信頼度投票を用いた競合学習ネットワークと 医用診断問題への応用

正員 長 山 格 (琉球大学)
正員 名嘉村 盛和 (琉球大学)
非会員 山 城 毅 (琉球大学)

Diagnosis of Breast Cancer by Using Competitive Learning with Modified Confidential Voting

Itaru NAGAYAMA, Member, Morikazu NAKAMURA, Member,
Tsuyoshi YAMASHIRO, Non-member (University of the Ryukyus)

This paper describes a new approach for competitive learning network and its application to diagnosis of breast cancer in medical pattern recognition. Conventional competitive learning such as RCE network proposed by Cooper et. al. has a good performance caused by the faster learnability than popular steepest descent methods. However, the RCE network has a shortcoming with its decision making process. Thus, we introduce the confidential voting process in order to avoid the ambiguous decision making in the RCE network. Generally speaking, despite of great deal of public awareness, breast cancer continues to be one of the most common cancer diseases. Therefore, if we can find an efficient method to diagnose the cancer with computer technology, the more efficient early detection can be performed. We first discuss some essential issues to be considered in medical aspects of cancer diagnosis. Experimental results by using the proposed competitive network with confidential voting are also described. The good performance of the new competitive learning approach is shown.

キーワード: 競合学習, 信頼度投票, 画像診断, 癌細胞, ニューラルネット

1. はじめに

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音声認識など多くの分野で応用されている。パターン認識を実現する手法として、ファジィ理論やニューラルネットワーク、ベイズ理論などが提案されており、これらはいずれも学習等の方法で認識システムを構築することによって実現される⁽¹⁾⁻⁽⁴⁾。特に、ニューラルネットワークはBP法に代表される逐次近似法に基づいた学習アルゴリズムにより、任意数の隠れ層ユニットを用いることで任意の写像を近似できることが示されている^{(5), (6)}。ところが、一般に逐次近似法に基づく学習則では、重みパラメータを変化させるため非常に多くの繰り返し計算が必要である。また、新規に学習パターンが生じた場合には再度全ての学習を行わねばならないなど、いわゆる追加学習には適さない。実際の応用では、新規パターンの学習も含めてできるだけ短い時間内に学習が終了し直ちに認識システムを利用できることが望まれる。多くのニューラルネットワークモ

デルのうち、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、多数の量子化ニューロンから成る構造であり、入力パターンの分類学習を効率的・高速に実行できるという特徴がある^{(7), (8)}。また、計算アルゴリズムがきわめて簡潔であり、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競合学習モデルは、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モデルにおいてメモリ容量の増大や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、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。

一方、癌は悪性新生物と言われ、心臓病などの循環器疾患とならんで成人の死亡原因の最大要因となっている。従来、癌の診断では病理医が病変細胞を直接肉眼で顕微鏡観察し診断するバイオプシーにより最終診断が行われている。しかし、検査に要する手間を低減するため、コンピュータ支援による細胞診の自動化が試みられており、多くの研究が行われてきた⁽⁹⁾⁻⁽¹¹⁾。重篤な病態である癌は現在でも完全に克服できたとは言えず、早期発見と早期治療が生存率を高めるための重要な手段である。

一般に、医用画像検査では、細胞の形状測定や異常細胞の検出が行われており、パターン識別を自動化することで検査の効率化・コスト低減を図っている。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てきた。Wisconsin大学病院では、Streetらが癌病変細胞を画像計測したデータベースを作成している。これは、569名の患者から採取した乳癌細胞を画像計測して特徴を検出し、それぞれの癌を悪性と良性に区分したデータである⁽¹²⁾。

ところが、一般に撮像画像や計測パターンの安定性・変動が認識処理結果に大きな影響を与えるため、これらの変動に対応・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ニューラルネットワーク等が知られており、多くの研究が行われている。ニューラルネットワークは脳における並列分散処理をシミュレートすることが可能であり、論理AIと比べてパターン情報処理に優れている。本論文では、適応的な学習を行う手法として、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、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。すなわち、従来のRCE競合学習ネットワーク⁽⁸⁾⁽⁹⁾に対して、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示し、癌細胞診断問題へ適用する。提案する競合ネットワークにより、高速な学習が可能であること、およびその有効性を示す。

2. 細胞診断と競合学習

〈2・1〉 癌細胞の検査と診断 癌細胞の診断自動化は検診・診断を容易にするとともに、治癒率向上に重要な役割を果たす。従来、染色画像を画像処理し、癌細胞に関する特徴を画像計測して正常細胞と癌細胞を自動識別することが試みられている。細胞診では、病変部から剥離させた細胞組織をスライドガラスに塗布し、HE染色薬により染色する。HE染色では、細胞核は紫色に染まるがその他の細胞質は薄桃色に染まるので、肉眼での識別が容易に可能となる。染色した標本を顕微鏡で観察し、癌細胞の特質を持つ異常細胞が存在するかどうか検査する。通常、集団検診で発見される癌は、1000人につき数人程度である。そのスライドガ

表1 乳癌細胞核の計測値データ

Table.1 Measured features of cancer cell nucleus.

	Features	Mean	S.E.	Largest
B E N I G N	radius	13.850	0.248	14.980
	texture	15.180	0.919	21.740
	perimeter	88.990	1.830	98.370
	area	587.400	19.410	670.000
	smoothness	0.095	0.004	0.118
	compactness	0.077	0.015	0.172
	concavity	0.045	0.015	0.146
	concave	0.037	0.010	0.100
	points symmetry	0.211	0.015	0.295
	fractal dimension	0.059	0.002	0.069
	Features	Mean	S.E.	Largest
M A L I G N A N T	radius	19.160	0.636	23.720
	texture	26.600	1.001	35.900
	perimeter	126.200	4.321	159.800
	area	1138.000	69.650	1724.000
	smoothness	0.102	0.007	0.178
	compactness	0.145	0.024	0.384
	concavity	0.192	0.040	0.575
	concave	0.097	0.013	0.187
	points symmetry	0.190	0.014	0.326
	fractal dimension	0.062	0.003	0.097

ラスにおいても、ほとんどの細胞は正常であり、異常な細胞はごくわずかにすぎない。また、癌細胞であるかどうかの判断も複雑であり、熟練と高度な技術・知識を必要とする。しかし、経験を積んだ検査技師や病理医の養成は容易ではないため、癌の細胞診の支援・自動化を実現するために画像処理技術を用いた診断支援の研究が行われている。このとき、癌細胞としての特徴量を画像処理によって計測し、それらの判別を行うパターン分類を経て、癌の有無や悪性・良性の判別が行われる。Streetらは、Wisconsin大学病院において569名の乳癌患者から採取された癌細胞を画像計測したデータベースを作成している⁽¹²⁾。これは、各患者の癌細胞核画像に関する10個の特徴量を計測したもので、これらの特徴量の平均値、標準偏差、最大値を求めており、1患者あたり30次元の特徴ベクトルとなっている。10個の特徴量としては、細胞核に関する1)半径、2)テクスチャ、3)周囲長、4)面積、5)曲率、6)Compactness、7)凹度、8)凹点数、9)対称性、10)フラクタル次元、を計測している。彼らはこれらの特徴ベクトルにより、癌が悪性であるか良性であるかの判別を試みている。表1に、データベース中の患者の乳癌に関する10個の特徴量の数値例を示す。なお、表1には悪性(Malignant)の例と良性(Benign)の例を示している。本研究では、提案手法をこのデータベ

ースに適用して癌細胞の悪性と良性の判別を試み、従来のRCEネットワークやBP法と比較検討する。これにより、提案手法は高速な学習と精度の高いパターン分類・診断を実現できることを示す。

〈2・2〉 RCE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、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。まず信頼度R

図2 信頼度投票競合学習ネットワーク

Fig.2 A competitive learning network.

図3 信頼度投票プロセス

Fig.3 Confidential voting.

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

$$R = \frac{1}{\exp(d)} \quad \dots \dots \dots (3)$$

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 倍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A,Bを表しているとする。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(点線)には発火が生じない。このとき、ニューロンの反応領域半径 λ_j を α 倍すると(実線)、 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。この信頼度合計値の比較により、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ものとする。

ここで、パラメータ α は、各量子化ニューロンが被膜する領域のサイズを変更するためのパラメータであり、周辺の量子化ニューロンとの相互の影響力範囲を規定する。すなわち、入力パターンが与えられたとき、その周辺の量子化ニューロンとの近傍性を制御することができる。また、量子化ニューロン間の隙間を充填する効果をもたらす。

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。それゆえ、入力特徴空間を稠密に覆う必要があり、多数の中間層ニューロンを必要とする。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。以上のような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と考えられる。

3. 実験

〈3.1〉 癌特徴データの判別 本実験に用いるデータとして、Streetらによる癌画像計測データベースを用いる。このデータベース中の全てのサンプルには乳癌の臨床的診断結果が与えられており、良性和悪性の2種の判断が与えられている。本実験では、競合学習ネットワークを適用して乳癌計測データを良性・悪性に分類することを試み、提案手法の有効性を示す。

〈3.2〉 競合ネットワークの学習 データベース中の569件のデータを2つに分割し、学習用データ $A=\{a_i; i=1, 2, \dots, 279\}$ とテスト用データ $B=\{b_j; j=1, 2, \dots, 290\}$ とする。このうち、学習用データ $A=\{a_i; i=1, 2, \dots, 279\}$ において、悪性のもの142件、良性のもの137件である。これらを1) 提案手法、2) 従来のRCEネットワーク、3) BP法を用いたフィードフォワード型ニューラルネットワーク、および 4) KohonenのLVQの4種でそれぞれ学習し、悪性・良性の分類を行う。ここで、BP法を用いたフィードフォワード型ニューラルネットワークは、入力層ニューロン30個、中間層ニューロン15個、出力層ニューロン2個の3層ネットワークを用いた。ニューロンの変換関数は $y=1/(1+\exp(-x))$ のシグモイド型関数を用い、最大学習回数2万回まで学習した。なお、提案手法では、信頼度 R の定義として式(4)を用いた場合について実験を行い検討した。ここで、 d は式(2)で

$$R = \frac{\exp(\lambda)}{\exp(d)} \quad \dots\dots\dots (4)$$

定義され、 λ は発火したニューロンの有するしきい値である。提案する競合ネットワークは、入力ユニット数30個、

出力ユニット2個であり、内部の競合ユニットは学習とともに増殖成長する。このとき、ある入力データに対して発火したニューロン全てについて信頼度 R を求めて投票し、最大値を得た出力ニューロンのカテゴリへ入力データを分類する。また、このときパラメータ α は1.9とする。これらのネットワークについて50回ずつの学習実験を行った。学習終了後、テスト用データを用いて診断性能を検証した。さらに従来のRCEネットワークについても同様に50回の学習実験を行い、提案手法との性能比較を行った。なお、本実験ではデータベース中のデータの値は全てそのまま使用している。

4. 実験結果

〈4.1〉 乳癌データの分類結果 表2に実験結果を示す。表2には、テスト用データ $B=\{b_j; j=1, 2, \dots, 290\}$ に対して悪性・良性の診断を行ったときの平均正解率、正解率の最高値、最低値、平均学習時間を示す。明らかに、提案手法の精度が良いことがわかる。提案手法の平均正解率は93.3%、最高正解率は95.7%であり、RCEネットワークの平均正解率80.7%と比べて分類能力が大きく向上している。一方、LVQ1とLVQ2はそれぞれ最高認識率では劣るものの、提案手法に匹敵する平均認識率を示す。特に、LVQ2は提案手法より最高認識率で0.6%劣るが平均認識率で0.3%上回っている。また、提案手法はBPネットワークよりもおよそ18%ほど精度が高い。このときのBPネットワークの学習曲線を図4に示す。BPネットワークの学習の様子を観察すると、初期にある程度学習が進むが、その後、誤差が減少せず学習が進みにくい状況がみられた。異なる初期値を用いて50回の学習実験を行った場合でも同様に学習が停滞した。これは、乳癌データの測定値が項目毎に大きく変化しているため、逐次近似に基づくBPネットワークでの学習は容易でないためと考えられる。一方、提案手法やRCEネットワーク、LVQ1、LVQ2は、ベクトル量子化を基本として特徴空間を分離するため、逐次近似法よりも学習が高速かつ容易である。ワークステーション(JULI-170)を用いて学習実験を行ったときの学習時間を比較すると提案手法とRCEネットワークは、BPネットワークに対して各々1/320、1/348の時間で学習を実行しており、明らかに高速な学習が可能である。

〈4.2〉 パラメータによる精度変化 図5に提案手法において(4)式を用いたときのパラメータ α に対する診断結果の平均正解率を示す。また、図6には(3)式を用いたときの平均正解率を示す。図中で横軸はパラメータ α を表し、縦軸は平均正解率を示す。パラメータ α の値は、1.05~2.5の間で0.05ずつ異なる値とした。ここではそれぞれ50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5より、パラメータ α が1.85のときに最も良い診断が可能であり、このとき92.18%の平均正解率となる。ところが、

表2 乳癌データの分類結果

Table.2 Results of breast cancer classification..

	Average	Max	Min	Time
Proposed	93.3%	95.7%	86.5%	8.9 sec
RCE	80.7%	84.2%	72.9%	8.2 sec
LVQ1	92.9%	94.4%	85.7%	21.6 sec
LVQ2	93.6%	95.1%	84.3%	13.8 sec
B. P.	74.9%	79.2%	71.8%	2856.3 sec

図4 BPネットワークの学習曲線

Figure 4 A learning curve by BP neural network.

$\alpha=1.1$ のときは最も低い正解率となる。一方、信頼度の定義として(3)式を用いた図6の結果では、診断精度が図5ほど高くない。明らかに、正解率の傾向と精度が両者で異なっており、(4)式を用いるとパラメータ値 α による正解率の変動が大きい、適当なパラメータ値をとれば、90%以上の高い正解率を得ることができるといえる。一方、(3)式の場合、全体として正解率は高くないがパラメータ α の値によらずほぼ80%前後の精度を示す。またパラメータ値 α の増加とともに若干精度が低下する傾向がある。

〈4.3〉 乳癌データ診断の汎化性 一方、パターン認識問題においては十分多数の学習サンプルが得られるとは限らないため、限られた学習サンプルのみからできるだけ精度の高い分類が実現されることが望ましい。このような汎化性について検討した。

提案手法において学習データ数をそれぞれ50, 100, 150, 200, 250として学習を行い、290個のテスト用データを対象とした診断を行った。このとき、学習データ数50, 100, 150,

図5 (4)式を用いたときの平均診断正解率

Fig.5 Average rate of diagnosis.

図6 (3)式を用いたときの平均診断正解率

Fig.6 Average rate of diagnosis.

200, 250のそれぞれの場合においてパラメータ値 α を0.05ずつ変化させて50回ずつ学習を行い、平均正解率を求めた。このとき、信頼度の定義は(4)式を用いた。その結果を図7に示す。図7より、明らかに学習データ数が多い方が精度が高いと言え、特に、パラメータ値 α が小さい場合、学習データ数が50個のときの精度は低く50%台ないし60%台の正解率である。100個以上の学習データを用いると、ほぼ70%以上の正解率を達成する。一方、パラメータ値 α が大きくなると、いずれの場合も正解率が上昇する。とくに、学習データ数50個の場合でも、大きく正解率が上昇しており、90%を越えていることがわかる。これは、信頼度投票とパラメータ値 α によってパターン参照の効果が現れているためと見られる。このような正解率の向上は、従来のRCEモデルでは学習パターンの増加によってのみ可能であった。それに対して、提案手法では少ない学習パターン数でもパラメータ値 α を適当に設定し、信頼度投票を行うことによって、精度の高い分類を行うことができる。

さらに、従来のRCEモデルとBPネットワークおよびKohonenの学習ベクトル量子化法LVQ1, LVQ2⁽¹³⁾についても、学習データ数を50, 100, 150, 200, 250として学習を行い、290個

図7 提案手法の学習データサイズと平均正解率
Fig.7 Average rate of diagnosis.

図8 学習データサイズと平均正解率
Fig.8 Average rate of diagnosis for variety size of the training data.

のテスト用データに対する診断精度を提案手法($\alpha=1.9$)と比較検討した。ここで、RCEモデル、BPネットワーク、LVQ1、LVQ2において、学習データ数毎にそれぞれ50回ずつの学習実験を行い、平均値を求めた。その結果を図8に示す。図8において横軸は学習データ数を表し、縦軸は正解率を表す。明らかに、提案手法の精度が学習データ数の多寡に

関わらず平均して最も良いことがわかる。次いでLVQモデル、RCEモデル、BPネットワークの順となる。このとき、LVQモデルとRCEモデル、BPネットワークはいずれも学習データ数の増加とともに正解率も向上する傾向が見られるが、提案手法はデータ数が50個の段階で90%程度の平均認識率を示し、100個以上の段階ではさらに高い精度を達成している。LVQモデルでは、LVQ1およびLVQ2ともに同程度の性能を持ち、学習データ数が十分多い200個以上の場合には提案手法を約0.4%上回る精度を示す。しかし、学習データ数が50個、100個と少ない場合には25%ないし79%程度の低い認識率となり、提案手法に較べて汎化性に優れているとはいえない。以上より、提案手法は従来のRCEモデルやLVQモデルと比較して、汎化性に優れた性質を持つとともに、表2から明らかなように高速な学習が可能であるといえる。

5. まとめ

本論文では信頼度を導入した信頼度投票競合ネットワークを提案するとともに癌細胞の診断問題に応用し、その有効性を検討した。ベクトル量子化法はLVQ1、LVQ2、RCEネットワークなど多くの学習型アルゴリズムの基礎となっており、最近では免疫ネットワークとの融合など新しい応用が進められているが⁽¹⁴⁾⁽¹⁶⁾、構造や学習アルゴリズムの簡潔さと少数の学習パターンから高い汎化性・分類性能を達成できる点で提案手法は優れているといえる。本論文の要旨は次のようにまとめられる。

- (1) Cooperらによる従来のRCEモデルに対して、信頼度を導入した競合ネットワークを提案した。
- (2) 提案手法を乳癌細胞の診断問題へ応用し、従来のRCEモデルと比較した結果、提案手法は最高95.7%、RCEモデルは最高84.2%となり提案手法が優れた結果を示すことを明らかにした。
- (3) また、提案手法では従来のRCEモデルやBPネットワークよりも高速な学習が可能であり、同時にパターン分類能力が向上していることを示した。
- (4) さらに、汎化性が高く、少ない学習データ数で優れた分類・診断が可能であることを示した。このことは、必ずしも十分な学習サンプルが得られないことがある実用的・応用的場面において大きな利点となる。

今後、提案手法をより詳しく調査するとともに、他の古典的パターン分類器等との詳細な比較、最適な信頼度の定義と信頼度投票方式の検討・改良を行い、提案手法のパターン分類性能の一層の向上を図る方針である。

(平成12年6月29日受付、平成13年2月19日再受付)

文 献

- (1) 鳥脇純一郎：“認識工学”，コロナ社(1993)

- (2) D.Wang: "Pattern recognition, Neural networks in perspective", IEEE Expert, pp.52-60, Aug.(1993)
- (3) 森健一: "パターン認識", 電子情報通信学会(1993)
- (4) R.Duda and P.Hart: "Pattern Classification and Scene Analysis", Wiley and Sons (1973)
- (5) S.Haykin: "Neural Networks, A Comprehensive Foundation", IEEE Computer Society Press(1995)
- (6) 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)
- (7) D.L.Reilly, L.N.Cooper, C.Elbaum: "A neural model for category learning", Biol. Cybern., 45, pp.35-41(1982)
- (8) 白井支朗, 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)
- (9) 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, No. 4, pp. 553-540(1997)
- (10) 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)
- (11) 橋詰明英, 本池順, 鈴木隆一, 山本真司: "標本内情報を用いた適応的好中球分類アルゴリズム", ME誌, vol. 3, No. 9, pp. 29-34(1989)
- (12) W.H.Wolberg, W.N.Street, D.Heisey, O.Mangasarian: "Computer-Derived Nuclear Features Distinguish Malignant From Benign Breast Cytology", Human Pathology, 26, pp.792-796(1995)
- (13) T.Kohonen, "The self-organizing map", Proc.IEEE, 78(9), pp.1469-1480(1990)
- (14) 鹿山昌宏, 杉田洋一, 諸岡泰男, 福岡昇平: "あいまい量子化ベクトルの導入による正常データのみを用いて構築した異常診断システムの性能向上方式", 電学論C, vol. 117-C, No. 8, pp. 1092-1100(1997)
- (15) 鹿山昌宏, 杉田洋一, 諸岡泰男: "免疫ネットワークとベクトル量子化を組み合わせたセンサ診断システム", 電学論D, vol. 115-D, No. 7, pp. 859-866(1995)

山城 毅

(非会員) 1945年2月22日生。1969年琉球大学工学部電気工学科卒業、同年1種非常勤職員(短期大学部事務室), 1972年文部技官, 1974年短期大学部助手, 1983年同講師, 1993年工学部講師。電子情報通信学会, 日本ロボット学会等の会員。

長山 格

(正員) 1966年10月20日生。1994年, 徳島大学大学院工学研究科システム工学専攻博士課程修了。琉球大学工学部情報工学科助手を経て, 1999年助教授。博士(工学)。ニューラルネットワーク, 信頼性工学, 画像情報処理, 知的信号処理, LSI アーキテクチャ等の研究と

教育に従事。電子情報通信学会, IEEE Computer Society, 日本神経回路学会, 情報処理学会等の会員。

名嘉村盛和

(正員) 1966年1月28日生。1991年, 琉球大学大学院工学研究科情報工学専攻修士課程修了。琉球大学工学部情報工学科助手を経て, 1996年助教授。博士(工学)。並列分散アルゴリズム, ペトリネット, LSI アーキテクチャ等の研究と教育に従事。電子情報通信学会,

情報処理学会等の会員。