

非線形回帰モデルとガウシアン関数ネットワークと GAを用いた鹿児島地区電力系統の台風被害予測

高田 等* 柳瀬 三司** 八野 知博*

A PREDICTION METHOD OF TYPHOON DAMAGE TO ELECTRIC POWER SYSTEMS IN KAGOSHIMA VIA NONLINEAR REGRESSION MODEL, GAUSSIAN NETWORKS AND GA

Hitoshi TAKATA , Mitsushi YANASE and Tomohiro HACHINO

Kagoshima Prefecture repeatedly suffers from typhoons which often damage to power systems and cut off electricity. In order to resume speedy normal electricity services, it is necessary to predict accurately the damage which may be caused by typhoons. This paper presents a method for predicting the typhoon damage to power systems by using nonlinear regression model, normalized Gaussian networks and GA. From the weather forecast, we are able to predict the degree of damage to electric distribution lines and poles. The effectiveness of this prediction method is demonstrated by applying it to the actual data.

Keywords: Prediction, Nonlinear regression model, Normalized Gaussian network, GA, Typhoon damage, Power system

1 はじめに

鹿児島県は、多くの台風の通り道に位置するので、台風による電力系統の被害を受けやすい。台風による被害のうち、停電は重大問題である。停電が長時間続くと社会生活に甚大な影響を及ぼし、また電力会社自身も大きな損害となる。それゆえ、停電時間をできるだけ最小に抑えるためには、台風による設備被害を迅速に復

旧させる必要がある。迅速かつ効率的に復旧作業を行うためには、台風被害発生前に設備被害を予め予測し、それに応じた復旧対応人員を被害予測地域に派遣する必要がある。すなわち、設備被害による損害を最小限に抑えるためには、停電時間や復旧にかかるコストを最小限にする必要がある。このため、正確な設備被害予測が必要不可欠になっており、高精度な予測法の開発が望まれている^{1)~3)}。

これまで、台風に関する多くの研究があるが、現在なお台風の正確な気象情報を知ることは困難である。一方、電力系統の設備被害では、様々な要因が考えられる。例えば、雨により水分を多く含み通常より安定度の低い地盤に立っている支持物は、一瞬の強い風が

2002年8月31日受理

* 電気電子工学科

** 博士前期課程電気電子工学専攻

吹くことで倒壊したり，流出する．さらに，強い風により倒された木によっても，電線が断線するなど間接的被害も受ける．このように設備被害はいろいろな要因によって影響を受けるので，その予測が容易でない．

本論文では入手可能な台風の気象情報を基に，電線や支持物等の設備被害を予測する手法について考察した．まず規格化ガウシアン関数ネットワーク (Normalized Gaussian Network) ⁴⁾ により被害予測を行った．その際，ガウシアン関数の形状を決める未知パラメータに対し，遺伝的アルゴリズム (Genetic Algorithm) ⁵⁾ を用いて，被害予測モデルに適した形でのガウシアン関数の準最適化を行った．次に，このモデルによる近似誤差を非線形回帰モデル ⁶⁾ で補正した．本手法は，鹿児島地区電力系統の台風被害予測に適用したが，他の地区でも同様に適用可能なものである．

2 準備

2.1 非線形回帰モデル

入力変数 x を M 個，出力変数 y を N 個としたとき，GMDH 法における入出力関係式で，よく使われる簡単な非線形モデル，2 次の多項式回帰モデルは以下の通りである．

本手法は入力変数 $\{x_j : 1 \leq j \leq M\}$ に対し，2 つの可能な組み合わせ (x_k, x_r) をすべて考えたとき，次式のような 2 次式で与えられる．

$$\begin{aligned} y_i &= A_{kri}^T Z_{kr} + \varepsilon_i \\ &= a_{i0}^{kr} + a_{i1}^{kr} x_k + a_{i2}^{kr} x_r \\ &\quad + a_{i3}^{kr} x_k x_r + a_{i4}^{kr} x_k^2 + a_{i5}^{kr} x_r^2 + \varepsilon_i \end{aligned} \quad (1)$$

ただし，

y_i : 出力変数 ($1 \leq i \leq N$)

x_k, x_r : 入力変数 ($1 \leq k, r \leq M$)

a_{is}^{kr} : 非線形パラメータ

$$A_{kri} = [a_{i0}^{kr}, a_{i1}^{kr}, \dots, a_{i5}^{kr}]^T \quad (2)$$

$$Z_{kr}(p) = [1, x_k, x_r, x_k x_r, x_k^2, x_r^2]^T(p) \quad (3)$$

p : データ数 ($1 \leq p \leq L$)

ε_i : 近似誤差．

(1) 式をベクトル表示すると

$$Y_i = \mathbf{Z}_{kr} A_{kri} + E_{1i}$$

ただし，

$$\begin{aligned} Y_i &= [y_i(1), \dots, y_i(p), \dots, y_i(L)]^T \\ \mathbf{Z}_{kr} &= [Z_{kr}(1), \dots, Z_{kr}(p), \dots, Z_{kr}(L)]^T \\ E_{1i} &= [\varepsilon_i(1), \dots, \varepsilon_i(p), \dots, \varepsilon_i(L)]^T. \end{aligned}$$

ここで評価関数として

$$J = \text{tr}(Y_i - \mathbf{Z}_{kr} A_{kri})^T (Y_i - \mathbf{Z}_{kr} A_{kri})$$

を導入すれば，最小二乗法を適用することで，

$$\frac{\partial J}{\partial A_{kri}} = -2\mathbf{Z}_{kr}^T (Y_i - \mathbf{Z}_{kr} A_{kri}) = 0.$$

よって，非線形パラメータ A_{kri} は，次のように推定される．

$$\begin{aligned} \hat{A}_{kri} &= (\mathbf{Z}_{kr}^T \mathbf{Z}_{kr})^{-1} (\mathbf{Z}_{kr}^T Y_i) \\ &= \left(\sum_{p=1}^L Z_{kr}^T(p) Z_{kr}(p) \right)^{-1} \left(\sum_{p=1}^L Z_{kr}(p) y_i(p) \right). \end{aligned} \quad (4)$$

したがって，非線形回帰モデル式は次のように近似される．

$$\begin{aligned} \hat{y}_i &= \hat{A}_{kri}^T Z_{kr} \\ &= \hat{a}_{i0}^{kr} + \hat{a}_{i1}^{kr} x_k + \hat{a}_{i2}^{kr} x_r \\ &\quad + \hat{a}_{i3}^{kr} x_k x_r + \hat{a}_{i4}^{kr} x_k^2 + \hat{a}_{i5}^{kr} x_r^2 \\ &\quad (1 \leq i \leq N). \end{aligned} \quad (5)$$

2.2 規格化ガウシアン関数ネットワーク

(i) ネットワーク式

規格化ガウシアン関数ネットワークは，RBF とスプライン関数の両方の特徴をあわせもった関数近似の方法である．ネットワークの式は，次のように与えられる．

$$y = \sum_{i=1}^n f_i(\mathbf{x}) \mu_i(\mathbf{x}) \quad (6)$$

$$f_i(\mathbf{x}) = \sum_{j=0}^m \theta_{ij} x_j \quad (7)$$

ただし，

$f_i(\mathbf{x})$: 観測データ各領域の同定モデル，

$\mathbf{x} = [x_1, x_2, \dots, x_m]^T$, $x_0 = 1$,

θ_{ij} : 相関係数，

n : ガウシアン関数の数.

ここに $\mu_i(\mathbf{x})$ は, 次式で与えられる規格化されたガウシアン関数である.

$$\mu_i(\mathbf{x}) = \frac{G_i(\mathbf{x})}{\sum_{j=1}^n G_j(\mathbf{x})} \quad (8)$$

$$G_i(\mathbf{x}) = \prod_{k=1}^m \exp \left\{ - \left(\frac{x_k - c_{ik}}{h_{ik}} \right)^2 \right\} \quad (9)$$

この場合, 各ガウシアン関数は入力データとの近さに応じて出力を受けもつことになり, 入力に近い中心値をもつガウシアン関数は, 関数 $f_i(\mathbf{x})$ で目的の関数を近似する. これにより, 2つのガウシアン関数の間は滑らかに接続されることになる. なお, 同定モデル $f_i(\mathbf{x})$ ($i = 1, 2, \dots, n$) には, 平面, 単調増加, 又は単調減少であるモデルが望ましい. 本手法では同定モデル $f_i(\mathbf{x})$ に線形回帰モデルを用いた. すなわち本関数近似法は, まず全データをプロットし, 入出力値による特質の類似した集団を作り n 個のグループ分けを行う. 次に, 各グループ内は線形回帰 $\{f_i(\mathbf{x})\}$ され, グループ間はガウシアン関数 $\{\mu_i(\mathbf{x})\}$ で結合して構築される.

(ii) 観測データの分割

観測データ $(\mathbf{x}(p), \mathbf{y}(p))$ ($p = 1, 2, \dots, L$) は n 個の領域に分割され, 各領域に同定モデル $f_i(\mathbf{x})$ ($i = 1, 2, \dots, n$) が構築される. その手順を図-1 の例を使って説明する.




図-1 観測データの分割 ($m = 2, n = 3$ の場合)

図-1 において, 中心 (o_{11}, o_{12}) , 半径 r_1 の円内に位置する観測データ $(\mathbf{x}(p), \mathbf{y}(p))$ が $p = 1$ から $p = 5$ までであると仮定する. この領域に与えられる入力データ

\mathbf{x}_{f_1} と出力データ \mathbf{y}_{f_1} は,

$$\mathbf{y}_{f_1}(q) = \sum_{j=0}^2 \theta_{1j} \mathbf{x}_{f_1,j}(q) + e_{f_1}(q) \quad (1 \leq q \leq 5) \quad (10)$$

ただし,

$e_{f_1}(q)$: 近似誤差,

θ_{1j} : 相関係数,

で表される. これをベクトル表示すると,

$$\mathbf{y}_{f_1} = \mathbf{x}_{f_1} \boldsymbol{\theta}_1 + \mathbf{e}_{f_1} \quad (11)$$

ただし,

$$\boldsymbol{\theta}_1 = \begin{bmatrix} \theta_{10} & \theta_{11} & \theta_{12} \end{bmatrix}^T$$

$$\mathbf{x}_{f_1} = \begin{bmatrix} 1 & x_{f_1,1}(1) & x_{f_1,2}(1) \\ 1 & x_{f_1,1}(2) & x_{f_1,2}(2) \\ 1 & x_{f_1,1}(3) & x_{f_1,2}(3) \\ 1 & x_{f_1,1}(4) & x_{f_1,2}(4) \\ 1 & x_{f_1,1}(5) & x_{f_1,2}(5) \end{bmatrix}$$

$$\mathbf{y}_{f_1} = \begin{bmatrix} y_{f_1}(1) \\ y_{f_1}(2) \\ y_{f_1}(3) \\ y_{f_1}(4) \\ y_{f_1}(5) \end{bmatrix} \quad \mathbf{e}_{f_1} = \begin{bmatrix} e_{f_1}(1) \\ e_{f_1}(2) \\ e_{f_1}(3) \\ e_{f_1}(4) \\ e_{f_1}(5) \end{bmatrix}$$

となる. ここで,

$$\mathbf{J} = \text{tr}(\mathbf{y}_{f_1} - \mathbf{x}_{f_1} \boldsymbol{\theta}_1)^T (\mathbf{y}_{f_1} - \mathbf{x}_{f_1} \boldsymbol{\theta}_1) \quad (12)$$

で表される評価関数 \mathbf{J} を $\boldsymbol{\theta}_1$ について微分し零とおくと,

$$\frac{\partial \mathbf{J}}{\partial \boldsymbol{\theta}_1} = \mathbf{x}_{f_1}^T (\mathbf{y}_{f_1} - \mathbf{x}_{f_1} \boldsymbol{\theta}_1) = \mathbf{0}$$

である. よって最小二乗法により求める相関ベクトル $\hat{\boldsymbol{\theta}}_1$ が,

$$\hat{\boldsymbol{\theta}}_1 = (\mathbf{x}_{f_1}^T \mathbf{x}_{f_1})^{-1} (\mathbf{x}_{f_1}^T \mathbf{y}_{f_1}) \quad (13)$$

となる. (13) 式で求めた $\hat{\boldsymbol{\theta}}_1 = [\hat{\theta}_{10} \hat{\theta}_{11} \hat{\theta}_{12}]^T$ を用いた次式を同定モデル $f_1(\mathbf{x})$ の出力

$$f_1(\mathbf{x}) = \sum_{j=0}^2 \hat{\theta}_{1j} x_j \quad (14)$$

とする.

同様に, $i = 2, 3$ の場合も, 分割された観測データから同定モデル $f_2(\mathbf{x})$, $f_3(\mathbf{x})$ をそれぞれ構築する.

結局、最終的に (1) 式に対応したモデル式が

$$\hat{y} = \sum_{i=1}^3 \left(\sum_{j=0}^2 \hat{\theta}_{ij} x_j \right) \mu_i(\mathbf{x}) \quad (15)$$

となる。

(9) 式における、各ガウシアン関数の構造は既知であるが中心値 c_{ik} と幅 h_{ik} 、および各同定モデル $f_i(\mathbf{x})$ の範囲を決めるパラメータ値の o_{ki} と r_i は未知である。これら未知パラメータを遺伝的アルゴリズム (GA) を用いて、準最適に求める。そのアルゴリズムは次の 3.2 節に記載される。

3 被害予測システムの構築

3.1 データ処理

鹿児島県各地区の電力系統に被害を与える台風の要素としては風速と進行経路を、および予測対象としては電線被害実績値と支持物被害実績値を考える。被害予測システムの入力データは台風情報である。しかし台風は時々刻々変化するのでその取り扱いが容易でない。また仮に、的確な入力データが獲得できたとしてもすべての要因を入力すると、必然的にネットワークの規模が大きくなり、計算時間量等の問題が生じる。そこで、本手法では風速の値 x_1 を、鹿児島本土付近の通過台風データの平均とした。また、各地区毎の進行経路評価値 x_2 は次の正規関数により与えた。

$$x_2(p) = \frac{1}{n} \sum_{j=1}^n \exp \left[-\frac{(T_{1j}(p) - \beta_1)^2}{h_1^2} - \frac{(T_{2j}(p) - \beta_2)^2}{h_2^2} \right] \quad (16)$$

ただし、

$T_{1j}(p)$: 台風の中心の緯度、

$T_{2j}(p)$: 台風の中心の経度、

$\beta_1, \beta_2, h_1, h_2$: 正規分布の形状を決定するパラメータ、

n : 台風の進行経路のプロット数。

なお本手法適用の際には、予め、データの規格化が必要である。すなわち観測データ $\mathbf{X}(p), \mathbf{Y}(p)$ ($p = 1, \dots, L$) は単位、最大値、および最小値がそれぞれ異なるため、各要素ごと 0 ~ 1 上への線形変換による規格化を行う。

$$x_k(p) = \frac{X_k(p) - X_{k,\min}}{X_{k,\max} - X_{k,\min}} \quad (17)$$

$$y(p) = \frac{Y(p) - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (18)$$

ただし、

$X_k(p)$: 実観測データ (入力)

$X_{k,\max}$: 入力データの最大値

$X_{k,\min}$: 入力データの最小値

$Y(p)$: 実観測データ (出力)

Y_{\max} : 出力データの最大値

Y_{\min} : 出力データの最小値。

その際、最終的な被害予測モデルの出力 \hat{y} は

$$\hat{Y} = \hat{y} (Y_{\max} - Y_{\min}) + Y_{\min} \quad (19)$$

により被害予測実績値 \hat{Y} に変換される。

3.2 アルゴリズム

本手法で用いた 2.2 節の規格化ガウシアン関数ネットワークの準最適化アルゴリズムは、次の GA を用いて行われる。

step0 : データ規格化

3.1 節により全データを規格化する。

step1 : 初期候補集団の発生

Q 個の二進文字列 (個体) から構成される Ω の初期候補集団 $\{c_{ik}^s, h_{ik}^s, o_{ki}^s, r_i^s : 1 \leq i \leq n, 1 \leq k \leq m\}$ ($s = 1, \dots, Q$) をランダムに発生させる。

step2 : デコーディング

各個体を遺伝子型から表現型にデコーディングする。

step3 : 規格化ガウシアン関数ネットワークの構築

デコーディングされたパラメータ候補値 $\{c_{ik}^s, h_{ik}^s, o_{ki}^s, r_i^s\}$ を用いて第 3 節の方法により、 Q 個の規格化ガウシアン関数ネットワーク候補を構築する。

step4 : 適応度計算

$s = 1, \dots, Q$ に対し各 s 毎、 $\{c_{ik}^s, h_{ik}^s, o_{ki}^s, r_i^s\}$ を用いて目的関数

$$J_s = \frac{1}{L} \frac{\sum_{p=1}^L |y(p) - \hat{y}(p)|}{\sum_{p=1}^L y(p)} \quad (20)$$

を求め、適応度 $F_s = 1/(J_s + 1)$ を計算する。ただし、

$y(p)$: パターン p における出力データ,
 $\hat{y}(p)$: パターン p において, $\{c_{ik}^s, h_{ik}^s, o_{ki}^s, r_i^s\}$ による (10) 式の規格化ガウシアン関数ネットワークの近似出力.

step5: 複製

適応度に比例した選択確率で複製を行う適応度比例戦略を用いる.

step6: 交叉

ランダムに個体のペアを $Q/2$ 個作成し, 交叉確率 P_c で交叉を行う.

step7: 突然変異

突然変異 P_m で個体の遺伝子 (0 あるいは 1) を反転させる.

step8: 繰り返し

以後 step2 ~ step7 をあらかじめ決められた世代数 G に達するまで繰り返し, 集団全体の適応度を高める. 最終的に, 全世代において最も高い適応度を有する個体から, 準最適な規格化ガウシアン関数ネットワークの未知パラメータ $\{c_{ik}, h_{ik}, o_{ki}, r_i\}$ が決定される.

3.3 1 段目予測

2.2 節による未知パラメータの決定に伴い, 規格化ガウシアン関数ネットワークの出力値は, 次のように近似される.

$$\hat{y} = \sum_{i=1}^n f_i(\mathbf{x})\mu_i(\mathbf{x}) \quad (21)$$

ただし, $\mu_i(\mathbf{x})$ は, 式 (8), (9) で表されるガウシアン関数である.

よって, 規格化ガウシアン関数ネットワークの近似誤差 Δy は,

$$\Delta y = y - \hat{y} \quad (22)$$

となる.

3.4 2 段目予測

誤差 Δy を 2.1 節の非線形回帰モデルで近似する. 非線形回帰モデルの入力は, 規格化ガウシアン関数ネッ

トワークと同じ入力変数 (x_1, x_2) を使用する. つまり,

$$Z_{12}(p) = [1, x_1, x_2, x_1x_2, x_1^2, x_2^2]^T(p) \quad (23)$$

を入力とし, 非線形回帰モデルの教師信号は,

$$\Delta y = [\Delta y_1, \dots, \Delta y_i, \dots, \Delta y_N] \quad (24)$$

となる. また, 非線形回帰モデルの入出力関係式は, 次式のようになる.

$$\begin{aligned} \Delta y_i &= A_{12i}^T Z_{12} + \varepsilon_i \\ &= a_{i0}^{12} + a_{i1}^{12}x_1 + a_{i2}^{12}x_2 \\ &\quad + a_{i3}^{12}x_1x_2 + a_{i4}^{12}x_1^2 + a_{i5}^{12}x_2^2 + \varepsilon_i \end{aligned} \quad (25)$$

a_{is}^{12} : 非線形パラメータ

$$A_{12i} = [a_{i0}^{12}, a_{i1}^{12}, \dots, a_{i5}^{12}]^T \quad (26)$$

ε_i : 近似誤差

最小二乗法によって求められた非線形パラメータ \hat{A}_{12i} から非線形回帰モデルの出力値 $\hat{\Delta y}$ が得られる. そして, 提案法の最終的な出力値 $\hat{\hat{y}}$ は,

$$\hat{\hat{y}} = \hat{y} + \hat{\Delta y} \quad (27)$$

となる. 図-2 に提案法の概略図を示す.




図-2 提案法の概略図

4 シミュレーション実験

4.1 実験内容

台風被害シミュレーション実験として, 1988 年から 1997 年までに鹿児島本土に接近した 17 個の台風を対象とし, 年代順に通しの台風番号を付与した. この 17 個の台風気象データを, $L = 16$ 個の観測データと $\hat{L} = 1$ 個のテスト用データに分け, 合計 $\hat{L} = 17$ 通りの予測シミュレーション実験を本被害予測システムから行った. なお本手法 (NEW) と他の手法との比較のため, 規格化ガウシアン関数ネットワークのみを用い

た予測 (NGN) 法, 非線形回帰モデルのみを用いた予測 (NR) 法による実験も同時に行った。

本手法の入力として, 2次元の $\mathbf{x} = [x_1, x_2]^T$ を, 出力としては1次元の $y = [y_1]^T$, または $y = [y_2]^T$ を選んだ。ただし, $x_1[\text{m/s}]$: 風速, x_2 : 進行経路, $y_1[\text{件}]$: 条径間電線被害, および $y_2[\text{本}]$: 支持物被害, とした。表-1は台風気象情報を示す。

2節の規格化ガウシアン関数ネットワークにおいては

入力数 $m = 2$

ガウシアン関数の数 $n = 3$

とし, GA の各パラメータ値を

個体数 $Q = 300$

各個体の二進文字列ビット数 $\zeta = 10$

交叉確率 $P_c = 0.8$

突然変異確率 $P_m = 0.03$

世代数 $G = 30$

選定パラメータ $\Omega = \{c_{ik}^s, h_{ik}^s, o_{ki}^s, r_i^s : 1 \leq i < n, 1 \leq k \leq m\}$ ($s = 1, \dots, Q$) の探索範囲は各要素毎 $0 \sim 1.0$ の範囲内,

とした。これらの各パラメータ値は工学的に妥当と思われるものを試行錯誤的に求めたものである。

図-3.1~3.2に, NR法とNGN法による予測結果, 図-4.1~4.2に, 本手法 (NEW) による予測結果をそれぞれ示す。

表-1 台風気象データ

| 年 | 号 | 台風番号 | 気象データ | |
|----|----|------|-------|--------|
| | | | x_1 | x_2 |
| H1 | 11 | 1 | 40 | 15.214 |
| | 22 | 2 | 30 | 10.375 |
| H2 | 19 | 3 | 50 | 2.393 |
| | 20 | 4 | 35 | 8.868 |
| H3 | 9 | 6 | 40 | 2.902 |
| | 17 | 7 | 40 | 11.434 |
| H4 | 10 | 9 | 40 | 15.201 |
| | 11 | 10 | 30 | 5.592 |
| H5 | 7 | 11 | 45 | 12.263 |
| | 13 | 12 | 50 | 13.335 |
| H6 | 14 | 13 | 35 | 0.888 |
| H7 | 14 | 14 | 35 | 15.446 |
| H8 | 12 | 15 | 40 | 15.011 |
| H9 | 8 | 16 | 35 | 8.788 |
| | 19 | 17 | 40 | 14.286 |




図-3.1 電線被害予測結果 (従来法)




図-3.2 支持物被害予測結果 (従来法)




図-4.1 電線被害予測結果 (提案法)




図-4.2 支持物被害予測結果 (提案法)

4.2 評価

各手法の誤差評価として、4.1節の \hat{L} 回予測シミュレーションを行った実験データ値に対し、各地区の y_i ($i = 1, 2$) に関し、次のような評価関数を導入する。

$$J_i = \frac{\sum_{q=1}^{\hat{L}} |y_i(q) - \hat{y}_i(q)|}{\sum_{q=1}^{\hat{L}} (y_i(q))} \quad (28)$$

ただし、

y_i : 鹿児島地区の実績被害値、

\hat{y}_i : 各手法による予測値。

式(28)を用いた、各手法による電線被害予測評価 J_1 、および支持物被害予測評価 J_2 をそれぞれ表-2に示す。

表-2 絶対平均値誤差

| 評価 | 電線 | 支持物 |
|------|---------|---------|
| NR法 | 0.66136 | 1.09743 |
| NGN法 | 0.44265 | 0.52189 |
| 提案法 | 0.36485 | 0.48969 |

4.3 考察

これらの結果より本手法 (NEW) は他の手法に比べ優れていることがわかる。しかし、表-3から電線被害予測結果と支持物被害予測結果を比べると、支持物被害予測結果の方が平均予測誤差値が大きい。

これらの予測誤差の起因としては、例えば以下が想像される。(1) 本手法の同定モデルは線形であり近似精度や汎化能力に限界がある。(2) 現在使っている入力データ以外にも、台風がもたらした雨量、地形などの影響がある。すなわち、線形回帰モデルと現使用の2種類の入力データでは台風情報と被害値との関係を十分に表現できなかったためと思われる。これらの予測誤差改善にはさらなるモデルの改良や入力データの選定が必要である。

5 あとがき

一般に高精度な予測が難しい鹿児島地区における、台風による電力系統設備被害の予測法について考察した。本手法は、台風の気象情報を入力、設備被害を出力とし、規格化ガウシアン関数ネットワークとGA、非線形回帰モデルを用いて構成されたものである。過去の実データを用いた数値シミュレーション実験により本手法の有効性を確かめた。

これを具体的に実用化する上において、次の検討課題がある。

- 1) 上記本手法の予測精度をさらに向上するために、入力に用いる気象データの選定、入出力データの規格化の改善、および規格化ガウシアン関数ネットワークモデルの改善などがあり、これらは多くの実験により達成できる。
- 2) 台風被害復旧を迅速に進めるに当たって、本手法を各地域ごとに対応したものに詳細化することも必要である。すなわち、地域性特徴も配慮した各営業所ごとの、台風被害予測法の確立である。これは上記手法の拡張として比較的容易に達成できる。
- 3) さらに、設備被害箇所の地点とその被害程度の、より正確な把握が必要である。これはGPS (Global Positioning System), IC, IT技術の有機活用により達成できる。

筆者らは上述課題に関する研究を進めており、詳細については別に報告されるであろう。

参考文献

- 1) 高田 等, 園田 克治, 八野 知博, 実成 義孝:「線形回帰モデルとニューラルネットワークによる鹿児島地区電力配電系統の台風被害予測法」, Journal of Signal Processing, Vol.3, No.6, pp.455-461, (1999)
- 2) 高田 等, 花田 秀幸, 土田 比佐志, 八野 知博, 宮島 廣美:「ニューラルネットワークを用いた鹿児島地区の電力系統台風被害予測」, 第18回SICE九州支部学術講演会, 311, pp.237-238, (1999)
- 3) 高田 等, 柳瀬 三司, 八野 知博, 坂元 均:「電力系統台風被害予測に対しガウシアン関数ネットワークを用いた台風進行経路の改善」, 平成13年度電気関係学会九州支部連合会大会論文集, pp.303, (2001)
- 4) 堀口 剛, 佐野 雅己:「情報数理物理」, 講談社, (2000)
- 5) 北野 宏明:「遺伝的アルゴリズム」, 産業図書, (1993)
- 6) 馬場 則夫, 小島 文男, 小澤 誠一:「ニューラルネットの基礎と応用」, 共立出版, (1994)