

降水量ダウンスケーリングにおける CNN の時間・空間方向への拡張

熊本大学工学部 学生会員 永里 赴義

熊本大学 くまもと水環境・減災研究教育センター 正会員 石田 桂

熊本大学大学院自然科学教育部 学生会員 横尾 和樹

1. 序論

将来の降水量予測は気象災害の被害低減において非常に重要である。降水量将来予測には主に全球気候モデルを用いた数値シミュレーションにより得られた将来予測データを用いられている。ただし、一般に将来予測データの水平解像度は 100km 以上であり、地域レベルの解析を行う際には空間情報の詳細化が必要となる。そこで、しばしばダウンスケーリングと呼ばれる手法を用いた高解像度化が行われる。ダウンスケーリングの手法には主に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がある。近年、これらに加え深層学習手法を用いたダウンスケーリング手法が開発されてきている。なかでも、畳み込みニューラルネットワーク(CNN)の高い適用可能性が示されている¹⁾。いくつかの既往研究²⁾では大気場の変数を CNN の入力データとし降水量を推定している。CNN にはいくつかの手法があるが、既往研究では通常入力データを 2 次元的に処理する 2D-CNN を用いている。しかしながら、大気場の変数は 3 次元的な空間的情報や時間的情報を有するため、3 次元的に処理することにより精度が向上する可能性がある。そこで、本研究では入力データを 3 次元的に処理する 3D-CNN³⁾を降水量ダウンスケーリングに適用する。入力データは大気の再解析データとし、対象データは流域レベルでの日平均降水量とする。また、2D-CNN と精度を比較することで 3D-CNN の適用可能性を調査する。

2. 手法

CNN は主に畳み込み層、プーリング層、全結合層で構成される。畳み込み層では入力データ内にフィルタをスライドさせ、積和演算を行うことにより特徴を抽出する。プーリング層では畳み込み層から出力されたデータにフィルタを適用し、入力されたデータの空間サイズを縮小する操作を行う。以降、畳み込み層での入出力データ及び特徴抽出の際に用いるフィルタをそれぞれ特徴マップ、カーネルと呼ぶ。ここで、2D-CNN では特徴マップ及び、

カーネルは 2 次元形状であり、3D-CNN では 3 次元形状を有する。

2D-CNN での 2 次元畳み込みによる位置 (x, y) での特徴マップは下式で示される。

$$v_{out}^{xy} = \sigma \left(\sum_m \sum_{h=0}^{H_i-1} \sum_{w=0}^{W_i-1} k^{hw} v_{in}^{(x+h)(y+w)} + b \right)$$

ここで、 σ は活性化関数、 b はバイアス、 m は現在の特徴マップのセットを表し、 H, W はカーネルの縦横のサイズである。また、 (h, w) はカーネル内での位置、 $v_{in}^{(x+p)(y+q)}$ は入力された特徴マップである

3D-CNN での 3 次元畳み込みによる位置 (x, y, z) での特徴マップは下式で示される。

$$v_{out}^{xyz} = \sigma \left(\sum_m \sum_{h=0}^{H_i-1} \sum_{w=0}^{W_i-1} \sum_{l=0}^{L_i-1} k^{hwl} v_{in}^{(x+h)(y+w)(z+l)} + b \right)$$

ここで、 H, W, L はカーネルのサイズであり、 (h, w, l) はカーネル内での位置である。式から、3 次元畳み込みにより 2 方向のつながりを表す特徴だけでなく、3 方向のつながりを表す特徴が抽出されることが分かる。

3. 対象地・データセット

本研究では熊本県白川流域を対象地とした。降水量予測に当たり、日単位の降水量データは Asian Precipitation -Highly-Resolved Observational Data Integration Towards Evaluation of Water Resources (APHRODITE)より得た。入力変数のデータは European Centre for Medium Range Weather Forecasts Interim Reanalysis (ERA-interim) から取得した。

APHRODITE は、0.05 度×0.05 度の解像度を持つ 1900 年から 2011 年までの日降水量データセットである。本研究では APHRODITE から 1980 年から 2015 年までの日降水量のグリッドデータから白川流域での平均降水量を求めた。ERA-interim は 1979 年 1 月 1 日から現在までの全球レベルの大気情報の再解析データセットであり、時間

表-1 3D-CNN-Vert と 2D-CNN の比較条件

Case	Algorithm	Predictors	Time range	Number of pressure levels	CNN structure	Kernel size
V_1	2D	q, u, v, w	6	5 (500/700/850/925/1000hPa)	2L	(3,3)
	3D-Vert	q, u, v, w	6	5 (500/700/850/925/1000hPa)	2L	(3,3,3)
V_2	2D	q, u, v, w	6	6 (300/500/700/850/925/1000hPa)	2L	(3,3)
	3D-Vert	q, u, v, w	6	6 (300/500/700/850/925/1000hPa)	2L	(3,3,3)
V_3	2D	q, u, v, w	6	12 (200/300/400/500/600/700/750/800/850/900/950/1000hPa)	2L	(3,3)
	3D-Vert	q, u, v, w	6	12 (200/300/400/500/600/700/750/800/850/900/950/1000hPa)	2L	(3,3,3)
V_4	2D	q, u, v, w	6	5 (500/700/850/925/1000hPa)	3L	(3,3)
	3D-Vert	q, u, v, w	6	5 (500/700/850/925/1000hPa)	3L	(3,3,3)
V_5	2D	q, u, v, w	6	6 (300/500/700/850/925/1000hPa)	3L	(3,3)
	3D-Vert	q, u, v, w	6	6 (300/500/700/850/925/1000hPa)	3L	(3,3,3)
V_6	2D	q, u, v, w	6	12 (200/300/400/500/600/700/750/800/850/900/950/1000hPa)	3L	(3,3)
	3D-Vert	q, u, v, w	6	12 (200/300/400/500/600/700/750/800/850/900/950/1000hPa)	3L	(3,3,3)




図-1 3D-CNN-Vert と 2D-CNN の比較 (RMSE に関しては NSE と同様の傾向を示したことより省略)。

解像度は 6 時間, 水平解像度は 0.75 度×0.75 度である。本研究では ERA-interim から等圧面 200/300/400/500/600/700/750/800/850/900/950/1000 hPa での各方向の風速(u,v,w) 及び比湿(q)を抽出した。

4. モデルの実装

畳み込みの方向について, 本研究では水平 2 次元方向に加え鉛直方向に拡張した場合 (3D-CNN-Vert) 及び, 水平 2 次元方向に加え時間方向に拡張した場合 (3D-CNN-Time) について 3 次元畳み込みを実装した。CNN の構造について, 畳み込み層・プーリング層・バッチ正規化がそれぞれ 2 層の場合と 3 層の場合の構造で比較を行った(以降, それぞれの構造を 2L, 3L と呼ぶ)。3D-CNN と 2D-CNN の比較における詳細な比較条件を表-1, 2 に示す。

データセットは CNN の学習を行う訓練期間 (1980-2005) 過学習が生じていないか確認する検証期間 (2006-2010) モデルの最終的な推定精度を評価する期間 (2011-2015) の 3 つの期間に分けた。CNN の学習過程には重みとバイアスの初期値に起因するランダム性がある。よって, 本研究では各条件につき 200 回ずつ学習を行い, 検証期間の中で最も loss が小さいものを抽出し, テスト期間での精度を箱髭図で表した。モデルの精度評価に関して, NSE, RMSE を算出した。加えて, ピーク時での推定精度として, 対象データの 99%ile 値とそのときの CNN による推定値との RMSE (99%ile-RMSE) を算出した。

5. 結果・考察

2D-CNN と 3D-CNN-Time を比較すると (図-1), ピーク時(99%ileRMSE)に関して 3D-CNN-Time を用いても精度向上はみられなかった。これは, CNN の学習に用いた大気情報の時間解像度が 6 時間であったことにより, 対象流域における大気情報の時間的変化の特徴を捉えるには不十分であったと考えられる。しかしながら, 推定精

表-2 3D-CNN-Time と 2D-CNN の比較条件

Case	Algorithm	Predictors	Time range	Number of pressure levels	CNN structure	Kernel size
T_1	2D	q, u, v, w	2	5 (500/700/850/925/1000hPa)	2L	(3,3)
	3D-Time	q, u, v, w	2	5 (500/700/850/925/1000hPa)	2L	(2,3,3)
T_2	2D	q, u, v, w	4	5 (500/700/850/925/1000hPa)	2L	(3,3)
	3D-Time	q, u, v, w	4	5 (500/700/850/925/1000hPa)	2L	(3,3,3)
T_3	2D	q, u, v, w	6	5 (500/700/850/925/1000hPa)	2L	(3,3)
	3D-Time	q, u, v, w	6	5 (500/700/850/925/1000hPa)	2L	(3,3,3)
T_4	2D	q, u, v, w	2	5 (500/700/850/925/1000hPa)	3L	(3,3)
	3D-Time	q, u, v, w	2	5 (500/700/850/925/1000hPa)	3L	(2,3,3)
T_5	2D	q, u, v, w	4	5 (500/700/850/925/1000hPa)	3L	(3,3)
	3D-Time	q, u, v, w	4	5 (500/700/850/925/1000hPa)	3L	(3,3,3)
T_6	2D	q, u, v, w	6	5 (500/700/850/925/1000hPa)	3L	(3,3)
	3D-Time	q, u, v, w	6	5 (500/700/850/925/1000hPa)	3L	(3,3,3)




図-2 3D-CNN-Time と 2D-CNN の比較 (RMSE に関しては NSE と同様の傾向を示したことより省略)。

度(RMSE, NSE)に関して, 3D-CNN-Time を用いることにより改善が見られた。よって, 3D-CNN-Time を用いることにより水平 2 方向の特徴に加え時間方向も加味した特徴を抽出できる可能性があることが示唆される。

テスト期間における 2D-CNN と 3D-CNN-Vert の精度の比較結果を図-2 に示す。結果から, 3D-CNN-Vert の使用によって精度の改善が見られた。特に, 3D-CNN-Vert は 2D-CNN と比較して, ピーク時 (99%ile-RMSE) の精度を向上が見られた。よって, これらの結果から 3D-CNN-Vert は 2D-CNN で抽出できる水平 2 方向の特徴に加え, 鉛直方向の大気変数の分布の特徴を抽出できていると考えられる。

6. 結論

本研究では, 降水量ダウンスケーリングにおける 3D-CNN の適用可能性について検討した。畳み込みの軸は水平 2 方向に加え, 鉛直方向または時間方向に拡張した。結果から, 3D-CNN-Vert, 3D-CNN-Time は 2D-CNN よりも精度が高い傾向にあることから 3D-CNN の適用可能性が高いことが示された。

参考文献

- 1) Pan et al. Improving Precipitation Estimation Using Convolutional Neural Network. Water Resources Research. 55, 23 01–2321 (2019).
- 2) MIAO, Qinghua, et al. Improving monsoon precipitation prediction using combined convolutional and long short term memory neural network. Water, 2019, 11.5: 977.
- 3) JI, Shuiwang, et al. 3D convolutional neural networks for human action recognition. IEEE transactions on pattern analysis and machine intelligence, 2012, 35.1: 221-231.