

深層学習を用いた北半球夏季季節内振動と 北西太平洋高気圧の予測と要因分析

前田優樹 (東京大学大気海洋研究所 佐藤研究室)

1. はじめに

北半球夏季季節内振動 (Boreal Summer Intraseasonal Oscillation; BSISO) は夏季に卓越する最も顕著な季節内振動の一つであり、冬季に卓越するマッデン・ジュリアン振動 (Madden-Julian Oscillation; MJO) と比較して、より複雑な構造をもって北インド洋から西太平洋へと北東進する。この対流変動に伴って、BSISO は回帰線内外の様々な現象に幅広い時間スケールで影響を与えるため、予測起源の解明はアジア夏季モンスーンシステムを理解する上で重要である。しかし、既存の数値モデルでは、その予測スキルと潜在的な予測可能性との間に大きな差がある。また、BSISO の変動が北西太平洋高気圧 (Western North Pacific Subtropical High; WNPSH) などの中緯度の循環場へ影響を与えることが示唆されているが、そのプロセスや予測可能性についての議論はなされていない。

本研究では、深層学習の 1 つである畳み込みニューラルネットワーク (Convolutional Neural Network; CNN) を用いて、1 ヶ月先までの BSISO 予測を行い、どのような要因が予測可能性の向上に寄与するかを解析した。さらに、BSISO の予測モデルを WNPSH の予測へ拡張し、BSISO が WNPSH の予測に与える影響を調べた。

2. CNN モデルによる BSISO の予測と要因

2.1 手法

まず、BSISO の予測可能性を調べるために、CNN モデルを用いたリアルタイム予測のフレームワークを提案した。教師データには、bimodal ISO index の real-time monitoring method (Kikuchi et al., 2012) を採用した。これにはまず、25-90 日のバンドパスフィルタを適用した OLR 偏差 (NOAA

の衛星観測データ) に対して、JJA 期間で Extended EOF (EEOF) 解析をすることで BSISO モード (EEOFs) を得た。BSISO の位相空間を構成する、主成分得点 PC1, 2 は、EEOFs に対して先行する時間の情報を含まない OLR 偏差場 (気候値、季節サイクル、前120日間平均を引き、前5日間平均を適用した場) を射影することで得た。

予測フレームワークは図1のように構築した。入力データ (a) には、上述の OLR に加えて、再解析データ (ERA5) として、850hPa, 200hPa の東西風 (U850, U200), 850hPa ジオポテンシャル高度 (H850), 可降水量 (PW), 海面水温 (SST) の6変数を用いた。各変数は PC1, 2 を得たときと同様の前処理を適用したのちに標準化した。CNN モデル (図 1b) は、3 層の畳み込み層、および1層の全結合層で構成し、2 つのユニットを出力するように設計した。これら出力をリードタイム τ 日後 ($\tau = 0, 1, \dots, 30$) の PC1, 2 に近づくように学習を行った。最適化には Adam を使用し、平均二乗誤差を損失関数とした。各層には活性化関数 ReLU, ドロップアウト, バッチ正規化を適用した。モデルはリードタイムごとに独立に作成し、それぞれ 10 メンバーのアンサンブル平均で予測値とした (図 1c)。学習は 1979-2015 年、検証には 2016-2022 年のデータを使用した。

2.2 モデルパフォーマンス

図2(a)に示すように、CNN モデルの予測スキルは、JJA, 8 月期間ともに現業数値モデルおよび全球非静力学モデル (NICAM) を上回り、COR = 0.6 となるスキルは約 29 日に達した。CNN モデルの予測スキルに関する初期 phase 依存性を調べた (図 2b-d)。初期 phase が 2-5 では 2 週間以降の予測で相対的にスキルが高い一方、初期 phase 6-8 ではスキルが低かった。




図1: BSISO をリアルタイム予測する CNN モデルの概要。(a)入力データは6変数 (OLR, U850, U200, H850, PW, SST) とする。(b) CNN アーキテクチャ。(c)位相空間上における CNN モデル予測の事例。




図2: CNNモデルのパフォーマンス。(a) BSISOのスキル。BSISOの初期 phase ごとの、(b)二乗平均平方根誤差、(c)振幅のエラー、および(d)phase のエラー。

2.3 XAIによる予測起源の解析

CNN モデルの予測根拠を定量化するために、XAI の手法に、Shapley Additive Explanations (SHAP: Lundberg and Lee, 2017) を採用した。本手法は、入力 $\mathbf{x}$ 、出力 $y = f(\mathbf{x})$ について、モデルの予測値 (PC1, PC2) を入力データの全グリッド i にわたってそれぞれの寄与度 ϕ_i に加法的に分解するアルゴリズムである:

$$f(\mathbf{x}) = \phi_0 + \sum_{i=1}^M \phi_i$$




図3: SHAP による入力変数の寄与度のリードタイム依存性

この解析を、検証データの JJA 期間に適用した。図3の予測起源の要約より、15日以降の予測では、PW, SST, U200 が第一に、U850, OLR が第二に支配的に寄与を示した。寄与度の初期 phase 依存性を調べると、SST は初期 phase2-4 の北インド洋の暖水域で支配的であり(図4)、BSISO の北進の駆動源を示唆した。一方で、PW は初期 phase5-6 の海洋大陸上で顕著に支配的であるものの、北インド洋での帯状偏差に対してはほとんど寄与せず、対流の東進への寄与を示唆する結果となった。

3. WNPSH への予測の拡張と BSISO との関係




図4: SHAP による SST の寄与度の初期 phase 依存性。PC1 の寄与(左)および入力変数の偏差(右)。

次に、BSISO と WNPSH を包括的に予測するマルチタスクモデルを構築した。学習データ量を増やすために、大規模アンサンブル大気モデル(d4PDF)による 1000 年のデータで事前学習したのちに、再解析データ(ERA5)でファインチューニングする転移学習を適用した。その結果、WNPSH の予測スキルは約 7 日程度と bimodal ISO index の予測と比べて短いものの、再解析データのみの学習に比べて精度が改善した。マルチタスク学習の結果から、高気圧性循環が西太平洋で卓越する BSISO の初期 phase2-3 では、WNPSH の予測スキルが比較的持続することがわかった。これにより、BSISO が WNPSH の予測可能性を決定する一因となることが示唆された。

4. まとめと今後の展望

本研究では、深層学習を用いて BSISO と WNPSH の予測と要因分析を行った。CNN モデルによる BSISO の予測は現業モデルを上回る精度を示した。スキルには初期 phase の依存性が見られたが、この差異が生まれる原因を XAI 手法によって解析したところ、北インド洋での SST 正偏差が BSISO の北進を、海洋大陸での PW が BSISO の東進を駆動させる要因となり、それが予測スキルの底上げを示唆する結果となった。次に、上述のタスクに、d4PDF の大規模データを利用したマルチタスクモデルへ拡張し、季節内スケールの BSISO と WNPSH の予測を行った。予測スキルは 7 日程度と短いものの、BSISO が WNPSH の予測可能性に影響を与えることを示唆した。WNPSH の変動には BSISO のみならず熱帯、中緯度の双方から多数の要因が幅広い時間スケールで関与するため、これらを考慮したモデルへの改良と予測可能性の分析が今後の課題である。

参考文献

- [1] Kikuchi, et al., 2012. *Clim. Dyn.* 38 (9-10), pp. 1989–2000.
- [2] Lundberg and Lee, 2017. *arXiv:1705.07874[cs.AI]*