

基于 DMOM 算法的航空发动机性能寻优控制

王 元¹, 李秋红², 黄向华²

(1. 中国航空工业集团公司 航空动力控制系统研究所, 江苏 无锡 214063;
2. 南京航空航天大学 能源与动力学院 江苏省航空动力系统重点实验室, 南京 210016)

摘 要: 提出一种分散迁移优化算法(DMOM),可实现多峰值优化问题的全局最优解搜索. 该算法通过随机选择参考粒子,不断迁移搜索自身所处区域峰值点,再通过分散操作排除局部最优解,重新生成新个体,可快速搜索到全局最优区域. 将 DMOM 应用于航空发动机性能寻优控制仿真,结果表明:在最小油耗和最低涡轮温度模式下,DMOM 的寻优速度相比遗传算法(GA)和粒子群算法(PSO)提高了 2 倍以上;同时 DMOM 的优化精度相比自组织迁移算法(SOMA)提高了 60% 以上,相比可行性序列二次规划(FSQP)算法提高了 20% 以上. 验证了 DMOM 相比其他优化算法有更强的跳出局部最优的能力,在航空发动机最小油耗和最低涡轮温度这类多峰值寻优问题中具有明显的优势.

关 键 词: 航空发动机; 性能寻优控制; 分散迁移优化算法; 最小油耗寻优控制; 全局最优解

中图分类号: V231 **文献标志码:** A

Aero-engine performance seeking control based on DMOM algorithm

WANG Yuan¹, LI Qiu-hong², HUANG Xiang-hua²

(1. Aviation Motor Control System Institute,
Aviation Industry Corporation of China, Wuxi Jiangsu 214063, China;
2. Jiangsu Province Key Laboratory of Aerospace Power System,
College of Energy and Power Engineering,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: A distributed migration optimization method (DMOM) for multi-peak optimization problem was proposed to find global optima solution. In this algorithm, the local optima could be searched out by continuous discrete and migration with new individuals. Then the global optima solution was found by sorting. During the discrete process the possibility of sinking into local optima was reduced compared with other algorithms. The DMOM was used for aero-engine performance seeking control in digital simulation. Results show that, in minimum fuel mode and minimum turbine temperature mode, the DMOM is improved by more than 2 times compared with genetic algorithm (GA) and particle swarm optimization (PSO), the optimization accuracy of DMOM is improved by more than 60% compared with self-organizing migrating algorithm (SOMA), and more than 20% compared with feasible sequential quadratic programming (FSQP). Comparative results show that the calculation time can be reduced and the aero-engine performance can be improved by using this algorithm.

Key words: aero-engine; performance seeking control (PSC); distributed migration optimization method (DMOM); minimum fuel consumption seeking control; global optima solution

随着新一代战机性能要求不断提高,为了挖掘航空发动机的潜力,NASA 提出了性能寻优控制 PSC^[1-4] (performance seeking control),PSC 可以根据不同飞行需求对航空发动机性能进行在线实时优化,获得最佳匹配的控制量,达到根据飞行任务提高发动机性能的目的.最小油耗控制是发动机性能寻优的一个重要研究内容,在保证推力的前提下,降低发动机的耗油率,可以起到节能减排,延长飞行器航行时间的作用,具有明显的经济效益和社会效益.

美国国家航空航天局通常采用线性规划(LP)算法进行 PSC^[5-10],但适用于线性系统的 LP 算法在对非线性系统进行寻优计算时会产生累积误差,优化精度较低.序列二次规划(SQP)算法优化精度相比 LP 算法有所增加^[10-11],在 SQP 算法的基础上,文献[12]又提出了能够保证迭代点可行性的可行性序列二次规划(FSQP)算法,相比于 SQP 算法计算量更小,文献[13]将 FSQP 算法引入 PSC 获得了较好的优化效果.另一类基于群体进化原理的优化算法如 GA,PSO 等在 PSC 中也有所应用^[14].

由于航空发动机是一个强非线性系统,随着可优化参数的不断增多,PSC 实时优化的难度也在不断加大.以双轴涡扇发动机最小油耗模式为例,当双轴涡扇发动机处于巡航状态时,为增加作战半径及提高经济性,需要同时优化燃油流量 W_{fm} ,尾喷口面积 A_8 ,风扇导叶角 d_f ,压气机导叶角 d_c 四个参数,在保持推力恒定的前提下尽可能的降低耗油率(SFC,量符号记为 S_{fc}).优化过程中,局部最优点随着可优化参数的增多和可搜索范围的增加而急剧增加,使得在保证优化实时性的前提下,无论是经典的 LP,SQP,FSQP 算法,还是群体智能的 GA,PSO 等,都容易陷入局部最优,这成为限制多变量寻优控制效果的主要因素.

本文从群体迁移角度出发,借鉴自组织迁移算法(SOMA)^[15-16]步骤,提出了一种分散迁移优化算法(distributed migration optimization method,DMOM),通过多个寻优个体的分散迁移,不断搜索出区域内的局部最优点,再通过排序确定全局最优点,算法收敛速度快且能够有效避免陷入局部最优.

1 分散迁移优化算法

与其他群体进化算法不同,DMOM 中每个寻优个体的任务是确定其所在区域的峰值位置,当多峰形区域内所有峰形最优点确定后,通过排序就可以找出全局最优点.相比其他通过向最优个体聚集获得最优解的群体进化算法,DMOM 对寻优个体采取分散迁移处理,随机生成初始种群后,每个个体随机选择其他个体作为参照点进行迁移,避免个体在局部最优处聚集,通过迁移处理寻找个体所在峰形区域的极值.由于寻优种群始终处于分散状态而非聚集收敛,这牺牲了算法在单峰形区域的寻优能力,但在多峰形问题中可以避免陷入局部最优,因此往往能获得更好的搜索结果.DMOM 运算流程如图 1 所示,具体步骤如下:




图 1 DMOM 流程图
Fig. 1 Flow chart of DMOM

Step 1 产生初始父代种群 P_0 ,种群个体数为 n ,决策变量个数为 m .初始化过程中每个个体的位置 $X_{0i}=(x_1,x_2,\cdots,x_m)$, $x_j(j=1,2,\cdots,m)$ 在给定的最大值 x_{jmax} 和最小值 x_{jmin} 之间随机生成.计算每个个体的适应度 $f(X_{0i})$.

Step 2 根据个体适应度对第 q 代种群 P_q 中的个体进行排序.

Step 3 种群个体迁移.随机选取参考个体

X_{qr} 为 X_{qi} 提供迁移速度和方向 V_{qi}

$$V_{qi} = k(X_{qi} - X_{qr}) \cdot \text{sign}[f(X_{qr}) - f(X_{qi})]$$

其中 k 为迁移步长, X_q 沿方向 V_{qi} 进行试探迁移, 若迁移后个体适应度没有优于迁移前的适应度, 则沿 V_{qi} 的反方向试探迁移

$$V_{qi} = -V_{qi}$$

若反向迁移仍得不到更优的适应度, 则该个体停止迁移进入 step 4; 若迁移后个体适应度优于迁移前的适应度, 则更新个体 X_{qi} 的位置并加大迁移步长 k

$$X_{qi} = X_{qi} + V_{qi}$$

$$k = 2k$$

式中 X_{qi} 继续沿 V_{qi} 方向迁移直至个体 X_{qi} 不再更新。

此操作的含义为个体 X_{qi} 以个体 X_{qr} 为参照, 通过初步试探迁移确定靠近还是远离参考个体, 再逐步增加迁移步长, 使个体向当前区域最优点快速迁移, 当新位置比原位置更优时则更新个体位置, 否则迁移方向反向, 若两次反向, 则中止迁移操作进入 step 4, 在多峰值问题中的操作示意图如图 2 所示, 图中以个体位置 X 为横坐标, 个体的适应度 $f(X)$ 为纵坐标, 考察个体 X_{qi} , 对应的适应度为 $f(X_{qi})$, 随机选择 X_{qr} 为参考点, 则 X_{qi} 以步长 k 向参考点位置移动到点“1”, 若其对应的适应度下降, 则以步长 k 反向迁移到点“2”, 若其对应的适应度增大, 则以步长 $2k$ 迁移到点“3”, 再以 $4k$ 步长迁移时发现适应度降低, 则停止迁移, 停留在点“3”的位置, 完成此粒子的本代搜索。




图 2 粒子迁移示意图
Fig. 2 Scheme of migration

Step 4 当个体迁移至当前区域最优点 (以不同个体为参照点, 多次初步试探迁移未能找附近更优位置) 并确定此点并非当前种群最优时, 以及当多个个体聚集于同一区域时, 如图 3 所示, 当个体 X_{qj} 与个体 X_{qbest} 距离较小 (小于 δ), 而适应

度相对较低时, 则随机生成新个体 X_{qj} , 代替原来的 X_{qj} . 而对于个体 X_{qi} , 已经达到局部最优, 但对比 X_{qbest} 的适应度, 发现低于全局最优, 证明在 X_{qi} 所处的局部区域, 没有全局最优点, 同样对其进行分散处理, 以在其他区域进行第 2 轮搜索. 分散处理如下所示:

$$X_{\text{new}} =$$

$$\beta \cdot (X_r - X_{\text{old}}) \cdot \text{sign}[f(X_{\text{old}})f(X_r)] + X_{\text{old}}$$

其中 β 为大于 0 的随机数, X_{old} 为待分散个体位置, X_r 为随机选取的参照点位置, X_{new} 为分散后个体的新位置. 分散处理的实际意义是期望通过参考适应度的变化趋势, 将已经不具备进化潜力的个体分配至可能存在更高局部峰值的区域, 再通过个体迁移找出该区域最优点。




图 3 粒子分散示意图
Fig. 3 Scheme of distributed

Step 5 通过迁移和分散生成种群 P_{q+1} .

Step 6 判断是否满足优化结束条件, 不满足则回到步骤 2 进行新一轮的迁移和分散操作。

2 PSC 数值仿真实验

航空发动机性能寻优控制中的最小油耗控制是个典型的多峰值问题, 由于发动机的强非线性, 使得以当前最优值为聚集目标的优化算法易陷入局部最优. 将 DMOM 用于发动机最小油耗控制, 其控制原理如图 4 所示, 优化控制系统主要包括发动机闭环控制系统和 PSC 模块, 其中 PSC 模块由 DMOM 和发动机机载模型组成, 在寻优过程中, 发动机机载模型通过接收来自发动机及数字电子控制器的当前工作点参数, 模拟发动机的工作状态, 当发动机处于准稳态时, DMOM 基于发动机的当前工作状态, 寻求 W_{fm} , A_8 , d_i , d_c 的最佳组合, 在保证发动机推力的前提下, 降低发动机的耗油率. 将优化所得的最优控制量组合, 通过机载模型计算出对应工作状态的高压转子转速

n_h 和低压转子转速 n_l 指令修正量,与原系统的指令相叠加,将 A_8, d_f, d_c 的修正量与控制器计算出来的相应控制量相叠加,实现基于优化结果的发动机工作状态调节。




图 4 性能寻优控制结构图
Fig. 4 Structural chart of PSC

基于上述发动机性能寻优控制结构及 DMOM, 本文以某型双轴涡扇发动机非线性部件级模型作为机载模型及寻优模型,进行了发动机性能寻优控制数值仿真,数值仿真是在主频 2.53 GHz + 2.53 GHz/内存 2G 的计算机中进行,仿真步长为 0.02 s,其中 $\Delta d_f, \Delta d_c$ 分别为风扇导叶角和压气机导叶角的变化量,其他物理量均为相对值。下面给出最小油耗控制在两个工作点的验证结果。

2.1 DMOM 参数设置

以最小油耗模式为例,在不增加燃油流量的同时,要获得尽可能小的耗油率,并保持推力恒定。通过多次数值仿真结果对比分析,将最小油耗模式下的 DMOM 参数设置如下:以 $W_{fm}, A_8, \Delta d_f, \Delta d_c$ 作为 4 个决策变量;种群个体数 $n=9$;决策变量最大与最小值设置为 $x_{wfm, max} = W_{fm0}, x_{wfm, min} = 0.96 \times W_{fm0}, x_{a8, max} = 1.15 \times A_{80}, x_{a8, min} = 0.9 \times A_{80}, x_{df, max} = 0, x_{df, min} = -3, x_{dc, max} = 3, x_{dc, min} = 0$,其中 W_{fm0} 和 A_{80} 分别为优化前发动机燃油流量及尾喷管面积;个体适应度为耗油率;优化终止条件为种群最优个体适应度连续两代相同或优化代数大于 15 代。

2.2 工作点仿真

最小油耗控制多应用于发动机的巡航工作状态。如果某飞行器在高度 $H=12\text{ km}$,马赫数 $Ma=0.8$,油门杆角度 $A_{pl}=40^\circ$ 工作点进行巡航,则在

此点开展基于 DMOM 的最小油耗模式的仿真验证,优化结果如图 5~图 7 所示,图中 F 表示推力, t 表示时间, Δt 表示时间变化量。为了便于比较,图中同时给出了应用 FSQP 算法的仿真曲线,其数据来源于文献[7]的仿真平台,本文性能寻优控制仿真所采用的发动机模型、参数及工作点均与文献[7]相同。

由图 5 可以看出,基于 FSQP 的寻优时间为 4.801 s,发动机控制稳定后耗油率降低 0.78%;






图 5 高度为 12 km, 马赫数为 0.8 处耗油率和推力变化
Fig. 5 Variation of S_{fc} and F at $H=12\text{ km}$, $Ma=0.8$






图 6 高度为 12 km,马赫数为 0.8 处 FSQP 与 DMOM 优化变量对比

Fig. 6 Comparison of optimal variables of FSQP and DMOM at $H=12\text{ km}$, $Ma=0.8$

DMOM 的寻优时间为 4.995 s,发动机控制稳定后耗油率降低 0.94%,虽然优化耗时有所增加,但优化效果有明显改善,耗油率由降低 0.78% 提升至降低 0.94%,降低油耗的效果提高了 20.5%。由图 6 可见,FSQP 算法和 DMOM 优化结束时,其决策变量变化明显不同,可知 FSQP 算法没能寻优到最优工作点,且其优化后推力下降,这也违背了最小油耗控制在降低油耗时不改变发动机推力的原则。

同时在表 1 中给出 DMOM 与 SOMA,GA,

PSO 三种常用群体智能算法的优化结果对比。由于群体进化算法具有一定的不确定性,因此分别对 SOMA,GA,PSO 和 DMOM 在该工作点优化计算 10 次,表 1 中给出了优化收敛时调用机载模型计算次数、优化时间及优化结果的平均值。




图 7 高度为 10 km,马赫数为 0.85 处耗油率和推力变化

Fig. 7 Variation of S_{fc} and F at $H=10\text{ km}$, $Ma=0.85$

表 1 高度为 12 km,马赫数为 0.8 处各算法优化性能对比

Table 1 Comparison of performance in different algorithms at $H=12\text{ km}$, $Ma=0.8$			
Algorithm	Individuals	Time/s	Decrease percentage of $S_{fc}/\%$
GA	30	12.61	0.83
PSO	30	12.87	0.87
SOMA	30	13.17	0.91
DMOM	10	4.99	0.94

由表 1 可见,基于 GA,PSO,SOMA 的寻优控制通过增加寻优个体数可以提高寻优效果,但耗费的时间也急剧增加;DMOM 无论在实时性上还是在优化效果上都具有明显的优势。

在 $H=10\text{ km}$, $Ma=0.85$, $A_{pl}=40^\circ$ 工作点上同样进行最小油耗模式的数值仿真, DMOM 与 FSQP 算法的仿真结果对比如图 8 所示, 与 SOMA, GA, PSO 优化计算 10 次平均值的对比结果如表 2 所示.

由图 8 可以看出, 在这个工作点上 DMOM 的寻优时间为 4.102 s, 优于基于 FSQP 算法的寻优时间 4.553 s, 发动机控制稳定后耗油率降低 1.15%, 并且保持了推力的恒定, 实际燃油消耗降低, 具有明显的优势. 由表 2 同样可以看出, 与基于 GA, PSO, SOMA 的寻优控制算法相比, DMOM 在实时性和优化效果上具有明显的优势. 在其他工作点的优化验证也得到了相同的结论, 这里不再一一给出.





图 8 高度为 10 km, 马赫数为 0.85 处 FSQP 与 DMOM 优化变量对比

Fig. 8 Comparison of optimal variables of FSQP and DMOM at $H=10\text{ km}$, $Ma=0.85$

表 2 高度为 10 km, 马赫数为 0.85 处各算法优化性能对比			
Table 2 Comparison of performance in different algorithms at $H=10\text{ km}$, $Ma=0.85$			
Algorithm	Individuals	Time/s	Decrease percentage of $S_{fc}/\%$
GA	30	12.69	0.81
PSO	30	12.91	0.89
SOMA	30	14.75	0.96
DMOM	10	4.10	1.15

除了最小油耗模式外, 航空发动机性能寻优控制还包括最大推力 (F) 模式和最低涡轮温度 (T_{46}) 模式, 其中最大推力模式是使发动机获得安全工作范围内的最大推力的控制模式, 而最低涡轮温度控制是在保持推力恒定的前提下获得最低涡轮后温度的控制模式. 为验证 DMOM 在最大推力模式和最低涡轮温度模式下的实用性, 下面分别在 $H=8\text{ km}$, $Ma=0.5$, $A_{pl}=70^\circ$ 工作点进行最大推力模式的数值仿真, 在 $H=10\text{ km}$, $Ma=1.5$, $A_{pl}=110^\circ$ 工作点上进行最低涡轮温度模式的数值仿真. 仿真分别采用 DMOM, FSQP, SOMA, GA, PSO 五种算法作为寻优算法, 最终的寻优结果分别如表 3 和表 4 所示.

从表 3 和表 4 可以看出, 在最大推力模式和最低涡轮温度模式下, DMOM 的寻优效果由于其他几种群体智能寻优算法. 但在最大推力模式下, DMOM 的寻优效果低于 FSQP 算法, 而在最低涡轮温度模式下, DMOM 的寻优效果高于 FSQP 算法, 这是由于最低涡轮温度模式和最小

表 3 最大推力模式寻优对比

Table 3 Comparison of max F optimization results

Algorithm	Individuals	Time/s	Increase percentage of $F/\%$
FSQP		0.872	9.52
GA	20	5.548	8.32
PSO	20	4.907	8.49
SOMA	20	5.115	7.78
DMOM	10	2.343	9.14

表 4 最低涡轮温度寻优对比

Table 4 Comparison of min T_{46} optimization results

Algorithm	Individuals	Time/s	Decrease of T_{46}/K
FSQP		4.215	25.6
GA	20	8.627	24.9
PSO	20	7.955	25.8
SOMA	20	7.891	24.2
DMOM	10	3.933	26.2

油耗模式寻优时,需要遵循推力恒定原则,使得这两种模式下的寻优问题成为多峰值寻优问题,DMOM 在这种情况下能够有效发挥算法效果,而最大推力模式无需遵循推力恒定原则,使得推力寻优问题的多峰值现象不明显,此时 DMOM 的寻优效果低于 FSQP 算法.除以上两个工作点的仿真外,在包线范围内其他工作点的最大推力模式和最低涡轮温度模式仿真结果与这两处工作点仿真结果类似,这里就不再赘述.

3 结 论

相比于 SOMA,GA 和 PSO 等向最优个体聚集的群智能优化算法,本文提出的 DMOM 通过小区域迁移寻找区域最优点,再通过分散处理寻找最优区域,进而找出全局最优点,在多峰值优化问题上能够有效避免陷入局部最优解.将 DMOM 应用于发动机性能寻优控制仿真,结果表明:在具有典型多峰值问题的最小油耗和最低涡轮温度控制寻优中,相比于 FSQP 算法的非线性迭代优化算法和其他群智能优化算法,本文所提出的算法能够以相对较快的速度,寻求到比其他算法性能更优越的工作点,提高发动机的经济性,验证了 DMOM 在解决多峰值优化问题中的有效性.

参考文献:

[1] Smith R H,Chisholm J D,Stewart J F. Optimizing aircraft performance with adaptive, integrated flight/propulsion control[J]. Journal of Engineering for Gas Turbines and Power,1991,113(1):87-94.

[2] Nobbs S G,Jacobs S W,Donahue D J. Development of the full-envelop performance seeking control algorithm[R]. AIAA 92-3748,1992.

[3] Orme J,Connors T. Supersonic flight test results of a performance seeking control algorithm on a NASA F-15 aircraft[R]. AIAA 94-3210,1994.

[4] Takeshi T,Nanahisa S. A performance optimization control of variable cycle engines[R]. AIAA-2003-4984,2003.

[5] John S O,Glenn B G. Subsonic flight test evaluation of a propulsion system parameter estimation process for the F100 engine[R]. AIAA 92-3745,1992.

[6] John S O,Glenn B G. Preliminary supersonic flight test evaluation of performance seeking control[R]. AIAA 93-1821,1993.

[7] Glenn B G,John S O. Performance-seeking control;program overview and future directions[R]. AIAA 93-3765-CP,1993.

[8] Adibhatla S,Johnson K L. Evaluation of a nonlinear PSC algorithm on a variable cycle engine[R]. AIAA 93-2077,1993.

[9] Mueller F D,Nobbs S G,Stewart J F. Dual engine application of the performance seeking control algorithm[R]. AIAA 93-1822,1993.

[10] Zhu Z B. A simple feasible SQP algorithm for inequality constrained optimization[J]. Applied Mathematics and Computation,2006,182(2):987-998.

[11] 孙丰诚,孙健国. 基于序列二次规划算法的发动机性能寻优控制[J]. 航空动力学报,2005,20(5):862-867.

SUN Fengcheng,SUN Jianguo. Aero-engine performance seeking control based on sequential quadratic programming algorithm[J]. Journal of Aerospace Power,2005,20(5):862-867. (in Chinese)

[12] Lawrence C T,Tits A L. A computational efficient feasible sequential quadratic programming algorithm[J]. Siam Journal on Optimize,2001,11(4):1092-1118.

[13] 王健康. 航空发动机模型基优化控制技术研究[D]. 南京:南京航空航天大学,2013.

WANG Jiankang. Research on model-based optimal control for aero-engines[D]. Nanjing: Nanjing University of Aeronautics and Astronautics,2013. (in Chinese)

[14] Valceres V R S,Wael K,Peter J F. Performance optimization of gas turbine engine[J]. Engineering Applications of Artificial Intelligence,2005,18(5):575-583.

[15] Zelinka I,Jouni L. SOMA-self-organizing migrating algorithm[R]. Brno, Czech: 6th International Conference on Soft Computing,2000.

[16] Zelinka I. SOMA-self-organizing migrating algorithm[M]. Berlin:Springer-Verlag,2004.