

ニューラルおよびファジイ手法応用による推論モデルの構築<sup>†</sup>

1P-10

音喜多 亨 ((株)松下通信仙台研究所)<sup>††</sup>

## 1. はじめに

知識処理手法の一般化応用にプロダクションルールを用いたルールベースシステムがある。また、あいまいな知識を扱うファジイ理論が提案され、推論等への応用が進められている。これらは主に人間の論理的思考に基づく方法であるが、実現には明示的かつ妥当な知識構造を必要とするため、いわゆる知識獲得ボトルネックの問題が存在する。一方、脳の情報処理をモデルとするニューラルネットワークは、学習能力や汎用性から広範な分野へ展開され、さらに、上記手法との相補的な取組みとして、推論・学習メカニズムや数値演算等の類似性に着目したニューラル・ファジイといった融合化も進展している<sup>1)</sup>。本報では、知識獲得に対する1アプローチとして、単純な力学的アナロジーを導入し、その枠組みに基づき各手法を融合した推論モデルの構築方法を提案、本方法の簡単な応用例について報告する。

## 2. 推論モデルの構築

## 2.1 推論と力学的アナロジー

推論に関して以下のアナロジーを考える。入力は推論を活性化し、推論は活性化された定性的事象や定性値の持つ“エネルギー”が推論構造中を伝搬する過程と捉える。エネルギーは伝搬過程で減少または供給を受け増加し、出力事象のエネルギーとして到達する。本報では、これらのエネルギーが構造中の相対的関係によるところや潜在的に存在し得る点から便宜的にポテンシャルとよぶ。定性的事象やルールなど知識の持つポテンシャルを知識ポテンシャルとし、個々知識のポテンシャルをルールポテンシャル等と称する。以下では、この枠組みとニューラルおよびファジイ手法を重ね合わせ、推論モデルの構築を検討する。具体的方法として、知識表現の観点から、(1)任意数のファジイ集合への量子化とメンバシップ関数設定、(2)ファジイプロダクションルールによる推論モデル形成、の2段階を考慮する。

## 2.2 ファジイ量子化とメンバシップ関数の設定

この段階では、推論に用いる入出力データの構成する多次元空間を複数領域に分割、各領域のデータ群と形成するポテンシャル分布を各次元に投影する。ここで、各次元の投影後データ群にラベル付けした定性的事象や定性値をファジイ集合、ポテンシャルをメンバシップ値に対応させ、ファジイ量子化とメンバシップ関数への置換を行う。分割には、データへの適応と自己組織化能力から、学習ベクトル量子化手法<sup>2)</sup>を適用する。置換は、単純に各データ群中最大ポテンシャルのデータの投影後座標を頂点、隣接の同座標を端点とする三角型メンバシップ関数とした。但し、各次元の端となる部分は、多数の次元の最小または最大を兼ねる点を固定の量子化ベクトルとし領域分割後、当座標を頂点とし各方向に開いた関数とした。本方法の概念を図1に示す。2つのデータ間のポテンシャル  $U$  はデータ間の距離  $r$  の関数による。データは  $[0, 1]$  に規格化している。

$$U = \frac{1}{1+r^2}$$

データ  $i$  のポテンシャルは所属するデータ群におけるデータ  $j$  とのポテンシャル  $U_{i,j}$  の平均値  $U_i = \frac{\sum_{j:j \neq i} U_{i,j}}{j-1}$  とする。また、本方法では、最大分割数  $C_{max}$  と最小ポテンシャル値  $U_{th}$  を設定し、以下の動的な量子化を実現した。分割数  $C$  と全データのポテンシャルの最小値  $U_{min} = \min_i U_i$  に関して、2つの条件  $C \leq C_{max}$ ,  $U_{min} \geq U_{th}$  を満たすまで、分割数を設定値より増加していく。 $C_{max}$  で適合しない場合、 $U_{th}$  を段階的に減少しながら処理を繰り返す。

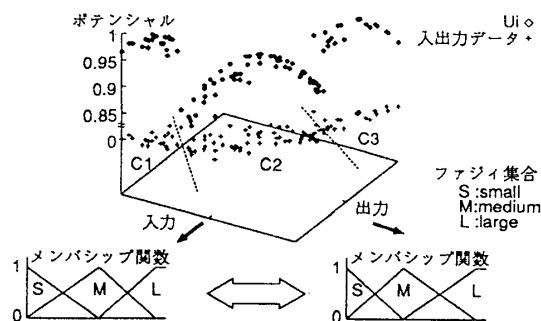


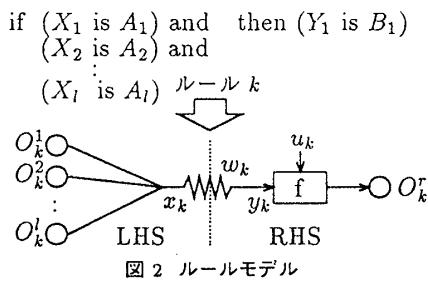
図1 ファジイ量子化・メンバシップ関数への置換

## 2.3 推論モデルの形成

本報では、前述の枠組みとファジイ推論<sup>3)</sup>に基づく図2のルールの集合体として推論モデルを構成する。ノードは LHS(Left Hand Side), RHS(Right Hand Side) の条件または結論要素であり、ファジイ命題である(以下、オブジェクトとよぶ)。ルール  $k$  では、

<sup>†</sup> Construction of Inference Model Using Neural Networks and Fuzzy Theory<sup>††</sup> Toru OTOKITA(Matsushita Communication Sendai R&D Labs. Co., Ltd.)

LHS のメンバシップ値であるオブジェクトポテンシャル  $O_k^l$  を評価し, LHS のポテンシャル  $x_k$  を決定する.  $x_k$  は伝搬係数  $w_k$  を介して RHS に  $y_k$  として伝搬する.  $y_k$  は推論構造への供給に等しいルールポテンシャル  $u_k$  と合成され, RHS のオブジェクトポテンシャル  $O_k^r$  が決定する. オブジェクトポテンシャル  $O^r$  は, 同一オブジェクトを RHS に持つ複数 ( $m$ ) 個のルール推論結果から決定される.



これらの推論演算を次式に示す.

$$\begin{aligned} x_k &= \min_l O_k^l \\ y_k &= x_k w_k \\ O_k^r &= f(y_k, u_k) \\ f(y_k, u_k) &= \frac{y_k + u_k}{1 + y_k u_k} \\ O^r &= \max_m O_m^r \end{aligned}$$

各値は  $O, w$  を  $[0, 1]$ ,  $u$  を  $[-1, 1]$  とする.  $f$  はポテンシャル  $y$  と  $u$  の合成関数である. 以上の演算は min-product-f-max 演算と言えるが,  $w, u$  を各々 1.0, 0.0 と固定するならば min-max 演算に等しい.

調整を要する伝搬係数  $w$  やルールポテンシャル  $u$  は, 入出力データにより決定する. 本報では, 調整に対し誤差逆伝播学習法<sup>4)</sup>と同様の方法を適用する.

$$w'_k = w_k + \alpha d_k x_k + N(\sigma, t)$$

$w'$  は学習後の伝搬係数,  $\alpha$  は学習係数,  $N$  は標準偏差  $\sigma$  の雑音項であり, 学習回数  $t$  による単調減少関数である.  $N$  は, 特に  $w_k = 1.0, u_k = 0.0$  設定時を含め, 初期値への依存性軽減と収束率向上を目的に導入した<sup>4)</sup>. 学習信号  $d$  は, 多段推論と推論パス形成への対応から, 出力のオブジェクトポテンシャルの誤差つまり出力段の  $O'$  と正解値(メンバシップ値)  $t$  の差  $e = t - O'$  を直接用いる. 調整対象は “ $O'$  を決定した入力段から出力段に到達するまでの推論パス上にあるルール” である. 同一ルールが複数の出力に関するパス上にあるとき, 各誤差の平均をとる.

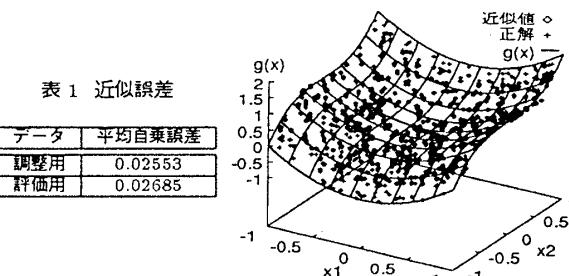
$$d_k = \sum_n \frac{e_n}{n} \frac{\partial f}{\partial y_k} \quad (n \geq 1)$$

$n$  はルール  $k$  の推論結果が出力段に到達した場合の推論パス数である.  $u$  は初期値を 0.0 と設定, 上の 2 式で  $x_k$  を 1.0,  $y_k$  を  $u_k$  として  $w$  同様に調整できる. 調整はパス形成を目的とした  $w$  終了後,  $u$  につ

いて行い, 必要により繰り返す. 評価は出力段での  $e$  の自乗和によるが, 非ファジィ化後の出力誤差と一致しない場合は後者の評価とする. 本調整は, 推論時に max 演算で推論ルールが決定することから一種の競合学習とみなせる. よって, ルールと推論パスを自己組織化できる. また, オブジェクトを 1 条件 1 結論のルールと考えれば上記の推論・学習メカニズムを適用でき, 入出力段のオブジェクトのファジィ集合に対してもメンバシップ関数の間接的調整となる. さらに, 調整時の  $w$  や  $u$  へのフォーカス設定, 正解のある任意ルールの調整可能といった特長がある.

#### 2.4 応用例

簡単な関数近似の例を示す. 以下では  $g(x) = x_1^2 + x_2^3$  ( $-1 \leq x_i \leq 1; i = 1, 2$ ) について乱数と白色雑音にてデータを作成,  $C_{max}$  を 5,  $U_{th}$  を 0.75 と設定し各次元で 3 つのファジィ集合へ量子化している. 推論モデルは 3<sup>3</sup> ルールと入力段のファジィ集合を 1 条件 1 結論のルールとする計 33 ルール, 2 段構造とした. 前者は  $w$  と  $u$ , 後者は  $u$  によるメンバシップ関数の調整 ( $w$  は 1.0 固定) を対象とした. 非ファジィ化は簡略化法<sup>3)</sup>のそれとし, その出力誤差で評価している. 調整後の結果を示す. 粗い方法であるが, ルールによる近似モデルが形成されていると考える.



#### 3. おわりに

推論モデルの構築に対して, 力学的なアナロジーの枠組みの中で自己組織化・学習メカニズムとしてのニューロ手法, あいまいな知識を扱うファジィ手法を融合した方法を示した. 今後, 本方法の具体応用への展開と検討を行う予定である.

#### - 参考文献 -

- 1) 林: “ファジィ制御とニューラルネットワークの融合法”, 情報処理, Vol.34, No.1, pp.44-51(1993).
- 2) Teuvo Kohonen: “The ‘Neural’ Phonetic typewriter”, IEEE COMPUTER, Vol.21, No.3, pp.11-22(1988).
- 3) 水本: “ファジィ制御向きのファジィ推論法”, 計測と制御, Vol.28, No.11, pp.17-21(1989).
- 4) 麻生: ニューラルネットワーク情報処理, 産業図書(1988).