brzoza	0,00	2,20	0,27	1,22	80,62	0,61
Sosna	0,00	7,80	7,16	1,63	4,65	80,24

Dokładność całkowita: 82,75% współczynnik Kappa 0,77


Tab. 2. Macierz błędów dla obszaru 1 (Góra Chojnik). Uzyskane wyniki z klasyfikacji porównane zostały względem wzorców terenowych (wartości w wierszach wyrażają wynik klasyfikacji, w kolumnach zawarte są wartości z danych referencyjnych). Wartości wyrażone są w procentach.

przedstawionych w macierzy błędów (Tabela 2.) wskazała, że część poligonów została niepoprawnie sklasyfikowania, jako klasa ‘świerk’ (15%), co wpłynęło na dokładność klasyfikacji w przypadku tej klasy. Pozostałe trzy klasy sklasyfikowano w dokładnością około 80%. Klasy te dotyczą gatunków sporadycznie występujących na obszarze Góry Chojnik, przez co możliwe było wyznaczenie niewielkiej liczby poligonów klasyfikacyjnych dla tych klas.

Klasyfikacja terenu w okolicach Jagniątkowa (Ryc. 3) uzyskała dokładność całkowitą 83% oraz współczynnik kappa 0,77. Najlepiej sklasyfikowano klasę ‘sosna’ (Tabela 3). Dokładność dla klas ‘świerk’ i ‘buk’ wynosiła w okolicach 90%. Najgorzej

wyższe klasy były ze sobą mylone w 13 do 16 procent. Fakt ten niewątpliwie wpłynął na końcowy wynik. Zaobserwowano niższe dokładności klasyfikacji dla gatunków rzadziej występujących na obszarze badań. Wynika to z niewielkiej liczby danych (mniej pikseli treningowych) dla tych gatunków (brzoza, olcha, modrzew, sosna). W przypadku modrzewia zaobserwowano, że rosną one w niewielkich grupach (zwykle w linii prostej). Wynika to z praktyk stosowanych przez leśników. Modrzewie z racji ich odporności, sadzono jako ochronę przed wiatrem dla gatunków rosnących wolniej.

Czytając macierz błędów należy kupić się na analizowaniu poszczególnych kolumn tabeli. Pogrubione liczby wskazują



Ryc. 3. Obszar badawczy 2 (Jagniątków). Obszary poza terenem KPN wymaskowano.

na dokładność producenta dla danej klasy. Pozostałe liczby wskazują, jaki procent pikseli walidacyjnych znalazł się w innej klasie, mimo że był pikselem walidacyjnym dla danej klasy. Uproszczając można w ten sposób stwierdzić, jaki procent pikseli został przypisany do innej klasy przez algorytm klasyfikacyjny, niż powinien. Na przykładzie klasy 'buk' w tabeli 3, można stwierdzić, że ta klasa uzyskała 88% dokładności producenta dla tej klasy oraz że niewłaściwie do klasy 'brzoza' 7% pikseli walidacyjnych należących do klasy buk. Podsumowując dla obu obszarów badawczych uzyskano wy-

sokie dokładności dla klasy 'świerk' (powyżej 90%). Pozostałe klasy charakteryzują się dużą fluktuacją dokładności sięgającą 30%, w zależności od klasyfikowanego obszaru.

DYSKUSJA UZYSKANYCH WYNIKÓW

W pracy uzyskano wysoką dokładność całkowitą klasyfikacji (83% w obu przypadkach). W badaniu osiągnięto dokładność powyżej 91% dla klasy 'świerk' i 80% dla klasy 'sosna'. Najlepsze wyniki uzyskano dla klas 'świerk' i 'sosna', a naj-

	Świerk	Buk	Modrzew	Olcha	Brzoza	Sosna
Świerk	91,71	0,00	0,00	0,00	0,00	0,85
Buk	0,00	88,04	9,87	14,20	10,39	0,47
Modrzew	0,00	1,15	58,48	4,32	16,23	0,57
Olcha	0,00	3,17	3,29	81,48	1,08	0,19
Brzoza	0,00	7,06	13,16	0,00	59,31	1,32
Sosna	8,29	0,58	15,19	0,00	12,99	96,60

Dokładność całkowita: 82,64% współczynnik Kappa 0,77

Tab. 3. Macierz błędów dla obszaru 2 (Jagniątków). Uzyskane wyniki z klasyfikacji porównane zostały względem wzorców terenowych (wartości w wierszach wyrażają wynik klasyfikacji, w kolumnach zawarte są wartości z danych referencyjnych). Wartości wyrażone są w procentach.

gorsze dla klas 'modrzew' oraz 'brzoza'. Lepsze wyniki uzyskano dla gatunków drzew rosnących w jednorodnych skupiskach. Drzewa rosnące pod koroną większych drzew innego gatunku lub też punktowo lub liniowo na ogół klasyfikowano gorzej (klasy 'brzoza' i 'modrzew'). W zależności od analizowanego obszaru uzyskano różne dokładności klasyfikacji dla poszczególnych gatunków. Wynika to z różnic w liczbie dostępnych poligonów treningowych i samego występowania danego gatunku drzewiastego na analizowanym obszarze. Badania tego typu są zwykle realizowane przy pomocy danych pomocniczych uzupełniających dane hiperspektralne. Wysokie dokładności klasyfikacji drzewostanu zaobserwowano podczas badań prowadzonych w Alpach (DALPONTE i in. 2012). Modrzew sklasyfikowano z dokładnością 58% mimo wspomaganie zobrazowania hiperspektralnego lidarem. Był on mylony ze świerkiem oraz sosną. Warto jednak zaznaczyć, że najgorzej klasyfikowane klasy miały zdecydowanie mniejszą liczbę poligonów treningowych.. Trzeba podkreślić, że te badanie wykorzystywał skaner hiperspektralny o zakresie 400-1000nm, więc o znacznie mniejszym zakresie zobrazowania, niż skaner APEX. Podobne rezultaty osiągnięto w tej pracy, chociaż mniejsze dokładności dla sosny na obszarze 1 zostały spowodowane trudnościami w uzyskaniu dużej liczby poligonów wzorcowych. Podczas badania przeprowadzonego przez Jones (2010) wykorzystano dane AISA oraz lidar do klasyfikacji gatunków drzewiastych porastających zachodnie

wybrzeże Kanady. Również i w tym badaniu zdecydowano się na wybranie 40 najlepszych kanałów zobrazowania do klasyfikacji. Używając tylko danych hiperspektralnych autorzy uzyskali lepszą dokładność dla gatunków liściastych, niż iglastych. Otrzymano dokładności dla olchy 67,7% i dla sosny 65,9%. Autorzy podkreślają, że dodanie danych lidarowych podnosi dokładność klasyfikacji o 14%. Stwierdzają również, że wyniki uzyskane tylko z analizy danych hiperspektralnych umożliwiają rozpoznanie indywidualnych gatunków drzewiastych (JONES i in. 2010).

Powyższe wyniki pozwalają stwierdzić, że możliwe jest klasyfikowanie drzewostanu wykorzystując do tego dane hiperspektralne APEX uzyskując dokładności klasyfikacji dla poszczególnych klas od 59,31% do 96,60%. Szeroki zakres zobrazowania pozwala na uzyskanie wyników porównywalnych z tymi uzyskanymi z syntezy danych lidarowych i skanera hiperspektralnego o mniejszym zakresie skanowania (NIR). Dalsze badania skupią się na klasyfikowaniu całego obszaru Karkonoskiego Parku Narodowego oraz oceny kondycji poszczególnych zbiorowisk.

PODZIĘKOWANIA

Autorzy pragną podziękować European Facility For Airborne Research Transnational Access (EUFAR TA), która ufundowała kampanię lotniczą oraz Fundacji Uniwersytetu Warszawskie-

go za finansowe wsparcie badań terenowych podczas projektu HyMountEcos. Pragniemy również podziękować niemieckiej agencji kosmicznej DLR za wykonanie nalogu, firmie VITO za przetworzenie danych APEX, administracji i personelowi Karkonoskiego Parku Narodowego i Krkonošský Národní Park za wsparcie w postaci dodatkowych danych i współ-

pracę. Dziękujemy też Instytutowi Geografii i Planowania przestrzennego Uniwersytetu Karola w Pradze za współpracę podczas badań.

„Praca naukowa finansowana ze środków budżetowych na naukę w latach 2013-2017 jako projekt badawczy w ramach programu pod nazwą „Diamentowy Grant”.

LITERATURA

- ASHUNTOSH S. 2012: MONITORING FORESTS: A NEW PARADIGM OF REMOTE SENSING & GIS BASED CHANGE DETECTION, *JOURNAL OF GEOGRAPHIC INFORMATION SYSTEM*, VOL. 4: 470-478.
- 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*, VOL. 113: 2345-2355.
- 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*, VOL. 123: 258-270.
- GOETZ A. F. H. 2009: THREE DECADES OF HYPERSPECTRAL REMOTE SENSING OF THE EARTH: A PERSONAL VIEW, *REMOTE SENSING OF ENVIRONMENT*, VOL. 113: S5-S16.
- ITTEN K. I., DELL'ENDICE F., HUENI A., KNEUBUHLER M., SCHLAPFER D., ODERMATT D., SEIDEL F., HUBER S., SCHOFFER J., KELLENBERGER T., BUHLER Y., D'ODORICO P., NIEKE J., ALBERTI E. & MEULEMAN K. 2008: APEX – THE HYPERSPECTRAL ESA AIRBORNE PRISM EXPERIMENT, *SENSORS*, VOL. 8: 6235–6259.
- JADCZYK P. 2009: NATURAL EFFECTS OF LARGE-AREA FOREST DECLINE IN THE WESTERN SUDETEN, *ENVIRONMENT PROTECTION ENGINEERING*, VOL. 35, NO. 1: 49-56.
- JONES G., COOPS 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*, VOL. 114: 2841-2852.
- KOKALY R.F., DESPAIN D.G., CLARK R.N. & LIVO K.E. 2003: MAPPING VEGETATION IN YELLOWSTONE NATIONAL PARK USING SPECTRAL FEATURE ANALYSIS OF AVIRIS DATA, *REMOTE SENSING OF ENVIRONMENT*, VOL. 84: 437-456.
- MARCINKOWSKA A., ŻAGAJEWSKI B., OCHTYRA A., JAROCIŃSKA A., RACZKO E., KUPKOVA L., STYCH P. & MEULEMAN K. 2014: MAPPING VEGETATION COMMUNITIES OF THE KARKONOSZE NATIONAL PARK USING APEX HYPERSPECTRAL DATA AND SUPPORT VECTOR MACHINES, *MISCELLANEA GEOGRAPHICA*, VOL. 18, NO. 2: 1-7, DOI: 10.2478/MGRSD-2014-0007.
- MAZURSKI K. R. 2009: DESTRUCTION OF FORESTS IN THE SUDETES: THIRTY YEARS LATER, W: GEODAYS LIBREC 2008. BOOK OF PROCEEDINGS. TECHNICAL UNIVERSITY OF LIBREC (CZ): 30-41.
- NAGENDRA H., LUCAS R., HONDRADO J. P., JONGMAN R. H. G., TARANTINO C., ADAMO M. & MAIROTAF P. 2013: REMOTE SENSING FOR CONSERVATION MONITORING: ASSESSING PROTECTED AREAS, HABITAT EXTENT, HABITAT CONDITION, SPECIES DIVERSITY, AND THREATS, *ECOLOGICAL INDICATORS*, VOL. 33: 45– 59.
- PAL M., MATHER P.M. 2006: SOME ISSUES IN THE CLASSIFICATION OF DAIS HYPERSPECTRAL DATA, *INTERNATIONAL JOURNAL OF REMOTE SENSING*, VOL. 27, NO. 14: 2895-2916.
- POPP C., BRUNNER D., DAMM A., VAN ROOZENDAEL M., FAYT C. & BUCHMANN B. 2012: HIGH-RESOLUTION NO2 REMOTE SENSING FROM THE AIRBORNE PRISM EXPERIMENT (APEX) IMAGING SPECTROMETER, *ATMOSPHERIC MEASUREMENT TECHNIQUES*, VOL. 5: 2211-2225.
- SHEN G., SAKAI K. & HOSHINO Y. 2010: HIGH SPATIAL RESOLUTION HYPERSPECTRAL MAPPING FOR FOREST ECOSYSTEM AT TREE SPECIES LEVEL, *AGRICULTURAL INFORMATION RESEARCH*, VOL. 19: 71–78.
- ŻAGAJEWSKI B., 2010: OCENA PRZYDATNOŚCI SIECI NEURONOWYCH I DANYCH HIPERSPEKTRALNYCH DO KLASYFIKACJI ROŚLINNOŚCI TATR WYSOKICH, *TELEDETEKCJA ŚRODOWISKA*, NO. 43, SS. 113