

NOAA/AVHRR 雲画像を用いた 降雪をもたらす雲の検出法および降雪量の推定

鈴木 香寿恵* (法政大理工)


下村 真生・中村 和幸(明治大)

徳永 旭将(九工大)

矢吹 裕伯・平沢 尚彦・山内 恭(極地研)


南極の涵養量は増えているのか？

JAREによる内陸ルート上の年間涵養量



2000年代に入ってから、変動幅が大きくなった。

ピーク：
2009, 2011年



東南極で観測されたAtmospheric River

Geophysical Research Letters

RESEARCH LETTER

10.1002/2014GL060881

The role of atmospheric rivers in anomalous snow accumulation in East Antarctica

Irina V. Gorodetskaya¹, Maria Tsukernik², Kim Claes¹, Martin F. Ralph³, William D. Neff^{4,5}, and Nicole P. M. Van Lipzig¹

Key Points:

- Atmospheric rivers explain East Antarctic anomalous SMB in

南極昭和基地の気象

佐藤 薫*






Fig. 11 : A contour map of geopotential height (in km) at 925 hPa when the fastest gust wind of 61.2 ms^{-1} was recorded at Syowa Station (X). A strong cyclone is situated around 65°S to the northwest of Syowa Station. Shaded are the regions with relative humidity larger than 80% (Sato and Hirasawa, 2004).

昭和基地周辺でみられる降雪時の雲



昭和基地で受信されたNOAA/AVHRR Ch.4 画像
(e.g., Hirasawa and Yamanouchi, 2000)

目的と方針

1. 降雪量を直接観測することの難しい南極氷床における降雪量を氷床全域で推定し、その涵養量の年々変動を導くことで、**気候変動下における南極氷床の容積の変動を捉えることを目的とする。**
2. 衛星観測による**雲画像から降雪量の多い雲パターンを抽出し、機械学習を用いて自動検出する。**年間涵養量からイベントごとの重み付けを行い、雲パターン毎の降雪量の推定を行う。
3. 雲画像を説明変数の一つとした、降雪量推定モデルを観測データに基づいた時系列モデリングを実施する。

客観解析データを用いた

降雪時における大気循環場の解析を行ったが、
イベント毎の大きな違いは見いだせなかった。


雲は何か違いがあるのか？

雲検出を試みる

既知の問題：

南極氷床はアルベドが高い

海氷もあるため、雲識別が難しい



降雪をもたらすような背の高い雲ならば、
AVHRR ch.4のみで識別可能か。
二値化による識別を行った。

前処理・解析

1. 複数の画像を結合(前後6時間以内)
2. ブリザードイベント(2009年)時の最大積雪深記録を元に多雪時と少雪時の雲面積(ピクセル数)の比較を行った.
3. 畳み込みニューラルネットによる正例・負例の学習の実施

使用したデータ

- 雲画像

NOAA/AVHRR ch.4 (2004~2007年, 2009~2010年, 5年分)

- 積雪深

昭和基地, 積雪深データ(/hour, 同期間)

- 天気概況

昭和基地, 現在天気(ww), 雲量(/3hour, 同期間)

- ブリザード情報

昭和基地, 南極地域観測隊気象部門報告より(同期間)


1. 雲画像の結合

2枚の画像を結合した場合

20090228.1315.n18.hrpt.ch1

20090228.0953.n18.hrpt.ch1

貼り合わせ後




3枚の画像を結合した場合

20090228.
0500.n17.hrpt.ch1

20090228.
0823.n17.hrpt.ch1

20090228.
0953.n18.hrpt.ch1

貼り合わせ後



1-2. 背の高い雲画像領域の分画



処理手順

- 南極大陸域をマスク
- 2値化（閾値となるピクセル輝度：100）
- 画像の膨張処理（膨張回数：3）
 - ・ 2値化処理の結果、前景に出現するノイズを低減するため
- Chan-Veseの動的輪郭法により雲境界を推定

2. 最大積雪深と高高度雲面積の比較

2009年9月9日-10日 **23cm**

2009年3月9日 **3cm**



The value is one digit different.

3. 降雪時の高高度の雲の学習

- 高高度の雲画像を自動検出するために、CNNによる学習器を作成する。

正例条件：昭和基地の天気概況「降雪」

昭和基地の雲量 ≥ 8

負例条件：上記以外の画像視野が大きいもの

- 正例に、GoodとNot Goodタグを付けた。

Good: 高高度の連なる雲が見られる

Not Good: 高高度の連なる雲があった場合でも、


-画像視野が途切れている

-降雪が観測されていない(降雪直前)

GoodとNot Goodを分けた学習→3値分類

GoodとNot Goodをすべて正例にした学習→2値分類

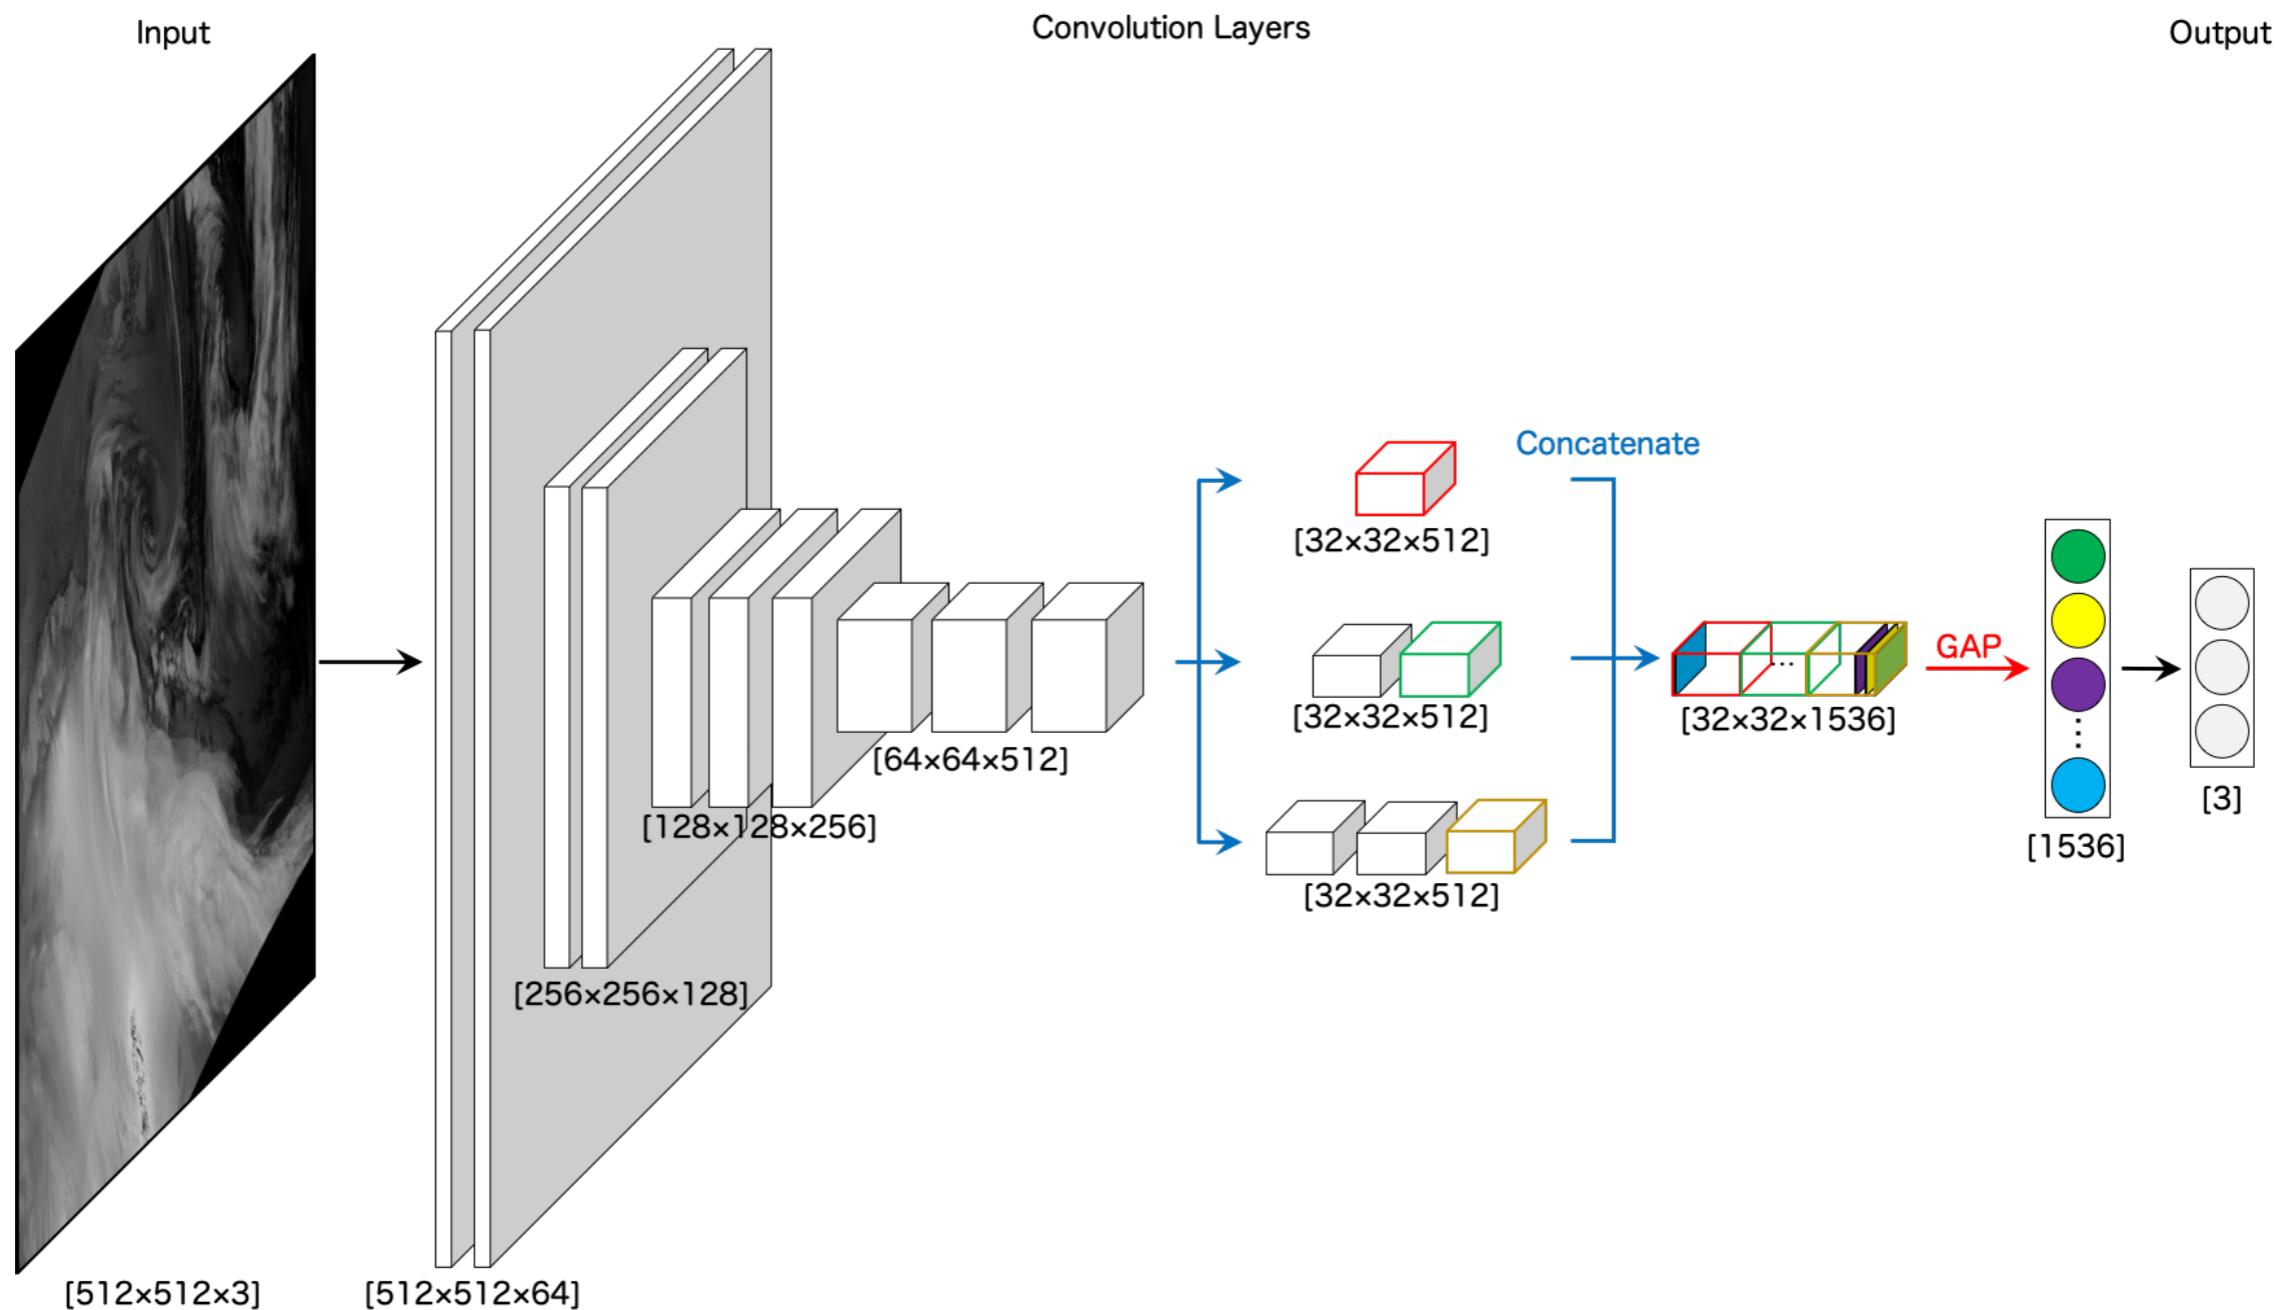
ネットワーク構造 -VGGnet-



畳み込み層と全結合層の数を足して16になるもの→VGG16

3値問題

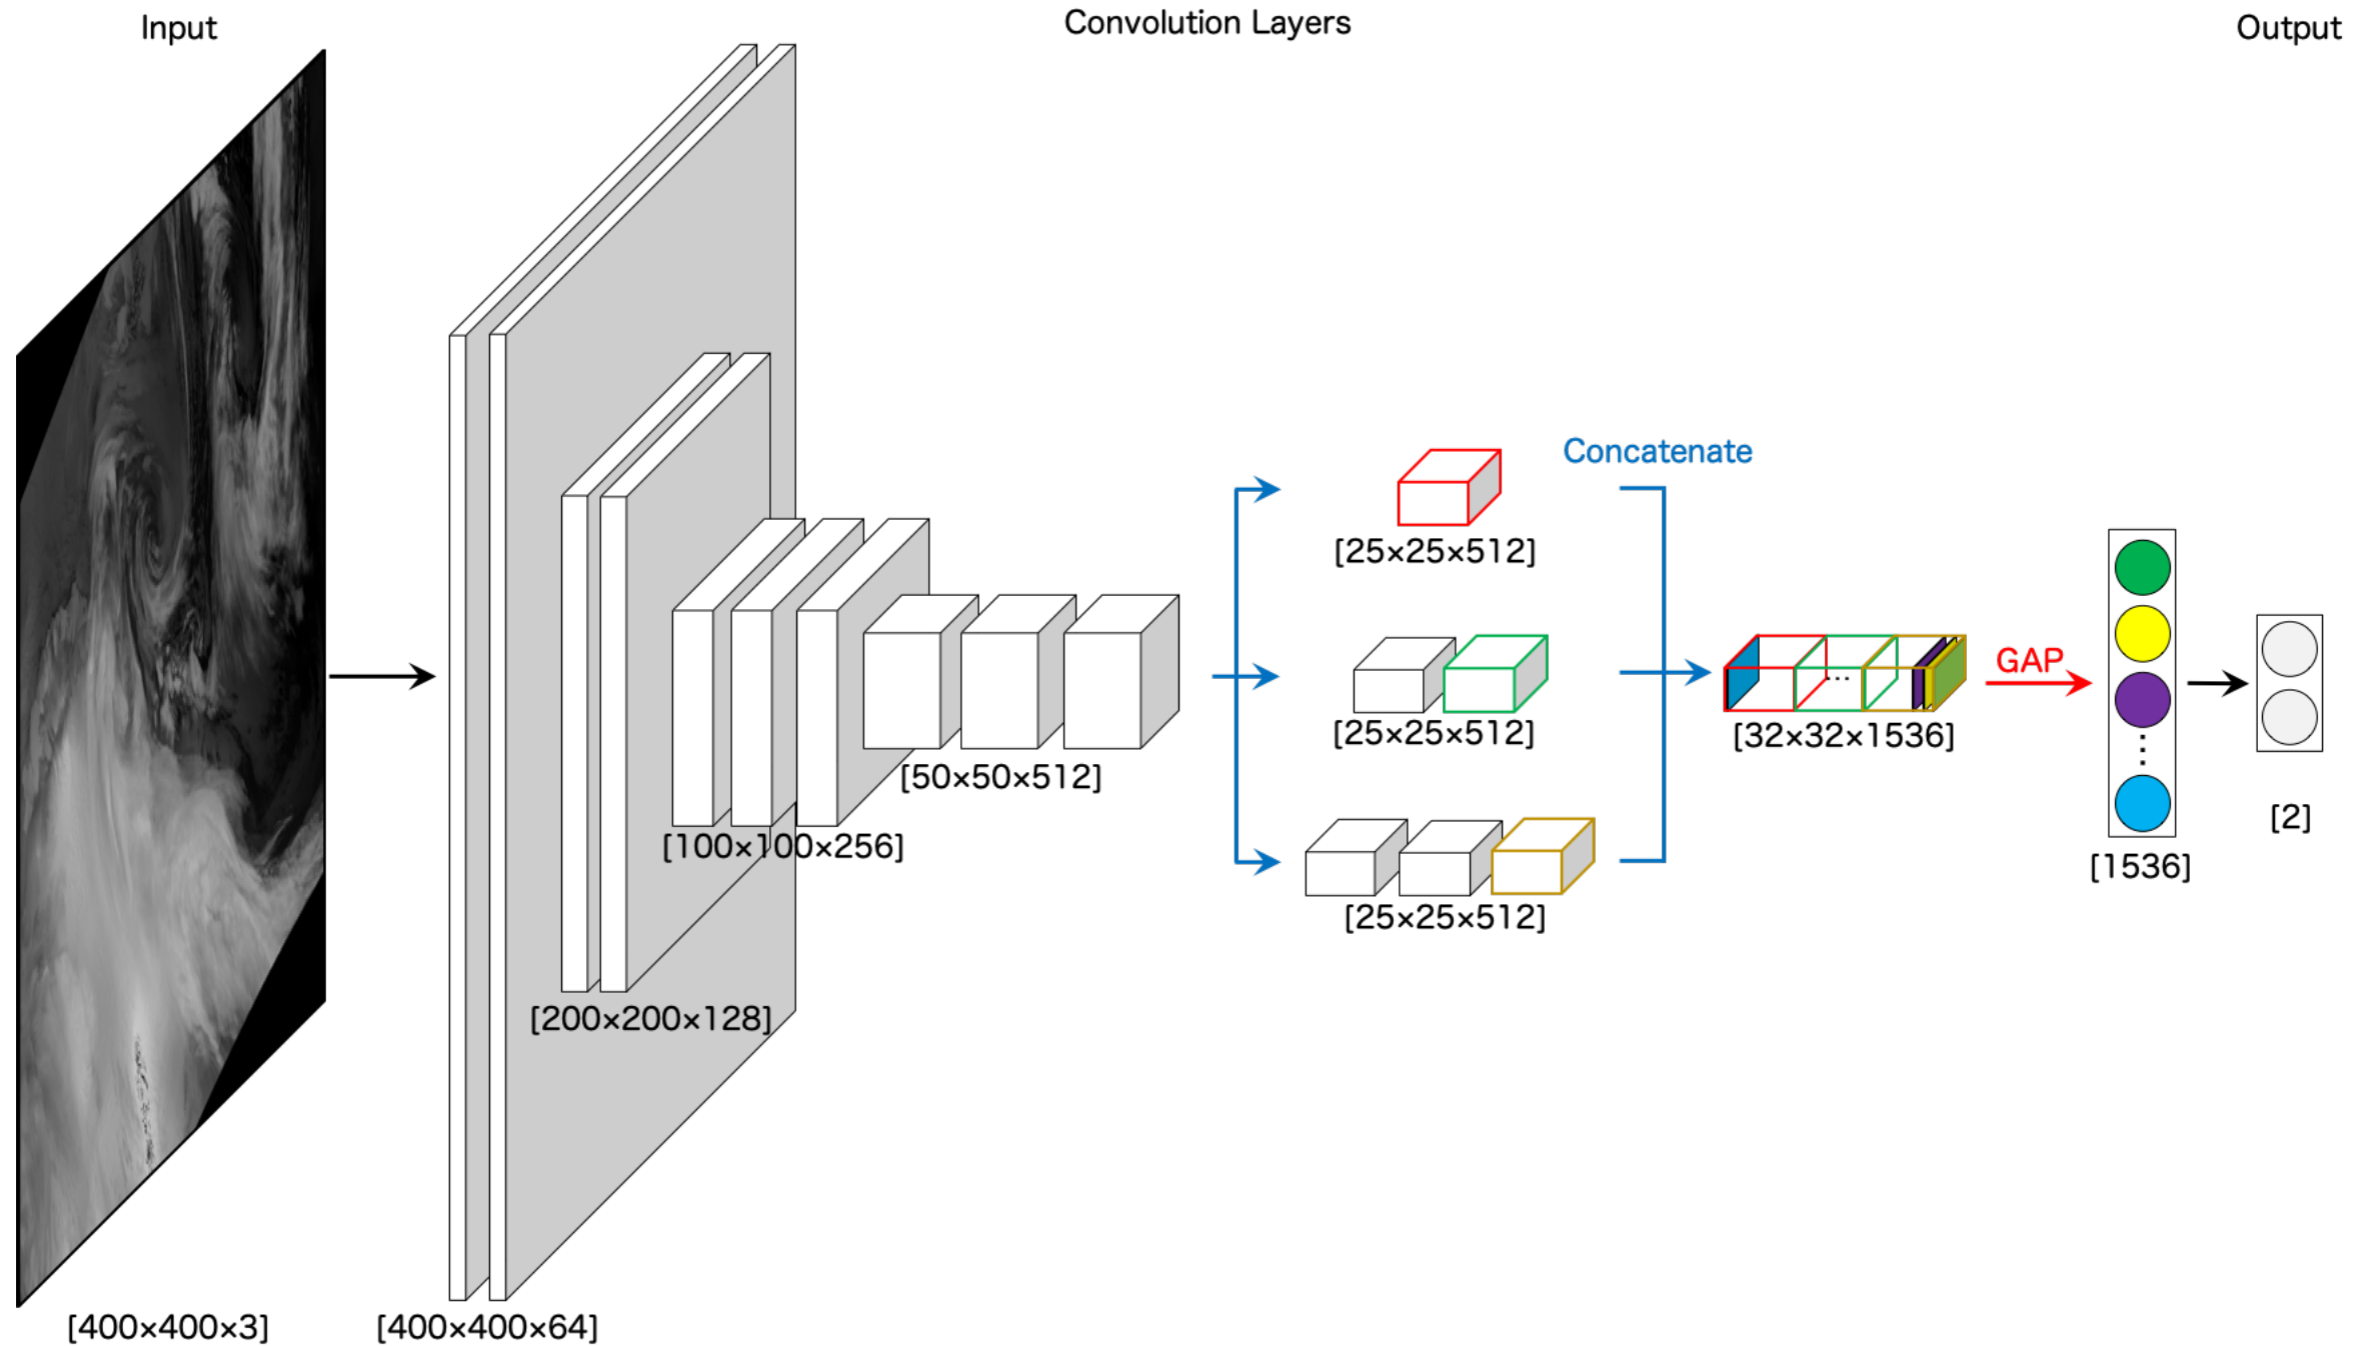
ネットワーク構造 -InceptionVGGNet-



VGG16にInception構造を加え、
さらにBatchNormalizationを施すなど工夫した。

2値問題

ネットワーク構造 -InceptionVGGNet-




CNNによる学習条件

- バッチサイズ：16
- バッチ生成時に画像をシャッフル
- 最適化手法：Adam
(学習率0.1, その他パラメータは一般的($\beta_1=0.9$, $\beta_2=0.99$))
- 最大学習エポック数：300
- 損失関数：Cross Entropy
- 学習がプラトーになって5エポック改善しなければ、学習率を0.1倍する

正・負例の画像数

	train[80%]	val[5%]	test[15%]
Good	138	6	26
NG	477	30	90
Fause	611	38	115

クロップ画像の定義



今回の学習では、
昭和基地では観測されていないが
昭和基地以外では
降雪現象が発生している擾乱に伴う雲
を負例としているため、
学習がうまくいかないと判断。




主に昭和基地に影響を与えると予想できる
画像の右上部分をクロップし、
学習対象とした。

InceptionVGGNetによる識別結果


	2値	3値
学習時精度	87.30%	68.63%
validation精度	87.16%	74.32%
テスト精度	71.00%	65.37%
テスト精度・正例	66.38%	65.52%
テスト精度・負例	75.65%	65.22%
昭和基地上空の雲	69.09%	66.36%

Grad-CAMによる可視化結果


クローズアップ画像



3値分類




2値分類



3値分類の場合、主な雲構造を捉えている。

2値分類の場合は、雲の切れ目や薄い雲と濃い雲の境目などを重点的に見ている様子が見られた。

考察：2層のCNNによる学習



データを増やし，5年分→7年分としたが，学習結果は5年分より精度が落ちてしまった。




原因究明のため，InceptionVGGと比較対象として，2層のCNNによる学習を行った。

7年分のデータセットに対する学習時の Grad-CAMによる特徴量可視化

Cropped image

InceptionVGG

CNN



3値: InceptionVGGは何も捉えていないが, CNNは雲構造を捉えている.



学習データ不足による過学習の発生

パラメータ数比較

Table 4. Number of parameters for CNN model

CNN model	Trainable parameters
InceptionVGGNet	19,705,026
VGG16	33,655,618
ResNet50	23,591,690
2ConvModel	38,978

InceptionVGGNetはVGG16やResNet50など、一般的なCNNよりもパラメータ数の削減に成功している。

しかし、2層モデルと比較するとパラメータ数が3オーダーで異なる。

パラメータ数に対して学習データ不足による過学習の発生



サンプル数を増やすしかない

まとめ

- 2009年のブリザード時について、事前解析を行った。
 - 多雪時, Atmospheric Riverと呼ばれる中緯度からの水蒸気輸送が見込まれる長い高高度の雲がよく見られた。
- 5年分のNOAA/AVHRR ch.4の雲画像を用い、降雪時の雲を正例としたCNNによる学習を行った。
- 画像に欠落がある場合や、降雪が起こる直前の画像をnot good(NG)とし、全体を捉えられている場合(Good)と併せた2値/区別した3値分類を行った。
 - 結果として、2値分類の学習がより精度が高かった。
 - Grad-CAMの可視化結果から、2値分類は雲の連続性、3値分類は雲の全体的な特徴を見ていると考えられた
- サンプル数を追加して7年分のデータセットを作成した結果、過学習に陥った。

謝辞

- 本研究は以下の研究費の支援を受けたものです
 - JSPS KAKENHI Grant Numbers 16K21585
 - JSPS KAKENHI Grant Numbers 20K11718
 - ROIS-DS-JOINT-009RP2019 to K. Suzuki
- 本研究論文は, 2020年度人工知能学会全国大会国際セッションにおいて JSAI 2020 top 21 papersとして選出され, Post Proceedingsとして発行が決定済