影響力の競合を考慮した競合学習型ネットワークと 電子部品の故障診断への応用*

長 山 格^{*1}

Diagnosis of Electric Parts by Using Competitive Self-Growing with Confidential Voting

Itaru NAGAYAMA^{*2}

^{*2} University of the Ryukyus, Faculty of Engineering,
1 Senbaru, Nishihara, Nakagami, Okinawa, 903-0213 Japan

This paper describes a new approach for competitive self-growing neural network and its application to fault diagnosis of electric parts using image analysis. Conventional competitive network such as RCE network proposed by Cooper et. al. has a greenhand for its decision making process. Thus, we introduce the confidential voting process in order to avoid the ambiguous decision making in the network. Reliability of electric product is evaluated with some average properties such as the Mean Time To Failure. However, if we can find an efficient method for fault diagnosis of individual electric product, the more efficient maintenance and quality control can be performed. The basic concept of this study is that the performance degradation of carbon film resistor can be efficiently estimated from their images using the proposed method. We first discuss some essential issues to be considered in reliability problems. Experimental results by using the proposed competitive network with confidential voting are also described. It is shown that the network gives a good performance.

Key Words: Competitive Learning, Fault Diagnosis, Neural Network, Electric Parts

1. 結 言

パターン認識問題は、非常に広範な応用範囲を持つため故障診断や画像解析など多くの分野で活用されている。従来、工業・科学計測分野では、異常の早期発見のため画像による外観検査が実施されてきた。例えば、金属の破壊形態を検査するため破壊表面のテクスチャを画像解析し、金属破断組織の分類判定を行うもの、超音波探傷エコーを対象とし溶接部のひびわれや溶接不良などの欠陥を検査するもの、はんだ接合形状の良否を濃淡画像とニューラルネットワークで行うもの等がある⁽¹⁾⁻⁽³⁾。一般に、外観検査システムでは、対象物の形状測定や異常の検出が行われており、パターン認識を自動化することで生産工程の効率化・コスト低減を実現している。そのため、ファジィ推論、ニューラルネット、論理AI等の様々な知的情報処理技術の応用が図られ、優れた効果をあげている。ところが、一般に画像データは、同一条件で連続撮像した場合でも全く同一のデータとはならないことが知られている⁽⁴⁾。すなわち、撮像画像の安定性・変動が処理結果に大きな影響を与えるため、

これらの変動を吸収できる適応型の処理アルゴリズムが重要な役割を果たす。適応的な学習を可能にするシステムとしてファジィ推論やニューラルネットワーク等が知られており、論理AIと比べてパターン情報処理に優れている⁽¹⁵⁾⁽¹⁶⁾。従って、対象データの変動を吸収しつつパターン識別を行う処理に適しているが、一般にBP等の逐次学習プロセスは所要時間が長くなる傾向がある。これに対し、特徴空間を量子化してパターン分類を行う量子化学学習プロセスは、比較的高速な学習とパターン分類が可能である⁽⁸⁾⁻⁽¹²⁾。特にCooperらによって提案されたRCE(Restricted Coulomb Energy)競合学習モデルは⁽⁸⁾、多数の量子化ニューロンから構成される構造であり、入力パターンの分類学習を効率的に実行できるという特徴がある。また、計算アルゴリズムが簡潔であり、特徴空間を量子化してカテゴリ分類するため、様々な分野での応用が可能である。ところが、CooperらによるRCEモデルは、精度の高いパターン分類のためには多数の量子化ニューロンが必要であること、また、量子化領域に含まれない新規入力パターンに対しては分類不能となるケースがある等の問題点がある。これらの問題点は、RCEモデルにおいてパターン分類能力の低下を招く要因となる。本論文では、上記の問題に対して、量子化ニューロンの影響力を考慮する投票プロセスを導入した競合ネットワ

* 原稿受付 2000 年 3 月 13 日。

^{*1} 正員、琉球大学工学部(〒903-0213 沖縄県中頭郡西原町千原1)。

ークモデルを提案する。これにより、従来のRCEモデルで生じていた問題点を改善でき、従来のRCEモデルよりも高精度なパターン分類が実現できることを示す。また、投票プロセスを伴わない最大値選択戦略についても検討した。

一方、コンピュータや計測器などの電子機器で使用されている半導体LSI、ダイオード、抵抗器などの部品は、その定格や性能基準内で正確に動作することが要求される。しかし、使用負荷、寿命、経年劣化や過電圧・過電流による破壊等によって性能が徐々に劣化し、ついには故障状態へ到る。従来の信頼性推定では、平均故障時間(MTTF)等によって平均的な信頼性を保証してきた。しかし、これらの指標は、多数の部品の故障に関する平均的な目安を与えることはできるが、個々の部品や個々の製品の故障を判断することは依然として容易ではない。従って、個々の部品・製品に対する信頼性評価や故障の診断・早期発見を高精度に実現すれば、メンテナンスの高効率化や高精度な保全管理、コスト低減の実現が期待される⁽⁵⁾⁻⁽⁷⁾。

本論文では、信頼度投票プロセスを導入した新しい競合ネットワークを用いて、電子部品故障の診断を行う。実際の測定値に基づく故障結果と本手法による故障診断結果、および従来のRCEネットワークを比較し、提案する競合ネットワークの有効性を示す。また、信頼度処理に関して最大値選択戦略を用いた場合についても比較検討する。

2. 部品故障と競合学習

2.1 抵抗器の劣化と故障 図1に炭素皮膜抵抗器の外観を示す。炭素皮膜抵抗器を覆う塗装被膜部分は合成樹脂を塗布したものであり、抵抗器内部を湿気から保護するとともに、簡易絶縁状態を維持する働きがある。中心部はセラミック基体であり、その表面に炭素を熱分解析出することにより抵抗被膜としている。この抵抗被膜に適当な溝切りを施すことによって所定の抵抗値を実現することができる。後述される故障抵抗器の外観から明らかに、抵抗器は劣化とともに生じる焼焦によって塗装皮膜部分が焼滅し、らせん状の溝切り抵抗部分が露出される。通常使用している場合においても、発熱に伴う熱酸化により炭素が酸化ガス発散し、抵抗値の増大を招くことがある。一般に抵抗器はストレス負荷によって発熱し、その抵抗値が徐々に上昇する。抵抗値が上昇すると、定格値として設計された定格抵抗値の許容範囲を逸脱するので、正常な使用に適さないと見なされる。例えば、定格抵抗330Ω、許容誤差5%の抵抗器は、330±16.5Ωまでの許容値を有するものとして設計されているため、抵抗値上昇により346.5Ωを越えると故障したと見なすことができる。炭素皮膜抵抗器は信頼性試験によって急速に劣化する。同時に、その劣化に伴って電流負荷による発熱を生じ、炭素皮膜の变成・焼焦が起こる。収縮・変化が生じ抵抗器の形状

Fig.1 A carbon filmed resistor.

が退縮変形する。試験時間の経過によって最も大きく現れる外観上の変化は変色であり、正常状態から焦げ茶色・黒色へと変化する。従って、ある抵抗器の画像からその抵抗器が故障しているかどうか判定することができれば、非接触画像計測による故障診断が可能になるため人的・時間的コストの低減に有用である。

2.2 自己組織競合学習 提案する信頼度投票型競合学習ネットワークは、教師あり学習に基づくパターン分類器であり、増殖する競合ニューロンからなる階層構造を持つ。その基本モデルであるRCEネットワークは、Cooperらによって示されており⁽⁸⁾、学習によって適応的にニューロンを増殖させ、同時に各ニューロンの結合重みを自己組織的に学習成長させていくことができる。すなわち、入力ベクトル空間をカテゴリー毎に分割する非線形識別境界を多数の量子化ニューロンによって形成する。識別時には、入力ベクトルと各ニューロンの結合重みとの類似度を計算し、最も近い類似度を示したニューロンの属するカテゴリーに分類する。出力層の各ニューロンはそれぞれのカテゴリを代表し、中間層ニューロンは量子化ニューロンとして機能するとともに学習により増殖されていく。いまk番目の入力データ x_k が与えられると、j番目の中間層ニューロンの出力値 y_j は次式により計算される。

$$y_j = \text{sgn} \left[\lambda_j - \sqrt{\sum_{i=0}^{N-1} (x_{ki} - w_{ji})^2} \right] \quad \dots (1)$$

ここで、 x_{ki} はk番目の入力データ x_k のi番目の要素、 w_{ji} はi番目の入力層ニューロンからj番目の中間層への結合重みである。すなわち、入力ベクトル空間において入力データ x_k とj番目の中間層ニューロンの結合重みベクトル w_j との距離がしきい値 λ_j よりも小さいときに、j番目の中間層ニューロンの出力 y_j は1となり、 λ_j より大きい時には0となる。出力が1となった中間層ニューロンがあると、そこから接続されている出力層ニューロン z_m の出力が1となる。ここで、入力データ x_k の属するカテゴリと出力層ニューロンが代表するカテゴリが一致する場合は何も修正されない。しかし、両者が異なる場合には、そのとき発火した中間層ニューロンが発火しなくなるまでしきい値 λ_j を小さくする。これは、特徴空間においてその中間層ニューロンの発火領

域を縮小することに相当する。また、入力 x_k に対して正しい出力層ニューロンが発火しない場合には、入力データ x_k と同じ結合重み w_j を持つ中間層ニューロンを生成し、その出力を正しいカテゴリを表す出力層ニューロンへ結合する。

2.3 信頼度投票競合学習ネットワーク ここで提案する信頼度投票競合学習ネットワークとは、上述の手法に対して、そのニューロンの出力に関する信頼度を設けて入力ベクトル分類の判断に利用するものである。ニューロンの重みや配置などの学習はRCEモデルと同様の手順で行い、認識時の処理に信頼度を定義し利用する。まず、 $F()$ を距離 d の関数として信頼度 R を(2)(3)式によって定義する。ここで、ある入力データが与えられたとすると、それに対して発火する中間層ニューロンが複数存在するとき、それらの信頼度 R を求めて投票しカテゴリ毎の合計値を比較する。その結果、入力データは最大投票値を得たカテゴリへ分類される。また、発火するニューロンが存在しないときは、全てのニューロンの係数 λ_j を α だけ拡張して再度入力データを与え、中間層ニューロンの発火を促す。これを2つの場合(overlap, out of area)に分けて図3に示す。

図3において太線と細線はそれぞれ異なるカテゴリを表しているとする。まず、ネットワークへの入力 x に対して反応するニューロンが存在しないとき(左下点線図)には、発火領域の外(out of area)になるので発火が生じない。このとき、ニューロンの反応領域半径 λ_j を α 倍すると(右下実線図)、 x は最も近いニューロンの反応領域に含まれるようになる。この結果いくつかのニューロンが発火するので、発火ニューロンの信頼度 R を求めて投票し、カテゴリ毎の合計値の比較を行う。この信頼度比較により、入力データは最も高い投票値を得たカテゴリへ分類される。

また、与えられた入力 x に対して複数のニューロンが反応する場合(左上点線図)には、反応領域が部分的に重なっている(overlap)。このとき、従来のRCEモデルでは同時発火し、出力は発火の有(1)、無(0)のみなので、カテゴリ判別が難しい。そこで、ニューロンの反応領域半径 λ_j を α 倍して(右上実線図)、ニューロン群の発火を促すようにする。発火ニューロンの信頼度 R を求めて投票し、カテゴリ毎の合計値の比較を行う。この信頼度比較により、入力データは最も高い投票値を得たカテゴリへ分類される。

すなわち、従来のRCEネットワークでは、ある入力データに対して異なる中間層ニューロンが同時発火した場合や、全く発火しない場合には分類ができない。それに対し提案方法では、発火を促された中間層ニューロンの信頼度投票に基づいて分類を行うことができる。また、発火したニューロンについてのみ信頼度 R を計算し投票を実行するので、処理負荷が小さくて済む。以上の投票プロセスにより、従来は分類不能であった場合にも、分類処理を実行することができる。

Fig.2 A competitive learning network.

Fig.3 Confidential voting by area expansion.

$$d_j = \sqrt{\sum_{i=0}^{N-1} (x_{ki} - w_{ji})^2} \quad \dots\dots\dots (2)$$

$$R = F(d_j) \quad \dots\dots\dots (3)$$

2.4 信頼度の定義 提案手法では、ネットワークを構成するニューロンの出力に関する信頼度 R を設けて入力ベクトル分類の判断に利用する。このとき、式(3)の関数 $F()$ の定義により各ニューロン出力の信頼度 R の評価値は変わる。ここでは、式(4)と式(5)によりそれぞれ R を定義し、これらによる提案手法の性能を比較検討する。式(4)は、各ニューロンの中心(参照パターン)との類似性(影響力)を表しており、各ニューロンが被覆する領域の中心から離れるにつれて急速に零に近づく。式(5)は、式(4)で表される類似性(影響力)に各ニューロンの半径を係数として掛けたものであり、ニューロン自身が持つ影響力を重み付けしたものとなる。

$$R = \frac{1}{\exp(d_j)} \quad \dots\dots\dots (4)$$

$$R = \frac{\lambda_j}{\exp(d_j)} \quad \dots\dots\dots (5)$$

3. 実 験

3.1 抵抗器の信頼性試験 本実験に用いる抵抗器として、1/4 Watt型、定格抵抗330Ω、許容誤差5%、定格電圧9.08Vの規格を持つ炭素皮膜抵抗器を80個使用する。まず、実験に先立って80個の抵抗器の初期抵抗値をそれぞれ測定しておく。電源に並列接続された80個の炭素皮膜抵抗器群に対し、27Vの加速試験電圧を印加する。この加速試験電圧は、定格電圧の2.97倍に相当する。加速試験電圧を印加された抵抗器はストレス負荷を受けるため、試験時間の経過とともに性能が劣化し抵抗値が徐々に上昇する。このとき、許容誤差は5%であるので、定格抵抗値330Ωから5%以上の抵抗値逸脱を生じた抵抗器は故障したと見なすことができる。50時間の加速試験を行い、1時間毎に各々の抵抗器の抵抗値をデジタルマルチメータで測定する。このように1時間毎に測定して得られた抵抗値データを記録する。通常、これら試験ロットの全抵抗器の劣化抵抗値をマルチメータにより逐一測定し、故障の判定を行うことは正確な診断を可能にするが、試験コストが大きくなるという問題点がある。従って、外観画像の情報から抵抗器の故障を診断できれば、故障診断に要する手間やコストの低減が実現できる。

上記と同時に、1時間毎にデジタルカメラ（1/4インチカラーCCD総画素数41万画素）を用いて試験装置上の抵抗器の外観を正面撮像し、時間経過毎の画像データを収集する。カメラの焦点調節および露出調節は自動的に行われる。80個の抵抗器について、それぞれ試験開始前の状態を含む51枚ずつの画像を撮像すると、合計4080枚の画像が得られる。このとき、ある抵抗器*x*について、1時間ごとに得た劣化抵抗値と撮像画像を照らし合わせると、抵抗器*x*に関して故障前の画像群と故障後の画像群が得られる。同様に、80個の抵抗器に関して故障前と故障後の2種の抵抗器画像群に分類することができる。これにより、4080枚のうち2741枚が故障前の抵抗器画像となり、1339枚が故障後の抵抗器画像となった。これら2種の画像群は、故障時の画像群と未故障時の画像群であるため、これらの外観画像から故障を判定する故障診断モデルを競合学習ネットワークにより構成することを試みる。

3.2 ネットワークの学習 撮像した抵抗器画像を計算機に転送し、画像中の抵抗器部分を切り出して画素値を得る。このとき、時刻*t*時点の画像において、ある抵抗器*i*の部分占める全ての画素についてのRGB値を得ることがで

Fig.4 Feature vector from register's image.

きる。ここで、一般に、RGB値の三刺激値には互いに相関があるのでデータ圧縮やパターン分離のうえで冗長な部分が存在する。従って、この相関を除去するため、KL変換に基づいた表色系の近似として次式を用いて、次のIII表色系へ変換する⁽¹⁰⁾。

$$\begin{cases} I_1 = (R+G+B)/3 \\ I_2 = (R-B)/2 \\ I_3 = (2G-R-B)/4 \end{cases} \quad \dots\dots\dots (6)$$

撮像した抵抗器の矩形画像を縦に32等分、横に5等分したとき、図4の斜線部のように、抵抗器中心線上に位置する32個の領域の画素を考える。上式によって得られた(*I*₁, *I*₂, *I*₃)値を、上記32個の領域内画素について、その平均値を求めて96個の要素から成る特徴ベクトルを作成する。これを試験対象の全抵抗器画像について行い、特徴ベクトル集合*Hai*; (*i*=1, 2, ..., 4080)を得る。

一方、通常の測色値と人間の視覚による色感覚の相違は必ずしも対応していないことが知られており、見かけ上の色差と一致しないことがある。このような場合、測色値と視覚による外見上の色差の感覚を一致させるため、ある抵抗器*i*の部分占める全画素についてのRGB値をHSV色空間へ次式により変換する⁽¹¹⁾。

$$\begin{cases} H = \tan^{-1}[(G-B)/(2R-G-B)] \\ S = [(B-R)^2 + (R-G)^2 + (G-B)^2]/3 \\ V = (R+G+B) \end{cases} \quad \dots\dots\dots (7)$$

HSV色系は、それぞれ色相、彩度、明度を表しており、Munsell表色系における円周、中心距離、高さに応じて、色表現の色差感覚に合致した対応系を維持しつつ一意に決定することができる。先と同様に、中心線上に取った32個の領域内の画素についてHSVの平均値を求め、96次元の特徴ベクトルを作成する。これを試験対象となった全ての抵抗器の画像について行い、*Hbi*; (*i*=1, 2, ..., 4080)を得る。

以上で得られた2つのベクトル H_{ai} と H_{bi} を、各々96次元を持つ特徴ベクトル H_{xi} ($i=1, 2, \dots, 4080$) とする。

得られた80個の抵抗器に関する試験データを、グループ $A: \{a_i; i=1, 2, \dots, 40\}$ 、グループ $B: \{b_i; i=1, 2, \dots, 40\}$ に分け、グループ A を学習用データ、グループ B を故障診断モデルの性能を検証するためのテスト用データとする。グループ $A: \{a_i; i=1, 2, \dots, 40\}$ の抵抗器40個に対する2040枚の画像を故障前と故障後の2種に分類すると、1397枚が故障前の画像群、643枚が故障後の画像群となった。これらの画像を用いて故障状態か故障状態でないかを診断するための学習を実行する。学習終了後、テスト用データを用いてネットワークの故障診断性能を検証する。

3.3 競合学習ネットワークによる故障診断 本節では、提案する競合学習ネットワークによる故障診断法について述べる。いま、III 表色系および HSV 表色系へ変換された2種類の特徴ベクトル H_{ai} 、 H_{bi} が与えられたとする。これら炭素皮膜抵抗器の特徴ベクトル $[H_{ai}(t)]$ 、 $[H_{bi}(t)]$ をそれぞれ正規化して競合学習ネットワークへ入力し、同時刻における抵抗の故障の有無を教師信号として学習を行う。例えば、競合学習ネットワークへの入力として、ある時刻 t における抵抗器 i の特徴ベクトル $[H_{ai}(t)]$ を与える。ここで、教師信号として時刻 t における抵抗器 i が故障していれば故障状態に対応するニューロンが発火し、故障していなければ正常状態に対応するニューロンが発火するように教示し学習を実行すると、これらによりネットワークは抵抗器 i に関する故障診断モデルを同定することになる。従って、ある抵抗器が故障しているかどうか診断する場合は、特徴ベクトルをネットワークに与え、発火したニューロンにより故障の有無を判断する。上記と同様に文献(8)の従来のRCEモデルについても実験を行い、性能比較を行った。

4. 実験結果

4.1 画像情報からの故障診断 図5に、故障後の抵抗器を示す。故障前の抵抗器は鮮やかな光沢のある炭素皮膜状態であるが、故障後の抵抗器は焦げ茶色ないし黒褐色に変色した炭素皮膜と、その燃焼に起因するひび割れや縮退など若干の形状変化を生じている。また、金属導線部にも熱変色の形跡が認められた。これらの炭素皮膜抵抗器の抵抗

Fig.5 An appearance of tested carbon film resistor.

値は、実験時間の経過に伴い正常状態から徐々に逸脱して劣化し、それに伴う抵抗値上昇、発熱、焼焦、変色を生じる。このとき、定格抵抗値から5%以上逸脱した抵抗器は故障したと見なすことができるので、故障個体が徐々に生じる。この場合、炭素皮膜抵抗器の定格抵抗値は330Ωであるため、346.5Ωを越えた時点で故障したものと見なすことができる。

図6に実験の結果得られた抵抗値の実測データ例を示す。図6において抵抗器の故障時期に注目すると、試験開始10時間以内は抵抗値の上昇すなわち劣化進行は比較的小さく、それ以降から抵抗値の上昇傾向が現れ346.5Ω近辺では比較的速度く劣化が進行しているとみられる。これは抵抗器が故障状態に至るまでにある程度のストレス負荷が印加される必要があるためと考えられる。その後、故障個体が徐々に発生し、ほぼ毎時間に故障が観測されるようになる。さらに、図6より明らかなように、抵抗器の劣化進行状況は個々の抵抗器によって相違があり、比較的速度く劣化するものや緩やかに劣化するものがある。すなわち、個体ごとの劣化状況の相違により故障時間のばらつきが生じる。このことは、個々の抵抗器に関する信頼性や故障発生について診断することの難しさを示している。

Fig.6 Examples of degradation of tested resistors.

Fig.7 An average rate of diagnosis.

4.2 故障診断の精度 図7に競合学習ネットワークによる診断結果の平均正解率を示す。ここではそれぞれ30回ずつの学習実験をおこない、その平均値を示している。図7の(Type A)は式(4)を用いた場合、(Type B)は式(5)を用いた場合を表している。また、Case 1, 2, 3, 4は、それぞれ信頼度投票におけるパラメータ α を1.3, 1.5, 1.7, 1.9とした場合を表している。

図7より明らかに、提案する競合学習ネットワークの精度が全体として高いことがわかる。例えば、図7のcase1($\alpha=1.3$)では、III表色系において90.8%、HSV表色系において81.2%の平均診断正解率となっている。HSV表色系とIII表色系それぞれに関する比較では、全体としてIII表色系の精度が高いことがわかる。すなわち、提案手法におけるIII表色系とHSV表色系それぞれの平均診断率を求めると、87.6%、78.5%となっている。これに対して文献(8)のRCEネットワークでは71.2%、64.2%であり、提案手法はRCEネットワークよりも16.4%、14.3%高い。このことは、三色の刺激値における相関を除去したIII表色系を用いることが有用であることを示している。このとき、Case 1からCase 4における競合学習ネットワークの実験において最も良い正解率はCase 1($\alpha=1.3$)で行った試行の場合に得られ、そのとき93.8%の正解率であった。一方、最も低い正解率となったのは、HSV表色系のCase 4($\alpha=1.9$)における試行であり、74.4%であった。一方、従来のRCEネットワークにおける試行で診断精度の最高値はIII表色系での77.8%、最小値はHSV表色系での60.2%であった。従って、競合学習ネットワークにより、従来のRCEネットワークよりも優れたパターン分類が実現可能といえる。

4.3 故障診断の誤差 図8に(Type A)の競合学習ネットワークによる故障診断の誤り率とRCEネットワークによる誤り率を示す。なお、誤り率は、故障していない抵抗器を故障していると診断した誤り数(P)と、故障している抵抗器を故障していないと診断した誤り数(Q)、および判別不能数の合計(total)で定義する。すなわち、 $\text{total} = P + Q + \text{判別不能数}$ である。また、前節での結果からIII表色系が良い結果を示しているの、これについてのみ記述する。

誤診断したケースを調べると、いずれの場合も劣化に伴う皮膜焼焦の進行と実際の劣化程度に相違が生じているケースに誤診断が生じやすい。RCEネットワークによる診断誤りでは、1)いずれのニューロンも発火しない場合、2)誤ったニューロンが発火する場合の2つに大別された。特に、ニューロンが発火せず判別不能のケースが、正しく診断できなかったケース全体の約60%程度みられた。

図8において、グループB: $\{b_i; 1, 2, \dots, 40\}$ の抵抗器の画像2040枚のうち実際に故障状態のものは696枚であるが、診断結果の誤り率では、いずれの場合も誤り率(Q)が誤り

Fig.8 Error rate of diagnosis by proposed method(Type A).

Fig.9 Error rate of diagnosis by proposed method(Type B).

率(P)よりも大きく、故障している抵抗器を故障していないと誤診断したケースが多い。また、全体的傾向として競合学習ネットワークはRCEネットワークより誤り率が小さい。明らかに、case1の競合学習ネットワークの誤り率が最も小さいことがわかる。このとき、誤り率(P)は3.5%、誤り率(Q)は4.9%、全体で9.5%となっている。RCEネットワークでは、誤り率(P)は5.1%、誤り率(Q)は6.8%となっているが誤り率全体は28.8%であり、判別不能すなわちニューロンが発火しないケースが16.9%みられた。一方、提案手法のcase 1~case4ではニューロンが発火しない場合はそれぞれ1.1%、1.3%、1.3%、1.6%生じたが、これらはRCEネットワークと比較して大幅に改善されている。

一方、図9に、(Type B)の競合学習ネットワークによる診断の誤り率を示す。比較のため、RCEネットワークによる結果も再掲している。(Type B)の競合学習ネットワークでは、(Type A)よりも診断誤りの発生率が若干高い。また、故障している抵抗器を故障していないと判断した誤りが多い点は、(Type A)と同様の傾向である。さらに、判別不能すなわち、ニューロンが発火しないケースは、case 1~case4それぞれにおいて1.1%、1.3%、1.3%、1.6%と、(Type A)と

同じであった。従って、(Type B)の診断誤りの増加は信頼度定義の相違による誤分類によって生じたものとみられる。

このように、提案手法が優れた結果をもたらした要因として、次の2点が考えられる。

(A)従来は識別不能とされたケースにも、ほぼ正しい識別結果を出したこと。つまりRCEモデルでは、十分に被覆できない特徴空間領域が存在し、その間隙に入力パターンが入った場合は識別不能となるが、提案手法ではニューロンの反応領域拡張(しきい値拡張)によって未被覆領域を減少させたこと。

(B)ニューロンの反応領域拡張(しきい値拡張)は、カテゴリ間の境界を再構成する働きがあること。

以上の要因は、量子化ニューロンをテンプレートとする従来のRCEモデルでは、学習パターンの増加すなわちニューロン数の増加によってのみ可能であったが、提案手法はニューロン領域の拡張によりパターン分類精度の向上が可能であることを示した。

4.4 最大値に基づく競合による故障診断 提案手法では、発火した量子化ニューロン群の信頼度をカテゴリ毎に投票し、最大値を得たカテゴリへ入力パターンを配することによって分類を行った。これは、与えられた入力パターンの周辺状況を分類処理の判断に利用することに相当する。

一方、あるカテゴリのニューロンが入力データの周囲に多数存在することが、入力データがそのカテゴリに分類されるべきであるということにつながらない、と考えられる場合がある。すなわち、例えば正常を表す領域が離れ小島のようにっており、入力データがその離れ小島の中に入っていた場合、領域拡張と投票によって、正常と識別されにくくなるケースが考えられる。このようなとき、投票を行わずに、発火した複数のニューロンのうちで信頼度が最大値となるカテゴリを選択し、入力パターンを分類する方法が考えられる。これを最大値に基づく競合戦略とする。ここでは、提案手法と最大値に基づく競合戦略を比較検討する。なお、前節での結果から III 表色系が良い結果を示しているため、これについてのみ記述する。

先の実験と同じ条件のもとで、最大値による競合戦略を採用した識別実験の結果を図10と図11に示す。図10は(Type A)のネットワークであり、図11は(Type B)のネットワークの結果である。明らかに、最大値による競合戦略を用いたときの診断誤差は増加しており、いずれの場合も、投票プロセスを行う提案手法の方が優れていることがわかる。すなわち、最大値による競合戦略を用いた場合、(Type A)では平均して5.57%、(Type B)では平均して9.80%の誤差増加となる。提案手法は、発火したニューロン群の信頼度投票を通じて入力パターンの周辺状況を考慮する。多くのパターン認識問題では、パターンはカテゴリ毎にクラスを構成して分布していることが多いと考えられるた

Fig.10 Error rate of diagnosis by max-selection (Type A).

Fig.11 Error rate of diagnosis by max-selection (Type B).

め、ある入力パターンの周辺の状況を考慮した分類を行うことは有効な方法である。従って信頼度を投票する提案手法は妥当なものといえる。しかし、一方、離れ小島のような特別な状況下では投票によって誤分類が生じ得る可能性もある。従って、パターンの分布状況によってパターン分類戦略を変更するなどの工夫が必要と考えられる。このような特別な状況下への対応は今後の検討課題である。

5. 結 言

本論文では、信頼度を導入した信頼度投票競合学習ネットワークを提案するとともに、炭素皮膜抵抗器の故障診断問題に応用し、その有効性を検討した。提案手法を電子部品の故障診断問題へ応用し、従来のRCEモデルと比較した結果、提案手法は最高93.8%、平均90.8%、RCEモデルは最高77.8%、平均77.8%となり、提案手法が優れた結果を示すことを示した。一方、故障診断精度を検討すると、全体として故障抵抗器を故障していないと誤診断するケースが多いことが判った。また、信頼度の定義によって精度が変動することから、より精度の高い診断を行うためには、診断に

用いる画像特徴や信頼度の適切な定義についての検討, および精密な画像計測方法を用いること等が課題である. 今後, より精密な画像計測方法を採用するとともに信頼度投票方式の改良・パターン分類戦略の柔軟化を行い, 提案する競合学習ネットワークのパターン分類性能の向上を図る方針である.

文 献

- (1) 波多野伸次, 大森成暁, 村田忠: ファジィ推論による電気部品の寿命推定, 第11回ファジィシステムシンポジウム講演集, p. 289-290 (1995)
- (2) 江尻正員: 画像処理の産業応用総覧, -AI技術を応用した溶接検査システム-下巻P. 550-562, フジテクノシステム(1994)
- (3) 小路祐吉, 高津直由, 王征成: ニューラルネットによるはんだ外観検査, 信学論DII, Vol. J78, No. 4, pp. 589-596 (1995)
- (4) 尾上守夫: 画像処理ハンドブック, p. 598-626, 昭晃堂(1985)
- (5) 村田忠: ファジィ推論による電子機器の信頼性評価, 日本ファジィ学会誌, Vol. 5, No. 5, pp. 981-990 (1993)
- (6) 村田忠, 小川幸成: ファジィ理論による電気部品の寿命改善推定, 日本信頼性学会論文誌, Vol. 15, No. 3, pp. 3-9 (1993)
- (7) 長山格, 星野聖, 村田忠: 信頼性問題へのニューロ技術の応用, 日本信頼性学会誌, vol. 18, No. 2, pp. 72-77 (1996)
- (8) D.L.Reilly, L.N.Cooper, C.Elbaum: A neural model for category learning, Biol. Cybern., 45, pp. 35-41 (1982)
- (9) 坂和正敏, 田中雅博: ニューロコンピューティング入門, 森北出版 (1997)
- (10) T.Kohonen: Self-Organizing Maps, Springer Verlag (1995)
- (11) 張新学, 大町真一郎, 阿曾弘具: RCEモデルに基づくネットワークを用いたファジィ回帰分析, ファジィ学会誌, Vol. 9, pp. 533-540 (1997)
- (12) 臼井支朗, 岩田彰, 久間和生, 浅川和雄: 基礎と実践ニューラルネットワーク, コロナ社 (1995)
- (13) 谷内田正彦: コンピュータビジョン, 丸善 (1993)
- (14) 高木幹雄: 画像解析ハンドブック, p. 485-492, 東京大学出版会 (1985)
- (15) R.Hecht-Nielsen, 袋谷賢吉訳: ニューロコンピューティング, Addison-Wesley-Toppan, (1992)
- (16) S.Haykin, Neural Networks, IEEE Computer Society Press (1996)