

1-4-2019

Modeling and Simulation of PID Networked Control Systems Based on Neural Network

Zhanzhi Qiu

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

Shifeng Li

1. Mechanical Engineering Inst, Dalian Jiaotong University, Dalian 116028, 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 Paper 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 PID Networked Control Systems Based on Neural Network

Abstract

Abstract: According to the problems of the delay compensation and PID parameters tuning of networked control systems, *a class of rapid PID networked control systems based on improved BP network was proposed*. Considering the problems of obtaining hidden layer nodes number and local optimum of the BP network delay prediction model, *a calculation method was proposed to obtain hidden layer nodes number, and an improved genetic algorithm was proposed to train the BP network*. Considering the problems of integral saturation, parameters tuning and model mismatch of the PID network control systems, *a PID parameter adjuster was designed based on on-line BP network*. The simulation results show that this system has the advantage of rapid running speed, coping model mismatch, and good control performance with random short delay or random long delay.

Keywords

networked control systems, delay predication, PID control, BP network, genetic algorithm

Recommended Citation

Qiu Zhanzhi, Li Shifeng. Modeling and Simulation of PID Networked Control Systems Based on Neural Network[J]. Journal of System Simulation, 2018, 30(4): 1423-1432.

基于神经网络的PID网络化控制系统建模与仿真

邱占芝^{1,2}, 李世峰¹

(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)

摘要: 针对网络化控制系统中的时延补偿问题和PID控制器参数整定问题, 提出了一类基于改进BP网络的快速PID网络化控制系统。考虑BP网络时延预测模型求取隐含层节点数耗时问题和训练方法的局部最优问题, 分别提出了基于计算公式的隐含层节点数求取方法和基于改进遗传算法的BP网络训练方法; 考虑PID网络化控制系统中的积分饱和问题、控制器参数整定问题和应对模型失配的能力, 设计了基于在线BP网络的PID参数调节器。仿真结果表明: 该系统运行速度较快, 具有应对模型失配的能力, 且在随机短时延和随机长时延情况下均有良好的控制性能。

关键词: 网络化控制系统; 时延预测; PID控制; BP网络; 遗传算法

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X(2018)04-1423-10

DOI: 10.16182/j.issn1004731x.joss.201804026

Modeling and Simulation of PID Networked Control Systems Based on Neural Network

Qiu Zhanzhi^{1,2}, Li Shifeng¹

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

2. Software Technology Inst, Dalian Jiaotong University, Dalian 116028, China)

Abstract: According to the problems of the delay compensation and PID parameters tuning of networked control systems, a class of rapid PID networked control systems based on improved BP network was proposed. Considering the problems of obtaining hidden layer nodes number and local optimum of the BP network delay prediction model, a calculation method was proposed to obtain hidden layer nodes number, and an improved genetic algorithm was proposed to train the BP network. Considering the problems of integral saturation, parameters tuning and model mismatch of the PID network control systems, a PID parameter adjuster was designed based on on-line BP network. The simulation results show that this system has the advantage of rapid running speed, coping model mismatch, and good control performance with random short delay or random long delay.

Keywords: networked control systems; delay prediction; PID control; BP network; genetic algorithm

引言

网络化控制系统(Networked Control Systems, NCSs)是一种基于网络的控制系统, 是自



收稿日期: 2016-05-20 修回日期: 2016-11-11;
基金项目: 国家自然科学基金(61074029), 大连市计划(2014A11GX006);
作者简介: 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; 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。

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、可扩展性强和易于维护等特点, 已成功应用于通信^[1-2]、交通、医疗、航天等领域。PID控制具有算法简单、鲁棒性强等特点, 到目前为止, 仍是工业过程控制中最为主要的控制形式^[3]。

将PID网络化控制系统应用于实际工程中,

时延补偿和 PID 参数整定是需要解决的两个主要问题。文献[4]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[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[8]通过回波状态网络模型和自回归集成移动平均模型对时延进行预测,其中,使用遗传算法优化回波状态网络的参数;文献[9]使用经过粒子群优化的最小二乘支持向量机对电流时延进行了预测,使用预测值作为实际值对时延进行了补偿,并设计了基于比例积分的广义预测控制器;文献[10]使用内部模型对 PID 参数进行了调节;文献[11]使用 Fruit Fly 优化算法对分数阶模糊 PID 控制器参数进行了调节,并将其应用于对电子节气门的控制;文献[12]重点研究了 CASK 烘烤系统温度控制问题,并针对该问题设计了基于模糊算法的 PID 控制器;文献[13]使用遗传算法对 PID 控制器参数进行在线调节,并将其应用于对工业微波干燥设备的控制。

将 BP(Back Propagation)神经网络与 PID 网络化控制系统相结合,能够有效应对时延补偿问题和 PID 参数整定问题。目前,在网络化控制系统中,同时使用 BP 网络对时延补偿和 PID 参数整定进行研究的文献较少,这主要是由于以下原因:BP 网络存在局部最优问题,需要重复训练,而且训练过程会消耗大量时间;BP 网络隐含层节点数的求取过程消耗大量时间。本文首先对 PID 网络化控制系统中的 BP 网络模型进行了分析和改进;然后提出了基于 BP 网络的快速 PID 网络化控制系统;最后进行了仿真验证。

1 PID 网络化控制系统中的 BP 网络模型

1.1 模型的分析与选择

1.1.1 网络化系统中的在线和离线 BP 网络模型

BP 网络的权值修正方式有两种:在线方式和离线方式。BP 网络的在线权值调整方式又称串行方式,是一种动态训练方法,网络每获得一个样本就计算一次误差并更新权值。该方式无需预先产生数据集,但由于其寻优高度依赖于梯度、难以融入智能算法等问题,使其多用于维度空间较为简单的情况。将其应用于网络化控制系统时,由于其不需要预先产生训练数据,因此初始化所需时间极短,但其训练和调节均在控制器响应部分完成,在线计算量较大,因此不适合采样周期非常短的情况。BP 网络的离线训练方式又称批量方式,网络在获得所有的训练样本后,根据误差函数计算所有样本总误差,然后才会更新权值。该方式能够预先确定网络结构,能够融入智能搜索算法,适合解决复杂问题,但需要预先产生训练数据集。其误差计算公式如下:

$$E = \frac{1}{2} \sum_{k=1}^L (d_k - O_k)^2 \quad (1)$$

式中: E 为误差函数, k 为输出节点编号, d 为期望输出, O 为实际输出。

将离线 BP 网络应用于网络化控制系统时,其需要预先产生训练数据,初始化所需时间较长,但由于仅其调节功能在控制器响应部分完成,在线计算量较低,因此适合采样周期非常短的情况。

1.1.2 网络化系统中的位置式和增量式 PID 控制

在网络化系统条件下,在线 BP 网络适合应用于位置式 PID,却不适合应用于增量式 PID。这是因为增量式 PID 计算公式为 $u(k) = u(k-1) + \Delta u$, 即便没有新的增量 Δu , 仍然存在原有的控制量 $u(k) = u(k-1)$, 这也是增量式 PID 与位置式 PID 的主要区别。根据相关定义,长时延可以理解为有概率会出现超过 1 个采样周期的时延,而当时延超

过1个采样周期, 增量式PID就会使用原有的控制量 $u(k) = u(k-1)$ 进行控制。这个控制量产生是在时延期间, 而非在正常的采样期间, 本不应该存在, 这会对控制性能造成严重干扰。即便进行时延补偿, 也不能保证对每一次传输时延都能进行精确补偿, 出现超过1个采样周期的情况在很多网络化控制系统中是不可避免的。这些时延, 甚至是设备时延都会对增量式PID下的在线BP网络算法有严重干扰, 如图1所示。




图1 在线BP网络应用于增量式PID网络化控制系统
Fig. 1 On-line BP network applied to incremental PID networked control systems

其中被控对象模型为 $G(s) = 400 / (s^2 + 50s)$, 控制器、执行器和传感器的驱动方式依次为事件、事件和周期, 网络节点优先级固定, 采样周期0.01 s。理想系统输出为在不考虑网络时延但不忽略设备时延情况下的系统输出, 实际系统为存在Internet随机短时延和设备时延情况下的系统输出。

短时延和长时延的定义如下^[14]: 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。

由图1可以看出, 网络化控制系统中的网络时延和设备时延均对应用于增量式PID控制的在线BP网络有严重影响。因此, 增量式PID适合使用

离线BP网络进行训练。

本文中设计的网络化控制系统需要具有应对模型失配的能力, 因此选用在线BP网络和位置式PID进行组合作为系统的控制器。对于时延预测和补偿问题, BP网络模型的阶数需要人工测试, 而且往往需要使用两个BP网络(前馈预测和反馈预测), 一般运算量较大, 不适合在线进行。因此本文中的时延预测与补偿模型采用离线BP网络。

1.2 基于快速离线GA-BP网络的时延预测模型

BP网络具有较好的非线性映射能力^[15], 也是当前应用最为广泛的神经网络。本文在保留了典型BP网络基本结构的基础上, 对BP网络的隐含层节点数求取方法和学习方法进行了改进:

1) BP网络的隐含层节点数如何确定目前尚无理论上的指导^[16], 通常采用反复试凑的方法求得, 试凑过程需要反复运行BP网络, 消耗大量时间。本文提出了一种基于计算公式的隐含层节点数求取方法, 该方法无需运行BP网络, 而是通过公式直接计算隐含层节点数, 从而极大的节省了时间。

2) 对于BP网络的学习方法, 典型的GA-BP (Genetic Algorithm - Back Propagation)方法可调参数较多(包括初始种群数, 交叉率, 变异率, GA上限进化次数, BP网络学习率, BP网络上限迭代次数), 无统一的调节方法, 仍然存在局部最优问题, 且运行速度较慢。本文中提出的GA-BP方法仅两个可调参数(BP网络学习率, BP网络上限迭代次数), 其余参数均自适应, 而且由于采用了较大的初始种群数和种群数递减的策略, 使得该算法具有防止局部最优的能力, 且运行速度更快。

在上述改进的基础上提出了一种基于快速离线GA-BP网络的时延预测模型, 算法内容如下:

1) 归一化。数据归一化用以消除指标之间的量纲影响, 本文中的BP网络使用Min-max方法对数据进行归一化, 计算公式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

其中, x 为原始个体, x' 为归一化后的个体, x_{\max} 、 x_{\min} 为 x 的最大值、最小值。

2) 输入属性筛选和输出属性的确定。相关文献表明^[5-6], 网络化控制系统中的时延模型阶数一般不会超过 10, 而且本文中用的是马尔科夫链模型, 总体测试次数最高为 10 次, 因此本文使用人工测试误差的方法对输入属性进行筛选。输出属性数取 1, 即单步时延预测。

3) 隐含层数和隐含层节点数的确定。已经证明, 单隐含层神经网络能够逼近任何有理函数。针对复杂数据集两层 BP 网络精度相比于单层网络略有提高, 但运算时间将大幅提升。本文兼顾算法的快速性, 选用单隐含层 BP 网络。

对于隐含层节点数, 求取方法如下:

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, 检测图形大于阈值 b_1 的峰值, 记峰值数为 $peaknum_i$ 。设置阈值 b_2 , 如果 $peaknum_i > b_2$, 则 $classnum_i = peaknum_i$; 如果 $peaknum_i < b_2$, 则 $classnum_i = 1$ 。根据公式(3)算出 $tclassnum$ 。

$$tclassnum = \prod_{i=1}^M classnum_i \quad (3)$$

其中, $tclassnum$ 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, 阈值 b_1 取 2, 用以屏蔽过小的峰值。

最后, 根据公式(4)算出隐含层节点数。

$$hidnum = \frac{1}{num} \sqrt[tclassnum]{tclassnum} + a \quad (4)$$

其中, $hidnum$ 为求得的隐含层节点数, num 为 $peaknum_i > b_2$ 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(5)计算 a , 否则 a 取 0。

$$a = ceil(\sqrt{inputnum}) \quad (5)$$

$$b_2 = floor(\sqrt{inputnum + outputnum}) \quad (6)$$

其中, $ceil$ 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:

$$l_1 = 4\sqrt{inputnum + outputnum} \quad (7)$$

$$l_2 = \sqrt{(inputnum + outputnum)} + c \quad (8)$$

$$\min(l_1, l_2) < l < \max(l_1, l_2) \quad (9)$$

其中, c 为 0-10 之间的常数, l 为实际隐含层节点数。

参数设置及解释:

归一化与保留小数。归一化后保留小数的位数决定了该方法能够处理隐含层节点数的上限。对于理想数据集, 若保留 1 位小数, 则在横坐标轴上出现的数据最多为 0, 0.1, 0.21 共 11 个, 也就是说最多能出现 5 个峰值, 由公式(3)(4)可以算得隐含层节点数上限为 5, 若保留 2 位小数, 则隐含层节点数上限为 50, 保留 3 位小数上限为 500, 以此类推。由经验可知, 隐含层节点数一般小于 50, 因此保留两位小数即可, 若求得的隐含层节点数大于 45, 则调整上限。

阈值 b_1 用于去除高度小于等于 b_1 的峰值, 取值范围为 2~5。在本文中 b_1 取 2, 也就是说, 对类似于“121”“1221”这类小于等于 2 的峰值进行了屏蔽, 使其不计入 $classnum_i$ 。这是因为 $classnum_i$ 为数据集在第 i 个属性轴上的类数, 或者说是聚类中心数, 而把小于等于 b_1 的峰值看作是噪声, 进行去除。

对样本数据进行分类的类数不仅与数据本身的分布有关, 还与先验知识有关, 因此, 设置阈值 b_2 。本文中的输出节点数均对应于二进制最简编码方案, 例如对于经典的鸢尾花数据集, 需要把它分为 3 类, 则输出节点数为 2。

4) 激发函数。大量实验证明^[17], 在其他条件同等的情况下, 隐含层激发函数为双曲正切函数时取得的实验效果较好。因此隐含层激发函数取双曲正切函数, 计算公式如下:

$$hid_y = \frac{2}{(1 + \exp(-2hid_x))} - 1 \quad (10)$$

其中, 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:

$$out_y = out_x \quad (11)$$

其中, out_y 为输出层输出, out_x 为输出层输入。

5) 训练方法。

基于改进 GA 的 BP 网络训练方法算法流程如图 2 所示。

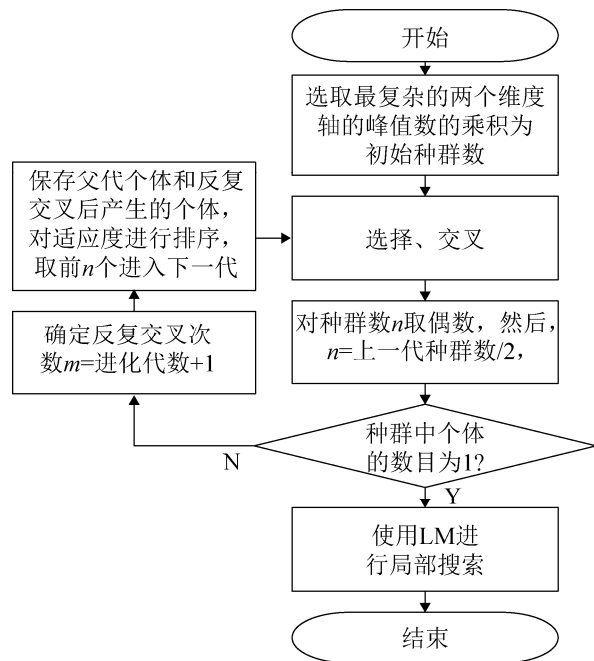


图 2 基于改进 GA 的 BP 网络训练算法流程图
Fig. 2 Training algorithm flowchart of BP network based on improved GA

初始种群数直接决定着初值对整个求解空间的覆盖程度, 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。求取方法如下: 取公式(3)中峰值数(即 $peaknum_i$)最大的两个维度轴为主维度轴, 记其峰值数为 x_1 、 x_2 , 初始种群数计算公式如下:

$$inipopnum = x_1 \times x_2 \quad (12)$$

其中, 若数据集只有一个维度则 $x_2=1$, $inipopnum$ 应在 10~200 之间。

由公式(12)求得的初始种群数通常较高, 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, 在本文中, 算法每进化一代, 对种群数进行向变大方向取偶数, 再除以 2 操作, 记种群数为 n 。这样做的优势在于提高算法的运行速度, 而且相当于为算法设置了终止条件, 因为上述除以 2 操作会使种群中个体的数量持续减少, 当种群数降为 1 时将无法进行交叉操作。

即便初始种群数为 200(即上限), 由于上述除以 2 操作, 算法也只进化 8 代, 这对交叉操作来说太少了, 不能发挥其优势。因此使用了反复交叉算法, 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个体进行反复交叉, 即使使用上一代个体交叉产生新个体后, 继续使用上一代个体而非新生成的个体进行交叉, 直到交叉 m 次; 然后, 保存上一代个体和交叉生成的全部个体, 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。

本文选用实数编码方案, 主要考虑实数编码方案较二进制编码方案具有更高的精度, 其次实数编码方案避免了编码、解码的过程, 使算法更加简洁。GA 中的初始个体即为 BP 网络的初始权值和阈值, 个体适应度公式如下:

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

式中: $fitness$ 为个体的适应度, 个体即 BP 网络的权值和阈值, $avalue$ 为 BP 网络在该个体下的期望输出值, $pvalue$ 为 BP 网络在该个体下的预测输出值, 两者之差即训练误差。

选择方案选用轮盘赌法, 即基于适应度比例的选择策略, 如公式(14):

$$p_j = f_j / \sum_{j=1}^n f_j \quad (14)$$

式中: p_j 为个体被选择的概率, j 为个体编号, f_j 为个体适应度。

交叉方案选用算术交叉, 如公式(15):

$$\begin{cases} x_1' = ax_1 + (1-a)x_2 \\ x_2' = ax_2 + (1-a)x_1 \end{cases} \quad (15)$$

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[0,1]之间的随机数。

在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(Levenberg Marquardt)算法进行局部搜索，因此未采用变异算子。

本文中使用的GA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，在后期寻优容易出现摆动、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。

1.3 基于在线BP网络的PID参数调节器

典型的PID算法计算公式如下：

$$u(k) = k_p e(k) + k_i \sum_{j=0}^k e(j)T + k_d \frac{e(k) - e(k-1)}{T} \quad (16)$$

由公式(16)可以看出，典型PID的积分项从初始状态一直累加误差，容易造成积分饱和，这在应用于很多系统中时是不合理的。本文考虑积分饱和问题，采用 $error(k-1) + error(k-2)$ 来代替 $\sum_{j=0}^k e(k)$ 算子进行运算。其中 $error(k-1)$ 和 $error(k-2)$ 分别为系统前一个和两个采样周期的误差。

典型的PID参数调节方法有响应曲线法和临界比例度法。响应曲线法需要对系统进行开环试验，因此其为离线算法，而且开环控制受干扰影响较大，容易产生误差。而临界比例度法也存在一定问题，其在应用于某些系统时获得临界震荡曲线较为困难，需要消耗大量时间。

本文设计了具有PID参数自调节能力和应对模型失配能力的在线BP网络PID参数调节算法，算法流程如下：

- 1) 参数初始化。
- 2) 计算当前时刻误差 $e(k) = r(k) - y(k)$ 。其中 $r(k)$ 为当前时刻的参考输入， $y(k)$ 为系统当前时

刻的输出。

3) 确定在线BP网络输入输出为 $[kp(k), ki(k), kd(k)] = f_{NN}[r(k), y(k), error(k)]$ 。其中 $f_{NN}[]$ 为BP网络算法。

4) 设在线BP网络输入为 $[r(k), y(k), error(k)] = [O_1(k), O_2(k), O_3(k)]$ ，即 $O_i(k)$ 。其中， i 为输入节点编号。

5) 输入数据经隐含层，传向输出层。隐含层输入为 $net_j(k) = \sum_{i=1}^M w_{ij}(k)O_i(k)$ ，其中 w_{ij} 为输入层到隐含层的权值。隐含层节点的输出为 $O_j(k) = f(net_j(k))$ ，其中 $f()$ 为双曲正切激发函数， j 为隐含层节点编号。输出层输入为 $net_k(k) = \sum w_{jk}(k)O_j(k)$ ，其中 k 为输出层节点编号。输出层激发函数为线性激发函数，即输出层节点输出为 $O_k = net_k$ 。

6) 计算控制量 $u(k)$ 。

$$x1 = error(k) \quad (17)$$

$$x2 = error(k-1) + error(k-2) \quad (18)$$

$$x3 = error(k) - error(k-1) \quad (19)$$

$$u(k) = kp \cdot x1 + ki \cdot x2 + kd \cdot x3 \quad (20)$$

7) 算法进入反向传播阶段，其隐含层到输出层权值系数调整公式为：

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

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。

输入层到隐含层权值系数调整公式为：

$$\Delta w_{ij}(k) = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \delta_j(k) O_i(k) \quad (22)$$

式中： i 为输入层标号， O_i 为隐含层输出。

隐含层局部梯度计算公式为：

$$\delta_j(k) = \left(\sum_{k=1}^L \delta_k(k) w_{jk}(k) \right) f'(net_j(k)) \quad (23)$$

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。

隐含层和输出层权值修正公式为:

$$w(k) = w(k-1) + \Delta w(k) \quad (24)$$

8) 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。

2 基于 BP 网络的快速 PID 网络化控制系统

系统结构如图 3 所示。

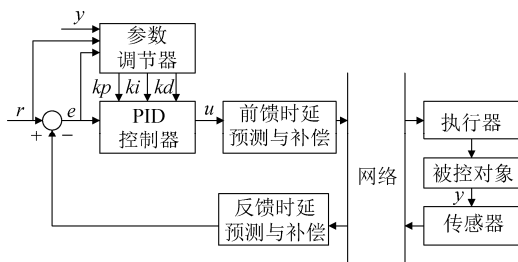


图 3 系统结构图

Fig. 3 The structure diagram of system

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: 该系统为快速线性网络化控制系统, 并具有 PID 控制器参数自适应和应对模型失配的能力。

2) 被控对象: 适用于线性被控对象。

3) 时延类型: 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) 控制器: 基于在线 BP 网络的 PID 控制器, 即使用 1.3 节中参数调节方法的 PID 控制器。

6) 时延模型: 基于快速离线 GA-BP 网络的时延预测模型, 即 1.2 节中提出的模型。

7) 节点驱动方案: 控制器(事件), 执行器(事件), 传感器(周期)。

系统运行流程图如图 4 所示。

系统运行流程如下:

1) 产生训练数据。前馈时延和反馈时延的训练数据为时延的实测数据, 产生的数据用来训练 1.2 节中提出的时延预测模型。

2) 确定模型的阶数。时延预测模型的阶数与具体的对象有关, 需要人工测试误差以确定其阶数。时延预测模型的训练在初始化部分完成, 预测与补偿在控制器响应部分完成。

3) 初始化。初始化包括训练前馈时延预测模型、反馈时延预测模型和参数初始化。

4) 控制器响应。根据 1.3 节中方法在线计算控制量 $u(k)$, 使用在第 3)步中训练好的时延模型对前馈时延和反馈时延进行预测、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、反馈时延预测与补偿后, 返回第 4) 步。




图 4 系统运行流程图

Fig. 4 Flowchart of system operation

3 仿真实验与结果分析

取前馈短时延和前馈长时延训练数据各 1 200 组对时延预测模型进行离线训练, 其中时延类型为 Internet 时延。典型 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, 数据集划分方案为 10 次 10 折交叉验证, 学习率为 0.1, 上限迭代次数 100; 典型 GA-BP 模型隐含层节点数求取方法同上, 训练方法为典型 GA 加 LM 算法, 初始种群数 20, 进化代数 20, 交叉率 0.4, 变异率 0.01, 学习率 0.1, 上限迭代次数 50; 快速 GA-BP 模型即本文中的方法, 学习率为 0.1, 上限迭代次数 50, 预测结果见表 1 和表 2。

其中, 典型 BP 网络的训练时间为 10 次重复训练的累积时间, 预测误差为 10 次重复训练中最低一次的预测误差。两种 GA-BP 模型的预测误差为单次运算。

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
典型 BP 网络模型	6	938	27	0.87
典型 GA-BP 模型	6	938	25	0.59
快速 GA-BP 模型	4	1	5	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
典型 BP 网络模型	7	745	28	1.07
典型 GA-BP 模型	7	745	26	0.75
快速 GA-BP 模型	5	1	7	0.72

本文中的学习方法通过数据集信息以及自适应策略减少参数,因此只剩下2个参数(BP网络学习率,上限迭代次数),其余参数均为自适应。学习率,上限迭代次数均为BP网络固有参数,取值效果依赖于具体的问题,目前一般采取经验选取。学习率一般取0.05~0.5,LM算法的上限迭代次数取30~200。本文中的算法由于已经使用GA进行了全局搜索,上述两个参数仅用于局部搜索,因此均取小一些。

由表1和表2可以看出,对于时延预测问题,本文中的算法相较于典型BP网络模型在运算速度和运算精度上均具有明显的优势,相较于典型GA-BP模型运算速度有明显优势且预测精度稍有提高。

使用上述快速GA-BP模型对反馈短时延和反馈长时延进行预测和补偿。然后,设线性被控对象模型为^[18]:

$$\begin{cases} G(s) = \frac{400}{s^2 + 50s}, t \leq 2.5 \text{ s} \\ G(s) = \frac{800}{s^2 + 50s}, t > 2.5 \text{ s} \end{cases} \quad (25)$$

式中:节点优先级固定,采样周期0.01s,在系统运行第2.5s时,被控对象模型参数发生突变,用来模拟设备发生故障,出现模型失配的情况。分别对无时延情况下的常规PID,有时延但不带时延补偿情况下的常规PID,有时延且带时延补偿下的常规PID和本文中的在线PID算法进行仿真,如图5~7所示。

由图5、图6(a)和图6(b)对比可以看出,短时延对系统的控制性能有影响,但影响较小,仅超调量和调节时间稍有增加,时延补偿效果并不明显。由图5、图7(a)和图7(b)对比可以看出,长时延对系统的控制性能有严重影响,经过时延补偿后的常规PID控制性能有明显的提升,即本文中的时延预测与补偿算法在长时延情况下的效果非常明显。由图6(c)和图7(c)在0~0.5s内的曲线可以看出,控制曲线在运行初期变化较为缓慢,这是因为BP网络需要对一定量的样本进行学习后才能进行有效控制。由图6(c)和图7(c)在2.5s后的曲线可以看出,本文中设计的算法具有应对模型失配的能力,这是常规PID控制所不具备的。由图6(c)和图7(c)可以看出本文中的算法具有良好的时延补偿功能和控制性能。







图5 无时延情况下的常规PID控制
Fig. 5 Conventional PID control without network delay



(a) 存在短时延情况下的常规 PID 控制




(b) 带时延补偿的常规 PID 控制




(c) 带时延补偿的在线 PID 控制

图 6 随机短时延情况下算法性能对比


Fig. 6 Performance comparison of the algorithms with random short delay



(a) 存在长时延情况下的常规 PID 控制



(b) 带时延补偿的常规 PID 控制



(c) 带时延补偿的在线 PID 控制

图 7 随机长时延情况下算法性能对比:

Fig. 7 Performance comparison of the algorithms with random long delay

4 结论

在 PID 网络化控制系统中, 时延补偿和 PID 参数整定是两个主要问题。本文提出了一种快速离

线 GA-BP 网络模型对时延进行了预测和补偿, 其运算速度和精度较典型方法均有明显提升。针对 PID 参数整定问题, 设计了基于在线 BP 网络的 PID

参数调节器。在上述改进的基础上提出了基于神经网络的快速PID网络化控制系统。仿真结果表明,该系统运行速度较快,具有应对模型失配的能力,且在随机短时延和随机长时延情况下均有良好的控制性能。

参考文献:

- [1] S M Alavi, M J Walsh, M J Hayes. 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] D S Kim, D H Choi, P Mohapatra. Real-time Scheduling Method for Networked Discrete Control Systems [J]. *Control Engineering Practice* (S0967-0661), 2009, 17(5): 564-570.
- [3] 侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望[J]. *自动化学报*, 2009, 35(6): 650-667.
Hou Zhongsheng, Xu Jianxin. On Data-driven Control Theory: the State of the Art and Perspective [J]. *Acta Automatica Sinica*, 2009, 35(6): 650-667.
- [4] Rahmani B, Markazi A H D. Networked Control of Industrial Automation Systems-a New Predictive Method [J]. *International Journal of Advanced Manufacturing Technology* (S0268-3768), 2012, 58(5/6/7/8): 803-815.
- [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 Muguo, 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] G Ji. 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.
- [8] Z D Tian, X W Gao, K Li. A Hybrid Time-delay Prediction Method for Networked Control System [J]. *International Journal of Automation and Computing* (S1476-8186), 2014, 11(1): 19-24.
- [9] Z D Tian, X W Gao, B L Gong, et al. Time-delay Compensation Method for Networked Control System Based on Time-delay Prediction and Implicit PIGPC [J]. *International Journal of Automation and Computing* (S1476-8186), 2015, 12(6): 648-656.
- [10] A T Azar, F E Serrano. Robust IMC-PID Tuning for Cascade Control Systems with Gain and Phase Margin Specifications [J]. *Neural Computing & Applications* (S1433-3058), 2014, 25(5): 983-995.
- [11] S Wang, B Yan. Fruit Fly Optimization Algorithm Based Fractional Order Fuzzy-PID Controller for Electronic Throttle [J]. *Nonlinear Dyn* (S0924-090X), 2013, 73(1/2): 611-619.
- [12] H Tang, G Wang, C Chen, et al. A Hybrid of Fuzzy and PID Controller for EAST AIA CASK Baking System [J]. *Journal of Fusion Energy* (S0164-0313), 2015, 34(1): 1-7.
- [13] B Yang, G Liang, J Peng, et al. Self-adaptive PID Controller of Microwave Drying Rotary Device Tuning On-line by Genetic Algorithms [J]. *Journal of Central South University* (S2095-2899), 2013, 20(10): 2685-2692.
- [14] W Zhang, MS Branicky, SM Phillips. Stability of Network Control Systems [J]. *IEEE Control Systems* (S1066-033X), 2001, 21(1): 84-99.
- [15] 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.
- [16] B Pizzileo, K Li, GW Irwin, et al. Improved Structure Optimization for Fuzzy-Neural Networks [J]. *IEEE Transactions on Fuzzy Systems* (S1063-6706), 2012, 20(6): 1076-1089.
- [17] 史峰, 王小川, 郁磊, 等. MATLAB神经网络30个案例分析[M]. 北京: 北京航空航天大学出版社, 2011: 18-19.
Shi Feng, Wang Xiaochuan, Yu Lei, et al. MATLAB Neural Network 30 Cases Analysis [M]. Beijing: Beihang University Press, 2011: 18-19.
- [18] 刘金琨. 先进PID控制MATLAB仿真 [M]. 3版. 北京: 电子工业出版社, 2011: 25-26.
Liu Jinkun. MATLAB Simulation of Advanced PID Control [M]. 3rd Edition. Beijing: Electronic Industry Press, 2011: 25-26.