

レーザ反射画像を用いた機械学習による路面判別

○南 承佑 (九州大学), 中嶋 一斗 (九州大学), 倉爪 亮 (九州大学), 関口 正一 (Jatco)

Road surface classification by machine learning using laser reflection image

○Seungwoo Nham (Kyushu univ.), Kazuto Nakashima (Kyushu univ.)

Ryo Kurazume (Kyushu univ.), and Shoichi Sekiguchi (Jatco Ltd.)

Abstract : For automatic driving, classification of a road surface is an important function for determining a route and ensuring the stability of driving. However, the environment where the vehicle drives is greatly influenced by the lighting condition such as the sun, night, vehicle light, etc. Therefore, stable classification of a road surface by a camera is generally difficult. In this research, we aim to realize a stable classification for a road surface by measuring the surface with a laser scanner installed on a vehicle, and examine two kinds of machine learning techniques: learning features extracted by Local Binary Pattern method with Support Vector Machine and learning by Convolution Neural Network.

1. はじめに

自動車の自動走行の実現には車両周囲の状況の正確な把握が極めて重要であり、特に路面状態の認識は、自動走行の経路決定や走行安定性の確保に必要な機能である。これまでに提案された車載センサを用いた車両周囲の環境識別法は、カメラを用いる手法 [1] とレーザスキャナを用いる手法 [2][3][4] に大別される。このうちカメラを用いた手法は、車両が走行する環境は太陽、ライトなどの影響により見えが大きく変動するため、路面状態の安定な認識は一般に難しい。一方、レーザレンジファインダによる計測は、光源環境の影響を受けにくく、夜間でも安定してデータを取得できる利点がある。そこで我々は現在、レーザスキャナを用いた路面状態の把握について研究を行っている。

本稿では、車載レーザスキャナから得られるレーザ計測データを用いた、2種類の機械学習法による路面種別手法の提案と精度評価実験について報告する。

2. 路面データセット

本研究では、自動車が走行する典型的な路面の例として、Fig.1 に示すアスファルト、小石、芝生、タイル、砂の5種類(5カテゴリ)を取り上げる。まず、Fig.2 に示すように、自動車上部に斜め 30° 下向きに全方向レーザスキャナ (Velodyne HDL-32E) を固定し、上記5種類の路面を走行してレーザ計測を行った。レーザスキャナから得られるデータは、距離値およびレーザ反射光の反射強度である。カテゴリごとのデータ数を Table 1 に、計測データの例を Fig.3 に示す。ただし、識別には、全方向レーザスキャナから得られる 360 度方向のデータ (1260×32 ピクセル) のうち、正面方向でかつ車体に隠れない 100×20 ピクセルの画像を切り出して用いる。計測データは、自動車

Table. 1: 各カテゴリのデータ数

| 地形クラス | データ数 |
|--------|-------|
| アスファルト | 10278 |
| 小石 | 10208 |
| 芝生 | 10072 |
| タイル | 10153 |
| 砂 | 10076 |

を 30km/h で実際に走行しながら連続してレーザ計測を行い、それぞれのカテゴリでは同じ領域(同じ海岸や森など)から取得した。なお、レーザスキャナからは距離情報は 32bit の浮動小数点として、反射強度は 0 から 255 までの整数値で得られることから、それらをそのまま記録したデータと、Fig.4 に示す 8bit 256 階調グレースケールに変換したデータの2種類を作成した。



Fig. 1: 5種類の路面(左上から右にアスファルト、小石、芝生、砂、タイル)



Fig. 2: 実験車両と全方向レーザスキャナ




Fig. 3: 全方向レーザスキャナによる計測結果. 32 ラインが取得できるが, 車両によって隠れた部分を除いた 20 ラインを有効なデータとして用いた.

3. 機械学習手法

本研究では機械学習の手法として, (1)Local Binary Pattern (LBP) による特徴記述と Support Vector Machine (SVM) を用いた識別法, (2)Convolutional Neural Network(CNN) を用いた識別法の 2 種類について検討する.

3.1 LBP による特徴記述と SVM を用いた識別

LBP は濃淡画像から局所的な特徴を抽出する特徴記述子であり, そのヒストグラムを学習することで, 高精度な環境識別が可能であることが報告されている [4]. そこで計測された距離値と反射強度を 32 ビット浮動小数点型で表したデータと, それを 8 ビットの濃淡画像に正規化した



Fig. 4: 8bit で表現した 100×20 ピクセルの濃淡画像

データの 2 種類のデータに対し, LBP を計算して特徴を抽出し, 得られた LBP のヒストグラムを用いて SVM により学習を行った. なお, 実験では各カテゴリのデータをランダムに 2 つに分け, それぞれ学習用, 評価用データとして識別率を計算した. これを 10 回繰り返して, 平均の識別率を求めた.

得られた平均識別率を Table 2 に示す. これより, 8 ビット, および 32 ビットのデータともに, 反射強度が距離値よりも高い識別率を示すことが分かる.

Table. 2: LBP と SVM を用いた手法の平均識別率

| 入力データ | 平均識別率 [%] |
|--------------------|-----------|
| 距離値, 8 ビット濃淡画像 | 76.8 |
| 反射強度, 8 ビット濃淡画像 | 98.3 |
| 距離値, 32 ビット浮動小数点型 | 77.7 |
| 反射強度, 32 ビット浮動小数点型 | 98.1 |

3.2 CNN による識別

前項と同様に 32 ビットと 8 ビットの 2 種類のデータに対して, CNN で学習を行った. CNN は, 畳み込み層とプーリング層などから構成される. 畳み込み層は, 入力をフィルタ処理をして特徴マップを得る. プーリング層は, 畳み込み層の出力を入力として受け, 特徴マップを縮小された新しい特徴マップに変換する. 全結合層は, 各層のユニットが次の層のユニットとすべて繋がる層である. それぞれの接続は重みを持ち, 入力, 出力共に 1 次元ベクトルである. この処理を繰り返すことによって, 入力画像の特徴を維持しながら, より次元の少ない特徴が得られる. 本実験では, Deep Learning Library に Chainer を使い, その構造と出力を以下のように設定した. (チャンネル数 × 横 × 縦)

- ・ 入力 (1×100×20)
- ・ 畳み込み層 (32×100×20)
- ・ プーリング層 (32×50×10)
- ・ 畳み込み層 (32×50×10)
- ・ プーリング層 (32×25×5)
- ・ 全結合層 (128)
- ・ 全結合層 (5)

畳み込み処理を行った後は, 次の層の入力分布をミニバッチごとに平均=0, 分散=1 に正規化を行う Batch Normalization 法を適用し, 識別精度の向上を図った.

識別結果を Table 3 に示す. 8 ビットの濃淡画像を入力した場合は, LBP と SVM を用いた場合と同様に, 反射強度が距離値よりも高い識別性を示している. 一方, 32

ビットの浮動小数点型データを入力した場合は、反射強度の識別精度が急激に低下しているが、現状ではこの理由は不明である。

Table. 3: CNN を用いた手法の平均識別率

| 入力データ | 平均識別率 [%] |
|--------------------|-----------|
| 距離値, 8 ビット濃淡画像 | 88.4 |
| 反射強度, 8 ビット濃淡画像 | 95.5 |
| 距離値, 32 ビット浮動小数点型 | 85.2 |
| 反射強度, 32 ビット浮動小数点型 | 63.2 |

また、全方位レーザ計測データから切り出す領域を 100×20 ピクセルから 160×16 ピクセルとして、同じ構造の CNN により学習を行ってみたところ、Table 4 の結果が得られた。今までは 8bit 256 階調グレースケールに変換するとき、データ一枚ずつ個別の値で正規化を行っていたが、正規化方法を全データを同一値、カテゴリーごと同一値、そのままの変換に分け、比較を行った。このように切り出す領域や正規化の方法によって、識別精度が大きく変化することがわかる。この切り出す画像の領域に加えて、CNN の構造をより最適化することで、LBP と SVM を用いた方法と同等、あるいはそれ以上の性能が得られる可能性があり、今後、さらに検討を進める予定である。

Table. 4: CNN を用いた手法の平均識別率 (160×16 ピクセル)

| 入力データ | 距離値の平均識別率 [%] | 反射強度の平均識別率 [%] |
|-----------------------------|---------------|----------------|
| 正規化しない (32 ビット浮動小数点型) | 90.4 | 70.6 |
| 正規化しない (8 ビット濃淡画像) | - | 65.8 |
| 1 枚ずつ異なる値で 正規化 (8 ビット) | 91.8 | 98.2 |
| 全データで同じ値で 正規化 (8 ビット) | 87.2 | 66.8 |
| カテゴリーごとで同じ値で 正規化 (8 ビット) | 80.8 | 61.9 |

4. まとめ

本稿では、車載レーザスキャナによる路面データの収集と、2 種類の機械学習法を用いた路面種別の識別精度の検証実験について説明した。実験の結果、レーザスキャナから得られる距離値よりも、反射強度を用いた場合が、識別精度が高いことが分かった。また、現状では LBP と SVM を用いた手法が CNN よりも若干識別精度が高かった。今

後は路面の種別を増やすとともに、入力データを切り出す領域や CNN の構造についても検討する。また、距離値と反射強度を同時に用いた場合についても検証を行う予定である。

参考文献

- [1] P. Filitchkin and K. Byl, “Feature-based terrain classification for LittleDog”, *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems, Vilamoura*, pp. 1387–1392, 2012.
- [2] Suger, Benjamin, Bastian Steder, and Wolfram Burgard, “Terrain-adaptive obstacle detection”, *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS)*, pp. 3608–3613, 2016.
- [3] Walas, Krzysztof, and Michal Nowicki, “Terrain classification using laser range finder”, *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS)*, pp. 5003–5009, 2014.
- [4] Hojung Jung, Oscar Martinez Mozos, Yumi Iwashita, Ryo Kurazume, “Local N-ary Patterns: a local multi-modal descriptor for place categorization”, *Advanced Robotics, Vol. 30, No. 6*, pp. 402–415, 2016.