

6-14-2018

Modeling and Simulation of Networked Control Systems Based on Improved BP Network

Shifeng Li

1.Mechanical Engineering Inst, Dalian Jiaotong University, Dalian 116028, China;;

Zhanzhi Qiu

1.Mechanical Engineering Inst, Dalian Jiaotong University, Dalian 116028, China;;2.Software Technology Inst, Dalian Jiaotong University, Dalian 116028, China;;

Liping Fan

1.Mechanical Engineering Inst, Dalian Jiaotong University, Dalian 116028, China;;2.Software Technology Inst, Dalian Jiaotong University, Dalian 116028, China;;3.Electrical Information Inst, Dalian Jiaotong University, Dalian 116028, China;;

Lina Zhao

1.Mechanical Engineering Inst, Dalian Jiaotong University, Dalian 116028, China;;2.Software Technology Inst, Dalian Jiaotong University, Dalian 116028, China;;4.Electrical Engineering Inst, Dalian Institute of Science and Technology, Dalian 116052, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Original Article is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Modeling and Simulation of Networked Control Systems Based on Improved BP Network

Abstract

Abstract: In the circumstance where both the delay model and the controlled object model were unknown in networked control systems, *a class of networked predictive control systems based on improved BP network were studied*. For the problem of obtaining the hidden layer nodes number of BP network, *a rapid calculation method was proposed*. For the problem of avoiding local optimum of BP network, *a hybrid learning method was proposed*. *A off-line BP network model was proposed for coping with the problem of the delay prediction based on the above algorithms*. For the problem of the linear and nonlinear control of the networked control systems, *a single step prediction controller based on on-line BP network was designed*. The simulation results show that the performance of the networked predictive control systems is improved in the running speed, the delay prediction, the linear and nonlinear controls.

Keywords

networked control system, BP network, delay prediction, genetic algorithm, linear controlled object, nonlinear controlled object

Recommended Citation

Li Shifeng, Qiu Zhanzhi, Fan Liping, Zhao Lina. Modeling and Simulation of Networked Control Systems Based on Improved BP Network[J]. Journal of System Simulation, 2018, 30(6): 2279-2287.

基于改进BP网络的网络控制系统建模与仿真

李世峰¹, 邱占芝^{1,2}, 樊丽萍^{1,2,3}, 赵丽娜^{1,2,4}

(1.大连交通大学机械工程学院, 大连 116028; 2.大连交通大学软件学院, 大连 116028;
3.大连交通大学电气信息学院, 大连 116028; 4.大连科技学院电气工程学院, 大连 116052)

摘要: 针对网络化控制系统中时延模型和被控对象模型均未知的情况, 研究了一类基于改进BP网络的网络化预测控制系统。针对BP网络隐含层节点数求取问题, 提出了一种快速求取方法。针对BP网络局部最优问题, 提出了一种混合学习方法。在上述算法的基础上, 提出了一种离线BP网络模型用于应对时延预测问题。针对网络化控制系统中的线性与非线性控制问题, 设计了基于在线BP网络的单步预测控制器。仿真结果表明: 系统在运行速度、时延预测、线性与非线性控制方面均具有良好的性能。

关键词: 网络化控制系统; BP网络; 时延预测; 遗传算法; 线性被控对象; 非线性被控对象

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X(2018)06-2279-09

DOI: 10.16182/j.issn1004731x.joss.201806035

Modeling and Simulation of Networked Control Systems Based on Improved BP Network

Li Shifeng¹, Qiu Zhanzhi^{1,2}, Fan Liping^{1,2,3}, Zhao Lina^{1,2,4}

(1.Mechanical Engineering Inst, Dalian Jiaotong University, Dalian 116028, China; 2.Software Technology Inst, Dalian Jiaotong University, Dalian 116028, China; 3.Electrical Information Inst, Dalian Jiaotong University, Dalian 116028, China; 4.Electrical Engineering Inst, Dalian Institute of Science and Technology, Dalian 116052, China)

Abstract: In the circumstance where both the delay model and the controlled object model were unknown in networked control systems, a class of networked predictive control systems based on improved BP network were studied. For the problem of obtaining the hidden layer nodes number of BP network, a rapid calculation method was proposed. For the problem of avoiding local optimum of BP network, a hybrid learning method was proposed. A off-line BP network model was proposed for coping with the problem of the delay prediction based on the above algorithms. For the problem of the linear and nonlinear control of the networked control systems, a single step prediction controller based on on-line BP network was designed. The simulation results show that the performance of the networked predictive control systems is improved in the running speed, the delay prediction, the linear and nonlinear controls.

Keywords: networked control system; BP network; delay prediction; genetic algorithm; linear controlled object; nonlinear controlled object

引言

网络化控制系统(networked control systems,



收稿日期: 2016-07-28 修回日期: 2016-12-29;
基金项目: 国家自然科学基金(61074029), 大连市计划(2014A11GX006);
作者简介: 李世峰(1987-), 男, 河北唐山, 博士生, 研究方向为机电系统理论与计算机测控技术;
邱占芝(1960-), 女, 辽宁朝阳, 博士, 教授, 博导, 研究方向为网络控制与智能系统。

NCSs)是一种基于网络的控制系统, 是自动化技术与网络通信技术融合的产物, 是一种新型控制系统。与传统控制系统相比, 网络化控制系统具有布线简单、成本低、可扩展性强等特点, 已成功应用于交通^[1]、通信^[2]、医疗、航天等领域。

在网络化控制系统中, 时延预测和控制器设计是需要解决的两个主要问题。文献[3]采用多层感

知器模型对网络化系统中的时延进行预测,并使用机床系统和直流电机系统对算法的有效性进行了验证;文献[4]使用神经网络对PD控制器的参数进行调节,同时使用Smith补偿器对时延进行补偿;文献[5]针对网络化控制系统的信息传输时延,采用带有时间戳的线性神经网络在线对时延进行预测,并设计了模型参考自适应闭环控制器;文献[6]使用小波神经网络对工业以太网时延进行了预测,并将时延预测模型应用于网络化控制系统;文献[7]提出了基于神经网络的误差跟踪方法,并将其应用于非线性网络化控制系统;文献[8]使用自适应神经网络对带时延的随机非线性系统进行控制,并将其应用于化学循环系统;文献[9]提出了一类基于径向基网络的控制系统,其中采用构造Lyapunov-Krasovskii函数的方式对时延进行了补偿;文献[10]使用神经网络对PID控制器的参数进行了整定,并在此基础上设计了直流电机控制系统;文献[11]使用神经网络对四冲程柴油机喷射过程进行了控制,并建立了开发平台;文献[12]使用神经网络对电动车的V带无级变速器系统进行了控制,并使用实物模型进行了验证。

目前,同时将BP神经网络应用于网络化控制系统中时延预测和控制器设计的文献罕见报道,这主要是由于以下原因:1)BP网络隐含层节点数的求取需要反复试凑,消耗大量时间。2)BP网络存在局部最优问题,需要重复训练,而且离线训练过程会消耗大量时间。本文在针对上述问题进行改进的基础上,提出了一类基于BP网络的网络化预测控制系统,并进行了仿真验证。

1 网络化控制系统中的BP网络模型

1.1 基于改进离线BP网络的时延预测模型

BP网络具有良好的函数逼近特性和泛化能力^[13],由其组成的单步时延预测模型如图1所示。

典型的BP网络存在隐含层节点数求取耗时间问题和局部最优问题,因此,本文在保留了BP网络

基本结构的基础上,对典型BP网络进行了如下改进:提出了基于计算公式的离线BP网络隐含层节点数求取方法,该方法依赖于蕴含在数据集中的规律而非BP网络的运行结果,能够快速求取隐含层节点数;针对离线BP网络局部最优问题和重复训练问题,提出了基于改进遗传算法(Genetic Algorithm, GA)和LM(Levenberg-Marquardt)算法^[14]的混合学习方法,该方法具有较好的全局搜索能力,能够一次性对BP网络进行训练。




图1 BP网络时延预测模型
Fig. 1 BP network delay prediction model

基于改进BP网络的时延预测模型具体内容如下:

(1) 确定输入和输出属性。BP网络时延预测模型的输入属性为过去时刻的时延,输出为下一时刻的时延,输入、输出属性的阶数由人工测试误差的方式进行确定。

(2) 数据归一化。该模型中的BP网络使用离线方式进行训练,即数据集的最大值和最小值可预先测得,因此采用Min-max方法对数据进行归一化,计算公式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x 为原始个体; x' 是归一化后的个体; x_{\max} 、 x_{\min} 分别为 x 的最大值、最小值。

(3) 激发函数。隐含层激发函数为双曲正切函数,计算公式为:

$$\text{hidt} = \frac{2}{(1 + e^{-2\text{hidt}})} - 1 \quad (2)$$

式中: hid_y 为隐含层输出; hid_x 为隐含层输入。

输出层激发函数为线性激发函数, 计算公式为:

$$out_y = out_x \quad (3)$$

式中: out_y 为输出层输出; out_x 为输出层输入。

(4) 确定隐含层节点数。BP 网络隐含层节点数量合适与否, 直接影响着 BP 网络的工作性能, 然而如何确定隐含层节点数目前尚无理论上的指导^[15], 最常用的方法是依靠经验公式法和反复测试法进行确定。

本文针对离线 BP 网络隐含层节点数求取问题, 提出了一种隐含层节点数的计算方法:

分别把每个输入属性的值由小到大进行排序, 并对其进行归一化, 保留两位小数。把每个不同的数字计入横坐标, 将数据集中出现的每个横坐标值的个数计入纵坐标, 去除个数为 0 的纵坐标点, 然后连接各点, 检测图形中的峰值, 记峰值数为 $peaknum_i$ 。设置阈值 b , 如果 $peaknum_i > b$, 则 $classnum_i = peaknum_i$; 如果 $peaknum_i < b$, 则 $classnum_i = 1$ 。根据公式(4)算出 $tclassnum$ 。

$$tclassnum = \prod_{i=1}^M classnum_i \quad (4)$$

式中: $tclassnum$ 为整个数据集需要被划分的类数; $classnum_i$ 为数据集在第 i 个属性轴上的类数。

最后, 根据公式(5)算出隐含层节点数。

$$hidnum = \frac{1}{num} \sqrt[tclassnum]{tclassnum} + a \quad (5)$$

式中: $hidnum$ 为求得的隐含层节点数; num 为 $peaknum_i > b$ 的输入属性个数, 且 $num \geq 1$, a 为针对马尔科夫链模型的加权系数, 若某问题使用马尔科夫链模型建模则按照公式(6)计算 a , 否则 a 取 0。

$$\begin{cases} a = 0, inputnum \leq 2 \\ a = ceil(\sqrt{(inputnum - 2)}), inputnum > 2 \end{cases} \quad (6)$$

$$b = floor(\sqrt{inputnum + outputnum}) \quad (7)$$

式中: $ceil$ 为向正方向取整; $floor$ 为向负方向取整; $inputnum$ 为输入节点数; $outputnum$ 为最简输

出节点数。

上述算法计算出的隐含层节点数不超过经验公式的上下限:

$$l_1 = inputnum - 1 \quad (8)$$

$$l_2 = \sqrt{(inputnum + outputnum)} + c \quad (9)$$

$$l_3 = \log_2 inputnum \quad (10)$$

$$\min(l_1, l_2, l_3) < l < \max(l_1, l_2, l_3) \quad (11)$$

式中: c 为 0~10 之间的整数; l 为实际隐含层节点数。

(5) 学习方法。典型的 BP 网络使用梯度下降法作为权值和阈值的训练方法, 该方法训练速度较慢、容易收敛到局部最优值^[16], 需要反复进行测试。GA 则具有全局寻优并行搜索的特点^[17], 适合解决局部最优问题。但典型 GA 后期收敛较慢且仍在一定程度上存在局部最优问题, 为了有效发挥 GA 的优势, 提出了一种混合算法, 具体内容如下:

1) 确定初始种群数。初始种群数直接决定着算法初值对整个求解空间的覆盖程度, 进而决定了获取最优解的可能性。本文使用维度空间中最复杂的两个维度轴对整个维度空间进行表征, 使用两者的峰值数的乘积作为初始种群数, 使得算法具有根据不同的数据集自动计算 GA 初始种群数的能力。具体求解方法与公式(4)中峰值数的求法类似: 取峰值数(即 $peaknum_i$)最大的两个维度轴为主维度轴, 记其峰值数为 $peaknum_1$ 和 $peaknum_2$, 初始种群数计算公式如下:

$$inipopnum = peaknum_1 \times peaknum_2 \quad (12)$$

式中: $inipopnum$ 应在 10~200 之间。

2) 确定种群进化策略。由公式(12)求得的初始种群数通常高于典型算法, 这虽然增加了初始种群的多样性, 但是也降低了算法的运行效率。因此, 设计了种群数递减、交叉次数递增的种群进化策略。对于种群数, 算法每进化一代, 对种群数进行取偶数再除以 2 操作, 记种群数为 n 。这样做的好处是提高算法的运行速度, 而且相当于为算法设置了终止条件, 因为当种群数降为 1 时将无法进行交叉操作。即便初始种群数取上限, 由于上述除 2

操作,种群数量快速下降,当降为1时,算法只进化了8代,这对交叉操作来说太少了,不能发挥其优势。为了提高交叉效率,使用了小范围竞争交叉算法,交叉次数由1开始,逐代加1,记交叉次数为 m 。具体的做法为使用上一代被选中的两个个体交叉产生新个体后,继续使用这两个个体进行交叉,直到交叉 m 次;然后,保存上一代个体和每两个个体反复交叉生成的适应度最大的个体,按适应度由大到小进行排序;最后,取前 n 个个体进入下一代。

3) 确定 GA 的其他操作。本文选用实数编码方案,GA 中的初始个体即为 BP 网络的初始权值和阈值,个体适应度计算公式如下:

$$fit = \sum \left(\frac{1}{|avalue - pvalue|} \right) \quad (13)$$

式中: fit 为由 BP 网络的权值和阈值组成的个体的适应度; $avalue$ 为期望输出值; $pvalue$ 为预测输出值,两者之差即训练误差。

注:为简便起见,本文中的公式均略去了样本编号。

针对轮盘赌法中高适应度个体丢失问题,本文设计了带梯度加权的轮盘赌法作为选择方法,计算公式如下:

$$p_i = \frac{fit'_i}{\sum_{i=1}^F fit'_i} \quad (14)$$

$$fit'_i = fit \times \left(1 + w_1 \left| \frac{fa - fa_{\min}}{fa_{\max} - fa_{\min}} \right| + w_2 \left| \frac{\nabla f - \nabla f_{\min}}{\nabla f_{\max} - \nabla f_{\min}} \right| \right) \quad (15)$$

式中: p 为个体被选中的概率; i 为个体编号; fit 为当前适应度; fit' 为经加权后的适应度(注:该适应度仅用于选择操作); w_1 和 w_2 为 0-1 之间的常数,反映了对加权系数的重视程度,在本案例中, w_1 和 w_2 均为 0.3, fa 为适应度差值, fa_{\max} 和 fa_{\min} 分别为 fa 的最大值和最小值, ∇f 为局部梯度, ∇f_{\max} 和 ∇f_{\min} 分别为 ∇f 的最大值和最小值。

$$fa = fit - fatherfit \quad (16)$$

$$\nabla f = d_1 + d_2 \quad (17)$$

$$\nabla f \approx 2d_1 = 2sum(\mathbf{E}) / n \quad (18)$$

式中: $fatherfit$ 为 fit 对应的父代个体适应度; d_1 为 BP 网络隐含层到输出层的局部梯度平均值; d_2 为输入层到隐含层的局部梯度平均值; sum 为对矩阵中所有元素进行累加求和; \mathbf{E} 为网络输出的误差矩阵; n 为矩阵中元素个数。由于 d_2 的求取较为耗时,兼顾系统的运行速度,因此取 $\nabla f \approx 2d_1$ 。

交叉方法选用实数交叉,公式如下:

$$\begin{cases} x'_1 = ax_1 + (1-a)x_2 \\ x'_2 = ax_2 + (1-a)x_1 \end{cases} \quad (19)$$

式中: x_1 、 x_2 为原始个体; x'_1 、 x'_2 为经交叉运算后的新个体; a 为在 0-1 之间的随机数。

在该 GA 中,由于父代个体也有机会进入下一代,并不存在“随机洗牌”问题,因此设置交叉率为 100%。由于使用了 LM 算法进行局部搜索,因此未采用变异算子。

4) 使用 LM 算法进行局部搜索。本文中的 GA 用以优化 BP 网络的权值和阈值,该问题要求精度较高,而且单独使用 GA,在寻优后期容易出现摆动、收敛速度慢等问题。为了提高寻优精度和收敛速度,在上述 GA 的种群数降为 1 时,取整个进化过程中适应度最高的个体为最优个体,然后使用 LM 算法对其进行局部搜索。

1.2 基于在线 BP 网络的预测控制器

注:本文中的在线 BP 网络,特指用做在线控制器的 BP 网络,即逐个产生数据,逐个训练数据的 BP 网络。

在线 BP 网络与离线 BP 网络有所不同:

1) 在线 BP 网络数据逐个产生,最大值、最小值和均值未知,因此无法归一化;

2) 在线 BP 网络逐个产生数据,然后修正权值和阈值,没有全局误差指导函数,并非真正的梯度下降法,但也正是因为这个特点,使其在应用于控制器时具有一定抗干扰能力;

3) 在线 BP 网络无法预先获得数据集,因此隐含层节点数无法使用 1.1 节中的方法进行求取。

在网络化控制系统中,在误差允许的范围内,

在线 BP 网络控制器的输入节点数、隐含层节点数和输出节点数要尽可能的小。一方面能够减少在线计算量, 另一方面能够降低维度空间的复杂度, 使在线 BP 网络陷入局部最优的可能性降低。因此, 本文使用单步预测控制器, 计算公式为:

$$u(k) = f_{NMC}(r(k); y(k-1); u(k-1)) \quad (20)$$

式中: $u(k)$ 为当前时刻的控制量; $f_{NMC}()$ 为在线 BP 网络模型; $r(k)$ 为当前参考输入; $y(k-1)$ 和 $u(k-1)$ 分别为前一时刻的被控对象输出和控制量输入。取隐含层节点数等于输入层节点数。

$f_{NMC}()$ 算法流程如下:

1) 输入数据由输入层经隐含层逐层处理, 传向输出层。其中隐含层激发函数为双曲正切函数, 输出层的激发函数为线性函数。

2) 进入反向传播阶段, 隐含层到输出层的权系数调整公式为:

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = \eta \delta_k O_j \quad (21)$$

式中: Δw 为权值调整量; j 为隐含层标号; k 为输出层标号; η 为学习率; δ 为局部梯度; O_j 为隐含层输出。

由于输出层激发函数为线性激发函数, 隐含层到输出层的局部梯度即为期望输出与实际输出之差, 即:

$$\delta_k = e_k \quad (22)$$

输入层到隐含层的权值系数调整公式为:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \delta_j O_i \quad (23)$$

式中: i 为输入层标号; O_i 为输入层输出。

输入层到隐含层局部梯度计算公式为:

$$\delta_j = \left(\sum_{k=1}^L \delta_k w_{jk} \right) f'(net_j) \quad (24)$$

式中: δ_j 为输入层到隐含层的局部梯度; $f'()$ 为对隐含层激发函数求导; net_j 为隐含层输入。隐含层和输出层均采用带附加动量项的权值修正公式:

$$w(k) = w(k-1) + \Delta w(k) + a[w(k-1) - w(k-2)] \quad (25)$$

式中: $w(k)$ 、 $w(k-1)$ 和 $w(k-2)$ 分别为 k 、 $k-1$ 和 $k-2$ 时刻的权值; a 为动量项学习率。

3) 返回第 2) 步, 依据新的样本个体反复调整权值和阈值, 直到算法达到设定条件。

公式(21)中的 δ_k 由超前一步的局部梯度进行替换, 体现了预测控制的思想。其中, 超前一步的局部梯度由被控对象辨识 BP 网络求得。对 BP 网络模型辨识的研究已较为成熟, 在此不再赘述。同时考虑干扰的影响, 还需要使用实测误差进行补偿, 计算公式如下:

$$e_p(k+1) = r(k+1) - y_m(k+1) + he(k) \quad (26)$$

式中: $e_p(k+1)$ 为预测误差; $r(k+1)$ 为参考输入; $y_m(k+1)$ 为预测输出; h 为补偿系数; $e(k)$ 为当前误差。

2 基于 BP 网络的网络化控制系统

系统结构如图 2 所示。

图中: d 为时延; dm 为时延的期望输出; e 为误差; u 为控制量; y 为系统输出; r 为参考输入; $k-1$ 、 k 和 $k+1$ 分别为上一个采样时刻、当前采样时刻和下一个采样时刻。

该网络化控制系统的设计目标和设计参数如下:

1) 设计目标: 针对时延模型和被控对象数学模型已知或未知的网络化控制系统。

2) 被控对象: 适用于线性和非线性被控对象。

3) 时延模型: 适用于固定时延、满足某种概率分布的随机时延和满足马尔科夫链模型的随机时延。

4) 系统结构: 径直结构。

5) 时延预测模型: 改进后的离线 BP 网络模型, 即 1.1 中的内容。

6) 被控对象辨识模型: 基于 LM 算法的离线 BP 网络模型。

7) 控制器: 在线 BP 网络单步预测控制器, 即 1.2 中的内容。

8) 节点驱动方案: 控制器(事件), 执行器(事件), 传感器(周期)。

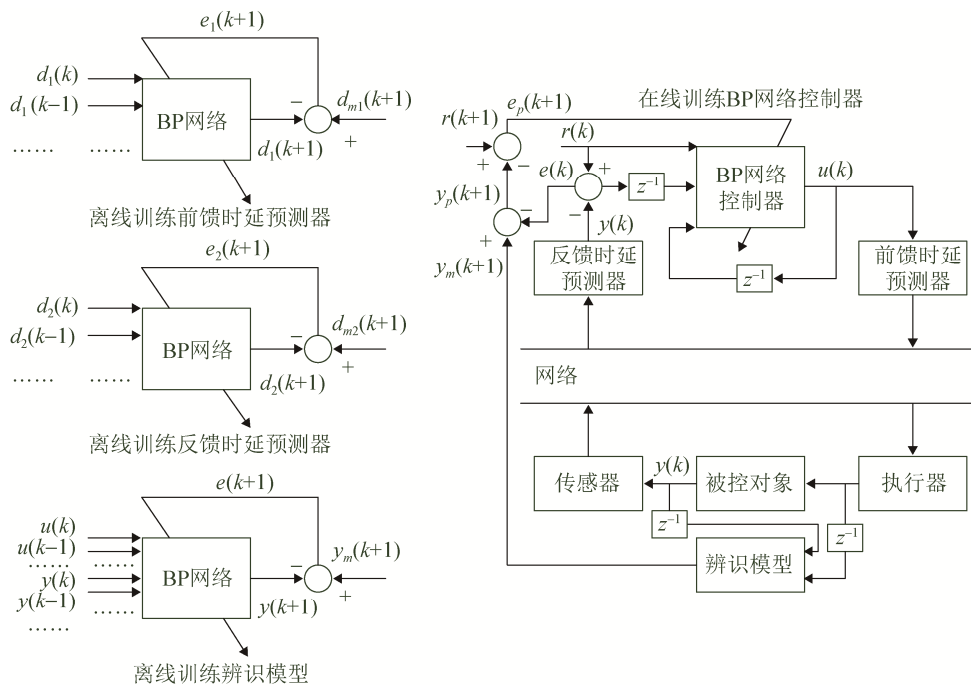


图2 系统结构图

Fig. 2 System structure diagram

系统运行流程图如图3所示。

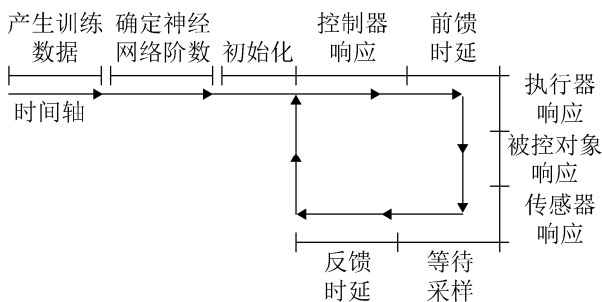


图3 系统运行流程图

Fig. 3 Flowchart of system operation

系统总体运行流程如下：

1) 产生用于离线训练 BP 网络的数据。前馈时延和反馈时延的训练数据为时延的实测数据，采集后用于训练时延预测模型；采集被控对象的输入和输出数据，用以训练辨识模型。

2) 确定 BP 网络模型的阶数。时延预测模型和被控对象辨识模型的阶数与具体的问题有关，需要人工测试误差以确定上述问题的阶数。预测控制器的参数也与具体的问题有关，通常，满足公式：

$$\tau_f + \tau_b + \tau_m < kT \quad (27)$$

式中： τ_f 和 τ_b 分别为前馈时延和反馈时延经过预测和补偿后的误差； τ_m 为执行器到传感器端的时延； k 为步数； T 为采样周期。

在设置合适的采样周期且多数时延预测较为准确的前提下，取 $k=1$ 即可，即单步预测控制。

3) 初始化。初始化包括离线训练前馈时延预测 BP 网络、反馈时延预测 BP 网络、模型辨识 BP 网络和参数初始化。

4) 控制器响应。由 $r(k)$ 、 $y(k-1)$ 和 $u(k-1)$ 计算控制量 $u(k)$ ；根据已经离线训练完成的时延预测模型进行时延预测，然后对时延进行补偿。

5) 系统经前馈时延、前馈时延预测与补偿、执行器响应、被控对象响应、传感器响应、等待采样时间、反馈时延和反馈时延预测与补偿后，返回第 4) 步。

3 系统仿真及结果分析

3.1 时延预测算法有效性验证

将改进离线 BP 网络时延模型应用于 Internet

时延预测, 结果如表 1~2 所示。

表 1 随机前馈短时延预测结果

Tab. 1 Prediction results of random feedforward short delay

模型	隐节点数	求隐节点所需时间/s	训练所需时间/s	预测误差均值/ms
BP 网络	6	925.2	27.7	0.87
GA-BP	6	925.2	13.7	0.61
改进 BP	5	0.8	7.1	0.57

表 2 随机前馈长时延预测结果

Tab. 2 Prediction results of random feedforward long delay

模型	隐节点数	求隐节点所需时间/s	训练所需时间/s	预测误差均值/ms
BP 网络	7	731.8	28.3	1.13
GA-BP	7	731.8	13.0	0.75
改进 BP	6	0.9	8.5	0.70

其中, 数据集训练样本数为 1 200; BP 网络模型隐含层节点数求取方法为经验公式法加反复测试法, 训练方法为梯度下降法, 学习率为 0.1, 上限训练次数 100, 训练时间为 10 次重复训练的累计时间, 预测误差为 10 次重复训练中最低一次的预测误差; GA-BP 模型隐含层节点数求取方法同上, 初始种群数 20, 进化次数 10, 交叉率 0.4, 变异率 0.01, 学习率 0.1, LM 算法上限训练次数 30, 训练时间和预测误差均为单次运算; 改进 BP 模型即本文中的方法, 学习率、上限训练次数和算法运算次数同 GA-BP 模型。

短时延和长时延的定义如下^[18]: 若网络诱导时延在区间 $[0, a]$ 分布, 且 $a < T$, 则称这样的网络诱导时延为短时延; 若网络诱导时延在区间 $[0, a]$ 分布, 且 $a > T$, 则称这样的网络诱导时延为长时延。其中, T 为采样周期。

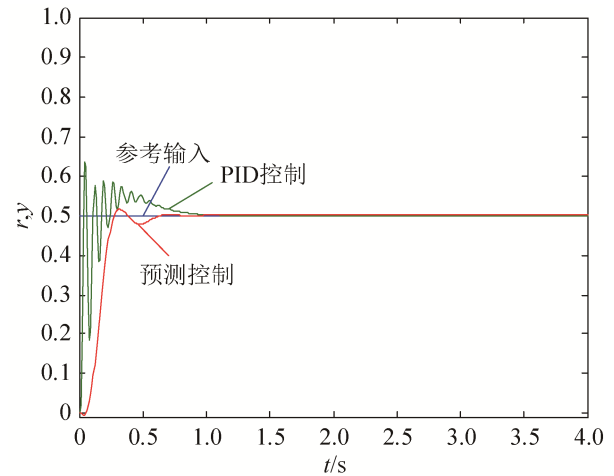
由表 1~2 可以看出, 改进后的 BP 网络时延预测模型预测精度较好, 且整体运行速度较两种典型方法有明显优势。

3.2 应用于线性/非线性被控对象


将该网络化控制系统应用于如下线性被控对象^[19]。

$$G(s) = \frac{523500}{s^3 + 87.35s^2 + 10470s} \quad (28)$$

时延类型为 Internet 时延, 网络节点优先级固定, 采样周期 0.01 s, 网络参数设置同 3.1 节。仿真结果如图 4 所示。



(a) 随机短时延



(b) 随机长时延

图 4 算法控制性能对比:

Fig. 4 Control performance comparison of the algorithms

对比图 4(a)和图 4(b)中的 PID 控制曲线可以看出, 随着时延的增加, PID 控制的超调量和调节时间均有所增加。由图 4 中的预测控制曲线可以看出, 本文中提出的网络化控制系统可以对含随机 Internet 时延的三阶线性被控对象进行控制, 且超调量和调节时间均优于典型算法。

将该网络化控制系统应用于如下非线性被控对象^[20]:


$$y(k) = \frac{y(k-1)}{1 + y(k-1)^2} + u(k-10)^3 \quad (29)$$

网络参数设置同3.1节,并在 $2s < t < 2.5s$ 内,加入干扰信号:


$$i(k) = 0.3 \times y(k-1) \times rand \quad (30)$$

式中: $rand$ 为在0~1之间符合均匀分布的随机数。

仿真结果如图5所示。



(a) 随机短时延



(b) 随机长时延

图5 算法控制性能对比:

Fig. 5 Control performance comparison of the algorithms

由图5可以看出,PID控制算法对该被控对象的控制效果并不理想。预测控制算法的系统输出在前0.2s内变化较慢,这是由于在线BP网络控制器需要一定时间的训练才能进行有效控制。对比图5a和图5b中的预测控制曲线可以看出,两者略有差异,这是由于BP网络初始权值、阈值的随机性和时延补偿误差造成的。由图5在2s后的曲线可

以看出,该算法具有一定的抗干扰能力。由图5可以看出,对于非线性被控对象,本文中提出的网络化控制系统在随机短时延和随机长时延的情况下均取得了较好的控制效果。

4 结论

在网络化控制系统中,时延预测和控制器设计是两个主要问题。本文从隐含层节点数求取和学习方法两个方面对BP网络进行了改进,提升了算法的运算速度和预测精度,并将其应用于解决时延预测问题。针对线性和非线性控制问题,设计了基于在线BP网络的单步预测控制器。仿真结果表明:对于线性和非线性被控对象,该网络化预测控制系统在随机短时延和随机长时延的情况下均取得了良好的控制效果。

参考文献:

- [1] Alavi S M, Walsh M J, Hayes M J. Robust Distributed Active Power Control Technique for IEEE 802.15.4 Wireless Sensor Networks - A Quantitative Feedback Theory Approach[J]. Control Engineering Practice (S0967-0661), 2009, 17(7): 805-814.
- [2] Kim D S, Choi D H, Mohapatra P. Real-time Scheduling Method for Networked Discrete Control Systems[J]. Control Engineering Practice (S0967-0661), 2009, 17(5): 564-570.
- [3] Rahmani B, Markazi A H D. Networked Control of Industrial Automation Systems - A New Predictive Method[J]. International Journal of Advanced Manufacturing Technology (S1433-3015), 2012, 58: 803-815.
- [4] 黄丽莲, 陈瑾. 基于Smith补偿与神经网络的网络控制系统 PD 控制[J]. 系统工程与电子技术, 2012, 34(9), 1884-1888.
Huang Lilian, Chen Jin. PD Control of Networked Control System Based on Smith Compensation and Neural Network[J]. Systems Engineering and Electronics, 2012, 34(9), 1884-1888.
- [5] 于晓明, 蒋静坪. 基于神经网络延时预测的自适应网络控制系统[J]. 浙江大学学报(工学版), 2012, 46(2), 194-198.
Yu Xiaoming, Jiang Jingping. Adaptive Networked Control System Based on Delay Prediction Using Neural

- Network[J]. Journal of Zhejiang University (Engineering Science), 2012, 46(2): 194-198.
- [6] 刘达, 李木国, 杜海. 基于小波神经网络的工业以太网延时预测控制[J]. 大连理工大学学报, 2014, 54(2): 246-250.
Liu Da, Li Mugu, Du Hai. Industrial Ethernet Delay Predictive Control Based on Wavelet Neural Network [J]. Journal of Dalian University of Technology, 2014, 54(2): 246-250.
- [7] Zhang J H, Wang H. Minimum Entropy Control of Nonlinear ARMA Systems over a Communication Network[J]. Neural Computing & Applications (S0941-0643), 2008, 17(4): 385-390.
- [8] Li D J, Zhang J, Cui Y, et al. Intelligent Control of Nonlinear Systems with Application to Chemical Reactor Recycle[J]. Neural Computing & Applications (S0941-0643), 2013, 23: 1495-1502.
- [9] Ji G. Adaptive Neural Network Dynamic Surface Control for Perturbed Nonlinear Time-delay Systems[J]. International Journal of Automation and Computing (S1476-8186), 2012, 9(2): 135-141.
- [10] Yuan X F, Wang Y N. Neural Networks Based Self-learning PID Control of Electronic Throttle[J]. Nonlinear Dyn (S0924-090X), 2009, 55: 385-393.
- [11] Yilmaz S, Bilgin M Z. Modeling and Simulation of Injection Control System on a Four-stroke Type Diesel Engine Development Platform Using Artificial Neural Networks[J]. Neural Computing & Applications (S0941-0643), 2013, 22: 1713-1725.
- [12] Lin C H. Dynamic Control of V-belt Continuously Variable Transmission-driven Electric Scooter Using Hybrid Modified Recurrent Legendre Neural Network Control System[J]. Nonlinear Dyn (S0924-090X), 2015, 79(2): 787-808.
- [13] 刘风华, 谢乃明. 小样本、贫信息下民用飞机费用估算模型及算法[J]. 系统仿真学报, 2014, 26(3): 687-691.
Liu Fenghua, Xie Naiming. Civilian Aircraft Cost Estimation Model and Algorithm Based on Small Sample and Poor Information[J]. Journal of System Simulation, 2014, 26(3): 687-691.
- [14] Behling R, Fischer A, Herrich M, et al. A Levenberg-Marquardt Method with Approximate Projections[J]. Computational Optimization and Applications (S0926-6003), 2014, 59: 5-26.
- [15] Pizzileo B, Li K, Irwin G W, et al. Improved Structure Optimization for Fuzzy-Neural Networks[J]. IEEE Transactions on Fuzzy Systems (S1063-6706), 2012, 20(6): 1076-1089.
- [16] Peng Z Q, Cao C, Huang J Y, et al. Seismic Signal Recognition Using Improved BP Neural Network and Combined Feature Extraction Method[J]. Journal of Central South University (S2095-2899), 2014, 21(5): 1898-1906.
- [17] 邵克勇, 李鑫, 邱跃峰. 模仿二倍体繁殖的改进遗传算法[J]. 系统仿真学报, 2012, 24(4): 816-820.
Sao Keyong, Li Xin, Qiu Yuefeng, et al. Improved GA Based on Imitating Diploidic Reproduction[J]. Journal of System Simulation, 2012, 24(4): 816-820.
- [18] Zhang W, Branicky M S, Phillips S M. Stability of Network Control Systems[J]. IEEE Control Systems (S1066-033X), 2001, 21(1): 84-99.
- [19] 刘金琨. 先进PID控制MATLAB仿真 [M] (3版). 北京: 电子工业出版社, 2011: 59-60.
Liu Jinkun. MATLAB Simulation of Advanced PID Control [M] (Third Edition). Beijing: Electronic Industry Press, 2011: 59-60.
- [20] 韩敏. 基于微粒群的神经网络预测控制理论及应用[M]. 北京: 中国水利水电出版社, 2013: 204-205.
Han Min. Neural Network Predictive Control Theory and Application Based on Particle Swarm[M]. Beijing: China Water&Power Press, 2013: 204-205.