

風速予測モデルの検討と カルマンフィルタに基づく短期風力発電予測

石川友規 滑川徹 (慶應義塾大学)

Short-Term Wind Speed Prediction for Wind Turbine Applications using Filtering Theory

*T. Ishikawa, T. Namerikawa (Keio Univ.)

Abstract— In this paper, 24 hours ahead power prediction method using a filtering theory is proposed for wind power generation. In recent years, an introductory expansion of renewable energy is expected and the prediction of wind power generation is needed for taking in wind power generation. First, four kinds of wind speed prediction models is considered. Next, the wind power generation is predicted based on the optimal wind speed model and kalman filter. Finally, the advantage of the proposed method can be shown, compared with the conventional method.

Key Words: wind speed and wind power forecast, prediction control, kalman filter

1 はじめに

地球温暖化対策の有力な手法の一つとして、再生可能エネルギーを導入したスマートグリッドの研究が盛んである。スマートグリッドは太陽光発電、風力発電などの直接制御不可能な再生可能エネルギーと、様々な発電、消費システムが結合している大規模複雑系となっている¹⁾。

このような分散システムにおいて、系統への影響を抑制するため、従来から風力発電は出力一定制御を行っている。翌日までの発電量予測値に基づき風力発電出力と蓄電池充放電量の合計出力が、事前通告通り一定出力になるよう制御する方法である。発電量予測値には誤差が含まれるため、事前通告値を守るためには高価な蓄電池を多量に設置するか、発電量予測値よりも低めに通告し、発電量が多くなる場合には出力制限する必要がある。

もし精度の高い風力発電量予測値が得られれば、事前通告通りに制御できる。また、頻度多く予測値が更新できれば、予測がはずれた場合に事前通告値を変更することが可能になる。

従来の風力発電予測の手法は 2 つのカテゴリーに大別することができる。1 つは物理モデルに基づく方法であり、Numerical Weather Prediction(NWP) が良く知られている。これら物理モデルに基づく方法は、予測を行うために多くの物理現象を考慮する必要がある。もう一つは ARMA Model などに代表されるような統計に基づく手法である。これは過去の測定データと現在のデータから未来のデータを予測する手法である。その中でも Box-Jenkins モデルとして知られる ARMA Model に基づく手法²⁾ や、Neural Network に基づく手法^{3) 4)} が盛んに研究されている。谷口ら⁵⁾ や、角田ら⁶⁾ は Neural Network による風速予測、発電予測を行っている。藤村ら⁷⁾ による手法では、予測に用いる入力データとして、(財) 気象業務支援センターから配信されるメゾ数値予報モデルの GPV データの利用に着目し、ファジィ推論を用いた 9 時間先の風力発電出力予測モデルを構築している。細田⁸⁾ は、統計モデルの中でカルマンフィルタを用いた太陽光発電予測を行っ

ており、この研究を参考にし太陽光に比べきわめて難しい風力発電予測を行う。

そこで本稿では、文献⁸⁾を基に予報値を統計的に補正する方法を用いた。予測モデルを状態空間モデルに変換し、カルマンフィルタを用いて予測モデルのパラメータ推定を行う。推定方法の特徴として、雑音を仮定し、予測誤差が最小となるようなゲインの設定により予想精度の向上を図る手法である。この手法では、パラメータ推定誤差に対しより正確な推定が可能であり、本研究の目的に適している予測手法である。さらに、風速予測モデルは 4 種類用意し、モデル毎に予測誤差の大きさを比較する。その結果、誤差の小さいモデルを用いて予測した風速予測値をパワーカーブに当てはめることで、風力発電予測値を求める。本稿では、カルマンフィルタを用いた風力発電予測の有効性を文献⁶⁾と比較し検証する。

2 問題設定

過去の平均風速のデータや、気象予報の風速データ等を風速モデルに代入し、統計処理をしてモデルの未知係数パラメータを推定する。統計処理の手法は線形手法の一つであるカルマンフィルタ (Kalman Filter) による方法を用いる。その後、風速の推定値を基に、風力発電出力を求め、最終的に風力発電機の出力予測を行う。

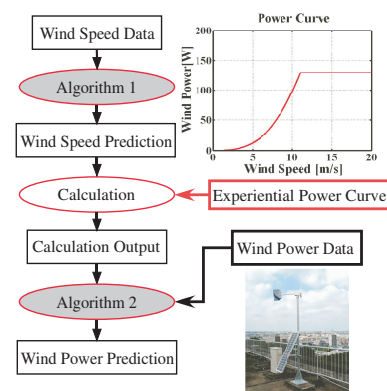


Fig. 1: Wind Power Prediction Process⁹⁾

2.1 予測モデル

風速データは気象庁のアメダス¹⁰⁾による降水量, 風向, 風速, 気温, 日照時間などの観測データの中から横浜市の風速のデータを使用した。データのサンプリング時間の間隔は1時間とする。過去の平均風速のみに基づく風速モデルを以下のように設定する。

$$\hat{y}_{t+1|t} = a_1 y_{t|t} + \cdots + a_{12} y_{t-12|t-12} \quad (1)$$

t は $t = 1 \cdots 12$ すなわち 12 時間に一致する。 $y_t[\text{m/s}]$ は時刻 $t[\text{h}]$ における風速であり, $y_{t|t}$ は, 時刻 $t[\text{h}]$ までのデータを基にした時刻 t の風速の値である。 $\hat{y}_{t+1|t}$ は時刻 t までのデータを基にした 1 ステップ後, つまり 1 時間後の風速の推定値である。 a_1, \cdots, a_{12} は時刻 t における風速係数である。このモデルに対し, 過去のデータを基にカルマンフィルタを用いた推定アルゴリズムを用いることで, a_1, \cdots, a_{12} を推定する。

2.2 1 時間予測と 24 時間予測

本稿では 1 時間毎に予測して 24 時間分予測している場合と, 24 時間先までをまとめて予測している場合とに分けられる。その違いがわかりにくいので簡単に Fig. 2, 3 を用いて説明する。




Fig. 2: Hour ahead Prediction




Fig. 3: Day ahead Prediction

1 時間毎の予測

- 最初の予測

$$\hat{y}_{t+1|t} = a_1 y_{t|t} + \cdots + a_{12} y_{t-12|t-12}$$

- 1 ステップ後

$$\hat{y}_{t+2|t+1} = a_1 \hat{y}_{t+1|t} + \cdots + a_{12} y_{t-11|t-11}$$

- 24 ステップ後

$$\hat{y}_{t+24|t+23} = a_1 \hat{y}_{t+23|t+23} + \cdots + a_{12} \hat{y}_{t+11|t+11}$$

24 時間予測

- 最初の予測

$$\hat{y}_{t+1|t} = a_1 y_{t|t} + \cdots + a_{12} y_{t-12|t-12}$$

- 1 ステップ後

$$\hat{y}_{t+2|t+1} = a_1 \hat{y}_{t+1|t} + \cdots + a_{12} y_{t-11|t-11}$$

- 23 ステップ後

$$\hat{y}_{t+24|t+23} = a_1 \hat{y}_{t+23|t+23} + \cdots + a_{12} \hat{y}_{t+11|t+11}$$

このように, 1 時間毎の予測の際には 1 時刻前にわかる 12 時間前までのデータを全て使っている。24 時間予測の場合は 12 時間前までの推定値を使い予測を行うことになる。

2.3 予測アルゴリズム

風速係数のパラメータを推定するアルゴリズムについて述べる。パラメータ推定には次のような離散時間状態空間表現を用いる。

$$\mathbf{x}_{k+1|k} = \mathbf{A}_k \mathbf{x}_{k|k} + \mathbf{w}_k \quad (2)$$

$$y_{k|k} = \mathbf{C}_k \mathbf{x}_{k|k} + v_k \quad (3)$$

ここで, $\mathbf{x}_{k|k} \in \mathbb{R}^{n_x}$ は時刻 k における推定対象の状態ベクトルで, 次のような係数の行列で定義される。

$$\mathbf{x}_{k|k} = [a_1 \cdots a_{12}]^T \quad (4)$$

$\mathbf{C}_k \in \mathbb{R}^{n_x}$ は時変出力ベクトルでここでは以下のような値とする。

$$\mathbf{C}_k = [y_{k|k}^{mean} \cdots y_{k-12|k-12}] \quad (5)$$

$\mathbf{A}_k \in \mathbb{R}^{n_x}$ は以下のように設定した。

$$\mathbf{A}_k = \mathbf{I}_k \quad (6)$$

$k \in \mathbb{Z}_+$ は時刻, $y_{k|k} \in \mathbb{R}$ は観測値, $\mathbf{w}_k \in \mathbb{R}^{n_x}, v_k \in \mathbb{R}^{n_x}$ は状態ノイズと観測ノイズを表わす。雑音はガウス性の白色雑音で以下のように仮定する。

$$E \left\{ \begin{bmatrix} \mathbf{w}_k \\ v_k \end{bmatrix} \begin{bmatrix} \mathbf{w}_l^T & v_l^T \end{bmatrix} \right\} = \begin{bmatrix} W_k & 0 \\ 0 & V_k \end{bmatrix} \delta_{kl} \quad (7)$$

また分散行列 $V_k \in \mathbb{R}$, $W_k \in \mathbb{R}$ は既知であるとする。以上の方程式を用いて係数を推定するためのカルマンフィルタのアルゴリズムは次のような再帰的な計算で得ることができる。これら式 (2) ~ (7) に基づき, カルマンフィルタを用いたパラメータ推定を行う。

1. カルマンゲインの更新

$$\mathbf{K}_k = [\mathbf{P}_{k|k-1} \mathbf{C}_k^T] [\mathbf{C}_k \mathbf{P}_{k|k-1} \mathbf{C}_k^T + W_k]^{-1} \quad (8)$$

2. 状態推定値の更新

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + K_k [\mathbf{y}_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1}] \quad (9)$$

3. 推定誤差共分散行列の更新

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - K_k \mathbf{C}_k \mathbf{P}_{k|k-1} \quad (10)$$

$\mathbf{P}_k \in \mathbb{R}^{n_x \times n_x}$ は時刻 k での推定誤差共分散行列で、 $K_k \in \mathbb{R}$ はカルマンゲインである。ここで、 $\hat{\mathbf{x}}_{k|k-1}$ は 1 ステップ前までのデータにより求められる係数の推定値である。以上の手順 1-3 を複数回繰り返すことで式 (1) の係数である式 (4) を推定することができる。

2.4 予測目的

風速の予測では、その評価として相対絶対誤差 (MAE) を用いて評価する。これを式として表わしたものを以下に示す。ここで、 $y_{k|k}$ は実測値、 $\hat{y}_{k+1|k}$ はモデルによる推定値、 $N \in \mathbb{Z}_+$ はデータ数を示す。

$$MAE = \frac{1}{24} \sum_{t=1}^{24} \frac{||y_{t+1|t+1} - \hat{y}_{t+1|t}||}{y_{t|t}} \quad (11)$$

本稿における短期予測の場合には 1 時間毎の風速の相対誤差を元に 24 時間先までの予測の評価を行う。

3 風速予測

この節では、風速予測モデルの検討を行う。具体的には以下の 4 つのモデルについて考察する。

1. 平均風速のみのモデル
2. 平均風速と最大瞬間風速と突風率と変化率のモデル
3. 風向を考慮したモデル
4. 気象予報と過去の風速によるモデル

上記の 4 つモデルについて、比較、検討を行い、最適な風速モデルを選ぶ。データの制約上、2 番目と 3 番目のモデルに関しては、1 時間毎の予測しか行えない。

3.1 モデル 1: 平均風速のみのモデル

前節のパラメータ推定の例で扱ったモデルが過去の平均風速のみのモデルとなる。

$$\hat{y}_{t+1|t} = a_1 y_{t|t} + \dots + a_{12} y_{t-12|t-12} \quad (12)$$

このモデルでは過去の 1 時間当たりの平均風速のデータしか使われない。ここでは 12 時間分のデータを基にしたモデルを提案する。

3.2 モデル 2: 平均風速と最大瞬間風速と突風率と変化率のモデル

平均風速と相関関係のありそうなパラメータを考える。文献¹¹⁾より比較的相関のありそうな気温、最大瞬間風速、突風率 (= 最大瞬間風速/平均風速)、風速の変化率の相関を調べてみた結果が以下の Table 1 となる。データは気象庁で公表されている 2011 年 9 月から 12 月の横浜の気象台での計測データを用いている。

この相関の値より、気温はあまり相関がないことがわかる。最大瞬間風速は相関が大きく、突風率や変化率は

Table 1: Correlation with Wind Speed

Temperature	Maximum Speed	Gust	Displacement
0.204	0.857	-0.368	0.318

少し相関があるようである。以上のことから以下のようなモデルを作った。

$$\begin{aligned} \hat{y}_{t+1|t} = & a_1 y_{t|t} + a_2 y_{t-1|t-1} + a_3 y_{t-2|t-2} \\ & + b_1 y_{t|t}^{max} + c_1 y_{t|t}^{gust} \\ & + d_1 (y_{t|t} - y_{t-1|t-1}) \end{aligned} \quad (13)$$

本稿では 24 時間先の予測を目的としているため、1 時間毎の風速データをもとに 24 時間先の平均風速を求める。 $y_{t|t}$ は 1 時間ごとにサンプリングされた平均風速の時系列のデータを用いた。 $\hat{y}_{t+i|t}$ は、時刻 t までのデータを基にした i 時間先の風速の推定値である。また他のパラメータはそれぞれ、 $y_{t|t}^{max}$ が最大瞬間風速、 $y_{t|t}^{gust}$ が突風率、 $y_{t|t}^{mean} - y_{t-1|t-1}^{mean}$ が変化率を示している。 $a_1, a_2, a_3, b_1, c_1, d_1$ は風速係数である。

3.3 モデル 3: 風向を考慮したモデル

このモデルでは風向きを考慮したモデルを作った。神奈川県横浜市は以下のような Fig. 4 の場所に位置する。風は伝播しているということに視点を置いて考えると、



Fig. 4: Map of Kanto

例えば北風というのは北の地域から吹いており北の地点での過去の風速が伝播している。すなわち、風の吹く方向、風向を考慮したモデルを考えてみる。横浜の東西南北の気象台のデータを用いて風速を予測しようということである。そこで Fig. 4 の 4 つの気象台での風速データと横浜での風速データの相関について Table 2 にまとめた。

Table 2: Correlation with Wind Speed

Tokyo	Kisarazu	Miura	Ebina
0.564	0.557	0.624	0.650

この Table 2 から、どの場所も相関があることがわかった。また、距離が近いほど相関があることもわかる。この結果を踏まえ、モデルは以下のようにした。

$$\hat{y}_{t+1|t} = a_1 y_{t|t} + b_1 y_{t|t}^{use} + b_2 y_{t-1|t-1}^{use} + b_3 y_{t-2|t-2}^{use} \quad (14)$$

$y_{t|t}$ は 1 時間ごとにサンプリングされた風速の時系列のデータを用いた。ここで $y_{t|t}[\text{m/s}]$ は平均風速のデー

タである。 $y_{t|t}^{use}$ は、風向によって選んだ風上の気象台の平均風速のデータを示している。 a_1, b_1, b_2, b_3 は風速係数である。

3.4 モデル 4: 気象予報と過去の風速によるモデル

このモデルでは新しい情報として、風速予報のデータを与えた。文献¹²⁾においては、モデルにメソスケール気象モデルにより予測した風速が含まれている。メソスケール気象モデルとは、気象庁ではメソ数値予報モデルと呼ばれており、気象庁が集中豪雨をはじめとした防災気象情報を作成する資料として導入している気象モデルである。1日8回の予報をし、4回の予報期間は33時間で、残りは15時間となっている。

そこで文献¹²⁾のモデルのように風速の予報の値を含めて、その値をもとに風速予測をすることを考えた。風速の予報のデータがないか探したところ、インターネット上にて気象予報を行っているページ存在した。こういった気象予報のページでは気象庁のデータをもとに数値処理を行うページが多くあり、気象業務センターなどで配信している。この気象業務センターでは33時間後まで1時間間隔の予測を行っている。Fig. 5のサイトとなっている。

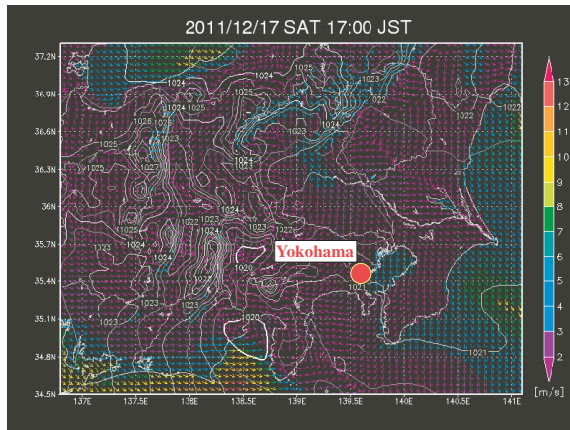


Fig. 5: Weather Forecast¹³⁾

Fig. 5の右側が風速の指標となる色であり、矢印が風向を表現している。この気象予報のデータをまとめ、風速予測に用いるモデルを作成した。

気象予報を用いた風速モデルは以下のような式となる。

$$\begin{aligned}\hat{y}_{t+1|t} &= a_t y_{t|t} + b_t y_{t+1|t}^{Model} + c_t (y_{t|t}^{Model} - y_{t|t}) \\ &= (a_t - c_t) y_{t|t} + b_t y_{t+1|t}^{Model} + c_t y_{t|t}^{Model} \quad (15)\end{aligned}$$

$y_{t|t}$ [m/s] は横浜の気象台で得られた気象庁の平均風速のデータである。 $y_{t+1|t}^{Model}$ は、時刻 t までのデータを基にした i 時間先の気象予報での平均風速の予測値のデータを示している。 a_t, b_t, c_t は風速係数である。

3.5 風速予測結果

本稿では前節までの予測手法を基に気象庁の横浜の気象台における実際の風速を用いて風速予測を行う。風速予測は気象庁で公表されている2011年9月1日～12月31日までの1時間間隔の時系列の平均風速データを用いた。前節で提案した4つのモデルでの結果を比べた。便宜上、風速予測結果を載せる際にはモデル1といった表記をする。モデル1～4において、1ヵ月分の

過去データを用いてパラメータ推定をした2011年12月13日の予測結果をまとめる。

モデル1に関しては1時間毎の予測を行って24時間分の予測をしたものと、24時間先まで予測したものの二つの結果を載せる。モデル2, 3に関しては1時間前の情報を使うことが必須となってしまうため、1時間毎の予測のみを行う。モデル4に関しては、24時間先予測のみを行う。全て予測開始日から1ヵ月分の過去データを用いてパラメータ推定を行った。初期値についてはモデル毎に設定した値とする。

それぞれのモデルでの1時間毎と24時間先までの予測結果は以下のFig. 6となった。

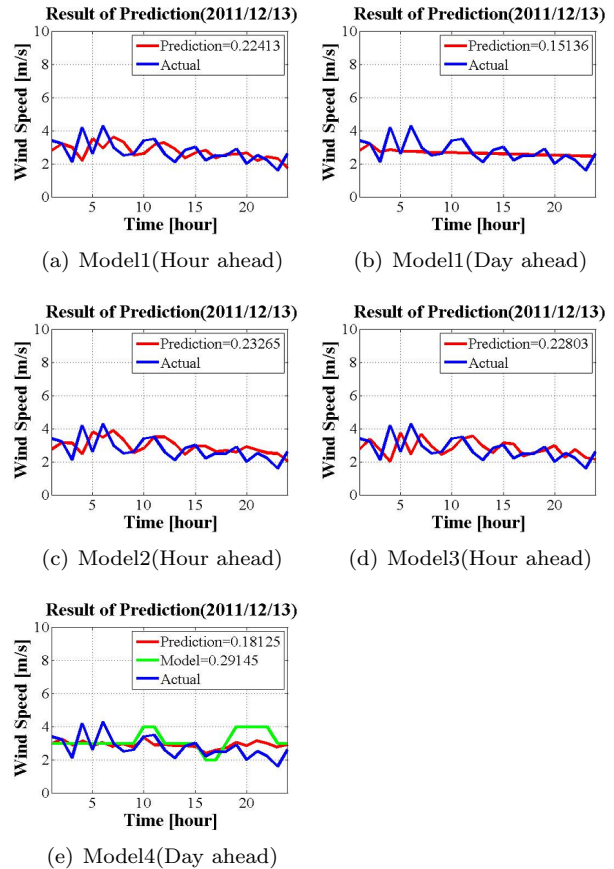


Fig. 6: Prediction Result

モデル1の1時間毎の予測では1ステップずれたような形の風速予測となっていることがわかる。これは、パラメータ推定の際に係数が1ステップ前の値が大きくなる形で収束してしまったことが原因とみられる。同様にして、モデル1の24時間先予測では1ステップ前の推定値がそのまま予測値になって直線になっている。誤差率は小さくなっているがうまく予測ができていない様子がわかる。このモデルでは風速の変化率が大きくなると誤差が大きくなることが予想できる。

モデル2はモデル1と同様に、1ステップずれたような形の風速予測となっていることがわかる。この場合もパラメータ推定の際に係数が1ステップ前の値が大きくなる形で収束していたのでこのような結果となったと言える。

モデル3はモデル1、モデル2と同様に、1ステップずれたような形の風速予測となっていることがわかる。この場合もパラメータ推定の際に係数が1ステップ前

の値が大きくなる形で収束していたので、1 ステップ前の風速の値が大きく影響するような結果となったと言える。

モデル 4 では緑のラインが GPV 気象予報の値である。モデル 4 を見ると予測値は GPV 気象予報の結果に依存した形になっている。モデル 4 から GPV 予報は時刻が経つほど予測誤差が大きくなり、それに伴って予測値も実測値との誤差が大きくなっている。0~7 時辺りまでの激しい変動を伴う予測も難しいのではと思われる。また、目視で GPV 気象予報のデータを得ているため、そこで生じる誤差もあるだろう。

3.6 予測精度の評価

相対誤差での評価を Table 3 にまとめた。

Table 3: Evaluation

	Error[%]
Model1(Hour ahead)	22.413
Model1(Day ahead)	15.136
Model2(Hour ahead)	23.265
Model3(Hour ahead)	22.803
Model4(Day ahead)	18.125
Weather Forecast	29.145

モデル 1(1 時間毎)、2、3 はほぼ同じように 1 ステップ前のデータに依存する形でパラメータ係数が収束してしまったため、結果が同じようになった。これは 1 ステップ前の風速のデータが信頼が高いとモデルが判断してしまったことによる。

一方、モデル 1(24 時間予測) は精度が良くなっていることが結果からはわかる。だがモデル 1 の 24 時間予測の図を見ると、予測値は 1 ステップ前の予測値と同じような値となっており、直線の予測図となっている。従って、風速の変化が大きい時には精度が悪くなることが考えられる。実際の 1 週間分の検証結果から、モデル 1 の相対誤差は大きい日と小さい日で差があることがわかっている。モデル 4 は気象予報よりも予測精度が良くなっており、予測ができていていることがわかる。パラメータ推定の結果からもこの結果は明らかであると言える。モデル 4 で用いた気象予報の風速は 1 ステップ後の未来の情報を使うことができるため、パラメータ推定の際に、過去の風速のデータを用いて気象予報を補正することで予測ができていている。モデル 4 では、GPV 気象予報の相対誤差は 29.145% であったのに対して、予測値の誤差は 18.125% となった。

4 風力発電量予測

前節で議論した結果から風速モデルはモデル 4(気象予報モデル) を使用し、風力発電の予測を 24 時間先まで 1 時間ずつ予測する。その際に用いる経験的パワーカーブの導出を行い、最後に実機での風力発電予測結果を載せる。また、提案手法による 1 週間分の風力発電予測の評価についても行った。

4.1 風力発電機について

使用するデータは気象庁の横浜の風速の気象データと、風速の気象予報データとなっている。また、発電量予測における風力発電機のデータは慶應大学矢上キャンパス 24 棟の屋上に設置してあるものとする。風力発

電機 (MWG-50) のパラメータは以下の Table 4 のようになっている。

Table 4: Parameter of Wind Turbine(MWG-50)

Blade Radius	950[mm]
Rated Output	50[W]
Rated Wind Speed	8[m/s]
Rotation Start Wind Speed	1.5[m/s]
Power Generation Start Wind Speed	3.5[m/s]
Maximum Output	130[W]

なお、発電機の発電量と 1 時間の平均風速の関係についてプロットしたものが以下の Fig. 7 となる。




Fig. 7: Relation between Wind Power and Wind Speed

Fig. 7 を見ると、発電開始風速の手前でも発電をおこなっていることがわかる。この時、平均風速は 1.5m/s 以下でも、1.5m/s 以上の風が吹いているということである。したがって、パワーカーブを作る際には、最大発電出力や回転開始風速等を考慮しなくても良いということになる。

4.2 経験的パワーカーブ

一般的にパワーカーブは風速に対する発電出力の式で表される。しかし、今回扱わなければならないパワーカーブは 1 時間あたりの平均風速あたりの発電出力である。したがって、発電出力のデータと実測した風速データからパワーカーブを作らなければならない。これを経験的パワーカーブとする。




Fig. 8: Exponential Power Curve

4.3 風力発電予測モデル

本研究で用いる風力発電量の予測モデルは文献¹²⁾を参考にしたものであり、風速を予測した値を経験的パワーカーブの関数に代入することによって発電量の予測を行う。その具体的なモデルは以下になる。

$$\hat{p}_{t+1|k} = d_t p_{t|t} + e_t f_{pc}(\hat{y}_{t+1|t}) + f_t(f_{pc}(\hat{y}_{t|t}) - p_{t|t}) \quad (16)$$

$$f_{pc}(\hat{y}_{t+1|t}) = 4.04\hat{y}_{t+1|t}^2 - 5.31\hat{y}_{t+1|t} + 2.03 \quad (17)$$

p_t [W] は時刻 t における出力の観測値、 $f_{pc}(\cdot)$ [W] は風力発電機のパワーカーブモデルの関数、 $\hat{p}_{t+1|t}$ は最終的に求める時刻 t における 1 時間先の発電出力の予測値である。 d_t , e_t , f_t は未知相関係数である。このモデルに対し、カルマンフィルタを用いた推定アルゴリズムを用いることで、未知相関係数を推定する。

4.4 予測目的

風力発電の予測では、その評価として相対関係誤差 (MRE) を用いて評価する。これを式として表わしたものを以下に示す。ここで、 $y_{t|t}$ は実測値、 $\hat{y}_{t+1|t}$ はモデル式による推定値、 W_{total} は定格出力、 N はデータ数を示す。

$$MRE = \frac{1}{W_{total}} \frac{1}{N} \sum_{i=1}^N \|y_{t|t} - \hat{y}_{t+1|t}\| \quad [\%] \quad (18)$$

4.5 予測条件

前節までのモデル 4 の風速予測手法を基に気象庁の横浜の気象台における実際の風速と気象予報のデータを用いて風速予測を行う。扱うデータ期間は 2012 年 3 月 1 日～5 月 31 日までの 1 時間間隔の時系列の平均風速データとする。風速予測も風力発電量も統計処理を行う際のデータ量は同じ量とし 10 日分とする。実機の風力発電機のデータは 1 時間当たりの出力となっている。以上の条件で 2012 年 5 月 27, 28 日の発電量予測をした結果を次の節で示す。

4.6 発電出力予測結果

24 時間の発電出力の予測結果を以下の Fig. 9 に示す。




Fig. 9: Wind Power Prediction Result

Fig. 9 の緑のラインが予測結果で、赤のラインが風速予測からパワーカーブに当てはめただけの値となる。結果より、27 日、28 日における提案手法の誤差率は 11.2%, 21.5% となった。一週間の検証では、17.67% 程度の誤差で収まっていた。これは文献⁶⁾の 17.87% という 1 日の予測誤差率に対して比較しても若干向上していることがわかる。また文献⁶⁾の最大誤差率に対して、提案手法では 67% であるのに対し、文献では 71.69% であり精度が向上していることがわかる。

5 おわりに

本稿では、風力発電機が自立的に風速データを計測し、計算を行えることを想定した風力発電予測を考えた。まず、風速予測モデルを 4 つ提案し、比較・検討を行った。予測に用いる統計処理の手法としては気象庁のホームページにある横浜における過去の風速等の時系列データ、気象業務センターの 33 時間先までの気象予報等のデータを用いてカルマンフィルタに基づき風速モデルの未知相関係数を推定した。

今回、最も精度が良かったのはモデル 4 (気象予報モデル) である。この風速モデルを用いて、風力発電出力の予測を行った。得られた風速予測データを、実機の経験的パワーカーブに当てはめ、24 時間先までの発電予測値を求め、さらに実機データを用いて風力発電モデルを推定した。この結果より、従来法⁶⁾の 1 日分の予測結果よりも、提案手法の 1 週間分の予測結果の方が若干精度が向上した。また、最大誤差率は従来よりも 4.69% の向上を確認できた。これらの結果より提案手法の有効性を示した。

参考文献

- 1) 滑川徹, "スマートグリッドのための分散予測制御," 計測と制御, 51-1, pp.62-68, 2012
- 2) L. Wendell, H. Wegley, M. Verholek, "Report from aworking group meeting on wind forecasts for WECS operation," PNL-2513, Pacific Northwest Laboratory, 1978.
- 3) C. Notis, D. Trettel, J. Aquino, T. Piazza, L. Taylor, D. Trask, et al., "Learning to forecast wind at remote sites for wind energy applications," PNL-4318, Pacific Northwest Laboratory, 1983.
- 4) H. Wegley, W. Formica, "Test applications of a semi-objective approach to wind forecasting for wind energy applications," PNL-4403, Pacific Northwest Laboratory, 1983.
- 5) 谷口謙悟, 一柳勝宏, 雪田和人, 後藤泰之, "風力発電のための広域気象データによる風速時系列予測の検討," 電気学会論文誌 B 編, 128-2, pp. 416-422, 2008.
- 6) 角田翔, 呉国紅, "ニューラルネットワーク法による風力発電の短時間先発電量予測の精度向上に関する研究," 電気学会論文誌 B 編, 129-9, pp. 1091-1097, 2009.
- 7) 藤村直人, 安野卓, 薬師寺亮太, 瀧川善義, 川崎憲介, "自己調整ファジィ推論と偏差持続モデルを用いた簡易風力発電出力予測システム," 電気学会論文誌 B 編, 129-5, pp. 614-620, 2009.
- 8) Yasuhiko Hosoda, and Toru Namerikawa, "Short-term Photovoltaic Prediction by using H Filtering and Clustering," SICE Annual Conference 2012, pp. 119-124, 2012
- 9) 谷川亮一, "蓄電池等併設型風力発電システムでの出力一定制御方法における風力発電出力予測方法の検討," 日本機械学会第 13 回動力・エネルギーシンポジウム講演論文集, pp. 395-398, 2008.
- 10) 気象庁ホームページ (<http://www.jma.go.jp/jma/index.html>) (2012/7 アクセス)
- 11) 近藤純正, "基礎 1: 地表近くの風," 近藤純正ホームページ (<http://www.asahi-net.or.jp/~rk7j-kndu/index.html>) (2011/11 アクセス)
- 12) 榎木康太, 石原孟, 山口敦, 福本幸成, "気象予測とオンライン観測に基づく風力発電出力予測システムの開発と検証," 土木学会第 61 回年次学術講演会, pp. 183-184, 2006.
- 13) 「GPV 気象予報」 (<http://weather-gpv.info>) (2012/7/31 アクセス)