


**IDEAS**  
NCBR ○ ● ●



# Ekstrakcja indywidualnych atrybutów drzew przy użyciu danych teledetekcyjnych bliskiego zasięgu

Maksymilian Kulicki

Promotor:  
dr hab. Janusz Będkowski



## O mnie

- Licencjat na kierunku Sztuczna Inteligencja na Radboud University w Nijmegen
- Magister na kierunku Sztuczna Inteligencja na University of Amsterdam
- Od 2023: Doktorat w IPPT PAN oraz w IDEAS NCBR
- Temat doktoratu: **Extracting individual tree attributes using close-range remote sensing data**

## Plan prezentacji

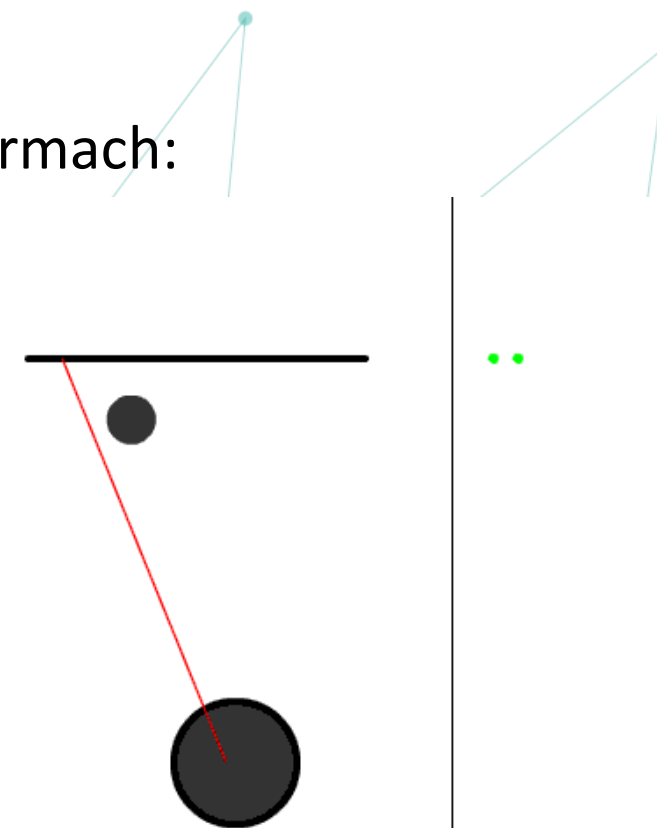
- Wprowadzenie
- Artykuł przeglądowy: AI i LiDAR naziemny w leśnictwie
- Badania nad segmentacją pojedynczych drzew
- Przyszłe badania

## Źródło danych: skaner LiDAR

**LiDAR (Light Detection and Ranging)**: technologia zdalnego mapowania przestrzeni. LiDAR emituje impulsy laserowe i mierzy czas powrotu odbitego światła, zbierając dane w postaci chmur punktów 3D.

Może być zamontowany na różnych platformach:

- Satelita
- Samolot
- Dron
- TLS (urządzenie naziemne)
- Ręczny skaner



## Mój obszar zainteresowań: LiDAR naziemny


- Bardzo wysoka gęstość pomiarów
- Dobrze widoczne pnie
- Statyczny lub przenośny



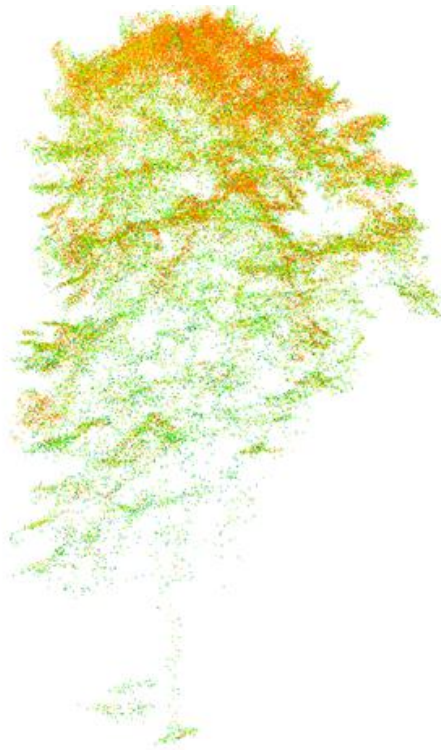
## Przykład naziemnej chmury punktów




# Różnica pomiędzy naziemnym i powietrznym LiDARem




a) ALS



b) ULS leaf-on



c) ULS leaf-off



d) TLS

## Początek doktoratu: Artykuł przeglądowy

- **Artificial Intelligence and Terrestrial Point Clouds for Forest Monitoring**
- Autorzy: Maksymilian Kulicki, Carlos Cabo, Tomasz Trzciński, Janusz Będkowski, Krzysztof Stereńczak
- Czasopismo: **Current Forestry Reports**




## Zastosowania modeli AI




**Segmentacja semantyczna**  
(pnie, gałęzie, liście)

**Segmentacja pojedynczych  
drzew**


**Klasyfikacja  
gatunków**



# Wyniki przeglądu

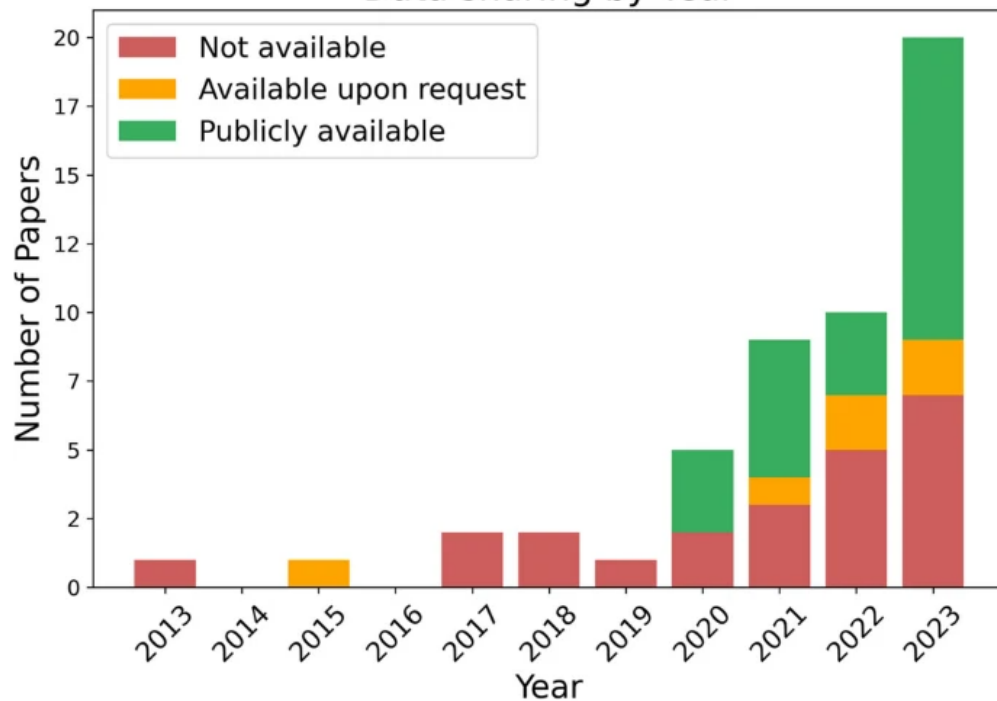


# Wyniki przeglądu

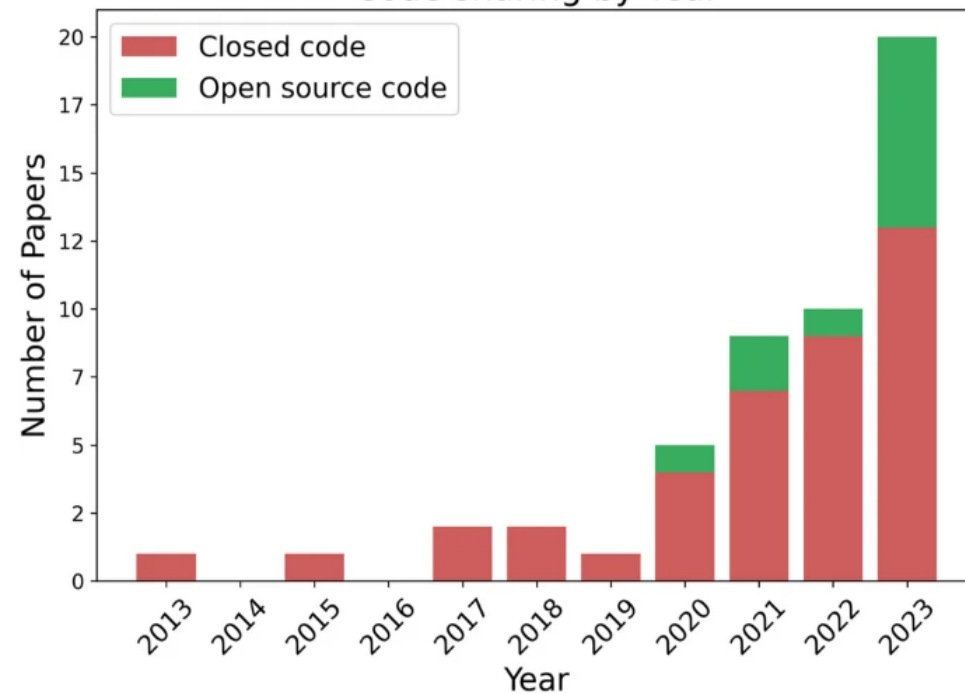


# Wyniki przeglądu

Data sharing by Year



Code sharing by Year




## Wyniki przeglądu - konkluzje

- + Szybki rozwój zastosowań modeli Deep Learning
- + Duża rola wstępnego przetwarzania: ekstrakcja atrybutów geometrycznych, projekcja na 2D
- + Problem: ograniczony dostęp do danych, brak referencyjnych zbiorów danych
- + Niewykorzystany potencjał: metody uczenia bez nadzoru, sieci grafowe

## Moje obecne badania: segmentacja pojedynczych drzew

- + Kluczowe zadanie
- + Niewiele metod Deep Learning w porównaniu do innych zadań
- + Konieczne do klasyfikacji gatunków
- + Ograniczone zbiory danych
- + Brak dobrze działających rozwiązań



# Moje obecne badania: segmentacja pojedynczych drzew

Plan działania:

- + Opracowanie dużego, kompleksowego zbioru danych
- + Trening różnych architektur Deep Learning
- + Porównanie i ewaluacja



## Obecnie dostępne zbiory danych

Name	Country	Reference	$n$ plots	$n$ trees	Annotated area (ha)	Forest type	Sensor
<b>L1 W</b>	Germany	<a href="#">Neudam et al. (2023)</a>	1	200	1.16	temperate deciduous forest	GeoSLAM ZEB-Horizon
<b>Lidar360</b>	Germany	<a href="#">Neudam et al. (2023)</a>	18	6665	25.09	temperate deciduous forest	GeoSLAM ZEB-Horizon
<b>LAUTx</b>	Austria	<a href="#">Tockner et al. (2022)</a>	6	514	0.83	temperate mixed forest	GeoSLAM ZEB-Horizon
<b>Wytham</b>	England	<a href="#">Calders et al. (2022)</a>	1	877 <sup>a</sup>	1.52	temperate deciduous forest	Riegl VZ-400

## Projekt: opracowanie dużego zbioru danych

- + Dane TLS zebrane przez Instytut Badawczy Leśnictwa
- + Ok. 20 000 drzew, 400 powierzchni
- + Dane referencyjne – gatunek, pierśnica i wysokość każdego drzewa
- + Projekt manualnej segmentacji pojedynczych drzew



# Projekt: opracowanie dużego zbioru danych

Praktyki dla studentów z 4 uczelni:

- + URK
- + SGGW
- + ITS (Indonezja)
- + UPI (Indonezja)

W sumie 54 osoby



UNIWERSYTET ROLNICZY  
im. Hugona Kołłątaja w Krakowie



SZKOŁA GŁÓWNA  
GOSPODARSTWA  
WIEJSKIEGO




ITS  
Institut  
Teknologi  
Sepuluh Nopember




# Procedura manualnej segmentacji

+ Użycie algorytmu 3DFin do wykrycia pni drzew




## Procedura manualnej segmentacji

- + Automatyczne wycięcie walca dookoła pnia
- + Manualne usuwanie punktów nienależących do drzewa



## Dane: Pilawa

- + Powierzchnia badawcza 1 ha
- + Ok. 500 drzew
- + Powierzchnia zeskanowana przy pomocy 6 różnych skanerów MLS
- + Różne pory roku (z liśćmi i bez)



## Projekt: kompleksowa ewaluacja metod segmentacji

- + Modele zaprojektowane do segmentacji drzew
- + Inne modele do segmentacji obiektów
- + Wieloczynnikowa analiza wyników

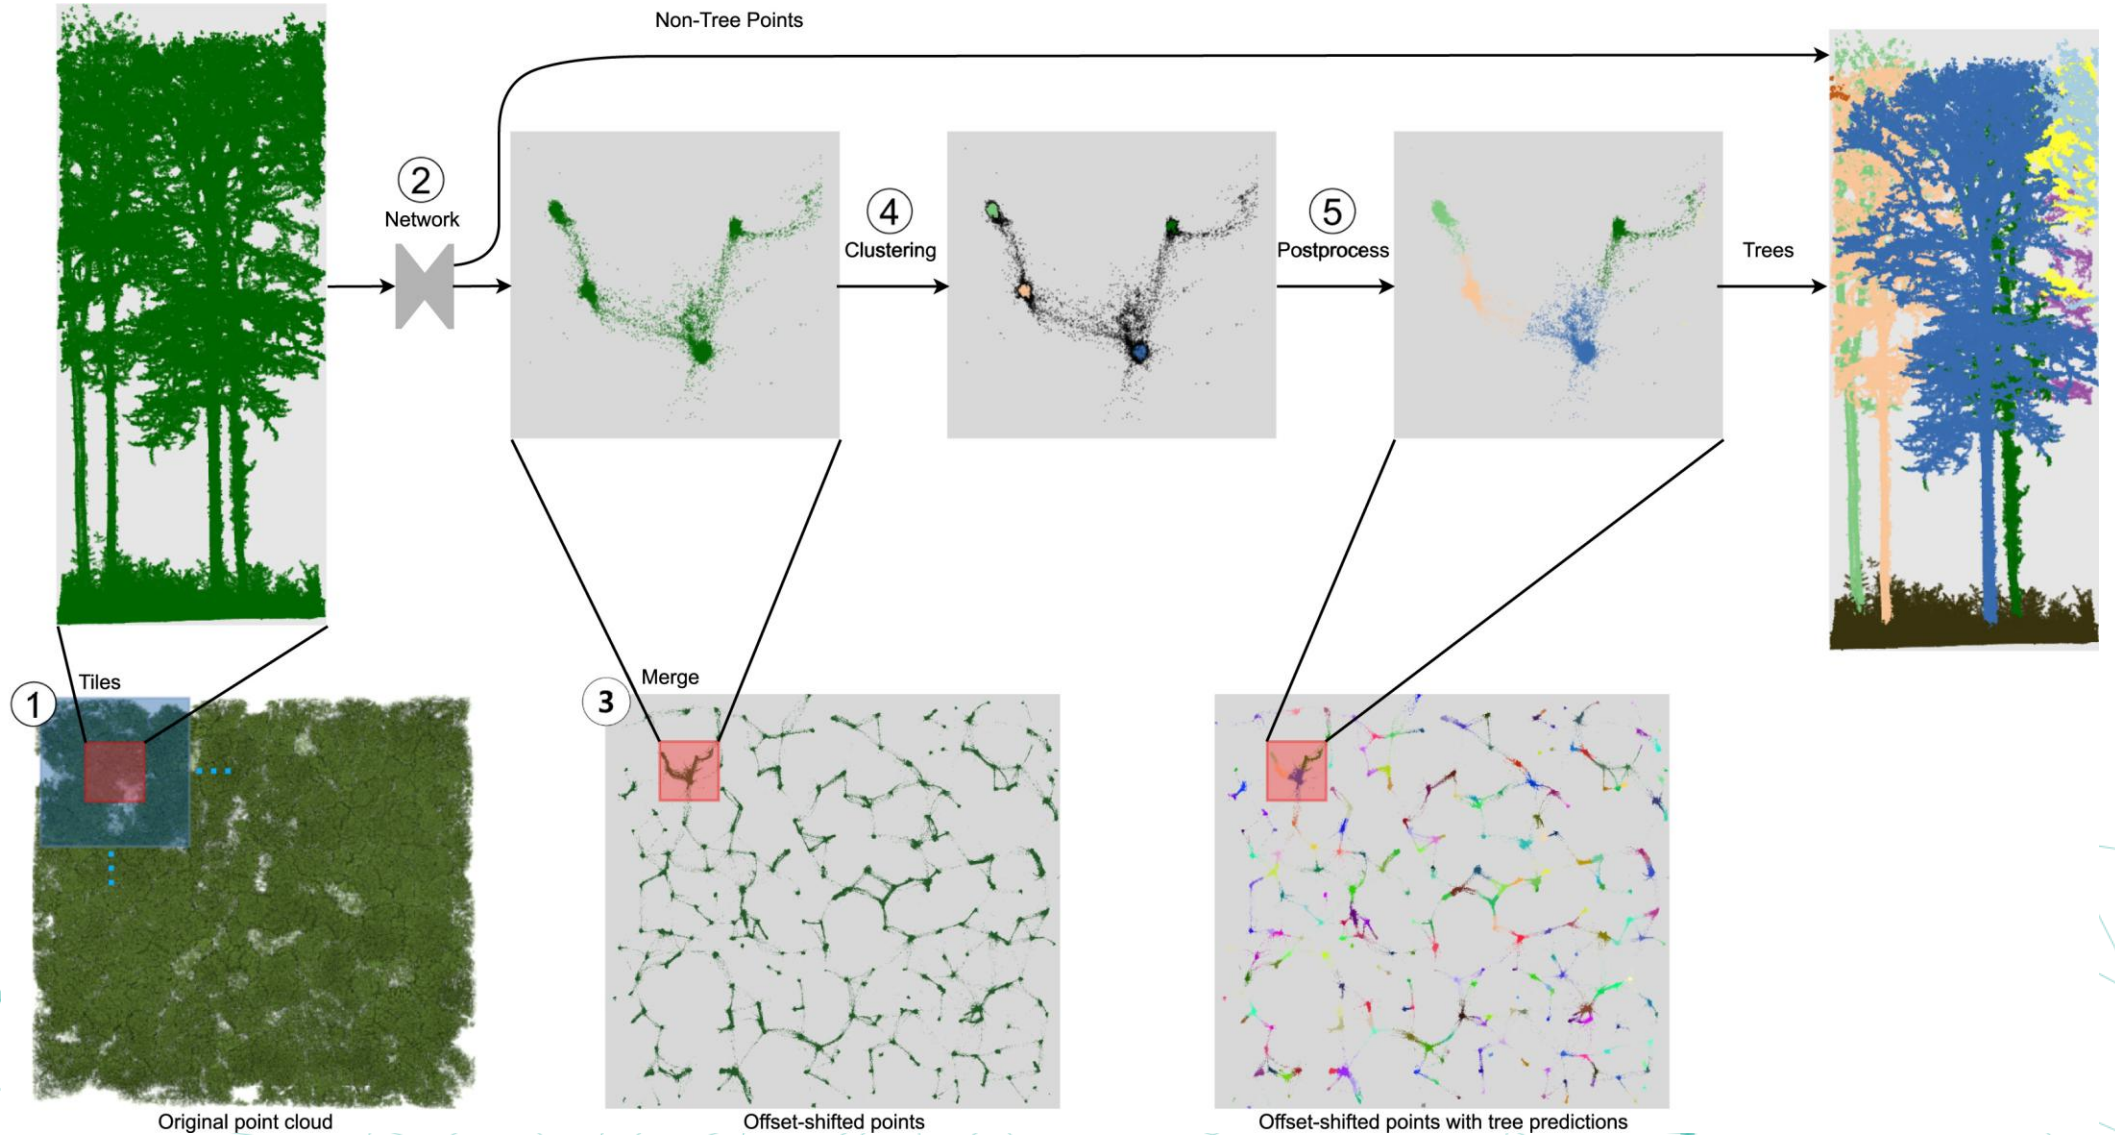
## Dostępne modele segmentacji drzew

- + TreeLearn
- + SegmentAnyTree

Oba modele są oparte o metodę PointGroup



# Architektura TreeLearn



# Alternatywne modele

- + Transformer 3D:
  - Mask3D
  - SPFormer
- + Coarse-to-Fine:
  - SphericalMask



Input 3D Scene



Instance Heatmaps



3D Semantic Instances

## Trening modeli

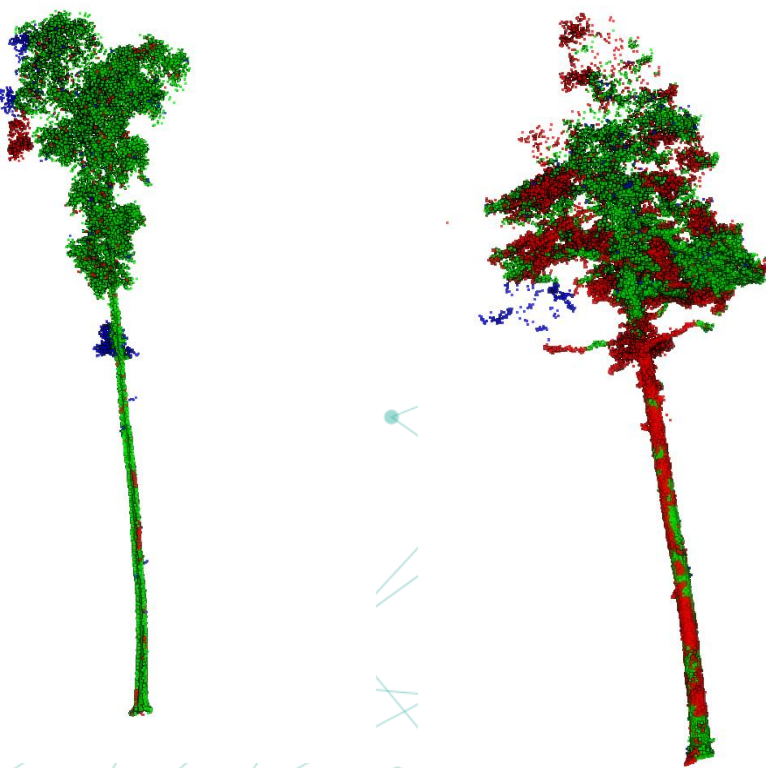
- + Nasz zbiór danych + pozostałe publiczne zasoby
- + Klaster CyfroNet AGH do obliczeń
- + Wszystkie modele wytrenowane od zera
- + Potencjalne zastosowanie *data augmentation*
  - TreeMix
  - Próbkowanie punktów
  - Dodanie szumu

## Ewaluacja


- + Analiza wpływu na jakość segmentacji
  - Gatunek drzewa
  - Rozmiar drzewa
  - Gęstość lasu
  - Typ skanera (statyczny / mobilny)
- + Czy są różnice pomiędzy modelami?

## Wstępne wyniki


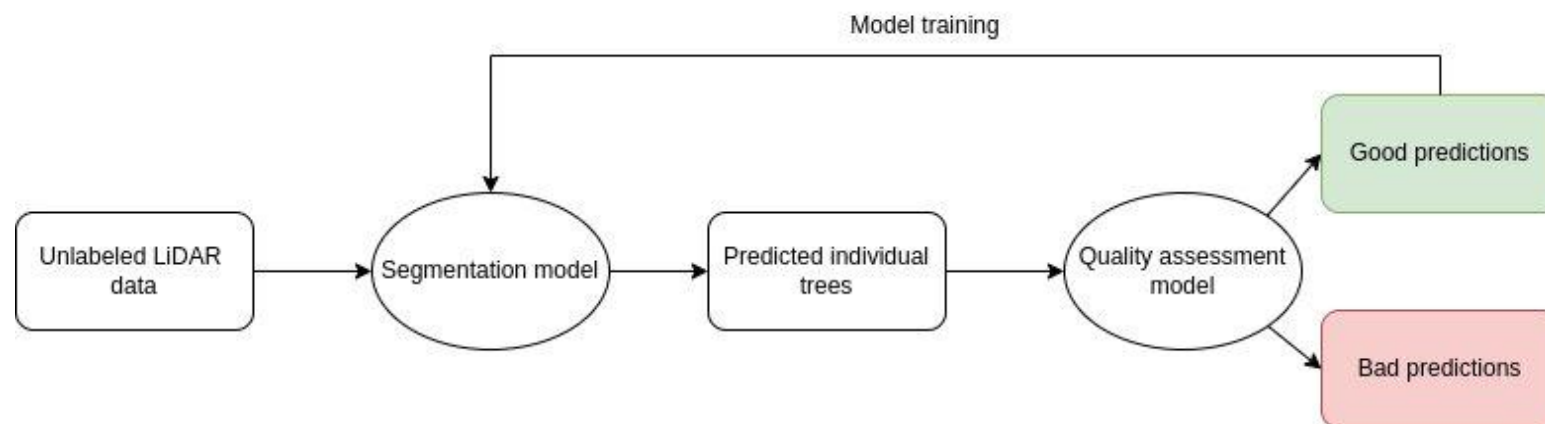
- Analiza jednego ze skanów z Pilawy
- Segmentacja z użyciem modelu TreeLearn
- Duże zróżnicowanie gatunkowe
- Stosunkowo niewielkie znaczenie rozmiaru drzewa




Distribution of Metrics by Tree Species



# Przerwane badania: uczenie półnadzorowane (semi-supervised)




## Przyszłe badania – integracja z kamerą





# Dziękuję za uwagę!



Email: [mkulicki@ippt.pan.pl](mailto:mkulicki@ippt.pan.pl)