

文章编号:1672-3961(2024)01-0025-08 DOI:10.6040/j.issn.1672-3961.0.2022.383

基于粒子群算法的模糊大脑情感学习非线性系统辨识

孙园^{1,2}, 曾惠权^{1,2*}, 欧阳苏建^{1,2}, 高佳倩^{1,2}, 王绮楠^{1,2}, 林智勇^{1,2}

(1. 厦门理工学院电气工程与自动化学院, 福建 厦门 361024; 2. 厦门市高端电力装备及智能控制重点实验室, 福建 厦门 361024)

摘要:为提高神经网络模型在解决非线性系统辨识问题上的精度,提出一种基于粒子群算法的模糊大脑情感学习模型。该模型包含大脑情感学习网络,在利用系统历史数据对模型进行训练的基础上,通过适应度函数动态调整网络结构中的权重因子,提高网络学习效率和辨识精度。在对连续搅拌反应器系统辨识试验和对 $\sin E$ 强非线性对象逼近试验中,与常规模糊大脑情感学习模型、BP神经网络和RBF神经网络相比,本模型拥有更高的逼近能力和更快的收敛速度,解决了基于试错法导致的模型参数调整时间长、模型不稳定等问题,为辨识的实际应用提供了可行的模型选择。

关键词:粒子群算法;类脑神经网络;大脑模糊情感学习模型;神经网络系统辨识;非线性系统

中图分类号:TP183 文献标志码:A

引用格式:孙园,曾惠权,欧阳苏建,等. 基于粒子群算法的模糊大脑情感学习非线性系统辨识[J]. 山东大学学报(工学版), 2024, 54(1): 25-32.

SUN Yuan, ZENG Huiquan, OUYANG Sujian, et al. Nonlinear system identification based on fuzzy brain emotional learning with particle swarm algorithm[J]. Journal of Shandong University (Engineering Science), 2024, 54(1): 25-32.

Nonlinear system identification based on fuzzy brain emotional learning with particle swarm algorithm

SUN Yuan^{1,2}, ZENG Huiquan^{1,2*}, OUYANG Sujian^{1,2}, GAO Jiaqian^{1,2}, WANG Qinan^{1,2}, LIN Zhiyong^{1,2}

(1. School of Electrical Engineering & Automation, Xiamen University of Technology, Xiamen 361024, Fujian, China; 2. Xiamen Key Laboratory of Frontier Electric Power Equipment and Intelligent Control, Xiamen 361024, Fujian, China)

Abstract: A fuzzy brain emotional learning model based on particle swarm algorithm was proposed to improve the accuracy of neural network model in solving nonlinear system recognition problems. The model contained a brain emotional learning network, and based on the training of the model using the system historical data, the adaptation function made the dynamic adjustment of the weight factors in the network structure to improve the network learning efficiency and recognition accuracy. In the identification test of continuous stirred tank reactor and the approximation test of $\sin E$ strong nonlinear object, compared with the conventional fuzzy brain emotional learning model, BP neural network and RBF neural network, this model had higher approximation ability and faster convergence speed, and solved the problems of long adjustment time of model parameters and model instability caused by trial-and-error based method, which provided a feasible model for practical application of recognition.

Keywords: particle swarm algorithm; brain-like neural network; fuzzy brainemotional learning model; neural network system identification; nonlinear system

收稿日期:2022-11-15

基金项目:福建省自然科学基金资助项目(2020J01281);厦门市自然科学基金资助项目(3502Z20227215);厦门理工学院高层次人才科研启动项目(YKJ22060R);厦门理工学院研究生科技创新项目(YKJXC2021128)

第一作者简介:孙园(1981—),女,河南南阳人,副教授,硕士生导师,博士,主要研究方向为神经网络基础及应用。

E-mail: sungirl609@126.com

* 通信作者简介:曾惠权(1998—),男,广东惠州人,硕士研究生,主要研究方向为神经网络应用。E-mail: huiquanzeng@hotmail.com

0 引言

现实系统中含有大量的非线性因素,采用在工作点附近建立局部线性化模型的辨识方法易丢失系统的非线性特性^[1]。为解决复杂非线性系统辨识问题,利用神经网络和基于模糊系统改进的神经网络在一定程度上成为辨识与控制非线性系统的有效方法^[2-3],在燃料-电池混合动力系统^[4]、永磁同步电动机^[5]、风能转换系统^[6-7]、污水处理过程^[8]、电力储能系统^[9]等方面均有研究和应用。

模糊大脑情感学习(fuzzy brain emotional learning, FBEL)模型^[10]作为类脑神经网络的一种,在处理数据^[11]和作为控制器^[12]方面,具有较为突出的表现。眶额皮层和杏仁核层的权值参数是通过网络中的情绪奖励信号训练得到的,根据模型任务的不同,信号的形式设定为模型输入、模型输出和模型误差多种相关组合。为进一步提高模型性能,一些学者对网络结构中的奖励反馈信号加以改进,文献^[13]提出一种具有双向奖励信号的大脑情感学习神经网络,改善了原有网络中奖励信号仅有正面奖励的设定,构建了对六轴姿态飞行器的轨迹跟踪控制系统;文献^[14]则是在原有大脑情感学习模型的基础上删除了情绪奖励信号,并在丘脑结构内增加了径向基网络,构建了一种间接自适应脑情绪神经鲁棒控制器,在用于车辆跟随纵向控制系统的物理仿真中有良好表现。本研究在FBEL模型的基础上,通过引入粒子群(particle swarm optimization, PSO)算法^[15],在情绪奖励信号权重因子的优化设定上,构建了基于粒子群算法的模糊大脑情感学习模型(PSO-FBEL)。同时建立对连续搅拌反应器(continuous stirred tank reactor, CSTR)非线性系统辨识和 $\sin E$ 函数逼近2个仿真试验,将提出的模型与其他主流神经网络进行对比,验证了本模型的有效性,为解决神经网络非线性系统辨识问题提供了有效模型之一。

1 基于 PSO-FBEL 的非线性系统辨识

1.1 神经网络非线性系统辨识

本研究采用离线辨识的方法构建辨识模型,即通过系统历史输入输出数据,使得神经网络经过训练后逼近于系统模型,达到辨识目的。PSO-FBEL

模型对于一个 n 阶离散动态因果系统的辨识过程如图1所示。




图1 非线性系统辨识原理示意图

Fig.1 Schematic diagram of nonlinear system identification principle

假设 N_p 为结构已知、参数未知的 n 阶非线性系统, $u(k)$ 为系统输入,是一个稳定的有界函数。离线训练阶段如图1(a)所示,系统输入 $u(k)$ 和系统输出 $y(k)$ 将分别通过 n 阶时滞信道 $[Z^{-1}, Z^{-2}, \dots, Z^{-n}]$,产生相应的离散时延信号 $Z(u(k))$ 和 $Z(y(k))$,两者作为PSO-FBEL模型的输入,通过网络内层计算得到模型输出 \hat{y} ,与系统真实输出 y 作比较,产生辨识误差 $e(k)$,模型接收该误差反馈,利用自身的学习规则调整网络内部各层待学习参数,最终达到逼近非线性系统 N_p 的效果。

在模型测试验证阶段,如图1(b)所示,当模型可以逼近与所辨识的非线性系统时,其模型在一定程度上可以代替非线性系统内部机理,利用模型输出代替系统输出,使用系统输入和模型输出作为模型的输入,在允许的指标范围内,起到代替非线性系统的作用。

1.2 模糊大脑情感学习模型

模糊大脑情感学习模型^[10]的拓扑结构如图2所示。其功能模块具有6部分:输入空间、感觉皮层、丘脑、眶额皮层、杏仁核层、输出空间。 R 是丘脑产生的情绪刺激或强化刺激奖励信号,促进了网络学习过程,具体表示为

$$R = k_1 e + k_2 \hat{y},$$

式中: e 为模型误差, $e = y - \hat{y}$; y 为样本的真实值; \hat{y} 为

模型输出值; k_1 和 k_2 均为奖励信号权重因子。




图2 FBEL神经网络拓扑结构

Fig.2 Topological structure of FBEL neural network

(1) 感觉输入层。大脑网络通过该层将输入数据传入网络,层内部的神经单元接收感觉输入信号 X ,并将信号传递到感觉皮层。其中 $X=(X_1 \cdots X_i \cdots X_n) \in \mathbf{R}^n$, X_i 为第 i 个神经单元接收到的数据, n 为单个样本数据输入的维度。一般而言, n 决定了本层的神经单元数量,指定了 n 可以确定一个模型。

(2) 感觉皮层空间。此空间将感觉输入层的输出进行相应的模糊规划化处理。主要是指接收上层数据并进行 2 个区域的模糊化规则处理。

区域 1 为眶额皮质层模糊化。如果 X_1 为 S_{1j} , 且 X_2 为 S_{2j}, \dots , 且 X_n 为 S_{nj} , 则

$$O = \sum_{i=1}^n \sum_{j=1}^m S_{ij} w_{ij}, \quad (1)$$

式中: $i=1, 2, \dots, n$, n 为每个样本的输入数据维度数; $j=1, 2, \dots, m$, m 为神经元个数; O 为眶额皮质层的输出; S_{ij} 为第 i 个输入 X_i 对应的隶属模糊集语言值; w_{ij} 表示眶额皮质层权重。

区域 2 为杏仁核层模糊化。如果 X_1 为 S_{1j} , 且 X_2 为 S_{2j}, \dots , 且 X_n 为 S_{nj} , 则

$$A = \sum_{i=1}^n \sum_{j=1}^m S_{ij} v_{ij} + A_{th} V_{th}, \quad (2)$$

式中, A 为杏仁核层的输出, v_{ij} 为杏仁核层权重, A_{th} 表示丘脑信号, V_{th} 表示 A_{th} 传输到杏仁核时的连接权重。

设置高斯隶属模糊公式为:

$$G_{ij} = \exp\left[\frac{-(X_i - m_{ij})^2}{2\sigma_{ij}^2}\right], \quad (3)$$

式中, G_{ij} 代表第 i 个输入 X_i 对应的模糊集 S_{ij} , m_{ij} 和 σ_{ij} 是高斯函数的均值和方差。

(3) 丘脑与权值空间。从感觉皮层到杏仁核层,每个节点都有一个对应的连接权值 V , $V=(v_{11} \cdots v_{ij} \cdots v_{mm})^T \in \mathbf{R}^{mm}$;从感觉皮层到眶额皮质系统,每个节点对应的连接权值为 W , $W=(w_{11} \cdots w_{ij} \cdots w_{mm})^T \in \mathbf{R}^{mm}$ 。此外,丘脑接收的最大输入信号直接输入到杏仁核,称为丘脑信号 A_{th} ,公式表示为:

$$A_{th} = \max(G_{ij}). \quad (4)$$

(4) 眶额皮质层。眶额皮质层节点接收到的信号主要来自感觉皮层的刺激信号 G_{ij} 。因此,眶额皮层的输出

$$O = \sum_{i=1}^n \sum_{j=1}^m G_{ij} w_{ij}. \quad (5)$$

(5) 杏仁核层。杏仁核接受来自感觉皮层的刺激信号 G_{ij} 和丘脑信号 A_{th} ,且丘脑信号经过丘脑权值 V_{th} ,最终杏仁核的输出

$$A = \sum_{i=1}^n \sum_{j=1}^m G_{ij} v_{ij} + A_{th} V_{th}. \quad (6)$$

(6) 输出空间。 \hat{y} 是模糊大脑情感学习神经网络的输出,公式表示为:

$$\hat{y} = A - O. \quad (7)$$

1.3 模型参数自学习规则

模型使用的模糊大脑情感学习神经网络,内部各层的学习过程是依据规则的动态自学习过程。其中杏仁核层和眶额皮质层两部分的学习过程主要是对杏仁核层权值 V 和眶额皮质层权值 W 进行学习更新,更新公式^[11]为:

$$\Delta v_{ij} = \eta_v (G_{ij} \max(0, R - A)), \quad (8)$$

$$\Delta w_{ij} = \eta_w (G_{ij} (A - O - A_{th} V_{th} - R)), \quad (9)$$

$$R = k_1 e + k_2 \hat{y}, \quad (10)$$

式中: η_v 和 η_w 分别为更新权值 V 和 W 的学习速率,是影响学习速度的关键因素; R 是情绪刺激或强化刺激的奖励信号,促进了杏仁核学习过程的进行;辨识误差 $e = y - \hat{y}$, y 为样本数据的真实值, \hat{y} 为模型的辨识输出值; k_1 和 k_2 均为奖励信号权重因子。

高斯函数中均值 m_{ij} 和方差 σ_{ij} 的更新规则采用梯度下降法,更新公式为:

$$m_{ij}(i+1) = m_{ij}(i) + \Delta m_{ij}(i) = m_{ij}(i) - \eta_m \frac{\partial E}{\partial m_{ij}}, \quad (11)$$

$$\sigma_{ij}(i+1) = \sigma_{ij}(i) + \Delta \sigma_{ij}(i) = \sigma_{ij}(i) - \eta_\sigma \frac{\partial E}{\partial \sigma_{ij}}, \quad (12)$$

式中: $i=1, 2, \dots, n$, 代表输入数据中的第 i 组; 损失函数 $E(i) = \frac{1}{2} e^2(i) = \frac{1}{2} (y(i) - \hat{y}(i))^2$; η_m 、 η_σ 是 m_{ij} 和 σ_{ij} 的学习率, 决定参数更新的步长。

Δm_{ij} 和 $\Delta \sigma_{ij}$ 的具体推导过程为:

$$\Delta m_{ij} = -\eta_m \frac{\partial E_0}{\partial m_{ij}} = -\eta_m \frac{\partial E_0}{\partial e} \frac{\partial e}{\partial \hat{y}} \frac{\partial \hat{y}}{\partial G_{ij}} \frac{\partial G_{ij}}{\partial m_{ij}} =$$

$$\eta_m \cdot e \cdot (v_{ij} - w_{ij}) \cdot G_{ij} \cdot \frac{2(X_i - m_{ij})}{\sigma_{ij}^2}, \quad (13)$$

$$\Delta\sigma_{ij} = -\eta_\sigma \frac{\partial E_0}{\partial \sigma_{ij}} = -\eta_\sigma \frac{\partial E_0}{\partial e} \frac{\partial e}{\partial \hat{y}} \frac{\partial \hat{y}}{\partial G_{ij}} \frac{\partial G_{ij}}{\partial \sigma_{ij}} = \eta_\sigma \cdot e \cdot (v_{ij} - w_{ij}) \cdot G_{ij} \cdot \frac{2(X_i - m_{ij})^2}{\sigma_{ij}^3}. \quad (14)$$

1.4 PSO-FBEL 非线性系统辨识算法实现

在本研究中, PSO 优化 FBEL 模型的实质在于优化权重因子 k_1 、 k_2 的设定, 利用适应度函数产生每个粒子的适应度值, 通过最小化全局适应度值, 动态调整 k_1 、 k_2 , 从而得到合适的奖励信号权重因子。PSO-FBEL 非线性系统辨识流程如图 3 所示。

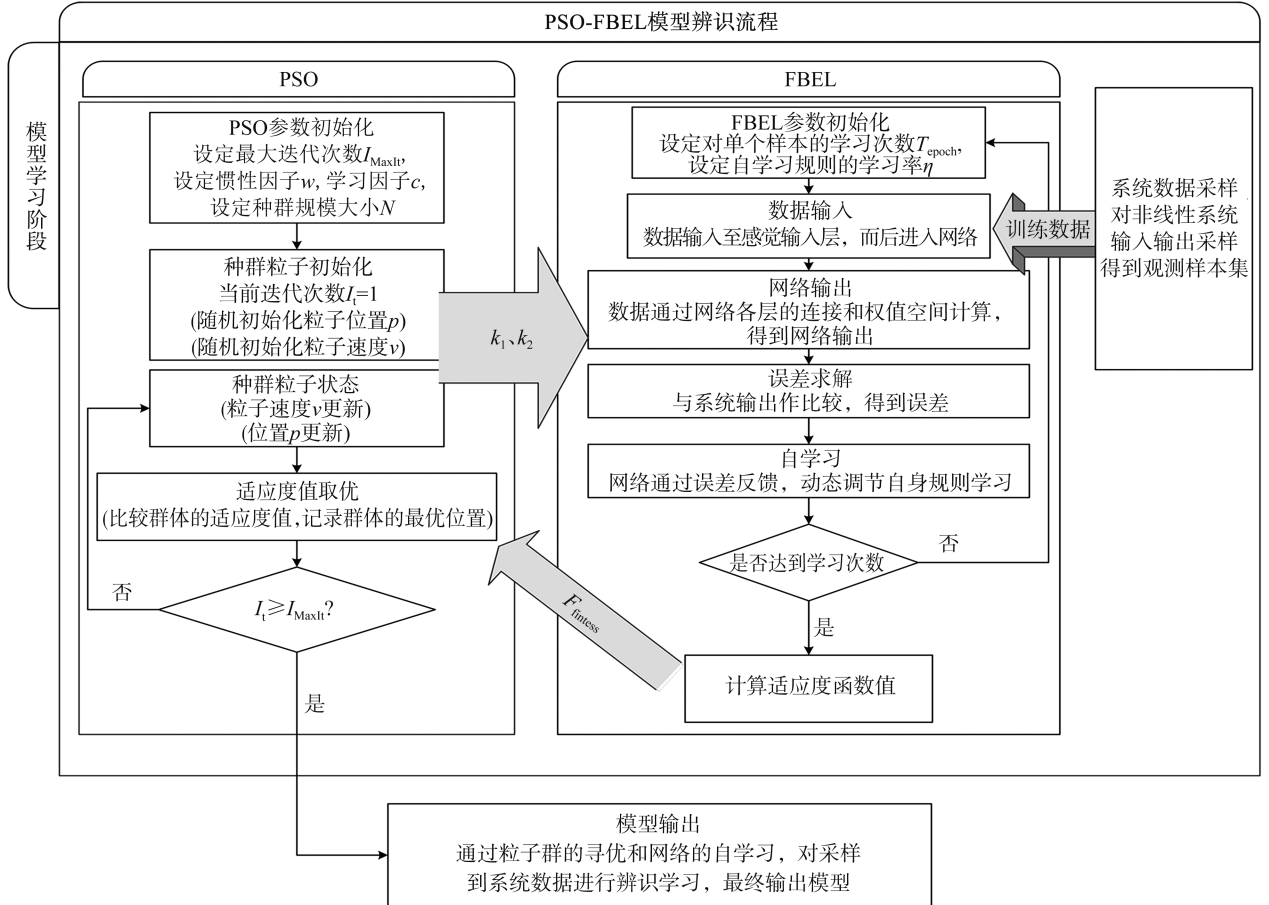


图 3 PSO-FBEL 非线性系统辨识模型整体流程示意图

Fig.3 Schematic diagram of the overall process of PSO-FBEL nonlinear system identification model

本模型对非线性系统辨识的具体步骤如下。

步骤 1: 模型参数初始化。分别初始化 PSO 和 FBEL 神经网络的各项参数。给定种群规模 N , 对应产生了规模为 N 的粒子种群, 每一个粒子的位置可以表示为 $O_l^i (i = 1, 2, \dots, N; l = 1, 2, \dots, M)$, 其中 O_l^i 代表种群中的第 i 个粒子, M 为粒子搜索空间的维度数, $M = 2$ 对应本研究中待优化的参数数量。给定种群迭代进化的最大次数 I_{MaxIt} 和速度惯性因子 w 、个体学习因子 c_1 、种群学习因子 c_2 ; 给定粒子的初始位置 $O_l^1 = k_1, O_l^2 = k_2$ 和初始速度 v_1, v_2 ; 同时给定 FBEL 神经网络中的样本学习次数 T_{epoch} 和训练学习率 η 。

步骤 2: 通过粒子群参数初始化, 粒子在限定的搜索空间内随机生成, 相当于设定了 FBEL 神经网络中奖励信号 R 的权重因子。将训练样本组的输

入数据代入 FBEL 神经网络, 网络通过各层的连接和权值空间计算, 得到网络训练辨识输出, 将网络辨识输出与真实系统输出作比较, 产生训练辨识误差, 由网络各层动态调整自身权值参数, 重复 T_{epoch} 次。在网络达到规定的样本学习次数 T_{epoch} 后, 将网络对当前样本组的训练辨识输出与系统训练样本组的真实输出作比较, 产生由当前种群粒子位置对应的适应度函数值。模型在训练过程中, 通过粒子群算法中的适应度函数对模型参数 k_1, k_2 的取值进行更新, 通过极小化适应度函数, 来得到最终的 k_1, k_2 。算法整体分为两部分, 即 PSO 和 FBEL, 在给当前的 k_1, k_2 下, 产生当前的适应度函数值, 后由 PSO 算法更新 k_1, k_2 , 由此得到多个适应度函数值, 最终选取适应度函数值最小的模型参数作为最终的准确模型。

步骤 3: 在种群进化达到最大进化迭代次数 I_{MaxIt} 前, 粒子通过速度的变化更新粒子的位置, 由此对 k_1 、 k_2 进行动态调整, 而粒子的速度会受到速度惯性因子 w 、个体学习因子 c_1 、种群学习因子 c_2 的综合影响, 进而产生合适的速度变化。在种群迭代进化过程中, 记录每次迭代产生的最优适应度值, 在种群结束进化迭代后, 输出最小适应度值对应的模型。

粒子的特征由其位置、速度、适应度函数值表示。粒子在搜索空间中的每个位置都是问题的潜在最优解, 当粒子的速度过大或过小都将影响寻优结果, 过小会导致种群迭代进化速度慢, 过大会使得粒子在搜索过程中越过最优值, 故需要对粒子 O_i 的搜索速度加以限定: $v_1 \in V_1, v_2 \in V_2$; 同时为避免粒子的盲目搜索, 限定了其搜索的位置范围, $O_i^1 \in D_1, O_i^2 \in D_2$ 。适应度函数用于选取种群在搜索空间中的最优位置, 对于辨识系统而言, 定义适应度函数为均方根误差 E_{RMSE} (root mean squared error, RMSE) [16], 计算公式为:

$$E_{\text{RMSE}} = \sqrt{\frac{1}{K} \sum_{k=1}^K (y(k) - \hat{y}(k))^2}, \quad (15)$$

式中, k 为对非线性系统进行离散采样得到的第 k 个样本组, K 为总的样本组数, $y(k)$ 表示系统第 k 个采样样本组的系统真实输出, $\hat{y}(k)$ 为模型的辨识输出。由式(15)可知, 适应度函数值减小, 对应于模型训练产生的辨识精度提高。

2 仿真验证及结果分析

本研究选取 2 个非线性对象作为仿真实例: (1) CSTR 非线性系统辨识; (2) $\sin E$ 强非线性函数逼近。试验仿真环境如下: CPU 处理器为 11th Gen Intel(R) Core(TM) i7-11800H@ 2.30 GHz; RAM 内存 40.0 GB; 操作系统为 64 位 Windows11 操作系统。

2.1 CSTR 系统

选取 CSTR 系统作为待辨识系统。CSTR 系统是现代化工生产不可或缺的主要设备之一, 其内部的化工生产过程具有很强的非线性。在实际化工生产中, 用以描述其系统的非线性微分方程为 [17]:

$$\dot{C}_a(t) = \frac{q}{v} (C_{a0} - C_a(t)) - k_0 C_a(t) e^{-\frac{E}{RT(t)}}, \quad (16)$$

$$\begin{aligned} \dot{T}(t) = & \frac{q}{v} (T_0 - T(t)) + \frac{(-\Delta H) k_0}{\rho C_p} C_a(t) e^{-\frac{E}{RT(t)}} + \\ & \frac{\rho_c C_{pc}}{\rho C_p v} q_c(t) [1 - e^{-\frac{h_a}{\rho_c C_{pc} RT(t)}}] (T_{co} - T(t)), \quad (17) \end{aligned}$$

式中, q 为进料流量, v 为反应釜容积, k_0 为反应速

率常数, E/R 为活化能量, T_0 为进料温度, T_{co} 为冷却剂温度, $-\Delta H$ 为反应热量, h_a 为导热系数, ρ 、 ρ_c 为液体密度, C_p 、 C_{pc} 为比热容。

反应釜的生产过程一般通过操纵冷却剂流量 q_c 改变反应温度 T , 从而控制生产物平衡浓度 C_a 。通过对式(16)(17)进行每间隔 0.1 min 的离散化采样, 生成 CSTR 系统共计 7 500 组生产数据 [18], 输入输出数据如图 4 所示, 分别为冷却剂流量 q_c 、生产物平衡浓度 C_a 和反应温度 T 。




图 4 CSTR 系统采样样本数据集
Fig.4 CSTR system sampling sample data set

通过对 CSTR 系统结构和工作原理的分析, 本研究选取系统的操纵变量 q_c 和输出变量 C_a 作为系统相关变量, 建立辨识结构公式为:


$$\hat{y}(k+1) = f(q_c(k), C_a(k)). \quad (18)$$

本研究利用图 4 中前 5 000 组作为训练数据, 用以模型学习以逼近系统真实输入输出映射关系, 并将余下的 2 500 组作为测试数据, 用以检验模型性能。试验初期, 设定 PSO-FEBL 辨识模型的初始化参数如表 1 所示。


表1 PSO-FBEL 模型参数设定
Table 1 PSO-FBEL model parameter settings

参数	I_{MaxIt}	w	c_1	c_2	N	k_1	k_2	
设定值	20	[0.4, 0.9]	1	2	50	(10, 100)	(0, 1)	
参数	v_1	v_2	V_1	V_2	D_1	D_2	T_{epoch}	η
设定值	0	0	[-10, 10]	[-1, 1]	[0, 100]	[0, 5]	2 000	0.000 1


图5(a)、图5(b)展示了粒子群在进化过程中,对于奖励信号权重因子 k_1 、 k_2 的迭代寻优变化曲线,由于种群粒子搜索出的 k_1 、 k_2 恰当,使得适应度函数值逐渐减小,图5(c)展示了在20次种群迭代进化过程中适应度函数值的变化。



(a) 奖励信号 k_1 迭代寻优曲线



(b) 奖励信号 k_2 迭代寻优曲线




(c) 适应度值迭代变化曲线

图5 粒子群进化过程曲线


Fig.5 Particle swarm evolutionary process curve

将本研究提出的 PSO-FBEL 模型与常规 FBEL 模型进行对比。图6(a)展示了两者模型在经过200次样本训练时的收敛曲线,可以看出,引入 PSO 算法的 FBEL 模型具有更快的收敛速度。图6(b)和图6(c)分别为 FBEL 模型和本模型对2500组测试数据得到的辨识误差曲线,可看出本模型的整体误差范围更小,最大误差出现在第157组,为0.0026,低于 FBEL 模型的最大误差0.0067。图6(d)和图6(e)分别为两者模型对于测试样本组的辨识输出曲线,从两者对于第100组数据至第200组的辨


识效果可以看出,PSO-FBEL 模型的拟合效果更好,辨识精度更高,证明了本算法的优越性。引入式(16)所表示的 E_{RMSE} 作为检验指标,表2列出了 FBEL 模型和 PSO-FBEL 模型的辨识精度,可以看出本模型的均方根误差较小,精度优于 FBEL。




(a) 训练迭代收敛曲线



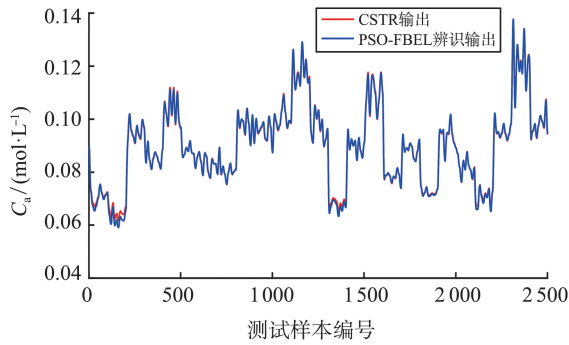
(b) FBEL 辨识误差曲线



(c) PSO-FBEL辨识误差曲线



(d) FBEL辨识输出曲线



(e) PSO-FBEL辨识输出曲线

图 6 FBEL 模型与 PSO-FBEL 模型的辨识效果对比

Fig.6 Comparison of FBEL network and PSO-FBEL model for system identification

表 2 2 种神经网络模型的辨识精度结果对比

Table 2 Comparison of recognition accuracy results of two neural network models


神经网络(模型)	E_{RMSE}
FBEL	7.87×10^{-4}
PSO-FBEL	4.05×10^{-4}

2.2 强非线性函数逼近

取“ $\sin E$ ”函数作为待逼近的非线性函数,该函数作为神经网络非线性系统辨识的基准问题,常用于测试网络模型性能,其具备较强的非线性性质,定义^[19]为:

$$y = 0.8 \sin(10x) \exp(-0.2x)。 \quad (19)$$

该函数进行离散化采样,令 x 分布于 $[0, 2]$, 产生共计 500 组样本数据,随机选取其中 300 组作为训练样本用于网络模型训练,另外 200 组用作测试样本组。在与常规 FBEL 神经网络作对比的同时,一并与主流的反向传播(back propagation, BP)、径向基函数(radial basis function, RBF)网络作比较,设置 4 种网络的训练次数均为 200 次;得到 4 种模型的逼近效果如图 7(a)所示,对应得到的逼近误差如图 7(b)所示,可以看出,PSO-FBEL 的总体逼近误差更小,模型性能更为优越。



(a) 逼近曲线

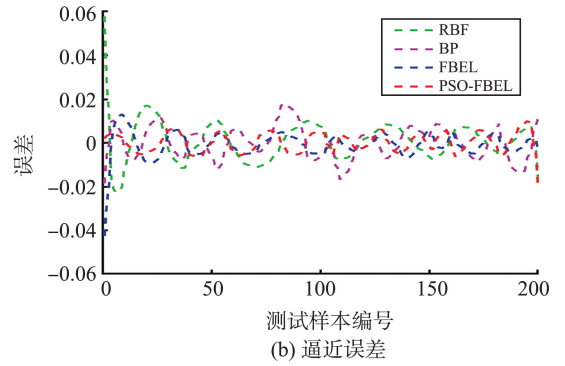


图 7 4 种模型对于 $\sin E$ 函数的逼近效果对比

Fig.7 Comparison of the approximation effect of four models for $\sin E$ function

与实例 1 相同,使用均方根误差 E_{RMSE} 作为逼近精度指标,得到了 4 种模型对于测试样本组的逼近精度,结果如表 3 所示,本研究构建的 PSO-FBEL 模型均方根误差为 0.004 3,与 FBEL 模型相比,精度高 34.8%;相较于 RBF 神经网络精度提高 0.004 9;相较于 BP 神经网络精度提高 0.003 2。

表 3 4 种神经网络模型逼近精度结果对比

Table 3 Comparison of approximation accuracy results of four neural network models

神经网络(模型)	E_{RMSE}
RBF	0.009 2
BP	0.007 5
FBEL	0.005 8
PSO-FBEL	0.004 3

在 2 个实例中,由于两者的输出数值数量级不同,造成了两者在辨识精度数量级上的差异,但在 2 个实例的试验中,设置了相同的训练参数,验证了 PSO-FBEL 模型在非线性系统辨识应用上的优越性。算法辨识精度的提升依赖于算法复杂度,本研究所提出的 PSO-FBEL 模型由于增加了粒子群对于 FBEL 模型参数的优化过程,在精度提升的同时增加了模型复杂度,在第 2 个实例中,本研究的 PSO-FBEL 算法训练时间为 130 s,FBEL 算法训练时间为 8 s,BP 算法训练时间为 6 s,RBF 算法训练时间为 5 s,其中,训练时间的差异与试验硬件、模型参数量和算法结构有关;在模型完成训练后,模型测试的时间差异减小,PSO-FBEL 算法测试时间为 0.079 s,FBEL 算法测试时间为 0.076 s,BP 算法测试时间为 0.067 s,RBF 算法测试时间为 0.061 s。

3 结论

本研究构建了 PSO-FBEL 模型,用于非线性系统辨识问题。该模型通过引入粒子群算法,以搜索迭代的方式,优化了 FBEL 模型的权重因子选定,减

少由人工设定随机性带来的模型性能损耗。仿真试验选取了2个实例,一是CSTR非线性系统实例,利用系统历史数据对模型进行训练与测试,测试结果表明,在CSTR系统辨识试验中,本模型较常规的FBEL模型拥有更快的收敛速度和更高的辨识精度,对于提高CSTR系统的生产效率有借鉴意义;二是 $\sin E$ 辨识基准函数实例,与FBEL模型、BP神经网络和RBF神经网络相比较,PSO-FBEL模型有更强的逼近能力,表明了所提出的模型有较广的适应性,为复杂非线性系统建模提供一种有效的辨识方法。

参考文献:

- [1] 伊泽曼·R, 明奇霍夫·M. 动态系统辨识: 导论与应用[M]. 机械工业出版社, 2016.
- [2] 张剑, 林瑞昌, 毕天昊. 一种用于非线性动态辨识的新型神经网络[J/OL]. 控制工程. (2022-07-26) [2023-09-11]. <https://doi.org/10.14107/j.cnki.kzgc.20220102>.
- [3] PAULO V D C S. Fuzzy neural networks and neuro-fuzzy networks: a review the main techniques and applications used in the literature[J]. Applied Soft Computing, 2020, 92: 106275.
- [4] GUO Xiaokai, YAN Xianguo. Optimization analysis of hydrog-en fuel cell hybrid power based on neural network and sensor networks[C]//2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS). Madurai, India; IEEE, 2021: 172-175.
- [5] HE H, LIU Y, BA L. A nonlinear dynamic model of fly-wheel energy storage systems based on alternative concept of back propagation neural networks[J]. Journal of Computational and Nonlinear Dynamics, 2022, 17(9): 091006.
- [6] MARUGÁN A P, MÁRQUEZ F P G, PEREZ J M P, et al. A survey of artificial neural network in wind energy systems[J]. Applied Energy, 2018, 228: 1822-1836.
- [7] KARABACAK K, CETIN N. Artificial neural networks for controlling wind-PV power systems: a review[J]. Renewable and Sustainable Energy Reviews, 2014, 29: 804-827.
- [8] QIAO Junfei, HOU Ying, ZHANG Lu, et al. Adaptive fuzzy neural network control of wastewater treatment process with multiobjective operation[J]. Neurocomputing, 2018, 275: 383-393.
- [9] LEE H J, JHANG S S, YU W K, et al. Artificial neural network control of battery energy storage system to damp-out inter-area oscillations in power systems[J]. Energies, 2019, 12(17): 3372.
- [10] LIN C M, CHUNG C C. Fuzzy brain emotional learning control system design for nonlinear systems[J]. International Journal of Fuzzy Systems, 2015, 17(2): 117-128.
- [11] SUN Y, LIN C M. A fuzzy brain emotional learning classifier design and application in medical diagnosis[J]. Acta Polytechnica Hungarica, 2019, 16(4): 27-43.
- [12] BRAZ-CÉSAR M T, GONÇALVES J, COELHO J P, et al. Development of a brain emotional learning based controller for application to vibration control of a building structure under seismic excitation[C]//COMP-DYN 2019 7th ECCOMAS Thematic Conference on Computational Methods in Structural Dynamics and Earthquake Engineering. Crete, Greece; ECCOMAS, 2019: 3473-3481.
- [13] MUTHUSAMY P K, GARRATT M, POTA H, et al. Real-time adaptive intelligent control system for quad-copter unmanned aerial vehicles with payload uncertainties[J]. IEEE Transactions on Industrial Electronics, 2021, 69(2): 1641-1653.
- [14] 魏民祥, 杨佳伟, 陈凯, 等. 基于改进大脑情感学习模型的车辆纵向跟随研究[J]. 吉林大学学报(工学版), 2022, 52(12): 2994-3005.
WEI Minxiang, YANG Jiawei, CHEN Kai, et al. Research on vehicle longitudinal following based on improved brain emotional learning model[J]. Journal of Jilin University (Engineering Edition), 2022, 52(12): 2994-3005.
- [15] KENNEDY J, EBERHART R. Particle swarm optimization[C]//Proceedings of ICNN'95-international Conference on Neural Networks. Perth, Australia; IEEE, 1995, 4: 1942-1948.
- [16] LIN C M, LE T L, HUYNH T T. Self-evolving function-link interval type-2 fuzzy neural network for nonlinear system identification and control[J]. Neurocomputing, 2018, 275: 2239-2250.
- [17] LIGHTBODY G, IRWIN G W. Nonlinear control structures based on embedded neural system models[J]. IEEE Transactions on Neural Networks, 1997, 8(3): 553-567.
- [18] DE M B, DE G P, DE S B, et al. DAISY: a database for identification of systems[R]. K U LeuvenBE; Department of Electrical Engineering (ESAT), 1997.
- [19] QIAO J F, MENG X, LI W J. An incremental neuronal-activity-based RBF neural network for nonlinear system modeling[J]. Neurocomputing, 2018, 302: 1-11.

(编辑:郭少华)