

73. 風力ランプ発生時における 総観場の気候学的解析と確率的予測手法の開発

大庭 雅道^{1*}・野原 大輔¹・門倉 真二¹

¹一般財団法人電力中央研究所（〒270-1194 千葉県我孫子市我孫子1646）

* E-mail: oba-m@criepi.denken.or.jp

時空間的に複雑に変動する日本域の気象場と風力の急激な出力変動（ランプ現象）との関連性を理解するために、パターン分類手法の一種である「自己組織化マップ」を導入することによって、過去の日本域の風力ランプ現象に関連した気象パターンの分類を行った。分類には気象庁全球大気再解析データJRA-55の海面更正気圧を用いた。また、再解析データとの比較のため、気象の地上観測データから、経験式に基づいて東北電力管内の1977年-2013年の風力発電量を推定した。本データを、自己組織化マップによる過去の気象場のパターンと照らし合わせることで、ランプ発生時の気象場(要因)を俯瞰的に把握することができた。さらに、気象庁全球予報モデルの予報結果から東北管内の系統積算の風力発電量を予報する手法を検討した。

Key Words : self-organizing maps, wind ramp events, probabilistic forecast

1. はじめに

今後のエネルギー政策として、風力発電等再生可能エネルギーの最大限の導入を進めることが政府の目標として掲げられている。しかしながら、天候によって出力が大きく変動する風力発電は、大量に電力系統に連系された場合、電力の安定供給に悪影響を及ぼす可能性がある。今後、風力を最大限電力系統に連系するためには、電力の需給運用の安定に影響を与える急激な出力変動（ランプ現象）を予測する技術が不可欠である（e.g., Marquis et al. 2011）。本研究では、日本の東北域における風力ランプ発生時総観場の気候学的な解析と要因分析を行うとともに、気象庁等の全球モデル予報値に基づく風力ランプ発生の確率的予測モデルを構築した。

2. 解析手法とデータ

(1) 自己組織化マップ

本研究ではパターンの分類手法として、自己組織化マップ (Self-Organizing Map: SOM, Kohonen, 1982)を用いた。自己組織化マップはT. Kohonenによって提案された分類手法であり、空間を持った「マップ」の組み合わせで実現される人工ニューラ

ルネットワークの一種である。SOMには、任意次元のマップ上(本研究では二次元マップ)において、パターンを類似度に合わせて分類できるという特徴がある。この手法は工学・医学を初めとして様々な分野に応用されており、気候・気象の解析においても近年適用例が増えてきている(e.g., Leloup et al. 2007; Iseri et al. 2009)。Ohba et al. (2015a; 2015b)では、豪雨の発生環境についての気候学的知見に基づき、SOMを駆使して、豪雨の予測手法を開発を行っている。構築された豪雨診断・降雨予測手法では、雨量に関する予測結果だけでなく、気象状態のパターンが診断され、そのパターンと類似する過去のイベントを検索することが可能であることを示しており、地域的な確率豪雨予測に応用できることを示した。

SOMは通常、入力層と競合層から成る2層構造のニューラルネットワークを形成しており、入力層の入力ベクトル(分類したいデータ、ここでは気象場の空間分布)を基に反復学習することで、入力ベクトルの分布パターンを分類していく。競合層は参照ベクトルと呼ばれる多次元ベクトルを持つ任意の数のノードで表現されており、学習前の参照ベクトルは乱数で構成されている。入力ベクトルと参照ベクトルの差(ユークリッド距離)を取り、最も差の小さい(似ている)ノードを勝者ノードとし、勝者ノード





図-1 (上) 気象庁全球大気再解析データ JRA-55 における過去 37 年間の東北域周辺の SLP (hPa) を 20x20 の SOM により分類した結果。各ノード (気象場) における (下左) ランプアップ、(下右) ランプダウンの発生率 (%)。

ドとその近傍のノードが、より入力ベクトルに近づくように反復学習を行っていく。

(2) 解析手法

1977-2013 年の気象庁アメダスデータの風速と日射量の 1 時間値を使用して、過去 37 年間の東北電力管内定格発電率 (PU 値) の再構築を実施した。

データの連続性が比較的確保されかつ、観測の PU 値（東大生産研より提供）と風速の相関が高い 15 地点のデータから経験式とニューラルネットワークを構築することで PU を推定した。なお、ここで再構築された PU 値は人為影響のない、風速の代替指数である。再構築された PU 値と観測との相関係数は 0.94 と高く、ある程度信頼できる推定値を得ることができたと考えられる。6 時間先までの最大 PU 値/最小 PU 値と開始時刻の PU の差が 0.3 以上/ - 0.3 以下の場合をそれぞれランプアップ/ランプダウンと定義した。

気象場の解析には気象庁全球大気再解析データ JRA-55 (Ebita et al. 2011) の海面更正気圧 (SLP) の 3 時間ごとの瞬間値と前述の PU 推定値を使用した。東北の周辺域の SLP をトーラス型 SOM を用いて、 20×20 の 400 パターンに分類した。解析は 3 ヶ月間ごとに実施したが、東北域においてランプ現象発生数の多い、冬 (DJF) の結果のみを示す。

3. SOMによる風力ランプの解析結果

図1に 20×20 のSOMによる気象場の分類結果を示す。右端から左端にかけてSLPの低いパターン、上端から下端にかけてSLPの高いパターンが分類されている。各ノード（気象パターン）におけるランプアップ・ダウン発生確率（図1）およびPUの平均・最小・最大値（図省略）は、ノード間において大きなコントラストが見られており、風力発電量・変動量の気象パターンに対する依存性が極めて高いことがわかる。ランプアップの発生率が特に高い代表的な気象場として、①太平洋側低圧型（東側が低気圧による冬型強化）、②西高東低型（冬型強化）、③低気圧接近型（東北管内）、④逆転型（南東部が高気圧に覆われる）などが挙げられる。一方、ランプダウンの発生率が高い気象場として、①冬型弱化的型、②西部高気圧型（日本海が高気圧で覆われる）、③南北型などが挙げられる。また、ランプアップ・ダウンどちらの発生率も高いカットアウトが原因と思われるようなケースも見られた。このように、SOMによるSLPの分類から、ランプ現象発生時における気象場を俯瞰的に把握することができた。

4. 確率的予測手法の開発と精度検証

SOMにより構築された過去37年間の気象場とPUの非線形関係を予報ガイダンスとし（Perfect Prognosis）、JMA 20km GSMのSLP予報値に基づく経験的確率予測モデルを構築した。本手法では、複数SOM上の予報値に対するbest-match node からその気象場におけるランプ発生確率・PU値の確率分布




図-2 JMA-20km GSM に基づく確率的ランプ予測の例（上）PU の観測値と予測値とその確率分布。（中）ランプアップ・ダウン発生確率（%：棒グラフ）。実線は現実・予測のランプ判定。（下）PU の 6 時間最大増加・減少値（50 & 95 percentile）。実線は現実・予測の最大増加・減少値。

を（複数の確率分布の合算として）推定する（Ohba et al. 2015a）。図2にその結果例を示す。本手法におけるランプ予測によって、ある程度PU確率幅とその変化、ランプ発生の可能性が推定できることがわかる。

5. まとめ

風力な変動パターンを示す広域の気象場に基づいて発生している。本研究では、自己組織化マップを用いて、風力ランプをもたらす広域気象パターンの抽出し、予測モデルの開発に応用した。本研究から複雑な変動を示す日本域周辺の気象場の抽出と長期的な変化傾向の理解において、SOMが有効であることが確認された。

謝辞：本研究は、新エネルギー・産業技術総合開発機構（NEDO）「電力系統出力変動対応技術研究開発事業」の支援により実施された。

参考文献

- 1) Ebita, A., S. Kobayashi, Y. Ota, M. Moriya, R. Kumabe, K. Onogi, Y. Harada, S. Yasui, K. Miyaoka, K. Takahashi, H. Kamahori, C. Kobayashi, H. Endo, M. Soma, Y. Oikawa, and T. Ishimizu, 2011: The Japanese 55-year Reanalysis "JRA-55": an interim report, SOLA, 7, 149-152.
- 2) Iseri Y., T. Matsuura, S. Iizuka, K. Nishiyama, and K. Jinno, 2009: Comparison of pattern extraction capability between self-organizing maps and principal component analysis. *Memoirs of Faculty Engineering, Kyushu Univ.*, 69, No.2, 37-47.
- 3) Kohonen, T., 1982: Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43, 59-69.
- 4) Leloup J. A., Zo. Lachkar, J. P. Boulanger, and S. Thiria, 2007: Detecting decadal changes in ENSO using neural networks. *Clim. Dyn.*, 28, 147-162.
- 5) Marquis, M., J. Wilczak, M. Ahlstrom, J. Sharp, A. Stern, J. C. Smith, and S. Calvert, 2011: Forecasting the wind to reach significant penetration levels of wind energy. *Bull. Amer. Meteor. Soc.*, 92, 1159–1171.
- 6) Ohba, M., D. Nohara, Y. Yoshida, S. Kadokura and Y. Toyoda, 2015: Anomalous Weather Patterns in Relation to Heavy Precipitation Events in Japan during the Baiu season, *Journal of Hydrometeorology*, 16, 688-701.
- 7) Ohba, M., D. Nohara, S. Kadokura and Y. Toyoda, 2015: Rainfall Downscaling of Weekly Ensemble Forecast using Self-Organizing Maps, submitted for *Inter. J. Clim.*.