

基于 Pi-Sigma 神经网络的高木-关野模糊系统 用于数据关联计算的建模¹

邢松寅 王士同

(华东船舶工业学院计算机系 镇江 212003)

摘 要 本文首先提出了高木-关野模糊系统的混合 Pi-Sigma 神经网络实现方法和技术, 然后研究了其在数据关联建模中的应用。实验结果表明, 本文的方法不失为一种解决数据关联计算建模问题的新方法。

关键词 模糊系统, 神经网络, 建模

中图分类号 TN-052

1 引言

在目标跟踪中数据关联是最重要且是最繁琐的问题, 也是实现多目标跟踪的前提。在数据关联计算方法中, 联合概率数据关联 (J-PDA) 是最著名的一种算法。但该方法的缺点较为明显: (1) 算法计算量随着目标和点迹数目呈指数增长。(2) 对于复杂背景, 由于此方法仍局限于经典的邻域法, 故很难准确地给出关联区域大小和波门中心以及相关积累。因此有必要寻找一种新的计算数据相关的途径。本文提出了用基于高木-关野模糊系统的模糊 Pi-Sigma 神经网络来计算数据相关的新方法。这个新方法能根据样本数据呈现出逼近性和自适应性。所谓逼近性, 是指数据相关计算模型应与已有的样本充分接近; 所谓自适应性, 是指模型能随着情况的变化而对模型本身实现自调整。因此, 本文的方法是一个十分有效的方法。

2 高木-关野模糊系统

在高木-关野模糊系统中, 高木和关野用以下的“如果-则”规则来定义模糊系统的“如果-则”规则:

$$\begin{aligned} R^i: & \text{IF } x_1 \text{ is } A_1^i, x_2 \text{ is } A_2^i, \dots, x_k \text{ is } A_k^i, \\ & \text{THEN } y^i = p_0^i + p_1^i \cdot x_1 + \dots + p_k^i \cdot x_k, \end{aligned} \quad (1)$$

式中 R^i 表示第 i 条模糊规则; x_1, x_2, \dots, x_k 为模糊系统的输入, $A_1^i, A_2^i, \dots, A_k^i$ 为其结论域上的模糊子集, 它们的隶属函数是分段连续或高斯型凸函数; y^i 为第 i 条规则的输出; $p_j^i (j = 0, 1, \dots, k)$ 则称为结论参数。如果模糊模型共有 m 条规则, 对于一个真值输入向量 $X = (x_1, x_2, \dots, x_k)^T$ 来讲, 高木-关野模糊系统的输出 Y 等于各 y^i 的加权平均:

$$Y = \frac{\sum_{i=1}^m w^i y^i}{\sum_{i=1}^m w^i}, \quad (2)$$

¹ 1997-06-28 收到, 1998-02-09 定稿
江苏省跨世纪学科带头人基金课题

(2) 式中加权系数 w^i 包括了规则 R^i 作用于输入所得的所有真值, w^i 的计算公式如下:

$$w^i = \prod_{j=1}^k \mu_{A_j^i}(x_j). \quad (3)$$

可以看出, 在高木和关野提出的这种模型中, 其“IF(如果)”部分是模糊的, 但其“THEN(则)”部分是确定的, 即输出为各输出变量的线性组合。高木-关野模糊系统的主要优点在于: 它提供了一个精密的系统方程式(2)式, 因此能够利用参数估计和确定系统阶数的方法来确定系统参数 p_i^j 。其缺点是: (1) 规则的“THEN”部分不是模糊的, 因而不能方便地利用专家提供的规则。(2) 各前提参数的模糊子集的划分和隶属函数的确定主要取决于人的经验, 有很大的主观性。(3) 各系统参数 p_i^j 一旦确定则模糊模型也不在变化; 要对系统进行扩充, 只能重新建模。下面, 本文首先给出一种新型的神经网络结构及其学习算法。

3 混合型 Pi-Sigma 神经网络

常规的前向型神经网络只含有求和节点, 这给处理某些复杂问题带来了困难。为此本文提出了一种基于 Pi-Sigma 神经网络的混合型网络模型, 如图 1 所示。网络中 s, p, \otimes 分别表示相加, 相乘, 相乘运算。由网络的结构可知, 该网络的输出为




图 1 混合型 Pi-Sigma 神经网络

$$Y = \frac{\sum_{i=1}^m w^i y^i}{\sum_{i=1}^m w^i} = \frac{\sum_{i=1}^m [(\mu_{A_1^i}(x_1) \cdot \mu_{A_2^i}(x_2) \cdot \mu_{A_3^i}(x_3) \cdot \mu_{A_4^i}(x_4)) \cdot (p_0^i + p_1^i + p_2^i + p_3^i + p_4^i)]}{\sum_{i=1}^m \mu_{A_1^i}(x_1) \cdot \mu_{A_2^i}(x_2) \cdot \mu_{A_3^i}(x_3) \cdot \mu_{A_4^i}(x_4)} \quad (4)$$

很明显, 这种结构的神经网络就是高木-关野模型。用这种网络实现的模糊模型辨识, 可方便地在线修正前提参数 (隶属函数) 和结论参数, 很适合于复杂系统的模糊预测和控制。为方便神经网络的学习, 各模糊子集的隶属函数均为高斯型, 即

$$\mu_{A_j^i} = \exp[-(x_i - a_j^i)^2 / b_j^i]. \quad (5)$$

下面给出混合神经网络的学习算法。本算法采用 BP 算法。假设网络的期望输出为 Y_d , 定义代价函数为

$$E = (1/2)(Y_d - Y)^2, \quad (6)$$

则根据梯度法有

$$p_j^i(k+1) = p_j^i(k) - \alpha \cdot \partial E / \partial p_j^i, \quad (7)$$

其中

$$\frac{\partial E}{\partial p_j^i} = \frac{\partial E}{\partial Y} \cdot \frac{\partial Y}{\partial p_j^i} = -(Y_d - Y) \cdot \partial \left(\frac{\sum_{i=1}^m w^i y^i}{\sum_{i=1}^m w^i} \right) / \partial p_j^i = -(Y_d - Y) \frac{w^i}{\sum_{i=1}^m w^i} \cdot \frac{\partial y^i}{\partial p_j^i} \quad (8)$$

因此有

$$p_j^i(k+1) = p_j^i(k) - \alpha \cdot (Y - Y_d) \cdot w^i / \left(\sum_{i=1}^m w^i \right) \cdot x_j. \quad (9)$$

在上式中 $j=0,1,2,3,4$, $x_0 = 1$, k 表示迭代次数, α 表示学习速率。

对 a_j^i, b_j^i 有

$$a_j^i(k+1) = a_j^i(k) - \beta \cdot \partial E / \partial a_j^i, \quad (10)$$

其中

$$\begin{aligned} \frac{\partial E}{\partial a_j^i} &= \frac{\partial E}{\partial Y} \cdot \frac{\partial Y}{\partial a_j^i} = \frac{\partial E}{\partial Y} \cdot \frac{\partial Y}{\partial w^i} \frac{\partial w^i}{\partial a_j^i} \\ &= -(Y_d - Y) \cdot \frac{y_i \sum_{i=1}^m w^i - \sum_{i=1}^m w^i y^i}{(\sum_{i=1}^m w^i)^2} \cdot 2 \cdot (x_i - a_j^i) \cdot w^i / b_j^i, \end{aligned} \quad (11)$$

$$b_j^i(k+1) = b_j^i(k) - \beta \cdot \partial E / \partial b_j^i, \quad (12)$$

其中

$$\begin{aligned} \frac{\partial E}{\partial b_j^i} &= \frac{\partial E}{\partial Y} \cdot \frac{\partial Y}{\partial b_j^i} = \frac{\partial E}{\partial Y} \cdot \frac{\partial Y}{\partial w^i} \frac{\partial w^i}{\partial b_j^i} \\ &= -(Y_d - Y) \cdot \left[\left(y_i \sum_{i=1}^m w^i - \sum_{i=1}^m w^i y^i \right) / \left(\sum_{i=1}^m w^i \right)^2 \right] \cdot (x_i - a_j^i)^2 \cdot w^i / (b_j^i)^2, \quad (13) \end{aligned}$$

因此有

$$a_j^i(k+1) = a_j^i(k) - 2\beta(Y - Y_d) \left[\left(y_i \sum_{i=1}^m w^i - \sum_{i=1}^m w^i y^i \right) / \left(\sum_{i=1}^m w^i \right)^2 \right] (x_i - a_j^i) w^i / b_j^i, \quad (14)$$

$$b_j^i(k+1) = b_j^i(k) - \beta(Y - Y_d) \left[\left(y_i \sum_{i=1}^m w^i - \sum_{i=1}^m w^i y^i \right) / \left(\sum_{i=1}^m w^i \right)^2 \right] (x_i - a_j^i) w^i / (b_j^i)^2, \quad (15)$$

上面两式中 k 为迭代次数, β 为学习效率, $j = 1, 2, 3, 4$.

4 多目标跟踪中, 数据总相关计算 可视为对相关决策函数的逼近

为了验证本文所提出方法的正确性, 我们以常规的数据总相关可能性计算公式:

$$\begin{aligned} AN &= \{0.427[(1 + \sin(\pi(x_1 - 0.5)))/2] + 0.607[(1 + \sin(\pi(x_2 - 0.5)))/2]\} / 2.858 \\ &\quad + \{0.779[(1 + \sin(\pi(x_3 - 0.5)))/2] + 0.607[(1 + \sin(\pi(x_4 - 0.5)))/2]\} / 2.858 \end{aligned}$$

为产生样本数据的标准, 并以此作为数据总相关的可能性建模。在实践中这种情形正好相反, 即往往有样本数据, 在根据本文的方法建模, 然后以建立好的网络模型作为数据总相关可能性计算结果。

不失一般性, 本文将四个输入的模糊子集划分为 $\{PL, PM, ZO\}$, 分别表示正大, 正中和零。它们的隶属函数均采用高斯型, 且有

$$\begin{aligned} \mu_{PL}(x) &= \begin{cases} 1, & x > 15, \\ \exp[-(x - 15)^2/3], & x \leq 15, \end{cases} \\ \mu_{PM}(x) &= \exp[-(x - 7.5)^2/1.5], \\ \mu_{ZO}(x) &= \begin{cases} 1, & x < 0, \\ \exp[-x^2/3], & x \geq 0. \end{cases} \end{aligned}$$

由此, 得到 $3^4 = 81$ 条规则:

$$\begin{aligned} R_1: & \text{IF } x_1 \text{ IS } PL, x_2 \text{ IS } PL, x_3 \text{ IS } PL, x_4 \text{ IS } PL, \\ & \text{THEN } y^1 = p_0^1 + p_1^1 \cdot x_1 + \cdots + p_k^1 \cdot x_k, \\ & \vdots \\ R^{81}: & \text{IF } x_1 \text{ IS } ZO, x_2 \text{ IS } ZO, x_3 \text{ IS } ZO, x_4 \text{ IS } ZO, \\ & \text{THEN } y^{81} = p_0^{81} + p_1^{81} \cdot x_1 + \cdots + p_k^{81} \cdot x_k, \end{aligned}$$




图 2

其中 x_1, x_2, x_3, x_4 为四个输入, 在本文所取的样本中, 它们的取值 $[1, 15]$ 。根据上文给出的模糊预测算法, 得输出为

$$Y = \frac{\sum_{i=1}^{81} w^i y^i}{\sum_{i=1}^{81} w^i}. \quad (17)$$

本文实验时, 用 80 组样本数据训练网络, 经过约 300 次学习后, 网络的平均误差可达 0.008。本文对训练的结果分析发现, 各语言值的隶属函数均产生修正, 修正后的隶属函数的标准偏离 b_j^i 均有所增加, 隶属函数变得平坦。

根据训练得到的模糊预测模型, 发现各样本数据的预测值与实际值都吻合的较好。只有个别的点的误差较大(如图 2)。另外, 在系统模型建立好后, 为检验建模的效果, 本文用另外抽取的十组数据作为检验样本, 结果令人满意。

5 结 论

从前面的分析和应用可以得出如下结论: (1) 高木-关野模糊系统可以应用混合的 Pi-Sigma 神经网络有效地予以实现。(2) 由于本文在高木-关野模糊系统对规则前提的运算采用乘积运算, 这为 Pi-Sigma 神经网络的学习算法提供了可以直接求导的方便, 有效地避免了在应用和运算中常见的不可直接求导的问题。(3) 本文所述的方法事实上表明所构造的系统是一个自适应系统, 它对于目标跟踪中数据关联计算建模问题是一个新方法。

参 考 文 献

- [1] 王立新. 自适应模糊系统与控制. 北京: 国防工业出版社, 1995, 21-74.
- [2] 赵振宇. 模糊理论和神经网络的基础与应用. 北京: 清华大学出版社, 1995, 173-242.

- [3] 金耀初, 蒋静坪, 诸静. 自适应模糊预测及其在天气预报中的应用. 模式识别与人工智能, 1993, (4): 75-78.
- [4] 王士同. Fuzzy basis function, Fuzzy neural network, The new hybrid learning algorithm, J. of Software Research. (已正式录用)
- [5] 胡守仁. 神经网络导论. 长沙: 国防科技大学出版社, 1994, 53-107.
- [6] 汪培庄. 模糊集合论及其应用. 上海: 上海科学技术出版社, 1987, 79-95.

PI-SIGMA NEURAL NETWORK BASED SUGENO-TAKAGI FUZZY SYSTEM USED FOR MODELLING DATA ASSOCIATION COMPUTATION PROBLEM

Xing Songyin Wang Shitong

(Dept. of Comp. Sci. and Techn., East China Ship Building Institute, Zhenjiang 212003)

Abstract In this paper, a method, which uses the new hybrid Pi-Sigma neural network to realize the Sugeno-Takagi fuzzy system, is presented. And then it is used for modelling the data association computation problem. Experimental results show that this method is a new one for data association modelling.

Key words Fuzzy system, Neural network, Modelling

邢松寅: 男, 1975 年生, 硕士生, 研究方向: 人工智能, 神经网络.

王士同: 男, 1964 年生, 教授, 系主任, 研究方向: 人工智能, 神经网络, 模糊数学.