

基于UKF的增长型模糊神经网络设计

韩红桂[†], 林征来, 乔俊飞

(1. 北京工业大学 电子信息与控制工程学院, 北京 100124;

2. 计算智能与智能系统北京市重点实验室, 北京 100124)

摘要: 为了实现模糊神经网络结构和参数的同时调整, 提出一种基于无迹卡尔曼滤波(UKF)的增长型模糊神经网络(UKF-GFNN). 首先, 利用UKF对模糊神经网络的参数进行调整; 然后, 设计一种基于隐含层神经元输出强度的模糊规则增长机制, 实现模糊神经网络的结构增长; 最后, 将所提出的增长型模糊神经网络应用于非线性系统建模. 实验结果显示, 基于UKF的增长型模糊神经网络能够实现结构和参数的自校正, 并且具有较高的建模精度.

关键词: 模糊神经网络; 无迹卡尔曼滤波; 增长型; 非线性系统建模

中图分类号: TP173

文献标志码: A

Growing fuzzy neural network design based on UKF algorithm

HAN Hong-gui[†], LIN Zheng-lai, QIAO Jun-fei

(1. College of Electronic Information & Control Engineering, Beijing University of Technology, Beijing 100124, China;

2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China)

Abstract: In order to adjust the structure and parameter of a fuzzy neural network simultaneously, a growing fuzzy neural network based on the unscented Kalman filter(UKF) method is proposed. Firstly, the UKF method is used to adjust the parameters of the fuzzy neural network. Then, a growing mechanism, using the output intensity of hidden neurons, is designed for self-organizing the fuzzy rules, and the structure of fuzzy neural networks can grow in the learning process. Finally, the proposed growing fuzzy neural network is used to model a nonlinear system. The experimental results show that the proposed growing fuzzy neural network is able to adjust the structure and parameters simultaneously, as well as with suitable modeling accuracy.

Keywords: fuzzy neural network; unscented Kalman filter; growing mechanism; nonlinear system modeling

0 引 言

模糊神经网络不仅可以利用先验知识实现模糊逻辑, 而且具有神经网络的自学习和自整定能力, 已经在模式识别、信号处理、非线性系统辨识和控制等领域得到了广泛的应用^[1-4]. 模糊神经网络的性能由其结构和参数共同确定, 在应用过程中必须预先确定其结构和学习算法, 使得模糊神经网络的应用受到了较大的限制^[5-6]. 如何实现模糊神经网络根据处理的问题自动调整结构和参数仍是一个开放性问题^[7-8].

为了实现模糊神经网络根据处理的问题实时调整结构和参数, 学者们做了大量的工作. Wu等^[9]提出了一种自组织动态模糊神经网络(DFNN), 采用误差下降率(ERR)对模糊神经网络结构进行调整, 并利用线性最小二乘法对DFNN的参数进行调整; 为

了进一步改进DFNN的性能, Wu等^[10]又提出了广义动态模糊神经网络(GDFNN), 采用椭圆基函数在线修改隶属函数(MF)的中心值, 其学习效率和性能都优于DFNN, 但是DFNN和GDFNN必须依赖全部训练样本对模糊神经网络结构进行调整, 因此不适合在线训练; Wang等^[11]提出了一种快速精确在线自组织模糊神经网络(FAOS-PFNN), FAOS-PFNN利用ERR作为模糊神经网络神经元的生长标准, 并采用扩展卡尔曼滤波(EKF)对模糊神经网络的参数进行学习, 模糊神经网络的性能有所提高; 随后, Wang等^[12]又提出了一种具有限制性增长的在线自构造模糊神经网络(OSFNNRG), OSFNNRG的学习速度和精度较FAOS-PFNN有所提高; Zhang等^[13]采用正交最小二乘(OLS)方法优化模糊神经网络结构, 并利

收稿日期: 2016-10-10; 修回日期: 2016-12-23.

基金项目: 国家自然科学基金项目(61533002, 61622301); 北京市自然科学基金项目(4172005); 科技部水专项(2017ZX07104).

作者简介: 韩红桂(1983-), 男, 教授, 博士生导师, 从事污水处理过程建模、优化与控制等研究; 林征来(1991-), 男, 硕士生, 从事复杂过程建模、控制的研究.

[†]通讯作者. E-mail: rechardhan@bjut.edu.cn

用LM(Levenberg-Marquardt)算法调整模糊神经网络中的参数,具有较好的分类能力和较少的计算复杂度;Rubio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,提出了一种改进型最小二乘自组织模糊神经网络(SOFMLS)^[14];Han等^[15]提出了一种基于敏感度分析算法(SA)的生长剪枝模糊神经网络(GPFNN),网络结构依赖于模糊神经网络隐含层神经元的灵敏度分析(SA)值。但是,以上模糊神经网络精度有待提高。近年来,许多学者也提出了利用进化算法实现对模糊网络结构和参数的同时调整。Leng等^[16]提出了一种基于遗传算法(GA)的混合自组织模糊神经网络(SOFNNGA),该网络的使用范围比其他网络更加广泛;Tzeng等^[17]利用GA算法对模糊小波神经网络(FWNN)的结构和参数进行了调整,调整后所得的最终模糊神经网络具有较好的逼近能力;Kuo等^[18]利用粒子群优化(PSO)方法对模糊神经网络的结构和参数进行了调整,提出了一种综合优化的人工免疫网络和基于PSO的模糊神经网络(IOAP-FNN),相比其他算法,IOAP-FNN具有较好的性能。但是,由于进化算法是全局搜索算法,基于进化算法的自组织模糊神经网络训练时间较长,限制了其推广运用。

针对上述问题,提出一种基于无迹卡尔曼滤波(UKF)的增长型模糊神经网络,利用UKF对模糊神经网络中的参数进行调整,保证模糊神经网络的精度,同时UKF避免对训练过程中雅克比矩阵的计算,提高模糊神经网络的训练速度,并利用模糊神经网络隐含层神经元输出强度设计一种增长机制,实现模糊神经网络结构和参数的同时调整。实验结果表明,基于UKF的模糊神经网络不仅具有相对紧凑的结构和较高的预测精度,同时具有较快的学习速度。

1 模糊神经网络

主要针对多输入单输出(MISO)的多层前馈模糊神经网络进行研究,其结构如图1所示。




图1 模糊神经网络结构

模糊神经网络由4层组成:输入层、RBF层、规则化层和输出层。各层的功能如下。

输入层:该层有 m 个神经元,代表 m 个输入变量,即

$$u_i = x_i. \quad (1)$$

其中: $i = 1, 2, \dots, m$; u_i 是第 i 个神经元的输出。

RBF层:该层的功能是对输入量进行模糊化,每个RBF神经元代表模糊规则的if部分,每个RBF神经元由中心值和宽度组成,其中心值的维数与输入变量相同,该层的输出为

$$\varphi_j = \prod_{i=1}^m e^{-\frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}} = e^{-\sum_{i=1}^m \frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}}. \quad (2)$$

其中: $i = 1, 2, \dots, m$; $j = 1, 2, \dots, p$; φ_j 是第 j 个神经元的输出; c_{ij} 是神经元 j 的中心值; σ_{ij} 是神经元 j 的隶属函数宽度。

规则化层:该层有 p 个神经元,该层的输出为

$$v_l = \frac{\varphi_l}{\sum_{j=1}^p \varphi_j} = \frac{e^{-\sum_{i=1}^m \frac{(u_i - c_{il})^2}{2\sigma_{il}^2}}}{\sum_{j=1}^p e^{-\sum_{i=1}^m \frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}}}. \quad (3)$$

其中: $j = 1, 2, \dots, p$; $l = 1, 2, \dots, p$; $\mathbf{v} = [v_1, v_2, \dots, v_p]^T$ 是规则化层输出, v_l 是第 l 个神经元的输出。

输出层:该层的功能是实现解模糊,文中采用重心法进行清晰化。

$$\beta_l = w_l v_l = \frac{w_l e^{-\sum_{i=1}^m \frac{(u_i - c_{il})^2}{2\sigma_{il}^2}}}{\sum_{j=1}^p e^{-\sum_{i=1}^m \frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}}}, \quad (4)$$

$$y = \sum_{l=1}^p w_l v_l = \frac{\sum_{l=1}^p w_l e^{-\sum_{i=1}^m \frac{(u_i - c_{il})^2}{2\sigma_{il}^2}}}{\sum_{j=1}^p e^{-\sum_{i=1}^m \frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}}}. \quad (5)$$

其中: $j = 1, 2, \dots, p$; $l = 1, 2, \dots, p$; $\mathbf{w} = [w_1, w_2, \dots, w_p]$ 是规则化层与输出层之间的连接权值; $\beta = [\beta_1, \beta_2, \dots, \beta_p]$ 是输出层的输入, β_l 是规则化层的第 l 个神经元的输出; y 是模糊神经网络的输出。

2 增长型模糊神经网络设计

模糊神经网络的学习包括参数学习和结构学习。参数学习主要利用UKF算法对模糊神经网络的参数进行调整,结构学习主要依靠模糊规则增长策略确定模糊神经网络结构,并给出了UKF-GFNN的算法步骤。

2.1 参数学习

假定在模糊神经网络中, n 对样本产生了 p 条模糊规则, 模糊神经网络输出为

$$\mathbf{y} = \mathbf{w}\mathbf{V}. \quad (6)$$

其中: $\mathbf{y} = [y_1, y_2, \dots, y_n]$, $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n]$.

已知模糊神经网络期望输出 $\mathbf{y}_d = [y_{d1}, y_{d2}, \dots, y_{dn}]$, 利用线性最小二乘估计得出模糊神经网络权值为

$$\mathbf{w} = \mathbf{y}_d(\mathbf{V}^T\mathbf{V})^{-1}\mathbf{V}^T. \quad (7)$$

已知模糊神经网络初始RBF层神经元隶属函数中心参数 \mathbf{c} 、隶属函数宽度参数 σ 以及模糊神经网络权值 \mathbf{w} 的前提下, 模糊神经网络作为非线性动力系统, 定义为

$$\theta(k) = \theta(k-1), \quad (8)$$

$$y_d(k) = h(\theta(k)) + e(k). \quad (9)$$

其中: $\theta(k) = [c_{1j}, c_{2j}, \dots, c_{mj}; \sigma_{1j}, \sigma_{2j}, \dots, \sigma_{mj}]$ 是 k 时刻的模糊神经网络状态变量, $y_d(k)$ 是 k 时刻模糊神经网络期望输出, h 是非线性函数, $e(k)$ 是 k 时刻模糊神经网络误差.

假定所有的随机变量服从高斯分布, 当采用UKF进行参数更新时, k 时刻模糊神经网络的状态变量为

$$\hat{\theta}(k|k) = \hat{\theta}(k|k-1) + K(k)(y_d(k) - \hat{y}_d(k)). \quad (10)$$

其中: $\hat{\theta}(k|k-1)$ 是 $\theta(k)$ 的最优预测, $\hat{y}_d(k)$ 是 $y_d(k)$ 的最优预测, $K(k)$ 是卡尔曼滤波增益.

式(10)中各个参数为

$$\hat{\theta}(k|k-1) = \sum_{q=0}^{2L} d \cdot \chi_q(k|k-1), \quad (11)$$

$$\hat{y}_d(k) = \sum_{q=0}^{2L} d \cdot \zeta_q(k), \quad (12)$$

$$K(k) = P_{x,y_d}(k)P_{y_d}^{-1}(k). \quad (13)$$

其中: $q = 0, 1, \dots, L$, L 是状态变量的个数; d 是加权值; 预测值 $\chi_q(k|k-1)$ 是由式(8)对各个状态变量 $\chi_q(k-1)$ 进行变换得到的; 输出值 $\zeta_q(k)$ 、状态变量的方差阵 $P_{x,y_d}(k)$ 、模糊神经网络输出的方差阵 $P_{y_d}(k)$ 是由式(9)对 $\chi_q(k|k-1)$ 进行变换得到的, 计算式为

$$d = \lambda/(L + \lambda), \quad (14)$$

$$\chi_q(k|k-1) = \chi_q(k-1), \quad (15)$$

$$\zeta_q(k) = h(\chi_q(k|k-1)), \quad (16)$$

$$P_{x,y_d}(k) = \sum_{q=0}^{2L} d(\chi_q(k|k-1) - \hat{\theta}(k|k-1))(\zeta_q(k) - \hat{y}_d(k))^T, \quad (17)$$

$$P_{y_d}(k) = \sum_{q=0}^{2L} d(\zeta_q(k) - \hat{y}_d(k))(\zeta_q(k) - \hat{y}_d(k))^T + R(k). \quad (18)$$

$\lambda = 3a^2 - L$, $a = 0.5$ 决定集合点的散布程度; $R(k)$ 是 k 时刻协方差随机噪声.

式(15), (17), (18)中 $\chi_q(k-1)$ 为

$$\chi_q(k-1) = \begin{cases} \bar{\theta}(k-1), \\ \bar{\theta}(k-1) - \sqrt{(L + \lambda)P(k-1)}, \\ q = 1, 2, \dots, L; \\ \bar{\theta}(k-1) + \sqrt{(L + \lambda)P(k-1)}, \\ q = L + 1, \dots, 2L. \end{cases} \quad (19)$$

式(19)中 $\bar{\theta}(k-1)$ 是 $k-1$ 时刻状态变量的均值, 初始方差阵 $P(0) = \gamma\mathbf{I}$, \mathbf{I} 是单位矩阵, γ 是常数. 状态后验方差矩阵 $P(k)$ 为

$$P(k) = P(k|k-1) - K(k) \cdot P_{y_d(k)}K(k)^T, \quad (20)$$

$$P(k|k-1) = \sum_{q=0}^{2L} d(\chi_q(k|k-1) - \hat{\theta}(k|k-1)) \times (\chi_q(k|k-1) - \hat{\theta}(k|k-1))^T + Q(k). \quad (21)$$

其中: $P(k|k-1)$ 是 $P(k)$ 的预测值, $Q(k)$ 是 k 时刻协方差随机噪声.

UKF通过对状态变量的对称采样来近似高斯随机变量的状态分布, UKF对于任何非线性系统统计量精度都能达到至少二阶以上.

2.2 结构学习

当第一个样本 $(\mathbf{x}(1), t(1))$ 进入模糊神经网络进行训练时, 模糊神经网络初始RBF层神经元参数设定为

$$\mathbf{c}_1 = \mathbf{x}(1), \quad (22)$$

$$\sigma_1 = (\sigma_0, \sigma_0, \dots, \sigma_0)^T. \quad (23)$$

其中: $\mathbf{x}(1)$ 是第一个样本的输入值, $t(1)$ 是期望输出, \mathbf{c}_1 是神经元隶属函数中心参数, σ_1 是神经元隶属函数宽度参数, σ_0 是预先定义的隶属函数宽度.

定义每一个新的样本进入之后, RBF层输出为隐含层输出强度, 即

$$\varphi = \operatorname{argmax}(\varphi_j), \quad (24)$$

其中 φ_j 是第 j 个神经元的输出. 假定 RBF 层输出强度阈值为 η , 如果当第 n 个样本进入网络训练时, 满足

$$\varphi \leq \eta, \quad (25)$$

则需增加一个新的 RBF 层神经元, 其参数为

$$\mathbf{c}_{\text{new}} = \mathbf{x}(n), \quad (26)$$

$$\sigma_1 = \sigma_1. \quad (27)$$

其中: $0 \leq \eta \leq 1$, \mathbf{c}_{new} 是新增神经元的中心值, $\mathbf{x}(n)$ 是当前输入样本值, σ_{new} 是新增神经元的隶属函数宽度.

若 RBF 神经元数过少, 则模糊神经网络性能很差, 精度难以保证. 式 (25) 利用隐含层输出强度的方法作为 RBF 神经元增长的条件, 采用合适的阈值, 较少或几乎不会出现冗余的节点, 同时也缩短了运行时间.

通过以上结构学习, 模糊神经网络 RBF 层神经元和规则化层神经元得到调整, 从而具有模糊神经网络结构在线自调整的能力.

2.3 UKF-GFNN 算法

根据以上对模糊神经网络的参数学习和结构学习, 具体的 UKF-GFNN 算法流程如下.

Step 1: 给定一个规则层和一个 RBF 层神经元的模糊神经网络, 初始化模糊神经网络 RBF 层神经元隶属函数中心参数 \mathbf{c} 和宽度参数 σ , RBF 层输出强度阈值 η , 初始化方差阵 $P(0)$, 协方差随机噪声 Q, R .

Step 2: 当前样本进入模糊神经网络训练, 根据增长判断条件 (24) 和 (25) 对模糊神经网络 RBF 层神经元进行分析, 如果神经元需要分裂, 则调整网络结构, 利用式 (26) 和 (27) 对新增长的神经元进行隶属函数中心值 \mathbf{c}_{new} 和隶属函数宽度 σ_{new} 设定. 利用式 (7) 得出结构调整后的模糊神经网络权值 \mathbf{w} , 否则跳转 Step 3.

Step 3: 根据式 (7) 和 \mathbf{c}, σ 得出模糊神经网络结构未调整的 \mathbf{w} , 利用式 (10) ~ (21) 对模糊神经网络 RBF 神经元的隶属函数中心值和隶属函数宽度进行更新, 利用线性最小二乘法对 \mathbf{w} 进行修改.

Step 4: 判断全部样本是否训练完毕. 若训练完毕, 则停止计算; 否则, 跳转 Step 2 进行重新训练.

3 论证实验

将 UKF-GFNN 应用于非线性动态系统的建模、Mackey-Glass 混沌时间序列预测、污水处理过程出水氨氮 ($\text{NH}_4\text{-N}$) 预测实验, 与 DFNN^[9]、GDFNN^[10] 和

FAOS-PFNN^[11] 等网络对比, 验证 UKF-GFNN 的有效性, 选取 η 的值为 0.3.

3.1 非线性动态系统辨识

非线性动态系统方程如下:

$$y(t+1) = \frac{y(t)y(t-1)[y(t)+2.5]}{1+y^2(t)+y^2(t-1)} + u(t). \quad (28)$$

其中: $y(1) = 0, y(2) = 1, u(t) = \sin(2\pi t/25)$. 该模型定义为

$$\bar{y}(t+1) = f(y(t), y(t-1), u(t)). \quad (29)$$

其中: f 是三输入单输出的模糊神经网络模型, 其输入为 $(y(t), y(t-1), u(t))$, 其输出为 $\bar{y}(t+1)$.

选取式 (29) 中 500 组样本, 其中包括 400 组训练样本和 100 组测试样本, 仿真结果如图 2 ~ 图 4 所示. 图 2 表示 UKF-GFNN 训练过程中规则化层神经元个数变化曲线, 图 3 表示 UKF-GFNN 测试样本的测试结果, 图 4 表示 UKF-GFNN 的预测误差.




图 2 非线性动态系统辨识规则化层神经元个数




图 3 非线性动态系统辨识测试结果




图 4 非线性动态系统辨识预测误差

利用 UKF-GFNN 对该非线性系统进行建模时, 与其他算法比较的性能指标为 RBF 神经元数、测试

RMSE、运行时间,比较结果如表1所示.

表1 不同算法性能对比

算法	RBF神经元数	测试RMSE	训练时间/s
UKF-GFNN	7	0.0057	1.81
DFNN ^[9]	6	0.0124	36.55
GDFNN ^[10]	8	0.0105	42.33
FAOS-PFNN ^[11]	6	0.0232	15.23
SOFMLS ^[14]	6	0.0276	33.24
GP-FNN ^[15]	6	0.0105	32.01

由表1可知,UKF-GFNN算法的RBF神经元数为7,相比于GDFNN算法,UKF-GFNN的结构更为紧凑,DFNN、FAOS-PFNN、SOFMLS、GP-FNN的RBF神经元数均为6,结构最紧凑,但是UKF-GFNN的测试RMSE为0.0057,具有最小的测试RMSE,同时UKF-GFNN的训练时间为1.81s,明显优于其他5种模糊神经网络算法.由此可知,UKF-GFNN不仅结构相对紧凑,有较好的泛化能力,而且具有最快的学习速度,较强的非线性系统辨识能力.

3.2 Mackey-Glass时间序列预测

Mackey-Glass混沌时间序列方程如下:

$$x(t+1) = (1-a)x(t) + \frac{bx(t-\tau)}{1+x^{10}(t-\tau)}. \quad (30)$$

其中: $a = 0.1, b = 0.2, \tau = 17$,初始状态 $x(0) = 1.2$. 预测模型描述为

$$x(t+p) = f[x(t), x(t-\Delta), x(t-2\Delta), x(t-3\Delta)]. \quad (31)$$

其中: $p = 6, \Delta t = 6$.在 $t = 1$ 到 $t = 1000$ 之间选择500组样本作为训练样本并选择500组样本作为测试样本,仿真结果如图5~图7所示.图5表示UKF-GFNN训练过程中规则化层神经元个数变化曲线,图6表示UKF-GFNN测试样本的测试结果,图7表示UKF-GFNN的预测误差.




图5 Mackey-Glass 规则化层神经元个数




图6 Mackey-Glass 测试结果




图7 Mackey-Glass 预测误差

利用UKF-GFNN对Mackey-Glass混沌时间序列建模预测时,与其他网络比较的性能指标为RBF神经元数、测试RMSE以及运行时间,它们的比较结果如表2所示.

表2 不同算法性能对比

算法	RBF神经元数	测试RMSE	训练时间/s
UKF-GFNN	6	0.0115	3.21
DFNN ^[9]	5	0.0131	93.21
FAOS-PFNN ^[11]	11	0.0127	7.61
SOFMLS ^[14]	7	0.0471	52.35
GP-FNN ^[15]	9	0.0107	56.14
SOFNNGA ^[16]	7	0.0132	168.35
CFNNLM ^[24]	3	0.0116	13.32

由表2可知,UKF-GFNN算法的RBF神经元数为6,相比于算法FAOS-PFNN、SOFNNGA、SOFMLS、GP-FNN,UKF-GFNN的网络结构更为紧凑.DFNN、CFNNLM的RBF神经元数相对于UKF-GFNN较少,但是,UKF-GFNN的测试RMSE为0.0115,除GP-FNN之外,具有最小的测试RMSE,同时UKF-GFNN的运行时间为3.21s,具有最短的训练时间.由此可知,UKF-GFNN不仅结构相对紧凑,而且具有较好的泛化能力和较强的在线学习速度,体现了UKF-GFNN预测Mackey-Glass混沌时间序列的优越性.

3.3 污水处理出水氨氮参数预测

污水处理出水氨氮含量是衡量水污染的重要指标.针对氨氮在水处理中的非线性、时变性和滞后性

导致难以实时检测的问题^[20-23],提出一种基于UKF-GFNN的出水氨氮(NH₄-N)的预测模型.通过机理分析得出NH₄-N的辅助变量,模型输入温度 T 、厌氧末端ORP、好氧前端DO、好氧末端TSS和出水PH,输出NH₄-N.为了测试NH₄-N预测模型的有效性,实验选取来自北京污水处理厂的140组NH₄-N样本数据,其中90组作为训练样本,50组作为测试样本.仿真结果如图8和图9所示.图8表示UKF-GFNN测试样本的测试结果,图9表示UKF-GFNN的预测误差.




图8 NH₄-N浓度测试结果




图9 NH₄-N浓度预测误差

利用UKF-GFNN对NH₄-N进行建模预测时,与ANFIS等模型比较的性能指标为测试RMSE和准确度,比较结果如表3所示.

表3 不同算法性能对比

算法	测试RMSE	准确度/%
UKF-GFNN	0.0960	99.30
DFNN ^[9]	0.4976	94.75
GDFNN ^[10]	0.1023	98.85
GP-FNN ^[15]	1.919	96.30
ANFIS ^[23]	0.1210	97.20
BP-FNN ^[25]	0.3405	88.42
LM-FNN ^[26]	0.1672	73.12

由表3可知,与算法DFNN、GDFNN、GP-FNN、ANFIS、BP-FNN、LM-FNN相比,算法UKF-GFNN预测NH₄-N的测试RMSE为0.0960,具有最小的测试RMSE. UKF-GFNN预测NH₄-N准确度高达99.30%,

其明显优于其他的模糊神经网络算法,表明将UKF-GFNN应用于NH₄-N参数预测时,具有较高的预测精度,验证了UKF-GFNN在预测污水处理中出水氨氮参数的有效性和优越性.

4 结论

针对模糊神经网络的结构和参数难以同时优化的问题,以及模糊神经网络精度不高和运行时间过长的局限性,提出了一种基于UKF的增长型模糊神经网络的设计:1)采用UKF算法对模糊神经网络进行参数调整,避免了对雅克比矩阵的计算,提高了模糊神经网络的训练速度,具有较高的精度,但UKF的初始参数设定还需继续深入,如何简化UKF算法而不影响算法性能是下一步研究的重点.2)根据隐含层输出强度提出了一种模糊神经网络RBF层神经元增长标准,实现了模糊神经网络结构的自调整.3)将UKF-GFNN应用于非线性动态系统建模、Mackey-Glass混沌时间序列预测、污水处理出水氨氮参数预测实验,与其他模糊神经网络相比,UKF-GFNN不仅结构相对紧凑,而且具有较好的泛化能力和较快的学习速度.通过以上分析可知,本文提出的UKF-GFNN能够实现结构和参数的自调整,具有较好的在线结构调整能力和较强的在线参数自学习能力,适用于非线性系统的建模预测,为复杂系统的建模预测提供了一种行之有效的方法.

参考文献(References)

- [1] Farahani M, Ganjefar S. An online trained fuzzy neural network controller to improve stability of power systems[J]. *Neurocomputing*, 2015, 162: 245-255.
- [2] 夏国清, 杨莹, 赵为光. 欠驱动AUV模糊神经网络 L_2 增益鲁棒跟踪控制[J]. *控制与决策*, 2013, 28(3): 351-356.
(Xia G Q, Yang Y, Zhao W G. L_2 gain robust tracking control for under actuated AUV fuzzy neural network[J]. *Control and Decision*, 2013, 28(3): 351-356.)
- [3] Tan S C, Watada J, Ibrahim Z, et al. Evolutionary fuzzy ARTMAP neural networks for classification of semi-conductor defects[J]. *IEEE Trans on Neural Networks and Learning System*, 2015, 26(5): 933-950.
- [4] Mohammed M F, Lim C P. An enhanced fuzzy min-max neural network for pattern classification[J]. *IEEE Trans on Neural Networks and Learning System*, 2015, 26(3): 417-429.
- [5] Chakraverty S, Sahoo D M. Fuzzy neural network-based system identification of multi-storey shear buildings[J]. *Neural Computing and Applications*, 2017, 28(2): 1-16.

- [6] 乔俊飞, 袁喜春, 韩红桂. 基于EKF的自组织T-S模糊Elman网络[J]. 控制与决策, 2014, 29(5): 853-859. (Qiao J F, Yuan X C, Han H G. Self-organizing T-S fuzzy Elman network based on EKF[J]. Control and Decision, 2014, 29(5): 853-859.)
- [7] Lian R J. Enhanced adaptive self-organizing fuzzy sliding-mode controller for active suspension systems[J]. IEEE Trans on Industrial Electronics, 2013, 60(3): 958-968.
- [8] Wai R J, Chen M W, Liu Y K. Design of adaptive control and fuzzy neural network control for single-stage boost inverter[J]. IEEE Trans on Industrial Electronics, 2015, 62(9): 5434-5445.
- [9] Wu S Q, Er M J. Dynamic fuzzy neural networks—A novel approach to function approximation[J]. IEEE Trans on Systems, 2000, 30(2): 358-364.
- [10] Wu S Q, Er M J, Gao Y A. A fast approach for automatic generation of fuzzy rules by generalized dynamic fuzzy neural networks[J]. IEEE Trans on Fuzzy Systems, 2001, 9(4): 578-574.
- [11] Wang N, Er M J, 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.
- [12] Wang N, Er M J, Meng X Y. An online self-constructing fuzzy neural network with restrictive growth[C]. Recent Advances in Intelligent Control Systems. London: Springer, 2009: 225-247.
- [13] Zhang L, Li K, He H, et al. A new discrete-continuous algorithm for radial basis function networks construction[J]. IEEE Trans on Neural Networks and Learning Systems, 2013, 24(11): 1785-1798.
- [14] Rubio J. SOFMLS: Online self-organizing fuzzy modified least-squares network[J]. IEEE Trans on Fuzzy Systems, 2009, 17(6): 1296-1309.
- [15] 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, 18(6): 1129-1143.
- [16] Leng G, McGinnity T M, Prasad G. Design for self-organizing fuzzy neural networks based on genetic algorithms[J]. IEEE Trans on Fuzzy Systems, 2006, 14(6): 755-761.
- [17] Tzeng S T. Design of fuzzy wavelet neural networks using the GA approach for function approximation and system identification[J]. Fuzzy Sets and Systems, 2010, 161(19): 2585-2596.
- [18] Kuo R J, Hung S Y, Cheng W C. Application of an optimization artificial immune network and particle swarm optimization-based fuzzy neural network to an RFID-based positioning system[J]. Information Sciences, 2014, 262(20): 78-98.
- [19] Han H G, Li Y, Qiao J F. A fuzzy neural network approach for online fault detection in waste water treatment process[J]. Computers & Electrical Engineering, 2014, 40(7): 2216-2226.
- [20] Huang M, Wan J, Ma Y, et al. A fast predicting neural fuzzy model for on-line estimation of nutrient dynamics in an Anoxic/oxic process[J]. Bioresource Technology, 2010, 101(6): 1642-1651.
- [21] Dürrenmatt D J, Gujer W. Data-driven modeling approaches to support wastewater treatment plant operation[J]. Environmental Modelling & Software, 2012, 30(5): 47-56.
- [22] Hong S H, Lee M W, Lee D S. Monitoring of sequencing batch reactor for nitrogen and phosphorus removal using neural networks[J]. Biochemical Engineering J, 2007, 35(3): 365-370.
- [23] 胡康, 万金泉, 马邕文, 等. 基于模糊神经网络的A2/O工艺出水氨氮在线预测模型[J]. 中国环境科学, 2012, 32(2): 260-267. (Hu K, Wang J Q, Ma Y W, et al. Online prediction model based on fuzzy neural network for the effluent ammonia concentration of A2/O system[J]. China Environmental Science, 2012, 32(2): 260-267.)
- [24] Ebadzadeh M M, Salimi-Badr A. CFNN: Correlated fuzzy neural network[J]. Neurocomputing, 2015, 148(1): 430-444.
- [25] Chen J F, Hsieh H N, Do Q H. Forecasting hoabinh reservoir's incoming flow: An application of neural networks with the cuckoo search algorithm[J]. Information, 2014, 5(4): 570-586.
- [26] Nourani V, Baghanam A H, Gebremichael M. Investigating the ability of artificial neural network(ANN) models to estimate missing rain-gauge data[J]. J of Environmental Informatics, 2012, 19(1): 38-50.

(责任编辑: 闫妍)