

# 移動計測データに基づく柱状物体の分類 に適した幾何特徴量

深野 健太<sup>1</sup>・増田 宏<sup>2</sup>

<sup>1</sup>非会員 電気通信大学学部生 知能機械工学科 (〒182-8585 東京都調布市調布ヶ丘1-5-1)  
E-mail:kenta.fukano@uec.ac.jp

<sup>2</sup>非会員 電気通信大学教授 知能機械工学専攻 (〒182-8585 東京都調布市調布ヶ丘1-5-1)  
E-mail:h.masuda@uec.ac.jp

移動計測によって得られた道路周辺の点群データは、電柱や標識のようなインフラのメンテナンスなどへの利用が期待されている。この点群データを3次元情報として利用するには、点群から地物成分を抽出し、地物ごとに分類する必要がある。この分類には、機械学習法を用いた自動分類が有効と考えられる。本研究では、機械学習による分類の指標として用いられる特徴量に着目する。道路周辺の地物には柱状物体が多く存在するが、柱状物体の分類に有効な特徴量については、定量的な評価は未だ行われていない。そこで特徴量の分類器生成への寄与度を評価に用い、この寄与度の高さから有効な特徴量を判定する。評価実験により、我々の手法によって、柱状物体の分類に有効な特徴量が検出できることを示す。

**Key Words :** poin- cloud, MMS, PLO, machine learning

## 1. 緒言

道路周辺の3次元情報はインフラのメンテナンスや自動車の安全性向上への利用が期待できる。この3次元情報の取得には移動計測装置(MMS)により得られる点群データが有効である。移動計測装置とは自動車にレーザーキャナ、GPS、IMU、カメラを搭載し、走行させることで道路周辺の点群データを計測する装置である。

移動計測により得られる点群データは膨大な量の地物点群を含み、3次元情報として利用するには、地物成分のみを抽出し、種類ごとに分類する必要がある。分類により地物にタグ付けをすることで、効率的な地物の管理や、詳細な都市のマッピングが可能になる<sup>1)</sup>。しかし、分類を手動で行うのは時間や費用的に現実的ではない。

この作業を自動的に行うには、機械学習が有効と考えられる。機械学習には分類の指標である特徴量が必要となる。特徴量とは物体の幾何学的特徴を数値化したものであり、正確な分類には、クラスの分類に適した特徴量の集合を選択することが重要である。そこで本研究では、機械学習における分類の指標となる特徴量に注目する。

道路周辺の地物は円柱部分を持つものが多いため、移動計測によって得られた点群から、柱状物体を効率的に抽出するための研究が多く報告されている<sup>1), 2), 3)</sup>。そこ

で、本研究では、そのように抽出された柱状物体を、さらに電柱、街灯、信号、標識、木の5つに分類することとし、これらの地物分類に有効な特徴量を考える。

本研究では、柱状物体の点群から計算可能な特徴量について考察し、どの特徴量が柱状物体の分類に有効かを調査することを目的とする。

そのための手段として、本研究では、地物ごとに分割された点群と、その点群をさらに曲面単位に分割した点群のそれぞれに関して特徴量を計算する手法と、機械学習法を用いて有効な特徴量を同定する手法を提案する。

## 2. 関連研究

MMSで取得された点群の分類については、いくつかの研究が存在するが、どの特徴量を用いれば高い認識率が得られるかについては定量的に検証されてこなかった。

Golovinsky<sup>1)</sup>らは車、街灯、標識などを分類している。特徴量には、地物重心の高さ、主成分分析の偏差に加えて、地物から道路までの距離などの文脈的特徴量も採用している。しかし、平均認識率は65%と比較的低い。

Ishikawa<sup>2)</sup>らは壁、柱状物体、ガードレールを分類した。特徴量には主成分分析の固有値、点群サイズ、点群のス

ライスなどを用いている。柱状物体を高い認識率で抽出しているが、それらをさらに電柱や標識などに分類するための特徴量は示していない。

Yokoyama<sup>3)</sup>らは機械学習法を用いずに、柱状物体を電柱、街灯、標識に分類をした。特徴量には円柱の高さ、付属物の個数や近傍の地物との位置関係などが用いられている。しかし、特徴量の選択には系統的な手法が用いられておらず、新たな地物の分類や特徴量の導入は容易ではない。

Zhu<sup>4)</sup>らはSVMとCARTを用いて建物、車、自転車、木などを分類した。特徴量には緯度と経度を指標としたヒストグラム上の数値や点群の最高点などを採用している。高い認識率で分類を行っているが、分類対象である物体の形状の違いが大きく、柱状物体は分類対象として多く扱っていない。

Cabo<sup>5)</sup>らは点群をボクセルで包括し、形状を簡略化したうえで分析を行うことで柱状物体を抽出している。抽出対象には信号、標識、木、街灯、公衆電話、電柱を選択している。抽出率は非常に高いが、分類に関しては前述した柱状物体かそれ以外の柱状物体の2種類のクラスでしか認識を行っていない。また抽出している柱状物体もほかの研究と比べて少ない。

Masuda<sup>6)</sup>らは、柱状物体の認識率を向上させるために、点群密度が高い領域を抽出した後、RANSAC法を用いて円柱の検出を行う手法を示した。本手法では、円柱の検出にこの方法を用いている。ただし、この研究では、柱状物体の分類法は示していない。

地物の分類において高い認識率を達成するためには有効な特徴量を選定することが重要であるが、従来手法ではそのための系統的な手法は提案されていなかった。本研究では、地物の分類に有効な特徴量を機械的に同定するための手法について考える。

### 3. 手法の概要

#### (1) 処理の流れ

本手法のフローチャートを図-1に示す。まず、MMSによって計測された点群データから路面の除去を行う。その結果、路面上の地物が得られる(図-1(a))。次に、近傍の点群が同じグループになるようにセグメンテーションを行い、個々の地物を分離する(図-1(b))。また、分離した地物点群に対して円柱抽出を行い、円柱が検出できる地物を柱状物体として選別する(図-1(c))。さらに、地物点群の特徴量を計算するために、地物点群から曲面要素を抽出して点群のセグメンテーションを行い(図-1(d))、分類の指標となる幾何特徴量を計算する(図-1(e))。計算した特徴量は、特徴量ベクトルとして、

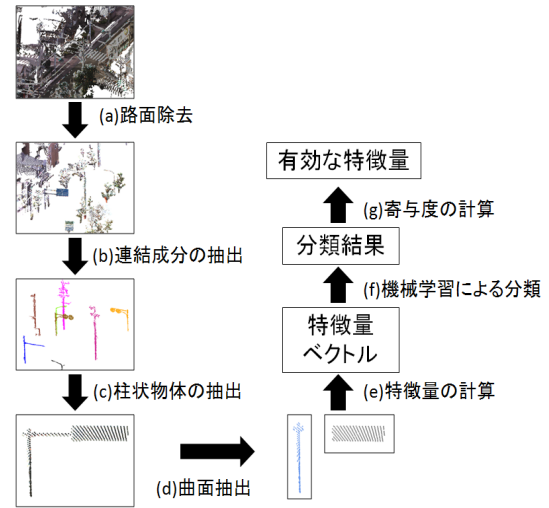


図-1 処理の流れ

機械学習の入力とする(図-1(f))。最後に、機械学習による分類を行い、分類するための寄与度の高い特徴量を有効な特徴量として出力する(図-1(g))。

#### (2) 機械学習

機械学習ではサンプルデータから規則性やルールなどを抽出し、アルゴリズムを生成する。今回のような分類に用いる機械学習は、大きく分けて学習と予測の二つのステップに分かれている。学習の際には説明変数と目的関数を含んだ学習データ、予測には説明変数のみを含んだ入力データが必要になる。点群から計算される特徴量はこの説明変数に当たる。

多数の説明変数から、分類に有効な説明変数を算出する機械学習法の1つにRandom Forest法<sup>7)</sup>がある。この手法では、学習データからランダムに説明変数をサンプリングして多数の決定木を生成する。複数の決定木を用いるという特徴のため、Random Forest法では多数の説明変数があっても有効に動作し、また説明変数の寄与度も計算できる。そのため、本研究の目的である有効な特徴量の同定に適した手法であるといえる。さらに、Random Forest法は、ノイズや外れ値に対して強いという特徴を持つ。MMSによる点群データはノイズや点群の欠落を多く含んでいるため、この点からも、本手法はMMSによって取得された点群の分類に適しているといえる。

#### (3) 点群データの概要

本研究ではSICKのLMS 291で計測された点群データを用いている。本研究では、1回の走査で1度置きに180個の点を取得し、毎秒37.5回の走査を行うモードで計測した。計測方式はTime of flight方式であり、計測データには点の間引きなどは施さず、そのままのデータを用いている。また、MMSの仕様では、計測の相対誤差は7m地点で10mmとなっている。

## 4. 地物分類のための前処理

### (1) 路面点群の除去

まず、計測した点群データから路面の点群を検出し除去する。路面の検出では、我々が提案した手法<sup>8)</sup>を用いている。

路面は、図-2に示すように、水はけを良くするために、中心から外側に行くに従って高さが低くなっている。そこで、道路中央を出発点として周辺に向かって点群を辿っていき、Z座標が小さくスキャンラインと水平面がなす角度 $\theta$ が小さい点を路面上の点として検出する。段差が検出されたら、それを路面の境界とする。路面上の点と判定された点は、点群から除去する。

### (2) 連結な点群の集合への分割

路面部分を除去した後に、点群を地物ごとに分割する。そのために、点群を連結な点集合に分割する。

連結成分を抽出するために、すべての点に関して、他の点との距離が閾値より小さい点を最大 $k$ 個エッジで接続した $k$ -近傍グラフを作成する。本研究ではこの閾値に、点群データの点間隔を当てはめた。点群の間隔距離は計測結果では30cmであったが、照射角度や計測誤差を考慮し、本研究では35cmを閾値とした。近傍点の探索には $kd$ -treeを用いている。その後、 $k$ -近傍グラフを探索し、連結成分に分離する。ただし連結成分の中にはノイズも多く存在する。ここでは、点数が30個に満たない連結成分はノイズとして除去した。なお、これらの閾値は、本研究で用いた計測データから実験的に求めている。ただし、これらは使用するレーザスキャナや車両の速度に依存するため、計測条件が異なるデータを用いる際は閾値の調整を行う必要がある。

### (3) 柱状物体の検出

連結成分として検出された点群の集合から、柱状物体を検出するために、円柱の検出を行う。

円柱上の点群の検出には、我々の提案したRANSAC法による検出法<sup>9)</sup>を用いた。この方法では、柱状物体をZ軸方向に投影すると点群が高密度になることを利用している。すべての点をXY平面に投影した後、点群密度の低い部分を除去し、残された高密度の部分から円弧

検出を行うことで、円柱部分を検出する。円弧検出では高密度部分の点を任意に3点選択し、その点を通る円を作成する。その後、円から5cmの範囲内に存在する点の数を数え上げていく。この動作を繰り返していき、点数が最大になる円を円柱とするが、ノイズ除去の時と同様に範囲内の点数が30個未満の場合は円を棄却する。この手法は点群密度が高い部分から円柱抽出を行うことで、円柱を安定的に検出することを可能にしている。なお、本論文で提案する手法は、特定の円柱検出法に依存していないので、他の手法で円柱を検出しても構わない。

本研究では、円柱が検出された連結点群を柱状物体とみなし、そのような点群のみを考えることとする。なお、点群から複数の円柱が含まれる場合には、一つの連結点群が複数の柱状物体を含んでいると考えられるため、今回の研究においては、そのような点群は除外する。

### (4) 円柱と平面の検出

柱状物体として認識された点群から、円柱と平面を抽出する。

円柱については、柱状物体を検出する際に既に検出されている。ここでは、円柱を構成する点集合を考慮するので、検出された円柱から距離 $d$ の範囲内に存在する点を円柱上点群として記録しておく。

次に、円柱上に乗っていないと判定された点群から平面検出を行う。平面上の点群の抽出にもRANSAC法を用いる。ランダムに3個の点を選択して平面上の点群の検出を行うが、ここでは $k$ -近傍グラフの連結性を調べ、平面上の点の集合から最大連結成分を求めている。この操作を繰り返して、最大連結成分が最も大きくなる平面を算出する。最終的に平面から $d$ の範囲内に存在する点を平面上点群として保存する。ただしこの処理だけでは平面以外の部分も誤って算出される可能性があるため、本研究では平面上の点数が $N$ 未満の場合には、検出された平面を棄却した。

なお、本研究では、実データによる実験から、 $d=5\text{cm}$ 、 $N=100$ としたときに良好な結果が得られたので、閾値としてこれらの値を用いた。ただし、計測条件が異なるデータの場合には、これらの値を調整する必要がある。

## 5. 地物分類のための特徴量

### (1) Random Forestによる分類器の生成

本研究では、機械学習としてRandom Forestを用いている。Random Forestの特徴は、特徴量を選択的に用いることで、多数の決定木を作成することにあるが、ここでは、 $m$ 個の特徴量が選ばれたときに、どのように決定木を作成するかについて説明する。




図-2 路面検出の概要

ここで、特徴量ベクトル  $v_i$  を特徴量の集合  $\{s_k^i\}$  とし、また集合  $V$  を特徴量ベクトルの集合として以下のように定義する。

$$v_i = \{s_1^i, s_2^i, \dots, s_m^i; c\} \quad (1)$$

$$V = \{v_i\} \quad (i = 1, 2, \dots, n) \quad (2)$$

ここで  $c$  はラベルであり、あらかじめ学習データとして地物の種類を人が判別して記述しておくものとする。

機械学習では、特徴量ベクトルの集合  $V$  が与えられると、図-3のような決定木を自動的に生成する。決定木の各ノードでは、データを二分するための基準が設定されている。たとえば「地物の高さ  $Z$ 」に関して、 $Z > Z_i$  のような不等式がその基準となる。機械学習では、この式の閾値  $Z_i$  は学習データから自動的に計算される。もし、特徴量  $Z$  が識別に最も有効と判定されると、決定木の最上位のノードは「地物の高さ  $Z$ 」となり、 $Z > Z_i$  であれば左の子ノードへ、そうでなければ右の子ノードへの移動することで、データが二分される。

本研究では、データを識別に最適な特徴量とその閾値を求めるために、情報利得  $I$  を用いている。  $I$  は式(3)のように定義される。

$$I(V) = G(V) - \frac{|V_L|}{|V|} G(V_L) - \frac{|V_R|}{|V|} G(V_R) \quad (3)$$

$V$  は入力された学習データで地物データの集合である。 $V_L$  と  $V_R$  は、ある条件式によって  $V$  を 2 分割したもので、決定木の左右に相当する。また、 $|V|$  は集合の要素数を示す。 $G(V)$  は集合  $V$  のジニ不純度であり、集合  $V$  から任意の 2 個をランダムに選択したとき、それらが異なるクラスの地物となる確率である。 $G(V)$  は、式(4)のように定義される。

$$G(V) = 1 - \sum_{c \in \Omega} P_V(c)^2 \quad (4)$$

ここで、 $\Omega$  は地物のクラスの集合であり、 $P_V(c)$  は集合  $V$  の中で特定の地物クラス  $c$  に属する要素の比率である。 $P_V(c)$  は、0 以上 1 以下の値を取る。




図-3 決定木の概要

式(3)の情報利得  $I$  は、データを二分することで、不純度がどれだけ減少するかの指標である。図-3のような決定木を作成するためには、この情報利得が最も大きくなる分割を算出する。そのために、個々の特徴量に関して学習データをソートしてデータの分割点を算出し、情報利得が最も大きくなる特徴量と閾値を探索する。二分されたデータ集合のそれぞれに関して、同じ操作を繰り返していけば、最終的に決定木が生成される。

なお、Random Forest では、全体の特徴量からランダムに部分集合を選び出してから決定木を作成するので、図-3のような決定木が多数作成される。データの識別は、多数の決定木からの出力による多数決によって行われる。

## (2) 地物点群のセグメンテーション

機械学習を用いれば、適切な特徴量の集合を選択して、それらの学習データを与えれば、地物を分類するための決定木は自動的に生成される。しかし、本研究で対象とする柱状物体は概形が似ているため、従来研究で用いられた特徴量では、十分な識別能力が得られていなかった。

そこで、本研究では、多様な特徴量を数え上げるために、地物を構成する点群を複数に分割して構造化する。

図-4に地物点群のセグメンテーションの概要を示す。本研究では、構造化された点集合のそれぞれに関して幾何特徴量を算出し、地物の分類に有効な特徴量を同定することを考える。

まず全体の点群データ  $P$  と地物成分の点群  $P_f$  を以下に示す式(5)(6)で定義する。

$$P = \{p_i\} \quad (i \in \Lambda) \quad (5)$$

$$P_f = \{p_j\} \quad (j \in \Lambda_f, \Lambda_f \subset \Lambda) \quad (6)$$

ここで、 $P_i$  は 1 個の点を示しており、 $\Lambda$  は点群全体の添字集合、 $\Lambda_f$  は一つの地物点群の添字集合である。

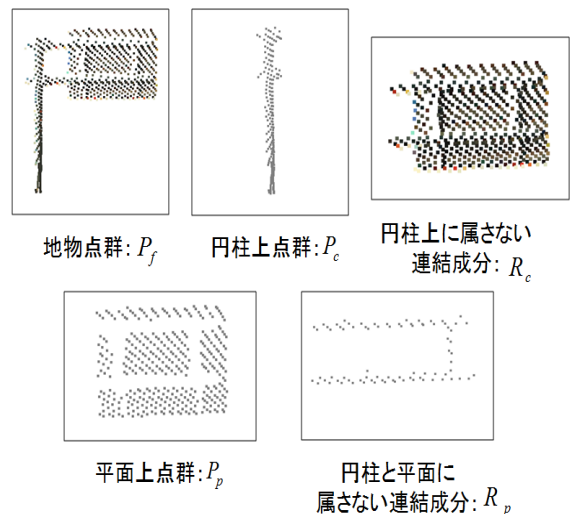


図-4 抽出する点群

次に、曲面要素として、円柱上の点群と平面上の点群を考える。本研究では、まず円柱部分を抽出した後、残った点群から平面を抽出する。円柱と平面は、最大連結成分のみを考える。このとき、円柱上の点群  $P_c$  と平面上の点群  $P_p$  を以下に示す式(7)(8)で定義する。

$$P_c = \{p_k\} \quad (k \in \Lambda_c, \Lambda_c \subset \Lambda_f) \quad (7)$$

$$P_p = \{p_l\} \quad (l \in \Lambda_p, \Lambda_p \subset \Lambda_f - \Lambda_c) \quad (8)$$

ここで、 $\Lambda_c$  は円柱上の点群の添字集合、 $\Lambda_p$  は平面上の点群の添字集合である。また、これらの点集合は、 $P_c \cap P_p = \phi$  を満たしている。

さらに、円柱  $P_c$  を抽出した後に、点集合  $P_f - P_c$  についても考える。この点集合は複数の連結成分を持つことがあるが、最大連結成分  $R_c$  のみを考える。このとき、最大連結成分  $R_c$  を以下の式(9)で表す。

$$R_c = \{p_s\} \quad (s \in \Lambda_{rc}, \Lambda_{rc} \subset \Lambda_f - \Lambda_c) \quad (9)$$

最後に、地物点群から円柱上の点と平面上の点を除去した点集合  $P_f - P_c - P_p$  についても考える。この点集合についても連結成分の検出を行い、最大連結成分  $R_p$  を以下のように定義する。

$$R_p = \{p_t\} \quad (t \in \Lambda_{rp}, \Lambda_{rp} \subset \Lambda_f - \Lambda_c - \Lambda_p) \quad (10)$$

このように定義される  $R_p$  は円柱と平面のどちらにも属さない連結な点集合となっている。

以上により、図-4に示す5個の点集合  $P_f, P_c, P_p, R_c, R_p$  が得られる。

### (3) 算出される幾何特徴量

本研究では地物点群  $P_f$  と円柱上点群  $P_c$ 、平面上点群  $P_p$ 、そして連結成分  $R_c, R_p$  の計5つの点群から以下の特徴量を計算する。

- (a) 点群の大きさ：  $X, Y, Z$
- (b) 主成分分析の固有値：  $\lambda_1, \lambda_2, \lambda_3$  ( $\lambda_1 \geq \lambda_2 \geq \lambda_3$ )
- (c) 主成分分析の固有値の比：  $\lambda_1/\lambda_2, \lambda_2/\lambda_3, \lambda_1/\lambda_3$
- (d) 点群間の距離：  $dist(P_c, R_c), dist(P_p, R_p)$
- (e) 線分方向分布：  $N_h/N, N_v/N, N_s/N$

本研究で用いる点群データは3次元の座標以外に色(RGB)の情報も持っているが、点群と色情報の同期が正確ではなかったため、今回は3次元の位置情報に基づく特徴量のみを用いる。

以下に、これらの特徴量を地物の分類に用いた場合の定性的な意味について説明する。

#### a) 点群の大きさ

点群を囲む直方体によって点群の大きさを表現する。直方体の直交する3辺の方向ベクトルを  $v_x, v_y, v_z$  とするとき、 $v_z$  は平面直角座標系のz軸と同じ方向にする。また、点群の  $x, y$  座標に関して主成分分析を行い、大きい固有値に対応する固有ベクトルを  $v_x$ 、もう一方の固有ベク

トルを  $v_y$  と決める。このような直方体のうち、すべての点群を包含する最小の寸法を点群の大きさとし、 $v_x, v_y, v_z$  の各方向の辺の長さをそれぞれ  $X, Y, Z$  とする。

#### b) 第1~3主成分分析の固有値

点群座標の共分散行列の固有値を特徴量として計算する。 $\lambda_1, \lambda_2, \lambda_3$  はそれぞれ第1, 第2, 第3主成分の固有値である。この固有値の値は、固有ベクトル方向の分散に等しい。

#### c) 主成分分析の固有値の比

主成分分析の固有値の比から、点群が線状もしくは平面上に分布している場合を検出できる。電柱のような線状物体では、 $\lambda_1/\lambda_2, \lambda_1/\lambda_3$  の値が  $\lambda_2/\lambda_3$  と比較して大きくなり、標識のような平面状物体では、 $\lambda_2/\lambda_3, \lambda_1/\lambda_3$  の値が  $\lambda_1/\lambda_2$  と比べて大きくなる。これらの数値は線状物体と平面状物体の分類によく用いられてきた。

#### d) 点群間の距離

円柱上点群  $P_c$  と円柱に属さない連結成分  $R_c$  の重心間の距離、そして平面上点群  $P_p$  と円柱と平面どちらにも属さない連結成分  $R_p$  の重心間の距離を計算する。この距離は、点群間の位置関係を示しており、対象物の大まかな構造を反映している。円柱上点群  $P_c$  と円柱に属さない連結成分  $R_c$  の重心間の距離を直線で表したものを図-5に示す。図のように街灯は円柱部分の先端に円柱上に属さない電灯の部分が接続しているため、図の信号よりも重心間距離が大きい。

#### e) 線分方向の分布

ここで特に、人工物と自然物の違いを記述するための特徴量について考える。人工物では柱状部分が地面に垂直に設置されるが、木のような自然物では様々な方向に枝が伸びていることが多い。この違いを表現するために、円柱や枝の方向の分布を特徴量として定量化する。

まず、点群のk近傍グラフを用いて、ワイヤフレームモデルを作成する。Yokoyamaら<sup>3)</sup>は、柱状物を線状に縮退させるために、ラブラシアン・スムージングを用いたが、ここでは閾値の調整が必要ないTaubinフィルタ<sup>9)</sup>を用いて細線化を行う。




図-5 円柱  $P_c$  と連結成分  $R_c$  の距離  
(左：信号機，右：街灯)

図-6に、地物点群に対して、細線化を施した結果を示す。この例のように、人工物では水平や垂直の線分が多いのに対して、木では様々な方向の線分が生成される。

そこで、線分と水平面がなす角度を計算し、角度が30°未満の水平に近い線分の個数  $N_h$ 、60°より大きい垂直に近い線分の個数  $N_v$ 、角度が30°以上60°以下の斜めの線分の個数  $N_s$  を求める。また、線分の個数を  $N$  とする。このとき、特徴量として、水平線分の比率  $N_h/N$ 、垂直線分の比率  $N_v/N$ 、斜め線分の比率  $N_s/N$  を加える。木のような自然物は斜め線分の比率が人工物の比率と比較して大きく、逆に人工物は垂直線分や水平線分の比率が自然物と比べて大きい。これらの特徴量は地物点群にのみ適用する。

## 6. 有効な特徴量の同定

### (1) 分類データの内容

地物点群のそれぞれは、前述した特徴量が計算されており、それらからなる特徴量ベクトルが与えられている。ここでは、教師付き機械学習を行うため、地物全体を学習用データと評価用データにほぼ半々になるように分けた。実験に用いた学習データと入力データの個数を表-1に示す。

表-1 評価実験に用いるデータの数

	学習データ数	入力データ数
電柱	139	138
街灯	113	113
木	44	44
標識	59	58
信号	64	64
合計	419	417




図-6 点群の細線化（上：標識，下：木）

表-2は、今回用いた特徴量の一覧である。この表においては、点群  $P_f$  を用いて特徴量  $X$  を算出することを  $X(P_f)$  のように示している。それぞれの地物点群は50個の点集合に分割され、そのそれぞれに対して、特徴量が計算される。その結果、各地物は50個の特徴量からなる特徴量ベクトルを持つ。

### (2) 機械学習による分類結果

表-3に Random Forest 法を適用した分類結果を示した。表左端の地物名はデータの本来のクラスを意味し、上端は認識結果によりラベル付けされたクラスを意味する。本来のクラスと認識結果のクラスが同じになる対角線上の欄は正しく分類された地物の個数を示し、それ以外の欄は上端のクラスとして誤認識された個数を意味する。街灯の例を見ると、113個のデータ中111個が街灯として認識され、2個が信号として誤認識されたことになっている。この表から、入力データの個数に対して誤分類の数は非常に少ないことがわかる。このことから、本研究で設定した50個の特徴量には、柱状物体の認識に有効な特徴量が含まれていることがわかる。

次に、誤分類された地物に着目する。表-3を見ると、街灯と標識のデータが2個ずつ信号に誤認識されている。

表-2 特徴量一覧

特徴量	点群	$P_f$	$P_c$	$R_c$	$P_p$	$R_p$
X値		$X(P_f)$	$X(P_c)$	$X(R_c)$	$X(P_p)$	$X(R_p)$
Y値		$Y(P_f)$	$Y(P_c)$	$Y(R_c)$	$Y(P_p)$	$Y(R_p)$
Z値		$Z(P_f)$	$Z(P_c)$	$Z(R_c)$	$Z(P_p)$	$Z(R_p)$
$\lambda_1$		$\lambda_1(P_f)$	$\lambda_1(P_c)$	$\lambda_1(R_c)$	$\lambda_1(P_p)$	$\lambda_1(R_p)$
$\lambda_2$		$\lambda_2(P_f)$	$\lambda_2(P_c)$	$\lambda_2(R_c)$	$\lambda_2(P_p)$	$\lambda_2(R_p)$
$\lambda_3$		$\lambda_3(P_f)$	$\lambda_3(P_c)$	$\lambda_3(R_c)$	$\lambda_3(P_p)$	$\lambda_3(R_p)$
$\lambda_1/\lambda_2$		$\lambda_1/\lambda_2(P_f)$	$\lambda_1/\lambda_2(P_c)$	$\lambda_1/\lambda_2(R_c)$	$\lambda_1/\lambda_2(P_p)$	$\lambda_1/\lambda_2(R_p)$
$\lambda_2/\lambda_3$		$\lambda_2/\lambda_3(P_f)$	$\lambda_2/\lambda_3(P_c)$	$\lambda_2/\lambda_3(R_c)$	$\lambda_2/\lambda_3(P_p)$	$\lambda_2/\lambda_3(R_p)$
$\lambda_1/\lambda_3$		$\lambda_1/\lambda_3(P_f)$	$\lambda_1/\lambda_3(P_c)$	$\lambda_1/\lambda_3(R_c)$	$\lambda_1/\lambda_3(P_p)$	$\lambda_1/\lambda_3(R_p)$
点群間の距離		$dist(P_c, R_c)$		$dist(P_p, R_p)$		
水平線分の比率		$N_h/N$				
垂直線分の比率		$N_v/N$				
斜め線分の比率		$N_s/N$				

表-3 分類の結果

		認識結果のクラス				
		電柱	街灯	木	標識	信号
本来の クラス	電柱	138	0	0	0	0
	街灯	0	111	0	0	2
	木	0	0	44	0	0
	標識	0	0	0	56	2
	信号	0	0	0	0	64

誤って分類された標識と街灯を図-7に示す。標識の場合は、点線枠内に示すように平面部分の点の欠落が多く、平面部分が正しく抽出できなかったため、信号として認識されてしまった。街灯の場合は点線枠内の電灯部分が支柱の頂点ではなく支柱の真ん中に接続されている。このことが原因で、円柱上点群と円柱に属さない点群との位置関係が一般的な街灯の位置関係と異なってしまったため、誤分類が生じてしまったと考察した。

### (3) 寄与度の計算

ここで、寄与度の定義について説明する。本研究の寄与度は、分類器を生成する際に計算された情報利得に基づき、各接点で計算された情報利得を特徴量ごとに足し合わせたものを寄与度と定義している。学習データの分割が正しい閾値ほど、その特徴量の情報利得は大きくなるため、特徴量を評価する指標に情報利得の総和は適していると言える。

### (4) 有効な特徴量の判定

柱状物体の分類に有効な特徴量を判定する。平面特徴量は寄与度は低いものの、標識の認識に必要であるため、平面特徴量の寄与度を閾値(約10)とし、閾値以上の寄与度を持つ特徴量のみで同様の分類を行った。この閾値以上の特徴量、計20個のリストを表-4に示す。

表-4の特徴量で分類した結果と、表-2の全特徴量を用いた結果を認識率で比較したものを表-5に示す。認識率には適合率と再現率を用いた。比較を見ると、表-4の特徴量では電柱と街灯の認識率が若干下がっているが、それ以外は表-2の特徴量と同じ認識率を維持している。

また、全データの特徴量の計算時間と学習時間、分類に要する時間を、全特徴量と寄与度の高い特徴量の場合の2種類でまとめたものを表-6にまとめた。特徴量を20個まで減らすことで、表のように特徴量の計算時間は3分の1以上短縮することができ、学習時間も約半分まで短くすることができる。認識率と計算時間を比較しても、特徴量を減らした前後で下がった認識率も非常に小さく、処理時間も圧倒的に短いことから表-4の特徴量を用いたほうが優位性が高いことがわかる。




図-7 誤分類された地物(左：標識，右街灯)

### (5) 考察

今回の分類に用いたデータは、複数の地域の計測データであり、市街地と高速道路両方の地物を含んでいる。地物の形状は地域差があるため、今回の学習用データが他の地域にも適用できる保証はないが、本研究で示した特徴量の同定法は、学習用データさえ用意できれば、他の地域の点群データにも適用が可能である。

今回の計測においては、同一のMMSを用いて、車両速度が40 km/h程度以下になるようにして計測を行った。しかし、計測条件が異なり、点群密度が大きく異なる場合には、セグメンテーションや曲面検出において異なる閾値が必要となる。車両の速度や点間隔については、計測データから算出可能と考えられるので、閾値を自動的に推定する方法については、今後検討していきたい。

また、MMSでの計測データでは、オクルージョンが避けられない。本研究では、この問題に対処するために、機械学習法としてRandom Forestを用いた。この手法では、特徴量を選択的に用いて多数の決定木を作成しているため、オクルージョンやノイズによって一部の

表-4 寄与度の高い特徴量

特徴量	寄与度	内容
$Z(P_f)$	14	地物点群のZ値
$\lambda_2(P_f), \lambda_3(P_f)$	20,18	地物点群の主成分固有値( $\lambda_2, \lambda_3$ )
$\lambda_1/\lambda_2(P_f), \lambda_1/\lambda_3(P_f)$	28,21	地物点群の主成分固有値の比( $\lambda_1/\lambda_2, \lambda_1/\lambda_3$ )
$N_h/N, N_v/N, N_s/N$	26,20,16	各エッジとエッジ総数の比
$X(R_c), Y(R_c), Z(R_c)$	15,22,26	円柱に属さない連結成分の大きさ
$\lambda_1(R_c), \lambda_2(R_c), \lambda_3(R_c)$	21,22,33	円柱に属さない連結成分の主成分固有値
$\lambda_1/\lambda_2(R_c)$	16	円柱に属さない連結成分の固有値の比( $\lambda_1/\lambda_2$ )
$Z(P_p)$	23	円柱点群のZ値
$dist(P_c, R_c)$	23	円柱点群と円柱に属さない連結成分との距離
$\lambda_1(P_p), \lambda_2(P_p)$	11,10	平面点群の主成分固有値( $\lambda_1, \lambda_2$ )
$\lambda_1/\lambda_2(P_p)$	11	平面点群の主成分固有値の比( $\lambda_1/\lambda_2$ )

表-5 認識率の比較

特徴量	認識率	電柱	街灯	木	標識	信号
表2	適合率	100%	100%	100%	100%	92.6%
	再現率	100%	98.2%	100%	94.8%	100%
表4	適合率	99.2%	97.3%	100%	100%	92.6%
	再現率	97.8%	97.3%	100%	94.8%	100%

表-6 処理時間の比較

全特徴量			寄与度の高い特徴量(20個)		
特徴量の計算(s)	学習時間(s)	分類(ms)	特徴量の計算(s)	学習時間(s)	分類(ms)
28.8	1.04	30.7	8.21	0.554	22.9

が損なわれても、その特徴量を用いない決定木によって正しい判定ができる余地がある。ただし、Random Forest法の有効性を定量的に検証するためには、他の機械学習法との比較が必要である。

## 7. 結論

本研究では、柱状物体を分類するために有効な特徴量を同定する手法と、分類のための特徴量を系統的に数え上げる方法について示した。また、本手法を実際の点群に適用し、その有効性を確認した。

今後は、レーザスキャナや車両速度に依存する閾値の自動計算法や、他の機械学習法の検討を行っていくことが必要である。今回は、点群の座標のみを用いた特徴量を扱ったが、MMSによっては、点群に反射強度や色情報が付加されていることがある。そうしたデータにおいては、これらの付加的な情報が物体の識別に有力な手がかりになる可能性がある。それについては、今後、検討していきたい。また、様々な計測データを用いて本手法の検証を行うとともに、より多くの分類対象が扱えるような特徴量の類型化について検討していく必要がある。今回は分類対象を柱状物体に限定したが、建物や壁などの多様な地物データに対応できるように拡張していきたい。また、今回の分類では、近接した複数の地物が混在する場合は分類対象から除外した。こうした場合にも適切に点群を分離して、分類できるように手法を拡張する必要がある。

**謝辞:** 本研究で用いた移動計測による点群データは、アイサンテクノロジー（株）から提供されたものである。本研究への協力に対して感謝の意を表す。

## 参考文献

- 1) Golovinskiy, A., Kim, V., Funkhouser, T. Shapebased Recognition of 3D Point Clouds in Urban Environments, International Conference on Computer Vision, pp.2154-2166, 2009.
- 2) Ishikawa, K., Tonomura, F., Amano, Y., Hashizume, T. Recognition of Road Objects from 3D Mobile Mapping Data, Proc. International Journal of CAD/CAM, Vol 13, pp.41-48, 2013.
- 3) Hiroki Yokoyama, Hiroaki Date, Satoshi Kanai, and Hiroshi Takeda, Detection and Classification of Pole-like Objects from Mobile Laser Scanning Data of Urban Environments, International Journal of CAD/CAM, Vol 13, pp.31-40, 2013.
- 4) Xiaolong Zhu, Huijing Zhao, Yiming Liu, Yipu Zhao, Hongbin Zha, Segmentation and classification of range image from an intelligent vehicle in urban environment, The 2010 IEEE/RSJ International Conference, pp.18-22, 2010.
- 5) C. Cabo, C. Ordoñez, S. García-Cortés, J. Martínez, An algorithm for automatic detection of pole-like street furniture objects from Mobile Laser Scanner point clouds, ISPRS Journal of Photogrammetry and Remote Sensing, Vol.87, pp.47-56, 2014.
- 6) H. Masuda, S. Oguri, J. He: Shape Reconstruction of Poles and Plates from Vehicle-Based Laser Scanning Data, Informational Symposium on Mobile Mapping Technology, 2013.
- 7) L. Breiman, "Random Forest", Machine Learning, Vol.45, pp.5-23, (2001).
- 8) J. He, H. Masuda Point-Clouds from Mobile Mapping System, The Asian Conference on Design and Digital Engineering (ACDDE), 2012.
- 9) G. Taubin, A Signal Processing Approach to Fair Surface Design, Proc. of ACM SIGGRAPH 95, pp. 351-358, 1995.

(?)

## GEOMETRIC PROPERTIES SUITABLE FOR CLASSIFICATION OF POLE-LIKE OBJECTS MEASURED BY MOBILE MAPPING SYSTEM

Kenta FUKANO, Hiroshi MASUDA

Point-clouds captured by a Mobile Mapping System(MMS) are useful for maintenance of infrastructures, such as utility poles and road signs. To use point-clouds in many applications, it is necessary to identify feature types of each point-set. We think that machine learning techniques are promising for this purpose. In our research, we consider geometric properties of a point-set that are effective for machine learning. Since there are a lot of pole-like objects to be repaired along roads, we investigate geometric properties of pole-like objects. Although a lot of geometric properties can be considered for point-sets, the effectiveness of geometric properties has not been quantitatively evaluated so far. We use the contribution degree of machine learning to identify effective geometric properties for classification of pole-like objects. Our experimental result showed that our method could effectively extract useful geometric properties that are calculated using a point-set.