

基于遗传算法学习的复合神经网络自适应温度控制系统

李敏远, 都延丽

(西安理工大学 自动化与信息工程学院, 陕西 西安 710048)

摘要: 针对一类温度控制系统中存在的非线性和参数不确定等问题, 提出一种复合神经网络自适应控制结构. 在控制系统中构造了神经网络正模型来再现被控对象的动态特性, 用神经网络控制器实现优化控制律的非线性映射. 文中选用了被控对象 80 组历史数据作为样本集, 并利用遗传算法的全局搜索能力及高效率来训练多层前向神经网络的权系数. 最后用升降温工艺曲线作为输入对温度控制系统进行仿真. 仿真结果表明, 应用遗传算法能够提高神经网络的学习效率, 保证神经网络全局快速收敛, 从而克服了传统的误差反传学习算法的一些缺点. 证明了采用这种神经网络自适应控制结构, 使神经网络控制器的输出可以适应对象参数和环境的变化, 使温度控制系统具有很好的学习和自适应控制能力, 取得了良好的控制效果.

关键词: 神经网络; 遗传算法; 神经网络自适应控制

中图分类号: TP273 **文献标识码:** A

Composite neural networks adaptive control system of temperature based on GA learning

LI Min-yuan, DU Yan-li

(College of Automation and Information Engineering, Xi'an University of Technology, Shaanxi Xi'an 710048, China)

Abstract: A kind of composite neural network adaptive control structure is proposed in this paper with the purpose of tackling problems such as nonlinearity and uncertainty in a temperature control system. The neural network positive model is constructed to represent the dynamic characteristics of the controlled object, and the neural network controller is used to realize the nonlinear mapping of optimal control rules. By taking eighty troops of history data to serve as samples the genetic algorithm with its searching ability and high efficiency is successfully used to train the weights of the multi-layer forward neural network. Then, the raising and falling temperature technics curve is acted as the input to simulate the temperature control system. The simulation results indicate the capability of genetic algorithm in fast learning of neural networks, guaranteeing a rapid global convergence and overcoming some shortcomings of the traditional error back propagation algorithms. It is shown that if this neural network adaptive control structure is applied to the temperature control system, the output of the neural network controller can adapt to changes of the object parameters and environment, and hence the temperature control system will have a nice learning and self-adaptive capability and lead to a good control result.

Key words: neural networks; genetic algorithm; neural networks adaptive control

1 引言(Introduction)

神经网络(neural networks, 简称 NN)的非线性映射逼近和学习能力, 并行信息处理和鲁棒性、容错能力, 使其在工业控制系统中得到了日益广泛的应用^[1]. 尤其在复杂的非线性对象建模和控制方面, 应用神经网络更是具有极大的优越性.

在建模和控制中使用的神经网络训练算法和结构很多, 例如多层前向神经网络常用 BP(Back Propagation)学习算法来训练网络^[2-4]. BP 算法结构简单、算法稳定, 但学习速度慢且存在局部极小问

题^[4]. 本文利用遗传算法(genetic algorithm, 简称 GA)的全局搜索能力及高效率来学习神经网络的权系数, 并构造复合神经网络的自适应控制结构解决一个实际温控系统中的控制问题, 力求达到良好的性能指标.

2 复合神经网络自适应控制系统(Composite neural networks adaptive control system)

2.1 系统描述(System description)

医药生产行业中的霜、液剂温度控制系统是一典型带有热焓过程的慢变系统^[5]. 纯水站内的冷、热


水介质通过管道输送至加热罐的隔层来对罐内的药剂进行加热、冷却和保温等自动化控制.管道中安装有进出电磁阀及调节阀,通过调整调节阀的开度改变介质的流量来控制介质的温度,经热传导控制药剂的温度.

由于系统中介质管道输送距离远,管道中间阀门较多,被控对象存在着较大的纯滞后.同时,介质经过了加热罐钢壁(导热率 $\lambda_1 \approx 42.8$) 和硬脂类药剂(导热率 $\lambda_2 < 1$) 使药剂温度变化,故对象模型带有小惯性和大惯性环节;此外,加热罐内药剂的种类经常根据生产的需要而发生改变,导热率 λ_2 变化很大,致使对象的大时间常数时常会有变动;而且以介质流量为调节手段控制某个工艺参数的热焓过程从过程动态学的角度看是一种参数非线性过程^[5].因此,该系统被控对象具有纯滞后、大惯性、非线性及参数不确定等特征,很容易产生振荡或较大的超调,应用传统的 PID 控制策略往往很难满足工艺要求的性能指标.神经网络则具有通过学习逼近任意非线性映射的能力,它的特点有望较好地解决系统中存在的非线性和时变不确定问题,故本文对这类过程控制中常见的对象实施神经网络控制.

2.2 神经网络控制结构(Neural networks control structure)

本系统中的神经网络选择为多层前向网络,系统控制结构采用复合神经网络自校正控制(STC)形式,原理如图1所示^[6].

在控制系统中,NNP 是被控对象的神经网络正模型,它采用串并联的辨识结构,由被控对象的输入和输出数据 $u(k)$ 和 $y(k)$ 作为 NNP 神经网络的输入,利用学习算法不断减小网络模型输出 y_m 与被控对象输出 y 的差值 e_1 , 最终达到 NNP 对被控对象的模拟.



t_{sp} ——药剂设定温度 t_{pv} ——药剂温度
图1 复合神经网络自适应控制系统

Fig. 1 Composite neural networks adaptive control system

神经网络控制器(NNC)则实现优化控制律的非线性映射.用神经网络正模型 NNP 来再现被控对象的动态特性,则被控对象输出从 $y(1)$ 运行到 T 时间步 $y(T+1)$ 的过程可以用 NNC 与 NNP 网络的串联结构体现.这样,NNC 可以使用学习算法来减小期望输出 y_d 与模型输出 y_m 的差值 e_2 , 以实现最优控制律的模拟.

3 神经网络正模型(NNP)的学习(Learning of neural networks positive model)

3.1 NNP 的建立(Modelling of NNP)

本系统的被控对象可以采用非线性模型来描述^[6]:

$$y(k) = f[y(k-1), y(k-2), \dots, y(k-n_y), u(k-1), u(k-2), \dots, u(k-n_u)]. \quad (1)$$

其中: $f(\cdot)$ 为未知非线性函数; $y(k)$, $u(k)$ 为被控对象的输出和输入; n_y , n_u 为 $\{y\}$ 和 $\{u\}$ 的阶次.

三层结构的前馈神经网络能以期望的精度逼近任意函数.本系统中,采集被控对象 80 组历史数据 $\{u(k), y(k)\}$ 作为样本集.全部数据进行归一化处理,使 $u(k) \in [0, 1]$, $y(k)$ 由 $0 \sim 100^\circ\text{C}$ 映射到区间 $[0, 1]$.对网络先利用自适应学习速率的 BP 算法进行离线训练,隐层的激励函数为 Tansig 函数,输出层的激励函数为 Purelin 函数,目标函数为误差平方和(取 L_2 范数):

$$J_{e_1} = \frac{1}{2} \sum_{k=1}^n \|y(k) - y_m(k)\|_2 = \frac{1}{2} \sum_{k=1}^n [y(k) - y_m(k)]^2. \quad (2)$$

式中: n 为样本组数, $y_m(k)$ 为神经网络模型输出,学习目标是使 $J_{e_1} \leq \epsilon = 0.002$.

取不同中间层神经元个数,经过实验比较确定神经元个数为 6,网络结构为 2-6-1.

3.2 遗传算法优化神经网络权系数(GA's optimizing weights of neural networks)

遗传算法在一定程度上可以克服 BP 算法的局限性. GA 在寻优过程中是在高维可行解空间随机产生多个起始点并同时开始搜索,由适应度函数来指导搜索方向,因而搜索区域广,搜索效率高.

由遗传算法进行神经网络权系数优化的训练步骤如下:

- 1) 给定神经网络的输入、输出样本集.

2) 确定网络权系数的编码方式、选定遗传操作、设置遗传参数。

3) 以设定的种群规模 N , 随机产生初始种群。

4) 译码种群中每一个体位串, 求得 N 组网络权系数, 得到具有相同结构的 N 个网络。

5) 由输入样本集经前向传播算法, 求得 N 组网络权值对应的 N 个网络输出。

6) 设定网络的目标函数, 将其转换为适应度, 对 N 个网络进行评价。

7) 依据适应度在遗传空间进行选择操作。

8) 依据选定的交叉、变异及有关算法、参数进行相应的操作, 得到新一代种群。

9) 返回步骤 4), 直到满足性能要求, 得到一组优化的权系数。

3.2.1 编码方式(Coding method)

GA 传统的编码方式为二进制编码, 当神经网络的规模稍大时, 染色体个体的长度就会很大, 从而影响遗传算法的效率, 为此本系统采用浮点数编码。

浮点数编码方法使用的是决策变量的真实值, 称真值编码方法。个体的每个基因值用某一范围内的一个浮点数来表示, 个体的编码长度等于其决策变量的个数。本系统中 NNP 网络的权值和阈值共有 25 个变量, 故个体 W 记作

$$W = (w_1, w_2, \dots, w_i, \dots, w_{25}).$$

分布如图 2 所示。




图 2 NNP 权系数分布图

Fig. 2 Distributing graph of weights of NNP

如果给定变量的上下限取值, W 对应的个体表现型如下所示:

$$W = [0.0948, 0.7890, 0.8164, 1.9181, -1.9246, -1.5666, -1.6645, \dots].$$

在浮点数编码方法中, 必须保证基因值在给定的区间范围内, 遗传算法中所使用的交叉、变异等算子必须保证其运算结果所产生的新个体基因在这个限制范围内。当用多个字节来表示一个基因值时, 交叉运算必须在 2 个基因的分界字节处进行。

3.2.2 适应度函数(Fitness function)

将染色体上表示的各权值和阈值分配到给定的 2-6-1 神经网络中, 网络以训练集样本 $\{u(k), y(k)\}$ 为输入, 以 $\{y(k+1)\}$ 为网络期望输出, 运行后返回误差平方和的倒数作为染色体个体的评价函数, 如式(3):

$$f_1 = 1/J_e. \quad (3)$$

3.2.3 遗传操作(Genetic operation)

遗传操作中的选择算法采用标准化几何排序 (normGeomSelect) 的方法^[7]。排序方法按拟和值对个体进行排序, 根据个体的位置分配选择概率。标准化几何排序定义个体的选择概率如式(4):

$$P_i = \frac{q}{1 - (1 - q)^n} (1 - q)^{r-1} (i = 1, 2, \dots, n). \quad (4)$$

其中: q 为最佳个体的选择概率, r 为个体的序列号, n 为种群大小。

针对浮点数编码, 交叉算法采用数学交叉 (arithXover) 和启发式交叉 (heuristicXover) 两种方式^[8]。数学交叉中新的个体是由 2 个父代个体进行线性组合运算而成。假设 2 个个体 X_1, X_2 之间进行算术交叉, a 是 $(0, 1)$ 之间的随机数, 则交叉后所产生的 2 个新个体是

$$\begin{aligned} X_1' &= aX_1 + (1 - a)X_2, \\ X_2' &= (1 - a)X_1 + aX_2. \end{aligned} \quad (5)$$

启发式交叉根据个体的适应度信息产生父本的线性外推。假设父代 X 的适应度大于父代 Y , 启发式交叉可按式(6)进行:

$$\begin{aligned} X' &= X + r(X - Y), \\ Y' &= X. \end{aligned} \quad (6)$$

r 为 $(0, 1)$ 之间的随机数。若 X', Y' 不在解空间内, 则重新产生随机数进行交叉。两种交叉方法结合使用可以增强算法的探测能力。

为保持种群的多样性和防止早熟现象, 需要对原种群中的基因加一随机扰动。本系统中的变异操作采用多元非均匀变异 (multiNonUnifMutation) 策略^[8]产生变异基因来构成新的种群, 即分别对自变量在其解空间进行非均匀变异后, 再随机取一组合

作为变异结果,原理如式(7)和式(8):

$$\begin{aligned} X_i' &= X_i + (b_i - X_i)f(g), r_1 < 0.5, \\ X_i' &= X_i - (X_i - a_i)f(g), r_1 \geq 0.5. \end{aligned} \quad (7)$$

其中

$$f(g) = (r_2(1 - \frac{g}{g_{\max}}))^b. \quad (8)$$

r_1, r_2 为 $[0, 1]$ 之间均匀随机变量, b_i, a_i 分别是变量上、下限, g 为当前进化代数, $g_{\max}$ 为最大进化代数, b 为衡量扰动程度的系统参数.

3.2.4 仿真运行结果(Simulation running results)

应用 MATLAB 中的 GA 工具包编程可以实现浮点式遗传算法学习神经网络正模型权系数过程的仿真.

在程序中,遗传算法的初始种群取 50 个染色体,每个染色体中有 25 个权系数变量,变量范围设为 $[-2, 2]$,终止进化代数为 300 代.遗传操作中标准化几何排序方法的参数 $q = 0.08$,多元非均匀变异的参数 $b = 3$.根据编好的适应度函数程序,运行学习权系数的主程序,经过 5 次的随机实验,得到遗传算法优化权系数的平均时间为 11.855 s.进化过程中适应度数值变化如图 3.可以看出,遗传操作在进化到 200 代时,最佳适值已经达到了 500 以上,即误差平方和达到了 0.002 以下.最终神经网络正模型优化后的最优权系数为

$$\begin{aligned} W = & [-0.0250, -0.4945, 0.1063, -0.3508, \\ & -2.0000, 1.9436, -1.1705, -0.4125, \\ & -0.8530, -0.7575, 1.2607, 0.1525, 0.0880, \\ & 0.3707, -1.7006, 0.6319, 1.3376, 0.6550, \\ & 1.0551, 0.2160, 0.0612, -1.2008, -0.3331, \\ & -1.4483, 1.8813]. \end{aligned}$$




图3 遗传算法学习神经网络正模型

Fig. 3 GA's learning the weights of NNP

表1给出了遗传算法和自适应学习速率BP算法在5次随机实验中的学习时间比较,通过对比可以看出遗传算法优化速度快、学习稳定,收到了良好的效果.

表1 遗传算法与改进BP算法学习时间比较

Table 1 Time comparison of genetic and improved BP algorithm learning

随机实验	1	2	3	4	5	平均时间
学习时间/s						
遗传算法	11.847	11.887	11.867	11.847	11.827	11.855
自适应学习	28	67.517	15.633	75.288	14.761	40.2398
速率BP算法						

系统神经网络正模型的权系数已经通过离线训练得到,在线应用时它们作为NNP的初始权系再通过目标函数进行不断地修正.

4 遗传算法学习神经网络控制器(NNC) (GA's learning the weights of NNC)

4.1 学习过程(Learning period)

在神经网络控制器的设计中,同样采用遗传算法在线调整权值和阈值.NNC的结构设计成3-6-1形式,则权值和阈值共有31个.网络的输入输出见图1.具体学习NNC的过程如下:

1) 开始时,神经网络控制器(NNC)的输入是 $y_d(1)$ 和来自神经网络正模型(NNP)的初始输入 $u(0)$ 和输出 $y_m(0)$.

2) NNC 没有经过训练,故给出不正确的输出 $u(1)$, 所以 NNP 的输出 $y_m(1)$ 也不正确.此时, $y_d(1) - y_m(1)$ 之间的误差通过反向传播过程,被用来调整 NNC 的权值和阈值.

3) 调整完毕后 NNC 输出新的 $u(1)$, 并经过 NNP 的串联输出 $y_m(1)$ 用来作为 NNC 的新输入变量.

4) NNC 新的输入变量又产生新的控制量 $u(2)$, 经过 NNP 产生新值 $y_m(2)$, 再次修正 NNC 的权系数,这个过程一直重复到获得满意的训练结果.

4.2 仿真结果(Simulation results)

染色体仍采用浮点数编码,适应度函数表达式如式(9):

$$f_2 = 1/J_{e_2}, J_{e_2} = \frac{1}{2} \sum_{k=1}^n [y_d(k) - y_m(k)]^2. \quad (9)$$

MATLAB 编程中,初始种群选取 50 个染色体,每个染色体中有 31 个权系数变量,变量范围设为 $[-2, 4]$,终止进化代数为 50 代.遗传操作算子和参数设置同 NNP 的学习.设期望温度值为 80°C ,运行主程序和适应度函数程序后,即得到图4.图中显示了 NNP 的输出即将达到温度设定值时,GA 优化 NNC 权系的适应度数值,最终误差平方和达到 0.003 以下,绝对误差在 0.3°C 以下.




图4 遗传算法学习 NNC 权系的适值曲线

Fig. 4 Fitness graph of GA's learning weights of NNC

用阶跃响应数据构成训练模式,升温输出期望值为 80°C ,降温为 40°C ,采样周期 $T_s = 20\text{ s}$. 运行以上仿真程序后,通过不断调整神经网络控制器的参数,可以获得系统输出值的仿真图如图5.可以看出系统能够及时跟踪设定值的变化,输出量超调较小,达到了良好的控制效果.




图5 系统跟踪温度设定值的仿真曲线

Fig. 5 Simulation graph of system tracking set temperature

5 结语(Conclusion)

本文从工程应用的角度出发,提出了复合神经网络的自适应控制策略,并用于含有纯滞后、非线性、时变不确定特征的实际温度控制系统当中.此结构通过建立神经网络正模型、训练神经网络控制器使系统输出量可以适应对象参数和环境的变化,不断对神经网络权系数进行自动的调整.在神经网络的学习中,本文采取了改进的遗传算法进行优化.仿真结果可以看出这种控制方法兼顾了神经网络的广泛映射能力和遗传算法的快速全局收敛的优点,具有良好的学习和自适应控制的能力,同时编程容易,

便于在实际系统中应用.

参考文献(References):

- [1] 汪朝军,刘艳明.遗传算法和神经网络融合型最优控制器及其在铣削加工参数控制中的应用[J].控制理论与应用,1999,16(4):607-610.
(WANG Chaojun, LIU Yanming. An optimization controller in milling compacting genetic algorithm with neural networks [J]. *Control Theory & Applications*, 1999, 16(4): 607-610.)
- [2] HUANG Sunan, REN Wei. Use of neural fuzzy networks with mixed genetic/gradient algorithm in automated vehicle control [J]. *IEEE Trans on Industrial Electronics*, 1999, 46(6): 1090-1101.
- [3] MANIEZZO V. Genetic evolution of the topology and weight distribution of neural networks [J]. *IEEE Trans on Neural Networks*, 1994, 5(1): 39-52.
- [4] 杨国军,崔平远,李琳琳.遗传算法在神经网络控制中的应用与实现[J].系统仿真学报,2001,13(5):567-570.
(YANG Guojun, CUI Pingyuan, LI Linlin. Applying and realizing of genetic algorithm in neural networks control [J]. *J of System Simulation*, 2001, 13(5): 567-570.)
- [5] 王树青.先进控制技术与应用[M].北京:化学工业出版社,2001.
(WANG Shuqing. *Advanced Control Technology and Application* [M]. Beijing: Chemical Industry Press, 2001.)
- [6] 王科俊,王克成.神经网络建模、预报与控制[M].哈尔滨:哈尔滨工程大学出版社,1996.
(WANG Kejun, WANG Kecheng. *Modelling, Predicting and Controlling of Neural Networks* [M]. Harbin: Harbin University of Technology Press, 1996.)
- [7] JOINES J, HOUCK C. On the use of non-stationary penalty functions to solve nonlinear constrained optimization problems with GAs [C]// *Proc of IEEE Congress on Computational Intelligence*. Orlando: [s. n.], 1994: 579-584.
- [8] MICHALEWICZ Z. *Genetic Algorithms + Data Structures = Evolution Programs* [M]. New York: Springer-Verlag, 1994: 89-120.

作者简介:

李敏远 (1957—),男,西安理工大学自动化与信息工程学院副教授.主要从事智能控制理论与应用以及电源技术的研究工作.
E-mail: rainbowbird@163.com; liminyuan@sohu.com;

都延丽 (1977—),女,西安理工大学自动化学院自动控制专业硕士研究生.主修方向为智能控制理论和应用.