

基于 EKF 的自组织 T-S 模糊 Elman 网络

乔俊飞, 袁喜春, 韩红桂

(北京工业大学 电子信息与控制工程学院, 北京 100124)

摘要: 针对模糊神经网络结构设计问题及模糊集在语言描述上存在的不足, 提出一种基于扩展的卡尔曼滤波(EKF)的自组织 T-S 模糊 Elman 网络, 并推导了网络训练算法. 分别采用递归最小二乘法和 EKF 对线性参数和非线性参数进行更新; 基于模糊规则生成准则和误差下降率修剪策略实现了模糊规则的增删减. 最后通过系统辨识和污水处理建模实验, 表明了该算法在保证网络精度和泛化能力的同时, 可以有效地简化网络结构.

关键词: 自组织 T-S 模糊 Elman 网络; 扩展的卡尔曼滤波; 误差下降率; 软测量; 函数逼近

中图分类号: TP273

文献标志码: A

Self-organising T-S fuzzy Elman network based on EKF

QIAO Jun-fei, YUAN Xi-chun, HAN Hong-gui

(School of Electric Information and Control Engineering, Beijing University of Technology, Beijing 100124, China.

Correspondent: HAN Hong-gui, E-mail: rechardhan@sina.com)

Abstract: For the design of the fuzzy neural network architecture and the deficiency of fuzzy sets on semantic description, a self-organising T-S fuzzy Elman network(SOTSFEN) based on extended Kalman filter(EKF) is proposed, and the training algorithm is derived. Furthermore, recursive least square(RLS) and EKF are used to update linear and non-linear parameters respectively. Then the criterion of rule generation is given and error ratio reduction(ERR) is regarded as the fuzzy rule pruning strategy. Finally, the simulation results of system identification and sewage treatment modeling show that the precision and generalization ability of SOTSFEN are ensured, and a simpler architecture network can be achieved simultaneously.

Key words: self-organising T-S fuzzy Elman network; extended Kalman filter; error ratio reduction; soft sensor; function approximation

0 引言

根据信息处理的需要, 实时地生成和修剪模糊规则, 动态地调整网络结构是当前模糊神经网络研究的热点. 文献 [1] 基于聚类思想提出了一种自组织模糊神经网络(SOFNN), 并将其应用于污水处理建模中, 取得了较好的预测效果. 但参数学习采用 BP 算法, 容易陷入局部最优, 影响网络精度. 文献 [2-3] 将遗传算法(GA)应用于结构设计中, 利用 GA 来扩展模糊规则, 得到一个合适的网络结构, 但 GA 算法运算时间长, 且依赖先验值, 应用领域有限. 文献 [4] 通过计算新数据与现有规则之间的最小距离及规则密度来增减模糊规则数, 提出了一种改进的最小二乘自组织模糊神经网络(SOFMLSN), 但该方法对输入数据有所要求. 文献 [5] 采用增长法生成了一种节约型自组织

模糊神经网络(FAOS-PFNN), 然而未给出规则删减准则, 对可能存在的冗余问题未作考虑. 文献 [6] 基于网络输出的敏感度分析, 提出了一种增减型算法, 得到一个结构较为紧凑的自组织模糊神经网络, 但该网络基于前馈网络设计, 对时变状态系统的处理能力有待提升. 文献 [7-8] 以误差下降率作为规则修剪策略, 结构辨识和参数学习同时进行, 分别提出了动态模糊神经网络(DFNN)和自组织模糊神经网络(SOFNN), 它们具有学习速度快和结构紧凑的优点. 但由于两者只对线性部分参数进行学习, 而对非线性部分参数只是有规律的扩大, 即要求隶属函数的参数是确定的, 这在实际中难以满足, 且降低了隶属函数层的作用, 使得模糊集在语言描述上存在不足.

鉴于以上的研究, 针对模糊神经网络结构设计

收稿日期: 2013-01-24; 修回日期: 2013-05-02.

基金项目: 国家自然科学基金杰出青年基金项目(61225016); 国家自然科学基金重点项目(61034008); 国家自然科学基金项目(61203099); 北京市自然科学基金项目(4122006); 教育部博士点新教师基金项目(20121103120020).

作者简介: 乔俊飞(1968—), 男, 教授, 博士生导师, 从事智能控制与智能信息处理、复杂过程建模与优化控制等研究; 袁喜春(1986—), 男, 硕士生, 从事智能计算与污水处理过程建模、模式识别与智能系统的研究.

问题及模糊集在语言描述上存在的不足, 本文基于扩展的卡尔曼滤波(EKF)提出了一种自组织 T-S 模糊 Elman 网络结构. 利用解耦方式将一个全局算法分解成一系列的解耦算法, 用 RLS 来训练网络的线性参数, 而非线性参数的学习采用 EKF, 实现了参数在线学习. 将系统误差判据和可容行边界判据作为模糊规则增加的准则, 并以误差下降率作为修剪策略, 删除不活跃的规则, 自动生成自组织 T-S 模糊 Elman 网络(SOTSFEN), 获取了 EKF-SOTSFEN 算法. 最后, 通过系统辨识和污水处理建模实验, 验证了该算法的有效性和可行性.

1 EKF-SOTSFEN 的结构

自组织 T-S 模糊 Elman 网络(SOTSFEN)由输入层、隶属函数层、规则层、参数层和输出层组成, 其拓扑结构如图 1 所示. n 和 m 分别表示输入节点和模糊节点数, W 表示线性参数 a 的矩阵, w 表示连接权值. 设 $u_i^L(k)$, $o_i^L(k)$ 分别表示第 L 层的第 i 个节点 k 时刻的输入和输出, 每层节点的函数描述如下:




图 1 SOTSFEN 的结构图

输入层: 该层的输出包括输入空间变量 $[x_1, x_2, \dots, x_r]$ 和反馈变量.

$$o_i^1(k) = u_i^1(k) = x_i + w_{ij}(k)u_{c_j}(k),$$

$$i = 1, 2, \dots, r, j = 1, 2, \dots, m, \quad (1)$$

其中 $u_{c_j}(k) = o_j^3(k-1)$ 表示反馈信息.

隶属函数层: 每个节点对应一个语言变量, 隶属函数为高斯函数.

$$o_{ij}^2(k) = \exp\left(-\frac{(o_i^1(k) - c_{ij}(k))^2}{\sigma_{ij}^2(k)}\right). \quad (2)$$

规则层: 每个节点代表一条模糊规则, 规则数等于节点数. 第 j 个规则的 R_j 的输出为

$$o_j^3(k) = \prod_i^n o_{ij}^2(k). \quad (3)$$

参数层: 该层代表 SOTSFEN 的后件部分, 是输入变量的线性组合.

$$o_i^4(k) = o_j^3(k)W_j(k), \quad (4)$$

其中 W_j 表示网络的线性参数.

$$W_j(k) = a_{0j} + a_{1j}u_{i1}^1(k) + \dots + a_{nj}u_{ij}^1(k) + a_{0j} + \sum_{j=1}^m a_{ij}U_j. \quad (5)$$

输出层: 该层是所有输入信号的叠加, 即

$$y(k) = \frac{\sum_{j=1}^m o_j^3(k)W_j(k)}{\sum_{j=1}^m o_j^3(k)}, \quad (6)$$

其中变量 y 表示第 5 层的输出 o_i^5 .

2 EKF-SOTSFEN 的学习算法

EKF-SOTSFEN 的学习算法包括结构辨识和参数学习. 结构辨识以系统误差判据和可溶性边界判据为规则产生准则, 以误差下降率为修剪策略, 动态地增减模糊规则. 参数学习将全局算法划分为线性和非线性两部分, 利用扩展的卡尔曼滤波算法(EKF)调整非线性参数, 即网络的前件部分. 通过递归最小二乘法(RLS)更新线性参数, 即网络的后件部分, 这样可以降低计算负担, 加快计算速度.

2.1 参数学习

2.1.1 线性参数的调整

假定 n 个观测数据产生 m 条模糊规则, 理想输出 $T = [t_1, t_2, \dots, t_n]$, 则网络输出可写成如下矩阵形式:

$$Y = W\psi, \quad (7)$$

$$Y = [y_1, y_2, \dots, y_n]. \quad (8)$$

其中

$$W = [a_{10} \ a_{11} \ \dots \ a_{1r} \ \dots \ a_{m0} \ a_{m1} \ \dots \ a_{mr}],$$

$$\psi = \begin{bmatrix} \varphi_{11} & \dots & \varphi_{1n} \\ \vdots & \ddots & \vdots \\ \varphi_{m1} & \dots & \varphi_{mn} \\ \varphi_{11}x_{11} & \dots & \varphi_{1n}x_{1n} \\ \vdots & \ddots & \vdots \\ \varphi_{m1}x_{11} & \dots & \varphi_{mn}x_{1n} \\ \vdots & \ddots & \vdots \\ \varphi_{m1}x_{r1} & \dots & \varphi_{un}x_{rn} \end{bmatrix}.$$

φ 为一个 $m \times n$ 的矩阵, 表示网络的第 3 输出, 即激活强度.

为了减小旧数据的影响, 增强算法的自适应能力, 采用回归最小二乘法(RLS, 又称卡尔曼滤波算

法KF)估计后件部分的系数矩阵 W ,有

$$W_i = W_{i-1} + S_i \psi_i^T (T_i - \psi_i W_{i-1}), \quad (9)$$

$$S_i = \frac{1}{\lambda} \left(S_{i-1} - \frac{S_{i-1} \psi_i^T \psi_i S_{i-1}}{\lambda + \psi_i S_{i-1} \psi_i^T} \right). \quad (10)$$

其中: $i = 1, 2, \dots, n$, 初始条件为 $W_0 = 0, S_0 = \chi I$. S_i 为第 i 个观测数据的误差协方差矩阵, χ 为一个足够大的正数, 一般取值 $0.05 \sim 0.5$; I 为单位矩阵; ψ_i 为 ψ 的第 i 列; W_i 为经过第 i 次迭代后的系数矩阵; $\lambda (0 \leq \lambda \leq 1)$ 为遗忘因子, λ 越小, 表明数据遗忘得越快.

2.1.2 非线性参数的调整

EKF 是一种基于梯度的在线学习算法, 可以用来调整 SOTSFEN 的非线性参数, 同其他基于梯度的在线算法相比, EKF 能够加快收敛速度, 减小参数对初值的依赖. 但模糊神经网络的高斯中心对网络性能影响不明显, 因此本文只给出高斯宽度和反馈权值的更新公式.

隶属函数的宽度 $\sigma_i = (\sigma_1, \sigma_2, \dots, \sigma_m)$ 的调整如下:

$$\begin{aligned} \sigma_i &= \sigma_{i-1} + K_i^\sigma (T_i^T - \psi_i^T W_{i-1}), \\ K_i^\sigma &= S_{i-1} F_i (1 + F_i^T S_{i-1} F_i)^{-1}, \\ S_i &= S_{i-1} - K_i^\sigma F_i^T S_{i-1}, \quad i = 1, 2, \dots, n. \end{aligned} \quad (11)$$

其中 $F_i = (\delta\sigma_1, \dots, \delta\sigma_j, \dots, \delta\sigma_m) (j = 1, 2, \dots, m)$ 为第 i 次观测宽度的梯度向量, 有

$$F_i = \left. \frac{\partial Y_i^T}{\partial \sigma_{i-1}} \right|_{\sigma = \hat{\sigma}_{i-1}} = -2\sigma_{i-1} \varphi_j \zeta \vartheta; \quad (12)$$

$$\begin{aligned} \zeta &= \left\| (X_i + W_{\text{rec},j} \varphi_{j-1}) - C_j \right\|^2, \\ \vartheta &= \sum_{k=1}^m (W_j - W_k) \varphi_k. \end{aligned}$$

反馈权值矩阵 $W_{\text{rec}} = [w_{i1}, w_{i2}, \dots, w_{ij}]$ 可以根据如下方式进行更新调整:

$$\begin{aligned} W_{\text{rec},i} &= W_{\text{rec},i-1} + K_i^W (T_i^T - \psi_i^T W_{i-1}), \\ K_i^W &= S_{i-1} H_i (1 + H_i^T S_{i-1} H_i)^{-1}, \\ S_i &= S_{i-1} - K_i^W H_i^T S_{i-1}, \quad i = 1, 2, \dots, n. \end{aligned} \quad (13)$$

其中 H 为 $1 \times m$ 维的 Jacobian 矩阵, 如下所示:

$$\begin{aligned} H &= \left. \frac{\partial Y_i^T}{\partial W_{\text{rec},i-1}} \right|_{W_{\text{rec}} = \hat{W}_{\text{rec},i-1}} = \\ &= \left(\frac{\partial Y_i^T}{\partial \psi_i} \frac{\partial \psi_i}{\partial \varphi_i} \frac{\partial \varphi_i}{\partial W_{\text{rec},i-1}} \right) \Bigg|_{W_{\text{rec}} = \hat{W}_{\text{rec},i-1}} = \\ &= 2W_i \exp \left\{ -\frac{\left\| (X_i + W_{\text{rec},j} \varphi_{j-1}) - C_j \right\|^2}{\sigma_j^2} \right\} \tau, \end{aligned} \quad (14)$$

$$\tau = \frac{\left\| (X_i + W_{\text{rec},j} \varphi_{j-1}) - C_j \right\|}{\sigma_j^2} \varphi_{j-1} \sum_{k=1}^m \varphi_{k-1}. \quad (15)$$

综上, 初始条件 $W_{\text{rec},0}$ 为 $[0,1]$ 上一致分布的随机数, $\delta_0 > 0, S_0 = \rho I$. 其中 ρ 为一个小的正数; S_i 为第 i 次观测误差协方差矩阵; K_i^σ 和 K_i^W 为第 i 次观测的增益矩阵; C_j 和 W_j 分别为高斯中心和线性参数矩阵, φ_j 为第 j 个神经元的激活强度.

2.2 规则的修正

2.2.1 模糊规则的产生准则

从模糊规则观点看, 每条规则是输入-输出空间的一个局部表达. 如果 SOTSFEN 同时满足系统误差判据和可容行边界判据, 则应该增加一条规则.

设观测数据为 $\{(X_i, t_i), i = 1, 2, \dots, n\}$, 对应的网络输出为 y_i . 其中: n 为训练数据的数量, X_i 为第 i 个输入样本向量, 对应第 i 个期望输出 t_i .

定义 1 (系统误差的判据^[9]) 对于第 i 个观测数据 (X_i, t_i) , 系统的辨识误差

$$\|e_i\| = \|t_i - y_i\|. \quad (16)$$

如果 $\|e_i\| > k_e$, 则应该考虑增加一条新的模糊规则, 其中

$$k_e = \begin{cases} e_{\max}, & 1 < i < \frac{n}{3}; \\ \max[e_{\max} \times \beta^i, e_{\min}], & \frac{n}{3} \leq i \leq \frac{2n}{3}; \\ e_{\min}, & \frac{2n}{3} < i < n. \end{cases} \quad (17)$$

它是基于粗学习和细学习并重的分级学习思想. 粗学习是对输出误差大且未被现有模糊规则覆盖的位置进行全局学习, 而细学习是指随着边界的逐渐减小, 当 k_e 达到 e_{\min} 时开始的局部学习. 其中: e_{\min} 为 SOTSFEN 期望误差, e_{\max} 为最大的输出误差, i 为学习次数, $\beta (0 < \beta < 1)$ 为收敛参数, 具体推导如下:

$$\beta = \left(\frac{e_{\min}}{e_{\max}} \right)^{1/3}. \quad (18)$$

定义 2 (可溶性边界的判据^[9]) 对于第 i 个观测数据 (X_i, t_i) 进入系统时, 计算观测数据 X_i 与现有神经网络之间的中心 $C_j (j = 1, 2, \dots, m)$ 之间的马氏距离 (Mahalanobis), 由下式表示:

$$d_i(j) = \left\| (X_i + W_{\text{rec},j} \varphi_{j-1}) - C_j \right\|, \quad (19)$$

其中 $j = 1, 2, \dots, m, m$ 为模糊规则数. 最小马氏距离可由下式得到:

$$md_{i,\min} = \arg \min(d_i(j)). \quad (20)$$

如果 $md_{i,\min} > k_d$, 则应考虑增加一条新的模糊规则; 反之, 只利用现有的网络对观测数据 X_i 进行学习. k_d 表示可容纳边界的有效半径, 其更新方式也是

基于分级学习思想,有

$$k_d = \begin{cases} d_{\max} = \sqrt{\ln\left(\frac{1}{\varepsilon_{\max}}\right)}, & 1 < i < \frac{n}{3}; \\ \max[d_{\max}\gamma^i, d_{\min}], & n/3 \leq i \leq \frac{2n}{3}; \\ d_{\min} = \sqrt{\ln\left(\frac{1}{\varepsilon_{\max}}\right)}, & \frac{2n}{3} < i \leq n. \end{cases} \quad (21)$$

其中: i 为学习次数, d_{\max} 为输入空间的最大长度, d_{\min} 为最小长度, γ ($0 < \gamma < 1$) 为衰减常数,可推导出

$$\gamma = \left(\frac{d_{\min}}{d_{\max}}\right)^{\frac{3}{n}} = \left(\sqrt{\frac{\ln(1/\varepsilon_{\max})}{\ln(1/\varepsilon_{\min})}}\right)^{\frac{3}{n}}. \quad (22)$$

只有当 $\|e_i\| > k_e$ 且 $md_{i,\min} > k_d$ 时,才增加一条新的模糊规则,其他情况下,只需用 RLS 和 EKF 更新参数即可。

2.2.2 模糊规则的修剪策略

本文以误差下降率 (ERR) 方法作为修剪策略,删除冗余或不活跃的规则,简化网络结构. n 对输入-输出 $\{(X_i, t_i), i = 1, 2, \dots, n\}$ 的线性回归模型如式 (7) 所示,其可以写成一种紧凑形式:

$$D = H\theta + E. \quad (23)$$

其中: $D = T^T \in R^n$ 为输出期望值; H 为回归量, $H = \psi^T = (h_1, h_2, \dots, h_n) \in R^{n \times v}$, $v = u \times (r + 1)$, θ 为实参数集; $E \in R^n$ 为误差向量。

对于任意矩阵 H , 如果它的行数大于列数,则利用正交分解法 (QR) 可以将 H 转换成正交基向量集

$$H = PA, \quad (24)$$

其中: $P = (p_1, p_2, \dots, p_v) \in R^{n \times v}$ 为正交矩阵, $A \in R^{n \times v}$ 为上三角矩阵。

将式 (24) 代入 (23), 得

$$D = PA\theta + E = PG + E. \quad (25)$$

G 的线性最小方差 (LLS) 的解为

$$g_i = \frac{p_i^T D}{p_i^T p_i}, \quad i = 1, 2, \dots, v. \quad (26)$$

当 $i \neq j$ 时, p_i 和 p_j 正交, 能量 D 可由下式表示:

$$D^T D = \sum_{i=1}^v g_i^2 p_i^T p_i + E^T E. \quad (27)$$

定义 p_i 的误差下降率

$$\text{err}_i = \frac{(p_i^T D)^2}{p_i^T p_i D^T D}, \quad i = 1, 2, \dots, v. \quad (28)$$

将新得到的 err_i ($i = 1, 2, \dots, (r + 1)m$) 重新排列为矩阵 $\Delta = (\rho_1, \rho_2, \dots, \rho_m) \in R^{(r+1) \times m}$, Δ 的第 j 列 p_j 便是与第 j 个规则相关的 $(r + 1)$ 个误差下降率。进一步定义

$$\eta_j = \sqrt{\frac{\rho_j^T \rho_j}{r + 1}}, \quad j = 1, 2, \dots, m. \quad (29)$$

其中: η_j 反映第 j 个规则的重要性, η_j 值越大, 表示第 j 个规则越重要。

如果 $\eta_j < k_{\text{err}}$, 则第 j 条规则可以剔除. 其中 k_{err} 为预先设定的阈值。

综上所述, EKF-SOTSFEN 算法的流程见图 2。

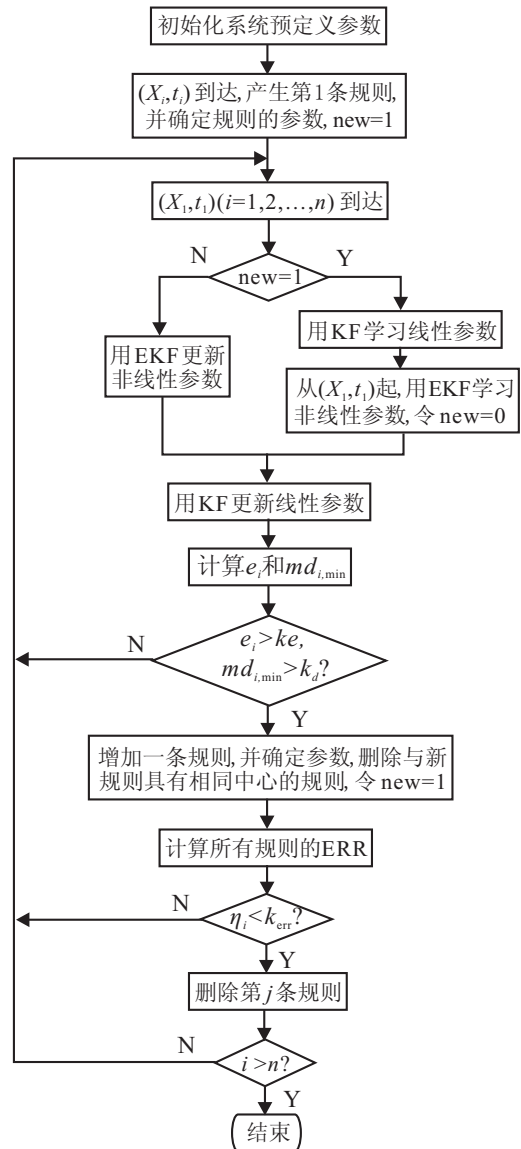


图 2 EKF-SOTSFEN 算法的流程

3 实验与分析

为了验证 EKF-SOTSFEN 算法的有效性和可行性, 本文给出了非线性动态系统的辨识和污泥容积指数 (SVI) 软测量建模的仿真实验, 并与其他算法进行性能比较, 表明了该算法的有效性和优越性。

3.1 非线性动态系统的辨识

命题 1 被辨识的对象描述如下:

$$y(t+1) = \frac{y(t)y(t-1)[y(t)+2.5]}{1+y^2(t)+y^2(t-1)} + u(t). \quad (30)$$


为了辨识该对象, 串-并行模型如下所示:

$$\hat{y}(t+1) = f(y(t), y(t-1), u(t)), \quad (31)$$


其中 f 是用三输入和单输出的GD-FNN^[10]实现的函数. 输入具有以下形式:

$$u(t) = \sin\left(\frac{2\pi t}{25}\right). \quad (32)$$


EKF-SOTSFEN的参数设置如下: $\lambda = 0.25$, $\chi = 0.1$, $e_{\min} = 0.03$, $e_{\max} = 0.85$, $\varepsilon_{\min} = 0.25$, $\varepsilon_{\max} = 0.75$, $k_{\text{err}} = 0.0015$. 200个数据作为训练样本, 另外200个数据作为测试样本^[2]. 网络经过学习后, 模糊规则、RMSE、网络误差及期望值和实际值如图3所示.




(a) 模糊规则的生成



(b) 均方根误差(RMSE)



(c) 训练误差



(d) 训练样本拟合曲线

图3 非线性动态系统辨识

SOTSFEN经过自组织学习, 实现了模糊规则的自适应, 网络结构达到最优, 规则层包含4个规则神经元, 结构较为紧凑. 从图3(b)可以看出, RMSE最终趋近于一个较小值, 表明了SOTSFEN具有较高的精度. 在第1个到第145个样本之间, RMSE的曲线较为陡峭, 表明该处生成或删除了一条规则, 但有时规则的增减是同时进行的, 所以在图3(b)中并不能明显地看出. 从图3(c)和图3(d)可以看出, 基于EKF的自组织T-S模糊Elman网络具有较强的学习能力, 网络误差较小, 训练样本的期望值与SOTSFEN的实际值基本重合, 网络达到一个较高的精度.

表1列出了EKF-SOTSFEN算法与其他算法的比较, SOTSFEN生成规则数为4, 但其训练和测试的均方根误差最小, 而且相比其他模型, 网络性能显著提高. 究其原因, 高斯宽度对网络结构和泛化能力影响巨大, 而D-FNN^[7]、SOFNN^[8]和GD-FNN^[11]对宽度处理较为简单, 在生成模糊规则后赋初值, 样本更新时, 根据某种准则决定是否成比例扩大, 这种方式对初值依赖性较强. UKF-SOIFNN^[12]虽然能够达到较为紧凑的结构, 但相对递归结构SOTSFEN网络, 其精度较差. SOFNNGA^[2]采用遗传算法, 训练时间长, 对先验知识依赖性较强. 本文采用EKF-SOTSFEN算法, 在实现规则增减的同时, 在线调整高斯函数的宽度, 减少了网络对初值的依赖. 当新样本进入时, 能够很好地寻优, 避免网络结构的冗余, 得到一个较为紧凑的结构, 并且精度能够达到二阶以上. 因此, 利用EKF-SOTSFEN算法进行学习, 网络能够达到较高的精度, 并且结构紧凑、泛化能力强.

表1 EKF-SOTSFEN与其他方法的比较


模型	模糊规则数	训练的RMSE	测试的RMSE
D-FNN ^[7]	6	0.0283	—
GD-FNN ^[10]	6	0.0241	—
SOFNN ^[8]	5	0.0157	0.0151
SOFNNGA ^[2]	4	0.0159	0.0146
UKF-SOIFNN ^[11]	4	0.0138	0.0130
EKF-SOTSFEN	4	0.0042	0.0046

3.2 SVI的软测量技术


命题2 在污水处理系统建模中的应用.

活性污泥法是目前世界上工业废水和城市污水二次处理的主要方法之一, 能够很好地实现废水的处理. 但污泥膨胀素有污水生化处理活性污泥法的“癌症”之称, 目前尚未找到一种通用的方式方法加以控制. 相对控制而言, 建立污泥容积指数(SVI)的软测量模型是预防污泥膨胀的有效方法, 可以根据SVI值及时调整运行参数, 保证系统处于最佳运行状态, 发挥最大的处理效能.


污泥容积指数(SVI)的影响因素众多,要包含曝气池混合液悬浮物浓度(MLSS)、氧化还原电位(ORP)、进水总氮(TN)、电导率(K)、曝气池温度(T)、进水总磷(TP)、进水浊度、进水悬浮物浓度(SS)、酸碱度(pH)、进水化学需氧量(COD)、进水流量(Q)、曝气池溶解氧(DO)和曝气池氨氮浓度(NH_4)共13个水质参量.利用主元分析法(PCA)选取MLSS、 NH_4 、pH和 T 等4个水质参数作为网络的输入变量,建立SVI的软测量模型.本实例数据来源于北京某小型污水处理厂实际日报表,共192组,其中120组数据用于训练网络,另72组作为测试样本.




(a) 模糊规则的生成



(b) 网络误差曲线



(c) 训练样本拟合误差



(d) 测试样本拟合曲线

图4 污泥容积指数的软测量建模

利用PCA和EKF-SOTSFEN建立SVI的软测量模型,对污水沉降指数SVI进行预测. SOTSFEN的网络参数设置如下: $\lambda = 0.25$, $\chi = 0.1$, $\varepsilon_{\min} = 0.08$, $\varepsilon_{\max} = 0.75$, $\varepsilon_{\min} = 0.25$, $\varepsilon_{\max} = 0.75$, $k_{\text{err}} = 0.0035$.网络经过训练后,实现了模糊规则的增减(见图4(a)),SOTSFEN的训练误差和测试误差较小(见图4(b)),网络达到一个较高的精度.训练样本的期望值与模型实际输出值,测试样本期望值与模型实际输出值分别如图4(c)和4(d)所示,模型输出能够很好地跟踪期望值.网络的主要性能指标在表2中列出,由表2数据可知,EKF-SOTSFEN精度高、结构紧凑、泛化能力强,能够很好地模拟实际活性污水处理系统的运行情况,实时准确地反映SVI的变化.

表2 EKF-SOTSFEN的性能指标

性能指标	训练样本实际(期望)输出	测试样本实际(期望)输出
rule	5	5
RMSE	0.0102	0.0171
APE	0.0021	0.0042
min	62.2855(62.3000)	61.9792(62.3000)
max	113.2476(112.3000)	112.9710(112.3000)

表2中,APE表示平均百分误差^[12],可以由

$$\text{APE} = \frac{1}{n} \sum_{i=1}^n \frac{|t(i) - f(i)|}{|t(i)|} \times 100\%$$

表示.其中: n 是数据对的数目, $t(i)$ 和 $f(i)$ 分别是第 i 个输入对应的期望输出和实际输出.

4 结 论

本文基于扩展的卡尔曼滤波算法(EKF),提出了一种自组织T-S模糊Elman网络(SOTSFEN),并推导了网络的学习算法,实现了网络结构和参数的在线调整,得到结构紧凑、泛化能力强、精度高的SOTSFEN.通过非线性动态系统辨识和SVI的在线检测实验,结果表明:

1) 基于误差下降率的模糊规则修剪策略,EKF-SOTSFEN能够根据输入输出数据实时调整模糊规则,自动生成网络结构;

2) EKF-SOTSFEN算法实现了高斯宽度的在线调整,减小了对初值的依赖,在不确定性表达和处理上更为灵活;

3) k_e , k_d 采用分级学习法,粗学习和细学习并重的方式能够提高网络精度;

4) EKF-SOTSFEN算法不仅对模糊规则重要性进行评估,而且通过加入遗忘因子减少了旧数据的影响,增强了算法的自适应能力;

5) 基于SOTSFEN的SVI软测量模型,能够很好地模拟实际污水处理系统的运行情况,实现SVI的实时检测,具有实际应用价值,可以为复杂非线性动态

系统辨识、建模和控制提供技术支持, 具有广泛的发展潜力.

参考文献(References)

- [1] 乔俊飞, 王会东. 模糊神经网络的结构自组织算法及应用[J]. 控制理论与应用, 2008, 25(4): 703-707.
(Qiao J F, Wang H D. Structure self-organizing algorithm for fuzzy neural networks and its applications[J]. Control Theory & Applications, 2008, 25(4): 703-707.)
- [2] Gang L, Girijesh P, Thomas M M, et al. Design for self-organizing fuzzy neural networks based on genetic algorithms[J]. IEEE Trans on Fuzzy Systems, 2006, 14(6): 755-766.
- [3] Alcal'a-Fdez J, Alcal'a R, Gacto M J, et al. Learning the membership function contexts for mining fuzzy association rules by using genetic algorithms[J]. IEEE Trans on Fuzzy Sets and Systems, 2009, 160(7): 905-921.
- [4] Rubio J D J. SOFMLS: Online self-organizing fuzzy modified least squares network[J]. IEEE Trans on Fuzzy Systems, 2009, 17(6): 1296-1309.
- [5] Wang N, Er M J, and Meng X Y. A fast and accurate online self-organizing scheme for parsimonious fuzzy neural networks[J]. Neurocomputing, 2009, 72(16/17/18): 3818-3829.
- [6] Han H G, Qiao J F. A self-organizing fuzzy neural network based on a growing and pruning algorithm[J]. IEEE Trans on Fuzzy Systems, 2010, 6(18): 1129-1143.
- [7] Wu S Q, Er M J. Dynamic fuzzy neural networks-a novel approach to function approximation[J]. IEEE Trans on Systems, Man, Cybernetics: Part B, 2000, 30(2): 358-364.
- [8] Gang L, Girijesh P, Thomas M M. An approach for on-line extraction of fuzzy rules using a self-organising fuzzy neural networks[J]. IEEE Trans on fuzzy Sets and Systems, 2005, 150(2): 211-243.
- [9] 陶永芹, 崔杜武. 基于动态模糊神经网络算法的负荷辨识[J]. 控制与决策, 2011, 26(4): 519-523.
(Tao Y Q, Cui D W. Load identification of algorithm based on dynamic fuzzy granular neural network[J]. Control and Decision, 2011, 26(4): 519-523.)
- [10] ER M J, Wu S, Gao Y. A fast approach for automatic generation of fuzzy rules by generalized dynamic fuzzy neural network[J]. IEEE Trans on Fuzzy Systems, 2001, 9(4): 578-594.
- [11] 徐小来, 雷英杰, 谢文彪. 基于UKF的自组织直觉模糊神经网络[J]. 电子学报, 2010, 38(3): 638-645.
(Xu X L, Lei Y J, Xie W B. Self-organising intuitionistic fuzzy neural networks based on UKF[J]. Acta Electronica Sinica, 2010, 38(3): 638-645.)
- [12] Chen S, Cowan C F N, Grant P M. Orthogonal least squares learning algorithm for radial basis function network[J]. IEEE Trans on Neural Network, 1991, 2(2): 302-309.

(责任编辑: 孙艺红)