

PETRO LAKYDA, VIKTOR MYRONIUK, ANDRII BILOUS, SERGII BOIKO

Określanie lesistości Polesia Ukraińskiego na podstawie wyników klasyfikacji sezonowych obrazów kompozytowych Landsat 8 OLI

Estimation of forest cover in Ukrainian Polissia using classification of seasonal composite Landsat 8 OLI images

ABSTRACT

Lakyda P., Myroniuk V., Bilous A., Boiko S. 2019. Określanie lesistości Polesia Ukraińskiego na podstawie wyników klasyfikacji sezonowych obrazów kompozytowych Landsat 8 OLI. Sylwan 163 (9): 754-764. DOI: <https://doi.org/10.26202/sylwan.2018158>.

Training dataset for modelling of forest cover was created after classification of multispectral satellite imagery IKONOS-2 with spatial resolution 3.2 m (acquisition date – 12.08.2011). As a result, we created binary forest cover map with 2 categories: 'forest' and 'not-forest'. That allowed us to compute the tree canopy cover for each pixel of Landsat 8 OLI, using vector grid with cell size of 30×30 m. Classification model was developed using training dataset that included 17,000 observations, 10,000 of them represented results of IKONOS-2 classification. Aiming to avoid errors of agricultural lands inclusion into forest mask because of lack of data, additionally we collected about 7000 random observations with canopy cover 0% that had been evenly distributed within unforested area. Random Forest (RF) model we developed allowed us to create continuous map of forests within study area that represents in each pixel value of tree canopy closeness (0-100%). To convert it into a discrete map, we recoded all values less than 30% as 'no data' and values from 30 to 100% as 1. Forest mask for two selected administrative districts of Chernihiv region (NE Ukraine) was created after screening map from small pixel groups that covered area less than 0.5 ha. Obtained results were compared with Global Forest Change (GFC) map and proved that GFC data can be used for forest mapping with tree canopy closeness threshold 40%. On considerable areas of abandoned agricultural lands in the analysed regions of Ukraine, forest stands are formed by Scots pine, silver birch, black alder and aspen. Existence of such forests substantially increases (on 6-8%) the forested area of Gorodnya and Snovsk districts of Chernihiv region – comparing to official forest inventory data. However, such stands are not protected and have high risks to be severed by wildfires, illegal cuttings with aim to renew the agricultural production, by diseases, insects and other natural disturbances.

KEY WORDS

forest cover, remote sensing, Random Forest, IKONOS-2, NDVI

ADDRESSES

Petro Lakyda ⁽¹⁾ – e-mail: lakyda@nubip.edu.ua

Viktor Myroniuk ⁽¹⁾ – e-mail: victor.myroniuk@nubip.edu.ua

Andrii Bilous ⁽¹⁾ – e-mail: bilous@nubip.edu.ua

Sergii Boiko ⁽²⁾ – e-mail: sergii.boiko@okl.lasy.gov.pl

⁽¹⁾ Katedra Taksacji i Urządzania Lasu, Narodowy Uniwersytet Nauk Przyrodniczych i Środowiskowych; Heroiv Oborony 15, 03041 Kijów

⁽²⁾ Ośrodek Kultury Leśnej; ul. Działyńskich 2, 63-322 Gołuchów

Wstęp

Zastosowanie danych teledetekcyjnych rozszerza możliwości odwzorowania stanu i dynamiki zmian lasów. Obecnie wiele satelitarnych systemów monitorowania zapewnia periodyczne fotografowanie znacznej części powierzchni Ziemi w ciągu 1-30 dni i niezbędną szczegółowość wykonywanych zdjęć. Dane Landsat (TM, ETM+, OLI) umożliwiają monitoring terenów leśnych, zapewniając dostateczną przestrzenną rozdzielczość (30 m), powtarzalność fotografowania (16 lub 8 dni) i szerokość pokrycia zdjęć (185×185 km) [Cohen, Goward 2004]. Dzięki wysokiej jakości kalibracji czujników i stabilności wyników radiometrycznej korekty archiwum Landsat stwarza unikalne możliwości badania lasów.

Liczba dostępnych zdjęć satelitarnych dla poszczególnych obszarów może jednak okazać się niewystarczająca. Znaczne ograniczenia stwarzają warunki fotografowania, m.in. zachmurzenie i stan atmosfery. Po udzieleniu przez Służbę Geologiczną USA dostępu do archiwum zdjęć Landsat w 2008 roku [Woodcock i in. 2008] pojawiły się algorytmy tworzenia bezchmurnych obrazów kompozytowych na podstawie analizy poszczególnych pikseli szeregów czasowych zdjęć satelitarnych [Roy i in. 2010; Hansen i in. 2011, 2014]. Powtarzalne obserwacje zwiększają prawdopodobieństwo odnalezienia dla pewnego obszaru bezchmurnych zdjęć i dają możliwość wyboru „najlepszych dostępnych pikseli” (best-available-pixel – BAP) zgodnie z ustalonymi kryteriami: sezonu fotografowania, czujnika, zachmurzenia itd. Ponadto w kompozytach BAP występuje mniej luk w danych, a zatem pozwalają one na monitorowanie dużych obszarów o większej powtarzalności.

Problem wykorzystania sezonowych obrazów kompozytowych był rozważany w badaniach Hansena i in. [2011, 2014] dla klasyfikacji typów pokrywy Ziemi i sporządzenia map lasów oraz Zalda i in. [2016] dla stworzenia modeli struktury drzewostanów i miąższości nadziemnej biomasy.

Chcąc zwiększyć dostęp do informacji dotyczących stanu i dynamiki lasów, opracowano na podstawie zdjęć satelitarnych produkty pochodne odzwierciedlające strukturę pokrywy leśnej na poziomie globalnym i lokalnym. Zwiększenie zainteresowania podobnymi zestawami geodanych wynikało pierwotnie ze skutecznego funkcjonowania systemów MODIS, na podstawie których opracowano zasoby informacyjne dotyczące charakterystyki i dynamiki ekosystemów lądowych w różnych regionach planety, w tym również na Ukrainie [Łesiw i in. 2012]. Nowym etapem w badaniu zasobów naturalnych było wykorzystanie pod koniec lat 90. XX wieku tzw. skal ciągłych Vegetation Continuous Fields (VCF). Dane VCF pozwalają na ocenę pokrywy leśnej na podstawie poszczególnych pikseli od 0 do 100% i odzwierciedlają w jednym pikselu zdjęcia procentowy udział trzech komponentów: roślinności drzewiastej, zielnej i obszarów pozbawionych pokrywy roślinnej [Hansen i in. 2003]. Dla drzewostanów wskaźnik ten będzie odpowiadał stopniowi zwarcia ich okapu, a dla obszarów z fragmentarycznym rozmieszczeniem lasów – lesistości terenu. Sporządzenie map pokrywy Ziemi za pomocą VCF okazało się dość skuteczne podczas badań dynamiki lasów [Song i in. 2014]. W ostatnim dziesięcioleciu obserwowany jest wzrost zainteresowania klasyfikacją pokrywy leśnej w postaci skal ciągłych z wykorzystaniem danych teledetekcyjnych o różnej rozdzielczości przestrzennej [Berberoglu i in. 2008; Coulston i in. 2012; Song i in. 2014].

W 2013 roku na Uniwersytecie Maryland we współpracy ze Służbą Geologiczną USA opracowano na podstawie satelitarnych zdjęć Landsat ogólnodostępną bazę Global Forest Change (GFC) [Hansen i in. 2013], z której można pobrać odpowiednie zestawy danych geograficznych o rozdzielczości przestrzennej 30 m. Globalna mapa ekosystemów leśnych (GFC) daje unikatową możliwość badania stanu i dynamiki pokrywy leśnej, ale przy dokładnej analizie dla odpowiednich warunków przyrodniczo-klimatycznych. Jedną z jej wad związana jest z brakiem możliwości stworzenia bezchmurnej mozaiki ze zdjęć wykonanych w ciągu sezonu wegetacyjnego [Hansen i in. 2011]. Wskutek tego dość prawdopodobne są błędy związane z pominięciem części pokrywy leśnej. Wada ta uwidoczniła się m.in. w drzewostanach z dominacją gatunków liściastych (dąb szypułkowy, grab zwyczajny, jesion wyniosły, brzoza brodawkowata, olsza czarna) w warunkach Polesia Ukraińskiego [Lakyda i in. 2014]. Ogólnie metodę klasyfikacji zdjęć satelitarnych na podstawie procentu pokrywy leśnej należy uznać za efektywną, ponieważ przejście do ciągłego opisu lasów w postaci skal VCF ułatwia ich analizę ilościową [Mironiuk, Georgiian 2017].

Celem badań było opracowanie algorytmu klasyfikacji kompozytowych zdjęć satelitarnych Landsat 8 OLI na podstawie procentu pokrywy leśnej, z wykorzystaniem wyników tematycznej interpretacji danych teledetekcyjnych o bardzo wysokiej rozdzielczości przestrzennej. W pracy przedstawiono wyniki klasyfikacji danych Landsat 8 OLI oraz wielospektralnych zdjęć satelitarnych o większej rozdzielczości przestrzennej wykorzystanych do ustalenia zwarcia drzewostanów i lesistości terenu.

Materiał i metody

W pracy wykorzystano dwa zdjęcia Landsat 8 OLI terenu powiatów snowskiego i horodniańskiego z obwodu czernihowskiego Ukrainy (LC81810242015144LGN00 oraz LC81810242013138LGN01), które przetworzono do wartości odbicia w czujniku TOA (Top of Atmosphere) według metodyki DOS (Dark Object Subtraction) [Chavez 1988]. Obróbka taka jest szczególnie ważna w przypadku korzystania z kilku scen zdjęć satelitarnych obejmujących duże obszary, ponieważ w znacznym stopniu usuwa wpływ zarówno atmosfery, jak i różnego stopnia oświetlenia obiektów.

W celu stworzenia bezchmurnej mozaiki wykorzystano procedurę połączenia dwóch zdjęć satelitarnych, piksel po pikselu, na podstawie maksymalnych wartości indeksu NDVI (maximum-value composite; MVC [Holben 1986]). Procedura ta pozwala na wybieranie do kompozytowego obrazu z każdego kanału spektralnego tylko tych pikseli zdjęć, które nie trafiają na chmury. Jeśli to kryterium jest spełnione przez piksele różnych zdjęć, wybierane są obserwacje z największymi wartościami NDVI. Opracowanie danych teledetekcyjnych wykonano z wykorzystaniem algorytmu opracowanego w środowisku R.

W analizie wykorzystano informację z sześciu kanałów zdjęcia satelitarnego: kanał 4 – Red (0,64-0,67 μm) zakresu widzialnego, kanał 5 – NIR (0,85-0,88 μm) zakresu bliskiej podczerwieni, kanały 6 – SWIR 1 i 7 – SWIR 2 krótkofalowego promieniowania podczerwonego (1,57-1,65 i 2,11-2,29 μm) oraz dwa kanały termalne 10 – TIRS 1 i 11 – TIRS 2 (10,60-11,19 i 11,50-12,51 μm). Zakresy błękitny i zielony nie były wykorzystywane wskutek ich znacznej wrażliwości na wpływ atmosfery. Ponadto, uwzględniając doświadczenie z podobnych badań [Hansen i in. 2014], utworzono dodatkowe rastry NDVI i następane proste stosunki kanałów: kanał 4/kanał 6, kanał 4/kanał 7, kanał 5/kanał 6, kanał 5/kanał 7, kanał 6/kanał 7.

Wybór algorytmów klasyfikacji wymaga uwzględnienia wielu aspektów postawionego zadania: typu danych, przestrzennego rozkładu klas tematycznych, dokładności docelowej oraz wyboru klasyfikatora. W ciągu ostatnich lat częściej wykorzystuje się metody klasyfikacji nadzorowanej (np. maksymalnego prawdopodobieństwa) niż algorytmy automatycznej klasyfikacji (ISODATA,

k-średnich). Ponieważ stosowanie parametrycznych metod klasyfikacji nadzorowanej dla wielowymiarowych zestawów danych albo w przypadku obecności bimodalnych rozkładów zestawu próbnego jest skomplikowane (jeśli rozkład różni się od normalnego), nieparametryczne metody zapewniają znacznie większą elastyczność podczas klasyfikacji. Wśród najnowszych metod klasyfikacji danych teledetekcyjnych dobre wyniki daje metoda Random Forest (RF) [Breiman 2001]. Algorytm uczenia maszynowego RF jest oparty na procedurze bootstrap aggregating (bagging) – losowym kształtowaniu z próby treningowej podzbiorów danych (około $2/3$ ogólnej liczebności) i tworzenia dendrogramów. Pozostałe obserwacje są wykorzystywane do oceny błędów klasyfikacji OOB (out-of-bag). Bagging powtarza się n -krotnie, a wyniki ze wszystkich drzew decyzyjnych są uśredniane. Procedura bootstrapping przewiduje stworzenie zestawu drzew klasyfikacyjnych, który zapewnia mniejszą zmienność modelu RF. Jej parametrami są *mtry* – liczba losowo wybranych przez algorytm zmiennych dla klasyfikacji oraz *ntrees* – liczba wygenerowanych drzew decyzyjnych. Na każdym etapie wybierane są najlepsze wyniki, które później są uśredniane.

Algorytm Random Forest jest dość uniwersalny, ponieważ pozwala rozwiązywać zarówno zadania klasyfikacji, jak i regresji. Wyniki licznych badań wskazują, że jest o wiele dokładniejszy od parametrycznych metod klasyfikacji i nie zależy od specyfiki rozkładu wartości w próbie badawczej [Mykłusz i in. 2013]. Dzięki specjalnemu pakietowi randomForest dla środowiska R odpowiedni algorytm może być z powodzeniem stosowany podczas obróbki zdjęć satelitarnych.

Zestaw próbny dla modelowania procentu pokrycia roślinnością leśną stworzono po przeprowadzeniu klasyfikacji wielospektralnego zdjęcia satelitarnego IKONOS-2 o wielkości piksela 3,2 m (data wykonania zdjęcia – 12.08.2011). Na tym etapie celem było stworzenie dyskretnej mapy lesistości z wyodrębnieniem dwóch kategorii: „las” i „nie las”. Pozwoliło to na określenie stopnia zwarcia dla każdego piksela Landsat 8 OLI, z wykorzystaniem siatki wektorowej o rozmiarach komórki 30×30 m (ryc. 1). Matematyczny model klasyfikacji zdjęcia satelitarnego opracowano na podstawie zestawu próbnego o objętości 17 tys. obserwacji, z których 10 tys. to wyniki klasyfikacji treści danych IKONOS-2. Dla uniknięcia błędnego włączenia gruntów rolnych do „maski leśnej” z powodu niereprezentatywności próby dodatkowo włączono do niej około 7 tys. obserwacji losowych, które miały zwarcie 0% i były rozmieszczone równomiernie na obszarach niepokrytych roślinnością leśną.

Dla właściwej interpretacji danych zarejestrowanych przez sensory konieczne jest posiadanie wiarygodnych informacji o rzeczywistych charakterystykach powierzchni Ziemi. Najbardziej dostępnymi źródłami danych referencyjnych do klasyfikacji obrazów satelitarnych i oceny dokładności tematycznej produktów końcowych są obecnie bezpłatne usługi Google i Bing Maps, które zapewniają swobodny dostęp do obrazów o wysokiej rozdzielczości przestrzennej.

Ocenę dokładności opracowanej mapy zwarcia dokonano w oparciu o warstwową losową próbę składającą się z 413 obserwacji, którą zaprojektowano w oparciu o globalny zestaw geodanych GFC zgodnie z zaleceniami Olofssona i in. [2014]. Wszystkie próby wizualnie zinterpretowano, wykorzystując obrazy o dużej przestrzennej rozdzielczości z ogólnie dostępnych serwisów Google Maps i Bing Maps z wykorzystaniem oprogramowania Open Foris [Bey i in. 2016]. Podczas interpretacji danych uznano, że każda jednostka próbna stanowi centrum działki o powierzchni 0,25 ha. Dla działek, które zostały sklasyfikowane jako pokryte roślinnością leśną, określono kategorię lasów: iglaste (udział gatunków iglastych według pokrycia koron ponad 75%), liściaste (udział gatunków liściastych według pokrycia koron ponad 75%) i mieszane. Ponadto wizualnie ustalono zwarcie drzewostanów.

Dokładność tematycznej interpretacji obszarów leśnych za pomocą ciągłej mapy zwarcia drzewostanów można oszacować za pomocą macierzy błędów (tab. 1). Aby przekonwertować mapy na obraz binarny typu „las” i „nie las”, zastosowano wartość progową zwarcia 30% [Lakyda i in. 2014].

Wyniki

Ogólna dokładność opracowanego modelu regresyjnego wyjaśnia 88% zmienności odpowiedzi (tab. 1). Wartość procentowa IncMSE (Increase of Mean Square Error) wskazuje, o ile zwiększy się średni błąd kwadratowy przy wyłączeniu z modelu odpowiedniego czynnika. Okazało się, że oddzielne kanały widmowe są ważniejsze niż ich stosunki. Stopień dokładności modelowania pokazuje rycina 1, która odzwierciedla zasady kształtowania zestawu próbnego oraz wynik modelowania procentu pokrywy leśnej metodą RF. Do gradientu zostały przyporządkowane rzeczywiste i modelowe wartości zwarcia okapu drzewostanów dla każdego piksela zdjęcia Landsat.

Ustalono również, że na podstawie opracowanego modelu klasyfikacyjnego można określić zwarcie drzewostanów o wiele dokładniej niż na podstawie produktów globalnych. Analizę wykonano na poziomie grup składających się z 9 pikseli (90×90 m). Wyniki faktycznego zwarcia drzewostanów otrzymane na podstawie zdjęć satelitarnych IKONOS były porównywane jednocześnie z globalną mapą GFC oraz opracowaną mapą. Wraz ze zwiększaniem faktycznego zwarcia drzewostanów dane GFC systematycznie zaniżają ten wskaźnik, przy czym prognozowane wartości skoncentrowane są przeważnie przy linii 1:1, co wskazuje na adekwatność opracowanego modelu regresyjnego (ryc. 2).

Na podstawie opracowanego matematycznego modelu dla terenu badań stworzono ciągłą mapę lasów, która odzwierciedla stopień zwarcia drzewostanów od 0 do 100%. W celu przetworzenia tej mapy na binarną wykonano przekodowywanie wszystkich wartości mniejszych od 30% jako „brak danych”, a wartości od 30 do 100% – jako 1. Po usunięciu niewielkich grup pikseli, o powierzchni do 0,5 ha, stworzono mapę rozmieszczenia lasów w dwóch powiatach obwodu czernihowskiego na Ukrainie. Analiza statystyczna wyników na podstawie macierzy błędów potwierdziła adekwatność wykorzystanej metody sporządzenia map lasów w postaci skal ciągłych VCF. Znajduje to odzwierciedlenie w wartości wskaźnika ogólnej dokładności klasyfikacji, który wynosi około 95%. Potwierdza to również wynik nałożenia „maski lasów” na zdjęcie satelitarne z serwisu Google Earth.


Dla rozróżnienia terenów pokrytych i niepokrytych roślinnością leśną na podstawie mapy GFC w warunkach Ukrainy należy stosować wartość progową zwarcia na poziomie 40%, co odpowiada rzeczywistemu zwarcia 30% [Mironiuk, Georgian 2017]. Opracowana mapa pokrycia roślinnością leśną (ryc. 3) pozwala przeprowadzić niezależną ocenę powierzchni lasów na terenie powiatów horodniańskiego i snowskiego, należących do obwodu czernihowskiego (tab. 2).

Tabela 1.

Ocena wpływu czynników na dokładność modelu

Assessment of the impact of predictor variables on model accuracy


	% IncMSE		% IncMSE
Kanał 4 – Red	50,7	NDVI	26,1
Kanał 5 – NIR	59,8	Red/SWIR 1	38,2
Kanał 6 – SWIR 1	40,3	Red/SWIR 2	48,4
Kanał 7 – SWIR 2	42,1	NIR/SWIR 1	37,6
Kanał 10 – TIRS 1	50,8	NIR/SWIR 2	23,7
Kanał 11 – TIRS 2	37,9	SWIR 1/SWIR 2	38,3



Ryc. 1.


Określenie udziału powierzchni leśnej [%] na podstawie danych IKONOS-2 oraz Landsat 8 OLI: A – stworzenie zestawu próbnego według wyników klasyfikacji treści zdjęcia IKONOS-2, B – wynik modelowania metodą Random Forest

Prediction of forest cover [%] according to IKONOS-2 and Landsat 8 OLI data: A – creation of a training dataset based on IKONOS-2 classification, B – Random Forest regression model results



Ryc. 2.

Zgodność obserwowanego oraz obliczonego stopnia zwracia drzewostanów (odpowiednio ZWobs, ZWobl [%]) dla danych Global Forest Change (kółka) i modelu klasyfikacyjnego Random Forest (trójkąty)
 Comparison of observed and predicted canopy cover (ZWobs and ZWobl [%], respectively) for Global Forest Change (circles) and Random Forest classification model (triangles)



Ryc. 3.

Klasyfikacja treści obszarów pokrytych lasem na terenach porolnych
 Classification of forested areas on abandoned agricultural lands

Tabela 2.

Powierzchnia [tys. ha] lasów (A_L) oraz powierzchnia pokryta roślinnością leśną według bazy danych urzędzenia lasu (A_{UL}), opracowanej mapy (A_{mapa}) i klasyfikacji treści danych Landsat 8 OLI (A_{GFC}) w powiatach Horodnia i Snovsk

Area [$\times 1000$ ha] of forests (A_L) as well as covered with forest vegetation according to forest management data (A_{UL}), developed map (A_{mapa}) and classification based on Landsat 8 OLI (A_{GFC}) in Horodnia and Snovsk counties

	A_L	A_{UL}	% A_{UL}	A_{mapa}	% A_{mapa}	A_{GFC}	% A_{GFC}
Horodnia	156,6	41,2	26,3	50,1	32,0	52,4	33,5
Snovsk	128,3	35,8	27,9	46,5	36,2	42,6	33,2

Tabela 3.

Macierz błędów interpretacji obszarów leśnych
Confusion matrix of forest areas classification

	Pokryte roślinnością leśną Forested area	Niepokryte roślinnością leśną Unforested area	Razem In total
Powierzchnie pokryte roślinnością leśną Forested area	166	24	190
Powierzchnie niepokryte roślinnością leśną Unforested area	45	178	223
Razem In total	211	202	413

Pomimo niezgodności prognozowanych wartości zwarcia drzewostanów według mapy globalnej i według wyników niniejszych badań (ryc. 2) obydwie zestawy danych zapewniają podobną ocenę powierzchni lasów na badanym terenie. Jest to związane z wykorzystaniem technologii klasyfikacji progowej, która potwierdza przydatność danych GFC dla stworzenia map binarnych „las” i „nie las”, pod warunkiem właściwego uzasadnienia progowej wartości zwarcia drzewostanów. Idea przedstawienia lasu w nieprzerwanej formie – w pikselowym rozkładzie zwarcia – pozwala uzasadnić dla każdego regionu wartość progową zwarcia, odpowiednią dla otrzymania dokładnej maski lasów. Przykładowo w Gabonie udowodniono, że wartość progowa zwarcia dla mapy GFC powinna wynosić 70% [Sannier i in. 2016].

Otrzymane dane pozwalają stwierdzić, że na podstawie progowej wartości zwarcia 30% można dokładnie rozdzielić na mapie obszary pokryte i niepokryte roślinnością leśną. Ogólna dokładność takiej klasyfikacji wynosi 83,3%. Spośród 45 błędnie interpretowanych obserwacji próby referencyjnej, zakwalifikowanych podczas interpretacji wizualnej do obszarów pokrytych roślinnością leśną, 40 dotyczyło odnowienia lasu (do 10 lat), tj. 34 zrębów i 6 gruntów porolnych. Natomiast błędy klasyfikacji obszarów niepokrytych roślinnością leśną (24) wystąpiły podczas interpretacji obszarów bagiennych (10), obszarów z rozluźnioną roślinnością drzewiastą wśród roślinności zielnej lub krzewiastej (12), a także roślinności na terenie wsi i osiedli (2).

Przeanalizowano również dokładność zastosowania opracowanego modelu RF dla prognozy zwarcia drzewostanu na poziomie pojedynczego piksela 30×30 m. W tym celu wykorzystano część punktów walidacyjnego zestawu danych, które w wyniku analizy wizualnej zostały przypisane do obszarów pokrytych roślinnością leśną.

Chociaż uzyskane wyniki wskazują na pewne problemy identyfikacji procesów odnowienia lasu, opracowaną metodę można z powodzeniem wykorzystać do określania zwarcia drzewostanów i wielkości powierzchni leśnej.

Dyskusja

Uzyskane wyniki zwracają uwagę na problemy ewidencji lasów, które pojawiły się w ciągu ostatnich dziesięcioleci na gruntach porolnych. Zgodnie z obowiązującymi przepisami prawnymi Ukrainy takie obszary nie są zaliczane do gruntów leśnych, chociaż ich obszar jest znaczny i stale się zwiększa [Popkow i in. 2009]. Przy użyciu zdjęć satelitarnych trudno jest wybrać kryteria pozwalające oddzielić zwartą leśną roślinność na gruntach porolnych od kompleksów leśnych, natomiast uwzględnienie ich przy ewidencji lasów znacznie zwiększa ogólną lesistość terenu.

Na terenie północnych powiatów obwodu czernihowskiego występują na dużej powierzchni drzewostany, które nie należą do gruntów leśnych (tab. 2). Przy uwzględnieniu ich w ewidencji lasów lesistość wymienionych powiatów może wzrosnąć o 6-8% w porównaniu z danymi oficjalnymi. Kwestia ta była wielokrotnie omawiana w literaturze – np. podobne wyniki uzyskano podczas weryfikacji lesistości zlewni rzeki Desna, która według globalnej mapy ekosystemów leśnych opracowanej przez University of Maryland okazała się o 20% wyższa [Hill i in. 2010; Hansen i in. 2013; Hłotka 2013; Bilous i in. 2017].

Zazwyczaj na gruntach porolnych, opuszczonych pastwiskach i łąkach w warunkach Polesia Ukraińskiego pojawia się odnowienie sosny, brzozy i olchy. Powstałe w taki sposób lasy nie są zaliczane do gruntów leśnych, nie podlegają państwowej ochronie i wskutek tego są bardzo narażone na pożary i nielegalne pozyskiwanie drewna. Ze względu na stopniowy rozwój agrobiznesu w regionie prowadzonych badań rzeczywista powierzchnia leśna za 5-10 lat może się zmniejszyć, ponieważ rolnicy dla zwiększenia powierzchni rolnej likwidują drzewostany w wieku 15-30 lat powstałe na terenach rolnych porzuconych w latach 90. XX wieku (ryc. 3).

Zgodnie ze Strategią Państwowej Polityki Środowiskowej Ukrainy [Ustawa... 2010] planowane jest zwiększenie powierzchni leśnej kraju do 17%. Ten cel strategiczny wymaga systematycznej analizy potencjalnych zasobów gruntów do zalesienia, mobilizacji środków na finansowanie zalesień i ich ochronę. Jednocześnie opracowanie mechanizmu legalizacji lasów na gruntach porolnych mogłoby zapewnić wzrost powierzchni lasów prywatnych oraz wzrost powierzchni leśnej Ukrainy bez ponoszenia nakładów finansowych z budżetu państwa.

Podsumowanie

Opracowana metoda tworzenia sezonowych obrazów kompozytowych Landsat 8 OLI, która jest podstawą klasyfikacji zdjęć satelitarnych, pozwala na uzyskanie niezależnej oceny powierzchni leśnej zarówno na poziomie globalnym, jak i regionalnym. Przedstawienie wyników klasyfikacji zdjęć satelitarnych w postaci ciągłych skal znacząco poprawia skuteczność analizy charakterystyk przestrzenno-czasowych lesistości, ponieważ lepiej odzwierciedla mozaikowość pokrywy leśnej i ciągłość długotrwałych procesów naturalnych. Metoda Random Forest okazała się wysoce efektywna przy rozwiązywaniu zadań klasyfikacji zdjęć satelitarnych, zarówno podczas sporządzania map tematycznych, jak i zadań analizy regresyjnej.

Na podstawie otrzymanych wyników można stwierdzić, że na północy Ukrainy w ciągu ostatnich dziesięcioleci na znacznej powierzchni terenów porolnych samorzutnie pojawiły się lasy. W większości przypadków nie zostały one zewidencjonowane jako las, co powoduje zaniżenie lesistości terenu w danych oficjalnych w porównaniu do stanu faktycznego.

Połączenie danych satelity Landsat 8 OLI z materiałami o większej rozdzielczości przestrzennej jest dość efektywną metodą, która pozwala na zastosowanie współczesnych metod klasyfikacji, analizy oraz interpretacji otrzymanych wyników. Wykonanie podobnych badań dla innych regionów przyrodniczo-klimatycznych stworzy podstawę dla oceny dokładności oraz nau-

kowo uzasadnionego wykorzystania nowoczesnych globalnych map lesistości podczas ewidencjonowania lasów. Do sporządzania map leśnych można wykorzystać również globalną mapę lasów Global Forest Change, przyjmując poziom 40% jako progową wartość zwarcia.

Literatura

- Berberoglu S., Donmez C., Ozkan C., Sunar F. 2008.** Percent tree cover mapping from Elista MERIS and MODIS data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 B8: 1115-1119.
- Bey A., Diaz A. S. P., Maniatis D., Marchi G., Mollicone D., Ricci S., Miceli G. 2016.** Collect Earth: Land Use and Land Cover Assessment through Augmented Visual Interpretation. *Remote Sensing* 8 (10). DOI: <https://doi.org/10.3390/rs8100807>.
- Bilos A., Myroniuk V., Holiaka D. 2017.** Mapping growing stock volume and forest live biomass: a case study of the Polissya region of Ukraine. *International Journal of Digital Earth* 1.
- Breiman L. 2001.** Random Forest. *Machine Learning* 45 (1): 5-32.
- Chavez P. S. 1988.** An Improved Dark-Object Subtraction Technique for Atmospheric Scattering Correction of Multispectral Data. *Remote Sensing of the Environment* 24: 459-479.
- Cohen W. B., Goward S. 2004.** Landsat's role in ecological applications of Remote Sensing. *Bioscience* 54: 535-545.
- Coulston J. W., Moisen G. G., Wilson B. T., Finco M. V., Cohen W. B., Brewer C. K. 2012.** Modeling Percent tree canopy cover: a pilot study. *Photogrammetric Engineering & Remote Sensing* 78 (7): 715-727.
- Hansen M. C., DeFries R. S., Townshend J. R. G., Carroll M., Dimiceli C., Sohlberg R. A. 2003.** Global percent tree cover spatial resolution of 500 meters: first results of the MODIS Vegetation Continuous Fields algorithm. *Earth Interactions* 7: 1-15.
- Hansen M. C., Egorov A., Potapov P. V. 2014.** Monitoring conterminous United States (CONUS) land cover change with Web-Enabled Landsat Data (WELD). *Remote Sensing of Environment* 140: 466-484.
- Hansen M. C., Egorov A., Roy D. P., Potapov P., Ju J., Turubanova S., Kommareddy I., Loveland T. R. 2011.** Continuous fields of land cover for the conterminous United States using Landsat data: first results from the Web-Enabled Landsat Data (WELD) project. *Remote Sensing Letters* 2: (4) 279-288. DOI: <https://doi.org/10.1080/01431161.2010.519002>.
- Hansen M. C., Potapov P. V., Moore R. 2013.** High-resolution global maps of 21st century forest cover change. *Science* 342: 850-853.
- Hill R. A., Wilson A. K., George M., Hinsley S. A. 2010.** Mapping tree species in temperate deciduous woodland using time-series multi-spectral data. *Applied Vegetation Science* 13 (1): 86-99.
- Hlotka D. W. 2013.** Heodani Global Forest Change dla utocznienia lisystosti subbasejniw Riczky Desna. *Naukowi praci UkrNDHMI* 265: 34-39.
- Holben B. N. 1986.** Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing* 7 (11): 1417-1434.
- Lakyda P. I., Myroniuk W. W., Hilitucha D. W. 2014.** Analiz ta interpretacja karty vysokoho prostorowoho rozrizenennia lisowych ekosystem Polissia Ukrainy. *Zbalansowane pryrodokorystuwannia* 4: 5-9.
- Loveland T. R. 2011.** Continuous fields of land cover for the conterminous United States using Landsat data: first results from the Web-Enabled Landsat Data (WELD) project. *Remote Sensing Letters* 2 (4): 279-288.
- Łesiw M. J., Szczepaszczenko D. H., Szwydenko A. Z., Buń R. A. 2012.** Pobudowa karty lisiw Ukrainy za danymi hlobalnych cyfrowych kart zemelnoho pokrywu. *Naukowyj Wisnyk NETU Ukrainy* 22 (9): 24-30.
- Mironiuk W. W., Georgiiian M. I. 2017.** Zastosuwannia stratyfikowanoji wybirky dla rehionalnoji ocinky ploszczi lisiw Ukrainy za danymi hlobalnych kart lisowoho pokrywu. *Zbalansowane pryrodokorystuwannia* 1: 69-74.
- Mykhus S. I., Czaskowskyj O. H., Hawryluk S. A. 2013.** Deszyfrowannia riznoplanych kosmicznych znimkiw dla ociniuwannia hrup porid. *Naukowi Praci Lisivnycozoi akademiji nauk Ukrainy: zbirnyk naukowych prac* 11: 144-150.
- Olofsson P., Foody G. M., Herold M., Stehman S. V., Woodcock C. E., Wulder M. A. 2014.** Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment* 148: 42-57. DOI: <https://doi.org/10.1016/j.rse.2014.02.015>.
- Popkow M., Kozuszko J., Sawuszczyk N. 2009.** Lesorzawiednienie w Ukrainie: fakty i iluzii.
- Roy D. P., Ju J., Kline K., Scaramuzza P. L., Kovalsky V., Hansen M., Loveland T. R., Vermote E., Zhang C. 2010.** Web-Enabled Landsat Data (WELD): Landsat ETM+ composited mosaics of the conterminous United States. *Remote Sensing of Environment* 114: 35-49.
- Sannier C., McRoberts R. E., Fichet L.-V. 2016.** Suitability of Global Forest Change data to report forest cover estimates at national level in Gabon. *Remote Sensing of Environment* 173: 326-338. <https://doi.org/10.1016/j.rse.2015.10.032>.

- Song X.-P., Huang Ch., Sexton L. O., Channan S., Townshend J. R. 2014.** Annual detection of forest cover loss using time series satellite measurements of percent tree cover. *Remote Sensing* 6 (9): 8878-8903.
- Ustawa z dnia 21 grudnia 2010 Nr 2818-VI Strategia Państwowej Polityki Środowiskowej Ukrainy. 2010.**
- Woodcock C. E., Allen R., Anderson M. 2008.** Free access to Landsat imagery. *Science* 320: 10-11.
- Zald H. S. J., Wulder M. A., White J. C. 2016.** Integrating Landsat pixel composites and change metrics with lidar plots to predictively map forest structure and aboveground biomass in Saskatchewan, Canada. *Remote Sensing of Environment* 176: 188-201.