

数値気象予測とオンライン現地観測データを利用した最大瞬間風速予報

山口 敦¹・石原 孟²

¹正会員 東京大学特任准教授 大学院工学系研究科 社会基盤学専攻 (〒113-8656 東京都文京区本郷7-3-1)
E-mail: atsushi@bridge.t.u-tokyo.ac.jp

²正会員 東京大学教授 大学院工学系研究科 社会基盤学専攻 (同上)
E-mail: ishihara@bridge.t.u-tokyo.ac.jp

山岳地帯に建設された社会インフラ施設の維持管理および交通インフラの運用のために最大瞬間風速の高精度な予報が求められている。本研究では、ARX (Autoregressive Exogenous) モデルを用いて数値気象予測データとオンライン現地観測データに基づく最大瞬間風速予報モデルを定式化し、モデルパラメータの動的同定により、最大瞬間風速予報を行う手法を提案した。動的適合モデルを用いることにより、従来の風速比に基づく手法と比較して最大瞬間風速の予報精度が向上した。さらに風速15m/s以上の強風イベントの予報可能性をROC (Receiver Operating Characteristic) 曲線とAUC (Area Under the Curve) によって評価し、強風イベントの予報可能性が提案した手法により向上することを明らかにした。

Key Words : gust forecasting, nonparametric regression with multi time scale forgetting factor, on-line measurement, numerical weather prediction

1. はじめに

わが国の国土の4分の3は山岳地帯であり、そのような場所にも鉄道・道路・風力発電設備等の社会インフラ施設は建設されている。これらの社会インフラ施設の運用・維持管理は強風時に実施できないため、作業の実施可否を最大瞬間風速により判断することが不可欠である。そのため、最大瞬間風速がある基準値を超えるかどうかを前日の夕方および当日の朝に予報することが重要である。また、鉄道・道路等の交通インフラでは、強風時に鉄道の運行を停止する、あるいは道路を閉鎖するなどの対策が必要であるが、このような対策も最大瞬間風速に基づくため、24時間先までの最大瞬間風速の予報が重要である¹⁾。

島村・松沼²⁾は、鉄道の運行規制のためにカルマンフィルタを用いて、瞬間風速の過去の観測データから15分先までの瞬間風速を予報する手法を構築した。また、Hoppmann et al.³⁾は、ドイツでの鉄道運行規制のために、線形トレンドモデルを用いて過去の観測データから2分先までの信頼区間付きの瞬間風速を予報する手法を提案した。しかし、24時間先までの予報を行うためにはこれらの観測データに基づくモデルでは不十分であり、数値気象予測データ等の気象現象の変化を考慮した予報値を

用いる必要がある。

一方、風力発電の分野では6~24時間先の発電出力が電力系統の運用に大きな影響を与えるため、風力発電出力予報に関する研究が多く行われてきた⁴⁾。風力発電出力は風速に大きく依存するため、風力発電出力予報は数値気象予測データに基づき、より詳細な地形・粗度を考慮して局所的な風速を予報する物理モデルと過去の観測データに基づく統計モデルを組み合わせて用いられることが多い。Landberg⁵⁾は数値気象予測データに基づいてウインドファーム内の風速を予測するとともに、風速の観測値を用いて、モデル出力統計(Model Output Statistics - MOS)と呼ばれる統計的な手法を用いて風速の予報誤差を補正した。モデル出力統計では、風速の現地観測データを用いて予報値を風向別に1次関数により補正することにより予報の高精度化を図る。この手法は、現地観測データにより補正を行うため、予報値のバイアスを低くすることが可能であるが、風向別の補正関数は静的に定められるため、信頼性の高い補正関数を得るために十分長期の観測データが必要である。また、季節に応じて補正関数が変化するような状況には対応できない、補正関数が1次関数で表せない状況には適用できないという問題点がある。

一方、Joensen et al.⁶⁾はリアルタイムの発電出力の観測

値と数値気象予測モデルによる予報値を用いたARX(Autoregressive with Exogenous inputs)モデルを提案し, 忘却係数付きのノンパラメトリック回帰を利用して過去の発電出力の観測値と数値気象予測データから未知関数を推定することにより, 24時間先までの1時間平均の風力発電出力予測を行い, デンマークの風力発電所で検証した。このモデルは平均風速に対応する1時間平均発電出力を高精度に予測できているが, 最大瞬間風速を予報するモデルは提案されていない。また, 複雑地形を有する日本での適用可能性は明らかにされていない。現在日本で容易に入手可能なオンライン数値気象予測データとして, いくつかの異なる解像度のデータがあるが, 数値気象予測データが予報精度に与える影響についても明らかにされていない。

本研究では, ARXモデルを用いた最大瞬間風速の予報モデルを構築するとともに, このモデルを山岳地帯における最大瞬間風速予報に適用し, 従来のモデルと比較することにより, 各モデルの予報精度や強風イベント予報への適用可能性を明らかにする。また入力として用いる数値気象予測データの違いが予報精度に与える影響や風速15m/s以上の強風イベントの予報可能性をROC曲線とAUCを用いて定量的に評価する。さらに, 強風イベント結果に基づき, 予報モデルの最適パラメータを求める。

2. 予報モデル

本研究では, 数値気象予測データと現地観測データから, 24時間先までの最大瞬間風速を予報するシステムを構築した。本システムの概要を図-1に示す。本システムは, 平均風速予報モデル, 変動風速予報モデル, ピークファクタ推定モデルからなり, それぞれのモデルが数値気象予測データと現地観測データから, 平均風速, 変動風速およびピークファクタを推定し, 最大瞬間風速を予報する。また, 予報誤差を考慮し, 最大瞬間風速の上限値を推定する。本章では, まず本研究で入力データとして使用した数値気象予測データと現地観測データについて述べ, 次に平均風速予報モデル, 変動風速予報モデル, ピークファクタ推定モデル, 最大瞬間風速予報モデル, 最大瞬間風速上限値推定モデルの各モデルについて述べる。

(1) 入力データと予報スケジュール

a) 数値気象予測データ

気象庁からは解像度, 発表間隔, 予報時間の異なるいくつかの数値気象予測データが提供されているが, 本研究では, 全ての時間において24時間先までの予報値が利用可能である中で最も細かい解像度を持つGPV-MSMと,

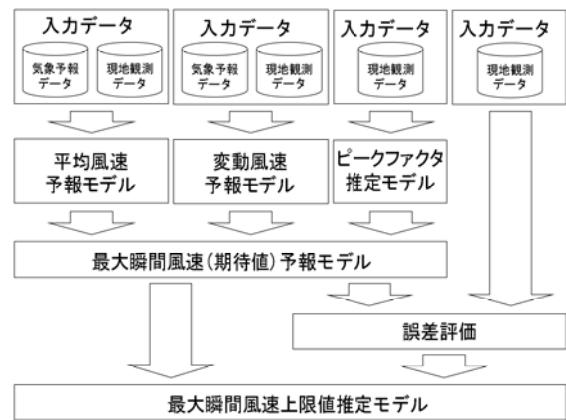


図-1 提案したモデルの概要

表-1 数値気象予測データのまとめ

モデル	GPV-MSM	GPV-GSM(日本域)
予報時間	39時間	84時間
配信時刻	初期値の約3時間後	初期値の約3時間後
時間解像度	1時間(地表面), 3時間(気圧面)	
初期時刻 (日本時間)	3時, 9時, 15時, 21時	3時, 9時, 15時, 21時
予報変数	海面更生気圧(地表面), 高度(気圧面), 水平風, 上昇流, 気温, 相対湿度, 積算降水量, 雲量,	
鉛直層数	60層	
地表面水平 格子間隔	南北0.05度×東西0.0625度	南北0.02度×東西0.025度
領域	北緯22.4度～47.6度, 東経120度～150度	北緯20度～50度, 東経120度～150度

次に細かい解像度を持つGPV-GSM(日本域)を用いた。GPV-MSMとGPV-GSM(日本域)の概要を表-1に示す。数値気象予測データは, 地表面および各気圧面での, 風速, 高度, 温度, 湿度等のパラメータで構成されているが, 本研究では地表面付近の風速の予報を対象とするため, 地表面の風速の東西成分および南北成分を用いた。

気象庁GPV-GSM(日本域)の地表面データの水平解像度は約20km, GPV-MSMの地表面データの水平解像度は約5kmであるが, 水平解像度が予報精度に与える影響を明らかにするため, 本研究では両者を用いた予報を行い, 両者の結果を定量的に評価した。なお, 気象庁GPV-MSMの予報回数は1日8回であるが, 本研究ではGPV-GSM(日本域)の予報回数に合わせて1日4回の予報値を用いた。

b) 現地観測データ

本研究では提案したモデルでは, 平均風速・平均風向, 風速の標準偏差および最大瞬間風速のリアルタイム観測値を入力とした。後述するように, 平均風速・風向予報モデルでは平均風速・平均風向を, 変動風速予報モデルでは風速の標準偏差を, ピークファクタ予報モデルでは平均風速・風速の標準偏差・最大瞬間風速を入力とした。

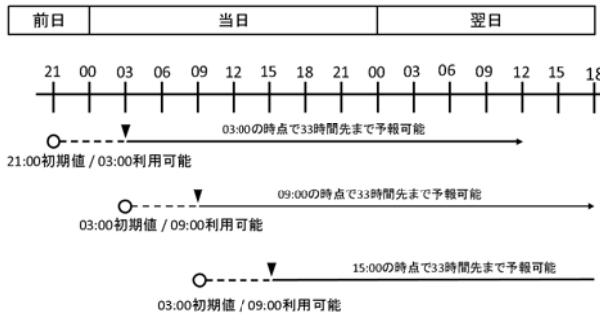


図-2 予報スケジュール

平均風速の評価時間は10分から1時間の間で設定することが可能であるが、本研究では30分に1回予報を発信することから評価時間も30分とした。また、予報も30分毎に実施し、30分毎の平均風速・変動風速に基づき、30分毎の最大瞬間風速を予報することとした。

c) 予報スケジュール

数値気象予測データとしてGPV-MSMを用いた場合の予報スケジュールを図-2に示す。予報データは初期時刻から約3時間後に気象業務支援センターからオンラインで配信されるが、最大で3時間程度遅延することがある。このため、初期時刻から6時間後に各予報データが利用可能になり、風速予報に用いることができる事とした。

例えば、強風イベントが発生するかどうかを当日午前6時に判断する場合、午前6時の時点で確実に利用可能な数値気象予測データは、前日21時を初期値とするデータである。このデータは初期値(前日21時)から39時間後の翌日12時までの予報値であり、翌日12時までの最大瞬間風速の予報が可能である。

(2) 予報モデル

a) 平均風速予報モデル

数値気象予測データは、空間的な解像度に限界があるため、高解像度の地形や地表面粗度の影響が考慮されていない。本研究では、高解像度の地形や地表面粗度の影響を受けた局所風速は、数値気象予測データの風速と風向の関数であると仮定し、時刻 t における \hat{k} ステップ(k 時間)後の局所風速の予報値 $|\bar{\mathbf{u}}_{t+k|t}^{\text{local}}|$ を同時刻の数値気象予測データの風速 $|\bar{\mathbf{u}}_{t+k|t}^{\text{nwp}}|$ と風向 $\theta_{t+k|t}^{\text{nwp}}$ の関数として式(1)に示すようにモデル化した。

$$|\bar{\mathbf{u}}_{t+k|t}^{\text{local}}| = f(|\bar{\mathbf{u}}_{t+k|t}^{\text{nwp}}|, \theta_{t+k|t}^{\text{nwp}}) \quad (1)$$

ただし、 $k = \hat{k}\Delta t$ とする。ここで、 $|\bar{\mathbf{u}}_{t+k|t}^{\text{nwp}}|$ 、 $\theta_{t+k|t}^{\text{nwp}}$ はそれぞれ数値気象予測データの風速の絶対値と風向であり、同時刻の風速・風向の東西成分 $u_{t+k|t}^{\text{nwp}}$ と南北成分 $v_{t+k|t}^{\text{nwp}}$ を用い式(2)のように求められる。

$$|\bar{\mathbf{u}}_{t+k|t}^{\text{nwp}}| = \sqrt{(v_{t+k|t}^{\text{nwp}})^2 + (u_{t+k|t}^{\text{nwp}})^2} \quad (2a)$$

$$\theta_{t+k|t}^{\text{nwp}} = \text{atan}2(v_{t+k|t}^{\text{nwp}}, u_{t+k|t}^{\text{nwp}}) \quad (2b)$$

また、 $f(|\bar{\mathbf{u}}_{t+k|t}^{\text{nwp}}|, \theta_{t+k|t}^{\text{nwp}})$ は局所的な地形や地表面粗度の影響を考慮するための風速比で、後述する忘却係数付きノンパラメトリック回帰により推定する。忘却係数は通常の値0.999とした。

このようにして求めた局所風速は局所的な地形や地表面粗度の影響が考慮されているため、誤差のバイアス成分をほとんど含まないと考えられるが、数値気象予報データに元来含まれる位相誤差成分は含まれている。本研究では、主に短時間の予報についてこの誤差を低減させることを目的として、時刻 t における最新の現地観測データ $|\bar{\mathbf{u}}_t^{\text{meas}}|$ と同じ値の風速がその後も継続するというモデル(持続モデル)を用いて、式(3)のように補正し、平均風速の予報値 $|\bar{\mathbf{u}}_{t+k|t}^{\text{pred}}|$ を求めた。

$$|\bar{\mathbf{u}}_{t+k|t}^{\text{pred}}| = a(k, \theta_{t+k|t}^{\text{nwp}}) |\bar{\mathbf{u}}_t^{\text{meas}}| + b(k, \theta_{t+k|t}^{\text{nwp}}) |\bar{\mathbf{u}}_{t+k|t}^{\text{local}}| \quad (3)$$

ここで、 a および b はなめらかな関数であり、後述する忘却係数付きノンパラメトリック回帰により推定する。忘却係数は通常の値0.999とした。これらの関数は予報時間 k の関数であり、予報時間によって、用いるべき最新の観測値と予報値の重みを決定づけている。

b) 変動風速予報モデル

変動風速の予報値 $\sigma_{t+k|t}^{\text{local}}$ も平均風速と風向の関数であると仮定し、本研究では平均風速と同様な形で式(4)に従いモデル化した。

$$\sigma_{t+k|t}^{\text{local}} = f_\sigma(|\bar{\mathbf{u}}_{t+k|t}^{\text{nwp}}|, \theta_{t+k|t}^{\text{nwp}}) \quad (4)$$

平均風速と同様に、位相誤差を補正するために最新の変動風速の観測値 σ_t^{meas} を用いて、変動風速の予報値 $\sigma_{t+k|t}^{\text{pred}}$ を式(5)のようにモデル化した。

$$\sigma_{t+k|t}^{\text{pred}} = a_\sigma(k, \theta_{t+k|t}^{\text{nwp}}) \sigma_t^{\text{meas}} + b_\sigma(k, \theta_{t+k|t}^{\text{nwp}}) \sigma_{t+k|t}^{\text{local}} \quad (5)$$

ここで、 a_σ および b_σ はなめらかな関数で、後述する忘却係数付きノンパラメトリック回帰により推定する。

c) 最大瞬間風速予報モデル

以上求めた平均風速 $|\bar{\mathbf{u}}_{t+k|t}^{\text{pred}}|$ 、変動風速 $\sigma_{t+k|t}^{\text{pred}}$ に基づき、最大瞬間風速の時刻 t における k 時間先予報値 $u_{t+k|t}^{\text{max,pred}}$ は式(6)により求める。

$$u_{t+k|t}^{\text{max,pred}} = |\bar{\mathbf{u}}_{t+k|t}^{\text{pred}}| + p_t \sigma_{t+k|t}^{\text{pred}} \quad (6)$$

ここで、 p_t はピークファクタであり、風速、風向、予報時間には依存せず、予報初期時刻のみに依存する値と仮定し、式(7)に示す誤差 ϵ が最小となるように、忘却係数付き回帰により定数として推定した。ピークファクタは

気象条件によって大きく変動するため、忘却係数は比較的短い時間スケールに対応するため、式(14)に示す有効データ数が11個、すなわち、5.5時間となるように0.917を用いた。

$$\epsilon = p_t - \frac{u_t^{\max, \text{meas}} - |\bar{u}_t^{\text{meas}}|}{\sigma_t^{\text{meas}}} \quad (7)$$

ここで、 $u_t^{\max, \text{meas}}$ は観測された30分最大風速である。

d) 最大瞬間風速上限値推定モデル

上記のモデルにより予報した最大瞬間風速は、予測値と観測値との平均的な関係から求めたものであるため、最大瞬間風速の期待値を予報するものである。実際の強風イベント時には、この値を上回る最大瞬間風速が発生する可能性がある。そこで、最大瞬間風速予報の平均二乗誤差を式(8)に示すように最大瞬間風速と予報時間の関数としてモデル化し、式(9)に示すように最大瞬間風速に予報誤差の一定の割合を加えることにより、最大瞬間風速の上限値を推定し、予報値とした。

$$\epsilon_t(k) = \sqrt{(u_t^{\max, \text{meas}} - u_{t+k|t}^{\max, \text{pred}})^2} \quad (8)$$

$$u_{t+k|t}^{\max, \text{upper}} = u_{t+k|t}^{\max, \text{pred}} + \gamma \epsilon_t(k) \quad (9)$$

ここで、 γ はモデルパラメータであり、この値については3.(3)で詳細に議論する。

(3) 忘却係数付きノンパラメトリック回帰

前節で述べた各予報モデルのパラメータあるいは関数を推定するために、本研究では忘却係数付きノンパラメトリック回帰を用いた。この手法では式(10)の形で定式化できるモデルを対象とする。

$$y_s = \mathbf{z}_s \Phi^T(\mathbf{q}_s) + \epsilon_s \quad (10)$$

ここで、 y_s は目的変数、 $\mathbf{z}_s = (z_{s(1)} \ z_{s(2)} \ \dots \ z_{s(M)})^T$ および $\mathbf{q}_s = (q_{s(1)} \ q_{s(2)} \ \dots \ q_{s(N)})$ は説明変数、 $\Phi^T(\mathbf{q}_s) = (\phi_{(1)}(\mathbf{q}) \ \phi_{(2)}(\mathbf{q}) \ \dots \ \phi_{(M)}(\mathbf{q}))$ は本手法で推定する \mathbf{q}_s の滑らかな関数、 ϵ_s は白色雑音であり、添え字 s は時系列データのインデックスを示す。本研究で提案した局所風速変換モデル、平均風速補正モデルおよび局所変動風速変換モデル、変動風速補正モデルは式(11)、式(12)の形で表す。例えば、風速変換モデルの場合、 $M = 1, N = 2$ であり、式(11)は以下のようになる。

$$\begin{cases} \phi_{(1)}(\mathbf{q}) = f(q_{(1)}, q_{(2)}) \\ \begin{cases} q_{(1)} = u_{t+k|t} \\ q_{(2)} = \theta_{t+k|t} \end{cases} \\ z_{(1)} = 1 \end{cases} \quad (11)$$

また、風速補正モデルの場合、 $M = 2, N = 2$ であり、式(12)は次式のようになる。

$$\begin{cases} \phi_{(1)}(\mathbf{q}) = a(q_{(1)}, q_{(2)}) \\ \phi_{(2)}(\mathbf{q}) = b(q_{(1)}, q_{(2)}) \\ \begin{cases} q_{(1)} = k \\ q_{(2)} = \theta_{t+k|t} \end{cases} \\ \begin{cases} z_{(1)} = u_{t+k|t}^{\text{local}} \\ z_{(2)} = u_{t+k|t}^{\text{meas}} \end{cases} \end{cases} \quad (12)$$

ノンパラメトリック回帰においては過去に得られた目的変数と説明変数の組(学習データ)を用いて、関数 $\Phi(\mathbf{q})$ を、 \mathbf{q} を格子上の点 $\mathbf{q}_p = (q_{p(1)} \ q_{p(2)} \ \dots \ q_{p(N)})^T$ の近傍で局所的に推定する。過去の時刻 s に得られた学習データを $y_s, z_s, \mathbf{q}_s = (q_{s(1)} \ q_{s(2)} \ \dots \ q_{s(N)})^T$ とすると、時刻 t における \mathbf{q}_p 近傍での関数 $\hat{\Phi}_{p,t}(\mathbf{q})$ は式(13)に示す重み付き誤差 ϵ を最小化することにより求める。

$$\epsilon = \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) (y_s - \mathbf{z}_s^T \hat{\Phi}_{p,t}(\mathbf{q}))^2 \quad (13)$$

ここで、 $\lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p)$ は誤差を評価する際の重みであり、2つの部分に分けられる。

λ は $0 < \lambda \leq 1$ の範囲の値を取る忘却係数と呼ばれるモデルパラメータである。 t は現在の時刻であり、 s は観測データの得られた過去の時刻であるため、 λ^{t-s} は古い観測データに対して小さな値となり、最近のデータでは大きな値となる。この忘却係数を用いることにより、過去の観測データを忘却し、新しい観測データの重みを重視した動的適合モデルが実現される。また λ の値が大きいほど長期間のデータを用いた学習となり、 λ の値が小さいほど直近のデータのみを用いた学習となる。異なる λ を用いた場合に学習に用いた過去のデータ数を表すための指標として有効データ数 N_{eff} があり⁵⁾、式(14)で計算できる。

$$N_{eff} = \frac{\lambda}{1-\lambda} \quad (14)$$

例えば、 $\lambda = 1$ とすると使用するデータ数は無限大となり、過去全てのデータを用いる場合と等価となる。風力発電の分野では忘却係数として、0.999が使われている⁵⁾。

$w(\mathbf{q}_s, \mathbf{q}_p)$ は時刻 s における学習データ \mathbf{q}_s と近傍で関数を推定する点 \mathbf{q}_p との距離が小さいほど大きな値をとり、距離が大きいほど小さな値をとる重み関数である。この重み関数により、関数の推定点の近傍にある学習データの重みを大きくするとともに、推定点から遠い学習データは重視しないことが実現される。多次元の重み関数 $w(\mathbf{q}_s, \mathbf{q}_p)$ は一次元の重み関数 $W(x)$ の積として、式(15)のように表される。

$$w(\mathbf{q}_s, \mathbf{q}_p) = \prod_{j=1}^N W\left(\frac{|q_{s(j)} - q_{p(j)}|}{h_j}\right) \quad (15)$$

ここで, \hbar_j はバンド幅と呼ばれる量であり, 推定した関数の滑らかさを決定するパラメータである. 一次元の重み関数 $W(x)$ としては式(16)で表される関数が用いるのが一般的である. この重み関数が $0 \leq x \leq 1$ の範囲で 0 より大きくなっていることによって離散的な一点 \mathbf{q}_p の近傍での局所的な推定が可能になる.

$$W(x) = \begin{cases} (1-x^3)^3 & 0 \leq x < 1 \\ 0 & 1 \leq x \end{cases} \quad (16)$$

式(13)に示す誤差を最小化するような \mathbf{z}_s および α は, 漸化式を用いて求めた. その詳細は付録Aに示す.

3. 予報結果と誤差評価

本章では, まず本研究で予報対象とした強風イベントおよび解析条件について説明する. 次に, 本研究で実施した予報の例と比較対象モデルを紹介するとともに, 入力として用いる数値気象予測データの違いが予報精度に与える影響を明らかにする. 最後に, 風速15m/s以上の強風イベントの予報可能性をROC曲線とAUCを用いて定量的に評価する.

(1) 解析条件

本研究では, 東日本の日本海側山岳地帯を対象とし, 地上高10mにおける風速計による現地観測データが得られた2014年1月6日から2014年3月31日まで, 2014年12月6日から2015年3月31日, 2015年12月6日から2016年3月31日の約11ヶ月間を解析対象期間とし, 表-2に示すような, 解析期間中に最大風速15m/sを超えた36イベントを最大瞬間風速予報の対象とした. なお, 表-2に示す日時は最大瞬間風速を記録した30分の最後の時間である. また, 図-3に本研究で対象とした地域の等高線と地表面粗度分布を示す. 図-3の中心が風速計設置位置である. 局所平均風速および局所変動風速の補正の際に必要な観測データは予報時に得られる最新のデータを用い, 30分間隔で予報を行った. なお, 予報評価に先立つ2013年12月の観測データを用いて予報モデルの初期値を作成した.

本研究では, 各モデルにおけるノンパラメトリック回帰の局所近似曲線に対して表-3に示すような条件で解析を行った. 忘却係数 α は通常のモデルでは0.999とした. これは長さスケールにして約20日であり, 過去20日分のデータに基づき予報モデルの学習を行うことに相当する. 一方, ピークファクタの推定に対しては0.917とし, 過去約5.5時間のデータに基づき学習を行うことに相当する. ノンパラメトリック回帰を行う際, 局所風速変換関数および風速補正関数の初期値を設定する必要がある. 本研究ではあらかじめ, 解析期間に先立つ2013年12月1日から12月31日において予報を実施し, 学習することにより

各モデルの初期値とした.

(2) 予報の例と比較対象モデル

本研究で提案した手法では, 多くの関数をノンパラメトリック回帰により学習した. 本節では学習した関数の一例を示し, その意味を考察する. 図-4には平均風速予報モデルで同定した関数 $f(\mathbf{u}_{t+k|t}^{\text{nwp}}, \theta_{t+k|t}^{\text{nwp}})$ を $\theta_{t+k|t}^{\text{nwp}} = 0^\circ$ と $\theta_{t+k|t}^{\text{nwp}} = 180^\circ$ の場合について示す. 風向によって局所的な風速は数値気象予測値に比例して増大または減少していないことがわかる.

平均風速予報モデルでは観測値の影響を考慮する関数 $a(k, \theta_{t+k|t}^{\text{nwp}})$ と $b(k, \theta_{t+k|t}^{\text{nwp}})$ も同定した. 図-5には同定したこれらの関数を $\theta_{t+k|t}^{\text{nwp}} = 180^\circ$ の場合について示す. 予報時間 k が短い時には直近の観測データの重みが大き

表-2 対象とした強風イベントの一覧

日時	最大瞬間風速(m/s)
2014/01/30 16:00	15.3
2014/01/31 13:00	15.6
2014/02/05 10:30	15.1
2014/02/16 12:00	21.2
2014/03/06 10:30	15.3
2014/03/10 12:30	16.2
2014/03/20 06:30	15.7
2014/03/21 06:30	16.2
2014/03/30 10:00	18.8
2014/03/31 06:00	19.4
2014/12/16 06:30	17.8
2014/12/18 15:30	17.6
2014/12/20 07:00	16.3
2015/01/06 15:30	17.8
2015/01/07 07:00	16.2
2015/01/17 13:00	15.1
2015/01/22 10:30	15.8
2015/01/23 11:30	15.1
2015/01/31 07:30	15.5
2015/02/01 10:00	15.0
2015/02/13 15:00	15.9
2015/02/15 14:30	16.0
2015/02/26 07:30	15.7
2015/02/27 12:30	15.7
2015/03/01 06:00	15.2
2015/03/02 07:00	20.1
2015/03/03 16:30	15.5
2015/03/09 06:00	15.4
2015/03/10 17:00	15.5
2015/12/11 14:30	17.4
2016/01/04 18:00	15.9
2016/01/18 06:00	21.8
2016/01/20 07:30	17.9
2016/02/09 16:00	17.1
2016/02/10 06:00	16.7
2016/03/01 06:00	16.8

く、予報時間 k が長くなるにつれ、数値気象予測に基づく予報値の重みが大きくなることがわかる。

従来から局所地形が風況に与える影響を評価するため

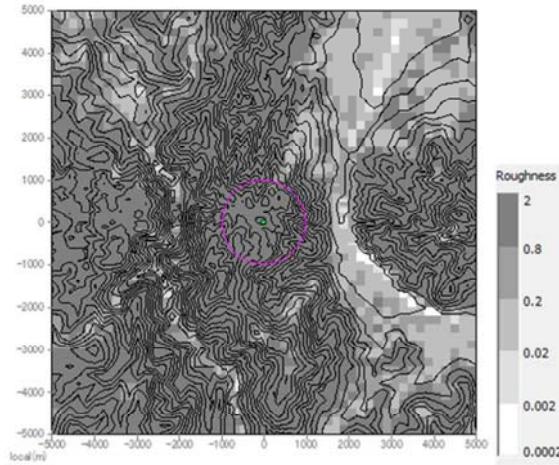


図-3 対象地点付近の標高センターと地表面粗度

表-3 モデルパラメータのまとめ

パラメータ	値	
忘却係数	0.917(ピークファクタ推定) 0.999(それ以外)	
パン ド幅	風速	4.0 [m/s]
	風向	11.25 [deg]
	予報時間	0.5 [hour]

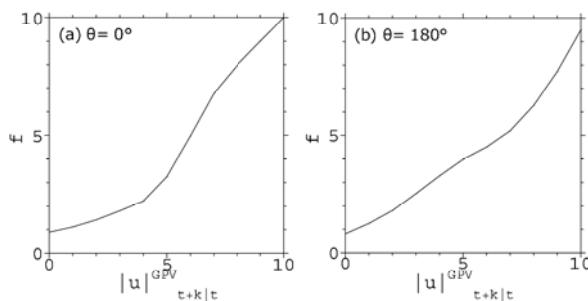


図-4 平均風速予報モデル内における $f(|\bar{u}_{t+k|t}^{\text{nwp}}|, \theta_{t+k|t}^{\text{nwp}})$ の学習結果: (a) $\theta_{t+k|t}^{\text{nwp}} = 0^\circ$; (b) $\theta_{t+k|t}^{\text{nwp}} = 180^\circ$

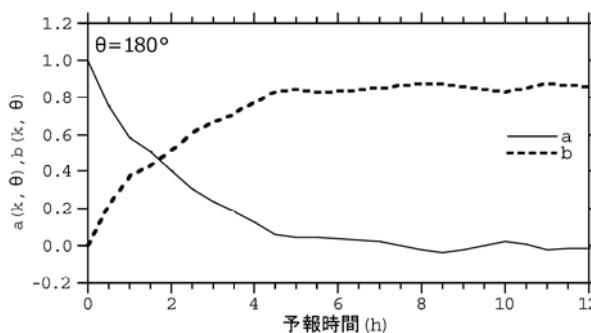


図-5 $\theta = 180^\circ$ (南風時)における風速予報モデルのパラメータ $a(k, \theta)$ と $b(k, \theta)$ の学習結果

に、風向別の風速比を用いる考え方が広く利用されてきた²⁾。また、風力発電出力予報モデル MOSにおいても予報風速に風向別の定数を乗じることが行われている。この考え方に基づき、気象庁発表の数値気象予測データに風向別の係数を乗じることにより予報が可能である。本研究ではこの考え方に基づく最大瞬間風速予報モデルを式(17)～式(19)のように構築し、比較対象予報モデルとした。平均風速 $|\bar{u}_{t+k|t}^{\text{MOS}}$ は次式により表す。

$$|\bar{u}_{t+k|t}^{\text{MOS}}| = C(\theta_{t+k|t}^{\text{nwp}}) |\bar{u}_{t+k|t}^{\text{nwp}}| \quad (17)$$

ここで、 $C(\theta_{t+k|t}^{\text{nwp}})$ は風向の関数であり、風向別に過去の観測データより同定する。また、変動風速 $\sigma_{t+k|t}^{\text{MOS}}$ を表す式(18)にある $S(\theta_{t+k|t}^{\text{nwp}})$ も風向の関数であり、過去の観測データより同定する。

$$\sigma_{t+k|t}^{\text{MOS}} = S(\theta_{t+k|t}^{\text{nwp}}) |\bar{u}_{t+k|t}^{\text{nwp}}| \quad (18)$$

またピークファクター p^{MOS} は定数であり、Ishizaki⁷⁾の論文に基づいて決定した。以上より MOS モデルによる最大瞬間風速 $u_{t+k|t}^{\max, \text{MOS}}$ は次式により計算できる。

$$u_{t+k|t}^{\max, \text{MOS}} = |\bar{u}_{t+k|t}^{\text{MOS}}| + p^{\text{MOS}} \sigma_{t+k|t}^{\text{MOS}} \quad (19)$$

図-6 に代表的な強風イベントが発生した日の朝 6 時における一日の最大瞬間風速の予報値と観測値の比較を示す。本研究で提案した動的適合モデルを用いると、従来の静的な MOS モデルに比べて予報精度が改善していることがわかる。特に朝 6 時の時点での数値予報に基づく予報値と観測値に大きな差がある 2014 年 1 月 31 日のケースでは、予報開始直後に MOS モデルと動的適合モデルの間に大きな差異があることがわかる。また、動的適合モデルを用いる場合でも、入力値として気象庁 MSM データを利用した場合の方が予報精度がよくなっていることがわかる。

(3) 予報結果の評価

本研究では、予報精度を最大瞬間風速の予報時間別平均二乗誤差と強風イベントの ROC 曲線により評価した。最大瞬間風速の平均二乗誤差は、11 ヶ月の全予報期間を通じての予報精度を評価し、式(20)を用いた。通常、短い予報時間に対する精度が高いため、予報時間 k の関数として評価する。

$$\epsilon_t(k) = \sqrt{\sum_t (u_{t|t-k}^{\max, \text{pred}} - u_t^{\max, \text{meas}})^2} \quad (20)$$

図-7 に従来の MOS モデルを用いた予報と本研究で提案した手法による予報の予報誤差を予報時間別に示す。MOS モデルでは予報時間によらず、ほぼ一定であるのに対して、本研究で提案した手法では観測データを用いるため、6 時間以内の予報誤差が大幅に減少している。

また、入力として用いる数値気象予測データとして、GPV-MSM予報値を用いる方が、GPV-GSM(日本域)予報値を用いる場合より、全ての予報時間において予報誤差が改善されていることがわかる。これはGPV-MSMモデルの水平解像度が高く、山岳地帯の地形の影響を予測に反映されていることによるものである。

表-2に示すような強風イベントを予報できるかどうかについては、2.(2)で説明した最大瞬間風速上限値推定モデルが重要となる。最大瞬間風速予報モデルは最大瞬間風速の平均値を予報するため、実際に強風イベントが発生するかどうかを予報するためには、最大瞬間風速の上限を推定する必要がある。最大瞬間風速上限推定モデルのパラメータ γ を大きくすると最大瞬間風速の上限が大きく予報されるため、予報される強風イベントの数が多くなる。一方、パラメータ γ を小さくすると最大瞬間風速の上限値が小さく予報されるため、予報される強風イベントの数が少なくなる。

このようなモデルパラメータを含む予報を評価するためにROC(Receiver Operating Characteristic)曲線^{8,9)}を用いるのが一般的である。ROC曲線は横軸に偽陽性率、縦軸に真陽性率(感度とも呼ばれる)をとり、モデルパラメータを変化させた際の偽陽性率と真陽性率の変化を見ることができる。真陽性 a 、偽陰性 b 、偽陽性 c 、真陰性 d の定義を表-4に示す。偽陽性率は実際に強風イベントが起らなかったケース($b+d$)のうち、強風イベントが予報されたケース b の割合 $b/(b+d)$ を表すものである。一方、真陽性率は強風イベントが発生したケース($a+c$)のうちで強風イベントが予報されたケース a の割合 $a/(a+c)$ で表せる。完全な予報モデルでは真陽性率が1であり、偽陽性率が0であることから、ROC曲線の左上の点を通る。また、強風が発生するかどうかをランダムに予報するモデルでは偽陽性率と真陽性率が常に等しくなることが期待されることから、ROC曲線は左下の点と右上の点を結ぶ直線となる。実際の予報モデルの結果はこの中間にあるため、ROC曲線において左下と右上を結ぶ直線と左上の点の間に位置し、よい予報モデルであれば、左上の点に近づく。ROC曲線の下の面積(Area under the curve - AUC)を用いて、予報モデルを定量的に評価することができ、AUCが大きいほど、良いモデルであると言える¹⁰⁾。

図-8にはMOSモデルを利用した場合のROC曲線、本研究で提案したモデルのうち、数値気象予測データとしてGPV-MSMを利用した場合とGPV-GSM(日本域)を利用した場合のROC曲線を示す。どのモデルを用いた場合でも、モデルパラメータを変化させることにより、真陽性を大きくすることができるが、偽陽性も同時に大きくなる。本研究で提案したモデルのうち、数値気象予測データとしてGPV-MSMを利用した場合にROC曲線は最も左上の

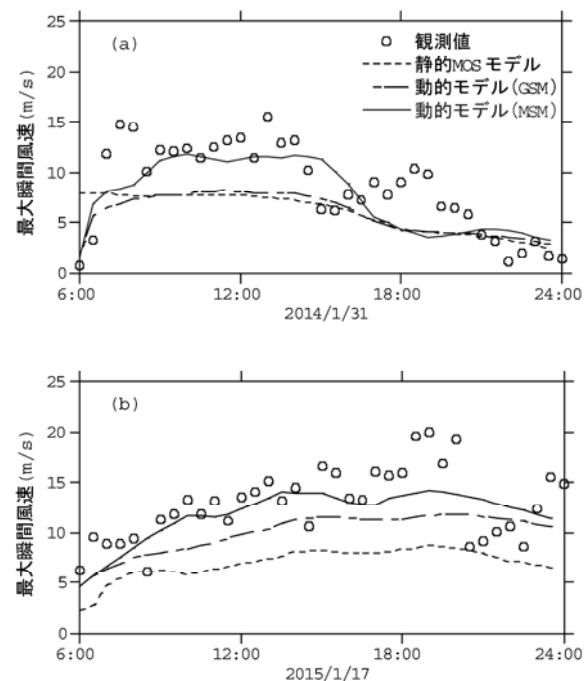


図-6 最大瞬間風速の観測値と予報値($\gamma=0$)

(a)2014年1月31日の結果

(b)2015年1月17日の結果

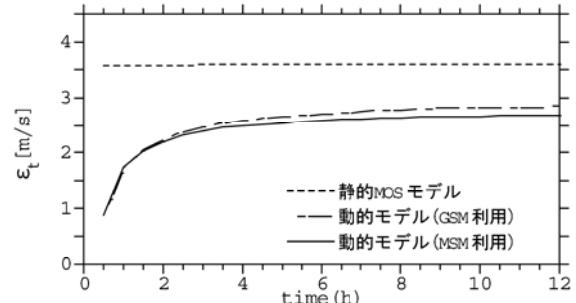


図-7 従来のMOSモデルと提案モデルにより予報した最大瞬間風速のRMSE($\gamma=0$)

点に近くなり、偽陽性を低く抑えつつ真陽性を高くしていることができるようになることがわかる。また、表-5からは、AUCがMOSモデルを利用した場合の0.842から動的モデル(GPV-MSM)を利用した場合の0.941に向上した。

なお、強風イベントの発生は朝6時から夜18時の間に最大瞬間風速15m/s以上を記録した場合として定義し、朝6時の時点で朝6時から夜18時までの間に強風イベントの発生が予報されていた場合に強風イベントが予報されているとした。

(4) 最大瞬間風速上限値推定モデルの最適化

最大瞬間風速上限値推定モデルにおける γ の値を最適化するためには何らかの評価関数が必要である¹¹⁾。予報が外れる場合、すなわち偽陽性が発生する場合、あるいは偽陰性が発生する場合に損失が発生するが、その値はそれぞれ異なる。偽陰性が発生した際の損失を l 、偽陽

性が発生した際の損失を αl とすると、予報期間を通じての損失 l_{total} は

$$l_{\text{total}} = cl + bal \quad (21)$$

となる。

本研究では、 α の値を0.5にした場合と1にした場合について無次元化損失(l_{total}/l)を γ の関数としてプロットしたものを図-9に示す。 $\alpha = 1$ の場合には $\gamma = 0.9$ 付近に、 $\alpha = 0.5$ の場合には $\gamma = 0.7$ 付近に最適値があることがわかる。また、このグラフは左右非対称となっているが、これは実際に強風イベントが発生した数には限りがあり、偽陰性が発生する数には上限があるのに対し、偽陽性が発生する数には上限がないと考えてよいためである。

4.まとめ

本研究では、数値気象予測データと現地観測データに基づく最大瞬間風速予報モデルを構築し、山岳地帯における実観測データを用いて検証を行い、以下の結論を得た。

- (1) ARX モデルを用いて最大瞬間風速予報モデルを構築した。また、ARX モデルのモデルパラメータの同定には、マルチタイムスケール忘却係数付きノンパラメトリック回帰を提案した。従来の MOS モデルと比較して、本手法による最大瞬間風速の予報精度が向上した。
- (2) 数値気象予測データとして高解像度モデルの結果を用いた場合、低解像度モデルの結果と比較した場合、最大瞬間風速予報の精度は向上した。
- (3) 最大瞬間風速 15m/s 以上の強風イベントの発生の予報可能性を、ROC 曲線を用いて評価した。提案した手法を用いた場合には偽陽性を低く抑えつつ真陽性を高くすることが可能であり、AUC は従来の MOS モデルの 0.842 から 0.941 に増大した。

謝辞：本研究は、東日本旅客鉄道株式会社との共同研究の一環として実施された。同社の三須弥生博士、南雲洋介氏にはオンラインデータの提供に際し、ご協力を頂いた。ここに記して関係者の皆様に感謝の意を表す。

付録A 忘却係数付きノンパラメトリック回帰

式(13)の誤差を最小化するように時刻 t における観測値 \mathbf{q}_p の近傍で局所的に推定する関数 $\hat{\Phi}_{p,t}(\mathbf{q})$ は本研究では 2 次式で近似した。ベクトル \mathbf{q} が 1 次元($N = 1$)の時、局所推定近似関数 $\hat{\Phi}_{p,t}(\mathbf{q})$ は次式で表すことができる。

表4 イベント発生表

		観測	
		あり	なし
予報	あり	真陽性 a	偽陽性 b
	なし	偽陰性 c	真陰性 d

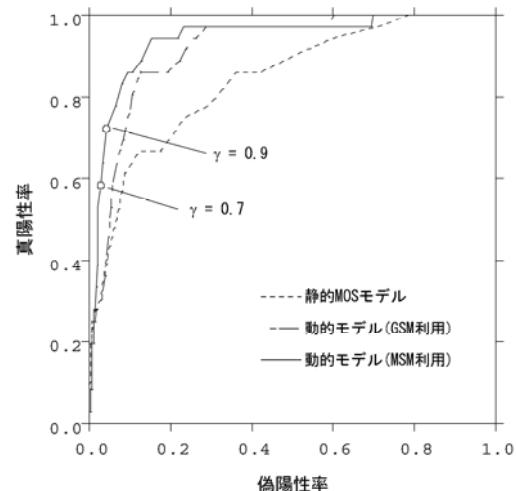


図-8 提案したモデルと従来モデルの ROC 曲線

表5 提案したモデルと従来のモデルの AUC

モデル	AUC
静的MOSモデル	0.842
動的モデル(GPV-GSM)	0.919
動的モデル(GPV-MSM)	0.941

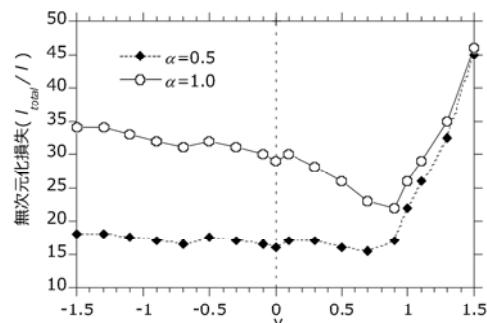


図-9 γ の違いによる無次元化損失の違い

$$\hat{\Phi}_{p,t}(\mathbf{q}) = \begin{pmatrix} \hat{\phi}_{p,t,1}^{(0)} + \hat{\phi}_{p,t,1}^{(1)}q + \hat{\phi}_{p,t,1}^{(2)}q^2 \\ \hat{\phi}_{p,t,2}^{(0)} + \hat{\phi}_{p,t,2}^{(1)}q + \hat{\phi}_{p,t,2}^{(2)}q^2 \\ \vdots \\ \hat{\phi}_{p,t,M}^{(0)} + \hat{\phi}_{p,t,M}^{(1)}q + \hat{\phi}_{p,t,M}^{(2)}q^2 \end{pmatrix} \quad (A.1)$$

関数 $\hat{\Phi}_{p,t}(\mathbf{q})$ を推定するということは、式(A.1)の係数 $\hat{\phi}_{p,t,m}^{(l)}$ ($0 \leq l \leq 2$, $0 \leq m \leq M$)を推定することに他ならない。式(A.1)を式(13)に代入すると、 \mathbf{q} が 2 次元の時は表-A.1 に示すように、最小化すべき誤差 ϵ は式(A.2)のよ

うになる。

$$\epsilon = \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) (y_s - \tilde{\mathbf{z}}_s^T \tilde{\Phi}_{p,t})^2 \quad (\text{A.2})$$

式(A.2)に示す ϵ を最小する解は最小二乗法により式(A.3)により求めることができる。

$$\tilde{\Phi}_{p,t} = (\mathbf{Z}_t^T \Lambda_t \mathbf{W}_{t,i} \mathbf{Z}_t)^{-1} \mathbf{Z}_t^T \Lambda_t \mathbf{W}_{t,i} \mathbf{y}_t \quad (\text{A.3})$$

ここで、行列 \mathbf{Z}_t , Λ_t , $\mathbf{W}_{t,i}$ とベクトル \mathbf{y}_t は下式により与えられる。

$$\mathbf{Z}_t = (\tilde{\mathbf{z}}_1 \quad \dots \quad \tilde{\mathbf{z}}_t) \quad (\text{A.4})$$

$$\Lambda_t = \begin{pmatrix} \lambda^{t-1} & & 0 \\ 0 & \ddots & \\ & & \lambda^{t-t} \end{pmatrix} \quad (\text{A.5})$$

$$\mathbf{W}_{t,i} = \begin{pmatrix} w(\mathbf{q}_1, \mathbf{q}_p) & & 0 \\ & \ddots & \\ 0 & & w(\mathbf{q}_t, \mathbf{q}_p) \end{pmatrix} \quad (\text{A.6})$$

$$\mathbf{y}_t = (y_1 \quad \dots \quad y_t)^T \quad (\text{A.7})$$

式(A.2)をそのまま解くことによっても、関数を推定することは可能であるが、この方法では計算上過去の学習データを全て記憶しておく必要があるため、時系列デー

タを扱う際には計算コストがかかり非効率的である。そこで、式(A.2)を漸化式によって表し、一つ前の時間における関数の推定結果を記憶するだけで、最新の推定結果を求める手法が提案されている。 $\mathbf{R}_{t,i}$ を次式で定義する。

$$\mathbf{R}_{t,i} = \mathbf{Z}_t^T \Lambda_t \mathbf{W}_{t,i} \mathbf{Z}_t \quad (\text{A.8})$$

また時刻 t における $\tilde{\Phi}_{p,t}$ は式(A.9)および式(A.10)のような漸化式で記述される。

$$\begin{aligned} \tilde{\Phi}_{p,t} = \\ \tilde{\Phi}_{p,t-1} + w(\mathbf{q}_s, \mathbf{q}_p) \mathbf{R}_{t,i}^{-1} \mathbf{z}_t (y_t - \mathbf{z}_t^T \tilde{\Phi}_{p,t-1}) \end{aligned} \quad (\text{A.9})$$

$$\mathbf{R}_{t,i} = \lambda w(\mathbf{q}_s, \mathbf{q}_p) \mathbf{R}_{t-1,i} + w(\mathbf{q}_s, \mathbf{q}_p) \mathbf{Z}_t \mathbf{Z}_t^T \quad (\text{A.10})$$

$\mathbf{R}_{t,i}$ の初期値 $\mathbf{R}_{0,i}$ としては、式(A.11)に示す形を用いた。

$$\mathbf{R}_{0,i} = \begin{pmatrix} R_0 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & R_0 \end{pmatrix} \quad (\text{A.11})$$

本研究では、 R_0 の値として、10を用いた。

参考文献

- 1) 三須弥生, 石原孟: 風観測と数值流体解析を利用し

表-A.1 2次式によるノンパラメトリック回帰

$$\begin{aligned} \epsilon &= \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) (y_s - \mathbf{z}_s^T \hat{\Phi}_{p,t}(\mathbf{q}))^2 \\ &= \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) \left[y_s - \mathbf{z}_s^T \begin{pmatrix} \hat{\phi}_{p,t,1}^{(0)} + \hat{\phi}_{p,t,1}^{(1)} q + \hat{\phi}_{p,t,1}^{(2)} q^2 \\ \hat{\phi}_{p,t,2}^{(0)} + \hat{\phi}_{p,t,2}^{(1)} q + \hat{\phi}_{p,t,2}^{(2)} q^2 \\ \vdots \\ \hat{\phi}_{p,t,M}^{(0)} + \hat{\phi}_{p,t,M}^{(1)} q + \hat{\phi}_{p,t,M}^{(2)} q^2 \end{pmatrix} \right]^2 \\ &= \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) \left[y_s - (z_{s,1} \quad z_{s,2} \quad \dots \quad z_{s,M})^T \begin{pmatrix} \hat{\phi}_{p,t,1}^{(0)} + \hat{\phi}_{p,t,1}^{(1)} q + \hat{\phi}_{p,t,1}^{(2)} q^2 \\ \hat{\phi}_{p,t,2}^{(0)} + \hat{\phi}_{p,t,2}^{(1)} q + \hat{\phi}_{p,t,2}^{(2)} q^2 \\ \vdots \\ \hat{\phi}_{p,t,M}^{(0)} + \hat{\phi}_{p,t,M}^{(1)} q + \hat{\phi}_{p,t,M}^{(2)} q^2 \end{pmatrix} \right]^2 \\ &= \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) \left[y_s - (z_{s,1} \quad z_{s,1}q \quad z_{s,1}q^2 \quad \dots \quad z_{s,M} \quad z_{s,M}q \quad z_{s,M}q^2)^T \begin{pmatrix} \hat{\phi}_{p,t,1}^{(0)} \\ \hat{\phi}_{p,t,1}^{(1)} \\ \hat{\phi}_{p,t,1}^{(2)} \\ \vdots \\ \hat{\phi}_{p,t,M}^{(0)} \\ \hat{\phi}_{p,t,M}^{(1)} \\ \hat{\phi}_{p,t,M}^{(2)} \end{pmatrix} \right]^2 \\ &= \sum_{s=1}^t \lambda^{t-s} w(\mathbf{q}_s, \mathbf{q}_p) (y_s - \tilde{\mathbf{z}}_s^T \tilde{\Phi}_{p,t})^2 \end{aligned}$$

ただし,

$$\begin{aligned} \tilde{\mathbf{z}}_s^T &= (z_{s,1} \quad z_{s,1}q \quad z_{s,1}q^2 \quad \dots \quad z_{s,M} \quad z_{s,M}q \quad z_{s,M}q^2)^T, \\ \tilde{\Phi}_{p,t} &= (\hat{\phi}_{p,t,1}^{(0)} \quad \hat{\phi}_{p,t,1}^{(1)} \quad \hat{\phi}_{p,t,1}^{(2)} \quad \dots \quad \hat{\phi}_{p,t,M}^{(0)} \quad \hat{\phi}_{p,t,M}^{(1)} \quad \hat{\phi}_{p,t,M}^{(2)})^T \end{aligned}$$

- た運転規制区間内の強風発生頻度の予測, 日本風学会論文集, Vol. 37, No. 1, pp. 11-24, 2012.
- 2) 島村誠, 松沼政明 : 強風警報システムの開発と実用化, JR EAST Technical Review, No. 13, pp. 36-43, 2005.
 - 3) Hoppmann, U., Koenig, S., Tielkes, T. and Matschke, G. : A short-term strong wind prediction model for railway application: design and verification, *J. Wind Eng. Indust. Aerodyn.*, Vol. 90, pp. 1127-1134, 2002.
 - 4) Giebel, G. : The State-Of-The-Art in Short-Term Prediction of Wind Power -The-Art in Short-Term Predi Pre ANEMOS, 2003.
 - 5) Landberg, L. : Short-term prediction of local wind conditions, Risø-R-702(EN), Risø National Laboratory, Roskilde, Denmark, 1994, ISBN 87-550-1916-1.
 - 6) Joensen, A., Madsen, H. and Nielsen, T. S. : Non-parametric Statistical Method for Wind Power Prediction, *Proc. European Wind Energy Conference 97*, 788, 1997.
 - 7) Ishizaki, H. : Wind Profiles, Turbulence Intensities and Gust Factors for Design in Typhoon-prone Regions, *J. Wind Eng. Indust. Aerodyn.*, 1983.
 - 8) Sweats, J. A. : Indices of discrimination or diagnostic accuracy: their ROCs and implied models, *Psychol. Bull.*, Vol. 99, pp. 100-117, 1986.
 - 9) Donaldson, R. J., Dyer, R. M. and Kraus, M. J. : An objective evaluator of techniques for predicting severe weather events, *9th Conference on Severe Local Storms, Amer. Meteor. Soc.*, Boston, pp. 321-326, 1975.
 - 10) Swets, J. A. : Measuring the accuracy of diagnostic systems, *Science*, Vol. 240, pp. 1285-1293, 1988.
 - 11) Pinson, P., Chevallier, C. and Kariniotakis, G. N. : Trading Wind Generation from Short-Term Probabilistic Forecasts of Wind Power, *IEEE Transactions on Power Systems*, Vol. 22, No. 3, 2007.

(2017. 4. 21 受付)

GUST FORECASTING BY USING NUMERICAL WEATHER PREDICTION AND ON-SITE MEASUREMENT

Atsushi YAMAGUCHI and Takeshi ISHIHARA

A gust forecasting based on ARX (Autoregressive with Exogenous inputs) model which uses numerical weather prediction and on-site measurement as inputs was proposed and the model parameters were estimated by using non-parametric regression with forgetting factors. The prediction accuracy by using dynamically adaptive model was improved compared to the conventional static MOS (Model Output Statistics) model. It was also shown that the prediction accuracy of maximum gust improves by utilizing the numerical weather prediction with higher horizontal resolution. The predictability of the gust with the maximum wind speed larger than 15m/s was evaluated by using ROC (Receiver Operating Characteristic) curve and AUC (Area Under the Curve) and was improved by the proposed method.