

# 画像認識技術を活用した雪氷路面の広域計測・予測手法に関する研究

研究予算：運営費交付金

研究期間：令2～令3

担当チーム：寒地交通チーム

研究担当者：佐藤昌哉、島山乃、  
徳永ロベルト、大廣智則、  
齊田光、奥村航太

## 【要旨】

冬期道路管理を効率的に行うにあたり、路面雪氷状態を把握することは重要である。既存の定量的な路面雪氷状態の計測機器は高価であるため、より安価に利用可能な路面雪氷状態把握手法が必要とされている。本研究では、AIと路面画像を用いて安価に路面雪氷状態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、冬期の路面画像および路面すべり実測値を教師データに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雪氷状態を推定できる可能性が高いことが示された。また、本手法により得られた路面雪氷状態を用いて、路面雪氷状態予測計算を補正する手法を開発した。

キーワード：冬期道路管理、路面雪氷状態、路面すべり摩擦係数、深層学習

## 1. はじめに

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、冬期道路管理では気象の局所的な急変などに対応するために速やかな作業実施判断が求められる場面が多い。また、国土交通省の冬期道路交通確保対策検討委員会による「大雪時の道路交通確保対策中間とりまとめ」<sup>1)</sup>では、気象急変時・大雪時などに適切な冬期道路管理を行うために、ICT・AI技術等を活用して路面雪氷状態現況値や短時間予測値を迅速・広範囲に把握する手法の開発が必要であるとされている。以上のように、路面雪氷状態現況値や短時間予測値を的確に把握することの重要性は広く認識されている。

路面雪氷状態の計測手法には、乾燥、圧雪等の定性的な路面雪氷状態を計測する手法、および路面のすべり摩擦係数( $\mu$ )等を定量的に計測する手法が存在する。定性的な路面雪氷状態の把握は道路管理者等の目視判別により行われている。しかしながら、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<sup>2)</sup>。このような問題を解決する手法として、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<sup>3)</sup>。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ー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<sup>4)</sup>。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<sup>5)</sup>。

また、路面雪氷状態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路面すべりやすさの計測手法<sup>6)</sup>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ことで $\mu$ を把握する手法<sup>7)</sup>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—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<sup>8)</sup>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。これには、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<sup>9)</sup>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 $\mu$ を計測する手法<sup>10)</sup>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）であるほか、機器が大型・大重量、または取扱い方法が複雑等の理由により、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。

また、路面雪氷状態の予測では熱収支法や統計的手法などにより路面温度、雪氷の質量や路面滑りやすさ等を予測する手法が提案されており<sup>11)</sup>、これらの予測手法の多くは数時間から1日程度先までの路面雪氷状態を予測可能である。一方、気象条件が急変した場合に正確な路面雪氷状態予測を行うためには路面雪氷状態の現況値を随時入力することで路面雪氷状態の予測結果を補正するなどの処理が必要となる。路面雪氷状態予測に用いるための路面雪氷状態現況値には、道路テレメータによる計測結果が主に用いられている。しかしながら道路テレメータの設置箇所は限られており、例えば北海道内の一般国道における道路テレメータ設置箇所は約120か所である。局所的な気象急変が路面雪氷状態に及ぼす影響を正確に予測するためには、より多くの地点で路面雪氷状態の現況値を把握することが重要となる。

これらの現況を鑑み、本研究では既存の路面雪氷状態計測手法が有する課題を画像認識技術により解決し、路面雪氷状態を広範囲にわたりリアルタイムかつ安価に計測する手法を開発する。また、得られた路面雪氷状態計測値を用いて路面雪氷状態の予測精度向上を行うことを目的とする。

## 2. 深層学習による路面雪氷状態推定手法の開発

### 2.1 路面雪氷状態の推定方法

本研究では路面雪氷状態の推定手法として、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る。

本研究で提案する路面雪氷状態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路面雪氷状態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 に入力することで路面雪氷状態を推定する。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。

#### 2.1.1 CNN の学習に用いるデータの作成方法

図-2はCNNの学習に用いるデータ（以下、学習用データ）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）、路面雪氷状態定性値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）<sup>9)</sup>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<sup>9)</sup>を用いてHFNを路面すべり摩擦係数計測値 $\mu_{obs}$ に換算する（図-2(1a)）。また、路面雪氷状態定性値は計測車両に乗車した計測者が目視で判別を行い、判別結果を車両内のPCに入力する。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-06 $\alpha$ 、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




図-1 深層学習を用いた路面雪氷状態推定手法の概要

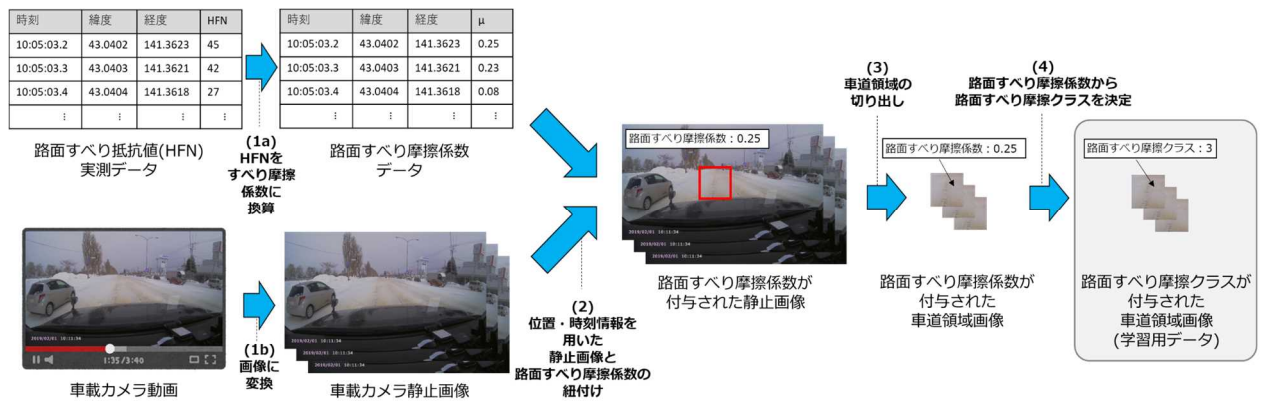


図-2 学習用データの生成方法



図-3 路面雪氷状態計測車両

表-1 路面すべり摩擦係数と画像分類クラスの関係

路面すべり摩擦係数、 $\mu$	画像分類クラス、 $C$
0.10 未満	1
0.10 以上 0.20 未満	2
0.20 以上 0.30 未満	3
0.30 以上 0.40 未満	4
0.40 以上 0.50 未満	5
0.50 以上 0.60 未満	6
0.60 以上 0.70 未満	7
0.70 以上	8

影間隔 0.1 秒毎の静止画像に変換する (図-2(1b))。その後、位置情報および時刻情報を用いて路面画像の撮影地点と $\mu_{obs}$ の計測位置が同一地点となるように調整を行い、 $\mu_{obs}$ 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 $\mu_{obs}$ に応じた 8 つのクラス $C_{obs}$  (表-1 参照) 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 $\mu$ に関する情報および路面雪氷状態定性値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 $\mu_{obs}$ の信頼性が低くなる条件で得られたデータ<sup>12)</sup> (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。

### 2.1.2 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学習済みモデルのパラメータ数が小さいMobileNet V2<sup>13)</sup>を $\mu$ 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、2.1.1に示した手法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 $\mu$ に応じた8つのクラス $C_{inf}$  (表-1参照) 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 $\mu_{inf}$ 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 $\mu$ 中央値 $\mu_i$ と $p_i$ を用いて $\mu_{inf}$ を以下の式で求める。

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

なお、 $\mu \geq 0.7$  となるクラスの $\mu$ 、 $\mu_8$ は 2.2.1 で述べる $\mu_{obs}$ の計測結果のうち $\mu_{obs} \geq 0.7$  である計測結果の平均値を用いて $\mu_8 = 0.8$ とした。

## 2.2 路面雪氷状態の推定精度検証

### 2.2.1 推定精度の検証方法

本研究では、2.1に示す方法で日中 (7時台~16時台)




図-4 平成31年2月8日 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 令和3年1月12日 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

および夜間（0時台～6時台および17時台～23時台）の $\mu$ 推定を行うCNNをそれぞれ生成し、CNNによる $\mu$ 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間で平成30年度から令和2年度の冬期に2.1.1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 $\mu$ 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 $\mu_{obs}$ 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 $\mu$ 推定用CNNの精度検定には平成31年2月8日の日中に一般国道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集されたデータ（ $\mu$ 実測データ数：7,007）を、夜間の $\mu$ 推定用CNNの精度検定には令和3年1月12日に札幌市二十四軒・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（ $\mu$ 実測データ数：3,189）をそれぞれ用いた。CNNの学習および検証は、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。

## 2.2.2 推定精度の検証結果

図-4は平成31年2月8日日中の湿潤、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 $\mu_{obs}$ （図中○）と $\mu_{inf}$ （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一部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 $\mu_{obs}$ は0.60から0.70程度、圧雪・凍結路面区間における $\mu_{obs}$ は0.15から0.45程度であった。 $\mu_{inf}$ は $\mu_{obs}$ と良好に一致し、湿潤路面区間の $\mu_{inf}$ は0.30から0.60の値をとった。また、圧雪・凍結路面区間の $\mu_{inf}$ は概ね0.25から0.35程度であり、 $\mu_{obs}$ 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 $\mu_{obs}$ が0.1未満となった区間では $\mu_{inf}$ は0.20から0.35程度であり、すべりやすい路面を的確に捉えることができなかった。なお、本ケースにおける $\mu_{inf}$ 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 $\mu$ 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、令和3年1月12日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 $\mu_{inf}$ と $\mu_{obs}$ の路線縦断方向の空間分布を示す。 $\mu_{inf}$ は $\mu_{obs}$ と比較して大きく変動する傾向にあり、 $\mu_{obs}$ の空間分布を正確に捉えることは出来なかった。この原因としては、夜間のシャーベット路面において収集された学習用データの数が少なく、シャーベット路面となっていた区間で $\mu$ 推定精度が低下したためと推察される。本ケースの $\mu_{inf}$ のRMSEは0.148、MAEは0.115および $\mu$ 推定誤差の標準偏差は0.151であった。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 $\mu$ 推定誤差の標準偏差は0.10程度である<sup>14)</sup>。

以上の結果より、本研究で提案する $\mu$ 推定手法は、日中においては従来の路面すべり計測装置に近い精度で $\mu$ を推定できる可能性があることが明らかとなった。また、夜間は学習用データセットの数が少ないシャーベット路面において $\mu$ 推定精度が低下することが分かった。なお、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 $\mu$ の推定精度を確認する必要がある。

### 3. 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 $\mu$ 推定を行うシステム（路面すべり摩擦係数推定システム）の試作を行った。本システムは、専門的な知識がなくとも容易に利用可能で、かつ端末のOS等によらず様々な環境下で動作できるようにするために、Webブラウザ上で動作するシステムを構築した。本システムでは、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<sup>15)</sup>した学習済みモデルに撮影した画像を入力することで $\mu$ 推定処理を行う。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 $\mu$ 推定が行われ、 $\mu$ 推定結果が表示される。

本研究では、深層学習を用いた $\mu$ 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 of スマートフォン上で $\mu$ 推定を行うアプリケーションを実行し実際の端末上で $\mu$ 推定処理が可能であるか確認した。

表-2 は各スマートフォン端末で $\mu$ 推定を行うアプリケーションを実行したときの $\mu$ 推定処理に要した時間



図-6 路面すべり摩擦係数推定システムの実行例

表-2 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

を示す。なお、本検証では $\mu$ 推定処理を10回行い、 $\mu$ 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。 $\mu$ 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、令和4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 $\mu$ 推定処理が可能である。この結果は60km/hで走行する車両に上記の端末を搭載し $\mu$ 推定を行った場合、走行経路上の $\mu$ 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 $\mu$ 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ことを示唆している。

#### 4. 深層学習による路面雪氷状態推定値を用いた路面雪氷状態予測精度の向上技術の開発

本研究では、2. で開発した路面雪氷状態推定手法を用いて路面雪氷状態の予測計算に用いる初期値（路面温度  $T_s$ 、路面の積雪状況等の初期条件）を補正することで、路面雪氷状態予測計算の精度向上を試みた。以下に詳細を示す。

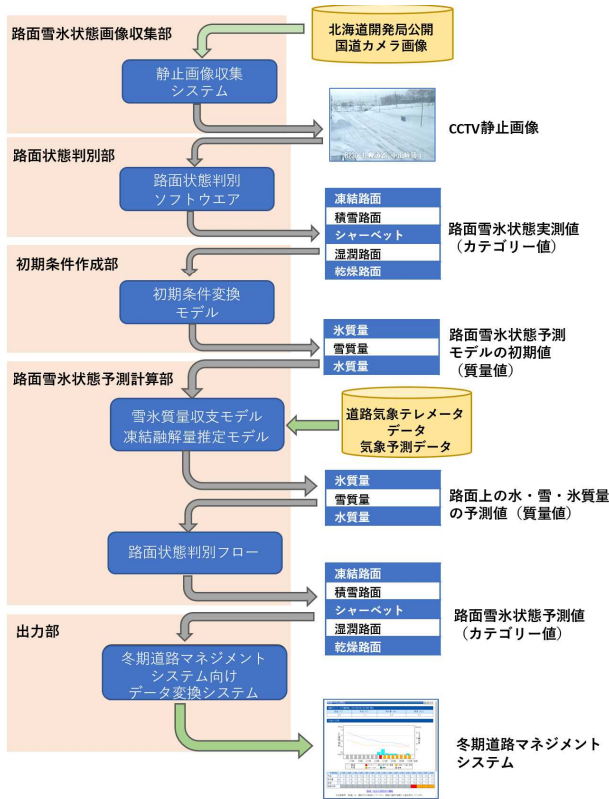


図-7 路面雪氷状態予測モデルの概要

下に詳細を示す。

#### 4.1 路面雪氷状態予測計算の初期値補正手法

図-7は本研究で改良した路面雪氷状態予測モデルの概要を示す。本研究では、路面雪氷状態予測計算の初期値を補正するために、路面雪氷状態予測モデルに路面雪氷状態画像収集部、路面状態判別部および初期条件作成部を追加した。

路面雪氷状態画像収集部はCCTVカメラで撮影された路面画像を収集するシステムから成り、得られた路面画像は路面状態判別収集部の入力値として用いられる。路面状態判別部は2. で提案した手法を基に開発した路面画像から $\mu$ を推定するソフトウェア、および路面画像から定性的な路面雪氷状態（乾燥、積雪、凍結等）を判別するソフトウェアから成る。なお、定性的な路面雪氷状態の判別には、北海道内の冬期道路で得られた路面雪氷状態判別結果と路面画像を学習用データとして生成した画像分類モデル<sup>16)</sup>を用いた。初




図-8 シャーベット路面における路面すべり摩擦係数と雪・氷・水質量の関係

表-3 路面すべり摩擦係数および定性的な路面雪氷状態の推定値と路面の水・雪・氷質量の初期条件の関係

水・雪・氷質量 (kg/m <sup>2</sup> )	定性的な路面雪氷状態の推定結果				
	乾燥	湿潤	シャーベット	積雪	凍結
水質量 $M_w$	0.00	1.80	0.12~1.20	0.00	0.00
雪質量 $M_s$	0.00	0.00	0.12~1.20	2.40	0.00
氷質量 $M_i$	0.00	0.00	0.00~2.26	0.00	2.80

表-4 定性的な路面雪氷状態の推定値を用いた路面温度の補正方法

定性的な路面雪氷状態の推定結果	路面温度 $T_s$ の補正	
	$T_s > 0^\circ\text{C}$ の場合	$T_s < 0^\circ\text{C}$ の場合
乾燥	補正なし	補正なし
湿潤	補正なし	$T_s = 0^\circ\text{C}$
シャーベット	$T_s = 0^\circ\text{C}$	補正なし
積雪	$T_s = 0^\circ\text{C}$	補正なし
凍結	$T_s = 0^\circ\text{C}$	補正なし

期条件作成部は、路面画像から推定された $\mu$ および定性的な路面雪氷状態を基に、路面雪氷状態の予測計算初期値として用いる路面の水質量 $M_w$ 、雪質量 $M_s$ および氷質量 $M_i$ を算出するモデルから成る。定性的な路面雪氷状態の推定結果と $M_w$ 、 $M_s$ および $M_i$ の関係を表-3に示す。なお、定性的な路面雪氷状態の推定結果がシャーベット路面である場合は、藤本らによる $\mu$ と質量含氷率 $\theta_i$ の関係式<sup>17)</sup>から路面雪氷中の $\theta_i$ を算出し、路面雪氷の全水分質量 $2.4\text{kg/m}^2$ を $\theta_i$ の算出結果を用いて図-8のように $M_w$ 、 $M_s$ および $M_i$ に分配した。また、以上の方法で得られた路面雪氷状態の初期状態を用いて、 $T_s$ の初期値を表-4のように補正した。

#### 4.2 路面雪氷状態予測計算の精度検証

路面雪氷状態予測計算の精度検証は、表-5に示す地点および日時を対象として行った。精度検証では、本研究で開発した手法（以下、「提案手法」）、および図-7のうち路面雪氷状態画像収集部、路面状態判別部および初期条件作成部を使用しない手法<sup>18)</sup>（以下、「従来手法」）を用いて、表-5の各ケースについて計算初期日時から24時間先までの $T_s$ を予測した。その後、精度検証対象地点に設置された道路テレメータによる $T_s$ の計測値を真値として、 $T_s$ の二乗平均平方誤差(RMSE)を求めた。なお、提案手法で用いる路面画像のうち、ケース1からケース6（一般国道12号KP26および一般国道333号KP69）では解像度720x480pxの画像を、ケース7からケース9（一般国道274号KP101）では解像度1920x1080pxの画像を用いて定性的な路面雪氷状態および $\mu$ の推定を行った。

表-6は各ケースについて提案手法および従来手法を用いて $T_s$ を予測した場合のRMSEを示す。提案手法を用いた際の $T_s$ 予測値のRMSEは、従来手法による $T_s$ 予測値のRMSEと比較して小さくなるケース（ケース8）が見られる一方で、ケース5のように提案手法を用いた際の $T_s$ 予測値のRMSEが従来手法に

よる $T_s$ 予測値のRMSEより大きくなる場合もあった。検証対象地点毎の $T_s$ 予測値のRMSEに着目すると、一般国道274号KP101地点では従来手法の $T_s$ 予測値のRMSE平均値は $4.92^\circ\text{C}$ である一方、提案手法の $T_s$ 予測値のRMSE平均値は $4.66^\circ\text{C}$ であり、提案手法を用いることで $T_s$ の予測誤差が小さくなることが明らかとなった。一方で、一般国道333号KP69地点では従来手法の $T_s$ 予測値のRMSE平均値は $4.68^\circ\text{C}$ であったが、提案手法の $T_s$ 予測値のRMSE平均値は $4.84^\circ\text{C}$ となり

表-5 路面雪氷状態予測計算の精度検証対象地点および日時

ケース	地点	初期日時
ケース1	一般国道12号	令和4年1月13日 19:00
ケース2	KP26 (江別太)	令和4年1月28日 15:00
ケース3		令和4年2月16日 15:00
ケース4	一般国道333号	令和4年1月17日 12:00
ケース5	KP69 (旭野)	令和4年1月21日 02:00
ケース6		令和4年1月30日 07:00
ケース7	一般国道274号	令和4年1月27日 18:00
ケース8	KP101 (王古丹)	令和4年1月31日 18:00
ケース9		令和4年2月4日 03:00

表-6 各検証ケースにおける路面温度の予測誤差(°C)

ケース	RMSE (提案手法)	RMSE (従来手法)
ケース1	2.70	2.87
ケース2	1.67	1.76
ケース3	2.83	2.87
ケース4	3.11	2.70
ケース5	3.68	3.22
ケース6	7.74	8.13
ケース7	3.67	3.58
ケース8	6.24	7.18
ケース9	4.06	3.99



図-9 一般国道333号KP69におけるCCTVカメラ画像（左、720x480px）および一般国道274号KP101におけるCCTVカメラ画像（右、1920x1080px）

提案手法による  $T_s$  予測精度の改善効果は見られなかった。両地点において  $T_s$  予測精度の改善効果に差が生じた理由としては、路面雪氷状態予測計算の補正に用いた道路 CCTV 画像の解像度の違いに起因すると推察される。図-9 に示すように、一般国道 333 号 KP69 地点で撮影された CCTV カメラ画像は一般国道 274 号 KP101 地点で撮影された CCTV カメラ画像と比較して解像度が低いため、 $\mu$  の推定精度が低下した可能性がある。以上の結果より、本手法による路面雪氷状態予測計算の精度向上を実現するためには、低解像度の路面画像を用いた場合の  $\mu$  推定精度を向上させるなどの改良が必要であると考えられる。

## 5. まとめ

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冬期の路面すべり摩擦係数を推定する手法、および路面画像から推定された路面すべり摩擦係数等を用いて路面雪氷状態予測計算の精度を向上させる手法を提案した。また、路面画像を用いた冬期道路の路面すべり摩擦係数推定手法の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畳み込みニューラルネットワーク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
- 本研究で開発した路面すべり摩擦係数推定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
- 道路CCTVカメラから得られた路面画像により路面雪氷状態を推定することで、路面雪氷状態の予測計算を補正する手法を開発し、路面温度予測精度の改善効果について検証した。その結

果、高解像度の道路CCTVカメラ画像を用いて路面温度予測計算を補正した場合は路面温度の予測精度が改善する可能性があることが示唆された

- 低解像度の路面画像を用いて路面すべり摩擦係数の推定を行った場合は路面すべり摩擦係数の推定精度が低下する可能性があることが明らかになった

## 参考文献

- 1) 国土交通省冬期道路交通確保対策検討委員会：大雪時の道路交通確保対策中間とりまとめ、  
<https://www.mlit.go.jp/road/ir/ir-council/toukidourokkanri/pdf/t02.pdf> (2022/6/2 確認)
- 2) 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.
- 3) 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.
- 4) 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.
- 5) 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.
- 6) 日本道路協会：舗装調査・試験法便覧、pp.[1]-92-[1]-97、2007.
- 7) 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.
- 8) 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.
- 9) 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.
- 10) 中島知幸、高橋尚人、館山一孝、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.
- 11) 例えば；堀井雅史、福田正：舗装路面凍結システムの構築、土木学会論文集、Vol. 50、No. 669、pp. 243-251、2001.
- 12) 徳永ロベルト、佐藤賢治、齊田光：カーブ区間の路面すべり抵抗計測技術構築について、第 62 回 (平成 30 年



度) 北海道開発技術研究発表会論文集、2019.

- 13) 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.
- 14) Teconer Oy:Datasheet of Road Condition Monitor RCM511,[https://www.teconer.fi/wp-content/uploads/Road-Condition-Monitor-RCM511-datasheet\\_en-1.pdf](https://www.teconer.fi/wp-content/uploads/Road-Condition-Monitor-RCM511-datasheet_en-1.pdf) (2022/1/6 確認)
- 15) Daniel Smilkov et al. : Tensorflow.js: Machine Learning for the Web and Beyond, arXiv preprint arXiv:1901.05350, 2019.
- 16) 齊田光、徳永ロベルト、佐藤昌哉 : 深層学習と車載可能な情報機器を用いた路面雪氷状態定性値の推定手法の開発、土木学会年次学術講演会講演概要集、2021.
- 17) 藤本明宏、渡邊洋、齊田光、福原輝幸 : シャーベット路面のすべり摩擦特性、日本雪工学会誌、Vol.28、No.2、pp.99-106、2012.
- 18) 高橋尚人、徳永ロベルト、浅野基樹、石川信敬 : 冬期路面管理支援システムの構築と運用、寒地土木研究所月報、No. 652、pp.8-17、2007.

# A STUDY OF ROAD SNOW CONDITION ESTIMATION AND PREDICTION FOR WIDE AREA USING IMAGE RECOGNITION TECHNOLOGY

Research Period: FY2020-2021

Research Team: Traffic Engineering Research Team,  
Cold-Region Engineering Research Group

Author: SATOU Masaya,  
TOKUNAGA Roberto,  
SAIDA Akira,  
HATAKEYAMA Osamu,  
OKUMURA Kouta

**Abstract:** It is important to understand road snow and ice condition for efficient winter road maintenance, and there is large demand for easy and inexpensive measurement method of road snow and ice condition. In this study, we developed the method to estimate road snow and ice condition with deep learning and road surface image and verified the accuracy of proposed method. In addition, we developed improved road surface temperature forecast method with estimated road snow and ice condition. As a result, this study clarified that there is high possibility to estimate road snow and ice condition with deep neural network trained with road surface image and observed road snow and ice condition.

**Keywords:** Winter road maintenance, Road snow condition, Road surface friction coefficient, Deep learning.