

時系列降雨分布データと再帰的畳み込み深層学習モデルを用いた短期降雨予測の試み

山梨大学 学生会員 ○鄭 世韜
 山梨大学 正会員 宮本 崇
 株式会社ビーエムシー 正会員 阿部 雅人
 防災科学技術研究所 非会員 清水 慎吾
 防災科学技術研究所 非会員 加藤 亮平
 防災科学技術研究所 非会員 岩波 越

1. はじめに

豪雨災害が頻発する我が国の現状の中で、降雨量を局地的に予測することは防災上重要な課題である。降雨予測の手法には、物理現象をモデル化した微分方程式の数値解に基づく数値予測と、現象の定常性を仮定した降雨域の外挿に基づくナウキャストの大きく2種に大別される。これらの手法はそれぞれ、予測のスピンアップ時間に起因して初期の予測精度が低いことと、現象の変化を追従できないため次第に精度が低下することから、図1のようにいずれの手法においても精度が低い予測時間帯が存在する。こうした点を補完するための手法として、近年では観測データの蓄積を背景として、機械学習モデルなどを利用するデータ駆動型手法の適用が研究されている。

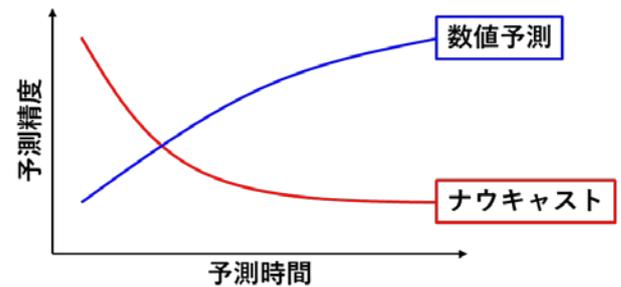


図1 降雨予測手法と予測精度の関係

降雨量の予測は、空間的な広がりを持つ量の時系列変化に対する、回帰の問題として捉えることができる。このような問題に対する機械学習モデルとして、データの空間的な特徴を抽出する畳み込み演算と、時系列的な関係性を学習する再帰的ネットワーク構造を組み合わせた深層学習モデルである Convolutional Recurrent Neural Network やその発展的モデルの適用が提案されており、気象予測の問題に対しても応用が進んでいる¹⁾。

そこで本研究では、レーダ観測による高い時空間解像度を有する降雨量分布データに対して上記の深層学習モデルを適用し、短時間の局地的な降雨予測を機械学習モデルによって行うことを試みる。本稿では、モデルの構築の際に行った各種機械学習モデルの比較検証結果を報告する。

2. 問題設定と観測データ

本稿では、機械学習による短時間の局地的な降雨予測を試行するために、ある時刻 T までの観測データに基づいて5分後の降雨強度分布を予測する問題を設定した(図2)。

機械学習モデルの訓練と性能の検証に用いるデータとして、関東地方において2011年から2017年の間にレーダ雨量計によって観測された、時間解像度1分、空間解像度250mの降雨強度分布を利用する。降雨のあるデータを検討対象と

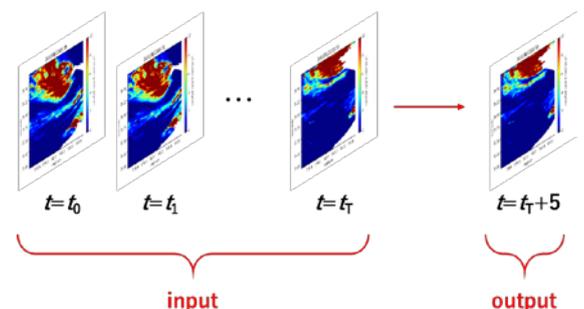


図2 機械学習による降雨予測の問題設定

するため、各年の8月のデータの中で、50km×50km四方の対象地域において半数以上のメッシュに降雨のある時刻を検索し、この時刻前後で連続する60分の記録を抽出することにより計8,460分のデータを抽出した。

これらのデータのうち95%を機械学習の訓練に、5%を性能の検証に用いる交差検証法を実施することにより、以降に示す機械学習モデルの予測性能を比較した。

キーワード 短期降雨予測, 深層学習, 時空間データ, Conv-LSTM

連絡先 〒400-8511 山梨県甲府市武田4-3-11 山梨大学 宮本 崇 tmiyamoto@yamanashi.ac.jp

3. 機械学習モデルの比較

降雨強度の空間分布を予測する機械学習モデルとして、本稿では以下に示す U-NET モデル、Conv-LSTM モデルの 2 種の深層学習モデルを利用し、その性能を比較した。U-NET は、空間分布量を入力として空間分布量を出力する、図 3 のような畳み込み層の積層構造を有する深層学習モデルである。U-NET による降雨量の予測は、時々刻々と変化する雨の降り方のある時刻 T でのスナップショット $R(t_r, x, y)$ を元に、次の時間ステップでの雨の降り方 $R(t_{r+1}, x, y)$ を予測しようとするに相当する。

Conv-LSTM は、畳み込み層 (Convolution 層) によってデータの空間的な特徴を抽出する機能と、Long Short-Term Memory(LSTM) と称される、データの時系列な関係性を学習するための層構造を組み合わせた、図 4 に示す構造を有する深層学習モデルである。

Conv-LSTM は、時刻 0 から時刻 T までの降雨強度分布 $\{R(t_0, x, y), R(t_1, x, y), \dots, R(t_r, x, y)\}$ を入力として、 $R(t_{r+1}, x, y)$ を出力する。このモデルでは、降雨強度分布が過去にどのように変化してきたか(例えば、西から東に推移している、雨が強まりつつある、といった変化) という時系列的な特性を考慮できる点で降雨予測に適していると期待される。また、気象状態は地形や土地利用の影響のために、空間位置に応じて一様でない変化をすることから、このような空間位置の影響を考慮するために位置座標値を入力情報に加える Coord-Conv 手法²⁾を畳み込み層に適用した。なお、解析においては予測時刻の 30 分前の時刻から 5 分おきのデータを入力した。

図 5 に、それぞれのモデルを学習させた際の、性能検証用のデータに対する 5 分後の予測結果と実際の降雨分布の 2 乗和誤差の推移を示す。図には、比較のために 5 分間で全く降雨が変化しないと予測した場合 (持続予測) の結果を示している。いずれの機械学習モデルも持続予測に比べて精度が向上しており、特に時系列方向の関係性を考慮可能な Conv-LSTM の予測精度が高いことが確認できる。Conv-LSTM による予測結果と実際の降雨分布を比較した 1 例を図 6 に示す。

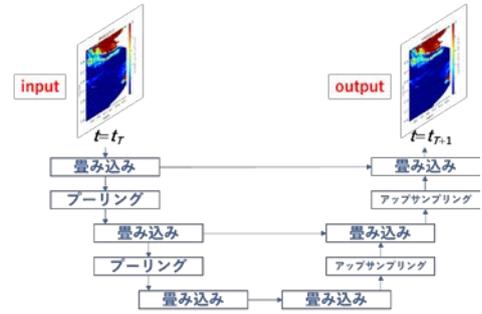


図 3 U-NET による予測の概念図

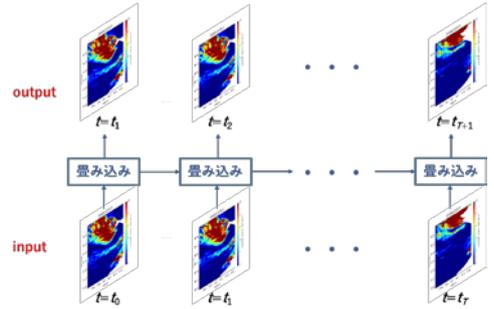


図 4 Conv-LSTM による予測の概念図

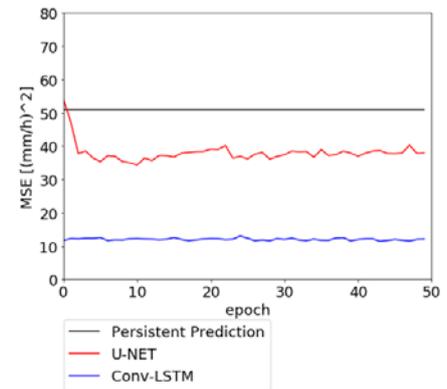


図 5 各モデルにおける予測誤差の比較

4. おわりに

本稿では、時系列データを入力とする深層学習モデルによる短期降雨予測の試行を行った。今後は、短期予測に特化したモデル構造の改良と、15-30 分先の降雨予測への適用を図っていく。

参考文献

- 1) X. Shi et al: Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting, NIPS'15 Proceedings of NIPS'15, Vol.1, pp.802-810., 2015.
- 2) R. Liu et al.:An intriguing failing of convolutional neural networks and the coordconv solution, arXiv preprint arXiv:1807.03247, 2018.

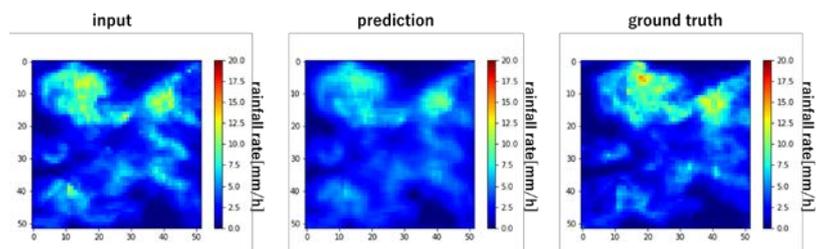


図 6 Conv-LSTM による予測と実際の降雨分布の比較