

一种基于过程神经网络的动态系统控制信号求解模型和算法

许少华^{1,2} 庞跃武¹ 何新贵²

(东北石油大学计算机与信息技术学院 大庆 163318)¹ (北京大学信息科学技术学院 北京 100871)²

摘 要 针对非线性动态系统控制问题,提出了一种基于过程神经网络的控制信号求解模型和算法。利用过程神经网络对动态系统时变输入/输出信号的非线性映射机制和对系统过程模态特征的自适应提取能力,建立基于过程神经网络的辨识模型;然后根据所建立的辨识模型、系统控制结构和状态参数之间的关系,构建可满足系统信息传递约束关系的控制信号求解模型。分析了过程神经网络控制模型的信息处理机制,给出了基于GA与LMS相结合的优化求解算法,实验结果验证了模型和算法的有效性。

关键词 动态系统,过程控制,过程神经网络,求解算法,仿真实验

中图分类号 TP183 **文献标识码** A

Control Signal Solving Model and Algorithm of Dynamic System Based on Process Neural Network

XU Shao-hua^{1,2} PANG Yue-wu¹ HE Xin-gui²

(School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China)¹

(School of Electronics Engineering and Computer Science, Peking University, Beijing 100871, China)²

Abstract Aiming at the control problem of nonlinear dynamic system, a control signal solving model and algorithm based on Process Neural Network (PNN) was proposed. First, a system forward identification model based on PNN was set up by using nonlinear transform mechanism and self-adaptive learning ability of PNN to time-varying input-output signals of dynamic system, then according to the established model, the system control structure and the expected output signals, a control signal solving model and algorithm which satisfies system dynamic signal transform mechanism and transfer constraint relation was constructed. The information processing mechanism based on PNN control model was analyzed and the control signal optimize method based on GA coupled with LMS was given. The experiment results verify the feasibility of the model and algorithm.

Keywords Dynamic system, Process control, Process neural network, Solving algorithm, Applications

1 引言

复杂非线性动态系统辨识和过程控制一直是自动控制领域和动态系统仿真领域中的一个重要研究方向。系统控制研究的对象主要是非线性动态系统,要求在给定的控制目标和信号传递关系约束下,利用所获得的系统信息和知识设计控制器,使控制系统满足稳定、精确、鲁棒、实时等性质要求^[1,2]。传统方法在解决系统控制问题时,主要是基于模型的控制,即先要建立被控对象解析的或数值的数学模型,然后根据模型设计控制器。目前,自动控制领域已较完善地解决了线性系统控制的理论和方法,对于非线性系统的控制问题也取得了丰富成果^[3-5]。但随着科学技术的进步和控制技术应用范围的不断扩大,对系统控制的性能也提出了更高的要求。一些工程领域,特别是一些新兴研究领域由于缺乏先验理论和知识,同时某些系统存在较高的复杂性和不确定性,致使难以获得正确的数学模型,对于系统通过数学建模实现有效控制仍有许多理论和技术上的问题尚未得到很好解决^[6-8]。

常规理论和方法无法有效解决一些系统的控制问题,近几年智能控制技术得到重视和发展,为解决非线性系统的控制问题提供了一种新的途径^[9-11]。

人工神经网络所具有的非线性变换机制和自适应学习能力,以及高度的并行计算能力和容错性为非线性系统的辨识和控制提供了一种有效的工具。目前已有许多科技工作者将人工神经网络技术应用于复杂系统的控制问题,并取得了较好的理论和应用结果^[12-16]。2006年,何新贵、许少华等提出和建立了一种连续过程神经网络模型^[17]。该模型的输入/输出以及连接权等都可以是时间函数,具有对动态系统时变输入/输出信号之间非线性关系的直接建模能力,以及对被控系统动力学特性、模态特征变化的自适应学习性质,因此将过程神经网络应用于非线性系统的辨识和过程控制在机制上具有较好的适应性。

本文提出了一种基于过程神经网络(Process Neural Network, PNN)的非线性动态系统控制信号求解模型和算法。根据系统控制结构和反映系统模态变化特征的动态样本数

据,首先建立基于 PNN 的系统正向辨识模型,然后依据系统控制结构和辨识模型构建可满足系统信号传递关系的逆向控制模型,并实现对控制信号的约束求解。文中给出了用于一种典型控制结构信号求解的 PNN 模型,以及基于遗传算法 (Genetic Algorithm, GA) 和最小均方误差 (Least Mean Square, LMS) 算法相结合的优化求解方法。仿真实验结果验证了模型和算法的有效性。

2 非线性动态系统控制模型

非线性动态控制系统有多种模型,这里考虑图 1 所示的一种典型反馈控制结构^[18]。




图 1 一种非线性动态系统控制结构

图 1 中, $r(t)$ 为实际系统 P 的期望输出信号, $u(t)$ 为系统控制器 P^{-1} 输出的过程控制信号, $y(t)$ 为 P 的实际输出信号, $\hat{y}(t)$ 为系统辨识器的输出信号。控制系统可通过辨识算法模块和控制信号求解模块对系统辨识器、控制器的模型结构及性质参数进行求解和修正。

由于系统控制器相当于非线性动态系统的逆向模型,因此控制系统的传递函数 P^{-1} 与实际系统 P 应满足 $P^{-1}P=1$, 其控制精度和鲁棒性取决于系统正向模型(辨识器)和逆向模型(控制器)的信号传递和变换机制。

3 用于系统辨识的过程神经网络模型

基于 PNN 的系统辨识就是要构建一个符合实际系统正向信息变换机制和模态变化特征的 PNN 仿真模型,通过学习系统时变输入/输出信号样本,确定系统 P 的辨识模型 $\hat{P}$, 使其能够正确表达系统的正向动力学特性。

3.1 过程神经元模型

考虑非线性系统输入/输出均为动态信号的情况,设计一种输入/输出均为时变函数的过程神经元模型。过程神经元由时变信号输入、时空二维加权聚合以及阈值激励输出等运算组成,其输入、输出、连接权和阈值等都可以是时间函数。空间聚合算子取为多输入信号加权求和等运算,时间累积算子取为含时间变参积分或其它阶段时间效应累积运算,拓扑结构如图 2 所示。




图 2 时变输入/输出过程神经元

图 2 中, $u_1(t), u_2(t), \dots, u_n(t)$ 为过程神经元的时变输入信号; $w_1(t), w_2(t), \dots, w_n(t)$ 为相应的连接权函数; “ Σ ” 为过程神经元的空间聚合算子, “ $\int$ ” 为过程神经元的阶段时间效应累积算子, $f(\cdot)$ 为激励函数, $y(t)$ 为输出函数。

若过程神经元的时间累积算子取为含时间变参积分, 空间聚合算子取为多输入信号加权求和, 则由图 2 所示的过程神经元输入与输出之间的映射关系为

$$y(t) = f\left(\int_0^t \sum_{i=1}^n w_i(\tau) u_i(\tau) d\tau - \theta(t)\right) \quad (1)$$

式中, $\theta(t)$ 为过程神经元的激励阈值, 也可作为时间函数。

3.2 过程神经网络辨识模型

设待辨识的非线性动态系统 P 为多输入/单输出系统, 构建一种带有系统输出延时反馈的 PNN 模型。网络输入层有 $n+1$ 个节点, 输入为 $u_1(t), u_2(t), \dots, u_n(t)$ 以及系统 P 在 t 时刻的延时输出为 $y(t-\Delta)$, 这里 Δ 为系统的一个时间延迟单元。当 $t \leq \Delta$ 时, $y(t-\Delta)=0$ 。网络隐层由 m 个式(2)定义的过程神经元组成, 输出层由 1 个线性输出的非时变神经元节点组成。拓扑结构如图 3 所示。




图 3 过程神经网络模型

图 3 中, $w_{ij}(t)$ ($i=1, 2, \dots, n; j=1, 2, \dots, m$) 为输入层节点与隐层节点的连接权函数, $v_j(t)$ ($j=1, 2, \dots, m$) 为隐层节点到输出节点的连接权函数, $y(t)$ 为网络输出。

由图 3 可知, PNN 辨识模型输入和输出之间的映射关系为

$$y(t) = \sum_{j=1}^m v_j(t) f\left(\int_0^t \sum_{i=1}^n w_{ij}(\tau) u_i(\tau) d\tau + \int_{\Delta}^t w_{0j}(\tau - \Delta) y(\tau - \Delta) d\tau - \theta_j(t)\right) \quad (2)$$

式中, $w_{0j}(t)$ 为对应于 $y(t-\Delta)$ 的输入节点与隐层节点的连接权函数。当 $t \in [0, \Delta]$ 时, $w_{0j}(t)=0$ 。

在实际应用中, 如果已知若干组可反映系统动力学特性和模态变化特征的输入/输出信号样本数据, 则可利用 PNN 对动态系统时变输入/输出信号的非线性变换机制和建模能力, 直接建立基于 PNN 的系统辨识模型。

4 基于 PNN 的系统控制信号求解

4.1 用于控制信号求解的 PNN 模型

考虑系统正向辨识模型与逆向控制模型之间信号传递应满足的——变换关系, 在 PNN 辨识模型的基础上, 构建一种图 4 所示的控制信号求解模型。




图 4 控制信号求解的 PNN 模型

图 4 所示的模型是在 PNN 辨识模型的前端增加一个节点数为 $n+1$ 的输入层, 而把正向模型的输入层作为第 1 隐

层,隐层节点变换采用线性转移函数,即 $f(u(t))=u(t)$ 。模型的输入为一个 $n+1$ 维单位恒等函数向量 $X_0(t) \equiv 1(t \in [0, T])$,以系统的期望过程输出信号为该模型的控制输出。在根据实际系统输出与辨识模型输出的偏差函数 $e(t)$ 调整网络连接权时,正向模型的连接权函数和性质参数保持不变,只调整新增输入层与正向模型输入层之间的连接权函数 $W_0(t) = (w_0(t), w_1(t), \dots, w_n(t))^T$ 。

由图 4 知,模型第 1 隐层(正向模型的输入层)的输入为 $X_0(t) * W_0(t) = (u_0(t), u_1(t), \dots, u_n(t))$,这里“*”表示两个向量函数的内积。由于第 1 隐层节点的作用函数为线性函数,故其输出 $u(t) = (u_0(t), u_1(t), \dots, u_n(t)) = (w_0(t), w_1(t), \dots, w_n(t))$,即 $W_0(t)$ 同时为正向模型的输入函数向量。由于正向模型的输入为系统控制信号,当调整权函数 $W_0(t)$ 使之满足系统正向模型的输入/输出关系时确定的 $W_0(t)$ 即为系统期望输出 $y(t)$ 所对应的过程控制信号,且该变换满足系统控制信号与系统正向模型输出信号之间的一一变换关系,从而实现了对于系统过程控制信号的求解。

4.2 基于 GA 的控制信号求解

基于 PNN 的系统控制信号的求解分为两个阶段:第 1 阶段确定系统的正向模型,即利用系统训练函数样本集确定图 3 表示的满足实际系统正向输入/输出关系的 PNN 辨识模型;第 2 阶段为求解图 4 所示的满足系统控制性能要求的过程控制信号。

下面考虑系统逆向模型的求解,即对应于系统的期望输出 $y(t)$,确定系统的过程控制信号 $u_0(t), u_1(t), \dots, u_n(t)$ 。由图 3 和图 4 可知, $u_0(t) = y(t - \Delta)$,故只需求解 $u_1(t), u_2(t), \dots, u_n(t)$,即 $w_1(t), w_2(t), \dots, w_n(t)$ 。

由前面的分析,图 4 中输入层与第 1 隐层的连接权函数即为系统所要求解的控制信号。在求解过程中,系统正向模型的连接权函数和参数值不变,网络训练所需调整的是输入层与第 1 隐层的连接权函数 $w_1(t), w_2(t), \dots, w_n(t)$ 。如果采用梯度下降等迭代算法进行网络训练,由于可调整的参数少,因此一般只能获得网络总体误差信号贡献很小的部分。这种调整策略训练周期长,且算法的稳定性也难以预知。为此,考虑一种和 GA 相结合的训练算法。

将权函数 $w_1(t), w_2(t), \dots, w_n(t)$ 表示为某一正交函数系的有限项展开形式^[19]。在 LMS 准则下,采用 GA 求解其展开式系数,然后与基函数进行组合来获得系统控制信号。在 GA 的设计中,依据控制系统正向传递的误差函数 $e(t)$ 构造染色体适应度函数。

将 $w_1(t), w_2(t), \dots, w_n(t)$ 用函数基 $b_1(t), b_2(t), \dots, b_L(t)$ 展开

$$w_i(t) = \sum_{l=1}^L w_i^{(l)} b_l(t), i=1, 2, \dots, n \quad (3)$$

式中, $w_i^{(l)}$ 为 $w_i(t)$ 相对于 $b_l(t)$ 的基展开系数, L 为满足系统输入信号拟合精度的函数基的项数。

染色体直接采用十进制实数编码,遗传操作具体步骤如下。

步骤 1 确定初始种群规模 N 。

步骤 2 种群染色体初始化。直接使用问题域空间中的解向量作为染色体,即采用十进制实数直接对 $w_i^{(1)}, w_i^{(2)}, \dots, w_i^{(L)} (i=1, 2, \dots, n)$ 进行编码,每条染色体上基因个数为 nL ,分别赋予 $[-1, 1]$ 区间上的随机数,完成种群染色体的初始化。也可在学习样本集中选择 N 个样本,以其基函数展开系

数的有序排列直接构成染色体。

步骤 3 构造染色体适应度函数。染色体适应度函数根据系统的输出误差函数 $E = \|e(t)\|$ 构造。考虑到适应度的实际意义,将其取为 $E+1$ 的倒数,即 $g(W) = 1/(1+E)$;

步骤 4 种群选择。采用按比例适应度分配方法。对于适应度值为 g_k 的染色体 $k (k=1, 2, \dots, N)$,其选择概率按 $p_k = g_k / \sum_{j=1}^N g_j$ 计算。根据这些概率值构造一个转轮,旋转转轮 N 次,每次选择一个染色体加入到新的种群。

步骤 5 算术交叉。算术交叉定义为两个染色体的如下组合方式

$$w_1' = \lambda w_1 + (1-\lambda) w_2 \quad (4)$$

$$w_2' = \lambda w_2 + (1-\lambda) w_1 \quad (5)$$

式中, $\lambda \in [0, 1]$ 为随机数。

步骤 6 非均匀变异。对于给定的父代 $w = (w_0^{(1)}, \dots, w_1, \dots, w_n^{(L)})$,若它的元素 w_i 被选来变异,生成的后代记为 $w' = (w_0^{(1)}, \dots, w_i', \dots, w_n^{(L)})$,则 w_i' 随机地按如下两种可能的机会变化

$$w_i' = w_i + \Delta(s, w_i^U - w_i) \quad (6)$$

或

$$w_i' = w_i - \Delta(s, w_i - w_i^L) \quad (7)$$

式中, s 为遗传代数, w_i^U 和 w_i^L 分别是 w_i 的上、下界,函数 $\Delta(s, z)$ 随 s 的增加而趋于 0。例如,可取 $\Delta(s, z) = z \cdot r(1-s/M)^d$,其中 $r \in [0, 1]$ 为随机数, M 为最大遗传代数, d 是确定非均匀度的参数。

步骤 7 循环控制。按照适应度函数计算每个染色体的适应度值;循环控制条件可选择目标函数极小化精度或适应度函数目标值。

5 仿真实验

考虑具有如下 26 个时变输入/输出函数样本对的非线性系统的辨识和控制信号求解问题。

$$\{t \sin((0.5+k\tau) \cdot t\pi) + 2.0, t \cos((0.5+k\tau) \cdot t\pi) + 2.0\} \\ k=0, 1, \dots, 15, t \in [-2, 2], \tau \in \{0.1, 0.15\}$$

采用图 3 所示的 PNN 建立函数系统的正向串-并联辨识模型。网络拓扑结构选择为 2-6-1,即 2 个输入节点,输入为 $t \sin((0.5+k\tau) \cdot t\pi) + 2.0$ 和 $(t-0.1) \cos((0.5+k\tau) \times (t-0.1)\pi) + 2.0$,这里系统的延时单元取为 0.1;6 个过程神经元隐层节点;1 个普通神经元输出节点。基函数选取连续 Walsh 正交函数系^[20],当基函数项数为 32 时满足输入函数拟合精度 0.05 的要求。限定训练误差精度为 0.05,最大迭代次数为 2000。对于 26 个训练样本函数,网络实际迭代 1173 次后收敛,平均逼近误差为 0.04923。其中 1 个函数样本的辨识模型输出曲线(虚线)与系统输出曲线(实线)的逼近情况如图 5 所示。




图 5 输出为 $t \cos(0.9t\pi) + 2.0$ 的样本曲线

下面利用所建立的系统正向辨识模型,采用本文第 4 节

(下转第 166 页)

- [5] Wu Ai-yan, Zhao Yu-hong. A Multi-layer cloud state space model and its application[C]//CISE, China; CPS, 2009
- [6] 涂序彦, 王枫, 郭慧. 大系统控制论[M]. 北京: 北京邮电大学出版社, 2005
- [7] Zenkai S. Rapid visual earthquake hazard evaluation of existing buildings by fuzzy logic modeling [J]. Expert Systems with Applications, 2010, 37(8): 5653-5660
- [8] Ajayi A O, Aderounmu G A. An adaptive fuzzy information retrieval model to improve response time perceived by e-commerce clients [J]. Expert Systems with Applications, 2010, 37(1): 82-91
- [9] Azimrad E, Pariz N. A novel fuzzy model and control of single intersection at urban traffic network [J]. IEEE Systems Journal, 2010, 4(1): 107-110
- [10] 李华莹, 罗自强, 李德毅. 基于云模型的汽车款式知识表示[J]. 舰船电子工程, 2006, 26(6): 1-4
- [11] 李德毅, 刘常昱. 不确定性人工智能[J]. 软件学报, 2004, 15(11): 1583-1594
- [12] 杜鹤, 李德毅. 基于云的概念划分及其在关联挖掘上的应用[J]. 软件学报, 2001, 12(2): 196-203

(上接第 161 页)

建立的控制信号求解模型和算法分别求解系统输出为 $t\cos(0.85t\pi)+2.0$ 和 $t\cos(1.65t\pi)+2.0$ 的过程控制信号。

遗传算法中, 种群规模设为 $N=6$, 以样本集中 6 个学习样本输入函数的连续 Walsh 基函数展开系数为初始染色体, 交叉概率 0.5, 变异概率 0.01, 基因上限 5.0, 基因下限 -2.5, 控制误差精度 0.05。对于期望输出为 $t\cos(0.85t\pi)+2.0$ 的信号函数, 算法在迭代 273 次后满足控制误差精度要求; 对于输出为 $t\cos(1.65t\pi)+2.0$ 的信号函数, 算法在迭代 351 次后满足误差控制精度要求。系统在控制信号输入下, 样本函数 $t\cos(1.65t\pi)+2.0$ 的网络输出信号曲线(虚线)和期望输出函数曲线(实线)如图 6 所示, 取得了较好的控制结果。




图 6 $t\cos(1.65t\pi)+2.0$ 的两种输出曲线

结束语 本文建立了一种基于过程神经网络的非线性动态系统控制信号求解模型和方法, 可根据反映实际系统模态变化特征的时变输入/输出样本数据, 直接建立动态系统的辨识模型和控制信号求解模型, 且该方法具有通用性。在计算机动态系统仿真等实际应用中, 文中建立的方法对解决诸如仿真模型建立、系统信号控制、时变信息处理等问题具有借鉴意义, 并有着较广泛的应用前景。

参考文献

- [1] 王树青, 载连奎, 于玲. 过程控制工程[M]. 化学工业出版社, 2008
- [2] 李言俊, 张科. 系统辨识理论及应用[M]. 国防工业出版社, 2004
- [3] Cheng Tao, Lewis F L, Abu-Khalaf M. A neural network solution for fixed-final time optimal control of nonlinear systems [J]. Automatica, 2007, 43(3): 482-490
- [4] Kumaresan N, Balasubramaniam P. Optimal control for stochastic nonlinear singular system using neural networks[J]. Computers and Mathematics with Applications, 2008, 56: 2145-2154
- [5] 金以慧. 过程控制[M]. 北京: 清华大学出版社, 2001
- [6] Mekki H, Chtourou M, Derbel N. Variable structure neural networks for adaptive control of nonlinear systems using the stochastic approximation [J]. Simulation Modelling Practice and Theory, 2006, 14: 1000-1009
- [7] Ng G W. Application of neural networks to adaptive control of nonlinear systems[J]. Automatica, 2000, 36(11): 1929-1933
- [8] Huang S N, Tan K K, Lee T H. Decentralized control of a class of large-scale nonlinear systems using neural networks[J]. Automatica, 2005, 41(12): 1645-1649
- [9] Ge S S, Hang C C, Zhang T. Nonlinear adaptive control using neural networks and its application to CSTR systems[J]. Journal of Process Control, 1998, 19: 313-323
- [10] Yoo S J, Park J B, Choi Y H. Indirect adaptive control of nonlinear dynamic systems using self recurrent wavelet neural networks via adaptive learning rates [J]. Information Sciences, 2007, 177: 3074-3098
- [11] Choi J T, Choi Y H, Park J B. Stable intelligent control of chaotic systems via wavelet neural network[C]//Proc. Int. Conf. Control, Automation Systems, 2003: 316-321
- [12] Karami-Mollaei A, Reza M. A new approach for instantaneous pole placement with recurrent neural networks and its application in control of nonlinear time-varying systems[J]. Systems & Control Letters, 2006, 55: 385-395
- [13] 李少远, 蔡文剑. 工业过程辨识与控制[M]. 北京: 化学工业出版社, 2005
- [14] Chow T W S, Fang Y. A recurrent neural-network-based real-time learning control strategy applying to nonlinear systems with unknown dynamics[J]. IEEE Trans. Industrial Electron, 1998, 45: 151-161
- [15] 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
- [16] Hong-Wei Gea, Feng Qia-na, et al. Identification and control of nonlinear systems by a dissimilation particle swarm optimization-based Elman neural network[J]. Nonlinear Analysis: Real World Applications, 2008, 9: 1345-1360
- [17] 许少华, 何新贵. 关于连续过程神经网络的一些理论问题[J]. 电子学报, 2006, 34(10): 1838-1842
- [18] 徐丽娜. 神经网络控制[M]. 北京: 电子工业出版社, 2003: 115-165
- [19] 许少华, 何新贵. 基于函数正交基展开的过程神经网络学习算法[J]. 计算机学报, 2004, 7(5): 645-650
- [20] 王能超. 同步并行算法设计[M]. 北京: 科学出版社, 1996: 100-105