

深層学習を用いた冬期路面すべり摩擦係数推定に関する基礎的検討

Basic Study for Friction Coefficient Inference on Winter Road by Using Deep Learning

齊田 光¹, 徳永 ロベルト², 佐藤 昌哉³

Akira Saida¹, Roberto Tokunaga², Masaya Satou³

Corresponding author: saida-a@ceri.go.jp (A. Saida)

冬期道路管理の効率化やスリップ事故の防止等を実現する上で、路面のすべりやすさを把握することは重要である。本研究では、近年発展が著しい深層学習を用いて車載カメラで撮影した画像から路面すべり摩擦係数を推定可能であるか基礎的な検証を行った。その結果、本研究で提案する手法を用いて冬期の積雪および非積雪路面の路面すべり摩擦係数を概ね良好な精度で推定できる可能性があることを確認した。また、路面すべり摩擦係数の推定をより精度良く行うためには、より多様な路面雪氷条件下で学習用データを多量に収集する必要があること、道路照明灯の反射光の映り込みなどによる影響を考慮した推定手法が必要となることが明らかになった。

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の意思決定支援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⁾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（数百万円～数千万円）かつ大型である。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に改善の余地があり、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

¹ 土木研究所 寒地土木研究所

² 元土木研究所 寒地土木研究所

³ 北海道開発局 札幌開発建設部 Sapporo Development and Construction Departments, Hokkaido Regional Development Bureau

Civil Engineering Research Institute for Cold Region, PWRI

Civil Engineering Research Institute for Cold Region, PWRI (former affiliation)

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 V2⁴⁾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



図 1 路面雪氷状態計測車両

データとは異なる日時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 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

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- -
		0.05	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	
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	

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られる。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 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

本研究では、冬期の路面すべりやすさを安価、簡単かつ精度良く把握するために、深層学習の一手法である CNN (畳み込みニューラルネットワーク) を用いて路面を撮影した画像からすべり摩




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
($\mu_{inf}=0.20$, $\mu_{obs}=0.70$)

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。

【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) 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*.