

機械学習による全天雲画像の分類

江 越 航 *

概 要

科学館では屋上にライブカメラを設置し、2014 年より全天雲画像のデータを蓄積している。この取得した画像データを、機械学習を利用して解析することを試みた。そこで機械学習のためのニューラルネットワークモデル、および畳み込みニューラルネットワークモデル(CNN)を構築して雲画像を分類し、雲量および天気と関連づけた。この際、雲量については0から10の11段階への分類を行い、天気については、期間中に観測された8種類の天気への分類を行った。本稿では、機械学習を雲画像分類に応用した手法と結果について述べる。

1. はじめに

近年、機械学習を用いた人工知能の技術が、幅広い分野で実用化されている。機械学習とは、コンピューターが画像などの大量のデータからルールや知識を自ら学習する技術のことである。

機械学習は、気象分野においても広く用いられている手法である。現在、日々の天気予報は数値予報の結果をもとに作成されている。この計算結果は物理法則に則り計算された、格子点上での大気状態の様々な数値の集合となっている。この数値データを、ユーザーが利用しやすい形式に加工して、予報要素へ変換(翻訳)することを、ガイダンスと呼んでいるが、このガイダンスを作成する過程において、ニューラルネットワーク、カルマンフィルタ、ロジスティクス回帰などの機械学習を用いた手法が利用されている[1][2]。

また、数値予報のモデルの不完全さによるバイアスを、レーダーアメダスによる降水分布と、機械学習の手法でパターン認識することで、数値予報モデル降水のバイアスを低減する手法なども試されている[3]。

この機械学習の際によく用いられるプログラム言語が Python である。筆者もこの Python を気象分野に活用して、科学館で行っている気象観測データを読み込み、処理してグラフ化し、リアルタイムで現在の気象状況を確認できるようにしている。これにより、展示場で観測データを表示して、現在の展示をさらに効果的に活

用する試みを実践してきた[4]。しかし、機械学習の手法を用いた解析は行っていない。科学館の屋上にはカメラを設置し、全天雲画像のデータを取得しているが、これに機械学習を用いた解析を行うことで、より有用な情報が得られることが見込まれる。

そこで本稿では Python を利用して、全天雲画像のデータを機械学習の手法を用いて活用を試みた方法について述べる。

2. 研究の概要

本研究は、科学館でこれまで蓄積してきた7年半に渡る全天画像・気象観測データを用いて、機械学習を用いて画像を解析し、分類を試みたものである。

最終的には、さらに数値計算モデルのデータと対応させ、モデルと実際の局地的な気象現象に見られる相関を求めることで、気象現象に関して観天望気を用いたより効果的な気象教育を実現することを目的としている。

そのためまず、解析を行うためのシステムの構築を行い、機械学習を用いた画像解析により、雲量および天気を判別することを試みた。

全天雲画像については、機械学習用に適した形にするために事前処理し、学習に必要なデータの抽出を行った。一方、教師データとしては、近隣の気象台で観測された結果を用いることとし、数値化が難しい観測者の目視による雲量、天気の観測結果について、画像データと同時刻のデータを準備した。

これらのデータを入力値とし、機械学習のためのニ

*大阪市立科学館 学芸員
e-mail:egoshi@sci-museum.jp

ューラルネットワークモデル、および畳み込みニューラルネットワークモデル(CNN)を構築して、雲画像の分類を実行した。

以下の項目では、その手順と解析結果を述べる。

3. 解析環境の構築

機械学習の計算を実行するには、高速な並列処理が必要となる。このため解析用 PC として、個別の GPU が搭載されている機種が望ましい。そこで今回は、以下の PC を使用した。

表 1 解析用 PC の仕様

項目	仕様
機種	Surface Laptop Studio
CPU	Core i7-11370H @ 3.30GHz
メモリー	32GB RAM
ストレージ	1TB SSD
グラフィックス	NVIDIA GeForce RTX 3050 Ti Laptop GPU

画像処理装置である GPU を利用して汎用の並列計算を行うためには、CUDA と呼ばれる GPU プログラム開発環境や、cuDNN と呼ばれる Deep Neural Network 開発用のライブラリを整備する必要がある。これらのライブラリを、機械学習のライブラリである TensorFlow のバージョンとの対応を調べてインストールして、GPUを利用して機械学習を行う解析環境を構築した。

4. データの準備

4-1. 訓練データ

入力となる訓練データとしては、科学館で 2014 年から取得している、全天画像データを用いた。

元データは、1 分ごとに取得されており、画像サイズ 640×480 ピクセルの RGB カラーデータである。



図 1 元画像

これを、周辺部をトリミングして 480×480 ピクセルの正方形の画像とする。この際、画像を円形にマスクすることで、全天画像外にある文字は削除する。また、カメラの不具合で明らかに何も映っていない画像が入っているため、各チャンネルのピクセル値から計算して、黒画像のものは学習データから除くようにした。

さらに、この画像サイズでは学習させるには大きすぎるため、48×48 ピクセルに縮小した。これを今回の訓練データとした。




図 2 トリミングした画像と縮小した画像

画像データの時刻は、次項で述べる教師データが存在する時刻で、かつ昼間の時間帯である [6 時、9 時、12 時、15 時、18 時] を用いることとした。期間は 2014～2021 年で、画像枚数はデータの取得できた 13,278 枚である。

4-2. 教師データ

教師データとしては、気象庁ホームページに公開されている、過去の気象データを用いた[5]。

このページでは、全国アメダス観測地点の、10 分ごとの気圧、降水量、気温などが公開されている。「天気」「雲量」についても、3 時間ごとの観測値が掲載されている。そこで、科学館から最も近い「大阪(大阪市中央区)」の観測値のデータを取得し、機械学習における教師データとして用いることとした。データ取得期間は 2014～2021 年とし、Python のライブラリ BeautifulSoup を用いて、該当ページのテーブルから、必要な欄の値を抜き出した。なお、「天気」のデータは、ホームページ上は画像データとして掲載されているが、alt 属性中に代替テキストが設定されているので、これを読み込むことでテキストデータとした。

雲量については、0～10 の 11 種類の分類のほか、「0+」、「10-」の分類もあるが、今回の解析では、それぞれ 0、10 にまとめた。

天気については、期間中大阪で観測された [快晴、晴れ、薄曇、曇、雨、みぞれ、雪、雷電] の 8 種類への分類を試みた。

5. 機械学習の実行

5-1. ニューラルネットワークモデルによる機械学習の実行

ニューラルネットワークモデルは、脳を構成する細胞の動作を模して作られた情報処理の手法である。単純な関数を大量に組み合わせて、複雑な関数を表現することが可能となる。このニューラルネットワークモデルを用いて分類することを試みた。ネットワークの構成を図3に示す。




図3 ニューラルネットワークモデルの構成

入力層として、縮小した雲画像のピクセルデータを1列に並べたものを入力する。入力データのサイズは、1つの画像データに対し、 $48 \times 48 \times 3 = 6,912$ となる。中間層（隠れ層）として、1,024 個のニューロンを用い、活性化関数には ReLU を用いる。中間層の後には、過学習を防ぐために、ドロップアウトを実装する。出力層は、0～10 への雲量の分類、もしくは8 種類への天気の種類とするため、活性化関数は Softmax を用いる。

表2 ニューラルネットワークモデルの構成

層	パラメータ	出力サイズ
入力層	画像データを1列に	6,912
中間層	ニューロン数 1,024	1,024
ドロップアウト	25%	1,024
出力層	ニューロン数 11 or 8	11 または 8

なお、実際に学習を実行する際には、データ全体の9割を学習用データとし、1割はテストデータとすることで、過学習が起こっているかを確かめるようにした。

これを Python で実装し、雲画像に対して雲量の分類、もしくは8種類への天気への分類を行った。

5-2. 畳み込みニューラルネットワークモデルによる機械学習の実行

畳み込みニューラルネットワークモデル(CNN)は、現在ディープラーニングで画像を分類する際に広く使われている方法である。これは生体が視覚情報を行う

際に用いる手法を、ニューラルネットワークモデルに応用したものである。ここではこの畳み込みニューラルネットワークモデルを用いて雲画像を分類することを試みた。ネットワークの構成を表3に示す。

表3 畳み込みニューラルネットワークモデルの構成

層	パラメータ	出力サイズ
畳み込み層 1	フィルタ数 32	$48 \times 48 \times 32$
畳み込み層 2	フィルタ数 32	$48 \times 48 \times 32$
プーリング層 1	ウィンドウサイズ 2×2	$24 \times 24 \times 32$
ドロップアウト	25%	$24 \times 24 \times 32$
畳み込み層 3	フィルタ数 64	$24 \times 24 \times 64$
畳み込み層 4	フィルタ数 64	$24 \times 24 \times 64$
プーリング層 2	ウィンドウサイズ 2×2	$12 \times 12 \times 64$
ドロップアウト	25%	$12 \times 12 \times 64$
Flatten 層	4 階テンソルから 2 階テンソルへ	9216
全結合層	ニューロン数 512	512
ドロップアウト	50%	512
出力層	ニューロン数 11 or 8	11 または 8

こちらでも学習の際に、データ全体の9割を学習用データ、1割はテストデータとして、過学習が起こっているか確認した。これを Python で実装し、雲画像に対して分類を行った。

6. 結果と考察

以下に、ニューラルネットワークモデル、および畳み込みニューラルネットワークモデルを用いて学習を行った結果を示す。

図4は、ニューラルネットワークモデルを使って雲画像の学習を進めた際の、損失関数の変化を示したものである。比較的早い段階で、損失関数の減少が止まっており、長時間学習を進めても、あまり変化は見られない。なお、最終的な正答率は、学習用データ、テストデータとも58%となった。




図4 損失関数の変化（ニューラルネットワークモデル）

実際の分類結果は、図 5 のようになった。ニューラルネットワークモデルによる予測は、ほとんど雲量 0、もしくは 10 に偏ってしまっていることが分かる。




図 5 雲量の分類(ニューラルネットワークモデル)

図 6 は、畳み込みニューラルネットワークモデルを使って雲画像の学習を進めた際の、損失関数の変化を示したものである。学習を進めるにつれて、学習用データの損失関数は減少していくが、逆にテストデータの損失関数は増加しており、過学習となっていることが分かる。

実際の分類結果は、図 7 のようになった。畳み込みニューラルネットワークモデルによる予測は、学習用データに対しては、非常にうまく分類できていることが分かる。最終的な正答率は、学習用データ 95%、テストデータ 60%となった。




図 6 損失関数の変化(CNN モデル)




図 7 雲量の分類(CNN モデル)

雲画像から 8 種類への天気への分類に関しても、同様の結果となり、ニューラルネットワークモデルに比べて畳み込みニューラルネットワークモデルによる分類の方が、正答率が高いものの、学習用データに対する過学習が起こっているという結果になった。

機械学習による雲画像の分類は、全体的には、精度はまだ十分なものになっていない。この原因として、入力データ側の問題点として、気象台の観測データと科学館での観測データに明らかに乖離があるケースの存在、画像内の太陽と雲の判別、元のデータに偏りがあり、雲量の観測値として曇りのデータが多い、等の要因が考えられる。もう一つの問題点として、ニューラルネットワークモデル、および畳み込みニューラルネットワークモデルを用いて解析する際のパラメータ値を、さらに多数回の試行を重ねて、適切に選定する必要があると考えられる。また、画像データだけでなく、同時に観測された気象データも、入力パラメータに含めることで、より正確な分類ができる可能性がある。

7. まとめ

今回、科学館で蓄積してきた 7 年半に渡る全天画像データを用いて機械学習により画像を解析し、雲量の分類、および 8 種類への天気への分類を行った。

用いる機械学習の手法として、ニューラルネットワークモデルに比べて畳み込みニューラルネットワークモデルによる分類の方が、雲量の分類、天気への分類とも、よい結果が得られた。一方で、学習用データに対する過学習が起こっているため、未知の画像に対しては、まだ十分な精度を得ることができていない。

より精度のよい分類のためには、入力データのチェック、パラメータの調整、追加の気象データの活用等を検討する必要がある。

謝辞

本研究は JSPS 科研費 JP22K02976 の助成を受けたものです。

参考文献

- [1]気象庁における機械学習の利用, 第 6 期 AITC 成果発表会(2016)
- [2]気象庁 数値予報解説資料, 51, p106-116(2018)
- [3]吉兼隆生, 芳村圭, 2018 年度人工知能学会全国大会(第 32 回)論文集(2018)
- [4]江越 航, 大阪市立科学館研究報告, 29, p25-30 (2019)
- [5]気象庁 過去の気象データ検索
<http://www.data.jma.go.jp/obd/stats/etrn/indwx.php>