



## Analiza możliwości wykorzystania obrazów hiperspektralnych HySpex do inwentaryzacji drzewostanów leśnych Puszczy Białowieskiej

*An analysis of use of hyperspectral images  
HySpex for an assessment of forest stand inventory in Białowieza Forest*

Paulina BARTKOWIAK  
Katarzyna OSIŃSKA-SKOTAK

Faculty of Geodesy and Cartography,  
Warsaw University of Technology  
Warsaw, Poland

### Streszczenie

W artykule przedstawiono analizę możliwości zastosowania zobrazowań hiperspektralnych HySpex do wykonania map rozmieszczenia poszczególnych gatunków drzewostanów leśnych, na przykładzie Puszczy Białowieskiej.

W tym celu przeprowadzono kilka wariantów klasyfikacji przy użyciu metody *Spectral Angle Mapper*. Całą procedurę wykonano w oprogramowaniu ENVI 5.3 (*Environmental for Visualizing Images*), w module specjalnie dedykowanym danym hiperspektralnym. Metodyka badawcza obejmuje: wstępne przetwarzanie obrazów, tworzenie wzorców do klasyfikacji, procedurę klasyfikacji SAM i finalną ocenę dokładności uzyskanych wyników. Ostatecznie otrzymano mapy rozmieszczenia gatunków drzew w obrębie badanego szeregu hiperspektralnego. Dokładność map została oszacowana na podstawie danych pochodzących z opisów taksacyjnych. Ogólna dokładność klasyfikacji gatunków drzew na podstawie obrazów hiperspektralnych HySpex wyniosła ok. 77%. Najlepiej sklasyfikowane zostały olcha, sosna i dąb, w pozostałych przypadkach (brzoza i świerk) zaobserwowano zróżnicowane dokładności producenta i użytkownika, co może wynikać zarówno z charakteru drzewostanów leśnych, jak i pól testowych wykorzystanych do oceny dokładności wyników klasyfikacji.

Na podstawie wygenerowanych map pokrycia terenu można wskazać obszary leśne o zróżnicowanym składzie gatunkowym fragmentu Puszczy Białowieskiej. Wykorzystanie danych teledetekcyjnych HySpex stanowi duży potencjał w zabiegach inwentaryzacyjnych lasu. Aktualizacja opisów taksacyjnych, modelowanie zjawisk czy symulacja scenariuszy dla obszarów leśnych technikami zdalnymi na potrzeby praktyki leśnej wydaje się technicznie i ekonomicznie uzasadnione.

### Abstract

This paper contains an analysis of use of hyperspectral images HySpex to create maps of tree species distribution within Białowieza Forest.

To this end, a couple of variants of image classification with the use of *Spectral Angle Mapper* (SAM) method were carried out. Whole procedure was conducted in ENVI software environment (*Environmental for Visualizing Images*) intended for this kind of dataset. In the beginning, the classification process involves the hyperspectral images *pre processing* and training samples collection. Next, SAM algorithm as well as an estimation of precision of the classification were performed. Finally, land cover layouts for tree species distribution within the extent of hyperspectral array were generated. The accuracy of tree species detection was estimated on the basis of data derived from forest taxations. Overall accuracies of classification based on HySpex imagery were approximately 77%. The highest possible precisions were obtained for alder, pine and oak tree stands. In other cases (birch and

spruce) diversified results for producer's and user's accuracy were achieved, which could be explained by various kinds of forest stands and characteristics of test samples used for an assessment of image classification results.

On the grounds of the land cover layouts it is workable to indicate forest areas with diversified tree species distribution within Białowieża Forest. Furthermore, remote sensing data obtained with the use of HySpex scanner has a lot of potential in forest inventory. An actualization of inventory database, woodland modelling and simulations of forest phenomena seem to be technically and economically reasoned.

**Keywords:** HySpex, Białowieża Forest, ENVI, Spectral Angle Mapper, tree species detection

**Słowa kluczowe:** HySpex, Puszcza Białowieża, ENVI, Spectral Angle Mapper, detekcja gatunków drzew

## 1. Wprowadzenie

### Charakterystyka drzewostanów Puszczy Białowieżskiej

Puszcza Białowieża, znana jako największy i najlepiej zachowany naturalny kompleks leśny na niżu środkowo-wschodniej Europy, jest jednym z najcenniejszych rejonów na świecie, gdzie niegdyś rozciągał się obszar rozległych lasów naturalnych w centralnej części kontynentu europejskiego. Powierzchnia kompleksu zajmuje około 1500 km<sup>2</sup> (SOKOŁOWSKI, 2004). Część należąca do Polski ma powierzchnię 635 km<sup>2</sup>, natomiast pozostały obszar o powierzchni 875 km<sup>2</sup> leży na terenie Białorusi.

Bogactwo flory Puszczy Białowieżskiej należy do jednych z najcenniejszych wśród kompleksów leśnych środkowo-wschodniej Europy. W przeciwieństwie do innych lasów, występuje tutaj duża różnorodność gatunkowa roślin (sosna pospolita, świerk pospolity, jodła pospolita, dąb szypułkowy, dąb bezszypułkowy, olcha czarna, brzoza brodawkowata, brzoza czarna, grab pospolity, jesion wyniosły, lipa drobnolistna, wierzba iwa i topola). Na obrzeżach lasów Puszczy rośnie też 18 gatunków innych drzew, które zostały wprowadzone w sposób sztuczny. Należą do nich m.in. modrzew europejski, buk zwyczajny, lipa szerokolistna, olsza szara, klon jaworowy

i wiśnia ptasia. Zgodnie z danymi inwentaryzacyjnymi dotyczącymi udziału występujących drzewostanów na obszarze Puszczy, dominującymi gatunkami jest sosna pospolita (27,04% powierzchni) oraz świerk pospolity, zajmujący nieco powyżej ¼ całego obszaru. Na trzeciej pozycji plasuje się olsza czarna (blisko 20% łącznej powierzchni), a po niej dąb szypułkowy (niemal 12%). Szczegółowe zestawienie odsetka najpowszechniej występujących drzewostanów dla Puszczy oraz Białowieżskiego Parku Narodowego przedstawiono w tabeli 1.

Lasy zajmujące 96% powierzchni oraz odznaczające się wielogatunkowym składem i różnowiekową strukturą stanowią istotę funkcjonowania Puszczy Białowieżskiej. Większość zbiorowisk leśnych cechuje się typem mieszanym bądź iglastym. Największy powierzchniowo obszar porastają grądy, zajmując blisko połowę powierzchni Puszczy. Drugie, co do wielkości zbiorowisko leśne Puszczy Białowieżskiej to bory. Lasy te zajmują 37% całej powierzchni (<http://bpn.com.pl/>).

Kompleksy leśne Puszczy Białowieżskiej podlegają ciągłym oraz stosunkowo dynamicznym przemianom wywołanym czynnikami biotycznymi, abiotycznymi oraz antropopresją. Wraz z upływem czasu zbiorowiska leśne przeobrażają się – przekształcaniem ulegają gaba-



Rys. 1. Lokalizacja Puszczy Białowieżskiej (źródło: zasoby map Esri; <http://darz-bor.info/>, [http://stary rowerowy.bialystok.pl/img/news/mapa\\_trasy\\_wschodniej.jpg](http://stary rowerowy.bialystok.pl/img/news/mapa_trasy_wschodniej.jpg))

Fig. 1. Location maps of Białowieża Forest (source: Esri maps resource; <http://darz-bor.info/>, [http://stary rowerowy.bialystok.pl/img/news/mapa\\_trasy\\_wschodniej.jpg](http://stary rowerowy.bialystok.pl/img/news/mapa_trasy_wschodniej.jpg))

Tab. 1. Procentowy udział głównych drzewostanów na obszarze Puszczy Białowieskiej oraz Białowieskiego Parku Narodowego (źródło: SOKOŁOWSKI, 2004)

Table 1. Major tree stands within Białowieża Forest (source: SOKOŁOWSKI, 2004)

Gatunek drzewa	Puszcza Białowieska	Białowieski Park Narodowy
Sosna	27,04%	20,57%
Świerk	25,30%	17,89%
Olsza	19,56%	17,41%
Dąb	11,87%	16,08%
Brzoza	8,00%	6,35%
Grab	3,51%	10,00%
Jesion	2,81%	5,80%
Klon	0,39%	2,08%
Lipa	0,72%	2,30%
Osika	0,80%	1,50%
Wierzba iwa	-	0,02%

ryty i skład gatunkowy drzewostanów (SOKOŁOWSKI, 2004). Obecnie, ze względu na inwazję kornika drukarza, lasy świerkowe masowo zamierają, w wyniku czego obszary porośnięte przez drzewostan stają się zwaliskami złomów świerczyny (Fig. 2). Zgodnie z danymi Lasów Państwowych, zaktualizowanymi na styczeń 2016 roku, inwazja kornika dotknęła blisko pół miliona drzew, co odpowiada powierzchni równej 4 tys. hektarów, stanowiącej własność Lasów Państwowych. Masowe zamieranie świerczyny obserwuje się również na obszarze Białowieskiego Parku Narodowego (<http://www.lasy.gov.pl/informacje/aktualnosci/puszcza-bialowieska>).

Dynamika degradacji drzewostanu wywołana zerowaniem kornika drukarza jest bardzo duża. Szacuje się, że w ciągu miesiąca zasiedlone przez owada drzewo świerkowe zamiera, a jak podkreślają specjaliści skala zjawiska jest na tyle poważna, że inwazja szkodników dotyka również drzewa dojrzałe i zdrowe. Należy zwrócić uwagę również na fakt, że kornik drukarz zaczął atakować również inne gatunki drzew, w tym m.in. modrzew czy sosnę. Do zagrożonych obszarów należą także cenne siedliska chronione z mocy prawa w ramach programu Natura 2000.



Rys. 2. Zamierające lasy świerkowe, zaatakowane przez kornika drukarza na obszarze Puszczy Białowieskiej (źródło: <http://www.lasy.gov.pl/informacje/aktualnosci/puszcza-bialowieska>)

Fig. 2. Destroyed spruce forest infested with bark beetle invasion in Białowieża Forest (source: <http://www.lasy.gov.pl/informacje/aktualnosci/puszcza-bialowieska>)

Inną kluczową kwestią, związaną z zarządzaniem i monitoringiem Puszczy Białowieskiej jest zmienność składu gatunkowego drzewostanów (PALUCH, 2014). Stwierdzono, że w ostatnich dziesięcioleciach udział gatunkowy w budowie kompleksów leśnych dla boru świeżego, boru mieszanego oraz grądów uległ znacznym przeobrażeniom. W swoim opracowaniu Paluch (2014) podkreśla ekspansję niektórych gatunków, m.in. grabu zwyczajnego, jak również zauważa niekorzystną redukcję udziału jesionu, świerka, sosny czy brzozy w tworzeniu drzewostanów Puszczy Białowieskiej.

Na podstawie obecnych zagrożeń, z jakimi zmagają się Puszcza Białowieska wyraźnie widać, że las jest ewoluującą materią, która ulega ciągłym przemianom biologicznym. Przytoczone problemy świadczą o ciągłej potrzebie monitoringu drzewostanów leśnych. Wiedza o tych procesach jest więc jednym z najbardziej kluczowych elementów prowadzenia zrównoważonej gospodarki leśnej. Obecnie, aby zapewnić kompleksowy monitoring siedlisk leśnych oraz bieżącą aktualizację składu gatunkowego, tradycyjne metody inwentaryzacji lasów nie należą do najefektywniejszych metod badania dynamiki zmian powierzchni ziemi. Istnieje zatem potrzeba implementacji alternatywnych technik obserwacji Ziemi, które zapewnią skuteczną detekcję zagrożenia w krótkim przedziale czasowym.

#### Zdalne techniki obserwacji siedlisk leśnych

Szybki rozwój technologii geoinformatycznych sprawia, że dane teledetekcyjne stanowią cenne i rzetelne źródło informacji o drzewostanach. W odróżnieniu do pomiarów naziemnych, które wymagają dużych nakładów pracy, lotnicze zobrażenia teledetekcyjne, w tym dane hiperspektralne, umożliwiają wydajne i szybkie pozyskanie informacji o terenie. Techniki te dostarczają produkty dobrej jakości o wysokiej rozdzielczości przestrzennej i radiometrycznej, które mogą stanowić konkurencję dla części prac realizowanych obecnie tradycyjnymi metodami inwentaryzacji lasów.

Wraz z postępowaniem technologicznym sensory optyczne są nieustannie udoskonalane. Dzięki obecności satelitarnych systemów optycznych charakteryzujących się



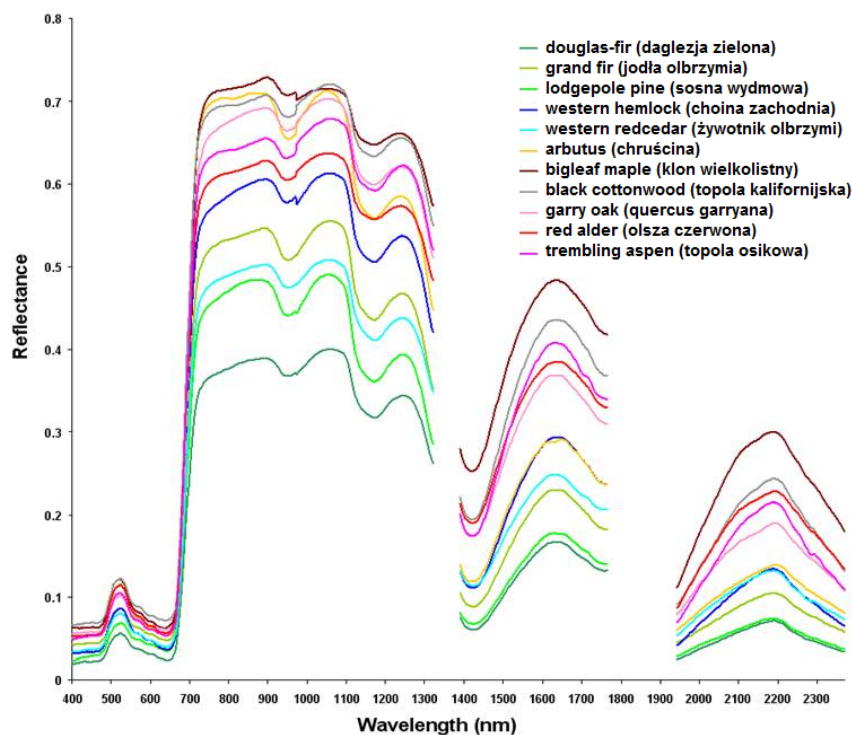
niską oraz wysoką rozdzielczością przestrzenną możliwe jest monitorowanie powierzchni lasów w skali globalnej oraz lokalnej.

Obecnie do jednej z najbardziej powszechnych technik pozyskiwania informacji o powierzchni Ziemi należy obrazowanie z pułapu satelitarnego. Począwszy od systemu satelitarnego Landsat aż po wysokorozdzielcze obrazy wielospektralne (pozyskiwane z satelitów GeoEye-1 czy Pleiades), zauważa się mnogość zastosowań pozyskiwanych danych. W przeciwieństwie do naziemnych metod kartowania i monitoringu, sensory wielospektralne umożliwiają w sposób wydajny i ekonomiczny pozyskanie informacji o pokryciu powierzchni leśnych. Potencjał danych obrazowych istnieje również na poziomie klasyfikacji treści obrazów, o czym świadczy chociażby projekt badawczy „ForseenPOMERANIA”. W toku badań, porównując uzyskane wyniki dla danych wielospektralnych RapidEye (ang. *Ground Sample Distance* – GSD = 5 m) z rezultatami otrzymanymi na podstawie zobrażeń zarejestrowanych przez skaner TM (GSD = 30 m) wykazano, że klasyfikacja gatunków drzew z wykorzystaniem danych o wyższej rozdzielczości przestrzennej jest dokładniejsza. Dla klasyfikacji treści obrazów Landsat osiągnięto dokładność 77%, a dla RapidEye – 89% (KÄRGEL i in., 2014).

W kontekście wykonywania szczegółowych analiz tematycznych przewagę nad danymi wielospektralnymi mają zobrażenia super- i hiperspektralne. Skanowanie terenu z pułapu lotniczego lub satelitarnego przy zastosowaniu więcej niż 10 kanałów spektralnych stwarza dogodne warunki do dokładnej klasyfikacji pokrycia terenu. W przeciwieństwie do szerokokanałowych sensorów wielospektralnych, możliwe jest wówczas uzyskanie złożonej informacji o budowie geologicznej podłoża czy stanie gatunkowym roślinności (DALPONTE, BRUZZO-

NE, GIANELLE, 2012; MÖCKEL et al., 2014). Obrazy hiperspektralne pozyskane przy użyciu aparatury lotniczej i skanerów satelitarnych dostarczają tego typu informacji z różną rozdzielczością przestrzenną. Wśród wielu technik teledetekcyjnych systemy hiperspektralne, pracujące w zakresie widzialnym aż po podczerwień krótkofalową, wspomagają zarządzanie ekosystemami leśnymi poprzez monitoring powierzchni leśnych (COATES et al., 2015; HABOUDANE et al., 2004) oraz są niezbędne przy klasyfikacji gatunków drzewostanów (DALPONTE et al., 2013; GHOSH et al., 2014; ZAGAJEWSKI et al., 2005; BARTOLD, 2008). Dzięki gromadzeniu informacji na temat pokrycia terenu jednocześnie w kilkudziesięciu wąskich pasmach promieniowania widzialnego (VIS) i bliskiej podczerwieni (IR) możliwe jest precyzyjne uchwycenie różnic między charakterystykami spektralnymi poszczególnych gatunków drzew. Przykładowe wyniki pomiarów spektrometrycznych dla 11 gatunków drzew, które wykonano na potrzeby automatyzacji procesu detekcji roślinności na terytorium Kanady zaprezentowano na rycinie 3 (<http://irsslab.forestry.ubc.ca/research/>). Dzięki analizie ich przebiegu można wskazać zakresy promieniowania, w których możliwe jest rozróżnienie poszczególnych gatunków.

O potencjale danych hiperspektralnych świadczą liczne prace i projekty badawcze o tematyce leśnej. Przykładem jest np. klasyfikacja gatunków drzew wykonana na podstawie zobrażeń hiperspektralnych pozyskanych z pokładu satelity EO-1 (BARTOLD, 2008). Autor opracowania przeprowadził detekcję trzech gatunków drzew – dębu, sosny i olszy – w różnym przedziale wiekowym (łącznie 7 klas). W trakcie klasyfikacji metodą SAM stwierdził duże podobieństwo spektralne dębu do olchy. Na etapie definiowania pikseli wzorcowych okazało się, że niemożliwe było wskazanie pikseli referencyjnych dla



Rys. 3. Charakterystyki spektralne dla różnych gatunków drzew uzyskane w wyniku pomiarów spektrometrem naziemnym (źródło: <http://irsslab.forestry.ubc.ca/research/>)

Fig. 3. Collected spectral profiles for tree species obtained from full-range spectrometer (source: <http://irsslab.forestry.ubc.ca/research/>)

brzozy, natomiast bez problemu zidentyfikowano te gatunki, które dominowały na badanym obszarze – sosnę oraz dąb. Ponadto w dalszej części pracy zauważono, że algorytm SAM błędnie rozpoznawał wyżej wymienione gatunki z uwzględnieniem ich zróżnicowania wiekowego (BARTOLD, 2008). Mimo dużego wymiaru terenowego piksela (GSD = 30 m) zastosowanych danych Hype- rion oraz gorszego stosunku sygnału do szumu ogólna dokładność klasyfikacji była dość wysoka. Dla 74-ka- nałowego obrazu (poddanego uprzednio transformacji *Minimum Noise Fraction* – MNF) wyniosła ona 88,8%, a dla zobrazowania składającego się z 47 skorelowa- nych kanałów 76,6%. Wysoką dokładność klasyfikacji gatunków można uzyskać także na podstawie danych ze skanerów hiperspektralnych rejestrujących z pułapu lotniczego. W opracowaniu Raczek (2015) podjęto próbę klasyfikacji pięciu gatunków drzew znajdujących się na obszarze Góry Chojnik w Karkonoskim Parku Naro- dowym. Wykorzystując urządzenie APEX pozyskano dane obrazowe z rozdzielczością terenową równą 3,5 m. W klasyfikacji zróżnicowania gatunkowego drzewosta- nów leśnych wykorzystano algorytm wektorów nośnych SVM (*Support Vector Machine*), za pomocą którego moż- liwe było określenie przynależności pikseli obrazu do poszczególnych klas. W pracy przeprowadzono analizę informacyjności obrazu polegającą na wielokrotnych klasyfikacjach dla badanego obszaru. Obraz źródłowy został sklasyfikowany 288 razy, co odpowiadało licz- bie kanałów spektralnych skanera APEX. Procedura redukcji nadwymiarowości danych hiperspektralnych polegała na eliminacji pojedynczych kanałów spektra- lnych, wykonaniu klasyfikacji, a następnie ocenie, jak redukcja kanałów wpłynęła na jakość klasyfikacji. Fi- nalnie, do dalszej ekstrakcji informacji wykorzystano 40 kanałów spektralnych, które stanowią optymalny zestaw do dalszego przetwarzania danych, przy zacho- waniu warunku, że ich dobór nie wpływa negatywnie na wyniki dokładnościowe klasyfikacji (PAL et al., 2006). W wyniku wykonania klasyfikacji uzyskano rozmiesz- czenie przestrzenne pięciu gatunków drzew. Najlepiej zidentyfikowano świerk (83,96%) oraz buk (87,09%), które należały do gatunków dominujących na obszarze badań. Dokładność całkowita klasyfikacji metodą SVM osiagnęła wartość 78,66%.

#### Cel i zakres badań

W związku z ciągłym doskonaleniem zdalnych tech- nik obserwacji powierzchni leśnych, monitoring lasów przy użyciu teledetekcyjnej aparatury obrazowej wydaje się nieodzownym elementem nowoczesnej gospodarki leśnej. Zgodnie z *Instrukcją wykonywania wielkoobsza- rowej inwentaryzacji lasów* (2014) zakres działań wielko- obszarowej inwentaryzacji lasów obejmuje dostarczenie informacji na temat stanu fizycznego drzewostanów, a w szczególności:

- składu gatunkowego,
- struktury wiekowej,
- stanu zdrowotnego,

- budowy pionowej drzewostanów,
- szkód leśnych wraz z przyczyną ich powstania.

Obecnie określenie powyższych wskaźników jest możliwe poprzez implementację zaawansowanych metod teledetekcyjnych. Na uwagę zasługuje nowo- cześnie obrazowanie hiperspektralne, które znajduje powszechne zastosowanie w monitoringu powierzchni zalesionych (BARTOLD, 2008, DALPONTE, 2013, KÄR- GEL i in., 2014). Niniejsza praca wpisuje się w trend badawczy dotyczący zdalnej analizy składu gatunkowego drzewostanów leśnych. Celem niniejszego opracowania była analiza możliwości określenia składu gatunkowe- go Puszczy Białowieskiej za pomocą lotniczych danych hiperspektralnych uzyskanych ze skanera HySpex VNIR-1800. Część badawcza obejmowała wykonanie klasyfikacji drzewostanów leśnych metodą SAM dla dwóch zobrazowań o zredukowanej liczbie kanałów spektralnych. Dzięki zastosowaniu procedury redukcji nadwymiarowości danych możliwe jest badanie wpływu liczby kanałów spektralnych na możliwość rozróżnienia gatunków drzew. Wynikiem ekstrakcji informacji ze zo- brazowań hiperspektralnych są mapy rozmieszczenia zidentyfikowanych drzewostanów leśnych fragmentu Puszczy Białowieskiej.

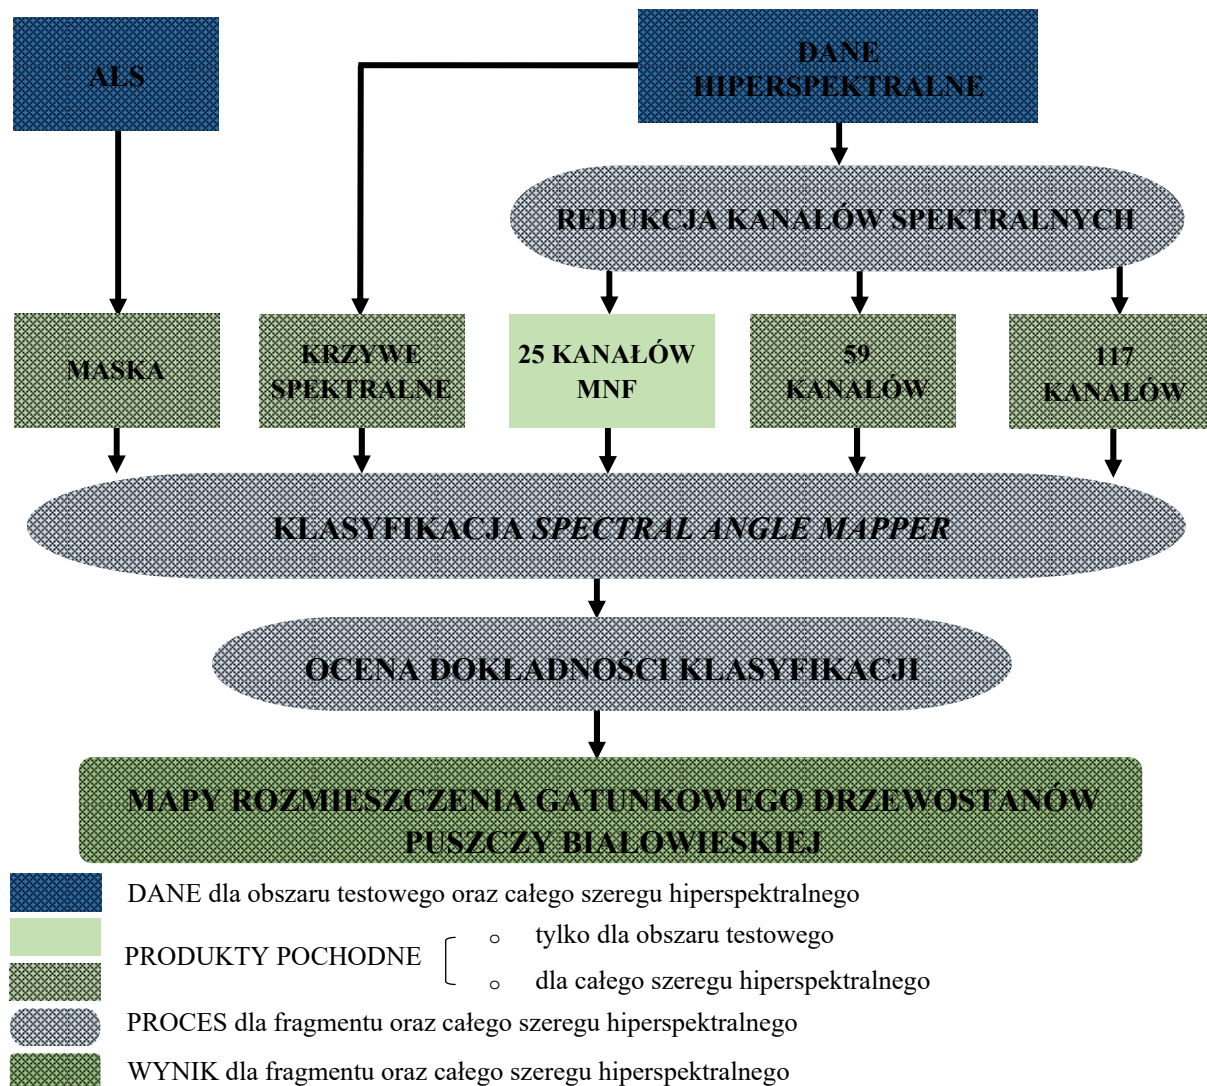
#### 2. Metodyka badawcza

Tematyką niniejszej pracy badawczej była analiza możliwości zastosowania danych hiperspektralnych Hy- Spex do określenia składu gatunkowego drzewostanów wybranego fragmentu Puszczy Białowieskiej. Schemat metodyki i realizacji badań zaprezentowano na rycinie 4. W pierwszym etapie opracowania został przeprowadzony proces redukcji nadwymiarowości kanałów spektralnych danych HySpex, w wyniku którego utworzono trzy zobra- zowania. Kolejny etap części badawczej obejmował anali- zę doboru danych referencyjnych, reprezentujących klasy wzorcowe. Następnie na podstawie wyselekcjonowanych danych wzorcowych oraz utworzonej maski przystąpio- no do klasyfikacji utworzonych wcześniej treści obrazo- wych. W następnym punkcie przeprowadzono analizę dokładności wyników ekstrakcji informacji bazując na wygenerowanych polach testowych. Końcowym etapem klasyfikacji było utworzenie map rozmieszczenia poszce- gólnych gatunków drzew dla analizowanego obszaru.

#### Dane źródłowe i obszar opracowania

W badaniach wykorzystano następujące dane:

- obrazy hiperspektralne uzyskane ze skanera Hy- Spex VNIR-1800,
- numeryczny model pokrycia terenu uzyskany na podstawie danych ALS,
- warstwę wektorową z lokalizacjami drzew pomie- rzonymi w terenie,
- zestaw krzywych spektralnych, który pozyskano przy użyciu spektrometru naziemnego,
- bazę danych SILP (System Informatyczny Lasów Państwowych).



Rys. 4. Schemat blokowy postępowania klasyfikacyjnego  
 Fig. 4. Scheme of the research process


Dane uzyskano dzięki uprzejmości Instytutu Badawczego Leśnictwa w Sękocinie Starym. Zobrazowania te wykonała firma MGGP Aero sp. z o.o. na potrzeby projektu „LIFE+ ForBioSensing PL” ([www.ibles.pl/](http://www.ibles.pl/)). Badania przeprowadzono na obszarze obejmującym jeden szereg zobrazowania hiperspektralnego, zarejestrowany w lipcu 2015 r. o łącznej powierzchni 51,8 km<sup>2</sup> (Fig. 5). Swym zasięgiem odpowiadał on centralnej części Puszczy położonej przy zachodniej granicy Białowieskiego Parku Narodowego.

System sensorów HySpex VNIR-1800 produkcji Norsk Elektro Optik AS rejestruje promieniowanie w 182 kanałach z zakresu widzialnego i bliskiej podczerwieni, z przedziału długości fal 0,4-1,0 μm. Szerokość rejestrowanego pasma wynosi 3,26 nm, a zakres dynamiczny 16 bitów. Przed wykonaniem nalotu kamera została skalibrowana. Otrzymane dane poddano również wstępnemu przetwarzaniu, czyli obrazy zostały poddane korekcji geometrycznej oraz radiometrycznej. Do wykonania korekcji geometrycznej obrazów ze skanera HySpex wykorzystano oprogramowanie PARGE,

dedykowane zobrazowaniom hiperspektralnym. Program ten analizuje geometryczne zależności pomiędzy położeniem skanera a terenem, biorąc pod uwagę odmienną geometrię obrazu rejestrowanego przy użyciu skanera linijkowego typu *pushbroom*. W rezultacie, po wykonaniu korekcji geometrycznej i interpolacji metodą najbliższego sąsiada, otrzymano przepróbkowany obraz w rzucie ortogonalnym, który został dowiązany do układu współrzędnych płaskich „PUWG 1992”. Do drugiego etapu, będącego jednym z najważniejszych procesów wstępnego przetwarzania danych hiperspektralnych, należało wykonanie korekcji atmosferycznej. Korekcję ze względu na wpływ atmosfery, stosując metodę bezwzględnej przeprowadzono przy użyciu modułu MODTRAN5 w środowisku programowym ATCOR-4. Jako produkt końcowy wygenerowano obraz odbicia spektralnego (ang. *spectral reflectance*) dla pikseli obrazów szeregów hiperspektralnych.

Dodatkowymi materiałami, które otrzymano od Instytutu Badawczego Leśnictwa były zestawy krzywych spektralnych dla czterech gatunków drzew. Ponadto





Rys. 5. Kompozycja barwna RGB (140 74 43) dla szeregu hiperspektralnego HySpex obejmującego obszar opracowania (źródło: opracowanie własne)

Fig. 5. A RGB colour composite image (R:140 G:74 B:43) of hyperspectral array obtained from scanner HySpex for the research area (source: own elaboration)

otrzymano warstwę wektorową z lokalizacjami drzew pomierzonymi techniką RTK. Na podstawie otrzymanego zestawu plików typu *shapefile* z rozmieszczeniem terenowym gatunków drzewostanów utworzono własnej biblioteki spektralne, które wygenerowano na podstawie zobrazowania hiperspektralnego. Istotnym źródłem informacji o drzewostanie była baza danych SILP (*System Informatyczny Lasów Państwowych*), która jest udostępniana poprzez portal internetowy Banku Danych o Lasach (<http://www.bdl.lasy.gov.pl/portal/>). Wiedząc, że architektura tego systemu polega na powiązaniu każdej danej szeregiem zależności, tj. „wiersze opisane w poszczególnych tabelach mogą łączyć się z wierszami innych tabel, gdzie jednemu wierszowi tabeli źródłowej może odpowiadać jeden lub wiele wierszy tabeli podrzędnej” (CHROMAŃSKI i in., 2013, s.79) utworzono własny zestaw danych. W ten oto sposób połączono wynikową tabelę zawierającą informację o geometrii wydziałów z tabelami opisowymi gromadzącymi dane o gatunkach, warstwach i wieku drzew. Dane te wykorzystano na etapie oceny dokładności wyników klasyfikacji.

#### Metodyka realizacji badań

Specyfiką danych hiperspektralnych jest mnogość kanałów spektralnych, co sprawia, że są one trudniejsze w przetwarzaniu. Metody klasycznie stosowane przy klasyfikacji obrazów wielospektralnych nie są w tym przypadku wydajne. Znaczącym utrudnieniem na etapie klasyfikacyjnym zobrazowań hiperspektralnych jest duża korelacja pomiędzy sąsiednimi kanałami. Oznacza to, że wysoka rozdzielczość spektralna nie warunkuje wzrostu informacji, a tym samym poprawy jakości klasyfikowanego obrazu. Ponadto duża ilość informacji znacznie wydłuża proces klasyfikacji, a także skutkuje problemami sprzętowymi. Według Serpico i Moser (2007) poprzez odpowiednią redukcję i selekcję kanałów możliwa jest poprawna klasyfikacja treści obrazowych. Z tego względu zdecydowano się na przeprowadzenie procedury redukcji liczby kanałów spektralnych. Redukcję nadwymiarowości przeprowadzono na dwa sposoby (rozdział 3). Pierwsze podejście polegało na wyborze odpowiedniego zestawu kanałów ze zbioru kanałów oryginalnych, natomiast druga metoda bazowała na transformacji liniowej MNF, przekształcającej dane wejściowe do postaci nowych kanałów o zmienionych właściwościach spektralnych.

Obraz źródłowy HySpex obejmował 182 kanały spektralne – od zakresu niebieskiego (B) po bliską podczerwień (NIR). Ze względu na występujące błędy radiometrii obrazu na wstępie wyeliminowano sześć kanałów spektralnych z widma promieniowania niebieskiego. Następnie, po wstępnej selekcji kanałów spektralnych, wykonano maskowanie dla wybranych form pokrycia terenu tak, aby obszar badań uwzględniał obszary zbiorowisk leśnych. W tym celu wykorzystano potencjał wskaźników roślinności. Na podstawie badań literaturowych oraz własnych obserwacji ostatecznie do dalszych analiz wybrano wskaźnik MRENDVI

(ang. *Modified Red Edge Normalized Difference Vegetation Index*), uwypuklający wrażliwość na zawartość chlorofilu (HABOUDANE, 2004). Wskaźnik MRENDVI opisany jest poniższym wzorem:

$$MRENDVI = \frac{R_{750} - R_{705}}{R_{750} + R_{705} - 2R_{445}}$$

gdzie:

R750; R705; R445 – odbicie spektralne dla fal elektromagnetycznych o długości odpowiednio 750, 705 i 445 nm.

Zastosowanie odpowiedniego progu dla wskaźnika MRENDVI pozwoliło na wyeliminowanie cienia rzucającego przez wyższe piętra drzewostanu. Istotną kwestią było również wykonanie maski dla obszarów nieleśnych, tj. łąk czy terenów zabudowanych. Na podstawie wygenerowanego znormalizowanego numerycznego modelu terenu (zNMPT) wyodrębniono rejony o niskiej wartości wysokości względnej nieprzekraczającej 1,50 m. W rezultacie, poprzez wybór wartości progowych zamaskowano większość obszarów pozbawionych roślinności, np. gleby odkryte i teren zabudowany.

Dalszy etap przetworzeń obejmował redukcję nadmiarowości danych (Fig. 4). W pierwszym przypadku wykonano selekcję danych, która polegała na wyborze co trzeciego kanału źródłowego HySpex (GŁOWIENKA-MIKRUT, 2014). W rezultacie otrzymano obraz składający się z 59 kanałów spektralnych, co przedstawiono w tab. 2. Równoległe do obrazu 59-kanałowego utworzono również obraz składający się ze 117 kanałów hiperspektralnych.

Tab.2. Charakterystyka zakresów spektralnych obrazu 59-kanałowego

Table 2. Characteristics of spectral bands for 59-channel HySpex image

Obraz HySpex (59 kanałów )							
nr kanału	dł. fali [μm]	nr kanału	dł. fali [μm]	nr kanału	dł. fali [μm]	nr kanału	dł. fali [μm]
1	0,429	16	0,579	31	0,723	46	0,867
2	0,445	17	0,589	32	0,733	47	0,876
3	0,455	18	0,598	33	0,742	48	0,886
4	0,464	19	0,608	34	0,752	49	0,896
5	0,474	20	0,618	35	0,761	50	0,905
6	0,483	21	0,627	36	0,771	51	0,915
7	0,493	22	0,637	37	0,781	52	0,924
8	0,503	23	0,646	38	0,790	53	0,934
9	0,512	24	0,656	39	0,800	54	0,944
10	0,522	25	0,666	40	0,809	55	0,953
11	0,531	26	0,675	41	0,819	56	0,963
12	0,541	27	0,685	42	0,829	57	0,972
13	0,550	28	0,694	43	0,838	58	0,982
14	0,560	29	0,704	44	0,848	59	0,992
15	0,570	30	0,713	45	0,857		

Ze względu na występowanie korelacji pomiędzy poszczególnymi kanałami spektralnymi obrazu hiperspektralnego przeprowadzono redukcję danych opartą na

transformacji MNF. Algorytm ten w pierwszej kolejności oblicza poziom szumu, a następnie wykorzystuje go na potrzeby transformacji danych do nowego układu. Drugi etap obejmuje wykonanie standardowej transformacji PCA dla danych skorygowanych ze względu na wyżej wymieniony typ zakłóceń. W rezultacie otrzymuje się obrazy, których kanały zostały uporządkowane według malejącej zawartości informacji. Oznacza to, że algorytm szereguje nowo powstałe kanały według malejącej wartości wariancji. W celu oszacowania przydatności nowoutworzonych kanałów do dalszych analiz wykorzystano wykres przedstawiający ich wartości własne. Weryfikacja ta pozwoliła zredukować źródłową liczbę kanałów na potrzeby dalszej ekstrakcji informacji. Na podstawie analizy wykresu (Fig. 6) wybrano kanały o najlepszej charakterystyce statystycznej. W jej wyniku do klasyfikacji wybrano 25 kanałów spektralnych zawierających największą ilość informacji.




Fig. 6. Profile of Eigenvalues for 117-channel hyperspectral image

Rys. 6. Wykres wartości własnych kanałów dla 117-kanałowego zobrazowania hiperspektralnego

Ze względu na odmienny charakter danych hiperspektralnych techniki ekstrakcji informacji różnią się od analizy danych metodami klasycznymi. Mnogość kanałów i związane z tym zakres i możliwości analiz obrazowych wymagają odmiennego podejścia do klasyfikacji treści obrazów hiperspektralnych. Poniżej przedstawiono etapy pracy, jakie wykonano w procesie klasyfikacyjnym zobrazowań hiperspektralnych. Cała procedura, tj. klasyfikacja, ocena dokładności oraz generalizacja obrazów wynikowych została przeprowadzona w środowisku programowym ENVI 5.3. Natomiast program ArcGIS 10.4 posłużył do selekcji pól testowych oraz wykonania finalnych opracowań kartograficznych dla zidentyfikowanych gatunków drzew.

Przed wykonaniem klasyfikacji, na podstawie obrazów wejściowych, utworzono wzorcowe charakterystyki spektralne. Niestety wykorzystanie spektrometrycznych pomiarów terenowych, jakie wykonano równoległe do nalotu hiperspektralnego było niemożliwe. Na podstawie otrzymanych danych stwierdzono, że wykresy spektralne dla pomierzonych drzew znacznie odbiegają od charakterystyk odbiciowych pomierzonych na obrazie. W związku z powyższym jako dane referencyjne



posłużyły krzywe spektralne pozyskane bezpośrednio z danych hiperspektralnych. W tym celu wykorzystano warstwę wektorową zawierającą dokładne lokalizacje określonych gatunków drzew w obrębie obszaru opracowania.

Uzyskane w ten sposób tzw. *endmembers* pozwoliły na utworzenie własnej biblioteki spektralnej drzewostanów Puszczy Białowieskiej. W pierwszym etapie wybrano siedem gatunków drzew – sosnę, świerk, olchę, dąb, brzozę, grab oraz lipę. Ze względu na dominujący charakter tych gatunków w stosunku do całkowitej powierzchni Puszczy Białowieskiej (Table 1), klasy te wytypowano jako najbardziej reprezentatywne. Kolejnym krokiem była selekcja pikseli, a następnie identyfikowanie gatunków i tworzenie wstępnych wzorców do klasyfikacji. Ze względu na punktowy charakter warstwy zadanie to było utrudnione, gdyż wiązało się z dużym prawdopodobieństwem występowania pikseli mieszanych. Proces zbierania wzorców przebiegał wieloetapowo. Niestety wielokrotnie klasy zostały błędnie rozpoznane, co wiązało się z eliminacją tych danych wzorcowych i ponownym wykonaniem klasyfikacji. W wielu przypadkach stopień przynależności pikseli do dwóch różnych klas był bardzo zbliżony. Sytuację taką zaobserwowano szczególnie dla zestawu sosny i świerku, jak i dla drzew liściastych. Dodatkową trudnością były zróżnicowana liczba próbek wzorcowych dla poszczególnych gatunków oraz niesprzyjająca lokalizacja drzew, często na obrzeżach lasu i innych obszarach nieleśnych. Poniżej przedstawiono przypadek, w którym prawdopodobieństwo występowania dębu i grabu przybrało zbliżone wartości dla tych samych obszarów (Fig. 7).

Ostatecznie dla wybranej grupy pikseli pozyskano charakterystyki spektralne, co do których istniało wysokie prawdopodobieństwo, że reprezentują rozróżniany typ pokrycia terenu. W rezultacie zdefiniowano następujące klasy:


- sosna,
- świerk,
- olcha,

- brzoza,
- dąb,
- lipa.

Dla każdego z gatunków drzew zapisano kilka krzywych spektralnych, tak aby uwzględnić ich naturalne zróżnicowanie (Fig. 8).

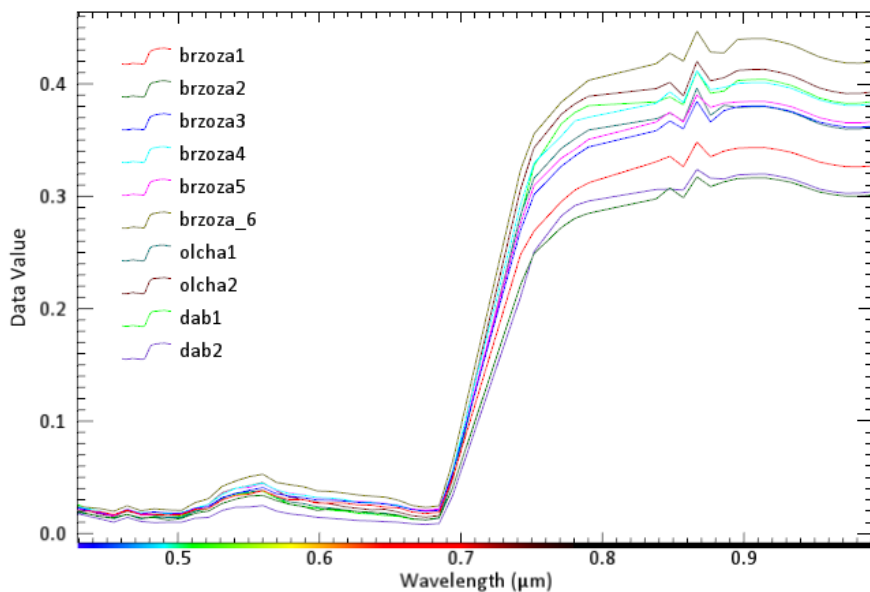
Na podstawie przeprowadzonych testów, zarówno przy użyciu klasyfikatora *Spectral Feature Fitting* (SFF), *Spectral Angle Mapper* (SAM), jak i metod podpikselowych, tj. *Linear Spectral Unmixing* (LSU) i *Matched Filtering* (MF), stwierdzono, że najlepsze rezultaty otrzymano stosując algorytm SAM. Początkowo procedurę tę przeprowadzono dla fragmentu opracowywanego szeregu hiperspektralnego, a w kolejnym etapie dla całego zobrazowania HySpex. W pierwszej kolejności zaimportowano zestaw wzorcowych charakterystyk spektralnych. Następnie zdefiniowano parametry klasyfikacji, dobierając dla danych referencyjnych odpowiednią maksymalną odległość kątową. Ustalenie prawidłowego kąta wiązało się z wykonaniem szeregu testów, polegających na wyznaczeniu progów, określających, które piksele obrazu będą należeć do zdefiniowanych klas. Wynikiem działania klasyfikatora SAM były obrazy o wartościach z przedziału 0-1. Po przeprowadzeniu klasyfikacji uzyskano 19 obrazów w odcieniach szarości, reprezentujących prawdopodobieństwo przynależności pikseli do danej klasy. W rezultacie dla badanego szeregu hiperspektralnego uzyskano zestaw jednokanałowych obrazów charakteryzujących występowanie gatunków drzew objętych analizą. Końcowy wynik klasyfikacji powstaje na podstawie reguł decyzyjnych. W większości przypadków poszukiwana na obrazie klasa miała minimum po dwie charakterystyki wzorcowe tworzące finalną bibliotekę spektralną. Dlatego też po utworzeniu sklasyfikowanego obrazu wykonano agregację oraz generalizację obrazu wynikowego. Wyniki klasyfikacji dla fragmentu opracowania zaprezentowano na rys. 9.

Najbardziej satysfakcjonujące rezultaty uzyskano dla klasyfikacji wykonanej dla obrazu 59-kanałowego




Rys.7. Wynik klasyfikacji metodą „Spectral Angle Mapper” dla 59-kanałowego obrazu dla (kolejno od lewej): grabu i dębu. Odcień ciemniejszy wskazuje na większe podobieństwo do klasy wzorcowej.

Fig. 7. SAM classification results on the basis of the 59-channel hyperspectral image (from the left side): for oak and hornbeam classes. Darker tone indicates bigger similarity to the reference class.



Rys. 8. Wykresy wybranych krzywych odbicia spektralnego, pozyskanych bezpośrednio z 59-kanalowego obrazu HySpex przy użyciu modułu „Spectral”.

Fig. 8. Spectral profiles for selected tree species obtained from 59-channel HySpex image in ENVI




Rys. 9. Wyniki klasyfikacji uzyskane odpowiednio dla: a) 59-kanalowego zobrazowania; b) 117-kanalowego obrazu; 25 kanałów po wykonaniu transformacji MNF. Legenda dla klas została zamieszczona na rys. 11.

Fig. 9. Forest classification for selected area in: a) 59-channel image; b) 117-channel image; c) 25-channel data after MNF transformation. The legend for classes was presented in Figure 11.

i 117-kanalowego, dlatego też w dalszej części pracy zostały one zaprezentowane dokładniej niż wyniki dla zobrazowania poddanego transformacji MNF. Z uwagi na odmienny charakter krzywych spektralnych obrazu poddanego transformacji Minimum Noise Fraction w porównaniu z dwoma wcześniejszymi zobrazowaniami, dane wzorcowe wybrane dla obrazu 59- oraz 117-kanalowego nie były w pełni reprezentatywne dla treści obrazowych MNF. Wiązało się to z indywidualnym doбором charakterystyk referencyjnych i ustaleniem maksymalnego kąta spektralnego. Przykładowy rezultat zastosowania metody SAM przedstawiono na rycinie 10. Na załączonych jednokanałowych obrazach SAM Rule Images skonfrontowano wyniki klasyfikacji dla 59-kanalowego zobrazowania z danymi poddanymi transformacji MNF.

Na podstawie analizy rys. 10. można zauważyć, że piksele obrazu, który został wcześniej poddany dekorrelacji kanałów spektralnych, nie zostały poprawnie zidentyfikowane przez klasyfikator SAM. Świadczą o tym kompleksy leśne zaznaczone na kompozycji barwnej CIR, które zostały wybrane na podstawie opisu taksonomicznego drzewostanów. Jak zaprezentowano na powyższym rysunku (Fig. 10), wytypowanemu drzewostanowi sosnowemu przypisano wysokie podobieństwo do dębu, o czym świadczy ciemny odcień na wyniku klasyfikacji treści 25-kanalowego zobrazowania MNF. Oznacza to, że odległość spektralna od wektora wzorcowego była mała. Podobną sytuację zaobserwowano dla lasu sosnowo-dębowego. W tym przypadku dąb nie został wykryty – widać jasny odcień pikseli w obrębie kompleksu. Natomiast pozostałemu arealowi (rzeczywiście porośniętemu przez





Rys. 10. Porównanie kompozycji barwnej CIR z wynikami klasyfikacji SAM dla dębu (kolejno od lewej): dla obrazu 25-kanalowego uzyskanego w wyniku redukcji danych metodą MNF oraz 59-kanalowego utworzonego poprzez wizualną selekcję kanałów hiperspektralnych. Im ciemniejszy odcień wynikowego obrazu, tym kąt spektralny mniejszy, co oznacza większe podobieństwo do wzorca.

Fig. 10. Comparison between CIR image and SAM classification results for oak class (from the left side): for 25-channel MNF image and 59-channel hyperspectral image. Darker tone indicates bigger similarity to the reference characteristic.

sośnie) klasyfikator przypisał wysokie prawdopodobieństwo występowania dębu. Podobne próby klasyfikacji na podstawie obrazu poddanego algorytmowi MNF wykonywano dla innych danych punktowych. Niestety większość podejść miała analogiczny przebieg do wyżej opisanego. Inaczej sytuacja wyglądała dla zobrazowania 59-kanalowego. Piksele obrazu zostały poprawnie sklasyfikowane – sośnie przypisano niski stopień podobieństwa do dębu (odcień jasny), a kompleks leśny z drzewostanem dębowym był zbliżony do danych referencyjnych. Ostatecznie procedurę klasyfikacyjną metodą SAM dla całego szeregu danych hiperspektralnych wykonano dla 59- oraz 117-kanalowego zobrazowania. Dla tych obrazów utworzono mapy rozmieszczenia gatunkowego drzew, które zamieszczono na rycinie 11.

#### Analiza i dyskusja uzyskanych wyników klasyfikacji

Po przeprowadzeniu klasyfikacji szeregu hiperspektralnego metodą *Spectral Angle Mapper* uzyskano dwa obrazy przedstawiające rozmieszczenie przestrzenne zidentyfikowanych gatunków drzew na badanym obszarze. Uzyskane obrazy wynikowe zostały poddane analizie mającej na celu oszacowanie dokładności zastosowanej metody klasyfikacji. Sposób oceny wyników polegał na porównaniu rezultatów klasyfikacji z obszarami testowymi, wyznaczonymi na podstawie informacji zawartych w opisach taksacyjnych drzewostanów, dotyczących m.in. procentowego udziału gatunków w danym kompleksie leśnym. Na tej podstawie wygenerowano warstwy wektorowe drzew, które dominowały w danym poligonie. Cały proces selekcji pól testowych wykonano przy użyciu programu ArcMap. W ten sposób wytypowano kompleksy leśne reprezentujące utworzone klasy,

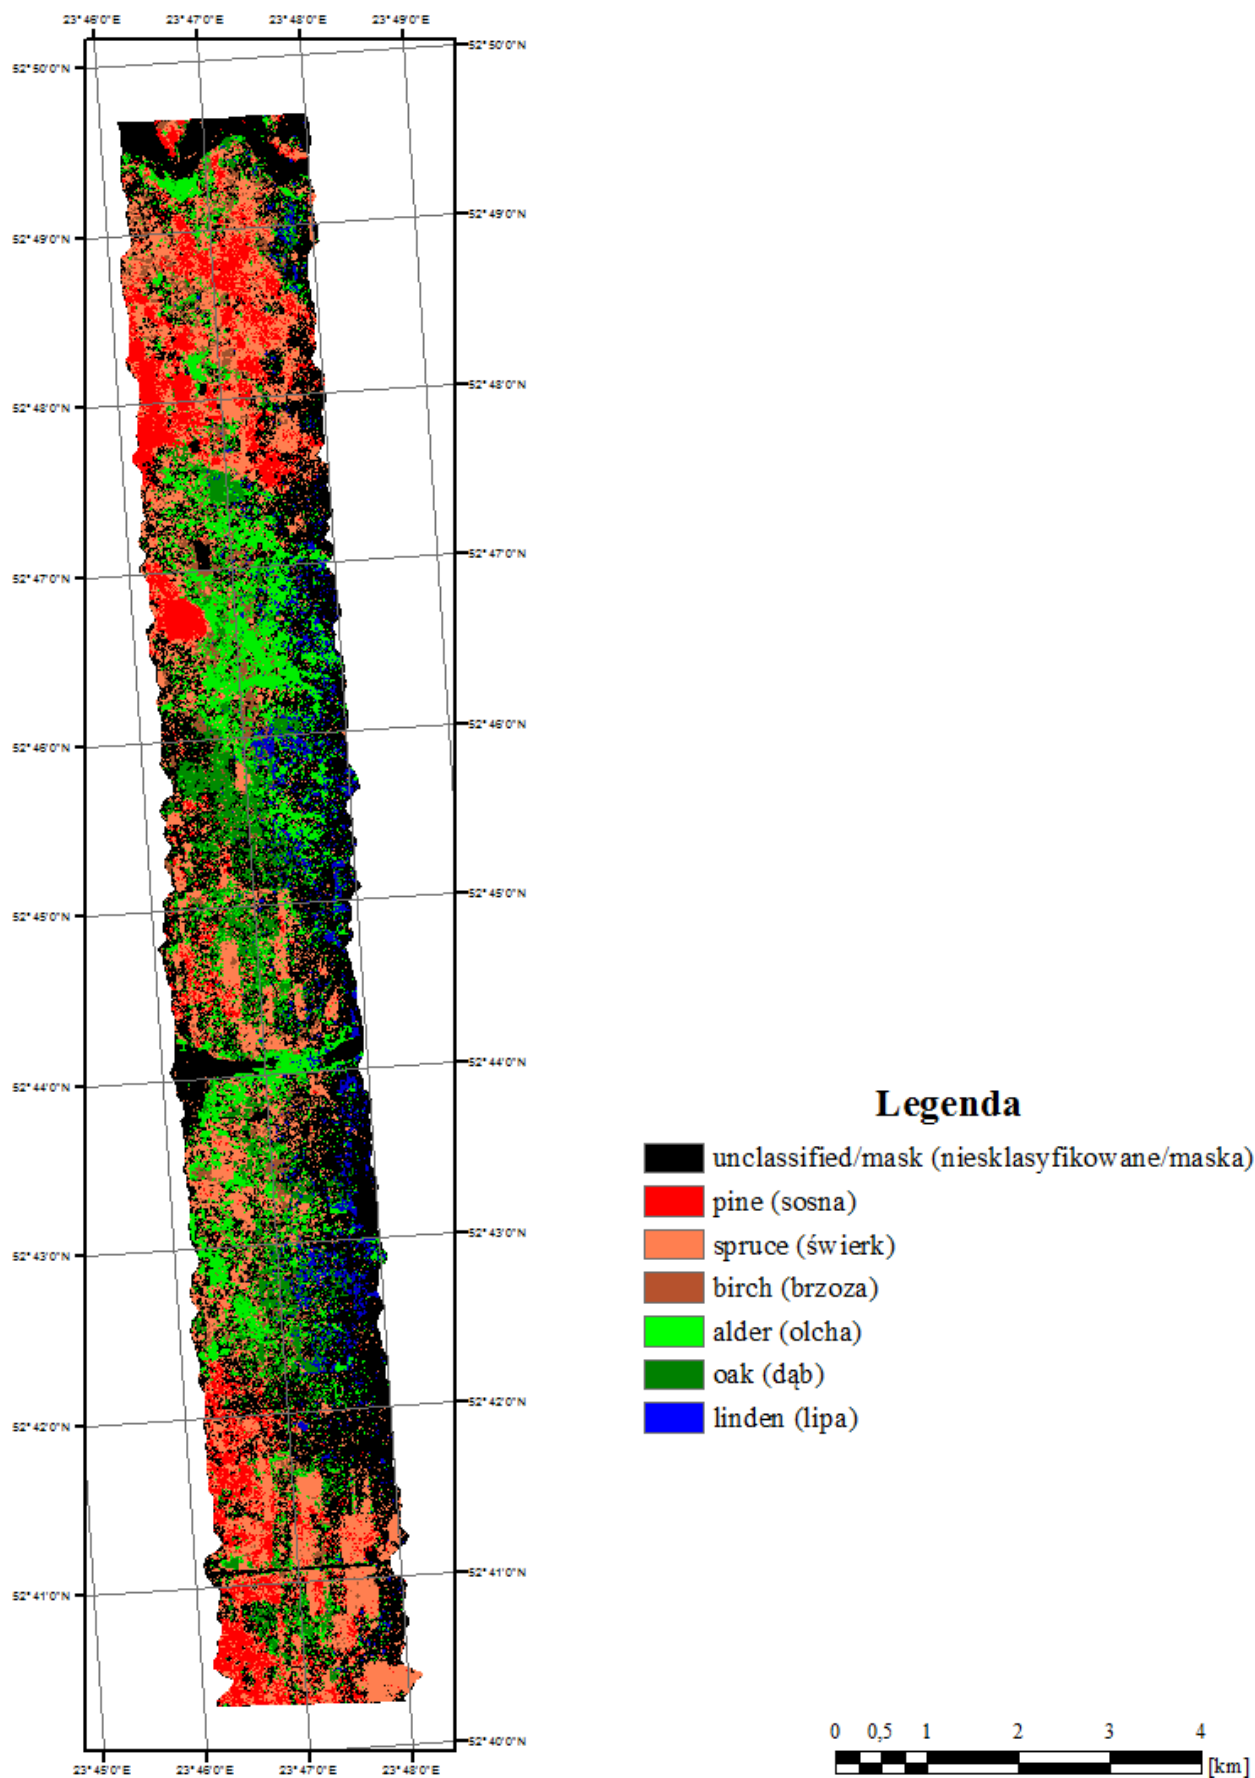
biorąc pod uwagę tylko te, które przeważały w danym poligonie. Dla każdego analizowanego gatunku zostały określone minimum po dwa obszary referencyjne. W rezultacie utworzono następujące pola testowe:

- Sosna – 90% oraz 100% udział w całej powierzchni,
- Świerk – 100% udział w całej powierzchni,
- Olcha – 90% oraz 100% udział w całej powierzchni,
- Dąb – 90% i 100% udział w całej powierzchni,
- Brzoza – 70% oraz 80% udział w całej powierzchni.

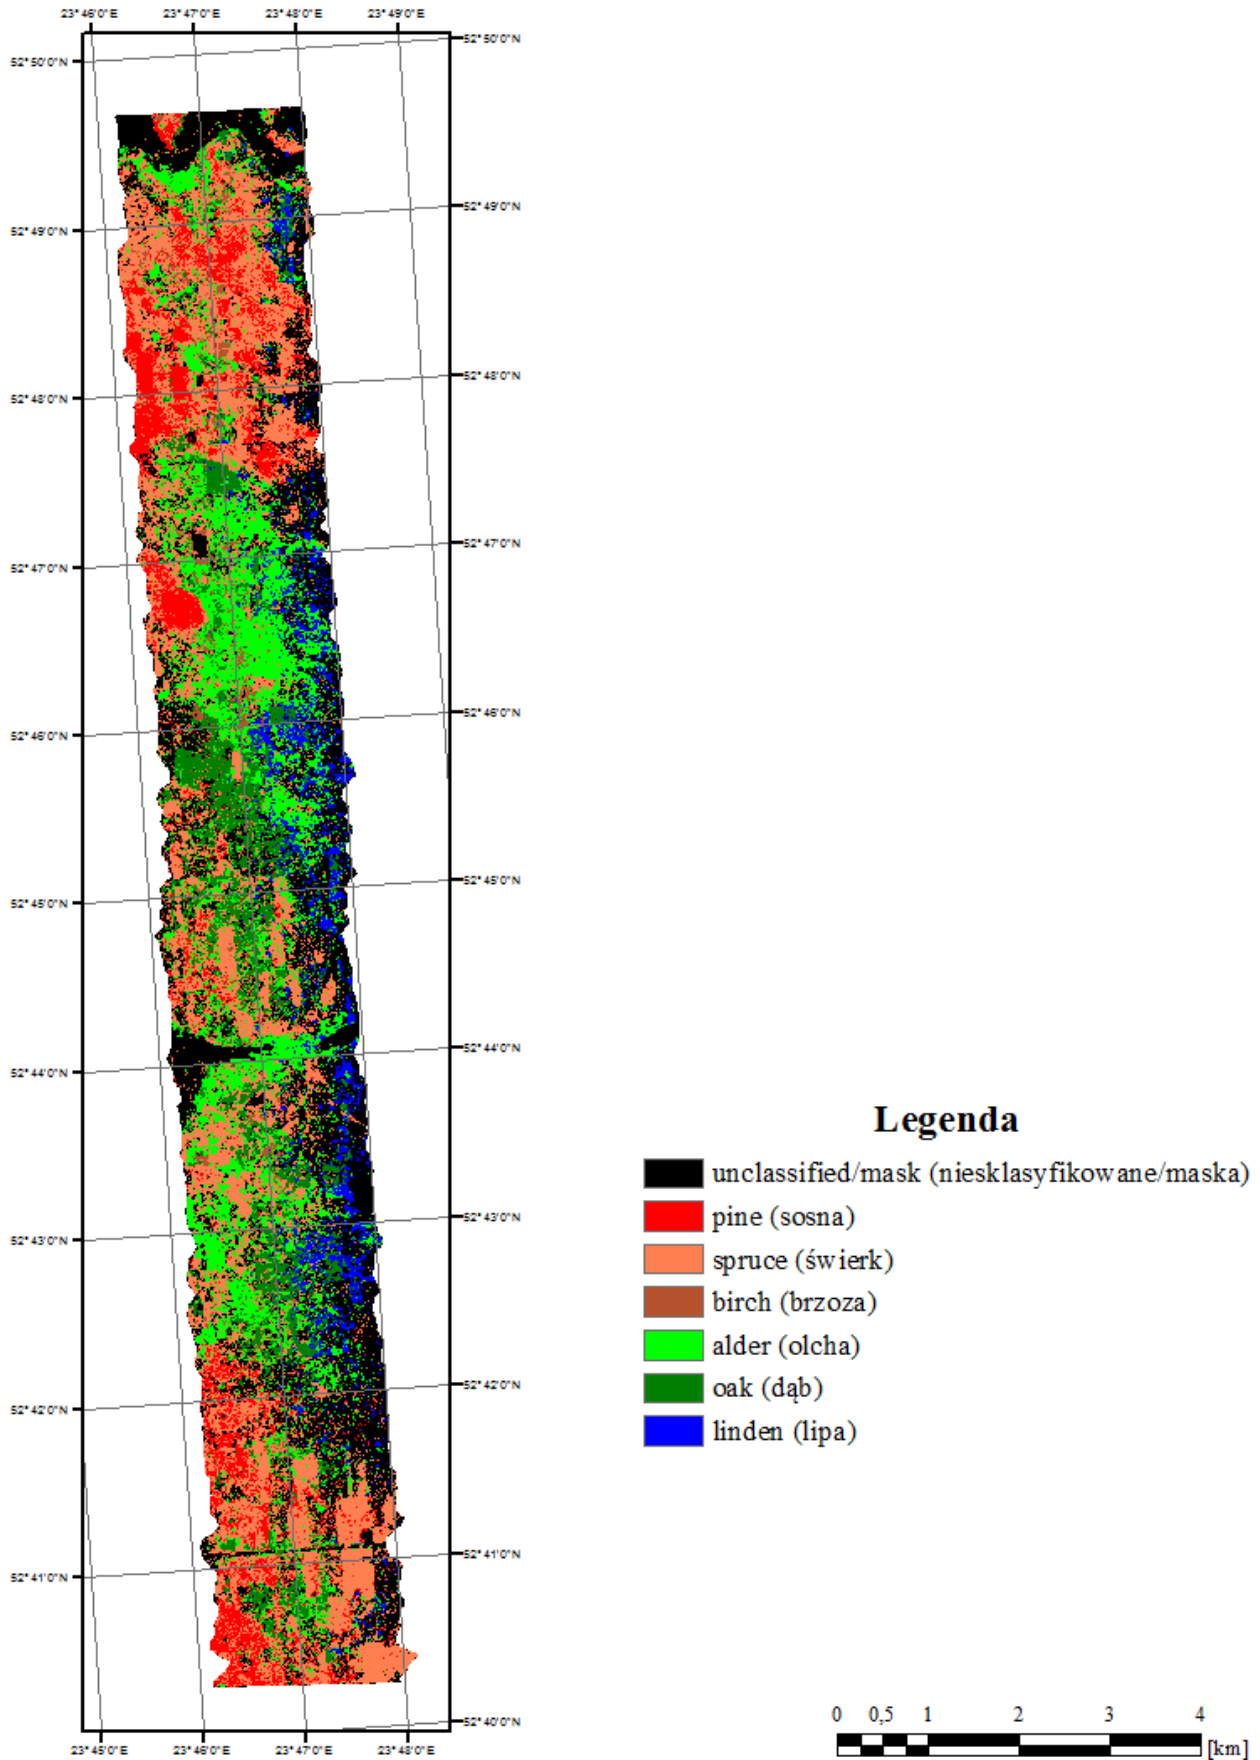
Ze względu na zróżnicowany udział procentowy gatunków drzew wchodzących w skład poligonów, nie dla wszystkich klas udało się odnaleźć kompleksy leśne składające się wyłącznie z jednego gatunku lub z 10% domieszką innych drzewostanów. Taką sytuację zaobserwowano dla brzozy. W większości przypadków gatunek ten nie był dominujący i nie przekraczał 1/2 zajmowanej powierzchni w obrębie poligonów. Jeszcze niższym udziałem procentowym charakteryzowała się lipa, która zajmowała małą powierzchnię w stosunku do całych poligonów. Ze względu na fakt, że jej udział wahał się przeważnie w granicach 20-50%, drzewostan ten pominięto w ocenie dokładności, uznając takie pola testowe za mało reprezentatywne.

Ocenę dokładności przeprowadzono przy użyciu wskaźnika rozpoznania (CIOŁKOSZ et al., 1999). Ocenę tę wykonano z wykorzystaniem macierzy błędów. W tym celu wcześniej utworzone warstwy wektorowe drzew zostały wykorzystane do oszacowania poprawnego rozpoznania gatunków dla obu obrazów wynikowych. Pod uwagę wzięto pięć klas drzewostanów – 2 gatunki iglaste (sosna i świerk) i 3 liściaste (dąb, olsza, brzoza). Na wynik końcowy składały się raporty rozpoznania z uzyskanymi dokładnościami. W tabelach 3 i 4 przedstawiono raporty stopnia rozpoznania, odpowiednio dla





Rys. 11a. Ostateczna klasyfikacja drzewostanów z wykorzystaniem algorytmu SAM dla: 59-kanalowego zobrazowania  
 Fig. 11a. Final classification results obtained with the SAM classifier for 59-channel imagery



Rys. 11b. Ostateczna klasyfikacja drzewostanów z wykorzystaniem algorytmu SAM dla 117-kanalowego obrazu  
 Fig. 11b. Final classification results obtained with the SAM classifier for 117-channel imagery

obrazu składającego się z 59 i 117 kanałów spektralnych.

Analizując powyższe tabele można dostrzec, że wyniki dla obu obrazów były zbliżone. Średnia dokładność rozpoznania drzewostanów na pierwszym zobrazowaniu wynosiła 77,59%, podczas gdy na drugim była nieco niższa, osiągając wartość 76,62%. Współczynniki *Kappa* wynosiły odpowiednio 0,69 i 0,68. Oznaczało to, że w przypadku 59-kanałowego obrazu proces klasyfikacji pominął 69% błędów, które mogłyby powodować klasyfikacja przypadkowa. Dla drugiego obrazu współczynnik ten był niższy o 1%. Wyniki procedury stopnia rozpoznania odzwierciedlały także dokładności producenta i użytkownika. Dla każdego obrazu dokładności te zostały przedstawione za pomocą wykresów słupkowych (Fig. 12, Fig. 13). Biorąc pod uwagę wykazy otrzymane dla 59-kanałowego zobrazowania, tj. zestawienia tabelaryczne oraz utworzony diagram, można zauważyć, że najlepsze wyniki dla dokładności producenta otrzymano przy rozpoznaniu świerka (88,1%), olchy (85,3%) i brzozy (84,1%). Pozostałe klasy zidentyfikowano poprawnie na poziomie 60-76%. Najgorszy rezultat otrzymano dla dębu, dla którego odnotowano wartość oscylującą w granicach 60%. Gorsze efekty otrzymano dla dokładności użytkownika. Taki stan rzeczy mógł mieć miejsce ze względu na charakter utworzonych pól testowych. Wydzielenia leśne, pełniące funkcję pól testowych z dużą dozą prawdopodobieństwa nie charakteryzowały się 100% występowaniem danego gatunku.

W wielu przypadkach jednogatunkowe kompleksy

leśne nie występowały na badanym obszarze. Przełożyło się to zatem na wyniki dla dokładności użytkownika. Taką sytuację bardzo dobrze odzwierciedlał gorszy wynik dla brzozy, który wyniósł 49,4%. Tak duża rozbieżność pomiędzy dwoma wskaźnikami dokładnościowymi (ang. *producer* i *user accuracy*) wynikała z procentowego udziału brzozy w poligonach referencyjnych, dla których ten gatunek zajmuje średnio 70-80%. Równie niezadowalającą dokładność uzyskano dla świerka (48,2%). Bardziej satysfakcjonujące rezultaty otrzymano dla sosny (96,4%), olchy (92,3%) oraz dębu (86,6%).

Biorąc pod uwagę zestawienie w tabeli 4 oraz wykres 2 (Fig. 13), przedstawiające ocenę dokładności dla 117-kanałowego obrazu, stwierdzono, że wyniki dokładnościowe były zbliżone do wyników dla pierwszego zobrazowania. Jak przedstawiono to w danych tabelarycznych, cztery na pięć klas zostały poprawnie rozpoznane z dokładnością w granicach 70-90%. Jedynie klasa „sosna” dała najgorsze rezultaty. W przypadku obrazu 117-kanałowego poprawność wyniosła 76,12%, a dla 59-kanałowego blisko 69%. Podsumowując otrzymane wyniki dla obu obrazów stwierdzono, że dla 117-kanałowego zobrazowania odnotowano większą dokładność dla dębu (70,38%), a mniejszą – dla sosny (68,91%). Pozostałe klasy nie charakteryzowały się znacznymi fluktuacjami. Z kolei analizując wykres 2 (Fig. 13) można zauważyć, że w przypadku klasy „dąb” oraz „sosna” dokładność producenta uległa zmniejszeniu lub odnotowano wzrost. Taką samą tendencję odnotowano dla

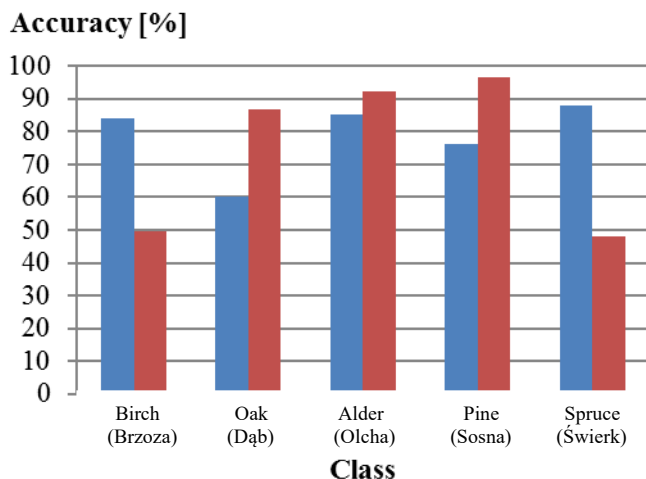
Tab. 3. Raport z oszacowania dokładności klasyfikacji – stopnia rozpoznania dla obrazu 59- kanałowego  
Table 3. Accuracy assessment report – Recognition Analysis for 59-channel image

Klasa	Poligony testowe [%]					
	Brzoza	Dąb	Olcha	Sosna	Świerk	Ogółem
Niesklasyfikowane	4,32	17,91	3,55	0,91	1,63	4,28
Brzoza	84,12	0,94	3,72	0,64	0,87	2,85
Dąb	0,33	60,31	4,69	0,5	0,44	10,59
Olcha	5,1	8,29	85,30	0,64	0,5	22,13
Sosna	1,32	0,76	0,24	76,12	8,51	36,48
Świerk	4,81	11,78	2,49	21,19	88,06	23,67
Ogółem	100,00	100,00	100,00	100,00	100,00	100,00
<b>Całkowita dokładność:</b>		77,59%				
<b>Współczynnik Kappa:</b>		0,6935				

Tab. 4. Raport z oszacowania dokładności klasyfikacji – stopnia rozpoznania dla obrazu 117- kanałowego  
Table 4. Accuracy assessment report – Recognition Analysis for 117-channel image

Klasa	Poligony testowe [%]					
	Brzoza	Dąb	Olcha	Sosna	Świerk	Ogółem
Niesklasyfikowane	2,72	9	1,51	0,4	2,06	2,24
Brzoza	79,59	0,29	1,67	0,41	0,3	2,00
Dąb	0,45	70,38	6,18	0,67	0,7	12,69
Olcha	8,44	8,41	88,02	0,9	0,8	22,95
Sosna	1,89	0,6	0,24	68,91	5,97	32,77
Świerk	6,91	11,32	2,39	28,7	90,17	27,35
Ogółem	100,00	100,00	100,00	100,00	100,00	100,00
<b>Całkowita dokładność:</b>		76,62%				
<b>Współczynnik Kappa:</b>		0,6836				



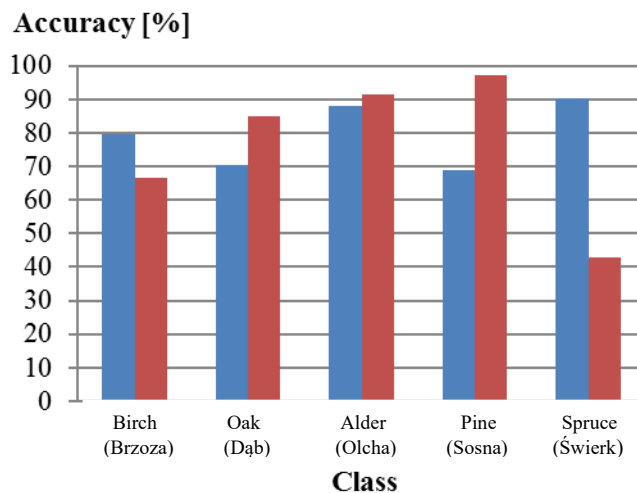


Wyk. 1. Prezentacja graficzna uzyskanych dokładności: producenta (niebieski) i użytkownika (czerwony) dla klasyfikacji SAM na zobrazowaniu 59-kanalowym.

Fig. 12. Bar graph of producer's (blue) and user's (red) accuracy of SAM classification for individual tree species for 59-channel image

dokładności użytkownika. Przykładowo wartości pierwszego wskaźnika dla zobrazowania 117-kanalowego dla klasy „świerk” wzrosły do 90,2%, podczas gdy dokładność użytkownika zmalała do poziomu 42,7%. Podobnie dla olchy i dębu – dokładność *Producer Accuracy* zwiększyła się odnotowując wartość 88,0% oraz 70,4%, natomiast drugi wskaźnik spadł dla obu klas o około 1% (Fig. 13). Kontrastową sytuację odnotowano dla brzozy i sosny. Jak przedstawiają wyniki dla zobrazowania 117-kanalowego, dokładność producenta spadła kolejno do poziomu 79,6% i 68,9%. Dla drugiego wskaźnika zanotowano wzrost – dla brzozy był on równy 17,0%, natomiast dla sosny dokładność użytkownika wyniosła ponad 97%, co ilustruje Fig. 13.

Po przeprowadzeniu oceny dokładności klasyfikacji metodą SAM dla wszystkich obrazów okazało się, że opracowanie mapy klasyfikacyjnej o dużej szczegółowości napotyka na wiele problemów. Na dokładność klasyfikacji miały wpływ charakterystyki spektralne, które utworzono bezpośrednio z danych hiperspektralnych na podstawie punktowej warstwy z lokalizacjami drzew znajdującymi się w obrębie obszaru opracowania. Należy zwrócić uwagę na fakt, że wszystkie krzywe referencyjne dla danego gatunku pozyskano z pojedynczych pikseli obrazu. Dlatego też zdolność do rozróżniania pomiędzy poszczególnymi drzewostanami na podstawie charakterystyk spektralnych była ograniczona. Dodatkowo, dane wzorcowe z dużą dozą prawdopodobieństwa mogły nie należeć do pikseli homogenicznych i czystych spektralnie, a tym samym mogły zawierać frakcje innych gatunków. Inną kwestią była struktura pionowa i pozioma drzewostanów. Drzewa rosnące pod koroną większych drzew innego gatunku lub różniących się wiekiem klasyfikuje się gorzej. Przy doborze pól testowych brano pod uwagę kryterium dominacji sklasyfikowanego gatunku nad pozostałymi drzewostanami. Pod względem



Wyk. 2. Prezentacja graficzna uzyskanych dokładności: producenta (niebieski) i użytkownika (czerwony) dla klasyfikacji SAM na zobrazowaniu 117-kanalowym

Fig. 13. Bar graph of producer's (blue) and user's (red) accuracy of SAM classification for individual tree species for 117-channel image

gatunkowym najłatwiej rozpoznano te drzewostany, które dominowały na danym obszarze. W przypadku drzew rzadziej występujących, np. wiąz czy klon klasyfikacja była niemożliwa. Wynikało to z faktu, iż na podstawie wiedzy *a priori* wskazanie obszarów rzeczywistego występowania danego gatunku wiązało się z dużym ryzykiem niepoprawnej identyfikacji. Kolejnym czynnikiem mogącym mieć wpływ na wynik klasyfikacji był zastosowany skaner hiperspektralny, którego zakres wynosił 400-1000 nm. Należał on więc do urządzeń o znacznie mniejszym zakresie rejestracji spektrum niż skaner AISA czy APEX. Większy zakres widma elektromagnetycznego mógłby przełożyć się na uchwycenie większych różnic w kształcie krzywych spektralnych pozyskiwanych wzorców do klasyfikacji.

Otrzymane wyniki skonfrontowano z dokładnościami uzyskiwanymi przez innych autorów przy klasyfikacji treści obrazów Hyperion oraz lotniczych danych hiperspektralnych APEX (BARTOLD, 2008; RACZKO i in., 2015). W pracy Bartolda (2008) wykorzystano zobrazowania z pułapu satelitarnego do wykonania klasyfikacji SAM dla zbiorowisk dębu, sosny i olszy w różnym przedziale wiekowym. W trakcie badań stwierdził on duże podobieństwo dębu do olchy. Podobnie jak w niniejszej pracy, na etapie definiowania pikseli wzorcowych okazało się, że niemożliwe było wskazanie pikseli referencyjnych dla brzozy, natomiast bez problemu zidentyfikowano te gatunki, które dominowały na badanym obszarze – sosnę oraz dąb. Ponadto zauważono, że algorytm SAM błędnie rozpoznawał wyżej wymienione gatunki z uwzględnieniem ich zróżnicowania wiekowego (BARTOLD, 2008). Odnosząc uzyskane rezultaty Bartolda (2008) do wyników klasyfikacji w niniejszym opracowaniu można zauważyć zbliżony procentowy przedział poprawnie identyfikowanych klas. Zarówno dla zobrazowania 59- oraz 117-kanalowego stopień

rozpoznania mieścił się w granicach 60-90%, a najlepsze wyniki uzyskano dla drzewostanów iglastych, głównie świerku (Tab. 3-4). Średnia dokładność klasyfikacji dla zobrazowań wynosi odpowiednio 77,59% oraz 76,62% i jest porównywalna z wynikami Bartolda (2008). Ze względu na inne źródło pozyskania danych, tj. z pokładu satelity EO-1 oraz wielkość piksela terenowego trudno o jednoznaczną charakterystykę porównawczą uzyskanych wyników. Kwestią ograniczającą niniejszą analizę stanowiła rozdzielczość przestrzenna, która dla badanego zobrazowania lotniczego była ponad 10-krotnie mniejsza niż dla danych satelitarnych Hyperion. W rezultacie taka sytuacja przełożyła się na różną szczegółowość porównywanych opracowań. Na etapie przygotowania wzorców referencyjnych możliwe było wstępne określenie gatunków drzewostanów dębu i sosny, które na kompozycji barwnej R (750 nm), G (650 nm), B (550 nm) cechowały się odmienną tonacją różu, czerwieni i czerni (BARTOLD, 2008). Bazując zatem na mapach poglądowych oraz analizie wizualnej obrazu RGB, identyfikacja *endmembers* i finalne określenie składu gatunkowego dla jednego gatunku liściastego oraz iglastego w różnych klasach wieku nie stanowiła dużej trudności. Odmienna sytuacja miała miejsce przy klasyfikacji treści danych HySpex. W tym przypadku identyfikacji podlegało sześć gatunków drzew, w tym cztery liściaste i dwa iglaste, których krzywe referencyjne czy tonacja kompozycji barwnych były trudne do jednoznacznego rozróżnienia.

Bardziej zbliżoną pracą badawczą uwzględniającą identyfikację gatunkową drzewostanów były badania przeprowadzone w ramach projektu kartowania zbiorowisk leśnych dla obszaru Góra Chojnik. Ze względu na pułap rejestracji danych ze skanera APEX (*Airborne Prism Experiment*), rozdzielczość terenowa zobrazowań hiperspektralnych (GSD = 3,5 m) była podobna do danych HySpex, wykorzystanych w niniejszej pracy. Raczko i in. (2015) wykorzystali algorytm wektorów nośnych SVM (*Support Vector Machine*), za pomocą którego możliwe było określenie przynależności do klas oraz wartości zmiennych liczbowych. Tak jak na potrzeby tej pracy, przeprowadzili oni analizę informacyjności obrazu polegającą na redukcji nadwymiarowości kanałów spektralnych. W wyniku klasyfikacji uzyskano rozmieszczenie przestrzenne pięciu gatunków drzew. Rezultaty klasyfikacji pokazały, że najlepiej zidentyfikowano świerk (83,96%) oraz buk (87,09%). Gatunki te dominowały na obszarze badań. Podobna sytuacja miała miejsce dla klasyfikacji danych HySpex, wykonanej w ramach przedstawianego opracowania. Wysoką dokładność uzyskano dla świerka (88,06%, 90,17%) i olszy (85,30%, 88,02%), których udział w tworzeniu dojrzałego drzewostanu był wysoki (Tab. 3-4).

### 3. Podsumowanie

Celem niniejszej pracy była analiza możliwości wykorzystania zobrazowań hiperspektralnych HySpex na

potrzeby inwentaryzacji lasów. Na podstawie przeprowadzonych badań literaturowych oraz własnych analiz dotyczących klasyfikacji gatunkowej drzewostanów potwierdzono, że możliwe jest kartowanie zbiorowisk leśnych przy użyciu zdalnych technik teledetekcyjnych.

Jak przedstawiono w niniejszej pracy, dane hiperspektralne umożliwiły ekstrakcję informacji związanej z bioróżnorodnością drzew fragmentu Puszczy Białowieskiej. Badaniem objęto sześć gatunków roślinności drzewiastej: sosnę, świerk, dąb, olchę, brzozę oraz lipę. Wykorzystując zobrazowanie HySpex, zarejestrowane z pułapu lotniczego, wykonano klasyfikację badanego terenu z wykorzystaniem algorytmu *Spectral Angle Mapper*. Uzyskane wyniki, pomimo niewykorzystania naziemnych pomiarów spektrometrycznych, pozwoliły na dobrym poziomie rozróżnić wybrane gatunki drzew. Na podstawie przeprowadzonych analiz dokładnościowych, badających zależność pomiędzy wynikami ekstrakcji informacji a rzeczywistym stanem pokrycia terenu, całkowita dokładność klasyfikacji dla klasyfikowanych zobrazowań wyniosła 77-78%. Ponadto zauważono, że przeprowadzona selekcja kanałów spektralnych nie przyniosła pożądanych efektów. Jak się okazało, redukcja kanałów nie spowodowała znaczącego wzrostu dokładności (Tab. 3-4), a wyniki klasyfikacji dla obrazu poddanego transformacji MNF były znacznie gorsze od wyżej wymienionych. Niestety przy dekorelacji kanałów nie została zachowana relacja długość fali – numer kanału – charakterystyka odbiciowa. Mając to na uwadze, zobrazowania zredukowane metodą MNF nie nadawały się do klasyfikacji przy użyciu algorytmu SAM i nie mogły być stosowane jako wzorce dla tworzonych bibliotek krzywych spektralnych. Mając na uwadze niniejsze kwestie oraz fakt, że badane gatunki drzew liściastych i iglastych mają bardzo podobne charakterystyki odbiciowe, można stwierdzić, że uzyskane wyniki klasyfikacji treści obrazowych z sensora HySpex upoważniają do wykonania na ich podstawie map badanych gatunków roślinności drzewiastej. Wykonana klasyfikacja treści danych obrazowych przy użyciu algorytmu SAM miała charakter pilotażowy, a wyniki dokładnościowe potwierdzają, że może być z powodzeniem przeprowadzana od kartowania drzewostanu całej Puszczy Białowieskiej.

Teledetekcyjne techniki hiperspektralne wskazują na duży potencjał w kartowaniu drzewostanów leśnych. Pomimo spostrzeżeń, które zaprezentowano powyżej można stwierdzić, że uzyskane wyniki klasyfikacji przy użyciu metody SAM pozwalają na wykonanie map badanych gatunków roślinności drzewiastej przy użyciu danych hiperspektralnych HySpex. Mając na uwadze powyższe problemy techniczne, wyniki te można poprawić poprzez zastosowanie dokładnych opracowań mapowych prezentujących występowanie roślinności (wiedza *a priori*), implementację innych procedur klasyfikacyjnych, tj. SVM, sztuczne sieci neuronowe czy integrację zobrazowań hiperspektralnych z danymi ze skaningu laserowego (DALPONTE, BRUZZONE, GIANELLE, 2012). Jak przedstawia Zagajewski (2005) zastosowanie większości klasyfikatorów bez dodatkowych danych, tj. ALS nie daje

satisfakcjonujących rezultatów. W związku z powyższym, należałoby wykorzystać dodatkowe dane, tak aby kartowanie roślinności było bardziej dokładne. Dodatkowo na poprawę uzyskanych dokładności mogłoby mieć wpływ uwzględnienie cech treści obrazowych, takich jak tekstura czy kształt identyfikowanych obiektów, co definiuje się na drodze klasyfikacji obiektowej.

## References

- BANK DANYCH O LASACH. 2016. *Lasy na mapach*. Available at: <http://www.bdl.lasy.gov.pl/portal/mapy>.
- BARTOLD, M. 2008. *Klasyfikacja drzewostanów na obrazie hiperspektralnym Hyperion (EO-1)*. Teledetekcja Środowiska, 39, p. 5-29, Warsaw.
- BIAŁOWIESKI PARK NARODOWY. 2007. *Flora*. Available at: <http://bpn.com.pl/>.
- CHROMAŃSKI, A., GRZEGORZEWICZ, T., MAJSTERKIEWICZ, K., WIŚNIEWSKA, E., ZAJĄCZKOWSKI, G. 2013. *Korzystanie z danych teledetekcyjnych w monografii GEOMATYKA w Lasach Państwowych. Część II. Poradnik praktyczny*. Monografia pod redakcją Ludmiły Kwiatkowskiej. Warszawa: Agencja Reklamowo-Wydawnicza A. Grzegorzczak, ss. 139-208.
- CIOŁKOSZ, A., MISZAŁSKI, J., OLEŃDZKI, J.R. 1999. *Interpretacja zdjęć lotniczych*. Wydawnictwo Naukowe PWN, Warsaw.
- COATES, A., R., DENNISON, P., E., ROBERT, D., A., ROTH, K., L. 2015. *Monitoring the Impacts of Severe Drought on Southern California Chaparral Species using Hyperspectral and Thermal Infrared Imagery*. *Remote Sensing*, 7(11), 14276-14291.
- 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, p. 258-270.
- DALPONTE, M., ØRKA, H. O., GOBAKKEN, T., GIANELLE, D., NÆSSET, E. 2013. *Tree Species Classification in Boreal Forests With Hyperspectral Data*. *IEEE Transactions On Geoscience And Remote Sensing*, vol. 51, nr 5, ss. 2632-2645.
- THE UNIVERSITY OF BRITISH COLUMBIA. 2017. *Data Fusion. Integrating advanced spectral and structural remotely sensed data to improve vegetated terrestrial ecosystem mapping*. Available at: <http://firslab.forestry.ubc.ca/research/>.
- GHOSH, A., FASSNACHT, F.E., JOSHI, 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, p. 49-63.
- GŁOWIENKA-MIKRUT, E. 2014. *Analiza porównawcza metod przetwarzania danych hiperspektralnych o zróżnicowanej rozdzielczości*. PhD report, Akademia Górniczo-Hutnicza im. Stanisława Staszica, Cracow.
- HABOUDANE, D., MILLER, J.R., PATTEY, E., ZARCO-TEJADA, P.J., STRACHAN, I.B. 2004. *Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture*. *Remote Sensing of Environment*, 90, p. 337-352.
- INSTYTUT BADAWCZY LEŚNICTWA. 2014. *Instrukcja wykonywania wielkoobszarowej inwentaryzacji lasów*. Sękocin Stary.
- INSTYTUT BADAWCZY LEŚNICTWA. 2016. *LIFE+ ForBio-Sensing PL*. Available at: [www.ibles.pl/](http://www.ibles.pl/).
- KÄRCEL, S., JANZEN, A., HOFMAN, J., KLINNER, S. 2014. *Szacowanie biomasy na podstawie różnych systemów teledetekcyjnych w monografii Szacowanie biomasy leśnej za pomocą teledetekcji i modelowania. Wyniki projektu „ForseenPOMERANIA” zrealizowanego w ramach współpracy polsko-niemieckiej*. Monografia pod redakcją Jensa Schrödera. Eberswalde: Leśne Centrum Kompetencyjne Eberswalde, ss. 15-115.
- LASY PAŃSTWOWE. 2016. *Kornik w Puszczy*. Available at: <http://www.lasy.gov.pl/informacje/aktualnosci/puszcza-bialowieska>.
- MÖCKEL, T., DALMAYNE, J., PRENTICE, H., C., EKLUNDH, L., PURSCHKE, O., SCHMIDTLEIN, S., HALL, K. *Classification of Grassland Successional Stages Using Airborne Hyperspectral Imagery*. *Remote Sensing*, 6(8), ss. 7732-7761.
- PAL, M., MATHER, P., M. 2006. *Some issues in the classification of DAIS hyperspectral data*. *International Journal of Remote Sensing* 27 (14), ss. 2895-2916.
- PALUCH, R. 2014. *Tempo i kierunki zmian składu gatunkowego drzewostanów naturalnych w wybranych zbiorowiskach leśnych Puszczy Białowieskiej*. *Leśne Prace Badawcze*, vol. 75 (4): 385-406.
- RACZKO, E., ZAGAJEWSKI, B., OCHYTRA, A., JAROCIŃSKA, A., MARCINKOWSKA – OCHYTRA, A., DOBROWOLSKI, M. 2015. *Określenie składu gatunkowego lasów Góry Chojnik (Karkonoski Park Narodowy) z wykorzystaniem lotniczych danych hiperspektralnych APEX*. *Sylvan*, 159 (7), ss. 593-599.
- SERPICO, S., MOSER, G. 2007. *Extraction of Spectral Channels from Hyperspectral Images for Classification Purposes*. *IEEE Transactions On Geoscience And Remote Sensing*, vol. 45, nr 2, ss. 484-495.
- SOBCZAK, M. 2009. *Hyperspektralna metoda badania i kartowania roślinności wysokogórskiej*. *Teledetekcja Środowiska*, 41, p. 79-103.
- SOKOŁOWSKI, A.W. 2004. *Lasy Puszczy Białowieskiej*. Centrum Informacyjne Lasów Państwowych, Warsaw.
- VARSHNEY, P., ARORA, M., RAO, C. 2006. *Signal Processing for Hyperspectral Data*. *IEEE International Conference on Acoustics, Speech and Signal Processing – Proceedings*, vol. 15.
- ZAGAJEWSKI, B. 2010. *Podstawy metodyczne klasyfikacji danych hiperspektralnych*. *Teledetekcja Środowiska*, 43, p. 23-37, Warsaw.
- ZAGAJEWSKI, B., JAROCIŃSKA, A., OLESIUŁ, D. 2010. *Metody i techniki badań geoinformatycznych*. Warsaw University, Faculty of Geography and Regional Studies.
- ZAGAJEWSKI, B., KOZŁOWSKA, A., KROWCZYŃSKA, M., SOBCZAK, M., WRZESIEŃ, M. 2005. *Mapping high mountain vegetation using hyperspectral data*. *EARSel eProceedings*.





**Mgr inż. Paulina BARTKOWIAK**, jest absolwentem Wydziału Geodezji i Kartografii Politechniki Warszawskiej. Obecnie pracuje w Zakładzie Fotogrametrii, Teledetekcji i Systemów Informacji Przestrzennej na Wydziale Geodezji i Kartografii PW, na stanowisku asystenta naukowo-dydaktycznego. Interesuje się synergicznym wykorzystaniem teledetekcji i technik GIS w badaniach środowiska miejskiego i przyrodniczego.

*Paulina BARTKOWIAK, MSc, graduated from the Faculty of Geodesy and Cartography of Warsaw University of Technology (WUT). Currently, employed in the position of research and teaching assistant in the Department of Photogrammetry, Remote Sensing and Spatial Information Systems of the Faculty of Geodesy and Cartography at Warsaw University of Technology. Experienced in image processing and analysis, in particular airborne and satellite based data. Interested in the synergistic use of remote sensing and GIS technology for urban applications*

*and environmental impact assessment.*



**Dr hab. inż. Katarzyna OSIŃSKA-SKOTAK** jest absolwentką Wydziału Geodezji i Kartografii (spec. Fotogrametria i Kartografia) oraz Wydziału Inżynierii Środowiska (spec. Ochrona Atmosfery i Meteorologia Techniczna) Politechniki Warszawskiej. W 2001 r. uzyskała z wyróżnieniem stopień doktora, a w roku 2011 stopień doktora habilitowanego nauk technicznych w dyscyplinie naukowej geodezja i kartografia (spec. teledetekcja i fotogrametria). Obecnie jest kierownikiem Zakładu Fotogrametrii, Teledetekcji i Systemów Informacji Przestrzennej na Wydziale Geodezji i Kartografii Politechniki Warszawskiej. Zajmuje się badaniami dotyczącymi zaawansowanych technik przetwarzania obrazów satelitarnych i lotniczych oraz ich zastosowaniem, w szczególności w badaniach i ochronie środowiska przyrodniczego, jego stanu i zachodzących zmian (m.in. w badaniach jakości wód śródlądowych, miejskiej wyspy ciepła, obszar), archeologii i gospodarce przestrzennej. Realizowała

26 projektów naukowo-badawczych i badawczo-wdrożeniowych, finansowanych ze środków krajowych i europejskich, obecnie kieruje realizacją zadań w ramach projektów badawczo-wdrożeniowych HabitARS („Innowacyjne podejście wspierające monitoring nieleśnych siedlisk przyrodniczych NATURA 2000, z wykorzystaniem metod teledetekcyjnych”, współfinansowany ze środków Narodowego Centrum Badań i Rozwoju w ramach konkursu BIOSTRATEG II, 2016-2018) i SAFEDAM (Zaawansowane technologie wspomagające przeciwdziałanie zagrożeniom związanym z powodziami”, finansowany ze środków Narodowego Centrum Badań i Rozwoju w ramach konkursu Bezpieczeństwo i Obronność, 2015-2018). Odbiła staże naukowe, m.in. w Belgii na Uniwersytecie w Gent, we Francji w GDTA w Toulouse, w Niemczech na Uniwersytecie we Freiburgu, w Niemieckim Centrum Kosmicznym w Oberpfaffenhofen k. Monachium, w Szwecji na KTH. Współzałożycielka Stowarzyszenia “Środowisko dla Środowiska”, członek Grupy Ekspertów przy Sekcji Teledetekcji Komitetu Badań Kosmicznych i Satelitarnych przy Prezydium PAN, członek Zarządu Oddziału Teledetekcji i Geoinformatyki PTG, członek Komisji Głównej ds. Zawodu i Kształcenia Zawodowego Stowarzyszenia Geodetów Polskich oraz członek Platformy Techniki Kosmicznych Politechniki Warszawskiej.