


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 obiektywizm.

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, recenzowano: 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 potrzebnej 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 dobrana 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.

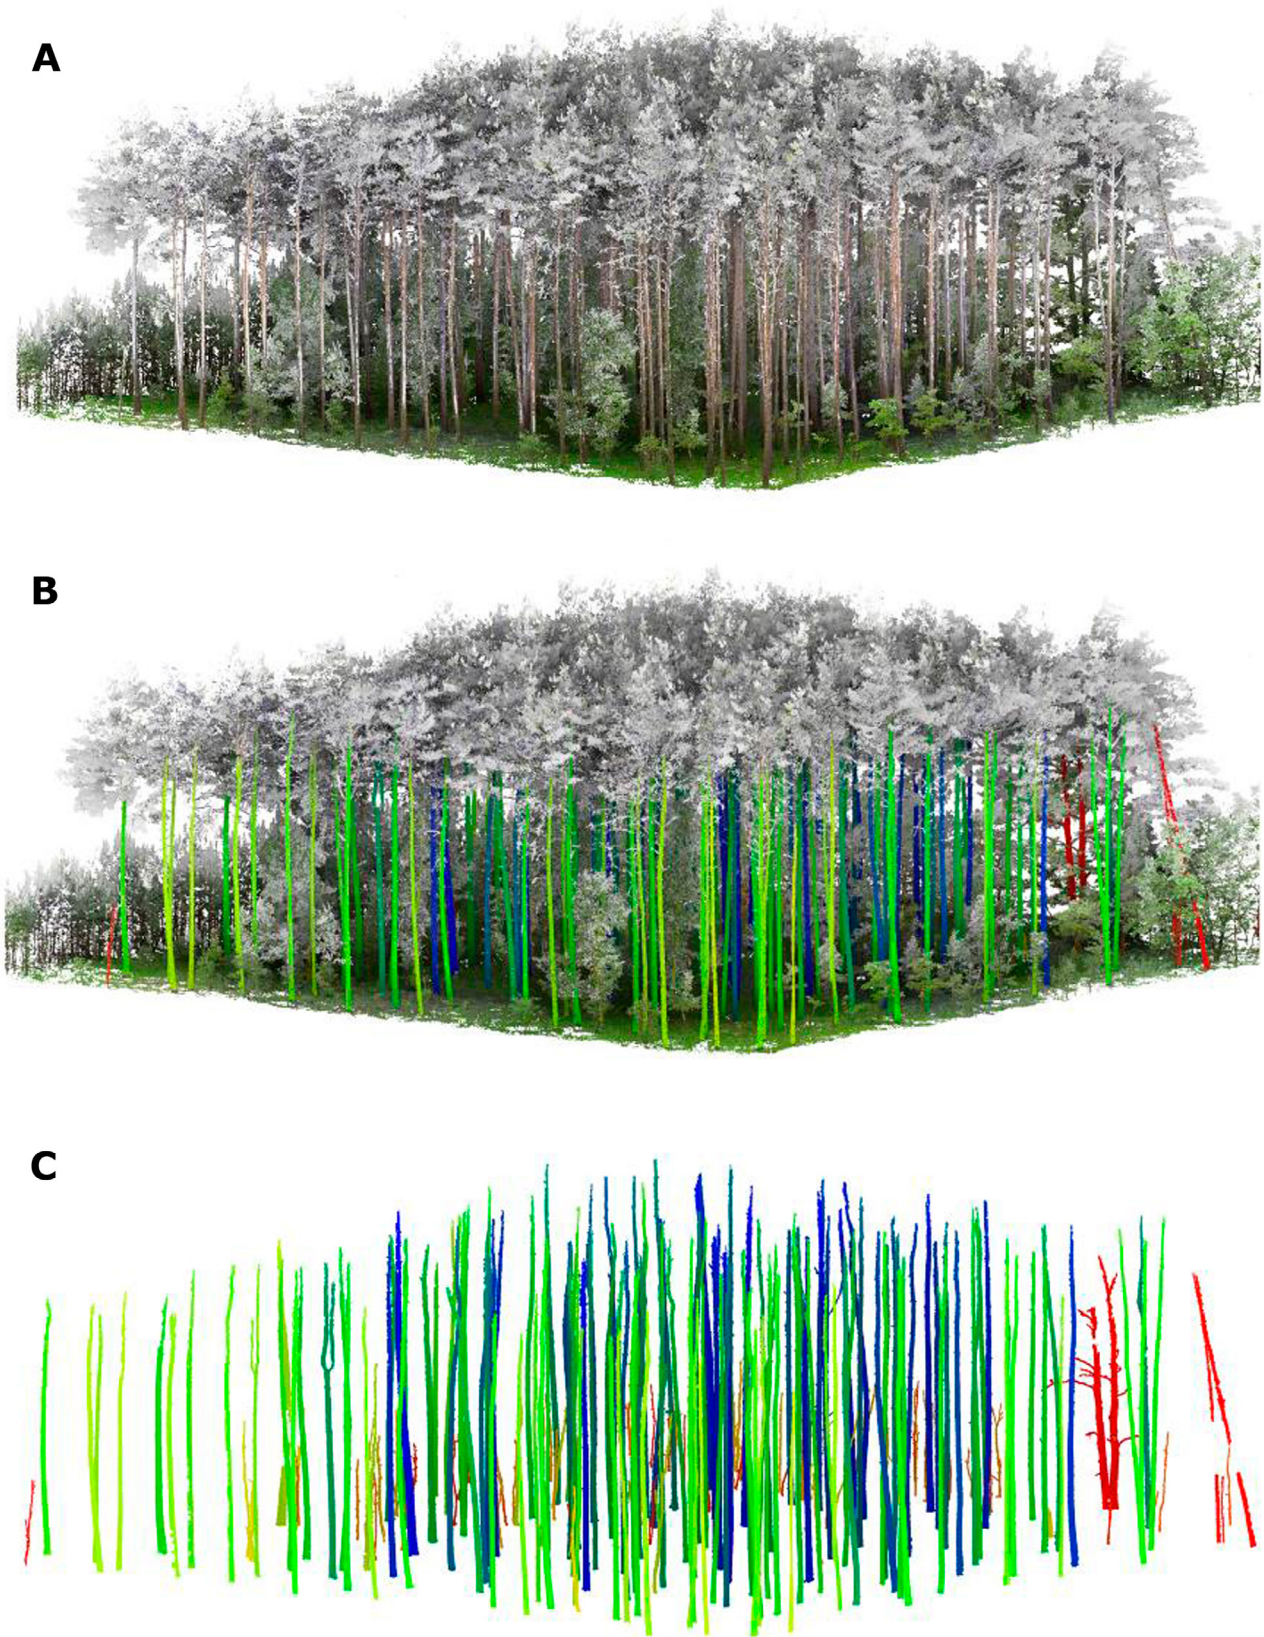
3.3. Całe drzewostany

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 nieznaczego opadu 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 miąższności 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., Karaszewicz 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., Katoh 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 skanowanie 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 skanowanie 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. Rönholm, H. Hyypä, J. Hyypä), 12–14.09.2007, Espoo, Finland. IAPRS 36, 3 / W52, 424–429.
- Wężyk P., Sroga R. 2010. Naziemny skanowanie 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 określenia 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., Strześliński 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 literatury, przygotowanie grafik i tabel, korekta; B.K. – koncepcja, korekta; K.S. – koncepcja, korekta.

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

Grzegorz Krok*, Bartłomiej Kraszewski, Krzysztof Stereńczak

Forest Research Institute, Department of Geomatics, Braci Leśnej 3 St., Sękocin Stary, 05–090 Raszyn, Poland

*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

1. Introduction

The precise determination of forest resources is one of the most important tasks of sustainable forest management. Accurate information on resources enables planning of current and future economic and conservation activities. This knowledge is also needed for the implementation of sustainable forest management policies. Depending on the purpose, availability of financial resources and required accuracy, many methods of forest inventory are distinguished. Because of the high cost and time involved in field work, foresters often use statistical and mathematical methods based on measurements on circular sample plots. Field crews typically measure characteristics such as diameter at breast height (DBH) and tree height, and determine the species and location of each tree relative to the centre of the sample plot. The time-consuming nature of field work with conventional tools (e.g. tree callipers, compass, altimeter) is driving the search for new, alterna-

tive solutions that reduce the cost and labour intensity of inventory and increase its objectivity.

In recent years, a number of scientific papers have been published on the use of remote sensing technologies for forest inventories, in particular Light Detection and Ranging (LiDAR) technology. The product of this technology is a three-dimensional image of reality, consisting of millions of points that form a 'point cloud'. This allows precise measurement of the dimensions and structure of scanned objects (Będkowski 2004; Wężyk 2006). Laser scanners are integrated with different types of platforms, e.g. aerial platform – airborne laser scanning (ALS) or stationary survey tripod – terrestrial laser scanning (TLS). In forest management, due to the vastness of forest areas, data collection by ALS technology is most often considered, as it provides data for entire forest areas in a short period of time (Wężyk 2006; Stereńczak 2010; Będkowski et al. 2011). Many papers have been written on 'enhanced forest inventories' that use ALS data together with field measure-

Received: 25.10.2020 r., accepted after revision: 16.11.2020 r.

ments to estimate stand characteristics of individual forest compartments with high accuracy (White et al. 2016). In some countries, ALS forest inventory methods are used in forestry practice, e.g. Norway, Finland, Denmark and Sweden (Kangas et al. 2018). The most commonly used forest inventory method using ALS data is the 'area-based approach' (ABA), which uses relationships between point cloud characteristics and ground measurements using statistical methods (Næsset 2002; White et al. 2013; Hawryło 2017). This method allows the development of a predictive model for each surveyed stand characteristic determined from field measurements. Once the mathematical models have been developed, the final step is to apply them to the entire scanned area.

ALS makes it possible to obtain data for vast areas quickly and with relatively little effort. Moreover, the use of ALS together with the field data requires a smaller number of sample plots compared to the traditional statistical and mathematical method, while maintaining the assumed precision of the estimates (Stereńczak et al. 2018). However, it should be emphasised that this method requires some field measurements to calibrate the statistical model, as woody parts of vegetation, including stems, cannot be directly observed using ALS technology (White et al. 2016).

A complementary data source for airborne measurements is TLS data. TLS data represent the image of a stand as seen from the ground beneath the tree canopy. The result of using TLS is a very dense point cloud with measurement accuracy in millimetres (Zawiła-Niedźwiecki et al. 2008, Wężyk 2010). Therefore, this technology is considered the most accurate source of remote sensing data for sample plots (Liang et al. 2018a). An additional advantage of using TLS is the automated and very fast way of obtaining data.

The use of TLS in forestry has a relatively short history. The first terrestrial laser scanner was introduced in 1998 (Liang et al. 2016). Pioneering scientific work on the use of TLS in forestry took place at the turn of the 20th and 21st centuries (Tanaka et al. 1998; Aschoff, Spiecker 2004; Henning, Radtke 2006). The main impetus for the use of TLS in forestry was initially to improve field work on sample plots by replacing some of the manual measurements. Early work addressed automatic or semi-automatic solutions based on TLS data aimed at measuring basic biometric characteristics of trees, such as DBH, height and location (Maas et al. 2008; Brolly, Kiraly 2009). With the increasing computational power of computers and the development of data processing algorithms, new opportunities arose for the use of TLS data. They have become a valuable source of information,

allowing for the automatic measurement of biometric traits that previously could not be measured directly using traditional forest inventory methods. Many papers have been published on methods for automatically determining tree volume and biomass based on TLS data, in which authors report accuracy comparable to the best national allometric equations (Astrup et al. 2014; Liang et al. 2014). The potential of this technology has also been recognised in forest ecology research. The suitability of TLS has been demonstrated for determining LAI (leaf area index) and studying the dynamics of changes in stand gaps and crown structure (Liang et al. 2016).

Polish scientific centres have also been studying the use of TLS in forestry for several years. These studies mainly concern forest inventory issues (Chirrek et al. 2007; Wężyk et al. 2007; Chmielewski et al. 2010; Wężyk, Sroga 2010; Zasada et al. 2013; Ratajczak, Wężyk 2015), but also such as determination of DBH distribution (Zasada, Stereńczak 2013), urban greenery inventory (Tompalski 2009) and monitoring the condition of natural monument trees (Wężyk et al. 2015).

This paper is a synthetic review of research on the use of TLS technology conducted in temperate tree stands for about 20 years. In this paper, the authors focused particularly on the practical aspects of using TLS technology for forest inventory and on summarising the achieved measurement accuracy of the main biometric characteristics of trees. In the Discussion section, the authors evaluate the possibility of introducing this technology into forestry practice.

2. How TLS works and types of scanners

TLS scanners work by measuring the distance and the horizontal and vertical angle between the device and the object under investigation using light beams (lasers) emitted by the device.

TLS measurements are made from a stationary position in designated locations, with the scanner placed on a survey tripod. During operation, the scanner registers the image of the surroundings, rotating around its own axis. The measurements performed by the device allow to determine the X, Y, Z coordinates of millions of measurement points, which form the so-called point cloud. In addition to registering the point coordinates, terrestrial laser scanners also record the intensity of the reflected signal, i.e. the value of the energy of the returning light beam (reflected from the object). Digital cameras are also integrated in TLS scanners, which makes it possible to assign real colours (RGB) from the digital images to each point

of the cloud (Wężyk 2010). Currently, several models of terrestrial laser scanners are available on the market, which can be divided into two main groups: time-of-flight (ToF) and phase-shift scanners. The main feature that distinguishes these two types of scanners is the distance measurement technology.

Phase-shift scanners are believed to measure more accurately than ToF scanners; however, the data obtained using them is subject to interference, i.e., the presence of noise in the obtained data. It is also worth noting that phase-shift scanners usually have a smaller range of data measurement compared to ToF scanners (Wężyk 2010). A major advantage of ToF scanners is the ability to register multiple reflections of the laser beam. This is especially important when scanning objects near vegetation (Liang et al. 2016). For example, when a laser beam falls on the outer edge of a trunk or thin branch, part of the beam bounces off it and the rest of the beam penetrates further and registers the subsequent objects encountered. Currently, there are ToF scanners on the market that can register up to 15 reflections of the laser beam (Riegl 2020).

To learn more about the types of scanners and the principles of their operation, the authors refer to the publications by Wężyk (2006, 2010), Dassot et al. (2011) or Liang et al. (2016).

3. Acquiring TLS data

The following subsections describe the general specifications of TLS data acquisition in the forest environment for three levels: sample plot, individual tree and whole stand.

3.1 Sample plots

Scanning sample plots using TLS technology is typically performed with a single-scan (SS) or multi-scan (MS) mode of data acquisition. In SS mode, the scanner is located in the centre of the sample plot. The data acquired in this mode represents an image of the stand from one perspective, i.e., as seen from the centre of the sample plot. In the MS mode, data is collected from multiple positions – usually from the centre and outside of the plot or by scanning only from outside positions. When deciding to collect data in this mode, artificial reference markers (spheres or targets) usually need to be set up during fieldwork to allow for later alignment of the data. This method of data collection ensures much greater data completeness compared to the SS mode. After alignment, data acquired in the MS mode represent a comprehensive,

fully three-dimensional image of the sample plot (Wężyk 2010; Liang et al. 2016).

When comparing the two methods of data collection, it should be noted that the SS mode is much faster. Currently, it takes about 20 min to perform such a measurement on a sample plot. The measurement time depends mainly on the class of laser scanner used and the settings used during operation. The data acquisition process itself takes between 2 and 10 min, and to this time must be added the time for setting up, starting, and configuring the scanner, which is about 5–10 min (Liang et al. 2016). The main disadvantage of data acquisition in SS mode is the high probability of the so-called 'occlusion effect' (Zasada et al. 2013). This effect causes some trees to be missed in the point cloud of the sample plot being mapped (Fig. 1) because trees in the same azimuth relative to the centre of the plot occlude each other. This effect increases with increasing distance from the scanner, i.e. the larger the radius of the sample plot, the more likely this effect occurs. The authors state in their papers that the percentage of undetected trees in a sample plot using the SS mode can range from 0 to 46%, with stand structure and sample plot size reported as the factors that have the greatest influence on this phenomenon (Astrup et al. 2014). In comparison, four or five scan positions are typically used to map the sample plot in MS mode. The scan positions are arranged in such a way that they map all trees from all sides as much as possible. Data obtained in this mode are considered the most accurate and also provide a complete three-dimensional image of the stand (the entire shape and stem area of each tree is mapped). The disadvantages of this mode include: higher labour intensity for field work, longer time for processing and aligning the point clouds, and a much larger amount of data collected. Currently, it is estimated that it takes about 1 h to measure a sample plot in MS mode. In MS mode data acquisition, an additional step of aligning the scans takes place during the initial processing. This is done using special software in an automatic or semi-automatic way (Liang et al. 2016).

3.2. Individual trees

TLS data can also be obtained on individual trees (Fig. 2). Such data can be useful in improving or developing allometric equations for characteristics such as whole-tree volume or biomass. The major advantage of using TLS technology for these purposes is the non-invasiveness, speed, and precision with which information on the morphological stem curve is obtained. Scanning of individual trees is usually performed in MS mode to obtain data




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).

with the highest level of detail. During fieldwork, scanner locations are positioned around the tree. Raunonen et al. (2013) suggest taking measurements from no less than three positions. However, it should be noted that the number of scanner positions should be chosen depending on the size of the object to be scanned and the planned level of detail of the data (Wilkes et al. 2017). For example, Wężyk et al. (2015) used 4 to 23 scanner positions during a field survey of the natural monument the Bartek Oak. In 2020, employees of the Forest Research Institute (IBL) scanned another natural monument – the Mieszko Oak – from 10 positions, which was sufficient to accurately register the appearance of the entire tree.

3.3. Whole stands

The MS mode is also used to scan entire stands (Fig. 3). However, the procedure for scanning large areas is usually more complicated, as the reference markers usually need to be repositioned when the locations of the scanning positions change. For more information on this, the authors refer readers to a paper by Wilkes et al. (2017) describing



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

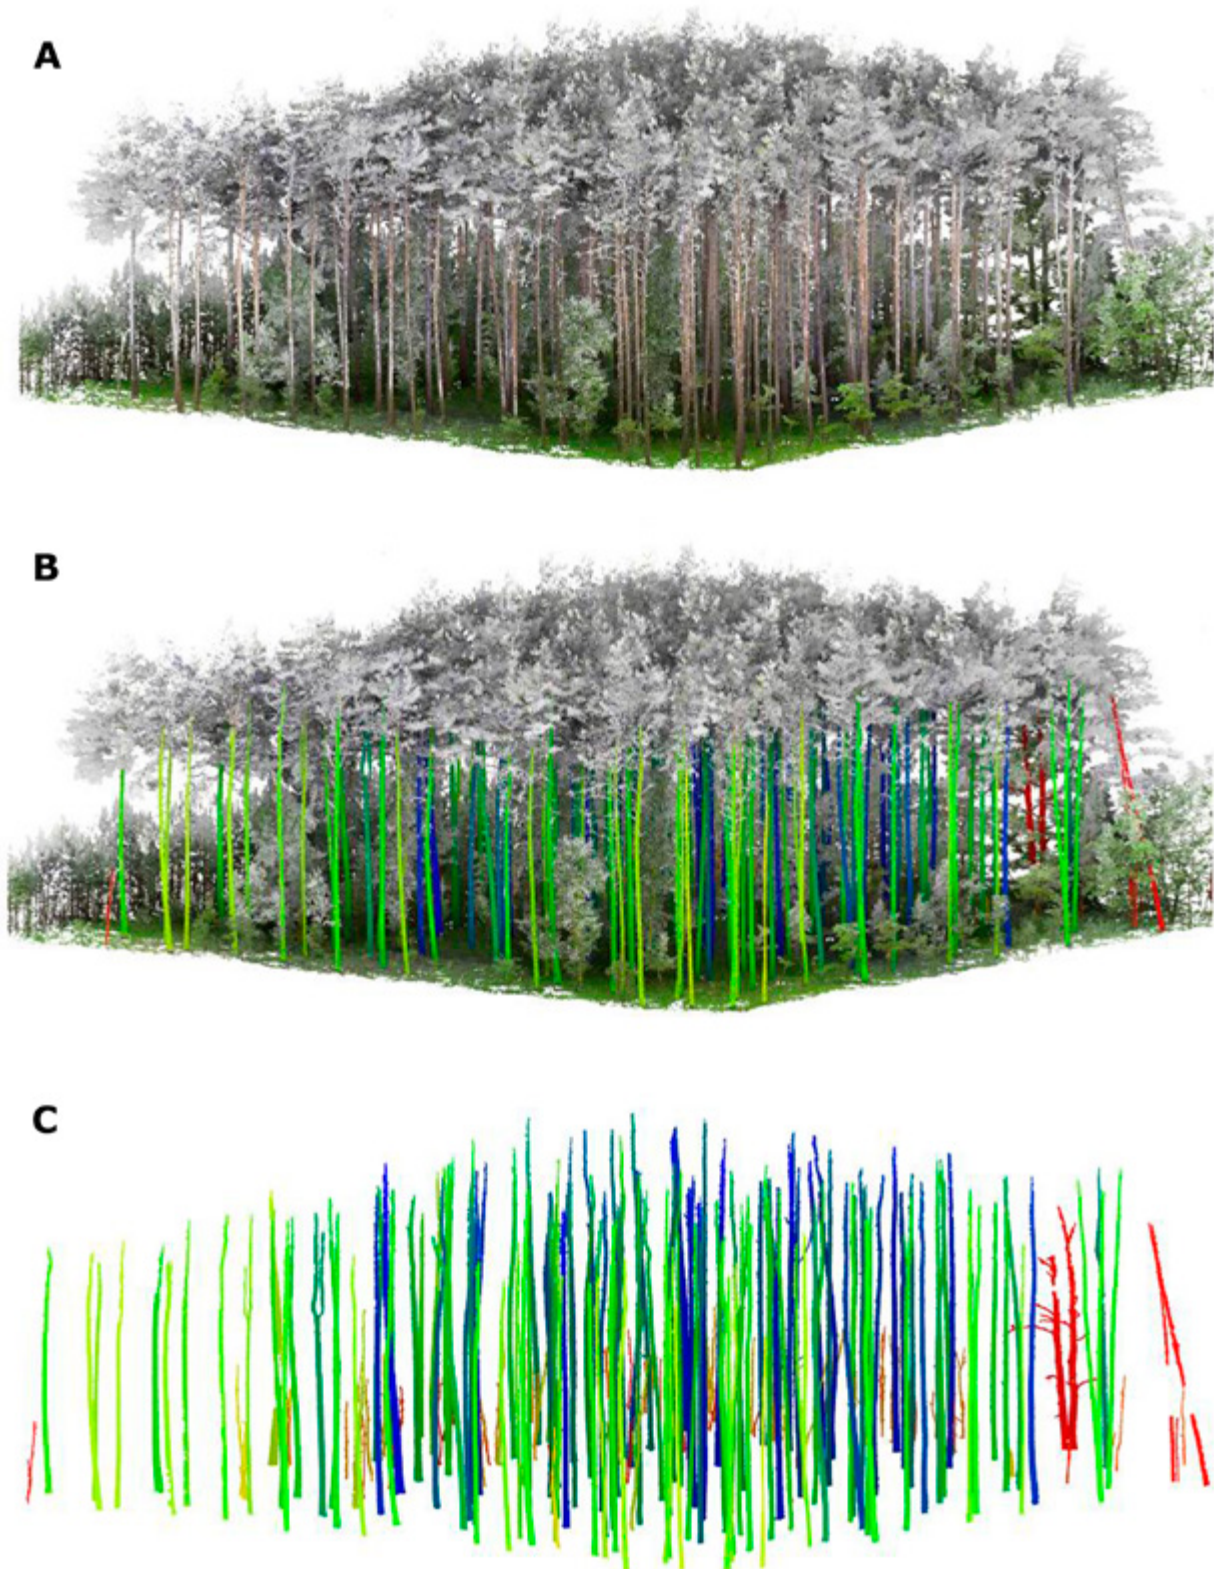


Figure 3. TLS point cloud representing Scots pine stand *Pinus sylvestris*. A – color scheme: RGB values, B – color scheme: RGB values and different colors for automatically detected tree stems, C – automatically detected tree stems, visualization was made in CloudCompare software (Girardeau-Montaut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

their experience from 27 field surveys in which they collected TLS data for large forest areas. They recommend scanning tree stands with a pre-planned 10×10 m grid where each node of the grid being the location of the scanner, and also recommend setting up about 120 scanning stations for stands of one hectare. Their experience indicates that conducting a TLS scan of a stand with such an area takes between 3 and 8 days for a crew of three in the field. It should be noted, however, that most of this work has been done in tropical rainforests, which are among the most complex stands in terms of vertical structure. In addition, the intensity of the work depends on many factors related to both the stand structure and the type of scanner used. The experience of IBL staff participating in a field study of TLS data collection for two 1 ha forest plots shows that under the conditions of Polish stands, a group of three people may need 2 to 4 days for such measurements of one plot, assuming more than 100 scanning stations for one plot and the use of Riegl VZ-400 or Riegl VZ-400i ToF scanners, which together with the software allow alignment of scans without the need to use reference markers during fieldwork.

4. Planning a TLS survey

When planning a measurement acquisition with TLS, the external environmental factors should be considered in addition to the technical aspects, such as the determination of the scan parameters and the selection of the appropriate data acquisition mode.

4.1. Weather conditions

When planning a TLS field survey, prevailing weather conditions must be considered (Dassot et al. 2011; Vaaja et al. 2016). Optimal conditions for TLS are windless days with no precipitation, moderate temperatures and low humidity. Wind is a factor that can significantly affect the quality of the data collected, especially within tree canopies. Swaying tree tops during the scan are captured in many places, resulting in image distortion in the upper parts of the stand. According to the study by Seidel et al. (2012), optimal scanning conditions occur when the average wind speed does not exceed 5 m/s. Vaaja et al. (2016) show that a wind speed of 9 m/s only does not significantly affect the stem parameters of the lower part of the tree (the part of the stem below one third of the total tree height).

TLS can be conducted in light rain or fog; however, this is not recommended due to poor data quality and the potential for distortions, i.e. false reflections in the obtained

data. Scanning is also not recommended when snow cover is present. Possible layers of snow deposited on the stem (absorbing the laser beams emitted by the scanner) may lead to errors in determining the diameter or volume of the stem (Dassot et al. 2011).

4.2. Vegetation period

An important aspect of planning a TLS survey is also the choice of an appropriate scanning date. For surveys that aim to obtain the most accurate data possible on the morphology of the woody parts of trees and to estimate their volume or biomass, the best times to scan are early spring or late autumn. During these periods, deciduous species lack foliage, so the effect of mutual obscuration is much smaller. Data collection during the leaf-off period provides a much better representation of the branches in the crowns of deciduous species and eliminates the potential effect of the lower parts of the stems being occluded by a layer of shrubs from the understory. This aspect is also important when scanning in MS mode with artificial reference markers. In the leaf-off period, the risk of the markers being occluded by leaves from lower forest layers is reduced.

5. TLS data processing methods

TLS data processing for dendrometric tree analysis can be divided into two main processes: tree detection in the point cloud and the development of three-dimensional models of individual trees.

5.1 Detection of trees

In recent years, a number of studies on automatic algorithms for detecting trees in a point cloud have been developed. In this context, tree detection can be understood either as an indication of the location of trees and their thickness (e.g. DBH) or as an attempt to reconstruct the overall shape and architecture of trees. The first algorithms were based on searching geometric patterns from the generated two-dimensional images representing the horizontal cross-section through a tree stand. The first stage of these methods consists of placing a thin horizontal slice of a three-dimensional point cloud on the horizontal plane. In the next stage, trees are detected by clustering groups of points (Węzyk et al. 2007) and searching for geometric patterns, e.g. circles (Chmielewski et al. 2010, Lindberg et al. 2012). These methods assume that the shape of a point cloud representing tree trunks

from a horizontal slice is similar to a circle or semicircle. The advantages of these methods include their relative simplicity and high computational speed. However, these algorithms encounter some difficulties in complex stands with high tree density or undergrowth, as the mapped points of the non-woody parts of the stem may be misclassified as a stem (Zhang et al. 2019). To remedy this, some researchers have focused on accurately identifying trunks or woody tree parts directly in the point cloud. In their work on distinguishing the woody or leafy parts of stems in point clouds, authors use different approaches. Côté et al. (2009) assumed that the woody parts of trees have a higher reflectance intensity than leaves and tried to exploit this fact in the classification. However, it should be noted that the reflection intensity of the laser beam depends not only on the spectral characteristics of the scanned objects, but also on the angle of the laser beam, the distance to the scanned object or its roughness. Normalising the value of reflection intensity is again a complicated and time-consuming process (Zhang et al. 2019). The use of dual wavelength laser scanners has also been tested (Li et al. 2013; Danson et al. 2014). The authors of these papers assumed that due to the distinct differences in the wavelength properties of leaves and woody parts of trees, they could be distinguished in the two wavelength bands. The accuracy of the classification was not discussed in detail in these papers. However, work on the development of such scanners is still in the testing phase and the availability of such devices is currently limited.

Another approach is to use the local geometric features of point clouds. In these methods, the point cloud is divided into small subsets in a first step. Iteratively, for each point, groups of points closest to it are selected, defined by the radius of the sphere or by the number of nearest neighbours around the central point. For selected subsets, geometric features are computed using the principal component analysis (PCA) algorithm (Burt et al. 2018, Zhou et al. 2019). For trunk detection, geometric features of point clouds such as linearity, flatness, and verticality were used. It was assumed that tree trunks in a point cloud are generally vertical objects, are linear, and form relatively flat surfaces at a small scale (Liang et al. 2012; Oloffson, Holmgren 2016). The geometric features are computed for each point in the cloud based on the set of neighbouring points determined by the radius of the distance parameter or the number n of nearest neighbours. The size of the selected subset affects the discrimination of the objects. For this reason, in some studies, multi-scale geometric features were used to classify the point cloud into woody and soft parts, i.e., leaves. Classification al-

gorithms were applied in the studies, using machine learning methods among others (Vicari et al. 2019; Zhou et al. 2019). A major advantage of these methods, in contrast to the previous ones, is the use of geometric information from the point cloud, which should be relatively similar regardless of the specifics of the scanner used. However, it should be noted that these methods require more computational power.

5.2 Three-dimensional tree modelling

In the analysis of both individual trees and groups of trees in sample plots or whole stands, the basic unit being analysed is the quantitative structure model (QSM) of a single tree. Such a model is assumed to represent the morphology of the tree as accurately as possible and to be fully measurable (Raumonen et al. 2013; Hackenberg et al. 2015). These properties allow accurate determination of the thickness and volume of the above ground tree components.

Liang et al. (2016) distinguish five levels of detail (LoD) of digital tree models that allow different characterizations of the modelled trees (Table 1).

Depending on the level of details, tree models are used for different tasks. For the purpose of forest inventory, the use of models with LoD from 1 to 3 are mainly considered (Fig. 4).

The use of conventional tools in a traditional forest inventory allows the collection of information at the LoD1 level, where each tree or a selected group of trees is described by two basic characteristics height and DBH. LoD2-level models are much more detailed, as the thickness of the main stem can be measured at each height for which TLS data have been collected. Such models allow stem volume to be measured directly and accurately. LoD3 models also take into account branches, allowing the total biomass and architectural features of trees to be determined. Building such models based on TLS data requires scanning from many positions, which significantly increases the cost of data acquisition. LoD3 and LoD4 models are used in individual tree modelling, while LoD5 models are used in computer graphics, but current TLS technology does not allow obtaining detailed data, such as characterising all tree leaves (Liang et al. 2016).

Many approaches can be found in the literature to generate three-dimensional tree models from a point cloud. The best results are obtained with two approaches. The first is based on the direct reconstruction of the outer surface of objects (meshing), resulting in a three-dimensional, uniform, continuous surface that represents the

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

Level of details	Parameters	Predecessor included
LoD1	tree height diameter at breast height	-
LoD2	tree position 3D model of the main stem	LoD1
LoD3	2 nd level branches (directly connected with the main stem)	LoD1 + LoD2
LoD4	3 rd level branches (connected with the 2 nd level branches)	LoD1 + LoD2 + LoD3
LoD5	leaves more details of branches (higher level branches)	LoD1 + LoD2 + LoD3 + LoD4




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)

appearance of a tree. This model represents the external shape of the bark and all its irregularities, allowing the tree volume to be determined very accurately (Fig. 5B, D). According to Dassot et al. (2012), the resulting model can serve as an absolute reference for volume measurements. However, the application of the direct surface reconstruction method requires a very high quality and high density point cloud, as it is very sensitive to the lack of data continuity. Due to the complexity of the forest environment and the fact that trunks and branches obscure each other, this method can only be used for MS mode data. However, it should be noted that even with data collected in this way, certain tree fragments will not be faithfully reproduced, which may result in a model being developed with some shortcomings or deficiencies. An additional disadvantage of this method is the need to pre-select points representing the woody parts of trees.

The second approach, most commonly used, is to fit simple geometric primitives into point cloud segments that re-

present the woody parts of trees. The process of creating a three-dimensional model using this method is usually done in stages, from the base of the trunk to the top of the tree. Simple three-dimensional geometric figures, such as a cylinder, circle, ellipse, or sphere (Raumonen et al. 2013; Hackenberg et al. 2015), are iteratively fitted into the point cloud segments, representing small fragments of a trunk or branch. The end result of the modelling is a set of shapes that can be combined into a whole. In these methods, the first stage of processing often involves building the skeleton of a tree (Du et al. 2019), which allows the model to be decomposed into components, i.e. individual branches. Compared to the previous one, this method produces a generalised image of the tree (Fig. 5C, E). However, it is less sensitive to data gaps. When using this method, the best results are obtained with data from the MS mode. It is also possible to build models of the main trunk based on SS data, as the algorithms for merging simple geometric figures are able to deal with partially incomplete data and interpolate the missing part of stem.

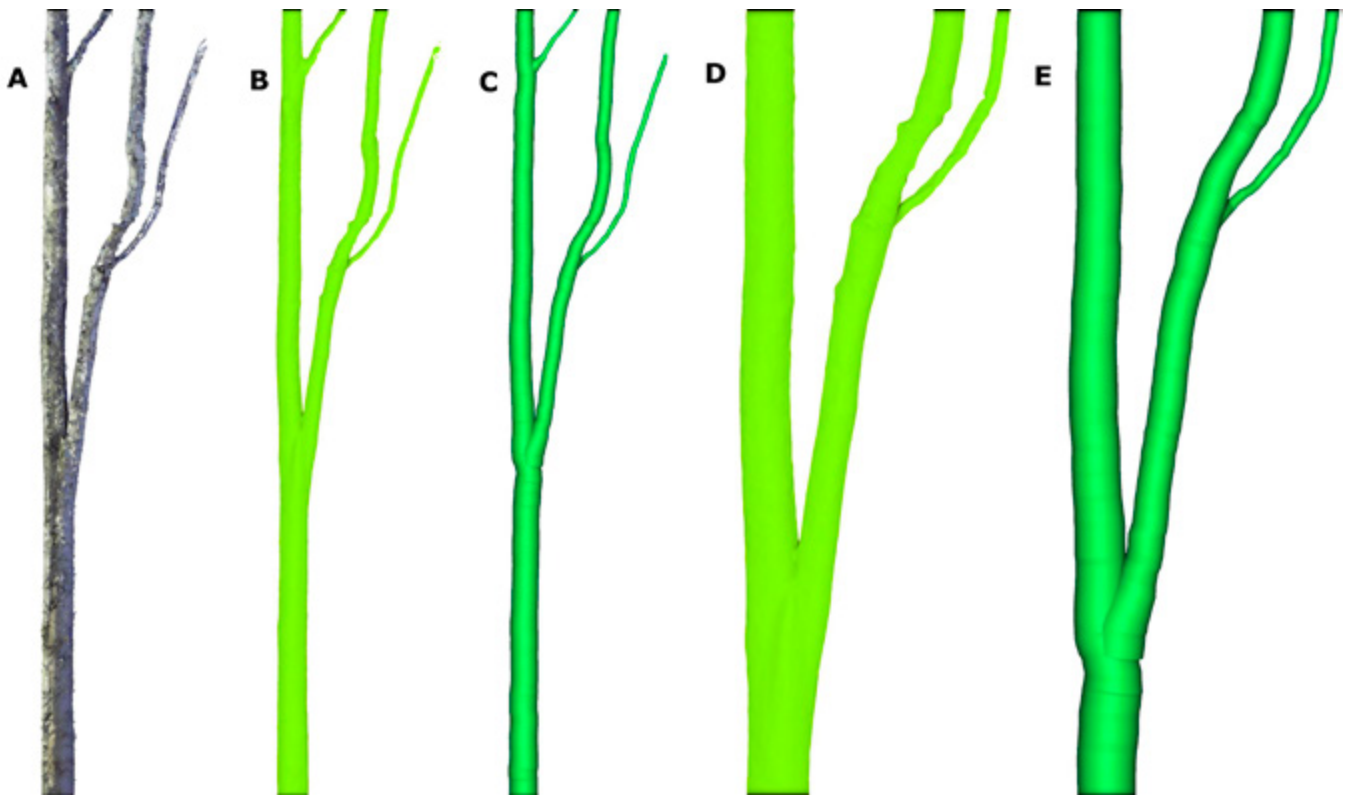


Figure 5. Comparison of quantitative structure models: A – TLS point cloud representing European beech in RGB colors; B, D – tree model obtained by meshing method; C, E – tree model obtained by cylinder fitting method, visualization was made in CloudCompare software (Girardeau-Montaut 2020)

5.3. TLS data processing software

To date, there is no commercial software for working with TLS data that covers all aspects of data processing for forestry purposes. Two companies are developing such software -Treemetrics (Ireland) is developing the AutoStem software (Bienert et al. 2007), while Taxus IT (Poland) is developing thetScan software (Konieczny, Neroj 2016). However, in both cases, they have not yet been included in the sales offer of their companies.

Nevertheless, there are several free solutions (Table 2) that enable such processing of TLS data, developed mainly by scientific centres.

These include standalone desktop applications and libraries of specialised tools used through programming development environments such as Matlab, R, or Python. These tools are publicly available and free of charge.

6. Assessment of the basic tree parameter estimates obtained by using TLS technology

In this section, the results of the paper are presented, summarising the achieved accuracy of the estimation of selected basic tree parameters. It should be noted that the obtained results depend on a number of factors such as: Stand structure, assumed sample size, type of scanner used and data processing method applied. The works cited focus on the results obtained for tree stands in the temperate climate zone.

6.1. Detection of trees in the sample plots

In 2018, an international academic consortium conducted a comparison of 18 algorithms for processing TLS data from sample plots (Liang et al. 2018b). In the study, reference dendrometric and TLS data were obtained for 24 square plots with side length of 32 m. The selected plots represented three categories depending on the complexity of stand structure: simple – stands with good stem visibility, lack of understory, and tree density of about 600 pcs/ha; medium – stands with moderately complex structure, where there are single clumps of understory and tree density is about 1,000 pcs/ha; and difficult – where there is abundant understory or a second stand layer and tree density is about 2,000 pcs/ha. The authors of this paper compared the algorithms for many biometric features of trees and for two types of data collection – SS and MS.

Three indicators were proposed to evaluate the tree detection algorithms: detection completeness – it indicates what

part of trees in the sample plot was detected, detection correctness – it indicates what part of detected trees was correctly classified as a tree (the algorithm can classify an object that is not a tree), and average detection accuracy – it is a resultant measure of the previous two measures.

The reference data and TLS from this project have been published, making it possible to compare newly developed tree detection algorithms (Zhang et al. 2019, Wang et al. 2020). However, it should be noted that an incomplete dataset was provided, i.e. 6 sample plots, two for each of the stand structure complexity categories.

Below are the tree detection results obtained in the project (Liang et al. 2018b) and other works (Zhang et al. 2019; Wang et al. 2020) using the SS (Table 3) and MS (Table 4) modes.

The above results indicate that the accuracy of tree detection differs depending on the mode of TLS data acquisition used for the analysis (SS or MS), the complexity of the stand structure and its vertical structure.

6.2. Diameter at breast height measurement

DBH is the most frequently measured and used biometric parameter of trees in forestry. Table 5 presents the selected results of DBH measurements obtained using two modes of TLS data acquisition. Two error measures are presented in this table: bias, which indicates whether the measurement is over- or underestimated on average, and root mean square error (RMSE), which indicates the average error.

Based on the results of previous work, one can see that the use of the MS mode does not significantly improve the estimation of DBH. On the basis of the above results, it can be assumed that the average error of determining DBH in the SS mode is 1–3 cm, while in the MS mode – under 2 cm.

It is worth noting that according to research conducted in Finland in the 1990s, the accuracy of measuring DBH with a tree calliper was about 0.7 cm (Hyypä et al. 2018). In the above experiment, an independent measurement of DBH for a fixed group of trees was performed many times by many surveyors, thus eliminating a potential systematic error.

6.3. Tree height measurement

The TLS tree height measurement has a systematic error because the upper parts of the tree crown are not well visible. The tops of the trees are obscured by the branches at the bottom of the crown, resulting in a measurement that is usually lower than the actual height. Errors reaching se-

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

Name	Reference	Platform	Algorithms used				
			DTM extraction	Tree stem detection	Point cloud classification into wood/leaf components	Basic tree parameters extraction	QSM extraction
DendroCloud	Koreň et al. 2017	standalone application	+	+	-	+	-
3DForest	Trochta et al. 2017	standalone application	+	+	-	+	+
Computree*	Othmani et al. 2013	standalone application	+	+	-	+	+
Simple-Forest**	Hackenberg et al. 2015	standalone application***	+	+	-	+	+
AdTree	Du et al. 2019	standalone application	-	-	-	+	+
SSSC	Wang et al. 2020	standalone application and Matlab	+	+	+	-	-
TreeQSM	Raumonon et al. 2013	Matlab	-	-	-	+	+
TreeLS	de Conto et al. 2017	R	-	+	-	+	-
TLSeparation	Vicari et al. 2019	Python	-	-	+	-	-

*a multifunctional platform designed for processing LiDAR data for forestry purposes, with the possibility of adding external plugins;

**the software has changed its name from SimpleTree;

***the Computree platform plug-in

veral metres have been reported in published works (Table 6). Using the MS mode improves the results, but there still remains some error in the height estimates.

6.4. Tree taper curve measurement

TLS data allow to reproduce the taper curve of a stem in a non-invasive manner by taking automatic diameter measurements of point cloud sections from different stem heights. When TLS is implemented in operational forestry, it is possible to reconstruct the taper curve for each of the trees in the sample plot.

It should be noted that it is often not possible to reconstruct the entire trunk from the base of the trunk to the top of the tree. This is due to the lack of visibility of the highest parts of the stem, or because its representation in the point cloud is too weak, resulting from the long distance of the scanner to the top of the tree (the distance can be more than 30 m for tall trees), which means less frequent point sampling.

It is assumed that, on average, the stems of up to 50–70% of the relative tree height can be reconstructed using TLS in the sample plots (Liang et al. 2018b). Note that this is the part of the stem where most of the tree volume is accumulated.

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

Stand complexity	Parameter [%]	Results	
		Liang et al. 2018b	Zhang et al. 2019
Easy	mean accuracy	~88*	79
	completeness	~81*	68
	correctness	~92*	95
Medium	mean accuracy	~73*	57
	completeness	~70*	41
	correctness	~92*	100
Difficult	mean accuracy	~48*	20
	completeness	~34*	11
	correctness	~95*	95
Mean	mean accuracy	57**	52
	completeness	62**	40
	correctness	93**	97

*result achieved by the best algorithm,

**mean value calculated from results based on all 18 algorithms

Maas et al. (2008) compared the taper curves of the stem obtained with TLS technology and with a harvester head. An RMSE of 4.7 cm was obtained with respect to the reference measurements from the harvester. The authors note that the error between stem sections between 0.7 and 7.7 m was only 1 cm. They also point out that the error on the whole trunk is larger due to the unusual (non-cylindrical) shape of the lower part of the trunk and the large number of branches in its upper part. The specific structure of the studied tree negatively influenced the diameter estimation.

Table 7 shows a summary of the results obtained for the determination of the longitudinal taper curve of the trunk. It contains information about the average longitudinal taper curve in the sample plots. This value expresses the percentage of relative tree height that could be mapped.

6.5. Determining tree volume

Using TLS data, it is possible to directly determine the volume of individual trees with an error not exceeding

10%, which is comparable to the results obtained using the best allometric equations (Dassot et al. 2012; Liang et al. 2014).

In an international comparison of TLS algorithms (Liang et al. 2018b), the best algorithm for data collection in the SS mode achieved an RMSE for single-tree volumes between 25 and 50%, and between 20 and 40% for the MS mode. In this study, a measure for the overall assessment of the tree volume of the sample plot was proposed by calculating the volume ratio. This is calculated as the quotient of the tree volume determined by TLS and the reference volume. The authors give the average volume ratio for circular plots with three different structures: easy – 94% for the mode SS and 107% for the mode MS, medium – 87% for the mode SS and 107% for the mode MS and difficult – 43% for the mode SS and 94% for the mode MS. These results show that it is possible to determine the volume at the sample plot level in both SS and MS modes with an error of 6 – 13% for stands with simple and medium structures. When using the SS mode in plots with difficult struc-

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

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

*result achieved by the best algorithm,

**mean value calculated from results based on all 18 algorithms

ture, the total volume is underestimated by more than 50%. Mode MS, on the other hand, gives very similar results to the reference data (6% difference).

Table 8 shows the results of estimating the volume of the individual trees.

7. Discussion

The presented results show the great potential of using TLS technology in forest inventory. However, the introduction of this technology in forest practice is a complicated and time-consuming process. The change from existing solutions to new technologies must bring measurable economic or qualitative benefits.

In terms of forest inventory, the most important factors influencing the adoption of a new measurement technology are: the accuracy of the determination of basic tree characteristics, the cost of the technology (both equipment and software) and aspects relating to the operational use

of the technology (technological limitations, time of data acquisition, dimensions of the equipment and the required qualifications of surveyors, including training in the use of the scanner and software). Considering these aspects, the main limitations of using TLS in forestry practice are the cost of the technology, lack of software and aspects relating to its operational use.

Although the price of TLS devices is gradually decreasing, the cost of 100,000–150,000 PLN per device is still too high. Given the current lack of multifunctional commercial TLS data processing software for forestry purposes, it can be assumed that the first ones to appear on the market will also be expensive. This aspect may be the main reason for not implementing this technology in forestry practice in the next few years.

Taking into account aspects of the operational use of TLS technology in forestry, the most difficult one is to ensure the detection of all trees in the sample plots. With the current methodology of taking measurements in circular plots, the MS data acquisition mode can be used in stands

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)

Reference	TLS mode	Tree species	Results	
			bias [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

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)

Reference	TLS mode	Tree species	Results	
			bias [m]	root mean square error RMSE [m]
Weżyk 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

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).

Reference	TLS mode	Tree species	Results		
			percentage of the tree height covered by measurements [%]*	bias [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

*mean value

with a simple structure. The results show that with this configuration, all or the vast majority of trees in the sample plots are able to be automatically detected. However, scanning from several positions significantly lengthens the surveyor's working time, which is currently considered to be too long. It is possible that the new generation of scanners will require less time to obtain data, but the cost of such devices will certainly be relatively high at first. Additionally, artificial markers usually have to be set up to align the scans when using the MS mode. The possible development and general availability of algorithms to automatically align scans without the use of targets will certainly be a factor influencing the potential implementation of TLS in forestry practice. So far, there have been several papers on this issue, and such algorithms are available only in a few commercial software programs.

The use of data obtained in the SS mode is competitive compared to the MS mode, but only for trees that are clearly visible in the point cloud. Based on the results of published works, it can be assumed that about 70% of the trees in a circular plot are detected using the SS mode. If an inventory method based only on visible trees or a correction method for invisible trees was developed, the SS mode would be attractive for forestry practice due to the much shorter time of data acquisition. So far, little work is available on this topic, and further research is required.

Should such methods be developed, it would be possible to use TLS in more complex stands. Worth noting recurrent research results, showing that the determination of some aggregate stand characteristics, e.g. abundance, using both data acquisition modes provides results very similar to the reference data for stands with simple and moderate structures, and using the MS mode – even for stands with a complex structure.

Another potential scenario is the use of TLS SS data to calibrate the methods of estimating survey characteristics using ALS and individual tree detection (ITD) methods. This approach would use only information from clearly visible trees. This topic also requires study and the development of precise methods to align TLS and ALS data with “tree-to-tree” accuracy. Of course, this solution is also very expensive at the moment.

The problem of obscured trees can be solved with mobile laser scanning (MLS). By using this constantly evolving technology, it is possible to design the trajectory of the survey of the sample area in such a way that all trees can be mapped. The use of terrestrial remote sensing techniques such as MS TLS or MLS also makes it possible to increase the size of the sample plots to be considered, which can be an additional advantage in forest inventory.

It is worth mentioning the release of the new version of Apple's flagship product. In March 2020, the company began

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)

Reference	TLS mode	Tree species	Results	
			bias [%]	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***

*deviation from the reference value,

**calculated from publication data,

***the best result among 18 tested algorithms in stands with different structure

selling a new version of the iPad Pro. One of its innovations is a built-in LiDAR sensor. According to the manufacturer, the range of the sensor is up to 5 metres and allows you to reconstruct the nearest environment in three dimensions (Apple Inc. 2020). The price of the basic version of this iPad is currently about 3,900. So far, there are no published works on the use of this tablet in forestry research, but it is expected that soon such studies will be conducted and may be of interest for forestry practise.

Given the continued development of LiDAR technology, one can expect to see the development of laser scanners capable of large-scale aerial mapping of tree trunks in the next decade or so. Assuming that the technology develops in this direction, it will then be possible to directly measure the basic characteristics of individual trees without the need for ground measurements and statistical modelling. It can be assumed that the algorithms developed for TLS data processing could be directly applied to this new type of data.

8. Conclusions

1. Over the last 20 years, TLS data processing algorithms for forest inventory purposes have significantly developed.

2. TLS technology can be used for non-invasive dendrometric measurements of trees and stands, with an estimation accuracy of most parameters comparable to traditional measurement methods currently used in forestry.

3. The best time to obtain TLS data for forest inventory purposes is early spring or late autumn (especially in deciduous stands or with the participation of deciduous species in the undergrowth). Scanning is best done in windless weather and low air humidity.

4. Better results for estimating the biometric characteristics of trees can be obtained using the MS data acquisition mode. However, measurements using this mode are much more time-consuming compared to the SS mode.

5. The TLS data acquisition mode and stand structure have a great influence on the detection of trees and the accuracy of describing their biometric characteristics.

6. Using TLS technology makes it possible to non-invasively measure the taper curve of standing trees up to about 60–70% of relative tree height.

7. The measurement of tree height is burdened with a relatively large systematic error caused by the ‘occlusion effect’ – the top of the tree is obscured by the lower part of the crown.

8. Further research is needed on the use of TLS technology in forest inventory and the creation of a set of ‘good practices’ and instructions on how to obtain and process TLS data, taking into account different variants of their acquisition.

Conflict of interest

The authors declare the lack of potential conflicts of interest.

Funding sources

This publication was written within the framework of the REMBIOFOR project ‘Remote sensing based assessment of woody biomass and carbon storage in forests’ co-financed by the National Centre for Research and Development under the program ‘Natural environment, agriculture and forestry’ BIOSTRATEG under agreement no. BIOSTRATEG1/267755/4/NCBR/2015.

References

- 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., Korpelta 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. Hyypä, J. Hyypä), 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-Niedźwiecki 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., Gnanwan 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., Broly G., Francesco P., Hackenberg J., Huang H., Jo H.-W., Katoh 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 RANSAC 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., Kaartinen 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_px-priegldownloads/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., Hyyppä J., Hyyppä 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.isprs.2020.04.020.
- Wang Y., Lehtomäki M., Liang X., Pyörälä J., Kukko A., Jaakkola A., Liu J., Feng Z., Chen R., Hyyppä 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.isprs.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., Koziol 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. Hyyppä, J. Hyyppä), 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 określenia 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., Strześliński 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.

Authors' contributions

G.K. – concept development, manuscript preparation, literature review, preparation of figures and tables, editing; B.K. – concept development, editing; K.S. – concept development, editing.