DOI:10.19344/j.cnki.issn1671-5276.2022.01.046

采摘机械臂的 PSO-RBF 神经网络自适应控制

董中华,陈鹏飞,李亚龙

(兰州理工大学 机电工程学院,甘肃 兰州 730050)

摘　要:针对采摘机械臂系统的不确定性为控制带来的问题,设计一种 PSO-RBF 神经网络自适应控制方法。该方法使用径向基函数神经网络来逼近并补偿系统模型误差,用粒子群优化算法来优化 RBF 的权值参数,确保 PSO-RBF 控制性能更好。MATLAB 仿真结果表明:与 RBF 神经网络控制相比,PSO-RBF 神经网络控制精度和性能更好。

关键词:机械臂;RBF 神经网络;粒子群算法;MATLAB 仿真

中图分类号:TP241　　**文献标志码**:B　　**文章编号**:1671-5276(2022)01-0181-03

Picking Manipulator Control Based on PSO-RBF Neural Network

DONG Zhonghua, CHEN Pengfei, LI Yalong

(School of Mechanical and Electrical Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Concerning the control problems caused by the uncertainty of the manipulator system, a new PSO-RBF neural network adaptive control method is designed, with which a radial basis function neural network is used to approximate and compensate for system model errors, and particle swarm optimization is applied to optimize RBF weight parameters to ensure better PSO-RBF control performance. The MATLAB simulation experiment results show that PSO-RBF neural network control manifests higher accuracy and better performance than that of RBC.

Keywords: manipulator; RBF neural network; particle swarm optimization; MATLAB simulation

0　引言

机械臂是一种多输入、多输出且具有时变性、时滞性和高度耦合性的复杂非线性系统[1]。机器臂系统的不确定性可能会导致依据该模型构造的控制器性能降低,甚至不稳定。在控制器设计时,很多控制策略都会有局限性,这将会对机械臂系统输出跟踪期望轨迹的实现带来巨大影响。因此机械臂系统中存在不确定项难以避免地会导致系统的性能大大降低[2]。神经网络应用在机械臂运动控制中,可以处理机械臂系统模型中的不确定性,还能对它进行实时控制[3]。

由于径向基神经网络结构简单,具有较强的泛化性能,近年来,很多人对 RBF 神经网络在机械臂控制的方向进行了研究,极大地推动了机械臂的 RBF 神经网络控制发展的进程。一些研究人员运用 RBF 神经网络的特性做出了自适应控制[4-5]。其中一部分研究人员在此基础上结合鲁棒控制,形成神经网络鲁棒自适应控制[6-7]。一些研究人员将 RBF 神经网络控制和模糊控制相结合,结合二者的优点组成模糊神经网络控制[8-9]。随着现代智能优化算法的兴起,如遗传算法(GA)、进化策略(ES)和粒子群算法(PSO)等,一些研究人员使用 GA 优化神经网络的参数,并设计了 GA-RBF 神经网络控制[10-11]。而 PSO 相对于 GA 而言,不需要编码,没有交叉和变异操作,粒子只是通过内部速度进行更新,因此原理更简单、参数更少、实现更容易。一些研究人员使用 PSO 结合 RBF 神经网络在预测方面的研究很深入,但在机械臂控制方面不多。文献[12-13]仅在自校正控制和逆运动方面进行了研究。

本文在文献[11]的 GA-RBF 控制方法中得到启发,采用了另一种现代智能算法(PSO)来替代 GA,设计了 PSO-RBF 控制方法。

1　机械臂系统问题描述

由于机械臂的每个关节就是一个输入,也是一个输出,而且关节与关节之间又存在着扰动,耦合关系复杂。所以机械臂的系统模型很难精确获得。通常是用它的静止模型作为名义模型,再通过反馈进行自适应调节,以达到精确的轨迹跟踪控制。

假设被控对象为 n 关节机械臂,其动态方程为:

$$\boldsymbol{M}(q)\ddot{q}+C(q,\dot{q})\dot{q}+\boldsymbol{G}(q)=\tau+d \tag{1}$$

其中:$\boldsymbol{M}(q)$ 为 $n\times n$ 阶正定惯性矩阵;$C(q,\dot{q})$ 为 $n\times n$ 阶离心力和哥氏力项;$\boldsymbol{G}(q)$ 为阶惯性向量;τ 为控制输入;d 为未知外加扰动。

在实际中很难获得机械臂模型的准确信息,通常可以得到机械臂的名义模型。设机械臂的名义模型为 $M_0(q)$、$C_0(q,\dot{q})$ 和 $G_0(q)$,令 $\Delta M=M_0-M$,$\Delta C=C_0-C$,$\Delta G=G_0-G$,其中 ΔM、ΔC、ΔG 为机械臂模型误差。结合式(1)可得

第一作者简介:董中华(1995—),男,山西朔州人,硕士研究生,研究方向为工业机器人技术及应用。

$$[M_0(q)-\Delta M]\ddot{q}+[C_0(q,\dot{q})-\Delta C]\dot{q}+G_0(q)-\Delta G(q)=\tau+d \tag{2}$$

因此,$M_0(q)\ddot{q}+C_0(q,\dot{q})\dot{q}+G_0(q)=\tau+f(q,\dot{q},\ddot{q})$

在计算力矩控制法中,采用名义模型,设计控制律为

$$\tau=M_0(q)(\ddot{q}-k_v e-k_p e)+C_0(q,\dot{q})\dot{q}+G_0(q)-f(\cdot) \tag{3}$$

其中:$k_p=\begin{bmatrix}\alpha^2 & 0\\ 0 & \alpha^2\end{bmatrix}$;$k_v=\begin{bmatrix}2\alpha & 0\\ 0 & 2\alpha\end{bmatrix}$;$\alpha>0$。

将式(2)代入式(1),可得误差系统为

$$\ddot{e}+k_v\dot{e}+k_p e=0 \tag{4}$$

其中:$e=q-q_d$;$\dot{e}=\dot{q}-\dot{q}_d$;$\ddot{e}=\ddot{q}-\ddot{q}_d$;$q_d$、$\dot{q}_d$、$\ddot{q}_d$分别为理想(期望)的角度、角速度、角加速度指令。

在实际工程中,$f(\cdot)$通常是未知的,需要估计$f(\cdot)$并对其补偿。利用 RBF 神经网络逼近任意非线性函数的特性逼近$f(\cdot)$,并对其进行补偿,就可以达到想要的控制效果。

2　PSO-RBF 神经网络

2.1　RBF 神经网络逼近原理

采用 RBF 网络逼近$f(\cdot)$,其算法为

$$h_j=\exp\left(-\frac{\|x-c_j\|^2}{2b_j^2}\right) \tag{5}$$

$$y=\boldsymbol{w}^{\mathrm{T}}h(x) \tag{6}$$

其中:x 是 RBF 神经网络的输入;$\boldsymbol{w}$ 是神经网络的权值;$\boldsymbol{h}=[h_1,h_2,\cdots,h_m]^{\mathrm{T}}$是高斯函数的输出。

给定一个很小的数 ε 使得 RBF 逼近公式(3)中的$f(\cdot)$,有如下公式:

$$\max\|f(\cdot)-\hat{f}^*(\cdot)\|\leqslant\varepsilon \tag{7}$$

定义逼近误差为

$$\eta=f(\cdot)-\hat{f}^*(\cdot) \tag{8}$$

其中$\hat{f}^*(\cdot)=\boldsymbol{w}^{*\mathrm{T}}h(x)$,$\boldsymbol{w}^*$ 表示$f(\cdot)$的最佳逼近权值向量。

当逼近误差 η 无限趋近于 0,则系统的不确定项被有效地逼近,通过补偿可以保证准确的控制。

2.2　PSO 优化原理

粒子群优化算法属于进化算法的一种,和模拟退火算法相似,它也是从随机解出发,通过迭代寻找最优解。

首先,粒子群算法将优化问题的解当作搜索空间中的一只鸟,在搜索的空间中以一定的速度飞行,速度大小根据它自身以及同伴的飞行经验进行动态调整。鸟被想象成为一个没有质量和体积的粒子,第 i 个速度粒子在 n 维空间里的位置表示为向量 $\boldsymbol{x}_i=(x_{i1},x_{i2},\cdots,x_{in})$,飞行速度表示为向量 $\boldsymbol{v}_i=(v_{i1},v_{i2},\cdots,v_{in})$。每个粒子都有一个由被优化函数所决定的适应值,而且知道自己到目前为止所发现的最好位置 $\boldsymbol{xp}_i=(xp_{i1},xp_{i2},\cdots,xp_{in})$。此外,每个粒子还知道到目前为止邻域粒子所发现的最好位置 $\boldsymbol{xg}=(\boldsymbol{xg}_1,\boldsymbol{xg}_2,\cdots,\boldsymbol{xg}_n)$。PSO 算法是一种基于迭代的优化算法,第 $t1$ 次迭代时,粒子将根据自身的经验和同伴的经验来决定下一步运动速度和位置。基本 PSO 算法的粒子位置和速度的更新公式如下:

$$v_{ij}(t+1)=wv_{ij}(t)+c_1r_1[xp_{ij}(t)-x_{ij}(t)]+c_2r_2[xg_i(t)-x_{ij}(t)] \tag{9}$$

$$x_{ij}(t+1)=x_{ij}(t)+v_{ij}(t+1) \tag{10}$$

其中:w 为惯性权重;c_1和c_2为学习因子;r_1和r_2为服从均匀分布 $U(0,1)$的随机数;$i=1,2,\cdots,N$,$j=1,2,\cdots,N$,N 为粒子规模。

2.3　PSO 优化 RBF 神经网络

在已知初始输入范围的条件下,运用 PSO 算法优化出最佳的网络权值 $\boldsymbol{w}$。取代优化参数向量 $\boldsymbol{n}$ 为个体粒子,PSO 算法每次迭代得到的参数值为

$$\boldsymbol{n}_m=\boldsymbol{w}^{\mathrm{T}}\qquad m=1,2,\cdots,S \tag{11}$$

其中 S 为粒子种群规模。

不确定性误差为公式(8),采用不确定项的逼近误差作为参数选择的最小目标函数,设计个体适应度函数为

$$E=\sum\frac{1}{2}\eta^2 \tag{12}$$

粒子群算法更新 RBF 权值的流程图如图 1 所示。

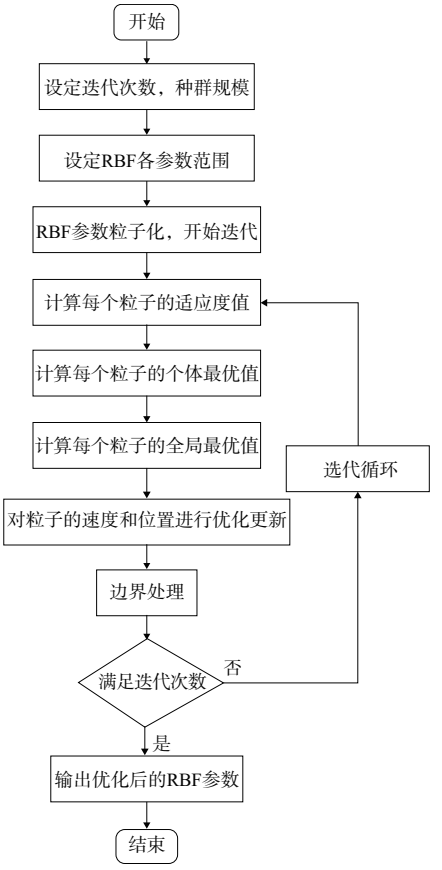

图 1　粒子群优化算法流程图

3　控制器的设计

在设计好 PSO 优化 RBF 参数的流程图后,PSO-RBF 神经网络自适应控制系统如图 2 所示。

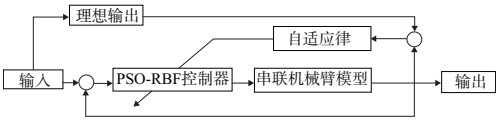

图 2　PSO-RBF 神经网络自适应控制系统框图

根据制定好的 PSO-RBF 神经网络自适应控制系统和参考文献[13],针对式(1)设计如下控制器:

$$\tau=M_0(q)(q-k_v e-k_p e)+C_0(q,\dot{q})\dot{q}+G_0(q)-\hat{f}(\cdot) \tag{13}$$

将式(13)代入式(1),整理可得

$$\ddot{e}+k_v\dot{e}+k_p e=M_0^{-1}(q)(f(\cdot)-\hat{f}(\cdot)) \tag{14}$$

令 $\boldsymbol{x}=[e \quad \dot{e}]^{\mathrm{T}}$,上述方程可以化为

$$\dot{\boldsymbol{x}}=\boldsymbol{A}\boldsymbol{x}+\boldsymbol{B}\{f(\cdot)-\hat{f}(\cdot)\} \tag{15}$$

其中:$\boldsymbol{A}=\begin{bmatrix}0 & I\\ -k_p & -k_v\end{bmatrix}$;$\boldsymbol{B}=\begin{bmatrix}0\\ M_0^{-1}(q)\end{bmatrix}$。

这是一个标准的现代控制理论方程。

设计 Lyapunov 函数来验证其稳定性:

$$V=\frac{1}{2}\boldsymbol{x}^{\mathrm{T}}P\boldsymbol{x}+\frac{1}{2\gamma}\|\tilde{w}\|^2 \tag{16}$$

其中 $\gamma>0$。

对 V 求导,整理可得

$$\dot{V}=-\frac{1}{2}\boldsymbol{x}^{\mathrm{T}}\boldsymbol{Q}\boldsymbol{x}+\boldsymbol{\eta}^{\mathrm{T}}\boldsymbol{B}^{\mathrm{T}}P\boldsymbol{x}-h\tilde{T}w\boldsymbol{B}^{\mathrm{T}}P\boldsymbol{x}+\frac{1}{\gamma}\|\dot{\tilde{w}}\| \tag{17}$$

为了和文献[13]中的结果进行比较,运用文献中的自适应率

$$\dot{\hat{\boldsymbol{w}}}^{\mathrm{T}}=\gamma\boldsymbol{B}^{\mathrm{T}}\boldsymbol{P}\boldsymbol{x}\boldsymbol{h}^{\mathrm{T}} \tag{18}$$

由于$\dot{\tilde{w}}=\dot{\hat{\boldsymbol{w}}}$,将式(18)代入式(17),整理可得

$$\dot{V}=-\frac{1}{2}\boldsymbol{x}^{\mathrm{T}}\boldsymbol{Q}\boldsymbol{x}+\boldsymbol{\eta}^{\mathrm{T}}\boldsymbol{B}^{\mathrm{T}}P\boldsymbol{x} \tag{19}$$

由上述的已知条件可得

$$\dot{V}\leqslant-\frac{1}{2}\lambda_{\min}(\boldsymbol{Q})\|\boldsymbol{x}\|^2+\|\boldsymbol{\eta}^{\mathrm{T}}\|\|\boldsymbol{B}\|\lambda_{\max}(\boldsymbol{P})\|\boldsymbol{x}\| \tag{20}$$

其中$\lambda_{\min}$和$\lambda_{\max}$分别是矩阵 $\boldsymbol{Q}$ 的最小特征值和矩阵 $\boldsymbol{P}$ 的最大特征值。

因已知只有 $\dot{V}\leqslant 0$ 时控制系统才是稳定的。为了保证 $\dot{V}\leqslant 0$,要保证误差收敛域$\|\boldsymbol{x}\|$满足

$$\|\boldsymbol{x}\|\geqslant\frac{2\|\boldsymbol{B}\|\lambda_{\max}(\boldsymbol{P})\|\boldsymbol{\eta}^{\mathrm{T}}\|}{\lambda_{\min}(\boldsymbol{Q})} \tag{21}$$

由式(21)可得出结论,增大 $\boldsymbol{Q}$ 的特征值或减小 $\boldsymbol{P}$ 的特征值可以提高 $\boldsymbol{x}$ 的收敛效果。

4　仿真实验

本控制是在 RBF 神经网络控制的基础上,通过粒子群算法优化了控制效果,引入文献[13]中的二连杆机械臂作为被控对象进行仿真对比。

被控对象为双关节机械臂如图 3 所示,其动力学方程为

$$M(q)\ddot{q}+C(q,\dot{q})\dot{q}+G(q)=\tau+d$$

各项参数参考文献[13]。

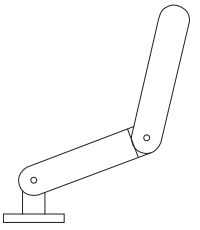

图 3　双关节机械臂示意图

设关节角度和关节角速度的期望跟踪指令为

$$\begin{cases}q_{1d}=1+0.2\sin(0.5\pi t)\\ q_{2d}=1-0.2\cos(0.5\pi t)\end{cases}。$$

仿真中,采用控制律式(14)和自适应律式(18),控制参数取

$$\boldsymbol{Q}=\begin{bmatrix}50 & 0 & 0 & 0\\ 0 & 50 & 0 & 0\\ 0 & 0 & 50 & 0\\ 0 & 0 & 0 & 50\end{bmatrix},\alpha=3,\gamma=20。$$

RBF 网络结构为 4-5-2,核函数是高斯函数,参数为 $\boldsymbol{c}_i=[-2 \quad -1 \quad 0 \quad 1 \quad 2]$ 和 $b_i=3.0$。RBF 神经网络权值 $\boldsymbol{w}=[w_1 \quad w_2 \quad \cdots \quad w_{10}]$,有 10 个参数需要优化。

采用粒子群优化算法对 RBF 神经网络中的权值 $\boldsymbol{w}$ 进行优化,在优化工程中,粒子群优化算法的参数为:迭代次数 $T=100$,种群规模 $S=50$,粒子维数 $D=10$。学习因子 $c_1=c_2=0.5$。

仿真结果如图 4-图 7 所示。

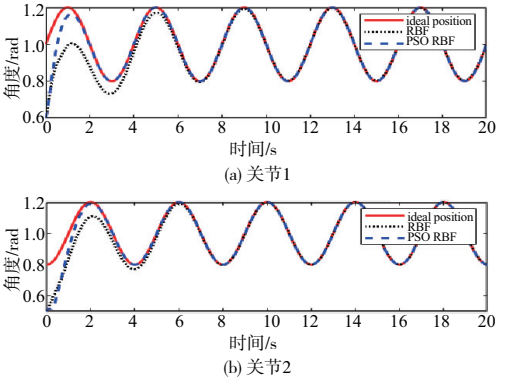

图 4　关节 1 和关节 2 的轨迹跟踪

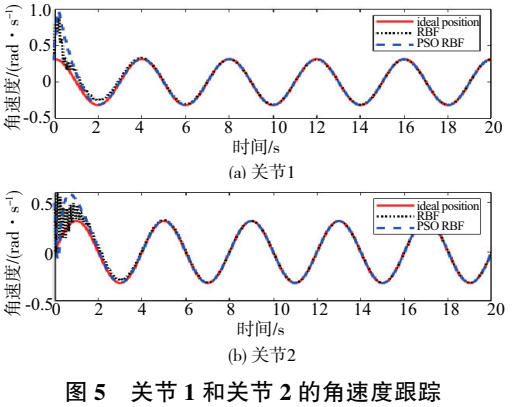

图 5　关节 1 和关节 2 的角速度跟踪

(下转第 233 页)

5　结语

本文设计并制作了一套带无线传送功能的车床夹紧力测试系统样机,完成了传感器选型、变送器设计与制作、传感器的标定等,并进行了实验测试。测试结果表明该测试系统可以有效满足卡盘夹紧力的测试需求。

参考文献:

[1] 张文亭. 数控车床液压卡盘夹紧控制系统的研究[J]. 工业仪表与自动化装置,2014(2):74-76,86.
[2] 冯平法,郁鼎文,吴志军,等. 离心力补偿卡盘高速回转夹紧特性研究[J]. 中国机械工程,2007,18(14):1648-1652.
[3] 于凯,王扬威,闫勇程,等. 仿生水下机器人三维力测试系统研究[J]. 机械制造与自动化,2016,45(5):152-155,229.
[4] 孙昊辰. 测力传感器的稳定性及其优化工艺[J]. 计算机产品与流通,2020(4):274.
[5] 张勇. 民机驾驶盘力测试技术研究[J]. 机械制造与自动化,2020,49(5):207-210.
[6] 陈会金. 楔式动力卡盘定心精度与夹紧力特性研究[D]. 烟台:烟台大学,2016.
[7] 姜学文. 半导体应变片全桥电路的补偿[J]. 仪表技术,1989(4):7-9.
[8] 姜培,李毅,王慧忠. 一种楔形液压动力三爪卡盘静态夹紧力测量仪的设计与应用[J]. 制造技术与机床,2020(10):124-125,132.

收稿日期:2020-12-09

(上接第 183 页)

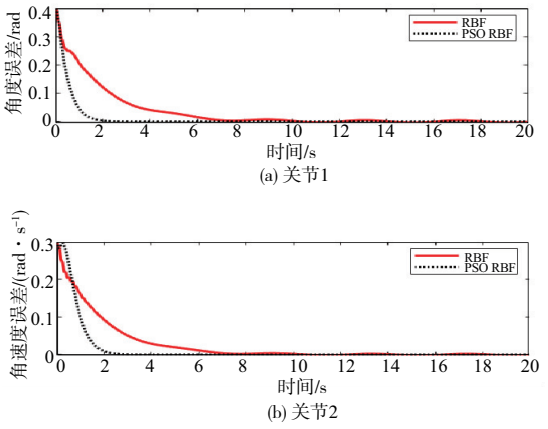

(a) 关节1　(b) 关节2

图 6　关节 1 和关节 2 的轨迹跟踪误差

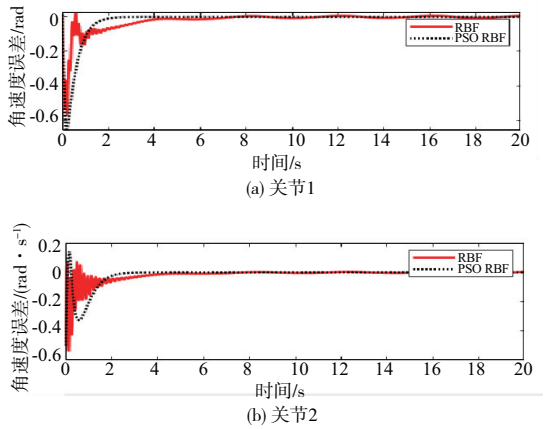

(a) 关节1　(b) 关节2

图 7　关节 1 和关节 2 的速度跟踪误差

从图 4 和图 5 分析得出,PSO- RBF 神经网络控制的轨迹和速度与理想的轨迹和速度基本吻合,而且与 RBF 神经网络控制相比,PSO-RBF 的轨迹更快地吻合理想轨迹。

从图 6 和图 7 可以看出,关节 1 轨迹吻合快将近 4 s,关节 2 轨迹吻合快将近 2 s。这表明 PSO-RBF 神经网络自适应控制实现了二连杆机械臂的高精度轨迹控制效果。通过和 RBF 控制方法对比,PSO-RBF 神经网络自适应控制方法能够确保关节 1 和关节 2 的不确定项误差在一个更小的收敛领域,这说明该方法能更快逼近系统不确定项,保证控制系统在更短时间获得补偿并提高性能。

5　结语

1) RBF 神经网络控制能够在部分未确定机械臂模型参数的情况下获得较好的轨迹跟踪性能。而用 PSO 优化后的 RBF 神经网络控制可以获得更好的轨迹跟踪性能。

2) 通过和 RBF 神经网络自适应控制相比,PSO-RBF 神经网络自适应控制系统能够在更短时间内吻合理想控制轨迹,且控制稳定,提高了控制性能。

参考文献:

[1] 蔡自兴,谢斌. 机器人学[M]. 3 版. 北京:清华大学出版社,2015.
[2] 张翠. 基于 RBF 神经网络的机械臂运动控制算法及应用研究[D]. 兰州:兰州交通大学,2014.
[3] 孙秀军. 基于 RBF 神经网络的机械手轨迹规划及运动仿真研究[D]. 淄博:山东理工大学,2007.
[4] 夏俊. 基于 RBF 神经网络的无人水面舰艇自适应控制[J]. 机械制造与自动化,2019,48(3):185-188.
[5] 刘福才,高娟娟,王芳. 不同重力环境下空间机械臂神经自适应鲁棒控制[J]. 宇航学报,2013,34(4):503-510.
[6] 张文辉,刘文艺,叶晓平,等. 自由漂浮空间机械臂基于神经网络的鲁棒自适应控制[J]. 机械工程学报,2012,48(21):36-40.
[7] 洪昭斌,陈力. 基于高斯基模糊神经网络的漂浮基柔性空间机械臂自学习控制[J]. 工程力学,2009,26(6):172-177.
[8] 张瑞芬. 受到外部扰动的空间机械臂基于模糊递归神经网络的控制策略[J]. 机电工程,2017,34(1):62-67.
[9] JIA W, ZHAO D, SHEN T, et al. A new optimized GA-RBF neural network algorithm [J]. Computational Intelligence and Neuroscience,2014:982045.
[10] 肖凡,李光,周鑫林. 多连杆机械臂 GA-RBF 神经网络轨迹跟踪控制[J]. 机械科学与技术,2018,37(5):669-674.
[11] 陈文元,杨东勇. 基于 PSO 的神经网络机械臂自校正控制[J]. 机电工程,2008,25(1):44-47.
[12] 张震,张亚. 基于 PSO-RBF 神经网络的串联机械臂逆运动学分析[J]. 科学技术与工程,2019,19(36):195-200.
[13] 刘金琨. RBF 神经网络自适应控制及 MATLAB 仿真[M]. 北京: 清华大学出版社. 2014.

收稿日期:2020-12-23