


報告番号 甲第 2974 号

ファジィニューラルネットワークの構成法と
その応用に関する研究

堀川 慎一



①

目次
ファジィニューラルネットワークの構成法と
その応用に関する研究

堀川 慎一

目次

1 緒言	1
1.1 本研究の背景	1
1.1.1 ファジィ推論	3
1.1.1.1 直接法	3
1.1.1.2 間接法	11
1.1.1.3 直接法と間接法の関係	18
1.1.2 ニューラルネットワーク	19
1.1.3 ファジィニューラルネットワーク	21
1.2 本研究の目的	25
1.3 本論文の構成	28
2 ファジィニューラルネットワークの構成法	31
2.1 はじめに	31
2.2 ファジィニューラルネットワークの前件部	32
2.2.1 前件部メンバーシップ関数	32
2.2.2 前件部適合度	38
2.3 直接法に基づくファジィニューラルネットワーク	44
2.3.1 後件部が定数で表される ファジィニューラルネットワーク (Type I)	44
2.3.2 後件部が一次式で表される ファジィニューラルネットワーク (Type II)	47
2.4 間接法に基づくファジィニューラルネットワーク	51

2.4.1	後件部がファジイ変数で表される ファジイニューラルネットワーク (Type III)	51
2.4.2	後件部ファジイ変数を単純化した ファジイニューラルネットワーク (Type IV)	55
2.4.3	言語的真理値をファジイ集合とした ファジイニューラルネットワーク (Type V)	58
2.4.4	ファジイルールの言語的表記	61
2.5	まとめ	66
3	ファジイニューラルネットワークの学習法	67
3.1	はじめに	67
3.2	バックプロパゲーション法	67
3.3	学習率の設定	71
3.4	ネットワークの規模と実現可能性	73
3.5	まとめ	75
4	ファジイ制御への応用	77
4.1	はじめに	77
4.2	むだ時間を持つ一次遅れ系のファジイ制御	77
4.3	ファジイニューラルネットワークによるファジイ制御器の構成	81
4.4	まとめ	93
5	ファジイモデリングへの応用	95
5.1	はじめに	95
5.2	ファジイニューラルネットワークを用いたファジイモデリング	95
5.3	数値例	98
5.4	まとめ	113
6	結言	115
6.1	本研究の成果	115
6.2	今後の課題	116
	謝辞	119

参考文献	121
研究業績	127

第1章

緒言

1.1 本研究の背景

近年、産業システムにおいては、エレクトロニクス技術の進歩に伴い制御の自動化が急速に進められている。しかし、その一方で、未だ熟練オペレータの経験や勘に頼らざるを得ないシステムも少なからず存在する。人間は、多種多様な情報を包括的に処理する能力においてコンピュータより優れ、制御対象のパラメータ変動等に対してもそれらを逐次学習することで柔軟に対処することができる。特に熟練オペレータは、現在のセンサでは計測不可能なシステムの状態をも考慮した制御を経験に基づいて行うことができる。しかし、人間による手動操作は、基本的に不確定要素が多く制御結果にばらつきを生じやすいという欠点を持つ。また、オペレータの育成には一般に長い時間と膨大なコストが必要であり、その確保は必ずしも容易ではない。従って、安定した操業を行うためには制御の自動化を極力推し進めることが望ましいが、従来の古典制御理論や現代制御理論はモデル化の難しい複雑な非線形システムへの適用が困難であった。

この問題に対する有効な一手法として、ファジィ制御^[1]が提案されている。ファジィ制御は、ファジィ推論^[2]を制御分野に応用したものであり、ファジィ理論の有用性を示す上で大きな役割を果たした。ファジィ理論は、1965年にZadehが発表したファジィ集合の論文^[3]を始まりとする。ファジィ理論の基本概念は、主観におけるあいまいさを積極的に取り込むという点にあるが、自然科学では一般に客観性が重んじられることから、Zadehがファジィ集合を提案した当初は学会からなかなか受け入れられなかつ

た。しかし、1974年のMamdaniによるスチームエンジンを制御対象としたファジィ制御の実験^[4]以後、ファジィ理論の有効性が広く認められるようになり、特に日本ではファジィ制御に関する研究がブームと呼ばれるほど盛んに行われてきた。ファジィ制御は、これまでの制御理論にはない並列(分散)型制御・論理型制御・言語的制御等の特徴を有し^[1]、人間の持つあいまいな制御アルゴリズムを言語的表現のままに取り扱うことができる。すなわち、ファジィ制御によれば、従来の制御理論のように制御対象の数式モデルを構築する必要がなく、熟練オペレータが経験的に獲得したノウハウを基に制御器を設計することが可能である。そのため、熟練オペレータに頼らざる得なかった複雑な非線形システムの制御を自動化できると期待され、現在では大規模プラントから家電製品まで幅広く実用化が進められている。しかし、人間が体得した制御アルゴリズムは常に明確な表現を伴うわけではなく、極めて漠然としていることが少なくない。また、場合によっては無意識に行われるものであったりする。このような制御アルゴリズムを正確に把握することは非常に困難であり、熟練オペレータへの聞き取り調査やその後の試行錯誤には多大な労力が必要となる。さらに、ファジィ制御器における具体的なパラメータ決定は、制御対象に関する的確な洞察がなければうまくできず、ファジィ制御に対する専門的な知識が不可欠とされる。

一方、人間の知識を扱うのに適したもう一つの手法にニューラルネットワーク(Neural Network: NN)^[5]がある。NNは、人間の脳における神経細胞の仕組みを模擬した数理モデルであり、その最も基本的なものとしては1958年にRosenblattが提案したパーセプトロン^[6]が挙げられる。パーセプトロンは、コンピュータに学習機能を持たせられることを初めて示した点では評価されたが、その適用範囲が線形分離可能な問題に限られていたため、NNに関する研究はそれ以後冬の時代を迎えた。しかし、1986年にパーセプトロンの学習則を多層ネットワークに拡張したバックプロパゲーション(Back-Propagation: BP)法がRumelhartらによって提案され^[5]、NNの能力が飛躍的に向上したことから再び広く研究が行われるようになった。NNは、計算方式においてノイマン型コンピュータと根本原理を異にする並列処理・分散記憶と呼ばれる性質を持ち、学習機能により任意の非線形な入出力関係を自動的に同定できることを特徴とする。NNの制御分野への応用ではこの特徴を活かして、制御対象の入出力データから同定したその順システムおよび逆システムにより制御系を構成することがよく行われている。また、NNに熟練オペレータの操作パターンを学習させれば、オペレータの持つ制御アルゴリズムを容易に得ることができる。しかし、NNにより獲得された知識はネットワー

ク内に分散して記憶されるため、これを明確に表現することは極めて難しい。

以上のように、ファジィ制御(推論)とNNは、ともに人間の脳における情報処理メカニズムに倣った本質的に非線形で並列・分散型のシステム構造を持つだけでなく、歴史的な側面においても共通する部分が多い。また、それぞれの長所および短所は、ほぼ双対な関係をなしている。このようなファジィ推論とNNを融合することにより、新たな知的情報処理システムの構築を目指したものがファジィニューラルネットワーク(Fuzzy Neural Network: FNN)^[7]である。ただし、FNNは一般にファジィ推論とNNを同時に扱うシステムを意味し、それらの組み合わせ方には様々な手法が提案されている。

ここでは本研究の背景として、まず、ファジィ制御の基本となるファジィ推論の詳細を説明し、その後、NNの概要とこれまでに提案されたFNNの分類について述べる。

1.1.1 ファジィ推論

ファジィ推論は、If-then形式で表されるファジィルールを基に、与えられた事実から結論を導く手法である。これをシステムとして見た場合、それぞれ事実が入力、結論が出力に相当する。ファジィ推論の具体的な計算方法には、大きく分けて直接法と間接法の二つがあり、互いに異なった推論過程を示す。以下、ファジィ推論の直接法と間接法を解説し、両者の関係について考察する。

1.1.1.1 直接法

ファジィ推論の直接法は、ファジィ理論の提唱者であるZadeh^[8]により提案されたものであり、次のような推論を対象とする。

$$\begin{array}{lcl} \text{ファジィルール} & : & \text{If } x \text{ is } A \text{ then } y \text{ is } B \\ \text{事実(入力)} & : & x \text{ is } A' \\ \hline \text{結論(出力)} & : & y \text{ is } B' \end{array} \quad (1.1)$$

ここで、ファジィルールにおけるIfの部分の前件部、then-の部分の後件部と呼び、“ x is A ”を前件部命題、“ y is B ”を後件部命題と呼ぶ。また、 x は入力変数、 y は出力変数であり、 A 、 B 、 A' 、 B' はSmallやBig等の言語ラベルが付いたファジィ集合により定義されることからファジィ変数と呼ばれる。なお、 x 、 y はそれぞれ前件部変数、後件部変数とも表される。

ファジィ集合は、言葉の持つ主観的なあいまいさを定量的に取り扱うための集合概念である。例えば、「身長」について「高い」、「中位」、「低い」という三つの言葉を考える。従来の集合論では、これらの意味を

$$\left. \begin{aligned} \text{Tall} &= \{h|h \geq 180\text{cm}\} \\ \text{Middle} &= \{h|160\text{cm} \leq h < 180\text{cm}\} \\ \text{Short} &= \{h|h < 160\text{cm}\} \end{aligned} \right\} \quad (1.2)$$

のように定義する。ここで、 h は身長(cm)を表し、Tall, Middle, Shortはそれぞれ「高い」、「中位」、「低い」に相当する集合である。このような集合はクリस्प集合と呼ばれ、次のような $\{0,1\}$ の離散値をとる特性関数によっても表現することができる。


$$\chi_{\text{Tall}}(h) = \begin{cases} 1, & h \in \text{Tall} \\ 0, & h \notin \text{Tall} \end{cases} \quad (1.3)$$

ただし、 $\chi_{\text{Tall}}(h)$ は(1.2)式における集合Tallの特性関数であり、MiddleやShortについても同様に表すことができる。一方、ファジィ集合では、それぞれの言葉の意味が


$$\left. \begin{aligned} \text{Tall}(h) &= \min[\max\{0.1(h-170), 0\}, 1] \\ \text{Middle}(h) &= \max\{-0.1|h-170|+1, 0\} \\ \text{Short}(h) &= \min[\max\{0.1(170-h), 0\}, 1] \end{aligned} \right\} \quad (1.4)$$

のような区間 $[0,1]$ の連続値をとるメンバーシップ関数によって定義される。このメンバーシップ関数の値はグレードと呼ばれ、(1.4)式の場合要素 h が各ファジィ集合に属する度合を表す。また、ファジィ集合の定義域(全体集合)は台集合と呼ばれる。なお、本論文では、ファジィ集合 P のメンバーシップ関数を $P(z)$ のように表記し、 P は言語ラベルを表すものとする。ただし、 z は P の台集合に含まれる要素である。

図1.1は、(1.2)、(1.4)式における各集合の特性関数またはメンバーシップ関数を示す。(a)が(1.2)式のクリस्प集合、(b)が(1.4)式ファジィ集合である。クリस्प集合は、各集合間にはっきりした境界が存在するのに対し、ファジィ集合は、隣り合う集合同士が互いに重なり合い明確な境界を持たない。図1.1(a)のクリस्प集合では、身長180cmが $\chi_{\text{Tall}}(180)=1$ より「高い」、179.9cmが $\chi_{\text{Tall}}(179.9)=0$ より「高くない」と厳密に区別されるが、(b)のファジィ集合では、 $\text{Tall}(180)=1$ 、 $\text{Tall}(179.9)=0.99$ とほぼ同等に取り扱われる。両者の差はわずか0.1cmであり、我々の感覚にはファジィ集合の方が適しているように思われる。従って、このようなファジィ集合表現を用いて(1.1)式の推論を行えば、人間の直感によく合った形で妥当な結果を得ることができると期待される。また、ファジィ集合は、クリस्प集合とは異なり主観的に定義されるとこ



(a) クリस्प集合



(b) ファジィ集合

図 1.1: クリस्प集合とファジィ集合




図 1.2: ファジィ集合の和集合と積集合

ろに特徴がある。そのため、図1.1(b)のメンバーシップ関数などは、評価する人の価値観によって違った形状を示すのが普通である。

図1.1からわかるように、ファジィ集合のメンバーシップ関数はクリस्प集合の特性関数を拡張したものと考えることができる。クリस्प集合では様々な集合演算が定義されているが、それらは一部を除いてファジィ集合でも成立する^[9]。その代表的なものとして和集合と積集合を取り上げると、ファジィ集合 $P(z)$, $Q(z)$ の和集合 $P \cup Q$ および積集合 $P \cap Q$ はそれぞれ次のように求められる。

$$(P \cup Q)(z) = \max\{P(z), Q(z)\} \quad (1.5)$$

$$(P \cap Q)(z) = \min\{P(z), Q(z)\} \quad (1.6)$$

ここで、 $(P \cup Q)(z)$, $(P \cap Q)(z)$ はそれぞれ $P \cup Q$, $P \cap Q$ のメンバーシップ関数である。上式は、クリस्प集合の場合を含んだものとなっている。図1.2は、(1.5), (1.6) 式の集合演算を示す。図中の点線が和集合 $P \cup Q$ または積集合 $P \cap Q$ のメンバーシップ関数を表しており、 P と Q の二つのメンバーシップ関数を比較して大きい方をなぞれば和集合、小さい方をなぞれば積集合が得られる。なお、ファジィ集合における和集合および積集合の演算は、一般にそれぞれ t -conorm (s -norm), t -norm^[10]により定義され、これらはファジィ論理の or 演算、 and 演算にも対応する。

(1.1) 式の推論は、以上のようなファジィ集合およびその集合演算を用いて行われる。ファジィ推論の直接法では、まず、ファジィルールにおける前件部と後件部の含意関係をファジィ関係により解釈する。ファジィ関係とは、ファジィ集合を用いて「ほぼ等しい」とか「とても大きい」といったあいまいな関係を表現したものである。ファジィルールの含意関係に対するファジィ関係にはこれまでに様々な定義が提案されており、それぞれが持つ特性について詳しい考察が行われている^[11]。それらのうち、ファジィ制御等でよく用いられるのは

$$R = A \times B \quad (1.7)$$

のような直積集合である。ここで、 R は (1.1) 式のファジィルールに相当するファジィ関係を表す。直積集合は基本的に積集合であることから、(1.7) 式は (1.6) 式より

$$R(x, y) = \min\{A(x), B(y)\} \quad (1.8)$$

と計算される。ただし、直積集合は入力変数(命題の主語)の異なるファジィ集合間で定義されるため、そのメンバーシップ関数は $R(x, y)$ のように多次元となる。このファ

ジィ関係 R により、結論 B' は与えられた事実 A' から次のように求められる。

$$B' = A' \circ R \quad (1.9)$$

上式は推論の合成規則と呼ばれ、記号 \circ は合成演算を表す。具体的には、

$$B'(y) = \max_x \{A'(x) \otimes R(x, y)\} \quad (1.10)$$

のような計算を意味する。ここで、記号 \otimes は t -norm を表し、(1.8) 式と同様に (1.6) 式の \min 演算を用いると、(1.1) 式の結論 B' は

$$\begin{aligned} B'(y) &= \max_x [\min\{A'(x), R(x, y)\}] \\ &= \max_x [\min\{A'(x), A(x), B(y)\}] \end{aligned} \quad (1.11)$$

と求められることになる。

また、次のようにファジィルールの前件部が複数の命題を持つ場合には、あらかじめそれらを一つにまとめておく必要がある。

$$\begin{array}{l} \text{ファジィルール} : \text{If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } A_2 \text{ and } \dots \text{ and } x_{n_{in}} \text{ is } A_{n_{in}} \\ \quad \quad \quad \text{then } y \text{ is } B \\ \hline \text{事実(入力)} : x_1 \text{ is } A'_1 \text{ and } x_2 \text{ is } A'_2 \text{ and } \dots \text{ and } x_{n_{in}} \text{ is } A'_{n_{in}} \\ \hline \text{結論(出力)} : y \text{ is } B' \end{array} \quad (1.12)$$

ここで、 x_j ($j=1, 2, \dots, n_{in}$) は j 番目の入力変数を表し、 n_{in} は入力数、 A_j , A'_j はそれぞれ x_j に対する前件部ファジィ変数、および与えられた事実である。(1.12) 式のファジィルールでは、前件部の各命題が and で結合されている。従って、この場合には、(1.7) 式のファジィ関係における A を前件部ファジィ変数の直積集合として (1.6) 式より

$$A(x_1, x_2, \dots, x_{n_{in}}) = \min\{A_1(x_1), A_2(x_2), \dots, A_{n_{in}}(x_{n_{in}})\} \quad (1.13)$$

のように求めればよい。これは、(1.9) 式の推論の合成規則における A' についても同様である。ゆえに、(1.12) 式の結論 B' は、(1.9), (1.7) 式により

$$\begin{aligned} B'(y) &= \max_{(x_1, \dots, x_{n_{in}})} [\min\{A'(x_1, \dots, x_{n_{in}}), R(x_1, \dots, x_{n_{in}}, y)\}] \\ &= \max_{(x_1, \dots, x_{n_{in}})} [\min\{A'(x_1, \dots, x_{n_{in}}), A(x_1, \dots, x_{n_{in}}), B(y)\}] \\ &= \max_{(x_1, \dots, x_{n_{in}})} [\min\{A'_1(x_1), \dots, A'_{n_{in}}(x_{n_{in}}), A_1(x_1), \dots, A_{n_{in}}(x_{n_{in}}), B(y)\}] \end{aligned} \quad (1.14)$$

と計算される。

さて、ファジィ制御等では、一般に入出力値がファジィ値ではなく確定値で表される。また、ファジィルールも一つだけに限らず複数個用いられる。そこで、簡単のために次のような2入力1出力の場合における推論を考える。

$$\begin{array}{l}
 \text{ファジィルール } R^1 : \text{ If } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{12} \text{ then } y \text{ is } B_1 \\
 \text{ファジィルール } R^2 : \text{ If } x_1 \text{ is } A_{21} \text{ and } x_2 \text{ is } A_{22} \text{ then } y \text{ is } B_2 \\
 \vdots \\
 \text{ファジィルール } R^{n_R} : \text{ If } x_1 \text{ is } A_{n_R1} \text{ and } x_2 \text{ is } A_{n_R2} \text{ then } y \text{ is } B_{n_R} \\
 \hline
 \text{事実(入力)} : x_1 = x_1^0 \text{ and } x_2 = x_2^0 \\
 \text{結論(出力)} : y = y^*
 \end{array} \quad (1.15)$$

ここで、 R^i ($i=1, 2, \dots, n_R$) は i 番目のファジィルールを表し、 n_R はルール数、 A_{ij} ($j=1, 2$)、 B_i はそれぞれ R^i における前件部ファジィ変数および後件部ファジィ変数である。また、 x_j^0 、 y^* は確定値で表される入出力値に相当する。(1.15) 式にて与えられている事実は、(1.12) 式において A_j^* が

$$A_j^*(x_j) = \begin{cases} 1, & x_j = x_j^0 \\ 0, & x_j \neq x_j^0 \end{cases} \quad (1.16)$$

のように表されているのと等価である。このようなファジィ集合は、特にシングルトンと呼ばれる。従って、ファジィルール R^i のみによる結論を B_i^* とすると、 B_i^* は(1.14) 式より

$$\begin{aligned}
 B_i^*(y) &= \max_{(x_1, x_2)} [\min\{A_1^*(x_1), A_2^*(x_2), A_{i1}(x_1), A_{i2}(x_2), B_i(y)\}] \\
 &= \min\{A_{i1}(x_1^0), A_{i2}(x_2^0), B_i(y)\}
 \end{aligned} \quad (1.17)$$

と求められる。ここで、

$$\mu_i = \min\{A_{i1}(x_1^0), A_{i2}(x_2^0)\} \quad (1.18)$$

とおくと、(1.17) 式は

$$B_i^*(y) = \min\{\mu_i, B_i(y)\} \quad (1.19)$$

のように表される。(1.18) 式の μ_i は R^i の前件部適合度と呼ばれ、与えられた事実に対して i 番目のファジィルールを適用すべき度合と考えることができる。(1.15) 式の推論では各ファジィルールが or で結合されていると解釈できることから、(1.5) 式よりファジィルール全体による結論 B' は

$$B'(y) = \max\{B_1^*(y), B_2^*(y), \dots, B_{n_R}^*(y)\} \quad (1.20)$$

のように各ファジィルールの結論 $B_i^*(y)$ を max 演算で統合したものとなる。確定値で表される最終的な推論値 y^* は、この $B'(y)$ から次のように計算される。

$$y^* = \frac{\int B'(y)y dy}{\int B'(y) dy} \quad (1.21)$$

上式は、メンバーシップ関数 $B'(y)$ の重心に相当し、台集合の要素 y の $B'(y)$ による重み付き平均とも見ることができる。一般にファジィ集合を確定値に変換することを非ファジィ化と呼ぶが、(1.21) 式の重心法の他にも様々な方法がある^[7]。ただし、ファジィ制御では、重心法による非ファジィ化が最も良い制御性能を示すことが経験的によく知られている。

図 1.3(a) は、ルール数 $n_R=2$ の場合における (1.15) 式の推論プロセスを示す。この推論では、まず、与えられた入力値 x_1^0 、 x_2^0 に対し前件部メンバーシップ関数のグレード $A_{i1}(x_1^0)$ 、 $A_{i2}(x_2^0)$ ($i=1, 2$) が求められる。次に、各ファジィルールにおいて $A_{i1}(x_1^0)$ と $A_{i2}(x_2^0)$ の小さい方が前件部適合度 μ_i となり、 μ_i の値で後件部メンバーシップ関数 $B_i(y)$ を頭切りしたものがそのファジィルールの結論 $B_i^*(y)$ となる。これらを max 演算で統合することによりファジィルール全体による結論 B' が求められ、最終的な推論値 y^* は $B'(y)$ の重心として計算される。

図 1.3(a) の推論は、その計算過程によって「min-max-重心法」と呼ばれる^[12]。しかし、min 演算や max 演算は C^0 級の関数で滑らかさに欠けるため、推論結果が人間の直感に合わないことがある。そこで、min, max 演算の代わりにそれぞれ代数積および加算(代数和)を用いた「代数積-加算-重心法」が提案されている^[12]。この方法では、(1.15) 式におけるファジィルール R^i の前件部適合度 μ_i が


$$\mu_i = A_{i1}(x_1^0) \cdot A_{i2}(x_2^0) \quad (1.22)$$

のように前件部メンバーシップ関数値 $A_{i1}(x_1^0)$ と $A_{i2}(x_2^0)$ の代数積で求められ、 R^i の結論 B_i^* も


$$B_i^*(y) = \mu_i \cdot B_i(y) \quad (1.23)$$

により μ_i と後件部メンバーシップ関数 $B_i(y)$ の代数積で計算される。ファジィルール全体による結論 B' は、これらを

$$B'(y) = B_1^*(y) + B_2^*(y) + \dots + B_{n_R}^*(y) \quad (1.24)$$



(a) min-max-重心法



(b) 代数積-加算-重心法

図 1.3: ファジィ推論 (直接法)

のように足し合わせたものとなる。ただし、 $B'(y)$ の非ファジィ化による推論値 y^* の計算は、「min-max-重心法」と同様に (1.21) 式に従う。

図 1.3(b) は、(a) の「min-max-重心法」と同じくルール数 $n_R=2$ の場合における「代数積-加算-重心法」の推論プロセスを示す。図 1.3(b) では、各ファジィルールの結論 $B'_i(y)$ が後件部メンバーシップ関数 $B_i(y)$ を前件部適合度 μ_i の値に合わせて押し縮めた形となっている。「代数積-加算-重心法」では、ファジィルール全体による結論 $B'(y)$ が $B'_i(y)$ の代数和によって求められるため、 $B'(y)$ の最大グレードが 1 を上回りファジィ集合として適切でなくなることがある。これについては、適当な係数を掛け合わせるにより $B'(y)$ を規格化する方法もあるが、最終的な推論値 y^* が $B'(y)$ の重心として計算されることから実用上は特に問題となることはない。

ファジィ推論の直接法にはその他代表的なものとして、ファジィルールの後件部をシングルトン (定数) とした簡略化推論法^[13] や入力変数の一次式とした高木・菅野の推論法^[14] 等がある。これらについては、2.3 節にて説明する。

1.1.1.2 間接法

ファジィ推論の間接法は直接法と違い、Baldwin^[15]、塚本^[16]、水本^[17]により互いに異なる方法が提案されている。ここでは、本研究に深い関わりを持つ塚本の推論法を中心として解説を行う。

間接法で対象とするのは、次のような推論である。

ファジィルール	:	(If x is A then y is B) is τ_R	
事実 (入力)	:	x is A'	(1.25)
結論 (出力)	:	y is B'	

ここで、 τ_R はファジィルールの確かさを表す言語的真理値 (Linguistic Truth Value : LTV) である。

LTV は、区間 $[0, 1]$ の連続値で与えられる数値的真理値を台集合としたファジィ集合である。一般的に定義されている LTV としては、次のようなものが挙げられる。

$$\text{true}(t) = t \tag{1.26}$$

$$\text{false}(t) = 1 - t \tag{1.27}$$

$$(\text{absolutely true})(t) = \begin{cases} 1, & t = 1 \\ 0, & t \neq 1 \end{cases} \tag{1.28}$$




図 1.4: 言語的真理値

$$(\text{absolutely false})(t) = \begin{cases} 1, & t=0 \\ 0, & t \neq 0 \end{cases} \quad (1.29)$$

$$\text{undefined}(t) = 1 \quad (1.30)$$

ここで、 t は数値的真理値を表す。図 1.4は、上の (1.26)~(1.30) 式を含む代表的な LTV のメンバーシップ関数を示す。図中の“very”や“more or less”は言語ヘッジと呼ばれるファジィ集合の修飾演算子であり、任意のファジィ集合 $P(z)$ に対し

$$(\text{very } P)(z) = \{P(z)\}^2 \quad (1.31)$$

$$(\text{more or less } P)(z) = \{P(z)\}^{0.5} \quad (1.32)$$

のようにメンバーシップ関数を変形させる働きを持つ。同様にして“(very)²”=“very very”や“(more or less)²”=“more or less more or less”のような言語ヘッジも定義することができ、その他にも様々なものが提案されている^[9]。図 1.4に示す LTV のうち、シングルトンで表される“absolutely true”(「完全に真」と“absolutely false”(「完全に偽」)は2値論理における「真」・「偽」に対応するものであり、ファジィ集合で表される“true”および“false”とは明確に区別される点に注意する必要がある。なお、多値論理における数値的真理値は、“absolutely true”や“absolutely false”と同じくシングルトンとなる。

このような LTV を用いた重要な演算に真理値限定と逆真理値限定がある。真理値限定とは、“(z is P) is τ ”のように LTV τ を持つファジィ命題を“z is Q”の形式に等価変換する手法であり、ファジィ集合 Q は次式により求められる。

$$Q(z) = \tau\{P(z)\} \quad (1.33)$$

一方、逆真理値限定は、“z is Q”という命題を“(x is P) is τ ”のような形に変換する手法であり、LTV τ は

$$\tau(t) = \sup_{\{z|P(z)=t\}} Q(z) \quad (1.34)$$

により得られる。すなわち、真理値限定によれば“(He is Tall) is very true”を“He is very Tall”に変換でき、逆真理値限定によれば“He is very Tall”を“(He is Tall) is very true”に変換することができる。

ファジィ推論の間接法は、以上のような LTV および真理値限定・逆真理値限定を用いて推論を真理値空間で行うところに特徴がある。(1.25)式の推論では、まず、与えら

れた事実 A' に対する前件部命題 “ x is A ” の LTV τ_A を (1.34) 式の逆真理値限定により

$$\tau_A(t) = \sup_{\{x|A(x)=t\}} A'(x) \quad (1.35)$$

のように求める。次に、この τ_A とファジイルールの LTV τ_R から後件部命題の LTV τ_B を計算する。塚本の推論法では、 τ_R があらかじめ外から与えられ、 τ_B は

$$\tau_R = \min\{1 - \tau_A + \tau_B, 1\} \quad (1.36)$$

と定義される Lukasiewicz の含意から導かれる。ただし、上式の演算はすべてクリスプ集合間の演算をファジィ集合間に適用するための拡張原理⁹⁾に基づいており、具体的には次のように表される。

$$(\tau_R)_\alpha = \min\{1 - (\tau_A)_\alpha + (\tau_B)_\alpha, 1\} \quad (1.37)$$

ここで、 $(\tau_R)_\alpha$ は

$$(\tau_R)_\alpha = \{t | \tau_R(t) \geq \alpha\} \quad (1.38)$$

なるクリスプ集合であり、ファジィ集合 τ_R の α レベル集合と呼ばれる。 $(\tau_A)_\alpha$ 、 $(\tau_B)_\alpha$ も同様に τ_A 、 τ_B の α レベル集合を意味する。今、 $(\tau_A)_\alpha$ および $(\tau_B)_\alpha$ をそれぞれ

$$(\tau_A)_\alpha = [a_1, a_2] \quad (1.39)$$

$$(\tau_B)_\alpha = [r_1, r_2] \quad (1.40)$$

のような閉区間で表すと、 $(\tau_B)_\alpha$ は (1.37) 式より

$$(\tau_B)_\alpha = \begin{cases} [\max(a_1 + r_1 - 1, 0), 1], & r_2 = 1 \\ [\max(a_1 + r_1 - 1, 0), a_2 + r_2 - 1], & a_2 + r_2 \geq 1, r_2 \neq 1 \\ \phi, & 0 \leq a_2 + r_2 < 1 \end{cases} \quad (1.41)$$

と計算できる。 τ_B は、ファジィ集合の分解定理⁹⁾によってこの $(\tau_B)_\alpha$ から

$$\tau_B(t) = \sup_{\alpha} [\min\{\alpha, \chi_{(\tau_B)_\alpha}(t)\}] \quad (1.42)$$

のように求められる。ここで、 $\chi_{(\tau_B)_\alpha}(t)$ は $(\tau_B)_\alpha$ の特性関数である。最後に、(1.33) 式に従い後件部命題 “ y is B ” を τ_B で真理値限定することにより、結論 B' が

$$B'(y) = \tau_B\{B(y)\} \quad (1.43)$$

と得られる。

また、次のように複数の命題がファジイルールの前件部に含まれる場合には、(1.35) 式による前件部命題の LTV τ_A の計算を多次元に拡張する必要がある。

$$\begin{array}{l} \text{ファジイルール} : \text{(If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } A_2 \text{ and } \dots \text{ and } x_{n_{in}} \text{ is } A_{n_{in}} \\ \text{then } y \text{ is } B \text{) is } \tau_R \\ \text{事実 (入力)} : x_1 \text{ is } A'_1 \text{ and } x_2 \text{ is } A'_2 \text{ and } \dots \text{ and } x_{n_{in}} \text{ is } A'_{n_{in}} \\ \hline \text{結論 (出力)} : y \text{ is } B' \end{array} \quad (1.44)$$

この推論における τ_A は、(1.35) 式の A および A' を直接法と同じく (1.13) 式のように各命題の直積集合と解釈することで

$$\begin{aligned} \tau_A(t) &= \sup_{\{(x_1, \dots, x_{n_{in}}) | A(x_1, \dots, x_{n_{in}}) = t\}} A'(x_1, \dots, x_{n_{in}}) \\ &= \sup_{\{(x_1, \dots, x_{n_{in}}) | \min\{A_1(x_1), \dots, A_{n_{in}}(x_{n_{in}})\} = t\}} [\min\{A'_1(x_1), \dots, A'_{n_{in}}(x_{n_{in}})\}] \end{aligned} \quad (1.45)$$

のように求めることができる。なお、(1.45) 式の τ_A は、その台集合が直接法の場合のように多次元とならず一次元の数値的真理値上で定義されるため、以後の推論過程は (1.25) 式の 1 入力時と全く同じになる。

さて、入出力値が確定値で表されファジイルールが複数個存在する場合を次のような 2 入力 1 出力の推論において考える。

$$\text{ファジイルール } R^1 : \text{(If } x_1 \text{ is } A_{11} \text{ and } x_2 \text{ is } A_{12} \text{ then } y \text{ is } B_1 \text{) is } \tau_{R^1}$$

$$\text{ファジイルール } R^2 : \text{(If } x_1 \text{ is } A_{21} \text{ and } x_2 \text{ is } A_{22} \text{ then } y \text{ is } B_2 \text{) is } \tau_{R^2}$$

⋮

$$\text{ファジイルール } R^{n_R} : \text{(If } x_1 \text{ is } A_{n_R1} \text{ and } x_2 \text{ is } A_{n_R2} \text{ then } y \text{ is } B_{n_R} \text{) is } \tau_{R^{n_R}}$$

$$\text{事実 (入力)} : x_1 = x_1^0 \text{ and } x_2 = x_2^0$$

$$\text{結論 (出力)} : y = y^*$$

(1.46)

上式にて与えられている事実を直接法と同様に (1.16) 式のようなシングルトンと見なすと、各ファジイルールにおける前件部命題の LTV τ_{A_i} は (1.45) 式より

$$\begin{aligned} \tau_{A_i}(t) &= \sup_{\{(x_1, x_2) | \min\{A_{i1}(x_1), A_{i2}(x_2)\} = t\}} [\min\{A'_1(x_1), A'_2(x_2)\}] \\ &= \begin{cases} 1, & t = \mu_i \\ 0, & t \neq \mu_i \end{cases} \end{aligned} \quad (1.47)$$

となる。ただし、 μ_i ($i=1, 2, \dots, n_R$) は (1.18) 式で定義される i 番目のファジイルール R^i の前件部適合度である。村上らは、塚本の推論法を自動車の速度制御に応用するた

め、(1.46)式におけるファジイルールのLTV τ_{R^i} をすべて“absolutely true”とする簡略化を行った^[18]。このとき、 R^i の後件部命題に対するLTV τ_{B_i} は、(1.41), (1.42)式から

$$\tau_{B_i}(t) = \tau_{A_i}(t) \quad (1.48)$$

のように τ_{A_i} と一致する。従って、(1.43)式より R^i の結論 B'_i は

$$\begin{aligned} B'_i(y) &= \tau_{B_i}\{B_i(y)\} \\ &= \tau_{A_i}\{B_i(y)\} \\ &= \begin{cases} 1, & y = B_i^{-1}(\mu_i) \\ 0, & y \neq B_i^{-1}(\mu_i) \end{cases} \end{aligned} \quad (1.49)$$

と求められる。すなわち、

$$y_i^* = B_i^{-1}(\mu_i) \quad (1.50)$$

の y_i^* が R^i の推論結果となる。ファジイルール全体による最終的な推論値 y^* は、直接法と同じく

$$y^* = \frac{\sum_{i=1}^{n_R} \mu_i y_i^*}{\sum_{i=1}^{n_R} \mu_i} \quad (1.51)$$

のように y_i^* の μ_i による重み付き平均として計算される。

図1.5は、ルール数 $n_R=2$ の場合における(1.46)式の推論プロセスを示す。図1.5では、前件部適合度 μ_i ($i=1,2$)を(1.18)式のmin演算により求めているが、代わりに(1.22)式の代数積を用いてもよい。入出力値を確定値とする間接法では、各ファジイルールの結論が(1.49), (1.50)式により μ_i に対する後件部メンバーシップ関数 $B_i(y)$ の逆関数値として導かれる。そのため、図1.5からわかるように $B_i(y)$ が単調な関数でなければならない、表現能力の点で基本的に直接法より劣るという欠点が存在する。村上らの制御向けに簡略化した方法では前件部メンバーシップ関数にも単調なものが用いられているが、(1.47)式の前件部命題に関わる推論演算にはその制約は特に必要とされない。なお、本論文における以下の文中では、(1.47)式のようにシングルトンで表されるLTVを簡単のため

$$\tau_{A_i} = \mu_i \quad (1.52)$$

のように表記しているので注意されたい。




図 1.5: ファジィ推論 (間接法)

1.1.1.3 直接法と間接法の関係

以上のように、ファジィ推論は、一般にその推論過程によって直接法と間接法の二つに大別される。Zadehにより提案された直接法は、“If x is A then y is B ”のように表されるファジィルールをファジィ関係と捉え、推論の合成規則を用いて推論結果を導くものである。一方、Baldwin、塚本、水本により別々に提案された間接法は、前件部と後件部の命題だけでなくファジィルールそのものに対しても真理度を評価し、推論結果を真理値空間を介して導出するところに特徴がある。このようなファジィ推論における直接法と間接法の関係については、Tongら^[19]、向殿ら^[20]、川瀬ら^[21]によってそれぞれ異なる条件の下に考察が行われている。

Tongらは、Baldwinの推論法において前件部メンバーシップ関数 $A(x)$ の逆関数が全射ならばZadehの推論法と同一の推論結果が導かれることを示し、多次元における(1.45)式の計算コストの問題からも間接法は不要であると述べている。向殿らは、それをさらに一歩進め、 $A(x)$ が全射でファジィ関係 $R\{A(x), B(y)\}$ が $A(x)$ に関して単調となるようにその定義域を分解可能な場合、直接法と間接法が等価であることを証明した。向殿らはまた、塚本の推論法がBaldwinの推論法と本質的に同じであることを示し、さらに、 $A(x)$ が全射という条件が間接法では必要条件であるのに対し直接法では特に必要としないことから直接法は間接法を含むとして、ファジィ推論の応用はすべて計算の簡単な直接法を基に構成されるべきであると主張している。川瀬らは、Tongらや向殿らとは異なり $A(x)$ および $R\{A(x), B(y)\}$ には何ら条件を設けずに逆真理値限定をmax演算ではなくsup演算で行うことによって、Baldwinの推論法による推論結果がZadehの推論法による推論結果を常に含み、推論の合成規則におけるt-normが連続であれば両者が一致することを証明した。さらに川瀬らは、多次元の場合に問題とされた間接法の計算コストが直接法と変わらないことを示し、水本の推論法もBaldwinの推論法と同様に解釈できるとしている。

これらの研究は、様々なファジィ推論法の間係を明らかにする上で大変意義深いものであるが、その主張は数学的な検証のみに基づくものであり実用の立場からは計算コストの問題を除いて全く議論されていない。例えば、塚本の推論法では、ファジィルールのLTVを外から与えるためファジィルールの調整に対する自由度が高い。また、ファジィルールの真理度がLTVにより示されていることは、ファジィルールの理解を容易にし、ヒューマン・コンピュータインタラクションの観点からも望ましい特徴で

あると言える。

ファジィ推論では、直接法・間接法ともあいまいな入出力関係をファジィルールにより言語的に記述することができる。このファジィルールは、入出力空間においてあいまいな点を定めていると考えられる。従って、ファジィルールを複数個用いれば、非線形な入出力関係を容易に実現することが可能である。しかし、ファジィ推論は、人間の主観を対象とすることから、ファジィルールの同定やメンバーシップ関数等のパラメータ調整に多大な労力を必要とするという問題を抱えている。

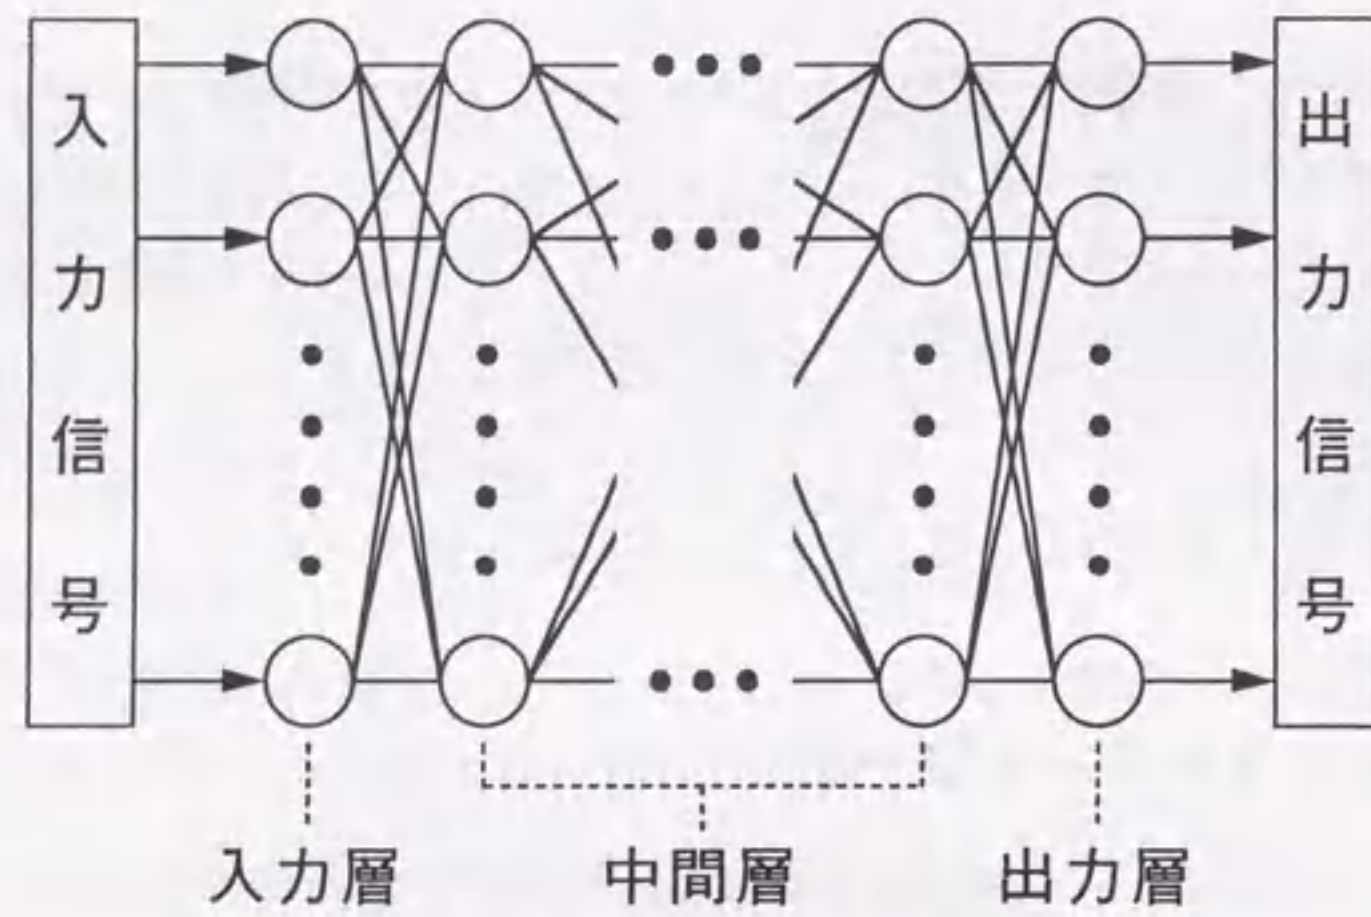
1.1.2 ニューラルネットワーク

人間の脳は、ニューロンと呼ばれる神経細胞が互いに結び付くことによって構成されている。この仕組みを工学的にモデル化した情報処理システムがNNであり、生体における神経回路網と区別して人工ニューラルネットワーク(Artificial Neural Network)あるいは単にニューロとも呼ばれる。一般に、NNのモデルは階層型と相互結合型の二つに分けられ両者とも様々なモデルが提案されているが、ここではその中でも特によく用いられる階層型のBPモデルについて簡単に説明する^[5]。


BPモデルは、図1.6(a)に示すようなフィードフォワード型のネットワークである。このネットワークは、信号が図の左から右へ方向のみに流れる構造になっており、入力信号を与える第1層を入力層、出力信号の表れる最終層を出力層、その他を中間層と呼ぶ。中間層の数には特に制限はないが、各層は少なくとも1個以上のユニットと呼ばれる基本素子で構成される。このユニットは、脳におけるニューロンに相当するものである。図1.6(b)は、ネットワークを構成するユニットの構造を示す。各ユニットは、前層のユニットと結合荷重と呼ばれる可変パラメータを介して結合され、内部関数として非減少かつ微分可能な準線形アクティベーション関数を持つ。ユニットは、この内部関数により前層のユニットの出力値と結合荷重との積和を非線形変換し、次層のユニットに出力する。すなわち、ユニットの入出力関係は次のように表される。

$$\begin{cases} I = \sum_{i=1}^n w_i o_i \\ O = f(I) \end{cases} \quad (1.53)$$

ここで、 I は入力、 O は出力を表し、 o_i ($i=1, 2, \dots, n$)は前層の*i*番目のユニットの出力、 n は前層のユニット数、 w_i は結合荷重、 $f(\cdot)$ は内部関数である。内部関数として



(a) ネットワークの構成



(b) ユニットの構造

図 1.6: バックプロパゲーションモデル

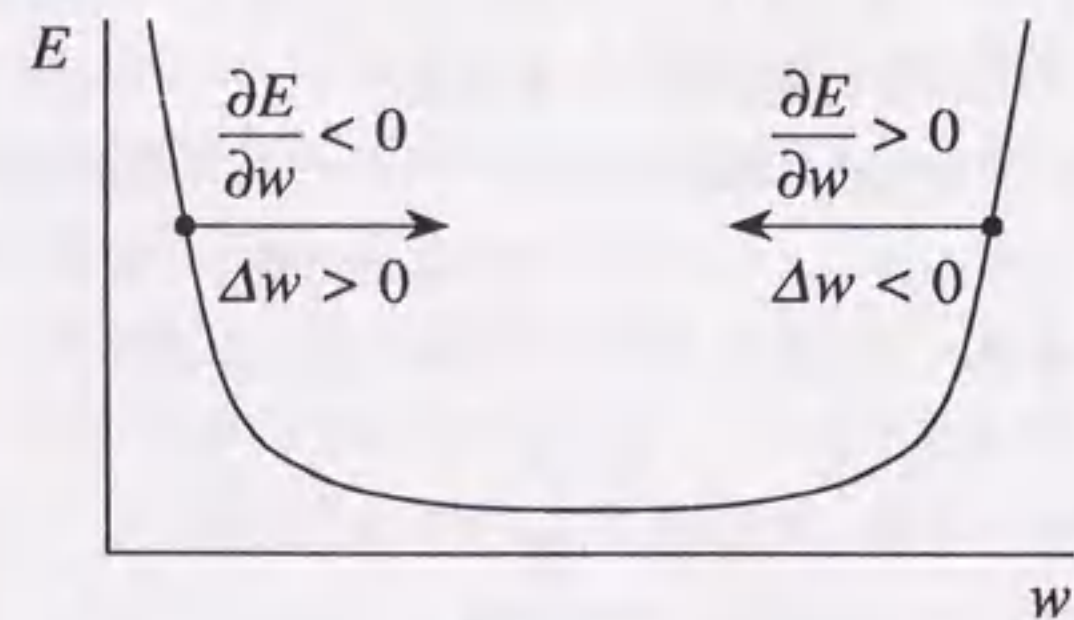


図 1.7: バックプロパゲーション法の原理

1.1. 本研究の背景

は、線形なものも用いられる。なお、ユニットは基本的に多入力1出力の構造を持ち、(1.53) 式の I は一般にユニットの内部状態と呼ばれるが、本論文ではユニットの出力に対して入力と呼ぶ。BP モデルは、このようなユニットを多数用いて複数の階層をなすよう構成され、全体として非線形な多入力多出力システムとなっている。

NN の特徴は、所望の非線形な入出力関係を結合荷重を変化させることにより自動的に同定できることである。この操作は NN において学習と呼ばれるが、BP モデルの学習アルゴリズムには BP 法が用いられる。BP 法では、ある入力に対する望ましい出力と実際の出力との間で定義される誤差評価関数 E を最小化するため、結合荷重 w の変化分 Δw を

$$\Delta w \propto \frac{\partial E}{\partial w} \tag{1.54}$$

により求め w を変化させる。ネットワークに与えられる所望の出力値は教師信号と呼ばれ、本論文では入力値と教師信号の組を学習データと呼ぶ。図 1.7 は、(1.54) 式による BP 法の原理を示す。図 1.7 からわかるように、 E の w による偏微分値が負のときは w の値を増加させ、また、正のときには減少させれば、 E の値を小さくすることができる。BP 法では、このような (1.54) 式に基づく学習を何回も繰り返すことによって E を最小にする w の値が求められ、最終的に望ましい入出力関係を実現する。BP 法の名前の由来は、(1.54) 式に従い誤差を出力層から入力層に向かって逆伝播させることにある。この規則はデルタルールと呼ばれるが、その詳細については 3.2 節にて説明する。

NN によれば、知識を自動的に獲得することができる。しかし、その知識は、ネットワーク内の結合荷重に分散記憶されるため定性的に把握することが難しいという問題がある。

1.1.3 ファジニューラルネットワーク

以上のように、ファジ推論と NN は、ともに人間の知的情報処理を模擬しているだけでなく、本質的に非線形で並列・分散型の処理機構を持つなど多くの共通点がある。また、ファジ推論は明示的な知識の取り扱いに優れた特徴を持つのに対し、NN は非明示的な知識の取り扱いに優れ、両者は互いに異なった長所を有している。FNN は、これらを融合することによってより有用な知的情報処理システムを生み出そうとしたものであり、本研究と並行してこれまでに数多くの手法が提案されている。その分類の仕方についても様々な方法があるが、ごく最近になって林らにより有力な分類

法が示された^[22]。ここでは、文献[22]の分類法によってFNNの解説を行い、本研究の位置付けを明確にする。

図1.8は、林らによるFNNの分類を示す。この分類では、これまでに提案されたFNNをファジィ推論とNNとの融合度合に応じて(a)のニューロ&ファジィから(i)のファジィ化ニューロまで9種類に大別しており、基本的に(a)から(i)の順に融合度合が高いとされる。なお、FNNの分類においては一般にNNをニューロと呼ぶことが多く、本項ではさらに簡単のためファジィ推論によるシステムを単にファジィと表記している。以下、図1.8におけるFNNを順に説明する。

(a)のニューロ&ファジィは、ファジィとNNを同一システム内で独立に配置したモデルである。このモデルはファジィとNNを単に組み合わせただけのものであり、両者の間には特別な関係はない。

(b)のニューロ/ファジィは、ファジィとNNを並列に結合したモデルである。ファジィとNNのどちらを主体とするかによって種々の形態が考えられるが、この特殊な場合としてNNによりファジィの出力を補正するモデルが提案されている。

(c)のニューロ-ファジィおよび(d)のファジィ-ニューロは、ファジィとNNを直列に接続したモデルである。システムの入力がまずNNに加えられその出力をファジィに入力するものがニューロ-ファジィ、システムの入力をファジィに加えた後その出力をNNに入力するものがファジィ-ニューロと呼ばれる。

(e)のニューロ的ファジィは、ファジィを基本としてNN的な学習機能を持たせたモデルである。このモデルでは、ファジィ推論におけるパラメータのチューニングを自動的に行うことができる。

(f)のファジィ入出力ニューロは、入出力値をファジィ値としたNNである。その入出力値はファジィルールの前件部ファジィ変数と後件部ファジィ変数に対応し、NNによりファジィ推論を実現していると捉えられる。

(g)のファジィ的ニューロは、ファジィ推論の構造を持つNNである。このモデルは、通常のNNと同様に所望の入出力関係を自動的に同定できるだけでなく、学習結果をファジィルールとしてわかりやすく表現することができる。

(h)のニューロ化ファジィは、NNを用いてファジィ推論における計算過程の一部を実現したモデルである。複数個のNNをうまく組み合わせることにより、全体としてファジィ推論が実現されている。

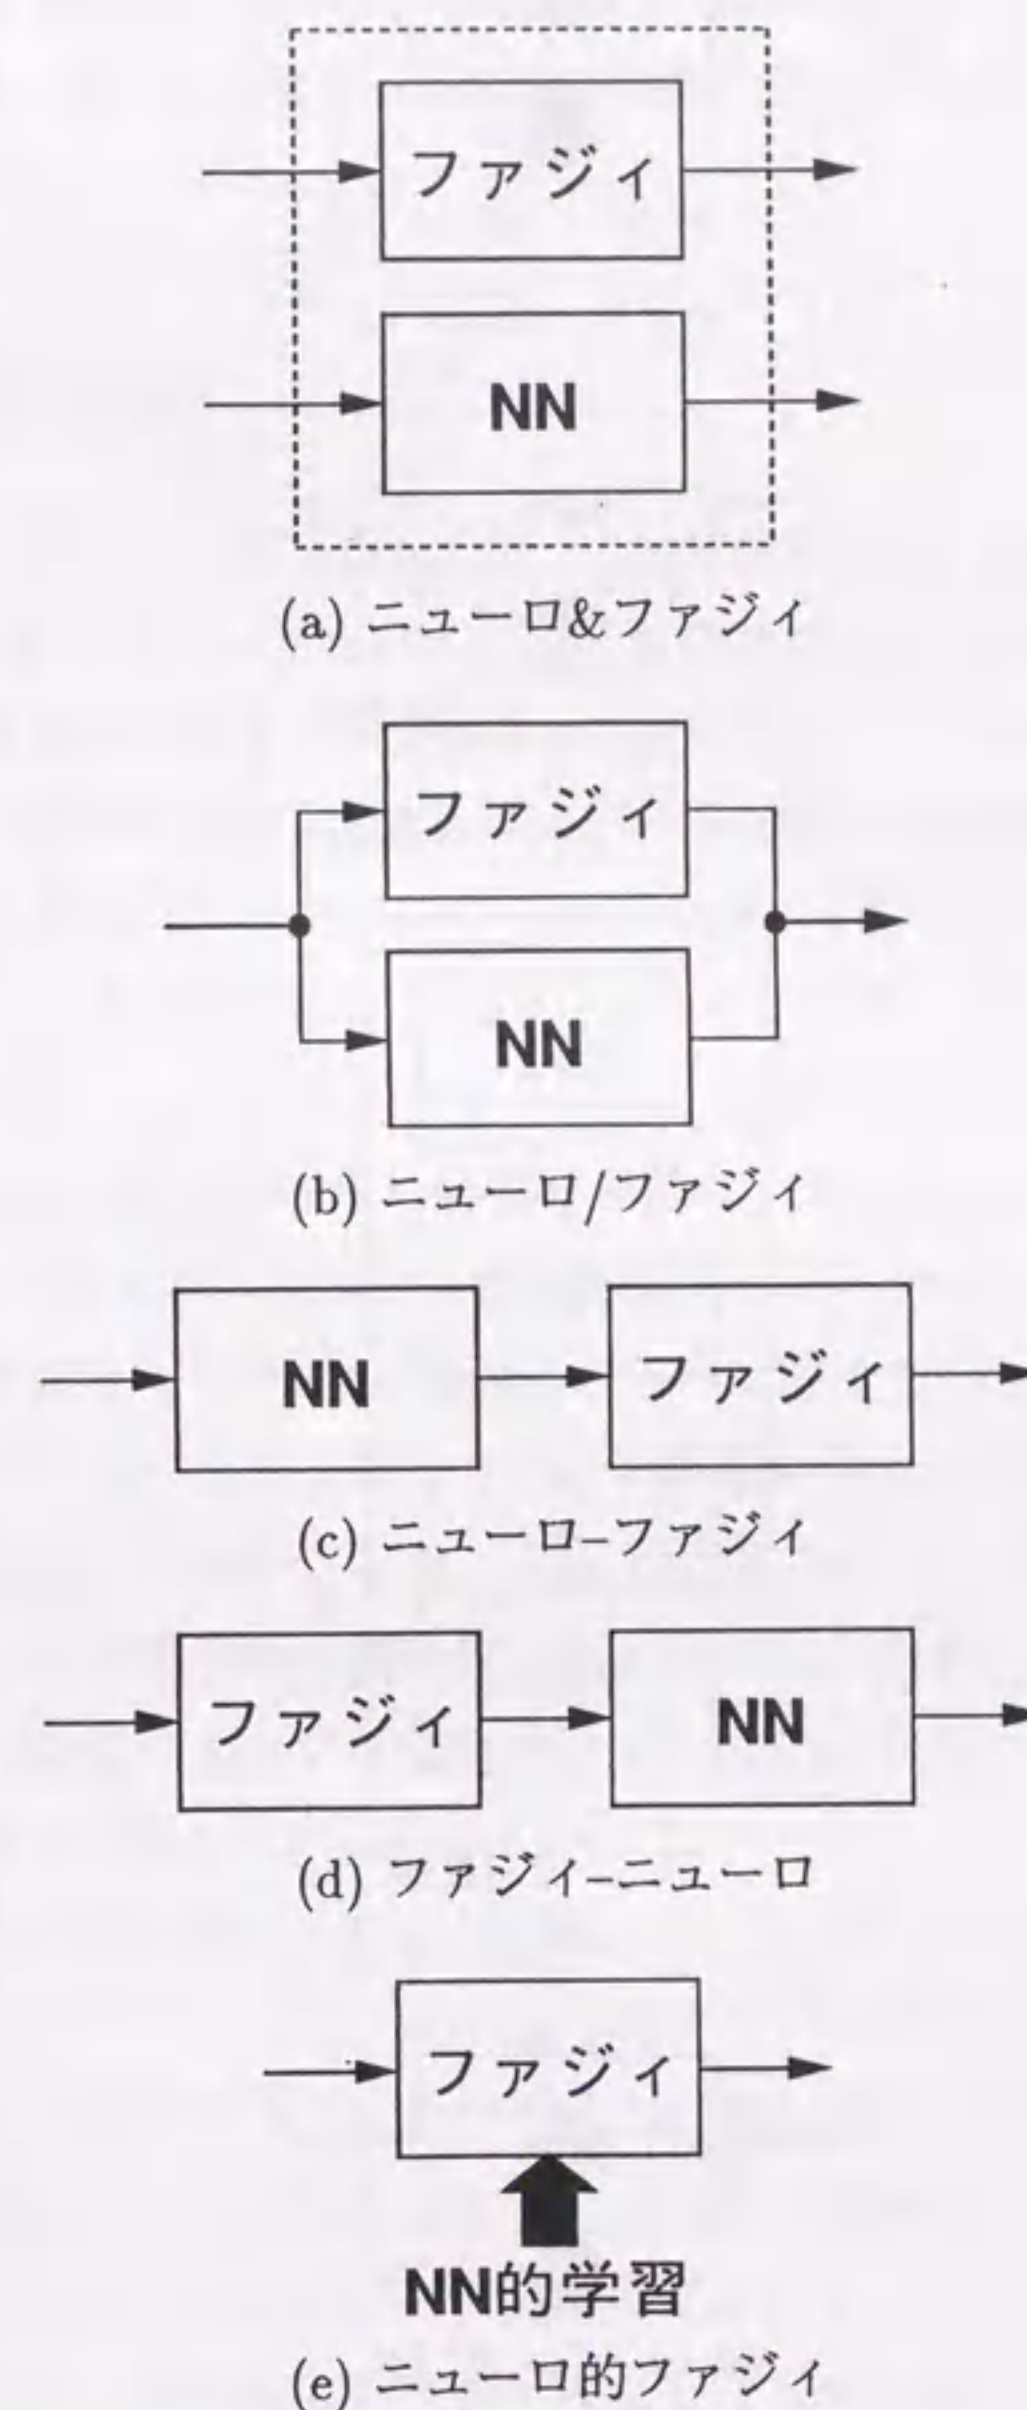


図 1.8: ファジィニューラルネットワークの分類




図 1.8: ファジィニューラルネットワークの分類

(i) のファジィ化ニューロは、結合荷重をファジィ値とした NN である。このモデルでは、入出力値もファジィ値で表され、学習方法についてもファジィ化する必要がある。

これらの FNN は、それぞれ異なった特徴を持ち、用途に応じて使い分けられるのが普通である。

1.2 本研究の目的

前節で述べたように、ファジィ推論は、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徴を持つ。しかし、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、NN の特徴は、学習機能により任意の入出力関係を自動的に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。本研究では、このようなファジィ推論と NN を融合することにより両者の特徴を兼ね備えた新しい FNN の提案を目的とする。本研究で提案する FNN は、図 1.8 において (g) のファジィ的ニューロに分類することができる。本 FNN は、ファジィ推論に適した構造を持ち、NN の学習法の一つである BP 法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ファジィ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^{[23][24]}、山口ら^[25]、および今崎ら^[26]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。また、今崎らのファジィルール構造化 NN では、山口らの手法における連想記憶システムを BP モデルとする

ことでシステム全体における誤差の逆伝播を可能とし、ファジイルールの「確かさ」だけでなくメンバーシップ関数の調整も行うことができる。しかし、林らの手法や今崎らの手法では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、獲得されたファジイルールの把握が難しいという問題がある。特に、三つの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、ファジイ推論の記述能力を向上させる有力な手段ではあるが、ファジイ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う。従って、NNの学習機能を活かしつつ、学習結果をファジイ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。

ファジイ推論におけるファジイ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。これらは、図1.8(e)のニューロ的ファジイに相当するものである。市橋らは、ファジイルールの後件部が定数で表される簡略化ファジイ推論において、入力空間のファジイ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^[27]。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^[28]や、前件部メンバーシップ関数も同時に学習する手法^{[29][30]}が提案されている。これらはすべて前件部メンバーシップ関数に三角型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イモデル^[31]は C^0 級であるために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イモデルを C^1 級とする手法^[32]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^[33]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)を用いてファジイモデルを C^∞ 級とする手法がある^[34]。最近では、最急降下法の代わりにペナルティ法を用いる手法^[35]や、遺伝的アルゴリズムを応用してファジイルールの同定等を行う手法^{[36]-[38]}も検討されている。

本研究では、NNの学習機能によりファジイ推論におけるファジイ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のできる新しいFNNの構成法を提案する。本FNNは、ファジイ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、ファジイ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、学習結果をファジイ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、実現されるファジイモデルが 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。本研究では、互いに異なる推論法を実現した5種類のFNNを提案する。これらのうち、Type I, Type IIと呼ぶFNNは直接法に基づいており、Type III, Type IV, Type Vと呼ぶFNNは間接法に基づいている。中でも、間接法に基づくFNNは、同定されたファジイルールを言語的にわかりやすく表記することができ、ファジイ推論の長所を有効に活用している。

本研究で提案するFNNは、ネットワーク中の結合荷重をBP法に基づく学習によって変化させることにより、ファジイルールの同定とメンバーシップ関数の調整を行う。しかし、本FNNでは、ファジイ推論をネットワークの構造で実現するために特殊な演算を行うユニットを多数用いており、BP法も通常のNNに比べてやや特殊なものが必要となる。また、本FNNの結合荷重はすべて明確な役割を持ち、初期設定の段階よりそれぞれの値が大きく異なることから、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という問題が存在する。そこで、本研究では、本FNNにおけるBP法を導出するとともに、学習時の学習率設定に対する煩雑さを低減する手法について述べる。さらに、本FNNのネットワークの規模について考察を行い、その実現可能性を検証する。

本FNNは、主にファジイ制御への応用を目的としている。ファジイ制御は、熟練オペレータが経験的に体得した制御アルゴリズムをIf-then型のファジイルールにより言語的に記述できるヒューマン・コンピュータインタラクションに優れた制御法である。しかし、熟練オペレータの操作は、オペレータ自身が意識していない知識や判断に基づいて行われる場合が多く、それらを正確に把握するためには一般に多大な労力を必要とする。そこで、本研究では、熟練オペレータが持つ制御アルゴリズムを非明示的に含むと考えられるオペレータの操作パターンを本FNNに学習させることにより、自動的にファジイ制御器を構成できることをシミュレーションにより示す。

また、前述したように、学習型のファジイ推論システムはファジイモデリング^[31]と密接な関係がある。ファジイモデリングは、ファジイ推論を用いて対象とするシステムの入出力関係を記述する手法であり、複雑な非線形システムの表現に優れた能力を持つ。ファジイモデルの特徴としては、その入出力関係がファジイルールによって言語的に表されることから、従来の数式モデルに比べて定性的で理解しやすいことが挙

げられる。しかし、ファジィモデルの同定は、ファジィ制御器の設計と同様に決して容易ではない。そこで、本研究では、本FNNを用いたファジィモデリング手法を提案し、簡単な数値例により対象システムの特性をよく表したファジィモデルが同定できることを示す。

以上のように、ファジィ制御における問題点をNNの学習機能の応用で改善することが本研究の目的である。

1.3 本論文の構成

本論文は、新しいFNNの構成法と学習法およびその基礎的な応用手法についてまとめたものであり、全6章で構成される。以下、各章の概要について述べる。

第1章では、本研究の背景としてファジィ推論、NN、FNNを解説し、本研究の目的および位置付けを述べた。

第2章では、本研究で提案する新しいFNNの構成法を説明する。まず、前件部メンバーシップ関数の構成法について解説し、本手法が他のメンバーシップ関数よりも優れた特徴を持つことを示す。次に、前件部適合度の計算をネットワークにより行う手法を述べる。以上の前件部の構成は、本研究で提案するすべてのFNNに共通となっている。さらに、直接法に基づくFNNとしてType I, Type IIの2種類、間接法に基づくFNNとしてType III, Type IV, Type Vの3種類を提案する。また、間接法に基づくFNNにより同定されたファジィルールを言語的に表記する手法について述べる。

第3章では、本FNNの学習法を説明する。まず、本FNNを構成する様々なユニットにおけるBP法のデルタルールを導出する。次に、学習の際の各結合荷重に対する学習率の設定について、その煩雑さを低減する手法を述べる。さらに、本FNNのネットワークの規模を通常のBPモデルと比較し、その実現可能性を検証する。

第4章では、本FNNのファジィ制御への応用例を示す。具体的には、むだ時間を持つ一時遅れ系を制御対象として、本FNNに熟練オペレータの操作パターンを学習させるシミュレーションを行い、良好な制御性能を持つファジィ制御器が自動的に構成できることを示す。

第5章では、本FNNを用いたファジィモデリング手法を提案する。また、簡単な数値例によりその有用性を検証し、対象システムの入出力関係を的確に捉えたファジィモデルが自動的に同定できることを示す。

第6章では、本研究の内容および得られた成果をまとめ、最後に今後の課題について述べる。

第2章

ファジィニューラルネットワークの 構成法

2.1 はじめに

本研究で提案する新しい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、1.1.1項で説明したように、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、前件部の構成について述べた後、それに後件部を含めたネットワーク全体の構成法を説明する。なお、前件部は、本研究で提案する5種類のFNNすべてに共通となっている[39]-[41]。

2.2 ファジィニューラルネットワークの前件部

2.2.1 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。

$$\text{三角型} : A(x) = \max(-g|x - c| + 1, 0) \quad (2.1)$$

$$\text{釣鐘型} : A(x) = \exp\{-g^2(x - c)^2\} \quad (2.2)$$

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[1]。しかし、BP法をNNの学習に適用するためには、1.1.2項で述べたように、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単調関数でなければならない。従って、本FNNの前件部に(2.1)、(2.2)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2.1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。

$$\Sigma : \begin{cases} I_j^{(n)} = \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = I_j^{(n)} \end{cases} \quad (2.3)$$

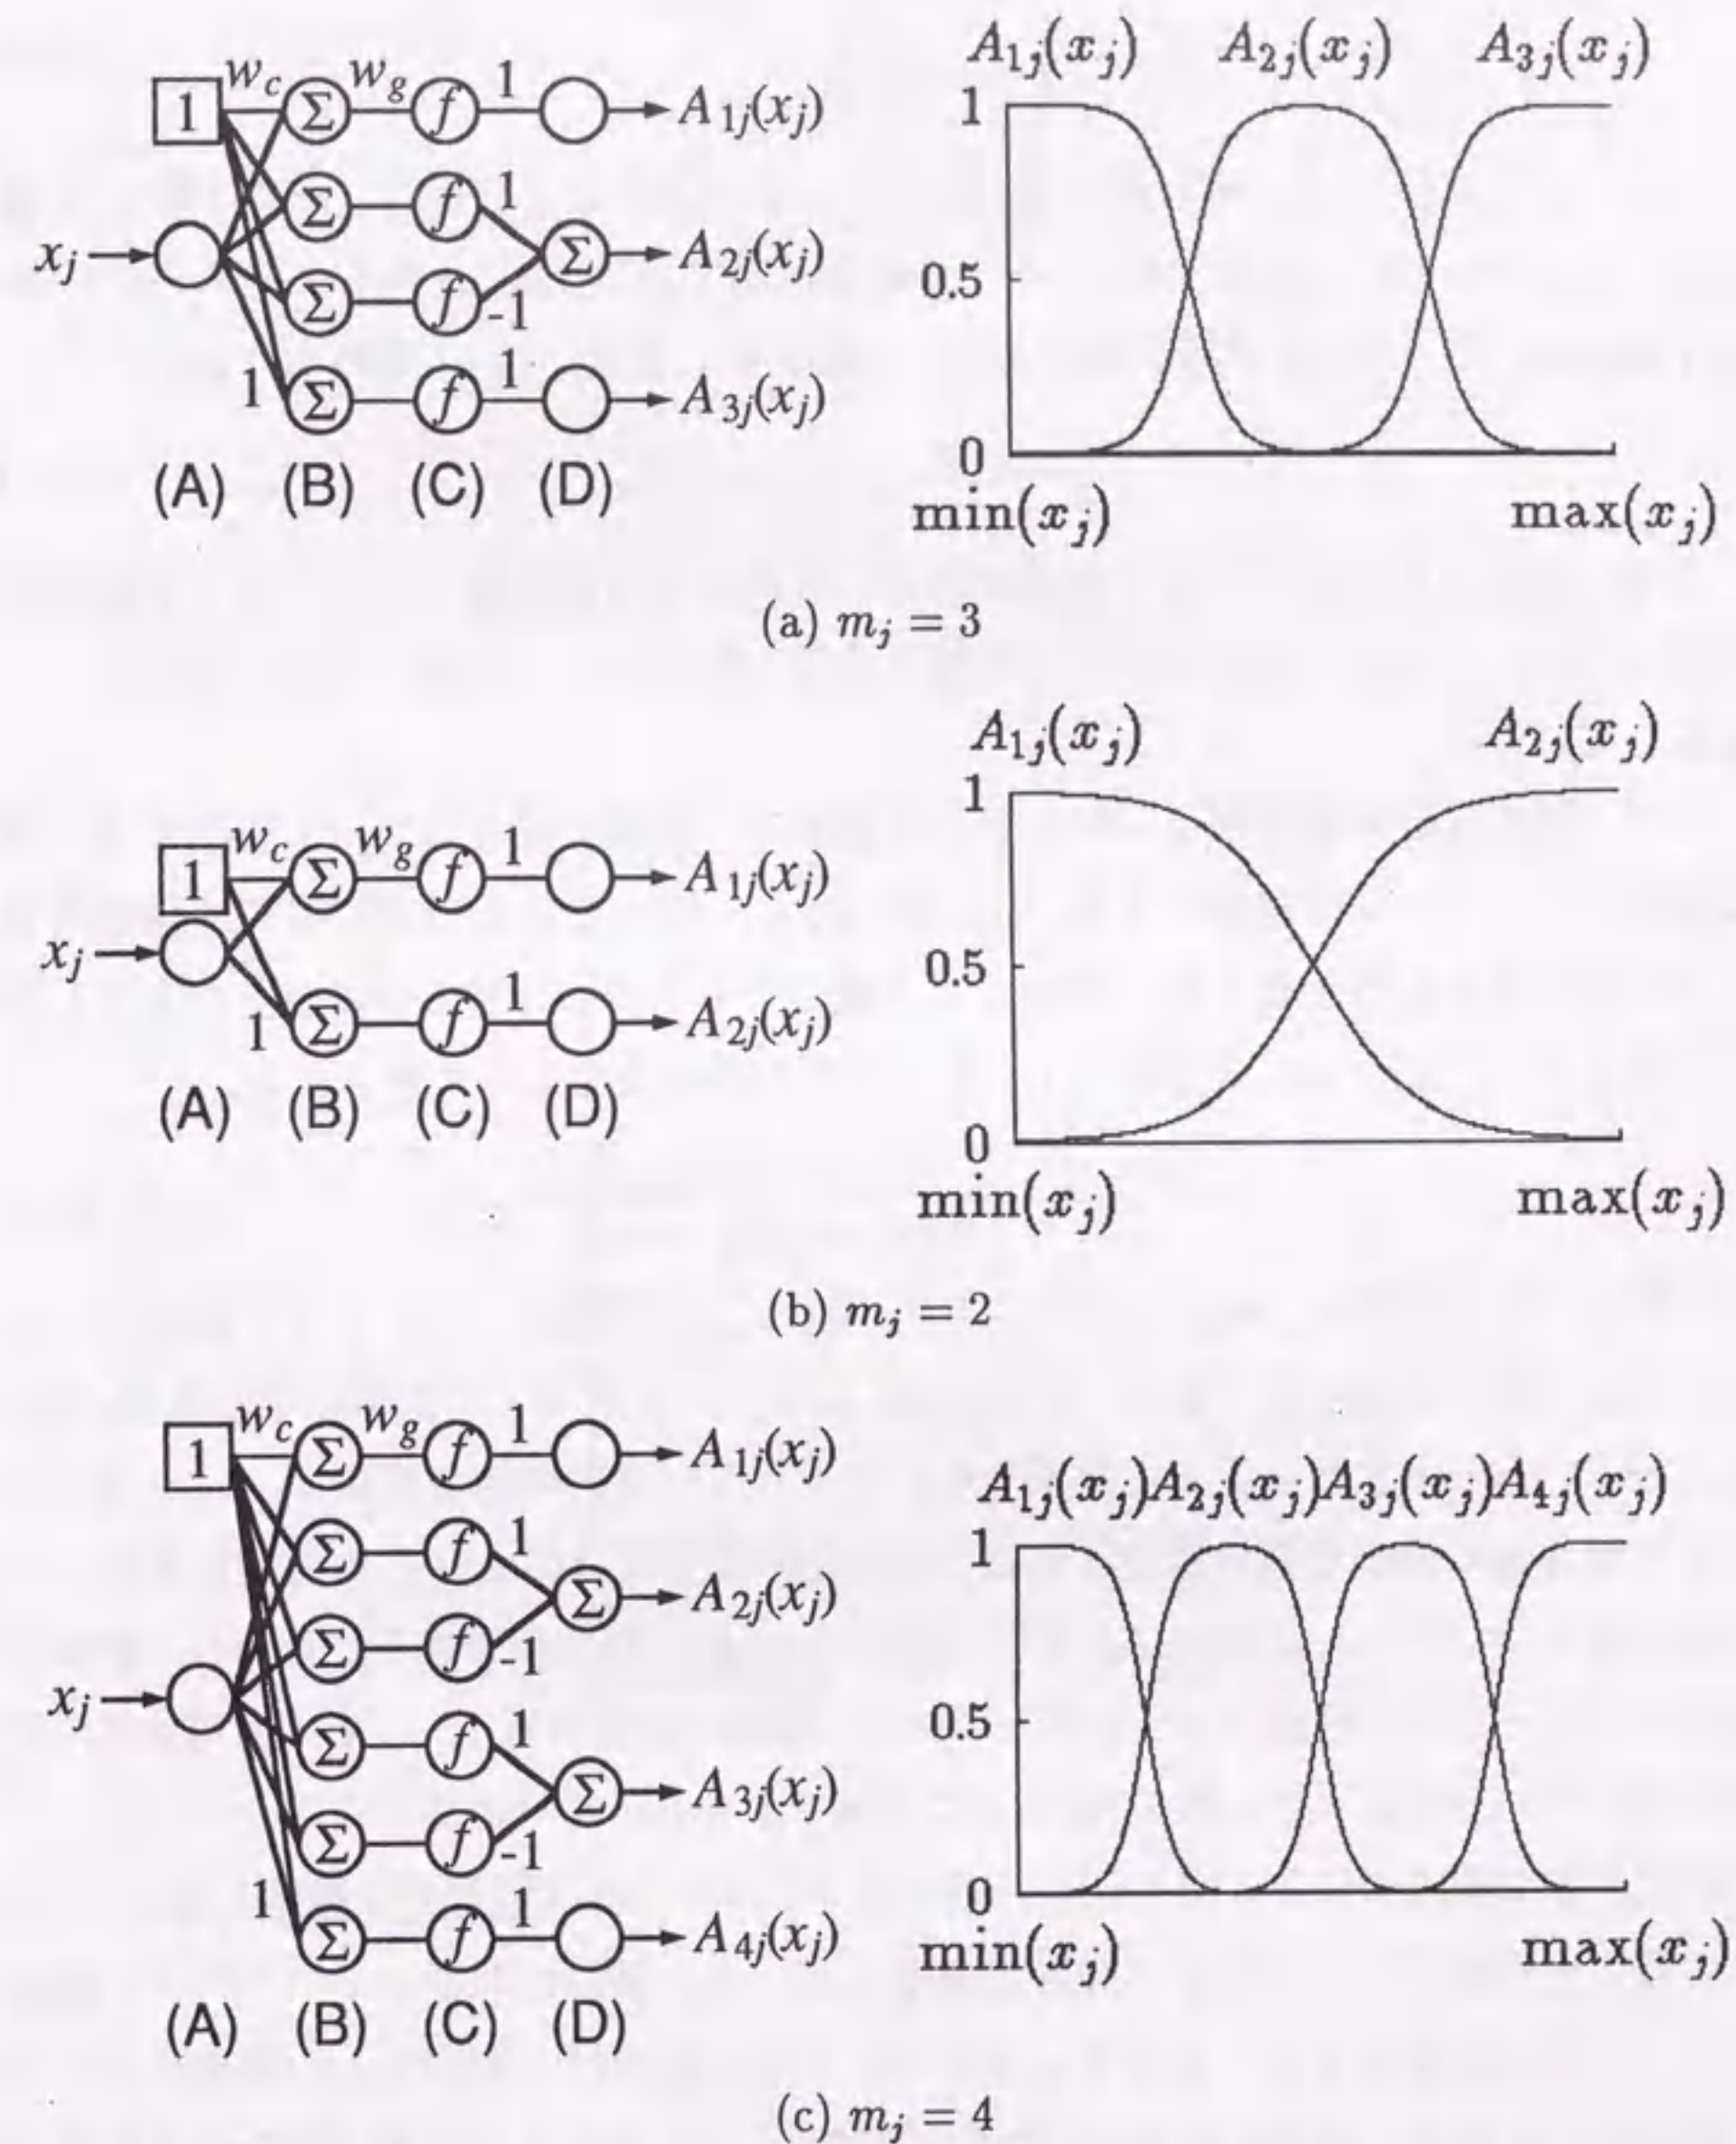


図 2.1: 前件部メンバーシップ関数の構成例

(左 : ネットワークの構成
右 : ネットワークが実現する前件部メンバーシップ関数)

$$f : \begin{cases} I_j^{(n)} = \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = f(I_j^{(n)}) \end{cases} \quad (2.4)$$

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。図2.1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、(2.4)式の $f(\cdot)$ は、

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2.5)$$

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2.1(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、(2.4)、(2.5)式より、(C)層の出力 $O^{(c)}$ は次のように表される。

$$O^{(c)} = \frac{1}{1 + \exp\{-w_g(x_j + w_c)\}} \quad (2.6)$$

すなわち、結合荷重 w_c 、 w_g は、(2.1)、(2.2)式の c 、 g と同様に、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、(2.5)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切な値に設定すれば、(D)層の出力には図2.1(a)の右側に示すような前件部メンバーシップ関数 $A_{1j}(x_j)$ 、 $A_{2j}(x_j)$ 、 $A_{3j}(x_j)$ を実現できる。ただし、擬似台形型メンバーシップ関数 $A_{2j}(x_j)$ 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2.2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2.1(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2.1(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って変化させることにより前件部メンバーシップ関数の調整を行う。なお、(A)~(B)層間と(C)~(D)層間の 1 および -1 の結合荷重は固定されており、学習で変化しない。




図 2.2: 擬似台形型メンバーシップ関数の構成

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[34]の手法では、前件部メンバーシップ関数に(2.2)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

$$f(x) = \exp(-x^2) \quad (2.7)$$

とし、擬似台形型メンバーシップ関数における-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2.3の例を用いて説明する。例えば、図2.3(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2.3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、各メンバーシップ関数はそれぞれ図2.3(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、 $x=a$ で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、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

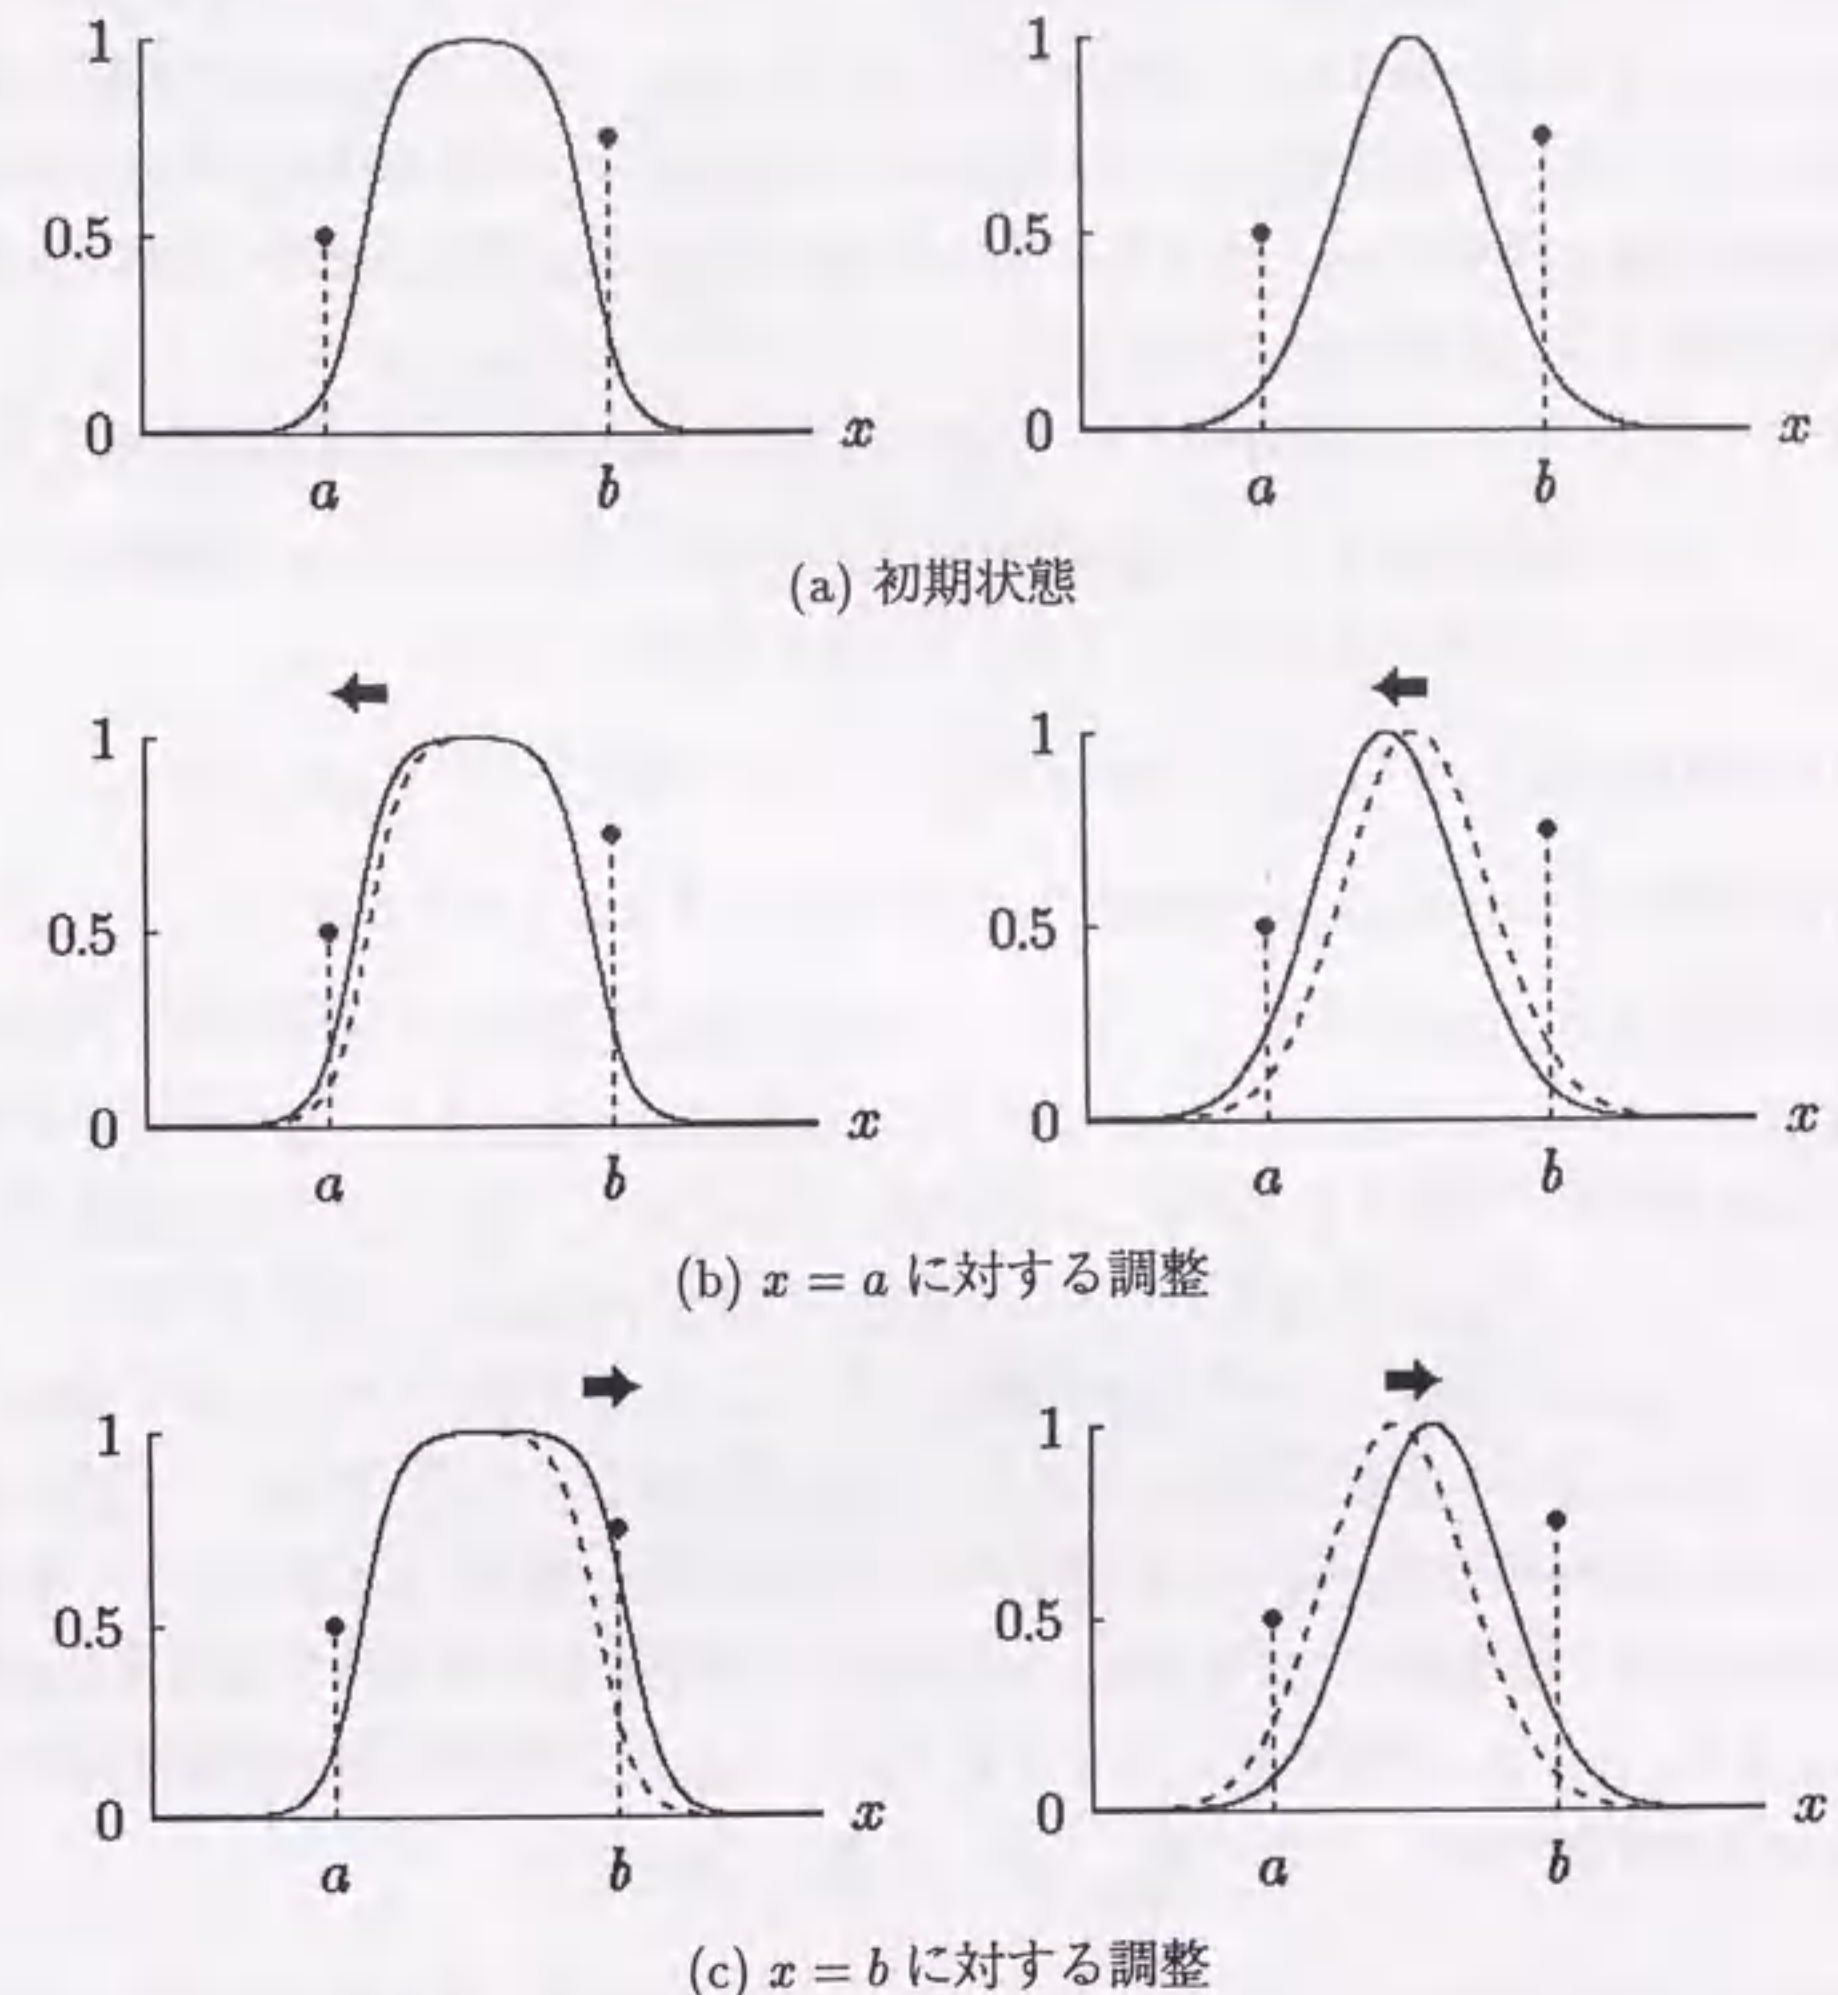


図 2.3: 擬似台形型メンバーシップ関数と釣鐘型メンバーシップ関数の調整例

(左 : 擬似台形型メンバーシップ関数)
(右 : 釣鐘型メンバーシップ関数)

数を適切な形状に調整することができる。しかし、図 2.3(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、4章に示す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、擬似台形型メンバーシップ関数の代わりに釣鐘型を用いた場合には、数百回程度の学習では良好な制御性能を実現することができなかつた。本 FNN は、わずか 100 回の学習で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た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たりのパラメータ数は、三角型や釣鐘型の 2 倍、4 となっている。また、擬似台形型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 (2.3.1 項参照)。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、3.3 節にて詳述する。

2.2.2 前件部適合度

ファジイルールの前件部における and 演算には、1.1.1 項で説明したように、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 2.4 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) は各入力に対する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。図中上側の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それぞれに示された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 2.4(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。

$$\hat{\Pi} : \begin{cases} I_j^{(n)} = \prod_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = \frac{I_j^{(n)}}{\sum_k I_k^{(n)}} \end{cases} \quad (2.8)$$

すなわち、(E) 層のユニットの出力 $O_j^{(E)}$ は、入力 $I_j^{(E)}$ を (E) 層の各ユニットにおける入力値の総和で規格化したものとなっている。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。

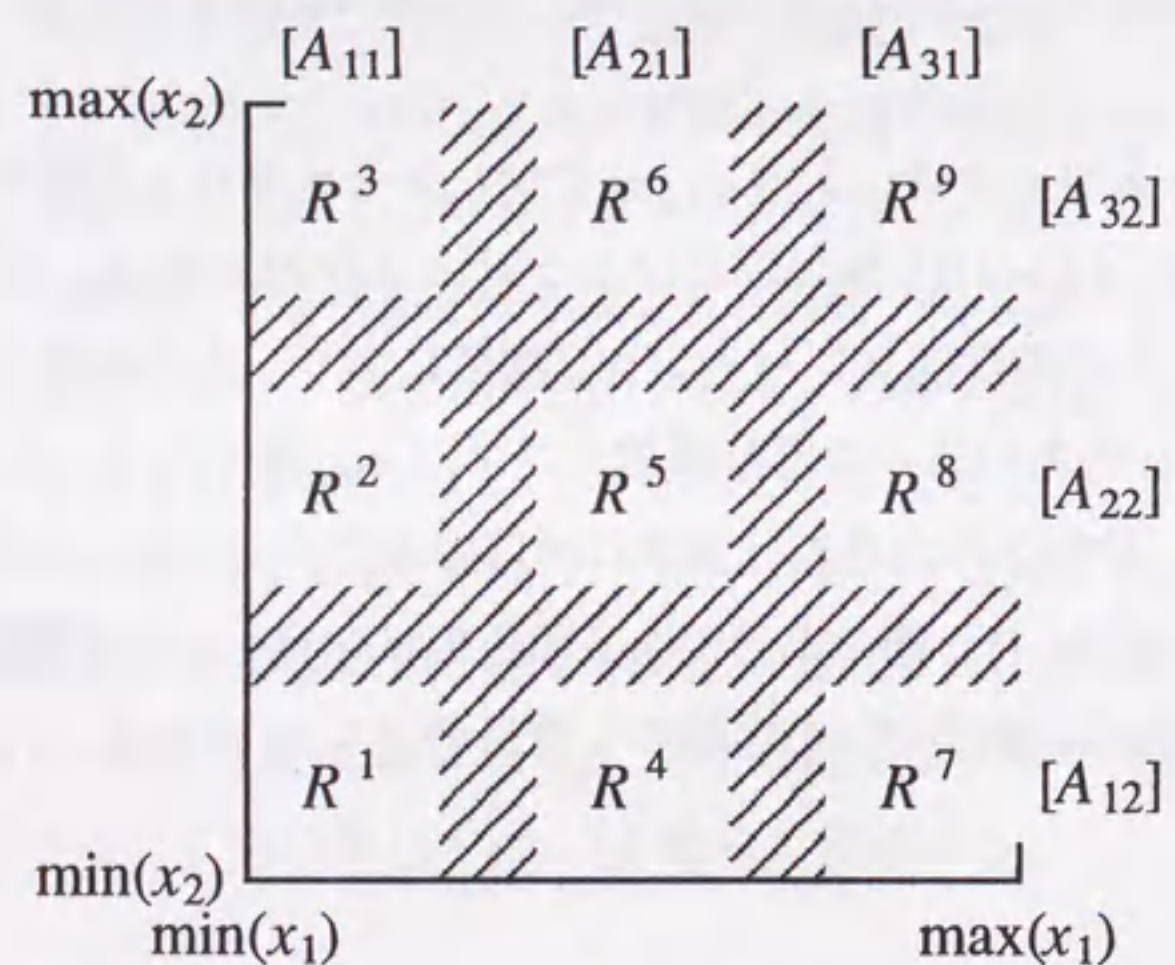

図 2.4(a) のネットワークは、入力 x_1, x_2 に対してそれぞれ 3 種類の前件部メンバーシップ関数を持つ。(A)~(D) 層の構成は図 2.1(a) と同様である。図 2.4(a) のネットワークでは、これらの前件部メンバーシップ関数により、入力空間が図 2.4(a) 下側に示すような $3 \times 3 = 9$ のあいまいな部分領域にファジィ分割される。ただし、図中の R^i ($i=1, 2, \dots, 9$) は、分割された各部分領域に対応するファジィルールを表す。各領域における前件部適合度は、(D) 層の出力である前件部メンバーシップ関数のグレードから (E) 層にて求められる。例えば、(E) 層の 1 番目のユニットでは、

$$\mu_1 = A_{11}(x_1) \cdot A_{12}(x_2) \quad (2.9)$$

のように前件部適合度 μ_i 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。

$$\text{入力} : \mu_i = \prod_j A_{ij}(x_j) \quad (2.10)$$


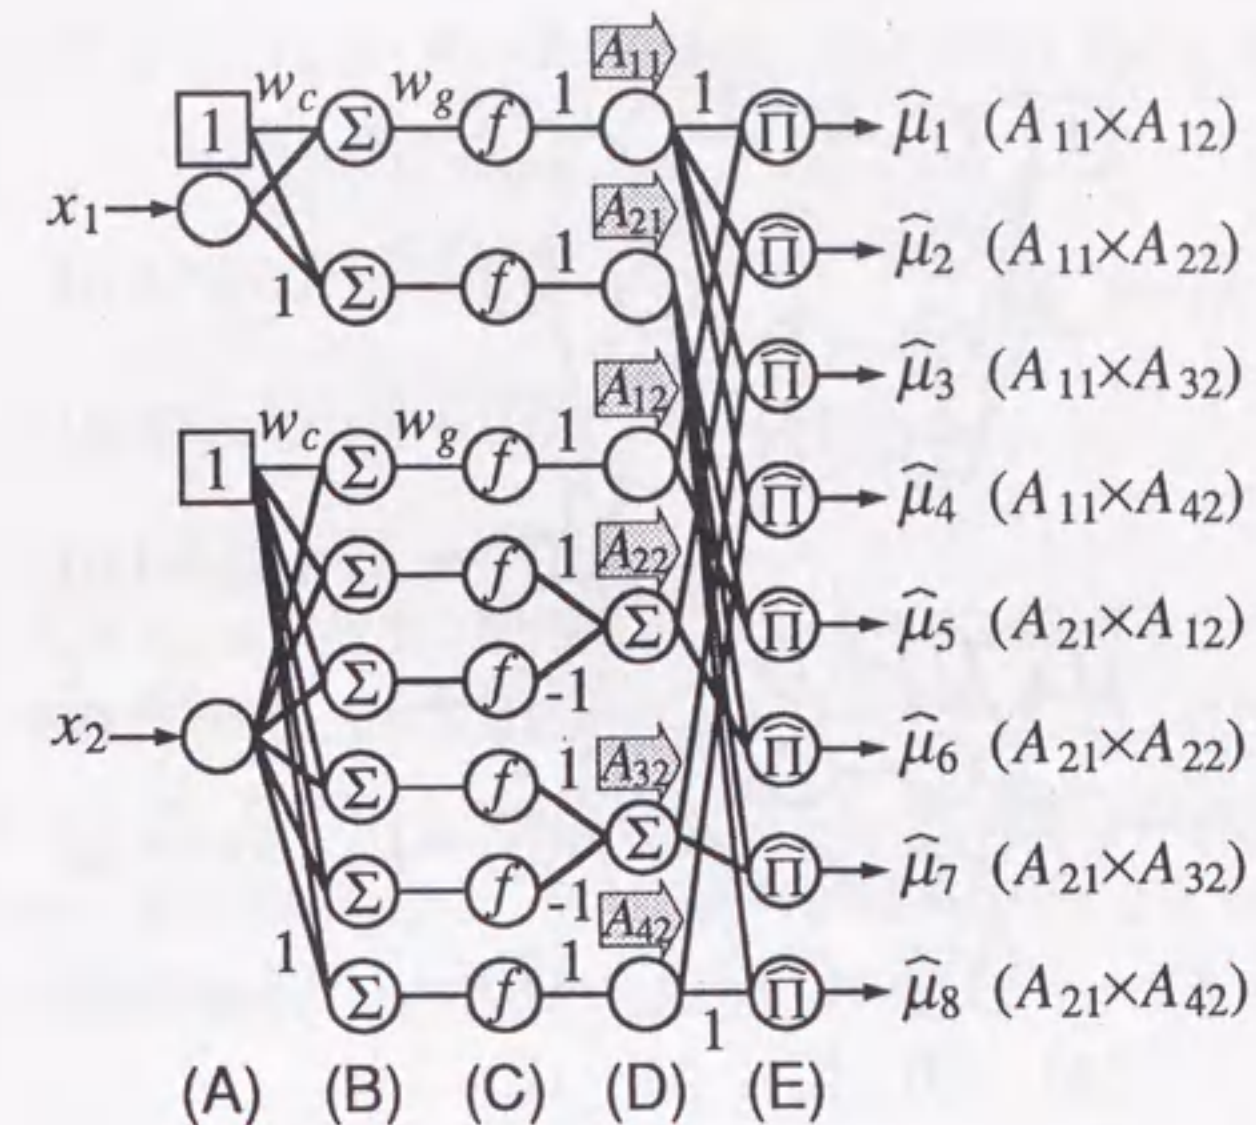
$$\text{出力} : \hat{\mu}_i = \frac{\mu_i}{\sum_k \mu_k} \quad (2.11)$$



(a) $m_1 = m_2 = 3, n_R = 9$

図 2.4: 前件部の構成例

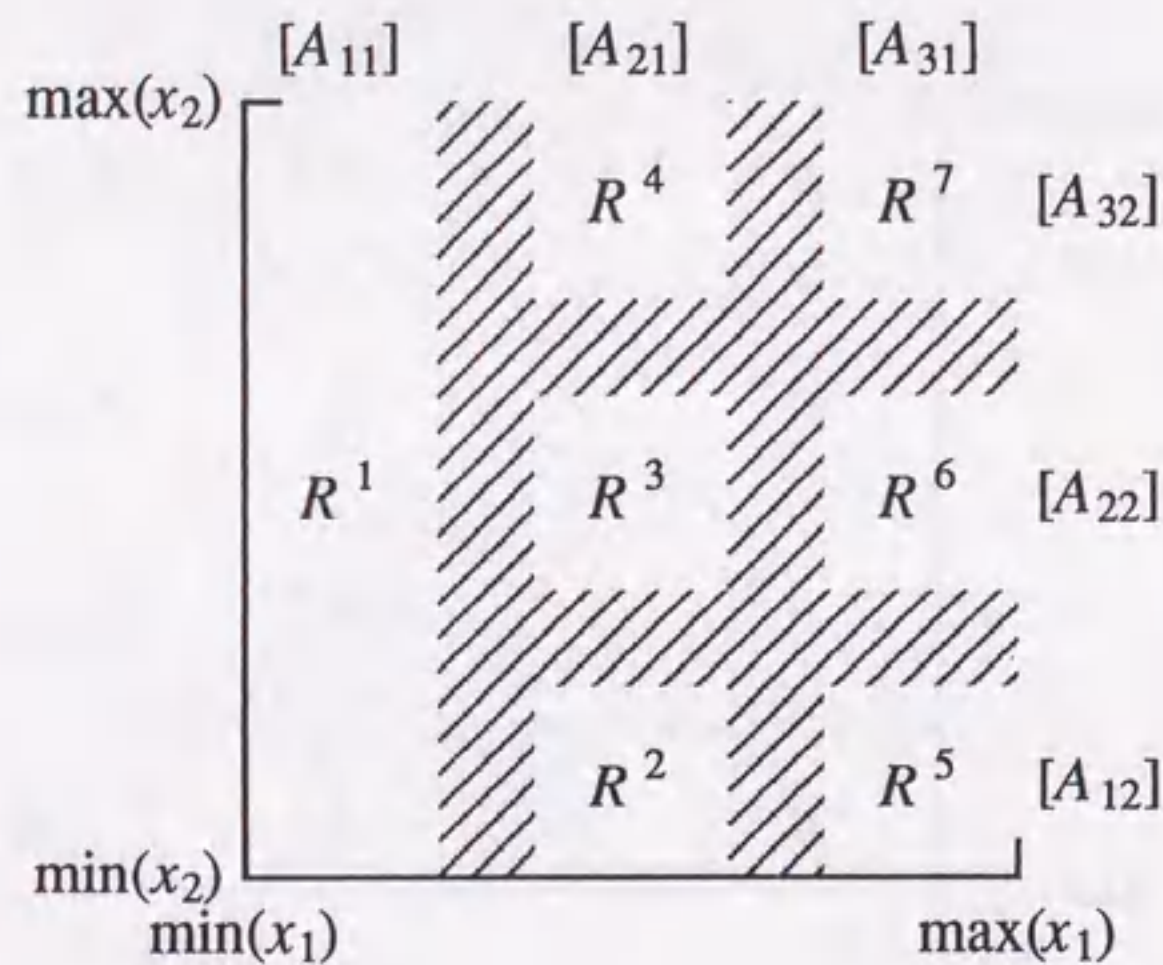
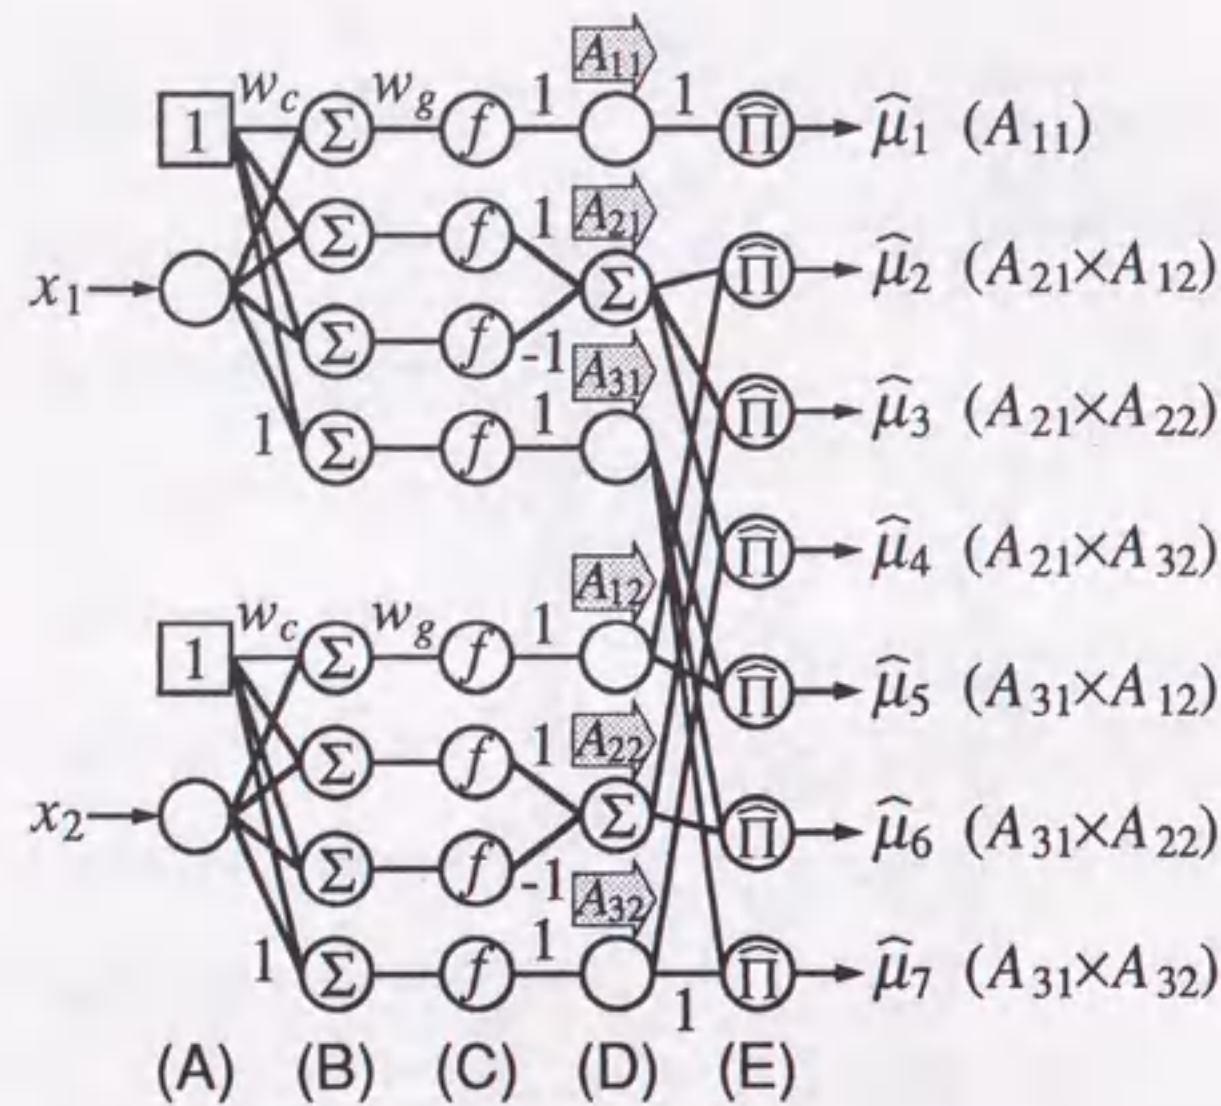
(上 : ネットワークの構成
下 : ネットワークが実現する入力空間のファジィ分割)



(b) $m_1 = 2, m_2 = 4, n_R = 8$

図 2.4: 前件部の構成例

(上 : ネットワークの構成
下 : ネットワークが実現する入力空間のファジィ分割)



(c) $m_1 = m_2 = 3, n_R = 7$

図 2.4: 前件部の構成例

(上 : ネットワークの構成
下 : ネットワークが実現する入力空間のファジィ分割)

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 μ_i である。ただし、(2.10)式の添え字 i_j は、例えば図2.4(a)に示すごとく

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

となる。

図2.4(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種類である場合の前件部の構成を示す。このネットワークでは、(A)~(D)層に x_1 について図2.1(b)のネットワークを用い、 x_2 について図2.1(c)のネットワークを用いている。ファジィ分割された部分領域の数は、図2.4(b)の下側のように8となる。

図2.4(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。

$$n_R = \prod_j m_j \tag{2.12}$$

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)が似通ったルール同士を一つにまとめることにより減らすことができる。図2.4(c)は、その一例を示す。図2.4(c)のネットワークにおいて、(A)~(D)層は図2.4(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2.4(c)の下側のようになり、図2.4(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、その入出力関係が(2.8)式で定義される規格化ユニットにより、ファジィ推論の推論値計算における重心法を実現している。なお、規格化ユニットでは、他のユニットと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

$$\frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} = \frac{\sum_{k \neq j} I_k^{(n)}}{\left(\sum_k I_k^{(n)}\right)^2} \geq 0 \tag{2.13}$$

のように $I_j^{(n)}$ に対して非減少性を満たすため、BP法に基づく学習が可能となっている。

2.3 直接法に基づくファジィニューラルネットワーク

本研究では、以上のような前件部構成を持つ5種類の新しいFNNを提案する。本FNNは互いに異なったファジィ推論を実現しており、その分類はそれぞれのFNNに基づく推論法によってなされる。一般にファジィ推論は、1.1.1項で述べたように、その推論過程により直接法と間接法の二つに分けられる。本研究で提案する5種類のFNNのうち、Type I, Type IIと呼ぶFNNはそれぞれ直接法に属する簡略化推論法および高木・菅野の推論法を実現している。以下、Type I, Type IIの順に直接法に基づくFNNの構成法を説明する。

2.3.1 後件部が定数で表される

ファジィニューラルネットワーク (Type I)

Type Iと呼ぶFNN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。

$$R^i : \text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y = f_i \quad (2.14)$$

$(i = 1, 2, \dots, n_R)$

$$y^* = \frac{\sum_{i=1}^{n_R} \mu_i f_i}{\sum_{i=1}^{n_R} \mu_i} = \sum_{i=1}^{n_R} \hat{\mu}_i f_i \quad (2.15)$$

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、 $\hat{\mu}_i$ は規格化された μ_i である。

図2.5は、前件部が図2.4(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。図中の記号 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2.5(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。


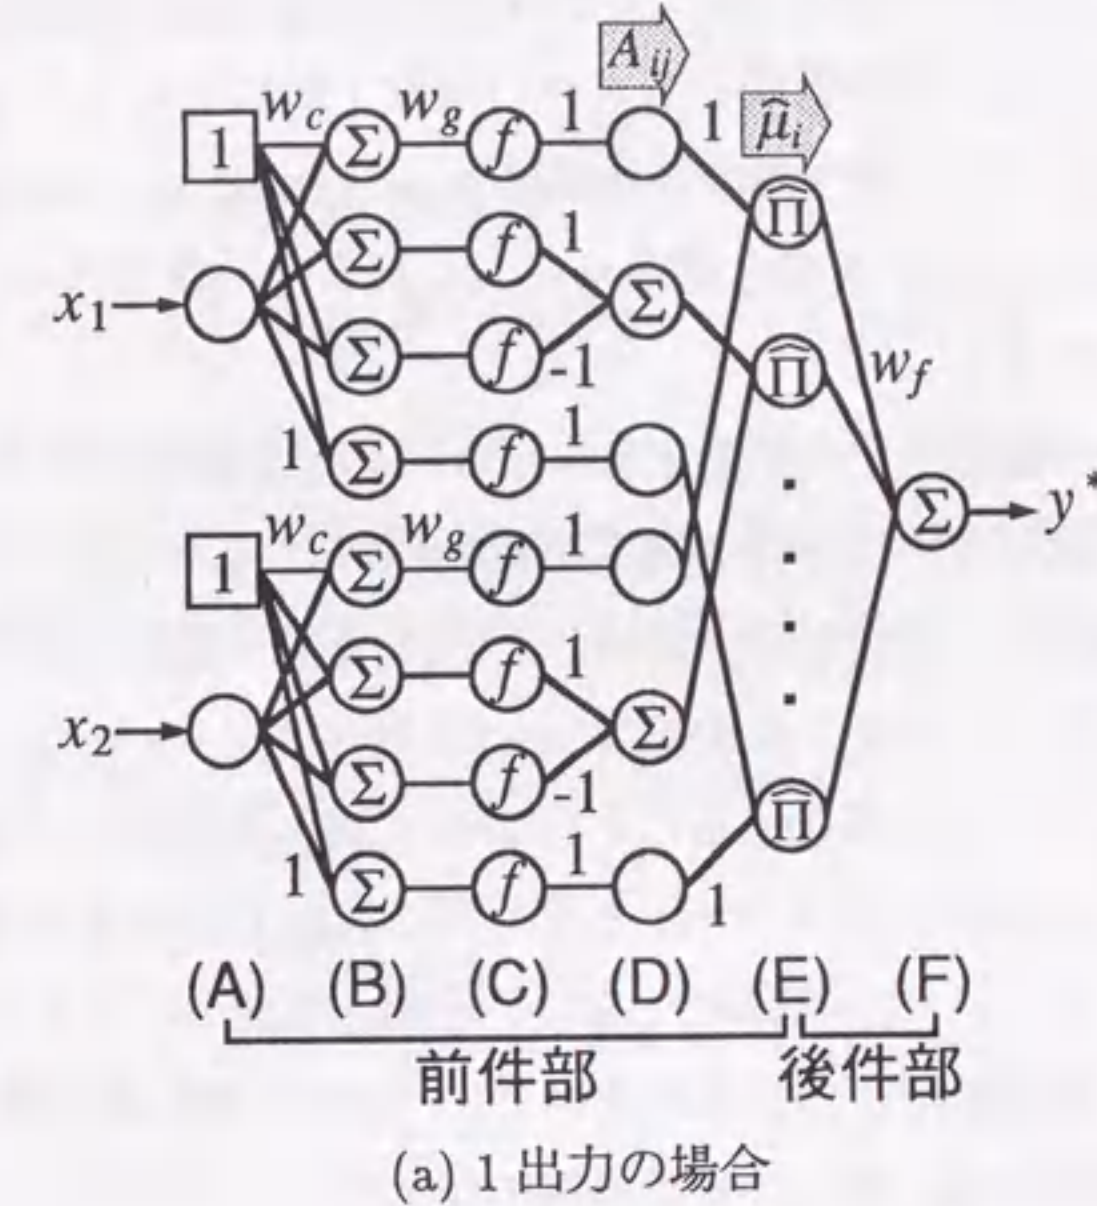


図 2.5: ファジィニューラルネットワーク (Type I)

これは、(2.15)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、(2.14)、(2.15)式に基づく簡略化ファジィ推論が実現される。図2.5(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。

このFNNに対し、増田らは、同様なネットワーク構成を持つFNNによりファジィルールを逐次的に生成していく手法を提案した^[42]。しかし、増田らのFNNでは前件部メンバーシップ関数に三角型を用いているため、1.2節で説明したように記述能力の点で問題がある。また、下川は、本FNNにおける前件部メンバーシップ関数の構成を基に、除算を行うユニットを追加することによって重心法を実現する手法を提案した^[43]。このFNNは、基本的には本FNNと全く同じ入出力特性を示すが、特に多入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を持つ。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。本研究で提案した手法では、重心法を前件部の規格化ユニットにより実現しているため、FNNが複雑なネットワークとなることはない。

ところで、文献[44][45]のFNNは、(2.14)式のファジィルールから、推論値 y^* を重心法ではなく

$$y^* = \sum_{i=1}^{n_R} \mu_i f_i \quad (2.16)$$

のように前件部適合度 μ_i と後件部定数 f_i の積和により求めている。推論値計算を上式で行う場合、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_1 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、2.2.1項で述べたように、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(2.15)式の重心法によれば、この例では $\mu_1=1$ 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。

2.3.2 後件部が一次式で表される

ファジィニューラルネットワーク (Type II)

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、高木・菅野の推論法と呼ばれるものであり、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。

$$R^i : \text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y = f_i(x_1, x_2) \quad (2.17)$$

$(i = 1, 2, \dots, n_R)$

$$y^* = \frac{\sum_{i=1}^{n_R} \mu_i f_i(x_1, x_2)}{\sum_{i=1}^{n_R} \mu_i} = \sum_{i=1}^{n_R} \hat{\mu}_i f_i(x_1, x_2) \quad (2.18)$$

ここで、

$$f_i(x_1, x_2) = a_{i0} + a_{i1}x_1 + a_{i2}x_2 \quad (2.19)$$


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2.6は、前件部が2入力 (x_1, x_2) で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2.5のType Iと同じである。図2.6(a)は後件部変数が前件部変数と共通の場合 (x_1, x_2)、(b)は後件部変数が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_a は入力変数の規格化定数を意味し、 w_a は(2.19)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

$$\Pi : \begin{cases} I_j^{(n)} = \prod_k w_{jk}^{(n)} O_k^{(n-1)} \\ O_j^{(n)} = I_j^{(n)} \end{cases} \quad (2.20)$$


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2.6(a)のネットワークにおいて、(F)層に加えられた各入力は結合荷重 w_a によって規格化され、それらに w_a を掛け



(a) 前件部変数と後件部変数が共通の場合

図 2.6: ファジィニューラルネットワーク (Type II)



(b) 前件部変数と後件部変数が異なる場合

図 2.6: ファジィニューラルネットワーク (Type II)

たものの和が(J)層にて求められる。すなわち、 w_a が(2.19)式の定数 a_{ij} に対応することから、(J)層の出力は各ファジィルールの後件部一次式 $f_i(x_1, x_2)$ の値となる。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。これにより(2.18)式に従い、(K)層にて $f_i(x_1, x_2)$ と規格化された前件部適合度 $\bar{\mu}_i$ 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2.6(b)は、後件部一次式を

$$\begin{aligned} y &= f_i(x_1, x_2, x_3) \\ &= a_{i0} + a_{i1}x_1 + a_{i2}x_2 + a_{i3}x_3 \end{aligned} \quad (2.21)$$

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2.6(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、このように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2.6(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と同様に、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、学習時の w_a に対する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 $w_{ji}^{(n)}$ の更新量が第 n 層第 j ユニットの逆伝播誤差と第 $n-1$ 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、逆伝播誤差は各後件部一次式毎に(J)層のユニットから結合荷重1を介して同じ値が伝播される。そのため、一つの後件部一次式における各係数 w_a の更新量は、それぞれに対する後件部の入力 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2.6のように規格化用の結合荷重を設けた場合には、各入力均等となることからそのような必要はなく、 w_a に対し一つの学習率を設定すればよい。

結合荷重 w_a 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各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 の初期値はすべて0として、 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。

2.4 間接法に基づくファジィニューラルネットワーク

ファジィ推論の間接法は、1.1.1項で説明したように、後件部メンバーシップ関数が単調なものでなければならないことから、そのような制約のない直接法より記述能力に劣るという問題を持つ。そのため、間接法の応用例は直接法に比べると極めて少なく、特に間接法による学習型のファジィ推論システムはこれまでに全く提案されていない。

本研究では、前節の直接法に基づく2種類のFNNに加え、Type III, Type IV, Type Vと呼ぶ3種類の間接法に基づくFNNを提案する。これらのFNNは、間接法が持つ優れたヒューマン・コンピュータインタラクションの能力に着目したものであり、塚本の推論法の考え方に沿って各ファジィルールのLTVを可変パラメータとしている。また、直接法と同等の記述能力を実現するため、文献[18]の制御向けに簡略化した方法とは異なる独自の推論法を用いている。

以下、本研究で提案する間接法に基づくFNNの基本となるType IIIの構成法を説明した後、Type IIIの推論法を単純化したType IV、Type IVにおいてシングルトンで表される各ファジィルールのLTVをファジィ集合としたType Vについて述べる。また、これらのFNNにより同定されたファジィルールを言語的に表記する手法を解説する。

2.4.1 後件部がファジィ変数で表される

ファジィニューラルネットワーク (Type III)

Type IIIの推論法におけるファジィルールは、 x_1, x_2 を入力、 y を出力とする2入力1出力の場合次のように表される。

$$\begin{aligned} R_k^i : (\text{If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ then } y \text{ is } B_k) \text{ is } \tau_{R_k^i} \end{aligned} \quad (2.22)$$

$$(i = 1, 2, \dots, n_R; k = 1, 2)$$

ここで、 B_k は後件部ファジィ変数であり、 R_k^i は前件部ファジィ変数が A_{i1} および A_{i2} で後件部ファジィ変数が B_k であるファジィルールを表す。Type IIIでは、同一の前件部命題に二つの異なる後件部命題を対応させているため、そのルール数がType IやType IIの2倍となる。また、 $\tau_{R_k^i}$ は区間 $[0, 1]$ の確定値(シングルトン)で表される R_k^i のLTVであり、 $\tau_{R_k^i}=0$ のとき対応するファジィルールが“absolutely true”、 $\tau_{R_k^i}=1$ の

ときのそれが "absolutely false" であることを意味する。Type III においては、この $\tau_{R_k^i}$ によりファジールールの同定を行う。

Type III が実現する推論法では、(2.22) 式 of ファジールールから次のようにして推論値が求められる。

$$\mu'_k = \sum_{i=1}^{n_R} \hat{\mu}_i \tau_{R_k^i} \quad (2.23)$$

$$y^* = \frac{\sum_{k=1}^2 \mu'_k B_k^{-1}(\mu'_k)}{\sum_{k=1}^2 \mu'_k} = \sum_{k=1}^2 \hat{\mu}'_k B_k^{-1}(\mu'_k) \quad (2.24)$$

ここで、 μ'_k 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。また、 $B_k^{-1}(\mu'_k)$ は後件部メンバーシップ関数 $B_k(y)$ の逆関数値を表し、 $\hat{\mu}'_k$ は $\hat{\mu}_i$ と同様にその総和が 1 となるように規格化された μ'_k である。

図 2.7 は、2 入力 1 出力で前件部が図 2.5 および図 2.6 と同じ場合における Type III の構成例を示す。図中の w_r は各ファジールールの LTV $\tau_{R_k^i}$ 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結合荷重である。

Type III は、(E)~(J) 層において後件部の計算を行う。図 2.7 の (E)~(F) 層の構成は、図 2.5(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 (2.23) 式右辺の規格化された前件部適合度 $\hat{\mu}_i$ と $\tau_{R_k^i}$ を意味する結合荷重 w_r の積和となり、後件部適合度 μ'_k が求められる。後件部メンバーシップ関数は、この μ'_k より (F)~(H) 層にて

$$B_k^{-1}(\mu'_k) = y = w'_g \mu'_k + w'_c \quad (2.25)$$

すなわち

$$B_k(y) = \mu'_k = \frac{y - w'_c}{w'_g} \quad (2.26)$$

のように実現される。上式より、 $B_k(y)$ は直線であり、その値が 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、

$$\tau_{R_k^i} \in [0, 1], \quad \sum_{i=1}^{n_R} \hat{\mu}_i = 1 \quad (2.27)$$




図 2.7: ファジニューラルネットワーク (Type III)




図 2.8: 後件部メンバーシップ関数

であることから(2.23)式より

$$B_k(y) = \mu'_k \in [0, 1] \quad (2.28)$$

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。Type III では、図 2.8 に示すような互いに補集合に近い関係にある二つの後件部ファジィ変数 B_1, B_2 を用いている。(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 $\hat{\mu}'_k$ 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 法を適用することができる。以上により、(I) 層では各後件部ファジィ変数毎に $\hat{\mu}'_k$ と $B_k^{-1}(\mu'_k)$ が結合され、(2.22)~(2.24) 式に基づく推論値が (J) 層から出力される。

Type III が実現する間接法では、ファジィルール R_i^k における前件部命題の LTV τ_{A_i} に (2.11) 式の $\hat{\mu}_i$ を用いており、また、後件部命題の LTV $\tau_{B_i^k}$ を直接法と同様に

$$\tau_{B_i^k} = \tau_{A_i} \cdot \tau_{R_i^k} \quad (2.29)$$

により計算し、これらを

$$\tau_{B_k} = \sum_{i=1}^{n_R} \tau_{B_i^k} \quad (2.30)$$

のように統合した後で真値限定を行っているとして解釈できる。ここで、 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 Type III の推論法が文献 [18] の制御向けの方法と少し異なっているのは、前件部の構成を直接法に基づく他の FNN と共通にするとともに、(2.28) 式で示したように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。また、文献 [18] では前件部・後件部とも単調なメンバーシップ関数を用いているのに対し、Type III の前件部には擬似台形型メンバーシップ関数が用いられているため、Type III の記述能力が一般によく利用されている直接法に比べて劣ることはない。さらに、文献 [18] のように各ファジィルールの LTV $\tau_{R_i^k}$ を固定せず可変としていることから、 $\tau_{R_i^k}$ を B_k の修飾演算子として解釈することもできる。これについては、2.4.4 項にて詳述する。

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'_o, 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、前件部メンバーシップ関数と同様に w'_o, w'_g を学習で変化させることによって行われる。ただし、本 FNN における後件部メンバーシップ関数は、

単なる直線で表されることから前件部に比べるとネットワークの実現する入出力特性に及ぼす影響が少ないため、特に調整しなくてもよい。一方、 w_r の初期値は (G) 層の規格化ユニットにおける内部関数の分母が 0 に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、以下の Type IV, Type V を含む間接法に基づく FNN も、直接法に基づく FNN と同様に、後件部の構成を増設することにより多出力化が可能であることを述べておく。

2.4.2 後件部ファジィ変数を単純化した

ファジィニューラルネットワーク (Type IV)

Type III が実現する推論法では、各前件部命題に対して後件部命題の異なるファジィルールが二つずつ存在する。従って、同定された入出力関係を把握するためには、前件部命題毎にそれぞれ二つのファジィルールの LTV を比較する必要がある。しかし、学習後の各後件部ファジィ変数は必ずしも補集合の関係にないことから LTV の差が出力値と厳密には一致せず、定性的には容易に理解できても定量的な比較が困難であるという問題を抱えている。そこで本項では、Type III の推論法において同一の前件部命題を持つ二つのファジィルールを一つに集約することにより、同定されたファジィルールを定性的にはもちろん定量的にも明確に把握できる FNN を提案する。この FNN を Type IV と呼ぶ。

図 2.9 は、Type IV の構成例を示す。入出力数および前件部の構成は図 2.7 の Type III と同じであり、図中の記号も同様の意味を持つ。この FNN は、次のような推論法を実現している。

$$R^i : (\text{If } x_1 \text{ is } A_{i,1} \text{ and } x_2 \text{ is } A_{i,2} \text{ then } y \text{ is } B) \text{ is } \tau_{R^i} \quad (2.31)$$

$$(i = 1, 2, \dots, n_R)$$

$$\mu' = \sum_{i=1}^{n_R} \hat{\mu}_i \tau_{R^i} \quad (2.32)$$

$$y^* = B^{-1}(\mu') \quad (2.33)$$

ここで、 B は後件部ファジィ変数、 τ_{R^i} は R^i の LTV、 μ' は B の後件部適合度、 $B^{-1}(\mu')$ は後件部メンバーシップ関数 $B(y)$ の逆関数値である。この $B(y)$ には、同定されたファジィルールの把握のしやすさを考慮して、図 2.10 に示すような単調増加なものを用いている。

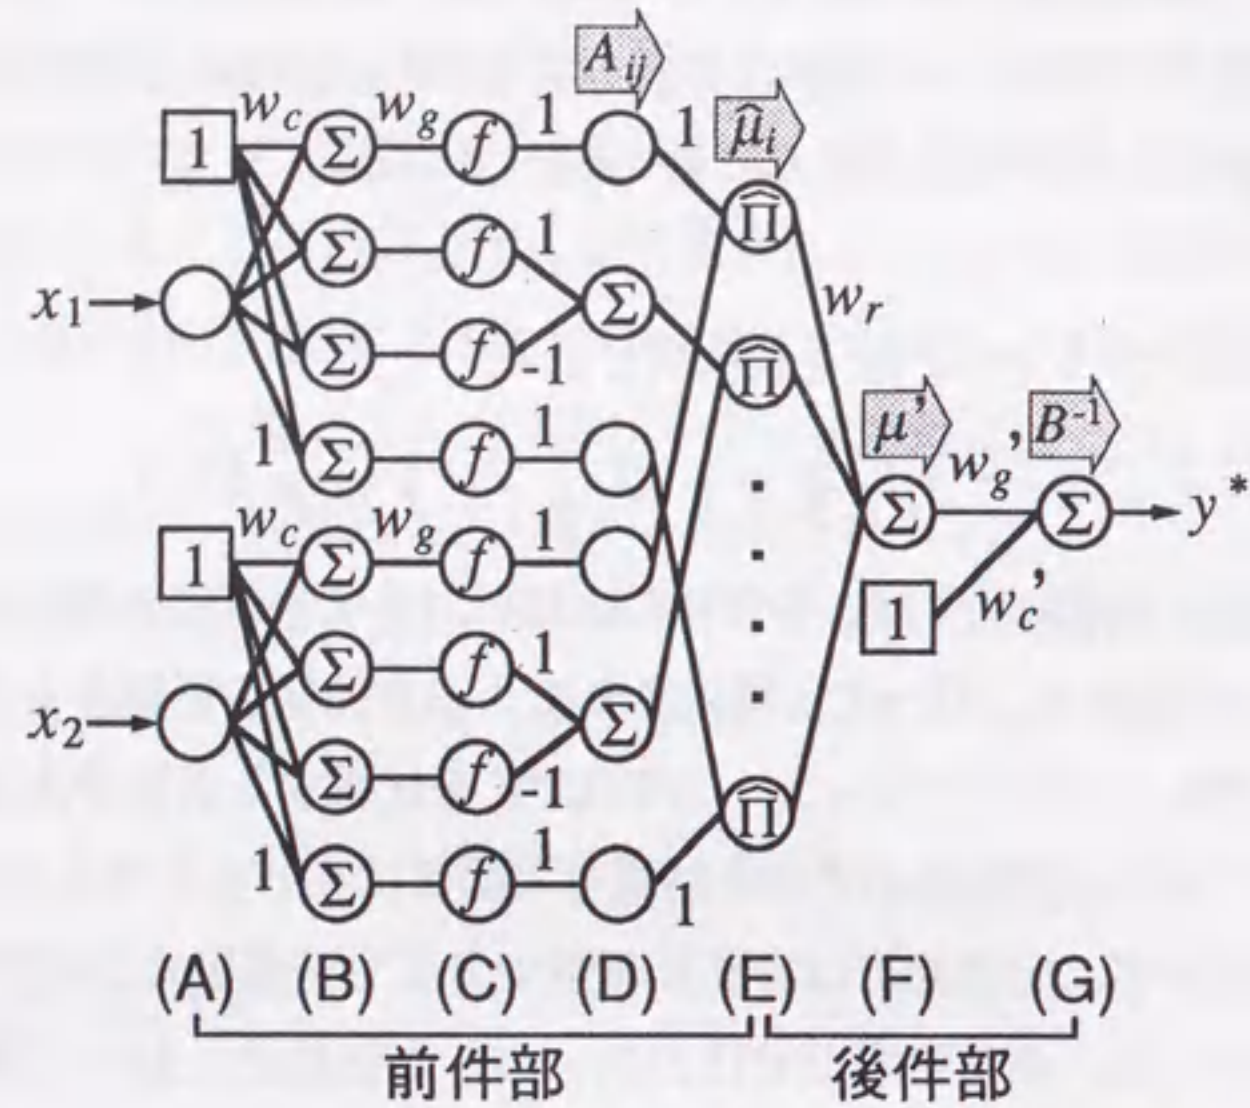


図 2.9: ファジィニューラルネットワーク (Type IV)




図 2.10: 後件部メンバーシップ関数

Type IV では、後件部の計算が (E)~(G) 層において Type III と全く同じように実現されている。すなわち、まず、(2.32) 式の後件部適合度 μ' が、(E) 層の出力である規格化された前件部適合度 $\bar{\mu}_i$ とファジィルールの LTV τ_{R_i} に相当する結合荷重 w_r の積和により (F) 層の出力として計算される。そして、(2.33) 式の後件部メンバーシップ関数の逆関数値 $B^{-1}(\mu')$ が、(F)~(G) 層にて (2.25) 式により求められる。Type IV は、学習についても Type III と同様である。

Type IV の推論法は、Type III において次のような条件を設けることにより導出できる。

$$B_1(y) = 1 - B_2(y) \tag{2.34}$$

$$\tau_{R_1} = 1 - \tau_{R_2} \tag{2.35}$$

上式は、Type III の初期状態における後件部ファジィ変数 B_1, B_2 およびファジィルールの LTV τ_{R_1}, τ_{R_2} の関係から、常に “ $B_1 = \text{not } B_2$ ” かつ “ $\tau_{R_1} = \text{not } \tau_{R_2}$ ” が成り立つことを仮定したものである。ただし、(2.35) 式はファジィ集合間の演算ではなく数値的真理値間の演算を表す。今、 B_2 のメンバーシップ関数が (2.26) 式で定義されているとすると、(2.34) 式より B_1 は

$$B_1(y) = \mu'_1 = \frac{-y + w'_c + w'_g}{w'_g} \tag{2.36}$$

$$B_1^{-1}(\mu'_1) = y = -w'_g \mu'_1 + w'_c + w'_g \tag{2.37}$$

のように表される。従って、(2.23), (2.35) 式より後件部適合度 μ'_1, μ'_2 について

$$\mu'_1 = 1 - \mu'_2 \tag{2.38}$$

の関係が成立することから、(2.24) 式の推論値 y^* は

$$\begin{aligned} y^* &= \frac{\mu'_1(-w'_g \mu'_1 + w'_c + w'_g) + \mu'_2(w'_g \mu'_2 + w'_c)}{\mu'_1 + \mu'_2} \\ &= \frac{(1 - \mu'_2)\{-w'_g(1 - \mu'_2) + w'_c + w'_g\} + \mu'_2(w'_g \mu'_2 + w'_c)}{(1 - \mu'_2) + \mu'_2} \\ &= w'_g \mu'_2 + w'_c \\ &= B_2^{-1}(\mu'_2) \end{aligned} \tag{2.39}$$

となる。ここで、 B_2, τ_{R_2}, μ'_2 をそれぞれ B, τ_{R_i}, μ' と表せば、(2.31)~(2.33) 式 of Type IV の推論法に一致する。Type IV では、すべての前件部命題に対し一つの後件部命題

が対応するため、各ファジィルールの LTV τ_{R^i} によって入出力関係を明確に把握することが可能である。

以上のようにして導かれた Type IV のネットワークは、2.3.1 項で説明した簡略化ファジィ推論に基づく Type I の推論値を (F)~(G) 層の構成により一次変換しているものに過ぎない。しかし、Type I により同定されたファジィルールは後件部が単なる定数で表されるのに対し、Type IV ではファジィ変数を用いて後件部を言語的に記述することができる。また、Type IV は、2.4.4 項で述べるように、ファジィルールの LTV を後件部ファジィ変数の修飾演算子と見なすことでファジィルール全体を言語的に表記でき、より人間にわかりやすい形でファジィルールを表現することが可能となっている。

2.4.3 言語的真理値をファジィ集合とした

ファジィニューラルネットワーク (Type V)

Type III および Type IV の推論法では、各ファジィルールの LTV をシングルトン(確定値)により表している。このような LTV は数値的真理値と等価であるために表現能力が低く、間接法を持つ優れたヒューマン・コンピュータインタラクションの能力を有効かつ十分に活かしているとは言えない。そこで本項では、Type IV の推論法における各ファジィルールの LTV をファジィ集合とすることによって、ファジィルールをより柔軟に表現できる FNN を提案する。この FNN を Type V と呼ぶ。

図 2.11 は、図 2.7 および図 2.9 と同じ場合における Type V の構成例を示す。この FNN が実現する推論法は、次のように表される。

$$R^i : (\text{If } x_1 \text{ is } A_{i,1} \text{ and } x_2 \text{ is } A_{i,2} \text{ then } y \text{ is } B) \text{ is } \tau_{R^i}(t) \quad (2.40)$$

$$(i = 1, 2, \dots, n_R)$$

$$\mu' = \sum_{i=1}^{n_R} \tau_{R^i}^{-1}(\hat{\mu}_i) \quad (2.41)$$

$$y^* = B^{-1}(\mu') \quad (2.42)$$

ここで、(2.40) 式の LTV $\tau_{R^i}(t)$ は

$$\tau_{R^i}(t) = \left(\frac{t}{r}\right)^{r'} \quad (2.43)$$

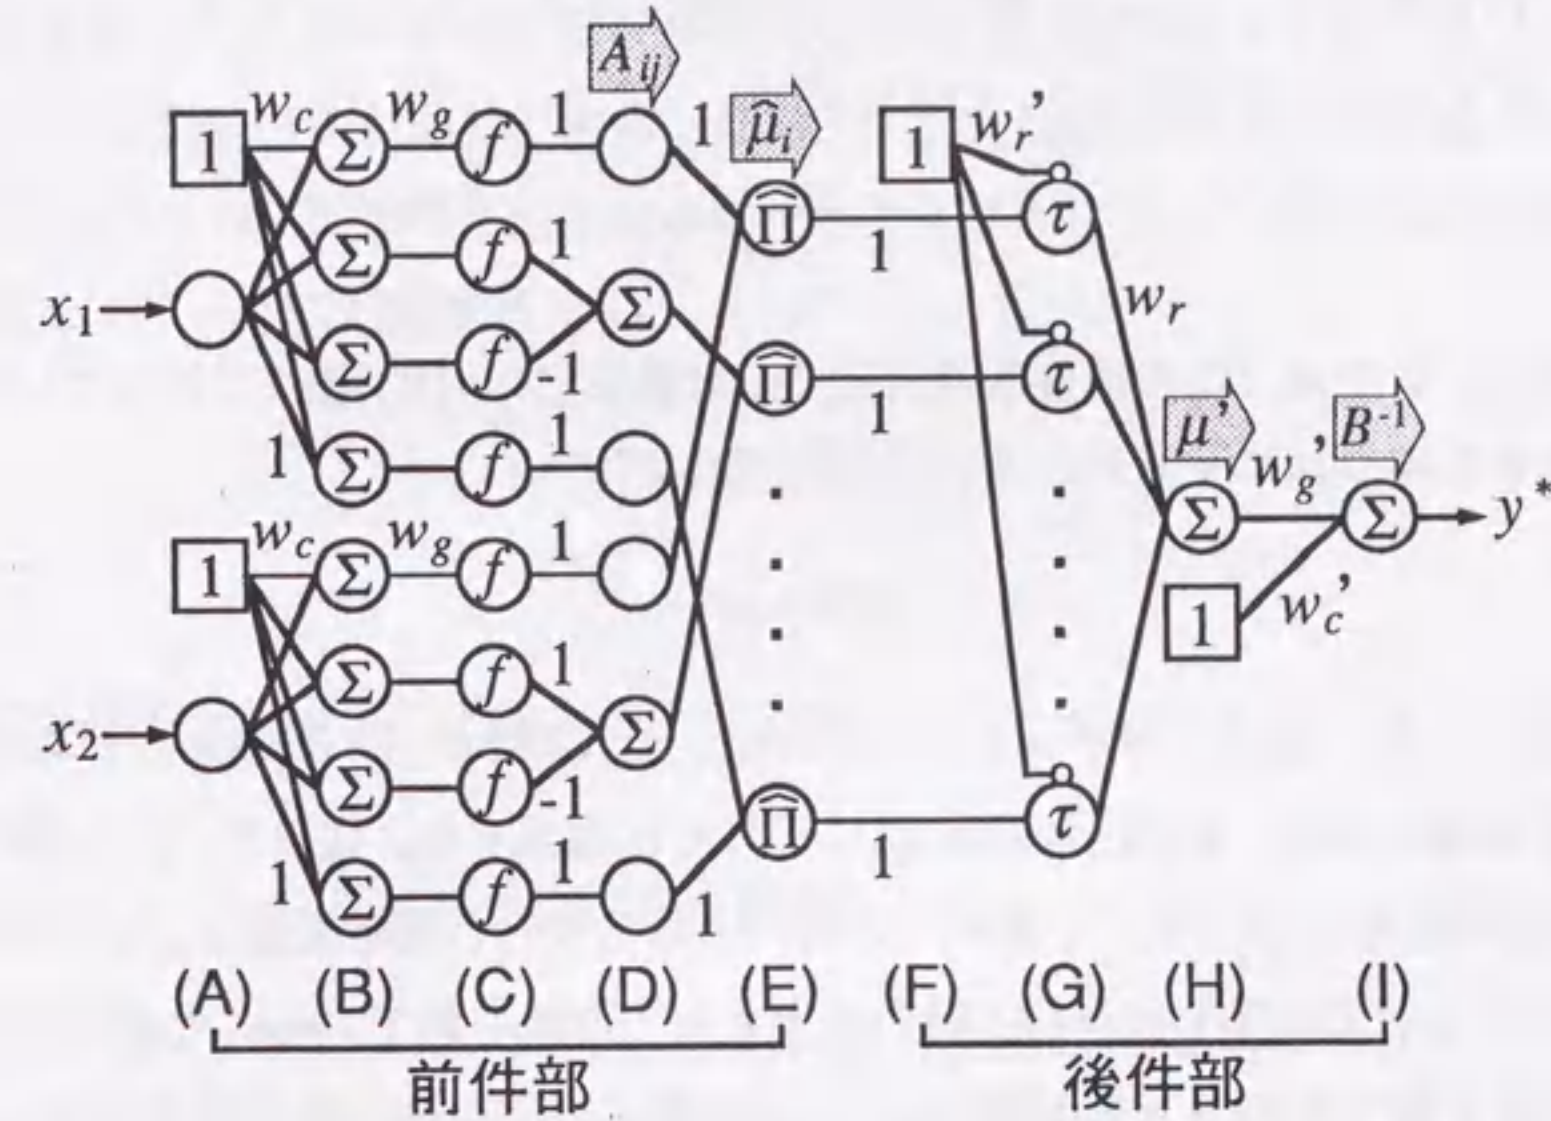


図 2.11: ファジィニューラルネットワーク (Type V)




図 2.12: 言語的真理値

と定義される。図 2.12 は、 $\tau_{R^i}(t)$ のグラフを示す。上式の r, r' は $r \in [0, 1], r' \in [0, \infty]$ の可変パラメータとなっており、 $\tau_{R^i}(t)$ は $r=r'=1$ のとき “true”、 $r=1$ かつ $r'=\infty$ のとき “absolutely true” のように図 1.4 に示した代表的な LTV と対応する。

Type V の後件部は、(F)~(I) 層において実現される。(2.43) 式の各ファジィルールに対する LTV $\tau_{R^i}(t)$ の定義より、(2.41) 式は

$$\mu' = \sum_{i=1}^{n_R} r \hat{\mu}_i^{(1/r')} \quad (2.44)$$

となる。Type V では、この後件部適合度 μ' の計算を (E)~(H) 層にて行っている。(G) 層の r の記号を持つユニットは、その入出力関係が

$$O_j^{(n)} = I^\Phi \quad (2.45)$$

のように表される。図 2.11 のネットワークでは、上式の I が (E) 層の出力である規格化された前件部適合度 $\hat{\mu}_i$ 、 Φ が結合荷重 w_r にそれぞれ相当する。従って、(G) 層の出力と結合荷重 w_r の積和が (H) 層にて求められていることから、結合荷重 w_r, w_r' がそれぞれ (2.44) 式の $r, 1/r'$ に対応し μ' が (H) 層の出力として計算されていることがわかる。(G) 層の r の記号を持つユニットを LTV ユニットと呼ぶ。(H)~(I) 層の構成は Type IV において後件部メンバーシップ関数の逆関数を実現する (F)~(G) 層と全く同様であり、(2.42) 式の推論値 y^* が (I) 層から出力される。

Type V が実現する間接法では、ファジィルール R^i における後件部命題の LTV τ_{B_i} の計算方法が Type III および Type IV とは異なったものとなっている。すなわち、Type V では、 R^i の LTV $\tau_{R^i}(t)$ を τ_{B_i} から前件部命題の LTV τ_{A_i} への写像と捉え、 τ_{B_i} を

$$\tau_{B_i} = \tau_{R^i}^{-1}(\tau_{A_i}) \quad (2.46)$$

により求めている。ただし、上式では τ_{A_i}, τ_{B_i} を数値的真理値として取り扱っている。Type V の推論法は、 $\tau_{R^i}(t)$ が t に対し単調増加であることから、(2.46) 式より前件部命題とファジィルールそのものの真理度が高いほど後件部命題の真理度も高いという考え方に基づいている。また、Type V では、(2.44) 式の $1/r'$ に相当する結合荷重 w_r' の値によって後件部適合度 μ' が 1 よりも大きな値をとる可能性がある。このような場合、(2.28) 式のように後件部メンバーシップ関数の存在を保証することができず、(2.42) 式による推論値 y^* は学習データにおける出力値の範囲から定められた台集合の最大値より大きな値となる。しかし、本 FNN の学習に用いる BP 法は基本的に出力誤差を最小

化するためのものであるため、 y^* があらかじめ設定した台集合から大きく外れることはなく実用上は特に問題はないと考えられる。

Type V では、結合荷重 w_r, w_r' の初期値をそれぞれ 0.5, 1 として、これらを学習により変化させることでファジィルールの同定を行う。後件部メンバーシップ関数の調整については Type IV と同じである。なお、入出力関係が (2.45) 式で表される (G) 層の LTV ユニットは、2 種類の入力 I, Φ がそれぞれ規格化された前件部適合度 $\hat{\mu}_i \in [0, 1]$ 、結合荷重 $w_r' \in [0, \infty]$ に対応するため

$$\frac{\partial O_j^{(n)}}{\partial I} = \Phi I^{(\Phi-1)} \geq 0 \quad (2.47)$$

$$\frac{\partial O_j^{(n)}}{\partial \Phi} = I^\Phi \ln(I) \leq 0 \quad (2.48)$$

のように単調性を満たすことから BP 法を用いることができる。

2.4.4 ファジィルールの言語的表記

Type IV の結合荷重 w_r は、前述したように間接法における各ファジィルールの LTV に対応するが、後件部命題の述語修飾演算子とも解釈できる^[46]。 w_r を LTV と見た場合、シングルトン (確定値) で表されることから言語ラベルの付与が難しいという問題があるのに対し、述語修飾演算子とすれば、同定されたファジィルールをより言語的にわかりやすく表記することができる。この手法は、文献 [18] の制御向けに簡略化された間接法と同様に、本 FNN における前件部命題と後件部命題の LTV すなわち規格化された前件部適合度と後件部適合度が一致すると見なすことによって導かれる。

今、Type IV において、ある一つのファジィルールの前件部適合度に比べ他のファジィルールのそれがすべて無視できるとすると、(2.33), (2.32) 式より推論値 y^* は

$$y^* \simeq B^{-1}(\hat{\mu} \cdot \tau_R) \quad (2.49)$$

となる。ただし、上式では簡単のためルール番号を省略している。このとき、後件部メンバーシップ関数の逆関数 $B^{-1}(\cdot)$ が (2.25) 式で定義されることから、

$$B^{-1}(\hat{\mu} \cdot \tau_R) = y = w_g'(\hat{\mu} \cdot \tau_R) + w_c' \quad (2.50)$$

より後件部メンバーシップ関数 $B(y)$ が

$$B(y) = \hat{\mu} = \frac{y - w_c'}{w_g' \cdot \tau_R} \quad (2.51)$$

と表されているのと等価である。ここで、文献[18]の間接法と同様に、規格化された前件部適合度 $\hat{\mu}$ を後件部適合度と見なせば、ファジイルールのLTV τ_R は後件部ファジイ変数 B の修飾演算子として(2.43)式の r と同じく $B(y)$ の傾きを変化させていると考えられる。従って、 τ_R が定める $B(y)$ の形状に応じて適当な言語ラベルを与えれば、同定されたファジイルール全体を言語的に表記することができる。

例えば後件部ファジイ変数 $B=Big$ の場合、(2.51)式よりそのメンバーシップ関数 $B(y)$ が各ファジイルールのLTV τ_R の値によって図2.13(a)のように変化することから、

$$\left. \begin{array}{l} \tau_R < 0.125 \cdots S : \text{Small} \\ 0.125 \leq \tau_R < 0.375 \cdots MS : \text{Medium Small} \\ 0.375 \leq \tau_R < 0.625 \cdots M : \text{Medium} \\ 0.625 \leq \tau_R < 0.875 \cdots MB : \text{Medium Big} \\ 0.875 \leq \tau_R \cdots B : \text{Big} \end{array} \right\} \quad (2.52)$$

と B を変換することができる。これらの言語ラベルは、それぞれの場合において $B(y)$ が高いグレードをとる y の値を考慮してつけたものである。同様にして $B=Positive$ の場合には、図2.13(b)より

$$\left. \begin{array}{l} \tau_R < 0.083 \cdots NB : \text{Negative Big} \\ 0.083 \leq \tau_R < 0.25 \cdots NM : \text{Negative Medium} \\ 0.25 \leq \tau_R < 0.417 \cdots NS : \text{Negative Small} \\ 0.417 \leq \tau_R < 0.583 \cdots ZO : \text{Zero} \\ 0.583 \leq \tau_R < 0.75 \cdots PS : \text{Positive Small} \\ 0.75 \leq \tau_R < 0.917 \cdots PM : \text{Positive Medium} \\ 0.917 \leq \tau_R \cdots PB : \text{Positive Big} \end{array} \right\} \quad (2.53)$$

のように表記することが可能である。ただし、図2.13(b)では台集合を区間 $[-1, 1]$ に規格化している。なお、(2.52), (2.53)式は言語ラベルの分類方法について一例を示しただけであり、場合に応じて各ラベルに相当する τ_R の範囲を適当に変えることにより人間の直感によく合った言語的表記が実現できる。

Type IIIでは、一つの前件部命題に対し、“ y is Big”と“ y is Small”あるいは“ y is Positive”と“ y is Negative”のような互いに補集合に近い関係にある後件部命題を持つ二つのファジイルールが存在する。Type IVの推論法は、これらの後件部ファジイ変数およびLTVが完全に正反対の意味あいを持つとして導出したものであるが、Type IIIの学習後においてもその(2.34), (2.35)式の関係がほぼ成立する。すなわち、後件部ファジイ変数がBig, SmallであるファジイルールのLTVを τ_B, τ_S 、Positive, Negative


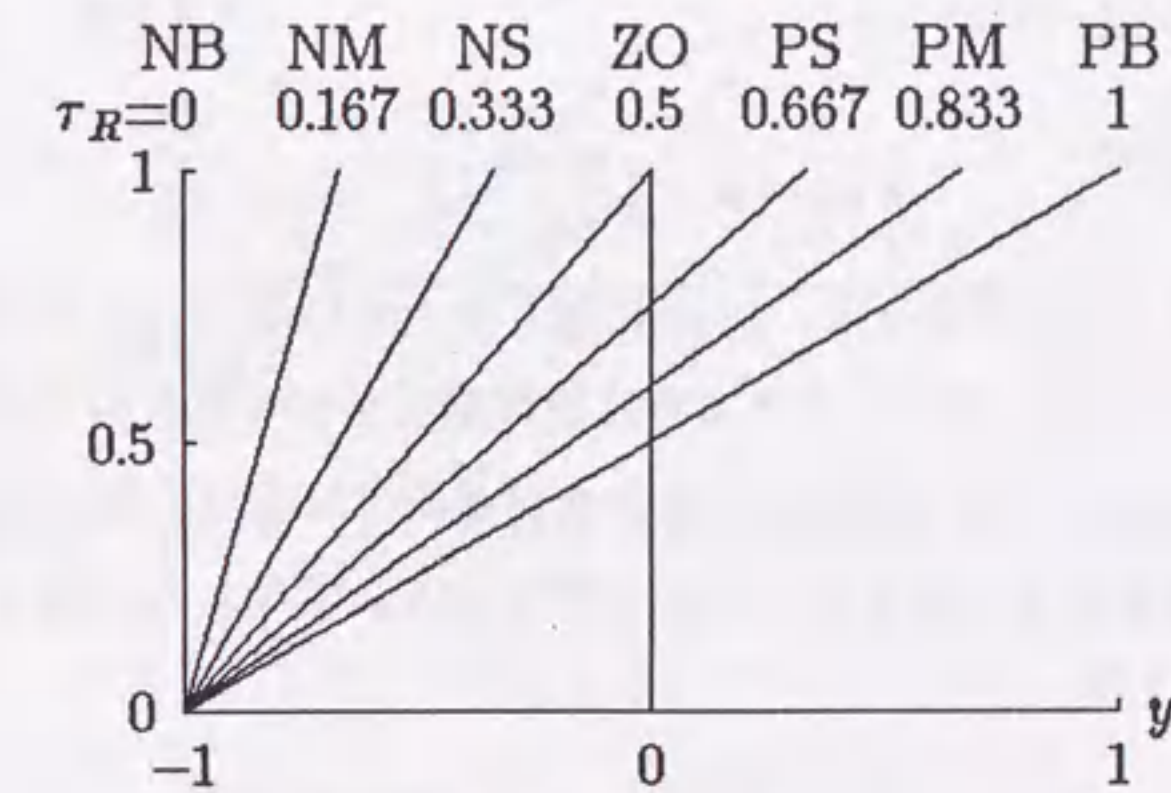
(a) $B = \text{Big}$ (b) $B = \text{Positive}$

図 2.13: ファジイルールの言語的表記

であるファジィルールの LTV を τ_P, τ_N とすると、それぞれ

$$\tau_B \simeq 1 - \tau_S \quad (2.54)$$

$$\tau_P \simeq 1 - \tau_N \quad (2.55)$$

のような関係にある。従って、(2.52), (2.53) 式の τ_R の代わりに (2.54), (2.55) 式を用いることにより、同じ前件部命題を持つ二つのファジィルールを Type IV と同様な言語的表記された一つのファジィルールにまとめることができる。ただし、Type III では、(2.54), (2.55) 式の関係を経験的には満足しないため、例えば τ_B と $1 - \tau_S$ で該当する言語ラベルが異なりファジィルールを変換できないことがある。

一方、Type V では、(2.49) 式と同じ仮定において、推論値 y^* が (2.42), (2.44) 式より

$$y^* \simeq B^{-1}(r\hat{\mu}^{(1/r')}) \quad (2.56)$$

のように表される。従って、後件部メンバーシップ関数 $B(y)$ は、

$$B^{-1}(r\hat{\mu}^{(1/r')}) = y = w'_g(r\hat{\mu}^{(1/r')}) + w'_c \quad (2.57)$$

から

$$B(y) = \hat{\mu} = \left(\frac{y - w'_c}{w'_g \cdot r} \right)^{r'} \quad (2.58)$$

と見なすことができる。上式の r は、 $B(y)$ に対して (2.51) 式の τ_R と同じ働きを持つため、その値に応じて (2.52), (2.53) 式のように後件部ファジィ変数 B を変換することができる。さらに、Type V により同定されたファジィルールは、(2.58) 式の r' の値によって各言語ラベルに修飾語を付加することが可能である。すなわち、図 2.14 に示すように、 r' の値により例えば

$$\left. \begin{array}{l} 0 < r' \leq 0.375 \cdots (\text{more or less})^2 \\ 0.375 < r' \leq 0.75 \cdots \text{more or less} \\ 1.5 \leq r' < 3 \cdots \text{very} \\ 3 \leq r' \cdots (\text{very})^2 \end{array} \right\} \quad (2.59)$$

と言語ヘッジを与えることができる。ただし、図 2.14 は $B = \text{Big}$, $r = 0.75$ の場合を表し、 $r' = 0$ の場合は “undefined” となる。

以上の手法は必ずしも厳密なものではなく、得られたファジィルールは直接法におけるものと全く同じ形式となっている。しかし、本手法によれば本 FNN により獲得さ

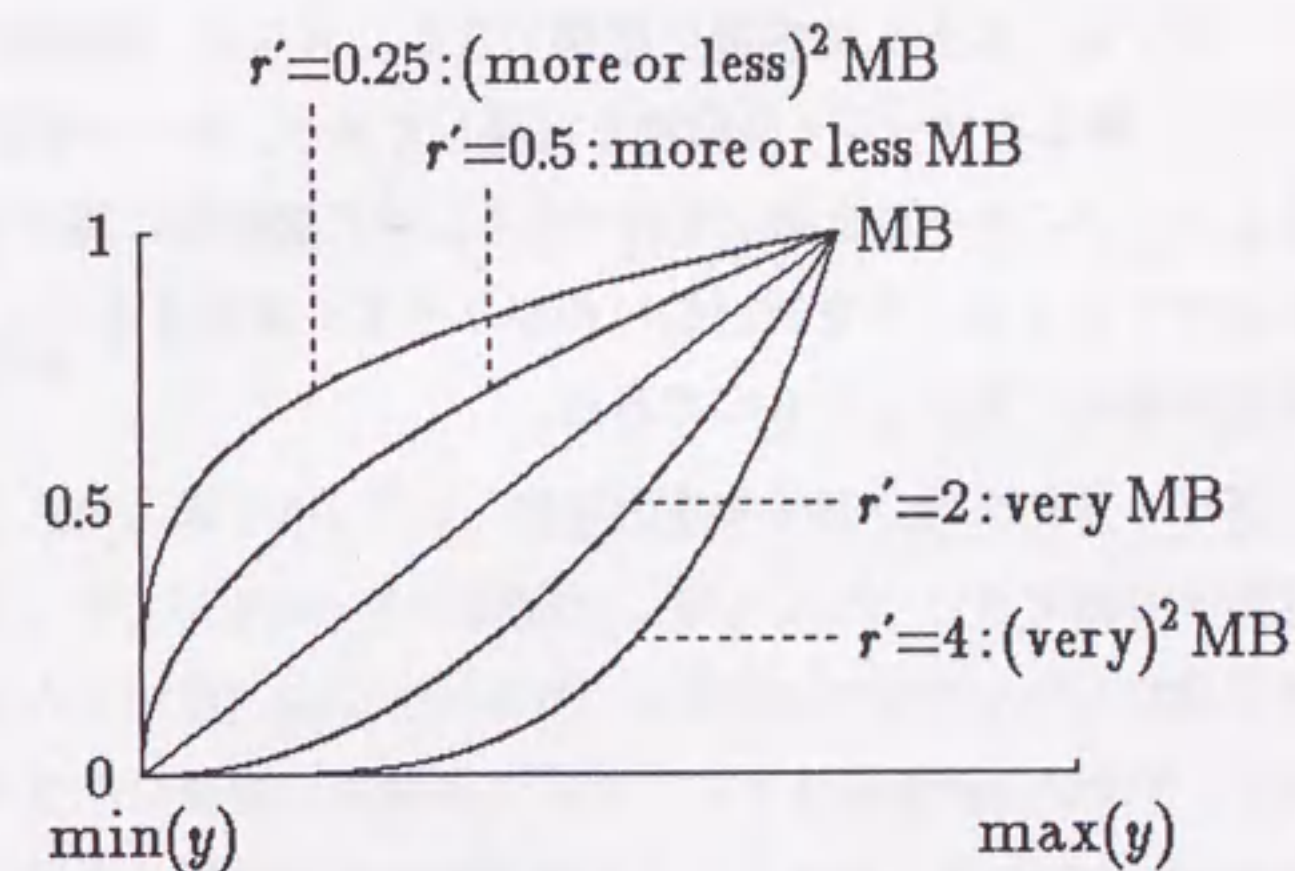


図 2.14: Type V における言語ヘッジの付与 ($B = \text{Big}$, $r = 0.75$)

れたファジィルールを言語的にわかりやすく表記することができ、その有用性は極めて高い。また、この特徴は本FNNが間接法に基づいていることによって可能となり、ファジィルールの理解を容易にしている点は間接法の大きな利点と言える。

2.5 まとめ

本章では、NNの学習機能によりファジィ推論における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る5種類の新しいFNNを提案した。本FNNの前件部メンバーシップ関数は、学習において他のメンバーシップ関数よりも優れた特徴を持つ。また、本FNNはファジィ推論をBPモデルの構造で実現しており、学習結果をファジィルールとして容易に把握できる。さらに、本研究で提案した5種類のFNNは互いに異なるファジィ推論法を実現しており、同一の学習データに対しそれぞれ特徴あるファジィルールを同定可能である。特に間接法に基づくFNNは興味深く、同定されたファジィルールを言語的にわかりやすく表記することができる。この特徴は、本研究が初めて見出したものである。

第3章

ファジィニューラルネットワークの学習法

3.1 はじめに

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BP法を用いるが、本FNNではファジィ推論をネットワークの構造で実現するために特殊な演算を行うユニットを多数用いており、BP法についても通常のNNとは異なる独自のものが必要となる。また、本FNNの結合荷重はすべて明確な役割を持ち、初期設定の段階よりそれぞれの値が大きく異なることから、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という問題が存在する。そこで本章では、本FNNにおけるBP法を導出するとともに、学習時の学習率設定に対する煩雑さを低減する手法について説明する。さらに、本FNNのネットワークの規模について考察を行い、その実現可能性を検証する^[39]。

3.2 バックプロパゲーション法

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。

$$E_p = \frac{1}{2} \sum_j (y_{pj} - y_{pj}^*)^2 \quad (3.1)$$

$$E = \sum_{p=1}^N E_p \quad (3.2)$$

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、(3.2) 式の学習データ全体による出力誤差 E を最小化するため、(3.1) 式で表される 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 $w_{ji}^{(n)}$ の更新量 $\Delta w_{ji}^{(n)}$ を

$$\Delta w_{ji}^{(n)} \propto -\frac{\partial E_p}{\partial w_{ji}^{(n)}} \quad (3.3)$$

のように定めればよい。上式の右辺は、(2.3), (2.4) 式等における $w_{ji}^{(n)}$ の定義より

$$-\frac{\partial E_p}{\partial w_{ji}^{(n)}} = -\frac{\partial E_p}{\partial I_j^{(n)}} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} \quad (3.4)$$

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

$$\begin{aligned} \frac{\partial I_j^{(n)}}{\partial w_{ji}^{(n)}} &= \frac{\partial}{\partial w_{ji}^{(n)}} \sum_k w_{jk}^{(n)} O_k^{(n-1)} \\ &= O_i^{(n-1)} \end{aligned} \quad (3.5)$$

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

$$\delta_j^{(n)} = -\frac{\partial E_p}{\partial I_j^{(n)}} \quad (3.6)$$

と定義する^[5]と、(3.3) 式は

$$\Delta w_{ji}^{(n)} \propto \delta_j^{(n)} O_i^{(n-1)} \quad (3.7)$$

のように表される。(3.6) 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 法に基づく学習は、この $\delta_j^{(n)}$ を出力層から入力層に向かって逆伝播させ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。

(3.6) 式は、一般に次のように変形できる。

$$\delta_j^{(n)} = -\sum_m \frac{\partial E_p}{\partial O_m^{(n)}} \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \quad (3.8)$$

$$= -\sum_m \left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_m^{(n)}} \right) \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \quad (3.9)$$

(3.8), (3.9) 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 (2.3) 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 (3.8), (3.1) 式より

$$\begin{aligned} \delta_j^{(n)} &= -\frac{\partial E_p}{\partial O_j^{(n)}} \frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} \\ &= -\frac{\partial}{\partial y_{pj}^*} \left\{ \frac{1}{2} \sum_k (y_{pk} - y_{pk}^*)^2 \right\} \frac{\partial}{\partial I_j^{(n)}} I_j^{(n)} \\ &= y_{pj} - y_{pj}^* \end{aligned} \quad (3.10)$$

となる。

一方、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 (2.4) 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、(3.9), (3.6) 式より、次層のユニットの入力が和で表されるとき

$$\begin{aligned} \delta_j^{(n)} &= -\left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_j^{(n)}} \right) \frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} \\ &= \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_j^{(n)}} \sum_i w_{ki}^{(n+1)} O_i^{(n)} \right) \frac{\partial}{\partial I_j^{(n)}} f(I_j^{(n)}) \\ &= f'(I_j^{(n)}) \sum_k \delta_k^{(n+1)} w_{kj}^{(n+1)} \end{aligned} \quad (3.11)$$

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

$$\begin{aligned} \delta_j^{(n)} &= -\left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_j^{(n)}} \right) \frac{\partial O_j^{(n)}}{\partial I_j^{(n)}} \\ &= \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_j^{(n)}} \prod_i w_{ki}^{(n+1)} O_i^{(n)} \right) \frac{\partial}{\partial I_j^{(n)}} f(I_j^{(n)}) \\ &= f'(I_j^{(n)}) \sum_k \delta_k^{(n+1)} w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} \end{aligned} \quad (3.12)$$

となる。ここで、 $f(\cdot)$ はユニットが持つ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、入出力関係が(2.45)式で表されるLTVユニットでは、二つの入力 I, Φ についてそれぞれ $f(\cdot)$ が(2.47), (2.48)式で求められる。また、その他のユニット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(2.8)式で定義さ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

$$\begin{aligned}
 \delta_j^{(n)} &= -\sum_m \left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_m^{(n)}} \right) \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \\
 &= \sum_m \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_m^{(n)}} \sum_i w_{ki}^{(n+1)} O_i^{(n)} \right) \frac{\partial}{\partial I_j^{(n)}} \left(\frac{I_m^{(n)}}{\sum_l I_l^{(n)}} \right) \\
 &= \sum_k \delta_k^{(n+1)} \left(\frac{w_{kj}^{(n+1)} \sum_l I_l^{(n)} - I_j^{(n)}}{\left(\sum_l I_l^{(n)} \right)^2} - \sum_{m \neq j} w_{km}^{(n+1)} \frac{I_m^{(n)}}{\left(\sum_l I_l^{(n)} \right)^2} \right) \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} \sum_l I_l^{(n)} - \sum_m w_{km}^{(n+1)} I_m^{(n)}}{\left(\sum_l I_l^{(n)} \right)^2} \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} - \sum_m w_{km}^{(n+1)} O_m^{(n)}}{\sum_l I_l^{(n)}} \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} - I_k^{(n+1)}}{\sum_l I_l^{(n)}} \tag{3.13}
 \end{aligned}$$

となり、次層のユニットの入力が積で表されるときには

$$\begin{aligned}
 \delta_j^{(n)} &= -\sum_m \left(\sum_k \frac{\partial E_p}{\partial I_k^{(n+1)}} \frac{\partial I_k^{(n+1)}}{\partial O_m^{(n)}} \right) \frac{\partial O_m^{(n)}}{\partial I_j^{(n)}} \\
 &= \sum_m \left(\sum_k \delta_k^{(n+1)} \frac{\partial}{\partial O_m^{(n)}} \prod_i w_{ki}^{(n+1)} O_i^{(n)} \right) \frac{\partial}{\partial I_j^{(n)}} \left(\frac{I_m^{(n)}}{\sum_l I_l^{(n)}} \right)
 \end{aligned}$$

$$\begin{aligned}
 &= \sum_k \delta_k^{(n+1)} \left(\frac{w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} \sum_l I_l^{(n)} - I_j^{(n)}}{\left(\sum_l I_l^{(n)} \right)^2} \right. \\
 &\quad \left. - \sum_{m \neq j} w_{km}^{(n+1)} \prod_{i \neq m} w_{ki}^{(n+1)} O_i^{(n)} \frac{I_m^{(n)}}{\left(\sum_l I_l^{(n)} \right)^2} \right) \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} \sum_l I_l^{(n)} - \sum_m w_{km}^{(n+1)} \prod_{i \neq m} w_{ki}^{(n+1)} O_i^{(n)} I_m^{(n)}}{\left(\sum_l I_l^{(n)} \right)^2} \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} - \sum_m w_{km}^{(n+1)} \prod_{i \neq m} w_{ki}^{(n+1)} O_i^{(n)} O_m^{(n)}}{\sum_l I_l^{(n)}} \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} - \sum_m \prod_i w_{ki}^{(n+1)} O_i^{(n)}}{\sum_l I_l^{(n)}} \\
 &= \sum_k \delta_k^{(n+1)} \frac{w_{kj}^{(n+1)} \prod_{i \neq j} w_{ki}^{(n+1)} O_i^{(n)} - \sum_m I_m^{(n+1)}}{\sum_l I_l^{(n)}} \tag{3.14}
 \end{aligned}$$

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(3.11), (3.12)式の和で求められる。

各結合荷重は、(3.10)~(3.14)式の結果から、(3.7)式に従い

$$w_{ji}^{(n)}(m+1) = w_{ji}^{(n)}(m) + \eta \delta_j^{(n)} O_i^{(n-1)} \tag{3.15}$$

と更新する。ここで、 m は更新回数、 η は学習率である。

3.3 学習率の設定

本FNNの学習には以上のようなBP法を用いるが、(3.7)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特定の意味を持つため、その用い方により各結合荷重の値が互いに大きく異なる。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の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う場合、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なってしまうことから、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

$$\eta = \eta' \kappa \quad (3.16)$$

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。結合荷重 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、入力変数毎に前件部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、前件部メンバーシップ関数の間隔を κ に入れることでメンバーシップ関数の w_c による形状変化がその間隔に比例し、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。これらは、本FNNのネットワークの構成から、 $\delta_j^{(C)}$ の値が入力変数によらずほぼ同等の値となることに着目したものである。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。Type IVでは $\delta_j^{(G)}$ 、Type Vでは $\delta_j^{(I)}$ がそれぞれ κ を求める基準となる。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することができる。

また、前件部の結合荷重 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。

$$w_{ji}^{(n)}(m+1) = w_{ji}^{(n)}(m) + \eta \delta_j^{(n)} |w_{ji}^{(n)}(m)| O_i^{(n-1)} \quad (3.17)$$

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2.3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、(3.17)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、適切な学習率の選定が容易になる。これによって2.2.1項で指摘した問題点(iii)が改善されるが、学習率の値が大き過ぎる場合には原理的に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が避けられない。なお、次章以降に示す学習率はすべて(3.16)式の見かけの学習率 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学習率 η 自身を表す。

3.4 ネットワークの規模と実現可能性

NNの学習則としてBP法を用いた場合、ネットワークの規模によっては出力誤差が収束するまでに膨大な時間を必要とすることが指摘されている。そこで本節では、本FNNのネットワークの規模と実現可能性について考察する。

一般に、本FNNのノード数(全結合荷重数) 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、第2章の構成例に従うとそれぞれ次のように求められる。

$$\text{前件部} : n_N = \sum_{j=1}^{n_{in}} (8m_j - 8) + n_{in} n_R \quad (3.18)$$

$$n_U = \sum_{j=1}^{n_{in}} (5m_j - 2) + n_R \quad (3.19)$$

$$n_W = \sum_{j=1}^{n_{in}} (4m_j - 4) \quad (3.20)$$

$$\text{Type Iの後件部} : n_N = n_{out} n_R \quad (3.21)$$

$$n_U = n_{out} \quad (3.22)$$

$$n_W = n_{out} n_R \quad (3.23)$$

$$\text{Type II の後件部 : } n_N = n_{out}\{n'_{in} + 3n_R(n'_{in} + 2)\} \quad (3.24)$$

$$n_U = n_{out}\{2n'_{in} + 2n_R(n'_{in} + 2) + 2\} \quad (3.25)$$

$$n_W = n_{out}n_R(n'_{in} + 1) \quad (3.26)$$

$$\text{Type III の後件部 : } n_N = n_{out}(2n_R + 12) \quad (3.27)$$

$$n_U = 10n_{out} \quad (3.28)$$

$$n_W = n_{out}(2n_R + 4) \quad (3.29)$$

$$\text{Type IV の後件部 : } n_N = n_{out}(n_R + 2) \quad (3.30)$$

$$n_U = 3n_{out} \quad (3.31)$$

$$n_W = n_{out}(n_R + 2) \quad (3.32)$$

$$\text{Type V の後件部 : } n_N = n_{out}(3n_R + 2) \quad (3.33)$$

$$n_U = n_{out}(n_R + 4) \quad (3.34)$$

$$n_W = n_{out}(2n_R + 2) \quad (3.35)$$

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(2.12)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 では、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、ノード数 n_N 、ユニット数 n_U に比べて結合荷重数 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 3 入力 1 出力の場合における図 2.6(b) の構成は $n_W=52$ より中間層のユニット数が 13 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いことがわかる。また、本 FNN において計算時間に占める割合の高い演算は、(C) 層の前件部メンバーシップ関数を構成するシグモイド関数と Type V の後件部 (G) 層の LTV ユニットにおけるべき乗関数の二つであり^[39]、すべてのユニットが内部関数としてシグモイド関数を持つ n_W の等しい BP モデルよりは確実に一回当たりの計算時間が短い。もちろん、本 FNN はネットワークを構成する層の数が多いことから学習時の誤差の逆伝播には通常の BP モデルよりも時間がかかるが、本 FNN のような各結合荷重に明確な意味が与えられているネットワークは学習による出力誤差の収束速度が 3 層 BP モデル

に比べて速いという報告もあり^[34]、本 FNN は大規模な問題においても十分実用的であると思われる。

3.5 まとめ

本章では、本 FNN の学習法について説明した。本 FNN は、学習則として BP 法を用いているが、ファジィ推論を実現するために特殊なユニットによりネットワークを構成しており、BP 法におけるデルタルールも一般的な NN とは一部異なったものとなる。また、本 FNN の結合荷重はすべて特定の意味を持つことから、適切な学習を行うには各結合荷重の学習率の選定に多大な労力が必要とされる。この問題に対して学習率設定における煩雑さを低減する手法を説明し、さらに、通常の BP モデルとの比較から本 FNN が大規模な問題においても十分実用的であることを示した。

第4章

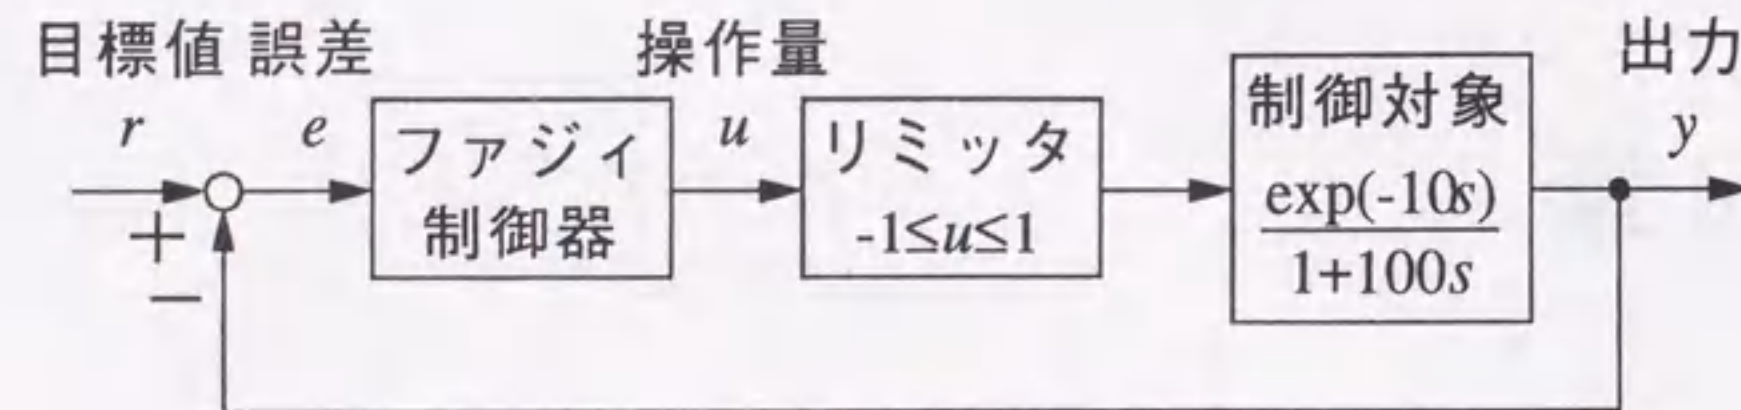
ファジィ制御への応用

4.1 はじめに

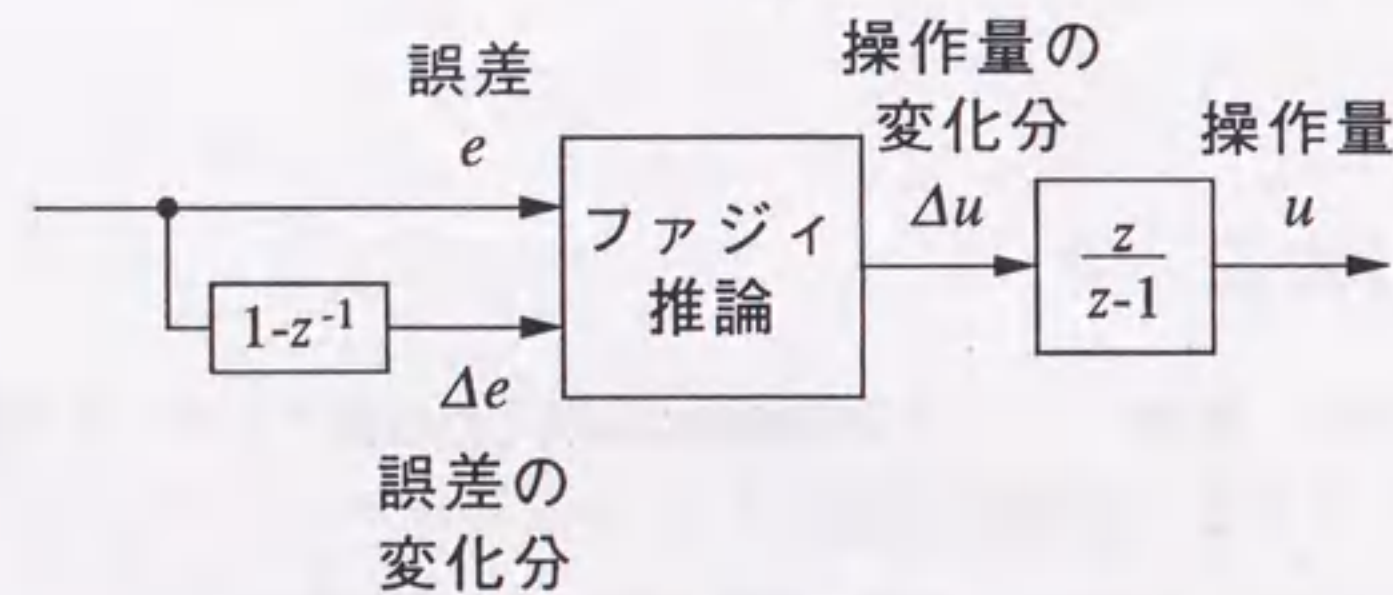
ファジィ制御は、熟練オペレータが経験的に体得した制御アルゴリズムを If-then 型のファジールールにより言語的に記述できる、ヒューマン・コンピュータインタラクションに優れた制御法である。しかし、熟練オペレータの操作は、オペレータ自身が意識していない知識や判断に基づいて行われる場合が多く、それらをファジールールとして正確に記述するためには一般に多大な労力を必要とする。また、ファジールールを同定した後のメンバーシップ関数等のパラメータ調整には、ファジィ制御に関する専門的な知識が不可欠とされ、試行錯誤により膨大な時間が費やされることも少なくない。本研究で提案した FNN は、NN の学習機能によりファジー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る。そこで本章では、むだ時間を持つ一次遅れ系を制御対象として、熟練オペレータが持つ制御アルゴリズムを非明示的に含むと考えられるオペレータの操作パターンを本 FNN に学習させることによりファジィ制御器を構成するシミュレーションを行う^{[44][45]}。

4.2 むだ時間を持つ一次遅れ系のファジィ制御

図 4.1 は、本章のシミュレーションに用いたシステム構成を示す。(a) はファジィ制御系全体の構成、(b) はファジィ制御器の構造を示したものである。制御対象の時定数とむだ時間はそれぞれ 100, 10 であり、これらはサンプリング時間を 1 として無名数



(a) ファジィ制御系の構成



(b) ファジィ制御器の構造

図 4.1: むだ時間を持つ一次遅れ系のファジィ制御




図 4.2: 熟練オペレータによる制御例

(左 : オペレータの操作波形
右 : オペレータの操作に対応する制御対象の出力波形)

化されている。また、ファジィ制御器は、入力を目標値 r と制御対象の出力 y との誤差 e およびその変化分 Δe 、出力を操作量 u の変化分 Δu とする 2 入力 1 出力の構造を持つ。ただし、 e 、 Δe 、 Δu はそれぞれ次のように計算した。

$$e_t = r_t - y_t \quad (4.1)$$

$$\Delta e_t = e_t - e_{t-1} \quad (4.2)$$

$$\Delta u_t = u_t - u_{t-1} \quad (4.3)$$

ここで、添え字 t 、 $t-1$ はサンプリング時刻を表す。このファジィ制御器は、速度型の制御アルゴリズムに基づくものであり、入力 e と出力 Δu が積分の関係に相当し Δe と Δu が比例の関係に相当することからファジィPI 制御とも呼ばれる^[1]。各変数に対するメンバーシップ関数は、 e 、 Δe 、 Δu と

$$\left. \begin{array}{l} \text{NB : Negative Big} \\ \text{NM : Negative Medium} \\ \text{NS : Negative Small} \\ \text{ZO : Zero} \\ \text{PS : Positive Small} \\ \text{PM : Positive Medium} \\ \text{PB : Positive Big} \end{array} \right\} \quad (4.4)$$

の言語ラベルを持つ 7 種類を用いている。

図 4.1 の制御対象において、熟練オペレータは、目標値 0.2, 0.4, 0.6, 0.8 に対し望ましい応答を得るように例えば図 4.2 に示すような制御を行う。図中左側が熟練オペレータの操作波形を示し、右側がそれに対応する制御対象の出力波形を示す。熟練オペレータは、時刻 0 にてステップ的に変化する各目標値に対し操作量をリミッタの制限値 1 まで急速に立ち上げ、制御対象の出力が目標値に近づいた時点で操作量を目標値まで減少させている。その結果、制御対象の出力は立ち上がり時間が短くオーバーシュートのない良好な波形となっている。

この制御アルゴリズムをファジィルールにより記述すると

$$\text{If } e \text{ is PB and } \Delta e \text{ is ZO then } \Delta u \text{ is PB} \quad (4.5)$$

$$\text{If } e \text{ is ZO and } \Delta e \text{ is NB then } \Delta u \text{ is NB} \quad (4.6)$$

のようになる。すなわち、(4.5) 式のファジィルールは、操作量の立ち上げの部分について、目標値と制御対象の出力との誤差が大きく制御対象の出力に変化が見られない

表 4.1: むだ時間を持つ一次遅れ系に対するファジィ制御器の設計

(a) 図 4.2の制御例から獲得したファジィルール

Δu	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB			NB				
	NM			NB				
	NS			NB				
	ZO	NB	NM	NS	ZO	PS	PM	PB
	PS				PB			
	PM				PB			
	PB				PB			

(b) 一般的に用いられるファジィルール^[1]

Δu	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB			NB				
	NM			NM				
	NS			NS				
	ZO	NB	NM	NS	ZO	PS	PM	PB
	PS				PS			
	PM				PM			
	PB				PB			

4.3. ファジィニューラルネットワークによるファジィ制御器の構成

81

場合に操作量を大きく増加させることを表す。また、(4.6) 式のファジィルールは、操作量の立ち下げの部分について、目標値と制御対象の出力とがほぼ一致し制御対象の出力が大きく増加している場合に操作量を大きく減少させることを表している。なお、目標値が一定である場合、出力が増加しているときは誤差 e の変化分 Δe が負の値をとり、出力が減少しているときは Δe が正の値をとることに注意されたい。

このようにして獲得したファジィルールを表 4.1(a) に示す。表 4.1(b) には、むだ時間を持つ一次遅れ系に対して一般的によく用いられるファジィルールを示す^[1]。図 4.2 ではすべての目標値に対して同様に操作量を立ち上げていることから、それに基づく表 4.1(a) のファジィルールは“ Δe is ZO” の列における操作量の変化分 Δu の大きさに全く差が見られない。 Δu は、誤差 e の正負により符号が変わるだけである。一方、表 4.1(b) のファジィルールでは、オーバーシュートを防ぐために Δu の大きさを e に比例させている。

図 4.1の制御対象は極めて簡単なものであるため、以上のようにファジィルールを比較的容易に獲得できたが、一般にはかなりの困難を伴う場合が多い。しかも、表 4.1(a), (b) の違いからわかるように、オペレータの制御アルゴリズムにより同一の制御対象に対しても異なったファジィルールとなることがある。また、表 4.1のファジィルールにおいても、良好な制御性能を実現するためにはメンバーシップ関数をうまく調整しなければならず、試行錯誤により多大な労力が必要とされる。

4.3 ファジィニューラルネットワークによる ファジィ制御器の構成

本研究で提案した FNN は、NN の学習機能によりファジィ推論におけるファジィルールの同定やメンバーシップ関数の調整を自動的に行えることを特徴とする。従って、本 FNN に熟練オペレータの操作パターンを学習させれば、容易にファジィ制御器を構成することができる。ここでは、前節のむだ時間を持つ一次遅れ系に対する熟練オペレータの制御例を基に、本 FNN の有用性をシミュレーションにより検証する。

このシミュレーションにおける本 FNN の構成は、図 4.1のファジィ制御器と同様に、目標値と制御対象の出力との誤差 e およびその変化分 Δe を入力、操作量の変化分 Δu を出力とする 2 入力 1 出力とした。ただし、Type II の入力変数は前件部・後件部とも

共通である。各入力変数に対する前件部メンバーシップ関数は、 $e, \Delta e$ とも(4.4)式の7種類を設定し、間接法に基づくFNNの後件部メンバーシップ関数の言語ラベルは、Type IIIについてNegativeとPositive、Type IVおよびType VについてPositiveのように与えた。学習データ($e, \Delta e, \Delta u$)は、図4.2の波形から操作量の立ち上がり・立ち下がり部分を中心として計160点の入出力パターンを抽出することにより作成した。また、負の目標値 $-0.2, -0.4, -0.6, -0.8$ に対しては、制御対象の線形性から、正の目標値に対するデータを学習した後、その符号を反転させることにより続けて学習させた。従って、学習データの総数は、正負の目標値に対するものを合わせて320個となる。学習データの教示はその順番をランダムに行い、データの一巡をもって学習回数1回とした。また、本FNNの各結合荷重に対する学習率は、学習データの値と学習時のメンバーシップ関数の形状変化からそれぞれのタイプにおいて表4.2のように設定した。ただし、間接法によるFNNの後件部メンバーシップ関数は、簡単のためにそれを定める結合荷重 w'_c, w'_g に対する学習率を0として調整を行っていない。表4.2では、(3.16)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 w_c, w_g の学習率がすべてのタイプで同じような値となっており、学習率設定の単純化が実現されている。

図4.3は、100回の学習を行った後のシミュレーション結果を示す。図中左側が学習データを採取した熟練オペレータの操作パターンにおける目標値に対する応答、右側がそれに含まれていない目標値に対する応答である。制御対象が極めて簡単なため本FNNの推論法の違いによる制御性能の差はほとんど見られないが、すべてのタイプにおいて学習データの対象とした目標値だけでなくそれ以外の目標値に対しても良好な制御が行われている。

図4.4には学習前後の前件部メンバーシップ関数を、図4.5には間接法に基づくFNNの後件部メンバーシップ関数をそれぞれ示す。図4.4(a)は学習前、(b)~(f)はType I~Vにおける学習後の前件部メンバーシップ関数を表している。これらのメンバーシップ関数は、各タイプとも学習前後でほとんど変化していない。

本FNNにより同定されたファジィルールを表4.3に示す。(c)の表中における τ_N, τ_P は、それぞれ後件部ファジィ変数がNegative, PositiveであるファジィルールのLTVを意味する。表4.3には、各タイプの推論法の特徴がよく表れている。それぞれの特徴については次章にて詳述するが、本FNNにおいて同定されたファジィルールは、Type IIのものを除いて表4.1(a)の熟練オペレータの制御例から獲得したファジィルールと非常に近いものとなっていることがわかる。表4.3(b)のType IIにおいても、各入力

表 4.2: 学習率の設定

タイプ	結合荷重	学習率
Type I	w_c	0.05
	w_g	0.2
	w_f	0.5
Type II	w_c	0.1
	w_g	0.2
	w_a (定数項)	0.5
	(変数項)	0.2
Type III	w_c	1
	w_g	0.2
	w_r	2
Type IV	w_c	0.5
	w_g	1
	w_r	5
Type V	w_c	0.2
	w_g	0.1
	w_r	1
	w'_r	10




図 4.3: シミュレーション結果

(左 : 学習データの対象とした目標値に対する応答)
 (右 : 学習データに含まれない目標値に対する応答)

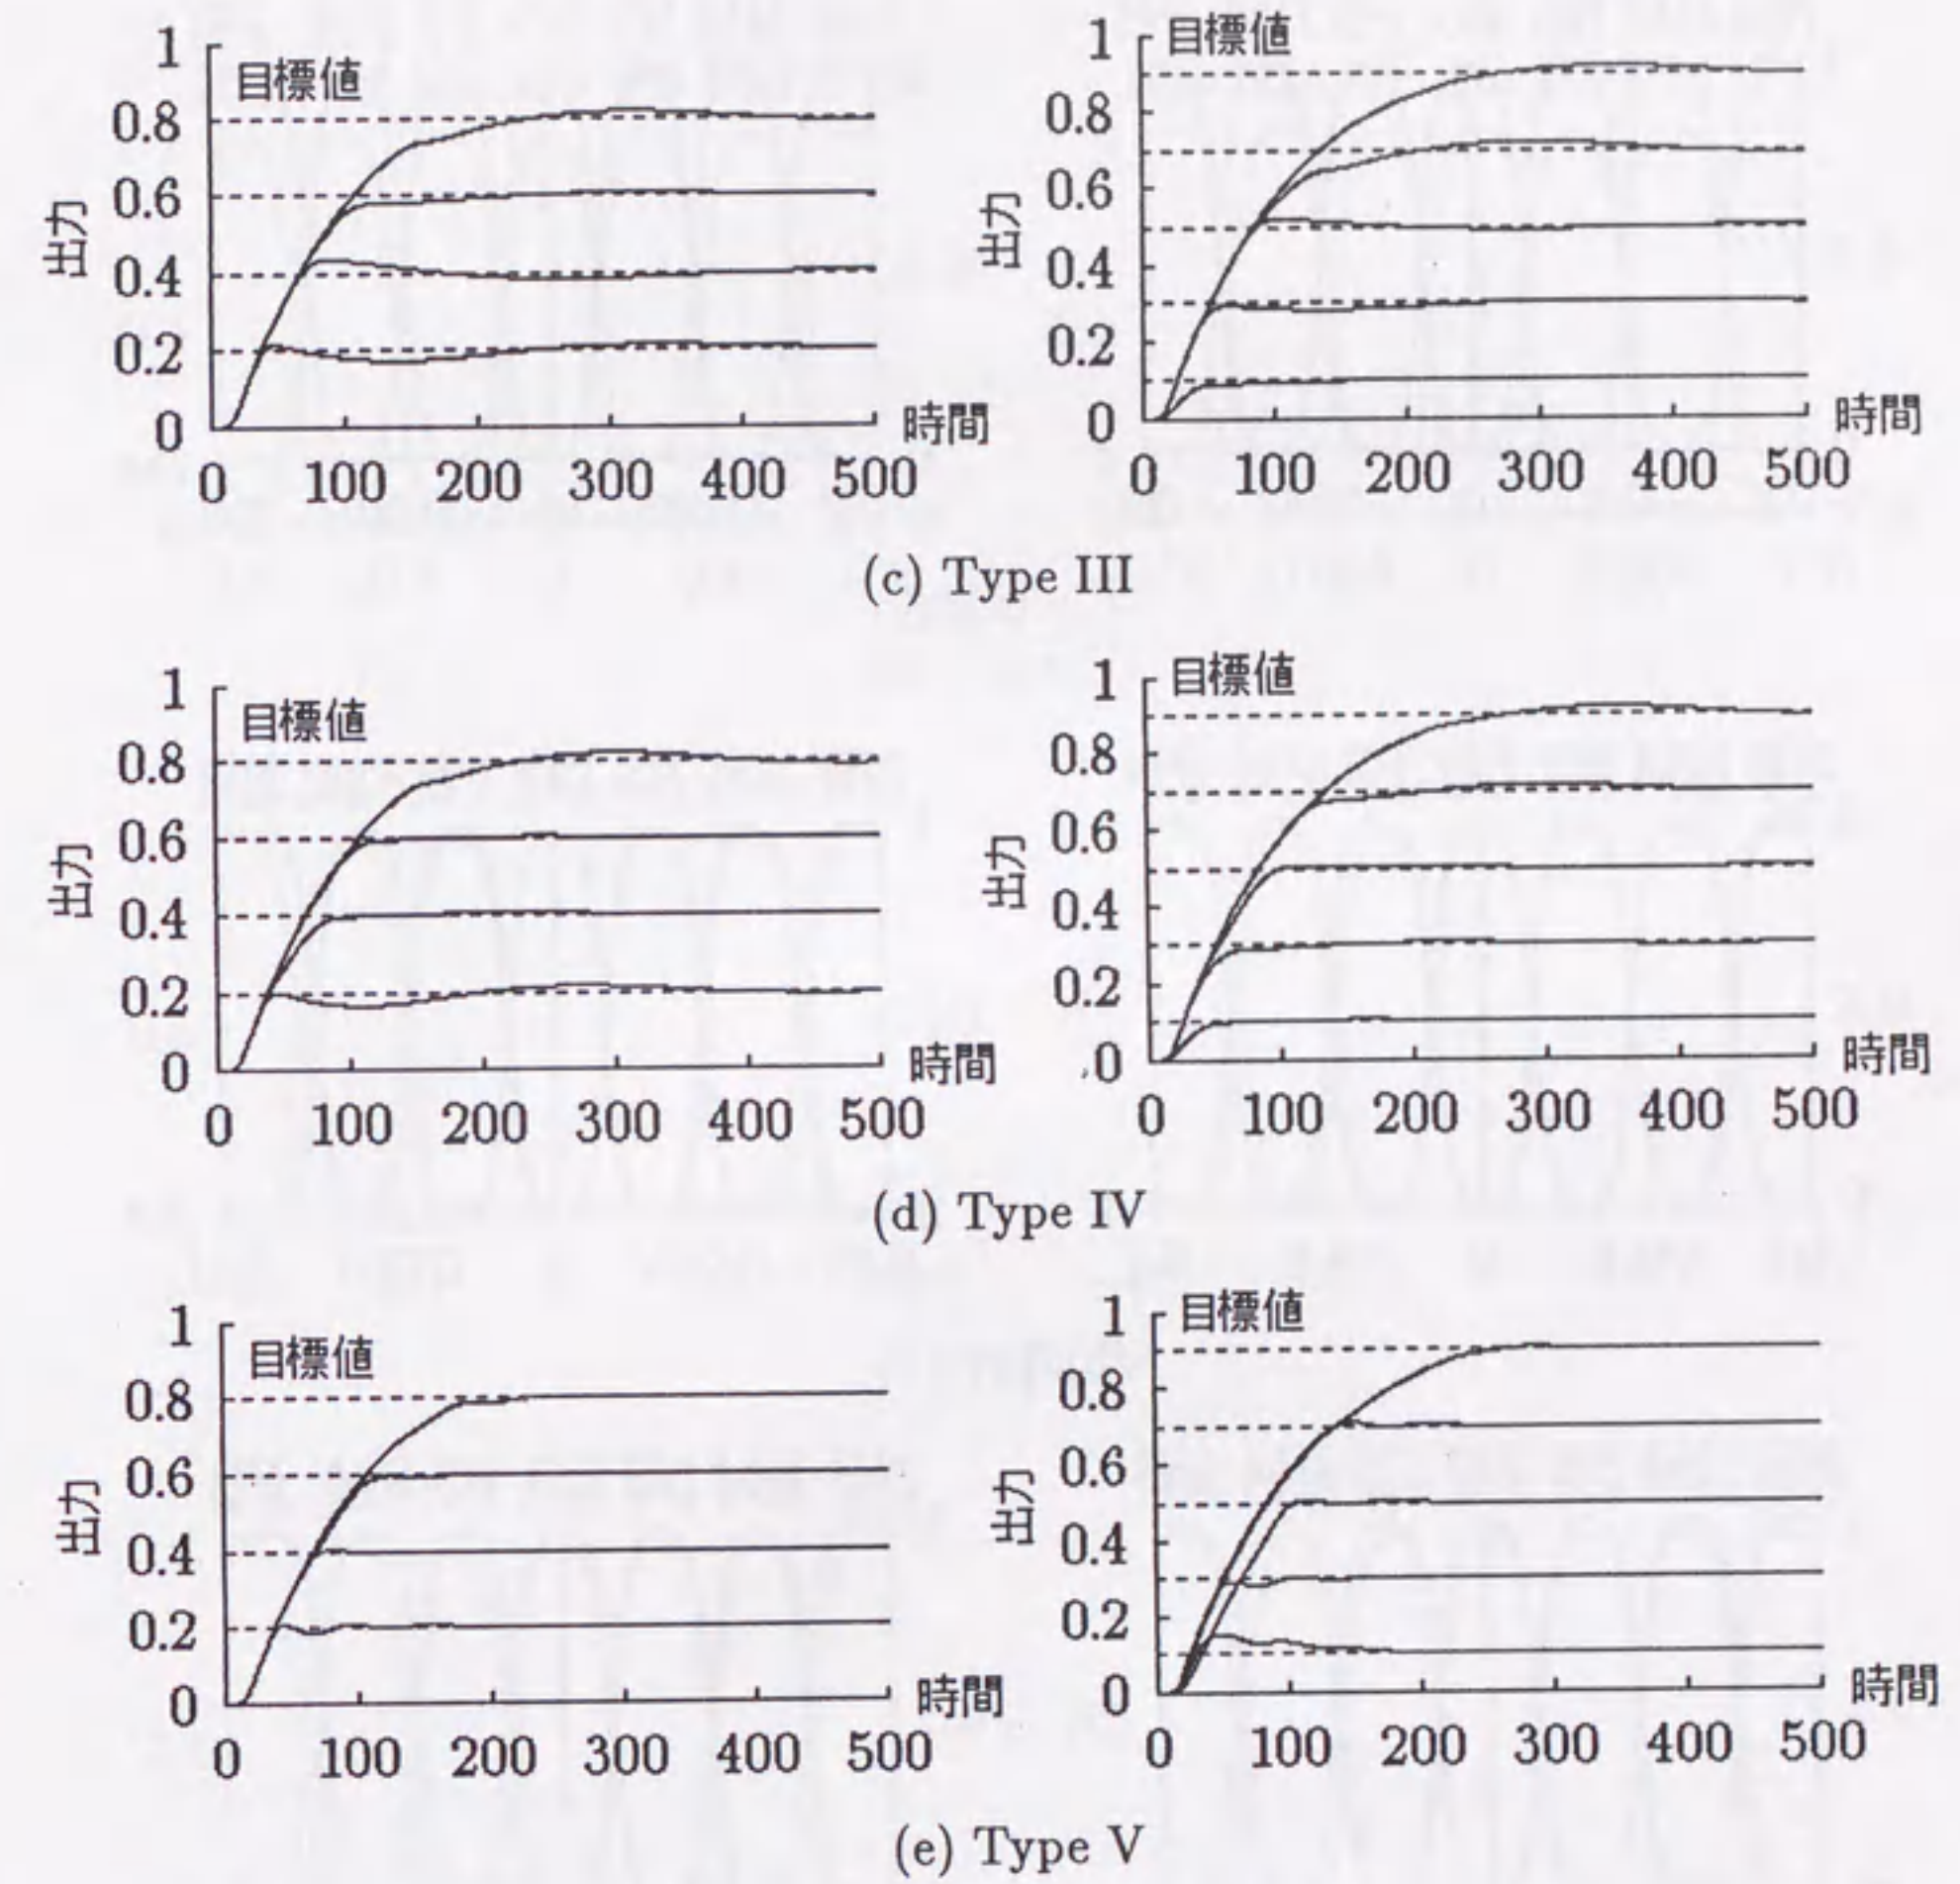




図 4.3: シミュレーション結果


(左 : 学習データの対象とした目標値に対する応答)
 (右 : 学習データに含まれない目標値に対する応答)



(a) 学習前




(b) Type I




(c) Type II


図 4.4: 前件部メンバーシップ関数



(d) Type III

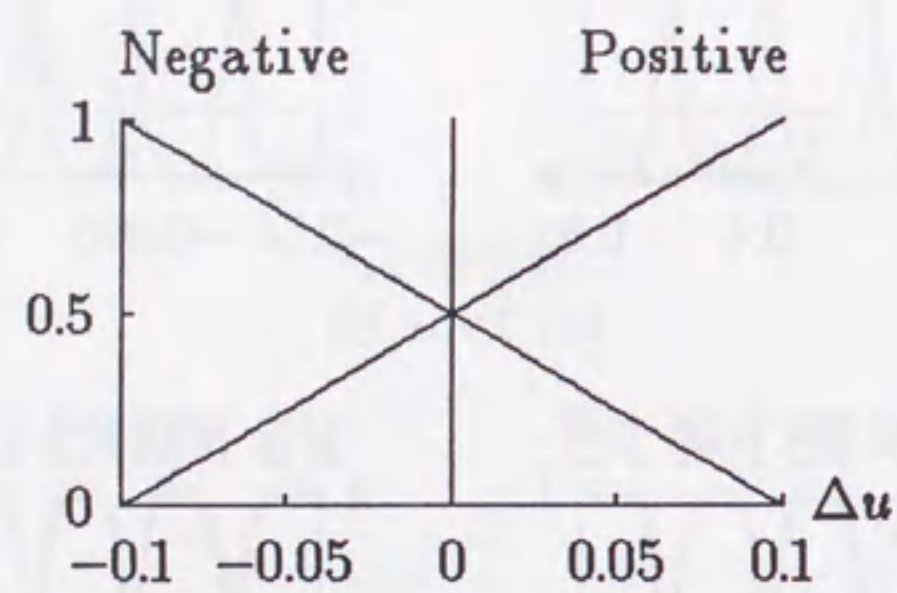


(e) Type IV




(f) Type V

図 4.4: 前件部メンバーシップ関数



(a) Type III



(b) Type IV, Type V

図 4.5: 後件部メンバーシップ関数

表 4.3: 同定されたファジィルール

(a) Type I

Δu		Δe						
		NB	NM	NS	ZO	PS	PM	PB
e	NB	0	0	0	-0.10	0	0	0
	NM	0	0	0	-0.10	0	0	0
	NS	0	0	0	-0.10	0	-0.01	0
	ZO	-0.06	-0.02	-0.01	0	0.01	0.02	0.06
	PS	0	0.01	0	0.10	0	0	0
	PM	0	0	0	0.10	0	0	0
	PB	0	0	0	0.10	0	0	0

(b) Type II

e	Δe	Δu	e	Δe	Δu
NB	ZO	$-0.07 + 0.04e$	ZO	PS	$6\Delta e$
NM	ZO	$-0.09 + 0.02e$	ZO	PM	$-0.04 - 0.01e + 10\Delta e$
NS	ZO	$-0.10 + 0.01e$	ZO	PB	$-0.11 - 0.12e + 20\Delta e$
NS	PS	$-0.01e$	PS	NB	$0.04 + 0.03e + 4\Delta e$
NS	PM	$-0.02 - 0.06e - \Delta e$	PS	NM	$0.02 - 0.06e - \Delta e$
NS	PB	$-0.04 + 0.03e + 4\Delta e$	PS	NS	$-0.01e$
ZO	NB	$0.11 - 0.12e + 20\Delta e$	PS	ZO	$0.10 + 0.01e$
ZO	NM	$0.04 - 0.01e + 10\Delta e$	PM	ZO	$0.09 + 0.02e$
ZO	NS	$6\Delta e$	PB	ZO	$0.07 + 0.04e$
ZO	ZO	Δe			

表 4.3: 同定されたファジィルール

(c) Type III

Δu τ_N/τ_P	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB	0.5/0.5	0.5/0.5	0.5/0.5	1.0/0.0	0.5/0.5	0.5/0.5	0.5/0.5
	NM	0.5/0.5	0.5/0.5	0.5/0.5	1.0/0.0	0.5/0.5	0.5/0.5	0.5/0.5
	NS	0.5/0.5	0.5/0.5	0.5/0.5	1.0/0.0	0.4/0.4	0.4/0.0	1.0/1.0
	ZO	0.8/0.0	0.6/0.2	0.6/0.5	0.5/0.5	0.5/0.6	0.2/0.6	0.0/0.8
	PS	1.0/1.0	0.0/0.4	0.4/0.4	0.0/1.0	0.5/0.5	0.5/0.5	0.5/0.5
	PM	0.5/0.5	0.5/0.5	0.5/0.5	0.0/1.0	0.5/0.5	0.5/0.5	0.5/0.5
	PB	0.5/0.5	0.5/0.5	0.5/0.5	0.0/1.0	0.5/0.5	0.5/0.5	0.5/0.5

(d) Type IV

Δu τ_R	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB	0.50	0.50	0.49	0.00	0.49	0.50	0.50
	NM	0.50	0.50	0.49	0.00	0.49	0.50	0.50
	NS	0.52	0.55	0.51	0.00	0.50	0.46	0.59
	ZO	0.12	0.39	0.44	0.50	0.56	0.61	0.88
	PS	0.41	0.54	0.50	1.00	0.49	0.45	0.48
	PM	0.50	0.50	0.51	1.00	0.51	0.50	0.50
	PB	0.50	0.50	0.51	1.00	0.51	0.50	0.50

(e) Type V

Δu $\tau_R(t)$	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.0)^{0.8}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$
	NM	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{0.9}$	$(t/0.0)^{0.7}$	$(t/0.5)^{0.9}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$
	NS	$(t/0.5)^{1.1}$	$(t/0.6)^{2.2}$	$(t/0.5)^{1.2}$	$(t/0.0)^{0.8}$	$(t/0.5)^{0.9}$	$(t/0.6)^{0.7}$	$(t/0.4)^{0.0}$
	ZO	$(t/0.2)^{0.8}$	$(t/0.3)^{1.4}$	$(t/0.4)^{0.9}$	$(t/0.4)^{0.9}$	$(t/0.6)^{1.6}$	$(t/0.6)^{0.7}$	$(t/0.9)^{1.4}$
	PS	$(t/0.6)^{0.6}$	$(t/0.5)^{1.3}$	$(t/0.4)^{1.3}$	$(t/0.9)^{2.0}$	$(t/0.5)^{0.9}$	$(t/0.5)^{0.9}$	$(t/0.5)^{0.9}$
	PM	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.6)^{3.3}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$
	PB	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/1.0)^{1.4}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$	$(t/0.5)^{1.0}$

表 4.4: 同定されたファジィルールの言語的表記

(a) Type III

Δu	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB	ZO	ZO	ZO	NB	ZO	ZO	ZO
	NM	ZO	ZO	ZO	NB	ZO	ZO	ZO
	NS	ZO	ZO	ZO	NB	—	—	—
	ZO	—	—	—	ZO	—	—	—
	PS	—	—	—	PB	ZO	ZO	ZO
	PM	ZO	ZO	ZO	PB	ZO	ZO	ZO
	PB	ZO	ZO	ZO	PB	ZO	ZO	ZO

(b) Type IV

Δu	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB	ZO	ZO	ZO	NB	ZO	ZO	ZO
	NM	ZO	ZO	ZO	NB	ZO	ZO	ZO
	NS	ZO	ZO	ZO	NB	ZO	ZO	PS
	ZO	NM	NS	ZO	ZO	ZO	PS	PM
	PS	NS	ZO	ZO	PB	ZO	ZO	ZO
	PM	ZO	ZO	ZO	PB	ZO	ZO	ZO
	PB	ZO	ZO	ZO	PB	ZO	ZO	ZO

(c) Type V

Δu	Δe							
	NB	NM	NS	ZO	PS	PM	PB	
e	NB	ZO	ZO	ZO	NB	ZO	ZO	ZO
	NM	ZO	ZO	ZO	m/l NB	ZO	ZO	ZO
	NS	ZO	v ZO	ZO	NB	ZO	m/l PS	$(m/l)^2$ NS
	ZO	NM	NS	ZO	ZO	v ZO	m/l ZO	PM
	PS	m/l PS	ZO	ZO	v PB	ZO	ZO	ZO
	PM	ZO	ZO	ZO	v ² PS	ZO	ZO	ZO
	PB	ZO	ZO	ZO	PB	ZO	ZO	ZO

変数の係数の違いに同様な傾向を見ることができる。しかし、例えば表 4.3(a) では、“e is PS and Δe is NM” や “e is NS and Δe is PM” に表 4.1(a) には見られないファジィルールが同定されている。これは、本 FNN の学習法によるものである。本 FNN でファジィルールに対応する結合荷重は、学習時の更新量が 3.2 節にて説明した BP 法に従い前件部適合度に比例した値で与えられる。従って、学習データが入力空間において隣り合う二つのファジィ部分領域の中間に位置する場合、“e is (ZO or PS) and Δe is NM” あるいは “e is (ZO or NS) and Δe is PM” のようにしてファジィルールの同定が行われる。特に今回用いた学習データでは、 e が ZO と PS または ZO と NS の境界に相当する値のとき $\Delta u \approx 0$ となっており、これを $e \approx 0$ のときの Δu の値と矛盾しないように実現するため表 4.3 のようなファジィルールに調整されたと考えられる。

表 4.4 は、間接法に基づく FNN によって同定されたファジィルールを 2.4.4 項で説明した手法により言語的に表記したものを示す。(a) における “—” はそのファジィルールが 2.4.4 項の手法で変換できなかったことを表し、(c) の “v”, “m/l” はそれぞれ “very”, “more or less” の言語ヘッジに相当する。表 4.4(a) の Type III のルール表で言語的に表記できないファジィルールが生じているのは、Type III における同一の前件部命題を持つ二つのファジィルールの LTV が望ましい出力値に対し一意性を持たないことによる。例えば、後件部ファジィ変数 B_1, B_2 が (2.34) 式のように完全に補集合の関係にあり、ファジィルールの LTV τ_{R_1}, τ_{R_2} がすべての i について等しいと仮定する。このとき、後件部適合度 μ'_1, μ'_2 も同じ値となることから、(2.24), (2.37) 式より推論値 y^* を (2.39) 式と同様にして計算すると

$$\begin{aligned} y^* &= \frac{\mu'_1(-w'_g\mu'_1 + w'_c + w'_g) + \mu'_2(w'_g\mu'_2 + w'_c)}{\mu'_1 + \mu'_2} \\ &= \frac{\mu'_2(-w'_g\mu'_2 + w'_c + w'_g) + \mu'_2(w'_g\mu'_2 + w'_c)}{\mu'_2 + \mu'_2} \\ &= \frac{2w'_c + w'_g}{2} \end{aligned} \quad (4.7)$$

のようになる。上式は、 $\tau_{R_1} = \tau_{R_2}$ であればその値によらず y^* が一定値をとることを表している。そのため、Type III では、表 4.3(c) の τ_N, τ_P が必ずしも (2.55) 式の関係を満たしておらず、それぞれに該当する言語ラベルが異なることから一部のファジィルールで言語的表記が不可能となっている。また、Type V でも、本節のシミュレーションのように入力空間における学習データの分布が一様でない場合、学習時の各ファジィルールの前件部適合度に偏りが伴うことからファジィルールの LTV $\tau_R(t)$ が一意に定

まらない。表 4.4(c) において表 4.1 のような対称性が見られないのは、この理由によるためである。しかし、そのルール表は直接法に基づく FNN が同定したものに比べると極めてわかりやすく、また、表 4.4(b) の Type IV によるファジィルールは表 4.1(a) とよく一致しており、本研究で提案した間接法に基づく FNN の有用性が示されている。

4.4 まとめ

本章では、本 FNN のファジィ制御への応用として、熟練オペレータの操作パターンを基にファジィ制御器を構成するシミュレーションを行った。本 FNN は、一般に困難とされる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えるため、熟練オペレータの操作パターンを学習データとして与えることにより容易にファジィ制御器を設計することができる。また、実現されたファジィ制御器は良好な制御性能を示し、通常的设计手法により獲得したファジィルールとはほぼ同じものが同定された。これによって、本 FNN が人間の直感によく合うファジィルールを同定可能であることが示された。

第5章

ファジィモデリングへの応用

5.1 はじめに

ファジィモデリングは、ファジィ推論を用いて対象とするシステムの入出力特性を記述する手法である。前章で行った熟練オペレータの操作モデルの同定によるファジィ制御器の構成も、一種のファジィモデリングと見なすことができる。ファジィモデルの特徴としては、複雑な非線形システムを精度良く近似できること、また、その入出力関係がファジィルールによって言語的に表されることから従来の数式モデルに比べて定性的で理解しやすいことが挙げられる。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の同定やメンバーシップ関数等のパラメータ調整には一般に多大な労力を必要とする。本研究で提案したFNNは、これらをNNの学習機能により自動的に行えるため、ファジィモデリングの自動化が期待できる。そこで本章では、本FNNを用いたファジィモデリング手法を提案し、簡単な数値例によりその有用性を検証する^{[47][48]}。

5.2 ファジィニューラルネットワークを用いた

ファジィモデリング

ファジィモデルの同定は、一般に前件部同定と後件部同定に分類され、それらはさらに構造同定とパラメータ同定に分けられる。ここで構造とは、ファジィルールの前

件部または後件部に現れる入力変数の組み合わせや各変数に対するメンバーシップ関数の種類数を意味する。菅野らは、本FNNのType IIで用いている高木・菅野の推論法において、前件部構造の選択、前件部パラメータの同定、後件部構造の選択、後件部パラメータの同定を順に繰り返して行うことにより、ある規範の下に最適なファジィモデルを同定する手法を提案した^{[14][31]}。本研究で提案するファジィモデリング手法は基本的に菅野らの方法と同様であるが、Type II以外のFNNには後件部の構造というものが存在せず構造としては前件部のみを同定すればよい。本FNNでは、以下のようにしてファジィモデルを同定する。

まず、ファジィモデリングの対象とするシステムの入出力データを二つのグループA, Bに分割する。各グループにおけるデータの分布が異なる場合には正確なファジィモデリングが不可能となることがあるので、この分割はそれらの統計的性質が可能な限り等しくなるようにする。

次に、構造同定を行う。入出力データの入力変数から考えられる様々な構造に対して本FNNを構成し、それぞれにおいてメンバーシップ関数の形状は変化させずに各グループのファジィモデルを同定する。すなわち、前件部メンバーシップ関数を定める結合荷重 w_c, w_g および間接法に基づくFNNの後件部メンバーシップ関数を定める w'_c, w'_g の学習率をすべて0として、Type Iの場合 w_f 、Type IIの場合 w_a 、Type IIIおよびType IVの場合 w_r 、Type Vの場合 w_r, w'_r のみを学習させる。出力誤差がある程度収束した時点で学習を終了し、グループAのデータから得られたモデルAとグループBのデータから得られたモデルBにより、後述する評価規範が最小となる構造を選択する。これは、ファジィモデルの入出力特性が、特に前件部についてメンバーシップ関数のパラメータよりもむしろ構造に大きく依存することによる。しかも、本FNNでは、メンバーシップ関数を入出力空間全体が等間隔に分割されるよう初期設定して学習後もその形状をほぼ維持するため、メンバーシップ関数におけるパラメータの構造同定に対する影響が少ない。ただし、評価規範の比較を正確なものとするため、学習時の入出力データの教示順やファジィルールを意味する結合荷重の学習率等の条件は常に同一とする。

学習の収束は、次式により判断する。

$$\frac{E(m-1) - E(m)}{E(m-1)} < \varepsilon \quad (5.1)$$

$$E(m) = \sum_i \{y_i - y_i^*(m)\}^2 \quad (5.2)$$

ここで、 $E(m)$ は(5.2)式で定義される m 回目の学習における出力誤差の自乗和であり、 y_i は i 番目のデータの出力値、 y_i^* は y_i に対する本FNNの推論値を表す。従って、(5.1)式は、出力誤差の変化率がある値 ε 未満になったとき学習を終了することを意味する。なお、計算コストの問題から(5.2)式の $y_i - y_i^*$ は学習時に逐次求められる出力誤差から計算するものとし、出力数が複数である場合にはすべての出力に対して(5.1)式が満たされるまで学習を行う。

本FNNによるファジィモデリングの構造評価規範 C は、グループA, Bのデータ数をそれぞれ n_A, n_B とすると次のように表される。

$$C = \sigma \sqrt{\sum_{i=1}^{n_A} (y_i^A - y_i^{AA})^2 + \sum_{i=1}^{n_B} (y_i^B - y_i^{BB})^2} + \sqrt{\sum_{i=1}^{n_A} (y_i^{AB} - y_i^{AA})^2 + \sum_{i=1}^{n_B} (y_i^{BA} - y_i^{BB})^2} \quad (5.3)$$

ここで、 y_i^A, y_i^B はそれぞれグループA, Bの出力データであり、 y_i^{AA}, y_i^{BA} はモデルAによる y_i^A, y_i^B に対する推論値、 y_i^{AB}, y_i^{BB} はモデルBによる y_i^A, y_i^B に対する推論値を表す。上式の第1項はモデルの精度を評価するものであり、第2項は不偏性規範^[49]すなわちモデルの汎化性を評価するものである。(5.3)式によれば、構造の違いに起因するモデルの精度と汎化性が総合的に評価されるため、最適な構造の選択が期待できる。また、それぞれの重視度合を定数 σ により調整することが可能であり、 $\sigma=1$ とすればモデルの精度と汎化性が対等に評価され、 $\sigma=0$ とすれば C は不偏性規範と一致し汎化性のみが評価される。本FNNによる構造同定においては精度よりも汎化性を幾分重視した方が良く、 σ の値は0.25~0.5程度が適当である。

最後に、メンバーシップ関数の調整を含めたファジィモデルのパラメータ同定を行う。上述の手順で選択された構造を持つ本FNNにおいて、すべての結合荷重に対して学習率を設定し、 w_c, w_g および w'_c, w'_g によりメンバーシップ関数の調整を、 w_f, w_a, w_r, w'_r によりファジィルールの同定をそれぞれ行う。この学習では、学習後のメンバーシップ関数がファジィモデルとして不適当な構成とならず、しかも、モデルの精度ができるだけ良好となるように、各結合荷重に対する学習率の最適な組み合わせを探索する必要がある。また、学習データとしてはグループA, Bの両方を合わせて用いてもよいが、次節の数値例のごとく汎化性の高いモデルを得るために一方を同定用、他方を評価用とすることも可能である。

以上の手順により、本 FNN における様々なファジィ推論に基づく対象システムのファジィモデルが同定される。

5.3 数値例

前節で提案した本 FNN によるファジィモデリング手法の有用性を検証するため、文献 [1][31] で用いられた簡単な数値例によりシミュレーションを行った。

ファジィ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。

$$y = (1 + x_1^{0.5} + x_2^{-1} + x_3^{-1.5})^2 \quad (5.4)$$

表 5.1 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^[1]。ただし、表中の入力変数 x_4 は (5.4) 式とは無関係なダミー変数である。前節の手順に従いこれらの入出力データを二つのグループに分割し、No.1~20 のデータをグループ A、No.21~40 のデータをグループ B として以下のようにファジィモデルを同定した。

まず、最適な構造の探索を、菅野らの手法と同様に、前件部については変数増加法により、Type II の後件部については変数減少法により行った。その結果を表 5.2~5.6 に示す。ただし、Type II における後件部構造の探索過程は、最終的に選択された前件部構造についてのみ示している。これらの探索では、本 FNN においてファジィルールを意味する結合荷重に対する学習率をそれぞれ表 5.7(a) のように設定し、出力誤差の収束を判定する (5.1) 式の ϵ を 0.001 として本 FNN の学習を行った。また、(5.3) 式の構造同定規範 C の定数 σ は 0.5 とした。表中の前件部構造における $x_j[k]$ は入力変数 x_j に対する前件部メンバーシップ関数が k 種類であることを意味し、ステップに応じて前件部変数が増加している。なお、前のステップで選択された変数については、前件部メンバーシップ関数の種類数が増やされている。一方、表 5.6(b) の Type II の後件部構造は、ステップ毎に入力変数が減少している。表 5.2~5.6 の E_A , E_B は、(5.3) 式で求められる構造評価規範 C の第 1 項に対応する学習後の出力誤差を表し次式で定義される。

$$E_A = \sqrt{\sum_{i=1}^{n_A} (y_i^A - y_i^{AA})^2} \quad (5.5)$$

$$E_B = \sqrt{\sum_{i=1}^{n_B} (y_i^B - y_i^{BB})^2} \quad (5.6)$$

表 5.1: 入出力データ

No.	x_1	x_2	x_3	x_4	y	No.	x_1	x_2	x_3	x_4	y
1	1	3	1	1	11.110	21	1	1	5	1	9.545
2	1	5	2	1	6.521	22	1	3	4	1	6.043
3	1	1	3	5	10.190	23	1	5	3	5	5.724
4	1	3	4	5	6.043	24	1	1	2	5	11.250
5	1	5	5	1	5.242	25	1	3	1	1	11.110
6	5	1	4	1	19.020	26	5	5	2	1	14.360
7	5	3	3	5	14.150	27	5	1	3	5	19.610
8	5	5	2	5	14.360	28	5	3	4	5	13.650
9	5	1	1	1	27.420	29	5	5	5	1	12.430
10	5	3	2	1	15.390	30	5	1	4	1	19.020
11	1	5	3	5	5.724	31	1	3	3	5	6.380
12	1	1	4	5	9.766	32	1	5	2	5	6.521
13	1	3	5	1	5.870	33	1	1	1	1	16.000
14	1	5	4	1	5.406	34	1	3	2	1	7.219
15	1	1	3	5	10.190	35	1	5	3	5	5.724
16	5	3	2	5	15.390	36	5	1	4	5	19.020
17	5	5	1	1	19.680	37	5	3	5	1	13.390
18	5	1	2	1	21.060	38	5	5	4	1	12.680
19	5	3	3	5	14.150	39	5	1	3	5	19.610
20	5	5	4	5	12.680	40	5	3	2	5	15.390

表 5.2: ファジィモデルの構造同定 (Type I)

ステップ	前件部構造	E_A	E_B	UC	C
1	$x_1[2]$	22.66	16.42	23.29	37.28
	○ $x_2[2]$	27.00	24.07	5.32	23.40
	$x_3[2]$	30.43	29.02	34.30	55.33
	$x_4[2]$	35.21	23.61	39.38	60.58
2	○ $x_1[2], x_2[2]$	13.14	9.02	11.41	19.38
	$x_2[3]$	28.30	24.13	6.93	25.52
	$x_2[2], x_3[2]$	28.02	22.19	51.83	69.70
	$x_2[2], x_4[2]$	33.57	17.67	37.65	56.62
3	$x_1[3], x_2[2]$	13.19	9.03	11.36	19.35
	$x_1[2], x_2[3]$	11.30	9.59	15.57	22.98
	○ $x_1[2], x_2[2], x_3[2]$	11.21	6.01	11.51	17.87
	$x_1[2], x_2[2], x_4[2]$	9.66	7.54	20.52	26.65
4	○ $x_1[3], x_2[2], x_3[2]$	11.24	6.01	11.55	17.93
	$x_1[2], x_2[3], x_3[2]$	7.54	5.76	14.16	18.90
	$x_1[2], x_2[2], x_3[3]$	8.78	4.39	17.73	22.64
	$x_1[2], x_2[2], x_3[2], x_4[2]$	7.53	3.87	40.89	45.12

表 5.3: ファジィモデルの構造同定 (Type III)

ステップ	前件部構造	E_A	E_B	UC	C
1	○ $x_1[2]$	15.28	13.69	8.09	18.35
	$x_2[2]$	24.14	17.48	4.16	19.06
	$x_3[2]$	22.37	21.30	20.26	35.71
	$x_4[2]$	26.07	21.46	7.50	24.38
2	$x_1[3]$	15.28	13.69	8.09	18.35
	○ $x_1[2], x_2[2]$	11.20	7.71	9.11	15.91
	$x_1[2], x_3[2]$	13.99	12.96	7.70	17.23
	$x_1[2], x_4[2]$	11.25	11.99	23.95	32.17
3	$x_1[3], x_2[2]$	11.20	7.71	9.09	15.89
	$x_1[2], x_2[3]$	9.31	6.70	11.75	17.48
	○ $x_1[2], x_2[2], x_3[2]$	9.06	5.86	8.48	13.88
	$x_1[2], x_2[2], x_4[2]$	9.22	7.34	15.30	21.19
4	○ $x_1[3], x_2[2], x_3[2]$	9.06	5.86	8.50	13.89
	$x_1[2], x_2[3], x_3[2]$	5.84	4.60	11.68	15.40
	$x_1[2], x_2[2], x_3[3]$	7.17	4.22	17.20	21.36
	$x_1[2], x_2[2], x_3[2], x_4[2]$	7.40	4.81	19.05	23.46

表 5.4: ファジィモデルの構造同定 (Type IV)

ステップ	前件部構造	E_A	E_B	UC	C
1	○ $x_1[2]$	15.31	13.66	6.68	16.94
	$x_2[2]$	24.23	17.56	5.70	20.66
	$x_3[2]$	22.44	21.26	26.09	41.55
	$x_4[2]$	26.17	21.45	9.94	26.86
2	$x_1[3]$	15.31	13.66	6.67	16.93
	○ $x_1[2], x_2[2]$	11.38	7.66	9.42	16.28
	$x_1[2], x_3[2]$	13.93	12.80	6.85	16.31
	$x_1[2], x_4[2]$	11.23	11.94	24.87	33.07
3	$x_1[3], x_2[2]$	11.38	7.66	9.42	16.28
	$x_1[2], x_2[3]$	9.25	6.65	11.86	17.55
	○ $x_1[2], x_2[2], x_3[2]$	9.39	5.91	7.45	13.00
	$x_1[2], x_2[2], x_4[2]$	9.12	7.22	16.02	21.83
4	○ $x_1[3], x_2[2], x_3[2]$	9.39	5.90	7.46	13.01
	$x_1[2], x_2[3], x_3[2]$	5.67	4.36	10.32	13.90
	$x_1[2], x_2[2], x_3[3]$	7.43	4.38	16.93	21.24
	$x_1[2], x_2[2], x_3[2], x_4[2]$	7.24	4.50	18.69	22.95

表 5.5: ファジィモデルの構造同定 (Type V)

ステップ	前件部構造	E_A	E_B	UC	C
1	○ $x_1[2]$	15.28	13.66	7.45	17.70
	$x_2[2]$	23.97	16.81	5.43	20.07
	$x_3[2]$	22.15	21.19	23.73	39.05
	$x_4[2]$	26.05	21.42	8.45	25.31
2	$x_1[3]$	15.28	13.67	7.59	17.84
	○ $x_1[2], x_2[2]$	9.32	6.78	11.29	17.05
	$x_1[2], x_3[2]$	13.12	11.32	10.48	19.15
	$x_1[2], x_4[2]$	11.22	11.95	24.34	32.54
3	$x_1[3], x_2[2]$	9.31	6.78	11.32	17.07
	$x_1[2], x_2[3]$	9.25	6.65	11.72	17.41
	○ $x_1[2], x_2[2], x_3[2]$	5.57	4.59	11.34	14.95
	$x_1[2], x_2[2], x_4[2]$	7.73	6.58	16.40	21.48
4	○ $x_1[3], x_2[2], x_3[2]$	5.57	4.60	11.60	15.22
	$x_1[2], x_2[3], x_3[2]$	5.48	4.37	14.27	17.77
	$x_1[2], x_2[2], x_3[3]$	2.97	2.95	18.66	20.76
	$x_1[2], x_2[2], x_3[2], x_4[2]$	3.71	2.87	19.59	21.93

表 5.6: ファジィモデルの構造同定 (Type II)

(a) 前件部

ステップ	前件部構造	後件部構造	E_A	E_B	UC	C
1	$x_1[2]$	x_1, x_2, x_3, x_4	6.75	4.95	9.92	14.11
	○ $x_2[2]$	x_1, x_2, x_3, x_4	5.38	2.68	5.94	8.95
	$x_3[2]$	x_1, x_2, x_3, x_4	5.89	5.36	8.20	12.18
	$x_4[2]$	x_1, x_2, x_3	6.80	4.91	8.43	12.62
2	$x_1[2], x_2[2]$	x_1, x_2, x_3	4.44	3.30	11.05	13.81
	$x_2[3]$	x_1, x_3	5.07	3.56	8.13	11.23
	○ $x_2[2], x_3[2]$	x_1, x_2, x_3	2.51	1.85	6.29	7.85
	$x_2[2], x_4[2]$	x_1, x_2, x_3	3.44	2.05	13.03	15.03
3	$x_1[2], x_2[2], x_3[2]$	x_1, x_2	5.93	4.46	8.89	12.60
	○ $x_2[3], x_3[2]$	x_1, x_2, x_3	1.50	0.95	11.18	12.06
	$x_2[2], x_3[3]$	x_1, x_2, x_3	0.26	0.47	12.77	13.04
	$x_2[2], x_3[2], x_4[2]$	x_1, x_2, x_3	0.00	0.00	18.77	18.77

(b) 後件部

ステップ	前件部構造	後件部構造	E_A	E_B	UC	C
1	$x_2[2], x_3[2]$	○ x_1, x_2, x_3, x_4	1.75	1.76	8.75	9.99
2		x_2, x_3, x_4	14.57	13.58	37.17	47.13
		x_1, x_3, x_4	6.11	4.85	7.64	11.54
		x_1, x_2, x_4	6.03	2.75	7.26	10.57
		○ x_1, x_2, x_3	2.51	1.85	6.29	7.85
3		x_2, x_3	17.88	14.03	27.68	39.05
		○ x_1, x_3	6.04	4.97	7.05	10.96
	x_1, x_2	7.74	4.41	7.63	12.08	

表 5.7: 学習率の設定

(a) 構造同定時

タイプ	結合荷重	学習率
Type I	w_f	1
Type II	w_a	0.1
Type III	w_r	0.001
Type IV	w_r	0.005
Type V	w_r w'_r	0.002 0.01

(b) パラメータ同定時

タイプ	結合荷重	学習率
Type I	w_c	0.005
	w_g	0.002
	w_f	1
Type II	w_c	0.01
	w_g	0.01
	w_a	0.5
Type III	w_c	0.05
	w_g	0.1
	w_r	0.01
	w'_c	0.00002
	w'_g	0.0001
Type IV	w_c	0.02
	w_g	0.05
	w_r	0.05
	w'_c	0.0001
	w'_g	0.0005
Type V	w_c	0.05
	w_g	0.05
	w_r	0.02
	w'_r	0.1
	w'_c	0.0001
	w'_g	0.0005

UCは、第2項の不偏性規範である。それぞれのステップにおいて○印の付いた構造が選ばれ、最終的に○印の付いた構造が同定されている。各タイプにおける最適な構造は、Type IIが前件部を $x_2[2], x_3[2]$ 、後件部を x_1, x_2, x_3 とした場合で、それ以外のFNNは前件部を $x_1[2], x_2[2], x_3[2]$ とした場合である。Type IIで同定された構造は、不偏性規範を用いた菅野らの手法によるものと一致している。本FNNでは、構造同定時にメンバーシップ関数の調整を行わないため、表5.2~5.6には表れていないが評価規範として不偏性規範を用いると誤った構造が選択されることがある。(5.3)式のCによれば、不必要な変数の含まれない正しい構造を同定できる。

この結果を基に、グループAのデータを同定用データ、グループBのデータを評価用データとして、(5.4)式で表されるシステムのパジィモデルを同定した。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5.7(b)のように設定し、メンバーシップ関数の言語ラベルは前件部・後件部ともすべてSmall, Bigとした。表5.7(b)では、(3.16)式の定数 κ により、前件部メンバーシップ関数を定める結合荷重 w_c, w_g および間接法に基づくFNN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。

表5.8は、100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、

$$J_1 = \frac{1}{20} \sum_{i=1}^{20} \frac{|y_i - y_i^*|}{y_i} \times 100 (\%) \quad (5.7)$$

$$J_2 = \frac{1}{20} \sum_{i=21}^{40} \frac{|y_i - y_i^*|}{y_i} \times 100 (\%) \quad (5.8)$$

のように定義される。表5.8には、非線形システムの一般的なモデリング手法であるGMDH^[49]や文献[1][31]の菅野らの手法、林らのNN駆動型ファジィ推論^[23]、野村らの学習型簡略化ファジィ推論^[29]、今崎らのファジィルール構造化NN^[26]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におけるルール数が $2^2=4$ 、それ以外のFNNにおけるルール数が $2^3=8$ 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の同定したモデルは他の手法によるものと同程度の精度

表 5.8: モデルの比較

手法		$J_1(\%)$	$J_2(\%)$
本 FNN	Type I	0.66	1.06
	Type II	0.23	0.68
	Type III	0.31	0.68
	Type IV	0.31	0.42
	Type V	0.23	0.79
GMDH ^[49]		4.7	5.7
菅野ファジィモデリング ^{[1][31]}	モデル I	1.5	2.1
	モデル II	1.1	3.6
NN 駆動型ファジィ推論 ^[23]		0.47	4.79
学習型簡略化ファジィ推論 ^[29]		0.38	5.1
ファジィルール構造化 NN ^[26]		0.453	4.57

を示しており、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わかる。

本 FNN における学習前後のメンバーシップ関数を図 5.1 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、(5.4) 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^[1]。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。本章でファジィモデリングの対象とした (5.4) 式は、展開すると x_1 , x_2^{-2} , x_3^{-3} のような項も現れるが、基本的には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 5.1 の入力データの範囲 $1 \leq x \leq 5$ において図 5.2 のように変化する。図 5.2 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、 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可能である。それ以外の FNN 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 本の直線で折線近似できるような非線形性を持っている。そして、 $x^{-1.5}$ 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^{[50][51]}。

表 5.9 は、本 FNN により同定されたファジィルールを示す。また、表 5.10 には、間接法に基づく FNN により同定されたファジィルールを言語的に表記したものを示す。表 5.9(c) の Type III の後件部における τ_S , τ_B 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 に相当する。表 5.9 では、本 FNN の各タイプが基づく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 “absolutely true” であるといった言語的なモデルが同定されている。これらは、Type IV, Type V

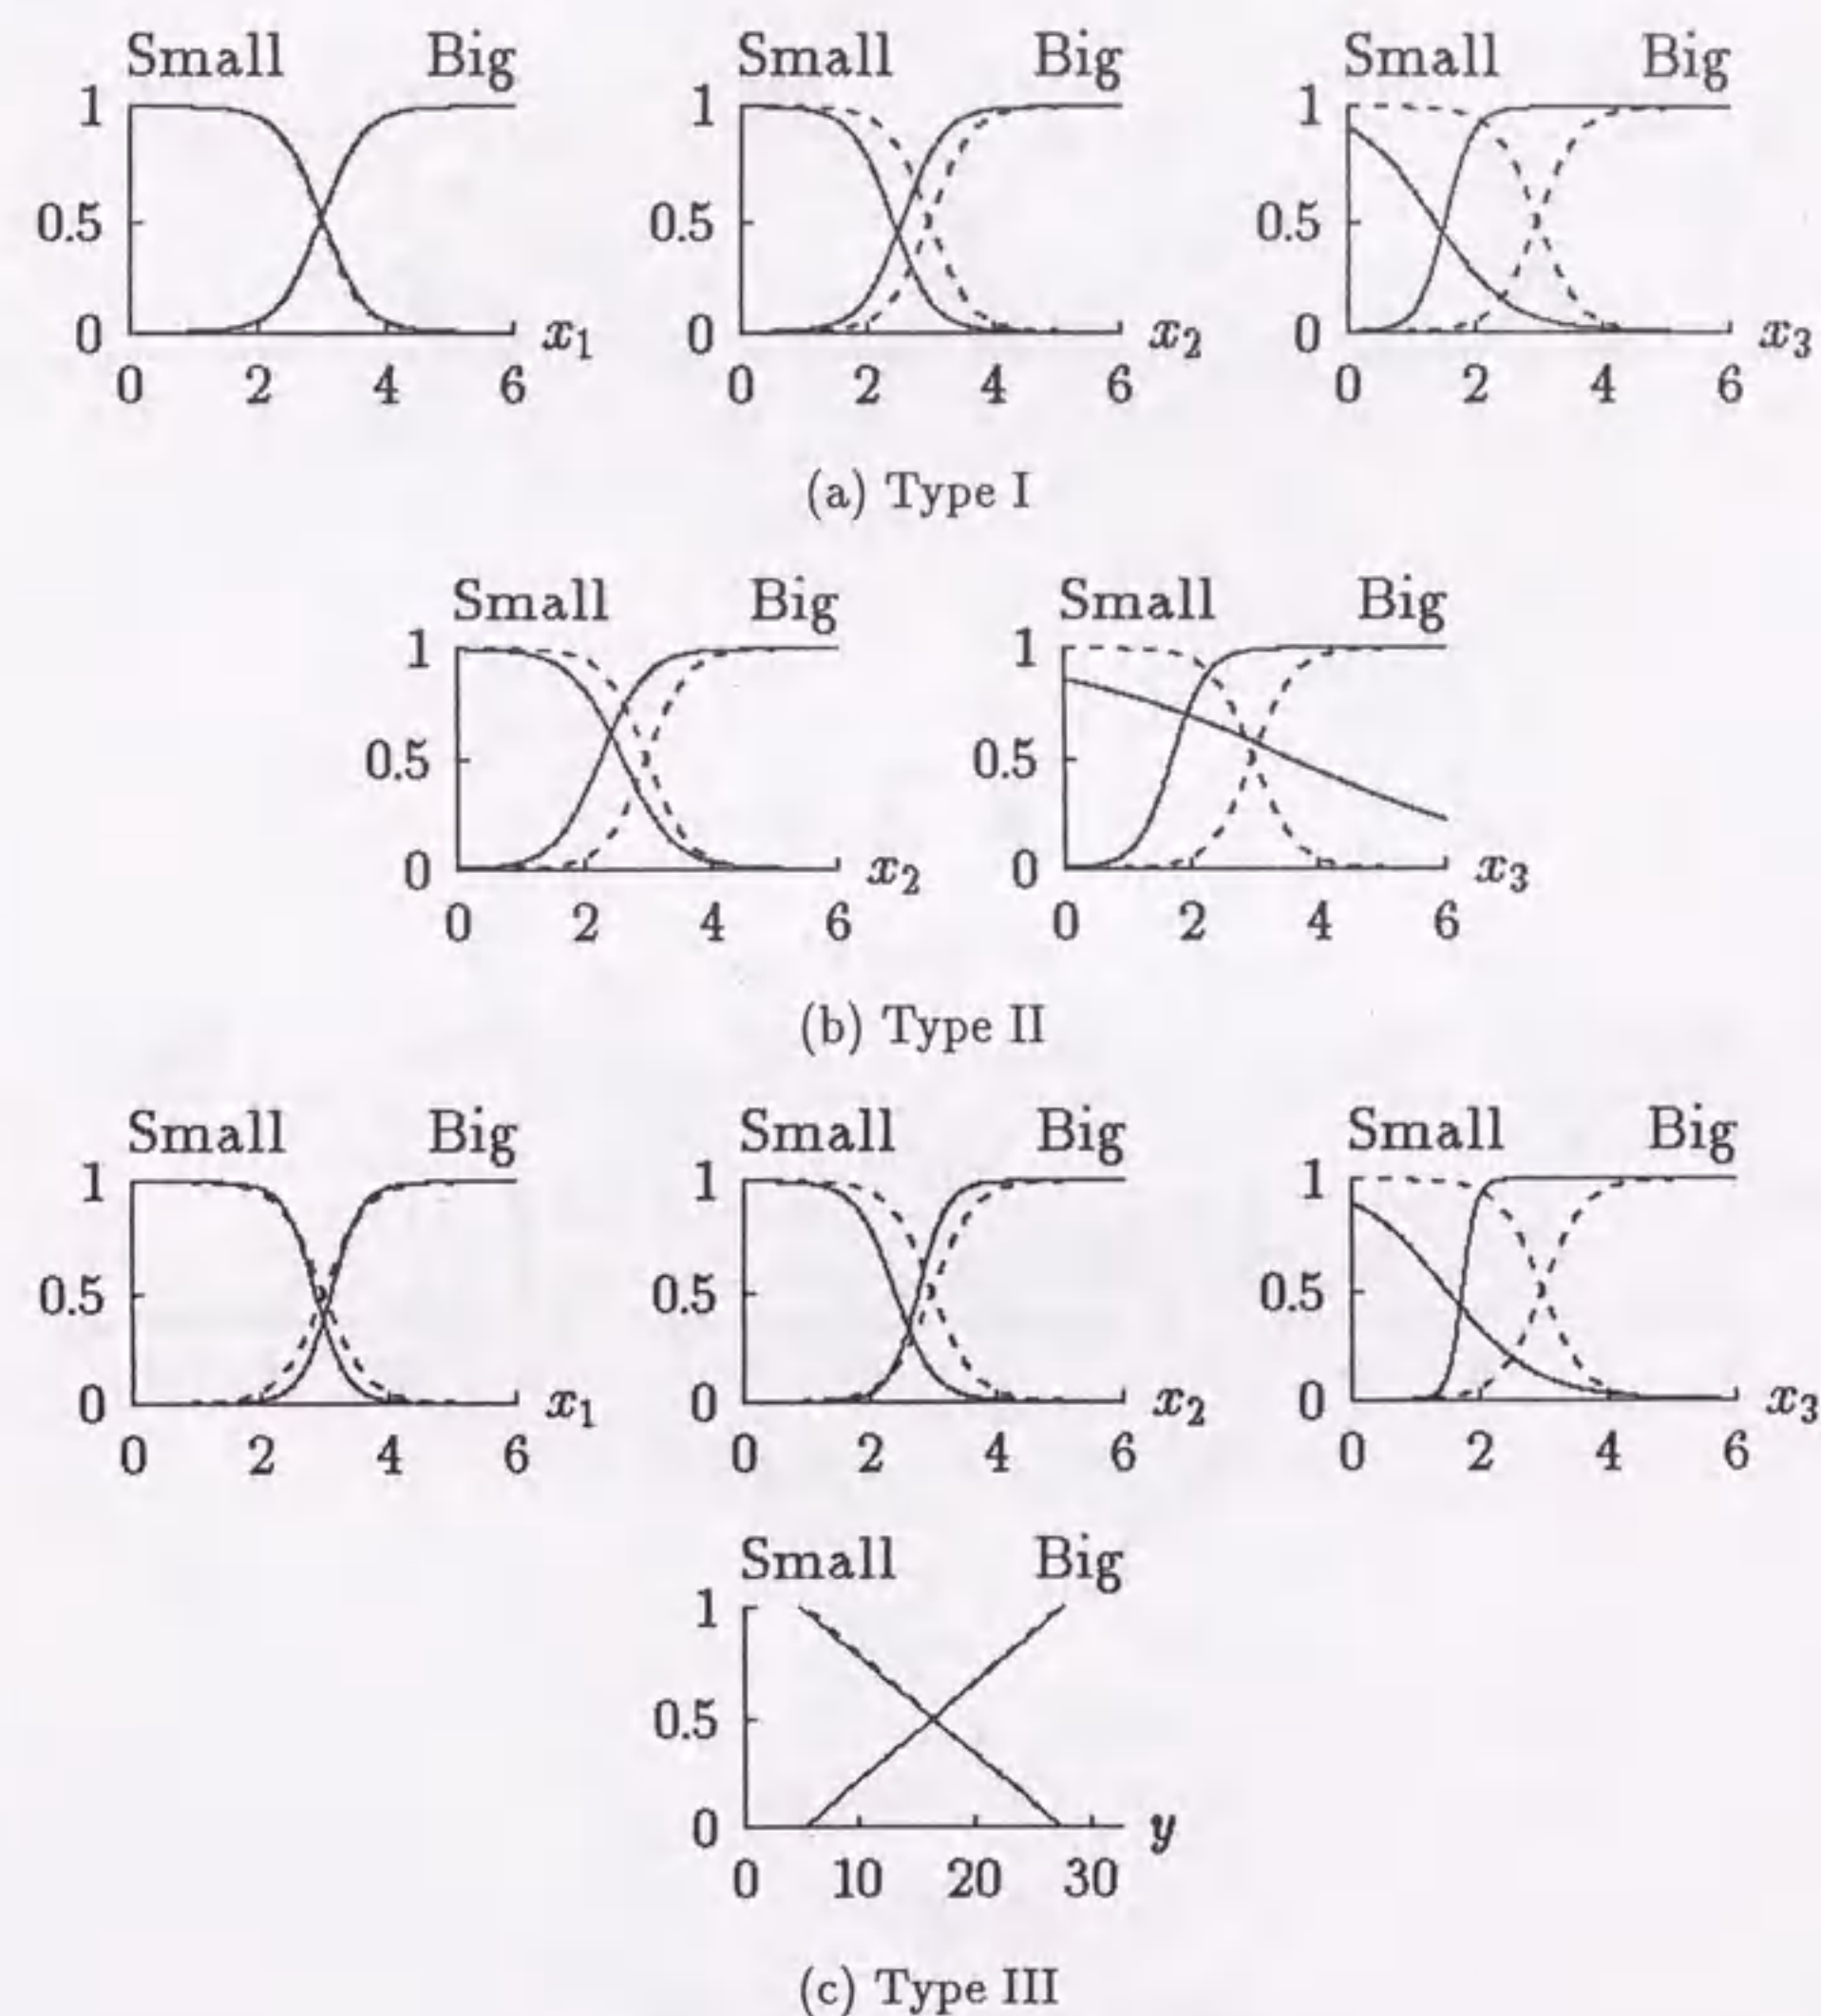


図 5.1: メンバーシップ関数

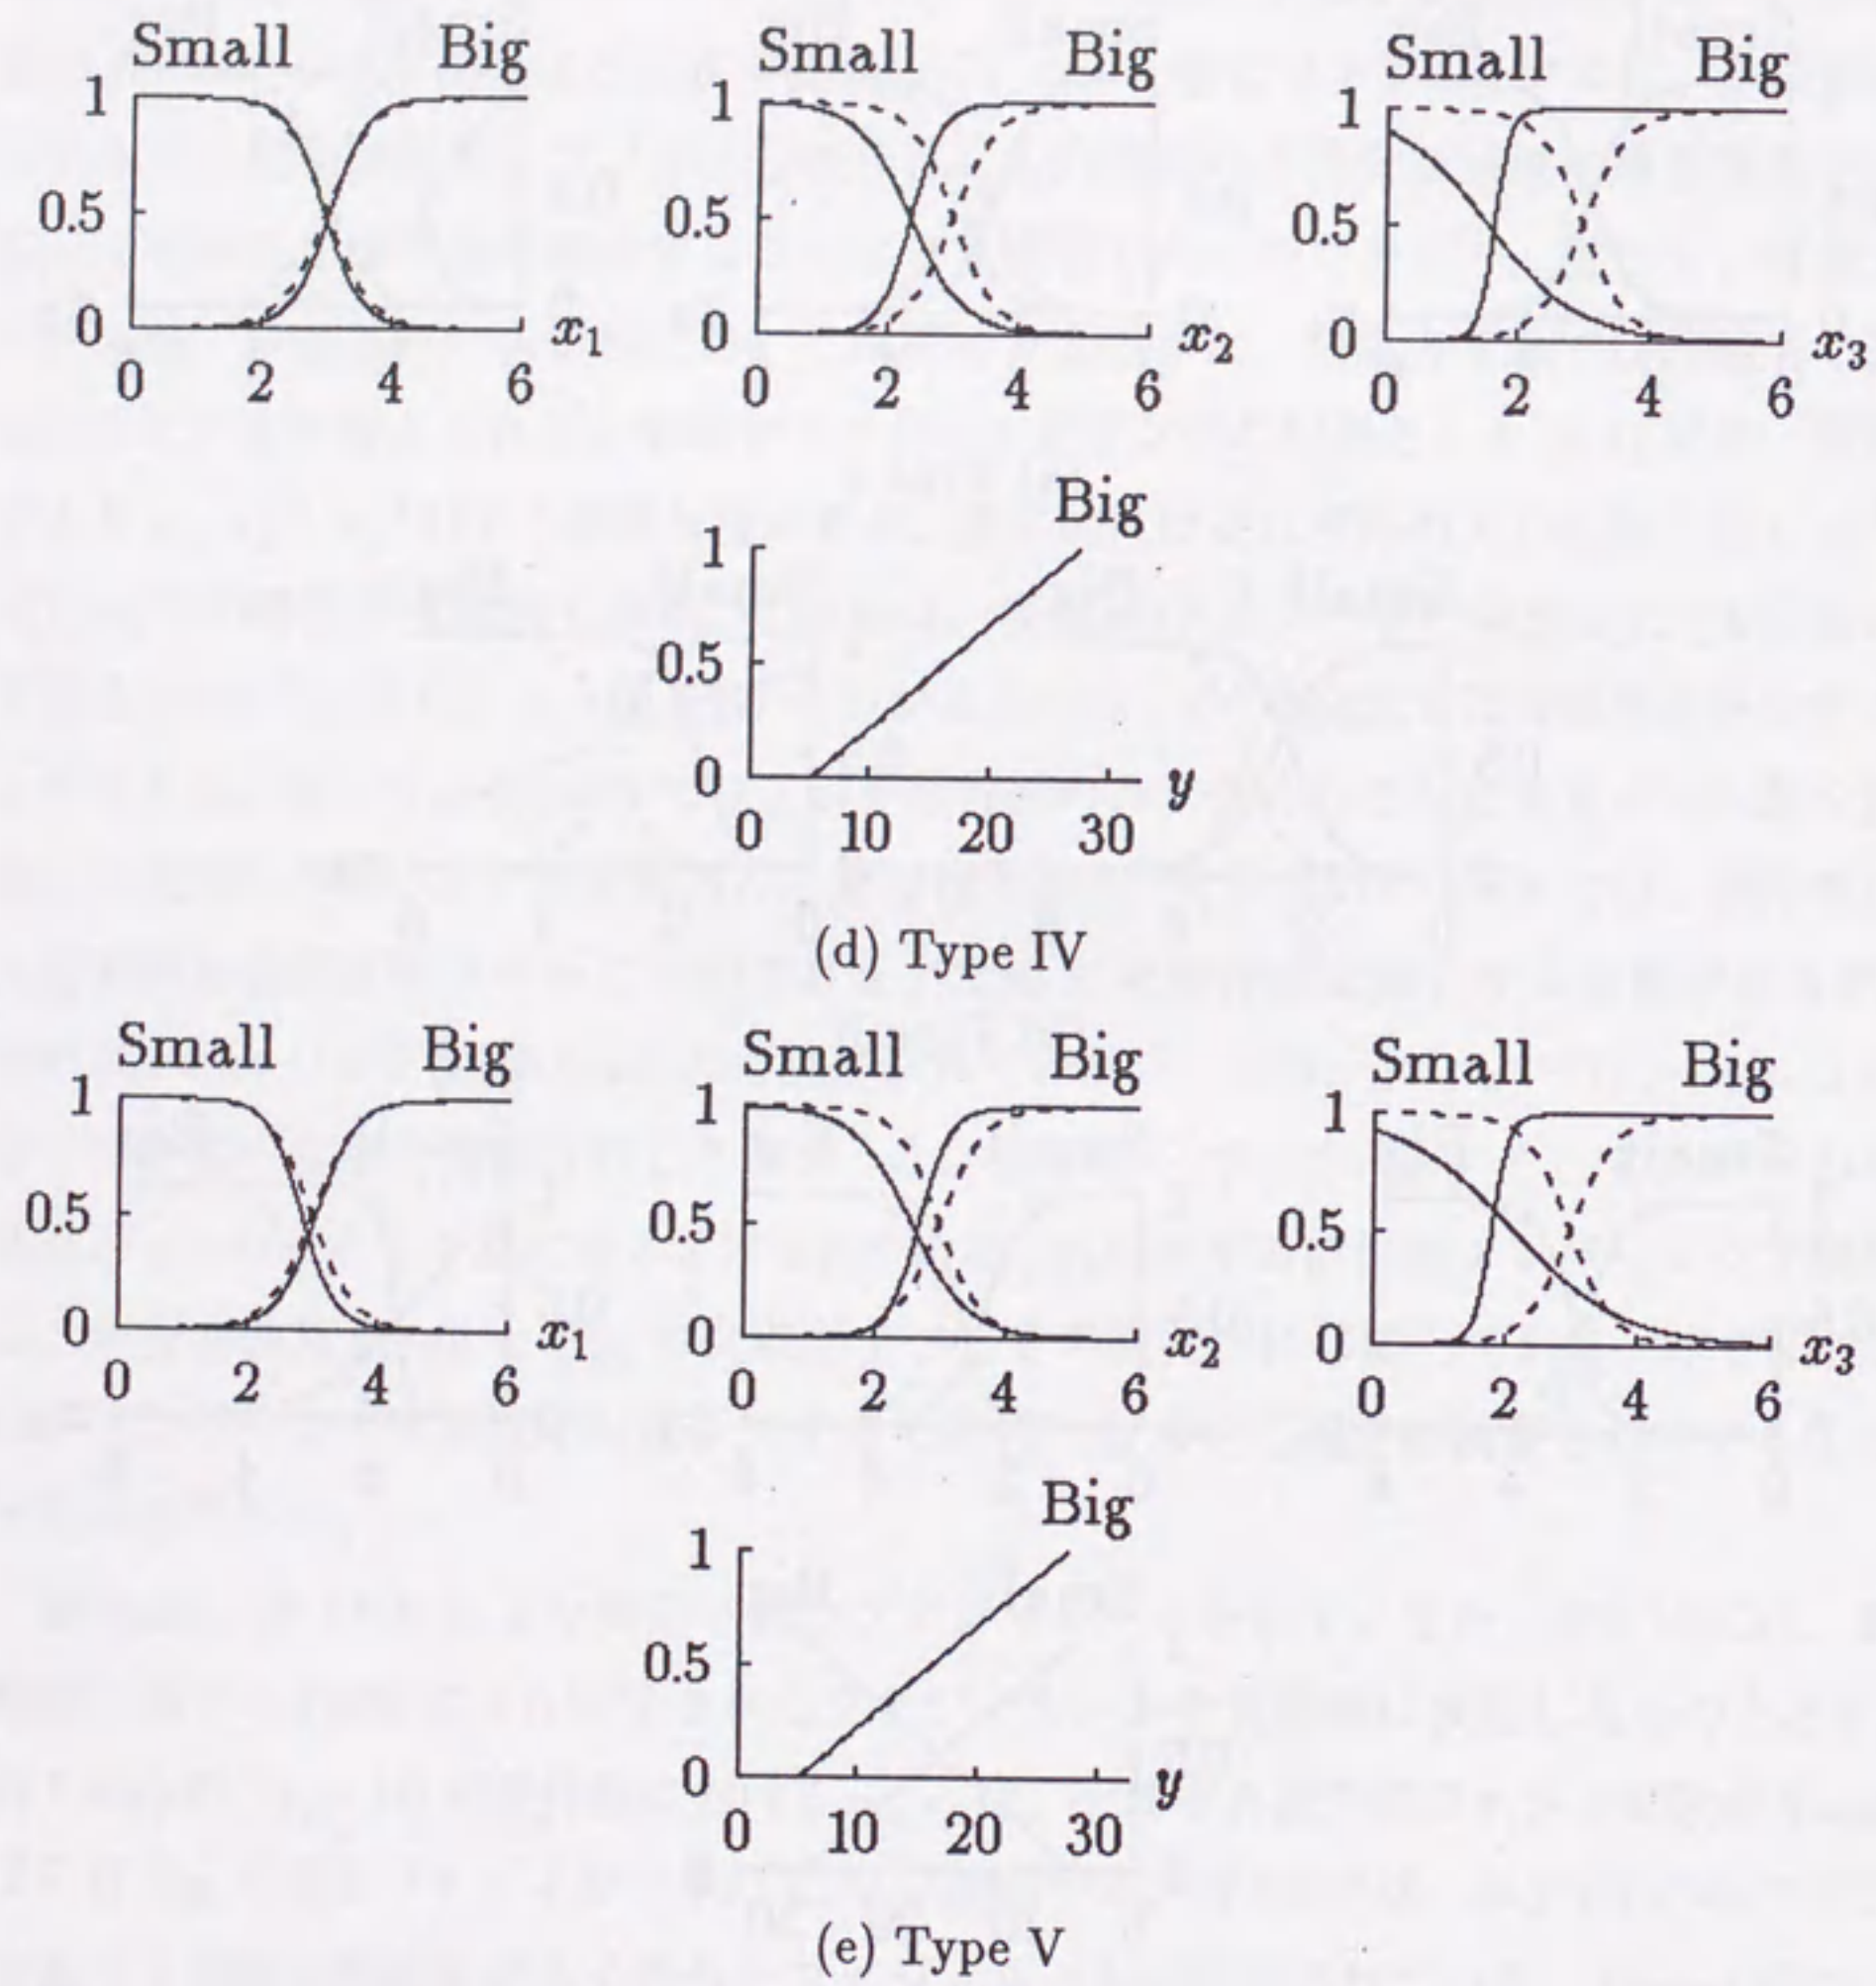


図 5.1: メンバシップ関数




図 5.2: $x^{0.5}, x^{-1}, x^{-1.5}$ の変化

表 5.9: 同定されたファジィルール

(a) Type I

前件部			後件部
x_1	x_2	x_3	f_i
Small	Small	Small	15.7
Small	Small	Big	9.8
Small	Big	Small	10.9
Small	Big	Big	5.3
Big	Small	Small	28.5
Big	Small	Big	19.0
Big	Big	Small	20.6
Big	Big	Big	12.6

(b) Type II

前件部		後件部
x_2	x_3	$f_i(x_1, x_2, x_3)$
Small	Small	$14.2 + 2.80x_1 + 0.57x_2 + 0.30x_3$
Small	Big	$2.4 + 2.10x_1 - 0.01x_2 + 0.40x_3$
Big	Small	$5.0 + 2.38x_1 + 0.79x_2 - 0.14x_3$
Big	Big	$-1.2 + 1.55x_1 + 0.21x_2 + 0.42x_3$

表 5.9: 同定されたファジィルール

(c) Type III

前件部			後件部	
x_1	x_2	x_3	τ_S	τ_B
Small	Small	Small	0.55	0.45
Small	Small	Big	0.83	0.30
Small	Big	Small	0.80	0.31
Small	Big	Big	1.00	0.11
Big	Small	Small	0.11	1.00
Big	Small	Big	0.41	0.63
Big	Big	Small	0.37	0.67
Big	Big	Big	0.69	0.36

(d) Type IV

前件部			後件部
x_1	x_2	x_3	τ_R
Small	Small	Small	0.50
Small	Small	Big	0.20
Small	Big	Small	0.23
Small	Big	Big	0.01
Big	Small	Small	1.00
Big	Small	Big	0.62
Big	Big	Small	0.66
Big	Big	Big	0.33

(e) Type V

前件部			後件部
x_1	x_2	x_3	$\tau_R(t)$
Small	Small	Small	$(t/0.43)^{0.96}$
Small	Small	Big	$(t/0.20)^{0.71}$
Small	Big	Small	$(t/0.26)^{0.65}$
Small	Big	Big	$(t/0.01)^{0.74}$
Big	Small	Small	$(t/1.00)^{0.92}$
Big	Small	Big	$(t/0.61)^{0.89}$
Big	Big	Small	$(t/0.66)^{0.89}$
Big	Big	Big	$(t/0.33)^{0.88}$

表 5.10: 同定されたファジィルールの言語的表記

(a) Type III

前件部			後件部
x_1	x_2	x_3	y
Small	Small	Small	Medium
Small	Small	Big	Medium Small
Small	Big	Small	Medium Small
Small	Big	Big	Small
Big	Small	Small	Big
Big	Small	Big	—
Big	Big	Small	Medium Big
Big	Big	Big	Medium Small

(b) Type IV

前件部			後件部
x_1	x_2	x_3	y
Small	Small	Small	Medium
Small	Small	Big	Medium Small
Small	Big	Small	Medium Small
Small	Big	Big	Small
Big	Small	Small	Big
Big	Small	Big	Medium
Big	Big	Small	Medium Big
Big	Big	Big	Medium Small

(c) Type V

前件部			後件部
x_1	x_2	x_3	y
Small	Small	Small	Medium
Small	Small	Big	more or less Medium Small
Small	Big	Small	more or less Medium Small
Small	Big	Big	more or less Small
Big	Small	Small	Big
Big	Small	Big	Medium
Big	Big	Small	Medium Big
Big	Big	Big	Medium Small

においても同様である。この Type III で “absolutely true” となるファジィルールは、(5.4) 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、表 5.10 では、(a) の Type III において前件部が “ x_1 is Big and x_2 is Small and x_3 is Big” であるファジィルールが言語的に解釈できなかった。これは、4.3 節で説明したように、Type III では (2.54) 式の仮定が必ずしも成立しないことによるものであり、それを満足する Type IV ではすべてのファジィルールが言語的に表されている。さらに Type V では、一部のファジィルールで “more or less” の言語ヘッジが付与されており、各ファジィルールの LTV をファジィ集合とする有用性が示されている。

5.4 まとめ

本章では、本 FNN を用いたファジィモデリング手法を提案し、簡単な非線形システムに適用することによりその有用性を検証した。本 FNN によれば、任意の非線形システムのファジィモデルを自動的に精度よく同定することができる。また、各タイプに基づく推論法の違いから、同一のシステムに対しそれぞれの特徴や記述能力差がよく表れたファジィモデルを同定可能である。ファジィモデルは、対象システムの入出力特性を従来の数式モデルに比べてわかりやすく表現できるため、制御分野だけでなく幅広い応用が期待できる。

第6章

結言

6.1 本研究の成果

ファジィ制御は、人間の持つあいまいな制御アルゴリズムを If-then 型のファジィルールにより言語的表現のままに記述できるヒューマン・コンピュータインタラクションに優れた制御法であり、これまでに幅広い分野で実用化が進められている。しかし、ファジィ制御器を設計する際のファジィルールの同定やメンバーシップ関数等のパラメータ調整は試行錯誤により行われることが多く、一般に多大な労力と時間を必要とする。

本研究は、このようなファジィ制御における問題点を NN の学習機能の応用により改善することを目的としたものであり、その主要な結果は本論文の第2章、第3章、第4章、第5章で述べられている。以下、各章における内容と得られた成果を順に示す。

本論文の第2章では、NN の学習機能によりファジィ推論における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る5種類の新しい FNN を提案した。本 FNN の前件部メンバーシップ関数は、学習において他のメンバーシップ関数よりも優れた特徴を持つ。また、本 FNN はファジィ推論を BP モデルの構造で実現しており、学習結果をファジィルールとして容易に把握できる。さらに、本研究で提案した5種類の FNN は、互いに異なるファジィ推論法を実現しており、同一の学習データに対しそれぞれ特徴あるファジィルールを同定可能である。特に間接法に基づく FNN は興味深く、同定されたファジィルールを言語的にわかりやすく表記することができる。この特徴は、本研究が初めて見出したものである。

本論文の第3章では、本 FNN の学習法について説明した。本 FNN は、学習則とし

てBP法を用いているが、ファジィ推論を実現するために特殊なユニットによりネットワークを構成しており、BP法におけるデルタルールも一般的なNNとは一部異なったものとなる。また、本FNNの結合荷重はすべて特定の意味を持つことから、適切な学習を行うには各結合荷重の学習率の選定に多大な労力が必要とされる。この問題に対して学習率設定における煩雑さを低減する手法を説明し、さらに、通常のBPモデルとの比較から本FNNが大規模な問題においても十分実用的であることを示した。

本論文の第4章では、本FNNのファジィ制御への応用として、熟練オペレータの操作パターンを基にファジィ制御器を構成するシミュレーションを行った。本FNNは、一般に困難とされる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えるため、熟練オペレータの操作パターンを学習データとして与えることにより容易にファジィ制御器を設計することができる。また、実現されたファジィ制御器は良好な制御性能を示し、通常的设计手法により獲得したファジィルールとほぼ同じものが同定された。これによって、本FNNが人間の直感によく合うファジィルールの同定可能であることが示された。

本論文の第5章では、本FNNを用いたファジィモデリング手法を提案し、簡単な非線形システムに適用することによりその有用性を検証した。本FNNによれば、任意の非線形システムのファジィモデルを自動的に精度よく同定することができる。また、各タイプが基づく推論法の違いから、同一のシステムに対しそれぞれの特徴や記述能力差がよく表れたファジィモデルを同定可能である。ファジィモデルは、対象システムの入出力特性を従来の数式モデルに比べてわかりやすく表現できるため、制御分野だけでなく幅広い応用が期待できる。

本FNNはこれまでに、製鉄所における転炉吹錬プロセス^[52]や織布のたて糸のり付工程^[53]のファジィモデリングおよびファンヒーターの制御等に実用化され、大きな成果を上げている。また、多属性意思決定問題^[54]やアバレルCAD^[55]など制御以外の分野にも適用例があり、本研究で提案したFNNは近年広く認められつつあるファジィ理論において有用なツールになり得ると期待される。

6.2 今後の課題

本研究において今後に残された課題としては、大きく分けて本FNNに関するものとそのファジィ制御への応用に関するものの二つがある。以下、それぞれについて簡単

に述べる。

まず、本研究で提案したFNNに関する課題としては、本FNNにおける学習過程の解析が挙げられる。本FNNが学習則として用いているBP法は、基本的に出力誤差の自乗和を最小化するためのものであり、ファジィモデルの細部において適切な学習が行われることは必ずしも保証されていない。特に前件部メンバーシップ関数は、ファジィモデルの入出力特性を定める上で大きな役割を果たしており、その学習による形状変化の解析は、ファジィモデリングにおいて対象システムに対する最適な構造の見極めに大変有用である^{[50][51]}。本FNNは、本質的に非線形なシステムであるため厳密な解析には多大な困難を伴うが、その結果は各結合荷重に対する学習率設定のさらなる単純化にも結びつけることができ、本FNNをより効率よく応用するためにもこの検討は行う必要がある。また、学習の高速化の一手法としては、ファジィ推論やNNで盛んに研究されているファジィチップやニューロチップのようなハードウェア化も今後の課題に挙げられる。

一方、ファジィ制御への応用に関する課題としては、制御対象のファジィモデルに基づくファジィ制御器の設計手法の確立が挙げられる。ファジィ制御は、これまでに様々な分野へ応用され有用性が広く認められているが、そのような実用面に比べて理論面が未だ整備されていないという問題がある。これに対し、従来の制御理論では、制御対象のモデルから安定性の保証された制御系を構築する手法が確立されている。ファジィ制御においてもそれに倣って、制御対象のファジィモデルからファジィ制御器を設計する手法が種々提案されている^{[14][56][57]}。しかし、それらはファジィモデルを数式化して用いており、ファジィモデルの言語的でわかりやすいという特徴が活かされていない。本研究で提案したFNNのうち、特に間接法に基づくものは言語的に表されたわかりやすいファジィモデルを自動的に同定することができる。このようなファジィモデルを基に、制御理論に関する特別な知識を必要とすることなくファジィ制御系を定性的に設計する手法の確立が望まれる。また、本FNNは、学習機能を備えたファジィ推論システムであり、ファジィ適応制御器の実現も期待できる。ファジィ制御器の設計を定性的に行い制御性能の改善に適応機能を用いれば、ヒューマン・コンピュータインタラクションに優れたファジィ制御システムを構築することができる。さらに、ファジィ制御系における安定性等の諸特性の解析についても、ファジィモデルを用いて定性的に行えるような手法が望まれる^[58]。

謝 辞

本研究の遂行に際し、終始並々ならぬ御指導と御鞭撻を賜りました名古屋大学工学部電子情報学科教授・工学博士内川嘉樹先生に深く感謝いたします。本研究の前半にいろいろと御指導を賜り、また、本論文をまとめるにあたって貴重な御助言をいただきました名古屋大学工学部電気学科教授・工学博士大熊繁先生に心より感謝いたします。

名古屋大学工学部電子情報学科助教授・工学博士古橋武先生には、本研究を進めるにあたり終始一貫して直接に熱心な御指導を賜りました。ここに、厚く御礼申し上げます。本研究に対し、NNの立場から御助言を賜りました中部大学工学部電気工学科助教授・工学博士郷原一寿先生に深く感謝いたします。また、従来の制御理論の立場から御助言を賜りました名古屋大学工学部電気学科助手・工学博士鈴木達也先生、名古屋大学工学部電子情報学科助手・工学博士石黒章夫先生に心より感謝いたします。

トヨタ自動車株式会社広瀬工場電子生技部第3グループ・工学博士今井勝次氏にはNNの応用について、また、富士通VLSI株式会社CAD-CAM部第三技術課・中山正一氏には本FNNの応用について、有益な御助言あるいは御討論をいただきました。さらに、名古屋市工業研究所機械部繊維技術課・松下聖一氏、株式会社中部日立エレクトリック電力設計部・上田悟氏、名古屋大学大学院工学研究科博士課程後期課程1年・橋山智則氏、楊旭華氏、名古屋大学大学院工学研究科博士課程前期課程2年・長谷川貴史氏、名古屋大学大学院工学研究科博士課程前期課程1年・佐々木雄二氏、平賀一郎氏、名古屋大学工学部4年・山口政博氏には、本FNNの様々な分野への適用に関して御協力をいただきました。ここに、深く感謝いたします。

末筆となりましたが、日頃から苦楽を共にした名古屋大学大学院工学研究科博士課程後期課程2年・奥田利信氏、道木慎二氏、名古屋大学大学院工学研究科博士課程後期課程1年・八木透氏をはじめとする内川研究室と大熊研究室の諸氏、ならびに最後まで暖かく見守ってくれた両親に感謝いたします。

参 考 文 献

- [1] 菅野：ファジィ制御，日刊工業新聞社，1988
- [2] 廣田，他：ファジィシステム，計測自動制御学会編，1990
- [3] L. A. Zadeh："Fuzzy Sets"，Information and Control, Vol.8, pp.338-353, 1965
- [4] E. H. Mamdani："Applications of Fuzzy Algorithms for Control of Simple Dynamic Plant"，Proceedings of IEEE, Vol.121, No.12, pp.1585-1588, 1974
- [5] D. E. Rumelhart, J. L. McClelland and the PDP Research Group：Parallel Distributed Processing, The MIT Press, 1986
- [6] F. Rosenblatt："The Perceptron：A Probabilistic Model for Information Storage and Organization in the Brain"，Psychological Review, Vol.65, pp.386-408, 1958
- [7] 寺野，他：実用ファジィ制御技術，電子情報通信学会編，1991
- [8] L. A. Zadeh："Fuzzy Logic and Approximate Reasoning"，Syntheses, Vol.30, pp.407-428, 1975
- [9] 水本：ファジィ理論とその応用，サイエンス社，1988
- [10] 水本："ファジィ集合とファジィ推論"，第3回ファジィシステムシンポジウム講演論文集，pp.37-48, 1987
- [11] M. Mizumoto and H. -J. Zimmermann："Comparison of Fuzzy Reasoning Methods"，Fuzzy Sets and Systems, Vol.8, No.3, pp.253-283, 1982
- [12] 水本："ファジィ制御の改善法(IV) (代数積-加算-重心法による場合)"，第6回ファジィシステムシンポジウム講演論文集，pp.9-13, 1990

- [13] 市橋, 田中: "PID と FUZZY のハイブリット型コントローラー", 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
- [14] T. Takagi and M. Sugeno: "Fuzzy Identification of Systems and Its Applications to Modeling and Control", IEEE Transactions on Systems, Man and Cybernetics, Vol.SMC-15, No.1, pp.116-132, 1985
- [15] J. F. Baldwin: "A New Approach to Approximate Reasoning Using a Fuzzy Logic", Fuzzy Sets and Systems, Vol.2, No.4, pp.309-325, 1979
- [16] Y. Tsukamoto: "An Approach to Fuzzy Reasoning Method", Advances in Fuzzy Set Theory and Applications, pp.137-149, North-Holland Publishing Company, 1979
- [17] 水本: "ファジィ推論法", システムと制御, Vol.28, No.7, pp.436-441, 1984
- [18] S. Murakami and M. Maeda: "Automobile Speed Control System Using a Fuzzy Logic Controller", Industrial Applications of Fuzzy Control, pp.105-123, Elsevier Science Publishers B.V., 1985
- [19] R. M. Tong and J. Efstathiou: "A Critical Assessment of Truth Functional Modification and Its Use in Approximate Reasoning", Fuzzy Sets and Systems, Vol.7, No.1, pp.103-108, 1982
- [20] 向殿, 野島: "ファジィ推論における直接法と間接法に関する考察", 日本ファジィ学会誌, Vol.4, No.2, pp.325-333, 1992
- [21] 川瀬, 柳原: "ファジィ推論における間接法と直接法について", 第9回ファジィシステムシンポジウム講演論文集, pp.545-548, 1993
- [22] 林, 馬野: "ファジィ・ニューラルネットワークの現状と展望", 日本ファジィ学会誌, Vol.5, No.2, pp.178-190, 1993
- [23] 林, 高木: "神経回路網モデルによるファジィ推論の定式化", 第4回ファジィシステムシンポジウム講演論文集, pp.55-60, 1988

- [24] 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
- [25] 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
- [26] 今崎, 木治, 遠藤: "ファジィルール構造化ニューラルネットワーク", 日本ファジィ学会誌, Vol.4, No.5, pp.985-995, 1992
- [27] 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
- [28] 荒木, 野村, 林, 若見: "ルールを逐次的に生成するファジィモデリングの一提案", 日本ファジィ学会誌, Vol.4, No.4, pp.722-732, 1992
- [29] 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
- [30] 野村, 林, 若見: "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
- [31] 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.650-652, 1987
- [32] 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", 電子情報通信学会論文誌 D-II, Vol.J74-D-II, No.12, pp.1794-1802, 1991
- [33] 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
- [34] 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
- [35] 片山, 梶谷, 藤山, 西田: "メンバーシップ関数の形状パラメータに関する制約条件を考慮した勾配法によるファジィモデリング", 日本ファジィ学会誌, Vol.5, No.6, pp.1393-1407, 1993

- [36] 野村, 荒木, 林, 若見: “デルタルールによる学習型ファジィ推論-遺伝アルゴリズムによる前件部の構造同定”, 第1回インテリジェントシステム・シンポジウム講演論文集, pp.25-30, 1991
- [37] 西山, 高木, R. R. Yager, 中西: “遺伝的アルゴリズムを用いたファジィ推論ルールの自動生成”, 第8回ファジィシステムシンポジウム講演論文集, pp.237-240, 1992
- [38] 山本, 久保, 和多田: “遺伝的アルゴリズムによるファジィ制御のメンバーシップ関数の学習”, 第9回ファジィシステムシンポジウム講演論文集, pp.97-100, 1993
- [39] 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と学習法”, 日本ファジィ学会誌, Vol.4, No.5, pp.906-928, 1992
- [40] S. Horikawa, T. Furuhashi and Y. Uchikawa: “A New Type of Fuzzy Neural Network for Linguistic Fuzzy Modeling”, Proceedings of the 2nd International Conference on Fuzzy Logic & Neural Networks IIZUKA '92, Vol.2, pp.1053-1056, 1992
- [41] 堀川, 古橋, 内川: “間接法に基づくファジィニューラルネットワークの構成法”, 第3回インテリジェントシステム・シンポジウム講演論文集, pp.417-422, 1992
- [42] 増田, 夜久: “ユニット生成機能をもつニューラルネットワークによるファジィ推論ルールの獲得手法”, 日本ファジィ学会誌, Vol.5, No.2, pp.348-357, 1993
- [43] 下川: “ファジィ推論ニューラルネットワークの構成とルール自動抽出”, 電気学会論文誌 C, Vol.113-C, No.7, pp.510-519, 1993
- [44] 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
- [45] S. Horikawa, T. Furuhashi, S. Okuma and Y. Uchikawa: “A Fuzzy Controller Using a Neural Network and Its Capability to Learn Expert's Control Rules”, Proceedings of the International Conference on Fuzzy Logic & Neural Networks IIZUKA '90, Vol.1, pp.103-106, 1990

- [46] 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
- [47] 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とそのファジィモデリングへの応用”, 1991 Dynamics and Design Conference 「ファジィ/ニューラルネットワークの機械システムのダイナミクスと制御への応用」シンポジウム講演論文集, pp.5-12, 1991
- [48] S. Horikawa, T. Furuhashi, Y. Uchikawa and T. Tagawa: “A Study on Fuzzy Modeling Using Fuzzy Neural Networks”, Fuzzy Engineering toward Human Friendly Systems / Proceedings of the International Fuzzy Engineering Symposium '91 IFES '91, Vol.1, pp.562-573, 1991
- [49] 近藤: “モデルの次数を推定する改良形 GMDH”, 計測自動制御学会論文集, Vol.22, No.9, pp.928-934, 1986
- [50] 堀川, 古橋, 内川: “ファジィニューラルネットワークによるファジィモデルの前件部構造同定に関する考察”, 第2回インテリジェントシステム・シンポジウム講演論文集, pp.249-254, 1992
- [51] S. Horikawa, T. Furuhashi and Y. Uchikawa: “On Identification of Structures in Premises of a Fuzzy Model Using a Fuzzy Neural Network”, Proceedings of the 2nd IEEE International Conference on Fuzzy Systems FUZZ-IEEE '93, Vol.1, pp.661-666, 1993
- [52] 長谷川, 堀川, 古橋, 内川, 島村, 山田, 國武, 大塚: “転炉吹錬プロセスのファジィモデリング”, 日本ファジィ学会誌, Vol.5, No.2, pp.409-419, 1993
- [53] 松下, 黒宮, 高木, 古橋, 堀川, 内川: “ファジィモデリングのたて糸糊付工程への適用”, 第9回ファジィシステムシンポジウム講演論文集, pp.261-264, 1993
- [54] 橋山, 堀川, 古橋, 内川: “ファジィニューラルネットワークの多属性意思決定問題への応用”, 日本ファジィ学会誌, Vol.4, No.4, pp.753-758, 1992
- [55] 楊, 古橋, 尾崎, 大野, 内川: “デザイナの感性を活かすアパレル CAD に関する基礎的研究”, 第9回ファジィシステムシンポジウム講演論文集, pp.393-396, 1993

- [56] 鈴木, 中森, 香春, 山中: “ファジィモデルによるモデル予測制御系の設計法”, 第7回ファジィシステムシンポジウム講演論文集, pp.9-12, 1991
- [57] 田中, 佐野, 鈴木: “ファジィ最適フィードバック制御系の設計”, 第7回ファジィシステムシンポジウム講演論文集, pp.17-20, 1991
- [58] 古橋, 堀川, 内川: “ファジィ動的システムの挙動の記述に関する一提案”, 日本ファジィ学会誌, Vol.5, No.6, pp.1464-1470, 1993

研究業績

● 学術論文

- (1) 堀川 慎一, 古橋 武, 大熊 繁, 内川 嘉樹: “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
- (2) 中山 正一, 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による制御戦略知識の獲得”, 計測自動制御学会論文集, Vol.28, No.7, pp.899-901, 1992
- (3) 橋山 智訓, 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多属性意思決定問題への応用”, 日本ファジィ学会誌, Vol.4, No.4, pp.753-758, 1992
- (4) S. Horikawa, T. Furuhashi and Y. Uchikawa: “On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm”, IEEE Transactions on Neural Networks, Vol.3, No.5, pp.801-806, 1992
- (5) 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
- (6) 中山 正一, 古橋 武, 堀川 慎一, 内川 嘉樹: “ファジィニューラルネットワークによる制御戦略・戦術知識の獲得”, 日本ファジィ学会誌, Vol.4, No.5, pp.929-941, 1992
- (7) 長谷川 貴史, 堀川 慎一, 古橋 武, 内川 嘉樹, 島村 滋, 山田 稔久, 國武 意智, 大塚 晋: “転炉吹錬プロセスのファジィモデリング”, 日本ファジィ学会誌, Vol.5, No.2, pp.409-419, 1993

- (8) 古橋 武, 堀川 慎一, 内川 嘉樹: “ファジィ動的システムの挙動の記述に関する一提案”, 日本ファジィ学会誌, Vol.5, No.6, pp.1464-1470, 1993
- (9) S. Horikawa, T. Furuhashi and Y. Uchikawa: “Fuzzy Neural Networks for Non-linear Control”, Journal of Modelling and Scientific Computing, Vol.1, No.3, 1993 (印刷中)

● 国際会議

- (1) S. Horikawa, T. Furuhashi, S. Okuma and Y. Uchikawa: “A Fuzzy Controller Using a Neural Network and Its Capability to Learn Expert's Control Rules”, Proceedings of the International Conference on Fuzzy Logic & Neural Networks IIZUKA '90, Vol.1, pp.103-106, 1990
- (2) S. Horikawa, T. Furuhashi, S. Okuma and Y. Uchikawa: “Composition Methods of Fuzzy Neural Networks”, Proceedings of the 16th Annual Conference of IEEE Industrial Electronics Society IECON '90, Vol.2, pp.1253-1258, 1990
- (3) S. Horikawa, T. Furuhashi, Y. Uchikawa and T. Tagawa: “A Study on Fuzzy Modeling Using Fuzzy Neural Networks”, Fuzzy Engineering toward Human Friendly Systems / Proceedings of the International Fuzzy Engineering Symposium '91 IFES '91, Vol.1, pp.562-573, 1991
- (4) T. Hasegawa, S. Horikawa, T. Furuhashi, Y. Uchikawa, S. Shimamura, K. Fuki-age, T. Yamada and T. Suzuki: “A Fuzzy Modeling of BOF Using a Fuzzy Neural Network”, Nonlinear Phenomena in Electromagnetic Fields / Proceedings of the 4th International ISEM Symposium on Nonlinear Phenomena in Electromagnetic Fields ISEM-Nagoya, pp.61-64, Elsevier Science Publishers B.V., 1992
- (5) T. Furuhashi, S. Horikawa, Y. Uchikawa and S. Nakayama: “An Acquisition of Strategic and Tactical Control Rules Using Fuzzy Neural Networks”, Proceedings of the 2nd IEEE International Workshop on Advanced Motion Control AMC '92, pp.383-390, 1992
- (6) S. Nakayama, S. Horikawa, T. Furuhashi and Y. Uchikawa: “Knowledge Acquisition of Strategy and Tactics Using Fuzzy Neural Networks”, Proceedings of the International Joint Conference on Neural Networks IJCNN '92-Baltimore, Vol.2, pp.II-751-II-756, 1992
- (7) S. Horikawa, T. Furuhashi and Y. Uchikawa: “A New Type of Fuzzy Neural Network for Linguistic Fuzzy Modeling”, Proceedings of the 2nd International Conference on Fuzzy Logic & Neural Networks IIZUKA '92, Vol.2, pp.1053-1056, 1992
- (8) T. Hasegawa, S. Horikawa, T. Furuhashi, Y. Uchikawa, S. Shimamura, T. Yamada, O. Kunitake and S. Otsuka: “A Study on Fuzzy Modeling of BOF Using a Fuzzy Neural Network”, Proceedings of the 2nd International Conference on Fuzzy Logic & Neural Networks IIZUKA '92, Vol.2, pp.1061-1064, 1992
- (9) T. Furuhashi, S. Horikawa and Y. Uchikawa: “A Linguistic Stability Analysis of Fuzzy Control Systems Using a Fuzzy Modeling Method”, Proceedings of the IFToMM-jc International Symposium on Theory of Machines and Mechanisms, Vol.1, pp.108-112, 1992
- (10) T. Furuhashi, S. Horikawa and Y. Uchikawa: “On Stability of Fuzzy Control Systems Using a Fuzzy Modeling Method”, Proceedings of the 1992 International Conference on Industrial Electronics, Control, Instrumentation, and Automation IECON '92, Vol.2, pp.982-985, 1992
- (11) T. Hasegawa, S. Horikawa, T. Furuhashi, Y. Uchikawa, S. Shimamura, T. Yamada, O. Kunitake and S. Otsuka: “An Application of Fuzzy Neural Network to Fuzzy Modeling of a Basic Oxygen Furnace”, Proceedings of the IEEE International Workshop on Neuro-Fuzzy Control -Instrumentation and Control Applications-, pp.133-138, 1993
- (12) T. Furuhashi, S. Horikawa and Y. Uchikawa: “An Application of Fuzzy Neural Networks to a Stability Analysis of Fuzzy Control Systems”, Proceedings of the

2nd IEEE International Conference on Fuzzy Systems FUZZ-IEEE '93, Vol.1, pp.369-374, 1993

- (13) S. Horikawa, T. Furuhashi and Y. Uchikawa : "On Identification of Structures in Premises of a Fuzzy Model Using a Fuzzy Neural Network", Proceedings of the 2nd IEEE International Conference on Fuzzy Systems FUZZ-IEEE '93, Vol.1, pp.661-666, 1993
- (14) T. Furuhashi, T. Hasegawa, S. Horikawa and Y. Uchikawa : "An Adaptive Fuzzy Controller Using Fuzzy Neural Networks", Proceedings of the 5th International Fuzzy Systems Association World Congress '93-Seoul, Vol.2, pp.769-772, 1993
- (15) T. Hasegawa, S. Horikawa, T. Furuhashi and Y. Uchikawa : "An Application of Fuzzy Neural Networks to Design of Adaptive Fuzzy Controllers", Proceedings of the 1993 International Joint Conference on Neural Networks IJCNN '93-Nagoya, Vol.2, pp.1761-1764, 1993
- (16) T. Hasegawa, S. Horikawa, T. Furuhashi and Y. Uchikawa : "An Adaptive Fuzzy Controller Using Linguistic Fuzzy Model of Controlled Object", Proceedings of the 1st Asian Fuzzy Systems Symposium AFSS '93, pp.386-393, 1993

