Any-Place Forecasting Method of Nationwide Time-Series Wind Speed Using Classified Forecast Models based on Wind Conditions

Shinichiro Oke Member (Toyohashi University of Technology)

Shin Higashiyama Student Member (Toyohashi University of Technology)

Yoshiyuki Suda Member (Toyohashi University of Technology)

Hirofumi Takikawa Member (Toyohashi University of Technology)

Keywords: nationwide time-series forecast of wind speed, neural network, RBFN, forecasting method using classified forecast model, wind speed estimation

Most of the methods forecasting the wind speed proposed so far are not universal and available only for specific area. In the present study, forecasting method of a time-series wind speed 24-hours ahead at any location in Japan was proposed, which was based on classified forecast models by wind conditions (called FCCM; Forecasting Method using Classified forecast Model). The model was structured by the radial basis function network (RBFN) and the performance was compared to the conventional feed forward neural network (FFNN). Figure 1 shows that structure of the RBFN which has 3 layers. The input vector x is inputted at the input layer. The hidden layer, it is function of u_j and σ_j , outputs h_j . Elements of output vector y_k are calculated from h_j and wait w_{kj} .

The procedure of the FCCM was as follows; (1) All the points where wind speed had been measured by the Japan Meteorological Agency were divided into the groups depending on their wind conditions (mean wind speed and standard deviation of wind speed). Figure 2 shows that relationship of mean wind speed and standard deviation of wind speed of 156 SDP points in winter. Group (a) and group (b) in this figure are mean wind speed: 1~2 m/s, standard deviation: 1~2 m/s and Mean wind speed: 5~6 m/s, standard deviation: 2~3 m/s, respectively. (2) RBFN was learned and the network model was optimized to forecast wind speed in each group. (3) If the wind speed was not measured in the forecast point, it was estimated by using measured data around there. (4) Then, the time-series wind speed of the forecast point was obtained by the network model for the group. The wind speeds at 6 points in Japan where the wind

condition were different were forecasted by FCCM.

Figure 3 shows that MAE of forecasted wind speed in winter 2005 using measured wind speed and estimated wind speed, respectively. As a result, the mean absolute error was about from 1.0 to 1.5 m/s. Although forecast error of RBFN and that of FFNN were similar, RBFN was able to learn fast than FFNN.

Fig. 1. Structure of radial basis function network (RBFN)

Fig. 2. Relationship of mean wind speed and standard deviation of wind speed of 156 SDP points in winter

Fig. 3. MAEs of forecasted wind speed in winter 2005 using measured wind speed and estimated wind speed

風況区分予測モデルを用いた全国各地の時系列風速予測

正員 桶 真一郎* 学生員 東山 伸*

正員 須田 善行* 正員 滝川 浩史*

Any-Place Forecasting Method of Nationwide Time-Series Wind Speed Using Classified Forecast Models based on Wind Conditions

Shinichiro Oke*, Member, Shin Higashiyama*, Student Member, Yoshiyuki Suda*, Member,
Hirofumi Takikawa*, Member

Most of the methods forecasting the wind speed proposed so far are not universal and available only for specific area. In the present study, forecasting method of a time-series wind speed 24-hours ahead at any location in Japan was proposed, which was based on classified forecast models by wind conditions (called FCCM; Forecasting Method using Classified forecast Model). The model was structured by the radial basis function network (RBFN) and the performance was compared to the conventional feed forward neural network (FFNN). The procedure of the FCCM was as follows; (1) All the points where wind speed had been measured by the Japan Meteorological Agency were divided into the groups depending on their wind conditions (mean wind speed and standard deviation of wind speed). (2) RBFN was learned and the network model was optimized to forecast wind speed in each group. (3) If the wind speed was not measured in the forecast point, it was estimated by using measured data around there. (4) Then, the time-series wind speed of the forecast point was obtained by the network model for the group. The wind speeds at 6 points in Japan where the wind condition were different were forecasted by FCCM. As a result, the mean absolute error was about from 1.0 to 1.5 m/s. Although forecast error of RBFN and that of FFNN were similar, RBFN was able to learn fast than FFNN.

キーワード：全国各地時系列風速予測，ニューラルネットワーク，RBFN，風況区分予測法，風速推測

Keywords: nationwide time-series forecast of wind speed, neural network, RBFN, forecasting method using classified forecast model, wind speed estimation

1. はじめに

太陽光発電や風力発電の出力は、日射量や風速に左右される。これらの装置を含んで構成された電力や熱の供給システムを、ランニングコストやCO₂排出量削減の面から効率的に運転するためには、日射量や風速を事前に予測しておくことが望ましい⁽¹⁾⁽²⁾。特に、風力発電の発電電力は風況の変化に伴って大きく変動するので、電力系統への風力発電の連系量が増加すると、系統からの見かけの負荷変動が増大し、系統全体に悪影響を与えるおそれがある。そのため、ウィンドファームへの蓄電設備の導入⁽³⁾⁽⁴⁾や風力発電の出力変動を吸収するための供給予備力としての可変電源の併設が検討されている。しかし、どちらの対策をとる場

合にも、設備コストや運用コストが増加するという問題がある。このような問題を解決するため、系統運用計画における風速予測の利用による蓄電設備のkWh容量の最適化、揚水発電などの計画的な利用、風力発電機の解列・出力抑制、および会社間連系線の活用による長周期変動の回避などが検討されている⁽⁵⁾。また、より多くのユーザが日射量や風速の予測を用いた運転を活用するためには、全国各地の任意の地点において、それらの予測を可能とすることが求められる。

これまでに、ニューラルネットワーク(NN)を用いたいくつかの気象予測法が提案されてきている^{(6)~(8)}。風速予測においては、類似天気日を抽出してフィードフォワードNN(FFNN)の学習を効率化する方法⁽⁹⁾、ARMAモデルを用いる方法⁽¹⁰⁾、リカレント型NNを用いる方法⁽¹¹⁾などがある。しかしながら、従来の予測法は、どのようなネットワークを用いた場合でも、予測地点ごとに専用の予測モデルを構築し、予測地点における過去の気象データを用いる必要があり、過去の気象データが蓄積されていない地点や

* 豊橋技術科学大学 電気・電子工学系
〒441-8580 豊橋市天伯町雲雀ヶ丘 1-1
Electrical and Electronic Engineering, Toyohashi University of
Technology
1-1, Hibarigaoka, Tempaku, Toyohashi 441-8580

気象データを計測していない地点の予測はできない。したがって、従来の予測法では全国各地の任意の地点の風速を予測することは困難である。

一方、筆者らのグループでは、FFNNを用いた日射量や風速の予測法を検討してきた^{(12)~(15)}。特に、日射量予測に関しては、日本列島を10気候区に分け、各気候区に対し単一の代表モデルを用いて全国各地の日日射量曲線を予測する気候区代表モデル予測法⁽¹⁵⁾を提案し、全国各地の任意の地点の日射量の変動を110~130 Wh/(m²・h)程度の平均誤差で予測した。今回は、風速予測に対して、同様な地点区分の考えを適用し、従来のように予測地点ごとに異なる予測モデルを構築するのではなく、あらかじめ風況ごとに予測モデルを構築しておく風況区分予測法 (Forecasting Method using Classified forecast Model ; FCCM) を考案した。また、風速データを計測していない地点における予測を可能とするために、周辺の地点の風速データを用いて予測地点の風速を推測する手法を考案した。これらの手法を用い、風況区分予測法および推測風速を用いて全国各地の24時間先までの3時間毎の風速を予測し、その予測誤差を検討した。なお、風速予測のモデル化において、FFNNではなく、ラジアル基底関数ネットワーク (RBFN)⁽¹⁶⁾⁽¹⁷⁾を用いた。RBFNは、FFNNよりも予測誤差の収束が速いとされており、気象予測への応用が注目されている。

2. 時系列風速予測へのRBFNの適用

筆者らは、これまで、3層構造を有するFFNNを用いた風速予測^{(13)~(15)}を検討してきたが、本研究ではRBFNを採用した。RBFNの構造は、これまで検討してきたFFNNと同じ3層構造とした。図1に、本研究で用いたRBFN (隠れ層ユニット数: m 個) の構造を示す。RBFNの入力層には入力ベクトル $\mathbf{x}$ (データ要素数: l 個) を入力する。隠れ層の出力は各ユニットの受容領域の中心と広がりを表す $\mathbf{u}_j$ と σ_j との関数である。隠れ層は、入力ベクトルとの距離に従って、(1) 式で表される隠れ層ユニット出力 h_j を出力する。

$$h_j = \exp\left(-\frac{\|\mathbf{x} - \mathbf{u}_j\|^2}{2\sigma_j^2}\right) \dots\dots\dots (1)$$

ここで、 $\mathbf{u}_j$: 隠れ層ユニット j のプロトタイプベクトル、 σ_j : 隠れ層の受容領域を表すスプレッドパラメータである。出力ベクトル $\mathbf{y}$ は、隠れ層ユニット出力 h_j 、重み $\mathbf{w}$ 、および隠れ層ユニット数 m から、(2) 式を用いて求められる。

$$y_k = \frac{\sum_{j=1}^m h_j w_{kj}}{m} \dots\dots\dots (2)$$

ここで、 y_k : 出力ベクトル $\mathbf{y}$ の k 番目の要素、 w_{kj} : 隠れ層ユニット j からの出力の出力層に対する重みである。

RBFNを学習する際に入力層に入力するデータセットを

図1 RBFNの構造

Fig.1. Structure of radial basis function network (RBFN).

学習用データセット、出力層に設定するデータセットを教師データセットと呼び、学習済みのモデル構築済みRBFNを用いて予測する際に入力層に入力するデータセットを入力データセットと呼ぶこととした。

RBFNは、その学習を開始する前に、入力データをクラスタリングしておく必要があり、クラスタリングにより、 $\mathbf{u}_j$ および σ_j の初期値を決定する。本研究では、非階層型クラスタリング手法のひとつであり、クラスタの平均を用いて入力データを K 個のクラスタに分類する K -means 法⁽¹⁸⁾を適用した。

RBFNの学習アルゴリズムは、NNの学習においてよく用いられているバックプロパゲーションとした。また、季節によって大きく異なる風況に対応するため、春 (3~5月)、夏 (6~8月)、秋 (9~11月)、および冬 (12~2月) それぞれに異なるネットワークを構築した。

3. 時系列風速予測モデル

〈3・1〉 時系列風速予測の概要 24時間先までの3時間毎の平均風速を予測した。予測および予測結果の評価には、1999~2005年の地上気象官署の気象観測データ (SDPデータ) を用いた。RBFNの入力データセットは、予測地点および予測地点周辺における3時間前から予測時点までの1時間毎の平均風速とした。これまでに、NNを用いた風速予測においては、予測地点から100km程度の範囲で計測された気象データが有効であることが示されている⁽¹⁹⁾ので、本研究でもそれを踏襲した。たとえば、予測地点を静岡県御前崎とする場合、図2に示すように、御前崎 (予測地点)、浜松、静岡、石廊崎、および三島の4地点の風速データを学習用および予測用データセットとした。以上のことから、RBFNの入力ベクトルのデータ要素数は15個 (3時間×5地点)、出力ベクトルのデータ要素数は8個 (3時間毎に24時間先まで) とした。なお、学習用および教師データセットは、次に示す予測法ごとに異なるデータセットを使用することとした。本研究では、学習用および予測用データセットを構成する地点数を4としたが、予測誤差のさらなる低減のためには、地点数の最適化が求められる。

〈3・2〉 単地点毎予測法 (従来手法) 予測地点ごとに

図2 予測地点（御前崎）および予測地点から100 km 以内にある気象観測地点の例

Fig. 2. Example of forecast point (Omaezaki) and data points (within 100 km from the forecast point).

専用の予測ネットワークを構築する従来の手法である。この方法を用いる場合には、予測地点における過去の風速データが蓄積されていることが必要条件であった。なぜなら、学習用および教師データセットに予測地点の過去の風速データを用いる必要があるからである。

〈3・3〉 風況区分予測法 予測用ネットワークの学習を、予測地点毎ではなく風況ごとに分類したグループごとに行う手法で、予測地点の風速データが蓄積されていない場合には周辺地点の風速データを用いてそれを推測することによって、全国各地の任意の地点の風速を予測する。以下に、その予測手順を示す。

まず、SDP データに収録されている 156 の風速計測地点を季節毎の風況（平均風速および風速の標準偏差）に基づきグループ分けする。ここでは、グループ分けの方法について、冬を例として説明する。図3に、冬における全国 156 地点の平均風速と風速の標準偏差との関係を示す。同図から、冬における平均風速と風速の標準偏差との関係は、線形に近いことがわかる。また、ほとんどの地点は、平均風速：1~7 m/s、風速の標準偏差：1~4 m/s の範囲に収まることわかる。同図に示すように、平均風速および風速の標準偏差 1 m/s 毎にマス目を描き、そのマス目 1 つに含まれる風速計測地点を 1 つのグループとし、156 の風速計測地点は 16 のグループに分けられた。同図中のグループ (a)（平均風速：1~2 m/s、風速の標準偏差：1~2 m/s）およびグループ (b)（平均風速：5~6 m/s、風速の標準偏差：2~3 m/s）に属する地点を図4に示す。グループ (a) に属する地点は同図 (a) に示す 10 地点で、やや西日本に偏っており、グループ (b) に属する地点は同図 (b) に示す 8 地点で、本州中央部を含まないことがそれぞれわかる。他の季節についても同様にグループ分けを行った結果、各季節のグループ数は、春：14、夏：12、秋：15 となった。

次に、各グループに属する全ての地点に対して、最適なネットワークとなるように RBFN を学習する。このとき、RBFN の教師データセットをグループに属する各地点の風速データ、学習用データセットを各地点の周辺 100 km 圏内のできるだけ予測地点に近い 4 地点（以下、周辺 4 地点）の風速データとする。たとえば、図 4(b) に示したグループ

図3 156 の SDP 地点における平均風速と風速の標準偏差との関係

Fig. 3. Relationship of mean wind speed and standard deviation of wind speed of 156 SDP points in winter.

図4 冬におけるグループ分類例

Fig. 4. Classified points into groups (a) and (b) in winter.

の場合、留萌、釧路、室蘭、八戸、浜田、枕崎、油津、および那覇の風速データを教師データセットとし、それぞれの周辺 4 地点の風速データを学習用データセットとする。これらの作業を、季節毎に全グループに対して行ない、予測地点の風況（平均風速および風速の標準偏差）によって、適用するネットワークが一意に定まるようにする。この方法の場合、予測できない地点は存在しないことになる。

実際に風速を予測する場合には、まず、予測地点における季節毎の平均風速および風速の標準偏差を求め、予測地点が属するグループを判定し、予測に用いるネットワークを決定する。ここで、過去の風速データが蓄積されていない地点の風速を予測する場合には、学習用および予測用デー

図5 豊橋における推測風速および実測風速
(2005/1/1~5)

Fig. 5. Estimated and measured wind speed data in Toyohashi (2005/1/1~5).

タセットを準備する場合に準拠し、予測地点から最も近い4地点の風速データを単純平均して予測地点の過去の風速データを推測し、代用する。図5に、SDPデータには風速が収録されていない愛知県豊橋における推測風速(2005年1月1日~5日)を示す。同図中の実測風速はアメダスによる計測値である。同図から、周辺の地点の風速データを平均することによって、風速を計測していない豊橋における風速データを推定できたことがわかる。なお、推測地点からの距離によって重み付けした加重平均よりも単純平均の方が、推測誤差が小さいことを前もって確認した。次に、実測あるいは推測によって用意した予測地点の風速データ、および予測地点周辺(100 km圏内)の4地点の風速データを予測用データセットとして、予測地点が属するグループに対して構築したネットワークを用いて24時間先までの時系列風速を予測した。

4. 風速予測結果の検討

〈4・1〉 予測結果の評価 予測結果の評価には、平均絶対誤差(MAE)、平均絶対誤差率(%MAE)、および最大絶対誤差を用いた。MAEおよび%MAEは次式を用いて求めた。

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |W_p(i) - W_m(i)| \dots \dots \dots (3)$$

$$E_{\%MAE} = \frac{\frac{1}{N} \sum_{i=1}^N |W_p(i) - W_m(i)|}{\frac{1}{N} \sum_{i=1}^N W_m(i)} \dots \dots \dots (4)$$

ここで、 E_{MAE} : 絶対平均誤差、 $E_{\%MAE}$: 絶対平均誤差率、 N : データ数、 $W_p(i)$: 予測値、 $W_m(i)$: 実測値である。

〈4・2〉 RBFNとFFNNとの比較 図6に、24時間分の時系列予測結果のうち、3時間後までの予測平均風速のみを抜き出し、並べた予測時系列例(2002年6月1日~20日)を示す。同図から、RBFNを用いて、3時間後までの平均風速をおおむね予測できたことがわかる。次に、予

図6 RBFNによる御前崎における予測風速
(2002/6/1~20)

Fig. 6. Wind speed forecasted by RBFN in Omaezaki (2002/6/1~20).

測用ネットワークにRBFNを用いた場合とFFNNを用いた場合とを比較検討した。予測手法は単地点毎予測法とし、予測地点は静岡県御前崎とした。今回用いたFFNNの設定は、入力層ユニット数:15、出力層ユニット数:8、シグモイド関数の傾き:1.0、学習係数:0.6、学習回数:3万回、結合荷重の修正法:一括修正法、とした。なお、隠れ層ユニット数は、従来の方法^{(13)~(15)}と同様に、入力層ユニット数の3分の1(今回の場合は5)とした。RBFNの入力層ユニット数、出力層ユニット数はFFNNと同じとし、隠れ層ユニット数はパラメータとして変化させた。図7に、季節ごとの%MAEを示す。同図から、RBFNの予測誤差はFFNNよりも全体的に1~4ポイント程度高いことがわかる。これは、今回用いた入力データセットはFFNNに対して最適となるように構築されたものであり、必ずしもRBFNに対して最適な構成ではなかったことが主な理由である。また、RBFNは、隠れ層ユニット数(同図中の m)が多いほど予測誤差が小さくなることがわかる。これ以降は、RBFNの隠れ層ユニット数を80とした場合の結果について述べる。図8に、1999年の冬における風速を予測した場合におけるRBFNおよびFFNNの学習回数と予測誤差との関係を示す。同図から、FFNNは学習開始時の予測誤差が大きく、学習回数を重ねても予測誤差があまり減少しないことがわかる。また、FFNNの予測誤差は不規則に減少していくことがわかる。一方、RBFNは、学習開始時の予測誤差がFFNNより小さく、ネットワークの学習による予測誤差の収束も速い。また、RBFNにおいては、隠れ層ユニット数が多いほど、予測誤差の収束が速い傾向にあった。これに対して、FFNNの場合は、予測誤差を低減するために隠れ層ユニット数を多くすると、学習回数が非常に多くなり、予測にかかる時間が長くなる。

〈4・3〉 風況区分予測法の評価 図9に、風況区分予測法を用いて予測した福岡県福岡の時系列風速を示す(2005年1月1日~10日)。同図(a)は、福岡で計測されている風速データを用いず、周辺の地点の風速データから推測した

図7 御前崎における各季節の予測誤差
Fig. 7. Forecast error for each season in Omaezaki.

図8 学習回数の増加に伴う予測誤差の減少
(1999年, 冬)
Fig. 8. Decrease of forecast error as a function of learning number of times in winter 1999.

風速データを用いて予測した場合, 同図 (b) は, SDP データに収録されている福岡の風速データを用いて予測した場合である。両図を比較すると, 風速が極端に強くなった4日や9日にはやや差があるものの, 全体的な予測値に大きな差はないことがわかる。

図10に, 全国各地の6地点の時系列風速を, 風況区分予測法を用いて予測した場合のMAEを示す。なお, 同図に示したのは, 予測した24時間先までの時系列風速のうち, 3時間後までの予測平均風速に含まれるMAEである。同図から, 静岡県御前崎を除いて予測風速に含まれるMAEはおおよそ1.0~1.5 m/s程度であることがわかる。この値は, 我が国において時系列風速を予測した文献(9)において示された予測誤差(1.5 m/s程度)と同等かそれ以下である。また, 本研究で提案した風速予測法は, 他の予測法に比べて簡易であり, 予測に必要なデータ量が少ないという利点がある。なお, %MAEは, いずれの地点においても約20~30%程度であった。また, 最大絶対誤差は, 春・夏においては7~8 m/s程度, 秋・冬においては4.5~5.5 m/s程度であった。

(a) Using estimated wind speed data

(b) Using measured wind speed data

図9 推測風速あるいは実測風速を用いて予測した風速の時系列例 (福岡, 2005年1月)

Fig. 9. Time series of forecasted wind speed using (a) estimated wind speed data and (b) measured wind speed data at January 2005 in Fukuoka.

図10 推測風速あるいは実測風速を用いて予測した各地点の風速に含まれるMEA (2005年冬)

Fig. 10. MAEs of forecasted wind speed in winter 2005 using measured wind speed and estimated wind speed.

以上のことから, 風況区分予測法を用いることによって, 予測地点において風速データが計測されているか否かにかかわらず, 全国各地の任意の地点の時系列風速を比較的よい精度で予測できることをわかった。

5. まとめ

風速のデータ蓄積がない地点も含めた全国各地の風速予測を統一的行うため, あらかじめ風況ごとに予測用ネットワークを構築しておく風況区分予測法, および予測地点

において過去の風速データが蓄積されていない場合には、周辺の地点の風速データを用いて必要な地点の風速データを推測する手法を考案し、検討した。また、本研究では、FFNN よりも短時間で誤差が収束する RBFN を用いて予測用ネットワークを構築した。これらの方法を用いて全国各地の風速を予測したところ、地点によって予測誤差に大きな差はなく、どの地点においても、MAE: 1.0~1.5 m/s 程度、%MAE: 20~30% 程度の予測誤差で予測できた。また、RBFN は、FFNN より学習が短時間で済み、ほぼ同程度の誤差で予測ができることがわかった。なお、風況区分予測法は、FFNN および RBFN 以外にも、RBFN と同等の予測精度が見込まれるリカレント型 NN⁽²⁰⁾ や ARIMA モデルを用いた風速予測にも適用可能であり、今後、それらを用いた場合の予測精度についても検討する予定である。

本研究の一部は、豊橋技術科学大学未来技術流動リサーチセンター若手教員プロジェクト、同外部資金プロジェクト、同未来ビークルリサーチセンター連携融合プロジェクト、同 VBL 研究プロジェクト、文部科学省グローバル GOE プログラム「インテリジェントセンシングのフロンティア」、日本学術振興会科学研究費補助金、および同拠点大学交流事業の支援を受けて行われた。

(平成 20 年 7 月 22 日受付, 平成 21 年 1 月 27 日再受付)

文 献

- (1) S. Oke, Y. Kemmoku, H. Takikawa, and T. Sakakibara: "Reduction of life cycle CO₂ emission in public welfare facilities equipped with PV/solar heat/cogeneration system", *IEEE Trans. PE*, Vol.123, No.11, pp.1365-1372 (2003-11) (in Japanese)
桶真一郎・見目喜重・滝川浩史・榊原建樹:「民生施設への太陽光・熱/コージェネシステム導入によるライフサイクル CO₂ 排出削減」, 電学論 B, **123**, 11, pp.1365-1372 (2003-11)
- (2) Y. Kemmoku, S. Edo, S. Nakagawa, T. Kawamoto, and T. Sakakibara: "Operation method of a solar-heat/electricity hybrid hot-water supply system using daily insulations forecasted in a few days later", *T. IEE Japan*, Vol.120-B, No.6, pp.831-837 (2000-6) (in Japanese)
見目喜重・江渡信一・中川重康・河本 映・榊原建樹:「数日先までの日射量を予測した太陽熱・電力ハイブリッド給湯システムの運用法」, 電学論 B, **120**, 6, pp.831-837 (2000-6)
- (3) 徳田憲昭:「苦前町でのバッテリー平準化実証試験報告」, 風力エネルギー, Vol.29, No.3, pp.4-12 (2005)
- (4) 矢後賢次:「風力発電システムと系統連系対策」, 風力エネルギー, Vol.29, No.3, pp.13-18 (2005)
- (5) 石原 孟:「風力発電出力予測技術の現状と課題」, 風力エネルギー, Vol.29, No.3, pp.19-25 (2005)
- (6) A.K. Mishra and V.R. Desai: "Drought forecasting using feed-forward recursive neural network", *Ecological Modeling*, Vol.198, pp.127-138 (2006)
- (7) A. More and M.C. Deo: "Forecasting wind with neural networks", *Marine Structures*, Vol.16, pp.35-49 (2003)
- (8) A. Sfetsos: "A novel approach for the forecasting of mean hourly wind speed time series", *Renewable Energy*, Vol.27, pp.163-174 (2002)
- (9) K. Taniguchi, K. Ichinaga, K. Yukita, and Y. Goto: "Study on forecast of time series of wind velocity for wind power generation by using wide meteorological data", *IEEE Trans. PE*, Vol.128, No.2, pp.416-422 (2008-2) (in Japanese)
谷口謙吾・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」, 電学論 B, **128**, 2, pp.416-422 (2008-2)
- (10) J.L. Torres, A. García, M. De Blas, and A. De Francisco: "Forecast of hourly average wind speed with ARMA models in Navarre (Spain)", *Solar Energy*, Vol.79, pp.65-77 (2005)
- (11) T.G. Barbounis and J.B. Theocharis: "A locally recurrent neural network with application to the wind speed prediction using spatial correlation", *Neurocomputing*, Vol.70, pp.1525-1542 (2007)
- (12) S. Oke, Y. Kemmoku, H. Takikawa, and T. Sakakibara: "Influence of atmospheric pressure on insolation forecast using artificial neural network", *Proc. ISES Asia-Pacific 2004*, pp.121-127 (2004)
- (13) S. Oke, Y. Itoh, Y. Kemmoku, H. Takikawa, and T. Sakakibara: "Introduction of atmospheric pressure to wind speed forecast with artificial neural network", *J. Jpn Solar Energy Soc.*, Vol.32, No.5, pp.39-44 (2006) (in Japanese)
桶真一郎・伊藤陽平・見目喜重・滝川浩史・榊原建樹:「ニューラルネットワークによる風速予測における気圧データの導入」, 太陽エネルギー, **32**, 5, pp.39-44 (2006)
- (14) S. Oke, H. Murata, H. Takikawa, and T. Sakakibara: "A forecasting-error reduction of daily total insolation by integration of forecasted daily solar irradiance curve", *J. Jpn Solar Energy Soc.*, Vol.33, No.2, pp.53-58 (2007) (in Japanese)
桶真一郎・村田浩之・滝川浩史・榊原建樹:「日射量曲線の予測に基づいた予測日積算日射量の誤差低減」, 太陽エネルギー, **33**, 2, pp.53-58 (2007)
- (15) S. Oke, H. Murata, S. Higashiyama, and H. Takikawa: "Representative modeling method in each climatic district for forecast of nationwide daily-solar-irradiance curve", *IEEE Trans. PE*, Vol.128, No.1, pp.151-156 (2008-1) (in Japanese)
桶真一郎・村田浩之・東山 伸・滝川浩史:「全国各地の日射量曲線予測のための気候区代表モデル法」, 電学論 B, **128**, 1, pp.151-156 (2008-1)
- (16) H.M. Fenga: "Self-generation RBFNs using evolutionary PSO learning", *Neurocomputing*, Vol.70, pp.241-251 (2006)
- (17) M.T. Vakil-Baghmisheh: "Training RBF networks with selective backpropagation", *Neurocomputing*, Vol.62, pp.39-64 (2004)
- (18) S.S. Khan and A. Ahmad: "Cluster center initialization algorithm for K-means clustering", *Pattern Recognition Lett.*, Vol.25, pp.1293-1302 (2004)
- (19) Y. Kemmoku, H. Ishii, H. Takikawa, T. Kawamoto, and T. Sakakibara: "Method of forecasting wind velocity of next day using weather data over wide area", *J. Jpn Solar Energy Soc.*, Vol.27, No.1, pp.85-91 (2001) (in Japanese)
見目喜重・石井弘樹・滝川浩史・河本 映・榊原建樹:「広域の気象データを利用した翌日の風速予測」, 太陽エネルギー, **27**, 1, pp.85-91 (2001)
- (20) T. Senju, A. Yona, N. Urasaki, T. Funabashi, and H. Sekine: "Application of recurrent neural network to short-time-ahead generating power forecasting for wind power generator", *Proc. of the 17th Annual Conference of Power & Energy Society, IEE Japan*, pp.401-406 (2006) (in Japanese)
千住智信・與那篤史・浦崎直光・舟橋俊久・関根秀臣:「リカレント型ニューラルネットワークを用いた風力発電機の短時間先出力予測」, 平成 18 年電気学会電力エネルギー部門大会, pp.401-406 (2006)

桶 真 一 郎 (正員) 2003 年 3 月豊橋技術科学大学大学院工学研究科修士課程修了。以後、豊橋技術科学大学電気・電子工学系助手を経て、現在、同助教。工博。日本太陽エネルギー学会、エネルギー資源学会、電気化学会会員。

東 山 伸 (学生員) 2008 年 3 月豊橋技術科学大学大学院工学研究科修士課程修了、現在に至る。

須 田 善 行 (正員) 1997 年 3 月北海道大学大学院工学研究科
修士課程修了。以後、パロマ工業(株)、北海道大
学大学院工学研究科助手、同大学院情報科学研究
科助手を経て、現在、豊橋技術科学大学電気・電子
工学系准教授。工博。ナノカーボンプロセスの研
究に従事。応用物理学会、フラーレンナノチュー
ブ学会会員。

滝 川 浩 史 (正員) 1986 年 3 月豊橋技術科学大学院電気・電
子工学専攻修士課程修了。以後、カナダ・シャーブ
ルック大学応用化学工学科研究員、釧路工業高等
校専門学校電気工学科助教授などを経て、現在、豊
橋技術科学大学電気・電子工学系教授。工博。プラ
ズマ応用学会、日本太陽エネルギー学会、IEEE
会員。