

定性的属性を含むデータからのファジイルールの自動抽出 -キッチン設計支援のために-

02004194	大阪大学	今村 佳世	IMAMURA Kayo
	大阪大学	* 篠原 清敏	SHINOHARA Kiyotoshi
	大阪府立大学	馬野 元秀	UMANO Motohide
01303394	大阪大学	田村 坦之	TAMURA Hiroyuki

1 はじめに

人間の持つ感じ方をコンピュータに模倣させる試みから生まれた『感性情報処理』の研究の有用性が、デザインやアートなどの分野で広く知られるようになってきた。この研究分野では、ニューラルネットワークや統計的手法などのアプローチを問題に応じて適用している。

我々は、システム・キッチンに対するユーザの感性評価を、アンケート調査データをもとにルールとして抽出する手法の研究を行っている [1]。キッチンのデザイン間の相互作用や、デザインとイメージの関係構造を明示的に取り出すことを考慮した場合、抽出手法としては、ファジィ・ニューラルネットワーク (FNN) の適用が望ましい手法の一つと考えられる。

しかし、従来の FNN では、定性的属性として表現されるキッチンのデザインが入力データとして取り扱えない。従って、本報告では、FNN で定性的な属性を扱うためのネットワーク構造と学習方法を提案する。そして、提案手法の効果を数値実験により示す。

2 FNN

入力データに定量的属性と定性的属性が混在する場合、それらのデータを同等に扱いながらファジイルールを抽出する手法を提案する。本研究では、簡略型ファジィ推論によるファジイルールを適用する。まず、以下に抽出するファジイルールを示す。

前件部が定量的属性 x_1, \dots, x_m と定性的属性 x_{m+1}, \dots, x_{m+n} からなり、後件部が y_1, y_2, \dots であるときのファジイルール j は

$$\begin{aligned} \text{if } & x_1 = A_{j1} \ \& \ \dots \ \& \ x_m = A_{jm} \ \& \\ & x_{m+1} = B_{j1} \ \& \ \dots \ \& \ x_{m+n} = B_{jn} \\ \text{then } & y_1 = C_{j1}, \ y_2 = C_{j2}, \ \dots \end{aligned}$$

となる。ここで、 A_{ji} 、 B_{ji} は第 j ルールの両属性の入力変数に対するメンバーシップ関数、 C_{jk} は第 j ルールの後件部変数 y_k の定数 (後件部実数値) である。

次に、定性的属性のためのメンバーシップ関数が必要になる。この場合は、数式でメンバーシップ関数を設

定することができないので、定性値とそのグレードの組の集合 (すなわち、列挙型のファジィ集合) で表現する。入力変数 x_i のとる定性値を c_1, c_2, \dots とし、各定性値に対するグレードを g_1, g_2, \dots とすると、次のように記述できる。

$$\{g_1/c_1, g_2/c_2, \dots\} \quad (1)$$

ここで、第 k 番目の定性値 c_k のグレード g_k は、 $0 \leq g_k \leq 1$ である。これを用いると、定性値 c_k をあたえると、グレードを 1 つ返すことができるので、これを定性値型メンバーシップ関数と呼ぶことにする。

このようなファジイルールをネットワーク表現すると図 1 のようになる。

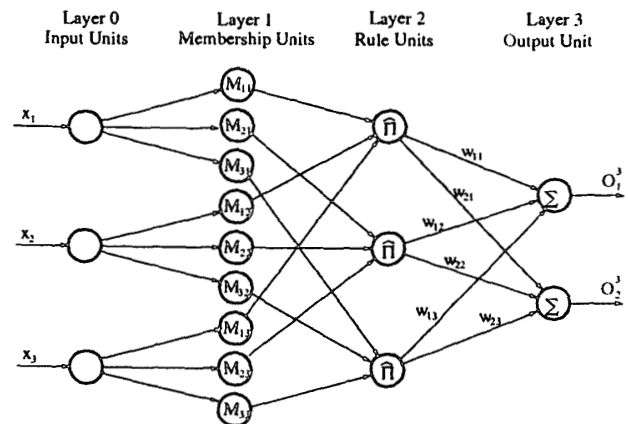


図 1: Fuzzy neural network configuration

ここで第 l 層の各ユニットの出力 O^l は次の式のように表現できる。

$$\mu_j = \prod_{i=1}^m A_{ji}(x_i) \prod_{i=m+1}^n B_{ji}(x_i) \quad (2)$$

$$\hat{\mu}_j = \frac{\mu_j}{\sum_k \mu_k} \quad (3)$$

$$y_k^* = \sum_j \hat{\mu}_j C_{jk} \quad (4)$$

3 ネットワークのチューニング

提案したネットワークでは、ルールの後件部実数値と前件部のメンバーシップ関数を学習する。ルールの後件部実数値と前件部の定量的属性に対するメンバーシップ関数の学習は、文献 [2] の提案方法と同じである。ここでは、前件部の定性値型メンバーシップ関数の学習方法について述べる。

まず、通常の BP 法での定性値型メンバーシップ関数のグレード値の更新を考える。第 1 層において、定性値 c_k に対するグレード値を $g_{ji}(c_k)$ とし、BP による更新量を $\Delta g_{ji}(c_k)$ とすると、次の式 (5) で更新後のグレード値 $g'_{ji}(c_k)$ が計算される。

$$g'_{ji}(c_k) = g_{ji}(c_k) + \alpha \Delta g_{ji}(c_k) \quad (5)$$

ここで α は学習係数である。

このとき、 $0 \leq g'_{ji}(c_k) \leq 1$ である必要がある。 $\Delta g_{ji}(c_k)$ はこのような制限を考慮していないので、これに対処するためには、一定の値が与えられる α を、現在の $g_{ji}(c_k)$ と更新量 $\Delta g_{ji}(c_k)$ に応じて学習ごとに決定するという方法が考えられる。しかし、このような定式化はかなり面倒であるうえに、制約的条件が少ないので様々な方法が考えられいずれが良いかを決めにくい。そこで、区間 $[0, 1]$ から区間 $[-\infty, +\infty]$ への写像 f を考え、区間 $[0, 1]$ の $g_{ji}(c_k)$ を区間 $[-\infty, +\infty]$ の値 $G_{ji}(c_k) = f(g_{ji}(c_k))$ に変換する。

更新後の $G'_{ji}(c_k)$ は、一定の学習係数 α を用いて、次の式で計算する。

$$G'_{ji}(c_k) = G_{ji}(c_k) + \alpha \Delta G_{ji}(c_k) \quad (6)$$

そして、 $G'_{ji}(c_k)$ から $g'_{ji}(c_k)$ を次のようにして計算する。

$$g'_{ji}(c_k) = f^{-1}(G'_{ji}(c_k)) \quad (7)$$

この時、 $G_{ji}(c_k)$ の更新量 $\Delta G_{ji}(c_k)$ は、

$$\frac{\partial E}{\partial G} = \frac{\partial E}{\partial g} \frac{\partial g}{\partial G} \quad (8)$$

$$\Delta G_{ji}(c_k) = (f^{-1})' \Delta g_{ji}(c_k) \quad (9)$$

となる。写像 f は、全単射で一回微分可能である必要がある。この条件を満たす関数の例としては、次のものがある。

$$f(g_{ji}) = -T \log \frac{1-g_{ji}}{g_{ji}} \quad (T > 0) \quad (10)$$

ここで、 T は係数である。

さらにネットワークの構造のために、忘却型構造学習を行った。ルールのブルーニングやメンバーシップ関数のブルーニングは、定量的属性における手法と同じ忘却学習により行う。定性値型メンバーシップ関数の場合には、定性値すべてに対するメンバーシップ値が 1 になるように忘却学習を行なうので、忘却学習時の定性値のグレードの更新量 $\Delta G''_{ji}(c_k)$ は、(6) 式の更新量 $\Delta G'_{ji}(c_k)$ に忘却量を加えて以下のようになる。

$$\Delta G''_{ji}(c_k) = \Delta G'_{ji}(c_k) + \epsilon \quad (11)$$

4 数値実験例

前節で提案した手法を、用意したデータに適用し、汎化能力についての数値実験を行った。用意したデータは合計 100 個の「身長」、「足の大きさ」、「性別」、「体重」が組となった体重予測データで、「体重」と「足の大きさ」は「身長」から次の式を用いて計算した。

$$\begin{aligned} \text{体重} &= \begin{cases} (\text{身長} - 100) \times 0.93 & (\text{男性の場合}) \\ (\text{身長} - 100) \times 0.88 & (\text{女性の場合}) \end{cases} \\ \text{足の大きさ} &= \begin{cases} \text{身長} \times 0.1 + 9.0 & (\text{男性の場合}) \\ \text{身長} \times 0.1 + 7.5 & (\text{女性の場合}) \end{cases} \end{aligned}$$

男性については、身長は 173 cm を中心に標準偏差 8 の正規分布からランダムに 50 個のデータを作成した。また、女性については身長 156 cm を中心とした標準偏差 8 の正規分布からランダムに 50 個のデータを作成した。

初期ネットワークは、3 入力 1 出力とし、入力は、定量値属性として $x_1 =$ 「身長」、 $x_2 =$ 「足の大きさ」、定性値属性として $x_3 =$ 「性別」を対応させ、出力は $y_1 =$ 「体重」を対応させる。

数値実験は、2-fold cross-validation 法を用いて行った。この実験で、正解率とは、得られたルールによる推論値と評価用データの値との誤差が 1.0kg 以内を正解として計算したものである。

この試行を 10 回行ったときの、正解率、誤差、ルール数の平均を、Table 1 に示す。

表 1: Result of test data

Ave.:Correct	Ave.:Error	Ave.:Rules
96.5%	8.23×10^{-2}	4.0

後件部実数値と定性値型メンバーシップ関数の初期値は、各試行で乱数により設定した。初期ルール数は、学習データ数の半分である 25 から始めたが、忘却型学習により最高で 3 ルール、平均で 4.1 ルールにまで冗長なルールを削除できた。

5 おわりに

定性的属性を含むデータからファジイルールを抽出する方法を提案した。また、提案法を実験データに適用することにより、定性的属性と定量的属性とを同等の扱いながら、効率的なルールを抽出ができることを示した。

参考文献

- [1] 今村, 栗林, 野村, 後藤, 田村: 顧客の感性評価モデルを用いたバーチャル・デザイン・システム, 日本バーチャルリアリティ学会誌, Vol.1, No.14, pp.40-45, 1996.
- [2] 馬野, 福中, 鳩野, 田村: 忘却の概念を用いたファジィ・ニューラルネットワークによるファジイルールの抽出, 計測自動制御学会論文集, Vol.32, No.3, pp. 409-416, 1996.