

修士論文概要書

Master's Thesis Summary

Date of submission: 01 / 09 / 2024 (MM/DD/YYYY)

専攻名 (専門分野) Department	経営システム 工学専攻	氏名 Name	天野智貴 Tomoi Amano	指導 教員 Advisor	後藤正幸 印 Seal
研究指導名 Research guidance	情報数理応用研究	学籍番号 Student ID number	5222C002-7		
研究題目 Title	マルチタスク学習に基づく極端な気象タグの予測アルゴリズムに関する研究 A Study on Prediction Algorithm for Extreme Weather Tags Based on Multi-Task Learning				

1. はじめに

現在、報道などで使用されている天気予報は、民間気象会社の気象予報士によって手作業で作成されている。これらの予報は、気象庁によって発表される予想天気図や各地域の予報文（府県概況文）をベースにしている。予想天気図は、気圧面ごとに気温などの物理量に関する 100 種類の予測数値が格納された数値データを 1 枚の図面に可視化したものである。しかし、予想天気図から気象状況を読み解き、天気予報文を作成するタスクには課題も存在する。具体的には、天気予報の作成には高い専門性を要することや、多くのメディア向けにそれぞれ別々に気象予報文を作成しなければならず、これら一つ一つの天気予報文作成の作業負担が非常に大きいことなどが挙げられる。

この問題を解決するために、松元ら[1]は GSM（全球数値予報モデル）[2]に対して、Attention Branch Network (ABN) [3]をマルチタスク予測に適したモデルに改良し、異常気象発生を予測することで天気予報文作成支援に結びつける手法を提案した。GSM データとは気圧面ごとに気温などの物理量 100 種類の予測数値が格納された特殊な形式のデータである。

しかし、対象問題における正解ラベル付きのデータは、1 年分を集めても 365 日分にしかならない。加えて異常気象の起こる頻度は極めて低いため、正例の学習データを十分に集めることが困難である。故に、推定モデルの学習を十分に行うことが困難であるという課題がある。

そこで本研究では、限られたサイズのデータをベースに、より多様なデータへ拡張することで、モデルの汎化性能を向上させる手法であるデータ拡張手法を提案する。具体的には、GSM データに対して、回転や反転などの拡張操作を施すことで、より多くの学習データを生成し、各拡張手法と GSM データの相性を考察する。また、データ拡張に加え、自己教師あり学習によって生成されたタスクを用いてマルチタスク学習を行うことで、拡張されたデータセットから効率的に、有用な情報を抽出することを目指す。これらの手法の組み合わせによって、提案手法は限られたサイズの GSM データの特徴を効率的に学習し、異常気象に関する高精度の予測が可能になる。

さらに本稿においては、実データを用いた様々な評価実験により提案手法の有効性を示す。提案手法により、従来の予報よりも正確かつ信頼性の高い天気予報文の作成支援が可能になると期待される。

2. 準備

2.1. Attention Branch Network

ABN[3]とは、画像識別で用いられる Deep Convolutional Neural Network(DCNN)に対して、CAM ベースの Attention 機構を組み込んだモデルである。この Attention 機構から得られる値を可視化することで、モデルの予測値に関する判断根拠を解釈することができる。近年注目されている Grad-CAM[4]や SHAP[5]などの model-agnostic な視覚的説明の手法は、深層学習の注視領域を視覚化することはできるが、予測モデルの精度向上には全く貢献しない[6]。しかし、ABN は視覚的説明のために活用可能な Attention 機構をモデルに導入することで、視覚的説明のための注視領域の可視化と精度の向上を同時に実現している。

ABNは図1で示すように Feature Extractor, Attention Branch, Perception Branch の 3 つのモジュールから構成されている。特に Attention Branch において、Attention Map を直接識別に用いることで、識別精度の向上が実現される。また、得られた Attention Map の可視化により、視覚的な説明力が伴うという利点がある。

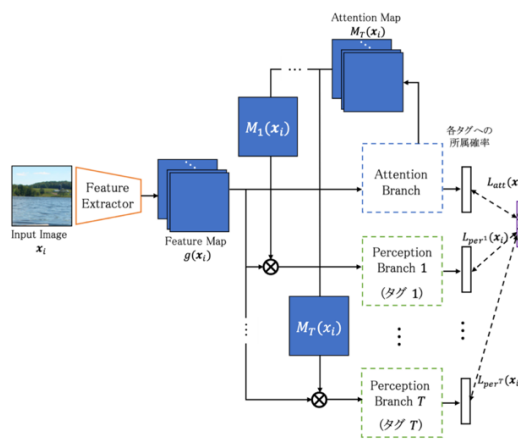


図 1. ABN のモデル構造の概要図

2.2. 松元らの手法

ABN をマルチタスク推定に適応する場合、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、各 Perception Branch での学習誤差の平均を損失関数としている。しかし、「大雪」

や「大雨」のようにラベル間の相関が高いケースが存在するが、従来の ABN ではこのような相関を考慮できていなかった。そこで松元ら[1]は、ラベル間の相関が高い場合に対応したモデル (図 2) を提案している。

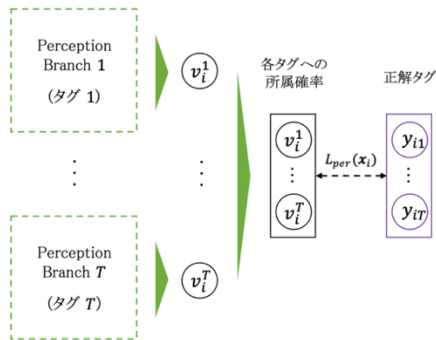


図 2. 松元らのモデルの概要図

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。これにより、タグ間に高い相関がある場合に、他のタグからの影響を受けてしまい、うまく学習が行われないという問題があった。そこで、松元らは各ラベルに関する誤差を独立に計算することでこの問題を解消し、推定精度の向上が実現されている。

2.3. 自己教師あり学習

自己教師あり学習とは、目的のタスク (target task) とは別に、target task の精度を向上するために、教師データ自身から設定できるタスク (pretext task) から事前学習を行う学習方法のことである。自己教師あり学習の概要図を図 3 に示す。




図 3. 自己教師あり学習の概要図

画像データを用いた pretext task の代表例として、画像の回転角分類や反転画像の分類、分割画像の並び替えなどが挙げられる。

自己教師あり学習では、pretext task に関する擬似的なラベルを自動生成するため、事前学習に用いるデータセットに人為的にラベル付与するコストの削減などのメリットがある。また、一般に、事前学習を行うことによって、モデルの汎化性能が向上することが知られている。

2.4. データ拡張

データ拡張とは、画像データに対して、反転や回転などの変換を施すことで学習データの数を増やす手法である。画像の回転を用いてデータ数を 4 倍に拡張した例を図 5 に示す。




図 4. 回転によるデータ拡張

学習データにこのような変換を施すことで、DCNN のような多くのパラメータを持つモデルの学習を十分にすることが可能になる。また、学習データに対する過学習を防ぐことが可能になるなどのメリットも有する。

しかし、変換方法によっては、逆にモデルの精度を下げってしまう可能性がある。そのため、目的のタスクにあったデータ拡張手法を選択することが重要である。

2.5. マルチタスク学習

マルチタスク学習とは、複数のタスクを一つのモデルに同時に学習させることでそれぞれの目的のタスクに関する精度を向上させる手法である。マルチタスク学習モデルの概要図を図 5 に示す。

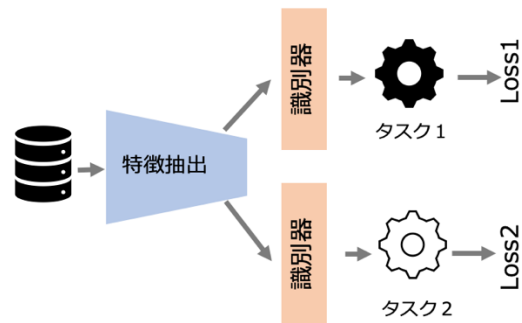


図 5. マルチタスク学習の概要図

各タスクに関する損失を、(0,1)の範囲で設定される調整パラメータによって重み付けした全体の損失を最適化する。これにより、モデルの汎化性能を高めることが可能になる。

3. 提案手法

3.1. 概要

本研究では、GSM データという、気圧面ごとに気温などの物理量の 100 種類の予測数値が格納された特殊な形式のデータを対象とし、かつ学習データ、及び正例の数が非常に少ない状況に対応するために、データ拡張とマルチタスク学習を導入した新たな学習手法を提案する。

3.2. 詳細

提案手法では、松元らのモデルをベースとしつつ、初めにデータ拡張手法を用いて学習データ数を増やす。

本研究で用いる 3 種類のデータ拡張手法を以下に示す。

- 入力データ (GSM) を 0,90,180,270 度回転し、データ数を 4 倍に拡張
- 左右, 上下, 左右上下の反転を施し、データ数を 4 倍に拡張
- データを縦に 3 分割し、並び替えて結合することで、データ数を 6 倍に拡張

次に、(a)から(c)によって拡張されたデータに合ったタスクを生成する。本研究では単に与えられたサイズのままのデータに対して自己教師あり学習を適用するのではなくデータ拡張技術により、データのバリエーションを増やした上で、データ拡張手法に合わせた新たなタスクを生成する。生成するタスクはそれぞれ、(a)回転角度を用いた分類タスク、(b)反転に関する分類タスク、(c)並び替えた順番に関する分類タスクとする。これら 3 つのタスクを

pretext task とし、マルチタスク学習を行う。(a)~(c)を代表して、(a)を用いた提案手法の概要図を図6に示す。

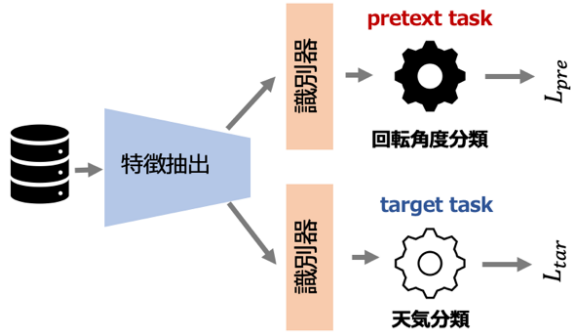


図6. 提案手法を用いたマルチタスク学習(回転角度分類)

ここで、 i 番目の入力データを x_i 、pretext taskの損失関数を $L_{pre}(x_i)$ 、target taskの損失関数を $L_{tar}(x_i)$ とすると、提案手法における損失関数 $L(x_i)$ は式(1)のように表せる。

$$L(x_i) = (1 - \alpha)L_{pre}(x_i) + \alpha L_{tar}(x_i) \quad (1)$$

式(1)のように、調整パラメータ $\alpha \in (0,1)$ によって、pretext taskとtarget taskの損失 $L_{pre}(x_i)$ 、 $L_{tar}(x_i)$ の重み付け和により損失関数を定義する。なお、 $\alpha = 1$ のとき、提案手法はマルチタスク学習ではなく、データ拡張のみを行い、松元らのモデルを使用することと等価になる。

提案手法に含まれるtarget taskに関する損失関数 $L_{tar}(x_i)$ は式(2)~(4)で与えられる。

$$L_{tar}(x_i) = L_{att}(x_i) + L_{per}(x_i) \quad (2)$$

$$L_{att}(x_i) = - \sum_{t=1}^T y_{it} \log(u_{it}) + (1 - y_{it}) \log(1 - u_{it}) \quad (3)$$

$$L_{per}(x_i) = - \sum_{t=1}^T y_{it} \log(v_{it}) + (1 - y_{it}) \log(1 - v_{it}) \quad (4)$$

ここで、 i 番目の入力データに対する t 番目のタグに関するAttention Branchから出力を u_{it} 、 t 番目のPerception Branchからの出力を v_{it} とする($i = 1, 2, \dots, N$, $t = 1, 2, \dots, T$)。なお、 $L_{pre}(x_i)$ も $L_{tar}(x_i)$ と同様に、Attention Branchに関する損失とPerception Branchに関する損失の合計で構成される。

4. 実験

本研究では、一般財団法人日本気象協会から提供されたGSMと気象予報府県概況文の実データセットに対して、提案手法を適用し有効性を検討する。

4.1. 実験条件

対象データは気象庁より発表された2017年1月1日から2018年6月30日の18ヶ月間のGSMデータと府県概要文から構成される。実験では、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。また、データ加工や正例ラベルの作成方法などは松元ら[1]の研究を参考にした。

比較手法には、Attention機構を用いない単純なResNet-20、ABN、松元らの手法(ABN+)に加え、拡張された各データに自己教師あり学習(SSL)を適用したモデルを用いた。また、CR、flip、splitはそれぞれ、回転角度の分類、反転画像の分類、画像の並び替えに関するタスク、

または拡張データを用いていることを表す。提案手法における α は事前実験により探索的に設定し、 $\alpha = 0.7$ とした。また、最大エポック数を50、バッチサイズ32として5回ずつ実験を行った。評価指標には、再現率を用いた。表1に各手法の平均を示す。

表1 各手法の再現率

手法	大雪	暴風	大雨	暴風雪
ResNet-20	0.816 (±0.050)	0.233 (±0.287)	0.424 (±0.353)	0.200 (±0.400)
ABN	0.809 (±0.027)	0.225 (±0.276)	0.657 (±0.191)	0.200 (±0.400)
ABN+	0.871 (±0.040)	0.104 (±0.198)	0.449 (±0.393)	0.100 (±0.200)
SSL(CR)	0.829 (±0.039)	0.429 (±0.386)	0.525 (±0.281)	0.347 (±0.366)
SSL(flip)	0.902 (±0.043)	0.000 (±0.000)	0.000 (±0.000)	0.000 (±0.000)
SSL(split)	0.828 (±0.056)	0.200 (±0.400)	0.343 (±0.430)	0.000 (±0.000)
CR($\alpha = 1.0$)	0.818 (±0.029)	0.549 (±0.298)	0.583 (±0.329)	0.468 (±0.402)
flip($\alpha = 1.0$)	0.823 (±0.043)	0.212 (±0.300)	0.437 (±0.464)	0.056 (±0.112)
split($\alpha = 1.0$)	0.839 (±0.065)	0.381 (±0.335)	0.567 (±0.321)	0.293 (±0.362)
CR($\alpha = 0.7$)	0.813 (±0.038)	0.396 (±0.205)	0.897 (±0.099)	0.680 (±0.411)
Flip($\alpha = 0.7$)	0.849 (±0.147)	0.333 (±0.268)	0.446 (±0.219)	0.138 (±0.276)
split($\alpha = 0.7$)	0.826 (±0.039)	0.080 (±0.160)	0.558 (±0.457)	0.200 (±0.400)

4.2. 実験結果

表1より、再現率は「大雪」以外のタグにおいて、回転画像によるデータ拡張や回転角度分類を用いたマルチタスク学習が最も良い値を示すことがわかった。

また、気象予報において、「実際にある極端現象が起こらない(負例)に対して、起こる日(正例)と予測してしまう誤り」よりも「実際にある極端現象が起こる日(正例)に対して、起こらない(負例)と予測してしまう誤り」のほうが、業務上の損失が大きい。そのため、本研究においては実際に観測された極端気象を正しく予測できているかを表す再現率が重要視される評価指標であると考えられる。その点、提案手法は正例数が極端に少ない「大雨」「暴風雪」のタグにおいて、従来手法を大きく上回る再現率を示している。これは、データ拡張によってデータ数を増加したことが、良い影響を与えたと考えられる。また、「大雪」「暴風」においても、その他の手法に遜色のない結果を示しており、有効なモデルであると言える。

しかし、反転や分割・結合によるデータ拡張手法は松元らの結果と比べても、大きな精度の向上は見られなかった。これより、データ拡張は、その方法によって精度に大きな差異をもたらすことがわかる。その点において、回転によるデータの拡張は気象予測に用いるGSMデータが保持する情報を失うことなく、データ拡張が可能であると示唆される。

5. 考察

5.1. ハイパーパラメータの設定

表1より、回転画像を用いたマルチタスク学習が最も高い精度を示すことがわかった。データ拡張だけでなく、マルチタスク学習における回転角度分類タスクが極端気象の予測に与える影響を図るために α を調整し、損失の重みを変化させたときの再現率の推移を観察する。その結果を図7に示す。

図7より、大雪では α の値が大きくなるにつれて、再現率が増加している。しかし、大雨や暴風雪のような正例データが極めて少ないラベルにおいては $\alpha = 0.7$ のときに最も高い精度を示している。これにより単にデータ拡張を施すだけでなく、target taskによって適切な選択や重みの調整が予測の精度に大きく影響することがわかる。




図7. α の変化による Recall の推移(実験回数 5 回の平均)

5.2. Attention Map の可視化

図8には最も良い精度を示した提案手法($CR \cdot \alpha = 0.7$)と松元らの手法によって得られた Attention Map の可視化した結果を示す。ここで、図8のように、日本地図上で赤色が塗られている箇所は、実際に観測された地点。また、四角の濃淡は Attention の大きさを表す。Attention はその地域のデータが予測に与える影響の大きさを表す。

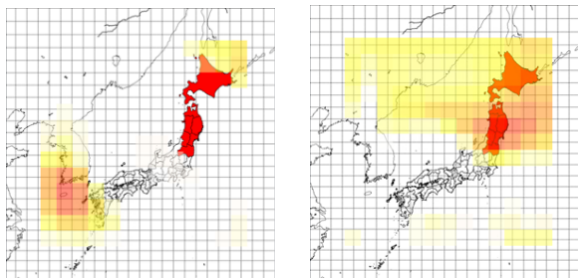


図8. 暴風雪に関する Attention Map

(左: 松元らの手法, 右: 提案手法)

図8より、提案手法は松元らの手法に比べ、全てのラベルにおいて実際に観測された地域を注視領域として捉えていることがわかる。このことは、松元らの手法に比べ提案手法の分類精度が向上した結果を裏付けている。また、得られた Attention Map を活用することで、どの地域の気象に注意すべきかを把握でき、予報士の負担を軽減することが期待される。

6. 結論と今後の課題

6.1. 結論

本研究では、気象予報文の作成支援を目的とし、ABN に自己教師あり学習やデータ拡張といった機械学習手法を組み合わせることで、極端気象のマルチタグ推定の予測精度の向上が可能なモデルを提案した。具体的には、一般的な画像データと異なる構造を持ち、データ数が非常に少ない GSM データに対して、画像認識で用いられるデータ拡張

手法を用いて、極端気象に関するマルチタグの自動推定を行った。その際に、データ拡張手法ごとに、タスクを生成しマルチタスク学習に適用させ、極端気象の予測と同時に学習させることで汎化性能の向上を実現した。特に、提案手法は「大雨」「暴風雪」のような正例数の少ないタグの再現率を大幅に向上させることができた。このことから、回転によるデータ拡張が GSM データと相性が良いデータ拡張手法であることが確認できた。

本研究の成果により、予報文作成にかかる時間を削減することが期待される。また、Attention Map の可視化により予測の対象地域を特定することにより、気象予報士のスキルの差による読み取る内容が異なる問題が軽減され、予報の品質の均一化が可能になると考えられる。

6.2. 今後の課題

提案手法における精度の向上させるため今後の課題としては、以下の2点挙げられる。

1 点目は新たなデータ拡張手法の開発である。今回の実験で用いた、回転によるデータの拡張は精度の向上に寄与した。そこで、GSM データに適した新たなデータ拡張の手法を開発することで、さらなる精度の向上が見込める。

2 点目は、ABN 内の Perception Branch における損失関数を再検討することが挙げられる。各日の天気を完全に予測できなければ損失が大きくなるような損失関数を導入することで、予測精度が向上する可能性が予想される。

参考文献

- [1] T. Matsumoto, Y. Seko, G. Kumoi, M. Goto, and T. Yoshikai. A study on text analysis model to support creation of summarized weather forecast. In *Proceedings of 17th Asian Network for Quality Congress*, 2019.
- [2] M. Kanamitsu, K. Tada, T. Kudo, N. Sato, and S. Isa. Description of the jma operational spectral model. *Journal of the Meteorological Society of Japan. Ser. II*, Vol. 61, No. 6, pp. 812–828, 1983.
- [3] H. Fukui, T. Hirakawa, T. Yamashita, and H. Fujiyoshi. Attention branch network: Learning of attention mechanism for visual explanation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 10705–10714, 2019.
- [4] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra. Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision*, pp. 618–626, 2017.
- [5] S. M. Lundberg and S.-I. Lee. A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, Vol. 30, 2017.
- [6] R. Shimizu, M. Matsutani, and M. Goto. An explainable recommendation framework based on an improved knowledge graph attention network with massive volumes of side information. *Knowledge-Based Systems*, Vol. 239, p.107970, 2022.
- [7] S. Gidaris, P. Singh, and N. Komodakis. Unsupervised representation learning by predicting image rotations. *arXiv preprint arXiv:1803.07728*, 2018.