

JOANNA PLUTO-KOSSAKOWSKA, KATARZYNA OSIŃSKA-SKOTAK, KRZYSZTOF STEREŃCZAK

Określenie rozdzielczości przestrzennej wielospektralnych zdjęć satelitarnych optymalnej do detekcji martwych drzew na obszarach leśnych*

Determining the spatial resolution of multispectral satellite images optimal to detect dead trees in forest areas

ABSTRACT

Pluto-Kossakowska J., Osińska-Skotak K., Stereńczak K. 2017. Określenie rozdzielczości przestrzennej wielospektralnych zdjęć satelitarnych optymalnej do detekcji martwych drzew na obszarach leśnych. Sylwan 161 (5): 395-404.

The mainstream of remotely sensed methodology for identifying the tree stand condition is based on spectral responses registered by a multispectral sensor as a digital image. The changes in spectral properties are caused by dying leaves, needles or whole trees. In further steps, the relationship between the spectral values (radiometry) registered in a multispectral satellite image and the health condition of trees should be determined. The most frequent situation includes the one when dying stand (*sensu* single tree) occupies the area of $<5 \text{ m}^2$. Therefore the remotely sensed data for determining sanitary conditions of trees must be of a very high spatial resolution (e.g. WorldView2 or 3, GeoEye-1, Pleiades) on one hand and at the same time favourable for the vegetation studies, i.e. utilizing suitable spectral bands and be of low acquisition cost (e.g. RapidEye, LANDSAT-7, ETM+, LANDSAT-8 OLI). Thus a compromise between spatial and spectral resolution should be found to answer the question at what resolution it is possible to clearly separate the damaged tree. The scope of the research included testing of selected methods of satellite image processing and analysis in terms of defining the optimal spatial resolution, which was performed on simulated images obtained for the area of the Beskidy Mountains (S Poland). Pixel size on simulated images was downgraded to the size corresponding to the currently functioning satellite systems. Consequently the obtained material for comparison was free from influence of external factors such as the differences in: time and weather conditions, the geometry of satellite image acquisition, light at the surface of the treetops and phenological vegetation. For each image we used vegetation indices (NDVI and GDVI) and supervised classification. These tests and the obtained results allowed to draw conclusions about the optimal satellite image resolution that can be used to detect damaged or dead stands.

KEY WORDS

VHR image, vegetation index, multispectral analysis, image classification

ADDRESSES

Joanna Pluto-Kossakowska ⁽¹⁾ – e-mail: jkossako@gik.pw.edu.pl

Katarzyna Osińska-Skotak ⁽¹⁾ – e-mail: k.osinska-skotak@gik.pw.edu.pl

Krzysztof Stereńczak ⁽²⁾ – e-mail: K.Sterenczak@ibles.waw.pl

*Materiały teledetekcyjne wykorzystane w niniejszych badaniach zostały zebrane w ramach projektu „Utworzenie dla obszaru Sudetów i Beskidu Zachodniego leśnego systemu informacyjnego w zakresie monitoringu i oceny stanu lasu” realizowanego w Instytucie Badawczym Leśnictwa na zlecenie Dyrekcji Generalnej Lasów Państwowych.

⁽¹⁾ Zakład Fotogrametrii, Teledetekcji i Systemów Informacji Przestrzennej, Politechnika Warszawska; pl. Politechniki 1, 00-661 Warszawa

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

Wstęp

Aby dobrze gospodarować zasobami leśnymi i przeciwdziałać ich degradacji, należy regularnie monitorować i inwentaryzować stan lasu. Są to procesy żmudne i czasochłonne, stąd warto szukać możliwości ich wsparcia wielospektralnymi danymi obrazowymi pozyskiwanymi z poziomu lotniczego lub satelitarnego. Technika pozyskiwania danych wielospektralnych (tj. rejestracja odbicia fal elektromagnetycznych w różnych zakresach spektralnych) jest znana i stosowana od wielu lat [Będkowski 2015]. Początkowo rozwijana była w teledetekcji lotniczej poprzez wprowadzenie do kamer analogowych filmu czułego na podczerwień (próba wykonania takiego zdjęcia w Polsce dla terenów leśnych miała miejsce w 1972 roku na obszarze Łasku Bielańskiego [Ciołkosz 2015]), a następnie wielospektralnych kamer cyfrowych. Obecnie jest już normą wykonywanie nalogów fotogrametrycznych przy użyciu takich kamer i opracowywanie ortofotomap w barwach rzeczywistych i z wykorzystaniem zakresu bliskiej podczerwieni. Jednocześnie techniki pozyskiwania danych wielospektralnych były intensywnie rozwijane wraz z rozwojem teledetekcji satelitarnej.

Rozwój oraz stosowanie fotogrametrii i teledetekcji w leśnictwie dla potrzeb urządzania lasu i inwentaryzacji jego stanu w Polsce bardzo szczegółowo opisuje w swojej publikacji Będkowski [2015], podkreślając dorobek naukowy i technologiczny wielu instytucji, m.in. Instytutu Badawczego Leśnictwa, Wydziału Leśnego SGGW w Warszawie, Akademii Rolniczej w Krakowie i w Poznaniu, Biura Urządzania Lasu i Geodezji Leśnej oraz Instytutu Geodezji i Kartografii. Już w latach 70. Instytut Geodezji i Kartografii prowadził badania nad zastosowaniem wielospektralnych zdjęć lotniczych do oceny stanu drzewostanów [Bychawski 1980; Ciołkosz 2015]. Ten kierunek badań, ale z wykorzystaniem wielospektralnych danych satelitarnych, rozwijali także inni polscy badacze w różnych ośrodkach naukowych [Wężyk, Mansberger 1998; Wiśniewska, Zawila-Niedźwiecki 2004; Kozioł, Wężyk 2005; Zawila-Niedźwiecki 2010; Wiśniewska 2013]. W połączeniu ze współczesnymi technikami przetwarzania obrazów cyfrowych i ich automatyzacji satelitarne dane teledetekcyjne pozwalają na jednoczesne badanie dużych obszarów leśnych w krótkim czasie. Sam proces cyfrowego przetwarzania w celu detekcji konkretnych obiektów jest ściśle związany z jakością i potencjałem interpretacyjnym zdjęć, przez co należy rozumieć rozdzielczość przestrzenną i spektralną danych. Odpowiedni ich dobór stanowi podstawę dalszych badań nad kondycją drzewostanu.

Główny nurt teledetekcyjnej metody identyfikacji drzew martwych lub obumierających opiera się na badaniu zmian ich właściwości spektralnych spowodowanych defoliacją, obumieraniem liści, igieł lub całych drzew i poszukiwaniu relacji pomiędzy wartościami spektralnymi (radiometrią) zarejestrowanymi na wielospektralnym obrazie satelitarnym bądź lotniczym a stanem zdrowotnym drzew [Adamczyk, Będkowski 2006; Lee, Cho 2006; Będkowski i in. 2011; Adamczyk, Osberger 2015]. W niniejszej pracy drzewa wykazujące symptomy zmian aparatu asymilacyjnego są traktowane jako jedna klasa, bez rozróżnienia stopnia uszkodzenia.

Ze wstępnej analizy dostępnych danych źródłowych oraz obserwacji innych autorów [Zmarz i in. 2012; Turowska 2015] wynika, że najczęściej występujące sytuacje to te, w których zamierające drzewa mają powierzchnię rzutu korony poniżej 5 m², co można odnieść do powierzchni

rzutu korony świerka w zwartym drzewostanie w wieku około 70-80 lat, czyli w momencie jego największego zagrożenia, m.in. przez kornika drukarza (*Ips typographus* L.) [Wermelinger 2004]. A zatem satelitarne dane teledetekcyjne służące określeniu stanu zdrowotnego drzew muszą charakteryzować się bardzo wysoką rozdzielczością przestrzenną (np. WorldView, GeoEye, Pleiades) i jednocześnie korzystnymi z punktu widzenia badań szaty roślinnej zakresami spektralnymi oraz kosztami ich pozyskiwania (co cechuje np. obrazy satelitarne RapidEye, LANDSAT-7 ETM+ i LANDSAT-8 OLI). Stąd poszukiwany jest kompromis pomiędzy rozdzielczością przestrzenną i spektralną, a co za tym idzie odpowiedź na pytanie, przy jakiej rozdzielczości przestrzennej i spektralnej jest możliwa jednoznaczna i dokładna detekcja martwych drzew.

Z punktu widzenia gospodarki leśnej, a w szczególności ochrony lasu, najważniejsze jest właściwe określenie położenia pojedynczych martwych/zamierających drzew, które mogą być zaczątkiem większej powierzchni zaatakowanej przez patogen, a są trudne do zidentyfikowania z wykorzystaniem tradycyjnych naziemnych metod monitorowania. Detekcja tych drzew uzależniona jest przede wszystkim od wielkości korony i wielkości piksela danych teledetekcyjnych wykorzystanych w ich detekcji [Stereńczak i in. 2008]. Wielkość korony drzewa skorelowana jest z jego wiekiem. Zależność ta modyfikowana jest dodatkowo przez wiele czynników i charakteryzuje się dużą zmiennością [Stereńczak 2013]. Z kolei w teledetekcji, zgodnie z teorią próbkowania sygnału, uznaje się, że do rozpoznania określonych obiektów wystarczą obrazy o pikselu co najmniej dwukrotnie mniejszym (w wymiarze liniowym) niż poszukiwany obiekt. Na tej podstawie można założyć, że dla młodych drzewostanów skuteczniejsze w detekcji drzew martwych będzie zastosowanie zdjęcia o małych wymiarach piksela, a dla drzew starszych o wymiarach większych.

Celem badań było określenie optymalnej rozdzielczości przestrzennej obrazów satelitarnych pod kątem ich przydatności do detekcji martwych drzew.

Material i metody

Badania przeprowadzono na obszarze Beskidu Żywieckiego, w okolicach miejscowości Ciapków, w Nadleśnictwie Ujszoły, w którym rozpoznaje się symptomy kłęski ekologicznej [Przybylski 2015]. Dominującą formą pokrycia tego terenu są lasy. Miejscami występują nieliczne i niewielkie obszary nieporośnięte roślinnością drzewiastą, a pokryte przez runo lub niską roślinność. Obszar w kierunku północ-południe przecinają również drogi: węższa na polanie przy wschodniej granicy obszaru, której dalszy bieg chowa się w koronach drzew, oraz szersza – we wschodniej części opracowywanego obszaru – rozciągająca się przez całą długość obrazu. Przy drugiej drodze znajduje się w północnej części obszaru badań kilka niskich zabudowań. Na obszarze występują znaczne deniwelacje, wynoszące około 300 metrów. Wzdłuż drogi znajduje się największe obniżenie terenu, natomiast w zachodniej części obszaru ułożone jest pasmo wzniesień opadające w kierunku północnym. Tak zróżnicowana rzeźba terenu skutkuje zróżnicowanym oświetleniem i co za tym idzie zacienieniem poszczególnych części obszaru w zależności od ekspozycji stoków.

Podstawą do wykonania analiz w niniejszej pracy były ortofotomapy lotnicze o rozdzielczości przestrzennej 0,5 m. Dane do opracowania ortofotomap zostały zarejestrowane cyfrową kamerą lotniczą DMC II posiadającą cztery zakresy promieniowania elektromagnetycznego: niebieski, zielony, czerwony i bliską podczerwień. Kamera ma również kanał panchromatyczny obrazujący w szerokim zakresie spektrum (380-780 nm), ale nie był on wykorzystany w procesie przetwarzania. Ortofotomapa została utworzona przy użyciu numerycznego modelu terenu wygenerowanego na podstawie danych pozyskanych lotniczym skanerem laserowym (ALS; ang.

Airborne Lasers Scanner). Gotowy produkt został również poddany korekcie balansu barwnego. Niestety, producent nie podał metody przetwarzania, która może mieć wpływ na wartości radiometryczne, a tym samym na wyniki klasyfikacji. Założono jednak, że ewentualne zmiany wartości pikseli dotyczą wszystkich przygotowanych zestawów danych (o różnej rozdzielczości) i przy analizie porównawczej można wnioskować na temat dokładności klasyfikacji. Nalot fotograficzny wykonano 28 i 30 sierpnia 2012 roku w ramach projektu „Utworzenie dla obszaru Sudetów i Beskidu Zachodniego leśnego systemu informacyjnego w zakresie monitoringu i oceny stanu lasu”.

Dane do weryfikacji uzyskanych wyników stanowiła baza danych przestrzennych reprezentująca obiekty poligonowe – korony drzew martwych, które pozyskano w procesie fotointerpretacji ortofotomap lotniczych o rozdzielczości przestrzennej 0,5 m. W bazie zapisano 2002 poligonów. Powierzchnia najmniejszej zidentyfikowanej korony wynosi poniżej 0,8 m², natomiast największej – ponad 34 m². Jeden z poligonów był obrysem sąsiadujących ze sobą uszkodzonych drzew, ale na tym obszarze badań zdecydowana większość to pojedyncze korony, ewentualnie 2-3 osobniki o mniejszych koronach. Obiekty bardzo małe, mniejsze niż 5 m², stanowią 72% wszystkich zidentyfikowanych obszarów, obiekty średniej wielkości – od 5 do 20 m² – 27%, a największe obszary (grupy drzew), powyżej 20 m², stanowią nieco ponad 1% zidentyfikowanego chorego drzewostanu (tab. 1). Przewaga obszarów małych może wynikać z tego, że zwektoryzowane korony to w większości świerki w różnym stadium zamierania, których korony ustępują miejsca sąsiadującym drzewom zdrowym. Korony drzew zdrowych, rozrastając się, zajmują miejsce zredukowanych koron drzew martwych.

Przyczyną degradacji drzewostanów leśnych regionu Beskidów jest m.in. dynamiczne rozprzestrzenianie się kornika drukarza, który będąc szkodnikiem wtórnym, często zabija drzewa wcześniej osłabione w wyniku działania innych czynników biotycznych i abiotycznych. Należy tu podkreślić, że w niniejszych badaniach nie brano pod uwagę przyczyny i terminu obumarcia drzew, a jedynie stwierdzano fakt jego zajęcia poprzez analizę wartości odbicia spektralnego. Skuteczną metodą na zlokalizowanie większości drzew uszkodzonych jest metoda klasyfikacji cyfrowej wysokorozdzielczych zdjęć wielospektralnych (VHR; ang. Very High Resolution) [Morales i in. 2011; Verlič i in. 2014]. Regularne pozyskiwanie takich danych dla regionu czy też obszaru lasów całego kraju generuje jednak spore koszty. Dlatego ocena, jak zastosowanie obrazów o mniejszej rozdzielczości przestrzennej, a tym samym tańszych i łatwiejszych do pozyskania, wpłynie na zdolność wykrywania uszkodzonych drzewostanów, jest ważna z punktu widzenia monitorowania stanu sanitarnego lasów.

Tabela 1.

Liczba (N) i udział (%N) poligonów reprezentujących zidentyfikowane martwe drzewa w zależności od zajmowanej powierzchni (P)

Number (N) and share (%N) of the dead trees polygons depending on the occupied area (P)

P	N	%N
<1 m ²	195	10
1 m ² <P<5 m ²	1249	62
5 m ² <P<10 m ²	405	20
10 m ² <P<20 m ²	129	7
>20 m ²	24	1
Razem	2002	100
In total		

Zakres badań obejmował testowanie wybranych metod przetwarzania i analizy obrazów satelitarnych pod względem określenia optymalnej rozdzielczości przestrzennej, którą przeprowadzono na symulowanych obrazach pozyskanych dla obszaru Beskidu Żywieckiego. Dla potrzeb badań zasymulowano obrazy wielospektralne o wymiarach terenowych piksela 1, 2,5 i 5 m, korespondujących z obecnie funkcjonującymi systemami satelitarnymi (m.in. Pleiades, SPOT5 i RapidEye). Obrazy te utworzono poprzez degradację rozdzielczości ortofotomapy lotniczej o pikselu 0,5 m. Wartości pikseli nowo powstałych obrazów zostały obliczone w drodze interpolacji uśredniającej. Metoda ta powinna najlepiej symulować wartości radiometryczne uzyskane w wyniku rejestracji obrazu o niższej rozdzielczości przestrzennej. Tym samym możliwe jest powiązanie wartości uśrednionych z cechami drzew uwidoczniwymi na zdjęciach wielospektralnych. W ten sposób uzyskano materiał porównawczy wolny od wpływu takich czynników zewnętrznych jak: różnice w terminie pozyskania i warunkach atmosferycznych, różnice w geometrii pozyskania obrazu satelitarnego, różnice w oświetleniu powierzchni koron drzew i różnice fenologiczne roślinności. Na każdym obrazie przeprowadzono wybrane przetworzenia: obliczono wskaźniki roślinności NDVI i GDVI oraz przeprowadzono klasyfikację nadzorowaną.

Ogólna koncepcja przeprowadzenia badań przedstawia się następująco:

- przygotowanie obrazów symulowanych, danych referencyjnych, klucza fotointerpretacyjnego oraz pól treningowych,
- analiza rozkładu próbek wzorcowych w przestrzeni spektralnej,
- obliczenie obrazów wskaźnikowych NDVI, GNDVI i ich klasyfikacja jednowymiarowa,
- klasyfikacja nadzorowana obrazu wielospektralnego metodą największego prawdopodobieństwa,
- ocena dokładności wyników przetworzeń i analiza porównawcza.

Do przeprowadzenia badań nad określeniem optymalnej rozdzielczości przestrzennej zdjęć przyjęto typowe przetworzenia stosowane przy automatycznej identyfikacji drzewostanów leśnych, czyli wskaźniki roślinności oraz klasyfikację nadzorowaną. Spośród wielu wskaźników wybrano dwa, ze względu na ich prostą formułę i potwierdzoną skuteczność w badaniu kondycji roślinności [Jones, Vaughan 2010; Campbell, Wynne 2011; Jensen 2015]. Pierwszy z nich to standardowy, sprawdzony w wielu badaniach i aplikacjach znormalizowany różnicowy wskaźnik roślinności, znany jako NDVI (ang. Normalized Difference Vegetation Index) [Rouse i in. 1974 za Jones, Vaughan 2010]:

$$\text{NDVI} = (\text{NIR} - \text{R}) / (\text{NIR} + \text{R})$$

Drugi wskaźnik to GNDVI (Green Normalized Vegetation Index) – zmodyfikowana wersja NDVI, w której kanał czerwony zastąpiono kanałem zielonym [Gitelson i in. 1996 za Jones, Vaughan 2010]:

$$\text{GNDVI} = (\text{NIR} - \text{G}) / (\text{NIR} + \text{G})$$

Wskaźnik ten jest bardziej niż NDVI wyczulony na gęstą roślinność z wysokim wskaźnikiem ulistnienia [Jones, Vaughan 2010], a zatem powinien skuteczniej różnicować zdrowy i chory drzewostan, a także drzewa iglaste i liściaste.

Kolejnym przetworzeniem wykorzystanym do automatycznej identyfikacji drzewostanów była klasyfikacja nadzorowana. Ze względu na zastosowanie większej liczby kanałów spektralnych daje ona możliwość bardziej szczegółowego (tematycznie), niż obrazy wskaźnikowe, wyznaczenia klas zróżnicowanych spektralnie. Jest ona często stosowana produkcyjnie do klasyfikacji pokrycia terenu, a jej najpopularniejsza odmiana to algorytm największego prawdopodobieństwa.

Do przeprowadzenia klasyfikacji nadzorowanej algorytmem największego prawdopodobieństwa posłużył przygotowany zestaw pól treningowych utworzony dla wszystkich czterech zestawów danych jednocześnie, tak aby były tym samym fragmentem terenu i reprezentowały ten sam typ pokrycia na wszystkich poziomach rozdzielczości przestrzennej. Teoretycznie ten sam fragment terenu powinien posiadać te same właściwości spektralne w każdym zestawie, jednak w wyniku przepróbkowania (ang. resampling) wykorzystanego podczas zmniejszania rozdzielczości przestrzennej niektóre obiekty uległy zgeneralizowaniu lub ich kontury zniekształciły się, dlatego też wybór lokalizacji trenowanych obszarów rozpoczynano na danych o mniejszej rozdzielczości – 5 oraz 2,5 m. Oczywiście można by utworzyć pola treningowe dla każdego zestawu oddzielnie i dałoby to zapewne lepsze wyniki dla danych o wysokiej rozdzielczości, jednak niniejsza analiza ma na celu porównanie wyników identyfikacji drzewostanów w zależności od rozdzielczości przestrzennej danych wielospektralnych. Jednakowe pola treningowe dla wszystkich poziomów rozdzielczości dają pewność, że różnice w ocenie dokładności klasyfikacji nie wynikają również z przygotowania innych pól treningowych dla różnych zestawów danych. Wytypowano następujące klasy: drzewa martwe, drzewa iglaste, drzewa liściaste, tereny odkryte i tereny zacienione.

Analizę wyników oparto na klasycznym podejściu do oceny dokładności wykonanych przetworzeń opracowanej przez Congaltona i Greena [2009]. Ocena ta polega na obliczeniu macierzy błędów oraz szeregu parametrów charakteryzujących dokładność. Daje to możliwość porównywania wyników osiągniętych dla poszczególnych klas oraz przedstawienia ogólnej dokładności ułatwiającej interpretację wyników i wyciągnięcia wniosków. Jednym z parametrów służących do oceny dokładności na poziomie klas jest dokładność użytkownika, mówiąca o stosunku poprawnie sklasyfikowanych pikseli w danej klasie do ogólnej liczby pikseli zaliczonych do tej klasy. Jej dopełnieniem jest tzw. błąd nadmiaru, czyli przeszacowania, który wskazuje na prawdopodobieństwo, że piksel zaliczony do danej klasy w rzeczywistości reprezentuje inną kategorię w terenie. Kolejny parametr to dokładność wykonawcy, czyli liczba poprawnie sklasyfikowanych pikseli do ogólnej liczby pikseli klasy zdefiniowanej w danych referencyjnych. Jej dopełnieniem jest błąd pominięcia, który wskazuje na prawdopodobieństwo, że piksel należący w terenie do danej klasy (tj. w danych referencyjnych) zostanie zaliczony do klasy innej. Dlatego parametr ten jest uznawany za istotniejszy w ocenie wyników, jako odniesienie do rzeczywistości terenowej.

Dwa parametry opisujące ogólną dokładność klasyfikacji to: kappa, czyli miara różnicy pomiędzy zgodnością obecnej klasyfikacji z danymi referencyjnymi i zgodnością przypadkowej klasyfikacji z danymi referencyjnymi, oraz omega, czyli stosunek liczby poprawnie sklasyfikowanych pikseli we wszystkich klasach do liczby wszystkich pikseli reprezentujących dane referencyjne [Congalton, Green 2009]. Dla najistotniejszej klasy „drzewa martwe” utworzono 60 punktów testowych na podstawie danych referencyjnych, a dla pozostałych po 30 dla każdej klasy.

Wyniki i dyskusja

Ocenę dokładności ujęto sumarycznie w tabeli 2. Wynika z niej, że dokładność użytkownika dla klasy „drzew martwych” jest wyższa niż dokładność wykonawcy. Oznacza to lepszy stosunek poprawnie sklasyfikowanych pikseli klasy „drzewa martwe” do wszystkich zaliczonych do tej klasy w procesie klasyfikacji (dokładność użytkownika), a gorszy, jeśli chodzi o stosunek poprawnie zaklasyfikowanych pikseli do pikseli rzeczywistości reprezentujących tę klasę w terenie (dokładność wykonawcy). Dla tej klasy występuje zatem większy błąd pominięcia, a mniejszy

Tabela 2.

Dokładność producenta (DP [%]) i użytkownika (DU [%]) oraz dokładność ogólna (współczynniki Ω [%] i κ) przy określaniu klasy „drzewa martwe” różnymi sposobami przetworzenia obrazów o rozdzielczości 0,5, 1,0, 2,5 i 5,0 m

Producers (DP [%]) and user (DU [%]) as well as total (Ω [%] i κ coefficients) accuracy of the image processing for the class 'dead trees' for 0.5, 1.0, 2.5 and 5.0 m resolution

		DP	DU	Ω	κ
NDVI	0,5	97	89	89	0,84
	1,0	91	92	87	0,82
	2,5	80	78	77	0,66
	5,0	49	74	61	0,48
GNDVI	0,5	84	100	91	0,88
	1,0	73	100	87	0,82
	2,5	66	100	84	0,78
	5,0	45	85	69	0,59
MaxLike	0,5	77	94	82	0,77
	1,0	65	91	77	0,71
	2,5	55	87	73	0,67
	5,0	15	69	62	0,53

błąd nadmiaru. W przypadku wykrywania martwych drzew błąd pominięcia, czyli brak obserwacji (tu: martwych drzew), wydaje się groźniejszy niż obserwacje nadmiarowe, które można zweryfikować ponownie – kameralnie lub w terenie. W przypadku tej klasy skuteczność klasyfikacji spada wraz ze zmniejszeniem rozdzielczości przestrzennej danych wielospektralnych.

Zdecydowanie najslabsze i najbardziej odstające od reszty wyniki uzyskano dla danych o rozdzielczości przestrzennej 5 m. Dokładność wykonawcy na poziomie 15, 45 i 49% świadczy o bardzo małej liczbie wykrytych obecnych w terenie drzew martwych. Jak wspomniano wcześniej, dla tych danych nie uzyskano także minimalnej liczby pikseli przy tworzeniu pól treningowych, co również mogło mieć wpływ na pogorszenie wyników. Dla danych o wielkości piksela 2,5 m uzyskano lepszy wynik w przypadku dokładności wykonawcy, która świadczy o sklasyfikowaniu poprawnie ponad połowy zamarych drzew, co jednak nie jest jeszcze zadowalającym wynikiem. W przypadku kolejnych poziomów rozdzielczości dokładność ta rosła o około 10 punktów procentowych i wyniosła 65% dla danych o rozdzielczości przestrzennej 1 m oraz 77% dla danych półmetrowych. Dla wszystkich danych, z wyjątkiem tych o wielkości piksela 5 m, otrzymano bardzo dobre wyniki dokładności użytkownika: prawie 90% dla danych o pikselu 2,5 m oraz powyżej 90% dla danych o pikselu 1 m i 0,5 m, co świadczy o poprawności klasyfikacji klasy „drzewa martwe”.

Największe błędy wynikały z przyporządkowania pikseli reprezentujących martwe drzewa do klas „tereny odkryte” lub „drzewa iglaste”. Jak wspomniano przy okazji opisu tworzenia pól treningowych, niektóre z podgrup w tych kategoriach miały bardzo podobne odpowiedzi spektralne do klasy drzew martwych, co mogło mieć związek np. z początkową fazą zamierania/defoliacją drzew, widoczną już w postaci odbarwiania igieł. W przypadku terenów odkrytych mogło to wynikać z faktu, że w przeważającej większości dno luk w drzewostanach pokryte było martwą materią organiczną. Poza tym wpływ na uzyskane rezultaty mogła mieć również procedura wyrównania tonalnego podczas tworzenia ortofotomapy, która szczególnie na granicy zdjęć o dużych różnicach tonalnych zniekształcała wartości pikseli i powodowała błędy w klasyfikacji.

Uszkodzone osobniki na analizowanym obszarze stanowią w dużej mierze pojedyncze drzewa, których korony zajmują często bardzo małe obszary. Jak już wcześniej wspomniano,

Tabela 3.

Rozdzielczość przestrzenna [m] w panchromatycznym (PAN) i wielospektralnym (XS) trybie skanowania, możliwe rewizyty (NR [dni]) oraz nazwy i zakres [µm] kanałów spektralnych w wybranych wysokorozdzielczych systemów satelitarnych
 Spatial resolution [m] in panchromatic (PAN) and multispectral (XS) scanning modes, possible revisits (NR [days]) as well as names and ranges [µm] of spectra bands in selected Very High Resolution satellite systems

	PAN	XS	NR	Pan	Coastal	Blue	Green	Yellow	Red	Red edge	Infrared
Worldview3	0,31	1,24	1-4	0,45-0,80	0,40-0,45	0,45-0,51	0,57-0,63	0,59-0,63	0,63-0,69	0,71-0,75	0,86-1,04
WorldView2	0,46	1,84									
GeoEye-1	0,41	1,65	2-8	0,45-0,80	0,45-0,51	0,45-0,51	0,51-0,58	0,66-0,69	0,66-0,69	0,78-0,92	0,78-0,92
Pleiades	0,50	2,00	1-2	0,48-0,83	0,43-0,55	0,43-0,55	0,49-0,61	0,60-0,72	0,60-0,72	0,75-0,95	0,75-0,95
QuickBird	0,60	2,40	1-3	0,45-0,90	0,45-0,52	0,45-0,52	0,52-0,60	0,63-0,69	0,63-0,69	0,76-0,89	0,76-0,89
Ikonos	0,80	3,20	~3	0,45-0,90	0,45-0,52	0,45-0,52	0,52-0,60	0,63-0,69	0,63-0,69	0,76-0,90	0,76-0,90
RapidEye	-	6,50	1-5		0,44-0,51	0,44-0,51	0,52-0,59	0,63-0,69	0,63-0,69	0,69-0,73	0,76-0,85

obszary pokryte przez martwe drzewa o powierzchni mniejszej niż 5 m², czyli nieco mniejsze niż piksel zdjęcia o rozdzielczości 2,5 m, stanowią aż 72% tych obszarów. Większe osobniki, o koronie powyżej 20 m², czyli zbliżone powierzchnią do piksela zdjęcia o rozdzielczości przestrzennej 5 m, stanowią nieco ponad 1%. Znaczenie ma też kształt obiektów – korony drzew mają obrys owalny, który na obrazie reprezentowany jest przez piksele o kształcie kwadratu. Stąd im większy wymiar piksela, tym mniej korzystna reprezentacja korony. Dużo lepiej w tym zestawieniu wypadają dane o rozdzielczości 1 i 0,5 m, ponieważ obszary zajęte przez korony drzew martwych większe niż 1 m² to większość wydzieleni i stanowią aż 90% wszystkich tych obszarów. Oczywiście fakt, że korona martwego drzewa jest mniejsza niż wielkość piksela systemu teledetekcyjnego, nie oznacza, że nie da on odpowiedzi spektralnej wystarczającej do poprawnego zaklasyfikowania piksela. Musi być jednak spełniony warunek, że zdecydowanie większa część piksela pokryta będzie przez zamarte drzewo (drzewa). Jeżeli pojedyncze drzewo zostanie zarejestrowane na granicy dwóch lub więcej pikseli, to odpowiedź spektralna może być mocno zniekształcona (uśredniona) lub przy dużej różnicy wielkości obszarów zajętych przez martwe drzewa i wielkości pikseli obrazu nie da wystarczająco silnej odpowiedzi spektralnej umożliwiającej prawidłowe zaklasyfikowanie pikseli.

Obrazy o rozdzielczości 0,5 m umożliwiają odtworzenie kształtu drzew, przez co obserwator jest w stanie określić, czy jest to drzewo iglaste, czy liściaste. Dla obrazów o pikselu 1 m widoczne były pojedyncze drzewa, przy rozdzielczości 2,5 m – skupiska małych drzew lub pojedyncze duże drzewa, a przy pikselu 5 m rozpoznawalne były już tylko większe drzewa i duże skupiska drzew.

Wyniki klasyfikacji i przetworzeń wskaźnikowych oraz ocena ich dokładności potwierdziły początkowe przypuszczenia – wraz ze spadkiem rozdzielczości przestrzennej danych wielospektralnych spada dokładność klasyfikacji, a także skuteczność wykrywania martwych i zamierających drzew (tab. 2). Dokładność wykonawcy dla klasy „drzewa martwe”, którą uznano za główny wyznacznik skuteczności klasyfikacji w odniesieniu do pojedynczych klas, osiąga najslabsze wyniki dla danych o rozdzielczości przestrzennej 5 m.

Fakt ten oraz niespełnienie warunku minimalnej liczby pikseli dla niektórych klas przy tworzeniu pól treningowych ostatecznie dyskwalifikuje ten zestaw danych jako materiał wystarczający do inwentaryzacji martwych drzew. Dopiero dla danych o mniejszym pikselu (1 m) wykryto od 77 do 97% pikseli reprezentujących drzewa uszkodzone. Należy również pamiętać, że celem tego typu analiz nie jest wykrycie dokładnych konturów koron drzew, ale ich lokalizacji i rozmieszczenia. Dlatego wynik dla obrazów o rozdzielczości przestrzennej 0,5 m można uznać za bardzo dobry, natomiast wynik dla obrazów o pikselu 1 m można uznać za wystarczający.

Dobór zdjęć satelitarnych do badania zdrowotności drzewostanów leśnych powinien uwzględniać, poza rozdzielczością przestrzenną (wielkością terenową piksela), także rozdzielczość spektralną (liczbę i zakres kanałów spektralnych) oraz rozdzielczość czasową (częstotliwość pojawiania się satelity nad tym samym obszarem). W tabeli 3 zestawiono funkcjonujące systemy satelitarne o bardzo dużej rozdzielczości VHR, ze wskazaniem WorldView 2 i WorldView 3 jako sensorów optymalnych zarówno ze względu na rozdzielczość przestrzenną, jak i spektralną. Dzięki dużej liczbie zakresów spektralnych, w tym unikatowych zakresów Coastal (0,40-0,45 μm), Yellow (0,59-0,63 μm) i RedEdge (0,71-0,75 μm), możliwe jest uzyskanie szerszej informacji na temat stanu roślinności.

Podsumowanie

Badania potwierdziły teoretyczne rozważania, że wraz ze zmniejszeniem rozdzielczości przestrzennej danych teledetekcyjnych spada również skuteczność wykrywania pojedynczych martwych drzewostanów. Zależność ta jest skorelowana z wielkością analizowanych koron drzew – wykrycie zmian w młodszym drzewostanie wymaga stosowania zdjęć o większej rozdzielczości przestrzennej, natomiast w starszym drzewostanie zdjęć o mniejszej rozdzielczości. Aby określić poziom tej korelacji, należałoby przeprowadzić dalsze badania nad stopniem identyfikacji drzew martwych w zależności od wieku.

Dokładność identyfikacji pojedynczych drzew martwych na poziomie powyżej 90% osiągnięto na zdjęciach o rozdzielczości przestrzennej 0,5 i 1,0 m. Przetworzenia zdjęć o rozdzielczości 2,5 oraz 5,0 m dają niezadowalające rezultaty dokładnościowe i wyniki automatycznego wykrycia pojedynczych martwych drzew na takich materiałach nie osiągają satysfakcjonującego poziomu. Jednak ze względu na postulat znajdowania pojedynczych drzew jako potencjalnych ognisk gradacyjnych wielkość piksela 2,5 m jest wystarczająca, aby wskazać na alert i dostarczać danych istotnych gospodarczego z punktu widzenia.

Podziękowania

Autorzy pragną podziękować Panu Mariuszowi Ciesielskiemu za pomoc w przygotowaniu danych.

Literatura

- Adameczyk J., Będkowski K. 2006. Cyfrowa analiza zależności między barwą koron na zdjęciach lotniczych a stanem zdrowotnym drzew. *Roczniki Geomatyki* 4 (4): 47-54.
- Adameczyk J., Osberger A. 2015. Red-edge vegetation indices for detecting and assessing disturbances in Norway spruce dominated mountain forests. *International Journal of Applied Earth Observation and Geoinformation* 37: 90-99.
- Będkowski K. 2015. Z historii rozwoju fotogrametrii i teledetekcji w leśnictwie polskim. *Teledetekcja Środowiska* 52: 5-15.
- Będkowski K., Adameczyk J., Kamińska B., Karaszkiwicz W., Korpetta D., Mozgawa J., Olenderek H., Stereńczak K., Tracz W., Zarzecka M. 2011. *Las w rastrowym modelu danych przestrzennych*. Wydawnictwo SGGW, Warszawa.
- Bychawski J. 1980. Zastosowanie lotniczych zdjęć spektrostrefowych do określania stref przemysłowego zagrożenia drzewostanów sosnowych. *Prace IGiK* 27 (66).

- Campbell J., Wynne R. 2011. Introduction to Remote Sensing – Fifth edition. The Guilford Press, New York.
- Ciołkosz A. 2015. Z historii rozwoju teledetekcji w Instytucie Geodezji i Kartografii. Teledetekcja Środowiska 52: 17-28.
- Congalton R. G., Green K. 2009. Assessing the Accuracy of Remotely Sensed Data. Principles and Practises – II edition. CRC Press, Taylor & Francis Group.
- Jensen J. R. 2015. Introductory Digital Image Processing: A Remote Sensing Perspective. Pearson Series in Geographic Information Science. Pearson Education.
- Jones H. G., Vaughan R. A. 2010. Remote Sensing of Vegetation. Principles, Techniques and Applications. Oxford University Press.
- Kozioł K., Wężyk P. 2005. Rola klasyfikacji nadzorowanej wysokorozdzielczych obrazów satelitarnych Quickbird w nowej koncepcji wyznaczania przemysłowych stref uszkodzeń drzewostanów na przykładzie Miasteczka Śląskiego. Roczniki Geomatyki 3 (2): 87-96.
- Lee S. H., Cho H. K. 2006. Detection of the pine trees damaged by pine wilt disease using high spatial remote sensing data. ISPRS Archives XXXVI, Part 7: WG VII/5.
- Morales R., Idol T., Friday J. B. 2011. Assessment of Acacia Koa Forest Health across Environmental Gradients in Hawai'i Using Fine Resolution Remote Sensing and GIS. Sensors (Basel) 11 (6): 5677-5694.
- Przybylski P. 2015. Lasy Beskidu Śląskiego i Żywieckiego – kłęska ekologiczna. <http://www.drzewostan44.blogspot.com>. Data dostępu: 05.2016.
- Stereńczak K. 2013. Czynniki warunkujące proces detekcji pojedynczych drzew w oparciu o dane pozyskane w wyniku lotniczego skanowania laserowego. Leś. Pr. Bad. 74 (4): 323-333.
- Stereńczak K., Będkowski K., Weinaecker H. 2008. Accuracy of crown segmentation and estimation of selected trees and forest stand parameters in order to resolution of used DSM and nDSM models generated from dense small footprint LIDAR data. Beijing. Proceedings of Youth Forum 38 (B6b): 27-33.
- Turowska A. 2015. Analiza zdrowotności drzewostanu leśnego Parku Narodowego Bory Tucholskie z wykorzystaniem danych lotniczych. Praca dyplomowa. Studium Podyplomowe Systemy Informacji Przestrzennej, Politechnika Warszawska.
- Verlič A., Đurić N., Kokalj Ž., Marsetič A., Simončič P., Oštir K. 2014. Tree species classification using WorldView-2 satellite images and laser scanning data in a natural urban forest. Prethodno priopćenje – Preliminary communication Šumarski list 9-10: 477-488.
- Wermelinger B. 2004. Ecology and management of the spruce bark beetle *Ips typographus* – A review of recent research. Forest Ecology and Management 202: 67-82.
- Wężyk P., Mansberger R. 1998. Techniki fotogrametrii cyfrowej i GIS w ocenie degradacji drzewostanów świerkowych w masywie Kudłonia w Gorcach. Archiwum Fotogrametrii, Kartografii i Telelekcji 8 (21): 1-10.
- Wietowski S. 2015. Analiza wpływu rozdzielczości przestrzennej zdjęć wielospektralnych na skuteczność wykrywania uszkodzonego drzewostanu. Praca dyplomowa inżynierska. Politechnika Warszawska.
- Wiśniewska E. 2013. Wprowadzenie do analiz teledetekcyjnych obszarów leśnych. Geomatyka w Lasach Państwowych. Część II. Poradnik praktyczny. 152-167.
- Wiśniewska E., Zawila-Niedźwiecki T. 2004. Ocena zasięgu żeru boreczników w Puszczy Kozienickiej na podstawie zdjęć wykonanych przez satelitę Landsat Thematic Mapper. Teledetekcja Środowiska 33: 82-86.
- Zawila-Niedźwiecki T. 2010. Podstawy teledetekcji i fotogrametrii. Geomatyka w Lasach Państwowych. Część I. Podstawy. 277-297.
- Zmarz A., Będkowski K., Miścicki S., Plutecki W. 2012. Ocena stanu zdrowotnego świerka na podstawie analizy zdjęć wielospektralnych wykonanych fotograficznymi aparatami cyfrowymi przenoszonymi przez bezzałogowy statek latający. Archiwum Fotogrametrii, Kartografii i Teledetekcji 23: 541-550.