

交通監視カメラ画像に機械学習を適用した湿潤路面の検知

服部充宏*¹ 大口敬*² 小山拓哉*³

東京大学大学院 工学系研究科 社会基盤専攻*¹

東京大学 生産技術研究所*²

首都高速道路株式会社 保全・交通部 道路情報・交通室 交通安全推進課*³

雨天時は、事故が多くなる傾向にある。さらに湿潤状態による路面摩擦の低下は速度超過や車両操作ミスの際に事故に繋がりがやすい。一方で、首都高速道路では多くのカメラが設置され交通監視が行われている。カメラ画像による積雪や凍結の検知を試みた研究や車載カメラにて路面状態を推定する研究はみられるが、可動する既設の交通監視カメラを利用して湿潤状態の検知を試みた研究は少ない。交通監視カメラにて路面の画像を得て、機械学習による画像分類手法を利用して湿潤状態を自動的に判別する仕組みの構築を試みた。

Identification of wet pavement by machine learning using camera data

Mitsuhiro Hattori*¹ Takashi Oguchi*² Takuya Koyama*³

Department of Civil Engineering, School of Engineering, The University of Tokyo*¹

Institute of Industrial Science, The University of Tokyo*²

Maintenance and Traffic Management Department, Metropolitan Expressway Co., Ltd*³

In rainy conditions, there is a tendency for accidents to increase. Additionally, reduced road friction due to wet conditions can lead to accidents. On the Tokyo Metropolitan Expressway, numerous cameras are installed to monitor traffic. While studies have explored detecting snow and ice through camera images and estimating road conditions using in-vehicle cameras, few studies have specifically focused on detecting wet pavement conditions using existing traffic surveillance cameras. This research aims to develop a system that uses images captured by traffic cameras and applies machine learning-based image classification techniques to identify wet road conditions automatically.

Keyword: Wet pavement, Machine learning, Camera image

1. はじめに

雨天時の高速道路走行は、ドライバーにとって注意が必要である。雨が降ると路面が湿潤状態になり、路面摩擦係数が低下する。これにより車両の安定性

が損なわれ、特に高速走行中に滑りやすくなる。また、視界不良や制動距離の増加も事故リスクを高める要因である。首都高速道路株式会社の調べによれば、雨天時の事故発生率は晴天時に比べて死傷事故

が約4倍、施設接触事故は約7倍に増加している。

ドライバーは、雨天時には速度を落とし、前方との十分な距離を確保することが重要であり、首都高速道路では、雨天時の高速道路走行における危険性を回避するため、注意喚起、パトロール体制の強化等のさまざまな対策を講じている。

雨天と路面湿潤の発生状況の把握は、道路管理において重要であり、コネクテッドカーなどのICT端末としての機能を有する車両には個別の車両に路面状況を提供することで適切に車両制御をすることにもつながる。さらに、事故発生時のより容易で精度の良い路面状態の記録も重要である。

一方で、首都高速道路では、事故・車両故障・落下物処理や交通流状況把握のため、交通管制員がCCTVカメラによる監視を行っている。このCCTVカメラは2,600台以上設置されておりこれらのカメラによって車両や施設、落下物とともに路面状況の把握が可能になる。

本稿では、交通監視カメラ画像を利用して路面の湿潤状態の検知とその精度向上の取り組みについて報告する。

2. 既往研究と本取り組みの位置づけ

カメラ画像の利用により路面の状態を把握する取り組みは、乾燥湿潤の判別や冬季の積雪・凍結の把握、舗装の損傷検知などを目的として実施されてきた。特に路面湿潤の検知に関して、次の取り組みがある。

上田ら¹⁾は湿潤路面の偏光特性の変化に着目して路面の湿潤検知を試みている。自然光が安定的に得られる環境では検出可能とした一方で、建物の影などの自然光が変化する領域に課題を残している。Šabanovićら²⁾は車載カメラの画像から路面状態を推定し、さらに車両の車輪スリップ率を測定し路面

状態と照合した摩擦係数の変化を得ている。舗装はアスファルト、石畳、砂利の3種類とし、状態は乾いた(Dry)状態と濡れている(Wet)状態の2種類としている。乾燥アスファルトの的中率は87.0%、湿潤アスファルトの的中率は95.5%である。

Morrisら³⁾は機械学習を利用して舗装状態の推定を試みた。米国の複数州の道路を撮影したカメラの画像を基にしており9月から11月までの期間の日中を対象としている。乾いた(Dry)状態と濡れている(Wet)状態の2分類の検出を目標として、92.7%の分類精度(的中率)を得ている。

既往研究では、車載カメラや道路脇の固定されたカメラを利用した手法の開発が進められている。一方で、実際の首都高速道路上のカメラは事故・車両故障・落下物処理や交通流状況把握のため、ズームイン/アウト、上下左右の角度変更により画像の取得対象範囲が変わる。さらに、明るさに反応して画像全体の色合いの変化も存在する。

本取り組みでは、上記の様に画像対象範囲や色合いの変化を含んだ運用状態にあるカメラから得られる画像を利用して、路面の湿潤状態の検知を試みている。

3. 利用データ

本取り組みでは、首都高速4号新宿線の三宅坂JCTから外苑出入口までの区間(赤坂S字区間)に設置された4台のCCTVデータを利用した(図1)。設置点はそれぞれ東から弁慶堀、赤坂TN、赤坂西、外苑分流地点である。利用期間は2024年4月9日、14日、20日、21日、22日、23日と9月1日から9月28日までの日付で11時30分から12時30分までの画像データを利用した。4月9日、14日、23日については追加的に13時まで、4月22日については13時30分までとなっている。また、4月21日と4月

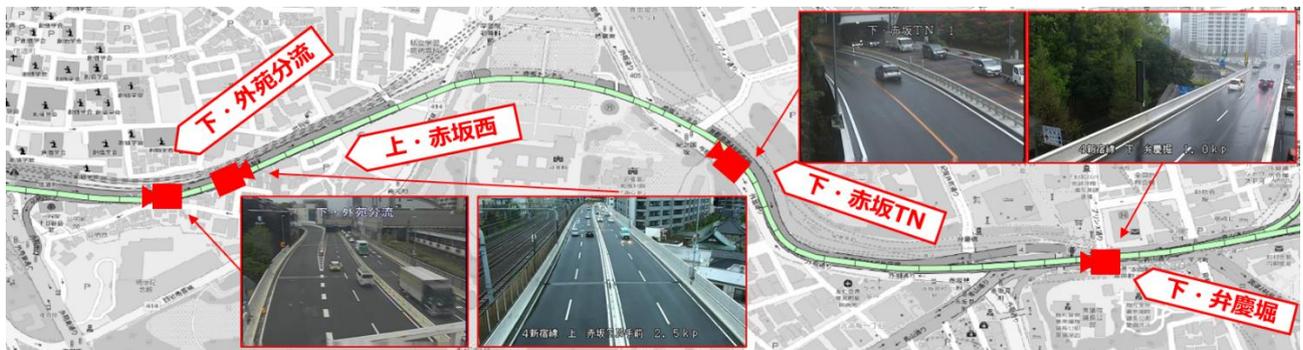


図1 カメラ設置点・地点名と画像サンプル

表 1 学習・検証データとテストデータの整理
(赤坂 TN, 赤坂西, 外苑分流地点)

#	学習・検証データ	テストデータ
Set1	右のテストデータ 以外すべて	2024/04/09 11:30-13:00
Set2	同上	2024/04/14 11:30-13:00
Set3	同上	2024/04/20 11:30-12:30
Set4	同上	2024/04/22 11:30-13:30

表 2 学習・検証データとテストデータの整理
(弁慶堀地点)

#	学習・検証データ	テストデータ
Set1	右のテストデータ 以外すべて	2024/04/22 11:30-13:30
Set2	同上	2024/04/09 11:30-13:00
Set3	同上	2024/04/14 11:30-13:00
Set4	同上	2024/04/20 11:30-12:30
Set5	同上	2024/04/21 11:30-12:30
Set6	同上	2024/04/23 11:30-13:00

23日は弁慶堀の画像のみとなっている。カメラデータは動画データであるため、動画から1分おきの静止画を抽出し、その静止画をデータとして利用している。各地点の学習・検証データとテストデータの組み合わせは表1, 2にまとめた。

本取り組みでは、まず4月の4日から6日分のデータにてモデルの開発を試みた。その後、学習データの増加による精度向上を評価するために追加的に9月のデータを取得して、再度モデル開発と精度評価を実施した。

4. モデル開発とテストデータによる評価

4-1 学習と検証によるモデル開発

本取り組みでは、先行研究³⁾で用いられている、残差ブロックを直列に多数つなげて残差系列をモデル化した、畳み込みニューラルネットワークのモデルである Residual Neural Networks を利用し、ResNet18 (18層モデル) を用いた。このモデルに対して、テスト用に1日分のデータを残して、それ以外のデータを学習・検証用とし、テスト用のデータにて精度評価した。学習データと検証データの割合は80%と20%である。学習のためのエポック数は5とした。分類層は乾燥・湿潤2クラスとして、それぞれの画像に乾燥・湿潤をラベル付けしている。ラベル付けは対象となるすべての画像に実施してお

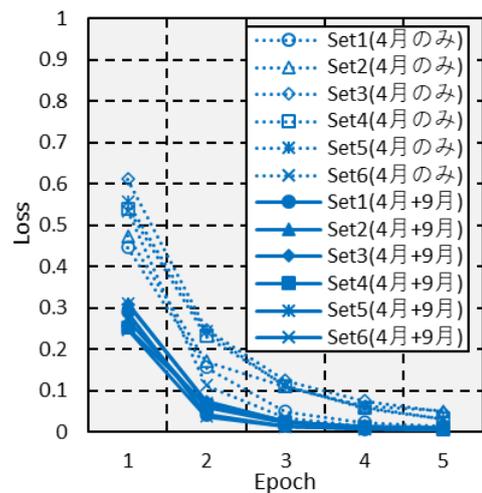


図 2 交差エントロピー損失
4月事例及び9月事例の利用 (弁慶堀地点)

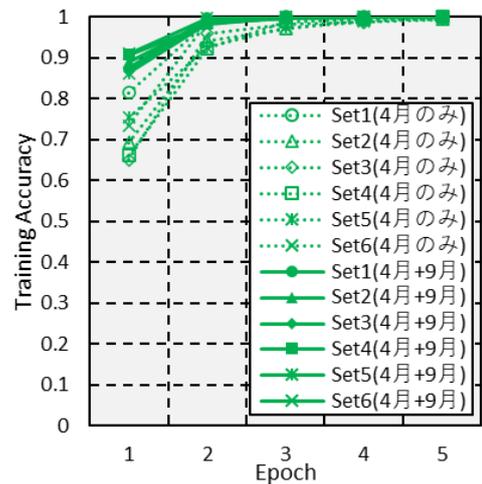


図 3 学習データの分類精度
4月事例及び9月事例の利用 (弁慶堀地点)

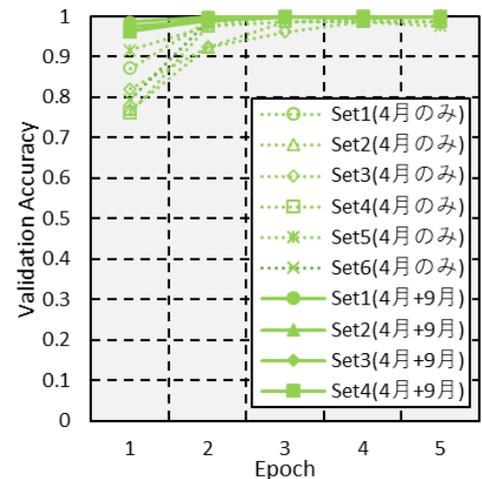


図 4 検証データを用いた分類精度
4月事例及び9月事例の利用 (弁慶堀地点)

り、降雨の気象状況を近傍のアメダス（東京地点）とレーダーデータから把握し、さらに画像を見て湿潤状態ラベルとしている。そのため、対象地点が雨域の縁辺に当たる場合や降雨後で乾燥と湿潤状態の判別が容易でない例は精度低下を引き起こす可能性があるため、ラベル付けせず欠測として扱った。

4-2 4月事例の学習・検証とテストの精度評価結果

本取り組みでは、4月に取得された各地点の画像データによって乾燥と湿潤の路面状態を分類する機械学習モデルの構築を試みた。弁慶堀地点における4月の事例のみを利用して構築したモデルの結果を図2から図4の点線で示している。エポックを経るごとに損失関数の出力値である交差エントロピー損失の値は0に近づいている。また、学習データの分類精度と検証データを用いた分類精度はともに1に近づいている。これらの傾向は他の地点でも同様であった。

4月事例の各Setにおいて、学習と検証を繰り返して作られたモデルをそれぞれ対応するテストデータに適応して精度評価を行った結果が表3から表6の「A: 4月データのみ」列である。乾燥状態の多くの場合で90%以上の結果が得られた一方で、湿潤状態の外苑分流地点と弁慶堀地点では比較的低い精度となっている。外苑分流地点と弁慶堀地点のカメラは他地点と比べてズームイン/アウト、上下左右の角度変更の多い地点であるため、その影響が出たと考えられる。

4-3 9月事例の学習データへの追加

4月事例では外苑分流地点と弁慶堀地点では比較的低い精度となっているが、運用状態にあるカメラにて路面の湿潤を判別するためにはこの部分の精度向上が必要である。そのため、学習・検証に用いる

データ数を増やすことで精度向上を図った。

4月事例の各Setの学習・検証に用いるデータに欠測日を除いた9月の1か月分のデータを追加した。これまでと同様にモデルを構築し、構築したモデルの結果のうち弁慶堀地点に該当するものを図2から図4の実線で示している。損失関数の出力値である交差エントロピー損失の値は4月のデータのみを利用してモデル構築を行った場合と比べて低下してい

表3 テストデータを用いた精度評価結果（赤坂TN地点）

#	乾湿	A: 4月データのみ(%)	B: 4月データ+9月データ(%)	B-A(差)
Set1	湿	100.0	100.0	0.0
Set2	乾	100.0	100.0	0.0
Set3	乾	91.8	100.0	8.2
Set4	湿	14.3	86.8	72.5

* 乾湿列はテストデータの路面状態を表す(以下、同様)

表4 テストデータを用いた精度評価結果（赤坂西）

#	乾湿	A: 4月データのみ(%)	B: 4月データ+9月データ(%)	B-A(差)
Set1	湿	100.0	100.0	0.0
Set2	乾	100.0	100.0	0.0
Set3	乾	96.7	100.0	3.3
Set4	湿	57.8	100.0	42.2

表5 テストデータを用いた精度評価結果（外苑分流）

#	乾湿	A: 4月データのみ(%)	B: 4月データ+9月データ(%)	B-A(差)
Set1	湿	23.1	83.5	60.4
Set2	乾	100.0	100.0	0.0
Set3	乾	98.3	98.3	0.0
Set4	湿	58.2	97.8	39.6

表6 テストデータを用いた精度評価結果（弁慶堀）

#	乾湿	A: 4月データのみ(%)	B: 4月データ+9月データ(%)	C: 4月データ+9月データ+ランダムクローズデータ(%)	B-A(差)	C-B(差)
Set1	湿	0.0	0.0	0.0	0.0	0.0
Set2	湿	0.0	20.0	52.2	20.0	32.2
Set3	乾	96.7	100.0	100.0	3.3	0.0
Set4	乾	85.0	100.0	100.0	15.0	0.0
Set5	乾	65.0	100.0	100.0	35.0	0.0
Set6	乾	0.0	0.0	3.3	0.0	3.3

る。また、学習データの分類精度と検証データを用いた分類精度はともに4月のデータのみを利用してモデル構築を行った場合と比べて上昇している。

学習と検証を繰り返して作られたモデルをそれぞれ対応するテストデータに適応して精度評価を行った結果が表3から表6の「B:4月データ+9月データ(%)」列である。赤坂TN, 赤坂西, 外苑分流地点では半分以上の場合で100%, 残りの場合についても大きな精度の向上が見て取れる。一方で、弁慶堀では精度向上が見えたものの、比較的小さな向上である。

4-4 ランダムクロップデータの追加

弁慶堀地点のカメラは他地点と比べてズームイン/アウト, 上下左右の角度変更の多く, ここまでの取り組みにて精度評価値が他の地点と比較して低い。そのため, この地点の画像について, 画像の一部をランダムに切り取るランダムクロップを行うことで, ズームイン/アウト, 上下左右の角度変更に対応した学習を行い更なる精度向上を目指した。ランダムクロップのサイズは元画像の30%から100%までの範囲とした。それぞれの元の画像に対してランダムクロップを1度実施したため, 学習と検証のための画像数は2倍となった。このデータから各地点の画像データによって乾燥と湿潤の路面状態を分類する機械学習モデルの構築を試みた。弁慶堀地点における4月の事例のみを利用して構築したモデルの結果を図5から図7の実線で示している。

学習と検証を繰り返して作られたモデルをそれぞれ対応するテストデータに適応して精度評価を行った結果が表6の「C:4月データ+9月データ+ランダムクロップデータ(%)」列である。ランダムクロップにより精度向上が見えた一方で精度向上が見られない事例が存在する。

5. まとめ

本取り組みは運用状態にある高速道路上のカメラデータを用いて湿潤路面の検知を目指した。特に運用状態にあるカメラはズームイン/アウト, 上下左右の角度変更があり, これまで機械学習の手法による路面状態の判別の取り組みがなかった。ここで示した開発手法は, そのような場合でも有効である可能性を示している。また, 乾燥2事例, 湿潤2事例(弁慶堀のみ乾燥4事例, 湿潤2事例)によるモデル構築では精度が不十分である地点の事例に対して, 学習・検証データの追加による精度向上が見られた。

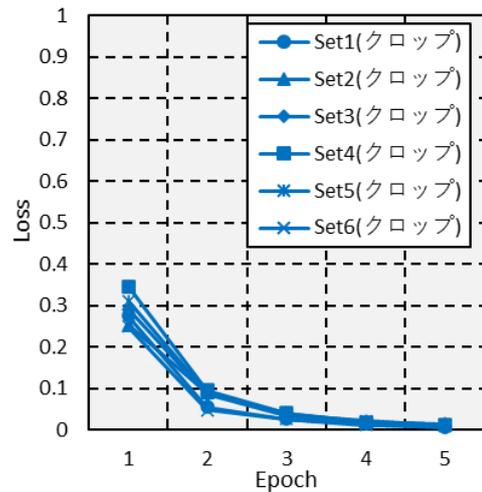


図5 交差エントロピー損失
ランダムクロップデータの追加 (弁慶堀地点)

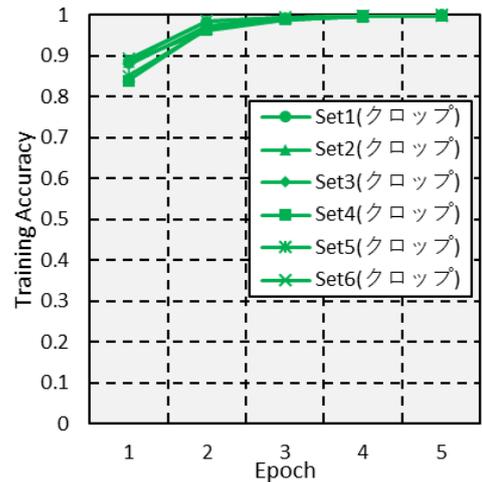


図6 学習データの分類精度
ランダムクロップデータの追加 (弁慶堀地点)

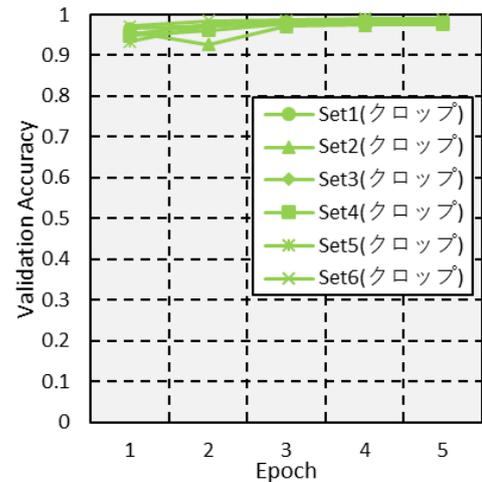


図7 検証データを用いた分類精度
ランダムクロップデータの追加 (弁慶堀地点)

さらに、弁慶堀の例にみられるように精度が不十分である地点の精度向上のために、ランダムに画像の一部を切り出すランダムクロップを行った。一部事例に改善が見られ手法が有効であることが示唆される。しかし、精度が向上しない事例もあることから更なる改良が必要である。

一方で、今後の精度向上と現場への応用に向けてより多くの地点にて同様の取り組みを実施することが望ましい。さらに、本取り組みとその応用によって開発された手法を用いて、湿潤路面の判別を実施したのちに、路面状態と路面状態に関連する気象要素の関係をモデル化することも検討できる。これにより、カメラのない地域にて同様の舗装状態における湿潤路面の推定手法を開発することが可能である。

謝辞：本取り組みに用いたカメラデータは首都高速道路株式会社のご厚意により、データを共有いただいた。加えて、開発にあたってご助言をいただいた。また、東京大学生産研究所大石研究室の皆様にごデータの受け渡しや研究を進めるにあたってご助言をいただいた。関係者の皆様に謝意を表す。

参考文献

- 1) 上田浩次, 堀場勇夫, 池谷和夫, & 大井史倫. (1994). 画像処理を用いた路面湿潤状況検出方式. 情報処理学会論文誌, 35(6), 1072-1080.
- 2) Šabanovič, E., Žuraulis, V., Prentkovskis, O., & Skrickij, V. (2020). Identification of road-surface type using deep neural networks for friction coefficient estimation. *Sensors*, 20(3), 612.
- 3) Morris, C., & Yang, J. J. (2021). A machine learning model pipeline for detecting wet pavement condition from live scenes of traffic cameras. *Machine Learning with Applications*, 5, 100070.