21.深層学習を用いた短期降水予測補正手法におけるデータ拡張の影響評価

松田　聖矢[1]・倉上　健[2]・相馬　一義[3*]・蘇田　憲司[4]・小島　光平[5]・
小畑　宏夢[6]・宮本　崇[3]・馬籠　純[7]・石平　博[7]

[1] 山梨大学大学院医工農学総合教育部（〒400-8511 山梨県甲府市武田 4-3-11）
[2] 日本工営株式会社 中央研究所（〒300-1259 茨城県つくば市稲荷原 2304）
[3] 山梨大学大学院総合研究部工学域土木環境工学系（〒400-8511 山梨県甲府市武田 4-3-11）
[4] 中日本ハイウェイ・エンジニアリング東京株式会社（〒160－0023　東京都新宿区西新宿 1 丁目 23-7 新宿ファーストウエスト 9F）
[5] 山梨県庁（〒400-8501 山梨県甲府市丸の内 1 丁目 6-1）
[6] 東海旅客鉄道株式会社（〒450-6101 愛知県名古屋市中村区名駅 1 丁目 1-4 ＪＲセントラルタワーズ）
[7] 大学院総合研究部生命環境学域環境科学系（〒400-8511 山梨県甲府市武田 4-3-11）
＊E-mail: *ksohma@yamanashi.ac.jp*

近年日本では短時間強雨が増加し，降水予測の信頼性向上と被害軽減への活用が急務である．そのため，物理式に基づくモデルである数値気象モデルの出力を深層学習で補正し，予測の信頼性を向上する手法が開発されている．本研究では数値気象モデル出力補正手法に対して，データ拡張が与える影響を検討した．先行研究では切り出しと平行移動を適用して入力データを拡張しており，160 セル×160 セルの画像から 40 セル×40 セルの画像を切り出す際にウィンドウをずらしたセル数（ストライド）を本研究では 8，20，40 と変えて補正結果を観測値と比較して評価した．台風による降水について検討した結果，ストライドを 40 とした場合で強い降水域が拡大し，その捕捉率が向上し観測値へ近づく傾向が見られた．

Key Words : *Short-term precipitation forecast, Machine learning, Deep learning, Numerical weather prediction model, Data Extension*

1. はじめに

近年，日本において短時間強雨の回数が増加している．気象庁は1976年から1985年までの10年間と，近年の2012年から2021年までの10年間を比較すると，短時間強雨（時間降水量50 mm以上）の年間発生回数は約1.4倍に増加していると報告している[注1)]．短時間強雨に伴う土砂災害や洪水被害も報告されており，被害を抑える対策が求められている．数時間以上先における短時間強雨を予測し被害軽減を図るためには，数値気象モデルが有効と考えられており，改良が進められている．しかし，数時間以上先の短期降水予測を定量的に用いて洪水や土砂災害予測へ活用するには未だ信頼性に課題が残っている．そこで，倉上ら[1),2)]は，深層学習を用いて数値気象モデルによる予測結果を補正して降水量分布を求める手法を開発し，改良[3),4),5),6)]が進められてきた．本研究では，倉上ら[1),2)]の補正手法について，特に学習データ数を補完するためのデータ拡張手法に注目して検討と改良を行うことを目的とする．

2. 使用するデータと深層学習手法

本研究では，詳細な都市環境を考慮した気象シミュレーションが可能な数値気象モデルCReSiBUCver2.4.4[7),8)]を用いる．CReSiBUCver2.4.4は大気モデルCReSS[9)]と，陸面過程モデルSiBUC[10)]とを結合した数値気象モデルである[7),8)]．数値気象モデル出力は1時間ごとの空間解像度2 kmで，鉛直解像度68層（平均200 m間隔，最下層30 m）であり，12時間後～36時間後の出力結果を用いる．数値気象モデルによる予測結果を機械学習の入力データとして，小島[3)]，蘇田[4)]と同様に，前日21JSTを初期時刻と設定した36

時間計算を2001年の夏季（8月1日～8月31日）及び2011年夏季（8月1日～9月7日）各日について行った結果を用いる．各時刻における地上付近の降水量，鉛直風速，水平風速（東西，南北方向成分）を深層学習手法に入力し，同じ時刻の降水量分布が出力される．降水量分布の教師データとしては，気象庁解析雨量を数値気象モデル出力に対応する各セルに最近隣法により内挿したデータを用いる．

本研究では，深層学習手法に畳み込みニューラルネットワークの一種であるU-Net[1)]を用いる．U-Netは，全結合層を持たず，畳み込み層，逆畳み込み層，プーリング層，ショートカット接続で構成されている．U-Netは，通常の全層が畳み込み層であるニューラルネットワークにショートカット接続を導入することにより、畳み込み層を経由して、情報が平滑化された情報に追加して、入力層付近の解像度の空間解像度が高い情報を考慮した学習が可能となる手法である．通常のU-Netでは領域抽出を目的としているため損失関数として交差エントロピーが一般的に用いられる．本研究では教師データとして気象庁解析雨量の連続的な降水強度分布を用いた回帰問題を扱う必要があるため，損失関数として二乗誤差和を用いた[2)]．

3. データ拡張手法の概要

データ拡張手法として小島[3)]，蘇田[4)]は，数値気象モデル予測結果と気象庁解析雨量1組の検討範囲（160×160セル；空間解像度2 km）に対して，ウィンドウサイズ40×40セル（空間解像度2 km）を設定し8セルずつずらし，切り出しと平行移動を適用して入力データを作成している．切り出す際にウィンドウをずらしたセル数を以降ストライドと呼ぶ．

この手法は，学習過程で入力画像の枚数を増やし，より多くの画像を用いることができる．一方で，平行移動を適用する際に画像同士で重複があり，学習に影響を与えている可能性がある．そこで本研究では，先行研究の手法であるストライド8に加えて，ストライドを拡大した20セルと40セルに設定し，ストライドを変更した際の補正結果への影響について検討を行う．

また，本研究におけるエポック数は，検証過程においてなめらかな降水量分布が得られる最小の値に設定した．ストライド8では蘇田[4)]と同様にエポック数500，ストライド20ではエポック数を1500，ストライド40ではエポック数を2500と設定し計算を行う．

4. 定量的評価で用いる評価指標

定量的評価ではカテゴリー分類表（表-1）を用いて指標を算出する．分類表では，FO（降水あり的中），FX（空振り），XO（見逃し）XX（降水事象無し）の4つに分類される．本研究では，以下の計算式を用いてデータ全体に対する予測精度（ACC），事象数が極めて多い降水事象なしXXを考慮に入れないときの予測精度（CSI），空振りの多さ（FAR），捕捉率の高さ（POD），をカテゴリー分類表の4要素を用いて算出する．

降水あり／なしの閾値として，本研究では1 mm/hr（降水の有無）と5 mm/hr（強い降水）を設定した．

$$\mathrm{ACC} = (\mathrm{FO} + \mathrm{XX})/(\mathrm{FO} + \mathrm{FX} + \mathrm{XO} + \mathrm{XX}) \quad (1)$$

$$\mathrm{CSI} = \mathrm{FO}/(\mathrm{FO} + \mathrm{FX} + \mathrm{XO}) \quad (2)$$

$$\mathrm{FAR} = \mathrm{FX}/(\mathrm{FO} + \mathrm{FX}) \quad (3)$$

$$\mathrm{POD} = \mathrm{FO}/(\mathrm{FO} + \mathrm{XO}) \quad (4)$$

表-1　定量的評価における分類表[注2)]

		解析雨量(観測値)	
		降水あり	降水なし
補正後	降水あり	FO	FX
	降水なし	XO	XX

5. 結果と考察

本研究における学習過程では，2001年8月1日~31日と2011年8月1日~19日の数値気象モデル計算結果を用いる．検証（ハイパーパラメータ調整）過程では，2011年8月20日，8月25日，9月1日の3日間，推論過程では，検証過程で使用した日を除いた2011年8月20日~2011年9月7日の計算結果を用いる．

推論過程について，特に台風による降水が見られた期間（2011年9月2日~2011年9月7日）における全画像を平均した評価指標の値を表-2に示す．POD（1 mm/hr）において，ストライド40では0.944とストライド8での0.815，ストライド20での0.781と比較して数値が大きく上昇した．POD（5 mm/hr）においても，ストライド40では0.337とストライド8での0.251，ストライド20での0.213と比較して数値が上昇した．また，CSI（1 mm/hr）においてもストライド40では0.664とストライド8での0.610，ストライド20での0.593と比較して数値が上昇した．一方で，FARの値はストライド40が最も高くなり，ACCでは各ストライドでの大きな変化は見られなかった．

以上のことより，ストライドを大きくすることによって強い降水域（5 mm/hr）の範囲が拡大し，捕捉率が向上したと考えられる．

表-2　台風による降水が見られた期間における各指標の平均値

	補正前	stride8	stride20	stride40
ACC(1mm/hr)	0.611	0.683	0.678	0.698
ACC(5mm/hr)	0.737	0.744	0.718	0.723
CSI(1mm/hr)	0.412	0.610	0.593	0.664
CSI(5mm/hr)	0.210	0.192	0.160	0.223
FAR(1mm/hr)	0.226	0.300	0.295	0.312
FAR(5mm/hr)	0.533	0.535	0.576	0.596
POD(1mm/hr)	0.412	0.815	0.781	0.944
POD(5mm/hr)	0.210	0.251	0.213	0.337

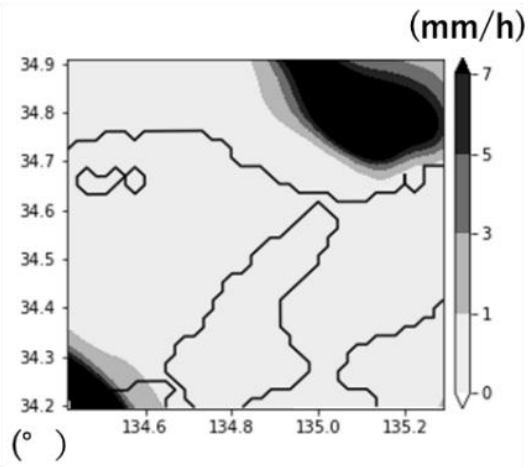


図-1　2011 年 9 月 2 日 19 時　兵庫県淡路島周辺における数値気象モデル出力結果（補正前）

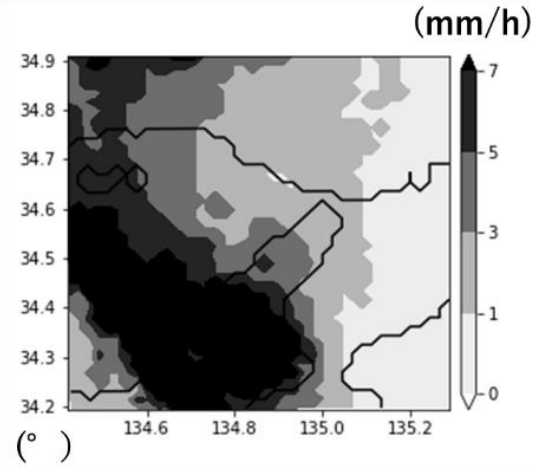


図-2　2011 年 9 月 2 日 19 時　兵庫県淡路島周辺における気象庁解析雨量（観測値）

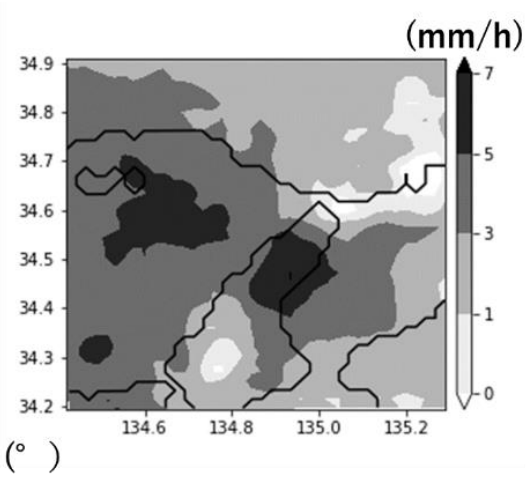


図-3　2011 年 9 月 2 日 19 時　兵庫県淡路島周辺における補正後出力結果（ストライド 8）

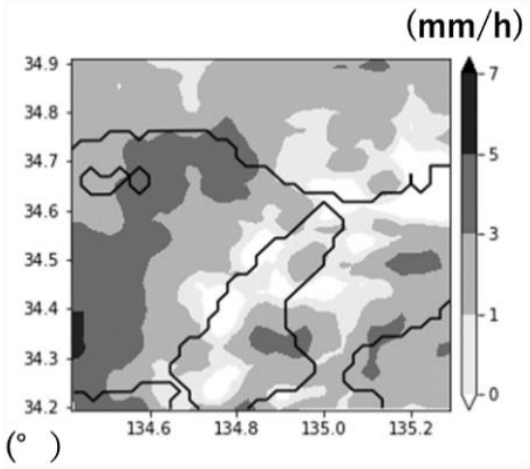


図-4　2011 年 9 月 2 日 19 時　兵庫県淡路島周辺における補正後出力結果（ストライド 20）

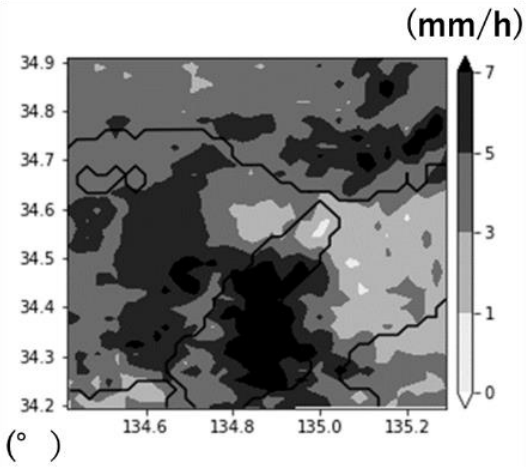


図-5　2011 年 9 月 2 日 19 時　兵庫県淡路島周辺における補正後出力結果（ストライド 40）

また，個々の画像で算出したCSIの評価について，補正前と比較して補正後で数値が上昇した時刻と画像を抽出した．補正前の数値気象モデル出力における降水量分布を図-1に，気象庁解析雨量による観測値を図-2に，ストライド8，20，40を用いた補正後の降水量分布を図-3，図-4，図-5に示す．スライド40を用いた補正後の値では，ストライドが小さい場合と比較すると，5mm/hr以上の強い降水域が拡大し図-2の解析雨量に近づいていることがわかる．

6. 結論

本研究では，深層学習を用いた短期降水予測補正手法にデータ拡張が与える影響について，異なるストライドの大きさで定量的評価を行った．また，各ストライドにおける補正後結果を降水量分布として出力し，定性的評価を行った．ストライドを大きくすることにより，台風による降水事例では 1 mm/hr，5 mm/hr 共に捕捉率の高さ（POD）が上昇した．このことにより，ストライドを大きくすることによって，数値気象モデル出力結果では捉えることが難しかった降水を捉えられる可能性があることが示唆された．一方で，短時間強雨等の降水事例に対しては更なる改善の必要があると考えられる．今後は，地形情報や水蒸気量等を入力データとして加えることにより，短期降水予測補正手法の更なる精度の向上を図る必要がある．

謝辞：

本論文の主要部分は山梨大学工学部土木環境工学科松田聖矢氏の卒業論文・修士論文研究及び蘇田憲司氏，小島光平氏，小畑宏夢氏の卒業論文研究において作成されました．また，山梨大学 古屋貴彦助教，宮沢直季助教，大槻順朗助教，松浦拓哉助教には多くのご助言をいただきました．そして，科研費 基盤研究（B）19H02246, 20H02258，19H01378，山梨大学スマート社会基盤創造研究ユニット，名古屋大学 HPC 計算科学連携研究プロジェクト，「富岳」機動的課題（一般）課題番号：hp210291 の支援を受けました．ここに感謝の意を表します．

NOTES

注1) 国土交通省　気象庁: 大雨や猛暑日など（極端現象）のこれまでの変化, https://www.data.jma.go.jp/cpdinfo/extreme/extreme_p.html, 2022 年 1 月 19 日閲覧

注2) 国土交通省　気象庁：数値予報研修テキストで用いた表記と統計的な指標, https://www.jma.go.jp/jma/kishou/books/nwptext/42/Appendix_B.pdf

REFERENCES

1) 倉上健，相馬一義，宮本崇，古屋貴彦，馬籠純，石平博: 深層学習を用いた降水短期予測における数値気象モデル出力補正手法の構築，土木学会論文集 G（環境），Vol.75,No.5,I_33-I_39,2019. [Kurakami, T. Souma, K. Miyamoto, T. Huruya, T. Magome, J. and Ishidaira, H.: Numerical Weather Model Output Correction Method for Short-Term of rainfall Precipitation Prediction using deep learning, Transaction of the Japan Society of Civil Engineers，Vol.75,No.5,I_33-I_39,2019.]

2) 倉上健, 相馬一義, 宮本崇, 古屋貴彦, 馬籠純, 石平博: ショートカット接続を含む深層学習による数値気象モデル降水量予測補正の検討, 土木学会論文集 G（環境）, Vol.76, No.5, I_471-I_478, 2020. [Kurakami, T. Souma, K. Miyamoto, T. Huruya, T. Magome, J. and Ishidaira, H.: Numerical Weather Model Precipitation Prediction Correction by Deep Learning with Shortcut Connections, *Transaction of the Japan Society of Civil Engineers*, Vol.76, No.5, I_471-I_478, 2020.]

3) 小島光平: 深層学習による降水短期予測補正手法の改良に関する検討, 山梨大学卒業論文, p.26, 2021. [Kojima, K.: A Study on Improvement of Short-Term Precipitation Prediction Method Using Deep Learning, University of Yamanashi Graduation Thesis, p.26, 2021.]

4) 蘇田憲司: 深層学習による降水短期予測補正手法の入力データ及びネットワーク構造に関する検討，山梨大学卒業論文, p.40, 2022. [Soda, K.: A Study on Input Data and Network Structure of Deep Learning Method for Short-Term Precipitation Prediction, University of Yamanashi Graduation Thesis, p.40, 2022.]

5) 小畑宏夢: 深層学習による数値気象モデル予測結果補正手法の拡張に関する検討, 山梨大学卒業論文, pp.33, 2020. [Obata, H.: A Study on Extension of Numerical Weather Model Prediction Method Using Deep Learning, University of Yamanashi Graduation Thesis, p.33, 2020.]

6) 松田聖矢：深層学習を用いた降水短期予測補正手法にデータ拡張が与える影響に関する検討, 山梨大学卒業論文，p.40，2023. [Matsuda, S.: A Study on the Impact of Data Extension on A Correction Method for Short-Term Precipitation Prediction Using Deep Learning, University of Yamanashi Graduation Thesis, p.42, 2023.]

7) Kazuyoshi Souma, Kenji Tanaka, Tadashi Suetsugi, Kengo Sunada, Kazuhisa Tsuboki, Taro Shinoda, Yuqing Wang, Atsushi Sakakibara, Koichi Hasegawa, Qoosaku Moteki, and Eiichi Nakakita: A comparison between the effects of artificial land cover and anthropogenic heat on a localized heavy rain event in 2008 in Zoshigaya, Tokyo, Japan, Journal of Geophysical Research, 118, pp.11,600-11,610, doi:10.1002/jgrd.50850, 2013.

8) Kazuyoshi Souma, Kengo Sunada, Tadashi Suetsugi and

Kenji Tanaka: Use of ensemble simultions to evaluate the urban effect on a localized heavy rainfall event in Tokyo, Japan, Journal of Hydro-environment Research, 7 (4), pp.228-235, doi:10.1016/j.jher.2013.05.001, 2013.

9) Kazuhisa Tsuboki, Atsushi Sakakibara: Large-Scale Parallel Computing of Cloud Resolving Storm Simulator, High Performance Computing, Zima HP et al.(ed), Springer, Germany, pp. 243–259, 2002.

10) Kenji Tanaka: Development of the new land surface scheme SiBUC commonly applicable to basin water management and numerical weather prediction model, Doctoral Dissertation, Kyoto University, 2005, p.292.

11) Ronneberger O., Fischer P., Brox T.: U-Net: Convolutional Networks for Biomedical Image Segmentation, arXiv:1505.04597, 2015.