

Zastosowanie naziemnego skanowania laserowego w inwentaryzacji lasu – przegląd wybranych zagadnień

Application of terrestrial laser scanning in forest inventory – an overview of selected issues

Grzegorz Krok* , Bartłomiej Kraszewski , Krzysztof Stereńczak 

Instytut Badawczy Leśnictwa, Zakład Geomatyki, Sękocin Stary, ul. Braci Leśnej 3, 05–090 Raszyn, Polska

*Tel. +48 22 7150366, e-mail: g.krok@ibles.waw.pl

Abstract: Precise determination of forest resources is one of the most important tasks in conducting sustainable forest management. Accurate information about the forest's resources allows for a better planning of current and future management as well as conservation activities. Such precise information is needed by both, individual forest managers and for developing the national forest policy. In recent years, interest in the use of remote sensing in forest inventory has significantly increased. Remote sensing allows for non-invasive measurements and the automation of data processing. The most accurate source of remote sensing data at the level of the sample plot is terrestrial laser scanning (TLS). Its use in forest inventory has been studied for about two decades.

This paper aims to introduce studies on state of the art TLS technology as well as provide an overview of research conducted in stands within the temperate climate zone. This article furthermore discusses issues such as TLS data acquisition, data processing and presents results for the estimation of tree biometric features.

Keywords: LiDAR, point cloud, forestry, remote sensing

Słowa kluczowe: LiDAR, chmura punktów, leśnictwo, teledetekcja

1. Wstęp

Precyzyjne określanie zasobów leśnych jest jednym z najważniejszych zadań w prowadzeniu zrównoważonej gospodarki leśnej. Dokładna informacja o zasobach pozwala planować aktualne i przyszłe działania gospodarcze i ochronne. Wiedza ta potrzebna jest także do prowadzenia zrównoważonej polityki leśnej. Zależnie od celu, dostępności środków finansowych i wymaganej dokładności wyróżnia się wiele metod inwentaryzacji lasu. Ze względu na wysokie koszty oraz czasochłonność prac terenowych leśnicy często wykorzystują metody statystyczno-matematyczne, oparte na pomiarach dokonywanych na kołowych powierzchniach próbnych. Grupy terenowe zazwyczaj dokonują pomiaru cech, takich jak pierśnica i wysokość, oraz określają gatunek i lokalizację każdego z drzew względem środka powierzchni próbnej. Wysoka czasochłonność prac terenowych prowadzonych przy wykorzystaniu konwencjonalnych narzędzi (np. średnicomierza, busoli, wysokościomierza) wymusza poszukiwanie nowych, alternatywnych rozwiązań, które obniżą koszty

oraz pracochłonność inwentaryzacji, a także zwiększą jej efektywność.

W ostatnich latach powstał szereg prac naukowych dotyczących wykorzystania technologii teledetekcyjnych w inwentaryzacji lasu, w szczególności technologii skanowania laserowego (ang. LiDAR – Light Detection and Ranging). Produktem tej technologii jest trójwymiarowy obraz rzeczywistości składający się z milionów punktów tworzących tzw. chmurę punktów. Pozwala on na precyzyjny pomiar wymiarów i struktury zeskanowanych obiektów (Będkowski 2004; Wężyk 2006). Skanery laserowe integrowane są z różnego rodzaju platformami, np. z platformą lotniczą – lotnicze skanowanie laserowe (ang. ALS – airborne laser scanning) lub ze stacjonarnym statywem geodezyjnym – naziemne skanowanie laserowe (ang. TLS – terrestrial laser scanning). W gospodarce leśnej, ze względu na rozległość obszarów leśnych, najczęściej rozpatrywane jest pozyskiwanie danych technologią lotniczego skanowania laserowego, zapewniającą pozyskanie danych dla całych obrębów leśnych w krótkim czasie (Wężyk 2006; Stereńczak 2010; Będkowski et al. 2011). Powstało wiele prac dotyczących

Wpłynęło: 25.10.2020 r., zrecenzowano: 9.11.2020 r., zaakceptowano: 16.11.2020 r.

tw. „wzmocnionych inwentaryzacji leśnych” (ang. enhanced forest inventories), które wykorzystują dane lotniczego skanowania laserowego w połączeniu z pomiarami terenowymi, umożliwiając oszacowanie cech taksacyjnych dla pojedynczych wydzielen leśnych z wysoką dokładnością (White et al. 2016). W niektórych krajach metody inwentaryzacji lasów wykorzystujące lotnicze skanowanie laserowe są stosowane w praktyce leśnej, np. w Norwegii, Finlandii, Danii i Szwecji (Kangas et al. 2018). Najczęściej stosowaną metodą inwentaryzacji lasu z wykorzystaniem danych lotniczego skanowania laserowego jest tzw. metoda powierzchniowa (ang. Area Based Approach, ABA), która wykorzystuje zależności pomiędzy charakterystykami chmury punktów a pomiarami naziemnymi, przy użyciu narzędzi statystycznych (Næsset 2002; White et al. 2013; Hawryło 2017). Metoda ta umożliwia opracowanie modelu predycyjnego każdej cechy taksacyjnej określonej na podstawie pomiarów terenowych. Po stworzeniu modeli matematycznych, finalnym etapem jest ich zastosowanie do całego zeskanowanego obszaru.

Lotnicze skanowanie laserowe umożliwia pozyskanie danych dla rozległych obszarów w sposób szybki i przy relatywnie niskich kosztach. Dodatkowo, w porównaniu do tradycyjnej metody statystyczno-matematycznej, zastosowanie lotniczego skanowania laserowego wraz z metodą powierzchniową wymaga mniejszej liczby powierzchni próbnych, przy zachowaniu założonego poziomu dokładności szacunków (Stereńczak et al. 2018). Należy jednak podkreślić, że dla tej metody musi zostać wykonana część pomiarów naziemnych służących do kalibrowania modelu statystycznego, gdyż technologia ALS nie umożliwia bezpośrednich obserwacji zdrewniałych części roślinności, w tym pni (White et al. 2016).

Komplementarnym źródłem danych do pomiarów lotniczych są dane naziemnego skanowania laserowego. Reprezentują one obraz drzewostanu widziany z poziomu gruntu pod koronami drzew. Efektem wykorzystania TLS jest bardzo gęsta chmura punktów o milimetrowej dokładności pomiaru (Zawiła-Niedźwiecki et al. 2008, Wężyk 2010). W związku z tym technologia ta postrzegana jest jako najdokładniejsze źródło danych teledetekcyjnych na poziomie powierzchni próbnych (Liang et al. 2018a). Dodatkową zaletą jej stosowania jest zautomatyzowany i bardzo szybki sposób pozyskiwania danych.

Wykorzystanie TLS w leśnictwie ma stosunkowo krótką historię. Pierwszy naziemny skaner laserowy został wprowadzony do sprzedaży w 1998 roku (Liang et al. 2016). Pionierskie prace naukowe dotyczące zastosowania TLS w leśnictwie przypadają na przełom XX i XXI wieku (Tanaka et al. 1998; Aschoff, Spiecker 2004; Henning, Radtke 2006). Początkowo, główną motywacją wykorzystania TLS w leśnictwie było usprawnienie prac terenowych na powierzchniach próbnych poprzez zastąpienie części pomiarów wykonywanych manualnie. Wczesne prace dotyczyły automatycznych lub półautomatycznych rozwiązań, które bazując na danych TLS, miały na celu pomiar podstawo-

wych cech biometrycznych drzew, takich jak: pierśnica, wysokość i lokalizacja (Maas et al. 2008; Brolly, Kiraly 2009). Wraz ze wzrostem mocy obliczeniowej komputerów i rozwojem algorytmów przetwarzania danych zaczęto dostrzegać nowe możliwości wykorzystania danych TLS. Stały się one cennym źródłem informacji pozwalających na automatyczny pomiar cech biometrycznych, które wcześniej nie były możliwe do bezpośredniego pomiaru przy pomocy konwencjonalnych metod inwentaryzacji lasu. Powstało wiele prac dotyczących metod automatycznego określania miąższości oraz biomasy drzew na podstawie danych TLS, w których autorzy raportują dokładności porównywalne z najlepszymi krajowymi wzorami allometrycznymi (Astrup et al. 2014; Liang et al. 2014). Potencjał tej technologii został również dostrzeżony w badaniach dotyczących ekologii lasu. Sprawdzano w nich przydatność TLS m.in. do określania wskaźnika LAI (ang. Leaf Area Index), badania dynamiki zmian w lukach drzewostanu i struktury koron drzew (Liang et al. 2016).

Polskie ośrodki naukowe również od lat prowadzą badania nad wykorzystaniem TLS w leśnictwie. Badania te dotyczą głównie zagadnień związanych z inwentaryzacją lasu (Chirrek et al. 2007; Wężyk et al. 2007; Chmielewski et al. 2010; Wężyk, Sroga 2010; Zasada et al. 2013; Ratajczak, Wężyk 2015), ale również takich zagadnień, jak: określanie rozkładu pierśnic (Zasada, Stereńczak 2013), inwentaryzacja zieleni miejskiej (Tompalski 2009) i monitorowanie stanu drzew będących pomnikami przyrody (Wężyk et al. 2015).

Niniejsza praca stanowi syntetyczny przegląd badań nad wykorzystaniem technologii naziemnego skanowania laserowego prowadzonych od około 20 lat w drzewostanach strefy umiarkowanej. W pracy tej autorzy skupili się w szczególności na praktycznych aspektach wykorzystania technologii TLS w inwentaryzacji lasu oraz na podsumowaniu osiągniętych dokładności pomiaru najważniejszych cech biometrycznych drzew. W sekcji Dyskusja autorzy oceniają możliwość wprowadzenia tej technologii do praktyki leśnej.

2. Zasada działania TLS oraz typ skanerów

Zasada działania skanerów TLS opiera się na pomiarze odległości oraz kąta poziomego i pionowego pomiędzy urządzeniem a badanym obiektem przy wykorzystaniu emitowanych przez urządzenie wiązek światła (lasera).

Pomiary TLS wykonuje się stacjonarnie z wyznaczonych stanowisk, gdzie ustawia się skaner na statywie geodezyjnym. Podczas pracy skaner rejestruje obraz otaczającej rzeczywistości, obracając się wokół własnej osi. Dzięki pomiarom wykonywanym przez urządzenie możliwe jest określenie współrzędnych X, Y, Z milionów punktów pomiarowych tworzących tzw. chmurę punktów. Naziemne skanery laserowe poza rejestrowaniem współrzędnych punktów rejestrują także intensywność odbitego sygnału, będącą wartością energii powracającej wiązki światła (odbitej od obiektu). Ze skanerami TLS integruje się również

kamery cyfrowe, dzięki czemu możliwe jest przypisanie każdemu punktowi chmury barw rzeczywistych (RGB) ze zdjęć cyfrowych (Wężyk 2010).

Obecnie na rynku dostępnych jest kilkanaście modeli naziemnych skanerów laserowych, które można podzielić na dwie główne grupy: skanery pulsacyjne (ang. time-of-flight, ToF) oraz skanery fazowe (ang. phase-shift). Główną cechą różniącą te dwa rodzaje skanerów jest technologia pomiaru odległości.

Przyjmuje się, że skanery fazowe są dokładniejsze w pomiarze od skanerów pulsacyjnych, jednakże dane pozyskane przy ich pomocy są narażone na zakłócenia, tj. pojawianie się szumów w pozyskanych danych. Warto zaznaczyć również, że skanery fazowe mają z reguły mniejszy zasięg pomiaru danych w porównaniu do skanerów pulsacyjnych (Wężyk 2010). Dużą zaletą skanerów ToF jest możliwość rejestracji wielokrotnych odbić wiązki lasera. Jest to szczególnie istotne przy skanowaniu obiektów, gdzie występuje roślinność (Liang et al. 2016). W przypadku gdy plamka lasera pada np. na skrajną część pnia lub cienką gałąź, część wiązki odbija się od niej, a pozostała część przenika dalej, rejestrując kolejne napotkane obiekty. Obecnie na rynku dostępne są w sprzedaży skanery pulsacyjne, które mogą rejestrować do 15 odbić wiązki lasera (Riegl 2020).

W celu poszerzenia wiedzy na temat typów skanerów oraz ich zasad działania autorzy odsyłają do prac Wężyka (2006, 2010), Dassot i in. (2011) lub Liang i in. (2016).

3. Pozyskanie danych TLS

W poniższych podrozdziałach została opisana ogólna specyfika pozyskiwania danych TLS w środowisku leśnym dla trzech poziomów: powierzchni próbnej, pojedynczego drzewa oraz całego drzewostanu.

3.1. Powierzchnie próbne


Skanowanie powierzchni próbnych przy użyciu technologii TLS zazwyczaj przeprowadza się, wykorzystując jednostanowiskowy (ang. single-scan, SS) lub wielostanowiskowy (ang. multi-scan, MS) tryb pozyskania danych. W trybie jednostanowiskowym skaner umiejscowiony jest na środku powierzchni próbnej. Dane pozyskane w tym trybie reprezentują obraz drzewostanu widziany z jednej perspektywy, czyli ze środka powierzchni próbnej. Z kolei w trybie wielostanowiskowym pozyskuje się dane z kilku pozycji – najczęściej ze środka oraz z zewnątrz powierzchni lub wykonując skanowanie tylko z pozycji zewnętrznych. Decydując się na pozyskanie danych w tym trybie, podczas kampanii terenowej zazwyczaj należy dodatkowo rozstawić sztuczne znaczniki referencyjne (kule lub tarczki), które umożliwiają wzajemne połączenie danych w późniejszym procesie ich przetwarzania. Ten sposób pozyskania danych zapewnia znacznie większą kompletność danych w porównaniu do trybu jednostanowiskowego. Dane pozyskane

trybem wielostanowiskowym po połączeniu reprezentują kompleksowy, w pełni trójwymiarowy obraz powierzchni próbnej (Wężyk 2010; Liang et al. 2016).

Porównując obie metody pozyskania danych należy zauważyć, że tryb jednostanowiskowy jest znacznie szybszy. Obecnie wykonanie takiego pomiaru na powierzchni próbnej trwa około 20 minut. Czas pomiaru uzależniony jest głównie od klasy używanego skanera laserowego oraz od ustawień wykorzystywanych podczas pracy. Sam proces pozyskania danych trwa od 2 do 10 minut. Do tego czasu należy doliczyć także czas rozstawienia, uruchomienia oraz skonfigurowania skanera, który wynosi około 5–10 minut (Liang et al. 2016). Główną wadą pozyskania danych w trybie jednostanowiskowym jest duże prawdopodobieństwo wystąpienia tzw. efektu przysłaniania (Zasada et al. 2013). Efekt ten powoduje, że nie wszystkie drzewa znajdujące się w obrębie powierzchni próbnej są odwzorowane w chmurze punktów (ryc. 1). Dzieje się tak, ponieważ drzewa znajdujące na tym samym azymucie względem środka powierzchni wzajemnie się przysłaniają. Efekt ten rośnie wraz ze wzrostem odległości od skanera, a zatem im większy promień powierzchni próbnej, tym większe prawdopodobieństwo wystąpienia tego efektu. Autorzy podają w swoich pracach, że odsetek niewykrytych drzew na powierzchni próbnej przy zastosowaniu trybu jednostanowiskowego może wynosić od 0 do 46%, wskazując strukturę drzewostanu oraz wielkość powierzchni próbnej jako czynniki mające największy wpływ na to zjawisko (Astrup et al. 2014). Dla porównania do zmapowania powierzchni próbnej w trybie wielostanowiskowym wykorzystuje się zazwyczaj cztery lub pięć stanowisk skanowania. Pozycje są tak rozmieszczone, aby odwzorować wszystkie drzewa, możliwie z każdej strony. Dane pozyskane w tym trybie uznawane są za najdokładniejsze, dodatkowo zapewniając w pełni trójwymiarowy obraz drzewostanu (każde drzewo ma odwzorowane pełny kształt i płaszczyznę pnia). Do wad tego trybu należą: większa pracochłonność podczas prac terenowych, dłuższy czas pracy potrzebny na przetworzenie i połączenie chmur punktów oraz znacznie większa objętość pozyskanych danych. Obecnie przyjmuje się, że pomiar wielostanowiskowy powierzchni próbnej trwa około 1 godziny. W przypadku pozyskania danych wielostanowiskowych, w procesie ich wstępnego przetwarzania, dochodzi dodatkowy etap wzajemnego łączenia skanów. Wykonuje się go w specjalistycznym oprogramowaniu w sposób automatyczny lub półautomatyczny (Liang et al. 2016).

3.2. Drzewa modelowe

Pozyskanie danych TLS można również przeprowadzić dla pojedynczych drzew (ryc. 2). Takie dane mogą być użyteczne w procesie poprawy lub tworzenia wzorów allometrycznych takich cech jak miąższość grubizny czy biomasa całego drzewa. Dużą zaletą wykorzystania technologii TLS do tych celów jest bezinwazyjność, szybkość i precyzja po-



Rycina 1. Chmura punktów TLS przedstawiająca powierzchnię kolową w drzewostanie sosnowym *Pinus sylvestris* L.: A – tryb jednostanowiskowy (SS), B – tryb wielostanowiskowy (MS). Czarny prostokąt wskazują na niezarejestrowane drzewa w trybie SS (efekt przysłaniania). Kolorystyka: wartość intensywności odbicia, wizualizacja została wykonana w oprogramowaniu CloudCompare (Girardeau-Montaut 2020).

Figure 1. TLS point cloud representing sample plot in a Scots pine stand *Pinus sylvestris* L.: A – single-scan mode (SS), B – multi-scan mode (MS). The black rectangle shows unregistered trees in SS mode (occlusion effect). Color scheme: Intensity values, visualization was made in CloudCompare software (Girardeau-Montaut 2020).

zyskania informacji o przebiegu krzywej morfologicznej strzały. Skanowanie pojedynczych drzew zazwyczaj prowadzi się metodą wielostanowiskową w celu pozyskania danych o najwyższym stopniu szczegółowości. Podczas prac terenowych stanowiska skanera rozmieszcza się wokół drzewa. Raunonen i in. (2013) sugerują wykonywanie pomiaru z nie mniej niż trzech stanowisk. Należy jednak zaznaczyć, że liczba pozycji skanera powinna być dobierana zależnie od wielkości skanowanego obiektu oraz planowanej szczegółowości danych (Wilkes et al. 2017). Dla przykładu w badaniach Wężyka i in. (2015) do zeskanowania drzewa pomnikowego Dębu Bartek, podczas jednej kampanii terenowej, wykorzystano od 4 do 23 stanowisk skanowania. Natomiast w 2020 roku pracownicy Instytutu Badawczego Leśnictwa (IBL) zeskanowali inne drzewo pomnikowe – Dąb Mieszko – z 10 stanowisk, co wystarczyło do wiernego zarejestrowania wyglądu całego drzewa.

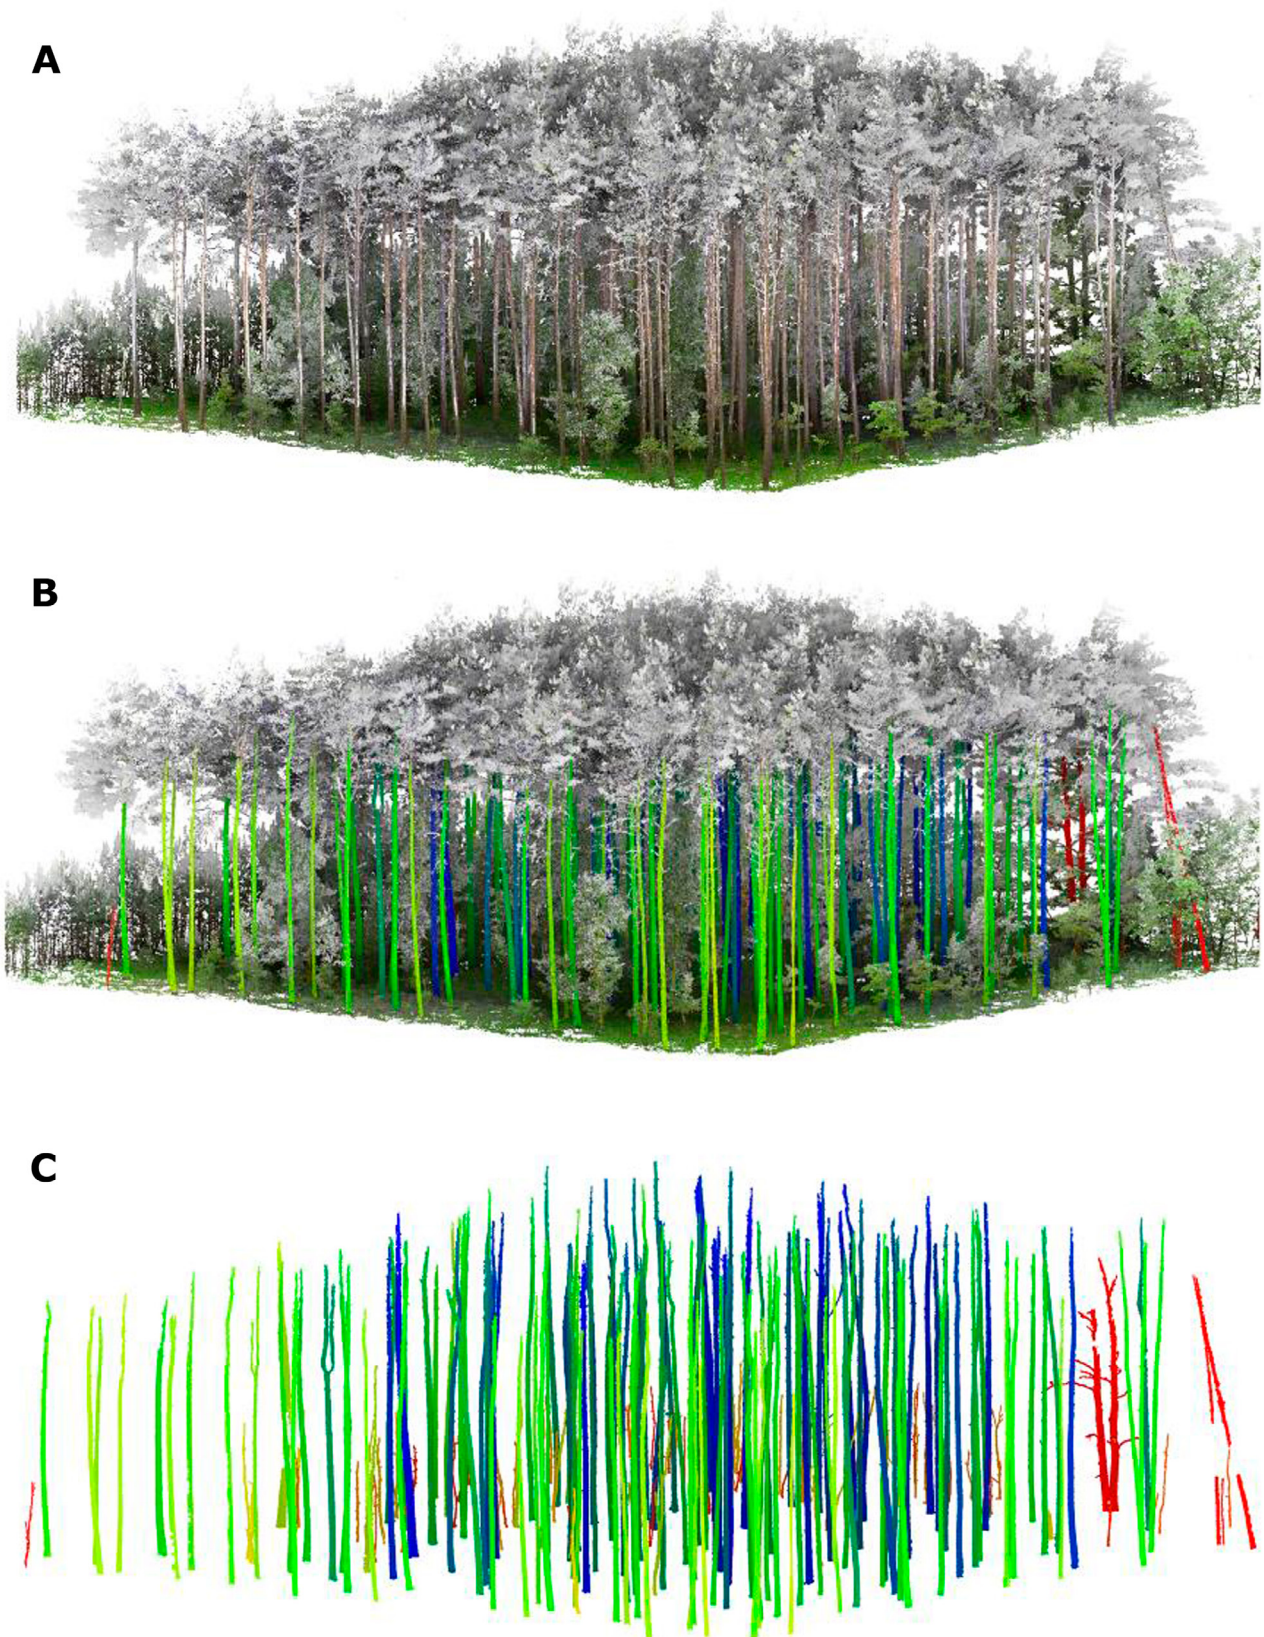
3.3. Całe drzewostany

W trybie wielostanowiskowym możliwe jest również skanowanie całych drzewostanów (ryc. 3). Metoda wykonania skanowania dla dużych powierzchni jest jednak z reguły bardziej skomplikowana, ponieważ zazwyczaj należy



Rycina 2. Chmura punktów TLS przedstawiająca pojedyncze drzewo modelowe: olszę czarną *Alnus glutinosa* Gaertn. Kolorystyka: barwy naturalne (RGB), wizualizacja została wykonana w oprogramowaniu CloudCompare (Girardeau-Montaut 2020).

Figure 2. TLS point cloud representing a single tree: Black alder *Alnus glutinosa* Gaertn. Color scheme: natural colors (RGB), visualization was made in CloudCompare software (Girardeau-Montaut 2020).



Rycina 3. Chmura punktów TLS – drzewostan sosnowy *Pinus sylvestris*. A – kolorystyka: barwy naturalne (RGB), B – kolorystyka: barwy naturalne (RGB) oraz różne kolory reprezentują automatycznie wykryte pnie, C – automatycznie wykryte pnie, wizualizacja została wykonana w oprogramowaniu CloudCompare (Girardeau-Montaut 2020).

Figure 3. TLS point cloud representing Scots pine stand *Pinus sylvestris*. A – color scheme: RGB values, B – color scheme: RGB values and different colors for automatically detected tree stems, C – automatically detected tree stems, visualization was made in CloudCompare software (Girardeau-Montaut 2020).

uwzględnić przekładanie znaczników referencyjnych wraz ze zmianą stanowisk skanowania. W celu poszerzenia wiedzy na ten temat autorzy odsyłają do pracy Wilkes et al. (2017), w której opisano doświadczenia zebrane podczas 27 kampanii terenowych, w których pozyskiwali dane TLS dla dużych powierzchni leśnych. Zalecają oni skanowanie drzewostanów, wykorzystując wcześniej zaplanowaną sieć kwadratów 10×10 metrów, gdzie każdy węzeł sieci stanowi pozycję skanera, a także rekomendują wykonanie około 120 stanowisk na drzewostan o powierzchni jednego hektara. Z doświadczeń autorów wynika, że skanowanie TLS drzewostanu o takiej powierzchni trwa od 3 do 8 dni dla grupy terenowej składającej się z trzech osób. Należy jednak zwrócić uwagę, że większość prac prowadzonych było w tropikalnych lasach deszczowych, które należą do najbardziej złożonych drzewostanów pod względem budowy pionowej. Poza tym pracochłonność zależy od wielu czynników związanych zarówno ze strukturą drzewostanu, jak i użytym typem skanera. Z doświadczeń pracowników IBL, którzy współuczestniczyli w kampanii terenowej pozyskania danych TLS dla dwóch 1-hektarowych powierzchni leśnych wynika, że w warunkach polskich drzewostanów wykonanie takich pomiarów przez grupę trzech osób dla jednej powierzchni może trwać 2–4 dni, przy założeniu wykonania ponad 100 stanowisk skanowania dla jednej powierzchni oraz wykorzystania skanerów pulsacyjnych Riegl VZ-400 lub Riegl VZ-400i, które wraz z oprogramowaniem umożliwiają łączenie skanów bez potrzeby stosowania znaczników referencyjnych podczas prac terenowych.

4. Planowanie kampanii TLS

Planowanie kampanii pomiarowej z wykorzystaniem TLS poza aspektami technicznymi, takimi jak zdefiniowanie parametrów skanowania oraz wybór odpowiedniego trybu pozyskania danych, powinno uwzględniać zewnętrzne czynniki środowiskowe.

4.1. Warunki atmosferyczne

Planując kampanię terenową TLS, należy wziąć pod uwagę panujące warunki atmosferyczne (Dassot et al. 2011; Vaaja et al. 2016). Optymalne warunki do wykonywania skanowania TLS występują podczas bezwietrznych dni bez opadów, przy umiarkowanych temperaturach oraz niedużej wilgotności powietrza. Wiatr jest czynnikiem, który może wpływać znacząco na jakość pozyskiwanych danych, szczególnie w obrębie koron drzew. Kołyszące się wierzchołki drzew podczas skanowania rejestrowane są w wielu miejscach, co prowadzi do zniekształcania obrazu górnych partii drzewostanu. Według badań Seidel i in. (2012) optymalne warunki do skanowania występują, gdy średnia prędkość wiatru nie przekracza 5 m/s. Z kolei doświadczenia Vaaja i in. (2016) wskazują, że wiatr o prędkości 9 m/s nie ma znaczącego wpływu tylko na parametry pnia w jego dolnej części (części pnia znajdującej się poniżej $\frac{1}{3}$ wysokości całkowitej drzewa).

Skanowanie TLS można przeprowadzić podczas nieznacznej opady deszczu lub gdy występuje mgła, jednakże nie jest to zalecane ze względu na gorszą jakość danych i potencjalną możliwość wystąpienia zniekształceń, tj. fałszywych odbić w pozyskiwanych danych. Nie zaleca się także skanowania, gdy występuje pokrywa śnieżna. Jest to związane z potencjalnie zalegającym na pniach śniegiem (absorbującym promienie lasera wysyłane ze skanera), który może powodować błędy przy określaniu średnicy lub objętości pni (Dassot et al. 2011).

4.2. Okres wegetacyjny

Ważnym aspektem przy planowaniu kampanii TLS jest również wybór odpowiedniego terminu skanowania. W kampaniach nastawionych na możliwe precyzyjne odwzorowanie morfologii zdrewniałych części drzew oraz na oszacowanie ich miąższości lub biomasy najlepsze terminy do wykonania skanowania to wczesna wiosna lub późna jesień. W tych okresach gatunki liściaste nie posiadają listowia, dzięki czemu efekt wzajemnego przesłaniania jest znacznie mniejszy. Pozyskanie danych w okresie bezlistnym umożliwia znacznie lepsze odwzorowanie gałęzi w koronach drzew gatunków liściastych oraz niweluje potencjalny wpływ zasłaniania dolnych części pni przez warstwę krzewów z podszytu drzewostanu. Aspekt ten ma również znaczenie w przypadku wykonywania skanowania w trybie wielostanowiskowym z użyciem sztucznych znaczników referencyjnych. W okresie bezlistnym występuje zmniejszone ryzyko zasłonięcia znacznika przez listowie z dolnego piętra.

5. Metodyka przetwarzania danych TLS

Przetwarzanie danych TLS dla potrzeb analiz dendrometrycznych drzew można podzielić na dwa główne procesy: detekcję drzew w chmurze punktów oraz tworzenie trójwymiarowych modeli pojedynczych drzew.

5.1. Detekcja drzew

W ostatnich latach powstał szereg prac dotyczących automatycznych algorytmów do detekcji drzew w chmurze punktów. Detekcję drzew należy tu rozumieć albo jako wskazanie lokalizacji drzew i ich grubości (np. pierśnicy), albo jako próbę odtworzenia całego kształtu i architektury drzew. Pierwsze algorytmy oparte były na wyszukiwaniu geometrycznych wzorców na wygenerowanych dwuwymiarowych obrazach przedstawiających przekrój horyzontalny przez drzewostan. Pierwszym etapem tych metod jest zrutowanie cienkiego poziomego wycinka trójwymiarowej chmury punktów na płaszczyznę poziomą. W następnym etapie detekcja drzew odbywa się poprzez klasteryzację grup punktów (Wężyk et al. 2007) i wyszukiwanie wzorców geometrycznych, np. okręgów (Chmielewski et al. 2010, Lindberg et al. 2012). Metody te zakładają, że kształt chmury punktów z horyzontalnego wycinka zbliżony jest do okręgu lub pół-

okręgu. Do zalet tych metod należy ich relatywna prostota i duża szybkość obliczeń. Jednakże algorytmy te napotyka- ją na pewne trudności w złożonych drzewostanach o dużym zagęszczeniu drzew lub podszytu, gdzie zmapowane punkty niezdrewniałych części pnia mogą zostać błędnie sklasyfi- kowane jako pnie (Zhang et al. 2019). Aby temu zaradzić, niektórzy badacze skoncentrowali się na bezpośredniej identyfikacji pni lub zdrewniałych komponentów drzew bezpośrednio w chmurze punktów. W pracach dotyczących różnicowania chmury punktów na zdrewniałe części pni oraz listowie autorzy wykorzystywali różne podejścia. Côté i in. (2009) założyli, że zdrewniałe komponenty drzew mają większą intensywność odbicia niż liście i ten fakt próbowali wykorzystać w klasyfikacji. Przy takim założeniu należy jed- nak zwrócić uwagę, że intensywność odbicia wiązki lasera nie jest zależna tylko od właściwości spektralnych skanowa- nych obiektów, ale również od kąta padania wiązki lasera, odległości do skanowanego obiektu czy jego szorstkości. Z kolei normalizowanie wartości intensywności odbicia jest procesem skomplikowanym i czasochłonnym (Zhang et al. 2019). Testowano również wykorzystanie dwuspektralnych skanerów laserowych (Li et al. 2013; Danson et al. 2014). Autorzy tych prac założyli, że ze względu na występujące wyraźne różnice w charakterystykach spektralnych aparatu asymilacyjnego i zdrewniałych części drzew, można je roz- różnić w dwóch pasmach spektralnych. W pracach tych nie omawiano szczegółowo dokładności klasyfikacji, jednakże prace nad rozwojem takich skanerów są cały czas w fazie te- stów, a dostępność takich urządzeń jest obecnie ograniczona.

Innym podejściem jest wykorzystanie lokalnych cech geometrycznych (ang. *geometric features*) chmury punktów. W tych metodach pierwszym etapem jest podział chmury punktów na małe podzbiory. Iteracyjnie dla każdego punktu wybierane są grupy punktów z jego najbliższego otocze- nia, definiowanego promieniem sfery lub liczbą najbliższych sąsiadów wokół punktu centralnego. Dla wybranych pod- zbiorów obliczane są cechy geometryczne przy pomocy algorytmu analizy głównych składowych (ang. *principal component analysis, PCA*) (Burt et al. 2018, Zhou et al. 2019). W pracach dotyczących detekcji pni wykorzystywano takie cechy geometryczne chmury punktów, jak: liniowość, płaskość i pionowość. Posługiwano się założeniem, że pnie drzew w chmurze punktów są z reguły obiektami pionowymi, mają charakter liniowy oraz w małej skali tworzą stosunkowo płaskie powierzchnie (Liang et al. 2012; Oloffson, Holmgren 2016). Cechy geometryczne liczone są dla każdego punktu chmury na podstawie grupy sąsiednich punktów wyznaczo- nych według parametru promienia odległości lub liczby n najbliższych sąsiadów. Wielkość wybranego podzbioru ma wpływ na rozróżnialność obiektów. Z tego względu w niektó- rych pracach wykorzystywano wiele parametrów do wyzna- czenia cech geometrycznych do klasyfikacji chmury punktów na części zdrewniałe oraz miękkie, tj. listowie. W pracach stosowano algorytmy klasyfikacji wykorzystujące m.in. tech- niki uczenia maszynowego (Vicari et al. 2019; Zhou et al. 2019). Dużą zaletą tych metod, w odróżnieniu od poprzed-

nich, jest wykorzystanie informacji geometrycznej z chmury punktów, która powinna być względnie podobna niezależnie od specyfiki użytego skanera. Jednakże należy zauważyć, że metody te wymagają większych mocy obliczeniowych.

5.2. Modelowanie drzew w 3D

Zarówno przy analizie drzew modelowych, jak i grup drzew na powierzchniach próbnych czy w całych drzewosta- nach podstawową jednostką podlegającą analizie jest geome- tryczny model pojedynczego drzewa QSM (ang. *quantitative structure model*). Model taki w swoim założeniu możliwie dokładnie odzwierciedla morfologię drzewa i jest w pełni mierzalny (Raumonen et al. 2013; Hackenberg et al. 2015). Dzięki tym cechom możliwe jest precyzyjne określenie gru- bości i miąższości nadziemnych komponentów drzewa.

Liang i in. (2016) wyróżniają pięć poziomów szczegóło- wości (ang. *level of details, LoD*) cyfrowych modeli drzew, które pozwalają na różną charakterystykę modelowanych drzew (tab. 1).

Zależnie od poziomu szczegółowości modele drzew wy- korzystuje się do różnych zadań. Na potrzeby inwentaryza- cji lasu rozpatrywane jest głównie wykorzystywanie modeli o LoD od 1 do 3 (ryc. 4).

Wykorzystanie konwencjonalnych narzędzi w tradycyj- nej inwentaryzacji lasu umożliwia pozyskanie informacji na poziomie LoD1, gdzie każde drzewo lub wybrana grupa drzew jest opisana przy pomocy dwóch podstawowych cech – wysokości i pierśnicy. Modele o LoD2 są znacznie bardziej szczegółowe ze względu na możliwość odczytania grubo- ści głównego pnia na dowolnej jego wysokości, dla której pozyskane zostały dane TLS. Dzięki takim modelom możli- wy jest bezpośredni i precyzyjny pomiar miąższości strzały. Modele LoD3 uwzględniają również konary/gałęzie, dzięki czemu pozwalają na określenie całej biomasy oraz cech architektonicznych drzew. Zbudowanie takich modeli na pod- stawie danych TLS wymaga skanowania z wielu stanowisk, co znacznie podwyższa koszty pozyskania danych. Modele o LoD 3 i 4 używane są w modelowaniu pojedynczych drzew, natomiast modele o LoD5 wykorzystywane są w gra- ficie komputerowej, przy czym obecna technologia TLS nie pozwala na pozyskanie danych szczegółowych, np. charakte- ryzujących wszystkie liście drzew (Liang et al. 2016).

W literaturze można znaleźć wiele podejść pozwalających na wytwarzanie trójwymiarowych modeli drzew z chmu- ry punktów. Najlepsze rezultaty przynoszą dwie koncepcje. Pierwsza z nich oparta jest na bezpośredniej rekonstrukcji powierzchni zewnętrznej obiektów (ang. *meshing*), której efektem jest wytworzenie trójwymiarowej, jednolitej po- wierzchni ciągłej reprezentującej wygląd drzewa. Model taki odzwierciedla kształt zewnętrzny kory oraz każdą jej nierówność, dzięki czemu pozwala na bardzo dokładne okre- ślenie miąższości drzewa (ryc. 5B, D). Według badań Dassot i in. (2012) powstały w ten sposób model może służyć jako bezwzględna referencja w pomiarach miąższości. Jednakże do zastosowania metody bezpośredniej rekonstrukcji po-

Tabela 1. Parametry charakteryzujące modele drzew dla danych poziomów szczegółowości, za Liang i in. (2016)

Table 1. Parameters characterizing tree models for given levels of detail, according to Liang et al. (2016)

Poziom szczegółowości modelu Level of details	Parametry opisujące model Parameters	Parametry z niższych poziomów Predecessor included
LoD1	wysokość / tree height pierśnica / diameter at breast height	-
LoD2	pozycja drzewa / tree position model podłużny strzały (główny pień) / 3D model of the main stem	LoD1
LoD3	gałęzie drugiego rzędu (połączone z głównym pniem) / 2 nd level branches (directly connected with the main stem)	LoD1 + LoD2
LoD4	gałęzie trzeciego rzędu (połączone z gałęziami drugiego rzędu) / 3 rd level branches (connected with the 2 nd level branches)	LoD1 + LoD2 + LoD3
LoD5	aparatus asymilacyjny / leaves najdrobniejsze gałęzie / more details of branches (higher level branches)	LoD1 + LoD2 + LoD3 + LoD4


**Rycina 4. Przedstawienie szczegółowości modeli drzew: A – chmura punktów TLS, B – model drzewa LoD1, C – model drzewa LoD2, D – model drzewa LoD3, wizualizacja została wykonana w oprogramowaniu CloudCompare (Girardeau-Montaut 2020)**

Figure 4. Presentation of details of tree models: A – TLS point cloud, B – LoD1 tree model, C – LoD2 tree model, D – LoD3 tree model, visualization was made in CloudCompare software (Girardeau-Montaut 2020)

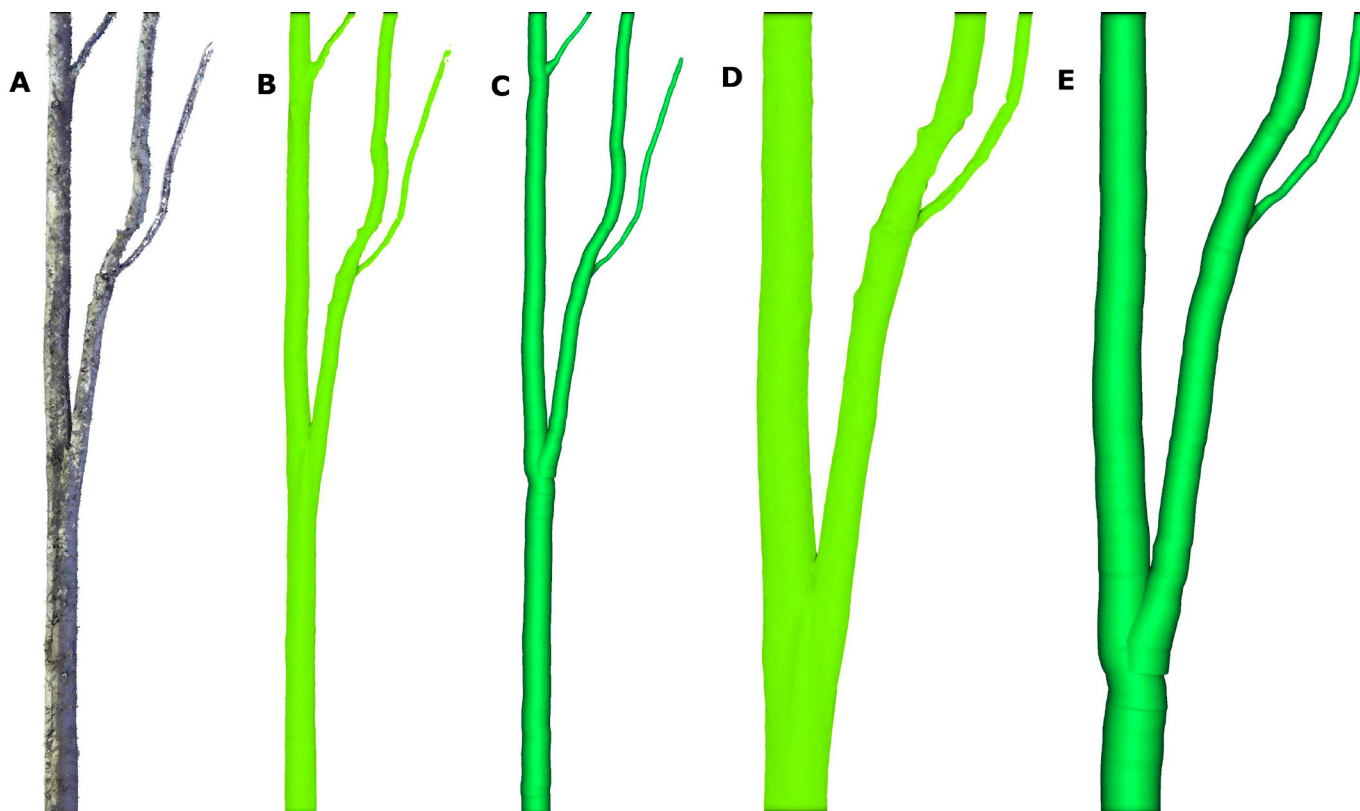
wierzchni potrzebna jest chmura punktów o bardzo wysokiej jakości i dużej gęstości, ponieważ jest ona bardzo czuła na brak ciągłości danych. Ze względu na złożoność środowiska leśnego i wzajemne przesłanianie się pni oraz gałęzi metoda ta możliwa jest do zastosowania tylko w przypadku danych pozyskanych trybem wielostanowiskowym. Należy jednak zaznaczyć, że nawet w przypadku pozyskania danych w ten sposób, pewne fragmenty drzew nie są wiernie odwzorowane, co może powodować stworzenie modelu z pewnymi brakami lub defektami. Dodatkowym minusem tej metody jest potrzeba wstępnego wyselekcjonowania punktów należących do zdrewniałych części drzew.

Drugie podejście, które jest najczęściej stosowane, polega na wpasowaniu prostych brył geometrycznych w wycinki chmury punktów reprezentujące zdrewniałe części drzew. Proces tworzenia trójwymiarowego modelu tą metodą zazwyczaj odbywa się stopniowo, od odziomka do szczytu drzewa. W wycinkach chmury punktów, reprezentujące małe fragmenty pnia lub gałęzi, iteracyjnie wpasowywane są proste, trójwymiarowe figury geometryczne, takie jak: walec, koło, elipsa lub sfera (Raumonen et al. 2013; Hackenberg et al. 2015). Finalnym efektem modelowania jest zbiór brył, które można połączyć w jedną całość. W metodach tych

często na pierwszym etapie przetworzeń budowany jest szkielet drzewa (Du et al. 2019), który pozwala na podział modelu na komponenty, tj. pojedyncze gałęzie. Metoda ta, w porównaniu do poprzedniej, tworzy w pewnym stopniu zgeneralizowany obraz drzewa (ryc. 5C, E). Jest jednak mniej czuła na braki w ciągłości danych. Stosując tę metodę, najlepsze wyniki otrzymuje się przy wykorzystaniu danych pozyskanych trybem wielostanowiskowym. Możliwe jest także stworzenie modeli głównego pnia na podstawie danych pozyskanych trybem jednostanowiskowym, ponieważ algorytmy wpasowania prostych figur geometrycznych radzą sobie z częściowo niekompletnymi danymi, interpolując ich brakującą część.

5.3. Oprogramowanie do przetwarzania danych TLS

Jak dotąd nie powstało komercyjne oprogramowanie do pracy z danymi TLS, które obejmowałoby wszystkie aspekty przetwarzania danych na potrzeby leśnictwa. Dwie firmy prowadzą prace rozwojowe nad takim oprogramowaniem – firma Treemetrics (Irlandia) rozwija oprogramowanie AutoStem (Bienert et al. 2007), natomiast firma Taxus IT (Polska) rozwija oprogramowanie tScan (Konieczny, Neroj 2016).



Rycina 5. Porównanie cyfrowych modeli drzew: A – chmura punktów TLS przedstawiająca buk pospolity, barwy naturalne (RGB); B, D – model drzewa metoda bezpośredniej rekonstrukcji; C, E – model drzewa na podstawie wpasowania cylindrów w wycinki chmury punktów, wizualizacja została wykonana w oprogramowaniu CloudCompare (Girardeau-Montaut 2020)

Figure 5. Comparison of quantitative structure models: A – TLS point cloud representing European beech in RGB colors; B, D – tree model obtained by meshing method; C, E – tree model obtained by cylinder fitting method, visualization was made in CloudCompare software (Girardeau-Montaut 2020)

Jednak w obu przypadkach nie zostały one jeszcze włączone do oferty sprzedażowej firm.

Niemniej jednak dostępnych jest kilka darmowych rozwiązań (tab. 2), stworzonych głównie przez ośrodki naukowe, które umożliwiają takie opracowanie danych TLS.

Wśród oprogramowań można znaleźć samodzielne aplikacje desktopowe oraz biblioteki ze specjalistycznymi narzędziami, które wykorzystuje się poprzez środowiska programistyczne, takie jak Matlab, R czy Python. Narzędzia te są ogólnodostępne oraz darmowe.

6. Ocena uzyskiwanych wyników oszacowania cech biometrycznych drzew przy użyciu technologii TLS

W niniejszym rozdziale przedstawiono wyniki prac, które podsumowują osiągnięte dokładności szacowania wybranych cech biometrycznych drzew. Należy przy tym zaznaczyć, że uzyskiwane wyniki zależą od wielu czynników, takich jak: struktura drzewostanu, przyjęta wielkość próby, rodzaj używanego skanera oraz zastosowana metoda przetwarzania danych. Przywoływane prace skupiają się na wynikach uzyskanych dla drzewostanów strefy umiarkowanej.

6.1. Detekcja drzew na powierzchniach próbnych

W 2018 roku międzynarodowe konsorcjum akademickie wykonało porównanie 18 algorytmów do przetwarzania danych TLS na powierzchniach próbnych (Liang et al. 2018b). W badaniach pozyskano referencyjne dane dendrometryczne oraz TLS dla 24 powierzchni w kształcie kwadratów o bokach równych 32 m. Wybrane powierzchnie reprezentowały trzy kategorie w zależności od stopnia skomplikowania struktury drzewostanu: prostą – drzewostany z dobrą widocznością pni, brakiem podszytu oraz zagęszczeniem drzew wynoszącym około 600 szt./ha, umiarkowaną – drzewostany z umiarkowaną skomplikowaną strukturą, gdzie występują pojedyncze kępy podszytu, a zagęszczenie drzew wynosi około 1000 szt./ha oraz złożoną – gdzie występuje obficie podszyt lub drugie piętro drzewostanu, a zagęszczenie drzew wynosi około 2000 szt./ha. Autorzy pracy wykonali porównanie algorytmów dla wielu cech biometrycznych drzew oraz dla dwóch trybów pozyskania danych – SS i MS.

Do oceny algorytmów detekcji drzew zaproponowano trzy wskaźniki: kompletność detekcji – wskazującą, jaka część drzew została wykryta na powierzchni próbnej, poprawność detekcji – określającą, jaka część wykrytych drzew jest poprawnie sklasyfikowana jako drzewo (algorytm może sklasyfikować jako drzewo obiekt niebędący nim), oraz średnią dokładność detekcji – będącą miarą wypadkową dwóch wcześniejszych miar.

Dane referencyjne oraz TLS z tego projektu zostały opublikowane, dzięki czemu możliwe jest porównanie nowo opracowanych algorytmów detekcji drzew (Zhang et al. 2019, Wang et al. 2020). Należy jednak zaznaczyć, że udostępnio-

no niepełny zbiór danych, tj. 6 powierzchni próbnych – po dwie dla każdej z kategorii stopnia skomplikowania struktury drzewostanu.

Poniżej przedstawiono wyniki detekcji drzew uzyskanych w projekcie (Liang et al. 2018b) oraz innych prac (Zhang et al. 2019; Wang et al. 2020) z zastosowaniem trybu jednostanowiskowego (tab. 3) oraz wielostanowiskowego (tab. 4).

Powyższe wyniki wskazują, że dokładność detekcji drzew różni się w zależności od: trybu pozyskania danych TLS wykorzystanych do analizy (SS czy MS) oraz stopnia skomplikowania struktury drzewostanu oraz jego budowy pionowej.

6.2. Pomiar pierśnicy drzew

Pierśnica jest najczęściej mierzonym i wykorzystywanym w leśnictwie parametrem biometrycznym drzew. W tabeli 5 zestawiono wybrane wyniki pomiaru pierśnicy uzyskiwane przy zastosowaniu dwóch trybów pozyskania danych TLS. W tabeli tej przedstawiono dwie miary błędów: błąd systematyczny (ang. bias), który określa, czy pomiar jest średnio przeszacowany lub niedoszacowany, oraz błąd średniokwadratowy RMSE (ang. root mean square error) mówiący o średniej wielkości błędu.

Bazując na wynikach wcześniejszych prac, można zauważyć, że zastosowanie trybu MS nie wpływa znacząco na poprawę oszacowania pierśnicy. Na podstawie powyższych wyników można przyjąć, że średni błąd określenia pierśnicy dla trybu SS wynosi 1–3 cm, z kolei dla MS – poniżej 2 cm.

Warto zaznaczyć, że wg badań prowadzonych w Finlandii w latach 90. dokładność pomiaru pierśnicy przy pomocy suwmiarki (średnicomierza) wynosiła około 0,7 cm (Hyypä et al. 2018). W powyższym doświadczeniu wykonano wielokrotnie niezależny pomiar pierśnicy dla stałej grupy drzew przez wielu taksatorów, przez co wyeliminowano potencjalny błąd systematyczny.

6.3. Pomiar wysokości drzew

Pomiar wysokości drzew przy pomocy technologii TLS jest z reguły obarczony błędem systematycznym z powodu braku dobrej widoczności szczytowych partii koron drzew. Spowodowane jest to przesłanianiem czubków drzew przez gałęzie z dolnej części korony, w efekcie czego wynik pomiaru jest z reguły niższy od faktycznej wysokości. W publikowanych pracach raportowano błędy sięgające kilku metrów (tab. 6). Wykorzystanie wielostanowiskowego trybu skanowania poprawia osiągnięte wyniki, jednakże wyniki oszacowania wysokości dalej są obciążone pewnym błędem.

6.4. Pomiar przekroju podłużnego strzały

Dzięki danym TLS można w sposób bezinwazyjny odtworzyć przekrój podłużny strzały, aplikując metody automatycznego pomiaru średnicy na wycinkach chmury punktów z różnych wysokości pnia. W przypadku zaimplementowania

Tabela 2. Darmowe oprogramowania do przetwarzania danych TLS na potrzeby leśnictwa

Table 2. Free software to TLS data processing for forestry purposes

Nazwa Name	Autor Reference	Platforma Platform	Zaimplementowane algorytmy				
			Generowanie numerycz- nego modelu terenu DTM extraction	Detekcja pni drzew Tree stem detection	Klasyfikacja chmury punktów na listowie i zdrewniale części drzew Point cloud classifi- cation into wood/leaf components	Podstawowe parametry biometryczne drzew Basic tree parameters extraction	Gene- rowanie modeli QSM QSM extraction
DendroCloud	Koreň et al. 2017	samodzielna aplikacja standalone application	+	+	-	+	-
3DForest	Trochta et al. 2017	samodzielna aplikacja standalone application	+	+	-	+	+
Computree*	Othmani et al. 2013	samodzielna aplikacja standalone application	+	+	-	+	+
SimpleFo- rest**	Hacken- berg et al. 2015	samodzielna aplikacja*** standalone applica- tion***	+	+	-	+	+
AdTree	Du et al. 2019	samodzielna aplikacja standalone application	-	-	-	+	+
SSSC	Wang et al. 2020	samodzielna aplikacja oraz Matlab standalone application and Matlab	+	+	+	-	-
TreeQSM	Raumonon et al. 2013	Matlab	-	-	-	+	+
TreeLS	de Conto et al. 2017	R	-	+	-	+	-
TLSeparation	Vicari et al. 2019	Python	-	-	+	-	-

*wielofunkcyjna platforma przeznaczona do przetwarzania danych LiDAR na potrzeby leśnictwa, posiada możliwość dodawania zewnętrznych wtyczek / a multifunctional platform designed for processing LiDAR data for forestry purposes, with the possibility of adding external plugins;

**oprogramowanie zmieniło nazwę z SimpleTree / the software has changed its name from SimpleTree;

***wtyczka do platformy Computree / the Computree platform plug-in

Tabela 3. Wyniki automatycznej detekcji drzew na powierzchniach próbnych o wielkości 32×32 m i różnym stopniu skomplikowania drzewostanów – jednostanowiskowy tryb pozyskania danych TLS (SS)

Table 3. Results of automatic tree detection on the 32×32 m sample plots at different levels of stand complexity – single-scan mode

Struktura drzewostanu Stand complexity	Miara [%] Parameter [%]	Wyniki Results	
		Liang et al. 2018b	Zhang et al. 2019
Prosta Easy	średnia dokładność mean accuracy	~88*	79
	kompletność detekcji completeness	~81*	68
	poprawność detekcji correctness	~92*	95
Umiarkowana Medium	średnia dokładność mean accuracy	~73*	57
	kompletność detekcji completeness	~70*	41
	poprawność detekcji correctness	~92*	100
Złożona Difficult	średnia dokładność mean accuracy	~48*	20
	kompletność detekcji completeness	~34*	11
	poprawność detekcji correctness	~95*	95
Średnia Mean	średnia dokładność mean accuracy	57**	52
	kompletność detekcji completeness	62**	40
	poprawność detekcji correctness	93**	97

*wynik uzyskany przez najlepszy algorytm / result achieved by the best algorithm,

**wartość średnia określona na podstawie wszystkich 18 algorytmów / mean value calculated from results based on all 18 algorithms

TLS do operacyjnego leśnictwa możliwe jest odtworzenie krzywej podłużnej dla każdego z drzew znajdujących się na powierzchni próbnej.

Należy zaznaczyć, że często nie jest możliwe odtworzenie całego pnia od odziomka do wierzchołka drzewa. Spowodowane jest to brakiem widoczności najwyższych partii pnia lub zbyt słabym jego odwzorowaniem w chmurze punktów, wynikającymi z dużej odległości od skanera (przy wysokich drzewach może to być ponad 30 metrów), co się wiąże z rzadszym próbkowaniem punktów.

Przyjmuje się, że przy pomocy TLS na powierzchniach próbnych możliwe jest odtworzenie przebiegu pni średnio do 50–70% relatywnej wysokości drzew (Liang et al. 2018b).

Należy zaznaczyć że jest to część pnia, w której zakumulowana jest zdecydowana większość miąższości drzewa.

W pracy Maas i in. (2008) porównano przekrój podłużny strzały pozyskany technologią TLS oraz przy pomocy głowicy harwestera. Uzyskano błąd średniokwadratowy na poziomie 4,7 cm w stosunku do pomiarów referencyjnych z harwestera. Autorzy zaznaczają, że błąd pomiędzy odcinkiem 0,7–7,7 metra strzały, wynosił zaledwie 1 cm. Wskazali także, że błąd na całej strzale jest większy ze względu na nietypowy (niecyldryczny) kształt dolnej części pnia oraz dużą liczbę gałęzi w górnej części pnia. Specyficzna budowa analizowanego drzewa wpłynęła negatywnie na oszacowanie średnicy.

Tabela 4. Wyniki automatycznej detekcji drzew na powierzchniach próbnych o wielkości 32×32 m i różnym stopniu skomplikowania drzewostanów – wielostanowiskowy tryb pozyskania danych TLS (MS)

Table 4. Results of automatic tree detection on the 32×32 m sample plots at different levels of stand complexity – multi-scan mode

Struktura drzewostanu Stand complexity	Miara [%] Parameter [%]	Wyniki Results		
		Liang et al. 2018b*	Zhang et al. 2019	Wang et al. 2020
Prosta Easy	średnia dokładność mean accuracy	~92*	90	90
	kompletność detekcji completeness	~90*	84	91
	poprawność detekcji correctness	~94*	97	88
Umiarkowana Medium	średnia dokładność mean accuracy	~88*	74	74
	kompletność detekcji completeness	~88*	59	78
	poprawność detekcji correctness	~89*	99	71
Złożona Difficult	średnia dokładność mean accuracy	~70*	51	63
	kompletność detekcji completeness	~66*	36	58
	poprawność detekcji correctness	~93*	96	69
Średnia Mean	średnia dokładność mean accuracy	69**	72	76
	kompletność detekcji completeness	81**	60	76
	poprawność detekcji correctness	92**	97	76

*wynik uzyskany przez najlepszy algorytm / result achieved by the best algorithm,

**wartość średnia określona na podstawie wszystkich 18 algorytmów / mean value calculated from results based on all 18 algorithms

W tabeli 7 przedstawiono zestawienie wyników osiągniętych dla określania krzywej podłużnej strzały. Została w niej umieszczona informacja o średnim podłużnym odwzorowaniu pni na powierzchniach próbnych. Wartość ta wyraża procent relatywnej wysokości drzewa, który udało się odwzorować.

6.5. Określanie miąższości drzew

Posługując się danymi TLS, możliwe jest bezpośrednio określenie miąższości pojedynczych drzew z błędem nieprzekraczającym 10%, co porównywalne jest do wyników osiągniętych przy użyciu najlepszych wzorów allometrycznych (Dassot et al. 2012; Liang et al. 2014).

W międzynarodowym porównaniu algorytmów TLS (Liang et al. 2018b), przy pozyskaniu danych trybem SS, najlepszy algorytm osiągnął błąd średniokwadratowy dla miąższości pojedynczych drzew pomiędzy 25 a 50%, oraz od 20 do 40% dla trybu MS. W badaniach tych zaproponowano miarę oceny sumarycznej miąższości drzew na powierzchni próbnej poprzez obliczenie tzw. współczynnika miąższości (ang. volume-ratio). Jest on obliczany jako iloraz miąższości drzew określanej przy pomocy TLS i miąższości referencyjnej. Autorzy raportują średni współczynnik miąższości dla powierzchni kołowych o trzech różnych strukturach: prostej – 94% dla trybu SS i 107% dla trybu MS, umiarkowanej – 87% dla trybu SS i 107% dla trybu MS oraz trudnej – 43%

Tabela 5. Wyniki automatycznego oszacowania pierśnicy na podstawie chmury punktów TLS dla dwóch trybów pozyskania danych – SS (tryb jednostanowiskowy) oraz MS (tryb wielostanowiskowy)

Table 5. Results of the automatic estimation of the diameter at the breast height based on the TLS point cloud in two data acquisition modes – SS (single-scan) and MS (multi-scan)

Autor Reference	Tryb TLS TLS mode	Gatunek Tree species	Wynik oszacowania Results	
			błąd systematyczny [cm] bias [cm]	błąd średniokwadratowy RMSE [cm] root mean square error RMSE [cm]
Pueschel et al. 2013	SS	<i>Fagus sylvatica</i> L., <i>Pseudotsuga menziesii</i> (Mirb.) Franco	-0,7	1,39–2,43
	MS		-0,55	0,66–1,21
Olofsson et al. 2014	SS	<i>Picea abies</i> (L.) H. Karst, <i>Pinus sylvestris</i> L., <i>Betula</i> spp L.	-3,1	2,3–7,4
Wang et al. 2017	SS	<i>Picea abies</i> , <i>Pinus sylvestris</i>	0,4	1,6
	MS		0,3	1,7
Koreň et al. 2017	SS	<i>Fagus sylvatica</i>	0,75	2,38
	MS		-0,37	0,77
Liang et al. 2018b	SS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula pubescens</i> Ehrh.	~ 0,0	1,0–3,0
	MS		~ 0,0	< 2,0
Pitkänen et al. 2019	MS	<i>Picea abies</i> , <i>Pinus sylvestris</i> , <i>Betula</i> spp.	0,04	0,7

Tabela 6. Wyniki automatycznego oszacowania wysokości drzew na podstawie chmury punktów TLS dla dwóch trybów pozyskania danych – SS (tryb jednostanowiskowy) oraz MS (tryb wielostanowiskowy)

Table 6. Results of the automatic estimation of the tree height based on the TLS point cloud in two data acquisition modes – SS (single-scan) and MS (multi-scan)

Autor Reference	Tryb TLS TLS mode	Gatunek Tree species	Wynik oszacowania Results	
			błąd systematyczny [m] bias [m]	błąd średniokwadratowy RMSE [m] root mean square error RMSE [m]
Wężyk et al. 2007	MS	<i>Pinus sylvestris</i> , <i>Quercus</i> spp. L., <i>Fagus sylvatica</i>	0,35–0,44	0,79–1,1
Maas et al. 2008	SS/MS	<i>Picea abies</i> , <i>Abies alba</i> Mill., <i>Fagus sylvatica</i> , <i>Larix decidua</i> Mill., <i>Pseudotsuga menziesii</i>	0,6	4,6
Olofsson et al. 2014	SS	<i>Picea abies</i> , <i>Pinus sylvestris</i> , <i>Betula</i> spp.	-0,1	4,9
Saarinen et al. 2017	SS/MS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula</i> spp.	-2,8– -1,4	1,9–3,6
Liang et al. 2018b	SS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula pubescens</i>	-2,2	2,4–7,8
	MS		< -2,2	2,8–4,7
Wang et al. 2019	MS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula</i> spp.	-1,21	1,68–2,11

Tabela 7. Wyniki automatycznego określania przekroju podłużnego strzały na podstawie chmury punktów TLS dla dwóch trybów pozyskania danych – SS (tryb jednostanowiskowy) oraz MS (tryb wielostanowiskowy)

Table 7. Results of the automatic estimation of the tree taper curve based on the TLS point cloud in two data acquisition modes – SS (single-scan) and MS (multi-scan).

Autor Reference	Tryb TLS TLS mode	Gatunek Tree species	Wynik oszacowania Results		
			podłużne odwzoro- wanie pnia [%]* percentage of the tree height covered by measurements [%]*	błąd systematyczny [cm] bias [cm]	błąd średniokwadratowy RMSE [cm] root mean square error RMSE [cm]
Maas et al. 2008	SS	<i>Picea sitchensis</i> (Bong.) Carrière	-	-	4,7
Liang et al. 2014	MS	<i>Pinus sylvestris</i> , <i>Picea abies</i>	61–66	0,15	1,13
Saarinen et al. 2017	SS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula</i> spp	38–45	-	-
	MS		58–62	-	-
Liang et al. 2018b	SS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula pubescens</i>	34–60	-0,1–0,2	1,3–6,0
	MS		56–65	0,2	0,9–5,0

*wartość średnia / mean value

dla trybu SS i 94% dla trybu MS. Wyniki te pokazują, że zarówno w trybie SS, jak i MS możliwe jest określenie miąższości na poziomie powierzchni kołowej z błędem 6–13% dla drzewostanów o strukturze prostej i umiarkowanej. Przy zastosowaniu trybu SS na powierzchniach o trudnej strukturze sumaryczna miąższość jest zaniżana o ponad 50%. Z kolei tryb MS przynosi bardzo zbliżone wyniki do danych referencyjnych (różnica na poziomie 6%).

W tabeli 8 przedstawiono wyniki szacowania miąższości pojedynczych drzew.

7. Dyskusja

Przedstawione wyniki pokazują duży potencjał wykorzystania technologii TLS w inwentaryzacji lasu. Wprowadzenie tej technologii do praktyki leśnej jest jednak procesem skomplikowanym i wymagającym czasu. Zmiana dotychczas stosowanych rozwiązań na nowe technologie musi przynieść wymierną korzyść ekonomiczną lub jakościową.

Dla inwentaryzacji lasu najważniejszymi czynnikami wpływającymi na zaadoptowanie nowej technologii pomiarów jest: dokładność określania cech dendrometrycznych, koszt technologii (zarówno urządzenia, jak i oprogramowania) oraz aspekty operacyjnego wykorzystania technologii (ograniczenie technologii, czas pozyskania danych, gabaryty urządzenia oraz potrzebne kwalifikacje taksatorów, w tym przeszkolenie ich z obsługi skanera oraz oprogramowania). Rozważając te aspekty, głównymi ograniczeniami stosowania

TLS w praktyce leśnej jest koszt technologii, brak oprogramowania oraz aspekty związane z operacyjnym wykorzystaniem tej technologii.

Mimo że cena urządzeń TLS stopniowo się obniża, koszt rzędu 100–150 tys. PLN za urządzenie jest nadal zbyt wysoki. Biorąc także pod uwagę fakt, że obecnie nie ma wielofunkcyjnego oprogramowania komercyjnego do przetwarzania danych TLS na potrzeby leśnictwa, można przypuszczać, że pierwsze, które pojawi się na rynku, będzie kosztowne. Aspekt ten przez następne lata może być główną przyczyną braku wdrożenia tej technologii do praktyki.

Uwzględniając aspekty operacyjnego wykorzystania technologii TLS w leśnictwie, najtrudniejsze jest zapewnienie detekcji wszystkich drzew na powierzchniach próbnych. Przy obecnej metodyce pomiarów na powierzchniach kołowych możliwe jest stosowanie wielostanowiskowego trybu pozyskania danych w drzewostanach o prostej strukturze. Wyniki prac pokazują, że dzięki takiej konfiguracji możliwa jest automatyczna detekcja wszystkich lub zdecydowanej większości drzew na powierzchniach próbnych. Jednakże skanowanie z kilku stanowisk znacznie wydłuża czas pracy skanera, który obecnie uznawany jest za zbyt długi. Możliwe, że nowa generacja skanerów będzie potrzebować mniej czasu do pozyskania danych, ale koszt takich urządzeń na pewno będzie początkowo relatywnie wysoki. Dodatkowo, zazwyczaj przy wykorzystaniu trybu MS potrzebne jest rozstawienie sztucznych znaczników do wzajemnego łączenia skanów. Ewentualny rozwój oraz ogólna dostępność algorytmów

Tabela 8. Wyniki automatycznego oszacowania miąższości drzew na podstawie chmury punktów TLS dla dwóch trybów pozyskania danych – SS (tryb jednostanowiskowy) oraz MS (tryb wielostanowiskowy)

Table 8. Results of the automatic estimation of the tree volume based on the TLS point cloud in two data acquisition modes – SS (single-scan) and MS (multi-scan)

Autor Reference	Tryb TLS TLS mode	Gatunek Tree species	Wynik oszacowania Results	
			błąd systema- tyczny [%] bias [%]	błąd średniokwadratowy RMSE [%] root mean square error RMSE [%]
Dassot et al. 2012	MS	<i>Quercus</i> spp., <i>Robinia pseudoaccia</i> L., <i>Alnus glutinosa</i> , <i>Fraxinus excelsior</i> L., <i>Tilia cordata</i> Mill., <i>Betula pendula</i> Roth., <i>Pinus halepensis</i> Mill.	+/-10*	-
Pueschel et al. 2013	SS	<i>Fagus sylvatica</i> , <i>Pseudotsuga menziesii</i>	-34–44*	-
	MS		-2–6*	-
Kankare et al. 2013	MS	<i>Pinus sylvestris</i> , <i>Picea abies</i>	0,67	15,34
Liang et al. 2014	MS	<i>Pinus sylvestris</i> , <i>Picea abies</i>	~ -2**	9,5
Saarinen et al. 2017	SS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula</i> spp	-0,8	12,4
	MS		4,3	8,5
Liang et al. 2018b	SS	<i>Pinus sylvestris</i> , <i>Picea abies</i> , <i>Betula</i> <i>pubescens</i>	-	~ 20–45***
	MS		-	~ 15–25***

*odchylenie od wartości referencyjnej / deviation from the reference value,

**obliczone na podstawie danych z publikacji / calculated from publication data,

***najlepszy wynik spośród 18 testowanych algorytmów w drzewostanach o różnej strukturze / the best result among 18 tested algorithms in stands with different structure

mów do automatycznego łączenia skanów bez wykorzystania znaczników na pewno będzie czynnikiem wpływającym na ewentualne wdrożenie TLS do praktyki leśnej. Do tej pory powstało kilka prac dotyczących tego zagadnienia, a algorytmy takie dostępne są na razie tylko w nielicznych oprogramowaniach komercyjnych.

Wykorzystanie danych pozyskanych w sposób jednostanowiskowy jest konkurencyjne do trybu MS, ale tylko dla drzew dobrze widocznych w chmurze punktów. Na podstawie wyników opublikowanych prac można przyjąć, że około 70% drzew jest wykrywanych na powierzchni kołowej przy zastosowaniu trybu SS. Jeżeli zostałaby opracowana metoda inwentaryzacji na podstawie tylko widocznych drzew lub metoda korekty obejmującej niewidoczne drzewa, to tryb SS byłby atrakcyjny dla praktyki leśnej ze względu na znacznie krótszy czas pozyskania danych. Do tej pory powstało niewiele prac dotyczących tego tematu i wymagane są dalsze badania. W przypadku opracowania takich metod powstałaby możliwość wykorzystania skanowania TLS w drzewostanach o bardziej skomplikowanej budo-

wie. Warto zaznaczyć, że obecne wyniki badań pokazują, że określenie niektórych sumarycznych cech drzewostanu, np. zasobności, przy zastosowaniu obu trybów pozyskania danych daje rezultaty bardzo zbliżone do danych referencyjnych dla drzewostanów o prostej i umiarkowanej strukturze, a przy wykorzystaniu trybu MS nawet dla drzewostanów o skomplikowanej budowie.

Innym potencjalnym scenariuszem jest stosowanie danych z trybu jednostanowiskowego TLS do kalibrowania metod szacowania cech taksacyjnych przy użyciu lotniczego skanowania laserowego i metod pojedynczych drzew (ang. individual tree detection – ITD). W tym podejściu wykorzystywana byłaby tylko informacja z dobrze widocznych drzew. Ten temat także wymaga badań oraz opracowania precyzyjnych metod pozwalających na łączenie danych TLS z ALS z dokładnością „drzewo do drzewa”. Oczywiście rozwiązanie to na ten moment jest też bardzo kosztowne.

Problem zasłoniętych drzew możliwy jest do rozwiązania przy pomocy mobilnych skanerów laserowych (ang. mobile

laser scanning, MLS). Dzięki wykorzystaniu tej ciągle rozwijającej się technologii, możliwe jest takie zaprojektowanie trajektorii przejścia po powierzchni próbnej, która pozwoli na zmapowanie wszystkich drzew. Wykorzystanie naziemnych technik teledetekcyjnych takich jak wielostanowiskowe TLS lub MLS pozwala również rozważać zwiększenie rozmiaru powierzchni próbnych, co może być dodatkowym atutem w inwentaryzacji lasu.

Warto odnotować premierę nowej wersji flagowego produktu firmy Apple. Firma ta w marcu 2020 roku rozpoczęła sprzedaż nowej wersji tabletu iPad Pro. Jedną z innowacji nowej wersji urządzenia jest wbudowany czujnik LiDAR. Według specyfikacji producenta zasięg sensora wynosi do 5 metrów, pozwalając na trójwymiarowe zrekonstruowanie najbliższego otoczenia (Apple Inc. 2020). Cena urządzenia w podstawowej wersji to obecnie około 3900 PLN. Aktualnie nie ma jeszcze opublikowanych prac na temat wykorzystania tego tabletu w badaniach leśnych, jednakże można spodziewać się, że wkrótce takie powstaną i mogą zainteresować praktykę leśną.

Biorąc pod uwagę ciągły rozwój technologii LiDAR, można przypuszczać, że w perspektywie następnych kilkunastu lat zostaną opracowane skanery laserowe, które pozwolą na wielkopowierzchniowe mapowanie pni drzew z pułapu lotniczego. Zakładając taki kierunek rozwoju technologicznego, możliwe będą bezpośrednie pomiary cech dendrometrycznych pojedynczych drzew bez potrzeby pomiarów naziemnych oraz modelowania statystycznego. Można przypuszczać, że opracowane algorytmy do przetwarzania danych TLS mogłyby być użyte bezpośrednio na nowym typie danych.

8. Wnioski

1. W przeciągu ostatnich 20 lat nastąpił znaczący rozwój algorytmów przetwarzania danych TLS na potrzeby inwentaryzacji lasu.

2. Technologia TLS może być wykorzystywana do bezinwazyjnych pomiarów dendrometrycznych drzew i drzewostanów, z dokładnością oszacowania większości parametrów porównywalną do tradycyjnych metod pomiarowych stosowanych aktualnie w leśnictwie.

3. Najlepszym terminem do pozyskania danych TLS w celu inwentaryzacji lasu jest wczesna wiosna lub późna jesień (szczególnie w drzewostanach liściastych lub z udziałem gatunków liściastych w podszyciu). Skanowanie najlepiej wykonać przy bezwietrznej pogodzie oraz niskiej wilgotności powietrza.

4. Lepsze wyniki oszacowania cech biometrycznych drzew można uzyskać stosując wielostanowiskowy tryb pozyskania danych, jednakże wykonanie pomiarów tym trybem jest znacznie bardziej czasochłonne w porównaniu do trybu jednostanowiskowego.

5. Tryb pozyskania danych TLS oraz struktura drzewostanu mają duży wpływ na detekcje drzew oraz dokładność określania ich cech biometrycznych.

6. Przy zastosowaniu technologii TLS możliwy jest bezinwazyjny pomiar przekroju podłużnego strzały drzew stojących do ok 60–70% relatywnej wysokości drzew.

7. Pomiar wysokości drzew jest obarczony stosunkowo dużym błędem systematycznym spowodowanym tzw. efektem przysłaniania – wierzchołek drzewa zasłaniany jest przez dolną część korony.

8. Istnieje potrzeba dalszych badań nad wykorzystaniem technologii TLS w inwentaryzacji lasu oraz utworzenia zbioru tzw. „dobrych praktyk” i instrukcji, jak wykonywać i przetwarzać dane TLS, uwzględniając różne warianty ich pozyskania.

Konflikt interesów

Autorzy deklarują brak potencjalnych konfliktów.

Źródło finansowania

Publikacja powstała w ramach projektu REMBIOFOR „Teledetekcyjne określanie biomasy drzewnej i zasobów węgla w lasach” współfinansowanego ze środków Narodowego Centrum Badań i Rozwoju w ramach programu „Środowisko naturalne, rolnictwo i leśnictwo” BIOSTRATEG na podstawie umowy nr BIOSTRATEG1/267755/4/NCBR/2015.

Literatura

- Apple Inc. 2020. Apple unveils new iPad Pro with breakthrough LiDAR Scanner and brings trackpad support to iPadOS, Apple Inc. <https://www.apple.com/pl/newsroom/2020/03/apple-unveils-new-ipad-pro-with-lidar-scanner-and-trackpad-support-in-ipados/> [20.09.2020].
- Aschoff T., Spiecker H. 2004. Algorithms for the automatic detection of trees in laser scanner data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36(8) / W2: 71–75.
- Astrup R., Ducey M., Granhus A., Ritter T., von Lüpke N. 2014. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. *Canadian Journal for Forest Research* 44(6): 666–676. DOI 10.1139/cjfr-2013-0535.
- Będkowski K. 2004. Skanowanie laserowe i jego zastosowanie w leśnictwie. *Roczniki Geomatyki* 4: 33–40.
- Będkowski K., Adamczyk 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, 213 s. ISBN 978-83-7583-335-5.
- Bienert A., Scheller S., Keane E., Mohan F., Nugent C. 2007. Tree detection and diameter estimations by analysis of forest terrestrial laserscanner point clouds, in: Proceedings of the ISPRS Workshop 'Laser Scanning 2007 and SilviLaser 2007' (ed. P. Rönholm, H. Hyyppä, J. Hyyppä), 12–14.09.2007, Espoo, Finland. 12–14.09.2007. *IAPRS* 36(3) / W52, 50–55.
- Brolly G., Kiraly G. 2009. Algorithms for stem mapping by means of terrestrial laser scanning. *Acta Silvatica et Lignaria Hungarica* 5: 119–130.

- Burt A, Disney M, Calders K. 2018. Extracting individual trees from lidar point clouds using *treeseg*. *Methods in Ecology and Evolution* 10(3): 438–445. DOI 10.1111/2041-210X.13121.
- de Conto T., Olofsson K., Görgens E.B., Rodriguez L.C.E., Almeida G. 2017. Performance of stem denoising and stem modelling algorithms on single tree point clouds from terrestrial laser scanning. *Computers and Electronics in Agriculture* 143: 165–176. DOI 10.1016/j.compag.2017.10.019.
- Chirrek M., Wencel A., Strzeliński P., Zasada M., Zawila-Niedzwiecki T. 2007. Wykorzystanie technologii naziemnego skaningu laserowego w inwentaryzacji lasu. *Roczniki Geomatyki* 5(5): 19–24.
- Chmielewski L., Bator M., Zasada M., Stereńczak K., Strzeliński P. 2010. Fuzzy Hough transform-based methods for extraction and measurements of single trees in large-volume 3D terrestrial LIDAR data, in: L. Bolc, R. Tadeusiewicz, L.J. Chmielewski, K. Wojciechowski (red.) *Computer Vision and Graphics*, 265–274. DOI 10.1007/978-3-642-15910-7_30.
- Côté J.F., Widlowski J.L., Fournier R.A., Verstraete M.M. 2009. The structural and radiative consistency of three-dimensional tree reconstructions from terrestrial lidar. *Remote Sensing of Environment* 113(5): 1067–1081. DOI 10.1016/j.rse.2009.01.017.
- Danson F.M., Gaulton R., Armitage R.P., Disney M., Gunawan O., Lewis P., Pearson G., Ramirez A.F. 2014. Developing a dual-wavelength full-waveform terrestrial laser scanner to characterize forest canopy structure. *Agricultural and Forest Meteorology* 198: 7–14. DOI 10.1016/j.agrformet.2014.07.007.
- Dassot M., Constant T., Fournier M., 2011. The use of terrestrial LiDAR technology in forest science: application fields, benefits and challenges. *Annals of Forest Science* 68: 959–974. DOI 10.1007/s13595-011-0102-2.
- Dassot M., Colin A., Santenoise P., Fournier M., Constant T. 2012. Terrestrial laserscanning for measuring the solid wood volume, including branches, of adult standing trees in the forest environment. *Computers and Electronics in Agriculture* 89: 86–93. DOI 10.1016/j.compag.2012.08.005.
- Girardeau-Montaut D. 2020. CloudCompare – 3D Point Cloud and Mesh Processing Software (Version 2.11.3). GPL Softw. 2020. <http://www.cloudcompare.org/> [14.10.2020].
- Hackenberg J., Spiecker H., Calders K., Disney M., Raunonen P. 2015. SimpleTree – An efficient open source tool to build tree models from TLS clouds. *Forests* 6(11): 4245–4294. DOI 10.3390/f6114245.
- 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. DOI 10.26202/sylwan.2017066.
- Henning J., Radtke P., 2006. Detailed Stem Measurements of Standing Trees from Ground-Based Scanning Lidar. *Forest Science* 52(1): 67–80. DOI 10.1093/forestscience/52.1.67.
- Hyypä J., Virtanen J.-P., Jaakkola A., Yu X., Hyypä H., Liang X. 2018. Feasibility of Google Tango and Kinect for Crowdsourcing Forestry Information. *Forests* 9(1): 6. DOI 10.3390/f9010006.
- Kangas A., Astrup R., Breidenbach J., Fridman J., Gobakken T., Korhonen K., Maltamo M., Nilsson M., Nord-Larsen T., Næsset E., Olsson H. 2018. Remote sensing and forest inventories in Nordic countries – roadmap for the future. *Scandinavian Journal of Forest Research* 33(4): 397–412. DOI 10.1080/02827581.2017.1416666.
- Kankare V., Holopainen M., Vastaranta M., Puttonen E., Yu X., Hyypä J., Vaaja M., Hyypä H., Alho P. 2013. Individual tree biomass estimation using terrestrial laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing* 75: 64–75. DOI 10.1016/j.isprsjprs.2012.10.003.
- Konieczny A., Neroj B. 2016. Projekt działania programu do obliczania miąższości drzew na podstawie danych skanowania naziemnego (TLS), prezentacja z „Narada Koordynatorów SIP”, Zakopane, 23–25.02.2016 r. <https://www.geomatyka.lasy.gov.pl/documents/25999395/0/Konieczny-TLS.pdf/b13219cc-1608-4004-8692-2de4d0d44a5e> [12.11.2020].
- Koreň M., Mokroš M., Bucha T. 2017. Accuracy of tree diameter estimation from terrestrial laser scanning by circle-fitting methods. *International Journal of Applied Earth Observation and Geoinformation* 63: 122–218. DOI 10.1016/j.jag.2017.07.015.
- Li Z., Douglas E., Strahler A., Schaaf C., Yang X., Wang Z., Yao T., Zhao F., Saenz E.J., Paynter I. 2013. Separating leaves from trunks and branches with dual-wavelength terrestrial LiDAR scanning, in: *Proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Melbourne, VIC, Australia, 21–26 July 2013, 3383–3386. DOI 10.1109/IGARSS.2013.6723554.
- Liang X., Litkey P., Hyypä J., Kaartinen H., Vastaranta M., Holopainen M. 2012. Automatic stem mapping using single-scan terrestrial laser scanning. *IEEE Transactions on Geoscience and Remote Sensing* 50: 661–670. DOI 10.1109/TGRS.2011.2161613.
- Liang X., Kankare V., Yu X., Hyypä J., Holopainen M. 2014. Automated stem curve measurement using terrestrial laser scanning. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3): 1739–1748. DOI 10.1109/TGRS.2013.2253783.
- Liang X., Kankare V., Hyypä J., Wang Y., Kukko A., Haggrén H., Yu X., Kaartinen H., Jaakkola A., Guan F., Holopainen M., Vastaranta M. 2016. Terrestrial laser scanning in forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing* 115: 63–77. DOI 10.1016/j.isprsjprs.2016.01.006.
- Liang X., Kukko A., Hyypä J., Lehtomäki M., Pyörälä J., Yu X., Kaartinen H., Jaakkola A., Wang Y. 2018a. In-situ measurements from mobile platforms: An emerging approach to address the old challenges associated with forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing* 143: 97–107. DOI 10.1016/j.isprsjprs.2018.04.019.
- Liang X., Hyypä J., Kaartinen H., Lehtomäki M., Pyörälä J., Pfeifer N., Holopainen M., Brolly G., Francesco P., Hackenberg J., Huang H., Jo H-W., Kato M., Liu L., Mokroš M., Morel J., Olofsson K., Poveda-Lopez J., Trochta J., Wang D., Wang J., Xi Z., Yang B., Zheng G., Kankare V., Luoma V., Yu X., Chen L., Vastaranta M., Saarinen N., Wang Y. 2018b. International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing* 144: 137–179. DOI 10.1016/j.isprsjprs.2018.06.021.
- Lindberg E., Holmgren J., Olofsson K., Olsson H. 2012. Estimation of stem attributes using a combination of terrestrial and airborne laser scanning. *European Journal of Forest Research* 131: 1917–1931. DOI 10.1007/s10342-012-0642-5.
- Maas H., Bienert A., Scheller S., Keane E. 2008. Automatic forest inventory parameter determination from terrestrial laser scanner data. *International Journal of Remote Sensing* 29(5): 1579–1593. DOI 10.1080/01431160701736406.
- Næsset E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field

- data. *Remote Sensing of Environment* 80: 88–99. DOI 10.1016/S0034-4257(01)00290-5.
- Olofsson K., Holmgren J., Olsson H. 2014. Tree stem and height measurements using terrestrial laser scanning and the RAN-SAC algorithm. *Remote Sensing* 6: 4323–4344. DOI 10.3390/rs6054323.
- Olofsson K., Holmgren J. 2016. Single Tree stem profile detection using terrestrial laser scanner data, flatness saliency features and curvature properties. *Forests* 7: 207. DOI 10.3390/f7090207.
- Pitkänen T.P., Raunonen P., Kangas A. 2019. Measuring stem diameters with TLS in boreal forests by complementary fitting procedure. *ISPRS Journal of Photogrammetry and Remote Sensing* 147: 294–306. DOI 10.1016/j.isprsjprs.2018.11.027.
- Pueschel P., Newnham G., Rock G., Udelhoven T., Werner W., Hill J. 2013. The influence of scan mode and circle fitting on tree stem detection, stem diameter and volume extraction from terrestrial laser scans. *ISPRS Journal of Photogrammetry and Remote Sensing* 77: 44–56. DOI 10.1016/j.isprsjprs.2012.12.001.
- Raunonen P., Kaasalainen M., Åkerblom M., Kaasalainen S., Karttinen H., Vastaranta M., Holopainen M., Disney M., Lewis P. 2013. Fast automatic precision tree models from terrestrial laser scanner data. *Remote Sensing* 5: 491–520. DOI 10.3390/rs5020491.
- Ratajczak M., Wężyk P. 2015. Automatyczne określanie średnicy pnia, podstawy korony oraz wysokości sosny zwyczajnej (*Pinus silvestris* L.) na podstawie analiz chmur punktów 3D pochodzących z wielostanowiskowego naziemnego skanowania laserowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 27: 123–138. DOI 10.14681/afkit.2015.009.
- Riegl 2020. Riegl VZ-400i. Riegl Laser Measurement System GmbH, Austria. http://www.riegl.com/uploads/tx_pxpriegldownloads/RIEGL_VZ-400i_Datasheet_2020-10-06 [20.10.2020].
- Seidel D., Fleck S., Leuschner C. 2012. Analyzing forest canopies with ground-based laser scanning: A comparison with hemispherical photography. *Agricultural and Forest Meteorology* 154–155: 1–8. DOI 10.1016/j.agrformet.2011.10.006.
- Stereńczak K. 2010. Technologia lotniczego skanowania laserowego jako źródło danych w półautomatycznej inwentaryzacji lasu. *Sylwan* 154(2): 88–99. DOI 10.26202/sylwan.2009041.
- Stereńczak K., Lisańczuk M., Parkitna K., Mitelsztedt K., Mroczek P., Miścicki S. 2018. The influence of number and size of sample plots on modelling growing stock volume based on airborne laser scanning. *Drewno* 61(201): 5–22. DOI 10.12841/wood.1644-3985.D11.04.
- Tanaka T., Yamaguchi J., Takeda Y. 1998. Measurement of forest canopy structure with a laser plane range-finding method – Development of a measurement system and applications to real forests. *Agricultural and Forest Meteorology* 91: 149–160.
- Tompalski P. 2009. Naziemny skaning laserowy w inwentaryzacji zieleni miejskiej na przykładzie Plant w Krakowie. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 20: 421–431.
- Trochta J., Krůček M., Vrška T., Král K. 2017. 3D Forest: An application for descriptions of three-dimensional forest structures using terrestrial LiDAR. *Plos One* 12: e0176871. DOI 10.1371/journal.pone.0176871.
- Vaaja M.T., Virtanen J.P., Kurkela M., Lehtola V., Hyypä J., Hyypä H. 2016. The effect of wind on tree stem parameter estimation using terrestrial laser scanning. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* III-8: 117–122. DOI 10.5194/isprs-annals-III-8-117-2016.
- Vicari M.B., Disney M., Wilkes P., Burt A., Calders K., Woodgate W. 2019. Leaf and wood classification framework for terrestrial LiDAR point clouds. *Methods in Ecology and Evolution* 10(5): 1–15. DOI 10.1111/2041-210X.13144.
- Wang D., Kankare V., Puttonen E., Hollaus M., Pfeifer N. 2017. Reconstructing stem cross section shapes from terrestrial laser scanning. *IEEE Geoscience and Remote Sensing Letters* 14: 272–276. DOI 10.1109/LGRS.2016.2638738.
- Wang D. 2020. Unsupervised semantic and instance segmentation of forest point clouds, *ISPRS Journal of Photogrammetry and Remote Sensing* 165: 86–97. DOI 10.1016/j.isprsjprs.2020.04.020.
- Wang Y., Lehtomäki M., Liang X., Pyörälä J., Kukko A., Jaakkola A., Liu J., Feng Z., Chen R., Hyypä J. 2019. Is field-measured tree height as reliable as believed – A comparison study of tree height estimates from field measurement, airborne laser scanning and terrestrial laser scanning in a boreal forest. *ISPRS Journal of Photogrammetry and Remote Sensing* 147: 132–145. DOI 10.1016/j.isprsjprs.2018.11.008.
- Wężyk P. 2006. Wprowadzenie do technologii skaningu laserowego w leśnictwie. *Roczniki Geomatyki* 4 (4): 119–132.
- Wężyk P. 2010. Naziemny skaning laserowy, w: *Geomatyka w Lasach Państwowych – Część I. Podstawy*. Centrum Informacyjne Lasów Państwowych, Warszawa, 343–357. ISBN 978-83-61633-01-3.
- Wężyk P., Kozioł K., Glista M., Pierzchalski M. 2007. Terrestrial laser scanning versus traditional forest inventory. first results from the Polish forests, in: *Proceedings of the ISPRS Workshop 'Laser Scanning 2007 and SilviLaser 2007'* (ed. P. Rönnholm, H. Hyypä, J. Hyypä), 12–14.09.2007, Espoo, Finland. IAPRS 36, 3 / W52, 424–429.
- Wężyk P., Sroga R. 2010. Naziemny skaning laserowy w inwentaryzacji miąższości drzewostanów sosnowych. *Roczniki Geomatyki* 8, 7(43): 63–73.
- Wężyk P., Szostak M., Zięba K., Rysiak P., Hawryło P., Ratajczak M. 2015. Preliminary results of the monumental tree monitoring based on terrestrial laser scanning – a case study of the Oak Bartek in Zagnańsk (Poland). *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 27: 185–200. DOI 10.14681/afkit.2015.014.
- White J., Wulder M., Varhola, A., Vastaranta M., Coops N., Cook B., Pitt D., Woods M. 2013. A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach. Information report FI-X-010, Natural Resources Canada, Canadian Forest Service, Canadian Wood Fibre Centre. DOI 10.5558/tfc2013-132.
- White J., Coops N., Wulder M., Vastaranta M., Hilker T., Tompalski P. 2016. Remote sensing technologies for enhancing forest inventories: A review. *Canadian Journal of Remote Sensing* 42(5): 619–641. DOI 10.1080/07038992.2016.1207484.
- Wilkes P., Lau A., Disney M., Calders K., Burt A., de Tanago J., Bartholomeus H., Brede B., Herold M. 2017. Data acquisition considerations for Terrestrial Laser Scanning of forest plots. *Remote Sensing of Environment* 196: 140–153. DOI 10.1016/j.rse.2017.04.030.
- Zasada M., Stereńczak K. 2013. Dokładność określania wybranych parametrów rozkładów pierśnic drzew w drzewostanach sosnowych za pomocą naziemnego skanowania laserowego. *Sylwan* 157(12): 883–891. DOI 10.26202/sylwan.2013084.
- Zasada M., Stereńczak K., Dudek W., Rybski A. 2013. Horizon visibility and accuracy of stocking determination on circular

- sample plots using automated remote measurement techniques. *Forest Ecology and Management* 302: 171–177. DOI 10.1016/j.foreco.2013.03.041.
- Zawiła-Niedźwiecki T., Stereńczak K., Bałazy R., Węcel A., Strze-
liński P., Zasada M. 2008. The use of terrestrial and airborne
lidar technology in forest inventory. *Ambiencja* 4: 57–68.
- Zhang W., Wan P., Wang T., Cai S., Chen Y. 2019. A novel approach
for the detection of standing tree stems from plot-level terrestrial
laser scanning data. *Remote Sensing* 11(2): 211. DOI 10.3390/
rs11020211.
- Zhou J., Wei H., Zhou G., Song L. 2019. Separating leaf and wood
points in terrestrial laser scanning data using multiple optimal
scales. *Sensors* 19: 1852. DOI 10.3390/s19081852.

Wkład autorów

G.K. – koncepcja, napisanie manuskryptu, przegląd litera-
tury, przygotowanie grafik i tabel, korekta; B.K. – koncepcja,
korekta; K.S. – koncepcja, korekta.