ファジィ推論を用いた心臓超音波画像における心筋症のコンピュータ支援診断

蔡　篤儀†　　李　鎔範†

Fuzzy Reasoning Based Computer-Aided Diagnosis for Automated Discrimination of Myocardial Heart Disease from Ultrasonic Images

Du-Yih TSAI† and Yongbum LEE†

あらまし　超音波診断法は，簡便で有用な画像診断法の一つである．この診断法は，心臓疾患の診断にも発揮され，広く用いられてきた．心臓疾患の中で心筋症は比較的よくある病気の一種である．この心筋症をより正確に診断できることは重要である．本論文では，心筋症のコンピュータ支援診断システムの構築を目的とし，ファジィ推論に基づく支援診断の一手法を提案する．提案手法は，従来よく用いられる三角形や台形のようなメンバシップ関数ではなく，ガウス分布形メンバシップ関数を用いることと，メンバシップ関数の形を最適化するために GA を用いることを特徴としている．提案法の性能を，正確度（正診率），感度（有病正診率）及び特異度（無病正診率）の三つのインデックスで評価した．その結果，本手法が支援診断に有効であることが示唆された．

キーワード　超音波医用画像，コンピュータ支援診断，ファジィ推論，遺伝的アルゴリズム，心筋症

1. まえがき

超音波診断法は，内科・外科を問わず各科多方面において最も普及した，簡便で有用な画像診断法の一つである．この診断法の利点としては，非観血・非侵襲でアプローチの仕方が自由であることと，体内の組織・器官の状況をリアルタイムで写しだし観察できることがあげられる．この特性は心臓疾患の診断にも発揮され，広く用いられてきた [1].

心臓超音波診断法による心臓疾患の診断は，多くの診断法の中では比較的簡単である．しかし実際の医療現場において，心臓機能の正常・異常の判別は，その医師個人の主観や経験に依存しており判断の基準はあいまいである．そのためコンピュータによる画像解析から，人間の判断だけでは得にくい定量的な情報を抽出・分析し，その結果を “第 2 の意見” として医師に提示することにより，診断結果のばらつきを減少させることのできる手法の開発が望まれている [2], [3].

心臓疾患の中で心筋症はよくある病気の一種である．心筋症は原因不明の心臓の病気であり [1]，拡張型心筋症（dilated cardiomyopathy：DCM）や肥大型心筋症（hypertrophic cardiomyopathy：HCM）などに分類されている．DCM は心内腔の拡大（収縮末期と拡張末期のどちらも）を主として，拡大に見合う肥大を伴わない心筋症である．一方，HCM は非均等型の左室肥大の心筋症である．筆者らはこれまでに，超音波画像における心筋症を対象に，最短距離判別法 [4]〜[7]，誤差逆伝搬学習（back-propagation：BP）に基づくニューラルネットワーク（neural network：NN）[8]〜[10] 手法（以下，BP-NN 法とする），遺伝的アルゴリズム（genetic algorithm：GA）[10]〜[13] に基づく NN 手法（以下，GA-NN 法とする）などを用いたコンピュータ支援診断（computer-aided diagnosis：CAD）の手法を提案してきた [14]〜[20]．しかし，これらの手法は，判別率の観点から，臨床に応用するにはまだ不十分であった．

そこで，本論文では判別率を更に向上させることを目的とし，ソフトコンピューティングの一種であるファジィ推論 [21]〜[23] を用いた CAD 手法を新たに提案する．提案手法は，ファジィ推論においてガウス分布形のメンバシップ関数を用いること，及び GA を

† 新潟大学医学部保健学科放射線技術科学専攻，新潟市
Department of Radiological Technology, School of Health Sciences, Niigata University, Niigata-shi, 951–8518 Japan

用いてメンバシップ関数の形状を最適化することを特徴としている．本論文では，提案手法の原理とアルゴリズムについて述べ，更に本手法の有効性を明らかにするために，従来手法との比較・検討を行う．

2. 対象画像及び画像特徴の抽出

2.1 対象画像

本研究で対象とする画像は心臓超音波画像 45 例で，その内訳は正常例 23 例，DCM12 例，HCM10 例である．本実験では両者をまとめて異常カテゴリーとし，正常と異常の 2 種類のカテゴリーを扱う．本論文では，超音波診断装置 SSH-160A（東芝）で出力された画像を用いる．なお，この装置で採集された画像はすべて 64 階調画像である．使用したトランスデューサは送受信とも 2.5 MHz の 1 個のプローブで，検査法は経胸壁 B モード心エコー法である．各症例はあらかじめ診断医によって正常，DCM，HCM のどれかに分類されており，1 例につき拡張末期と収縮末期の画像 2 枚がある．これらの画像はイメージスキャナでコンピュータに取り込むが，その際の取り込み条件は，解像度 200 dpi，8 ビット，白黒濃淡画像とした．取り込み後の画像サイズは縦横ともに 256 画素である．本研究では拡張末期と収縮末期の画像を直接使用せず，合成画像を作成し用いた．ここでいう合成画像とは，2 枚の画像の同位置画素に注目し，輝度（階調値や濃度ともいう）の高い方を出力画素の輝度とした画像である．2 枚の画像 $f(x,y)$ と $g(x,y)$ の合成画像 $h(x,y)$ は次式のようになる．

$$h(x,y) = \max[f(x,y), g(x,y)] \tag{1}$$

ここで，本論文で用いる超音波心臓像では，心臓内部が黒く（低濃度），心臓輪郭が白く（高濃度）写る．式 (1) を用いた理由は，鑑別診断時に判断材料とする拡張末期，収縮末期の両画像における心臓の輪郭及び形状を 1 枚の画像に現すためである．図 1 に本研究で使用した超音波心臓短軸断面像の 1 例を示す．(a)，(b) 及び (c) はそれぞれ拡張末期，収縮末期及び合成画像である．

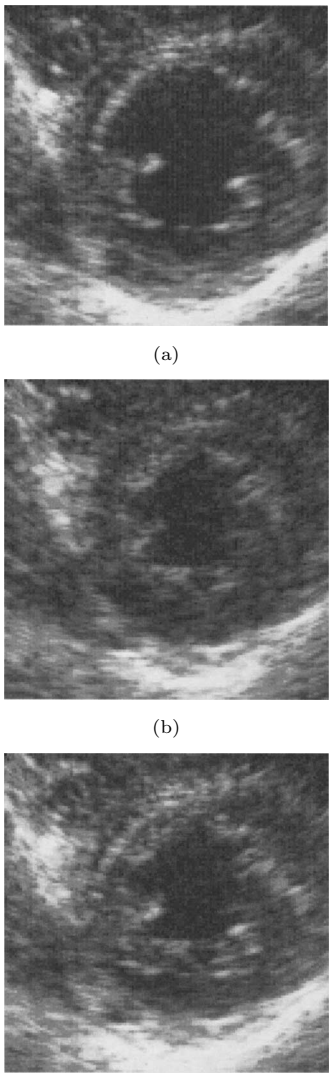

図 1 使用する超音波心臓断面像の 1 例 (a) 拡張末期，(b) 収縮末期，(c) 合成画像

Fig. 1 Examples of echocardiograms. (a) end-diastole, (b) end-systole, and (c) composite images.

2.2 画像特徴の抽出

本論文では，超音波画像に特有なスペックルにおけるパターンが組織領域ごとに異なっていることに着目し，濃度共起行列に基づく統計的特徴量を利用する．濃度共起行列とは，画像内の濃度 m をもつ画素から一定の変位 $\delta = (r, \theta)$ だけ離れた画素の濃度値が n である頻度（あるいは確率）をすべての濃度対 (m, n) について求めたものである．本研究では濃度共起行列から得られる 12 種類の特徴量 [24] の中で，経験的にもっとも有効であった angular second moment（Q_1），contrast（Q_2），correlation（Q_3），entropy（Q_4）の四つの特徴量を選択し用いる．また，$r = 1$，$\theta = 0°$，$45°$，$90°$，$135°$ とし，各方向の平均値を最終的な特

徴値とする．Q_1 はテクスチャの均一性を表す特徴であり，特定の濃度対が多く存在する場合，その値は大きくなる．Q_2 は画素対の濃度差（$|m-n|$）の画像全体における平均を表しており，その濃度差すなわちコントラストの高い画素対が多いほど，値が大きくなる．Q_3 は，-1 から 1 の値となり，δ の関係にある画素対の濃度値が比例している場合ほど値が大きくなる．つまり δ 方向の周期性パターンを示している．Q_4 は，共起行列内の値が均等に割り当てられているほど大きくなり，均一性とは逆の性質を示す．なお，本論文で提案する GA を適用したガウス分布形メンバシップ関数によるファジィ推論法では，これらの各特徴量からそれぞれメンバシップ関数を作成し，判別を行う．

3. 提案手法

3.1 ファジィ推論法の概要

ファジィ理論が提案されてから 35 年以上になる．その応用分野も多岐にわたり，医療分野への適用の試みも行われている [25]．ファジィ理論に基づいた推論がファジィ推論である．推論の知識ベースは If〜Then $\cdots$ 形式のファジィ推論規則（またはファジィ・ルール），入出力値を判断する前件部及び後件部メンバシップ関数から構成される．ファジィ推論には，いくつかの種類があるが，中でも簡略化ファジィ推論法はよく用いられる手法の一つである [26], [27]．本研究では簡略化ファジィ推論法を用いる．簡略化推論法におけるファジィ・ルールの例を式 (2) に示す．

$$\begin{aligned}&\text{rule } i : \text{if } \ x_1 \ \text{ is } \ c_{i1}, \ \text{and} \ldots, \\ &\qquad \text{and } \ x_M \ \text{ is } \ c_{iM} \ \text{ then } \ y \ \text{ is } \ w_i \end{aligned} \tag{2}$$

ここで，$i\,(i=1,2\ldots M)$ はルール番号，$x_1,\ldots,x_M$ はファジィ推論への入力変数，y は推論出力，$c_{i1},\ldots,c_{iM}$ は各入力変数について定義されたファジィ・ラベルである．また，w_i はファジィ・ルールの後件部実数である．

メンバシップ関数には，三角形，形が英文字の S のような S 関数，中央が凸の関数などがあるが，本研究では，前件部には式 (3) に示すような，ガウス分布形メンバシップ関数を用いる．

$$f(x) = \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\} \tag{3}$$

ただし，μ は平均値，σ は標準偏差である．式 (3) から明らかなとおり，あるカテゴリーに属する多数の画像データから抽出した，ある画像特徴量の平均及び標準偏差がわかれば，図 2 の実線に示すようなファジィ・ルールのメンバシップ関数を決定することができる．しかし，画像データ数が小規模である場合は，このメンバシップ関数で必ずしも同一カテゴリーの特性を完全に反映できるとは限らない．特に分布の端の周辺にある症例は誤認識されやすい．そこで，本論文では，この問題を解消するために GA によるガウス分布形メンバシップ関数形状の最適化手法（以下 GA-Fuzzy 法とする）を考案する．

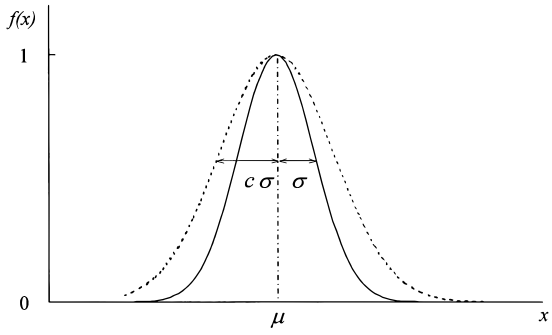

図 2　ガウス分布形メンバシップ関数
Fig. 2　Gaussian-distributed membership functions.

3.2 遺伝的アルゴリズムによるメンバシップ関数の最適化

3.2.1 ファジィ・ルールの遺伝子コード化

本手法では，式 (4) に示すような標準偏差 σ に係数 c を掛けたガウス分布形メンバシップ関数を考える．c はメンバシップ関数の幅に対応した係数であり，その値は GA に基づく学習法で調整し最適化を行う（図 2 の破線）．

$$f(x) = \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{c\sigma}\right)^2\right\} \tag{4}$$

例えば，N 個のファジィ・ルールがあり，それぞれのルールに M 個のメンバシップ関数を用いている場合，図 3 に示すように 1 列に並べることで，これを一つの個体とみなすことができる．この個体の中には $M \times N$ の染色体（または遺伝子）が存在する．本手法では各染色体を一つの変数と考える．また各変数を 8 bits の 2 進数 $(0,1)$ で表す．ここで，本論文の心筋症鑑別の例では，四つのメンバシップ関数（濃度共起行列から求めた特徴量 Q_1〜Q_4 に対応）で構成された二つのファジィ・ルール（ルール 1：normal rule, ルール 2：abnormal rule）を用いる．そのため，一つ

の個体の中には 8 個の染色体が存在する（図 4）．一方，後件部のメンバシップ関数には，傾きが 45° かつ最大値が 1 の直線を用いる．

3.2.2 GA 操 作

GA では，ある世代を形成している個体の集合，すなわち個体群を基本単位として進化を行う．GA の基本的操作には，選択，交差，突然変異の三つがある．処理手順として，まず処理のはじめに初期世代の個体群を生成する．この生成された個体群の中で環境への適応度の高い個体が高い確率で生き残るように選択を行う．更に，交差や突然変異を行うことで次の世代の個体群が形成されていく．この操作をあらかじめ設定した終了条件を満たすまで続け，終了するまでに得た最良の個体を問題の最適解とする．

GA によるメンバシップ関数の最適化の手順を図 5 に示す．各手順について以下に述べる．

（1） まず初期世代の個体群として図 4 に示したようなコードを 200 個ランダムに決定する．

（2） 各個体について，二つの評価関数を用いて各個体の適応度を算出する．評価関数の詳細については，**3.3** で述べる．

（3） 次に適応度の高い順に個体を並び替える．

（4） 1 点交差及び突然変異を施す．方法は，まず，ランキングの上位 70%（140 個）の i 世代の集団中の個体を親として 1 点交差を行い，子を 140 個生成する．このとき，残りの 30%（60 個）の親は淘汰される．そして，140 個の親はそのまま $i+1$ 世代に移し，集団中の個体総数を合わせるため，新たに生成された 140 個の子のうち，適応度の高い上位 60 個を $i+1$ 世代に移し，残りは破棄する．次に，集団中の 5%の個体（ランダムに選択）に突然変異を行う．

（5） （2）〜（4）までを 1 世代とし，50 世代まで終了した時点で最も適応度の高い個体を最適解とする．

なお，最大世代数は実験的に決定した値であり，複数の組合せの学習データを用いて実験した結果，そのすべてにおいて 50 世代までに最大適応度が 1.0 となったためである．また同様に，個体数，交差率，突然変異率なども実験的に決定した値である．ここで，図 6 に各世代における最大適応度の変移グラフの一例を示す．ここでの適応度は，**3.3** で述べる評価関数式 (10) で求められる f_1 の計算値に等しい．このグラフでは 25 世代以降に最大適応度が 1.0 になっていることがわかる．

3.2.3 非ファジィ化の方法

メンバシップ関数最適化のための学習及び判別を行うとき，後件部のメンバシップ関数を強制的に一つの数値で代表させなければならない．この操作を非ファジィ化（defuzzification）と呼ぶ．最もしばしば用い

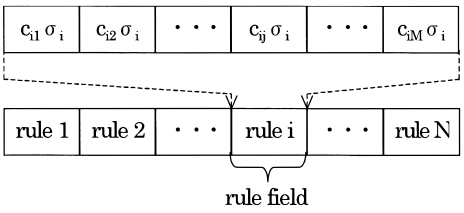

図 3 N 個のファジィ・ルールから構成される個体
Fig. 3 Configuration of an individual consisting of N fuzzy rules.

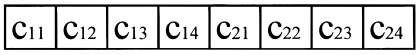

図 4 二つのファジィ・ルールからなる個体の中に 8 個染色体が存在する様子
Fig. 4 Two-rule set presented by a string having eight variables.

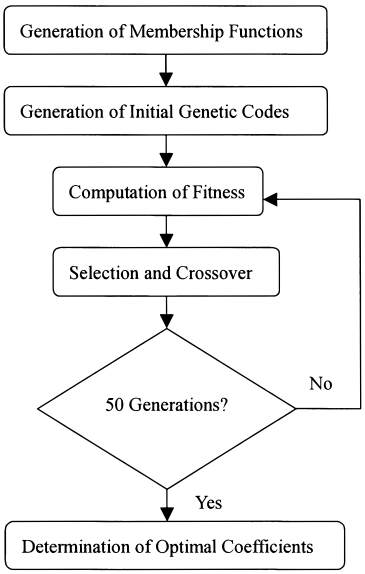

図 5 GA による最適化の手順
Fig. 5 Procedure of optimization using GA's.

られる方法は，結論として得られたメンバシップ関数の重心や面積の中心を求める方法である．本研究では，これらの方法の代わりに，最大のメンバシップ値を採用する MIN-MAX 合成高さ法を用いる [28]．以下，本手法での非ファジィ化について述べる．

まず，$\mu_{\mathrm{nor}}(Q_1)$，$\mu_{\mathrm{nor}}(Q_2)$，$\mu_{\mathrm{nor}}(Q_3)$，$\mu_{\mathrm{nor}}(Q_4)$ を正常カテゴリーのある画像から得た四つの統計的特徴量の値とし，同様に，$\mu_{\mathrm{ab}}(Q_1)$，$\mu_{\mathrm{ab}}(Q_2)$，$\mu_{\mathrm{ab}}(Q_3)$，$\mu_{\mathrm{ab}}(Q_4)$ を異常カテゴリーのある画像から得た四つの統計的特徴量の値とする．次に，両画像のそれぞれの特徴量の最小値を式 (5) と式 (6) で表す．

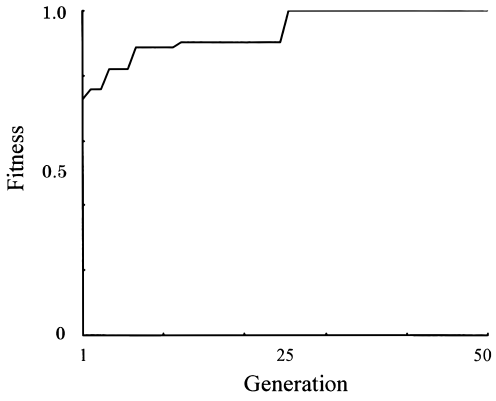

図 6　各世代における最大適応度の変移グラフ
Fig. 6　A graph of maximum fitness at each generation.

$$\mu_{\mathrm{nor}} = \mathrm{MIN}[\mu_{\mathrm{nor}}(Q_1), \mu_{\mathrm{nor}}(Q_2), \mu_{\mathrm{nor}}(Q_3), \mu_{\mathrm{nor}}(Q_4)] \tag{5}$$

$$\mu_{\mathrm{ab}} = \mathrm{MIN}[\mu_{\mathrm{ab}}(Q_1), \mu_{\mathrm{ab}}(Q_2), \mu_{\mathrm{ab}}(Q_3), \mu_{\mathrm{ab}}(Q_4)] \tag{6}$$

この操作を MIN（minimum）操作と呼ぶ．更に，式 (7) に示すように，値の大きいほうをとる操作，すなわち MAX（maximum）操作を行う．

$$\mu_{\mathrm{nor}\cup\mathrm{ab}} = \max[\mu_{\mathrm{nor}}, \mu_{\mathrm{ab}}] \tag{7}$$

最後に，推論の結果を次のように決める．

$$\text{If } \ \mu_{\mathrm{nor}\cup\mathrm{ab}} = \mu_{\mathrm{nor}} \qquad \rightarrow \text{正常} \tag{8}$$

$$\text{If } \ \mu_{\mathrm{nor}\cup\mathrm{ab}} = \mu_{\mathrm{ab}} \qquad \rightarrow \text{異常} \tag{9}$$

例えば，ある未知の画像特徴データを入力したとき，図 7 に示すように，ルール 1 の後件部の最小値（MIN），すなわち正常の確信度が 0.4，ルール 2 の後件部の MIN，すなわち異常の確信度が −0.2 になったとする．この場合，両者の絶対値の MAX を採用するので，認識用の未知データは正常であると判別される．ここで，$\mu_{\mathrm{nor}} = \mu_{\mathrm{ab}}$ の場合は，判別不能であるため誤認識となる．

3.3　ファジィ推論による判別

2.1 で述べた 45 例の画像データを Group A（正常 12 例，異常 12 例）と Group B（正常 11 例，異常 10

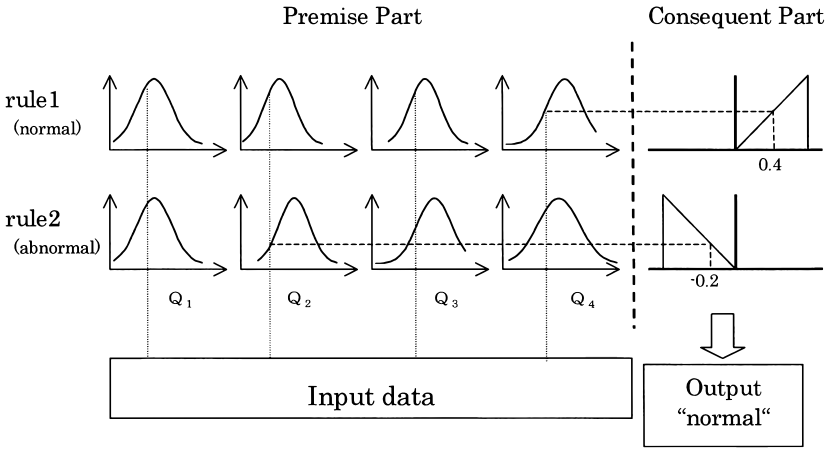

図 7　ガウス分布形メンバシップ関数を用いたファジィ推論
Fig. 7　Fuzzy reasoning using 8 Gaussian-distributed membership functions.

例）に分ける．Group A を学習用データとし，学習後 Group B を判別させる．また，学習データと認識データを入れ換えて同じ実験を行い，結果の値の平均をとる．

学習の段階で，式 (10) と式 (11) に示している評価関数を用いて適応度を算出する．

$$f_1 = \frac{n-m}{n} \tag{10}$$

$$f_2 = \sum_{i=1}^{n}(d_{1i} - d_{2i})^2 \tag{11}$$

ここで，式 (10) の n は学習用の画像データの総数，m は学習用データを順次入力して認識された場合の誤認識の回数である．$m = n$，すなわち入力されたデータすべてが誤認識であった場合は $f_1 = 0$ となり，$m = 0$，すなわち入力されたデータがすべて正しく認識された場合は $f_1 = 1$ となる．式 (11) の d_{1i} と d_{2i} は，それぞれ i 番目の入力データに対するルール 1 とルール 2 の各メンバシップ関数から得られる最小値，すなわち正常の確信度と異常の確信度を表している．メンバシップ関数の最小値の差が大きいほど f_2 は大きくなる．f_1 と f_2 から得た値を用いて，次の規則に従い集団中の個体を並べ換える．

（1） 集団中の個体を，f_1 の高い順に並べ換える．

（2） 集団中に複数の個体が同じ f_1 の値をもつ場合は，f_2 の高い順に並べ換える．

設定された世代数まで学習が完了すれば，その時点の一番適応度が高い個体の遺伝子コードを最適係数とする．得られた最適係数を用いてルールごとの各メンバシップ関数の幅（$c\sigma$）を決定し，認識用データを順次入力して判別を行う．なお，具体的な数値の一例として，Group A を学習データとしたとき，正常例に対する特徴量 Q_1 の平均値 μ は 0.137，標準偏差 σ は 0.037 であった．また，そのときの最適係数 c は 1.21 であり，最終的なメンバシップ関数の幅は 0.045 となった．

4. 実験結果と考察

表 1 に本研究で提案している GA-Fuzzy 法，そして筆者らが以前報告した BP-NN 法と GA-NN 法による判別結果を示す．また，GA によるメンバシップ関数の最適化の有効性を確認するため，GA を使用しない場合の判別結果も調べた．

これらの支援診断システムの性能は，ROC（receiver operating characteristic）解析でよく用いられる accuracy（正確度：正診率），sensitivity（感度：有病正診率）及び specificity（特異度：無病正診率）を用いて比較評価を行った．これらの三つのインデックスは，式 (12)〜式 (14) で定義されている [29]．

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \tag{12}$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \tag{13}$$

$$\text{Specificity} = \frac{TN}{TN + FP} \tag{14}$$

ここで，TP，FP，TN 及び FN は，それぞれ true positive，false positive，true negative 及び false negative である．

表 1 から，まず accuracy だけを比較したとき BP-NN 法，GA-NN 法及び Fuzzy 法に比べて，GA-Fuzzy 法は 95.9% と高い値を示し，最も優れた手法と言える．しかし，判別率だけでシステムの性能の比較をすることは不十分である．それは False Positive か，あるいは False Negative かでは，診断後の受診者に与える影響に大きな違いを見せることになるからである．したがって，sensitivity 及び specificity の二つの評価パラメータを用いる．

Sensitivity のもつ意味は受診者の体が実際に異常で

表 1 異なる CAD 手法の性能比較
Table 1 Performance comparison for various CADs.

Method	Data set	TP	TN	FP	FN	Accuracy	Sensitivity	Specificity
BP-NN	A	9	11	1	3	82.1%	83.0%	80.8%
	B	10	7	3	1			
GA-NN	A	10	12	0	2	88.7%	91.7%	86.4%
	B	10	8	3	0			
Fuzzy	A	10	11	1	2	91.4%	91.7%	91.3%
	B	10	10	1	0			
GA-Fuzzy	A	10	12	0	2	95.9%	91.7%	100%
	B	10	11	0	0			

あった場合について正確に判別できたかを示し，また specificity は実際に正常であった場合について正確に判別できたかを示す．実験結果から sensitivity は BP-NN 法の 83.0%を除き，他の 3 手法は共に 91.7%であり，有意差はない．BP-NN 法の sensitivity が低い理由としては，FN の症例数は他の方法によるものよりも多いことがあげられる．Specificity については GA-Fuzzy 法が 100%で最も高く，Fuzzy 法，GA-NN 法及び BP-NN 法の順に低くなる．またこの結果は GA によるメンバシップ関数の最適化が，有効であることを示している．

NN を利用した BP-NN 法と GA-NN 法では，GA-NN の方が良好な結果を示した．NN で重要なことは重み係数の決定である．これら二つの手法の大きな違いはその重み係数の決定方法である．BP-NN 法では出力信号と教師信号との比較で，そこに生じた誤差信号をネットワークにフィードバックさせ，誤差が無くなるように NN の重み係数を修正し決定する．しかし，local minimum に陥ることもあり，必ずしも最適な重み係数を見出せるとは限らない．一方，GA では突然変異などのパラメータ設定を適切に行うことで，local minimum に陥る問題をある程度意識的に回避することができる．そのため，本研究では BP-NN より GA-NN のほうが良好な結果を得たと考える．

ファジィ推論を用いた場合では，Fuzzy 法よりも GA-Fuzzy 法の方が良好な結果を示した．判別率が向上した理由として，入力データがメンバシップ関数の端の値になる症例であったときに，ファジィ推論だけでは対処できず，誤認識の原因となったと考えられる．そのため，GA を用いてメンバシップ関数の幅を最適化したことが，判別率の向上に寄与したと考える．

NN を用いた場合と Fuzzy を利用した場合とでは，Fuzzy を用いた方が判別率は良好であった．両手法ともあいまいさを取り扱う理論であるが，両者の違いは画像から得た特徴量のとらえ方にある．結果から，Fuzzy 推論の方が特徴量のとらえ方が優れており，また，GA による Fuzzy メンバシップ関数の最適化も有用であったと考える．なお，文献 [15] では，線形判別法と NN の比較実験を行っており，NN のほうが有用であったと結論づけている．それに従って，今後は NN と Fuzzy の特徴量のとらえ方に対する厳密な比較実験をシミュレーション等で行う必要があると考える．

また，今後は症例を増やしてからの再実験が不可欠であり，母体数（学習データ数）による Fuzzy 法と GA-Fuzzy 法の有意差なども検定する予定である．つまり，どれぐらいの学習データがあれば，GA によるメンバシップ関数の補正が不要になるかなどを検討する．また，実際に臨床現場での試用を考えると，多種多様の症例が必要であり，そのためには症例の収集が今後の最も大きな課題であると考える．

5. む す び

本論文では，ファジィ推論を用いたコンピュータ支援診断の一手法を提案した．この手法の特徴は，ガウス分布形のメンバシップ関数を用いたことと，GA を用いてそのメンバシップ関数の形状を最適化したことである．本手法の有効性を明らかにするため，従来の手法との比較を行った．Accuracy, sensitivity 及び specificity の結果から，本手法によるシステムが評価対象とした心筋症の CAD としては最も優れたシステムであることがわかった．また，これらの実験結果から，GA によるメンバシップ関数の最適化が有効であることを示した．

今後の課題としては，症例を増やすこと，簡略化したファジィ・ルール後件部のメンバシップ関数形状の再検討，等があげられる．

謝辞　本研究を進めるに当り，画像の提供と討論をして頂いた岐阜県立病院の富田政明医師（前岐阜大学医学部第 2 内科）に感謝する．本研究の一部は，医療法人くりくり会の研究助成金及び電気通信普及財団の助成金の援助による．

文　　献

[1] 小塚隆弘，画像医学プログレスシリーズ 1—心臓超音波，中山書店，東京，1992.
[2] 土井邦雄，“世界における CAD 開発研究の動向,” INNERVISION, vol.8, no.9, pp.16–17, Sept. 1993.
[3] 鳥脇純一郎，“画像診断支援—研究開発の動向,” Med. Imag. Tech., vol.12, no.3, pp.171–179, May 1994.
[4] 尾崎　弘，谷口慶治，画像処理—その基礎から応用まで，コロナ社，東京，1989.
[5] 安居院　猛，長尾智晴，画像の処理と認識，昭晃堂，東京，1992.
[6] R.C. Gonzalez and R.E. Woods, Digital Image Processing, Addison-Wesley Publishing, Cambridge, 1992.
[7] 内田　勝 監修，ディジタル放射線画像，オーム社，東京，1998.
[8] P.D. Wasserman, Neural Computing, Van Nostrand Reinhold, New York, 1989.
[9] J.A. Anderson and E. Rosenfeld, Neuro-Computing Foundations of Research, The MIT Press, Cambridge, 1990.

[10] 萩原将文，ニューロ・ファジイ・遺伝的アルゴリズム，産業図書，東京，1994.
[11] D.E. Goldberg, Genetic Algorithm in Search, Optimization, and Machine Learning, Addison-Wesley Publishing, New York, 1989.
[12] 米澤保雄，遺伝的アルゴリズム—進化理論の情報科学，森北出版，東京，1994.
[13] 伊藤斉志，遺伝的アルゴリズムの基礎—GA の謎を解く，オーム社，東京，1994.
[14] D.Y. Tsai and M. Tomita, "A computer-aided system for discrimination of dilated cadiomyopathy using echocardiographic images," IEICE Trans. Fundamentals, vol.E78-A, no.12, pp.1649–1654, Dec. 1995.
[15] 蔡　篤儀，渡邉伸司，小島克之，富田政明，"超音波画像処理を用いた心筋症の支援診断システム，" 医用画像情報学会雑誌，vol.13, no.2, pp.61–69, May 1996.
[16] 蔡　篤儀，渡邉伸司，小島克之，富田政明，"遺伝的アルゴリズムによる伸筋鑑別回路網の荷重値決定，" Med. Imag. Tech., vol.15, no.4, pp.557–558, July 1997.
[17] D.Y. Tsai, S. Watanabe, K. Kojima, and T. Tomita, "Comparative performance study of BP- and GA-based neural networks for automated classification of heart diseases from ultrasound images," Proc. CARS'98-Computer Assisted Radiology and Surgery, pp.248–253, Tokyo, Japan, June 1998.
[18] D.Y. Tsai, "Classification of heart diseases in ultrasonic images using neural networks trained by genetic algorithm," Proc. IEEE Fourth International Conference on Signal Processing (ICSP'98), vol.2, pp.1213–1216, Peiking, China, Aug. 1998.
[19] D.Y. Tsai, Sh. Watanabe, Sa. Watanabe, K. Kojima, and I. Yamada, "Application of a genetic-algorithm-based fuzzy reasoning for classification of myocardial heart disease," Proc. CARS'99 Computer Assisted Radiology and Surgery, pp.398–402, Paris, France, June 1999.
[20] D.Y. Tsai and S. Watanabe, "A method for optimization of fuzzy reasoning by genetic algorithms and its application to discrimination of myocardial heart disease," IEEE Trans. Nucl. Sci., vol.46, no.6, pp.2239–2246, Dec. 1999.
[21] 水本雅晴，ファジイ理論とその応用，サイエンス社，東京，1990.
[22] 寺野寿郎，浅居喜代治，菅野道夫，ファジイシステム入門，オーム社，東京，1990.
[23] 柴田崇徳，福田敏男，ファジイロボット，朝倉書店，東京，1997.
[24] 高木幹雄，下田陽久，画像解析ハンドブック，東京大学出版社，東京，1991.
[25] 有田清三郎，メディカル・ファジイのはなし，日刊工業新聞社，東京，1992.
[26] 菅野道夫，ファジイ制御，日刊工業新聞社，東京，1996.
[27] 大木　誠，森山敏明，大北正昭，"可変型ビット選択確率を用いた遺伝的アルゴリズムによるファジイ推論の最適化，" 信学論（D-II），vol.J81-D-II, no.1, pp.127–136, Jan. 1998.
[28] 寺野寿郎，浅居喜代治，菅野道夫，応用ファジイシステム入門，オーム社，東京，1990.
[29] M.G. Penedo, M.J. Carreira, and A. Mosquera, "A neural-network-based approach to lung nodule detection," IEEE Trans. Med. Imaging, vol.17, no.6, pp.872–880, Dec. 1998.

（平成 13 年 2 月 26 日受付，6 月 18 日再受付）

蔡　　篤儀　（正員）

1970 台湾国立成功大学・工・電機卒．1970〜1976 民間会社エンジニアとして勤務．1979 岐阜大大学院工学研究科（修士）了．1985 年工博（名古屋大）．岐阜医療技術短期大学助教授，岐阜高専電気・助教授，教授を経て，2000 より新潟大学医学部教授．医療分野における画像処理や認識などの研究に従事．IEEE（Senior），SPIE，日本エム・イー学会，日本医用画像工学会，医用画像情報学会等各会員．

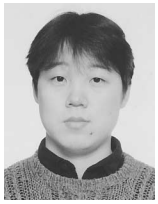

李　　鎔範　（正員）

1996 岐阜大・工・応情卒．2001 同大大学院博士後期課程了．同年新潟大医学部保健学科助手．工博．医用画像を扱った画像処理・認識に関する研究に従事．日本医用画像工学会，日本放射線技術学会，医用画像情報学会各会員．