

修士論文

# オブジェクト指向画像分類を用いた 地上型レーザスキャナの点群の分類

令和 6 年度

三重大学 工学研究科 情報工学専攻  
423M522 前田 直哉

# 概要

日本の林業では労働力不足という深刻な課題に対応するためにリモートセンシング技術の活用が進められている。本研究では、地上型レーザスキャナ（Terrestrial Laser Scanner：TLS）を用いて、針葉樹の部位（幹、枝、葉）の分類を行う新たな手法を提案した。三次元（3D）空間において点同士の関係を適切に捉えることが困難である、という従来の課題を克服するため、画像のオブジェクト指向分類を適用した。本研究では、提案手法の有効性を検討した。

本手法では、TLS で取得した 3D 点群データを直交座標から極座標に変換し、天頂角と方位角を基軸にした二次元（2D）画像を作成した。画像には、距離や反射強度に加え、距離の標準偏差や隣接画素間の距離の差分など 9 種類の特徴量を付与した。次に、セグメンテーションを実施して、似た特徴量を持つ隣接画素をいくつか集合させたセグメントに分割した。各セグメントには、画素に付与した 9 種類の特徴量から計算した平均と標準偏差に加えて、オブジェクトに基づく二つの特徴量（周長の二乗に対する面積の比とアスペクト比）を付与し、合計 20 種類の特徴量を使用して分類を行った。分類には、サポートベクターマシン（Support Vector Machine：SVM）とランダムフォレスト（Random Forest：RF）を使用した。

SVM と RF のいずれも高い分類精度を達成し、F-measure がそれぞれ 0.82 と 0.83 であった。傾向として、SVM は TLS から離れた地面や幹の分類精度が高く、RF は葉の分類において優れた性能を示した。Permutation Feature Importance（PFI）により変数の重要度を調査した結果、SVM は Z 座標の平均や Y 座標の平均など座標に基づく特徴量の重要度が高かった一方で、RF は反射強度や TLS からの距離の標準偏差などに関する特徴量の重要度が高かった。ある観測データで学習させたモデルを、他の計測データへ適用した結果、SVM と RF の F-measure はそれぞれ 0.17 と 0.39 と著しく低下した。現段階では、測定データごとに学習させる必要がある。

今後の課題として、既存手法との精度比較を行い、分類モデルの性能を定量的に評価するため、既存手法との精度比較を行う必要がある。また、PFI の結果を踏ま

えて特徴量の最適化を進め、さらに高い分類精度を実現することが期待される。本手法は、林業の作業効率の向上に貢献するだけでなく、TLS 点群処理ソフトウェアへの実装を通じて、他分野への応用も視野に入れた展開が可能である。

# 目次

<b>第 1 章</b>	<b>はじめに</b>	<b>1</b>
1.1	研究背景 . . . . .	1
1.1.1	林野庁における林業 . . . . .	1
1.1.2	地上型レーザスキャナの研究 . . . . .	2
1.1.3	樹木の部位の分類 . . . . .	3
1.2	関連研究 . . . . .	4
1.2.1	Liu らによる 3D モデリングに関する研究 . . . . .	4
1.2.2	Wang らによる機械学習を用いた樹木部位の分類に関する研究 . . . .	4
1.2.3	江藤と増田による樹木部位の形質を抽出する研究 . . . . .	5
<b>第 2 章</b>	<b>使用データ</b>	<b>6</b>
2.1	データ取得 . . . . .	6
2.2	点群 . . . . .	7
2.3	地上型レーザスキャナ . . . . .	8
2.3.1	地上型レーザスキャナ . . . . .	8
2.3.2	使用した地上型レーザスキャナ . . . . .	9
<b>第 3 章</b>	<b>手法</b>	<b>11</b>
3.1	研究の目的 . . . . .	11
3.2	解析の流れ . . . . .	11
3.3	二次元画像作成 . . . . .	12
3.3.1	作成方法 . . . . .	12
3.3.2	画像に付与した特徴量 . . . . .	13
3.3.3	その他の処理 . . . . .	14
3.4	セグメンテーション . . . . .	15
3.4.1	セグメンテーション方法 . . . . .	15
3.4.2	セグメンテーションのアルゴリズム . . . . .	16



3.5	分類 . . . . .	16
3.5.1	分類方法 . . . . .	16
3.5.2	セグメントに付与した特徴量 . . . . .	17
3.5.3	学習と評価に用いる正解ラベル . . . . .	18
3.5.4	分類アルゴリズム . . . . .	18
3.5.5	分類精度の評価 . . . . .	18
3.6	点群への分類結果の付与 . . . . .	19
3.7	他の計測データへの学習済みモデルの適用 . . . . .	20
<b>第 4 章</b>	<b>結果と考察</b>	<b>21</b>
4.1	作成された二次元画像 . . . . .	21
4.2	セグメンテーション . . . . .	22
4.3	分類 . . . . .	23
4.3.1	正解ラベル . . . . .	23
4.3.2	分類結果 . . . . .	23
4.3.3	評価指標 . . . . .	25
4.4	点群への分類結果の付与 . . . . .	29
4.5	他の計測データへの学習済みモデルの適用 . . . . .	30
<b>第 5 章</b>	<b>まとめ</b>	<b>32</b>
5.1	まとめ . . . . .	32
5.2	展望 . . . . .	32
<b>謝辞</b>		<b>33</b>
<b>参考文献</b>		<b>34</b>
<b>付録 A</b>	<b>高画質画像での補足</b>	<b>37</b>
<b>付録 B</b>	<b>画像作成の詳細手法</b>	<b>41</b>

# 第 1 章

## はじめに

### 1.1 研究背景

#### 1.1.1 林野庁における林業

近年、日本の林業界は、労働力に関するいくつかの課題に直面している。中でも、深刻な課題は林業従事者数の減少である。林野庁の報告によると、過去 40 年間で林業従事者数は約 3 分の 1 に減少した（図 1.1）[1]。林業従事者数の減少により、生産性や持続可能性が低下し、業界全体の発展が阻まれる恐れがある。以上のような状況を打破するため、林野庁では、リモートセンシング技術の活用が推進されている [2]。リモートセンシング技術の活用により、労働力を削減しつつ、作業の効率化や精度向上が期待されている。リモートセンシング技術は、地上型レーザスキャナ（Terrestrial Laser Scanner：TLS）をはじめ、レーザ光を照射して反射光から対象物までの距離や形状を計測する技術（Light Detection and Ranging：LiDAR）などのレーザを用いた技術が含まれる。加えて、Landsat や Sentinel などの衛星データ、無人航空機（Unmanned Aerial Vehicle：UAV）によって撮影された航空画像なども含まれる。リモートセンシング技術は、広範囲にわたる森林のモニタリングを可能にし、効率的かつ正確に森林資源を把握することができる。




Fig. 1.1: 林業従事者数の推移（参考文献 [1] のデータより作成）

リモートセンシングで取得したデータを利用することで、樹高や胸高直径、樹種、および樹木の本数など、森林の様々な属性を抽出できる [3]。属性の情報は、伐採や出荷作業における木材製品の品質向上や、生産性の改善に寄与する重要な要素となる。さらに、日本の人工林のほとんどは針葉樹（主にスギ、ヒノキ、カラマツ）で占められている [4]。針葉樹の形状や状態を正確に評価するためのリモートセンシング技術の活用は、非常に価値があり、今後の林業における重要な分野といえる。

### 1.1.2 地上型レーザスキャナの研究

リモートセンシング技術の中でも、TLS は特に針葉樹の構造の詳細な測定に適している。理由は、地上から 360° の範囲を計測できるため、他のリモートセンシング技術と比べて、樹冠の干渉を受けにくい側面からの測定が可能だからである。

TLS は、衛星データや UAV と組み合わせることで森林資源量の推定 [5]、ユーカリの点群による枝や葉の 3D モデル化 [6]、さらには日本庭園の多種多様な樹種樹木の高精度な再現 [7] など、様々な分野で応用されている。TLS の応用範囲は広く、林業の研究においても注目されている。実際、近年では TLS を用いた林業作業の効率が追求されており、TLS を活用した林業に関する研究数は増加していると報告されている（図 1.2） [8]。




Fig. 1.2: TLS の研究数の推移（参考文献 [8] のデータより作成）

### 1.1.3 樹木の部位の分類

リモートセンシング技術で針葉樹の形状と状態を正確に評価するためには、樹木の部位（幹、枝、葉）の分類が必要不可欠である。理由は、樹木の部位でサイズ、使用用途、および特性が大きく異なり、実用においては部位単位での形状と状態が求められるからである [9]。例えば、幹や枝の大きさを特定できれば、樹木の伐採前に取得できる資源の量を推定し、不必要な伐採を防止できる。また、点群データを定点的かつ継続的に取得し、比較することで樹木の成長を測定することもできる。樹木の成長の測定により、幹の伐採時期や、葉や枝の剪定時期を推定でき、結果として労働コストの削減に繋がる。さらに、樹木の三次元（3D）モデル化は、様々なシミュレーションに応用が可能である。例えば、点群データから樹木を除去することで、伐採後の区画整備計画に利用できる。また、枝に積雪がかかった場合の負荷を物理エンジンを使ってシミュレーションすることで、一般市民の事故防止にも寄与できる。したがって、TLSで取得した点群を樹木の部位に分類することは、林業において重要な役割を果たす。

## 1.2 関連研究

### 1.2.1 Liu らによる 3D モデリングに関する研究

Liu ら [10] は、広葉樹の 3D 点群データを用いて、幹や枝などの各部位を自動的に分解し、高精度な再構成を可能にする新しいディープラーニングフレームワーク「TreePartNet」を提案した。従来の樹木モデリング手法では、手動で操作する必要がある、ノイズや欠損に対して脆弱であるという課題があった。一方、TreePartNet は、学習ベースのアプローチを採用し、点群データから樹木構造を自動的に抽出・分離することで、現実的かつ詳細な形状復元を実現した。TreePartNet では、樹木に関する部位分類の手法がいくつか使用された。具体的には、幹の太さや枝の階層構造といった広葉樹特有の特徴を捉えるためのアルゴリズムを用いることで、点群データをセグメント化し、幹や枝などの部位ごとに分類した。また、グラフニューラルネットワーク（Graph Neural Network：GNN）を活用し、点群データの局所的小域的特徴を学習することで、幹から枝、枝から小枝といった階層的な関係を捉えることが可能となり、複雑な樹木構造の分解精度を向上させた。TreePartNet を、取得した広葉樹のデータに適用した結果、幹や枝をより正確に分類し、複雑な広葉樹の樹木構造を詳細に捉えていた。ノイズや欠損の多い非常に大規模な点群データに対しても高い精度を発揮したことで、既存の手法より性能面で大幅な向上が示された。

### 1.2.2 Wang らによる機械学習を用いた樹木部位の分類に関する研究

Wang ら [11] は、TLS 点群データを用いて、木材部分（幹・枝）と非木材部分（葉）を区別するための機械学習手法の適用可能性を検討した。従来の手法における課題として、さらなる自動化・汎用化が挙げられていた。複数の機械学習アルゴリズムを比較し、それらの分類精度、特徴選択、および実用性を評価することで、TLS 点群データ処理の効率化と精度向上を目指した。樹木の TLS 点群データから得られる特徴量を基に、機械学習が行われた。学習に使用した特徴量は、点の標高、密度、最近傍点までの距離、法線ベクトル、曲率、レーザの反射強度などであった。また、機械学習手法は、汎用性が高く、特徴量の重要度を明確に評価可能なランダムフォレスト（Random Forest：RF）と高次元特徴空間での分類性能が優れるサポートベクターマシン（Support Vector Machine：SVM）とデータの分布を柔軟にモデル化できる Gaussian Mixture Model と確率モデルに基づく分類手法である Naïve Bayes の 4 種類を使用した。結果、特徴量の中では、法線ベクトルや曲率といった形状特徴が分類精度に大きく寄与していた。さらに、最も高い分類精度を示した手法は RF であり、次が SVM であった。どちらの手法も、分類精度と計算効率のバランスが取れており、高い実用性が示された。

### 1.2.3 江藤と増田による樹木部位の形質を抽出する研究


江藤と増田 [12] は、TLS を用いて取得した森林の点群データから、幹、枝、葉といった樹木の主要部位を分離し、それぞれの部位に対応する形質を高精度で抽出する方法を提案した。まず、地面点の検出や座標補正を行い、樹木全体の位置情報を正確に把握するための準備を整えた。次に、高さ情報や密度解析を組み合わせたクラスタリング手法を用いて、点群データを幹、枝、葉に分類した。幹のような直線的な構造を特定するために、Random Sample Consensus (RANSAC) によるフィッティングが用いられた。幹から分岐する枝は、階層的な構造を考慮した分類アルゴリズムが適用された。形質の抽出では、幹の直径や高さといった基本的なパラメータが点群の断面形状解析により推定された。具体的には、任意の高さで点群の断面を切り出し、2D 平面上で円にフィッティングを行うことで、幹の直径が計算された。一方、葉の形質抽出では、葉の点群が幹や枝よりも密度が低い特性を利用し、葉面積や配置密度が推定された。結果、スギやヒノキなど特定の樹種を対象とした森林管理や収穫量推定に対する提案手法の応用可能性が示された。

## 第 2 章

# 使用データ

### 2.1 データ取得

点群データは，三重大学大学院生物資源学研究科附帯施設演習林（平倉演習林）で取得した．平倉演習林は，三重県津市美杉町に位置し，その座標は北緯 34 度 27 分，東経 136 度 14 分である（図 2.1）．



**Fig. 2.1:** 平倉演習林の位置

研究の対象とした樹木は針葉樹（スギおよびヒノキ）で，樹高は約 30 メートルである．測

定においては、一部（樹冠部分と TLS の視点から隠れる樹木の裏側）を除いた全ての部分を計測できた。データ取得は、2023 年 10 月 11 日の 10:00 から 17:00、および 10 月 12 日の 10:00 から 14:00 に実施した。いずれの日も天候は晴れであった。測定は演習林内の 3 地点で実施し、各地点において 5 箇所からスキャンを行った。スキャンの正確な位置合わせを目的として、8 個の基準球 (Reference sphere) を配置し、TLS が少なくとも 5 個の基準球を視認できる位置に設置した。取得の様子を図 2.2 に示す。




Fig. 2.2: 平倉演習林における点群の取得の様子

## 2.2 点群

点群は、3D 空間内の点の集合として定義されるデータ形式であり。物体の形状や空間的構造を詳細に記録・分析するために利用される。各点には、空間座標である  $x$ ,  $y$ ,  $z$  に加えて、反射強度、色情報 (RGB)、法線ベクトルなどの属性が付与される場合もある。点群データは、TLS, UAV, および専用のカメラなどを用いて取得できる。

図 2.3 は、iPad Pro の LiDAR 機能を用いて大学内の樹木を撮影した点群データを例示した。赤枠で囲まれた部分は拡大して表示しており、実際に点群がどのように視認できるかを示している。なお、本研究で扱うデータは、TLS によって取得したものであり、より大規模かつ高密度な点群データである。





Fig. 2.3: 点群の例

## 2.3 地上型レーザスキャナ

### 2.3.1 地上型レーザスキャナ

TLS は、 $360^\circ$  回転しながらレーザを照射し、反射光を検出することで点群データを取得する装置である。林業のほか、道路整備のための測量 [13]、鉄道車両に搭載して線路の安全点検を行う分析など、幅広い分野で利用されている。通常、TLS は複数の位置から対象物をスキャンし、レーザが届かない領域を補うことで、より詳細な点群データを取得する。複数のスキャン位置で取得されたデータは、対象物の周囲に配置された基準球を使用して位置合わせが行われる。図 2.4 では、それぞれの TLS から見える基準球を用いて位置合わせを行い、1 台の TLS ではカバーできない範囲を補完し、広範囲かつ詳細な点群データを生成する様子を示している。一方、本研究の手法では、複数回のスキャンデータではなく、1 回のスキャンデータに対して処理を行う。理由は、TLS を中心とした円筒面に再投影する手法を採用しているためである。複数回のスキャンデータを用いる場合、本手法は適用が困難であり、1 回のスキャンデータで完結できる点は、本手法の利点の一つである。




Fig. 2.4: 位置合わせを表す図

### 2.3.2 使用した地上型レーザスキャナ

図 2.5 は、本研究で使用した TLS の写真である。本研究では、FARO 社製の「FARO Focus3D X330」を使用した。これは、研究室でレンタルしたもので、解像度は「1/2」、品質は「4 倍」に設定した。この条件で、1 回のスキャンに約 30 分を要し、約 1 億 7300 万点の点群データを取得した。



Fig. 2.5: 使用した TLS の写真

TLS で取得したデータは、FARO 社の点群処理ソフトウェアである SCENE[14] で、確認を行った (図 2.6)。SCENE では、取得したデータに対して位置合わせや、カラーカメラで撮影した画像を用いた色情報を付与することが可能である。一方、本研究では、より汎用性の高い形式でデータを利用することを目的とし、TLS データの出力を「 $x, y, z$  座標」と「反射強度」のみに限定した。また、プログラミングを行いやすい点群フォーマットである PLY 形式に変換した。




Fig. 2.6: 確認した点群データ

## 第 3 章

# 手法

### 3.1 研究の目的

針葉樹林の 3D 点群の正確な分類には、現在でも多くの課題が残されている。課題の一つの原因として、3D 空間における点同士の関係を適切に表現することが困難であることが挙げられる [15]。例えば、隣接する点同士が同じ部位を表すと仮定し、これを繰り返し作業することで、部位分類ができると考えられる。しかし、3D 空間では「隣接する点」の定義自体が曖昧であるため、その解法が複雑化してしまうという問題に直面する。そこで、本研究では新しい分類手法を提案する。提案する手法では、点群データを平面上に投影された 2D 画像として扱い、画像を基にオブジェクト指向の分類を行う。各画素（点）は、画素の属するオブジェクトに基づいて個別に分類され、最終的に画素は元の 3D 空間に戻すことで 3D データ（点群）を再構築する。手法の利点は、3D 空間で隣接点との関係を直接取得するのが難しい部分を、「隣接している四方の画素」として定義することで効率的に処理できることにある。したがって、2D 画像を介することで隣接している四方の画素などの新たなバイアスを加えられるため、分類精度の向上が期待できる。さらに、従来 3D で行っていた処理を 2D で行うことで、単純に計算速度の減少から、処理時間の短縮にも寄与できると考えられる。本研究の目的は、提案する新たな手法の実現可能性と妥当性を評価し、さらに改善と応用の可能性を探ることである。

### 3.2 解析の流れ

本研究の解析の流れを図 3.1 に示す。まず、取得した TLS 点群を用いて、2D 画像を作成した。作成した 2D 画像の画素には、特徴量を付与した。その後、付与した特徴量を用いて、セグメンテーションを行い、画素の集合であるセグメントを作成した。また、各セグメントに、画素を用いた特徴量とセグメントの形状の性質を反映した特徴量を付与した。作成したセグメントは、SVM と RF で分類した。そして、2D 画像の画素を分類したオブジェクトにフィッ

ティングさせて，対応する分類結果を付与した点群に再変換した．

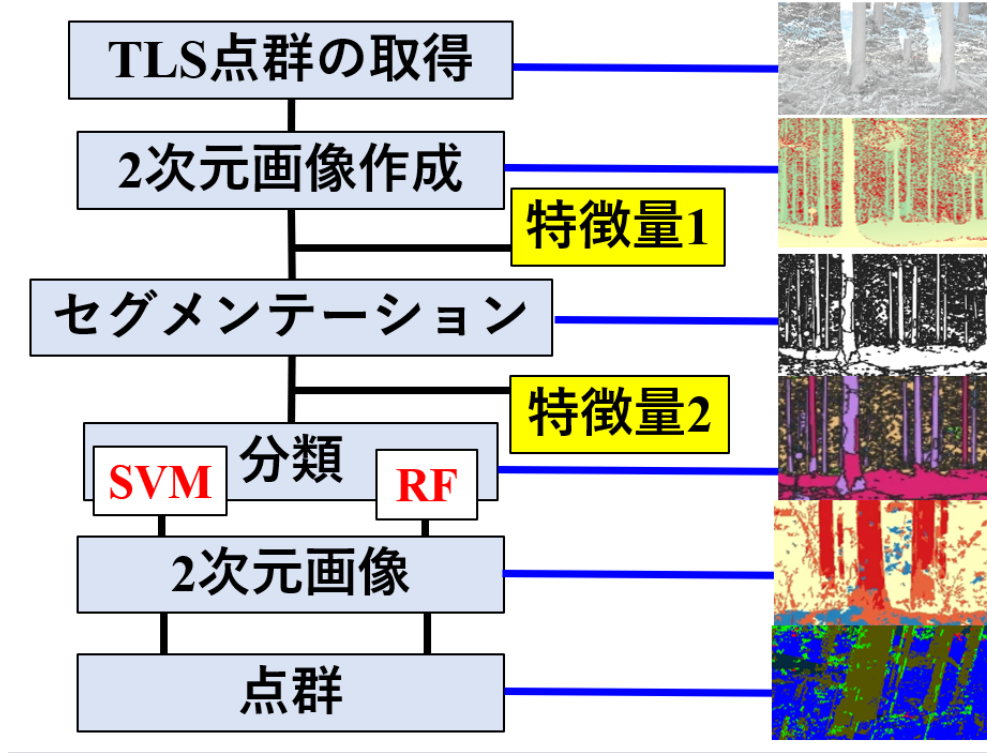


Fig. 3.1: 解析の流れ

### 3.3 二次元画像作成

#### 3.3.1 作成方法

TLS で取得した点群データを使用し，2D 画像を作成した．各点群の 3D 位置座標 ( $x, y, z$  座標) を，3D 極座標に変換することで，画像のピクセル情報を構成した．以下に，極座標への変換式を示す．

$$r = \sqrt{x^2 + y^2 + z^2}$$

$$\theta = \cos^{-1} \left( \frac{z}{r} \right)$$

$$\phi = \text{sgn } y \cdot \cos^{-1} \left( \frac{x}{\sqrt{x^2 + y^2}} \right)$$

ここで， $\theta$  は天頂角 ( $-\pi/2 < \theta < \pi/2$ )， $\phi$  は方位角 ( $-\pi < \phi < \pi$ )， $\text{sgn } y$  は， $y$  の符号を返す．天頂角と方位角は，TLS を原点とした球面座標系を基に算出された．図 3.2 は，2D 画像

作成の具体的な処理を表す。天頂角を縦軸，方位角を横軸とした 2D 平面上に，各点群を対応させて並べることでパノラマ画像に似た画像を生成した。このとき，縦軸と横軸のスケールは TLS で取得した情報と対応させて，取得した点群の数と画素の数を概ね近づけた。

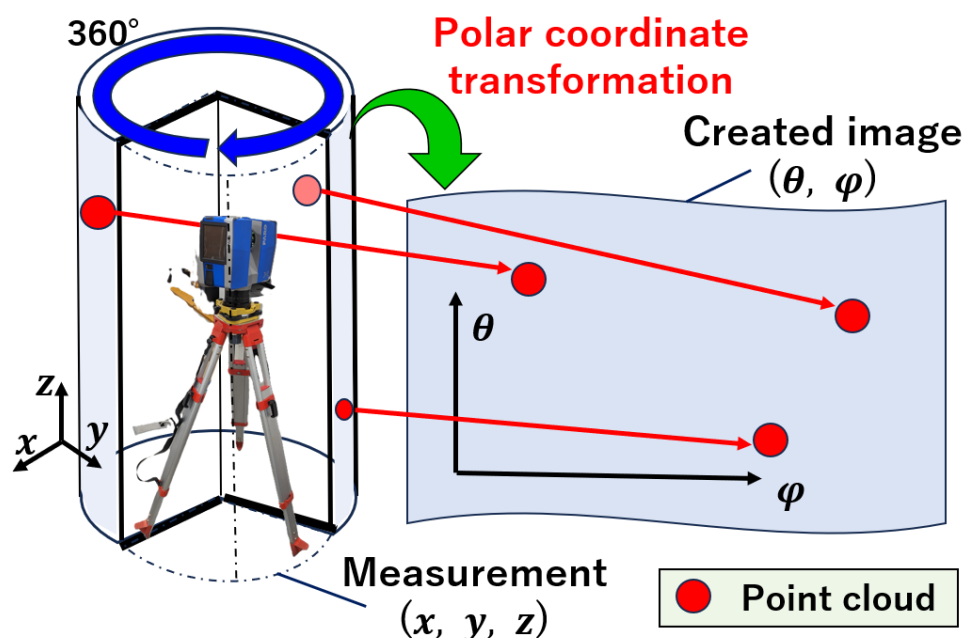


Fig. 3.2: 画像作成の処理フロー

### 3.3.2 画像に付与した特徴量

作成した 2D 画像の画素には，以下の 9 つの特徴量を付与した。結果の画像は Quantum Geographic Information System(QGIS)[16] を用いて可視化した。

- $x$  座標  
TLS で取得した座標。
- $y$  座標  
TLS で取得した座標。
- $z$  座標  
TLS で取得した座標。地面は低い値，葉は高い値を示し，高度に基づく特徴を反映する可能性が高い。
- 反射強度  
TLS で取得した値。木材部分 (幹や枝) と非木材部分 (葉) で大きな違いが見られる可能性が高い。
- TLS からの距離

三次元極座標変換で計算された距離。近接する画素の距離に差がなければ、同じオブジェクトに属する可能性が高い。

- **反射強度の標準偏差**

反射強度画像の  $3 \times 3$  画素を用いて計算した標準偏差を特徴量として中心画素に付与した。これにより、各部位のエッジが鮮明になる可能性が高い。

- **TLS からの距離の標準偏差**

TLS からの距離画像の  $3 \times 3$  画素を用いて計算した標準偏差を特徴量として中心画素に付与した。これにより、各部位のエッジが鮮明になる可能性が高い。

- **距離画像の上下隣接画素の絶対値の差**

TLS からの距離画像の上下隣接画素の差の絶対値を計算した最大値。幹は横方向の円柱形であるため小さな値を示し、枝は縦方向の円柱形であるため大きな値を示す可能性が高い。

- **距離画像の左右隣接画素の絶対値の差**

TLS からの距離画像の左右隣接画素の差の絶対値を計算した最大値。幹は横方向の円柱形であるため大きな値を示し、枝は縦方向の円柱形であるため小さな値を示す可能性が高い。

### 3.3.3 その他の処理

本研究では、簡潔化するために以下の2つの追加処理を行った。1つ目の処理は、作成した画像に用いた全ての特徴量に対して、データの有無をそれぞれ1と0で表すマスク処理である。TLSからの距離を表す画像を用い、画素ごとに値を持つか否かを判定し、0または1のフラグを立てた。TLSからの距離が0である画素には点群が存在しないためである。その後、フラグを全ての特徴量の対応する画素に乗算することで、データのない画素を設定した。データがない部分を解析から外すことで、データを軽量化した。2つ目の処理は、作成した画像のサイズを半分にするのである。データを軽量化するとともに、2D画像の作成の際に生じた空白画素を埋めた。具体的な処理手順を図3.3に示す。






Fig. 3.3: 画像のサイズを半分にする処理

まず、画像を  $2 \times 2$  画素のブロック単位に分割し、ブロック内のデータを以下の優先順位で出力画素に反映した。左上の画素にデータがある場合、その画素を出力画素とする。左上以外の画素にデータがある場合、その画素を出力画素とする。その画素の優先順位は、右上、左下、右下という順番である。また、すべての画素のデータがない場合、その画素をデータなしとする。この処理は、全ブロックに対して適用した。本来、画像全体が取得した点群データによって塗りつぶされているため、この処理は不要である。しかし、データがない画素の削減の必要性和、処理時間の短縮を考慮し、追加的に実施した。結果として、データがない画素を削減するとともに、データ量も元の  $1/4$  に削減することができた。これらの処理は、Python のライブラリである rasterio[17] を使用して実装した。

## 3.4 セグメンテーション

### 3.4.1 セグメンテーション方法

作成した 2D 画像に対して、セグメンテーションを実行した。この論文内では、セグメンテーションにより生成された画素の集合を「セグメント」と称し、分類した後のセグメントを「オブジェクト」と称する。セグメンテーションにより生成されたセグメントは、それぞれ



オブジェクトの分類の単位として使用した。セグメンテーションは、画像処理およびリモートセンシングデータ解析向けのオープンソースソフトウェア Orfeo Toolbox[18] を使用した。Orfeo Toolbox は、オブジェクト指向の解析に適しており、QGIS にプラグインとして統合できる点で有用である。パラメータ調整は、画像全体を処理する前に、作成した画像の一部分をいくつか用いて、試行錯誤を行った。具体的には、パラメータを決めて、コマンドラインで実行して結果を確認、調整することを繰り返した。最終的に決定したパラメータを画像全体に適用させた。

### 3.4.2 セグメンテーションのアルゴリズム

本研究では、セグメンテーション手法として LargeScale MeanShift を使用した。これは、MeanShift 法を大規模データに適用可能とした手法であり、本研究のセグメンテーションにおいて有効である。MeanShift 法は、データ密度の極大値を探索する非パラメトリックな手法である。MeanShift 法の動きを図 3.4[19] に示す。まず赤い矢印で示される MeanShift ベクトルを計算する。このベクトルは、通常、確率密度が増加する方向を指しており、これに基づいてデータ点が反復的に移動する。数回の反復の後、データ点は図中の赤い点のように、密度分布の極大値であるモード点に収束する。このように、MeanShift 法は、データ点を密度の高い領域へと移動させることで、密度分布関数の極大値を検出する。この特徴を利用することで、画像セグメンテーションにおいては、検出された極大値をクラスターの中心と定義し、各画素を対応するセグメントに分類することが可能となる。

## 3.5 分類

### 3.5.1 分類方法

セグメンテーションによって生成されたセグメントに対して、セグメント単位で分類を実施した。Orfeo Toolbox の「Train Vector Classifier」を使用して、付与した 20 個の特徴量を基に分類を行った。また、セグメントに正解ラベルを手動で付与し、訓練用とテスト用に分けた後、教師あり学習に基づいて分類を行った。本研究では、分類アルゴリズムとして SVM と RF の 2 種類を用いた。それぞれのアルゴリズムにより、幹、枝、葉、地面（土、アスファルトに加えて、針葉樹の根、倒木なども含む）の 4 つのクラスに分類を実施した。その後、分類精度をいくつかの指標を用いて評価した。なお、本研究では最終的にデータの有無を表すマスク処理を再び行うため、分類した結果にはデータが含まれていないセグメントも分類対象に含む。




Fig. 3.4: Meanshift の動き（参考文献 [19] より抜粋）

### 3.5.2 セグメントに付与した特徴量

セグメントに付与したオブジェクト由来の特徴量として、セグメント内の画素に基づく 9 つの特徴量の平均値と標準偏差に加え、以下の 2 つの特徴量を追加した。これらは QGIS 上のフィールド計算機を用いて計算した。

- $\text{perimeter}^2/\text{area}$

物体の形状を定量的に評価するため、周長（perimeter）と面積（area）を用いた形状指標を特徴量として導入した [20]。この指標は、形状が円形に近い場合に小さな値を示し、形状が不規則になるほど大きな値を取る特性を持つ。周長の 2 乗を面積で割ることで、相対的に周長が長い形状を強調することが可能である。この指標は、セグメント間の形状の違いを定量化でき、特に枝や幹の細長い形状や葉の不規則な形状のセグメントを識別する際に有用である。

- アスペクト比

物体の形状を評価する指標としてアスペクト比を導入した [21]。アスペクト比は、形状の長軸と短軸の比率を表し、形状の縦横比を示す指標である。この指標は、長方形や楕円形など、方向性を持つ形状の識別に有効であり、比率が 1 に近い場合は円形や正方形に近い形状、1 と比較して離れた値の場合は細長い形状を示す。具体的には、対象の境界ボックス（Bounding Box）の幅と高さを計算し、その比率を求めることで算出され

る。この指標は、セグメント間の形状の方向性や比率の違いを評価する際に有用であり、特に枝や幹のような細長いセグメントと、他のセグメントを区別するのに適している。

### 3.5.3 学習と評価に用いる正解ラベル

ラベルには、訓練用ラベルとテスト用ラベルの2種類を付与した。訓練用ラベルは学習時に使用し、テスト用ラベルは分類結果と比較する際に使用した。どちらのラベルも、目視で判断し、QGIS上で手作業で付与した。まず、作成した2D画像を参考にしてポイントとしてラベルを付与し、ポイントを訓練用ラベルとテスト用ラベルに分割した。さらに、ポイントが含まれるセグメントにポイントのラベルを転記した。この作業には、QGISの「ベクタレイヤの空間結合」機能を使用した。最後に、ラベルが付与されたセグメントを確認し、誤っているセグメントを除去した。

### 3.5.4 分類アルゴリズム

本研究では、分類手法としてSVMおよびRFを使用した。SVM[22]は、線形分離可能な場合に最適な分離超平面を構築するアルゴリズムであり、拡張によって線形分離困難なデータに対しても実現できる。また、カーネル関数を適用することで非線形な分離も実現できる。高次元データに対しても安定した性能を発揮し、特にサンプル数が少ない場合に有効とされている。一方、RF[23]はアンサンブル学習手法の一つで、複数の決定木を用いて分類を行う。それぞれの決定木は異なる特徴に基づいてデータを分類し、最終的にそれらの予測結果を多数決で統合して最も適切な分類を決定する。この方法は、個々の決定木が持つ誤差を補い合うため、データのばらつきやノイズに強く、過剰適合を避けることができる。また、特徴量が多い場合にも効果的に分類を行える。

分類は、以下の実行環境で行った。全ての処理はCPU上で実行された。ハードウェア構成は、*Intel(R)Xeon(R)Gold5220RCPU@2.20GHz* および *125GB* のRAMを搭載しており、OSは *Ubuntu24.04.1LTS* を使用した。SVMおよびRFは、Orfeo Toolbox内の「Vector Classifier」を用いて実行した。

### 3.5.5 分類精度の評価

#### 混同行列 (Confusion Matrix)

分類結果を評価するための指標の一つとして、混同行列[24]を用いた。混同行列とは、モデルが分類した結果と実際の結果（テスト用ラベル）との対応を示す行列であり、分類精度や誤分類のパターンを可視化するための評価指標である。本研究では「幹、枝、葉、地面」の4ク

ラス分類を行った。

行方向はテスト用ラベルを、列方向は分類結果を表している。さらに、行列で同じクラスの交わる箇所にはテスト用ラベルのセグメントが正しいクラス分類されたデータ数を示し、異なるクラスの交わる箇所にはテスト用ラベルのセグメントが誤ったクラスに分類されたデータ数を示す。例えば、行方向のクラスが「幹」で、列方向のクラスも「幹」の箇所は、テスト用ラベルが「幹」であるセグメントが正しく「幹」と分類されたオブジェクトのデータ数を表す。行方向のクラスが「枝」で、列方向のクラスは「幹」の箇所は、テスト用ラベルが「幹」であるセグメントが誤って「枝」と分類されたオブジェクトのデータ数を表す。また、分類結果を評価するための指標の一つとして、F 値 (F-measure) [24] を用いた。加えて、F 値を導くために、適合率 (Precision) および再現率 (Recall) も求めた。これらの値を算出するために、混同行列を活用した。適合率は、あるクラスに分類されたオブジェクトの中で、実際にそのクラスに属していたオブジェクトの割合を示す。再現率は、実際にあるクラスに属していたオブジェクトの中で、正しくそのクラスに分類されたオブジェクトの割合を示す。F 値は、適合率と再現率の調和平均を示す。

### Permutation Feature Importance(PFI)

分類結果を評価するための指標の一つとして、PFI[25] を用いた。PFI は、特定の特徴量の値をランダムに置換し、それを用いて分類を行った結果、分類精度がどの程度低下するかを測定する手法である。この手法により、各特徴量がモデルにとってどれほど重要かを定量的に評価できる。PFI の計算には、scikit-learn の関数を使用した。PFI の結果は、特徴量ごとの相対的な重要度を示し、モデルの解釈を助けるとともに、性能向上に寄与する特徴量を選択する指針となる。本研究では、画素由来の特徴量とオブジェクト由来の特徴量を含む 20 個の特徴量を用いて分類モデルを構築し、それらの特徴量に対して PFI を計算した。

## 3.6 点群への分類結果の付与

本研究の手法では、3D 点群の各点と、2D 画像の各画素が対応づいているため、分類結果を容易に点群に付与できる。そこで、各点の分類結果をスカラー値として付与し、3D モデルを構築した。まずオブジェクトごとに分割されたベクタファイルを、縦横の画像サイズを指定してラスタファイルに変換した。次に、そのラスタファイルを CloudCompare[26] で取り扱える点群形式に変換し、点群に戻した。点群に変換することで、分類結果がより視覚的に判断しやすくなり、分類の傾向を立体的に把握できた。

### 3.7 他の計測データへの学習済みモデルの適用

本研究では、提案手法で得られたモデルの汎用性を確認するため、異なる地点で取得した点群データを使用して評価を行った。本来、提案手法では各地点ごとに教師あり学習を実施し、その地点専用のモデルを新たに作成する必要がある。一方、今回は1地点目で作成したSVMおよびRFの学習済みモデルが、他の計測データでも適用できるかどうかを確認することを目的とし、1地点目のモデルを使用して評価を行った。地点選定にあたって、まず針葉樹林が目視で判別できることを確認した。また、針葉樹以外の樹木も含まれており、ほかの樹木にも適用できるかを検証できることを基準とした。これにより、異なる種類の樹木に対する分類能力も確認できる。学習済みモデルは転用させ、テスト用ラベルのみを新しく付与した。分類結果の画像とテスト用ラベルを用いた混同行列で評価を行った。

## 第 4 章

# 結果と考察

### 4.1 作成された二次元画像

図 4.1 は、作成された 2D 画像を示す。画像では、9 つの特徴量それぞれの値が画素として表示されている。拡大した画像を付録 A に載せている。特徴的な点として、360° の計測結果を 1 枚の画像に表現することで、パノラマ画像に似た画像となっている。また、図の配色は、青に近い色が小さい値を、赤に近い色が大きい値を表している。この計測データにおいて、Z 座標は、地面を中心とした範囲を捉えることができた。反射強度は、幹、枝、葉で異なり、特に TLS から距離の近い点ではその差が顕著であった。TLS からの距離は、1 本の樹木内の葉と枝の細かな違いを強調するとともに、2D 画像では区別が難しい、隣り合った樹木同士の部分の違いを際立たせた。さらに、反射強度と TLS からの距離の標準偏差では、樹木の境界が鮮明に表現され、葉の値のばらつきも捉えることができた。隣接画素間の距離の差の最大値では、水平方向と垂直方向において幹と枝の違いが表現された。

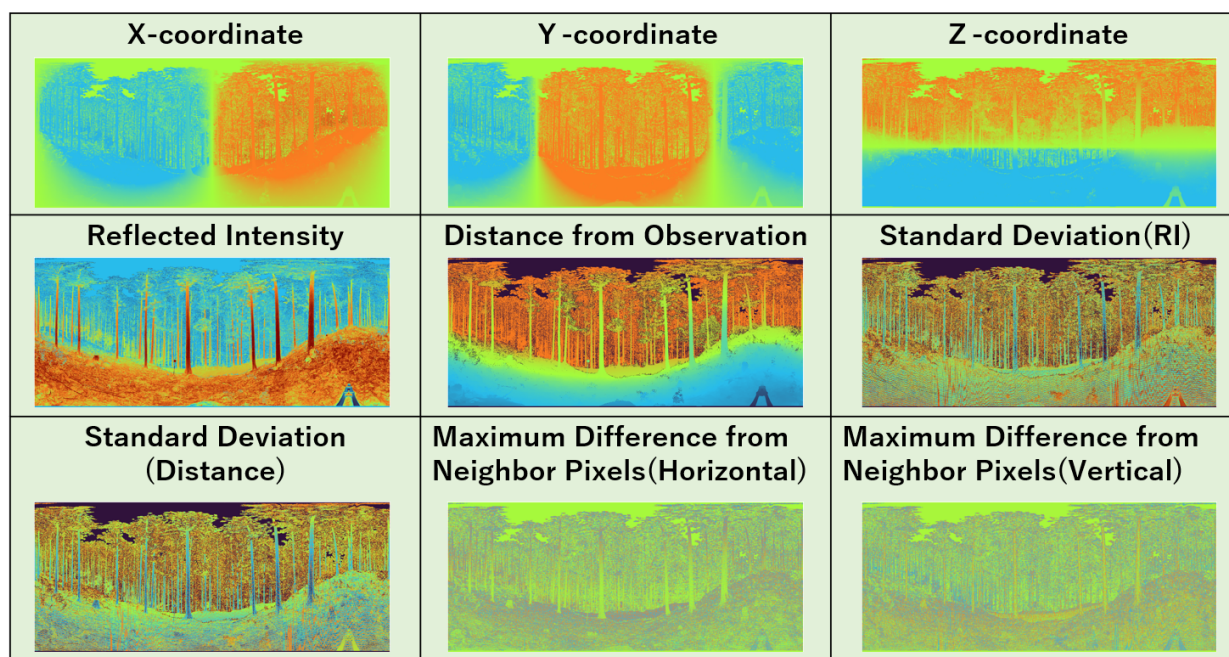


Fig. 4.1: 作成された二次元画像

## 4.2 セグメンテーション

図 4.2 は、セグメンテーションの結果である。セグメント数は、表 4.1 に示した 539,852 個となった。作成されたセグメントからは、幹と枝は比較的細長い形状を示すという特徴が読み取れた。また、葉のセグメントは、枝のセグメントの周囲に分布するという特徴も読み取れた。さらに、パラメータ調整時に曖昧になりやすかった地面と幹のセグメントは、ほぼ別々のセグメントとなった。データの無い部分は、データのある部分に大きな影響を及ぼさない形でセグメントとなった。




Fig. 4.2: セグメンテーションの結果



Table. 4.1: セグメンテーションのパラメータと結果

Number of Segment	539,852	Algorithm	LargeScaleMeanshift
Spatial Radius	140	Range Radius	60
		Minimum Segment Size	30

## 4.3 分類

### 4.3.1 正解ラベル

図 4.3 は、点で訓練用ラベルを付けた結果である。ラベルは、約 11,000 個であり、異なるセグメントとなるように分散させた。また、分類結果で数が非常に多くなると推定される葉に最も多くラベルを付けた。一方で、地面のラベルを付けたセグメントは、落葉、折れた枝、切り株など針葉樹の分類に影響を及ぼすセグメントを含むため、ラベルの付与数を少なくした。表 4.2 は、正解ラベルを付けたセグメントの数を表す。




Fig. 4.3: 訓練用ラベルを付けた結果 (点)

Table. 4.2: 正解ラベルを付けた数 (セグメント)

	stems	branches	leaves	ground
Train Label	1,000	2,659	2,696	653
True Label	480	1,227	1,648	449

### 4.3.2 分類結果

SVM による分類結果を図 4.4 に示す。幹は、TLS から遠い位置においても何本か分類されていた。しかし、幹は、枝や地面との境界線が曖昧であった場合に、枝や地面との誤分類が多



かった。枝は、葉が重なり合って影ができた場合や、隠れて一部分しか映らなかった場合に誤分類が発生した。葉も同様に、枝との誤分類が目立った。地面は、TLS から遠く、傾斜が急であっても、地面と分類された。なお、地面に含まれる根や切り株が幹や枝と誤分類された。反射強度やアスペクト比が幹や枝に近い値を持っていたためと考えられる。




Fig. 4.4: 分類結果 (SVM)

RF による分類結果を図 4.5 に示す。幹は、TLS から遠くに位置する樹木が、枝や葉と誤分類されることが多かった。一方、幹を構成する細かいセグメントについて、SVM では別のオブジェクトと誤分類された数が多かったものの、RF では誤りが少なかった。葉と類似した枝のオブジェクトは、SVM では正しく枝に分類されたが、RF では葉に誤分類された。一方、幹か枝が曖昧な枝のオブジェクトでは、枝と分類される傾向があった。地面は、TLS から距離が遠くなるにつれて、一帯を別のオブジェクトと誤分類する結果が散見された。後述のように、SVM では座標由来の特徴量が高いのに対し、RF では他の特徴量の重要度が高いためと考えられる。




Fig. 4.5: 分類結果 (RF)

表 4.3 は、正解ラベル（訓練用ラベルとテスト用ラベル）と分類結果（SVM と RF）のセグメント数を示した。分類結果では、SVM で幹のセグメントが約 30,000 個多く、RF で葉のセグメントが約 30,000 個多かった。これは、TLS から距離遠い位置にある幹と葉をどう分類したかが影響したものと考えられる。

**Table. 4.3:** 正解ラベルと分類結果のセグメント数の表

	stems	branches	leaves	ground
<b>Train Label</b>	<b>1,000</b>	<b>2,659</b>	<b>2,696</b>	<b>653</b>
<b>True Label</b>	<b>480</b>	<b>1,227</b>	<b>1,648</b>	<b>449</b>
<b>Classified(SVM)</b>	<b>66,862</b>	<b>55,892</b>	<b>203,647</b>	<b>213,451</b>
<b>Classified(RF)</b>	<b>28,538</b>	<b>59,930</b>	<b>232,149</b>	<b>219,235</b>

### 4.3.3 評価指標

#### 混同行列

表 4.4 は、SVM の混同行列を示す。正解ラベルと分類されたラベルの係る混同行列部分のセルの数字は、それぞれのデータ数を表している。また、図の最下段の左から 4 つのセル（青字）はそれぞれの Precision を計算しており、最右列の上から 4 つのセル（赤字）はそれぞれの Recall を計算している。最右下のセルは、本分類器の F-measure を表している。

全てのクラスで Precision は 0.75 以上になった。特に、遠くの位置まで認識できた幹が Precision は最も高くなった。さらに、同様の理由から地面も Precision は高かった。一方、細部の分類が不適切であったことから、枝と葉は Precision が低かった。地面に含まれる切り株や根の分類が、幹と判定されていたことから、地面は分類しきれていなかった。計測データから土の部分を取り除いて樹木点群を使用したい場合は、SVM は有効であると考えられる。また、Precision と Recall で大きな差はなく、F-measure は 0.82 となった。調和平均を表す F-measure は、ラベルと数の多い葉の Precision が低かったことから、大幅に下がったと考えられる。

Table. 4.4: 混同行列 (SVM)

		Classified Label				Recall
		stems	branches	leaves	ground	
True Label	stems	455 (0.946)	16 (0.033)	3 (0.006)	7 (0.015)	0.82
	branches	18 (0.015)	1060 (0.862)	144 (0.117)	8 (0.007)	0.72
	leaves	18 (0.011)	381 (0.231)	1247 (0.755)	6 (0.004)	0.89
	ground	66 (0.147)	8 (0.018)	9 (0.020)	366 (0.815)	0.95
Precision		0.95	0.86	0.75	0.82	F-measure 0.82

表 4.5 は、RF の混同行列を示す。各クラスの Precision では、SVM と比較すると 3 クラスが低かったものの、他のクラスに比べて低かった葉の Precision は高くなっていた。また、クラス単位では、SVM と同じ幹が最も高かった。一方、TLS から遠くに位置する地面一帯が枝や葉と誤分類されたため、地面の Precision は大きく低下した。また、TLS からの距離があまり遠くない樹木単体のデータ（地面を除く）では、RF は葉をより多く正しく分類できており、葉を抽出したい場合は、SVM よりも有効であると考えられる。これは関連研究 2 で示唆されていた結果とも一致する。また、Precision と Recall は地面を除いて大きな差はなく、F-measure は 0.83 となった。調和平均を表す F-measure は、ラベルが少ない地面を多く誤分類したことに加え、ラベルと分類数の多い葉の正解率が高かったことから、SVM よりも 0.01 高くなったと考えられる。

Table. 4.5: 混同行列 (RF)

		Classified Label				Recall
		stems	branches	leaves	ground	
True Label	stems	439 (0.915)	28 (0.058)	5 (0.010)	8 (0.017)	0.93
	branches	9 (0.007)	978 (0.797)	239 (0.195)	1 (0.001)	0.75
	leaves	4 (0.002)	217 (0.132)	1427 (0.866)	0 (0.000)	0.83
	ground	18 (0.040)	77 (0.171)	58 (0.129)	296 (0.659)	0.97
Precision		0.91	0.80	0.87	0.66	0.83

### Permutation Feature Importance

図 4.6 は, SVM の Permutation Feature Importance である. グラフの縦軸は各特徴量を示し, 横軸はその特徴量の重要度を表す. 特徴量は, 画素由来 (緑枠内) とオブジェクト由来 (赤枠内) の 2 つの領域に分けた. 画素由来の特徴量では, 上段は平均値, 下段は標準偏差を示す. また, オブジェクト由来の特徴量は, オブジェクトの形状から計算されるため, それぞれ一段で示す.

Z 座標の平均値が最も高い値を示した特徴量であった. 本計測データでの地面は, Z 座標がほぼ同じであったため, 分類結果で地面の Precision が高くなり, PFI も最も高い値を示したと考えられる. また, 反射強度の平均値も高い値を示した. 幹枝と葉の分類で反射強度の違いが表れたためと考えられる. Y 座標の平均値も高い値を示した. TLS から距離が離れた Z 座標が変化している傾いた地面であっても分類されていたためと考えられる. さらに SVM では, 全ての特徴量が約 0.005 以上は使用されていた. オブジェクト由来の特徴量では, アスペクト比が高い値を示した. アスペクト比は, 1 からより離れた値を示した枝, 幹などの細長い長方形を持つオブジェクトが, 正確に分類されたためである. SVM は, 座標に基づく特徴量の PFI が高いため, 異なる地点で同じ学習モデルを用いると良好な結果が得られず, 汎化性能が低い可能性がある. これは, SVM の分類アルゴリズムが座標をより多く使用しているためであると考えられる. また, 地点を変更するたびにモデルを再構成する必要があるため, 全特徴量が寄与していたことから, 似た場所であっても PFI の結果は大きく変化すると予想される.




Fig. 4.6: Permutation Feature Importance(SVM)

図 4.7 は、RF の PFI の結果である。分析の結果、反射強度の平均値が最も高い値を示し、0.40 程度であった。SVM と比較して、RF は分類アルゴリズムにおいて各特徴量の重要度に差がなく、反射強度の影響を受けやすい葉の Precision と重要度が高くなったと考えられる。また、Z 座標も高い値を示していたが、SVM ほど高い値を示さなかったため、TLS から距離の遠いオブジェクトが低下したと考えられる。次に高い値を示したのは、TLS からの距離の標準偏差をセグメント化した時の標準偏差であった。樹木のエッジを鮮明にすることで、枝と幹の細かな部分のオブジェクトまで、より多く分類できたと考えられる。また、オブジェクト由来の特徴量では、SVM と同様にアスペクト比が高い値を示した。一方、SVM とは異なり、重要度が 0 である特徴量がいくつか表れた。また、RF は座標にあまり依存していないため、他の地点でもモデルを利用できると考えられる。特に、反射強度の平均値と TLS からの距離の標準偏差が分類に大きな影響を与えていることから、幹枝と葉の分類においては、RF モデルの汎化性能が発揮されると予想できる。針葉樹でない別の樹木データにおいても、一定の分類結果を得られる可能性があると考えられる。






Fig. 4.7: Permutation Feature Importance(RF)

#### 4.4 点群への分類結果の付与

図 4.8 は、SVM と RF で得られた分類結果を点群へ付与した結果の一部である。CloudCompare を使用して、同じ地点を比較し表示した。上段は幹、枝、葉と分かる部分を比較し、下段は幹、葉、地面と分かる部分を比較した。3D 点群で表示したことで、正解が枝か葉のどちらか 2D 画像では判別が困難だった部分など、実際の真偽を視覚的に確認できた。上段に関しては、2D で得られた結果から見ると、SVM の方が RF よりも正解率が高かったため、SVM の方が適していると考えていたが、実際は一概には言えないことがわかった。例えば、樹木の葉の裏側にある枝を部分的に測定できた箇所では、RF の方が枝と正しく分類できた部分が散見された。さらに、枝と葉の接合部分では、SVM の方が葉や地面への誤分類を多く含んでいた。一方、下段では、2D で得られた結果がより鮮明になった。地面は、SVM が TLS から離れた距離にある地面まで分類できていたものの、RF は分類ができていなかった。また、樹木と地面の接合部分や TLS から距離の離れた樹木の葉の分類は、SVM の方が正しく分類できていた。

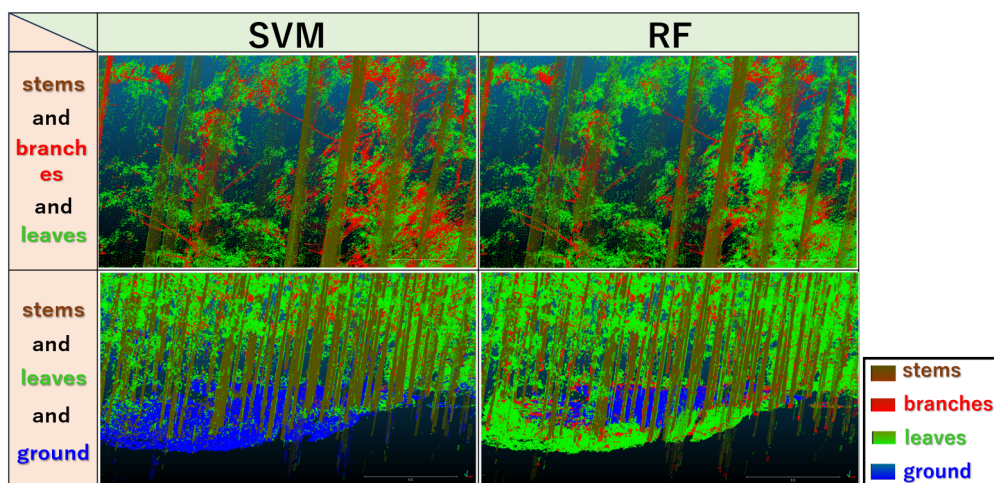


Fig. 4.8: 分類結果を点群へ付与した結果の一部

## 4.5 他の計測データへの学習済みモデルの適用

図 4.9 は、学習済み SVM モデルを他の計測データへ適をした結果である。ほぼ全てのデータが枝として分類された。アスペクト比が 1 から離れたオブジェクトのみ、幹としていくつか分類されたものの、アスペクト比が 1 から離れたオブジェクトは、幹に加えて枝も含まれていたため、誤分類も多く生じていた。




Fig. 4.9: 他の計測データへの学習済み SVM モデルの適用をした分類結果

図 4.10 は、他の計測データへの学習済み RF モデルの適用をした結果である。SVM とはクラスが異なるものの、ほぼ全てのデータが葉として分類された。なお、SVM とは異なり、枝を正しく分類できていたオブジェクトが散見された。




Fig. 4.10: 他の計測データへの学習済み RF モデルの適用をした分類結果

図 4.6 と図 4.7 は、他の計測データへの学習済みモデルの適用をした混同行列を示す。分類がほぼできていないことがわかる。RF は枝だけ 0.52 の Precision を示しており、SVM よりは分類の兆しが見えた。なお、他の計測データへの学習済みモデルの適用は、SVM も RF も現段階では実用性はない。

Table. 4.6: SVM モデルの混同行列

		Classified Label			
		stems	branches	leaves	ground
True Label	stems	<b>131</b> (0.177)	<b>601</b> (0.812)	<b>8</b> (0.011)	<b>0</b> (0.000)
	branches	<b>61</b> (0.113)	<b>481</b> (0.887)	<b>0</b> (0.000)	<b>0</b> (0.000)
	leaves	<b>74</b> (0.085)	<b>801</b> (0.915)	<b>0</b> (0.000)	<b>0</b> (0.000)
	ground	<b>13</b> (0.064)	<b>191</b> (0.936)	<b>0</b> (0.000)	<b>0</b> (0.000)

Table. 4.7: RF モデルの混同行列

		Classified Label			
		stems	branches	leaves	ground
True Label	stems	<b>46</b> (0.062)	<b>24</b> (0.032)	<b>670</b> (0.905)	<b>0</b> (0.000)
	branches	<b>57</b> (0.105)	<b>280</b> (0.517)	<b>205</b> (0.378)	<b>0</b> (0.000)
	leaves	<b>9</b> (0.010)	<b>72</b> (0.082)	<b>794</b> (0.907)	<b>0</b> (0.000)
	ground	<b>7</b> (0.034)	<b>14</b> (0.069)	<b>183</b> (0.897)	<b>0</b> (0.000)



## 第 5 章

# まとめ

### 5.1 まとめ

本研究では、点群データを平面上に投影された 2D 画像として扱い、オブジェクト指向分類を行うという提案手法の実用可能性について検討した。分類結果では、SVM と RF の両方で、F-measure が 0.8 を超え、どちらも実用的な可能性を示した。混同行列の結果では、SVM の Precision が幹、枝、地面で RF よりも高かった。RF は最もオブジェクトの数が多い葉が高かった。PFI の結果では、本計測データにおいて、SVM は座標に基づく特徴量が高い重要度を示した。一方、RF は反射強度が最も高い重要度を示した。また、オブジェクト由来の特徴量では、どちらの分類においてもアスペクト比の重要度は高かった。3D 点群へ分類結果を付与した結果、2D 画像では判別しづらかった分類の傾向も確認できた。また、他の計測データへ学習済みモデルを適用した結果、どちらのモデルも汎化性能は低いため、現段階では計測データ単位でのモデルの学習が必要であった。

### 5.2 展望

本研究手法がより実用的であるかどうかは、既存の手法と比較してどれだけ分類精度が向上しているかを様々な観点から確認する必要がある。また、他の地点でモデルを学習した結果を得ることで、信頼性をさらに高めることができる。さらに、今回の PFI の結果を基に、特徴量を絞る、増やすことにより、精度をさらに向上させることができると考えられる。本研究は、林業での作業効率を向上させることに加えて、林業以外の分野においても、TLS 点群から直接樹木の部位まで分類する機能を TLS 点群処理ソフトの一機能としての実装が検討できる。

# 謝辞

本研究は、三重大学 大学院 工学研究科 情報工学専攻 松岡真如先生のご指導のもとで行われた。また、三重大学・生物資源学研究科・附帯施設演習林との共同研究として実施された。

## 参考文献

- [1] Forestry Agency of Japan. "一目でわかる林業労働". 2022. <https://www.rinya.maff.go.jp/j/routai/doukou/attach/pdf/index-5.pdf>.
- [2] Forestry Agency of Japan. "地上型 3D レーザスキャナを活用した収穫調査実証等委託事業報告書". 2021. [https://www.rinya.maff.go.jp/j/gyoumu/gijutu/attach/pdf/syuukaku\\_kourituka-58.pdf](https://www.rinya.maff.go.jp/j/gyoumu/gijutu/attach/pdf/syuukaku_kourituka-58.pdf).
- [3] Forestry Agency of Japan. "地上型 3D レーザ機器を用いた森林調査の手法現地検討会". 2022. <https://www.rinya.maff.go.jp/kanto/hukusima/event/attach/pdf/230324-4.pdf>.
- [4] Forestry Agency of Japan. "スギ・ヒノキ林に関するデータ". 2023. [https://www.rinya.maff.go.jp/j/sin\\_riyou/kafun/data.html](https://www.rinya.maff.go.jp/j/sin_riyou/kafun/data.html) (アクセス日: 2024 年 1 月 20 日).
- [5] 飯塚浩太郎, 早川裕式, 小倉拓郎, 中田康隆, 小杉緑子, 米原太一郎. "リモートセンシングによる森林資源量推定に関する研究", 2018. <https://www.csis.u-tokyo.ac.jp/csisisdays2018/csisisdays2018-ra-pdf/A15.pdf> (アクセス日: 2024 年 1 月 20 日).
- [6] Guangpeng Fan, Zhenyu Xu, Jinhua Wang, Liangliang Nan, Huijie Xiao, Zhiming Xin, and Feixiang Chen. "Plot-level reconstruction of 3D tree models for aboveground biomass estimation". *Ecological Indicators*, Vol. 142, p. 109211, 2022.
- [7] 熊崎理仁. "TLS 点群データを用いた 3D 樹木モデルの構築と応用". *ランドスケープ研究*, Vol. 84, No. 5, pp. 527–530, 2021.
- [8] S Arrizza, S Marras, R Ferrara, and G Pellizzaro. "Terrestrial Laser Scanning (TLS) for tree structure studies: A review of methods for wood-leaf classifications from 3D point clouds". *Remote Sensing Applications: Society and Environment*, p. 101364, 2024.
- [9] Forestry Agency of Japan. "近畿中国森林管理局のスマート林業の取組". 2020. <https://www.rinya.maff.go.jp/kinki/sidou/gijyutukaihatsu/attach/pdf/201117-7.pdf> (アクセス日: 2024 年 1 月 20 日).
- [10] Yanchao Liu, Jianwei Guo, Bedrich Benes, Oliver Deussen, Xiaopeng Zhang, and


- Hui Huang. "TreePartNet : neural decomposition of point clouds for 3D tree reconstruction". *ACM Transactions on Graphics*, Vol. 40, No. 6, 2021. Article Number: 232.
- [11] Di Wang, Markus Hollaus, and Norbert Pfeifer. "Feasibility of machine learning methods for separating wood and leaf points from terrestrial laser scanning data". *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 4, pp. 157–164, 2017.
- [12] 江藤信輔・増田宏. Tls 点群を用いた樹木形質の抽出と評価. "精密工学会学術講演会講演論文集 2020 年度精密工学会春季大会", pp. 228–229. 公益社団法人 精密工学会, 2020.
- [13] 加藤泰朗. "【入門】地上型レーザースキャナの仕組みと測定の手順 ～メリット・デメリットも紹介～", 2023. <https://digital-construction.jp/column/777> (アクセス日: 2024 年 1 月 20 日) .
- [14] Inc. FARO Technologies. "SCENE", 2023. <https://www.faro.com/products/software/scene>(アクセス日: 2023 年).
- [15] 信州大学審査学位論文. "特徴点を用いた 3 次元点群処理に関する研究", 2021. [https://soar-ir.repo.nii.ac.jp/record/2000397/files/15ST202J\\_ronbun.pdf](https://soar-ir.repo.nii.ac.jp/record/2000397/files/15ST202J_ronbun.pdf) (アクセス日: 2024 年 1 月 20 日).
- [16] QGIS Development Team. "QGIS". <https://qgis.org>(アクセス日: 2023 年).
- [17] Mapbox. "rasterio". <https://rasterio.readthedocs.io>.
- [18] "Orfeo Toolbox", 2024. from<https://www.orfeo-toolbox.org/>(アクセス日: 2023 年).
- [19] Zhenyang Hui, Shuanggen Jin, Yuanping Xia, Leyang Wang, Yao Yevenyo Ziggah, and Penggen Cheng. "Wood and leaf separation from terrestrial LiDAR point clouds based on mode points evolution". *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 178, pp. 219–239, 2021.
- [20] 株式会社オープン GIS. "ポリゴンの形状指数", 2006. [https://www.opengis.co.jp/html/kako\\_mail/mail\\_mag\\_272.html](https://www.opengis.co.jp/html/kako_mail/mail_mag_272.html) (アクセス日: 2025 年 1 月 22 日) .
- [21] Zenken 株式会社. " ニーズに合った製品が見つかる！粒子径分布測定装置 Navi", 2024. <https://www.tsubu-navi.net/knowledge/shape-evaluation.html> (アクセス日: 2025 年 1 月 22 日) .
- [22] 高野祐一. "サポートベクトルマシンとカーネル法", 2020. [https://orsj.org/wp-content/corsj/or65-6/or65\\_6\\_304.pdf](https://orsj.org/wp-content/corsj/or65-6/or65_6_304.pdf) (アクセス日: 2025 年 1 月 22 日) .
- [23] 渡部 斉. "ランダムフォレスト", 2012. [https://www.habe-lab.org/habe/RFtutorial/CVIM\\_RFtutorial.pdf](https://www.habe-lab.org/habe/RFtutorial/CVIM_RFtutorial.pdf) (アクセス日: 2025 年 1 月 22 日) .
- [24] 岡崎直観. "機械学習帳", 2024. <https://chokkan.github.io/mlnote/>

- classification/02multi.html (アクセス日: 2025 年 1 月 22 日) .
- [25] "Permutation Feature Importance — scikit-learn 1.5.0 documentation", 2024. [https://scikit-learn.org/1.5/modules/permutation\\_importance.html](https://scikit-learn.org/1.5/modules/permutation_importance.html) (アクセス日: 2025 年 1 月 22 日) .
- [26] CloudCompare Development Team. "CloudCompare". <https://www.cloudcompare.org> (アクセス日: 2025 年 1 月 22 日) .
- [27] LibTIFF Contributors. "LibTIFF". <http://www.simplesystems.org/libtiff/>.


## 付録 A

# 高画質画像での補足

以下，特徴量別に表示した 2D 画像である．




**Fig. A.1:** 作成された二次元画像 (X 座標)




**Fig. A.2:** 作成された二次元画像 (Y 座標)




**Fig. A.3:** 作成された二次元画像 (Z 座標)




**Fig. A.4:** 作成された二次元画像 (反射強度)




**Fig. A.5:** 作成された二次元画像 (TLS からの距離)



**Fig. A.6:** 作成された二次元画像 ( $3 \times 3$  画素内の反射強度の標準偏差)




**Fig. A.7:** 作成された二次元画像 ( $3 \times 3$  画素内の TLS からの距離の標準偏差)



**Fig. A.8:** 作成された二次元画像 (水平方向に隣接画素との差の絶対値の最大)





**Fig. A.9:** 作成された二次元画像 (鉛直方向に隣接画素との差の絶対値の最大)

## 付録 B

# 画像作成の詳細手法

計算に用いた直交座標は, SCENE のスキャンパラメータから, 得られたズレの情報 ( $Z$  座標の標高の高さなど) も調整した座標である. スキャンパラメータから得られたズレの数値を, 取得した  $x, y, z$  座標と差分をとることで調整した. 調整の結果,  $\theta$  と  $\phi$  が適切な範囲内に分布した値となった. また, 一度 raw ファイルとして出力をした後, raw2tif コマンドを使って, 画像の縦と横のサイズをスキャンパラメータのパノラマ画像と同様のサイズとしたことで, 取得した点の数と画素の数がおおよそ対応するよう設定して作成した. 画像作成は, C++ 言語のライブラリ LibTIFF[27] を使用し, 効率的なデータ処理と画像生成を実現した.