

226 誤差共分散の減少性を考慮した カルマンフィルタによる短期風力発電予測

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 via Kalman Filter Considering Reduction of Error Covariance

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

Abstract— This paper addresses wind power prediction which is known to be a key technology in EMS(Energy Management Systems). In this paper, 24 hours ahead power prediction method using a filtering theory is proposed for wind power generation. The prediction method is a simple algorithm, the procedure of prediction consists of two steps, the data processing and the calculation of predicted values. In the calculation of predicted value, the unknown parameters are estimated via constrained kalman filter. Moreover, in the estimation of the unknown parameters, the convergence of them are also guaranteed. Finally, the advantages of the proposed method over the conventional method are shown through actual prediction evaluations.

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

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に行われている。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または蓄電池によりで補償することが可能になる。

現在、様々な風力発電予測の研究がされている。その詳細については参考文献²⁾にまとめている。主な予測手法としては、Neural Network³⁾と統計データ⁴⁾に基づく手法がある。それらの問題点として、予測に使用するデータ量が多く、モデルが複雑で扱い辛いといった点、局所解に陥ることがある点がある。

そこで本稿では、文献^{2, 5)}を基に予報値を統計的に補正する方法を提案する。文献^{2, 5)}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^{6, 7)}によって

風速と風力発電の波形を自動で相関の高いデータを判別する。また、未知係数収束性についても文献⁸⁾を基にし状態誤差共分散行列を減少させることにより保証した。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³⁾と比較し有効性を検証する。

2 問題設定

本稿での予測プロセスは文献⁹⁾を基にしており、その詳細を Fig. 1 にまとめる。まず、データベースに風速の気象予報¹⁰⁾、それに対応する風速、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、気象予報データ内で予測したい地点での予報と相関のあるデータを抜き出し、その過去データに対応する実際の風速、発電量を得る。JIT モデリングによって得られた相関のある風速、気象予報データを風速モデルに代入し、線形手法の一つであるカルマンフィルタ(Kalman Filter)を用いた統計処理をし、モデルの未知係数パラメータを推定する。得られた気象予報よりも精度の高い風速予測値を基に、発電量を計算して計算予測値を求める。発電量計算予測値と JIT モデリングによって得る発電量を基にした風力発電モデルに数値を代入し、風速モデルと同様に未知係数パラメータを推定する。

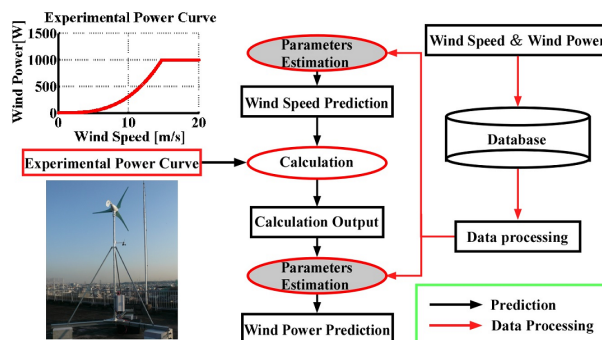


Fig. 1: Wind power prediction process⁹⁾

2.1 予測モデル

2.1.1 風速モデル

風速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。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式となる。

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

$v_{t-23|t}^{JIT}$ [m/s] は JIT モデリングによって得られた近傍データの同時刻の風速である。 $v_{t+1|t}^f$ は、時刻 t で知っている i 時間先の平均風速の気象予報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義塾大学矢上キャンパス 25 棟の屋上に設置してある発電機を利用する。風力発電機 (Z-1000) のパラメータは以下の Table 1 で与えられる。

Table 1: Parameter of wind turbine(Z-1000)

Blade Radius	1.8[m]
Rated Output	1000[W](12.5m/s)
Rotation Start Speed	0[m/s]
Generation Start Speed	2.5[m/s]
Maximum Output	2300[W](20m/s)

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、発電量と実測風速の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. 2: Experiential power curve

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²⁾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。

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

$$f_{pc}(v_{t+1|t}) = 7.1 v_{t+1|t}^2 - 13 v_{t+1|t} + 3 \quad (3)$$

$p_{t|t}$ [Wh] 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近傍データの同時刻の発電量である。 $f_{pc}(\cdot)$ [Wh] 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。また、 c_t, d_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。

2.2 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。

$$\mathbf{x}_{k+1|k} = \mathbf{A}_k \mathbf{x}_{k|k} + \mathbf{w}_k \quad (4)$$

$$v_{k|k} = \mathbf{C}_k \mathbf{x}_{k|k} + r_k \quad (5)$$

ここで、 $k \in \mathbb{Z}_+$ は時刻、 $\mathbf{x}_{k|k} \in \mathbb{R}^{n_x}$ は時刻 k における推定対象の状態ベクトル、 $\mathbf{A}_k \in \mathbb{R}^{n_x}$ は状態行列、 $\mathbf{C}_k \in \mathbb{R}^{n_x}$ は時変観測ベクトルで次の係数の行列で定義される。

$$\mathbf{x}_{k|k} = \begin{bmatrix} a_k & b_k \end{bmatrix}^T \quad (6)$$

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

$$\mathbf{C}_k = \begin{bmatrix} v_{k|k}^{JIT} & v_{k+1|k}^{Model} \end{bmatrix} \quad (8)$$

ここで時変観測ベクトルの中の $v_{k|k} \in \mathbb{R}$ は観測値を表わす。 $\mathbf{w}_k \in \mathbb{R}^{n_x}, r_k \in \mathbb{R}^{n_x}$ 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。

$$E \left\{ \begin{bmatrix} w_k \\ r_k \end{bmatrix} \begin{bmatrix} w_l^T & r_l^T \end{bmatrix} \right\} = \begin{bmatrix} W_k & 0 \\ 0 & R_k \end{bmatrix} \delta_{kl} \quad (9)$$

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再帰的な計算で得られる。これら式 (4) ~ (9) 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

$$\mathbf{K}_k = [\mathbf{P}_{k|k-1} \mathbf{C}_k^T] [\mathbf{C}_k \mathbf{P}_{k|k-1} \mathbf{C}_k^T + W_k]^{-1} \quad (10)$$

2. 状態推定値の更新

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k [y_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1}] \quad (11)$$

3. 推定誤差共分散行列の更新

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{C}_k \mathbf{P}_{k|k-1} \quad (12)$$

$\mathbf{P}_k \in \mathbb{R}^{n_x \times n_x}$ 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から求められる状態推定値である。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 (6) を推定できる。

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。

$$MAE = \frac{1}{24} \sum_{i=1}^{24} \|v_{t+i|t+i} - \hat{v}_{t+i|t+i-1}\| \times 100[\%] \quad (13)$$

$$MRE = \frac{1}{W_{total}} \frac{1}{24} \sum_{i=1}^{24} \|p_{t+i|t+i} - \hat{p}_{t+i|t+i-1}\| \times 100[\%] \quad (14)$$

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

本稿では観測値として、実測風速、気象予報の風速、発電の 3 種のデータに対し JIT モデリングを用いて過去データから相関性の高いデータを取り出す。JIT モデリングは、気象予報を基に、風速、発電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、高精度な予測を実現するために必要な操作となる。

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 24 時間分の近傍データを取り出す。本節では、データベースに蓄積された気象予報の風速、実測風速、発電量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 JIT モデルは以下に示すシステムで表されるとする。

$$\mathbf{y}_\tau^{JIT} = g(\mathbf{x}_\tau^{JIT}), \tau = 0, 1, 2 \quad (15)$$

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

$$\mathbf{x}_\tau^{JIT} = [v_{\tau+1}^f, \dots, v_{\tau+24}^f] \quad (16)$$

\mathbf{y}_τ^{JIT} は以下の出力、

$$\mathbf{y}_\tau^{JIT} = [v_{\tau+1}, \dots, v_{\tau+24}, p_{\tau+1}, \dots, p_{\tau+24}] \quad (17)$$

とし、時刻 τ での発電電力と風速の含まれる $\mathbf{y}_\tau^{JIT} \in \mathbb{R}^{1 \times 48}$ は 24 ステップ先までの入力 (風速の気象予報値) v^f 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 \mathbf{y}^{JIT} の τ 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ベクトルと定義する。

$$\phi_\tau = [v_{\tau+1}^f, \dots, v_{\tau+24}^f] \quad (18)$$

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

$$\psi_{i_{opt}} = [v_{i_{opt}+1}^{Model}, \dots, v_{i_{opt}+24}^{Model}] \quad (19)$$

をデータベースの中から見つけ

$$\hat{\mathbf{y}}_{i_{opt}}^{JIT} = [v_{i_{opt}+1}, \dots, v_{i_{opt}+24}, p_{i_{opt}+1}, \dots, p_{i_{opt}+24}] \quad (20)$$

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 $[\psi_i \mathbf{y}_i^{JIT}]$ 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

$$\{v_\tau^f\} | \tau = 1, \dots, N \quad (21)$$

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

$$D = \begin{bmatrix} \psi_1 & \mathbf{y}_1^{JIT} \\ \vdots & \vdots \\ \psi_N & \mathbf{y}_N^{JIT} \end{bmatrix} \quad (22)$$

ただし、

$$\begin{aligned} \psi_i &= [v_{i+1}^f, v_{i+2}^f, \dots, v_{i+24}^f] \\ \mathbf{y}_i^{JIT} &= [v_{i+1}, \dots, v_{i+24}, p_{i+1}, \dots, p_{i+24}] \end{aligned} \quad (23)$$

となる。以下に JIT モデリングのアルゴリズムをまとめる。

$$\hat{\mathbf{y}}_{i_{opt}}^{JIT} = JIT(D, \phi_\tau, i_{opt}) \quad (24)$$

Step1: 情報ベクトルの並び替え

情報ベクトル ϕ_τ と ψ_i との距離を標準化ユークリッド距離

$$d(\phi_\tau, \psi_i) = \sqrt{(\phi_\tau - \psi_i)W^{-1}(\phi_\tau - \psi_i)^T} \quad (25)$$

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

$$W = \left[\text{diag}\left(\frac{1}{l} \sum_{i=1}^l (\psi_i - \bar{\psi})^T (\psi_i - \bar{\psi})\right) \right] \quad (26)$$

$$\bar{\psi} = \frac{1}{l} \sum_{i=1}^l \psi_i \quad (27)$$

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 は標準偏差のスカラーである。

Step2: i_{opt} の設定

ϕ_τ の i_{opt} 最近傍 $\psi_{i_{opt}}$ を定める。

$$\psi_{i_{opt}} := \{\psi_i | i = 1, \dots, k_{opt}\} \quad (28)$$

Step3: $\hat{\mathbf{y}}_{i_{opt}}^{JIT}$ の計算

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

$$\hat{\mathbf{y}}_{i_{opt}}^{JIT} = \mathbf{y}_{i_{opt}}^{JIT} \quad (29)$$

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. 3 では予測を行った際に、予測精度を下げる「はずれ値」が存在している。




Fig. 3: Outlier of wind power prediction(5/28)

「はずれ値」を補正することができれば、性能が良くなることは明らかである。実測値の最大発電量、最大風速について過去データから 432[Wh], 8.5[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 $\hat{v}_k > v_{max}$ 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} [Wh] として風速予測を例として以下の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 (30)-(36) 式により提案する。

Step1. 予測値を計算する

$$\hat{v}_{k|k-1} = C_k \hat{x}_{k|k-1} \quad (30)$$

Step2. 検証・補償をする

$$\hat{v}_{k|k-1} = \begin{cases} v_{max} & \hat{v}_{k|k-1} > v_{max} \\ \hat{v}_{k|k-1} & \hat{v}_{k|k-1} < v_{max} \end{cases} \quad (31)$$

Step3. 事前誤差共分散行列 $P_{k|k-1}$ の計算

$$P_{k|k-1} = A_k P_{k-1} A_k^T + W_k \quad (32)$$

Step4. カルマンゲインの計算

$$K_k = P_{k|k-1} C_k^T [C_k P_{k|k-1} C_k^T + R_k]^{-1} \quad (33)$$

Step5. 予測値を観測値との誤差で修正

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (v_k - C_k \hat{x}_{k|k-1}) \quad (34)$$

Step6. 予測推定値の計算

$$\hat{x}_{k+1|k} = A_k \hat{x}_{k|k} \quad (35)$$

Step7. 推定誤差共分散行列の更新

$$P_{k|k} = P_{k|k-1} - K_k C_k P_{k|k-1} \quad (36)$$

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 1²⁾

$\hat{v}_{k|k-1} > v_{max}$ 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 $S_k^{max} = cov(v_k - v_{max})$ が、一般的なカルマンフィルタの観測誤差共分散 $S_k = cov(v_k - \hat{v}_{k|k-1})$ との間に以下の関係が成り立つ。

$$S_k^{max} < S_k \quad (37)$$

このアルゴリズムは、 v_k を p_k と置き換えることで風力発電モデルにも適用できる。

5 誤差共分散減少アルゴリズム

未知相関係数推定において、誤差共分散の収束性を早めることで推定精度を上げることを本節では提案する。従来法は、過去から現時刻という向きに未知相関係数の推定を行っていたが、相関の小さな過去データを用いて学習した未知相関係数から変化しない問題が発生する。この問題に対して、提案法では現時刻に近いデータで学習し未知相関係数を収束させることを目的として、本節では状態誤差共分散行列を減少させるアルゴリズムを提案する。文献²⁾では、式 (36) に γ をつけ、特定の条件下で 1 か 0 に変化させることで誤差共分散行列を小さくしている。

$$P_{k|k} = P_{k|k-1} - \gamma K_k C_k P_{k|k-1} \quad \begin{cases} \gamma = 1 \\ \gamma = 0 \end{cases} \quad (38)$$

本稿では状態誤差共分散の減少性について、以下の式 (39) に注目した。

$$P_{k|k-1} = A_k P_{k-1|k-1} A_k^T + W_k \quad (39)$$

ここで $|P_{k-1|k-1}| < |P_{k|k}|$ となる時に、 $\gamma = 0$ とし状態誤差共分散を小さくすることで収束性を早めることを考案する。 $|P_{k-1|k-1}| > |P_{k|k}|$ ならば、従来通りの更新式で $\gamma = 1$ とし未知相関係数の学習を行う。以下に、制約付きカルマンフィルタのアルゴリズム Step1-7 に加える Step8 の式を記述する。

Step7. 推定誤差共分散行列の更新

$$\hat{P}_{k|k} = P_{k|k-1} - K_k C_k P_{k|k-1} \quad (40)$$

Step8. 状態誤差共分散行列を検証・保証をする

$$P_{k|k} = P_{k|k-1} - \gamma K_k C_k P_{k|k-1}$$

$$\begin{cases} \gamma = 1 & |P_{k-1|k-1}| > |\hat{P}_{k|k}| \\ \gamma = 0 & |P_{k-1|k-1}| < |\hat{P}_{k|k}| \end{cases} \quad (41)$$

ここで、以下の定理 2 が成り立つ。

定理 2

未知相関係数の学習でのカルマンフィルタの状態誤差共分散収束保証アルゴリズムにおいて、状態誤差共分散行列に関して以下の関係式が成り立つ。

$$P_{k|k} \leq P_{k-1|k-1} + W_k \quad (42)$$

Proof. アルゴリズム内の式 (41), (42) より、以下の $P_{k|k}$ の場合分けができる。

$$P_{k|k} = \begin{cases} P_{k|k-1} - K_k C_k P_{k|k-1} & \gamma = 1 \\ P_{k|k-1} & \gamma = 0 \end{cases} \quad (43)$$

ここで、 $P_{k|k-1}$ は状態雑音の入った状態での状態誤差共分散行列であり、

$$P_{k|k-1} = A_k P_{k-1|k-1} A_k^T + W_k \quad (44)$$

$$\longleftrightarrow |P_{k|k-1}| \geq |P_{k-1|k-1} + W_k| \quad (45)$$

$$\longleftrightarrow |P_{k|k-1}| \geq |P_{k-1|k-1}| \quad (46)$$

$$(47)$$

であるから、式 (41), (47) より以下の関係は明らかである。

$$|\hat{P}_{k|k}| < |P_{k-1|k-1}| \leq |P_{k|k-1}| \quad (48)$$

$$\longleftrightarrow |P_{k|k}| \leq |A_k P_{k-1|k-1} A_k^T + W_k| \quad (49)$$

$$= |P_{k-1|k-1} + W_k| \quad (50)$$

から

$$P_{k|k} \leq P_{k-1|k-1} + W_k \quad (51)$$

が示せる。 □

6 風力発電予測

本節では、まずデータ処理の結果を示し JIT モデリングの有効性を検証する。その後、モデルの未知係数推定において考察する。最後に、提案するフィルタリング理論についての制約による効果と予測結果を示し、提案予測法の有効性について述べる。

6.1 データ処理結果

Fig. 4 に気象予報に対応する近傍データと実測値を示す。データ処理を行った後の近傍データのうち、最も近いデータを 4 つプロットしたものとなる。横軸は時間、縦軸は上下でそれぞれ風速と風力発電量を表す。Fig. 4 より実測値に近いデータを取得できていることがわかる。以上より、データ処理を行うことで推定に用いるデータ集合の分散を小さくし、より有用なデータを用いて予測をする。

6.2 予測条件

風速予測は、慶應大学の風力発電機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、風力発電機の発電データを用いる。扱うデータ期間は 2013 年 6 月 1 日～8 月 7 日までの 1 時間間隔の時系列データとする。

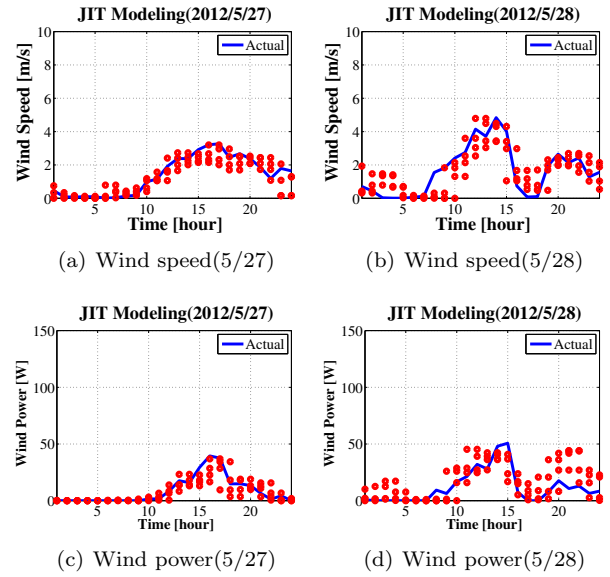


Fig. 4: Neighborhood data based on JIT modeling

6.3 未知係数推定結果

状態誤差共分散行列 P に関して以下の Fig. 5 に示す。結果より、状態誤差共分散行列は提案法の方が減少




Fig. 5: Reduction in trace of covariance matrix

しており、Fig. 6 に未知相関係数の収束性を示す。未知

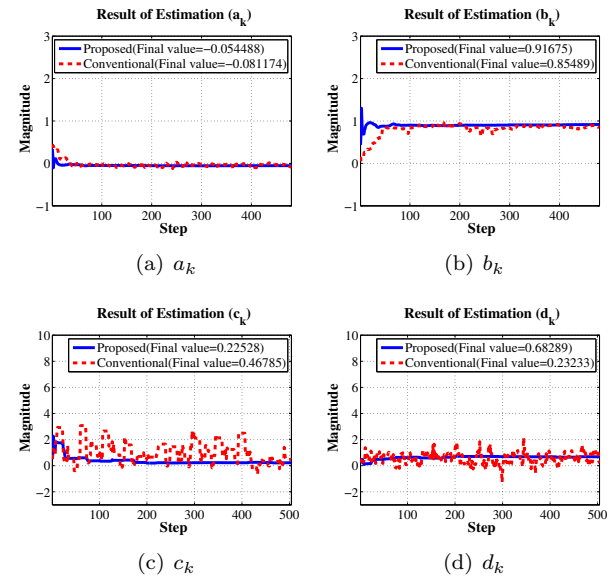


Fig. 6: The estimation of parameter

相関係数の収束性が提案法により補償されていることが、風速モデル、風力発電モデルの係数のどちらを見て

もわかる。特に、風力発電出力の係数は収束することで値が大きく変わっている。次の予測結果で、この結果がどう反映されるか確認する。

6.4 予測結果

初期値を風速予測と風力発電量予測は同様とし、 $W_k = 0.1$, $R_k = 0.1$, 状態推定値の初期値は $x_0 = \begin{bmatrix} 1/2 & 1/2 \end{bmatrix}^T$, 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。以下に8月4, 5日の24時間の風速予測結果を Fig. 7 の (a)-(b) に、24時間の風力発電予測結果を Fig. 7 の (c)-(d) に示す。見方について風速予測と発電予測に分けて解説する。風速予測は、点線が気象予報の値で、一点鎖線が提案手法で、実線が実測値である。発電予測は、一点鎖線が従来の制約付きカルマンフィルタによる予測データの値で、点線が提案手法での予測の予測結果で、実線が実測値である。風速予

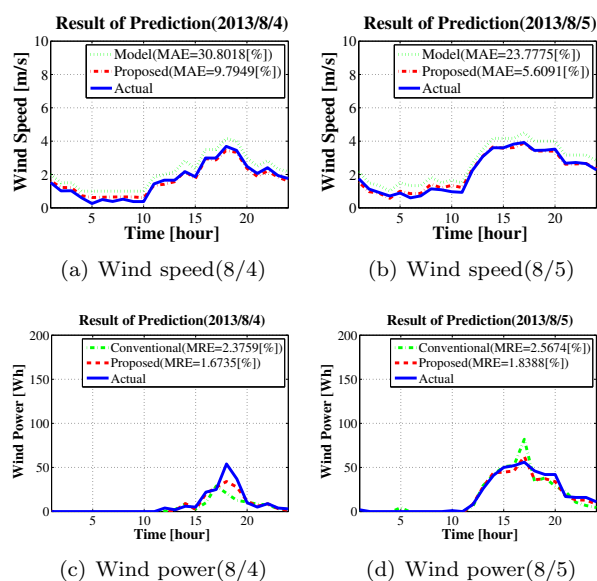


Fig. 7: Prediction result

測結果を見ると実測値の変化に気象予報と予測値はそれぞれ追従している。また、実測値との誤差率の値を見るとどちらも気象予報よりも精度の良い予測値を得られている。風力発電予測結果は、4日と5日における提案手法の誤差率はそれぞれ1.67%, 1.84%となった。これは文献³⁾の7.08%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。

6.5 予測精度の評価

8月1～7日の1週間分の評価結果を以下の Table 2, Table 3 にまとめる。評価より提案手法の予測の精度が

Table 2: Wind speed

	Error[%]
Weather forecast	46.69
JIT	42.56
proposed	30.19

Table 3: Wind power

	Error[%]
Reference ⁸⁾	17.87
Calculation	11.01
JIT	7.92
proposed	6.81

良いことがわかる。風速予測に関しては、JIT モデリングで得られた近傍データと気象予報の風速よりも、予測値は誤差率の少ない値となっていることがわかる。発

電予測に関しても同様に、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、提案手法は誤差率の少ない値となった。発電予測において、文献³⁾の予測誤差率(MRE)が7.08%に対して、提案手法では一週間での平均誤差率(MRE)が6.81%と精度が上がった。

7 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風力発電予測を考えた。提案手法では、データを JIT モデリングを用いて処理することで、予測に用いるデータの相関性を高くしている。また、未知相関係数推定において誤差共分散を減少させることで、推定での収束性を示し信頼度の高いデータでの予測を達成できた。

1週間分の予測結果の検証より、文献³⁾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。今後の課題として、年周期性や季節性の考慮、JIT モデリングの改良によりさらなる予測技術の向上を目指す。

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) Tomoki Ishikawa, and Toru Namerikawa, “Short-Term Wind Power Prediction for Wind Turbine via Kalman Filter based on JIT Modeling,” SICE Annual Conference 2013, pp. 1126-1131 (2013)
- 3) K. Bhaskar, S.N.Singh, “AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network,” IEEE Trans. Sustainable Energy, vol. 3, no. 2, pp. 306-315 (2012)
- 4) L. Wendell, H. Wegley, and M. Verholek, “Report from a Working Group Meeting on Wind Forecasts for WECS Operation,” PNL-2513, Pacific Northwest Laboratory (1978)
- 5) 滑川徹, 細田康彦, “需要曲線の特徴を考慮した H_∞ フィルタによる短期電力需要予測,” 電学論 C, Vol. 132, No. 9, pp.1446-1453 (2012)
- 6) 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)
- 7) Shinji Wakao, Daisuke Hosogoshi, Tugio Yamamura, “Fundamental Study on The Application of Just-In-Time Modeling to Wind Power Estimation,” Proceedings of JSES/JWEA Joint Conference, pp. 345-348 (2004)
- 8) A. S. Leong, S. Dey, “Power Allocation for Error Covariance Minimization in Kalman Filtering Over Packet Dropping Links,” 51st IEEE CDC, pp. 3335-3340 (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) 「Weather news」 (<http://weathernews.jp/>) (2012/5/31 アクセス)