

森田 慶†

大村 廉‡

豊橋技術科学大学

豊橋技術科学大学

1. はじめに

現在、気象庁は「降水短時間予報」として、1～6 時間先までの降水予測を 10 分ごとに 1km 四方の解像度で発表している。降水短時間予報は気象レーダーやアメダスなどで観測された降水量データをもとに作成される「解析雨量」という 1 時間降水量分布の実況値を基にして行われ、北緯 20～48 度、東経 118～150 度と日本全土とその周辺範囲を含む非常に広範囲を予測対象としているため、局所的な予測ミスが発生するという問題がある。このことは、例えば屋外作業など天候がスケジュールを左右するような業務では、予測が外れることによって作業スケジュールを大幅に変更する必要性が生じてしまうなど、業務に大きな支障をきたす可能性がある。このため、局所的にも高精度な雨量予測が強く望まれている。

降水量予測に関する研究として、Shi ら[1]は Convolutional LSTM (ConvLSTM) を用い、降水量データの時系列性と空間性を考慮した予測手法を提案している。また、この手法を発展させ、林ら[2]は降水量に加えて同時刻の雲画像を入力データに取り込むことでマルチモーダル学習を行い、予測精度の向上を図った。しかし、これらの研究では、いずれも数 km 四方範囲の降水量を予測し、その高精度化を目指した手法である。局所的であっても簡易な設備で高精度な予測が可能であれば、屋外作業の計画を精密に行うことができるようになるなど、大きなメリットを得がある。

本研究では対象とする地点に IoT 雨量計を設置し、その観測結果を利用して局所的に高精度の雨量予測を行うことを試みた。具体的には、気象庁が発表する降水短時間予報、および、解析雨量、また、設置した IoT 雨量計の実測値の 3 種類のデータを入力とし、IoT 雨量計を設置した座標の降水量を予測する深層学習モデルを作成した。3 種類のデータをそれぞれ単体で用いるモデル、ならびに統合して予測を行うモデルを作成し、気象庁の降水短時間予報と予測精度を比較した。

2. 入力データ

本研究では、3 種類のデータ（降水短時間予報、解析雨量、対象座標実測値）を単体で入力データとして用いるモデルと、これらを統合して予測するモデルの合計 4 つのモデルを作成した。

入力データとなる各データの時間範囲を図 1 に示す。降水短時間予報は気象庁提供の予測データであり、現在から 1～6 時間先のデータを用いた。解析雨量と IoT 雨量計の対象座標実測値は観測データであるため、現在時刻を含む過去 5 時間分を入力として用いた。いずれも 6 時間分が入力となる。

なお、降水短時間予報と解析雨量は対象座標およびその周辺範囲（80×120 グリッド）のデータであり、IoT 雨量計の観測データは対象座標 1 地点のデータである。




図 1 各データの入力範囲

3. 予測モデル

各予測モデルの構造図 2、図 3 に示す。なお、これらのモデルは[3]の研究を参考とし、設計した。それぞれ 1 時間後、2 時間後といった予測のリードタイムごとに 6 時間後までの予測結果を出力する。

降水短時間予報モデルと解析雨量モデル（図 2）は、80×120 の 2 次元データを入力とし、ConvLSTM 層を 3 層重ねた構造を採用している。各 ConvLSTM 層のフィルター数は最上層から順に 32, 16, 1 とし、層が深くなるにつれてフィルター数を減少させている。すべての層でフィルターサイズは 5×5 を用い、バッチ正規化層を挿入することで学習を安定化させている。これにより、時空間的な特徴を効率よく学習し、ReLU 活性化関数を通じて非負の予測値を生成する。

一方、対象座標実測値モデル（図 3）は、IoT 雨量計で計測された 1 次元の時系列データを入力としており、ConvLSTM の代わりに LSTM 層を 2 層（各 64 ユニット）重ねた構造を採用している。このモデルは過去の降水量データから時間的な特徴を抽出し、全結合層を通じて予測値を出力する。この場合も ReLU 活性化関数を使用し、降水量が非負となるよう設計した。

さらに、統合モデル（図 3）は、降水短時間予報モデル、解析雨量モデル、対象座標実測値モデルのそれぞれの出力を結合し、その後 LSTM 層で処理することで各データの特徴を統合する構造となっている。このアプローチにより、異なる種類のデータを組み合わせることで予測精度の向上を目指した。





図 2 各入力に基づくモデル



4. 評価実験

4.1 実験内容

実験では愛知県豊橋市中原町にある平山池を対象として降水量予測をおこなった。この平山池には RainTech 株式会社によって大田計器製作所の雨量計 OW-34-BP が設置されており、この雨量計の降水量データを用いた。雨量計で計測された雨量を正解とし、各モデルによる予測結果、および気象庁の降水短時間予報における平山池座標が含まれる範囲の降水量予測データについて、予測のリードタイム（1～6 時間後）ごとに平均絶対誤差（MAE）を算出した。

実験に用いたデータは、2024 年 6 月 14 日から同年 9 月 25 日までの期間に観測された平山池の IoT 雨量計の降水量データ、および同期間の降水短時間予報、解析雨量である。降水短時間予報と解析雨量は 30 分毎の 1 時間降水量の予測値、および実測値データであり、雨量計のデータは 10 分毎に記録された降水量データである。これらのデータに前処理を施し、最終的に 4929 個のサンプル数を作成した。

前処理では、主にデータ形式の変換を行った。気象庁が提供する降水短時間予報および解析雨量のデータについては、平山池およびその周辺地域（北緯 35 度～36 度、東経 137 度～138 度）の範囲のデータを抽出して 80×120 の 2 次元データに変換した。また、IoT 雨量計の実測データは雨量計の仕様により 10 分間隔での降水量データとなるため、1 時間降水量に変換して他のデータと一致させた。

学習データとテストデータの分割比率は 7:3 とし、学習には 2024 年 6 月 14 日から 2024 年 8 月 25 日のデータを使用した。テストデータは同年 8 月 25 日から 9 月 25 日を用いた。

4.2 実験結果

図 3 に各モデルの予測結果の MAE（IoT 雨量計で計測された実測値との平均絶対誤差）を示す。図 3 より、本研究で実施した降水短時間予測モデル、解析雨量モデル、対象座標実測値モデル、のすべてのモデルについて、気象庁が発表する降水量短時間予測（図中「気象庁予測」；MAE 約 1.2）よりも MAE が減少しており、気象庁の予測（降水短時間予測）よりも高精度な予測が行えていることがわかる。

今回は解析雨量モデルが最も精度が高く、MAE の最小値は約 0.8 であった。統合モデルでは 3 種類のデータすべてを入力としたことから他の 3 モデルよりも精度が向上することを期待したが、MAE の最小値は約 0.9 程度となり、解析雨量モデルに及ばなかった。統合モデルにおける統合方法は、今回は非常に単純な方法を採用しており、このため十分に有効な統合が行えなかったと予想される。統合モデルの性能向上には、異なるデータ間の特徴をより効果的に

に融合する方法を検討する必要があると考えられる。

また、リードタイム別の MAE（平均絶対誤差）の挙動について、対象座標実測値モデルではリードタイムが進むにつれて MAE が上昇する傾向を示した。一方で、降水短時間予測モデルおよび解析雨量モデルでは、リードタイムが進んでも MAE はほぼ一定であった。この違いは、対象座標実測値モデルが入力データとして対象地点のみの 1 次元データを使用しているのに対し、降水短時間予測モデルと解析雨量モデルが対象地点を中心とした周囲範囲（空間的情報）を含む 80×120 の 2 次元データを入力としていることに起因していると考えられる。周囲の空間的な変化を学習することで、リードタイムが進んだ場合でも誤差の増加が抑えられた可能性がある。




図3 各手法の予測結果の MAE

5. まとめ

本研究では、IoT 雨量計を用いてその座標での実測値を利用し、高精度の局所的降水量予測を試みた。降水短時間予測、解析雨量、雨量計実測データ 3 種類の入力データに基づくモデル、および、それらを統合したモデルを開発し、実験結果によっていずれも気象庁予測よりも精度の良い予測を行うことができることを確認した。統合モデルではデータの統合に単純な統合方法を用いたため、精度は解析雨量に基づく予測に及ばなかった。今後、より高精度化を目指し、データの統合方法についてより深く検討していく予定である。

謝辞

本研究の実施にあたり、貴重なデータの提供やその他多くのご協力を戴いた RainTech 株式会社に感謝します。

参考文献

- [1] Xingjian Shi, Zhouong Chen, Hao Wang, Dit-Yan Yeung, Wai-kin Wong, Wang-chun Woo: "Convolutional LSTM Network: a machine learning approach for precipitation nowcasting", NIPS' 15: Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1, December 2015, Pages 802-810.
- [2] 林政行, Rafik Hadfi, 伊藤孝行: 深層学習を用いたマルチモーダル学習による降水量予測, 情報処理学会第 78 回全国大会, 4p-03, 2016.
- [3] Ashutosh Kumar, Tanvir Islam, Yoshihide Sekimoto, Chris Mattmann, Brian Wilson: "Convcast: An embedded convolutional LSTM based architecture for precipitation nowcasting using satellite data", PLOS ONE open access (Published: March 11, 2020)