

(12) 風速予測のためのカオス理論とGMDH理論の適用に関する研究

Application of Chaos Theory and GMDH to Wind Velocity Prediction

古田均*・広兼道幸**・瀬戸口光宏***

Hitoshi FURUTA, Michiyuki HIROKANE, Mitsuhiro SETOGUCHI

*工博 関西大学教授 総合情報学部総合情報学科

**博(工) 関西大学助教授 総合情報学部総合情報学科

***関西大学大学院 総合情報学研究科知識情報学専攻

In these days, monitoring and controlling play important roles to reduce the vibration of high-rise buildings due to winds and to control traffic flows on such bridges as Amarubé Bridge, Kansai International Airport Bridge and Akashi Strait Bridge under strong winds. In order to improve the performance of monitoring and controlling, it is desirable to establish a practical method of predicting the wind velocity.

In this paper, an attempt is made to develop a prediction method of wind velocity, which behaves irregularly time to time, by introducing chaos theory and GMDH (Group Method of Data Handling). Many researches have revealed that the chaos theory is useful in dealing with complex systems, and GMDH can analyze highly nonlinear systems which have a few input and output variables. Numerical examples are presented to illustrate the applicability of the proposed method, and to discuss the characteristics of the both methods.

1. はじめに

建築物の高層化に伴い、風による高層建築物の振動が問題となっている。現在、多くの高層建築物には、その建築物自体に振動制御装置が設置されている。しかし、現在の振動制御方法は、風が吹き、振動が起こってから制御するという、受動的なものである。また、関西国際空港連絡橋・明石海峡大橋などの長大橋では、風速を計測し、その大きさにより交通規制を行っている。この際、実際の風速と観測された風速との間に時間的ずれが生じるので、適切な交通規制が行われない場合も生じる。これらの問題を解決するためには、建築物や橋梁自体の構造を考え直すだけでなく、制御や規制などに有効な精度の高い風速予測が必要である。

そこで本研究では、不規則な振る舞いを見せる「風」を対象として、風速予測を行うことを目的とする。ここでは、現在電力需要量や水道需要量¹⁾などの社会現象や天気などの自然現象といった、「不規則な振る舞い」の評価に適しているカオス理論による予測手法と、ダム貯水池水温の予測²⁾など、複雑で大規模な構造のシステムのモデリングを行う場合に有効な手法であり、少ない入出力データで複雑な多変数非線形系の同定が可能な GMDH (Group Method of Data Handling)理論による予測手法の比較を行った。

2. カオス理論

2. 1 カオスとは

カオス²⁾ (chaos) は、広義では「混沌」や「無秩序」という意味であるが、科学・工学の分野では専門用語として使われ、多くの研究がなされている。しかし、明確な定義をすることすら難しく、また現象がカオスであるか否かの判別にも決定的な方法が確立されていない。

カオスの定義は様々な研究者によってなされているが、それらを総じて要約すると、カオスとは、「決定論的なシステムが作り出す非周期振動」という現象であるといえる。ここでいう決定論的なシステムとは、破ることができない不変の法則からなる系という意味である。また、非周期振動というのは、専ら偶然に支配される確率論的な運動という意味である。すなわちカオスは、不変の法則に支配される系でありながら法則性の無い予測不可能な非周期的振る舞いということである。

2. 2 カオスの特徴

カオスには、初期値のほんのわずかな違いが、時間とともに大きく拡大する初期値鋭敏性という特徴がある。この特徴をロジスティック写像と呼ばれる、式(2.1)を用いて説明する。

$$x_{n+1} = a x_n (1 - x_n) \quad (2.1)$$

$a = 4.0$ で、 $x_1 = 0.8$ のときと $x_1 = 0.8001$ のときを比較する(図-2.1)。7ステップまでは、比較的誤差が少な

いが、それ以降は徐々に誤差が大きくなり、全く異なる挙動を見せるようになる。この初期値鋭敏性を説明する際に、バタフライ効果（Butterfly Effect）という言葉が用いられる。バタフライ効果とは、「蝶の羽ばたきのようなわずかな空気の揺れが後に台風を起こすかもしれない」というローレンツの比喻から派生している。




図-2. 1 バタフライ効果

また初期値鋭敏性により、カオス的な現象には状態空間上で非常に近い2点が、時間の経過とともに離れていく軌道不安定性という性質がある。現在、時系列データがカオス的であるかどうかという判別は、リアプノフ数（Lyapunov Exponent）という数量を用いて行われている。リアプノフ数とは、近い位置から発した2本の軌道が、時間発展とともに離れていく速さを表すもので、リアプノフ数が正のときはカオスの振動である可能性が高く、負であればカオスではない可能性が高い。

この軌道不安定性により、カオスの振る舞いをする現象の予測は、短期予測には向いているが、長期予測には不向きであることがわかる。

2. 3 カオスの振る舞いをする現象の予測

カオスの振る舞いをする現象は、式（2. 1）のロジスティック写像のような、明確な数式モデルに従っているものや、社会現象としての、上下水道需要量・電力需要量・交通量や、自然現象である、心臓の鼓動、地震、水の乱流状態、気温の季節的変動や天候の移り変わりなど、様々である。そしてその多くに予測が必要であり、そのための研究がなされている。

2. 4. 1 カオス理論による短期予測の手順

短期予測をするために、まず時系列データを等サンプリング間隔で観測する。サンプリングされたデータがカオス的であるならば、その振る舞いは決定論的な法則に従っていると考えられる。このとき、非線形的な決定論的規則を推定すれば、初期値鋭敏性により、決定論的因果性を失うまでの近未来のデータを予測することが可能である。

ここで最も重要なことは、ダイナミクスの推定である。この手順は、観測した時系列データのダイナミクスを保存したかたちで、タケンス（Takens）の埋め込み定理を用いて、 n 次元再構成状態空間にプロットすることにより、 n

次元状態空間に時系列データを再構成し、軌道を作る。この軌道のことをアトラクタと呼び、カオス現象のときに現れるアトラクタを特に、ストレンジアトラクタと呼ぶ。そして、プロットされたデータベクトルの近傍データベクトルと、その s ステップ先のデータベクトルを用いて、局所再構成法により、目的とする予測データベクトルを推定する。局所再構成法として、グラム・シュミットの直交系法、テセレーション法、局所ファジィ再構成法などがある。そして最後に、局所再構成法により推定されたデータベクトルを元の時系列に変換して、目的とする s ステップ先の時系列データの予測を求める。

2. 4. 2 埋め込み（Embedding）

以上に述べたように、カオス理論における予測は「一本の観測時系列データから、もとの力学系の状態空間とアトラクタを再構成する」というタケンスの定理に基づいている。タケンスの埋め込み定理の概要は以下のとおりである。観測されたある時系列データ $y(t)$ から、ベクトル $(y(t), y(t-\tau), y(t-2\tau), \dots, y(t-(n-1)\tau))$ を作る（ τ は遅れ時間）。このベクトルは、 n 次元再構成状態空間 R^n の1点を示すことになる。したがって、 t を変化させると、この n 次元再構成状態空間に軌道が描ける。この再構成軌道は、 n を十分大きく取れば、もとの決定論的力学系の埋め込みとなっている。つまり、もとの力学系に何らかのアトラクタが現れているならば、再構成状態空間にはこのアトラクタの位相構造を保存したアトラクタが再現することになる。 n は通常「埋め込み次元」と呼ばれているが、再構成の操作が「埋め込み」であるためには、この次元 n はもとの状態空間の次元を m としたとき、

$$n > 2m + 1 \quad (2. 2)$$

であれば十分であることが証明されている。ただし、これは十分条件であって、データによっては $2m+1$ 未満でも埋め込みができる場合がある。

2. 4. 3 局所再構成法

観測された時系列データをタケンスの埋め込み定理を用いて、多次元再構成状態空間に有限個数のデータベクトルからなる、なめらかなアトラクタを構成する。この埋め込み操作により再構成された状態空間とアトラクタの軌道に関して、最新に観測された時系列データを含むデータベクトル $z(t)$ と、その近傍ベクトル $x(i)$ から s ステップ後のデータベクトル $x(i+s)$ への軌道を用いて、 $z(t)$ の近未来の軌道を推定し、 s ステップ先のデータベクトルを求める。これを局所再構成という。

代表的な局所再構成法にグラム・シュミットの直交系法、テセレーション法、局所ファジィ再構成法などがある。本研究は、カオス理論と GMDH 理論の比較を行う。そこで、局所再構成法の比較を行ったところ、今回最も予測精度の高かったのは、局所ファジィ再構成法であったので、これをカオス理論による予測手法として選択した。

3. GMDH 理論

3. 1 GMDH 理論とは

GMDH 理論（Group Method of Data Handling, データ処理の群的手法）は、複雑な非線形現象の入出力関係を見出すために、発見的自己組織化（Heuristic Self Organization）の原理により提案され、キエフの研究者であるイワネンコ

(A.G.Ivakhnemko) により、1968年に導入された。GMDH は画像ネットワークであり、多項式 (polynomial) ニューラル・ネットワークの一つでもある。イワネンコは、河川および海洋における魚体数の、より正確な予測モデルを作るために GMDH を開発した。この GMDH は漁場のモデルをはじめ、以後多くのモデルに応用されて好成績を収めた。実際、イワネンコが開発したモデルは、多重の層を持つ画像ネットワークの作成に関する最初の合理的方法であった。手法的にはニューラル・ネットワークの一種とされているが、多項式多様体に基づいているため、複雑な構造を持つデータの解析に有用である。GMDH の最大の特徴は、層を重ねることにある。この多層構造がモデルの成功の要因として挙げられる。

3. 2 GMDH アルゴリズム

GMDH アルゴリズムの操作の手順を簡単に示す⁴⁾。

3. 2. 1 入出力データの分割

GMDH では、まず入出力データを学習用データ (Training Data) と評価用データ (Checking Data) とに分割する。学習用データとは、モデルを同定するために用いるデータであり、評価用データとは、同定されたモデルを評価するためのデータである。ただし、入出力データが N 個、学習用データと評価用データがそれぞれ N_L 個と N_C としたとき、 $N = N_L + N_C$ となるようにする。入出力データの分割には、前半と後半で分ける方法、最初の入出力データから交互に分ける方法、データ番号の乱数を用いて分ける方法、出力データの分散の大きいデータを学習用に、小さい方を評価用に分ける方法などがある。

3. 2. 2 イワネンコ多項式 (Ivakhnemko Polinomial)

n 個の入出力データから、任意の 2 つの入力変数 x_p, x_q と出力変数 y から、(3. 1) の 2 変数 2 次式の部分表現式を構成する。

$$y = a + b x_p + c x_q + d x_p^2 + e x_q^2 + f x_p x_q \quad (3. 1)$$

ここで a, b, c, d, e, f は係数である。

3. 2. 3 係数の選定

線形回帰分析により、学習用データを用いて、係数 $a \sim f$ の 6 つの係数を推定する。推定された係数と評価用データの入力データを部分表現式に代入し、式 (3. 2) より z を計算する。

$$z = a + b x_p + c x_q + d x_p^2 + e x_q^2 + f x_p x_q \quad (3. 2)$$

次に式 (3. 3) より、評価用データに対する 2 乗誤差 E を計算する。

$$E = \sum (y - z)^2 \quad (3. 3)$$

得られた $n(n-1)/2$ 個の誤差に対して、小さい順に並び替え、 $E_1 E_2 E_3 \dots E_{n(n-1)/2}$ とする。

3. 2. 4 アルゴリズムの終了判定

得られた E_1 が、 E^* (前層での E_1) との関係において、不等式 (3. 4) を満たすとき、アルゴリズムを終了する。

$$E_1 > E^* \quad (3. 4)$$

3. 2. 5 次層の入力変数の生成

不等式 (3. 4) を満たさなかったとき、入力変数を用いて式 (3. 2) から、中間変数 z を求める。この z が次層での入力変数となり、再び 3. 2. 2 以下を繰り返す。

3. 2. 6 推定モデルの獲得

アルゴリズムが終了した場合、2 乗誤差値 E^* を得た (3. 2) 式の部分表現式に前層での中間変数を代入し、同じ操作を第 1 層まで繰り返して、最終的な推定モデルを得る。

3. 3 GMDH のための時系列データの整理

GMDH は、少ない入出力データで複雑な多変数非線形系の同定が可能である。そこで本研究では、ただ 1 つの変数である時系列データを加工して、いくつかの入力変数と出力変数を得る。その手法を以下に述べる。

時系列データを、1 番目から一定の遅れ時間を取って N 個を入力変数 X_1 、2 番目から X_1 のときと同じだけ遅れ時間を取って N 個を入力変数 X_2 、 $\dots$ 、 k 番目から N 個を入力変数 X_k とする。同様に $k+1$ 番目から N 個を出力変数 Y とする。入力変数の数は、入力変数 X_1 と出力変数 Y の相関性が比較的高くなる範囲で考える。

入出力データがそろると、前節の手順に従って、推定モデルを獲得する。

4. カオス理論と GMDH 理論による予測結果の比較

4. 1 ロジスティック写像の予測

予測の対象として、まずロジスティック写像の予測を行う。ここで行う予測は、長期予測である。長期予測とは、得られた予測値を用いて予測を行うものとする。今回対象として用いるものは、式 (2. 1) の $a=4.0$ 、 $X_1=0.8$ のときのものである。カオス理論による予測、GMDH 理論による予測ともに、1 件目から 5000 件目までを用いて同定を行い、5001 件目以降を予測するものとする。

4. 1. 1 カオス理論による予測

5000 件のデータを用いてアトラクタを生成する。ロジスティック写像のアトラクタは 2 次元で十分であることが証明されているので、アトラクタの次元は 2 次元とする。また、アトラクタ上で探索する近傍点の数は 3 個で

ある。

4. 1. 2 GMDH 理論による予測

5000件のデータを分割して入力変数と出力変数を作成した。まず入力変数は、1件目からの4996件を X_1 、同様に2件目、3件目、4件目からの4996件をそれぞれ X_2 、 X_3 、 X_4 とした。次に出力変数は、5件目からの4996件を Y とした。

入出力変数の各組み合わせに対して、1件目からの4000件を学習用データとし、4001件目から4996件目までの996件を評価用データとした。

同定した、各層における各組み合わせによる係数と2乗誤差を、表4. 1に示す。第1層における、評価用データによる最小2乗誤差は、入力変数が X_3 と X_4 のときで、 1.08×10^{-23} となった(表4. 1 (i))。次層での入力変数は、 X_3 と X_4 、 X_1 と X_4 、 X_2 と X_4 、 X_2 と X_3 による中間変数をそれぞれ X_1 、 X_2 、 X_3 、 X_4 とする。

第2層における、評価用データによる最小2乗誤差は、表4. 1 (ii) より、入力変数が X_1 と X_3 のときで、 4.6×10^{-24} となった。これは前層での最小2乗誤差よりも小さいので、アルゴリズムを続行する。次層での入力変数は、 X_1 と X_3 、 X_1 と X_2 、 X_2 と X_3 、 X_1 と X_4 による中間変数をそれぞれ X_1 、 X_2 、 X_3 、 X_4 とする。

第3層における、評価用データによる最小2乗誤差は、表4. 1 (iii) より、入力変数が X_1 と X_2 のときで、 6.01

$\times 10^{-24}$ となった。これは前層での最小2乗誤差よりも大きいので、アルゴリズムを終了する。

最小2乗誤差の推移(図-4. 1)より、第2層での推定式を獲得した推定モデルとする。

4. 1. 3 予測結果




図-4. 1 最小2乗誤差の推移

5001件目以降の実際の値、カオス理論による予測値、GMDH 理論による予測値それぞれの推移を図-4. 2に示す。この結果より、ロジスティック写像の長期予測において、カオス理論では、12件目以降で相関性をほぼ失ってしまうのに対して、GMDH 理論では、40件近くまで相関性を保っていることがわかる。




図-4. 2 ロジスティック写像の予測

4. 2 風速の予測

次に風速の予測を行う。対象として用いるものは、季節風のデータである。ロジスティック写像の予測と同様に、カオス理論による予測、GMDH 理論による予測ともに、1件目から10000件目までを用いて同定を行い、10001件目以降を予測するものとする。

表-4. 1

各層におけるそれぞれの入力変数の
組み合わせに対する係数と2乗誤差

(i) 第1層						
	X_1X_2	X_1X_3	X_1X_4	X_2X_3	X_2X_4	X_3X_4
a	0.489132	0.474681	2.9E-13	0.454905	2.69E-13	2.5E-13
b	-0.09892	0.038532	-1.2E-13	0.240095	4.52E-14	2.082607
c	0.097409	0.090923	4	0.09574	4	3.479348
d	0.075286	-0.04737	-4.5E-14	-0.1957	-2.2E-13	-2.08261
e	-0.0767	-0.06221	-4	-0.06	-4	-4
f	0.021121	-0.02007	2.89E-13	-0.13421	3.41E-13	6.15E-13
2乗誤差	121.6966	122.1501	1.64E-23	121.5903	1.68E-23	1.08E-23

(ii) 第2層						
	X_1X_2	X_1X_3	X_1X_4	X_2X_3	X_2X_4	X_3X_4
a	-1.2E-13	-1.5E-13	2.31E-10	-1.9E-13	6.77E-10	1.98E-09
b	2.506162	1.282407	1	-0.86667	1	1
c	-1.50616	-0.28241	-9.9E-10	1.866667	-2.8E-09	-8.3E-09
d	-1.62366	-0.53862	-1.9E-13	0.918806	1.1E-13	3.31E-14
e	0.685482	-0.16494	1.08E-09	1.390597	2.91E-09	8.66E-09
f	0.958181	0.703561	-7.9E-11	-2.3094	-4.8E-11	-2.9E-10
2乗誤差	1.08E-23	4.6E-24	1.46E-22	1.11E-23	5.75E-22	4.96E-21

(iii) 第3層						
	X_1X_2	X_1X_3	X_1X_4	X_2X_3	X_2X_4	X_3X_4
a	3.73E-14	2.1E-14	2.57E-14	4.57E-14	4.18E-14	1.98E-09
b	0.591239	0.857011	1.243684	0.939708	0.955128	1
c	0.408761	0.142989	-0.24368	0.060292	0.044872	-8.3E-09
d	-0.35386	2.198572	-0.48646	-0.18656	-0.10254	3.31E-14
e	-0.44683	0.555046	0.149588	0.106657	0.185419	8.66E-09
f	0.800689	-2.75362	0.336875	0.079907	-0.08288	-2.9E-10
2乗誤差	6.01E-24	1.12E-23	1.26E-23	8.57E-24	1.61E-23	1.58E-15

4. 2. 1 カオス理論による予測

10000件までのデータを用い、アトラクタを生成する。このとき、アトラクタの次元数は16次元で行い、アトラクタ上で探索する近傍点の数は9個である。

4. 2. 2 GMDH 理論による予測

1件目、2件目、3件目、4件目それぞれから9996件を入力変数 X_1 、 X_2 、 X_3 、 X_4 とし、5件目から9996件を出力変数 Y とした。入出力変数の各組み合わせに対して、1件目からの8000件を学習用データとし、8001件目から9996件目までの1996件を評価用データとした。

同定して得られた各層における各組み合わせによる係数と2乗誤差を表4. 2に示す。第1層における、評価用データによる最小2乗誤差は、入力変数が X_3 と X_4 のときで、753.4946 となった (表4. 2 (i))。次層での入力変数は、 X_3 と X_4 、 X_2 と X_4 、 X_1 と X_4 、 X_1 と X_3 による中間変数をそれぞれ X_1 、 X_2 、 X_3 、 X_4 とする。

第2層における、評価用データによる最小2乗誤差は、表4. 2 (ii) より、入力変数が X_2 と X_4 のときで、741.2442 となった。これは前層での最小2乗誤差よりも小さいので、

表4. 2

各層におけるそれぞれの入力変数の
組み合わせに対する係数と2乗誤差

(i) 第1層						
	X_1, X_2	X_1, X_3	X_1, X_4	X_2, X_3	X_2, X_4	X_3, X_4
a	0.8439703	0.4818647	0.2552571	0.508399	0.3093047	0.3165369
b	-0.065974	0.0210885	0.011197	-0.259539	-0.107793	-0.399731
c	1.0126984	0.9420573	0.9743651	1.2172858	1.0841399	1.3778737
d	0.1879068	0.0848717	0.0331803	0.1620721	0.0503911	0.156268
e	0.1816356	0.0584448	0.0280177	0.1404522	0.0352233	0.1269272
f	-0.370777	-0.124355	-0.062373	-0.303486	-0.086413	-0.284271
2乗誤差	1368.0582	1090.8425	754.18954	1099.0175	754.52371	753.49465
(ii) 第2層						
	X_1, X_2	X_1, X_3	X_1, X_4	X_2, X_3	X_2, X_4	X_3, X_5
a	-0.028635	-0.011717	-0.017193	-0.03149	0.152243	0.0721856
b	0.8489441	1.7072955	0.9824098	2.7674232	1.5273141	1.2493119
c	0.1546383	-0.705882	0.0199542	-1.761315	-0.552017	-0.258956
d	1.9361038	2.2466924	0.0109824	4.8634766	0.0826966	0.0567313
e	1.9697382	2.3546784	0.0114648	5.053126	0.1187199	0.0672731
f	-3.905992	-4.601465	-0.022523	-9.91692	-0.200556	-0.123814
2乗誤差	744.87137	743.13568	753.49341	755.63802	741.24424	745.02487
(iii) 第3層						
	X_1, X_2	X_1, X_3	X_1, X_4	X_2, X_3	X_2, X_4	X_3, X_6
a	-0.001143	-0.000592	0.0042595	-0.036184	0.0205398	-0.002185
b	4.8998387	0.4002916	7.7305686	-2.370878	4.9780879	6.1928635
c	-3.899185	0.5998468	-6.730897	3.378075	-3.982333	-5.191817
d	0.7774056	0.4891094	3.678991	3.8124907	-4.405571	-1.542015
e	1.1086917	0.3897073	4.2936892	3.5723137	-4.010064	-1.019826
f	-1.886155	-0.878827	-7.972711	-7.385168	8.4158674	2.5817912
2乗誤差	740.41978	741.46888	745.09557	759.23642	749.8503	756.17538
(iv) 第4層						
	X_1, X_2	X_1, X_3	X_1, X_4	X_2, X_3	X_2, X_4	X_3, X_7
a	-0.032525	0.0724668	-0.005132	-0.047964	-0.005509	-0.011538
b	1.4994555	-1.049161	1.3861934	-0.058039	2.7767143	0.9755532
c	-0.492977	2.0348384	-0.385261	1.0672846	-1.775463	0.0264265
d	1.9986364	-2.726504	0.0529158	1.3363187	-0.193805	0.2466273
e	2.0634095	-2.804135	0.1102021	1.3144115	-0.017227	0.2529989
f	-4.062369	5.5313419	-0.16316	-2.651177	0.2109656	-0.499712
2乗誤差	740.59449	742.67943	741.8874	752.61422	745.24427	746.15282


アルゴリズムを続行する。次層での入力変数は、 X_2 と X_4 、 X_1 と X_3 、 X_1 と X_2 、 X_3 と X_4 による中間変数をそれぞれ X_1 、 X_2 、 X_3 、 X_4 とする。

第3層における、評価用データによる最小2乗誤差は、表4. 2 (iii) より、入力変数が X_1 と X_2 のときで、740.4198 となった。これは前層での最小2乗誤差よりも小さいので、アルゴリズムを続行する。次層での入力変数は、 X_1 と X_2 、 X_1 と X_3 、 X_1 と X_4 、 X_2 と X_4 による中間変数をそれぞれ X_1 、 X_2 、 X_3 、 X_4 とする。

第4層における、評価用データによる最小2乗誤差は、表4. 2 (iv) より、入力変数が X_1 と X_2 のときで、740.5945 となった。これは前層での最小2乗誤差よりも大きいので、アルゴリズムを終了する。

また、最小2乗誤差の推移を図4. 3に示す。これより、第3層での推定式を獲得した推定モデルとする。

図4. 3 最小2乗誤差の推移



4. 2. 3 予測結果

カオス理論とGMDH理論のそれぞれによる短期予測を行う。短期予測とは、得られた予測値を用いずに、実測値のみを用い、1件ずつ先を予測したものである。10001件目以降の実測値、カオス理論による予測値、GMDH理論による予測値それぞれの推移を図4. 4に示す。このグラフで見ると、どちらの予測結果もほぼ同じように見




図4. 4 風速の予測結果




図-4. 5 予測結果の実測値に対する誤差の割合

える。また、それぞれの予測値の、実測値に対する誤差の割合の推移を図-4. 5に示す。

このグラフで見ると、短期予測において、どちらも誤差は10%未満におさまっており、誤差の平均はカオス理論による予測の方が3.07%、GMDH理論による予測の方が3.06%と両手法とも予測結果の精度にほとんど差がない。

5. おわりに

5. 1 結論

本研究では、不規則な振る舞いを見せる風を対象として取り上げ、その予測システムの構築のために、カオス理論とGMDH理論の比較を行った。

まず、1次元のカオスと呼ばれるロジスティック写像の同定と予測において、GMDH理論による予測によって、カオス理論に比べはるかに良い予測結果が得られた。カオスの現象は、軌道不安定性のため、短期予測は可能であるが、長期予測は不可能とされている。しかし、カオスの現象がカオス理論以外の方法を用いて同定し、また短期予測だけではなく長期予測を行い得る可能性が示されたといえる。

次に、風速の予測に関しては、短期予測においてはカオス理論による予測とGMDH理論による予測のどちらも誤差が小さかった。よって、風速予測システムの構築において、カオス理論とGMDH理論のどちらも、短期予測を行う上では有用である。ただし、使用するデータの種類の風速のデータ1種類だけでなく、周辺の風速や気温など、いくつかの関連する、あるいは関連すると思われるデータを数種類収集できるなら、多変数非線形系の同定に長けているGMDH理論の方が有用となるだろう。

今回の研究によって、風速の予測に関してGMDH理論の有用性は示された。しかし、実用のことを考えると、さらに精度の向上を目指すべきである。そこで、今後の課題を以下に挙げる。

- GMDH理論による予測システムにおいて、モデルの推定に用いる式を2次式ではなく、他の多次多項式を用いる。
- 部分表現式の係数を求める際に、回帰分析を行わず、GA (Genetic Algorithm、遺伝的アルゴリズム) を用いる。

以上のことを考慮することにより、より精度の高い風速予測システムの構築が可能になると期待される。

参考文献

- 1) 五百旗頭正・木村孝・合原一幸：決定論的非線形短予測手法の上下水道需要量データへの応用，電気学会論文誌D, vol. 114-D, No.4, pp409-414, 1994
- 2) 伊藤敬祐：カオスって何だろうー予測できないカオスを予測するー，ダイヤモンド社, 1993
- 3) 林勲・田中英夫・大野俊夫・高木不折：ファジィGMDHによるダム貯水池水温の解析と予測，計測自動制御学会論文集, vol.23, No.12, pp1304-1311, 1987
- 4) 林勲：GMDH, 日本ファジィ学会誌, vol.7, No.2, pp270-274, 1995