

機械学習を用いた冬期路面温度予測手法に関する研究

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
大廣 智則
伊東 靖彦

路面雪氷状態に関する予測情報は冬期道路管理の効率的な実施を推進する上で重要であり、より高精度な予測手法が必要とされている。本研究では、機械学習を用いて路面温度を予測する手法を開発し、予測精度および予測計算処理時間の検証を行った。その結果、予測対象時刻の1日程度前までの気象データを用いて訓練した学習済みモデルにより、従来の路面温度予測手法と同等以上の精度で高速に路面温度を予測できることが明らかとなった。

キーワード：冬期道路管理、路面温度予測、機械学習、ランダムフォレスト、LSTM

1. 研究の背景および目的

路面雪氷状態に関する予測情報は、冬期道路管理作業（凍結防止剤散布や除雪など）の作業内容の判断を適切に行う上で重要である。路面雪氷状態を表す指標のうち路面温度は路面凍結リスクの判断に用いられるため、路面温度予測の精度向上が必要とされている。また冬期道路管理の作業内容判断を適切に行うためには、積雪や路面凍結の可能性が高い区間を面的に把握することで効率的な作業方法を決定する必要があるため、広域にわたり路面雪氷状態（路面雪氷の種類や量）を予測する手法が必要である。

路面雪氷状態を予測する手法としては熱収支法¹⁾⁵⁾や統計的手法⁶⁾⁷⁾などが提案されており、例えば寒地土木研究所が開発している路面雪氷状態予測手法は16~24時間先までの路面雪氷状態を予測可能である⁸⁾。一方で、広域にわたる路面雪氷状態を予測するためには路面雪氷状態に大きな影響を及ぼす路面温度の空間分布が予測計算の初期値として必要となる。路面温度の空間分布（サーマルマップ）は計測車両を用いて予測を行いたい区間を複数回走行することで得られるが、この作業を広域にわたる路線網で行うためには多大な費用と時間を要する。

当研究所では上述の課題を解決するために、定点路面雪氷状態予測手法と高解像度気象メッシュデータから生成した統計サーマルマップを組み合わせて路面温度を予測する手法を開発した⁹⁾。当該手法は路面温度を広域かつ安価に予測可能であるが、路面温度の予測誤差は二乗平均平方誤差（RMSE）で2.3℃であり、予測精度の向上が課題となっている。

一方、近年の機械学習や深層学習に関連する技術の発展は著しく、機械学習による予測・分類アルゴリズムの高精度化、機械学習による推論処理を行うハードウェア

の高性能化・低価格化が進んでいる。また、機械学習アルゴリズムの開発を行うためのソフトウェアやライブラリのオープンソース化が同時に進んでいる。このような背景から、路面雪氷状態予測の分野においても、機械学習を活用することで高精度かつ安価に路面雪氷状態を予測する手法を開発できる可能性があると考えられる。

本研究は、機械学習を用いることで安価かつ高精度に路面雪氷状態を予測することを最終目的とする。このうち本論文では、路面雪氷状態に大きな影響を及ぼす路面温度を機械学習により予測する手法を開発し、予測精度および予測に要する処理時間の検証を行ったので結果を報告する。

2. 機械学習を用いた路面温度予測の方法

本研究では、機械学習アルゴリズムの一種であるランダムフォレストおよびLSTM（Long Short-Term Memory、長・短期記憶）の2つの手法を用いて路面温度を予測する手法を提案する。詳細を以下に示す。

(1) ランダムフォレストを用いた路面温度予測手法の概要

本研究では路面温度の予測を行うために、気象メッシュデータをランダムフォレストによる予測モデル（以下、ランダムフォレスト予測モデル）に入力することで、気象メッシュデータの時刻以降の路面温度を予測する手法を構築した。ランダムフォレストはランダムに抽出した訓練用データから決定木を複数生成し、複数の決定木の出力結果の平均値または最頻値を用いて分類や回帰問題を解く機械学習アルゴリズムである。ランダムフォレスト予測モデルを作成するためには、目的変数（路面温

度計測値)と説明変数(気象データ)を1組とした訓練用データを作成し、ランダムフォレスト予測モデルの学習を行う必要がある。ランダムフォレスト予測モデルの訓練には、目的変数として北海道開発局の道路テレメータで2021年度冬期に長期間の欠測が生じなかった100地点のうちランダムに選択した90地点で2021/11/8から2022/3/19に計測された路面温度を用いた。また、説明変数には気象庁メソ数値予報モデル(以下、MSM)から取得した道路テレメータ設置地点における気象データ解析値(気温、相対湿度、降水量、日射フラックス、南北および東西方向風速)とMSMの気温および雲量から算出した長波放射フラックスを使用した。なお、MSMは京大生圏研究所が運営する生存圏データベース¹⁰によって収集・配布されたものを用いた。訓練用データセットは、路面温度と路面温度計測時刻の3時間前の気象データ(ケース1)、または3~27時間前までの3時間毎気象データを1組とするデータ(ケース2)とした(図-1)。以上の方法で作成したランダムフォレスト予測モデルは、予測対象時刻から3時間前、または3~27時間前までの3時間毎の気象データ(気温、相対湿度、降水量、日射フラックス、長波放射フラックス、風向および風速)を入力することで、予測対象時刻におけ

る路面温度予測値を出力する。

本研究ではランダムフォレスト予測モデルを作成するにあたり、グリッドサーチを用いてランダムフォレストのハイパーパラメータ(ランダムフォレストに用いる決定木の大きさや数などの予測計算の挙動を設定するパラメータ)を決定した。


(2) LSTMを用いた路面温度予測手法の概要

本研究では、気象時系列データをLSTMによる予測モデル(以降、LSTM予測モデル)に入力することで路面温度を予測する手法を構築した。LSTMは回帰型ニューラルネットワークを用いた機械学習アルゴリズムの一種であり、時系列データや文章データのような連続したデータの前後関係を考慮して次に続くデータを推測することが可能である。LSTMはこのような特徴を有することから、土木分野ではダム流入量の予測¹¹や排水機場の水位予測¹²などへの適用可能性が検証されている。LSTM予測モデルを作成するためには、目的変数(路面温度計測値)と説明変数(路面温度計測値の計測時刻以前における気象時系列データ)を1組とした訓練用データを作成し、LSTM予測モデルの学習を行う必要がある。LSTM予測モデルの訓練にはランダムフォレスト予測モデルと同じく、目的変数として北海道開発局の道路テレメータ100地点のうちランダムに選択した90地点で2021/11/8から2022/3/19に計測された路面温度を、説明変数としてMSMから取得した道路テレメータ設置地点における気象データ解析値(気温、相対湿度、降水量、日射フラックス、南北および東西方向風速)とMSMの気温および雲量から算出した長波放射フラックスを使用した。訓練用データセットは、路面温度と路面温度計測時刻の3~27時間前までの3時間毎気象データを1組とするデータとした。

図-2はLSTM予測モデルのネットワーク構造を示す。

LSTM予測モデルは入力層、中間層および出力層の3層で構成される。入力層は気温、相対湿度、降水量、日射フラックス、長波放射フラックス、南北および東西方向風速を入力する7つのノードから成る。中間層は64個のLSTMブロックから成り、個々のLSTMブロックは情報を記憶するためのセルとLSTMブロック内情報の追加・削除を行う入力ゲート、出力ゲートおよび忘却ゲートから構成される。本研究で用いるLSTMブロックにはHochreiterにより考案された内部構造¹³を用いた。出力層は路面温度予測値を出力する1つのノードから成る。以上の方法で作成したLSTM予測モデルは、予測対象時刻から3~27時間前までの3時間毎の気象データ(気温、相対湿度、降水量、日射フラックス、長波放射フラックス、風向および風速)を入力することで、予測対象時刻における路面温度予測値を出力する。

ケース1



ケース2



図-1 ランダムフォレスト予測モデルの訓練および精度検証に用いるデータセットの概要

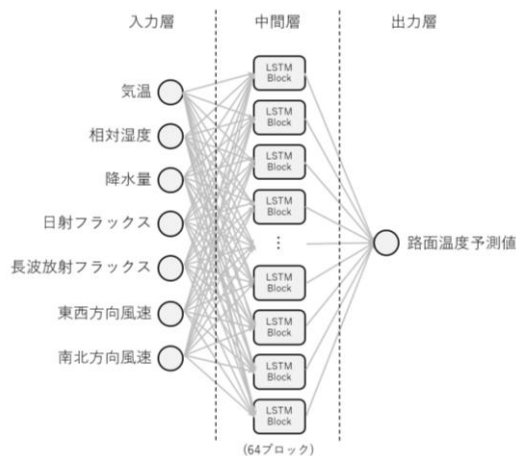


図-2 LSTM予測モデルのネットワーク構造




図-3 ランダムフォレストを用いた路面温度予測値と路面温度実測値の関係
(ケース1の検証用データセット使用時)




図-4 ランダムフォレストを用いた路面温度予測値と路面温度実測値の関係
(ケース2の検証用データセット使用時)

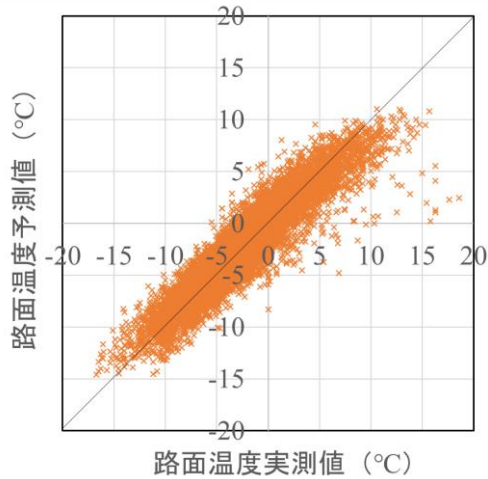


図-5 LSTMを用いた路面温度予測値と路面温度実測値の関係

3. 機械学習を用いた路面温度予測精度および予測処理時間の検証方法

(1) 路面温度予測精度の検証方法

ランダムフォレストを用いた路面温度予測精度は、2. (1)に示す方法で生成したランダムフォレスト予測モデルに精度検証用データセットの気象データを入力し、出力された路面温度予測値と実際の路面温度を比較することで検証した。ランダムフォレスト予測モデルで用いる精度検証用データセットは北海道開発局の道路テレメータのうち、訓練用データの作成に用いた地点を除く10地点における気象および路面温度データから、ランダムフォレスト予測モデル用の訓練用データセットと同様の手法で作成した。

また、LSTMを用いた路面温度予測精度は、2. (2)に示す方法で生成したLSTM予測モデルに精度検証用データセットの気象データを入力し、出力された路面温度予

測値と実際の路面温度を比較することで検証した。LSTM予測モデルで用いる精度検証用データセットは北海道開発局の道路テレメータのうち、訓練用データの作成に用いた地点を除く10地点における気象および路面温度データから、LSTM予測モデル用の訓練用データセットと同様の手法で作成した。

(2) 路面温度予測処理時間の検証方法

路面温度の予測処理時間検証は、気象データから24時間分の路面温度を予測するための予測用データを作成し、ランダムフォレスト予測モデルおよびLSTM予測モデルに予測用データを入力し13000地点相当の路面温度予測に要した時間を計測することで検証した。予測用データは訓練用データの説明変数と同じく、予測対象時刻の3時間前または3~27時間前の3時間毎気象データ（気温、相対湿度、降水量、日射フラックス、長波放射フラックス、南北および東西方向風速）とした。路面温度予測処理時間は、scikit-learn 1.0.2およびtensorflow 2.8.0を用いて作成したランダムフォレストモデルおよびLSTM予測モデルとWindows PC（CPU: AMD Ryzen Threadripper 3970X、GPU: NVIDIA GeForce RTX 3090×1、メモリ: DDR4-3200 16GB×4）を用いて、予測モデル毎に10回計測した。

4. 路面温度予測精度および予測処理時間の検証結果

(1) 路面温度予測精度の検証結果

図-3はケース1の検証用データセットを用いた場合の2021/11/9から2022/3/19の路面温度実測値とランダムフォレストを用いた場合の路面温度予測値の関係を、図-4はケース2の検証用データセットを用いた場合の2021/11/9から2022/3/19の路面温度実測値とランダムフォレストを用いた場合の路面温度予測値の関係をそれぞ

表-1 ランダムフォレスト予測モデルおよびLSTM予測モデルを用いた場合の予測計算処理時間 (秒)

	ランダムフォレスト 予測モデル	LSTM 予測モデル
1	2.555	10.887
2	3.225	10.759
3	2.504	10.767
4	2.431	10.822
5	2.517	11.002
6	2.417	11.117
7	2.439	10.893
8	2.444	11.341
9	2.395	11.114
10	2.391	11.237
平均	2.532	10.994

れ示す。ケース1のデータセットを用いた場合の路面温度の予測誤差(二乗平方平均誤差、RMSE)は2.40°C、およびケース2のデータセットを用いた場合のRMSEは2.19°Cであった。ケース2のRMSEがケース1のRMSEより小さくなった理由は、ケース2では予測対象時刻から27時間前までの気象データを説明変数として用いたことにより、ケース1と比較してRMSEが小さくなった。また、路面温度実測値が0°C以上である条件下では、ケース1、ケース2ともに予測誤差が大きくなる傾向にあった。この理由としては、本研究で提案する手法では日陰が路面温度に及ぼす影響を考慮していないためと考えられる。路面温度が0°C以上である場合の路面性状は乾燥または湿潤路面であることが多く、路面における日射の反射率は積雪路面と比較して低くなる。また、路面における日射の反射率が低い場合は日射フラックスの大きさが路面温度に及ぼす影響が大きくなる。日陰と日向の日射フラックスは大きく異なるため、日陰の影響を考慮していない本手法では路面温度実測値が0°C以上である条件下で日射が路面温度に与える影響を正確に推定することができず、予測誤差が増大したものと推察される。

図-5は2021/11/9から2022/3/19の路面温度実測値とLSTMを用いた場合の路面温度予測値の関係を示す。LSTMを用いた場合の路面温度予測値のRMSEは1.72°Cであり、ランダムフォレストを用いた場合の路面温度予測値のRMSEより小さくなった。また、路面温度実測値が0°C以上の場合は、ランダムフォレストを用いて路面温度を予測した場合と同様に予測誤差が大きくなる傾向が見られた。

(2) 路面温度予測処理時間の検証結果

表-1はランダムフォレスト予測モデルおよびLSTM予測モデルを用いた場合の予測計算処理に要した時間を示す。ランダムフォレスト予測モデルを用いた場合は約13000地点・24時間の路面温度予測計算を約2.5秒で行うことができた。また、LSTM予測モデルを用いた場合は約13000地点・24時間の路面温度予測計算に約11秒を要

した。本手法を用いると、北海道内の国道約6700kmを対象として100m毎に路面温度予測を行った場合の予測計算処理時間はランダムフォレスト予測モデルを用いた場合で約13秒、LSTM予測モデルを用いた場合で約57秒となる。これらの結果は、本研究で提案する手法を用いると高速な予測計算処理が可能であること、北海道内の国道全区間のような広域にわたる路面温度の予測を一般的なPCを用いて安価かつ実用的な処理時間で行えることを示している。

5. 結論および今後の展望

本研究では、路面雪氷状態に大きな影響を及ぼす路面温度を機械学習により予測する手法を開発し、予測精度および予測処理時間の検証を行った。以下に得られた知見を列挙する。

- 予測対象時刻の3時間前または3~27時間前の気象データをランダムフォレストを用いた予測モデルに入力することで、予測対象時刻の路面温度を出力する手法を開発した
- 上記手法を用いた場合の路面温度予測誤差は予測対象時刻3時間前の気象データを入力値として用いた場合に二乗平方平均誤差(RMSE)で2.40°C、予測対象時刻3~27時間前の気象データを入力値として用いた場合の路面温度予測値のRMSEは2.19°Cであり、統計サーマルマップを用いた従来の路面温度予測手法と同程度の予測精度を有することを確認した
- 予測対象時刻の3~27時間前の気象データを長・短期記憶(LSTM)を用いた予測モデルに入力することで、予測対象時刻の路面温度を出力する手法を開発した
- LSTMを用いた場合の路面温度予測誤差はRMSEで1.72°Cであり、ランダムフォレストを用いた手法よりも高い精度で路面温度を予測できることを確認した
- ランダムフォレストおよびLSTMを用いた路面温度予測手法を用いると短時間で広域にわたる路面温度の予測が可能であることが明らかとなった

機械学習を用いた路面温度予測の精度を向上させるためには、日陰のほかにも通過車両が路面雪氷状態や路面温度に及ぼす影響¹⁴⁾を考慮する必要があると考えられる。今後はこれらの影響を考慮した予測モデルを開発するとともに、路面雪氷状態のうち路面凍結リスクや路面のすべりやすさを機械学習により予測する手法を開発し、これらを安価かつ精度良く推定可能であるか検証を行う。

参考文献

- 1) 石川信敬、成瀬廉二、前野紀一：道路雪氷の熱収支特性、低温科学、Vol. 46、pp. 151-161、1987.
- 2) 武市靖：路面凍結の予測に関する研究、土木学会論文集、No. 470/IV-20、pp. 175-184、1993.
- 3) 高橋尚人、浅野基樹、石川信敬：沿道構造物の影響を考慮した路面温度推定モデルの構築について、寒地技術論文・報告集、Vol. 22、pp. 153-158、2006.
- 4) 齊田光、藤本明宏、福原輝幸：熱収支法による広域路面温度予測モデル—乾燥路面の路線温度分布予測—、土木学会論文集 E1、Vol. 69、No. 1、pp. 1-11、2013.
- 5) Thomes, J. E., Cavan, G. and Chapman, L.: The use of GIS and IceMiser to predict winter road surface temperatures in Poland, 12th International Road Weather Conference, 2004.
- 6) 舟田久之：道路凍結と降雪の予測、地学雑誌、Vol. 101、No. 6、pp. 491-505、1992.
- 7) 沼田実、伊藤駿、岩浪守、河村容輔、岡本純、田代享、後藤律子：短期路面凍結予測に関する新しい手法の研究、寒地技術論文・報告集、Vol. 19、pp. 147-151、2003.
- 8) 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.
- 9) 藤本明宏、中島知幸、佐藤賢治、徳永ロベルト、高橋尚人、石田樹：気象メッシュデータを用いた路面温度予測の広域化に関する一検討、雪氷研究大会講演要旨集、p. 228、2016.
- 10) 京都大学生存圏研究所 生存圏データベース、<http://database.rish.kyoto-u.ac.jp>
- 11) 天方匡純、梁田信河、藤井純一郎：LSTM (Long Short-Term Memory) を活用したダム流入量予測に関する研究、電力土木、Vol. 405、pp.11-18、2020.
- 12) 木村延明、中田達、桐博英、関島建志、安瀬地一作、吉永育生、馬場大地：LSTM モデルを用いた低平地排水機場の水位予測、土木学会論文集 B1 (水工学)、Vol. 75、No. 2、pp. 139-144、2019.
- 13) Sepp Hochreiter and Jürgen Schmidhuber : Long Short-Term Memory, Neural Computation, Vol. 9, pp. 1735-1780, 1997.
- 14) 藤本明宏、渡邊洋、福原輝幸：車両熱のモデリングと乾燥路面温度への影響評価、土木学会論文集 E、Vol. 63、No. 2、pp. 250-261、2007.