

# 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

曾田 康秀<sup>1</sup>・成 岱蔚<sup>2</sup>・酒寄 千展<sup>3</sup>

<sup>1</sup>非会員 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)

<sup>2</sup>非会員 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

<sup>3</sup>非会員 (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

AFNO(Adaptive Fourier Neural Operator)は Fourier 変換による高速な self-attention 機能を持った深層学習モデルであり、これまでデータ駆動型全球 AI 気象予報モデル FourCastNet で、その有効性が確認されている。一方、線状降水帯のようなメソスケールでのイベントに対する降雨予測に対しては、降雨領域の移流効果を考慮した予測モデルの有効性が知られている。本研究では AFNO をメソスケールでの気象データに適用し、大気・降雨一体型の AI 予測モデルを構築した。AFNO 大気・降雨予測モデルの入力に降雨移流項および可降水量を含めた大気予測項を付与し、損失関数にフーリエ振幅・相関損失(FACL)を用いることで、30mm/h 以上の強降雨領域の 2~3 時間先の線状降水帯発生時の降雨予測精度が向上することが示された。

**Key Words:** deep learning, Neural Operator, rainfall prediction, self-attention, weather forecasting

## 1. はじめに

近年、気候変動の影響により、日本では九州地方を中心に線状降水帯を伴う集中豪雨が多発しており<sup>1)</sup>、水害リスクが増大している。それに伴い、これらの豪雨に対する予測精度の向上が望まれている。短時間の降雨の予測においては、ナウキャストのような降雨移流モデルが有効であるが、数時間先での予測精度の低下が課題である。実際、Kato<sup>2)</sup>らは線状降水帯の発生に水蒸気フラックスや相当温位、風速の鉛直シアなどの大気の状態が強く影響していることを示している<sup>2)</sup>。また数値予報モデルでは、水蒸気や風速、気温の観測を同化することにより、予測精度が向上することが示されている<sup>3)</sup>。数値予報モデルでは、予測の信頼度を高めるために、複数の初期条件によるアンサンブルを用いた降雨予測も行われている。アンサンブル予測では初期条件を変えた大量の数値計算が必要なため、観測量による同化も含めたリアルタイム

での予測に対しては、計算コストの低減が課題となっている。

一方、近年では大規模な数値予報に代わり、大量の観測データや再解析データを学習させることにより得られるデータ駆動型 AI 気象予報モデルが進展している。降雨領域の移流・生成・消滅の過程を大量に学習させた NowcastNet<sup>4)</sup>や大気データの予測を降雨予測と組み合わせた FourCastNet<sup>5)</sup>では、推論時に従来の数値気象予報モデルよりもはるかに少ない計算コストで同等以上の予測精度を上げることが報告されている。

降水量予測に関しては、CNNやLSTMおよびそれらを組み合わせた Convolutional LSTM モデルなど、これまでさまざまな AI モデルが提案されている<sup>6)</sup>。CNN ベースのモデルは、局所的な空間相関を捉えるのには適しているが、空間的に離れた点の間の大域的な特徴を捉えるのが課題となっている。

一方、近年、大規模言語モデルにおいて self-attention




図-1 九州地方対象領域.

機構を効果的に取り入れた Transformer<sup>9)</sup>の有効性が広く認められている。self-attention とは、入力テキストをトークン単位に分割し、各トークンが他の全トークンにどの程度注目すべきかを計算することで、文脈に応じた意味表現（ベクトル）を生成する仕組みである。この手法は画像処理の分野にも応用されており、画像をトークン化して領域間の self-attention を行うことで、高精度な認識が可能になることが報告されている<sup>9)</sup>。気象予測においても、self-attention 機構を組み込んだ手法が提案されている<sup>10)</sup>。

また、さまざまな初期条件に対する数値計算の解を高速に取得する AI 手法として、Neural Operator<sup>11)</sup>が提案されている。Neural Operator の一つである Fourier Neural Operator (FNO) および、FNO に柔軟性を持たせた Adaptive Fourier Neural Operator (AFNO)<sup>12)</sup>は、高速フーリエ変換 (FFT) を用いて空間的な依存関係を効率的に学習する手法であり、Transformer の self-attention と類似した役割を果たしつつ、学習時の計算コストを大幅に低減できる利点を有する。実際、FourCastNet では、欧州中期気象予報センター (ECMWF) が提供する再解析データセット (ERA5) に AFNO を適用することで、全球スケールでの気象データの空間的特徴を高精度に捉えることに成功している<sup>9)</sup>。さらに AFNO は、ConvLSTM ベースの self-attention モデルと比較してネットワーク構築が相対的に容易であるという実装上の利点も有する。

以上の点から AFNO を用いた気象予測モデルは、線状降水帯の予測に必要なメソスケールでの予測にも有用であることが示唆される。日本におけるメソスケールの再解析データとしては、気象庁のメソ客観解析や局地客観解析データが公開されており、気象支援センターなどを通して入手が可能である。特に局地客観解析データは 1 時間間隔 5Km メッシュでの時空間解像度であるため、線状降水帯のようなメソスケール以下の気象予測に適していると考えられる。降雨の予測では水蒸気量の情報が有効であるが、リアルタイムの予測では、現時刻までの

再解析データからは入手できず、現時刻までの水蒸気量の空間分布の情報を取得することは困難である。一方、水蒸気量の鉛直方向の総和である可降水量は、GEONET による天頂遅延量や気象衛星の輝度温度の分布からリアルタイムに推定することが可能である<sup>13)</sup>。よって、AI による大気・降雨予測モデルにおいても説明変数として、可降水量を用いた場合の予測精度を検証することは実用面においても重要であると考えられる。

以上の点を踏まえ、本研究では、気象庁の局地客観解析データから可降水量を構築し、可降水量を含めた大気データを教師データとして、AFNO 大気予測モデルを構築する。長時間予報を目的とした FourCastNet では、同時刻の大気の状態だけから降雨予測を行うが、メソスケールでの数時間程度の予測では、降雨の移流の情報が重要である。以上から本研究では AFNO 降雨予測の入力に移流項を加え、降雨移流モデルでの有効性が認められているフーリエ振幅・相関損失 (FACL)<sup>14)</sup> を学習の誤差関数に用いることでの降雨予測精度がどの程度向上するかを検討する。

## 2. AFNO 深層学習における教師データの構築

本研究では、西側をライダーなどの観測データが取得できる福江島とする、九州地方 [30.9350 - 34.0186°N, 128.4852 - 132.1657°E] を対象領域とした (図-1)。また大気・降雨予測の教師データとしては 2018 年から 2024 年までの気象庁局地客観解析データおよび気象庁解析雨量の正時データを用いた。AI モデルの教師データ構築のために、HRA (Heavy rainfall areas) 候補を特定するための基準<sup>15)</sup>から、各年の 4 月から 11 月の範囲で、以下の条件を少なくとも 1 つ満たす時刻を抽出した。

- (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。

(i) においては、先行研究の基準に対して該当するメッシュが領域に点在している場合を考慮した緩い基準になっている。抽出した時刻から前 24 時間、後 12 時間の期間をイベント期間とし、期間の重複が見られた場合は結合し 1 つのイベント期間とした。また各イベント期間内で、対象領域を 2 のべき乗となる (128 × 128) のメッシュ点に分割し、気象データの値を空間内挿で各メッシュ点上に割り当てて教師データを構築した。可降水量の構築には、OpenTopography<sup>16)</sup> の API を通じて「AW3D30」データセットを取得することで、約 30 メートルの空間解像度を持つ標高データを取得し、内挿補間により、局地客観解析データメッシュ点上の値を割り当てた。またこれ

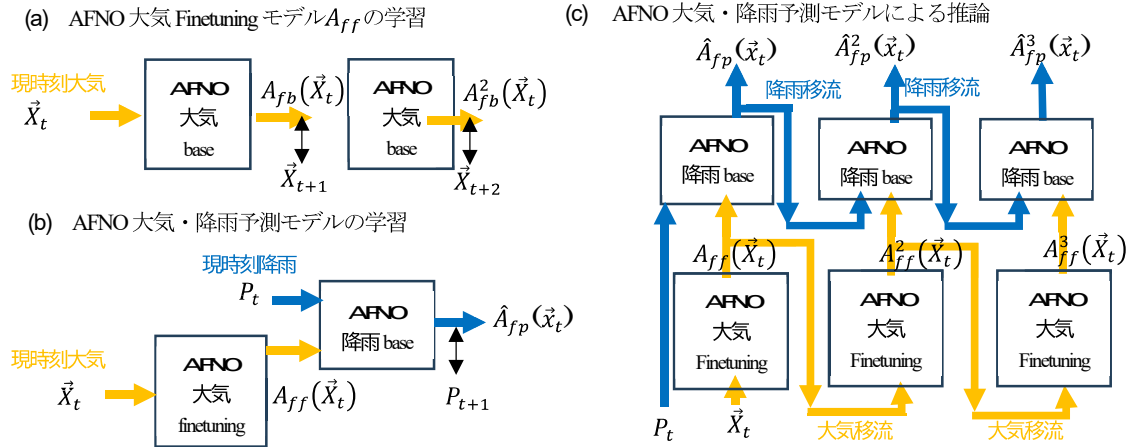


図-2 学習時、推論時における AFNO モデルのネットワーク構造

を客観解析データの海面更正気圧と組み合わせて地表面気圧を求め、局地客観解析データの各等圧面での相対湿度および気温から、以下の式で可降水量を求めた<sup>1)</sup>。

$$PW \approx \sum_{i=0}^N \frac{(W_i + W_{i+1})}{2g} (P_i - P_{i+1}) \times 10^3 \quad (1)$$

ただし  $g$  は重力加速度 ( $9.8[m/s^2]$ ) で、 $W_i, P_i$  はそれぞれ、 $i$  番目気圧面での水蒸気混合比 [ $g/Kg$ ] および気圧 [ $hpa$ ] であり、水蒸気混合比は同気圧面での気温、相対湿度で決まる<sup>1)</sup>。

以下では大気データ学習用の説明変数として、FourCastNet 同様に地上面での気温、風速、海面更正気圧、500hpa および 850hpa の気温、風速、ジオポテンシャル高度を用いた。これらは気象庁 30 分再解析データでリアルタイムに取得できる。一方、リアルタイムに取得できない相対湿度の代わりに、上で取得した可降水量を加え、合計 13 個の大気データを大気予測モデルの説明変数とした(表-1)。

### 3. AFNO モデル構築

#### (1) AFNO 大気予測モデル

以下では、各説明変数の ( $128 \times 128$ ) のメッシュ点上での各時刻での値を画像データの 1 チャンネルとみなし AFNO 予測モデルでの学習を行う。FourCastNet と同様、AFNO モデルの入力層と出力層の間には、AFNO ブロック層があり、各入力データは、 $4 \times 4$  の小パッチに分割された後、各パッチごとに埋め込みベクトル (トークン) に変換される<sup>9)</sup>。変換後の  $32(=128/4) \times 32(=128/4)$  のベクトルの組が各成分ごとに Fourier 変換され、空間情報が mixing される。Fourier 空間上で他の深層学習と同様、重みおよび活性化関数が作用された後に、逆 Fourier 変換で

実空間に戻され、ブロック層の出力層で埋め込み次元から元の入力データと同じ次元に変換される。AFNO では Fourier 変換および逆 Fourier 変換に FFT を用いることで高速にトークン間の self-attention 機能を実現できる<sup>12)</sup>。以下では、3 層の AFNO ブロックから成る大気予測モデルを AFNO 大気 base モデルと呼ぶ。

以下では訓練データに対する最大値と最小値を用いて各説明変数の値を正規化し、入力値を各時刻  $t$  での正規化された大気データ  $\vec{x}_t$ 、出力値を 1 時間後の大気データ  $\vec{x}_{t+1}$  とする。バッチサイズを 16 とし、学習の損失関数 (loss) に出力値と正解値 (ラベル) との平均二乗誤差 (MSE) を用い、AFNO 大気 base モデルに対して深層学習を行った。具体的には、2018 年から 2023 年までのデータのうち、1 年分を検証用、残りの年のデータを訓練用とした 5 ケースに対して、GPGPU による深層学習を行った。また検証用データが過学習を起こすと判定された段階で早期終了で学習を完了させて AFNO 大気 base モデルを学習した。次に FourCastNet<sup>9)</sup> と同様、2 時刻分の大気データ  $\vec{x}_{t+1}, \vec{x}_{t+2}$  を正解値 (ラベル) として、同様の手続きで base モデルを再学習し AFNO 大気 finetuning モデル  $A_{ff}$  を構築した(図-2(a))。

表-1 AFNO 大気モデルの説明変数

地上面	気温、水平風速 (2 成分)、海面更正気圧
500hPa	気温、水平風速 (2 成分)、ジオポテンシャル高度
850hpa	気温、水平風速 (2 成分)、ジオポテンシャル高度
others	可降水量

#### (2) AFNO 大気・降雨予測モデル

FourCastNetにおけるAFNO降雨予測モデルでは、入力層に、同時刻での大気予測モデルの出力値 $\vec{X}_{t+1}$ が用いられる。従って、現時刻の降雨データは入力されず、降雨の移流の効果が反映されない。一方、我々はメソスケールでの数時間先までの予測を考慮するので、AFNOの入力層に、150 mm/hで正規化された時刻 $t$ での降雨データ $P_t$ を加え、AFNOの降雨baseモデル $A_{fp}(P_t, \vec{X}_{t+1})$ を構築する。ただし学習時に、1時刻後の大気データは、現時刻の大気データ $\vec{X}_t$ の $A_{ff}$ による出力値 $A_{ff}(\vec{X}_t)$ を用いる。以下では、 $\vec{x}_t \equiv (P_t, \vec{X}_t)$ としてAFNO大気・降雨モデルの出力を

$$\hat{A}_{fp}(\vec{x}_t) \equiv A_{fp}(P_t, A_{ff}(\vec{X}_t)) \quad (2)$$

と表記する。AFNO大気・降雨モデルの学習では、各時刻で $\hat{A}_{fp}(\vec{x}_t)$ に対するラベルを $P_{t+1}$ として深層学習を行う(図-2(b))。学習時には大気baseモデルと同じネットワーク構造とバッチサイズを用い、lossには移流モデルの学習に有効であるフーリエ振幅・相関損失(FACL)を用いた<sup>14)</sup>。FACLでは、学習の前半にフーリエ相関損失(FCL)、後半にフーリエ振幅損失(FAL)が用いられ、学習ステップ $\mu$ での損失関数は以下の式で与えられる。

$$\text{loss} = \text{FACL}(\hat{A}_{fp}(\vec{x}_t), P_{t+1}, \mu) = \begin{cases} \text{FAL}(\hat{A}_{fp}(\vec{x}_t), P_{t+1}), & \text{if } p > P(\mu) \\ \text{FCL}(\hat{A}_{fp}(\vec{x}_t), P_{t+1}), & \text{otherwise} \end{cases} \quad (3)$$

ただし、 $p$ は $[0,1]$ 区間の一様乱数、 $P(\mu)$ は非負の単調減少関数である。

大気・降雨モデルの推論時には、1時刻後の降雨予測値 $\hat{A}_{fp}(\vec{x}_t)$ および2時刻後の大気予測値 $A_{ff}^2(\vec{X}_t)$ を $A_{fp}$ の入力に用いて2時刻後の降雨予測値 $\hat{A}_{fp}^2(\vec{x}_t)$ を取得する。同様に、 $\hat{A}_{fp}^2(\vec{x}_t)$ および $A_{ff}^3(\vec{X}_t)$ を $A_{fp}$ の入力に用いて、3時刻後の降雨予測値 $\hat{A}_{fp}^3(\vec{x}_t)$ を取得する(図-2(c))。以上の手続きを繰り返せば、任意の時刻 $n$ までの降雨予測値 $(\hat{A}_{fp}(\vec{x}_t), \hat{A}_{fp}^2(\vec{x}_t), \dots, \hat{A}_{fp}^n(\vec{x}_t))$ を取得することが可能である。

#### 4. 解析結果

本研究では、2018年から2023年までの教師データのうち、2018年から2022年までのいずれか一つの年のデータを検証用とし、残りの年のデータを訓練用とした5ケースについて、3時間先までのAFNO大気・降雨予測モデルを構築した。また学習後のモデルに対する予測精度を検証するために、九州北部で線状降水帯が発生した期間を含む2024年7月12日00:00から2024年7月16日00:00までの期間をテスト期間として選択した。AFNO

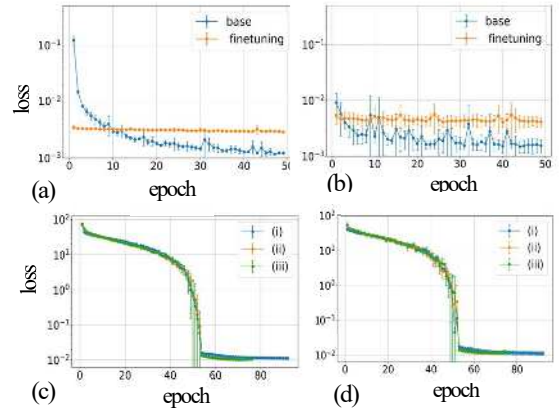


図-3 予測モデル学習曲線の5ケース平均値。(a)大気モデル訓練、(b)大気モデル検証、(c)大気・降雨モデル訓練、(d)大気・降雨3モデル検証。誤差棒は5ケースのstd。

大気・降雨予測モデルの降雨予測精度は、AFNO大気finetuningモデルによる大気予測の精度と、AFNO降雨baseモデルの精度の両方に依存する。以下では、これらを検証するために、以下の3モデルを学習・構築した。

- (i) AFNO降雨baseモデルの入力を $P_t$ のみとする。
- (ii) AFNO降雨baseモデルの入力層に降雨データの正解値 $P_t$ と大気データの正解値 $\vec{X}_{t+1}$ を用いる。
- (iii) AFNO降雨baseモデルの入力層に降雨データの正解値 $P_t$ とAFNO大気finetuningモデルによる予測値 $A_{ff}(\vec{X}_t)$ を用いる。

(i)はNowcastNetに、降雨の移流のみを考慮したものであり、(ii)は大気データの予測が完全に観測量と一致する理想的な場合を想定している。(iii)は図-2(b)のAFNO大気・降雨モデルで、大気データの予測精度が高いほど、降雨の予測精度が(ii)に近づく予想される。

##### (1) AFNO大気・降雨予測モデルの深層学習

AFNO大気モデルの5ケース平均に対する50エポックまでのbaseおよびfinetuningでの学習曲線の振る舞いは図-3(a), (b)のようになる。訓練データでのlossは、baseでは急速に小さくなるが、finetuningではbaseの学習済みモデルを再学習させているため、緩やかに減少している。finetuningでは2時刻の誤差を評価しているため、最小誤差はbaseよりも大きくなる。

AFNO大気・降雨予測モデルで、最大エポック数を100とし、 $\mu_{max} \equiv \text{最大エポック数} \times \text{バッチ数}$ 、 $P(\mu) \equiv \max[0, 1 - 2\mu/\mu_{max}]$ とした場合の、学習曲線の5ケース平均の振る舞いは図-3(c), (d)のようになる。式(3)のFACLは、 $P(\mu)$ の定義から、前半の50エポックまではFCLが優位となり、後半の50エポックでFALが優位になっている。また検証データでのlossも訓練データでのlossと同様に十分に小さくなることが確認できる。




図4 AFNO 大気 finetuning モデルによる可降水量予測値。赤線はゾンデ観測による可降水量、黒の実線、点線、一点破線はそれぞれ1, 2, 3時間後の可降水量予測値の観測点への内挿。いずれも9時, 21時の値を直線で結んでいる。

### (2) AFNO 大気 finetuning モデルの検証

AFNO 大気 finetuning モデルの予測精度を検証するために、気象庁福岡観測点(33.5833 N, 130.3833°E)でのテスト期間内の各日での  $t = 9$ 時,  $21$ 時のラジオゾンデ高度観測から式(1)によって得られた可降水量と、時刻  $t$  に対する AFNO 大気 finetuning モデルの予測値  $\{A_{ff}^s(\vec{x}_{t-s})\}_{s=1,2,3}$  の可降水量成分とを比較する。AFNO 大気 finetuning モデルでの1から3時間後の可降水量の予測値は、ゾンデ観測による値と同様、線状降水帯の発生時に向けて上昇傾向を示していることが確認できる(図-4)。

### (3) AFNO 大気・降雨予測モデルの検証

まず AFNO 大気・降雨予測モデルによる予測精度を検証するために、線状降水帯が熊本で発生した2024年7月15日5:00の3時間前における降雨分布の予測精度を5ケースで比較した(図-5)。図-5の最上段右端が基準時刻7月15日2:00の降雨分布の正解値、2段目が基準時刻から1~3時間後の正解値を表し、7月15日5:00には熊本県で40mm/h以上の強雨が確認できる。3段目以降がケース1から5までの3時間先までの予測分布を表す。範囲や強度はケースごとに異なるが、いずれのケースでも3時間先までに熊本県で強雨領域が確認できる。

次に、対象期間における3モデルの予測精度を比較するため、各メッシュ点で降雨量が閾値  $R_{cr}$  を超えるか否かを正解値および予測値に基づいて判定し、両者の一致度を以下の臨界成功指数 (CSI) により評価する。

$$CSI \equiv \frac{TP}{TP + FN + FP} \quad (4)$$

ここで、 $TP$  (真陽性) は正解値・予測値の両方が  $R_{cr}$  以上となったメッシュ点数、 $FN$  (偽陰性) は正解値が閾値以上で予測が閾値未満、 $FP$  (偽陽性) はその逆を示

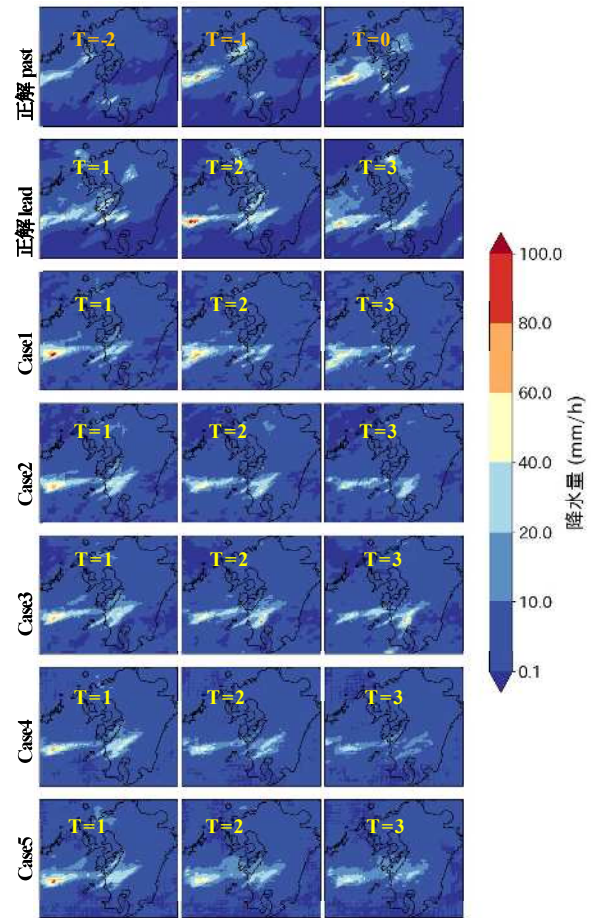


図-5 AFNO 大気・降雨予測モデル(iii)による線状降水帯の検証。最上段右端が基準時刻7月15日2:00での降雨分布、2段目が予測時刻の正解値。3段目以降は、ケース1からケース5のモデルによる予測値。各列の最上段は、左から基準時刻の2,1,0時間前、2段目以下は、左から基準時刻の1,2,3時間後の降雨分布を表している。

す。 $CSI$ は  $TN$  (真陰性) を考慮しない指標であり、 $TP$  の割合が多いほど1に近づく。 $R_{cr} = 10.30[\text{mm/h}]$ とした場合の1時間前から3時間先までの予測に対する3モデルでの  $CSI$  の結果を図-6に示す。図-6で  $R_{cr}$  を超えるメッシュがない時刻では、 $CSI$  の値は0としている。また、図-6の各点は5ケースの平均値を表し、誤差棒は5ケースでの最小値から最大値の範囲を示している。また、線状降水帯が(A)長崎県五島、(B)熊本県で発生した期間をそれぞれ橙色、灰色で示している。

図-6(a),(c),(e)はそれぞれ  $R_{cr} = 10[\text{mm/h}]$ での1時間前から3時間先までの予測に対する  $CSI$  を表している。線状降水帯発生期間(A),(B)での  $CSI$  は、1時間先では3モデルで大きな差はなく、0.4~0.6程度となっているが3時間先では0.2~0.3となる。この結果をKimらによるCNNでの  $R_{cr} = 1.0[\text{mm}/10\text{min}]$ での結果<sup>6)</sup>と比較すると、CNNでは東京、大阪、京都3地点でのテストケースでの30分後予測の  $CSI$  はいずれも0.4未満となっており、本

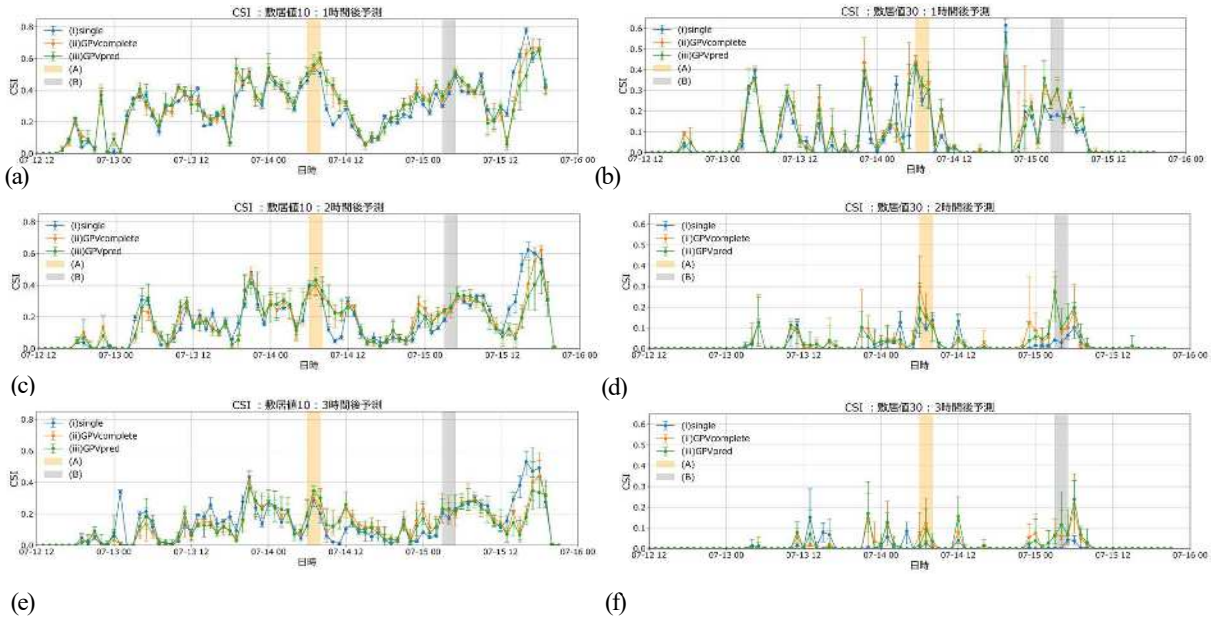


図-6 AFNO 大気・降雨予測モデル降水量予測の CSI. (a)  $R_{cr} = 10[mm/h]$ , 1 時間後, (b)  $R_{cr} = 30[mm/h]$ , 1 時間後, (c)  $R_{cr} = 10[mm/h]$ , 2 時間後, (d)  $R_{cr} = 30[mm/h]$ , 2 時間後, (e)  $R_{cr} = 10[mm/h]$ , 3 時間後, (f)  $R_{cr} = 30[mm/h]$ , 3 時間後. 橙色および灰色の帯は、それぞれ線状降水帯が(A)長崎県五島, (B)熊本県で発生した期間を表す.

研究での線状降水帯発生時の 1 時間後予測結果はこれを上回っている.

図-6(b),(d),(f)は、それぞれ  $R_{cr} = 30[mm/h]$ での 1 時間先から 3 時間先までの予測に対する CSI を表している. この場合、期間(A)の 1 時間先予測は、3 モデルいずれも 0.3~0.4 程度となっているが、期間(B)の 1 時間先予測では、大気データを含むモデル(ii),(iii)で 0.3 程度なのに対し、降雨データのみモデル(i)では、0.2 程度と低くなっている. この CSI の差は 2 時間先、3 時間先の予測ではより顕著になり、モデル(ii),(iii)では 0.1~0.2、モデル(i)では 0.05 未満となる. 以上から予測時間が長くなるほど、降雨のみでの予測精度の低減は顕著になり、大気による精度向上の寄与が大きくなる. これは予測時間が長くなるにつれ、大気の状態による積乱雲の発生に伴う強降雨領域への発生確率が高くなり<sup>2)</sup>、単純な移流だけでは予測が困難となるためであると考えられる.

(4) 推論に掛かる計算コスト

学習後の予測モデルの推論に要する時間の検証に対しては、CPU として AMD Ryzen™ Threadripper™ PRO 5975WX (ベースクロック 3.6GHz, 32 コア) を搭載した Linux マシンで 32 コアを利用した場合と 1 コアのみで計算した場合の 1 時刻分の予測に対する CPU 計算時間を比較した. 表-2 のように、降雨のみの場合はコア数に依らず 0.1 秒程度であり、大気データを含めた場合でも、1 コア 1 秒程度で推論が完了することが確認できた (表-2).

5. 結び

本研究では、AFNO を用いて可降水量を含めたメソスケールでのデータ駆動型 AI 大気・降雨予測モデルを構築した. AFNO 大気予測モデルでは、3 時間先までの予測で、線状降水帯発生時の水蒸気上昇を再現できることが示された. また降雨予測モデルに大気データを含めることで、強降雨条件での 2~3 時間先までの降雨予測精度が改善されることが確認できた. 本研究での AFNO 学習済みモデルでの推定に要する時間は CPU を用いて数秒以内であるので、予測精度の改善により、データ同化を考慮した降雨予測をリアルタイムで運用することが可能になると期待できる.

一方で、降雨予測精度は教師データの組み合わせによるケースごとの差異が顕著となった. これは局所客観解析データが 6 年分しか利用できないのが一因と推測される. 気象庁メソ客観解析データは 2001 年から提供されており、これらの事前学習およびその転移学習により、予測精度を向上させられる可能性がある. また、AFNO 降雨予測では、1 時刻モデルを繰り返すため、複数時刻の予測で予測誤差の蓄積が顕著になる. 実際、強降雨判

表-2 AFNO 1 時刻降雨予測に要する平均 CPU 計算

	32 コア	1 コア
(i)降雨のみ	0.101sec	0.09sec
(ii)降雨+PWV	0.409sec	0.748sec
(iii)降雨+全大気	0.499sec	1.14sec

定のCSIの値は予測時間が長くなるにつれて、大きく減少している。よって AFNO 大気モデルを Nowcastnet のような降雨移流モデルと組み合わせるなど、降雨予測精度の改善が課題となる。また、今回は1時間間隔の降雨データを用いたが、時間分解能を高められれば、線状降水帯の予測精度をさらに向上させられることが期待できる。大気データにおいては衛星による水蒸気量観測の空間分解能や観測頻度も今後上昇していくと考えられるため、それに合わせたモデルの精度向上が今後の課題となる。

## REFERENCES

- 1) Hatsuzuka, D., Kato, R., Shimizu, S. and Shimose, K.: NOTES AND CORRESPONDENCE Verification of Forecasted Three-Hour Accumulated Precipitation Associated with “Senjo-Kousuitai” from Very-Short-Range Forecasting Operated by the JMA, *Journal of the Meteorological Society of Japan*, Vol. 100, Issue 6, pp. 995–1005, 2022.
- 2) Kato, T.: Quasi-stationary Band-Shaped Precipitation Systems Named “Senjo-Kousuitai” Causing Localized Heavy Rainfall in Japan, *Journal of the Meteorological Society of Japan*, Vol. 98, Issue 3, pp. 485–509, 2020.
- 3) 二宮 洗三：数値予報の基礎知識，オーム社，2004. [Ninomiya, K.: *Suuchi Yoho no Kiso Chishiki*, Ohmsha, 2004.]
- 4) Zhang, Y., Long, M., Chen, K. et al.: Skilful Nowcasting of Extreme Precipitation with NowcastNet, *Nature*, Vol. 619, pp. 526–532, 2023.
- 5) Pathak, J., Subramanian, S., Harrington, P. et al.: FourCastNet: A Global Data-driven High-resolution Weather Model using Adaptive Fourier Neural Operators, arXiv:2202.11214v1, 2022.
- 6) Kim, S., Suzuki, T. and Tachikawa, Y.: Rainfall Occurrence Prediction with Convolutional Neural Network, *Annual Journal of Hydraulic Engineering*, Vol. 76, pp. I\_379–I\_384, 2020.
- 7) Rahimi, R., Ravirathinam, P., Eftehaj, A. et al.: Global Precipitation Nowcasting of Integrated Multi-satellite Retrievals for GPM: A U-Net Convolutional LSTM Architecture, *Journal of Hydrometeorology*, Vol. 25, Issue 6, pp. 947–963, 2024.
- 8) Vaswani, A., Shazeer, N., Parmar, N. et al.: Attention is All You Need, *In Advances in Neural Information Processing Systems*, pp. 5998–6008, 2017.
- 9) Dosovitskiy, A., Beyer, L., Kolesnikov, A. et al.: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, *In Advances in Neural Information Processing Systems*, Vol. 34, pp. 16200–16212, 2021.
- 10) Ji, C. and Xu, Y.: trajPredRNN+: A new approach for precipitation nowcasting with weather radar echo images based on deep learning, *Helixyon*, Vol. 10, Issue 18, e36134, 2024.
- 11) Kovachki, N. B., Li, Z., Liu, B. et al.: A Neural Operators: Learning Maps between Function Spaces, *Acta Numerica*, Vol. 32, pp. 71–230, 2023.
- 12) Guibas, J., Mardani, M., Li, Z. et al.: Adaptive Fourier Neural Operators: Efficient Token Mixers for Transformers, arXiv.2111.13587v2, 2021.
- 13) 赤塚 慎，遠藤 貴宏，安岡 善文：衛星画像と GPS を用いた陸域可降水量分布の推定，*生産研究*，Vol. 58, pp. 343–346, 2006. [Akatsuka, S., Endo, T. and Yasuoka, Y.: Estimation of Precipitable Water Distribution over Land Using Satellite Images and GPS, *SEISAN KENKYU*, Vol. 58, pp. 343–346, 2006.]
- 14) Yan, C. W., Foo, S. Q., Trinh, V. H. et al.: Fourier Amplitude and Correlation Loss: Beyond Using L2 Loss for Skillful Precipitation Nowcasting, arXiv.2410.23159v1, 2024.
- 15) Hirokawa, Y., Kato, T., Tsuguti, H., and Seino, N.: Identification and Classification of Heavy Rainfall Areas and their Characteristic Features in Japan, *Journal of the Meteorological Society of Japan*, Vol. 98, Issue 4, pp. 835–857, 2020.
- 16) Krishnan, A. K. et al.: OpenTopography: A cyberinfrastructure-based data facility for topographic data. *Earth Science Informatics*, <https://opentopography.org/>, 2022.
- 17) 西村 昌明，内藤 勲夫，岩淵 哲也，里村 幹夫：GPS とラジゾンデから推定される可降水量の相互比較，*静岡大学地球科学研究報告*，Vol. 29, pp. 61-75, 2002. [Nishimura, M., Naito, I., Iwabuchi, T. and Satomura, M.: A Comparison of Precipitable Water Vapor Obtained from GPS and Radiosond, *Geosci Repts Shizuoka Univ.*, Vol. 29, pp. 61-75, 2002.]

(Received May 30, 2025)

(Accepted September 18, 2025)

## DEVELOPMENT OF A MESOSCALE ATMOSPHERIC AND PRECIPITATION PREDICTION MODEL USING AFNO WITH CONSIDERATION OF PRECIPITABLE WATER VAPOR

Yasuhide SOTA, Daiwei CHENG and Chiro SAKAYORI

The Adaptive Fourier Neural Operator (AFNO) is a deep learning model with self-attention based on Fourier transforms, whose effectiveness has been demonstrated in data-driven global AI weather forecasting models such as FourCastNet. Meanwhile, for rainfall prediction of mesoscale events such as linear precipitation bands, models that account for the advection of rainfall regions have proven to be effective. In this study, we applied AFNO to mesoscale meteorological data and constructed an integrated atmospheric–precipitation AI forecasting model. By incorporating rainfall advection terms and atmospheric predictors including precipitable water vapor into AFNO input, and by employing the Fourier Amplitude and Correlation Loss (FACL) as the loss function, we demonstrated the forecast accuracy for intense rainfall areas exceeding 30 mm/h associated with linear precipitation bands, up to 2–3 hours ahead.