

# 深層学習によるメソアンサンブル降雨予測の 実況補正手法の開発

## DEVELOPMENT OF NOWCAST CORRECTION METHOD FOR ENSAMBLE RAINFALL PREDICTION USING DEEP LEARNING

山本雅也<sup>1</sup>・増田有俊<sup>2</sup>  
Masaya YAMAMOTO and Aritoshi MASUDA

<sup>1</sup>非会員 一般財団法人日本気象協会 関西支社 (〒542-0081 大阪市中央区南船場2-3-2)

<sup>2</sup>正会員 工博 一般財団法人日本気象協会 本社 (〒170-6055 東京都豊島区東池袋3-1-1)

In this study, we developed nowcast correction method for ensemble rainfall prediction using deep learning. We adopted convolutional lstm neural network for rainfall prediction model. Our model's parameter has updated by past 4 years observed radar and MSM (Meso-scale Model) datasets. Furthermore, we applied our model to all ensemble member of MEPS (Meso-scale Ensemble Prediction System) rainfall prediction provided by JMA (Japan Meteorological Agency).

As a result, corrected rainfall prediction's MAE (Mean Absolute Error) has improved. Moreover, ensemble member's range of corrected MEPS can hold observed rainfall.

**Key Words :** Rainfall prediction, deep learning, convolutional lstm neural network, ensemble prediction.

### 1. はじめに

洪水時のダム洪水調節操作のひとつに特別防災操作がある。特別防災操作は、下流河川で洪水被害が発生又は発生するおそれがある場合において、洪水の終わりの見通しが相当程度確実と考えられる場合のみ実施するものであり、今後の雨の見通しについては、6時間先までの予測雨量である降水短時間予報を用いることが基本とされている。しかし、我々は現状の降水短時間予報ひとつの値をもって洪水の終わりの見通しが相当程度確実と判断する情報として、メソアンサンブル数値予報モデルGPV<sup>1)</sup> (Meso-scale Ensemble Prediction System; 以下MEPS) を用いて実況補正を行い、複数の短時間予測を算出することで、より確度の高い情報を提供することができると考えた。

MEPSは気象庁より2019年6月27日から配信が行われている。MEPSはアンサンブル手法を用いて21メンバーの計算を実施するため、決定論的なメソ数値予報モデルGPV<sup>2)</sup> (以下MSM) に対し、MEPSは複数の客観的な予測結果を得られる。現在MEPSは初期時刻から3時間半ほど遅れて配信される仕様となっている。

そこで、本研究では、近年コンピュータービジョンや自然言語処理の分野で著しい成果を上げている深層学習を利用し、初期時刻からMEPSの配信までに得られる解析雨量(雨量実況値)を用いてMEPSの21メンバーを実況補正する手法を開発した。

既存の研究としては、実況観測雨量値を用いて直近の雨量を予測する研究が存在する<sup>3)</sup>が、これは決定論的な予測を深層学習で代替する手法であり、アンサンブル予測として複数の予測値を算出することはできない。

そこで、本研究では、実況補正手法として、時系列畳み込み(Convolutional LSTM Network; ConvLSTM)モデルを採用した。学習データには過去5年分のMSMと解析雨量を用いた。解析雨量はMSMと同等の5kmメッシュのデータに加工し、MEPSの配信時間を考慮して、直近4時間分のMSMと解析雨量からMSMの予測誤差を算出し、1時間後の誤差を予測するモデルとした。これにより、深層学習モデルの学習データとしては不足しているMEPSにも適用可能なモデルとなり、21メンバーのアンサンブル予測すべてを実況補正することが可能となった。

## 2. 手法

### (1) ConvLSTMモデル

本研究では、降雨予測の実況補正モデルとして、深層学習のひとつであるConvLSTMモデルを採用した。

ConvLSTMはShiら<sup>3)</sup>により提案されたモデルであり、時空間データを予測するモデルである。ConvLSTMはSutskeverら<sup>4)</sup>が提案したseq2seq学習フレームワークをもとに、LSTMを拡張し、畳み込み演算（Convolutional Network）を取り入れることで、LSTMの状態において空間性を保つことを可能としたモデルである。時空間データから時空間データを生成するShiらの予測モデルは、2つの同じ構成のConvLSTMをスタックさせたネットワークを時間軸で結合したEncoding Forecastingネットワークから成るseq2seqモデルである（図-1）。

本研究では、Shiらのモデルを参考に、ConvLSTM層を5層重ね、最後にConv3D層を経ることで降雨の直近4時間の予実差の時空間データから降雨の予測値の補正值の時空間データを生成するモデルを構築した。Shiらの研究では、実況値のみのデータを用いて予測を行っているが、本研究では最終的にMEPSに適用できるモデルにしたかったため、4時間分の解析雨量とMSMの予実差から次の時刻の差分を予測するようにしている。予実差を予測するということは、予測に対する補正值を予測することになる。MSMはMEPSのコントロールランなので、運用開始して間もない中で学習データが少ないMEPSに対しても、MSMのデータのみを使って学習させたモデルでありながら、MEPSの21メンバー全てに適用できるモデルとなった。表-1に構築したモデルの各層の入力データサイズと出力データサイズをまとめる。

### (2) 学習データ

学習データには2013年9月から2017年12月までの約4年分の解析雨量とMSMを利用した。解析雨量は1kmメッシュの空間分解能を持つ1時間雨量値である。

本研究では、アンサンブル実況補正対象領域を関西地方とし、関西地方全体が含まれるように、北西端の緯度・経度が36度・134度、南東端の緯度・経度が33度・137度となるように領域を切り出した（図-2）。

領域で切り出した解析雨量を、MSMと同じ形状になるように5kmメッシュに加工したデータセットを作成した。また、前述の解析雨量とMSMデータの差分をとり、4時間分を並べてひとつのシーケンスとし、これをインプットデータとした。さらに、4時間分並べたデータの1時間後をアウトプットとし、これを予測対象として学習させた。




図-1 ConvLSTMモデルの概念図

表-1 モデルの各層の入出力サイズ

| 層の名前       | 入力サイズ           | 出力サイズ           |
|------------|-----------------|-----------------|
| ConvLSTM2D | (4, 61, 49, 1)  | (4, 61, 49, 32) |
| ConvLSTM2D | (4, 61, 49, 32) | (4, 61, 49, 32) |
| ConvLSTM2D | (4, 61, 49, 32) | (4, 61, 49, 32) |
| ConvLSTM2D | (4, 61, 49, 32) | (4, 61, 49, 32) |
| ConvLSTM2D | (4, 61, 49, 32) | (4, 61, 49, 32) |
| Conv3D     | (4, 61, 49, 32) | (1, 61, 49, 1)  |



図-2 アンサンブル実況補正対象領域

学習データは十分に存在するため、解析雨量とMSMに差分がない事例（雨が降っていない事例）を除いた上で、ランダムにシャッフルし、訓練データ・検証データ・テストデータに3等分に分割した。データ数はそれぞれ10159, 1269, 1269セット存在する。また、学習データは平均0, 分散1となるように正規化を施した。

重みの学習にあたって、損失関数には平均絶対誤差（Mean Absolute Error ; MAE）を雨が降っている領域の重みが高くなるように改良した自作関数を用意し、オプティマイザにはAdam<sup>4)</sup>を採用した。また、学習の際のバッチサイズは16とし、MAEの変化が緩やかになってきた40エポック時点で学習を停止させた。前述の訓練データ・検証データ・テストデータでのMSEの結果を監視し、特定のアーキテクチャに対して過学習が起きていないか確認しながら、ハイパーパラメータの調整を行った。




図-3 テストデータに学習済モデルを適用した事例

### (3) 学習の検証

テストデータに学習済モデルを適用した事例を示す(図-3)．図-3は左から右に向かって1時間ずつ雨量分布および予実差をプロットしたものである．1段目は解析雨量をプロットしたものであり、これが雨量の実測値にあたる．2段目は1段目の解析雨量と同じ時刻のMSMをプロットしたものであり、実況補正を行う前の予測値となる．3段目は解析雨量とMSMの予実差をプロットしたものであり、4時間分の予実差をインプットとして学習済みのConvLSTMモデルにより、次の1時間の予実差を予測している．なお、2時間後を予測する場合は直近3時間分の予実差と予測された1時間後の予実差を用いて予測しており、その先の時間に対しても同様の考え方で6時間先まで予測を行っている．4段目は、予測された予実差を用いて2段目のMSMの予測値を実況補正したものをプロットしたものである．特に、1, 2時間後について実測値に近づくように補正されていることが見てとれる．

## 3. ダム流域での事例検証

### (1) 評価指標

本章ではダム流域を対象に、MEPSの実況補正手法の精度検証を行う．

精度検証の指標としてはMAE (Mean Absolute Error) を用いる．MAEは次の式で表され、0に近い値になるほど精度のよい予測と判断できる．

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - x_i| \quad (1)$$

なお、 $x$  は観測値、 $y$  は予測値である．

### (2) 精度検証対象

精度検証の対象としては、2018年7月豪雨で異常洪水時防災操作が実施された日吉ダムと一庫ダムを選定した．日吉ダムは淀川の主要支川の一つである桂川中流部に位置するダムで集水面積は290.0km<sup>2</sup>である．一庫ダムは淀川水系一庫大路次川に建設されたダムで集水面積は115.1km<sup>2</sup>である．これらのダムについて、2018年7月豪雨の降り始めから降り終わり、2018年7月5日21時から2018年7月7日21時までの6時間ごとの初期時刻のMEPSに実況補正を適用し、精度検証を行った．

### (3) 精度検証結果

前述の初期時刻の予測を対象に、MSMの実況補正前と実況補正後、さらにMEPSの実況補正後のアンサンブル平均の精度を1時間ごとに算出した．日吉ダムにおける予測精度を表-2に、一庫ダムにおける予測精度を表-3に示す．なお、本研究の1時間後の予測はMEPSの初期時刻から換算すると5時間後の予測に相当する（最初の4時間と実測値の差分をConvLSTMモデルの入力として用いているため）．

まずMSMの実況補正前後のMAEを比較すると、日吉ダムの2時間後と一庫ダムの5時間後を除き、実況補正後のMAEが実況補正前のMAEを上回っており、特に1時間後の予測に関しては実況補正前後で比べると大幅にMAEが改善しており、補正が効いていると判断した．また、補正後のMSMとMEPSのアンサンブル平均を比べると、これも例外となる事例が存在するが、概ねMEPSのアンサンブル平均の方が良い精度であると読み取れる．

表-2 日吉ダムにおけるMAE (mm/h)

|      | MSM補正前 | MSM補正後 | MEPS補正後<br>平均 |
|------|--------|--------|---------------|
| 1時間後 | 4.22   | 2.34   | 2.30          |
| 2時間後 | 1.82   | 1.84   | 1.93          |
| 3時間後 | 3.32   | 3.08   | 3.37          |
| 4時間後 | 3.34   | 3.05   | 2.88          |
| 5時間後 | 2.67   | 2.57   | 2.09          |
| 6時間後 | 3.48   | 3.55   | 3.35          |

表-3 一庫ダムにおけるMAE (mm/h)

|      | MSM補正前 | MSM補正後 | MEPS補正後<br>平均 |
|------|--------|--------|---------------|
| 1時間後 | 2.55   | 2.09   | 2.03          |
| 2時間後 | 2.56   | 2.51   | 2.60          |
| 3時間後 | 4.64   | 4.40   | 4.44          |
| 4時間後 | 4.49   | 4.40   | 4.26          |
| 5時間後 | 4.46   | 4.50   | 4.23          |
| 6時間後 | 2.41   | 2.33   | 2.64          |

表-4 各ダムの6時間累積雨量捕捉率 (%)

|      | 割合  |
|------|-----|
| 日吉ダム | 100 |
| 一庫ダム | 100 |




図-4 日吉ダムMEPS初期時刻2018年7月6日3時の事例

#### (4) アンサンブル予測としての検証

次に、MEPSの実況補正後の値21メンバーの値の中に実測値が含まれているかどうかを検証した。特別防災操作の際には21メンバーの最大雨量に実測値が収まっている

かどうか重要であるため、最小雨量は考えず、6時間先までの累積雨量の実績値が予測最大雨量に収まっている割合を算出した。結果を表-4に示す。表-4のとおり、すべてのMEPSの初期時刻の予測について、実績値が予測最大雨量に収まっていることが分かった。

また、参考までに日吉ダムにおけるMEPS初期時刻2018年7月6日3時の予測事例を図-4に示す。この事例ではMSMの予測（緑の太線）では実測値（青線）に対して過少の予測となっているが、MEPSの最大の予測値には実績値が収まっている形となっている。

#### 4. まとめと今後の課題

本研究では、深層学習モデルにより、直近4時間の予実差を用いてMEPSを実況補正する手法を開発した。これにより、MSM一本の予測では捉えられなかった雨量の予測最大値を把握することが可能となり、ダムの洪水調節操作の判断材料としてより高度な情報を提供できることが期待できる。また、2020年3月に提供開始されるメソアンサンブルガイダンス<sup>5)</sup>に適用すると予測精度が向上する可能性がある。

今後の課題としては、この手法を全国展開し、2019年台風19号で異常洪水時防災操作を行ったダムについても精度検証し、他事例でも本手法が有効かどうか検証を行う必要があると考える。また、本手法による実況補正值を入力として、ダムの流入量まで計算を行い、ダム操作のシミュレーションまで行う形がベストであると考えている。

#### 参考文献

- 1) 気象庁予報部：メソアンサンブル数値予報モデルGPVの提供開始について、配信資料に関する技術情報（気象編）第505号，2019。
- 2) 気象庁予報部：平成18年3月からの数値予報モデルGPV等の変更について、配信資料に関する技術情報（気象編）第205号，2005。
- 3) Xingjian Shi, Zhourong Chen, Hao Wang, Dit-Yan Yeung, Wai-Kin Wong, and Wang-chun Woo. Convolutional lstm network: A machine learning approach for precipitation nowcasting. arXiv preprint arXiv:1506.04214, 2015.
- 4) Ilya Sutskever, Oriol Vinyals, and Quoc VV Le. Sequence to sequence learning with neural networks. In Advances in neural information processing systems, pp. 3104–3112, 2014.
- 5) 気象庁予報部：メソアンサンブルガイダンスの提供について、配信資料に関する技術情報（気象編）第205号，2005。

(2020. 4. 2受付)