

車載カメラの画像解析による視程障害検知技術に関する研究

研究予算：運営費交付金

研究期間：平 30～令 2

担当チーム：雪氷チーム

研究担当者：高橋丞二、萬直樹、金子学、
國分徹哉、大久保幸治、武知洋太、
櫻井俊光

【要旨】

本研究では、冬期道路における吹雪視程障害の要対策箇所を低コストかつ効率的に抽出することを目的に、AI 技術の畳み込みニューラルネットワーク（CNN）を活用して、車両に搭載されたカメラで撮影した画像から視程障害の発生を検知、およびその程度を数段階に判別する技術の検討を行った。その結果、吹雪視程判別モデル構築に用いる画像の学習条件について、次のことを明らかにした。1）吹雪発生（視程 200m 未満）の検知には、色調がカラーで特定の画角でトリミングした画像を用いることが有効であった。2）吹雪の程度の判別には、色調がカラーで特定の画角でトリミングしない画像を用いることが有効であった。以上から、CNN により目的に応じた吹雪発生程度の判別が可能であると考えられる。

キーワード：深層学習、視程障害、吹雪対策、自然災害

1. はじめに

積雪寒冷地の冬期道路では、吹雪による視程障害や吹きだまりによる交通障害が発生する。特に近年の北海道では、急激に発達した低気圧が引き金となり、極端な暴風雪による人命に関わるような吹雪災害に発展するケースが見られる。暴風雪による吹雪災害を減らすため、道路管理者は防雪柵等の吹雪対策施設を設置しているが、必要とされる道路すべてに設置することは予算的な観点から難しいものがある。また、適切な設置箇所の抽出には現地観測および熟練技術者の判断に頼るところが大きい。一方で、経験が乏しい場合は、設置箇所を的確に判断することは容易ではない。

路線上の吹雪による視程障害が著しい箇所を抽出するためには、定量的なデータの取得が必要となる。その場合は、ビデオカメラ、視程計、風向風速計などを搭載した視程障害移動観測車（図 1）を用いて、吹雪発生時に繰り返し観測している¹⁾。ただし、現地に向かう時間と作業コストを要するうえ、暴風雪時に繰り返し走行するには危険も伴う。そこで、視程障害移動観測車のような特殊車両ではなく、該当路線を頻繁に走行するパトロール車にカメラを搭載し、走行時に得られた画像を活用し、吹雪による視程障害が発生する箇所を経験の有無によらず簡易的に抽出することが可能となれば、生産性の向上と、コスト削減が期待できる。そこで本研究では、平成 30 年度から AI（Artificial intelligence）を活用した吹雪による視程



図 1 視程障害移動観測車

障害の著しい道路箇所を抽出するための手法について検討を開始した。

AI には様々なものがある²⁾。画像認識・検出に利用される AI には、たとえば畳み込みニューラルネットワーク（Convolutional Neural Network, CNN）³⁾が代表的であり、CNN は多種多様な分野で利用されている。近年では、普通乗用車等に搭載された車載カメラ画像に関する研究もあり、たとえば、車載カメラから舗装の状態を検知する方法^{4,5)}、歩行者の流れを車載カメラで分析する方法⁶⁾、悪天候を CNN で判断し急ブレーキの推定を行う研究⁷⁾、豪雨、多量降雪や霧などの悪天候において最適な走行速度を推定するための研究⁸⁾など、道路研究分野においても CNN が利用

され始めている。

吹雪による視程障害などの道路交通状況を提供する方法には CNN だけでなく、背景が固定された CCTV カメラの静止画像から視程を自動的に数値化してランク付けし、視程情報を道路管理者に提供する画像解析システムが開発されている⁹⁾。しかし、車載カメラのような走行時に背景が変わる画像で、かつ吹雪時における視程を推定する技術について研究事例はほとんどない。

そこで本研究は、CNN を活用し、車載カメラで撮影した画像から吹雪による視程障害の発生を検知し、さらに、その程度を数段階に判別する技術を検討することを目的とする。

2. 研究概要

本章では、吹雪画像を用いた視程障害判別実験において判別対象とした視程ランク、CNN による実験手順について記す。なお、実験で利用する吹雪画像は、視程障害移動観測車 (図 1) に搭載されている車載カメラにより撮影された動画を切り出した静止画である。

2. 1 視程障害検知に向けた判別する視程ランクと視程データ

視程の定義は、空を背景としたとき視角 $0.5\sim 5^\circ$ 程度となる黒ずんだ目標物が肉眼で識別できる最大の距離¹⁰⁾とされる。この定義は、主に霧に適用されるものであるが、吹雪時の視程についてもこの概念を応用し、吹雪時の視程を評価¹¹⁾している。

ドライバーの運転挙動に基づき区別される視程のランクは、視程 1,000m 以上をランク A、500m～1,000m 未満をランク B、200m～500m 未満をランク C、100m～200m 未満をランク D、100m 未満をランク E とする 5 つがある¹²⁾。本研究では、吹雪の発生有無について CNN で判別するため、ドライバーの運転挙動に影響を与える視程 200m 未満を「吹雪発生」、200m 以上を「吹雪未発生」とする。各ランクの代表的な画像を図 2 に示す。この 5 段階の視程ランクおよび 2 段階で吹雪発生有無を CNN で評価することとした。

車載カメラで撮影された画像に映り込む目標物等は様々であり、また道路線形も多様であるため、視程の定義に合致させることは難しい。そこで本研究では、視程障害移動観測車 (図 1) に搭載された車載式前方散乱型 (明星電気 (株) 製 TZF-31A) の視程データを利用する。サンプリング周波数は 10Hz で 1 秒平均



図 2 各視程ランクの代表的な画像

値の視程データである。なお、車載式前方散乱型視程計は、車両のフロント部分に取り付けられており、出力される値は、車両から前方方向の視程に相当するものではないことに留意したい (3 章に詳細を記す)。

2. 2 CNN の概要

一般的に深層学習による画像認識は、「正解」がわかっている「教師データ」を用いて学習した「判別モデル」に、「未知の画像」を入力して確信度を算出させ、「未知の画像」が「正解」かどうかを判別するものである (図 3)²⁾。CNN はその手段の一つである。

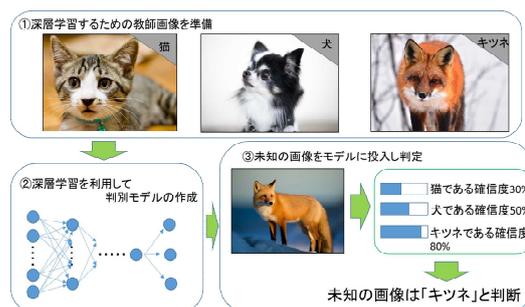


図 3 深層学習による画像認識の概念図

図 4 に示すように、CNN は入力画像に対して「Convolutional 層 (畳込み層)」、「Pooling 層 (プーリング層)」と「出力層」で構成されている²⁾。Convolutional 層は、フィルターを利用して特徴の抽出を行う。Pooling 層は Convolutional 層から出力された情報を圧縮し、その特徴をまとめる処理を行う。CNN は Convolutional 層と Pooling 層の処理を繰り返す、最終的に得られる特徴を基に出力層でカテゴリ毎に確信度を算出するものである。

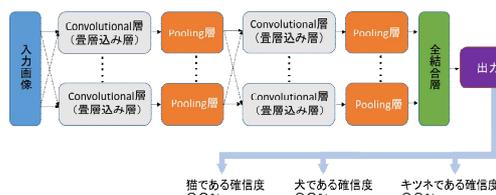


図 4 CNN の概念図

確信度の評価は、Recall（再現率）、Precision（適合率）、F-score（調和平均）および Accuracy（正解率）が利用される。以下に、これら4つの評価方法について定義を示す。

- Precision（適合率）とは、モデルが正解と判別した中に、どの程度本当の正解が含まれているかを示す値であり、正確性に関する指標である（図5）。
- Recall（再現率）とは、全正解に対してモデルが正解と判別した中に、本当の正解がどの程度含まれているかを示す値であり、網羅性に関する指標である（図6）。
- F-score（調和平均）とは、PrecisionとRecallの2つの指標だけでは客観的に精度がわかりづらいため、PrecisionとRecallからF-score（調和平均）を算出した値である。F-scoreは次式により算出している。

$$F\text{-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

- Accuracy（正解率）とは、「モデル全体のテストデータ総数」に対する「モデルが正解した総数」の割合である。本研究で利用するCNNで得られた結果においても、上述した評価手法を用いることとする。

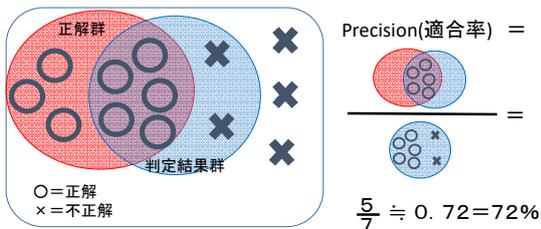


図5 Precision（適合率）の概念図

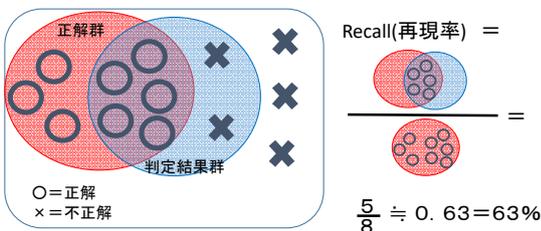


図6 Recall（再現率）の概念図

2.3 CNNによる視程障害判別実験の手順

視程障害移動観測車に搭載した車載カメラで撮影された動画から切り出した静止画の吹雪時の視程ラン

クを、CNNを活用して判別させる。車載カメラで撮影された静止画は、時々刻々と背景と吹雪の視程が変化する。そのため、CNNで画像を判別する前に画像を解析することが必要である。

図7に深層学習による視程障害判別実験の手順を示す。①深層学習用の吹雪画像を作成し（3章）、②吹雪画像と組み合わせた視程評価手法の検討を行った（4章）。その結果を踏まえて③深層学習の学習条件（パラメータ）の検討を行い（5章）、さらに④画像の前処理手法の検討し（6章）、最後に、⑤作成した吹雪画像判別モデル（以降では、モデルとする）を評価した（7章）。

各検討では目的に応じたモデルを作成し、判別精度を評価しているが、判別させるテストデータは判別結果を公正に評価するため、教師データと重複しないデータを使用している。なお、CNNの解析にはハイスペックPCが必要となる。表1に、モデル作成の深層学習に利用したPCの実行環境およびソフトウェアを示す。

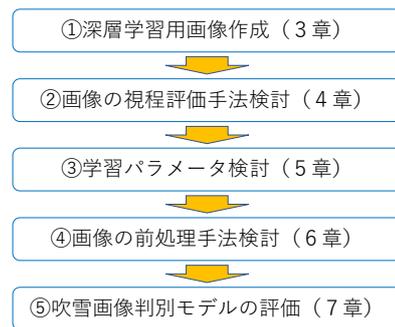


図7 深層学習による視程障害判別実験の手順

表1 CNNの実行環境

項目	仕様等
CPU	Xeon Bronze
GPU	Quadro P6000
Software	ViDi Suite (COGNEX 社製)

3. 深層学習用画像作成

図8に、動画を撮影した一般国道を示す。各動画は、平成26年1~3月、平成26年12月~平成27年3月の午前9時から午後5時の間に撮影されたものであり、いずれも道路周辺に積雪があるものを使用した。動画から静止画像を切り出すタイミングは、視程計の1秒データに合わせて1秒とした。なお、切り出した静止画像からワイパーの写り込み、ピントずれ、トンネル内の画像および日没後の周囲が暗い画像など吹雪の認

識に支障となると考えられる画像は除外した。切り出す静止画像の解像度は 1,280×720pixel とし、色調はカラー (RGB) とした。動画から切り取られた画像の総数は 18,800 枚程で、そこからワイパーの映り込み等によりモデル作成に適さない画像を任意に除外し、モデル作成には 13,000 枚程の画像を用いた。

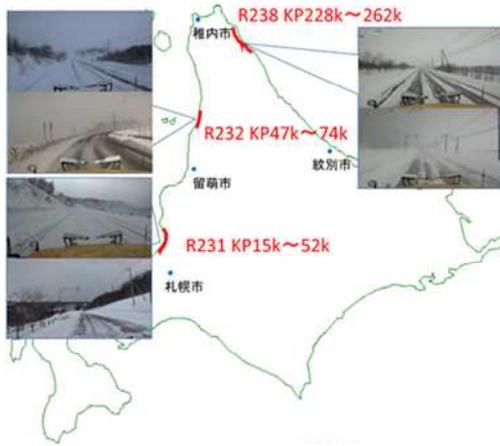


図 8 動画の撮影箇所

4. 画像の視程評価手法の検討

車載カメラで撮影された画像と、視程計で計測された視程値が一致していることが望ましいが、視程計による測定範囲は車両フロント部分における装置の十数 cm の極狭い範囲に限られる¹³⁾。そのため、遠方までの視野を対象とする画像と、視程計による視程値の違いが生ずることがある (図 9)。



図 9 視程計測値と吹雪状況が相違している画像
視程計:86m (視程ランク E)
画像を目視で読み取った視程:視程ランク B

こうしたデータを使用して学習したモデルでは、正しく吹雪を判別できないと考えられる。そこで、画像の視程を適切に評価する手法を検討した。また、車載カメラで撮影された画像は、道路の平面、縦断線形、時刻等により道路に対する画角や見通し、情景の明暗が複雑に変化する。

4. 1 視程の評価手法の検討

画像の視程を適切に評価するため、撮影された画像の時刻から継続的に走行して得られた視程データを含めることで、吹雪の奥行きを評価することとした。すなわち、次の3つの手法 (図 10) で求めた画像の視程評価値を用いたモデルとした。これらのモデル毎の判別精度を評価することで、画像と組み合わせる視程評価値の決定手法を検討した。なお、表 2 に、画像の視程評価手法を検討するためのソフトウェアの学習パラメータを示す。設定した学習パラメータは、Feature Size (以降では、特徴サイズとする)、Color および Count Epochs (以降では、エポック数とする) である。

- ▶ 計測視程 1:画像切り出し時刻の視程値
- ▶ 計測視程 2:画像切り出し時刻から 4~7 秒までの間の視程値の平均 (50m 程度走行)
- ▶ 計測視程 3:画像切り出し時刻から 9 秒後までの視程値の平均 (時速 40km/h で 100m 程度走行)

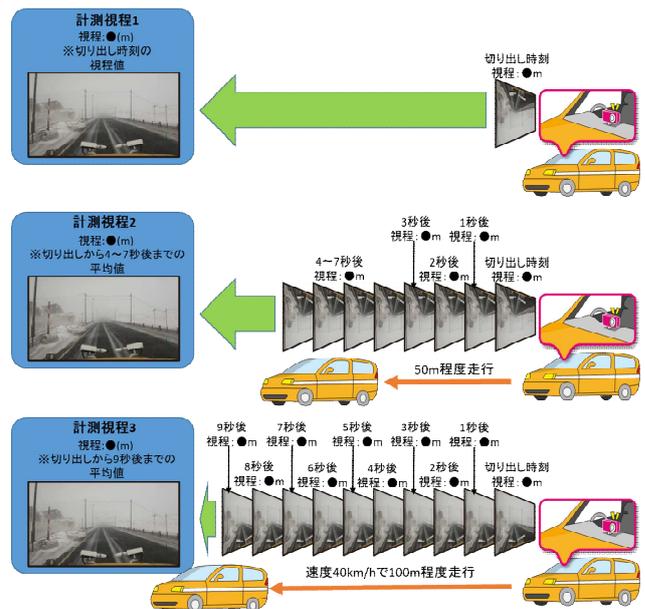


図 10 画像の視程評価手法

表 2 ViDi Suite の学習条件の設定値

Feature size	200 pixel
Color	3 (RGB カラー)
Count epochs	50 回 (デフォルト)

4. 2 視程評価手法検討の教師データ

作成した画像を前節の 3つの手法により視程に応じた A~E の視程ランクに振り分けた。しかし、視程ランク A~E それぞれの画像枚数には偏りがある。視程

ランク A~E の画像データ数が異なるとデータ数の多い視程ランクに判定が偏り、公正な判別の妨げとなる可能性がある。そこで、全ての視程ランクにおける教師データの画像枚数を同一の 250 枚とした。この画像枚数は、最もデータ数の少なかった計測視程 3 のランク E の 127 枚を水平反転によりデータ補充し確保が可能な枚数である。画像枚数が 250 枚を超えているランクは、ランク毎の全データ序列に乱数を与え、ランダムに 250 枚を抽出した。また画像は、画角内に写り込んだ地物に対する方向が統一されていない。あらかじめワイパーの映り込み等によるピントずれ等を除外していても、車体ボンネットが大きく写り込んでいる画像とほとんど写っていない画像が混在していた。車体ボンネットの有無による判別への影響を避けるため、教師データに用いる画像の対象領域（以下、対象領域）を図 11 のとおり画像上端から 82% に設定した（図 11 の赤い部分）。



図 11 対象領域の設定範囲

4.3 作成モデルの評価手法

3 つの手法で評価視程を変えたモデルの判別精度は、2.2 節の評価項目により各モデルを評価した。評価にあたり、モデル作成に利用した画像数が、1 つの視程ランク当たり 250 個と、一般的な深層学習のデータ数としては少ないため、作成モデルの評価は、データ数が少ない場合の評価手法として用いられる k-分割交差検証を導入した（図 12）。k-分割交差検証とは、モデル作成に使用したデータを k 個のグループに分割し、k-1 個のグループを教師データとし、残った 1 個のグループを検証データとして、教師データと検証データを入れ替えながら k 回検証を行い、その平均をモデルの評価値とするものである。本検討では k=5 とした。

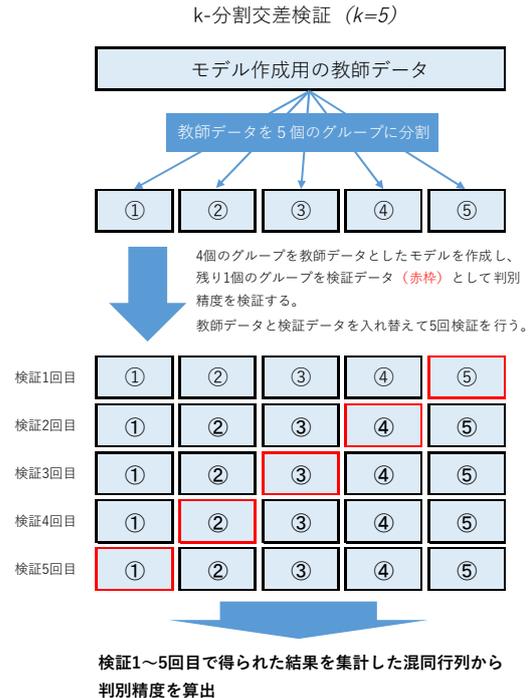


図 12 k-分割交差検証の概要

4.4 視程評価手法検討のテストデータ

前節の評価手法は、教師データを分割して行うものであるため、教師データとは別の画像でも同じ評価を得られるか検証した。検証は、最も判別精度が高いモデルを用いて、2 つのテストを行った。1 つは、モデルが学習した画像と類似した風景の画像を判別できるか検証するためのテストで、これをテスト 1 とする。もう 1 つは、モデルが学習した画像と全く違う景色の画像を判別できるか検証するためのテストで、これをテスト 2 とする。それぞれのテストには、次のデータを用いた。モデル作成に使用した教師データとテストデータの関係を表 3 に示す。

- ▶テスト 1:教師データと同じエリアの画像
- ▶テスト 2:教師データと異なるエリアの画像

なお、テスト 1 の画像と教師データの画像は同じ路線・区間であるが、それぞれ重複しないデータを使用している。

表 3 モデル作成およびテストに使用した路線・区間

データ区分	方面	R231	R232	R238
モデル作成用	上り	KP25k~52k	KP47k~74k	KP228k~262k
	下り	KP15k~52k		
テスト1用	上り	KP25k~52k	KP47k~74k	KP228k~262k
	下り	KP15k~52k		
テスト2用	上り	KP15k~24k		
	下り			

4. 5 視程評価手法の解析結果

4. 5. 1 k-分割交差検証の判別結果

画像の組み合わせる視程評価手法を検討するため、評価手法を変えた3つのモデルの判別結果を表4に示す。なお、表内の赤丸は、3つのモデルでの項目毎の最高スコアを示す。その結果、計測視程1で作成したモデルは、Accuracyが58.2%であり、3つのモデル中で最低であった。また、ランクD、EのRecallが低いことから、視程200m未満の視界がかなり悪い状態(吹雪発生)を判別できておらず、実用的な面で問題があると考えられる。次に、計測視程2で作成したモデルは、Accuracyが76.3%であり、3つのモデル中で2番目に良い値であった。また、ランクD、EのRecallも概ね良好であった。最後に、計測視程3で作成したモデルは、Accuracyが82.3%であり、3つのモデル中で最高であった。また、全ランクのRecall、Precision、F-scoreも3つのモデル中で最高であった。

以上のことから、画像に組み合わせる視程評価値は、「画像切り出し時刻から9秒後までの視程値の平均(計測視程3)」を用いることが適していると考えられる。

4. 5. 2 テスト1の判別結果

前項で最も評価の良かった計測視程3のモデルを使用し、教師データと同じエリアの画像を用いたテスト1の判別結果を表5に示す。Accuracyは82.8%と高い精度で吹雪を判別できていた。また、ランク毎のRecall、Precision、F-scoreも高い値であり、k-分割交差検証の判別結果と傾向が概ね一致している。

4. 5. 3 テスト2の判別結果

前項と同様に、計測視程3のモデルを使用し、教師データと異なるエリアの画像を用いたテスト2の判別結果を表6(上表:成績表)に示す。Accuracyは46.0%と低い判別精度であった。特に、ランクEのRecall、Precision、F-scoreは0%であり、著しい視界不良を全く判別できなかった。しかしながら、不正解の内訳が計測値に対して予測値のずれが1ランクだけのものが多くあった(表6下表:混同行列)。現場の状況を画像で確認すると、吹雪の濃淡以外に画像の景色や前方車両の写り込みといった点が誤った判別の原因となっていることが確認できた。

4. 5. 4 画像の視程評価手法検討の考察

画像に組み合わせる視程評価値は、計測視程3のモデルの判別精度が最も高かったことから、画像切り出し時刻から9秒後までの視程値の平均とする手法が適していると考えられる。

テスト1の結果から、モデルが学習した画像と風景

が類似した画像は、画像から吹雪を良好に判別できていることが分かった。また、テスト2の結果から、モデルが学習した画像と風景が異なるエリアの画像は、画像から吹雪を判別できていないことが分かった。しかしながら、テスト2の不正解の内訳が計測値に対して予測値が1つだけずれただけだったものが多かったことから、教師データの構成等を改善することにより、精度が向上する可能性がある。

表4 k-分割交差検証の判別結果

計測視程1: 画像切り出し時刻の視程値

ランク	Recall (再現率)	Precision (適合率)	F-score (調和平均)	accuracy (正解率)
A	81.2%	73.6%	77.2%	58.2%
B	69.6%	77.7%	73.4%	
C	43.2%	54.0%	48.0%	
D	53.2%	41.4%	46.6%	
E	44.0%	59.8%	50.7%	

計測視程2: 画像切り出し時刻から4~7秒までの間の視程値の平均

ランク	Recall (再現率)	Precision (適合率)	F-score (調和平均)	accuracy (正解率)
A	88.4%	88.4%	88.4%	76.3%
B	78.4%	71.8%	75.0%	
C	64.4%	69.7%	66.9%	
D	67.2%	71.5%	69.3%	
E	83.2%	84.9%	84.0%	

計測視程3: 画像切り出し時刻から9秒後までの視程値の平均

ランク	Recall (再現率)	Precision (適合率)	F-score (調和平均)	accuracy (正解率)
A	88.4%	89.8%	89.1%	82.3%
B	82.0%	77.7%	79.8%	
C	72.4%	81.5%	76.7%	
D	82.8%	76.4%	79.5%	
E	86.0%	89.2%	87.6%	

表5 テスト1の判別結果

ランク	Recall (再現率)	Precision (適合率)	F-score (調和平均)	accuracy (正解率)
A	84.0%	87.5%	85.7%	82.8%
B	74.0%	80.4%	77.1%	
C	76.0%	80.9%	78.4%	
D	98.0%	75.4%	85.2%	
E	82.0%	100.0%	90.1%	

表 6 テスト 2 の判別結果

ランク	Recall (再現率)	Precision (適合率)	F-score (調和平均)	accuracy (正解率)
A	100.0%	90.9%	95.2%	46.0%
B	40.0%	45.5%	42.6%	
C	46.0%	30.3%	36.5%	
D	44.0%	30.1%	35.8%	
E	0.0%	0.0%	0.0%	

混同行列 (Confusion Matrix)		予測					分類不可
		吹雪未発生			吹雪発生		
計測値	吹雪未発生	A 1000m以上	B 500m以上 1000m未満	C 200m以上 500m未満	D 100m以上 200m未満	E 100m未満	
	A	50	0	0	0	0	0
	B	4	20	20	5	0	1
	C	0	17	23	10	0	0
	D	0	3	24	22	1	0
E	1	4	9	36	0	0	

5. 学習パラメータの検討

5.1 概要

前章までの結果を踏まえて、吹雪状況の判別に重要な影響を与えると推測される Feature Size と、モデルの過学習を抑えるため Count Epochs を検討対象とした。特徴サイズは AI が着目する画像範囲であり、エポック数は学習回数である。図 13 に検討手順の概要を示す。まず、特徴サイズの値を変えたモデルを複数作成し、2.2 節の評価項目により各モデルを評価した。次に、特徴サイズの最適値を用いて、エポック数を変えたモデルを複数作成し、各モデルを評価した。



図 13 学習パラメータの検討手順

5.2 学習パラメータ検討の教師データおよびテストデータ

教師データの構成等を次のとおり見直した。テストデータは、教師データの見直しで作成したデータ群から教師データと重複しないデータをランダムに抽出した。

- ▶ 静止画切り出しのタイミングを 0.1 秒とし、画像数が少ないランク D、E の画像を増強
- ▶ 前方車両が大きく写り込んでいる画像を除外
- ▶ 目視により読み取った視程と、画像の視程評価値に 2 ランク以上の乖離がある画像を除外

学習パラメータ検討に用いるデータ数を表 7 に示す。なお、ランク A は視程 1,000m 以上で視程障害が発生していない状態であるため、検討の対象外とした。

増強したデータ画像の総数は 8,854 枚である(表 7)。この 8,854 枚の画像のうちのランク B~E それぞれの画像枚数には偏りがあり、最も偏りが大きかったのはランク D の画像枚数が 3,405 枚に対して、ランク C の画像枚数は 779 枚であった。そこで、全てのランクにおける教師データの画像枚数をランク毎に 400 枚、テストデータの画像枚数をランク毎に 100 枚とした。教師データ、テストデータの抽出はランク毎の全データ序列に乱数を与え、ランダムに抽出した。

表 7 学習パラメータ検討に用いるデータ数

データ種別	データ数				計
	吹雪未発生		吹雪発生		
	B	C	D	E	
教師データ	400	400	400	400	1,600
テストデータ	100	100	100	100	400
未使用	1,708	279	2,905	1,962	6,854
計	2,208	779	3,405	2,462	8,854

5.3 学習パラメータの設定値

5.3.1 特徴サイズ検討の学習パラメータ

特徴サイズは、識別したいシンボルの大きさに応じて設定するものである。しかし、画像に写っている吹雪には、その大きさを示す指標がない。そこで、道路標識を識別したいシンボルと仮定し、特徴サイズの範囲を決定した。画像に写っている約 100m 先の道路標識のサイズは、画像全体との比で換算したところおよそ 200pixel である。そこで、AI ソフトウェアにデフォルトで設定されている 60pixel の 1/2 である 30pixel を下限、200pixel の 2 倍の 400pixel を上限として、特徴サイズを検討した。

画像特徴サイズを検討するモデルの AI ソフトウェアの学習パラメータは、表 8 のとおり設定した。

表 8 ViDi Suite の学習条件の設定値

Feature size	表 9 による
Color	3 (RGB カラー)
Count epochs	50 回 (デフォルト)

表 9 特徴サイズの設定値

Feature Size (単位 : Pixel)							
30	60	90	120	150	200	300	400

5. 3. 2 エポック数検討の学習パラメータ

エポック数は、モデルの学習不足、過学習を抑えるために検討が必要であるが、学習に使用する画像や特徴サイズなどの学習パラメータ設定値によって適正な値が変わるため、基準となる値がない。そこで、AI ソフトウェアのデフォルトで設定されている 50 回の 1/10 である 5 回を下限、4 倍である 200 回を上限として、エポック数を検討した。

エポック数を検討するモデルの AI ソフトウェアの学習パラメータを表 10 のとおり設定した。

表 10 ViDi Suite の学習条件の設定値

Feature size	200 pixel
Color	3 (RGB カラー)
Count epochs	表 11 による

表 11 エポック数の設定値

Count Epochs (単位 : 回)							
5	10	25	50	75	100	150	200

5. 4 学習パラメータ検討の実験結果

5. 4. 1 特徴サイズ検討の判別結果

モデル作成の学習パラメータである特徴サイズの最適値を検討するため、特徴サイズを変えた 8 つのモデルの判別結果を図 14 に示す。

モデルの Accuracy が最も高かったのは、特徴サイズが 150pixel および 200pixel のモデルであった。Recall、Precision および F-score はランク毎に変化の傾向が異なっていた。吹雪判別は、吹雪の発生を判別できることが重要であるため、その境の吹雪発生側であるランク D の Recall に注目した。ランク D の Recall が高かったモデルは、特徴サイズが 200pixel のモデル

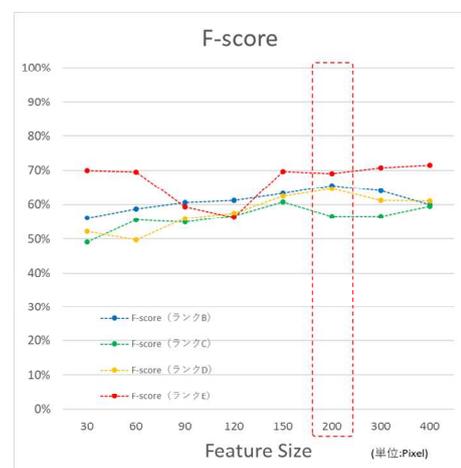
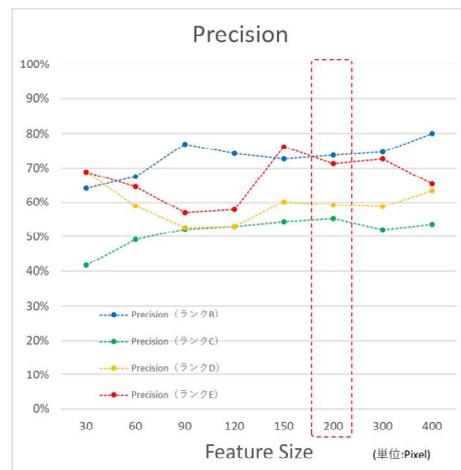
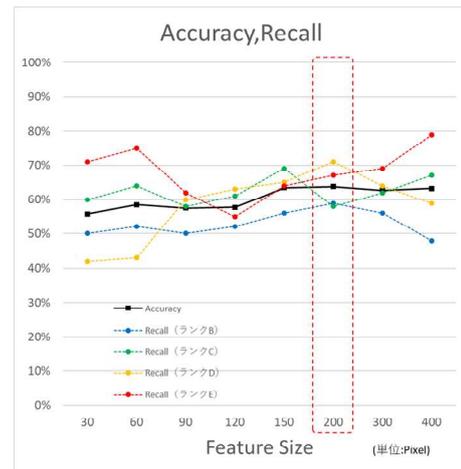


図 14 特徴サイズを変更した判別結果

であり、Accuracy も他のモデルより高かったことから、特徴サイズは 200pixel が適していると考えられる。なお、特徴サイズは、画像の解像度に依存し最適値が変化するため、得られた結果は、本研究のモデル作成に用いた画像に限るものである。

5. 4. 2 エポック数検討の判別結果

モデル作成の学習パラメータである特徴サイズの

最適値を検討するため、特徴サイズを変えた8つのモデルの判別結果を図15に示す。なお、学習パラメータの特徴サイズは、前項の結果から200Pixelとした。

モデルのAccuracyが最も高かったエポック数は150回で64%、最も低かったエポック数は5回で58%であり、エポック数の違いによる大きな差は見られなかった。ランク毎のRecallではランクB、C、Dがエポック数の増加に伴いRecallが上昇する傾向が見ら

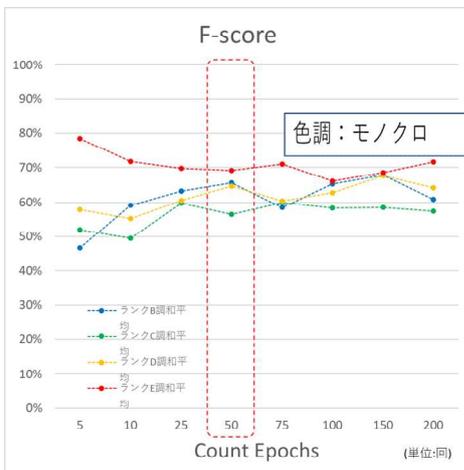
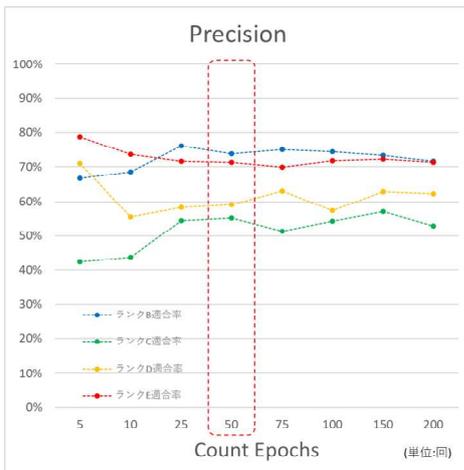
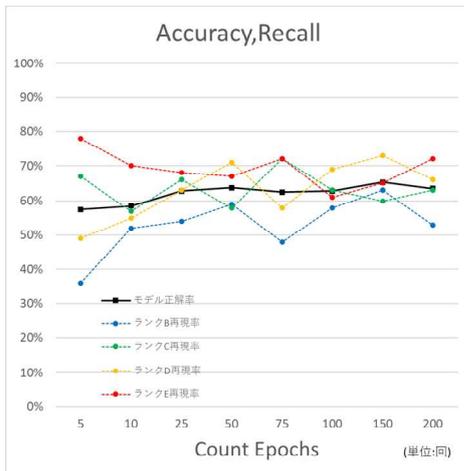


図15 エポック数を変更した判別結果

れたが、ランクEはエポック数の増加によりRecallが下降する傾向が見られた。ランクEは著しい吹雪が発生している画像であり画像の情景に白色が多く含まれるため画像毎の背景の変化が少ない。そのため、他ランクよりも過学習が起きやすかったと思われる。

ランクEの過学習を最小限に抑えるにはエポック数を小さい値にすることが有効となる。しかしながら他ランクではエポック数150回まで過学習の傾向が見られないことから、各ランクの再現率が60~70%程度に集中してランク毎の偏差が小さくなっているエポック数50回が吹雪視程のランク判別に適していると考えられる。

6. 画像の前処理手法検討

6.1 概要

教師データやテストデータに用いる画像の色調や画角が吹雪の視程判別に与える影響を検討するため、画像の前処理を変えた2つのモデルを作成し評価した。前処理は、色調をカラーからモノクロに変更する手法



図16 無加工および前処理加工した画像 (代表)

と、「ボンネットや地吹雪の判別に不向きな遠方の道路構造物より上空の写り込みをカットした画角」にトリミングする手法とした。各手法の代表画像を図 16 に示す。

6. 2 画像の前処理検討の教師データ、テストデータおよび学習パラメータ

教師データとテストデータは、前章と同じデータを使用した。また、学習パラメータを表 12 のとおり設定した。

表 12 ViDi Suite の学習条件の設定値

Feature size	前章の最適値
Color	1 (モノクロ) 又は 3 (RGB カラー)
Count epochs	前章の最適値

6. 3 画像の前処理手法検討の実験結果

画像の色調や画角が吹雪の視程判別に与える影響を検討するため、画像の前処理を変えた 2 つのモデルの判別結果を表 13 に示す。なお、学習パラメータは前章の検討結果から、特徴サイズを 200pixel、エポック数を 50 回とした。

モデルの Accuracy が最も高かったのは①の前処理していない解像度 1280×720pixel のカラー画像で作成したモデルであった。ただし、本研究の目的である吹雪の程度を判断するためには、著しい視程障害であるランク E を適切に評価する必要がある。そのため、ランク E に注目すると、ランク E の Recall が最も高かったのは③のトリミングした画像で作成したモデルであった。これはトリミングにより画像の背景に白色の占める割合が大きくなることで、ランク E の特徴が顕著になったと考えられる (図 17)。以上から、吹雪の程度の判断を目的としたモデルの作成にはトリミングした画像を用いることが有効と思われる。

一方、吹雪発生の検知は、前処理の有無にかかわらず高い Accuracy であったが、最も高かったのは①の前処理していない画像で作成したモデルであった。③は判別結果の混同行列 (図 18) からランク D をランク C として誤って判別した数が多いことが分かった。これはトリミングにより画像の背景に白色以外の色が占める割合が大きくなったことが原因の 1 つにあると思われる (図 18)。以上から、吹雪の発生 (視程 200m 未満) の検知を目的としたモデルの作成には、①のように色調がカラーで、特定の画角でトリミングしない画像を用いることが有効と思われる。

表 13 画像の前処理を変えた判別結果

①前処理なし

(解像度:1280×720pixel、カラー画像)

ランク	Recall 再現率	Precision 適合率	F-score 調和平均	Accuracy 正解率
B	59%	74%	66%	64%
C	58%	55%	57%	
D	71%	59%	65%	
E	67%	71%	69%	

吹雪発生の検知	Recall 再現率	Precision 適合率	F-score 調和平均	Accuracy 正解率
吹雪未発生 ランクB・C	90%	97%	93%	93%
吹雪発生 ランクD・E	97%	91%	94%	

②Color 変更あり、トリミングなし

(解像度:1280×720pixel、モノクロ画像)

ランク	Recall 再現率	Precision 適合率	F-score 調和平均	Accuracy 正解率
B	26%	79%	39%	50%
C	72%	44%	55%	
D	46%	47%	47%	
E	57%	54%	55%	

吹雪発生の検知	Recall 再現率	Precision 適合率	F-score 調和平均	Accuracy 正解率
吹雪未発生 ランクB・C	88%	89%	88%	88%
吹雪発生 ランクD・E	89%	88%	88%	

③Color 変更なし、トリミングあり

(解像度 1280×360pixel、カラー画像)

ランク	Recall 再現率	Precision 適合率	F-score 調和平均	Accuracy 正解率
B	51%	74%	60%	61%
C	62%	48%	54%	
D	57%	58%	57%	
E	73%	73%	73%	

吹雪発生の検知	Recall 再現率	Precision 適合率	F-score 調和平均	Accuracy 正解率
吹雪未発生 ランクB・C	90%	91%	90%	90%
吹雪発生 ランクD・E	90%	90%	90%	



図 17 各ランクのトリミングした画像 (③代表)

①前処理なし

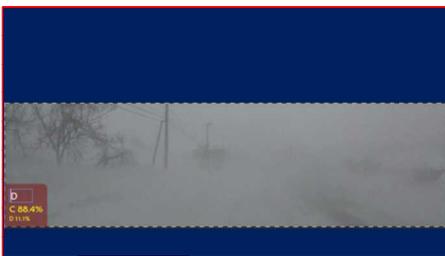
(解像度:1280×720pixel、カラー画像)



混同行列		予測値				分類不可	
		吹雪未発生		吹雪発生			
		B	C	D	E		
計測値	吹雪未発生	B	59	41			1
		C	21	58	16	4	
	吹雪発生	D		6	71	23	
		E			33	67	

③Color 変更なし、トリミングあり

(解像度 1280×360pixel、カラー画像)



混同行列		予測値				分類不可	
		吹雪未発生		吹雪発生			
		B	C	D	E		
計測値	吹雪未発生	B	51	49			
		C	18	62	15	5	
	吹雪発生	D		18	57	22	3
		E			27	73	

図 18 ランク D の判別結果

7. まとめ

吹雪視程障害の要対策箇所を低コストかつ効率的に抽出することを目的に、AI 技術を活用して、車に搭載されたカメラで撮影した画像から視程障害の発生を検知し、さらに、その程度を数段階に判別する技術の検討を行った。その結果、以下のことを明らかとした。

- 1) 画像に組み合わせる視程は、”画像切り出し時刻から 9 秒後までの視程の平均”を用いたモデルが最も判別精度が高かった。
- 2) モデルが学習したエリアと同じエリアの画像は、吹雪の判別精度が高いが、異なるエリアの画像は判別精度が低かった。しかしながら、1 ランク違いでの誤判別が多く、教師データの構成等を改善することにより、精度が向上する可能性がある。
- 3) 本研究で用いた画像では、AI ソフトウェアの学習パラメータである特徴サイズは 200pixel、エポック数は 50 回が最も吹雪判別に適していた。
- 4) 吹雪の程度の判断を目的としたモデルの作成は、「ボンネットや地吹雪の判別に不向きな遠方の道路構造物より上空の写り込みをカットした画角」でトリミングした画像を用いることが有効だと思われる。一方、吹雪発生の検知を目的としたモデルの作成は、色調がカラーで、トリミングしない画像を用いることが有効だと思われる。

本研究では、AI 技術を用いることで車載カメラ画像から吹雪の検知、視程障害の程度の判別が概ね可能であることが分かった。一方でモデルが学習していないエリアの画像では判別精度が低くなる問題があることが分かった。適用エリアを拡大したモデルを構築するには、適用したい道路の吹雪画像と視程データを基にした教師データを作成する必要がある。しかしながら、このようなデータを取得するためには、視程障害移動観測車による繰り返しの調査が必要となるが、モデル構築を目的としてこのような調査を行うことは本末転倒である。今後、吹雪画像判別モデルの適用エリア拡大のためには、敵対性生成ネットワーク技術を用いた擬似的な吹雪画像の作成など、教師データの拡充手法を検討していくことが必要である。

参考文献

- 1) 独立行政法人 土木研究所 寒地土木研究所: 道路吹雪対策マニュアル (平成 23 年度改訂版)
- 2) 岡谷貴之: 深層学習、ISBN-13:978-4061529021、2018.
- 3) Russakovsky, O., J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M.

Bernstein, A. C. Berg, L. Fei-Fei: ImageNet large scale visual recognition challenge, *International Journal of Computer Vision*, 115(3), 211-252, 2015.

- 4) Robert, R., G. Giancontieri, L. Inzerillo, G. Di Mino: Towards low-cost pavement condition health monitoring and analysis using deep learning, *Applied Sciences*, 10, 319, app10010319, pp.1-22, 2020.
- 5) 丸山記美雄、大浦正樹、木村孝司: 深層学習によるポットホール判別技術に関する基礎的研究、第 61 回 (平成 29 年度) 北海道開発技術研究発表会、2018.
- 6) 原祐輔、内山彰、梅津高朗、東野輝夫: 車載カメラを用いた深層学習による人流推定法の提案、情報処理学会研究報告、Vol.2018-ITS-72、No.3、2018.
- 7) 張 ハンウェイ、佐藤祐大、川崎洋、峰恒憲、小野晋太郎: ドライブレコーダーデータから深層学習により推定した天候情報を用いた急ブレーキ推定、生産研究、73(2)、131-52、2021.
- 8) M.N. Khan, M.M. Ahmed: Development of a novel convolutional neural network architecture named RoadweatherNet for Trajectory-level weather detection using SHRP2 naturalistic driving data, *Transportation Research Record*, 2021 in press.
- 9) 永田泰浩、萩原亮、金田安弘、川村文芳、田宮啓士: 吹雪多発路線における CCTV カメラの画像を利用した視界情報提供システムの検証、土木計画学・論文集 Vol. 26、No.5、2009.
- 10) 公益社団法人日本雪氷学会編: 新版 雪氷事典、古今書院、2014.
- 11) 松沢勝、竹内政夫: 気象条件から視程を推定する手法の研究、雪氷、64(1)、77-85、2020.
- 12) 加治屋安彦、松澤 勝、鈴木武彦、丹治和博、永田泰浩: 降雪・吹雪による視程障害条件下のドライバーの運転挙動に関する一考察、寒地技術論文・報告集、Vol.20、325-331、2004.
- 13) 福沢義文: 車の雪煙による視程障害と側方散乱方式車載型視程計の開発、雪氷、55(1)、29-38、1993.

DETECTION TECHNIQUES FOR POOR VISIBILITY IN SNOW BY IMAGE ANALYSIS OF IN-VEHICLE CAMERA

Research Period : FY2018-2020

Research Team : Cold-Region Road Engineering
Research Group (Snow and Ice)

Author : TAKAHASHI Joji

YOROZU Naoki

KANEKO Manabu

KOKUBU tetsuya

OKOBO Koji

TAKECHI Hirotaka

SAKURAI Toshimitsu

Abstract : In order to efficiently extract specific locations of national highways where require countermeasures for cost-effectiveness development, we studied a method to determine the occurrence of and the severe levels of snowstorms from images of the in-vehicle camera using the convolutional neural network (CNN), typical techniques of artificial intelligence. As a result of several configurations constructed the discrimination models for the visibility, color images trimmed with specific angle of the view can determine the occurrence of poor visibility in snow. We also found that the image should not cropped at a specific angle of view can determine the levels of visibility in snow. Finally, this study suggested that the CNN model is useful for determine the occurrence and the severe levels of poor visibility in snow from the in-vehicle images.

Key words : convolutional neural network, poor visibility in snow, snowstorm countermeasures, natural disasters