

リアルタイム微気象予測のための深層学習と物理シミュレーションの融合

課題責任者

安田 勇輝

東京工業大学 学術国際情報センター

著者

安田 勇輝^{*1}, 大西 領^{*1}, 小野寺 孔明^{*1}, 宮下 和也^{*1}, 寺田 崇志^{*1}, 野津 有礼^{*1}, 平澤 慧悟^{*1}

^{*1} 東京工業大学 学術国際情報センター

キーワード: 微気象, MSSG, 深層学習, 超解像, データ同化

本研究課題ではリアルタイム微気象予測の実現に向け、4つのサブ課題を遂行している。以下ではそれぞれに関する成果報告を行う。

1. リアルタイム微気象予測に向けた超解像シミュレーションの実現

都市における微気象は、人間活動に強く影響し得る。しかし、その小スケール性 (数 m オーダー) から数値計算負荷は高く、リアルタイム予測は難しい。この計算負荷を下げる試みとして、深層学習技術「超解像」と数値流体計算を組み合わせる「超解像シミュレーション法」が提案された [1]。この手法は、低解像度の数値流体計算の結果を、ニューラルネットにより高解像度化 (超解像) することで、高解像度の推論を高速に出力する。先行研究では [1,2], 都市微気象の予測に対し超解像シミュレーション法が有

効である可能性が示されていた。本研究は、マルチスケール大気・海洋結合モデル MSSG (Multi Multi-Scale Simulator for the Geoenvironment) [e.g. 3,4] と深層ニューラルネット [2] を組み合わせ、超解像シミュレーション法が実際に都市微気象に対し有効であり、総計算時間を約 1/35 に低減できることを示した。

具体的に、東京駅周辺の 2 km 四方の領域を対象とした微気象計算を利用し、手法の有効性を示した。この実験では、MSSG による水平・鉛直 20 m 解像度の微気象計算結果を 5 m へと超解像する (4 倍超解像)。推論対象としたのは、温度と 3 次元速度の計 4 成分である。ニューラルネットの訓練には、5 m 解像度の MSSG の計算結果を用いた。図 1 は地上付近における温度と鉛直風の推論の例を示す。20 m 解像度 (入力データ) では表現されない街路上の流れが、超解像により復元されている。5 m 解




図1: 超解像シミュレーション結果のスナップショット。東京駅八重洲・地上 10 m 高さにおける 600 m 四方領域を示す。灰色の領域は建物による欠損を表す。

像度の MSSG 計算結果を正解とした時、誤差率は温度に対し 7%, 速度ベクトルに対し 15% 程度であった。また、1 時間先予測の総計算時間は約 260 分から 7.5 分へと 1/35 に低減された。得られた成果は国内学会で発表し、査読付き国際論文誌への投稿を行った。現在、査読結果を待っている。

2. 気象予測に基づく微気象場の推論

本サブ課題では、「気象」予測に対し、超解像シミュレーション法を適用する。気象予測は、数 km 以上の大気現象を扱い、日々の天気予報の元となる。もし気象 (数 km スケール) から微気象 (数 m スケール) への超解像が実現出来れば、例えば、東京全域の微気象予測が低コストで得られるかもしれない。その実現可能性を調べるため、本年度は MSSG による水平 100 m 解像度の気象計算結果を 5 m 解像度へと超解像した (倍率 20 倍)。図 2 にその推論の例を示す。気象計算では、地面付近の流れが表現されず欠損しているため、上空の流れのみを入力した。ニューラルネットにより、上空の流れから地表付近の流れが推論され、街路間の細かい温度場が再現された。得られた成果は国内学会で発表し、現在、ニューラルネットの更なる改善に取り組んでいる。




図 2: 気象計算 (100 m 解像度) からの超解像結果。地面から高さ 7.5 m の温度分布を示す。白い領域は建物による欠損を表す。入力的气象データはこの高さで欠損しているため図に示さない。

3. 教師なし学習による超解像データ同化法の開発

気象予測は、初期条件の不確実性や大気のカオス性などから、時間と共に現実から乖離する。そのため、現行の予報業務では、観測データを予測に取り込む「データ同化」

を行い、予測精度を向上させる。本課題では、リアルタイム微気象予測への応用を見すえ、データ同化と超解像を組み合わせる基礎研究を実施した [5]。先行研究 [6, 7] と異なり、教師なし学習に基づく新たな手法を提案し、その妥当性を理論と数値実験の両面から示した。

具体的に、Bayes 推論の手法を用いることで、本提案手法が、伝統的な同化方法「3 次元変分法」の拡張であることを理論的に明らかにした。この結果は、ニューラルネットによる同化の妥当性を示唆する。さらに、理想的な海洋ジェット流の数値実験を通し、超解像とデータ同化が同時に実現可能なことを示した。図 3 にその推論の例を示す。ニューラルネットの訓練に高解像度のデータは利用しないにも関わらず (教師なし学習)、高解像度の流れを推論している。得られた成果は、国内・国際学会で発表した。また、そのプレプリントは公開済みである [5]。現在、査読結果を同化手法へ反映している途中であり、それが完了した後、国際論文誌に再投稿する予定である。

4. 深層生成モデルを利用した超解像

近年、深層生成モデル (生成 AI) の発展が著しい。深層生成モデルは、限られたサンプルから背後にあるデータの確率分布を推定する。そして、得られた分布からサンプリングを行うことで、未知データが生成できる。データ同化は、Bayes 推論の考え方に基づけば、真の状態の確率分布の推定と見なせる。そこで、最新の深層生成モデル [8] を超解像データ同化に利用する試みを実施している。本年度は、その第一歩として、深層生成モデルを流れ場の超解像に利用し、その有効性を示した。得られた結果は国内学会で発表し、現在、データ同化への応用を進めている。

謝辞

本研究課題は、国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の委託業務 (JPNP22002) の助成を受けている。

文献

- [1] R. Onishi, D. Sugiyama, and K. Matsuda, “Super-resolution simulation for real-time prediction of urban micrometeorology,” *SOLA*, **15**, 178-182, (2019).
- [2] Y. Yasuda, R. Onishi, and K. Matsuda, “Super-resolution of three-dimensional temperature and velocity for building-




図 3: 超解像データ同化結果のスナップショット。理想的な海洋ジェット流の渦度分布を示す。正解データ中の黒点は観測される格子点を示す。全格子点 (128×64) 中、1.56% の格子点上の渦度が観測されるとした。

resolving urban micrometeorology using physics-guided convolutional neural networks with image inpainting techniques,” *Build. Environ.*, **243**, 110613 (2023).

[3] K. Takahashi, R. Onishi, Y. Baba, S. Kida, K. Matsuda, K. Goto, and H. Fuchigami, “Challenge toward the prediction of typhoon behaviour and down pour,” *J. Phys. Conf. Ser.*, **454**, 012072 (2013).

[4] K. Matsuda, R. Onishi, and K. Takahashi, “Tree-crown-resolving large-eddy simulation coupled with three-dimensional radiative transfer model,” *J. Wind Eng. Ind. Aerodyn.*, **173**, 53-66 (2018).

[5] Y. Yasuda and R. Onishi, “A Theory of Evidence Lower Bound and Its Application to Super-Resolution Data Assimilation (SRDA) Using Conditional Variational Autoencoders,” *arXiv*, 2308.03351 (2023).

[6] S. Barthélémy, J. Brajard, L. Bertino, and F. Counillon, “Super-resolution data assimilation.” *Ocean Dyn.*, **72**, 661-678 (2022).

[7] Y. Yasuda and R. Onishi, “Spatio-Temporal Super-Resolution Data Assimilation (SRDA) Utilizing Deep Neural Networks With Domain Generalization”, *J Adv. Model. Earth Syst.*, **15**, e2023MS003658 (2023).

[8] F. Croitoru, V. Hondru, R. Ionescu, and M. Shah, “Diffusion Models in Vision: A Survey,” *IEEE Trans. Pattern Anal. Mach. Intell.*, **45**, 10850-10869 (2023).