

深層学習を利用したリアルタイム微気象予測への挑戦

安田勇輝（東京工業大学 学術国際情報センター）

1. はじめに

リチャードソンは 1920 年頃「6 万 4 千人が手計算すれば、リアルタイム天気予報が可能」と提案した。それから 100 年経ち、計算機の発達により、気象予測は我々の生活に欠かせないものとなった。この予測は、空間を格子状に離散化し、物理方程式を数値的に解くことで実現される。この計算で表現可能な現象のスケールは、空間格子の解像度に依存する。

微気象とは、空間スケール約 1 km 未満、時間スケール約 1 日未満の局所的な大気現象を指す [1]。微気象過程は、地表の影響を受ける低高度で主に起こり、例えば、ビル風などを含む。このような小スケール現象の再現には、数メートル程度の解像度が必要となり、その計算負荷は非常に高い。スーパー・コンピュータを用いても、1 時間予測に数時間を要する。これではリアルタイム予測は実現できない。

もしリアルタイム微気象予測が実現すると、人々の生活はより良くなると考えられる。例えば、ビル風の予測は、ドローンの運航をより安全にし、物流網の発展に繋がる。また、酷暑環境において、路幅の空間スケールで気温は変化し、熱中症リスクに影響を与え得る [2]。微気象の気温予測に基づくナビゲーションができれば、このリスクは低減され得る。

本講義では、深層学習により計算負荷を低減し、リアルタイム微気象予測を実現しようとする最新の試みを紹介する。

2. 深層学習を利用する理由

深層学習とは、ニューラルネットと呼ばれる階層構造を持つ関数のパラメータを、データから最適化する手法を指す。この最適化を通し、ニューラルネットはデータから規則を学習し、自然言語や画像分野の課題へ応用される。様々な機械学習法から深層学習を選択する理由は、少なくとも 3 つ挙げられる。

第一に実行環境の豊富さである。クラウド上はもちろん、ローカルデバイス上でも容易に動かせる。例えば、TensorFlow.js を使えば、特別な準備をせずに、ウェブブラウザ上の JavaScript 経由でニューラルネットの推論が実行できる。

第二にスケーリング則が挙げられる [3]。例えば、

学習データの増加と共に層を深くすると性能が向上する。この結果は、気象データの拡充と共に、ニューラルネットの精度向上が可能なことを示唆する。

第三に、物理との整合性がある。畳込ニューラルネットの成功の理由として、抽出される特徴量が位置に依存しない点が挙げられる。これは人の認識と似ている。犬が写真に写っている時、人はその位置によらず犬と判断できる。この位置に依存しない性質は対称性と呼ばれ、物理では保存則と密接に関係する。つまり、ニューラルネットを利用することで、運動量などの保存が実現できる。さらに、これらの対称性を満たす演算は、畳込などのいくつかの演算に数学的に絞り込まれる [4]。

以上から、様々な環境で実行でき、データの拡充と共に精度向上が期待でき、さらに、物理と相性の良いニューラルネットを利用する。




図 1: 辞書型・超解像におけるパターンの対応関係

3. 超解像法

リアルタイム微気象予測の困難は、解像度の高さに帰する。解像度を下げると計算負荷は低減するが、ビルなどの流れに影響する障害物が表現できない。

超解像とは、画像の解像度を向上させる手法を指す。近年、ニューラルネットを利用した手法が研究されており、低解像度では不鮮明なパターンが復元可能なことが示されている。ここでは、超解像法として辞書型の手法を説明する。これは畳込ニューラルネットで実現可能で [5]、後の微気象データの超解像でも利用する。

辞書型の方法では、低解像度と高解像度のパターンの対応関係が、局所的に存在すると仮定する (図 1)。学習時はこの対応関係をデータから構築する。テスト時はこの対応関係に従い、低解像度のパターンを高解像度のものに写像する。この処理を画像全体に対し実行し、高解像度の出力が得られる。

4. 超解像シミュレーション法

Onishi et al. (2019) は、超解像により物理シミュレーションの計算負荷を低減しつつ、高解像度の推論を得る手法を提案した [6]。この方法は、学習とテスト段階に分けられる。まず、気象シミュレーションなど物理に基づく数値計算を高解像度と低解像度で別々に行う。高解像度の結果を教師データとし、低解像度の結果を入力とする。この学習データを用いて、ニューラルネットの訓練を行う (図 2)。テスト時は、低解像度の数値計算のみを行い、その結果をニューラルネットにより高解像度化する。高解像度の数値計算は必要なく、また、ニューラルネットの推論時間は通常無視できるほど小さいため、この手法の計算効率は良い。

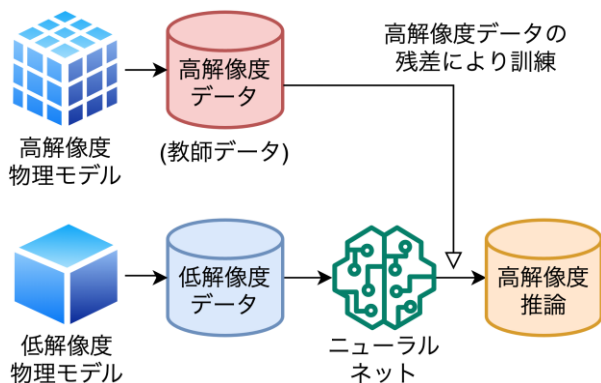


図 2: 超解像シミュレーション法の模式図

気象学において解像度を上げる手法は、ダウンスケーリングと呼ばれ、深層学習の登場以前から研究されてきた。この方法は、力学的なもの統計的なものに分けられる。力学的ダウンスケーリングでは [7]、低解像度の気象モデルの結果を初期条件および境界条件として、高解像度のモデルによる数値計算を行う。統計的ダウンスケーリングでは [8]、気象データの統計性に基づき、解像度を向上させる。3 章で説明した超解像は、この統計的手法に分類できる。一方、2 章で議論したように、物理的な対称性はニ

ューラルネットに組み込める。ニューラルネットを適切に設計すれば、超解像シミュレーションは、統計的な情報を利用しつつ、物理に整合した高解像度の結果を出力できる。つまり、この手法は、力学的と統計的ダウンスケーリングの間に位置づけられる。

5. 超解像法の微気象予測への応用

超解像は、気候または気象モデルに適用され、その有効性が確認されている [9,10]。しかし、都市における微気象には十分に活用されていない。その理由の 1 つは、障害物であるビルの形状が解像度に依存するためである。例えば、20 m 解像度では細い街路は表現できないが、5 m 解像度では表現できる (図 3)。もし 20 m から 5 m へ超解像を行う場合、欠損していた街路上の流れを構築しつつ、高解像度化を行う必要がある。このような複合問題を扱うため、我々はまず空間 2 次元のデータを作成し、解像度のみを変化させる問題を扱う (5.2 節)。次に、空間 3 次元を対象とし、高解像度化と欠損域の流れの構築の複合問題を扱う (5.3 節)。




図 3: 高解像度と低解像度のビル高さの分布

5.1 微気象シミュレーションによる訓練データ作成

ここでは、MSSG (Multi-Scale Simulator for the Geoenvironment) と呼ばれる大気モデルを用いて、高解像度の微気象計算を行った [11,12]。そして、その結果を平均操作し、低解像度のデータを作成した。超解像シミュレーション法と異なり、低解像度の計算は別途実施しない。その理由は、上で議論した複合問題に対し、まずは簡単に作成できるデータで超解像の有効性を確認するためである。また、簡単な流体モデルによる事前実験によると、低解像度データの生成法に結果は大きく依存しない [13]。

2013 から 2020 年の猛暑日を対象とした再現実験を 171 ケース行った。微気象予測の気温分布に従う

と、熱中症リスクを低減できる可能性があるため [2]、この問題設定を選んだ。計算領域には、東京駅を中心とした 2 km 四方を選んだ。格子間隔は全ての方向で 5 m とした。図 4 は風速の 3 次元分布を示す。ビルの後方で風速が複雑に変化する様子が確認できる。得られた 5 m の高解像度データに対し平均操作を施し、20 m の低解像度へ変換した。推論対象の物理量は、気温または風速ベクトルとした。




図 4: 高解像度の微気象シミュレーションから得た東京駅・丸の内口の風速の大きさの 3 次元分布

5.2 空間 2 次元データの超解像

この節では、空間 2 次元データに対し高解像度化を行い、微気象への超解像の有効性を示す [6,14]。




図 5: 2 次元データ生成の模式図。赤点線がサンプリング高度を表す。

欠損領域が生じないように、下部境界から 2 m 高さのデータをサンプリングし、2 次元データを作成した (図 5)。ビルが存在する場合、ビルの屋上から 2 m の高さがサンプリングされる。この 2 m の高さ

の気温や風を、人々は生活で感じる。推論するのは高解像度の気温場で、入力として低解像度の気温、水平風速、日射量、そして、高解像度のビル高さ分布を利用した。

ニューラルネットは、SRCNN [5] に注意機構 [15] を組み込んだものとした。この機構により、入力データに応じた特徴量の動的な重み付けが可能となり、精度や解釈性の向上が期待できる。このニューラルネットを教師あり学習により訓練した。

図 6 は結果の例を示す。教師データと推論結果は良く似ている。ビルの存在する地点では、屋上の気温がサンプルされる為、その分布はビルを反映した不連続性を持つ。ニューラルネットは、高解像度のビル高さ分布を活用し、このパターンの再現に成功している。さらに結果を解析すると、ニューラルネットは物理量間の関係を学習することが示唆された [14]。例えば、日射量が高い時、ビル高さに対する注意機構の重みは大きくなる。この結果は、ビルによる日向と日陰のコントラストが強まると気温が大きく影響を受けることに対応するかもしれない。以上の結果により、都市の微気象に対し、ニューラルネットによる高解像度化の有効性を確認できた。




図 6: 気温の 2 次元超解像の例

5.3 空間 3 次元データの超解像

次に空間 3 次元データに対し、高解像度化と欠損域 (細い街路上) の流れの構築を同時に行う [16]。2 次元の時のようなサンプリングは利用しない。

この欠損域の復元には、画像修復 (image inpainting) 技術を応用した。この技術は画像編集アプリなどに利用されており、例えば、写真内のオブジェクトを指定すると、周りの風景に整合する様にそれを消すことが出来る。具体的にゲート畳込 [17]

と呼ばれる技術を用い、周囲の情報から畳込による欠損域の復元を行う。

ニューラルネットとして U-Net を用いた。U-Net は画像修復にも利用されている [18]。出力は、高解像度の気温と風速ベクトルの計 4 成分であり、入力には、低解像度の気温と風速および高解像度のビル分布とした。このビル分布は、3 次元空間内の格子点がビル内であれば 0 を、ビル外であれば 1 を取る。訓練時の損失関数に、風速の発散を組み込むことで、推論の物理的整合性を向上させた。このようなニューラルネットは「物理を考慮している (physics guided)」とみなされる。




図 7: 気温と鉛直風の 3 次元超解像の例。地面から 3 m および 43 m 高さの水平断面を示す。灰色はビルを表す。水平風速に対しても似た結果を得た。

図 7 は結果の例を示す。3 m 高さでは、多くの街路が低解像度の入力データ内で表現されない。それに関わらず、ニューラルネットは流れ場の復元と高解像度化を同時に達成している。高さの増加に従い、ビル内に位置する格子点数が減少し、入力の欠

損域が小さくなる。そのため、推論精度は高さと共に上昇する。ニューラルネットの推論の成功は、3 次元パターンマッチに起因する。低高度の入力を全て欠損させても、地面付近の流れは定性的に推論できた [16]。つまり、上空の流れのパターンから、地面付近のパターンを推定していると解釈できる。

また、超解像シミュレーションの計算時間も見積った。この仮見積によると、1 時間予測に約 5 分かかる。これはリアルタイム予測の可能性を示唆する。

以上の結果により、都市の 3 次元の微気象に対し、高解像度化とそれに伴う欠損域の補正が同時に実現可能なことが実証できた。

6. 4 次元超解像データ同化

この章では、微気象予測への応用を見据えて開発中の「4 次元超解像データ同化」を説明する [19]。

数値シミュレーションの結果は、大気のカオス性やモデルで表現できない小スケール現象により、時間と共に現実から乖離する。データ同化はこの乖離を観測データにより修正する方法である。近年、衛星などの高解像度の観測が利用可能になってきた。そのような観測を十分に活用するには、高解像度の気象モデルが必要だが、その計算負荷は高い。

ここでは、超解像シミュレーション法とデータ同化を融合させる (図 8)。時間発展は低解像度の物理モデルで計算し、その結果をニューラルネットにより高解像度化する。この際、高解像度の観測データを同化し、推論の補正を同時に行う。この入出力データは流れ場の時系列であり、4 次元 (空間 3+時間 1) 配列で記述される。出力された推論のうち、現在時刻に対応する高解像度のスナップショットを適当な平均操作で低解像度化する。これを初期値として、次の観測データが得られるまで物理モデルで予測計算を行う。このサイクルは繰り返し実行する。この手法は、超解像シミュレーション法と同様に、低解像度の物理計算を利用するため、計算効率が良い。

超解像データ同化の有効性を確認するため、理想化された 2 次元の海洋ジェット流の数値実験を行った。高解像度と低解像度の流体計算を別々に行い、データのペアを作成した。観測データは高解像度の結果から擬似的に作成した。ニューラルネットは、畳込により特徴量を抽出し、時系列相関をトランスフォーマー [20] により取り込み、超解像とデータ同化を同時に行う。

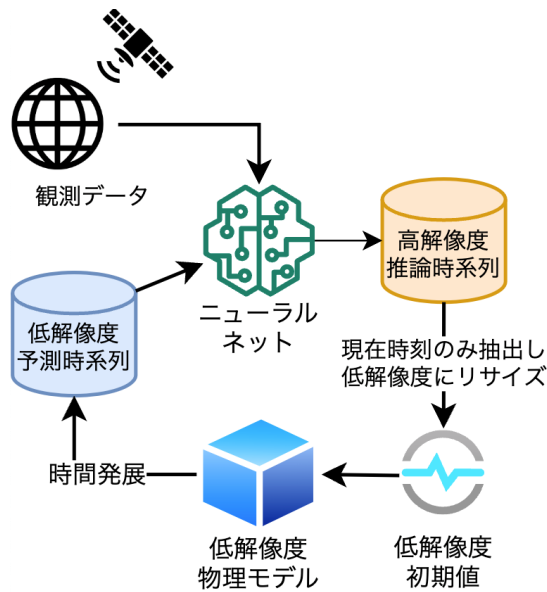


図 8: 4 次元超解像データ同化の模式図

図 9 は結果の例を表す。真の渦度分布は、教師データよりも 8 倍高解像度のシミュレーションから求めた。観測される格子点（図中の黒点）は疎なのにも関わらず、超解像と同化の両方が実現されている。その精度は、比較対象のアンサンブル・カルマンフィルタ (EnKF) よりも高い。また、ニューラルネットの推論時間は小さく、実質的に、低解像度のシミュレーションの計算時間で、高解像度の推論が得られた。




図 9: 超解像データ同化の結果の例。渦度の時間発展を表す。真の渦度分布中の黒点は、観測格子点を示す。EnKF はアンサンブル・カルマンフィルタより得られた推論である。この推論は超解像データ同化に対する比較対象である。

7. おわりに

本講義では、深層学習を用いた超解像により計算

負荷を下げ、リアルタイム微気象予測を実現しようとする試みを紹介した。超解像シミュレーション法 [6] では、低解像度の微気象モデルで時間発展を計算し、ニューラルネットにより高解像度化を行う。都市における微気象では、ビルなどの障害物の形状が解像度に依存することが難点であった。すなわち、高解像度化と欠損域の流れの構築を同時に行う必要がある。この難点は画像修復技術 (image inpainting) により克服した [16]。また、データ同化と超解像を組み合わせる基礎研究にも触れた [19]。

現在、我々は基礎技術を組み合わせ、超解像シミュレーション・システムの試作を行っている。また、超解像データ同化を発展させ、生成モデルによる教師なし学習法の研究も進めている。このような技術発展の先に、近い将来、リアルタイム微気象予測が実現されるであろう。近未来都市では、この微気象予測とドローンや熱環境の制御が組み合わさり、より便利で安全な社会が訪れると期待される。

参考文献

- [1] T. Foken, *Micrometeorology*, Springer (2017).
- [2] T. Kamiya, R. Onishi, S. Kodera, A. Hirata, Estimation of time-course core temperature and water loss in realistic adult and child models with urban micrometeorology prediction, *Int. J. Environ. Res. Public Health* 16 (24) (2019) 106-120.
- [3] I. Alabdulmohsin, B. Neyshabur, X. Zhai, Revisiting Neural Scaling Laws in Language and Vision, *NeurIPS* (2022).
- [4] M. Weiler, M. Geiger, M. Welling, W. Boomsma, T. Cohen, 3D Steerable CNNs: Learning Rotationally Equivariant Features in Volumetric Data, *NeurIPS* (2018).
- [5] C. Dong, C. C. Loy, K. He, X. Tang, Image Super-Resolution Using Deep Convolutional Networks, *ECCV* (2014).
- [6] R. Onishi, D. Sugiyama, K. Matsuda, Super-resolution simulation for real-time prediction of urban micrometeorology, *SOLA* 15 (2019) 178-182.
- [7] F. Giorgi, W. J. Gutowski, Regional dynamical downscaling and the cordex initiative, *Annu. Rev. Environ. Resour.* 40 (1) (2015) 467-490.
- [8] D. Maraun, M. Widmann, *Statistical Downscaling and Bias Correction for Climate Research*, Cambridge

- Univ. Press (2018).
- [9] Y. Wu, B. Teufel, L. Sushama, S. Belair, L. Sun, Deep learning-based super-resolution climate simulator-emulator framework for urban heat studies, *Geophys. Res. Lett.* 48 (19) (2021) e2021GL094737.
- [10] J. Wang, Z. Liu, I. Foster, W. Chang, R. Kettimuthu, V. R. Kotamarthi, Fast and accurate learned multiresolution dynamical downscaling for precipitation, *Geosci Model Dev.* 14 (10) (2021) 6355-6372.
- [11] K. Takahashi, R. Onishi, Y. Baba, S. Kida, K. Matsuda, K. Goto, H. Fuchigami, Challenge toward the prediction of typhoon behaviour and down pour, *J. Phys. Conf. Ser.* 454 (2013) 817 012072.
- [12] K. Matsuda, R. Onishi, K. Takahashi, Tree-crown-resolving large-eddy simulation coupled with three-dimensional radiative transfer model, *J. Wind. Eng. Ind. Aerodyn.* 173 (2018) 834 53-66.
- [13] Y. Yasuda, R. Onishi, Rotationally equivariant super-resolution of velocity fields in two-dimensional flows using convolutional neural networks, <https://arxiv.org/abs/2202.11099v2> (published version: <https://doi.org/10.1063/5.0132326>).
- [14] Y. Yasuda, R. Onishi, Y. Hirokawa, D. Kolomenskiy, D. Sugiyama, Super-resolution of near-surface temperature utilizing physical quantities for real-time prediction of urban micrometeorology, *Build. Environ.* 209 (2022) 108597.
- [15] J. Hu, L. Shen, S. Albanie, G. Sun, E. Wu, Squeeze-and-Excitation Networks, *CVPR* (2018).
- [16] Y. Yasuda, R. Onishi, K. Matsuda, Super-resolution of three-dimensional temperature and velocity for building-resolving urban micrometeorology using physics-guided convolutional neural networks with image inpainting techniques, *Build. Environ.* 243 (2023) 110613.
- [17] J. Yu, Z. Lin, J. Yang, X. Shen, X. Lu, T. S. Huang, Free-form image inpainting with gated convolution, *ICCV* (2019).
- [18] L. Schweri, S. Foucher, J. Tang, V. C. Azevedo, T. Günther, B. Solenthaler, A physics-aware neural network approach for flow data reconstruction from satellite observations, *Front.Clim.* 3 (2021).
- [19] Y. Yasuda, R. Onishi, Spatio-Temporal Super-Resolution Data Assimilation (SRDA) Utilizing Deep Neural Networks with Domain Generalization Technique Toward Four-Dimensional SRDA, <https://arxiv.org/abs/2212.03656> (preprint).
- [20] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, I. Polosukhin, Attention Is All You Need, *NeurIPS* (2017).