

特集論文 ファジィ・ニューラルネットワークとその応用

ファジィニューラルネットワークの構成法と学習法[†]堀川 慎一^{*1} 古橋 武^{*2} 内川 嘉樹^{*2}

最近、ニューラルネットワークをファジィ推論におけるファジィルール等の同定に応用する研究が盛んに行われている。本論文では、このようなニューラルネットワークをファジィニューラルネットワーク (Fuzzy Neural Network : FNN) と呼ぶ。

著者らはこれまでに、ファジィルールの後件部が定数および一次式で表されるファジィ推論を実現した2種類のFNNを提案してきた。これらのFNNは、ファジィルールの同定とメンバーシップ関数の調整を自動的に行うことができ、学習結果をファジィルールとして容易に把握できるという優れた特徴を持つが、同定されたファジィルールや学習時の結合荷重に対する学習率設定に問題があった。

本論文では、上記のFNNに対して前件部に規格化演算を行うユニットを導入することにより重心法を実現する手法を提案する。重心法によれば、ネットワークの入出力関係や対象システムの特性を正確に表したファジィルールの同定が可能となる。さらに、後件部がファジィ変数で表される推論法に基づく新しいFNNを提案する。そして、学習における学習率設定の煩雑さを低減する手法について述べ、簡単な数値例により本FNNの有用性を示す。本FNNの前件部メンバーシップ関数は学習において優れた特徴を持ち、バックプロパゲーション法により適切に調整される。また、同定されたファジィルールは対象システムの特性をよく表している。

キーワード：ファジィ推論、ニューラルネットワーク、バックプロパゲーション法、自動同定、自動調整、ファジィニューラルネットワーク

1. はじめに

ファジィ推論^[1]は、人間の判断のようなあいまいさを含むアルゴリズムをif-then型のファジィルールにより言語的に記述できるという特長を持つ。しかし、ファジィ制御器の設計例に見られるように、ファジィ推論におけるファジィルールやメンバーシップ関数等の同定もしくは調整には、一般に多大な労力を必要とする。一方、人間の知識を扱うのに適したもう一つの手法としてニューラルネットワーク (Neural Network : NN)^[2]がある。NNの特徴は、学習機能により任意の入出

力関係を同定できることにあるが、その入出力関係に関する知識はネットワーク内の結合荷重に分散して記憶されるため、この知識を定性的に把握することは難しい。本論文では、ファジィ推論とNNを融合し、両者の特徴を兼ね備えたファジィニューラルネットワーク (Fuzzy Neural Network : FNN)^[3]の新しい構成法および学習法を提案する。本論文で提案するFNNは、ファジィ推論に適した構造を持ち、NNの学習法であるバックプロパゲーション (Back-Propagation : BP) 法^[2]の適用を可能としながら、知識を言語的に記述できるというファジィ推論の特徴と知識を自動的に学習できるというNNの特徴を併せ持つ。なお、本論文では、ファジィ推論として制御等で用いられる入出力値が確定値で表されるもののみを考え、ファジィ推論におけるファジィルールの同定をNNの学習機能により自動化することを目指す。

† Composition Methods and Learning Algorithms of Fuzzy Neural Networks

Shin-ichi HORIKAWA, Takeshi FURUHASHI and Yoshiki UCHIKAWA

*1 名古屋大学大学院工学研究科

Graduate School of Engineering, Nagoya University

*2 名古屋大学工学部

Faculty of Engineering, Nagoya University

的とした「ファジィ推論を行う NN」を FNN と定義する。

このような FNN の構成法としては、従来、林ら^[4]および山口ら^[5]の手法が提案されていた。林らの NN 駆動型ファジィ推論では、ファジィルールの前件部において入力空間のファジィ分割を行う 1 個の NN と、後件部の出力推定式を表す複数個の NN を組み合わせることによってファジィ推論を実現している。これらの NN に入出力データを学習させれば、自動的にファジィルールの同定を行うことができる。山口らの手法は、前件部と後件部を独立した NN を用いて構成する点で基本的には林らの手法と同様であるが、それらを連想記憶システムで結合することにより、各ファジィルールの「確かさ」の自動調整が可能となっている。しかし、林らの手法では NN に通常の 3 層 BP モデルを用い、また、山口らの手法では連想記憶システムをそのまま用いているため、獲得されたファジィルールの把握が難しいという問題がある。特に、両手法とも後件部の出力推定式の同定に 3 層 BP モデルを用い、出力推定式として非線形関数を同定可能としている。これは、ファジィ推論の記述能力を向上させる有力な手段ではあるが、ファジィ推論の言語的でわかりやすいという特徴を損なってしまっている。従って、NN の学習機能を活かしつつ、学習結果をファジィルールとして容易に把握できるような FNN の構成が望まれる。

ファジィ推論におけるファジィルールやメンバーシップ関数等の自動同定・自動調整については、最急降下法に基づく逐次学習によって NN を用いずに行う手法も種々提案されている^{[6]~[11]}。市橋らは、ファジィルールの後件部が定数で表される簡略化ファジィ推論^[12]において、入力空間の分割を段階的に細分化しながら後件部定数を同定していく手法を提案した^[6]。これに対して、入力空間の分割の細分化を推論誤差の大きい領域に限って行う手法^[7]や、前件部メンバーシップ関数も同時に学習する手法^[8]が提案されている。これらはすべて前件部に三角型のメンバーシップ関数を用いて

いるが、三角型メンバーシップ関数によるファジィモデル^[13]は C^0 級であるために、学習に対する記述能力に欠けている。そこで、非線形関数を区分的に接続してメンバーシップ関数を設定することによりファジィモデルを C^1 級とする手法^[9]が、また、三角型メンバーシップ関数をそのまま用いて入力変数を n 重とすることにより n 次のメンバーシップ関数を実現する手法^[10]が提案されている。さらに、入出力関係の滑らかさを BP モデルと同等にするため、釣鐘型メンバーシップ関数(ガウス基底)を用いてファジィモデルを C^∞ 級とする手法がある^[11]。

著者らはこれまでに、後件部が定数で表される簡略化ファジィ推論において、ファジィルールの同定と前件部メンバーシップ関数の調整を自動的に行うことができる FNN を提案した^[16]。この FNN は、ファジィ推論による推論値の計算過程を NN(BP モデル)の構造で実現し、ファジィ推論で同定または調整すべきパラメータを NN の結合荷重に対応づけたものであり、学習結果をファジィルールとして容易に把握できる。また、本 FNN の前件部メンバーシップ関数は BP モデルでよく用いられるシグモイド関数により構成されているため、実現されるファジィモデルが C^∞ 級となるだけでなく、本論文で明らかにするように学習において釣鐘型メンバーシップ関数よりも優れた特徴を持つ。しかし、この FNN には次のような問題点があった。

- (i) 推論値を重心法ではなく簡易化した方法により求めているため、同定されたファジィルールがネットワークの入出力関係や対象システムの特性を正確に表していないことがある。
- (ii) 本 FNN の結合荷重はそれぞれ明確な役割を持っており、初期設定の段階からそれぞれ値が大きく異なる。従って、各結合荷重の更新量を定める学習率の設定が煩雑である。

下川は、著者らの FNN に対して後件部の構成に除算を行うユニットを追加し、推論値を重心法によって求める手法を提案した^[14]。文献[14]では、重心法の導入が FNN の汎化能力の向上に有効で

あるという位置づけがなされている。

さて、本論文では、文献[16]のFNNを新たにType Iと呼ぶ。このType IのFNNは、ファジィルールの後件部が定数である簡略化されたファジィ推論を実現していた。これに対して、著者らは、後件部が入力変数の一次式で表される推論法を実現するFNNも提案してきた^{[18][19]}。このFNNをType IIと呼ぶ。

本論文では、新たに後件部がファジィ変数で表される推論法を実現するFNNの構成法を提案する。これをType IIIと呼ぶ。そして、すべてのタイプのFNNに共通な前件部に規格化演算を行うユニットを導入することにより重心法を実現する手法を提案する^[20]。本手法によれば、文献[14]のように後件部に新たなユニットを付け加える必要はなく、各タイプにおいて容易に重心演算を実現できる。本手法は、ファジィモデリングを正確に行うために上記問題点(i)の改善を目的としたものであり、汎化能力の向上に着目した文献[14]とは重心法の実現方法および導入の意図が異なっている。さらに、上記問題点(ii)に関して、学習時の学習率の設定に対する煩雑さを低減する手法について述べる。そして、これらのFNNを用いて簡単な数値例に基づくファジィモデリング^[13]を行い、重心法の導入によりネットワークの入出力関係や対象システムの特性を正確に表したファジィルールが同定できることを示す。

2. 構成法

本論文で提案する新しいFNNは、文献[16]で提案したFNNと同様に、ファジィ推論による推論値の計算過程をNN(BPモデル)の構造で実現し、ファジィ推論において同定または調整すべきパラメータをNNの結合荷重に対応づけたものである。これらの結合荷重をBP法を用いて更新することによりファジィルールの同定およびメンバーシップ関数の調整を自動的に行うことができ、また、学習結果をファジィルールとして容易に把握することも可能である。

一般に、ファジィ推論による推論値は、与えら

れた入力値から、

- (i) 前件部メンバーシップ関数値
 - (ii) 各ファジィルールの前件部適合度
 - (iii) 各ファジィルールの後件部出力推定値
- を順次求め、(ii)および(iii)の結果を統合することにより求められる。本FNNでは、この過程を、ファジィルールとの対応から(i)と(ii)を計算する前件部と、(iii)を計算し(ii)と(iii)の結果を統合する後件部との二つに分けて実現している。これらは計算過程に従って直列に結合され、全体として一つのネットワークを構成する。

以下、前件部、後件部の順にその構成法を説明するが、前件部はType I, II, IIIの3種類のFNNすべてに共通となっている。

2.1 前件部

2.1.1 前件部メンバーシップ関数

ファジィ推論における代表的な前件部メンバーシップ関数としては、次のように表される三角型と釣鐘型の二つを挙げることができる。

$$\text{三角型: } A(x) = \max(-g |x - c| + 1, 0) \quad (1)$$

$$\text{釣鐘型: } A(x) = \exp\{-g^2(x - c)^2\} \quad (2)$$

ここで、 c はメンバーシップ関数のグレードが1となる x の値(中心位置)、 $g(>0)$ は幅(傾き)を定めるパラメータである。最近では、その計算の容易さから三角型がよく用いられている^[15]。しかし、BP法をNNの学習に適用するためには、ネットワークを構成するユニットの内部関数が微分可能な非減少関数でなければならない^[2]。従って、本FNNの前件部に(1), (2)式のメンバーシップ関数を用いることは、BP法に基づく学習を不可能としてしまう。

そこで、本FNNでは、BPモデルでよく用いられるシグモイド関数により前件部メンバーシップ関数を実現する。図1は、本FNNにおける前件部メンバーシップ関数の構成例を示す。(a)は入力 x_j の前件部メンバーシップ関数が3種類の場合、(b)は2種類の場合、(c)は4種類の場合のものであり、 m_j は x_j の前件部メンバーシップ関数の種

類数である。図中左側のネットワークにおける丸および四角の記号はユニットを表し、ユニット間の記号 w_c, w_g および $1, -1$ は結合荷重を意味する。また、(A)層の 1 の記号を持つユニットは、常に一定値 1 を出力するバイアスユニットであり、(B), (D)層の Σ , (C)層の f の記号を持つユニットは、一般にその入出力関係がそれぞれ次のように表される。

$$\Sigma : \begin{cases} I_j^{(n)} = \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = I_j^{(n)} \end{cases} \quad (3)$$

$$f : \begin{cases} I_j^{(n)} = \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = f(I_j^{(n)}) \end{cases} \quad (4)$$

ここで、 $I_j^{(n)}, O_j^{(n)}$ はそれぞれ第 n 層第 j ユニットの入力および出力、 $w_{jk}^{(n)}$ は第 $n-1$ 層第 k ユニットから第 n 層第 j ユニットへの結合荷重である。

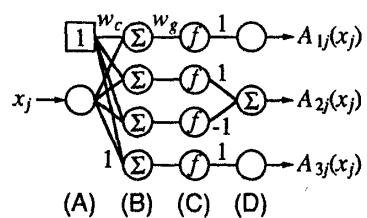
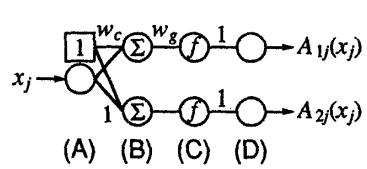
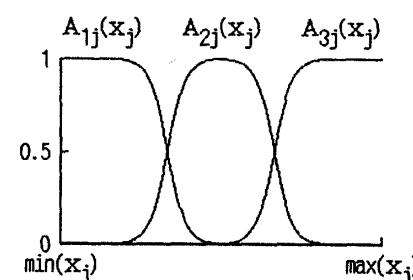
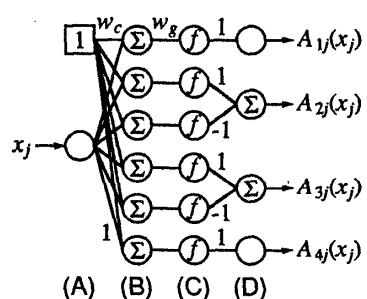
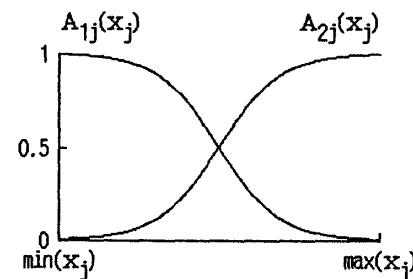
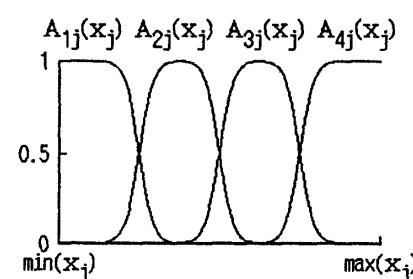
(a) $m_j=3$ (b) $m_j=2$ (c) $m_j=4$ 

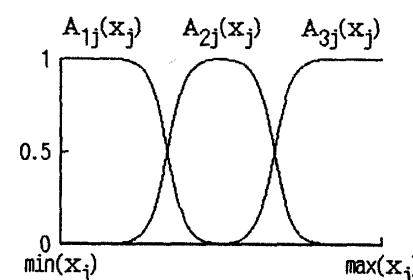
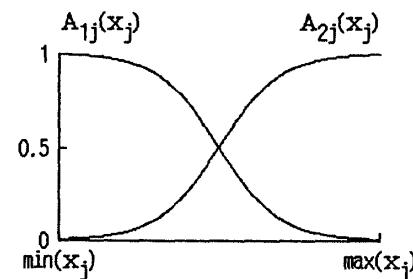
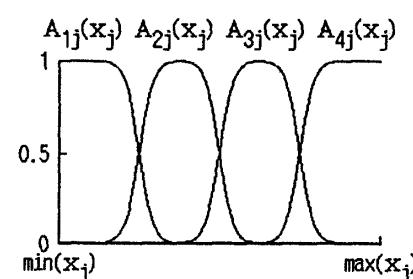
図1 前件部メンバーシップ関数の構成例

図1のネットワークでは、(A)層が第1層、(B)層が第2層のように対応する。また、(4)式の $f(\cdot)$ は、

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (5)$$

のように定義されるシグモイド関数であり、これにより前件部メンバーシップ関数が構成される。なお、(A)層および(D)層の記号のないユニットは、単に入力を出力に分配している。

まず、図1(a)の前件部メンバーシップ関数が3種類の場合について説明する。図に示すネットワークの構成により、(A)層に加えられた入力 x_j は(B)層にて結合荷重 w_c がバイアスとして加算され、それに w_g を掛けたものが(C)層のユニットの入力となる。従って、(4), (5)式より、(C)層の出力は次のように表される。

(a) $m_j=3$ (b) $m_j=2$ (c) $m_j=4$

$$O^{(c)} = \frac{1}{1 + \exp\{-w_g(x_j + w_c)\}} \quad (6)$$

すなわち、結合荷重 w_c, w_g は、(1), (2)式の c, g と同様、シグモイド関数の中心位置および傾きを定めるパラメータである。ここで、シグモイド関数の中心位置とは、(5)式の $f(x) = 0.5$ となる x を意味する。ネットワーク内の結合荷重 w_c, w_g を各シグモイド関数毎に適当な値に設定すれば、(D)層の出力には図1(a)の右側に示すような前件部メンバーシップ関数 $A_{1,j}(x_j), A_{2,j}(x_j), A_{3,j}(x_j)$ を実現できる。ただし、擬似台形型メンバーシップ関数 $A_{2,j}(x_j)$ は、(C)～(D)層間の結合荷重 1, -1 と(D)層の Σ の記号を持つユニットにより、図2のように点線で示される符号の異なる二つのシグモイド関数の和で構成される。図1(b)の前件部メンバーシップ関数が2種類の場合では、この擬似台形型メンバーシップ関数を省略している。擬似台形型メンバーシップ関数を二つとした例を図1(c)に示す。メンバーシップ関数が5種類以上の場合についても同様にして実現できる。本FNNでは、学習データにおける入力値の最小値から最大値までを台集合として、この台集合上に前件部メンバーシップ関数が等間隔に配置されるように結合荷重 w_c, w_g を初期化する。そして、これらの結合荷重を学習により変化させることによって前件部メンバーシップ関数の調整を行う。なお、1および-1の結合荷重は固定とする。

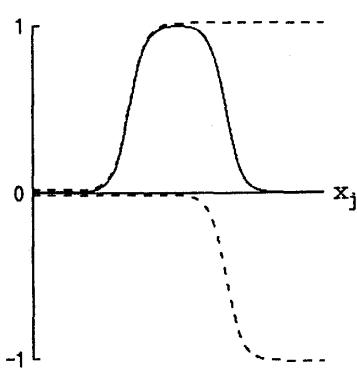


図2 擬似台形型メンバーシップ関数の構成

文献[16]のFNNでは、入力部に規格化のための結合荷重を設けていたが、これは、前件部メンバーシップ関数の台集合が[0,1]または[-1,1]に規格化できるという前提に基づくものであった。しかし、4章で示す数値例にもあるように、一般に規格化のためには学習データに対して閾値を設定する等の前処理を必要とし、規格化用の結合荷重はむしろFNNの制約条件となっていた。図1の構成によれば、観測・採取された学習データを事前に加工することなくそのまま用いることができ、また、学習率を設定すべき結合荷重が一つ少なくなっていることから、学習時における学習率設定に対する労力の低減も実現している。

本FNNは、以上のようにシグモイド関数を用いて前件部メンバーシップ関数を構成するため、ファジィモデルとして C^∞ 級となる。同様に C^∞ 級である文献[11]の手法では、前件部メンバーシップ関数に(2)式の釣鐘型(ガウス基底)を用いているが、そのパラメータの与え方は、本FNNにおける(C)層のユニットの内部関数 $f(\cdot)$ を

$$f(x) = \exp(-x^2) \quad (7)$$

とし、擬似台形型メンバーシップ関数の-1の結合を設けない場合に一致する。しかし、本FNNの擬似台形型メンバーシップ関数の方が、一つのメンバーシップ関数を独立した二つのシグモイド関数により構成しているため、学習時の出力誤差の減少に優れた性能を示す。

この性能の違いを図3の例を用いて説明する。例えば、図3(a)に示すような初期状態において、入力 $x=a$ のとき前件部メンバーシップ関数の望ましいグレードが 0.5、 $x=b$ のときのそれが 0.75 である二つの学習データが与えられたと仮定する。図3の左側が本FNNの擬似台形型メンバーシップ関数、右側が釣鐘型メンバーシップ関数である。このとき、シグモイド関数およびガウス基底の中心位置を定める結合荷重 w_c のみを $x=a, b$ のデータの順に更新するものとすると、各メンバーシップ関数はそれぞれ図3(b), (c)のように調整される。ただし、図中の破線は調整前、実線は調

整後のメンバーシップ関数を表し、矢印は各学習データの提示によるシグモイド関数およびガウス基底の移動方向を示す。本FNNの擬似台形型メンバーシップ関数では、まず、 $x=a$ のデータの提示により左側のシグモイド関数のみが左に移動し、 $x=a$ でのグレードを高める。右側のシグモイド関数は、その微分係数がほぼ0であるためにBP法ではほとんど変化しない。同様にして、次に $x=b$ のデータの提示により右側のシグモイド関数のみがグレードを増加させる方向に移動する。以上のように、本FNNの擬似台形型メンバーシップ関数においては、学習データに応じて左右のシグモイド関数が独立に変化するため、学習データの提示毎に出力誤差が確実に減少する。一方、釣鐘型メンバーシップ関数を実現するガウス基底においても、データの提示に応じてそれぞれのグレード

を増加させる方向に移動している。しかし、メンバーシップ関数が単一の関数で構成されているため、一つの入力データに対してグレードを増加させるような移動は他のデータに対するグレードを減少させており、全体としての出力誤差はあまり変化していない。

もちろん、中心位置と傾きの両方について学習を行えば、釣鐘型メンバーシップ関数を適切な形状に調整することができる。しかし、図3(b), (c)のような逐次学習によるガウス基底の振動的な移動は避けられず、さらに多くの学習データが与えられたときには出力誤差を減少させるためにかなりの学習回数を必要とする。事実、著者らの経験では、文献[16]のむだ時間を持つ一次遅れ系を制御対象としたシミュレーションにおいて、擬似台形型のメンバーシップ関数をガウス基底とした場合、数百回程度の学習では良好な制御性能を

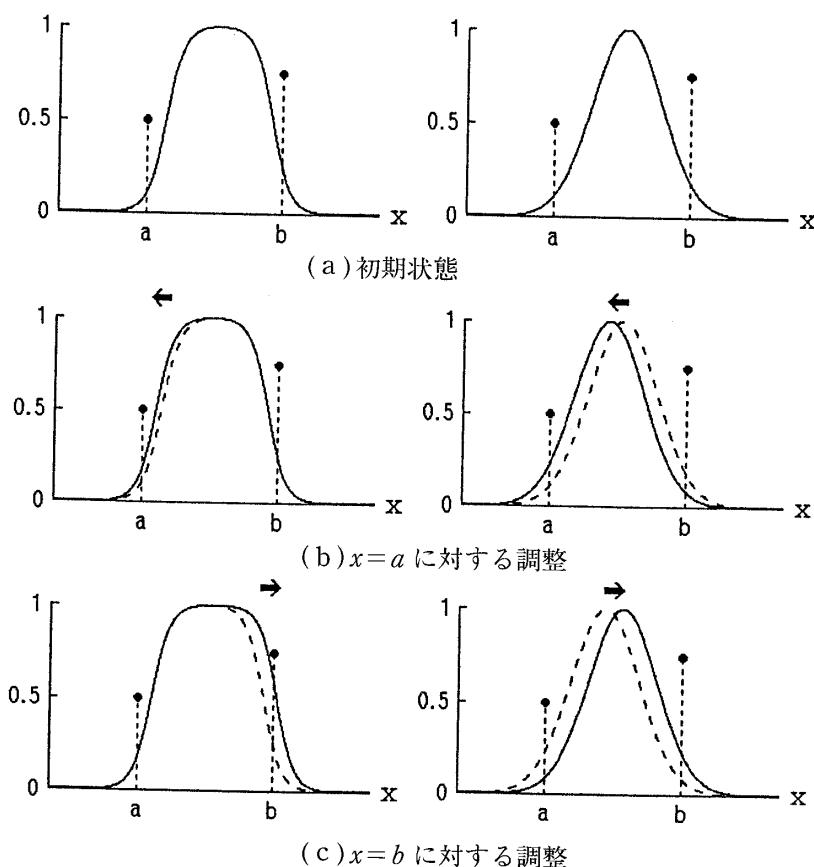


図3 学習による擬似台形型メンバーシップ関数と釣鐘型メンバーシップ関数の調整例

実現することはできなかった。文献[16]のFNNは、わずか50回の学習で比較的良好な制御性能を示している。

その一方で、本FNNの前件部メンバーシップ関数には次のような問題点が存在する。

- (i) 三角型や釣鐘型のメンバーシップ関数に比べて一つのメンバーシップ関数当りのパラメータ数が多く、ネットワークの構成が複雑となる。
- (ii) 擬似台形型メンバーシップ関数が完全には正規(最大グレード=1)でない。
- (iii) 学習後のメンバーシップ関数が不適当な形状になることがある。

これらはすべて、擬似台形型メンバーシップ関数の構成に起因するものである。擬似台形型メンバーシップ関数は二つのシグモイド関数の和で構成され、各シグモイド関数は中心位置および傾きを定める二つのパラメータを持つ。従って、一つの擬似台形型メンバーシップ関数当りのパラメータ数は、三角型や釣鐘型の2倍の4となっている。また、メンバーシップ関数のグレードの最大値は、シグモイド関数が完全に0または1とはならないために、1にすることができない。しかし、上記問題点(i)は本FNNの学習に対する有効性とのトレードオフであり、(ii)についても実用上の問題はなく、推論値への影響は重心法を用いることによって解消できる(2.2.1節参照)。また、(iii)は、結合荷重 w_c および w_g に対する適切な学習率の設定法を検討することにより改善できる。これに関しては3.2節にて詳述する。

2.1.2 前件部適合度

ファジィルールの前件部におけるand演算には、最小値演算(min演算)もしくは代数積がよく用いられる。本FNNでは、BP法による学習を可能とするために、その連続性から代数積を用いている。

図4は、2入力(x_1, x_2)の場合における本FNNの前件部の構成例を示す。(a)は入力 x_1, x_2 に対する前件部メンバーシップ関数がともに3種類の場合、(b)は x_1 のメンバーシップ関数が2種類で x_2

のそれが4種類の場合、(c)はメンバーシップ関数の種類数が(a)と同じで入力空間のファジィ分割の仕方が異なる場合のものである。 m_1, m_2 はそれぞれ x_1, x_2 のメンバーシップ関数の種類数を表し、 n_R は入力空間の分割数を意味する。図中左側の各ネットワークにおいて、(D)層の各ユニットに付けられた矢印は、そのユニットの出力が各前件部メンバーシップ関数値であることを表す。例えば、図4(a)の場合、上から順に $A_{11}(x_1), A_{21}(x_1), A_{31}(x_1), A_{12}(x_2), A_{22}(x_2), A_{32}(x_2)$ が出力される。また、(E)層の $\hat{\Pi}$ の記号を持つユニットは、その入出力関係が次式で定義される。

$$\begin{aligned} I_j^{(n)} &= \prod_k w_{jk}^{(n)} O_k^{(n-1)} \\ \hat{\Pi} : \left\{ \begin{array}{l} I_j^{(n)} \\ O_j^{(n)} = \frac{I_j^{(n)}}{\sum_k I_k^{(n)}} \end{array} \right. \end{aligned} \quad (8)$$

すなわち、(E)層のユニットの出力 $O_j^{(E)}$ は、入力 $I_j^{(E)}$ の総和で規格化されている。この $\hat{\Pi}$ の記号を持つユニットを規格化ユニットと呼ぶ。

図4(a)は、入力 x_1, x_2 に対してそれぞれ3種類の前件部メンバーシップ関数を持つ。(A)~(D)層の構成は図1(a)と同様である。図4(a)のネットワークは、入力空間を図4(a)右側に示すように $3 \times 3 = 9$ のあいまいな部分領域にファジィ分割する。ただし、図中の $R^i (i=1, 2, \dots, 9)$ は、分割された部分領域に対応するファジィルールを表す。各領域における前件部適合度は、(D)層の出力である前件部メンバーシップ関数のグレードから(E)層にて求められる。例えば、(E)層の1番目のユニットでは、前件部適合度

$$\mu_1 = A_{11}(x_1) A_{12}(x_2) \quad (9)$$

が計算される。また、(E)層のユニットの出力は、その前件部適合度を(E)層の全ユニットで得られる前件部適合度の総和で規格化した値となる。すなわち、(E)層では、一般に次のような計算が行われる。

$$\text{入力} : \mu_i = \prod_j A_{ij}(x_j) \quad (10)$$

$$\text{出力} : \hat{\mu}_i = \frac{\mu_i}{\sum_k \mu_k} \quad (11)$$

上式の μ_i はファジィルール R^i の前件部適合度、 $\hat{\mu}_i$ はその総和が 1 となるように規格化された前件部適合度である。ただし、(10)式の添え字 i_j は、例えば図 4(a)に示すごとく

$$\begin{array}{ll} i=1 \text{ のとき} & (1_1, 1_2) = (1, 1) \\ i=2 \text{ のとき} & (2_1, 2_2) = (1, 2) \\ & \vdots \\ i=9 \text{ のとき} & (9_1, 9_2) = (3, 3) \end{array}$$

となる。以上により、(E)層のユニットにおいて重心演算が実現される。

図 4(b)は、入力 x_1, x_2 に対する前件部メンバーシップ関数がそれぞれ 2 種類、4 種類の場合の構

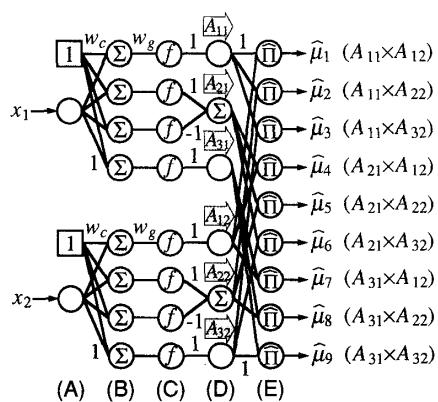
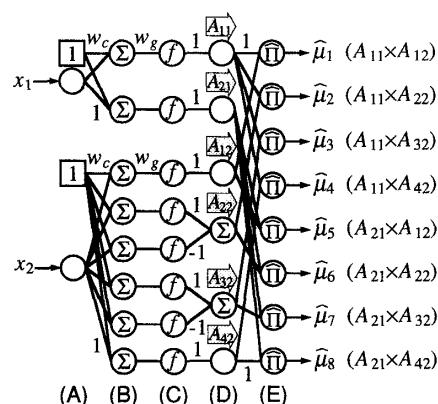
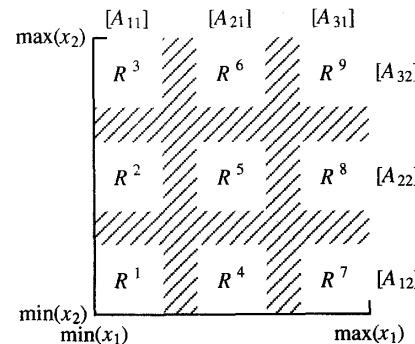
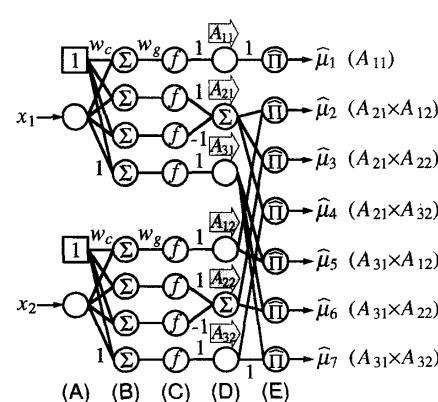
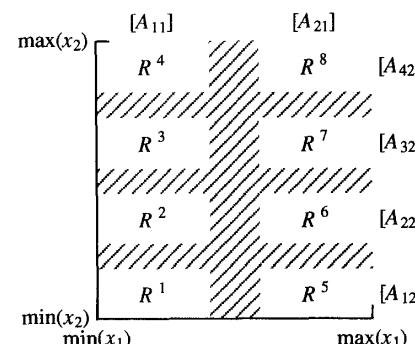
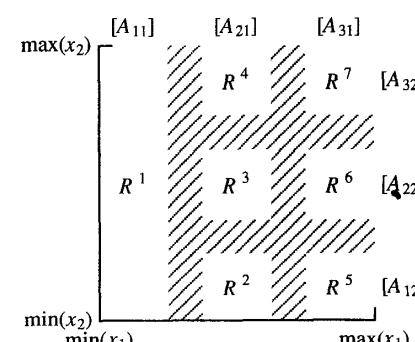
(a) $m_1 = m_2 = 3, n_R = 9$ (b) $m_1 = 2, m_2 = 4, n_R = 8$ (c) $m_1 = m_2 = 3, n_R = 7$ 

図4 前件部の構成例

成を示す。このネットワークでは、(A)～(D)層に x_1 について図 1(b)のネットワークを用い、 x_2 について図 1(c)のネットワークを用いている。ファジィ分割された領域の数は、図 4(b)の右側のように 8 となる。

図 4(a), (b)の構成では、入力空間の分割数 n_R が次のように表される。

$$n_R = \prod_j m_j \quad (12)$$

ここで、 m_j は入力 x_j に対する前件部メンバーシップ関数の種類数である。この n_R はルール数に一致する。ルール数は、後件部の出力推定値(式)が似通っている場合にそれらのルールを一つにまとめることにより減らすことができる。図 4(c)は、その一例を示す。図のネットワークにおいて、(A)～(D)層は図 4(a)と全く同じであるが、(E)層の 1 番上のユニットの入力は $A_{11}(x_1)$ のみとなっている。その結果、入力空間のファジィ分割は図 4(c)の右側のようになり、図 4(a)のファジィルール $R^1 \sim R^3$ が一つにまとめられている。ルール数は、9 から 7 に減少した。

本FNN では、その入出力関係を(8)式で定義する規格化ユニットにより重心法が実現されている。なお、規格化ユニットでは他のユニットとは異なり乗除算が行われているが、(E)層の各ユニットの入力 $I_j^{(n)}$ が非負の前件部適合度であることから

$$\frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} = \frac{\sum_{k \neq j} I_k^{(n)}}{\left(\sum_k I_k^{(n)}\right)^2} \geq 0 \quad (13)$$

となり $I_j^{(n)}$ に対して非減少性を持つため、BP 法に基づく学習が可能となっている。

2.2 後件部

本論文では、著者らの提案してきた Type I, Type II の FNN に以上の新しい前件部構成を取り入れた構成法について述べる。また、後件部がファジィ変数で表されるファジィ推論を実現する新しい FNN を、新たに Type III として提案する。本 FNN の分類は、ファジィ推論の後件部の形

式によってなされる。以下、後件部が定数で表される Type I、一次式で表される Type II、ファジィ変数で表される Type III について順に説明する。

2.2.1 Type I (後件部: 定数)

Type I は、ファジィルールの後件部が定数で表される簡略化ファジィ推論に基づいている。この推論法は、2 入力(x_1, x_2)1 出力(y)の場合次のように表される。

$$R^i : \text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y = f_i \quad (i=1, 2, \dots, n_R) \quad (14)$$

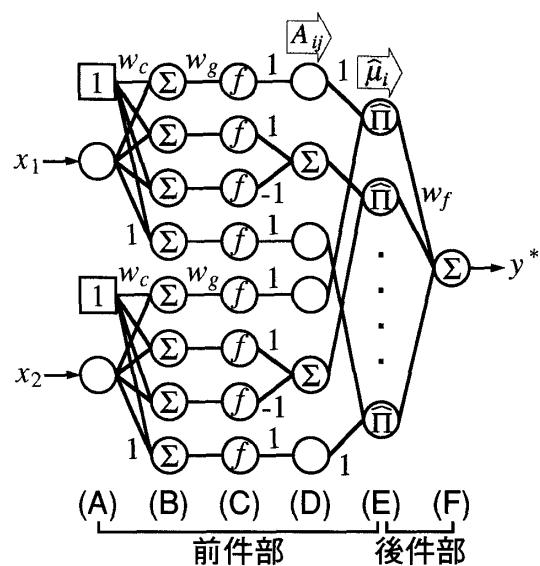
$$y^* = \frac{\sum_{i=1}^{n_R} \mu_i f_i}{\sum_{i=1}^{n_R} \mu_i} = \sum_{i=1}^{n_R} \hat{\mu}_i f_i \quad (15)$$

ここで、 R^i は i 番目のファジィルール、 A_{i1}, A_{i2} は前件部ファジィ変数、 f_i は定数、 n_R はルール数、 y^* は推論値、 μ_i は R^i の前件部適合度、 $\hat{\mu}_i$ は R^i の規格化された前件部適合度である。

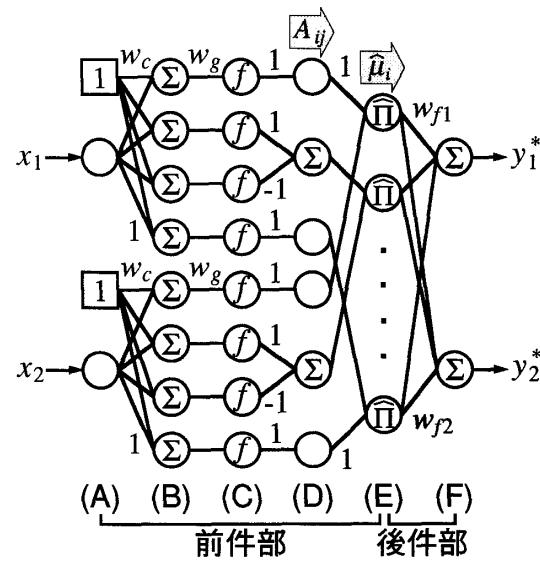
図 5 は、前件部が図 4(a)と同じ場合における Type I の構成例を示す。(a) は 1 出力(y^*)、(b) は 2 出力(y_1^*, y_2^*) の場合のものである。図中の w_f は、後件部定数 f_i を意味する結合荷重である。また、(D), (E) 層に付けられた矢印は、各層におけるユニットの出力がそれぞれ前件部メンバーシップ関数値 A_{ij} および規格化された前件部適合度 $\hat{\mu}_i$ であることを表す。

Type I では、(E)～(F) 層が後件部に対応する。図 5(a)の構成では、(F) 層において (E) 層の出力である規格化された前件部適合度 $\hat{\mu}_i$ と結合荷重 w_f の積和が求められる。これは、(15) 式からわかるように、簡略化ファジィ推論の重心法による推論値となる。以上により、(14), (15) 式に基づく簡略化ファジィ推論が実現される。図 5(b) は、(a) における (E)～(F) 層の構成をもう一つ増設することにより 2 出力としたものである。このとき、ファジィルールの後件部は “ $y_1 = f_{i1}$ and $y_2 = f_{i2}$ ” と表され、各推論値はそれぞれ f_{i1}, f_{i2} を意味

する結合荷重 w_{f1}, w_{f2} により計算される。3 出力以上の場合も同様にして構成できる。これらの FNN は、重心法が前件部の規格化ユニットにより実現されているため、文献[16]の FNN と基本的な構成に変わりはない。一方、文献[14]の除算を行うユニットを用いた場合には、特に多出力の場合においてネットワークが複雑になるという問題が生じる。これは、通常の NN に比べてネットワーク内の処理がわかりやすいという FNN の特徴を損なうものである。本論文で提案した重心法の実現手法によれば、FNN が複雑なネットワークとなることはない。



(a) 1出力の場合



(b) 2出力の場合

図5 FNN(Type I)の構成例

文献[16]の FNN では、(14)式のファジィルールから、推論値を重心法ではなく

$$y^* = \sum_{i=1}^{n_r} \mu_i f_i \quad (16)$$

のように前件部適合度と後件部定数の積和により求めている。推論値計算を(16)式で行う場合、ある入力に対して例えば1番目のファジィルールのみが0でない前件部適合度を持ったとすると、推論値は $\mu_1 f_1$ となる。これは、前件部適合度の値が推論値に直接影響を及ぼすことを表す。1番目のファジィルールだけが適用されるにもかかわらず、推論値は $\mu_1 = 1$ のとき以外は f_i よりも小さな値となるため、推論値とファジィルールに記述された値が一致しない。しかも、2.1.1節で述べたように本 FNN の前件部メンバーシップ関数は完全には正規とならないことから、推論値は常にファジィルールの値よりも小さくなる。これに対して(15)式の重心法によれば、この例では $\hat{\mu}_1 = 1$ となって推論値は f_1 となり、ファジィルールに記述された通りの値を得ることが可能となる。これは、重心法を用いた新しい FNN によりネットワークの入出力関係を正確に表したファジィルールが同定できることを意味する。

Type I では、結合荷重 w_f の初期値をすべて 0 としてファジィルールが全く存在しない状態から学習を始め、 w_f を変化させることによりファジィルールの同定を行う。

2.2.2 Type II (後件部:一次式)

Type II で用いる推論法においては、ファジィルールの後件部が入力変数の一次式で表される。この方法は、2 入力 1 出力で前件部変数と後件部変数が共通の場合次のように表される。

$$R^i : \text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y = f_i(x_1, x_2) \quad (i=1, 2, \dots, n_r) \quad (17)$$

$$y^* = \frac{\sum_{i=1}^{n_r} \mu_i f_i(x_1, x_2)}{\sum_{i=1}^{n_r} \mu_i} = \sum_{i=1}^{n_r} \hat{\mu}_i f_i(x_1, x_2) \quad (18)$$

ここで、

$$f_i(x_1, x_2) = a_{i0} + a_{i1}x_1 + a_{i2}x_2 \quad (19)$$

であり、上式の a_{ij} ($j=0, 1, 2$) は定数を表す。Type I における簡略化ファジィ推論は、この推論法の後件部一次式を定数項のみにしたものと考えることができる。従って、Type II は、基本的に Type I よりも優れた記述能力を持つ。

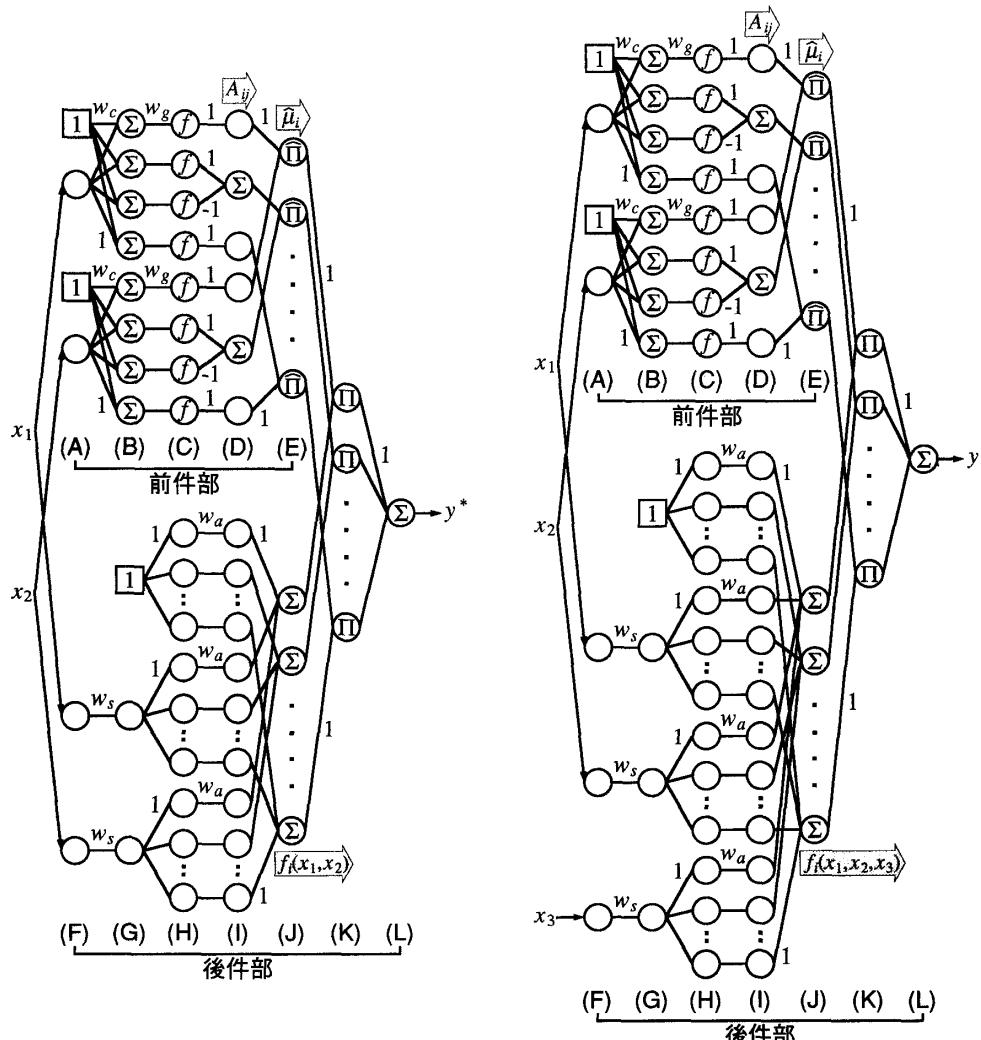
図 6 は、2 入力 (x_1, x_2) 1 出力 (y^*) の場合における Type II の構成例を示す。前件部は図 5 の Type I と同じである。図 6(a) は後件部変数が前件部変数と共通の場合 (x_1, x_2)、(b) は前件部変数と異なる場合 (x_1, x_2, x_3) のものである。図中の結合

荷重 w_s は、文献[16]の FNN と同様に入力変数の規格化定数を意味し、 w_a は、(19) 式の定数 a_{ij} に対応する。また、(K) 層の Π の記号を持つユニットは、その入出力関係が

$$\Pi : \begin{cases} I_j^{(n)} = \prod_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = I_j^{(n)} \end{cases} \quad (20)$$

のように表される。

Type II の後件部は、(F)～(L) 層により実現される。図 6(a)において、(F) 層に加えられた各入力は結合荷重 w_s によって規格化され、それらに w_a を掛けたものの和が (J) 層にて求められる。すなわち、 w_a が (19) 式の定数 a_{ij} に対応し、(J) 層の出力は各ファジィルールの後件部一次式 $f_i(x_1, x_2)$ となる。ただし、定数項以外の a_{ij} ($j \neq 0$) は、正確には w_s と w_a の積に一致する。(18) 式に従い、(K)



(a) 前件部変数と後件部変数が共通の場合 (b) 前件部変数と後件部変数が異なる場合

図6 FNN (Type II) の構成例

層にて $f_i(x_1, x_2)$ と規格化された前件部適合度 $\hat{\mu}_i$ の積が求められ、(L)層にてその総和である推論値が計算される。なお、(E), (J), (K)層のユニット数はすべてルール数に一致している。図 6(b)は、後件部一次式を

$$\begin{aligned} y &= f_i(x_1, x_2, x_3) \\ &= a_{i0} + a_{i1}x_1 + a_{i2}x_2 + a_{i3}x_3 \end{aligned} \quad (21)$$

としたものである。入力 x_3 に対する前件部メンバーシップ関数は構成されていない。このネットワークでは、図 6(a)の場合と全く同様にして推論値が求められる。Type IIでは、前件部変数と後件部変数を独立に選定することが可能である。図 6(b)とは逆に前件部変数の数を後件部変数のそれより多くすることももちろんできる。また、Type I 同様、後件部(F)～(L)層の増設によって多出力化を実現できる。

Type IIにおける結合荷重 w_s は、 w_a の値を入力変数によらずほぼ同程度の値として、 w_a の学習率の設定を簡単化するためのものである。BP 法では、後述するように、結合荷重 $w_{ji}^{(n)}$ の更新量は第 n 層第 j ユニットにおける逆伝播誤差と第 $n-1$ 層第 i ユニットの出力に比例した値で与えられる。 w_a では、その更新量が(I)層の逆伝播誤差と(H)層の出力に比例することになるが、逆伝播誤差は(J)層のユニットから結合荷重 1 を介して伝播されるため、一つの後件部一次式 $f_i(x_1, x_2, \dots)$ の中の各係数 w_a の更新量は後件部の各入力 x_j の大きさによって左右される。すなわち、入力値が大きいほど結合荷重の更新量も大きくなり、各 w_a の望ましい更新量とは必ずしも一致しない。従って、 w_a に対する学習率を入力変数毎に個別に設定しなければならず、この学習率の選定を含む学習には多大な労力が必要となる。図 6 のように規格化用の結合荷重を設けた場合には、各入力が均等となることからそのような必要はなく、各 w_a に対し一つの学習率を設定すればよい。

結合荷重 w_s は、後件部変数の規格化定数であることから学習データにおける入力値の絶対値最大値の逆数に設定し、以後更新はしない。また、 w_a

の初期値をすべて 0 にして、 w_a のみを学習で変化させることによりファジィルールの同定を行う。

2.2.3 Type III (後件部: ファジィ変数)

Type IIIでは、Type I や Type II とは異なり、間接法によるファジィ推論を用いている。この推論法のファジィルールは、次のように後件部がファジィ変数で表され言語的真理値(Linguistic Truth Value : LTV)を持つ。

$$R_k^i : (\text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y \text{ is } B_k) \quad \text{is } \tau_{R_k^i} \quad (i=1, 2, \dots, n_R; k=1, 2) \quad (22)$$

ここで、 B_k は後件部ファジィ変数である。そのメンバーシップ関数には、図 7 のような互いに補集合に近い関係にある二つのファジィ変数 B_1, B_2 が用いられている。 R_k^i は、前件部ファジィ変数が A_{i1} および A_{i2} であり、後件部ファジィ変数が B_k ($k=1, 2$)であるときのファジィルールである。従って、Type IIIのルール数は、Type I や Type II のそれの 2 倍となる。また、 $\tau_{R_k^i}$ は区間[0,1]の確定値で表される LTV であり、 $\tau_{R_k^i}=0$ のとき対応するファジィルールが「完全に偽」、 $\tau_{R_k^i}=1$ のときのそれが「完全に真」であることを意味する。Type IIIにおいては、この $\tau_{R_k^i}$ によりファジィルールの同定を行うが、本 FNN の中では最も言語的表現に近いファジィルールが獲得されることとなる。

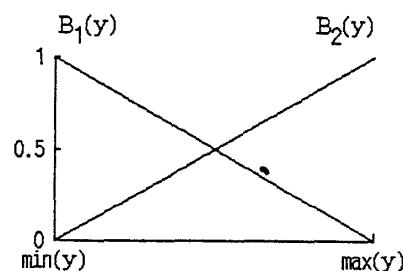


図7 後件部メンバーシップ関数

Type IIIの推論法では、次のようにして推論値が求められる。

$$\mu'_{ik} = \sum_{i=1}^{n_k} \hat{\mu}_i \tau_{R_{ik}} \quad (23)$$

$$y^* = \frac{\sum_{k=1}^2 \mu'_{ik} B_k^{-1}(\mu'_{ik})}{\sum_{k=1}^2 \mu'_{ik}} = \sum_{k=1}^2 \mu'_{ik} B_k^{-1}(\mu'_{ik}) \quad (24)$$

ここで、 μ'_{ik} は B_k を出力すべき度合を表すものであり、前件部適合度に倣って後件部適合度と呼ぶ。

$B_k^{-1}(\mu'_{ik})$ は後件部メンバーシップ関数 $B_k(y)$ の逆関数値である。

図8は、2入力1出力の場合におけるType IIIの構成例を示す。図中の w_r は各ファジィルールのLTV $\tau_{R_{ik}}$ を表す結合荷重であり、 w'_c , w'_g はそれぞれ後件部メンバーシップ関数のグレードが0となる点および傾きを意味する。Type IIIは、(E)～(J)層において後件部の計算を行う。図8の(E)～(F)層の構成は、図5(b)に示すType Iの後件部と同一である。従って、Type Iの推論値と同様に、(F)層の出力は(23)式右辺の規格化された前件部適合度 $\hat{\mu}_i$ と $\tau_{R_{ik}}$ を意味する結合荷重 w_r の積和となり、後件部適合度 μ'_{ik} が求められる。後件部メンバーシップ関数は、この μ'_{ik} より(F)～(H)層にて

$$B_k^{-1}(\mu'_{ik}) = y = w'_g \mu'_{ik} + w'_c \quad (25)$$

すなわち

$$B_k(y) = \mu'_{ik} = \frac{y - w'_c}{w'_g} \quad (26)$$

のように実現される。(26)式より $B_k(y)$ は直線であり、その値の0となる点および傾きがそれぞれ結合荷重 w'_c , w'_g で定められていることがわかる。また、

$$\tau_{R_{ik}} \in [0, 1], \sum_{i=1}^{n_k} \hat{\mu}_i = 1 \quad (27)$$

であることから(23)式より

$$B_k(y) = \mu'_{ik} \in [0, 1] \quad (28)$$

となり、 $B_k(y)$ のとる値は[0, 1]の区間内にある。従って、 $B_k(y)$ をメンバーシップ関数とみなすことができる。(G)層においては、前件部(E)層と同じく規格化された後件部適合度 $\hat{\mu}'_{ik}$ が計算される。(G)層の規格化ユニットは、その入力が非負の後件部適合度であるため非減少性を満たしBP法を適用できる。以上により、(I)層では各後件部ファジィ変数毎に $\hat{\mu}'_{ik}$ と $B_k^{-1}(\mu'_{ik})$ が結合され、(22)～(24)式に基づく推論値が(J)層から出力される。

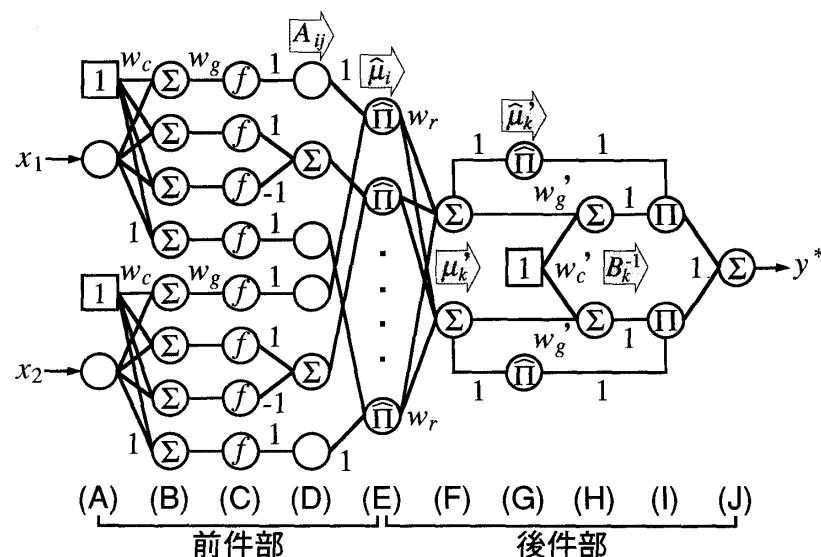


図8 FNN(Type III)の構成例

一般に、間接法によるファジィ推論は、次のように真理値空間を介して行われる^[3]。

- (i) 逆真理値限定により与えられた事実(入力値)に対する前件部命題の LTV τ_A を求める。
- (ii) τ_A と条件命題(ファジィルール)の LTV τ_R から後件部命題の LTV τ_B を計算する。
- (iii) τ_B を真理値限定することにより結論(推論値)を得る。

この推論過程における LTV は、すべて数値的真理値を台集合とするファジィ集合であるが、制御等では入力値が確定値で表されるためシングルトンとなる。制御向けに簡略化された方法では、(i) の τ_A が前件部適合度を用いて求められ、(ii) の τ_B は τ_R が「完全に真」すなわち 1 とされることからルカシーウィッチの含意により τ_A に一致する。(iii) における真理値限定は、ファジィルールが複数個存在する場合各ファジィルール毎に行われるものであり、推論値は、(15), (18) 式と同じく真理値限定された値の前件部適合度による重み付き平均で計算される。一方、Type III の実現するファジィ推論は、NN の構造で表現するためにやや特殊な方法となっている。Type III では、 τ_A に(11)式の μ_i を用いており、また、ファジィルール R_k^i の後件部命題の LTV $\tau_{B_k^i}$ を直接法と同様に

$$\tau_{B_k^i} = \tau_{A_i} \cdot \tau_{R_k^i} \quad (29)$$

により計算し、これらを

$$\tau_{B_k} = \sum_{i=1}^{n_k} \tau_{B_k^i} \quad (30)$$

のように統合した後で真理値限定を行う。ここで、 τ_{A_i} は R_k^i の前件部命題の LTV、 τ_{B_k} は後件部ファジィ変数 B_k の LTV である。このように、本 FNN により実現された間接法によるファジィ推論が制御に用いられる従来の間接法によるそれと少し異なっているのは、本 FNN において前件部の構成を Type I および Type II と共にするとともに、前述のごとく後件部メンバーシップ関数の存在を保証し、ネットワークの構成が複雑になるのを防止するような工夫がなされたためである。

Type III は間接法によるファジィ推論ではあるが、従来の間接法によるファジィ推論法では前件部、後件部ともそのメンバーシップ関数が単調性を持たなければならない制約がある^[3]のに対し、Type III の前件部は直接法と同じ擬似台形型メンバーシップ関数が用いられているので、Type III の記述能力が Type I, Type II に劣ることはない。また、従来法のように各ファジィルールの LTV $\tau_{R_k^i}$ を固定せず可変にしているため、(29) 式から $\tau_{R_k^i}$ を B_k の述語修飾演算子として解釈することもできる。

Type III では、後件部メンバーシップ関数を、そのパラメータである結合荷重 w_c, w_g により学習データにおける出力値の最小値から最大値までを台集合として初期化する。そして、その調整は、前件部と同様に w_c, w_g を学習で変化させることによって行われる。また、 w_r の初期値は (G) 層のユニットにおける内部関数の分母が 0 とならないようすべて 0.5 とし、等価的にファジィルールを持たない状態から学習を始める。なお、Type III においても多出力化が可能である。

3. 学習法

3.1 BP 法

前章で述べたように、本 FNN では、特定の意味を持つ結合荷重を学習によって変化させることにより、ファジィルールの同定およびメンバーシップ関数の調整を行う。その学習アルゴリズムには、以下に示す BP 法を用いる。

今、 N 個の学習データが与えられたとして、次のような出力誤差評価関数を定義する。

$$E_p = \frac{1}{2} \sum_j (y_{pj} - y_{pj}^*)^2 \quad (31)$$

$$E = \sum_{p=1}^N E_p \quad (32)$$

ここで、 y_{pj} は p 番目の学習データにおける j 番目の出力値、 y_{pj}^* は y_{pj} に対する本 FNN の推論値である。このとき、学習データ全体による出力誤差 E の最小化のため、 p 番目の学習データに対する出力誤差 E_p を最小にするには、結合荷重 $w_{ji}^{(p)}$ の

更新量 $\Delta w_{ji}^{(n)}$ を

$$\Delta w_{ji}^{(n)} \propto -\frac{\partial E_p}{\partial w_{ji}^{(n)}} \quad (33)$$

のように定めればよい。上式の右辺は、 $w_{ji}^{(n)}$ の定義より

$$-\frac{\partial E_p}{\partial w_{ji}^{(n)}} = -\frac{\partial E_p}{\partial I_j^{(n)}} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} \quad (34)$$

と変形できるが、その 2 番目の項は、本 FNN において学習時に変化する結合荷重に対し

$$\begin{aligned} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} &= \frac{\partial}{\partial w_{ji}^{(n)}} \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ &= O_i^{(n-1)} \end{aligned} \quad (35)$$

となる。従って、1 番目の項を 2 層線形パーセプトロンに倣い

$$\delta_j^{(n)} = -\frac{\partial E_p}{\partial I_j^{(n)}} \quad (36)$$

と定義する^[2]と、(33) 式は

$$\Delta w_{ji}^{(n)} \propto \delta_j^{(n)} O_i^{(n-1)} \quad (37)$$

のように表される。(36) 式の $\delta_j^{(n)}$ は、各ユニットにおける出力誤差を意味する。BP 法の学習は、この $\delta_j^{(n)}$ を出力層から入力層に向かって逆伝播されることにより行われる。以下、本 FNN における $\delta_j^{(n)}$ の逆伝播規則であるデルタルールを導出する。

(36) 式は、一般に次のように変形できる。

$$\delta_j^{(n)} = -\sum_m \frac{\partial E_p}{\partial O_m^{(n)}} \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \quad (38)$$

$$= -\sum_m \left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_m^{(n)}} \right) \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \quad (39)$$

(38), (39) 式は、各ユニットにおける $\delta_j^{(n)}$ の計算が、そのユニットの内部関数と次層 ($n+1$ 層) の入力形式によって異なることを示している。

まず、出力層におけるデルタルールを導出する。本 FNN の出力層は、タイプによらず入出力関係が(3) 式で定義される Σ の記号を持つユニットにより構成される。従って、出力層では、 $O_j^{(n)}$ が推論値 y_{pj}^* に一致することから、(38), (31) 式より

$$\begin{aligned} \delta_j^{(n)} &= -\frac{\partial E_p}{\partial O_j^{(n)}} \frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} \\ &= -\frac{\partial}{\partial y_{pj}^*} \left\{ \frac{1}{2} \sum_k (y_{pk} - y_{pj}^*)^2 \right\} \frac{\partial}{\partial I_j^{(n)}} I_j^{(n)} \\ &= y_{pj} - y_{pj}^* \end{aligned} \quad (40)$$

となる。

中間層においては、入出力関係の互いに異なるユニットが特殊な構造で結合されているため、そのユニットの内部関数が 1 入力または多入力、次層のユニットの入力が和 (Σ) または積 (Π) によって、次の四つの場合に分けられる。まず、内部関数が 1 入力のユニットとして、入出力関係が(4) 式で定められる f の記号を持つユニットを考える。このユニットでは、(39), (36) 式より、次層のユニットの入力が和で表されるとき

$$\begin{aligned} \delta_j^{(n)} &= -\left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_j^{(n)}} \right) \frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} \\ &= \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_j^{(n)}} \sum_i w_{ki}^{(n+1)} O_i^{(n)} \right) \frac{\partial}{\partial I_j^{(n)}} f(I_j^{(n)}) \\ &= f'(I_j^{(n)}) \sum_k \delta_k^{(n+1)} w_{kj}^{(n+1)} \end{aligned} \quad (41)$$

により $\delta_j^{(n)}$ が求められる。また、次層のユニットの入力が積で表されるときには

$$\begin{aligned} \delta_j^{(n)} &= -\left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_j^{(n)}} \right) \frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} \\ &= \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_j^{(n)}} \prod_i w_{ki}^{(n+1)} O_i^{(n)} \right) \frac{\partial}{\partial I_j^{(n)}} f(I_j^{(n)}) \\ &= f'(I_j^{(n)}) \sum_k \delta_k^{(n+1)} w_{kj}^{(n+1)} \left(\prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} \right) \end{aligned} \quad (42)$$

となる。ここで、 $f'(\cdot)$ は各ユニットの内部関数の導関数である。上式は、規格化ユニット以外のすべてのユニットにおいて適用できるものである。ただし、 f の記号を持つユニットの他はすべて線形ユニットであるため、常に $f'(I_j^{(n)}) = 1$ となる。次に、内部関数が多入力の場合である入出力関係が(8) 式で定められる規格化ユニットを考える。この場合、次層のユニットの入力が和で表されるときには

$$\delta_j^{(n)} = -\sum_m \left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_m^{(n)}} \right) \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}}$$

$$\begin{aligned}
 &= \sum_m \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_m^{(n)}} \sum_i w_{ki}^{(n+1)} O_i^{(n)} \right) \\
 &\quad \times \frac{\partial}{\partial I_j^{(n)}} \left(\frac{I_m^{(n)}}{\sum_l I_l^{(n)}} \right) \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} (1 - O_j^{(n)}) - \sum_{m \neq j} w_{km}^{(n+1)} O_m^{(n)}}{\sum_l I_l^{(n)}} \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} - I_k^{(n+1)}}{\sum_l I_l^{(n)}} \tag{43}
 \end{aligned}$$

となり、次層のユニットの入力が積で表されるときには

$$\begin{aligned}
 \delta_j^{(n)} &= - \sum_m \left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_m^{(n)}} \right) \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \\
 &= \sum_m \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_m^{(n)}} \prod_i w_{ki}^{(n+1)} O_i^{(n)} \right) \\
 &\quad \times \frac{\partial}{\partial I_j^{(n)}} \left(\frac{I_m^{(n)}}{\sum_l I_l^{(n)}} \right) \\
 &= \sum_k \delta_k^{(n+1)} \left(\frac{w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} (1 - O_j^{(n)})}{\sum_l I_l^{(n)}} \right. \\
 &\quad \left. - \frac{\sum_{m \neq j} w_{km}^{(n+1)} \prod_{i \neq m} w_{ki}^{(n+1)} O_i^{(n)} O_m^{(n)}}{\sum_l I_l^{(n)}} \right) \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} \left(\prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} \right) - \sum_m I_m^{(n+1)}}{\sum_l I_l^{(n)}} \tag{44}
 \end{aligned}$$

により計算される。なお、Type IIIの後件部(F)層の $\delta_j^{(n)}$ は、その構成から (41), (42) 式の和で求められる。

結合荷重は、(40)～(44) 式の結果から、(37) 式に従い

$$w_{ji}^{(n)}(m+1) = w_{ji}^{(n)}(m) + \eta \delta_j^{(n)} O_i^{(n-1)} \tag{45}$$

と更新する。ここで、 m は更新回数、 η は学習率である。ただし、Type III の w_r については、

$$w_{ji}^{(n)}(m+1) = (1 - \beta) w_{ji}^{(n)}(m) + \eta \delta_j^{(n)} O_i^{(n-1)} \tag{46}$$

により更新を行う。上式の β は減衰率である。 w_r の更新に(45)式を用いた場合、その初期値をすべて 0.5 に設定することから、入力空間における学習データの分布に偏りがあると一部の不必要的ファジィルールが残ってしまう可能性が考えられる。(46)式によれば、そのようなファジィルールを学習回数に応じて減衰させることができ、有効なファジィルールのみの抽出が可能である。なお、学習データが入力空間全体にはほぼ均一に分布している場合には、減衰率 β を設定する必要はない。

3.2 学習率の設定

本 FNN の学習には以上の BP 法を用いるが、(37) 式に基づく結合荷重の更新に対しては次のような問題が存在する。本 FNN では、すべての結合荷重が意味を持つため、その用い方により結合荷重の値が大きく異なる。従って、結合荷重を介して逆伝播される各層の $\delta_j^{(n)}$ にも偏りが生じ易く、学習率を結合荷重の種類毎に設定してそれぞれの更新量を適切な値とする必要がある。特に、メンバーシップ関数を定める結合荷重においてはこの学習率の設定が重要であり、学習後のメンバーシップ関数が学習前に比べて過剰に変化することないようにしなければならない。例えば、前件部メンバーシップ関数では、それを構成するシグモイド関数が学習時に独立に移動するため、学習率が大き過ぎるとメンバーシップ関数があらかじめ設定した台集合上に存在しなくなる可能性がある。もし、そのような前件部構造となってしまった場合、同定されたファジィルールは正しく評価できるものではなくくなってしまうので、適切な学習率の設定が必要である。しかし、前件部メンバーシップ関数を定める結合荷重 w_c , w_g は、前件部構造によって初期値の比が 10^4 を超えることがあり、適切な学習率も同程度に異なることからその探索はかなり煩雑となる。すなわち、ネットワークが実現するファジィモデルの構造が学習率設定に与える影響を除去できれば、学習率設定における煩

雑さを幾分低減できる。

そこで、学習率 η に対して

$$\eta = \eta' \kappa \quad (47)$$

のように各結合荷重の更新量の基準となる定数 κ を考える。この κ は、見かけの学習率 η' が本 FNN の構造に依存しないようにするためのパラメータである。 w_g の学習率については $\kappa = (w_g \text{ の初期値})$ とし、 w_c の学習率では前件部メンバーシップ関数の間隔と w_g の初期値の逆数の積とする。 w_g の κ は、 $\delta_j^{(C)}$ に対して、入力変数毎にメンバーシップ関数の種類数が異なる場合におけるそれぞれの w_g の違いを吸収している。 w_c の学習率に w_g の初期値の逆数が含まれているのは、 $\delta_j^{(B)}$ が $\delta_j^{(C)}$ と w_g の積により求められることからこの w_g の影響を相殺するためである。また、メンバーシップ関数の間隔を κ に入れることで前件部メンバーシップ関数の w_c による形状変化が関数の間隔に比例し、メンバーシップ関数の配置を大きく偏らせることがない。同様に、Type III の後件部では、 $\delta_j^{(H)}$ に対し、 w'_c の学習率については κ を後件部メンバーシップ関数の間隔と一致させ、 w'_g のそれについては $\kappa = (w'_g \text{ の初期値})$ 、 w_r では w'_g の初期値の逆数とする。これらの κ の値は、各結合荷重を初期化する際に自動的に計算できるものである。

また、前件部の w_g については、 $O_i^{(B)}$ の影響を低減するため次式により更新を行う。

$$w_{ji}^{(n)}(m+1) = w_{ji}^{(n)}(m) + \eta \delta_j^{(n)} |w_{ji}^{(n)}(m)| O_i^{(n-1)} \quad (48)$$

上式の $|w_{ji}^{(n)}(m)| O_i^{(n-1)}$ は、(C)層のシグモイド関数の入力と等価である。図3からわかるように、前件部メンバーシップ関数を構成する各シグモイド関数が変化するのは、その微分値が入力値に対して無視できない値を持つときであるから、このときの(C)層の入力値はほぼ一定の範囲内にあると考えられる。従って、(48)式によれば、 w_g の更新量に対する $O_i^{(B)}$ の影響を小さくすることが可能である。

以上のような手法により、 w_c と w_g 等の見かけの学習率 η' は同程度の値となり、適切な学習率の設定が容易になる。これによって 2.1.1 節で指摘した問題点(iii)が改善されるが、学習率の値が大き過ぎる場合には学習後のメンバーシップ関数が不適当な形状となることは避けられず、この点については今後の検討課題としている。

なお、次章の数値例における学習率はすべて(47)式の η' を意味するが、Type I の w_f および Type II の w_a については、その大きさが $\delta_j^{(n)}$ に比例するためこのような手法は必要なく η 自身を表す。

4. 数値例

本論文において提案した Type III の有効性、重心法によるファジィルールの正確な同定および学習率設定の簡単化を検証するため、文献[17]と同様に文献[13][15]で用いられた簡単な数値例によりファジィモデリングを行った。

モデリングの対象としたのは、次式で表される3入力1出力の非線形システムである。

$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \quad (49)$$

表1は、このシステムから採取した40個の入出力データを示す^[15]。No.1~20は同定用データ、No.21~40は評価用データである。文献[15]では、一般的なファジィモデリングの例題とするためこれらのデータに(49)式とは無関係なダミー変数 x_4 を加えているが、ここでは上記目的に従い x_1 , x_2 , x_3 のみを用いてファジィモデルを同定した。

本FNNの構成は、Type I および Type III では x_1 , x_2 , x_3 の3入力としたが、Type II では

- (i) 前件部、後件部とも3入力
 - (ii) 前件部が x_2 , x_3 の2入力、後件部が3入力
- の二つ場合について学習を行った。前件部メンバーシップ関数はすべての入力変数に対して2種類とし、Type III の後件部メンバーシップ関数とともにそれらのラベルを Small, Big としている。従って、Type II の(ii)の構成は、文献[13][15]における構造同定の結果に一致する。本FNNの学習

は、20個の同定用データを順次ネットワークに入力することによって行い、データの一巡をもって学習回数1回とした。また、各結合荷重に対する学習率は、入出力データの値と学習時のメンバーシップ関数の変化から、それぞれのタイプにおいて表2のように設定した。表2では、(47)式の定数 κ の導入によって、前件部メンバーシップ関数を定める結合荷重 w_c , w_g およびType IIIの後件部メンバーシップ関数を定める結合荷重 w'_c , w'_g の学習率がそれぞれ同程度の値となっている。なお、Type IIIの w_r に対する(46)式の減衰率 β は、入出力データの分布がほぼ均一であるため0としている。

表3は、2000回の学習を行った後の本FNNの精度を示す。表中の J_1 , J_2 は、それぞれ同定されたファジィモデルの同定用データおよび評価用データに対する平均相対誤差であり、

$$J_1 = \frac{1}{20} \sum_{i=1}^{20} \frac{|y_i - y_i^*|}{y_i} \times 100 (\%) \quad (50)$$

$$J_2 = \frac{1}{20} \sum_{i=21}^{40} \frac{|y_i - y_i^*|}{y_i} \times 100 (\%) \quad (51)$$

のように定義される。表3には、重心法を用いていないFNN^[17]や文献[13][15]の菅野の手法により獲得されたモデルについてもその精度を示す。本FNNでは、推論法やType IIにおける構成の相違によるモデルの精度の差はほとんど見られないが、Type IIの(ii)の場合のルール数が $2^2=4$ 、他の場合が $2^3=8$ であることから、Type IIの記述能力の高さが表れていると理解できる。また、本FNNの同定したモデルの精度は、重心法を用いていないFNNや菅野の手法によるものと同程度の値となっており、本FNNがファジィシステムとして十分な性能を持つことが示されている。

本FNNにおける学習前後のメンバーシップ関数を図9に示す。破線が学習前、実線が学習後のメンバーシップ関数を表す。前件部メンバーシップ関数は、タイプによらずほぼ同様な調整がなされており、(49)式で出力値に及ぼす非線形性が高い入力変数のメンバーシップ関数ほど大きく変化

表1 入出力データ

No.	入力			出力	No.	入力			出力
	x_1	x_2	x_3			x_1	x_2	x_3	
1	1	3	1	11.110	21	1	1	5	9.545
2	1	5	2	6.521	22	1	3	4	6.043
3	1	1	3	10.190	23	1	5	3	5.724
4	1	3	4	6.043	24	1	1	2	11.250
5	1	5	5	5.242	25	1	3	1	11.110
6	5	1	4	19.020	26	5	5	2	14.360
7	5	3	3	14.150	27	5	1	3	19.610
8	5	5	2	14.360	28	5	3	4	13.650
9	5	1	1	27.420	29	5	5	5	12.430
10	5	3	2	15.390	30	5	1	4	19.020
11	1	5	3	5.724	31	1	3	3	6.380
12	1	1	4	9.766	32	1	5	2	6.521
13	1	3	5	5.870	33	1	1	1	16.000
14	1	5	4	5.406	34	1	3	2	7.219
15	1	1	3	10.190	35	1	5	3	5.724
16	5	3	2	15.390	36	5	1	4	19.020
17	5	5	1	19.680	37	5	3	5	13.390
18	5	1	2	21.060	38	5	5	4	12.680
19	5	3	3	14.150	39	5	1	3	19.610
20	5	5	4	12.680	40	5	3	2	15.390

表2 学習率の設定

結合荷重	学習率	結合荷重	Type II			Type III
			構成	(i)	(ii)	
w_c	0.001	w_c	0.001	0.001		w_c
w_g	0.0005	w_g	0.0005	0.0005		w_g
w_f	0.5	w_a (定数項) (変数項)	0.1 0.05	0.2 0.1		w_r w'_c w'_g
						0.02 0.01 0.05 0.0001 0.0001

表3 ファジィモデルの比較

手法	$J_1(\%)$	$J_2(\%)$
本FNN	Type I	0.31
	Type II (i)	0.27
	(ii)	0.67
	Type III	0.42
重心法を用いないFNN ^[17]	Type I	0.82
	Type II (i)	0.60
	Type III	1.38
菅野ファジィモデリング ^{[13][15]}	モデル I	1.5
	モデル II	1.1
		3.6

している。一般にファジィモデルは、非線形システムの入出力関係を、ファジィ分割された入力空間の各部分領域毎に線形関数で近似してそれらを

滑らかに結合することにより実現したものである^[15]。従って、対象システムは、分割された各領域においては線形で近似され、台集合全域では非線形で近似されていると考えられる。本論文でファジイモデリングの対象とした(49)式では、展開すると x_1, x_2^{-2}, x_3^{-3} のような項も現れるが、基本的にそれぞれの入力変数に関し $x_1^{0.5}, x_2^{-1}, x_3^{-1.5}$ の特性が支配的である。これらは、表1の入力データの範囲 $1 \leq x \leq 5$ において図10のように変化する。図10からわかるように、 $x^{0.5}$ は全域でほぼ線形

と見なすことができる。従って、Type IIでは、(ii)のように x_1 を後件部のみに含めることによりルール数を削減して見通しの良いモデルを得ることができる。実際、表3におけるそれらの精度には大差がなく、(ii)の構造の方がむしろ適当であると言える。Type IおよびType IIIでは、後件部に入力変数を直接反映させることができないため x_1 を前件部変数とする必要があるが、そのメンバーシップ関数は、ほとんど調整されていない。一方、 $x^{-1}, x^{-1.5}$ は、 $1 < x < 3$ において2本の直線で折

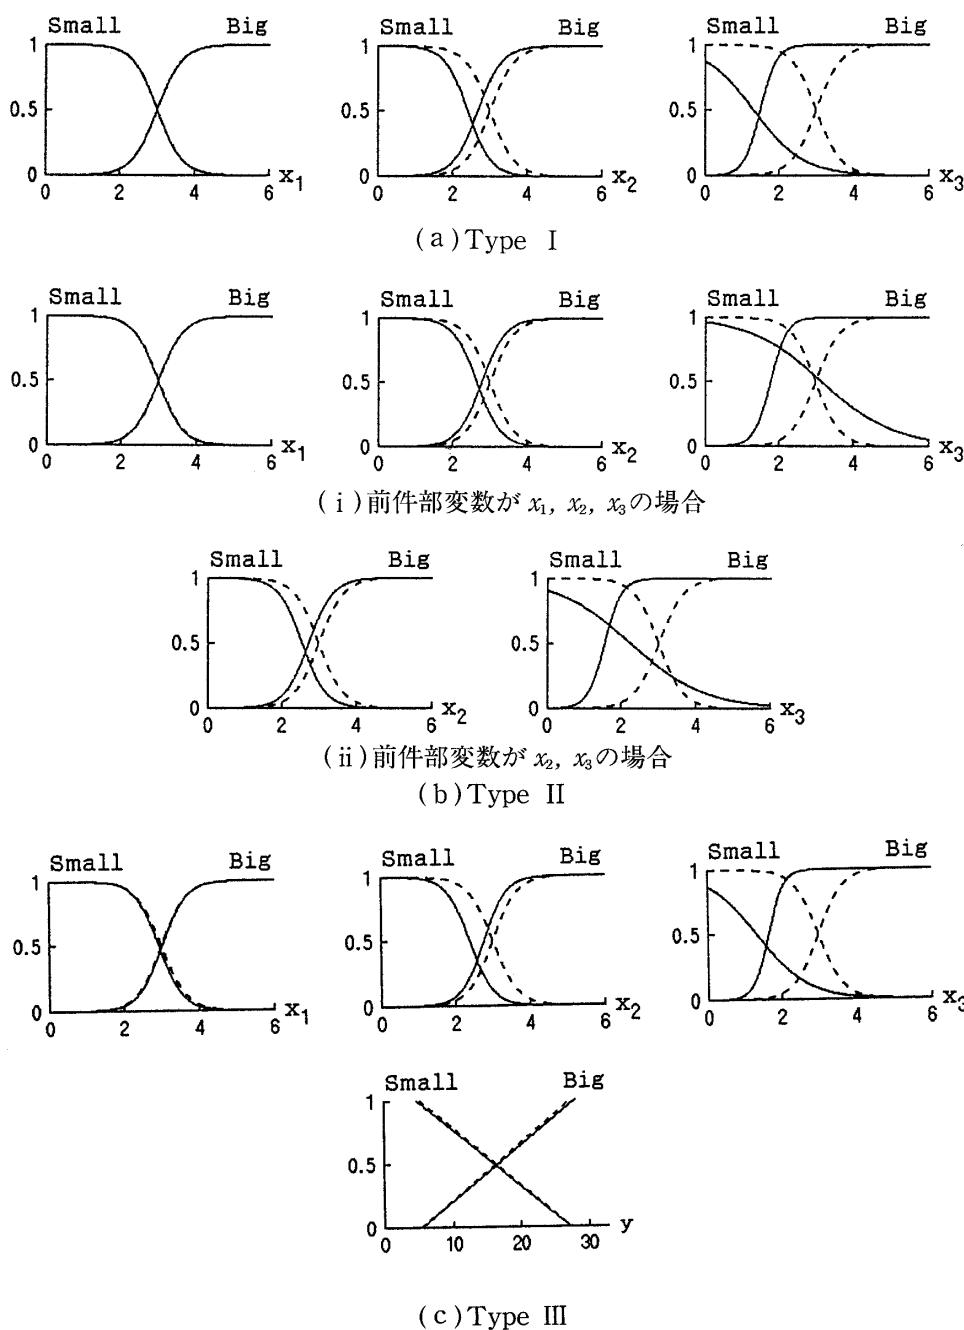


図9 ファジイモデルにおけるメンバーシップ関数

線近似できるような非線形性を持っている。そして、 $x^{-1=3.5}$ の接続点が x^{-1} のそれより左に来る。本FNNの x_2, x_3 に対する前件部メンバーシップ関数は、学習前後でSmallとBigの交点がすべてその範囲内に移動しており、本FNNでは、メンバーシップ関数が対象システムの特性に合わせて適切に調整されていることがわかる。

表4は、本FNNにより同定されたファジィルールを示す。表4(c)のType IIIの後件部における $\tau_{R_S^i}, \tau_{R_B^i}$ は、それぞれ後件部ファジィ変数がSmallまたはBigであるファジィルールのLTVを意味する。本FNNでは、それぞれの推論法の特徴がよく表れたファジィルールが同定されている。Type Iのファジィルールは、あいまいさには欠けるが比較的その把握が容易であり、Type IIでは、記述能力が高い代わりにファジィルールの評価がやや難しくなっている。Type IIIによるファジィルールは特に興味深く、“If x_1 is Small and x_2 is Big and x_3 is Big then y is Small”と“If x_1 is Big and x_2 is Small and x_3 is Small then y is Big”とが「完全に真」($\tau_{R_k^i}=1$)であるといった言語的なモデルが同定されている。このType IIIで「完全に真」となるファジィルールは、(49)式の持つ入力 x_1 に対する単調増加性および x_2, x_3 に対する単調減少性を表す。Type Iの後件部定数にも同様の傾向が見られ、Type IIにおいても定数項にこの傾向がある。このように、本FNNの同定したファジィルールでは、対象システムの入出力関係が正確に表現されている。一方、Type IIIの推論値を(24)式の重心法によらず

$$y^* = \sum_{k=1}^2 \mu'_k B^{-1}(\mu'_k) \quad (52)$$

のように後件部適合度 μ'_k と後件部メンバーシップ関数の逆関数値 $B^{-1}(\mu'_k)$ の積和で求めた場合、“ x_1 is Small and x_2 is Big and x_3 is Big”的前件部命題を持つファジィルールのLTVは $\tau_{R_S^i}=0.24, \tau_{R_B^i}=0.05$ と同定される^[17]。その結果、同一の前件部命題に対する二つのファジィルールはともにほぼ偽となってしまうため、(52)式による推

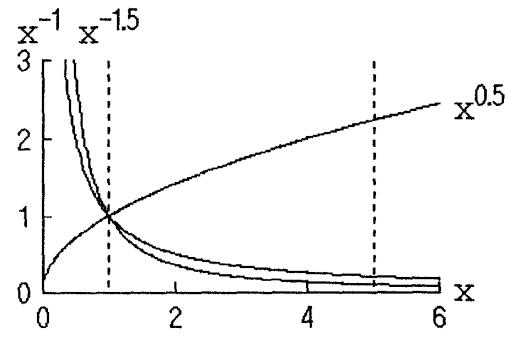
図10 $x^{0.5}, x^{-1}, x^{-1.5}$ の変化

表4 同定されたファジィモデル

(a) Type I

前件部			後件部
x_1	x_2	x_3	f_i
Small	Small	Small	18.0
Small	Small	Big	9.6
Small	Big	Small	10.8
Small	Big	Big	5.3
Big	Small	Small	28.8
Big	Small	Big	18.9
Big	Big	Small	20.8
Big	Big	Big	12.6

(b) Type II

(i) 前件部変数が x_1, x_2, x_3 の場合

前件部			後件部
x_1	x_2	x_3	$f_i(x_1, x_2, x_3)$
Small	Small	Small	$12.7 + 0.26x_1 + 0.61x_2 + 0.36x_3$
Small	Small	Big	$6.2 + 0.13x_1 - 0.07x_2 + 0.49x_3$
Small	Big	Small	$9.8 + 0.20x_1 + 0.08x_2 - 0.27x_3$
Small	Big	Big	$-0.5 - 0.01x_1 + 0.48x_2 + 0.57x_3$
Big	Small	Small	$18.4 + 1.84x_1 + 0.36x_2 - 0.01x_3$
Big	Small	Big	$7.7 + 0.77x_1 + 0.15x_2 + 1.18x_3$
Big	Big	Small	$10.0 + 1.00x_1 + 1.07x_2 - 0.31x_3$
Big	Big	Big	$3.4 + 0.34x_1 + 0.41x_2 + 0.90x_3$

(ii) 前件部変数が x_2, x_3 の場合

前件部		後件部
x_2	x_3	$f_i(x_1, x_2, x_3)$
Small	Small	$16.6 + 2.48x_1 + 0.28x_2 - 0.55x_3$
Small	Big	$3.3 + 2.33x_1 - 0.02x_2 + 0.75x_3$
Big	Small	$6.2 + 2.38x_1 + 0.69x_2 - 0.97x_3$
Big	Big	$1.0 + 1.73x_1 + 0.21x_2 + 0.30x_3$

(c) Type III

前件部			後件部	
x_1	x_2	x_3	$\tau_{R_S^i}$	$\tau_{R_B^i}$
Small	Small	Small	0.48	0.45
Small	Small	Big	0.77	0.08
Small	Big	Small	0.76	0.26
Small	Big	Big	1.00	0.14
Big	Small	Small	0.00	1.00
Big	Small	Big	0.33	0.58
Big	Big	Small	0.38	0.69
Big	Big	Big	0.66	0.34

論値計算では対象システムの特性を正しく表すことができず、ネットワークの入出力関係についても表現が不適切なものとなる。

以上の数値例における本FNNのネットワークの規模と学習に要した計算時間を表5に示す。ただし、表中のノード数(全結合荷重数)およびユニット数は2章の構成例に従って算出している。また、結合荷重のうち学習時に更新するものの個数を結合荷重数として併せて示している。この計算には、CPU 80286(16 MHz)+数値演算プロセッサ 80287(10 MHz)を搭載したパーソナルコンピュータを用いた。一般に、本FNNのノード数 n_N 、ユニット数 n_U および学習時に変化する結合荷重数 n_W は、

前件部：

$$n_N = \sum_{j=1}^{n_{in}} (8 m_j - 8) + n_{in} n_R \quad (53)$$

$$n_U = \sum_{j=1}^{n_{in}} (5 m_j - 2) + n_R \quad (54)$$

$$n_W = \sum_{j=1}^{n_{in}} (4 m_j - 4) \quad (55)$$

Type I の後件部：

$$n_N = n_{out} n_R \quad (56)$$

$$n_U = n_{out} \quad (57)$$

$$n_W = n_{out} n_R \quad (58)$$

Type II の後件部：

$$n_N = n_{out} \{ n'_{in} + 3 n_R (n'_{in} + 2) \} \quad (59)$$

$$n_U = n_{out} \{ 2 n'_{in} + 2 n_R (n'_{in} + 2) + 2 \} \quad (60)$$

$$n_W = n_{out} n_R (n'_{in} + 1) \quad (61)$$

Type IIIの後件部：

$$n_N = n_{out} (2 n_R + 12) \quad (62)$$

$$n_U = 10 n_{out} \quad (63)$$

$$n_W = n_{out} (2 n_R + 4) \quad (64)$$

によりそれぞれ求められる。ここで、 n_{in} は前件部の入力数、 n'_{in} はType IIの後件部の入力数、 n_{out} は出力数、 m_j は入力 x_j に対する前件部メンバーシップ関数の種類数、 n_R はルール数である。上式では、前件部の構成として n_R が(12)式で定義されるものを考え、Type IIにおける後件部の構成はすべての出力に共通であると仮定している。本FNNは、ファジィ推論をNNの構造で実現するために結合荷重の固定されたノードや入力を出力に分配するだけのユニットが多数存在し、 n_N 、 n_U に比べて n_W は小さな値となっている。例えば、Type IIは前件部5層、後件部7層の合計12層のネットワークからなるが、 n_W のみに着目すると、表5のType II(i)の構成は中間層のユニット数が11の3層BPモデルと同じであり、実質的なネットワークの規模はそれほど大きくなっている。実際、表5によれば、本FNNの計算時間は主に n_W の値に依存し、前件部と後件部の n_W にそれぞれ4:1の割合でおおよそ比例している。これは、(C)層の前件部メンバーシップ関数を構成する各シグモイド関数の計算に最も時間がかかる事によるものであり、(55)式より計算時間が前件部メンバーシップ関数の種類数 m_j の総和ではなく決定されると解釈できる。しかし、計算時間には、学習データ数や学習回数も大きく関係する。従って、本FNNによるファジィモデリングに必

表5 ネットワークの規模と計算時間

構成	ネットワークの規模									計算時間	
	ノード数			ユニット数			結合荷重数				
	前件部	後件部	合計	前件部	後件部	合計	前件部	後件部	合計		
Type I	48	8	56	32	1	33	12	8	20	10分30秒	
Type II (i)	48	123	171	32	88	120	12	32	44	14分31秒	
(ii)	24	63	87	20	48	68	8	16	24	7分17秒	
Type III	48	28	76	32	10	42	12	20	32	14分29秒	

要な計算時間は、入出力数と各入力に対する前件部メンバーシップ関数の種類数および学習データ数、学習回数で定められる。本FNNのようなネットワークは、各結合荷重に明確な意味が与えられているため、学習による出力誤差の収束速度が通常の3層BPモデルに比べて速いという報告もあり^[11]、大規模な問題においても十分実用的であると思われる。

5. まとめ

本論文では、NNの学習機能によって通常困難とされるファジィルールの同定およびメンバーシップ関数の調整を自動的に行うことができるFNNの新しい構成法を提案した。また、学習時の各結合荷重に対する学習率設定についてその煩雑さを低減する手法を述べ、本FNNの有用性を簡単な数値例に基づくファジィモデリングにより示した。

本FNNの前件部メンバーシップ関数は、学習において優れた特徴を持ちBP法により適切な構成となるよう調整される。また、ネットワークをファジィモデルの構造に対し柔軟に構成することができる。本FNNでは、重心法の導入によりネットワークの入出力関係や対象システムの特性を正確に表したファジィルールの同定を実現している。Type I, II, IIIのFNNはそれぞれ異なるファジィ推論に基づくことから、同一のシステムに対しそれぞれ特徴あるファジィモデルを同定可能である。

参考文献

- [1] 廣田, 他: ファジィシステム, 計測自動制御学会編, 1990
- [2] D.E.Rumelhart, J.L.McClelland and the PDP Research Group: Parallel Distributed Processing, The MIT Press, 1986
- [3] 寺野, 他: 実用ファジィ制御技術, 電子情報通信学会編, 1991
- [4] 林, 野村, 若見: “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] 山口, 今崎, 春木: “連想記憶によるファジィルールの推論・学習方式”, 電気学会論文誌C, Vol. 110-C, No.3, pp.207-215, 1990
- [6] 市橋, 渡辺: “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
- [7] 荒木, 野村, 林, 若見: “ファジィ推論ルールの自動生成手法の提案と移動ロボットの障害物回避ルールの獲得”, 第7回ファジィシステムシンポジウム講演論文集, pp.623-626, 1991
- [8] 野村, 林, 若見: “最急降下法によるファジィ推論の自動チューニングと障害物回避への応用”, 第6回ファジィシステムシンポジウム講演論文集, pp.423-426, 1990
- [9] 渡辺, 市橋: “逆キネマティクス-逆ダイナミクスモデルを学習するマニピュレータのファジィ制御 -C¹級のファジィモデリング-”, 第6回ファジィシステムシンポジウム講演論文集, pp.535-538, 1990
- [10] 渡辺, 市橋: “n次メンバーシップ関数を用いた逐次ファジィモデリングとそのクレーン制御への応用”, 日本ファジィ学会誌, Vol.3, No.2, pp.347-356, 1991
- [11] 市橋: “C[∞]級の階層型ファジィモデル”, 第7回ファジィシステムシンポジウム講演論文集, pp.505-508, 1991
- [12] 市橋, 田中: “PIDとFUZZYのハイブリッド型コントローラー”, 第4回ファジィシステムシンポジウム講演論文集, pp.97-102, 1988
- [13] 姜, 菅野: “ファジィモデリング”, 計測自動制御学会論文集, Vol.23, No.6, pp.106-108, 1987
- [14] 下川: “ファジィニューラルネットワークの一手法”, 電子情報通信学会技術研究報告, Vol.90, No.483, pp.83-88, 1991
- [15] 菅野: ファジィ制御, 日刊工業新聞社, 1988
- [16] 堀川, 古橋, 大熊, 内川: “ニューラルネットワークによる学習型ファジィ制御器”, 計測自動制御学会論文集, Vol.27, No.2, pp.208-215, 1991
- [17] 堀川, 古橋, 大熊, 内川: “ファジィニューラルネットワークの構成法とその性能評価”, 第6回ファジィシステムシンポジウム講演論文集, pp.57-62, 1990

- [18] S.Horikawa, T.Furuhashi, S.Okuma and Y.Uchikawa : "Composition Methods of Fuzzy Neural Networks", Proc. of IEEE/IECON '90, pp.1253-1258, 1990
- [19] 堀川, 古橋, 内川 : "ファジィニューラルネットワークの構成法(II)", 第8回日本ロボット学会学術講演会予稿集, pp.521-523, 1990
- [20] 堀川, 古橋, 内川 : "ファジィニューラルネットワークの構成法(III)", 第7回ファジィシステムシンポジウム講演論文集, pp.493-496, 1991

(1991年12月6日 受付)
(1992年5月1日 再受付)

[問い合わせ先]

〒464-01 名古屋市千種区不老町
名古屋大学工学部電子機械工学科
内川研究室
堀川 慎一
TEL: 052-781-5111(内線)2792
FAX: 052-781-9263
E-mail: horikawa@uchikawa.nuem.nagoya-u.ac.jp

著者紹介



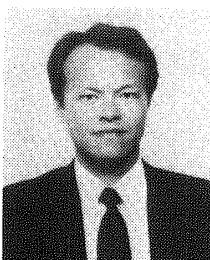
堀川 慎一 (ほりかわ しんいち)

名古屋大学大学院 工学研究科博士課程後期課程電気工学、電気工学第二及び電子工学専攻
平成2年3月 名古屋大学工学部卒業。平成4年3月 同大学大学院工学研究科博士課程前期課程修了。現在、同後期課程在学中。ファジィニューラルネットワークとその制御への応用に関する研究に従事。日本ファジィ学会、電気学会の会員。



内川 嘉樹 (うちかわ よしき)

名古屋大学 工学部電子機械工学科
昭和44年 名古屋大学大学院博士課程満了。同年、同大学工学部助手、昭和53年 同助教授を経て昭和60年同教授、現在に至る。工学博士。主として、電子工学および、電子銃の計算機援用設計、SEMによる半導体デバイス診断の研究に従事。昭和61年日本電子顕微鏡学会論文賞受賞。現在は、ニューラルネットワーク、ファジィ理論、遺伝アルゴリズムなどを利用したシステム技術の基礎および産業への応用に関する研究を行っている。日本ファジィ学会、日本電子顕微鏡学会、日本ロボット学会、精密工学会、計測自動制御学会、情報処理学会、日本AEM学会の会員、応用物理学会東海支部長。



古橋 武 (ふるはし たけし)

名古屋大学 工学部電子機械工学科
昭和60年3月 名古屋大学大学院博士課程修了。同年4月 (株)東芝入社。府中工場においてGTO PWMインバータの研究・開発に従事。昭和63年4月から名古屋大学工学部助手、平成2年12月同助教授、現在に至る。工学博士。主として、制御システム・エキスペートシステムにおける知識獲得技術の確立を目指して、ファジィニューラルネットワークによる知識獲得、ファジィ推論による知識獲得に関する研究に従事。日本ファジィ学会、電気学会、計測自動制御学会、人工知能学会、日本AEM学会、IEEEの会員。