

濃度配慮型GAによる鹿児島県各地区における 電力配電システム台風被害予測法

高田 等* 脇 寿彦** 八野 知博*

A METHOD FOR PREDICTING TYPHOON DAMAGE TO ELECTRIC POWER SYSTEMS IN KAGOSHIMA VIA GA COUNTED CONCENTRATION

Hitoshi TAKATA , Toshihiko WAKI and Tomohiro HACHINO

Kagoshima suffers from typhoons which often damage power systems and cut off electricity. In order to resume speedy normal electricity services, it is necessary to predict accurately the damage which will be caused by typhoons. This paper presents a method for predicting the typhoon damage to power systems by using neural networks, RBF and GA, which is counted the concentration of a group. The weather forecast for the approaching typhoon makes it possible to predict the degree of damage to disconnection for lines, breakage poles, and inclination poles. The effectiveness of this prediction method has been shown by applying it to the actual data.

Keywords: Prediction, RBF, neural networks, GA counted concentration, Typhoon damage, Power system

1. はじめに

日本国内の電力系統設備は台風、洪水、地震のような自然災害により多大な被害を被ることがある。特に鹿児島県は、毎年数個の台風が接近、通過する特殊な地域であり、台風による電力系統設備の被害が甚大な地域でもある。電力系統設備が台風により被害を被ると、停電を引き起こし、停電が長時間続くと民間、企業などの社会生活ばかりでなく、電力会社自身も大き

な損害となる。それゆえに、停電時間をできるだけ最小に抑止めるために台風による設備被害を迅速に復旧させる必要がある。災害時に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被害予測地域に派遣する必要がある。このために、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)~7)}。これまで、台風に伴う塩害や火山灰電線設備による硝子汚損に関する多くの研究がある。また、台風の風向風速に関する研究もある。しかし台風に伴う折損転倒、傾斜、断混線等の被害量の正確な予測法はない。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、台風時の雨による水分を多く含んだ軟弱地盤に立つ支持物は、一瞬の強風でも

2003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

倒壊, 傾斜, 流出することがある。電線は, 強風による直接断線被害と, 飛来物や樹木倒壊などによる間接被害も受ける。市街地, 農村部, 海岸地帯によってもその地域性が顕著に現れる。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, 台風による電力系統設備被害予測問題において, 入手可能な台風の気象情報を基に, 折損-転倒, 傾斜, 断混線等の設備被害値を3階層型ニューラルネットワーク⁸⁾とRBF⁹⁾を用いて予測する手法について考察した。その際, 本ネットワークの最適化に濃度を考慮した遺伝的アルゴリズム (Genetic Algorithm)^{10),11)}を使用した。

2. RBF モデル

基底関数 $g_i(\mathbf{x})$ ($i = 1, 2, \dots, n$) は, m 次元の入力ベクトル \mathbf{x} に対して次のように定義されるスカラー関数である。

$$g_i(\mathbf{x}) = f(\|\mathbf{x} - \mathbf{c}_i\|) \quad (1)$$

ここで, \mathbf{c}_i は基底関数の中心を表すベクトル, $\|\mathbf{x} - \mathbf{c}_i\|$ はユークリッドノルム, f は正規分布関数である。RBF モデルの出力を1次元スカラー y とすると, m 次元から1次元への写像が次の様に与えられる。

$$y(p) = w_0 + \sum_{i=1}^n w_i g_i(\mathbf{x}(p)) + e(p) \quad (1 \leq p \leq L) \quad (2)$$

$$g_i(\mathbf{x}(p)) = \exp \left\{ - \sum_{j=1}^m \left(\frac{x_j(p) - c_{ij}}{h_{ij}} \right)^2 \right\} \quad (3)$$

ただし,

- $\mathbf{x}(p)$: 入力変数 (ベクトル)
- $y(p)$: 出力変数 (スカラー)
- g_i : 基底関数
- h_{ij} : 基底関数の幅
- c_{ij} : 中心位置
- L : 入出力のデータ数
- p : 台風番号

ここで, ベクトル表示すると

$$\mathbf{W} = [w_1, w_2, \dots, w_n]^T$$

$$\Phi = \begin{bmatrix} 1 & g_1(\mathbf{x}(1)) & g_2(\mathbf{x}(1)) & \cdots & g_n(\mathbf{x}(1)) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & g_1(\mathbf{x}(p)) & g_2(\mathbf{x}(p)) & \cdots & g_n(\mathbf{x}(p)) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & g_1(\mathbf{x}(L)) & g_2(\mathbf{x}(L)) & \cdots & g_n(\mathbf{x}(L)) \end{bmatrix}$$

$$\mathbf{Y} = \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(L) \end{bmatrix}, \quad \mathbf{e} = \begin{bmatrix} e(1) \\ e(2) \\ \vdots \\ e(L) \end{bmatrix}$$

となり, 以下の評価関数 \mathbf{J} を導入する。

$$\mathbf{J} = \frac{1}{2} (\mathbf{Y} - \Phi \mathbf{W})^T (\mathbf{Y} - \Phi \mathbf{W}) \quad (4)$$

\mathbf{J} を \mathbf{W} について微分すると,

$$\frac{d\mathbf{J}}{d\mathbf{W}} = \Phi^T (\mathbf{Y} - \Phi \mathbf{W}) \quad (5)$$

となり, 最小二乗法より

$$\frac{d\mathbf{J}}{d\mathbf{W}} = 0 \quad (6)$$

とすれば求める $\hat{\mathbf{W}}$ は,

$$\hat{\mathbf{W}} = (\Phi^T \Phi)^{-1} (\Phi^T \mathbf{Y}) \quad (7)$$

となるので, 最終的にRBFモデルの最適近似出力は

$$\hat{\mathbf{Y}} = \Phi \hat{\mathbf{W}} \quad (8)$$

と表される。

3. 誤差逆伝播法

ニューラルネットワークは, システムの知能化を考える際に極めて有効な技術である。ニューラルネットワークの学習アルゴリズムは, これまでいくつか提案されてきたが, 現在よく活用されているものに誤差逆伝播法がある⁸⁾。

誤差逆伝播法とは, 中間層を有する階層型ニューラルネットワークに用いられる誤差修正法で, ニューラルネットワークの出力と教師信号の差を小さくするようにユニット間を結合している入力-中間層, 中間層間, 中間層-出力層の3種類の重みをそれぞれ修正し, 理想のネットワークに近づけるものである。誤差逆伝播法の概略として, 対象とするニューラルネットの第 p 入力パターンに対する第 $s-1$ 層第 j ニューロンの出

力を y_{jp} , 第 s 層第 i ニューロンの出力を x_{ip} とし, ニューロンの入出力関係が次の式 (9), 式 (10) および式 (11) で与えられているものとする.

$$x_{ip} = h_i(z_{ip}) \quad (9)$$

$$z_{ip} = \sum_j \omega_{ij} y_{jp} \quad (10)$$

$$h_i(x) = \frac{1}{1 + \exp(-x)} \quad (11)$$

ただし, $h_i(\cdot)$ は, シグモイド関数である.

ω_{ij} は, 第 $s-1$ 層第 j ニューロンと第 s 層第 i ニューロンを結ぶ結合強度を意味する. つまり式 (9) と式 (10) は, 第 $s-1$ 層の各ユニットからの出力が重み付けられて第 s 層に達し, 総和され, シグモイド関数などを用いることによって変形され, 第 s 層からの出力となることを示している. いま, 第 p 番目の入力パターンに対する出力層の i 番目のユニットからの出力値を \bar{x}_{ip} とし, 教師信号を d_{ip} とすると, 第 p 番目の入力パターンに対する誤差関数 $E_p(\omega)$ およびすべての入力パターンに対する総誤差関数 $E(\omega)$ は, それぞれ式 (12), (13) で与えられる.

$$E_p(\omega) = \frac{1}{2} \sum_i (\bar{x}_{ip} - d_{ip})^2 \quad (12)$$

$$E(\omega) = \sum_p E_p(\omega) \quad (13)$$

誤差逆伝播法では, ニューラルネットワークの総誤差関数 $E(\omega)$ を最小化するため, 各パターンに関する誤差関数 $E_p(\omega)$ の勾配ベクトルを計算し, その逆方向に ω を改良する最急降下法である. つまり, 誤差逆伝播法では, 総誤差関数 $E(\omega)$ の最小化問題を取り扱うための代用として, 各パターンに対する $E_p(\omega)$ の最小化問題を考えている.

4. 濃度を考慮した GA

本論文では, 適応度を求める際に従来の GA 手法に対し, 集団における濃度を考慮した¹¹⁾. これにより, 従来の GA 手法に比べて局所解に陥りにくいより多様性のある解候補の生成と複数の局所解の効率的な探索が可能になると考えられる. 4.2 節に濃度を考慮した GA における適応度計算について述べる.

4.1 GA の構成手順

GA の一般的手順を以下に示す.

- step1 : 初期候補集団発生
ランダムに M 個の個体を生成して初期集団候補 $P(0)$ を作り, 世代 $g = 0$ とする.
- 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 : 適応度計算
個体集団 $P(g)$ 内の各個体について, その目的関数 J を計算し, J を適応度 F に変換する.
- step4 : 複製
個体集団 $P(g)$ に複製操作を施し, $P'(g)$ を生成する.
- step5 : 交叉
個体集団 $P'(g)$ に交叉操作を施し, $P''(g)$ を生成する.
- step6 : 突然変異
個体集団 $P''(g)$ に突然変異操作を施し, 次世代の個体集団 $P(g+1)$ を生成する.
- step7 : 繰り返し
停止条件を満たさなければ $g = g+1$ として step2 へ. 満たすなら終了し, 全世代で最大の適応度を持つ個体を解とする.

4.2 適応度計算

4.2.1 適応度計算

従来の GA における適応度を \tilde{F}_i とすると, 次式のように表される.

$$\tilde{F}_i = \frac{1}{\beta + J_i} \quad (\beta \geq 0) \quad (14)$$

β は J_i が 0 となる場合も想定して導入した定数であるが, β により適応度関数の傾きを調整することも可能である. さらに, 式 (15) で表される $Y_{i,j}$ を考慮することにより, 従来の GA 手法に対し濃度の概念を導入する¹¹⁾.

$$Y_{i,j} = \frac{1}{1 + H(2)} \quad (15)$$

$H(2)$ は, 二つの個体 i と j の情報エントロピーである. M 個の遺伝子を持つ N 個の個体で遺伝子表現

でき、対立遺伝子が S 個存在するものと仮定すると、個体の遺伝子座 ω の情報エントロピー $H_\omega(N)$ は

$$H_\omega(N) = \sum_{\omega=1}^S -p_{v,\omega} \log p_{v,\omega} \quad (16)$$

で表すことが出来る。ここで、 $p_{v,\omega}$ は、 v 番目の記号が遺伝子座 ω に出現する確率である。したがって、個体遺伝子の平均情報エントロピー $H(N)$ は

$$H(N) = \frac{1}{M} \sum_{\omega=1}^M H_\omega(N) \quad (17)$$

で定義でき、遺伝子の多様性を測定することができる。

4.2.2 個体の濃度

次世代に残る個体 i の適応度 F_i は、従来の GA の適応度 \tilde{F}_i を用いて式 (18) のように表せる。

$$F_i = \frac{\tilde{F}_i}{c_i} \quad (18)$$

ここで、 c_i は個体の濃度を表し、式 (19) で表される。

$$c_i = \frac{1}{N} \sum_{j=1}^N ac_{i,j} \quad (19)$$

ただし、

$$ac_{i,j} = \begin{cases} 1 & Y_{i,j} \geq Tac1 \\ 0 & \text{その他} \end{cases}$$

ここで、 $Tac1$ は類似度のしきい値を示す。

式 (18) は、従来の GA における適応度が高い個体ほど次世代に残る確率が高く、かつ濃度が高い個体ほど次世代に残る確率が低いことを示す。

5. 電力系統台風被害予測システム

5.1 データ処理

鹿児島県各地区の電力系統設備に被害を与える台風情報として風速、進行経路を取り上げ、予測対象として、電力系統設備の折損-転倒、傾斜、断混線の被害値を取り上げた。被害予測システムの入力データは台風情報であり、台風は時間変化するので、的確な入力データとして得ることは難しい。また、獲得できたとしてもすべての要因をシステムの入力とすると、必然的にネットワークの規模は大きくなり、計算時間などが大きくなる。そこで、本手法が用いた風速の値 x_1 は、鹿児島本土付近を通過した台風データの平均値とした。また、台風の進行経路においては、台風の進行

経路をより明確に数値データとして取り扱うために、鹿児島県各地区毎に以下の正規関数により与えた。

$$x_2(p) = \frac{1}{n} \sum_{j=1}^n \exp \left[-\frac{w_i(T_{LAj}(p) - b_{LAi})^2}{h_i^2} - \frac{(T_{LOj}(p) - b_{LOi})^2}{h_i^2} \right] \quad (20)$$

ただし、

T_{LAj} : 台風の中心の緯度、

T_{LOj} : 台風の中心の経度、

$w_i, b_{LAi}, b_{LOi}, h_i$: 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。

5.2 提案法

5.2.1 ネットワークの構築

本手法では、「RBF」と「3階層型ニューラルネットワーク」と「濃度を考慮したGA」を用いてネットワークを構築した。本ネットワークの概略図を図-1に示す。本ネットワークは次のように表される。

$$y_k = \sum_{i=1}^n f_{kipj} \mu_{ki}(\mathbf{x}) \quad (k = 1, 2, 3) \quad (21)$$

$$f_{kipj} = h(z_{kipj}) \quad (22)$$

$$z_{kipj} = \sum_{q=1}^{N_1} w_{kipq} y_{kiqj} \quad (23)$$

ただし、

m : 入力数、

n : 領域分割数、

N_1 : 中間層のニューロンの数、

f_{kipj} : 観測データ各領域のニューラルネットワークによる近似モデル、

$h(\cdot)$: シグモイド関数、

$\mathbf{x} = [x_1, \dots, x_m]^T$ 、

$x_0 = 1$ 、

w_{kipq} : 中間層第 q ニューロンと出力層第 p ニューロンの結合重み、

y_{kiqj} : x_j に対する中間層第 q ニューロンの出力。

また、ガウシアン関数 $\mu_{ki}(\mathbf{x})$ は、次のように表せる。

$$\mu_{ki}(\mathbf{x}) = \frac{G_{ki}(\mathbf{x})}{\sum_{j=1}^n G_{kj}(\mathbf{x})} \quad (24)$$

$$G_{ki}(\mathbf{x}) = \prod_{k=1}^m \exp \left\{ -\left(\frac{x_k - c_{ik}}{h_{ik}} \right)^2 \right\} \quad (25)$$




図-1 本ネットワークの概略図

5.2.2 ニューラルネットワークによる近似モデル

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、各グループ内をニューラルネットワーク f_{kipj} で近似し、グループ間はガウシアン関数 $\mu_{ki}(\mathbf{x})$ で結合して構築される。この際、RBF の調整パラメータ c_{ki} , h_{ki} とニューラルネットワークの中間層のニューロンの数 N_1 は濃度を考慮した GA により準最適に求める。本手法では、まず入力データの大小による領域分割を行う。

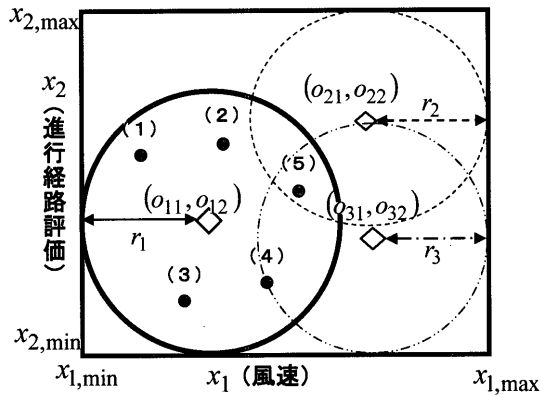


図-2 観測データの領域分割

図-2 に示すように入力データ $(\tilde{\mathbf{x}}(L), \tilde{\mathbf{y}}(L))$ ($L = 1, 2, \dots, M$) を n 個の領域に分割し、各領域毎にニューラルネットワークの近似モデル f_{kipj} ($i = 1, 2, \dots, n$) を構築する。図-2 より、中心 (o_{11}, o_{12}) 、半径 r_1 の円内に位置する観測データ $(\tilde{\mathbf{x}}(L), \tilde{\mathbf{y}}(L))$ が $L = 1$ から $L = 5$ までであるものとする。この領域に与えられる入力データ $\tilde{\mathbf{x}}_{fk1pj}$ と出力データ $\tilde{\mathbf{y}}_{fk1pj}$ は、

$$\tilde{\mathbf{y}}_{fk1p}(L) = f_{k1pj}(L) + e_{fk1p}(L) \quad (1 \leq L \leq 5) \quad (26)$$

$$f_{k1pj}(L) = h \left(\sum_{q=1}^{N_1} w_{k1pq} y_{k1qj}(L) \right) \quad (27)$$

ただし、

$e_{fk1p}(L)$: 近似誤差、

w_{k1pq} : 中間層第 q ニューロンと出力層第 p ニューロンの結合強度、

$y_{k1qj}(L)$: 入力 $\tilde{\mathbf{x}}_{fk1pj}(L)$ に対する中間層第 q ニューロンの出力、

$h(\cdot)$: シグモイド関数、

l : 出力層のニューロンの数。

で表される。誤差逆伝播法の評価関数として、教師信号と出力層の出力値の 2 乗誤差 $E^j(\mathbf{w})$ は、

$$E^j(\mathbf{w}) = \frac{1}{2} \sum_{p=1}^l \left(f_{k1pj} - \tilde{y}_{fk1pj} \right)^2 \quad (28)$$

$$E(\mathbf{w}) = \sum_{j=1}^m E^j(\mathbf{w}) \quad (29)$$

となる。誤差逆伝播法では、ニューラルネットワークの総誤差関数 $E(\mathbf{w})$ を最小化するため最急降下法を用いる。最急降下法では、結合強度ベクトル $\mathbf{w}^{(t)}$ が次の $(t+1)$ ステップにおける結合強度ベクトル $\mathbf{w}^{(t+1)}$ へと変更される。

$$\mathbf{w}^{(t+1)} = \mathbf{w}^{(t)} - \left(\eta \frac{\partial E^j}{\partial \mathbf{w}^{(t)}} + \alpha \Delta \mathbf{w}^{(t)} \right) \quad (30)$$

ただし、

$$\Delta \mathbf{w}^{(t)} = \mathbf{w}^{(t)} - \mathbf{w}^{(t-1)} \quad (31)$$

このとき、

η : 学習係数、

α : 慣性項係数、

$\Delta \mathbf{w}^{(t)}$: t ステップ目における結合強度ベクトル $\mathbf{w}^{(t)}$ の変更量。

このようにして、 \mathbf{w} の値を改良していき、総誤差関数 $E(\mathbf{w})$ の値が十分小さくなるか学習回数が規定回数を満たした時に計算をストップする。そして、計算をストップさせた時点における結合強度ベクトル $\hat{\mathbf{w}}$ を記憶し、 $\hat{\mathbf{w}}$ を結合強度ベクトルとして持つニューラルネットワークモデルを用いることにより、領域 1 における近似モデル f_{k1pj} の出力とする。同様にして、 $i = 2$ の場合と $i = 3$ の場合も、分割された観測データから近似モデル f_{k2pj} , f_{k3pj} を構築する。

6. シミュレーション実験

6.1 実験内容

台風被害シミュレーションとして入力に使用したデータは、1989年から1999年までの鹿児島県本土に接近した19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。鹿児島県本土内を各営業所毎の9地区(出水, 大口, 川内, 加治木, 鹿児島, 志布志, 加世田, 鹿屋, 指宿)に分割した。この19個の台風気象データを用いて学習用18個とテスト用1個に分けた。それをテスト用のデータについて、18個の学習用データから予測を行った。なお本手法(NEW)との比較のため、ニューラルネットワークを用いた予測(NN)法、線形回帰モデルを用いた予測(LRM)法、RBFを用いた予測(RBF)法によるシミュレーション実験も同時に行う。

各々の手法の入力として、2次元の $\mathbf{x} = [x_1, x_2]^T$ を、出力としては、1次元の $\mathbf{y} = [y_1]^T$, $\mathbf{y} = [y_2]^T$, $\mathbf{y} = [y_3]^T$ を選んだ。ただし、 $x_1[m/s]$: 風速, x_2 : 進行経路評価, $y_1[本]$: 折損-転倒, $y_2[本]$: 傾斜, $y_3[件]$: 断混線, とした。

本手法において、

入力数 $m = 2$,

ガウシアン関数の数 $n = 3$,

とした。ニューラルネットワークの各パラメータ値は、

入力層ニューロン数: 2 ユニット,

出力層ニューロン数: 1 ユニット,

学習係数 $\eta = 0.2$,

慣性項の係数 $\alpha = 0.8$,

学習回数: 10000 回

とした。また、GAの各パラメータ値を

個体数 $M = 300$,

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 $G = 30$,


類似度のしきい値 $Tac1 = 0.93$

選定パラメータ $\Omega_1 = \{c_{ik}^s, h_{ik}^s; 1 \leq i \leq n, 1 \leq k \leq m\}$ ($s = 1, \dots, Q$) の探索範囲は各要素毎 0~1.0 の範囲内,


選定パラメータ $\Omega_2 = \{N_1; 1 \leq i \leq n, 1 \leq k \leq m\}$ ($s = 1, \dots, Q$) の探索範囲は 2~10 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。代表と


して、出水地区の台風による被害予測結果を図-3(a)~(c)に示す。



(a) 折損-転倒被害値予測



(b) 傾斜被害値予測



(c) 断混線被害値予測

図-3 出水地区の台風による被害予測結果

6.2 評価

各手法の誤差評価として、6.1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 ($i = 1, 2, 3$) に関し、次のような評価関数を導入する。

$$J_i = \frac{\sum_{q=1}^{\hat{L}} |y_i(q) - \hat{y}_i(q)|}{\sum_{q=1}^{\hat{L}} (y_i(q))} \quad (32)$$

ただし、

y_i : 被害実績値,

\hat{y}_i : 各手法による予測値.

各手法による折損-転倒被害予測評価 J_1 , 傾斜被害予測評価 J_2 , および断混線被害予測評価 J_3 をそれぞれ表-1~表-3 に示す.

表-1 折損-転倒被害予測誤差評価

地区名	NEW	LRM	RBF	NN
出水	0.56	1.85	2.58	2.53
大口	1.14	1.35	2.05	0.88
川内	0.38	1.34	2.19	2.22
加治木	0.68	1.45	2.17	1.87
鹿児島	0.89	1.51	2.32	2.01
志布志	1.13	1.47	1.49	2.04
加世田	0.82	1.36	1.96	1.43
鹿屋	0.93	1.49	1.37	1.85
指宿	0.82	1.20	1.76	1.33
平均	0.81	1.44	1.99	1.79

表-2 傾斜被害予測誤差評価

地区名	NEW	LRM	RBF	NN
出水	0.84	2.23	2.68	2.60
大口	0.99	1.18	2.00	1.35
川内	0.67	1.31	2.01	2.03
加治木	0.84	1.10	1.86	1.48
鹿児島	1.16	1.50	2.07	1.99
志布志	1.04	1.50	1.45	1.68
加世田	0.73	0.86	1.69	1.56
鹿屋	1.35	1.60	1.67	1.85
指宿	0.99	0.99	1.80	1.55
平均	0.95	1.36	1.91	1.79

表-3 断混線被害予測誤差評価

地区名	NEW	LRM	RBF	NN
出水	0.66	1.56	2.36	2.20
大口	1.45	1.32	2.06	1.47
川内	0.58	1.14	2.01	1.97
加治木	0.93	0.99	1.89	1.82
鹿児島	0.77	1.10	1.78	1.76
志布志	1.13	1.36	1.63	1.76
加世田	0.71	0.87	1.57	1.40
鹿屋	1.22	1.48	1.40	1.73
指宿	0.71	0.95	1.46	1.54
平均	0.90	1.20	1.79	1.74

6.3 考察

表-1~表-3の予測誤差評価から、台風による電力系統設備被害予測問題において、提案法が他の手法に比べて有効であることが示された。設備被害としては折損-転倒を対象とした場合が最も予測精度が高く、また傾斜を対象とした場合が予測精度が低いことが分かる。また、提案法における各地区毎の比較をしてみると、同じ手法を用いているにもかかわらず、出水地区と大口地区では予測精度の差が大きいという結果が得られた。その結果として、大口地区では、折損-転倒を対象とした場合、提案法よりもニューラルネットワークを用いた手法の方が予測精度が優れており、また断混線を対象とした場合においても、提案法よりも線形回帰モデルを用いた手法の方が予測精度が優れているという結果が得られた。これらの要因としては、各地域を占める山間部の割合など地形による要因、地域全体の支持物に占める木柱の割合や電線の径間長などの電力系統設備の地域差、今回使用したモデルの近似精度の問題などが挙げられる。今後の課題としては、さらなるモデルの改良と地形、電力系統設備の地域差を考慮した入力データの選定などが必要だと考えられる。

7. あとがき

一般的に、台風による電力系統設備被害値には風速などによる直接的被害や水分を多く含むことによる地盤の安定度の低下などによる間接的被害もあるために、正確な予測は困難であると思われる。そこで、本論文では、「RBF」と「3階層型ニューラルネットワーク」と「濃度を考慮したGA」を用いた鹿児島県各地区毎

の台風による電力系統設備の被害予測法について考察した。過去のデータによる数値シミュレーション実験を行うことにより、提案法の有効性を確かめることができた。

本手法の予測精度をより高めるためには、地形、電力系統設備の地域差を考慮した入力データの選定や、更なる非線形最適予測手法の探索、構築と電力系統台風被害予測問題への適用などが必要だと考えられる。また、これらを具体的に実用化するためには、設備被害箇所と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技術の有機的活用により達成できると考えられる。

著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, 土田 比佐志, 花田 秀幸, 八野 知博, 宮島 廣美:「遺伝的アルゴリズムと線形回帰モデルに基づく電力配電系統の台風被害予測」, 平成 11 年度電気関係学会九州支部連合会大会論文集, p.323, 1999
- 3) 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, pp.237-238, 1999
- 4) 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, p.303, 2001
- 5) 高田 等, 脇 寿彦, 八野 知博, 坂元 均:「鹿児島県各地域における電力系統台風被害の一予測手法について」, 第 20 回 SICE 九州支部学術講演会, pp.231-232, 2001

- 6) 高田 等, 脇 寿彦, 八野 知博, 坂元 均:「電力系統台風被害予測用 RBF ネットワークについて」, 平成 14 年度電気関係学会九州支部連合会大会論文集, p.300, 2002
- 7) Hitoshi Takata, Mitsushi Yanase, Toshihiko Waki and Tomohiro Hachino :
"A Prediction Method of Electric Power Damage by Typhoons in Kagoshima via GMDH and NN", Proceedings of SICE Annual Conference, pp.2423-2428, 2002
- 8) 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
- 9) 堀口 剛, 佐野 雅己:「情報数理物理」, 講談社, 2000
- 10) 北野 宏明:「遺伝的アルゴリズム」, 産業図書, 1993
- 11) 石田 好輝他:「免疫型システムとその応用」, コロナ社, 1998