

# レーザ反射画像を用いた機械学習による路面判別

○ Lee Beomjoon (九州大), 中嶋 一斗 (九州大), 倉爪 亮 (九州大)

## Road surface classification by machine learning using laser reflection image

○ Beomjoon LEE(Kyushu Univ.), Kazuto NAKASHIMA(Kyushu Univ.),  
and Ryo KURAZUME(Kyushu Univ.)

Abstract : The recognition of the road surface condition is a crucial problem for autonomous driving system. Although an embedded camera is popularly used for the road surface recognition, the lighting condition affects the performance severely. In this research, we adopt three omni-directional laser scanners with different line numbers and line spacings and compare their performance using several Convolutional Neural Networks.

### 1. 緒論

近年, 自動走行車両の開発が各地で盛んに行われている. 自動走行車両の実現において, 車両周囲の状況, 特に走行路面の状態の正確な把握は極めて重要である. 車両に搭載した外界センサを用いた車両周囲の環境識別では, これまでに主にカメラが用いられているが [2], カメラは他の車両のライトや太陽など光源環境の影響を大きく受け, 昼夜で安定的な識別が難しい. これに対し, レーザスキャナを用いた手法 [3] は, 光源環境の影響が少なく, 夜間でも安定的にデータを取得できる利点がある.

南ら [1] は, 全方位レーザスキャナ (Velodyne HDL-32E) を用い, レーザスキャナの距離と反射画像を基に Convolutional Neural Network(CNN) により路面種別を識別する手法を開発し, 5 種類の路面に対して 95.5% の識別率で識別が可能であることを報告した.

本研究では, 南ら [1] の研究をもとに, レーザのライン間隔とライン数が異なる 3 種類の全方位レーザスキャナ (Velodyne VLP-16, HDL-32E, VLP-16-Hires) を用い, レーザのライン間隔とライン数が路面の識別性能に及ぼす影響を調査した. さらに南ら [1] の CNN モデルの改良を行ったことを報告した.



Fig. 1: 全方位レーザスキャナ (Velodyne VLP-16, HDL-32E, VLP-16-Hires)

### 2. 全方位レーザスキャナ

実験に用いた 3 種類の全方位レーザスキャナ (Velodyne VLP-16, HDL-32E, VLP-16-Hires) と, その諸元を Fig.1, Table 1 に示す.

Table 1: 使用した全方位 LiDAR

	VLP-16	HDL-32E	VLP-16-Hires
測定距離	100m	70m	100m
測定精度	$\pm 3cm$	$\pm 2cm$	$\pm 3cm$
測定視野	$+15^\circ \sim -15^\circ$	$+10^\circ \sim -30^\circ$	$+10^\circ \sim -10^\circ$
角度分解能 (水平)	$0.1^\circ \sim 0.4^\circ$	$0.1^\circ \sim 0.16^\circ$	$0.1^\circ \sim 0.4^\circ$
角度分解能 (垂直)	$2.0^\circ$	$1.33^\circ$	$1.33^\circ$

### 3. 路面データの取得

レーザスキャナを用いた路面識別に対する公開データセットは存在しない. そこで本研究では, レーザスキャナを車両に取り付け, 実際に走行して路面のレーザ計測を行い, データセットを作成した. 具体的には, 全高 1610mm の乗用車に高さ 500mm のレーザ固定台を搭載し, 上部に斜め  $11^\circ$  下向きに 3 種類のレーザスキャナを取り付けた (Fig. 2). 各レーザスキャナ間での反射を防ぐため, レーザの間に黒い板を設置した. この車両を 5~15km/h のスピードで走行させ, 路面までの距離データと, その際の反射率のデータを取得した.

識別対象の路面は, Fig. 3 に示すように, Asphalt (アスファルト), Grass (芝生), Sand (砂), Tile (タイル), Gravel (砂利) の 5 種類の路面である, 各クラスごとに位置の離れた 5ヶ所で計測を行い, 各場所で 2000 枚ずつ取得した (Table 2). ただし, Tile クラスは計測候補となる路面が少ないため, 2 箇所のタイル状の路面区域で計測を行い, 位置を変えて計 5 回の計測を行った.



Fig. 2: 3種類レーザスキャナを取り付けた実験車両



Fig. 3: 識別対象路面：左から *Asphalt*, *Grass*, *Sand*, *Tile*, *Gravel*

#### 4. 距離、反射率データの作成

レーザスキャナで取得したデータは、レーザスキャナから 360° 方向で取得した点群データである。例を Fig. 4 に示す。データの左右に、建物や草など路面範囲以外の物体が計測されているため、まず進行方向のデータのみを切り出して、それらを取り除いた。レーザスキャナから得られるデータは、路面までの距離データと反射率データである。具体的な手順を以下に示す。

- 1) 車両の走行方向の決定 : レーザを一番下のラインから 5 ラインを選び、それぞれレーザスキャナからの距離が最も近い点を選択して、その点までの方向の平均を走行方向として決定
- 2) 中心付近の切り出し : 得られた走行方向から左右 20° 内のデータを切り出す
- 3) ライン数の設定 : ライン数による識別率の比較のため、各レーザで使用するライン数を設定
- 4) 4 種類のデータの生成 : レーザスキャナから得られる距離データと反射光データから、距離データの 8 ビット濃淡画像データと 32 ビット浮動小数点型データ

Table 2: 取得データ

	場所 1	場所 2	場所 3	場所 4	場所 5
<i>Asphalt</i>	2000	2000	2000	2000	2000
<i>Grass</i>	2000	2000	2000	2000	2000
<i>Sand</i>	2000	2000	2000	2000	2000
<i>Tile</i>	2000	2000	2000	2000	2000
<i>Gravel</i>	2000	2000	2000	2000	2000




Fig. 4: レーザスキャナから得られたデータの例

データを、また反射光データから 8 ビット濃淡画像データと 32 ビット浮動小数点型データを、それぞれ生成した。ただし濃淡画像は計測値を 0 から 255 に正規化して作成した。濃淡画像データはビットマップ形式で、浮動小数点型データは NPY ファイルで保存されており、それぞれ Table 3 に記述した。

Table 3: CNN への入力データ

	8 ビット濃淡画像	32 ビット浮動小数点
距離	D BMP	D NPY
反射光	R BMP	R NPY

また、全方位レーザの特性として、レーザの計測距離が遠くなるほどレーザの間隔が疎になる。そこで本研究では、32 ラインを用いるレーザ (HDL-32E) では、32 ライン (一番上・遠距離) から 20 ラインまでは 2 ラインずつ、20 ラインから 8 ラインまでは 4 ラインずつ、レーザのライン数を減らして識別を行い、レーザの間隔と識別率の関係性を調べた。また、16 ラインを用いる VLP-16 と VLP-16-Hires では、16 ラインから 8 ラインまで 4 ラインずつ減らした。

#### 5. CNN を用いた学習

作成された距離、反射率データを用い、Fig 5 に示す 4 種類の CNN モデルを用いて学習を行った。ただし、各モデル名で文字 C は Convolution Layer を、文字 Bn は Batch normalization が適用されていることを示す。また、CC は Convolution Layer が 2 重であり、CCC は 3 重であることを示す。また D は Transposed Covolution[4] である。

Table 4: HDL-32E を用いた識別結果 [%]

ライン数	32	<b>30</b>	28	26	24	22	20	16	12	8
<b>D BMP</b>	73.85	<b>74.33</b>	72.02	69.47	62.81	56.61	52.32	52.14	49.38	45.66
<b>D NPY</b>	73.85	<b>73.88</b>	72.23	68.30	62.64	55.52	51.54	51.23	49.32	44.44
<b>R BMP</b>	86.13	<b>86.52</b>	84.96	84.91	84.14	82.89	82.29	79.67	75.93	69.15
<b>R NPY</b>	83.43	<b>85.11</b>	84.16	83.58	83.47	81.22	80.58	78.30	74.76	68.19

Table 5: VLP-16 を用いた識別結果 [%]

ライン数	16	<b>12</b>	8
<b>D BMP</b>	52.31	<b>53.95</b>	42.91
<b>D NPY</b>	51.56	<b>53.00</b>	42.91
<b>R BMP</b>	<b>80.78</b>	80.56	73.30
<b>R NPY</b>	80.42	<b>80.56</b>	72.53

Table 6: VLP-16-Hires を用いた識別結果 [%]

ライン数	16	<b>12</b>	8
<b>D BMP</b>	48.77	<b>56.60</b>	42.39
<b>D NPY</b>	49.27	<b>56.79</b>	41.94
<b>R BMP</b>	72.72	<b>80.80</b>	68.54
<b>R NPY</b>	71.63	<b>79.81</b>	68.46

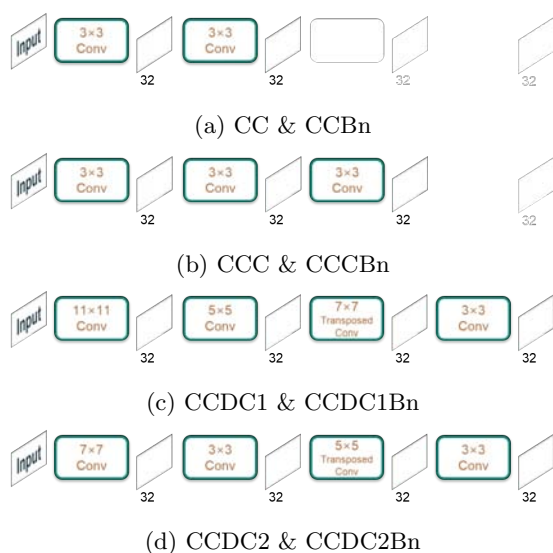


Fig. 5: 4種類のCNNモデル

## 6. 実験結果

上述したCNNを用い、レーザのライン間隔、ライン数の異なるデータに対して、路面種別の識別精度を比較した。実験では、それぞれの路面種別に対する5つのデータから、3つを学習データ、2つをテストデータとした。また各セットの学習データから1500枚ずつをランダムに選択して学習の評価に用いた。これを10セット行い、平均識別率を求めた。

### 6.1 レーザのライン数、ライン間隔の識別率への影響

レーザのライン数とライン間隔を変えて識別実験を行った。CNNにはCCBnモデルを用い、学習率0.001、Epoch数200、Batch size16で学習を行い、Momentum

Stochastic Gradient Descent(Momentum SGD)を用いて最適化した。入力画像は横120ピクセル、縦はライン数である。

各レーザスキャナを用いた識別実験における平均識別率をTable4～6に示す。全般的に、レーザスキャナの距離データに比べて、反射光データを用いた場合の識別率が高かった。HDL-32Eを用いた場合は、30ラインを用いた場合が最も識別精度が高く、またVLP-16とVLP-16-Hiresでは、16あるいは12ラインを用いた反射光が最も高かった。また全てのセンサでライン数が減少するほど識別率が低下した。HDL-32Eで、32ラインを用いた場合の識別率が30ラインを用いた場合よりも低くなっているが、これは最後の2ラインはかなり遠方を撮影したものであり、対象路面以外の物体が計測されている場合があるためと考えられる。また特に距離データでは、VLP-16-Hiresを用いた方がVLP-16に比べて識別精度が若干高く、ライン間隔が狭いほうが正確に識別できることが分かった。

### 6.2 レーザ反射画像を用いるCNNモデル性能比較

次に、4種類のCNNモデルに対する識別性能の比較実験を行った。ただし学習率0.003、Epoch数200、Batch size16で学習を行い、Momentum SGDを用いて最適化した。

各モデルに対する識別結果をTable7に示す。実験の結果、CCDC2モデルが最も識別精度が高かった。またBatch normalizationを適用することで識別精度が低下している。特にCCDC1Bnは識別率が非常に低いが、これは過学習の影響であると考えられる。

Table 7: CNN モデル性能比較 [%]

CNN モデル	CC	CCBn	CCC	CCCBn
R BMP	88.98	84.41	89.48	83.31
CNN モデル	CCDC1	CCDC1Bn	<b>CCDC2</b>	CCDC2Bn
R BMP	85.92	45.26	<b>89.51</b>	78.86

## 7. 結論

本稿では、3種類の車載全方位レーザスキャナを用いて路面データを取得し、4種類のCNNを用いて路面種別の識別実験を行った結果を示した。実験の結果、レーザスキャナの距離データより反射光データを用いたほうが識別精度が高いことが分かった。また、ライン数が多いほど識別性能が高く、またライン間隔が狭いほど正確に識別できることがわかった。また4種類のCNNモデルを比較した結果、Batch normalizationを適用しないCCDC2モデルが最も性能が高いことを確認した。なお、今回の結果は南ら[1]よりも低い結果であるが、データセットが異なるため、数値的な比較は困難である。

今後は路面の種別を増やすとともに、より性能の良いCNNモデルの構造について検討する予定である。

## 謝辞

本研究はジャトコ株式会社の支援により実施されました。

## 参考文献

- [1] 南 承佑, 中嶋 一斗, 倉爪 亮, 関口 正一: “レーザ反射画像を用いた機械学習による路面判別”, 第18回計測自動制御学会システムインテグレーション部門講演会, pp.2372-2374(2017)
- [2] Nolte, M., Kister, N., and Maurer, M.: “Assessment of deep convolutional neural networks for road surface classification”, *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, pp. 381-386(2018)
- [3] Wang, H., Wang, B., Liu, B., Meng, X. and Yang, G.: “Pedestrian recognition and tracking using 3D LiDAR for autonomous vehicle”, *Robotics and Autonomous Systems*, vol.88, pp.71-78(2017)
- [4] Dumoulin, Vincent and Francesco Visin.: “A guide to convolution arithmetic for deep learning”, *arXiv preprint arXiv:1603.07285*, (2016)