

基于多源传感与双分支网络的 旋转设备预测性维护算法

郝朋越, 郭丽敏, 柴一清, 刘庚辰, 谢红辉, 杨旭, 李衍志
(中国恩菲工程技术有限公司, 北京 100038)

摘要: 伴随工业装备复杂度及自动化程度的持续提高, 传统事后检修与定期维保模式难以满足现代工业生产对设备可靠性与安全性的严苛要求; 针对现有检测算法对异常样本量敏感、运算效率低、难以满足实时性需求等问题, 基于双分支预测网络架构设计了一种融合振动、温度、电压及电流等多源传感信号的设备预测性维护算法; 该算法挖掘设备健康状态下多维传感器数据特征, 捕捉正常工况运行规律, 实现当前时刻数据的可靠预测; 基于预测值与实测值绝对误差的分布特性建立高斯统计模型, 通过监测数据与该模型的偏离程度自动判定设备异常状态, 并量化评估异常等级以生成差异化的处理策略; 实验验证表明, 所提双分支预测网络平均绝对误差为 0.069, 推理速度达 1 593 SPS, 表现出优异的预测精度与实时性能; 在设备异常工况下, 能依据传感器数据异常程度自动触发相应处理机制; 该研究成果为工业设备智能化运维提供了高效可靠的解决方案, 具备显著的工程应用价值。

关键词: 设备预测性维护; 多源传感器信号; 生成式技术; 故障预警

A Predictive Maintenance Method for Rotating Equipment Based on Multi-Source Sensing and Dual-Branch Network

HAO Pengyue, GUO Limin, CHAI Yiqing, LIU Gengchen, XIE Honghui, YANG Xu, LI Yanzhi
(China Enfi Engineering Technology Co., Ltd., Beijing 100038, China)

Abstract: With the continuous increase in the complexity of industrial equipment and the level of automation, it is difficult for traditional post-repair and periodic maintenance models to meet the stringent reliability and safety requirements of modern products. Existing detection algorithms have the characteristics of sensitivity to the number of anomalous samples, low computational efficiency, and inadequate real-time performance. To address these issues, a predictive maintenance algorithm based on a dual-branch forecasting network is proposed, which fuses the signals of multi-source sensors, including vibration, temperature, voltage, and current. The algorithm learns the features of multi-dimensional sensor data under healthy equipment conditions, captures normal operating patterns, and reliably predicts current data. A Gaussian statistical model is then established from the distribution features of absolute errors between predicted values and actual measurements; By monitoring the deviation between the data and the model, the method automatically identifies abnormal states of equipment, quantifies the severity level of anomalies, and generates differentiated response strategies. Experimental results show that the proposed dual-branch network achieves a mean absolute error of 0.069 and an inference speed of 1 593 samples per second (SPS), demonstrating excellent predictive accuracy and real-time performance. Under abnormal operating conditions, it automatically triggers appropriate handling mechanisms based on the degree of sensor anomalies. The research results provide an efficient and reliable solution for intelligent operation and maintenance of industrial equipment, with significant engineering application value.

Keywords: equipment predictive maintenance; multi-source sensor signals; generative technology; fault warning

收稿日期:2025-08-14; 修回日期:2025-09-19。

基金项目:国家科技部重点研发计划(2022YFB3304901)。

作者简介:郝朋越(1981-),男,硕士,高级工程师。

通讯作者:李衍志(1994-),男,博士,工程师。

引用格式:郝朋越,郭丽敏,柴一清等.基于多源传感与双分支网络的旋转设备预测性维护算法[J].计算机测量与控制,2026,34(2):80-86.

0 引言

设备预测性维护技术是保障企业生产稳定性和降低运维成本的关键手段^[1-3]。随着工业领域的发展,出现了设备需求量大,迭代更新快,结构日益复杂的问题。传统固定周期的预防性维护策略^[4]已难以满足需求,存在资源浪费和维护效率低下等问题。

在工业监测领域,传感器数据的异常检测对设备故障诊断和实时监测尤为重要。传统的门限设定法,振动信号分析法需要人为的设定上下限和提取异常特征。人为设定的参数很难自适应非平稳非线性的工况,很难挖掘到高维的深层故障模式。近年来,深度学习算法的快速发展为这一领域的研究提供了新的思路。在深度学习应用于传感器异常数据检测算法中,主要有无监督聚类、有监督二分类及重建共3种算法。其中,无监督聚类算法和有监督二分类算法都通过大量数据将模型拟合,借助模型将测试数据分为故障数据和检测数据。但是,在工业现场中,故障数据是很稀少的,短时间很难收集到足以训练模型的故障数据。而重建算法仅依赖正常数据训练自编码模型。通过人为设定阈值来比较重构信号和真实信号的误差来判断是否发生故障。但是自编码模型大多参数量巨大,运算效率低下,在现场环境下很难实时的检测出设备发生的异常。

针对上述问题,本文围绕设备预测性维护中的异常检测算法展开研究,提出一种基于多源传感与双分支网络的旋转设备预测性维护算法。该算法参数量小,模型效率高,能自适应设定误差阈值以适配不同的工况场景。该算法集成多维度传感器阵列,确保数据采集的全面性和准确性。通过趋势分析及频谱分析,有效剔除环境与设备正常波动造成的假阳性异常信号采用生成式机器学习模型,对处理后的数据进行深度分析,学习并建立正常工作状态下的数据特征模型。对比实时数据与模型预测,能够即时识别出偏离正常模式的异常数据和异常程度值,精确定位传感器故障或设备运行异常,从而提前预警潜在的设备损坏或工艺失控风险,还可推广至其他多种工业场景,为设备智能运维提供通用化解决方案^[5-9]。

1 设备预测性维护算法相关研究

1.1 无监督聚类相关算法

聚类是一种无监督学习算法,旨在根据数据的内在相似性将未标注的数据集划分为多个类别,使相似样本归为同一簇,而差异较大的样本分至不同簇^[10-12]。传统的聚类算法可以分为五类:基于划分的聚类、基于模型的聚类、基于层次的聚类、基于密度的聚类、基于模型的聚类。近年来,新型聚类算法不断涌现,如谱聚类、

核聚类、不确定聚类、基于熵和粒度的聚类等,进一步提升了算法的适应性和精度^[13-14]。

文献[15]将振动信号聚类分析应用于风力涡轮机工况监测,通过引入协同推荐优化算法显著提升聚类算法预测准确性至93%,实现了故障类型的准确分类与预防性维护。随后,文献[16]采用聚类算法处理变压器绝缘油溶解气体数据,成功识别出高能电弧放电、油温异常等四类典型故障模式,为电力设备状态评估提供了新思路。在旋转机械故障诊断领域,文献[17]系统地对比了聚类算法与支持向量机等机器学习算法在涡扇发动机故障预测中的性能差异。针对轴承故障特征提取难题,文献[18]结合Hilbert包络解调与全矢融合技术预处理信号,使聚类分析的预测准确率提升至90.64%。无监督聚类通过对拥有不同程度健康等级的数据聚类,得到聚类中心然后判断当前值距离哪个聚类中心更近,以此来判断设备的状况。

聚类算法可以通过新样本再训练来改变簇的中心,在处理大数据集上表现出良好的性能。但其也存在一些问题,只集中在异常数据点的检测,没有深入数据异常的程度,对于设备故障诊断和状态实时监测作用较小,并且算法运行速度慢,实时性差。

1.2 基于二分类和重建的相关算法

基于二分类的算法,将数据分为正常数据和异常数据两类并分别标注,然后利用机器学习算法训练分类模型,最后根据分类模型输出的结果判断数据是否异常^[19]。这种算法在使用时需要以大量的异常数据为基础,但是实际工况中工业设备故障的频率基本不高,难以集齐该算法所需的异常数据样本量。同时该算法也没有考虑当前传感器数据与在时序上与历史数据的关系。

基于重建的算法其底层原理在于训练时所有数据都采用正常数据,神经网络来学习正常数据的重建映射关系,如果出现异常数据那么该数据就不符合正常数据的重建映射关系,神经网络会输出更大的重建误差^[20]。该类算法,虽然克服了异常数据样本难以集齐的困难,但是该类算法在训练过程中会生成较为庞大的数据字典。设备工况越复杂,设备投入使用的时间越长,用传感器数据训练生成的数据字典越大,会严重影响算法的运行速度。

2 设备预测性维护处理算法

2.1 设备预测性维护算法概述

通过对设备进行全方位监测,实时获取设备的振动、温度、电压、电流中的异常信号,结合深度学习算法中的生成式学习技术,通过持续监测这些关键信号,在设备发生故障之前捕捉到异常的迹象,其主要流程如

图 1 所示。首先从传感器上获取时序数据；然后通过傅里叶变换提取频域信息，将时序数据和频域信息一起作为训练好的双分支预测网络输入，双分支预测网络的输出为预测值；紧接着计算预测值与实际值的绝对误差；最后计算绝对误差与建立好的高斯模型的偏离程度。由于训练双分支预测网络和建立高斯模型时都是使用的正常数据，所以发生的异常越大，偏离程度就越大，设备异常等级也越高。




图 1 设备预测性维护处理算法流程

2.2 设备预测性数据的特征提取

根据设备机理和结构安装阵列式传感器，将各个传感器数据传输到高速数据采集器，再发送到网关，网关统一发送到服务器进行处理。振动信号、压力传感器信号、温度传感器信号等，都属于离散数字信号，离散的数字信号包含时域和频域两种信息。时域信息如信号的幅值、峰值、峭度等随时间的变化规律能反映信号的瞬态特性和时间序列趋势；频域信息则可揭示信号的周期性规律和隐藏的频率特征如设备的特定频率振动峰值。二者结合可覆盖信号在时间和频率维度的完整特征空间，避免单一域信息的片面性，提升神经网络的预测精度。服务器接收到传感器数据之后对其进行傅里叶变换计算频谱。其时域波形图及傅里叶变换的频谱如图 2 所示。采用傅里叶变换将传感器信号从时域转换到频域，其转换过程如公式 (1) 所示：

$$x(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-(2\pi i / N)kn} \quad (1)$$

式中， $x(k)$ 代表第 k 个频率分量， $x(n)$ 是原始信号的第 n 个采样点， N 表示样本点的总数量， i 是虚数单位。对于每一个频率点 k ，将时域信号的所有采样点 $x(n)$ 分别与一个复数旋转因子 $e^{-(2\pi i / N)kn}$ 相乘并累加，该旋转因子代表了不同频率的正弦和余弦基函数，通过这种加权求和，FT 将时域信号分解为不同频率的正弦波叠加形式，从而得到频域频谱，为故障诊断和预测性维护提供频域特征依据。

2.3 设备数据预测分析

针对工业场景中异常样本稀缺而正常数据充足的特点，采用无监督学习策略，利用海量正常数据训练双分支神经网络模型以学习设备正常运行模式。首先，根据




图 2 时域波形图及其频谱

现场的实际运行记录，对历史数据片段进行挑选和分类，挑出所有的正常运行的情况下的传感器数据。因为正常数据的变化都在一定范围内，而异常数据的变化是难以预估的。且设备异常的情况是偶发的，短时间内难以获得足够的异常样本。因此将正常数据作为模型训练的基础，训练过程中每个正常数据片段从头开始，以 N 个数据点为长度划分数据 (N : 表示正整数，以每个传感器数据具体情况通过实验得出)，以 $N+1$ 个数据点为训练的历史数据，第 $N+1$ 个数据为神经网络的预测值。

如图 3 所示，双分支异常数据检测网络的核心思想是通过并行结构分别处理信号的时序图和频谱图。两个分支均采用两层一维卷积层与池化层，分别提取时域与频域的特征表示。其中一维卷积层卷积核为 3，步长为 1，补充为 1；池化层核为 2，步长为 2。全连接层将提取到的分布式特征映射到统一的样本特征空间。网络引入自适应池化机制，以捕捉不同特征通道的重要性，并对样本特征空间进行自适应加权融合。这一机制能够根据输入数据的特性动态调整权重：当任务更依赖频域信息时，权重 W_2 增大；当更依赖时域信息时，权重 W_1 增大，从而增强模型对多源信息的感知与整合能力。最终，将加权的时域和频域特征进行融合，并通过多层全连接层得到预测的输出。

双分支数据预测神经网络一条支路负责通过卷积神经网络对时序数据进行特征提取，另外一条支路负责对输入数据的频谱信息进行分析，然后通过神经网络的自适应权重结合两条支路的频域信息和时域信息，最后通过全卷积层输出预测结果。将神经网络设置为双分支形式，可以将任务拆解为“时序特征提取”和“频域特征




图 3 双分支数据预测神经网络结构图

提取”, 每个分支仅需针对单一数据类型有利于神经网络的轻量化和增强特征提取能力, 同时避免传统单一网络需要对深层网络的中间特征进行多次转换或跨层传递带来的额外计算开销。

3 设备预测性维护实验

3.1 实验环境及数据集介绍

本文提出的算法已在赣州恩菲环保能源有限公司生活垃圾焚烧发电项目中投入实际验证。该项目由中国恩菲工程技术有限公司投资建设, 设计总规模为日处理生活垃圾 1 600 t, 其中一期工程 (1 200 t/d) 于 2018 年 6 月投产, 二期工程 (400 t/d) 于 2020 年 4 月底实现并网发电。电厂采用先进的生活垃圾焚烧技术, 实现了垃圾的无害化、减量化和资源化处理。

现场监测对象包括一次风机、二次风机、引风机、凝结水泵、国产工频锅炉给水泵、变频锅炉给水泵以及雾化器等关键旋转设备。振动信号通过新部署的温振一体传感器采集, 该传感器分别安装于设备的输入端、输出端及轴承侧等关键测点, 如图 4 所示。




图 4 风机类设备传感器测点示意图

如图 5 所示, 数据传输依托于高速数据采集器与网关系统, 振动和温度数据由阵列式传感器采集后, 经采集器传输至网关, 最终上传至云服务器, 支持远程多终端实时监测。

算法训练在配备 Intel® Xeon® Silver 4210R CPU @ 2.40 GHz、64 GB 内存和一张 NVIDIA A5000 (24 GB) 的服务器上进行, 系统环境为 Windows 64 位操作系统与 Python3。模型训练优化器选用 SGD。超参数设置方面, 输入序列长度固定为 100, 学习率设为 0.001。

3.2 评价指标

在设备预测性维护的神经网络模型中, 采用平均绝对误差, 均方根误差这两个关键指标来评估模型的性

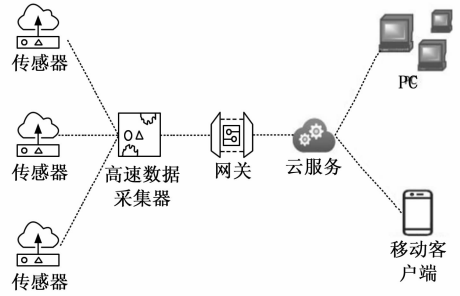


图 5 传感器数据采集传输链路

能。平均绝对误差直接反映预测值与真实值的平均绝对误差, 更直观的体现模型误差水平, 其计算过程如公式 (2) 所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |V_{P_i} - V_{r_i}| \quad (2)$$

其中: MAE 为平均绝对误差, n 为测试样本数量, V_{P_i} 和 V_{r_i} 分别为测试集数据的预测结果和真实值, i 为被测样本序号。直接反映预测值与真实值的平均绝对偏差, 更直观地体现模型误差水平。均方误差计算如公式 (3) 所示:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (3)$$

式中, RMSE 为均方误差, m 为样本数量, i 为被测样本序号, y_i 表示真实值, \hat{y}_i 为预测值。

3.3 预测性维护算法实验参数设置及结果分析

实验过程中双分支预测神经网络, 训练集测试集验证集比例为 6 : 2 : 2, 总数据量 52 000 条。模型训练损失函数采用均方误差通过平方差惩罚较大误差, 加速模型收敛。实验结果表明, 所提算法平均绝对误差为 0.069, 能准确通过历史数据预测当前数据值。上述神经网络训练过程中, 使用均方误差损失作为损失函数。其计算过程如公式 (4) 所示:

$$Loss = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (4)$$

x_i 和 y_i 分别为模型的预测值和真实值, n 为样本的数量。均方误差损失由于采用了平方差, 对于误差给予了更大的惩罚, 有助于模型更好地根据历史数据来预测当前数据值。同时在优化过程中提供了明确的梯度方向, 可以帮助模型更快的收敛到局部最小。训练过程中保留在验证集上预测值与实际值损失最小的模型。训练时 50 个 epoch 内损失值不再降低则表示模型收敛, 停止训练。

在高斯建模与预警判断的实现中, 需在预测模型训练完成后, 为每个传感器通道的预测误差序列分别建立以均值 (μ) 和标准差 (σ) 为参数的高斯统计模型; 在实际推理过程中, 通过计算实时数据误差与模型参数的

标准差倍数进行异常等级判定，并依据预设阈值触发相应预警；为保持模型对设备状态的准确表征，系统每月需基于新采集的健康数据动态更新各通道的高斯模型参数，此次维护需要一年左右，以避免气候问题影响实际工况。

模型训练完成后对训练的模型进行测试，首先随机取正整数 N 开始划分训练数据的长度，对测试数据进行预处理后输入训练好的网络模型得到预测值，计算所有预测值和真实值之间的平均绝对误差，计算算法如公式 (4) 所示。根据实验结果随机增大或者减少 N 值，重复上述过程进行实验。

如果 N 值增大， M_b 值就减小，则下次实验时继续增大 N 值，直到 M_b 值不再变化时，确定该 N 值为最佳取值。同理如果 N 值减小， M_b 值减小，则下次实验时继续减小 N 值，直到减小 N 值， M_b 值不再变化或者减小时，确定该 N 值为最佳取值。如表 1 所示为设备温度传感器数据预测平均误差，随 N 值改变的情况。当 N 值较小时由于对应数据长度太短，信息量不足，其平均误差较大，当 N 值接近 100 时平均误差基本降到最小， N 值超过 100 时由于所用的历史数据过长，存在冗余信息影响算法性能，平均误差又开始逐渐增大。因此 N 值取 100 为最佳取值。

表 1 设备温度传感器数据预测平均误差表

序号	N 值	平均误差
1	20	0.51
2	30	0.41
3	50	0.35
4	70	0.38
5	90	0.22
6	100	0.10
7	120	0.13
8	110	0.12
9	105	0.12
10	103	0.11
11	101	0.10
12	99	0.11

结合现场的实际情况，将异常程度值划分为：无异常、一般异常、中度异常、严重异常，并根据不同的异常程度提出对应的建议。当检测到无异常时，表示设备处于正常运行状态，此时无需采取任何特别措施，可以继续保持当前运行状态。若识别到一般异常，可能是由于某些参数轻微偏离正常范围或传感器数据波动较大所致。此时，可以进一步发出预警，并建议进行初步的检查和调试，如检查传感器是否受到轻微污染或松动，调整设备参数等，以确保设备能够继续稳定运行。

当检测到中度异常时，意味着设备存在较为明显的

故障或潜在风险。则需要立即发出报警，并建议采取紧急措施，如停机检查、更换故障部件、调整工艺参数等，以避免设备进一步损坏或生产中断。若检测到严重异常，这表示设备已经发生严重故障或即将面临失控风险。此时，需要立即启动紧急停机程序，并建议立即组织专业人员对设备进行全面检查和维修，确保设备能够尽快恢复正常运行，同时防止事故扩大和造成更严重的后果。

3.4 数据预测算法模型对比验证

为了验证本算法的有效性与准确性，本研究选取了 TCN^[21]、LSTM^[22]、Informer^[23] 及 Autoformer^[24] 作为对比算法进行实验。其中，TCN 利用多层一维卷积提取单通道数据的时序特征；LSTM 依靠其门控机制建模时序依赖关系；Informer 通过在多头注意力中引入稀疏注意力机制，有效降低了 Transformer 的计算复杂度；Autoformer 则结合了趋势分解与自回归注意力，重点捕捉序列的周期性趋势。为了公平比较，所有对比模型均采用了与本算法 (Ours) 相似的双分支融合策略：即时域数据与频域数据分别输入两个结构相同的子网络，其输出相加后得到最终预测值。所有模型均使用 SGD 优化器 (学习率 0.003)，输入序列长度均为 100 个数据点。

表 2 不同预测算法性能对比分析

算法	推理速度/SPS	MAE	RMSE
TCN ^[21]	910	0.478	0.27
LSTM ^[22]	317	0.241	0.075
Informer ^[23]	222	0.175	0.044
Autoformer ^[24]	238	0.386	0.191
Ours	1 593	0.069	0.009

从表 2 中可以看出双分支数据预测算法，推理速度明显高于其他算法，其根本原因在于传统单一网络，往往需要通过加深网络层级如堆叠更多 LSTM 层或卷积层来覆盖复杂模式，导致前向传播时的计算路径更长。而双分支结构将任务拆解为“时序特征提取”和“频域特征提取”，每个分支仅需针对单一数据类型设计轻量化子网络，无需冗余层级即可完成特征提取，直接减少整体计算量。




图 6 不同算法时序数据预测结果对比

结合图 6 和表 2 综合分析，本文所提算法在数据预

测性能上也优于其他对比算法, MAE 和 RMSE 指标都高于对比算法。从理论上分析, TCN 依赖一维卷积进行特征提取, 对输入序列的数据变化值敏感性差, 导致其表现欠佳。LSTM 虽然能依赖长短期依赖, 但是其容易受到短期波动的影响, 严重影响了预测的连贯性, 导致其波动较大, Transformer 类模型在长序列中表现突出, 但是在要求高精度短序列的场景下效果较差, Informer 侧重于关键信息, 导致其与实际值拟合效果较差。而 Autoformer 模型聚焦于趋势捕捉, 二者均难以充分表述短序列内部复杂的颗粒度关联。此外, 庞大的注意力参数量会对输入时出现的异常点敏感性差, 容易在追踪实际值的过程中出现偏移。相比之下, 本文仅采用时频双分支结构的预测模型通过融合时域和频域特征, 模型能更全面地刻画传感器数据的内在模式减少单一域特征的片面性, 从而降低预测误差。

3.5 典型一次风机验证案例

该算法目前已经部署到赣州泵类、风机类、雾化器等三类设备上。一次风机的温振一体传感器安装在电机驱动端、过桥轴承输入端、过桥轴承输出端, 一次风机所有传感器于 2024 年 10 月安装完毕。其他压力、电流、电压传感器数据已经在二期工程建设完毕时就已经安装, 因此直接从现有 DCS 系统获取即可。

实施过程中, 现场持续采集 3 个月的设备正常运转的传感器数据来训练预测模型, 训练集数据和验证数据集测集划分比例为 6:2:2。预测模型训练完成后, 开始建立设备正常运行时, 传感器数据预测值与实际值绝对误差的高斯模型。由于预测性模型是用设备正常运行时的数据训练出来的, 所以一旦出现设备故障或者异常时, 预测值与实际值的绝对误差就会变大, 偏离建立好的高斯模型。偏离程度越远, 说明异常程度越大。高斯模型如公式 (5) 所示:

$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5)$$

式中, μ 为均值, σ 为标准差, x 为各传感器实际值与预测值的绝对误差。根据高斯分布的特性和数据统计分析, 1 倍标准差到 2 倍标准差之间的数据占比最大, 2~3 倍标准差之间的数据次之, 3 倍标准差之外的数据最少。因此实践过程中设置绝对误差处于 2~3 倍标准差之间时, 判定为轻度异常, 3~5 倍之间时判定为中度异常, 大于 5 倍标准差判断为高度异常。

在赣州垃圾焚烧发电厂 2 号炉一次风机上, 算法监测系统在 2025 年 5 月 10 日首次检测到电机驱动端垂直方向振动速度 (mm/s) 的预测值与实际值的绝对误差开始持续超出正常范围。正常情况下, 该测点的绝对误差均值 μ 约为 0.05 mm/s, 标准差 σ 约为 0.02 mm/s。5 月 10 日当天, 该误差值达到约 2.3σ (即约 0.096 mm/s),

系统判定为轻度异常, 并自动提示现场人员注意观察该设备运行状态。现场听到异常声音但未进行检修处理, 随后, 该异常信号持续存在并逐渐发展。至 2025 年 7 月 20 日, 该测点的绝对误差值已增长约 3.8σ (即约 0.126 mm/s), 达到中度异常等级。系统随即发出明确的报警提示。现场人员根据报警信息对设备进行检查, 拆开维护后发现设备转子存在轻微不对称情况。维护工作完成后, 电机驱动端振动速度的预测误差迅速回落至 1.2σ 以内 (约 0.074 mm/s), 设备运行状态恢复正常。

4 结束语

本文提出了一种基于多源传感与双分支网络的旋转设备预测性维护算法, 通过协同融合振动、温度、电压与电流等多源传感器数据, 构建双分支时频联合神经网络, 有效提取并融合时域与频域特征, 可判断设备的实时状态、识别预期风险并给出运维方案。在赣州恩菲环保能源有限公司生活垃圾焚烧发电项目的实际应用中展现出优异性能: 实测平均绝对误差低至 0.069, 推理速度达 1 593 SPS, 满足工业现场实时性要求; 以一次风机为例, 基于仅利用正常数据训练的高斯模型, 成功实现对振动信号异常的早期识别, 提前 2 个月发现潜在故障并在异常达到中级时发出预警, 验证了其在复杂工况下的鲁棒性与实用性, 有效解决了工业场景中异常样本稀缺的难题; 然而, 当前算法主要聚焦于异常检测与程度评估, 尚难以精准识别轴承磨损、转子不对中、皮带松动等具体故障类型, 限制了维护决策的精确性, 为此, 未来研究将构建基于知识图谱的故障诊断机制, 系统性地建立“异常特征—故障类型—维修建议”的关联规则知识库, 通过挖掘历史数据中典型故障的多源信号特征模式 (如特定频段振动能量变化对应转子不对中), 结合领域知识实现从“异常预警”到“根因定位”的闭环, 推动预测性维护向智能化、可解释化方向发展, 进一步提升设备运维效率与系统可靠性。

参考文献:

- [1] 李杰其, 胡良兵. 基于机器学习的设备预测性维护算法综述 [J]. 计算机工程与应用, 2020, 56 (21): 11-19.
- [2] 朱正伍. 面向智能制造的时代电气设备预测性维护管理优化研究 [D]. 株洲: 湖南工业大学, 2022.
- [3] 杨恩睿. 智能技术在变电设备预测性维护中的应用 [J]. 集成电路应用, 2025, 42 (3): 226-227.
- [4] 祝旭. 故障诊断及预测性维护在智能制造中的应用 [J]. 自动化仪表, 2019, 40 (7): 66-69.
- [5] 陶冲. 机械设备的故障诊断与维护策略研究 [J]. 模具制造, 2025, 25 (4): 237-239.

