

引用格式:王慧芬,张艳兵,孙志瑞,等.转盘跟踪试验系统的控制策略研究[J].电光与控制,2020,27(4):68-72. WANG H F, ZHANG Y B, SUN Z R, et al. On control strategy of turntable tracking test system[J]. Electronics Optics & Control, 2020, 27(4):68-72.

转盘跟踪试验系统的控制策略研究

王慧芬^a, 张艳兵^b, 孙志瑞^a, 高夏翔^a

(中北大学, a. 电气与控制工程学院; b. 电子测试技术国家重点实验室, 太原 030051)

摘要: 为创建精确、稳定的试件二维加速度过载环境,提高对转盘跟踪试验系统的控制精度,对系统矢量转盘进行建模,采用自适应混沌蚁群优化的RBF神经网络PID控制器,解决RBF神经网络权值优化较慢的问题,有效缩短神经网络学习时间,提高PID控制器的在线自适应能力,使转盘跟踪试验系统快速跟踪目标。仿真结果表明:自适应混沌蚁群优化的RBF神经网络PID控制器优于传统的RBF神经网络PID控制器,具有很好的准确性和快速性,对于转盘跟踪试验系统设计具有较大的工程意义。

关键词: 伺服控制; 转盘跟踪试验系统; 自适应混沌蚁群优化算法; 径向基神经网络

中图分类号: TP273

文献标志码: A

开放科学(资源服务)标识码(OSID):

doi:10.3969/j.issn.1671-637X.2020.04.013



On Control Strategy of Turntable Tracking Test System

WANG Huifen^a, ZHANG Yanbing^b, SUN Zhirui^a, GAO Xiexiang^a

(North University of China, a. School of Electrical and Control Engineering;

b. National Key Laboratory of Electronic Measurement Technology, Taiyuan 030051, China)

Abstract: In order to create an accurate and stable two-dimensional acceleration overload environment for the test pieces and improve the control precision of the turntable tracking test system, the vector turntable is modeled. The PID controller based on the RBF neural network optimized by the adaptive chaotic ant colony algorithm is used, to solve the problem that the optimization of the weight of the RBF neural network is very slow, to effectively shorten the learning process of the neural network, and to improve the online adaptive ability of the PID controller, thus to enable the turntable tracking test system to rapidly track the target. The simulation results show that the PID controller based on the RBF neural network optimized by the adaptive chaotic ant colony algorithm is superior to that based on the traditional RBF neural network, and has satisfying accuracy and rapidity. It has great engineering significance for the design of the turntable tracking test system.

Key words: servo control; turntable tracking test system; adaptive chaotic ant colony algorithm; radial basis neural network

0 引言

飞行器的加速度过载是衡量其作战能力的重要指标之一^[1],常用离心机做飞行器过载半实物仿真模拟试验,但一般的离心机不能提供试件在实际使用过程中快速变化的二维动态加速度过载环境^[2]。因此,本文在离心机的基础上,使用伺服电机对矢量转盘进行高性能位置调节,以保证转盘精确跟踪目标轨迹,为试件提供所需的加速度环境^[3]。

转盘跟踪试验系统基于传统PID控制器,易受到内部参数变化和外界环境的影响,控制稳定性较差^[4]。文献[5]采用BP神经网络对PID进行整定,但由于BP神经网络结构复杂、训练速度慢而很难满足实时控制的要求。径向基函数(Radial Basis Function, RBF)神经网络结构简单、数学基础扎实,具有较强的自学习能力^[6-7],但RBF神经网络权值优化较慢,蚁群算法对初值和参数选择不敏感、鲁棒性强^[8],在组合优化中取得广泛的应用^[9],但该算法搜索时间长,易出现停滞。

本文针对转盘跟踪试验系统跟踪目标轨迹误差较大的问题,采用了自适应混沌蚁群优化的RBF神经网络PID控制策略,具备神经网络的广泛映射能力,同时还具有混沌蚁群算法的快速全局收敛特点,可以补偿

收稿日期:2019-05-08

修回日期:2019-05-27

基金项目:国家部委资助项目(A32010);重点实验室基金(C120401)

作者简介:王慧芬(1994—),女,山西晋城人,硕士生,研究方向为智能控制。

系统非线性以及参数摄动对控制性能的影响,达到提高转盘跟踪试验系统的响应速度和控制精度的目的。

1 转盘跟踪试验系统的结构及模型

1.1 转盘跟踪试验系统的结构

转盘跟踪试验系统结构如图1所示。

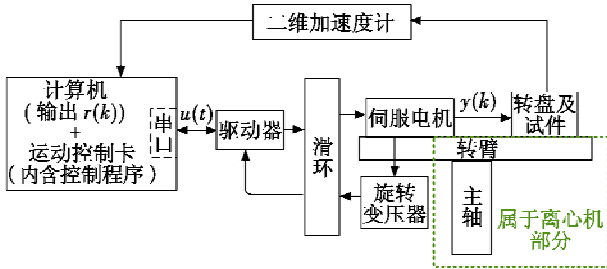


图1 转盘跟踪试验系统结构图

Fig.1 Structure diagram of turntable tracking test system

转盘跟踪试验系统主要包含转盘机械组件、驱动控制系统、加速度测试系统等。将运动控制卡插于电脑的扩展槽并与上位机连接,再通过串口实现电脑与驱动器的通信,驱动器通过滑环连接到电机,电机尾部的旋转变压器将信息反馈到驱动器,形成半闭环控制。在离心机转臂旋转的基础上,电机对矢量转盘进行精密位置控制,给试件提供所需的二维过载加速度,二维加速度计测出试件的加速度后反馈到计算机,形成全闭环控制,提高控制精度。

1.2 转盘跟踪试验系统的建模

转盘跟踪试验系统的数学模型为

$$\begin{cases} u_q = R_s i_q + L_q \frac{di_q}{dt} + L_d i_d p \dot{\theta} + p \psi_f \dot{\theta} \\ u_d = R_s i_d + L_d \frac{di_d}{dt} - L_q i_q p \dot{\theta} \\ T_e = \frac{2}{3} p \psi_f i_q \\ T_e = J \ddot{\theta} + B \dot{\theta} + T_L \\ \ddot{\theta} = -\frac{B}{J} \dot{\theta} - \frac{T_L}{J} + \frac{1.5 p \psi_f}{J} u(t) + d(t) \end{cases} \quad (1)$$

式中: $d(t)$ 为干扰; u_q, u_d 分别为 q, d 轴定子电压; i_q, i_d 分别为 q, d 轴定子电流; L_q, L_d 分别为 q, d 轴电感; R_s 为定子绕组电阻; T_e 为电机的输出转矩; ψ_f 为永磁体磁链; θ 为转子转角位置; T_L 为负载转矩; p 为电机极对数; J 为负载转动惯量; B 为摩擦阻力系数;采用控制策略 $u(t) = i_q$ 作为系统的控制输入。

2 基于自适应混沌蚁群算法的RBF神经网络PID位置控制器

该方法是在采用PID控制的基础上,使用自适应混沌蚁群算法对RBF神经网络模型的权值进行反复优化,直至出现最优解为止;神经网络的输出对应PID

的3个参数,进而通过神经网络的最优输出实时调整PID控制器参数,使系统性能指标达到最优化。图2为控制器结构框图。

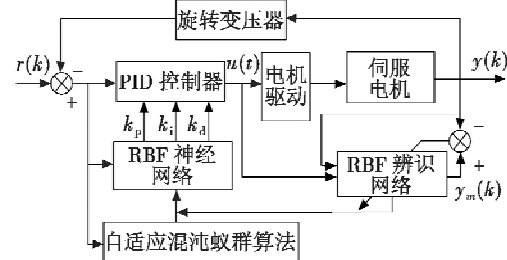


图2 自适应混沌蚁群RBF神经网络PID控制器结构图

Fig.2 RBF neural network PID controller based on adaptive chaotic ant colony

2.1 自适应混沌蚁群算法

假定神经网络中待优化的参数有 n 个,记为 p_1, p_2, \dots, p_n ,其中,任一参数 $p_i (1 \leq i \leq n)$ 的所有可能取值形成一个集合 Q_{p_i} 。定义蚂蚁数目为 m ,这些蚂蚁从蚁巢出发去寻找食物。

2.1.1 转移概率规则

每只蚂蚁从第一个集合出发,依据信息素强度来计算状态转移概率,依次从每个参数的可能取值集合 Q_{p_i} 中选择一个元素。第 k 只蚂蚁选择集合 Q_{p_i} 中第 j 个元素 $\tau_j^k(Q_{p_i})$ 的概率为

$$P[\tau_j^k(Q_{p_i})] = \frac{\tau_j^k(Q_{p_i})}{\sum_{s=1}^n \tau_s(Q_{p_i})} \quad (2)$$

蚂蚁对所选元素的信息素做相应调节,第 $t+n$ 时刻集合 Q_{p_i} 的第 j 个元素上所留的信息素算式为

$$\tau_j(t+n) = (1-\rho)\tau_j(t) + \Delta\tau_j \quad (3)$$

式中: $0 < \rho < 1, \rho$ 为信息素挥发因子, $1-\rho$ 为残留因子; $\tau_j(t)$ 表示 t 时刻第 j 个元素上信息素的强度; $\Delta\tau_j$ 表示一个周期中第 j 个元素上信息素的总增量,其值为

$$\Delta\tau_j = \sum_{k=1}^m \Delta\tau_j^k \quad (4)$$

式中, $\Delta\tau_j^k$ 表示第 k 只蚂蚁留在第 j 个元素上的信息素量。

2.1.2 局部信息素混沌化

典型的混沌系统:Logistic映射,具有确定的表达式形式,可以使系统在不包含任何随机因素的情况下产生看似完全随机的序列,其迭代公式为

$$z_{i+1} = \mu \cdot z_i \cdot (1 - z_i) \quad (5)$$

式中: μ 为控制参量, $\mu \in (2, 4], \mu = 4$ 时,Logistic所产生的序列处于完全混沌状态; $0 < z_i < 1, i = 0, 1, \dots, z_0 \notin \{0, 0.25, 0.5, 0.75, 1\}$ 。

混沌系统加入算法后,式(3)改写为

$$\tau_j(t+1) = (1-\rho)\tau_j(t) + \Delta\tau_j + \lambda z_j \quad (6)$$

式中: λ 为调节系数; z_j 为混沌变量,可由式(5)迭代得到。

2.1.3 信息素自适应更新

路径上的信息素强度差异过大,会导致以后迭代中选择其他路径的概率过小而造成算法陷入局部最优。因此分别设置信息素及信息素增量的上下限:将各个元素的信息素强度限制于区间 $[\tau_{\min}, \tau_{\max}]$ 内,同时更新信息素时将其增量限制于区间 $[\Delta\tau_{\min}, \Delta\tau_{\max}]$ 内,有效避免由算法正反馈所引起的信息素强度差异过大而陷入局部最优。综合以上两点,信息素自适应更新的总表达式为

$$\tau_j(t+n) = \begin{cases} \tau_{\max} & \text{更新后大于 } \tau_{\max} \\ \tau_{\min} & \text{更新后小于 } \tau_{\min} \\ (1-\rho)\tau_j(t) + \Delta\tau_j + \lambda z_j & \text{其他} \end{cases} \quad (7)$$

2.1.4 计算参数的混沌自适应调整

信息素挥发因子 ρ 反映蚂蚁之间相互影响的强弱,其值越小,信息素挥发越慢,算法的随机性和全局搜索能力越强^[10]。通常情况下需要经过反复调整得到 ρ 的经验值,一般取0.3左右^[11],但在算法计算的不同阶段,固定的 ρ 值对算法寻找最优解不利,所以,在蚁群算法计算的不同阶段,对 ρ 进行自适应混沌化调整: ρ 的初值为0~0.5之间的任意数^[12],而后对其进行混沌自适应调整,算式为

$$\rho(N_c + 1) = \begin{cases} 0.95\rho(N_c) & \text{陷入局部最优} \\ 1.6(\rho(N_c) - 0.1)(1.1 - \rho(N_c)) + 0.1 & \text{其他} \end{cases} \quad (8)$$

式中, N_c 为迭代次数。

实施过程中,当算法求得的单次迭代最优路径若干次内没有明显改进时,认为算法陷入局部最优。

2.2 RBF神经网络的自适应PID控制器

基于RBF神经网络的PID控制系统一部分通过经典PID控制器对电机进行闭环控制;另一部分通过RBF神经网络实时对PID控制器的3个参数进行调整,使其控制性能达到最佳。RBF神经网络拓扑结构如图3所示。




图3 RBF神经网络拓扑结构图

Fig. 3 Topology diagram of RBF neural network

此处辨识网络的输出为

$$y_m(k) = \sum_{j=1}^m w_j h_j \quad (9)$$

式中: h_j 为径向基向量 \mathbf{H} 的元素, $\mathbf{H} = [h_1, h_2, \dots, h_j, \dots, h_m]^T$; w_j 为网络的权向量 \mathbf{W} 的元素, $\mathbf{W} = [w_1, w_2, \dots, w_j, \dots, w_m]^T$ 。

辨识器的性能指标函数为

$$J = \frac{1}{2} (y(k) - y_m(k))^2 \quad (10)$$

系统的控制误差为

$$e(k) = r(k) - y(k) \quad (11)$$

式中: $e(k)$ 为误差; $r(k)$ 为输入; $y(k)$ 为反馈。

神经网络的3项输入分别为

$$x(1) = e(k) - e(k-1) \quad (12)$$

$$x(2) = e(k) \quad (13)$$

$$x(3) = e(k) - 2e(k-1) + e(k-2) \quad (14)$$

自适应混沌蚁群算法用来搜索最优权值并保证系统稳定,因此目标函数形式为

$$E(k) = \frac{e(k)^2}{2} \quad (15)$$

PID参数调整采用梯度下降法,即

$$\Delta k_p = -\eta \frac{\partial E}{\partial k_p} = -\eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial \Delta u} \frac{\partial \Delta u}{\partial k_p} = \eta e(k) \frac{\partial y}{\partial \Delta u} x(1) \quad (16)$$

$$\Delta k_i = -\eta \frac{\partial E}{\partial k_i} = -\eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial \Delta u} \frac{\partial \Delta u}{\partial k_i} = \eta e(k) \frac{\partial y}{\partial \Delta u} x(2) \quad (17)$$

$$\Delta k_d = -\eta \frac{\partial E}{\partial k_d} = -\eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial \Delta u} \frac{\partial \Delta u}{\partial k_d} = \eta e(k) \frac{\partial y}{\partial \Delta u} x(3) \quad (18)$$

其中,雅可比矩阵算法为

$$\frac{\partial y(k)}{\partial \Delta u(k)} \approx \frac{\partial y_m(k)}{\partial \Delta u(k)} = \sum_{j=1}^m w_j h_j \frac{c_{ji} - x_i}{b_j^2} \quad (19)$$

2.3 对神经网络的训练

算法对RBF神经网络优化训练时采用离线的方式,选择20组不同给定值的情况,每50个样本点取平均值(保证学习样本的各态遍历,提高神经网络泛化能力)。训练前需要对原始数据进行归一化处理,训练过程中采用最优停止法,目标误差为0.001。



通过不断迭代,得到神经网络的径向基向量 \mathbf{H} 和权值向量 \mathbf{W} ,经过式(9)计算得到辨识网络的输出值 $y_m(k)$,并计算出PID控制参数的调整量,经过迭代优化使参数误差逐渐减小。

3 仿真实例

本次试验的仿真参数为:电机星形连接,极对数 $p = 4$;额定电压 $V_n = 380$ V,额定频率 $f_n = 50$ Hz;定子电阻 $R_s = 1.132$ Ω ,转子电阻 $R_r = 2.023$ Ω ;d轴定子电感 $L_d = 0.01238$ H,q轴定子电感 $L_q = 0.01572$ H;系统转盘轴的转动惯量 $J_1 = 0.09$ $\text{kg} \cdot \text{m}^2$,伺服电机轴的转动惯

量 $J_2 = 7.2 \times 10^{-4} \text{ kg} \cdot \text{m}^2$, 减速比 $i = 6$, 将转动惯量全部折算到伺服电机轴: $J = J_1 + J_2/i^2 = 3.2 \times 10^{-3} \text{ kg} \cdot \text{m}^2$; 摩擦阻力系数 $B = 0.001 \text{ N} \cdot \text{m} \cdot \text{s}$; 学习速率 $\eta = 0.05$; PID 参数的取值范围 $[0, 20]$, 初始值取 $k_p = k_d = 0.03, k_i = 0.02$, 参数初始学习速率取 $\eta_p = \eta_i = \eta_d = 0.3$ 。

根据以上所给参数, 使用传统的 RBF 神经网络 PID 控制器和自适应混沌蚁群算法优化的 RBF 神经网络 PID 控制器对系统进行控制, 神经网络误差曲线对比如图 4 所示。




(a) 传统算法训练神经网络误差曲线
(b) 自适应混沌蚁群算法训练神经网络误差曲线
图 4 神经网络误差曲线


Fig. 4 Error curve of neural network training

由图 4 可知: 自适应混沌蚁群算法在循环次数为 74 时, 满足最优停止法条件, 网络终止训练; 而传统方法则在循环次数为 199 时才终止训练, 因此采用自适应混沌蚁群算法可以缩短训练时间, 提高网络效率。

参考输入跟踪的目标信号为 $r(t) = 3 \sin(3t)$, 传统 RBF 神经网络 PID 控制位置跟踪曲线和自适应混沌蚁群 RBF 神经网络 PID 控制位置跟踪曲线对比如图 5 所示。



(a) 传统 RBF 神经网络 PID 控制



(b) 自适应混沌蚁群 RBF 神经网络 PID 控制


图 5 位置跟踪曲线

Fig. 5 Position tracking curves

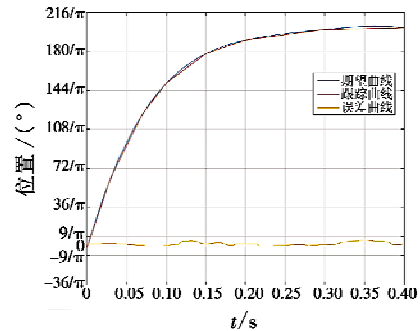
由图 5 可知: 传统的 RBF 神经网络 PID 控制器跟踪存在延时, 最大误差可达 20.92° , 由自适应混沌蚁群优化的 RBF 神经网络 PID 控制的跟踪延时明显减小, 最大误差减小到 3.5° , 控制在 3% 以内, 说明本文采用的控制器的精度较高、响应速度快、稳态误差小, 可使矢量转盘精准跟踪目标轨迹。

4 现场模拟试验

模拟试验装置如图 6(a) 所示, 是在离心旋转臂的基础上安装的矢量转盘试验装置, 跟踪目标曲线为飞行器部件过载半实物仿真试验提供二维加速度环境, 控制部分的关键设备包括计算机、运动控制卡、驱动器、电机和滑环。



(a) 矢量转盘试验装置



(b) 实测位置跟踪曲线

图 6 矢量转盘试验装置及试验结果

Fig. 6 Vector turntable test device and the test result

使用之前通过 Pwin32 Pro 软件对本算法进行编程写入 PMAC 卡并调试, 运行时接收上位机发出的

目标指令,PMAC 卡运算后通过串口输出 $\pm 10\text{ V}$ 电压给驱动器,驱动器接收信号之后通过滑环对电机进行控制和保护。试验结果如图 6(b) 所示,矢量转盘输出跟踪误差在 3% 以内,配合离心机为试件提供二维加速度过载模拟环境。

5 结论

本文为得到准确、稳定的二维加速度过载环境,提高矢量转盘的位置跟踪精度,采用自适应混沌蚁群优化的 RBF 神经网络 PID 控制器,通过自适应混沌蚁群优化算法解决 RBF 神经网络权值优化较慢的问题,有效缩短神经网络学习时间,提高 PID 控制器的在线自适应能力,使转盘跟踪试验系统精准地跟踪目标轨迹。仿真结果表明,自适应混沌蚁群优化 RBF 神经网络的误差明显小于传统算法,跟踪误差小、精确度高。将此控制策略应用于飞行器二维加速度过载模拟的矢量转盘跟踪试验系统,结果表明:系统具有良好的准确性和快速性,跟踪误差控制在 3% 以内,能精确提供所需的二维加速度过载环境,满足模拟试验要求,在工程实践中有广泛的应用前景。

参 考 文 献

- [1] 王士超. 离心旋转试验台控制策略研究[D]. 太原: 中北大学, 2018.
- [2] 张艳兵, 马铁华, 孙江涛. 导弹二维加速度过载环境的离心转盘模拟方法[J]. 火箭与制导学报, 2016, 36(4): 109-112.
- [3] 窦晓之. 复合台精密离心机控制方法研究与实现[D]. 哈尔滨: 哈尔滨工业大学, 2015.
- [4] 李阳阳. 基于 IRMC171 的医用离心机优化控制系统的研究与设计[D]. 天津: 天津理工大学, 2017.
- [5] 叶德住. 基于 BP 神经网络的永磁同步电机控制[J]. 微电机, 2016, 49(11): 57-61.
- [6] 邵文强, 康尔良. 基于 RBF 神经网络的永磁同步电动机 PID 控制[J]. 微特电机, 2018, 46(11): 75-78.
- [7] TATAR A, BARATI A, NAJAFI A, et al. Radial basis function (RBF) network for modeling gasoline properties [J]. *Petroleum Science and Technology*, 2019, 37(11): 1306-1313.
- [8] 孙启豪, 蔡爱华. 航空搜潜布阵航路优化研究[J]. 电光与控制, 2017, 24(4): 39-42.
- [9] 谢颖, 李吉兴, 杨忠学, 等. 改进遗传蚁群算法及其在电机结构优化中的研究[J]. 电机与控制学报, 2015, 19(10): 64-70.
- [10] 李亚女, 潘广贞. 蚁群算法中挥发系数与迭代次数和最优路径长度关系研究[J]. 科学技术与工程, 2013, 13(23): 79-83.
- [11] 毛亮亮, 王旭东. 蚁群算法在永磁同步电机起动过程中的应用[J]. 电力电子技术, 2015, 49(11): 74-76, 80.
- [12] 王跃钢, 文超斌, 左朝阳, 等. 自适应混沌蚁群径向分析算法求解重力辅助导航匹配问题[J]. 物理学报, 2014, 63(8): 089101-1-089101-8.
- [9] OBERMAISSER R, AHMADIAN H, MALEKI A, et al. Adaptive time-triggered multi-core architecture [J]. *Designs*, 2019, 3(1): 1-23.
- [10] WISNIEWSKI L, CHAHAR S, JASPERNEITE J. Seamless reconfiguration of time triggered Ethernet based protocols [C]//IEEE World Conference on Factory Communication Systems (WFCS), 2015. doi: 10.1109/WFCS.2015.7160581.
- [11] LI Z H, WAN H, PANG Z Y, et al. An enhanced reconfiguration for deterministic transmission in time-triggered networks [J]. *IEEE/ACM Transactions on Networking*, 2019, 27(3): 1124-1137.
- [12] 熊华钢, 王中华. 先进航空电子综合技术[M]. 北京: 国防工业出版社, 2009.
- [13] Military Agency for Standardization. STANAG 4626 (Part VI: Guidelines for system issues) (Vol. 7: Safety) [S]. Brussels: North Atlantic Treaty Organization, 2014.
- [14] STEINER W. An evaluation of SMT-based schedule synthesis for time-triggered multi-hop networks [C]//The 31st IEEE Real-Time Systems Symposium, 2010. doi: 10.1109/RTSS.2010.25.
- [15] STEINER W. Synthesis of static communication schedules for mixed-criticality systems [C]//The 14th IEEE International Symposium on Object/Component/Service-Oriented Real-Time Distributed Computing Workshops, 2011. doi: 10.1109/ISORCW.2011.12.

(上接第 48 页)