

DOI:10.3969/j.issn.1673-4785.201305083

网络出版地址: <http://www.cnki.net/kcms/doi/10.3969/j.issn.1673-4785.201305083.html>

基于 MFOA 和 LW 的混沌时间序列鲁棒模糊预测

刘福才, 窦金梅, 王树恩

(燕山大学 电院工业计算机控制工程河北省重点实验室, 河北 秦皇岛 066004)

摘要:针对含有例外点的混沌时间序列的预测问题,提出了一种基于修正型果蝇优化算法(MFOA)和最小 Wilcoxon 方法(LW)的混合学习算法来训练 T-S 模糊模型,以达到准确建模和提高模型鲁棒性的目的。首先采用修正型果蝇优化算法优化模糊前件的高斯型隶属函数参数,利用其编程简单、收敛速度快的优点提高辨识精度和收敛速度。然后采用最小 Wilcoxon 方法辨识模型的结论参数,在训练数据中出现例外点时,LW 方法的强鲁棒性可以有效克服传统最小二乘方法对例外点敏感的缺点。最后以 Mackey-Glass 混沌时间序列的预测为例进行仿真研究,通过比较不同的优化算法的辨识结果来验证修正型果蝇优化算法的优越性,并在系统存在例外点的情况下验证了所提方法的有效性和鲁棒性。

关键词:修正型果蝇优化算法;最小 Wilcoxon 方法;例外点;Mackey-Glass 混沌时间序列;T-S 模糊模型;模糊预测

中图分类号: TP15 **文献标志码:** A **文章编号:** 1673-4785(2014)04-425-07

中文引用格式:刘福才,窦金梅,王树恩. 基于 MFOA 和 LW 的混沌时间序列鲁棒模糊预测[J]. 智能系统学报, 2014, 9(4): 425-431.

英文引用格式:LIU Fucui, DOU Jinmei, WANG Shu'en. Robust fuzzy prediction of the chaotic time series based on the MFOA and LW[J]. CAAI Transactions on Intelligent Systems, 2014, 9(4): 425-431.

Robust fuzzy prediction of the chaotic time series based on the MFOA and LW

LIU Fucui, DOU Jinmei, WANG Shu'en

(Key Laboratory of Industrial Computer Control Engineering of Hebei Province, Yanshan University, Qinhuangdao 066004, China)

Abstract: Focusing on the prediction of the chaotic time series containing outliers, a hybrid learning method based on the modified fruit fly optimization algorithm(MFOA) and the least Wilcoxon (LW) method is proposed in order to train the T-S fuzzy model. The purpose of this is to improve the accuracy and robustness of fuzzy modeling for nonlinear systems. Firstly, the MFOA is used to optimize the antecedent parameters of the Gaussian membership function with the advantages of ease of transformation of such a concept into program code and a high convergence speed, which can improve the identification accuracy and convergence speed in fuzzy modeling. Secondly, the least Wilcoxon method is applied to identify the consequential parameters of the model. When the outliers occur in the training data, the strong robustness of the LW with the outliers is effective for improving the sensitivity of the traditional least mean square method. Finally, a simulation experiment is conducted on the prediction of the Mackey-Glass chaotic time series, and the comparisons of the prediction results by different optimization methods are done to verify the superiority of the modified fruit fly optimization algorithm and in the case of outliers existing, the simulation results show the effectiveness and robustness of this proposed method.

Keywords: modified fruit fly optimization algorithm; least Wilcoxon method; outliers; Mackey-Glass chaotic time series; T-S fuzzy model; fuzzy prediction

混沌是一种出现在确定性系统中的貌似无序类

似随机的复杂现象。随着混沌理论研究的不断深入及其在通信信号处理、自动控制与电子对抗等领域中的广泛应用,混沌时间序列的建模与预测已成为混沌理论研究领域中一个非常重要且极为活跃的方

收稿日期:2013-05-31. 网络出版日期:2014-06-21.

基金项目:河北省自然科学基金资助项目(F2010001320).

通信作者:刘福才.E-mail: lfc@ysu.edu.cn.

向。模糊集合理论自 1965 年创建以来,已得到广泛研究,并在许多领域得到了应用。基于模糊系统的混沌时间序列预测已取得丰硕成果,如文献[1]中提出基于模糊树模型辨识混沌系统,文献[2]提出了一种模糊竞争学习算法的在线辨识方法来预测混沌动力系统,文献[3]提出一种鲁棒模糊聚类算法预测混沌时间序列,增强了模型的抗干扰能力。果蝇优化算法(fruit fly optimization algorithm, FOA)是一种新的元启发式算法[4],具有编程简单、全局优化、计算速度快等优点,目前在外贸出口预测[5]、企业经营业绩评估[6]、船舶操纵响应模型的辨识[7]等方面都得到很好的应用,将 FOA 应用于模糊模型的参数辨识是一个全新方向,为模糊辨识参数优化提供了一条新途径。最小 Wilcoxon (least Wilcoxon, LW)算法[8]可以在有例外点的情况下实现对线性系统的辨识,有较强的鲁棒性,其应用已被很多学者重视。如文献[9]基于最小 Wilcoxon T-S 模糊模型,对非线性函数进行逼近;文献[10]用神经网络和粒子群优化算法对非线性复杂系统进行了基于 LW 方法的鲁棒辨识;文献[11]中,用 W-范数和粒子群算法对前馈有源噪声系统进行鲁棒控制,改善了传统的 x 滤波最小均方误差(FxLMS)算法对扰动敏感的问题。针对混沌时间序列的建模与预测问题,考虑到上述方法结合的优点,本文提出了一种基于修正型果蝇优化算法(modified fruit fly optimization algorithm, MFOA)和 LW 的混合算法的模糊预测方法,分别用来优化模糊模型的前提和结论参数,实现对模型参数的全局优化。

1 模糊模型与参数优化编码

采用基于 T-S 模糊模型的混沌时间序列预测方法,一个模糊逼近器由数条模糊规则组成,T-S 模型的第 i 条规则描述为[12]

R^i : if x_1 is A_1^i and x_2 is A_2^i and \cdots and x_r is A_r^i ,

then $y^i = p_0^i + p_1^i x_1 + \cdots + p_r^i x_r$

式中: $i = 1, 2, \cdots, c$ 为第 i 条模糊规则, $x_j (j = 1, 2, \cdots, r)$ 是第 j 个输入变量, A_j^i 是一个模糊集合, y^i 是第 i 条规则的输出, p_j^i 是结论参数。

$f = [m_1^1 \ \sigma_1^1 \ \cdots \ m_1^c \ \sigma_1^c \ m_2^1 \ \sigma_2^1 \ \cdots \ m_2^c \ \sigma_2^c \ \cdots \ m_r^1 \ \sigma_r^1 \ \cdots \ m_r^c \ \sigma_r^c]$

式中: m 和 σ 分别为隶属函数的中心和宽度。 f 为 $2r \times c$ 维向量,此即优化参数的编码。

2 MFOA 与 LW 方法

2.1 修正型果蝇优化算法(MFOA)

FOA 是基于果蝇的觅食行为推演出寻求全局优化的新方法。作为一种昆虫,果蝇在感官知觉上,尤其是嗅觉和视觉上优于其他生物。果蝇的嗅觉器

前件模糊划分采用高斯型隶属函数:

$$A_j^i(x_j) = \exp\left(-\frac{(x_j - m_j^i)^2}{\sigma_j^i}\right)$$

式中: m_j^i 为隶属函数中心, σ_j^i 为隶属函数宽度,采用修正型果蝇优化算法优化高斯型隶属函数的参数 m_j^i 和 σ_j^i 。

那么由诸规则的输出 $y^i (i = 1, 2, \cdots, c)$ 可求出系统的总输出 \hat{y} 为

$$\hat{y} = \frac{\sum_{i=1}^c \mu_i y^i}{\sum_{i=1}^c \mu_i} = \frac{\sum_{i=1}^c w_i y^i}{\sum_{i=1}^c w_i} = \frac{\sum_{i=1}^c w_i (p_0^i + p_1^i x_1 + \cdots + p_r^i x_r)}{\sum_{i=1}^c w_i} \quad (1)$$

式中: $\mu_i = \prod_{j=1}^r A_j^i(x_j) (i = 1, 2, \cdots, c)$, 表示广义输入向量对应的第 i 条规则的权重, \prod 是模糊算子,通常采用取小运算或乘积运算,本文采用取小运算;

$w_i = \mu_i / \sum_{i=1}^c \mu_i$ 。

要对一个未知的目标系统建模,首先应该对未知系统的输入输出进行采样来得到一个输入输出数据集 $(u_k, y_k) (k = 1, 2, \cdots, K)$ 。通过观测到的数据, T-S 模糊系统能够逼近目标系统,模糊辨识的结构框图如图 1 所示,图中 $e_k = y_k - \hat{y}_k$ 。建模的均方根误差(root means square error, RMSE)可以表示为

$$\text{RMSE} = \sqrt{\frac{1}{K} \sum_{k=1}^K e_k^2}$$




图 1 模糊辨识的结构框图

Fig.1 Diagram of fuzzy identification

在一个模糊系统中,如果有 r 个输入变量, c 条模糊规则,那么对于 MFOA,食物在搜索空间的位置可由向量 f 表示:

$f = [m_1^1 \ \sigma_1^1 \ \cdots \ m_1^c \ \sigma_1^c \ m_2^1 \ \sigma_2^1 \ \cdots \ m_2^c \ \sigma_2^c \ \cdots \ m_r^1 \ \sigma_r^1 \ \cdots \ m_r^c \ \sigma_r^c]$

它能够搜索到漂浮在空气中的所有气味,甚至能够嗅到 40 km 外的食物源,在飞近食物的位置后又可以利用敏锐的视觉发现食物和同伴聚集位置,并飞向该方向[4]。

虽然 FOA 计算简单,易于编程和理解,但在随机初始化果蝇的位置距食物较远时,FOA 有可能不成熟收敛,容易陷入局部最优值。为了得到较 FOA 性能

更好的算法,文献[13]提出一种带逃离局部最优因子 β 的修正型果蝇优化算法(MFOA),它通过一种数学转换来扩展味道浓度值的分布,从而避免陷入局部最优,同时提高收敛速度,获得高质量的解。

基于果蝇搜寻食物的特点,MFOA主要有以下几个步骤^[13]:

1) 给定种群个体数目(sizepop)和最大迭代次数(maxgen),随机初始化果蝇的初始位置(IntiX_axis, IntiY_axis)。

2) 给出果蝇个体利用嗅觉搜寻食物的随机方向和距离(X_i, Y_i),如式(2)所示。

$$\begin{aligned} X_i &= \text{IntiX_axis} + \text{Random Value} \\ Y_i &= \text{IntiY_axis} + \text{Random Value} \end{aligned} \quad (2)$$

3) 估计果蝇与原点之间的距离(Dist_i),计算味道浓度判定值(S_{Mi})。

$$\begin{aligned} \text{Dist}_i &= (X_i^2 + Y_i^2)^{1/2} \\ S_{Mi} &= 1/\text{Dist}_i + \beta \end{aligned}$$

式中: β 为逃离局部最优因子,它的2种表达式如式(9)和(10)所示:

$$\beta = g \times \text{Dist}_i \quad (3)$$

$$\beta = \lambda \times \text{IntiX_axis or } \lambda \times \text{IntiY_axis} \quad (4)$$

式(3)中 g 为服从均匀分布的随机变量,式(4)说明 β 与群体的随机初始化相关, λ 是一个常数。

4) 将 S_{Mi} 代入味道浓度判定函数(Fitness function)求出该果蝇个体位置的味道浓度(Smell_i)。

$$\text{Smell}_i = \text{Function}(S_{Mi})$$

5) 找出此果蝇群体中味道浓度最高的果蝇。

$$[\text{bestSmell } \text{bestIndex}] = \max(\text{Smell}_i) \quad (5)$$

6) 保留最佳味道浓度值,最佳味道浓度判定值与相应果蝇 x, y 坐标,果蝇群体中其他果蝇利用视觉向该方向飞去。

$$\text{Smellbest} = \text{bestSmell}$$

$$\text{Sbest} = S_M(\text{bestIndex})$$

$$\text{IntiX_axis} = X(\text{bestIndex})$$

$$\text{IntiY_axis} = Y(\text{bestIndex})$$

7) 迭代寻优,重复执行2)~5),并判断味道浓度是否优于前一次迭代味道浓度,若是,则进入6)。

在MFOA算法中,以味道浓度值最大为迭代标准,所以将建模的均方根误差(RMSE)的倒数作为果蝇味道浓度判断函数,而得到的对应的最佳味道浓度判定值即作为参数的潜在最优解。所以,果蝇味道浓度判定函数为

$$\text{Function} = 1/(\text{RMSE} + \varepsilon) \quad (6)$$

式中: $\varepsilon = 10^{-10}$,用于避免零作为除数(RMSE为零时)。

2.2 最小 Wilcoxon 方法

W-范数考虑的是误差值的顺序或位置而不是其幅值。考虑向量 $\mathbf{v} = [v_1 v_2 \cdots v_l]$,其中 l 是向量的长度,那么 \mathbf{v} 的W-范数定义为^[8]

$$\|\mathbf{v}\|_w = \sum_{i=1}^l a(R(v_i))v_i = \sum_{i=1}^l a(i)v_{(i)}$$

式中: $R(v_i)$ 是 v_i 在向量 \mathbf{v} 中的顺序号。如果向量 \mathbf{v} 中的所有元素以升序排列,即 $v_{(1)} \leq v_{(2)} \leq \cdots \leq v_{(l)}$,那么 $R(v_i)$ 就是元素 v_i 的排列位置 i 。 $a(i)$ 是通过记号函数 $\varphi(t):[0,1] \rightarrow \mathbb{R}$ 定义的联合记号函数, $a(i) = \varphi(\frac{i}{l+1})$ 。 $\varphi(t)$ 满足

$$\int_0^1 \varphi^2(t) dt < \infty$$

文献[15]中给出了很多记号函数,这里选择最常用的一个,即

$$\varphi(t) = \sqrt{12}(t - 0.5) \quad (7)$$

由于Wilcoxon范数是基于统计参数的一个排序,所以在W-范数中,需要采用点或块的学习策略来计算一个排序。基于点的学习方法耗费时间,并且在实时应用中难于实现。然而,由于权值在每个输入样本块输入后就进行更新,所以基于块的学习方法速度更快。因此本文采用基于块的学习方法。

由式(1)可得出模糊系统的输出

$$\begin{aligned} \hat{y} &= \sum_{i=1}^c w_i(p_0^i + p_1^i x_1 + p_2^i x_2 + \cdots + p_r^i x_r) = \\ &[w_1 w_1 x_1 \cdots w_1 x_r \cdots w_c w_c x_1 \cdots w_c x_r] \times \\ &[p_0^1 p_1^1 \cdots p_r^1 \cdots p_0^c p_1^c \cdots p_r^c]^T \end{aligned}$$

将 K 对输入输出数据代入上式可得

$$\hat{\mathbf{Y}} = \mathbf{X}\mathbf{P} \quad (8)$$

式中: \mathbf{P} 是 $L = (r+1)c$ 维结论参数向量; \mathbf{Y}, \mathbf{X} 是 $K \times I, K \times L$ 的矩阵。

为了求出结论参数 \mathbf{P} ,这里应用LW方法来进行辨识。每次迭代的输入向量相同,权值不断更新,随着每次实验,权值达到收敛。

辨识误差向量为

$$\mathbf{E} = [e(1) \ e(2) \ \cdots \ e(K)]^T$$

式中:误差的第 k 个元素定义如下:

$$e(k) = y(k) - \hat{y}(k) \quad (9)$$

式中: $y(k)$ 是系统期望输出, $\hat{y}(k)$ 是模型输出。

式(9)用矩阵表示为

$$\mathbf{E} = \mathbf{Y} - \hat{\mathbf{Y}} \quad (10)$$

目标函数定义为

$$\psi = \|E\| = \sum_{k=1}^K s(k)e_k \quad (11)$$

式中: $s(k)$ 是通过记号函数 $\varphi(t):[0,1] \rightarrow R$ 定义的联合记号函数,记号函数的选择如式(7)所示。 e_k 表示的是将向量 E 中的值 $e(k)$ 按升序排列后的误差值:

$$e_k \leq e_{k+1}, 1 \leq k \leq K \quad (12)$$

当 $t = \frac{R\{e(k)\}}{K+1}$ 时, $s(k,l)$ 表示为

$$s(k) = \sqrt{12} \left(\frac{R\{e(k)\}}{K+1} - 0.5 \right) \quad (13)$$

式中: $R\{e(k)\}$ 表示 $e(k)$ 在向量 E 中的顺序号。

式(13)写成矩阵形式为

$$s = \sqrt{12} \left(\frac{R}{K+1} - 0.5 \right) \quad (14)$$

式中: R 表示 $R\{e(k)\}$ 在 $k=1,2,\dots,K$ 时所形成的一个矩阵。

结论参数 P 的更新公式可以写成

$$P = P + \Delta P \quad (15)$$

式中: $\Delta P = -\eta \frac{\partial \psi}{\partial P}$ 。 η 是调节自适应速度和稳定性的学习率因子。由式(8)、(10)~(12)、(14)可以求出 W -范数的梯度向量(ΔP)的估计,那么

$$\Delta P = \eta \frac{sX}{K} \quad (16)$$

式中 s, X 如前所述。

所以, LW 算法可以由等式(8)、(10)、(14)~(16)来完整描述。

2.3 MFOA-LW 混合算法

将 MFOA 和 LW 算法以一种组合的形式来训练含有例外点的 T-S 模糊模型。本文根据经验给定模糊规则数和输入变量,采用模糊网格对角线法划分前提结构^[14], MFOA 算法用来优化模型的前提参数(即隶属函数参数),果蝇寻找到的每一个最佳味道浓度判断值都是一个潜在的前提解。前提结构和参数确定以后,下一步工作就是用 LW 方法辨识结论参数。

MFOA-LW 混合学习算法辨识 T-S 模糊模型的学习步骤如下:

- 1) 由目标系统得到一组输入输出数据对;
- 2) 设计一个模糊逼近器(其中包括输入变量个数的选择和模糊规则数的确定,模糊空间的划分);
- 3) 随机初始化果蝇的初始位置,根据第 2.1 节中 MFOA 算法的步骤计算初始果蝇群体中最佳味

道浓度判定值,将其作为模糊模型的初始前提参数;

4) 输入训练数据集到图 1 所示的模糊逼近器,用 2.2 节的 LW 方法计算 T-S 模型结论参数 P ;

5) 用结论参数 P 和训练数据集计算模型的输出;

6) 用式(6)计算果蝇的味道浓度值(类似适应度函数),并根据式(5)得出果蝇最优味道浓度值及相应的判定值和果蝇相应位置,更新种群中果蝇的位置,根据第 2.1 节中 MFOA 算法的步骤计算此次迭代的最佳味道浓度判定值;

7) 返回到 4),直到满足终止条件(MFOA 算法迭代终止)。


3 仿真研究

自 1977 年 Mackey 和 Glass 发现时滞系统中的混沌现象^[15]以来,时滞混沌系统便引起了人们的广泛关注,并常常用其作为检验非线性系统模型性能的标准。应用本文的 MFOA-LW 方法对 Mackey-Glass 混沌时间序列进行建模与预测,以此来说明本文方法的有效性和鲁棒性。


Mackey-Glass 混沌时间序列用微分方程描述为

$$\frac{d(x(t))}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t) \quad (17)$$

此方程描述的是在正常呼吸和不正常呼吸时动脉的 CO_2 浓度,属于一类有混沌行为的时延方程。其中 τ 为时滞参数, $\tau \geq 17$ 时,方程(17)处于混沌状态,其分形维数近似为 2.1,并且 τ 值越大,混沌程度越高。图 2(a)和图 2(b)给出了 $\tau = 17$ 时的混沌时间序列及其相图,初始条件 $x(0) = 1.2$ 。本文中, $\tau = 17, a = 0.2, b = 0.1$ 。混沌时间序列预测的目标是用 t 时刻以前的值预测 $t+p$ 时刻的值。通常,取间隔为 Δ 的 D 个历史时刻的值,建立 $[x(t-(D-1)\Delta) \cdots x(t-\Delta) \ x(t)]^T$ 到 $x(t+p)$ 的映射关系。



(a) Mackey-Glass 混沌时间序列



(b) 系统相图

图 2 $\tau = 17$ 时 Mackey-Glass 时滞混沌系统

Fig.2 Mackey-Glass time delay chaotic system when $\tau = 17$

本文中取 $D = 3$, $\Delta = 1$, $p = 1$, 那么模型输入向量 X 为 $[x(t - 2) \ x(t - 1) \ x(t)]^T$, 输出 Y 为 $x(t + 1)$ 。 $x(0) - x(17)$ 赋初值为 1.2。在 $t = 117$ 和 $t = 617$ 之间采集 500 个数据作为建模数据。模糊划分数 $c = 4$ 。

MFOA 参数:最大迭代次数 $\text{maxgen} = 500$, 种群数目 $\text{sizepop} = 40$ 。随机初始化果蝇群体的位置区间为 $[0, 20]$, 迭代过程中果蝇搜寻食物的随机飞行方向与距离区间为 $[-5, 5]$, β 采用式(3)形式, 其中 g 定义为在 $[-0.5, 0.5]$ 上均匀分布的随机变量。

首先验证 MFOA 算法在辨识方面的优越性, 将 MFOA 算法的优化结果与粒子群算法 (PSO)、菌群优化算法 (BFO) 进行比较。分别采用 MFOA, PSO, BFO 优化模糊模型的前提参数, 递推最小二乘法 (RLS) 优化结论参数^[18]。本文所选参数均为相关文献常用参数。

PSO 算法参数为:学习因子 $c_1 = 1.496\ 2$, $c_2 = 1.496\ 2$; 惯性权重 $\omega = 0.729\ 8$; 最大迭代次数 $\text{Max } DT = 1\ 000$; 初始化群体个体数目 $N = 40$ 。

BFO 算法参数:种群数目 $S = 100$, 趋向性操作数 $N_e = 100$, 在同一方向上前进的最大限制步数 $N_s = 4$, 复制操作数 $N_{re} = 8$, 迁徙操作数 $N_{ed} = 2$, 细菌迁徙概率 $P_{ed} = 0.5$, 趋向性行为步长 $C(i) = 0.1$, 细菌间引力深度 $d_{\text{attractant}} = 0.01$, 引力宽度 $w_{\text{attractant}} = 0.2$, 斥力高度 $h_{\text{repellant}} = 0.01$, 斥力宽度 $w_{\text{repellant}} = 10$ 。


RLS 算法初始条件为: $P_0 = 0$, $S_0 = \alpha I$, α 是一个很大的实数, $0 < \alpha < \infty$, 本文取 $\alpha = 10^4$ 。

表 1 给出了 3 种优化算法的参数和仿真结果的 RMSE。图 3~5 分别给出仿真结果的逼近曲线和误差曲线。由仿真结果可以看出, 较其他算法相比, MFOA-RLS 算法辨识精度高, 计算量小, 能够有效预测混沌时间序列。


表 1 不同优化算法的建模结果 (RMSE)

Table 1 RMSE of different optimization algorithms

优化算法	种群规模	迭代次数	RMSE
PSO-RLS	40	1 000	0.002 8
BFO-RLS	40	1 600	0.002 4
MFOA-RLS	40	500	0.002 2




(a) 建模逼近曲线




(b) 建模误差曲线

图 3 MFOA-RLS 预测结果

Fig.3 Prediction result of MFOA-RLS




(a) 建模逼近曲线




(b) 建模误差曲线

图 4 PSO-RLS 预测结果

Fig.4 Prediction result of PSO-RLS



(a) 建模逼近曲线



(b) 建模误差曲线

图5 BFO-RLS 预测结果

Fig.5 Prediction result of BFO-RLS

为了检验 MFOA-LW 建模的鲁棒性,在建模数据集中加入一定比例的例外点;随机选取 $per\%$ 的建模数据对,输入保持不变,输出加上 $[-15, 15]$ 的均匀分布的随机数。为了充分体现 LW 方法的鲁棒性,不断地增加例外点的比例(0 ~ 50%)。LW 中,最大实验次数 $L_{\max} = 1\,500$,学习率 $\eta = 0.09$ 。为了表现本文方法的鲁棒性,仿真结果与 MFOA-RLS 方法进行比较。


表2给出了在建模数据集中加入不同比例的例外点时,2种方法的均方根误差,由于输入加入的是随机数,为了克服仿真结果的偶然性,每个结果均为20次仿真结果的平均值。

表2 含有不同比例例外点时,2种方法的预测误差(RMSE)

Table 2 RMSE of two methods with different proportions of outliers

方法	0	10%	20%	30%	40%	50%
MFOA-RLS	0.002 2	0.037 5	0.058 3	0.074 3	0.092 4	0.116 0
MFOA-LW	0.008 6	0.009 6	0.009 8	0.010 5	0.013 5	0.015 4

图3和图6分别为不包含例外点(0%)时 RLS 方法和 LW 方法的建模结果,图7和图8是含30%例外点时的建模结果。




(a) 建模曲线




(b) 误差曲线

图6 MFOA-LW 方法的建模结果(无例外点)

Fig.6 Modeling result of MOFA-LW (without outliers)




(a) 建模曲线




(b) 误差曲线

图7 MFOA-LW 方法的建模结果(30%例外点)

Fig.7 Modeling result of MOFA-LW (with 30% outliers)



(a) 建模曲线



(b) 误差曲线

图8 MFOA-RLS 方法的建模结果(30%例外点)

Fig.8 Modeling result of MOFA-RLS (with 30% outliers)

由以上的仿真结果可以看出,在含有例外点(10%~50%)时,MFOA-LW 方法明显地对例外点有较强的鲁棒性,建模精度高出一个数量级,能较准确地建立混沌时间序列的模糊预测模型。

4 结束语

针对混沌时间序列预测问题,本文提出了一种

基于MFOA-LW方法的鲁棒模糊预测算法。MFOA优化模型的前提参数,LW方法优化模型的结论参数,实现了模糊模型的全局优化。MFOA算法具有计算简单,容易编程,收敛速度快和成熟收敛等优点,应用在模糊模型辨识方面具有很大的优越性。最小Wilcoxon方法辨识模型具有鲁棒性,当训练数据中出现例外点时,LW方法仍然可以有效地辨识出模糊模型。为了检验所提方法的有效性,用本文方法对Mackey-Glass混沌时间序列进行了建模和预测,并与其他方法进行了比较。仿真结果表明,在系统不存在例外点时,采用MFOA-RLS方法的建模精度高于PSO-RLS、BFO-RLS等方法,这证明了MFOA的优越性;在系统存在例外点时,MFOA-LW方法辨识出的模型仍然具有较高的精度,可以满足辨识要求,但MFOA-RLS方法的辨识精度很低,根本无法有效地预测混沌时间序列,这充分验证了本文方法的鲁棒性,表明在存在例外点的情况下,这是一种有效的混沌时间序列预测方法,在复杂有干扰的非线性系统的研究中有较高的实用价值。

参考文献:

- [1] 毛剑琴,姚健,丁海山. 基于模糊树模型的混沌时间序列预测[J]. 物理学报, 2009, 58(4): 2220-2230.
MAO Jianqin, YAO Jian, DING Haishan. Chaotic time series prediction based on fuzzy tree[J]. Acta Physica Sinica, 2009, 58(4): 2220-2230.
- [2] 王宏伟,马广富. 基于模糊模型的混沌时间序列预测[J]. 物理学报, 2004, 53(10): 3293-3297.
WANG Hongwei, MA Guangfu. Prediction of chaotic time series based on fuzzy model[J]. Acta Physica Sinica, 2004, 53(10): 3293-3297.
- [3] 刘福才,张彦柳,陈超. 基于鲁棒模糊聚类的混沌时间序列预测[J]. 物理学报, 2008, 57(5): 2784-2790.
LIU Fucui, ZHANG Yyanliu, CHEN Chao. Prediction of chaotic time series based on robust fuzzy clustering[J]. Acta Physica Sinica, 2008, 57(5): 2784-2790.
- [4] PAN W T. A new fruit fly optimization algorithm: taking the financial distress model as an example [J]. Knowledge-Based Systems, 2012, 26(2): 69-74.
- [5] 许智慧,王福林,孙丹丹,等. 基于FOA-RBF神经网络的外贸出口预测[J]. 数学的实践与认识, 2012, 42(13): 14-19.
XU Zhihui, WANG Fulin, SUN Dandan, et al. A forecast of export trades based on the FOA-RBF neural network[J]. Mathematics in Practice and Theory, 2012, 42(13): 14-19.
- [6] 潘文超. 应用果蝇优化算法优化广义回归神经网络进行企业经营绩效评估[J]. 太原理工大学学报:社会科学版, 2011, 29(4): 1-5.
- [7] 王雪刚,邹早建. 基于果蝇优化算法的船舶操纵响应模型的辨识[J]. 大连海事大学学报:自然科学版, 2012, 38(3): 1-4, 8.
WANG Xuegang, ZOU Zaojian. Identification of ship manoeuvring response model based on fruit fly optimization algorithm[J]. Journal of Dalian Maritime University: Natural Science Edition, 2012, 38(3): 1-4, 8.
- [8] HOGG R V, MCKEAN J W, CRAIG A T. Introduction to mathematical statistics[M]. 6th ed. Englewood Cliffs, NJ: Prentice-Hall, 2005: 531-570.
- [9] SUN T Y, TSAI S J, TSAI C H. Nonlinear function approximation based on least Wilcoxon Takagi-Sugeno fuzzy model [C]//The Eighth International Conference on Intelligent Systems Design and Applications. Kaohsiung, China, 2008: 312-317.
- [10] MAJHI B, PANDA G. Robust identification of nonlinear complex systems using low complexity ANN and particle swarm optimization technique[J]. Expert Systems with Applications, 2010, 38(1): 321-333.
- [11] NITHIN V G, PANDA G. A robust evolutionary feedforward active noise control system using Wilcoxon norm and particle swarm optimization algorithm[J]. Expert Systems with Applications, 2012, 39: 7574-7580.
- [12] TAKAGI T, SUGENO M. Fuzzy Identification of system and its application on modeling and control [J]. IEEE Trans on Systems, Man and Cybernetics, 1985, 15(1): 116-132.
- [13] LI C Q, XU S P, LI W, et al. A novel modified fly optimization algorithm for designing the self-tuning proportional integral derivative controller [J]. Journal of Convergence Information Technology, 2012, 7(16): 69-77.
- [14] 刘福才. 非线性系统的模糊模型辨识及其应用[M]. 北京:国防工业出版社, 2006: 41-44.
- [15] MACKEY M C, GLASS L. Oscillation and chaos in physiological control systems[J]. Science, New Series, 1977, 197(4300): 287-289.

作者简介:



刘福才,男,1966年生,教授,博士生导师,主要研究方向为模糊辨识与预测控制、电力拖动及其计算机控制。发表学术论文160余篇,出版专著1部。