

ADRIAN OCHTYRA, BOGDAN ZAGAJEWSKI, ANNA KOZŁOWSKA, ADRIANA MARCINKOWSKA-OCHTYRA, ANNA JAROCIŃSKA

Ocena kondycji drzewostanów Tatrzańskiego Parku Narodowego za pomocą metody drzewa decyzyjnego oraz wielospektralnych obrazów satelitarnych Landsat 5 TM*

Assessment of the condition of forests in the Tatra National Park using decision tree method and multispectral Landsat TM satellite images

ABSTRACT

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.

The paper presents a method of Landsat 5 Thematic Mapper satellite image processing to assess the condition of forests in the Tatra National Park (southern Poland). Selected images were acquired on 1987/09/01, 2005/09/02 and 2011/09/03 from the same sensor with maximum time interval for the first and last scene and from similar phenological period. Firstly, the data were radiometrically corrected using the ATCOR 2/3 software and Digital Terrain Model from the ASTER mission. Quality of the correction was assessed calculating RMSE for reflectance values from images and resampled spectral characteristics collected in terrain. RMSE was in range 3-10%. Next, basing on Landsat images, Normalized Difference Infrared Index (NDII) and a Maximum Likelihood supervised classificatory, following dominant land cover types were identified: forests (including dwarf pine), grasslands, rocks, lakes, shadows (additionally clouds were distinguished on data from 1987/09/01). It allowed to select forest areas with producer accuracy not worse than 97.69% and user accuracy not worse than 98.31%. On corrected Landsat images Normalized Difference Vegetation Index (NDVI, an overall vegetation state) and Moisture Stress Index (MSI, canopy water content) were calculated. Vegetation indices discriminated forest state using the decision tree method. The worst overall condition was observed for the 1987 (about 21% of forest stands were in the worst condition and 87% were in medium condition), while the best one in 2005 (75.51% forest stands were in good condition and 10.66% were in the best condition). In case of 2011, the overall condition was quite good, but there were large areas with poor condition caused by bark beetle outbreaks. Proposed method allows for a fast and objective assessment of forest condition. It is possible to detect damaged areas or stands in poor condition. It can be complement for traditional methods of monitoring and management in forestry and nature protection.

KEY WORDS

Landsat TM, forest, assessment of condition, vegetation indices, remote sensing, the Tatras

*Niniejsze badania zostały zrealizowane w ramach projektu PECS AVeReS (Assessment of Vegetation damages using Remote Sensing) finansowanego przez European Space Agency (ESA Contract No: 4000107684/13/NL/KML).

ADDRESSES

Adrian Ochtyra ⁽¹⁾ – e-mail: adrian.ochtyra@uw.edu.pl
 Bogdan Zagajewski ⁽¹⁾ – e-mail: bogdan@uw.edu.pl
 Anna Kozłowska ⁽²⁾ – e-mail: a.kozl@twarda.pan.pl
 Adriana Marcinkowska-Ochtyra ⁽¹⁾ – e-mail: adriana.marcinkowska@uw.edu.pl
 Anna Jarocińska ⁽¹⁾ – e-mail: ajarocinska@uw.edu.pl

⁽¹⁾ Zakład Geoinformatyki, Kartografii i Teledetekcji, Uniwersytet Warszawski;
 ul. Krakowskie Przedmieście 30, 00-927 Warszawa

⁽²⁾ Zakład Geoekologii i Klimatologii, Polska Akademia Nauk; ul. Twarda 51/55, 00-818 Warszawa

Wstęp

Uwaga badaczy powinna koncentrować się na górskich obszarach chronionych, ponieważ obserwacja pionowej strefowości biosfery dostarcza informacji o dynamice zmian środowiska zarówno lokalnych, jak i globalnych. Tatry na niewielkiej przestrzeni kumulują naturalne i antropogeniczne zmiany, np. składu gatunkowego, szkód powodowanych przez korniki, zanieczyszczenia powietrza czy wylesiania [Guzik 2009]. Duża dynamika przekształceń poszczególnych płatów leśnych wymaga stałego monitoringu ich kierunku i tempa, a także przygotowywania pożądanych scenariuszy działań.

Obszary wysokogórskie wymagają stosowania technik teledetekcyjnych. Wynika to z trudności eksploracyjnych, krótkiego sezonu wegetacyjnego, a także zmiennych warunków atmosferycznych. Sensory satelitarne, rejestrując widmo elektromagnetyczne w różnych zakresach spektrum, dostarczają szczegółowych informacji o roślinności, np. o zawartości celulozy, nutrientów, wody, barwników fotosyntetycznie czynnych czy rodzaju struktur komórkowych roślin [Jensen 1983; Jarocińska, Zagajewski 2008].

Teledetekcyjne badania obszarów górskich należą do trudnych, gdyż teren o urozmaiconej rzeźbie odbija promieniowanie w różnych kierunkach z różną intensywnością, powodując zmienne charakterystyki spektralne tych samych obiektów, ale zlokalizowanych w różnych jego częściach. Ponadto heterogeniczność środowiska oraz deniwelacje terenu zwiększają liczbę mieszanych pikseli [Zagajewski 2010; Raczko i in. 2015]. Obszary górskie charakteryzują się dużą zmiennością pogody i obecnością chmur oraz cieni, które utrudniają badania. Wrzask wzrostem wysokości bezwzględnej maleje miąższość atmosfery, co zwiększa dopływ promieniowania krótkofalowego i wymusza przystosowania morfologiczne oraz anatomiczne roślin (np. skład barwników czy pokrycie liści woskami) [Caldwell 1971].

Satelity serii Landsat obrazują Ziemię nieprzerwanie od 1972 roku. Pierwsze obrazy zapoczątkowały nową erę badań środowiska [Cook, Iverson 1989; Bauer i in. 1994]. Cyfrowe obrazy Landsat TM umożliwiły opracowanie nowych wskaźników, np. NDVI [Rouse i in. 1973], który pozwala określić zdolność absorpcji promieniowania czerwonego przez chlorofil i karotenoidy, a także ocenić miękisz w zakresie bliskiej podczerwieni. Znajduje to szerokie zastosowanie m.in. w analizach skutków pożarów [Walczykowski in. 2012], jak również w ocenie stanu lasów zaatakowanych przez szkodniki [Zawiła-Niedźwiecki, Wiśniewska 2004]. Obrazy Landsat pozwalają ocenić różne parametry i uszkodzenia drzewostanów [Ciołkosz, Kęsik 1989; Arzani, King 1997; Baniya i in. 2006]. Na podstawie danych Landsat TM i teledetekcyjnych wskaźników roślinności wykonywano także klasyfikację kondycji roślinności metodą sztucznych sieci neuronowych [Olthof i in. 2004]. Dane teledetekcyjne i klasyfikacja metodą drzewa decyzyjnego wykorzystywane były do analiz stanu i zmian powierzchni lasów. Metody drzewa decyzyjnego używano do analiz zmian

ekosystemów leśnych w południowej Kalifornii [Rogan i in. 2002]. Na podstawie obrazów Landsat TM oraz krzywych odbicia spektralnego wyznaczono 5 klas zmian roślinności.

Roślinność tatrzańska jest badana teledetekcyjnie od wielu lat, zarówno przy użyciu sensorów naziemnych, jak lotniczych czy satelitarnych. Dane teledetekcyjne były wykorzystywane do tworzenia map satelitarnych [Fedorowicz-Jackowski, Głazek 1994], oceny stanu kondycyjnego roślinności [Jakomulska 1999; Zwijacz-Kozica i in. 2010; Kycko i in. 2014] czy opracowania nowych metod badawczych [Wężyk, Guzik 2001; Zagajewski 2010].

Celem niniejszego opracowania jest prezentacja metody wstępnej oceny kondycji drzewostanów oraz ukazanie zmian, jakie zaszły na obszarze Tatrzańskiego Parku Narodowego w latach 1987-2011.

Obszar badań

Roślinność Tatr cechuje się dużym zróżnicowaniem w gradiencie wysokościowym. Zbiorowiska leśne sięgają do wysokości 1500 m n.p.m., natomiast subalpejskie piętro kosodrzewiny (*Pinus mugo* Turra) do 1800 m n.p.m. Lasy zajmują 60%, a kosodrzewina 14% powierzchni Tatr. Siedliska leśne nawiązują do pięter klimatyczno-roślinnych i są to bory: wysokogórski i mieszany górski oraz lasy: mieszany górski, górski i łągowy górski. Drzewostany Tatr tworzy kilkanaście gatunków drzew. Największą powierzchnię zajmuje świerk (*Picea abies* (L.) Karst.). W reglu górnym jest on jedynym gatunkiem budującym zbiorowiska leśne tego piętra. W reglu dolnym w warunkach naturalnych na siedliskach boru górskiego tworzy on drzewostany wraz z jodłą (*Abies alba* Mill.), która jest drugim gatunkiem pod względem ilościowego występowania w Tatrach. Pozostałe gatunki drzew mają jedynie znikomy udział. W piętrze subalpejskim głównym gatunkiem jest kosodrzewina, której towarzyszą wierzba, jarząb, świerk i limba (*Pinus cembra* L.).

Wielkie obszary drzewostanów świerkowych podlegają naturalnym procesom rozpadu, zachodzącym w miarę starzenia się drzew. Monokultury świerkowe (zwłaszcza dolnoreglowe) są mniej odporne na wiatr i gradację kornika drukarza niż drzewostany różnowiekowe i wielogatunkowe. Dlatego też częste są wśród nich wiatrołomy i zamieranie drzewostanów na skutek masowych pojawień się kornika drukarza.

Materiał i metody

Po analizie archiwalnych zobrazowań satelitarnych Landsat 5 TM wybrano trzy sceny: 1987.09.01, 2005.09.02 i 2011.09.03. Kryteriami wyboru były: jak najmniejsze zachmurzenie, podobny okres fenologiczny oraz maksymalny odstęp czasowy pomiędzy skrajnymi scenami. Obrazy te poddane zostały korekcji radiometrycznej złożonej z korekcji atmosferycznej, topograficznej oraz redukcji wpływu położenia Słońca. Korekcja wykonana została w oprogramowaniu ATCOR 2/3 i polegała na eliminacji wpływu ukształtowaniu terenu, atmosfery oraz oświetlenia słonecznego [Richter, Shläpfer 2015]. Proces ten jest niezbędny do porównania różnych obrazów i wymaga Numerycznego Modelu Terenu (NMT, wykorzystano dane ASTER o rozdzielczości 30 metrów). NMT umożliwia uwzględnienie położenia 3D każdego piksela względem Słońca, ekspozycji oraz bezwzględnej wysokości terenu. Źródłem oceny jakości korekcji były dane spektrometryczne pomierzone w terenie na tzw. poligonach kalibracyjnych za pomocą spektrometrów hiperspektralnych ASD FieldSpec 3/4. Pomiary wykonane zostały w 2013 i 2015 roku na 13 poligonach, których współrzędne zarejestrowano odbiornikiem GPS Trimble GeoXT. Były to duże, homogeniczne powierzchnie ciemne (wody) i jasne (skały oraz powierzchnie dużych parkingów). Każdy poligon określony był przez 250 niezależnych pomiarów hiperspektralnych, a następnie z każdych 25 pomiarów obliczona została wartość średnia (w celu eliminacji przypadkowych błędów). Wartości

średnie zostały przepróbkowane do rozdzielczości poszczególnych kanałów Landsat TM według charakterystyk spektralnych podanych przez operatora – United States Geological Survey (USGS). Dokładność korekcji obliczono na podstawie średniego błędu kwadratowego (RMSE) pomiędzy wartościami odbicia spektralnego pobranymi z obrazu (\hat{y}_s) a wartościami przepróbkowanych charakterystyk spektralnych pomierzonych w terenie (\hat{y}) według wzoru:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_s - \hat{y})^2}{n}}$$

Na skorygowanych obrazach przystąpiono do klasyfikacji form pokrycia terenu w celu wyznaczenia zasięgu lasów na zobrazowaniach (subalpejskie zarośla kosodrzewiny zostały zaliczone do obszarów leśnych). Na podstawie interpretacji wizualnej utworzono dla każdej ze scen zestawy poligonów testowych oraz weryfikacyjnych. W procesie klasyfikacji wyznaczono dla zobrazowań z 02.09.2005 oraz 03.09.2011 5 klas pokrycia terenu: skały, wody, cienie, lasy oraz zbiorowiska nieleśne. Dla obrazu z 01.09.1987 wyróżniono dodatkowo klasę chmur, gdyż występowały one tylko na tym obrazie. Przetestowano 4 metody klasyfikacji: Minimum Distance, Mahalanobis Distance, Maximum Likelihood oraz Support Vector Machines. Testowano także 3 różne zestawy danych: a) kanały 1, 2, 3, 4, 5 i 7 TM, b) kanały 1, 2, 3, 4, 5 i 7 TM i kanał Greenness z transformacji Tasseled Cap (transformacja służy do pozyskania nowych jakościowo kanałów: greenness, brightness, wetness) oraz c) kanały 1, 2, 3, 4, 5 i 7 TM i wskaźnik Normalized Difference Infrared Index (NDII) [Hardisky i in. 1983]. Zastosowanie wskaźnika NDII pozwoliło na podniesienie dokładności klasyfikacji obszarów leśnych i odseparowanie od obszarów zacienionych. Uzyskane wyniki klasyfikacji pokrycia terenu poddano analizie dokładności, obliczając dokładność producenta (A_p) oraz dokładność użytkownika (A_u). Do kalkulacji tych dokładności wykorzystano informacje o liczbie pikseli poprawnie zaklasyfikowanych do danej klasy (x_{ij}), liczbie pikseli w poligonach weryfikacyjnych tej klasy ($x_{wi...}$) oraz o całkowitej liczbie pikseli danej klasy na obrazie weryfikowanym ($x_{i...}$). Dokładność producenta obliczono wzorem:

$$A_p = \frac{x_{ii}}{x_{wi...}}$$

Dokładność użytkownika obliczono według poniższego wzoru:

$$A_u = \frac{x_{ij}}{x_{i...}}$$

Obrazy poklasyfikacyjne posłużyły jako maski, czyli obrazy binarne, gdzie piksele o wartości 1 reprezentowały drzewostany, natomiast piksele o wartości 0 pozostałe obszary.

W kolejnym kroku obliczono wskaźnik NDVI [Rouse i in. 1973] według wzoru:

$$NDVI = (RNIR - RRED) / (RNIR + RRED)$$

gdzie:

$RRED$ i $RNIR$ – odbicie w zakresie czerwonym (RED) oraz bliskiej podczerwieni (NIR).

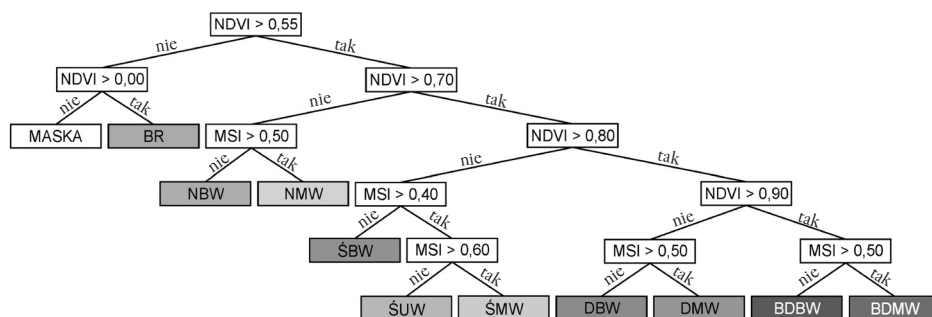
Wskaźnik przyjmuje wartości z zakresu $<-1, 1>$. Im wyższa jest jego wartość, tym absorpcja promieniowania czerwonego przez chlorofil jest większa oraz większe odbicie w bliskiej podczerwieni od miękkszu.

Podobnie wyglądała procedura obliczenia wskaźnika MSI. Wykorzystano podczerwień średnią (MIR) i bliską (NIR) oraz wzór: $MSI = RMIR/RNIR$ [Rock i in. 1986]. Niższe wartości

wskaźnika świadczą o większej zawartości wody w roślinach [Hunt, Rock 1989]. Następnie przystąpiono do właściwej części klasyfikacji metodą drzewa decyzyjnego. Dobór parametrów wynikał z wartości pochodzących z literatury i rozkładu histogramów (ryc. 1). Końcowy etap pracy objął opracowanie map wynikowych.

Wyniki i dyskusja

Wykonana korekcja obrazów satelitarnych pozwoliła uzyskać wyniki na wysokim poziomie dokładności, gdyż pomiary z poziomu satelitarnego i naziemnego (13 par) uzyskały błędy RMSE mieszczące się w przedziale 3-10%, przy czym wartość 10% wystąpiła tylko raz. Satelitarne pomiary spektrometryczne wykazują dużą zgodność z poziomem naziemnym, mimo że zostały wykonane w innym terminie. Wynika to z doboru stabilnych spektralnie obiektów oraz dużej liczby powtórzeń rejestrowanego sygnału. Podobne rozwiązania stosuje się powszechnie, a dostawy danych satelitarnych udostępniają bezpłatnie biblioteki spektralne [Clark i in. 2007]. Klasyfikacja form pokrycia terenu w celu poprawnego wyboru obszarów leśnych przeprowadzona była czterema metodami na trzech zestawach danych. Najlepsze rezultaty otrzymano przy użyciu algorytmu Maximum Likelihood. Głównym celem tego etapu było uzyskanie jak najwierniejszego rozmieszczenia lasów na każdym ze zobrazań. Problematyczne okazało się klasyfikowanie terenów zacienionych jako obszarów leśnych, co w dużym stopniu udało się zniwelować przy włączeniu do klasyfikacji wskaźnika NDII, rozwiązało to również problem klasyfikowania martwych drzewostanów jako skał. Problem ten obserwowany był na danych z roku 2011, gdzie widoczne są duże połacie lasów martwych wskutek ataku kornika. Ostatecznie uzyskane wyniki klasyfikacji lasów wyniosły: 97,69% dokładności producenta oraz 98,31% dokładności użytkownika. Jest to bardzo dobry wynik, gdyż podobny zakres był możliwy do uzyskania na lotniczych danych hiperspektralnych DAIS 7915 [Zagajewski 2010]. Najważniejszy etap klasyfikacji drzewostanów ze względu na ich kondycję bazował na wskaźnikach stanu chlorofilu, struktur komórkowych (NDVI) i zawartości wody (MSI). Został on wykonany za pomocą metody drzewa decyzyjnego.



Ryc. 1.

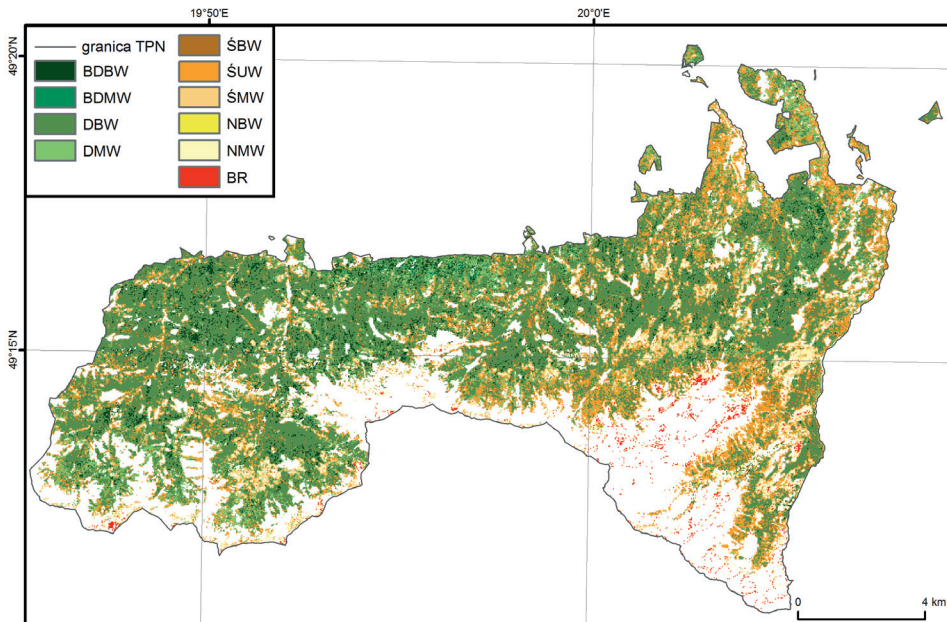
Schemat klasyfikacji metodą drzewa decyzyjnego

Scheme of decision tree classification method

NDVI – Normalized Differenced Vegetation Index, MSI – Moisture Stress Index, NBW – drzewostany o najgorszej kondycji bardziej wilgotne, NMW – drzewostany o najgorszej kondycji mniej wilgotne, SBW – drzewostany o średniej kondycji bardziej wilgotne, SUW – drzewostany o średniej kondycji umiarkowanie wilgotne, SMW – drzewostany o średniej kondycji mniej wilgotne, DBW – drzewostany o dobrej kondycji bardziej wilgotne, DMW – drzewostany o dobrej kondycji mniej wilgotne, BDBW – drzewostany o bardzo dobrej kondycji bardziej wilgotne, BDMW – drzewostany o bardzo dobrej kondycji mniej wilgotne, BR – brak roślinności

NDVI – Normalized Differenced Vegetation Index, MSI – Moisture Stress Index, NBW – forest stands in the worst condition more moist, NMW – forest stands in the worst condition less moist, SBW – forest stands in medium condition more moist, SUW – forest stands in medium condition less moist, SMW – forest stands in medium condition less moist, DBW – forest stands in good condition more moist, DMW – forest stands in good condition less moist, BDBW – forest stands in good condition more moist, BDMW – forest stands in good condition less moist, BR – areas without vegetation

W ramach klasyfikacji wydzielono 9 klas kondycji oraz jedną zawierającą część martwych drzew i obszary bezleśne, których występowanie związane jest ze wspomnianym wcześniej problemem klasyfikacji obszarów zaciemnionych jako lasów. Analizując histogramy oraz statystyki obrazów wskaźników NDVI i MSI, zwracano uwagę na rozkład i rozpiętość wartości, a także na wartość średniej. Ostatecznie wydzielono następujące klasy kondycji drzewostanów, z podziałem na stopień wilgotności aparatu asymilacyjnego: drzewostany o najgorszej kondycji bardziej wilgotne (NBW), drzewostany o najgorszej kondycji mniej wilgotne (NMW), drzewostany o średniej kondycji bardziej wilgotne (ŚBW), drzewostany o średniej kondycji umiarkowanie wilgotne (ŚUW), drzewostany o średniej kondycji mniej wilgotne (ŚMW), drzewostany o dobrej kondycji bardziej wilgotne (DBW), drzewostany o dobrej kondycji mniej wilgotne (DMW), drzewostany o bardzo dobrej kondycji bardziej wilgotne (BDBW) i drzewostany o bardzo dobrej kondycji mniej wilgotne (BDMW). Szczegółowy schemat budowy drzewa decyzyjnego przedstawia rycina 1. Skróty występujące po opisie każdej klasy zastosowane zostały w legendzie mapy prezentującej rozmieszczenie przestrzenne tych klas w roku 2011 (ryc. 2). Wśród wydzielonych klas znajduje się również klasa zawierająca obszary bezleśne oraz lasy zdegradowane w najwyższym stopniu (BR). W przypadku klasy średniej kondycji postanowiono wydzielić trzy stany wilgotności ze względu na największe zróżnicowanie tej klasy po względem zawartości wody. Pełne zestawienie udziału poszczególnych klas w powierzchni drzewostanów prezentuje tabela. Najgorszą kondycją charakteryzował się rok 1987, kiedy dominowały klasy najgorsza i średnia, zajmując niemalże 81% powierzchni leśnej. Było to związane zapewne z występowaniem silnych zanieczyszczeń powietrza w tym rejonie. Znacznie mniejsza powierzchnia zajęta przez lasy na tym obrazowaniu wynika z faktu, iż część terenu zakryta była chmurami. Rok 2005 odznaczał się najlepszą kondycją z trzech



Ryc. 2.

Kondycja lasów Tatrzańskiego Parku Narodowego (stan z 3 września 2011 roku)

Condition of forests in the Tatra National Park (as for 2011, September 3rd)

objaśnienia jak na rycinie 1; denotes as in figure 1

Tabela.

Powierzchnia (A [km²]) i udział powierzchniowy [%] poszczególnych klas kondycji drzewostanów w latach 1987, 2005 i 2011

Area (A [km²]) and areal share [%] of individual condition classes in 1987, 2005 and 2011

	1987		2005		2011	
	A	%	A	%	A	%
NBW	13,23	9,91	0,26	0,17	0,43	0,28
NMW	7,95	5,95	2,30	1,51	7,68	4,98
ŚBW	29,11	21,80	2,75	1,80	3,23	2,09
ŚUW	56,56	42,35	13,25	8,69	31,12	20,18
ŚMW	1,31	0,98	1,81	1,19	7,97	5,17
DBW	21,10	15,80	104,98	68,91	78,32	50,79
DMW	3,92	2,93	10,05	6,60	16,88	10,95
BDBW	0,05	0,04	15,62	10,26	6,26	4,06
BDMW	0,00	0,00	0,61	0,40	0,57	0,37
BR	0,32	0,24	0,72	0,47	1,75	1,13
Razem Total	133,55	100	152,35	100	154,21	100

objaśnienia jak na rycinie 1; denotes as in figure 1

analizowanych okresów, zauważalna jest poprawa stanu w kierunku klas dobrych i bardzo dobrych, które obejmują nieco ponad 86% powierzchni drzewostanów, gdzie dominowały te o wysokiej zawartości wody (około 92%). Udział powierzchni o najgorszej kondycji wyniósł poniżej 2% ogółu powierzchni leśnych. Świadczy to o bardzo dobrej ogólnej kondycji drzewostanów. Najbliższy współczesności badany okres odznacza się dominacją obszarów o kondycji średniej i dobrej (89,18%). Zauważyć można wzrost udziału klasy BR, która zawiera piksele zaklasyfikowane jako lasy, a będące obszarami zacienionymi, jak również martwymi fragmentami lasu (zachodnie zbocza ujścia Doliny Rybiego Potoku). W pozostałej części Parku występowanie klasy NMW oraz ŚMW związane jest z występowaniem posuszu po ataku kornika. Podobne wyniki zaobserwowano dla Karkonoszy, gdzie także w 2002 roku wilgotność była wyższa i przełożyło się to na wzrost kondycji roślin. Co ciekawe, w ostatnich latach również obserwuje się spadek kondycji lasów w Karkonoszach [Jarocińska i in. 2014].

Zę względu na retrospektywny charakter badań autorzy nie posiadają ówczesnych pomiarów terenowych, które posłużyłyby weryfikacji rezultatów klasyfikacji. Niemniej niniejsze badania oparte są na danych satelitarnych po korekcji atmosferycznej. Zastosowane metody, jakość korekcji oraz użycie powszechnych wskaźników roślinności pozwalają wnioskować o poprawności uzyskanych wyników [Richter, Shläpfer 2015].

Dobór wartości progowych dla poszczególnych klas jest subiektywny, jednakże założeniem prezentowanego podejścia jest ukazanie różnic pomiędzy stanem poszczególnych fragmentów drzewostanów w obrębie analizowanego obszaru bez badania przyczyn. Czynniki takie jak zmienność międzygatunkowa czy zwartość drzewostanu mają wpływ na wyniki, lecz przez zastosowanie tych samych kryteriów dla wszystkich analizowanych scen możliwe było obiektywne porównanie stanu oraz zmian kondycji drzewostanów w wybranych latach.

Podsumowanie

Celem pracy była analiza kondycji drzewostanów Tatrzańskiego Parku Narodowego w wybranych okresach (lata 1987, 2005 i 2011) na podstawie satelitarnych danych Landsat 5 TM. Dane zostały poddane korekcji radiometrycznej w oprogramowaniu ATCOR 2/3 z wykorzystaniem

NMT. Uzyskane błędy oscylowały na poziomie 3-10% średniego błędu kwadratowego (RMSE). Do wyznaczenia zasięgu lasów w poszczególnych okresach przetestowano 4 metody klasyfikacji: Minimum Distance, Mahalanobis Distance, Maximum Likelihood oraz Support Vector Machines. Najlepsze wyniki otrzymano za pomocą metody Maximum Likelihood na obrazach po korekcji atmosferycznej oraz z obrazem wskaźnika NDII. Pozwoliło to na dokładniejsze odróżnienie lasów od obszarów zaciemionych. W wyniku klasyfikacji rozróżniono 5 klas pokrycia terenu: lasy, murawy, skały, wody i cienie (dla roku 1987 dodatkowo chmury). Na podstawie wyników klasyfikacji utworzono maski obszarów leśnych i nałożono je na zobrazowania. Kolejnym krokiem było obliczenie dwóch teledetekcyjnych wskaźników roślinności – NDVI i MSI. Wykorzystano je do wyznaczenia 9 klas kondycji drzewostanów w klasyfikacji metodą drzewa decyzyjnego. Wyróżniono cztery klasy ze względu na ogólny stan: najgorszą, średnią, dobrą i bardzo dobrą. Klasy te zostały zróżnicowane dodatkowo ze względu na wilgotność aparatu asymilacyjnego na bardziej i mniej wilgotne (dla klasy średniej uszczegółowiono podział o klasę średniej wilgotności). Wybrane zobrazowania ukazują różny stan kondycyjny lasów Tatrzańskiego Parku Narodowego, począwszy od ogólnie niskiej kondycji w roku 1987, najprawdopodobniej spowodowanej zanieczyszczeniem powietrza, przez bardzo dobry stan w 2005 roku, aż po przeważający na terenie parku dobry stan z silnie zaznaczającymi się obszarami o znacznie obniżonej kondycji. Na podstawie przeprowadzonych badań stwierdzono poprawę kondycji drzewostanów TPN w analizowanym okresie.

Dzięki zaproponowanej metodzie możliwa jest ocena ogólnej kondycji drzewostanów w podziale na klasy wilgotności. Opracowanie szybkiej, a zarazem skutecznej metody przetwarzania danych satelitarnych pozwoli na skuteczne wsparcie monitoringu obszarów chronionych. 23 czerwca 2015 roku został umieszczony na orbicie europejski satelita Sentinel 2a, posiadający parametry sensora zbliżone do sensora OLI wykorzystywanego obecnie na satelicie Landsat 8. Umożliwi to częstszą akwizycję danych, przez co monitoring będzie mógł być bardziej skuteczny. Zastosowanie bezpłatnych danych może w sposób znaczący wspomóc tradycyjne techniki ochrony i monitoringu środowiska.

Literatura

- Arzani H., King G. W. 1997. Application of remote sensing (Landsat TM data) for vegetation parameters measurement in western division of NSW. Proceedings of XVIII IGC. Winnipeg, Manitoba.
- 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.
- Bauer M. E., Burk T. E., Ek A. R., Coppin P. R., Lime S. D., Walsh T. A., Walters D. K., Befort W., Heinzen D. F. 1994. Satellite inventory of Minnesota forest resources. Photogrammetric Engineering and Remote Sensing 60 (3): 287-298.
- Caldwell M. M. 1971. Solar ultraviolet radiation and the growth and development of higher plants. W: Giese A. C. [red.]. Photophysiology. Academic Press, New York. 131-177.
- Ciołkosz A., Kęsik A. 1989. Teledetekcja satelitarna. PWN, Warszawa.
- Clark R. N., Swayze G. A., Wise R., Livo E., Hoefen T., Kokaly R., Sutley S. J. 2007. USGS digital spectral library splib06a: U.S. Geological Survey, Digital Data Series 231.
- Cook E. A., Iverson L. R. 1989. Estimating forest productivity with Thematic Mapper and biogeographical data. Remote Sensing of Environment 28: 131-141.
- Fedorowicz-Jackowski W., Głazek G. 1994. Tatrzy. Satelitarna Mapa Obrazowa. NEOKART GIS. Warszawa.
- Guzik M. [red.]. 2009. Długookresowe zmiany w przyrodzie i użytkowaniu Tatrzańskiego Parku Narodowego 1955-1977-2004. Materiały konferencyjne, 21-22 maja 2009, Zakopane.
- Hardisky M. A., Klemas V., Smart R. M. 1983. The influences of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. Photogrammetric Engineering and Remote Sensing 49: 77-83.
- Hunt E. R., Rock B. N. 1989. Detection of changes in leaf water content using near- and middle-infrared reflectances. Remote Sensing of Environment 30: 43-54.

- Jakomulska A. 1999. Zróżnicowanie wysokogórskiej roślinności Tatr w świetle badań teledetekcyjnych. Katedra Geoinformatyki i Teledetekcji, WGiSR UW. Praca doktorska.
- Jarocińska A., Zagajewski B. 2008. Korelacje naziemnych i lotniczych teledetekcyjnych wskaźników roślinności dla zlewni Bystrzanki. *Teledetekcja Środowiska* 40: 100-124.
- Jarocińska A., Zagajewski B., Ochtyra A., Marcinkowska-Ochtyra., Kycko M., Pabjanek P. 2014. Przebieg klęski ekologicznej w Karkonoszach i Górach Izerskich na podstawie analizy zdjęć satelitarnych Landsat. Konferencja „25 lat po klęsce ekologicznej w Karkonoszach i Górach Izerskich – obawy a rzeczywistość”. Jelenia Góra. 47-61.
- Jensen J. R. 1983. Biophysical Remote Sensing – Review Article. *Annals of the Associations of American Geographers* 73 (1): 111-132.
- Johansen K., Phinn S. 2006. Mapping Structural Parameters and Species Composition of Riparian Vegetation Using IKONOS and Landsat ETM+ Data in Australian Tropical Savannas. *Photogrammetric Engineering & Remote Sensing* 72 (1): 71-80.
- Kycko M., Zagajewski B., Kozłowska A. 2014. Variability in spectral characteristics of trampled high-mountain grasslands. *Miscellanea Geographica* 18 (2): 10-14.
- Olthof I., King D. J., Lautenschlager R. A. 2004. Mapping deciduous forest ice storm damage using Landsat and environmental data. *Remote Sensing of Environment* 89: 484-496.
- 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.
- Richter R., Shläpfer D. 2015. Atmospheric/Topographic Correction for Satellite Imagery. ATCOR-2/3 User Guide, Version 9.0.0, http://www.rese.ch/pdf/atcor3_manual.pdf
- Rock B. N., Vogelmann J. E., Williams D. L., Hoshizaki T. 1986. Remote detection of forest damage. *BioScience* 36: 439-445.
- Rogan J., Franklin J., Roberts D. A. 2002. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote Sensing of Environment* 80: 143-156.
- Rouse J. W., Haas R. H., Schell J. A., Deering D. W. 1973. Monitoring Vegetation Systems in the Great Plains with ERTS. Third ERTS Symposium, NASA SP-351 1: 309-317.
- Walczykowski P., Orych A., Łysenko J. 2012. Przykład wykorzystania obrazów Landsat TM do oceny stanu zagrożenia pożarowego lasów. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 24: 393-402.
- Wężyk P., Guzik M. 2001. Techniki geoinformatyczne w badaniach czasowo-przestrzennych zmian szaty roślinnej na przykładzie rejonu Kasprowego Wierchu w Tatrach. *Teledetekcja Środowiska* 33: 58-67.
- 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.
- Zwijacz-Kozica M., Zwijacz-Kozica T., Zagajewski B. 2010. Ocena wpływu turystyki i narciarstwa na stan koso-drzewiny w rejonie Hali Gąsienicowej na podstawie zdjęć hiperspektralnych. *Nauka a zarządzanie obszarem Tatr i ich otoczeniem. Tom II.* 81-86.