GA によるデータ規格化と線形回帰モデルに基づく 電力系統の台風被害予測

正員 高田 等 (鹿児島大学)

非会員 土田 比佐志 (鹿児島大学)

正員 八野 知博 (鹿児島大学)

正員 実成 義孝 (鹿児島大学)

A Prediction Method of Damage by Typhoons to Power Systems via Linear Regression Model based on Normalization of Data by GA

Hitoshi Takata, Member, Hisashi Tsuchida, Non-member, Tomohiro Hachino, Member, Yoshitaka Minari, Member (Kagoshima University)

Typhoons strike Kagoshima district every year and sometimes hit power systems very badly and cut off the electricity. In order to resume normal services as soon as possible, one needs to predict the damage by typhoons accurately. This paper proposes a prediction method of the damage of power systems by using a linear regression model, in which the data on typhoons and harms are efficiently normalized by genetic algorithm. From weather information about the forthcoming typhoon, it enables us to predict the damage of electric lines, poles, and so on. Effectiveness of this prediction method is assured by applying it to the actual data.

キーワード：台風被害，予測，規格化，遺伝的アルゴリズム，線形回帰モデル，電力系統

1. ま え が き

電力系統は毎年台風による被害を被り、特に鹿児島地区配電系統のそれは甚大である。台風に伴う塩害や火山灰による電線設備の碍子汚損に関する研究は多い[1~4]。また台風の風向風速予測に関する研究もある[5]。しかし台風に伴う電線や支持物等の被害量の正確な予測法はない。現状は、過去の台風の瞬間最大風速と被害数との相関関係から、概略的な被害想定を行う被害予測法が用いられているが、高精度な予測は期待できない。

さて一般に、台風により電力系統が大きな被害を受けることがあり、それにより停電が発生することもしばしばである。停電が長時間続くと社会生活に甚大な影響をおよぼし、また電力会社自身も大きな損害となる。迅速な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台風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抑える必要がある。このために正確な設備被害予測が不可欠であり、高精度な予測法の開発が強く望まれている。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[6,7]。また電力系統の設備被害は様々である。例えば、台風時の雨による水分を多く含んだ安定度の悪い地盤に立つ支持物は、一瞬の強風でも倒壊、傾斜、流出する。電線は、強風による直接断線被害や、倒れた木等による間接被害も受ける。このように設備被害はいろいろな要因によって変化し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線形回帰モデルで予測する手法について考察した。その際、入力した台風気象情報や出力の被害量は、それぞれ単位が異なりしかも大きさの範囲が広い。そこで、遺伝的アルゴリズム（以下、GAと記す）を用いて、線形回帰予測に適した形での非線形関数による入出力データの規格化を最適に行った。

本手法を、過去13年間に鹿児島地区に接近した29個の台風に適用し、台風被害予測の計算機シミュレーション実験を行った。その結果、本手法は入出力データの規格化に線形関数等を用いた場合と比べ、極めて良好な結果を与えることが示された。

2. 問題の設定

気象台などから台風情報としては、各台風ごと、その現在位置、予測進路、規模等の気象情報が入手できる。そこで台風被害予測のための入力として、 $x_1[\text{hPa}]$: 中心気圧、 $x_2[\text{m/s}]$: 風速、 $x_3[\text{km/h}]$: 進行速度、 $x_4[\text{km}]$: 暴風半径、 x_5 : 位置などを考える。出力としては $y_1[\text{件}]$: 条径間電線被害件数、 $y_2[\text{本}]$: 支持物被害本数などを選ぶ。これらの入出力データをベクトル表示すれば以下の通りである。

$$x(p) = [x_1(p), x_2(p), \dots, x_M(p)]^T \dots\dots\dots (1)$$

$$y(p) = [y_1(p), y_2(p), \dots, y_N(p)]^T \dots\dots\dots (2)$$

ただし、

p : 台風番号 ($1 \leq p \leq \bar{L}$)

$\bar{L}$: 台風総数

x_j : 気象情報値 ($1 \leq j \leq M$)

y_i : 設備被害値 ($1 \leq i \leq N$)

T : 転置記号

本論文では台風気象情報を入力とし、電線設備被害を出力とする線形回帰予測器を開発する。その際、入出力データの規格化が予測器精度を左右するので、非線形変換規格化パラメータを GA により準最適に選定する。

3. データの改修と規格化

〈3・1〉 データ改修 本論文を通じ、入力数 M をできるだけ少なくして、取り扱いを簡単にするため次のデータ改修を行う。

台風の進行速度は時々刻々変化しているが、入力量 x_3 としては鹿児島地区付近の平均値を用いる。

日本に接近する台風の多くが衰弱期に当たるので、暴風半径は一般に円対称ではない。しかしここでは東半径と西半径の中間値を入力量 x_4 とする。

また台風の位置 x_5 については図 1 に基づいて決定する。まず鹿児島地区を中心として北緯 30 度から 32 度までの間を格子状に区切り、暴風半径の楕円性と被害予測性を配慮して各格子に重みを与える。入力量 x_5 は、北緯 31 度を境とした上段と下段の台風通過位置の値の積を用いる。例えば図 1 内に示す台風 1 の場合、 x_5 は $4 \times 4 = 16$ となり、台風 2 の場合、 x_5 は $3 \times 2 = 6$ となる (表 1 参照)。

次に、入出力データの規格化を行う。この予測のための規格化はできるだけ簡単で効率良いものが好ましい。

図 1 台風通過重み
Fig. 1 Passing weights of typhoons

〈3・2〉 データ規格化 入力 $x_j(p)$ に関して各要素 $x_j(p)$ ($1 \leq j \leq M, 1 \leq p \leq \bar{L}$) ごと、最大値と最小値がそれぞれ +1 と -1 となるような

$$x'_j(p) = f(x_j(p), \lambda_j, m_j) = \frac{1 - \exp\{-\lambda_j(\tilde{x}_j(p) - m_j)\}}{1 + \exp\{-\lambda_j(\tilde{x}_j(p) - m_j)\}} \dots\dots\dots (3)$$

$$\tilde{x}_j(p) = \frac{x_j(p) - \bar{x}_j}{x_{j,\max} - \bar{x}_j} \dots\dots\dots (4)$$

ただし、

- $x_{j,\max} = \max\{x_j(p): 1 \leq p \leq \bar{L}\}$
- $x_{j,\min} = \min\{x_j(p): 1 \leq p \leq \bar{L}\}$
- $\bar{x}_j = (x_{j,\max} + x_{j,\min})/2$
- λ_j : 規格化パラメータ
- m_j : 規格化パラメータ

の入力データ非線形変換関数 $f(x_j(p), \lambda_j, m_j)$ を導入する。これは入力データ $x_j(p)$ の線形変換値 $\tilde{x}_j(p)$ が、さらに $x'_j(p)$ へ非線形変換される。関数の中心値は m_j 、および立ち上がりは λ_j で調整できる。式 (3) の関数は規格化パラメータにより様々な表現ができるものであり、幾つかの例を図 2 に示す。すなわち、各入力変数 $x_j(p)$ ($1 \leq j \leq M$) ごと、異なるタイプの出現分布 (表 1 参照) をもつデータを、シンプルでしかも被害予測に最も適した形に改変したい。このため立ち上がり度 λ_j と中心値 m_j のわずか 2 パラメータの選択で、変換関数を準最適に設定する。

図2 入力データ用非線形変換関数

Fig. 2 Nonlinear modulation function for input data

一方、出力である設備被害値は台風の経路や規模に大きく左右され、値も零から数千までの広い範囲を有する。このような被害無しと被害甚大の両極端の場合を共に有効に予測するものとして、次の非線形変換関数 $h(y_i(p), \kappa_i)$ を導入する。

$$y'_i(p) = h(y_i(p), \kappa_i) = \frac{\ln\{\kappa_i(y_i(p) - y_{i,\min}) + 1\}}{\ln\{\kappa_i(y_{i,\max} - y_{i,\min}) + 1\}} \quad \dots\dots\dots (5)$$

ただし、

$$y_{i,\max} = \max\{y_i(p) : 1 \leq p \leq \tilde{L}\}$$

$$y_{i,\min} = \min\{y_i(p) : 1 \leq p \leq \tilde{L}\}$$

κ_i : 規格化パラメータ

これは各要素 $y_i(p)$ ($1 \leq i \leq N$) ごと、最大値と最小値がそれぞれ +1 と 0 となるようなデータ非線形変換関数であり、 κ_i により、被害なしの $y_i(p) = 0$ 近傍を重視しつつ、大きな値をも比較的効率よく調整できる。式 (5) の関数の幾つかの例を図3に示す。すなわち各出力変数 $y_i(p)$ ($1 \leq i \leq N$) ごと、異なるタイプの出現分布をもつデータを、シンプルでしかも被害予測に最も適した形に変換したい。このため立ち上がり度 κ_i のわずか1パラメータの選択で、変換関数を準最適に設計する。これは κ_i が小さい時は一様に、逆に大きい時は被害零近傍を強く考慮することになる。式 (5) の逆変換 $h^{-1}(y'_i(p), \kappa_i)$ は、

$$y_i(p) = h^{-1}(y'_i(p), \kappa_i) = \frac{\exp[y'_i(p) \ln\{\kappa_i(y_{i,\max} - y_{i,\min}) + 1\}] - 1}{\kappa_i} + y_{i,\min} \quad \dots\dots\dots (6)$$

である。

図3 出力データ用非線形変換関数

Fig. 3 Nonlinear modulation function for output data

これら規格化パラメータ $\{\lambda_j, m_j, \kappa_i\}$ の準最適選定はGAを用いて5節で行う。

以下簡単のため、本論文を通じ (3), (5) 式による規格化後のデータ x', y' を改めて (1), (2) 式の x, y で表記する。

4. 線形回帰モデルによる予測

GAによる準最適な規格化パラメータ $\{\lambda_j, m_j, \kappa_i\}$ 決定後の (3) (5) 式による規格化後データ $\{x'_i(p), y'_j(p)\}$ を用いて、線形回帰モデル予測を行う。図4に本被害予測器の概略図を示す。以下本論文を通じ、学習データ数を L 、およびテスト用データ数を $\tilde{L}$ と記す。

図4 被害予測器

Fig. 4 Predictor of damage

(1), (2) 式の入出力データに対する線形回帰モデルは

$$y_i(p) = \theta_{i0} + \sum_{j=1}^M x_j(p) \theta_{ij} + e_i(p) \quad \dots\dots\dots (7)$$

$$(1 \leq i \leq N)$$

$$(1 \leq p \leq L)$$

ただし、

θ_{ij} : 線形パラメータ,
 $e_i(p)$: 近似誤差,

である。これを行列表現すると,

$$Y = X\Theta + E$$

ただし,

$$Y = \begin{bmatrix} y_1(1) & \cdots & y_i(1) & \cdots & y_N(1) \\ \vdots & & \vdots & & \vdots \\ y_1(p) & \cdots & y_i(p) & \cdots & y_N(p) \\ \vdots & & \vdots & & \vdots \\ y_1(L) & \cdots & y_i(L) & \cdots & y_N(L) \end{bmatrix}$$
$$X = \begin{bmatrix} 1 & x_1(1) & \cdots & x_j(1) & \cdots & x_M(1) \\ \vdots & \vdots & & \vdots & & \vdots \\ 1 & x_1(p) & \cdots & x_j(p) & \cdots & x_M(p) \\ \vdots & \vdots & & \vdots & & \vdots \\ 1 & x_1(L) & \cdots & x_j(L) & \cdots & x_M(L) \end{bmatrix}$$
$$\Theta = \begin{bmatrix} \theta_{10} & \cdots & \theta_{i0} & \cdots & \theta_{N0} \\ \vdots & & \vdots & & \vdots \\ \theta_{1j} & \cdots & \theta_{ij} & \cdots & \theta_{Nj} \\ \vdots & & \vdots & & \vdots \\ \theta_{1M} & \cdots & \theta_{iM} & \cdots & \theta_{NM} \end{bmatrix}$$
$$E = \begin{bmatrix} e_1(1) & \cdots & e_i(1) & \cdots & e_N(1) \\ \vdots & & \vdots & & \vdots \\ e_1(p) & \cdots & e_i(p) & \cdots & e_N(p) \\ \vdots & & \vdots & & \vdots \\ e_1(L) & \cdots & e_i(L) & \cdots & e_N(L) \end{bmatrix}$$

である。評価関数として

$$J = \text{tr}(Y - X\Theta)^T(Y - X\Theta) \quad \cdots \cdots \cdots (8)$$

を導入すれば, 線形パラメータ Θ は, 最小二乗法により

$$\frac{\partial J}{\partial \Theta} = -2X^T(Y - X\Theta) = 0$$
$$\hat{\Theta} = (X^T X)^{-1}(X^T Y) \quad \cdots \cdots \cdots (9)$$

となる。したがって, 線形回帰モデル式が,

$$\hat{Y} = X\hat{\Theta}$$

となる。すなわち任意の入力 $\hat{x}_j$ に関し予測値が

$$\hat{y}_i = \hat{\theta}_{i0} + \sum_{j=1}^M \hat{x}_j \hat{\theta}_{ij} \quad \cdots \cdots \cdots (10)$$
$$(1 \leq i \leq N)$$

となる。

5. GA による規格化パラメータ選定

本節では, GA を用いて (3), (5) 式の $\Omega = \{\lambda_j, m_j, \kappa_i\}$ を準最適に選定する。

λ_j と m_j および κ_i を決定する際にこれらの各々を ζ ビットの二進符号で表し, 結合して一つの文字列を作成する。

$\lambda_j(j = 1, \cdots, M)$ と $m_j(j = 1, \cdots, M)$ および $\kappa_i(i = 1, \cdots, N)$ のデコーディングは

$$\Omega = \frac{x_{\max} - x_{\min}}{2^{\zeta} - 1} A + x_{\min} \quad \cdots \cdots \cdots (11)$$

により実行される。ただし, Ω は規格化パラメータ, $[x_{\max}, x_{\min}]$ は探索範囲, A は規格化パラメータ λ_j と m_j および κ_i に対応する二進符号を十進数に変換したものである。なお, 実用的には工学的観点から, λ_j の探索範囲は $[\lambda_{j,\min}, \lambda_{j,\max}] = [1, 10]$, m_j の探索範囲は $[m_{j,\min}, m_{j,\max}] = [-0.8, 0.8]$, および κ_i の探索範囲は $[\kappa_{i,\min}, \kappa_{i,\max}] = [0.005, 5.0]$ で十分であろう。

具体的アルゴリズムを以下に示す。

〈アルゴリズム〉

step 1: 初期化

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 $\{\lambda_j^r, m_j^r, \kappa_i^r : 1 \leq j \leq M, 1 \leq i \leq N\}$ ($r = 1, 2, \cdots, Q$) をランダムに発生させる。

step 2: デコーディング

(11) 式によりデコーディングを行う。

step 3: 線形回帰モデルの構築

デコーディングされた候補 $\{\hat{\lambda}_j^r, \hat{m}_j^r, \hat{\kappa}_i^r\}$ ($r = 1, 2, \cdots, Q$) より規格化後データを計算し, これらのデータを用いて第4節の方法により, Q 個の線形回帰モデルの候補を構築する。

step 4: 適応度計算

$r = 1, 2, \cdots, Q$ に対し各 r 毎, $\{\hat{\lambda}_j^r, \hat{m}_j^r, \hat{\kappa}_i^r\}$ を用いて目的関数

$$J_r = \frac{1}{NL} \sum_{p=1}^L \sum_{i=1}^N \{|y_i(p) - \hat{y}_i^r(p)|\} \quad \cdots \cdots \cdots (12)$$

ただし,

$y_i(p)$: パターン p における出力データ (i 要素),
 $\hat{y}_i^r(p)$: パターン p において, $\{\hat{\lambda}_j^r, \hat{m}_j^r, \hat{\kappa}_i^r\}$ による (10) 式の線形回帰モデル近似出力 (i 要素),
を求め, 適応度 $F_r = 1/(J_r + 1)$ を計算する。

step 5: 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。

step 6 : 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。

step 7 : 突然変異

突然変異確率 P_m で個体の遺伝子 (0 あるいは 1) を反転させる。

step 8 : 繰り返し

以後 step 2 ~ step 8 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、最適な規格化パラメータが決定される。

6. シミュレーション実験

台風被害シミュレーション実験として、1984 年から 1997 年までに鹿児島本土に接近した 29 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 $\bar{L} = 29$ 個の台風気象データを、 L 個の学習データと $\bar{L}$ のテスト用データに分け、4 節の設備被害予測器から、その被害予測を行った。なお本手法 (NEW) と他の方法との比較のため、5 節の step 1 のみで step 2 以降の GA 操作を省略したときの予測 (NOGA) 法、入出力データを (4) 式タイプの線形変換をしたときの予測 (LINEAR) 法、および規格化操作を省略したときの予測 (NONOR) 法による実験も同時に行う。

線形回帰モデルの入力として、5 次元の $x = [x_1, \dots, x_5]^T$ を、出力としては 2 次元の $y = [y_1, y_2]^T$ を選んだ。ただし、 x_1 [hPa]: 中心気圧, x_2 [km/h]: 進行速度, x_3 [m/s]: 風速, x_4 [km]: 暴風半径, x_5 : 位置, y_1 [件]: 条径間電線被害, y_2 [本]: 支持物被害, とした。表 1 は 3.1 節に従い台風気象情報を整理したものであり、 x_1 から x_4 は 5 刻みデータ値表示である。

5 節の 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 $\zeta = 30$
- 交叉確率 $P_c = 0.8$
- 突然変異確率 $P_m = 0.03$
- 世代数 $G = 100$

とした。これら各パラメータ値は工学的に妥当なものを試行錯誤的に求めた。ここで誤差評価として、 K 個の実験データ値に対し、各 $y_i (i = 1, 2)$ に対し

$$J_{1i} = \frac{1}{K} \sum_{p=1}^K |y_i(p) - \hat{y}_i(p)|$$
$$J_{2i} = \sqrt{\frac{1}{K-1} \sum_{p=1}^K (y_i(p) - \hat{y}_i(p))^2} \dots\dots\dots (13)$$
$$J_{3i} = \frac{\max(|y_i(p) - \hat{y}_i(p)| : 1 \leq p \leq K)}{\max(|y_i(p)| : 1 \leq p \leq K)}$$

なる 3 種類の評価関数を導入する。すなわち J_{1i} は平均誤差評価, J_{2i} は標準偏差形評価, および J_{3i} は最大誤差評価の比較である。ただし y_i : 実績被害値 (TRUE), $\hat{y}_i$: 各手法による予測値である。

表 1 台風気象データ
Table 1 Weather data of typhoons

台風番号	x_1	x_2	x_3	x_4	x_5
1	965	20	40	280	36
2	960	35	45	160	3
3	970	40	25	345	49
4	990	30	20	0	12
5	960	15	40	230	64
6	950	35	40	160	49
7	935	40	45	255	30
8	960	25	40	130	8
9	975	45	30	110	6
10	970	25	35	210	144
11	925	20	50	230	20
12	970	20	35	70	9
13	975	35	30	70	9
14	940	10	40	190	25
15	965	5	30	150	12
16	955	20	40	130	16
17	935	25	50	280	16
18	955	15	40	150	6
19	970	10	30	90	25
20	975	20	30	130	12
21	940	15	45	275	12
22	930	15	50	160	6
23	965	10	35	150	16
24	970	25	35	110	8
25	955	15	40	190	12
26	970	20	35	205	20
27	965	10	35	140	36
28	945	10	45	330	172
29	960	10	40	190	3

表 2 汎化能力
Table 2 Generalization ability

評価		学習誤差	予測誤差
電線被害 y_1	J_{11}	217.38	529.26
	J_{21}	395.60	576.67
	J_{31}	0.3946	0.9282
支持物被害 y_2	J_{12}	67.590	218.69
	J_{22}	139.63	315.95
	J_{32}	0.2489	0.9841

表 3 評価
Table 3 Performance

評価		NEW	NOGA	LINEAR	NONOR
電線被害 y_1	J_{11}	306.41	500.73	564.96	1019.3
	J_{21}	511.47	857.99	808.34	1261.7
	J_{31}	0.3917	0.5926	0.6536	0.6298
支持物被害 y_2	J_{12}	140.51	192.32	242.03	522.81
	J_{22}	272.19	427.85	432.34	653.84
	J_{32}	0.3466	0.8339	0.8123	0.7511

図5 電線被害予測結果

Fig. 5 Prediction results of damage of electric wire

図6 支持物被害予測結果

Fig. 6 Prediction results of damage of poles

図7 最大適応度の推移

Fig. 7 The Best of Fitness versus generation

まず、本手法 (NEW) の汎化能力を調べるため、 $\bar{L} = 29$ 個のうちランダムに $\bar{L} = 9$ 個のテスト用データを選び、残り $L = 20$ 個を学習用データとした。このランダム選択による実験を 20 回繰り返した。よって、(13) 式の誤差評価算出の際、 K は学習誤差に対しては $K = 20 \times 20 = 400$ 、予測誤差に対しては $K = 20 \times 9 = 180$ となる。GA の初期世代をランダムに発生させたときの各種評価値例を表 2 に示す。表 2 では、学習誤差に比べ予測誤差がかなり大きい。さらに学習用データ数を $L = 21 \sim 28$ と増やせば予測誤差評価が改善された。表 3 の NEW は $L = 28$ の場合の予測誤差であり、台風データのさらなる蓄積により L が増えれば、さらに改善されるであろう。

次に、本手法 (NEW) と他の手法 (NOGA, LINEAR, NONOR) との比較実験を行う。 $\bar{L} = 29$ の台風データに対し、テスト用に $\bar{L} = 1$ 個を選び、残り $L = 28$ 個を学習用データとした。よって、テスト用台風の選び方は $\bar{L} = 29$ 種類あり、それぞれについて 10 種類の GA の初期世代をランダムに発生させた。故に実験回数は 29×10 であり、(13) 式の $K = 290$ のときの各手法に対する評価比較を表 3 に示す。

図 5 は電線被害 y_1 の実績値 (TRUE) と各手法 (NEW, NOGA, LINEAR, NONOR) による予測結果の代表例を示す。図 6 は支持物被害 y_2 に関するものである。なお、図 7 は世代に対する最大適応度の推移を示す。世代が進むにつれ最大適応度が増加していることが確認できる。

これらの結果により本手法 (NEW) は他の手法に比べて極めて優れていることがわかる。しかし、台風番号 8, 12, 25 の電線被害予測値などは他の被害予測結果と比べてその誤差が比較的大きい。これらの台風は最大風速も十分大きい状態で鹿児島近傍を通っている。これらの予測誤差の起因としては、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、地形などの影響が考えられる。すなわち、現在の 5 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想像される。これらの予測誤差改善にはさらなる入力データの選定や、入出力変換関数の改良が必要である。

また最大風速との相関のみを用いる現被害予測法からでは、十分な予測結果が期待できない。例えば、台風番号 11, 17, 22 のように最大風速がいずれも $50[\text{m/s}]$ 代であるのに、実績電線被害数がそれぞれ 1700, 200, 4000[件] 代と極めて幅広く、その高精度な推測が極めて難しい。以上より本手法の有効性が確認された。

なお、一回の予測に用いた計算時間は、平均で NEW が $45.0[\text{s}]$ 、NOGA が $0.41[\text{s}]$ 、LINEAR が $1.38[\text{ms}]$ 、NONOR が $1.38[\text{ms}]$ であった (Pentium プロセッサ 600MHz 使用)。

7. まとめ

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、遺伝的アルゴリズム GA を用い線形回帰モデルの予測精度を高めたものである。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。

本論文は台風被害予測問題の基礎的研究と位置づけられる。すなわち、まずデータ改修と規格化を、各変数ごと、少ないパラメータ表現した非線形変換関数の導入と大域的準最適化の GA を使って行う。次にこの改修規格化後データを用い、最も広く認知された手法の一つである線形回帰モデルと最小二乗法を使って、被害予測を行ったものである。さて一般に、データ変換関数は各種存在し、パラメータ選定も GA 以外に他の多くの最適化手法がある。また、線形回帰モデル以外に、非線形回帰モデル、ニューラルネットワーク、ファジィ推論など多くの非線形最適予測手法も存在する。さらに入力データ等の効果的選択と利用法の課題もある、これに対し台風被害予測問題は、各手法にそれぞれ適用可能であると思われる。よって各手法でそれぞれ調べ、最も効率の良い予測手法を探索し構築するのが今後の課題である。また実用化に際しては、復旧対応人員を派遣するための、小地域ごとの被害予測法の確立が要求され、これに関してもさらなる詳細な研究が必要である。

謝 辞

本研究を行うにあたり、各種データの提供と論議を賜った九州電力（株）鹿児島支店の各諸氏に深甚の謝意を表します。

（平成 11 年 12 月 06 日受付，同 12 年 03 月 21 日再受付）

文 献

- (1) 東盛 良夫：「台風接近時のがいしの急速汚損」，電気学会論文誌 B, Vol.113, No.2, pp.177-184, 1993
- (2) 川畑 秋馬，入佐 俊幸，上妻 生朗：「火山灰汚損がいしの漏れ電流特性」，電気学会論文誌 B, Vol.115, No.8, pp.956-963, 1995
- (3) 後藤 聡，中村 政俊，Nishantha Nanayakkara, 谷口 孝：「気象情報に基づく碍子汚損モデルを用いた沿岸変電所碍子洗浄時期に関する考察」，システム制御情報学会論文誌, Vol.11, No.9, pp.491-498, 1998
- (4) Lixin Ma, Shuma Kawabata, Mikio Oda, Hiromi Miyajima : "Diagnosis of Injury by Salt for Distribution Lines by Neural Networks", NOLTA'98, pp.507-510, 1998
- (5) 佐野 清志，鎌野 琢也，安野 卓，鈴木 茂行，北原 隆行：「ファジィ推論とリアルタイム観測データを用いた台風接近時の風速風向予測システム」，日本風工学会誌, No.74, pp.5-14, 1998
- (6) 小倉 義光：「一般気象学」，東京大学出版会，1984
- (7) 和達 清夫：「気象の事典」，東京堂，1954
- (8) 相良 節夫，秋月 影雄，中溝 高好，片山 徹：「システム同定」，計測自動制御学会，1981
- (9) D.E.Goldberg : Genetic Algorithms in Search, Optimization, and Machine Learning, Addison-Wesley Publishing Company, Inc., 1989.
- (10) 北野 宏明：遺伝的アルゴリズム，産業図書，1993.

高 田 等（正員） 1973 年九州大学大学院電気工学専攻博士課程修了。同年九州大学助手，1974 年九州工業大学工学部情報工学科講師，1975 年同助教授，1994 年鹿児島大学電気電子工学科教授となり，現在に至る。非線形システム制御などの研究に従事。工学博士。計測自動制御学会，システム制御情報学会，IEEE 会員。

土 田 比佐志（非会員） 1999 年鹿児島大学工学部電気電子工学科卒業。現在，同大学大学院理工学研究科電気電子工学専攻博士前期課程在学中。システム予測に関する研究に従事。

八 野 知 博（正員） 1996 年九州工業大学大学院電気工学専攻博士後期課程修了。同年鹿児島大学電気電子工学科助手，現在に至る。システム同定に関する研究などに従事。博士（工学）。計測自動制御学会，システム制御情報学会会員。

実 成 義 孝（正員） 1960 年鹿児島大学工学部電気工学科卒業。同年（株）日立製作所入社。1965 年鹿児島大学助手，1992 年同助教授，現在に至る。速度発電機，二軸同期機，電圧形インバータ，電磁界解析，システム制御などの研究に従事。工学博士。