

数値気象モデルにおける移流のニューラル場表現

柳 龍哉[†] 藤村 友貴[†] 向川 康博[†] 安永 数明^{††}

久保 尋之^{†††} 岡崎 淳史^{†††} 小槻 峻司^{†††} 船富 卓哉^{†,†††}

[†] 奈良先端科学技術大学院大学

^{††} 富山大学

^{†††} 千葉大学

^{††††} 京都大学

あらまし 本研究では、豪雨発生メカニズムの理解に向けて、数値気象モデルにおける物理量の可視化を目指す。数値気象モデルの出力は時空間座標上の膨大なデータで構成されており、その効率的な処理にはデータ圧縮と高精度な補間が求められる。そこで、膨大なデータを効率的に圧縮しつつ高精度に補間することを目的として、ニューラル場を用いた連続関数表現を提案する。特に、回転および並進を表現可能な幾何変換のニューラル場を導入し、複雑な移流場を効率的に表現した。線形補間と比較した結果、提案手法はデータサイズを約1%に圧縮しつつ同等以上の精度を達成し、全結合ニューラルネットワークに対しても精度の優位性を確認した。

キーワード 数値気象モデル, 連続関数表現, データ圧縮, 幾何変換場, ニューラル場

1. 緒 論

豪雨の発生メカニズムを理解することは、気象予測精度の向上や災害リスクの低減に直結する重要な課題である。例えば、降雨を誘発するクラウドシーディングを海上で実施することで陸域での豪雨被害を軽減する取り組みが検討されているが、その適切な場所やタイミングを判断するためには、豪雨の発生過程に対する深い理解が不可欠である [1]。こうした理解に資する基盤として、観測を用いたデータ同化を行う数値気象モデルが広く利用され、大気中のさまざまな物理量が現実に応じて推定されている [2]。しかし、その出力は空間のグリッドごとに与えられる膨大な離散データであり、時間的・空間的に連続する現象を直接的に把握することは難しい。特に、豪雨形成過程で重要となる移流は、雲の発達など物理量の時間発展を直感的に理解する上で鍵となるため、これを連続的に捉える表現が求められる。本研究では、この移流を対象として、膨大なグリッドデータを効率的に圧縮しつつ高精度に補間することを目的とする。移流はグリッドごとに与えられる離散的なベクトル場であり、混合比や温度といったスカラー場とは異なる扱いが必要である。そこで本研究では、幾何変換を用いたニューラル場による連続関数表現の獲得を提案する。

2. 関連研究

気象分野で扱う現象には移流をはじめとする複雑な時空間変化が含まれており、その理解や可視化には連続的で滑らかな表現が欠かせない。特に降雨の発生や発達を支配する移流を正しく表すには、4次元(3次元空間+時間)の連続的に変化するデータを用いて、空間的变化を滑らかに捉える方法が必要となる [3]。

流体分野では、速度場を連続関数として学習する試みが数多く行われており [4]~[6]、計算を高速化したり将来予測を改善したりする成果が報告されている。しかし、これらの研究は主としてシミュレーションや予測の改善を目的としており、大規模な4次元データを大幅に圧縮しつつ高精度に補間する問題を直接扱ったものは少ない。

一方、コンピュータビジョンやグラフィックスの分野では、オプティカルフローやシーンの変形を表すベクトル場をニューラルネットワークで連続的に表現する研究が行われている [7]~[9]。ただし、これらは視覚的な一貫性を重視したものであり、物理的意味を持つ移流の表現には必ずしも適さない。

こうした背景のもと、本研究では「幾何変換場」に注目する。幾何変換場は、局所的な剛体変換を組み合わせることで非剛体変形を滑らかに表す枠組みである。船富ら [10] は2次元画像の位置合わせに幾何変換場を導入し、単純なベクトル場よりも複雑な非剛体変形を簡潔に表現できることを示した。本研究はこの枠組みをニューラルネットワークで拡張し、基底変換とその合成重みを学習することで、4次元気象データにおける移流の高圧縮と高精度補間の両立を図るものである。

3. 提案手法

本研究では、数値気象モデルから得られる空間座標 $\mathbf{x}_m = (x_m, y_m, z_m)$ と時刻 t_m を入力とし、その点に対応する幾何変換 $\mathbf{Y}_m \in \text{Sim}(3)$ を推定するニューラル幾何変換場を構築する。モデルは、推定した幾何変換 $\mathbf{Y}(\mathbf{x}_m, t_m)$ を空間座標 \mathbf{x}_m に対して適用した結果が、数値気象モデルから得られた各グリッド上における風速成分 $(U_{met_m}, V_{met_m}, W_m)$ で移流させた位置 $\mathbf{x}' = (x_m + U_{met_m}, y_m + V_{met_m}, z_m + W_m)$ と一致するように学習される。

3.1 ニューラル幾何変換場 [11] とその問題点

石原ら [11] は、 K 個の基底変換 $\{c_1, c_2, \dots, c_K\} \subset \text{Sim}(3)$ の重み付き合成によって幾何変換のニューラル場をモデル化する手法を提案した。ここで、基底変換の合成重み $\mathbf{W} = (w_1, w_2, \dots, w_K) \in \mathbb{R}^K$ の決定には、時空間座標を入力とする多層パーセプトロン (MLP) を用いる。また、幾何変換の重み付き合成には様々な方法があるが、指数重心 (Exponential barycenter) [12] の定式化が用いている。ただし、指数重心は閉形式では求まらない。そこで石原ら [11] は、指数重心の定式化による幾何変換の合成方法として、Iterative Blending (IB) [13] を用いている。これは、係数 \mathbf{W} と基底変換 \mathbf{C} から幾何変換 q を合成する方法であり、 $\sum_i w_i \text{Log}_q(c_i) = 0$ を満たす指数重心 q を反復的に求めている [12]。具体的には、 j 番目の反復において、各基底 c_i を q_j を接点とした対数写像により接空間へ写像し (図 1)、その線形結合 $\alpha \sum_i w_i \text{Log}_{q_j}(c_i)$ を指数写像で幾何変換が成す多様体に戻すことで次の更新点 q_{j+1} を得る。初期値を q_0 (例えば恒等変換) として、 $\sum_i w_i \text{Log}_{q_j}(c_i)$ のノルムが閾値以下に収束するまで反復を行う (Algorithm 1)。ここで α は減衰率であり、また w_i が非負でない場合には収束が保証されない。

しかし、ニューラルネットワークの学習の各ステップにおいて、収束判定を伴う繰り返し演算による幾何変換の合成手法を用いると、誤差逆伝播の計算において不都合となる。そこで石原ら [11] は、恒等変換を初期値として予め定めた回数だけを繰り返す Deep Unrolling と呼ばれる近似法を取っていた。しかし、固定回数の繰り返しでは指数重心の計算で収束の保証がなく、適切な学習を妨げる恐れがある。

3.2 幾何変換の事前推定

一方、推論結果として出力すべき幾何変換を与えることができれば、繰り返し演算を介さずに適切な損失関数を設計することが可能である。そこで本手法では、各サンプル点に対し、その隣接グリッドでの移流成分からサンプル点での幾何変換を推定し、これを教師信号として用いる。

本研究では幾何変換として、等角性を保持する相似変換 $\text{Sim}(3)$ を用いることとし、Umeyama [14] の手法に基づき、移流前後の座標の対応関係から各グリッドにおける相似変換を事前に推定する。これにより学習時には、推定された変換の接空間上で基底変換と重みの合成結果を直接評価することができるため、繰り返し演算が不要となる。なお、推論時には任意の座標を MLP に入力して得られた重みと基底変換を用いて IB を実行し、繰り返し演算によって相似変換 $y(x) \in \text{Sim}(3)$ を推定する必要がある。

各グリッド $\mathbf{x}_m = (x_m, y_m, z_m)^T$ を中心に、前後・上下・左右の 6 近傍と自点を合わせた計 7 点の対応を用いて、局所的な相似変換 \mathbf{Q}_m を推定する。ここで \mathbf{Q}_m は、以下の誤差関数 $e(\mathbf{Q})$ を最小とする。 $\hat{\mathbf{x}}, \hat{\mathbf{x}}'$ は、入力の空間座標、風速成分による移流後の空間座標のそれぞれを同次座標系で表したものである。また、 i, j, k は \mathbf{x}_m に対応するグリッドの X, Y, Z 軸のインデックス値である。




図 1: $\text{Sim}(3)$ の接平面空間

Algorithm 1 Optimization technique on Lie group $\text{Sim}(3)$.

Input:

Initial value $q_0 \in \text{Sim}(3)$, weights $w_i \in \mathbb{R}^+$, basis $c_i \in \text{Sim}(3)$,
decay rate $\alpha \in \mathbb{R}, 0 < \alpha \leq 1$

Output: Optimal value $q \in \text{Sim}(3)$

while $\sum_i w_i \text{Log}_q(c_i) > \epsilon$ **do**
 $q \leftarrow \text{Exp}_q(\alpha \sum_i w_i \text{Log}_q(c_i))$
end while

$$e(\mathbf{Q}) = \|\mathbf{Q}\hat{\mathbf{x}}_m - \hat{\mathbf{x}}'_m\|^2 \quad (1)$$

$$\hat{\mathbf{x}}_m = \begin{bmatrix} x_{i,j,k} & x_{i+1,j,k} & x_{i-1,j,k} & x_{i,j+1,k} & x_{i,j-1,k} & x_{i,j,k+1} & x_{i,j,k-1} \\ y_{i,j,k} & y_{i+1,j,k} & y_{i-1,j,k} & y_{i,j+1,k} & y_{i,j-1,k} & y_{i,j,k+1} & y_{i,j,k-1} \\ z_{i,j,k} & z_{i+1,j,k} & z_{i-1,j,k} & z_{i,j+1,k} & z_{i,j-1,k} & z_{i,j,k+1} & z_{i,j,k-1} \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (2)$$

$$\hat{\mathbf{x}}'_m = \begin{bmatrix} x'_{i,j,k} & x'_{i+1,j,k} & x'_{i-1,j,k} & x'_{i,j+1,k} & x'_{i,j-1,k} & x'_{i,j,k+1} & x'_{i,j,k-1} \\ y'_{i,j,k} & y'_{i+1,j,k} & y'_{i-1,j,k} & y'_{i,j+1,k} & y'_{i,j-1,k} & y'_{i,j,k+1} & y'_{i,j,k-1} \\ z'_{i,j,k} & z'_{i+1,j,k} & z'_{i-1,j,k} & z'_{i,j+1,k} & z'_{i,j-1,k} & z'_{i,j,k+1} & z'_{i,j,k-1} \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (3)$$

3.3 MLP による重みの推定

本研究では、所与の座標に対応する幾何変換を表現するための基底変換の重みを、座標を入力した MLP により推定する。MLP の構造は、図 2 に示す通り、中間層 256 ユニットの 8 層積層し、各層の活性化関数には Leaky ReLU (負の傾き 0.1) を用いた。Leaky ReLU を採用することで勾配消失を防ぎ、学習の安定化と収束速度の向上を図っている。さらに、出力層には ReLU を適用し、IB の収束条件である非負制約を満たすようにしている。また、過学習を防ぐために、MLP 全体にドロップアウト率 0.05 を適用した。

3.4 モデルの学習

図 3 に、本研究で用いるモデルの順伝播の流れを示す。座標 (\mathbf{x}_m, t_m) が MLP に入力され、各基底変換 c_i に対する重み w_i が出力される。

ここで基底変換 \mathbf{C} と合成重み \mathbf{W} は、学習に用いられるサンプル点 (\mathbf{x}_m, t_m) と、3.2 節で求めた幾何変換 \mathbf{Q}_m に対し、以下の関係を満たすように学習する。まず、MLP に対して (\mathbf{x}_m, t_m) を入力して得られる重みを $\mathbf{W}(\mathbf{x}_m, t_m; \theta)$ と表記する。この重みを用いて、基底変換 \mathbf{C} を IB によって合成した結果が、 \mathbf{Q}_m




図 2: MLP アーキテクチャ




図 3: 提案モデル

となることを望ましい。これはつまり、 \mathbf{Q}_m が IB の収束条件 $\sum_i w_i(\mathbf{x}_m, t_m; \theta) \text{Log}_{\mathbf{Q}_m}(c_i) < \epsilon$ を満たすことを意味する。この値が 0 となれば、合成重み $\mathbf{W}(\mathbf{x}_m, t_m; \theta)$ によって基底変換 \mathbf{C} を IB で合成した結果得られる幾何変換 $\hat{\mathbf{Y}}(\mathbf{x}_m, t_m; \theta, \mathbf{C})$ が \mathbf{Q}_m に一致することを意味する。しかし、学習の過程においてはこれは成り立たない。

そのため、基底変換 \mathbf{C} や MLP のパラメータ θ の学習においては、幾何変換 $\hat{\mathbf{Y}}(\mathbf{x}_m, t_m; \theta, \mathbf{C})$ と \mathbf{Q}_m の誤差を評価する。相似変換は回転・並進・拡大縮小といった異なるパラメータを含み、行列の要素によって意味合いが異なる。本研究では、それぞれの変換をサンプルの空間座標 \mathbf{x}_m に作用させ、移流後の空間座標 \mathbf{x}'_m との二乗距離によって誤差を評価することとした。その結果、モデルの学習に用いる損失関数は以下のように定まる。

$$\hat{\mathbf{Y}}(\mathbf{x}_m, t_m; \theta, \mathbf{C}) = \text{Exp}_{\mathbf{Q}_m} \left(\sum_i w_i(\mathbf{x}_m, t_m; \theta) \text{Log}_{\mathbf{Q}_m}(c_i) \right) \quad (4)$$

$$\mathcal{L}(\theta, \mathbf{C}) = \sum_m \left\| \hat{\mathbf{Y}}(\mathbf{x}_m, t_m; \theta, \mathbf{C}) \begin{bmatrix} \mathbf{x}_m \\ 1 \end{bmatrix} - \begin{bmatrix} \mathbf{x}'_m \\ 1 \end{bmatrix} \right\|^2 \quad (5)$$

モデルの学習には誤差逆伝播を用いるが、基底変換 \mathbf{C} を更新する際、 $\text{Sim}(3)$ は加法に関して閉じていないため、一般的な勾配降下法 (式 (6)) を直接適用することはできない。

$$c_i \leftarrow c_i - \alpha \frac{\partial}{\partial c_i} \mathcal{L}(\theta, \mathbf{C}) \quad (6)$$

そこで本研究では、各基底変換 c_i に対し、接空間に定義した最適化用の一時変数 $v_i = 0 \in \text{Sim}(3)$ を使い、接空間上で勾配を計算した後、指数写像を用いて c_i を更新する (Algorithm 2)。

$$c_i \leftarrow \text{Exp}_{c_i} \left(\alpha \frac{\partial}{\partial v_i} \mathcal{L}(\theta, \{\text{Exp}_{c_i}(v_i)\}) \right) \quad (7)$$

3.5 モデルの推論

推論時には、学習によって得られた MLP のパラメータ θ と

Algorithm 2 Optimization technique on Lie group $\text{Sim}(3)$.

Input: Initial value $\{c_i\} \in \text{Sim}(3)^K$, Learning rate $\alpha \in \mathbb{R}$,

Loss function $\mathcal{L}(\theta, \mathbf{c}) \in \mathbb{R}$, #iteration $\text{Itr} \in \mathbb{N}$

Output: Optimal value $c_i \in \text{Sim}(3)$

for $j = 1$ to Itr **do**

$v \leftarrow 0 \in \text{Sim}(3)$

$\Delta v \leftarrow -\alpha \frac{\partial}{\partial v} \mathcal{L}(\theta, \{\text{Exp}_{c_i}(v)\})$

$c_i \leftarrow \text{Exp}_{c_i}(\Delta v)$

end for

基底変換 \mathbf{C} を用いて、Iterative Blending (IB) による幾何変換の推定を行う。

4. 評価実験

4.1 データセット

本研究では、気象介入操作シナリオに基づく 2 種類の 4 次元データセットを用いる。データの生成には気象モデル SCALE-RM [15], [16] を用いた。

a) Dataset1

Dataset1 は、図 4 に示す平成 27 年 9 月関東東北豪雨を対象とした気象介入シミュレーションデータである。オリジナルデータは北緯 32~37 度、東経 136~143 度にわたり、 x, y 方向に 720 グリッド、 z 方向に 55 グリッド、 t 方向に 73 タイムステップを有する、約 2.1×10^9 点のデータから構成される。用いたデータは、介入操作として対象領域内に高さ 300m・幅 200m の障害物を 500m 間隔で 100 基配列し、およそ 0.5 度の範囲にわたる構造物群を設置した場合のものである。空間解像度は 800m、積分期間は 12 時間であり、出力は 10 分間隔の netCDF 形式で記録されている。出力変数は東西風 (U_{met})、南北風 (V_{met})、鉛直風 (W) である。

本研究では、この大規模データから台風近傍の領域を切り出して解析対象とした。切り出し後のデータは x, y 方向に 346




図4: Dataset1 のシナリオ概要. (左) 初期時刻, (中) 中間時刻, (右) 終盤を示し, 時間が進むにつれて台風の発達と移動が表されている.

グリッド, z 方向に 41 グリッド, t 方向に 27 タイムステップを含む, 約 1.5×10^8 点のデータである.

b) Dataset2

Dataset2 は, 令和 3 年 8 月に九州地域を対象として実施した気象介入シミュレーションデータである. オリジナルデータは北緯 30~33 度, 東経 126~132 度にわたり, x 方向に 1440 グリッド, y 方向に 960 グリッド, z 方向に 159 グリッド, t 方向に 36 タイムステップを有し, 約 7.9×10^9 点のデータから構成される. 空間解像度は 800m, 積分期間は 36 時間であり, 出力は 1 時間間隔の netCDF 形式で記録されている. この大規模データから, x 方向に 241 グリッド, y 方向に 120 グリッド, z 方向に 159 グリッド, t 方向に 36 タイムステップを切り出して, 約 1.6×10^8 点のデータを対象とする.

なお, 学習に際しては両データセットに共通して, 空間方向 (x, y, z) において約 20~50%, 時間方向 (t) において 50% を学習データとして用い, 残りを評価用データとした. この分割により, 提案手法が未知データに対してどの程度汎化性能を発揮できるかを検証した.

4.2 実験条件

提案手法の有効性を検証するために, 以下の条件で実験を行った.

本研究では, 性能評価の指標としてデータサイズ (MB) および風速成分 $\mathbf{u}_m = (U_{met_m}, V_{met_m}, W_m)$ に基づく平均二乗誤差 RMSE (Root Mean Square Error) を用いる. RMSE は次式で定義される.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{m=1}^N \|\hat{\mathbf{u}}_m - \mathbf{u}_m\|^2} \quad (8)$$

ここで, $\hat{\mathbf{u}}_m$ は推定された風速ベクトル, N は評価対象データの総数を表す.

これらの指標に基づき, 以下の手法をベースラインとして設定し, 提案手法と比較する.

a) 全結合ニューラルネットワーク (MLP)

入力は $\mathbf{x}_m = (x_m, y_m, z_m)$ と時刻 t_m であり, ネットワーク内部で基数 $C = 2$, 周波数 $K = 4$ の位置エンコーディングを適




図5: ステップサイズに対する RMSE とデータサイズ

用した. 出力は風速成分 ($U_{met_m}, V_{met_m}, W_m$) であり, ネットワークは中間層 256 ユニットを 8 層積み重ね, 活性化関数に Leaky ReLU (負の傾き 0.1), 出力層には tanh を用いた.

b) 線形補間 (バイリニア補間)


入力された時空間座標に対し, 学習データに含まれる近傍の時空間座標における値を用いて線形補間を行った.

4.3 データサイズと精度の結果


図 5 に, Dataset1 における線形補間 (Linear) と提案手法 (GTF) の比較結果を示す. 時間方向のステップサイズを 2 に固定し, 空間方向 (x_m, y_m, z_m) におけるステップサイズを 2, 3, 4, 5 に変化させて学習を行い, 学習データに含まれないグリッドを対象に評価した. 図中の横軸は空間方向のステップサイズ, 縦軸は RMSE (km/10min), バブルサイズはデータサイズ (MB), 色は手法の違いを表す.

線形補間は, ステップサイズが小さいほど精度は良好であるがデータサイズは大きく, 逆にステップサイズを大きくするとデータサイズは減少する一方で精度が悪化するという, 典型的なトレードオフの関係を示した.

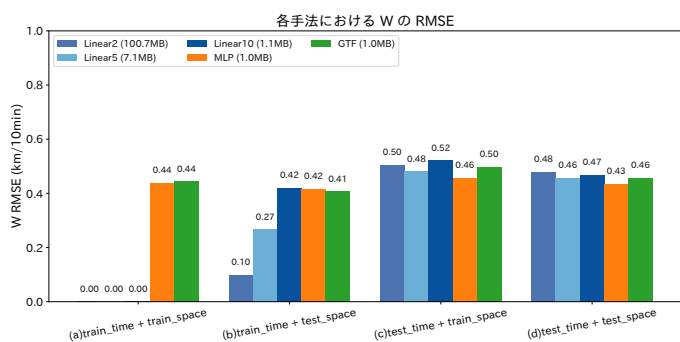
一方, 提案手法は, ステップサイズ 2~5 のいずれにおいてもデータサイズは一定の 1.0 MB に保たれており, 圧縮率が極



(a) Umet 成分




(b) Vmet 成分

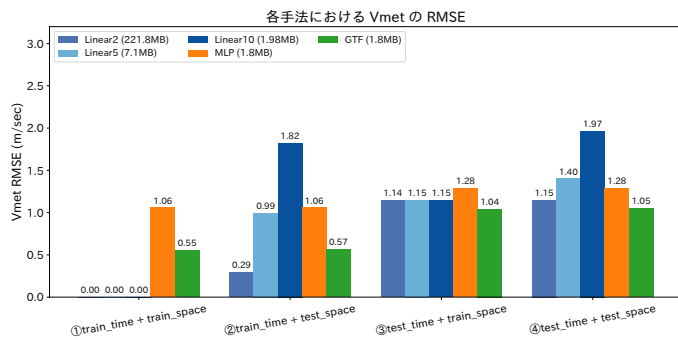


(c) W 成分


図 6: Dataset1 における各成分の学習/検証データ別精度



(a) Umet 成分



(b) Vmet 成分



(c) W 成分

図 7: Dataset2 における各成分の学習/検証データ別精度

めて高いにもかかわらず精度の劣化は小さい。特にステップサイズ2では、元データサイズに対して約1%に相当する極めて高い圧縮率を達成しつつ、RMSEは0.78程度に留まった。

以上の結果から、提案手法は線形補間に比べて極めて高い圧縮率を達成しつつ精度を保持でき、圧縮率と精度の両立が可能であることが示された。

4.4 評価データとテストデータ別の結果

図6と図7に、Dataset1とDataset2での空間・時間方向の教師信号の有無に基づく4条件((a) train time + train space, (b) train time + test space, (c) test time + train space, (d) test time + test space)における各手法のRMSEを示す。比較対象として、空間方向のサンプリング間隔を変えた線形補間(Linear2, Linear5, Linear10)、空間方向のステップサイズを2とした全結合ニューラルネットワーク(MLP)、および提案手法(GTF)を用いた。なお、Linear10は、ニューラル手法におけるデータサイズと同

程度であるため、比較対象として選定した。

(a)(既知時間・既知空間)の条件では、すべての手法でRMSEが小さく、線形補間は既知データ点を完全に再現するためRMSEがゼロとなった。一方、(b)~(d)の未知データを含む条件では、各手法の汎化性能の差が顕著に現れた。特にLinear系列は未知時間・空間で急激にRMSEが増大したのに対し、MLPとGTFは0.5~1.0程度に抑えられ、(d)(未知時間・未知空間)の条件においても安定した精度を維持した。Umet成分とVmet成分ではこの傾向が共通して観測され、W成分は変動幅が小さいため全体的にRMSEが低く、大きな差は生じなかった。これは、z方向におけるグリッド間隔がx,y方向に比べて極端に狭いことが原因であると考えられる。

さらに、MLPとGTFの性能を比較した結果、いずれのDatasetにおいても、多くの条件でGTFのRMSEが小さく、より高い推定精度を示した。これは、提案手法が単純な座標入力に基

づく MLP と異なり、隣接する時空間座標間の関係を学習できるためであり、未知データに対してもより良好な一般化性能を発揮した結果と考えられる。

以上の結果から、提案手法 (GTF) は時間的・空間的に未知のデータに対しても高い一般化性能を有し、小さなモデルサイズで複雑な移流を適切に表現できることが確認された。

5. 結 論

本研究は、数値気象モデルにおける膨大な 4 次元データを対象として、高精度な補間と効率的なデータ圧縮を両立することを目的とした。この目的のために、幾何変換を連続関数として表現可能な幾何変換場 (GTF) のニューラル表現を導入し、2 種類の大規模気象データに適用した。実験の結果、提案手法は線形補間および全結合ニューラルネットワーク (MLP) と比較して、小さなモデルサイズで高い精度を維持でき、未知の時間・空間に対しても優れた汎化性能を有することが示された。

本研究では、数値気象モデルから得られる 4 次元データを対象として提案手法の有効性を検証したが、気象介入操作そのものの影響についてはクローズアップしていない。今後の課題として以下の 3 点が挙げられる。第 1 に、提案手法 (GTF) が介入操作による気象場の変化をどの程度表現できるかを調査する必要がある。特に、介入規模や配置条件の違いに対して風速場の変化をどの程度再現可能かを検証することで、本手法の表現力と限界を明らかにできると考えられる。第 2 に、提案モデルを用いた風速場の可視化をさらに発展させる必要がある。特に流線の可視化に適用し、空間的・時間的に連続性を保ちながら風速場を再構成することで、介入操作が気象場に与える影響を直感的かつ高精度に把握できると期待される。第 3 に、GTF における鉛直風成分 (W) の再現精度が他の成分に比べて十分でないため、(W) 成分の表現精度を向上させるための検討が必要である。

謝辞 本研究の一部は JST さきがけ JPMJPR2025, JST ムーンショット型研究開発事業 JPMJMS2389 の支援を受けた。モデルの学習・評価には、産総研及び AIST Solutions が提供する ABCI 3.0 を利用し、「ABCI 3.0 開発加速利用」の支援を受けた。また、本研究の一部は、スーパーコンピュータ「富岳」の計算資源の提供を受け、実施しました (課題番号: hp240169, 250178, 250188)

文 献

- [1] Y. Hiraga, J.M. Mbugua, S. Kotsuki, Y. Suzuki, S.-H. Chen, A. Hamada, K. Yasunaga, and T. Funatomi, "Numerical experiments of cloud seeding for mitigating localization of heavy rainfall: A case study of mesoscale convective system in japan," *EGUsphere*, vol.2025, pp.1–29, 2025.
- [2] R.N. Bannister, "A review of operational methods of variational and ensemble-variational data assimilation," *Quarterly Journal of the Royal Meteorological Society*, vol.143, no.703, pp.607–633, 2017.
- [3] S. Ravuri, K. Lenc, M. Willson, D. Kangin, R. Lam, P. Mirowski, M. Fitzsimons, M. Athanassiadou, S. Kashem, S. Madge, R. Prudden, A. Mandhane, A. Clark, A. Brock, K. Simonyan, R. Hadsell, N. Robinson, E. Clancy, A. Arribas, and S. Mohamed, "Skilful precipitation nowcasting using deep generative models of radar," *Nature*, vol.597, no.7878, p.672 – 677, 2021.

- [4] K. Um, R. Brand, Y. Fei, P. Holl, and N. Thuerey, "Solver-in-the-Loop: Learning from Differentiable Physics to Interact with Iterative PDE-Solvers," *Advances in Neural Information Processing Systems*, pp.6111–6122, 2020.
- [5] J. Brandstetter, D.E. Worrall, and M. Welling, "Message passing neural PDE solvers," *International Conference on Learning Representations*, pp.1–27, 2022.
- [6] D. Kochkov, J.A. Smith, A. Alieva, Q. Wang, M.P. Brenner, and S. Hoyer, "Machine learning – accelerated computational fluid dynamics," *Proceedings of the National Academy of Sciences*, vol.118, no.21, p.e2101784118, 2021.
- [7] Z. Li, S. Niklaus, N. Snavely, and O. Wang, "Neural scene flow fields for space-time view synthesis of dynamic scenes," *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.6494–6504, 2021.
- [8] A. Pumarola, E. Corona, G. Pons-Moll, and F. Moreno-Noguer, "D-nerf: Neural radiance fields for dynamic scenes," *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.10318–10327, 2021.
- [9] E. Tretschk, A. Tewari, V. Golyanik, M. Zollhöfer, C. Lassner, and C. Theobalt, "Non-rigid neural radiance fields: Reconstruction and novel view synthesis of a dynamic scene from monocular video," *IEEE International Conference on Computer Vision (ICCV)*, pp.12959–12970, 2021.
- [10] 船富卓哉, 山田重人, 藤村友貴, 榎田貴弘, 向川康博, "幾何変換のスパース回帰による変形場の表現," *情処研報 CGVI*, pp.184–21, 2021.
- [11] 石原 実, 船富卓哉, 藤村友貴, 久保尋之, 向川康博, "ニューラル幾何変換場による非剛体画像位置合わせ," *信学技報 PRMU*, 第 124 巻, pp.44–48, 2025. IEICE Technical Report, PRMU2024-41 (2025-01).
- [12] X. Pennec and V. Arsigny, "Exponential barycenters of the canonical cartan connection and invariant means on lie groups," pp.123–166, Springer Berlin Heidelberg, Berlin, Heidelberg, 2013.
- [13] L. Kavan, S. Collins, J. Zara, and C. O'Sullivan, "Skinning with dual quaternions," *I3D*, pp.39–46, 2007.
- [14] S. Umeyama, "Least-squares estimation of transformation parameters between two point patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol.13, no.4, pp.376–380, 1991.
- [15] S. Nishizawa, H. Yashiro, Y. Sato, Y. Y. Miyamoto, and H. Tomita, "Influence of grid aspect ratio on planetary boundary layer turbulence in large-eddy simulations," *Geoscientific Model Development*, vol.8, pp.3393–3419, 2015.
- [16] Y. Sato, S. Nishizawa, H. Yashiro, Y. Miyamoto, Y. Kajikawa, and H. Tomita, "Impacts of cloud microphysics on trade wind cumulus: which cloud microphysics processes contribute to the diversity in a large eddy simulation?," *Progress in Earth and Planetary Science*, vol.2, no.23, pp.1–16, 2015.