第65回(2021年度)　北海道開発技術研究発表会論文

AIによる画像認識技術を用いた冬期路面滑り摩擦係数推定手法の開発

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　○齊田　光
同　　大廣　智則
同　　畠山　乃

冬期道路管理の効率的な実施等を推進する上で冬期路面のすべりやすさを把握することは重要であり、より安価な路面すべり計測手法が必要とされている。本研究では、路面画像を用いてAIにより路面すべり摩擦係数を推定する手法を開発し、推定精度検証を行った。その結果、冬期の路面画像を用いて訓練した畳み込みニューラルネットワークと一般的なカメラで撮影した路面画像から路面すべり摩擦係数を推定できる可能性があることが明らかとなった。

キーワード：冬期道路管理、路面すべり摩擦係数、深層学習

1. はじめに

(1) 研究に至る背景

冬期の安全・快適な道路交通を維持する上で、路面雪氷状態、特に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、近年多発している冬期の急激な降雪や気温低下は、スリップに起因する交通事故や大規模な車両立ち往生等の冬期交通障害の主要な原因となっている。多大な損害を発生させるこれらの事象を防止することは道路管理者にとって最も重要な課題の1つである。このため、路面すべりやすさの現況値を把握することは、冬期交通障害を防止するための作業（除雪や凍結防止剤散布等）や道路通行止めの判断を適切に行う上で重要となる。また、路面すべりやすさに関する情報は道路管理者のみならず道路利用者からの需要も存在する。例えば、道路利用者が路面すべりやすさを把握することが出来れば、スリップ事故回避や雪氷路面における車両の制御に用いることが可能である。このような背景から、路面すべりやすさの計測は後述するような様々な手法が提案されている。

(2) 路面すべりやすさの計測手法に関連する既往の研究と課題

路面すべりやすさの計測手法としては定性的な路面雪氷状態（乾燥、圧雪等）の判別結果から路面すべりやすさの概況を推測する手法、および路面のすべり摩擦係数等を定量的に計測する手法が存在する。このうち、定性的な路面雪氷状態は道路管理者等の目視による判別が従来より行われている。一方で、目視による路面雪氷状態の判別精度は、判別を行う者の主観や経験、天候等の影響を受けて変化することが明らかとなっている [1]。このような問題を解決する手法としては、人の判断を介さない路面雪氷状態の判別手法が提案されている。例えば、佐野はCCTVカメラで撮影された画像から路面の積雪の有無や雪氷に覆われていない領域の割合を計測する手法を提案している [2]。また、花塚らは車両のタイヤ内側に取り付けた加速度センサによりタイヤに生じる振動を計測し、振動の特徴から路面雪氷状態を7種に判別する手法を提案した [3]。近年では李らにより、深層学習を用いて車載カメラ画像から路面雪氷状態を推定する手法も提案されている [4]。このように、定性的な路面雪氷状態は手法によっては安価かつ容易に判別することが可能である。しかしながら、これらの手法で判別された路面雪氷状態から路面すべりやすさを正確に推定することは必ずしも容易ではない。例えば既往の研究では、シャーベット路面における路面すべり摩擦係数μは路面雪氷層の厚さや含氷率等の影響により0.2未満から0.8以上と非常に広い範囲の値をとるため、定性的な路面雪氷状態とμを関連付けることは困難であることが報告されている [1]。

一方で、路面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タを用いた手法 [5]が広く用いられているほか、車両の急制動時に生じる加速度を計測する手法 [6]等が提案されている。これらの手法は計測時に交通規制を要するため、冬期道路管理等への活用を目的とした高頻度な路面すべりやすさの計測には不向きである。このような欠点を解消するための手法としては、車両に独立した計測輪と制動装置を搭載し、計測輪にのみブレーキをかけることで生じた路面ー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 [7]が開発されている。

また、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、走行経路上の路面すべりやすさを線的に計測する手法が提案されている。路面すべりやすさの線的計測の手法としては、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 [8]や、複数の波長が異なる近赤外光を路面に照射し、近赤外光の反射率を計測することでμを計測する手法 [9]等が開発されている。これらの手法は定性的な路面雪氷状態判別結果からすべりやすさを推測する手法と比較して精度良く路面のすべりやすさを把握することが可能であるが、計測機器が総じて高価（百万円～数千万円程度）、機器が大型・大重量である、または取扱い方法が複雑である等の理由により、路面すべりやすさの計測に大きな労力を要する等の課題を有している。

以上のように、既存の路面すべりやすさの計測手法は計測精度、計測に要する費用および労力等の点で課題を有しており、高精度、安価かつ簡単に路面すべりやすさを計測する手法が必要とされている。

(3) 研究の目的

本研究は、既存の路面すべりやすさ計測手法が有する課題を解決し、安価、簡単かつ精度良く路面すべりやすさを計測する手法を開発することを目的とする。本論文では、

1) 深層学習を用いて、路面を撮影した画像からμを推定する手法を提案する
2) 上記手法によって得られたμ推定値と既存の路面すべり計測装置によるμ実測値を比較することで、提案手法の路面すべり摩擦係数推定精度を確認する
3) 本論文で提案する手法によって、冬期道路管理等の現場で利用可能な情報機器（スマートフォン等）および一般的なWebサーバ等を用いてμを推定するシステムを構築および運用することが可能か、基礎的な検討を行う

ことを目的とする。

2. 深層学習による路面すべり摩擦係数推定手法

本研究ではμの推定手法として、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り、路面評価分野では前述した李らによる定性的な路面雪氷状態の判別 [4]や全らによる舗装ひび割れ率の評価 [10]等で用いられている。本論文ではこれらの既往の研究を参考としつつ、μを精度良く高速に推定する手法を提案する。

本研究で提案するμ推定手法の概要を図-1 に示す。本手法では、車載カメラ等で撮影した画像のうちμの推定を行いたい小領域を切り出し、切り出した画像を学習済み CNN に入力することでμを推定する。

上記の手法を実現するためには、 CNN の学習を行うためのデータ（学習用データ）を多数用意し、未学習の CNN に学習用データを入力することで CNN の学習を行う必要がある。以下に本手法で用いた学習用データおよび CNN の詳細を示す。

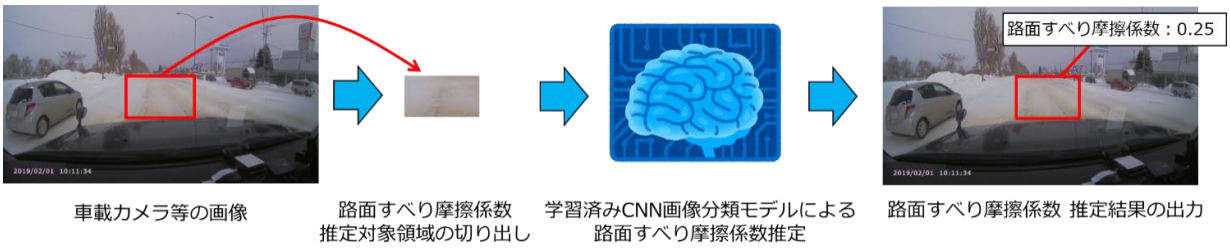

図-1 深層学習を用いた画像分類による路面すべり摩擦係数推定手法の概要

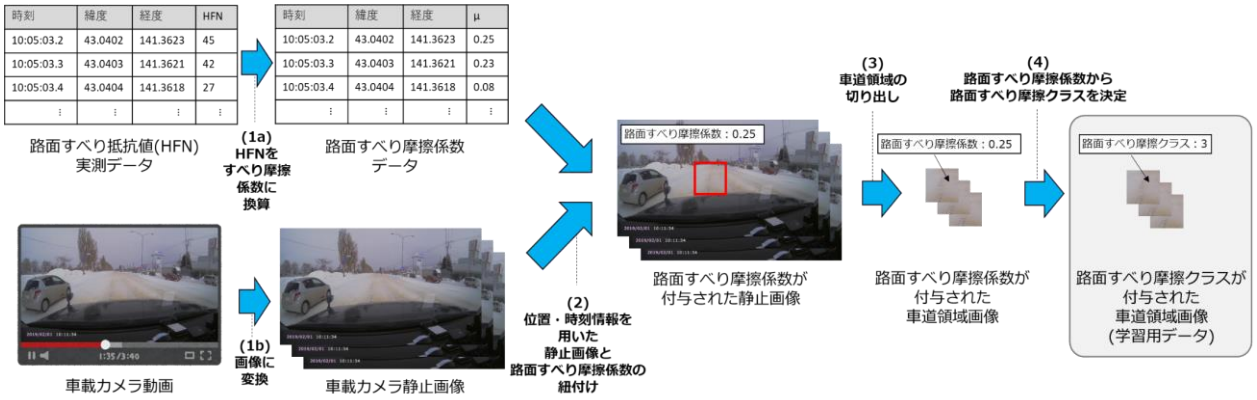

図-2 学習用データ生成方法の概要

図-3　路面雪氷状態計測車両

(1)　CNNの学習に用いるデータの概要

図-2はCNNの学習に用いるデータの生成方法を示す。本手法では、図-3に示す路面雪氷状態計測車両を用いて収集された路面すべり抵抗値（HFN）および路面画像とこれらの計測位置・計測時刻を用いて学習用データを生成する。HFNは計測車両後部に取り付けられた連続路面すべり抵抗測定装置（Halliday Technology RT3）[8]を用いて計測する。連続路面すべり抵抗測定装置は車両進行方向に対して数度傾いた状態で車両に固定された計測輪を有し、走行中に計測輪に生じる横力を測定することで走行区間のHFNを毎秒10回計測する。連続路面すべり抵抗測定装置により計測されたHFNは計測機器独自の指標であるため、路面すべり計測機器間の計測値を比較した結果[8]を用いてHFNを路面すべり摩擦係数計測値μ_{obs}に換算する（図-2 (1a)）。同時に、計測車両のフロントガラスに固定されたドライブレコーダー（JAF MEDIA WORKS DD-06α、水平画角110度、垂直画角60度、最低検知照度1lx）を用いて車両前方の画像を1920×1080ピクセル、毎秒27フレームで記録し、得られたH.264 AVI形式の動画を撮影間隔0.1秒毎の静止画像に変換する（図-2 (1b)）。その後、μ_{obs}と路面画像データの計測位置および時刻情報を用いてμ_{obs}と画像の紐付けを行う（図-2 (2)）。このようにして得られた静止画像には路面以外の領域も含まれているため、静止画像から計測車両の前照灯によって路面が照らされる領域（計測車両から5m前方の幅2.5m×奥行き5m程度の領域、幅224ピクセル×高さ112ピクセル）を切り出す（図-2 (3)）。最後に、画像をμ_{obs}に応じた8つのクラスC_{obs}（C_{obs} =1： μ_{obs} <0.10、C_{obs} =2：0.10≦μ_{obs} <0.20、…、C_{obs} =8：μ_{obs} ≧0.70）に分類し、C_{obs}を画像に付与する（図-2 (4)）。この処理により、路面画像にμに関する情報が付与された学習用データを多数生成する。

なお、本手法ではμ_{obs}の信頼性が低くなる条件で得られたデータ（計測車両の走行速度が 20km/h 以下または計測車両のステアリング角度が 15 度以上であるデータ）を除外して学習用データを生成した。また、路面画像に車両やワイパー等が映り込んだデータは除外せず学習用データとして用いた。

(2)　路面すべり摩擦係数推定に用いたCNNの概要

本研究では冬期道路管理の現場で安価かつ容易に路面すべりやすさを計測する手法を開発することを目的としている。この目的を達成するためには、一般に広く普及している車載可能な情報機器で高速に推論処理が可能な学習済みCNNを生成する必要がある。このため、本研究では推論処理が高速かつ予測器のサイズが小さいMobileNet V2[11]をμ推定のためのCNNとして用いる。本研究で提案する手法では、2.(1)で生成した路面画像およびC_{obs}を学習用データとしてCNNに入力する。これにより、入力画像をμに応じた8つのクラスC_{inf}（C_{inf} =1：μ <0.10、C_{inf} =2：0.10≦μ <0.20、…、C_{inf} =8：μ ≧0.70）に分類する学習済みCNNを作成する。その後、本手法では路面すべり摩擦係数推定値μ_{inf}を求める。学習済みCNNの出力値にはC_{inf}の分類確率p_iが含まれているため、C_{inf}のクラスiのμ中央値μ_iとp_iを用いてμ_{inf}を以下の式で求める。

$$\mu_{inf} = \sum_{i=1}^{8} \mu_i p_i \qquad (1)$$

なお、μ≧0.7 となるクラスのμ_iはμ_{obs}の収集結果より 0.8 とした。また、CNN の学習率は 2.0×10^{-6} とし、最適化関数は Adam を用いた。

3.　路面すべり摩擦係数の推定精度検定および推定処理時間検証の方法

本研究では、前章に示す方法で日中（7時台～16時台）および夜間（0時台～6時台および17時台～23時台）のμの推定を行うCNNをそれぞれ生成し、CNNによるμの推定精度検定を行った。CNNの学習用データは、北海道札幌市、石狩市および苫小牧市の一般道路と北陸自動車道富山IC～東海北陸自動車道福光IC間で2018年度から2020年度の冬期に2. (1)で述べた方法で収集したデータを用いた（日中のデータ数：927,199個、夜間のデータ数：1,110,073個）。その後、学習用データ数を増やすために上記データのうち画像切り出し位置を左右および上方向に32ピクセルずらした学習用データを生成した。CNNの学習では、これらの学習用データのうち80%をCNNの訓練に、20%をCNNの検証に用いた。

生成した学習済みCNNによるμ推定精度の検定では、上記の学習用データと異なる日時および路面雪氷状態で収集された画像およびμ_{obs}を基に、2.(1)で示す方法で作成した検定用データを用いた。日中のμ推定用CNNの精度検定には2019/2/8の日中に一般国道231号 北33西2交差点～八幡2丁目（区間長19.2km）の往路および復路で収

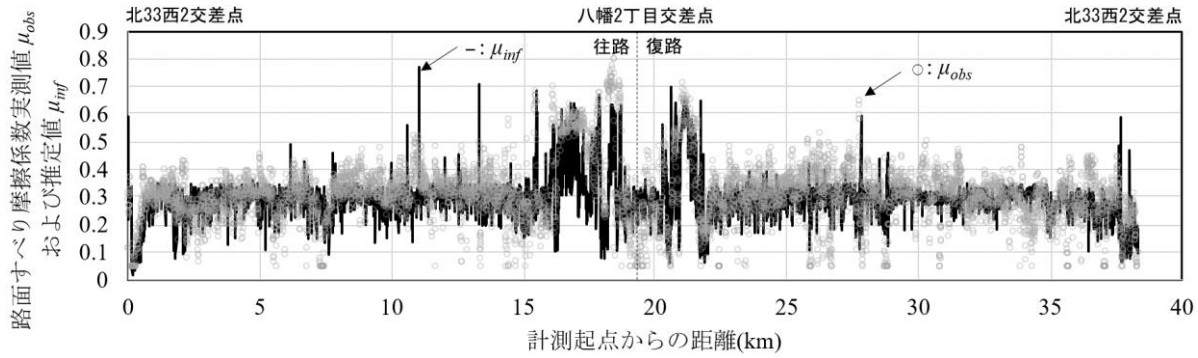

図-4　2019/2/8 日中の一般国道 231 号 KP0～KP19 における路面すべり摩擦係数実測値と推定値の路線縦断方向空間分布

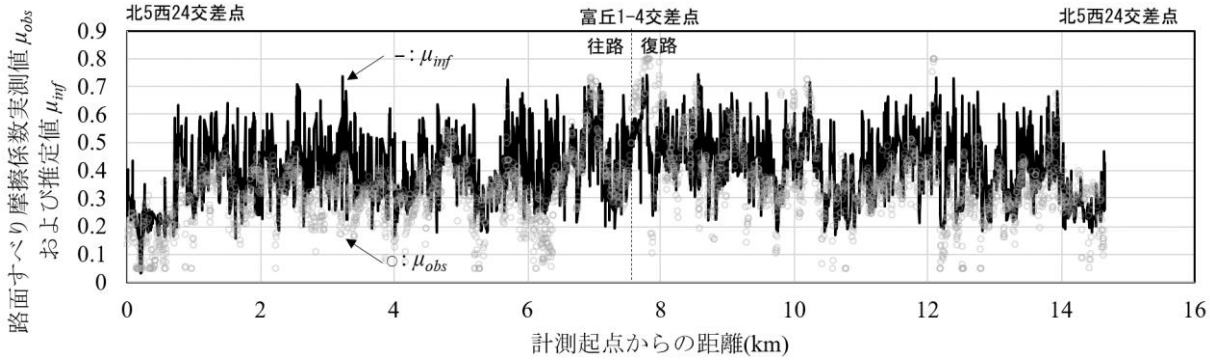

図-5　2021/1/12 夜間の二十四軒・手稲通における路面すべり摩擦係数実測値と推定値の路線縦断方向空間分布

集されたデータ（μ実測データ数：7,007）を、夜間のμ推定用CNNの精度検定には2021/1/12に札幌市二十四軒・手稲通 北5西24交差点～富丘1-4交差点（区間長7.7km）の往路および復路で収集されたデータ（μ実測データ数：3,189）をそれぞれ用いた。CNNの学習および検定は市販 PC（CPU：AMD Ryzen Threadripper 3970X×1、GPU：NVIDIA Geforce RTX 3090×1、メモリ：DDR4-3200 16GB×4）を用いて、Python 3.8.8、TensorFlow 2.4.0およびOpenCV 4.0.1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および推定処理時間検証の結果

図-4は2019/2/8日中の湿潤、圧雪および凍結路面下において一般国道231号で計測したμ_{obs}（図中○）とμ_{inf}（図中実線）の路線縦断方向の空間分布を示す。本検定用データの計測時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（石狩河口橋付近）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}はμ_{obs}と良好に一致し、湿潤路面区間のμ_{inf}は0.30から0.60の値をとった。また、圧雪・凍結路面区間のμ_{inf}は概ね0.25から0.35程度であり、μ_{obs}と比較するとやや狭い範囲の値をとった。一方で、計測区間内に散在するμ_{obs}が0.1未満となった区間ではμ_{inf}は 0.20から0.35程度であり、両者には大きな差が生じた。なお、本ケースにおけるμ_{inf}の二乗平方平均誤差（RMSE）は0.095、平均絶対誤差（MAE）は0.071およびμ推定誤差の標準偏差は0.095であった。

図-5は検定用データのうち、2021/1/12夜間に湿潤およびシャーベット路面下において二十四軒・手稲通で計測したμ_{inf}とμ_{obs}の路線縦断方向の空間分布を示す。μ_{inf}は数百m程度の距離で変動するμ_{obs}の傾向を概ね捉えることができた。他方、μ_{inf}はμ_{obs}と比較して短距離で大きく変動する傾向にあり局所的なμ_{obs}の変化を検出することは出来なかった。本ケースのμ_{inf}のRMSEは0.148、MAEは0.115およびμ推定誤差の標準偏差は0.151であった。なお、2019/2/8日中および2021/1/12夜間の両ケースにおけるμ推定誤差の標準偏差は0.116となった。

なお、既存の路面すべり計測手法のうち、近赤外光を用いた非接触路面すべり計測装置のμ推定誤差の標準偏差は0.10程度である[12]。以上の結果より、本研究で提案するμ推定手法は、特殊な装置を用いることなく、従来の路面すべり計測装置に近い精度でμを推定できる可能性があることが明らかとなった。しかしながら、本検証結果は限られた区間および路面雪氷状態において得られたものであるため、今後はより多様な条件下でμの推定精度を確認する必要がある。

5. 深層学習を用いた路面すべり摩擦係数推定システムの開発

本研究では、2.で述べた手法によりスマートフォン等の携帯端末を用いてμを推定し、推定結果および路面画像を収集・閲覧するためのシステム（路面すべり摩擦係数推定システム）の試作を行った。本システムでは、端末のOS等によらず様々な環境下でμ推定の実施や推定結果の確認を可能とするために、Webブラウザ上で動作するシステムとした。本システムのうちμ推定を行うアプリケーションでは、Webブラウザにビデオ会議や画面共有等の機能を実装するための機能であるWebRTC APIを用いることで、端末のカメラにアクセスし1秒毎に画像を撮影する。その後、Webブラウザ上で動作可能な形式に変換[13]した学習済みモデルに撮影した画像を入力することでμの推定処理を行う。本アプリケーションを用いてμの推定を行う際は、スマートフォン等のカメラが搭載された端末からアプリケーション実行用のURLにアクセスし、μの推定を行いたい箇所に端末のカメラを向ける。これにより、**図-6**のように端末の画面中央枠内に映っている領域のμ推定が行われ、μ推定結果が表示される。また、本アプリケーションで得られたμ推定結果および路面画像は随時Webサーバにアップロードされる。アップロードされたμ推定結果および路面画像はWebサーバ上に構築したデータ集計システムに記録され、**図-7**に示すように道路事務所等の遠隔地からμ推定結果や路面画像を確認することが可能となる。

本研究では、深層学習を用いたμ推定システムを安価かつ簡単に構築可能であるか基礎的な検証を行った。検証では、新旧様々な機種のスマートフォン上でμ推定を行うアプリケーションを実行し実際の端末上でμ推定処理が可能であるか確認するとともに、Webサーバ上にデータ集計システムの構築を行い、同システムの運用試験を行った。

表-1はスマートフォン端末でμ推定を行うアプリケーションを実行したときのμ推定処理に要した時間を示す。なお、本検証ではμ推定処理を10回行い、μ推定処理に要した時間の平均値、最小値および最大値を求めた。μ推定処理に要した時間はスマートフォンの機種により大きく異なるが、2022年時点で発売から5年以上経過した古い端末（iPhone 6s）や廉価な端末（ASUS Zenfone 4 Max）を用いた場合でも200msecから300msec程度の時間でμ推定処理が可能であることが明らかとなった。この結果は60km/hで走行する車両に上記の端末を搭載しμ推定を行った場合、走行経路上のμを概ね3mから5mの間隔で推定可能であることを意味する。また、高性能な端末を用いるとμ推定処理に要する時間は100msec以下となった。この結果は、本手法は車両前方のすべりやすい箇所を検出することで凍結防止剤散布装置等の自動制御を行う等のリアルタイム性が要求される用途にも利用できる可能性があることを示唆している。

図-6 路面すべり摩擦係数推定アプリケーションの実行例

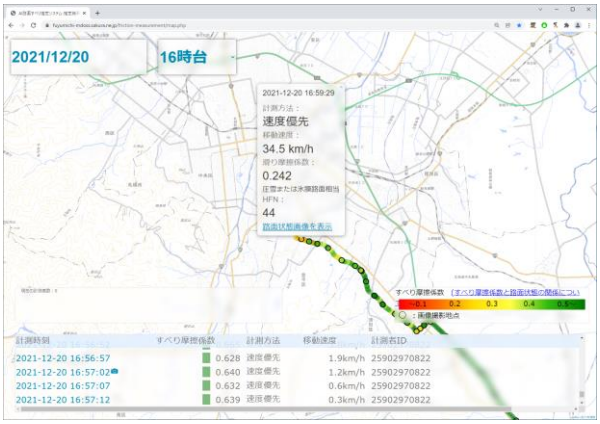

図-7 路面すべり摩擦係数推定結果の閲覧画面

表-1 路面すべり摩擦係数の推定処理に要した時間

使用機器(発売年)	平均推定時間(msec)	最小推定時間(msec)	最大推定時間(msec)
Sony Xperia 1 III (2021)	38	32	47
Samsung Galaxy S9+ (2018)	52	41	79
ASUS Zenfone 4 Max (2017)	241	209	285
Apple iPhone 6s (2016)	172	139	246

また、本検証では路面すべり摩擦係数推定システムを一般的なレンタルWebサーバ（さくらインターネットレンタルサーバ）上に構築し、2021/12/1より運用試験を行

っている。2022/1/14現在における本システムへのアクセス数は最大で約3300件/日、μ推定地点数は最大で約3000地点/日であるが、サーバの過負荷等によるシステム障害等は発生していない。また、本システムで使用しているWebサーバのデータ転送量も、上記レンタルWebサーバの許容転送量（900GB/日）と比較して十分小さく（最大180MB/日）、路面すべり摩擦係数推定システムを安定的に運用可能であることを確認した。

以上の結果より、本研究で開発した路面すべり摩擦係数推定システムを用いると、一般的なスマートフォンやレンタルWebサーバを用いて安価かつ簡単に路面のμ推定やμ推定結果の集計・配信を実現できる可能性があることが明らかとなった。

6. おわりに

本研究では、深層学習を用いて路面を撮影した画像のみから路面すべり摩擦係数を推定する手法を提案した。また、本手法により冬期道路の路面すべり摩擦係数推定を行い、路面すべり摩擦係数の推定精度について検証を行った。さらに、本手法を用いた路面すべり摩擦係数推定システムを試作し、システムの実用性について基礎的な検証を行った。以下に得られた結果を示す。

- 車載カメラにより撮影された画像と連続路面すべり抵抗測定装置による路面すべり実測値を用いてCNNを学習させることで、路面画像のみを入力することで路面すべり摩擦係数を推定する手法を開発した
- 上記手法による路面すべり摩擦係数推定値の二乗平方平均誤差は日中で0.10程度、夜間で0.15程度であり、本手法を用いて路面すべり摩擦係数を推定できる可能性があることが明らかとなった
- 本手法を活用することで、一般的なスマートフォンやWebサーバ等を用いて安価・簡単に路面すべり摩擦係数の推定および推定結果の集計・配信を実現できる可能性があることが明らかとなった

今後はより多様な条件下での路面すべり摩擦係数推定精度の検証を行うとともに、学習用データの追加や学習用データに用いる路面画像の空間分解能改善等による路面すべり摩擦係数推定精度の向上を試みる。

参考文献

1) 徳永ロベルト、舟橋誠、高橋尚人、浅野基樹、中野雅充：連続路面すべり抵抗値による冬期路面管理の高度化に関する研究、寒地土木研究所月報、No. 661、pp. 11-18、 2008.
2) 佐野弘：画像処理による積雪センサーの研究開発、福井県雪対策 建設技術研究所年報、No. 16、pp. 13-22、2003.
3) 花塚泰史、森永啓詩、若尾泰通：センシングテクノロジータイヤによる路面状態判別　～冬季道路管理への活用～、雪氷研究大会講演要旨集、p. 167、2009.
4) 李瑾、阿部雅人、杉崎光一、中村一樹、上石勲：AI技術を活用した冬季道路路面判別の効率化、AI・データサイエンス論文集、Vol. 1、No. J1、pp. 210-216、2020.
5) 日本道路協会：舗装調査・試験法便覧、pp.[1]-92 – [1]-97、2007.
6) 舟橋誠、浅野基樹：加速度計を用いた雪氷路面のすべり摩擦係数の測定、日本雪工学会誌、Vol. 21、No. 2、pp. 116-120、2005.
7) 舟橋誠、徳永ロベルト、高橋尚人、葛西聡：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、No.27、pp.57-60、2008.
8) 舟橋誠、徳永ロベルト、浅野基樹：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、No.26、pp.5-8、2007.
9) 中島知幸、高橋尚人、舘山一孝、飯島由美：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、2017.
10) 全邦釘、井後敦史、南免羅裕治、黒木航汰、大窪和明：車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価、土木学会論文集 E1（舗装工学）、Vol. 73、No. 3（舗装工学論文集第 22 巻）、pp. I_97-I_105、2017.
11) Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, Liang-Chieh Chen : MobileNetV2: Inverted Residuals and Linear Bottlenecks, Proceedings of the IEEE conference on computer vision and pattern recognition, 2018.
12) Teconer Oy:Datasheet of Road Condition Monitor RCM511,https://www.teconer.fi/wp-content/uploads/Road-Condition-Monitor-RCM511-data-sheet_en-1.pdf (2022/1/6 確認)
13) Daniel Smilkov et al. : Tensorflow.js: Machine Learning for the Web and Beyond, arXiv preprint arXiv:1901.05350, 2019.