

自動機械学習を用いた気象判別アプリケーションの 基礎検討

若松 健斗^{1,a)} 林 祐作^{1,b)} 富田 智彦^{2,c)} 小野 智司^{1,d)}

概要: 近年、ゲリラ豪雨や竜巻の予測を目的とした詳細な地上観測網の実現や、気象病と呼ばれる気象変化による体調不良の記録を目的とした個人の環境における天候の記録など、様々な用途で局所的な気象観測の必要性が高まっている。一方で、全国に整備されている地域気象観測システム（アメダス）による数十キロ間隔の気象観測網では、局所的な気象変動を観測し記録することは困難である。そこで本研究では、スマートフォン上で動作する気象判別アプリケーションを、自動機械学習を利用して試作する。本アプリケーションは、自動機械学習を用いて構築した学習済みのネットワークを圧縮してスマートフォン上に搭載することで、オフライン環境での気象判別を実現する。評価実験では、ネットワークの汎化性能と、アプリケーションの機能を検証した。

A Preliminary Study on a Weather Identification Application Using Automatic Machine Learning

Abstract: In recent years, the need for local weather observation has increased for various applications. For instance, predicting local weather phenomena such as guerrilla rains and tornadoes require detailed ground-based observation network. In addition, recording weather conditions in an individual's environment can be used for the purpose of treating physical illnesses caused by changes in climate and weather, known as weather-related diseases. Therefore, this study develops a smartphone application that discriminates the weather using automatic machine learning.

1. はじめに

気象観測は一般に、地上に設置された気象レーダーや静止気象衛星などにより行われ、数十キロメートル程度の水平分解能を持つ広域気象観測網を実現している。一方で近年、より局所的な気象観測の必要性が高まっており、局所的な気象現象の予測のみならず、市街地管理・開発や医療分野等への応用が期待されている。

近年、日本国内では突発的な局所的豪雨（ゲリラ豪雨）によって引き起こされる災害が多発している。気象庁のま

とめによると、2010 年から 2019 年の 10 年間のゲリラ豪雨発生回数は 1976 年から 1985 年の統計と比較して約 1.4 倍にもものぼることが明らかになっており、局所的な気象観測の要望が高まっている。ゲリラ豪雨の他にも、竜巻や突風などの観測や予測の需要も高い。

また、太陽光や風力などの自然エネルギーを用いた発電設備の設置計画やエネルギー管理、大雨や暴風に対する農業用施設等の対策計画においても局所的な気象観測の需要が高い。さらに、医療分野においても認知症患者が受ける刺激の記録による譫妄行動の予測や、気象病と呼ばれる天候が原因となる体調不良の記録や予測への応用が期待されている。しかし、気象観測衛星や地上気象観測システム（アメダス）などによる広域気象観測網の情報のみでは、これらのニーズに対応した局所的な気象の観測や予測は困難である。

そこで本研究では、局所的な気象観測に利用できるスマートフォンアプリケーションを、自動機械学習を利用し

¹ 鹿児島大学 大学院理工学研究科
Graduate School of Science and Engineering, Kagoshima University, 1-21-40 Korimoto, Kagoshima 890-0065, Japan
² 熊本大学 先端科学研究部
Faculty of Advanced Science and Technology, Kumamoto University, 2-39-1 Kurokami, Chuo-ku, Kumamoto 860-8555, Japan
a) sc116033@ibe.kagoshima-u.ac.jp
b) sc115096@ibe.kagoshima-u.ac.jp
c) t-tomita@kumamoto-u.ac.jp
d) ono@ibe.kagoshima-u.ac.jp

て試作する。本アプリケーションでは、一般的なスマートフォンに学習済みのネットワークを実装することで、サーバを介さずオフライン環境でシーンフリーかつリアルタイムに気象の判別が可能となる。また、自動機械学習を用いてネットワークの設計を行い、学習済みのネットワークを圧縮することで、計算資源の限られたスマートフォン単体での気象判別を実現する。評価実験では、自動機械学習で設計したネットワークの汎化性能と、アプリケーションの機能を検証する。

2. 関連研究

気象画像から複数の視覚的特徴を抽出し、ランダムフォレストを用いて気象を判別する方式が提案されている [1]。この研究では、ランダムフォレストで構築した分類器の精度を向上させるために気温、湿度等の気象特性を利用する。しかし、気象特性を考慮せず、単一画像から気象を判別した場合、気象特性を考慮した場合と比較して、精度が著しく低下する。気温、湿度等の気象特性を考慮する場合、環境センサが必要になるため、環境センサが搭載されていない、スマートフォン単体でシステムを完結させることは困難である。

単一の気象ラベルで画像进行分类することの欠点と、異なる気象条件間の共起関係を分析することにより、気象判別をマルチラベル分類タスクとして扱う方式が提案されている [2]。気象認識をマルチラベル分類タスクと見なすことで、特定の画像の気象条件を包括的に記述できない問題や、一部の気象カテゴリ間のクラス境界が曖昧である問題をシングルラベル分類タスクと比較してより解消できる。しかし、マルチラベル分類タスクはシングルラベル分類タスクと比較して、画像からより多くの特徴を抽出する必要があるため、ネットワークのパラメータ数が多くなり、計算量が大きくなる。このため、スマートフォン単体での実装が困難である。

3. 提案手法

3.1 基本アイデア

本研究では、局所的な気象観測を目的とした、気象判別を行うスマートフォンアプリケーションを試作する。自動機械学習技術は、近年、機械学習の実応用において広く利用されており、機械学習モデルのネットワークアーキテクチャの自動設計、および、ハイパーパラメータの自動調整を行うことができる。また、本アプリケーションは、撮影画像から気象を判別する機能だけでなく、時間情報や位置情報を収集し、気象情報と共にデータベースに記録する機能を有する。

気象の判別には、自動機械学習を用いて設計したネットワークによる推論結果を使用し、さらに、学習済みのネットワークをスマートフォンに搭載可能なサイズに圧縮する




図 1: システム構成

ことでスマートフォン単体での気象判別を行う。スマートフォン単体で機械学習を用いて気象の判別を行うことで、サーバ上での推論が不要となるため、ユーザ数が増加した際にもサーバの負荷を抑えることが可能である。

3.2 試作するスマートフォンアプリケーションの処理手順

試作したスマートフォンアプリケーションの処理手順を図 1 に示す。本アプリケーションは、あらかじめ訓練が行われたネットワークを搭載しているため、スマートフォン単体で気象を判別する。まず、アプリケーションが起動されるとカメラが起動し、画面にプレビューが表示され、自動で撮影を行う。次に撮影画像から時間情報や位置情報を取得する。時間情報の取得には撮影画像の exif 情報を、位置情報の取得には位置情報 API を用いる。その後、スマートフォンに搭載した学習済みのネットワークで気象を判別し、収集した天気、時間、位置情報をクラウド上のデータベースに記録する。試作するクラウドサーバ上のデータベースは、モバイルアプリケーションのバックエンドサービスである Firebase の Cloud Firestore を利用する。

3.3 自動機械学習を用いたネットワークの自動構築

気象判別を行うネットワークの構築には、自動機械学習のフレームワークの 1 つである AutoKeras [3] を用いる。AutoKeras は、ニューラル構造検索 (Neural Architecture Search: NAS) をより効率的に行うために、ベイズ最適化アプローチを利用する。NAS は、画像認識や物体検出を目的とした深層ニューラルネットワークの設計に利用され、人手によって設計されたネットワークよりも優れたネットワークを探索可能なことが示されている [4], [5], [6]。AutoKeras は特に、他の自動機械学習のフレームワークと比較して、マルチクラス分類で優れた結果を示している [7]。

3.4 学習済みネットワークの圧縮

本研究では、スマートフォン単体で気象を判別するために、自動機械学習によって構築された学習済みネットワークをスマートフォンに搭載可能なサイズに圧縮する。学習済みネットワークの圧縮には TensorFlow Lite を用いることで、推論精度をほとんど損なわずにサイズを圧縮することが可能になる。

表 1: 自動構築したネットワークの平均正解率

試行	平均正解率 (%)	層数	総パラメータ数
trial 1	77.0%	11	28,746
trial 2	77.1%	11	84,138
trial 3	75.2%	11	28,746
trial 4	73.6%	11	47,210
trial 5	67.7%	11	276,229
trial 6	73.8%	11	305,706
trial 7	76.2%	11	28,746
trial 8	77.3%	11	47,210
trial 9	77.6%	11	28,746
trial 10	78.2%	11	305,706
平均	75.4%	11	118,118

表 2: 混同行列 (平均)

		真値		
		sunny	cloudy	rain
予測	sunny	1687	236	118
	cloudy	271	1610	667
	rain	42	154	1215

4. 評価実験

評価実験では、試作した気象判別アプリケーションの性能と、スマートフォン上に実装した際のアプリケーションの機能を検証する実験を行った。

4.1 実験 1: AutoKeras によるネットワークの自動構築

実験 1 では、天気の日データセットである Image2Weather [8] を用いて、正解率が比較的良好でパラメータ数が少ないネットワークを設計するための実験を行った。Image2Weather に存在する各クラスの画像は不均衡であるため、本実験では、晴れ、曇り、雨の画像をランダムに 1,000 枚ずつサンプリングした合計 3,000 枚のデータセットを 10 個作成し、それぞれ 80% の画像を訓練に用いて 10 個のネットワークを自動構築した。構築した学習済みのネットワークは、10 個のデータセットの全てのテストデータ（データセットのうち 20% の画像）を用いて推論を行い、平均正解率をそのネットワークの性能として評価した。

AutoKeras を用いて自動構築したネットワークの例を図 2 に示し、各ネットワークの平均正解率を表 1 に示す。自

動構築されたネットワーク構造は、10 個のネットワーク全てにほぼ同様の構造が確認された。図 2(a) に示すような畳み込み層 2 層とプーリング層 1 層の組合せが 2 回繰り返された後に全結合層を備える構造や、図 2(b) に示すような、深さ方向に分離可能な 2 次元の畳み込み層である SeparableConv2D 層を含む構造が得られた。表 1 より、いずれの構造の場合も平均正解率に大きな差異はみられなかった。

上記の実験によって得られた 10 種類の構造において、総パラメータ数と平均正解率との関係を表すグラフを図 3 に示す。図 3 より、9 個目に得られたネットワーク構造（図 2(a)）がもっともパラメータ数が少なく、平均正解率も良好であったため、以後の実験では、9 個目に得られたネットワーク構造を用いることとした。

4.2 実験 2: 設計したネットワークの気象判別性能の評価

ここでは、実験 1 で得られたネットワークの気象判別性能の評価を行うために層化 5 分割交差検証を行なった。Image2Weather の晴れ、曇りの画像を 10,000 枚ずつ、雨の画像に画像処理を加えて 10,000 枚に水増しを行なった合計 30,000 枚のデータセットを作成した。なお、画像処理による影響を抑えるために、晴れと曇りの画像にも同じ割合だけ画像処理を加えた。水増しのための画像処理は、データ拡張ライブラリの 1 つである imgaug[9] を使用することとし、図 4 に示す 9 種類の画像処理を適用した。また、データセットのうち 80% の画像を訓練に、20% の画像を推論に使用した。雨の画像については、水増しを行う前の元画像を訓練および推論に分けた後に、それぞれ水増しを行った。

実験 2 における混同行列を表 2 に示す。ネットワークの正解率は 75.2% であり、晴れ、曇りのクラスにおいて 8 割以上の正解率で気象の判別ができたことが確認できる。一方、正解ラベルが雨の画像のうち 33.4% を曇りと誤認識していることから、雨と曇りの判別性能が低いことが確認できる。

実際に雨を正常に認識した画像（図 5(a)）と、雨を曇りと誤認識した画像（図 5(b)）、また、それらを Grad-CAM[10] で可視化した画像の例を図 5 に示す。Grad-CAM は、入力画像のどの領域が推論結果に影響を与えるかを可視化する手法であり、今回は実験 1 で選択したネットワークの最終畳み込み層の勾配を使用し、着目している領域の可視化を行なうことでネットワークにおける気象判別性能の判断根拠とした。雨を正常に認識した画像は、雨を曇りと誤認識した画像と比較して濡れている地面に着目していることが確認できる（図 5(c)）。一方で、雨を曇りと誤認識した画像は、雨を正常に認識した画像と比較して画像内の空の領域が広く、濡れている地面ではなく、雲に着目している（図 5(d)）ことから、このようなシーンにおける気象判別では誤った推論結果を出力する可能性が考えられる。




図 2: 自動構築したネットワーク構造の例




図 3: 自動機械学習によって得られた構造の比較

4.3 実験 3: 試作したアプリケーションの機能評価

実験 3 では、実験 1 で選択した学習済みネットワークをスマートフォン上に実装し、アプリケーションを動作させた際の気象判別機能の評価を行なった。スマートフォン端末は HUAWEI P20 lite を使用し、アプリケーションが正常に動くことを室内と屋外の 2 箇所から確認した。

試作したアプリケーションを用いて、実際に気象を判別

した様子を図 6 に示す。屋内、屋外ともに気象を判別し、天気や時間情報、位置情報をデータベースに記録したことを確認できた。

5. おわりに

本研究では、気象判別を行うスマートフォンアプリケーションを自動機械学習を用いて試作し、学習済みのネットワークを圧縮することでスマートフォン単体での気象判別を可能とした。実験では、スマートフォン端末に実装したアプリケーションの正常な動作を確認し、自動機械学習で構築したネットワークにより、75.2%の正解率で気象判別が行えることを確認した。推論精度の向上や、処理時間の短縮は今後の重要な課題である。

参考文献

- [1] Chu, W.-T., Zheng, X.-Y. and Ding, D.-S.: Camera as weather sensor: Estimating weather information from single images, *Journal of Visual Communication and Image Representation*, Vol. 46, pp. 233–249 (2017).




(a) 元画像



(b) 左右反転 (c) Average Pooling (d) エッジ強調



(e) Affine 変換 15° +1.23 倍拡大 (f) Affine 変換 -15° +1.23 倍拡大 (g) Emboss



(h) PiecewiseAffine (i) Cutout (j) Gaussian ぼかし

図 4: 水増しに用いた画像処理


- [2] Zhao, B., Li, X., Lu, X. and Wang, Z.: A CNN-RNN architecture for multi-label weather recognition, *Neurocomputing*, Vol. 322, pp. 47–57 (2018).
- [3] Jin, H., Song, Q. and Hu, X.: Auto-Keras: An Efficient Neural Architecture Search System, *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 1946–1956 (2019).
- [4] Bello, I., Zoph, B., Vasudevan, V. and Le, Q. V.: Neural optimizer search with reinforcement learning, *arXiv preprint arXiv:1709.07417* (2017).
- [5] Zoph, B., Vasudevan, V., Shlens, J. and Le, Q. V.: Learning transferable architectures for scalable image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 8697–8710 (2018).
- [6] Cai, H., Chen, T., Zhang, W., Yu, Y. and Wang, J.: Reinforcement learning for architecture search by network transformation, *arXiv preprint arXiv:1707.04873*, Vol. 4 (2017).
- [7] Truong, A., Walters, A., Goodsitt, J., Hines, K., Bruss, C. B. and Farivar, R.: Towards automated machine learning: Evaluation and comparison of automl




(a) 雨を正常に認識



(b) 雨を曇りと誤認識




(c) (a) を Grad-CAM で可視化

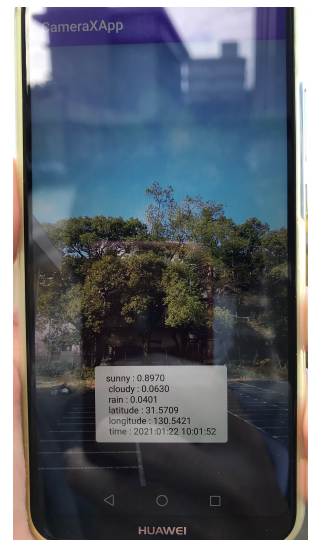


(d) (b) を Grad-CAM で可視化

図 5: 誤認識した画像の例



(a) 室内



(b) 屋外

図 6: 気象を判別している様子

- approaches and tools, *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*, pp. 1471–1479 (2019).
- [8] Chu, W.-T., Zheng, X.-Y. and Ding, D.-S.: Image2Weather: A Large-Scale Image Dataset for Weather Property Estimation, pp. 137–144 (2016).
- [9] Jung, A. B., Wada, K., Crall, J., et al.: imgaug, <https://github.com/aleju/imgaug> (2020). Online; accessed 16-Feb-2021.
- [10] Selvaraju, R. R., Das, A., Vedantam, R., Cogswell, M., Parikh, D. and Batra, D.: Grad-cam: Why did you say that?, *arXiv preprint arXiv:1611.07450* (2016).