

深層学習による降雨予測の時空間方向への ダウンスケーリング手法の開発

DEVELOPMENT OF SPATIO-TEMPORAL DOWNSCALING METHOD FOR RAINFALL PREDICTION USING DEEP LEARNING

山本雅也¹・増田有俊²

Masaya YAMAMOTO and Aritoshi MASUDA

¹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)

²正会員 工博 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)

In this study, we developed spatio-temporal downscaling method for rainfall prediction using deep learning. We adopted convolutional neural network for statistical downscaling model, and our model can convert 3hours/20km resolution data into 1hour/5km. Our model's parameter has updated by past 11 years observed radar datasets. Furthermore, we applied our model to GSM (Global Spectral Model) Guidance's rainfall prediction provided by JMA (Japan Meteorological Agency).

As a result, statistical downscaled rainfall prediction can smoothly describe rainfall area move and quantity change. Moreover, spatio-temporal downscaled rainfall prediction can generate peak time and quantity that is not given by GSM Guidance.

Key Words : Rainfall prediction, deep learning, convolutional neural network,
spatio-temporal downscaling

1. はじめに

2018年の7月豪雨では、8箇所のダムで異常洪水時防災操作が実施された。異常洪水時防災操作となるリスクを低減する方法の一つに、事前放流操作がある。事前放流を実施するためには、できるだけ長時間で精度の高い予測が必要であり、その候補として気象庁が発表しているGSM（全球数値予報モデル：Global Spectral Model）ガイダンス（以下、GSM-Gと表記）を活用することが考えられる。ガイダンスとは、統計手法を用い、数値予報の系統誤差を補正する手法である。GSM-GはGSMを元に作成されているため、84時間先まで予測値が存在し、元のGSMより予測精度が向上している¹⁾。しかし、GSM-Gの予測時間の粒度は3時間間隔、空間的な解像度は約20kmメッシュであり、GSM-Gをダム管理等に利用するには、時間的にも空間的にも分解能が不十分であると言える。

そこで、本研究では、近年画像認識・画像生成の分野で著しい成果を上げている深層学習（Deep Learning）を利用し、GSMガイダンスの予測値を時空間方向にダウ

ンスケーリングする手法を開発した。ダウンスケーリングを行う手法には大きく分けて力学的ダウンスケーリングと統計的ダウンスケーリングの2種類が存在する。深層学習によるダウンスケーリングは統計的ダウンスケーリングに当たり、学習時には多少時間がかかるものの、一度学習さえしてしまえば、力学的ダウンスケーリングのようにスーパーコンピュータを用いずとも、標準的な計算機で実運用可能な点がメリットとして挙げられる。

既存の研究としては、コンピュータビジョンの分野で開発された低解像度の画像を高解像度に変換するモデル²⁾を降水量に適用し、ダウンスケーリングを行った研究が存在する³⁾が、これらは空間方向のみのダウンスケーリング手法であり、時間方向のダウンスケーリングには対応していない。そこで、本研究では、深層学習による空間方向のダウンスケーリングで用いられている畳み込み演算時のカーネルの次元を上げることで、時間方向にも対応できるようにした。本手法により、20kmメッシュ・3時間雨量が5kmメッシュ・1時間雨量にダウンスケーリングされ、雨域の移動や降水量の増減を滑らかに表現することが可能となった。

2. 手法

(1) 深層学習モデル

本研究では、ダウンスケーリングモデルとして、深層学習のひとつである畳み込みニューラルネットワーク（Convolutional Neural Network; CNN）を採用した。低解像度から高解像度へのマッピングに対応するにあたって、転置畳み込み（Transposed Convolution）層と畳み込み（Convolution）層を組み合わせるネットワークを構築した（図-1）。ただし、図-1は空間的にのみダウンスケーリングを行う場合の模式図であり、一般的な画像認識に用いられている畳み込みニューラルネットワークと同じく2次元のカーネルが用いられている場合の図であるが、本研究で構築したネットワークの構造は、空間に加えて時間方向にもダウンスケーリングするため、3次元のカーネルを用いており、中間の層のデータは4次元となっているのが特徴である。

インプットデータをカーネルによる重みで畳み込み処理したアウトプットは、次式のように、インプットデータの一部 x とカーネルの重み w とバイアス b で計算される。

$$y = w^T x + b \quad (1)$$

本稿では、以降、カーネルの重みとバイアスはまとめて重みと記述する。重みは訓練データを通じて学習されるパラメータである。

また、最終的なアウトプットは非負の値であるため、活性化関数にはReLU関数を用いた。

$$h(x) = \begin{cases} x & (x > 0) \\ 0 & (x \leq 0) \end{cases} \quad (2)$$

(2) 学習データ

学習データには2007年1月から2017年12月までの過去11年分の解析雨量を利用した。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、ダウンスケーリング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134度・36度、南東端の緯度・経度が137度・33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、GSMガイダンスをダウンスケーリングした後のもの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、加工した5kmメッシュ・1時間雨量データをもとに、GSM-Gと同じ形状になるように20kmメッシュ・3時間雨量に加工したデータセットを作成した。さらに、20kmメッシュ・3時間雨量データを3時間間隔14時間分がワンセットとなるようにデータを加工し、このデータセットを深層学習モデルのインプットとした。また、インプットデータの対となるように、5kmメッシュ・1時間雨量データを1時間間隔42時間分がワンセットとなるようにデータを加工し、このデータセットを深層学習モデルの




図-1 モデルの概念図



図-2 ダウンスケーリング対象領域




図-3 訓練データ・検証データのMSE

アウトプットとした。

GSM-Gの降水量は本来、6-84時間予報、3時間間隔のデータであるため、一度にダウンスケーリングできるようにインプット・アウトプットデータの形状を調整したいところであるが、GPUメモリ容量の制約上、42時間分を時空間方向にダウンスケーリングする方法を学習させ、GSM-Gは2回に分けてダウンスケーリングすることにした。

学習データは十分に存在するため、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12478セット存在する。




図-4 テストデータに学習済深層学習モデルを適用した事例
(上段：テストデータ，中段：モデルによる出力，下段：正解データ)

(3) 学習の検証

重みの学習にあたって、損失関数は平均二乗誤差 (Mean Squared Error ; MSE) とし、オプティマイザには Adam⁴⁾を採用した。また、学習の際のバッチサイズは64とし、MSEの変化が緩やかになってきた200エポック時点で学習を停止させた。前節で分割した訓練データ・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。学習によってMSEが減少していく様子を図-3に示す。

なお、テストデータに対しても、最終的な検証データでのMSEとほぼ同じ値になっていることを確認しているため、過学習は起きていないと判断した。最後に、テストデータに学習済モデルを適用した事例を示す (図-4)。図-4の上段は解析雨量から作成した20kmメッシュ・3時間雨量であり、深層学習モデルのインプットデータとなる。中段は学習済みモデルにより出力されたデータであり、5kmメッシュ・1時間雨量にダウンスケーリングされている。下段は解析雨量を5kmメッシュに加工したものであり、中段に対する正解のデータである。深層学習モデルによるダウンスケーリングにより、雨域の移動や雨量の増減が滑らかに復元されていることが見てとれる。

深層学習であるため、詳しい途中経過までは説明できないが、3次元カーネルによる畳み込みを行った結果、中間層において入力データを時空間方向に上手く配分できるような中間データが作成されており、最終的にそれらを組み合わせることで、時空間方向へのダウンスケーリングが実現されているものと推測される。

3. GSMガイドランスへの学習済モデルの適用

前章で解析雨量データを用いて学習した深層学習モデルをGSM-Gに適用し、ダウンスケーリングを行った事

例を図-5に示す。上段が学習済深層学習モデルによってGSM-Gをダウンスケーリングしたもの、中段がGSM-G、下段がGSMである。なお、GSM-Gに関しては比較のために3時間雨量を単純に時間方向に3等分して1時間雨量に加工している。

図-5は初期時刻2018年9月3日15時 (GSM-G, GSMとも) の19-27時間予報部分である。この予報部分は2018年台風24号の事例であり、関西領域全体を南西から北東に向かって台風が通過していくと予測された部分である。深層学習モデルによってGSM-Gをダウンスケーリングしたものは、2019年9月4日16時の予測部分では3等分したGSM-Gより雨量が多めに配分されている一方で、2019年9月4日18時の予測部分では3等分したGSM-Gより雨量が少なめに配分されていることが分かる。このことから、深層学習モデルによってGSM-GをダウンスケーリングしたものはGSM-Gを時間方向に3等分したものに比べて前後の予測時間の降雨分布がスムーズに繋がっており、時空間方向のダウンスケーリングの効果により、雨域の移動や雨量の急激な変化を適切に時空間方向に配分できていることが分かる。また、GSMと比較すると、ガイダンスの効果により、全体的に強い雨が降るように補正されていることが分かる。雨量の強度に差はあるが、全体的な雨域の移動の様子に関しては、深層学習モデルによってGSM-GをダウンスケーリングしたものとGSMで概ね一致していることが見てとれるため、時間方向のダウンスケーリングが深層学習モデルによって上手く働いていることが分かる。

なお、深層学習モデルによってGSM-Gをダウンスケーリングした5kmメッシュ・1時間雨量データを再びGSM-Gと同じ20kmメッシュ・3時間雨量データの形状に復元したところ、ダウンスケーリング時の誤差は多少影響するものの、元のGSM-Gの値と同じ値に復元されることを確認している。




図-5 GSM-Gに学習済深層学習モデルを適用した事例
(上段：GSM-G-DS，中段：GSM-G，下段：GSM)

表-1 予測精度検証対象事例

事例番号	日付	降雨要因
1	2018年6月20日	前線
2	2018年7月6日	前線（7月豪雨）
3	2018年7月29日	台風12号
4	2018年8月24日	台風20号
5	2018年9月4日	台風21号
6	2018年9月26日	前線
7	2018年9月30日	台風24号

表-2 各ダムにおけるMAE（mm/81h）と総雨量比

		GSM-G (DS)	GSM-G	GSM
青蓮寺	MAE	55.6	53.1	68.2
	総雨量比	0.91	1.05	0.59
室生	MAE	50.7	49.8	48.1
	総雨量比	0.94	1.05	0.64
比奈知	MAE	58.7	76.8	70.8
	総雨量比	1.00	1.17	0.61

4. ダム流域での精度検証

(1) 評価指標

本章ではGSM-Gを深層学習モデルでダウンスケーリングしたものとGSMおよびGSM-Gとの精度比較検証を行う。

精度検証の指標としてはMAE（Mean Absolute Error）と総雨量比を用いる。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。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - x_i| \quad (3)$$

総雨量比は次の式で表され、1に近い値となるほど精度がよく、1より大きい場合は過大予測、1より小さい場合は過少予測と判断できる。

$$r = \frac{\sum y}{\sum x} \quad (4)$$

なお、 x は観測値、 y は予測値である。MAEと総雨量比の2つの指標を用いる理由としては、例えばMAEだけを評価指標としてみた場合、予測が常に過少気味であるといった偏りまでは判断できないためである。特に、ダム運用の際には過少気味に予測されている場合と過大気味に予測されている場合とでは、運用時のリスクに大

きな違いが出るため、量的な指標だけでなく、予測の偏りについても評価するのが望ましいと考えられる。

(2) 精度検証対象

精度検証の対象としては、昨年度台風等による大雨が観測された比奈知ダム・青蓮寺ダム・室生ダムの3箇所をダムを選定した。あまりに広い集水面積を持つダムでは空間方向へのダウンスケーリングの効果が顕著に現れないと考えられるため、これらのダムを選定した。比奈知ダムは木津川左支名張川の上流部に位置するダムで集水面積は75.5km²である。青蓮寺ダムは木津川左支名張川の左支、青蓮寺川に位置するダムで集水面積は100km²である。室生ダムは木津川左支名張川の左小支川である宇陀川に位置するダムで集水面積は169km²である。これら3箇所のダム流域平均雨量について、2018年の出水期について予測精度の検証を行った。具体的には、総雨量50mm以上もしくはダム流入量のピークが100m³/s以上の事例を抽出した。精度検証対象の3箇所のダム流域は地理的に近いこともあり、表-1に示す7事例に集約された。

(3) 精度検証結果

GSM-Gの予測のうち、予測時間に表-1の事例が含まれている初期時刻の予測を対象に、累積雨量の精度を算出した。各ダムにおける予測精度を表-2に示す。




図-6 青蓮寺ダムの流域平均一時間雨量と累積雨量（初期時刻：2018年8月21日21時）




図-7 比奈知ダムの流域平均一時間雨量と累積雨量（初期時刻：2018年7月4日15時）

まずGSMとGSM-GのMAEを比較すると、青蓮寺ダムではGSM-Gの方が精度が高く、その他の2箇所のダムではGSMの方が僅かに精度が良いことが分かる。次に総雨量比を比較すると、GSMの方は全てのダムにおいて0.6前後の値となっており、全体的に過少気味に予測していることが分かる。一方でGSM-Gの方では、全てのダムにおいて1を少し越えた値をとっており、全体的に少し過大傾向の予測であると言える。最後に、GSM-Gをダウンスケーリングしたものと元のGSM-Gを比較すると、総雨量比ではダウンスケーリングの効果によって過少となる方向に働いていることが分かる。それでも、GSMと比較した場合は1に近い値をとっているため、総雨量比に関しては良い精度を保っていると言える。一方、MAEに関してはダウンスケーリングによって、青蓮寺ダムでは少し改悪気味になっており、室生ダムではあまり変化が見られないものの、比奈知ダムでは約20%の精度の改善がみられる。精度の比較対象が累積雨量であるため、元のGSMとの違いが生じているのは、時間方向よりも空間方向へのダウンスケーリングの効果によるものであると考察できる。

(4) 個別事例での検証

前節において、青蓮寺ダムの予測精度が深層学習モデルによるダウンスケーリングによって改悪されていた原因について調べたところ、2018年8月24日の台風20号に対する予測に原因があることが分かった。初期時刻2018年8月21日21時の予測による青蓮寺ダムの流域平均雨量と累積雨量の図を図-6に示す。また、比較のために、初期時刻2018年7月4日15時の予測による比奈知ダムの流域平均雨量と累積雨量の図を図-7に示す。

図-6において、雨量は予測初期時刻の51時間後にピークを迎えるが、GSM-GをダウンスケーリングしたものとGSM-Gで予測値に大きな乖離が生じている。このような傾向は2018年8月24日の台風20号に対するほかの初期時刻の予測にも見られた一方で、他の事例に関しては図-6に見られるほどのダウンスケーリング前後における予測値の乖離は見られなかった（図-7）。予測値の乖離の原因は、GSM-Gでは流域に強雨域が重なっていたものが、空間方向へのダウンスケーリングによって強雨域が流域から外れたためである。




図-8 青蓮寺ダム流域の雨量分布図

図-8に青蓮寺ダム流域における初期時刻2018年8月21日21時の51時間後の降雨予測分布を示す。

図-8を見て分かるように、GSM-Gの予測では30-50mm/hの予測がされている隣のメッシュが1-5mm/hと予測されており、ひとつメッシュがずれただけで値の落差の激しい予測となっていたことが分かる。このことにより、空間的ダウンスケーリングを行った結果、値に落差のあるメッシュの境界部分が相対的に弱い雨となり、さらに、その部分がちょうどダム流域であったことから、図-6に見られるようなダウンスケーリング前後における予測値の乖離を生み出したものと推測される。

次に、2018年8月24日を検証の対象から外した場合の各ダムにおける予測精度を表-3に示す。

2018年8月24日を検証の対象から外した場合、全てのダムにおいて、元のGSM-Gに比べてダウンスケーリング後のほうが精度が良くなっていることが分かる。元々2018年8月24日を検証の対象に含めても7事例しかないため、精度検証の対象としてサンプルが少ない中、2018年8月24日の事例が特異な予測事例として全体の精度に大きな影響を与えていたと考察できる。

最後に、1時間毎の雨量に注目すると、図-7の事例が分かりやすいが、GSM-Gでは表現しきれなかった雨量のピークが、ダウンスケーリング後の予測値には存在していることが見てとれる。1時間毎の雨量のピークやピークの発生時刻を把握できることは、時空間方向にダウンスケーリングすることによる大きな利点であると言える。

5. おわりに

本研究では、深層学習モデルにより、GSM-Gを20kmメッシュ・3時間雨量から5kmメッシュ・1時間雨量にダウンスケーリングする手法を開発した。これにより、GSM-Gでは捉えられなかった1時間毎の雨量のピークや

表-3 各ダムにおけるMAE (mm/81h) と総雨量比
(2018年8月24日を除いた場合)

		GSM-G (DS)	GSM-G
青蓮寺	MAE	53.0	57.2
	総雨量比	0.96	1.08
室生	MAE	49.5	53.1
	総雨量比	1.03	1.11
比奈知	MAE	60.2	76.2
	総雨量比	1.03	1.16

ピークの発生時刻を把握することが可能となり、ダムの効率的な運用や洪水予測の精度向上に寄与することが期待できる。

また、本研究では用いていないが、もう少し短期の予測に目を向けるのであれば、MSGガイドランス⁵⁾（以下、MSM-Gと表記）の利用も考えられる。MSM-Gは39時間先まで予測が存在し、予測時間の間隔は3時間間隔で、空間的な分解能は5kmメッシュである。MSM-Gを深層学習モデルにより時間方向にダウンスケーリングすることで、5kmメッシュ・1時間雨量の予測となり、本研究で開発したGSM-Gダウンスケーリング後の時空間分解能と同じ予測情報となる。そこで、39時間先までは、GSM-GダウンスケーリングとMSM-Gダウンスケーリングによる深層学習等機械学習を用いたモデル間アンサンブルによって、さらなる予測精度の向上が期待できる。

参考文献

- 1) 気象庁予報部：GSMガイドランスの変更について、配信資料に関する技術情報（気象編）第316号，2010.
- 2) Dong, C., Loy, C. C., He, K. and Tang, X.: Image super-resolution using deep convolutional networks, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016.
- 3) Vandal, T., Kodra, E., Ganguly, S., Michaelis, A., Nemani, R. and Ganguly, A. R.: DeepSD: Generating high resolution climate change projections through single image super-resolution, Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2017.
- 4) Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, ICLR, 2014.
- 5) 気象庁予報部：メソモデル（MSM）及びMSMガイドランスの予測精度向上について、配信資料に関する技術情報（気象編）第457号，2017.

(2019. 4. 2受付)