

**PAWEŁ HAWRYŁO**

## Określanie wybranych cech drzewostanów sosnowych z wykorzystaniem chmur punktów pozyskanych w procesie automatycznego dopasowania cyfrowych zdjęć lotniczych

Estimating selected characteristics of Scots pine stands based on point clouds derived from automatic matching of airborne images

### ABSTRACT

Hawryło P. 2017. Określanie wybranych cech drzewostanów sosnowych z wykorzystaniem chmur punktów pozyskanych w procesie automatycznego dopasowania cyfrowych zdjęć lotniczych. Sylwan 161 (9): 707-714.

Recent research show that image-derived point clouds (IPC) can be successfully utilized in the context of estimation of selected forest parameters. However there are still some topics for further investigation in the context of using archival data. Particularly, in case of forest stands in Poland the number of such studies is limited. This study investigates the usefulness of airborne IPC for estimation of Lorey's height (H), basal area (G) and growing stock volume (V) of Scots pine stands. Additionally, the accuracy of predictive models is analyzed for images acquired in the same year as the field reference data were collected (2015) and for archival images acquired in 2012. The study was performed in Janów Lubelski Forest District (south-eastern Poland) on approximately 7,800 ha. The measurements from 94 circular plots were used as the reference data. The Area Based Approach and multiple linear regression were used to create predictive models. For each analyzed dependent variable variety of IPC characteristics were evaluated to select the most accurate predictive models. The best model for each variable was selected based on Akaike Information Criteria and RMSE. The same predictor variables were used for both years of aerial images acquisition. For models comparison the one-sided bootstrap test was used. The RMSPE for H, G and V in case of images acquired in 2015 amounted to 5.3, 16.3 and 17.3%, respectively. Analogically, the relationship between predicted and observed values ( $R^2$ ) amounted to 0.96, 0.47 and 0.81. The finally selected models had three, one and two predictors for H, G and V, respectively. The difference between accuracy of models based on aerial images from 2012 and 2015 was not statistically significant for all analyzed variables. The obtained results show high potential of using airborne image-derived point clouds for forest inventory activities in Scots pine dominated stands.

### KEY WORDS

Area-Based Approach, forest inventory, Lorey's height, basal area, growing stock volume

### ADDRESSES

Paweł Hawryło – e-mail: p.hawrylo@ur.krakow.pl

Zakład Urządzania Lasu, Geomatyki i Ekonomiki Leśnictwa, Uniwersytet Rolniczy w Krakowie;  
al. 29 Listopada 46, 31-425 Kraków

## Wstęp

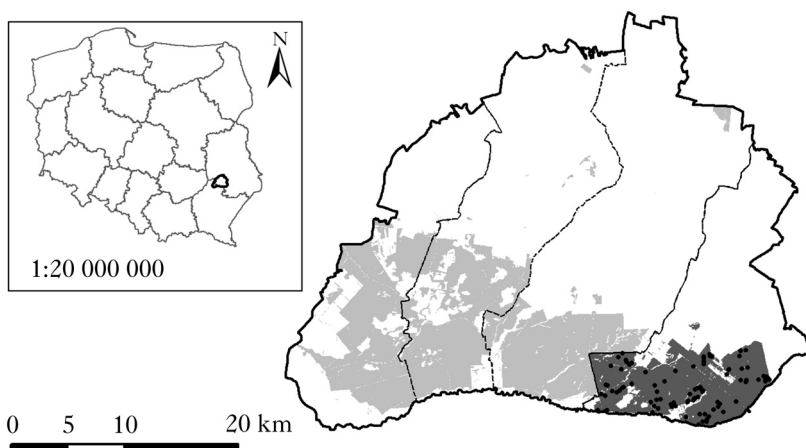
Wykorzystanie technik fotogrametrycznych w leśnictwie ma długą historię. Pierwsze próby użycia zdjęć lotniczych do określania zapasu grubizny sięgają lat 30. XX wieku [Hildebrandt 1996]. W Polsce badania z zakresu wykorzystania technik fotogrametrycznych dla potrzeb zarządzania lasu prowadzone są od kilkudziesięciu lat [Będkowski 2015], poczynając od pracy Gieruszyńskiego [1948]. Jednak w ciągu ostatnich kilkunastu lat w wielu krajach bardziej popularne od klasycznej fotogrametrii stało się wykorzystywanie w inwentaryzacji drzewostanów technologii lotniczego skanowania laserowego (ang. Airborne Laser Scanning; ALS) [Vauhkonen i in. 2014]. Technologia ALS jest od lat także w kręgu zainteresowań polskich badaczy [Będkowski 2004; Wężyk 2006; Stereńczak 2010; Miścicki, Stereńczak 2013]. Dotychczasowe doświadczenia wskazują, że dane ALS są najczęściej przydatne w inwentaryzacji drzewostanów w ramach metody opartej na powierzchniach próbnych (ang. Area-Based Approach; ABA) [Vauhkonen i in. 2014].

Pomimo licznych doświadczeń krajowych i zagranicznych wskazujących na duży potencjał danych ALS technologia ta nie znalazła jak dotąd szerszego zastosowania w praktyce zarządzania lasu w naszym kraju. Jednym z powodów są stosunkowo wysokie koszty pozyskania danych. Z problemem tym borykają się także leśnicy w innych krajach świata, co stało się impulsem do poszukiwania źródła danych gwarantującego podobne dokładności do danych ALS. Taką alternatywą mogą być chmury punktów pozyskiwane w procesie automatycznego dopasowania zdjęć lotniczych (ADZ) [White i in. 2013a; Gobakken i in. 2015; Yu i in. 2015; Hawryło i in. 2017]. Oprócz niższych kosztów pozyskania danych [Ørka, Hauglin 2016] zdjęcia lotnicze umożliwiają ponadto określanie innych cech drzewostanu, takich jak skład gatunkowy, forma zmieszania czy stan zdrowotny, które są dużo trudniejsze, a czasami niemożliwe do określenia na podstawie danych ze skanowania laserowego [Wulder i in. 2008]. Należy jednak pamiętać, że dla optymalnego wykorzystania danych pochodzących z ADZ wymagane jest posiadanie precyzyjnego Numerycznego Modelu Terenu (NMT) w celu normalizacji wysokości bezwzględnej punktów do ich wysokości względnej ponad gruntem. NMT o wymaganej w tym przypadku dokładności generowany jest najczęściej z chmur punktów ALS. W konsekwencji wykorzystanie ADZ będzie ograniczone głównie do obszarów, dla których istnieje precyzyjny NMT stworzony na podstawie danych ALS [White i in. 2013a].

Dotychczasowe badania wskazują na duży potencjał wykorzystania chmur punktów generowanych na podstawie ADZ w określaniu wybranych parametrów drzewostanów. Istnieje jednak potrzeba dalszych badań w celu określenia przydatności zdjęć lotniczych o różnych charakterystykach. Jedną z ważnych cech zobrazowań lotniczych jest ich aktualność. W tym kontekście zdefiniowano dwa główne cele badawcze: (1) określenie dokładności szacowania wysokości Loreya, pierścnicowego pola przekroju oraz zasobności drzewostanów sosnowych na poziomie powierzchni kołowych na podstawie aktualnych oraz archiwalnych chmur punktów uzyskanych w drodze automatycznego dopasowania zdjęć lotniczych, a także (2) wskazanie optymalnych zmiennych objaśniających do budowy modeli predykcyjnych analizowanych cech drzewostanu.

## Materiał i metody

Obiekt badawczy stanowiły drzewostany sosnowe obrębu Władysławów w Nadleśnictwie Janów Lubelski. Obszar badań o powierzchni 7800 ha jest częścią kompleksu leśnego Lasów Janowskich i położony jest w VI Krainie Małopolskiej, Dzielnicy Niziny Sandomierskiej, Mezonegionie Puszczy Solskiej. Według danych zawartych w obowiązującym Planie Urządzenia Lasu dominującymi typami siedliskowymi na analizowanym obszarze są siedliska borów i borów mieszanych



Ryc. 1.

Lokalizacja stanowisk pomiarowych (kropki) na tle lasów obrębu Władysławów (ciemnoszary) Nadleśnictwa Janów Lubelski

Location of the study plots (dots) in relation to forests of Władysławów subdistrict (dark grey) in the Janów Lubelski Forest District

(89,75%), głównie BMw (32,42%), Bśw (26,72%) oraz BMśw (12,81%). Na badanym terenie przeważają drzewostany I (54,49%) i II (27,78) klasy bonitacji. Drzewostany sosnowe zajmują 94,18% powierzchni analizowanego obrębu leśnego. Przeciętny wiek drzewostanów w obrębie wynosi 71 lat (70 lat dla sosny), natomiast przeciętna zasobność 285 m<sup>3</sup>/ha (294 m<sup>3</sup>/ha dla sosny).

W niniejszej pracy wykorzystano metodę ABA. Pomiary terenowe, których celem było zebranie danych referencyjnych, zostały przeprowadzone w sierpniu 2015 roku na 94 powierzchniach kołowych (PK) o powierzchni 400 m<sup>2</sup> każda. Wielkość PK wybrano na podstawie doświadczeń innych autorów wykorzystujących metodę ABA [White i in. 2013b; Næsset 2014]. Przed rozpoczęciem prac terenowych dokonano wyboru lokalizacji PK w taki sposób, aby reprezentowały one możliwie pełną zmienność drzewostanów w badanym obrębie pod względem trzech kryteriów: wieku, zwarcia oraz wysokości drzewostanu. Lokalizacje PK były wybierane w sposób losowy w zdefiniowanych grupach stratyfikacyjnych. Dokładny opis procedury wyboru lokalizacji powierzchni przedstawiono w pracy Hawryło i in. [2017]. Powierzchnie kołowe lokalizowano wyłącznie w drzewostanach, w których w latach 2012-2015 nie było prowadzone pozyskanie drewna. Współrzędne środka PK w terenie lokalizowano przy pomocy odbiornika GNSS Mobile Mapper 120 (Spectra Precision) wyposażonego w dodatkową antenę zewnętrzną. Dane pomiarowe zostały poddane korekcji różnicowej w trybie post-pressing z wykorzystaniem danych systemu ASG-EUPOS ze stacji referencyjnej Biłgoraj (BILG). Średni względny błąd wyznaczania pozycji HRMSE (ang. Horizontal Root Mean Squared Error) określony dla stacji referencyjnej wynosił 0,85 m przy średniej odległości punktów od stacji referencyjnej na poziomie 16,7 km. Na każdej PK mierzono pierśnicę wszystkich drzew o grubości  $\geq 7$  cm. Wysokość (H) mierzono dla trzech drzew każdego gatunku w danej warstwie drzewostanu. Wybierano 7 drzew najbliższych środka PK, a po ich uszeregowaniu według pierśnicy mierzono wysokość trzeciego, czwartego i piątego drzewa w szeregu. Na podstawie pomierzonych pierśnic obliczono pierśnicowe pole przekroju (G) dla każdej PK. Wysokość oraz miąższość (V) każdego drzewa obliczono z wykorzystaniem wzorów opracowanych przez Bruchwalda i in. [2000]. Statystyki opisowe analizowanych cech dla PK przedstawiono w tabeli 1.

Tabela 1.

Minimum (Min), maksimum (Max), mediana (Me), średnia (M) i odchylenie standardowe (SD) wysokości Loreya (H [m]), pierścnicowego pola przekroju (G [m<sup>2</sup>/ha]) oraz zasobności (V [m<sup>3</sup>/ha]) dla wszystkich 94 powierzchni kołowych

Minimum (Min), maximum (Max), median (Me), mean (M) and standard deviation (SD) for Lorey's height (H [m]), basal area (G [m<sup>2</sup>/ha]) and growing stock volume (V [m<sup>3</sup>/ha]) calculated for all 94 circular sample plots

|   | Min  | Me    | M     | Max   | SD    |
|---|------|-------|-------|-------|-------|
| H | 10,1 | 22,5  | 21,8  | 32,5  | 5,8   |
| G | 15,8 | 34,5  | 34,5  | 53,2  | 7,5   |
| V | 93,6 | 343,8 | 344,3 | 764,2 | 133,2 |

W pracy wykorzystano zdjęcia lotnicze w barwach CIR (ang. Colour Infrared) o rozdzielczości przestrzennej 25 cm pozyskane kamerą Vexcel UltraCamXp w czerwcu 2012 roku oraz sierpniu 2015 roku. Dla każdego ich zestawu wygenerowano trójwymiarowe chmury punktów metodą ADZ w oprogramowaniu Agisoft PhotoScan Professional przy użyciu odpowiedniej procedury dopasowania zdjęć [Dandois, Ellis 2013]. Otrzymano chmury punktów o gęstościach 6,8 pkt/m<sup>2</sup> oraz 6,9 pkt/m<sup>2</sup>, odpowiednio dla zdjęć z 2012 i 2015 roku. Normalizację chmur punktów wykonano z użyciem NMT o rozdzielczości przestrzennej 1 m utworzonego w oprogramowaniu FUSION [McGaughey 2015] na podstawie danych ALS pozyskanych w 2013 roku w ramach Informatycznego Systemu Osłony Kraju (ISOK) przed nadzwyczajnymi zagrożeniami.

Kolejnym etapem było ograniczenie znormalizowanych chmur punktów do granic PK i obliczenie dla każdej PK statystyk opisowych z chmur punktów w programie FUSION [McGaughey 2015]. Obliczono wartość maksymalną, średnią, modalną, odchylenie standardowe, wariancję, współczynnik zmienności, rozstęp ćwiartkowy, skośność i kurtozę wysokości punktów oraz średnie odchylenie bezwzględne od średniej wysokości punktów, medianę odchyleń bezwzględnych od mediany i modalnej wysokości punktów, a także 1., 5., 10., 20., 25., 30., 40., 50., 60., 70., 75., 80., 90., 95. i 99. percentyl wysokości punktów, współczynnik reliefu korony (ang. canopy relief ratio;  $CRR = \frac{\text{wysokość średnia} - \text{wysokość minimalna}}{\text{wysokość maksymalna} - \text{wysokość minimalna}}$ ), udział punktów powyżej wysokości 4 m, powyżej średniej wysokości i powyżej modalnej wysokości. W obliczeniach pominięto punkty o wysokości względnej mniejszej niż 1 m w celu wyeliminowania wpływu punktów leżących na gruncie, które mogą powstawać w obszarach o mniejszym zwarciu.

Wykorzystując obliczone statystyki opisowe chmur punktów jako zmienne objaśniające, utworzono modele predykcyjne dla H, G oraz V. Modele te były budowane niezależnie, z wykorzystaniem chmur punktów z lat 2012 i 2015. Tworzenie modeli rozpoczęto od usunięcia zmiennych objaśniających, będących wzajemnie silnie skorelowanymi. Zastosowano współczynnik korelacji Spearmana, ponieważ część zmiennych miała rozkład inny od normalnego. Jeżeli dla pary zmiennych objaśniających współczynnik korelacji był większy bądź równy 0,9, usuwano zmienną, która była słabiej skorelowana z analizowaną zmienną zależną. Na podstawie tak wyselekcjonowanych zmiennych utworzono modele regresji wielorakiej, uwzględniając wszystkie możliwe kombinacje predyktorów. Następnie dla każdej zmiennej zależnej wybrano modele, dla których  $\Delta AIC$  (ang. Akaike Information Criterion) jest mniejsza bądź równa 2, przyjmując, że modele takie charakteryzują się podobną dokładnością predykcji i niekoniecznie modelem optymalnym będzie ten o najniższej wartości parametru AIC [Burnham, Anderson 2002]. Z tak zdefiniowanych podzbiorów modeli dla każdej zmiennej objaśnianej wybrano model o najmniejszej wartości błędu RMSE (ang. Root Mean Squared Error).

Walidację modeli przeprowadzono metodą bootstrap z 500 powtórzeniami, co wykonano odpowiednią procedurą w środowisku R. Istotą takiej walidacji jest szacowanie rozkładu analizowanej statystyki na podstawie wielokrotnego losowania ze zwracaniem z próby [Efron, Tibshirani 1986]. W pojedynczej iteracji losowano 94 obserwacje, które tworzyły zbiór uczący, natomiast obserwacje niewylosowane w danej iteracji tworzyły zbiór testowy, na podstawie którego obliczano wybrane parametry opisujące dokładność modeli. Wykorzystując wyniki próbkowania bootstrapowego, obliczono wartości średnie dla następujących parametrów: współczynnik determinacji ( $R^2$ ), RMSE, procentowy RMSE (RMSPE), błąd średni (ME) oraz błąd średni procentowy (MPE). Porównanie istotności różnic pomiędzy modelami opartymi na danych z 2012 i 2015 roku wykonano przy użyciu testu bootstrapowego dla  $R^2$  oraz RMSE na poziomie istotności  $\alpha=0,05$  [Lopatin i in. 2016].

## Wyniki

W wyniku wstępnej selekcji zmiennych bazującej na współczynniku korelacji Spearmana otrzymano po 10 zmiennych objaśniających dla każdej zmiennej zależnej, na podstawie których, uwzględniając wszystkie możliwe kombinacje, utworzono po 1024 modele liniowe. Modele wybrane ostatecznie na podstawie kryteriów AIC oraz RMSE jako najlepsze dla analizowanych zmiennych zależnych zawierały następujące zmienne objaśniające: dla H – kurtoza, 20. percentyl wysokości oraz 80. percentyl wysokości, dla G – 1. percentyl wysokości, a dla V – średnia wysokość oraz współczynnik reliefu korony.

Największą dokładność predykcji otrzymano dla zmiennej H, dla której współczynnik determinacji wyniósł dla danych z lat 2012 i 2015 odpowiednio 0,95 oraz 0,96, natomiast RMSPE odpowiednio 6,4 oraz 5,3% (tab. 2). Analiza relacji wartości przewidywanych względem obserwowanych także wskazuje, że najlepsze dopasowanie modelu uzyskano dla H, natomiast najłabsze dla G (ryc. 2). W przypadku zasobności drzewostanu wartość współczynnika  $R^2$  uzyskano na poziomie 0,81, a błędy RMSPE dla danych z lat 2012 i 2015 wyniosły odpowiednio 17,6 oraz 17,3%. Wartości MPE były niewielkie dla wszystkich analizowanych zmiennych, a najwyższą wartość tego błędu otrzymano dla zmiennej H szacowanej na podstawie zdjęć z 2012 roku (MPE=0,2%). Porównanie dokładności modeli opracowanych na podstawie zdjęć lotniczych z lat 2012 i 2015 za pomocą testu bootstrapowego wykazało, że różnice w parametrach  $R^2$  oraz RMSE były nieistotne statystycznie dla wszystkich analizowanych zmiennych zależnych.

## Dyskusja

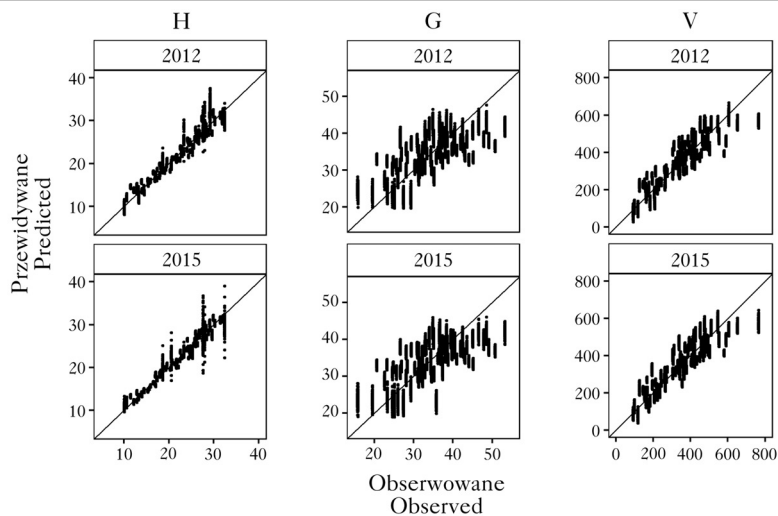
Uzyskana w niniejszej pracy dokładność modeli predykcyjnych dla H, G oraz V jest zbliżona do wyników dotychczasowych doświadczeń prowadzonych w różnych drzewostanach [White i in. 2013a, 2015; Pitt i in. 2014; Gobakken i in. 2015; Stepper i in. 2015]. W Polsce badania dotyczące określania zasobności z wykorzystaniem zdjęć lotniczych w zróżnicowanych drzewostanach sosnowych (udział sosny 66%) prowadził Miścicki [2009], wykorzystując pomiary wykonywane na stacji fotogrametrycznej. Badając związek pomiędzy zasobnością określoną w terenie na powierzchniach kołowych a zasobnością obliczoną na podstawie zmiennych pomierzonych na tzw. powierzchniach fotolotniczych, uzyskał współczynnik determinacji  $R^2$  na poziomie 0,69. W tych samych drzewostanach Miścicki i Stereńczak [2013], wykorzystując zmienne objaśniające uzyskane w sposób automatyczny z Wysokościowego Modelu Koron (WMK) opracowanego na podstawie danych ALS, uzyskali współczynnik  $R^2$  na poziomie 0,86. Doświadczenia Yu i in. [2015] wskazują, że w przypadku podobnie zróżnicowanych drzewostanów możliwe jest uzyskanie modeli szacowania zasobności bazujących na ADZ o wysokim współczynniku determinacji ( $R^2=0,77$ ).

Tabela 2.

Miary dokładności predykcji wysokości Loreya (H [m]), pierśnicowego pola przekroju (G [m<sup>2</sup>/ha]) oraz zasobności (V [m<sup>3</sup>/ha]) oszacowane metodą próbkowania bootstrapowego dla zdjęć lotniczych pozyskanych w latach 2012 oraz 2015

Prediction errors for Lorey's height (H [m]), basal area (G [m<sup>2</sup>/ha]) and growing stock volume (V [m<sup>3</sup>/ha]) obtained from bootstrap resampling for airborne images acquired in 2012 and 2015

|                | H    |      | G    |      | V    |      |
|----------------|------|------|------|------|------|------|
|                | 2012 | 2015 | 2012 | 2015 | 2012 | 2015 |
| R <sup>2</sup> | 0,95 | 0,96 | 0,46 | 0,47 | 0,81 | 0,81 |
| RMSE           | 1,4  | 1,2  | 5,7  | 5,6  | 60,7 | 59,5 |
| RMSPE [%]      | 6,4  | 5,3  | 16,4 | 16,4 | 17,6 | 17,3 |
| ME             | 0,0  | 0,0  | 0,0  | 0,0  | -0,1 | -0,3 |
| MPE [%]        | 0,2  | -0,1 | 0,0  | 0,0  | 0,0  | -0,1 |



Ryc. 2.

Wyniki walidacji modeli predycyjnych wysokości Loreya (H [m]), pierśnicowego pola przekroju (G [m<sup>2</sup>/ha]) oraz zasobności (V [m<sup>3</sup>/ha]) metodą próbkowania bootstrapowego z 500 powtórzeniami dla zdjęć lotniczych pozyskanych w latach 2012 oraz 2015

Results of the validation of predictive models for Lorey's height (H [m]), basal area (G [m<sup>2</sup>/ha]) and growing stock volume (V [m<sup>3</sup>/ha]) based on bootstrap resampling with 500 repetitions for airborne images acquired in 2012 and 2015

Wcześniejsze badania obejmujące drzewostany analizowane w niniejszej publikacji wykazały, że chmury punktów wygenerowane w procesie ADZ pozwalają na uzyskanie dokładności szacowania zasobności porównywalnej z danymi z ALS (RMSPE na poziomie odpowiednio 17,0% oraz 15,2%) [Hawryło i in. 2017]. Stosowanie metody opartej na ADZ wydaje się obecnie z kilku względów atrakcyjne w kontekście możliwości wdrożenia jej do praktyki zarządzania lasu. Dla większości drzewostanów naszego kraju dostępny jest precyzyjny NMT utworzony w ramach projektu ISOK, dzięki czemu normalizacja chmur punktów ADZ nie wymaga ponoszenia dodatkowych kosztów. Za metodą opartą na ADZ przemawiają także zdecydowanie mniejsza pracochłonność w porównaniu do metody bazującej na tzw. powierzchniach fotolotniczych oraz niższe koszty pozyskania danych niż w przypadku technologii ALS. Wyniki wcześniejszych badań wskazują, że wykorzystanie metody ABA pozwala na znaczne ograniczenie wymaganej liczby powierzchni kołowych założonych w terenie w porównaniu do obecnie stosowanej metody inwen-

taryzacji drzewostanów [Instrukcja... 2012; Miścicki, Stereńczak 2013]. Na potrzebę doskonalenia obecnie stosowanej metody inwentaryzacji wskazują również badania Jabłońskiego [2012], który analizował dokładność określania zasobności na poziomie drzewostanu.

Uzyskane różnice w dokładności modeli predycyjnych opracowanych na podstawie zdjęć lotniczych z lat 2012 i 2015 są nieistotne statystycznie. Wyniki te wskazują, że w określonych sytuacjach możliwe jest wykorzystanie archiwalnych zdjęć lotniczych bez zmniejszenia dokładności predykcji wybranych cech drzewostanów. Należy jednak pamiętać, że stosowanie modeli opartych na danych archiwalnych pozwala na uzyskanie w pełni wiarygodnych wyników tylko w tych drzewostanach, w których nie było prowadzone pozyskanie drewna w okresie od wykonania zdjęć (2012) do momentu, dla którego wykonywana jest inwentaryzacja (2015). W przypadku określania zasobności dla lasów będących pod zarządem Państwowego Gospodarstwa Leśnego Lasy Państwowe błędy szacowania zasobności mogą być poddane korekcie na podstawie danych o przyroście miąższości oraz pozyskaniu drewna dostępnych dla każdego drzewostanu w bazie Systemu Informatycznego Lasów Państwowych. Analogiczna korekta w przypadku wysokości i pierśnicowego pola przekroju nie byłaby niestety możliwa przy użyciu wyłącznie tej bazy.

## Wnioski

- ✦ Chmury punktów uzyskane w wyniku automatycznego dopasowania zdjęć lotniczych pozwalają na szacowanie wysokości Loreya oraz zasobności drzewostanu ze stosunkowo dużą dokładnością.
- ✦ Przy poziomie dokładności modeli predycyjnych bazujących na danych ADZ różne tempo przyrostu wysokości drzew w zależności od ich wieku w skali czasowej trzech lat (2012-2015) nie powoduje zmniejszenia dokładności szacowania wysokości Loreya, pierśnicowego pola przekroju oraz zasobności.
- ✦ Dzięki stosunkowo niewielkiej liczbie zmiennych objaśniających opracowane modele predycyjne są atrakcyjne w kontekście wdrożeń praktycznych.
- ✦ Z uwagi na powszechną dostępność precyzyjnego NMT dla większości obszarów leśnych w Polsce oraz coraz częstszą praktykę wykonywania zdjęć lotniczych dla celów opracowywania Planów Urządzenia Lasu zaproponowana metoda inwentaryzacji drzewostanów sosnowych może stanowić alternatywę bądź uzupełnienie obecnie stosowanej metody inwentaryzacji drzewostanów sosnowych.

## Literatura

- Będkowski K. 2004. Skanowanie laserowe i jego zastosowanie w leśnictwie. *Roczniki Geomatyki* 2 (4): 33-40.
- Będkowski K. 2015. Z historii rozwoju fotogrametrii i teledetekcji w leśnictwie polskim. *Teledetekcja Środowiska* 52: 5-15.
- Bruchwald A., Rymer-Dudzińska T., Dudek A., Michalak K., Wróblewski L., Zasada M. 2000. Wzory empiryczne do określania wysokości i pierśnicowej liczby kształtu grubizny drzewa. *Sylvan* 144 (10): 5-12.
- Burnham K. P., Anderson D. R. 2002. *Model Selection and Multimodel Inference. A Practical Information-Theoretic Approach* (Second Edition). Springer.
- Dandois J. P., Ellis E. C. 2013. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. *Remote Sensing of Environment* 136: 259-276.
- Efron B., Tibshirani R. 1986. Bootstrap Methods for Standard Errors, Confidence Intervals, and Other Measures of Statistical Accuracy. *Statistical Science* 1 (1): 54-75.
- Gieruszyński T. 1948. *Zastosowanie fotogrametrii przy urządzaniu gospodarstw leśnych*. Instytut Badawczy Leśnictwa. Warszawa.
- Gobakken T., Bollandsås O. M., Næsset E. 2015. Comparing biophysical forest characteristics estimated from photogrammetric matching of aerial images and airborne laser scanning data. *Scandinavian Journal of Forest Research* 30 (1): 73-86.
- Hawryło P., Tompalski P., Wężyk P. 2017. Area-based estimation of growing stock volume in Scots pine stands using ALS and airborne image-based point clouds. *Forestry* 90 (5): 686-696.



- Hildebrandt G. 1996. Fernerkundung und Luftbildmessung. Herbert Wichmann Verlag, Heidelberg.
- Instrukcja urządzania lasu. 2012. CILP, Warszawa.
- Jabłoński M. 2012. Dokładność szacowania miąższości drzewostanów sosnowych w trakcie prac urządzania lasu. Sylwan 156 (9): 643-649.
- Lopatin J., Dolos K., Hernández H. J., Galleguillos M., Fassnacht F. E. 2016. Comparing Generalized Linear Models and random forest to model vascular plant species richness using LiDAR data in a natural forest in central Chile. Remote Sensing of Environment 173: 200-210.
- McGaughey R. J. 2015. FUSION/LDV: Software for LIDAR Data Analysis and Visualization. USDA Forest Service, Pacific Northwest Research Station: Seattle, WA, USA.
- Miścicki S. 2009. Pomiar zapasu grubizny z wykorzystaniem zdjęć lotniczych. Sylwan 153 (6): 373-385.
- Miścicki S., Stereńczak K. 2013. Określanie miąższości i zagęszczenia drzew w drzewostanach centralnej Polski na podstawie danych lotniczego skanowania laserowego w dwufazowej metodzie inwentaryzacji zasobów drzewnych. Leś. Pr. Bad. 74 (2): 127-136.
- Næsset E. 2014. Area-Based Inventory in Norway – From Innovation to an Operational Reality. W: Maltamo M., Næsset E., Vauhkonen J. [red.]. Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies, Springer Netherlands. 215-240.
- Ørka H. O., Hauglin M. 2016. Use of remote sensing for mapping of non-native conifer species.
- Pitt D. G., Woods M., Penner M. 2014. A Comparison of Point Clouds Derived from Stereo Imagery and Airborne Laser Scanning for the Area-Based Estimation of Forest Inventory Attributes in Boreal Ontario. Canadian Journal of Remote Sensing 40 (3): 214-232.
- Stepper C., Straub C., Pretzsch H. 2015. Using semi-global matching point clouds to estimate growing stock at the plot and stand levels: application for a broadleaf-dominated forest in central Europe. Canadian Journal of Forest Research 45 (1): 111-123.
- Stereńczak K. 2010. Technologia lotniczego skanowania laserowego jako źródło danych w półautomatycznej inwentaryzacji lasu. Sylwan 154 (2): 88-99.
- Vauhkonen J., Maltamo M., McRoberts R. E., Næsset E. 2014. Introduction to Forestry Applications of Airborne Laser Scanning. W: Maltamo M., Næsset E., Vauhkonen J. [red.]. Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies, Springer Netherlands. 1-16.
- Węzyk P. 2006. Wprowadzenie do technologii skaningu laserowego w leśnictwie. Roczniki Geomatyki 4 (4): 119-132.
- White J., Stepper C., Tompalski P., Coops N., Wulder M. 2015. Comparing ALS and Image-Based Point Cloud Metrics and Modelled Forest Inventory Attributes in a Complex Coastal Forest Environment. Forests 6 (10): 3704-3732.
- White J., Wulder M., Vastaranta M., Coops N., Pitt D., Woods M. 2013a. The Utility of Image-Based Point Clouds for Forest Inventory: A Comparison with Airborne Laser Scanning. Forests 4 (3): 518-536.
- White J. C., Wulder M. A., Varhola A., Vastaranta M., Coops N. C., Cook B. D., Pitt D.G., Woods M. 2013b. A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. Information Report FI-X-10. Canadian Forest Service, Canadian Wood Fibre Centre, Pacific Forestry Centre: Victoria, BC, Canada.
- Wulder M. A., Bater C. W., Coops N. C., Hilker T., White J. C. 2008. The role of LiDAR in sustainable forest management. Forestry Chronicle 84 (6): 807-826.
- Yu X., Hyypää J., Karjalainen M., Nurminen K., Karila K., Vastaranta M., Kankare V., Kaartinen H., Holopainen M., Honkavaara E., Kukko A., Jaakkola A., Liang X., Wang Y., Hyypää H., Katoh M. 2015. Comparison of laser and stereo optical, SAR and InSAR point clouds from air- and space-borne sources in the retrieval of forest inventory attributes. Remote Sensing 7 (12): 15933-15954.