

深層学習を用いた 1～3 時間降水量の予測

広島県 非会員 今村実 愛媛大学大学院 学生会員 ○伊藤寛幸
愛媛大学大学院 正会員 全邦釘 愛媛大学大学院 正会員 藤森祥文
京都大学 正会員 西村文武 愛媛大学大学院 正会員 森脇亮

1. はじめに

近年、日本各地で豪雨災害が頻発し甚大な被害をもたらしている。平成 30 年 7 月豪雨では、多くの気象庁アメダス観測点観測史上 1 位の記録を更新するなど、広い範囲で記録的な大雨となった。今後、更に豪雨の回数が増加することが見込まれており¹⁾、豪雨発生時に避難やダム操作を適切に行うためには高い精度で降水を予測することが重要である。そこで本研究では、近年学習機能の向上が著しい深層学習²⁾を用いて降水量の予測を試みた。




図-1 使用データの観測地点

2. 研究方法

降水の発生には面的な気象要素が深く関係している。そこで本研究では、愛媛県内で観測された気象データと 1～3 時間先の松山の降水量との関係を学習させ、ある時刻の気象データからリードタイム 1 時間、2 時間、3 時間で松山の降水量を予測させる深層学習モデルを構築する。ここでリードタイムとは、入力データの時間帯と出力データの時間帯の差である。使用した気象データの観測地点を図-1 に、入出力データの内容を表-1 に示す。モデルの構築方法を図-2 に示す。モデルの学習データには、表-1 に示す気象データのうち観測期間が 2007～2016 年の 6 月 1 日～8 月 31 日で、欠測がある時間を除いたものを使用した。このとき、パラメータとして、中間層の数：10、中間層のユニット数：200、バッチサイズ：256、ドロップアウト：0.3 と設定した。予測モデルのパフォーマンス検証には、2017 年、2018 年の夏季において、5 つの異なる降雨パターンを使用した。検証に用いた降雨パターンの諸元を表-2 にまとめる。また、5 つの Case で、深層学習モデルを用いて降水量予測を行い、その実用性を検証した。

表-1 入力・出力データ

入力						出力
観測地点	項目					
松山	気温	風速	風向NS成分	風向EW成分	日射量	松山の 降水量 (1～3時間後)
	海面気圧	相対湿度				
松山南吉田	降水量	気温	風速	風向NS成分	風向EW成分	
大洲	降水量	気温	風速	風向NS成分	風向EW成分	
今治	降水量	気温	風速	風向NS成分	風向EW成分	
西条	降水量	気温	風速	風向NS成分	風向EW成分	
久万	降水量	気温	風速	風向NS成分	風向EW成分	




図-2 モデルの構築方法

表-2 検証に用いた降雨パターンの諸元

Case No.	説明	期間
Case1	小規模な雨	2017/06/27 19:00 ～ 06/28 08:00
Case2	中規模な雨	2017/06/24 18:00 ～ 06/25 10:00
Case3	突発的な降水量増加がある	2018/06/19 22:00 ～ 06/20 16:00
Case4	台風の上陸による降水	2017/08/06 02:00 ～ 08/07 14:00
Case5	平成30年7月豪雨	2018/07/05 05:00 ～ 07/07 18:00

3. 結果と考察

3.1 深層学習モデルの構築

構築した深層学習モデルのパフォーマンス検証を行った。すべての Case において、降水波形の立ち上がりと降り終わりの時間を予測できていることが確認できた。ここで、平成 30 年 7 月豪雨の降水量予測をみる。Case5 の実測値とリードタイム 1 時間の深層学習モデルによる予測値の比較を図-3 に示す。図-3 より、

7月6日 8:00~14:00 にかけて、降水波形の立ち上がりと降り終わりの時間を予測できていることがわかる。しかし、降水量が突発的に増加する7月6日 17:00、7月7日 7:00の時間は降水を大きく過小評価していることがわかる。

ここで、松山の降水量予測には入力データのどの要素が重要か検証するために、モデルの入力層の各ユニットで計算された重みの出力を行った。出力結果からいくつか重みの特徴が見えてきた。一つ目は、松山の降水量予測には南吉田の降水量と松山の日射量が重要である。松山の日射量はどのCaseでも重みが大きいため、日射量の変化が降水量の予測に重要であると考えられる。二つ目は、大洲の降水量と風速はリードタイム2時間のモデルで重みが大きくなる傾向がある。このことから大洲のある時刻の降水量と風速は、2時間後の松山の降水量と深い関係を持っていることが考えられる。




図-3 Case3の実測値とリードタイム1時間の深層学習モデルによる予測値




図-3 Case5の実測値とリードタイム1時間の深層学習モデルによる予測値

3.2 GPV との比較による実用性検証

構築した深層学習モデルの実用性検証を行った。深層学習モデルの予測値と気象庁が提供するGPV(Grid Point Value)の予測値を比較した。評価指標として降水規模の大きさを考慮してモデルの精度を評価できるNash係数を用いた。各CaseのNash係数とGPVのNash係数の比較を図-4に示す。図-4より、深層学習モデルはGPVよりもNash係数が高い傾向があることがわかる。このことから、深層学習モデルはGPVに比べて実用性が高いことが示唆される。

4. おわりに

深層学習を降水量予測に用いることで、高いパフォーマンスを発揮した。また、実用性の検証として深層学習モデルとGPVの予測精度の比較を行うと、GPVよりも深層学習モデルは予測精度が高い傾向がみられた。本研究は、松山の降水量予測を試みた解析結果であり、今後、他の場所で検討していく必要がある。

参考文献

- 1) 国立環境研究所, 異常気象と地球温暖化の関係について (閲覧日: 2019年2月8日)
<http://www.cger.nies.go.jp/ja/news/2013/130911.html>
- 2) 岡谷貴之: 深層学習, 講談社サイエンティフィク, 2015.

謝辞

本研究は、平成31年度下水道技術研究開発(GAIA)(代表: 西村文武)の援助を受けた。




図-4 各Caseの深層学習モデルとGPVのNash係数