

ニューロファジイ推論の 移動体駆動シミュレーションへの適用

広内 哲夫

An Application of Neuro Fuzzy Inference to Simulating Drive Control of Vehicles

Tetsuo Hirouchi

Recently, The fuzzy systems and neural networks are making good progress. Some studies to unify both theories have got started. For an example, it is reported that membership functions in fuzzy theory can be determined automatically by making use of the merits of theory.

Last time, the author made some fuzzy expert systems simulating "drive control of vehicles", and discussed the efficiency of the fuzzy inference. This time, the author tried to unify both fuzzy systems and neural networks and to apply neural networks to determining the membership functions in regard to the simulation.

The results derived from the neuro fuzzy inference are almost same as results of the last study based on pure fuzzy inference. The author came to the conclusion that the neuro fuzzy inference can apply to decision making problem of management which doesn't require high accuracy.

1. はじめに

経営における意思決定, 医療における診断, あるいは心理学における判定などの分野にファジイ推論が適用され始め, 良好な結果が得られている^(1,2)。ファジイ推論はファジイ理論の一分野であり, モデル化の手法に言語表現によるモデリングを採用し, 曖昧さを許している。ファジイ理論においては, 曖昧さを数量的に表現するメンバーシップ関数が理論体系の中心に据えられており, この関数は各個人の主観によって決定される。そして, 場合によっては, 理論を適用したモデルの出力結果が妥当となるように, その関数を調整することも行われる。この作業は, 関数の形状を徐々に変更しながら試行錯誤的に行うので, かなりの経験を要するが, ファジイ理論は制御工学の分野では多大な成果を上げている。

主観の導入こそがファジィ理論の真髄であると考えて、ファジィ理論を積極的に評価する研究者がいる一方、思考錯誤的によってメンバーシップ関数を決定することに疑問を感じている批判派がいることも事実である⁽³⁾。彼らからするとメンバーシップ関数という主観を許容する不確かなものを理論体系に導入した付けが、その関数の調整という作業を強いていると考えるのである。このようなことから、これまでもメンバーシップ関数のあり方に関しては色々議論され、その決定法についても数多く報告されて来ている⁽⁴⁾。

一方、ニューラルネットワーク（神経回路網）の分野においては、1986年、ラメルハートらが、階層型ニューラルネットワークを用いたバックプロパゲーション学習（誤差逆伝搬学習）と呼ばれる手法を開発した⁽⁵⁾。これはニューラルネットワークに教師データを与えて、ネットワーク中のニューロンのシナプス結合に学習データを記憶させる方法である。学習を繰り返して行わせることによって、その記憶の正確さは増して来る。そして、ネットワークに評価データを与えると、そのネットワークは過去の学習経験に基づいて、評価データに対する結果を推論して出力する。この際、推論の過程における従来のような分析的なアルゴリズムは一切必要としない。このため、ニューラルネットワークは、アルゴリズムの判然としないパターン認識の解析などに向いている。

ファジィ推論におけるメンバーシップ関数の決定には特別なアルゴリズムが存在する訳ではなく、勘や経験（教師データ）を頼りに行われる。この点は教師データを必要とするニューラルネットワークと同じである。最近、ファジィ推論とニューラルネットワークの研究が進み、これらの両理論の補完的な関係が明らかになるにつれて、両者を融合させる研究が開始された。そして、両者のそれぞれ長所を生かし、メンバーシップ関数を自動的に決定する方法論の開発が徐々に行われ始めている。その報告は少ないが、主に電子総合技術研究所、富士通、松下電器産業などのハイテク関連の研究所や企業で行われている^(6,7,8,9)。

筆者は前回、移動体の駆動をファジィ推論によりシミュレートするファジィエキスパートシステムを作成し、ファジィ理論の適用性を論じた⁽¹⁰⁾。そこで今回は、ファジィ推論とニューラルネットワークを融合し、ファジィ推論の枠組みの中でメンバーシップ関数の決定にニューラルネットワークを適用することを試みることにした。この新しい融合方式の推論をニューロファジィ推論と呼ぶことにし、従来のファジィ推論を場合によってはネオファジィ推論と呼んで区別することにする。本論文の目的は、ニューロファジィ推論をネオファジィ推論と比較することによって評価することにある。そのため、本論文での移動体駆動シミュレーションは、前回の論文と同一の条件で行った。

2. 階層型ニューラルネットワーク

2.1 ニューロンによる信号の伝搬

最初にニューラルネットワークの概要を述べる⁽¹¹⁾。ニューラルネットワークは、図1に示すようなニューロン（神経細胞）と呼ばれるものが多数、相互に結合し合ったものである。ニューロンは、外部から信号（データ）を受容する入力点を多数もっており、その入力点はシナプス結合と呼ばれる。そして、ニューロンは唯一の信号のみを出力する。シナプス結合は入力信号に重み付けしてニューロン内部にそれを伝達する。シナプス結合が持つ重み付けの数值は重み係数と呼ばれる。ニューロンの内部状態は、外部からの信号入力との総和によって定まる。ニューロンの重み係数を w_i 、シナプス結合を通る入力信号を x_i とすると、ニューロンの内部状態は、その積和演算で表される。




図1 ニューロンの構成

$$u = \sum_i w_i x_i \quad (1)$$

ニューロンは内部状態が u の時、次の式に従う信号を外部のニューロンに対して出力する。

$$z = f(u - h) \quad (2)$$

ここで、 h はニューロンのしきい値である。関数 f としては実用上、 $x = -\infty$ で $f = 0$ 、 $x = \infty$ で $f = 1$ の値に収束する次のようなシグモイド型関数が用いられる。

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

この関数に従うニューロンはシグモイド型ニューロンと呼ばれる。

バックプロパゲーション学習に用いられるニューラルネットワークは、図2に示すような階層型ニューラルネットワークと呼ばれるものである。これはニューロンが層状に重なった構造となっており、外部から信号を受信する層を入力層、信号を外部に伝達する層を出力層と呼んでいる。入力層と出力層の間には何層かの層が存在するが、これを隠れ層と呼んでいる。隣合う層のニューロン同士は相互に完全に結合し合うが、しかし、同じ層内のニューロン同士、および層間




図2 階層型ニューラルネットワーク

を飛び越えたニューロン同士は結合しない。本研究では、隠れ層は1層とする。

入力層のニューロンに与えられた信号は(2)式に従って、出力層に向かってニューラルネットワークの中を伝搬する。なお、入力層のニューロンは線形ニューロンが用いられる。

2.2 バックプロパゲーション学習

階層型ニューラルネットワークは、自らシナプス結合の重み係数を変化させることによって、入力信号に対して望ましい信号を出力する能力を持っている。これは入力信号を繰り返し取り込むことによって、そのパターンを自ら学習しながら記憶することが出来ることを意味する。この記憶は従来のコンピュータの記憶法とは異なり、パターンは各ニューロンのシナプス結合に分散されて記憶されるのである。このニューラルネットワークの学習法が一般にバックプロパゲーション学習（誤差逆伝搬学習）と呼ばれるものである^(5,12)。

このアルゴリズムの基本は次の通りである。出力層のニューロンからの出力信号 z と教師信号 d の2乗誤差の総和

$$E = \frac{1}{2} \sum_i (z_i - d_i)^2 \quad (4)$$

を誤差の評価関数とする。重み係数を変化させると、評価関数 E は変化する。この変化は次のように起こる。偏微分 $\partial E / \partial w_{ji}$ が正の時、重み係数 w_{ji} を減らし、負の時、重み w_{ji} を増やせば、誤差関数 E は減少する。ここで w_{ji} の添え字 i, j は下位層のニューロン i から上位層のニューロン j へのシナプス結合を示す添え字を意味する。このことから、重み係数を徐々に変化させながら、誤差関数 E を減少させていくには、次の方程式

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} \quad (5)$$

を段階的に解いて行けばよいことになる。 η は学習係数と呼ばれ、正の値をとる。 Δw_{ji} は i から j へのニューロンの重み係数の変化分であり、学習回数を t で表すと

$$\Delta w_{ji}(t) = w_{ji}(t) - w_{ji}(t-1) \quad (6)$$

である。

Δw_{ji} は、次の一般化デルタルールと呼ばれる式によって具体的に表される。

$$\Delta w_{ji}(t) = \eta \delta_j z_i \quad (7)$$

ここで δ_j は、ニューロン j が、出力層に存在するか、隠れ層に存在するかによって異なった式となる。

$$\delta_j = f'(u_j - h_j) (\delta_j - z_j) \quad (\text{出力層の時}) \quad (8)$$

$$\delta_j = f'(u_j - h_j) \sum_k \delta_k w_{jk} \quad (\text{隠れ層の時}) \quad (9)$$

関数 f' は関数 f を微分したものである。(9)式の添え字 k は、ニューロン j が存在する隠れ層より下位の隠れ層に存在するニューロンを表している。(7)式で表されるシナプス結合の重み係数 w_{ji} の変化により、ニューラルネットワーク中に情報が記憶されるのである。

ところで、ニューロンの内部状態を

$$u = u - h \quad (10)$$

と改めて定義すれば、新しい内部状態は

$$u = \sum_i w_i x_i - h \quad (11)$$

となり、しきい値は、シナプス結合の重み係数が $-h$ で、常に出力を 1 とするようなニューロンと想定することが出来る。このようなニューロンはバイアスニューロンと呼ばれる。これにより、しきい値もシナプス結合の重み係数と同様に評価関数 E を減少させるために、変化させることが出来る。

なお、本研究では、繰り返しの収束を速くするために、(7)式に慣性項と呼ばれる付加項を付けた次の式を用いることとする。

$$\Delta w_{ji}(t) = \eta \delta_j z_i + \alpha \Delta w_{ji}(t-1) \quad (12)$$

ここで、 α は安定化係数と呼ばれる正の値であり、収束時に振動を抑える働きがある。

3. ニューラルネットワークとファジィ推論の融合

3.1 メンバシップ関数決定のニューラルネットワーク

ファジィ推論を現実の問題に適用する場合、問題となるのがメンバシップ関数の決定である。メンバシップ関数とは、本来、利用者の主観によって、自由に決定してよいものではあるが、実際にはその決定は面倒であり、その根拠も薄弱となってしまうことも多い。しかし、最近、メンバシップ関数の決定にニューラルネットワークを適用する手法もいくつか開発されている^(6,7,8,9)。ニューラルネットワークはすでに述べたように学習によって、パターンをそのネットワークの中に記憶させることが出来るのである。従って、ファジィ理論におけるメンバシップ関数もその中に憶え込ませることが可能となるのであるが、その方法を述べよう。

3.1.1 前件部変数が1つの場合

まず、以下のようなファジィ規則からなるファジィ推論を考察する⁽¹⁰⁾。前件部変数を x 、後件部変数を z とする。その入力空間のファジィ分割は 3 つであるとする。 $A_1, A_2, A_3, C_1, C_2, C_3$ は、それぞれ変数 x, z のとるファジィ値のファジィ集合である。

規則	if $x = A_1$ then $z = C_1$
	if $x = A_2$ then $z = C_2$
	if $x = A_3$ then $z = C_3$
事実	$x = A'$
-----	-----
推論結果	$z = C'$

これはファジィ集合 A' に対して、ファジィ規則を適用すると、推論結果としてファジィ集合 C' が得られることを意味する。メンバシップ関数を用いて、ファジィ推論の合成規則を max-min 合成演算で、ファジィ含意をマムダニの min 演算で行うと、その具体的な結果は次の

ようになる。

$$mC'_i(z) = \alpha_i \wedge mC_i(z) \quad (13)$$

ここで、 i は 1 から 3 までの値が対応する。 mC_i は、ファジィ集合 C_i のメンバーシップ関数であり、 \wedge は min 演算子である。 mC'_i はファジィ集合 C'_i のメンバーシップ関数である。 α は適合度と呼ばれる量であり、次の式で表される。

$$\alpha_i = \bigvee_x (mA_i(x) \wedge mA'(x)) \quad (14)$$

mA_i , mA' はファジィ集合 A_i , A' のメンバーシップ関数であり、 \bigvee は max-max 演算子である。

ところで、本研究の移動体駆動シミュレーションは一種のファジィ制御の応用であり、入力データ x はクリस्प値を用いるので、それを x_0 とすると、(14)式は以下のように簡単になる。

$$\alpha_i = mA_i(x_0) \quad (15)$$

それぞれのファジィ規則に対する推論は(13)式によって行われるので、最終的な推論結果は、個々の推論結果の max 演算から得られる以下のメンバーシップ関数 mC' で表される。

$$mC'(z) = mC'_1(z) \vee mC'_2(z) \vee mC'_3(z) \quad (16)$$

本研究の主目的は、上記のようなファジィ集合 A_1 , A_2 , A_3 のメンバーシップ関数をバックプロゲーション学習によってニューラルネットワークに記憶させるとともに、(15)式に示すような、各ファジィ規則の前件部と入力データ（クリस्पな事実）との適合度 α をそのネットワークから得ようとするものである。

以上の手続きを実現するニューラルネットワークを、上記のような3つのファジィ規則からなるファジィ推論について説明する。図3に示すように、3層のニューラルネットワークを構成する。これには隠れ層と出力層にバイアスニューロンを加えてある。入力層のニューロンは1つと




図3 メンバーシップ関数決定ネットワーク

し、出力層のニューロンの個数は、ファジィ規則の前件部変数 x に関する入力空間のファジィ分割数とする。この場合それぞれ3つである。隠れ層については任意でよい。教師データをファジィ分割に従って、3グループに分類する。そのグループを集合 A_1 , A_2 , A_3 に関連付けて A_1 グループ, A_2 グループ, A_3 グループと呼ぶことにする。

バックプロパゲーション学習における教師データの与え方を図3を用いて説明する。まず、第1回目の学習で、 A_1 グループの教師データを1つ選んで、入力層のニューロンにそれを、出力層のニューロン a に1を、その他 b, c には0をそれぞれ与える(図3はこの回の学習を示す)。2回目の学習では、 A_2 グループの教師データを1つ選んで、入力層のニューロンにそれを与え、出力層のニューロン b に1, その他 a, c には0をそれぞれ与える。また3回目の学習では、 A_3 グループの教師データを1つ選んで、入力層のニューロンにそれを、出力層のニューロン c に1を、その他 a, b には0をそれぞれ与える。以上の手続きを、教師データを順繰りに交換しながら(すべてのデータを使用したら最初のデータに戻る)何度も繰り返す。2.2節の(4)式の誤差関数 E が0.05以下になったら終了する。




図4 前件部のメンバーシップ関数

このような繰り返しの後、ニューラルネットワークには、図4に示すようなメンバーシップ関数が記憶される(図4の x 軸の x_1, x_2, x_3 は、 A_1 グループ, A_2 グループ, A_3 グループに分類される教師データのそれぞれの平均値を示す)。そして、ニューラルネットワークからは、入力データが与えられると、そのデータとメンバーシップ関数の適合度が出力される。この値を対応するファジィ規則の後件部の頭切りに用いる。以上に示したニューラルネットワークをメンバーシップ関数決定ネットワークと呼ぶことにする。

3.1.2 前件部変数が2つ以上の場合

実用上は、ファジィ規則の前件部がファジィ基本命題の連言によるファジィ複合命題から構成されることが多い。この場合のファジィ推論を考える⁽¹⁰⁾。ファジィ規則の前件部変数を x, y の2つとし、その入力空間および後件部変数 z の出力空間のファジィ分割数を、3.1.1項と同様にそれぞれ3とする。

規則	if $x = A_{si}$ and $y = B_{sj}$ then $z = C_{sk}$
事実	$x = A'$ and $y = B'$
推論結果	$z = C'$

ここで、 s はファジィ規則に関する添え字であり、1 から最大 9 まで値が対応する。 i, j, k は、前件部と後件部の入出力空間のファジィ分割に関する添え字であり、1 から 3 の値がそれぞれに対応する。

個々のファジィ規則によるファジィ推論は、以下の通りである。

$$mC'_s(z) = (\bigvee_x (mA_{si}(x) \wedge mA'(x))) \wedge (\bigvee_y (mB_{sj}(y) \wedge mB'(y))) \wedge mC_{sk}(z) \quad (17)$$

上式から分かるように、1 つのファジィ規則の中で前件部変数が 2 つ以上存在するときには、同一ファジィ規則内において得られた次の 2 つの適合度 α

$$\alpha_1 = \bigvee_x (mA_{si}(x) \wedge mA'(x)) \quad (18)$$

$$\alpha_2 = \bigvee_y (mB_{sj}(y) \wedge mB'(y)) \quad (19)$$

との間で \min 演算を行い、その結果を前件部の適合度とする。3.1.1 項で述べたのと同じ理由から、入力データはクリस्प値であるので、それを x_0, y_0 とすると、 α_1, α_2 は以下のように簡単になる。

$$\alpha_1 = mA_{si}(x_0) \quad (20)$$

$$\alpha_2 = mB_{sj}(y_0) \quad (21)$$

全体のファジィ規則からのファジィ推論は、以下のように(17)式の個別推論結果を \max 演算によって合成することから得られる。

$$mC(z) = \bigvee_x mC'_s(z) \quad (22)$$




図5 ファジィ推論の過程

メンバーシップ関数 m_A , m_B の決定には、2つのニューラルネットワークを用いて、それぞれのシナプス結合の重み係数を求めるのである。そして、連言を成す組 (20式と21式) の間で最小の適合度を求め、これを後件部のメンバーシップ関数の頭切りに使用するのであるが、このファジィ推論の関係を図5に示す。なお、このニューラルネットワークの構成法については後述する。

ファジィ規則の前件部変数 x , y の入力空間のファジィ分割数が、いまそれぞれ3としているので、最大 3×3 個のファジィ規則を設定することが出来る。しかし、実際のファジィ推論におけるファジィ規則の数は、ファジィ分割数の積よりも少ないのが普通である。これについては後に述べる。

3.2 min-max 演算のニューラルネットワーク

ファジィ規則の前件部におけるファジィ複合命題の min 演算および後件部におけるファジィ規則間の max 演算を行うニューラルネットワークを図6に示す⁽⁹⁾。これを構成するニューロンはすべてシグモイド型ニューロンではない。このニューラルネットワークを min-max 演算ネットワークと呼ぶことにする。入力層は線形ニューロンであり、その数は結合されたメンバーシッ

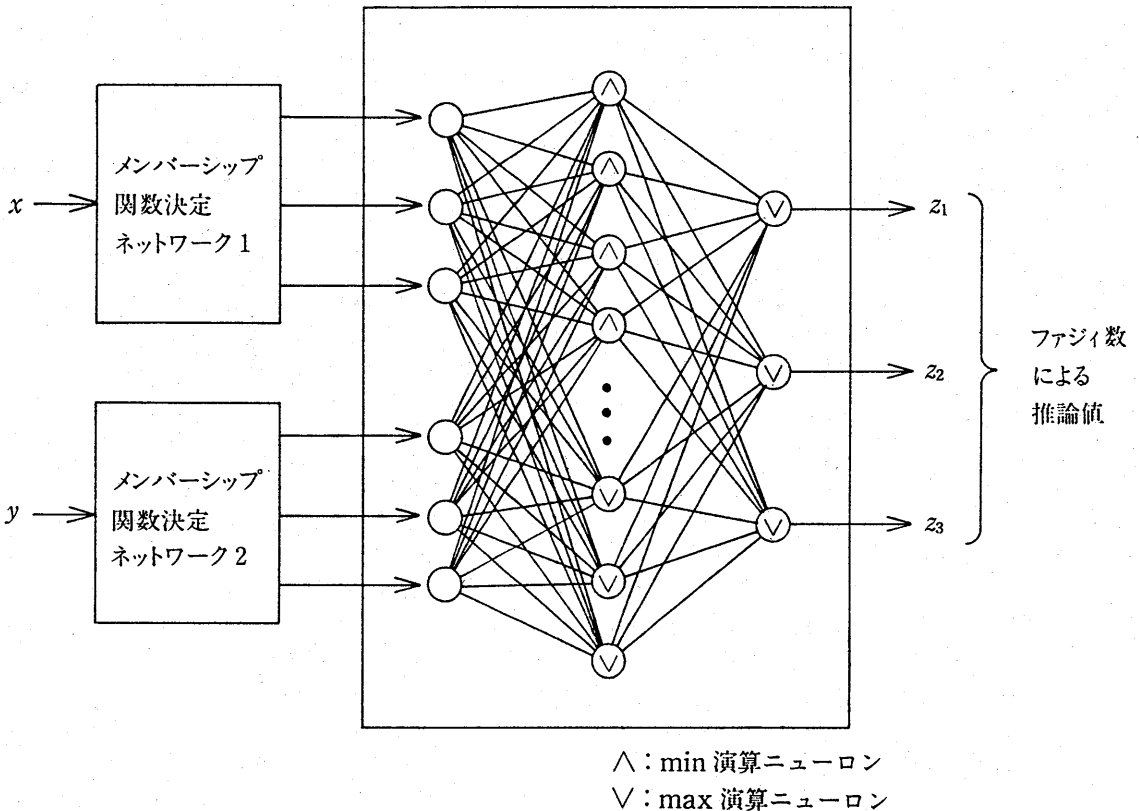


図6 min-max演算ネットワーク

ブ関数決定ネットワークの合計の出力数と同じである。隠れ層は min 演算ニューロンであり、その数はファジィ規則の数と同じである。出力層は max 演算ニューロンであり、その数はファジィ規則の後件部の出力空間のファジィ分割数と同じである。出力層のニューロンからの出力は、メンバーシップ関数の頭切りの値となるが、これが最終的なファジィ数としての推論値である。

min-max 演算ネットワークにおいては、バックプロパゲーション学習は行わず、シナプス結合の重み係数はすべて1とする。ニューロン間のワイヤリングは、ファジィ規則の内容に従って行うが、それについては4.1節で述べる。

3.3 重心算定のニューラルネットワーク

推論結果の非ファジィ化である重心を計算するニューラルネットワークを図7に示す。これは3層のネットワークであるが、バックプロパゲーション学習の対象となるネットワークではない。




図7 重心算定ネットワーク
(出力空間のファジィ分割が4つの場合)

これを重心算定ネットワークと呼ぶことにする。このような方式の算定法は富士通の川村ら⁽⁹⁾によって求められているが、それは特殊な場合についてである。そこで本論文では、それを一般化した方法を述べる。図8に示すようにファジィ規則の後件部のメンバーシップ関数の形状は台形型を用いる。そのファジィ集合の言語ラベルを $LB_1, LB_2, LB_3, \dots, LB_n$ で示し、各メンバーシップ関数と z 軸の交点の座標を z_1, z_2, \dots, z_n とする。特に z_1 と z_n をそれぞれ s, e と

しても表すことにする。 z 軸は言語ラベルの具体的尺度を数量として表す。

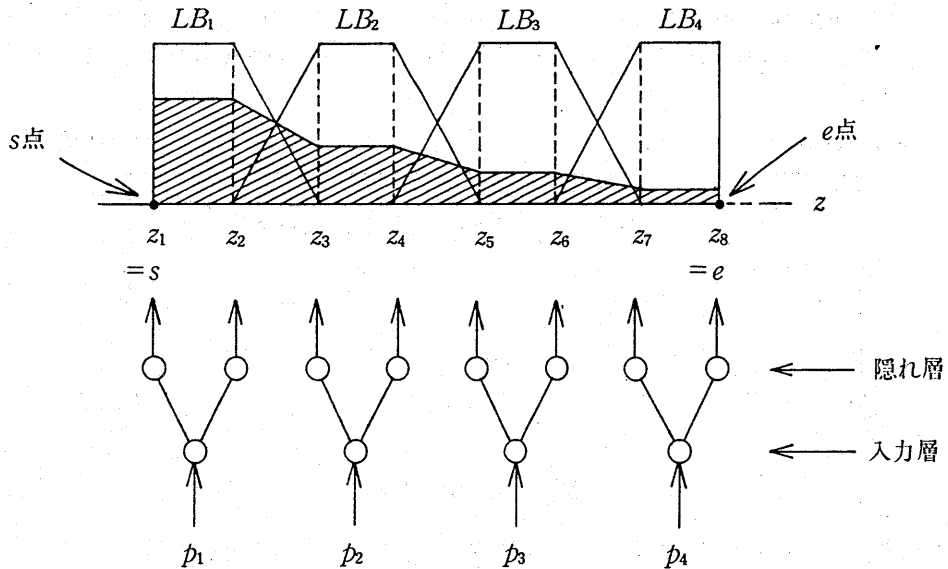


図8 ニューラルネットワークによる頭切り法
(出力空間のファジィ分割が4つの場合)

入力層のニューロンは、min-max演算ネットワークの出力層のニューロンと結合している。隠れ層のニューロンは線形ニューロンであり、その数はファジィ規則の後件部の各メンバーシップ関数と z 軸の交点の数と同じである。出力層のニューロンは線形ニューロンであり、その数は2つである。これは後述のように回転モーメントを求める働きをする。

各ニューロンのワイヤリングは次のように行う。入力層のニューロンと隠れ層のニューロンとは、完全結合形ではなく、図7のように入力層のニューロン1つに対して隠れ層のニューロンを2つずつ順番に結合する。このシナプス結合の重み係数は1である。ちなみに入力層のニューロンは隠れ層のニューロンに対して、後件部の適合度を伝える。隠れ層のニューロンは、図8に示すように、言語ラベルでラベル化された各メンバーシップ関数を頭切り（正確には、適合度を乗じている）している。

隠れ層のニューロンと出力層のニューロンは完全結合型であり、しきい値はともに0とする。その出力層のニューロン a と入力層のニューロン間のシナプス結合の重み係数は次のようになる。

$$w_{ai} = z_i - s$$

また、出力層のニューロン b と入力層のニューロン間のシナプス結合の重み係数を

$$w_{bi} = e - z_i + s \quad (24)$$

とすると、出力層のニューロン a, b は次の値を出力する。

$$m_a = \sum_i (z_{2i} + z_{2i-1} - 2s) \quad (25)$$

$$m_b = \sum_i (2s + 2e - z_{2i} + z_{2i-1}) \quad (26)$$

ここで、 p_i は min-max 演算ネットワークの i 番目のニューロンの出力値である。この m_a 、 m_b はそれぞれ座標 s の s 点、同じく座標 e の e 点を中心とする図形の面積の作り出す回転モーメントを示している (図9)。




図9 つり合いの条件

図形の重心 z_g は、この回転モーメントのつり合いの関係から求めることが出来る。重心を z_g とすれば、つり合の式は

$$m_b (z_g - s) = m_a (e - z_g) \quad (27)$$

であり、この式を解くと

$$z_g = \frac{em_a + sm_b}{m_a + m_b} \quad (28)$$

である。これが、非ファジィ化した推論値である。

なお、証明は省略するが、図10に示すようにメンバーシップ関数の形状が三角形となった場合には、通常、よく用いられる市橋らの簡易法 (後件部のメンバーシップ関数をクリップ値とする方法) で用いられる加重平均による推論値

$$z_g = \frac{\sum_i p_i z_i}{\sum_i p_i} \quad (29)$$

と一致する。




図10 簡易法に対応するメンバーシップ関数

4. 自動車の走行制御へのニューロファジィ推論の適用

筆者は前回の論文で、自動車の走行制御をシミュレートするファジィエキスパートシステムを作成し、その報告を行った⁽¹⁰⁾。走行制御は、速度、位置、停止の制御をすべてファジィ推論を用いて行うものであった。今回の研究は、そのファジィ推論（ネオファジィ推論）部分のみをニューロファジィ推論に置き換え、その両者の推論の特性を比較することである。このため本論文では、ニューロファジィ推論の実現の仕方だけを示すこととする。シミュレーションの枠組みについては、前論文を参照されたい。

4.1 速度制御

前回の論文で用いた速度制御に関するファジィ規則を以下に再掲する。

- 規則 1 if $x = PS$ and $y = ZO$ then $z = NG$
- 規則 2 if $x = PS$ and $y = PS$ then $z = NG$
- 規則 3 if $x = PS$ and $y = NG$ then $z = ZO$
- 規則 4 if $x = ZO$ and $y = ZO$ then $z = ZO$
- 規則 5 if $x = NG$ and $y = PS$ then $z = ZO$
- 規則 6 if $x = NG$ and $y = NG$ then $z = PS$
- 規則 7 if $x = NG$ and $y = ZO$ then $z = PS$

ここで、 x , y , z はそれぞれ、現在速度と目標速度との差、加速度の程度、加速機の出力を示す前件部変数と後件部変数であり、 NG , ZO , PS は、ファジィ集合である「負の値」、「ほとんど零」、「正の値」の言語ラベルである。 x , y に関する入力空間は図11に示すようにファジィ分割されている。 x と y がともに3つにファジィ分割されているので、最大9通りのファジィ規則の設定が可能であるがここでは、7通りのファジィ規則を用いている。図11の a と b の領域は




図11 速度制御における入力空間のファジィ分割

ファジィ規則が設定されていないので、文字通りファジィな領域となっているが、これはこれで構わない。




図12 速度制御のニューラルネットワーク




図13 速度制御のためのメンバーシップ関数

第3章に示したニューラルネットワーク構成法に従って、速度制御のそれを構成する。それを図12に示す。このうち、実際のバックプロパゲーション学習に参与するネットワークは、メンバーシップ関数決定ネットワークだけである。前回のネオファジィ推論で用いたメンバーシップ関数を図13に示す。言語ラベル NG , ZO , PS に関する目標速度との差と加速度の程度と加速機の出力のファジィ集合の代表点(クリस्प値)はそれぞれ $(-3, 0, 3$: 図13(a)の f_2, f_3, f_4 の値)と $(-2, 0, 2$: 図13(b)の g_2, g_3, g_4 の値)と $(-1.5, 0, 1.5$: 図13(c)の h_2, h_3, h_4 の値)であった。

今回のニューロファジィ推論ための教師データについては、言語ラベル NG , ZO , PS に関する目標速度との差、加速度、加速機の出力とも前回のネオファジィ推論で用いたそれらの代表点を採用した。目標速度との差と加速度の出力に関する2つのメンバーシップ関数決定ネットワークは、入力層、隠れ層、出力層のニューロンをそれぞれ1個、3個、3個で構成した。入力層を1つのニューロンとしているのは、入力データが1つであるためである。図12に示すように出力層のニューロン a と d はファジィ規則における言語ラベル NG に、ニューロン b と e は同じく ZO に、またニューロン c と f は同じく PS に対応する。従って、これらにニューロンから出力された値は、各言語ラベル付けされたメンバーシップ関数に対する適合度である。

バックプロパゲーション学習の条件は次の通りである⁽¹²⁾。節2.2の(4)式の誤差関数 E は0.05以下とし、重み係数 w_{ji} は絶対値0.3以内の乱数で、またしきい値は0でそれぞれ初期化した。学習係数 η は誤差によって変化させ、開始直後は0.75、誤差関数 E が0.5になったら0.5、 E が0.3になったら0.3とした。安定化係数 α は0.8とした。全繰り返し回数は136×3回であった。なお、今回の後件部の加速機の出力に関するメンバーシップ関数は、図14に示す形状のものを使用した。




図14 速度制御における加速機の出力のメンバーシップ関数

max-min 演算ネットワークのワイヤリングは、ファジィ規則の内容に基づいて行う。速度制御におけるファジィ規則の数は7つなので、隠れ層はそれと同数とし、ニューロンとファジィ規則を一对一対応させる。入力層と隠れ層のワイヤリングは、隠れ層から行うと分かりやすい。図12の上部に位置するニューロン r_1 は、第1番目のファジィ規則に対応したニューロンとする。そして、ファジィ規則の前件部のファジィ複合命題に基づいて、ニューロン r_1 をメンバーシップ関数決定ネットワークの出力ニューロン c と e に連結された入力層のニューロン c' と e' との間でワイヤリングする。次に位置するニューロン r_2 以下を同様にワイヤリングする。これにより前件部のファジィ複合命題の min 演算による連言処理を行うことが出来る。

出力層のニューロン g, h, i は、それぞれ言語ラベル NG, ZO, PS に対応している。隠れ層

のニューロンはファジィ規則と一対一対応しているので、そのニューロンは、そのファジィ規則の後件部のメンバーシップ関数の言語ラベルにも対応している。そこで、隠れ層からの出力層のワイヤリングは、同じ言語ラベルと対応するニューロン同士で行う。例えば図12では、ニューロン r_1 と r_2 は NG の言語ラベルに対応しているので、それらとニューロン g との間でワイヤリングする。これにより、ファジィ規則の \max 演算処理を行うことが出来る。

4.2 位置制御

前回の論文で用いた速度制御に関するファジィ規則を以下に再掲する。

- 規則 1 if $x = NB$ then $z = NG$
- 規則 2 if $x = NS$ then $z = NS$
- 規則 3 if $x = ZO$ then $z = ZO$
- 規則 4 if $x = PS$ then $z = PS$
- 規則 5 if $x = PB$ then $z = PB$

ここで、 x は定められた走行コースからのズレの距離を示す前件部変数、 z は自動車の走行角度を示す後件部変数であり、 NB , NS , ZO , PS , PB は、ファジィ集合である「大きな負の値」、「小さな負の値」、「ほとんど零」、「小さな正の値」、「大きな正の値」の言語ラベルである。 x , z に関する入出力空間はそれぞれ5つにファジィ分割される。

第3章に示したニューラルネットワーク構成法に従って、位置制御のそれを構成する。この場合には、速度制御のような \min - \max 演算ネットワークを用いる必要はなく、出力層を直接、重心算定ネットワークに結合させればよい。それを図15に示す。このうち、実際のバックプロパゲーション学習に関与するネットワークは、メンバーシップ関数決定ネットワークだけである。前回のネオファジィ推論で用いたメンバーシップ関数を図16に示す。言語ラベル NB , NS , ZO ,




図15 位置制御のニューラルネットワーク




図16 位置制御のためのメンバーシップ関数

PS, PB に関する距離と走行角度のファジィ集合の代表点 (クリस्प値) はそれぞれ (-40, -20, 0, 20, 40 : 図16(a)の f_2, f_3, f_4, f_5, f_6 の値) と (-72, -36, 0, 36, 72 : 図16 (b) の g_2, g_3, g_4, g_5, g_6 の値) であった。

今回のニューロファジィ推論のための教師データについては、言語ラベル NB, NS, ZO, PS, PB に関する距離, 走行角度とも前回のネオファジィ推論で用いたそれらの代表点を採用した。距離に関するメンバーシップ関数決定ユニットは、入力層, 隠れ層, 出力層をそれぞれ1個, 5個, 5個のニューロンで構成した。入力層を1つのニューロンとしているのは、入力データが1つであるためである。図15に示すように出力層のニューロン a, b, c, d, e は、ファジィ規則における言語ラベル NB, NS, ZO, PS, PB それぞれに対応する。従って、これらにニューロンから出力される値は、各言語ラベル付けされたメンバーシップ関数に対する適合度である。

バックプロパゲーション学習の条件は、速度制御の場合と全く同じとした。全繰り返し回数は 665×3 回であった。なお、今回の後件部の走行角度に関するメンバーシップ関数は、図17に示す形状のものを使用した。




図17 位置制御における走行角度のメンバーシップ関数

4.3 停止制御

前回の論文で用いた速度制御に関するファジィ規則を以下に再掲する。

- 規則1 if $x = BG$ then $z = BG$
- 規則2 if $x = MD$ then $z = MD$

- 規則3 if $x = SM$ then $z = SM$
 規則4 if $x = ZO$ then $z = zero$

ここで、 x は停止線からの距離を示す前件部変数、 z は自動車の停止速度を示す後件部変数であり、 BG , MD , SM , ZO は、ファジィ集合である「大きな値」、「中間の値」、「小さな値」、「直前の値」の言語ラベルである。 x , z に関する入出力空間はそれぞれ4つにファジィ分割される。




図18 停止制御のニューラルネットワーク

第3章に示したニューラルネットワーク構成法に従って、停止制御のそれを構成する。この場合には、位置制御と同様に min-max 演算ネットワークを用いる必要はない。それを図18に示す。このうち、実際のバックプロパゲーション学習に与するネットワークは、メンバーシップ関数決定ネットワークだけである。前回のネオファジィ推論で用いたメンバーシップ関数を図19に示す。言語ラベル SM , MD , BG に関する停止距離と停止速度のファジィ集合の代表点 (クリस्प値) はそれぞれ (0, 0.5, 1 : 図19(a)の f_1, f_3, f_4 の値) と (0, 0.5, 1 : 図19 (b) の g_2, g_3, g_4 の値) であった。




図19 停止制御のためのメンバーシップ関数

今回のニューロファジィ推論のための教師データについては、言語ラベル *MD*, *BG* に関する停止距離、停止速度とも前回のネオファジィ推論で用いたそれらの代表点 (クリस्प値) を採用した。しかし、*SM* については、停止距離 0.05 のとき、停止速度を 0 とした。これは、自動車が停止線をオーバーランしないようにするためである。また、*ZO* については、停止距離が 0 のとき、停止速度は -0.05 という負の値を採用した。これは、停止線上に位置したとき、船がスクリューを逆回転させるように、減速効果として負の値としたものである。

停止距離に関するメンバーシップ関数決定ネットワークは、入力層、隠れ層、出力層をそれぞれ 1 個、4 個、4 個のニューロンで構成した。入力層を 1 つのニューロンとしているのは、入力データが 1 つであるためである。図 18 に示すように出力層のニューロン *a*, *b*, *c*, *d* は、ファジィ規則における言語ラベル *ZO*, *SM*, *MD*, *BG* にそれぞれ対応する。従って、これらにニューロンから出力される値は、各言語ラベル付けされたメンバーシップ関数に対する適合度である。

バックプロパゲーション学習の条件は、速度制御の場合と全く同じとした。全繰り返し回数は 1646×3 回であった。なお、今回の後件部の停止速度に関するメンバーシップ関数は、図 20 に示す形状のものを使用した。




図 20 停止制御における停止速度のメンバーシップ関数

5. 結 果

メンバーシップ関数の設定条件は、前回のネオファジィ推論の場合と全く同様である。そのためのシミュレーションの条件も同じとした。これは、ネオファジィ推論とニューロファジィ推論を比較するためである。シミュレーションプログラムは Turbo-C コンパイラーを用いて作成し、

表 1 位置制御におけるメンバーシップ関数決定ネットワークの重み係数

	1	2	3	4	5
<i>a</i>	0.958	0.095	0.000	0.002	0.000
<i>b</i>	0.039	0.878	0.078	0.001	0.000
<i>c</i>	0.001	0.087	0.901	0.101	0.000
<i>d</i>	0.000	0.000	0.053	0.862	0.051
<i>e</i>	0.000	0.003	0.028	0.106	0.948




図21 得られたメンバーシップ関数
(位置制御における走行角度)

その実行は PC9801VM パソコンで行った。まず、バックプロパゲーション学習で得られたニューロンのシナプス結合の重み係数を表1に示す。これは、位置制御を行うためのメンバーシップ関数決定ネットワークに関する重み係数である。結果はマトリックス形式で配置したが(表1の行と列は、図15の出力層と隠れ層のニューロンにそれぞれ対応する)、この配置の場合には、学習に用いた教師データからして、本来、中心要素についての180度回転に対して、マトリックスは点対称にならなければならない。しかし、完全にはそうになっていない。初期値の設定や隠れ層の数によって、ニューラルネットワークの結果はばらつきが大きいと言われているが、それがこの結果にも現れている。また、図21に、その重み係数から得られたメンバーシップ関数の形状を示す。重み係数の非対称性を反映して、その形状にも若干の歪みが存在しているが、大局的にはほぼ満足すべき形状が得られたと言える。

表2にニューロファジィ推論に用いたファジィ規則の後件部のメンバーシップ関数のパラメーターの値を示す。本来用いるべき値は下段に括弧で示した。実際に使用したパラメーターの値が、本来使用すべきだった値と若干ずれているのは、ニューラルネットワークで得られたメンバー

表2 ニューロファジィ推論に用いた後件部の
メンバーシップ関数のパラメーター

	z_1, z_2	z_3, z_4	z_5, z_6	z_7, z_8	z_9, z_{10}
速度制御(距離のズレ)	-2.066 (-2.000)	0.0 (0.0)	2.0 (2.0)		
位置制御(走行角度)	-72.0 (-72.0)	-32.0 (-32.0)	-0.504 (0.000)	32.0 (32.0)	72.0 (72.0)
停止制御(停止速度)	-0.01 (-0.05)	0.036 (0.000)	0.5 (0.5)	1.0 (1.0)	

シップ関数が若干、対称性を欠いているためである。このずれの値は、実際に自動車走行シミュレーションを行って、ニューロファジィ推論とネオファジィ推論を比較して、修正することによって得られた値である。その修正作業は、両推論によって得られた推論データを比較したり、パソコン画面でモデル自動車の走行状況を注視して比較したりして総合的に行った。

このパラメーターの修正によって、ニューロファジィ推論はネオファジィ推論と比べてほんの少々劣る程度で、多くの場合は、ほぼ同程度のシミュレーションを実行することが出来た。

6. おわりに

本研究はニューロファジィ推論の効果を調査するのが目的であった。著者の目標は、ファジィ推論におけるメンバーシップ関数を自動的に決定する手法を確立することにある。このためには、まず、ニューラルネットワークから得られるメンバーシップ関数の特性を知ることであったが、本研究により、精度をそれほど要求しない経営の意思決定問題などには適用可能であろうということが推察された。今回はファジィ規則の前件部に関するメンバーシップ関数だけを自動決定の対象としたが、今後は後件部にも適用できる手法を確立し、完全なニューロファジィ推論を取り入れたデータ解析システムの枠組みを設定したい。

参考文献

- (1) 金子文司, 菅野道夫: 「ファジィ推論を利用した証券投資エキスパートシステム」, 情報処理, vol. 30, No 8 (1989)
- (2) 広内哲夫, 宮川浩之: 「企業診断ファジィエキスパートシステム」, 『社会・人文科学のためのファジィ論入門』, オーム社 (1993年初春行予定)
- (3) 菅野道夫: 「ファジィ理論の目指すもの—主観の科学化から科学の主観化へ—」, 『ファジィ—新しい知の展開—』, 日刊工業新聞社 (1989)
- (4) 下田睦, 石川知雄, 宮内新: 「ファジィ推論における if—then rule の導出」, 情報処理学会情報システム研究報告, 32—4 (1991)
- (5) D.E. ラメルハート, J.L. マクレランド, PDP リサーチグループ (甘利俊一監訳): 『PDP モデル—認知科学とニューロン回路網の探索—』 産業図書 (1989)
- (6) 古谷立美, 国分明男, 坂本健: 「NFS: ニューラルネットワークを用いたファジィ推論システム」, 情報処理学会論文誌, vol. 30, No 6 (1989)
- (7) 林勲, 野村博義, 若見昇: 「ニューラルネット駆動型ファジィ推論による推論ルールの獲得」, 日本ファジィ学会誌, vol. 2, No 3 (1990)
- (8) 高木英行, 香田敏行, 小島良宏: 「ファジィ推論アーキテクチャに基づくニューラルネットワーク」, 日本ファジィ学会誌, vol. 3, No 1 (1991)
- (9) 川村旭, 渡辺信雄, 大和田有理, 益岡竜介, 浅川和男: 「ニューロ・ファジィ融合システム」, 情報処理学会マイクロコンピュータとワークステーション研究報告, 66—3 (1991)
- (10) 広内哲夫: 「移動体の駆動をシミュレートするファジィエキスパートシステム」, 情報研究 (文教大学情報学部紀要), vol. 11 (1990)
- (11) J. デイホフ (桂井浩訳): 『ニューラルネットワークアーキテクチャ入門』, 森北出版 (1992)
- (12) 安西祐一郎: 『認識と学習』 岩波書店 (1989)