

「恐竜」襲来と気象・気候予測研究

榎本剛（京大防災研）

はじめに

2022年頃から、現業予報機関が作成している全球予報と同等ないしはより高精度な機械学習（ML, machine learning）モデルを構築したとする報告がされている。本稿では、MLモデルが気象・気候予測研究に与える影響を論じる。一般的にはAI（artificial Intelligence）予報とも呼ばれており、大規模言語モデルと類似した手法を用いているものもあるが、数値天気予報に特化しており、「知能」ではないので、本稿では以下MLモデルと呼ぶ。

純粋なMLモデル

MLモデルの仕組みは多種多様である。FourCastNet (Pathak et al. 2022) は、無限次元の関数の動作を模倣するニューラル演算子（NO: Neural Operator, Li et al. 2020）に基づいている。Fourはフーリエ変換（Fourier transform）を用いたフーリエニューラル演算子（FNO: Fourier Neural Operator, Li et al. 2021）に由来している。FNOを拡張した球面ニューラル演算子は浅水波モデルとMLモデルに適用され、従来のMLモデルができなかった約1年間に互る長期積分を実現した（Bonev et al. 2023）。

Pangu-Weather (Bi et al. 2023) は、階層的Vision TransformerであるSwin Transformer (Liu et al. 2021)に基づき、3次元の地球に特化したものである。GraphCast (Lam et al. 2023) は16層のグラフニューラルネットワークを用い、正二十面体を再分割した多重網のグラフによりさまざまなスケールの情報伝達を行う。Pangu-WeatherとGraphCastは、それぞれ7日及び10日予報で欧州中期予報センター（ECMWF: European Centre for Medium-range Weather Forecasts）の高解像度予報HRESの精度を超えたとしている。

これらの機械学習モデルは、物理的一貫性に欠けることが指摘されている。例えば、Pangu-Weatherでは、温帯低気圧や熱帯低気圧付近の非地衡風が5日間で非現実的に時間発展することか

ら、総観スケール以下やメソスケールを物理的一貫性を持って忠実に再現することはできない（Bonavita 2024）。

ハイブリッドMLモデル

ハイブリッドMLモデルは、力学コアと機械学習した物理過程から構成されている。NeuralGCM (Kochkov et al. 2024) は、力学コアにスペクトルモデルdinosaur（恐竜）を採用し、スペクトル空間において時空間スケールを粗いものから細かいものに変化させながら学習を行っている。力学コアを用いることにより、物理的一貫性を向上させ、アンサンブル予報及び数十年間の長期積分が可能になり、ECMWF現業アンサンブルENS同等の精度を得たとしている。

経験的なパラメタリゼーションの代わりに、個別に要素分解せず物理過程全体をホリスティックに扱い、バイアスが極めて小さくすることに成功している。バイアスが小さくても、現実から乖離していくので、カオスを乗り越えたわけではないが、10日程度の総観規模の気象予測には、物理モデルよりも高精度な予測が得られる。ハイブリッドモデルによるアンサンブル予測は、モデルバイアスに起因する誤差が低減されるため、大気のカオス性をより明示的に表現できる可能性がある。アンサンブル予測は、データ同化や感度解析に用いることができる。長期積分ができるので、気候変動研究に用いることも可能である。

また、NeuralGCMの力学コアが既存の物理モデルと異なる点は、微分可能であることである。機械学習ライブラリJAXを用いて書かれており、JAXが持つ自動微分により、誤差逆伝播（随伴計算）が可能である。機械学習においては、入力から出力まで（end-to-end）の学習を可能にする。微分可能であることは、随伴モデルを作成することなく、変分法データ同化が可能であること意味している。

寒波の予測実験

2020/2021年の年越しに（榎本 2021）日本域は寒波に見舞われた。日本域（120°E–150°E, 20°N–50°N）において2020年12月31日と2021年1月8日の2回、気温が極小となった。このうち予測が困難であった後者について、NeuralGCMで予報実験を行った。初期値はERA5（Hersbach et al. 2020）を用いた。

結果

決定論的予測（図1）において、29日からの10日予測（黒）では、ERA5が示す日本域の低温（青）を予測できている。ERA5との差は約0.5 Kである。これに対して12月28日からの11日予測（赤）では低温を予測できていない。これは気象庁の現業予測でも同様であり、両日の間に予測可能性の壁が存在することを示唆している。

次にERA5の10メンバを用いて28日からのアンサンブル予測を行った（図2）。アンサンブルメンバ（灰）の多くは低温を予測しており、アンサンブル平均（黒）は 2 K近い誤差があるものの、コントロール予測（赤）よりも改善している。ERA5のアンサンブルスプレッドは小さく、120時間予測（1月2日）ころまでコントロールや平均とほぼ重なっている。1月2日は、グリーンランド南端付近の低気圧（図3a）が29日からの4日予測では再現されたのに対し、28日からの5日予測では再現されなかった日に対応している（榎本 2021）。

アンサンブル予測データを用いて850 hPa面気温（図4a）の日本域平均（白棒）を重みとしたアンサンブル随伴感度解析を行った。1月6日には500 hPa面高度に北極域や亜寒帯ジェットに沿ったEUパターンに似た感度が見られる。1月4日にはグリーンランド東岸（図3b）の低気圧に対応した偏差が捉えられている。

まとめと議論

NeuralGCMはバイアスの少ない大気大循環モデルとして、寒波を精度よく再現した。スペクトル力学コアを含めることにより、力学的な一貫性を保ち、アンサンブル予報が可能であることを確認した。28日からの予測は初期時刻から5日後に29日から予測した日本域の平均気温から乖離し、アンサンブルがばらつき始め、低温の予測に失敗している。機械学習モデルの精度が良くても、予測可能




図1 ERA5（青）、2020年12月28日（赤）及び29日（黒）のそれぞれ 0000 UTCを初期時刻としたNeuralGCMにより予測された1000 hPa面における日本域（120°E–150°E, 20°N–50°N）の平均気温。横軸は28日0000 UTCからの時間




図2 図1と同様。黒はアンサンブル平均、灰色はアンサンブルメンバ

性の壁は依然として存在することを意味している。アンサンブルスプレッドは過小評価である可能性があるが、モデルのバイアスに起因する誤差成長から力学的な不安定性をより忠実に表現している可能性もある。アンサンブル感度解析の結果は、二つの海盆間におけるストームトラック活動の結びつきを示唆している。本研究で見出した北大西洋の低気圧が極域を通る道筋は、亜寒帯ジェットに加えて、顕著な気象の予測において重要であることが示唆される。

このようにハイブリッド機械学習モデルは、気象・気候予測研究に有用であるが、いくつかの限界も存在する。解像度は学習モデルに依存してい




図3 気象庁全球スペクトルモデル初期値の海面気圧 (hPa) 。2021年1月2日 (a)及び4日(b)

る。学習はGPUやTPUのようなアクセラレータを用いて行われ、メモリや計算量に制約される。多くの機械学習モデルの解像度は教師としている再解析の解像度の制約も受ける。この一部は統計的（超解像度）や力学的ダウンスケーリングで克服できる可能性がある。物理過程をホリスティックに扱ったことが成功の理由の一つであると考えられるが、予測誤差に対する個々の物理過程からの寄与を見積もることはできない。現象のメカニズムと予測可能性を研究するためには、物理パラメタリゼーションも必要であり、微分可能なフレームワークでこれらを構築することには意義がある。

モデル全体を微分可能に書き換えることにより、機械学習の効率化・高精度化に寄与するだけでなく、データ同化、モデル開発、メカニズム・予測可能性研究にも役に立つ。しかしながら、微分




図4 NeuralGCMによるERA5からのアンサンブル予測に基づく随伴感度解析。a) 1月8日850 hPa面気温、b) 1月6日及び c) 4日500面高度

可能モデルの構築には技術的課題がある。既存のモデルの多くに用いられているFortranで微分可能

なプログラミングを実践するのは困難である。機械学習フレームワークを用いて書きおなすか、コンパイラをFortranによる自動微分に対応させるかする必要はある。

参考文献

- Bi, K., L. Xie, H. Zhang, X. Chen, X. Gu, and Q. Tian, 2023: Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, **619**, 533–538, doi:10.1038/s41586-023-06185-3.
- Bonev, B., T. Kurth, C. Hundt, J. Pathak, M. Baust, K. Kashinath, and A. Anandkumar, 2023: Spherical Fourier neural operators: learning stable dynamics on the sphere. doi:10.48550/arXiv.2306.03838.
- Bradbury, and Coauthors, 2018: JAX: composable transformations of Python+NumPy programs. <http://github.com/google/jax>.
- Hersbach, H., and Coauthors, 2020: The ERA5 global reanalysis. *Quart. J. Roy. Meteor. Soc.*, **146**, 1999–2049, <https://doi.org/10.1002/qj.3803>.
- Kochkov, D., and Coauthors, 2024: Neural general circulation models for weather and climate. *Nature*, **632**, 1060–1066, doi:10.1038/s41586-024-07744-y.
- Enomoto, T., S. Yamane, and W. Ohfuchi, 2015: Simple sensitivity analysis using ensemble forecasts. *J. Meteor. Soc. Japan*, **93**, 199–213.
- 榎本剛, 2021: 2020/2021年越し寒波と極越え気流との関係. 日本気象学会2021年度春季大会, SP3-08+ 専門分科会3「気象庁データを利用した気象研究の現状と展望」, 2021/5/20, オンライン.
- Lam, R., and Coauthors, 2023: Learning skillful medium-range global weather forecasting. *Science*, **382**, 1416–1421, doi:10.1126/science.adi2336.
- Li, Z., N. Kovachki, K. Azizzadenesheli, B. Liu, K. Bhattacharya, A. Stuart, and A. Anandkumar, 2020: Neural operator: Graph kernel network for partial differential equations. doi:10.48550/arXiv.2003.03485.
- Li, Z., N. Kovachki, K. Azizzadenesheli, B. Liu, K. Bhattacharya, A. Stuart, and A. Anandkumar, 2021: Fourier neural operator for parametric partial differential equations. doi:10.48550/arXiv.2010.08895.
- Liu, Z., Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, and B. Guo, 2021: Swin transformer: hierarchical vision transformer using shifted windows. doi:10.48550/arXiv.2103.14030.
- Pathak, J., and Coauthors, 2022: FourCastNet: A global data-driven high-resolution weather model using adaptive Fourier neural operators. doi:10.48550/arXiv.2202.11214.