

ライブカメラ画像と気象データを用いた機械学習による 霧の視程判定モデルの開発

西 原 大 貴^{*1}・大 橋 唯 太^{*2}

1. はじめに

霧の発生による視程の悪化は、道路・鉄道・航空など公共交通において、様々な障害を引き起こす。視程悪化に伴う交通障害のリスクを軽減するためには、高い精度をもった視程判定・予測の技術が必要となる。近年の気象学分野では、様々な大気現象に機械学習の応用研究が進んでおり、予測の自動化や精度向上に向けた活用が注目されている（例えば、加藤ほか 2019; Hilburn *et al.* 2021; Itoh and Mouri 2021）。霧はカメラなどを通して遠隔でも視認できる大気現象であり、機械学習の適用も期待できる。カメラ画像から吹雪の自動判別は行われているが（大久保ほか 2020），霧に関しては見当たらない。一方で、気象データを用いた機械学習による霧の発生予測は試みられてきているが（例えば、Negishi and Kusaka 2022），研究事例はまだ極めて少ないと見える。そこで本研究は、広島県にある三次盆地で発生する放射霧を例に、画像と気象データそれぞれに対して機械学習による霧の視程判定を試み、精度評価した。

三次盆地は、広島県北部に位置し、東西約40km、南北約25kmの規模をもつ（第1図）。一般に盆地では晴天静穏の夜間に放射霧が発生しやすく（例えば、Roach *et al.* 1976; Gerber 1981; 下畠 1992; 近藤・和田 2004; Ohashi *et al.* 2012），三次盆地は西日本で最大規模の霧の拡大が発生することで知られる（宮田 1994；

西原ほか 2020）。この盆地内には、河川の水位等を監視するライブカメラが国土交通省中国地方整備局によって常設されているため（第2図），その映像から霧の発生を捉えることが可能である。

第3図に、研究フローを示す。一つ目として、深層学習である畳み込みニューラルネットワーク（Convolutional Neural Network, 以下、CNN）を用いて、河川ライブカメラ画像からリアルタイムの視程を推定できる視程判定モデルを開発した。二つ目として、第3節で紹介する4種類の機械学習アルゴリズムを用いて、盆地内で観測された気象データからリアルタイムの視程を推定できる視程判定モデルを開発した。作成されたモデルに対しては精度評価を行い、視程を判定する手法としての有効性を検討した。

ライブカメラ画像による視程判定モデルが適用できない地域では、気象観測データによる視程判定モデルを代替することで、日本全国の様々な地域で発生する霧の視程を広範囲に推定できる期待につながる。

2. ライブカメラ画像による視程判定方法

2.1 ライブカメラ画像による視程判定

視程の分類には、国土交通省三次河川国道事務所のWEBサイト（<http://www.cgr.mlit.go.jp/miyoshi/2023.3.12閲覧>）で公開されている河川ライブカメラ画像を資料として用いた。このうち、三次市中心部（第1図の右図中の白丸）から南西へ約8km離れた瀬谷（第2図）と呼ばれる地域のライブカメラ画像を解析した。対象期間は、2019年10月1日～11月18日と、2020年10月1日～11月18日の計3か月である。その3か月の画像のうち、典型的な放射霧が発生した2019年11月9, 10, 12, 13日の4日間に得た画像を視程判定モデルの最終評価用画像（以降、テスト画像と呼ぶ）とし、

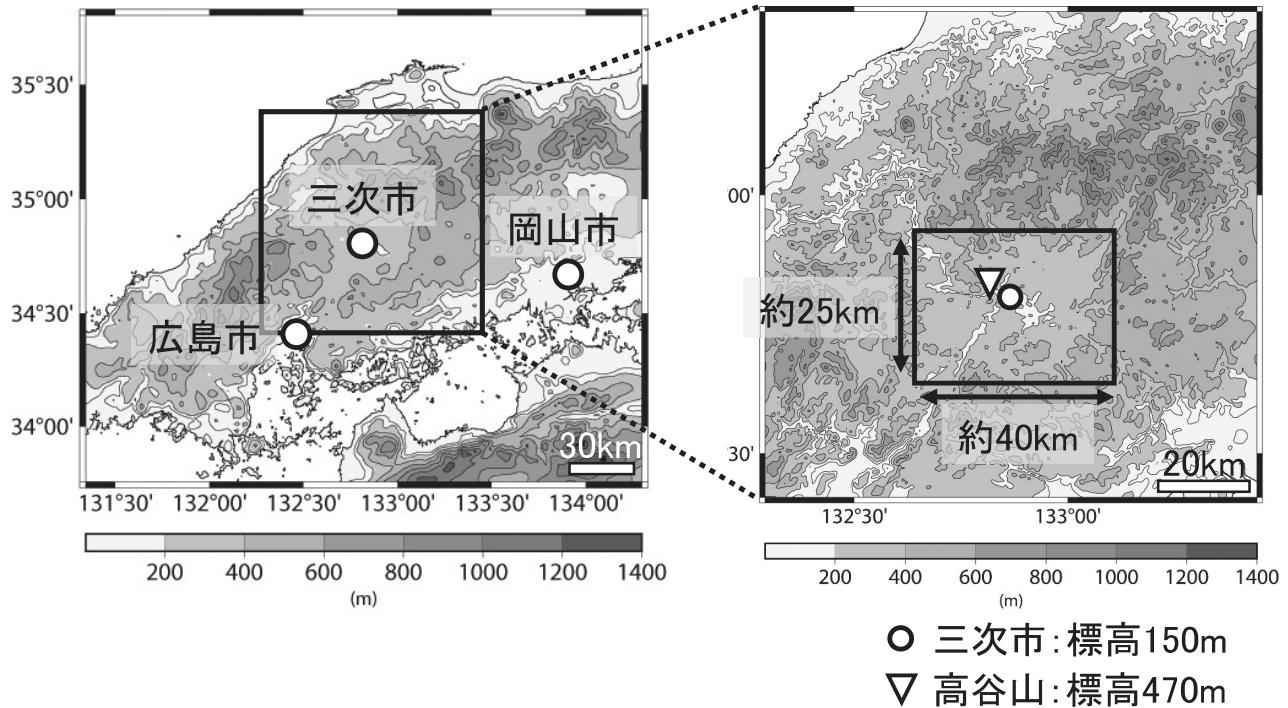
*¹ 岡山理科大学大学院生物地球科学研究科（現：株式会社気象工学研究所）。

*² 岡山理科大学生物地球学部。

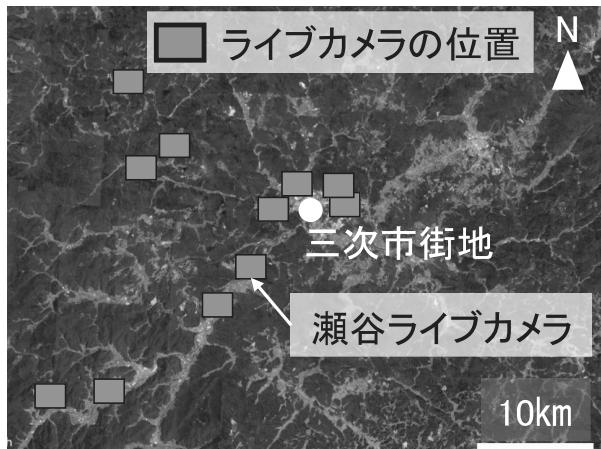
g20gm07nh@ous.jp

—2022年8月22日受領—

—2023年3月14日受理—



第1図 本研究の対象地域である三次盆地の位置。



第2図 国土交通省中国地方整備局によって設置された河川ライブカメラの位置(第1図右の四角で囲んだ領域を拡大)。

残りの画像を教師画像とした。用いたライブカメラ画像の時間間隔は10分であり、画像の総枚数は13,064枚(教師画像12,984枚、テスト画像80枚)にのぼる。

機械学習で必要となる教師画像は、あらかじめ視程ごとに分類して用意しておく必要がある。本研究では、画像に写る橋梁や街灯までの距離を地図上で測定し、その目標物や光源が霧で隠れることを目安に視程を判別した。対象とした瀬谷のライブカメラ画像では、100m、600m、1,000m、1,000m以遠の地点に対

象物が確認されたため、100m未満、100~600m、600~1,000m、1,000m以上の区分で視程を判別できる。本研究では便宜上これらを、視程(VIS)「VIS=100 m」、「VIS=600 m」、「VIS=1,000 m」、「VIS>1,000 m」、「非発生」の5クラスに分類して教師画像を作成した(第4図)。クラス分類して作成した視程ごとの画像枚数を、第1表に示す。

2.2 CNNを用いた視程判定モデルの構築

CNNは、おもに画像認識の分野で高い性能を発揮することで知られる深層学習の一つであり(石川 2018)、入力層、畳み込み層とプーリング層を複数重ねた中間層、出力層によって学習が構成される。CNNによって作成された学習モデルの評価手法には、 k -分割交差検証を用いた。 k -分割交差検証では、教師データを k 個に分割し、 $k-1$ 個のデータを訓練データ、残りの1個のデータを検証データとして、訓練データと検証データを入れ替えながら k 回検証を行い、最終的にその平均をモデルの評価値とする(大久保ほか 2020)。この手法であれば、教師データから検証データを抽出するときに、すべての組み合わせを試行するため、より安定したモデル評価が可能となる(石川 2018)。本研究では、 $k=5$ として教師画像を5分割し、5回の検証結果を平均して視程判定モデルの評価値を算出した。

CNNの構築にはPythonの深層学習ライブラリであ

るKerasを用い、CNNの構造を入力層1層・中間層8層・出力層1層の計10層に設定した。このCNNを用いて、エポック数（学習回数）を100に設定して学習を実行すると、20回以降の学習で正解率（Accuracy）（すべての判定結果のなかで正解した数の割合）が頭打ちとなつたため、エポック数20に設定してCNNによる視程判定モデルを作成することにした。

2.3 テスト画像を用いた

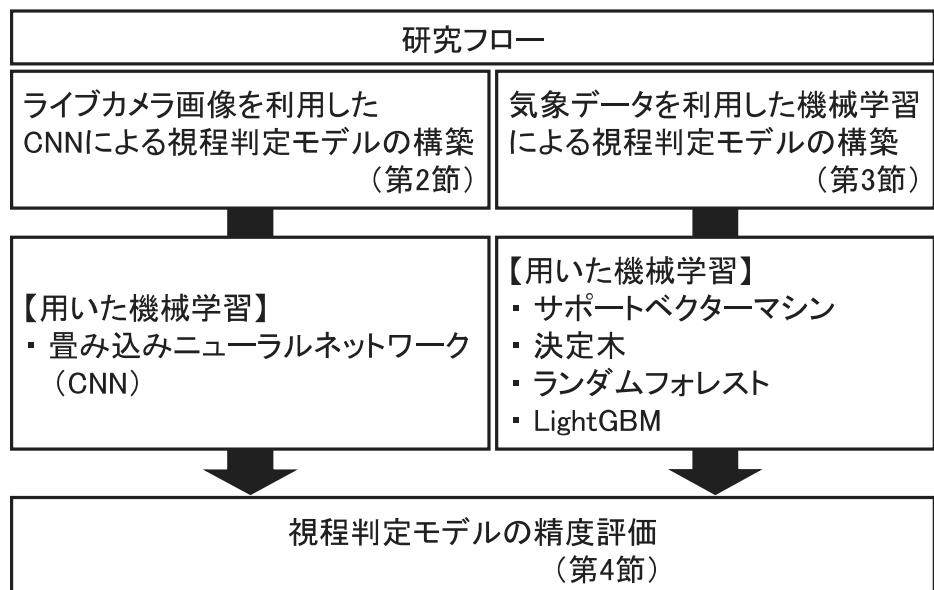
視程判定モデルの評価

2.2節で作成した視程判定モデルを用いて、教師画像に含めなかつたテスト画像（2019年11月9, 10, 12, 13日）を視程クラスごとに20枚ずつ視程を判定し、その正解率をそれぞれ算出した。ただし、テスト画像の期間中に視程100m未満になる霧（濃霧）が発生しなかつたため、VIS=100mの評価は実行できなかつた。

2.4 画像から推定される 視程の検証

視程判定モデルは、ライブ

カメラ画像上で視認できる目標物までの見通し距離に基づく視程であるため、実際に光学距離を測定する視程計による視程とは差異が生じている可能性がある。そこで両者の比較を行う目的で、視程計による視程の直接観測と簡易カメラを用いた霧の撮影を、現地で独自に実施した。観測期間は、2021年11月5日～12月13日の計38日間である。観測に使用した視程計および簡



第3図 機械学習によって視程判定モデルを構築する研究フローの概要。



第4図 教師画像に使用した三次市瀬谷にある河川ライブカメラ画像 (<http://www.cgr.mlit.go.jp/miyoshi/>) の例。(a) 100m未満, (b) 100～600m, (c) 600～1,000m, (d) 1,000m以上, (e) 非発生の5クラスに視程(VIS)を分類した。

第1表 教師画像に用いた5クラスの視程ごとの画像枚数(画像の時間間隔は10分)。

教師画像						テスト画像
視程(VIS)	①100m	②600m	③1,000m	④>1,000m	⑤非発生	4クラス(②~⑤) ×20枚
画像枚数	71	773	761	2,319	9,060	
計	12,984枚(訓練画像:80%, 検証画像:20%)					
	総枚数 13,064枚					

第2表 観測で使用した視程計の概要。

測定機器	MiniBSV (アイ・アール・システム社製)
測定方式	後方散乱
測定算出距離	20m~4 km
サンプリング間隔	10分

第3表 観測で使用した簡易カメラの概要。

測定機器	セキュリティカメラ(400-CAM067) (サンワサプライ社製)
静止画解像度	4,608×3,456ピクセル
画像の種類	日中:可視画像 夜間:赤外画像
撮影間隔	10分

第4表 現地で行った地上気象観測の概要。

観測日	2020年10月21日~11月19日	
観測項目	気温(°C) 相対湿度(%)	気圧(hPa)
測定機器	SHTDL-3 (SysCon社製)	TR-73U (T & D社製)
測定精度	温度:±0.2°C 湿度:±1.5%	気圧:±1.5hPa
測定間隔	5分	10分
サンプル数	8,561	4,282

易カメラの概要を、第2表および第3表に示す。視程計および簡易カメラによる観測は高谷山(第1図)東側のふもとに位置する江の川の河川敷で実施し、これらの機器はいずれも同じ場所に設置した。また、簡易カメラ画像の視程の判別方法は、2.1節で述べたライブカメラ画像の場合と同様に、画像から視認できる目標物や光源等を目安とした。ただし、簡易カメラ画像から推定される視程の範囲はライブカメラ画像とは異なり、100~1,900mであった。

3. 気象観測データによる視程判定方法

3.1 地上気象観測

視程判定モデルの説明変数に用いる気象データを取得するため、三次盆地内で独自に地上気象観測を行った。2020年10月21日~11月19日の期間に、気温(°C)・相対湿度(%)・気圧(hPa)の3要素を測定した(第4表)。このときの観測は、2.1節で使用した瀬谷ライブカメラの設置場所から南西に約1km離れた地点である。

3.2 教師データの作成

気象要素を説明変数、霧画像から判別した5クラスの視程を目的変数にした視程判定モデルを構築するために必要な教師データセットを作成した。説明変数には、放射霧の発生に影響すると既往研究で示されている(Ohashi *et al.* 2012; Negishi and Kusaka 2022)、気温変化量(°C)、湿数(°C)、水蒸気圧(hPa)、風速(m/s)の4要素を選択した。気温変化量は、日中に最も気温が高くなる14時を起点に各時刻の気温差とした。気温の低下量・湿数・水蒸気圧の3項目は、3.1節で述べた現地の観測データから算出し、独自に観測できなかった風速は気象庁の三次メダス局の観測値を用いることにした。いずれの気象要素も1時間ごとで整理したため、総データ数は各要素649となった。

一方で目的変数は、説明変数とした気象データが観測された時刻の視程とし、同様に正時1時間毎の値で整理した。視程データは、2.1節で述べたライブカメラ画像の視程分類と同じ5クラスとしたが、「1,000m以遠」は機械学習で判定する便宜上、「4,000m」の数値を与えた。したがって、「VIS=100m」、「VIS=600m」、「VIS=1,000m」、「VIS=4,000m」、「非発生」と設定した。

対象期間中には、降雨が観測された時間帯があったが、その時間帯は教師データから除外することとした。

3.3 機械学習による視程判定モデルの構築

機械学習には、分類問題でよく用いられる「サポートベクターマシン(SVM)」「決定木」「ランダムフォレスト」「勾配ブースティング」の4種類のアルゴリ

ズム（柴原ほか 2019）を選択し、モデル間の視程判定精度の比較を行った。SVMは、クラスの境界を決定するデータが最大の距離をとる境界線を導き出す手法（マージン最大化）を用いて学習を行う。決定木は、木構造によってデータを段階的に分類する手法であり、ランダムフォレストは、複数の決定木を並列的に用いること（バギング）で高い予測性能を得る手法である。一方の勾配ブースティングは、決定木を直列に配置することで学習精度を高める手法であり、本研究ではこのうち計算速度が速いことで知られる LightGBM (Ke et al. 2017) というアルゴリズムを採用した。

視程判定モデルの評価手法には、2.2節の CNN による視程判定モデルと同様に、 k -分割交差検証を採用した。 $k=5$ として教師データを5分割し、5回の検証結果を平均して視程判定モデルの精度評価を行った。

4. 結果と考察

4.1 ライブカメラ画像による視程判定モデル

4.1.1 モデルの精度とテスト画像を用いた判定

CNN によって構築した視程判定モデルで、 k -分割交差検証による判定精度を検証した結果、平均正解率は95.5%に達した。したがって、十分な精度を得たモデルが作成できたと考え、この視程判定モデルによって、視程クラスごとに20枚ずつ用意した（教師画像に含めなかった）テスト画像の視程を判定させた。

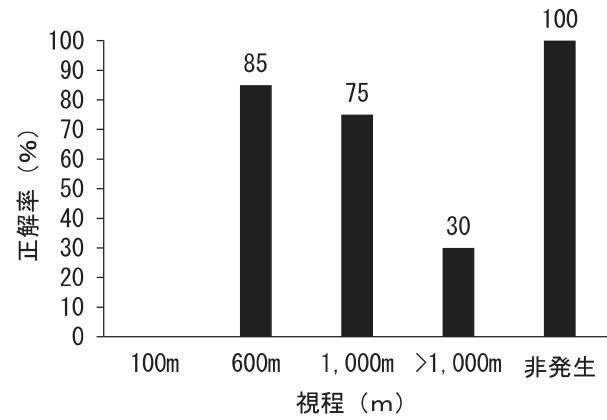
第5図に、テスト画像に対する視程ごとの判定結果（正解率）を示す。視程ごとの正解率は、VIS=600m で85%，VIS=1,000m で75%，非発生では100%の判定精度がそれぞれ得られたが、VIS>1,000m のクラスは正解率が30%となっており、前述の3クラスと比較すると判定精度が悪かった。その誤判定は、すべて「非発生」に分類されていた。早朝に発生している霧と夜間に発生している霧の画像のあいだで判定精度を比較すると、夜間の霧の画像に対して誤判定が多くなる傾向がみられた。教師画像に使用した夜間の画像は、VIS=100 m, VIS=600 m, VIS=1,000 m, VIS>1,000 m の4クラスで早朝の画像枚数よりも多く（夜間の画像枚数は全体の60~70%程度）、学習不足が起因しているとは考えにくい。したがって、夜になると画像が暗く識別が困難になることや、特徴が捉えにくくなる影響が考えられるが、時間帯ごとに視程判定モデルを作成することで判定精度が向上する可能性がある。

4.1.2 画像から推定された視程の検証

第6図に、視程計で測定された視程（図中の実線）と、独自に設置した簡易カメラで撮影された画像から推定した視程（図中の破線）を比較した結果について示す。前日の22時から当日午前10時までの時間帯における推移である。現地で視程を観測した2021年11月5日～12月13日の38日間のうち、(a) 11月6～7日、(b) 11月19～20日、(c) 12月6～7日の3日間を例に述べる。

いずれの日も夜間の視程変化をみると、簡易カメラ画像から推定された視程が1,900m 以遠を記録していないとわかる。これは夜間の簡易カメラ画像では、視程の判別に使用可能な光源までの最長距離が1,900m であったことに起因している。したがって夜間は、1,900m 以遠の視程を比較することができなかった。そこで、視程が1,900m 未満になっている時間帯で比較すると、画像判定と視程計による各視程の変化傾向はよく一致しているといえる。また日の出後は、視程の変化が安定している時間帯（第6図（b）6:30～8:30, (c) 6:45～7:45）で、両者がほぼ一致していた。しかし、霧が消散し始め、視程の変化が大きくなる時間帯では、簡易カメラ画像の視程のほうが短くなる傾向がみられた。

これらの比較から、日の出後に起こる霧が消散する数時間除けば、視程計で測定された気象光学距離とカメラ画像から判定された視認距離の変化傾向は同じと考える。つまり、ライブカメラ画像を利用した視程判定モデルで判断された視程は、光学的な測定距離と大きな差がなく、本研究の視程判定モデルが簡易的な視程の判定手法としても期待できるといえる。



第5図 テスト画像を用いた視程判定モデルによる視程の判定結果（正解率）。

4.2 気象観測データによる視程判定モデル

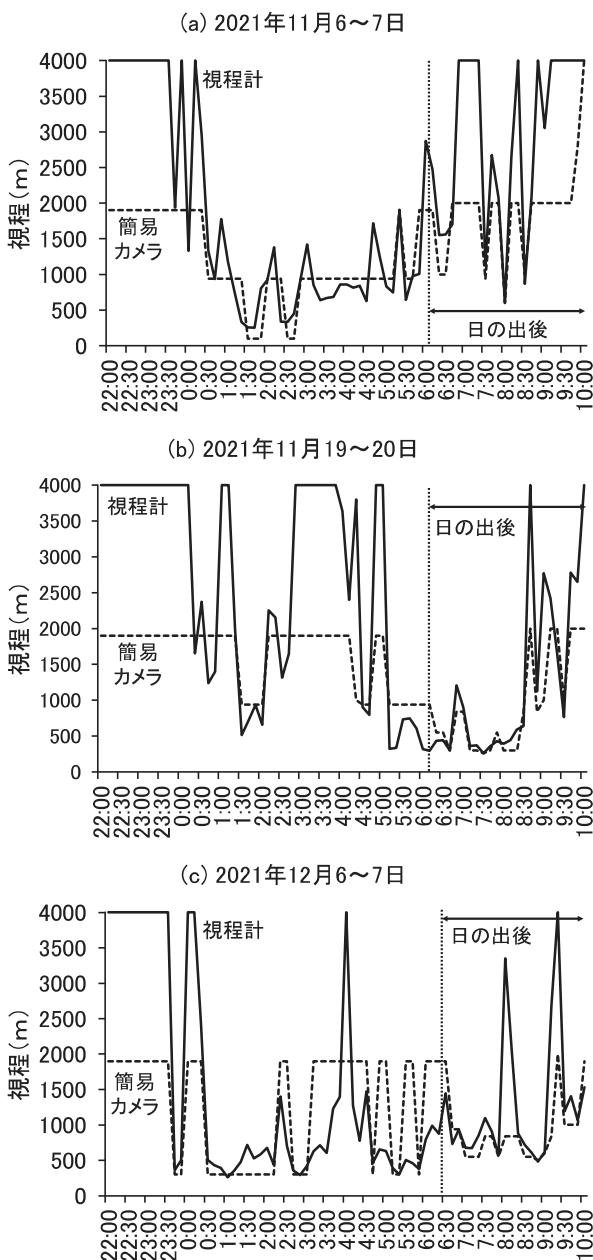
気象データを教師データとした視程判定モデルの精度について、4種類の機械学習を用いた気象要素特徴量ごとの正解率を第5表に示す。機械学習のアルゴリズム間で比較すると、LightGBMで作成したモデルの正解率がやや高い傾向にあった（気温変化量を選択した場合59%，湿数67%，水蒸気圧56%，風速55%）。一方で、最も正解率が高くなった説明変数の選択は湿数

であり、モデルの正解率はSVMを除く3種類のアルゴリズムで67%に達した。したがって、4つの気象要素の中では湿数が視程判定の精度を高める第一選択になると考えられる。湿数は気温と露点温度の差であり、空気の飽和状態を表す指標といえ、霧の発生原理から考えてもモデルの精度を高める主要なパラメータになることが示唆される（例えば、Hiatt *et al.* 2012；Gray *et al.* 2019）。

第6表には、複数の気象要素を組み合わせて作成した視程判定モデルの正解率を示す。前述で第一選択になった湿数を基準とし、他の気象要素を投入（変数増加）して正解率がどの程度変化するか確認した。いずれの学習アルゴリズムでも、説明変数として湿数に気温変化量を追加すると正解率が上昇しており、SVMを除いて2～4%程度の精度の向上がみられた（決定木67%→69%，ランダムフォレスト67%→69%，LightGBM 67%→71%）。機械学習のなかではLightGBMで作成したモデルの正解率が、いずれの組み合わせでも高くなり、安定的に70%以上を示す結果が得られた。LightGBMは、アンサンブル学習のなかの勾配ブースティングと呼ばれる手法に基づく機械学習であり、モデル全体の出力から正解データとの残差を求め、その残差を次の学習に用いることで精度を上げるアルゴリズムをもつ（坂本 2019）。この特徴によって、LightGBMのモデルが最も精度良い結果を得たと考えられる。

気象要素の組み合わせでは、気温変化量、湿数、水蒸気圧、風速の4つすべてを投入したモデルの正解率が（SVMを除いて）高くなり（決定木で71%，ランダムフォレストで75%，LightGBMで76%），特にLightGBMによるモデルの正解率が、76%と最も高い精度が得られた。Castillo-Botón *et al.*(2022)による研究では、機械学習を含む複数のモデルから、視程の予測に関して70～82%の正解率が得られている。したがって、本研究の視程判定モデルも同程度の精度になっていることがいえる。

以上の実行結果から、視程を気象要素から判定するには、第一選択で得られた湿数だけでなく、気温変化量、水蒸気圧、風速といった放射霧の形成プロセスに重要とされる要素も加えていくことで、より高い精度のモデルを構築できることがわかった。このうち水蒸気圧の多寡は霧の濃さに関係すると考えられ、視程の推定に重要なパラメータになっている可能性がある（第6表）。



第6図 22時から翌朝10時までに視程計で測定された視程（実線）と簡易カメラ画像から推定された視程（破線）の時間変化。(a) 2021年11月6～7日, (b) 11月19～20日, (c) 12月6～7日の結果。

5. まとめ

本研究では、機械学習を利用した霧の視程判定モデルを作成し、検証をおこなった。畳み込みニューラルネットワーク(CNN)によるライブカメラ画像からの視程判定モデルは、視程ごとの正解率でみると、VIS=600mで85%，VIS=1,000mで75%，非発生では100%の判定精度がそれぞれ得られた。したがって、視程1km未満の霧状態の画像を高い精度で判定できることが確認された。全国各地に存在するライブカメラ画像を利用した視程の判定に機械学習が有効な手段として使えることを示唆する結果といえる。

ライブカメラが設置されておらず、代わりに気象観測が行われている地域では、気象データによる霧の視程判定モデルを構築する手法が考えられた。本研究からは、機械学習のうち勾配ブースティング(LightGBM)と呼ばれるアルゴリズムで視程判定に高い精度が得られた(気温変化量を選択した場合59%，湿数67%，水蒸気圧56%，風速55%)。さらに、気象データとして単一要素ではなく、湿数、気温変化量、水蒸気圧、風速といった霧の発生に寄与する特徴量をできるだけ多く学習モデルに投入することが、精度の向上につながることも明らかとなった(LightGBMですべての変数を用いた場合、正解率は9%精度の向上につながった)。

謝 辞

本研究では、三次河川国道事務所ホームページ(<http://www.cgr.mlit.go.jp/miyoshi/> 2023.3.12閲覧)で公開されている河川ライブカメラ画像を、許可を得て使用させて頂きました。視程計と簡易カメラの設置には、三次市水道局に御協力を頂きました。この場を借りて、心より感謝の意を表します。

参考文献

Castillo-Botón, C., D. Casillas-Pérez, C. Casanova-Mateo, S. Ghimire, E. Cerro-Prada, P. A. Gutierrez, R. C. Deo and S. Salcedo-Sanz, 2022: Machine learning regression and classification methods for fog events prediction. *Atmos. Res.*, 272, 106157, doi:10.1016/j.atmosres.2022.

第5表 4種類の機械学習による気象データを用いた視程判定モデルの正解率。説明変数に1要素を選択した場合の結果。

説明変数	サポートベクターマシン(SVM)	決定木	ランダムフォレスト	LightGBM
・気温変化量	58%	54%	53%	59%
・湿数	64%	67%	67%	67%
・水蒸気圧	55%	52%	51%	56%
・風速	55%	54%	54%	55%

第6表 4種類の機械学習による気象データを用いた視程判定モデルの正解率。説明変数に気温変化量を基準として、複数を追加していく場合の結果。

説明変数	サポートベクターマシン(SVM)	決定木	ランダムフォレスト	LightGBM
・湿数	64%	67%	67%	67%
・湿数 ・気温変化量	62%	69%	69%	71%
・湿数 ・気温変化量 ・水蒸気圧	55%	70%	71%	74%
・湿数 ・気温変化量 ・風速	60%	69%	69%	74%
・湿数 ・気温変化量 ・水蒸気圧 ・風速	55%	71%	75%	76%

106157.

- Gerber, H. E., 1981: Microstructure of a radiation fog. *J. Atmos. Sci.*, 38, 454–458.
- Gray, E., S. Gilardoni, D. Baldocchi, B. C. McDonald, M. C. Facchini and A. H. Goldstein, 2019: Impact of air pollution controls on radiation fog frequency in the Central Valley of California. *J. Geophys. Res. Atmos.*, 124, 5889–5905.
- Hiatt C., D. Fernandez and C. Potter, 2012: Measurements of fog water deposition on the California central coast. *Atmos. Clim. Sci.*, 2, 525–531.
- Hilburn K. A., I. Ebert-Uphoff and S. D. Miller, 2021: Development and interpretation of a neural-network-based synthetic radar reflectivity estimator using GOES-R satellite observations. *J. Appl. Meteor. Climatol.*, 60, 3–21.
- 石川 聰, 2018: Pythonで動かして学ぶ!あたらしい深層学習の教科書 機械学習の基本から深層学習まで. 翔泳社, 792pp.
- Itoh, J. and H. Moura, 2021: Estimating instantaneous surface momentum fluxes in boundary layers using a deep neural network. *AIP Adv.*, 11, 045021.

- 加藤紘熙, 筆保弘徳, 北本朝展, Danlan Chen, 吉田龍二,
竹見哲也, 2019: 深層学習を用いた台風強度推定に対する台風の特徴の影響. 天気, 66, 51–58.
- Ke, G., Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye and T.-Y. Liu, 2017: LightGBM: A highly efficient gradient boosting decision tree. 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA.
- 近藤昌寿, 和田幸一郎, 2004: 判別分析による山形県新庄盆地における放射霧予測. 気象庁研究時報, (56), 71–81.
- 宮田賢二, 1994: 三次盆地の霧の研究. 溪水社, 255pp.
- Negishi, M. and H. Kusaka, 2022: Development of statistical and machine learning models to predict the occurrence of radiation fog in Japan. Meteor. Appl., 29, e2048, doi:10.1002/met.2048.
- 西原大貴, 大橋唯太, 重田祥範, 2020: ドローン技術を活用した霧の鉛直気象情報の観測. 環境情報科学学術研究論文集, 34, 228–233.
- Ohashi, Y., M. Iwashita and M. Kusamoto, 2012: Possibility of prediction for basin fog by using the maximum possible cooling amount and surveillance camera images. J. Agric. Meteorol., 68, 97–106.
- 大久保幸治, 武知洋太, 櫻井俊光, 高橋丞二, 2020: 車載カメラ画像を用いたAI技術による視程ランク判別手法の試行について. 寒地土木研究所月報, 810, 2–10.
- Roach, W. T., R. Brown, S. J. Caughey, J. A. Garland and C. J. Readings, 1976: The physics of radiation fog: I—a field study. Quart. J. Roy. Meteor. Soc., 102, 313–333.
- 坂本俊之, 2019: アンサンブル学習アルゴリズム入門. C & R研究所, 247pp.
- 柴原一友, 築地毅, 古宮嘉那子, 宮武孝尚, 小谷善行, 2019: 機械学習教本. 森北出版, 225pp.
- 下畠五夫, 1992: 飛騨の朝霧について. 天気, 39, 565–567.

Developments of Visibility Decision Model by Machine Learning Methods with Live Camera Images and Meteorological Data

Hiroki NISHIHARA^{*1} and Yukitaka OHASHI^{*2}

^{*1} (Corresponding author) Graduate School of Biosphere-Geosphere Science, Okayama University of Science (Present affiliation: Meteorological Engineering Center, Inc.)

^{*2} Faculty of Biosphere-Geosphere Science, Okayama University of Science

(Received 22 August 2022; Accepted 14 March 2023)
