

深層学習を用いた降水量の予測精度向上に関する基礎的検討

愛媛大学大学院 学生会員 ○木原拓海 愛媛大学大学院 学生会員 泉翔太
愛媛大学大学院 正会員 藤森祥文 愛媛大学大学院 正会員 森脇亮

1. はじめに

近年集中豪雨が頻発し、日本各地で甚大な被害をもたらしている。豪雨による被害の抑制のためには、ダム流入流出量の適切な管理、正確な洪水予測や土砂災害警戒避難情報が求められる。ダム管理や情報発信は降雨量をもとに実施されているため、降水量予測の高精度化は必要不可欠である。そこで本研究では近年予測精度の向上が著しい深層学習を用いて、降水量の正確な予測を試みる。深層学習を用いた降雨予測はこれまでも行われており、藤森ら(2019)は愛媛県内の AMeDAS データと 1 から 3 時間後の松山の降水量の関係をモデル化し、松山の降水量予測を試みた¹⁾。その結果、気象庁の数値予測と同等またはそれ以上の精度を示した。しかし、リードタイム（予測までの時間）が大きくなるにつれて精度の低下がみられた。その要因として、藤森らは予測対象地点の周辺の実測値のみを用いており、リードタイムを大きくするにはより広域なデータが必要だと考えられる。また、降水の発生は様々な面的な要因が関係しており、地点データだけでなく面的なデータを用いることで精度が向上すると考えられる。そこで本研究では面的な気象データを用いて降水量予測の精度向上を試みた。その際、学習データの面的な範囲の違いによる精度と、リードタイムの違いによる精度についても検証を行い、リードタイムの向上についても検討する。

2. 研究方法

本研究では面的な気象データ（学習データ）として気象庁の GPVMSM（Grid Point Value Meso - Scale Model）の初期値（客観解析値）を用いた。学習データの項目は海面更正気圧、全雲量、東西風、南北風の 4 項目で、学習期間は 2007 年から 2016 年の 10 年分（6 から 8 月のみ）である。これらの学習に対して正解ラベルとして数時間先のアメダスの降水量を与え、それらの関係を学習させモデルを構築する。その後、構築した深層学習に予測したい期間の気象データを入力することによって、数時間先の降水量の予測値が出力される。モデルの検証データ（テストデータ）として表-1 に示す 5 つの降水パターンを用いた。また、検証するリードタイムは 3 時間と 6 時間とした。

学習させる気象データの範囲による精度の検証を行うため、図-1 に示す 3 つの Range を用いて検証を行った。本研究では松山の降水量を予測することを目的としたため、Range S は松山周辺、Range M は松山を含む四国と九州、Range L は松山を含む中・四国と九州を囲む範囲に設定した。

表-1 検証に用いた 5 つの降水 Case

Case No.	期間	説明
Case1	2017年6月27日 19:00 ～ 6月28日 08:00	小規模な降水
Case2	2017年6月24日 18:00 ～ 6月25日 10:00	中規模な降水
Case3	2018年6月19日 22:00 ～ 6月20日 16:00	突発的な降水量増加がある
Case4	2017年8月7日 02:00 ～ 8月7日 14:00	台風の上陸による降水
Case5	2018年7月5日 05:00 ～ 7月7日 18:00	平成30年7月豪雨




図-1 学習データの範囲

Range S(左上) Range M(右上)
Range L(下)

3. 結果と考察

図-2、図-3に Range M と Range L における Case4(台風の上陸に伴う降水)のリードタイム3時間および6時間の降水量予測結果をそれぞれ示す。深層学習モデルによる予測値は GPV のデータが3時間間隔であることから、3時間間隔の予測となっている。予測結果と松山実測値を比較すると、Range M ではリードタイム3時間が過小評価しているものの、どちらのリードタイムも降水の始まり、傾向、終わりをおおむね予測できていることがわかる。しかし、Range L では降水量を大幅に過小評価しており、Range L による学習モデルの予測精度が低いことがわかる。この原因として台風の上陸に伴う降水の予測をする際に Range M が適切な範囲だったのに対して、Range L のような大きな範囲を学習させると無駄なデータが多く適切に学習できていないことが考えられる。このことから、学習に適切である面的な範囲を設定することができれば、予測精度を向上させる可能性があることが示唆された。

それぞれの降水 Case における GPV と藤森らの研究(既往研究)、リードタイム3時間の予測の実測値に関する RMSE を図-4に示す。学習範囲はすべて Range M である。GPV と比較すると、いずれの Case も RMSE は深層学習モデルによる予測値の方が小さく、精度が良いことがわかる。特に Case1 の小規模な降水と Case4 の台風の上陸に伴った降水では深層学習予測値の精度が高いことがわかる。また、既往研究と比較すると、Case4 以外で RMSE は深層学習モデルによる予測値の方が小さく、精度が良いことがわかる。これらのことから面的な気象データを用いた予測をすることで、降水パターンによらず降水量予測精度の向上が見込まれることがわかった。

4. おわりに

本研究では面的な気象データと松山の降水量の関係を深層学習モデルに学習させ、3から6時間先の降水量の予測を行った。適切な学習範囲を設定することで、降水量予測の精度が向上すること、リードタイムを大きくすることが可能であることがわかった。また、地点データを用いて予測した既往研究や気象庁の GPV と比べ、降水量予測の精度の向上が確認された。しかし、いまだ精度が高いとはいえない。今後、学習データの項目や範囲の検討、深層学習モデルのハイパーパラメータ等の調整によって、降水量予測精度とリードタイムの向上を図る必要がある。

参考文献

- 1) 藤森祥文, 今村実, 全邦釘, 西村文武, 森脇亮: AMeDAS 観測データを用いた深層学習による降水量予測の試み土木学会論文集 B1(水工学) Vol.75, No.2, I_1189-I_1194, 2019.




図-2 Range M における降水量予測結果(Case4)




図-3 Range L における降水量予測結果(Case4)




図-4 RMSE の比較