

## 仮想森林を用いた深層学習による点群からの立木検出手法の開発

中込広幸 \*

中込広幸：仮想森林を用いた深層学習による点群からの立木検出手法の開発. 森利誌 39 (4) : 129 ~ 138, 2024. 伐木作業を行う林業機械を自動化するため、伐木対象の立木を検出する手法が必要となっている。遠距離の点群測定が可能である3D-LiDARを使用した手法が望ましいが、伐木用林業機械に3D-LiDARを搭載する場合、点群を測定する方向が限定されるため、立木の背面の点群を取得することができず、また、下層植生や他の立木によって検出対象の立木や周辺の地面が遮蔽され、立木検出に必要な点群が不足する。そこで本研究では、ゲームエンジンにより仮想的な森林環境を構築することで、点群の不足を再現した教師データを効率よく生成し、深層学習におけるネットワークの学習に用いる。これにより点群の不足時においても立木を検出し、検出した立木の3次元位置および胸高直径を推定可能な手法を提案する。評価として、実際の森林環境において点群、立木の3次元位置および胸高直径の真値を取得し、立木の検出精度および立木の3次元位置および胸高直径の推定精度を算出した。提案手法では3D-LiDARに対する距離の増加による適合率および再現率の低下を抑制することが可能であり、提案手法の有効性が示すことができた。

キーワード：立木検出, 深層学習, ゲームエンジン, PointPillars, 3D-LiDAR

Hiroyuki Nakagomi : **Detecting standing trees using 3D-LiDAR point clouds based on deep learning models trained in virtual forest environments. J. Jpn. For. Eng. Soc. 39(4): 129 – 138, 2024.** To automate felling forestry machinery, a method for detecting standing trees is necessary. It is recommended to measure point clouds obtained using 3D-LiDAR, which is capable of measuring over long distances. However, 3D-LiDAR is mounted on felling forestry machinery, and measuring point clouds from multiple directions reduces productivity. When measuring point clouds using single-scan, the point cloud of the back of a standing tree cannot be obtained. Furthermore, other standing trees and understory vegetation occlude the standing trees targeted for detection. In this study, virtual forest environments were constructed using gaming engines to efficiently generate teacher data while simulating insufficient point clouds to train deep learning networks. This network can detect standing trees even when the point cloud is insufficient and can estimate the 3D location and diameter of the detected standing trees. To evaluate the proposed method, true values were obtained in a real forest environment, and the accuracy of detecting the standing trees and estimating the 3D location and breast height diameter of the standing trees were calculated. The proposed method reduced the decreases in precision and recall values with increasing distance, demonstrating its effectiveness.

**Keywords** : standing tree detection, deep learning, game engine, PointPillars, 3D-LiDAR

2024年3月6日受付, 2024年9月6日受理

連絡先 (Corresponding author) : 中込広幸 (Hiroyuki Nakagomi) Email : hnakagomi@affrc.go.jp

\* 森林総合研究所 For. and Forest Prod. Res. Inst., Tsukuba 305-8687

## 1. はじめに

わが国の林業では、生産性向上による国産材の競争力の強化および林業従事者の安全確保を目的として、高性能林業機械の導入が推進されている。伐木作業では倒れてくる伐倒木に作業者が激突するなどの原因により、他の作業よりも死亡事故が発生しやすいことが長年指摘されており（今富 2003；岡ら 2011）、近年においても、林業全体に対する伐木林業中の死亡事故は、2021 年において 63%（林業・木材製造業労働災害防止協会 2022）、2023 年において 48%（林野庁 2024）と高い割合となっていることから、ハーベスタやフェラーパンチャなどの伐木用林業機械を用いた安全な伐木作業の実施が期待されている。しかし、わが国の森林は主に傾斜地に存在し、さらに伐木作業は立木の把持により機体の重心が著しく変化するため転倒の恐れがある。勾配のある環境で作業者の安全性を確保し、かつ平坦な環境と同等の生産性を得るための解決方法の一つとして、自動化による無人での伐木が望まれる。伐木作業を自動化するためには立木の把持動作の制御や伐倒方向を自動で決定する必要があり、そのためには伐倒対象および周辺の立木検出、立木の切断位置の座標・直径・傾きの推定が必要である。また、伐倒時の制御のために立木の重心の推定が必要となる可能性がある。

立木検出の主な従来手法では、地上型レーザーキャナ（TLS）を用いる方法（Thies *et al.* 2004; Maas *et al.* 2008; Tansey *et al.* 2009; Othmani *et al.* 2011; Burt *et al.* 2019）や、可搬式 3D-LiDAR と simultaneous localization and mapping（SLAM）技術により取得した点群を用いる方法が存在する（McDaniel *et al.* 2012; Tremblay *et al.* 2020）。これらの手法は、まず、地面の高さ推定により点群内の地面と立木を分離し、次に、点群を個別の立木に分割し、最後に分割後の点群に対して円近似や円柱近似することで、立木の検出と、検出した立木の 3 次元座標および直径が求められる。直径は主に胸高における値が求められ、その場合の 3 次元座標は胸高において近似した円・円柱の中心座標とされる。また、樹高、細り、曲がりを求める場合は、一定の高さごとに円・円柱近似が行われ、それぞれの高さにおいて幹の直径と 3 次元座標が求められる。

これらの手法は円・円柱近似や遮蔽による影響を除去するため、立木全体の点群が得られていることが前提となっており、森林の複数地点から点群を測定する必要がある。例として、treeseq と呼ばれる手法（Burt *et al.* 2019）では複数地点からの TLS による測定により、立木全体の点群を取得し検出を行っている。しかし、伐木用林業機械に搭載した 3D-LiDAR を用いる場合、伐採前の森林を走行し複数の視点から点群を測定することは困難であり、無理に計測しようとするとう生産性が著しく低下することが予想される。効率的に計測するためには、1 方向から測定された点群のみを用いて立木検出を行っ

て点群取得に必要な時間を短縮することが必要であるが、視点が限定されるため、1) 立木の背面の点群が得られない、2) 下層植生や他の立木によって立木や地面が遮蔽される、3) 3D-LiDAR の原理上、遠距離となるほど点群の密度が低下するといった問題が生じる。これら問題は従来手法における地面と立木の点群の分離、円近似・円柱近似の妨げとなるため、従来手法を伐木作業の自動化に適用することは困難である。

他の立木検出手法として、カメラの画像に対して深層学習を適用する手法が存在する（Itakura and Hosoi 2020; Grondin *et al.* 2022）。これらの手法は深層学習によりカメラ画像における立木領域を抽出し、ステレオ視により算出した深度画像と重ねることで立木の 3 次元位置および直径を推定している。また、ステレオカメラ画像から復元された点群に対して深層学習による 3 次元物体検出手法を適用し、直接立木の 3 次元座標と胸高直径を推定する手法も存在する（Wang *et al.* 2021）。しかし、これら従来手法は Structure From Motion（SfM）やステレオカメラの視差情報から 3 次元形状の復元を用いているため、3D-LiDAR と比較して遠距離の正確な形状測定が難しい。伐倒時の掛かり木の防止や、玉切りする際に効率よく引き出すためには伐倒木と残存木との位置関係を把握して伐倒方向を決めなければならず、スギであれば伐期である林齢 50 年の立木の高さが 25 m 以上になる場合もあることから（岐阜県林政部 1992）、より遠方の立木についても検出可能とする必要があると考える。

そこで本研究では、3D-LiDAR と深層学習により 1 方向から測定された点群のみを用いて立木を検出し、その 3 次元座標と直径を計測する手法を提案する。遠距離の点群測定が可能な 3D-LiDAR を使用し、遮蔽や密度の低下等により点群が不足した場合においても、教師データに基づく学習により、立木検出を可能とする。ただし、深層学習による 3 次元物体検出には Kitti データセット（Geiger *et al.* 2012）や、nuScenes データセット（Caesar *et al.* 2020）のように、データ数が数千～数万セットに及ぶ大規模な教師データを用いることが一般的となっている。立木検出においてこれらと同規模の教師データを実際の森林から取得することは難しく、立木毎にトータルステーション等による 3 次元位置測定や輪尺等による直径の測定が必要なため、データ収集に多大な労力を必要とする。そこで本研究では、自動運転分野において用いられている手法（Dosovitskiy *et al.* 2017）と同様に、ゲームエンジンを用いて教師データを自動的かつ大量に取得する手法を構築し、立木検出のための深層学習に用いる。

提案手法の推定精度を検証するために、実際の森林において取得した立木位置と胸高直径を真値として用いる。提案手法と従来手法である treeseq による立木検出精度と比較し、提案手法の有効性を明らかにする。なお、真値の取得および従来手法との比較のため、本研究で推

定する立木の3次元位置は、胸高（高さ1.2 m）において幹の形状を円柱に近似した場合の円柱の中心の3次元座標であり、推定する立木の直径は胸高における値とする。

## 2. 研究方法

### 2.1 ゲームエンジンを用いた教師データの作成

**2.1.1 仮想森林の構築** 本研究の目的は、下層植生等による3D-LiDARの遮蔽や遠距離の点群密度が低下する環境において立木の検出と胸高における立木位置と直径を求めることである。このため仮想森林に必要な条件は、立木と下層植生を設置可能、立木の3次元位置や胸高直径にばらつきを持たせることが可能、3D-LiDARの機能を模倣し疑似的な点群の取得と遠距離の点群密度の低下を再現可能であることとする。条件を満たす仮想森林をゲームエンジンであるEpicGames社製UnrealEngine4を用いて森林環境を再現する（以降、再現された森林環境を仮想森林と呼ぶ）。仮想森林は、地面メッシュ、立木メッシュ、下層植生メッシュ、伐木用林業機械メッシュ、3D-LiDARメッシュから構成される。構築した仮想森林を図-1に示す。

地面メッシュは、UnrealEngine4のLandscapeツールと呼ばれる機能により作成する。この機能は平面なメッシュを編集し勾配を持たせることが可能となっており、平面および勾配面のあるメッシュを作成し地面メッシュとする。立木・下層植生メッシュは、UnrealEngine4のFoliageツールを用いて構築することで次のような森林条件を表現できる。立木・下層植生メッシュを地面メッシュ表面のランダムな位置に配置でき、単位面積あたりの立木・下層植生数を指定することができる。林分内の立木・下層植生をランダムに拡大縮小させ胸高直径や樹高にばらつきを与えることができる。このほか、立木全体を傾斜させることができ、1本ごとに傾斜角度と方位をランダムな値で設定しばらつきを与えることが可能である。本研究の仮想森林はFoliageツールの機能により、

一定の立木密度でランダムな位置に立木メッシュを配置し、立木メッシュごとに異なる値で拡大縮小、傾斜を与えることで、胸高直径、傾斜角度と方位にばらつきを持たせた森林条件を構築する。立木メッシュは針葉樹、広葉樹を1種類ずつ使用したが、幹の曲がりには設定されておらず、断面はほぼ円形のメッシュを使用している。下層植生についても、低木および雑草のメッシュをFoliageツールにより拡大縮小率を変化させ配置する。今回構築する仮想森林には適用していないが、複数の立木メッシュを用いて混交林を構築することや、立木の断面形状を扁平させることが可能である。一方、UnrealEngine4の機能やFoliageツールでは、立木の曲がり、細り率、根際形状、幹の複雑な断面形状、樹冠の形状、枝の生え方、枝葉の茂り方といった立木形状の詳細な変更はできない。また、立木密度は林分ごとに異なる値となるため、立木密度にばらつきをもたせた配置はできない。伐木用林業機械メッシュは、履帯式のフェラーバンチャを模したメッシュを作成する。伐木用林業機械メッシュのキャノピー上部に3D-LiDARを模した円筒形のメッシュを配置し3D-LiDARメッシュとする。

**2.1.2 教師データの構成** 教師データは、点群、および立木の3次元位置と直径を1セットとして構成する。点群は仮想森林に再現した3D-LiDARを用いて取得する。立木の3次元位置と直径は、地面メッシュの高さ情報と立木メッシュの頂点情報を用いて算出する。

**2.1.3 点群の取得** UnrealEngine4のレイキャストと呼ばれる機能を用いて3D-LiDARを再現し（以降、仮想3D-LiDARと呼ぶ）、仮想森林において点群を取得する。レイキャストと呼ばれる機能は、任意の3次元の位置および3次元の方向ベクトルを指定することで仮想的な光線（レイと呼ばれる）を飛ばし、レイと物体が接触した点の3次元位置を取得することができる。3D-LiDARメッシュの中心位置をレイの原点とし、方向ベクトルのピッチ角およびヨー角を変化させ点群を取得することで3D-LiDARの機能を再現する。仮想3D-LiDARは伐木用

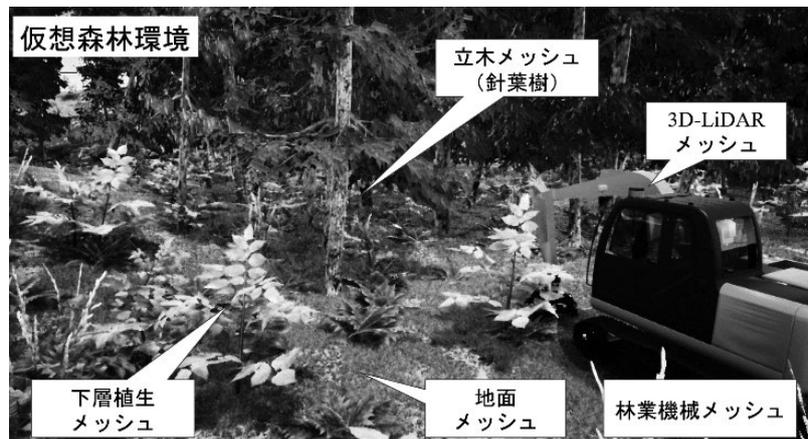


図-1 構築した仮想森林環境

林業機械メッシュのキャノピー上部に設置し、周辺の3次元点群を取得する。取得した点群の例を図-2に示す。

**2.1.4 立木の3次元位置および胸高直径の取得** はじめに、仮想3D-LiDARの測定範囲内に存在する立木のメッシュ情報を取得する。次に、胸高を1.2 mとして、地面メッシュから高さ1.2 m  $\pm$  0.3 mの範囲に存在するメッシュの頂点に対して円柱近似を行い、円柱の中心位置と直径を胸高における幹の3次元座標および胸高直径として取得する。最後に、立木の3次元座標を仮想3D-LiDARを原点とする座標系に変換する。仮想3D-LiDARにより取得した点群と、立木の3次元座標および胸高直径を対応させたものを教師データとする。なお、仮想3D-LiDARやメッシュ情報は誤差を再現していないため、疑似的な点群の座標値や立木の位置、直径は誤差のない値となっている。将来的に仮想3D-LiDARの誤差を再現することで、深層学習により誤差の大きい低価格の3D-LiDARでも高価格帯の3D-LiDARと同等の立木検出やその3次元位置、直径等の推定ができる可能性がある。

## 2.2 PointPillarsを用いた立木検出モデルの構築

**2.2.1 PointPillars** 本研究では、深層学習を用いた3次元物体検出手法であるPointPillars (Lang *et al.* 2019)を用いて、立木の3次元座標および胸高直径を推定する。深層学習とは機械学習の一種であり、ニューラルネットワークを多層化し、教師データを用いてニューラルネットワークの重み係数を最適化することで学習が行われる。これまでに様々な手法が提案されており、画像認識では、2次元畳み込みニューラルネットワーク(2D-CNN)と呼ばれるネットワークが汎用的に用いられている。PointPillarsは2D-CNNを用いた画像処理用のニューラルネットワークを、3次元情報をもつ点群に対して適用するための手法である。

PointPillarsは前処理として、入力された点群を水平方向に分割された空間(セルと呼ばれる)に分割し、セルごとに点群の重心位置、点群の重心位置からの偏差を求め、これら値とレーザの反射強度を特徴量として算出する。次に、得られた特徴量をPillar Feature Netと呼ばれるニューラルネットワークに入力し、前処理で得られた特徴量を、画像処理用のニューラルネットワークで利

用可能な特徴量(pseudo-imageと呼ばれる)に変換する。得られたpseudo-imageは2D-CNNにより、検出したい物体の種類(クラスと呼ばれる)ごとに、水平方向の2次元グリッド上における存在確率、存在する物体の3次元座標および物体のサイズ(幅、高さ、奥行き)に変換する。

**2.2.2 ネットワークの変更** 本研究は立木だけを対象とするため、PointPillarsにおけるクラスは立木のみに変更する。また、仮想森林の点群は3D-LiDARのレーザの反射強度を再現することが難しいため、特徴量における反射強度は一定値とする。PointPillarsから出力される物体の3次元座標が、幹の胸高における3次元座標となるようネットワークを変更する。同様に、出力される物体のサイズを、幅と奥行きが胸高直径、高さが胸高となるよう変更する。変更後の深層学習モデルを立木検出モデルとする(図-3)。

**2.2.3 立木検出モデルの学習** PointPillarsに関するパラメータとして、セルのサイズを幅0.16 m、奥行き0.16 m、高さ4.0 mとし、3D-LiDARの原点を中心として前後・奥行き方向に40.0 mから40.0 mの範囲で特徴量を算出した。学習に関するパラメータとして、バッチ数2、エポック数160、初期学習率0.0002とし、学習率は20エポックごとに20%低下するよう設定した。これら学習における各パラメータは、PointPillars (Lang *et al.* 2019)における車両を検出する際に用いた値を基準として用いた。ただし、セルの範囲については、伐木機械の自動化において後方の立木の検出が必要と判断し変更した。本研究ではパラメータを変更せずに実験を行ったが、セルの幅、奥行きを増減した場合、複数の立木が1つのセル内に存在する、もしくは1本の立木の点群が複数のセルに存在することとなり、複数の立木が単独の立木として過少に検出される可能性や、単独の立木が複数の立木として過剰に検出されることが予想される。セルの高さを増加させた場合、樹冠の点群が多く取得されることで立木の誤検出が生じることや、減少させた場合地面や立木の幹の点群が少なくなり、立木が未検出となる可能性がある。バッチ数、エポック数、初期学習率を増減さ

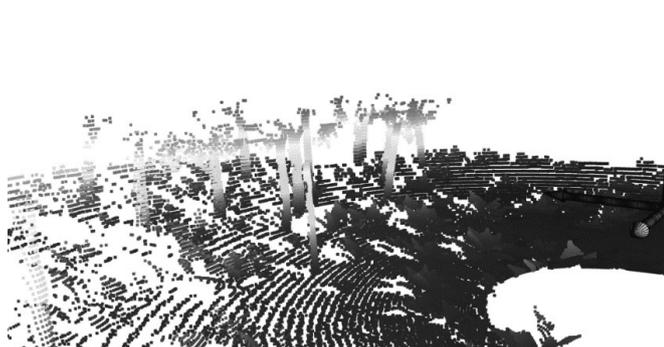


図-2 仮想3D-LiDARにより取得した点群

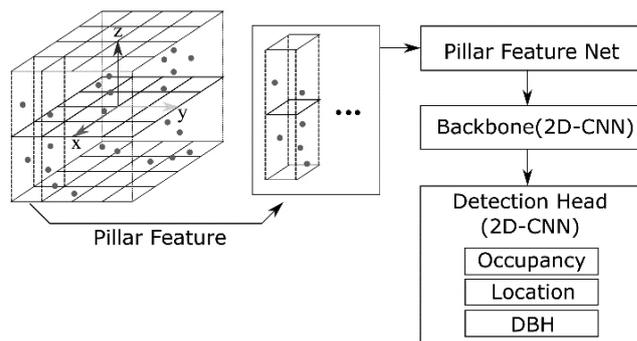


図-3 立木検出のための深層学習モデル

せる場合、学習の進行に影響が発生し、適切なパラメータを選択すればより高い精度の立木検出や立木の位置・直径の推定が可能となるが、局所解に陥り精度が上昇しない場合や、過学習と呼ばれる教師データにのみ最適化された状態となり、未知のデータに対する冗長性が失われる可能性がある。

仮想森林において 2,926 セットの教師データを作成し、2,633 セットを学習用データセット、293 セットを検証用データセットとして使用し、立木検出モデルの学習を行った。立木検出モデルを構築するためのプログラムは Python と Python 用ライブラリである Tensorflow により作成し、立木検出モデルの学習は、CPU として AMD 製 EPYC 7742 2.25GHz、GPU として NVIDIA 製 A100 を使用した。

2.3 実際の森林における真値の取得

本研究では、仮想森林で作成した教師データを立木検出に用いているため、実際の森林において真値を取得し、立木検出精度、立木の 3 次元座標の推定精度および胸高直径の推定精度を検証する必要がある。

実際の森林は森林総合研究所（茨城県つくば市）内のヒノキ林（図-4）とした。まず、FARO 社製 FOCUS S 150 により森林全体の点群を取得し、treeseg を用いて立木の胸高における 3 次元位置および胸高直径を取得した。3 次元位置については、treeseg の地面判定により、地面と立木の点群を分離した後、立木の点群のうち地面から高さ 1.2 m ± 0.3 m の点群に対して円柱近似を行い、近似した円柱の中心座標を立木の 3 次元位置として取得した。次に、3D-LiDAR である北陽電機製 YVT-35LX-FK により、1 方位から点群を取得した。使用した 3D-LiDAR の諸元を表-1 に示す。ただし、YVT-35LX-FK により得られた点群および提案手法が推定する立木の 3 次元位置は YVT-35LX-FK を原点とする座標系（ローカル座標系と称する）の値であり、ヒノキ林全体の点群および treeseg により求めた立木の 3 次元座標の座標

系（グローバル座標系と称する）の値に対して座標系が異なる。このため、treeseg により得られた立木の 3 次元位置をローカル座標系に座標変換し、座標変換後の立木の 3 次元位置と胸高直径を真値とした。座標変換に必要な変換行列は、YVT-35LX-FK が取得した点群とヒノキ林全体の点群の位置合わせを行うことで求めた。

ヒノキ林計 8 箇所において真値を取得した。実際の森林（ヒノキ林）および仮想森林の条件を表-2 に示す。この林分における下層植生の状態として、林内は樹冠により日光が遮断されていたため、高さ 15 cm 程度までの低層の植生が一樣に存在していた。一方で林縁部は日光の遮蔽物が無く下層植生が繁殖し、最大で高さ約 140 cm の植生が存在していた。林分における枝下高の状態として、立木は枝打ちされておらず、枝下高は平均 7.3 m であった。林縁部の立木に限定した場合、日光が遮蔽されないためさらに枝下高が低下し、平均 5.2 m となった。外縁部の一部の枝は垂れ下がることで幹を遮蔽し、最も低い枝は地上から高さ約 90 cm まで垂れ下がり幹を



図-4 実験に用いた実際の森林（ヒノキ林）

表-1 使用した 3D-LiDAR の諸元

3D-LiDAR	測定距離 (m)	走査角度 (deg)	走査角度精度 (deg)	測距精度 (mm)
YVT-35LX-FK	0.3 ~ 35.0	水平 : 210	水平 : ± 0.125	± 50.0
		垂直 : 40	垂直 : ± 2.000	(15 m 以下) ± 100.0 (15 m 以上)
FOCUS S 150	0.6 ~ 350.0	水平 : 360	水平 : ± 0.005	± 2.0 (10 m)
		垂直 : 300	垂直 : ± 0.005	± 3.5 (25 m)

表-2 仮想森林および実際の森林（ヒノキ林）の実験条件

環境	樹種	立木の密度 (本 /ha)	胸高直径 (m)	立木の傾斜 (deg)	データ数
仮想森林	針葉樹・広葉樹メッシュ	500	0.21 ~ 0.65	0 ~ 10	2,926
ヒノキ林	ヒノキ	約 640	0.19 ~ 0.48	-	8

遮蔽していた。なお枝下高は、立木単体に対して最も低い位置にある生枝の基部の高さを測定することで求めた。

### 3. 結果

#### 3.1 実際の森林における立木の検出

立木の検出精度、および立木の3次元位置と胸高直径の推定精度を算出するため、実際の森林において一方向から3D-LiDARで取得した点群に対して、仮想森林で得られた教師データを用いて学習した立木検出モデルを使用し、立木の検出、および立木の3次元位置、胸高直径を推定した。一方向から3D-LiDARにより取得した点群に対する立木検出モデルによる立木検出結果の例を図-5に示す。

#### 3.2 立木の検出精度

**3.2.1 検出精度の定義** 立木の存在の有無を判定するような、2値分類問題を取り扱う場合、機械学習における一般的な評価手法を適用することができる。すなわち、

- 適合率 (Precision) = 真陽性数 / (真陽性数 + 偽陽性数)
- 再現率 (Recall) = 真陽性数 / (真陽性数 + 偽陰性数)

により検出精度を評価することができる。そこで本研究では立木の検出精度を算出するため、検出結果について次のように分類した。

- 真陽性: 検出された立木の水平1 m以内に、真値において立木が存在する場合
- 偽陽性: 検出された立木の水平1 m以内に、真値において立木が存在しない場合
- 偽陰性: 真値において立木が存在し、その水平1 m以内に立木が検出されない場合

各分類の立木数をカウントし、適合率、再現率を算出することで、立木の検出精度を評価した。ただし、水平距離を評価するため、ローカル座標系である立木位置の真値、推定値を、 $x$ 、 $y$ 軸が水平方向、 $z$ 軸が反重力方向となる座標系(水平ローカル座標系と称する)に座標変換し、 $x$ 、 $y$ 軸値のユークリッド距離を算出することで水

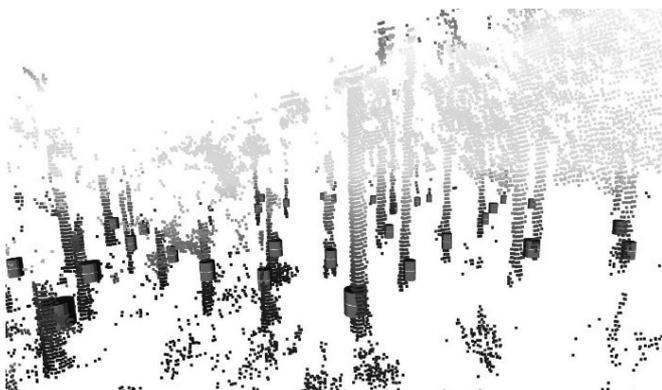


図-5 実際の森林における一方向から取得した点群に対する立木検出結果

平距離を求めた。ローカル座標系と水平ローカル座標系の変換行列は、YVT-35LX-FKに内蔵された加速度センサを用いて反重力方向を測定し求めた。また、判定距離を小さくした場合、真陽性となる立木数が減少し立木の位置推定誤差の評価が困難となるため、判定距離を1 mとした。

また、立木が3D-LiDARから離れるほど、点群密度の低下および他の立木や下層植生による遮蔽により、立木検出精度が低下することが予想される。このため3D-LiDARからの距離ごとに適合率、再現率を算出した。

**3.2.2 従来手法との比較** 提案した立木検出手法の有効性を確認するため、3D-LiDARを用いた他の立木検出手法と立木検出精度を比較する必要がある。本研究では、真値を求めるために使用したtreesegを比較においても使用した。本来treesegは立木全体の点群が得られた場合に用いる手法だが、提案手法との比較のため、1方向から測定した点群に対してtreesegによる立木検出と、3次元位置および胸高直径の推定を行った。伐木用機械に搭載された3D-LiDARのように立木に対して限定された方向からしか点群を取得できない場合において、提案手法が従来手法に対してどの程度有効なのか、立木検出精度を用いて比較した。

**3.2.3 立木検出の適合率および再現率** 立木検出精度として算出した適合率を図-6、再現率を図-7に示す。適合率の結果を比較すると、3D-LiDARに対して0 mから10 mの距離において、提案手法の適合率は従来手法と比較して高く、10 mから25 mまでの適合率は同程度であった。25 m以上の距離において、従来手法は立木が検出されなかったため適合率がゼロとなったが、提案手法では立木を検出することができ、25 mまでの距離における精度と同程度の精度が得られた。

再現率の結果を比較すると、3D-LiDARに対して距離15 mまでの再現率は従来手法および提案手法において

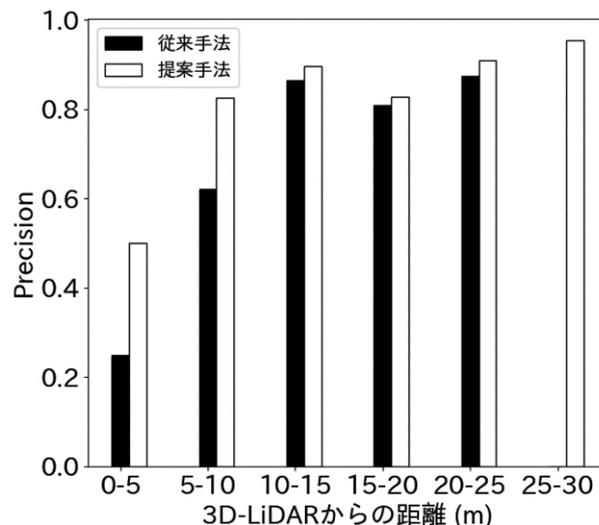


図-6 立木検出における適合率 (Precision) の算出結果

同程度の値となった。15 m 以上の距離では、従来手法の再現率は低下したが、提案手法の再現率は従来手法と比較して低下の度合いが少なかった。

### 3.3 立木の3次元位置と胸高直径の推定精度

真陽性に分類された立木について、提案手法の3次元位置と胸高直径の推定誤差を算出した。立木位置の推定誤差は水平方向と垂直方向に分けて分析した。立木位置の推定値と真値は、3.2.1における水平ローカル座標系に変換した値を使用し、 $x$ ,  $y$ 軸値のユークリッド距離を水平方向の誤差、 $z$ 軸値の絶対誤差を垂直方向の誤差とした。結果、立木の3次元位置推定誤差のRMSEは水平方向0.32 m (標準偏差0.15 m)、垂直方向0.48 m (標準偏差0.37 m)、胸高直径は0.09 m (標準偏差0.07 m)となった。距離に対する推定誤差の変動を算出したところ(図-8)、垂直方向のRMSEが増加した。水平方向、胸高直径のRMSEに顕著な変動は確認できなかった。

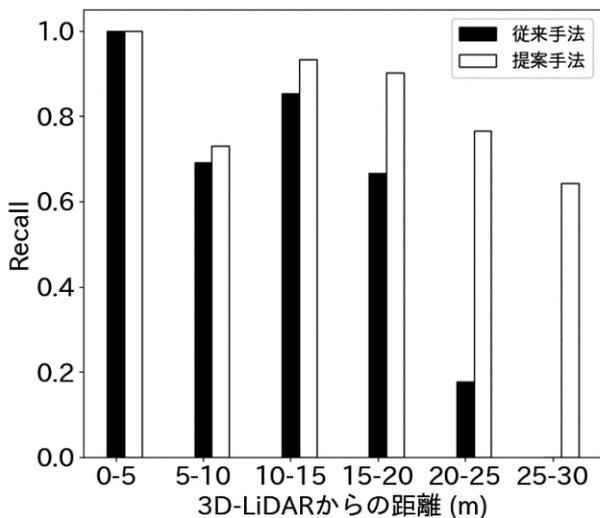


図-7 立木検出における再現率 (Recall) の算出結果

### 4. 考察

従来手法と提案手法の適合率を比較すると、10 m 未満の近距離において、提案手法の適合率が従来手法と比較して向上した。この要因を考察すると、林分の外部は遮蔽物が無く日当たりが良好であったことから下層植生や立木の枝葉が繁殖しており、かつ3D-LiDARは林分の外部から内部に向けて設置されていた。このため、3D-LiDARに対して近距離は繁殖した下層植生や立木の枝葉が存在し、これらが立木として誤検出され従来手法の適合率が低下したと予想される。提案手法は下層植生等による遮蔽を再現した教師データを使用し学習していることから、近距離において繁殖した下層植生や枝葉を立木と誤検出する割合が低下し、従来手法と比較して適合率の低下を抑制できたと推測される。また、立木と3D-LiDARの距離が10 m以上に増加しても、従来手法と比較して提案手法の適合率は低下せず、常に従来手法より高い値が得られた。1方向から測定された点群を測定すると、立木までの距離の増加に応じて点群密度が低下し、かつ他の立木や下層植生に遮蔽される。従来手法は立木の点群密度が低下した場合が想定されておらず、また検出に必要な地面の点群が不足したことから適合率が低下したと予想される。一方、提案手法は、点群密度の低下や遮蔽により点群が不足した場合の教師データが多く得られており、このような状況に対応することができたと考えられる。

再現率について考察すると、従来手法・提案手法に共通する傾向として、立木と3D-LiDARの距離が5 m~10 mの区間で低下し、10 m~15 mにおいて一時的に上昇し、15 m以降の遠距離になると再度低下した。5 m~10 mの区間の再現率の低下は、林分の境界で繁殖した下層植生により立木が遮蔽されたため未検出の立木が発生し、再現率が低下したと考えられる。その後、10 m~15 mの距離において林分の内部となり下層植生の減少により再現

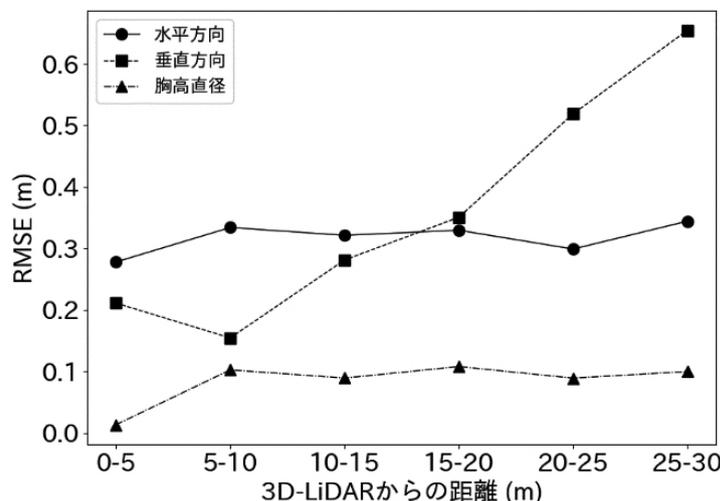


図-8 立木の3次元位置と胸高直径の推定精度

率が一時的に上昇し、15 m 以降の遠距離では点群の密度の低下により、再び未検出の立木が増加し再現率が低下したと推測される。従来手法、提案手法の再現率を比較すると、提案手法の再現率は15 m 以降において従来手法よりも向上した。教師データには極めて点群密度の低い状態で立木を検出するためのデータが多く含まれており、点群密度が低下する遠距離においても、立木の未検出を防止できたと考えられる。提案手法により検出された立木1本あたり計測点群数をカウントしたところ、遠距離に存在する立木において最低5点あれば検出することが可能であった。ただし、点群が幹の上下方向に沿って取得された場合に限られていた。5点よりも点群密度が低い場合や、幹の上下方向に沿った点群の配置とならない点群については、学習データを増加させても立木検出の学習において有効でない可能性がある。また、低層の雑木等において同様の点群が取得される可能性があるため、極端に点群の少ない立木については学習に有効でないことが予想される。

立木の位置推定誤差を考察すると、水平方向は遠距離・近距離にかかわらず約0.3 mの誤差が生じ、垂直方向では遠距離となるほど誤差が増加した。近距離でも約0.3 mの誤差が生じた要因として、学習の経過を確認したところ、教師データのうち学習用データに対する位置推定誤差は学習の進行に伴い低下したが、評価用データでは学習の初期の時点で誤差が最小となり、それ以降、学習が進行しても誤差が減少しなかった。学習の進行に対して誤差が減少しなかった原因として、立木密度を一定としたことや、地面メッシュの勾配のばらつきが不足し、仮想森林の条件が単純だったため、学習用データに過剰に最適化され未知のデータに対する汎化性能が失われる状態（過学習と呼ばれる）となった可能性がある。その他の要因として、深層学習モデルの学習は評価関数により教師データと推定結果の誤差を求めることで行われるため、深層学習モデルのパラメータや評価関数を見直すことでより高い精度が得られる可能性がある。

垂直方向の誤差が距離の増加に伴って増大した原因として、3D-LiDARから照射されたレーザー光は、平坦な環境では遠距離ほど地面に対して鋭角に照射されるため、地面に対する光路が低くなり下層植生に遮蔽される可能性が高くなる。高さを推定する上で基準となると考えられる地面の点群が、遠距離となるほど光路が低くなり下層植生の遮蔽により得られなくなったため誤差が増加したと考えられる。より教師データを充実させることで、垂直方向の推定精度を改善する必要があると考えられる。傾斜地で運用するケースを考慮すると、作業道から谷側の斜面の立木を検出したい場合に、レーザーの入射角が鋭角となり下層植生の遮蔽により遠近ともに地面点群の消失が顕著となることが予想される。勾配のない環境より垂直方向の精度が低下する可能性があるため、実際の傾斜地を模倣した勾配を仮想森林に設定し、地面点群

が消失した教師データを取得する必要がある。

胸高直径の推定誤差は0 m～5 mにおいて低い値となったが、5 m以上の距離において増加し0.1 m程度の一定の誤差が存在した。水平誤差と同様に、学習時の初期において推定誤差の減少が停止していたことから、汎化性能が得られず、実際の森林においても十分な精度が得られなかったことや、深層学習モデルのパラメータ、評価関数が原因と考えられる。

提案手法における立木の3次元位置の推定精度は、水平方向のRMSEが0.32 m、垂直方向0.48 mとなった。自動化の際、立木の把持動作に水平・垂直方向の精度が影響すると考えられる。また、掛かり木とならないよう伐倒方向を制御する場合や、効率よく伐倒木を引き出し玉切りするためには水平方向の精度が影響すると考えられる。特に把持動作は近距離における高い立木位置・直径の推定精度が必要であると考えられるため、提案手法の精度を改善する必要があると考える。また、胸高直径における推定誤差のRMSEは0.09 mとなったが、木材を把持する上で立木の質量や重心位置の推定が必要となる可能性があり、直径の精度についても改善が必要であると考える。

## 5. おわりに

本研究では、ゲームエンジンにより仮想的な森林環境を構築することで、点群の不足を再現した教師データを効率よく生成し、得られた教師データを用いて深層学習におけるネットワークの学習を行った。これにより点群の不足時においても立木を検出し、検出した立木の3次元位置および胸高直径を推定可能な手法を提案した。

提案手法は下層植生による立木の遮蔽による適合率の低下や、遠距離の点群密度の低下における適合率および再現率の低下を抑制することが可能であり、これは下層植生等による遮蔽や点群密度の低下がある場合の教師データが十分に存在していたためと考えられる。ゲームエンジンで構築した仮想森林から得た疑似的な点群や立木の位置、直径などの教師データは、立木の検出というタスクにおいて有用であることを確認することができた。一方で立木の3次元位置と胸高直径の推定精度において、仮想森林の条件不足による過学習、もしくは深層学習モデルのパラメータに問題があると考えられる水平方向・垂直方向の位置推定誤差が生じた。また、立木の垂直方向の位置推定誤差において、地面点群の不足によるものと考えられる誤差の増加があることを確認した。

今後は、立木密度や地面勾配にばらつきを持たせることで仮想森林の条件を複雑化し立木の3次元位置推定精度の向上を目指す。さらに深層学習モデルのパラメータや評価関数を見直すことで、3次元位置および直径の推定精度の向上を図る。特に立木密度について、本研究の仮想森林の立木密度は500本/haとしており、これは実験に用いた実際のヒノキ林の立木密度に近い値として設

定した。このため立木密度が大きく異なる森林に対応するには様々な立木密度をもつ教師データが必要になると考えられるが、新たな問題として立木密度が過密な教師データに影響され下層植生を立木と誤検出する場合や、立木密度が疎な教師データに影響され立木が未検出となる割合が増加することが予想される。このような問題が生じた場合、深層学習モデルのパラメータを精査する必要がある。また、伐木用機械の自動化を目的として、立木の傾斜角度および重心の推定や、伐倒木、伐根等についても検出可能となるよう、教師データの作成手法および深層学習モデルの開発を行っていく。

仮想森林を活用した将来的な展望として、立木メッシュの樹高、曲がり、細り率、根際形状、断面形状等のパラメータ化し、パラメータに応じた立木の変形を再現し学習することで、実際の立木に対してこれらパラメータを推定できる可能性がある。また、立木メッシュの樹種を充実させることで、林分が広葉樹の場合でも立木のパラメータの推定が可能になると考えられる。そのほか、Digital Terrain Model (DTM) を地面メッシュとして配置し、現実の勾配条件を再現することで過学習の防止や、傾斜地への適用が可能となると考えられる。これらの可能性について今後検証していく。

本研究は(国研)森林研究・整備機構森林総合研究所交付金プロジェクト(課題番号202306)の研究成果である。また、本研究の深層学習モデルの学習において、農林水産研究情報総合センター科学技術計算システムのAI用ノードを活用した。本研究で使用したヒノキ林全体の点群データは瀧らの研究成果(瀧ら2021)より提供されたものである。ここに謝辞を申し上げる。

### 引用文献

Burt, A., Disney, M. and Calders, K. (2019) Extracting individual trees from lidar point clouds using treeseg. *Methods Ecol. Evol.* **10** (3): 438-445.

Caesar, H., Bankiti, V., Lang, A.H., Vora, S., Liong, V.E., Xu, Q., Krishnan, A., Pan, Y., Baldan, G. and Beijbom, O. (2020) nuScenes: A multimodal dataset for autonomous driving. In: 2020 IEEE/CVF Conf. Comput. Vis. Pattern Recognit.: 11618-11628.

Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A. and Koltun, V. (2017) CARLA: An Open Urban Driving Simulator. In: 1st Annual Conf. Rob. Learn.: 1-16.

Geiger, A., Lenz, P. and Urtasun, R. (2012) Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite. In: 2012 IEEE Conf. Comput. Vis. Pattern Recognit.: 3354-3361

岐阜県林政部 (1992) スギ人工林林分収穫表・林分密度管理図. オンライン, (<https://www.pref.gifu.lg.jp/uploaded/attachment/48141.pdf>). 2024年9月20日参照.

Grondin, V., Fortin, J., Pomerleau, F. and Giguère, P. (2022) Tree detection and diameter estimation based on deep learning. *Forestry: Int. J. For. Res.* **96** (2): 264-276.

今富裕樹 (2003) 伐木作業におけるリスクテイキング行動分析. *森利誌* **18** (1) : 37 ~ 41.

Itakura, K. and Hosoi, F. (2020) Automatic Tree Detection from Three-Dimensional Images Reconstructed from 360° Spherical Camera Using YOLO v2. *Remote Sens.* **12** (6): 988.

Lang, A.H., Vora, S., Caesar, H., Zhou, L., Yang, J. and Beijbom, O. (2019) PointPillars: Fast Encoders for Object Detection From Point Clouds. In: 2019 IEEE/CVF Conf. Comput. Vis. Pattern Recognit.: 12689-12697.

Maas, H.G., Bienert, A., Scheller, S., and Keane, E. (2008) Automatic forest inventory parameter determination from terrestrial laser scanner data. *Int. J. Remote Sens.* **29** (5): 1579-1593.

McDaniel, M.W., Nishihata, T., Brooks, C.A., Salesses, P. and Iagnemma, K. (2012) Terrain classification and identification of tree stems using ground-based LiDAR. *J. Field Rob.* **29** (6): 891-910.

岡勝・中澤昌彦・佐々木達也・吉田智佳史・上村巧・鹿島潤・加藤隆 (2011) 高性能林業機械の導入後10年目における林業労働死亡災害の考察. *森利誌* **26** (1) : 27 ~ 34.

Othmani, A., Piboule, A., Krebs, M., Stolz, C. and Lew Yan Voon, L.F.C. (2011) Towards automated and operational forest inventories with T-Lidar. In: 11th Int. Conf. LiDAR Appl. Assess. For. Ecosyst. (SilviLaser 2011).

林業・木材製造業労働災害防止協会 (2022) 令和3年における林業・木材製造業の死亡労働災害分析結果と再発防止対策について－林業編. オンライン, ([https://www.rinsaibou.or.jp/safety/assets/safety/R3-bunsekitaisaku\\_ring.pdf](https://www.rinsaibou.or.jp/safety/assets/safety/R3-bunsekitaisaku_ring.pdf)). 2024年9月20日参照.

林野庁 (2024) 林業労働災害の現況. オンライン, (<https://www.rinya.maff.go.jp/j/routai/anzen/iti.html>). 2024年9月20日参照.

Tansey, K., Selmes, N., Anstee, A., Tate, N.J. and Denniss, A. (2009) Estimating tree and stand variables in a Corsican Pine woodland from terrestrial laser scanner data. *Int. J. Remote Sens.* **30** (19): 5195-5209.

Thies, M., Pfeifer, N., Winterhalder, D. and Gorte, B.G.H. (2004) Three-dimensional reconstruction of stems for assessment of taper, sweep and lean based on laser scanning of standing trees. *Scand. J. For. Res.* **19** (6): 571-581.

Tremblay, J., Béland, M., Gagnon, R., Pomerleau, F. and

- Giguère, P. (2020) Automatic three-dimensional mapping for tree diameter measurements in inventory operations. *J. Field Rob.* **37** (8): 1328-1346.
- 瀧誠志郎・青木三六・小路丸未来・稲田純次 (2021) AI搭載ドローンによる森林内空撮と三次元モデルの構築. *森利誌* **36** (3) : 151 ~ 160.
- Wang, B.H., Diaz-Ruiz, C., Banfi, J. and Campbell, M. (2021) Detecting and Mapping Trees in Unstructured Environments with a Stereo Camera and Pseudo-Lidar. In: *2021 IEEE Int. Conf. Rob. Autom.*: 14120-14126.