DOI: 10. 13382/j. jemi. B2407344

# 面向涡轮的 PCA-POA-LSTM 数据驱动建模及 故障预警方法\*

刘 斌 白红艳 何璐瑶 张晓北 田 野 杨理践<sup>1,2</sup>

(1. 沈阳工业大学信息科学与工程学院 沈阳 110870;2. 沈阳路杰管道检测有限公司 沈阳 110027;

3. 管网集团(新疆)联合管道有限责任公司 乌鲁木齐 830011)

摘 要:针对传统 LSTM 数据驱动模型存在输入参数规模过大导致运算负担过大、超参数选择不当和涡轮系统故障发生频率、运维成本高的问题,提出一种基于 PCA-POA-LSTM 的涡轮数据驱动建模方法,并结合滑动窗口法实现了涡轮故障预警。首先,应用 PCA 降维技术,减少输入数据维度;其次,采用 POA 参数寻优方法选出最优超参数组合;然后,利用 LSTM 算法预测涡轮的输出参数;最后,在 PCA-POA-LSTM 涡轮数据驱动模型预测结果的基础上,结合滑动窗口法对涡轮故障进行预警,通过窗口内标准差定义报警阈值,攻克了涡轮故障预警的难题。结果表明,以 PCA-POA-LSTM 为基础的涡轮数据驱动建模实现了较高的精确度,平均绝对百分比误差均在 0.396 以下,平均绝对误差均在 0.809 以下,平均方根误差均在 1.387 以下。并且故障预警方法,至少可提前 173 个监测点发出故障预警信号,实现了对涡轮故障预警的目的,为未来开展涡轮健康管理提供了理论依据和技术支持。

# PCA-POA-LSTM data-driven modeling and fault warning method for turbine systems

Liu Bin<sup>1</sup> Bai Hongyan<sup>1</sup> He Luyao<sup>1</sup> Zhang Xiaobei<sup>2</sup> Tian Ye<sup>3</sup> Yang Lijian<sup>1,2</sup>

(1. School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China;

2. Shenyang Lujie Pipeline Inspection Co., Ltd, Shenyang 110027, China; 3. Pipeline Group (Xinjiang)

Joint Pipeline Co., Ltd, Urumqi 830011, China)

**Abstract**: In response to the issues such as the overly large scale of input parameters in the traditional LSTM data-driven model, which leads to an excessive computational burden, improper selection of hyperparameters, high frequency of turbine system failures, and high operation and maintenance costs, a turbine data-driven modeling approach based on PCA-POA-LSTM is proposed, and the turbine fault early warning is achieved by combining with the sliding window method. Firstly, the PCA dimensionality reduction technique is applied to reduce the dimension of the input data. Secondly, the POA parameter optimization method is adopted to select the optimal combination of hyperparameters. Then, the LSTM algorithm is utilized to predict the output parameters of the turbine. Finally, based on the prediction results of the PCA-POA-LSTM turbine data-driven model, the turbine faults are warned by combining with the sliding window method, and the alarm threshold is defined by the standard deviation within the window, thus conquering the difficulty of turbine fault early warning. The results indicate that the turbine data-driven modeling based on PCA-POA-LSTM achieves a relatively high accuracy, with the average absolute percentage error all below 0. 396, the average absolute error all below 0. 809, and the average root mean square error all below 1. 387. Moreover, the fault early warning method can issue a fault early warning signal at least 173 monitoring points in advance, achieving the purpose of turbine fault early warning and providing theoretical basis and technical support for the future development of turbine health management.

Keywords: turbine; pelican optimization algorithm; long short-term memory network; principal component analysis; data-driven

收稿日期: 2024-03-16 Received Date: 2024-03-16

<sup>\*</sup>基金项目:国家自然科学基金(62371315)、国家自然科学基金(62301341)、辽宁省自然科学基金计划(2023-BS-126)、辽宁省应用基础研究计划(2022JH2/101300244)项目资助

# 0 引 言

发动机健康管理是利用分布在发动机上的传感器所 获得的数据,借助各种先进智能算法来监控、预测和管理 发动机的健康状态<sup>[1]</sup>,以提高飞行安全性和可靠性,缩短 发动机停机时间,提高运行效率,并减少发动机维修费 用<sup>[2]</sup>。其中,涡轮是发动机的重要部件<sup>[3]</sup>,发动机涡轮一 旦出现故障,其影响和损失巨大。因此,在涡轮发生故障 之前,对其工作状态实现监测,提前识别故障,具有重要 意义<sup>[4]</sup>。

在机械设备预警领域,传统预警手段大多从特征提 取角度出发去研究引发故障的原因和其所征兆的特定设 备运行状态<sup>[5]</sup>,通过建立两者之间的对应关系,根据特定 的故障现象进行预警<sup>[6]</sup>。但上述研究方法需要大量的样 本数据,对数据的完整性要求较高,且过度依赖人工 经验。

随着大数据时代的到来,数据驱动下的故障预警技 术逐渐受到广大学者的青睐<sup>[7]</sup>。Wu 等<sup>[8]</sup>采用基于非对 称支持向量机算法和离心压缩机的输入输出数据建立了 喘振预测模型,避免了压缩机在喘振区域运行。夏存江 等<sup>[9]</sup>提出了一种基于改进的压缩激励网络(squeeze and excitation network, SENet)模型的方法,使用真实的快速 存取记录仪(quick access recorder, QAR)数据进行随机采 样,从而实时追踪振动的突变和波动。陶金伟等<sup>[10]</sup>提出 一种加权邓普斯特-沙弗证据理论(dempster-shafer, D-S) 的故障诊断方法,使用飞行状态参数结合混淆矩阵求解 子证据体加权系数,提高了故障预警正确率。Lin 等<sup>[11]</sup> 基于核函数的高维映射和经验方法,将输入样本映射到 高维空间以增强故障特征信息,从而提高故障诊断的准 确性。伍济钢等<sup>[12]</sup>提出了一种改进的双通道1维卷积 神经网络(1d convolutional neural network, 1DCNN), 通过 内嵌多尺度层和幅值变化通道增强时域特征提取能力, 证明了其在故障检测中的抗噪性。虽然目前的一些故障 预警研究,都采用了数据驱动方法建立预测模型<sup>[13]</sup>,但 存在未充分考虑输入参数规模过大、各个变量之间耦合 性强、非线性等问题。这些因素会导致模型运算时间过 长,增加运算负担。此外,在先验知识有限的情况下,模 型超参数设置不合理可能会降低模型的可靠性,而影响 其预测精度。

论文采用基于 PCA-POA-LSTM 的方法建立发动机 涡轮数据驱动模型及故障预警模型,实现对发动机涡轮 运行状态预测和故障预警的目的。首先,使用主成分分 析法(principle component analysis, PCA), 针对具有大量 相关参数、高维度和强耦合性的非线性发动机涡轮输入 变量,进行预处理以消除变量之间的相关性,并实施数据 降维。这一过程旨在保持预测准确性的同时,缩短模型 训练和优化时间<sup>[14]</sup>。其次,采用鹈鹕优化算法(pelican optimization algorithm, POA) 来对长短期记忆网络(long short-term memory,LSTM)预测模型中需要手动方法设置 或者调整的超参数进行寻优,从而找到这些超参数的最 优组合,确保模型的预测精度。最后,利用滑动窗口的标 准差对预警残差进行分析,根据正常状态下的标准差设 置报警阈值,进行涡轮故障预警。综上所述,论文结合 PCA、POA、LSTM,3种方法建立出预测精度高、训练时间 少的发动机涡轮出口温度、压力和流量的数据驱动模型, 并结合滑动窗口标准差分析法,实现对发动机涡轮的故 **障预警**。

# 1 数据预处理和涡轮建模及故障预警方法 设计

# 1.1 数据预处理

1)涡轮特性分析及输入输出参数选取

涡扇发动机作为当今航空工程的核心,其复杂的结构和精密的设计使得其性能和效率达到了前所未有的高度。该发动机主要由风扇(Fan)、低压压缩机(LPC)、高压压缩机(HPC)、燃烧室(CC)、低压涡轮机(LPT)和高压涡轮机(HPT)组成,其示意图如图1所示,各截面参数如表1所示。这些组件相互协作,将大气中的空气转化为高速喷出的气流,产生强大的推力,推动飞机飞行<sup>[15]</sup>。空气首先进入风扇,风扇通过增加进气量和改善燃烧效率的作用,为后续的压缩和燃烧创造条件。接着,空气进入压气机,其中的旋转叶片将空气压缩,增加密度和压力,为燃烧室提供高压高温的工作介质。压缩后的空气与燃料在燃烧室中混合燃烧,产生高温高压的燃气。最后,燃烧后的气体通过涡轮喷出,涡轮从燃烧气体的能量中吸取动力,并将其转化为旋转动能,驱动压气机继续压缩更多空气,形成了连续的循环过程。

	表 1	涡扇发动机	1各截面 1	参数	Į	
Table 1	Parameters	s of various	sections	of	turbofan	engine

									0			
符号	Wf	Nf	Nc	<i>T</i> 2	T21	<i>T</i> 24	<i>T</i> 30	T48	<i>T</i> 50	P2	P15	P21
燃油	燃油	物理风	物理核	风扇进	风扇出	低压压气机	高压压气机	高压涡轮	低压涡轮	风扇	旁路管	风扇出
捆地	流量	扇转速	心速度	口总温	口总温	出口总温	出口总温	出口总温	出口总温	进口总压	道总压	口总压
单位	$\mathbf{pps}$	rpm	rpm	R	R	R	R	R	R	psia	psia	psia



图 1 涡扇发动机示意图 Fig. 1 Schematic diagram of a turbofan engine

从这个过程中可以看出,各个发动机部件产生的气体质量直接影响着发动机的做功量。特别是涡轮这一关键部件,其性能参数对整个发动机的性能起着至关重要的作用。因此,将低压涡轮最终产生的关键参数作为预测对象,包括低压涡轮出口总温(*T50*)/°R、低压涡轮出口总压(*P50*)/psia 以及低压涡轮出口流量(*W50*)/(lbm·s<sup>-1</sup>)。这些参数的准确预测对于优化发动机性能、提高燃烧效率具有重要意义。

基于以上分析,结合对发动机测点的考量以及发动 机涡轮本身的特性,确定了模型的11个输入参数,分别 为高度(*alt*)/ft、马赫数(*Mach*)、节气门-分解器角度 (*TRA*)/(°)、高压压气机出口总温(*T*30)/°R、高压涡轮 出口总温(*T*48)/°R、高压压气机出口净压(*Ps*30)/psia、 物理风扇转速(*Nf*)/(r·min<sup>-1</sup>)、物理核心速度(*Nc*)/(r· min<sup>-1</sup>)、燃油流量(*Wf*)/pps、高压压气机出口总压 (*P*30)/psia、高压涡轮出口流量(*W*48)/pps,其中,lbm/s 表示磅质量/秒,ft 表示英尺,°R 表示兰式度,psia 表示 磅/平方英寸,pps 表示磅/秒,这些均为 NASA 宇航局所 用标准单位。

2) PCA 降维及数据集划分

由于发动机涡轮相关参数数据量大、变量个数多、各 个变量之间耦合性强、非线性的特点<sup>[16]</sup>。为了应对这些 复杂性,采用了 PCA 降维方法,以减少变量之间的相关 性。这样一来,不仅能确保预测精度,还能缩短模型的训 练和优化时间。

PCA 旨在通过线性变换将原始数据映射到一个新的 坐标系中,以提取数据的主要特征并生成能够综合反映 原始数据信息的几个指标。这些新指标之间相互独 立<sup>[17-18]</sup>,使得数据结构更简单,实现数据的降维<sup>[19-22]</sup>。文 中设定了阈值为 0.999。当累积贡献率超过阈值时,表 示主成分已经包含了原始数据的 99.9% 信息。因此,可 以提取这几个主成分作为建立模型所需的输入参数,实 现数据降维。

在将数据输入到模型训练模块之前,为了评估模型的性能和泛化能力,根据留出验证法,对 PCA 降维后的数据进行划分,将数据集的 80%作为训练集,用于模型的训练和参数优化;将剩余的 20%作为测试集,用于验证模型的预测效果。

# 1.2 涡轮建模及故障预警方法设计

1) PCA-POA-LSTM 数据驱动建模方法

为了充分利用 PCA 对多维特征的卓越提取能力和 LSTM 的时间记忆优势<sup>[23]</sup>,本研究提出了一种新的 PCA-LSTM 混合神经网络模型方案,该模型采用串联方法进行 模型融合。同时,为了进一步优化 LSTM 的性能,引入了 POA<sup>[24]</sup>算法对 LSTM 进行参数优化。如图 2 所示,该方 案主要包括 3 部分:数据处理子模块、模型子模块和 POA 参数寻优子模块,这 3 部分的结构比单个模型更丰富。 POA 算法与 LSTM 的结合能够提高模型的学习能力和泛 化能力,从而更有效地利用 PCA 提取的特征进行时间序 列数据的预测。

数据处理子模块用于格式化原始数据,并将样本传 递给模型子模块。模型子模块中的 LSTM 神经网络负责 从输入数据中学习高级特征。此外,为了避免传统的神 经网络中,随机下降梯度法进行学习率更新,收敛速度较 慢且存在容易陷入"鞍点"的问题<sup>[25]</sup>,使用了自适应矩估 计优化算法(adaptive moment estimation, Adam),此优化 方法具有能有效处理稀疏梯度、自适应学习率、并且对内 存需求较低的优点<sup>[26]</sup>,能够加快 LSTM 网络的收敛速度 和提高训练效果。POA 参数寻优方法寻优的参数包括 模型子模块中的 LSTM 神经网络的 3 个超参数分别是隐 含层神经元数,初始学习率和L2正则化系数。

该方法的工作流程包括几个关键步骤。首先,数据 处理模块负责对原始数据进行预处理,包括 PCA 降维和 归一化等,以确保输入数据的质量和一致性。其次,多个 输入样本以矩阵形式表示,并传递给模型子模块进行处 理。接着,POA 超参数寻优模块通过对部分超参数进行 寻优,以确定这些超参数的最优配置,从而提高模型的预测精度。POA 技术的应用有助于有效地搜索超参数空间,找到最佳的模型配置,以最大程度地优化模型的性能。最后,LSTM 模型训练模块使用 Adam 优化算法对LSTM 结构进行训练,以捕捉涡轮的特征信息,并生成相应的涡轮状态数据。





2)故障预警方法

论文采用滑动窗口法预警发动机涡轮潜在故障,选 取涡轮正常工况数据训练 PCA-POA-LSTM 模型,当涡轮 正常运行时,PCA-POA-LSTM 模型的输出参数预测误差 相对较小。当涡轮出现故障时,输出参数会偏离正常区 间,从而导致 PCA-POA-LSTM 模型的输出参数预测误差 变大<sup>[27]</sup>。可以通过分析预测值和测量值之间的标准偏 差,来评估涡轮状态以预警涡轮故障。

滑动窗口宽度为 N 时, 残差的均值和标准差的计算 公式如式(1)和(2)所示。

$$\overline{X_{\varepsilon}} = \frac{1}{N} \sum_{i=1}^{N} \varepsilon_i$$
(1)

$$S_{\varepsilon} = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N} (\varepsilon_i - \overline{X_{\varepsilon}})^2}$$
(2)

计算出标准偏差的最大值为 S<sub>max</sub>。通过标准偏差设 置报警阈值:

$$S_T = k \cdot S_{\max} \tag{3}$$

其中,k通常由操作员根据经验获得。

# 2 模型性能评估与分析

# 2.1 涡轮建模及故障预警实现过程

论文采用滑动窗口法预警发动机涡轮潜在故障,整体流程图如图3所示。实现过程分为模型训练和故障预 警两部分。

模型训练部分,首先将数据集 data1 和 data2 分别输入图 2 中的 PCA 降维模块,以减少数据维度并为后续的 POA 超参数优化和 LSTM 模型训练做准备。以数据集 data1 为例,演示了通过 PCA 降维和 POA 优化 LSTM 模型超参数的优势。随后,将降维后的数据输入到模型模块中,进行超参数优化,找出最佳的超参数组合。接着,将优化后的数据输入到 LSTM 神经网络模块中进行训练,得到正常工况下的 PCA-POA-LSTM 涡轮数据驱动模型,并将其与其他基准模型进行了比较。通过 MAPE、MAE 和 RMSE 等指标对模型性能进行了详细分析。

最后是故障预警部分,选取涡轮正常工况数据训练



图 3 滑窗预警流程 Fig. 3 Sliding window alerting process flowchart

PCA-POA-LSTM 模型,当涡轮正常运行时,PCA-POA-LSTM 模型的输出参数预测误差相对较小。当涡轮出现 故障时,输出参数会偏离正常区间,从而导致 PCA-POA-LSTM 模型的输出参数预测误差变大。可以通过分析预 测值和测量值之间的标准偏差,来评估涡轮状态以预警 涡轮故障。

# 2.2 PCA 降维

通过对数据 datal 进行 PCA 处理,得到了各主成分 的累计贡献率以及贡献率的变化,如图 4 所示。从图中 可以看出,主成分 1 的贡献率超过了 79%,在累计贡献率 中占据较大比例;到达主成分 3 时,累计贡献率已经达到 了 99.9%,此后的主成分贡献率非常小。因此,选择前 3 个主成分作为预测模型的输入参数,将输入数据的维度 从 11 维降低到 3 维。

根据表 2 提供的前 3 个主成分的特征和它们的贡献 率以及累计贡献率,计算出相应的特征向量,并得出各主 成分的数值。

### 表 2 前 3 个主成分信息

_				
	主成分	特征值	贡献率/%	累计贡献率/%
	1	8.714 721	79. 225	79.2
	2	2.245 686	20. 415	99.6
_	3	0.031 454	0.286	99. 9

同时为了比较使用 PCA 处理过的数据与使用未经 PCA 处理过的数据建模的异同,选用未经 PCA 降维的 11 维数数据作为模型输入,输出仍为 3 维数据,用 POA 对



模型的3个超参数进行寻优,并与 PCA 处理后的数据建 模寻优结果进行对比。图5展示了两类模型在 POA 超 参数调整过程中,适应度函数值随着迭代次数的变化 情况。



图 5 适应度函数值随迭代次数变化

Fig. 5 Variation of fitness function value with iteration number

根据图 5 的观察结果,在最初的 12 次迭代中,两类 模型的适应度函数值迅速下降,并且在接近 4.8×10<sup>-5</sup> 时 趋于稳定。此后,随着更多的迭代次数,这两类模型的适 应度函数值变化极小。经过多次迭代后,经过 PCA 处理 的模型在寻优过程中达到了适应度函数值为 4.845 9× 10<sup>-5</sup>,未 PCA 处理模型的寻优适应度函数值为 4.845 9× 10<sup>-5</sup>,相差 0.279 1×10<sup>-5</sup>。由此可见,经过 PCA 处理后的 数据所训练的模型在预测精度上可能会略微降低,但这 种损失非常小。但是在寻优时间上,经过 PCA 处理模型 的时间 为 44 326.30 s,未 PCA 处理模型的时间为 46 354.82 s,经过 PCA 处理模型的寻优时间要比未 PCA 处理模型缩减了 2 028.52 s。因此,采用 PCA 对数据进 行降维处理,可以在极小的预测精度损失的情况下,显著 缩短模型寻优和训练的时间。

# 2.3 POA 对 LSTM 模型超参数寻优结果

使用 POA 对 LSTM 模型的 3 个超参数进行寻优时, POA 优化参数中种群数量设置为 35,迭代次数设置为 25,适应度函数选用测试集输出参数的真实值与预测值 的均方根误差。3 个超参数设置的上下限如表 3 所示。

表 3 超参数上下限

Table 3	Upper :	and lower	limits of	hyperparameters
I HOIC C	C P P CI	and to not	minus or	ing per par annever 5

项目	隐含层神经元数	初始学习率	L2 正则化系数
上限	800	0.02	$1 \times 10^{-2}$
下限	10	0.000 1	$1 \times 10^{-10}$

最终得到适应度函数值为 4.845 9×10<sup>-5</sup>,LSTM 层隐 含神经元数为 266,初始学习率为 0.007 8,L2 正则化系 数为 0.000 6。因此可知,在进行 25 次迭代后,适应度函 数值达到 4.845 9×10<sup>-5</sup>,表明 POA 寻优效果显著。

# 2.4 不同涡轮建模方法的比较

选用平均绝对百分比误差(mean absolute percentage error, MAPE)、平均绝对误差(mean absolute error, MAE) 和均方根误差(root mean square error, RMSE)作为模型的评估指标。其中计算公式如式(4)~(6)所示。

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{y_i - y_i}{y_i} \right|$$

$$\tag{4}$$

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |\hat{y}_i - y_i|$$
(5)

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n} (\hat{y}_{i} - y_{i})^{2}}{n}}$$
(6)

式中:n 为数据样本的个数; $\hat{y}_i$  为预测值; $y_i$  为真实值。

为评估 PCA-POA-LSTM 模型的预测性能,选用 PCA-LSTM 和 PCA-LSF 模型作为对照组,建立相应模型, 并使用测试集验证各模型的预测结果。750、P50、W50 三种参数在数据集 data1 的预测效果,如图 6 所示。

图 6 显示了使用 data1 的 3 个涡轮输出参数的预测, 其中图 6(a)~(c)分别表示 T50、P50 和 W50 的预测结 果。黑色底块表示实际输出参数,红色圆形表示 PCA-POA-LSTM 模型的预测结果。其他图形分别表示 PCA-LSF 模型、和 PCA-LSTM 模型的预测结果。根据图 6(a),PCA-LSF 方法在预测模型输出 T50 与实际数值的 变化趋势拟合度较低,属于 3 种方法中最低的情况。相 对而言,PCA-LSTM 方法在 T50 的预测中表现较为出色, 其输出曲线与实测曲线基本吻合,但仍存在一定的偏差。 而 PCA-POA-LSTM 方法在 T50 的预测中表现较为出色, 属佳的拟合效果。此外,从图 6(b)和(c)可以观察到,尽 管 PCA-LSF 方法在 P50 和 W50 的预测上在一些情况下 略优于其他两种方法,但总体趋势上仍然拟合度较低。 PCA-LSTM 方法在拟合程度上表现较好,但提出的 PCA-POA-LSTM 方法仍然是3种方法中最准确的模型。







为了深入评估 PCA-POA-LSTM 方法的参数预测准确性 和稳定性,对另一个数据集 data2 进行了测试,具体结果 如图 7 所示。

在图 7 中,可以清晰地观察到,PCA-LSF 和 PCA-LSTM 模型在被预测数据的平滑区域表现出良好的性能,然而,在第 500 和 1 500 个预测点附近,由于真实数据的







Fig. 7 Comparison of predicted values and true values for three models under data2, along with residual plot

波动,它们的预测误差显著增加。相比之下,PCA-POA-LSTM 模型在子图中的所有测试点上都展现出极佳的 性能。

此外,为了更详细地描述发动机涡轮输出参数预测 的评估指标,可以参考表4。

表4展示了所有模拟的评估指标的结果,最优情况 以粗体显示。可以看出,所提出的 PCA-POA-LSTM 模型 具有更低的误差。

对于 data1 的 *T*50 预测,3 个模型对 *T*50 的 MAPE 均 小于 0.12,MAE 均小于 1.3,RMSE 均小于 1.9。对比其 他两种方法,PCA-POA-LSTM 模型对 *T*50 的 MAPE 降低 幅度均大于 19.64%, MAE 降低幅度均大于 19.92%, RMSE 降低幅度均大于 14.52%;对于 data1 的 *P*50 预测, 3 个模型对 *P*50 的 MAPE 均小于 0.38, MAE 均小于 0.05, RMSE 均小于 0.06。对比其他两种方法, PCA-POA-LSTM 模型的 MAPE 降低幅度均大于 11.05%, MAE 降低幅度均大于 10.83%, RMSE 降低幅度均大于 11.53%; 对于 data1 的 W50 预测, 3 个模型对 750 的 MAPE 均小于 0.19, MAE 均小于 0.35, RMSE 均小于 0.43。对比其他两种方法, PCA-POA-LSTM 模型的 MAPE 降低幅度均大于 17.12%, MAE 降低幅度均大于 19.93%, RMSE 降低幅度均大于 21.15%。

# 表 4 发动机涡轮输出参数预测评估指标信息

 
 Table 4
 Evaluation metrics for predicting output parameters of engine turbines

对比指标	数据集	预测参数	PCA-LSF	PCA-LSTM	PCA-POA-LSTM
MAPE	data1	<i>T</i> 50	0.1117	0.088 7	0.071 3
		P50	0.3713	0.1817	0.1617
		W50	0.126 4	0.1864	0.104 8
		<i>T</i> 50	0.229 1	0.201 5	0.084 4
	data2	P50	1.345 9	0.7806	0.3951
		W50	0.183 8	0.4894	0.153 0
	data1	<i>T</i> 50	1.2917	1.010 1	0.808 8
		P50	0.044 4	0.021 2	0.018 9
MAE		W50	0.242 3	0.340 6	0.194 0
MAL	data2	<i>T</i> 50	2.581 6	2.2703	0.9557
		P50	0.132 8	0.072 5	0.039 5
		W50	0.329 0	0.8139	0.259 0
	data1	<i>T</i> 50	1.8990	1.286 6	1.099 6
RMSE ·		P50	0.058 6	0.024 6	0.021 8
		W50	0.342 0	0.426 9	0.2697
	data2	<i>T</i> 50	3.453 6	2.8177	1.386 1
		P50	0.158 1	0.085 3	0.053 4
		W50	0.4167	0.9956	0.330 5

对于 data2 的 *T5*0 预测,3 个模型对 *T5*0 的 MAPE 均 小于 0.23%, MAE 均小于 2.6%, RMSE 均小于 3.5%。 对比其他两种方法, PCA-POA-LSTM 模型对 *T5*0 的 MAPE 降低幅度均大于 58.10%, MAE 降低幅度均大于 57.90%, RMSE 降低幅度均大于 50.81%; 对于 data2 的 *P5*0 预测,3 个模型对 *P5*0 的 MAPE 均小于 1.4%, MAE 均小于 0.14%, RMSE 均小于 0.16%。对比其他两种方 法, PCA-POA-LSTM 模型的 MAPE 降低幅度均大于 49.39%, MAE 降低幅度均大于 45.51%, RMSE 降低幅度 均大于 37.41%; 对于 data2 的 *W5*0 预测,3 个模型对 *T5*0 的 MAPE 均小于 0.49%, MAE 均小于 0.82%, RMSE 均 小于 1.00%。对比其他两种方法, PCA-POA-LSTM 模型 的 MAPE 降低幅度均大于 16.75%, MAE 降低幅度均大 于 21.27%, RMSE 降低幅度均大于 20.69%。

综上分析,采用 POA 对 LSTM 模型进行优化显著提高了模型的预测精度。因此,提出的基于融合 PCA、POA 和 LSTM 的发动机涡轮输出参数预测模型不仅能够有效 缩短模型的训练时间,同时还能更好地捕捉历史健康运行数据之间的规律,从而实现对各个参数的准确预测。这一研究成果为提高涡轮系统性能预测的可靠性和准确 性提供了有力支持。

# 2.5 预警结果分析

选取 DS01\_unit1.0\_cycle2.0 和 DS01\_unit2.0\_ cycle2.0 巡航稳态数据,将数据集代入训练好的 PCA-POA-LSTM 涡轮模型,计算涡轮输出预测值,得到设备正 常运行状态下,标准差变化趋势,如图 8 和 9 所示。





Fig. 8 Standard deviation of normal turbine operation of turbine under data1

由图 8 可知,涡轮正常状态运行时,750 标准差的最 大值为 2.258 7° R。根据式(3),标准差报警阈值为 6.776 1° R;涡轮正常状态运行时,P50 标准差的平均值为 0.058 8 psia。根据式(3),标准差报警阈值为 0.2176 psia;涡轮正常状态运行时,W50 标准差的平均 值为 1.474 4 lbm/s。根据式(3),标准差报警阈值为 4.423 2 lbm/s。

由图 9 可知,涡轮正常状态运行时,*T*50 标准差的最大值为 4.621 5° R。根据式(3),标准差报警阈值为 16.175 3° R;涡轮正常状态运行时,*P*50 标准差的平均值

监测点/个

(b) P50标准差

(b) Standard deviation of P50

data2 下涡轮正常状态运行标准差

Standard deviation of normal operation of turbine under data2

0.0 0 200 400 600 800

图 9



1 000 1 200

0.4

0 200 400

为 0.284 2 psia。根据式 (3),标准差报警阈值为 0.9948 psia:涡轮正常状态运行时,W50标准差的平均 值为1.7440 lbm/s。根据式(3),标准差报警阈值为 6. 103 9 lbm/s.

800

(a) T50标准差

(a) Standard deviation of T50

1 000 1 200

Fig. 9

为了验证预警模型的正确性,分别在 DS01\_unit1.0\_ cycle2.0的819个巡航稳态数据后,注入DS01\_unit1.0\_ cycle100.0的100个巡航稳态涡轮故障数据和DS01\_ unit2.0\_cycle2.0的1367个巡航稳态数据后,注入DS01\_ unit2.0\_cycle75.0的200个巡航稳态涡轮故障数据,来 对涡轮系统故障进行模拟。将数据集导入训练好的 PCA-POA-LSTM 模型得到预测值与真实值的残差,并代 入N=180,移动步长为1的滑窗故障预警模块得到故障 预警图,如图10和11所示。



Fig. 10 Turbine output alert chart under data1

在图 10 中, 750 第 548 个监测点, 标准差开始超过 报警阈值,并发出预警信号;W50 第548个监测点,标准 差开始超过报警阈值,并发出预警信号:W50 第 546 个监 测点,标准差开始超过报警阈值,并发出预警信号。而涡 轮的实际警报信息是在第720个监测点发布的。通过提 出的方法,最早可以在第546个数据点发出警报信号.这 意味着与现有方法相比,此方法可以提前173个监测点 发出涡轮故障的预警信号。

600 800

监测点/个

(c) W50标准差

(c) Standard deviation of W50



在图 11 中, 750 第1 190 个监测点, 标准差开始超过 报警阈值,并发出预警信号:P50 第1197个监测点,标准 差开始超过报警阈值,并发出预警信号:W50 第1189个 监测点,标准差开始超过报警阈值,并发出预警信号。而 涡轮的实际警报信息是在第1368个监测点发布的。通 过提出的方法,最早可以在第1189个数据点发出警报 信号,这意味着与现有方法相比,此方法可以提前179个 监测点发出涡轮故障的预警信号。

#### 结 3 论

论文提出了一种新的 PCA-POA-LSTM 涡轮数据驱

1 000 1 200

5

4

3

2

1

0 200 400 600 监测点/个

"50标准差

最大标准差值点

(1,4.6215)

动模型,用于航空发动机涡轮的输出参数预测,并利用滑 动窗口分析法,提出了一种航空发动机涡轮故障预警方 法。通过融合 PCA、POA 和 LSTM 模型,充分利用 PCA 强大的降维能力以及 LSTM 在时间序列分析方面的能 力,同时结合 POA 算法有效平衡局部搜索与全局搜索的 特性,使得 PCA-POA-LSTM 能够更高效的学习原始数据 信息。在技术层面,解决了高效整合3种方法的难点,能 够保持模型复杂性与确保泛化能力之间的平衡。通过深 入分析模型的构建与优化,不仅提高了涡轮输出参数预 测的准确性与鲁棒性,同时为航空发动机故障预警系统 的开发奠定了坚实基础。未来的研究将集中于模型的进 一步优化与扩展,特别是在应用于大规模数据集和不同 类型涡轮方面。考虑到航空发动机在实际运行中的复杂 性,探索更智能化的模型结构与算法融合将有助于提升 预测精度。此外,结合实时监测数据与先进的机器学习 算法,提出的 PCA-POA-LSTM 模型能够进一步发展为智 能故障诊断与预警系统,显著提升航空发动机的安全性 与可靠性。

# 参考文献

- [1] 李运华,黎雯洋,车鑫.发动机数据实时监控设计与实现[J].制造业自动化,2016,38(6):32-35.
  LIYH,LIWY,CHEX. Design and implementation of real-time monitoring for engine data[J]. Manufacturing Automation, 2016, 38(6): 32-35.
- [2] 殷锴,钟诗胜,那媛,等. 基于 BP 神经网络的航空发动 机故障检测技术研究[J]. 航空发动机,2017,43(1): 53-57.

YIN K, ZHONG SH SH, NA Y, et al. Research on fault detection technology for aero-engine based on BP neural network[J]. Aero-Engine, 2017, 43(1): 53-57.

- [3] 孙海霞,夏毅锐,崔爱永,等. 航空发动机涡轮盘有限 元应力分析[J]. 新技术新工艺,2024(5):34-37. SUN H X, XIA Y R, CUI AI Y, et al. Finite element stress analysis of aero-engine turbine disc [J]. New Technology & New Process, 2024(5): 34-37.
- [4] 陈福锋,杨黎明,宋国兵,等.主动探测式保护关键技术概述及展望[J].电力系统保护与控制,2023,51(15):175-186.

CHEN F F, YANG L M, SONG G B, et al. Overview and prospects of active detection protection key technologies[J]. Power System Protection and Control, 2023, 51(15): 175-186.

[5] 时全局,马波,张海,等. 往复式压缩机小头瓦磨损故 障动力学仿真研究[J]. 机械强度, 2019, 41(6): 1278-1285.

SHI Q J, MA B, ZHANG H, et al. Dynamic simulation study on wear fault of small end bearing in reciprocating compressor[J]. Mechanical Strength, 2019, 41(6):

1278-1285.

- [6] LU G L, WEN X, HE G S, et al. Early fault warning and identification in condition monitoring of bearings via wavelet packet decomposition coupled with graph [J].
   IEEE-ASME Transactions on Mechatronics, 2022,27(5): 3155-3164.
- [7] SUN ZH Y, WANG ZH P, LIU P, et al. An online datadriven fault diagnosis and thermal runaway early warning for electric vehicle batteries [J]. IEEE Transactions on Power Electronics, 2022, 37(10): 12636-12646.
- [8] WU X, LI Y. Self-learning based centrifugal compressor surge mapping with computationally efficient adaptive asymmetric support vector machine[J]. Journal of Dynamic Systems, Measurement, and Control, 2012, 134(5), DOI: 10.1115/1.4006219.
- [9] 夏存江,詹于游. 基于改进的 SENet 航空发动机振动 预测[J]. 航空动力学报,2022,37(12):2807-2817. XIA C J, ZHAN Y Y. Vibration prediction of aero-engine based on improved SENet [J]. Journal of Aerospace Power, 2022, 37(12): 2807-2817.
- [10] 陶金伟,王浩楠. 涡扇发动机气路故障的信息融合诊断方法[J]. 测控技术,2021,40(4):8-12,57.
  TAO J W, WANG H N. Information fusion diagnosis method for bypass engine gas path faults[J]. Measurement & Control Technology, 2021, 40(4): 8-12,57.
- LIN L, HE W, FU S, et al. Novel aeroengine fault diagnosis method based on feature amplification [J]. Engineering Applications of Artificial Intelligence, 2023, 122, DOI: 10. 1016/J. ENGAPPAI. 2023. 106093.
- [12] 伍济钢,文港,杨康.改进一维卷积神经网络的航空发动机故障诊断方法[J].电子测量与仪器学报,2023,37(3):179-186.
  WUJG, WENG, YANGK. Fault diagnosis method for aero-engine based on improved 1D convolutional neural network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 179-186.
- [13] 尚超,Fengqi You.智能过程制造中的数据解析与机器学 习——大数据时代的最新进展与展望[J].Engineering, 2019,5(6):1010-1016,1120.
  SHANG CH, YOU F Q. Data analysis and machine learning in intelligent process manufacturing—Latest progress and prospects in the era of big data [J]. Engineering, 2019, 5(6): 1010-1016,1120.
- [14] MA X, ZHANG C, LI K. Hybrid modeling and efficiency analysis of the scroll compressor used in micro compressed air energy storage system [J]. Applied Thermal Engineering, 2019, 161: 114139.
- [15] 王笑晨,陈玉春,贾琳渊,等.回热式工质驱动分布式 推进系统参数研究[J].推进技术,2022,43(9): 60-68.

WANG X CH, CHEN Y CH, JIA L Y, et al. Parameter study of regenerative working medium driven distributed propulsion system [J]. Propulsion Technology, 2022, 43(9): 60-68.

- [16] ARIAS CHAO M, KULKARNI C, GOEBEL K, et al. Aircraft engine run-to-failure dataset under real flight conditions for prognostics and diagnostics [J]. Data, 2021, 6(1):5.
- [17] 郭尚志,廖晓峰,李刚,等. 基于 PCA 的大数据降维应用[J]. 计算机仿真,2024,41(5):483-486.
  GUO SH ZH, LIAO X F, LI G, et al. Application of PCA for big data dimensionality reduction[J]. Computer Simulation, 2024, 41(5): 483-486.
- [18] 范勇,胡名东,杨广栋,等. PCA-GWO-SVR 机器学习用 于边坡爆破振动速度峰值预测研究[J]. 振动工程学 报,2024,37(8):1431-1441.

FAN Y, HU M D, YANG G D, et al. PCA-GWO-SVR machine learning for predicting peak velocity of blasting vibration in slopes[J]. Journal of Vibration Engineering, 2024,37(8):1431-1441.

[19] 陈勇,李鹏,张忠军,等. 基于 PCA-GA-LSSVM 的输电 线路覆冰负荷在线预测模型[J].电力系统保护与控 制,2019,47(10):110-119.

> CHEN Y, LI P, ZHANG ZH J, et al. Online prediction model of ice load on transmission lines based on PCA-GA-LSSVM[J]. Power System Protection and Control, 2019, 47(10): 110-119.

[20] 张厚,刘长良,王梓齐. 基于 PCA 和改进 TOPSIS 法的 电厂混煤配比方案综合评价[J]. 热力发电,2019,48 (11):73-78.

ZHANG H, LIU CH L, WANG Z Q. Comprehensive evaluation of coal blending scheme in power plants based on PCA and improved TOPSIS [J]. Thermal Power Generation, 2019, 48(11): 73-78.

[21] 李杨,蓝茂蔚,赵国钦,等. 基于 PCA-PSO-LSSVM 的电 站锅炉效率预测模型研究 [J]. 热力发电, 2021, 50(12):43-50.

> LI Y, LAN M W, ZHAO G Q, et al. Research on prediction model of boiler efficiency based on PCA-PSO-LSSVM[J]. Thermal Power Generation, 2021, 50(12): 43-50.

[22] 刘鑫洋,李秋红,周文祥,等.涡轴发动机稳态性能退 化缓 解 控 制 方 法 [J]. 推 进 技 术, 2023, 44 (2): 285-295.

> LIU X Y, LI Q H, ZHOU W X, et al. Control method for mitigating steady-state performance degradation of turboshaft engines [ J]. Propulsion Technology, 2023, 44(2): 285-295.

[23] 谢锦阳,姜媛媛,王力. 基于 RA-LSTM 的轴承故障诊 断方法[J]. 电子测量与仪器学报, 2022, 36(6): 213-219.

XIE J Y, JIANG Y Y, WANG L. Bearing fault diagnosis method based on RA-LSTM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 213-219.

- [24] TROJOVSKY P, DEHGHANI M. Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications[J]. Sensors (Basel), 2022, 22(3): 855.
- [25] KINGMA D P, BA J. Adam: A method for stochastic optimization [ J ]. ArXiv preprint arXiv: 1412. 6980, 2014.
- [26] 陈刚,段洁,衣文索,等. 基于 BOTDR 散射谱的应变提 取方法研究[J]. 仪器仪表学报,2021,42(1):75-81.
  CHEN G, DUAN J, YI W S, et al. Research on strain extraction method based on BOTDR scattering spectrum[J].
  Chinese Journal of Scientific Instrument, 2021, 42(1): 75-81.
- [27] 王敬翰,吕杰,赵丁,等.基于 BP 神经网络的电动汽 车动力电池产热估计[J].化工进展,2024,43(1): 400-406.

WANG J H, LYU J, ZHAO D, et al. Heat generation estimation of electric vehicle power batteries based on BP neural network [J]. Chemical Industry Progress, 2024, 43(1):400-406.

# 作者简介



刘斌,2004年于沈阳工业大学获得学 士学位,2007年于沈阳工业大学获得硕士 学位,2013年于沈阳工业大学获得博士学 位,现为沈阳工业大学信息学院教授、院长, 主要研究方向为管道、钢轨、飞机等装备的 无损检测技术。

E-mail: 13998284051@163.com

Liu Bin received his B.Sc. degree from Shenyang University of Technology in 2004, M.Sc. degree from Shenyang University of Technology in 2007, and Ph.D. degree from Shenyang University of Technology in 2013, respectively. Now he is a professor and the dean at the School of Information Science, Shenyang University of Technology. His main research interests include non-destructive testing technologies for pipelines, rails, aircraft, and other equipment.



**白红艳**(通信作者),2019年于沈阳工 业大学获得学士学位,2024年于沈阳工业 大学获得硕士学位,主要研究方向为航空发 动机健康管理技术。

E-mail: 758269768@ qq. com

**Bai Hongyan** (Corresponding author) received her B. Sc. degree from Shenyang University of Technology in 2019 and M. Sc. degree from Shenyang University of Technology in 2024. Her main research interest is health management technology for aero-engines.