

规则可生长与修剪的非线性系统 T-S 模糊模型辨识

廖龙涛¹ 李少远¹ 黄广斌²

摘要 通常离线提取 T-S 模糊模型的规则后, 规则数无法在模型使用中进行调整, 而这成为表达非线性系统复杂性的一个瓶颈. 针对这一问题, 本文引入一种神经网络的生长和修剪方法, 从实时数据中提取 T-S 模型的规则, 并定义其对应局部模型对输出的影响, 以此作为在线调整规则数的依据, 从而更准确地表达了非线性系统的复杂性和运行中的变化. 再加上基于竞争性 EKF (Extended Kalman filter) 的模型参数在线学习, T-S 模型的建模精度也得到了保证. 整个算法完全实现了 T-S 模糊模型的在线辨识, 使模型的结构和参数具有很好的自适应能力. 对 CSTR (Continuously stirred tank reactor) 系统的辨识, 表明了该算法在处理非线性系统辨识问题上的优越性能.

关键词 T-S 模型, 模糊规则, 生长与修剪, 平均响应, 在线辨识
中图分类号 TP273

T-S Fuzzy Model Identification with Growing and Pruning Rules for Nonlinear Systems

LIAO Long-Tao¹ LI Shao-Yuan¹ HUANG Guang-Bin²

Abstract Offline rule extraction for the T-S fuzzy systems usually gives a fixed number of fuzzy rules, which make it a bottleneck for revealing the complexity of nonlinear systems. Thus, due to a growing and pruning strategy of the neural network, in this paper the fuzzy rules are extracted from real-time data and their number is adjusted online by the impact degree of one local model, such that the rules vary with the system dynamically and more precisely reflect the character of nonlinear systems. Furthermore, the accuracy of the T-S model is guaranteed by the parameter learning based on a competitive extended Kalman filter (EKF). The entire algorithm presents a completely online identification of the T-S model and gains a structural and parameter adaptability. An example for CSTR identification illustrates its good performance.

Key words T-S model, fuzzy rule, growing and pruning, average response, online identification

1 引言

T-S 模糊推理系统^[1] 由于具有万能逼近能力^[2], 能用较少规则很好地近似任意非线性函数, 非常适于建立非线性系统的近似数学模型, 其线性模型的形式亦便于分析. 它相当于把输入空间划分成若干模糊子空间, 在其内建立局部线性

模型, 最终将这些局部线性模型用隶属度函数平滑地连接起来, 形成一个全局模糊模型.

模糊空间划分属于 T-S 模糊模型的结构辨识问题, 可采用网络划分^[1], 模糊聚类^[3] 或自组织^[4] 等方法离线获得所需模糊规则的个数和前件参数, 而后 T-S 模型后件的参数辨识就可以采用 RLS (Recursive least square)^[5] 等方法解决. 而自从自适应学习算法^[6] 被引入模糊系统, T-S 模型前后件参数便能在辨识结果基础上通过如 BP^[7] 或遗传算法^[8] 等进行优化, 以提高模型精度和泛化能力.

然而上述方法只能离线给出模型所需的规则个数, 不同方法所得个数并不一致, 既不能准确描述非线性系统的复杂性, 也不能通过学习使规则数与系统现况吻合. 因此, 本文考虑从实时数据中提取 T-S 模型的规则并实现规则数的在线调整, 以更准确地表达非线性系统的复杂性和运行中的变化.

为此, 本文将引入一种 RBF 神经网络的生长与修剪方法 (Generalized growing and pruning, GGAP)^[9], 基于 T-S 模型中单个局部模型对输出的影响, 提出了 T-S 模型规则的在线学习算法, 并结合竞争性 EKF (Extended Kalman filter) 进行参数优化, 保证了建模精度. 最终形成的广义生长与修剪 T-S 模糊推理系统 (GGAP-TS) 仅利用当前时刻的系统数据, 就能完成 T-S 模型结构和参数的在线辨识. 对 CSTR (Continuously stirred tank reactor) 系统的在线辨识表明了该算法的高效率以及良好的辨识精度与自适应能力.

2 T-S 模糊模型的结构形式

对于一个多输入多输出系统 (MIMO), T-S 模糊模型一般可表示为如下形式

$$\begin{aligned} R_k : & \text{IF } x_1 \text{ is } A_1^k, \text{ and } \cdots, \text{ and } x_l \text{ is } A_l^k \\ & \text{THEN } y_{jk} = p_{j0}^k + p_{j1}^k x_1 + \cdots + p_{jl}^k x_l \end{aligned} \quad (1)$$

其中 $j = 1, 2, \cdots, m$, $k = 1, 2, \cdots, K$, K 表示模糊规则数, $A_i^k (i = 1, 2, \cdots, l)$ 为对应于前件输入变量 $x_1, \cdots, x_l$ 的模糊集合, y_{jk} 是模型第 k 条规则在第 j 个输出端的值, 后件参数 $p_{ji}^k (i = 0, 1, \cdots, l) \in \mathbf{R}$.

采用高斯型隶属度函数、单点模糊化、乘积推理和重心法解模糊化, T-S 模型输出

$$\mathbf{y} = \frac{\sum_{k=1}^K R_k(\mathbf{x}) \bar{P}_k^T \bar{\mathbf{x}}}{\sum_{k=1}^K R_k(\mathbf{x})} = \frac{\sum_{k=1}^K \exp\left(-\frac{1}{\sigma_k^2} \|\mathbf{x} - \boldsymbol{\mu}_k\|^2\right) \bar{P}_k^T \bar{\mathbf{x}}}{\sum_{k=1}^K \exp\left(-\frac{1}{\sigma_k^2} \|\mathbf{x} - \boldsymbol{\mu}_k\|^2\right)}$$

其中 $\mathbf{y} = (y_1, \cdots, y_m)^T$, $\mathbf{x} = (x_1, \cdots, x_l)^T \in \mathbf{X} \subseteq \mathbf{R}^l$, R_k 是规则适用度, 其归一化后的值用 $\bar{R}_k$ 表示. 每条规则的中心和宽度是 $\boldsymbol{\mu}_k$ 和 σ_k , $\|\cdot\|$ 表示两个向量间的欧式距离. 令 $\bar{\mathbf{x}} = (1, \mathbf{x}^T)^T$, 由 (1) 可知, 权重 $\bar{P}_k = (\mathbf{p}_1^k, \cdots, \mathbf{p}_m^k)$, 其中 $\mathbf{p}_j^k = (p_{j0}^k, p_{j1}^k, \cdots, p_{jl}^k)^T$.

这样, 在第 n 个采样时刻将系统的实际输入输出 $(\mathbf{x}_n, \mathbf{y}_n^*)$ 作为训练信号, MIMO 系统即可通过辨识得到的 T-S 模糊模型来近似.

3 T-S 模糊模型的广义生长与修剪算法

3.1 局部线性模型对 T-S 模型输出的影响

在上述 T-S 模糊模型中, 规则适应度反映了与之对应的局部线性模型在全局模型中的比重. 在整个连续样本空间 $\mathbf{X}$ 和 $\mathbf{Y}$ 中, 利用它考察某个局部线性模型在输出端的平均响应

收稿日期 2006-7-21 收修改稿日期 2006-12-28
Received July 21, 2006; in revised form December 28, 2006
国家自然科学基金 (60474051), 高等学校博士点专项科研基金 (20060248001) 和国家教育部新世纪优秀人才计划资助
Supported by National Natural Science Foundation of China (60474051), the Specialized Research Fund for the Doctoral Program of Higher Education of China (20060248001), and the Program for New Century Excellent Talents in University of China (NCET)
1. 上海交通大学自动化系 上海 200240 2. 南洋理工大学电机与电子工程学院 新加坡 639798, 新加坡
1. Department of Automation, Shanghai Jiao Tong University, Shanghai 200240 2. School of Electrical and Electronic Engineering, Nanyang Technological University, Singapore 639798, Singapore
DOI: 10.1360/aas-007-1097

即可知它对输出贡献的重要程度,从而将相对重要的局部线性模型保留下来.

首先,在第 n 时刻第 k 个局部线性模型在输出端的响应

$$\mathbf{y}_n^k = \frac{R_k(\mathbf{x}_n) \bar{P}_k^T \bar{\mathbf{x}}_n}{\sum_{k=1}^K R_k(\mathbf{x}_n)}$$

将其写成如下形式

$$\sum_{k=1}^K R_k(\mathbf{x}_n) \mathbf{y}_n^k = R_k(\mathbf{x}_n) \bar{P}_k^T \bar{\mathbf{x}}_n$$

对训练开始以来获得的 N 个样本有

$$\sum_{n=1}^N \sum_{k=1}^K R_k(\mathbf{x}_n) \mathbf{y}_n^k = \sum_{n=1}^N R_k(\mathbf{x}_n) \bar{P}_k^T \bar{\mathbf{x}}_n$$

上式两边同除以 N , 并令 $N \rightarrow \infty$ 得

$$\lim_{N \rightarrow \infty} \sum_{k=1}^K \sum_{n=1}^N \frac{R_k(\mathbf{x}_n) \mathbf{y}_n^k}{N} = \lim_{N \rightarrow \infty} \sum_{n=1}^N \frac{R_k(\mathbf{x}_n) \bar{P}_k^T \bar{\mathbf{x}}_n}{N}$$

设 $\varphi(\mathbf{x})$ 和 $\psi(\mathbf{y})$ 分别是连续样本空间 $\mathbf{X}$ 和 $\mathbf{Y}$ 的概率密度. 将它们的乘积空间 $\mathbf{X} \times \mathbf{Y}$ 划分成 $M_1 \times M_2$ 个区域 $\Delta_s \subset \mathbf{X} (s=1, \dots, M_1)$ 和 $\Omega_t \subset \mathbf{Y} (t=1, \dots, M_2)$, 对应分区大小为 $S(\Delta_s)$ 和 $S(\Omega_t)$. 当划分很细时, 分区也变得很小, 故可近似认为在每个分区 $\Delta_s \times \Omega_t$ 中, 取值均为 $(\mathbf{x}_s, \mathbf{y}_t)$ 的样本有 $N \cdot \varphi(\mathbf{x}_s) S(\Delta_s)$ 个, 它们对应着 T-S 模型的输入输出, 且输出为 $\mathbf{y}_t$ 的概率为 $\varphi(\mathbf{y}_t) \cdot S(\Omega_t)$, 因此上式可近似表示成

$$\sum_{k=1}^K \lim_{M_1, M_2 \rightarrow \infty} \sum_{s=1}^{M_1} \sum_{t=1}^{M_2} \frac{R_k(\mathbf{x}_s) N \varphi(\mathbf{x}_s) S(\Delta_s) \mathbf{y}_t^k \varphi(\mathbf{y}_t) S(\Omega_t)}{N} = \lim_{M_1 \rightarrow \infty} \sum_{s=1}^{M_1} \frac{R_k(\mathbf{x}_s) \bar{P}_k^T \bar{\mathbf{x}}_s N \varphi(\mathbf{x}_s) S(\Delta_s)}{N}$$

写成积分形式

$$\sum_{k=1}^K \iint_{\mathbf{X} \times \mathbf{Y}} R_k(\mathbf{x}) \mathbf{y} \varphi(\mathbf{x}) \psi(\mathbf{y}) d\mathbf{x} d\mathbf{y} = \bar{P}_k^T \int_{\mathbf{X}} R_k(\mathbf{x}) \bar{\mathbf{x}} \varphi(\mathbf{x}) d\mathbf{x}$$

其中 $\mathbf{x} \in \mathbf{X}, \mathbf{y} \in \mathbf{Y}$ 且相互独立, 故上式可变为

$$\sum_{k=1}^K \int_{\mathbf{X}} R_k(\mathbf{x}) \varphi(\mathbf{x}) d\mathbf{x} \int_{\mathbf{Y}} \mathbf{y} \psi(\mathbf{y}) d\mathbf{y} = \bar{P}_k^T \int_{\mathbf{X}} R_k(\mathbf{x}) \bar{\mathbf{x}} \varphi(\mathbf{x}) d\mathbf{x}$$

因此第 k 个局部线性模型在输出端的平均响应, 也就是它的数学期望

$$E(\mathbf{y}^k) = \int_{\mathbf{Y}} \mathbf{y} \psi(\mathbf{y}) d\mathbf{y} = \frac{\bar{P}_k^T \int_{\mathbf{X}} R_k(\mathbf{x}) \bar{\mathbf{x}} \varphi(\mathbf{x}) d\mathbf{x}}{\sum_{k=1}^K \int_{\mathbf{X}} R_k(\mathbf{x}) \varphi(\mathbf{x}) d\mathbf{x}}$$

这一结果与样本无关而只与局部模型的参数有关, 是其对输出影响程度的一种描述. 引入 q 范数^[9] 来描述其大小, 向量 $\mathbf{y} = (y_1, \dots, y_m)^T$ 的 q 范数: $\|\mathbf{y}\|_q = \sqrt[q]{\sum_{j=1}^m |y_j|^q} / m$. 它表征了一个向量的平均大小, 因此 T-S 模糊模型中第 k 个局部线性模型对输出的影响: $E(k) \triangleq \|E(\mathbf{y}^k)\|_q$.

它全面反映了在输入空间上此局部模型对输出的影响. 增加或删除它对应的规则, 就能使输出误差减少或增大

$E(k)$. 如果把它与精度要求作比较, 就可以反映此规则对精度的影响是否显著, 从而决定是否增加或删除此规则. 一般认为宽度 σ_k 远小于 $\mathbf{X}$ 的范围, 当 $\mathbf{x}_n$ 服从均匀分布, 即 $\varphi(\mathbf{x}) = 1/S(\mathbf{x})$, 其中 $S(\mathbf{x})$ 是 $\mathbf{X}$ 的范围大小. 对于单输出的情况, $\bar{P}_k = \mathbf{p}_1^k$, $\|\mathbf{y}\|_q = |y|$

$$E(k) \approx \left| \frac{(\mathbf{p}_1^k)^T (\sqrt{\pi} \sigma_k)^l \bar{\mu}_k / S(\mathbf{x})}{\sum_{k=1}^K \left(\int_{-\infty}^{+\infty} \exp\left(-\frac{x^2}{\sigma_k^2}\right) dx \right)^l / S(\mathbf{x})} \right| = \frac{\sigma_k^l}{\sum_{k=1}^K \sigma_k^l} \left| (\mathbf{p}_1^k)^T \bar{\mu}_k \right|$$

其中 $\bar{\mu}_k = (1, \mu_k^T)^T$.

3.2 T-S 模糊模型规则的生长与修剪

与神经网络生长和修剪的方法相同, 本文 T-S 模糊模型的规则也是从无到有, 而其个数与参数经在线学习不断得到调整, 没有离线过程. 将每一时刻的模型输入 $\mathbf{x}_n (n=1, 2, \dots)$ 作为候选规则中心, 根据 3.1 节的结论, 增加一条规则后所对应增加的局部线性模型要使建模误差降至期望值以下; 同时, 为保证 T-S 模型的泛化性能, 规则的空间分布要求相对均匀. 因此对于单输出系统, 生成一条模糊规则应满足

$$\|\mu_{K+1} - \mu_{nr}\| > \varepsilon_n, \quad \frac{\sigma_{K+1}^l \left| (\mathbf{p}_1^{K+1})^T \bar{\mu}_{K+1} \right|}{\sum_{k=1}^K \sigma_k^l + \sigma_{K+1}^l} > e_c \quad (2)$$

其中, μ_{nr} 是离当前输入 $\mathbf{x}_n$ 最近的模糊规则 R_{nr} 的中心, 精度要求 e_c 预先设定, 距离阈值 ε_n 由下式给出

$$\varepsilon_n = \max \{ \varepsilon_{\max} \times \gamma^n, \varepsilon_{\min} \} \quad (3)$$

其中 $\varepsilon_{\max}, \varepsilon_{\min}$ 和衰减因子 $\gamma (0 < \gamma < 1)$ 将共同决定模糊规则空间上的相对分布^[9]. 不难理解, 在线学习时的模糊规则将从稀疏变得稠密. 新增加的这第 $K+1$ 条规则其参数

$$\begin{cases} \mathbf{p}_1^{K+1} = \bar{\mathbf{e}}_n = (y_n^* - y_n, 0, \dots, 0)_{(l+1) \times 1}^T \\ \mu_{K+1} = \mathbf{x}_n \\ \sigma_{K+1} = \kappa \|\mathbf{x}_n - \mu_{nr}\| \end{cases} \quad (4)$$

其中 κ 是预先给定的模糊规则的重叠系数. 反之, 当某个局部模型对输出的影响不足, 即满足

$$\frac{\sigma_k^l}{\sum_{k=1}^K \sigma_k^l} \left| (\mathbf{p}_1^k)^T \bar{\mu}_k \right| \leq e_c \quad (5)$$

它对应的模糊规则就被删去.

3.3 T-S 模糊模型的参数学习

在线学习时若当前输入不满足式 (2), T-S 模型的规则数将不会增加. 此时进行参数学习, 可以使 T-S 模型的逼近性能进一步提高, 而由于在线学习要求计算速度快, 占用资源少, 使得一种新型的竞争性 EKF^[9] 能发挥其优势. 为进行参数估计, 首先令

$$\theta_n = \left((p_1^1)^T, \mu_1^T, \sigma_1, \dots, (p_1^{nr})^T, \mu_{nr}^T, \sigma_{nr}, \dots, (p_1^K)^T, \mu_K^T, \sigma_K \right)^T$$

其中 $(p_1^{nr})^T, \mu_{nr}^T, \sigma_{nr}$ 是离当前输入 x_n 最近的模糊规则的参数. 式 (2) 的距离条件与式 (4) 的参数配置使 x_n 对 R_{nr} 之外其它规则的适应度几乎为零, 因此 EKF 的梯度向量

$$\beta_n \approx (0, \dots, 0, (p_1^{nr})^T, \mu_{nr}^T, \sigma_{nr}, 0, \dots, 0)^T$$

$$\begin{cases} \dot{p}_1^{nr} = \bar{R}_{nr} \bar{x}_n \\ \dot{\mu}_{nr} = \left((p_1^{nr})^T \bar{x}_n - y_n \right) 2 \bar{R}_{nr} \frac{1}{\sigma_{nr}^2} (x_n - \mu_{nr}) \\ \dot{\sigma}_{nr} = \left((p_1^{nr})^T \bar{x}_n - y_n \right) 2 \bar{R}_{nr} \frac{1}{\sigma_{nr}^3} \|x_n - \mu_{nr}\|^2 \end{cases}$$

并根据 EKF 公式, θ_n 可调整为

$$\begin{aligned} G_n &= P_{n-1} \beta_n (R_n + \beta_n^T P_{n-1} \beta_n)^{-1} \\ \theta_n &= \theta_{n-1} + G_n e_n \\ P_n &= (I_{Z \times Z} - G_n \beta_n^T) P_{n-1} + q I_{Z \times Z} \end{aligned} \quad (6)$$

其中, q 是梯度方向上的步长, Z 是 θ_n 的维数. 式 (6) 中向量和矩阵的维数都将根据现有规则的数目而变化, 若有新的规则加入, 则

$$P_n = \begin{pmatrix} P_{n-1} & 0 \\ 0 & p_0 I_{Z_1 \times Z_1} \end{pmatrix}$$

增加的维数 Z_1 即 θ_n^{nr} 的维数, p_0 表示不确定性大小, 本文设为 1; 反之, 当删减一条规则后, P_n 相应删去了 $I_{Z_1 \times Z_1}$ 对应的行和列.

3.4 算法步骤

初始化: 选取适当的学习参数 $\varepsilon_{\max}, \varepsilon_{\min}, \gamma, \kappa, q$ 和精度要求 e_c , 模型初始规则数 $K = 0$, 对当前接收到的样本 $(x_n, y_n^*), x_n \in X \subseteq R^l, y_n^* \in Y \subseteq R, n = 1, 2, \dots$.

1) 计算 T-S 模型输出及与实际输出间的误差;

2) 根据式 (3) 计算距离阈值;

3) 根据若满足式 (2) 则生成一条规则, 按照式 (4) 配置其参数, $K = K + 1$, 否则利用式 (6) 仅调整最邻近规则的参数;

4) 判断调整后的最邻近规则是否满足式 (5) 的修剪判据, 若满足则删去该规则并使 EKF 减少相应维数, $K = K - 1$.

综上所述, GGAP-TS 模糊模型生长和修剪的整个过程, 只需利用当前样本 (x_n, y_n^*) . 由于在参数调整中引入了竞争, 使得规则修剪变得简单, 总的计算量、计算时间和占用资源都大为减少.

4 仿真实验

本节通过 GGAP-TS 模糊模型对 CSTR 这一非线性系统的在线辨识验证本方法的有效性, 辨识精度指标采用均方根误差 (Root mean square error, RMSE) 和最大绝对误差 (Maximal absolute error, MAE). 将它的结果与其它两种方法作比较: 1) FCM-TS: 先对训练样本进行模糊 C 均值聚类^[10], 再利用竞争性 EKF 在线调整该 T-S 模型的参数

(规则数确定); 2) SAFIS^[11]: Mamdani 型模糊推理系统, 其规则数可根据精度要求利用生成与修剪方法确定.

连续搅拌反应釜是一多变量非线性系统, 反应物在其内部发生不可逆放热反应. 可以通过控制流经反应釜的冷却剂流量 q_c (温度为 T_{cf}) 使生成物浓度 C_a (温度为 T_a) 达到生产要求. 其反应过程可以由以下方程组来描述:

$$\begin{aligned} \dot{C}_a &= \frac{q(C_{af} - C_a)}{V} - a_0 C_a e^{-\frac{E}{RT_a}} \\ \dot{T}_a &= \frac{q(T_f - T_a)}{V} + a_1 C_a e^{-\frac{E}{RT_a}} + a_3 q_c (1 - e^{-\frac{a_2}{q_c}}) (T_{cf} - T_a) \end{aligned}$$

各参数的意义及取值参照文献 [12], 初始条件 $C_{a0} = 0.1 \text{ mol/L}$, $T_{a0} = 440.0 \text{ K}$, $q_c = 100 \text{ mL/min}$. 采样时间为 0.1 秒, 模型输入为 $(C_a(n-1), C_a(n-2), q_c(n-1))$. 取 1200 个样本, 其中前 1000 个用于训练, 后 200 个用于检验三种算法的效果, 控制量 q_c 用 90 和 110 之间服从均匀分布的一系列随机数模拟, 然后将采集的数据归一化至 $[0, 1]$. FCM-TS 方法的聚类数为 20, GGAP-TS 和 SAFIS 两种方法的建模精度要求同设为 $e_c = 0.001$, 而两者的学习参数均为 $\varepsilon_{\max} = 0.1, \varepsilon_{\min} = 0.01, \gamma = 0.999, \kappa = 0.87, q = 0.0002$.

检验阶段, 用三种算法进行在线辨识, 完成后统计其检验误差. 在 110 秒 (即第 1100 个样本), 令反应物温度 T_f 上升 10 K 以产生工况变化, 从而检验本文提出的算法对时变参数的自适应能力. 以参数改变为界, 把检验阶段分割为 P1 和 P2. 仿真结果如图 1、图 2 及表 1 所示.




图 1 三种算法的辨识结果

Fig. 1 Comparison of results of the three algorithms




图 2 随时间的变化的模糊规则数

Fig. 2 Number of rules changing with time

由表 1 的定量指标可以看出, 虽然 FCM-TS 多数指标均为最优 (值最小), 但它首先需要通过很长时间的离线训练以完成聚类; 而由于 P2 阶段开始时系统参数的改变, 它的指标陡然恶化, 说明工况变化对它有较大影响. 与之相比, 可以在线训练的 GGAP-TS 和 SAFIS 由于在参数改变时生成了新规则 (如图 2 中 110 秒处), 克服了工况变化的影响, 所有性能指标均很好, 而又以本文提出的 GGAP-TS 算法以最少的规则数取得了最好的建模效果.

表 1 三种算法辨识结果的比较 (归一化后)
Table 1 Performance comparison (normalized)

算法	最终规则数	训练误差		检验误差 (P1)		检验误差 (P2)		训练时间
		RMSE	MAE	RMSE	MAE	RMSE	MAE	
GGAP-TS	16	0.0575	0.0397	0.0445	0.0351	0.0640	0.0379	4.001
FCM-TS	20	0.0530	0.0331	0.0396	0.0298	0.1193	0.0436	103.640
SAFIS	17	0.0655	0.0456	0.0516	0.0419	0.0716	0.0427	2.018

5 结 论

本文针对 T-S 模糊推理系统, 引入神经网络中一种神经元生长和修剪方法, 提出了模糊规则的在线生成与修剪的算法. 它计算一条模糊规则所对应的局部线性模型在输出端的平均响应, 并从统计角度描述了它对输出的影响. 与精度要求的比较反映了该局部模型减小误差的显著程度, 从而决定一条规则的增加或删减, 同时模型参数利用竞争性的 EKF 还进行着有监督的学习. 最终形成的 GGAP-TS 方法能够直接在线增减模糊规则与调整参数, 具有良好的自适应和逼近的能力. 仿真实验说明, 利用本文提出的 GGAP-TS 模糊推理系统对非线性系统辨识取得了良好效果.

References

1 Takagi T, Sugeno M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 1985, **15**(1): 116~132

2 Ying H. Sufficient conditions on uniform approximation of multivariate functions by general Takagi-Sugeno fuzzy systems with linear rule consequent. *IEEE Transactions on Systems, Man, and Cybernetics*, 1998, **28**(4): 515~520

3 Setnes M. Supervised fuzzy clustering for rule extraction. *IEEE Transactions on Fuzzy Systems*, 2000, **8**(4): 416~424

4 Nie J H. Constructing fuzzy model by self-organizing counterpropagation network. *IEEE Transactions on Systems, Man, and Cybernetics*, 1995, **25**(6): 963~970

5 Chiu S L. Cluster estimation method with extension to fuzzy model identification. In: *Proceedings of IEEE International Conference on Fuzzy Systems*. IEEE, 1994. 1240~1245

6 Jang J S R. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 1993, **23**(3): 665~685

7 Lin F J, Lin C H, Shen P H. Self-constructing fuzzy neural network speed controller for permanent-magnet synchronous motor drive. *IEEE Transactions on Fuzzy Systems*, 2001, **9**(5): 751~759

8 Shimojima K, Fukuda T, Hasegawa Y. Self-tuning fuzzy modeling with adaptive membership function, rules, and hierarchical structure based on genetic algorithm. *Fuzzy Sets and Systems*, 1995, **71**(3): 295~309

9 Huang G B, Saratchandran P, Sundararajan N. A generalized growing and pruning RBF neural network for function approximation. *IEEE Transactions on Neural Networks*, 2005, **16**(1): 57~67

10 Karayiannis N, Mi G W. Growing radial basis neural networks: merging supervised and unsupervised learning with network growth techniques. *IEEE Transactions on Neural Networks*, 1997, **8**(6): 1492~1506

11 Rong H J, Sundararajan N, Huang G B. Sequential adaptive fuzzy inference system for nonlinear system identification and prediction. *Fuzzy Sets and Systems*, 2006, **157**(9): 1260~1275

12 Ge S S, Hang C C, Zhang T. Nonlinear adaptive control using neural networks and its application to CSTR systems. *Journal of Process Control*, 1999, **9**(4): 313~323

廖龙涛 上海交通大学自动化系硕士研究生. 主要研究方向为非线性系统的模糊建模与控制. E-mail: ltliao@gmail.com
(LIAO Long-Tao Master student at Department of Automation, Shanghai Jiao Tong University. His research interest covers fuzzy modeling and fuzzy control of nonlinear system.)

李少远 上海交通大学自动化系教授. 主要研究方向为预测控制, 优化理论和 Fuzzy 系统. 本文通信作者. E-mail: syli@sjtu.edu.cn
(LI Shao-Yuan Professor at Department of Automation, Shanghai Jiao Tong University. His research interest covers model predictive control, optimization theory, and fuzzy systems. Corresponding author of this paper.)

黄广斌 新加坡南洋理工大学电机与电子工程学院教授. 主要研究方向为计算智能理论, 图像处理和机器人控制.
E-mail: egbhuang@ntu.edu.sg
(HUANG Guang-Bin Professor at School of Electrical and Electronic Engineering, Nanyang Technological University, Singapore. His research interest covers computational intelligence theories, image processing, and robot control.)