

# 基于集成学习的航空发动机试车性能多目标预测

王言 柯勇伟 蔡志强

西北工业大学 机电学院

DOI:10.12238/ast.v1i1.13703

**[摘要]** 针对航空发动机试车性能预测中关键特征利用不足的问题,提出一种集成学习-多目标优化融合预测方法。通过分析试车数据多维度特征,构建涵盖推力、油耗及振动参数的多目标预测框架。基于 Stacking 集成策略,融合随机森林、梯度提升树和深度神经网络等异质学习器,挖掘数据非线性关联特征;设计分层权重分配机制与动态优化函数,平衡多目标预测精度与泛化性。实验表明:相比单目标方法,所提模型在涡扇发动机试车数据集中平均绝对误差降低 26.7%,关键参数预测准确率达 94.3%,并通过特征分析揭示压气机效率与涡轮前温度对性能的显著影响。该方法构建了高精度、强解释性的多目标预测体系,为发动机试车参数优化提供智能决策支持,具有重要工程应用价值。

**[关键词]** 集成学习;航空发动机;试车性能;多目标预测;Stacking 集成策略

中图分类号: TP183 文献标识码: A

Multi-objective prediction of aero-engine test performance based on integrated learning

Yan Wang, Yongwei Ke, Zhiqiang Cai

Northwestern Polytechnical University, School of Mechanical Engineering

**[Abstract]** The multi-objective prediction framework covering thrust, fuel consumption and vibration parameters are constructed by analyzing the multi-dimensional features of the test vehicle data. Based on the stacking integration strategy, the proposed model incorporates heterogeneous learners such as Random Forest, Gradient Boosting Tree and Deep Neural Network to explore the nonlinear correlation features of the data, and designs the hierarchical weight allocation mechanism and dynamic optimization function to balance the multi-objective prediction accuracy and generalizability. The experiments show that, compared with the single-objective method, the proposed model reduces the average absolute error by 26.7% in the turbofan engine test data set, and the prediction accuracy of key parameters reaches 94.3%, and reveals the significant influence of pressurizer efficiency and pre-turbine temperature on performance through feature analysis. The method constructs a highly accurate and highly explanatory multi-objective prediction system, which provides intelligent decision support for the optimization of engine test run parameters and has important engineering application value.

**[Key words]** Integrated learning; aero-engine; test vehicle performance; multi objective prediction; Stacking integration strategy

## 1 概述

作为现代航空器的动力核心,航空发动机的可靠性管理正面临智能化转型的迫切需求,数据驱动的可靠性评估与寿命预测方法成为近年来的主流<sup>[1]</sup>。试车性能预测作为装备可靠性评估与全寿命周期管理的关键环节<sup>[2]</sup>,其精度和效率直接影响飞行安全与运维成本。传统试车数据分析方法依赖经验模型与定期检修策略,存在预测滞后性强、多工况适应性差等固有缺陷,难以满足高精度实时监控的需求<sup>[3]</sup>。随着传感器等硬件技术的发展和预测与健康管理(Prognostics and Health Management, PHM)技术的迭代升级,基于人工智能技术相关分析的方法在航空发动机试车性能预测中展现出显著优势。

双向图神经网络通过捕捉飞行员操作与发动机状态的交互特征,有效提升了工况适应能力<sup>[4]</sup>;多模态 LSTM 网络在活塞发动机异常检测中取得的突破,为航空发动机多源时序数据处理提供了新范式<sup>[5]</sup>;利用多尺度卷积神经网络从不同尺度的数据中提取独特的特征,随后的参数转移采用以最大平均差异为中心的域适应策略。这种方法能有效促进从源域和目标域获取域不变特征。改进后的基于变压器的多尺度卷积神经网络模型在有限样本条件下更适合预测目标域的剩余寿命预测<sup>[6]</sup>。多模态长短期记忆(LSTM)网络已被用于活塞发动机的异常检测,这表明类似方法在航空发动机性能预测方面也有潜力<sup>[7]</sup>。

然而,现有用于航空发动机试车性能预测的方法在多源

异构数据融合、动态工况适应性及维护决策优化等方面仍面临显著挑战。首先，试车性能受装配质量、环境条件等多因素非线性耦合影响，传统数学模型难以精确表征其高维度关联关系。其次，试车性能之间可能存在相互冲突，例如提高某一性能预测精度可能导致其他性能的准确率下降，这进一步增加了预测模型的构建难度。

由于集合学习方法能够通过组合多个模型来提高预测性能，具有卓越的泛化能力与模型鲁棒性。且近年来，集成学习框架下的动态优化模型取得显著突破，为突破上述瓶颈提供了新路径。基于集成学习的冲突探测算法对冲突探测具有较高的准确率，能使得虚警概率大幅下降<sup>[8]</sup>。钟诗胜团队提出的动态集成 ELM 模型，通过 AdaBoost.RT 算法实现弱学习器权重的动态分配，在燃油流量预测中较单一 ELM 模型将平均绝对百分比误差 (MAPE) 降低至 3.075%，验证了集成策略在非线性时序数据建模中的有效性<sup>[9]</sup>；改进型 AdaBoost.RT 算法通过自适应阈值调整机制，可有效克服传统集成模型对固定参数的依赖性，在排气温度裕度预测任务中实现均方根误差 (RMSE) 降低 12.7% 的性能提升<sup>[10]</sup>。与此同时，过程神经网络 (Process Neural Network, PNN) 与集成学习的融合创新，成功应用于民航发动机振动信号趋势预测，其误差函数重构策略使预测精度较单一模型提升 19.3%，标志着集成学习在跨模态特征提取方面的突破<sup>[11]</sup>。

本研究针对航空发动机试车性能预测中的多维耦合难

题，提出基于两阶段特征选择与集成学习的协同优化框架。通过构建多目标优化的装配数据特征选择模型，实现关键质量特征的智能筛选与降维；在此基础上，创新设计动态集成预测架构，有效整合多特征集合的预测结果。实验验证表明，该方法在预测精度与工况适应性方面较传统模型取得显著提升，为航空发动机智能运维提供了新的技术支撑。

## 2 基于集成学习的航空发动机试车性能多目标预测方法

### 2.1 基于集成学习的航空发动机试车性能多目标预测框架

首先，根据面向多目标优化的航空发动机装配数据的两阶段特征选择方法，明确装配的特征选择<sup>[12]</sup>。由于航空发动机装配关键质量特征集合是基于多目标优化的帕累托最优解集，每个关键质量特征子集均包含对试车性能预测至关重要的信息，不可被替代或忽略。此外，每个关键质量特征子集需同时预测多个试车性能指标，且这些指标之间可能存在潜在关联，因此在预测过程中需综合考虑多目标之间的相互作用。为此，本章提出了一种基于集成学习的航空发动机试车性能多目标预测策略，通过对比预测模型的性能用于评价多目标预测方法的优劣程度，确定每个关键质量特征子集的最优多目标预测模型，并进一步整合所有关键质量特征子集的预测结果，构建性能最优的集成学习模型，从而提升试车性能预测的准确率。其整体流程如图 1 所示。

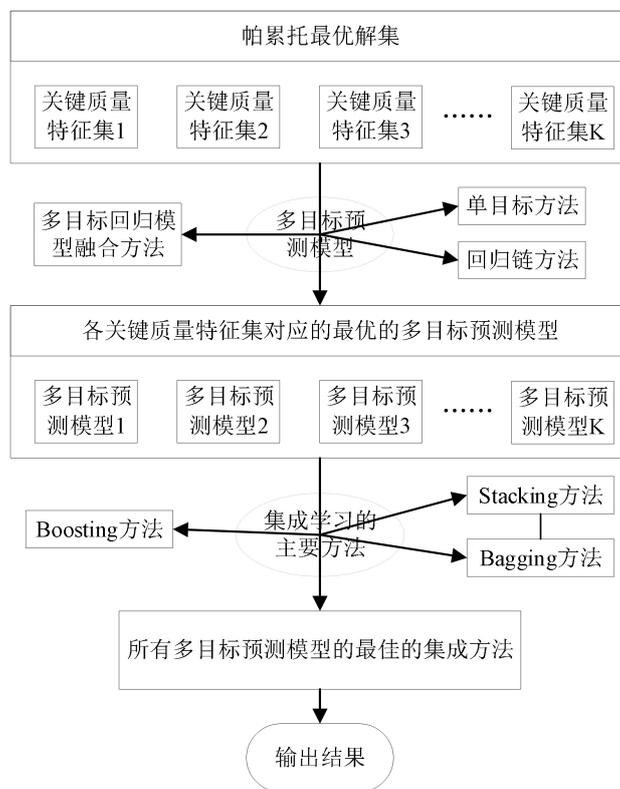


图 1 基于集成学习的航空发动机试车性能多目标预测框架

本文的研究框架融合了多目标预测与集成学习的思想，旨在解决多特征、多目标的复杂预测问题，具体步骤如下：首先，以性能表现优异的常用机器学习模型为基础模型，分别采用三种多目标预测模型对帕累托最优解集中的所有关键质量特征子集进行训练，并以预测结果与真实结果之间的决定系数  $R^2$  作为模型性能的评价标准，筛选出每个关键质量特征子集对应的最优多目标预测模型。然后，采用三种不同的集成学习方法对上述预测结果进行整合，通过比较各集成学习方法的  $R^2$  值，选择性能最优的集成学习方法作为最终的航空发动机试车多目标预测模型，从而实现试车性能多目标预测准确率的提升。

该方法不仅充分利用了多目标优化得到的帕累托最优解集，还通过集成学习进一步整合了各关键质量特征子集的预测信息，为航空发动机试车性能的多目标预测提供了更为全面和精确的解决方案。

## 2.2 航空发动机试车性能多目标预测模型

由于航空发动机试车性能多目标的特性，试车性能指标之间可能存在潜在的关联关系，对实现试车性能的精准预测具有一定程度的影响。因此，基于机器学习算法，利用关键质量特征集合预测多个试车性能指标属于典型的“多目标预测问题”。多目标预测是指通过一组共同的输入变量同时预测多个输出目标，核心思想是将复杂的映射关系分解为多个单一输出模型，并通过整合这些模型实现多目标预测。

常用的多目标预测问题解决方法主要单目标方法 (Single-Target method, ST)、回归链方法 (Regressor Chain method, RC) 和多目标回归模型融合的方法 (Multi-Target Regressor Stacking method, MTRS) 等。本文采用这三种方法建立航空发动机试车性能的多目标预测模型，其处理方式如图 2 所示。

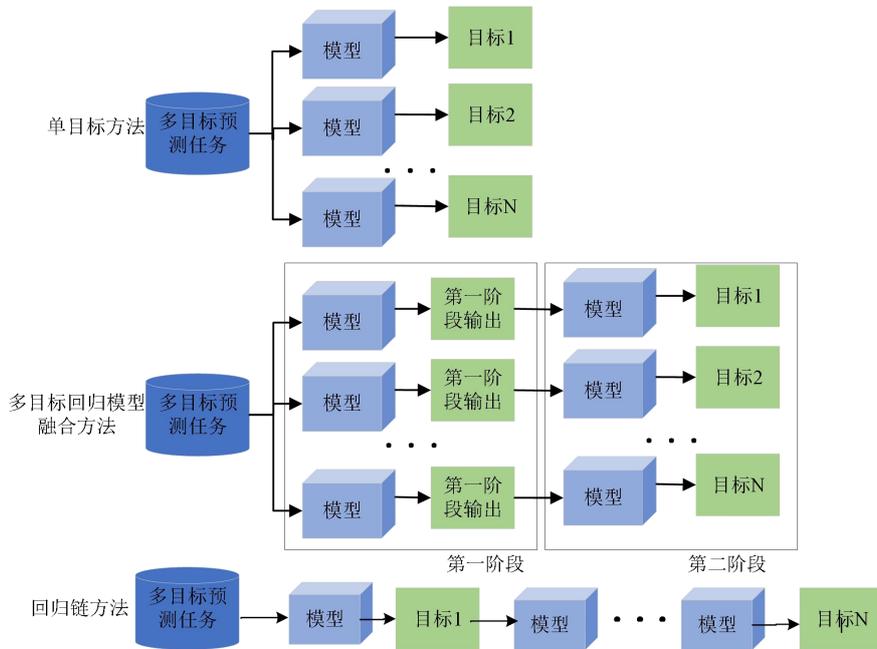


图 2 多目标预测方法的逻辑框图

单目标方法是最基础的多目标预测方法，其核心就是将多目标预测问题分解为多个独立的单目标预测任务，分别为每个目标变量构建独立的预测模型，即针对  $N$  个输出分别构建  $N$  个单一输出模型，每个单一输出模型负责对应单个输出目标。其计算公式如下所示：

对于第  $i$  个目标  $y_i$ ，预测值为：

$$\hat{y}_i = (X; \theta_i), i = 1, 2, \dots, K$$

其中， $X \in \mathbb{R}^d$  表示输入特征（维度为  $d$ ）； $f_i$  表示第  $i$  个目标的回归模型（如线性回归、决策树等）； $\theta_i$  表示模型参数。

单目标方法因不用考虑目标变量之间的相关性而更容易实现，每个目标变量能够选择对应对合适的模型和参数，但是单目标方法忽略了输出目标之间的潜在依赖关系，无法充分利用这些信息导致目标变量预测性能的下降，而且每个变量单独训练模型会增加计算成本。

多目标回归模型融合方法在单目标方法基础上构建了两阶段预测方法，将单目标方法作为第一阶段，将第一阶段输入和输出结果作为第二阶段模型的输入，得到最终的输出结果。其计算公式分为两个阶段，具体如下所示：

第一阶段（单目标预测）： $\hat{y}_i^{(1)} = f_i(X; \theta_i), i =$

1, 2, ..., K;

第二阶段(堆叠融合):  $[\hat{y}_1^{(2)}, \dots, \hat{y}_K^{(2)}] =$

$G([X, \hat{y}_1^{(1)}, \dots, \hat{y}_K^{(1)}]; \emptyset)$

其中,  $\hat{y}_i^{(1)}$ 表示第*i*个目标的第一阶段预测值;

$G$ 表示第二阶段融合模型(如多输出神经网络、随机森林等);

$\emptyset$ 表示融合模型参数。

该方法通过两阶段建模, 隐式学习目标间的关联性, 修正第一阶段误差。适用于需提升预测精度且目标间存在复杂关系的场景。

回归链方法是一种基于马尔科夫随机链思想, 根据确定的链顺序对每个目标构建独立的回归预测模型。其计算公式如下所示:

假设目标顺序为 $y_1 \rightarrow y_2 \rightarrow \dots \rightarrow y_K$ , 预测过程为:

$$\hat{y}_1 = f_1(X; \theta_1)$$

$$\hat{y}_2 = f_2([X, \hat{y}_1]; \theta_2)$$

$$\hat{y}_3 = f_3([X, \hat{y}_1, \hat{y}_2]; \theta_3)$$

⋮

$$\hat{y}_K = f_K([X, \hat{y}_1, \hat{y}_2, \dots, \hat{y}_{K-1}]; \theta_K)$$

其中,  $[X, \hat{y}_1, \hat{y}_2, \dots, \hat{y}_{K-1}]$ 表示原始特征与前面所有目标的预测值拼接后的输入;  $f_K$ 表示第*K*个目标的回归模型。

回归链方法通过链式结构显式建模目标变量之间的潜在关联关系, 按预定义顺序链式建模, 能够提升预测性能, 具有较高的灵活性。但后续目标的预测依赖前面目标的预测结果, 不合理的预测顺序可能会导致预测误差累积, 并且当目标变量数较多时, 多目标预测的计算复杂度非常高。

### 2.3 集成学习的主要方法

集成学习(Ensemble Learning)则是通过训练多个有所差别的个体学习器(即弱学习器), 并按照特定策略将其整合为一个强学习器, 从而显著地提升预测模型的精度及泛化能力。该方法能够弥补单一模型在复杂场景下难以全面捕捉数据特征的缺陷, 其基本原理如图3所示。根据个体学习器的类型, 集成学习能分成同质集成学习及异质集成学习两种。同质集成学习中, 所有个体学习器类型一致, 称为基学习器; 而异质集成学习中, 个体学习器类型多样, 称为组件学习器。此外, 集成学习不仅要求个体学习器具备一定的预测准确性, 还要确保个体学习器之间输出的差异性。当个体学习器采用同一类模型时, 通常通过抽样不同数据样本或调整权重的方式确保差异性。考虑到噪声等不确定因素的干扰, 采用多模型、多角度、多参数的集成学习方法能够有效克服单一模型的局限性, 减少过拟合风险, 从而提升整体预测精度与模型鲁棒性。正因如此, 集成学习在金融风险管

理等多个领域得到了广泛应用, 并展现出显著优势。

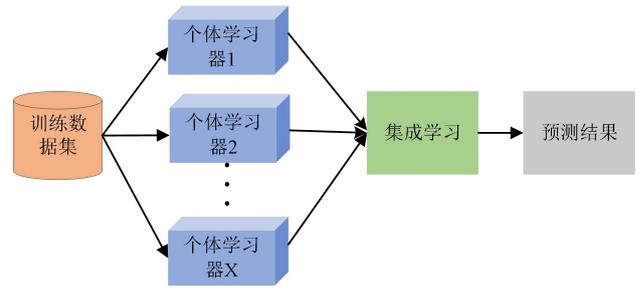


图3 集成学习示意图

集成方法的优势在于能够利用模型的多样性实现更好的泛化。例如, 结合不同的算法可以捕捉数据的各个方面, 从而提高不同数据集的性能。根据弱分类器之间的集成关系, 集成学习方法主要分为三类, 分别为 Bagging 方法、Boosting 方法和 stacking 方法, 本文使用的这三种方法进行数据处理的逻辑框图如图4所示。

Bagging 方法首先进行 Bootstrap 抽样: 从原始数据集  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$  中, 通过有放回抽样生成  $T$  个子数据集:  $D_t = \text{Bootstrap}(D), t = 1, 2, \dots, T$ 。其中, 每个子数据集  $D_t$  的样本量通常与原始数据集  $D$  相同(允许重复样本); 然后对每个子数据集  $D_t$ , 训练一个基学习器  $h_t: h_t = \text{Train}(D_t), t = 1, 2, \dots, T$ ; 最后将  $T$  个结果按照特定的结合策略实现弱学习器预测结果的集成。

针对分类问题, 结合策略一般为投票法, 硬投票公式为:

$$\hat{y} = \underset{c \in C}{\text{argmax}} \sum_{t=1}^T \mathbb{I}(h_t(x) = c)$$

其中,  $C$  表示类别集合;  $\mathbb{I}(\cdot)$  表示指示函数(若  $h_t(x) = c$  则为 1, 否则为 0);  $T$  表示基学习器数量。

这样得到最多票数的类别即为最终输出, 如: 3 个基分类器对样本  $x$  的预测结果为  $[A, B, A]$ , 则最终输出为  $A$  (出现次数最多)。

对于回归问题, 结合策略一般为平均值法或加权法, 对  $T$  个回归结果计算平均值或加权平均值作为模型输出。Bagging 方法表现非常突出, 通过对训练数据集进行多次抽样和模型训练, 能够有效地降低模型的方差, 提高预测的稳定性, 通过集成多个弱学习器的预测结果, 能够减少过拟合风险, 具有较强的泛化能力, 弱学习器的训练过程相互独立, 可以并行化处理, 提高计算效率。但是, Bagging 方法对降低偏差的效果较为有限; 由于训练多个基学习器, 导致计算开销较大; 若弱学习器对噪声数据敏感, Bagging 集成方法则可能会放大噪声的干扰影响。

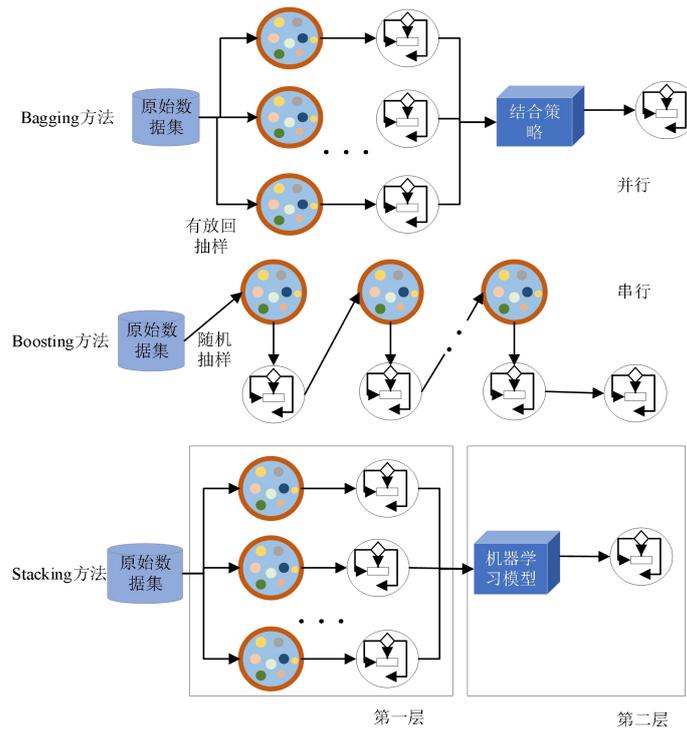


图 4 集成学习主要方法的逻辑框图

Boosting 方法按照顺序每一阶段生成一个弱学习器，并根据损失函数的梯度提升，将弱学习器加权累计生成强学习器，是种串联算法。其公式如下：

首先，基模型顺序训练，加权组合结果：AdaBoost：

$$H(X) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(X)\right)$$

其中， $h_t$ 表示第  $t$  轮弱分类器； $\alpha_t = \frac{1}{2} \ln\left(\frac{1-\epsilon_t}{\epsilon_t}\right)$ 表示分类器权重 ( $\epsilon_t$ 表示错误率)；

其次，梯度提升 (GBDT)：

$$\hat{y} = \sum_{t=1}^T \gamma_t h_t(X)$$

其中， $h_t$ 表示第  $t$  棵树，拟合当前模型的负梯度 (残差)； $\gamma_t$ 表示学习率。

该方法的核心思想是通过提高前一阶段弱学习器错误分类样本的权重和降低正确分类的数据的权重，使后续学习器更加关注难以分类的样本，改善被错误分类的数据在下一阶段中的训练，从而提升强学习器的预测准确率。在实际应用中，Boosting 方法通过调整弱学习器的权重，更加重视难以预测的样本，能够提高模型整体的精度和可靠性，但是其稳定性常受到随机噪声、异常值等的干扰，并且不适用于高维度稀疏数据，由于按阶段生成弱学习器导致计算成本较高。

Stacking 方法类似于双层“神经网络”的架构，结合训练和预测两阶段流程：首先，进行基学习器训练 (第一层)：从训练集  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$  中训练  $T$  个学

习器： $h_t = \text{Train}(D)$ , ( $t = 1, 2, \dots, T$ )；然后生成元特征 (Meta Features)：对每个样本  $x_i$ ，基学习器的预测结果构成元特征向量： $H(x_i) = [h_1(x_i), h_2(x_i), \dots, h_T(x_i)] \in \mathbb{R}^T$ ；元训练集  $D_{\text{Meta}} = \{(H(x_i), y_i) | i = 1, 2, \dots, N\}$ 。再进行元学习器训练 (第二层)：基于元训练集  $D_{\text{Meta}}$ ，训练元学习器  $g$ ： $g = \text{Train}(D_{\text{Meta}})$ 。

Stacking 方法将第一层所有弱学习器的预测结果作为第二层的输入以训练第二层模型，第一层模型的数量即使第二层模型的输入特征维度，从而完成最终的预测结果输出。一般来说，stacking 方法中的第一层模型为强学习器，而第二层模型则为简单的弱学习器是较为普遍的设计，防止过拟合。

### 3 案例分析

#### 3.1 实验设计

根据多目标优化得到的帕累托最优解集，关键质量特征集合共有 9 个，随机森林在每个关键质量特征集合的预测性能均表现优异。基于本节所提出的试车性能预测方法，使用随机森林模型、XGBRegressor 模型、GradientBoostingRegressor 模型和 ExtraTreesRegressor 模型作为实现回归预测的机器学习基础模型，模型优劣的判断标准为真实值与预测值之间的决定系数  $R^2$ 。

#### 3.2 实验结果

首先，基于所有关键质量特征集合训练多目标预测模型，通过对比性能评价指标  $R^2$ ，筛选出关键质量特征对应的最优的航空发动机试车性能多目标预测模型，结果如表 1 所示。

实验表明，三种多目标预测模型在不同输入特征、输出目标或基础模型的多目标预测任务中表现出显著的性能差异。相较于基于原始特征数据集训练得到的单一目标预测模型的

预测性能，本节所得到的多目标预测模型在预测试车性能指标的效果有所改善，说明多目标预测模型具有提高多目标预测准确率的优势。

表1 关键质量特征集合的多目标预测模型

关键质量特征集合	试车性能指标 $y_1$			试车性能指标 $y_2$		
	模型	多目标预测方法	R2	模型	多目标预测方法	R2
原始数据	---	---	0.54	---	---	0.78
1	GradientBoostingRegressor	ST	0.59	GradientBoostingRegressor	MTRS	0.80
2	GradientBoostingRegressor	ST	0.58	GradientBoostingRegressor	ST	0.80
3	GradientBoostingRegressor	ST	0.58	GradientBoostingRegressor	MTRS	0.81
4	GradientBoostingRegressor	ST	0.59	GradientBoostingRegressor	MTRS	0.81
5	RandomForestRegressor	ST	0.61	GradientBoostingRegressor	ST	0.81
6	GradientBoostingRegressor	ST	0.60	GradientBoostingRegressor	ST	0.81
7	ExtraTreesRegressor	MTRS	0.60	GradientBoostingRegressor	MTRS	0.78
8	GradientBoostingRegressor	ST	0.64	GradientBoostingRegressor	ST	0.80
9	GradientBoostingRegressor	ST	0.60	GradientBoostingRegressor	RC	0.79

然后，将每个关键质量特征集合对应的多目标预测模型作为集成学习的个体学习器，分别采用三种集成方法实现试车性能指标的预测，得到航空发动机试车性能的预测结果如表2所示。实验结果显示，基于 Bagging 方法的多目标预测

模型将预测试车指标  $y_1$  的 R2 提升至 0.64，将预测  $y_2$  的 R2 提升至 0.83，明显优于原始数据的预测性能，验证了本文所提方法在试车性能多目标预测方法适用性和有效性。

表2 基于集成学习的多目标预测结果对比表

	试车指标 $y_1$			试车指标 $y_2$		
	MSE	MAE	R2	MSE	MAE	R2
Bagging	38.25	4.70	0.64	53.13	5.46	0.83
Stacking	39.16	4.55	0.62	57.64	5.32	0.81
Boosting	60.45	5.25	0.42	62.91	5.57	0.80
原始装配数据	47.60	5.03	0.54	64.99	6.05	0.78

4 结论

本文深入探讨了集成学习在航空发动机试车性能预测中的应用，对集成学习的主要方法进行了系统的介绍与总结。基于航空发动机试车性能指标的多目标特性，我们构建了一个专门针对航空发动机试车性能的多目标预测模型。此模型

不仅结合了集成学习的优势，还特别提出了一个创新性的策略，即通过整合多个关键质量特征的多目标预测结果来提升整体预测的准确率。

实验对比分析表明，本文提出的基于集成学习的多目标预测策略在提高航空发动机试车性能预测准确性方面具有

显著优势。相较于传统的单一模型或未使用集成技术的方法，该策略能够更全面地捕捉到航空发动机试车过程中的复杂性和多样性，从而为航空发动机的可靠性评估提供了更为精准的数据支持。

综上所述，本文不仅拓展了集成学习在航空发动机领域的应用范围，而且为相关领域提供了一种有效的解决方案。未来的研究可以进一步探索如何将这一策略应用于其他类型的航空器组件或是不同的工业领域中，以期实现更加广泛的技术创新和应用。同时，随着数据量的增长和技术的进步，优化现有的预测模型并探索新的集成方法也是值得深入研究的方向。

#### [参考文献]

[1] 喻勇, 司小胜, 胡昌华, 等. 数据驱动的可靠性评估与寿命预测研究进展: 基于协变量的方法[J]. 自动化学报, 2018, 44(02): 216-227.

[2] 刘子敬, 张伟, 邹守铭. 可靠性评估、全寿命周期评估和 PHM 技术关联性分析[J]. 内燃机与配件, 2019(18): 205-206.

[3] 杨宏运. 基于数据驱动的机械设备故障预测与维修策略优化[J]. 中国机械, 2023(20): 103-106.

[4] Huang Y, Tao J, Zhao J, et al. Graph structure embedded with physical constraints-based information fusion network for interpretable fault diagnosis of aero-engine[J]. Energy, 2023, 283: 129120.

[5] Khattak W R, Salman A, Ghafoor S, et al. Multi-modal LSTM network for anomaly prediction in piston engine aircraft[J]. Heliyon, 2024, 10(3).

[6] Liu Q, Zhang Z, Guo P, et al. Enhancing aircraft

engine remaining useful life prediction via multiscale deep transfer learning with limited data[J]. Journal of Computational Design and Engineering, 2024, 11(1): 343-355.

[7] Khattak W R, Salman A, Ghafoor S, et al. Multi-modal LSTM network for anomaly prediction in piston engine aircraft[J]. Heliyon, 2024, 10(3).

[8] 蒋旭瑞, 吴明功, 温祥西, 等. 自由飞行下基于集成学习的概率型冲突探测算法[J]. 航空工程进展, 2018, 9(4): 530-536.

[9] 钟诗胜, 雷达. 一种可用于航空发动机健康状态预测的动态集成极端学习机模型[J]. 航空动力学报, 2014, 29(9): 2085-2090.

[10] 徐建新, 侯振华. 基于集成 ELM 模型的航空发动机性能参数预测[J]. 中国民航大学学报, 2017, 35(2): 20-23.

[11] 雷达, 钟诗胜. 用集成过程神经网络预测民航发动机振动趋势[J]. 振动. 测试与诊断, 2015, 35(1): 137-141, 194.

[12] 陆文灏, 柯勇伟, 郭永强, 等. 面向多目标优化的航空发动机装配特征选择[J]. 工业工程, 2024, 27(4): 1-8.

#### 作者简介:

蔡志强, 1981 年生, 湖南衡阳人, 博士, 西北工业大学机电学院教授、博导, 主要从事复杂装备可靠性建模与优化理论研究。

#### 基金项目:

国家自然科学基金重点项目 (72231008); 国家自然科学基金面上项目 (72271200); 陕西省杰出青年科学基金 (2023-JQ-JC-10)。