

GAによるファジー推論自動チューニング・ツールの開発

2E-6

佐々木誠夫

富士総合研究所 解析技術第二部

1. まえがき

近年¹、ファジー推論の様々な制御系への応用、開発がさかんに行われている。例えば、プラント制御、画像処理におけるノイズを除去するためのフィルター、災害時における、人間の行動分析の推定などが挙げられる。

ルール作成のためのデータ形式が多入力1出力の場合には対象の複雑化のために、視覚的な認識に頼ることは難しく、設計者の思考錯誤によりルールの作成が行われることが常である。ここからルールの作成(ルール数、メンバーシップ関数の形状の決定)、すなわちルールのチューニングを自動的に行なうことが要求される。

現在行われている自動チューニングのための手法としては、第一にニューラル・ネットワークの学習能力を用いた方法がある。この手法では、基本的にバック・プロパゲーションを用いてチューニングを行う。解析的に解を求める手法という点ではメリットがあるが、チューニングの過程で、ルールが局所解に収束したり、アルゴリズムが複雑化してしまう傾向があると考える。

第二の手法として、遺伝的アルゴリズム(GA)とデルタ・ルールの組合せによるチューニング方法⁽²⁾⁽³⁾がある。要求される解を得るまでの計算時間についてのデメリットはあるものの、簡単なアルゴリズムによる自動チューニングが可能である。

ここでは、GAを用いた自動チューニング法を紹介する。また、既存の研究では、最適化すべき目的関数についての議論があまり行われていないが、目的関数について再考する。そして最後に同定問題として1次元及び2次元の非線形関数を対象にした結果を示す。

2. 後件部のチューニング

まず最初に、遺伝的アルゴリズムを用いたファジー・メンバーシップ関数の最適配置であるが。これは文献⁽²⁾と類似の手法を用いている。

後件部には、簡略ファジー推論⁽¹⁾を用いる。

$$\mu_i = \prod_{j=1}^n A_{ij}(x_j) \quad (1)$$

$$y_k = \frac{\sum_{i=1}^n \mu_i w_i}{\sum_{i=1}^n \mu_i} \quad (2)$$

A Development of Auto tuning tool for Fuzzy Inference by a GA

Shigeo Sasaki

Fuji Research Institute Corporation and Supercomputing Technology Div.

3-18-1 Kaigan, Minato-ku

ここで、 x_j : j番目の入力、 m : 入力の次元、 n : ファジールール数、 μ_i : 推論ルールの適合度、 A_{ij} : ファジー変数、 w_i : 後件部の重みである。

$$ER = \sum_{k=1}^N \frac{1}{2} (y_k - t_k)^2 \quad (3)$$

ここで、 ER : 入出力データに対する推論誤差、 t_k : x_k に対する出力値。

このとき、 $\partial^2 ER / \partial^2 w_i^2 \geq 0$ であることに注意する。ここから、与えられたメンバーシップ関数の配置に対して、 ER を最小にする($w_i, i = 1, \dots, n$)は一意的に決まることがわかる。

3. 目的関数の選定

過去の研究では、次のような目的関数⁽³⁾が提案されている。

$$F = C \times N + ER \quad (4)$$

ER : 最小二乗誤差、 N : 前件部のメンバーシップ関数の個数、 C : 定数。

この目的関数は単純で分かり易いが、パラメータCを決定する基準が難しい。

また、AIC基準(赤池情報量基準)⁽⁴⁾に基づく目的関数⁽²⁾も提案されている。

$$F = P \times \log(ER) + 2 \times N_p \quad (5)$$

P : 与えられた入出力データ数、 N_p : パラメータ数。AICを最小とすることは近似的にKL情報量(カルバック・ライブラー情報量)⁽⁴⁾を最小としていることを考慮すれば、真の分布をできる限り正確に近似するために合理的にモデルが選択される関数であることがわかる。このことは、場合によってはルールの数を抑える方向に機能しない。

ところで、要求される目的関数は、「誤差を最小にする」とこと及び、「ルール数を最小にする」という多目的関数の一種と考えられる。一般にルール数が増えれば、最小二乗誤差 ER は減少する傾向にあるが、これと同時にルール数を抑える作用も備えた目的関数とするためには、ルール数の増加に伴って誤差に敏感に反応する関数が適している。以下に提案する目的関数を示す。

$$F = N_p \times \exp(C \times ER) \quad (C = DN/P) \quad (6)$$

DN : サンプル数(数千程度)

DN を大きくすれば精度が上がり、逆に小さくすればル

ル数を抑えることができる。この関数において N_p が $N_p + \delta y$ になるときの x の値、すなわち方程式

$$N_p + \delta y = N_p \times \exp(C \times x) \quad (7)$$

を解くと次式が得られる。

$$x(N_p) = \frac{1}{C}(\log(N_p + \delta y) - \log(N_p)) \quad (8)$$

$\partial x / \partial N_p < 0$ 、 $\partial^2 x / \partial N_p^2 > 0$ から、 $x(N_p)$ は単調減少かつ下に凸な関数である。特に $C = 10$ 、 $\delta y = 1$ とおいたときの $x(N_p)$ を以下に示す。




図 3.1 関数 $x(N_p)$

$x(N_p)$ は、 N_p が増加するにつれて減少していくが、これは目的関数が、ルール数の増加に伴い誤差に敏感に反応することを示している。

4. 計算結果とまとめ

前節で提案した目的関数を基に同定問題に対する計算結果を示す。

● 1 次元非線形関数

$$y = 3.0 \times (x - 1.0)^2 + 3.0 \quad x \in [0, 2] \quad (9)$$




図 4.1 対象関数の形状

ここで、 x 軸上の 100 点をランダムに選び、その選択された座標に対応する $y(x)$ の値を、式 (9) から計算した 100 組の入力データに対して、固体数 11 で 20 世代まで計算した。チューニングされた結果を以下に示す。




図 4.2 式 (9) のチューニング結果

● 2 次元非線形関数

$$y = \exp(-7((x_1 - 0.5)^2 + (x_2 - 0.5)^2)) \quad (10)$$

$$x_1, x_2 \in [0.15, 1.85]$$




図 4.3 対象関数の形状

x_1, x_2 平面上の 200 点をランダムに選び、固体数 11 で 20 世代まで計算した。チューニングされた結果を以下に示す。




図 4.4 式 (10) のチューニング結果

以上の結果から、提案した目的関数が 1 次元のみならず 2 次元の非線形関数に対しても有効であることが分かった。

参考文献

- (1) 石橋 秀友、渡辺 俊彦：“簡略ファジー推論を用いたファジーモデルによる学習型制御”、日本ファジー学会誌、2、3、pp.429-437(1990)
- (2) 野村 博義、若見 昇：“遺伝的アルゴリズムによるファジー推論ルールの決定法”、信学論 A、Vol.177-A、No.9、pp.1241-1249(1994)
- (3) 福田 敏男、石上 秀之、新井 史人、柴田 崇徳：“遺伝的アルゴリズムとデルタルールによるファジー モデルの自動生成”、電学論 C、113巻7号(1994)
- (4) 北川 源四郎：「FORTRAN77 時系列解析プログラミング」、岩波書店