

文章编号: 1000-8055(2008)10-1913-08

航空发动机的智能神经网络自适应控制研究

赵 俊¹, 陈建军¹, 王灵刚²

(1. 西安电子科技大学 机电工程学院, 西安 710071;

2. 中航一集团电光设备研究所, 洛阳 471009)

摘 要: 针对结构复杂、模型不确定、强非线性的航空发动机对象, 提出一种综合模糊推理、神经网络自适应和 PID 简单控制各自优点的控制方案。在改进模糊 PID 控制器的基础上, 进行了新型智能型神经网络控制器的设计, 并提出离线混沌蚁群优化与在线误差反传调整相结合的优化方法。应用具有良好泛化能力的最小二乘支持向量机进行系统辨识, 对某型航空发动机进行了设计点处的线性和非线性模型控制仿真。结果表明: 控制系统具有满意的动、静态性能和较好的鲁棒性, 验证了该方案的可行性和有效性。

关 键 词: 航空发动机; 智能神经网络; 模糊 PID 控制; 混沌蚁群优化; 误差反传算法;
最小二乘支持向量机

中图分类号: V233. 7

文献标识码: A

New intelligent neural network adaptive control scheme research for aeroengine

ZHAO Jun¹, CHEN Jian-jun¹, WANG Ling-gang²

(1. School of Electromechanical Engineering, Xidian University, Xi'an 710071, China;

(2. Institute of Electro-Optical Equipment of Aviation Industry Corporation I,
Luoyang 471009, China)

Abstract: In view of complicated, undetermined and strongly nonlinear aeroengine object, a novel control scheme integrating the merits of fuzzy inference, neural network adaptation and simple proportional-integral-derivative (PID) method was presented. Based on the improved fuzzy PID controller, a novel intelligent neural network controller was designed. The parameters of the controller were optimized by the mixed learning method integrating off-line chaotic ant colony optimization and online error back propagation (BP) algorithm. By applying least square support vector machine for system identification, with its fine nonlinear mapping ability, Simulation results at the design point show that the control system has good robustness and better performance than conventional control methods. The feasibility and validity of the control scheme are proved.

Key words: aeroengine; intelligent neural network; fuzzy-pid control;
chaotic ant colony optimization; error back propagation algorithm;
least square support vector machine

航空发动机是一类结构复杂、非线性时变的 多变量控制对象, 其特性随外界环境而变, 难以建

收稿日期: 2007-09-21; 修订日期: 2008-03-12

基金项目: 国家 863 项目(2006AA04Z402); 陕西省自然科学基金(2005A09)

作者简介: 赵俊(1982-), 男, 江西南昌人, 博士生, 研究方向为模糊控制、神经网络、智能控制系统与先进算法。

立其精确的数学模型. 传统的 PID (Proportional integral differential) 控制方法较适用于线性、单变量确定性控制, 虽在航空发动机中得到广泛的应用, 但已无法满足日益发展的航空发动机对象的控制性能需求. 为此, 人们研究了许多能有效处理非线性问题的智能控制方法, 如模糊控制、模糊 PID 控制、神经网络和模糊神经网络控制等, 可以不需要对象精确数学模型来有效地控制对象, 都为航空发动机的智能控制问题开辟了新的思路^[1-5]. 然而, 在应用模糊推理和神经网络等工具进行控制时需尽可能避免它们的本质缺陷, 如模糊控制中局限于规则的启发式调节, 缺乏自适应性; 神经网络无法充分利用专家经验知识, 且存在样本过拟合问题; 参数优化算法易陷入局部极值或无法满足实时性.

为有效避免和改善上述缺陷, 本文提出一种新的控制方案: 以最小二乘支持向量机 (Least square support vector machine, LS_SVM) 作为辨识器; 通过改进模糊 PID 控制器, 将模糊神经网络 (Fuzzy neural network, FNN) 与 PID 神经网络 (PID neural network, PIDNN) 结合构成一种新型智能神经网络作为控制器; 参数优选采用离线时混沌蚁群 (Chaotic ant colony optimization, CACO) 全局寻优与在线时误差反传 (Error back propagation, BP) 快速调整的方法. 在设计点处对某型航空发动机的线性化模型和非线性模型进行控制仿真, 结果表明: 该方案较好地利用了 LS_SVM 的系统辨识能力并综合了各种控制方法的优点, 系统稳态基本无静差, 动态性能好, 且具有较好的鲁棒性.

1 智能神经网络控制系统结构与原理

控制系统结构如图 1 所示, LS_SVM 用作辨识器, 按需要进行离线辨识与在线离散时间控制条件下在线辨识; 控制器 (Neural network controller, NNC) 为 FNN 与 PIDNN 组成的智能型神经网络, 其优化算法采用离线 CACO 和在线 BP 结合的方式.

其中 r 为期望信号; y 和 y' 分别为实际输出和 LS_SVM 输出; e 为期望信号与实际输出之间的误差; 辨识器以 J 为优化目标, 它是 y 与 y' 的偏差; 控制器的主要任务是基于 LS_SVM 的辨识输出来优化目标 J , 使得 e 最小. 离散后的系统一般可写为 $y(k+1) = f[u(k), \dots, u(k-m+1); y(k), \dots, y(k-n+1)]$, 记当前仿真时刻为 $k+1$,

在第 $k+1$ 个时刻有 u 和 y 之前的状态输入到 LS_SVM 中, 这样它就可以给出 $y(k+1)$ 时刻的预估值, 即 $y'(k+1)$. 故 J 可定义为

$$J(k+1) = \frac{1}{2} (r(k+1) - y'(k+1))^2 \quad (1)$$




图 1 智能神经网络控制系统图

Fig. 1 Scheme of intelligent neural network control system

1.1 发动机的智能神经网络控制器设计

在模糊 PID 控制器基础上, 将 FNN 与 PIDNN 结合构成一种新颖的智能型神经网络用作控制器, 其具体结构如图 2 所示.




图 2 神经网络控制器拓扑结构

Fig. 2 Structure of neural network controller

控制器由两个神经网络组合而成, 下面说明该神经网络控制器的具体结构:

FNN 为传统的 4 层网络: 输入层、模糊化层、规则层、解模糊层. 输入层有两个节点, 输入为系统偏差和偏差变化; 模糊化层的节点数按 E 和 EC 划分的模糊子集个数而定, 隶属函数取高斯函数; 规则层节点数按先验知识中的规则数而定; 解模糊层同时作为 PIDNN 的第 1 层, 输出为间接控制量 U' .

PIDNN 为 5 个神经元组成的 3 层网络: 输入层、PID 作用层、输出层. 输入层仅一个节点, 输出等于输入. 但当 PIDNN 单独用作控制器时, 输入层节点则有两个, 分别对应系统的输入和输出, 即输出反馈到输入层节点上; PID 作用层有三个节点, 分别为比例 P、积分 I 和微分 D 神经元, 起到常规 PID 控制器中 P, I, D 的调节作用, 考虑实际

系统中输出为有限,故有限幅处理;输出层只有一个节点,它是 P,I,D 三者的加权值,即控制量 U 。

传统 FNN 的神经元输入输出关系这里就不加以赘述了,PIDNN 各层神经元输入输出关系如下:

①输入层输入、输出

$$I_1(k) = U'(k) \quad (2)$$

$$O_1(k) = I_1(k) \quad (3)$$

②PID 层输入、输出

$$I_{Hi}(k) = \sum_{j=1}^3 \omega_{ij}' I_j(k), i = 1, 2, 3 \quad (4)$$

比例神经元

$$O_{H1}(k) = \begin{cases} -1, & I_{H1}(k) < -1 \\ I_{H1}(k), & -1 \leq I_{H1}(k) \leq 1 \\ 1, & I_{H1}(k) > 1 \end{cases} \quad (5)$$

积分神经元

$$O_{H2}(k) = \begin{cases} -1, & I_{H2}(k) < -1 \\ I_{H2}(k) + I_{H2}(k-1), & -1 \leq I_{H2}(k) \leq 1 \\ 1, & I_{H2}(k) > 1 \end{cases} \quad (6)$$

微分神经元

$$O_{H3}(k) = \begin{cases} -1, & I_{H3}(k) < -1 \\ I_{H3}(k) - I_{H3}(k-1), & -1 \leq I_{H3}(k) \leq 1 \\ 1, & I_{H3}(k) > 1 \end{cases} \quad (7)$$

③输出层输入、输出

$$O(k) = I(k) = \sum_{i=1}^3 \omega_i O_{Hi}(k) \quad (8)$$

按神经网络控制器结构可推导出其控制律

$$U(k) = \omega_1' \omega_{11}' U'(k) + \omega_2' \omega_{21}' [U'(k) + U'(k-1)] + \omega_3' \omega_{31}' [U'(k) - U'(k-1)] \quad (9)$$

原理:前件 FNN 主要是改进模糊 PID 控制器的模糊部分,引入神经网络自适应调整规则,达到有效调整误差量的效果。后件 PIDNN 是用来替换模糊 PID 控制器中的静态 PID 参数环,通过调节权重进一步提高系统的瞬态性能和稳态精度。鉴于常规模糊神经网络被广泛应用于控制领域,很多研究学者都对它进行过深入的研究开发,如利用它来调整 P,I,D 参数(属静态)或使其带自反馈构成动态模糊神经网络(属动态)。本文同样是为了增强网络的动态处理能力,与带反馈的方法是出于同一个目的,但做法不同,且凸现了 P,I,D 三者的作用,属综合各种智能方法的非线性 PID 策略。

具体做法是:将独立的 PIDNN 的输入层两

节点结构变为一个节点,其输入为 FNN 的输出(一个偏差和偏差变化的非线性映射,对应模糊 PID 控制中系统控制量的调整),它作为间接控制量以加权的形式输入到 PIDNN 的 PID 作用层,由 P,I,D 神经元作用后产生 PID 控制效果并再次加权,输出最终的系统控制量。这样就把模糊 PID 控制方法中局限于模糊规则的系统控制量和 P,I,D 静态参数转变为动态调整,使得网络成为一种动态网络,大大地增强了网络处理信息的能力,且融合了各种控制方法的优点,是对模糊 PID 控制的一种有效改进。而此改进的一个前提是需具备原模糊 PID 控制中模糊子集划分和模糊规则的先验知识,从而确定控制器第 1、2 层神经元数并使系统具有较好的鲁棒性,在进行网络结构设计时,如果能事先对模糊规则进行优化选取,则可简化网络结构。而通过 FNN 的自适应调整效果和 PIDNN 引入 PID 控制的作用,使得它成为了一种融合模糊推理、神经网络自适应和 PID 简单控制三者优点的动态模糊神经网络控制器。

对于航空发动机的控制而言,这样设计的好处在于:①可以充分利用已有的先验专家知识,即启发式的模糊推理;②通过引入神经网络使得系统不局限于专家知识,具有自适应调整规则的效果;③引入 PID 控制作用,且 P,I,D 参数均为动态调整,增强控制器的信息处理能力;④由其神经网络的结构,可以设计离线和在线优化算法,以满足实时控制的要求;⑤融入各种控制方法的优点,有效提高了控制系统的鲁棒性和跟踪精度。⑥其结构复杂度和训练计算复杂度均能满足实际应用。(a)较常规智能方法而言(如 FNN 控制),智能型神经网络需要训练的参数仅多出 PIDNN 的 6 个权值,并没有大大地增加训练的计算复杂度;(b)PIDNN 仅 5 个神经元,且与 FNN 共用一个神经元。其激活函数非常简单,P,I,D 三个神经元的激活函数均为简单的界限函数和加减关系,这部分网络的结构简单且易于计算。综合看来,随着航空发动机自身的日益发展,一个简单的控制器已无法满足其基本需求,结合多种智能方法优点的控制器将对未来航空发动机控制领域提供新的参考和借鉴意义。

1.2 控制器离线与在线优化算法

设计好的控制器能较好地解决“局限于启发式调节”、“缺乏自适应能力”等问题,然而对于航空发动机对象,需要一种能用于实时控制的算法,大多数全局性算法如遗传、粒子群、蚁群算法等,

都是批量处理数据,实时性难以满足.虽具有全局性搜索能力,但同样容易陷入局部极值,故不适合于在线工作. BP 算法是神经网络应用最为广泛的一种算法,它基于梯度本质的特征使得在计算时容易陷入局部极小,但当初始参数选择适当时,算法不仅收敛速度快,且精度高.为此,本文设计了一种混沌与蚁群算法结合离线寻找控制器近似最优参数的方法,使得在线 BP 调整能快速有效地进行.

蚁群算法是由意大利学者 Dorigo M 等人提出的一种基于群智能的模拟进化算法,其原理是模拟蚂蚁在搜索食物源过程中体现出来的寻优行为^[6].近年来有学者将其引入到函数优化、神经网络权值优化等方面,取得了一系列令人满意的结果.但对 ACO 的研究在理论上仍不成熟,如何解决 ACO 在寻优过程中搜索时间长和局部极值问题是当前研究的难点,一些改进的方法主要有 ACO 参数的优选、信息素更新策略的改进及自适应方法的引入.为避免出现寻优搜索停滞陷入局部极值的现象,本文提出一种带混沌扰动的策略.

混沌是广泛存在于非线性系统中的一种现象,它具有的随机性、遍历性的特点使其能在一定范围内能按照某种规律不重复地遍历所有的状态.基于这种特性,使得混沌搜索方法^[7]在智能控制领域的应用受到广泛的关注.混沌优化的基本思想是将变量的解空间转换到混沌空间.

采用 Logistic 映射产生混沌运动

$$x_{n+1} = \mu \cdot x_n (1 - x_n),$$

$$n = 0, 1, 2, \dots, M (0 < x_0 < 1) \quad (10)$$

其中当 $\mu = 4$ 时,系统完全处于混沌状态且混沌变量 x_n 在 $(0, 1)$ 范围内遍历.混沌运动对初始值的选取极其敏感,不同的初始值会有不同的遍历轨迹.

控制器待优化参数: FNN 部分中模糊化层高斯函数的中心、宽度及输出层权值; PIDNN 部分中各层权值. CACO 的具体思想如下:

Step1. 首先由经验知识确定控制器网络结构(规则未优化),设待优化的参数共有 n 个,记为 $P_1 P_2 \dots P_n$. 在可能取值范围内初始化各个参数的取值集合,记为 $U_{P_i} (1 \leq i \leq n)$,每个集合以区间形式表示,含 m 个随机数.初始化:令 $t = 0$,迭代次数 $N = 0$,给定最大迭代次数 $N_{\max}$ 和蚂蚁数目 A ,令集合 $U_{P_i} (1 \leq i \leq n)$ 中元素 j 的信息素 $\tau_j(U_{P_i}) (0) = 0$,其更新量 $\Delta \tau_j(U_{P_i}) = 0, 1 \leq j \leq m$.

Step2. 将所有蚂蚁的初始出发点置于当前解集中,开始寻优.令每只蚂蚁 $a (a = 1, \dots, A)$ 从集合 $U_{P_i} (1 \leq i \leq n)$ 开始,按照概率 $P(\tau_j^a(U_{P_i}))$ 依

次从每个集合中选择第 j 个元素,直到选完所有集合后就到达食物源.

$$P(\tau_j^a(U_{P_i})) = \frac{\tau_j(U_{P_i})}{\sum_j \tau_j(U_{P_i})} \quad (11)$$

Step3. 信息素的更新,并计算用各蚂蚁选择的元素作为控制器参数时训练样本产生的输出与期望值的误差,同时记录下最好的元素组作为当前最优解.设所有蚂蚁寻优过程中经历了 ε 个时间单位,此时令 $t = t + \varepsilon, N = N + 1$. 信息素更新按下式进行

$$\tau_j(U_{P_i})(t + \varepsilon) = \rho \tau_j(U_{P_i})(t) + \Delta \tau_j(U_{P_i}). \quad (12)$$

Step4. 信息素更新的混沌扰动策略.虽然蚁群算法利用了正反馈原理,但仍像诸如遗传、粒子群算法等全局性搜索方法一样,容易陷入局部极小.合理利用混沌运动的优质特性,可有效避免这一情况的出现,使得搜索到的解更为接近最优值.扰动原理:由于算法以一定概率选择各集合中信息素最大的元素,这将使得新一代解在该分量处的值集中在这个信息素最大的元素附近,容易出现停滞现象,为了避免这种情况,文中采用对信息素进行混沌扰动的策略.

设定混沌扰动激发的条件:陷入停滞时迭代次数变化量 N' 和判断量 η .并令 $\tau_c = 0$.混沌策略下信息素调整如下:

$$\text{if } \text{abs}(e_{\text{now}}^{k=k+1, \dots, k+N'} - e_{\text{next}}^{k=k+1, \dots, k+N'}) \leq \eta \quad (13)$$

$$\tau_c = \tau_c + \alpha(2X_i - 1),$$

$$X_{i+1} = 4X_i(1 - X_i), i = i + 1 \quad (14)$$

$$\tau_j(U_{P_i})(t + n) =$$

$$\rho \tau_j(U_{P_i})(t) + \Delta \tau_j(U_{P_i}) + \tau_c \quad (15)$$

$$\Delta \tau_j(U_{P_i}) = \sum_a^A \Delta \tau_j^a(U_{P_i}) \quad (16)$$

式中 $e_{\text{now}}^{k=k+1, \dots, k+N'}$ 分别表示当前第 k 次迭代时的最优值和第 $k+1$ 次迭代到第 $k+N'$ 次迭代的历次最优值; η 是常数,为一个微小值; τ_c 为混沌扰动量; α 是常数,为扰动搜索半径; X_i 为混沌变量,由于 Logistic 映射在 $(0, 1)$ 区间上对称,为避免重复,其初始值只需在 $(0, 0.5)$ 之间产生.其中混沌变量 X_i 的维数与信息素 τ_j 一致.当前搜索到的最优值在 N' 次迭代中发生的变化量不大于 η 时,产生混沌扰动. $\rho (0 \leq \rho < 1)$ 表示信息素的持久性, $1 - \rho$ 理解为信息素的衰减度,一般取 $\rho = 0.7$. $\Delta \tau_j^a(U_{P_i})$ 为本次循环中第 a 只蚂蚁在集合 U_{P_i} 的第 j 个元素上留下的信息素,其计算如下:

$$\Delta \tau_{ij}^a(U_{pi}) = \begin{cases} \frac{q}{e^a}, & \text{若第 } a \text{ 只蚂蚁在本次循环} \\ & \text{中选择了 } U_{pi} \text{ 中第 } j \text{ 个元素} \\ 0, & \text{其它} \end{cases} \quad (17)$$

式中 q 是常数,用于调节信息素调整的速度, q 的取值对算法影响不大,一般 $q \in [1, 10\ 000]$,实际选择时,事先选定 ρ 值,再试凑 q ,可得较好结果。 e^a 为蚂蚁 a 选择的元素作为控制器参数时由训练样本产生的系统输出 Y 与期望输入 Y_d 之间的误差,可采用如下定义

$$e^a = \frac{1}{K} \sum_{i=1}^K (Y_d(i) - Y(i))^2, K \text{ 为样本数} \quad (18)$$

Step5. 重复步骤 2 至 4,直到算法收敛或达到最大迭代次数.输出结果为离线相对最优解.算法结束.

对发动机对象的优化方法:①离线寻优时,尽可能地采集其飞行包线内各种状态下的数据样本,利用这些样本及上述算法,可找到控制器参数的一组相对最优解.②在线仿真时,首先利用辨识器得到发动机地面初始状态的近似模型,此时由于控制器参数已近似得到优化,可利用 BP 算法快速进行调整.对于全包线内其它设计点处的优化,则由辨识器相应地进行在线辨识,并结合 BP 算法快速整定.

1.3 LS_SVM 辨识器设计

Vapnik 等人提出的支持向量机^[8]是在统计学习理论基础上发展起来的新一代学习算法,算法具有严格的数学基础,成功地解决了神经网络在系统辨识方面遇到的“维数灾”、“过拟合”、“局部极小”等问题,具有良好的泛化能力,已被广泛应用于模式识别和函数回归问题.有关 LS_SVM 的原理这里就不再赘述,仅说明一下其辨识方法.

设被控对象为

$$y(k+1) = f[u(k), \cdots, u(k-m+1); y(k), \cdots, y(k-n+1)] \quad (19)$$

u, y 分别为系统输入和输出; m, n 分别为输入和输出的阶次; f 为线性或非线性函数.其数学模型是未知的,利用 LS_SVM 的辨识方法需建立如下训练样本集

$$[(y(n-1), \cdots, y(0), u(n-1), \cdots, u(n-m)), y(n)] = (x_1, y_1) \quad (20)$$

$$[(y(n), \cdots, y(1), u(n), \cdots, u(n-m+1)), y(n+1)] = (x_2, y_2) \quad (21)$$

$$[(y(n+\mu-2), \cdots, y(\mu-1), u(n+\mu-2), \cdots, u(n-m+\mu-1)), y(n+\mu-1)] = (x_\mu, y_\mu) \quad (22)$$

先按网格搜索(Gridsearch)和交叉验证方法(Crossvalidate)^[9]选定 LS_SVM 参数,再利用试验采集的 μ 对样本点训练好 LS_SVM.由其良好的泛化能力,可得到描述系统动力学行为的回归模型.这样 LS_SVM 就可以给出系统下一时刻的预估值,从而得到需要的系统误差量,再由控制器根据目标函数进行误差调整,达到有效控制的目的.由于训练集不可能覆盖对象所有可能的工作范围,故需对被控对象进行离线学习后的在线学习,从而使 LS_SVM 能更准确地逼近模型.

以有两个控制量的某型双转子涡轮发动机为例.一般来说,发动机全包线内非线性模型可以表示为

$$y = f(N_h, N_l, M_f, A_e, Ma, H) \quad (23)$$

通过对飞行包线进行区域划分的方法,可由数值计算验证各个划分区域质心点处的小偏差动态模型可以近似作为整个区域的动态数学模型,且整个飞行包线内的动态模型可以用各个划分区域质心点处的小偏差动态模型来近似表示.选定飞行马赫数 Ma 和飞行高度 H ,给定发动机的工作点,有小偏差下的状态方程为

$$\dot{x} = Ax + Bu \quad (24)$$

$$y = Cx \quad (25)$$

式中 $x = \begin{bmatrix} N_h \\ N_l \end{bmatrix}$, $y = \begin{bmatrix} N_h \\ N_l \end{bmatrix}$, $u = \begin{bmatrix} M_f \\ A_e \end{bmatrix}$, N_h, N_l 分别表示高、低压转速, M_f, A_e 分别表示主燃油流量和尾喷口面积.

在 $H = 0, Ma = 0$ 时,将模型离散化后利用 LS_SVM 进行离线辨识,由于是针对转速控制系统在包线内各设计点处的阶跃响应,故 LS_SVM 的样本可根据能使模型产生阶跃输出的数据为准则随机选取,共 200 组数据,100 组用于训练,100 组用于测试.尽管支持向量机在用于系统辨识方面有着十分显著的优势,但对于同时进行精确大数据量在线辨识并且实时控制的实现,目前仍然是一个巨大的难题,主要是支持向量机训练算法与控制器优化算法均要求实时性好,目前最好的支持向量机优化算法是序列最小最优化(Sequential minimal optimization, SMO)算法,它可以实现大样本数据的学习并且学习速度较快,但利用它来训练 SVM 并结合神经网络、模糊控制等智能方法进行控制的文献尚未遇见.本文仅是针对

设计样本集范围内进行了控制仿真。

采用 10-rcrossvalidate 方法,以高斯核作为核函数。辨识结果如图 3、4 所示。




图 3 交叉验证结果

Fig. 3 10-rcrossvalidation result




图 4 LS_SVM 辨识结果

Fig. 4 LS_SVM identification result

其中 $\gamma = 39\,424.22$, $\sigma = 8.769$ 。采用 MSE (Mean squared error) 指标,离线训练误差为 $2.5\,058 \times 10^{-8}$,测试误差为 $1.848\,4 \times 10^{-5}$ 。偏离设计状态点时在离散时间小样本条件在线训练 LS_SVM。

2 控制系统仿真

仿真中采用控制方案为:主燃油流量为输入,低压转子转速为输出,尾喷口面积不可调。分别采用传统 PID、模糊 PID、神经网络 PID 及本文方法对小偏差动态模型进行阶跃信号控制仿真,结果如图 5、图 6 所示。仿真参数:

PID 控制:基本参数设计点

$$K_p = 18.341, K_i = 28.469, K_d = 0$$

模糊 PID 控制:输入 E , EC 和输出 K_p , K_i , K_d 均划分为 7 个模糊子集,共 49 条规则。

神经网络 PID 控制:优化算法为 BP 算法,初始参数在 (0, 1) 内随机选取。

本文方法:新型神经网络控制器结构为 2-14-49-1-3-1,第 2 层激活函数取高斯函数,采用自适

应调整。离线时 CACO 参数: $n = 83$, $A = 60$, $\rho = 0.7$, $q = 100$, $N_{\max} = 3\,000$,取值集合 $U_{p_i} \in [-5, 5]$,混沌扰动参数 $N' = 100$, $\eta = 0.000\,1$ 。在线仿真时采用 CACO 优化得出的相对最优值作为初始值用 BP 快速调整。

由图 4 可以看出,LS_SVM 的离线辨识结果能较好地描述被控对象的动力学行为,但在实时工作的条件下,需要有更完善的在线辨识方法,目前对于真正意义上的在线辨识仍有许多难题和未完善的工作。

由图 5 可以看出,基本的 PID 控制在不同工作条件下调节时间有起伏,且出现了超调的情况,这显然是因为 PID 参数未得到有效地调整;模糊 PID 的控制效果优于 PID 控制,可以在全包线内进行控制,但也出现了超调,调节时间较本文方法要长,主要原因是变量初始论域设置不够合理,而同时又缺乏神经网络的自适应调整造成的;神经网络 PID 控制的效果波动较大,由于初始权系一般采用试凑法拟定,BP 算法不能很好地进行调整,从而容易陷入局部最优,尽管初始权系可以离线进行优化,但却缺乏明确的物理意义,故应与模糊推理结合运用;文中方法是各种智能方法与 PID 的结合,在基于 PID 的本质基础上,合理地利用了已有的专家知识和神经网络自适应调整,离线优化时设法取得较好初始参数,在线控制时可以在包线内快速有效地进行调整。系统具有鲁棒性好、调节时间短、基本无超调、稳态精度高的良好品质。图 6 给出了地面最大状态 $H = 0$, $Ma = 0$ 时转速单位阶跃响应对应的供油量曲线。为避免喘振、熄火等情形,在各状态下燃油量的量值及其变化的速率都必须受到限制,利用 Simulink 下的 Rate limiter 和 Saturation 模块分别限制燃油流量的变化速率和燃油量值。

为验证控制器对非线性模型的动态响应性能,将离线混沌蚁群全局寻优获得的控制器参数用于其非线性模型的仿真,结果如图 7 和图 8 所示,仿真附加说明:

① 离线寻优结果已获得较高精度,在线进行 BP 算法的调整。

② 重新利用 LS_SVM 进行非线性模型的离线辨识与建模,在设计点处进行控制。

从图中可以看出,系统仍具备良好的动静态性能和跟踪精度,在其它设计点处的效果类似。由此可见控制器同样适合于非线性模型的控制。

对比许多利用神经网络对多变量航空发动机




图 5 各种控制方法结果比较
Fig. 5 Results of several control methods




图 6 $H=0, Ma=0$ 供油量曲线
Fig. 6 Fuel supply curve($H=0, Ma=0$)




图 8 $H=10, Ma=1.3$ 时供油量曲线
Fig. 8 Fuel supply curve




图 7 $H=10, Ma=1.3$ 时非线性阶跃结果
Fig. 7 Simulation result for non-linear model

对象进行控制的情形,本文方法也可以很好地拓展到多变量的情形.限于篇幅,这里没有给出验证系统鲁棒性的仿真结果和对多变量进行解耦控制的情形.而本文的侧重点是:尽管应用智能方法进行包线内的控制可以达到近似最优 PID 参数控制的效果,然而各种智能方法在具体实施时会遇到上述各种缺陷,如最典型的神经网络初始权系、神经元个数的拟定和模糊推理初始论域的划分.如果缺少合理的初始离线优化过程,智能方法在飞行包线内将可能遇到难以整定最优参数的情形,系统也将变得不稳定,新的优化和控制方案较合理地处理了这些问题.

下一步的工作就是将控制方案延伸到发动机过渡过程的控制仿真中,实质上过渡过程控制问题也可以利用变参数PID控制,基于神经网络的智能控制方法正符合变参数PID控制规律的要求,已有一些学者将其应用在过渡态的控制中,取得了一些成果.但由于需对描述各控制量变化规律的模糊规则进行详细分析与总结,得出具体规则库,本文暂没有对此进行深入研究和探讨.

3 结 论

本文以改进航空发动机各种智能控制方法中存在的不足为出发点,设计了一种综合模糊理论、神经网络自适应和PID简单控制各自优点的控制方案.从仿真结果可见,新的控制方案较好地利用了LS-SVM的良好系统辨识能力,并在所设计的智能神经网络控制器及其优化算法的基础上,取得了良好的控制品质,为航空发动机的控制问题提供了一种新的参考.但同时也存在一些问题:①如何在实时控制基础上完善LS-SVM的在线辨识;②如何在对航空发动机的模糊规则形成及其优化进行研究基础上进一步优化文中控制器网络的拓扑结构.更多的工作还有待进一步的进行研究和探讨.

参考文献:

- [1] 袁春飞,孙健国,姚华.航空发动机模型参考模糊自学习控制[J].南京航空航天大学学报,2004,36(2):155-158.
YUAN Chunfei, SUN Jianguo, YAO Hua. Fuzzy model reference learning control of aero-engine[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2004, 36(2): 155-158. (in Chinese)
- [2] 董劲,黄金泉.航空发动机多变量模糊PID控制[J].航空动力学报,2003,18(4):538-541.
DONG Jin, HUANG Jinquan. Multivariable fuzzy-PID control for aeroengine[J]. Journal of Aerospace Power, 2003, 18(4): 538-541. (in Chinese)
- [3] 苏伟生,李玥,孙健国,等.基于遗传算法的航空发动机PI控制器参数优化方法[J].航空动力学报,2005,20(6):1078-1082.
SU Weisheng, LI Yue, SUN Jianguo, et al. Optimization methodology of PI controller parameters for aeroengines based on genetic algorithm[J]. Journal of Aerospace Power, 2005, 20(6): 1078-1082. (in Chinese)
- [4] 侯胜利,吴云,刘建勋,等.基于混沌变量的航空发动机模糊神经网络控制[J].航空动力学报,2005,20(3):494-498.
HOU Shengli, WU Yun, LIU Jianxun, et al. Chaos based fuzzy neural networks control for aeroengines[J]. Journal of Aerospace Power, 2005, 20(3): 494-498. (in Chinese)
- [5] 郭迎清.航空发动机神经网络自适应控制研究[J].航空动力学报,2001,16(1):83-86.
GUO Yingqing. A new neural network adaptive control scheme research[J]. Journal of Aerospace Power, 2001, 16(1): 83-86. (in Chinese)
- [6] Dorigo M, Maniezzo V, Colomi A. Antsystem: Optimization by a colony of cooperating agents[J]. IEEE Transactions on Systems Man and Cybernetics, Part B, 1996, 26(1): 29-41.
- [7] 李祥飞,邹恩,邹莉华,等.前馈神经网络的混沌学习方法研究[J].小型微型计算机系统,2004,25(2):233-236.
LI Xiangfei, ZOU En, ZOU Lihua, et al. Chaos optimization design for feed-forward neural networks[J]. Mini-micro Systems, 2004, 25(2): 233-236. (in Chinese)
- [8] Vapnik V, Golowich S, Smola A. Support vector method for function approximation, regression estimation and signal processing[C]//Proceedings of the 10th Annual Conference on Neural Information Processing Systems. Cambridge: MA, USA: MIT Press, 1997:281-287.
- [9] 郑水波,韩正之,唐厚君,等.最小二乘支持向量机在汽车动态系统辨识中的应用[J].上海交通大学学报,2005,39(3):392-395.
ZHENG Shuibao, HAN Zhengzhi, TANG Houjun, et al. Application of LS-SVMs in the automobile dynamical system identification[J]. Journal of Shanghai Jiaotong University, 2005, 39(3): 392-395. (in Chinese)