

多時刻統合型 AFNO 降雨予測モデル の九州河川流域への適用と精度評価

曾田 康秀¹・成 岱蔚²・酒寄 千展³

¹ 博士(理学)(株)東京建設コンサルタント 環境防災研究所 (〒170-0004 東京都豊島区北大塚 1-15-6)
E-mail: sota-y@tokencon.co.jp (Corresponding Author)

² 博士(工学)(株)東京建設コンサルタント 環境防災研究所 (〒170-0004 東京都豊島区北大塚 1-15-6)
E-mail: cheng-d21@tokencon.co.jp

³ (株) 東京建設コンサルタント 環境防災研究所 (〒170-0004 東京都豊島区北大塚 1-15-6)
E-mail: sakayori-c23@tokencon.co.jp

近年、線状降水帯による豪雨災害が頻発しており、6 時間先までの降雨予測精度の向上は水害軽減対策において重要な課題となっている。Adaptive Fourier Neural Operator (AFNO) による AI 大気・降雨予測モデルは推論時間が短く、降雨予測の配信遅れ時間を低減できる点で有用である。本研究では、多時刻の降雨予測を 1 時刻の複数チャンネルに統合する多時刻統合型 AFNO 降雨予測モデルを構築し、九州地方の筑後川および球磨川流域における 6 時間先までの降雨の予測精度を評価した。境界の影響を考慮した多時刻統合型 AFNO 降雨予測では、可降水量の AFNO による予測値を入力チャンネルに加えることで 6 時間先までの降水量予測精度が向上した。また NowCastNet および気象庁降水短時間予報との比較を行い、強降雨領域での降雨予測において移流型降雨予測モデルと同等の予測精度が得られることを示した。

Key Words: AFNO, rainfall prediction, precipitable water vapor, AI weather forecasting, heavy rainfall

1. はじめに

近年、日本各地で線状降水帯による集中豪雨が頻発しており、九州地方でも大規模な水害が発生している。特に筑後川流域では、2017 年 7 月九州北部豪雨や 2020 年 7 月豪雨において記録的な降雨が観測され、流域各地で洪水および土砂災害が発生したことが報告されている¹⁾。このような豪雨災害の軽減のため、近年では洪水氾濫の危険度を事前に評価する水害リスクライン²⁾を用いた防災対策が進められている。その精度向上には、数時間先までの数値気象予報 (NWP) による降雨予測の高精度化が重要な課題となっている。

気象庁降水短時間予報 (JMA) は、レーダーおよびアメダス観測から作成された解析雨量を基に、降水域の移動や発達・衰弱を考慮したナウキャストおよび実況補外型予報 (EX6) と、メソ数値予報モデル (MSM) および局地数値予報モデル (LFM) の予報値を加工・統合す

ることで作成される降水予測プロダクトであり、日本域を対象として最大 6 時間先までの 1 時間降水量を提供している³⁾。また気象レーダー画像を入力とし、降水域の移動および強度変化を同時に予測する AI 型降雨ナウキャストモデル NowCastNet⁴⁾では、従来のレーダー外挿法では表現が困難であった降水セルの発達や減衰を再現可能であることが報告されている。これらは、いずれも気象レーダー観測から得られる降水分布を基に降水域の移動 (移流) をベースにした降雨予測モデルである。

一方、ここ数年、気象予報の再解析データを大量に学習させるデータ駆動型 AI モデルの適用可能性が検討されている。欧州中期気象予報センター (ECMWF) が提供する全球規模の再解析データセット (ERA5) を Adaptive Fourier Neural Operator (AFNO)⁵⁾で学習させた FourCastNet⁶⁾は、数値気象予報と同程度の予測精度を保ちながら、推論時間を大幅に短縮できることが示されている。また著者らによるメソスケールでの気象庁局地客

観解析データ⁷⁾および気象庁解析雨量データを AFNO で学習させた大気・降雨予測モデル⁸⁾では、九州地方における数時間先までの線状降水帯による降雨予測の計算時間が大幅に短縮できることや、大気予測情報を降雨予測に組み込むことで降雨の予測精度が向上することが示されている。

一方、著者らの AFNO 降雨予測モデルでは、2~3 時間先の降雨予測精度が 1 時間先の予測精度に比べ著しく低下することが確認されている⁸⁾。メソスケールにおける AFNO 大気・降雨予測モデルでは、全球の気象データを学習に利用している FourCastNet と異なり、学習対象領域の境界条件の影響が予測精度に大きく影響する。特に九州地方を対象とした大気予測では、対象領域の西側から流入する水蒸気が数時間先の降雨予測に大きく影響するため、対象領域外からの水蒸気輸送を十分に考慮できないという問題がある。また、降水量は大気状態と比較して不確実性が大きい量であり、逐次型予測において、前時刻の予測誤差が次時刻の予測誤差に伝播し、数時間先の降雨予測誤差が増幅する可能性がある。

以上の点を踏まえ、本研究では九州の河川流域に影響を及ぼす大気の影響範囲を考慮した AFNO 大気予測モデルおよび降雨予測手法を逐次型から複数チャンネル統合型へ変更した多時刻統合型 AFNO 降雨予測モデルを構築し、特に水害リスク対策の視点から気象庁 JMA および NowCastNet との流域単位での降雨予測精度の比較を行う。2 章では筑後川流域からの軌道逆追跡により、6 時間先までの大気予測に対する影響範囲を求め AFNO 大気モデルを構築する。また 6 時間先までの降雨予測を行うために、AFNO の複数時刻での入出力データを 1 時刻でのチャンネルにまとめた多時刻統合型 AFNO 降雨予測モデルを構築する。3 章ではテスト用降雨イベントに対し、多時刻統合型および逐次型 AFNO 降雨予測モデルの九州地方 2 河川流域での JMA に対する降雨予測精度を比較する。また JMA および NowCastNet との比較により、2025




図-1 筑後川流域にランダムに配置された仮想粒子の 500hPa および 850 [hPa] 等圧面上での逆追跡による 6 時間前までの移動位置。

年の年最大降雨期間における多時刻統合型 AFNO 降雨予測モデルの予測精度を検証する。4 章では、AFNO 大気予測モデルの有効性や今後の課題について述べる。

2. 九州地方での AI 大気・降雨予測モデルの構築

本章では、AFNO 大気・降雨予測モデルにおける境界の影響を考慮するために、九州地方の筑後川流域を対象に上空大気の 6 時間前までの影響領域を考慮した AFNO 大気予測モデルを構築する。また九州地方を対象とした AI 降雨予測の有用性を考察するために、複数時刻での説明変数を統合した AFNO 降雨予測モデルおよび NowCastNet を構築する。

(1)境界を考慮した AFNO 大気予測モデルの構築

以下では、九州地方の代表的な河川流域として筑後川流域を対象とし、同流域に流入する大気の影響を評価するため、流域内に仮想粒子を配置する。次に、局地客観解析データの風速場を用いて、これらの粒子をラグランジュ的に過去方向へ逆追跡し、6 時間後に筑後川流域へ流入し得る大気の影響領域を推定する。このような後方粒子軌道解析は、水蒸気輸送の評価などに広く用いられている⁹⁾¹⁰⁾。

本研究における「大気移流」は、局地客観解析データに含まれる水平方向風速成分 (u, v) を用いて、粒子の位置 (x, y) を時間積分することで表現する。時間積分には一定時間刻みでの陽的オイラー法を用いた。500 [hPa] および 850 [hPa] において 6 時間前まで粒子を逆追跡した結果を図-1 に示す。上空ほど粒子軌道の広がり大きくはなるが、実際の空気塊は鉛直運動を伴うため、その影響領域はこれらの軌道分布よりも内側に位置すると考えられる。以上より、本研究では図-1 で得られた粒子軌道に基づき、6 時間後までに筑後川流域へ影響を及ぼす可能性のある領域を AFNO 大気予測モデルの学習領域 (図-2 左) として設定する。

訓練データとしては、2018 年から 2025 年までの各年

表-1 イベント数および逐次型モデルのスライド窓数

年	イベント数 N_E	スライド窓数 N_S
2018	24	963
2019	46	1842
2020	46	1745
2021	40	1616
2022	42	1590
2023	35	1484
2024	33	1231
2025	44	1838




図-2 AFNO 大気・降雨予測モデルにおける学習領域. AFNO 大気予測モデルの学習領域(左)を AFNO 降雨予測モデルの学習領域(右)よりも広範囲に設定する. 降雨予測モデルでは, 青の実線 (狭領域) または破線枠 (広領域) を学習領域に用いる.

の4月から11月を対象とし, 既往研究⁸⁾と同様

(i) 解析雨量 1km 点で 3 時間累加雨量が 80mm 以上であるメッシュの数が 500 以上となる.


(ii) 解析雨量 1km 点で 3 時間累加雨量の最大が 100mm 以上である.

のいずれかの条件を満たす時刻から前 24 時間, 後 12 時間の期間を降雨イベントとして取り出す. 既往研究⁸⁾では 2018 年から 2023 年までのイベントを学習用, 2024 年イベントをテスト用としたのに対し, 本研究では 2018 年から 2024 年までの学習用降雨イベントのうち 1 年分を


検証用, 残りの年を訓練用とし, 2025 年の降雨イベントをテスト用とする. 各年のイベント数 N_E および正時での説明変数を入力する逐次型大気モデルの学習用スライド窓の総数 N_S は表-1 となる. 学習時には, 訓練用および検証用イベント期間内の全スライド窓の気象データを用いて深層学習を行う.

既往研究⁸⁾では図-2 左青枠の領域を 128×128 のメッシュに分割したのに対し, 本研究では図-2 左緑枠の影響範囲を 128×128 のメッシュに分割し, 各メッシュ点上に説

(a) AFNO 大気 Finetuning モデル A_{ff} の学習



(b) 多時刻統合型 AFNO 降雨予測モデルの学習



(c) 多時刻統合型 AFNO 降雨予測モデルによる推論




図-3 学習時, 推論時における AFNO モデルのネットワーク構造例: 現時刻を含めた未来 3 時刻を予測する.




図4 (a) 筑後川流域(赤線)および球磨川流域(青線). (b) 流域平均雨量の最大値が 1 [mm/h]以上となるテスト用イベントの 3 時間累加雨量(赤棒). 最大値が 10 [mm/h]以上のイベントには黒矢印が付与されている. (c) 筑後川流域(左)および球磨川流域(右)での年最大雨量発生時刻(それぞれ $t_{c,max}$, $t_{k,max}$)での降雨分布.

明変数の物理量を線形補間した値を用いる. 時刻 t (正時)における AFNO 大気予測モデルの説明変数 $\vec{X}_t$ は既往研究⁸⁾と同様, 可降水量 (PWV) および局地客観解析データにおける 500 [hPa], 850 [hPa]の圧力面での風速 2 成分, 気温, ジオポテンシャル高度, 地上面での風速 2 成分, 気温, 海面更生気圧とし, 目的変数はそれらの 1 時間後の値 $\vec{X}_{t+1}$ とする. PWV は局地客観解析データから得られる水蒸気混合比および標高データから水蒸気密度の積分を差分近似して求める⁸⁾. 以下では時刻 t での PWV を W_t と表記する. 本研究では, 原著論文⁹⁾で公開されていた AFNO ソースコードを利用し, 学習の損失関数(loss)にモデル出力値 $A_{fb}(\vec{X}_t)$ と正解値 $\vec{X}_{t+1}$ との平均二乗誤差 (MSE) を用い 1 層の AFNO ブロックにスキップコネクションを用いたネットワーク構造(図-2 左)に対して, GPGPU による深層学習を行う. また既往研究と同様に 1 時間先の AFNO 大気 base モデルを学習したのちに, 2 時

間先までの予測値 $A_{fb}(\vec{X}_t)$, $A_{fb}^2(\vec{X}_t)$ に対して base モデルを再学習し, AFNO 大気 finetuning モデルを構築する(図-3(a)). 以下では時刻 t での入力値 $\vec{X}_t$ に対する学習済み AFNO 大気 base モデルの出力 $A_{fb}(\vec{X}_t)$ を次の時刻の入力に代入する操作を n 回繰り返した時の出力値を $A_{fb}^n(\vec{X}_t)$, 同様の手続きで得られる AFNO 大気 finetuning モデルの出力値を $A_{ff}^n(\vec{X}_t)$, $A_{fb}^n(\vec{X}_t)$ および $A_{ff}^n(\vec{X}_t)$ の PWV 成分をそれぞれ $W_{fb}^n(\vec{X}_t)$, $W_{ff}^n(\vec{X}_t)$ と表記する.

一般に, 九州全域から抽出した降雨イベントには, 各河川流域内で無降雨となるケースが含まれる. このため, 以下では, 2025 年の 44 のテスト用降雨イベント期間 T_{ei} のうち, 各流域におけるイベント期間中の流域平均雨量の最大値が 1[mm/h] 以上となるイベントを検証対象とする. 筑後川流域(図-4(a)赤線)および球磨川流域(図-4(a)青線)でのこれら対象イベント期間での 3 時間累加雨量(図-4(b)の赤帯)はいずれも 8 月 6 日から 8 月 12 日 12 :




図-5 イベント期間 $T_{e,max}$ における流域平均PWV予測値。(a)筑後川流域での3時間先予測値(左)および6時間予測値(右), (b)球磨川流域での3時間先予測値(左)および6時間予測値(右), 黒の実線は流域平均PWV実績値。紫の縦線は時刻 $t_{c,max}$ (筑後川流域)および $t_{k,max}$ (球磨川流域)。

00までのイベント期間 $T_{e,max}$ (図-4(b)黒枠)で年最大となる。筑後川, 球磨川流域での流域平均雨量の年最大発生時刻をそれぞれ $t_{c,max}$ (8月10日20:00), $t_{k,max}$ (8月7日16:00)と表記すると, これらの時刻において, 流域の大部分で30[mm/h]以上の降雨が確認される(図-4(c))。実際, この期間内に九州地方で複数の線状降水帯が発生しており, 当該期間 $T_{e,max}$ を線状降水帯発生時における降雨予測精度の検証期間として設定する。

以下では物理量 A の筑後川流域および球磨川流域での流域平均値をそれぞれ $\langle A \rangle_c, \langle A \rangle_k$ と表記すると, 推論期間 $T_{e,max}$ での $\langle W_t \rangle_c$ および $\langle W_t \rangle_k$ はそれぞれ時刻 $t_{c,max}, t_{k,max}$ の直前で最大となる。図-5より, これらの実績値と2018年, 2022年, 2024年を検証データとした $W_{fb}^k(\vec{X}_t), W_{ff}^k(\vec{X}_t)$ ($k=3, 6$)を流域平均した値を比較すると, $k=6$ では $k=3$ の場合と比較してモデルごとの予測値のばらつきが大きくなるが, finetuningモデルでは $k=6$ での実績からのずれがbaseモデルよりも低減されることが確認できる。また筑後川流域での $\langle W_{ff}^k(\vec{X}_t) \rangle_c$ と $\langle W_t \rangle_c$ のピーク値の差は時刻 $t_{c,max}$ 付近で5mm程度だが, 球磨川流域での $\langle W_{ff}^k(\vec{X}_t) \rangle_k$ と $\langle W_t \rangle_k$ の時刻 $t_{k,max}$ 付近でのピーク値の差は10mm程度まで広がっている。よって finetuningモデルを用いることでPWVの予測誤差は低減するが, 流域平均値のピーク時刻付近での誤差はモデルごとや流域ごとにはばらつきが見られることが確認できる。

(2)多時刻統合型AFNO降雨予測モデルの構築

著者らの既往研究⁹⁾では, 時刻 t での可降水量 W_t およ

び降雨量 P_t を入力とし1時刻後 $t+1$ での降雨量 P_{t+1} を出力とするAFNO降雨予測モデルを構築した。しかしながら, このモデルに基づく降雨予測では2時間先, 3時間先の降雨予測誤差が著しく低下した。これは降雨予測については不確実性が大きく, その予測値を次の時刻の入力に入れると予測誤差が著しく増幅するためであると考えられる。そこで本研究では, 複数時刻の入力データおよび出力データをAFNOの複数チャンネルに統合し, 複数時刻の降雨を1度に予測する多時刻統合型AFNO降雨予測モデルを構築する。

本モデルでは時刻 t での2時刻前から現時刻までの降雨量(P_{t-2}, P_{t-1}, P_t)および2時刻前から n 時刻後までのPWV($W_{t-2}, \dots, W_{t+n}$)を入力チャンネルに, 1時刻後から n 時刻後までの降雨量($P_{t+1}, \dots, P_{t+n}$)を出力チャンネルに用いる($n=3$ の場合を図-3(b)に示す)。各年の多時刻統合型のスライド窓の総数は表-1の N_E, N_S を用いて $N_S - N_E(n+2)$ と表される。学習領域については, 境界条件の影響を考慮し, 図-2左青実線枠(狭領域)または青破線枠(広領域)を用いる。入力データにはこれらの領域を128×128のメッシュに分割し, 各メッシュ点上に降雨量およびPWVを線形補間した値を用いた。

AFNO降雨予測モデルの学習における誤差関数には, 既往研究⁹⁾と同様にフーリエ振幅・相関損失(FACL)を用いる¹¹⁾。FACLでは, 学習前半にフーリエ相関損失(FCL), 後半にフーリエ振幅損失(FAL)に重みを付与して学習を行う。さらにPWVの寄与を評価するため, 降雨量のみを入力とするAFNO-SOLRモデルを構築し, PWV値も




図-6 筑後川流域（左）および球磨川流域（右）における $r_{k,s}$ ($1 \leq k \leq 6$)の比較。上段は $s=1$ 、下段は $s=10$ の場合を示す。黒の太線は $r_{k,s} = 0.5$ を表す。

入力に用いた AFNO 降雨予測モデルとの比較を行う。

(3)多時刻統合型 AFNO 降雨予測モデルの推論

学習済みの多時刻統合型 AFNO 降雨予測モデルのリアルタイムでの推論する場合、未来の可降水量の値 $W_{t+1}, \dots, W_{t+n}$ は既知ではない。このため、本研究ではこれらの値として、AFNO 大気 finetuning モデルによる可降水量の予測値 $W_{ff}^n(\vec{x}_t)$ を用いる(図-3(c))。以下では、この $W_{ff}^n(\vec{x}_t)$ を推論に用いた AFNO 降雨予測モデルを AFNO-PWVPR と表記する。また理想条件として、未来の可降水量が完全に既知である場合を想定し、 $W_{t+1}, \dots, W_{t+n}$ をそのまま用いたモデルを AFNO-PWVCR と表記する。次章では $n=6$ として、これら3種類のモデル AFNO-SOLR, AFNO-PWVPR, AFNO-PWVCR の精度検証を行う。

(4) NowCastNet による移流型 AI 降雨予測モデルの構築

以下では、移流型降雨予測モデルに対する AFNO 降雨予測の予測精度を比較するために、国土交通省が運用している高解像度降雨観測システム XRAIN の九州地方における降雨データを用いて、NowCastNet による移流型降雨予測モデルを構築する。NowCastNet は、DeepMind により提案された DGMR¹²⁾のような生成型 AI に基づく短時間降雨予測モデルであり、大気場の情報を明示的には用いず、過去の降雨分布から将来の降雨場を推定する手法である。NowCastNet では、降雨の移流および生成・

消滅過程を表現する EvolutionNetwork を導入し、その出力を Generator への条件情報として与えることで、安定した降雨予測を実現している。NowCastNet の公式実装はオープンソースとして公開されており、転移学習が可能である。本研究では、Generator 部分については原著論文で配布されている学習済みパラメータをそのまま使用し、Evolution Network のみを九州地方西部 (AFNO 大気予測モデルの学習領域と同一領域) のデータを用いて再学習する。原著論文では、10 分間隔の降雨データを用いて 9 フレームの入力から 20 フレーム先までを予測する (9 入力 + 20 予測) 構成で学習されているため、本研究でも同じ設定を用いる。すなわち、XRAIN の空間解像度を 1 km、時間解像度を 10 分とし、現時刻から過去 90 分間の 9 フレームを入力として、将来 200 分 (20 フレーム) 先までの降雨を予測する。Evolution Network の学習には、AFNO モデルの学習期間と同期間の XRAIN 降雨データを用い、推論では毎正時を初期時刻として最大 3 時間先までの降雨予測を行う。

3. 九州河川流域 AFNO 降雨予測モデルの精度検証

以下では(1)節で流域平均雨量の最大値が 1[mm/h]以上のテスト用降雨イベント(図-4(b)赤帯)および 10[mm/h]以上のテスト用降雨イベント(図-4(b)黒矢印)を対象とし、境界の影響および逐次型および多時刻統合型モデル




図-7 JMA, NowCastNet, 狭領域 AFNO-PWVCR (検証期間 2018,2022,2024)によるイベント期間 $T_{e,max}$ 内の各時刻における流域平均雨量予測値。

の 6 時間先までの降雨予測精度を検証する。さらに(2)節では線状降水帯が発生した年最大降雨イベント期間 $T_{e,max}$ (図-4(b)黒枠)を対象として, NowCastNet および気象庁の JMA による 3 時間先までの降雨予測結果との比較を行う。

(1) テスト用降雨イベントに対する降雨予測精度検証

以下では多時刻統合型降雨予測モデルの精度検証のため, 同一の境界条件 (図-2 左青実線枠) および降雨イベントに基づく教師データを用いて逐次型 AFNO 降雨予測モデル⁸⁾を構築する。次にこれらの AFNO 降雨予測モデルの精度評価のために, 筑後川, 球磨川の 2 流域を対象とし, テスト用降雨イベント期間 $T_{e,i}$ における k ($1 \leq k \leq 6$) 時間先までの各流域での平均雨量の予測誤差 $\langle \Delta P_{t+k} \rangle_{t \in T_{e,i}}$ を定義する。

AFNO 降雨予測モデルおよび JMA の $\langle \Delta P_{t+k} \rangle_{t \in T_{e,i}}$ をそれぞれ $\langle \Delta P_{AF,t+k} \rangle_{t \in T_{e,i}}$, $\langle \Delta P_{JMA,t+k} \rangle_{t \in T_{e,i}}$ と表記し, 両者の比を $RP_k(T_{e,i}) \equiv \langle \Delta P_{AF,t+k} \rangle_{t \in T_{e,i}} / \langle \Delta P_{JMA,t+k} \rangle_{t \in T_{e,i}}$ とする。以下では図-4(b)の流域平均雨量の最大値が s [mm/h] 以上($s=1,10$)を満たすイベントの総数を N_s とし, 2018 年, 2022 年, 2024 年を検証データとした 3 つの学習済みモデルそれぞれに対して評価を行う。すなわち, 全評価対象数を $3N_s$ とし, このうち $RP_k(T_{e,i}) < 1.0$ を満たすイベントの総数の割合を $r_{k,s}$ と定義する。

逐次型, 多時刻統合型, 多時刻統合型広領域モデル (図-2 左の青破線で示す広領域)における AFNO-SOLR と AFNO-PWVCR について, $r_{k,s}$ を比較した結果を図-6 に示す。図-6 から以下の知見が得られる。(i) 逐次型予測モデルの $r_{k,s}$ は概ね 0.5 以下となる。一方, 多時刻統合型では

$r_{k,s}$ は逐次型よりも高くなる傾向があり, 筑後川流域の $s = 10$ を除き, 多時刻統合型 AFNO-PWVCR では 3 時間以上のリードタイムにおいて $r_{k,s}$ が 0.5 を超える。(ii) 筑後川および球磨川流域($s=1$)では, 広領域学習を行うことで予測精度が向上する傾向が認められる。(iii) $s=1,10$ のいずれの場合においても, AFNO-PWVCR の $r_{k,s}$ は AFNO-SOLR の値を概ね上回り, 可降水量を入力に含めることが降雨予測精度の向上に寄与することが示される。

(2) 線状降水帯発生時での降雨予測モデル精度検証

以下では線状降水帯の発生した年最大降雨時刻 $t_{c,max}, t_{k,max}$ を含むイベント期間 $T_{e,max}$ での, JMA, NowCastNet および 2018, 2022, 2024 年を検証データとした 3 つの学習済みの AFNO 降雨モデルによる流域平均雨量の予測値を比較する。

狭領域 AFNO-PWVCR の 3 モデルと JMA および NowCastNet の $T_{e,max}$ での年最大雨量時刻付近での 3 時間先までの 2 流域での流域平均雨量予測値の時系列を図-7 に示す。1 時間先予測では JMA および NowCastNet はともにピーク時刻を良く予測しているが AFNO は少し遅れてピーク時刻を予測している。2 時間先予測では JMA の予測精度が最も良く, NowCastNet は筑後川流域で予測が実測よりも高く出ている。この NowCastNet の予測不安定性は, Generator 部分の学習を行っていないことが要因と考えられる。3 時間先では, JMA の予測のピーク値は実測の半分以下に落ちる一方, AFNO では, 3 モデルで予測のばらつきが 2018 年検証モデルでは, 球磨川流域での 3 時間予測が JMA を上回っている。次に $T_{e,max}$ での流域平均の降雨強度が 10 [mm/h]を超える時刻 t を対象に,




図-8 狭流域および広流域における 2025 年最大降雨イベント期間 $T_{e,max}$ における流域平均雨量の降雨強度が 10 [mm/h]を超えた時刻での, JMA, NowCastNet および 2018, 2022, 2024 年検証 AFNO 降雨予測モデルのリードタイム 6 時間までの $\langle \Delta P_{t+k} \rangle_{t \in T_{e,max}}$.

AFNO-PWVCR や AFNO-SOLR も含め, 各モデルの $\langle \Delta P_{t+k} \rangle_{t \in T_{e,max}}$ を比較した結果を示す(図-8). 筑後川流域での狭領域予測では, AFNO-PWVCR の予測誤差はいずれも JMA の予測誤差を上回っている. 一方, 球磨川流域での狭領域予測では, 2018 年検証 AFNO-PWVCR の予測誤差は 6 時間先まで JMA の半分程度となり JMA の予測精度を上回っている. また, リードタイム 4 時間以上では, 2024 年検証 AFNO-PWVCR の予測精度も JMA の予測精度を上回っている.

筑後川流域の広領域では, 2018 年, 2024 年検証 AFNO-PWVCR および AFNO-PWVPR モデルの予測精度は JMA を上回り, AFNO の予測精度が向上している. これは, 筑後川流域の年最大降雨時刻では領域の境界付近に強い降雨が降っており, 境界の影響が強く効いているためと推定される. 一方, 球磨川流域では AFNO-PWVPR モデルの予測精度は全てのリードタイムで JMA よりも下回っている. これは球磨川流域での PWV の予測精度が低いことが要因であると考えられる. AFNO-SOLR モデルの予測精度も全てのリードタイムで JMA よりも下回る.

時刻 $t_{c,max}$, $t_{k,max}$ での降雨強度分布(図-4(c))に対する 2018 年検証広域モデルによる 1 時間先から 3 時間先までの予測結果をそれぞれ図-9, 図-10 に示す. 時刻 $t_{c,max}$ では JMA と NowCastNet, AFNO-SOLR はいずれも 1,2 時間先予測において筑後川流域北側で 30 [mm/h]以上の強降雨領域を予測しているが, 3 時間先予測では流域内の大部分で 10 [mm/h]未満となっている. 一方, AFNO-PWVCR,

AFNO-PWVPR では, 3 時間先予測でも流域内の大部分で 10 [mm/h]以上となっている. 特に AFNO-PWVCR モデルでは, 30 [mm/h]以上の強降雨領域の占める割合が大きくなっている. 時刻 $t_{k,max}$ では JMA と NowCastNet, AFNO-SOLR はいずれもリードタイムが長くなるにつれ強降雨の雨域が北のほうに移動しているが, AFNO-PWVCR, AFNO-PWVPR では流域内に留まっている.

以上から, AFNO の降雨予測精度は境界の影響を考慮し PWV を含めることで JMA の予測精度と同等以上になりうるが, その効果は PWV の予測精度に強く依存することが確認できる.

4. まとめ

本研究では, AFNO 降雨予測モデルを多時刻統合型に拡張することで, 全体として予測精度が改善し, 多くのテスト降雨イベントにおいて 3 時間以上先の予測精度が気象庁 JMA と同等またはそれ以上となることを示し, 6 時間先までの降雨予測に対する有効性を明らかにした. また, AFNO 大気モデルにおいて学習領域を拡張することで, 大気移流の影響を適切に考慮でき, 筑後川流域における PWV の予測精度が向上することを示した. さらに, 降雨予測モデルにおいても学習領域を拡張することで予測精度が向上することが確認された. これらの結果から, 境界に周期性を持たない領域を対象とする




図-9 時刻 $t_{c,max}$ における九州地方の降雨強度分布予測値の比較. 左から JMA, NowCastNet, AFNO-PWVCR, AFNO-PWVPR, AFNO-SOLR による予測分布. AFNO 予測モデルはいずれも広領域の 2018 年検証モデル.




図-10 時刻 $t_{k,max}$ における九州地方の降雨強度分布予測値の比較. 左から JMA, NowCastNet, AFNO-PWVCR, AFNO-PWVPR, AFNO-SOLR による予測分布. AFNO 予測モデルはいずれも狭領域の 2018 年検証モデル.

AFNO モデルでは、境界条件の影響を十分に考慮する必要があることが示された。

線状降水帯が発生した年最大降雨時刻においては、筑後川流域では JMA, NowCastNet および AFNO-SOLR において 3 時間先予測で流域中心付近の降雨強度が低下するのに対し、PWV を入力とした AFNO-PWVCR および AFNO-PWVPR では 25 [mm/h] 以上の強降雨域が維持された。一方、球磨川流域では AFNO-PWVCR において予測精度の改善が確認されたが、AFNO-PWVPR では他モデルと同程度に留まった。これは球磨川流域における PWV 予測精度の低さに起因すると考えられる。以上より、高精度な PWV 予測が線状降水帯の降雨予測精度向上に重要であることが示唆された。

陸上での PWV については、国土地理院 GEONET 基地局で得られる天頂遅延量により可能である。著者らはこれら陸上の PWV に加え、海上の多地点での PWV もひまわり衛星の輝度温度から 10 分程度の遅延での取得が可能であることを示した¹³⁾。今後はデータ同化と組み合わせることでその予測精度の向上が期待される。これにより、河川流域における 6 時間先までの降雨予測精度が向上し、水害リスクの低減に寄与する可能性がある。

一方、AFNO 降雨予測モデルでは、訓練データと検証データの組み合わせにより予測精度が変動することや、イベントごとに JMA に対する優劣が異なることが認められた。特に筑後川流域 ($s=10$) における JMA との比較において、年最大降雨イベントでは予測精度が向上する

一方で、多くの降雨イベントでは3時間以上のリードタイムにおいて予測精度が低下する傾向が認められた。これは、局地客観解析データによる教師データ量の不足により、大気および降雨の多様な特徴が十分に学習されていないことに起因すると考えられる。今後は、転移学習や最良モデル選択手法の導入による精度向上が課題である。

データ駆動型 AI 予測モデルは、大規模数値予報モデルと比較して推論コストが著しく低く、リードタイムの延長による配信遅延の影響が小さい。そのため、リアルタイムでの大規模アンサンブル降雨予測が可能である。実際に、球面 Fourier Neural Operator (SFNO) を用いた全球規模の大規模 AI アンサンブル予測が報告されている¹⁴⁾。今後、メソスケール領域において AFNO を用いた大規模アンサンブル降雨予測モデルを構築することは、河川流域における長時間降雨予測および水害リスク低減に資する重要な課題である。

謝辞：本研究は、内閣府の研究プログラム BRIDGE「革新的な統合気象データを用いた洪水予測の高精度化」の一環として実施されたものである。研究の遂行にあたり、参画研究機関の先生方、ならびに（株）東京建設コンサルタント環境防災研究所の皆様より多くの有益な助言を賜ったことに深く感謝の意を表する。

参考文献

- 1) 赤木宣明, 坂本貴啓, 山本晴彦: 2017年北部九州豪雨災害の特徴的現象からみる河川災害復旧手法の考察, 河川技術論文集, 第24巻, pp.475-480, 2018.
- 2) 田島二仁, 町田佳隆: 水害リスクラインの考え方と活用, 第23回都市水害に関するシンポジウム講演集, pp.19-26, 2024.
- 3) 気象庁: JMAの改善について, 配信資料に関する技術情報, 第675号, 2026年2月.
- 4) Zhang, Y., Long, M., Chen, K., Xing, L., Jin, R., Jordan, M. I., and Wang, J.: Skilful Nowcasting of Extreme Precipitation with NowcastNet, *Nature*, Vol. 619, pp. 526-532, 2023.
- 5) Guibas, J., Mardani, M., Li, Z., Tao, A., Anandkumar, A., and Catanzaro, B.: Adaptive Fourier Neural Operators: Efficient Token Mixers

for Transformers, arXiv:2111.13587v2, 2021.

- 6) Pathak, J., Subramanian, S., Harrington, P., Raja, S., Chattopadhyay, A., Mardani, M., Kurth, T., Hall, D., Li, Z., Azizzadenesheli, K., Hassanzadeh, P., Kashinath, K., and Anandkumar, A.: FourCastNet: A Global Data-driven High-resolution Weather Model using Adaptive Fourier Neural Operators, arXiv:2202.11214v1, 2022.
- 7) 気象庁 情報基盤部: 局地客観解析データを含む客観解析値ユーザーズガイド (users_guide_analysis.pdf) https://www.jmbc.or.jp/jp/offline/info/users_guide/users_guide_analysis.pdf, 令和3年9月.
- 8) 曾田康秀, 成岱蔚, 酒寄千展: 可降水量を考慮したメソスケールでの AFNO 大気・降雨予測モデルの構築, 土木学会論文集, Vol. 82, No. 16, 25-16189, 2026.
- 9) Zhao, N., Manda, A., Guo, X., Kikuchi, K., Nasuno, T., Nakano, M., Zhang, Y., and Wang, B.: A Lagrangian view of moisture transport related to the heavy rainfall of July 2020 in Japan: Importance of the moistening over the subtropical regions, *Geophysical Research Letters*, Vol. 48, e2020GL091441, 2021.
- 10) Dantanarayana, M. M. and Kanae, S.: Machine learning-based postprocessing of NWP precipitable water forecast constraining input features to moisture sources based on atmospheric moisture transport, *Journal of JSCE Special Publication*, 25-16190, 2026.
- 11) Yan, C.W., Foo, S. Q., Trinh, V. H., Yeung, D. Y., Wong, K. H., and Wong, W. K.: Fourier Amplitude and Correlation Loss: Beyond Using L2 Loss for Skillful Precipitation Nowcasting, arXiv:2410.23159v1, 2024.
- 12) Ravuri, S., Lenc, K., Willson, M., Kangin, D., Lam, R., Mirowski, P., Fitzsimons, M., Athanassiadou, M., Kashem, S., Madge, S., Prudden, R., Mandhane, A., Clark, A., Brock, A., Simonyan, K., Hadsell, R., Robinson, N., Clancy, E., Amibas, A., and Mohamed, S.: Skilful precipitation nowcasting using deep generative models of radar, *Nature*, Vol. 597, No. 7878, pp. 672-677, 2021.
- 13) 曾田康秀, 酒寄千展: GNSSおよび衛星輝度温度を用いた AI リアルタイム可降水量推定についての考察, AI・データサイエンス論文集掲載予定, 2026.
- 14) Mahesh, A., Collins, W., Bonev, B., Brenowitz, N., Cohen, Y., Elms, J., Harrington, P., Kashinath, K., Kurth, T., North, J., O'Brien, T., Pritchard, M., Pruitt, D., Risser, M., Subramanian, S., and Willard, J.: Huge ensembles part I: Design of ensemble weather forecasts using spherical Fourier neural operators, *Nature Communications*, Vol. 15, 2024.

(Received March 13, 2026)

(Accepted May 15, 2026)

Application and accuracy evaluation of a multi-temporal integrated AFNO-based rainfall prediction model for river basins in Kyushu

Yasuhide SOTA, Daiwei CHENG and Chihiro SAKAYORI

In recent years, heavy rainfall from line-shaped rainbands has increased, highlighting the need for accurate precipitation forecasts up to 6 hours ahead. We develop a multi-temporal AFNO-based model integrating precipitation and precipitable water vapor (PWV) into channel-wise inputs. Evaluation over the Chikugo and Kuma River basins shows improved accuracy up to 6 hours ahead, particularly when boundary effects are considered and PWV predictions are included. Comparisons with NowCastNet and the JMA short-term forecast demonstrate comparable performance for intense rainfall prediction.