

文章编号: 1000-8055(2007)06-0923-05

基于 PSO 算法的航空发动机 起动燃油控制

张东方, 李应红, 陈东林
(空军工程大学 工程学院, 西安 710038)

摘 要: 针对航空发动机起动过程燃油流量优化控制的实时性要求, 提出一种新的航空发动机起动燃油控制方法——基于粒子群优化(PSO)算法的非线性预测控制. 该方法在建立最小二乘支持向量机(LS-SVM)预测模型的基础上, 运用 PSO 算法实现其滚动优化功能. 经实例验证, 燃油流量经过 PSO 算法优化控制后, 高低压转子转速的超调量减小, 并且其稳定的时间比没有经过优化控制的要快上 5~6 s. 由仿真结果可知, 该方法可以用于航空发动机起动过程燃油控制, 当给定的约束条件足够精确时, 能以较高的精度计算出最佳供油规律.

关 键 词: 航空、航天推进系统; 航空发动机; 起动; 燃油流量; 预测控制; 滚动优化; 粒子群优化算法
中图分类号: V233.2 **文献标识码:** A

A new method to control fuel flow of aircraft engine's starting process based on PSO Algorithm

ZHANG Dong-fang, LI Ying-hong, CHEN Dong-lin
(The Engineering Institute,
Air Force Engineering University, Xi'an 710038, China)

Abstract: In order to solve the real time application demand of the fuel flow control in aircraft engine's starting process, a new nonlinear predictive control method based on particle swarm optimization (PSO) algorithm is presented. The method established a predictive model with last squares support vector machines (LS-SVM), and then carried out the receding horizon optimization with PSO algorithm. The example validated that the new control method can reduce the rotors' rotating speed fluctuation and the steady state can be attained 5~6 seconds earlier than that without optimization. The result of the emulation shows that the method is suitable for the fuel flow control, and it can achieve the best control pattern of fuel flow when the restriction is provided accurately.

Key words: aerospace propulsion system; aircraft engine; starting; fuel flow; predictive control; receding horizon optimization; particle swarm optimization (PSO)

目前, 国内外关于航空发动机起动过程控制的研究较少, 特别是理论研究更少. 西北工业大学的屠秋野提出了航空发动机起动控制的一般规

律^[1], 空军工程大学的余波对航空发动机起动过程控制进行了初步研究并提出了基于遗传算法的航空发动机起动过程数字控制方法^[2]. 但遗传算

收稿日期: 2006-05-30; 修订日期: 2006-10-30

作者简介: 张东方(1979), 男, 河南南阳人, 博士生, 主要从事航空发动机控制与仿真的研究.

法速度慢的缺点限制了控制过程实时优化功能的实现。

粒子群优化算法(particle swarm optimization, PSO)是根据鸟群觅食过程中的迁徙和群集模型而提出的一种随机全局优化技术^[3],与遗传算法相比其优势在于简单容易实现而又功能强大^[4]。

本文提出基于 PSO 滚动优化的非线性预测控制方法,解决了文献[2]中起动过程燃油控制实时优化速度慢的问题。

1 起动燃油流量预测控制原理

发动机起动过程燃油流量非线性预测控制的目标函数为二次型指标

min J = \sum_{j=1}^P [y_p(t+j) - y_r(t+j)]^2 + \sum_{i=1}^M \lambda \Delta u(t+i-1)^2 \tag{1}

式中: $y_p(t+j)$ 是 $t+j$ 时刻过程的输出预测, $y_r(t+j)$ 是 $t+j$ 时刻参考轨迹的输出, λ 为参数 Δu 为控制增量。

控制目的为从控制量的容许区间寻找一组最优控制增量序列 $\{\Delta u^*(t+j-1), j=1, \dots, M\}$, 使得目标函数 J 最小。由于本文只研究供油量 p_t 对起动过程性能的影响, 而 n_k 在这个过程中是一个不受控制的量, 应为一组定值序列, 所以 $\Delta u = \Delta p_t$ 。这个寻优过程是在线滚动进行的, 原理图如图 1 所示。




图 1 发动机起动过程预测控制原理图
Fig. 1 Sketch map of predictive control principium of engine's starting process

其中 y_s 为被控对象输出的设定值, $y_r(k+i)$ 为 $k+i$ 时刻的参考轨迹, $u(k)$ 为当前时刻施加于被控对象的控制作用, $y(k)$ 为当前被控对象的实际输出, $y(0)$ 为 $y(k)$ 在零时刻的初始值, $y_m(k)$ 表示当前时刻 LS-SVM 预测模型的输出值, $y_m(k+$

$i)$ 表示 $k+i$ 时刻 LS-SVM 预测模型的预测输出值, $y_p(k+i)$ 为 $k+i$ 时刻考虑到反馈校正作用时的预测输出, $e(k)$ 表示 $y(k) - \hat{y}_m(k)$; $v(k)$ 表示 k 时刻的噪声干扰。当 $i=1$ 时为单步预测控制, 当 $i>1$ 时为多步预测控制, 本文主要讨论多步预测控制。

2 建立非线性预测模型

对于发动机起动过程来说, 可以用状态空间模型进行描述, 其中输入值 $u(k)$, 输出值 $y(k)$, 中间变量为 $x(k)$, 在这里取 $y(k) = x(k)$, 可得发动机起动过程的非线性预测模型为

\begin{cases} x(k+1) = f[x(k), u(k)] \\ y(k) = x(k) \end{cases} \tag{2}

将第 2 个式子代入第 1 个式子, 得

y(k+1) = f[x(k), u(k)] \tag{3}

公式(3)为系统的一步预测模型, 由此可推

y(k+2) = f[x(k+1), u(k+1)]

即为

y(k+2) = f[f[x(k), u(k)], u(k+1)]

依次推下去可得

y(k+i) = F_i[y(k), u(k), u(k+1), \dots, u(k+i-1)] \tag{4}

(1 \leq i \leq P) \quad P \text{ 为优化时域}

公式(4)为系统的多步预测模型。我们可利用 LS-SVM 离线学习大量的发动机起动数据^[2], 将 $u(k) = [N_k(k), p_t(k)]^T$, $y(k) = [N_1(k) \ N_2(k) \ t_s(k)]^T$ 作为状态向量, $y(0) = [N_1(0) \ N_2(0) \ t_s(0)]^T$ 作为初始条件, $y(k+1) = [N_1(k+1) \ N_2(k+1) \ t_s(k+1)]^T$ 作为输出值, 对 LS-SVM 进行反复训练, 得到一些支持向量, 然后再利用支持向量机的回归原理, 按照要求预测 P 步的未来输出值。

由于最小二乘支持向量机不需要对 ε 进行设定, 我们只需设定 C 和 σ 值即可^[5], 使用网格搜索技术^[2], 分别得出这 3 个 LS-SVM 的 C 和 σ 值依次为 (173.7858, 0.4608), (897.8036, 0.2001), (904.842, 0.2142), 将输入数据和输出数据输入 LS-SVM 模型, 进行训练学习并得到辨识模型。

3 PSO 滚动优化

在整个控制过程中, 滚动优化对于非线性预测控制有着非常重要的作用, 它是整个系统的导向器, 引导系统趋于稳定。在发动机起动过程供油

量的优化控制中, 优化主要包括两个方面:

(1) 使得输出矢量 $y(k)$ 中的两个数值 n_1 和 n_2 尽快达到规定的慢车状态的标准转速.

(2) 根据起动约束条件对起动过程进行约束.

航空发动机起动时燃油控制规律的确定主要遵循以下几个原则^[1]: ① 保证高压转子具有一定的喘振裕度; ② 保证涡轮后温度不超出一定限制; ③ 在满足前两个要求的同时, 尽量缩短起动时间.

根据以上原则, 本文选择起动燃油控制过程中受约束的控制量及其取值范围为: ① $t_5 < 500\text{ }^{\circ}\text{C}$ (用涡轮后温度 t_5 替代涡轮前总温 t_4^*); ② $CYD > 10\%$ (高压压气机喘振裕度); ③ $N_2 < 80\%$ (高压转子转速); ④ $0.028 < f < 0.08$ (燃烧室油气比); ⑤ $p_f < 1500$ (用副油道燃油压力 p_f 代替供油量 w_i); ⑥ $-0.5 < dp_f < 0.5$ (用副油道燃油压力变化 dp_f 代替供油量变化 dw_i).

设 Δu 在限定的燃油增量范围 $[\Delta u_{\min}, \Delta u_{\max}]$ 内取值, 在程序设计时, 选择式(1)中的 J 值作为每个粒子的目标函数值 f_i , f_i 值越小, 对应的 Δu_i 的适应值越大.

运用粒子群算法进行航空发动机起动供油规律优化的过程, 相当于在一个一维的目标搜索空间中 $[\Delta u_{\min}, \Delta u_{\max}]$, 有 m 个粒子组成一个部落, 其中第 i 个粒子在该空间中的位置对应一个燃油增量值 Δu_i ($i = 1, 2, \dots, m$); 飞行速度 v_i ($i = 1, 2, \dots, m$); $f_{\min i}$ 和 $\Delta u_{\text{best} i}$ 分别对应第 i 个粒子曾经达到的最大适应值和最好解. $f_{\min G}$ 和 $\Delta u_{\text{best} G}$ 为群体所有粒子达到过的最大适应值和全局最优解, 其索引号为 g . 则每一代其参数随如下方程迭代

$$v_i = wv_i + c_1r_1(\Delta u_{\text{best} i} - \Delta u_i) + c_2r_2(\Delta u_{\text{best} G} - \Delta u_i) \tag{5}$$

$$\Delta u_i = \Delta u_i + v_i \tag{6}$$

式中: r_1, r_2 为 $[0, 1]$ 间的随机数; c_1, c_2 为加速系数; w 为惯性权重. 公式(5)中, 首项为粒子先前的速度; $c_1r_1(\Delta u_{\text{best} i} - \Delta u_i)$ 项为“认知项 (Cognitive term)”, 该项与粒子的认知经验相关; $c_2r_2(\Delta u_{\text{best} G} - \Delta u_i)$ 项为“社会项 (Social term)”, 它代表粒子间的信息共享与合作. 公式(6)为粒子的新坐标位置. 它们共同决定粒子下一步的运动位置.

在每个采样周期 k , PSO 在线优化的流程如下:

- (1) 初始化粒子群. 设群体规模为 m , 在限定的燃油增量范围随机生成粒子 i 的初始值 Δu_i 和初始飞行速度 v_i ($i = 1, 2, \dots, m$);
- (2) 评价每个粒子的适应值, 即计算每个粒

子的当前值对应目标函数值的大小;

(3) 对所有的 $i \in \{1, 2, \dots, m\}$, 如果 $f_i < f_{\min i}$ 则令 $f_i = f_{\min i}$, $\Delta u_i = \Delta u_{\text{best} i}$; 如果, $f_i < f_{\min G}$, 则重新设置 $f_{\min G}$ 的索引号 g ;

(4) 根据公式(6)和(7)调整每一个粒子的位置和速度;

(5) 检查周期完成情况. 如果达到最大迭代次数, 将此时 $\Delta u_{\text{best} G}$ 作为最优控制量投入控制, 并返回步骤 1), 开始下一个采样周期, 否则返回步骤(2).

PSO 中可调的参数主要有: 群体规模 m , 惯性权重 w , 加速度系数 c_1 和 c_2 , 最大代数 $t_{\max}$. 参数对优化过程影响及取值范围见参考文献[4].

对于 PSO 算法中存在的设计约束, 采用动态扰动罚函数的形式转化为无约束问题, 再用无约束优化的方法来寻优. 动态罚函数的表达式为^[3]

$$f_p(x) = f(x) + (Cz)^{\alpha} \sum_{i=1}^m f_i^{\beta}(x) \tag{7}$$

式中: $f_p(x)$ 为罚函数, $f(x)$ 为目标函数, $C = 0.5$, z 为演化代数, $\alpha = 2$, $\beta = 2$, $f_i(x)$ 为约束函数.

4 反馈校正

反馈校正主要是对预测模型的预测偏差进行校正, 提高系统的稳定性, 防止可能出现的发散. 具体过程为: 在 k 时刻, 实际输出值 $y(k)$ 与从 $k-1$ 时刻预测系统的输出值 $y_M(k|k-1)$ 之差为 $e(k|k-1)$, 则 $k+i$ 时刻的预测输出值应为预测模型的输出值 $y_M(k+i|k)$ 与 k 时刻的 $e(k|k-1)$ 之和.

5 实例分析

按照上面的思想和方法, 针对某型涡扇发动机地面起动过程, 利用 C 语言编程实现图 1 所表示的整个优化控制过程, 其中 $M = 2$, $P = 2$; 依据文献[3], 取 PSO 中参数 $w = 1.05$, $c_1 = c_2 = 2$, 粒子个数 $m = 30$, 进化 50 代; 其它限制边界见第 4 部分. 优化控制结果如图 2 所示.

从图 2 可以看出, 燃油流量经过 PSO 算法优化控制后, N_1 和 N_2 的超调量减小, 并且 N_1 和 N_2 稳定的时间比没有经过燃油供油量优化控制的要快上 5~6 s, 但各条曲线在 30~45 s 之间时, 有大约 15 s 的时间停止不变, 产生类似“转速悬挂”的现象. 经过分析, 发现主要有以下两个原因:

- (1) 边界条件限制不够: 尤其是对油气比 f 的富油、贫油限制, 不能简单的用 p_f 和 dp_f 的限制替代. 由于起动初期, 发动机高压转速较低, 对进入燃烧室的空气做功不够, 导致进入燃烧室空




图 2 $-0.5 < dp_f < 0.5$ 时燃油优化控制前后的 N_1, N_2, t_s, p_f 曲线

Fig. 2 Curve of N_1, N_2, t_s, p_f fore and aft the fuel flux optimization control when $-0.5 < dp_f < 0.5$




图 3 $-0.1 < dp_f < 0.1$ 时燃油优化控制前后的 N_1, N_2, t_s, p_f 曲线

Fig. 3 Curve of N_1, N_2, t_s, p_f fore and aft the fuel flux optimization control when $-0.1 < dp_f < 0.1$

气流量较小。而给定的 dp_f 限定范围 $-0.5 < dp_f < 0.5$ 较大,使得优化器一味提高供油量,以达到提高转速的目的,却没有考虑到过量的供油会导致燃烧室富油,引起不正常的反应。

(2) 起动机功率不够: 当起动初期大发涡轮所能发出的功率受到高压压气机喘振裕度和涡轮前燃气温度的限制时, 起动机功率不足, 限制了各状态量的继续爬升。

针对边界条件限制不够的问题, 对控制器参数进行调整, d_{pr} 的限制范围调整到 $[-0.2, 0.2]$, 并重新建立起动模型和预测模型, 将 N_k 的统一区间缩小为 $[-1, 1]$, 以减少它对系统的影响和限制。控制效果如图 3。

从图 3 可以看出来, 参数经过调整后, 效果要比图 2 好很多, 但两组参数得到的转速响应时间却基本不变。经分析可知, 这是因为在起动机功率及其他控制方式(如高压压气机放气活门控制、高压压气机可调叶片角度控制及喷口控制等)确定的情况下, 进行供油规律调整时, 所能达到的控制效果是一定的。

由以上仿真结果及分析可知, 在优化控制的限制条件足够精确的情况下, 该控制方法能较好的沿着边界寻求最优供油曲线。

6 结 论

通过上述分析可以得出如下结论:

(1) 针对特定的发动机, 当起动机型号确定

时, 进行供油规律优化控制所能达到的控制效果是一定的。

(2) 基于 PSO 滚动优化的非线性预测控制方法可以应用于航空发动机起动过程供油控制过程中, 当给定的限定条件足够精确时, 该方法能以较高的精度计算出最佳供油规律。

参考文献:

- [1] 屠秋野, 唐狄毅. 涡扇发动机起动模型及起动控制规律的研究[J]. 推进技术, 1999, 20(2): 21-24.
TU Qiuye, TANG Diyi. Study on startup model and control law of turbofan engine [J]. Journal of Propulsion Technology, 1999, 20(2): 21-24.
- [2] 余波. 航空发动机起动过程控制研究[D]. 西安: 空军工程大学, 2006.
- [3] Kennedy J, Eberhart R. Particle swarm optimization[R]. In: IEEE Int' Conf on Neural Networks, 1995.
- [4] 沈艳, 郭兵, 古天祥. 粒子群优化算法及其与遗传算法的比较[J]. 电子科技大学学报, 2005, 34(5): 696-699.
SHEN Yan, GUO Bing, GU Tianxiang. Particle swarm optimization algorithm and comparison with Genetic Algorithm [J]. Journal of UEST of China, 2005, 34(5): 696-699.
- [5] Suykens J A K, Vandewalle J, De M B. Optimal control by least squares support vector machines[J]. Neural Networks, 2001, 14(1): 23-25.