DA前処理付き大域的構造を持つRBFNの 電力系統事故検出への応用

正員 森 啓之 (明治大) 学生員 青山 光 (明治大)
正員 山中 俊幸 (東京電力) 正員 浦野 昌一 (東京電力)

Application of DA-Preconditioned RBFN with Global Structure to Power System Fault Detection

Hiroyuki Mori, Member and Hikaru Aoyama, Student Member (Meiji University)
Toshiyuki Yamanaka, Member and Shoichi Urano, Member (Tokyo Electric Power Co., Inc.)

In this paper, a hybrid method of data precondition techniques and an artificial neural network (ANN) is proposed to deal with fault detection in power systems. The proposed method makes use of FFT and DA clustering as a precondition technique. FFT is used to extract features of fault currents so that faults to be studied are characterized by frequency domain. DA clustering classifies input data into clusters in a sense of global clustering. DA contributes to the universal clustering that is not affected by the initial conditions. For each cluster, an ANN model is constructed to estimate the location and the type of fault. As ANN, this paper focuses on RBFN (Radial Basis Function Network) due to the better nonlinear approximation. DA clustering is also proposed to determine the centers of RBFN appropriately. Thus, the RBFN model results in one with global structure. The proposed method is successfully applied to a sample system. A comparison is made between the proposed and the conventional methods.

キーワード：事故検出, FFT, ANN, RBFN, クラスタリング, 確定的アニーリング

Keywords : fault detection, FFT, ANN, RBFN, clustering, deterministic annealing (DA)

1. はじめに

本稿では、電力系統における事故に対し、前処理を用いたラジアル基底関数ネットワーク(Radial Basis Function Network, 以下RBFNと略記)による事故検出手法を提案する。事故検出は電力系統の円滑化、コスト削減において重要な課題である。そのため、事故検出手法は高精度でなければならない。この問題に対し、現在まで多くの手法が提案された。代表的な手法として、回路解析に基づいたインピーダンス法⁽¹⁾、パルス法⁽²⁾などがある。しかし、これらの手法は複雑な特徴を持つ事故に対し、良好な結果が得られない。また、参考文献(3)では、事故前後の電圧や電流の基本周波数を評価する手法が提案されたが、事故波形には高調波も含まれるため、高精度な事故検出が行えない。そこでインテリジェントシステムを用いた手法が提案された。Handschinらはエキスパートシステムを事故検出に応用した⁽⁴⁾。しかし、この手法は経験によるデータベースに基づいているため、今までに経験したことのない突発的な状態に対応できない。一方、ニューラルネットワーク(以下、ANNと略記)は優れた汎化能力を持つため、未知のデータに対しても適切に対処できる利点がある⁽⁵⁾。参考文献(5)、(6)ではそれぞれANNの入力データに系統の基準端の電流や電圧の大きさ、サーキットブレーカーやリレーのパターンを用いた。参考文献(7)では、事故電流の波形を把握し、多層パーセプトロン(以下、MLP

と略記)により事故検出を行った。従って本稿では事故検出の推定に対し、ANNの中でも精度が良いと報告されているRBFNを用いる⁽⁸⁻¹¹⁾。しかし、従来提案されたRBFNモデルは基底関数の中心ベクトルの決定に問題があった。そこで本稿では、最適クラスタリングにより基底関数の中心ベクトルを決定し、大域的な構造を持つRBFNを構築する。これにより従来のANNよりも高精度な事故検出の推定を行う。

本稿では、クラスタリング手法として確定的アニーリング(以下、DAと略記)に着目する。DAとは1990年にRoseらによって提案されたクラスタリングの最適化手法である^(12,13)。DAは統計力学の概念により、最適化問題を自由エネルギーの最小化問題として定式化した手法である。この手法はシミュレーテッドアニーリング(以下、SAと略記)と同様に温度パラメータを持ち、これを高温限界から徐々に下げることで最適解を得る。DAは統計力学の概念を利用するため、上記の過程において目的関数が増加し、各温度で確定的に最適化を行うため、初期値に依存せず大域的最適解を得られる。DAクラスタリングは上記の概念を利用したクラスタリング手法である。従来のクラスタリング手法に、K-means法が挙げられる。この手法は高速に計算を行うが、解が初期値に依存する欠点を持つ。一方、DAクラスタリングはK-means法に比べて多くの計算時間を要するが、初期値に依存せず高精度な解を得られる。DAクラスタリングは短期電力負荷予測などに適用され、従来法に対する有効性が報告されている⁽¹³⁾。

さらにRBFNによる推定精度を向上させるために入力データに前処理を施す。図1は事故検出に対する前処理付き推定モデルの概念図を示す。従来の推定モデルは得られる入力データを直接用いるが、入出力関係が複雑であるため、高精度な結果が得られない。一方、提案する前処理付き推定モデルは入力データに前処理を施して推定精度の向上を図る。本稿では入力データとして事故電流を用い、その前処理に高速フーリエ変換(First Fourier Transformation, 以下FFTと略記)⁽¹⁴⁾と入力データを分類するDAクラスタリング手法の2段階を用いる。FFTは事故電流の波形の周波数成分分解を行い、波形の特徴を把握する。他方、DAクラスタリングは入力データを分類し、類似データの抽出を行う。これにより同一のクラスにおけるデータは互いに類似するため、クラス毎にRBFNを構築すれば、RBFNのみの手法に比べ高精度な事故検出が可能となる。提案法を例題系統に適用し、その有効性を確認する。

2. RBFN

本節では、事故検出の推定に用いるRBFNについて述べる。RBFNは、入力空間に配置された複数のラジアル基底関数の線形結合により、任意の関数を近似するネットワークである⁽⁹⁾。図2にRBFNの構造を示す。同図のように、RBFNは入力層、中間層、出力層の3層で構成される。図2において、 $x_1, x_2, \dots, x_m$ は入力データ、 $a_1, a_2, \dots, a_n$ は中間層ユニット

図1 前処理付き推定モデル

Fig. 1. Inference Model with Precondition Technique.

図2 RBFNの構造

Fig. 2. Architecture of RBFN.

の出力、 $w_1, w_2, \dots, w_n$ は中間層と出力層間の重み、 y は出力データを表す。入力データは、入力層のユニットにそれぞれ割り当てられ、重みを1として各中間層に渡される。中間層のユニットは、ラジアル基底関数を含む。ラジアル基底関数は、中心と幅によって定義されるガウス密度関数と同じである。入力ベクトルを $x = (x_1, x_2, \dots, x_m)$ とすると、中間層の i 番目のRBFユニットの出力 a_i は次式で求められる。

$$a_i = \exp\left(-\frac{(x - u_i)^2}{\sigma_i^2}\right) \quad \dots\dots\dots (1)$$

但し、 x : 入力ベクトル、 u_i : i 番目のRBFユニットの中心ベクトル、 σ_i : i 番目のRBFユニットの幅、 a_i : i 番目のRBFユニットの出力

次に出力値 y は、中間層ユニットの重み付けされた出力となり次式で計算される。

$$y = \sum_{i=1}^n w_i a_i(x) \quad \dots\dots\dots (2)$$

但し、 n : 中間層のユニット数(RBF関数)、 y : 出力値、 w_i : i 番目のRBFユニットと出力ユニットとの間の重み

RBFNは入力層と中間層間の重みが1であり、出力が複数のラジアル基底関数の線形結合で表現される点でMLPと異なる。RBFNは非線形近似能力がMLPより優れており、中間層-出力層間の重みのみを学習するため、計算時間が大きく削減される。従って、RBFNを用いることで高精度かつ効率的な事故検出の推定が期待できる。また参考文献(11)では、RBFNの基底関数の中心ベクトル u の決定に対して、クラスタリング手法の1つである K -means法を用いた手法が提案された。この手法は、 K -means法によって得られた各クラス代表をRBFNの基底関数の中心とする。しかし、 K -means法は得られるクラス代表が初期値に依存し、必ずしも最適なクラス代表が求まらないため、RBFNが局所的構造を持つ。そこで本稿では、RBFNの基底関数における中心ベクトル u の決定に、DAクラスタリングを利用する。この手法は、クラス代表が初期値に依存せず、最適なクラスタリングを行う。これにより、大域的構造を持つRBFNを構築できる。

3. クラスタリング

〈3・1〉 クラスタリング クラスタリングとは、あるデータの集合に対し、類似したデータ同士を任意のクラス数に分類する手法である。つまり、クラスタリングは与えられたサンプル数 m のベクトル $x_i (i=1, 2, \dots, m)$ の集合を k 個の代表ベクトル $y_j (j=1, 2, \dots, k)$ を持つクラス $C_j (j=1, 2, \dots, k)$ に分類する処理である。代表ベクトルは、分類された各クラス C_j の中心ベクトルであり、クラスの特徴を表現する。また、クラスタリングは C_j の中心を y_j で近似し、ベクトル x_i との距離の自乗和 d で評価する。 d は次式のような目的関数で表現する。

$$d = \sum_{i=1}^m \sum_{j=1}^k v_{x_i, j} \|x_i - y_j\|^2 \quad \dots\dots\dots (3)$$

但し, d : 誤差基準, $v_{x_i, j}$: x_i の所属状態を表す定数($x_i \in C_j$ ならば1, そうでなければ0), x_i : 与えられたデータベクトル, y_j : クラス j の代表ベクトル, i : データベクトルのサンプル番号, j : クラス番号

(3)式はクラスタリングの目的関数を示し, 誤差基準 d を最小化する。よって, 最適なクラスタリングを行うために誤差基準 d を最小化するような所属状態 $v_{x_i, j}$ とクラス代表 y_j を決定する。

〈3・2〉 確定的アニーリング DAは, 1990年にRoseらによって提案されたクラスタリングの最適化手法である⁽¹²⁾。この手法はアニーリング手法であるため, SAと類似している。両手法とも温度パラメータを持ち, これを高温状態から徐々に下げることで最適解へと収束する。但し, DAは統計力学における自由エネルギーを利用し, 各温度で目的関数を変化させるため, SAと異なる。これにより解の初期値への依存や局所解への陥落を抑制し, 効率的に最適化を行う。図3はDAとSAにおける解の収束過程の違いを示す。同図において縦軸は目的関数を示し, 横軸は状態変数を示す。図3からわかるように, SAは目的関数が一定であり各温度において確

率的に解の移動を行う手法であることにに対し, DAは温度変化のたびに目的関数が増加する手法である。またSAでは, 十分な高温状態において高い確率で解の改悪への移動を許可し, 低温になるにつれてその確率が低くなっていく。従って, 十分な低温状態においてSAの目的関数は収束する。一方DAでは, 十分な高温状態において目的関数が最適解を1つだけもつ簡単な非線形関数になる。従って, 初期値への依存を防止できる。DAはSAと同様に温度を徐々に低下させ, 低温状態になるにつれて目的関数は与えられた元の非線形関数に近づく。これによりDAは十分な低温状態において元の目的関数を得る。さらにDAは各温度において最適化を確定的に行い, 現在の状態から得られた最適解を次の状態の初期解として反復計算を行う。温度変化が小さいほど目的関数の変化も小さくなるため, 高温状態からゆっくりと温度を変化させることにより各温度で確定的な最適化を行う。この操作を繰り返し行うことで, 十分な低温状態において大域的最適解を発見する。

〈3・3〉 確定的アニーリングクラスタリング DAクラスタリングとは, 前述したDAの原理を応用したクラスタリング手法である⁽¹²⁾。K-means法等の従来のクラスタリング手法は, 与えられたデータのクラス j への所属状態が0か1で表現されるため初期値へ依存し, 局所解へ陥る欠点がある。一方, DAクラスタリングはその所属状態に対して確率を利用し, あるデータの複数のクラス j への所属を可能とする。これによりクラスタリング過程において, 各データに対するクラス代表の柔軟な探索を行うため, 従来法に比べ初期値への依存および局所解への陥落を防止できる。従って, (3)式の目的関数における所属状態に確率を導入し, 次式を得る。

$$d' = \sum_{i=1}^m \sum_{j=1}^k P(x_i \in C_j) \|x_i - y_j\|^2 \quad \dots\dots\dots (4)$$

但し, d' : 誤差基準, $P(x_i \in C_j)$: 与えられた i 番目のデータが j 番目のクラス j に所属する確率

DAクラスタリングは, (4)式における所属確率に対し, 最大エントロピーの原理を利用する。これにより各データが全てのクラス j に対し所属可能となる。最大エントロピーを利用した(4)式の所属確率は次式のようなボルツマン分布となる。

$$P(x_i \in C_j) = \frac{\exp(-\beta \|x_i - y_j\|^2)}{\sum_{j=1}^k \exp(-\beta \|x_i - y_j\|^2)} \quad \dots\dots\dots (5)$$

但し, β : 温度の逆数

上式における β はアニーリングアルゴリズムにおける温度の逆数を示し, 各温度において最適化を行う。 $\beta=0$ においては各データが全てのクラス j に均等に所属する。一方, β が増加(温度が低下)するにつれ, 各データが徐々に1つのクラス j に所属し, $\beta=\infty$ においてはある1つのクラス j への所属確率が1となり, 他のクラス j に対してはそれが0となるため, 全てのデータがそれぞれ1つのクラス j に所属する。すなわち

図3 DAとSAの比較

Fig. 3. Comparison between DA and SA.

(3)式で示すクラスタリングの目的関数 d の最小化に等しくなる。統計力学における平衡状態では、自由エネルギーが最小となるため、各温度でクラスタ代表に関して次式を得る。

$$y_j^{(t+1)} = \frac{\sum_{i=1}^m x_i P(x_i \in C_j^{(t)})}{\sum_{i=1}^m P(x_i \in C_j^{(t)})} \dots\dots\dots (6)$$

但し、 t : 反復回数, $y_j^{(t+1)}$: 反復 $t+1$ におけるクラスタ代表

上述したように各温度で確定的にクラスタリングを最適化するために、上式と次式の反復計算を行う。次式は(6)式で得た反復 $t+1$ におけるクラスタ代表から得られる新しい所属確率である。

$$P(x_i \in C_j^{(t+1)}) = \frac{\exp(-\beta \|x_i - y_j^{(t+1)}\|^2)}{\sum_{j=1}^k \exp(-\beta \|x_i - y_j^{(t+1)}\|^2)} \dots\dots\dots (7)$$

以上のように、DAクラスタリングでは温度変化のたびに目的関数が逐次的に変化し、各温度で確定的にクラスタ代表の最適化を行う。以下にDAクラスタリングのアルゴリズムを示す。

- Step 1: 初期温度パラメータ β_0 と収束判定基準 ε を十分小さな正の値とし、温度パラメータの上限値 $\beta_{\max}$ を設定する。
- Step 2: クラスタ代表の初期値を与えられたデータの中から選択する。
- Step 3: (6)式により t における所属確率 $P(x_i \in C_j^{(t)})$ からクラスタ代表 $y_j^{(t+1)}$ を求める。
- Step 4: Step 3で求めたクラスタ代表 $y_j^{(t+1)}$ から(7)式により新しい所属確率 $P(x_i \in C_j^{(t+1)})$ を求める。
- Step 5: (4)式により $d^{(t+1)}$ を評価する。 $|d^{(t+1)} - d^{(t)}| \Delta \varepsilon$ を満たすならStep 6へ。そうでないならばStep 3へ戻る。
- Step 6: $\beta \geq \beta_{\max}$ ならば終了。そうでないならば、 β を増加させStep 3へ戻る。

4. 提案法

本稿では、事故波形の前処理を行い、RBFNを用いて事故検出を行う手法を提案する。図4に提案法の概念図を示す。同図(a)は前述の図1(a)に対応し、従来のANNのみを用いた手法である。図4(b)は図1(b)における前処理付き推定モデルを一般化したモデルである。同図においては m 種類の前処理を行っている。事故波形の特徴を把握する際、時間領域よりも周波数領域の方が特徴をつかみやすい。従って、提案法は事故電流の波形をFFTにより周波数成分分解する。参考文献(14)では、入力データの前処理にFFTを用いて特徴抽出を行い、ANNの1つであるMLPを用いて高調波負荷の分類を行った。しかし、入力データにおいて事故電流の特徴

を示す周波数成分の集合にはばらつきがあり、その中には事故検出と関係の薄いデータも存在する。すなわち得られるデータを全て用いても高精度な結果が得られない。そこで提案法は、図4(c)に示すように、1つ目の前処理としてFFTを用い、2つ目の前処理としてクラスタリングを利用する。クラスタリングにより周波数成分の類似データを分類する。類似データのみを用いてRBFNを構築することで、より高精度な推定結果を得る。本稿では、類似データの分類に大域的なクラスタリング手法であるDAクラスタリングを用いる。図4(d)に提案法の詳細なモデルを示す。同図において、 x は事故波形を表す入力データ、 $C_i (i=1, 2, \dots, k)$ はクラスタ、 $z_i (i=1, 2, \dots, k)$ は事故の位置と種類の推定値、 k は分類後のクラスタ数を表す。図4(d)からわかるように、提案法は入力データが最も類似するクラスタを選択し、そのクラスタのRBFNを用いて推定を行う。さらに本稿では、RBFNにおける基底関数の中心の決定に対してもDAクラスタリングを利用する。これにより大域的なRBFNモデルを構築し、従来のRBFNと比べ高精度な事故検出が期待できる。本稿では、入力データの分類において K -meansとDAを用いた場合を比較する。また、RBFNにおいては基底関数の中心ベクトルの決定にもクラスタリングを必要とするため、その決定に K -meansを用いる K -RBFNとDAを用いる D -RBFNを比較する。そこで本稿は以下の手法を定義する。

- 手法A₁: FFTとMLPを組合せた手法
- 手法A₂: FFTと K -RBFNを組合せた手法
- 手法A₃: FFTと D -RBFNを組合せた手法

図4 提案法の概念図

Fig. 4. Concept of Proposed Method.

- 手法B₁: FFTとK-meansとMLPを組合せた手法
- 手法B₂: FFTとK-meansとK-RBFNを組合せた手法
- 手法B₃: FFTとK-meansとD-RBFNを組合せた手法
- 手法C₁: FFTとDAとMLPを組合せた手法
- 手法C₂: FFTとDAとK-RBFNを組合せた手法
- 手法C₃: FFTとDAとD-RBFNを組合せた手法

図5に提案法のフローチャートを示す。まず、系統における事故電流の波形のデータを作成する。次に、得られた事故電流の波形をFFTにより周波数成分分解し、RBFNの入力データを作成する。さらにDAクラスタリングにより入力データを分類する。ここでDAクラスタリングは学習データを用い、クラスタごとにRBFNを構築する。テストデータの inputs は k 個のクラスタ代表 $y_1, y_2, \dots, y_k$ のうち、距離が最小となるクラスタを選択し、そのクラスタに対応するRBFNにより事故の位置と種類を推定する。

5. シミュレーション

〈5・1〉 シミュレーション条件 シミュレーションは以下の条件で行う。

(i) 例題系統として図6に示す1機無限大母線系統を用いる。ここでは同図の2回線送電線の一方における L_1 点から L_5 点に対し、以下に示す5種類の事故を考える。

(a) 1相地絡事故

図5 提案法のフローチャート
Fig. 5. Flowchart of Proposed Method.

- (b) 2相地絡事故
- (c) 3相地絡事故
- (d) 2相短絡事故
- (e) 3相短絡事故

(ii) 表1は事故の位置におけるANNの教師信号を示す。同表の各行は事故の各位置に対するANNの教師信号を表現する。事故の位置は例題系統における発電機母線から無限大母線までの距離を6等分し、 L_1 点から L_5 点までの5箇所の中の1点とする。従って、教師信号には $1/6(=0.167)$ の倍数を割り当てる。例えば、事故の位置 L_1 点におけるANNの教師信号は0.167となる。次に、表2は事故の種類におけるANNの教師信号を示す。同表の各行は事故の各種類に対するANNの教師信号を表現する。事故の種類は区間[0, 1]を5分割し、それぞれの区間の midpoint に教師信号を割り当てる。例えば、事故の種類が1相地絡事故のとき、ANNの教師信号は0.1となる。また、本稿では事故の種類の推定値を以下のように定義する。

図6 例題系統
Fig. 6. Sample System.

表1 事故の位置の教師信号
Table 1. Target Signals of Fault Location.

事故の位置	ANNの教師信号
L_1	0.167
L_2	0.333
L_3	0.5
L_4	0.667
L_5	0.833

表2 事故の種類の教師信号
Table 2. Target Signals of Fault Types.

事故の種類	ANNの教師信号
1相地絡	0.1
2相地絡	0.3
3相地絡	0.5
2相短絡	0.7
3相短絡	0.9

$$z_T = \begin{cases} 1 \text{ 相地絡事故} (0 \leq z'_T \leq 0.2) \\ 2 \text{ 相地絡事故} (0.2 < z'_T \leq 0.4) \\ 3 \text{ 相地絡事故} (0.4 < z'_T \leq 0.6) \cdots \cdots \cdots (8) \\ 2 \text{ 相短絡事故} (0.6 < z'_T \leq 0.8) \\ 3 \text{ 相短絡事故} (0.8 < z'_T \leq 1) \end{cases}$$

但し、 z'_T : 事故の種類に関するRBFNの推定値
 上式は、RBFNの推定値がある事故の種類に対応する教師信号の ± 0.1 の範囲内であるならば、その種類を認識したと見なす。そのため事故の種類の認識率は次式で与えられる。

表3 MLPとRBFNのパラメータ
 Table 3. Parameters of MLP and RBFN.

手法	n_c	α	η	中間層の数	学習回数
A_1 (MLP)	-	0.8	0.5	92	70000
A_2 (K-RBF)	-	0.1	0.5	40	60000
A_3 (D-RBF)	-	0.1	0.5	40	60000
B_1 (K-means-MLP)	2	0.03	0.5	92	40000
	3	0.03	0.8	92	30000
	4	0.02	0.8	92	30000
	5	0.02	0.8	92	30000
B_2 (K-means-K-RBFN)	2	0.01	0.5	30	30000
	3	0.01	0.5	30	30000
	4	0.01	0.8	20	30000
	5	0.01	0.8	20	30000
B_3 (K-means-D-RBFN)	2	0.01	0.5	30	30000
	3	0.01	0.5	30	30000
	4	0.01	0.8	20	30000
	5	0.01	0.8	20	30000
C_1 (DA-MLP)	2	0.03	0.5	92	40000
	3	0.03	0.8	92	30000
	4	0.02	0.8	92	30000
	5	0.02	0.8	92	30000
C_2 (DA-K-RBFN)	2	0.01	0.5	30	30000
	3	0.01	0.5	30	30000
	4	0.01	0.8	20	30000
	5	0.01	0.8	20	30000
C_3 (DA-D-RBFN)	2	0.01	0.5	30	30000
	3	0.01	0.5	30	30000
	4	0.01	0.8	20	30000
	5	0.01	0.8	20	30000

註) n_c : クラスタ数, α : 学習係数, η : モーメント係数

$$m = \frac{m_c}{m_T} \times 100 (\%) \cdots \cdots \cdots (9)$$

但し、 m : 認識率, m_c : 正しく認識されたデータ数, m_T : 全データ数

(iii) ANNに対する入力データを得るため、検出する状態量は発電機母線の線路電流 I_1 と無限大母線の線路電流 I_2 とする。線路電流 I_1 および I_2 のサンプリング時間を10(μ s)刻みの250(ms)とする。事故発生時刻は、サンプリング開始100(ms)後から0°, 30°, 45°, 60°, 90°遅れの時点とするため、事故発生時刻は5パターンとなる。また事故除去時刻は事故発生から70(ms)後とする。

(iv) FFTにより事故波形の周波数成分分解を施す期間は、上述した70(ms)の間とし、15次まで検出する。従って、2箇所3相電流を検出するのでANNの入力データの次元は90次元となる。

(v) 事故の位置が5箇所、事故の種類が5種類、事故発生時刻が5パターンあるため、入力データは125パターンとなる。そのうち100パターンを学習データ、25パターンをテストデータとする。また、交差検証法として全データのうちの学習データとテストデータの組合せを5通りローテーションさせる。

(vi) RBFNにおいて、基底関数の中心をクラスタリングにより決定し、その幅はクラスタリングにより得られた中心からクラスタ内の最も遠い点までの距離とする。

(vii) 入力データのクラスタリングにおいて、クラスタ数は2, 3, 4, 5とし、クラスタ代表を50通りとする。また初期温度パラメータ β_0 を0.001とし、これを0.001ずつ増加させる。また各温度における収束条件 ϵ を 10^{-4} とし、温度パラメータの上限値 $\beta_{\max}$ を1000とする。

(viii) 表3はMLPとRBFNの学習係数 α 、モーメント係数 η 、中間層の数および学習回数を示す。これらの値は事前シミュレーションにより決定された。

・〈5・2〉 シミュレーション結果 表4はクラスタリングにおける初期値50通りに対する目的関数の最小値、最大

表4 クラスタリングの目的関数
 Table 4. Cost Function of Clustering.

クラスタリング手法	n_c	目的関数			
		最小値	最大値	平均値	標準偏差
K-means	2	7.5066	7.9665	7.7881	2.53×10^{-1}
	3	4.6589	5.6943	4.8086	2.23×10^{-1}
	4	3.0853	4.3218	3.1638	1.41×10^{-1}
	5	2.1598	3.3238	2.3720	1.18×10^{-1}
DA	2	7.1657	7.1662	7.1658	1.76×10^{-3}
	3	4.0071	4.0076	4.0073	1.53×10^{-3}
	4	2.6932	2.6937	2.6935	1.16×10^{-3}
	5	2.1292	2.1298	2.1296	1.13×10^{-3}

註) n_c : クラスタ数

値、平均値および標準偏差を示す。また、図7にクラスタリングの目的関数のグラフを示す。ここでK-meansとDAの目的関数値は、それぞれ前述の(3)式と(4)式を表現する。表4と図7からわかるように、どのクラスタ数においてもDAはK-meansに対し目的関数の最大値、最小値、平均値において良好な結果を得た。特にDAにおいては標準偏差が0に近い値となった。これよりDAが初期値に依存せずに良好な目的関数を得たことがわかる。従って、DAはK-meansに比べ有効なクラスタリング手法であることを確認した。また、両手法ともにクラスタ数の増加に伴い、全ての数値が減少している。これはクラスタ数の増加により、詳細なクラスタリングが行われ、各データとそれが所属するクラスタ代表

間の距離が減少したためである。

表5は事故の位置の推定結果を示す。同表は推定値の絶対値誤差と誤差の標準偏差を示し、絶対値誤差の定義を次式に示す。

$$\varepsilon_d = |z_d - z'_d| \quad (10)$$

但し、 ε_j : 事故の位置の絶対値推定誤差、 z_j : 事故の位置の教師信号、 z'_j : 事故の位置の推定値

まず、入力データの分類を用いない手法Aグループと入力データの分類を用いる手法Bグループ、手法Cグループの比較を行う。推定手法にMLP、K-RBFN、D-RBFNのどれを用いてもそれぞれのクラスタ数において手法Bグループ、手法Cグループが良好な結果を得た。特にDAクラスタリングを

表5 事故の位置の推定結果

Table 5. Inference Results of Fault Location.

手法	n_c	平均誤差(p. u.)	最大誤差(p. u.)	標準偏差
A_1 (MLP)	-	4.513×10^{-2}	1.082×10^{-1}	5.112×10^{-2}
A_2 (K-RBFN)	-	4.521×10^{-2}	1.103×10^{-1}	5.140×10^{-2}
A_3 (D-RBFN)	-	4.162×10^{-2}	1.078×10^{-1}	4.994×10^{-2}
B_1 (K-means-MLP)	2	4.005×10^{-2}	1.016×10^{-1}	4.627×10^{-2}
	3	3.773×10^{-2}	9.648×10^{-2}	4.354×10^{-2}
	4	3.887×10^{-2}	9.795×10^{-2}	4.408×10^{-2}
	5	4.011×10^{-2}	1.029×10^{-1}	4.797×10^{-2}
B_2 (K-means-K-RBFN)	2	4.014×10^{-2}	1.032×10^{-1}	4.866×10^{-2}
	3	3.895×10^{-2}	9.892×10^{-2}	4.416×10^{-2}
	4	3.991×10^{-2}	9.907×10^{-2}	4.432×10^{-2}
	5	4.033×10^{-2}	1.046×10^{-1}	4.824×10^{-2}
B_3 (K-means-D-RBFN)	2	3.626×10^{-2}	9.633×10^{-2}	4.026×10^{-2}
	3	3.045×10^{-2}	8.961×10^{-2}	3.661×10^{-2}
	4	3.161×10^{-2}	9.202×10^{-2}	3.778×10^{-2}
	5	3.740×10^{-2}	9.647×10^{-2}	4.313×10^{-2}
C_1 (DA-MLP)	2	3.628×10^{-2}	9.642×10^{-2}	4.035×10^{-2}
	3	3.159×10^{-2}	8.976×10^{-2}	3.673×10^{-2}
	4	3.243×10^{-2}	9.287×10^{-2}	3.800×10^{-2}
	5	3.831×10^{-2}	9.691×10^{-2}	4.361×10^{-2}
C_2 (DA-K-RBFN)	2	3.631×10^{-2}	9.649×10^{-2}	4.045×10^{-2}
	3	3.160×10^{-2}	8.995×10^{-2}	3.676×10^{-2}
	4	3.251×10^{-2}	9.298×10^{-2}	3.807×10^{-2}
	5	3.850×10^{-2}	9.707×10^{-2}	4.379×10^{-2}
C_3 (DA-D-RBFN)	2	3.517×10^{-2}	9.480×10^{-2}	4.027×10^{-2}
	3	3.008×10^{-2}	8.781×10^{-2}	3.629×10^{-2}
	4	3.102×10^{-2}	8.894×10^{-2}	3.661×10^{-2}
	5	3.522×10^{-2}	9.573×10^{-2}	4.011×10^{-2}

註) n_c : クラスタ数

図7 クラスタリングの目的関数
Fig. 7. Cost Function of Clustering.

用いる手法Cグループは最も誤差を削減した。これよりDAが入力データの分類に有効な手法であることを確認した。またそれぞれの手法において、クラスタ数を3とした場合に最良の結果を得ており、表5に下線で示す。図8に手法グループA, B, Cの推定結果のグラフを示す。同図において、手法Bグループと手法Cグループは最良の結果を得たクラスタ数3における結果を示す。ここでは、それぞれの結果の大きい順に並べた。手法C₃は手法A₃と比較して平均誤差を 1.154×10^{-2} 、最大誤差を 1.999×10^{-2} 、誤差の標準偏差を 1.365×10^{-2} 改善した。しかし、クラスタ数を4つ以上に増加すると推定値の誤差やその標準偏差が大きくなる。これは入力データのクラスタリングにおいて類似データが分類される一方で、各クラスタにおけるデータ数が減少し、推定精度が向上しないためである。よって適切なクラスタ数を選択することで推定誤差を削減できることがわかる。次に、推定手法にMLPを用いる場合とRBFNを用いる場合を比較する。K-RBFNを用いる手法A₂、手法B₂、手法C₂はそれぞれ従来のMLPを用いる手法A₁、手法B₁、手法C₁よりも結果が改善されていない。これはK-meansが初期値に依存し、K-RBFNが局所的構造を持ったためである。一方、D-RBFNを用いる手法A₃、手法B₃、手法C₃は同じ前処理を用いた他の手法と比較

し、推定精度が向上している。中でもクラスタ数3の場合、手法C₃は手法C₁と比較して平均誤差を 1.51×10^{-3} 、最大誤差を 1.95×10^{-3} 、誤差の標準偏差を 4.40×10^{-4} 改善した。またクラスタ数3の場合、提案法の手法C₃は従来のMLPのみを用いる手法A₁と比較して平均誤差を 1.505×10^{-2} 、最大誤差を 2.039×10^{-2} 、誤差の標準偏差を 1.483×10^{-2} 削減した。これより提案法の中でもDAとD-RBFNを組合せた手法C₃が最良の結果を得た。従って、DAにより入力データを分類し、RBFNの構造決定にDAを用いるDA-D-RBFNが、比較手法よりも事故の位置の推定において高精度であることを確認した。

表6は事故の種類の推定結果を示す。同表は事故の種類の

表6 事故の種類の推定結果

Table 6. Inference Results of Fault Types.

手法	n_c	認識率(認識の割合)	平均誤差(p. u.)	標準偏差
A ₁ (MLP)	-	89.6 (112/125)	5.915×10^{-2}	6.879×10^{-2}
A ₂ (K-RBFN)	-	89.6 (112/125)	6.064×10^{-2}	6.935×10^{-2}
A ₃ (D-RBFN)	-	92.8 (116/125)	5.491×10^{-2}	6.357×10^{-2}
B ₁ (K-means-MLP)	2	92.8 (116/125)	5.440×10^{-2}	6.334×10^{-2}
	3	<u>94.4 (118/125)</u>	<u>5.236×10^{-2}</u>	<u>6.114×10^{-2}</u>
	4	94.4 (118/125)	5.256×10^{-2}	6.167×10^{-2}
	5	91.2 (114/125)	5.691×10^{-2}	6.585×10^{-2}
B ₂ (K-means-K-RBFN)	2	92.8 (116/125)	5.358×10^{-2}	6.333×10^{-2}
	3	<u>92.8 (116/125)</u>	<u>5.348×10^{-2}</u>	<u>6.272×10^{-2}</u>
	4	91.2 (114/125)	5.595×10^{-2}	6.544×10^{-2}
	5	91.2 (114/125)	5.831×10^{-2}	6.600×10^{-2}
B ₃ (K-means-D-RBFN)	2	95.2 (119/125)	5.087×10^{-2}	5.911×10^{-2}
	3	<u>96.8 (121/125)</u>	<u>4.790×10^{-2}</u>	<u>5.516×10^{-2}</u>
	4	96.8 (121/125)	4.872×10^{-2}	5.635×10^{-2}
	5	94.4 (118/125)	5.222×10^{-2}	6.090×10^{-2}
C ₁ (DA-MLP)	2	92.8 (116/125)	5.272×10^{-2}	6.206×10^{-2}
	3	<u>95.2 (119/125)</u>	<u>4.942×10^{-2}</u>	<u>5.910×10^{-2}</u>
	4	94.4 (118/125)	5.150×10^{-2}	6.002×10^{-2}
	5	94.4 (118/125)	5.221×10^{-2}	6.082×10^{-2}
C ₂ (DA-K-RBFN)	2	92.8 (116/125)	5.314×10^{-2}	6.223×10^{-2}
	3	<u>94.4 (118/125)</u>	<u>5.172×10^{-2}</u>	<u>6.014×10^{-2}</u>
	4	94.4 (118/125)	5.189×10^{-2}	6.043×10^{-2}
	5	93.6 (117/125)	5.272×10^{-2}	6.201×10^{-2}
C ₃ (DA-D-RBFN)	2	95.2 (119/125)	4.888×10^{-2}	5.877×10^{-2}
	3	<u>97.6 (122/125)</u>	<u>4.659×10^{-2}</u>	<u>5.210×10^{-2}</u>
	4	96.8 (121/125)	4.738×10^{-2}	5.448×10^{-2}
	5	95.2 (119/125)	5.135×10^{-2}	5.925×10^{-2}

註) n_c : クラスタ数

図8 事故の位置の推定結果

Fig. 8. Inference Results of Fault Location.

認識率、絶対値平均誤差および誤差の標準偏差を示す。また、事故の種類の推定における絶対値誤差の定義を次式に示す。

$$\varepsilon_r = |z_r - z'_r| \quad \dots\dots\dots (11)$$

但し、 ε_r : 事故の種類の絶対値推定誤差、 z_r : 事故の種類の教師信号、 z'_r : 事故の種類の推定値

同表における認識率は前述の(9)式を示し、括弧内の数値は全テストデータのうち正しく認識されたデータ数を表現する。まず、入力データのクラスタリングを行わない手法Aグループとクラスタリングを行う手法Bグループ、手法Cグループの比較を行う。表6からわかるように、入力データのクラスタリングにDAを用いる手法Cグループが同じANNを用いる他のグループと比較し、認識率が向上し、平均誤差と誤差の標準偏差が削減された。特にクラスタ数を3とした場合、どの手法においても他のクラスタ数に比べて認識率、平均誤差および誤差の標準偏差を改善し、表6においてクラスタ数3の結果を下線で示した。図9は手法Aグループから手法Cグループの推定結果のグラフを示す。同図において、手法Bグループと手法Cグループは最も結果が良かったクラスタ数3における結果を表現する。ここでは、事故の種類の認識率は小さい順に、平均誤差と標準偏差は大きい順にグラフを

図9 事故の種類の推定結果

Fig. 9. Inference Results of Fault Types.

並べた。手法C₃は手法A₃、B₃と比較してそれぞれ認識率を4.8%, 0.8%, 平均誤差を 8.32×10^{-3} , 1.31×10^{-3} , 誤差の標準偏差を 1.147×10^{-2} , 3.06×10^{-3} 改善した。しかし、クラスタ数を4つ以上に増加すると事故の種類の認識率が向上せず、平均誤差と誤差の標準偏差が減少しない。これも前述における事故の位置の推定と同様に、各クラスタにおけるデータ数が減少し、推定精度が向上しないためである。よって、事故の種類の推定においても適切なクラスタ数を選択することにより推定誤差の改善が確認できた。次に、推定手法にMLPを用いる場合とRBFNを用いる場合を比較する。K-RBFNを用いる手法A₂、手法B₂、手法C₂はそれぞれMLPを用いる手法A₁、手法B₁、手法C₁と比較して、それぞれのクラスタ数において認識率は同等であるが、平均誤差と誤差の標準偏差が大きくなっている。これもK-RBFNが構造決定にK-meansを用いており、局所的構造を持ったためである。一方、D-RBFNを推定手法に用いる手法A₃、手法B₃、手法C₃は同じ前処理を用いた他の手法と比べ、それぞれのクラスタ数において認識率、平均誤差および誤差の標準偏差が改善されている。特にクラスタ数3の場合、手法C₃は手法C₁と比較して認識率が2.4%向上し、平均誤差を 2.83×10^{-3} , 誤差の標準偏差を 7.0×10^{-3} 削減した。特にDAとD-RBFNを用いる手法C₃がクラスタ数3の場合において認識率を97.6%, 平均誤差を 4.659×10^{-3} , 誤差の標準偏差を 5.210×10^{-3} とした。以上より事故の種類の推定において、入力データの分類にDAを用い、推定手法にD-RBFNを用いる手法C₃が比較手法中最も高精度な推定を行った。

6. まとめ

本稿は電力系統における事故検出に対し、入力データの分類にクラスタリングを用い、大域的構造を持つD-RBFNを提案した。提案法を例題系統に適用してシミュレーションを行い、以下の結果を得た。

(i) 提案法は、入力データの前処理として事故波形の特徴把握にFFTを用い、類似データの分類にクラスタリングを用いることを提案した。その分類機能を向上させるためにDAを提案した。また、推定手法にANNの中でも非線形近似能力がよいとみなされているRBFNを適用した。その性能を一層向上させるためにD-RBFNを提案した。

(ii) 本稿は、入力データの分類にK-meansを用いる手法Bグループと、入力データの分類にDAを用いる手法Cグループを提案した。手法Aグループから手法Cグループを比較した結果、入力データの分類にDAを用い、RBFNの構造決定にDAを用いる手法C₃が最も良好な結果を得た。

(iii) 提案法は、事故の位置の推定において、従来のMLPと比較して平均誤差を 1.505×10^{-2} , 最大誤差を 2.039×10^{-2} , 誤差の標準偏差を 1.483×10^{-2} 削減した。また、提案法は事故の種類の推定において、認識率を97.6%, 平均誤差を 4.659×10^{-3} , 誤差の標準偏差を 5.210×10^{-3} とした。特に、提案法は従来のMLPと比較し、事故の種類の認識率を8.0%, 平均誤差を 1.256×10^{-2} , 誤差の標準偏差を 1.669×10^{-2} 改善した。

以上より、大域的クラスタリングを行うDAクラスタリングは入力データの分類およびRBFNの構造決定に適しており、比較手法よりも事故検出に対して有効であることを確認した。

謝辞

本研究の一部が明治大学ハイテクリサーチセンターの助成を受けて行われたことに感謝する。

(平成14年2月28日受付, 平成14年7月16日再受付)

文 献

- (1) T. Takagi, et al.: "Development of a New Type Fault Locator Using the One-terminal Voltage and Current Data," *IEEE Trans. PAS*, **PAS-101**, No. 8, pp. 2892-2898 (1982-8)
- (2) A.O. Ibe and B.J. Cory, "Traveling Wave-based Fault Locator for Two and Three Terminal Networks," *IEEE Trans. Power Syst.*, **1**, No. 2, pp. 283-288 (1986)
- (3) A.A. Girgis, et al.: "A New Fault Location Technique for two-three terminal lines," *IEEE Trans. Power Deliv.*, **7**, No. 1, pp. 98-107 (1992)
- (4) E. Handschin, et al.: "Knowledge Based Alarm Handling and Fault Location in Distribution Networks," *IEEE Trans. Power Syst.*, **7**, No. 2, pp. 770-776 (1992-5)
- (5) K.-H. Kim and J.-K. Park: "Application of Hierarchical Neural Network to Fault Diagnosis of Power System," *Proc. of ESAP'91*, pp. 323-327, Tokyo/Kobe, Japan (1991-4)
- (6) A.J. Mazon, et al.: "New Approach to Fault Location in Two-terminal Transmission Lines Using Artificial Neural Networks," *Elec. Power Syst. Res.*, **56**, No. 3 pp. 261-266 (2000-12)
- (7) H. Mori and H. Aoyama: "A Preconditioned Pattern Recognition Technique for Fault Diagnosis," *Proc. of the 12th Annual Conference of Power and Energy Society, IEE of Japan, Session II*, No. 182, pp. 566-567, Sendai, Japan (2001-8) (in Japanese)
森・青山: 「前処理を用いた故障診断のためのパターン認識法」, 平成13年電気学会電力・エネルギー部門大会, 論文II, No. 182, pp.566-567 (2001-8)
- (8) M.J.D. Powell, "Radial Basis Functions for Multivariable Interpolation: A Review," in J. C. Mason and M.G. Cox (Eds.), *Algorithms for Approximation of Functions and Data*, pp. 143-167 Oxford Univ. Press, UK (1987)
- (9) H. Mori and S. Urano: "Deterministic Prediction for Short-term Power System Load Forecasting," *Proc. of the 5th Annual Conference of Power and Energy Society, IEE of Japan, Session II*, No. 253, pp. 103-104 (1994-7) (in Japanese)
森・浦野: 「決定論的予測手法を用いた電力系統における短期負荷予測」, 平成6年電気学会電力・エネルギー部門大会, 論文II, No. 253, pp.103-104 (1994-7)
- (10) H. Mori and S. Urano: "RBFN Based Short-term Load Forecasting with Considerations of Chaos of Electric Power Loads," *the Papers of Joint Technical Meeting on Power Engineering, IEE of Japan*, PE-94-49 (1994-10) (in Japanese)
森・浦野: 「電力需要のカオス性を考慮したRBFネットワークによる短期負荷予測」, 電気学会電力技術研資, PE-94-49 (1994-8)
- (11) D.K. Ranaweera, et al.: "Application of Radial Basis Function Neural Network Model for Short-term Load Forecasting," *IEEE Proc.-Gener. Transm. Distrib.*, **142**, No. 1, pp. 45-50 (1995-1)
- (12) K. Rose, et al.: "Deterministic Annealing Approach to Clustering," *Pattern*

Recognition Lett., **11**, No. 9, pp. 589-594, North-Holland (1990-9)

- (13) H. Mori and A. Yuihara: "Deterministic Annealing Clustering for ANN-Based Short-term Load Forecasting," *IEEE Trans. Power Syst.*, **16**, No. 3, pp. 545-551 (2001-8)
- (14) H. Mori and H. Uematsu: "Artificial Neural-Net Based Classification of Harmonic Loads," *T. IEE Japan*, Vol. 111-B, No. 7, pp. 757-763 (1991-7) (in Japanese)
森・植松: 「ニューラルネットによる高調波負荷の分類」, 電学論B, **111**, 7, pp. 757-763 (1991-7)

森 啓之 (正員) 1985年3月早稲田大学院博士課程修了。工学博士。早稲田大学助手, 明治大学助手, 助教授を経て, 1995年10月同教授, 現在に至る。その間, 1994年3月~1995年4月米国コーネル大学電気工学科客員準教授。電力系統の系統解析, インテリジェントシステムの研究に従事。IEEE, INNS, AAAI, ACM, SIAM会員。

青山 光 (学生員) 2001年3月明治大学理工学部電気電子工学科卒業。同年4月より同大学大学院博士前期課程進学, 現在に至る。主として電力系統事故検出, ニューラルネットワークの研究に従事。電気学会学生員。

山中 俊幸 (正員) 1981年3月東京大学工学部電気工学科卒業。同年4月東京電力株式会社入社。現在, 同社技術開発本部技術開発研究所に勤務。主として, 電力系統の系統解析, 送電系統の事故点標定の研究に従事。電気学会正員。

浦野 昌一 (正員) 1996年3月明治大学大学院理工学研究科電気工学専攻博士前期課程修了。同年4月東京電力株式会社入社。現在, 同社技術開発本部技術開発研究所に勤務。主として, 電力系統のシミュレーターの開発, 送電系統の事故点標定の研究に従事。電気学会正員。

電力・エネルギー部門大会座長のコメントと回答

—A14 系統保護制御—

質 疑

座長 尾畑 義雄

1. 同セッションでの対象論文への質疑応答

- (1) 本研究を行うことになった背景は？
- (2) 実機 (FL と思われるが) においても、シミュレーション時間と同程度の時間と考えてよいのか？

2. 著者に照会したい座長コメント

他方法との論理的な比較により、本提案法の妥当性を立証している。今後は、実機への適用を前提としたアプローチを期待する。

応 答

森 哲之・青山 光 (明 治 大)
山中 俊幸・浦野 昌一 (東京電力)

1. 「同セッションでの質疑応答」に対する追加説明

- (1) 現在、電力系統における事故の位置と種類を適切に推定することが重要な課題となっている。特に、山間部における長距離送電線の事故が発生した場合、事故の位置と種類を推定することは困難である。そこで、計算機を使用して高精度に事故検出を行う手法が要求されている。
- (2) 本論文では、シミュレータにより作成されたデータを用いて計算機シミュレーションを行った。実機において同様のデータが与えられた場合、計算時間はシミュレーション時間と同程度であると考えられる。