

文章编号:1000-8055(2013)01-0074-08

熵判别粒子群优化算法在发动机模型修正中的应用

王永华^{1,2}, 杨欣毅¹, 苏 珉¹, 李 冬², 王星博²

(1. 海军航空工程学院 飞行器工程系, 山东 烟台 264001;

2. 海军航空工程学院 研究生管理大队, 山东 烟台 264001)

摘 要: 因生产、安装工艺差别导致单台发动机部件特性的差异,使得模型计算结果与单台发动机的性能差异较大,提出了一种基于熵判别粒子群优化算法。通过判别粒子群的熵值,调整种群的多样性,对适应度差的粒子进行迁移,克服了易陷入局部极小点的缺陷。从仿真结果可知:基于熵判别粒子群优化算法的修正效果显然优于影响系数矩阵的修正方法。经验证,模型修正后的低压涡轮出口温度等 8 个目标性能参数的误差在 1% 以内,达到较好的修正效果,使单台发动机模型能够与真实发动机进行匹配。

关 键 词: 发动机模型; 修正; 信息熵; 粒子群优化; 部件特性

中图分类号: V235.1

文献标志码: A

Engine model correction based on entropy criterion PSO

WANG Yong-hua¹, YANG Xin-yi¹, SU Min¹, LI Dong², WANG Xing-bo²

(1. Department of Aircraft Engineering,

Naval Aeronautical and Astronautical University, Yantai Shandong 264001, China;

2. Graduate Students' Brigade,

Naval Aeronautical and Astronautical University, Yantai Shandong 264001, China)

Abstract: The difference of single component characteristics which is caused by manufacture and installation can make the performance discrepant. A new entropy criterion particle swarm optimization (PSO) has been presented to revise the engine model based on the trial run data. The new algorithm adjusted the speed of inertia weight and migrated the particles of part poor fitness at the same time based on entropy discrimination. The presented algorithm overcame the defect of the original algorithm. The simulation results indicate that the single engine model correction based on entropy criterion PSO is better than the correction based on influence coefficient matrix (ICM). It is verified that the maximum error of the performance parameter is under 1.5%, which means the single engine model and real engine match better.

Key words: engine model; correction; information entropy;
particle swarm optimization (PSO); component characteristic

航空发动机性能仿真广泛应用于发动机设计 研制及使用维护过程中,对于发动机性能改善优

收稿日期:2011-12-12

网络出版地址: http://www.cnki.net/kcms/detail/11.2297.V.20130114.1726.201301.74_Q11.html

基金项目:国家自然科学基金(61102167);航空科学基金(20095584006)

作者简介:王永华(1975—),女,山东海阳人,讲师,博士生,研究领域为发动机性能仿真。E-mail: wangyonghua721@sina.com

化,故障诊断分析起到相当关键的作用.航空发动机是高度非线性的多变量复杂系统,工作范围宽、参数变化范围大,建立其准确的数学模型相当困难.长期以来,国内外的研究人员对模型的修正方法进行了深入的研究,不断地提出一些行之有效的方法.设计部件跟踪滤波器来解决模型计算和发动机实际输出间的失配问题,使发动机实际输出参数和模型计算参数的误差最小^[1].Stamatis等提出了利用修正因子(modification factors, MF)获取实际发动机部件特性的方法,真实的部件特性可由修正因子和参考的通用部件特性获得^[2].针对部件特性的不准确对发动机性能的影响,根据测量数据和模型计算数据的差异,引入一系列修正因子和一个代价函数,利用这些修正因子对发动机部件性能参数进行适应性修正^[3-6].采用三维曲面代替二维转速特性线进行插值提高了模型计算精度^[7-8].基于部件法建立的发动机模型在未知单台发动机部件特性情况下,通常采用通用部件特性进行计算.由于通用部件特性和单台发动机部件特性之间存在差别,发动机性能模型计算的精度会受到影响.即使同一型号、同一批次的发动机由于制造、安装工艺的差异,其部件特性也会有所差异,使得每台发动机的性能差异较大,因而使得发动机模型的仿真结果与各台发动机的真实性能存在较大的误差,不能准确地进行发动机性能分析.本文以某型涡扇发动机为研究对象,针对不同发动机的部件特性的差异使得发动机的性能差异较大的问题,基于熵判别粒子群优化算法进行单台部件特性修正,使模型能够与真实发动机进行匹配.

1 涡扇发动机性能仿真数学模型

图1为所研究的某型混合排气涡扇发动机的结构图,发动机由进气道、风扇、高压压气机、燃烧室、高低压涡轮、混合室和喷管等部件组成.发动机在稳定状态下(高、低转子转速保持不变)工作时,各部件之间必须遵循气动热力学与转子动力学的共同工作条件^[9],即发动机的共同工作方程(也称为平衡方程).各方程如下:

低压涡轮/风扇流量平衡方程

$$\dot{m}_{44} = \dot{m}_{26} \cdot (1 - C_3 + C_2) + \dot{m}_f \quad (1)$$

式中 $\dot{m}_{44}$ 为高压涡轮流量, $\dot{m}_{26}$ 为内涵流量, $\dot{m}_f$ 为燃烧室供油量, C_2 为低压涡轮部件抽气系数, C_3 为飞机引气系数.

高压涡轮/压气机流量平衡方程

$$\dot{m}_{40} = \dot{m}_{26} \cdot (1 - C_3 + C_1) \quad (2)$$

式中 $\dot{m}_{40}$ 为高压涡轮流量, C_1 为高压涡轮部件抽气系数.

低压涡轮/风扇功率平衡方程

$$(N_{tl} - N_{cl})/N_{tl} = 0 \quad (3)$$

高压涡轮/压气机功率平衡方程

$$(N_{th} - N_{ch})/N_{th} = 0 \quad (4)$$

混合室进口静压平衡方程

$$(p_5 - p_{15})/p_5 = 0 \quad (5)$$

加力燃烧室出口/尾喷管气流流量平衡方程

$$(\dot{m}_8 - \dot{m}_7)/\dot{m}_8 = 0 \quad (6)$$




图1 涡扇发动机系统结构图

Fig.1 System structure of turbofan engine

上述方程中的流量、功率等参数由相应的部件计算模型计算得到.一般计算求解时选取高、低压转子转速 n_h, n_l , 风扇和高压压气机的增压比 π_{cl}^*, π_{ch}^* 以及高、低压涡轮的焓降 $\Delta H_l, \Delta H_h$ 共6个参数作为稳态求解初猜值,代入各部件计算模型,将得到的流量、功率、压力等部件性能参数代入式(1)~式(6)组成的非线性方程组,当各方程的残差满足一定值即得到解.选取高、低压转子转速 n_h, n_l 作为求解初猜值,主要作用是在部件特性图上确定特性参数值.以压气机特性为例,已知增压比,需要由转速计算出换算转速,然后从压气机特性图上对应的换算转速线上找到该增压比对应的流量和效率.因此,部件特性的差异会导致发动机模型仿真计算结果误差较大.考虑到单台发动机部件特性的差异,利用试车数据进行部件特性修正.将部件的增压比、流量和效率都作为被优化变量,不再需要特性图的插值运算,因此不需要转速为求解初猜值.

2 部件特性修正

采用多台发动机多状态的试车数据进行单台部件特性修正,将各部件特性的具体数值直接作为待求解的独立变量代入优化目标函数计算,这样发动机非设计点特性计算就转换成为设计点性能计算,从而解决了计算的不收敛的问题.

选择风扇和压气机的流量、增压比、效率和高低压涡轮的效率、焓降和流量等 12 个部件参数作为未知参数。除了上述 6 个平衡方程外还需补充 6 个参数方程。考虑某型发动机试车过程的截面参数,从中选择 6 个测量参数建立流量平衡、压力平衡、热焓平衡方程,得到 12 个优化目标方程来优化求解。选择参数时要避免存在相关性的参数,如推力、耗油率和燃油流量中只有 2 个参数是独立的。如果这 3 个参数都被选中构成目标方程组,则方程组中就出现了线性相关的方程,可能导致无穷解情况出现。本文选择发动机的推力、空气流量、高压气机出口总压 p_{t3} 、高压气机出口总温 T_{t3} 、低压涡轮出口总温 T_{t6} 和加力燃烧室出口总温 T_{t8} 共 6 个测量参数建立方程。

定义目标函数为各方程残差的加权和。

$$F(c) = \sum_{i=1}^{12} \alpha_i \cdot f_i + \sum_{j=1}^{12} \beta_j \cdot (y_j - y'_j) \quad (7)$$

式中 f_i 表示平衡方程, y_j 和 y'_j 分别为试验和计算的参数值。使得该目标函数取得最小值的部件特性参数的组合即为优化过程的解。为简化计算,所有加权系数 α_i 和 β_j 均设置为 1。

3 湿度修正

在进行发动机性能仿真计算时,通常假设其工质为理想的干空气,而实际在低空飞行或地面试车时发动机吸入的工质都是含有水蒸气的湿空气,大气湿度的变化对发动机性能及其工作特性有一定的影响,这种影响在夏天地面台架试车时更为明显。考虑不同地区、不同季节绝对湿度差异情况,对发动机模型进行湿度修正^[10]。

假定发动机与外界没有热交换,气体流动对雷诺数自模化,忽略气体重力的影响,在燃烧室内不考虑物理化过程的相似。按相似原理,定义压气机换算转速、流量、焓降的湿度修正系数为

$$\left(\frac{N}{\sqrt{T_0^*}} \right)_w / \left(\frac{N}{\sqrt{T_0^*}} \right)_d = \sqrt{\frac{R_w \gamma_w}{R_d \gamma_d}} \quad (8)$$

$$\left(\frac{\dot{m} \sqrt{T_0^*}}{p_0^*} \right)_w / \left(\frac{\dot{m} \sqrt{T_0^*}}{p_0^*} \right)_d = \sqrt{\frac{R_d \gamma_w}{R_w \gamma_d}} \quad (9)$$

$$\left(\frac{\Delta H}{T_0^*} \right)_w / \left(\frac{\Delta H}{T_0^*} \right)_d = R_w \cdot \gamma_w / R_d \cdot \gamma_d \quad (10)$$

下标 w, d 分别表示对应的湿空气状态和标准状态,同理,涡轮换算转速、流量、焓降的湿度修正系数为

$$\left(\frac{N}{\sqrt{T_0^*}} \right)_w / \left(\frac{N}{\sqrt{T_0^*}} \right)_d = \sqrt{\frac{R_w \gamma_w (1 + \gamma_d)}{R_d \gamma_d (1 + \gamma_w)}} \quad (11)$$

$$\left(\frac{\dot{m} \sqrt{T_0^*}}{p_0^*} \right)_w / \left(\frac{\dot{m} \sqrt{T_0^*}}{p_0^*} \right)_d = \sqrt{\frac{R_d \gamma_w}{R_w \gamma_d}} \cdot \left(\frac{2}{1 + \gamma_w} \right)^{(\gamma_w + 1)/2 \cdot (\gamma_w - 1)} \cdot \left(\frac{1 + \gamma_d}{2} \right)^{(\gamma_d + 1)/2 \cdot (\gamma_d - 1)} \quad (12)$$

$$\left(\frac{\Delta H}{T_0^*} \right)_w / \left(\frac{\Delta H}{T_0^*} \right)_d = R_w \cdot \gamma_w \cdot (1 + \gamma_d) / R_d \cdot \gamma_d \cdot (1 + \gamma_w) \quad (13)$$

推力和耗油率的湿度修正系数为

$$C_{h,f} = \left(\frac{F}{p_0^*} \right)_w / \left(\frac{F}{p_0^*} \right)_d = \gamma_{9,w} / \gamma_{9,d} \quad (14)$$

$$C_{h,sfc} = \left(\frac{s_{fc}}{\sqrt{T_0^*}} \right)_w / \left(\frac{s_{fc}}{\sqrt{T_0^*}} \right)_d = \frac{\gamma_{9,w}}{\gamma_{9,d}} \cdot \frac{C_{p,w}}{C_{p,d}} \cdot \sqrt{\frac{\gamma_{9,w} R_w}{\gamma_{9,d} R_d}} \quad (15)$$

某型发动机在不开加力的情况下的出口温度在 500~800 K,通过上述公式可得到该温度变化区间的换算推力修正湿度系数。

4 单台发动机性能模型修正的实现

考虑了湿度和部件特性修正后,采用多台发动机多状态的试车数据进行单台部件特性修正问题就转化为 12 个优化目标方程求解问题。随着目标方程数目增加,采用传统的迭代方法求解变得非常困难。近年来,一些学者采用遗传算法、粒子群优化等智能算法^[11-12]进行求解,克服了传统迭代方法的不足,取得了较好的效果。本文提出一种基于熵判别粒子群算法进行求解,取得了较好的效果。

4.1 熵判别粒子群优化算法

自 Clerc 和 Kennedy 提出粒子群优化 (particle swarm optimization, PSO) 算法以来,在很多领域得到了成功的应用^[13]。在标准 PSO 算法中,粒子收敛是以轨道的形式实现的,根据全体粒子和自身的搜索经验向着最优解的方向“飞行”,在进化后期收敛速度明显变慢,同时算法收敛到一定精度时,算法无法继续优化,不能稳定地获得全局最优解。如何科学、合理地控制种群多样性对于粒子群算法的收敛效率有着至关重要的意义。引入熵判别的概念,根据粒子群的熵值大小,对粒子的速度惯性权重进行调整,同时对部分适应度差的粒子进行迁移,从而对粒子群算法进行改进。

4.1.1 熵模型

基于信息熵理论,建立熵模型,通过计算粒子的熵值对粒子的惯性权重进行动态调整,在最优

解的求解过程中,使粒子在较大程度上离开原来的寻优轨程,偏到新的方向进行搜索,能够快速搜索到最优解。

采用适应度比例法, $f(x_{ti})$ 为第 t 代的第 i 个粒子的适应度值,则第 t 代的第 i 个粒子适应度值与当代全体粒子适应度值的比率 $p(x_{ti})$ 为

$$p(x_{ti}) = \frac{f(x_{ti})}{\sum_{i=1}^N f(x_{ti})} \quad i = 1, 2, \dots, N \quad (16)$$

式中 N 为整个群体的粒子总数。

构造如下熵模型:

$$\begin{aligned} H(t) &= - \sum_{i=1}^N p(x_{ti}) \log_N p(x_{ti}) \\ \text{s. t. } \sum_{i=1}^N p(x_{ti}) &= 1 \\ p(x_{ti}) &\in (0, 1) \end{aligned} \quad (17)$$

式中 $H(t)$ 为第 t 代全体粒子的熵值。利用 $H(t)$ 的好坏程度来衡量整个粒子群当代的寻优程度。根据最大熵原理,算法终止时所有粒子都聚集到最优点附近,所有粒子的适应度值在该时刻都与最优值相同或非常接近。所有粒子的 $p(x_{ti})$ 应无限接近于 $1/N$, $H(t)$ 达到最大值 1, 粒子趋于稳定; $H(t)$ 越接近于 0, 说明第 t 代粒子适应度值分布越不均匀,相差越大,算法不稳定。

4.1.2 种群多样性调整算子

研究表明如果进化过程中粒子多样性损失过快,种群可能会过早收敛于局部最优,从而丧失了全局搜索能力;反之,如果种群在算法迭代的后期保持较高的多样性,粒子分布范围很分散,则算法搜索到最优解的可能性会减小。如果在迭代过程中粒子的多样性始终保持合理的范围,则有利于提高算法的收敛性能。

本文中种群的多样性是由其熵值来表示的。因此在迭代过程中,可以根据种群熵值的变化情况进行调整,避免出现过早收敛或局部收敛现象。

具体的调整措施如下:定义熵值分布的上界 $L_{up}(t)$ 和下界 $L_{down}(t)$ 为

$$L_{up}(t) = \begin{cases} 1 - \frac{a(t-t')^2}{T_{max}^2} & t \leq t' \\ 1 & t > t' \end{cases} \quad (18)$$

$$L_{down}(t) = bt \quad (19)$$

粒子群调整区域见图 2。

如图 2 所示,当种群在第 t 代的熵 $H(t)$ 低于 $L_{down}(t)$ 或高于 $L_{up}(t)$ 时,说明种群分布过于分




图 2 基于熵判别的粒子群调整区域图

Fig. 2 Redressal area based on the entropy of PSO

散或过于集中,种群分布处于“非理想”状态,可能会过早收敛或收敛失败。此时,通过对粒子群飞行速度的惯性权重进行调整可以有效打破种群的“非理想”状态分布。

新的速度更新公式为

$$\begin{aligned} v_{id}(k+1) &= c_w w \cdot v_{id}(k) + \\ & c_1 r_1 [p_{id} - x_{id}(k)] + c_2 r_2 [p_{gd} - x_{id}(k)] \end{aligned} \quad (20)$$

其中 c_w 为基于熵的速度惯性权值系数。

$$c_w = \begin{cases} 1 + c_u [H(t) - L_{up}] & H(t) > L_{up} \\ 1 & L_{down} \leq H(t) \leq L_{up} \\ 1 - c_d [L_{down} - H(t)] & H(t) < L_{down} \end{cases} \quad (21)$$

其中 $c_u, c_d > 0$ 为调整参数,本文取 $c_u = 1.3, c_d = 0.7$ 。对种群中 $\sigma(t)$ 个个体适应度最差的个体进行迁移。如果 $H(t)$ 大于 $L_{up}(t)$, 则对 $\sigma(t)$ 个个体进行随机赋值替换;如果 $H(t)$ 小于 $L_{down}(t)$, 则从剩下的 $N - \sigma(t)$ 个粒子中随机选择 $\sigma(t)$ 个适应度差的个体进行替换。

考虑到算法收敛问题,在算法后期进行迁移运算不宜替换过多的粒子。对 $\sigma(t)$ 作如下设计:

$$\sigma(t) = c_q N \left(1 - \frac{t}{T_{max}} \right) \quad (22)$$

其中 $c_q \in \mathbb{R}$ 为迁移参数,本文取 1.0。

根据仿真计算结果, b 越大,种群的熵值越大; a 越大,调整上限减小,调整区域增大,粒子分布范围分散; t' 增大时,超出上下限的粒子数量增多。综合考虑取 $a=200, b=0.4, t'=0.7$ 。

本文提出的熵判别粒子群优化 (entropy-based particle swarm optimization, EPSO) 算法,其主要步骤如下:

Step 1 在定义域内随机初始化 N 个粒子的位置和速度,设置最大迭代次数 T_{max} 。

Step 2 计算每个粒子的适应度.

Step 3 更新粒子的速度和位置, 确定每个粒子个体极值和全局极值.

Step 4 根据熵模型式(17)计算种群的熵值, 若该时刻的熵值低于 $L_{\text{down}}(t)$ 或高于 $L_{\text{up}}(t)$ 则进行 Step 5, 否则进行 Step 6.

Step 5 根据式(21)调整惯性权重, 重新更新粒子的速度, 并对 $\sigma(t)$ 个适应度最差的个体进行迁移.

Step 6 若迭代次数达到 T_{max} 则输出全局极值 gbest 并退出, 否则, $i_{\text{ter}} = i_{\text{ter}} + 1$, 转 Step 2 继续迭代.

4.1.3 基于熵判别的改进粒子群优化算法

为验证改正算法的性能, 选取 3 个非线性方程组^[14]作为测试问题. 各方程组及其定义域和解如下:

方程组 1

$$\begin{cases} x_1^2 + x_2^2 + x_3^2 - 3 = 0 \\ x_1^2 + x_2^2 + x_1 x_2 + x_1 + x_2 - 5 = 0 \\ x_1 + x_2 + x_3 - 3 = 0 \end{cases} \quad (23)$$

$x_i \in [-1.732, 1.732]$, 理论解 $x^* = (1, 1, 1)^T$.

方程组 2

$$\begin{cases} 821x_1^2 - 263x_2x_3 + 661 = 0 \\ 613x_1x_3 - 977x_1x_2 - 268 = 0 \\ 977x_1x_3 + 373x_1 - 647x_2x_3 - 811 = 0 \end{cases} \quad (24)$$

$x_i \in [0, 10]$, 理论解 $x^* = (2, 3, 5)^T$.

方程组 3

$$\begin{cases} x_1 + 0.25x_2^2x_4x_6 + 0.75 = 0 \\ x_2 + 0.405e^{(1+x_1x_2)} - 1.405 = 0 \\ x_3 - 0.25x_4x_6 + 1.25 = 0 \\ x_4 - 0.605e^{(1+x_3^3)} - 0.395 = 0 \\ x_5 - 0.5x_2x_6 + 1.5 = 0 \\ x_6 - x_1x_5 = 0 \end{cases} \quad (25)$$

$x_i \in [-2, 2]$, 理论解 $x^* = (-1, 1, -1, 1, -1, 1)^T$.

以 N-R (Newton-Rathson) 算法、PSO、文献[14]中的免疫粒子群优化算法 (IMPSO) 作为被比较算法和本文的 EPSO 对测试的方程组进行优化求解. 算法中学习因子、惯性权重等参数设置对算法性能有重要影响, 本文参考文献[13]的参数设置: 取粒子 $N=100$, 学习因子 $c_1 = c_2 = 1.4962$, 惯性权重 $\omega = 0.728$.

迭代上限为 300 次. 各算法均运行 20 次, 将各次运算得到的最优解取平均值, 结果见表 1 和表 2.

由表 1 和表 2 的结果可以发现: 基于种群的智能优化算法其结果无论是收敛的成功率还是解的平均值都要优于传统的迭代方法. 由于 N-R 法的求解受到初值影响较大, 当初始值偏离解较远时, 算法经常不收敛, 得不到满足精度要求的解. 而其他粒子群优化算法则不受初值影响, 均能得到满足精度要求的解, 求解的成功率均为 100%. 在几种粒子群优化算法中, 除了方程组 3 的 x_5 由 IMPSO 取得最好的结果, 其他解的最好结果均是由本文的 EPSO 算法取得.

表 1 各算法对方程组 1 和 2 求解的结果

Table 1 Algorithmic results of equations sets 1 and 2

问题序号	算法	成功率/%	x_1		x_2		x_3	
			平均值	误差/ 10^{-6}	平均值	误差/ 10^{-6}	平均值	误差/ 10^{-6}
方程组 1	N-R	70	1.0000097	9.7	1.0000082	8.2	1.0000107	11
	PSO	100	1.0000034	3.4	0.9999941	-5.9	0.9999964	-3.6
	IMPSO	100	1.0000005	0.54	0.9999992	-0.73	0.9999990	-0.86
	EPSO	100	0.9999999	0.32	0.9999998	0.013	0.9999996	-0.056
方程组 2	N-R	65	2.0000123	6.1	2.9999903	-3.3	5.0000128	2.5
	PSO	100	1.9999936	-3.2	2.9999925	-2.5	4.9999897	-2.1
	IMPSO	100	1.9999998	-0.1	3.0000009	0.33	5.0000034	0.63
	EPSO	100	2.0000001	0.021	3.0000002	0.043	4.9999999	0.13

采用 EPSO 算法, 以发动机地面试车的大气温度、压力和湿度为仿真环境, 以 001 号发动机工作在 $N_h=98\%$ 的工作状态为例, 分别给出 PSO

和 EPSO 算法在计算求解收敛过程的熵值变化情况, 见图 3. 当预测参数和实际参数的标准差小于阈值 δ , 则停止迭代. 本文中选取 $\delta=0.001$.

表 2 各算法对方程组 3 求解的结果
Table 2 Algorithmic results of equations set 3

问题序号	算法	成功率/%	x_1		x_2		x_3	
			平均值	误差	平均值	误差	平均值	误差
方程组 3	N-R	55	-1.0000128	13	0.9999851	-15	-0.9999780	-22
	PSO	100	-1.0000095	9.5	0.9999919	-9.1	-1.0000054	5.4
	IMUPSO	100	-1.0000017	1.7	0.9999984	-1.6	-0.9999977	-2.3
	EPSO	100	-0.9999999	0.95	1.0000000	0.41	-1.0000000	1.2
问题序号	算法	成功率/%	x_4		x_5		x_6	
			平均值	误差	平均值	误差	平均值	误差
方程组 3	N-R	55	1.0000094	9.4	-1.0000115	12	0.9999883	-12
	PSO	100	0.9999943	-5.7	-0.9999956	-4.4	0.9999912	-8.8
	IMPSO	100	0.9999970	-3.0	-1.0000000	1.5	1.0000034	3.4
	EPSO	100	0.9999999	-2.3	-1.0000021	2.1	0.9999999	1.9




图 3 不同模型的熵值变化图
Fig. 3 Entropy variation of different models

从计算结果可以看出基于熵改进粒子群算法的熵值在理想收敛区域的比例要明显高于基本粒子群的熵值在理想收敛区域的比例基本粒子群算法在求解后期的熵值几乎为 0,表明群体很不稳定.

4.2 模型修正仿真结果

采用 2005 年至 2010 年的 12 台涡扇发动机的 6 个工作状态下的试车数据对模型修正方法进行检验.选择表 3 所示的气路截面参数作为目标性能参数.

表 3 目标性能参数
Table 3 Target performance parameters

序号	符号	意义
1	T_2	低压压气机出口温度
2	p_2	低压压气机出口压力
3	T_3	高压压气机出口温度
4	p_3	高压压气机出口压力
5	T_5	低压涡轮出口温度
6	T_8	尾喷管出口温度
7	F	发动机推力
8	s_{fc}	耗油率

将基于熵判别粒子群优化算法的单机修正模型的计算结果(EPSO)、文献[15]中的基于影响系数矩阵的修正模型计算结果(ICM)和未修正的模型计算结果(Uncorrected)进行比较,以 001 号发动机 6 个工作状态平均误差为例,给出计算结果见图 4.

通过计算,可以看出 2 种修正方法得到的单个性能参数的偏差量都达到了修正的精度要求.但基于影响系数矩阵的修正模型计算结果中的部分性能参数如低压压气机出口温度和高压压气机出口压力参数的偏差量较大,总体上基于熵判别




图 4 不同修正方法计算的参数偏差

Fig. 4 Parameter deviation of different methods

粒子群优化算法的单机修正效果较好。

采用本文提出的单台发动机性能模型修正方法对 12 台发动机进行求解,将每台发动机试车数据与修正模型计算的各截面气路参数进行比较,计算单台发动机多状态每个气路目标性能参数的平均误差,并求出单个气路目标性能参数误差的统计分布,见图 5,每个气路目标性能参数多状态误差最大、最小和平均值见图 6。

从 12 台发动机修正模型计算的各截面目标性能参数与试车数据的误差分析可知,单台发动机的 6 个工作状态的 8 个目标性能参数平均误差均在 1% 以下,其中尾喷管出口温度参数误差最









(a) T_2 (b) p_2 (c) T_3 (d) p_3 (e) T_5 (f) T_8 (g) F (h) s_{fc}

图 5 12 台发动机的目标性能参数误差分布

Fig. 5 Parameter error distribution of twelve engines

大为 0.82%。计算各个目标性能参数误差分布的偏斜度,得到低压压气机出口温度参数的偏斜度最大为 0.4202,发动机推力参数的偏斜度最小为 0.0658,可以近似认为各参数误差分布符合正态分布。计算各个目标性能参数误差在区间

$[-0.01, 0.01]$ 的概率,则低压涡轮出口温度参数概率值最大为 0.9964,低压压气机出口压力概率值最小为 0.9220,可以认为各截面的气路目标性能参数经单台模型修正后总体误差在 1% 以内,一般工程要求修正精度在 2% 以内,采用本文算法达到较好的修正效果。




图6 目标性能参数平均误差

Fig. 6 Mean error of target performance parameter

5 结 论

本文针对单台发动机因生产安装工艺差别导致的单台发动机部件特性的差异进行发动机模型单机修正,提出了一种基于熵判别粒子群优化算法进行多维非线性方程组求解的方法。经测试,与 N-R 算法、基本粒子群算法和免疫粒子群优化算法相比,本文提出的熵判别粒子群算法有较高的求解精度。将该算法应用于发动机模型修正,以多台多状态的发动机试车数据对发动机模型修正结果进行验证,求解的气路目标性能参数误差符合正态分布,总体误差在 1% 内,表明经该算法求解修正模型取得较好的效果。

参考文献:

- [1] 张海波,陈霆昊,孙健国,等. 一种新的航空发动机自适应模型设计与仿真[J]. 推进技术, 2011, 32(4): 557-563.
ZHANG Haibo, CHEN Tinghao, SUN Jianguo, et al. Design and simulation of a new novel engine adaptive model [J]. Journal of Propulsion Technology, 2011, 32(4): 557-563. (in Chinese)
- [2] Stamatis A, Mathioudakis K, Papailiou K D. Adaptive simulation of gas turbine performance[J]. Journal of Engineering for Gas Turbines and Power, 1990, 112(2): 168-175.
- [3] Li Y G, Pilidis P. An adaption approach for gas turbine design-point performance simulation[J]. Journal of Engineering for Gas Turbines and Power, 2006, 128(10): 789-795.
- [4] Li Y G, Nilkitsaranont P. Gas turbine performance prognostic for condition-based maintenance [J]. Applied Energy, 2009, 86(3): 2152-2161.
- [5] 李本威,尹大伟,王永华,等. 某型涡扇发动机状态模型修正[J]. 海军航空工程学院学报, 2008, 23(2): 212-216.
LI Benwei, YIN Dawei, WANG Yonghua, et al. State-model correction of a certain turbopfan engine [J]. Journal of Naval Aeronautical and Astronautical University, 2008, 23(2): 212-216. (in Chinese)
- [6] 陈玉春,黄兴,徐思远,等. 涡轮发动机部件特性自适应模型的确定方法[J]. 推进技术, 2008, 29(2): 214-218.
CHEN Yuchun, HUANG Xing, XU Siyuan, et al. A method of definition for the adaptive simulation model of gas turbine performance [J]. Journal of Propulsion Technology, 2008, 29(2): 214-218. (in Chinese)
- [7] 杨欣毅,沈伟,刘海峰,等. 一种应用滑动最小二乘求取压气机特性的方法[J]. 航空动力学报, 2009, 24(8): 1741-1746.
YANG Xinyi, SHEN Wei, LIU Haifeng, et al. Compressor characteristics generation method using moving least square [J]. Journal of Aerospace Power, 2009, 24(8): 1741-1746. (in Chinese)
- [8] 尹大伟,李本威,王永华,等. 基于 Kriging 方法的航空发动机压气机特性元建模[J]. 航空学报, 2011, 32(1): 99-105.
YIN Dawei, LI Benwei, WANG Yonghua, et al. Research on aeroengine compressor characteristics metamodeling methodology using Kriging method [J]. Acta Aeronautica et Astronautica Sinica, 2011, 32(1): 99-105. (in Chinese)
- [9] 骆广琦,桑增产,王如根,等. 航空燃气涡轮发动机数值仿真[M]. 北京:国防工业出版社, 2007.
- [10] Mathioudakis K, Tsalavoutas T. Uncertainty reduction in gas turbine performance diagnostics by accounting for humidity effects [J]. Journal of Engineering for Gas Turbines and Power, 2002, 124(5): 801-808.
- [11] Li Y G, Pilidis P. GA-based design-point performance adaptation and its comparison with ICM-based approach [J]. Applied Energy, 2010, 87(1): 340-348.
- [12] 杨欣毅,沈伟,刘海峰,等. 弹用喷喷发动机风车启动过程仿真及性能分析[J]. 兵工学报, 2011, 32(1): 37-44.
YANG Xinyi, SHEN Wei, LIU Haifeng, et al. Numerical simulation and performance analysis on start process of missile turbojet engine windmill [J]. Acta Armamentarii, 2011, 32(1): 37-44. (in Chinese)
- [13] Clerc M, Kennedy J. The particle swarm: explosion, stability, and convergence in a multi-dimensional complex space [J]. IEEE Trans on Evolutionary Computation, 2002, 6(1): 58-73.
- [14] 李本威,张赞,孙涛. 基于免疫粒子群算法的滑油屑末支持向量机预测模型设计[J]. 航空动力学报, 2009, 24(7): 1639-1643.
LI Benwei, ZHANG Yun, SUN Tao. Design of forecasting model for aero-engine lubrication debris support vector machines based on immune-particle swarm optimization algorithm [J]. Journal of Aerospace Power, 2009, 24(7): 1639-1643. (in Chinese)
- [15] Doel D. TEMPER: a gas path analysis tool for commercial jet engines [J]. Journal of Engineering for Gas Turbines and Power, 1994, 116(5): 82-89.