

基于改进 NSGA-III 三阶协同优化模型的 航天测试流程优化方法

周 岩, 侯洪波, 宋 微, 隋建成, 赵大志

(吉林通用航空职业技术学院, 吉林 吉林 132000)

摘要: 针对航天测试流程自动化中多目标优化问题的高维性、强约束性与计算实时性矛盾, 研究提出基于改进 NSGA-III 的三阶协同优化模型; 通过结合 LHS、Kriging 模型等方法建立“参数初始化控制—评估模态切换—在线参数调节”的创新协同架构, 实现多目标优化全流程动态调控; 实验结果表明, 该模型的 SP 降幅达 70.6%, 最终 SP 值 (0.162) 为对比算法的 21.8%~27.4%; 其 HV 与 IGD 均值分别为 0.928 与 0.048, 较传统方法分别提升 5.0%~13.7%、降低 26.2%~50.0%。实际部署中, 模型平均耗时 47.90 h, 资源消耗率 78.20%, 功能覆盖率 94.90%, 约束满足率 97.80%, 较对比方法更优越; 经实验测试, 研究模型实现了复杂航天测试场景下的控制鲁棒性与工程适用性, 为高维强约束任务的实时决策提供新方法。

关键词: 航天测试; 三阶协同优化; 多目标优化

Optimization Method for Aerospace Testing Process Based on Improved NSGA-III Third-Order Collaborative Optimization Model

ZHOU Yan, HOU Hongbo, SONG Wei, SUI Jiancheng, ZHAO Dazhi

(Jilin General Aviation Vocational and Technical College, Jilin 132000, China)

Abstract: Aiming at the contradiction between high dimensionality, strong constraints and computational real-time performance of multi-objective optimization problems in aerospace testing process automation, this paper proposes a third-order collaborative optimization model based on improved non-dominated sorting genetic algorithm III (NSGA-III). By combining the Latin hypercube sampling (LHS) and the Kriging model, an innovative cooperative architecture of the parameter initialization control, evaluation mode switching, and online parameter adjustment is established to realize the dynamic regulation of the whole process of multi-objective optimization. Experimental results show that this model reduces the spacing indicator (SP) by 70.6%, with a final SP value of 0.162, which is 21.8%~27.4% that of the comparative algorithms. The mean values of its hyper volume (HV) and inverted generational distance (IGD) are 0.928 and 0.048, which are 5.0%~13.7% higher and 26.2%~50.0% lower than those of the traditional methods, respectively. In actual deployment, the average time consumed by the model is 47.90 h, with a resource consumption rate of 78.20%, a function coverage rate of 94.90%, and a constraint satisfaction rate of 97.80%, this method is significantly superior to the comparative methods. After experimental testing, the model has a control robustness and engineering applicability in complex aerospace testing scenarios, and provides a new method for the real-time decision-making of high-dimensional strong constraint tasks.

Keywords: aerospace testing; third-order collaborative optimization; multi-target optimization

0 引言

随着航天事业的蓬勃发展, 航天测试作为确保航天任务成功的关键环节, 其重要性日益凸显^[1-2]。然而, 面对日益复杂的航天系统和不断增长的测试需求, 传统

的手工测试流程设计方式已难以满足高效、精准的要求^[3-4]。针对传统航天器测试资源独占等问题, 文献[5]提出航天器测试数字化转型方法。其能够通过资源集约化管理和按需分配, 提升测试效率和协同能力。但该方法的局限性在于: 面对更加复杂的航天器系统时,

收稿日期:2025-04-14; 修回日期:2025-05-26。

基金项目:2024 年度吉林省职业教育科研项目(2024XH2017);2025 年吉林省中华职业教育社改革创新课题(2025GGZ011)。

作者简介:周 岩(1982-),女,大学本科,讲师。

引用格式:周 岩,侯洪波,宋 微,等.基于改进 NSGA-III 三阶协同优化模型的航天测试流程优化方法[J].计算机测量与控制,2025,33(9):109-117.

计算量极大,限制了该方法的应用范围。针对航天器测试多类型数据接入瓶颈问题,文献[6]提出多类数据接入的航天器综合测试数据处理方法。其能够在扩大数据接口和解码效率的同时,缩短测试时间。但该方法的局限性是:在处理复杂或特殊类型的数据的处理能力和适应性不足。针对载人航天器电气性能测试流程多的问题,文献[7]提出采用柔性框架测试体系的方法。其通过可拓展体系结构,能够实现测试流程的自动管理,提高测试效率。但该方法的局限性在于:可能导致实际调配效率降低或出现应用资源冲突等问题。针对国产化航天器设计测试的迫切需求,文献[8]提出一种基于图形处理器的大规模航天系统多领域建模方法。其通过构建基于时间和事件混合驱动的航天系统软件运行框架,并高效仿真流程管理。但该方法的局限性在于:面对特殊或高度复杂任务需求时,模型构建灵活性较低。针对参数依赖型软件在初始化时读取并解析配置参数的问题,文献[9]提出对参数验收测试的方法。其能够实现参数依赖型流程的有效测试,具有测试覆盖性强、测试重点突出、测试效率高的特点。但该方法的局限性是:难以覆盖参数之间的复杂关联性和相互影响,测试结果不够准确。针对航空航天中的深度神经网络测试中测试数据标注成本高的问题,文献[10]提出基于模型输出差异的测试输入优先级方法。其能够更有效地筛选出高价值的测试输入,提高测试效率和准确性。但该方法的局限性在于:面对大规模、高维度的测试数据处理时,计算效率低、资源消耗大。

综上所述,现有研究在资源集约管理、数据接口扩展、测试流程自动化及参数依赖测试方面取得阶段性进展。然而在面对高维性、强约束性与计算实时性矛盾时,现有研究存在初始化效率低、评估开销大及参数固化引发早熟收敛等局限。此外,航天测试多目标优化的核心问题在于:高维参数与实时性冲突引发维度灾难;强资源约束导致仅 1/4 方案存在资源冲突;动态场景与静态模型不适配,现有算法无法在线调参^[11-12]。非支配排序遗传算法 III (NSGA-III, non-dominated sorting genetic algorithm III) 是一种用于高效处理多目标优化问题的遗传算法,其解分布均匀,收敛性好,适应性强^[13]。然而,当前 NSGA-III 存在局限性:随机初始化致种群覆盖率较低,易引发收敛偏差;全评估致单次迭代时间较长,无法满足实时需求^[14]。因此,研究以 NSGA-III 为基础框架,并结合 Kriging 代理模型及拉丁超立方采样 (LHS, latin hypercube sampling) 等方法,提出基于改进 NSGA-III 的航天测试流程自动生成模型。研究旨在为航天测试流程自动化生成的可靠性提供保障,为航天产业的安全和稳定发展做出贡献。研究的创新性在于提出“领域知识引导的 LHS 初始化-Kriging 代理评估”双引擎协同机

制。其利用非对称 LHS 初始化参数群,通过密集采样关键参数提升 NSGA-III 初始参数群的覆盖范围。并利用 Kriging 代理双模态评估减少 70% 计算耗时。最后利用混合参数动态调节降低资源冲突。通过以上方法的创新,研究方法能够针对性突破现有研究瓶颈、应对航天测试多目标优化的核心挑战。

1 NSGA-III 算法

在航天工程领域,随着技术的不断进步和任务的日益复杂化,航天测试流程的设计与实施面临着更高的要求。现代航天任务的复杂性不断增加,涉及多个子系统和大量参数^[15-16]。为了确保航天任务的成功,必须提高测试流程的效率和可靠性,同时降低开发成本和时间。这促使研究人员探索新的方法和技术,以满足航天测试流程设计与实施的高标准要求。然而传统的航天测试流程往往依赖于人工设计和经验判断,这不仅耗时耗力,而且容易受到人为因素的影响,导致测试效率低下和结果的不确定性^[17-18]。NSGA-III 是一种高效的多目标优化算法,其能够同时优化多个目标,生成一组帕累托最优解,为决策者提供多样化的选择。NSGA-III 在处理复杂约束和高维问题时表现出色,能够有效找到可行解。NSGA-III 的运行流程如图 1 所示。




图 1 NSGA-III 运行流程图

由图 1 可知,NSGA-III 从初始化种群操作开始,然后进行非支配排序,将个体与参考点关联,接着选择与交叉、变异操作生成新个体,更新种群,判断是否满足最大迭代次数,若不满足则重复上述过程,直至得到最终结果。其具体操作如下:研究首先将测试流程参数(如时序、资源分配)编码为决策变量,目标函数包括最小化时间 (f_1)、资源消耗 (f_2) 和最大化覆盖率 (f_3),如式 (1) 所示:

$$\begin{cases} f_1 = \sum t_i \\ f_2 = \sum c_j \\ f_3 = \frac{V_{\text{covered}}}{V_{\text{total}}} \end{cases} \quad (1)$$

式中, t_i 表示第 i 个测试步骤的耗时; c_j 表示第 j 类资源 (如电力、燃料) 的单个消耗量; $V_{covered}$ 表示测试覆盖的航天器功能; V_{total} 表示部件总数量。之后算法根据航天测试任务的特点和约束条件, 随机生成初始种群, 种群中的每个个体代表一个潜在的航天测试流程方案。紧接着对初始种群中的每个个体进行非支配排序^[19]。然后, 在非支配排序划分的同一非支配层内计算个体的拥挤距离。对于每个目标 i , 第 k 个个体在该目标上的拥挤距离 D_k 的计算如式 (2) 所示:

$$D_k = \sum_{i=1}^m \left(\frac{f_i^{k+1} - f_i^{k-1}}{f_i^{max} - f_i^{min}} \right) \tag{2}$$

式中, f_i^{k-1} 和 f_i^{k+1} 分别表示个体 $k-1$ 、 $k+1$ 的目标值; f_i^{max} 和 f_i^{min} 分别表示目标 i 上所有个体目标值的最大值和最小值; m 为总目标数。然后, NSGA-III 引入参考点来引导种群的搜索方向。参考点分布在目标空间中, 用于评估个体在不同目标方向上的性能。参考点生成如式 (3) 所示:

$$\begin{cases} z_k = \left(\frac{k_1}{H}, \frac{k_2}{H}, \dots, \frac{k_n}{H} \right) \\ k_1 + k_2 + \dots + k_n = H \end{cases} \tag{3}$$

式 (3) 中, H 为分解参数, 用于控制参考点密度; k 为非负整数, 用于构成参考点坐标 z_k , 引导种群在目标空间均匀分布。根据非支配排序和拥挤距离, 算法选择普通的个体进行交叉和变异操作^[20-21]。之后, 算法将父代种群和子代种群合并, 然后根据非支配排序和参考点引导, 选择新一代种群。新一代种群将包含更多优质个体, 以更好地逼近帕累托前沿^[22]。重复上述步骤, 直到满足预设的终止条件, 如达到最大迭代次数或种群收敛到稳定状态。其间, NSGA-III 通过自惩罚函数处理资源、时序等约束, 并将不可行解推向可行域。自惩罚函数如式 (4) 所示:

$$f_{penalty} = f + \beta * \sum g_i^2 \tag{4}$$

式 (4) 中, g_i 为第 i 个约束的违反量, 即实际值与上限值的差值; β 为惩罚系数, 用于调节约束违反对适应度的影响权重; f 为不同目标值, 即最小化时间、资源消耗和最大化覆盖率等; $f_{penalty}$ 为自惩罚函数修正后的目标值。最终, 算法将生成一组帕累托最优解, 为航天测试流程的设计提供多样化的优化方案。

然而传统 NSGA-III 存在两大局限: 1) 随机初始化易导致种群在复杂约束空间分布不均, 引发维度灾难与搜索盲区; 2) 目标函数依赖高成本真实评估, 难以应对航天测试等计算密集型场景^[23-24]。针对上述问题, LHS 通过领域知识驱动的非对称区间划分, 优先对关键参数实施密集采样, 确保初始种群均匀覆盖高潜力区域; Kriging 代理模型则构建目标响应曲面, 对非支配排序的前 30% 个体进行物理仿真, 其余个体通过 Krig-

ing 预测目标值, 减少 70% 计算开销。因此研究利用 LHS 提升初始种群质量, 降低后续优化迭代次数, 并通过 Kriging 通过并行评估, 实现资源分配与时序冲突的快速修正, 最终在解集质量与工程效率间建立高效映射。

2 改进 NSGA-III 三阶协同优化模型构建

2.1 航天测试流程三阶协同优化机制设计

在航天器测试领域, 复杂系统的多目标协同优化始终是核心挑战。以卫星推进系统测试为例, 其需同时优化燃料供给时序、电力负载分配与故障检测覆盖率三个目标, 传统方法常因参数耦合性强、约束条件复杂导致解集分布不均。所以, 此节提出的三阶协同优化架构, 通过融合 LHS 先验采样、Kriging 代理评估与动态参数调节机制, 构建了从初始化到迭代优化的全流程闭环。其总体设计如图 2 所示。




图 2 三阶协同优化设计图

由图 2 可知, 该架构包含初始化控制层、代理评估层、参数优化层。其中, 初始化控制层通过非对称 LHS 采样生成领域知识引导的初始种群, 突破随机初始化在高维空间的覆盖缺陷。而代理评估层基于 Kriging 模型构建“高保真验证—代理预测”双模态评估机制, 建立计算资源动态分配通道。参数优化层则采用网格搜索预选与在线反馈调节的混合策略, 实现 6 维核心参数的闭环寻优。三层架构通过种群质量指标、模型预测方差、参数调节因子三类信号构建跨层反馈链路, 形成“初始化质量提升—评估效率优化—参数自适应调节”的协同增强机制。

2.2 三阶协同优化模型实现方法

2.2.1 航天测试参数非对称 LHS 初始化

航天测试参数的敏感性与约束多样性对初始化策略提出严苛要求。例如, 在深空探测器热控系统测试中, 隔热材料厚度 (0.5~5.0 mm) 与加热功率 (10

~200 W) 的参数组合存在强非线性关系, 传统随机采样易遗漏关键参数区间。此节引入的非对称 LHS 方法, 针对热控关键参数实施 5 倍密集区间划分 (如厚度在 1.2~2.8 mm 区间划分 10 层), 次要参数宽泛覆盖, 既继承前文三阶架构的领域适配理念, 又通过结构化采样策略构建高质量初始种群。

因此研究利用 LHS 对 NSGA-III 的种群初始化操作进行元启发式优化, LHS 的设计原理如图 3 所示。




图 3 LHS 采样设计图

由图 3 可知, LHS 采样将变量的取值范围分为互不重叠的区间, 每个区间内按照概率分布随机抽取一个样本, 确保样本覆盖整个变量范围, 且每个区间内的样本数量与该区间的概率密度成比例。因此, LHS 通过分层随机化策略, 在多维设计空间中生成均匀分布的初始种群^[25]。LHS 的运行流程如下: 首先定义设计空间, 设优化问题包含 d 个决策变量。每个变量 x_i 的取值范围为 $[a_i, b_i] (i = 1, 2, \dots, d)$, 设定采样点数 N (即种群规模)。将每个变量 x_i 的取值范围等分为 N 个不重叠的子区间, 如式 (5) 所示:

$$\Delta_i = \frac{b_i - a_i}{N} \quad (5)$$

式 (5) 中, Δ_i 为每个区间长度。那么, 第 j 个子区间范围为 $[a_i + (j-1)\Delta_i, a_i + j\Delta_i] (j = 1, 2, \dots, N)$ 。之后对每个变量 x_i 独立生成一个长度为 N 的随机排列向量 π_i , 例如当 $N = 4$ 时, $\pi_i = [3, 1, 4, 2]$ 。该排列确保每个子区间在所有维度上仅被选中一次, 避免重叠。对每个变量 x_i , 在其第 $\pi_i(k)$ 个子区间内 ($k = 1, 2, \dots, N$) 随机抽取一个值 $[x_i^{(k)}]$, 如式 (6) 所示:

$$x_i^{(k)} = a_i + [\pi_i(k) - 1 + u_i^{(k)}] \Delta_i \quad (6)$$

式 (6) 中, $u_i^{(k)} \in [0, 1)$ 为均匀分布的随机数。将所有变量的采样值组合为 N 个样本点, 构成初始种群, 如式 (7) 可知:

$$\mathbf{X} = [x_1^{(1)}, x_2^{(1)}, \dots, x_d^{(1)}]^T, \dots, [x_1^{(N)}, x_2^{(N)}, \dots, x_d^{(N)}]^T \quad (7)$$

式 (7) 中, $\mathbf{X}$ 即为 LHS 优化后的初始种群; $x_d^{(N)}$ 即为

变量 x_d 在其第 $\pi_i(N)$ 个子区间内随机抽取一个值。此外若在生成样本时, 剔除明显违反约束 (如资源超限) 的点, 能够提升初始种群可行性。若某些变量对目标函数影响显著 (如航天测试中的关键资源参数), 则区间长度如式 (8) 所示:

$$\Delta_i = \frac{b_i - a_i}{N^\alpha} \quad (8)$$

式 (8) 中, α 为子区间密度, 当 $\alpha > 1$ 时, 区间更密集。LHS 结合 NSGA-III 后, 每个变量子区间仅采样一次, 避免传统随机采样在高维空间的“空洞”现象^[26]。其复杂度为 $O(Nd)$, 适合大规模种群初始化。并且 LHS 通过调整子区间划分策略, 灵活适配问题特性 (如航天测试中的关键参数敏感区域)。

2.2.2 多目标代理评估的响应面控制

在完成非对称 LHS 初始化对关键参数的高效控制后, 如何动态平衡计算开销与解集精度成为多目标优化的核心挑战。传统全量高保真评估模式受限于航天测试场景的强时序约束与资源敏感特性, 难以在有限计算资源下实现全局解集的精准调控。为此, 此节提出基于 Kriging 代理模型的响应面控制机制, 通过构建动态高斯过程响应曲面, 将评估过程分解为“代理预测—高保真验证”双模态控制闭环: 对非支配排序前 30% 的个体实施高保真物理仿真, 确保关键解集的绝对精度; 其余 70% 个体通过 Kriging 预测值进行代理评估。帕累托优化理论表明非支配解主导搜索方向, 该比例平衡计算资源分配与关键区域精度保障^[27]。并结合模型不确定性 (预测方差) 动态修正交叉变异方向, 其流程如图 4 所示。




图 4 双模态控制设计图

由图 4 可知, 首先进行数据标准化处理, 之后按非支配排名双模态评估。在其余个体中构建半变异函数, 并拟合指数模型参数。之后计算协方差矩阵, 求解 Kriging 估计, 生成预测值及方差。

Kriging 代理模型的运行流程具体如下: 首先收集空间样本点 (即种群个体) 集 $S = \{s_1, s_2, \dots, s_n\}$ 及其观测值 (即种群目标值) $Z = \{Z(s_1), Z(s_2), \dots, Z(s_n)\}$ 。

对数据进行 Z-score 标准化处理,确保满足平稳性假设。之后计算所有点对的距离 h ,按距离间隔分组,定义经验半变异函数 $\hat{\gamma}(h)$,如式(9)所示:

$$\hat{\gamma}(h) = \frac{1}{2|N(h)|} \sum_{(i,j) \in N(h)} [Z(s_i) - Z(s_j)]^2 \quad (9)$$

式(9)中, $N(h)$ 为距离间隔 h 内的点对集合; $|N(h)|$ 为点对数。然后选择指数模型为理论模型,拟合经验半变异函数 $\gamma(h)$,如式(10)所示:

$$\gamma(h) = c_0 + c(1 - e^{-3h/a}) \quad (10)$$

式(10)中, e 为自然对数的底数; c_0 、 c 和 a 分别为块金值、基台值和变程,三者通过最小二乘法估计获得^[28]。基于理论模型计算样本点间的协方差矩阵 C ,其中元素如式(11)所示:

$$C_{ij} = C(0) - \gamma(\|s_i - s_j\|) \quad (11)$$

式(11)中, $C(0)$ 为基台值,且 $C(0) = c_0 + c$ 。假设预测点为 s_0 ,则 Kriging 估计表示如式(12)所示:

$$\begin{bmatrix} C & 1 \\ 1^T & 0 \end{bmatrix} = \begin{bmatrix} \lambda \\ \mu \end{bmatrix} \begin{bmatrix} c_0 \\ 1 \end{bmatrix} \quad (12)$$

式(12)中, λ 为权重向量; μ 为拉格朗日乘数; 1 为全1向量; 1^T 表示1的转置。紧接着通过线性代数方法求解方程组,得到 λ 和 μ 。此时,预测值及方差 σ^2 如式(13)所示:

$$\begin{cases} \hat{Z}(s_0) = \lambda^T Z \\ \sigma^2(s_0) = C(0) - \lambda^T c_0 + \mu \end{cases} \quad (13)$$

式(13)中, $\hat{Z}(s_0)$ 为数据点的预测值,即种群个体的预测目标值; λ^T 为 λ 的转置。该流程通过半变异函数建模空间相关性,利用协方差结构求解最优权重,实现无偏最小方差预测^[29]。结合 Kriging 代理模型的 NSGA-III 能够更高效地收敛至优质解,并显著提升解的分布均匀性。相较于多项式回归,Kriging 代理模型通过半变异函数建模空间相关性及预测方差动态调节评估模式,兼顾计算效率与预测的准确性。通过 Kriging 代理模型的引入,NSGA-III 在处理复杂多目标优化问题时表现出更好的性能,为航天测试流程的优化提供有力的支持。

2.2.3 航天测试参数混合优化策略

航天器综合测试的多目标动态优化需兼顾算法稳定性与适应性。以空间站舱段对接测试为例,其涉及机械臂轨迹规划(10维)、碰撞检测灵敏度(3维)等跨领域参数优化,固定参数策略易导致局部收敛。此节提出的网格搜索预选与在线调节机制,通过分解参数空间构建6维度寻优矩阵(种群规模/交叉概率/参考点密度等),既继承前文代理模型的效率增益,又通过参数协同优化增强算法鲁棒性。

NSGA-III 的性能依赖于种群大小、交叉概率及变异概率等关键参数选择。传统参数选择方法往往依赖于

人工经验或简单规则,难以系统地探索复杂的参数空间,导致参数选择的效率低下。并且其在处理高维参数空间时,容易陷入局部最优,难以找到全局最优解。而固定参数的敏感性分析不足,难以准确评估参数变化对优化结果的影响。因此研究利用网格搜索法系统优化 NSGA-III 的参数设置,以提升其在多目标优化问题上的求解效率和解的质量。参数混合优化策略的运行流程如图5所示。




图5 参数混合优化策略的运行流程

由图5可知,该参数混合优化策略通过离线网格搜索预选最优参数组合,并在线监测多目标优化性能指标来动态调节参数变化,实现周期性更新参数集保障算法适应性。研究首先确定需要优化的 NSGA-III 参数及其可能的取值范围,如表1所示。

表1 NSGA-III 的关键参数及典型候选值

参数	符号	候选范围	作用
种群规模	N	{50,100,200}	决定搜索广度,过小易陷入局部最优,过大增加计算成本。
交叉概率	p_c	{0.6,0.8,0.9}	控制父代个体生成子代的概率,影响全局搜索能力。
变异概率	p_m	{0.01,0.05,0.1}	引入多样性,避免早熟收敛。
参考点分解参数	H	{5,10,15}	控制参考点数量,公式: $C(H + m - 1, m - 1)$, m 为目标数。
最大迭代次数	$G_{\max}$	{100,200}	影响收敛性和计算时间。
交叉分布指数	η	{10,20,30}	控制交叉操作生成子代的扩散程度(值越大子代越靠近父代)。

由表1可知,研究选择种群规模、交叉概率、变异概率、参考点分解参数、最大迭代次数及交叉分布指数等参数^[30]。候选值基于问题复杂度与目标维度,通过领域知识设定典型范围,平衡收敛性与多样性。之后研究选择超体积(HV, hyper volume)和逆世代距离

(IGD, inverted generational distance) 等多目标优化的性能指标,来量化解集质量。 HV 和 IGD 的计算如式 (14) 所示:

$$\begin{cases} HV = \text{Volume}[\bigcup_{f \in P} (f_{\text{ref}}, f)] \\ IGD = \frac{1}{|P^*|} \sum_{f^* \in P^*} \min_{f \in P} \|f - f^*\| \end{cases} \quad (14)$$

式 (14) 中, P 为非支配解集; f 为所有个体; f_{ref} 为参考点; P^* 为真实 Pareto 前沿。 HV 值越大表示解集收敛性与分布性越好,即解集分布越广,覆盖的目标空间越大。 IGD 越小表示解集越接近真实帕累托前沿且分布均匀。紧接着构建参数候选值的笛卡尔积,生成所有可能的参数组合^[31]。例如,若优化 $N \in \{100, 200\}$ 、 $p_c \in \{0.8, 0.9\}$ 、 $p_m \in \{0.01, 0.05\}$, 则生成 $2 \times 2 \times 2 = 8$ 种组合。为减少随机性影响,研究对每个参数组合进行多次独立运行并取平均结果。网格搜索法通过系统遍历参数空间,为 NSGA-III 提供了可靠的参数优化方案,尤其适合可解释性要求高的场景。混合参数优化策略较固定参数和随机选择,采用网格搜索预筛选与在线 HV/IGD 反馈调节机制,提升算法收敛速度并增强高维参数适应性^[32]。

2.3 三阶协同优化的整体实现流程

改进的 NSGA-III 三阶协同优化模型运行流程如下:首先,模型基于非对称 LHS 对关键测试参数实施区间密度控制,在参数敏感区间进行超密度分层采样,生成符合领域约束的均匀初始种群。之后,模型对种群个体执行非支配排序,依据目标函数值将个体划分为多个非支配层级,并采用参考点关联策略将个体映射至目标空间中的标准化参考向量方向,通过式 (3) 生成的参考点集引导种群分布均匀性。紧接着,引入 Kriging 代理模型构建动态响应面,将评估过程分解为双模态控制:对第一非支配层个体 (前 30%) 启动高保真物理仿真验证,其余个体通过式 (13) 的代理模型预测目标值。随后,基于非支配排序结果与参考点关联度执行环境选择,保留靠近参考点且分布均匀的优质个体进入下一代。

在进化迭代过程中,混合参数控制策略分阶段生效:离线预选阶段通过网格搜索在六维参数空间 (种群规模、交叉概率等) 确定最优参数配置;在线调节阶段依据实时种群多样性指标 (HV 和 IGD) 动态调整变异概率,当多样性低于阈值时提升变异强度以突破局部最优。最后,将子代种群与父代合并后执行精英保留策略,循环执行非支配排序、参考点关联、代理评估与参数调节流程,直至达到预设的最大迭代次数或收敛条件。全流程通过“初始化采样—代理评估分流—参数动态优化”的三阶协同机制,实现计算效率、解集质量与工程可行性的多目标平衡。

3 实验验证

3.1 实验设计

为验证研究提出模型的可靠性,研究以某小型航天器测试车间为实验场地。并且以某航天器测试车间 2020~2022 年 37 组历史测试案例为数据来源,涵盖燃料供给速率 (20~500 L/min)、电力负载阈值 (0.5~5.0 kW) 等核心参数。数据通过 Keysight 34972A 数据采集器和 NI PXIe-8840 控制器实时记录,包含时序依赖、设备互斥等 6 类约束规则。原始数据经孤立森林算法检测剔除 15% 异常值,对连续变量采用 Z-score 标准化,离散变量进行 One-Hot 编码,并通过线性插值法填补缺失值,最终构建包含 1 200 条测试序列的数据集,每条序列标注资源分配比例、功能覆盖状态及约束违反标记。研究按 8:2 比例随机划分训练集/测试集,针对高维参数空间特性,采用分层抽样确保不同测试场景 (正常/极端负载) 和约束条件 (时序/资源) 的数据分布一致性,避免局部偏差。此外,研究引入基于分解的多目标进化算法 (MOEA/D, multi-objective evolutionary algorithm based on decomposition)、强度帕累托进化算法 2 (SPEA2, strength pareto evolutionary algorithm 2) 和传统 NSGA-III 作为对比方法,将研究提出的模型作为研究对象。NSGA-III 与研究对象均设置统一参数以确保公平性:初始种群规模为 120、最大迭代次数为 200、交叉概率为 0.85、变异概率为 0.05。MOEA/D 采用切比雪夫分解法,权重向量为 8,邻域大小为 20。SPEA2 设置档案容量为 100,适应度分配采用 k 近邻密度估计 (k 设置为 5)。改进 NSGA-III 额外配置 LHS 初始化对关键参数划分 5 倍密集区间,Kriging 代理模型每代筛选 30% 个体进行高保真评估。

3.2 天测试解集分布特性验证

3.2.1 间距指标的工程意义

研究首先对比不同方法在迭代期间的间距指标 (SP, spacing indicator) 变化。在多目标优化问题中,SP 是一种用于评估解集分布均匀性的指标。它通过衡量解集在目标空间中的分布情况,展示算法在探索解空间时的性能。SP 值越小,表示解集的分布越均匀,反之则表示分布越不均匀。研究以此衡量不同方法生成解集的分布均匀性,实验结果如图 6 所示。

由图 6 (a) 和图 6 (b) 结合可知,研究对象的 SP 值从 0.892 降至 0.162,整体降幅达到 70.6%;NSGA-III 从 1.124 降至 0.741,整体降幅为 34.1%;MOEA/D 从 1.057 降至 0.592,整体降幅为 44.0%;而 SPEA2 则从 1.203 降至 0.731,整体降幅为 39.3%。在较低迭代次数 (如 10 次) 时,SPEA2 表现最优,其 SP 值为




图 6 SP 值与迭代变化

1.203; 然而, 在较高迭代次数 (如 200 次) 时, 研究对象表现出显著优势, SP 值仅为 0.162, 且降幅最大。这一结果表明, 虽然 SPEA2 在初期具有较好的收敛速度, 但研究对象在长期运行中展现出更强的优化潜力和稳定性。此外, NSGA-III 和 MOEA/D 的表现相对平稳, 但与研究对象相比仍存在一定差距, 尤其是降幅方面不及研究对象显著。实验结果表明, 但从整体降幅和最终优化效果来看, 研究对象的優勢更加明显, 适合需要长时间优化的问题场景。

3.2.2 航天测试 HV 与 IGD 解集质量对比

之后研究对比不同方法输出的 20 个测试流程的 HV 值和 IGD 值差异, 来评估各算法在多目标优化问题中的性能表现。研究选择 HV 和 IGD 作为评估指标的原因在于其能够从不同角度全面评估解集的质量和分布特性。HV 值衡量解集在目标空间中所占据的体积, 反映了解集的分布范围和覆盖度。较大的 HV 值意味着解集能够覆盖更广泛的目标空间区域, 表明算法在寻找多样化的解方面表现良好。而 IGD 值则衡量生成解集与真实帕累托前沿之间的平均距离, 反映了解集的收敛性和准确性。较小的 IGD 值意味着生成解集更接近真实帕累托前沿, 表明算法能够找到高质量的解。这两个指标的结合使用, 可以全面评估多目标优化算法的性能, 既关注解集的多样性, 又关注解集的收敛性。该实验结果如图 7 所示。

由图 7 (a) 和由图 7 (b) 结合可知, 可知, 从 HV 值来看, 研究对象在大部分流程中取得了较高解集覆盖范围, 其平均 HV 值为 0.928, 明显优于 MOEA/




图 7 HV 与 IGD 值差异

D (平均 HV 值为 0.884)、SPEA2 (平均 HV 值为 0.816) 以及 NSGA-III (平均 HV 值为 0.884)。在 IGD 值方面, 研究对象的平均值为 0.048, 表明其解集更接近真实 Pareto 前沿且分布更加均匀, 而 MOEA/D、SPEA2 和传统 NSGA-III 的 IGD 值分别为 0.065、0.096 和 0.065, 说明这些方法在解的逼近性和多样性上存在一定不足。在前 10 个流程中, 各算法表现差异较小, 但随着流程数量增加, 研究对象的優勢逐渐显现, 特别是在第 15~20 个流程中, 其 HV 值稳定保持在 0.900 以上, 而其他方法则出现不同程度的波动。实验结果表明, 研究对象不仅在解的质量和分布上具有明显优势, 还能够有效应对复杂约束条件下的优化需求, 为航天测试流程自动化提供了可靠的解决方案。

3.3 实际部署效能验证

3.3.1 测试耗时与资源利用率优化

研究对 3.2.2 中不同方法输出流程的总耗时、资源消耗进行对比, 探究其输出流程的实际可行性。实验中的数据采集主要通过小型航天器测试车间安装的传感器和监测设备进行, 这些设备能够实时记录测试过程中的各项参数, 包括资源消耗情况和测试任务的执行时间。数据处理方面, 首先对采集到的原始数据进行清洗和预处理, 去除异常值和噪声数据, 以保证数据的准确性和可靠性。然后, 对数据进行归一化处理, 使得不同维度的数据能够在同一尺度上进行比较, 实验结果如图 8 所示。

由图 8 (a) 可知, 研究对象在测试流程总耗时方面表现出显著优势, 其平均耗时为 47.90 h, 较 MOEA/D (53.00 h) 和 SPEA2 (56.10 h) 分别减少 9.62% 和 14.62%。NSGA-III 的平均耗时为 50.40 h, 与研究对象相比仅高出 5.22%。图 8 (b) 可知, 从资源消耗来看, 研究对象的平均资源使用率为 78.20%, 比 MOEA/D (82.60%)、SPEA2 (85.90%) 和 NSGA-III (81.20%) 分别低 4.40%、7.70% 和 3.00%。这表明改进模型在资源分配效率上更具竞争力, 能够有




图 8 测试耗时与资源利用率差异

效降低资源浪费。

3.3.2 功能覆盖率与约束满足率提升

最后, 研究对 3.2.2 中不同方法输出流程的功能覆盖率与约束满足率进行对比, 探究其输出流程的实际可行性。功能覆盖率的数据则通过分析测试结果和系统日志来获取, 以确保每个测试流程都能覆盖到航天器的各个功能模块。约束满足率通过实时监测系统校验 12 类约束规则, 以合规步骤占比量化评估, 实验结果如图 9 所示。




图 9 功能覆盖率与约束满足率差异

由图 9 (a) 可知, 研究对象的表现最优, 平均覆盖率达到 94.90%, 比 MOEA/D (91.30%)、SPEA2 (89.70%) 和 NSGA-III (93.10%) 分别高出 3.60%、5.20% 和 1.80%。这说明研究对象能够更全面地满足任务需求, 提供更高的任务完成度。由图 9 (b) 可知, 研究对象在约束满足率方面表现最优, 达到了 97.80%。MOEA/D、SPEA2 和 NSGA-III 的约束满足率分别为 85.4%、77.6% 和 88.3%。这表明研究对象在确保生成的测试流程符合各项约束条件上具有明显优势, 能够有效减少超时或资源冲突等问题。

由上可知, 研究对象在时间、资源与功能覆盖率上全面优于其他方法, 尤其在资源节约和功能覆盖方面优势显著, 证明其在航天测试流程优化中的高效性和可靠性。

4 结束语

研究针对航天测试流程自动化中多目标优化问题的复杂性, 提出一种基于改进 NSGA-III 的智能生成模型, 通过融合先验知识引导、Kriging 代理模型加速与动态参数调节机制, 显著提升了算法的优化效率与工程适用性。迭代实验显示, 模型 SP 降幅达 70.6%, 最终 SP 值 (0.162) 仅为对比算法的 21.8%~27.4%, 证明其解集均匀性显著提升。HV 值与 IGD 值的对比进一步验证了模型的全局优化能力: 模型平均 HV 值 (0.928) 较 MOEA/D、SPEA2 分别提升 5.0% 与 13.7%, IGD 值 (0.048) 较二者降低 26.2% 与 50.0%。这一优势得益于双层代理评估体系的设计——Kriging 代理模型通过非支配排序动态筛选高潜解, 减少 70% 的物理仿真成本; 约束预测网络则实时调整罚函数权重, 确保解集严格满足时序与资源约束。在实际工程部署中, 该模型测试流程平均耗时 (47.90 h) 较 MOEA/D 与 SPEA2 缩短 9.6%~14.6%, 资源消耗率 (78.20%) 降低 4.4%~7.7%, 功能覆盖率 (94.90%) 提升 1.8%~5.2%, 约束满足率 (97.80%) 提升 12.40%~20.20%。综上所述, 研究模型的主要贡献在于: 1) 提出领域知识驱动的 LHS 初始化、Kriging 代理评估体系和动态参数调节机制创新技术; 2) 能够显著缩短测试流程的平均耗时, 降低资源消耗率, 提升功能覆盖率和约束满足率; 3) 提高了高维强约束任务的实时决策性能, 增强测试系统的工程适用性。未来研究将重点开发分布式多保真度 Kriging 代理评估框架以应对超大规模测试任务, 集成强化学习与数字孪生技术实现参数自主优化, 并扩展至卫星组网协同测试及深空探测器自主决策场景, 同时探索跨领域应用与动态环境下的实时自适应机制。

参考文献:

- [1] 赵国锋, 卢奕杉, 徐川, 等. 面向航天器有线无线混合场景的流调度机制研究 [J]. 电子与信息学报, 2023, 45 (2): 464-471.
- [2] VYASA V, XU Z. Maintenance in automotive and aerospace applications-An overview [J]. International Journal of Advances in Science Transactions, 2024, 3 (2): 349-361.
- [3] 陈宸, 翟天祺, 张金刚, 等. 航天测控系统数据处理软件系统设计与实现 [J]. 计算机测量与控制, 2024, 32 (2): 299-308.
- [4] AHMED Q O. The future of aerospace research: How data collection systems can advance space exploration [J]. Volume, 2024, 9 (1): 360-370.
- [5] 赵欣, 李鹏, 梁岩里, 等. 航天器测试数字化转型探

- 索和实践 [J]. 航天器工程, 2023, 32 (1): 144-149.
- [6] 原晋谦, 尚叔楠, 李昆泽, 等. 支持多类数据接入的航天器综合测试数据处理方法 [J]. 宇航计测技术, 2024, 44 (4): 76-81.
- [7] 杨 枫, 任 亮. 多航天器电气性能测试的协同动态调配法研究 [J]. 计算机仿真, 2022, 39 (2): 29-33.
- [8] 魏 承, 乔 彬, 刘天喜, 等. 航天器系统仿真软件 SpaceSim 设计与应用 [J]. 宇航学报, 2024, 45 (11): 1724-1731.
- [9] 魏 波, 张卫祥, 齐玉华, 等. 参数依赖型软件参数更动测试策略和方法 [J]. 计算机测量与控制, 2022, 30 (10): 76-81.
- [10] 朱 进, 陶传奇, 郭虹静. 基于 DNN 模型输出差异的测试输入优先级方法 [J]. 计算机科学, 2024, 51 (z1): 818-825.
- [11] KUMAR N, SATAPATHY R K. Bearings in aerospace, application, distress, and life: a review [J]. Journal of Failure Analysis and Prevention, 2023, 23 (3): 915-947.
- [12] 马祥跃, 杜晓婷, 采 青, 等. 深度学习框架测试研究综述 [J]. 软件学报, 2024, 35 (8): 3752-3784.
- [13] FERGUSON S, VAN VELZEN E, OLECHOWSKI A. Team and communication impacts of remote work for complex aerospace system development [J]. Systems Engineering, 2024, 27 (1): 199-213.
- [14] AWAD M, ABOUHAWWASH M, AGIZA H N. On NSGA-II and NSGA-III in portfolio management [J]. Intelligent Automation & Soft Computing, 2022, 32 (3): 1893-1904.
- [15] KHETTABI I, BENYUCEF L, AMINE BOUTICHE M. Sustainable multi-objective process planning in reconfigurable manufacturing environment: adapted new dynamic NSGA-II vs New NSGA-III [J]. International Journal of Production Research, 2022, 60 (20): 6329-6349.
- [16] 虞炳文, 肖晓强, 范利波, 等. 航天测控站供电系统智能监测系统设计及验证 [J]. 计算机测量与控制, 2024, 32 (1): 1-7, 15.
- [17] 牛嘉祥, 胡玉茜, 吴志红, 等. 空间站舱段或目标航天器自主捕获及转位方案 [J]. 航天器工程, 2023, 32 (5): 49-55.
- [18] 杨同智, 党建成, 刘廷玉, 等. 航天器电源智能判读规则框架构建与应用 [J]. 航天器工程, 2023, 32 (1): 150-157.
- [19] CHAUDHARI P, THAKUR A K, KUMAR R, et al. Comparison of NSGA-III with NSGA-II for multi objective optimization of adiabatic styrene reactor [J]. Materials Today: Proceedings, 2022, 57 (1): 1509-1514.
- [20] SUN X, XU N, YAO M. Sequential subspace optimization design of a dual three-phase permanent magnet synchronous hub motor based on NSGA III [J]. IEEE Transactions on Transportation Electrification, 2022, 9 (1): 622-630.
- [21] 赵 芮, 郎 峻, 顾幸生. 基于多目标离散正弦优化算法的混合零空闲置换流水车间调度 [J]. 华东理工大学学报 (自然科学版), 2022, 48 (1): 76-86.
- [22] SETHI K C, PRAJAPATI U, PARIHAR A, et al. Development of optimization model for balancing time, cost, and environmental impact in retrofitting projects with NSGA-III [J]. Asian Journal of Civil Engineering, 2024, 25 (7): 5123-5136.
- [23] ADEKOYA O, ANEIBA A. An adapted nondominated sorting genetic algorithm iii (nsga-iii) with repair-based operator for solving controller placement problem in software-defined wide area networks [J]. IEEE Open Journal of the Communications Society, 2022, 3 (1): 888-901.
- [24] 王昊煜, 高培超, 谢一茹, 等. 基于遗传算法的土地利用优化: NSGA-II 和 NSGA-III 的对比研究 [J]. 生态学报, 2023, 43 (2): 639-649.
- [25] IORDANIS I, KOUKOUVINOS C, SILOU I. On the efficacy of conditioned and progressive Latin hypercube sampling in supervised machine learning [J]. Applied Numerical Mathematics, 2025, 208 (1): 256-270.
- [26] 李维友, 段良霞, 谢红霞, 等. 基于条件拉丁超立方抽样的县域耕地土壤有机质空间插值合理样本密度的确定 [J]. 土壤通报, 2022, 53 (3): 505-513.
- [27] 徐玉萍, 周金赛, 张津杭, 等. 基于帕累托最优效率模型的轨道交通沿线公交线路运行效率评价 [J]. 科学技术与工程, 2024, 24 (22): 9569-9576.
- [28] MENG D, YANG S, DE JESUS A M P, et al. A novel Kriging-model-assisted reliability-based multidisciplinary design optimization strategy and its application in the offshore wind turbine tower [J]. Renewable Energy, 2023, 203 (1): 407-420.
- [29] 姜 杰, 杨旭锋, 丁国富. 基于多峰优化 Kriging 模型与距离相关系数的高速列车动力学参数多输出灵敏度分析 [J]. 工程科学与技术, 2024, 56 (4): 250-260.
- [30] ALHIJAWI B, AWAJAN A. Genetic algorithms: Theory, genetic operators, solutions, and applications [J]. Evolutionary Intelligence, 2024, 17 (3): 1245-1256.
- [31] SHAMS M Y, ELSHEWEY A M, EL-KENAWY E S M, et al. Water quality prediction using machine learning models based on grid search method [J]. Multimedia Tools and Applications, 2024, 83 (12): 35307-35334.
- [32] AeIKKAR M. Fast grid search: A grid search-inspired algorithm for optimizing hyperparameters of support vector regression [J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2024, 32 (1): 68-92.