

除雪出動決定支援のための除雪関連情報共有サイトの構築

大倉 博貴

北海道大学 大学院情報科学院
hiroki0113@eis.hokudai.ac.jp

山下 倫央

北海道大学 大学院情報科学研究所
tomohisa@ist.hokudai.ac.jp

横山 想一郎

北海道大学 大学院情報科学研究所
yokoyama@ist.hokudai.ac.jp

川村 秀憲

北海道大学 大学院情報科学研究所
kawamura@ist.hokudai.ac.jp

要旨

北海道を始めとする積雪地帯において、道路除雪業務は道路交通を維持する重要な役割を果たしている一方で、除雪作業を行う従業員の業務負担は大きい。除雪業務の出動判断は局所的な天候の変動によって出動判断が覆ることが多いため、除雪作業員は休日でも出動に備えておく必要があり、除雪従業員の大きな負担となっている。

このような背景に基づき、本研究では担当者の行う除雪出動の判断が覆らず、除雪対象範囲を安全に遠隔監視するために、除雪出動の決定に必要な情報を自動で収集し、可視化する除雪出動の意思決定支援システムの開発に取り組んでいる。本稿では、除雪出動決定支援システムの一部として既に実用化されている収集した道路の積雪状況や気象情報を可視化するための除雪関連情報共有サイトを構成について述べる。また、除雪関連情報共有サイトに追加して掲載する情報として、定点カメラ画像における積雪割合推定機能を開発している。深層学習を用いて定点カメラ画像の積雪範囲を数値化する積雪割合推定モジュールを提案し、実際の定点カメラ画像に対する推定結果を確認する。

1. はじめに

道路除雪業務は積雪地帯における冬季の道路交通や生活インフラを維持するために重要な役割を果たしている。道路除雪業務の問題点のひとつに、道路除雪業務の出動判断の難しさが挙げられる。道路除雪業務の出動判

断は、担当者が16時に翌日2時に除雪業務を行うかどうかを判断する。翌日2時からおこなう除雪業務はそれまでの道路の除雪状況や16時以降の局所的な天候変化に大きく影響を受けるため、ベテラン担当者でも16時に行った判断を覆すことが多い。

このように出動判断が覆ることが多くあるため、実際に除雪をおこなう除雪作業員は16時に出動がないと判断された場合でも、出動に備える必要があり、除雪作業員の大きな負担となっている。また、道路除雪の直前に実際に除雪対象エリアに自動車で行って積雪状況を目視で確認する雪見巡回が除雪出動の判断を下すために行われている。しかし、積雪している深夜の雪道の走行は車両のスタックやスリップ事故の危険を伴うため、代替手法が望まれている。

本研究では、このような除雪出動の意思決定に伴う負担を軽減するため、大規模かつ複雑なデータに対して視覚的なインターフェースを利用して解析的な推論をおこなう Visual analytics に基づくアプローチを採用する。[1] 道路の積雪状況や気象情報を収集・可視化して、担当者の除雪出動の決定支援をおこなうシステムの開発をおこなっている。本研究で開発を目指している除雪出動決定支援システムの機能のひとつとして、除雪対象エリアに設置した定点カメラからリアルタイムに道路画像を取得し、気象情報を収集する機能を実装する。

収集した情報をシステム上で可視化して、担当者の意思決定に利用し、天候状況の変動があっても覆らない出動判断をおこない、雪見巡回の手間を省くことを目的とする。さらに、除雪作業員も収集した情報を閲覧可能と

することで、天候の変動等の出動判断が変更される予兆を共有可能とすることを目指す。

本稿では、除雪出動決定支援システムの一部として先行して利用を開始している収集した道路の積雪状況や気象情報を可視化するための除雪関連情報共有サイトを構成について述べる。また、除雪関連情報共有サイトに掲載する情報として、定点カメラ画像の積雪割合が挙げられる。定点カメラの目視確認を自動化するために、定点カメラ画像の積雪範囲を数値化する深層学習を用いた積雪割合推定モジュールの提案を行い、その推定機能を確認する。

2. 関連研究

本章では積雪割合推定に利用する画像処理に関する関連技術について説明する。

2.1 セマンティックセグメンテーション

セマンティックセグメンテーションとは画像をピクセル単位に分割し、すべてのピクセルに意味的ラベルの付与を行う深層学習を用いた画像認識タスクのことを指す。このタスクの分野では、Fully Convolution Network[2](以下、FCN)が発表されて以来、このFCNの構造を利用した手法が基本となっている。高解像度の特徴量マップを得るために、EncoderとしてFCNを利用し、DecoderとしてEncoderの特徴量マップを取り入れて空間情報を回復するEncoder-Decoder構造が提案され、その中で代表的なものとして、Seg-Net[3]、U-Net[4]などがある。Seg-Netは前半のEncoderでダウンサンプリングを行った回数分、後半のDecoderでアップサンプリングを行う。各プーリング層での最大値の空間インデックスを、解像度が同じDecoder側のアップサンプリングの際に利用することで、より明確に推論できる。U-NetはSeg-Netと同じEncoder-Decoder構造であるが、低次元の特徴を高次元の特徴へ結合するスキップ接続が採用されており、これはダウンサンプリングの際に失われてしまう情報を回復するための手段である。この他にもPSP-Net[5]やDeepLab[6]を利用した手法があり、さまざまな研究が行われている。

また、ロードヒーティングの対象路面を俯瞰する画像を用いて、セグメンテーションを行うことで路面の積雪を判定する研究がある。今原の研究[7]では、札幌市内

の駐車場を30メートル程の高さから俯瞰する画像の積雪判定を行った結果、ロードヒーティングの制御において問題のない判定精度が得られることが示されている。

本研究の積雪割合推定でセマンティックセグメンテーションを用いる理由を述べる。現在、除雪対象地点に設置された定点カメラの撮影画像を目視で確認することで除雪出動決定の判断材料として利用がされている。そこで、目視による積雪状況の判定を自動で数値化することに取り組む。画像の積雪判定を回帰問題として捉えると、画像認識を用いて行う上で邪魔になる車や建築物、人などの障害物に対処するためには事前処理が必要である。この事前処理は障害物自体の移動や、カメラ角度の変化が起こる関係で無視できない作業量となってしまう。そのため障害物領域の推定もセマンティックセグメンテーションで試みることで、作業量を減らす。他にも1ピクセルごとに学習データがあると考えられるので、1枚の積雪割合を回帰問題として捉えるよりもデータ数を多く扱うことができる点、積雪が多くなりやすい領域や積雪が少なくなりやすい領域の情報を利用できる点が挙げられる。

3. 除雪出動意思決定支援システム

本研究で開発する除雪出動の意思決定を支援するシステムに関して、可視化するデータとシステム構成について述べる。

3.1. 可視化対象データ

本研究で開発するシステムは、北海道留萌市内の除雪対象の5地点に対して、定点カメラ画像と気象情報を収集し可視化する。各地点には異なる角度から撮影する定点カメラ2台を設置し、詳細な積雪状況を把握する。システムで可視化するデータは以下の4つである。

定点カメラの撮影画像 各地点に設置してあるネットワークカメラでリアルタイムで撮影した道路画像。

定点カメラの撮影画像の解析による積雪率 道路画像に写る除雪対象路面領域の中の積雪領域の面積の割合を、セマンティックセグメンテーションによる解析で求めた値。

気象情報 WeatherNewsが提供する天気予報に関する情報[8]。天気予報は72時間先までの1時間おきの天

気予報である短期予報と、10日間先までの1日おきの天気予報である中期予報がある。短期予報は、天気コード、気温、降水量、気圧、風速、風向、相対湿度からなる。中期予報は、天気コード、最高気温、最低気温、降水確率からなる。

積雪深情報 WeatherNewsが提供する積雪深に関する情報 [8]。積雪深とは芝上の積雪を想定した cm 単位での数値である。10分毎の積雪深実況と、60時間先までの1時間おきの積雪深予報からなる。

気象情報と積雪深情報は、緯度経度を指定することで除雪対象地点の詳細な情報を得ることができる。

3.2. システムの構成

除雪出動の意思決定支援システムの構成を図1に示す。本提案システムは、クライアントサイド、サーバサイド、データベース、外部データの4つから構成される。外部データは定点カメラの撮影画像と気象情報、積雪深情報の3つのデータを示している。外部データをサーバサイドで呼び出し、データベースへと格納することで外部データを収集する。また、サーバサイドがデータベースに格納されたデータをAPI化することで、クライアントサイドが常にデータベースからデータを取り出すことが可能である。

本提案システムの開発に利用した技術スタックを以下に示す。

- クライアントサイド : JavaScript, React
- サーバサイド : Python, FastAPI
- データベース : MySQL

3.3. システムの機能

本提案システムには、除雪対象地点の定点カメラ画像をリアルタイムで表示する機能、除雪出動の意思決定に利用する気象情報と積雪深情報を表示する機能を実装する。クライアントサイドからは以下の画面を通じて、情報の入力や閲覧をおこなう。

地点選択画面 除雪対象の全地点が表示され、情報を閲覧したい地点を選択することができる画面。表示される地点ごとにリアルタイムの定点カメラの撮影画

像とその更新時刻を表示する。具体的な画面を図2に示す。

地点ごとのリアルタイム情報画面 選択された地点のリアルタイムの定点カメラの撮影画像とその地点の気象情報、積雪深情報を表示する画面。

地点ごとの過去情報画面 選択された地点の過去の定点カメラの撮影画像とその地点の気象情報、積雪深情報を表示する画面。気象情報と積雪深情報についてはグラフで可視化することで時系列的な情報を確認できる。具体的な画面を図3に示す。

地点ごとの予報情報画面 選択された地点の気象予報情報、積雪深予報情報を表示する画面。気象予報情報と積雪深予報情報を可視化することで時系列的な情報を確認できる。

積雪深値の入力フォーム画面 除雪作業員が計測した積雪深を入力する画面。

4. システムの導入効果の検証

本提案システムは、i) 出動判断をおこなう担当者が事後に覆らない出動判断をおこなうこと、ii) 雪見巡回の手間を省くこと、iii) 除雪従業員が出動判断の担当者と同じ情報を閲覧し出動に備えること、を目指している。

道路画像に写る積雪領域の割合は、出動判断に大きな影響を与えるため、セマンティックセグメンテーションによる自動解析は本提案システムの有用性に大きく貢献する。そこで、2.1節で述べた、定点カメラの撮影画像から目視による積雪状況の確認を自動化・数値化する技術を適用し、積雪割合推定の精度検証を行う。また、画像時系列に対する積雪割合推定の結果と除雪出動の有無を比較し、技術が除雪出動意思決定支援における有用性を考察する。

4.1. 深層学習を用いた積雪割合推定の精度検証

深層学習による積雪割合推定の精度に関して、領域推定や積雪割合の推定の精度を評価指標として検証を行う。

4.1.1 データセット

検証で利用するデータセットについて述べる。3.1節で述べた定点カメラの撮影画像を利用する。本検証では

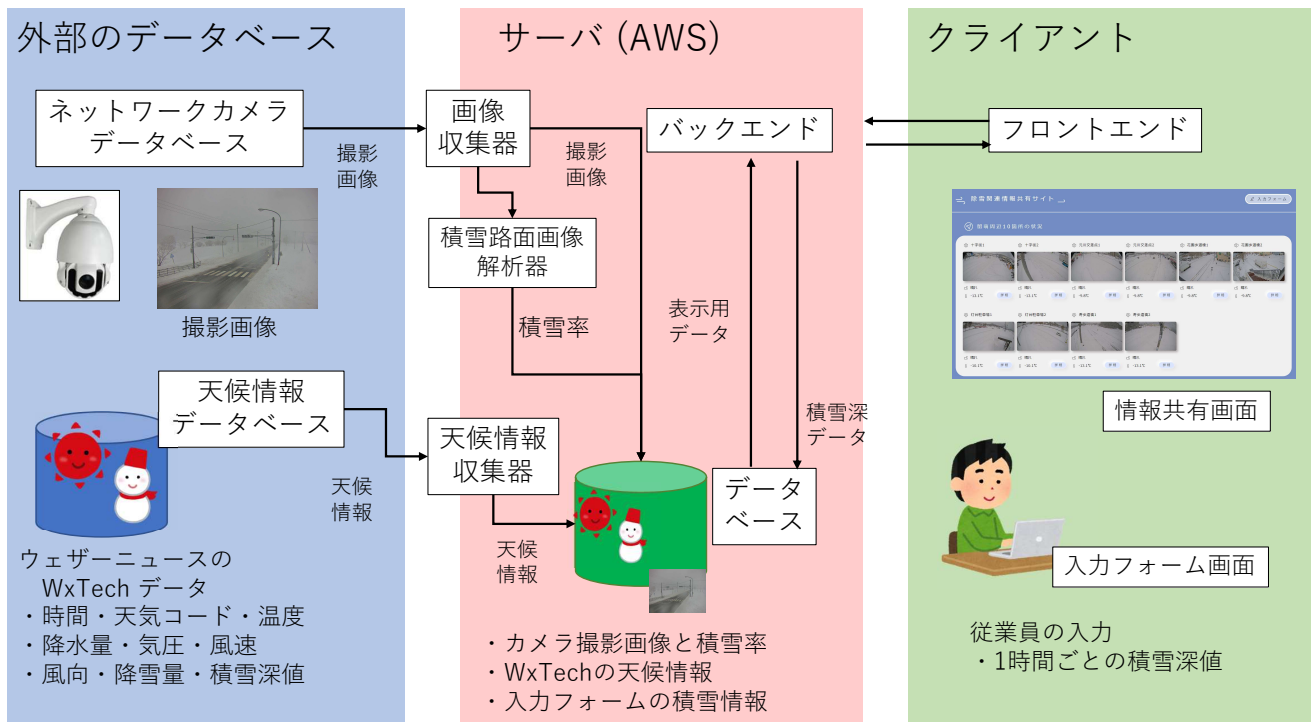


図 1. システム構成の概要

ラベル付けやシステムの都合上 10 地点中 8 地点の撮影画像のみを利用する。撮影期間は 2022 年 12 月 19 日から 2023 年 1 月 27 日であり、その中から同日に 1 から 3 枚程度を選択した 752 枚をデータセットとして利用する。画像の選択について、それぞれ 6 時間以上時間間隔が離れており時系列的な偏りはない。また天候的な偏りについて、積雪が全くない状況と路面が見えなくなるほどの積雪がある状況、それらのどちらにも当たらない状況をそれぞれ選択し、偏りはあるものの様々な状況を選択する。

学習用データのラベル付け定義について述べる。対象となる撮影画像に対し正解ラベルを付与し、学習用の正解であるマスクデータとする。

画像内の全ピクセルにラベルを付与するものとし、画像内のピクセルはすべていずれかのクラスに属するものとする。画像に付与する正解ラベルは下記の 3 種類である。

積雪 積雪が確認された除雪対象路面の領域に付与するラベル。

非積雪 積雪が確認されていない除雪対象路面の領域に

付与するラベル。

障害物 上記の 2 クラスの判定の障害となるもので除雪対象路面に関連するものに付与するラベル。建物、車、木、人、電柱など該当する。

無関係な領域 上記の 3 クラスに分類されないすべての領域に付与するラベル。

このようなマスクデータを撮影画像の選択枚数だけ用意し、作成したマスクデータと対応する撮影画像のデータセットを用いて学習を行う。

4.1.2 学習モデルと設定

セマンティックセグメンテーションのタスクで高いスコアを残していた学習モデルとして、Unet++を利用し、Encoder の特徴抽出の部分では Xception[9] のネットワーク構造を用いる。また、Imagenet のデータセットによる事前学習済みモデルを利用する。

学習パラメータは表 1 に示す。



図 2. 地点選択画面




図 3. 地点ごとの過去情報画面

データセットについて、4.1.1 節で述べたものを学習画像、検証画像の割合が 8:2 の比になるように撮影地点、撮影日ごとに分配した。撮影日ごとに学習画像と検証画像を分けることによって、学習画像と異なる日付に撮影された画像に対する推定精度を評価し、システムの実運用の際の性能をより正確に見積もることができる。

表 1. 学習パラメータ

エポック数	40
ミニバッチサイズ	2
最適化	Adam
学習率	初期値:0.0001 25 エポック以降:0.00001

4.1.3 評価指標

評価指標には、Intersection over Union を用いた。

Intersection over Union(以下 IoU) とは、物体検出の評価指標である。正解ラベルを付与した画像と推定結果の画像を比べた際に、正解領域と推定領域が重複する割合を表す。画像 1 枚 1 枚に対し、積雪、非積雪、障害物クラスの IoU の平均値を算出する。各クラスをそれぞれ正例とし、画像内の各画素に対して表 2 のような混同行

表 2. 混同行列

		推定結果	
		正例	負例
正解データ	正例	TP(True Positive)	FN(False Negative)
	負例	FP(False Positive)	TN(True Negative)

列を作成する。

このとき IoU は下記式で与えられる。

$$IoU = \frac{TP}{TP + FP + FN} \quad (1)$$

4.1.4 積雪割合推定方法

積雪割合推定方法について述べる。今原ら [7] が提案した積雪割合を利用した積雪判定を行う。2つの利用したデータセットを対象に、積雪割合について算出を行う。各画像の積雪割合を式 2 で定義する。

$$\text{積雪割合} = \frac{\text{積雪ラベルのピクセル数}}{(\text{積雪ラベル} + \text{非積雪ラベル}) \text{のピクセル数}} \quad (2)$$

本研究ではこの値を利用した積雪判定が、目視による確認の自動化・数値化として用いることができるかを考察する。

4.1.5 検証結果

評価指標に対する結果として、IoU は 0.951 となり学習がうまく実行されていることがわかる。

検証画像として利用した 172 枚に対する積雪割合推定結果を述べる。式 2 で示される積雪割合を正解データと推定結果のマスクデータについて算出し、その違いを比較する。

正解データと推定結果の積雪割合の混同行列を表 3 に示す。多くの画像では正解データと推定結果の値の範囲が一致し、大きな外れ値がないことがわかる。

4.2. 画像時系列に対する積雪割合推定の検証

4.1 節で検証した積雪割合推定を定点カメラ画像に対して適用し、除雪出動意思決定の支援における有用性を調査する。

4.2.1 実験設定

検証で利用するデータセットについて述べる。3.1 節で述べた全 10 地点の定点カメラの撮影画像を利用する。撮影期間は 2022 年 2 月 21 日 12 時から 2023 年 2 月 25 日 12 時、撮影間隔は 10 分ごと、撮影画像枚数は 1 地点ごと 576 枚で全地点合計 5,760 枚である。

学習モデル、パラメータについて、4.1.2 節で述べた学習済みモデルを利用する。本検証では、未学習のデータセット、さらに学習画像のない 2 地点を含むものを利用する。

4.2.2 検証方法

検証方法について述べる。データセットに対して学習済みモデルを適用、積雪割合を推定し 10 地点の平均値を扱い、除雪出動が必要・不要な時間帯を比較する。ただし、定点カメラの撮影画像を目視で確認し、道路面が見えなくなる程度の積雪が確認できる時間帯とし、それ以外の時間帯を除雪出動が不要な時間帯とする。

4.2.3 検証結果

検証結果について述べる。データセットに対する推定積雪割合の平均値の時間推移を図 4 に示す。除雪出動が必要な時間帯は 2 月 21 日 19 時から 2 月 22 日 5 時までの時間帯と、2 月 25 日 6 時から 2 月 25 日 7 時までの時間帯である。図 4 から、除雪出動が必要な時間帯は積雪割合が 100 % に近い数値を 30 分以上維持することがわかる。また、除雪出動が不要な時間帯では、積雪割合が増加するがすぐに減少する、または 100 % よりも低い数値を維持することがわかる。これは、画像時系列に対する積雪割合推定が、除雪出動が必要な時間帯を捉えていることを示し、これまで目視により行われていた積雪状況の確認の自動化・数値化を通して除雪出動意思決定の支援における有用性を明らかとしている。

5. まとめ

本稿では、除雪出動決定支援システムの一部として、既に実際に利用が開始されている。除雪関連情報共有サイトを概説した。除雪関連情報共有サイトは、除雪対象地点のリアルタイムで道路画像とその地点の気象情報を

表 3. 積雪割合の混同行列

		正解データの積雪割合										
		0.0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
推定結果の積雪割合	0.0	2	0	0	0	0	0	0	0	0	0	0
	0.1	9	22	0	0	0	0	0	0	0	0	0
	0.2	0	4	2	0	0	0	0	0	0	0	0
	0.3	0	1	1	0	0	0	0	0	0	0	0
	0.4	0	1	0	0	0	0	0	0	0	0	0
	0.5	0	0	0	0	1	0	0	0	0	0	0
	0.6	0	0	0	0	0	0	0	0	1	1	0
	0.7	0	0	0	0	0	0	0	0	0	0	0
	0.8	0	0	0	0	0	0	0	0	0	0	0
	0.9	0	0	0	0	0	0	0	0	0	0	1
	1.0	0	0	0	0	0	0	0	0	0	0	126

自動収集・サイト上での可視化をおこない、除雪出動を決定する担当者だけでなく除雪作業員も閲覧して、関連情報の共有を可能にした。さらに、今後の除雪出動決定支援システムの導入効果の検証に関して概説した。また、収集した定点カメラの撮影画像を用いた深層学習による積雪割合推定に取り組み、その結果と利用可能性を説明した。今後の展開として、出勤判断の変更回数、担当者の負担軽減への寄与度、雪見巡回の負荷軽減、情報閲覧による除雪従業員の精神的な負担軽減を調査し、収集した気象情報と除雪出動履歴、推定積雪割合を用いて、深層学習による除雪出動必要性の推定に取り組む。

謝辞

本研究は、PRISM (Public/Private R&D Investment Strategic Expansion Program) 官民研究開発投資拡大プログラムの国土交通省「建設現場の生産性を飛躍的に向上するための革新的技術の導入・活用に関するプロジェクト」の支援を受けたものである。

参考文献

- [1] James J. Thomas and Kristin A. Cook. Illuminating the path: The research and development agenda for visual analytics. 2005.
- [2] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431–3440, 2015.
- [3] Roberto Cipolla Vijay Badrinarayanan, Alex Kendall. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 2481–2495, 2017.
- [4] Thomas Brox Olaf Ronneberger, Philipp Fischer. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pp. 234–241, 2015.
- [5] Shi J. Qi X. Wang X. Zhao, H. and J. Jia. Pyramid scene parsing network. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 6230–6239, 2017.
- [6] George Papandreou Florian Schroff Hartwig Adam Liang-Chieh Chen, Yukun Zhu. Encoder-decoder with atrous separable convolution for semantic image segmentation. *European Conference on Computer Vision (ECCV)*, pp. 801–818, 2018.
- [7] 今原智広, 横山想一郎, 山下倫央, 川村秀憲. ロードヒーティング制御に向けたセマンティックセグメン

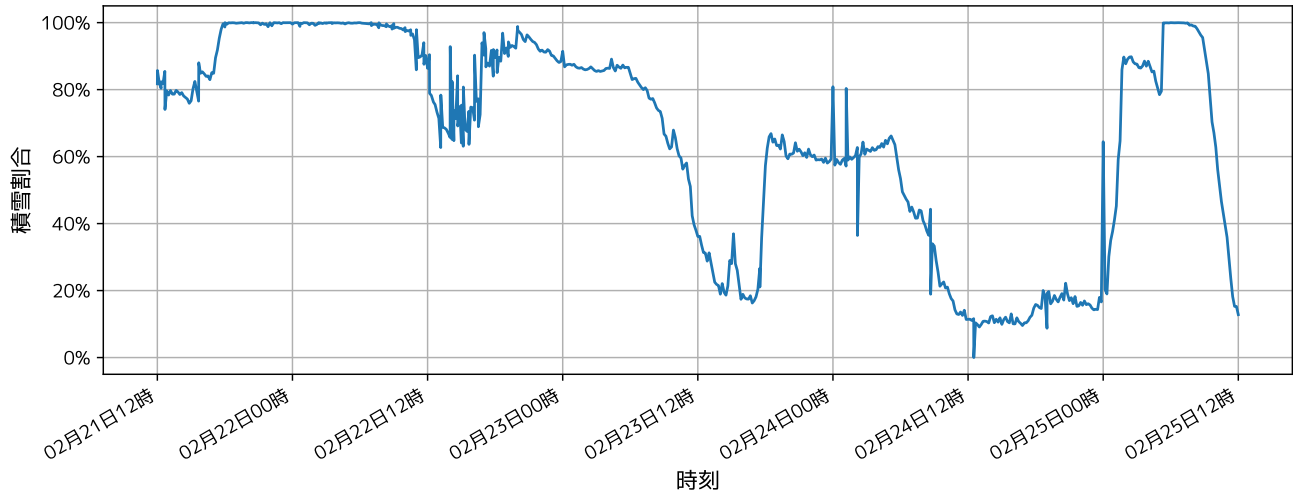


図 4. 画像時系列に対する推定積雪割合平均値の時間推移

テーションによる路面画像の積雪状況認識. 第 201 回知能システム研究発表会, 2021.

- [8] ウェザーテック (wxtech[®]): 気象データのビジネス活用・分析. <https://wxtech.weathernews.com/>. (Accessed on 01/12/2023).
- [9] Francois Chollet. Xception: Deep learning with depthwise separable convolutions. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017.