

# 機械学習を用いたガードレールの抽出と形状再構成

○松本 裕稀<sup>†</sup>, 増田 宏<sup>†</sup>

<sup>†</sup>: 電気通信大学大学院情報理工学研究科

m1832102@edu.cc.uec.ac.jp

概要: MMS で取得した点群からガードレールを抽出およびモデル化することは、3次元地図において重要である。しかし、地域によって様々な形状のガードレールが存在するという問題がある。本研究では、点群と画像を用いて、機械学習によって、多様なデザインのガードレールを抽出する手法を提案する。また、抽出された様々なデザインのガードレールの3Dモデルを自動生成し、3次元地図上に配置する手法についても提案する。

<キーワード> 移動計測, 点群, 3次元モデリング

## 1. 緒言

近年、自動運転やインフラ保守の効率化などを目的として、道路周辺地物の3次元モデルを含んだ3次元地図に大きな関心が持たれている。3次元地図の作成には、道路周辺地物の膨大な3次元情報が必要となる。移動計測装置 (Mobile Mapping System, MMS) は道路周辺地物の3次元点群を短時間で広範囲に取得できるため、3次元地図を効率的に作成する手段として有望である(図1)。

道路周辺地物の中でも、ガードレールは車両と歩道を分離するために設置されるため、自動運転の安全性の面でも3次元地図での重要度は高い。ガードレールは国土交通省により設置規格が規定されているが、その形状規格は規定されておらず、地域によって様々な形状が存在する。したがって、全国の3次元地図に対して同じ形状のテンプレートを当てはめることはできない。森の研究[1]では、点群に対応する画像に対して機械学習を用いることでガードレールの抽出を行った。本研究ではこの手法を用いてガードレールを抽出することを考える。

MMS で取得した点群を用いて多様な形状のガードレールの3次元モデルを生成できることが望ましいが、MMS で取得した3次元点群は点の密度が低いため、抽出された点群から忠実に形状再構成を行うことは難しい。そこで本手法では、抽出された点群について、同一形状のガードレールを重ね合わせることで点密度を上げ、3次元モデルを生成する手法を提案する。さらに生成された3次元モデルを3次元地図上に配置する手法についても検討する。

## 2. ガードレールの抽出

### 2.1. 候補画像の抽出

ガードレールは、ビーム状のものやパイプ状のものなど形状の差異が大きい。また、MMS で取得したガードレールの点群は点密度が低い。したがって点群だけを用いてガードレールの点群を抽出することは容易ではない。そこで、森の研究[1]によるガードレールの抽出手法を用いる。

最初に点群から地面の除去を行う。本研究で用いた点群データには走行軌跡が含まれているため、



図1 移動計測装置(MMS)

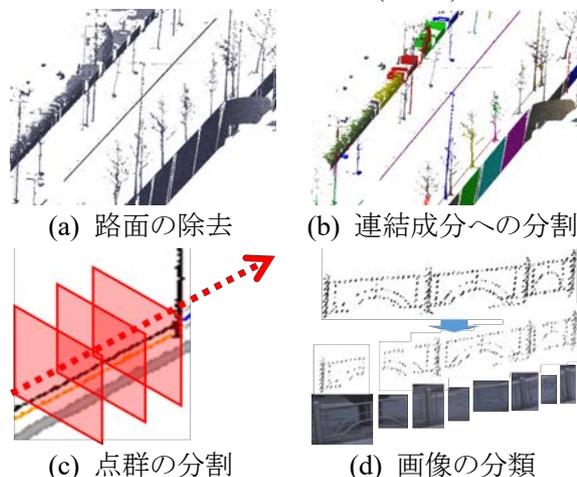


図2 ガードレールの抽出

おおよその地面の高さはわかっている。そこで、Z座標が地面位置付近であり、近傍点から算出される法線がZ方向に近いとき、図2(a)のように地面であるとして除去する。

MMSで取得された点群は、レーザスキャナの回転数とパルス繰り返し周波数を用いて、2次元格子上に写像できることが知られている。そこで、地面除去後の点群を2次元格子に写像し、近傍点を連結することで、図2(b)のように個々の地物に対応した連結なワイヤフレームモデルを生成する。

ガードレールは同一形状のものを複数接続して設置されている。よって連結されたワイヤフレームモデルの大きさは異なる。そこで、図2(c)のように、連結なワイヤフレームモデルを走行軌跡に沿って分割する。

ここでは個々の分割された点群が、ガードレールであるかどうかを判定する。本研究ではカメラとレーザスキャナの位置関係がわかっているので、3次元の点群を2次元画像上に投影することができる。そこで、図2(d)のように分割された個々の点群を画像上に投影して、点群が投影された矩形領域のカメラ画像を切り出す。

## 2.2. 抽出された画像の分類

抽出された画像を用いて地物の小領域の分類を行う。分類対象はガードレールとし、それ以外の

表1 データ数

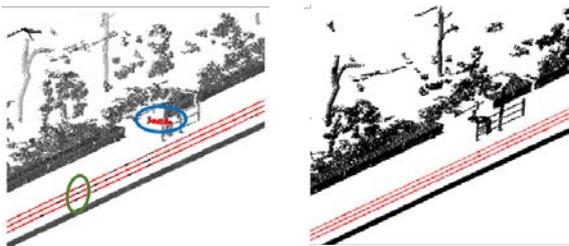
	学習データ	テストデータ
ガードレール	3912	777
その他	3910	1910

表2 地物画像の分類結果

	ガードレール	その他	F値
ガードレール	753	24	79.6%
その他	361	1609	93.7%

表3 補正後の分類結果

	ガードレール	その他	F値
ガードレール	761	16	94.6%
その他	71	1238	96.6%



(a) 分類結果 (b) 補正後  
図3 分類の得票率を用いた補正

地物を「その他」クラスとした。画像の分類にはImageNetの訓練用画像データを用いて事前学習したVGG16[4]に、ガードレールの画像とその他の地物の画像を用いて転移学習を行ったConvolutional Neural Network (CNN)を用いた。表1に用いたデータ数を示す。

## 2.3. 抽出結果

表2に、画像の分類結果を示す。ここで、図3(a)に示すように、画像の分類には誤分類が存在する。そこで、接続成分に対して分類の得票率によって改善をすると、図3(b)のように補正することができる。補正後の分類結果を表3に示す。補正によってF値が改善されていることがわかる。

## 3. ガードレールの形状再構成

### 3.1. 概要

抽出されたガードレールの点群は、雑草などが接触していると、その点群を含んでしまう。そこで図4に示すように、反射強度の違いを利用することで雑草の点群を除去する。

また、図5に示すように、パイプがレーザの照射方向と平行に近い個所は大きな範囲で点が欠落する。そこでガードレールはほとんどが左右対称なので、中心から折り返すことで、大きな範囲で点が欠落することはなくなる。さらに複数の単位形状を重ね合わせることでさらに点密度を上げる。

手法の概要を図6に示す。まず、ガードレール

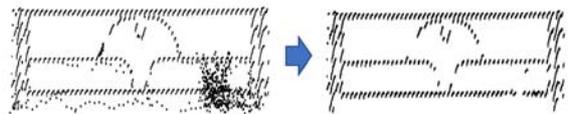


図4 反射強度を用いたノイズ除去

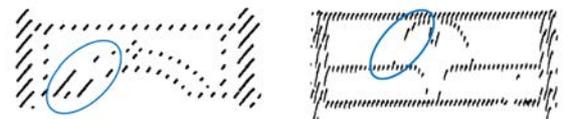
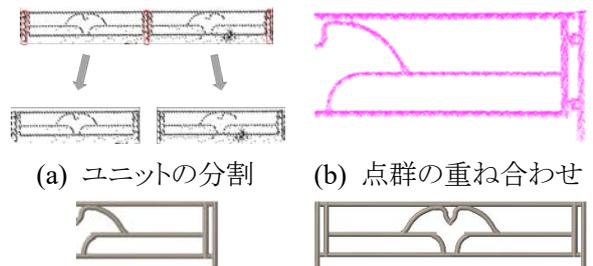


図5 点の欠落



(a) ユニットの分割 (b) 点群の重ね合わせ  
(c) モデル (d) ミラー操作  
図6 ガードレールの形状再構成

からポールを検出し、ポールを基準に単位形状に分割する(図 6(a)). それぞれの単位形状は、平面に投影することで、2次元の点群にする。さらにそれぞれの単位形状を中心に分割し、重ね合わせることで、図 6(b)のような高密度な点群を得ることができる。これを用いて生成されたモデルを図 6(c)に示す。最後にミラー操作を行い、図 6(d)のような単位形状の 3D モデルを生成することができる。

### 3.2. ユニットの分割

ガードレールは同一形状を複数接続することで構成されている。ここでは、最少単位の形状(ユニット)に分割することを考える。まず、計測順

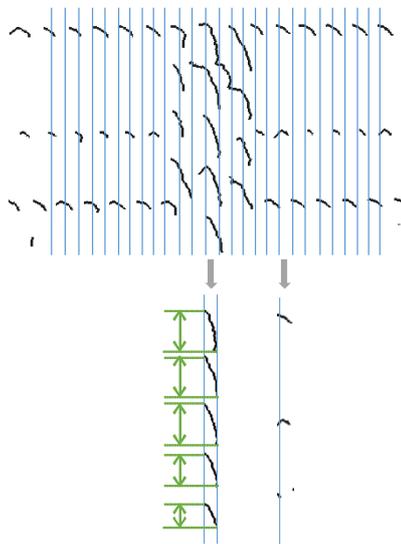


図 7 ユニットの分割

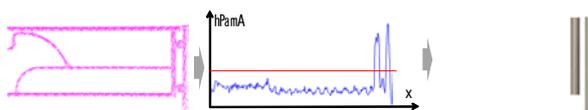


図 8 地面に垂直なパイプのモデル化

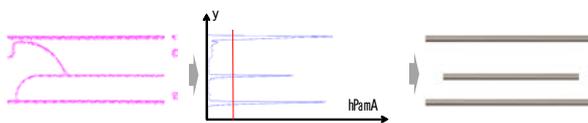


図 9 地面に平行なパイプのモデル化

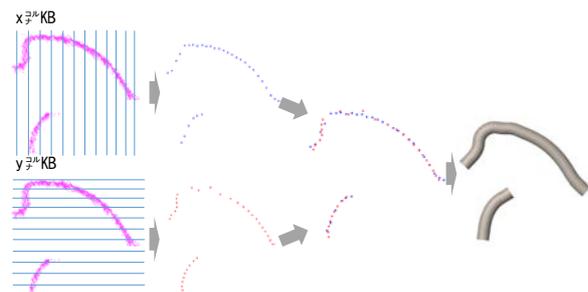


図 10 曲線のパイプのモデル化

で点の近い点同士を接続し、接続成分にする。得られた接続成分を平面に投影することで 2次元の点群を得る。次に図 7 上のように接続成分を x 軸に沿って分割する。そして図 7 下のように、接続成分と分割する直線の交点の距離を算出し、その和を算出する。この和が閾値を超えるような接続成分をポールとして算出する。ここでは分割する幅を 30mm、閾値を 400mm とした。

算出されたポールを境界にガードレールを分割する。それぞれのユニットを平面に投影することで、2次元の点群が得られる。それらをレジストレーション手法 ICP (Iterative Closest Points) を用いることで位置合わせを行う。さらに点群を重心で分割し、折り返すことで、図 6(b)のような高密度な点群を得ることができる。

### 3.3. モデルの生成

図 6 ガードレールの形状再構成(b)の点群から最初に直線状のパイプのモデル化を考える。地面に垂直な直線パイプはまず、図 8 のように、縦軸を点数、横軸を x 座標としたヒストグラムを作成する。次に、点数の最高値を算出し、それから一定の割合に含まれるようなヒストグラムの山を算出する。そしてそれぞれの山について、両側の谷を算出し、二つの谷の距離をパイプの直径、二つの谷の中点をパイプの中心軸とする。また、中心軸の長さは、二つの谷の範囲に含まれる点の z 座標の最小値と最大値の差として算出した。これらを用いて地面に垂直なパイプとしてモデルを作成する。ここで範囲に含まれた点は除去する。図 9 のように、地面に平行な直線パイプも同様にモデル化を行う。

曲線状のパイプは、まず図 10 左のように x 方向、y 方向で等間隔に区切る。ここでは間隔を 30mm とした。それぞれの領域でドロネー三角形分割を用いて領域を分割する。そしてそれぞれの領域で重心を算出する。これらを順に結合し、平滑化手法 Low-Pass フィルタ[2]を行うことでパイプのスケルトンを算出する。また、パイプの直径は図 8 と図 9 で求めた各パイプの直径の平均値を用いた。これらを用いて曲線状のパイプのモデルを作成すると図 10 右のようなモデルが生成された。

最後にそれぞれのモデルをマージし、ミラー操作を行うことで、単位形状の 3D モデルを生成することができる。

### 3.4. 生成結果

本手法を3種類の複雑な形状のガードレールに対して適用した。図11のように3Dモデルを生成することができた。ガードレールの多種多様なデザインを再現できていることがわかる。また、重ね合わせるユニット数を変化させたところ、10個以上のユニットを重ねると安定的にモデルを生成できた。



(a) カメラ画像 (b) 3Dモデル  
図11 生成されたガードレールのモデル

## 4. ガードレールの3次元地図への配置

### 4.1. 概要

生成された3Dモデルを3次元地図に配置する。本研究ではGoogle Earthを用いる。図12に示すように、Google Earthはビルや民家などの建造物と街路樹の3Dモデルは多く配置されている。しかしながら、ガードレールのような小型の道路周辺地物の3Dモデルはほとんど配置されていない。Google EarthではXMLファイルの一種であるKML(Keyhole Markup Language)を用いることで、作成した3DモデルをGoogle Earth上に配置することができる。そこで、3Dモデルを配置する位置の緯度経度座標( $\phi$ ,  $\lambda$ )およびモデルの回転移動量 $\alpha$ を算出する必要がある。ガードレールを上から見た図を図13に示す。図6(a)で算出した二つのポールの中点を配置する平面直角座標(X, Y)とする。平面直角座標(X, Y)を緯経度座標( $\phi$ ,  $\lambda$ )へ変換するために河瀬の計算手法[3]を用いて算出した。回転移動量 $\alpha$ は二つのポールからなる方向ベクトルと座標軸方向との角度として算出した。図14にガードレールの3Dモデルを配置した3次元地図を示す。

### 4.2. 配置結果

生成された3Dモデルを3次元地図にどれだけ配置できるか評価を行なった。3次元地図に配置するためには、前章におけるポールの検出において、ユニットの両側のポールが二つとも検出されている必要がある。そこで、実際のガードレールの総数と検出できたガードレール数を算出すると表4のようになった。検出率は85.0%と非常に高い数値で配置することができた。



図12 Google Earth

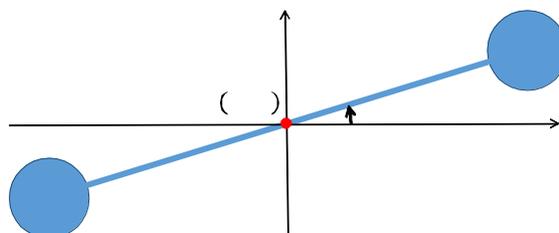
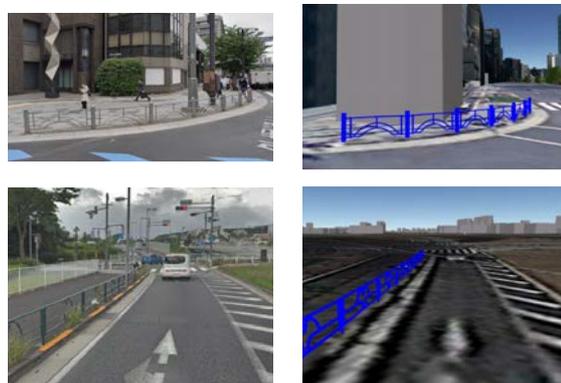


図13 配置する位置の算出



(a) カメラ画像 (b) 3次元地図

図14 3次元地図への配置

表4 モデルの配置結果

総数	検出	検出率
107	91	85.0%

## 5. 結言

本稿では、ガードレールの抽出、形状再構成、および3次元地図への配置手法について提案した。評価実験の結果、抽出、モデル化、配置を高い数値で行うことを示した。

今後は抽出および形状再構成の対象を増やし、

様々な物体を自動でモデルに置き換える手法を検討したい。

### 参考文献

- [1] 森悠真, 増田宏: 機械学習を用いた道路周辺地物の自動抽出, 精密工学会春季講演会, 2018.
- [2] G. Taubin: A Signal Processing Approach to Fair Surface Design, Proceedings of the 22<sup>nd</sup> annual conference on Computer graphics and interactive techniques 351-358, 1995.
- [3] 河瀬和重: Gauss-Krüger 投影における経緯度座標及び平面直角座標相互間の座標換算についてのより簡明な計算方法, 国土地理院時報, 121, 109-124, 2011.

**松本裕稀**: 2018 年, 電気通信大学情報理工学部知能機械工学科卒業. 同大学院情報理工学研究科修士課程在学中. 3次元計測, 点群処理, 物体認識に関する研究に従事.

**増田宏**: 1985 年, 東京大学工学部精密機械工学科卒業. 1987 年, 同大学院工学系研究科修士課程修了. 同年, 日本アイ・ビー・エム(株)入社, 東京基礎研究所に勤務. 1998 年, 東京大学大学院工学系研究科准教授, 2013 年より電気通信大学大学院情報理工学研究科教授. 形状モデリング, 3次元計測, 点群処理, CAD に関する研究に従事.