

深層学習を用いた冬期路面すべり摩擦係数推定技術に関する基礎的検討

齊田 光, 大廣 智則*1

1. 研究の背景および目的

冬期の安全・快適な道路交通を維持する上で、路面のすべりやすさを把握することは重要である。例えば、道路管理者が路面すべりやすさを正確に把握できるようになれば、冬期のスリップ事故や車両スタックに起因する大規模な渋滞等を防止するための対策（除雪、凍結防止剤の散布や道路通行止めの実施）を従来以上に適切かつ効率的に行うことが可能となる。また、道路利用者自らが事前に路面すべりやすさを把握することが出来れば、すべりやすい路面でのスリップ事故回避や雪氷路面における車両の適切な制御などに用いることが可能である。

一方で、既存の路面すべりやすさ計測手法は、冬期道路維持管理作業や道路利用者自身による路面状態の把握に用いるためには解決すべき課題が複数存在する。例えば、路面のすべりやすさを定量的に計測する手法としては振り子式スキッドレジスタンステストを用いた手法¹⁾が広く用いられているが、この手法は機器を路面に設置して計測を行う必要があるため、計測時に交通規制を要するなどの課題を有している。また、このような欠点を解消するための手法としては、計測輪と制動装置を搭載した車両を走行させ、計測輪にのみブレーキをかけることで生じた路面-計測輪間の摩擦力を計測することで、一般車両の通行を妨げることなく路面すべりやすさを計測する手法²⁾が開発されている。近年では広範囲の道路網におけるすべりやすい区間を把握することを目的として、車両進行方向に対して斜めに取り付けられた計測輪に生じる横力から路面すべりやすさを計測する手法³⁾や近赤外光を用いた非接触式の路面雪氷状態計測手法⁴⁾が開発されている。これらの手法は交通規制を行うことなく路面のすべりやすさを精度良く計測することが可能であるが、計測機器が非常に高価（百万円～数千万円）であり、装置の運用にも労力を要する。このように、既存の路面すべりやすさの計測手法は機器の導入・運用に要する費用や労力などの面で改善の余地があり、より安価かつ簡単に路面のすべりやすさを計測する手法が必要とされている。

本研究ではこれらの課題を解決する一手法として、深層学習による画像分類技術を用いて路面すべりやすさを推定可能であるか基礎的な検討を行ったので結果の一部を報告する。

2. 深層学習を用いた路面摩擦係数推定の方法

本研究では、深層学習の一種である Convolutional Neural Network（畳み込みニューラルネットワーク、以下 CNN）による画像分類手法を用いて路面すべり摩擦係数 μ を推定可能であるか検討を行った。CNN による画像分類は畳み込み・プーリング等の処理により入力した画像の特徴量を抽出し、得られた特徴量を用いて入力画像をいくつかのクラスに分類する手法である。本研究で作成した CNN は幅 112×高さ 112 ピクセルの RGB 画像を入力することで路面のすべりやすさを 17 段階（ $\mu < 0.05$, $0.05 \leq \mu < 0.10$, ..., $\mu \geq 0.80$ ）で推定するものである。CNN は一般に推論処理に要する計算量が大きく、スマートフォンのような携帯機器を用いて CNN による推論を行うと推論処理に長時間を要する可能性がある。これは車載カメラ画像を用いたすべりやすい路面の検知のような、リアルタイムな推論処理が要求される用途では好ましくない特徴である。このような理由から、本研究ではリアルタイムな路面すべり摩擦係数の推定を可能とするために、CNN の構造として推論処理が高速かつ予測器のサイズが小さい MobileNet V2⁵⁾を用いた。

上記の CNN を作成するためには、学習用データとして路面すべりやすさの実測データと路面画像データの組が多数必要となる。本研究では、図 1 に示す連続路面すべり抵抗測定装置（Halliday Technology RT3）³⁾およびドライブレコーダー（JAF MEDIA WORKS DD-06 α ）が搭載された路面雪氷状態計測車両を用いて、2018 年度および 2019 年度冬期の北海道札幌市、石狩市、苫小牧市の一般道路および北陸自動車道富山 IC～小矢部砺波 JCT、東海北陸自動車道小矢部砺波 JCT～福光 IC で路面すべりやすさ実測データおよび路面画像データを収集した。その後、これらのデータから生成した学習用データ（日中のデータ数：566,618 個および夜間のデータ数：846,672 個）を用いて CNN の学習を行い、日中または夜間の μ を推定する CNN を生成した。

3. 路面すべり摩擦係数の推定精度検定方法

本研究では、2. で述べた方法で生成した CNN を用いて μ の推定精度検定を行った。 μ の推定精度検定に用いる検定用データには、上記の学習用データとは異なる日時

* 1 国立研究開発法人 土木研究所 寒地土木研究所



図1 路面雪氷状態計測車両

および路面雪氷条件下で収集した路面画像および路面すべりやすさデータ（2019/2/8日中および2020/2/12夜間に一般国道231号 KP0～KP19の上り・下り両方向で得られたデータ）を基に作成したデータを用いた。検定では、路面すべり摩擦係数の実測値 μ_{obs} およびCNNによる推定値 μ_{inf} を比較することで μ_{inf} の推定誤差（二乗平均平方誤差, RMSE）を求めた。なお, CNNの学習および検定は市販PC（CPU：AMD Ryzen Threadripper 3970X×1, GPU：NVIDIA Geforce RTX 2080Ti×1, メモリ：DDR4-3200 16GB×4）を用いて, Python 3.7.7, TensorFlow 2.1.0およびOpenCV 3.4.2で実装したソフトウェアにより行った。

4. 路面すべり摩擦係数の推定精度検定結果および考察

表1は2019/2/8日中および2020/2/12夜間の検定用データをCNNに入力することで得られた μ_{inf} と μ_{obs} の混同行列を示す。なお, 表中各項目の背景色の濃淡は μ_{inf} と μ_{obs} が当該項目の範囲内であったケースの出現回数を示す。 μ_{obs} が0.20から0.30程度（概ね圧雪路面の μ に相当）または0.70から0.80程度（非積雪路面の μ に相当）である場合の μ_{inf} は μ_{obs} と同程度の値となるケースが多く, 本手法を用いると路面のすべりやすさが圧雪路面や非積雪路面に相当する場合においては μ を概ね良好な精度で推定できる可能性があることが分かる。一方で, μ_{obs} が上記の範囲内の値である場合, μ_{inf} が μ_{obs} よりも低い値となるケースも少なからず見られた。

図2は2019/2/8日中の一般国道231号における μ_{obs} （図中●）と μ_{inf} （図中実線）の空間分布を示す。本検定用データ計測時の目視による路面状態は計測起点である北33西2交差点から17～18kmおよび21～22kmの区間では湿潤路面、それ以外の区間では圧雪または凍結路面であり, 湿潤路面区間における μ_{obs} は0.60から0.70程度, 圧雪・凍結路面区間における μ_{obs} は0.15から0.45程度であった。 μ_{inf} の空間分布は概ね μ_{obs} と同様の傾向を示し, 計測起点から17～18kmおよび21～22kmの区間における μ_{inf} は最大で0.80と大きい値となり, その他の区間における μ_{inf} は0.05から

表1 路面すべり摩擦係数推定結果の混同行列

		路面すべり摩擦係数実測値, μ_{obs}																	
		0.00	0.05	0.10	0.15	0.20	0.25	0.30	0.35	0.40	0.45	0.50	0.55	0.60	0.65	0.70	0.75	0.80	0.80-
路面すべり摩擦係数推定値, μ_{inf}	0.00-0.05	2	7	6	9	24	25	4	0	0	0	1	1	0	0	1	0	0	
	0.05-0.10	1	5	3	7	21	19	5	1	0	1	1	0	0	0	2	2	0	
	0.10-0.15	1	0	9	16	58	50	8	1	0	0	0	0	0	1	1	0	1	
	0.15-0.20	1	3	17	41	95	80	14	1	1	0	1	0	0	0	0	2	0	
	0.20-0.25	0	5	7	64	155	179	43	5	1	4	0	0	0	2	4	2	0	
	0.25-0.30	0	1	23	93	260	336	67	9	2	2	0	0	0	1	1	2	1	
	0.30-0.35	0	0	7	51	215	277	33	11	5	4	0	0	0	4	0	2	1	
	0.35-0.40	0	1	1	16	46	63	11	3	4	0	1	0	0	3	0	0	0	
	0.40-0.45	0	0	1	1	13	9	3	2	1	1	0	1	1	1	1	5	1	
	0.45-0.50	0	0	0	3	4	1	6	0	3	3	4	1	1	3	4	4	1	
	0.50-0.55	0	0	0	3	5	5	7	8	8	10	13	8	6	5	3	3	0	
	0.55-0.60	0	0	0	3	2	3	5	8	10	10	17	20	13	10	22	30	5	
	0.60-0.65	0	0	0	1	1	2	3	13	9	10	27	26	28	29	34	56	16	
	0.65-0.70	0	0	1	0	0	1	2	7	13	19	33	57	58	65	87	151	59	
	0.70-0.75	0	0	0	0	0	1	6	7	11	18	31	63	72	99	130	234	86	
	0.75-0.80	0	0	0	0	1	0	0	3	6	14	20	29	39	67	124	231	79	
0.80-	0	0	0	0	0	0	0	2	2	7	13	17	23	26	76	139	56		




図2 2019/2/8 日中の一般国道 231 号における路面すべり摩擦係数の実測値および推定値




図3 2020/2/12 夜間の一般国道 231 号における路面すべり摩擦係数の実測値および推定値




図4 路面すべり摩擦係数の過小評価例
($\mu_{inf}=0.20$, $\mu_{obs}=0.70$)

基に作成した学習用データの数は限られているためであると考える。このため、 μ の推定精度を改善するためにはより多様な路面雪氷条件下で路面画像および路面すべりやすさデータを収集し、学習用データを追加することが必要であると推察される。なお、本ケースの全区間における μ_{inf} のRMSEは0.135、 μ_{obs} と μ_{inf} の差の絶対値が0.125未満であった場合を推定的中としたときの推定的中率は73.1%であった。

図3は2020/2/12夜間の一般国道231号における μ_{obs} (図中●)と μ_{inf} (図中実線)の空間分布を示す。本検定用データの計測時の路面状態は約15km地点では凍結路面、それ以外の区間では湿潤路面であり、凍結路面における μ_{obs} は0.30以下、湿潤路面における μ_{obs} は0.60から0.80程度の値であった。 μ_{inf} は μ_{obs} と同様に大部分の区間で0.80程度の値となったが、計測起点から1~6km区間および16~22km区間などでは μ_{inf} が局所的に0.10から0.35程度まで低下し、 μ_{obs} と比較して大幅に小さくなる現象が見られた。本ケースの全区間における μ_{inf} のRMSEは0.169、 μ_{obs} と μ_{inf} の差の絶対値が0.125未満であった場合を推定的中としたときの推定的中率は63.7%であった。

本ケースで見られた μ_{inf} の局所的な過小評価は、道路照明灯の反射光などが原因の1つになっていると考えられる。一例として、図4に計測起点から約17km地点で発生した

0.30程度であった。一方で、 μ_{inf} は μ_{obs} と比較して値が偏る傾向にあり、計測起点から1~11kmの区間などでは μ_{inf} の大部分が0.10程度または0.30程度のいずれかとなった。この結果は本手法で開発したCNNが μ の細かな変化の検出を不得手としていることを示している。この理由としては、本研究で用いた日中の学習用データの大部分が $\mu=0.10$ 程度の凍結路面、 $\mu=0.30$ 程度の圧雪路面または $\mu=0.50$ 以上の非積雪路面で得られたデータを基に作成されたものであり、それ以外の条件下で得られたデータを

μ の過小評価例を示す。本画像中の図中枠内の領域における μ_{obs} は0.70であったが、同領域の画像を用いて推定された μ_{inf} は0.20であった。図中枠内の領域に映っている路面は道路照明灯により照らされており、同領域の画像の明度は図中左側の雪氷路面における画像の明度と同程度である。このため、CNNによる推論では、入力画像の特徴が雪氷路面に類似していると判別され、その結果 μ_{inf} が低い値になったと推察される。道路照明灯の反射光などが μ の推定に及ぼす影響を軽減するためには、道路照明灯で照らされていない範囲の路面画像をCNNの入力として用いるなどの手法が考えられる。

5. 結論および今後の展望

本研究では、冬期の路面すべりやすさを安価、簡単かつ精度良く推定するために、路面を撮影した画像から深層学習の一手法である畳み込みニューラルネットワークを用いてすべり摩擦係数を推定する手法を開発し、推定精度について基礎的な検証を行った。その結果、本手法を用いることで路面すべり摩擦係数を把握できる可能性があることが示唆された。一方で、本手法では学習用データの偏りや道路照明灯の反射光などの影響などにより路面すべり摩擦係数の推定精度が低下する現象が見られた。今後はより多様な路面雪氷条件下で路面画像および路面すべりやすさ実測値を収集し学習用データの拡充を行うとともに、道路照明灯などの有無によらず精度良く路面すべり摩擦係数を推定する手法の開発を行い、路面すべり摩擦係数の推定精度向上を試みる。併せて、本研究で得られた学習済み深層学習モデルを用いて、スマートフォン等の一般的な情報機器を用いて路面すべりやすさを推定するアプリケーション（図5）の開発および試行運用を行う、道路CCTVカメラで得られた画像から路面すべりやすさの推定を行うシステム（図6）の開発を行うなどにより本研究成果の実用化を目指す。

【参考文献】

- 1) 日本道路協会, 2007: 舗装調査・試験法便覧, [1]-92-[1]-97.
- 2) 舟橋誠, 徳永ロベルト, 高橋尚人, 葛西聡, 2008: 冬期路面のすべり抵抗値計測試験について, 北海道の雪氷, 27, 57-60.
- 3) 舟橋誠, 徳永ロベルト, 浅野基樹, 2007: 連続路面すべり抵抗値測定装置 (RT3) の導入について, 北海道の雪氷, 26, 5-8.
- 4) 中島知幸, 高橋尚人, 舘山一孝, 飯島由美, 2017: 近赤外線およびマイクロ波を用いた着氷モニタリングに関する試験, 雪氷研究大会講演要旨集, p. 99.

- 5) Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, Liang-Chieh Chen, 2018: MobileNetV2: Inverted Residuals and Linear Bottlenecks, Proceedings of the IEEE conference on computer vision and pattern recognition.

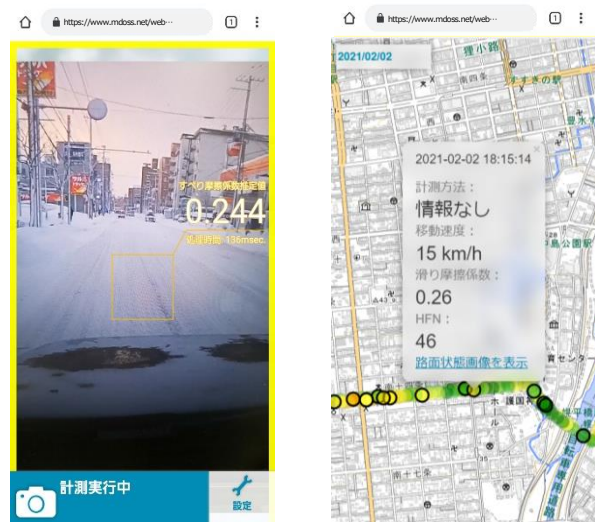


図5 スマートフォン等を用いた路面すべり推定アプリケーション
(左: 路面すべり推定の実施例, 右: 路面すべり推定結果の地図表示例)



国道333号, 北見峠
画像撮影時刻: 2021/03/11 16:20



図6 道路CCTVカメラ画像を用いた路面すべり推定システム