船舶における全天球画像のデータ収集と 雲形・状態・全雲量の自動判定の試み

森 川 優*1·中 西 波 瑠*²·稲 村 直 樹*3·近 藤 伸 明*3 浩*7 /[\ 希*4·大 澤 渕 浩 輝 夫*5·松 原 崇*6·申 吉 明*8・上 原 昭*9 大 島 裕 邦

要旨

航行中の船舶において、気象観測を行って気象庁に報告する業務は、法律で定められた義務である。観測項目は多岐にわたるが、雲の目視観測業務は自動化されておらず、船舶気象観測指針が定める分類基準に基づく必要があり、観測を行う船員にとって大きな負担となっている。雲の観測業務の自動化には、画像認識で目覚ましい成果を上げている深層畳み込みニューラルネット(CNN)の利用が有望であると考えられるが、過酷な船上環境に耐える観測装置の開発、船舶気象観測指針が定める分類基準に基づくデータセットの構築、同分類基準に準拠する CNNの開発の3つの課題を解決しなければならない。本研究では、この3つの課題を解決し、船舶における雲の自動観測システムを初めて実現した。

1. はじめに

近年, 気象予報のための気象データの収集には気象レーダーや気象衛星が重要な役割を果たすようになってきているが, それでもなお, 地表面からの気象観測の重要性は減じていない. 特に, 四方を海に囲まれている我が国では、明確な基準に基づいた船舶からの気

*1 (連絡責任著者) 学習院大学計算機センター/兵庫県立大学大学院応用情報科学研究科.

〒171-8588 東京都豊島区目白1丁目5-1 学習院大学計算機センター.

morikawa@gakushuin.ac.jp

- *2 株式会社神戸デジタル・ラボ.
- *3 バニヤン・パートナーズ株式会社.
- *4 スカパー JSAT 株式会社.
- *5 神戸大学大学院海事科学研究科.
- *6 大阪大学大学院基礎工学研究科.
- *7 学習院大学計算機センター.
- *8 兵庫県立大学大学院応用情報科学研究科.
- *9 大阪学院大学大学院コンピュータサイエンス研究科.

-2021年5月10日受領--2023年6月29日受理-

© 2023 日本気象学会

象の観測が欠かせない.

実際, 気象庁が定める気象業務法施行規則中では, 気圧・気温・風など11種目の観測項目が規定されているが, 自動化が困難な, 雲の観測は観測員(船員)の 目視と経験に頼っているのが現状である.

雲の分類の基準は、国際機関が発行する国際雲図帳 (World Meteorological Organization 2017)において、雲量・雲形・雲の状態の3種の観点から規定されている。雲量は13段階に分類、雲形は10種雲形(genera)を基本とし、15種(species)、9変種(varieties)、11補足雲形(supplementary features)、4 付属雲(accesory clouds)に分類、雲の状態は下層・中層・上層それぞれ10段階に分類することが求められ、非常に複雑である。船舶気象観測指針(気象庁 2019)は、国際雲図帳に準拠して基準を定めている『気象観測の手引き』(気象庁 1998)は、雨量計・温度計・風向計・乾湿計・露点計・気圧計・日射計・日照計などについては図や写真入りで計測機器の取り扱いを説明しているのに対し、雲については官能に頼った観測方法の記述にとどまっている(第1表~第3表)。

このように、雲の自動観測がすすんでいない事情の

一因には、雲の分類基準が複雑である事実があり、単純化した基準に基づく雲量と雲形の自動判別については従来研究が存在しているものの、雲の状態の自動判別については未着手の状態である。本研究は、雲量・雲形・雲の状態の全ての項目について、船舶気象観測指針が定める複雑な基準に則った自動判別の仕組みの開発を目指す。

自動判別は船舶から撮影した画像を解析することに

よって行われるわけだが、画像解析技術は深層学習の1つである畳み込みニューラルネットワーク(Convolution Neural Network, CNN)によって顕著に進展した。雲形を自動判別する従来研究においても、第4表に見るように、CNNを用いた技術がよい結果を出している。この事実から、本研究においてもCNNによる高度な画像解析技術の活用が鍵となるが、基準に則った雲の分類を可能とするCNNの学習のためのラ

第1表 国際雲図帳 (World Meteorological Organization 2017) において定められている雲形.

層	雲形	出現高度
下層	層積雲 (Stratocumulus), 層雲 (Stratus), 積雲 (Cumulus), 積乱雲 (Cumulonimbus)	地表付近~2km
中層	高積雲(Altocumulus),高層雲(Altostratus), 乱層雲(Nimbostratus)	$2\sim7~\mathrm{km}$
上層	巻雲(Cirrus),巻積雲(Cirrocumulus),巻層雲(Cirrostratus)	5 ∼13km

第2表 国際雲図帳に準拠した気象観測の手引き (気象庁 1998) で定める雲の状態.

レベル			
	下層		
CL-0	層積雲、層雲、積雲、積乱雲のいずれも存在しない状態		
CL-1	発達していない扁平な積雲のある状態		
CL-2	並又はそれ以上に発達した積雲のある状態		
CL-3	積雲が積乱雲に変って間もない状態		
CL-4	積雲からひろがってできた層積雲がある状態		
CL-5	積雲からひろがってできたものでない層積雲がある状態		
CL-6	層雲又は層雲からちぎれた雲片が存在しているか,若しくはそれらが共存している状態		
CL-7	高層雲又は乱層雲が空をおおい,その下にちぎれ層雲又は積雲のある状態		
CL-8	積雲及び積雲からひろがってできたものでない層積雲が共存している状態		
CL-9	雲頂が明らかに巻雲状をなし、多くは、かなとこ状を呈している積乱雲のある状態		
	中層		
CM-0	高積雲、高層雲、乱層雲のいずれも存在しない状態		
CM-1	薄い高層雲がある状態		
CM-2	厚い高層雲又は乱層雲がある状態		
CM-3	薄い高積雲が単層をなして存在している状態		
CM-4	レンズ型をした高積雲が散在して存在している状態		
CM-5	帯状又は薄い層状をなし、次第に天空にひろがり、通常全般的に厚さも増していく高積雲のある状態		
CM-6	積雲又は積乱雲からひろがってできた高積雲のある状態		
CM-7	二重の層をなした高積雲,高層雲をともなった高積雲又は部分的に高積雲の特徴を示す高層雲のある状態		
CM-8	塔状を呈してつらなった高積雲又は房状の高積雲がある状態		
CM-9	種々の高さに雲片が散在する高積雲で、通常ところどころに濃い巻雲も見られる状態		
	上層		
CH-0	巻雲,巻積雲,巻層雲のいずれも存在しない状態		
CH-1	繊維状の巻雲が分散していて増加しない状態		
CH-2	積乱雲から生じたものでない濃い巻雲のある状態		
CH-3	積乱雲から生じたもので、通常かなとこ状を呈している巻雲のある状態		
CH-4	厚みを増しながら増加しているかぎ状又は房状の巻雲のある状態		
CH-5	巻雲及び巻層雲又は巻層雲のみの層であって、次第にひろがってきているが、まだ地平線上45度に達していない 状態		
CH-6	巻雲及び巻層雲又は巻層雲のみの層であって,次第にひろがってきて,地平線上45度を超えている状態		
CH-7	巻層雲が全天をおおっている状態		
CH-8	巻層雲が増加せず全天をおおっていない状態		
CH-9	少量の巻雲又は巻層雲を伴うこともあるが,主として巻積雲のみが存在する状態		

ベル(答え)付きデータセットが存在しないことから、データセットを準備することが本研究で解決するべき 課題の第一である。CNNの学習には大規模なデータセットが必要であるが、船舶気象観測指針が定める基準に従うことにより分類結果(ラベル)は多岐にわたるため、一般には更に大規模なデータセットが必要である。しかしながら、船舶からの観測に依存するデータセットの作成では、自ずと、データセットのサイズに制限が存在するので、制限された規模のデータセットで効率的な学習を実現しなければならない。

この問題を解決するための手法のひとつとして、本研究では、近年研究が進んだファインチューニング (Tan et al. 2018) の技法を積極的に利用する. ファインチューニングは、事前学習済みの汎用の深層ニューラルネットワークを比較的小規模のデータセットによって追加学習させる技術である.

第3表 気象庁 (2019) において定められている船舶 気象観測指針が示す雲のラベル. 不明とは, 霧・煙霧・黄砂などで天球が見えない雲の状態, 上位層が下位層の雲に覆われて観測できない雲の状態を指す.

層	雲形	雲の状態	雲量
下層	な積層積 層 動 電 動 電 動 電 気 雲 悪 の 悪 の 男 の 男 の の の の の の の の の の の の の	C _L -0~9, 不明	
中層	な高 高 属 雲 三 高 層 雲 三 明 明 明 明 明 明 明 明 明 明 明 明 明 明 明 明 明 明	C _M −0~9, 不明	0, 0 ⁺ , 1, 2,, 9, 10 ⁻ , 10
上層	な 巻 養 養 養 層 雲 不明	C _H -0~9, 不明	

第4表 従来研究の比較. 正解率は5節で定義. 雲量予測におけるラベル数2は、ピクセル毎の雲の有無を表す.

文献	対象	ラベル数	学習器	正解率
Yang et al.(2019)	雲量	2	CNN	0.90
Zi et al.(2018)	雲量	2	CNN+SVM	0.89
Zhang et al. (2018)	雲形	11	CNN	0.88
Ye et al.(2017)	雲形	9	CNN+SVM	0.87
Huertas-Tato et al. (2017)	雲形	11	ランダムフォレスト	0.71

現実には、船舶で収集するデータ量の制限と数千種に及ぶラベルの多様性を考えると、単にファインチューニングを利用するだけでは、十分な学習はなお困難であると考えられる。そこで、ラベルを7種類のサブラベルに構造化し、サブラベル間の相関を学習しつつ特徴抽出を行う共通のCNNを、7つの独立した全結合ネットワーク(Fully Connected Network、FC)に接続する独自のアーキテクチャにより、少ない学習データと多様なラベルの条件のもとでも、良好な判別性能を実現することを狙う、手順としては、本研究では以下に述べる項目を実施する。

- a. 船上という厳しい環境において自動的に観測を 行い、保守管理のために自律的に陸上の拠点と 通信する能力を有する全天球観測装置の開発.
- b. 実船に搭載した前記全天球観測装置による観測 データの収集.
- c. 船舶気象観測指針の基準に基づく正確なラベル 付けによる雲データセットの構築.
- d. 構築した雲データセットを学習に用いた分類器 の構築.
- e. 構築した分類器の分類性能の評価.

本研究は、森川ほか(2018)によって発表された研究の発展である。データセットを大規模化し、雲量・雲形・雲の状態の間の相関を評価するように分類器のアーキテクチャを再設計することで、分類性能を顕著に改善した。

2. 船舶気象観測指針による分類規定

気象庁が定める船舶気象観測指針 (気象庁 2019) では、WMO が定める国際雲図帳(World Meteorological Organization 2017) に準拠して、第 3 表のように、船舶が報告するべき報告項目を規定する。下層・中層・上層それぞれについて、観測される雲形(第 1 表)及び雲の状態(第 2 表)の報告に加えて、全層にわたる雲量(全雲量)の報告が求められる。気象観側の手引きにおける雲量は、国際雲図帳における Total

Cloud Cover であり、雲形毎の雲量である Cloud Amount は使用しない点が国際雲図帳との差異である。下層・中層・上層において、複数の雲形が観測された場合は、全天球に占める面積の割合が最も大きい雲形を報告する。霧・煙霧・黄砂などにより空がさえぎられている場合や、中

層或いは上層が下位の層の雲によって覆われていて観 測が不可能な状態を「不明」と報告する.

雲の状態の観測においても同様で、観測不能時には「不明」と報告する。雲量は、雲形を問わず、全天空に占める雲の割合を、0から10までの数字で表す。更に、 10^- (雲間にわずかな隙間が見られる状態を表す)と 0^+ (些少の雲が観察されるものの1割に届かない状態を表す)とを値に加え、合計13段階で評価する。

3. 雲の分類システムに関する関連研究

雲の自動分類に関する先行研究の多くは、画像デー タから雲量を判定することを目的とする. 雲量予測に 用いる画像データとしては、全天球カメラによる画像 (Kuii et al. 2018; Yabuki et al. 2014). 気象衛星から 撮影した広域の画像 (Yang et al. 2019; Zi et al. 2018) などが報告されている. これらの研究では、画像のピ クセルごとに雲の存在を判定するが、ピクセル毎の雲 の存在判定法としては、数理モデルに基づく方法 (Kuji et al. 2018; Yabuki et al. 2014) と機械学習的手 法に基づく方法に大別される. 機械学習的手法につい ては、決定木アルゴリズム (Quinlan 2014) を利用す る方法 (Román et al. 2017), 畳み込みニューラルネッ ト (Convolutional Neural Network, CNN) (LeCun et al. 1989) を利用する方法 (Yang et al. 2019), CNN と サポートベクターマシン (Support Vector Machine, SVM) (Boser et al. 1992) を組み合わせて利用する方 法(Zi et al. 2018) が提案されている、 雲量そのもの を予想するものではないが、雲の全天球画像から日射 量の予測を行う研究も報告されている(稲村ほか 2020).

一方、画像に基づく雲形の識別問題は、画像から明瞭な輪郭線や陰影など識別に役立つ特徴を抽出することが難しく、画像認識問題としては困難な部類に属すると考えられる。そのため、CNNを応用する試みが比較的早くからなされ、高層・中層・低層の区別を行わないものの、Zhang et al. (2018) は、国際雲図帳が定める10種類の雲形に飛行機雲を加えた11種類の雲形を、学習済みネットワークである Alex Net (Krizhevsky et al. 2012)を改良した独自の CNNを用いて判定する方法を提案している。また、Zi et al. (2018) は、衛星画像が捉える近赤外光の観測データも併用し、CNNと SVMを組み合わせることにより雲の輪郭を捉えるシステムを提案している。CNNを独自に開発する研究例も報告されている(Ye et al. 2017)。

上で紹介した雲量・雲形の判定を行う従来研究で報告されている正解率を第4表にまとめる。雲量については85%から90%の高い数値を示している。雲形についても、CNNを用いた2例における87%と88%は、CNNではなくランダムフォレストを用いた例(Breiman 2001)の71%に比較して高い値を示していることから、CNNを用いた手法が有望であることが分かる。本論文では、雲量に加えて、国際雲図帳で定義されている雲形を高層・中層・低層で分類するほか、定義が官能に依存する雲の状態も推定することを目的としており、従来研究より格段に難しい問題に取り組むことになる。

4. データセットと分類器の構築

本研究では、船舶気象観測指針(気象庁 2019)が規定する分類ラベルを出力とする、雲の自動分類システムを構築することが目的である。先に述べたように、船舶気象観測指針は国際雲図帳(World Meteorological Organization 2017)に準拠している。一方、3節で述べた従来研究(Yang et al. 2019; Zi et al. 2018; Zhang et al. 2018; Ye et al. 2017; Huertas-Tato et al. 2017)では、本研究で判別しなければならないクラスラベルの一部しか判定対象としていない。従って、本研究の目的には、雲に関する既存のデータセットでは学習には不十分で、分類器も設計し直さなければならない。

4.1 船舶に設置する雲観測装置の開発

開発を行う雲観測装置は以下の要件を満足するべき ものとした。

- a. 船舶気象観測指針では、全天球に関して観測を 行うことを要請している.このため、本研究で用 いる観測装置は、全天球を視野に収めるカメラ を具備していることが必要である.
- b. 船舶に装備された発電機による電力供給は不安 定であるため、大容量バッテリーとの併用によ り、安定した電力供給を保証することが必要で ある.
- c. 船上は常に海水飛沫や風雨に晒されるため,電子装置を保護する防護手段が必要である.
- d. 船舶は「東は西経百六十度,西は東経百度,南 は緯度零度,北は北緯六十五度の線により限ら れた海域」を航行する場合,気象観測を実施す る義務があることが気象業務法施行規則に規定 されていることから、観測装置は気温の変動に

耐える必要がある. 特に, 装置そのものが熱を 発生すること, 日光の直射に晒されること, 電 子装置は熱により暴走することから, 暑熱への 対策が万全でなければならない.

e. 船上に絶えずシステム管理者が常駐することは 現実的ではないため、陸上の拠点からシステム を遠隔管理できる必要がある.

aとりの条件を満足する観測機器は販売されているが、塩害対策の強度(要件c)・高温環境下における稼働の安定性(要件d)・システムの稼働状況の遠隔監視機能(要件e)を確認できていないことから、上記の条件を検証可能なレベルで満足する観測機器を、以下のように、独自に開発することとした。

- a⁺. 魚眼レンズを取り付けた小型カメラに、雨風や潮風からカメラを守る透明な保護ドームを被せ、周囲360度の全天球撮影を可能とする.
- b⁺. 12万 mAh の大容量バッテリーを観測装置に接続し、安定した電力供給を図るとともに、万が一、船舶の発電機からの電力供給が途絶えた場合でも、20時間の稼働を保証する.
- c⁺. PC 冷却用水冷キットを装備し, 高温時には観 測装置全体を冷却する.
- d⁺. 市販の防水防塵ケースを全天球撮影を妨げないように改造し、観測装置を格納する.
- e⁺. 観測機器に通信装置を取り付け, 陸上の拠点 から ssh (Secure Shell) でシステムログイン が可能となるようにする.

第1図は、観測カメラの稼働試験中の写真である. 写真右手前に、バッテリー(①)に接続され、ドーム型レンズが装着されたカメラ(③)が見える。カメラの奥、画面右端の黒い大きな筐体が冷却装置(④)である。画面左端にある数字が表示されている前面黒色の大きな筐体が、カメラの制御装置(②)であり、1分間に1回、カメラに撮影の指示を送り、JPEG画像を保存する。使用したカメラはコダック社製 PIXPRO SP360 4Kで、露出、ホワイトバランスの制御はカメラ側で自動的に制御を行う。

4.2 観測データの収集

第2図は、防水防塵ケースに格納した観測装置を、船上に設置した際の写真である。防水防塵ケース上面に、ドーム型レンズ(①)が突出している。開発した観測装置は、神戸大学大学院海事科学研究科所属の深江丸船上に設置して、観測データの収集を行った。

今回の研究では、観測装置を搭載する船舶を1隻し

か用意できず、データセット構築に必要な量の観測 データを収集できるか確実ではなかったため、地上に も観測装置を設置することとした、設置場所はできる だけ船舶での観測条件に近づけるため、東経127度56 分、北緯26度55分に位置する伊是名島を選定した、伊 是名島は、面積14.12km²、周囲16.7km、最高標高 119.9m の小島であり、沖縄本島の北28km に位置す る. 周囲を海に囲まれ. 平坦で面積が小さいことから. 陸地が雲に与える影響が小さく、船舶における観測と 類似した環境での観測が可能と想定できる. 観測機器 は、伊是名村役場の屋上に設置した、また、事前に観 測機器を高温環境下に設置し、正常に稼働するかどう かのテストも行った。データ観測は、毎分1枚の全天 球写真を撮影することで実施した、深江丸に設置した 観測装置では、2017年9月19日から2018年3月2日ま での間に、10万枚以上の観測画像を撮影し、その中か ら学習データとしては4.079枚の画像を使用した。伊 是名島に設置した観測装置では、2017年12月24日から



第1図 観測装置の稼働実験.





第2図 深江丸に搭載した防水防塵ケース格納済 の観測装置。

2018年5月16日までの間に、同じく10万枚以上の観測画像を撮影し、その中から学習データとしては3,523枚の画像を使用した、第3図に、深江丸で撮影された全天球画像を伊是名島で撮影された全天球画像を示す。伊是名島とは違い、深江丸では船の構造物が映り込んでいる点が学習データとして大きな違いとなっている。今回の観測では、全ての雲の状態が観測できたわけではなかった。第一に、深江丸が航行した海域では出現しにくい雲の状態が存在したことが理由であり、後述する第6表が示すように、いくつかの雲の状態は、画像数が0枚であったり、数十枚程度であったりした。第二に、雲形が積乱雲の場合、激しい雷雨のため、画像から雲の状態を正確に判定することが不可能であった。

- 4.3 船舶気象観測指針に基づくデータセットの構築 深江丸及び伊是名村役場の2箇所に設置した観測装 置によるデータは、全天球画像のみであるので、機械 学習(教師あり学習)に用いるためには、ラベル付与 を行う必要がある。本研究では、以下の手順により、 船舶気象観測指針に規定される雲の分類基準(第3表) に準拠するラベル付与を行う。
 - ・船舶上で正確な気象観測を行うには経験が必要で、中でも雲の観測は正しい知識と経験が必要である。本研究においては、ラベル付与は、神戸大学大学院海事科学研究科が船舶気象観測指針に基づいて観測画像を目視で評価することにより実施することとした。その途中過程においては、気象庁からも多くのアドバイスを頂いた。またラベルの正確性を担保するため、各観測画像を複数名が評価してそれぞれラベルを仮決めし、ラベルが一致しなかった場合には合議によって1つに決定することとした。
 - ・全天球画像では、魚眼レンズの特性により、周辺部には歪みが生じるため、目視による判定が困難





第3図 データセット内の雲の画像.

- となるケースがある. このため,全天球画像に加え,パノラマ画像に変換した画像も併せて,評価を実施した.
- ・船舶気象観測指針では、雲量の評価は13段階で行うこととなっているが、本研究では11段階(0, 1, 2, …, 9, 10) で行った、雲量の目視による判定に正確性を求めることは困難で、船舶気象観測指針でも ± 1 の誤差を認めている。その意味では、 $0^+ と 10^-$ のラベルは刻みが細かすぎ、実作業で用いられることは稀である。本研究でも、観測作業の実態に合わせて、 $0^+ と 10^-$ は使わないこととした。
- ・観測装置は1分間に1回,全天球画像の撮影を行うが,1分間の間隔では撮影画像の差分が小さいことと、ラベル付けの作業量が大きくなることを考え、10分間に1データに間引いてラベル付けを行う。またその際には、10枚の静止画像を連続的に見ることによって雲の動きを把握し、評価の参考とした。
- ・夜間の画像については、評価者が判別できないほ どの暗さの場合ラベル付与は行わないこととした.
- ・積雲と層積雲の区別は一般に困難であり、本研究でも、ラベルを決定できない画像が95件存在した。

第5表~第7表に、ラベル付与の結果を示す。第5表は、雲形毎に判定された観測画像数を示す。雲形によって出現頻度に大きな差があることが分かる。第6表は、層毎の雲の状態に対し、観測画像数を示す。雲

第5表 雲観測装置によって得られた雲形毎の画像数.降雨のため雲の状態が観測できなかったので、積乱雲はデータセットから除外した.

層	雲形	画像数
下層	なし	2190
	積雲	4681
	層積雲	211
	層雲	436
	積乱雲	31
中層	なし	3212
	高積雲	3467
	高層雲	443
	乱層雲	480
上層	なし	6323
	巻雲	898
	巻積雲	202
	巻層雲	179

16 "天気" 70. 12.

の状態についても、ラベル間で大きな差があることが分かる。第7表は、雲量に対し、観測画像数を示す、雲量が9や10の画像が多く、0や1の画像が次に多い、中間的な雲量の画像は少ない傾向にある。

ラベル付与の結果に基づき,一部のデータをデータ セットから除外した.

・積乱雲が出現した場合は、激しい降雨のため雲の 状態が観測できず、完結したラベル付与は不可能 である。そのため、積乱雲は、データセットのラ

第6表 雲観測装置によって得られた雲の状態毎の画像数.灰色の背景色で表示された雲の状態は、観測数が少ないため、データセットから除外した.下層の状態に関して、数が少ないラベルが学習の際に複数含まれることはよくないと考え CL4だけをデータセットに加え. CL8は除外した.

層	雲の状態	画像数
下層	C_L -0	2,190
	C_L -1	1,200
	C_L -2	3,071
	C_L -3	31
	C_L -4	50
	C_{L} -5	161
	C_L -6	25
	$C_{\rm L}$ -7	820
	C_L -8	54
	C_L -9	0
中層	C _M -0	1,666
	$C_{M}-1$	160
	$C_{M}-2$	752
	$C_{\rm M}$ -3	981
	$C_{\rm M}$ -4	0
	$C_{\rm M}$ -5	18
	$C_{\rm M}$ -6	0
	$C_{\rm M}$ -7	2,475
	$C_{\rm M}$ -8	4
	$C_{\rm M}$ -9	0
	不明	814
上層	C _H -0	2,538
	$C_{H}-1$	417
	$C_{\rm H}$ -2	479
	$C_{\rm H}$ -3	0
	C_H -4	2
	$C_{\rm H}$ -5	3
	$C_{\rm H}$ -6	3
	$C_{\rm H}$ -7	74
	$C_{\rm H}$ -8	99
	$C_{H}-9$	202
	不明	3,783

ベルからは除外した.

・観測数が少なかった雲の状態も、データセットの ラベルから除外することとした。第5表及び第6 表において、灰色の背景色で示されたラベルが、 データセットから除外されたラベルである。

最終的に、7,407個のデータを含むデータセットを構築した。データセット中のデータは、「不明」も含めて、ラベルに値をもつ。

4.4 雲分類器の構築

雲の分類器は、特徴抽出の機能を担う CNN に 2 層の全結合ネットワーク (FC) を接続する構成とするが、以下にその構築方法を示す.

4.4.1 学習の構造

第3表に示すように、1つのラベルは7つのサブラベル(下層・中層・上層毎の雲形と雲の状態,及び,全天球の雲量)を含み,サブラベルの組み合せによるラベルの値の総数を第3表から単純に計算すると, $(6+5+5) \times 11 \times 13 = 2,288$ 通りになる.実際には,第1表と第2表から分かるように,サブラベルの値の組み合わせには制約がある.例えば,下層の雲形が「なし」ならば,下層の雲の状態は「 C_L -0」が選ばれなければならない.このため,実際のラベル数は2288より少なくなるが,それでも,実際に出現するサブラベルの組み合わせは相当に多い.学習後の分類性能は,1ラベルあたりの学習データの数に強く依存するため,ラベル数が多くなると良好な分類性能を期待できなくなる.

この問題を解決するために、本研究では、下層・中層・上層毎の雲形、下層・中層・上層毎の雲の状態、雲量の合計7種のサブラベルの判定に、それぞれ独立したFC層の出力を利用する。一方、特徴抽出器の役

第7表 雲観測装置によって得 られた雲量毎の画像数.

雲量	画像数
0	850
1	780
2	394
3	372
4	304
5	564
6	251
7	277
8	389
9	1,530
10	1,891

割をはたす CNN と CNN の出力が入力される FC 層は、サブラベル間の関係・相関を学習することができるように、全てのサブラベル間で共通とする。 CNN と共通 FC 層は、7種類の全てのサブラベルに基づいてパラメータの最適化(学習)が行われ、サブラベル毎の FC 層はそれぞれのサブラベルのみに基づいて学習が行われる。

4.4.2 ファインチューニング

深層 CNN の学習は膨大な数のパラメータを最適化 する. したがって、SVM などの他の分類器に比べ、遥 かに大規模なデータセットを学習に用いる必要があ る、本研究では、後述するデータ拡張(Data Augmentation) の手法を用いて、得られたデータセットの嵩 増しを行うが、それでも、深江丸・伊是名村役場2箇 所のみで撮影した観測画像だけでは不足することが予 想され、この問題を避けるために、Keras で提供され ている学習済みの ResNet50をベースに、ファイン チューニングの技法を用いて CNN を構築する。第4 図で示すように、事前学習によってパラメータが決定 されたResNet50の出力はサブラベル間で共通のFC層 に入力され、共通 FC 層の出力はサブラベル毎に独立 な7つのFC層に入力されるように構成する、Softmax は階層型ニューラルネットの最終段において、多 値分類を行うために適用される関数であり、複数ノー ドの出力を各ラベルの期待確率に変換する. ReLU 関 数は、Sigmoid 関数に代わって利用されることが多い 活性化関数である、x>0の入力値に対する関数の傾 きが定数1であることから、勾配消失問題を免れ易い という性質があることと、誤差逆伝播法における計算

が効率的であることから広く利用される。Dropout は、出力の一部を確率的に捨てることで、少ない訓練データを嵩増しして学習効率を改善するために導入される。第4図における Dropout の0.5は半分のノードの出力を0にする処理となっている。ラベル付与が行われた観測データによって、ResNet50と FC の両パラメータの最適化を行うことで学習を行う。

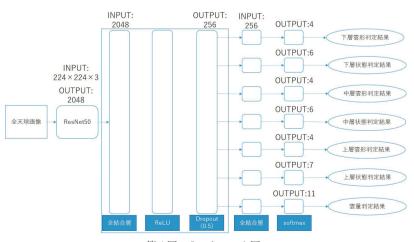
4.4.3 データ拡張

深層学習、特に CNN では、データ拡張によって、データセットが持つ情報量を有効に活用する手法が一般的に利用される。 CNN では画像中の近傍関係によって、リンクが偏在する一方、学習データサンプリングの偶然性により、画像に現れる局所的パターンが位置や画像の角度に依存して偏る場合、学習結果に偏りが生じる可能性がある。 入力画像に不偏性(例えば、回転に対する不偏性、平行移動に関する不偏性、拡大・縮小に対する不偏性) が想定できる場合、データ拡張はこの偏りを平均化する効果も有する。

本研究では、回転から左右反転まで、Keras が標準的に提供するデータ拡張項目(第8表)に加え、プログラムを新たに作成して mixup によるデータ拡張も行うようにした。 mixup では、各画像データ A に対して、混合比率 λ をベータ分布に従ってランダムに選び、更に、画像データ A と異なる画像データ B をデータセットの中から一様ランダムに選ぶ。その上で、画像データ A と B の各ピクセルの値を、 λ : $(1-\lambda)$ の比率で足し合わせることで、画像データ A から変更された画像データを得る。

ニューラルネット (NN) 学習では, 学習データセッ

トを繰り返し使用して学習するが、全ての学習データを用いた1回分の学習をエポック(epoch)と呼ぶ、本研究では、KerasのImageDataGeneratorクラスの機能を使い、新たな、カックを実施する度に、で、ランダムに画像変更ができまれる画像数をですり、つまり、学習画像数ができまれるで、学習に使用されるデータ数は共通にnであるが、画像



第4図 ネットワーク図.

データそのものは画像変換によりエポック毎に異なるものになる.言い換えると,実行するエポックの回数をNとすると,学習に使用される画像の種類は $n \times N$ になる.

4.4.4 ハイパーパラメータの設定

ファインチューニングにおける CNN の学習を実行するためには、更に、いくつかのハイパーパラメータを決定しなければならない。ハイパーパラメータは、分類器のパラメータであって、学習によって最適化されないものを指す。例えば、4.4.3節で説明したエポックの実行回数は、ハイパーパラメータである。最適化アルゴリズムは予測値と正解値との差である損失を最小化することを目的とするが、学習率は勾配降下におけるパラメータ変更の幅を決定する係数で、ハイパーパラメータの別の例である。ハイパーパラメータは学習アルゴリズムにより決定(最適化)されないので、あらかじめ、値を指定しておくか、値の指定方法を決定しておく必要がある。第9表に、本研究におけるハイパーパラメータの指定方法を示す。

5. 雲分類器の性能評価

データセットを用いて雲分類器を構築した際の、雲分類器の性能評価の方法と結果 について述べる.

5.1 分類性能の評価方法

分類性能の評価は、学習のための訓練 データとは独立に用意されたテストデータ を入力として, 学習済みの分類器に予測ラ ベルを出力させ、正解ラベルと予測ラベル の一致の度合いを定量的に計測することで 行う. テストデータを訓練データと重なり がないように用意しなければならない理由 は、分類器は訓練データを学習しているこ とから、訓練データをテストに用いると、 いわばカンニングと同じ効果が発生し、本 来の性能よりも不当に高い評価が得られる 危険があるためである. このため, 雲分類 器の性能評価では、4.3節で構成したラベ ル付き画像データセットを、概ね8:1: 1の比率で訓練データセット・テストデー タセット・検証データセットに重なりのな いように分割する、4.3節で得られたラベ ル付き画像の総数は7407であるので、訓練 データは5925件、検証データは741件、テス

トデータは741件となる. 検証データセットの利用目的については、次の節で説明する.

分類性能の評価はサブラベル毎に実施する. 説明の便宜のため、ラベルを構成する 7 種類のサブラベルを自然数 k \in $\{1, \cdots, 7\}$ で表し、サブラベル k がとり得る値を自然数 $1, \cdots, L_k$ により表す、更に、サブラベル k に関する正解 i_k のテストデータを分類器に入力して予測 j_k が得られるとして、このようなテストデータの個数を $N^k_{i_k}$ kと表すものとする.

サブラベルkの全ての値にわたる全般的な分類性能の評価には、正解率を用いる、正解率は

サブラベル
$$k$$
 に関する正解率= $\frac{\sum_{i_{k=1}}^{L_k} N_{i_k}^k i_k}{\sum_{i_{k=1}}^{L_k} \sum_{j_{k=1}}^{L_k} N_{i_k,j_k}^k}$

と定義される.

一方、サブラベルkの値 i_k が予測された場合、予測

第8表 データ拡張に用いた画像変換.

変換	定義	パラメータ
回転	画像中心を軸として	回転角度(−180° から180°)
	画像を回転	
シアー変形		傾斜角度 $ heta$ (-20° から20°)
	ル を、 $(x-y \sin \theta, y)$	
	$\cos \theta$)に移動	
拡大	画像中心を相似の中	拡大率(-40%から40%)
	心として拡大縮小	
上下方向拡大		拡大率(-20%から20%)
左右方向拡大	水平方向に拡大縮小	**··· · · · · · · · · · · · · · · · · ·
上下反転	水平中線を軸として	あり・なし
	反転	
左右反転	垂直中線を軸として	あり・なし
	反転	
mixup	二つの画像をピクセ	$\alpha = \beta = 0.1$
	ルごとにλ: (1−λ) の	
	比率で混合する. λ	
	は、ベータ分布 $B(\lambda)$	
	α , β)に従ってランダ	
	ムに選ぶ.	

第9表 ハイパーパラメータの値.

ハイパーパラメータ	指定方法
損失関数	交差エントロピー
エポック数	学習後に検証結果から決定(5
<i>t</i> エポック目の学習率 0 ≤ <i>t</i> <300	節) $0.002 \cdot e^{\frac{\ln 0.001 - \ln 0.002}{299}t}$
巣籠(2017)によるモーメンタム	0.9
最適化アルゴリズム	巣籠 (2017) による確率的勾配
	降下法

がどの程度の信頼性を有するかは、適合率・再現率、 及び、適合率と再現率の調和平均であるF値により評 価する. サブラベルkの値i、それぞれに対して. 適合 率・再現率・F値は次のように定義される.

適合率…サブラベル i,と予測されるテストデータの 全体における正しい予測の割合である.

サブラベル
$$i_{\scriptscriptstyle k}$$
の適合率 $= \frac{N_{i_k\,i_k}^{\scriptscriptstyle k}}{\sum_{j_k=1}^{L_k}N_{j_k\,i_k}^{\scriptscriptstyle k}}$

再現率…サブラベル i,が正解であるテストデータの 全体における正しい予測の割合である.

サブラベル
$$i_{k}$$
 の再現率 $=$ $\frac{N_{i_{k}}^{i_{k}}.i_{k}}{\sum_{j_{k}=1}^{L_{k}}N_{i_{k}}^{i_{k}}.j_{k}}$

F値…適合率と再現率の分子は共通であるので、そ の平均は適合率の逆数と再現率の逆数の算術平均の逆 数 (調和平均) で定義する.

サブラベル
$$i_k$$
の F 値=
$$\frac{2N_{i_k}^k}{2N_{i_k}^k i_k} + \sum_{j_k \neq i_k} (N_{i_k}^k j_k + N_{j_k}^k i_k)}$$
(1)

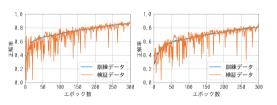
5.2 エポック数の決定

雲分類器の学習におけるハイパーパラメータを第9 表に示しているが、エポック数については、静的に決 定するのではなく、十分な学習効果が得られるまでエ ポックを繰り返すことで動的に決定する.

仮に学習効果を訓練データに対する正解と予測の乖 離を表す損失関数の値(損失)で評価することとしよ う。エポック数を増やすほど損失は小さくなっていく が. 訓練データに含まれないデータに対して行った予 測に対しては、逆に損失が大きくなってしまう過適合 と呼ばれる現象が発生することがある。そのため、訓 練データとは独立に検証データを用意し、検証データ に対する損失が最小となるエポック数を最適エポック 数として採用する必要がある.

第5図から第8図では、下層・中層・上層毎の雲 形・雲の状態、及び、雲量の7つのサブラベルの予測 に関する正解率の推移を、実行したエポック数を追っ て示したものである. 青色の線は訓練データに対する 予測に対する正解率を、オレンジ色の線は検証データ

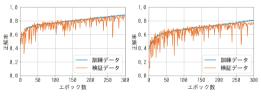
に対する予測の正解率を表す、いずれも、エポック数 を重ねるに従って、トレンドとしては増加傾向を示す が、訓練データに対しては、正解率のばらつきは小さ いのに対し、検証データに対する正解率はばらつきが 大きい、また、エポックの実行回数が多くなっても、 訓練データにおける正解率はほぼ線形に増加し続ける のに対し、検証データにおける正解率の増加は鈍化を 示し、エポック数が200を超えるあたりから両者の値 は乖離するようになり、過適合の発生が示唆される。 損失値の推移でもエポック数が287を超えると、検証 データの損失値は減少しなくなる. この結果に基づ き、ハイパーパラメータであるエポック数を287と決



(a) 下層の雲形

(b) 下層の雲の状態

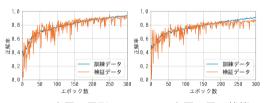
第5図 下層におけるモデル学習の進行状況.



(a) 中層の雲形

(b) 中層の雲の状態

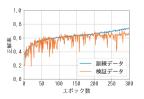
第6図 中層におけるモデル学習の進行状況.



(a) 上層の雲形

(b) 上層の雲の状態

第7図 上層におけるモデル学習の進行状況.



第8図 雲量.

"天気"70. 12. 20

定し、エポック数287まで学習した分類器を、以降の分類性能の評価に利用することとする.

5.3 サブラベル毎の分類性能の評価

第10表に、7種類それぞれのサブラベルについて、 テストデータに対する予測の正解率を示すので、第10 表に基づいて説明を行う.

5.3.1 高層・中層・低層の雲形に関する正解率 雲形に関する予想の正解率は、いずれも 9 割弱と なっている. 先行研究 (Zhang *et al.* 2018; Ye *et al.* 2017; Huertas-Tato *et al.* 2017) とほぼ同程度の正解 率であるが、以下の点でより難しい判定問題を解決し ている.

- ・先行研究では判定が難しい地平に近い部分を避け、 天頂の一部を矩形に切り抜いた画像を判定に利用するのに対して、本研究では、水平線付近を含めた全 天球画像を用い、水平線付近の雲も判定対象とする。
- ・先行研究では、1枚の画像データから1種類の雲形を判定しているのに対し、本研究では、船舶気象観測指針(気象庁 2019)の規定に準拠して、一枚の画像データから、下層・中層・上層の別に3種類の雲形を判定する。

5.3.2 高層・中層・低層の雲の状態に関する正解率 先行研究(Yang et al. 2019; Zi et al. 2018; Zhang et al. 2018; Ye et al. 2017; Huertas-Tato et al. 2017) は雲の状態の判定を対象としていない. 一方, 本研究 の分類器は, 70%後半から80%前半の正解率で雲の状態を判定した(第10表). 船舶気象観測指針(気象庁 2019)における雲の状態分類の定義そのものが官能に 頼る部分が多く(第2表), 実際, 本研究における画像 の目視によるラベル付け(4.3)の段階から判断がばら つくことが指摘されていたことを考えると, 良好な結 果を得たものと考えられる.

5.3.3 雲量に関する正解率

船舶気象観測指針(気象庁 2019) において,「観測

第10表 サブラベル毎の正解率.

サブラベル	正解率
下層の雲形	87.9%
中層の雲形	86.8%
上層の雲形	89.1%
下層の雲の状態	77.7%
中層の雲の状態	75.0%
上層の雲の状態	84.8%
雲量(船舶気象観測指針に従い±1を正解に含める場合)	88.7%
雲量(厳密なラベル一致を求める場合)	64.4%

に際しては、雲量が多いか少ないかのおおよその程度を初めに観測し、雲量の ± 1 ぐらいは個人誤差にも含まれるので、あまり神経質になることなく大勢を誤らないようにする.」との記述があることから、 ± 1 の範囲を含めて計算して正解率を計算し、88.7%と良好な値を得た。

これは、先行研究(Yang et al. 2019; Zi et al. 2018)での、衛星が撮影した広域画像データを利用した事例と同程度である。一方、ラベルの厳密な一致に基づく正解率は、64.4%であったが、これは目視によるラベル付けそのものが個人の主観によりばらついていたことが理由であると考えられ、船舶気象観測指針(気象庁 2019)の記述通り正解の幅を ± 1 として計算した結果が実態を表しているといえる。

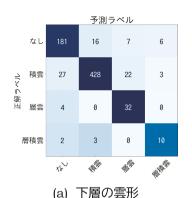
5.4 サブラベルの値毎の分類性能の評価

前述のように、サブラベルに対して得られる予測の 信憑性については、適合率・再現率・F値の指標によ り評価したが、必ずしも全てにおいて良好な成績を示 したとは言えない。これは一部のサブラベルの値に対 して用意できた画像数が少ないことが主な原因と考え られる。学習や評価に用いる画像数が少ない場合、適 合率と再現率それぞれに対して、以下に述べるような 悪影響が生じる。

適合率…テストデータにおけるサブラベル値 A の画像数は多く, サブラベル値 B の画像数は少ないとしよう. サブラベル値 A に関する再現率が高くとも, サブラベル値 B と誤判定される画像の数はサブラベル値 B の総画像数に比較して大きくなり, 結果, サブラベル値 B の適合率は大きく低下してしまう可能性がある.

再現率…訓練データの数が少ないと、十分に学習を行うことができず、再現率低下の要因となる。一方、テストデータの数が少ないと、計算した再現率の好悪によらず、サンプリングに由来するばらつきの影響が大きくなり、再現率の値の信頼性が低くなる。

この問題を解決するためには、今回画像数を多く得られなかったサブラベル値の観測画像数を増やす努力が必要である。また、本研究の画像データへのラベル付け作業において、サブラベル値によっては、船舶気象観測指針などで示されている判定基準に照らして明確に判定を行うことが容易ではなく、観測者によって判定結果がバラつく可能性がある





第9図 下層における雲形と雲の状態の混同行列.

第11表 下層の雲形と雲の状態の適合率・ 再現率・F 値.

種別	ラベル	再現率	適合率	F値
雲形	なし	86.2%	84.6%	85.4%
	積雲	89.2%	95.7%	92.3%
	層雲	88.9%	52.5%	66.0%
	層積雲	66.7%	52.6%	58.8%
雲の状態	0	79.5%	87.4%	83.3%
	1	82.8%	54.6%	65.8%
	2	71.9%	93.1%	81.1%
	4	50.0%	50.0%	50.0%
	5	72.7%	53.3%	61.5%
	7	91.5%	70.7%	79.8%

ことも指摘された. ラベル付けの作業において, より 厳密な判定基準を付加的に適用することで, ラベル付 けの段階でのばらつきを抑制する必要がある.

以下に、指標の値と混同行列を用いて、個別・具体 的に説明を行う.

5.4.1 下層の雲形と雲の状態

第9図は下層の雲形・雲の状態における混同行列を示し、第11表は混同行列から導かれる適合率・再現率・F値を示す.

雲形…層雲と層積雲では、テストに用いた画像数がそれぞれ36枚・15枚と少ないため、適合率の値が悪い、実際、正解ラベルが「なし」と積雲の画像を層雲・層積雲と誤判別した件数はそれぞれ29件・9件であり、層雲と層積雲とラベル付けされた画像数に対して大きい。また、層積雲の訓練データは120枚なので学習が十分に行われなかった可能性があることと、テストデータが15枚であるので66.7%という再現率そのものに信頼性がないことが、層積雲の再現率が悪い原因であると考えられる。

雲の状態…状態 4 と 5 に関しては、テストに用いた画像数が 4 枚及び11枚と非常に少ないため、適合率・再現率どちらの値も十分な信頼性があるとはいえない、一方、状態 1 の適合率と状態 2 を明期率で低い値が出ている理由は、状態 2 を状態 1 と誤判定する件数が64件と多かったことによる、船舶気象観測指針の規定によると、低層の 1 の状態は

「へん平な積雲」、低層の2の状態は「並又はそれ以上に発達した積雲」と定義されており、その差が微妙であるためであろうと考えられる.

5.4.2 中層の雲形と雲の状態

第10図は中層の雲形・雲の状態における混同行列であり、第12表は混同行列から導かれる適合率・再現率・F 値である.

雲形…高層雲の適合率が悪い以外は、良好な結果が得られた。高層雲の適合率が悪い原因は、高積雲を高層雲と誤判断するケースが24件存在することによる。高積雲の画像数376に対して24件は小さいので、高積雲に関する再現率に影響は与えないが、高層雲の画像数44に対しては十分に大きいので、高層雲に関する適合率を低下させている。

雲の状態…状態1・状態3・状態7・「不明」の適合 率、状態7の再現率が悪い以外は、総体的に良好な 結果が得られた. 状態1と「不明」の適合率が低い 理由は、他の状態と比較して画像数が少ないことに よる. 一方. 状態3の適合率と状態7の再現率が低 い主な理由は、状態7の画像を状態3と誤判定する 件数が43も存在する点にある。中層の状態3の定義 は「半透明状の高積雲 | であり中層の状態7の定義 は「多重層の高積雲」となっている。多重層である かどうかは主として目視の際の透明度によって判断 されると想定されるが、その差が微妙でラベル付け の作業者によって判断がばらついたことが原因では ないかと思われる.また、中層の状態7の注釈には 「高層雲又は乱層雲を伴う」場合も含まれていること から、ラベル付け作業時において、「半透明状態の高 層雲」である中層の状態1.「不透明状の高層雲又は 乱層雲 | である中層の状態2との区別が難しかった

ものと考えられ,第10図では,状態7の状態1・ 状態2への誤判断の件数 として現れている.

5.4.3 上層の雲形と雲 の状態

第11図は上層の雲形・雲の状態における混同行列を示し、第13表は混同行列から導かれる適合率・再現率・F値を示している.

雲形…全画像のうち「なし」 の画像は80%強を占めて いることから、その他の 雲形の適合率の値は低く とどまっている. また. 再現率の値が低い事実 も、訓練用の画像データ 数が少なく, 学習が十分 に行われなかったことが 原因であると考えられる. 雲の状態…データ数が十分 な状態0と「不明」以外 はデータ数が少なく、雲 形の場合と同様の理由 で、適合率・再現率とも によい値が示されていない.

5.4.4 雲量

第12図に雲量に関する混同行列を示し、第14表に再現率・適合率・F値を示す。船舶気象観測指針(気象庁 2019)では、雲量の観測においては ± 1 の誤差は認められるとしており、予測ラベルが正解ラベルの ± 1 の範囲内であれば予測が当たっているものと判定した場合の再現率・適合率・F値を示した表が、第14表aとなる。雲量0・雲量1・雲量9・雲量10以外の正解ラベルに対しては画像数が少ないことから、適合率、再現率、もしくは、その両方で良好な値が得られていない。雲量の値全体にわたる正解率は88.7%と良好であることから、ラベル付け作業において、人間の官能にたよると低い値と高い値の評価に集中する傾向があり、それが中間の値のラベルのデータが少ない原因であるのかも知れない。

5.5 サブラベルの正解数の分布

上層・中層・下層の雲形と雲の状態、及び、雲量の

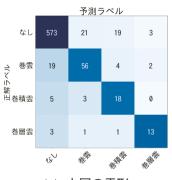




(a) 中層の雲形

(b) 中層の雲の状態

第10図 中層における混同行列.







(b) 上層の雲の状態

第11図 上層における混同行列.

第12表 中層の雲形と雲の状態の適合率・ 再現率・F 値.

種別	ラベル	再現率	適合率	F値
雲形	なし	88.1%	89.3%	88.7%
	高積雲	84.7%	89.3%	88.7%
	高層雲	88.6%	60.0%	71.6%
	乱層雲	94.7%	90.0%	92.3%
雲の状態	0	82.9%	92.6%	87.5%
	1	72.2%	46.4%	56.5%
	2	90.8%	78.7%	84.3%
	3	72.5%	51.3%	60.1%
	7	66.0%	86.2%	74.8%
	不明	72.3%	56.0%	63.1%

7つのサブラベルに対して、雲分類器が何個のサブラベルに対して正解を予測できたかを調べた結果を第13図に示す。36.2%のテスト画像において、7つ全てのサブラベルについて予測が的中し(雲量に関しては誤差±1を許す)、過半数である4つ以上のサブラベルについて予測が的中したテスト画像は92.3%に上り、

雲

第13表	上層の雲形と雲の状態に関する適
	合率・再現率・F 値.

	<u>п</u> + 11	元十 1	IIE.	
種別	ラベル	再現率	適合率	F値
雲形	なし	93.0%	95.5%	94.2%
	巻雲	69.1%	69.1%	69.1%
	巻積雲	69.2%	42.9%	52.9%
	巻層雲	72.2%	72.2%	72.2%
雲の状態	0	87.2%	85.8%	86.5%
	1	33.3%	76.5%	46.4%
	2	77.8%	57.4%	66.0%
	7	71.4%	83.3%	76.9%
	8	63.6%	50.0%	56.0%
	9	65.4%	48.6%	55.7%
	不明	91.0%	94.1%	92.5%

	予測ラベル											
	0	73	3	0	0	0	0	0	0	0	0	0
	1	7	57	16	0	1	3	0	0	0	0	0
	2	1	3	21	8	5	1	1	1	0	0	0
	3	0	1	3	9	11	9	1	0	0	0	0
3	4	0	0	3	8	12	7	1	0	1	0	0
ラベル	5	0	1	1	7	11	20	5	6	2	1	0
正解	6	0	0	1	0	2	7	5	7	3	3	0
	7	0	0	0	0	2	4	3	6	4	4	0
	8	0	0	0	0	3	3	2	7	20	8	0
	9	0	0	0	0	2	1	3	2	22	112	16
	10	0	0	0	0	0	0	0	0	2	24	142
		0	^	2	_O	>	4	6	1	8	0)	10

第12図 雲量における混同行列.

第14表 雲量に対する混合行列から導き出された再現率・適合率・F値.

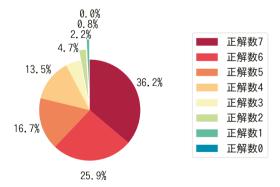
(a) 船舶気象観測指針に指定された誤 差を考慮した再現率・適合率・F値

雲量	再現率	適合率	F値	雲量	再現率	適合率	F値
0	100.0%	98.8%	99.4%	0	96.1%	90.1%	93.0%
1	95.2%	96.9%	96.1%	1	67.9%	87.7%	76.5%
2	78.0%	88.9%	83.1%	2	51.2%	46.7%	48.8%
3	67.6%	78.1%	72.5%	3	26.5%	28.1%	27.3%
4	84.4%	69.4%	76.2%	4	37.5%	24.5%	29.6%
5	66.7%	61.8%	64.2%	5	37.0%	36.4%	36.7%
6	67.9%	61.9%	64.7%	6	17.9%	23.8%	20.4%
7	56.5%	69.0%	62.1%	7	26.1%	20.7%	23.1%
8	81.4%	85.2%	83.2%	8	46.5%	37.0%	41.2%
9	94.9%	94.7%	94.8%	9	70.9%	73.7%	72.3%
10	98.8%	100.0%	99.4%	10	84.5%	89.9%	87.1%

良好な成績を示しているものと判断する.

6. 結論

外洋を航行する船舶の義務 である気象観測のうち、従来 は困難であった雲の観測の自 動化を行った、船舶気象観測 指針に準拠し雲の観測業務を 自動化するためには、観測者 の経験に基づく暗黙知を機械 の処理に等価に置き換えると いう課題を解決する必要が



第13図 サブラベルの正解数毎のデータの割合.

ある.

(b) 厳密なラベルの一致のみで判定し

た場合の再現率・適合率・F値

本研究では、自動観測装置の開発から着手し、全天球を自動的に撮影する観測装置を、船上の過酷な環境に耐えるように設計し、開発した、撮影データから気象庁が求める雲形・雲の状態・雲量を判定するためには、観測員の経験と熟練による暗黙知を形式知化する必要がある。暗黙知の獲得は機械学習の技術、特に、画像認識の分野で顕著な実績を上げている深層畳み込みニューラルネット(CNN)技術を利用し、計算機に学習させることで実現することとした。CNNの学習には、観測結果であるラベルが付与されたデータセットの準備が必要である。このために、開発した観測装置を実船に搭載して、データを収集し、収集したデータに対して、3名の知見者が合議により可能な限り正

"天気" 70. 12.

確なラベルを付与する作業を実施した.得られたデータセットは、気象庁が定める船舶気象観測指針に準拠したものとしては、初めてのものである。全て前述の方法でラベル付された約7500枚の画像を含み、船舶気象観測指針が定める雲形と雲の状態の75.0%をカバーするものとなった.

7500というデータ数は、CNN の学習には少なすぎ るが、汎用の画像データを用いて事前学習を行った既 成の CNN をベースに、学習結果の調整を行うファイ ンチューニングにより、比較的小さなデータセットで も, 実用に足る性能を得ることができた. 実際, 正し くラベルを推定できたデータの割合を表す正解数で. 下層・中層・上層の雲形,上層の雲の状態,雲量の5 項目の予測において、正解率は84.8%から89.1%の間 を示した. これは、衛星からの撮影画像など大域的な データを用い、また、難しい雲の状態は対象とせず、 雲形のみ、雲量のみをそれぞれ単独で予測する先行研 究と比べても、肩を並べる数値である、評価に使用し たデータのうち、全7項目が正しく予測できたデータ の割合は36.2%であり、4項目以上とするとその割合 は92.3%に達したことから、データセットの規模を大 きくすることで実用上十分な性能を獲得できるものと 考える.

謝辞

本研究は、国土交通省の「先進船舶・造船技術研究開発費補助事業(先進船舶技術研究開発)」の支援対象事業における「海上気象観測の自動観測・自動送信システムの開発」((株)商船三井、古野電気(株)、スカパー JSAT(株)を主体とする産学官連携の共同研究)の一環として行われたものであり、また、JSPS 科研費JP21K12015の助成を受けたものである。

参考文献

- Boser, B. E., I. M. Guyon and V. N. Vapnik, 1992: A training algorithm for optimal margin classifiers. Proceedings of the Fifth Annual Workshop on Computational Learning Theory, 144–152.
- Breiman, L., 2001: Random forests. Machine Learning, 45, 5-32.
- Huertas-Tato, J., F. Rodrguez-Bentez, C. Arbizu-Barrena, R. Aler-Mur, I. Galvan-Leon, and D. Pozo-Vázquez, 2017: Automatic cloud-type classication based on the combined use of a sky camera and a ceilometer. J. Geophys. Res.: Atmos., 122, 11045-11061.

稲村直樹,藤原宏太,天方貴久,釣 文男,中西波瑠,小 渕浩希,大澤輝夫,松原 崇,上原邦昭,2020:全天球 画像と日射量データによる太陽光発電量予測.人工知能 学会全国大会論文集,(34),doi:10.11517/pjsai. JSAI2020.0_4I2GS203.

気象庁、1998: 気象観測の手引き.

https://www.jma.go.jp/jma/kishou/know/kansoku guide/tebiki.pdf.

気象庁, 2019:船舶気象観測指針.

https://marine.kishou.go.jp/brochure/guide-jp.pdf.

- Krizhevsky, A., I. Sutskever and G. E. Hinton, 2012: ImageNet classification with deep convolutional neural networks. Adv. Neural Inf. Process. Syst., 25, 1097–1105.
- Kuji, M., A. Murasaki, M. Hori and M. Shiobara, 2018: Cloud fractions estimated from shipboard whole-sky camera and ceilometer observations between East Asia and Antarctica. J. Meteor. Soc. Japan, 96, 201–214.
- LeCun, Y., B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard and L. D. Jackel, 1989: Backpropagation applied to handwritten zip code recognition. Neural Comput., 1, 541-551.
- 森川 優, 中西波瑠. 稲村直樹, 近藤伸明, 大澤輝夫, 松原 崇, 上原邦昭, 2018:全天球画像のデータ収集と雲形と状態判定. 人工知能学会全国大会論文集, (32), doi:10.11517/pjsai,JSAI2018.0_2A401.
- Quinlan, J. R., 2014: C4.5: Programs for Machine Learning. Elsevier.
- Román, R., A. Cazorla, C. Toledano, F. Olmo, V. Cachorro, A. de Frutos and L. Alados-Arboledas, 2017: Cloud cover detection combining high dynamic range sky images and ceilometer measurements. Atmos. Res., 196, 224-236.
- 巣籠悠輔, 2017: 詳解ディープラーニング TensorFlow・ Keras による時系列データ処理.マイナビ出版, 328pp.
- Tan, C., F. Sun, T. Kong, W. Zhang, C. Yang and C. Liu, 2018: A survey on deep transfer learning. International Conference on Artificial Neural Networks, 270–279.
- World Meteorological Organization, 2017: International Cloud Atlas.

https://cloudatlas.wmo.int/en/home.html.

- Yabuki, M., M. Shiobara, K. Nishinaka and M. Kuji, 2014: Development of a cloud detection method from wholesky color images. Polar Sci., 8, 315–326.
- Yang, J., J. Guo, H. Yue, Z. Liu, H. Hu and K. Li, 2019: CDnet: Cnn-based cloud detection for remote sensing imagery. IEEE Trans. Geosci. Remote Sens., 57, 6195-6211.
- Ye, L., Z. Cao and Y. Xiao, 2017: Deepcloud: Groundbased cloud image categorization using deep convolu-

tional features. IEEE Trans. Geosci. Remote Sens., 55, 5729–5740.

Zhang, J., P. Liu, F. Zhang and Q. Song, 2018: CloudNet: Ground-based cloud classification with deep convolutional neural network. Geophys. Res. Lett., 45, 8665-

8672.

Zi, Y., F. Xie and Z. Jiang, 2018: A cloud detection method for Landsat 8 images based on PCANet. Remote Sens., 10, doi:10.3390/rs10060877.

An Attempt at Automated Recognition of Cloud Genera, Cloud Conditions and Total Cloud Cover from All-sky Images Captured by Maritime Vessels

Yu MORIKAWA^{*1}, Haru NAKANISHI^{*2}, Naoki INAMURA^{*3}, Nobuaki KONDO^{*3}, Hiroki OBUCHI^{*4}, Teruo OHSAWA^{*5}, Takashi MATSUBARA^{*6}, Yoshihiro SHIN^{*7}, Hiroaki OHSHIMA^{*8}, Kuniaki UEHARA^{*9}

(Received 10 May 2021; Accepted 29 June 2023)

^{*1 (}Corresponding author) Computer Centre, Gakushuin University / Graduate School of Applied Informatics, University of Hyogo.

morikawa@gakushuin.ac.jp

^{*2} Kobe Digital Labo Inc.

^{*3} BANYAN PARTNERS INC.

^{*4} SKY Perfect JSAT Corporation.

^{*5} Graduate School of Maritime Sciences, Kobe University.

^{*6} Graduate School of Engineering Science, Osaka University.

^{*7} Computer Centre, Gakushuin University.

^{*8} Graduate School of Applied Informatics, University of Hyogo.

^{*9} Graduate School of Computer Science, Osaka Gakuin University.