

物理モデルとマルチタイムスケールモデルに基づく風力発電出力予測

Wind Power Forecasting with Physical Model and Multi Time Scale Model

○ 山口 敦¹⁾ 榎木 康太¹⁾ 石原 孟¹⁾ 福本 幸成²⁾
 Atsushi YAMAGUCHI¹⁾ Kota Enoki¹⁾ Takeshi ISHIHARA¹⁾ Yukinari FUKUMOTO²⁾

1. はじめに

電力系統においては需要と供給の一致が要求されるが、風力発電出力は風速に応じて変動するのに加え、出力変動をあらかじめ知ることができないため、実際の系統運用において不確実性の一因となっている。この問題を解決するため数値気象予報に基づく風力発電出力予測が各国で試みられている。地形が複雑な我が国ではメソスケールモデル等の物理モデルを用い、数値気象予報データをダウンスケールすることが必要とされているが、物理モデルがどのような誤差の低減に効果的かは明らかにされていない。さらに風力発電所では風車の故障等により予期しない出力の低減がしばしば見られるが既存の出力予測モデルではこのような現象を考慮できない。

そこで本研究では各種物理モデルが誤差の低減に与える効果を定量的に評価するとともに、風車の運転状況を考慮した発電出力予測モデルを構築し、検証を行った。

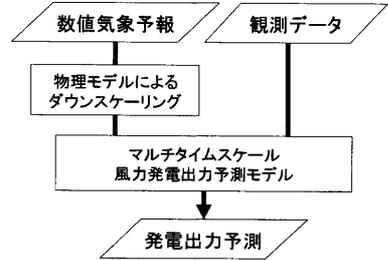


図1 発電出力予測システムの概要

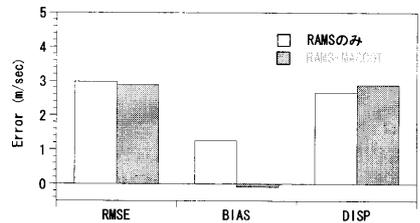


図2 ダウンスケーリング手法別の予測誤差とその成分

2. 観測地点および発電出力予測システム

本研究では(株)東京電力の八丈島風力発電所を対象とし、風速、風向、発電出力をインターネットを通じてリアルタイムに取得するシステムを構築し、発電出力の予測を行った。

本研究で構築した予測モデルの概略を図1に示す。モデルの入力は気象庁提供の数値気象予報データと風力発電所における風向・風速・発電出力の実測データである。まず、数値気象予報データを物理モデルにより局所地形を考慮した風速にダウンスケールする。次に本研究で提案するマルチタイムスケール風力発電出力予測モデルによりリアルタイム観測データを反映した発電出力の予測を行う。

3. 物理モデルによるダウンスケーリング

気象庁提供の数値気象予報データの解像度は約20kmと粗いためメソスケール気象モデル RAMS¹⁾により空間解像度1kmにダウンスケールする。さらに非線形風況予測モデル MASCOT²⁾を組み合わせ、水平解像度50mにダウンスケールを行った。こ

れら2つの予測モデルの結果に対し式(1)に示す平均二乗誤差 RMSE を計算した。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (u_i^{pred} - u_i^{meas})^2}{n}} \quad (1)$$

ここで u_i^{pred} , u_i^{meas} はそれぞれ風速の予測値、観測値、 n は予測の回数である。RMSE は式(3)から(4)で示されるバイアス(bias)、標準偏差のバイアス(sdbias)及び分散(dis)の各成分に分解することが可能である。

$$RMSE^2 = bias^2 + sdbias^2 + disp^2 \quad (2)$$

$$bias = \overline{u^{Pred} - u^{Meas}} \quad (3)$$

$$sdbias = \sigma(u^{Pred}) - \sigma(u^{Meas}) \quad (4)$$

$$disp = \sqrt{2\sigma(u^{Pred})\sigma(u^{Meas})(1 - r(u^{Pred}, u^{Meas}))} \quad (5)$$

ここで $\sigma(u^{Pred})$, $\sigma(u^{Meas})$ はそれぞれ予測値、観測値の標準偏差を示し、 $r(u^{Pred}, u^{Meas})$ は観測値と予測値の相互相関を示す。図2に RAMS のみを用いた場合と RAMS 及び MASCOT を用いた場合の RMSE および

¹⁾ 東京大学大学院工学系研究科 School of Engineering, The University of Tokyo

²⁾ 東京電力技術開発研究所 Tokyo Electric Power Company

bias, disp 成分を示す. 高解像度の物理モデルにより減少する誤差は主にバイアス成分であることがわかる.

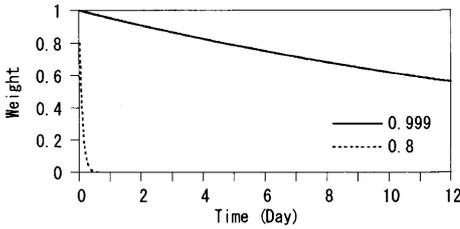


図3 忘却係数λに対する過去の時間別の重み

4. マルチタイムスケール発電出力予測モデル

一般的に風力発電出力予測モデルは風速の予測値と最新の出力の観測値とを用いて予測を行う³⁾. 具体的には, 時刻 t における $t+k$ に対する出力予測値($P_{t+k|t}^{For}$)は, パワーカーブモデルにより風速予測値から求めた出力予測値($P_{t+k|t}^{PC}$)と, 発電出力の最新の観測値(P_t^{Obs})とを式(6)により組み合わせることにより求める.

$$P_{t+k|t}^{For} = a^k \times P_{t+k|t}^{PC} + b^k \times P_t^{Obs} \quad (6)$$

ここで a^k および b^k は予測時間 k に依存するモデルパラメータであり, 本研究では忘却係数付き逐次最小二乗法(RLSEF法)により過去のデータを用いて推定した. RLSEF法においては忘却係数 λ を用い, 過去データの重みを調整する. 本研究では a^k および b^k の推定には $\lambda=0.999$ を用いた. このとき, 対応する時間スケールは約2.8ヶ月であり(図3), 緩やかな変化に対応してパラメータの値が変化します.

しかしながら実際の風力発電所は機械の故障, 事故, メンテナンス等によりもっと短いスケールでみかけのパワーカーブが変化することがある. そこで研究ではパワーカーブモデルに風車の運転状況を考慮するための新たなパラメータを導入した.

$$P_{t+k|t}^{PC} = c \times f^{PC}(u_{t+k|t}^{For}) \quad (7)$$

ここで f^{PC} はパワーカーブ, $u_{t+k|t}^{For}$ は風速予測値, c は風車の運転状況を表すパラメータであり, RLSEF法を用いて推定する. c は1日以内の比較的短い時間に変化することが期待されるため, 時間スケール2.5時間に対応する忘却係数 $\lambda=0.8$ (図3)を用いて過去のデータから推定した.

以上提案したモデルを八丈島風力発電所における実測データを用い検証した. 図4は2004年7月下旬の発電出力の実測値と各時刻の3時間前に予測した

3時間先予測値を示す. 2004年7月28日午後6時頃八丈島に台風10号が接近し強風のため風車が停止した. 従来のモデルでは風車の停止にも関わらず出力を予測しているが, 本モデルでは風車の停止を検出し, それに応じた予測を行っている.

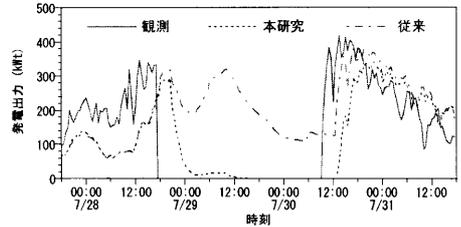


図4 2004年7月後半の3時間先予測の比較

この結果, 月別の予測誤差に大きな改善が見られた. 図5は2004年5月1日から2005年4月30日の1年間における月別の予測誤差を示す. 風車の稼働率が約19%と低かった2004年8月には既存モデルに比べ74%の改善がみられた.

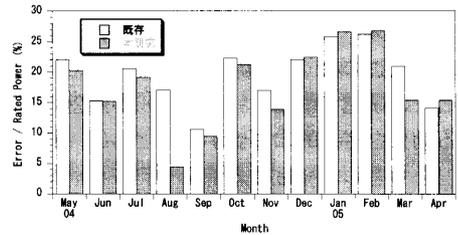


図5 2004年5月から1年間の月別短期予測誤差

5. まとめ

本研究では, 風車の運転状況を考慮可能な風力発電出力予測モデルを構築し, 以下の結論を得た. 1) 物理モデルによるダウンスケリングは主に予測の平均誤差成分を減少させる. 2) 風車の運転状況を反映させるマルチタイムスケールモデルにより月別の予測誤差が最大74%改善し, 稼働率が低い場合の予測に有効なことが分かった.

参考文献 1) R. A. Pielke et al., A Comprehensive Meteorological Modeling System - RAMS, *Meteorol. Atmos. Phys.*, Vol. 49, pp. 69-91, 1992. 2) Ishihara, T. and Yamaguchi, A., A Dynamical Statistical Downscaling Procedure for Wind Climate Assessment, European Wind Energy Conference 2003, 2003. 3) Nielsen, T.S., H. Madsen, and J. Tøfting: Experiences with Statistical Methods for Wind Power Prediction. Proceedings of the European Wind Energy Conference, Nice, France, 1-5 March 1999, pp. 1066-1069.