

畳み込みニューラルネットワークによる天気カテゴリー推定

岐阜大学 学生会員 ○尾関 慶祐
 岐阜大学 正会員 吉野 純
 岐阜大学 正会員 小林 智尚

1. 緒言

天気予報に用いられる数値予報モデルは「晴れ」「雨」「くもり」などといった天気カテゴリーを直接予測しているわけではなく、大気の特徴を表す気圧、湿度などの物理量の予測結果を格子点値（GPV）として出力している。この GPV から天気カテゴリーへと翻訳する処理を天気予報ガイダンスとよぶ。これは、GPV と実際に観測された天気との間の関係を統計処理によって事前に求めておき、予報日の GPV を入力することによって各気象値の予想を行うものであり、いわゆる MOS 方式がそれに該当する（新田ら, 2015）。このような天気予報技術の進展により、今日明日の天気予報の精度は年々向上しつつあるが、夏季のゲリラ豪雨や冬季の降雪など、予測の困難な状況もある。

気象庁が作成する天気予報ガイダンスには、ニューラルネットワーク（NN）という統計処理手法が用いられているが、近年、画像認識の分野において NN の一種である畳み込みニューラルネットワーク（CNN）が注目されている。そこで本研究では、人間を凌駕する画像認識能力を持つと言われている CNN を用いて、日本周辺の天気図と気象台で観測された天気カテゴリーを学習させることによって高精度な天気予報ガイダンスを構築することを目的とする。

2. 研究手法

2.1 畳み込みニューラルネットワーク CNN

本研究では最先端の画像認識技術である CNN を活用する。CNN の基となる NN は脳の神経系を模した数学モデルのことを指し、ネットワークは訓練データと対応する正解データを同時に与えられることによって学習し、パラメータは自動で最適化されていく。そして、CNN は特に画像認識に適した技術であり、GPV を画像

データとして学習し、気象台で観測された天気を正解データとすることで、従来以上の精度で天気カテゴリーを推定できると期待される。

本研究では、図-1 に示すように、畳み込み層を 6 層含んだ CNN を用いて学習を行う。CNN は画像内の特徴を表すフィルターを作成し、類似度を評価して認識に活用する仕組みをもつ。すなわち、多くのフィルターをもつ CNN はより多くの認識パターンを学習することができる。図-1 中の橙色の層（Conv）が畳み込み層を表すが、Conv1～6 までのフィルター数はそれぞれ 16, 16, 32, 32, 64, 64 を基準として用いる。




図-1 学習に用いる CNN の模式図

2.2 使用する学習データ

本研究では岐阜市における冬季の天気カテゴリーを予測するネットワークを構築するため、学習データとして米国環境予報センターNCEPのFinal Analyses（FNL）データを使用する。FNLデータは $1^{\circ} \times 1^{\circ}$ メッシュの3次元客観解析データであり、対象期間は2008～2017年の1月の00時、06時、12時UTCとし、内2008～2015年（計744枚）を訓練データ、2016～2017年（計186枚）をテストデータとする。画像領域は北緯 $22^{\circ} \sim 49^{\circ}$ 、東経 $123^{\circ} \sim 150^{\circ}$ の $28^{\circ} \times 28^{\circ}$ の範囲とする。

そして、学習データに対応する正解データとして、岐阜地方気象台（北緯 35.40° 、東経 136.76° ）で同期間

キーワード 畳み込みニューラルネットワーク（CNN）、天気予報ガイダンス、天気カテゴリー、画像認識
 連絡先 〒501-1193 岐阜市柳戸1-1 国立大学法人 岐阜大学 TEL (058)230-1111

に観測された天気を用いる。ここでは、気象庁の天気カテゴリのうち快晴・晴・薄曇・曇を「降水なし」、雨・みぞれ・雪を「降水あり」として集計した。

3. 結果と考察

本研究では、CNN のフィルター数の違いや学習データの種類や数の違いに着目して、多数のケースを設定して認識精度の違いについて比較を行った。ここで、CNN の学習のケースを表-1 に示す。ただし、CNN のフィルター数については、2.1 節で示したフィルター数を基準として、表-1 の比率で定数倍している。また、CNN の精度検証には、的中率とスレットスコアの 2 種類を使用する。スレットスコアとは、降水のような発生頻度の低い現象の的中評価に適した指標として知られている。いずれも、学習が十分に進行した後に、テストデータに対する平均値を評価して、認識精度とした。

表-1 各学習ケースの設定

ケース	学習データ	データ種類	CNNのフィルター数
Case1-1	地上気圧	1種	基準
Case1-2			2倍
Case1-3			1/16倍
Case2-1	地上気圧, 850・500hPaの	3種	基準
Case2-2	ジオポテンシャル高度		3倍
Case3	地上気圧, 850・700・500・300hPaの	5種	5倍
	ジオポテンシャル高度		
Case4	地上気圧, 850・500hPaの	11種	11倍
	ジオポテンシャル高度・相対湿度		
	・気温・東西風速・南北風速		

各学習ケースの認識精度を表-2 に示す。表-2 の Case1-1 より、地上気圧のみを学習させた場合においてもテストデータに対する的中率は 0.883、スレットスコアは 0.348 (図-2) となり、このことから CNN の高い画像認識性能を確認することができる。ここで、Case1-1 に対してフィルター数を 2 倍にした Case1-2 では認識精度は大きく変化しなかったが、フィルター数を 1/16 倍と減らした Case1-3 では的中率もスレットスコアも大きく低下していることが見て取れる。これらの結果より、フィルター数を十分に大きく設定することは認識精度の向上において非常に重要となるが、必要以上に大きくしても精度は向上しないことが明らかとなった。本研究の目的においては、1 種類のデータを学習する際には基準のフィルター数で十分であると考えられる。

Case2 では、地上気圧に上層 (850hPa 面および 500hPa 面) のジオポテンシャル高度を追加することで計 3 種類のデータを学習させているが、Case2-1 では基準のフィルター数を、Case2-2 では種類に応じて 3 倍のフィルター数を設定している。このとき、両ケースの的中率

はあまり変化しなかったが、スレットスコアは Case2-2 の方がより高く、学習データの種類を増やす場合にはそれに応じてより多くのフィルターを用いる必要があると言い換えられる。よって、以降では x 種類のデータを学習する場合には x 倍の数のフィルターを用いることとする。

次に、Case3 では、Case2 に新たに 2 つの気圧面 (700hPa 面および 300hPa 面) を追加しているが、このとき Case1 や Case2 よりも的中率が向上していることがわかる。そして、Case4 では Case2 に新たに 4 種類の気象値 (相対湿度、気温、東西風速、および、南北風速) を追加しているが、テストデータに対する的中率は 0.917、スレットスコアは 0.455 となり、評価基準である Case1-1 と比較して認識精度が高く、多種類のデータを学習したことで認識精度が大きく向上したことが分かる。Case3 と Case4 の対比により、1 月の天気予報を行う上で、学習データに対して層の数を増やすよりも、種類の数を増やした方がより認識精度を向上させることができることが明らかとなった。

表-2 各学習ケースの認識精度

ケース	的中率	スレットスコア
Case1-1	0.883	0.348
Case1-2	0.885	0.338
Case1-3	0.828	0.090
Case2-2	0.898	0.321
Case2-2	0.895	0.349
Case3	0.910	0.344
Case4	0.917	0.455




図-2 Case1-1 におけるスレットスコア (紺色線) の推移

4. 結語

本研究では CNN を用いて過去の GPV を学習し、天気予報ガイダンスを構築した。学習データに地上気圧だけを用いた場合に比べて、上空のジオポテンシャル高度を学習データに追加した場合において認識精度の向上が見られた。また、そこに降水現象に関係する相対湿度・気温・風速などの情報を加えると精度はさらに向上した。今後は、異なる月に対して、本稿より複雑な天気カテゴリを設定することで、実用性が高く、より高精度な天気予報ガイダンスを作成してゆきたい。