

極端気象現象に対する全球数値予報モデルの可視化手法に関する研究

情報数理応用研究

5219C031-8 松元琢真
指導教員 後藤正幸

A Visualization Methods of Global Spectral Model for Extreme Weather

MATSUMOTO Takuma

1. 研究背景と目的

現在、報道などに用いられる各種の天気予報は、民間気象会社の気象予報士により手作業で作成されており、気象庁により発表される予想天気図や各地域に対する予報文（以下、府県概況文）がベースとなっている。ここで用いられる予想天気図は、全球数値予報モデル（以下、GSM）という気圧面ごとに気温などの物理量計 100 種の予測数値が格納された数値データを 1 枚に可視化したものである。そのため、この予想天気図から、気象状況を読み解く力には経験により差が生じるという問題がある。そのため、天気予報で扱うべき特徴的な気象状況（以下、極端現象）に対して、あらかじめその現象を予測し、かつ予想天気図上の該当地域を自動的に特定することができれば大きな予報支援になると考えられる。そこで本研究では、以下に示す 2 つのアプローチから予報支援を行うことを考える。

- (1) 極端現象をタグとし、天候を直接左右する物理量の予測数値が格納された GSM から極端現象を特定するマルチタグ推定モデルの構築。
- (2) Attention 機構 [1] を導入し、タグ付与の要因として注視されている領域を示すことで、極端現象の対象地域を示すモデルの構築。

これらのアプローチにより、タグを用いた過去の事例検索に加えて、気象予報士の熟練度の違いに起因する予想天気図の注視領域のばらつきを解消できると期待される。

このようなタグ推定問題は、画像認識の分野において研究が盛んに行われており、その手法の 1 つとして Attention Branch Network（以下、ABN）[2] が挙げられる。ABN とは、画像認識で用いられる Deep Convolutional Neural Network（以下、DCNN）に対して Attention 機構を組み込み、推論時に DCNN が注視した領域（以下、Attention Map）を用いた重み付けにより識別精度を向上させるとともに、Attention Map の可視化により推論時の判断根拠を視覚的に捉えることを可能としたモデルである。ABN は、様々な DCNN モデルに対して適用可能であることから、本研究で対象とするマルチタグの推定に加えて、Attention Map を可視化することにより、タグごとの注視領域の可視化が可能であると考えられる。

そこで本研究では画像認識で用いられる ABN に対し数値データである GSM を入力として、入力ごとにマルチタグでタグを推定するとともに、タグごとに Attention Map を出力することによりタグごとの注視領域を特定する方法を提案する。GSM を用いてタグを推定することで、予想天気図よ

り高精度な気象状況の推定が可能となると考えられる。さらに、Attention Map を活用することにより、各物理量の組み合わせにより推定されるタグの対象地域の可視化が可能になると考えられる。最後に、実際の気象データ及び予報を用いて分析実験・考察を行い、提案手法の有効性を検証する。

2. 準備

2.1. Deep Convolutional Neural Network

Deep Convolutional Neural Network（以下、DCNN）は、画像認識の分野で用いられる Neural Network の一種であり、画像の局所的な特徴をつかむ畳み込み層と位置のズレに対してロバストにするプーリング層を繰り返し配置することで、認識に有効な特徴を獲得している。DCNN を用いた代表的なモデルの 1 つに ResNet [3] がある。ResNet は深層学習モデルにおいて勾配消失という学習時の課題を回避したモデルである。具体的には、Residual モジュールと呼ばれるショートカットを追加することで、各層において畳み込み等を行った後の情報だけでなく、行う前の情報も加算して学習を行っている。これにより、深いネットワークでも勾配消失を回避し効率的な学習を可能としたモデルである。

2.2. Attention 機構

Attention 機構 [1] とは、機械学習や画像解析で用いられる入力に対して注視すべき箇所を自動的に学習する仕組みを指す。また、推論時に Attention Map と呼ばれるモデルが注視した領域を可視化することで、分類における判断根拠として用いられる。

2.3. マルチタグ学習

マルチタグ学習 [4] とは、関連した複数のタスクを 1 つのネットワークで学習を行う手法である。これは入力が 1 つのタグのみに所属するシングルタグのデータではなく、複数のタグに所属することを許容されたマルチタグのデータにおいて有用となる。1 つのネットワークで学習を行い、各タスクに共通した知識を獲得させることで、各タスクをそれぞれに対応したネットワークで学習させた場合と比較して、少ないデータサンプルで各タスクの予測精度を向上させることが可能である。

2.4. Attention Branch Network (ABN)

Attention Branch Network（以下、ABN）[2] とは、画像認識で用いられる DCNN に対して判断根拠を示す Attention 機構を組み込んだモデルである。ABN は Feature Extractor, Attention Branch, Perception Branch の 3 つのモジュールから構成されている。Attention Map を識別に用いることで画像認識に対して有効な領域に対して適切

な重み付けを行うことで識別精度の向上が見込め、Attention Map の可視化により視覚的な説明力が半うという利点がある。Feature Extractor では、入力画像から Feature Map を抽出する。Attention Branch では、Feature Map を入力とし、入力画像の注視領域を示す Attention Map を出力するとともに、各タグへの所属確率を出力する。Perception Branch では、Feature Map と Attention Map を入力とし、最終的な識別結果を出力する。ABN はマルチタグ学習などのあらゆるモデルに適用可能である。本研究では、1つの入力が複数のタグへ所属することを許容するマルチタグでのタグ推定を考慮しているため、以降では、マルチタグにおける ABN について述べる。

一般的なマルチタグ学習では出力層の各ユニットが各タグに対する識別結果を推定するように設計されている。ABN をマルチタグに拡張する場合は、タグと同数の Perception Branch を設計することによって、各タグに対する識別結果を出力することが可能である。その際、Attention Map を1つの入力に対してタグ数分出力する必要があるため、Feature Map に対してタグと同数のフィルタを用いて畳み込みを行うことで1つの入力に対してタグ数分の Attention Map を得ることが可能となる。

タグ数を T 、 i 番目の入力データの特徴量を \mathbf{x}_i 、正解タグを $\mathbf{y}_i = (y_{i1}, \dots, y_{ij}, \dots, y_{iT})$ 、 $y_{ij} \in \{0, 1\}$ とする。ここで、 $y_{ij} = 1$ は j 番目のタグが付与される場合を、 $y_{ij} = 0$ は j 番目のタグが付与されない場合を表す。また、 i 番目の入力データにおける t 番目の Perception Branch からの出力を $\mathbf{u}_i^t = (u_{i1}^t, \dots, u_{ij}^t, \dots, u_{iT}^t)$ とする。

各 Perception Branch には、式 (1) で示すように、各タグに対応した Attention Map で重み付けられた Feature Map が入力される。

$$\tilde{g}^t(\mathbf{x}_i) = M_t(\mathbf{x}_i)g(\mathbf{x}_i) \quad (1)$$

ここで、 $\tilde{g}^t(\mathbf{x}_i)$ は t 番目の Perception Branch の入力、 $g(\mathbf{x}_i)$ は Feature Map、 $M_t(\mathbf{x}_i)$ は t チャンネル目の Attention Map を表す。

損失関数 $L(\mathbf{x}_i)$ は以下の式 (2)~(4) で与えられる。

$$L(\mathbf{x}_i) = L_{att}(\mathbf{x}_i) + L_{per}(\mathbf{x}_i) \quad (2)$$

$$L_{per}(\mathbf{x}_i) = \frac{\sum_{t=1}^T L_{per^t}(\mathbf{x}_i)}{T} \quad (3)$$

$$L_{per^t}(\mathbf{x}_i) = - \sum_{j=1}^T \{y_{ij} \log u_{ij}^t + (1 - y_{ij}) \log(1 - u_{ij}^t)\} \quad (4)$$

ここで、 $L_{att}(\mathbf{x}_i)$ 、 $L_{per}(\mathbf{x}_i)$ は Attention Branch、Perception Branch による学習誤差、 $L_{per^t}(\mathbf{x}_i)$ はタグ t に対応する Perception Branch における学習誤差を表す。その際、Attention Branch では Sigmoid 関数とクロスエントロピー誤差、Perception Branch では Softmax 関数とクロスエントロピー誤差を用いて学習誤差を算出する。

2.5. 全球数値予報モデル (GSM)

気象予報士は予想天気図として可視化された情報を読み取り、その情報を基にして天気予報を行なっている。この予想

天気図は GSM を基に作成されているため、GSM から直接情報を読み取ることによって高い精度で気象情報を推定することができると考えられる。

GSM とは気象庁により 1 日 4 回発表される、気圧面ごとの気温など計 100 種の物理量が格子点ごとに格納された数値予報データである。1 回の発表につき 84 時間までの予報が地上では 1 時間間隔、気圧面では 3 時間間隔で行われている。GSM には全球域と日本域の 2 種類あり、本研究では日本域（格子点 151×121 の 20km メッシュデータ）を用いる。一般的な画像データとの違いは以下に示す通りである。(1) RGB の 3 チャンネルではなく、物理量ごとにチャンネルが存在し、最大 100 とチャンネル数が多い。(2) 各チャンネルの値域が 0~255 ではなく、各物理量の単位が異なるため値域が変動する。(3) 対象領域が北緯 20 度~50 度、東経 120 度~150 度と固定されている。

3. 提案手法

3.1. 問題設定

注意報・警報として発令される大雪などの極端現象は、被害が大きいため、天気予報で必ず伝えるべき事象である。その際、極端現象は1つとは限らず、例えば、北海道地方に大雨、暴風警報が発令されるというように複数の同時発生することが考えられる。また、天気予報において極端現象は、対象となる地域に関する情報も合わせて発表される。ここで、気象予報士は天気予報を行う際、主に予想天気図から情報を参照しているが、予想天気図は GSM と呼ばれる気圧面ごとの物理量計 100 種の予測数値が格納された 20km メッシュの数値データを基に作成される。GSM を用いることで、天候を直接左右する各物理量の予測数値によって推定が可能であることから、予想天気図を用いた場合と比べてより精度の高い予報が可能であると考えられる。しかし、各極端現象は GSM の物理量の組み合わせにより判定されることから、各極端現象の対象地域を特定することは困難である。

3.2. 概要

本研究では予報士支援を目的とし、一般的な画像データと異なる特性を持つ GSM において、複数の同時に発生する極端現象をタグとしてマルチタグで推定を行うとともに、タグの対象地域の可視化を行う。その際、タグの推定とともに推論時の判断根拠として用いられる Attention Map を出力することで、タグごとの出現位置を可視化することが可能な ABN を援用することを考える。ここで、マルチタグ学習に拡張した ABN では、タグ数と等しい T 個の Perception Branch を設計する必要がある。その際、出力層では各 Perception Branch において全タグに対する所属確率が出力され、式 (3) に示すように各 Perception Branch での学習誤差の平均を Perception Branch の損失関数としている。しかし、本研究で対象とするタグは「大雪」や「大雨」のようにタグ間の相関が高く、従来の ABN では適切な学習が行われないう問題がある。

そこで本研究では、上述の問題に対し、マルチタグにおいてタグ間の相関が高い場合に対応したモデルを提案する。

3.3. 提案モデル

提案モデルでは、各 Perception Branch において出力層のノード数を1つとして、各タグに対する所属確率を出力するように設計した。その際、各 Perception Branch での出力を結合したものと正解データとの学習誤差を損失関数として学習を行う。

i 番目の入力データに対する j 番目の Perception Branch からの出力を v_i^j とし、損失関数を以下の式 (5) に示す。

$$L_{per}(\mathbf{x}_i) = - \sum_{j=1}^T \{y_{ij} \log v_i^j + (1-y_{ij}) \log(1-v_i^j)\} \quad (5)$$

従来の ABN の設計では、各 Perception Branch に対応したタグの学習が行われる際に、出力層に Softmax 関数を適用していたことで、タグ間に高い相関を持つデータの場合に他のタグからの影響によりうまく学習が行われない問題があったが、式 (5) の損失関数によってこれを解消し、Attention Map やタグ推定精度の向上が期待できる。

4. 実データによる検証

4.1. 実験条件

対象データには気象庁より発表される GSM (入力) と府県概況文 (出力ラベル) を用いる。対象期間は 2017 年 1 月 1 日から 2018 年 6 月 30 日であり、2017 年の 365 日間を学習用とし、2018 年の 181 日間をテスト用とした。出力タグは、一般利用者向け、かつ気象が原因となって発令される警報である「大雪」・「暴風」・「大雨」・「暴風雪」の4つを選択した。これらのタグにおいて、府県概況文中でそれぞれのタグに関する記述がある日を正例、それ以外を負例とした。入力データとしては、層ごとの GSM の物理量計 100 種のうち経験的に各ラベルとの関連性が高いと考えられる、500・700・850・1000hPa 風 (東西, および南北方向) (m/s), 500hPa 高度 (m), 300・400・500・600・700・850・925・1000hPa 気温 (°C), 300・400・500・600・700・850・925・1000hPa 相対湿度 (%), 地上降水量 (mm/h) の 26 指標を用いた。また、本研究におけるタグの対象地域は、気象庁により発表される各地に対する予報文である府県概況文に記述されるか否かで行う。そのため、20km メッシュの GSM より、広範囲のメッシュ数でも特定可能と考えられる。したがって、日本域における GSM の 151 × 121 の 20km メッシュデータに対して以下の処理を行い、25 × 25 の 100km メッシュデータに変換した。(1) 151 × 121 の領域を持つ GSM の上下を切り取り 121 × 121 の 20km メッシュデータに変換する。(2) 20km メッシュの格子点から 4 つおきに値を抽出し、25 × 25 の 100km メッシュデータとした。比較手法には、従来手法である ABN とベースライン手法として Attention 機構を用いない単純な ResNet-20 [3] を用いる。ここで、提案手法や ABN における DCNN 構造はベースラインと同じく Resnet-20 [3] を用いた。その際、エポック数 100, バッチサイズ 16 として実験を行った。評価指標としては、正例に対する再現率、適合率、F-measure を用いた。

4.2. 結果と考察：タグ推定

以下の表 1, 2, 3 に実験結果を示す。

表 1: カテゴリごとの再現率

手法	大雪	暴風	大雨	暴風雪
提案手法	0.9464	0.6170	0.8065	0.8571
ABN	0.7500	0.1915	0.8387	0.0714
ResNet-20	0.7679	0.0000	0.0000	0.5000

表 2: カテゴリごとの適合率

手法	大雪	暴風	大雨	暴風雪
提案手法	0.6163	0.3867	0.3788	0.2927
ABN	0.6563	0.2368	0.4000	0.0909
ResNet-20	0.7544	0.0000	0.0000	0.3182

表 3: カテゴリごとの F-measure

手法	大雪	暴風	大雨	暴風雪
提案手法	0.9464	0.6170	0.8065	0.8571
ABN	0.7500	0.1915	0.8387	0.0714
ResNet-20	0.7679	0.0000	0.0000	0.5000

これらの結果により、適合率では「暴風」において、再現率、F-measure では「大雨」以外のタグにおいて、従来手法である ABN や ResNet-20 よりも良い結果を示した。これにより、Attention Map によりタグ推定に有効な領域に重み付けを行うことによって、分類精度が向上することが確認できる。また、適合率においてベースラインである ResNet-20 が最も良い結果を示した。これは、すべてのタグにおいて ResNet-20 が負例と多く予測していたことに起因すると考えられる。

ここで気象予報において、「実際にある極端現象が予報されなかった日 (負例) を正例と予測」する場合よりも、「実際にある極端現象が予報された日 (正例) を負例と予測」する場合のほうが、業務上の損失が大きい。そのため、実際にある極端現象が予報された日をどれだけ正しく予測できているかを示す再現率が重要であると考えられる。したがって、多くのタグにおいて高い再現率を示した本提案モデルは有効であると考えられる。

4.3. 結果と考察：該当地域の特定

図 1, 2 の Attention Map において日本地図内で都道府県が色付けられている箇所は、府県概況文で各タグに関して記述されている場合 (正例) を示す。したがって、図中においてタグは {1, 1, 0, 1} を示している。また、図内のマス目が塗られている箇所は Attention 機構を用いた DCNN モデルによる注視領域を示しており、色が濃くなるほどより強く注視していることを表している。また、図中の予想天気図は GSM において地上気圧を可視化した一例を示す。

図 1 の結果により、提案手法における Attention Map では、各タグにおいて異なる領域に対して注視していることが見てとれる。「大雪」「暴風」「暴風雪」のように実際に予報された箇所に対して注視領域が一致している部分が多い。そ

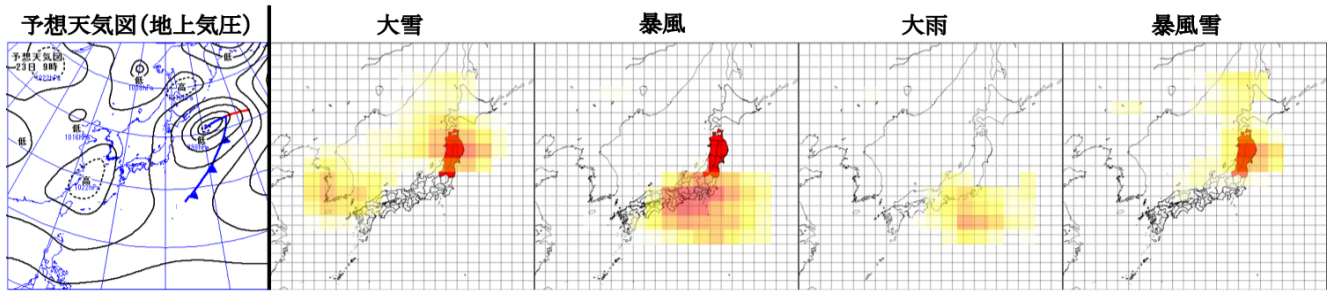


図 1: 提案手法における Attention Map (2018 年 3 月 23 日)

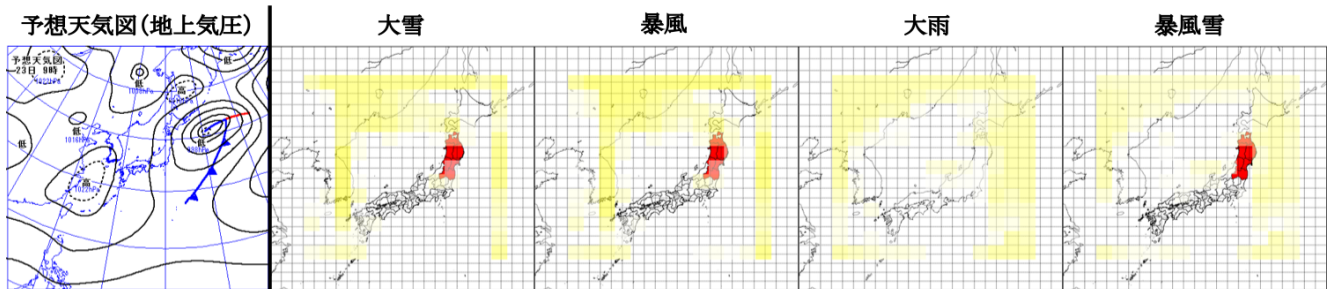


図 2: ABN における Attention Map (2018 年 3 月 23 日)

の一方で、「大雨」のように予報が行われていない場合は、関東付近を注視しているものの強い注視箇所は見受けられない。したがって、Attention 機構により対象領域に対して適切に重み付けられ、分類精度が向上したことが確認できる。また、「大雪」「暴風」「暴風雪」では、正例と注視領域が一致している部分が多いことから、強く注視している部分に対して予報を行うことで出現位置の特定が可能であると示唆される。これにより、様々な情報が記載される予想天気図において、練度の異なる予報士によって読み取る内容が異なるという問題が解消され、予報の均一化に結びつくと考えられる。

図 2 の結果により、ABN における Attention Map では、全てのタグにおいて日本域を囲う形で注視領域がとられており、北海道・東北地方を除く地域がほとんど注視されていないことがわかる。すなわち、誤った重み付けがなされてベースラインである単純な ResNet よりも分類精度が低下したと考えられる。これは、全てのタグに関して類似した Attention Map が出力されており、タグ間の相関が高いことから他のタグから影響を受けたために適切な学習が行われなかった可能性が考えられる。

5. 考察

本研究では、マルチタグで極端現象に関するタグの自動推定を行うとともにその気象現象が該当する地域を可視化する方法を示した。予報士支援を目的として、天候を直接左右する気温などの予測数値が格納された GSM を用いたタグの対象地域の可視化を行ったが、本提案モデルを実務上で用いる際には更なる検証が必要である。現状では、2017 年の 1 年間の学習データとしているが、入力として用いた GSM は 26 チャネルであり、更なる精度向上を考えた場合にはデータ数を拡張することが望ましい。これは、「暴風」であれば、500hPa、850hPa 気温、850hPa 湿度、500–1000hPa 風（東西成分・

南北成分）の物理量と関連性が高いように各タグに基づく物理量が非常に多いことに起因する。また、Attention Map の注視領域で示された部分に対して、具体的にどの地域に対して予報を行うべきかなど位置ラベルの付与方法を検討することにより更なる予報士支援になると考えられる。

6. まとめと今後の課題

本研究では、予報士支援を目的とし、一般的な画像データとは異なる特性を持つ GSM データを用いて、マルチタグで極端現象に関するタグの自動推定を行うとともにそのタグの対象地域を可視化する方法を提案した。結果として提案手法を用いることで、タグの推定精度が向上し、かつ Attention Map を用いて注視領域を可視化することにより対象領域の可視化が可能となった。これにより、気象予報士の経験の差による予想天気図の注視領域のばらつきの一統化など、さまざまな予報士支援への活用が見込まれる。

今後の課題としては、Attention Map を人手により修正し学習させることで、Attention Map の性能向上を図ること、注視領域の位置ラベルの付与方法や入力として用いる GSM の物理量の検討などが挙げられる。

参考文献

- [1] K. Xu *et al.*, “Show, Attend and Tell: Neural Image Caption Generation with Visual Attention,” *ICML*, pp. 2048–2057, 2015.
- [2] H. Fukui *et al.*, “Attention Branch Network: Learning of Attention Mechanism for Visual Explanation,” *CVPR*, pp. 10 705–10 714, 2019.
- [3] K. He *et al.*, “Deep Residual Learning for Image Recognition,” *Proc. of the IEEE conf. on CVPR*, pp. 770–778, 2016.
- [4] R. Caruana, “Multitask Learning: A Knowledge-Based Source of Inductive Bias,” *ICML*, pp. 41–48, 1993.