

AIによる雪氷対応の効率化について

徳島河川国道事務所 池田国道維持出張所 高松 孝昭

平成26年12月に発生したゲリラ豪雪では、国道192号の徳島県と愛媛県の県境付近で積雪が20～30cmを超え、池田国道維持出張所では立ち往生車両の移動等、雪氷対応に追われることになった。降雪の少ない四国でも、今後ゲリラ豪雪が再発する危険性があるため、徳島河川国道事務所では現在、雪氷対応を支援するシステムの導入について検討を進めている。

本論文ではその初期検討として、AI(人工知能)技術の一種であるディープラーニングを用いて、道路の降雪や積雪の発生を自動判定するモデルを試験開発した結果を報告する。

キーワード 雪氷対応, AI, ディープラーニング

1. はじめに

近年の日本は暖冬少雪傾向の中にあるが、冬期の交通障害は毎年のように発生している。特に、世界的な気候変動に伴い、短期間で集中的に降雪するゲリラ豪雪発生の傾向が高まっており、積雪地域ばかりではなく、除雪体制が手薄な少雪地域でも、豪雪の影響を受けた交通障害が多発している。降雪の少ない四国においても、平成26年12月に発生したゲリラ豪雪時には、徳島県と愛媛県を結ぶ国道192号の県境付近で、約130台の大規模な立ち往生車両が発生し、約26時間に及ぶ通行止めと立ち往生車両の移動に対応¹⁾を追われた。

このような状況を踏まえ、降雪や道路積雪を迅速に見・対応できるよう、雪氷対応を支援するシステムの導入について検討を進めている。

本論文ではその初期検討として、AI(人工知能)技術により、道路の降雪や積雪の発生を自動判定するモデルについて検討した結果を報告する。

判別するAIモデルを試験開発した。



図-1 対象 CCTV カメラの設置位置図

2. 検討目的

徳島河川国道事務所が管理するCCTVカメラの映像を対象に、AI技術を用いて積雪判別を自動化する方法を検討する。AI技術については、近年の第3次AIブームのメイン技術であるディープラーニング(深層学習)の1種であり、自動運転や医療診断等の分野において、高度な画像解析能力を発揮しているCNN(畳み込みニューラルネットワーク)を利用する。また、今回対象とした映像については、2020年2月17日(月)～2月19日(水)に道路の積雪が確認された3箇所を対象に、降雪・積雪の程度を自動

3. AIを用いた積雪判別モデルの検討

(1) 積雪判別基準

AIによる積雪判別基準として、下記3段階を設定する。また、②と③の境目については、映像の目視確認結果から、図-2に示す瞬間を対象に判定した。

- ① 定常時：雪が存在しない状態
- ② 降雪・残雪時：雪が存在するが道路に積雪していない状態
- ③ 道路積雪時：道路に積雪している状態

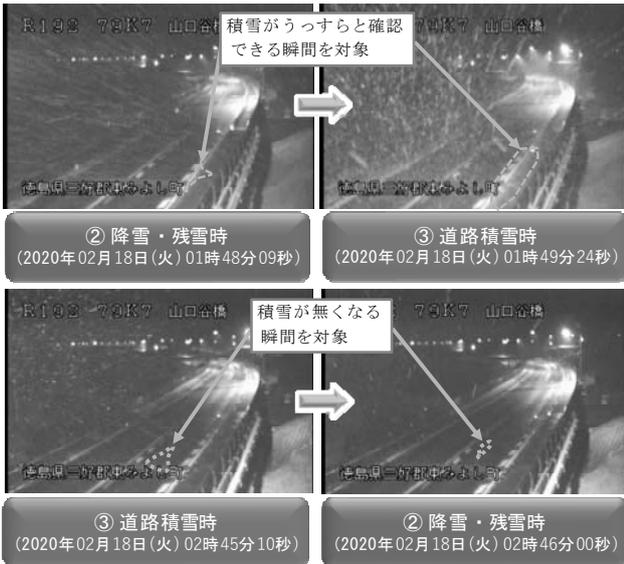


図-2 降雪・残雪時と道路積雪時の変化する境目
(例：(3)山口谷橋)

(2) 学習用画像データ

AI学習用画像データとして、上記3箇所のCCTVカメラ映像を状況が変化する10秒間隔で画像化し、① 定常時、② 降雪・残雪時、③ 道路積雪時の3段階に分類したもの、並びに3箇所を全て統合した画像データも併せて使用する。これらの画像データを、AI学習用の訓練データ、精度検証用のテストデータとして、9:1の比率でランダムにデータセットを作成することでAIの学習を実施した。

表-1 (1)猪ノ鼻TのAI学習用画像データ数

積雪判別基準	データ数	訓練データ数 (9割)	テストデータ数 (1割)
① 定常時	3,000枚	2,700枚	300枚
② 降雪・残雪時	3,000枚	2,700枚	300枚
③ 道路積雪時	3,000枚	2,700枚	300枚
データ総数	9,000枚	8,100枚	900枚

表-2 (2)馬路西之坊のAI学習用画像データ数

積雪判別基準	データ数	訓練データ数 (9割)	テストデータ数 (1割)
① 定常時	2,300枚	2,070枚	230枚
② 降雪・残雪時	2,300枚	2,070枚	230枚
③ 道路積雪時	2,300枚	2,070枚	230枚
データ総数	6,900枚	6,210枚	690枚

表-3 (3)山口谷橋のAI学習用画像データ数

積雪判別基準	データ数	訓練データ数 (9割)	テストデータ数 (1割)
① 定常時	3,000枚	2,700枚	300枚
② 降雪・残雪時	3,000枚	2,700枚	300枚
③ 道路積雪時	3,000枚	2,700枚	300枚
データ総数	9,000枚	8,100枚	900枚

表-4 3つのカメラを統合したAI学習用画像データ数

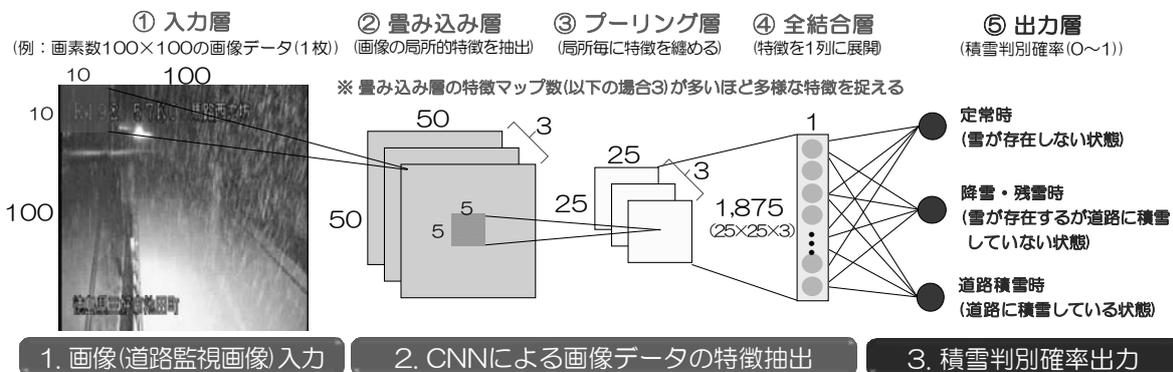
積雪判別基準	データ数	訓練データ数 (9割)	テストデータ数 (1割)
① 定常時	8,300枚	7,470枚	830枚
② 降雪・残雪時	8,300枚	7,470枚	830枚
③ 道路積雪時	8,300枚	7,470枚	830枚
データ総数	24,900枚	22,410枚	2,490枚

(3) AI積雪判別モデルの開発

CNNにより積雪判別を行うモデルの概要図を図-3に示す。本モデルでは、入力画像から3段階の積雪判別基準確率を算出し、最も確率の高い項目を判別結果として出力する。CNNモデルは、画像判別技術の研究開発分野で実績のあるVGG19²⁾をベースモデルとして使用した。

【AI積雪判別モデルの解析手順】

- ① 入力層で学習用データである積雪有無画像を入力
- ② 中間層(畳み込み層、プーリング層、全結合層)で特徴抽出器であるフィルタを用いて各画像の特徴抽出を実施
- ③ 出力層で3種類の積雪判別基準の予測確率を算出
- ④ 出力層の結果と実際の結果(正解)を比較し、正解を予測できるようにフィルタのパラメータを更新
- ⑤ 指定した学習回数分①～④の処理を繰り返す



※ : フィルタ (特徴を抽出するための検出器)、 : 特徴マップ (フィルタが抽出した特徴)
 ※ 図内の数値(フィルタサイズや特徴マップ数等)はサンプルであり、本数値や各層の数を変更することでモデルを修正

図-3 CNNによる積雪判別モデルの概要図

(4) モデルの精度検証結果

開発した積雪判別モデルにより，下記の方針で訓練データの学習と，テストデータに対する判別精度検証を実施する．その際，学習の難易度を「低難易度：訓練データとテストデータが同一箇所のケースA・B」，「高難易度：訓練データとテストデータが異なるケースC」に分けて精度比較を実施した．なお，判別精度の安定性確認のため，学習と検証は10回ずつ実施した．精度検証結果と考察を以下に示す．

【AI 積雪判別モデルの精度検証方針】

- ケースA：訓練データとテストデータが同じ箇所
(訓練：1箇所，テスト：1箇所)_低難易度
- ケースB：訓練データとテストデータが同じ箇所
(訓練：3箇所，テスト：3箇所)_低難易度
- ケースC：訓練データとテストデータが別の箇所
(訓練：1箇所，テスト：1箇所)_高難易度

【AI 積雪判別モデルの精度検証結果・考察】

ケースA：

- 全箇所に対して訓練データが100%，テストデータが約99%の高い正解率が得られた(図-4～図-6)．
- テストデータの誤検知について，(3)山口谷橋では，②降雪・残雪時と③道路積雪時を①定常時と判定する確率が高いため，危険状態の方に判定するよう改良する必要がある．

ケースB：

- ケースAと同様の高い正解率を得た(図-7)．
- 図-8に示す様な夜間かつ車両のライトの影響を受ける場合等では，一部誤判定が見られるが，3段階の積雪判別(①定常時，②降雪・残雪時，③道路積雪時)が概ね正しく実施できている．

ケースC：

- ケースA・Bと比べ，正解率がと大幅に低くなった(図-9～図-14)．
- 訓練データが(2)馬路西之坊，テストデータが(3)山口谷橋，またはその逆のパターンでは，訓練データに(1)猪ノ鼻Tを用いた場合と比較して，一定の精度が確保できた(図-12，図-14)．
- その一因として，(2)馬路西之坊と(3)山口谷橋は道路線形，風景等が似ていることが考えられる．
- 訓練データに(2)馬路西之坊を用いた場合の精度が最も高く(図-11，図-12)になっており，今回対象とした中では最も優れた学習データとなった．
- その一因として，(2)馬路西之坊が他の2箇所と共通する特徴が最も多かったことが考えられる．
- テストデータの誤検知について，全体的に，②降雪・残雪時と③道路積雪時を①定常時と判定する確率が高いため，危険状態の方に判定するよう改良する必要がある．

100.00%	0.00%	0.00%	0.00%	99.97%	0.03%	0.00%	0.01%	99.99%			
① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時
① 定常時			② 降雪・残雪時			③ 道路積雪時					

■：正解率 ■：誤検知率

図-4 モデル精度検証結果(ケースA)_(1)猪ノ鼻T

100.00%	0.00%	0.00%	0.00%	99.98%	0.02%	0.00%	0.09%	99.91%			
① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時
① 定常時			② 降雪・残雪時			③ 道路積雪時					

■：正解率 ■：誤検知率

図-5 モデル精度検証結果(ケースA)_(2)馬路西之坊

100.00%	0.00%	0.00%	0.00%	100.00%	0.00%	0.01%	0.00%	99.99%			
① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時
① 定常時			② 降雪・残雪時			③ 道路積雪時					

■：正解率 ■：誤検知率

図-6 モデル精度検証結果(ケースA)_(3)山口谷橋

100.00%	0.00%	0.00%	0.00%	99.99%	0.01%	0.00%	0.03%	99.97%			
① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時	① 定常時	・ 残雪時	② 降雪	③ 道路積雪時
① 定常時			② 降雪・残雪時			③ 道路積雪時					

■：正解率 ■：誤検知率

図-7 モデル精度検証結果(ケースB)_3カメラ統合



「③ 道路積雪時」(正解)→「① 定常時」と誤判定した画像例



「③ 道路積雪時」(正解)→「② 降雪・残雪時」と誤判定した画像例

図-8 モデルが誤判定した画像例

(上図：(1)猪ノ鼻T，下図：(2)馬路西之坊)

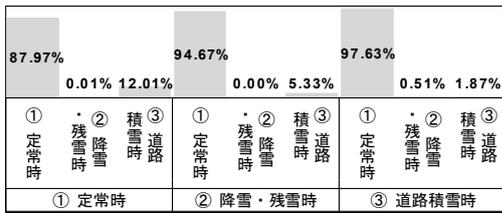


図-9 モデル精度検証結果(ケースC)
(訓練データ：(1)猪ノ鼻T, テストデータ：(2)馬路西之坊)

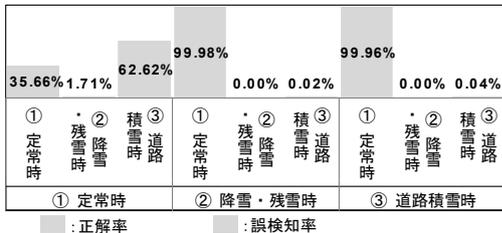


図-10 モデル精度検証結果(ケースC)
(訓練データ：(1)猪ノ鼻T, テストデータ：(3)山口谷橋)

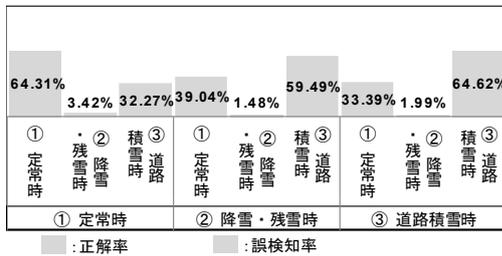


図-11 モデル精度検証結果(ケースC)
(訓練データ：(2)馬路西之坊, テストデータ：(1)猪ノ鼻T)

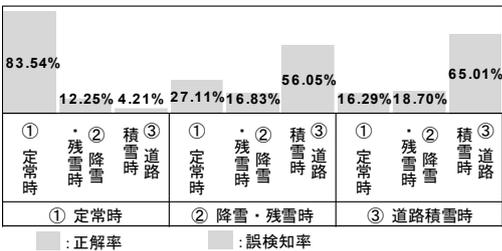


図-12 モデル精度検証結果(ケースC)
(訓練データ：(2)馬路西之坊, テストデータ：(3)山口谷橋)

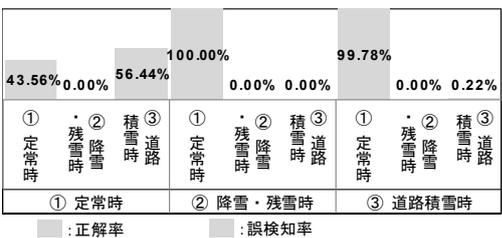


図-13 モデル精度検証結果(ケースC)
(訓練データ：(3)山口谷橋, テストデータ：(1)猪ノ鼻T)

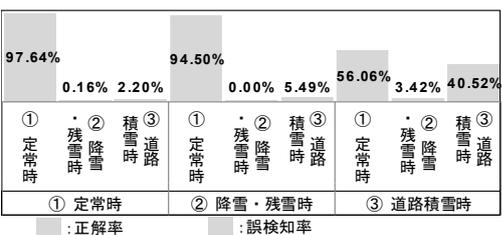


図-14 モデル精度検証結果(ケースC)
(訓練データ：(3)山口谷橋, テストデータ：(2)馬路西之坊)

4. おわりに

本検討では、最新 AI 技術の一種である CNN を使用した 3 段階の積雪判別モデルを開発し、3 箇所 CCTV カメラへの適用に取り組んだ。その結果、訓練データとテストデータが同じ箇所の場合は、ほぼ 100%の精度で訓練・テストデータに対する積雪判別が可能となり、CNN の有効性を示すことができた。

今後は、本モデルを道路管理者による雪氷対応の支援に実際に役立てるため、下記取り組みを実施することが重要である。

① より積雪の多い学習データの追加

今回対象とした 3 箇所のカメラ映像では、大雪注意報・警報が発令される程の積雪は生じていないため、モデルの精度向上を目的に、それらの映像についても学習を実施する。

② 対象カメラの増加

今回対象としたカメラ以外に、厳寒期に道路への積雪が危惧される他のカメラについても適用する。

③ プリセット映像以外の映像の学習

今回対象としたカメラ映像はプリセット状態のみを対象としているため、カメラを操作し画角を変更した場合、精度低下が予想される。必要に応じて、プリセット以外の映像についても学習する必要がある。

④ 積雪判定システムの開発

開発したモデルを利用し、実際の降雪時に出張所職員・事務所職員の方にアラートメールを送信するシステム開発を行う。

⑤ 運用に適した AI 積雪判別モデルの検討

今回検討結果から、ケース A・B のモデルで実用可能なレベルの精度が得られた。今後現場へ導入するには、試用検証とその結果に基づく現場職員との協議を行い、適したモデルを選定する必要がある。

【ケース A の特徴】

- ・カメラ毎の専用モデルのため、ケース B よりも精度が高くなりやすい。
- ・カメラ毎にモデルを管理・学習する必要があり、対象カメラが多くなるほど職員の手間が増える。

【ケース B の特徴】

- ・対象とする全カメラの統合モデルのため、管理・学習が容易。
- ・ケース A よりも精度が低くなりやすい。

参考文献

- 1) 国土交通省 四国地方整備局 道路部：平成26年12月5日の豪雪による国道192号 雪害への対応，2014
- 2) K.Simonyan, and A.Zisserman. : Very deep convolutional networks for large-scale image recognition, CoRR, abs/1409.1556, 2014.