

# JIT モデリングに基づく カルマンフィルタによる短期風力発電量予測

石川友規 (慶應義塾大学) 滑川徹 (慶應義塾大学/JST CREST)

## Short-Term Wind Power Prediction for Wind Turbine via Kalman Filter based on JIT Modeling

\*T. Ishikawa (Keio University) and T. Namerikawa (Keio University/JST CREST)

**Abstract**— This paper deals with wind power prediction algorithm applying for energy management systems. This research work is to predict the amount of the next day of generation in condition of the constrained previous actual data and the weather forecast data of wind. The prediction method is simply algorithm, the procedure of prediction consists of two steps, the data processing and the calculation of predicted value. In the data processing, in order to get the correlative data from the database, we employ JIT(Just-In-Time) Modeling. In the calculation of predicted value, we provide the regression model for wind speed and wind power and wind power, and the unknown parameters are estimated via constrained kalman filter. 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. Finally, the advantage of the proposed method can be shown, compared with the conventional method.

**Key Words:** Short-term Prediction, Wind Power, Just-In-Time Modeling(JIT Modeling), Constrained Kalman Filter, Energy Management Systems(EMS)

### 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、文献 [8] を基に予報値を統計的に補正する方法を用いた。文献 [8] の特徴としては、少ないデータから予測が可能な予測手法であり、発電出力の変動が大きく、十分な数のデータが得られない風力発電予測にも有用であると考えられる。具体的に提案手法では回帰式によって風速モデルと風力発電モデルを表現し、過去の風速と風力発電量から制約付きカルマンフィルタによって未知係数を推定する。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測精度の向上を図る手法である。その際に JIT(Just-In-Time) モデリング [9–12] によって風速と風力発電の波形を自動で関連の高い学習データを判別する。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。その結果、誤差の小さい風速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、風力発電計算値を求めた後に風力発電モデルから発電量予測を求める。提案手法の特徴として、予測の信頼性を未知係数推定の係数によって陽に保証し、十分に少ないデータから予測を行う点がある。最後に、JIT モデリングと制約付きカルマンフィルタによる予測法を提案し、文献 [6] と比較し有効性を検証する。

## 2 問題設定

まず、データベースに風速の気象予報データ、それに対応する風速の過去データ、風力発電データを2ヵ月分蓄積する。データベース内でJITモデリングにより、予測したい地点での気象予報データと相関のあるデータを抜き出し、そのデータに対応する風速データ、発電量データを得る。JITモデリングによって得られた相関のある風速のデータと気象予報の風速データ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学習し、推定する。そうして得られた気象予報よりも精度の高い風速予測データを基に、発電量を計算して計算予測値を求める。この発電量計算予測値とJITモデリングによって得られた相関のある発電量データを基にした発電量モデルに数値を代入し、風速モデルと同様の統計処理をしてモデルの未知係数パラメータを学習し、推定する。まとめると、風速の予測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といった流れとなる。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。Fig. 1に予測のプロセスをまとめる。

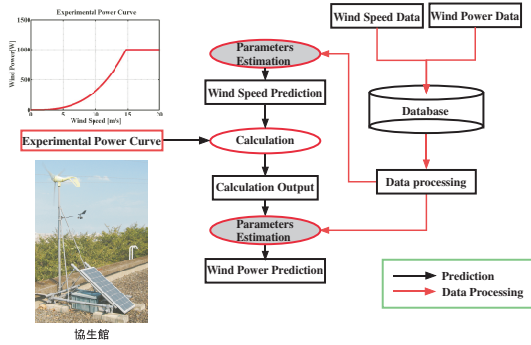


Fig. 1: Wind power prediction process [13]

### 2.1 予測モデル

#### 2.1.1 風速予測モデル

風速データは実機発電機の横にある実際の風速計で得られた風速値を使用した。データのサンプリング時間の間隔は1時間とする。気象予報の風速データは、気象業務センターなどで配信している気象予報を使用する。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。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。

JITモデリングで得られた近傍データと気象予報を用いた風速モデルは以下のような式となる。

$$v_{t+1|t} = a_t v_{t-23|t}^{JIT} + b_t v_{t+1|t}^{Model} \quad (1)$$

$v_{t-23|t}^{JIT}$  [m/s] はJITモデリングによって得られた近傍データの1日前の同時刻の風速データである。 $v_{t+1|t}^{Model}$  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。 $a_t$ ,  $b_t$  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。

#### 2.1.2 風力発電機

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 1のようになっている。

Table 1: 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. 2となる。

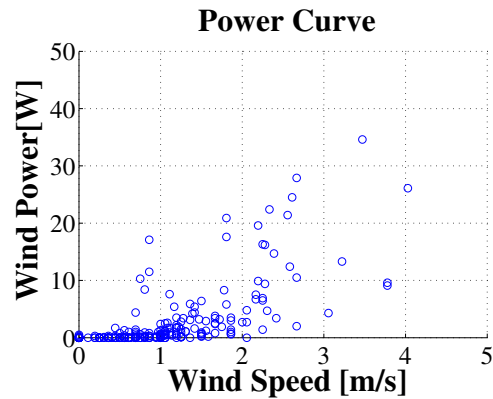


Fig. 2: Relation between wind power and wind speed

Fig. 2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。

#### 2.1.3 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。

#### 2.1.4 風力発電量モデル

本稿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。得られた計算予測値とJITモデリングで得られた近傍データも用いたモデルは以下になる。

$$p_{t+1|t} = d_t p_{t-23|t}^{JIT} + e_t f_{pc}(v_{t+1|t}) \quad (2)$$

$$f_{pc}(v_{t+1|t}) = 4.04v_{t+1|t}^2 - 5.31v_{t+1|t} + 2.03 \quad (3)$$

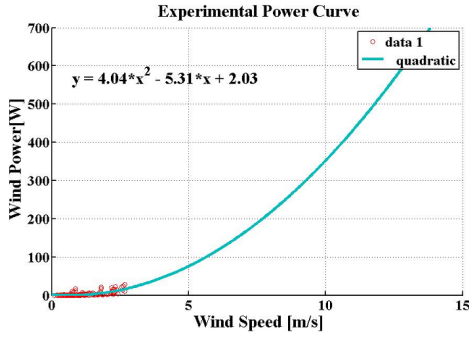


Fig. 3: Experiential power curve

$p_{t|t}$  [W] は時刻  $t$  における出力の観測値,  $p_{t-23|t}^{JIT}$  は JIT モデリングによって得られた最近傍のデータの時刻  $t$  から 23 時間前の発電量である.  $f_{pc}(\cdot)$  [W] は風力発電機のパワーカーブモデルの関数,  $p_{t+1|t}$  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.  $d_t$ ,  $e_t$  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.

このように, 24 時間先の予測まで 1 ステップずつ値が変化していくことで 1 時間毎にモデルが変化し, 予測を 1 時間ずつ行うことができる.

## 2.2 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, 風速モデルを用いて説明する. 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.

$$\begin{aligned} \mathbf{x}_{k+1|k} &= \mathbf{A}_k \mathbf{x}_{k|k} + \mathbf{w}_k \\ v_{k|k} &= \mathbf{C}_k \mathbf{x}_{k|k} + r_k \end{aligned} \quad (4)$$

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.

$$\mathbf{x}_{k|k} = \begin{bmatrix} a_k & b_k \end{bmatrix}^T \quad (5)$$

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

$$\mathbf{C}_k = \begin{bmatrix} v_{k|k}^{JIT} & v_{k+1|k}^{Model} \end{bmatrix} \quad (6)$$

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

$$\mathbf{A}_k = \mathbf{I}_k \quad (7)$$

$k \in \mathbb{Z}_+$  は時刻,  $v_{k|k} \in \mathbb{R}$  は観測値,  $\mathbf{w}_k \in \mathbb{R}^{n_x}, r_k \in \mathbb{R}^{n_x}$  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.

$$E \left\{ \begin{bmatrix} \mathbf{w}_k \\ r_k \end{bmatrix} \begin{bmatrix} \mathbf{w}_l^T & r_l^T \end{bmatrix} \right\} = \begin{bmatrix} W_k & 0 \\ 0 & R_k \end{bmatrix} \delta_{kl} \quad (8)$$

また分散行列  $W_k \in \mathbb{R}, R_k \in \mathbb{R}$  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 (4) ~ (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

$$\mathbf{K}_k = [\mathbf{P}_{k|k-1} \mathbf{C}_k^T] [\mathbf{C}_k \mathbf{P}_{k|k-1} \mathbf{C}_k^T + W_k]^{-1} \quad (9)$$

### 2. 状態推定値の更新

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k [y_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1}] \quad (10)$$

### 3. 推定誤差共分散行列の更新

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{C}_k \mathbf{P}_{k|k-1} \quad (11)$$

$\mathbf{P}_k \in \mathbb{R}^{n_x \times n_x}$  は時刻  $k$  での推定誤差共分散行列で,  $\mathbf{K}_k \in \mathbb{R}$  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 (5) を推定することができる.

### 2.3 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, 風力発電の予測ではその評価として相対関係誤差 (MRE) を用いる. これを式として表わしたものを以下に示す. ここで,  $v_{k|k}$  は実測値,  $\hat{v}_{k+1|k}$  はモデルによる推定値,  $N \in \mathbb{Z}_+$  はデータ数を示す. ここで,  $p_{t+i|t+i}$  は実測値,  $\hat{p}_{t+i|t+i-1}$  はモデル式による予測値,  $W_{total}$  は定格出力を示す.

$$MAE = \frac{1}{24} \sum_{i=1}^{24} \|v_{t+i|t+i} - \hat{v}_{t+i|t+i-1}\| \times 100 \quad [\%] \quad (12)$$

$$MRE = \frac{1}{W_{total}} \frac{1}{24} \sum_{i=1}^{24} \|p_{t+i|t+i} - \hat{p}_{t+i|t+i-1}\| \times 100 \quad [\%] \quad (13)$$

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 JIT モデリングに基づくデータ処理

本稿では観測データとして, 風速データ, 気象予報の風速データ, 発電量データを扱い, これらのデータに対して JIT モデリングを用いることで過去のデータから相関性の高いデータを取り出し予測を行う. JIT モデリングは, 気象予報データを用いて, 風速データと発電量データを相関性の高い順に分類する. 分類されたデータは未知係数推定に用いられ, 高精度の予測に必要な操作である.

一般的な JIT モデリングはリアルタイムに参照値と出力との偏差を小さくする制御入力を与える制御則であるが, 本稿で扱う問題では参照値は存在しない. そこで, 今回行う風力発電予測では現在までの出力データをもとに未来の出力を予測する必要がある. 本節では, データベースに蓄積された気象予報の風速データ, 実測風速データ, 発電量データのデータ処理として JIT モデリングについて説明する.

まず, 風力発電量モデルは以下に示すシステムで表さ

れるとする。

$$y_\tau = g(x_\tau), \tau = 0, 1, 2 \quad (14)$$

ただし、ここで  $x[\tau] \in \mathbb{R}^{1 \times 24}$  は回帰ベクトルで

$$x_\tau = [v_{\tau+1}^{Model}, \dots, v_{\tau+24}^{Model}] \quad (15)$$

$y_\tau$  は以下のような出力、

$$y_\tau = [v_{\tau+1}, \dots, v_{\tau+24}, p_{\tau+1}, \dots, p_{\tau+24}] \quad (16)$$

とし、時刻  $\tau$  での発電電力と風速の含まれる  $y[\tau] \in \mathbb{R}^{1 \times 48}$  は 24 ステップ先までの入力 (風速の気象予報値)  $v^{Model}$  に依存するものとする。本稿の制御目的は風速予報値から出力  $y$  の  $\tau$  以降の 24 時間先を予測することとする。予測したい時刻での要求点  $\phi[\tau] \in \mathbb{R}^{1 \times 24}$  は次のように風速予報値によって構成される次のようなベクトルと定義する。

$$\phi_\tau = [v_{\tau+1}^{Model}, \dots, v_{\tau+24}^{Model}] \quad (17)$$

この要求点との距離が最も小さくなる過去の情報ベクトル

$$\psi_{k_{opt}} = [v_{k_{opt}+1}^{Model}, \dots, v_{k_{opt}+24}^{Model}] \quad (18)$$

をデータベースの中から見つけ

$$\hat{y}_{k_{opt}} = [v_{k_{opt}+1}, \dots, v_{k_{opt}+24}, p_{k_{opt}+1}, \dots, p_{k_{opt}+24}] \quad (19)$$

として近傍データを得る。また、アルゴリズムではデータベースを  $[\psi_i, y_i]$  を要素としてもつ行列  $D$  として扱う。例えば異なる状況で記録された  $N$  組の出力データ

$$\{v_\tau^{Model}\}_{\tau=1, \dots, N} \quad (20)$$

が与えられた時、行列  $D \in \mathbb{R}^{N \times 2}$  は以下ようになる。

$$D = \begin{bmatrix} \psi_1 & y_1 \\ \vdots & \vdots \\ \psi_N & y_N \end{bmatrix} \quad (21)$$

ただし、

$$\begin{aligned} \psi_i &= [v_{i+1}^{Model}, v_{i+2}^{Model}, \dots, v_{i+24}^{Model}] \\ y_i &= [v_{i+1}, \dots, v_{i+24}, p_{i+1}, \dots, p_{i+24}] \end{aligned} \quad (22)$$

となる。以下に JIT モデリングのアルゴリズムについてまとめる。

$$\hat{y}_{k_{opt}} = JIT(D, \phi_\tau, k_{opt}) \quad (23)$$

**Step1:情報ベクトルの並び替え**

情報ベクトル  $\phi_\tau$  と  $\psi_i$  との距離を標準化ユークリッド距離

$$d(\phi_\tau, \psi_i) = \sqrt{(\phi_\tau - \psi_i)W^{-1}(\phi_\tau - \psi_i)^T} \quad (24)$$

により定義し、昇順に  $D$  の行を並び替える。ただし、ここで  $W$  は重み行列で

$$W = \left[ \text{diag}\left(\frac{1}{l} \sum_{i=1}^l (\psi_i - \bar{\psi})^T (\psi_i - \bar{\psi})\right) \right] \quad (25)$$

$$\bar{\psi} = \frac{1}{l} \sum_{i=1}^l \psi_i \quad (26)$$

とする。ここで  $l$  は  $D$  の次数であり  $\text{diag}(A)$  は行列  $A$  の非対角成分を全て 0 にする作用素を表す。  $W$  は  $j$  番目の対角要素が  $S(j)$  である  $l$  行  $l$  列の対角行列で  $S$  は標準偏差のベクトルである。

**Step2: $k_{opt}$  の設定**

$\phi_\tau$  の  $k_{opt}$  最近傍  $\psi_{k_{opt}}$  を定める。

$$\psi_{k_{opt}} := \{\psi_i | i = 1, \dots, k_{opt}\} \quad (27)$$

**Step3: $\hat{y}_{k_{opt}}$  の計算**

$k_{opt}$  最近傍に対応する  $y_i$  の出力を  $\hat{y}_{k_{opt}}$  として近傍データを得る。

$$\hat{y}_{k_{opt}} = y_{k_{opt}} \quad (28)$$

## 4 制約付きカルマンフィルタ

本節では、制約付きカルマンフィルタに基づく未知係数推定に関して記述する。まず、未知係数推定にあたり、カルマンフィルタの問題点を提示する。次に、問題を解決するための制約付きカルマンフィルタアルゴリズムを提案する。

### 4.1 カルマンフィルタの問題点

Fig. 4 より予測を行った際に、予測精度を下げる「はずれ値」が存在することがわかる。

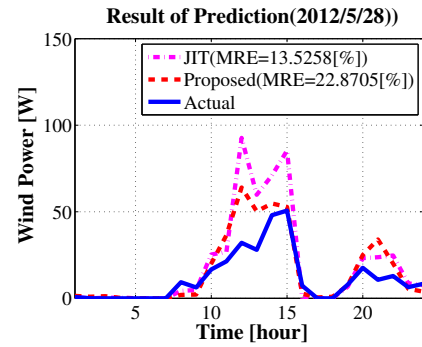


Fig. 4: Outlier of wind power prediction(5/28)

このはずれ値の主な原因は風速予測時の予測ミスにあると考えられ、風速予測の値がずれる原因として気象予報の値が大きくなりすぎていることが考えられる。この「はずれ値」を上手く補正することができれば、性能が良くなると感じアルゴリズムに手を加えた。実測値の最大発電量について過去のデータから 55.3[W] であることがわかり、その値をパワーカーブから逆算した最大風速値が 5.15[m/s] となった。以上から、本稿で扱う推定問題に関して以下の問題 1 として定義する。

### 問題 1

予測値が  $\hat{y}_k > y_{max}$  となる予測値の検出を行い、信頼性が低下した予測値に、より信頼度の高い予測値を与えるアルゴリズムを求めよ。

風速最大値を  $v_{max}$  [m/s], 発電最大値を  $p_{max}$  [W] として以下のようなアルゴリズムを提案する。

#### 4.2 制約付きカルマンフィルタのアルゴリズム

風速モデルを例にして、制約付きカルマンフィルタを (29)-(35) 式により提案する。

##### Step1. 予測値を計算する

$$\hat{v}_{k|k-1} = C_k \hat{x}_{k|k-1} \quad (29)$$

##### Step2. 検証・補償をする

$$C_k = \begin{cases} v_{max} & \hat{v}_{k|k-1} > v_{max} \\ \hat{v}_{k|k-1} & \hat{v}_{k|k-1} < v_{max} \end{cases} \quad (30)$$

##### Step3. 事前誤差共分散行列 $P_{k|k-1}$ の計算

$$P_{k|k-1} = A_k P_{k-1} A_k^T + W_k \quad (31)$$

##### Step4. カルマンゲインの計算

$$K_k = P_{k|k-1} C_k^T [C_k P_{k|k-1} C_k^T + R_k]^{-1} \quad (32)$$

##### Step5. 予測値を観測値との誤差で修正

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (y_k - C_k \hat{x}_{k|k-1}) \quad (33)$$

##### Step6. 予測推定値の計算

$$\hat{x}_{k+1|k} = A_k \hat{x}_{k|k} \quad (34)$$

##### Step7. 推定誤差共分散行列の更新

$$P_{k|k} = P_{k|k-1} - K_k C_k P_{k|k-1} \quad (35)$$

Step1-7 を繰り返し計算することで制約を考慮しながら未知係数を推定することができる。

以上より、問題 1 に対して以下の定理が成り立つ。

### 定理 1

$\hat{v}_{k|k-1} > v_{max}$  となる時、カルマンフィルタアルゴリズムにおいての観測誤差共分散  $S_k^{max} = cov(y_k - y_{max})$  が、一般的なカルマンフィルタの観測誤差共分散  $S_k = cov(y_k - \hat{y}_{k|k-1})$  との間に以下の関係が成り立つ。

$$S_k^{max} \prec S_k \quad (36)$$

*Proof.* 観測値  $v_k$  は、

$$0 \leq v_k \leq v_{max} \quad (37)$$

予測値  $\hat{v}_{k|k-1}$  について  $\hat{v}_{k|k-1} > v_{max}$  である時、観測誤差共分散  $S_k$  は

$$\begin{aligned} S_k &= cov(y_k - \hat{y}_{k|k-1}) \\ &= E[(y_k - \hat{y}_{k|k-1} - E[y_k - \hat{y}_{k|k-1}]) \\ &\quad (y_k - \hat{y}_{k|k-1} - E[y_k - \hat{y}_{k|k-1}])^T] \quad (38) \end{aligned}$$

となる。この時、 $\hat{y}_{k|k-1} = y_{max}$  とおけば観測誤差共分散行列  $S_k^{max}$  は

$$\begin{aligned} S_k^{max} &= cov(y_k - y_{max}) \\ &= E[(y_k - y_{max} - E[y_k - y_{max}]) \\ &\quad (y_k - y_{max} - E[y_k - y_{max}])^T] \quad (39) \end{aligned}$$

観測誤差共分散  $S_k, S_k^{max}$  を比較すると

$$|y_k - y_{max}| < |y_k - \hat{y}_{k|k-1}| \quad (40)$$

となることから、式 ( ) が成り立つ。

$$\begin{aligned} S_k^{max} - S_k &= E[(y_k - y_{max} - E[y_k - y_{max}]) \\ &\quad (y_k - y_{max} - E[y_k - y_{max}])^T] \\ &\quad - E[(y_k - \hat{y}_{k|k-1} - E[y_k - \hat{y}_{k|k-1}]) \\ &\quad (y_k - \hat{y}_{k|k-1} - E[y_k - \hat{y}_{k|k-1}])^T] \\ &< 0 \quad (41) \end{aligned}$$

したがって、

$$S_k^{max} \prec S_k \quad (42)$$

となり、 $y_{max} < \hat{y}_{k|k-1}$  の場合、 $y_{max}$  を  $\hat{y}_{k|k-1}$  におくことで、予測精度向上を達成できる。□

## 5 風力発電予測

### 5.1 予測条件

風速予測は、慶應大学の実機風力発電機の横にある実際の風速計で得られた風速値と横浜の気象予報のデータを用いて風速予測を行う。発電量予測は、慶應大学の実機の風力発電機のデータの 1 時間当たりの出力データと用いる。扱うデータ期間は 2012 年 4 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風力発電量データとする。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 20 日分とする。以上の条件で 2012 年 5 月 25-28 日の 3 日間の発電量予測をした結果を次の節より示す。

### 5.2 予測結果

初期値を風速予測と風力発電量予測のどちらも同じように設定し、 $W_k = 0.01$ ,  $R_k = 0.01$ , 状態推定値の初期値は風速予測の場合は  $x_0 = [1/2 \ 1/2]^T$ , 発電量予測の場合は  $x_0 = [1/2 \ 1/2]^T$ , 誤差共分散行列の初期値  $P_0 = I$  として係数の推定を行った。24 時間の風速予測結果 Fig. 5 の (a)-(c) に、24 時間の発電出力の予測結果を以下の Fig. 5 の (d)-(f) に示す。以下に 5 月 25～27 日の予測結果を示す。この図の見方について風速予測と発電予測に分けて解説する。風速予測の見方は、緑の点線が気象予報の値で、赤の一点鎖線が

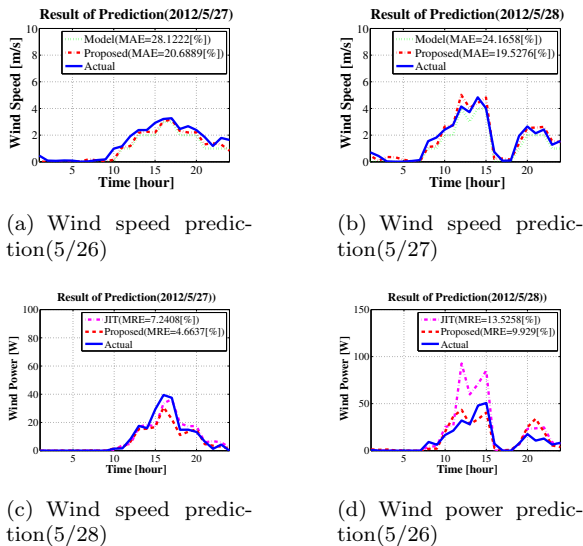


Fig. 5: Prediction result

で、青の実線が実測値である。青のラインの変化に緑と赤のラインはそれぞれ追従しているように見える。また、実測値との誤差率 MAE の値を、それぞれの図で見るとどれも気象予報の風速よりも精度の良い風速予測値を得られていることがわかる。

次に発電予測については、赤紫の一点鎖線が JIT モデリングで得た近傍データの値で、赤の点線が提案手法での予測の予測結果で、青の実線が実測値である。結果より、26 日-28 日における提案手法の誤差率はそれぞれ 9.04%, 4.66%, 9.92% となった。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向上していることがわかる。また、5 月 28 日に関しては、制約付きカルマンフィルタによって予測値が補償されていることも確認できる。

### 5.3 予測精度の評価

以下に 5 月 25 ~ 31 日の 1 週間分の発電予測の結果の評価を以下の Table 2 にまとめる。

Table 2: Evaluation(Wind power)

	Error[%]
Reference [6]	17.87
Calculation	11.01
JIT	7.92
proposed	5.95

評価より提案手法の予測の精度が良いことがわかる。JIT モデリングで得られた近傍データと風速予測値による計算予測値よりも、提案手法は実測値と誤差率の少ない値となった。発電予測に関しては、文献 [6] の 1 日での予測誤差率 (MRE) が 17.87% に対して、提案手法では一週間での平均誤差率 (MRE) が 5.95% と精度が上がった。

## 6 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制約付きカルマンフィ

ルタによる発電特性を考慮した風力発電予測を考えた。予測に用いるデータを JIT モデリングを用いてデータ処理を行うことで、予測に用いるデータを相関性の高いデータにすることができた。このデータを用いてモデルを構築したことで、本稿における提案法では過去データや計算量に関しても従来法よりも少なく、予測の信頼性を補償した予測手法を提案している。

1 週間分の予測結果の検証より、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。

今後の課題として、観測値への制約によって状態推定値を変化させるアルゴリズムや、未知相関係数の単調減少性の証明をすることで予測精度向上と信頼性向上に取り組んでいきたい。

## 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) Qiubao Zheng, Hidenori Kimura, "JUST-IN-TIME MODELING FOR FUNCTION PREDICTION AND ITS APPLICATIONS," Asian Journal of Control, Vol. 3, No. 1, pp. 35-44, 2001.
- 10) 鈴木貴宣, "Just-In-Time Modeling に基づく日射量予測手法の開発," 電気学会論文誌 B, 131-11, pp. 912-919, 2011.
- 11) T. Brunsch, J. Raisch, L. Hardouin, "Modeling and control of high-throughput screening systems," Control Engineering Practice, vol. 20, pp. 14-23 2012.
- 12) 沈浩洋, 日野英逸, 村田昇, 若尾真治, "JIT モデリングによる太陽光発電量予測とその信頼性評価," 情報処理学会研究報告, 27-14, 2011.
- 13) 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.
- 14) 「GPV 気象予報」 (<http://weather-gpv.info>) (2012/7/31 アクセス)