

引文格式: 智鹏鹏, 刘瀚儒, 官毅, 等. 基于主动学习Kriging的航空发动机机构可靠性分析方法[J]. 航空制造技术, 2025, 68(20): 14-26.

ZHI Pengpeng, LIU Hanru, GUAN Yi, et al. Active learning Kriging-based mechanism reliability analysis for aero-engine[J]. Aeronautical Manufacturing Technology, 2025, 68(20): 14-26.

基于主动学习Kriging的航空发动机机构可靠性分析方法*

智鹏鹏^{1,2}, 刘瀚儒^{1,3}, 官毅², 汪忠来^{1,2}, 张均富³

(1. 电子科技大学长三角研究院(湖州), 湖州 313000;

2. 电子科技大学, 成都 611731;

3. 西华大学, 成都 610039)

[摘要] 针对复杂航空机构可靠性分析过程中建模难度大、精度差、计算效率低等问题, 提出一种数据增强拉丁超立方抽样(Data augmentation Latin hypercube sampling, DALHS)、自适应分区拒绝权重采样(Adaptive partitioned threshold rejection sampling, APTRS)和主动学习Kriging相结合的机构可靠性分析方法。首先, 利用数据增强技术改进拉丁超立方抽样, 获取初始样本点, 提高初始样本点的多样性和代表性; 其次, 采用自适应分区策略划分设计空间, 并在子空间内执行拒绝权重采样, 提升样本局部和全局搜索能力; 再次, 提出主动学习NU(Normalize U)函数筛选高质量样本, 结合准随机分形算法(Quasi-random fractal algorithm, QRFA)动态优化Kriging模型, 构建DALHS-APTRS-Kriging模型; 最后, 利用变异系数收敛准则, 实现航空机构可靠度的高效计算。结果表明, 通航活塞发动机机构的可靠度为0.987, 模型调用次数仅为72, 相比传统方法, 计算误差仅为5.7%, 说明所提方法不仅能在少量样本下获得高质量的Kriging模型, 而且在兼具局部和全局搜索下提升了可靠度计算的效率和精度。

关键词: 机构可靠性; Kriging模型; 主动学习策略; 通航活塞发动机; 数据增强拉丁超立方抽样

中图分类号: V263.5

文献标志码: A

DOI: 10.16080/j.issn1671-833x.2025.20.014



智鹏鹏

副研究员, 博士, 主要研究方向为智能航空装备结构可靠性、不确定性分析与优化。

机构运动可靠性分析旨在量化机械系统在多体动力学、运动副间隙及外部随机载荷等不确定性因素下的性能稳健性^[1]。航空发动机作为飞机的动力来源和重要组成部分, 其运行状态在很大程度上能够决定飞机的性能指标及可靠性, 一旦发生故障, 造成的损失不可估量^[2]。然而, 航空机构的性能函数往往涉及复杂的多体动力学模型, 其隐式非线性特征显著, 难以通过显式物理方程描述, 形成了所谓的“黑箱问题”。传

统方法通常需要调用大量耗时的高保真仿真模型, 计算效率低下, 尤其在小失效概率的黑箱问题中更为明显。因此, 为了保障航空发动机系统安全运行, 在保证精度的前提下提升机构可靠性分析效率成为航空界共同面临的挑战。

在航空机构可靠性分析领域, 现有的方法主要可分为传统可靠性分析方法和代理模型驱动方法。传统可靠性分析方法包含蒙特卡洛(Monte Carlo sampling, MCS)类和

* 基金项目: 国家自然科学基金(52405255); 湖州市科技特派员项目(2023KT76); 河南省人机环境与应急管理国际联合实验室(安阳工学院)开放基金(KFKT-02); 河南省科技攻关项目(252102220051); 安阳市科技攻关项目(2025C01GX53)。

数值近似类。MCS 法为可靠性分析的基准方法,能为可靠性分析提供高精度的结果,这使得它在结果准确性要求较高的场景中具有一定的应用价值,但其效率极低^[3]。子集模拟 (Subset simulation, SS)^[4]和重要性抽样 (Importance sampling, IS)^[5]能够有效减少所需样本数量,对小概率问题的效率有一定改进。赵洪利等^[6]基于 MCS 模拟,给出了用于评估航空发动机发生故障可能性的风险预测方法。Narayanan 等^[7]提出了基于 MCS 模拟的航空发动机机构疲劳寿命估算方法。数值近似类则是以一阶可靠性方法 (First-order reliability method, FORM)^[8]和二阶可靠性方法 (Second-order reliability method, SORM)^[9]为代表,依赖梯度信息进行可靠性分析,广泛应用于实际工程中,但在面对非线性失效域的情况时精度较差。为了提升传统可靠性分析方法的性能,学者们已经成功开发出了多种改进方法,例如自适应混沌控制法^[10]、混合自适应共轭策略^[11]、采用 Barzilai-Borwein 策略改进的 Hasofer-Lind 和 Rakwitz-Fiessler (HL-RF)^[12]等。针对航空机构可靠性分析,杨周等^[13]使用 FORM 方法,基于模拟的随机参数与随机响应的关系进行发动机可靠性分析。张飞^[14]则改进了 FORM,通过在验算点 (而非均值点) 进行线性化展开,对航空发动机部件进行可靠性评估。梁振彬等^[15]针对强非线性问题高精度可靠性求解困难的问题,依据 SORM 建立了基于包络面的可靠性界限计算方法。

不过,相关研究显示,部分基于梯度的 FORM 在处理高度非线性问题时,可能会出现收敛速度缓慢,甚至结果发散的状况。鉴于此,不少学者运用基于启发式优化算法的 FORM 来解决上述问题,并取得了较为理想的进展。例如, Zhu 等^[16]提出了一种借助改进的粒子群优化算

法 (Particle Swarm optimization, PSO) 辅助的 FORM,其在处理高维问题时,展现出了更高的稳定性和计算效率。Zhong 等^[17]提出了一种全新的哈里斯鹰优化算法,并与 FORM 相结合,显著提升了其对高维算例的分析求解效率。

然而,随着工程机构日益复杂,其可靠性分析的成本逐渐变高^[18]。尤其在处理复杂多域耦合下大型机构的可靠性评估问题时,单次仿真所需的计算成本极高。为了降低工程产品的设计成本,缩短设计周期,代理模型技术已被广泛用于补充仿真分析^[19]。其通过替代高成本仿真模型,并与上述经典可靠性分析方法相结合,为机构可靠性分析提供了高效解决方案。

目前,主流的代理模型有传统响应面法 (RBF)、Kriging 代理模型、支持向量机 (SVM)、人工神经网络 (ANN)、径向基函数 (RBF) 及混沌多项式展开 (PCE)^[20]等。其中, Kriging 代理模型凭借非线性拟合能力与预测不确定性量化优势,成为主流方法之一^[21]。近年来,国内外学者围绕 Kriging 模型的构建与优化提出了多种策略。针对 Kriging 代理模型的精度和效率优化方面, Sun 等^[22]通过最小改进函数 (Least improvement function, LIF),动态筛选对模型误差贡献最大的样本点,显著提升了插值精度。Han 等^[23]进一步考虑样本点梯度信息,构建梯度增强 Kriging 模型 (Gradient-enhanced Kriging, GE-Kriging),有效改善了高非线性区域的拟合效果。Schöbi 等^[24]通过改进确定性基函数,实现了对复杂响应曲面的高精度逼近。Zhang 等^[25]提出的基于折叠正态和考虑样本密度的 REIF2 (Reliability-based expected improvement function 2) 学习函数,通过与低差异样本和自适应截断仿真区域相结合,有效解决了结构可靠度计算精度和效率的平衡问题。

上述研究虽然从模型更新策略等方面提高了 Kriging 模型的精度和效率,但传统方法主要依赖拉丁超立方抽样 (Latin hypercube sampling, LHS) 生成初始样本^[26],其样本点在设计空间内的随机分布性和均匀覆盖性不足,且需要大量的样本点才能使初始 Kriging 代理模型的预测精度满足要求。相比之下,针对 Kriging 模型可靠度计算的效率优化与精度提升,许多学者通过自适应抽样策略与代理模型协同优化,实现对关键区域的精准探索。Huang 等^[27]将 Kriging 代理模型和 SS 结合,提出 AK-SS,提高了小失效概率可靠度的计算效率。李诚等^[28]通过结合 Kriging 与花授粉算法 (FPA),提高了 Kriging 可靠度计算的迭代更新速度。杨旭锋等^[29]针对小失效概率可靠度计算问题,引入了改进的交叉熵自适应重要抽样 Kriging 代理模型的可靠度计算方法。同时还有自适应 Kriging 模型与重要性抽样相结合的 AK-IS^[30]、能够获得多个失效点的 Meta-AK-IS^[31]及基于自适应 Kriging 的定向采样方法 AK-DS^[32],它们为复杂系统的可靠性评估提供了理论突破。

为此,针对上述 Kriging 模型存在的不足和航空机构可靠性分析中建模难度大、计算效率与精度难以兼具的问题,本文提出一种融合数据增强拉丁超立方抽样与自适应分区拒绝权重采样的主动学习 Kriging 方法 (DALHS-APTRS-Kriging)。首先,通过 DALHS 的数据增强机制提升初始样本密度,有效解决传统拉丁超立方抽样在少样本条件下模型拟合精度不足的局限性;其次,基于 APTRS 的自适应分区策略动态划分设计空间,结合改进的 NU 主动学习函数,优先在失效概率区域进行样本迭代补充,平衡局部精细化建模与全局不确定性探索需求;最后,集成 Kriging 代理模型与 APTRS 高效可靠性计算框架,构建航空机构可靠度快速求解范式。

相比现有方法,所提方法通过数据驱动与自适应优化的协同机制,显著提升可靠性分析的收敛速度与预测精度,实现了复杂运动机构可靠性的高效计算。

1 DALHS 方法

为建立具有高精度的初始 Kriging 代理模型,样本点需要兼具代表性、随机性和空间覆盖性。传统拉丁超立方抽样(LHS)虽能保证单维投影均匀性,但在多维空间中易出现样本聚集或边界分布不均问题。为此,在传统 LHS 的基础上提出一种数据增强拉丁超立方抽样(Data augmentation Latin hypercube sampling, DALHS)方法,通过数据增强与扰动优化提升样本质量。

首先假设机构的设计变量为 m 维,其样本取值范围为 $l_j \leq x_j \leq u_j$ ($j=1, 2, \dots, m$),样本量为 N ,于是, DALHS 样本生成流程如下。

(1) 变量分层:对每维变量的取值范围进行等概率划分,生成 n 个互不重叠的区间。若变量服从均匀分布 $U(l_j, u_j)$,则第 i 个区间为

$$\left[l_j + \frac{(i-1)(u_j - l_j)}{n}, l_j + \frac{i(u_j - l_j)}{n} \right] \quad (1)$$

式中, l_j 和 u_j 为变量取值的上下限; $i=1, 2, \dots, n$ 。

(2) 层内随机抽样:生成随机偏移量,在每个区间内随机抽取一个样本点。对于第 i 个区间,所抽取的样本为

$$x_j^{(i)} = l_j + \frac{(i-1+u_{ij})(u_j - l_j)}{n} \quad (2)$$

式中, $u_{ij} \sim U(0, 1)$ 为区间内的随机偏移量。

(3) 随机排列组合:对每维变量 j 生成一个独立的随机排列序列,即

$$\pi_j = [\pi_j(1), \pi_j(2), \dots, \pi_j(k)] \quad (3)$$

式中, $\pi_j(k)$ 表示第 k 个样本在第 j 维的排列位置。

随后,将各维度的排列序列按索

引组合,生成 LHS 样本矩阵,即

$$\mathbf{x}_i = (x_1^{(\pi_1(k))}, x_2^{(\pi_2(k))}, \dots, x_m^{(\pi_m(k))}) \quad (4)$$

(4) 数据增强样本:初始化数据增强样本波动系数 ε_1 和 ε_2 以及波动变量 $\eta_{ik}, \eta'_{ik} \sim N(0, 1)$ (独立同分布, $k \in \{1, 2\}$)。对于原始样本,通过不同波动系数生成两组数据增强样本,即

$$\mathbf{x}_i^{(j1)} = \mathbf{x}_i \odot \begin{bmatrix} 1 + \varepsilon_1 \eta_{i1} \\ 1 + \varepsilon_1 \eta_{i2} \\ 1 + \varepsilon_1 \eta_{i3} \\ \vdots \\ 1 + \varepsilon_1 \eta_{ik} \end{bmatrix} \quad (5)$$

$$\mathbf{x}_i^{(j2)} = \mathbf{x}_i \odot \begin{bmatrix} 1 + \varepsilon_2 \eta'_{i1} \\ 1 + \varepsilon_2 \eta'_{i2} \\ 1 + \varepsilon_2 \eta'_{i3} \\ \vdots \\ 1 + \varepsilon_2 \eta'_{ik} \end{bmatrix} \quad (6)$$

即

$$\mathbf{x}_{ik}^{(j1)} = \mathbf{x}_{ik} \cdot (1 + \varepsilon_1 \eta_{ik}) \quad (7)$$

$$\mathbf{x}_{ik}^{(j2)} = \mathbf{x}_{ik} \cdot (1 + \varepsilon_2 \eta'_{ik})$$

通过合并原始 LHS 样本和数据增强样本,得到增强后的样本集为

$$\mathbf{x}_{\text{augmentation}} = \mathbf{x}_i \cup \mathbf{x}_{ik}^{(j1)} \cup \mathbf{x}_{ik}^{(j2)} \quad (8)$$

2 基于归一化的改进主动学习 Kriging 模型

2.1 优化 Kriging 模型

Kriging 模型是一种半参数化的插值技术,广泛应用于代理模型构建,其核心思想是结合全局趋势拟合与局部偏差修正,通过统计方法提供高精度的预测结果及不确定性估计,其基本表达式为

$$\hat{g}(\mathbf{x}) = f(\mathbf{x})\beta_1 + z(\mathbf{x}) \quad (9)$$

式中, $\hat{g}(\mathbf{x})$ 为系统功能函数; $f(\mathbf{x})$ 为样本回归部分的基函数; β_1 为回归系数; $z(\mathbf{x})$ 为随机统计过程,用以表征模拟结果的偏差。 $z(\mathbf{x})$ 统计特征为

$$\begin{cases} \text{MSE}[z(\mathbf{x})] = 0 \\ \text{Var}[z(\mathbf{x})] = \sigma^2 \\ \text{Cov}[z(\mathbf{x}_i), z(\mathbf{x}_j)] = \sigma^2 [R_{ij}(\theta, \mathbf{x}_i, \mathbf{x}_j)] \end{cases} \quad (10)$$

式中, $\text{MSE}(\cdot)$ 为均方误差函数; $\text{Var}(\cdot)$ 为方差函数; $\text{Cov}(\cdot)$ 为协方差函数; σ^2 为方差; $R_{ij}(\theta, \mathbf{x}_i, \mathbf{x}_j)$ 为核函数,用以表示样本点之间的关联; θ 为核函数的系数,其值影响着 Kriging 模型的精度。

根据式(9)和式(10), β_1 和 σ^2 在 Kriging 模型中的表达式为

$$\begin{cases} \beta_1 = (\mathbf{F}^T \mathbf{R}^{-1} \mathbf{F})^{-1} \mathbf{F}^T \mathbf{R}^{-1} \mathbf{y} \\ \sigma^2 = \frac{1}{N} (\mathbf{y} - \mathbf{F} \beta_1)^T \mathbf{R}^{-1} (\mathbf{y} - \mathbf{F} \beta_1) \end{cases} \quad (11)$$

式中, N 为样本点个数; \mathbf{F} 为收敛矩阵; \mathbf{R} 为函数集合矩阵。

综合式(9)~(11), Kriging 模型可表示为

$$\hat{y}(\mathbf{x}) = f(\mathbf{x})^T \beta_1 + r(\mathbf{x})^T \mathbf{R}^{-1} (\mathbf{y} - \mathbf{F} \beta_1) \quad (12)$$

式中, r 为相关系数。

为了提高 Kriging 模型的建模精度,核函数选择高斯核函数,通过 QRFA 算法求解式(13),以计算核函数中 θ 的最优值,其优化表达式为

$$\min \Psi(\theta) = |R(\theta)|^{(1/n)\sigma^2}, \theta \in [0, 20] \quad (13)$$

式中, $R(\theta)$ 为 θ 核函数的相关系数; $\Psi(\cdot)$ 为正态化的概率密度函数。

2.2 基于归一化的改进主动学习策略

在构建 Kriging 代理模型过程中,通过增加样本点优化初始模型的精度是至关重要的步骤。然而,传统样本点选取方法往往忽视了对抽样区域的针对性分析,导致关键区域(如结构性能函数梯度显著或失效概率较高的区域)样本密度不足,而次要区域(如响应值平稳或失效概率极低的区域)样本冗余堆积。这种不均衡的样本分布不仅降低了代理模型的局部拟合能力,还会因无效样本的引入增加计算资源消耗,从而制约整体建模效率。为此,本研究提出一种基于归一化的主动学习加点策略 NU,通过约束新增样本点的空间分布范围,主动学习加点策略 NU 能够优先聚集于结构性能函数的邻近

区域,从而在减少冗余计算的同时显著提升模型对关键区域的表征精度。

设当前候选样本集为 $x = \{x_{i_N} | i_N = 1, 2, \dots, N\}$, 预测均值和方差为 μ_{i_N} 和 $\sigma_{i_N}^2$, 表示为

$$\mu_{i_N} = \mu_y(x_{i_N}), \sigma_{i_N}^2 = \sigma_y^2(x_{i_N}) \quad (14)$$

式中, $\mu_y(\cdot)$ 和 $\sigma_y^2(\cdot)$ 分别为 Kriging 模型的预测均值和方差函数。

由于传统学习函数 $U(\cdot)$ 仅考虑均值与方差的比值, 为此, 在改进的主动学习策略中引入归一化与概率密度加权, 增强对关键区域的聚焦能力, 同时考虑开发(靠近失效边界)与探索(高不确定性区域), 并且通过概率密度项抑制对非关键区域的冗余采样。于是, 改进的主动学习策略 $NU(\cdot)$ 定义为

$$NU(x_{i_N}) = \frac{|\mu_y(x_{i_N})|}{\max \mu_y(x_{i_N})} \cdot \frac{f(x_{i_N})}{\sigma_y^2(x_{i_N}) / \max \sigma_y^2(x_{i_N}) \cdot \max f(x_{i_N})} \quad (15)$$

式中, $f(\cdot)$ 为标准正态分布的概率密度函数。

$NU(\cdot)$ 通过归一化均值表示与失效边界的相对接近程度, 利用均值与方差比平衡均值和不确定性的影响, 并通过概率密度函数抑制对极值区域的过度采样, 于是通过最小化 $NU(\cdot)$ 函数值筛选最佳样本点, 表示为

$$x_{\text{new}} = \arg \min_{x_{i_N} \in X} NU(x_{i_N}) \quad (16)$$

同时, 为保证式(15)增加的样本点具有较高的质量, 提出了对应主动学习策略 $NU(\cdot)$ 的收敛准则, 其表达式为

$$\min_{x \in S} [NU(x)] \geq 2 \quad (17)$$

式中, S 为样本库中的样本点集。

通过实施归一化改进主动学习策略, 优先筛选出对失效边界或高不确定性区域具有显著影响的样本点, 并将其作为新增样本加入训练集, 从而在降低冗余计算的同时, 显著提升 Kriging 代理模型对关键区域的局部

逼近精度及全局迭代效率。

3 APTRS 可靠性分析方法

传统的 AK-MCS 方法通过结合代理模型与 MCS 实现结构失效概率或可靠度的计算, 然而在面对小失效概率问题时, 其计算效率显著下降, 需要消耗大量样本资源以保障结果精度。针对这一局限性, 提出自适应分区拒绝权重采样 (Adaptive partitioned threshold rejection sampling, APTRS) 方法进行可靠性分析, 与现有分层抽样方法相比, APTRS 的动态自适应分区通过 Kriging 模型预测反馈, 动态调整对失效域的认知, 让分区聚焦到潜在失效区域。传统 SS 使用固定条件概率水平的马尔可夫链, 而 APTRS 使用自适应分区和分区内加权拒绝采样; 自适应重要性抽样 (AIS) 通常迭代更新一个全局重要性密度函数, 而 APTRS 在分区内定义局部重要性密度, 且分区是动态的。同时 APTRS 在子区域内结合了原始分布和子区域特性, 采用拒绝采样的权重机制, 旨在更有效地在子区域内产生对失效概率贡献大的样本, 并且 APTRS 与基于 NU 函数的主动学习 Kriging 模型是紧密协同的。Kriging 模型为 APTRS 提供失效边界信息以指导分区, 而 APTRS 高效生成的样本又用于更新 Kriging 模型。通过不断探索样本点失效区域, 直到样本点覆盖失效区域, 实现高效小失效概率可靠性分析, 从而以更低的计算成本获得高精度可靠性指标, 且显著提高了局部搜索能力。

APTRS 通过自适应扩展设计空间、引入拒绝采样机制及优化抽样权重, 显著提升了对高维复杂失效域的探索效率, 同时降低小失效概率问题的计算成本。首先, 设计空间被划分为一系列子区域,

$$D = \sum_{i_d=1}^{m_d} D_{i_d} \quad (18)$$

式中, $D_{i_d} = \{\mathbf{x} | R_{i_d-1} < \|\mathbf{x}\| < R_{i_d}, \mathbf{x} \in D\}$ 是

两个半径分别为 R_{i_d-1} 和 R_{i_d} 围成的区域, 半径 R 是一个递增序列, 按照设计维度表示为 $R_0 = 0 < R_1 < \dots < R_{m_d} = \infty$; i_d 表示第 i_d 个区域 $\{i_d = 1, 2, \dots, m_d\}$; m_d 是区域数量。因此, 计算的失效概率重新被定义为

$$P_f = \sum_{i_d=1}^{m_d} \int_{D_{i_d}} I_F(\mathbf{x}) f_X(\mathbf{x}) d\mathbf{x} \quad (19)$$

子区域的概率密度函数可表示为

$$f_X^{i_d}(\mathbf{x}) = \begin{cases} \frac{f_X(\mathbf{x})}{\theta_{i_d}} & \text{if } \mathbf{x} \in D \\ 0 & \text{otherwise} \end{cases} \quad (20)$$

式中, $\theta_{i_d} = \int_{D_{i_d}} f_X(\mathbf{x}) d\mathbf{x}$ 为子区域失效概率。根据式(19)和式(20), 失效概率可表示为

$$P_f = \lambda \sum_{i_d=1}^{m_d} \theta_{i_d} \int_{D_{i_d}} I_F(\mathbf{x}) f_X^{i_d}(\mathbf{x}) d\mathbf{x} = \lambda \sum_{i_d=1}^m \theta_{i_d} P_{f_{i_d}} = \lambda \sum_{i_d=1}^{m_d} P_{f_{i_d}}^{i_d} \quad (21)$$

式中, $P_{f_{i_d}} = \int_{D_{i_d}} I_F(\mathbf{x}) f_X^{i_d}(\mathbf{x}) d\mathbf{x}$ 为子区域的条件失效概率, 表示失效样本点与所有样本点的比例; $P_{f_{i_d}}^{i_d}$ 为子区域失效概率; λ 为概率系数。于是, 失效概率可表示为

$$P_f^* = \lambda \sum_{j_d=1}^{N_{i_d}} \frac{I_F(\mathbf{x}_{i_d}^{j_d})}{N_{i_d}} \quad (22)$$

式中, $\{\mathbf{x}_{i_d}^{j_d}, j_d = 1, 2, \dots, N_{i_d}\}$ 是从第 i_d 个区域采样的样本点。根据式(21)和式(22), 失效概率可表示为

$$P_f^* = \sum_{i_d=1}^{m_d} \theta_{i_d} P_{f_{i_d}} = \sum_{i_d=1}^{m_d} P_{f_{i_d}}^* \quad (23)$$

其相关方差为

$$\text{Var}(P_f^*) = \text{Var} \left(\sum_{i_d=1}^{m_d} P_{f_{i_d}}^* \right) = \sum_{i_d=1}^{m_d} \frac{\theta_{i_d}^2 P_{f_{i_d}}^* (1 - P_{f_{i_d}}^*)}{N_{i_d}} + \sum_{i_d=1}^{m_d} \text{Var}(P_{f_{i_d}}^*) \quad (24)$$

根据式(23), 总方差等于所有子区域的方差之和, 因此变异系数的计算公式为

$$\text{Cov}_{\text{APTRS}}(P_f^*) = \frac{\sqrt{\text{Var}(P_f^*)}}{P_f^*} = \sqrt{\frac{\sum_{i_d=1}^{m_d} \theta_{i_d}^2 P_{i_d}^* (1 - P_{i_d}^*)}{N_{i_d} P_f^{*2}}} \quad (25)$$

在分区策略完成之后,在不同分区进行拒绝抽样,首先生成均匀分布样本点 $x_{\text{prop}} \sim U(a, b)$,同时为保证拒绝抽样的有效性,需要计算其包络常数 M ,使得

$$f_R(x_{\text{prop}}) \leq M \cdot q(x_{\text{prop}}) \quad (26)$$

式中, $f_R(\cdot)$ 为子区域半径 R 的概率密度函数; $q(\cdot)$ 为均匀分布样本的概率密度函数。

其次,根据卡方分布计算目标密度:

$$f_R(x_{\text{prop}}) = \frac{1}{p_2 - p_1} \cdot \chi_d^2(x_{\text{prop}}^2) \cdot 2x_{\text{prop}} \quad (27)$$

式中, p_2 为第二个子区域的归一化系数; p_1 为第一个子区域的归一化系数; χ_d^2 为区域样本点的卡方二次分布。

然后计算拒绝采样的接受概率,其值为候选样本密度与包络线密度之比:

$$\alpha(x_{\text{prop}}) = \frac{f_R(x_{\text{prop}})}{M \cdot q(x_{\text{prop}})} = \frac{f_R(x_{\text{prop}}) \cdot (R_{i+1} - R_i)}{M} \quad (28)$$

式中, $\alpha(x_{\text{prop}})$ 为样本点的接受概率。

最后,将 $\alpha(x_{\text{prop}})$ 作为一个阈值,利用生成的均匀分布样本的概率密度 pdf(x) 进行判断,若 pdf(x) $\leq \alpha(R_{\text{prop}})$,则接受该样本,否则拒绝。重复此过程,直到收敛或满足最大迭代次数。

4 基于主动学习的可靠性分析方法

4.1 Adams 与 Simulink 联合仿真计算方法

对于多数复杂工程结构而言,由于难以直接获取其显式物理模型参数与解析表达式,通常需要借助数值

仿真方法构建其隐式性能函数。针对这一技术挑战,基于运动仿真软件 Adams 的通用性优势,提出一种 Adams-Simulink 协同仿真平台构建方法,实现代理模型在工程实际问题中的自动化调用与验证,如图 1 所示。

具体操作步骤如下:

(1) 通过所建模型获取输入变量数据,并将模型导入 Adams 进行仿真;

(2) 在 Adams 仿真平台中定义模型动力学约束、材料密度及运动受力,并将输入变量数据连接仿真平台;

(3) 调用 Adams_Controls 模块,配置 Adams_Controls 联合仿真接口,生成扩展名为“.m”的仿真接口软件;

(4) 通过 Adams_Controls 模块生成实时数据交互接口“.m”文件,实现 Adams 多体动力学响应与 Simulink 控制指令的闭环耦合,步长设置为 1 ms;

(5) 在 Simulink 中建立针对运动模型的控制策略,对运动信号进行反馈调节,提升机构运动可靠性分析的工况真实性,并通过 Adams 平台计算出发动机机构运动数据;

(6) 最后将输入变量和模型计算结果一同写入 Matlab,将其作为初始数据输出,建立 Kriging 模型。

4.2 主动学习机构可靠性分析流程

综上,提出的基于 DALHS-APTRS-Kriging 的主动学习机构可靠性分析方法流程如图 2 所示,具体步骤如下。

(1) 数字化仿真模型,获得真实性能函数,搭建 Adams 与 Simulink 的联合仿真平台,确定设计变量和空间。

(2) 根据设计变量维度在设计空间 LHS 抽取初始样本点 N_1 ,数据增强获得 DALHS 后的样本点 N_{1d} 。

(3) 将初始样本点输入联合仿真平台,计算模型机构真实性能函数集合。

(4) 选择高斯核函数,利用 QRFS 算法优化参数 θ ,并通过初始样本点及其对应的真实性能函数值集合构建性能函数的初始 Kriging 模型。

(5) 确定 APTRS 样本数,采用 APTRS 进行自适应分区拒绝采样计算,根据目标函数确定分区区域数量 m ,初始化抽取样本数量 N 和条件概率 P_f ,在各子区域进行改进拒绝的采样,构建优化 Kriging 模型。

(6) 计算当前 Kriging 模型的失效概率和累积分布函数,若结果满足式(29),流程结束,若不满足继续步骤(7)。

$$\text{Cov}_{\text{APTRS}} \leq 0.05 \quad (29)$$

(7) 通过提出的主动学习函数 $\text{NU}(x)$ 计算设计空间中样本点的函数值,确定 $\min[\text{NU}(x)]$ 的值及对应的样本 x_i ,判断是否满足收敛条件 $\min_{x \in S}[\text{NU}(x)] \geq 2$,若满足,则增加当前样本点,计算其真实性能函数值,并加入样本库,否则重新选择样本。

(8) 每完成一次循环,迭代计数参数增加 1,即 $\text{Gen} = \text{Gen} + 1$,直至满

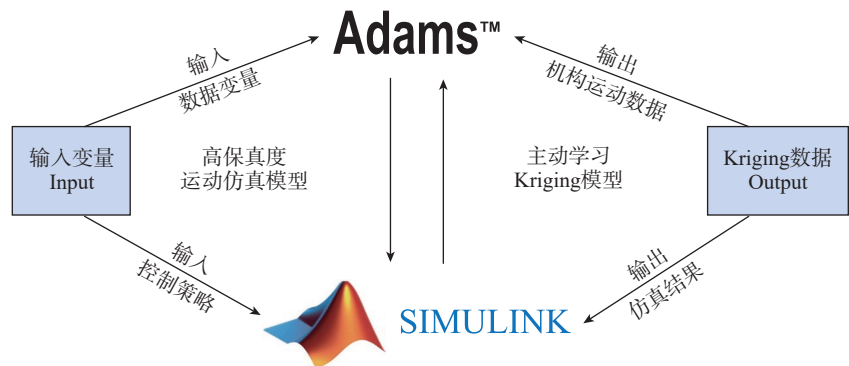


图 1 Adams 和 Simulink 协同计算流程
Fig.1 Collaborative computing between Adams and Simulink

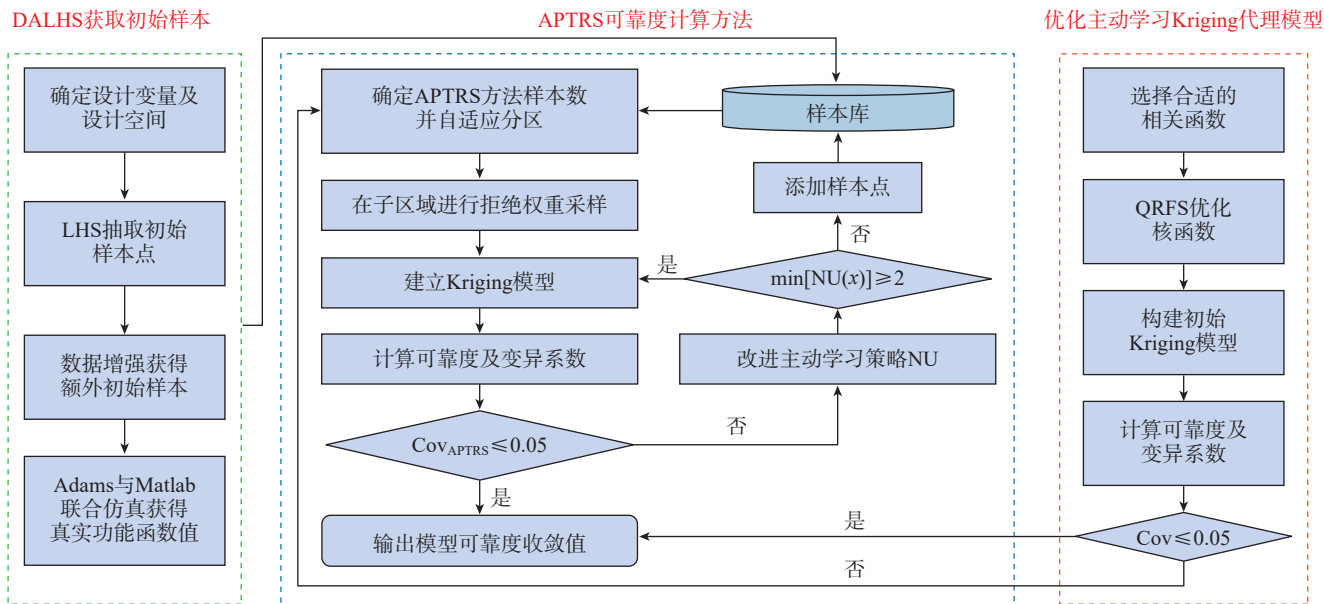


图2 主动学习机构可靠性分析流程
Fig.2 Reliability analysis for active learning institutions

足步骤(6)的收敛条件,迭代终止。

5 方法验证及工程应用

5.1 DALHS 有效性验证

为验证所提出 DALHS 方法的有效性,采用 LHS 和均匀网格抽样进行对比分析,假设设计变量 x_1 和 x_2 的取值范围为 $[0, 1]$ 。LHS 和均匀网格抽样获得 25 个采样点,本文数据增强获得 54 个样本点,结果如图 3 所示。

由图 3 可知:传统 LHS 方法在 25 个样本点的空间分布上表现出良好的随机性特征,但其均匀性和覆盖度指标存在明显缺陷,具体表现为局

部区域样本点聚集现象突出、相邻点距过近,且存在空间信息采集盲区;均匀网格抽样虽能弥补 LHS 方法在均匀性的不足,且质量会随着设计变量的波动而改变,但随机性不如 LHS 方法,同时大部分样本点处在设计空间边界,这会导致样本点信息利用率较低;相较之下,所提 DALHS 在保持良好随机性的基础上,实现了设计空间内多维度的均匀覆盖,且无超出边界情况,其样本点集同时满足空间信息采集的完备性和分布均匀性要求。试验数据表明,基于 DALHS 构建的初始 Kriging 模型的预测精度较传统采样方法提升显著,验证了该采样策

略在平衡空间探索与开发方面的优势特性,以此为基础构建 Kriging 模型有利于模型精度的提升。

5.2 主动学习 Kriging 可靠性分析方法验证

为验证所提方法效能,选取可靠性分析领域的典型基准案例进行实证研究。通过对比 AK-MCS+U、AK-MCS+NU 主流方法的收敛速度与计算稳定性,说明所提方法的高效性,同时,与多种经典可靠性分析方法进行数据对比,验证所提方法的优异性。

选择四分之一串联系统作为算例分析,其中有两个标准正态无量纲随




图3 不同抽样方法对比
Fig.3 Comparison of different sampling methods

机变量 x_1 和 x_2 , $x \sim N(0, 1)$, 该系统的性能函数^[33]为

$$G(x_1, x_2) = \min \begin{cases} 3 + 0.1(x_1 - x_2)^2 - (x_1 + x_2) / \sqrt{2}; \\ 3 + 0.1(x_1 - x_2)^2 + (x_1 + x_2) / \sqrt{2}; \\ (x_1 - x_2) + 6 / \sqrt{2}; \\ (x_2 - x_1) + 6 / \sqrt{2} \end{cases} \quad (30)$$

根据式(30)中的变量取值范围, 采用 DALHS 获取初始样本点, 求解真实响应值, 构建 Kriging 代理模型, 计算可靠度并进行精度检验, 通过改进 NU 主动学习策略, 加入最佳样本点进行模型更新。本算例中, DALHS 初始样本量设置为 4 个, 数据增强增加为 12 个。其余方法初始样本点数量设为 12 个。通过 APTRS 计算得到所提方法拟合的最佳 Kriging 模型和样本点分布, 如图 4 所示。

由图 4 可知, DALHS 样本集呈现全域空间随机分布特性, 验证了其初始采样策略的优越性。APTRS 能够自适应扩充样本点到失效区域, 并且样本点主要分布在极限状态邻域, 具有显著的临界区域聚集特征。所提出的 NU 主动学习策略明显提高了主动学习的优化效果, 添加的样本点质量有所提高。所构建的 Kriging 代理模型在全局范围内与真实性能函数保持高度吻合, 尤其在四象限边界的局部拟合精度表现突出。通过与文献 [7, 19] 中不同主动学习方法对比, 所提方法在代理模型精度指标与样本空间分布优化方面均展现出全面优势。

为了验证所提方法的可靠度精度, 以 MCS 结果为精确解, 通过与 AK-MCS+U、AK-MCS+NU 进行对比分析, 得到 3 种方法的可靠度收敛曲线, 如图 5 所示。

由图 5 的可靠度收敛曲线可知, 3 种不同的计算方法的可靠度指标随计算进程演变的整体趋势高度一致, 均呈现向目标值逐步逼近并最终稳定的典型收敛特征。在收敛效率上, DALHS-APTRS-Kriging 方法收

敛速度最快, 能以最小的计算成本迅速达到稳定状态; AK-MCS+NU 方法的收敛速度次之, 而 AK-MCS+U 方法相对最慢, 两者计算成本相近。尽管收敛速度存在明显差异, 但 3 种方法计算结果非常接近, 表明它们在解决该可靠性分析问题时有较好的一致性精度。随后, 以文献 [7] 中提供的方法和数据进行参考, 以调用次数 N_{call} 、失效概率 P_f 、可靠性指标 β 及其相对误差 δ 进行对比

分析, 见表 1。

由表 1 可知, DALHS-APTRS-Kriging 方法在可靠度计算精度方面展现出显著优势, 其与 MCS 结果的偏差较小, 相较于 AK-MCS+NU 和 AK-MCS+U 方法, 性能函数调用次数仅需 67 即可达到同等精度水平, 计算效率提升超过 30%。特别值得注意的是该方法的归一化探索能力, 在保证全局搜索能力的同时有效降低了函数调用次数, 较传统分析方

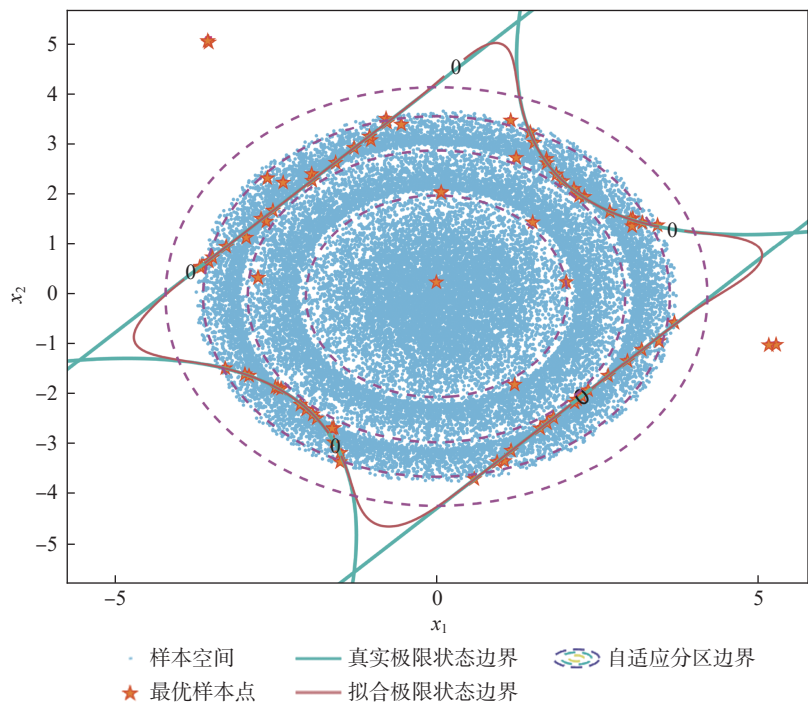


图 4 模型效果和样本分布

Fig.4 Model effect and sample distribution

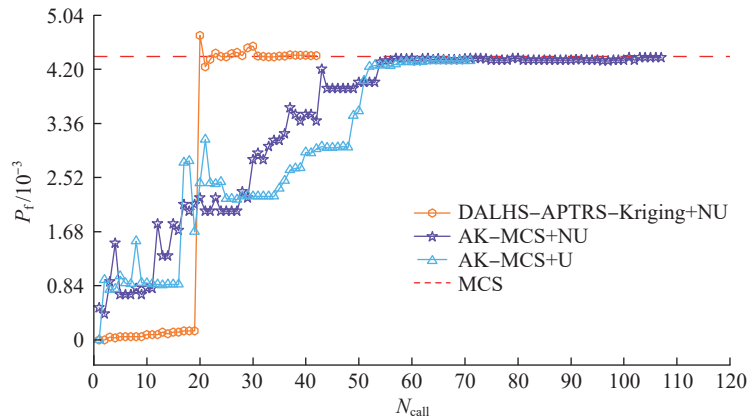


图 5 可靠度收敛曲线

Fig.5 Reliability convergence curves

式 AK-MCS-EFF 函数调用次数减少 45%。在横向对比中,所提方法精度高于 IS、DS+Neural network 等算法并且计算资源消耗减少 50% 以上;与 DS 方法、IS+Neural network 方法相比,在保持相近计算效率的前提下,计算精度分别提升 2.17 个百分点和 29.30 百分点。试验数据证实,基于 APTRS 的框架设计,算法在保持精度标准时,有效地减少了小失效概率事件的计算成本。这些特征表明, DALHS-APTRS-Kriging 方法通过数据增强初始样本和自适应分区拒绝采样筛选以及改进主动学习策略,实现了可靠性分析中精度与效率的协同优化,为小失效概率的高维复杂系统的可靠性评估提供了有效解决方案。

5.3 高维非线性振荡器算例验证

6 维非线性系统如图 6 所示^[34],其主要性能函数为

$$G(C_1, C_2, M, R, T_1, F_1) = 3R -$$

$$\left| \frac{2F_1}{M\omega_0^2} \sin \frac{\omega_0^2 T_1}{2} \right| \quad (31)$$

式中, $\omega_0 = \sqrt{(C_1 + C_2) / M}$ 。

6 个随机变量分布见表 2。

采用 DALHS 方法在式(31)定义的变量取值范围内获取初始样本点,同时利用 APTRS 候选样本点,求解其真实响应值以构建 Kriging 代理模型。随后进行可靠度计算与精度检验,并通过改进的主动学习策略选择最佳样本点加入以更新模型。在本算例中, DALHS 的初始样本量设置为 4 个,经数据增强后增至 12 个。其他对比方法的初始样本点数量均设置为 12 个。同时,为减少随机变量的影响,每种方法进行 30 次计算,其计算结果取平均值见表 3。

从表 3 分析结果可知,在高维非线性可靠性分析中, AK-MCS+U 与 AK-SS 方法有着较高的计算精度,但其功能函数的调用频率显著高于其他方法。当响应值需通过计算密

表 1 不同方法结果对比

Table 1 Comparison of results from different methods

| 分析方法 | N_{call} | $P_f/10^{-3}$ | β | $\delta/\%$ |
|---------------------------|------------|---------------|---------|-------------|
| MCS | 10^6 | 4.4160 | 2.6180 | — |
| DALHS-APTRS-Kriging | 67 | 4.4133 | 2.6182 | 0.06 |
| AK-MCS+U | 71 | 4.4169 | 2.6185 | 0.02 |
| AK-MCS+NU | 88 | 4.4351 | 2.6183 | 0.43 |
| AK-MCS-EFF | 124 | 4.4122 | 2.6188 | 0.09 |
| Directional sampling (DS) | 52 | 4.5146 | 2.6221 | 2.23 |
| DS+Neural network | 165 | 4.1135 | 2.6437 | 6.85 |
| Importance sampling (IS) | 1469 | 4.9238 | 2.5828 | 11.50 |
| IS+Neural network | 52 | 5.7125 | 2.5302 | 29.36 |




图 6 非线性算例^[34]

Fig.6 Non-linear oscillator^[34]

表 2 随机变量统计特征

Table 2 Statistical characteristics of random variables

| 随机变量 | 均值 | 分布类型 | 方差 |
|-------|-----|------|------|
| M | 1 | 正态分布 | 0.05 |
| C_1 | 1 | 正态分布 | 0.1 |
| C_2 | 0.1 | 正态分布 | 0.01 |
| R | 0.5 | 正态分布 | 0.05 |
| T_1 | 1 | 正态分布 | 0.2 |
| F_1 | 1 | 正态分布 | 0.2 |

表 3 计算结果及对比

Table 3 Calculation results and their comparison

| 分析方法 | N_{call} | $P_f/10^{-2}$ | $\delta/\%$ |
|---------------------|------------|---------------|-------------|
| MCS | 10^6 | 2.850 | — |
| FORM | 48 | 3.112 | 9.19 |
| IS | 10^4 | 3.021 | 6.00 |
| AK-SS | 145 | 2.863 | 0.46 |
| AK-MCS+U | 136 | 2.852 | 0.07 |
| AK-MCS-EFF | 34 | 3.031 | 6.35 |
| DALHS-APTRS-Kriging | 28 | 2.842 | 0.28 |

集的有限元仿真获取时,有着较高的计算成本。另一方面,AK-MCS-EFF方法及传统FORM法虽计算效率较高、调用次数较少,但其精度在高维复杂问题下明显不足,难以满足工程实践对精度的严格要求。相比

之下,所提方法尤其适用于高维场景,它有效克服了精度与效率难以兼得的困境:在严格保持高计算精度的同时,显著降低了功能函数的调用需求。特别在进行30次重复试验时,其平均调用次数为所有对比方法中

最低,充分证明了所提方法在求解高维可靠性问题时兼具高精度与高效率的显著优势。

5.4 通航活塞发动机机构可靠性分析

航空发动机运动机构作为通用航空飞行器的核心动力传输单元,其动态稳定性直接决定飞行系统的安全性等级。本文以某型通航活塞发动机关键运动系统为研究对象,通过构建运动可靠性分析框架(图7),计算其运动可靠度。

基于参数化建模技术构建发动机数字样机后,通过Adams-Matlab联合仿真平台构建运动学/动力学闭环验证系统,其仿真环境配置如图8所示。

该协同仿真策略利用多物理场耦合计算,获取高置信度的运动副数据,为后续可靠性建模提供关键输入参数。特别地,采用Adams进行多体动力学仿真,揭示机构运动规律,结合Matlab/Simulink实现控制系统交




图7 发动机主要结构
Fig.7 Main structure of engine




图8 发动机运动环境仿真
Fig.8 Engine motion environment simulation

互验证,确保仿真数据与真实工况高度一致。

在完成运动环境搭建之后,将其与 Matlab 连接,建立发动机运动模块,随后在 Matlab 中搭建发动机控制模块,进行联合仿真,获取发动机主要机构运动数据。

为了更好地量化其机构运动,定义了一个以曲轴为中心的笛卡尔坐标系,如图 9 所示。曲轴、连杆和活塞之间的运动关系可以表示为

$$Y = r \cos \alpha + \sqrt{l^2 - r^2 \sin^2 \alpha} = f(r, l, \alpha) \quad (32)$$

式中, Y 为发动机活塞行程; r 为曲轴半径; l 为连杆长度; α 为输入转角; ψ 为连杆与 Y 轴之间的夹角。

由于发动机原始制造误差和运动位置不准确的存在影响着运动精度,因此活塞的实际行程可以通过一阶泰勒级数展开表示:

$$Y = Y^* + \Delta Y = f(r^* + \Delta r, l^* + \Delta l, \alpha^* + \Delta \alpha) = f(r^*, l^*, \alpha^*) + \frac{\partial f}{\partial r} \Delta r + \frac{\partial f}{\partial l} \Delta l + \frac{\partial f}{\partial \alpha} \Delta \alpha \quad (33)$$

式中, Y^* 是通航活塞发动机行程的理想值; r^* 是曲轴半径的理想值; l^* 是连杆长度的理想值; α^* 是角度的理想值; Δr 是曲轴半径误差, Δl 是连杆长度误差, $\Delta \alpha$ 是角度误差, ΔY 是行程误差,这是评估通航活塞发动机运动

精度的重要指标。

当 $\Delta Y=0$ 时,认为通航活塞发动机运行安全可靠;反之,则认为通航活塞发动机存在运行风险。其机构运动误差示意图如图 10 所示。通航活塞发动机的运动误差可以表示为

$$\Delta Y = \left(\cos \Delta \alpha - \frac{r \sin^2 \Delta \alpha}{\sqrt{l^2 - (r \sin \Delta \alpha)^2}} \right) \Delta r + \left(\frac{l}{\sqrt{l^2 - (r \sin \Delta \alpha)^2}} \right) \Delta l - \left(l \cdot \sin \Delta \alpha + \frac{l \cdot \sin \Delta \alpha \cdot \cos \Delta \alpha}{\sqrt{l^2 - (r \sin \Delta \alpha)^2}} \right) \Delta \alpha \quad (34)$$

同时,由于发动机运动机构复杂,结构尺寸参数众多,除了现有曲




图 10 发动机运动示意图
Fig.10 Schematic diagram of engine movement

轴半径 r 、连杆长度 l 及输入角度 α 误差以外,通过多域耦合联合仿真发现,发动机的材料不确定性(如活塞的热变形 ε_a 、发动机机构的弹性模量 E 和材料密度 ρ)和载荷及材料不确定性(如活塞销运动间隙 ε_θ 、各部件的装配误差 ε_r)等,都会影响发动机可靠性分析。为使其更贴近真实航空机构的复杂性,引入活塞的热变形 ε_a 、发动机机构的弹性模量 E 、材料密度 ρ 、活塞销运动间隙 ε_θ 、机构装配误差 ε_r 进行可靠性分析。于是,通航活塞发动机运动精度的性能函数可以定义为

$$G(x) = \Delta Y = f(\Delta r, \Delta l, \Delta \alpha, \varepsilon_\theta, \varepsilon_r, \varepsilon_a, E, \rho) \quad (35)$$

随机变量的统计公差按照“ 3σ 原则”确定,其主要统计特征如表 4 所示。

依照图 1 所示流程对所提发动机进行可靠性分析。首先借助 Matlab 与 Adams 构建的协同仿真框架,采用 DALHS 方法生成初始样本点;通过循环迭代,调用 Matlab 计算架构性能函数的真实响应值,并基于提出的主动学习优化策略 NU 对 Kriging 模型进行动态更新,利用 APTRS 进行可靠性计算。当失效概率估计值的相对误差满足预设收敛阈值时,终止迭代过程,计算结果如图 11 所示。

由图 11 可知,在考虑多种不确




图 9 发动机运动坐标
Fig.9 Coordinates of engine motion

表 4 随机变量统计特征

Table 4 Statistical characteristics of random variables

| 随机变量 | 均值 | 分布类型 | 方差 |
|------------------------------|----------------------------------|------|------|
| 曲轴半径误差 Δr | 0 | 正态分布 | 0.05 |
| 连杆长度误差 Δl | 0 | 正态分布 | 0.05 |
| 输入角度误差 $\Delta \alpha$ | 0 | 正态分布 | 1 |
| 活塞销运动间隙 ε_θ | 0 | 正态分布 | 0.05 |
| 装配误差 ε_r | 0 | 正态分布 | 0.05 |
| 活塞热变形 ε_a | 0 | 正态分布 | 0.05 |
| 弹性模量 E | 68.9 GPa | 正态分布 | 0.02 |
| 材料密度 ρ | $2.7 \times 10^3 \text{ kg/m}^3$ | 正态分布 | 0.05 |

定性影响下,发动机主要运动系统的可靠度指标达到工程安全阈值要求。通航活塞发动机机构在多种因素不确定的情况下失效概率为 0.0130,即可靠度为 0.9870。量化表征了不确定性传播对结构安全性的影响。相较于传统确定性分析,基于可靠度的评估方法更精准反映实际工况风险。为验证计算结果的有效,将所提方法与 MCS 方法进行比较,结果见表 5。

由表 5 可知,以 MCS 为基准, DALHS-APTRS-Kriging 方法在函数调用次数方面具有显著优势,仅为 72 次,且计算误差仅 5.7%,可见,所提方法具有较好的工程应用性,能够高效处理工程中复杂的可靠性分析问题。

6 结论

本文结合 DALHS 和 APTRS 方法,提出一种基于主动学习 Kriging 的机构可靠性分析方法,用于解决航空机构可靠性分析中建模难度大和计算效率低等问题。

(1) 基于传统拉丁超立方抽样和数据增强技术,提出了 DALHS 方法。该方法不仅有效改善了初始样本质量,还通过数据增强协同作用,提高了初始样本集的多样性和随机性。数值验证表明: DALHS 方法相比 LHS 方法、均匀网格抽样方法在同等条件下增加了 29 个样本,且样本的多样性和随机性有明显提升,进一步保证了初始 Kriging 的拟合精度。

(2) 基于 U 函数与传统自适应分区方法,提出改进 NU 学习函数和 APTRS 策略,能够自适应填充样本,实现局部处理与全局探索的动态平衡。数值算例表明:改进 NU 学习函数和 APTRS 策略的新增样本基本分布在极限状态函数附近,不仅保证了新增样本的质量,而且实现了 Kriging 模型的高效拟合。

(3) 通过低维四分之串联系统和高维非线性振荡器数值算例验证




图 11 发动机失效概率的累积分布函数曲线

Fig.11 Cumulative distribution function curve of engine failure probability

表 5 计算结果及对比

Table 5 Calculation results and their comparison

| 分析方法 | N_{call} | P_f | $\delta/\%$ |
|---------------------|------------|--------|-------------|
| MCS | 10^6 | 0.0138 | — |
| DALHS-APTRS-Kriging | 72 | 0.0130 | 5.7 |

了所提方法的高效性。对于低维四分之串联系统,所提方法的函数调用次数仅需 67 即可达到传统方法精度水平,计算效率提升 30%;对于高维非线性振荡器系统,所提 DALHS-APTRS-Kriging 方法相比 MCS 的计算误差为 0.28%,但性能函数调用次数仅为 28,在保证精度同时显著降低了计算成本。

(4) 利用所提方法对通航活塞发动机进行机构可靠性分析,在考虑不确定性因素影响下通航活塞发动机的机构可靠度为 0.987,相比传统 MCS 方法,计算误差仅为 5.7%,且计算成本显著降低。说明所提方法具有较好的工程应用性,能够在求解复杂机构可靠性中兼具计算效率和精度。

参考文献

[1] ZHANG J F, DU X P. Time-dependent

reliability analysis for function generation mechanisms with random joint clearances[J]. Mechanism and Machine Theory, 2015, 92: 184-199.

[2] 陶春虎, 钟培道, 王仁智, 等. 航空发动机转动部件的失效与预防[M]. 北京: 国防工业出版社, 2000.

TAO Chunhu, ZHONG Peidao, WANG Renzhi, et al. Failure analysis and prevention for rotor in aero-engine[M]. Beijing: National Defense Industry Press, 2000.

[3] 张学仪, 何小妹, 刘峻峰, 等. 基于蒙特卡洛法的叶片型面参数测量不确定度分析[J]. 航空制造技术, 2021, 64(12): 94-101.

ZHANG Xueyi, HE Xiaomei, LIU Junfeng, et al. Evaluation of uncertainty in blade parameter measurement based on Monte Carlo method[J]. Aeronautical Manufacturing Technology, 2021, 64(12): 94-101.

[4] ZHANG J H, XIAO M, GAO L. An active learning reliability method combining Kriging constructed with exploration and exploitation of failure region and subset simulation[J]. Reliability Engineering & System Safety, 2019, 188: 90-102.

- [5] BARKHORI M, ALI SHAYANFAR M, ALI BARKHORDARI M, et al. Kriging-aided cross-entropy-based adaptive importance sampling using Gaussian mixture[J]. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 2019, 43(1): 81–88.
- [6] 赵洪利, 刘宇文. 基于蒙特卡罗模拟的航空发动机故障风险预测[J]. *北京航空航天大学学报*, 2015, 41(3): 545–550.
- ZHAO Hongli, LIU Yuwen. Forecasting for aero-engine failure risk based on Monte Carlo simulation[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2015, 41(3): 545–550.
- [7] NARAYANAN G, REZAEI K, NACKENHORST U. Fatigue life estimation of aero engine mount structure using Monte Carlo simulation[J]. *International Journal of Fatigue*, 2016, 83: 53–58.
- [8] KESHTEGAR B, EL AMINE BEN SEGHIER M, ZHU S P, et al. Reliability analysis of corroded pipelines: Novel adaptive conjugate first order reliability method[J]. *Journal of Loss Prevention in the Process Industries*, 2019, 62: 103986.
- [9] HU Z L, MANSOUR R, OLSSON M, et al. Second-order reliability methods: A review and comparative study[J]. *Structural and Multidisciplinary Optimization*, 2021, 64(6): 3233–3263.
- [10] LI G, LI B, HU H. A novel first-order reliability method based on performance measure approach for highly nonlinear problems[J]. *Structural and Multidisciplinary Optimization*, 2018, 57(4): 1593–1610.
- [11] KESHTEGAR B, CHAKRABORTY S. A hybrid self-adaptive conjugate first order reliability method for robust structural reliability analysis[J]. *Applied Mathematical Modelling*, 2018, 53: 319–332.
- [12] ZHAO W, CHEN Y Y, LIU J K. An effective first order reliability method based on Barzilai–Borwein step[J]. *Applied Mathematical Modelling*, 2020, 77: 1545–1563.
- [13] 杨周, 杜尊令, 张义民. 某型航空发动机涡轮盘的可靠性灵敏度设计[J]. *东北大学学报(自然科学版)*, 2011, 32(8): 1161–1164.
- YANG Zhou, DU Zunling, ZHANG Yimin. Reliability-based sensitivity design of an aero-engine turbine disk[J]. *Journal of Northeastern University (Natural Science)*, 2011, 32(8): 1161–1164.
- [14] 张飞. 基于有限元法的某涡轮盘的疲劳可靠性灵敏度分析[D]. 沈阳: 东北大学, 2009.
- ZHANG Fei. Sensitivity analysis on fatigue reliability of a turbine disk using finite element method[D]. Shenyang: Northeastern University, 2009.
- [15] 梁振彬, 董聪. 结构可靠性界限计算的包络面方法[J]. *机械科学与技术*, 2018, 37(4): 501–504.
- LIANG Zhenbin, DONG Cong. Envelope surface method for computing structural reliability boundary[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2018, 37(4): 501–504.
- [16] ZHU S P, KESHTEGAR B, EL AMINE BEN SEGHIER M, et al. Hybrid and enhanced PSO: Novel first order reliability method-based hybrid intelligent approaches[J]. *Computer Methods in Applied Mechanics and Engineering*, 2022, 393: 114730.
- [17] ZHONG C T, WANG M F, DANG C, et al. First-order reliability method based on Harris Hawks Optimization for high-dimensional reliability analysis[J]. *Structural and Multidisciplinary Optimization*, 2020, 62(4): 1951–1968.
- [18] 智鹏鹏, 汪忠来, 李永华, 等. 基于RMQGS-APS-Kriging的主动学习结构可靠性分析方法[J]. *机械工程学报*, 2022, 58(16): 420–429.
- ZHI Pengpeng, WANG Zhonglai, LI Yonghua, et al. RMQGS-APS-Kriging-based active learning structural reliability analysis method[J]. *Journal of Mechanical Engineering*, 2022, 58(16): 420–429.
- [19] WANG Z L, ZHAO D Y, GUAN Y. Flexible-constrained time-variant hybrid reliability-based design optimization[J]. *Structural and Multidisciplinary Optimization*, 2023, 66(4): 89.
- [20] ZHANG W, WANG Z L, WANG H Y, et al. AEK-MFIS: An adaptive ensemble of Kriging models based on multi-fidelity simulations and importance sampling for small failure probabilities[J]. *Computer Methods in Applied Mechanics and Engineering*, 2025, 441: 117952.
- [21] ZHAN H, XIAO N C, JI Y. An adaptive parallel learning dependent Kriging model for small failure probability problems[J]. *Reliability Engineering & System Safety*, 2022, 222: 108403.
- [22] SUN Z L, WANG J, LI R, et al. LIF: A new Kriging based learning function and its application to structural reliability analysis[J]. *Reliability Engineering & System Safety*, 2017, 157: 152–165.
- [23] HAN Z H, GÖRTZ S. Alternative co-Kriging method for variable-fidelity surrogate modeling[J]. *AIAA Journal*, 2012, 50(5): 1205–1210.
- [24] SCHÖBI R, SUDRET B, MARELLI S. Rare event estimation using polynomial-chaos Kriging[J]. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, 2017, 3(2): D4016002.
- [25] ZHANG X F, WANG L, SØRENSEN J D. REIF: A novel active-learning function toward adaptive Kriging surrogate models for structural reliability analysis[J]. *Reliability Engineering & System Safety*, 2019, 185: 440–454.
- [26] HONG L X, SHANG B, LI S Z, et al. Portfolio allocation strategy for active learning Kriging-based structural reliability analysis[J]. *Computer Methods in Applied Mechanics and Engineering*, 2023, 412: 116066.
- [27] HUANG D, ALLEN T T, NOTZ W I, et al. Global optimization of stochastic black-box systems via sequential kriging meta-models[J]. *Journal of Global Optimization*, 2012, 54(2): 431–431.
- [28] 李诚, 王仲奇, 童话, 等. 基于Kriging与FPA的薄壁件夹具布局设计[J]. *航空制造技术*, 2020, 63(18): 95–101.
- LI Cheng, WANG Zhongqi, TONG Hua, et al. Design of fixture locating layout for thin-walled part based on Kriging and FPA[J]. *Aeronautical Manufacturing Technology*, 2020, 63(18): 95–101.
- [29] 杨旭锋, 程鑫, 刘泽清. 一种融合交叉熵自适应抽样与ALK模型的可靠性分析方法[J]. *机械工程学报*, 2024, 60(16): 73–82.
- YANG Xufeng, CHENG Xin, LIU Zeqing. Reliability analysis method combining cross-entropy adaptive sampling and ALK model[J]. *Journal of Mechanical Engineering*, 2024, 60(16): 73–82.
- [30] ECHARD B, GAYTON N, LEMAIRE M, et al. A combined Importance Sampling and Kriging reliability method for small failure probabilities with time-demanding numerical models[J]. *Reliability Engineering & System Safety*, 2013, 111: 232–240.
- [31] ZHANG X B, LU Z Z, CHENG K. AK-DS: An adaptive Kriging-based directional sampling method for reliability analysis[J]. *Mechanical Systems and Signal Processing*, 2021, 156: 107610.
- [32] ZHU X M, LU Z Z, YUN W Y. An efficient method for estimating failure probability of the structure with multiple implicit failure domains by combining Meta-IS with IS-AK[J]. *Reliability Engineering & System Safety*, 2020,

193: 106644.

[33] 智鹏鹏, 刘雪琴, 官毅, 等. 基于AMESim-PID-Kriging的通航发动机空燃比控制可靠性分析方法[J/OL]. 中国机械工程, 2024: 1–12. (2024–12–31). <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=ZGJX20241227008&dbname=CJFD&dbcode=CJFQ>.

ZHI Pengpeng, LIU Xueqin, GUAN Yi, et al. Reliability analysis method of air-fuel ratio control of navigation engine based on AMESim-

PID-Kriging[J/OL]. China Industrial Economics, 2024: 1–12. (2024–12–31). <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=ZGJX20241227008&dbname=CJFD&dbcode=CJFQ>.

[34] 李卫, 李连升, 杜尊峰, 等. 基于PC-Kriging模型的发动机活塞低周疲劳可靠性分析[J]. 机械强度, 2025, 47(5): 131–139.

LI Wei, LI Liansheng, DU Zunfeng, et al. Low-cycle fatigue reliability analysis of engine pistons based on PC-Kriging model[J]. Journal of

Mechanical Strength, 2025, 47(5): 131–139.

通信作者: 汪忠来, 教授, 博士, 主要研究方向为可靠性设计、稳健设计、模型验证。

张均富, 教授, 博士, 主要研究方向为可靠性与概率工程设计、高端装备机构学与机电一体化。

Active Learning Kriging-Based Mechanism Reliability Analysis for Aero-Engine

ZHI Pengpeng^{1,2}, LIU Hanru^{1,3}, GUAN Yi², WANG Zhonglai^{1,2}, ZHANG Junfu³

(1. Yangtze Delta Region Institute (Huzhou), University of Electronic Science and Technology of China, Huzhou 313000, China;

2. University of Electronic Science and Technology of China, Chengdu 611731, China;

3. Xihua University, Chengdu 610039, China)

[ABSTRACT] In order to address the problems of high modeling difficulty, poor accuracy and low computational efficiency in the process of reliability analysis of complex aerospace agencies, a method combining data augmentation Latin hypercube sampling (DALHS), adaptive partitioned threshold rejection sampling (APTRS) and active learning Kriging is proposed for agency reliability analysis. First, the data enhancement technique is used to improve Latin hypercube sampling to obtain initial sample points and improve the diversity and representativeness of the initial sample points; second, an adaptive partitioning strategy is used to divide the design space and perform rejection weight sampling within the subspace to improve the local and global search capability of the samples; third, the active learning NU (Normalize U) function is proposed to screen high-quality samples, combined with the quasi-random fractal algorithm (QRFA) to dynamically optimize the Kriging model, and construct the DALHS–APTRS–Kriging model; finally, we use the convergence criterion of the coefficient of variation to realize the efficient calculation of the reliability of the aviation mechanism. The results show that the mechanism reliability of the general aviation piston engine is 0.987, with only 72 model calls, and a calculation error of only 5.7% compared to traditional methods. This indicates that the proposed method can not only obtain high-quality Kriging models with a small number of samples but also improve the efficiency and accuracy of reliability calculation by combining local and global search.

Keywords: Mechanism reliability; Kriging model; Active learning strategy; General aviation piston engine;

Data augmentation Latin hypercube sampling

(责编 青燕)