

ニューラルネットワークによる風速の予測能力の検討

松 坂 知 行

Time serial prediction of wind speed by neural network

Tomoyuki MATSUZAKA

Abstract

Effective prediction of wind speed and direction is the basis for a wind energy conversion system aiming at economical fuel control of a stand alone wind energy conversion system. There are several methods for prediction of time serial signal such as statistical approach, linear estimation and Kalman filter approach. However, it is difficult to treat such non-linear prediction problems as wind speed estimation with conventional methods. Hence, the author studied a prediction method using neural networks, which are considered to be powerful for non-linear prediction method. The data base used in our study is composed of time serial points recorded at TAPPI wind park. The first part of the data was used for the training the networks, the other was used for the validation. The types of the neural networks used in this paper are feed forward and recurrent network. It was found that neural networks perform better short-term prediction of wind speed.

Key words: Wind speed, Estimation, Neural Networks

1. ま え が き

自然エネルギーは環境を汚染しないため、近時再生可能なエネルギーとして利用が推進されている。この中でも現在最も実用化されているのは風力エネルギーであり、欧州、米国などで分散型エネルギーとして利用が推進されている。これらの諸国で伸びている理由は、低利率での融資、電力の買い取り価格の保証、風力発電に対する補助制度、送電系統への接続の開放と再生可能エネルギーへの優遇税制などの誘導策が要因である。また最近では、地球温暖化の観点からCO₂を削減するため、自然エネルギーの利用に追風が吹いているのも大きな要因の一つである。日本においても過去2年間の伸び率は約50%であり、漸く離陸し始めた感はあるが、発電設備の絶対量は12 (Mw) であり、同じ工業国であるドイツの100分の1にも満たない。

風力エネルギー導入の大きな障害の一つは風の変動と持続性である。すなわち風が定常的なエネルギー源として信頼できないことである。このことを既存電源と比較してみると、水力、火力、原子力発電においては、入力エネルギーは予め確保され、その入力量を制御することによる発電量を調整することができるが、風力発電を始めとする自然エネルギーにおいては、エネルギーの変動が大きくまたその変動が予測できないため、実用的な観点から見れば信頼できないエネルギーと見なされているのが実状である。

しかし、もし風の変動が予測可能であれば以下のような系統運用が可能になる。

離島など単独系統で用いられているディーゼル発電機は燃料が高価であるため、価格的に現在の風力発電で十分代替可能であると云われている。もしこの場合、数分～数10分先の風速の予測が可能であれば、風力発電に任せてディーゼル発電機の出力を制御し、省燃料化を行い、予測に沿った計画的運用ができる。すなわち風力発電機と組み合わせたハイブリットシステムが実現でき、系統運用と省燃料化が同時に達成できる。これを実現するためには風速の予測が重要であり、本研究では不規則に変動する信号の予測に適していると考えられるニューラルネットワークに着目し、風速の時系列予測の基礎研究を行った。

第一報¹⁾においては秒単位(0.5秒)で計測された風速を用いて数秒先の風速を予測したが、本稿においてはさらに数10分～1時間先の風速の予測を試みた。また前稿においてはフィードフォワード型のニューラルネットワークのみを用いたが、本稿²⁾においてはリカレント型についても検討してみた。以下得られた結果について報告する。

2. 研究 方 法

時系列信号の予測には統計モデル、線形モデル、カルマンフィルタなどを用いた方法が考えられるが、風速のように非線形性の強い信号に対しては予測が困難であり、ニューラル・ネットワークのような柔軟なモデルの方が有効であると考えられる。

風速の予測に関してニューラル・ネットワークを用いた研究は最近いくつか見られるようになった。可変速風車発電機を最大効率で運転するための予測器を構成する

平成9年12月15日受理
八戸工業大学 情報システム工学研究所 教授

ために、ニューラル・ネットワークで風速を予測した研究²⁾、単独系統に用いられる風力発電機をディーゼル発電機と併用し、ハイブリット発電システムを構成したときの省燃料制御を実現するため数分～数十分先の風速の変動を予測する研究などが見られる³⁾。これらの研究は欧州で行われたものであり、当然日本の風況とは異なった環境であるため、本稿では日本を代表する竜飛ウインドパークのデータを用いて基礎的な段階から研究を行った。予測の基本的な考え方は以下のとおりである。

風速、風向などの自然界の現象の変動は常に過去の変動の履歴に左右される。すなわち現時点の風速は、不連続的に出現したものではなく、直前までの風速と相関が強いと考えられる。したがって現時点から遡った過去のデータから次の時点の風速を予測することが可能となる。しかし現時点ではどの程度過去まで遡ればよいか、またどの程度の先まで予測可能かは試行錯誤的にやってみる以外に方法がない。予測に用いられるニューラル・ネットワークにはフィードフォワード型、リカレント型などが考えられる。本稿では二つの型を取り上げて予測能力を検討した。

3. ニューラルネットワーク

ニューラル・ネットワークは人間の脳を模倣した機能を持っており、図1に示す通り数理モデルのように多数のニューロンから成り立ち、これらが図2のように多段階、多層結合しネットワークを構成している。

図1、図2に示すようなニューラル・ネットワークは、




図1 ニューラルネットワークの基本構成




図2 多層結合したニューラル・ネットワーク

信号は入力側から出力側への一方向に進み、出力側から入力側へのフィードバックがないのでフィードフォワード型と呼ばれている。

これに対して出力側から入力側へフィードバックするネットワークも考案されており、この型のネットワークはリカレント型と呼ばれている。リカレント型ネットワークは内部に記憶要素があるため、信号の時間的、空間的な特徴を識別する能力が大きいと云われており、風速のような不規則に変動する信号の特徴を記憶し、予測を行うのに適していると考えられる。

図3にリカレント型ニューラル・ネットワークの基本構成を示す。また図4はリカレント型ニューラル・ネットワーク要素を用いた代表的なニューラル・ネットワークとして知られているElman ネットワークである。このネットワークは中間層から入力層へフィードバックがあり、このフィードバックによる記憶作用で空間的なパターン認識を行うことができる。全体の構成は図4に示すように正接シグモイドニューロンの中間層と線形ニューロンの出力層から構成されている。

つぎにニューロン関数について説明する。図5は線形

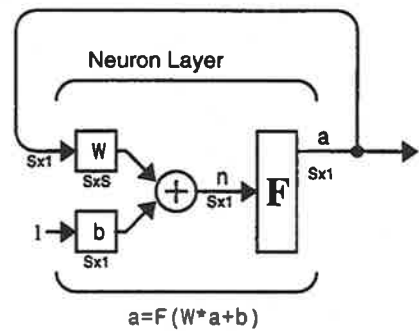


図3 リカレント型ニューラル・ネットワークの基本構成




図4 Elman ネットワーク




図5 線形ニューロン関数




図6 超正接シグモイド関数




図7 ラジアルベース関数

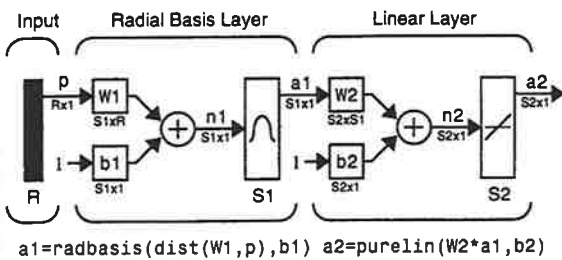


図8 ラジアルベース・ネットワーク

ニューロン関数，図6は正接シグモイド関数，図7はラジアルベース関数である。また図8はラジアルベース関数と線形ニューロン関数を用いたニューラル・ネットワークである。ラジアルベース関数を用いたネットワークは少ない学習階数で収束すると云われており，このため今回の検討に含めた。

4. 風速の予測の原理

つぎに風速の予測を行うためのデータの流れを説明する。図9はこの構成図である。まず入力 x は風速の時系列信号である。この信号を $1, 2, \dots, n$ 単位時間遅らせた信号を入力層の各ニューロンに入力する。一方ニューラルネットワークの出力 y には，1時点先あるいは n 時点先の信号を教師信号として用い，学習信号を生成するブロックに入力する。本図は入力層，出力層の2階層から成り，図示の関数 f_1, f_2 に対しては種々組合せを考慮し，実際にはこの関数を種々変えながら検討した。

学習ルールにはバックプロパゲーション法，慣性項付




図9 風速の予測器

きバックプロパゲーション法，Levenberg-Marquardt法(LM法)などがあるが，前回の研究でLM法が最も収束が速いことが分かったので今回はすべてLM法で計算した。

5. データの処理方法

ニューラルネットワークのソフトウェアとしては Matlab の Toolbox を利用した。Matlab はインタプリタ型の言語であるため，プログラムの試行錯誤が容易で，開発時間が非常に速く，また Toolbox には多数のライブラリ関数が備えられているのでソフトウェアの開発環境として適している。またハードウェアとしては DOS/V 機 (Pentium の 200 MHz) を用いた。DOS/V 機を用いた理由は，Matlab の動作するコンピュータとして標準的な PC/AT が望ましいためである。

4.1 データの前処理

つぎにデータの前処理について述べる。いまのデータを

$$X = (x_1, x_2, x_3, \dots, X_n) \quad (1)$$

とする。このデータを以下のように正規化する。これは各関数の値域が ± 1 の範囲に定められているためである。

$$\bar{x}_i = \frac{x_i - \text{mean}(X)}{\text{Max}(X) - \text{Min}(X)} \quad (2)$$

4.2 ニューラルネットワークによる学習と予測

ネットワークはフィードフォワード・ネットワーク，Elman ネットワーク，ラジアルベース・ネットワーク，適応ネットワークの4種類とし，また過去に遡るステップ数 Nd は $4 \sim 8$ ，未来の予測ステップ数 Np は $1 \sim 5$ まで検討することにした。また全データ数を $1,000$ とし，前後二分け，前の 500 でニューラルネットワークを学習させ，後の 500 で予測することにした。

4.3 採取データのタイムステップ

前稿においては予測のタイムステップを秒単位で行ったが、今回は10分および1時間とした。本研究では離島などのスタンドアロン風力発電機のディーゼル・ハイブリットシステムを想定しているため、予想の時間ステップを大きくすることにしたものである。また将来電力の先物買いなども考えられるので比較的長い先の時間を考慮したものである。

具体的には竜飛ウインドパークの10分間平均運転データおよび竜飛灯台の1時間毎の観測データを用いた。

5. 予測結果

5.1 フィードフォワード・ネットワーク

図10(a)はフィードフォワード・ネットワークによる学習結果の適合性、図10(b)は未知のデータに対するネットワークの予測能力を示す汎化能力を示す。入力データは10分間平均である。また予測のステップは10分であり、10分先の風速の予測を示す。(a),(b)とも測定値と予測値はある程度一致しているが、細部においてはずれが見られる。

表1(a),(b)は過去の時間ステップNdと未来の予測時間ステップNpに対する測定値と実測値の相関係数を示す。

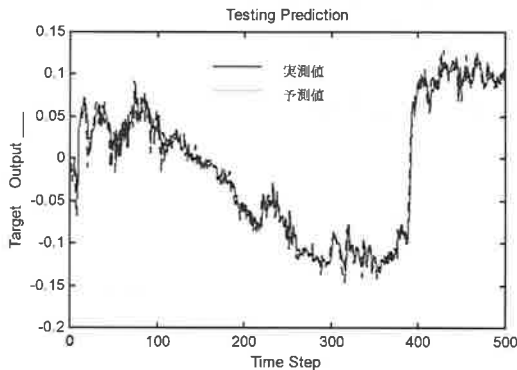


図10(a) 適合性のテスト

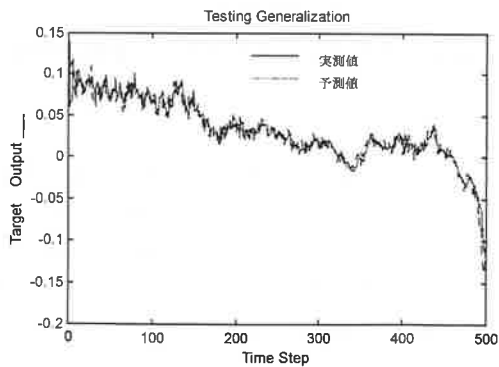


図10(b) 汎化能力のテスト

表1(a) フィードフォワード・ネットワーク (生データ, ステップ=10分)

		Np				
		1	2	3	4	5
Nd	4	0.9693	0.9683	0.9591	0.9691	0.9677
	5	0.9644	0.9487	0.9603	0.956	0.9413
	6	0.9645	0.9517	0.9381	0.9385	0.9471
	7	0.9630	0.9411	0.9440	0.9296	0.9497
	8	0.9500	0.9455	0.9321	0.9475	0.9275

表1(b) フィードフォワード・ネットワーク (差分データ, ステップ=10分)

		Np				
		1	2	3	4	5
Nd	4	0.9687	0.9702	0.9757	0.9782	0.9728
	5	0.9641	0.9379	0.9709	0.9623	0.9153
	6	0.9594	0.9697	0.9369	0.9374	0.9198
	7	0.9527	0.9036	0.9151	0.9202	0.9388
	8	0.9394	0.9018	0.9207	0.9034	0.9156

表2(a) フィードフォワード・ネットワーク (生データ, ステップ=1時間)

		Np				
		1	2	3	4	5
Nd	4	0.8966	0.8837	0.8699	0.8627	0.8465
	5	0.8964	0.88	0.8586	0.854	0.8377
	6	0.8844	0.8626	0.8562	0.8516	0.8044
	7	0.887	0.8604	0.839	0.8002	0.7874
	8	0.8771	0.8617	0.8274	0.7701	0.7674

表2(b) フィードフォワード・ネットワーク (差分データ, ステップ=1時間)

		Np				
		1	2	3	4	5
Nd	4	0.8986	0.8921	0.8676	0.8653	0.8628
	5	0.8883	0.8857	0.8626	0.8732	0.8514
	6	0.8883	0.856	0.8466	0.8043	0.8000
	7	0.8807	0.8555	0.8031	0.7978	0.7921
	8	0.8694	0.8372	0.8067	0.8064	0.7562

表1はデータをそのまま入れた場合、表2は差分データを入れた場合であり、両者の比較から差分データを用いた方が予測能力が高いことがわかる。

表2は1時間データを用いて、1時間先の風速を予測したもので、この場合は相関係数の値も小さくなり、10分データよりは予測がずれることを示している。また表1と同様に差分データの方が予測能力が高い。

一方フィードフォワード・ネットワークはしばしば計算が不安定に発散することがあり、ネットワークとして

は問題をもっていることが分かった。内部に記憶要素がないため、風速のような非線型の信号に対しては学習過程で計算が不安定になるものと思われる。

5.2 リカレントネットワーク

つぎに Elman ネットワークを用いた場合の結果を図 11, 表 3, 表 4 に示す。

表 3, 表 4 の (a), (b). 比較してみると Elman ネットワークでは生データと差分データとの差がほとんどないことが分かる。この理由は Elman ネットワークが内部に記憶要素をもっているため信号の時間的、空間的な処理能力が高いためと考えられる。また表 1, 表 2 と表 3, 表 4 を比較すると Elman ネットワークの方が相関係数が低くなっているが、細部を見るとむしろ Elman ネットワークの方が予測がよいことが分かった。また学習段階の計算においても原因不明の発散が見られず安定であった。




図 11(a) 適合性のテスト

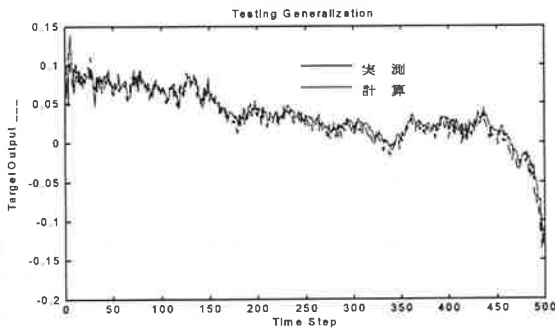


図 11(b) 汎化能力のテスト

5.3 ラジアルベース・ネットワーク

表 5, 表 6 はラジアルベース・ネットワークによる計算結果である。ラジアルベース・ネットワークは少ない計算時間で収束すると言われており、風速の予測などでよく使われている。しかし Np が大きくなると、いままでのネットワークに比較して相関係数が急に下がり、予測能力があまりよくない。特にステップ時間が 1 時間の場合は急激に相関係数が小さくなり、時系列的な予測には適していないようである。

表 3(a) Elman ネットワーク
(生データ, ステップ=10 分)

		Np				
		1	2	3	4	5
Nd	4	0.9503	0.953	0.9127	0.9431	0.9084
	5	0.9647	0.9486	0.9502	0.8778	0.8979
	6	0.9488	0.9611	0.9508	0.8887	0.8178
	7	0.9373	0.8798	0.9716	0.9553	0.9042
	8	0.9178	0.9715	0.9209	0.9514	0.8248

表 3(b) Elman ネットワーク
(差分データ, ステップ=10 分)

		Np				
		1	2	3	4	5
Nd	4	0.9245	0.9708	0.9415	0.932	0.9453
	5	0.9454	0.9264	0.9712	0.9465	0.9471
	6	0.9399	0.9348	0.9567	0.9428	0.9229
	7	0.9557	0.9622	0.9465	0.9388	0.963
	8	0.9681	0.9488	0.9323	0.936	0.9399

表 4(a) Elman ネットワーク
(生データ, ステップ=1 時間)

		Np				
		1	2	3	4	5
Nd	4	0.8948	0.9006	0.8996	0.8813	0.8839
	5	0.8968	0.9023	0.8880	0.8855	0.8883
	6	0.9004	0.8953	0.8960	0.8915	0.8827
	7	0.8976	0.8976	0.8958	0.8918	0.8872
	8	0.8981	0.8951	0.8935	0.8904	0.8786

表 4(b) Elman ネットワーク
(差分データ, ステップ=1 時間)

		Np				
		1	2	3	4	5
Nd	4	0.9005	0.8999	0.8975	0.8925	0.8779
	5	0.8991	0.8977	0.8905	0.8955	0.8867
	6	0.8969	0.8986	0.8966	0.8933	0.8935
	7	0.8981	0.8925	0.8950	0.8900	0.8880
	8	0.8992	0.8975	0.8917	0.8898	0.8825

ラジアルベース・ネットワークにおいても差分データを用いた方がよい結果が得られている。

5.4 適応ニューラル・ネットワーク

表 7, 表 8 に適応ニューラル・ネットワークの処理結果を示す。ステップ時間が 10 分のときは非常によく合うが、ステップ時間が 1 時間になると大きくはずれることが分かる。この原因はデータを離散的な値で与えていることにあると思われる。

表5(a) ラジアルベース・ネットワーク
(生データ, ステップ=10分)

		Np				
		1	2	3	4	5
Nd	4	0.9506	0.7623	0.6458	0.5131	0.6311
	5	0.8118	0.6302	0.6238	0.4689	0.6930
	6	0.9341	0.8732	0.7552	0.7378	0.7113
	7	0.9290	0.8339	0.8286	0.7985	0.7770
	8	0.9345	0.8882	0.9080	0.876	0.8311

表7(a) 適応ネットワーク
(生データ, ステップ=10分)

		Np				
		1	2	3	4	5
Nd	4	0.9616	0.9588	0.9614	0.9614	0.9640
	5	0.9617	0.9599	0.9606	0.9613	0.9639
	6	0.9617	0.9593	0.9605	0.9612	0.9637
	7	0.9611	0.9592	0.9604	0.9610	0.9630
	8	0.9610	0.9588	0.9595	0.9588	0.9608

表5(b) ラジアルベース・ネットワーク
(差分データ, ステップ=10分)

		Np				
		1	2	3	4	5
Nd	4	0.9363	0.881	0.7767	0.8874	0.8636
	5	0.9303	0.7887	0.797	0.9172	0.7302
	6	0.9469	0.8836	0.6999	0.7627	0.7651
	7	0.9357	0.9294	0.8025	0.8294	0.6638
	8	0.9484	0.9293	0.8213	0.8988	0.7386

表7(a) 適応ネットワーク
(差分データ, ステップ=10分)

		Np				
		1	2	3	4	5
Nd	4	0.9744	0.9752	0.9757	0.9761	0.9770
	5	0.9745	0.9747	0.9757	0.9761	0.9769
	6	0.9742	0.9747	0.9757	0.9761	0.9762
	7	0.9742	0.9747	0.9752	0.9745	0.9754
	8	0.9742	0.9746	0.9739	0.9735	0.9740

表6(a) ラジアルベース・ネットワーク
(生データ, ステップ=1時間)

		Np				
		1	2	3	4	5
Nd	4	0.8189	0.8112	0.7861	0.7737	0.7357
	5	0.8244	0.805	0.7777	0.7784	0.6951
	6	0.8229	0.8099	0.8804	0.7723	0.7524
	7	0.8150	0.8074	0.7801	0.7758	0.7388
	8	0.8179	0.8005	0.779	0.7677	0.7317

表8(a) 適応ネットワーク
(生データ, ステップ=1時間)

		Np				
		1	2	3	4	5
Nd	4	0.8350	0.8139	0.7109	0.4061	-0.0293
	5	0.8329	0.7942	0.6668	0.4110	0.0286
	6	0.8310	0.7843	0.6688	0.4351	0.1052
	7	0.8302	0.7864	0.6789	0.4757	0.1791
	8	0.8303	0.7893	0.6924	0.5102	0.2159

表6(b) ラジアルベース・ネットワーク
(生データ, ステップ=1時間)

		Np				
		1	2	3	4	5
Nd	4	0.8580	0.7629	0.7617	0.7273	0.7113
	5	0.8832	0.8263	0.7914	0.7609	0.7476
	6	0.8673	0.8413	0.8311	0.799	0.7596
	7	0.8628	0.8392	0.7983	0.7976	0.7638
	8	0.8775	0.8357	0.8125	0.8002	0.7634

表8(b) 適応ネットワーク
(差分データ, ステップ時間=1時間)

		Np				
		1	2	3	4	5
Nd	4	0.9001	0.8974	0.8945	0.8905	0.8739
	5	0.9002	0.8976	0.8896	0.8877	0.8627
	6	0.9002	0.8929	0.8863	0.8793	0.8360
	7	0.8981	0.8916	0.8831	0.8709	0.8166
	8	0.8982	0.8920	0.8838	0.8714	0.8187

6. ま と め

以上ニューラルネットワークを用いて風速の時系列予測を試みた。この結果、ニューラルネットワークを用いた予測は良く合うことが認められ、風速の予測の可能性は十分あるものと考えられる。

主なる結論としては

(1) Elman ネットワーク以外は差分データを与えた方が予測の精度が高い。

(2) Elman ネットワークは時間的、空間的な特徴を識別でき、風速の予測には適している。

(3) 学習データ数はステップ時間が10分の場合、500点で十分と思われる。しかし1時間の場合はより多くの点数を必要とするものと思われる。

なお本研究は、平成9年度文部省科研費の補助により行ったものである。

6. 参考文献

- 1) 松坂他:「ニューラルネットワークによる風速の時系列予測」, 八戸工業大学情報システム工学研究所紀要, pp. 15-20.
- 2) LiLin et al.: “Predicting wind bahavior with neural networks”, EU Wind Energy Conference, pp.15-22, Gortborg, 1996.
- 3) H.G. Beyer et al.: “Short term prediction of wind speed and power output of a wind turbine with neural networks”, pp. 349-356, Proc. of EWEC '94, Greece, 1994.