

拡散モデルを用いた多変量気候データの高解像度化手法

課題責任者

吉田 広顕

株式会社豊田中央研究所

著者

杓名 拓郎^{*1}, 石崎 紀子^{*2}, 大山 倫弘^{*1}, 吉田 広顕^{*1}

^{*1}株式会社豊田中央研究所, ^{*2}国立環境研究所

キーワード: ダウンスケーリング, 拡散モデル, 生成 AI, 多変量相関

1. はじめに

気候変動が社会・経済活動に及ぼす影響が顕在化する中で, 将来の気候を高精度に予測し, 防災やインフラ計画, 農業・エネルギー分野の意思決定に活用することの重要性が高まっている。将来気候の予測には全球気候モデル (GCM) による数値シミュレーションが用いられるが, 計算資源の制約から空間解像度は数十〜100km 程度にとどまり, 地域スケールでの利用には不十分である。

この課題に対し, GCM 出力を高解像度化するダウンスケーリング手法が広く用いられてきた[1, 2]。従来の統計的ダウンスケーリングは計算負荷が小さい一方で, 地点ごと・変数ごとに独立した処理を前提とするものが多く, 空間相関や複数の気象変数間に存在する依存関係を十分に再現できないという課題がある。しかし, 熱ストレスや洪水, 干ばつなどの高影響事象は, 複数の気象変数の組み合わせによって発生・増幅するため, 変数間相関の再現は重要である。

本研究では, 生成 AI の一種である拡散モデルを用いた統計的ダウンスケーリング手法を提案し, 多変量気象データに内在する相関構造を高解像度で再現することを目的とする。拡散モデルによる高解像度推定と従来のバイアス補正を組み合わせた二段階手法を採用し, 日本周辺を対象とした数値実験を通じてその有効性を検証する。

2. 提案手法

本研究では, 生成 AI の一種である拡散モデルを用いた統計的ダウンスケーリング手法を提案する [3]。提案手法は, 低解像度の気候モデル出力を入力とし, 多変量気象データの高解像度推定量を生成することで, 空間構造および変数間相関を同時に再現することを目的としている。

提案手法は二段階で構成される。第 1 段階では, 拡散モデルを用いて高解像度の多変量気象データを確率的に生成する。拡散モデルは高次元データの生成に適しており [4], 高解像度場全体を一括して推定できるため, 従来の地点独立型手法と比較して, 空間的に離れた地点間の相関や複数の気象変数間に存在する共変動構造を高精度に再現できることが期待される。また, 確率的生成が可能であることから, 同一条件下で複数の実現例を得ることができ, 不確実性評価への応用も期待できる。

一方で, 拡散モデルによる生成結果は, 各気象変数の絶対値や分布特性に系統的な偏りを含む場合がある。そこで第 2 段階として, 拡散モデルによって得られた高解像

度推定量に対し, 従来の累積分布に基づくバイアス補正手法を適用する。本研究では, 標準的な分位点マッピング (Quantile Mapping, QM) [5] を用いることで, 各変数の統計的分布特性を補正しつつ, 第 1 段階で再現された相関構造を維持することを図る。

以上の二段階手法により, 単変量の再現性と多変量相関構造の再現性を両立した高解像度気候データの生成を実現する。

3. 数値実験

提案手法の有効性を検証するため, 日本周辺を対象とした気候観測データおよび再解析データを用いて数値実験を行った。高解像度の正解データとして, 約 1km 解像度の気象観測データを使用し, 低解像度データとして全球気候モデルの再解析データを用いた。対象期間は 1980 年から 2023 年までとし, 学習用, 検証用, テスト用データに分割して評価を行った。ダウンスケーリングの倍率は, 緯度・経度方向それぞれ 50 倍とした。

ダウンスケーリングの対象変数として, 日平均気温, 日最高気温, 日最低気温, 日降水量, および全天日射量の 5 変数を用いた。比較手法として, 低解像度データを空間補間した後に分位点マッピング (Quantile Mapping, QM) によるバイアス補正を適用する従来手法, および生成モデルに基づく既存のダウンスケーリング手法を用いた [6]。

まず, ダウンスケーリング結果の空間分布を視覚的に比較した例を図 1 に示す。図は, 提案手法によって得られた高解像度分布と, 正解となる観測データの分布を並べて示したものである。提案手法による結果は, 単純な空間補間と比較して, 局所的な強弱や分布形状をより良く再現しており, 気温や日射量に見られる大局的な勾配構造に加えて, 地形や陸海分布に対応した細かな空間構造も明瞭に再現されていることが確認できる。特に降水量については, 空間的に散在する強降水域の分布や局所的なコントラストが観測データに近い形で再現されており, 拡散モデルによる高解像度生成の効果が視覚的にも確認できる。

次に, これらの視覚的な一致が定量的にも妥当であるかを確認するため, 単変量および多変量の指標に基づく評価を行った。単変量指標としては, 各気象変数について, ダウンスケーリング結果と高解像度観測データとの差に基づく誤差指標を用いた。その結果, 提案手法は, 気温, 降水量, 全天日射量のいずれにおいても, 従来手法と同程




図 1. ダウンスケーリング結果と高解像度観測データ（正解データ）との空間分布の比較

度、もしくはそれ以上の再現精度を維持できていることが確認された。拡散モデル単体では、一部の変数において系統的な偏りが生じる場合が見られたが、QM を組み合わせることで分布特性が補正され、単変量精度が安定化する傾向が確認された。

さらに、多変量指標に着目すると、提案手法は、地点間相関および変数間相関の再現性において、従来手法と比較して顕著な改善を示した。地点間相関の誤差量で比較すると、空間補間と QM を組み合わせた従来手法を基準とした場合、既存の生成モデルに基づく手法 [6] を QM と組み合わせた手法では誤差が約 40% 程度まで低減されているのに対し、提案手法では誤差が約 13% 程度まで抑えられていることが確認された。これは、拡散モデルを用いることで、空間的に離れた地点間に存在する相関構造がより高精度に再現されていることを示している。

また、変数間相関誤差についても同様の傾向が確認された。空間補間と QM を組み合わせた従来手法と比較すると、既存手法 [6] を QM と組み合わせた手法では誤差が約 75% 程度まで低減されている一方で、提案手法では誤差が約 21% 程度まで抑えられており、多変量気象データに内在する依存関係がより高精度に再現されていることが分かる。これらの結果は、拡散モデルが高解像度場全体を同時に生成することで、空間構造と変数間の共変動特性を一体的に学習できていることを示唆している。

さらに、QM によるバイアス補正を適用した後も、これらの相関構造が損なわれることなく維持されていることから、提案する二段階手法が、単変量の統計的整合性と多変量相関構造の再現性を両立する上で有効であることが確認された。以上より、提案手法は、視覚的な分布構造の再現性と定量的な評価指標の双方において、従来手法を上回る性能を示しており、多変量かつ高解像度の気候データ生成に有効なアプローチであることが示された。

4. まとめ

本研究では、拡散モデルを用いた統計的ダウンスケーリング手法を提案し、日本周辺を対象とした気候データを用いてその有効性を検証した。提案手法は、拡散モデルによって多変量気象データの空間構造および変数間相関を高解像度で再現した後、従来のバイアス補正手法を組み合わせる二段階構成を採用している。

数値実験の結果、提案手法は、各気象変数の単変量的な再現精度を従来手法と同程度以上に維持しつつ、地点間相関および変数間相関の再現性において顕著な改善を示した。特に、複数の気象変数が関与する相関構造については、従来手法では再現が困難であった特徴的な依存関係が、高い精度で再現されることを定量評価および視覚的比較の両面から確認した。

以上の結果から、提案手法は、地域スケールでの気候リスク評価や、防災、インフラ計画、エネルギー分野などにおいて重要となる、多変量かつ高解像度の気候情報を生成する有効な手法であることが示された。今後は、確率的に生成される複数のダウンスケーリング結果を活用した不確実性評価や、将来気候予測データへの適用を進めることで、実務的な意思決定へのさらなる貢献が期待される。

謝辞

本研究は、国立研究開発法人海洋研究開発機構（JAMSTEC）が運用する地球シミュレータを利用して実施された。

参考文献

- [1] Wood, A. W. et al., "Hydrologic implications of dynamical and statistical approaches to downscaling climate model outputs", *Clim. Change*, 62(1), 189–216, (2004).
- [2] Sun, Y. et al., "Deep learning in statistical downscaling for deriving high spatial resolution gridded meteorological data: A systematic review", *ISPRS J. Photogramm. Remote Sens.*, 208, 14–38, (2024).
- [3] Kutsuna, T., et al. "Generative climate downscaling enables high-resolution compound risk assessment by preserving multivariate dependencies." *arXiv:2605.11531* (2026).
- [4] Dhariwal, P. and Nichol, A., "Diffusion models beat GANs on image synthesis", *Adv. Neural Inf. Process. Syst.*, 34, 8780–8794, (2021).
- [5] Cannon, A. J. et al., "Bias correction of GCM precipitation by quantile mapping", *J. Climate*, 28(17), 6938–6959, (2015).
- [6] Oyama, N. et al., "Deep generative model super-resolves spatially correlated multiregional climate data", *Sci. Rep.*, 13(1), 5992, (2023).