

基于粒子群优化的 BPNN 自适应切换控制算法研究^{*}

王丽丽 辛玲

(青岛科技大学 自动化与电子工程学院 青岛 266061)

摘要: 针对工业控制系统中存在的一系列非线性和时变性,以及传统自适应控制方法中的瞬态响应差等问题,提出了一种基于粒子群优化(PSO)的神经网络多模型切换自适应控制方法。利用粒子群优化算法对神经网络权重进行调节得到最优权值,基于 BP 神经网络和多模型设计自适应控制方案,构造合理的切换准则,使得系统在任意时刻都可以选择最优控制器对系统进行控制,并利用神经网络良好的逼近能力有效提高自适应控制的效果。最后,通过 MATLAB 仿真结果验证,所提的优化算法收敛快,精度高,有较好的网络泛化和逼近能力,能够很好地跟踪控制系统的输出。

关键词: 瞬态响应;自适应控制;神经网络;粒子群优化

中图分类号: TP13 **文献标识码:** A **国家标准学科分类代码:** 510.99

Adaptive switching control algorithm design of BPNN
based on particle swarm optimization

Wang Lili Xin Ling

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: In view of the nonlinearity and time variability of industrial control systems, as well as the poor transient response in traditional adaptive control, presents a neural network multi-model switching adaptive control method basing on particle swarm optimization. Firstly, the PSO algorithm was used to adjust the neural network weights to achieve the optimal value. Then an adaptive control strategy was designed basing on the BPNN and multiple models. The optimal controller can be selected to control the system through the constructed rational switching rules. The good approximation ability of neural network can improve the performance of adaptive control. The performance through PSO optimization are studied through simulation methods using MATLAB, which verifies that the proposed method can significantly improve the overall performance of the system; fast convergence, high precision, good network generalization and approximation ability, and can precisely track the output of the control system.

Keywords: transient response; adaptive control; neural network; particle swarm optimization

0 引言

传统的自适应控制对于一些参数已知的时变系统以及具有较小不确定性的系统来说具有较好的控制效果。而实际系统通常存在较强非线性、大时变以及明显的不确定性,因此,常规的自适应控制往往难以达到令人满意的控制效果,甚至无法满足控制系统的要求^[1]。20世纪50年代,便有学者对自适应控制方法进行了初步探索,它是一种通过改变控制系统行为来适应被控对象动态特性和环境条件变化的控制策略,原理是能在被控对象的模型知识或者外部环境知识知之不全或者是知之甚少,使系统能够

自动地工作于最优或者接近于最优的运行状态,从而获得高品质的控制性能^[2]。

近年来,神经网络因其良好的学习能力以及非线性逼近特性,被广泛应用于控制系统的研究当中,而神经网络自适应控制被证实可得到良好的辨识和控制效果。其中,BP神经网络因其可以任意精度逼近非线性关系被广泛应用于处理非线性的控制问题。文献[3]针对一类非线性离散时间系统设计了一个自适应控制方案,保证系统任意时刻都能选择良好的控制器对系统进行控制,但设计的非线性模型参数不能保证为最优参数。文献[4]针对一类非线性离散动态系统,设计了能够保证闭环系统所有信号有界的线

收稿日期:2020-12-11

^{*} 基金项目:山东省自然科学基金(2015ZRB019FA)项目资助

性鲁棒自适应控制器,并定义了一个非线性预测模型,使得系统稳定的前提下有效提高控制效果。文献[5]在一类不确定非线性离散时间动态系统提出了基于神经网络与多模型的非线性广义预测自适应控制方法,该方法在保证系统稳定的同时,还可保证系统的性能。但是,上述方法忽略了神经网络在权值选择的一般性,从而导致系统的暂态性能变差,过渡时间较长。

本文提出的基于粒子群优化的神经网络多模型切换自适应控制方法。利用粒子群优化算法对神经网络权重进行调节得到最优权值,基于 BP 神经网络和多模型设计自适应控制方案设计有效合理的切换性能函数,使得系统在任意时刻都可以选择最优控制器对系统进行控制,并利用神经网络良好的逼近能力有效提高自适应控制的效果,而且避免系统陷入局部最小值的弊端。

1 问题描述

对于如下非线性离散时间系统:

$$\begin{cases} \mathbf{x}(k+1) = A(\mathbf{x}(k), u(k)) \\ y(k) = B(\mathbf{x}(k)) \end{cases} \quad (1)$$

式中: $u(k), y(k) \in R$ 为被控对象的输入与输出; $\mathbf{x}(k) \in R^N$ 为 N 维状态向量; A, B 为非线性函数。

将非线性系统式(1)在零点出进行泰勒展开,可得:

$$\begin{cases} \mathbf{x}(k+1) = a\mathbf{x}(k) + bu(k) + \tilde{f}(\mathbf{x}(k), u(k)) \\ y(k) = c\mathbf{x}(k) + \tilde{h}(\mathbf{x}(k)) \end{cases} \quad (2)$$

对于系统的线性部分,表示成式(3)形式,得:

$$y(k+d) = \sum_{i=0}^{n-1} a_i y(k-i) + \sum_{j=0}^{n-1} b_j u(k-j) \quad (3)$$

其中, $b \neq 0$, 因此非线性系统可以表示为式(4):

$$y(k+d) = \sum_{i=0}^{n-1} a_i y(k-i) + \sum_{j=0}^{n-1} b_j u(k-j) + f(\omega) = \theta^T \omega(k) + f(\omega(k)) \quad (4)$$

式中: $\omega(k) = [y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]^T$, $\theta = [a_0, \dots, a_{n-1}, b_0, b_{n-1}]^T$ 。

2 基于 PSO-BP 神经网络多模型切换自适应控制论

2.1 PSO-BP 神经网络多模型切换自适应控制系统结构设计

当受控系统的结构参数和起始状态产生变化或目标函数(评价函数)的最值点出现偏移时,自适应控制能够确保系统自行获取最佳执行状态。基于 PSO-BPNN 自适应控制系统结构如图 1 所示。

针对图 1 非线性系统的结构,首先根据先验知识将被控系统划分多个区间,在每个区间内建立线性自适应模型和非线性神经网络模型,而神经网络模型是以离线的方式通过粒子算法优化网络权值从而获取一个最优权值后得到的。而 BP 神经网络控制的功能是控制被控对象的输出能




图 1 PSO-BP 多模型切换自适应控制系统结构

够很好的获得期望的输出,并且通过设定一个合适的切换策略来选取相应的控制器以得到期望的性能效果。

2.2 模型集的建立

根据先验知识,将被控系统的未知参数集划分成 n 个参数子集 $\Omega_i (i = 1, 2, \dots, n)$, 并且 Ω_i 满足以下的条件:

- 1) $\bigcup_{i=1}^n \Omega_i \subseteq \Omega, \Omega \neq \emptyset, (i = 1, 2, \dots, n)$;
- 2) $\Omega_{i+1} \cap \Omega_i = \delta_i, (i = 1, 2, \dots, n)$, δ_i 为两个参数子集的交集;
- 3) $\forall \theta^* \in \Omega_i, (i = 1, 2, \dots, n)$ 。

在系统的每个 Ω_i 内,将式(1)进行泰勒展开可得线性自适应模型和神经网络非线性模型。

当系统参数未知时,可以建立如下线性辨识模型:

$$\bar{y}(k+d) = \bar{\theta}^T(k+d-1)\omega(k) \quad (5)$$

其中,其参数更新可采用最小二乘辨识算法进行更新。

神经网络非线性模型可表示为以下形式:

$$\bar{y}(k+d) = \bar{\theta}^T(k+d-1)\omega(k) + \bar{f}(\omega(k), w(k)) \quad (6)$$

其中, $\bar{f}(\cdot)$ 是连续有界的非线性函数; $w(k)$ 更新通过粒子群优化算法进行优化,从而不断迭代更新,直到获得最优权重。

2.3 切换控制指标

假设被控系统的切换控制性能指标为 $J_i(k)$, 它取决于每个辨识模型的辨识误差。其形式为:

$$J_i(k) = \alpha e_i^2(k) + \beta \int_0^k e^{-\gamma(k-\sigma)} e_i^2(\sigma) d\sigma \quad (7)$$

其中, $\alpha \geq 0, \beta > 0, \gamma > 0$ 为遗忘因子决定性能指标的记忆长度; α, β 两者决定了当前误差和历史误差的在性能指标中的权重; $e_i(k) = y(k) - \hat{y}_i(k)$ 为系统中各个模型的辨识误差。在每个采样时刻,根据性能指标选取辨识误差最小的模型,并切换到该模型上,从而控制输入切换到与该

模型相对应的控制器上。

2.4 基于 PSO-BP 神经网络控制器设计

BP 神经网络 (back propagation neural network, BPNN), 在许多种预测模型控制中得到了普遍应用^[6]。BPNN 在构造上依次是输入层、隐层和输出层。其拓扑结构如图 2 所示, 当它处于前向传播的阶段时, 输入信号首先是从输入层经过隐层进行逐层分析, 然后再传入输出层。神经网络的前一层神经元状况仅作用于它的后一层神经元的状况。如果系统在输出层没有获得所希望的输出信号, 那么网络就会转向误差反向传播阶段, 然后就对预测值与实际结果的偏差的权值和阈值作预期的改变, 进而使 BP 神经网络在传播完毕后达到期望的输出。因此, 神经网络具有很好的拟合效果。




图 2 BPNN 拓扑结构

设想某一层神经元 j 的载入信号为 net_j , 传出信号为 y_j , 则 $net_j = \sum_i \omega_{ij} y_i$, $y_j = f(net_j)$, ω_{ij} : 神经元 i 与 j 之间的连接权重; $f(\cdot)$ 神经元的输出函数。

用粒子群算法优化神经网络的权重, 以此不断重复更新权值以获得最优权重数据, 其主要优化过程将在后文介绍。在采样时刻根据指标函数选择与实际被控对象最接近的控制模型, 将此模型对应的控制器切换到当前控制器。采用该方案极大地改善了跳变系统的暂态相应性能。

PSO 算法最初是对一个随机的粒子种群设定一个初始值^[7], 通过重复反馈过程找寻最佳值, 在每次反馈过程中, 每个粒子目前所对应的最佳值为 $pBest$, 所有粒子, 即整组粒子目前所对应的最佳值为 $gBest$, 每个粒子利用这两个最佳值来改进自己的速度和位置, 相应的公式:

$$V_{id} = \omega \times V_{id} + C_1 \times \text{rand}() (pBest - X_{id}(t)) + C_2 \times \text{rand}() \times (gBest - X_{id}(t)) \quad (8)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (9)$$

V_{id} 为第 i 个粒子 (有 d 维) 的速度; $pBest$ 为每个粒子到目前为止所出现的最佳位置; $gBest$ 为所有粒子到目前为止所出现的最佳位置; X_{id} 为每个粒子目前的位置; C_1, C_2 为学习常数; ω 为惯性权重; $\text{rand}()$ 为 $0 \sim 1$ 之间的随机自然数。

伴随有权重因子 ω , 可以大大地提升 PSO 的搜索能力, 并且对于不同情况的搜索问题, 可以进行整体和局部搜寻性能, 这也是粒子群优化算法能够很好地应用于较多实际问题的重要因素。

2.5 适应度函数

粒子群中各个粒子的位置取代 BP 神经网络目前更替中权重的集, 每个粒子的维数依赖于由网络中起连接功能的权重的数目和能够产生的最低值或最高值的个数, 种群粒子变为神经网络的连接权重, 把对预先规定的训练样本集的神经网络输出偏差作为神经网络练习问题的符合函数, 适应度值代表网络输出层的偏差最小, 粒子的速度变化过程为是改变网络权重的过程, 从而能够减少估计量与被估计量之间的差异程度。适应度函数如下形式:

$$T = \frac{1}{N} \sum_{n=1}^N (u_n^{(d)} - u_n)^2 \quad (10)$$

其中, $n=1, 2, \dots, N$, N 是样本数; $u_n^{(d)}$ 是控制率的输出值; u_n 是实际输出值。

2.6 PSO-BPNN 的多模型自适应切换算法过程

粒子群优化 BP 神经网络多模型切换自适应^[8-15]步骤如下:

- 1) 由系统输入输出数据组成数据向量;
- 2) 将神经网络的权阈值初始化, 把权重和阈值变化成实数矢量, 将这些矢量作为种群粒子;
- 3) 设置种群个数和反馈次数, 并把局部最优值和全局最优值进行初始化;
- 4) 依照优化过程对神经网络权重进行优化获得最优权值;
- 5) 利用输入输出数据和最优权值计算模型的输出;
- 6) 依据每个模型的输出和系统实际输出计算每个模型是输出误差;
- 7) 按照误差计算切换指标函数, 从而选取满足条件的模型;
- 8) 通过选取的模型挑选控制器, 进而对被控系统进行控制, 达到满意的控制性能。

其粒子群算法优化神经网络的基本流程结构如图 3 所示。




图 3 粒子群算法优化神经网络流程

考虑到粒子优化算法有着易早收敛,寻优精度不高,迭代速率差等缺点,引入了变异操作,其主要方法就是在粒子每进行以此更新,都要以一定的概率重新初始化粒子,进而能够扩大了在寻优过程中持续缩小的寻优范围,使粒子可以在更大的范围内进行寻优搜索,既保证了粒子的多样性,又提高了算法的收敛性^[16]。

2.7 PSO-BPNN 的多模型控制器设计

首先,如果依据性能指标函数计算出的性能最佳模型为线性自适应模型,则所对应的控制器为如下形式:

$$u_a(k) = \frac{1}{b_{a0}}(y^*(k+d) - \theta^{aT} \omega(k)) \quad (11)$$

其次,如果依据性能指标函数计算出的性能最佳模型为神经网络非线性模型,则所对应的控制器具有以下形式:

$$u_a(k) = \frac{1}{b_{a0}}(\theta^{aT} \omega(k) + y^*(k+d) - \bar{f}(\omega(k), w(k))) \quad (12)$$

3 仿 真

为了验证基于 PSO 优化的 BP 神经网络自适应控制系统的控制性能,本文对其进行了仿真测试。假设太阳能新风系统的非线性被控对象的模型描述为: $y(k) = \frac{0.8 + y^2(k-1)}{5 + y(k-1) + y^3(k-2)}$, 取输入信号 $u(k) = 0.58\sin(0.05\pi k)$, 即输入为 $\{y(k-1), y(k-2); u(k)\}$, 输出为 $y_i(k)$ (优化后的网络输出), 期望输出与优化网络输出误差 $e(k) = y(k) - y_i(k)$ 。

采用不同的控制器,使优化后的网络输出能够渐近跟踪期望输出(系统实际输出),利用 MATLAB 仿真软件,分别将常规 BPNN 自适应、未采用优化的自适应以及 PSO 优化 BPNN 后的自适应控制进行了仿真验证。仿真结果如图 4、5、6 所示。图 4 为常规多模型自适应控制,可以看出其跟踪能力还比较差;图 5 为采用 BP 神经网络后的多模型自适应控制,可以看出,其拟合能力要比优于常规多模型自适应;图 6 为 PSO-BP 多模型自适应控制,对比图 4、5,几乎完全实现了其跟踪能力,其效果远远好于常规和未优化神经网络的自适应控制,在保证辨识精度的前提下,其跟踪误差也逐渐变小。仿真结果验证了该方法的合理性。




图 4 常规多模型自适应控制




图 5 BPNN 多模型自适应控制




图 6 PSO-BPNN 多模型自适应控制

根据仿真结果,可以知道,常规多模型自适应切换控制的输出误差较大,达到了约 ± 1 ,而神经网络的多模型自适应控制输出误差相对于前者则减少了 0.5,则由粒子群进行权重优化的神经网络多模型自适应控制其输出误差几乎为 0,达到了很好的控制效果,性能更佳。

4 结 论

本文提出了利用粒子群优化神经网络的权值,得到优化好的最优神经网络权值来获取良好的控制率进而选择合适的模型,然后选择最优的切换策略在工作区域的不同控制器进行切换,进而实现对被控对象的控制。仿真结果证明了所提方法能够在保证误差逐渐收敛的情况下很好地跟踪受控对象,从而能够有效地改善系统的暂态性能。

参考文献

- [1] 陈杰,陈伟,孙健. 多模型自适应控制研究概述[J]. 系统科学与数学, 2014, 34(12): 1421-1437.
- [2] 黄帅,王昕,王振雷. 一类非线性多变量系统的多模型自适应控制[J]. 控制理论与应用, 2020, 37(4): 829-835.
- [3] XIAO Y S. Multi-model adaptive control for a class of nonlinear system based on neural networks [J]. Proceedings of 32th Chinese Control Conference, 2013: 2969-2973.
- [4] 姚健,纪志成,黄言平. 基于神经网络的非线性多模型

- 自适应控制[J]. 控制工程, 2014, 21(2): 172-177.
- [5] 石宇静, 柴天佑. 基于神经网络与多模型的非线性自适应广义预测控制[J]. 自动化学报, 2007, 33(5): 540-545.
- [6] 李小珉, 尹明. 基于遗传算法的 BP 神经网络电子预测方法研究[J]. 电子测量技术, 2016, 39(9): 182-186.
- [7] 周驰, 高海兵, 高亮, 等. 粒子群优化算法[J]. 计算机应用研究, 2003, (12): 7-11.
- [8] CHEN L J, NARENDRA K S. Nonlinear adaptive control using neural networks and multiple model[J]. Automatica, 2001, 37(8): 1245-1255.
- [9] 陈聆, 闫海波, 毛万标. 基于粒子群优化的 BP 神经网络模型参考自适应控制系统[J]. 成都理工大学学报(自然科学版), 2007, 34(6): 640-642.
- [10] 徐胜男, 周祖德, 艾青松, 等. 基于粒子群优化的神经网络自适应控制算法[J]. 中国机械工程, 2012, 23(22): 2732-2738.
- [11] 王永俊, 贾建芳. 航天器自适应滑模变结构姿态控制[J]. 电子测量与仪器学报, 2019, 33(9): 9-15.
- [12] 朱鹏, 董文瀚, 郭嘉. 基于核自适应滤波的多操纵面飞机多模型舵面故障诊断[J]. 电子测量与仪器学报, 2019, 33(10): 29-38.
- [13] 白中浩, 朱磊, 李智强. 基于多模型融合和重新检测的高精度鲁棒目标跟踪[J]. 仪器仪表学报, 2019, 40(9): 132-141.
- [14] 朱飞燕. 多模型自适应加权的无线网络安全风险评估[J]. 国外电子测量技术, 2020, 39(6): 106-109.
- [15] 吴阳, 刘凯, 陈柏, 等. 自适应粒子群优化算法优化径向基函数神经网络用于电阻抗成像重建[J]. 仪器仪表学报, 2020, 41(6): 240-249.
- [16] 蔡奇志, 苗荣霞, 樊逸飞, 等. 基于粒子群优化神经网络的电梯群控算法[J]. 国外电子测量技术, 2019, 38(5): 114-119.

作者简介

王丽丽, 博士, 副教授, 硕士生导师, 主要研究方向为智能控制算法设计与优化、控制系统设计与应用、控制算法仿真等。

E-mail: wllqst@126.com

辛玲, 工学硕士, 主要研究方向为多模型控制与智能算法设计与优化。

E-mail: 1755350672@qq.com