

サポートベクター回帰とカルマンフィルタを組み合わせた風速予測

Forecasting wind speed using combination of Support Vector Regression and Kalman Filter

中村 仁之*¹
Hitoshi Nakamura

櫻井 彰人*²
Akito Sakurai

*¹ 慶應義塾大学理工学部

*² 慶應義塾大学大学院理工学研究科

Faculty of Science and Technology, Keio University Graduate School of Science and Technology, Keio University

Forecasting accurate wind speed for operating wind power generator is a difficult task due to its high uncertainty. In this paper, we show the fact that multiple forecasting methods can overcome this difficulty. We propose to use two predictors whose inputs are different from each other, to combine these predictors linearly, and adjust combination coefficients of the linear combination by exploiting the Kalman Filter. This method is capable of modeling both long term and short term fluctuations of wind speed effectively. Numerical experiments show that this method can forecast wind speed in spite of its high uncertainty.

1. はじめに

1.1 背景

近年、電力自由化の流れを追い風に、再生可能エネルギーの導入に高い関心が寄せられている。中でも、再生可能エネルギーを活用した代表的な発電装置である風力発電は、枯渇の可能性がある化石燃料での発電に代わる電源として、長い間注目されてきた。しかし風力発電は基本的に天候依存のため、その発電量が不確実であるという大きな問題点がある。具体的には、発電量が不安定で変動が激しく、なおかつ急激な需要変化にも対応できないという風力発電に特有の問題であり、これが風力発電を電力網に組み込むことを困難にしている。例えば、発電量の急変が起こると発電機が停止してしまうために電力網全体の大停電に繋がる危険性がある [1]。そしてこれを回避するためには、需給量の急変を吸収するための調整電源や蓄電池といった設備を用意する必要があるが、これには多額のコストがかかってしまう。このような問題点が風力発電の積極的導入を妨げている。もし高精度な発電量の予測が実現できれば、その情報を活用して効果的な風力発電の運用が可能となる。例えば事前に発電量の変動が見積もられれば、その情報を活用して冗長な調整電源や蓄電池を減らしコストを削減でき、あるいは、今後電力自由化で活発になると予想される電力市場に対し、価格決定等に必要で有益な情報が提供できる。このように正確な発電量予測はコスト削減や市場の最適性に貢献できるため、風力発電量の予測精度向上の研究には大変意義があると考えられる。

1.2 関連研究と問題点

前節では風力発電量について議論をしたが、風力発電量は本質的には風速に依存するため、本研究では風速の予測を行うこととする。風速は地表面、障害物、高度、大気の状態、天候など様々な影響を受けるため、ランダム性が著しい。具体的には、挙動が一様に定まらない不定性、そして不規則で突発的な挙動変化が頻繁である不規則性といった問題があり、この不定性と不規則性が予測を困難なものにしているのである。この克服のため、これまで、扱うデータの種類や手法の違いによって多種多様な風速の予測手法が研究なされてきた。それらを分類

すれば、物理モデル、統計モデルの大きく 2 種類に分けられ、それぞれは以下で述べるような利点と欠点を持っている。

物理モデルは物理原理の第 1 法則や気象学の知識を活用して風速を予測する手法であり、例えば流体解析や気象解析による予測手法や独自の気象モデルを用いた予測システムがある [2] [3]。しかし、想定した物理モデルが誤りである可能性、地形の複雑さや方程式の初期条件によって予測精度が変わること、そして複雑かつ大規模なデータを扱うため計算コストが膨大になることなどが問題点として指摘されている [1] [4]。

統計モデルは統計的手法や人工知能技術を使った予測方法であり、例えば統計的手法では自己回帰移動平均 (ARMA) モデルなどが、人工知能技術ではサポートベクター回帰 (SVR) やニューラルネットワーク (NN) などの機械学習技術が典型的な手法である [5] [6]。統計モデルではデータのみからモデルを構築するために物理モデルで必須だった専門知識が不要という利点がある一方、不適切な分布やアルゴリズムを適用してしまう可能性や、データ中のノイズや外れ値のために推定されたパラメータの信頼性が低くなるという問題点が挙げられる [4]。

以上のように各モデルとも利点と欠点の両方を併せ持つため、手法単体で用いるのではなく複数の手法を組み合わせ、それぞれの手法の利点を活かし欠点を補う方法が検討される。実際、手法を複数活用することで予測精度が上げられることが知られている [4]。従って、複数の手法を用意して各々の手法が持つ長所を活かしつつ互いの欠点を補い合うようにし、さらにこれらを統合するときにも何らかの工夫を施すことが有効であろう。

1.3 本研究の目的と手法の概要

本研究の目的は、未来の風速値を高精度に予測できる手法を構築することである。この達成のために本研究では、前節の議論を踏まえて、複数の予測器を導入して過去の風速時系列データの挙動を捉えつつ気象に関する複数の特徴量を考慮し、さらに、予測値を結合する際の係数にその時々々の風況に応じて逐次調整を施す予測手法を提案する。

具体的には次のような手法である。まず、異なる入力特徴量を使った 2 種類のサポートベクター回帰による予測器を構築し、それぞれの出力値を線形結合したものを予測値にする。そしてこの結合係数に対してカルマンフィルタを利用し、過去の誤差を反映した調整を逐次施す。入力するデータの種類を変えて差別化した 2 つの予測値を使えば、単一手法で起こりうる予測のバイアスを減少させることが期待でき、また性質の異なる予測器は活用する情報も異なるため、予測に必要で十分な種類の情

連絡先: 中村仁之, 慶應義塾大学理工学部, 〒223-8522
横浜市港北区日吉 3-14-1,
E-mail: naka.mura.nmhs@gmail.com

報を得ることもできる。さらに結合係数を逐次更新することで、直近の風況に合うように出力の調整がなされる。実データを使ったシミュレーションの結果、本手法がランダムネスの強い風速の予測に大変効果的であることが示された。

本論文は以下で構成される。まず第 2 章で本研究に用いた手法の理論概要、第 3 章と第 4 章で使用したデータと予測手法の具体的説明、そして第 5 章と第 6 章でシミュレーションの結果と考察を行う。最後に第 7 章でまとめを行う。

2. 本研究で使用した手法とその理論の概要

2.1 SVR モデリング

SVR(Support Vector Regression, サポートベクター回帰)とは、SVM(Support Vector Machine, サポートベクターマシン)において分離超平面を求める際に利用するアルゴリズムを回帰問題に適用して回帰関数を構築するモデルである。具体的には、最適化問題を解いて最適パラメータを求めるという SVM の学習アルゴリズムを回帰問題にも応用した手法である。データ点を (x_i, y_i) とすると、SVR では(1)式で表される評価関数を最小化する問題を解いて得られる(2)式の関数 $f(x)$ で回帰を行う。

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^-) \quad (1)$$

$f(x)$

$$= \sum_{i=1}^n (\alpha_i - \alpha_i^*) (x_i, x) + y_i - \epsilon - \sum_{j=1}^n (\alpha_j - \alpha_j^*) (x_i, x_j) \quad (2)$$

ただし、(1)式中の ξ_i 及び ξ_i^- は回帰誤差に関する損失、 \mathbf{w} は回帰関数の係数パラメータ、そして定数 C は回帰関数からのデータ点の乖離による損失と関数の複雑さのトレードオフを調整するハイパーパラメータである。また、(2)式中の α_i と α_i^* はラグランジュ乗数、 $(\)$ は内積演算を示す。 \mathbf{x} の入力空間において非線形な回帰関数を作成する場合は、(1)式の \mathbf{x} を、 \mathbf{x} の高次元空間への写像 $\phi(\mathbf{x})$ に置換する。高次元空間への写像後は内積計算の計算量が膨大になるが、内積計算をカーネル関数に置き換えることで大幅に計算量が削減できる。カーネル関数は、例えば(3)式のガウスカーネルがよく用いられる。

$$K(x_i, x_j) = \exp \left\{ -\frac{\|x_i - x_j\|^2}{2\sigma^2} \right\} \quad (3)$$

ただし、 σ は事前に指定しておくハイパーパラメータである。

SVR を風速予測に使う利点は次の 3 つである。まず、SVR はデータの分布に依存しない定式化であるため、不確実性が強く分布が一様に定まらない風速に対しても、その時々々の風速データ構造に合わせた分布をあてはめられる。次に、(2)式より SVR では回帰関数の複雑さがデータの次元ではなくサポートベクター数に依存するため、データの次元高次元に伴う計算量の増大を抑制できる。高次元空間に写像する場合でもカーネルトリックによって計算量を減少でき、さらに評価関数で回帰係数 \mathbf{w} の増大にペナルティを課すため次元数を増しても回帰関数の過適合を防げる。そして最後に、損失関数に絶対誤差を利用したこととトレードオフパラメータ C が調整可能であることにより、突風などの外れ値やノイズに対してもロバストに回帰関数が構築できる。

2.2 カルマンフィルタ

カルマンフィルタ(Kalman Filter, 以下 KF と省略する)とは、時系列データ(観測値) $y(t)$ を観測する度、その背後に存在する物理量(状態)を推定する方法である。KF では、状態の時間変化を記述する状態方程式と、状態と観測値との関係を記述する観測方程式の 2 式からなる状態空間モデルを用いる。時刻 t における状態を $\mathbf{x}(t)$ 、観測値を $y(t)$ 、システム雑音を $v(t) \sim N(0, \sigma_v^2)$ 、観測雑音を $w(t) \sim N(0, \sigma_w^2)$ とすると、状態空間モデルは行列 \mathbf{A} とベクトル \mathbf{b}, \mathbf{c} を用いて

$$\mathbf{x}(t+1) = \mathbf{A}\mathbf{x}(t) + \mathbf{b}v(t) \quad (4)$$

$$y(t) = \mathbf{c}^T \mathbf{x}(t) + w(t) \quad (5)$$

と表現される。(4)式を状態方程式、(5)式を観測方程式と呼ぶ。KF では、次期の状態を予測する予測ステップと予測した状態を修正するフィルタリングステップの 2 つの操作で状態 $\mathbf{x}(t)$ の推定を行う。前者で求める状態の予測値を事前状態推定値 $\hat{\mathbf{x}}^-(t)$ 、その誤差共分散を事前誤差共分散行列 $\mathbf{P}^-(t)$ 、後者で求める、事前状態推定値の更新値を事後状態推定値 $\hat{\mathbf{x}}(t)$ 、その誤差共分散を事後誤差共分散行列 $\mathbf{P}(t)$ とすると、KF は以下のステップを交互に繰り返す。

予測ステップ

$$\hat{\mathbf{x}}^-(t) = \mathbf{A}\hat{\mathbf{x}}(t-1) \quad (6)$$

$$\mathbf{P}^-(t) = \mathbf{A}\mathbf{P}(t-1)\mathbf{A}^T + \sigma_v^2 \mathbf{b}\mathbf{b}^T \quad (7)$$

フィルタリングステップ

$$\mathbf{g}(t) = \frac{\mathbf{P}^-(t)\mathbf{c}}{\mathbf{c}^T \mathbf{P}^-(t)\mathbf{c} + \sigma_w^2} \quad (8)$$

$$\hat{\mathbf{x}}(t) = \hat{\mathbf{x}}^-(t) + \mathbf{g}(t)(y(t) - \mathbf{c}^T \hat{\mathbf{x}}^-(t)) \quad (9)$$

$$\mathbf{P}(t) = (\mathbf{I} - \mathbf{g}(t)\mathbf{c}^T)\mathbf{P}^-(t) \quad (10)$$

なお、 σ_v^2 と σ_w^2 は事前に指定するハイパーパラメータである。

今回状態 $\mathbf{x}(t)$ として扱うのは、SVR_{global} による F 期後予測値 $\hat{y}_{t+F}^{\text{SVRglobal}}$ と SVR_{local} による F 期後予測値 $\hat{y}_{t+F}^{\text{SVRlocal}}$ との線形結合に用いる結合係数をベクトルにしたものである。各記号の説明など詳細は第 3 章に記述するが、本提案手法では上記 2 つの出力値を線形結合した、以下の式で予測することを考える。

$$\hat{y}_{t+F|t} = \theta_{\text{SVRglobal}}(t)\hat{y}_{t+F|t}^{\text{SVRglobal}} + \theta_{\text{SVRlocal}}(t)\hat{y}_{t+F|t}^{\text{SVRlocal}} \quad (11)$$

この結合係数を状態ベクトルにして、KF を用いて逐次推定、更新する。よって KF アルゴリズムに用いる状態量 $\mathbf{x}(t)$ は

$$\mathbf{x}(t) = (\theta_{\text{SVRglobal}}(t), \theta_{\text{SVRlocal}}(t))^T \quad (12)$$

と設定することとなる。(12)を結合係数ベクトルと呼ぶ。

KF の利点は結合係数を自動調整できることである。係数値は常に一定ではなく風況や時間に応じて変化するため、固定値に設定することができない。そこで観測値が入る度に KF で状態推定し最新の風況に適した係数値へ自動調整するのである。

3. データ

今回使用するデータは、「風速(m/s)」、「気温(°C)」、「気圧(hPa)」、「日照時間(時間)」の 4 種類である。前者 2 つは慶應義塾大学矢上キャンパスの屋上風車で観測された 10 分間隔データを、後者 2 つは気象庁横浜地方気象台で観測された 60 分間隔データを使用した [7]。前者と後者ではサンプリング間隔が異なっていたため、後者の「気圧」と「日射時間」のデータに 3 次スプライン補間を施し、全種類を 10 分間隔のデータに揃えた。また各観測値はそれぞれ単位も値域も異なることと SVR を活用する際はデータの基準化が必要なことから、4 種類全てのデータに基準化を施した。ただし、予測値の性能評価の際は、基準化と逆の処理を行って元データの尺度に戻してから評価をした。

4. 提案する予測手法

以下では、第 2 章で取り上げた各種手法のアルゴリズムを風速予測へどう応用したかを説明する。なお、何期先を予測するか(予測ステップと呼ぶ)の表現は、今後「 F 期先」と表す。

4.1 SVR によるモデリング方法

これ以降、上記で説明した大域的な予測をする SVR 予測値を SVR_{global}、詳細な予測をする SVR 予測値を SVR_{local} と呼ぶ。

(1) 学習方法

過去の風速時系列データ(以下、学習データと呼ぶ)を用いて、

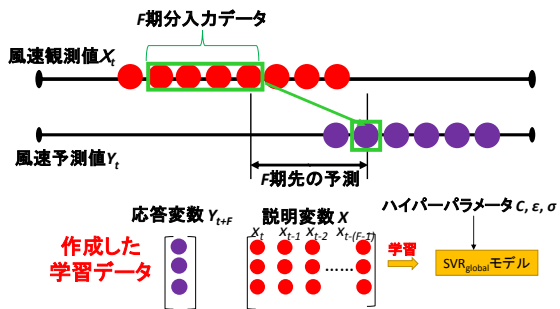


図 1 SVR_{global} の学習方法.

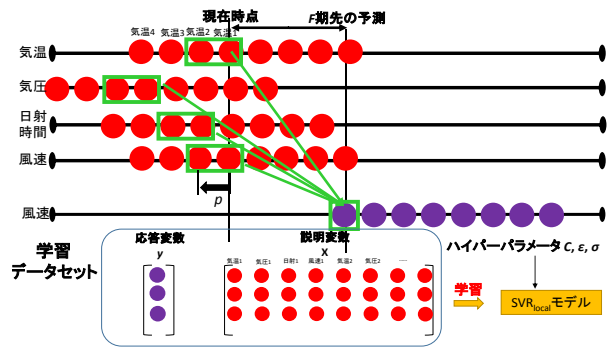


図 2 SVR_{local} の学習方法.

SVR_{global} 及び SVR_{local} のモデル構築 (以下, 学習と表記する)を行う. 学習方法は以下の手順で行った. また, 図 1 に SVR_{global} の, 図 2 に SVR_{local} の学習方法の概略を示す.

① 学習データの構築

SVR の学習には入出力の形をしたデータが必要なため, 学習に使う時系列型の風速データを入出力の組の形へと変換した. まず SVR_{global} の入力, 現在時刻 t から過去 F 期分まで遡った風速値とした. そして SVR_{local} の入力, 「気温」, 「気圧」, 「日射時間」, 「過去の風速」の 4 種類の特徴量について, 過去の風速からみて最も相互相関の強いラグ分をずらしてとった数期分の観測値とした. 出力は両手法とも F 期先の風速値とした.

② 学習データによる SVR の学習

① で作成した入出力データを学習データとし, SVR_{global} 及び SVR_{local} それぞれのモデルを推定した. カーネル関数にはガウスカーネルを使用し, モデル作成に必要な 3 つのハイパーパラメータ (C , ϵ , 及び σ) は後ほど述べる方法で事前決定しておいた.

(2) 予測方法

テストデータで未来風速値を予測する. 学習済の予測器にデータを入力し予測値を出力する流れであり, 以下に手順を示す.

① テストデータの再構築

前項の入出力データ作成方法と同様の手順で, テストに使う時系列型のデータを入出力データへ変換しテストデータとした.

② 予測

作成した各々のモデルを使ってデータセットの入力データを 2 つの予測器それぞれに入力し, F 期先風速予測値を出力した. こうして得た 2 つの F 期先風速予測値はそれぞれ $\hat{y}_{t+F|t}^{SVR_{global}}$ と $\hat{y}_{t+F|t}^{SVR_{local}}$ とで表す. そして両出力値を(11)式の通り線形結合し, この値をもって最終的な予測値とした.

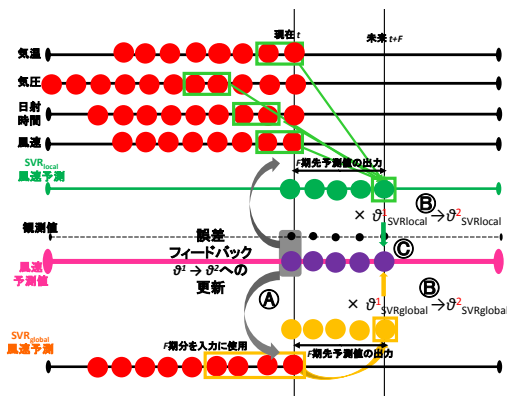


図 3 KF による線形結合係数の更新方法. 過去に予測した値と実際の実測値の誤差をフィードバックし(A), フィルタリングステップで結合係数ベクトルを更新し(B), 更新された結合係数で SVR_{global} 予測値と SVR_{local} 予測値を線形結合したものを, 予測値として出力する(C).

4.2 KF による結合係数の更新

(11)式中の結合係数を KF で更新する. (12)式で表す結合係数ベクトル $\mathbf{x}(t)$ を状態として状態空間モデルを作り, この $\mathbf{x}(t)$ を逐次推定, 更新する. 図 3 に概要を, 以下に具体的手順を示す.

① 状態空間モデルの構築

(4)式及び(5)式で表される状態空間モデルの式を, それぞれ以下の状態方程式(13)と観測方程式(14)に設定した.

$$\begin{pmatrix} \theta_{SVR_{global}}(t+1) \\ \theta_{SVR_{local}}(t+1) \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \theta_{SVR_{global}}(t) \\ \theta_{SVR_{local}}(t) \end{pmatrix} + \mathbf{v}(t) \quad (13)$$

$$y(t+F) = \begin{pmatrix} \hat{y}(t+F|t) & \theta_{SVR_{global}} \\ \hat{y}(t+F|t) & \theta_{SVR_{local}} \end{pmatrix}^T \begin{pmatrix} \theta_{SVR_{global}}(t) \\ \theta_{SVR_{local}}(t) \end{pmatrix} + w(t) \quad (14)$$

ただし, システム雑音 $\mathbf{v}(t)$ は $\mathbf{v}(t) \sim N(0, \Sigma_v)$ と二変量正規分布, 観測雑音 $w(t)$ は $w(t) \sim N(0, \sigma_w^2)$ と一変量正規分布に従う. 今回の手法では, (5)式中の c が時変係数 $\mathbf{c}(t)$ となる.

② $F \sim F + (F - 1)$ までの, F 期分の予測

SVR_{global} と SVR_{local} の 2 つの予測値を現在の結合係数ベクトル $\mathbf{x}(t)$ で線形結合し((11)式を参照), $\hat{y}_{t+F|t}$, $\hat{y}_{t+F+1|t+1}$, ..., $\hat{y}_{t+F+(F-1)|t+(F-1)}$ と F 個の予測値を求める. 各時刻 t では予測ステップ(13)式を F 回繰返し, 事前状態推定値 $\hat{\mathbf{x}}^-(t+F)$ を得る.

③ 予測, 実測値の誤差フィードバックによる結合係数更新

時刻 $t+F$ で KF フィルタリングステップ(8)~(10)式を行い, 予測値と実測値の誤差から事前状態推定値 $\hat{\mathbf{x}}^-(t+F)$ を事後状態推定値 $\hat{\mathbf{x}}(t+F)$ へと更新する. 得られた $\hat{\mathbf{x}}(t+F)$ は予測誤差を反映した新しい係数 $(\theta_{SVR_{global}}(t+F), \theta_{SVR_{local}}(t+F))^T$ であり, これを用いて次の F 期先予測が行われる.

4.3 ハイパーパラメータ

(1) ハイパーパラメータの種類

SVR ではトレードオフパラメータ C と損失関数における ϵ 不感帯の幅 ϵ 及びガウスカーネルのパラメータ σ が, KF ではシステム雑音の分散 Σ_v と観測雑音の分散 σ_w^2 が, 事前に決定の必要なハイパーパラメータである. このうち KF のシステム雑音は大変小さいと考えて $\Sigma_v = \begin{pmatrix} 0.05^2 & 0 \\ 0 & 0.05^2 \end{pmatrix}$ と恣意的に定めたが, 他の $(C, \epsilon, \sigma, \sigma_w^2)$ は予測性能を左右するためその決定には考慮が必要ゆえ, 次の要領でそれらの値を決定した. まず, 予測を行う年の前年同期間における学習データとテストデータを使って (C, ϵ, σ) のグリッドサーチを行い, 最小の MAE 値を与える SVR ハイパーパラメータの組み合わせ (C, ϵ, σ) を決定した. 次にこの (C, ϵ, σ) を用いた SVR_{global} と SVR_{local} で予測を行い, 同じく最小の MAE 値を与える KF の観測ノイズ σ_w^2 をグリッドサーチにて求めた. 以上の手続きにより, 4 つのパラメータを $(C, \epsilon, \sigma) \rightarrow \sigma_w^2$ の順で決定した.

5. シミュレーション

第3章で説明したデータで風速値の予測シミュレーションを行い、提案手法と比較対象手法とを比較した。用いたデータ、比較対象及び評価基準予測、そして予測結果を以下で示す。

5.1 使用したデータの年月日とハイパーパラメータ設定

学習データの月日は春夏秋冬の全季節、表1の期間とした。

表1 シミュレーションに用いた期間の年月日。

季節	春	夏	秋	冬
学習	'14 4/4~4/11	'14 7/4~7/11	'14 10/4~10/11	'14 1/4~1/11
テスト	'14 4/16~4/17	'14 7/16~7/17	'14 10/16~10/17	'15 1/16~1/17

なお、予測は3時間先、つまり F を3時間分である $F=18$ とした。これは、本研究の主目的が発電量予測による大停電防止であり、このための調整電源の安定稼働に必要な時間が数時間だからである[8]。ハイパーパラメータは、2013年の7/4~7/11を学習、7/15~7/19をテスト期間にし、4.3(1)の方法で決定した。

5.2 比較対象と性能評価基準

提案手法に対する比較対象(ベンチマーク手法と表す)には次の2つを使用する。1つは SVR_{global} と SVR_{local} に使うデータを一緒に入力した単一の SVR モデル(SVR_{only} と表す)、もう1つは幅広い分野で高精度を誇るニューラルネットワーク(NN)である。前者を使う目的は単一手法よりも複数手法が有効なことを示すため、後者を使う目的は、様々な分野で使用されている手法ゆえ比較対象にふさわしいからである。比較条件統一のため両者は提案手法と同一の入出力データとした。ハイパーパラメータは、 SVR_{only} は提案手法と同じ方法で決定し、NNは層構造を入力・中間・出力層の3層、中間層素子数を10、活性化関数は中間層出力にシグモイド関数、出力層に線形関数を使った。

予測の評価基準には、主に平均二乗誤差(MSE)と平均絶対誤差(MAE)の2種類があるがそれぞれ性質が異なるため、本研究では両方を評価基準に用いた。もし提案手法がベンチマーク手法よりも良い成績を出せば本提案手法が有用であると言える。

5.3 シミュレーション結果

(1) 提案手法とベンチマーク手法の性能比較

提案手法及びベンチマーク手法で行った3時間先予測シミュレーションの、予測に対するMAE値とMSE値を表2に示す。表2から明らかなように、冬のMSE値を除き、全季節で提案手法がより低いMAE、MSE値を達成した。どの季節でも提案手法の予測性能がベンチマーク手法のそれを上回ることが示せた。

表2 シミュレーションの結果得られた各手法の誤差評価。

手法	提案手法		SVR_{only}		NN	
	MAE	MSE	MAE	MSE	MAE	MSE
基準						
春	0.96	1.44	1.06	1.67	1.41	3.22
夏	0.65	0.71	0.70	0.80	0.75	0.88
秋	0.66	0.65	0.73	0.74	0.81	0.94
冬	0.90	1.47	0.91	1.46	1.64	4.74

6. 考察

表2から、いずれの季節でも提案手法がベンチマーク手法を上回る予測能力を持つことが示せた。これは本提案手法が、風速の持つ不定性と不確実性を低減し、その予測に対して効果的に働いたことを示唆する。1つ目の問題点である不定性の低

減は、複数の予測器が相互に誤差を打ち消し、予測に必要な情報を十分確保して実現できたと考える。性質の異なる2種類の SVR 予測器の導入により風速の振舞いに応じて適切な方の手法が適宜選択ないし混合されることで、片方の予測器が不適切な予測をしても、もう片方がそれを打ち消したと推測する。そして両予測器はそれぞれ相異なる種類の入力特徴量ゆえ、予測に必要な十分な種類の情報を取り込み、これも不定性低減に寄与したと考えられる。そして2つ目の問題点である不規則性の低減は、その時々々の風況固有の状態に出力値を調整することで実現したと考える。KFにより、2種類の出力値の結合に用いる係数を、新たな観測値が入る度に自動調整したと考える。

以上をまとめると、本手法は、2つの予測器が互いに誤差を打ち消し十分な情報を取り込み、結合係数をその時々々の風況に応じて自動調整し、比較的高精度な予測がなされたと推測する。

7. まとめ

本研究では、複数手法とその結合係数の逐次調整からなる予測手法が予測困難な風速が比較的高精度に予測できることを示した。提案手法ではまず、入力を変えて性質の異なる2種類の予測器を作り、両者の線形結合値を予測結果とした。互いに性質の異なる2つの予測器によって、予測の誤差を低減することができた。そして、KFで結合係数を現在の風況に逐次適合させることで、急変動に追従する予測を実現した。その結果、全季節で本提案手法が比較対象よりも低い誤差を実現し、不定性と不規則性を持つ風速の予測に本提案手法が効果的であることが示された。

今後の課題は、グリッドサーチ以外のハイパーパラメータ決定方法や、今回用いた特徴量以外のものを検討することである。

参考文献

- [1] マティアス,ランゲ;ウルリッヒ,フォッケン;石原孟 ほか訳、『風力発電出力の短期予測』,東京:オーム社,2012.
- [2] 藤野陽三,山口敦,石原孟,「力学統計的局所化による新しい風況予測手法の提案と実測による検証」,土木学会論文集A, vol.62, no.1, pp. 110-125, 2006.
- [3] California Institute for Energy and Environment, “California Renewable Energy Forecasting, Resource Data and Mapping,” 2010.
- [4] G. Giebel, R. Brownsword, G. Kariniotakis, M. Denhard, C. Draxl, “The State-Of-The-Art in Short-Term Prediction of Wind Power: A literature Overview, 2nd Edition,” Project ANEMOS Deliverable Report, 2011.
- [5] D. Liu, D. Niu, H. Wang, L. Fan, “Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm,” Renewable Energy, vol.62, pp. 592-597, 2014.
- [6] J. Torres, A. Garcia, M. Blas, A. Francisco, “Forecast of hourly average wind speed with ARMA models in Navarre (Spain),” Solar Energy, vol.79, no.1, pp. 65-77, 2005.
- [7] 気象庁,「過去の気象データ・ダウンロード」[Online]. Available: <http://www.data.jma.go.jp/gmd/risk/obsdl/index.php>. [Accessed: Nov. 25, 2015].
- [8] 経済産業省 資源エネルギー庁,「火力発電による太陽光発電の出力変動対策」,低炭素電力供給システムに関する研究会報告書(3), p.72, 2009.
- [9] 足立修一,丸田一郎,『カルマンフィルタの基礎』,東京:東京電機大学出版局,2012.
- [10] 小野田崇,『サポートベクターマシン』,東京:オーム社,2007.