

積雪寒冷地域での路面状態推定

戸塚 康貴[†] 神戸 英利[‡]東京電機大学大学院理工学研究科^{†‡}

1. 研究背景・課題

積雪寒冷地域において、積雪や凍結などの路面状態を適切に認知することは、自動車を運転する際に非常に重要である。しかし、積雪寒冷地域での冬季の路面状態は気温や天候などにより刻一刻と変化し、目視による認知の限界や、ヒューマンエラーなどにより、多くの交通事故が発生している。北海道で2004年から2013年に発生した冬型人身事故の85[%]はスリップが原因の事故であり、スリップ事故を路面状態別に見ると、凍結が85[%]、積雪が13[%]であった[1]。

昨今では、車載カメラや加速度センサなど、多様なセンサから得られたデータを用いて機械学習を行うことで路面状態を推定する研究が行われている[2]。しかし、検出精度の面で向上の余地が残されており、また走行路や時間帯の違いを含めたデータによる検出精度の検証も必要である。

2. 研究目的

本研究では、走行する自動車前方の路面状態を車載カメラの映像や各種センサの情報をもとに時間帯や走行路の違いに関係なく乾燥、湿潤、雪解け、積雪、凍結の5クラスに推定することを目的とする。また、本研究で構築したシステムは一般の乗用車に搭載することを前提とし、シングルボードコンピュータなど、小規模な演算装置でも高速に処理ができるシステムの構築を目指す。

3. 提案手法

システム概要図を図1に示す。

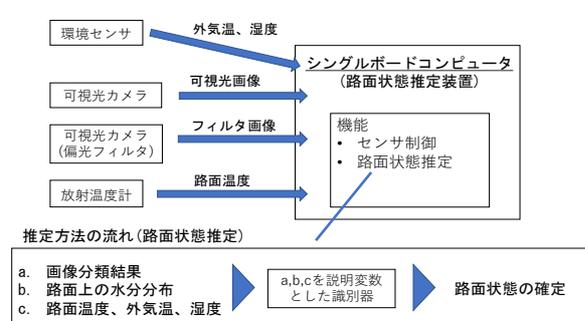


図1 システム概要図

Estimation of road conditions in snowy and cold areas

[†]Kouki Totsuka, [‡]Hidetoshi Kambe[†]

^{†‡}Graduate School of Science and Engineering,
Tokyo Denki University

本研究では自動車に設置した2台のカメラ(1つは偏光フィルタ搭載)、放射温度計、環境センサから得られたデータを1台のシングルボードコンピュータに集約する。次に得られた可視光画像とフィルタ画像を用いて画像分類と路面上の水分分布量の推定を行い、それらの結果と路面温度、外気温、湿度を説明変数とした機械学習の教師あり学習を用いて路面状態を推定する。

3.1. 画像分類

カメラから得られた可視光画像を用いて画像分類を行う。画像分類には畳み込みニューラルネットワークを使用する。また、本研究では小規模な演算装置での実装を前提としているため、可能な限り計算コストが低くなるようにモデルの構築を行う。また、分類クラスは2章の研究目的と同様の5クラスとする。

3.2. 水分分布量の推定

山田宗男らが行った研究では光の偏光特性などを利用することで路面状態を5クラスに分類した[3]。この研究で使われている技術を利用した。

乾燥路面では光は乱反射するため、光の偏光特性を示が、路面上に水分が存在し光が鏡面反射した場合、p偏光とs偏光の反射率に違いが発生し、その比はブルースター角で最大となる。この時、撮影された可視光画像とフィルタ画像において、水分が分布する場所では画素値に違いが発生する。この比を測定し水分の存在を推定する。

3.3. 識別器

画像認識の結果、水分分布量、路面温度、外気温、湿度を説明変数として、機械学習の教師あり学習を用いて分類を行う。分類するクラスは2章の研究目的と同様の5クラスとする。分類には、ランダムフォレスト、XGBoost、LightGBMの3つのモデルを作成し、精度の高いものを採用する。

4. 実装

4.1. 実装システム

本研究ではセンサ制御と路面状態推定を行うシングルボードコンピュータはRaspberry Pi 4 model Bを使用し、カメラ、放射温度計、環境センサはそれぞれRaspberry Pi Camera V2, Lepton3.5+PureThermalMini I/O module, BME280を用いて実装行なった。また可視光カメラは自動車のフロ

ントガラス中央上部, 放射温度計はボンネット, 環境センサはフロントグリルの裏側に設置した。

現在実装を行なっているのは3.2節の画像分類と3.3節の路面上の水分分布量推定である。従って, 以降ではこの2つについて説明する。

4.2. 画像分類

学習のフレームワークには TensorFlow, ライブラリは Keras を用いた。また学習には転移学習の手法を採用し, ベースモデルには MobileNetV3 を使用した。さらに, 作成したモデルの計算量を減らすため, 学習済みモデルは TnsorFlow Lite への変換を行なった。

現在使用している学習データは dry クラスが 5615 枚, wet クラスが 821 枚, slushy クラスが 510 枚, snowy クラスが 983 枚の合計 7929 枚である。今回, icy クラスはまだ撮影ができていないので, 上記の4クラスで画像分類を行なった。

4.3. 水分分布量の推定

路面上の水分分布量の推定は, 同時に撮影された可視光画像とフィルタ画像の対応するピクセルの RGB 値においてそれぞれ比を求める。その比が閾値を下回った場合に, 対応するピクセル上には水分が存在すると定義した。

現在実装を行なっているシステムは閾値を 0.75 に設定し (RGB 値のどれかが 25% 減少), 閾値を下回った場合に水分が存在するとした。画像を処理した例を図 2 に示す。



図 2 処理画像の例

5. 評価

5.1. 画像分類

4.2 節で示した学習データをトレーニング画像と検証画像に 0.75:0.25 の割合で分割し, 学習を行なった。検証画像に対する精度を表 1 に示す。

表 1 各クラスでの精度

class	precision	recall	f1-score	support
dry	0.9735	0.9721	0.9728	1398
wet	0.8049	0.8418	0.8229	196
slushy	0.8696	0.8759	0.8727	137
snowy	0.9793	0.9480	0.9634	250
accuracy	0.9495			1981

5.2. 水分分布量の推定

乾燥路面と湿潤路面で走行を行い, それぞれ路面上の水分分布量の推定を行なった。乾燥路面では 95 枚, 湿潤路面では 152 枚の撮影を行い, それぞれ路面上に水分が存在すると推定されたピクセルの割合の平均は乾燥路面では 25.63%, 湿潤路面では 35.88% であった。

6. 考察

6.1. 画像分類

表 1 に示すように wet, slushy クラスの精度が良くない原因として, 学習データをラベル付けする際に定義を曖昧にしてしまっていたことが挙げられる。wet クラスでは, 単に路面が濡れている状態なのか, 路面が冠水状態で水膜が発生している状態なのか明確に定義せずにラベル付けを行っていた。slushy クラスでも同様のことが言える。今後はデータ量を増やすと共に, クラスの定義を明確にし, 場合によっては分類クラスを増やしていくことが必要になると考えられる。

6.2. 水分分布量の推定

図 2 に示すように, 乾燥路面と湿潤路面では画素値に違いが発生することが確認できた。しかし, 5.2 節に示すようにその差は 10[%] 程度であり, 閾値や画像の前処理に改善が必要である。

7. まとめと今後の展望

本研究では, 自動車に搭載したカメラ, 放射温度計, 環境センサから得られたデータをもとに路面状態を 5 クラスに分類し, 一般の乗用車に搭載できるシステムの提案及び, 構築を行った。また, 現在実装を行なっている画像分類と水分分布量の推定では, ある程度の精度が確認できた。しかし, 改善の余地が多く残されており, 画像の処理方法の改善や学習データの収集が必要である。

今後の展望として, 学習データの収集とクラスの定義の明確化が最優先事項として挙げられる。また, 路面状態を確定する識別器の実装を行い, システム全体での精度の検証を行なっていく。

参考文献

- [1] 国立研究開発法人 土木研究所 寒地土木研究所 寒地交通チーム: 北海道における冬期の交通事故傾向および交通事故リスク要因の分析, <https://thesis.ceri.go.jp/db/files/13325455305976dc6aaa14c.pdf> (参照 2021-8-16)
- [2] 石附将武, 高橋翔, 萩原亨, 石井啓太, 岩崎悠志, 森 徹平, 花塚泰史: 複数の車載センサーデータを統合した冬期の路面状態の Late Fusion による推定モデル, https://www.jstage.jst.go.jp/article/jsceiii/3/J2/3_642/_pdf/-char/ja (参照 2022-3-22)
- [3] 山田宗男, 上田浩次, 堀場勇夫, 津川定之, 山本新: 画像処理による車載型路面状態検出センサの開発, https://www.jstage.jst.go.jp/article/ieejieiss/124/3/124_3_753/_pdf/-char/ja (参照 2022-2-4)