

Detekcja pojedynczych martwych świerków w Puszczy Białowieskiej na podstawie integracji danych satelitarnych z danymi lotniczego skanowania laserowego

Detection of dead Norway spruce individuals in the Białowieża Forest
based on the integration of satellite imagery with airborne laser scanning data

Małgorzata Białczak 

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

e-mail: m.bialczak@ibles.waw.pl

Abstract. The Białowieża Forest, a unique lowland forest complex in Central Europe, has undergone significant ecological changes in recent years, primarily due to a massive outbreak of the spruce bark beetle (*Ips typographus* L.). This outbreak, which peaked in 2016, caused extensive Norway spruce (*Picea abies* (L.) H. Karst) mortality, leading to major changes in forest structure and functioning. Ground-based forest inventory methods remain a fundamental and accurate source of ecological information. However, they are time-consuming and relatively expensive, particularly when applied across large or inaccessible areas such as protected areas or wetlands. For this reason, alternative approaches are increasingly being explored – especially those leveraging remote sensing techniques, which allow for faster, spatially consistent and repeatable forest condition assessments. Satellite imagery and airborne laser scanning (ALS) data have proven to be powerful tools for monitoring forest condition at different spatial scales.

This study investigates the feasibility of integrating high-resolution multispectral satellite imagery (Pléiades, 2 m spatial resolution) with ALS data (11 points/m²) to detect and map individual dead spruce trees in the Polish part of the Białowieża Forest. The methodological framework (Fig. 2) included pre-processing steps such as cloud masking, shadow elimination, canopy gap removal and segmentation of individual tree crowns from ALS data. These procedures aimed to enhance the classification accuracy and spatial alignment of the datasets. A supervised maximum likelihood classification was applied to the satellite imagery, distinguishing three vegetation classes: dead trees, conifers and broadleaves. The classification resulted in a high accuracy for dead trees (producer's accuracy: 96.8%, user's accuracy: 94.6%; Tab. 4, Fig. 3).

A multistep integration method was used to detect individual dead trees by correlating spectrally classified pixels with tree crown segments derived from ALS data. Each crown was assessed for spatial proximity and spectral coverage of the classified dead pixels. By applying optimized thresholds for proximity and coverage, the algorithm identified individual dead spruce trees with a detection accuracy of 71.1% – true positives and a false positive rate of 22.0% (Tab. 9), validated against manually interpreted reference data. The final detection map indicated over 381,000 individual dead spruce trees in the forest area (Tab. 8, Fig. 5).

The integration of ALS and satellite data proved to be effective, especially in forest compartments with lower structural and species complexity. However, limitations were observed in areas such as the Białowieża National Park, where diverse canopy structures, species heterogeneity and occlusion effects significantly reduced detection rates. In such areas, the satellite pixels often represent mixed spectral signals, which reduces the reliability of the classification for individual tree identification.

The study emphasizes the utility of combining complementary remote sensing datasets to enable cost-effective, large-scale monitoring of forest health. It also highlights the temporal constraints of integrating data collected in different years, as forest conditions may change due to logging or vegetation regrowth. Although data mismatches can lead to errors, these can be mitigated by excluding known logged areas.

This research contributes to the development of practical approaches for operational forest monitoring and supports sustainable forest management under increasing ecological pressures. The proposed method, when adapted to specific forest conditions, can improve forest inventory systems. Future work should explore improvements in tree crown segmentation, the use of multi-temporal satellite data and the integration of additional spectral indices or Deep Learning-based classification algorithms.

Słowa kluczowe: detekcja pojedynczych drzew, integracja danych, klasyfikacja największego prawdopodobieństwa, lotnicze skanowanie laserowe (ALS), monitoring stanu zdrowotnego lasu, Pléiades, Puszcza Białowieska, zamieranie drzew

Keywords: individual tree detection, data integration, maximum likelihood classification, airborne laser scanning (ALS), forest health monitoring, Pléiades, the Białowieża Forest, tree mortality

Wpłynęło: 29.06.2025 r., recenzowano: 19.08.2025 r., zaakceptowano: 09.09.2025 r., opublikowano: 17.09.2025 r.

 BY-NC-ND 4.0 © 2025 M. Białczak

1. Wstęp

Puszcza Białowieska jest jednym z ostatnich i najlepiej zachowanych nizinnych lasów naturalnych w Europie, stanowiąca rozległy kompleks leśny o wyjątkowo wysokiej różnorodności biologicznej. Obszar ten, położony na pograniczu Polski i Białorusi, charakteryzuje się zróżnicowaną strukturą siedlisk oraz bogactwem gatunków roślin, zwierząt i grzybów. W strukturze gatunkowej drzewostanów istotną rolę odgrywa świerk pospolity (*Picea abies* (L.) H. Karst) (Czerepko 2025), który jeszcze w 2015 roku był gatunkiem dominującym (Miślicki i in. 2022), choć ze względu na zmiany klimatu skutkujące m.in. nasileniem gradacji owadów, suszami oraz wzrostem podatności na czynniki biotyczne i abiotyczne, jego udział w ostatnich latach znacząco zmalał.

Puszcę Białowieską wielokrotnie nawiedzały gradacje kornika drukarza (*Ips typographus* L.) (Keczyński 2002). Ostatnia trwająca od 2012 do 2019 roku była jedną z największych w historii tego obiektu przyrodniczego (Gutowski i in. 2022). Szczytowy okres gradacji przypadł na rok 2016 (Ginszt, Laskowska-Ginszt 2022), prowadząc do masowego zamierania świerków i znaczących zmian w strukturze i funkcjonowaniu ekosystemów leśnych. Odporność drzewostanów znacząco obniżyła się m.in. wskutek występowania susz i związanymi z nimi stresu wodnego roślinności. Szczególnie suchy rok odnotowano w Puszczy Białowieskiej w 2015 roku. Sezon wegetacyjny tego roku charakteryzował się wyjątkowo wysokimi temperaturami i deficytem opadów, a także suchą i ciepłą jesienią, co stworzyło bardzo korzystne warunki termiczne dla rozwoju kornika drukarza (Grodzki 2016).

W obliczu tak dynamicznych i rozległych zmian zachodzących w drzewostanach, tradycyjne, naziemne metody inwentaryzacji zasobów leśnych okazują się niewystarczające – są pracochłonne, kosztowne i w niektórych przypadkach (np. na terenach podmokłych lub w obszarach ochrony ścisłej) wręcz niemożliwe do zastosowania (Vatandaşlar, Zeybek 2021). W związku z tym coraz większego znaczenia nabierają metody zdalnego monitorowania środowiska, a w szczególności dane teledetekcyjne, które dostarczają aktualnych, jednorodnych i przestrzennie spójnych informacji o stanie lasów i zachodzących w nich procesach (Gavilan-Acuna i in. 2025). Teledetekcja umożliwia szybkie pozyskanie danych o dynamice zmian, stanowiąc istotne wsparcie dla zarządzania zasobami leśnymi (Banskota i in. 2014).

Możliwości wykorzystania obrazów satelitarnych w skutecznej identyfikacji zamarych drzew zostały już potwierdzone w licznych badaniach (Skakun i in. 2003; Coops i in. 2006; Wulder i in. 2006; Hicke, Logan 2009; Pluto-Kossakowska i in. 2017; Bałazy i in. 2019; Migas-Mazur i in. 2021; Krawczyk, Wężyk 2023). Jednym z najważniejszych czynników determinujących skuteczność detekcji martwych drzew z wykorzystaniem danych satelitarnych jest rozdzielczość terenowa zdjęcia (ang. Ground Sampling Distance – GSD) (Hicke, Logan 2009). W przypadku monitoringu zamierania drzew, wartość spektralna pojedynczego piksela może stanowić mieszankę sygnałów pochodzących z różnych obiektów, takich jak sąsiadujące drzewa,

czy roślinności podszytu (Hicke, Logan 2009). Z tego względu konieczne jest uprzednie określenie odpowiedniej skali analiz, adekwatnej do celu badań. Dane satelitarne o średniej terenowej wielkości piksela (GSD 10–100 m), pochodzące m.in. z sensorów Landsat czy Sentinel, można zastosować do prowadzenia analiz na dużych obszarach, w tym na poziomie krajowym. Dane te mogą być użyte do szacowania przybliżonego zasięgu przestrzennego zamierania drzew, ale ograniczona rozdzielczość terenowa może wpływać na precyzję identyfikacji poszczególnych obszarów (Jutras-Perreault i in. 2023). W celu zwiększenia dokładności klasyfikacji oraz uchwycenia dynamiki czasowo-przestrzennej, dla danych o średniej wartości GSD często stosuje się analizy oparte na szeregach czasowych obrazowań (Meddens i in. 2013). Z kolei dane satelitarne o wysokiej rozdzielczości terenowej (GSD 1–10 m), pozyskiwane m.in. z systemów WorldView-2 czy Pléiades można wykorzystać do prowadzenia bardziej szczegółowych analiz na poziomie regionalnym, w tym identyfikację zamierania na poziomie pojedynczych drzew (Coops i in. 2006; Jutras-Perreault i in. 2023).

Ze względu na szeroką dostępność bezpłatnych obrazowań, w analizach zamierania drzew najczęściej wykorzystywane są dane satelitarne o średniej rozdzielczości terenowej, pochodzące z systemów Landsat oraz Sentinel (Meddens i in. 2013; Fernandez-Carrillo i in. 2020). Zastosowanie tych danych umożliwia osiągnięcie wysokiej dokładności klasyfikacji sięgającej od ok. 70% do 90% (Franklin i in. 2003; Skakun i in. 2003; Wulder i in. 2006; Meddens i in. 2013). Ich dodatkowym atutem jest możliwość pozyskania dużej liczby obrazowań (w tym archiwalnych) dla tego samego obszaru bez konieczności ponoszenia kosztów finansowych, co ułatwia prowadzenie analiz szeregów czasowych. Należy jednak zaznaczyć, że dane te pozwalają jedynie na identyfikację powierzchni objętej procesem zamierania, a nie na dokładne odwzorowanie pojedynczych osobników. Pojedynczy piksel obrazowania reprezentuje w tym przypadku obszar, który w rzeczywistości może być tylko częściowo pokryty przez martwe drzewa – najczęściej w zakresie od 20% do 80% (Meddens i in. 2011). W związku z tym, powierzchnia zamierania drzew oszacowana na podstawie danych satelitarnych może być obciążona błędem.

Dane satelitarne o wysokiej rozdzielczości terenowej (GSD poniżej 10 m) były z powodzeniem stosowane w licznych badaniach, umożliwiając detekcję zarówno niewielkich skupisk martwych drzew, jak i pojedynczych osobników (White i in. 2004; Coops i in. 2006; Weidenbach i in. 2008; Garrity i in. 2013; Bryk i in. 2021; Migas-Mazur i in. 2021). Uzyskiwana całkowita dokładność klasyfikacji (ang. Overall accuracy – OA) wahała się od 70 do ponad 90%, a wykorzystanie serii czasowych obrazów o wysokiej rozdzielczości terenowej pozwalało osiągnąć jeszcze wyższe rezultaty – nawet powyżej 95% (Garrity i in. 2013). Mimo to, również w tym przypadku detekcja opiera się głównie na identyfikacji powierzchni objętych zamieraniem, a próby precyzyjnej identyfikacji pojedynczych drzew są nadal ograniczone.

Jednym z wyjątków jest badanie Jutras-Perreault i in. (2023), w którym podjęto próbę integracji danych lotniczego skanowa-

nia laserowego (ang. Airborne Laser Scanning - ALS) z obrazami optycznymi pochodzącymi z różnych źródeł, w tym danych lotniczych o GSD = 0,3 m, satelitarnych danych PlanetScope GSD = 3 m oraz Sentinel-2 o GSD = 10 m. Analiza zgodności między przewidywaną a rzeczywistą obecnością lub brakiem martwych drzew stojących wykazała, że najwyższe wartości współczynnika korelacji Matthews (MCC), mieszczące się w przedziale od 0,94 do 0,97, uzyskano dla danych o najwyższej rozdzielczości terenowej. W przypadku danych satelitarnych dokładność detekcji była znacząco niższa – dla PlanetScope wartość MCC nie przekraczała 0,67, a dla danych Sentinel-2 była jeszcze niższa. Wyniki te wskazują, że precyzyjna identyfikacja martwych drzew na poziomie pojedynczych osobników, nadal stanowi wyzwanie w przypadku danych satelitarnych. Jednocześnie należy zauważyć, że liczba badań integrujących dane ALS z danymi satelitarnymi pozostaje ograniczona, co wskazuje na istotną lukę badawczą w zakresie zintegrowanego monitoringu stanu zdrowotnego lasów z danych satelitarnych.

W latach 2015–2019 realizowany był projekt ForBioSensing, ukierunkowany na monitorowanie zmian środowiskowych w Puszczy Białowieskiej (Stereńczak 2022). W ramach projektu systematycznie pozyskiwano szeroki zakres danych – zarówno terenowych, jak i teledetekcyjnych – dokumentujących zmiany środowiskowe w okresie intensywnej gradacji kornika drukarza. Zgromadzone dane stanowią cenny materiał badawczy, który można wykorzystać do przeprowadzania licznych analiz środowiskowych. W niniejszej pracy skoncentrowano się na roku 2016, który stanowił apogeum rozwoju gradacji kornika drukarza. Celem artykułu jest przedstawienie możliwości wykorzystania danych satelitarnych do detekcji martwych drzew w Puszczy Białowieskiej oraz ocena potencjału integracji tych danych z danymi lotniczego skanowania laserowego (ALS) w identyfikacji pojedynczych martwych drzew. Analiza ta wpisuje się w szerszy kontekst badań nad zastosowaniem teledetekcji w monitoringu ekosystemów leśnych poddanych intensywnemu oddziaływaniu czynników stresowych.

2. Materiały badawcze i metodyka badawcza

2.1 Obszar badań

Polska część Puszczy Białowieskiej zajmuje powierzchnię około 62 000 ha, z czego 10 500 ha obejmuje Białowiecki Park Narodowy, około 12 000 ha to rezerwat przyrody, a pozostała część – blisko 39 500 ha – stanowi lasy gospodarcze zarządzane przez Lasy Państwowe (Stereńczak i in. 2017; Kamińska i in. 2021). Obszar cechuje się stosunkowo płaskim ukształtowaniem terenu, z wysokościami mieszczącymi się w przedziale około 144–176 m n.p.m. (Mielcarek i in. 2020). Puszcza charakteryzuje się wyjątkowym zróżnicowaniem siedlisk oraz bogactwem gatunkowym drzew. W roku 2015 dominującym gatunkiem w puszczy był świerk pospolity z łącznym udziałem mięszosioćwym ok. 32%, następnie sosna zwyczajna (*Pinus sylvestris* L.) (19,6%), olsza czarna (*Alnus glutinosa* Gaertn.) (14,9%), dąb (głównie *Quercus robur* L. i *Q. petraea* (Matt.) Liebl)

(11,5%), grab zwyczajny (*Carpinus betulus* L.) (8,8%) oraz brzoza (*Betula pendula* Roth i *B. pubescens* Ehrh.) (6%) (Miścicki i in. 2022). Rok 2015 był szczególnie suchy i gorący, co sprzyjało masowemu rozmnażaniu się kornika drukarza, który szczególnie intensywnie atakuje osłabione świerki (Grodzki 2016). Zjawisko to doprowadziło do istotnych zmian w strukturze drzewostanów, przyczyniając się do wzrostu śmiertelności świerków.

2.2. Dane teledetekcyjne

2.2.1. Dane satelitarne

Do analiz wykorzystano dane satelitarne pozyskane w 2016 roku z konstelacji satelitów Pléiades (Airbus Defence and Space), należącej do systemów obserwacji Ziemi o wysokiej rozdzielczości terenowej. Satelity Pléiades rejestrują dane w pięciu kanałach spektralnych, z GSD wynoszącym 2 m dla danych wielospektralnych oraz 0,5 m dla kanału panchromatycznego. Zakres spektralny obejmuje kanał niebieski (430–550 nm), zielony (490–610 nm), czerwony (600–720 nm), bliską podczerwień (750–950 nm) oraz kanał panchromatyczny (480–830 nm), co umożliwia szczegółową analizę stanu szaty roślinnej i struktury pokrycia terenu.

Zobrazowania obejmujące obszar Puszczy Białowieskiej zostały pozyskane 8 i 9 sierpnia 2016 roku. Aby zobrazować całą Puszczę do analiz wykorzystano trzy sceny satelitarne o numerach 5231, 5105 oraz 7235 (ryc. 1), na podstawie których utworzono mozaikę w celu uzyskania jednorodnego zbioru danych pokrywającego cały obszar badań. Ze względu na to, że zobrazowania zostały pozyskane pod różnymi kątami względem pionu, wynoszącymi odpowiednio 12,9°, 19,4° oraz 27°, na etapie mozaikowania zastosowano strategię doboru linii mozaikowania w taki sposób, aby maksymalizować udział scen pozyskanych pod najmniejszym kątem, przy jednoczesnym zminimalizowaniu powierzchni pokrytej zachmurzeniem, która w końcowym, zmozaikowanym obrazie Puszczy nie przekroczyła 5%.

Zestaw danych pozyskano na poziomie przetworzenia 1A, co oznacza, że obrazy zostały poddane wstępnej kalibracji radiometrycznej oraz podstawowej korekcji geometrycznej i atmosferycznej wykonanej przez dostawcę danych – firmę Airbus Defence and Space. Korekcja atmosferyczna została przeprowadzona z wykorzystaniem algorytmu LOWTRAN, który symuluje transmisję promieniowania przez atmosferę w oparciu o modele atmosferyczne. Wstępna korekcja geometryczna uwzględniała wyłącznie eliminację zniekształceń wynikających z niestabilności orbity satelity oraz rekonstrukcję warunków liniowego odwzorowania obrazu.

Z uwagi na wysoką precyzję wykonywanych analiz, przeprowadzono dodatkową korekcję geometryczną oraz ortorektyfikację danych. Proces ten został wykonany w środowisku ERDAS Imagine Professional 2015, przy wykorzystaniu pomiarów terenowych GPS jako danych kontrolnych oraz Numerycznego Modelu Terenu (NMT) o rozdzielczości 2 m. Model ten został opracowany na podstawie danych lotniczego skanowania

laserowego (szczegóły w podrozdziale 2.2.2.).

W efekcie przeprowadzonych działań uzyskano zestaw zobrazowań satelitarnych o wysokiej jakości geometrycznej i radiometrycznej, który stanowił podstawę do dalszych analiz teledetekcyjnych, w tym detekcji zmian stanu zdrowotnego drzew na terenie Puszczy Białowieskiej.

2.2.2. Dane lotniczego skanowania laserowego

Dane lotniczego skanowania laserowego zostały pozyskane w okresie pełnego ulistnienia drzewostanów, w dniach od 2 do 5 lipca 2015 roku. Pomiary wykonano z wykorzystaniem skanera Riegl LMS-Q680i, działającego w trybie rejestracji pełnej fali (ang. full waveform). Średnia gęstość chmury punktów wyniosła 11 punktów/m², a nalot przeprowadzono z wysokości około 500 metrów nad poziomem terenu. Wymiar śladu wiązki laserowej (ang. footprint) wynosił 0,25 m, natomiast maksymalny kąt skanowania dochodził do $\pm 30^\circ$.

Aby zapewnić pełne pokrycie analizowanego obszaru Puszczy Białowieskiej, zrealizowano 135 pasów nalotu, przy zachowaniu 40% pokrycia sąsiednich linii (ang. overlap). Uzyskane dane ALS posłużyły do wygenerowania Numerycznego Modelu Terenu (NMT) oraz Numerycznego Modelu Pokrycia Terenu (NMPT) o rozdzielczości przestrzennej 0,5 m. Modele te stanowiły podstawę do obliczenia tzw. Wysokościowego Modelu Koron (WMK).

Równoległe z nalotem ALS wykonano także zdjęcia lotnicze w barwach bliskiej podczerwieni (ang. Color Infrared – CIR), przy użyciu kamery UltraCam Eagle. Zdjęcia pozyskano z wysokości 3040 m, uzyskując GSD wynoszące 0,20 m. Łącznie wykonano 1372 zdjęcia, przy czym pokrycie podłużne i poprzeczne wyniosło odpowiednio 90% i 40%. Każdy punkt chmury ALS został powiązany z odpowiednim fragmentem ortorektyfikowanego obrazu CIR, dzięki czemu możliwe było przypisanie wartości spektralnych w kanałach bliskiej podczerwieni, czerwonym i zielonym do poszczególnych punktów.

Dane ALS wykorzystano w procesie segmentacji poszczególnych drzew (Stereficzak i in. 2020). Następnie wykonano obiektową klasyfikację gatunkową (Kamińska i in. 2018) przy-

pisując każdy segment do jednej z 6 klas: sosna, świerk, drzewa liściaste w podziale na żywe i martwe. Tak przygotowaną warstwę segmentów wykorzystano w prowadzonych analizach. W ramach prezentowanych badań dane ALS przetwarzano jedynie w celu wygenerowania warstwy luk w drzewostanie.


2.3. Przetwarzanie wstępne

Wstępne przetwarzanie danych satelitarnych stanowiło kluczowy etap przygotowawczy do dalszej analizy klasyfikacyjnej. Proces ten obejmował eliminację obszarów zacienionych oraz obszarów o wysokości mniejszej niż 2 m (luki w drzewostanie), które mogły negatywnie wpływać na dokładność wyników klasyfikacji pikselowej (ryc. 2).

Procedura usuwania (maskowania) cieni została przeprowadzona na podstawie wartości progowych kanału odpowiadającego zakresowi zieleni zobrazowań satelitarnych. W celu dopasowania wartości progowych dla maski cieni, każda scena satelitarna została podzielona na mniejsze jednostki przestrzenne uzyskując łącznie 11 obszarów. Podział był niezbędny ze względu na znaczące zróżnicowanie warunków atmosferycznych w obrębie jednej sceny, przekładające się na różnice radiometryczne. Dla każdego z wydzielonych obszarów ustalono indywidualny próg detekcji cienia, a uzyskane maski poddano procesowi mozaikowania. Ostatecznie, przy ich użyciu usunięto piksele zacienione z analizowanych zobrazowań satelitarnych.

Maska luk utworzona została na podstawie danych z Wysokościowego Modelu Koron (WMK) wykonanego na podstawie danych ALS. Proces generowania luk, a następnie maskowania zobrazowań satelitarnych przeprowadzono w środowisku R. Opracowany algorytm umożliwia generowanie rastrowej maski luk dla dowolnego zobrazowania teledetekcyjnego, tzn. układ pikseli mapy odpowiada układowi pikseli obrazu źródłowego, co umożliwia bezpośrednie operacje algebry map bez konieczności przepróbkowania wartości. Etapy wytwarzania maski obejmowały następujące kroki:

- Wygenerowanie binarnej maski luk na podstawie WMK o rozdzielczości 0,5 m, przy założeniu, że piksele o wysokości poniżej 2 m reprezentują luki;



Rycina 1. Zasięg zobrazowań satelitarnych wykonanych dla obszaru badań
Figure 1. Extent of satellite imagery acquired for study area

- Utworzenie pustego rastra o rozdzielczości odpowiadającej obrazowi satelitarnemu (2 m w przypadku danych z systemu Pléiades);
- Wartości pikseli pustego rastra zostały wyliczone z maski luk opracowanej z WMK (o rozdzielczości 0,5 m) w taki sposób, że uzyskano wartość procentową pikseli luk z WMK, mieszczących się w obrębie danego piksela rastra;
- Reklasyfikacja rastra luk do postaci binarnej, poprzez przypisanie wartości 0 pikselom poniżej ustalonego progu procentowego wynoszącego 50%, a wartości 1 – pikselom o udziale równym lub większym niż 50%.

Aby poprawić jakość maski luk, wygenerowanej w rozdzielczości 2 m, zastosowano dodatkowy algorytm filtrujący niewielkie skupiska pikseli o zbyt małej powierzchni. Procedura ta przebiegała według następującego schematu:

- Grupowanie sąsiadujących pikseli w ciągle obszary przy zastosowaniu metody rozrostu regionów (ang. Region growing) (Tianyang 2018). W ramach algorytmu kolejne niesklasyfikowane piksele były przyłączane do rosnących obszarów na podstawie ich sąsiedztwa (góra–dół–lewo–prawo);
- Przypisanie unikalnych wartości każdej grupie pikseli, co umożliwiło określenie liczebności grup;
- Usunięcie grup, których rozmiar nie przekraczał zdefiniowanego progu (w analizie przyjęto wartość 5 pikseli);
- Reklasyfikacja pozostałych grup do postaci binarnej maski luk.

Dane ALS oraz produkty powstałe na ich podstawie charakteryzowały się inną geometrią w porównaniu z danymi satelitarnymi, dlatego konieczne było uwzględnienie różnic w kacie akwizycji poszczególnych scen satelitarnych oraz wynikowych

masek. W związku z tym, dla każdej sceny dokonano przesunięcia odpowiadającej jej maski o odpowiednią liczbę pikseli, tak aby zapewnić precyzyjne dopasowanie przestrzenne do rzeczywistego położenia luk widocznych na obrazowaniach satelitarnych.


Przetwarzanie wstępne danych satelitarnych miało na celu eliminację zakłóceń wynikających z obecności cieni oraz luk w drzewostanie, które mogły obniżyć jakość klasyfikacji drzew martwych na obszarze Puszczy. Wynikiem tego procesu było uzyskanie wysokiej jakości rastrowych masek cieni i luk, w pełni zgodnych geometrycznie z analizowanymi obrazowaniami satelitarnymi, co umożliwiło ich bezpośrednie wykorzystanie w dalszych operacjach analizy przestrzennej.

2.4. Dane treningowe, weryfikacyjne i kalibracyjne

W procesie klasyfikacji oraz detekcji pojedynczych martwych drzew wykorzystano trzy zestawy danych referencyjnych. Dla klasyfikacji pikselowej opracowano zbiór danych treningowych oraz danych weryfikacyjnych, zaś dla procesu integracji danych satelitarnych z danymi ALS – zbiór danych kalibracyjnych. Każdy z tych zestawów został opracowany niezależnie i dostosowany do specyfiki analizowanego problemu oraz charakterystyki danych.

Zbiór danych treningowych do klasyfikacji zdjęć satelitarnych został opracowany w oparciu o fotointerpretację obrazowań, przy czym szczególną uwagę zwrócono na równomierne rozmieszczenie próbek w obrębie każdej sceny satelitarnej. Obszary treningowe (poligony) obejmowały trzy klasy: 1 – drzewa martwe, 2 – drzewa iglaste, 3 – drzewa liściaste i posłużyły do uczenia algorytmu klasyfikacyjnego. Łącznie dla danych wyznaczono 396 poligonów (tab. 1).

Zbiór danych weryfikacyjnych klasyfikacji składał się



Rycina 2. Schemat metodyki badawczej

Figure 2. Schematic overview of the methodological workflow

z dwóch niezależnych zestawów punktów. Pierwszy z nich obejmował punkty rozmieszczone równomiernie co 500 m na terenie całej Puszczy, oraz ze względu na niedostateczną liczebność punktów reprezentujących martwe drzewa, punkty wyznaczone dodatkowo przez fotointerpretatora. Drugi zestaw weryfikacyjny stanowiły punkty pozyskane na piętnastu stałych powierzchniach badawczych, służące do weryfikacji klasyfikacji martwych drzew. Łączna liczba punktów weryfikacyjnych wynosiła 4689. Zestawienie liczebności punktów w podziale na klasy przedstawiono w tabeli 2.

Trzeci zestaw danych posłużył do kalibracji modelu służącego do detekcji pojedynczych martwych drzew oraz do oceny jego dokładności. Dane te wykorzystywane były w procesie łączenia zobrażeń satelitarnych ze sklasyfikowanymi segmentami koron drzew wyodrębnionymi na podstawie danych ALS. W pierwszej kolejności z Leśnej Mapy Numerycznej losowo wybrano 23 wydzielania leśne dla których gatunkiem panującym był świerk, uwzględniając różny procentowy udział tego gatunku w wydzielaniu (od 20 do 70%) oraz po dwa wydzielania, w których gatunek panującym był dąb lub brzoza. Dla tych wydzieleń leśnych, wyselekcjonowano segmenty kalibracyjne z istniejącej bazy segmentów drzew, zaklasyfikowanych na podstawie danych ALS z 2015 r. jako drzewa martwe lub iglaste. Następnie dokonano ręcznej weryfikacji każdego segmentu i przypisano mu odpowiednią klasę (drzewo żywe lub martwe), zgodną ze stanem widocznym na zobrażowaniu satelitarnym z 2016 r. W przypadku wątpliwości, związanych z przesunięciem między danymi satelitarnymi a segmentami, do poprawnej

identyfikacji poszczególnych drzew, jako materiał pomocniczy wykorzystywano dodatkowe źródła danych w tym ortofotomapę wykonaną w 2015 r. Szczegółowe zestawienie liczby segmentów kalibracyjnych dla poszczególnych zobrażeń przedstawiono w tabeli 3.

2.5. Klasyfikacja zobrażeń satelitarnych

Podstawowym celem klasyfikacji było wyodrębnienie drzew martwych. Biorąc jednak pod uwagę istotne różnice spektralne pomiędzy drzewami liściastymi a iglastymi, zdecydowano o rozszerzeniu klasyfikacji do trzech klas – drzewa martwe, iglaste i liściaste. Klasyfikację zobrażeń wykonano metodą klasyfikacji nadzorowanej. Wykorzystano algorytm największego prawdopodobieństwa (ang. Maximum Likelihood) w oprogramowaniu ERDAS Imagine Professional 2015. Następnie połączono wyniki klasyfikacji zgodnie z przebiegiem linii mozaikowania danych, uzyskując w ten sposób jedną spójną warstwę dla całego obszaru Puszczy Białowieskiej. W celu ograniczenia analizy do rzeczywistego zasięgu lasów, wyniki klasyfikacji przycięto do granic wydzieleń leśnych, zgodnie z aktualną Leśną Mapą Numeryczną, a następnie usunięto ze zobrażenia obszary zachmurzone. Z uwagi na brak skutecznych automatycznych metod rozróżniania pikseli zachmurzenia i martwych drzew (które w niektórych kanałach spektralnych wykazywały podobne wartości odbicia), zastosowano maskę wektorową przygotowaną manualnie na podstawie interpretacji wizualnej.

Oceny dokładności wyników klasyfikacji dokonano z wyko-

Tabela 1. Poligony treningowe wykorzystywane do klasyfikacji nadzorowanej

Table 1. Training polygons used for supervised classification

Zobrazowanie / Image ID	Klasa / Class	Zbiór danych treningowych / Training dataset		
		Liczba poligonów Number of polygons	Liczba pikseli Number of pixels	Powierzchnia [m ²] Area [m ²]
5105	1	51	268	1072
	2	37	202	808
	3	38	467	1868
	Suma / Total	126	937	3748
5231	1	38	179	716
	2	43	470	1880
	3	37	365	1460
	Suma / Total	118	1014	4056
7235	1	55	155	620
	2	57	540	2160
	3	40	549	2196
	Suma / Total	152	1244	4976

Tabela 2. Liczba punktów weryfikacyjnych użytych do oceny klasyfikacji

Table 2. Number of validation points used for the classification accuracy assessment

Klasa / Class	Liczba punktów weryfikacyjnych Number of validation points		
	Siatka punktów / Grid points	Punkty terenowe / Field points	Suma / Total
1	1474	241	1715
2	795	845	1640
3	1146	188	1334

Tabela 3. Liczba segmentów kalibracyjnych wyznaczonych dla zobrażeń satelitarnych

Table 3. Number of calibration segments delineated for use with satellite imagery

Zobrazowanie Image ID	Liczba wybranych wydzieleń Number of selected stands	Liczba segmentów kalibracyjnych Number of calibration segments
5231	8	14 774
5105	12	13 629
7235	7	21 515

rzystaniem niezależnego zbioru punktów weryfikacyjnych, których opracowanie opisano w rozdziale 2.4. Dla zmozaikowanej warstwy klasyfikacyjnej obliczono macierz błędów, która pozwala ocenić skuteczność przypisania pikseli do poszczególnych klas.

Na podstawie macierzy błędów wyznaczono standardowe miary dokładności klasyfikacji, w tym:

– dokładność całkowitą – udział prawidłowo sklasyfikowanych pikseli w stosunku do wszystkich punktów weryfikacyjnych, wyrażoną wzorem:

$$OA = \frac{\sum_{i=1}^k x_{ii}}{N} \quad (1)$$

– dokładność użytkownika – prawdopodobieństwo, że piksel przypisany do danej klasy rzeczywiście jej odpowiada (miara precyzji), wyrażoną wzorem:

$$UA = \frac{x_{ii}}{x_{i+}} \quad (2)$$

– dokładność producenta – prawdopodobieństwo, że piksel danej klasy został prawidłowo sklasyfikowany (miara czułości), wyrażoną wzorem:

$$PA = \frac{x_{ii}}{x_{i+}} \quad (3)$$

– miarę F1-score – średnią harmoniczną dokładności użytkownika (UA, precyzja) i dokładności producenta (PA, czułość), stanowiącą wskaźnik jakości danej klasy, wyrażoną wzorem:

$$F1_i = 2 * \frac{UA_i * PA_i}{UA_i + PA_i} \quad (4)$$

2.6. Detekcja pojedynczych drzew martwych

Proces detekcji pojedynczych martwych drzew przeprowadzono w oparciu o analizę danych z obrazowań satelitarnych pozyskanych w 2016 roku oraz segmentów kalibracyjnych reprezentujących pojedyncze korony drzew. W ramach detekcji analizowano dwa kluczowe atrybuty dla każdego segmentu korony drzewa: (1) odległość centroidu segmentu od obszaru sklasyfikowanego na obrazowaniu satelitarnym jako martwe drzewo oraz (2) procent powierzchni segmentu pokryty przez piksele sklasyfikowane jako martwe drzewa. Segment uznawano za reprezentujący martwe drzewo, jeśli spełniał warunek:

$odlmartwe \leq x \text{ AND } procentmartwe \geq y$

gdzie:

$odlmartwe$ – odległość centroidy segmentu od obszaru sklasyfikowanego jako martwe drzewo,

x – graniczna wartość odległości, $procentmartwe$ – procent pokrycia segmentu przez obszar sklasyfikowany jako martwe drzewo,

y – graniczna wartość pokrycia.

Z uwagi na różne kąty wychylenia sensora w czasie pozyskiwania obrazowań satelitarnych, każde obrazowanie analizowa-

no osobno uwzględniając przesunięcie względem danych ALS. Dla każdego obrazu obliczono atrybuty odlmartwe i procentmartwe, po czym przeprowadzono optymalizację wartości granicznych x i y z wykorzystaniem segmentów kalibracyjnych opisanych w poprzednim podrozdziale 2.4. Optymalizacja granicznych wartości atrybutów przebiegała w środowisku R według opracowanego automatycznego algorytmu. Segmenty kalibracyjne w każdym wydzieleniu podzielono na obszary 50x50 m, co umożliwiło zwiększenie liczby niezależnych prób wykorzystanych w procesie kalibracji. Dla zobrazowania 5105 uzyskano łącznie 171 obszarów pokrytych segmentami kalibracyjnymi, dla zobrazowania 5231 – 195 obszarów, a dla zobrazowania 7235 – 295 obszarów. Następnie obszary te losowo rozdzielono na wewnętrzny zbiór kalibracyjno-walidacyjny (70%) i zbiór walidacji zewnętrznej (30%). W ramach 1000 iteracji przy wykorzystaniu wewnętrznego zbioru kalibracyjno-testowego sprawdzano kombinacje progów odległości (0–5 m) i pokrycia (0–100%), wybierając te, które spełniały kryteria skuteczności ($segtrue \geq 60\%$ i $segfalse \leq 30$; gdzie $segtrue$ – liczba segmentów pokrywających się z referencją podzielona przez liczbę drzew referencyjnych; $segfalse$ – liczba segmentów niepokrywających się z referencją podzielona przez liczbę drzew referencyjnych). Spośród nich wybrano najczęściej występującą parę progową jako optymalną. Na tej podstawie wygenerowano warstwę martwych drzew dla całego obszaru, którą następnie zweryfikowano przy użyciu zbioru walidacji zewnętrznej.

3. Wyniki

3.1 Klasyfikacja obrazowań satelitarnych

Wyniki klasyfikacji obrazowań satelitarnych wykonanych dla obszaru Puszczy Białowieskiej zaprezentowano w dwóch wariantach: 1. w podziale na trzy klasy: drzewa martwe, drzewa iglaste, drzewa liściaste (tab. 4) oraz 2. z uproszczonym podziałem binarnym: drzewa martwe i klasa drzewa żywe (tab. 5).

W przypadku wyników klasyfikacji trójklasowej, dla mozaiki obrazowań uzyskano całkowitą dokładność klasyfikacji na poziomie 89,9%, przy F1-score wynoszącym 0,896. Dokładność użytkownika dla klasy drzewa martwe wyniosła 94,6%, dla klasy drzewa iglaste 82,6%, a dla drzew liściastych 94,1%. Dokładność producenta dla tych samych klas wyniosła odpowiednio: 96,8%, 90,2% oraz 80,7%, a F1-score: 0,957, 0,862, 0,869.

W uproszczonym wariancie klasyfikacji binarnej, obejmującym jedynie klasy drzewa martwe i drzewa żywe osiągnięto całkowitą dokładność wyników klasyfikacji na poziomie 96,8%, przy F1-score wynoszącym 0,966. Dokładność użytkownika dla klasy drzew martwych wyniosła 94,6%, natomiast dla klasy drzew żywych 98,1%, podczas gdy dokładność producenta wyniosła w obu przypadkach 96,8%. F1-score wyniósł odpowiednio 0,957 dla drzew martwych i 0,975 dla drzew żywych. Mapy wynikowe przedstawiające rozmieszczenie drzew martwych na podstawie klasyfikacji przedstawiono na rycinie 3.

Tabela 4. Macierz błędów dla wyników klasyfikacji w podziale na 3 klasy


Table 4. Confusion matrix for three-class classification

Klasyfikacja Classification	Drzewa martwe Dead trees	Drzewa iglaste Coniferous trees	Drzewa liściaste Deciduous trees	PA
Referencja Reference				
Drzewa martwe Dead trees	1660	55	0	96,8%
Drzewa iglaste Coniferous trees	94	1479	67	90,2%
Drzewa liściaste Deciduous trees	1	257	1076	80,7%
UA	94,6%	82,6%	94,1%	OA = 89,9%

Tabela 5. Macierz błędów dla wyników klasyfikacji w podziale na 2 klasy

Table 5. Confusion matrix for binary classification

Klasyfikacja Classification	Drzewa martwe Dead trees	Drzewa żywe Alive trees	PA
Referencja Reference			
Drzewa martwe Dead trees	1660	55	96,8%
Drzewa żywe Live trees	95	2879	96,8%
UA	94,6%	98,1%	OA=96,8%



Rycina 3. Wyniki klasyfikacji zobrazowań w podziale na dwie klasy

Figure 3. Classification results using a binary class scheme

3.2 Detekcja pojedynczych drzew martwych

Na podstawie wyników klasyfikacji danych satelitarnych oraz segmentów wygenerowanych z lotniczego skanowania laserowego wyznaczono wartości graniczne parametrów selekcji martwych drzew dla poszczególnych zobrazowań satelitarnych. Wartości te zostały opracowane i wybrane w oparciu o wewnętrzne zestawy danych kalibracyjno – walidacyjnych i zestawione poniżej (tab. 6).

Na podstawie wybranych parametrów, dla każdej sceny satelitarnej oszacowano liczbę martwych drzew (tab. 7). Należy jednak podkreślić, że wartości te nie są ostateczną liczbą martwych drzew występujących na terenie całej Puszczy Białowieskiej. Każde zobrazowanie analizowane było niezależnie ze względu na różne kąty odchylenia sensora od nadiru, co oznacza, że obiekty występujące w obszarach nakładania się scen mogły zostać policzone wielokrotnie.

W celu oszacowania rzeczywistej liczby martwych drzew, poszczególne warstwy wynikowe poddano dalszemu procesowi łączenia, zgodnie z wcześniej określonymi liniami mozaikowa-

nia. Dopiero na podstawie połączonego zbioru danych, odpowiadającego spójnemu pokryciu całej polskiej części Puszczy Białowieskiej, wyznaczono ostateczną liczbę martwych świerków, którą poddano weryfikacji na podstawie niezależnego zbioru walidacji zewnętrznej. Liczbę martwych świerków w podziale na poszczególne nadleśnictwa oraz BPN przedstawiono w tabeli 8, zaś wyniki oceny dokładności detekcji pojedynczych martwych świerków w tabeli 9.

Na rycinie 4 przedstawiono fragment obszaru Puszczy Białowieskiej ilustrujący kolejne etapy procesu prowadzącego do ekstrakcji pojedynczych martwych drzew. Ostatni panel obrazuje różnice w lokalizacji centroidów martwych drzew zidentyfikowanych na podstawie danych ALS względem ich pozycji na zobrazowaniach satelitarnych pozyskanych pod określonym kątem wychylenia sensora od nadiru. Zjawisko to wynika z geometrycznych przesunięć obiektów koron drzew w zależności od kąta akwizycji obrazu oraz wysokości drzewa. Częściowa korekta tego przesunięcia umożliwiła dokładniejsze dopasowanie położenia drzewa i wybór odpowiadających im obiektów w danych ALS. Na kolejnej rycinie (5) zaprezentowano nato-

Tabela 6. Wartości progowe parametrów selekcji drzew martwych

Table 6. Threshold values of parameters applied in dead tree selection

Zobrazowanie Image ID	Odległość [m] Distance [m]	Pokrycie [%] Coverage [%]	segtrue [%]	segfalse [%]
5105	1,4	10	76,6	16,6
5231	2,2	10	83,1	35,5
7235	1,8	40	52,4	23,8

Tabela 7. Liczba drzew martwych wyznaczona na podstawie pojedynczych zobrazowań satelitarnych

Table 7. Number of dead trees identified from individual satellite scenes

Zobrazowanie Image ID	Liczba drzew Number of trees
5105	276 172
5231	92 657
7235	140 522

Tabela 8. Szacunkowa liczba martwych świerków w Puszczy Białowieskiej w 2016 roku


Table 8. Estimated number of dead Norway spruce trees in the Białowieża Forest in 2016

Nadleśnictwo Forest District	Liczba martwych świerków Number of dead spruces
Białowieża	190 400
Browski	85 124
Hajnówka	77 916
BPN	27 703
Ogółem / Total	381 143

Tabela 9. Dokładność detekcji martwych drzew na podstawie integracji danych satelitarnych z danymi ALS w 2016 r

Table 9. Accuracy of dead tree detection based on the integration of satellite and ALS data in 2016

segtrue [%]	segfalse [%]
71,1	22,0



Rycina 4. Zobrazowanie satelitarne (A), wynik klasyfikacji martwych drzew z uwzględnieniem warstw luk i cieni (B) oraz centroidy martwych drzew wygenerowane w wyniku integracji klasyfikacji z segmentacją danych ALS (C)

Figure 4. Satellite imagery (A), classification of dead trees with delineated gap and shadow layers (B), and centroids of dead trees derived from the integration of classification and ALS-based crown segmentation (C)


miast mapę wszystkich centroidów martwych świerków zidentyfikowanych na obszarze Puszczy Białowieskiej, opracowaną w wyniku integracji informacji pozyskanych z danych ALS oraz satelitarnych.

4. Dyskusja

Analiza obrazowań wielospektralnych, w tym satelitarnych, odgrywa istotną rolę w monitoringu zamierania drzew, stanowiąc ważny element współczesnych metod teledetekcyjnych wykorzystywanych w badaniach ekosystemów leśnych. Zastosowanie obrazów satelitarnych, dzięki ich systematycznemu pozyskaniu, szerokiemu zasięgowi przestrzennemu oraz rosnącej rozdzielczości terenowej i spektralnej, pozwala na prowadzenie analiz zmian dużych kompleksów leśnych w długiej perspektywie czasowej, przy niewielkich nakładach finansowych (Abdollahnejad i in. 2019; Gavilan-Acuna i in. 2025). Dane lotnicze (w tym dane ALS), charakteryzują się znacznie wyższą rozdzielczością terenową, co umożliwia detekcję zmian na poziomie pojedynczych drzew. W porównaniu do danych

satelitarnych są one mniej podatne na zakłócenia atmosferyczne, a ich akwizycję można dopasować do istniejących warunków pogodowych i oświetleniowych. Wadą jest jednak wysoki koszt pozyskania oraz ograniczony zasięg przestrzenny w porównaniu do danych satelitarnych.

Szczególnie obiecujące rezultaty przynosi łączenie danych spektralnych z danymi ALS (Kamińska i in. 2018; Lisiewicz i in. 2025). Na podstawie danych ALS można uzyskać informację o pojedynczym drzewie, jego wysokości, strukturze, a także obliczyć miąższość. Z kolei dane obrazowe można wykorzystać do oceny fizjologicznego stanu drzew. Integracja tych dwóch źródeł pozwala na bardziej kompleksową ocenę stanu zdrowotnego drzewostanów, a także przestrzennego zróżnicowania tych procesów. Silne natężenie gradacji kornika drukarza, mogące utrzymywać się przez kilka sezonów wegetacyjnych, wymaga prowadzenia systematycznego monitoringu drzewostanów świerkowych. W takich warunkach, częste pozyskiwanie danych lotniczego skanowania laserowego, szczególnie dla dużych kompleksów leśnych, staje się przedsięwzięciem kosztownym i logistycznie wymagającym. Dlatego w niniej-



Rycina 5. Mapa pojedynczych martwych świerków
Figure 5. Map of individual dead Norway spruce trees

szym opracowaniu podjęto próbę integracji satelitarnych danych wielospektralnych z danymi ALS pozyskanymi w roku poprzedzającym pozyskanie scen satelitarnych, w celu oceny przydatności takiego podejścia do identyfikacji pojedynczych martwych drzew.

W celu oceny wiarygodności zastosowanej metody detekcji martwych drzew przeprowadzono porównanie uzyskanych wyników z istniejącymi danymi z 2016 roku. Dla Nadleśnictwa Białowieża, według danych prezentowanych przez Ginszt i Laskowską-Ginszt (2022), liczba drzew trocinkowych w 2016 roku wyniosła 200 761 osobników. Wyniki uzyskane w niniejszym badaniu, oparte na analizie danych satelitarnych zintegrowanych z danymi ALS wskazują na obecność 190 400 martwych świerków w obrębie tego samego nadleśnictwa. Choć drzewa zasiedlonego przez kornika nie można bezpośrednio uznać za martwe, to przy skali zjawiska obserwowanej w 2016 roku oraz uwzględniając fakt, że dane satelitarne pozyskano w sierpniu, zbieżność tę należy uznać za zadowalającą, szczególnie biorąc pod uwagę ograniczenia zobrażeń satelitarnych, które stanowią narzędzie do detekcji zmian jedynie w górnej części okapu leśnego, bez możliwości oceny struktury pionowej i martwych drzew zasłoniętych przez wyższe piętra drzewostanu.


Dla całego obszaru Puszczy Białowiejskiej liczba martwych świerków oszacowana w prezentowanej analizie wyniosła 381 143. Jest to wartość wyższa o ok. 12,5% niż ta, wyznaczona dla roku 2015 na podstawie metody opracowanej przez Lisiewicz i in. (2025) z danych ALS. Różnica ta nie wynika jedynie z realnego przyrostu liczby martwych drzew w ciągu jednego sezonu wegetacyjnego, ale również z odmiennych założeń metodycznych i różnych ograniczeń wynikających z samego pozyskania danych. W szczególności należy podkreślić, że rozdzielczość terenowa danych wielospektralnych wziętych do analiz w obydwu opracowaniach różni się dziesięciokrotnie (2 m dla danych satelitarnych i 0,2 m dla danych lotniczych), dlatego możliwość detekcji danych satelitarnych jest znacznie mniejsza, szczególnie w przypadku pojedynczych martwych drzew występujących w otoczeniu zdrowych drzew liściastych czy iglastych. Ten przypadek widoczny jest szczególnie na terenie Białowiejskiego Parku Narodowego (BPN), gdzie drzewostany charakteryzują się wysokim stopniem zróżnicowania gatunkowego i strukturalnego. Obecność domieszki licznych gatunków liściastych, a także mozaikowy układ drzewostanu powodują, że korony drzew martwych są częściowo przesłonięte przez korony sąsiadujących drzew żywych. W efekcie całość drzewa (w przypadku małych drzew), lub jego fragment odwzorowany jest przez piksel niejednorodny spektralnie, będący mieszaniną sygnału odbitego od drzewa żywego i martwego. Na etapie klasyfikacji pikselowej tego typu osobniki często są pomijane, lub identyfikowane jako pojedynczy piksel przypisany do klasy „martwe drzewo”. Tak mały powierzchniowo obszar, w kolejnym etapie podczas integracji danych satelitarnych z warstwą segmentów z danych ALS, jest często pomijany. Skutkuje to zaniżoną detekcją pojedynczych drzew martwych w stosunku do tej prowadzonej na danych ALS z wykorzysta-

niem lotniczych zobrażeń wielospektralnych o rozdzielczości terenowej (GSD) kilkunastu cm. W przypadku obszaru BPN różnica między wynikami uzyskanymi metodą zaprezentowaną przez Lisiewicza i in. (2025) a rezultatami niniejszego opracowania sięga aż ok. 50% – odpowiednio 56 400 martwych drzew dla roku 2015 w porównaniu z 27 703 drzewami martwymi dla roku 2016. Nieco mniejsza skala tego zjawiska została zaobserwowana w pozostałych rezerwach przyrody zlokalizowanych na terenie Puszczy Białowiejskiej, gdzie pomiędzy kolejnymi sezonami wegetacyjnymi odnotowano spadek liczby martwych drzew o ok. 11%. Odmienny trend zidentyfikowano natomiast w lasach gospodarczych, dla których analiza wykazała wzrost liczby martwych drzew w porównaniu rok do roku, sięgający ok. 41%. Biorąc pod uwagę, że liczba martwych świerków na terenie całej Puszczy Białowiejskiej wykazywała wyraźną tendencję wzrostową w analizowanym okresie, uzyskany w niniejszej pracy wynik dla rezerwatów i BPN należy uznać za znacznie niedoszacowany. Wskazuje to na istotne ograniczenia zastosowania zobrażeń satelitarnych w detekcji pojedynczych drzew martwych w drzewostanach o wysokim zróżnicowaniu pionowym i gatunkowym. Podobne wnioski zaprezentowano w artykule Jutras-Perreault i in. (2023), gdzie jednoznacznie stwierdzono, że wykorzystanie danych satelitarnych w badaniach pojedynczych drzew prowadzi w pierwszej kolejności do znacznego błędu niedoszacowania czułość (ang. recall) wahała się w przedziale 0,08 do 0,39, przeszacowania precyzja (ang. precision) wahała się w przedziale 0,49 do 0,70.

Integracja segmentów koron drzew wygenerowanych na podstawie danych ALS ze zobrażowaniami satelitarnymi pozyskanymi w odmiennym sezonie wegetacyjnym może prowadzić do błędnej klasyfikacji niektórych obszarów w sytuacji, gdy np. w analizowanym okresie wykonano cięcia sanitarne, a teren nie został jeszcze uprzątnięty lub powierzchnia gleby została odsłonięta w znacznym stopniu. Ze względu na zbieżność charakterystyk spektralnych tych powierzchni do sygnału generowanego przez obumarłe korony drzew w zakresie kanałów widzialnych i bliskiej podczerwieni, istnieje ryzyko przypisania pozostałości zrębowych bądź odkrytej gleby do klasy martwych drzew. Natomiast w przypadku gdy obszar pozrębowy został wtórnie pokryty roślinnością zielną lub krzewiastą, obszary te zostaną błędnie sklasyfikowane jako drzewa żywe.

W odniesieniu do Puszczy Białowiejskiej, w okresie pomiędzy rokiem 2015 a 2016 nie prowadzono szeroko zakrojonych prac związanych z pozyskaniem drewna. Jedynie lokalnie, głównie w obrębie Nadleśnictwa Białowieża, zidentyfikowano kilka niewielkich powierzchni, na których mogły wystąpić wspomniane zjawiska. Analiza tych obszarów wykazała, że w części z nich nie zaobserwowano istotnych błędów klasyfikacyjnych, podczas gdy w innych przypadkach problem ten pojawiał się sporadycznie, co zilustrowano na rycinie 6.

W kontekście planowania integracji danych ALS i satelitarnych pozyskanych w różnych latach kalendarzowych, zasadne wydaje się pozyskanie informacji o rzeczywistie przeprowadzonych zabiegach gospodarczych bezpośrednio z właściwego nadleśnictwa. Informacje te mogą posłużyć do ręcznego wyłączenia



Rycina 6. Przykład nowo powstałej luki widocznej na zobrazeniach z 2016 roku

Figure 6. Example of a newly formed canopy gap observed in an image from 2016

czenia tych powierzchni z dalszych analiz lub przygotowania maski na podstawie danych z Leśnej Mapy Numerycznej, którą można wykorzystać do automatycznej eliminacji wydzieli poddanych zabiegom pielęgnacyjnym bądź sanitarnym. Takie podejście pozwala ograniczyć ryzyko błędnej interpretacji danych i zwiększyć wiarygodność wyników końcowych klasyfikacji.

Przeprowadzona analiza potwierdza użyteczność integracji satelitarnych danych wielospektralnych z danymi lotniczego skanowania laserowego (ALS) w ocenie stopnia zamierania drzewostanów świerkowych w Puszczy Białowieskiej. Wyniki wskazują jednak na istotne ograniczenia tej metody, szczególnie w złożonych warunkach leśnych charakteryzujących się dużym zróżnicowaniem gatunkowym i złożoną strukturą drzewostanu. Mimo tych ograniczeń, zaproponowane podejście może stanowić efektywną i relatywnie niską kosztową alternatywę dla tradycyjnych kampanii lotniczych, umożliwiając prowadzenie zautomatyzowanego, długoterminowego monitoringu zmian zdrowotności drzewostanów w skali regionalnej.

5. Wnioski

Wyniki przedstawione w niniejszym opracowaniu wskazują, że integracja wielospektralnych obrazów satelitarnych z danymi lotniczego skanowania laserowego (ALS) może stanowić efektywne narzędzie do identyfikacji i monitoringu drzewostanów zamierających, szczególnie na dużych obszarach leśnych. Połączenie informacji o pojedynczym drzewie, pochodzącej z danych ALS z informacją spektralną danych wielospektralnych umożliwia uzyskanie bardziej kompleksowego obrazu stanu zdrowotnego lasu.

Zastosowana metoda okazała się skuteczna szczególnie na

poziomie tych wydzieli leśnych, które charakteryzują się mniej złożoną strukturą gatunkową oraz pionową. Jednocześnie badanie wykazało, że dokładność detekcji martwych drzew przy wykorzystaniu danych satelitarnych istotnie maleje w warunkach silnego zróżnicowania gatunkowego, jakie ma miejsce w Białowieskim Parku Narodowym. Ograniczenia te wynikają przede wszystkim z gorszej rozdzielczości terenowej danych satelitarnych oraz braku możliwości obserwacji niższych warstw drzewostanu.

Analiza wykazała również istotne znaczenie spójności czasowej pomiędzy danymi ALS i satelitarnymi, na co szczególnie należy zwrócić uwagę w przypadku integracji danych pozyskanych w znacznie bardziej odległych przedziałach czasowych (np. kilkuletnich). W takich przypadkach ryzyko błędnej klasyfikacji, zwłaszcza na obszarach objętych cięciami sanitarnymi lub innymi intensywnymi zmianami pokrycia terenu, może być istotnie większe. Należy jednak podkreślić, że potencjalne skutki rozbieżności czasowej danych mogą być stosunkowo łatwo eliminowane poprzez maskowanie wydzieli leśnych, w obrębie których prowadzono wycinkę drzew.

Zaproponowana metoda może stanowić cenne uzupełnienie dotychczasowych technik teledetekcyjnych stosowanych w leśnictwie, zwłaszcza w kontekście systematycznego i efektywnego pod względem kosztów monitoringu drzewostanów. Dzięki wykorzystaniu zobrażeń satelitarnych o wysokiej rozdzielczości terenowej, możliwe jest prowadzenie analiz na dużych obszarach w sposób regularny i porównywalny w czasie. Integracja tych danych z danymi ALS znacząco zwiększa potencjał interpretacji analiz, umożliwiając identyfikację pojedynczych martwych drzew. Przyszłe prace badawcze powinny koncentrować się na dalszym doskonaleniu metod segmentacji koron drzew, co umożliwi zwiększenie precyzji wyodrębniania obiektów na poziomie pojedynczych osobników. Istotnym kierunkiem rozwoju jest również wykorzystanie satelitarnych danych wieloczasowych, których

zastosowanie może wpłynąć na redukcję błędów klasyfikacyjnych. Integracja dodatkowych wskaźników spektralnych oraz zaawansowanych algorytmów klasyfikacyjnych, opartych na metodach uczenia głębokiego (ang. Deep Learning), może przyczynić się do poprawy dokładności wyników klasyfikacji. Ponadto warto rozważyć doskonalenie metody integracji danych ALS z danymi satelitarnymi poprzez stworzenie algorytmu przesuwania segmentów drzew lub nawet zmiany ich kształtu w oparciu o wartość kąta odchylenia sensora od nadiru w czasie wykonywania zobrazowania satelitarnego i informacji o wysokości pojedynczego drzewa. Uzupełnienie o dane wysokościowe pozwoliłoby na bardziej precyzyjne dopasowanie segmentacji koron drzew do danych satelitarnych.

Podziękowania

Autor pragnie podziękować Bartłomiejowi Kraszewskiemu, Maciejowi Lisiewiczowi, Krzysztofowi Stereńczakowi oraz Łukaszowi Kuberskiemu za ich eksperckie wsparcie i konstruktywne uwagi.

Konflikt interesów

Autor deklaruje brak potencjalnych konfliktów.

Źródła finansowania badań

Badania zostały sfinansowane w ramach projektu pt. „AfterFBS – utrzymanie wskaźników projektu ForBioSensing” (numer wewnętrzny 261509). Dane zostały sfinansowane w ramach projektu „LIFE+ ForBioSensing PL Kompleksowy monitoring dynamiki drzewostanów Puszczy Białowieskiej z wykorzystaniem danych teledetekcyjnych” współfinansowany ze środków Komisji Europejskiej w ramach instrumentu finansowego Unii Europejskiej LIFE+ (numer umowy LIFE13 ENV/PL/000048) oraz ze środków Narodowego Funduszu Ochrony Środowiska i Gospodarki Wodnej (numer umowy 485/2014/WN10/OP–NM–LF/D).

Literatura

- Abdollahnejad A., Panagiotidis D., Bílek L. 2019. An Integrated GIS and Remote Sensing Approach for Monitoring Harvested Areas from Very High-Resolution, Low-Cost Satellite Images, *Remote Sensing* 11 (21). DOI: <https://doi.org/10.3390/rs11212539>.
- Bałazy R., Hycza T., Kamińska A., Osińska-Skotak K. 2019. Factors Affecting the Health Condition of Spruce Forests in Central European Mountains-Study Based on Multitemporal RapidEye Satellite Images, *Forests* 10: 943. DOI: <https://doi.org/10.3390/f10110943>.
- Banskota A., Kayastha N., Falkowski M.J., Wulder M.A., Froese R.E., White J.C. 2014. Forest Monitoring Using Landsat Time Series Data: A Review, *Canadian Journal of Remote Sensing* 40 (5): 362–384. DOI: <https://doi.org/10.1080/07038992.2014.987376>.
- Bryk M., Kołodziej B., Pliszka R. 2021. Changes of Norway Spruce Health in the Białowieża Forest (CE Europe) in 2013–2019 during a Bark Beetle Infestation, Studied with Landsat Imagery, *Forests* 12: 34. DOI: <https://doi.org/10.3390/f12010034>.
- Coops N.C., Johnson M., Wulder M.A., White J.C. 2006. Assessment of QuickBird high spatial resolution imagery to detect red attack damage due to mountain pine beetle infestation, *Remote Sensing of Environment* 103: 67–80.
- Czerepko J. 2025. Sprawozdanie końcowe z realizacji zadań I-IV. Ocena i monitoring zmian stanu różnorodności biologicznej w Puszczy Białowieskiej na podstawie wybranych elementów przyrodniczych – kontynuacja. Instytut Badawczy Leśnictwa, Sękocin Stary. https://tbr.lasy.gov.pl/apex/f?p=102:3:::P3_TEMAT:5325 (dostęp 5.09.2025).
- Fernandez-Carrillo A., Patočka Z., Dobrovolný L., Franco-Nieto A., Revilla-Romero B. 2020. Monitoring Bark Beetle Forest Damage in Central Europe. A Remote Sensing Approach Validated with Field Data, *Remote Sensing* 12 (21). DOI: <https://doi.org/10.3390/rs12213634>.
- Franklin S., Wulder M., Skakun R., Carroll A. 2003. Mountain pine beetle red attack damage classification using stratified Landsat TM data in British Columbia, Canada, *Photogrammetric Engineering and Remote Sensing* 69: 283–288.
- Garrity S.R., Allen C.D., Brumby S.P., Gangogadagamage C., McDowell N.G., Cai D.M. 2013. Quantifying tree mortality in a mixed species woodland using multitemporal high spatial resolution satellite imagery, *Remote Sensing of Environment* 129: 54–65.
- Gavilan-Acuna G., Coops N.C., Tompalski P., Roesel D., Varhola A. 2025. The use and integration of airborne laser scanning and satellite time series data in precision forest management for plantations of fast-growing tree species, *Annals of Forest Science*: 82–22. DOI: <https://doi.org/10.1186/s13595-025-01292-9>.
- Ginszt T., Laskowska-Ginszt A. 2022. 10 lat (2012–2021) aktywności kornika drukarza *Ips typographus* (L.) w Puszczy Białowieskiej na przykładzie Nadleśnictwa Białowieża, *Sylwan* 166 (3): 183–193. DOI: <https://doi.org/10.26202/sylwan.202200048>.
- Grodzki W. 2016. Gradacyjne występowanie kornika drukarza *Ips typographus* (L.) (Col.: Curculionidae, Scolytinae) w aspekcie kontrowersji wokół Puszczy Białowieskiej, *Leśne Prace Badawcze* 77 (4): 324–331.
- Gutowski J.M., Bobiec A., Ciach M., Kujawa A., Zub K., Pawlaczyk P. 2022. Drugie życie drzewa. (wyd. 2) Fundacja WWF Polska, Warszawa.
- Hicke J.A., Logan J. 2009. Mapping whitebark pine mortality caused by a mountain pine beetle outbreak with high spatial resolution satellite imagery, *International Journal of Remote Sensing* 30 (17): 4427–4441. DOI: <https://doi.org/10.1080/01431160802566439>.
- Jutras-Perreault M.C., Gobakken T., Næsset E., Ørka H.O. 2023. Comparison of Different Remotely Sensed Data Sources for Detection of Presence of Standing Dead Trees Using a Tree-Based Approach, *Remote Sensing* 15: 2223. DOI: <https://doi.org/10.3390/rs15092223>.
- Kamińska A., Lisiewicz M., Stereńczak K., Kraszewski B., Sadkowski R. 2018. Species-related single dead tree detection using multitemporal ALS data and CIR imagery, *Remote Sensing of Environment* 219: 31–43. DOI: <https://doi.org/10.1016/j.rse.2018.10.005>.
- Kamińska A., Lisiewicz M., Kraszewski B., Stereńczak K. 2021. Mass outbreaks and factors related to the spatial dynamics of spruce bark beetle (*Ips typographus*) dieback considering diverse management regimes in the Białowieża forest, *Forest Ecology and Management* 498. DOI: <https://doi.org/10.1016/j.foreco.2021.119530>.
- Keczyński A. 2002. Wpływ gradacji kornika drukarza na drzewostany obszaru ochrony ścisłej Białowieskiego Parku Narodowego, *Kosmos* 257: 471–474.
- Krawczyk W., Wężyk P. 2023. Using Satellite Imagery and Aerial Orthophotos for the Multi-Decade Monitoring of Subalpine Norway Spruce Stands Changes in Gorce National Park, Poland, *Remote Sensing* 15 (4): 951. DOI: <https://doi.org/10.3390/rs15040951>.
- Lisiewicz M., Kamińska A., Kraszewski B., Kuberski Ł., Pilch K., Stereńczak K. 2025. Comprehensive mapping of individual living and dead tree species using leaf-on and leaf-off ALS and CIR data in a complex temperate forest, *Forestry: An International Journal of Forest Research* cpaf007. <https://doi.org/10.1093/forestry/cpaf007>.
- Meddens A.J.H., Hicke J.A., Vierling L.A. 2011. Evaluating the potential of multispectral imagery to map multiple stages of tree mortality, *Remote Sensing of Environment* 115: 1632–1642.
- Meddens A.J.H., Hicke J.A., Vierling L.A., Hudak A.T. 2013. Evaluating methods to detect bark beetle-caused tree mortality using single-date and multi-date Landsat imagery, *Remote Sensing of Environment* 132: 49–58.
- Mielcarek M., Kamińska A., Stereńczak K. 2020. Digital Aerial Photogrammetry (DAP) and Airborne Laser Scanning (ALS) as Sources of Information about Tree Height: Comparisons of the Accuracy of Remote Sensing Methods for Tree Height Estimation, *Remote Sensing* 12: 1808. DOI: <https://doi.org/10.3390/rs12111808>.
- Migas-Mazur R., Kycko M., Zwijacz-Kozica T., Zagajewski B. 2021. Assessment of Sentinel-2 Images, Support Vector Machines and Change Detection Algorithms for Bark Beetle Outbreaks Mapping in the Tatra Mountains, *Remote Sensing* 13 (16): 3314. DOI: <https://doi.org/10.3390/rs13163314>.

- Miścicki S., Kuberski Ł., Paluch R., Pilch K., Stereńczak K. 2022. Zasoby drzewne Puszczy Białowieskiej w latach 2015-2019 – stan i dynamika. w: K. Stereńczak (red.) Aktualny stan Puszczy Białowieskiej na podstawie wyników projektu LIFE+ ForBioSensing. Instytut Badawczy Leśnictwa, Sękocin Stary.
- Pluto-Kossakowska J., Osińska-Skotak K., Stereńczak K. 2017. Określenie rozdzielczości przestrzennej wielospektralnych zdjęć satelitarnych optymalnej do detekcji martwych drzew na obszarach leśnych, *Sylwan* 161 (5): 395–404.
- Skakun R.S., Wulder M.A., Franklin S.E. 2003. Sensitivity of the thematic mapper enhanced wetness difference index to detect mountain pine beetle red-attack damage, *Remote Sensing of Environment* 86 (4): 433–443. DOI: [https://doi.org/10.1016/S0034-4257\(03\)00112-3](https://doi.org/10.1016/S0034-4257(03)00112-3).
- Stereńczak K., Kraszewski B., Mielcarek M., Piasecka Ż. 2017. Inventory of standing dead trees in the surroundings of communication routes– The contribution of remote sensing to potential risk assessments, *Forest Ecology and Management* 402: 76–91. DOI: <https://doi.org/10.1016/j.foreco.2017.07.018>
- Stereńczak K., Kraszewski B., Mielcarek M., Piasecka Ż., Lisiewicz M., Heurich M. 2020. Mapping individual trees with airborne laser scanning data in an European lowland forest using a self-calibration algorithm, *International Journal of Applied Earth Observation and Geoinformation* 93. DOI: <https://doi.org/10.1016/j.jag.2020.102191>.
- Stereńczak K. 2022. Aktualny stan Puszczy Białowieskiej na podstawie wyników projektu LIFE+ ForBioSensing. Instytut Badawczy Leśnictwa, Sękocin Stary.
- Tianyang D., Jian Z., Sabin G., Ying S., Jing F. 2018. Single-Tree Detection in High-Resolution Remote-Sensing Images Based on a Cascade Neural Network, *ISPRS International Journal of Geo-Information* 7 (9): 367. DOI: <https://doi.org/10.3390/ijgi7090367>
- Vatandaşlar C., Zeybek M. 2021. Extraction of forest inventory parameters using handheld mobile laser scanning: A case study from Trabzon, Turkey, *Measurement* 177. DOI: <https://doi.org/10.1016/j.measurement.2021.109328>.
- Weidenbach M., de Kok R., Węzyk P., Szombara S. 2008. Developing strategies for large scale forest inventories combining LiDAR data, satellite imagery and regional yield models, (w:) Proceedings of SilviLaser 2008: 8th International Conference on LiDAR Applications in Forest Assessment and Inventory, red. Hill R., Rosette J., Suárez J., 635. University of Edinburgh, Edinburgh.
- White J.C., Wulder M.A., Brooks D., Reich R., Wheate R.D. 2004. Mapping mountain pine beetle infestation with high spatial resolution satellite imagery, *The Forestry Chronicle* 80 (6): 743–745. DOI:10.5558/tfc80743-6.
- Wulder M., White J., Bentz B., Ebata T. 2006. Augmenting the existing survey hierarchy for mountain pine beetle red attack damage with satellite remotely sensed data, *The Forestry Chronicle* 82 (2): 187–202.