

MARLENA KYCKO, KRZYSZTOF STEREŃCZAK, RADOMIR BAŁAZY

Detekcja posuszu kornikowego z wykorzystaniem obrazowań BlackBridge na przykładzie drzewostanów Sudetów i Beskidów*

Detection of bark beetle infected trees with BlackBridge image on the example of the Sudety and the Beskidy mountains

ABSTRACT

Kycko M., Stereńczak K., Bałazy R. 2016. Detekcja posuszu kornikowego z wykorzystaniem obrazowań BlackBridge na przykładzie drzewostanów Sudetów i Beskidów. Sylwan 160 (9): 707-719.

BlackBridge imagery is one of the new means of information used in forest condition analysis. Rapid Eye satellite data with a 5 m spatial resolution register spectral information from 440 to 850 nm through 5 spectral bands. This range of electromagnetic spectrum provides information on plant chlorophyll content as well as cell structure. Such data allows to monitor vegetation condition. This paper focuses on a research conducted in the Sudety and Western Beskidy mountains (southern Poland). The aim of the research was to verify whether high resolution satellite imagery is applicable in detection of the damages caused by *Ips typographus* and acid rain in Norway spruce dominated stands through supervised classification. BlackBridge Rapid Eye satellite images from 2012 and 2013 were analysed. Various modifications of classification methods were tested, including change in combination of spectral bands. Each method resulted in different classification accuracy. Best results were observed in case of the Maximum Likelihood classification method applied on all spectral bands. The analysis showed that the time of the image registration has a significant impact on classification results. The average classification accuracy for 2012 images was 0.53, whereas for 2013 – 0.69. Moreover, information gathered from 5 m pixels is too general to classify individual dead trees in a precise manner. Tested methods are applicable only in detection of clusters of dead trees.

KEY WORDS

BlackBridge, condition of forests, satellite image classification, mountain areas

ADDRESSES

Marlena Kycko ⁽¹⁾ – e-mail: marlenakycko@uw.edu.pl
 Krzysztof Stereńczak ⁽²⁾ – e-mail: K.Sterenczak@ibles.waw.pl
 Radomir Bałazy ⁽²⁾ – e-mail: R.Balazy@ibles.waw.pl

⁽¹⁾ Zakład Geoinformatyki, Kartografii i Teledetekcji, Uniwersytet Warszawski,
 ul. Krakowskie Przedmieście 24/26, 00-927 Warszawa

⁽²⁾ Zakład Zarządzania Zasobami Leśnymi, Instytut Badawczy Leśnictwa; Sękocin Stary, ul. Braci Leśnej 3,
 05-090 Raszyn

*Pozyskanie danych i analizy przedstawione w artykule możliwe były dzięki projektowi „Utworzenie dla obszaru Sudetów i Beskidu Zachodniego leśnego systemu informacyjnego w zakresie monitoringu i oceny stanu lasu” realizowanemu ze środków Dyrekcji Generalnej Lasów Państwowych.

Wstęp

Struktura lasów przekształca się pod wpływem zmian klimatu, a także w wyniku działania różnego rodzaju czynników stresogennych i katastrof ekologicznych. Zbiorowiska leśne łagodzą zmiany klimatu oraz zmieniają cyrkulację CO₂ w środowisku, dlatego też ich monitorowanie jest bardzo ważne i pełni istotną funkcję we właściwym zarządzaniu przyrodą. Obserwowane w Beskidach Zachodnich zamieranie drzewostanów świerkowych nie jest zjawiskiem nowym. Takie klęski wystąpiły w ostatnich kilkudziesięciu latach także i w Sudetach oraz w innych regionach Europy [Manion 1981], przy czym ich przyczyny były często różne, a prowadziły do tego samego efektu, czyli zniszczenia dużych pościeli lasu w bardzo krótkim czasie. Mimo że podobne zjawiska poddawane były wnikliwej analizie, to jednak nie do końca udało się opisać i poznać złożony proces rozpadu świerczyn. Warto zwrócić uwagę na fakt, że również klęska ekologiczna w lasach sudeckich nie doczekała się jednolitej interpretacji i wskazania, który z czynników odegrał decydującą rolę w rozpadzie drzewostanów [Grodzki 1995; Jadczyk 1995; Błaś, Dore 1998]. Zachodzące w przyrodzie Beskidów Zachodnich oraz Sudetów zmiany są wypadkową wielu, często równoległe toczących się procesów. Dostępne obecnie modele zjawiska zamierania, oparte o cyfrowe modele terenu i powierzchni jego pokrycia, wraz z szeregiem innych zmiennych opisujących funkcjonowanie ekosystemów leśnych, przyczynią się do lepszego poznania mechanizmów wielkoobszarowych wylesień. Stwarza to niespotykaną szansę obserwacji procesów rozpadu drzewostanów w czasie rzeczywistym, pozwalając tym samym na długookresowy monitoring danego zjawiska.

Techniki teledetekcyjne umożliwiają wieloczasową analizę stanu środowiska. Jednak dla obszarów górskich takie analizy są utrudnione. Spowodowane jest to zmiennymi warunkami atmosferycznymi, jak też urozmaiconą rzeźbą, heterogenicznością środowiska oraz deniwelacją terenu, a także rozdzielczością materiału satelitarnego bądź lotniczego, co prowadzi do dużej liczby pikseli mieszanych utrudniających precyzyjną analizę [Zagajewski 2010; Raczko i in. 2015; Ochtyra i in. 2016]. Mimo to zauważalny jest wzrost zainteresowania użyciem danych satelitarnych do badania stanu lasów i ich inwentaryzacji [Holmgren, Thuresson 1998; Vohland i in. 2007]. Początkowo wykorzystywano dane wielospektralne z satelity Landsat [Wolter 1995; Mickelson i in. 1998; Franco-Lopez i in. 2001; Townsend, Walsh 2001; Reese i in. 2002; Dorren i in. 2003], SPOT [Davranche i in. 2010] czy Aster [Stoffels i in. 2012]. Zobrazowania z satelity Landsat, mimo 30-metrowego piksela, znalazły szerokie zastosowanie w ocenie stanu lasów dotkniętych inwazją szkodników [Zawiła-Niedźwiecki, Wiśniewska 2004] i pozwalały ocenić różne parametry oraz uszkodzenia drzewostanów [Ciołkosz, Kęsik 1989; Baniya i in. 2006]. Stosowane je także w analizach skutków pożarów [Walczykowski i in. 2012]. W ostatnim czasie pojawiły się konstelacje takich samych satelit, pozwalające na niemal codzienną rejestrację zobrazowań. Przykładem takiego systemu jest RapidEye (BlackBridge) [Marx 2010; Stoffels i in. 2012; Elatawneh i in. 2013; Arnett i in. 2014].

Zobrazowania te stosowane były w wielu różnych analizach środowiska leśnego, m.in. do monitorowania struktury lasu i wspierania gospodarki leśnej [Wallner i in. 2015] oraz do klasyfikacji gatunków leśnych [Elatawneh i in. 2013]. W tym przypadku rozdzielczość obrazu była jednak zbyt mała i utrudniająca przede wszystkim analizę młodych drzewostanów. Na podstawie tych danych szacowano także parametry biofizyczne i biochemiczne drzewostanu. Wyniki wykorzystane były w tworzeniu modeli, które usprawniły planowanie i zarządzanie zasobami leśnymi [Holmgren, Thuresson 1998; Boyd, Danson 2005; Kongwen, Baoxin 2012]. We wcześniejszych pracach zetknięto się z problemem wyznaczania zasięgu koron poszczególnych drzew na zobrazowaniach BlackBridge [Key i in. 2001; Waser i in. 2011], co związane jest

z wielkością piksela tych zobrazowań. W analizie składu gatunkowego stosowano różne metody klasyfikacji, m.in. metodę uwzględniającą obliczenie kąta spektralnego (ang. Spectral Angle Mapper – SAM), dla której uzyskano wysoką dokładność – 86% [Elatawneh i in. 2013]. Stosując połączenie danych RapidEye oraz ALS, sprawdzano użyteczność modeli do analizy struktury lasu [Dash i in. 2015]. Zastosowanie danych było w tym przypadku mniej precyzyjne niż technologia ALS, jednakże zobrazowania satelitarne stanowiły doskonałe dopełnienie uzyskiwanych informacji.

Stosowano także połączenie danych Landsat z RapidEye w celu opracowania modeli dokładnego oszacowania wylesienia i degradacji lasów w Zambii [Halperin i in. 2016]. Użyto modelu liniowego (ang. Generalized Linear Model – GLM), addatywnego (ang. Generalized Additive Model – GAM), k – najbliższych sąsiadów (ang. k-Nearest Neighbor – k-NN) i algorytmu losowych lasów drzew (ang. Random Forest – RF), z czego model GAM najprecyzyjniej określał wylesienie, natomiast większa liczba kanałów satelity Landsat OLI (Operational Land Imager) pozwoliła na dokładniejsze określenie niż RapidEye. Zobrazowania RapidEye dostały także użyte do klasyfikowania defoliacji wywołanej przez owady. Na obszarze Afryki Subsaharyjskiej użyto klasyfikatora RF oraz metody wektorów nośnych (ang. Support Vector Machine – SVM) przy klasyfikacji RapidEye [Adelabu i in. 2014]. Podkreślono wówczas szczególne zastosowanie kanału RedEdge do zwiększenia precyzji klasyfikacji poziomej defoliacji przez owady. Dokładniejsze wyniki uzyskano przy zastosowaniu znormalizowanego różnicowego wskaźnika wegetacji „krawędzi czerwieni” (ang. Red Edge Normalized Difference Vegetation Index – RENDVI) niż znormalizowanego różnicowego wskaźnika wegetacji (ang. Normalized Difference Vegetation Index – NDVI). Dokładność całkowita wzrosła dla RF o 19%, a dla klasyfikatora SVM o 21%.

Oceniano także przydatność zobrazowań RapidEye do analizy stanu lasów zaatakowanych przez kornika i zniszczeń po burzach, m.in. w regionach Europy Środkowej [Elatawneh i in. 2014]. Rozdzielczość tych zobrazowań jest odpowiednia do wykrywania zmian w lesistości, a zdolność do częstej akwizycji obrazów pozwala na stały monitoring tego zjawiska. Dobierano też różnorodne metody klasyfikacji w badaniach stanu lasów [Elatawneh i in. 2012], porównując metodę SAM oraz sztuczne sieci neuronowe (ang. Artificial Neural Networks – ANNs) z wykorzystaniem dodatkowo danych Hyperion oraz danych z QuickBird, co pozwoliło na poprawę ostatecznych wyników klasyfikacji. Stwierdzono, że przy wzroście rozdzielczości czasowej wzrasta także dokładność całkowita klasyfikacji. Wzrost dokładności zauważono dla zdjęć z okresu letniego, a dla wczesnego okresu fenologicznego rozwoju drzew dokładność była wyższa w porównaniu z okresem jesiennym, gdzie wystąpił zbyt duży wpływ kąta padania promieni słonecznych na jakość informacji na obrazie. Problemem bywa podobna charakterystyka spektralna niektórych gatunków drzew, co generuje trudności w poprawnym sklasyfikowaniu badanych obiektów [Elatawneh i in. 2012]. Analiz zobrazowań BlackBridge dokonywano poprzez klasyfikację metodą wektorów nośnych (SVM) i maksymalnego prawdopodobieństwa (Maximum Likelihood), jako najbardziej efektywnych rodzajów klasyfikacji form pokrycia terenu, które ulepszyły wyniki wstępnej segmentacji obrazu także dla terenów leśnych [Tavares de Carvalho 2013]. Pokrycie terenu na zdjęciu RapidEye klasyfikowano za pomocą drzewa decyzyjnego (Decision Tree, DT), algorytmu losowych lasów drzew (ang. Random Forest, RF) i metody wektorów nośnych (SVM). Pod względem ogólnej dokładności metoda RF okazała się lepsza zarówno od DT, jak i SVM, powodując najwyższą dokładność klasyfikacji – 85,05%. Różnica pomiędzy DT i SVM wynosiła 1,18% [Tavares de Carvalho 2013]. Kozioł i Węzyk [2005] w procesie klasyfikacji zastosowali metodę największego prawdopodobieństwa (Maximum Likelihood) do wyznaczania przemysłowych stref uszkodzeń drzewostanów na przykładzie Miasteczka Śląskiego.

Celem niniejszej pracy było opracowanie metodyki bazującej na danych teledetekcyjnych RapidEye (BlackBridge), która mogłaby służyć do znalezienia najbardziej przydatnego algorytmu klasyfikacji i detekcji posuszu kornikowego w drzewostanach Sudetów i Beskidów, gdzie gatunkiem przeważającym jest świerk pospolity (*Picea abies* (L.) Karst). Dodatkowo sprawdzono wpływ terminu wykonania zobrażeń BlackBridge na dokładność detekcji martwych drzew.

Materiał i metody


Badaniami objętych zostało sześć nadleśnictw położonych w Sudetach: Świeradów, Szklarska Poręba, Bystrzyca Kłodzka, Zdroje, Międzyzlesie i Łądek Zdrój oraz sześć nadleśnictw położonych w Beskidach Zachodnich: Bielsko (częściowo), Jeleśnia (częściowo), Ujsoły (częściowo), Ustroń, Węgierska Górka i Wisła. Łącznie badania dotyczyły 778 km² w Sudetach i 1200 km² w Beskidach. Były to tereny, na których występowały wcześniej bądź występują obecnie gradacje korników.

Dane satelitarne BlackBridge (BB) są pierwszym komercyjnym systemem rejestrującym promieniowanie w dwóch zakresach podczerwieni. Okres rewizyty wynosi 1 dzień, co powoduje, że zdjęcia stają się bardziej przydatne do monitoringu czy też wsparcia zarządzania kryzysowego. Zobrazowania satelitarne RapidEye posiadają rozdzielczość 5 metrów (piksel przepróbkowany ORTHO, oryginalna wielkość piksela – 6,5 m – nadir) [Tyc i in. 2005]. Sensor multispektralny działa w 5 zakresach spektralnych: 440-510 nm (Blue), 520-590 nm (Green), 630-685 nm (Red), 690-730 nm (Red Edge) i 760-850 nm (Near IR), czyli obejmuje zakresy, które charakteryzują takie parametry roślinne jak chlorofil i struktury komórkowe.

Zobrazowania RapidEye (BlackBridge) użyte do niniejszych analiz pochodziły z lat 2012-2013. W celu przygotowania obrazów satelitarnych do dalszej analizy poddano je korekcji geometrycznej i atmosferycznej. Ortofotomapa każdego z badanych obszarów wykonana w 2012 roku posłużyła jako dane referencyjne do oceny klas stanu zdrowotnego drzewostanów, a także do wyrysowania poligonów referencyjnych, które zastosowano do oceny dokładności metod klasyfikacji. Dane lotniczego skanowania laserowego pozyskane zostały równolegle z ortofotomapą w sierpniu 2012 roku. Na ich podstawie wygenerowano znormalizowany numeryczny model pokrycia terenu (zNMPT) i za jego pomocą usunięto ze zobrażeń satelitarnych obszary o wysokości mniejszej od 1 m, wykluczając w ten sposób luki, w których często zalegała martwa materia organiczna, powodująca fałszywe wskazania martwych drzew (ryc. 1).

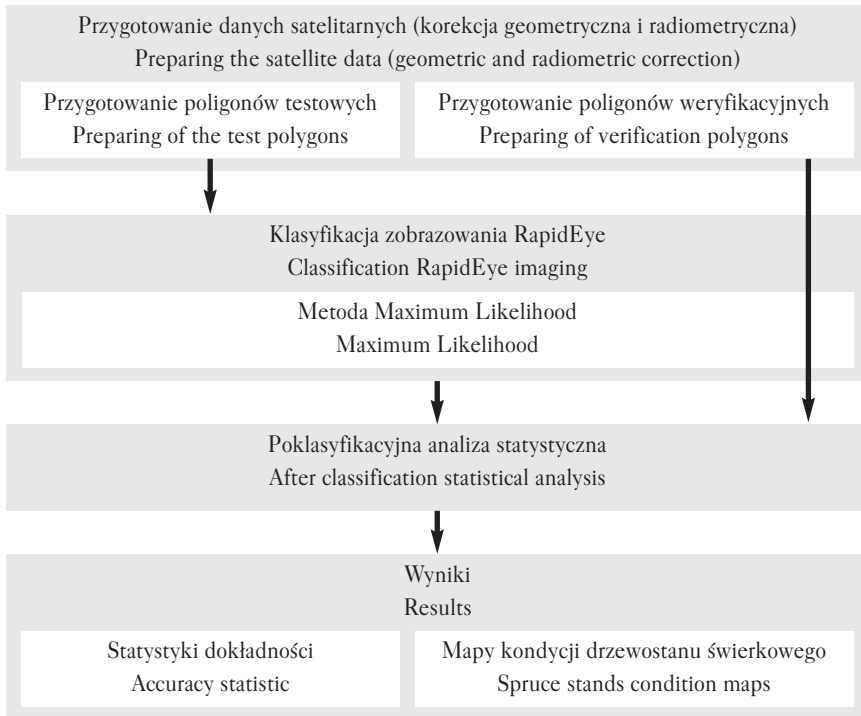
Zobrazowania satelitarne BB pozyskane na poziomie 1A (korekcja radiometryczna i korekcja sensora) zostały poddane korekcji geometrycznej i atmosferycznej (ENVI 5.0), a także dopasowane do ortofotomapy (ArcGIS). W oprogramowaniu ENVI 5.0 przygotowano maskę chmur dla scen, na których występowało zachmurzenie. Dla każdego badanego terenu wyznaczono poligony weryfikacyjne i testowe, wykorzystane w dalszej kolejności do klasyfikacji (ryc. 2).

W celu lepszej analizy drzewostanu wybrano w oparciu o NMPT obszary o wysokości 1 m (by wyeliminować przestrzeń między drzewami, a także zacienione luki), które odzwierciedlały zadrzewienie na zobrażeniach satelitarnych. Dla zobrażeń późnojesiennych bądź też wczesnowiosennych utworzono warstwę zawierającą lasy liściaste, a następnie odseparowano te obszary, maskując je na zobrażeniach satelitarnych, aby nie zaburzały wyników i nie klasyfikowały się jako martwe świerki. Poligony testowe i referencyjne służące do klasyfikacji i oceny dokładności klasyfikacji wyrysowano w oparciu o ortofotomapę. Dla każdego obszaru badawczego założono 500 poligonów testowych i 250 poligonów weryfikacyjnych. Poligony były rozłożone równomiernie na zobrażeniu, a ich powierzchnia była nie mniejsza niż rozmiar piksela. Wykonano klasyfikację przetworzonych zobrażeń metodą największego prawdopodobieństwa (ang. Maximum



Ryc. 1.

Ortofotomapa z 2012 roku z uwzględnieniem drzew o wysokości powyżej 1 m
 Orthofotomap from 2012 with regard to trees over 1 m of theight



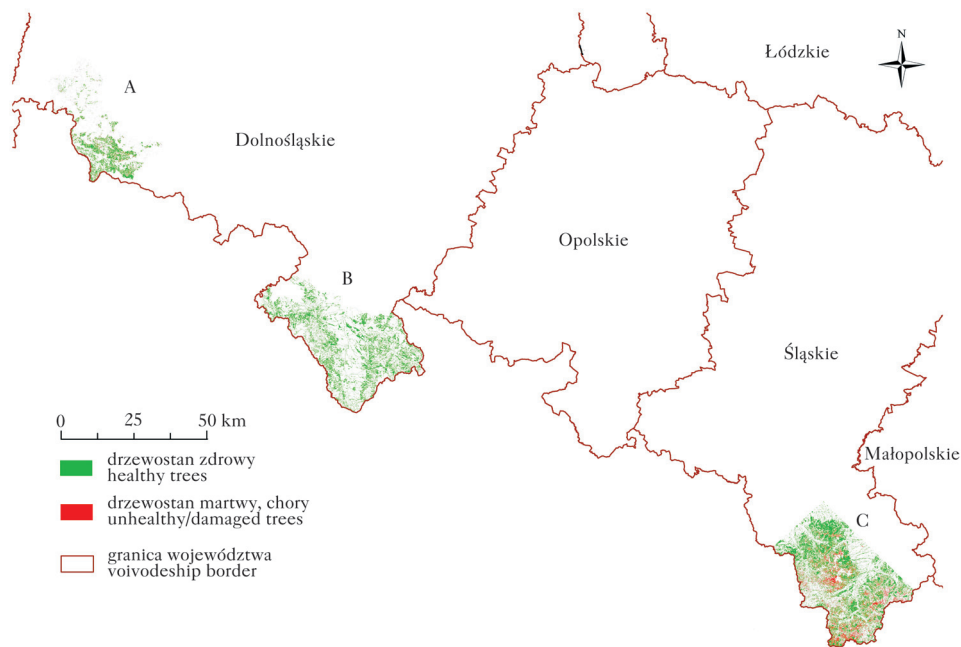
Ryc. 2.

Schemat postępowania
 Study design

Likelihood), najmniejszej odległości (ang. Minimum Distance) i odległości Mahalanobisa (ang. Mahalanobis Distance).

Klasyfikację zobrazowań dla wszystkich obszarów badawczych wykonano z modyfikacją różnych kompozycji kanałów – 1: 440-510 nm (Blue), 2: 520-590 nm (Green), 3: 630-685 nm (Red), 4: 690-730 nm (Red Edge), 5: 760-850 nm (Near IR). Przeprowadzono klasyfikację następujących zestawów danych utworzonych odpowiednio z kanałów: 2,3,4,5; 1,2,3,4,5; 5,4,3; 5,4,2 i 5,3,2. Do klasyfikacji wykorzystano także teledetekcyjne wskaźniki roślinności (NDVI, RENDVI), tworząc następujące zestawy klasyfikowanych danych: NDVI, RENDVI, 4,NDVI,2 i 3,NDVIRE,2. Wskaźniki Normalized Difference Red Edge Index [Sims, Gamon 2002] oraz Normalized Difference Vegetation Index [Rouse i in. 1973] bazują odpowiednio na wzorach $(\text{kanał5}-\text{kanał4})/(\text{kanał5}+\text{kanał4})$ oraz $(\text{kanał5}-\text{kanał3})/(\text{kanał5}+\text{kanał3})$. Oba wskaźniki obrazują kondycję badanej roślinności (rozwój jej baldachimu, zawartość chlorofilu, stan struktur komórkowych), jednakże wskaźnik RENDVI, poprzez wykorzystanie tzw. „krawędzi czerwieni” (Red Edge), precyzyjniej podkreśla to, co dzieje się w komórkach roślinnych [Kycko i in. 2014]. Najlepsze wyniki dokładności klasyfikacji uzyskane zostały dla algorytmu przeprowadzonego na wszystkich 5 kanałach zobrazowania RapidEye (ryc. 3, tab.).

Wyniki klasyfikacji martwych drzew poddano analizie dokładności, obliczając dokładność producenta (A_p), dokładność użytkownika (A_u) oraz dokładność całkowitą (I_{CP}). Dokładność producenta jest wyrażona poprzez stosunek pikseli poprawnie sklasyfikowanych w danej klasie do całkowitej liczby pikseli tej klasy w danych wzorcowych:



Ryc. 3.

Wyniki detekcji martwych i chorych drzew iglastych klasyfikacją Maximum Likelihood dla nadleśnictw Świeradów i Szklarska Poręba (A), Bystrzyca Kłodzka, Zdroje, Międzyzlesie i Łądek Zdrój (B) oraz Bielsko, Jeleśnia, Ujsoły, Ustroń, Węgierska Górka i Wisła (C)

Dead or damaged trees detection with Maximum Likelihood method for Świeradów and Szklarska Poręba (A), Bystrzyca Kłodzka, Zdroje, Międzyzlesie and Łądek Zdrój (B) as well as Bielsko, Jeleśnia, Ujsoły, Ustroń, Węgierska Górka and Wisła (C)

Tabela.

Dokładność całkowita (I_{CP}), producenta (A_P) i użytkownika (A_U) wykrywalności martwego drzewostanu za pomocą klasyfikacji zobrażeń BlackBridge

Total (I_{CP}), producer (A_P) and user (A_U) accuracy of the dead trees detection with BlackBridge image classification

Termin Date	Świeradów, Szklarska Poręba		Bystrzyca Kłodzka, Zdroje, Międzylesie, Lądek Zdrój				Bielsko (częściowo), Jelesnia (częściowo), Ujszoły (częściowo), Ustroń, Węgierska Górka, Wisła					
	08.07.2012	15.05.2013	09.09.2012	19.05.2013			24.07.2012	24.07.2013				
I_{CP}	0,54	0,72	0,52	0,63	0,53	0,72						
Kappa	0,02	0,44	0,02	0,02	0,01	0,44						
Klasa	1	2	1	2	1	2	1	2	1	2		
A_P	0,95	0,51	0,44	0,69	0,93	0,52	0,92	0,52	0,95	0,51	0,45	0,69
A_U	0,07	0,08	0,27	0,71	0,13	0,16	0,13	0,16	0,07	0,08	0,27	0,72

Klasa: 1 – zdrowy drzewostan, 2 – martwy lub chory drzewostan

Klasa: 1 – healthy trees, 2 – weakened or dead trees

$$A_P = \frac{n_{jj}}{\sum_{i=1}^k n_{ij}}$$

gdzie:

n_{jj} – liczba pikseli poprawnie sklasyfikowanych,

k – liczba klas,

n_{ij} – liczba pikseli z danego pola weryfikacyjnego, które zostały zaliczone do klasy i , podczas gdy faktycznie należą do klasy j .

Dokładność użytkownika jest ilorazem pikseli poprawnie sklasyfikowanych w klasie i całkowitej liczby pikseli tej klasy na obrazie weryfikowanym:

$$A_U = \frac{n_{ii}}{\sum_{j=1}^k n_{ij}}$$

gdzie:

n_{ii} – liczba pikseli poprawnie sklasyfikowanych,

k – liczba klas,

n_{ij} – liczba pikseli z danego pola weryfikacyjnego, które zostały zaliczone do klasy i , podczas gdy faktycznie należą do klasy j .

Całkowita dokładność klasyfikacji jest ilorazem sumy pikseli sklasyfikowanych poprawnie i całkowitej liczby pikseli:

$$I_{CP} = \frac{\sum_{p=1}^k n_{pp}}{n}$$

gdzie:

k – liczba klas,

n_{pp} – liczba pikseli poprawnie sklasyfikowanych,

n – całkowita liczba pikseli.

Współczynnik Kappa wyraża łączny błąd klasyfikacji – wartość 1 oznacza pełną zgodność klasyfikacji.

Wyniki

Dla badanych terenów uzyskano niską dokładność klasyfikacji w przypadku detekcji pojedynczych martwych drzew świerka. Jest to spowodowane 5-metrową rozdzielczością zobrazenia (piksel przepróbkowany ORTHO, oryginalna wielkość piksela – 6,5 m – nadir), a także sezonem pozyskania zobrazenia satelitarnego. Najlepszą dokładność wyznaczenia samych martwych drzewostanów uzyskano dla klasyfikacji Maximum Likelihood podczas klasyfikacji obrazu (po usunięciu na nim powierzchni poniżej 1 metra) z użyciem wszystkich kanałów spektralnych zobrazenia BlackBridge. Przeanalizowanie dwóch sezonów wegetacyjnych pozwoliło zauważyć zmienną dokładność klasyfikacji opracowaną na tych samych poligonach (tab.). Poligony użyte do analizy zostały opracowane na podstawie ortofotomapy z 2012 roku. Dla roku 2013 uzyskano znacznie wyższą całkowitą dokładność klasyfikacji, oscylującą w granicach 0,70. By dopasować możliwości detekcji martwych drzew do możliwości przestrzennych użytych danych teledetekcyjnych, podjęto próbę wyznaczenia grup uszkodzonych drzew i sprawdzenia, w jakim procencie możliwe jest prawidłowe ich określanie. Kryterium określającym grupę drzew było zagęszczenie powierzchniowe większe niż jeden piksel. Analizę przeprowadzono dla roku 2013 dla wszystkich obszarów badawczych. Na obszarze badawczym w rejonie Beskidu Zachodniego stopień wykrywalności pojedynczych martwych drzew wyniósł 68%, natomiast dla terenu Sudetów osiągnięto gorsze wyniki: nadleśnictwa Świeradów i Szklarska Poręba – 58%, a nadleśnictwa Bystrzyca Kłodzka, Zdroje, Międzyzlesie i Lądek Zdrój – 56%. Sprawdzone także procent wykrywalności drzew martwych rosnących w grupach, gdzie wyniki były następujące: teren Beskidu Zachodniego – 74%, nadleśnictwa Świeradów i Szklarska Poręba – 62%, natomiast nadleśnictwa Bystrzyca Kłodzka, Zdroje, Międzyzlesie i Lądek Zdrój – 68%.

Dyskusja

Dostępne metody klasyfikacji umożliwiają wieloaspektową analizę danego zjawiska, co pozwala na realizację różnych koncepcji do prezentowanego zagadnienia. Szerokie możliwości prowadzenia parametrów czy też progów podczas klasyfikacji dają zmienne dokładności zarówno w analizie danych wielospektralnych, jak też hiperspektralnych [Rajee i in. 2014]. Rajee i in. [2014] zastosowali klasyfikację SVM dla danych z rozdzielczością przestrzenną 30 m (dane z sensora Hyperion), uzyskując dla wydzieleni poszczególnych gatunków (dąb, sosna, cedr, jodła) dokładność klasyfikacji 82%. Porównując uzyskane wyniki badań, można stwierdzić, że dokładność całkowita wydzielenia martwego drzewostanu na zobrazeniach RapidEye jest zadowalająca z uwagi na topografię terenu. Klasyfikacje na zobrazeniach BlackBridge dają wyniki dokładności zróżnicowane (56-74%) w zależności do przyjętych metod, a także rodzaju roślinności czy też innej badanej formy pokrycia terenu. W klasyfikacjach roślinności używano też teledetekcyjnych wskaźników roślinności, które pozwalały na dokładniejsze rozróżnienie badanych form i wysoką dokładność klasyfikacji – powyżej 85% [Roslani i in. 2014]. Dodatkowe zastosowanie w klasyfikacji kanału RedEdge, obrazującego zawartość chlorofilu i stan struktur komórkowych, poprawiło identyfikację gatunków drzew. Najwyższa dokładność została osiągnięta dla świerka (94,52%), natomiast najniższa (64%) dla modrzewia [Elatawneh i in. 2013]. W analizie strat leśności terenu pagórkowatego w Niemczech uzyskano dokładność około 94%. Analiza stanu drzewostanu na zobrazeniach RapidEye miała dość wysoką dokładność (97% użytkownika, 82% producenta; kappa: 0,89) w przypadku klasyfikacji drzew martwych. Zauważono, że wyróżnienie

zagrożonych drzewostanów (tzw. chorych) jest utrudnione, gdyż drzewa te niekiedy nadal są wizualnie „zielone” [Marx 2010]. Powyższe badania potwierdzają spostrzeżenia autorów niniejszego opracowania odnośnie do trudności wydzielenia martwych drzew. Wskaźniki teledetekcyjne (w tym wypadku NDVI i RENDVI) ze względu na uschnięty materiał nie wnoszą dodatkowej informacji, która ułatwiłaby klasyfikowanie takich obiektów na obrazowaniach RapidEye. Co więcej, wpływ na dokładność klasyfikacji ma także pora wykonania obrazowania satelitarnego oraz bujnie rozwijający się podszyt, który zmienia odbicie spektralne w wybranym pikselu (mimo obecności tam martwego drzewostanu). Kolejnym problemem jest wielkość obiektów, które są przedmiotem analizy, i charakter zjawiska. Jedynie największe drzewa w całości mieszczą się w całym pikselu, często niestety tylko dla fragmentów dużych drzew rejestrowana jest w pikselu informacja spektralna, dlatego też dokładniejsze jest wykrycie centrum uszkodzonego drzewostanu [Elatawneh i in. 2014]. Elatawneh i in. [2014] prowadzili klasyfikację obiektową stanu lasów na górzystym obszarze Bawarii (Bavarian Forest National Park), uzyskując dokładność 96,7, a wartość kappa 0,86, z tym że klasyfikowano tutaj zwarte powierzchnie leśne, wspierając się przy analizie wizualną interpretacją fotografii lotniczej oraz stosując algorytm różnicowy zdjęć zarówno przed zniszczeniami wywołanymi burzą, jak i po nich. Problematyczne są w analizach także tzw. mixele, które mają obniżoną/podwyższoną wartość, wynikającą nie ze złego stanu drzewostanu, a z mieszania się informacji spektralnej podszytu, dna lasu i koron drzew. Na obrazowaniu wielospektralnym BlackBridge można wyznaczać z największą dokładnością jedynie duże pojedyncze martwe drzewa lub grupy martwych drzew. Piksel (5 m) obrazowania BB jest przepróbkowany, co daje zbyt uśrednioną, niekiedy zmieszaną informację w pikselu, by można było klasyfikować pojedyncze martwe drzewa. Dodatkowo znaczny wpływ na wynik klasyfikacji ma zastosowana metoda resamplingu – może dojść do wygładzenia skrajnych wartości, ich uśrednienia czy też zduplikowania bądź nawet zaginięcia niektórych pikseli. Goodwin i in. [2008] potwierdzają trudności w wykryciu na obrazowaniach RapidEye mniejszych zmian w stanie drzewostanu, takich jak przebarwienia liści i stopniowa defoliacja spowodowana przez szkodniki. Ochtyra i in. [2016] zastosowali do klasyfikacji form pokrycia terenu Tatrzańskiego Parku Narodowego metody Minimum Distance, Mahalanobis Distance, Maximum Likelihood oraz Support Vector Machines. Najlepsze wyniki klasyfikacji zasięgu lasów uzyskali przy użyciu algorytmu największego prawdopodobieństwa (Maximum Likelihood): 97,69% dokładności producenta oraz 98,31% dokładności użytkownika. Badacze ci odnotowali podobne problemy jak autorzy niniejszego opracowania, mianowicie obszary zacienione i luki między drzewami, które klasyfikowały się błędnie. Zastosowano wskaźnik NDII, co rozwiązało problem klasyfikacji drzewostanów martwych jako skał. Stosując obrazowania RapidEye, nie można wyliczyć wskaźników wodnych, gdyż sensor działa w 5 zakresach spektralnych. Aby rozwiązać ten problem, w prowadzonych badaniach posłużono się maską z nMPT. Niestety, górzysty teren i różna rozdzielczość przestrzenna materiałów czynią ten proces nie dość dokładnym, stąd nawet po użyciu maski pozostają fragmenty gruntu, które pogarszają wyniki klasyfikacji.

Dobór wartości progowych dla poszczególnych algorytmów klasyfikacji był subiektywny, jednakże zaprezentował jednolite podejście dla obu okresów prowadzonych badań (lata 2012 i 2013). Celem niniejszego opracowania było przedstawienie możliwości wykrycia martwego drzewostanu, nie brano natomiast pod uwagę takich aspektów jak warunki meteorologiczne w danym roku. Czynniki te mają wpływ na stan drzewostanu i rozwój zagrożenia spowodowanego przez korniki, aczkolwiek proces ten jest na tyle złożony, że posłużono się zastosowaniem tych samych kryteriów, by obiektywnie ocenić martwy drzewostan w badanych obszarach.

Proces zamierania świerka w górach południowej Polski ma obecnie charakter objawiający się na pojedynczych drzewach lub w małych gniazdach, różni się więc charakterem od podobnych procesów zachodzących w przeszłości [Grodzki 2004, 2009; Grodzki, Guzik 2009; Grodzki i in. 2010, 2014]. W związku z tym do analizy tego zjawiska bardziej odpowiednie byłyby dane o wyższej rozdzielczości przestrzennej, np. QuickBird [Ghioca-Robrecht i in. 2008], Pleiades [Rougier, Puissant 2014; Beguet i in. 2015] lub WorldView-2 [Abd i in. 2012; Immitzer i in. 2012]. Najbardziej dokładne, ale i najdroższe byłyby dane hiperspektralne, które z największym prawdopodobieństwem odzwierciedlałyby stan drzewostanu, a także pozwalały na monitoring zagrożeń wywołanych zarówno przez kornika, jak i inne czynniki zewnętrzne. Prowadzone są badania z użyciem zaawansowanych klasyfikatorów na danych hiperspektralnych służących do inwentaryzacji i określenia składu gatunkowego lasów [Kokaly i in. 2003; Shen i in. 2010; Raczko i in. 2015].

Nie bez znaczenia jest tu rola pracowników administracji leśnej. W warunkach niegradacyjnych gniazda kornikowe biorą najczęściej swój początek od kilku-kilkunastu zaatakowanych drzew. W miarę upływu czasu i w warunkach, w których nie ingeruje człowiek, korniki zasiedlają sąsiadujące drzewa, przez co po kilku latach powstaje gniazdo, w którym środkowe drzewa są już martwe, często także już leżące, a na obwodzie gniazda znajdują się drzewa w różnym stopniu osłabione lub obumarłe w wyniku żerowania kornika [Grodzki 2004; Grodzki i in. 2010]. Takie gniazdo, rozwijające się w sposób naturalny, ma dość charakterystyczny wygląd, a ponadto jest stosunkowo duże, przez co łatwo jest je zlokalizować teledetekcyjnie. W warunkach gospodarki leśnej zaatakowane drzewa lub posusz są na bieżąco usuwane z lasu. Stąd detekcja tych zjawisk w lasach gospodarczych obarczona jest przede wszystkim mniejszą skalą przestrzenną występowania zjawiska (poziom pojedynczych drzew lub małych luk), a po drugie – występowanie luk po usuniętych drzewach może powodować błędy w klasyfikacji.

Pora roku znacznie wpływa na klasyfikację zobrazowania pod kątem oceny stanu drzewostanu, a także wydzielenia typów drzewostanu. Najwyższą dokładność klasyfikacji martwych drzew osiągnięto dla zobrazowań satelitarnych pochodzących z okresu letniego, gdzie w pełni rozwinięty jest drzewostan, natomiast zdjęcia wiosenne, jak i jesienne uniemożliwiają prawidłowe sklasyfikowanie drzewostanu liściastego. Spowodowane jest to specyfiką rozwoju drzew liściastych, a także zmiennym kątem oświetlenia [Elatawneh i in. 2013]. W celu jak najlepszej klasyfikacji drzewostanu świerkowego bez zaburzeń drzewami liściastymi stosuje się maskę.

Podsumowanie

Zastosowane zobrazowań BlackBridge pozwala na analizę wielkoobszarowych skupisk martwych drzew i detekcję rozprzestrzeniania ognisk zapalnych kornika bądź też analizę zmienności stanu drzewostanów świerkowych. Stopień dokładności zależy od odpowiednio przygotowanych materiałów, a także od stopnia trudności terenu. W przypadku terenów górskich mamy do czynienia z nachyleniem stoków i zacienieniem obszarów, co obniża możliwość osiągnięcia wysokich dokładności. Zaproponowana w pracy metoda umożliwia detekcję posuszu kornikowego, co może stanowić wsparcie monitoringu obszarów chronionych, a zarazem cennych z punktu widzenia leśnictwa.

Literatura

- Abd L. Z. 2012. Determination of Tree Species Using Worldview-2 Data. Paper presented at the 2012 IEEE 8th International Colloquium on Signal Processing and its Applications.
- Adelabu S., Mutanga O., Adam E. 2014. Evaluating the impact of red-edge band from Rapidehe image for classifying insect defoliation levels. ISPRS Journal of Photogrammetry and Remote Sensing 95: 34-41.

- Arnett J. T. R., Coops N. C., Gergel S. E., Falls R. W., Baker R. H. 2014. Detecting Stand-Replacing Disturbance using RapidEye Imagery: a Tasseled Cap Transformation and Modified Disturbance Index. *Canadian Journal of Remote Sensing* 40: 1-14.
- Baniya N., Zawila-Niedzwiecki T., Majunke C., Hauswirth M. 2006. Zdjęcia satelitarne Landsat TM w ocenie gradacji brudnicy mniszki. *Leśn. Pr. Bad.* 3: 33-44.
- Beguet B., Chehata N., Boukir S., Guyon D. 2015. Classification of forest structure using very high resolution Pleiades image texture. *Geoscience and Remote Sensing Symposium (IGARSS), 2014 IEEE International.* 2324-2327.
- Błaś M., Dore J. 1998. Znaczenie bariery orograficznej w determinowaniu roli efektu „seeder-feeder” na przykładzie Gór Izerskich i masywu Ślęży. *Problemy klimatyczno-botaniczne Gór Izerskich. Materiały z konferencji naukowej* 21-23.IX.1998, Świeradów Zdrój.
- Boyd D., Danson F. 2005. Satellite remote sensing of forest resources: three decades of research development. *Progress in Physical Geography* 29 (1): 1-26.
- Ciołkosz A., Kęsik A. 1989. Teledetekcja satelitarna. PWN, Warszawa.
- Dash J., Watt M., Bhandari S., Watt P. 2015. Characterising forest structure using combinations of airborne laser scanning data, RapidEye satellite imagery and environmental variables. *Forestry* 89 (2): cpv048.
- Davranche A., Lefebvre G., Poulin B. 2010. Wetland monitoring using classification trees and SPOT-5 seasonal time series. *Remote Sensing of Environment* 114 (3): 552-562.
- Dorren L. K. A., Maier B., Seijmonsbergen A. C. 2003. Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. *Forest Ecology and Management* 183 (1-3): 31-46.
- Elatawneh A., Kalaitzidis C., Petropoulos G. P., Schneider T. 2012. Evaluation of diverse classification approaches for land use/cover mapping in a Mediterranean region utilizing Hyperion data. *International Journal of Digital Earth* 1-23.
- Elatawneh A., Rappl A., Rehush N., Schneider T., Knoke T. 2013. Forest tree species communities identification using multiphenological stages RapidEye data: case study in the forest of Freising. 5 RESA Workshop 4/2015, Berlin.
- Elatawneh A., Wallner A., Manakos I., Schneider T., Knoke T. 2014. Forest Cover Database Updates Using Multi-Seasonal RapidEye Data – Storm Event Assessment in the Bavarian Forest National Park. *Forests* 5 (6): 1284-1303.
- Franco-Lopez H., Ek A. R., Bauer M. E. 2001. Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors method. *Remote Sensing of Environment* 77 (3): 251-274.
- Ghiocea-Robrecht D. M., Johnston C. A., Tulbure M. G. 2008. Assessing the Use of Multiseason Quickbird Imagery for Mapping Invasive Species in a Lake Erie Coastal Marsh. *Wetlands* 28 (4): 1028-1039.
- Goodwin N. R., Coops N. C., Wulder M. A., Gillanders S., Schroeder T. A., Nelson T. 2008. Estimation of insect infestation dynamics using a temporal sequence of Landsat data. *Remote Sensing of Environment* 112: 3680-3689.
- Grodzki W. 1995. Wpływ osłabienia świerka przez zanieczyszczenia przemysłowe w Sudetach Zachodnich na zagrożenie ze strony szkodników wtórnych. *Pr. Inst. Bad. Leś.* B 25 (1): 145-162.
- Grodzki W. 2004. Some reactions of *Ips typographus* (L.) (*Col.: Scolytidae*) to changing breeding conditions in a forest decline area in the Sudeten Mountains, Poland. *Journal of Pest Science* 77: 43-48.
- Grodzki W. 2009. Forest decline in mountain spruce stands affected by bark beetle outbreaks in Poland. Attempt to spatial characteristics. *Forest, Wildlife and Wood Sciences for Society Development* Prague.
- Grodzki W., Guzik M. 2009. Wiatro- i śniegolomy oraz gradacje kornika drukarza w Tatrzańskim Parku Narodowym na przestrzeni ostatnich 100 lat. Próba charakterystyki przestrzennej. W: Guzik M. [red.], *Długookresowe zmiany w przyrodzie użytkowaniu TPN*. Wydawnictwa Tatrzańskiego Parku Narodowego, Zakopane. 33-46.
- Grodzki W., Starzyk J. R., Kosibowicz M. 2014. Wpływ wybranych elementów charakterystyki drzewostanów na intensywność występowania kornika drukarza *Ips typographus* (L.) w Beskidzie Żywieckim. *Leśn. Pr. Bad.* 75 (2): 159-169.
- Grodzki W., Turčáni M., Jakuš R., Hlásny T., Raši R., McManus M. L. 2010. Bark beetles in the Tatra Mountains. *International research 1998-2005 – an overview. Folia Forestalia Polonica A* 52 (2): 114-130.
- Halperin J., Lemay W., Coops N., Verchot L., Marshall P., Lochhead K. 2016. Canopy cover estimation in miombo woodlands of Zambia: Comparison of Landsat 8 OLI versus RapidEye imagery using parametric, nonparametric, and semiparametric methods. *Remote Sensing of Environment* 179: 170-182.
- Holmgren P., Thuresson T. 1998. Satellite remote sensing for forestry planning – A review. *Scandinavian Journal of Forest Research* 13 (1-4): 90-110.
- Immitzer M., Atzberger C., Koukal T. 2012. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. *Remote Sensing* 4 (9): 2661-2693.
- Jadczyk P. 1995. Przyczyny zniszczenia lasów w Górach Izerskich i Karkonoszach Cz. II. Przemiany kwaśnych gazów w środowisku i ich wpływ na lasy. *Sylwan* 139 (1): 63-72.

- Key T., Warner T. A., McGraw J. B., Fajvan M. A. 2001. A Comparison of Multispectral and Multitemporal Information in High Spatial Resolution Imagery for Classification of Individual Tree Species in a Temperate Hardwood Forest. *Remote Sensing of Environment* 75 (1): 100-112.
- 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* 84: 437-456.
- Kongwen Z., Baoxin H. 2012. Urban Tree Species Classification Using Very High Spatial Resolution Airborne Multi-Spectral Imagery Using Longitudinal Profiles. *Remote Sens.* 4 (6): 1741-1757.
- Kozioł K., Wężyk P. 2005. Rola klasyfikacji nadzorowanej obrazów satelitarnych QuickBird w nowej koncepcji wyznaczania przemysłowych stref uszkodzeń drzewostanów na przykładzie Miasteczka Śląskiego. *Roczniki Geomatyki* 3 (2): 87-96.
- Kycko M., Zagajewski B., Kozłowska A. 2014. Variability in spectral characteristics of trampled high-mountain grasslands. *Miscellanea Geographica* 18 (2): 10-14.
- Manion P. 1981. *Tree Disease Concepts*. Prentice Hall Inc., Englewood Cliffs. New Jersey.
- Marx A. 2010. Detection and Classification of Bark Beetle Infestation in Pure Norway Spruce Stands with Multi-temporal RapidEye Imagery and Data Mining Techniques. *PFG Photogrammetrie, Fernerkundung, Geoinformation Jahrgang Heft 4* <<https://www.schweizerbart.de/papers/pfg/list/2010>>: 243-252.
- Mickelson Jr. J., Civco D., Silander Jr. J. 1998. Delineating forest canopy species in the northeastern United States using multi-temporal TM imagery. *Photogrammetric Engineering & Remote Sensing* 64 (9): 891-904.
- Ochtyra A., Zagajewski B., Kozłowska A., Marcinkowska-Ochtyra A., Jarocińska A. 2016. Ocena kondycji drzewostanów Tatrzańskiego Parku Narodowego za pomocą metody drzewa decyzyjnego oraz wielospektralnych obrazów satelitarnych Landsat 5 TM. *Sylwan* 160 (3): 256-264.
- Raczko E., Zagajewski B., Ochtyra A., Jarocińska 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.
- Rajee G., Hitendra P., Kushwaha S. P. S. 2014. Forest tree species discrimination in western Himalaya using EO-1 Hyperion. *International Journal of Applied Earth Observation and Geoinformation* 28: 140-149.
- Reese H. M., Lillesand T. M., Nagel D. E., Stewart J. S., Goldmann R. A., Tessar P. 2002. Statewide land cover derived from multiseasonal Landsat TM data: A retrospective of the WISCLAND project. *Remote Sensing of Environment* 82 (2-3): 224-237.
- Roslani M. A., Mustapha M. A., Lihan T., Wan Julaina W. A. 2014. Applicability of RapidEye Satellite Imagery in Mapping Mangrove Vegetation Species at Matang Mangrove Forest Reserve, Perak, Malaysia. *Journal of Environmental Science and Technology* 7: 123-136.
- Rougier S., Puissant A. 2014. Improvements of Urban vegetation segmentation and classification using multi-temporal Pleiades images. *South-Eastern European Journal of Earth Observation and Geomatics* 3 (2S).
- Rouse J., Haas R., Schell J., Deering D. 1973. Monitoring Vegetation Systems in the Great Plains with ERTS. *Third ERTS Symposium, NASA*. 309-317.
- Shen G., Sakai K., Hoshino Y. 2010. High Spatial Resolution Hyperspectral Mapping for Forest Ecosystem at Tree Species Level. *Agricultural Information Research* 19: 71-78.
- Sims D., Gamon J. 2002. Relationships Between Leaf Pigment Content and Spectral Reflectance Across a Wide Range of Species, Leaf Structures and Developmental Stages. *Remote Sensing of Environment* 81: 337-354.
- Stoffels J., Mader S., Hill J., Werner W., Ontrup G. 2012. Satellite-based stand-wise forest cover type mapping using a spatially adaptive classification approach. *Eur. J. Forest. Res.* 131 (4): 1071-1089.
- Tavares de Carvalho L. M. 2013. Evaluating segmentation and Classification approaches using RapidEye data for vegetation Mapping in minas gerais, brazil. *Célio helder resende de souze*.
- Townsend P., Walsh S. 2001. Remote sensing of forested wetlands: application of multitemporal and multispectral satellite imagery to determine plant community composition and structure in southeastern USA. *Plant Ecology* 157 (2): 129-149.
- Tyc G., Tulip J., Schulten D., Krischke M., Oxford M. 2005. The RapidEye mission Design. *Acta Astronaut.* 56: 213-219.
- Vohland M., Stoffels J., Hau C., Schüler G. 2007. Remote sensing techniques for forest parameter assessment: multispectral classification and linear spectral mixture analysis. *Silva Fennica* 41 (3): 441-456.
- Walczykowski P., Orych A., Łysenko J. 2012. Przykład wykorzystania zobrażeń Landsat TM do oceny stanu zagrożenia pożarowego lasów. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 24: 393-402.
- Wallner A., Elatawneh A., Schneider T., Knoke T. 2015. Estimation of forest structural information using RapidEye satellite data. *Forestry* 88 (1): 96-107.
- Walsh S. J. 1980. Coniferous tree species mapping using LANDSAT data. *Remote Sensing of Environment* 9 (1): 11-26.
- Waser L. T., Ginzler C., Kuechler M., Baltsavias E., Hurni L. 2011. Semi-automatic classification of tree species in different forest ecosystems by spectral and geometric variables derived from Airborne Digital Sensor (ADS40) and RC30 data. *Remote Sensing of Environment* 115 (1): 76-85.

- Wolter P.** 1995. Improved forest classification in the northern Lake States using multi-temporal Landsat imagery. *Photogrammetric Engineering & Remote Sensing* 61 (9): 1129-1143.
- Zagajewski B.** 2010. Ocena przydatności sieci neuronowych i danych hiperspektralnych do klasyfikacji roślinności Tatr Wysokich. *Teledetekcja Środowiska* 43: 113.
- Zawiła-Niedźwiecki T., Wiśniewska E.** 2004. Satellite based inventory of insects outbreaks as a tool of forest landscape monitoring. *Proceedings of the Lviv University, Ser. Geogr.* 31: 285-291.