

基于模块化迁移学习的全机静力试验 高载支反力预估方法

薛小锋^{1,2}, 宋乐^{1,2}, 贺谦^{3,4}, 冯蕴雯^{1,2}, 崔宇航^{1,2}

- 1.西北工业大学 航空学院, 陕西 西安 710072;
2.西北工业大学 飞行器基础布局全国重点实验室, 陕西 西安 710072;
3.中国飞机强度研究所 强度与结构完整性全国重点实验室, 陕西 西安 710068;
4.中国飞机强度研究所 全尺寸飞机结构静力/疲劳航空科技重点实验室, 陕西 西安 710068

摘 要:针对全机静力试验支反力计算忽略加载载荷不确定性和飞机结构变形的问题,提出一种基于模块化迁移学习的全机静力试验高载支反力预估方法。该方法引入模块化迁移学习框架,分模块构建加载载荷不确定性预测模型;利用历史试验数据构建主预测模型,提取静力试验的通用规律;结合现场试验低载数据训练残差修正模型,实现对当前试验工况的适应与误差校正。同时,为考虑结构变形的影响,采用二项式回归方法预估高加载级数下的加载点坐标,进而计算加载力线方向,并结合空间力系平衡方程实现精确的支反力预估。此外,运用某型验证机的全机静力试验案例验证所提方法的预估准确性。与传统刚体假设下的支反力计算结果相比,文中方法显著提升了高载阶段支反力预估的精度,为大规模复杂试验系统中的支反力计算提供了理论和技术支撑。

关 键 词:全机静力试验;模块化迁移学习;载荷不确定性;结构变形;支反力预估
中图分类号:V216 **文献标志码:**A **文章编号:**1000-2758(2026)02-0235-12

全机静力试验是飞机研制过程中不可缺少的一个阶段^[1-2]。全机静力试验是用于模拟飞机在飞行中可能遇到的各种复杂载荷,以验证其在不同工作条件下的结构强度和安全性的一项重要测试^[3-5]。试验通常采用六自由度静定支持约束方式,这种支持方式可以计算出每一级加载载荷对应的约束点支反力^[6]。通过精确计算和预估高加载级数下的约束点支反力,可监测结构受力状态,预警异常载荷引发的损伤,评估进一步开展高载试验的安全性^[7]。支反力的精确预估依赖于加载载荷和加载路径参数的准确输入,然而在实际工程中,受加载系统、结构变形等因素影响,这些关键输入参数普遍存在一定的不确定性。具体而言,加载系统受设备误差、装配误差和控制精度等因素影响,实际加载载荷与理论设计载荷之间存在偏差,导致加载载荷存在不确定

性。与此同时,随着加载级数的提升,飞机结构会发生弹性变形,使得加载点坐标和力线方向偏离初始设定。尤其在高加载级数和大载荷工况下,加载载荷不确定性和结构变形带来的偏差会进一步加剧,影响约束点支反力的预估精度^[8]。此外,受限于全机静力试验周期、成本及安全性要求,试验数据样本数量有限,尤其高载荷阶段的数据获取更加困难,进一步制约了支反力模型的训练与精度验证^[9]。

近年来,针对全机静力试验支反力分析面临的试验参数存在不确定性和试验数据样本数量有限问题,国内外学者进行了大量研究工作。针对试验输入参数存在偏差问题,何志全等^[10]提出了试验基准载荷筛选、载荷转换和加载方案优化等技术,所设计的试验加载载荷能够有效覆盖理论设计载荷。田文朋等^[11]提出了一种优化机翼变形的载荷配平方案,能够显著减少机翼的变形,保证试验考核区域的真实受力情况不受影响,提高了静力试验的加载精度。王彬等^[12]提出了一种基于考核目标等效的试验载荷处理方法,结合灵敏度分析和遗传算法,有效提高

了施加载荷的精度和效率。Shim^[13]提出了一种评估静力结构试验载荷施加精度的方法,通过计算均方根偏差来评估载荷施加误差,分析了加载系统控制对误差的影响。王孟孟等^[14]通过分析撬杠施加载荷的力学模型,推导出载荷修正公式,将理论载荷修正转化为实际施加载荷。Xue 等^[15]分析了支撑系统刚度对载荷分配和支反力计算的影响,提出了基于有限元修正结构变形的支反力计算方法。

针对试验数据样本数量有限问题,Zhang 等^[16]提出一种基于迁移学习和有限元辅助的集成神经网络方法,依靠有限元预训练与参数迁移策略实现结构应力应变的高精度预测。施英杰等^[17]通过融合地面标定试验数据与有限元仿真数据,提出映射式与补偿式2种多级神经网络架构。田阔等^[18]提出了一种面向结构静力试验监测的高精度数字孪生方法,将仿真数据用于预训练梯度提升树模型,并结合少量试验数据采用 Stacking 集成学习构建残差模型,构建高精度应力场预测模型。Tian 等^[19]提出了一种基于迁移学习的变保真代理建模方法,在大量低保真数据上预训练深度神经网络,再利用少量高保真数据微调模型,有效提升模型预测精度。

通过文献调研发现,目前在全机静力试验支反力预估中有两点尚待解决的问题:①针对试验输入参数存在偏差问题的现有研究,多集中于试验方案的优化设计与修正计算方法的改进,虽然已在提升试验精度上取得一定成效,但对于试验参数不确定性本身的定量建模与系统分析仍显不足,亟需构建更加系统全面的不确定性分析模型;②针对试验数据样本数量有限问题的研究,多依赖有限元仿真数据以扩充样本,但全机静力试验系统结构过于复杂,仿真结果存在较大误差,因此亟需有效融合历史试验数据与现场试验数据,充分挖掘已有工程规律。

针对上述调研结果,本文提出了一种基于模块化迁移学习的支反力预估方法。该方法融合历史试验数据与现场低载试验数据,分模块构建加载载荷不确定性预测模型,实现历史试验特征向当前试验的有效迁移,解决小样本条件下载荷不确定性建模困难的问题。同时,采用二项式回归方法对高加载级数下的加载点坐标进行预测,并计算加载力线方向,以充分考虑结构变形带来的影响。在此基础上,综合预测得到的加载载荷不确定性、加载点坐标及力线方向数据,利用空间力系平衡方程实现高精度支反力预估。最后,本文以某型验证机的全机静力

试验为案例,验证所提方法在高载阶段的预测精度和工程适用性。

1 全机静力试验支反力预估框架

约束点支反力作为评估全机静力试验安全性的重要指标,其计算精度影响到评估结果的可靠性和试验过程的安全保障。然而,受限于试验系统的复杂性,结构变形、姿态变化以及加载系统误差等因素导致支反力计算面临多重挑战,尤其在高载试验条件下误差将进一步放大。为此,本文提出一种基于模块化迁移学习的载荷不确定性建模方法,在考虑结构变形影响的基础上,构建支反力预估模型,提高支反力预估的准确性。支反力预估流程如图1所示。




图1 全机静力试验高载支反力预估流程

首先,基于加载载荷服从正态分布的统计特性,本文将实际载荷预测任务分解为均值预测与标准差预测,分别表征载荷的整体趋势与波动特性。为进一步提高预测精度,本文充分考虑试验数据的特性,提出模块化迁移学习策略,分阶段建立以历史试验数据为基础的实际载荷均值和标准差主预测模块、以现场试验低载数据为基础的实际载荷均值和标准

差残差修正模块。历史试验数据能够反映试验系统载荷的共性规律,现场试验的低载数据则揭示了当前试验系统载荷的个性化特征。通过残差修正模块将主模型中学习到的通用规律迁移至当前试验系统中,实现在不重构主模型的前提下,对新试验系统特征的快速适应与精度补偿。通过这种分解和建模策略,可有效提高加载载荷预测模型的准确性和泛化能力。

其次,随着加载级数增加,飞机结构发生弹性变形,导致载荷点和方向偏离初始设定,传统刚体假设下的静力平衡计算方法忽视了这种动态变化。为此,本文利用试验低加载级数下的加载合力点坐标数据,拟合加载合力点坐标随加载级数变化的回归模型,结合加载着力点坐标推算加载力线方向,实现对高加载级数下加载路径变化的建模与修正。

最终,基于所预测的加载载荷、加载点坐标与加载力线方向,结合飞机总质量、约束点坐标及约束力线方向等参数,构建空间力系平衡方程,求解各约束

点的支反力,实现对高载阶段支反力的精确预估。

2 全机静力试验支反力预估方法

2.1 基于模块化迁移学习的加载载荷不确定性预估方法

为更好地表征加载载荷数据的统计特性,本文在分析历史试验数据的基础上,将加载载荷不确定性预测分解为实际载荷均值预测与标准差预测。为进一步提升加载载荷预测的准确性与动态适应性,本文提出一种基于模块化迁移学习的载荷不确定性预估方法。该方法将模型结构划分为 2 层功能模块:①基于历史试验数据训练的主预测模块,用于提取试验系统中的共性规律;②基于当前试验低载数据训练的残差修正模块,用于刻画试验系统个性差异并修正主模型的预测偏差。整个建模流程如图 2 所示。




图 2 加载载荷不确定性预测模型建模流程

1) 建立主预测模型

基于对历史试验数据的分析,本文构建从输入

特征到载荷不确定性响应参数(实际载荷均值和标准差)之间的映射关系,构建主预测模型。根据数

据特征分析结果,选取理论载荷作为输入变量,用于预测实际载荷均值,选取加载级数、理论载荷及其变化量作为输入特征用于预测实际载荷标准差。构建的主预测模型如(1)式所示。

$$\hat{Y}_0 = f_{\text{shared}}(X_1, X_2, \dots, X_i) \quad (1)$$

式中: $\hat{Y}_0$ 为主预测模型预测值; $X_1, X_2, \dots, X_i$ 为各输入特征参数。

最终,基于所预测的加载载荷、加载点坐标与加载力线方向,结合飞机总重、约束点坐标及约束力线方向等参数,构建空间力系平衡方程,求解各约束点的支反力,实现对高载阶段支反力的精确预估。

2) 建立残差修正模型

由于不同机型的静力试验存在实际工况、结构平台、加载方式等方面差异,主模型难以完全覆盖当前试验的个性特征。为提高模型适应性,本文在当前试验的低载数据集上训练残差修正模块,对主模型预测值进行误差补偿。

首先,计算主模型的残差值,残差的表达式为

$$\varepsilon = Y_{\text{ture}} - \hat{Y}_0 \quad (2)$$

式中: Y_{ture} 为试验的实际载荷值; ε 为主模型预测残差。

其次,采用机器学习算法和模型优化算法建立残差修正模型,捕捉当前试验数据的特征。残差修正模型为

$$\Delta Y = f_{\text{task}}(X_1, X_2, \dots, X_i) \quad (3)$$

式中: ΔY 为修正模型预测值; $X_1, X_2, \dots, X_i$ 为各输入特征参数。

最终,模型预测输出为 2 层模块结果的叠加,实现对现场试验数据的适应性迁移,得到最终的载荷不确定性预测模型,即

$$\hat{Y} = \hat{Y}_0 + \Delta Y \quad (4)$$

该模块化迁移学习建模方法提高了预测的准确性与适应性,为高载支反力的准确预估提供可靠的加载载荷输入。

2.1.1 加载载荷均值预测模型

基于历史试验数据分析结果,理论载荷与实际载荷均值呈完全正相关线性关系,故采用最小二乘法(least squares method, LSM)构建实际载荷均值主预测模型。LSM 是一种广泛用于线性回归模型的参数估计方法,其目标是通过最小化实际载荷均值与模型预测值之间的误差平方和,来确定模型的最佳参数,从而获得最优的回归预测模型。模型表达式为

$$y = ax + b \quad (5)$$

式中: y 为实际载荷均值; x 为理论载荷值; a, b 为模型参数。

为提升预测精度并增强模型对具体试验特性的适应能力,采用低载试验数据对历史数据驱动的实际载荷均值主预测模型进行修正。计算预测模型残差,采用支持向量回归(support vector regressor, SVR)建立残差修正模型。SVR 模型是一种基于统计学习理论的非线性回归模型,使用支持向量找到一个最佳的超平面,从而最小化预测误差并保持模型的平滑性。其回归函数形式为

$$f(x) = \sum_{i=1}^N (\alpha_i^* - \alpha_i) K(x_i, x) + c \quad (6)$$

式中: α_i 和 α_i^* 为拉格朗日乘子; $k(x_i, x_j)$ 为核函数, c 为偏置项。

采用粒子群优化算法(particle swarm optimization, PSO)对 SVR 模型参数进行优化。PSO 是一种基于群体协作的随机搜索算法,通过模拟粒子在搜索空间中的移动,寻找 SVR 模型最优参数组合。粒子通过更新速度(下一次迭代中的移动方向和步长)和位置(当前参数),不断调整模型参数,逐渐收敛到全局最优参数。速度和位置的更新迭代公式分别为

$$\begin{cases} v_i^{k+1} = \omega \cdot v_i^k + c_1 \cdot r_1 \cdot (p_{\text{best}_i} - x_i^k) + \\ \quad c_2 \cdot r_2 \cdot (g_{\text{best}_i} - x_i^k) \\ x_i^{k+1} = x_i^k + v_i^{k+1} \end{cases} \quad (7)$$

式中: ω 为惯性权重,控制粒子对先前速度的依赖程度; c_1, c_2 为学习因子,分别控制个体和群体的学习影响; r_1, r_2 为随机数,增加搜索的随机性; p_{best_i} 为粒子的个体最优解; g_{best_i} 为群体最优解。

最终,将基于历史试验数据训练的 LSM 主预测模型与基于当前试验低载数据构建的 SVR 残差修正模型进行叠加,形成基于 LSM-SVR 的实际载荷均值预测模型。

2.1.2 加载载荷标准差预测模型

基于历史试验数据分析结果,实际载荷标准差与理论载荷、加载级数、载荷变化量之间呈非线性耦合关系,故采用随机森林(random forest, RF)构建实际载荷标准差主预测模型,并运用 PSO 优化模型参数。RF 是一种监督式集成学习算法,通过集成多棵决策树的预测结果提升模型的精度与稳定性。每颗决策树的拟合质量通过均方误差(MSE)进行评估,

其表达式为

$$E_{\text{MS,DT}_k} = \frac{1}{k} \sum_{p=1}^k (y_p - \hat{y}_p)^2 \tag{8}$$

式中: y_p 为试验测试的真实值; $\hat{y}_p$ 为模型预测值; k 表示决策树编号。

$$y_{\text{RFR}} = \frac{1}{k} \sum_{p=1}^k \hat{y}_p = \frac{1}{k} \sum_{p=1}^k f(X, S_j^k) \tag{9}$$

式中, y_{RFR} 为前一步骤计算的所有 $\hat{y}_p$ 的平均值。

为提升预测精度并增强模型对具体试验特性的适应能力,采用低载试验数据对历史数据驱动的实际载荷标准差主预测模型进行修正。计算预测模型残差,采用 SVR 建立残差修正模型,并运用 PSO 优化 SVR 修正模型参数。

最终,将基于历史试验数据训练的 RF 主预测模型与基于当前试验低载数据构建的 SVR 残差修正模型进行叠加,形成基于 RF-SVR 的实际载荷标准差预测模型。

2.2 考虑结构变形的支反力计算模型

在高加载级数下,由于飞机结构发生变形,加载合力点坐标和加载力线方向也会发生变化。因此,为了实现高载支反力的精确预估,还需要对高加载级数下加载合力点坐标和加载力线方向进行合理预估,以考虑结构变形的影响。全机静力试验系统的加载原理如图 3 所示。




图 3 加载原理图

根据工程经验,加载合力点在随加载级数增加的过程中,其垂向与展向位移通常表现出近似线性变化规律,而航向位移整体保持基本稳定^[20]。因此,可利用试验低加载级数下的加载合力点坐标数据,采用最小二乘法建立加载合力点坐标的二阶多项式回归模型,预测高加载级数下的加载合力点坐

标。因为着力点固定在试验台的承载结构上,可视作为固定点,所以加载力线的方向均可通过加载合力点坐标和着力点坐标计算得到,即

$$\begin{bmatrix} \cos\alpha_{jn} \\ \cos\beta_{jn} \\ \cos\gamma_{jn} \end{bmatrix} = \begin{bmatrix} \frac{x_{jo} - x_{jn}}{\sqrt{(x_{jo} - x_{jn})^2 + (y_{jo} - y_{jn})^2 + (z_{jo} - z_{jn})^2}} \\ \frac{y_{jo} - y_{jn}}{\sqrt{(x_{jo} - x_{jn})^2 + (y_{jo} - y_{jn})^2 + (z_{jo} - z_{jn})^2}} \\ \frac{z_{jo} - z_{jn}}{\sqrt{(x_{jo} - x_{jn})^2 + (y_{jo} - y_{jn})^2 + (z_{jo} - z_{jn})^2}} \end{bmatrix} \tag{10}$$

式中: x_{jo}, y_{jo}, z_{jo} 为加载合力点 j 对应的加载着力点坐标; x_{jn}, y_{jn}, z_{jn} 为加载合力点 j 在第 n 级加载级数下的坐标; $\cos\alpha_{jn}, \cos\beta_{jn}, \cos\gamma_{jn}$ 分别为加载点 j 在第 n 级加载级数下的加载力线方向和 x, y, z 轴方向的夹角余弦值。

基于上述流程,本文利用试验中低加载级数下测得的加载合力点坐标数据,构建坐标预测模型,结合加载着力点的已知坐标计算加载力线方向,从而考虑结构变形的影响,实现对高加载级数下加载合力点坐标及其力线方向的有效预估。由于全机静力试验系统通常采用六自由度静定支持方案,约束点在试验过程中视为静定支撑,其空间坐标及力线方向可视为不变,故不再对其进行预测建模。

在此基础上,结合加载载荷、加载合力点坐标及其力线方向的预测结果,以及飞机总质量、约束点坐标和约束力线方向等参数,根据空间力系平衡原理,构建支反力计算模型^[21],即

$$\mathbf{A}_n \mathbf{X}_n = \mathbf{B}_n \quad n = 1, 2, \dots, D \tag{11}$$

式中: $\mathbf{A}_n$ 为约束点坐标矩阵; $\mathbf{B}_n$ 为试验时的载荷合力矩阵; $\mathbf{X}_n$ 为第 n 级载荷级数下对应的约束点支反力矩阵; n 表示第 n 级载荷级数; D 为总加载级数。

3 案例分析

3.1 试验数据处理与分析

本文数据来源于中国飞机结构强度研究所采集的 6 组不同机型的全机静力试验在保载状态下的载荷数据及结构变形数据,选取其中 5 组作为历史试

验数据构建预测模型,剩余的 1 组作为案例的试验数据用于构建修正模型,以检验本文所提方法的有效性和合理性。

首先,采用四分位距法对试验数据进行预处理。根据预处理后的历史试验载荷数据,绘制不同加载级数下不同加载点的载荷数据分布图,并采用 K-S 检验(Kolmogorov-Smirnov test)确定载荷数据分布类型。图 4 展示了某试验段加载点在不同加载级数下数据分布及 K-S 检验结果。结果表明,载荷数据符合正态分布,且在不同加载工况下,载荷的分布参数存在一定差异。因此,实际载荷不确定性可以采用实际载荷的均值和标准差来表征。

根据预处理后的历史试验数据,分别采用图示

法和皮尔森等级相关系数法分析载荷不确定性参数(实际载荷均值 μ 和实际载荷标准差 σ)与加载级数 n 、理论载荷 F_i 以及载荷变化量 ΔF 之间的相关性,如图 5 所示。




图 4 载荷数据分布




图 5 相关性分析

通过相关性分析可得,理论载荷与实际载荷均值呈完全正相关线性关系;理论载荷、载荷变化量与实际载荷标准差之间呈强正相关关系,加载级数与实际载荷标准差之间存在弱等强度的正相关关系。因此,选用理论载荷预测实际载荷均值并计算其模型误差;选用理论载荷、载荷变化量和加载级数预测实际载荷标准差并计算其模型误差。

3.2 建模与高载支反力评估

3.2.1 确定输入文件

根据本案例的某全机静力试验,共设 12 个加载合力点 C_i 、对应 12 个加载着力点 K_i 和 6 个静定约束点 X_i 支持,试验加载示意图和约束示意图分别如图 6~7 所示。




图 6 试验加载示意图




图 7 试验约束示意图

进行支反力计算所需的输入文件包括:试验约束点的坐标和载荷谱文件,分别如表 1~4 所示。

束点的坐标及方向、加载合力点的坐标、加载着力点

表 1 100%加载级数下的约束点坐标及方向参数

约束点	航向夹角 $\alpha/(^{\circ})$	垂向夹角 $\beta/(^{\circ})$	展向夹角 $\gamma/(^{\circ})$	航向坐标 x	垂向坐标 y	展向坐标 z
前主起垂向 X_1	90	180	90	2 000	-2 500	0
左主起垂向 X_2	90	180	90	6 500	-1 000	1 500
右主起垂向 X_3	90	180	90	6 500	-1 000	-1 500
前主起航向 X_4	0	90	90	2 000	-1 500	0
前主起侧向 X_5	90	90	180	2 000	-1 500	0
左主起侧向 X_6	90	90	0	6 500	-1 000	1 500

表 2 100%加载级数下的加载合力点坐标参数

加载合力点	航向坐标 x	垂向坐标 y	展向坐标 z	加载合力点	航向坐标 x	垂向坐标 y	展向坐标 z
C_1	2 000	1 000	0	C_7	2 152.28	6 500.58	-992.09
C_2	3 624.10	6 507.80	7 272.25	C_8	-2 000	2 500	-1 000
C_3	2 753.62	6 504.23	4 188.89	C_9	-2 000	11 000	0
C_4	2 147.85	6 500.51	991.75	C_{10}	-2 000	12 500	0
C_5	3 589.26	6 508.50	-7 275.15	C_{11}	2 000	2 000	0
C_6	2 740.47	6 504.07	-4 190.78	C_{12}	2 000	14 000	0

表 3 100%加载级数下的加载着力点坐标参数

着力点	航向坐标 x	垂向坐标 y	展向坐标 z	着力点	航向坐标 x	垂向坐标 y	展向坐标 z
K_1	2 544	6 000	2 651	K_7	6 500	4 500	-1 000
K_2	6 500	4 500	7 600	K_8	2 500	-4 000	-1 000
K_3	6 500	4 500	4 300	K_9	10 220	-4 000	-1 276
K_4	6 500	4 500	1 000	K_{10}	12 500	-4 000	0
K_5	6 500	4 500	-7 600	K_{11}	2 000	6 000	0
K_6	6 500	4 500	-4 300	K_{12}	14 000	6 000	0

表 4 100%加载级数下的载荷谱

加载合力点	载荷/N	加载合力点	载荷/N
C_1	10 000	C_7	20 000
C_2	10 000	C_8	54 000
C_3	15 000	C_9	20 000
C_4	20 000	C_{10}	36 000
C_5	10 000	C_{11}	40 000
C_6	15 000	C_{12}	20 000

表 5 140%加载级数下各加载实际
载荷均值和标准差预测结果

点号	均值	标准差	点号	均值	标准差
C_1	13 987.09	6.85	C_7	27 983.33	12.95
C_2	13 982.15	6.51	C_8	75 564.14	12.03
C_3	2 0991.08	7.39	C_9	29 991.42	9.34
C_4	2 7972.97	10.95	C_{10}	50 386.46	8.19
C_5	13 988.05	8.73	C_{11}	39 989.50	11.25
C_6	20 985.81	9.38	C_{12}	19 994.34	13.48

3.2.2 载荷不确定性预估

基于模块化迁移学习的建模方案,根据试验加载过程中高加载级数下各加载点对应的理论加载级数、理论载荷和理论载荷变形量数据,预测各加载点在高加载级数下的实际载荷均值和标准差,以 140%加载级数为例,预测结果如表 5 所示。

3.2.3 加载合力点坐标预估

根据工程实际可知,全机静力试验加载过程中,变形结构加载合力点航向坐标保持不变,其高载工况下展向和垂向坐标可通过采集低载试验阶段各加载合力点坐标数据,建立加载合力点展向和垂向坐

标随加载级数变化模型进行预估。本文采用最小二乘法建立加载合力点展向和垂向坐标预测模型,实现高加载级数下加载点空间位置的合理预估。以加载合力点 C_2 为例,基于低载阶段的实测数据分别构建其垂向与展向方向的坐标预测模型(见图 8);由于航向坐标在加载过程中变化极小,近似保持恒定,因此未进行单独建模。具体表达式为

$$\begin{cases} y_{C_2}(n) = 0.000\,248\,9n^2 - 0.286\,1n + 7\,299.48 \\ z_{C_2}(n) = -0.006\,442n^2 + 6.678\,0n + 3\,007.42 \end{cases}$$

(12)

式中: y_{C_2} 为加载点 C_2 在第 n 级加载级数下加载合力点的垂向坐标; z_{C_2} 为加载点 C_2 在第 n 级加载级数下加载合力点的展向坐标。





图 8 加载点 C_2 坐标拟合数据

利用上述加载合力点坐标预测模型,对高加载级数下各加载点的合力点坐标进行预估;进一步地,结合固定的加载着力点坐标,计算获得相应加载力线在空间中的方向余弦,从而为支反力计算提供精确的坐标和力线输入参数。

3.2.4 高载支反力预估

基于建立的载荷不确定性预估模型和加载点坐标预估模型,预估高载试验支反力。根据试验输入文件,结合预测得到的实际载荷均值和标准差数据、加载合力点坐标和加载力线方向数据,采用蒙特卡洛仿真方法预估高载试验的支反力。以 140% 加载级数为例,支反力预估结果如图 9 所示。




图 9 140% 加载级数下支反力预估结果

4 方法验证

4.1 载荷不确定性模型验证

为了验证本文所提建模方法的合理性,分别采用多种机器学习方法和模型优化算法建立实际载荷均值和标准差预测模型及其修正模型,以平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)和拟合优度(R-square, R²)作为评价指标评估各模型性能,即

$$\left\{\begin{aligned} E_{\text{MA}} &= \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \\ E_{\text{RMS}} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \\ R^2 &= 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \end{aligned}\right. \quad (13)$$

式中: y_i 为实际值; $\hat{y}_i$ 为预测值; $\bar{y}$ 为实际值的均值; n 为样本数。

1) 实际载荷均值预测模型验证

由于基于历史试验数据的 LSM 实际载荷均值预测模型拟合效果较好,因此仅对比本文所提方法

LSM-SVR 与传统 LSM 实际载荷均值预测模型的预测性能,模型性能评价指标如表 6 所示。结果表明,本文所提出的基于 LSM-SVR 模型的实际载荷均值预测精度更高。

表 6 实际载荷均值预测模型性能指标对比

模型	E_{MA}	E_{RMS}	R^2
LSM	4.725 7	8.477 9	0.999 8
LSM-SVR	4.685 3	8.428 2	0.999 9

2) 实际载荷标准差预测模型验证

基于历史试验数据,分别采用 BP 神经网络(back propagation neural network, BPNN)、支持向量回归(support vector regressor, SVR)、随机森林(random forest, RF)和克里金法(Kriging)构建传统的载荷标准差预测模型,并采用粒子群优化算法(particle swarm optimization, PSO)优化预测模型参数。为验证本文所提出的模块化迁移学习建模方法的有效性,进一步基于历史试验数据与现场试验低载数据,构建 BP-SVR、SVR-SVR、RF-SVR 和 Kriging-SVR 等多种组合形式的实际载荷标准差预测模型,并同样采用 PSO 进行参数调优。各模型预测性能的评估对比结果如图 10 所示。




图 10 不同实际载荷标准差模型性能对比

根据不同实际载荷标准差预测模型的性能对比结果可知,基于本文提出模块化迁移学习框架的 RF-SVR、BP-SVR、SVR-SVR、Kriging-SVR 预测模型与传统实际载荷标准差预测模型相比,均能明显提高模型的预测精度。在所有方法中,RF-SVR 模型表现最佳,与最差的 Kriging 模型相比,平均绝对误差降低了 16.9%,均方根误差降低了 19.0%,拟合优度提高了 5.9%。因此,基于 RF-SVR 的实际载荷标

准差预测模型具有较高的预测精度和较强的稳定性。

4.2 高载支反力预估结果验证

为验证本文提出的全机静力试验支反力预估方法的合理性,在不考虑载荷不确定性和结构变形的情况下,采用传统方法进行支反力计算。将本文所提的支反力预估结果、传统支反力计算结果与试验真实测量值进行对比分析,以 140%加载级数为例,

对比结果如图 11 所示。




图 11 支反力计算结果对比

支反力计算结果的对比分析表明,相比传统计算方法,本文提出的支反力预估方法具有更高的计算精度。以 140% 加载级数下的支反力数据为例,试验测得的各支反力均落在所预测的 95% 置信区间内。本文所提出的考虑载荷不确定性和结构变形的全机静力试验支反力预估方法,充分考虑载荷不确定性的影响,通过模块化迁移学习建立载荷不确定性预测模型;同时,考虑结构变形的影响,构建了加载合力点坐标和加载力线方向模型,获得更为精确的支反力预估结果。

5 结 论

1) 本文提出了一种基于模块化迁移学习的高载支反力预估方法。该方法通过分阶段建模融合历史试验数据与现场低载数据,构建具备良好泛化能力与适应性的载荷预测模型,同时结合结构变形建

模与空间力系平衡方程,实现高载工况下支反力的精确求解。通过某型原型机的全机静力试验验证,结果显示本方法在支反力预测精度方面显著优于传统刚体计算模型。

2) 结果分析表明,在实际载荷标准差预测建模方面,基于模块化迁移学习的 RF-SVR 模型性能最优,与其他模型相比,RF-SVR 模型的平均绝对误差最高降低了 16.9%,均方根误差最高降低了 19.0%,拟合优度最高提高了 5.9%。此外,与传统计算方法相比,所提支反力预估方法的计算精度更高。在 140% 加载级数下,实验测量值均落在所预测的 95% 置信区间内。

本文提出的基于模块化迁移学习的全机静力试验支反力预估方法不仅为全机静力试验支反力计算提供技术支持,也为其他复杂试验系统支反力分析提供参考价值。

参考文献:

- [1] 中国民用航空局. 运输类飞机适航标准: CCAR-25-R3[S]. 北京: 中国民用航空局, 2011.
- [2] MOHAGHEGH M. Validation and certification of aircraft structures[C]// AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics & Materials Conference, 2013.
- [3] 中国飞机强度研究所. 航空结构强度技术[M]. 北京: 航空工业出版社, 2013.

- Aircraft Strength Research Institute of China. Aviation structural strength technology[M]. Beijing: Aviation Industry Press, 2013. (in Chinese)
- [4] SHIM J, LEE S, AHN S. KC-100 full-scale static test system[J]. Aerospace Engineering and Technology, 2012, 11(1): 7-18.
- [5] SHIM J Y, AHN S. Full-scale static test of small composite aircraft[J]. Advanced Composite Materials, 2014, 23(1): 85-98.
- [6] 曹景涛. 六自由度静定支持与约束技术在飞机载荷校准试验中的应用[J]. 应用力学学报, 2014, 31(3): 317-321.
- CAO Jingtao. The application of six degree of freedom statically determinate support and restraint technology in aircraft load calibration test[J]. Chinese Journal of Applied Mechanics, 2014, 31(3): 317-321. (in Chinese)
- [7] LOVEJOY A E, JEGLEY D C, HILBURGER M W, et al. Lessons learned from large-scale aerospace structural testing[J]. AIAA Journal, 2023, 61(11): 11.
- [8] 郑建军, 唐吉运, 王彬文. C919 飞机全机静力试验技术[J]. 航空学报, 2019, 40(1): 210-221.
- ZHENG Jianjun, TANG Jiyun, WANG Binwen. Static test technology for C919 full-scale aircraft structure[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(1): 210-221. (in Chinese)
- [9] 王育鹏, 裴连杰, 李秋龙, 等. 新一代战斗机全机地面强度试验技术[J]. 航空学报, 2020, 41(6): 342-354.
- WANG Yupeng, PEI Lianjie, LI Qiulong, et al. Full-scale aircraft strength test technology of next generation fighter[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(6): 342-354. (in Chinese)
- [10] 何志全, 刘杨, 李泽江. 大型民用飞机缝翼全尺寸静力试验载荷设计[J]. 航空学报, 2019, 40(2): 88-94.
- HE Zhiquan, LIU Yang, LI Zejiang. Load design for full scale static test of slat on large civil aircraft[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(2): 88-94. (in Chinese)
- [11] 田文朋, 夏峰, 宋鹏飞, 等. 水陆两栖飞机静力试验优化机翼变形的载荷配平[J]. 航空学报, 2020, 41(11): 358-366.
- TIAN Wenpeng, XIA Feng, SONG Pengfei, et al. Load balancing for wing deformation optimization in amphibious aircraft static test[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(11): 358-366. (in Chinese)
- [12] 王彬, 郑建军, 刘玮, 等. 基于考核目标等效的试验载荷处理方法[J]. 航空学报, 2023, 44(17): 176-186.
- WANG Bin, ZHENG Jianjun, LIU Wei, et al. Testing load transacting method based on assessment target equivalent[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(17): 176-186. (in Chinese)
- [13] SHIM J. Evaluating the Accuracy of load application for static structural testing of aerospace flight vehicles[J]. International Journal of Aeronautical and Space Sciences, 2020, 21(1): 133-152.
- [14] 王孟孟, 刘冰, 王高利. 大型飞机起落架载荷修正方法研究[J]. 应用力学学报, 2021, 38(2): 708-714.
- WANG Mengmeng, LIU Bing, WANG Gaoli. Research on load modification method of large aircraft landing gear[J]. Chinese Journal of Applied Mechanics, 2021, 38(2): 708-714. (in Chinese)
- [15] XUE Caijun, MEI Rong, CHANG Qingchun. Wing support stiffness simulation and reliability evaluation in the engine-pylon static test[J]. Journal of Aircraft, 2019, 56(4): 1715-1721.
- [16] ZHANG Ning, XU Kunpeng, YIN Yuzhen, et al. Transfer learning-enhanced finite element-integrated neural networks[J]. International Journal of Mechanical Sciences, 2025, 290: 110075.
- [17] 施英杰, 刘斌超, 鲁嵩嵩, 等. 融合“试验-仿真”标定数据的机翼应变载荷关系神经网络模型[J]. 航空学报, 2025, 46(19): 106-117.
- SHI Yingjie, LIU Binchao, LU Songsong, et al. Neural network model for wing strain-load relationship by fusing real data and virtual data[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(19): 106-117. (in Chinese)
- [18] 田阔, 孙志勇, 李增聪. 面向结构静力试验监测的高精度数字孪生方法[J]. 航空学报, 2024, 45(7): 288-299.
- TIAN Kuo, SUN Zhiyong, LI Zengcong. High-precision digital twin method for structural static test monitoring[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(7): 288-299. (in Chinese)
- [19] TIAN Kuo, LI Zengcong, ZHANG Jiaxin, et al. Transfer learning based variable-fidelity surrogate model for shell buckling prediction[J]. Composite Structures, 2021, 273: 114285.
- [20] 郭琼, 夏峰, 刘冰, 等. 全尺寸飞机结构静力试验约束点载荷计算及应用[J]. 科学技术与工程, 2020, 20(19): 7934-7940.
- GUO Qiong, XIA Feng, LIU Bing, et al. Calculation and application of restraint load in full-scale aircraft static test[J]. Science Technology and Engineering, 2020, 20(19): 7934-7940. (in Chinese)
- [21] 任鹏, 李涛. 全机结构试验约束点载荷计算方法研究[J]. 工程与试验, 2020, 60(4): 29-30.

REN Peng, LI Tao. Research on load calculation method of constrained point in full-size aircraft structure test[J]. Engineering & Test, 2020, 60(4): 29-30. (in Chinese)

A modular transfer learning-based method for predicting high-load support reactions in full-scale static tests

XUE Xiaofeng^{1,2}, SONG Le^{1,2}, HE Qian^{3,4}, FENG Yunwen^{1,2}, CUI Yuhang^{1,2}

(1.School of Aeronautics, Northwestern Polytechnical University, Xi'an 710072, China;
2.National Key Laboratory of Aircraft Configuration Design, Northwestern Polytechnical University, Xi'an 710072, China;
3.National Key Laboratory of Strength and Structural Integrity, Aircraft Strength Research Institute, Xi'an 710068, China;
4.Key Laboratory of Aviation Science and Technology on Full Scale Aircraft Structure Static and Fatigue Strength,
Aircraft Strength Research Institute, Xi'an 710068, China)

Abstract: To address the problem of neglecting load uncertainties and structural deformation in conventional support reaction calculations for full-scale aircraft static tests, this paper proposes a novel approach based on modular transfer learning for accurately predicting high-load support reactions. The proposed method introduces a modular transfer learning framework in which separate models are developed to account for loading uncertainties. A primary prediction model is first established using historical test data to extract general static testing characteristics. Subsequently, a residual correction model trained with low-load data from the current test condition is integrated, enabling adaptation and correction of prediction errors specific to the present testing scenario. Additionally, to explicitly consider structural deformation effects, a binomial regression technique is employed to estimate loading-point coordinates at high-load levels, facilitating accurate determination of loading directions. By combining these coordinates with spatial force equilibrium equations, precise prediction of support reactions is achieved. The effectiveness and accuracy of the proposed method are validated through a full-scale static test case involving a representative verification aircraft. Comparative analyses demonstrate that, compared with traditional rigid-body assumptions, the developed method significantly enhances the prediction accuracy for high-load stages, thereby providing robust theoretical and technical support for support reaction estimation in large-scale and complex testing environments.

Keywords: full-scale static test; modular transfer learning; load uncertainty; structural deformation; support reaction prediction

引用格式: 薛小锋, 宋乐, 贺谦, 等. 基于模块化迁移学习的全机静力试验高载支反力预估方法[J]. 西北工业大学学报, 2026, 44(2): 235-246.

XUE Xiaofeng, SONG Le, HE Qian, et al. A modular transfer learning-based method for predicting high-load support reactions in full-scale static tests[J]. Journal of Northwestern Polytechnical University, 2026, 44(2): 235-246. (in Chinese)