

メンバーシップ関数の形状に着目した
ファジィルールの自動調整に関する研究

2006年1月

鳥取大学大学院工学研究科博士後期課程

権田 英功

論文概要

本論文は、「メンバーシップ関数の形状に着目したファジィルールの自動調整に関する研究」について、以下の6章にまとめたものである。

第1章では、ファジィ推論ルールの調整に関する研究背景、問題点を述べ、メンバーシップ関数の形状に着目して学習データの分布に適応するメンバーシップ関数を提案、種類選択を行ない、より精密なモデリングを目指すという、本研究の目的を示した。

第2章では、ファジィ制御におけるファジィ推論ルールの自動調整にニューラルネットワークの学習機能を利用する方法において、学習データが急激に変化する分布に対応するために、ファジィ推論ルールのメンバーシップ関数を二等辺三角型から2つの直角三角形からなるメンバーシップ関数に変更する手法を提案した。また、シミュレーテッドアニーリングの手法を取り入れメンバーシップ関数の頂点位置幅を温度パラメータにより可変とし、スムーズに局所最適解を回避し大域最適解に近づける方法を提案した。本方法によって、学習データが急激に変化する場合でも、メンバーシップ関数を適切に配置できることを示すことができた。

第3章では、第2章と同様にファジィ制御におけるファジィ推論ルールの自動調整にニューラルネットワークの学習機能を利用する方法において、遺伝的アルゴリズムの手法を付加しメンバーシップ関数の適否の判定、種類の選択及びその最適化の可能な遺伝子を個体に組み込んだ。これにより、モデルの形状に適合した1種類または複数種類のメンバーシップ関数を選択することができ、被制御モデルをあらかじめ準備したメンバーシップ関数に関して最小の個数で表現できることを示した。

第4章では、第3章の手法を多入出力学習データに適用した。これにより、多入出力学習データに対してもモデルの形状に適合した1種類または複数種類のメンバーシップ関数を選択することができ、被制御モデルをあらかじめ準備したメンバーシップ関数に関して最小の個数で表現できることを示した。また、学習後のモデル関数の観点において単一種類のメンバーシップ関数単独で使用した場合と比較し第3章の手法は優れており、さらに学習データによる最小平均自乗誤差から検査データによる最小平均自乗誤差の増加量についても単一種類のメンバーシップ関数単独で使用した場合と比較し最小であることを示した。第3章の手法は汎化能力についても有効であることが確認できた。

第5章では、応用について述べた。第2章と同様にファジィ制御におけるファジィ推論ルールの自動調整にニューラルネットワークの学習機能を利用する方法において、遺伝的アルゴリズムの手法によるメンバーシップ関数の種類選択を付加し、時系列加速度脈波データのモデリングを行ない、形状特徴量をベクトルとして取り出した。さらに、自己組織化マップ(SOM)により時系列加速度脈波データの分類を行なった。これにより、学習データの分布に適合したメンバーシップ関数が選択され、健常、インフルエンザ、中年女性更年期、動脈硬

化の分類は可能であることを示した。また、加速度脈波アトラクタ形状のモデリングを行ない、自乗誤差をアトラクタの平行度、定常度の指標として用いることが可能であることを確認した。

第6章では、本研究における総括を行ない、今後検討すべき課題について述べた。

目次

論文概要	i
主要記号	v
主要略語	vii
第1章 序論	1
第2章 学習データが急激に変化する分布におけるファジィルールの自動調整	6
2.1 序言	6
2.2 学習データが急激に変化する分布に対応した MSF を用いたファジィ推論	6
2.2.1 簡略化ファジィ推論	6
2.2.2 学習データが急激に変化する分布に対応した MSF	7
2.3 ニューラルネットワークによる学習	7
2.3.1 簡略化ファジィ推論の NN 表現	7
2.3.2 学習アルゴリズム	9
2.3.3 学習の手順	12
2.4 SA の手法を用いた局所最適解の回避	14
2.4.1 MSF の移動による局所最適解の回避	14
2.4.2 SA 法を用いた MSF の再配置	14
2.5 シミュレーション	16
2.5.1 1 入力 1 出力の関数近似問題	16
2.5.2 2 入力 1 出力の関数近似問題	24
2.6 結言	27
第3章 種々の MSF で構成されるファジィルールの自動調整	29
3.1 序言	29
3.2 種々の MSF を用いたファジィ推論ならびに学習	29
3.3 GA の手法を用いた局所最適解回避	30
3.3.1 MSF の再配置による局所最適解の回避	30
3.3.2 GA 法を用いた MSF の再配置	32
3.4 シミュレーション	34
3.4.1 1 入力 1 出力の関数近似問題	34
3.4.2 2 入力 1 出力の関数近似問題	41

3.5	結言	45
第4章	多入出力学習データへの適用と汎化能力	47
4.1	序言	47
4.2	多入出力学習データにおけるファジィ推論方法	47
4.2.1	簡略化ファジィ推論	47
4.2.2	多入出力学習データにおける学習過程	48
4.3	MSF 形状選択による汎化能力	50
4.3.1	1 入力 1 出力の関数近似問題	50
4.3.2	2 入力 2 出力の関数近似問題	59
4.4	結言	63
第5章	加速度脈波のファジィモデリング	64
5.1	序言	64
5.2	脈波データの分類に特化した種々の MSF を用いたファジィ推論	64
5.2.1	簡略化ファジィ推論	64
5.3	脈波データの分類に特化した GA 法を用いた MSF の種類選択	65
5.4	脈波データの解析	69
5.4.1	時系列加速度脈波データのモデリング	69
5.4.2	自己組織化マップによる加速度脈波データの分類	74
5.4.3	加速度脈波アトラクタのモデリング	75
5.5	結言	86
第6章	結論	87
	謝辞	89
	参考文献	90
	研究業績	93

主要記号

記号	意味
R^i	ファジィルール (i :ファジィルールの番号)
x_j	前件部入力変数 (j :入力変数の番号)
$A_{ji}(x_j)$	メンバーシップ関数 (j :入力変数の番号, i :ファジィルールの番号)
w_i	後件部実数値 (i :ファジィルールの番号)
μ_i	適合度 (i :ファジィルールの番号)
y	制御量 (出力変数)
a_{ji}	メンバーシップ関数の頂点位置 (j :入力変数の番号, i :ファジィルールの番号)
b_{ji}	メンバーシップ関数の幅に相当するパラメータ (j :入力変数の番号, i :ファジィルールの番号)
c_{ji}, d_{ji}	メンバーシップ関数のグレード (j :入力変数の番号, i :ファジィルールの番号)
E	評価関数
t	学習回数 (繰り返し演算のカウンタ)
$\psi(t)$	学習回数が t のときのメンバーシップ関数の形状を決定するパラメータベクトル
$\mathbf{x}(p)$	連続な変数である x_j を離散化した $x_j(p)$ の p 番目の入力値を要素とする入力ベクトル
y^*	学習データ (出力)
K_w, K_a, K_b, K_c, K_d	学習係数
G_t	平均自乗誤差
ε	閾値
T^t	温度
F	目的関数

記号	意味
x'	摂動解
u	一様乱数
$N(x)$	x の近傍領域
c	温度カウンタ
y_k	多出力の場合の制御量 (出力変数)(k :出力変数の番号)
y_k^*	多出力の場合の学習データ (出力)(k :出力変数の番号)
w_{ki}	後件部実数値 (k :出力変数の番号, i :ファジィルールの番号)

主要略語

略語	意味
NN	Neural Network, ニューラルネットワーク
GA	Genetic Algorithm, 遺伝的アルゴリズム
FNN	Fuzzy Neural Network, ファジィニューラルネットワーク
MSF	Membership Function, メンバーシップ関数
SA	Simulated Annealing, シミュレーテッドアニーリング
RBF	Radial Basis Function, ガウス基底
DRTMSF	Double Right-angled Membership Function, 2つの直角三角形から成る直角三角型メンバーシップ関数
SOM	Self-Organizing Map, 自己組織化マップ
TPM	Trajectory Parallel Measure, 軌道平行測度法
Rp-dw	Recurrence plot draw white rate, リカレンスプロット白色描画率

第1章 序論

ファジィ理論は、1980年代後半から基礎技術として認められている。特にファジィ制御は種々の製品に応用され、ファジィ家電と呼ばれる家電製品が続々と登場した。ファジィ制御は、オペレータの経験的な知識をファジィ集合を含むルールの形で記述し、ファジィ推論により制御操作を決定する方法である。1974年にE.H.Mamdaniら[1]によってスチームエンジンの実験装置の制御に応用されその有効性が示された。その後、菅野ら[2]のファジィモデリングなどを含む多くの推論法が提案され、1990年代には、重工業や自動車、家電などの分野で多くの製品が開発された。ファジィ制御ではif-then形式のファジィルールで制御規則を表現できるので、モデルの構造が理解しやすく非線形な入出力関係を表現できる。しかし、専門家の知識から作成したルールだけでは実際の入出力関係を表現していない場合があり、ルールの調整が必要となる。

ファジィ理論の実用化の進展とともに、より複雑・大規模なシステムに対するファジィ知識を人手のみによって試行錯誤的に設計したり調整することは益々困難になってきている。このような問題を解決するため、与えられた入出力データを近似するようにファジィ推論ルールを調整する方法として、ファジィ推論とニューラルネットワーク (Neural Network; NN) を融合する手法 [3, 4, 5, 6, 7, 8, 9]、また遺伝的アルゴリズム (Genetic Algorithm; GA) といった最適化手法を用いてファジィ推論ルールの調整を行う方法 [10, 11, 12] など様々な手法が提案されている。

前者については、1990年市橋らの最急降下法を用いたファジィルールの調整法 [3] が提案され、1990年野村らによってより一層の収束性の向上が研究されている [5]。また、従来とは異なる観点から、1992年堀川らは NN にファジィ推論機構を導入したファジィニューラルネットワーク (Fuzzy Neural Networks; FNN) を提案した [6]。1995年岸田らは、不必要なルールを無くすことに主眼を置き、ルールの生成、削除機構を組み合わせた調整法を提案している [7]。

後者については、1994年野村らが前件部メンバーシップ関数 (Membership Function; MSF) を遺伝的アルゴリズムを用いて決定する手法を提案した [10]。また1995年福田らは、ルールの生成、削除機構に遺伝的アルゴリズムを応用した [11]。

NNの学習を利用してファジィ推論ルールの調整を行う手法 [5] では、制御対象の入出力データを用意しなければならないが、NNの学習則である最急降下学習により比較的短時間で制御対象の入出力関係を満足するファジィ推論ルールが得られるという利点がある。しかし、求めるべき解が局所最適解に陥る場合がある。

一方、遺伝的アルゴリズム [13] のような直接探索法を用いると、理論的には必ず解が得られることがわかっている。しかし、広い解空間において解を直接探索するために、最適解を得るには時間がかかるという問題点がある。また、最適な解であるかどうかを判断する評価関数を新たに定義しなければならないという問題点もある。

筆者らは、NNの学習機能を用いる手法をファジィ推論ルールの調整に取り入れている。入出力データさえ用意すれば比較的短時間でファジィ推論ルールの調整を行うことが可能である。しかし、この手法をそのまま適用した場合、制御対象によって、調整に時間がかかる、あるいは調整できないことがある。以前、宮田らはファジィ推論ルールの前件部 MSF を従来用いられてきた二等辺三角型 MSF から折れ線型 MSF に変更することを提案している [14]。これにより、MSFの形状を柔軟に変更することが可能になり、1個の推論ルールの表現能力が向上する。さらに、学習係数自動更新アルゴリズムにより局所最適解を回避することができる。よって、二等辺三角型 MSF を用いた場合と比べて、より短時間で、より少ない推論ルール数でファジィルールの調整を行うことができる。

しかし、これには2つの問題点がある。1つは、制御対象の入出力データが急激に変化する分布を持つ場合、つまり、制御対象の関数形が微分不可能あるいは不連続の場合、MSFの調整が困難になり局所最適解を回避できないことがある。もう1つは、二等辺三角型を起源とする折れ線近似的な MSF では、関数の汎化能力の面において、微分不可能あるいは不連続な入出力関係に対しては有効であるが、滑らかに変化する部分については劣ってしまう。

第2章において前者の問題点を回避する手法を提案する。制御対象の入出力データが急激に変化する分布を持つ場合、つまりカオス性を有するような非線型ダイナミカルシステムの同定、決定論的非線型予測 [15] を行う場合、上記の方法では局所最適解を回避できないことがある。従来からカオス時系列予測における関数近似問題に対しては、誤差逆伝搬アル

ゴリズムを用いた階層型ニューラルネットワークや、Radial Basis Functions を用いた方法 [16, 17] などが用いられているが、それから派生した上記の方法も同様に用いることが可能である。一般に1変数の時系列データが決定論的ダイナミクスによって生成されている場合には Takens の埋め込み定理 [18] によって元の力学系を再構成することができる。この場合、サンプル時間間隔の大きさと埋め込み次元の推定が重要 [16] であるが、ここではそれらが既知とし、例として比較的単純なロジスティック写像のような1次元差分力学系の数理モデルを同定する。ロジスティック写像では関数形が滑らかなため十分に局所最適解を回避できるが、テント写像、ベルヌーイ写像、変形ベルヌーイ写像 [19] などの場合、関数形が微分不可能あるいは不連続であるため回避できないことが発生する。そこで、このような不具合を改善するために折れ線型 MSF の別の形として MSF をその変化に追従できるような型に置き換え、シミュレーテッドアニーリング (Simulated Annealing; SA) の手法 [20, 21, 22, 23] を用いて MSF の頂点位置を移動することにより局所最適解を回避できることを示す [24]。これにより、入出力データの急激な変化に対して MSF のグレードが追従し、その部分に適切に MSF を配置できるようになる。本手法を様々な数値例に適用し、シミュレーションによりその有効性を示す。

第3章において後者の問題点を回避する手法を提案する。二等辺三角型を起源とする折れ線近似的な MSF では、関数の汎化能力の面において、微分不可能あるいは不連続な入出力関係に対しては有効であるが、滑らかに変化する部分については劣ってしまう。逆に釣鐘型のような滑らかな MSF は、滑らかに変化する部分において有効であるが、微分不可能あるいは不連続な入出力関係に対しては劣る。また、上述した FNN などの学習型ファジィ推論は、複数の MSF により入力空間をあらかじめ分割することで、NN と比較して高速な学習を可能としている。しかし MSF をあらかじめ設定しなければならないことから、初期状態によって学習能力がほぼ決定されてしまう。例えば、学習能力を優先させるためには、多くの数の MSF を使用すればよいが、冗長なルールが存在する可能性がある。このような問題の解決方法として、推論ルールの最適化、MSF の数の低減を目的とした GA を用いたファジィ推論法が提案されている [10, 11]。ところがこの手法では MSF のパラメータ全てを調整しなくてはならず、MSF のパラメータ数を満足する遺伝子が必要なため、必然的に遺伝子が長くなるという問題がある。

上述の MSF の種類による関数の汎化能力性能の問題、調整する MSF のパラメータ全てを

満足するためには遺伝子が長くなるという問題、この2つの問題を解決するため、従来SAの手法で行っていた頂点位置移動をGAの手法で行う。MSFの頂点位置を表すパラメータのみを調整するため遺伝子長の短縮が可能になる。さらにMSFの適否の判定、種類の選択ができる遺伝子を個体に組み込んだ。これによりモデルの形状に適合した複数種類のMSFを選択することができ、あらかじめ準備したMSFに関して最小のMSFの個数を決定できることを示す[25]。本手法を様々な数値例に適用し、シミュレーションによりその有効性を示す。

第4章は、第3章で提案する手法の多入出力学習データへの適用と汎化能力を探る。第3章で提案する手法を用いる場合、学習後のモデル関数の様子や、学習データとは異なる検査データに対しての振る舞いについてわかっておらず、また多入出力の学習データに対しても適用していない。そこで、第3章の手法を様々な数値例に適用し、シミュレーションによりその汎化能力を示す。

第5章は、第3章で提案する手法の指尖加速度脈波への応用を行う。カオスの医療応用において、現在その応用分野は、脈波をはじめ、脳波、心拍、血糖値など多岐に及んでいる。このような発展を遂げている原因として、これまでの医療診断技術は、一瞬のクリस्प生体情報の線形解析が主体であったためである。例えば、血圧や脈拍数、心電図、各種血液生化学検査などが挙げられるが、これらの検査項目は生体の局所の1時点の診断であり、このような情報の組み合わせで病態の診断を行っていた。しかし、近年、これまでの医療検査項目に異常がなくても、ストレスなどに悩み、非健康と感じている人が多い。また、痛みや苦悩、生体の病態変化、治療による改善度などを客観的に定量化できる情報を医療従事者も求め始めた。様々な応用の中で、指尖加速度脈波カオス解析がある[26, 27]。加速度脈波は指尖容積脈波を2次微分した生体情報である。透過型光学センサで検知された指尖脈波波形から加速度脈波評価をするシステムが開発されており、生体に非侵襲で脈波データを取り出しカオス解析を行なうことができる。加速度脈波のカオス統計量として、軌道平行測度法(TPM)[28]とリカレンスプロット法[19]が解析に用いられている。TPMはカオスアトラクタの任意の接線ベクトルの平行度を示している。また、リカレンスプロット法は、時系列波形のカオス的非定常性を視覚化する手法として注目されている。しかし、この2つのカオス統計量は、カオスアトラクタの形状を的確に捉えるものではなく、その形状の一部分の情報しか持ち合わされていない。それを補うように、加速度脈波の時系列における振幅比が形状パラメータとして使用されている[27]。しかし、被験者によってはその値が検出されにくい

場合が存在する。また、加速度脈波が周期ごとに波形が異なることがあり、時間的に振幅比が変動することも観測されている。そこで、上記に左右されず加速度脈波情報を取り入れるためにFNN[4, 5, 6, 14, 25]を応用する。第3章で提案する手法をMSFの種類を選択に特化し、時系列加速度脈波データとそのカオスアトラクタ形状のモデリングを行なう。また、学習後のMSFの種類、後件部実数値等を形状特徴量ベクトルとして取り出し、さらに、そのベクトルを自己組織化マップ[29]に入力することにより脈波データの分類を行なう。

第6章では、本研究における総括を行ない、今後検討すべき課題について述べる。

第2章 学習データが急激に変化する分布 におけるファジィルールの自動調整

2.1 序言

制御対象の入出力データが急激に変化する分布をもつ場合、つまりカオス性を有するような非線型ダイナミカルシステムの同定、決定論的非線型予測 [15] を行う場合、従来の方法では局所最適解を回避できないことがある。折れ線型 MSF の別の形として MSF をその変化に追従できるような型に置き換え、SA の手法 [20, 21, 22, 23] を用いて MSF の頂点位置を移動させることにより局所最適解を回避できることを示す。これにより、急激な入出力データ変化に対して MSF のグレードが追従し、その部分に適切に MSF を配置できるようになる。本手法を様々な数値例に適用し、シミュレーションによりその有効性を示す。

2.2 学習データが急激に変化する分布に対応した MSF を用いたファジィ推論

2.2.1 簡略化ファジィ推論

本手法では、次に示すような後件部出力値が実数値の簡略化ファジィ推論を用いる。

$$\begin{aligned} & \text{Rule } i : \text{if } x_1 \text{ is } A_{1i} \text{ and } x_2 \text{ is } A_{2i} \text{ and } \dots \\ & \quad \text{and } x_j \text{ is } A_{ji} \text{ and } \dots \text{ and } x_m \text{ is } A_{mi} \\ & \quad \text{then } y \text{ is } w_i \quad (i = 1, \dots, n) \end{aligned} \tag{2.1}$$

式 (2.1) において、 A_{ji} は前件部 MSF、 w_i は後件部出力値、添え字 i はルール番号、添え字 j ($j = 1, \dots, m$) は入力変数の番号を表す。制御量 y は、各ルールの前件部適合度 μ_i を式 (2.2) で示す代数積で算出し、式 (2.3) で示すように要素 w_i の重み μ_i による重み付き平均に

よって推論出力を決定する。

$$\mu_i = A_{1i}(x_1)A_{2i}(x_2) \cdots A_{ji}(x_j) \cdots A_{mi}(x_m) \quad (2.2)$$

$$y = \frac{\sum_{i=1}^n \mu_i \cdot w_i}{\sum_{i=1}^n \mu_i} \quad (2.3)$$

2.2.2 学習データが急激に変化する分布に対応した MSF

図 2.1 に従来のファジィ推論ルールでよく用いられてきた二等辺三角型 MSF を示す。これを式 (2.4) のように定式化する。

$$A_{ji}(x_j) = \begin{cases} 1 - \frac{2|x_j - a_{ji}|}{b_{ji}} & , a_{ji} - \frac{b_{ji}}{2} < x_j < a_{ji} + \frac{b_{ji}}{2} \\ 0 & , \text{otherwise} \end{cases} \quad (2.4)$$

学習データが急激に変化する分布に対応した、2つの直角三角形から成る直角三角型 MSF(ここでは便宜的に Double Right-angled Triangular MSF と書き DRTMSF と略して用いる。)を提案する。図 2.1 に示す二等辺三角型 MSF の頂点位置 a_{ji} にあるグレードを可変できるようにし、そのグレードを左右で2つに分け、それぞれ c_{ji} , d_{ji} とした。グレードの差の部分、および左右両側のグレードから底辺 b_{ji} の両端に向かう部分は直線で構成される。図 2.2 にその概形を示す。この DRTMSF を式 (2.5) のように定式化する。

$$A_{ji}(x_j) = \begin{cases} c_{ji} + \frac{2c_{ji}(x_j - a_{ji})}{b_{ji}} & , a_{ji} - \frac{b_{ji}}{2} < x_j \leq a_{ji} \\ d_{ji} - \frac{2d_{ji}(x_j - a_{ji})}{b_{ji}} & , a_{ji} < x_j \leq a_{ji} + \frac{b_{ji}}{2} \\ 0 & , \text{otherwise} \end{cases} \quad (2.5)$$

2.3 ニューラルネットワークによる学習

2.3.1 簡略化ファジィ推論の NN 表現

本手法では、ファジィ推論ルールの調整において NN の学習機能を利用するために、式 (2.1)~(2.3) で示されるファジィ推論の各演算を NN の各機能に割り当て、ファジィ推論の過程を NN で表現する [5, 14]。図 2.3 に NN 表現の概念図を示す。




図 2.1: 二等辺三角型 MSF




図 2.2: 学習データが急激に変化する分布に対応した MSF ($c_{ji} = 1.0$ の場合)




図 2.3: 簡略化ファジィ推論の概念図

2.3.2 学習アルゴリズム

本手法では、ファジィ推論ルールの調整には、NNの学習則である最急降下学習法を用いる。ここで、学習の対象となるのはNNにおける入力層と中間層ユニットの結合係数と中間層と出力層ユニットの結合係数、すなわち推論ルールの前件部MSFと後件部実数値である。前件部MSFの学習とは、具体的には図2.1, 2.2に示すようなMSFの形状を決定するパラメータの学習である。最急降下学習法において、学習の方向を決定する評価関数を次に示すように定義する。

$$E = \frac{1}{2} \{y^*(p) - y(\psi(t), \mathbf{x}(p))\}^2 \quad (2.6)$$

ここで、 $\psi(t)$ は学習回数が t のときのMSFの形状と後件部実数値を決定するパラメータベクトル

$$\begin{aligned} \boldsymbol{\psi}(t) = & [a_{11}(t), b_{11}(t), c_{11}(t), d_{11}(t), w_1(t), \\ & \cdots, a_{mn}(t), b_{mn}(t), c_{mn}(t), d_{mn}(t), w_n(t)] \end{aligned} \quad (2.7)$$

であり、二等辺三角型 MSF を用いる場合は、 $c_{ji}(t), d_{ji}(t)$ をこのパラメータベクトルに含ませない。 $\boldsymbol{x}(p)$ は、連続な変数である x_j を離散化した $x_j(p)$ の p 番目の入力値を要素とする入力ベクトルであり、次式で表せる。

$$\boldsymbol{x}(p) = [x_1(p), x_2(p), \cdots, x_m(p)] \quad (2.8)$$

$y(\boldsymbol{\psi}(t), \boldsymbol{x}(p))$ は式 (2.3) のファジィ推論出力であるが、パラメータベクトル $\boldsymbol{\psi}(t)$ で決定された MSF をもつファジィ推論ルールが、 p 番目の入力ベクトル $\boldsymbol{x}(p)$ をとったときの推論出力であることを表している。 $y^*(p)$ は NN が出力すべき学習データであり、 p 番目の入力に対する学習すべき出力データである。これらを以後、 y および y^* で表す。

式 (2.6) において、 y は NN の出力値で、 y^* は入出力学習データである。最急降下学習法では、式 (2.6) で定められた評価関数の値が最も小さくなる方向に逐次的に学習を繰り返し、最適な解を得る。

次に、DRTMSF の場合の各学習手順におけるパラメータの学習式を示す。

$$w_i(t+1) = w_i(t) - K_w \frac{\partial E}{\partial w_i} \quad (2.9)$$

$$a_{ji}(t+1) = a_{ji}(t) - K_a \frac{\partial E}{\partial a_{ji}} \quad (2.10)$$

$$b_{ji}(t+1) = b_{ji}(t) - K_b \frac{\partial E}{\partial b_{ji}} \quad (2.11)$$

$$c_{ji}(t+1) = c_{ji}(t) - K_c \frac{\partial E}{\partial c_{ji}} \quad (2.12)$$

$$d_{ji}(t+1) = d_{ji}(t) - K_d \frac{\partial E}{\partial d_{ji}} \quad (2.13)$$

式 (2.9)～(2.13) で、 K_w, K_a, K_b, K_c, K_d は学習の刻み幅を決定する学習係数である。式 (2.2)～(2.6) から $\frac{\partial E}{\partial w_i}, \frac{\partial E}{\partial a_{ji}}, \frac{\partial E}{\partial b_{ji}}, \frac{\partial E}{\partial c_{ji}}, \frac{\partial E}{\partial d_{ji}}$ を計算すると、式 (2.15)～(2.19) のようになる。ここで入力 x_j が領域

$$D = \{x_j | a_{ji} - b_{ji}/2 < x_j \leq a_{ji}\} \quad (2.14)$$

にある場合を述べるが、他の領域についても同様に考えればよい。

$x_j \in D$ のとき、

$$\frac{\partial E}{\partial w_i} = -(y^* - y) \cdot \frac{\mu_i}{\sum_{i=1}^n \mu_i} \quad (2.15)$$

$$\frac{\partial E}{\partial a_{ji}} = -(y^* - y) \cdot \frac{1}{\sum_{i=1}^n \mu_i} \cdot (w_i - y) \cdot \frac{-2c_{ji}}{b_{ji}} \cdot \frac{\mu_i}{A_{ji}(x_j)} \quad (2.16)$$

$$\frac{\partial E}{\partial b_{ji}} = -(y^* - y) \cdot \frac{1}{\sum_{i=1}^n \mu_i} \cdot (w_i - y) \cdot \frac{c_{ji} - A_{ji}(x_j)}{b_{ji}} \cdot \frac{\mu_i}{A_{ji}(x_j)} \quad (2.17)$$

$$\frac{\partial E}{\partial c_{ji}} = -(y^* - y) \cdot \frac{1}{\sum_{i=1}^n \mu_i} \cdot (w_i - y) \cdot \frac{\mu_i}{c_{ji}} \quad (2.18)$$

$$\frac{\partial E}{\partial d_{ji}} = 0 \quad (2.19)$$

となる。式(2.9)～(2.13)で示される学習式は以下のように具体的に計算できる。 $\delta = y^* - y$ とすると、以下の関係を得る。

$$w_i(t+1) = w_i(t) + K_w \delta \frac{\mu_i}{\sum_{i=1}^n \mu_i} \quad (2.20)$$

$$a_{ji}(t+1) = a_{ji}(t) - K_a \delta \frac{1}{\sum_{i=1}^n \mu_i} (w_i - y) \frac{2c_{ji}}{b_{ji}} \frac{\mu_i}{A_{ji}(x_j)} \quad (2.21)$$

$$b_{ji}(t+1) = b_{ji}(t) + K_b \delta \frac{1}{\sum_{i=1}^n \mu_i} (w_i - y) \frac{c_{ji} - A_{ji}(x_j)}{b_{ji}} \frac{\mu_i}{A_{ji}(x_j)} \quad (2.22)$$

$$c_{ji}(t+1) = c_{ji}(t) + K_c \delta \frac{1}{\sum_{i=1}^n \mu_i} (w_i - y) \frac{\mu_i}{c_{ji}} \quad (2.23)$$

$$d_{ji}(t+1) = d_{ji}(t) \quad (2.24)$$

入力 x_j が D 以外の領域に属する場合についても、同様に式(2.20)～(2.24)の各学習式が定義できる。

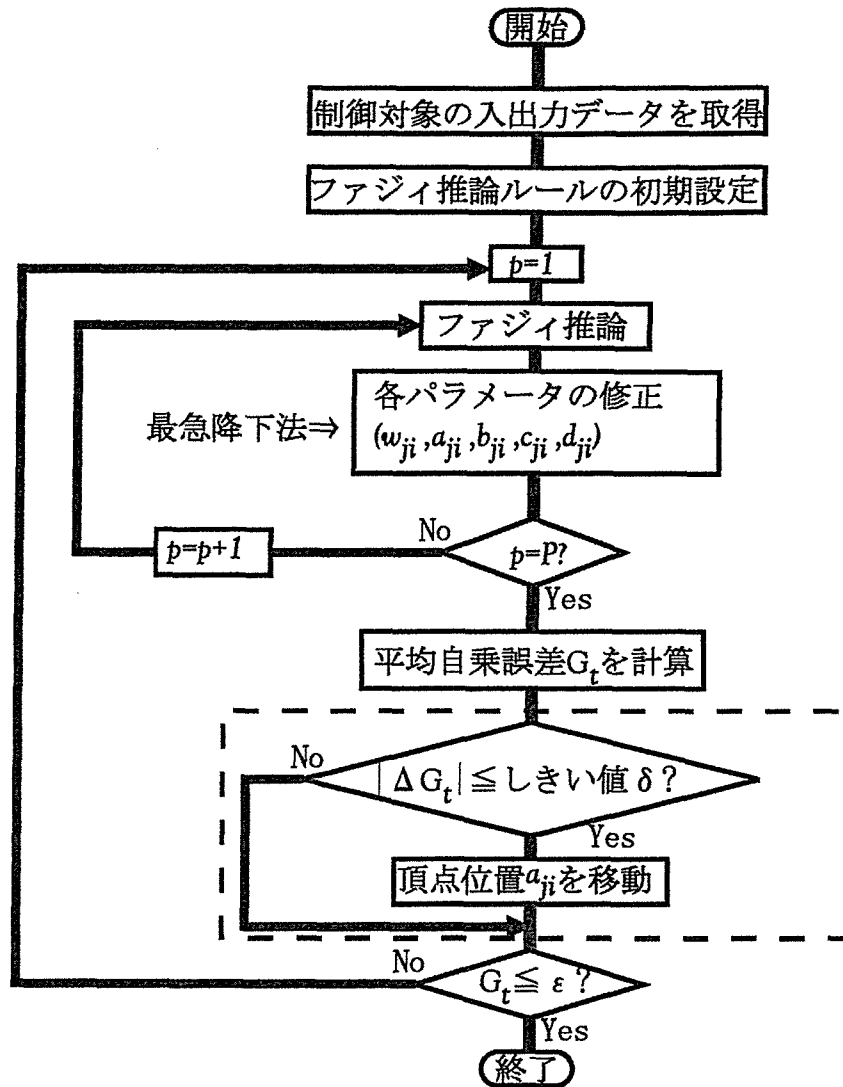


図 2.4: 本手法の学習手順の流れ図

2.3.3 学習の手順

本手法の学習の手順は、図 2.4 に示すフローチャートに従う。はじめに制御対象の入出力関係を示すデータを P 組得る。次に、ファジィ推論ルールに関するパラメータの初期設定を行う。ここで、図 2.5 に示すように、入力領域 $[a_{ji}, a_{jn}]$ を $n-1$ 等分し、領域端も含め等分点に MSF を置き、隣接する MSF どうしがグレード 0.5 で重なり合うように b_{ji}, c_{ji}, d_{ji} を設定する。後件部実数値 w_i は全て一様乱数により区間 $[0, 1]$ の範囲に設定する。入力データを 1 組ずつ NN に入力し、ファジィ推論を行い制御量 y を出力する。式 (2.20)~(2.24) に示す学習式に従い、後件部実数値 w_i 、前件部 MSF のパラメータ $a_{ji}, b_{ji}, c_{ji}, d_{ji}$ の修正を行う。




図 2.5: 前件部 MSF の初期設定

これを P 組のデータについて行い、学習回数 t に対する平均自乗誤差 G_t を計算する。

$$G_t = \frac{1}{P} \sum_{p=1}^P \{y^*(p) - y(\psi(t), \mathbf{x}(p))\}^2 \quad (2.25)$$

平均自乗誤差 G_t が、あらかじめ定められた閾値 ε より小さくなったとき学習の終了とする。

$$G_t \leq \varepsilon \quad (2.26)$$

(2.26) 式が満たされない場合は、再び最初の入力データの組から学習を繰り返す。

2.4 SA の手法を用いた局所最適解の回避

2.4.1 MSF の移動による局所最適解の回避

最急降下法による学習過程において、平均自乗誤差 G_t の減少が微量であるため期待する状態まで学習が進まない場合がある。これは、MSF が学習データに対して適切な位置に配置されていないことに起因すると考えられる。この場合、MSF の頂点位置 a_{ji} を移動することにより、より適切な位置に配置することを提案する。

2.4.2 SA 法を用いた MSF の再配置

SA 法は、スピン系などの物理系シミュレーションに用いられるメトロポリス法 [20] を応用した手法で、最適化問題に確率的要素を取り入れること、そして温度と呼ばれるパラメータを適切に制御することにより、局所最適解にとらわれることなく大域最適解を探索できるという利点がある。その SA のプロトタイプアルゴリズムを以下に示す。

Step1 初期解 x^0 を設定する。

Step2 繰り返し演算のカウンタ t を 0 にする。

Step3 温度 T^t が十分に低くなれば全探索の過程で得られた最良解を近似解としてアルゴリズムを終了する。

Step4 摂動解 $x' \in N(x^t)$ を生成する。

Step5 目的関数を F とし、 $\Delta F = F(x') - F(x^t)$ を求める。

Step6 もし $\Delta F < 0$ ならば $x^{t+1} = x'$ として Step8 に進む。

Step7 もし $\Delta F \geq 0$ ならば区間 $[0, 1]$ での一様乱数 u を発生させ、 $u < \exp(-\Delta F/T^t)$ ならば $x^{t+1} = x'$ とし、それ以外には $x^{t+1} = x^t$ とする。

Step8 $t = t + 1$ として Step3 にもどる。

ここで T^0, T^1, T^2, \dots は単調に減少する温度の系列である。また、 $N(x)$ は x の近傍領域を示す。

しかし、SA 法は1つの初期状態から状態遷移を繰り返して状態系列を発生させ、その中で解を探索する一種の逐次改善法であるため、状態空間中の広い範囲の探索は難しいという欠点がある [23]。また、一般に近傍の設計は探索性能に大きく影響する欠点もある [22]。この欠点は近傍 $N(x)$ の取り方により局所最適解の個数やこれらから脱出するために乗り越えるべき目的関数 F の壁の高さが変化することにより生ずる。

そこで、近傍 $N(x)$ の領域を温度により可変にすることを提案する。つまり温度が高いときは近傍 $N(x)$ の領域を広くとり、学習が進み温度が低くなったときは近傍 $N(x)$ の領域を温度に応じ狭くする。また、低温状態に落ち着いたにもかかわらずそれが局所最適解であった場合、再度高温状態に戻すことを提案する。これは状態空間中の別の範囲を指定することにつながる。このように近傍 $N(x)$ の領域を可変にすることは過去に例がなく、近傍の設計をより柔軟にすることが出来る。また、頂点位置 a_{ji} を近傍 $N(x)$ の領域で可変とするパラメータとした。そして、最急降下学習法にこの考え方を導入することにより演算の高速化と局所最適解回避を行う。以下に本手法のアルゴリズムを述べる。

Step1 初期解 x^0 を設定する。

Step2 繰り返し演算のカウンタ t を 0 にする。

Step3 $G_t(x^t)$ が十分に小さくなれば全探索の過程で得られた最良解を近似解としてアルゴリズムを終了する。

Step4 最急降下法により摂動解 $x' \in N(x^t)$ を生成する。

Step5 $\Delta G = G_t(x') - G_t(x^t)$ を求める。

Step6 もし $\Delta G < 0$ ならば $x^{t+1} = x'$ として Step9 に進む。

Step7 もし $|\Delta G| < \epsilon (= 0.0001)$ ならば、温度カウンタを c とすると、

$a'_{ji} = a_{ji}^t + (\text{区間} [-1, 1] \text{ での一様乱数}) \cdot (\text{温度による頂点の可変振動幅})$ で a'_{ji} を複数個求め、それぞれの a'_{ji} に対して $G_t(x')$ を求める。それぞれの $G_t(x')$ から ΔG を求め、

$\Delta G < 0$ なら、そのときの a'_{ji} は受け入れる。また、 $\Delta G \geq 0$ なら、区間 $[0, 1]$ での一様乱数 u を発生させ、 $u < \exp(-\Delta G/T^c)$ ならば a'_{ji} は受け入れる。受け入れた複数個の中から $G_{t,min}$ を発生する a'_{ji} を選び、それを $a_{ji}^{t+1} = a'_{ji}$ とする。

Step8 温度カウンタを $c = c + 1$ とする。しかし、 $c > 100$ の場合、 $c = 0$ とし温度を初期値にする。

Step9 $t = t + 1$ として Step3 にもどる。

ここで T^0, T^1, T^2, \dots は単調に減少する温度の系列である。

2.5 シミュレーション

2.5.1 1入力1出力の関数近似問題

本手法を次の各数式に示される6種類の1入力1出力の関数の近似問題に適用し、その有効性を検討する。

$$y = 300 - 100x \quad (2.27)$$

$$y = 100 + 10 \exp\{-10(x - 0.3)^2\} \quad (2.28)$$

$$y = \begin{cases} 1 & , \text{if } x \leq -0.2 \text{ or } x \geq 0.7 \\ 0 & , \text{otherwise} \end{cases} \quad (2.29)$$


$$y = \begin{cases} |x| & , -1 \leq x < 0 \\ (x - 2)^2 & , 0 \leq x < 1 \end{cases} \quad (2.30)$$

$$y = \tan \frac{\pi}{2}(x - 1) \quad (2.31)$$

$$y = \{50 + 1/(0.7 - x^2)\} \cdot \cos(5\pi x/4) \quad (2.32)$$

はじめに、式(2.27)~(2.32)の入力値 x を一様乱数により $[-1, 1]$ の範囲で発生させ、各式を計算し出力値 y を得る。そして、各式において20組の入出力データを取得する。また、出力値 y は $[0, 1]$ の範囲で正規化する。

学習が進まなくなった場合、つまり $|\Delta G_t| < \delta (= 0.0001)$ の場合は、移るべき頂点位置 a'_{ji} を20個候補として求め $G_{t,min}$ を発生する a'_{ji} を選択している。温度による可変振動幅は、初期設定時の隣り合うMSFの頂点間を初期幅とし、温度により減少させる。温度スケジュールは $T^{oc+1} = T^{oc} \times 0.8$ を用いた。



$t_1 < t_2$

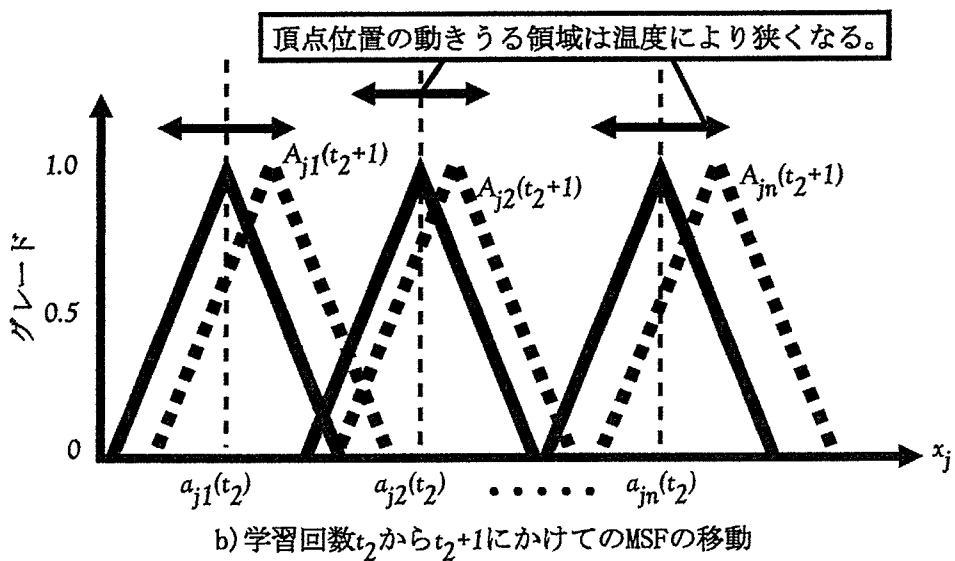


図 2.6: 頂点位置の変更過程




図 2.7: 式 (2.30) の関数近似における学習経過

そして、図 2.4 に示した学習の手順に従って、入出力関係を表現するよう逐次的に学習し、平均自乗誤差がある閾値 ε 以下になるまで学習を繰り返す。

学習の結果、式 (2.27)~(2.32) について、表 2.1 に示すような結果が得られた。釣鐘型 MSF とは別名ガウス基底と呼ばれ、RBF(Radial Basis Functions) を用いる学習ネットワーク [17] 等で使われる関数である。関数の形状は、式 (2.33) で与えられる。

$$A_{ji}(x_j) = \exp\{-(x_j - a_{ji})^2/b_{ji}\} \quad (2.33)$$

式 (2.27)~(2.32) は平均自乗誤差の閾値が 0.001 になるまで学習を繰り返した。表 2.1 での学習係数は釣鐘型 MSF の場合 $K_w = 0.01, K_a = 0.001, K_b = 0.01$ としている。ここで、 K_a, K_b はそれぞれ頂点位置、釣鐘型 MSF の幅に関わる学習係数である。二等辺三角型 MSF の場合には $K_w = 0.01, K_a = 0.01, K_b = 0.01$, DRTMSF の場合には $K_w = 0.01, K_a = 1.0 \times 10^{-9}, K_b = 0.01, K_c = 0.1, K_d = 0.1$ としている。釣鐘型 MSF, 二等辺三角型 MSF の学習係数の値は、1 つの学習係数の組に対して、各式において 5 回ずつ計算し、最も速く収束する学習係数の値を選択している。収束しない式に関しては、収束する式番号が 1 つ前の式の学習係数を用いている。各式の入力データに対して 50 回収束計算を行い、10 回ごとに学習データセットを置換える。10000 回学習を行っても収束しない場合は計算を打ち切り収束の回数に数えない。表中の数値は、収束した回数、そのときの平均学習回数、表中の×印は、収束した回数が 0 回の場合を示している。また式番号が進むにつれて、それぞれの関数の複雑度、不連続度が増大するように各式を設定した。

表 2.1: 各 MSF に対する収束回数, 平均学習回数の比較

	釣鐘型MSF +最急降下法	二等辺三角型 MSF +最急降下法	DRTMSF +本手法
近似対象	収束した回数	収束した回数	収束した回数
	平均学習回数	平均学習回数	平均学習回数
式(2.27)	48	49	50
	530	203	344
式(2.28)	0	49	50
	 	250	565
式(2.29)	0	41	46
	 	154	382
式(2.30)	0	0	13
	 	 	1609
式(2.31)	0	0	21
	 	 	3500
式(2.32)	0	0	10
	 	 	6691




図 2.8: 式 (2.31) の関数近似に対して自動調整の結果得られた MSF

表 2.1 で、釣鐘型 MSF と二等辺三角型 MSF と DRTMSF を用いた場合の学習回数を比較する。ここでは、ルール数を $n = 6$ とした。1 入力であるので 6 個の MSF を構成することになる。式 (2.27) のように比較的単純な線形関数の近似においては、3 種類の MSF は全て収束している。式 (2.28)~(2.29) のように不連続度が上昇すると釣鐘型 MSF では学習が収束しなくなる。式 (2.30)~(2.32) のようにさらに不連続が厳しく、不連続の個数も増えると、二等辺三角型 MSF をもってしても学習が終了しない。DRTMSF の場合、全式において学習が終了している。式 (2.27)~(2.29) において、二等辺三角型 MSF は他と比較して最も少ない回数で学習が終了しているが、パラメータの初期設定によるものであるため、ここでは言及しな




図 2.9: 式 (2.31) の関数近似における誤差分布

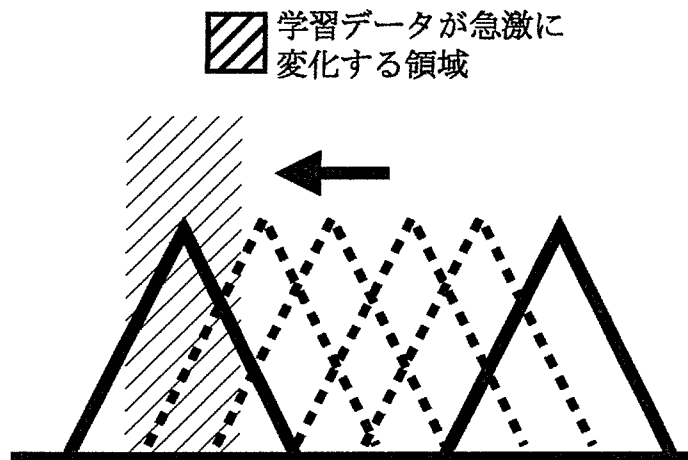
い。図 2.7 に代表例として式 (2.30) の関数近似における学習経過を示す。学習過程において時折平均自乗誤差が上昇しているが、この部分において上昇する直前で平均自乗誤差が変化しなくなり、本手法により頂点位置 a_{ji} が大幅に更新されている様子がわかる。学習終了時には図 2.8 に示すように学習すべき関数の不連続点において DRTMSF のグレードの不連続が適切に拡張していることがわかる。また、表 2.1 で関数の不連続度が増すにつれ DRTMSF の場合、学習回数が増加している。これは学習データが急激に変化する部分に MSF を配置するとき、SA の手法を用いているため、配置確率が不連続度の上昇のために低下するからである。式 (2.31) の関数近似における誤差分布を図 2.9 に示す。入力データに対する学習すべき出力データと推論出力との差の絶対値を求めた。式 (2.31) は $x = 0$ およびその近傍で学習データが急激に変化するため、誤差の大部分がその付近に集中している。

次に、式 (2.32) において DRTMSF の学習係数 K_a を変化させ学習を行った。表 2.2 はその結果である。表 2.2 において他の学習係数は $K_w = 0.01, K_b = 0.01, K_c = 0.1, K_d = 0.1$ とし、平均自乗誤差の閾値が 0.01 になるまで学習を繰り返した。表中の×印は、学習が 10000 回で終了しなかった場合を示している。表 2.2 に示すように K_a が増加するに従い、学習が収束しなくなっている。これは図 2.10 に示すように K_a が微小であるとき SA の手法により MSF を確率的に学習データが急激に変化する位置に直接的に配置してしまうが、 K_a が大きくなるにつれ、学習データが急激に変化する位置の横方向から徐々に MSF を配置しようとするようになる。そのため MSF のグレードの変化、つまり c_{ji}, d_{ji} が変化する前にその位置に近づいてしまうため、 b_{ji} が MSF を狭める方向に変化しようとする。そして、MSF は他の学習データに捕獲され局所最適解に陥り、学習が進まない場合が多発すると考える。

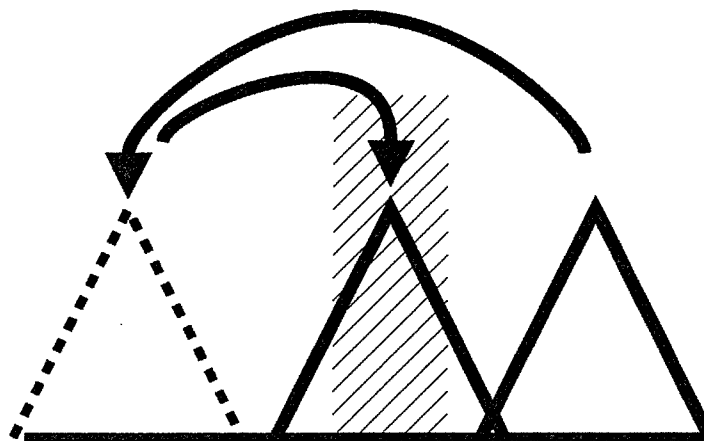
表 2.3 に、(2.32) 式における学習データ数に対する学習回数を示す。表 2.3 において二等辺三角型 MSF, DRTMSF とも学習係数は $K_w = 0.01, K_a = 1.0 \times 10^{-9}, K_b = 0.01, (K_c = 0.1, K_d = 0.1)$ とし、等しくした。また、それぞれの手法のパラメータ数は、ほぼ等しくなるようにした。1 ルールにつき、二等辺三角型は 3 個、本手法は 5 個必要とする。実質的には、 c_{ji}, d_{ji} は学習中に同時にパラメータの修正を行わないので、1 ルールあたり本手法は 4 個としてよい。二等辺三角型 MSF は 8 ルール、DRTMSF は 6 ルールとした。全パラメータ数は二等辺三角型、本手法とも 32 個となる。二等辺三角型 MSF, DRTMSF とも局所最適解回避に本手法を用いている。平均自乗誤差の閾値が 20 組の場合には 0.001、それ以外は 0.002 で学習が終了するようにした。各組の入力データに対して 50 回收束計算を行い、10 回ごと

表 2.2: 学習係数 K_a を変化させた場合の収束回数, 平均学習回数

学習係数 K_a	収束した回数	平均学習回数
1.0×10^{-9}	21	5547
1.0×10^{-7}	14	5819
1.0×10^{-5}	16	6658
1.0×10^{-3}	7	4827
1.0×10^{-1}	0	X



(a) 最急降下学習法によるMSF配置



(b) 確率的なMSF配置

図 2.10: 本手法による学習時のMSFの動き

表 2.3: 学習データ数に対する収束回数, 平均学習回数の比較

	二等辺三角型 MSF +本手法	DRTMSF +本手法
学習 データ数	収束した回数	収束した回数
	平均学習回数	平均学習回数
20組	1	12
	9289	17721
60組	4	18
	15309	13591
100組	1	22
	17944	7573

に学習データセットを置換える。30000 回学習を行っても収束しない場合は計算を打ち切り収束の回数に数えない。表中の数値は、収束回数、そのときの平均学習回数を示している。表 2.3 に示すように、学習データが 20 組の場合、閾値を 0.001 に設定しているため二等辺三角型 MSF の収束回数は大変少ないが、学習データが多くなるにつれ、二等辺三角型 MSF では収束しなくなっている。学習データが多くなるということは、学習の定義域に対するデータの密度が増大するため、必然的に学習データの急激な変化が得られやすくなる状況を作り出している。二等辺三角型 MSF の場合、急激な変化に対応するため MSF の底辺を狭める必要があるが、その狭める学習の過程で急激に変化する学習データ以外のその近隣の学習データに影響されやすい。また、ルール数が DRTMSF と比較して多く、MSF の関数としての自由度が小さいため、急激な変化部分に複数の MSF が存在し一度に変更すべきパラメータ数が DRTMSF と比較して多いことが収束しない原因だと考えられる。

2.5.2 2 入力 1 出力の関数近似問題

本手法を式 (2.34) に示される 2 入力 1 出力の関数の近似問題に適用した。シミュレーションの方法は、入出力関係を表す関数から、400 組の学習データを取り出し、それらを用いて






図 2.11: 前件部 MSF の初期設定


ファジィルールの自動調整を行った。前件部 MSF の初期設定は図 2.11 に示すように各ルール毎に MSF を設定した。それぞれの手法のパラメータ数は、ほぼ等しくなるようにした。1 ルールにつき、二等辺三角型では 5 個、本手法では 9 個必要とする。そのためルール数は同一パラメータ数により構成されるものと仮定して二等辺三角型が 64、本手法が 36 とした。実質、 c_{ji}, d_{ji} は学習中に同時にパラメータの修正を行わないので、1 ルールあたり本手法は 7 個としてよい。全パラメータ数は二等辺三角型が 320 個、本手法が 252 個となり、本手法は二等辺三角型と比較して少ないことがわかる。また、図 2.12 に示すように式 (2.34) から 3 種類の入出力データの存在する領域を作成した。そして、平均自乗誤差が 0.001 以下になるまで学習を繰り返す。10000 回学習を行っても収束しない場合は計算を打ち切り収束の回数に数えない。入力データの各領域に対して 50 回収束計算を行い、10 回ごとに学習データセットを置換える。入力データの各領域に対する収束回数 (50 回中)、およびそのときの平均学習回数の関係を表 2.4 に示す。



(a) $x_1, x_2 \in [-1.0, 1.0]$



(b) $x_1, x_2 \in [-0.75, 0.75]$



(c) $x_1, x_2 \in [-0.5, 0.5]$

図 2.12: 入出力データの分布

表 2.4: 各領域に対する収束回数, 平均学習回数の比較

	二等辺三角型MSF	本手法のMSF
入力データ x_1, x_2 の領域	収束した回数	収束した回数
	平均学習回数	平均学習回数
[-1.0, 1.0]	25	42
	985	1026
[-0.75, 0.75]	24	38
	806	1580
[-0.5, 0.5]	3	22
	1864	2813

$$y = \begin{cases} 1 & , \text{if } -1 \leq x_1 < 0 \text{ and } 0 \leq x_2 < 1 \\ 1 & , \text{if } 0 \leq x_1 < 1 \text{ and } -1 \leq x_2 < 0 \\ 0 & , \text{otherwise} \end{cases} \quad (2.34)$$

入力データの領域が狭まるにつれ, 学習データの $x_1 = 0, x_2 = 0$ 付近の不連続度が増加する。図 2.12(c) の領域において, 二等辺三角型は 50 回の収束計算に対し 1 割弱しか収束しないが, 本手法は平均学習回数は増加するけれども, 5 割近く収束している。さらに, 平均学習回数について両手法を比較すると, 二等辺三角型の場合の回数が少ないことがわかる。これは, 二等辺三角型のルール数が本手法よりも多く存在するため, 入出力データが急激に変化する部分に MSF が到達しやすい。つまり二等辺三角型の場合, 学習が各パラメータの初期値に大きく依存し, 局所最適解の回避手法の効果が薄いと考えられる。つまり本手法の場合, 局所最適解の回避手法が不連続度が増加するにつれ, 有効に動作しているといえる。

2.6 結言

本章では, ファジィ制御におけるファジィ推論ルールの自動調整に NN の学習機能を利用する方法において, 学習データが急激に変化する分布に対応するために, ファジィ推論ルールの MSF を二等辺三角型から DRTMSF に変更する手法を提案した。また, SA の手法を取り入れ MSF の頂点位置幅を温度パラメータにより可変とし, スムーズに局所最適解を回避

し大域最適解に近づける方法を提案した。本方法によって、学習データが急激に変化する場
合でも、MSF を適切に配置できることを示すことができた。

第3章 種々のMSFで構成されるファジィ ルールの自動調整

3.1 序言

二等辺三角型を起源とする折れ線近似的なMSFでは、関数の汎化能力の面において、微分不可能あるいは不連続に対しては有効であるが、滑らかに変化する部分については劣ってしまう。逆に釣鐘型のような滑らかなMSFは、滑らかに変化する部分において有効であるが、微分不可能あるいは不連続に対しては劣る。また、冗長なルールの低減を目的にGAを用いたファジィ推論法が提案されているが[10, 11]、この手法ではMSFのパラメータ全てを調整しなくてはならず、MSFのパラメータ数を満足する遺伝子が必要なため、必然的に遺伝子長が長くなるという問題がある。

この2つの問題を解決するため、第2章においてSAの手法で行っていた頂点位置移動をGAの手法で行う。MSFの頂点位置を表すパラメータのみ調整するため遺伝子長の短縮が可能になる。さらにMSFの適否の判定、種類の選択ができる遺伝子を個体に組み込んだ。これにより、モデルの形状に適合した複数種類のMSFを選択することができ、あらかじめ準備したMSFに関して最小のMSFの個数を決定できることを示す。本手法を様々な数値例に適用し、シミュレーションによりその有効性を示す。

3.2 種々のMSFを用いたファジィ推論ならびに学習

本手法では、第2.2.1節に示すような後件部出力値が実数値の簡略化ファジィ推論を用いる。複数種類のMSFからモデルの形状に適合したMSFを選択するため、ここでは、以下に示す3種類のMSFを用いる場合について考える。MSFは従来ファジィ推論ルールでよく用いられてきた二等辺三角型MSF、釣鐘型MSFが主である。二等辺三角型MSFについては、第2.2.2節の図2.1に示している。釣鐘型MSFについては、式(3.1)のように定式化し、




図 3.1: 釣鐘型 MSF

図 3.1 に示す。

$$A_{ji}(x_j) = \exp\{-(x_j - a_{ji})^2/b_{ji}\} \quad (3.1)$$

上記の第 1, 2 種の MSF について, 第 3 種類目の MSF として, 我々が第 2.2.2 節に提案している, 学習データが急激に変化する分布に対応した, 2 つの直角三角形から成る直角三角型 MSF[24](ここでは便宜的に Double Right-angled Triangular MSF と書き DRTMSF と略して用いる。)を用いる。また本手法では, ファジィ推論ルールの調整において NN の学習機能を利用するために, 第 2.3 節と同様の学習を行う。本手法の学習の順序を, 図 3.2 のフローチャートに示す。

3.3 GA の手法を用いた局所最適解回避

3.3.1 MSF の再配置による局所最適解の回避

最急降下法による学習過程において, 平均自乗誤差 G_t の減少が微量であるため期待する状態まで学習が進まない場合がある。これは, MSF が学習データに対して適切な位置に配置されていないこと, 冗長なルールが存在すること, さらに MSF の形状が学習データに合致していないことに起因すると考える。この場合, MSF の頂点位置 a_{ji} を移動すること, MSF

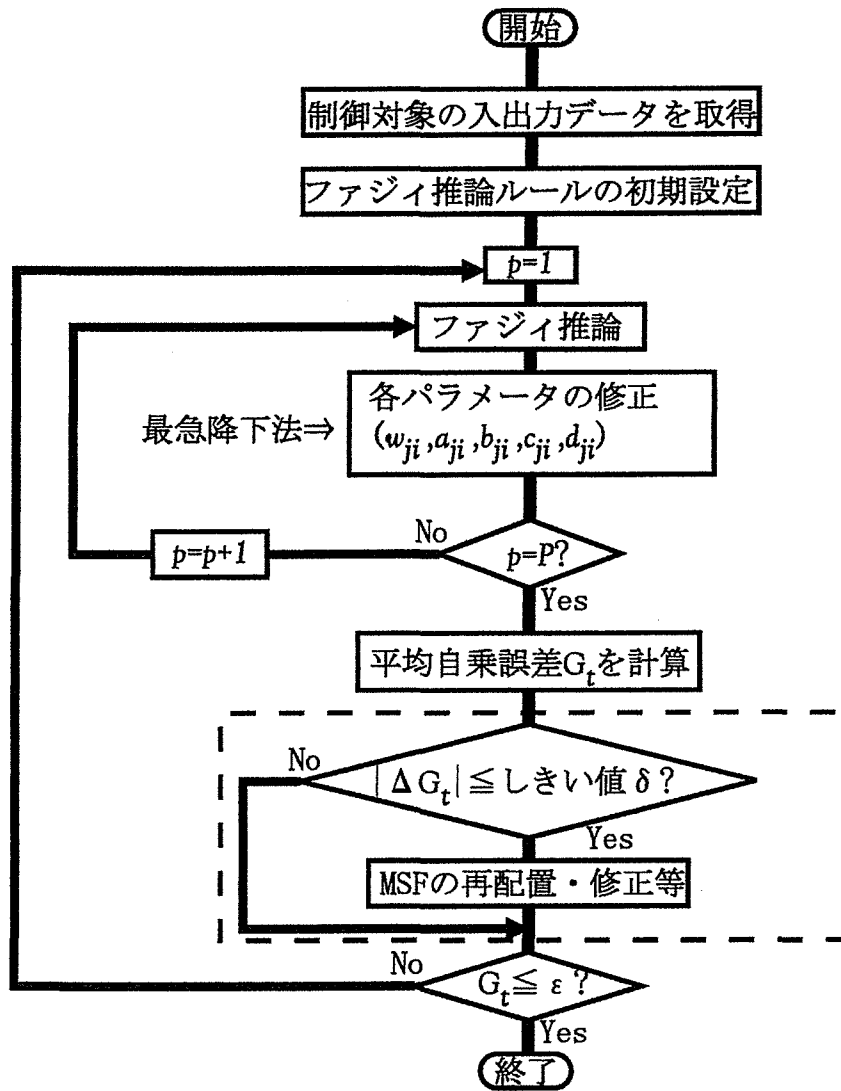


図 3.2: 本手法の学習手順の流れ図

の種類、個数を変えることにより、MSF を学習データに対し適切に配置をすることを提案する。

3.3.2 GA 法を用いた MSF の再配置

図 3.3 に示すように 1 つの個体は、複数のルールから構成されている。個々のルールは頂点位置 a_{ji} を有限ビット長の 2 進数、かつ、固定小数点数として表現した遺伝子列と MSF の適否の判定、種類の選択ができる遺伝子ビットからなる。GA の操作には、基本的な操作のみを行うものから、多点交叉などを備えた複雑なものまで、さまざまな場合が考えられる。ここでは、一般に単純 GA として知られているものを適用するが、必ずしも単純 GA である必要はない。GA による最適化の操作として、以下に挙げる各操作を行う。

(1) 初期個体の生成

乱数を用いて図 3.3 に示すような構成をもった一定個数の遺伝子を生成する。

(2) 各個体の評価と優良個体の保存

次に平均自乗誤差の逆数を適応度とし生殖操作を行い適応度が高い個体を次世代の個体として選んでいく。

(3) 交叉

個体群の中から 1 対の遺伝子を選択し、1 点交叉を行う。このとき、ランダムに選択される交叉位置は、ルールフィールドの境界とする。

(4) 突然変異

突然変異操作によりビット選択確率に基づき各ビットを反転する。

最後に最大適応度の個体を選択し最急降下法による学習過程に復帰するが、図 3.4 に示すように各ルールフィールドの遺伝子情報に基づき、MSF の on,off 遺伝子により、このルールにおける MSF の使用の有無を選択し、MSF の種類遺伝子により形状を選択する。頂点位置遺伝子については有限ビット長の 2 進数を 10 進数に変換し、入力データが取りうる変域をその 10 進数に変換した値の最大値で等分割する。変域の左端 (最小値) から頂点位置遺伝子の値に応じて頂点位置を移動する。

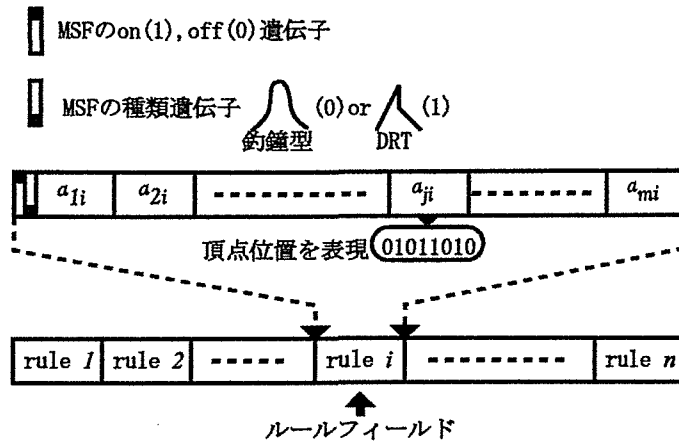


図 3.3: 遺伝子の構成




図 3.4: 頂点位置の変更過程

3.4 シミュレーション

3.4.1 1入力1出力の関数近似問題

本手法を次の各数式に示される3種類の1入力1出力の関数の近似問題に適用し、その有効性を検討する。

$$y = 4x(1-x) \quad (3.2)$$

$$y = \begin{cases} -2x+1 & , 0 \leq x < 0.5 \\ -\sin(\pi x) & , 0.5 \leq x < 1 \end{cases} \quad (3.3)$$

$$y = \begin{cases} x+2(1-2 \times 10^{-13})x^2+2 \times 10^{-13} & , 0 \leq x < 0.5 \\ x-2(1-2 \times 10^{-13})(1-x)^2-2 \times 10^{-13} & , 0.5 \leq x < 1 \end{cases} \quad (3.4)$$

ここで、式(3.2)は、滑らかな形状であるロジスティック写像のモデルの関数、式(3.3)は、微分不可能な点が存在する関数、式(3.4)は、不連続が存在する変形ベルヌーイ写像のモデルの関数である[19]。はじめに、式(3.2)~(3.4)の入力値 x を乱数により $[0, 1]$ の範囲で発生させ、各式を計算し出力値 y を得る。そして、各式において100組の入出力データを取得する。また、出力値 y は $[0, 1]$ の範囲で正規化する。

そして、図3.2に示した学習の手順に従って、入出力関係を表現するよう逐次的に学習し、平均自乗誤差が最小となる値を取り出す。GA法を利用した頂点位置移動については、頂点位置遺伝子(2進数8ビット長)、MSFのon,off遺伝子(2進数1ビット)、MSFの種類遺伝子(2進数1ビット)からなりルール数(10ルール)分結合した個体を20個体を生成する。その後、5世代淘汰を行う。交叉は1対の遺伝子を選択し交叉確率1.0で交叉を行う。突然変異操作はビット選択確率0.1で行う。

学習の結果、式(3.2)~(3.4)について、表3.1に示すような結果が得られた。式(3.2)~(3.4)に対して100000回学習を行い、平均自乗誤差が最小となる値を取り出した。ここで1回の学習とは図2.4の外側のループを示している。表3.1での学習係数は釣鐘型MSFを用いる場合 $K_w = 0.01, K_a = 1.0 \times 10^{-9}, K_b = 0.01$ としている。ここで、 K_a, K_b はそれぞれ頂点位置、釣鐘型MSFの幅に関わる学習係数である。二等辺三角型MSFを用いる場合 $K_w = 0.01, K_a = 1.0 \times 10^{-9}, K_b = 0.01$ 、DRTMSFを用いる場合 $K_w = 0.01, K_a = 1.0 \times 10^{-9}, K_b = 0.01, K_c = 0.1, K_d = 0.1$ としている。 K_a が他の学習係数と比較し値を小さく設定する理由は、最急降下法によるMSFの移動に依存するのではなくMSFの再配置に重きを置いているためである[24]。表中の数値は、最小平均自乗誤差、全ルール数とその内訳

表 3.1: 平均自乗誤差, ルール数の比較


	釣鐘型+二等辺三角型		釣鐘型+DRT	
近似対象	平均自乗誤差		平均自乗誤差	
	全ルール数		全ルール数	
	釣鐘型数	二等辺三角型数	釣鐘型数	DRT数
式(3.2)	8.87×10^{-6}		6.91×10^{-6}	
	2		2	
	2	0	2	0
式(3.3)	1.26×10^{-4}		8.03×10^{-5}	
	6		5	
	5	1	4	1
式(3.4)	2.63×10^{-4}		1.09×10^{-4}	
	10		3	
	0	10	2	1

表 3.2: MSF を単独で用いた場合の平均自乗誤差, ルール数の比較


	釣鐘型	二等辺三角型	DRT
近似対象	平均自乗誤差	平均自乗誤差	平均自乗誤差
	全ルール数	全ルール数	全ルール数
式(3.2)	9.89×10^{-6}	9.09×10^{-5}	8.49×10^{-5}
	3	8	5
式(3.3)	2.19×10^{-4}	1.65×10^{-4}	1.25×10^{-4}
	6	6	6
式(3.4)	2.18×10^{-2}	5.26×10^{-4}	6.86×10^{-4}
	5	10	10

を示している。また式番号が進むにつれて、それぞれの関数の複雑度、不連続度が增大するように各式を設定した。

表 3.1 で、釣鐘型 MSF + 二等辺三角型 MSF と釣鐘型 MSF + DRTMSF を用いた場合の最小平均自乗誤差の値、ならびにルール数を比較する。また参考のため表 3.2 において、それぞれの MSF を単独で用いた場合についても計算を行った。ここでは、ルール数を $n = 10$ として学習を開始している。式(3.2)のように比較的単純な滑らかな曲線の近似においては、図 3.5 に示すように、両方とも釣鐘型 MSF からなる 2 ルールで平均自乗誤差が最小に至っている。MSF 単独のものと比較すると、表 3.2 から釣鐘型 MSF では 3 ルールで最小に至っているが、二等辺三角型 MSF, DRTMSF では最小平均自乗誤差が 1 桁大きい。これは釣鐘型 MSF の形状が学習データの分布に適合しているものと考えられる。図 3.6 にルール数の推移を示す。三角型 MSF 10 ルールで学習を開始しているが、平均自乗誤差が最小に至ったときには釣鐘型 MSF 2 ルールに置き換わっている様子がわかる。式(3.3)~(3.4)のように不連続度が上昇するにつれて最小平均自乗誤差は上昇している。また図 3.7, 図 3.8 に示すように、釣鐘型 MSF のみではなく二等辺三角型 MSF や DRTMSF といった三角型の MSF が現れてくる。式(3.3)について両方を比較すると、図 3.7 のように釣鐘型 MSF + 二等辺三角型 MSF に比べ釣鐘型 MSF + DRTMSF の方が少ないルール数で最小に至っていることがわかる。し



(a)釣鐘型MSF+二等辺三角型MSF



(b)釣鐘型MSF+DRTMSF

図 3.5: 式 (3.2) において自動調整の結果得られた MSF






図 3.6: ルール数の推移

かし表 3.2 に示すように単独の MSF の場合と比較しても平均自乗誤差, ルール数に大差がないため, この学習データの分布に対してはどのような MSF の組み合わせであってもほぼ 6 ルールで最小に至ると考えられる。式 (3.4) において, 図 3.8(a) のように釣鐘型 MSF + 二等辺三角型 MSF は二等辺三角型 MSF が 10 ルールで最小となっている。これも二等辺三角型 MSF が DRTMSF に対して自由度が劣るのが原因といえる。また, パラメータの初期設定が等間隔の二等辺三角型 MSF で開始するため, ルール数の多い開始時は関数形状に適合しやすい状況にある。表 3.2 からその様子が見える。図 3.8(b) は式 (3.4) の最小平均自乗誤差を取るときの MSF 形状である。学習すべき関数の不連続点において DRTMSF の中心にあるグレードの不連続部分が適切に拡張していることがわかる。また, それを補うように釣鐘型 MSF が存在している。以上のシミュレーション結果から, 1 入力 1 出力の関数近似問題に対して, 学習データの分布に適合した MSF が選択され, より少ないルール数でモデリングされることがわかった。さらに, 自由度の高い MSF を用いれば, より少ないルール数でのモデリングが可能であるといえる。




(a)釣鐘型MSF+二等辺三角型MSF




(b)釣鐘型MSF+DRTMSF

図 3.7: 式 (3.3) において自動調整の結果得られた MSF



(a)釣鐘型MSF+二等辺三角型MSF



(b)釣鐘型MSF+DRTMSF

図 3.8: 式 (3.4) において自動調整の結果得られた MSF

3.4.2 2入力1出力の関数近似問題

関数近似問題において多次元データに対しても様々なアプローチが提案されている [8, 9, 12]。本手法を被制御モデルの一例として式 (3.5)~(3.7) に示す 2 入力 1 出力の関数近似問題に適用を試みた。ここで、式 (3.5) は、滑らかな形状のモデル関数、式 (3.6) は、微分不可能な部分が存在する関数、式 (3.7) は、不連続な部分が存在する関数である。シミュレーションの方法は、入出力関係を表す関数から、 $x_1, x_2 \in [-1.0, 1.0]$ について 400 組の学習データを取り出し、それらを用いてファジィルールの自動調整を行った。前件部 MSF の初期設定は図 3.9 に示すように各ルール毎に MSF を設定した。また、MSF が釣鐘型、三角型と交互に並ぶように配置し、グレードが 0.5 のところでそれぞれの MSF が重なるようにした。ルール数は 16 ルールから学習を開始した。式 (3.5)~(3.7) に対して 100000 回学習を行い、平均自乗誤差が最小となる値を取り出した。

$$y = 1 - 0.5x_1^2 - 0.5x_2^2 \quad (3.5)$$

$$y = \begin{cases} -0.5(x_1 + x_2) & , x_1 + x_2 < 0 \\ 0.25(x_1 + x_2)^2 & , 0 \leq x_1 + x_2 \end{cases} \quad (3.6)$$

$$y = \begin{cases} 1 & , -1 \leq (x_1, x_2) < 0 \\ 0.5(x_1^2 + x_2^2) & , 0 \leq (x_1, x_2) < 1 \\ 0 & , otherwise \end{cases} \quad (3.7)$$

表 3.3 において、釣鐘型 MSF + 二等辺三角型 MSF と釣鐘型 MSF + DRTMSF を用いた場合の最小平均自乗誤差の値、ならびにルール数を比較する。図 3.10, 図 3.12, 図 3.13 は学習後の MSF の位置情報を示している。釣鐘型 MSF は楕円で表し、長軸、短軸の交点が頂点位置を、長軸、短軸の長さがグレード 0.5 における MSF の幅を示している。三角型 MSF は長方形で表し、その各辺の midpoint から対になる辺の midpoint へ結んだ線の交点が頂点位置を、各辺の長さが MSF の幅を示している。式 (3.5) のように比較的単純な滑らかな曲面の近似においては、図 3.10 に示すように、両方とも釣鐘型 MSF からなる 3 ルールで平均自乗誤差が最小に至っている。図 3.11 にルール数の推移を示す。釣鐘型 MSF 8 ルール、三角型 MSF 8 ルールで学習を開始しているが、平均自乗誤差が最小に至ったときには釣鐘型 MSF 3 ルールに置き換わっている様子がわかる。式 (3.6) のように微分不可能な部分が存在する関数においては、図 3.12, 図 3.13 に示すように、釣鐘型 MSF のみではなく二等辺三角型 MSF や DRTMSF と




図 3.9: 前件部 MSF の初期設定




図 3.10: 式 (3.5) において自動調整の結果得られた MSF の位置 (釣鐘型 MSF + DRTMSF)

表 3.3: 平均自乗誤差, ルール数の比較

	釣鐘型+二等辺三角型		釣鐘型+DRT	
近似対象	平均自乗誤差		平均自乗誤差	
	全ルール数		全ルール数	
	釣鐘型数	二等辺三角型数	釣鐘型数	DRT数
式(3.5)	5.00×10^{-5}		4.92×10^{-5}	
	3		3	
	3	0	3	0
式(3.6)	6.97×10^{-4}		6.82×10^{-4}	
	9		6	
	5	4	3	3
式(3.7)	3.66×10^{-3}		3.24×10^{-3}	
	5		4	
	1	4	1	3




図 3.11: ルール数の推移




図 3.12: 式 (3.6) において自動調整の結果得られた MSF の位置 (釣鐘型 MSF + DRTMSF)




図 3.13: 式(3.7)において自動調整の結果得られた MSF の位置 (釣鐘型 MSF + DRTMSF)

いった三角型の MSF が現れてくる。式(3.6)~(3.7)について両方を比較すると、表 3.3 のように釣鐘型 MSF + 二等辺三角型 MSF に比べ釣鐘型 MSF + DRTMSF の方が少ないルール数で最小に至っていることがわかる。これは、三角型 MSF の形状による自由度からくるものと考えられる。以上のシミュレーション結果から、2入力1出力の関数近似問題に対しても、学習データの分布に適合した MSF が選択され、より少ないルール数でモデリングされることがわかった。

3.5 結言

本章では、最急降下法を用いたファジィルールの自動調整において、GA の手法を付加し MSF の適否の判定、種類の選択及びその最適化の可能な遺伝子を個体に組み込んだ。これにより、モデルの形状に適合した1種または複数種類の MSF を選択することができ、被制御モデルをあらかじめ準備した MSF に関して最小の MSF 個数で表現できることを示した。本手法は、連続的及び不連続的特性をもつ被制御モデル、例えばカオス的なふるまいを示す

時系列の予測などのファジィ制御に有効であると考えられる。

第4章 多入出力学習データへの適用と汎化能力

4.1 序言

第3章では、最急降下法を用いたファジィルールの自動調整において、GAの手法を付加しMSFの適否の判定、種類の選択及びその最適化の可能な遺伝子を個体に組み込んだ。これにより、モデルの形状に適合した複数種類のMSFを選択することができ、あらかじめ準備したMSFに関して最小のMSFの個数を決定できることがわかった。しかし、学習後のモデル関数の様子や、学習データとは異なる検査データに対しての振る舞いについてはわかっていなかった。また、多入出力の学習データに対しても適用していなかった。そこで、第3章の手法を様々な数値例に適用し、シミュレーションによりその汎化能力を示す。

4.2 多入出力学習データにおけるファジィ推論方法

4.2.1 簡略化ファジィ推論

本手法では、多出力に対応するため次に示すような後件部出力値が実数値の簡略化ファジィ推論を用いる。

$$\begin{aligned} \text{Rule } i : & \text{if } x_1 \text{ is } A_{1i} \text{ and } x_2 \text{ is } A_{2i} \text{ and } \dots \\ & \text{and } x_j \text{ is } A_{ji} \text{ and } \dots \text{ and } x_m \text{ is } A_{mi} \\ & \text{then } y_k \text{ is } w_{ki} \quad (i = 1, \dots, n) \end{aligned} \quad (4.1)$$

式(4.1)において、 A_{ji} は前件部MSF、 w_{ki} は $k(k = 1, \dots, l)$ 番目の後件部出力値、添え字 i はルール番号、添え字 $j(j = 1, \dots, m)$ は入力変数の番号を表す。制御量 y は、各ルールの前件部適合度 μ_i を式(4.2)で示す代数積で算出し、式(4.3)で示すように要素 w_{ki} の重み μ_i

による重み付き平均によって推論出力を決定する。

$$\mu_i = A_{1i}(x_1)A_{2i}(x_2)\cdots A_{ji}(x_j)\cdots A_{mi}(x_m) \quad (4.2)$$

$$y_k = \frac{\sum_{i=1}^n \mu_i \cdot w_{ki}}{\sum_{i=1}^n \mu_i} \quad (4.3)$$

4.2.2 多入出力学習データにおける学習過程

ここでは、よくファジィ推論に使用される以下に示す二等辺三角型 MSF、釣鐘型 MSF の 2 種類の MSF を用いる。

本手法では、ファジィ推論ルールの調整には、NN の学習則である最急降下学習法を用いる。図 4.1 に NN 表現の概念図を示す。ここで、学習の対象となるのは NN における入力層と中間層ユニットの結合係数と中間層と出力層ユニットの結合係数、すなわち推論ルールの前件部 MSF と後件部実数値である。

最急降下学習法において、学習の方向を決定する評価関数を次に示すように定義する。

$$E = \frac{1}{2}(y_k - y_k^*)^2 \quad (4.4)$$

式(4.4)において、 y は NN の出力値で、 y^* は入出力学習データである。最急降下学習法では、式(4.4)で定められた評価関数の値が最も小さくなる方向に逐次的に学習を繰り返し、最適な解を得る。

次に、二等辺三角型 MSF、釣鐘型 MSF の場合の各学習手順におけるパラメータの学習式を示す。

$$w_i(t+1) = w_i(t) - K_w \frac{\partial E}{\partial w_i} \quad (4.5)$$

$$a_{ji}(t+1) = a_{ji}(t) - K_a \frac{\partial E}{\partial a_{ji}} \quad (4.6)$$

$$b_{ji}(t+1) = b_{ji}(t) - K_b \frac{\partial E}{\partial b_{ji}} \quad (4.7)$$

式(4.5)~(4.7)で、 K_w, K_a, K_b は学習の刻み幅を決定する学習係数である。変数 t は学習回数が t 回目であることを示している。これらの学習過程を通して、望まれる推論ルールが得られる。 P 組の入出力学習データを仮定し、学習回数 t に対する平均自乗誤差 G_t を計算




図 4.1: 簡略化ファジィ推論の概念図

する。

$$G_t = \frac{1}{P} \sum_{p=1}^P \sum_{k=1}^l (y_{kp}^*(t) - y_{kp}(t))^2 \quad (4.8)$$

平均自乗誤差 G_t が、あらかじめ定められた閾値 ε より小さくなったとき学習の終了とする。

$$G_t \leq \varepsilon \quad (4.9)$$

式 (4.9) が満たされない場合は、再び最初の入力データの組から学習を繰り返す。GA の手法を用いた局所最適解の回避については、第 3.3 節と同様に行う。

4.3 MSF 形状選択による汎化能力

4.3.1 1入力1出力の関数近似問題

本手法を次の各数式に示される2種類の1入力1出力の関数の近似問題に適用し、MSF形状選択の有効性を検討する。

$$y = \begin{cases} x+1 & , -1 \leq x < 0 \\ -x+1 & , 0 \leq x < 1 \end{cases} \quad (4.10)$$


$$y = -x^2 + 1 \quad (4.11)$$

ここで、式(4.10)は、微分不可能な点が存在する関数、式(4.11)は、滑らかな形状の関数である。はじめに、式(4.10)~(4.11)の入力値 x を乱数により $[-1, 1]$ の範囲で発生させ、各式を計算し出力値 y を得る。そして、各式において100組の入出力データと10組の入出力データを取得する。また、出力値 y は $[0, 1]$ の範囲で正規化する。


そして、10個の前件部MSFを入力領域に均等に配置し、前章に示した学習の手順に従って、入出力関係を表現するよう逐次的に学習を行い、平均自乗誤差が最小となる値を取り出す。GA法を利用した頂点位置移動については、頂点位置遺伝子(2進数8ビット長)、MSFのon,off遺伝子(2進数1ビット)、MSFの種類遺伝子(2進数1ビット)からなりルール数(10ルール)分結合した個体を20個体を生成する。その後、5世代淘汰を行う。交叉は1対の遺伝子を選択し交叉確率1.0で交叉を行う。突然変異操作はビット選択確率0.1で行う。

式(4.10)~(4.11)について、釣鐘型MSF単独、二等辺三角型MSF単独、両方のMSFを用いた本手法の3種類の場合について、100組の入出力データと10組の入出力データに学習を適用した。

式(4.10)によって与えられる学習結果を図4.2~4.4、表4.1に示す。また、式(4.11)によって与えられる学習結果を図4.5~4.7、表4.2に示す。図4.2、図4.5は、それぞれ平均自乗誤差が最小値をとるとき、釣鐘型MSF単独、二等辺三角型MSF単独で使用した場合における100組の学習データと学習後のモデル関数を示している。図4.3、図4.6は、それぞれ平均自乗誤差が最小値をとるとき、釣鐘型MSF単独、二等辺三角型MSF単独で使用した場合における10組の学習データと学習後のモデル関数を示している。図4.4、図4.7は、それぞれ平均自乗誤差が最小値をとるとき、両方のMSFからなる本手法を使用した場合、100組、10




(a) 釣鐘型MSF単独で使⽤した場合




(b) 二等辺三角型MSF単独で使⽤した場合

図 4.2: 式 (4.10) における 100 組の学習データと学習後のモデル関数との比較




(a) 釣鐘型MSF単独で使用了した場合




(b) 二等辺三角型MSF単独で使用了した場合

図 4.3: 式 (4.10) における 10 組の学習データと学習後のモデル関数との比較



(a) 学習データ100組の場合



(b) 学習データ10組の場合


図 4.4: 式 (4.10) における本手法を用いた学習データと学習後のモデル関数との比較

表 4.1: 式 (4.10) におけるルール数の比較

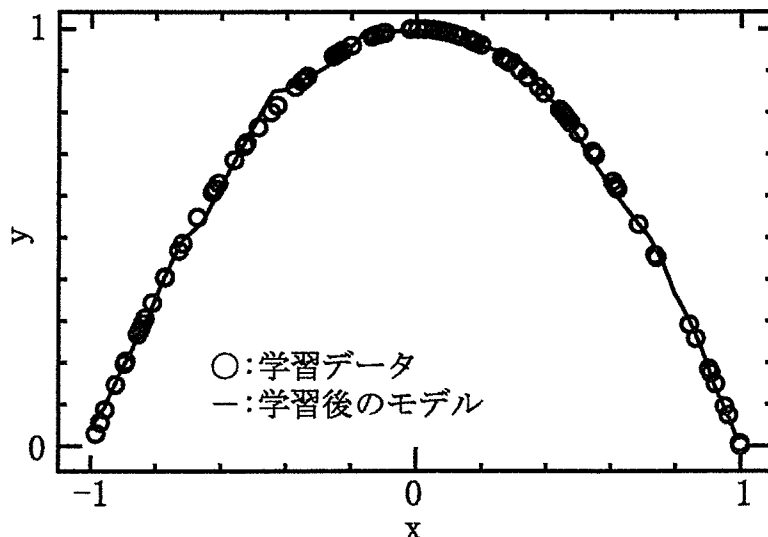
	全ルール数 (釣鐘型, 二等辺三角型)		
	釣鐘型	二等辺三角型	釣鐘型 + 二等辺三角型
学習データ 100組	5 (5, 0)	5 (0, 5)	4 (0, 4)
学習データ 10組	6 (6, 0)	6 (0, 6)	6 (3, 3)

表 4.2: 式 (4.11) におけるルール数の比較

	全ルール数 (釣鐘型, 二等辺三角型)		
	釣鐘型	二等辺三角型	釣鐘型 + 二等辺三角型
学習データ 100組	3 (3, 0)	8 (0, 8)	4 (4, 0)
学習データ 10組	4 (4, 0)	4 (0, 4)	6 (3, 3)




(a) 釣鐘型MSF単独で使⽤した場合




(b) 二等辺三角型MSF単独で使⽤した場合

図 4.5: 式 (4.11) における 100 組の学習データと学習後のモデル関数との比較




(a) 釣鐘型MSF単独で使した場合

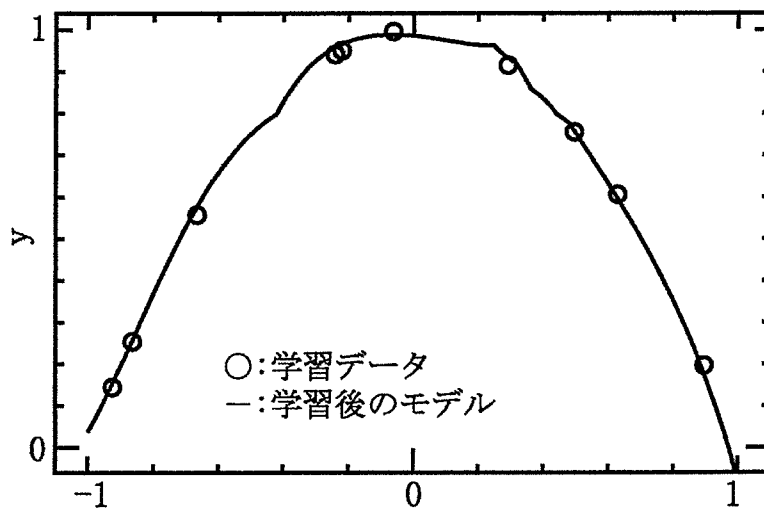


(b) 二等辺三角型MSF単独で使した場合

図 4.6: 式(4.11)における 10 組の学習データと学習後のモデル関数との比較



(a) 学習データ100組の場合



(b) 学習データ10組の場合

図 4.7: 式 (4.11) における本手法を用いた学習データと学習後のモデル関数との比較

組の学習データと学習後のモデル関数を示している。表 4.1 は、式 (4.10) によって与えられる学習の結果、図 4.2~4.4 のそれぞれの場合におけるルール数を示している。表 4.2 は、式 (4.11) によって与えられる学習の結果、図 4.5~4.7 のそれぞれの場合におけるルール数を示している。表 4.1, 表 4.2 の括弧内の数値 (n_1, n_2) は、 n_1 が釣鐘型 MSF のルール数、 n_2 が二等辺三角型 MSF のルール数を示している。

式 (4.10) において、図 4.2(a) に示すように釣鐘型 MSF 単独で使った場合、 $x = 0$ において学習データと学習後のモデル関数との間にギャップが存在することがわかる。一方、図 4.2(b) に示すように二等辺三角型 MSF 単独の場合、領域全体にわたって学習後のモデル関数が学習データにフィットしていることがわかる。これは、釣鐘型 MSF の滑らかな形状が図 4.2(a) のギャップを引き起こしていると考えられる。学習データ数を 10 組に領域全体にわたって減らしたとき、図 4.3(a) に示すように釣鐘型 MSF 単独で使った場合、学習後のモデル関数は滑らかに学習データにフィットしていることがわかる。一方、図 4.3(b) に示すように二等辺三角型 MSF 単独の場合、学習後のモデル関数は学習データを通過しているけれども、学習データを除く領域においてそれはジグザグな振る舞いをしている。その理由として考えられるのは、二等辺三角型 MSF が直線と不連続点から成り立っているためであり、このような過学習に近い状態では、学習データを除く領域において MSF の素性が際立つ。図 4.4 に示すように、両方の MSF からなる本手法を使用した場合、それぞれの MSF 単独で使用する場合の問題は解決される。図 4.4(a) は学習データ 100 組の学習結果であるが、二等辺三角型 MSF 単独で使った場合と同じように領域全体にわたって学習後のモデル関数が学習データにフィットしていることがわかる。また表 4.1 に示すように、本手法は適切に二等辺三角型 MSF を選択していることがわかる。図 4.4(b) は学習データ 10 組の学習結果であるが、学習後のモデル関数は図 4.3(a) に示すような釣鐘型 MSF 単独で使った場合に比べ、式 (4.10) で与えられる関数形状に似ている。それは表 4.1 からわかるように両方の MSF を適切に使用することにより、それぞれの MSF の素性の良い部分を引き出していると考えられる。

式 (4.11) において、図 4.5 に示すように釣鐘型 MSF 単独、あるいは二等辺三角型 MSF 単独で使った場合、領域全体にわたって学習後のモデル関数が学習データにフィットしていることがわかる。領域全体における学習データ密度が高いためおのおの単独で用いた場合、両者にはほとんど違いはない。学習データ数を 10 組に領域全体にわたって減らしたとき、図

4.6(a) に示すように釣鐘型 MSF 単独で使用した場合、学習後のモデル関数は滑らかに学習データにフィットしていることがわかる。一方、図 4.6(b) に示すように二等辺三角型 MSF 単独の場合、学習後のモデル関数は学習データを通過しているけれども、領域の端ではフラットになっている。理由として考えられるのは、釣鐘型 MSF は関数形状に裾野が存在するが二等辺三角型 MSF はそれを持ち合わせていない。図 4.7 に示すように両方の MSF からなる本手法を使用した場合、それぞれの MSF 単独で使用する場合は問題は解決される。図 4.7(a) は学習データ 100 組の学習結果であるが、釣鐘型 MSF 単独で使用した場合と同じように領域全体にわたって学習後のモデル関数が学習データにフィットしていることがわかる。また表 4.2 に示すように、本手法は適切に釣鐘型 MSF を選択していることがわかる。図 4.7(b) は学習データ 10 組の学習結果であるが、学習後のモデル関数は図 4.6(a) に示すような釣鐘型 MSF 単独で使用した場合に次いで、式 (4.11) で与えられる関数形状に似ている。それは表 4.2 からわかるように両方の MSF を適切に使用することにより、それぞれの MSF の素性の良い部分を引き出していると考えられる。

4.3.2 2 入力 2 出力の関数近似問題

多入出力学習データへの適用効果を検証するために、2 入力 2 出力の関数の近似問題に適用した。

$$\begin{cases} x(t+1) = 1 - 1.4x(t)^2 + y(t) \\ y(t+1) = 0.3x(t) \end{cases} \quad (4.12)$$

$$\begin{cases} x(t+1) = 1 + 0.9(x(t)\cos(\theta(t)) - y(t)\sin(\theta(t))) \\ y(t+1) = 0.9(x(t)\sin(\theta(t)) + y(t)\cos(\theta(t))) \\ \theta(t) = 0.4 - 6.0/(1 + x(t)^2 + y(t)^2) \end{cases} \quad (4.13)$$

$$\begin{cases} x(t+1) = 0.8x(t) + 0.2f(y(t)) - f(x(t)) + 0.68 \\ y(t+1) = 0.8x(t) + 0.2f(x(t)) - f(y(t)) + 0.68 \\ f(z) = 1/(1 + \exp(-z/0.04)) \end{cases} \quad (4.14)$$

ここで、式 (4.12) はエノン写像の関数、式 (4.13) は池田写像の関数、式 (4.14) はカオスニューラルネットワークの関数を示している [19]。これらの関数はしばしばカオス理論の代表的な写像として使用される。関数近似は次のような条件で実行される。

(a) 各関数から時系列データを生成する。

表 4.3: 式 (4.12) における最小平均自乗誤差とルール数の比較

	釣鐘型	二等辺三角型	釣鐘型 + 二等辺三角型
全ルール数 (釣鐘型, 二等辺三角型)	7 (7, 0)	16 (0, 16)	7 (2, 5)
平均自乗誤差 (学習データ)	4.54×10^{-3}	2.14×10^{-3}	2.31×10^{-3}
平均自乗誤差 (検査データ)	6.32×10^{-3}	3.57×10^{-3}	2.87×10^{-3}

- (b) 時系列データから 100 組の学習データ $(x(t), y(t), x(t+1), y(t+1))$ を取り出す。
- (c) 学習データの入力を $x(t), y(t)$ とする。
- (d) 学習データの出力を $x(t+1), y(t+1)$ とする。

GA 法を利用した頂点位置移動については、前節と同様に行う。MSF は 16 個用意し入力領域を隈なく覆うように等間隔に配置した。式 (4.12)~(4.14) に示した 3 種類の関数に適用し、二等辺三角型 MSF と釣鐘型 MSF 両方を使用した本手法とそれぞれ単独で MSF を使用した場合を比較した。表 4.3~4.5 の近似結果は全ルール数、学習データによる最小平均自乗誤差、検査データ (学習データとは別の 100 組) による最小平均自乗誤差を示している。図 4.8 は調整後の MSF の様子である。



二等辺三角型 MSF 単独の場合、学習データによる最小平均自乗誤差は、式 (4.12)~(4.14) に示した 3 種類の関数の中で最小である。しかし、全ルール数は 3 種類の関数の中で最も多い。一方、二等辺三角型 MSF と釣鐘型 MSF 両方を使用した本手法の場合、3 種類の関数の中で全ルール数は最も少ない。また、学習データによる最小平均自乗誤差から検査データによる最小平均自乗誤差の増加量は最小である。これは汎化能力が優れていることの指標とし

表 4.4: 式 (4.13) における最小平均自乗誤差とルール数の比較


	釣鐘型	二等辺三角型	釣鐘型 + 二等辺三角型
全ルール数 (釣鐘型, 二等辺三角型)	6 (6, 0)	10 (0, 10)	7 (2, 5)
平均自乗誤差 (学習データ)	1.07×10^{-1}	2.98×10^{-2}	2.99×10^{-2}
平均自乗誤差 (検査データ)	1.15×10^{-1}	4.17×10^{-2}	3.52×10^{-2}

表 4.5: 式 (4.14) における最小平均自乗誤差とルール数の比較

	釣鐘型	二等辺三角型	釣鐘型 + 二等辺三角型
全ルール数 (釣鐘型, 二等辺三角型)	9 (9, 0)	8 (0, 8)	8 (3, 5)
平均自乗誤差 (学習データ)	1.74×10^{-2}	1.13×10^{-3}	1.37×10^{-3}
平均自乗誤差 (検査データ)	2.32×10^{-2}	2.53×10^{-3}	2.45×10^{-3}



(a) 二等辺三角型MSF単独で使用了した場合



(b) 両方のMSFをを使用した場合(釣鐘型+二等辺三角型)

図 4.8: 式 (4.13) について学習によって得られた MSF

てよい。また、図 4.8(a) に示すように二等辺三角型 MSF 単独でを使用した場合、入力領域において MSF が存在しない領域が存在するが、図 4.8(b) に示すように両方の MSF を使用した本手法の場合、そのような領域は存在しない。よって、全ルール数、汎化能力に関してこの手法は優れているといえる。

4.4 結言

本章では、第 3 章の手法を多入出力学習データに適用した。これにより、多入出力学習データに対してもモデルの形状に適合した 1 種または複数種類の MSF を選択することができ、被制御モデルをあらかじめ準備した MSF に関して最小の MSF 個数で表現できることを示した。また、学習後のモデル関数において MSF 単独でを使用した場合と比較し第 3 章の手法は優れていることがわかった。さらに学習データによる最小平均自乗誤差から検査データによる最小平均自乗誤差の増加量についても MSF 単独でを使用した場合と比較し最小であることがわかった。よって、第 3 章の手法は汎化能力についても有効であるといえる。

第5章 加速度脈波のファジィモデリング

5.1 序言

指尖加速度脈波の様々な応用の中で、指尖加速度脈波カオス解析がある [26, 27]。加速度脈波のカオス統計量として、軌道平行測度法 (TPM)[28] とリカレンスプロット法 [19] が解析に用いられている。TPM はカオスアトラクタの任意の接線ベクトルの平行度を示している。また、リカレンスプロット法は、時系列波形のカオス的非定常性を視覚化する手法として注目されている。しかし、この2つのカオス統計量は、カオスアトラクタの形状を的確に捉えるものではなく、その形状の一部分の情報しか持ち合わされていない。それを補うように、加速度脈波の時系列における振幅比を形状パラメータとして使用されている [27] が、被験者によってはその値が検出されにくい場合が存在する。また、加速度脈波が周期ごとに波形が異なることがあり、時間的に振幅比が変動することも観測されている。そこで、上記に左右されず加速度脈波情報を取り入れるために FNN[4, 5, 6, 14] を応用する。第3章で示した手法を MSF の種類の選択に特化し、時系列加速度脈波データとそのカオスアトラクタ形状のモデリングを行なう。また、学習後の MSF の種類、後件部実数値等を形状特徴量ベクトルとして取り出し、そのベクトルを自己組織化マップに入力することにより脈波データの分類を行なう。

5.2 脈波データの分類に特化した種々の MSF を用いたファジィ推論

5.2.1 簡略化ファジィ推論

本手法では、次に示すような後件部出力値が実数値の簡略化ファジィ推論を用いる。

Rule i : if x_1 is A_{1i} and x_2 is A_{2i} and...

$$\begin{aligned} & \text{and } x_j \text{ is } A_{ji} \text{ and } \cdots \text{ and } x_m \text{ is } A_{mi} \\ & \text{then } y \text{ is } w_i \text{ (} i = 1, \cdots, n \text{)} \end{aligned} \quad (5.1)$$

式(5.1)において、 A_{ji} は前件部MSF、 w_i は後件部出力値、添え字 i はルール番号、添え字 $j(j = 1, \cdots, m)$ は入力変数の番号を表す。制御量 y は、各ルールの前件部適合度 μ_i を式(5.2)で示す代数積で算出し、式(5.3)で示すように要素 w_i の重み μ_i による重み付き平均によって推論出力を決定する。しかし、この章では前件部MSFの形状パラメータの調整は行わず、後件部のみの調整となるので $\sum_{i=1}^n \mu_i = 1$ とする。

$$\mu_i = A_{1i}(x_1)A_{2i}(x_2) \cdots A_{ji}(x_j) \cdots A_{mi}(x_m) \quad (5.2)$$

$$y = \sum_{i=1}^n \mu_i \cdot w_i \quad (5.3)$$

また、ここでは二等辺三角型MSF、釣鐘型MSFの2種類のMSFを用いて種類選択を行う。本手法では、ファジィ推論ルールの調整においてNNの学習機能を利用するために、式(5.1)~(5.3)で示されるファジィ推論の各演算をNNの各機能に割り当て、ファジィ推論の過程をNNで表現する[5, 14]。図5.1にNN表現の概念図を示す。学習アルゴリズムについては、第2.3節と同様に行うが、後件部のみの調整となる。本手法の学習の順序を、図5.2のフローチャートに示す。

5.3 脈波データの分類に特化したGA法を用いたMSFの種類選択

最急降下法による学習過程において、平均自乗誤差 G_t の減少が微量であるため期待する状態まで学習が進まない場合がある。これは、MSFが学習データに対して適切な位置に配置されていないこと、冗長なルールが存在すること、さらにMSFの形状が学習データに合致していないことに起因すると考える。この場合、我々はMSFの頂点位置 a_{ji} を移動すること、MSFの種類、個数を変えることにより、MSFを学習データに対し適切に配置をすることを提案している[25]。

本章では脈波データに使用するため、個体の機能をMSFの種類選択、後件部実数値のみに絞った。図5.3に示すように1つの個体は、複数のルールから構成されている。個体にはルールごとにMSFの種類選択を遺伝子コード(有限ビット長の2進数、かつ、固定小数点数




図 5.1: 簡略化ファジィ推論の概念図

として表現)とし、その遺伝子ビットを個体に組み込んだ。GA の操作には、基本的な操作のみを行うものから、他点交叉などを備えた複雑なものまで、さまざまな場合が考えられる。ここでは、一般に単純 GA として知られているものを適用するが、必ずしも単純 GA である必要はない。GA による最適化の操作として、以下に挙げる各操作を行う。

(1) 初期個体の生成

乱数を用いて図 5.3 に示すような構成をもった一定個数の遺伝子を生成する。

(2) 各個体の評価と優良個体の保存

次に平均自乗誤差の逆数を適応度とし生殖操作を行い適応度が高い個体を次世代の個体として選んでいく。

(3) 交叉

個体群の中から 1 対の遺伝子を選択し、1 点交叉を行う。このとき、ランダムに選択される交叉位置は、ルールフィールドの境界とする。

(4) 突然変異

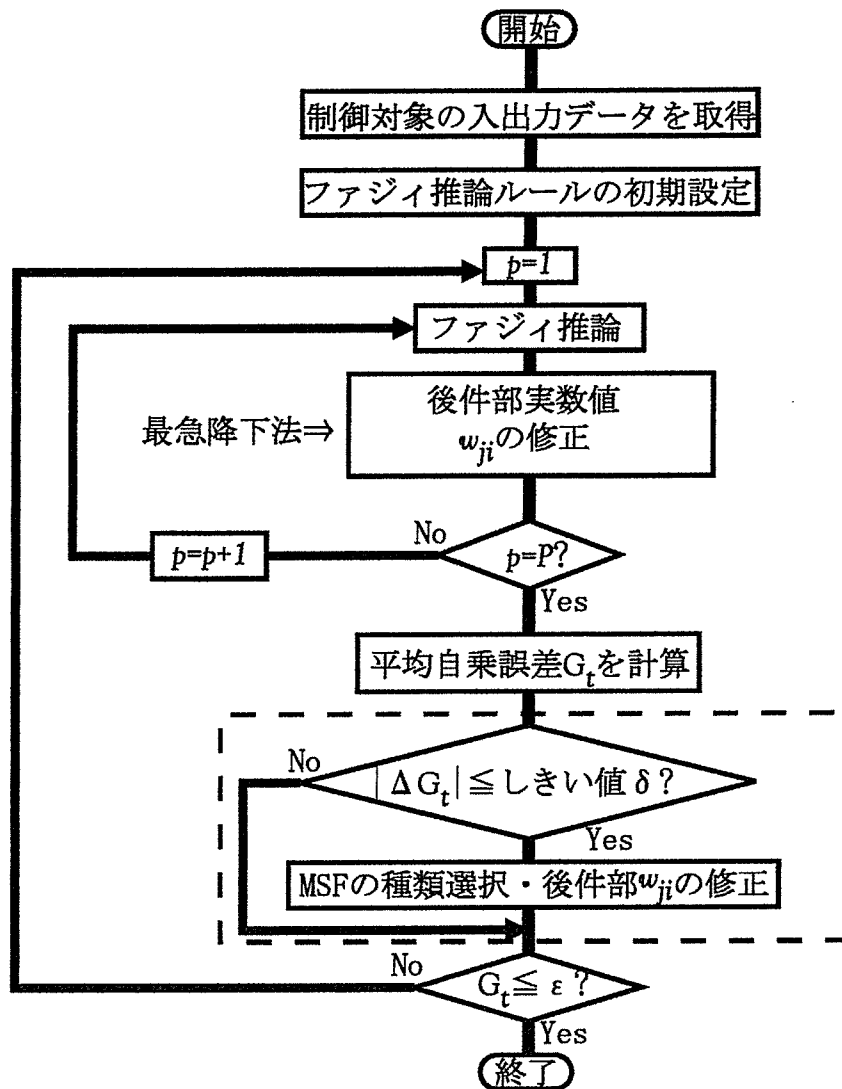


図 5.2: 本手法の学習手順の流れ図




図 5.3: 遺伝子の構成と変更過程

突然変異操作によりビット選択確率に基づき各ビットを反転する。

最後に最大適応度の個体を選択し最急降下法による学習過程に復帰するが、図 5.3 に示すように遺伝子情報に基づき、MSF の種類を指定する遺伝子により形状を選択する。




図 5.4: 時系列加速度脈波データ

5.4 脈波データの解析

5.4.1 時系列加速度脈波データのモデリング

本手法を図 5.4 に示すような時系列加速度脈波データ (200Hz サンプルング, 1200 点) に適用し, その有効性を検討する。まず, 図 5.5 に示すように 1200 点の時系列信号である脈波データから 1 波長分切り出し, 脈波データが最大値をとる時間軸の座標を入力値 $x = -1.0$ とし, 最初に脈波データの値が 0 となる座標を $x = -0.9$ とすることで, 全データの最大振幅時の時間幅を合わせる規格化を行ない, 入力値 $x = 1.0$ で波形をうち切る。よって, $[-1, 1]$ を入力値とし, 振幅値 y を出力値とする。

時系列加速度脈波データのモデリングでは, 次に示すような式 (5.1) を 1 入力 1 出力用に限定した簡略化ファジィ推論を用いる。

$$\text{Rule } i : \text{if } x \text{ is } A_{1i} \text{ then } y \text{ is } w_i \quad (i = 1, \dots, n) \quad (5.4)$$

式 (5.4) において, A_{1i} は前件部 MSF, w_i は後件部出力値, 添え字 i はルール番号を表す。

そして, 図 5.2 に示した学習の手順に従って, 入出力関係を表現するよう逐次的に学習し, 平均自乗誤差が最小となる値を取り出す。GA 法を利用した種類選択については, MSF の種類を決める遺伝子 (2 進数 1 ビット) からなりルール数 (30 ルール) 分結合した個体を 20 個体




図 5.5: 時系列加速度脈波データの切り出し




図 5.6: MSF の初期設定




図 5.7: 学習データと学習後のモデルとの比較 (健常)




図 5.8: 学習データと学習後のモデルとの比較 (インフルエンザ)




図 5.9: 学習データと学習後のモデルとの比較 (中年女性更年期)




図 5.10: 学習データと学習後のモデルとの比較 (動脈硬化)




図 5.11: 学習後の MSF の様子 ($x = [-0.5, 0]$)

を生成する。その後、5 世代淘汰を行う。交叉は 1 対の遺伝子を選択し交叉確率 1.0 で交叉を行う。突然変異操作はビット選択確率 0.1 で行う。前件部 MSF の初期設定は図 5.6 に示すように各ルール毎に MSF を設定した。また、MSF が釣鐘型、三角型と交互に並ぶように配置し、グレードが 0.5 のところでそれぞれの MSF が重なるようにした。

健常者 5 例、インフルエンザ失病者 5 例、中年女性更年期者 10 例、動脈硬化失病者 10 例について学習を行ない、平均自乗誤差が最小となる値を取り出した。図 5.7~5.10 にそれぞれ 1 例ずつ、学習データの分布と学習後のモデルの比較を示す。図 5.7 は通常の流れの状態、図 5.8 は体がインフルエンザウィルスを除去しようがんばって血流を異常によくしようとしている状態、図 5.9 はホルモン異常などでやや渋滞した状態、図 5.10 は血流が渋滞した状態を示していると考えられる。各群の中でも重症度によって多少差はあるが、形状的にはこのような特徴を持ち合わせている。図 5.7~5.10 からわかるように、学習データの分布に学習後のモデルが沿っている様子が観察できる。また、図 5.11 に学習後の MSF の様子 $x = [-0.5, 0]$ を示す。学習データの分布に応じて平均自乗誤差が最小になるように適切に MSF を選択している。




図 5.12: 時系列加速度脈波分類マップ

5.4.2 自己組織化マップによる加速度脈波データの分類

健全者 5 例，インフルエンザ失病者 5 例，中年女性更年期者 10 例，動脈硬化失病者 10 例を前節の手法を用いてモデリングを行ない，その学習結果をパラメータとして SOM に入力した。最初に，健全者 5 例に $k1 \sim k5$ ，インフルエンザ失病者 5 例に $i1 \sim i5$ ，中年女性更年期者 10 例に $d1 \sim d10$ ，動脈硬化失病者 10 例に $f1 \sim f10$ とラベリングした。

全 30 例に対してモデリングを行い，その学習結果から MSF の種類 (便宜的に二等辺三角型は 0、釣鐘型は 0.2 として数値を割り振った。)，MSF の後件部実数値 w (学習結果の値をそのまま使用) を自己組織化マップに入力するパラメータとした。シミュレーションには SOMPAK[29] を用いた。図 5.12 に時系列加速度脈波分類マップを示す。図 5.12 に示されるように，健全 (図左下，インフルエンザ右隣)，インフルエンザ (図 5.12 左下)，中年女性更年期 (図 5.12 左上)，動脈硬化 (図 5.12 右下) に分類されていることがわかる。ここで， $i1$ が中年女性更年期に含まれていることがわかる。これは，それぞれの波形の形状が中年女性更年期と似通った部分が存在することを示している。また $i2$ は図 5.12 右上に 1 つの区画を形成




図 5.13: i2 と他のインフルエンザ学習データ

している。これは、図 5.13 に示すように本手法の時系列加速度脈波データの時間幅規格化が当てはまらない例であると考えられる。そこで、i2 を除いた時系列加速度脈波分類マップを図 5.14 に示す。特異データである i2 が除かれたため、区分けがより鮮明になり境界データはあるものの適切に分類されている。以上のシミュレーション結果から、時系列加速度脈波のモデリングデータより、健常、インフルエンザ、中年女性更年期、動脈硬化の分類は可能であることがわかった。しかし、このモデリングでは時系列加速度脈波の 1 波長分しか適用していないため、脈波周期や振幅の時間的な変化に関係した TPM, RP-dw[19, 28] を代表とするアトラクタの平行度や定常度といった情報があまり入らない。そこで、加速度脈波アトラクタをモデリングすることにより、そのような情報を得る手段を次節で説明する。

5.4.3 加速度脈波アトラクタのモデリング

図 5.15 に示すように、三次元アトラクタの断面を切り出し、学習後のモデル曲面と学習データとの関係を考える。アトラクタの平行度、定常度が良い場合、図 5.15(a) のように学習データがまとまっていると考えられる。また、アトラクタの平行度、定常度が悪い場合、図 5.15(b) のように学習データが曲面から分散していると考えられる。アトラクタの平行度や定常度といった情報を得るために、本手法を加速度脈波アトラクタデータに適用し、その有効性を検討する。まず、1200 点の時系列信号である脈波データを埋め込み次元 3、遅れ時




図 5.14: 時系列加速度脈波分類マップ (i2 を除く)




図 5.15: アトラクタと学習後のモデル関数

間1で三次元のアトラクタ [18] を生成する。ここで、遅れ座標 $(x[t], x[t+1])$ を入力値とし、 $x[t+2]$ を出力値とする。これにより、1200組の入出力データを取得する。また、入出力データは $[-1, 1]$ に規格化する。

加速度脈波アトラクタのモデリングは、次に示すような式 (5.1) を2入力1出力用に限定した簡略化ファジィ推論を用いる。

$$\text{Rule } i : \text{if } x_1 \text{ is } A_{1i} \text{ and } x_2 \text{ is } A_{2i} \text{ then } y \text{ is } w_i \quad (i = 1, \dots, n) \quad (5.5)$$

式 (5.5) において、 A_{1i}, A_{2i} は前件部 MSF, w_i は後件部出力値、添え字 i はルール番号を表す。

そして、図 5.2 に示した学習の手順に従って、入出力関係を表現するよう逐次的に学習し、平均自乗誤差が最小となる値を取り出す。GA 法を利用した種類選択については、MSF の種類遺伝子 (2 進数 1 ビット) からなりルール数 (16 ルール) 分結合した個体を 20 個体を生成する。その後、5 世代淘汰を行う。交叉は 1 対の遺伝子を選択し交叉確率 1.0 で交叉を行う。突然変異操作はビット選択確率 0.1 で行う。

前件部 MSF の初期設定は図 5.16 に示すように各ルール毎に MSF を設定した。また、MSF が釣鐘型、三角型と交互に並ぶように配置し、グレードが 0.5 のところでそれぞれの MSF が重なるようにした。




図 5.16: 前件部 MSF の初期設定

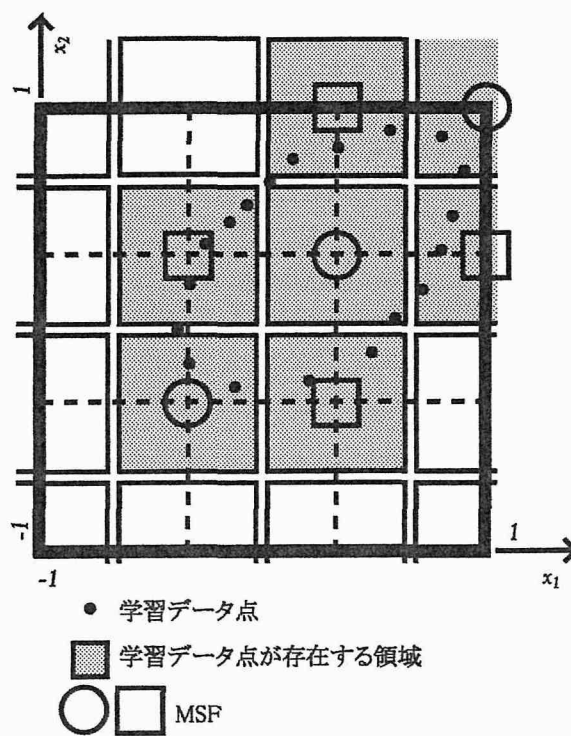


図 5.17: 学習データの存在する領域への MSF 配置




図 5.18: 健常のアトラクタ




図 5.19: 動脈硬化のアトラクタ




図 5.20: 学習後の MSF の位置 (健常)

さらに、学習データが軌道を描いており、均一に学習領域を覆っているわけではないので、あらかじめ図 5.17 に示すように学習データが存在する領域を区切っておき、その領域に学習データが存在していれば同領域の MSF を使用する。学習データが存在していなければ、MSF は使用しない。初期設定ではルール数は 16 ルール用意しているが、実際は軌道に応じたそれより少ないルール数で学習を始める。

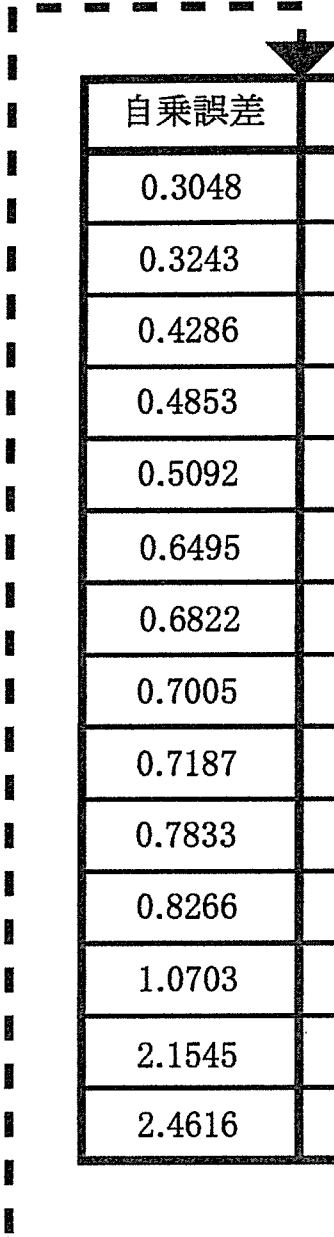
図 5.18, 5.19 にそれぞれ健常、動脈硬化の加速度脈波アトラクタを示す。また、表 5.1 に 30 例の学習後の自乗誤差を示す。図 5.20 は学習後の MSF の位置情報を示している。釣鐘型 MSF は楕円で表し、長軸、短軸の交点が頂点位置を、長軸、短軸の長さがグレード 0.5 における MSF の幅を示している。三角型 MSF は正方形で表し、その各辺の midpoint から対になる辺の midpoint へ結んだ線の交点が頂点位置を、各辺の長さが MSF の幅を示している。表 5.1 を自乗誤差の小さい順に並びかえたものを表 5.2 に示す。表 5.2 からわかるように、健常、インフ

表 5.1: 30 例の学習後の自乗誤差

	自乗誤差		自乗誤差
k1	0.0608	d6	0.4286
k2	0.0608	d7	0.2771
k3	0.1035	d8	0.3048
k4	0.0544	d9	0.2385
k5	0.0581	d10	0.2718
i1	0.0990	f1	0.7187
i2	0.0655	f2	0.6822
i3	0.0680	f3	0.7005
i4	0.0576	f4	2.1545
i5	0.0560	f5	0.8266
d1	0.0608	f6	0.6495
d2	0.1061	f7	0.3243
d3	0.4853	f8	1.0703
d4	0.7833	f9	2.4616
d5	0.1563	f10	0.5092

表 5.2: 30 例の学習後の自乗誤差 (値の小さい順にソート)

自乗誤差	
0.0544	k4
0.0560	i5
0.0576	i4
0.0581	k5
0.0608	k1,k2,d1
0.0655	i2
0.0680	i3
0.0990	i1
0.1035	k3
0.1061	d2
0.1563	d5
0.2385	d9
0.2718	d10
0.2771	d7



自乗誤差	
0.3048	d8
0.3243	f7
0.4286	d6
0.4853	d3
0.5092	f10
0.6495	f6
0.6822	f2
0.7005	f3
0.7187	f1
0.7833	d4
0.8266	f5
1.0703	f8
2.1545	f4
2.4616	f9




図 5.21: 時系列加速度脈波分類マップ (i2 を除く, 自乗誤差付加)

インフルエンザは自乗誤差の値が小さいが、中年女性更年期、動脈硬化のように血流量が停滞するにつれて値が大きくなることがわかる。これは図 5.18, 5.19 に示すように、双方のアトラクタのばらつき度と関係していることがいえる。この値を $[0, 1]$ に規格化し、i2 を除いた時系列加速度脈波分類マップに適用にしたものを図 5.21 に示す。表 5.1 に示すように、動脈硬化 f4, f9 といった自乗誤差の大きいものが (図 5.21 右下) に分布している様子がわかる。




図 5.22: 時系列加速度脈波データにおける振幅値

次に馬庭らの手法 [27] と比較を行った。表 5.3 に TPM とリカレンスプロットのプロット全体における白 (非ドット) の割合 RP-dw を示す。表 5.1 と比較すると、それぞれの数値のばらつきから、TPM は健常とインフルエンザは区別できるが中年女性更年期、動脈硬化を区別することができない。RP-dw は健常は区別できるが他は区別することができない。自乗誤差は中年女性更年期、動脈硬化は区別することができるが、健常、インフルエンザは区別することができない。このように各指標において分類に得意分野が存在する。さらに馬庭らの手法を用いて自己組織化マップ分類を行った。入力データは $b/a, c/a, d/a, e/a$, TPM, RP-dw である。ここで $a \sim e$ は図 5.22 に示すように時系列加速度脈波における振幅値である。馬庭らの手法では、 c が検出できないデータが存在する。その場合 $c/a = 0$ とする。入力データは馬庭らの手法の Priority に従い、 $b/a \in [-0.1, 0.1], c/a \in [-0.1, 0.1], d/a \in [-0.1, 0.1], e/a \in [-0.1, 0.1], TPM \in [-2.0, 2.0], RP-dw \in [-1.0, 1.0]$ で規格化を行った。図 5.23 に馬庭らの手法を用いた分類マップを示す。健常は区別できるが、インフルエンザの区画には $d1, d2$ が混ざっている。また、中年女性更年期、動脈硬化は分類できていない。

以上のシミュレーション結果から、他指標と比較して一長一短はあるが、自乗誤差をアトラクタの平行度、定常度の指標として用いることができ、加速度脈波データをモデリングし分類できることがわかった。また、自己組織化マップ分類において馬庭らの手法と比較を行

表 5.3: 30 例の TPM, RP-dw

	TPM	RP-dw		TPM	RP-dw
k1	0.1076	0.2884	d6	0.1851	0.5014
k2	0.1229	0.2716	d7	0.1336	0.5248
k3	0.1226	0.2819	d8	0.1475	0.4864
k4	0.1065	0.2520	d9	0.1371	0.4958
k5	0.1134	0.2992	d10	0.1610	0.4607
i1	0.0669	0.5590	f1	0.1713	0.5197
i2	0.0349	0.5548	f2	0.1935	0.4459
i3	0.0571	0.5584	f3	0.1770	0.5197
i4	0.0666	0.5727	f4	0.1831	0.4809
i5	0.0641	0.4956	f5	0.1621	0.3743
d1	0.0773	0.4985	f6	0.1690	0.4889
d2	0.0922	0.5010	f7	0.1642	0.3980
d3	0.2090	0.4962	f8	0.2017	0.5344
d4	0.1869	0.4466	f9	0.2155	0.4913
d5	0.1533	0.4371	f10	0.1954	0.4467

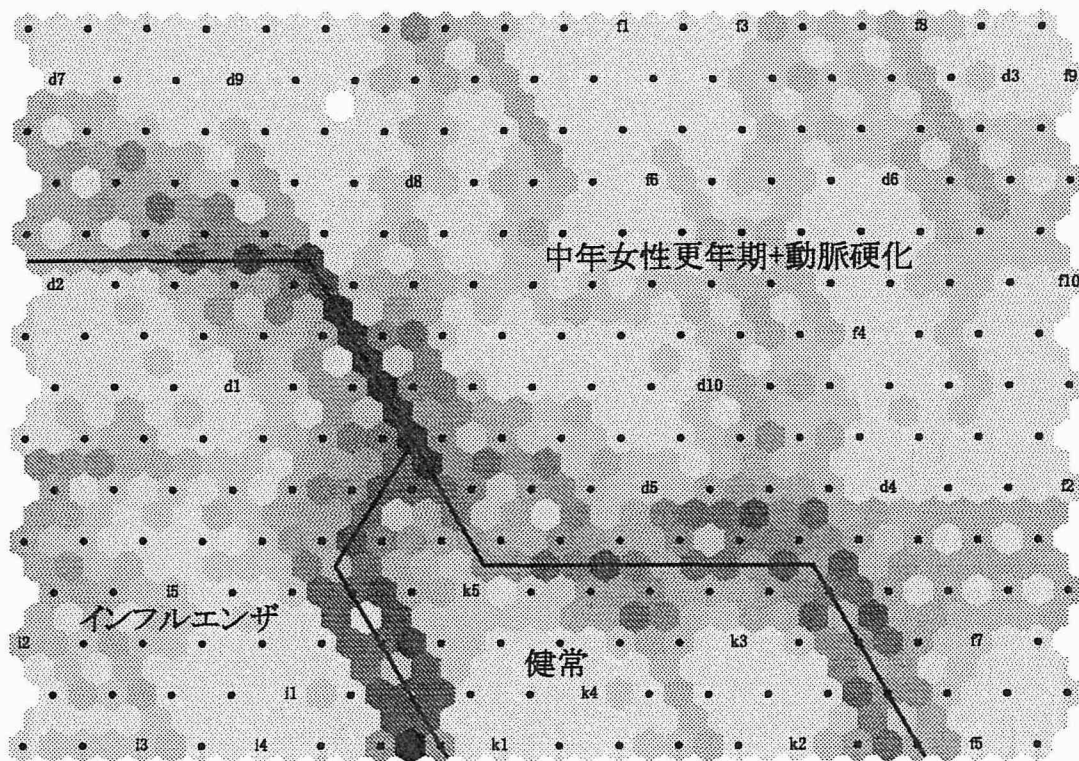


図 5.23: 加速度脈波分類マップ (馬庭らの手法による)

い、本手法は優れていることがわかった。

5.5 結言

本論文では最急降下法を用いたファジィルールの自動調整において、GAの手法によるMSFの種類を選択を付加し、時系列加速度脈波データのモデリングを行ない、形状特徴量をベクトルとして取り出した。さらに、自己組織化マップにより時系列加速度脈波データの分類を行なった。これにより、学習データの分布に適合したMSFが選択され、健常、インフルエンザ、中年女性更年期、動脈硬化の分類は可能であることがわかった。また、加速度脈波アトラクタ形状のモデリングを行ない、自乗誤差をアトラクタの平行度、定常度の指標として用いることが可能であることがわかった。加えて、自己組織化マップ分類において馬庭らの手法と比較を行い、本手法の有効性を示した。

第6章 結論

近年、ファジィ理論の実用化の進展とともに、ファジィ推論が多くの分野で用いられるようになってきている。それは、ファジィ推論が非線形のモデリングが容易であり、エキスパートの知識が簡単に表現できる特徴などを有しているからである。しかし、ファジィ推論には、入力数の増加に伴うファジィルール数の急増、ファジィシステムの大規模化などの問題を抱えている。そこで、ファジィルールの自動調整においてこれらの問題を解決するには、局所最適解を回避すること、ファジィルール数を削減すること、汎化能力を向上すること、この3つが強く求められていた。本研究では上記3つの課題の解決を目指し、ならびにその応用に取り組んだ。

本研究を通じて得られた成果を要約すると次の通りとなる。

1. 局所最適解の回避については、MSFの再配置にSA、GAの手法を導入した。従来のSA、GAでは、ファジィルールの自動調整に限らず様々な最適化問題において、全てのパラメータを調整していた。本研究では、通常のパラメータ調整において最急降下法を用いるため、時間を多大に費やすSA、GAを局所最適解に陥った場合にのみ使用している。また、DRTMSFの使用や種類選択といったMSFの形状利用によってその配置のみに着目し調整するパラメータも絞っている。そのため、局所最適解の回避と同時に、SA、GA単独で用いる場合と比較し探索領域を削減できるため計算時間の短縮につながった。
2. ファジィルール数の削減については、GAにルール数に関する遺伝子を導入した。これは従来の解決方法と同じであり、推論ルールの最適化、MSFの数の低減を目的としたGAを用いたファジィ推論法が提案されている[10, 11]。ところが、この手法ではMSFのパラメータ全てを調整しなくてはならず、MSFのパラメータ数を満足する遺伝子が必要なため、必然的に遺伝子長が長くなるという問題があった。本研究では、GAの個

体に MSF の種類を選択可能な遺伝子をさらに加えることにより学習データにより適応する MSF が選ばれるため、さらなるファジィルール数の削減が可能となった。

3. 本手法の汎化能力については、学習データが急激に変化する場合、つまり関数形状が不連続な場合について DRTMSF を提案した。また、MSF を学習データの形状に対して種類選択できるようにした。これにより、どのような学習データの形状であってもあらかじめ準備した MSF に関して最小の MSF 個数で表現できることを示した。
4. 本手法の応用については、指尖加速度脈波に適用した。時系列加速度脈波データのモデリングを行ない、形状特徴量をベクトルとして取り出した。さらに、自己組織化マップにより時系列加速度脈波データの分類を行なった。これにより、学習データの分布に適合した MSF が選択され、健常、インフルエンザ、中年女性更年期、動脈硬化の分類は可能であることがわかった。また、加速度脈波アトラクタ形状のモデリングを行ない、自乗誤差をアトラクタの平行度、定常度の指標として用いることが可能であることがわかった。

以上の研究結果を踏まえ、今後の研究課題を以下に述べる。

現状では、MSF を 2 種類のうちから選択しているが、例えば方形な MSF といった基底となる MSF を考案し選択肢を増やす。また、指尖加速度脈波に応用しているが、他の生体情報への適用を目指す。さらに本研究で行った手法のハードウェア化を行ない機器に組み込みで用いる必要がある。

謝辞

本論文は、鳥取大学大学院工学研究科博士後期課程において行った「メンバーシップ関数の形状に着目したファジィルールの自動調整に関する研究」についてまとめたものであります。

本研究を遂行するにあたり、終始、懇切丁寧な御指導と御鞭撻を頂きました鳥取大学工学部大北正昭教授に深く感謝し、厚く御礼申し上げます。また、数々の有益な御教示を頂きました鳥取大学工学部副井裕教授、大木誠助教授には心より御礼申し上げます。さらに、本研究において有益な御助言および便宜をお計り頂きました米子工業高等専門学校宮田仁志助教授、及び倉敷リバーサイド病院健康管理センター長馬庭芳朗博士に心より深く感謝します。

本研究を実施するにあたり、多くの有益な議論を頂きました鳥取大学工学部電気電子工学科演算制御工学研究室の諸氏に深く感謝します。

さらに、研究活動に対し、御理解と特別の御配慮を頂きました米子工業高等専門学校鈴木充前々校長、杉浦哲郎前校長、水島和夫校長をはじめ、教職員の方々に、心より御礼申し上げます。また、故長井啓三教授、千葉敦生教授、松原孝史教授をはじめ電気情報工学科の諸先生方より、学科を挙げて御支援頂きました。厚く御礼申し上げます。

2006年1月

参考文献

- [1] E.H.Mamdani,S.Assilian, *An experiment in linguistic synthesis with a fuzzy logic controller*, Int. J. Man-Mach. Stud., vol.7, pp.1-13(1974).
- [2] 菅野道夫, ファジィ制御, 日刊工業新聞社,(1988).
- [3] 市橋秀友, 渡辺俊彦, 簡略ファジィ推論を用いたファジィモデルによる学習型制御, 日本ファジィ学会誌, Vol.2, No.3, pp.429-437 (1990).
- [4] 林勲, 野村博義, 若見昇, ニューラルネット駆動型ファジィ推論による推論ルールの獲得, 日本ファジィ学会誌, Vol.2, No.4, pp.585-597 (1990).
- [5] 野村博義, 林勲, 若見昇, デルタルールによるファジィ推論の自動チューニング手法と障害物回避への応用, 日本ファジィ学会誌, Vol.4, No.2, pp.379-388 (1992).
- [6] 堀川慎一, 古橋武, 内川嘉樹, ファジィニューラルネットワークの構成法と学習法, 日本ファジィ学会誌, Vol.4, No.5, pp.906-928 (1992).
- [7] 岸田一也, 宮島廣美, 福元伸也, 村島定行, 学習アルゴリズムによるファジィモデルの構成, 日本ファジィ学会誌, Vol.7, No.3, pp.585-593 (1995).
- [8] 増田達也, 太田俊彦, ファジィ・ニューラルネットワークによるメンバシップ関数および推論ルールの獲得手法, 電気学会論文誌C, Vol.114-C, No.11, pp.1185-1193, (1994).
- [9] 宮島廣美, 福元伸也, 石塚洋一, ルール削除に基づくファジィモデリング, 電子情報通信学会論文誌A, Vol.J77-A, No.11, pp.1555-1562, (1994).
- [10] 野村博義, 若見昇, 遺伝アルゴリズムによるファジィ推論ルールの決定法, 電子情報通信学会論文誌A, Vol.J77-A, No.9, pp.1241-1249, (1994).

- [11] 福田敏男, 長谷川泰久, 下島康嗣, 遺伝的アルゴリズムを用いた階層型ファジィモデルの自動生成法, 日本ファジィ学会誌, Vol.7, No.5, pp.988-996, (1995).
- [12] 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ィ推論の最適化, 電子情報通信学会論文誌 D- II, vol.J81-D- II, No.1, pp.127-136, (1998).
- [13] 北野宏明 (編) , 遺伝的アルゴリズム, 産業図書, (1993).
- [14] H.Miyata, M.Ohki and M.Ohkita, *Self-tuning of Fuzzy Reasoning by the Steepest Descent Method and its Application to a Parallel Parking*, IEICE Trans. Information and Systems, vol.E79-D, No.5, pp.561-569 (1996).
- [15] 片山立, 鍛田海平, 梶谷雄治, 西田行輝, 自己増殖型 C^∞ 級ファジィモデルとカオス時系列同定問題への応用, 第8回ファジィシステムシンポジウム講演論文集, pp.253-256 (1992).
- [16] M.Casdagli, *Nonlinear Prediction of Chaotic Time Series*, Physica, D, 35, pp.335-356 (1989).
- [17] 丸山稔, Radial Basis Function を用いた学習ネットワーク—ニューロコンピューティングに対する新しいアプローチ—, システム/制御/情報, vol.36, No.5, pp.322-329 (1992).
- [18] F.Takens, *Detecting Strange Attractors in Turbulence*, in "Dynamical Systems and Turbulence", Lecture Notes in Mathematics, 898, pp.366-381, Springer, Berlin (1981).
- [19] 合原一幸 (編) , カオス時系列解析の基礎と応用, 産業図書, (2000).
- [20] N.Metropolis, A.W.Rosenbluth, M.N.Rosenbluth, A.H.Teller and E.Teller, *Equation of state calculations by fast computing machines*, J. of Chemical Physics, vol.21, No.6, pp.1087-1092 (1953).
- [21] S.Kirkpatrick, C.D.Gelatt and M.P.Vecchi, *Optimization by simulated annealing*, Science, vol.220, pp.671-680 (1983).
- [22] J.M.Garibaldi and E.C.Ifeachor, *Application of Simulated Annealing Fuzzy Model Tuning to Umbilical Cord Acid-Base Interpretation*, IEEE Trans. Fuzzy Syst., vol.7, No.1, pp.72-83 (1999).

- [23] 小坏成一, 須貝康雄, 平田廣則, 遺伝的要素を取り入れた改良型アニーリング法によるブロック配置手法, 電子情報通信学会論文誌A, Vol.J73-A, No.1, pp.87-94 (1990).
- [24] 権田英功, 宮田仁志, 大北正昭, 学習データが急激に変化する分布におけるファジィルールの自動チューニング, 電気学会論文誌C, Vol.122-C, No.6, pp.1033-1042, (2002).
- [25] 権田英功, 宮田仁志, 大北正昭, 種々のMSFで構成されるファジィルールの自動調整, 日本知能情報ファジィ学会誌, Vol.16, No.6, pp.540-550, (2004).
- [26] T.Iokibe, M.Kurihara, Y.Maniwa, S.Ohta, I.Uchida, M.Amata, and M.Yamamoto, *Chaos-based Quantitative Health Evaluation and Disease State Estimation by Acceleration Plethysmogram*, Journal of Japan Society for Fuzzy Theory and Intelligent Informatics, vol.15, No.5, pp.565-576, (2003).
- [27] Y.Maniwa, H.Tokutaka, K.Fujimura, M.Ohkita, T.Iokibe, and K.Tada, *Use of Chaos and Self-Organizing Maps for Acceleration Plethysmogram Information*, Journal of Japan Society for Fuzzy Theory and Intelligent Informatics, vol.16, No.3, pp.253-261, (2004).
- [28] 藤本泰成, 五百旗頭正, 谷村隆義, 観測された時系列データの決定論的性質を測る軌道平行測度法, 日本ファジィ学会誌, Vol.9, No.4, pp.580-588, (1997).
- [29] 徳高平蔵, 岸田悟, 藤村喜久郎, 自己組織化マップの応用, 海文堂, (1999).

研究業績

I. 学術雑誌, 国際会議発表論文

番号	著者・論文題目・発表機関	本文対応
(1)	E.Gonda, H.Miyata and M.Ohkita, Self-tuning of Fuzzy Reasoning when Learning Data has a Radically Changing Distribution, Proceedings of 16th IMACS World Congress 2000, 169-5 (CDROM)	第2章
(2)	権田英功, 宮田仁志, 大北正昭, 学習データが急激に変化する分布におけるファジィルールの自動チューニング, 電気学会論文誌C, Vol.122-C, No.6, 2002, pp.1033-1042. E.Gonda, H.Miyata and M.Ohkita, Self-tuning of Fuzzy Rules When Learning Data Have a Radically Changing Distribution, Electrical Engineering in Japan, Vol.144, No.4, 2003, pp.63-74.	第2章
(3)	E.Gonda, H.Miyata and M.Ohkita, Self-Tuning of Fuzzy Rules with Some Kinds of Membership Functions using Genetic Algorithm, Proceedings of International Symposium on Bio-inspired Systems, Part 5 Robotics and Motion Control, pp.89-95(2004)	第3章
(4)	権田英功, 宮田仁志, 大北正昭, 種々のMSFで構成されるファジィルールの自動調整, 日本知能情報ファジィ学会誌, Vol.16, No.6, 2004, pp.540-550.	第3章
(5)	E.Gonda, H.Miyata and M.Ohkita, Self-tuning of fuzzy rules with different types of membership functions for multi input and output learning data, Proceedings of 17th IMACS World Congress 2005, Paper T5-R-00-0140 (CDROM)	第4章
(6)	権田英功, 宮田仁志, 大北正昭, ファジィ・ニューラルネットワークの加速度脈波解析への応用, 電子情報通信学会技術研究報告NC, Vol.105, No.457, 2005, pp.7-12.	第5章

II. 学会研究会発表論文

番号	著者・論文題目・発表機関	本文対応
(1)	権田英功, 宮田仁志, 大北正昭, 局所最適解回避に SA の手法を用いたファジィルールの自動チューニング, 平成 11 年度電気・情報関連学会中国支部連合大会講演論文集 pp.505(1999)	第 2 章
(2)	権田英功, 宮田仁志, 大北正昭, 多入力学習データが急激変化する分布を持つ場合のファジィルールの自動調整, 平成 13 年電気学会全国大会講演論文集 3-037(2001)	第 2 章
(3)	権田英功, 宮田仁志, 大北正昭, 局所冷却的 SA を融合したファジィルールの自動チューニング, 平成 14 年電気学会全国大会講演論文集 3-048(2002)	第 2 章
(4)	権田英功, 宮田仁志, 大北正昭, 局所最適解回避に GA の手法を用いたファジィルールの自動チューニング, 平成 14 年度電気・情報関連学会中国支部連合大会講演論文集 pp.418(2002)	第 3 章
(5)	権田英功, 宮田仁志, 大北正昭, 種々の MSF で構成されるファジィルールの自動チューニング, 平成 15 年度電気・情報関連学会中国支部連合大会講演論文集 pp.518(2003)	第 3 章
(6)	権田英功, 宮田仁志, 大北正昭, 多入出力学習データにおける種々の MSF で構成されるファジィルールの自動調整, 平成 16 年度電気・情報関連学会中国支部連合大会講演論文集 pp.389(2004)	第 4 章
(7)	権田英功, 宮田仁志, 大北正昭, 種々の MSF で構成されるファジィルールの自動調整における汎化能力, バイオメディカル・ファジィ・システム学会第 17 回年次大会講演論文集 pp.151-152(2004)	第 4 章

END