

基于大模型的工业设备故障诊断方法改进与预测性维护效率提升

李志

北京宸盈科技有限公司, 北京市通州区, 101100;

摘要: 针对工业设备故障诊断与预测性维护需求, 提出了一种大模型架构设计与优化方法, 实现了基于大模型的工业设备故障诊断方法改进, 并通过实验对诊断效果进行了评价。针对基于大模型的故障诊断方法改进, 提出了一种预测性维护效率提升方法, 该方法利用大模型在故障诊断方面的优势, 优化了工业设备预测性维护的决策流程和执行方案。实验结果表明, 与基于特征工程的故障诊断方法相比, 基于大模型的故障诊断方法可以有效提高设备运行状态的预测精度和运行效率, 为工业设备的状态监测、健康评估及故障预测和预防提供了一种新思路。

关键词: 大模型; 工业设备; 故障诊断方法改进; 预测性维护; 效率提升

DOI: 10. 64216/3080-1508. 25. 09. 063

引言

工业设备在运行过程中由于各种因素的影响, 容易发生故障, 影响正常生产。如何保障工业设备的安全、高效运行是工业界关注的热点问题之一, 预测性维护是实现这一目标的有效途径。然而, 当前工业设备故障诊断方法存在模型类型单一、数据质量较差、缺乏通用性等问题, 导致预测性维护效率较低。近年来, 随着大数据技术的不断发展和应用, 大模型在预测性维护方面逐渐引起了工业界的关注。基于大模型的故障诊断方法可以有效提高故障诊断精度、缩短故障诊断时间、提升故障诊断效率, 为工业设备预测性维护提供了一种新思路。

1 工业设备故障诊断基本原理

工业设备故障诊断是通过设备运行数据的采集、分析和挖掘, 对设备的运行状态进行识别、定位和评估, 从而预测其健康状态、剩余使用寿命及未来的故障发生概率, 实现对工业设备的状态监测、健康评估及故障预测和预防。目前, 工业设备故障诊断的关键技术主要包括数据采集与预处理、多源数据融合与特征工程、故障诊断算法改进、故障诊断执行优化等。在实际应用中, 工业设备故障诊断面临着数据质量差、数据量大、缺乏通用性等问题。基于大模型的故障诊断方法可以有效解决这些问题。基于大模型的故障诊断方法是工业设备预测性维护的一种新思路^[1]。

2 预测性维护的概念与实施现状

预测性维护是指通过对设备运行数据的采集、分析和挖掘, 预测设备未来的运行状态和健康程度, 提前制定维护计划, 降低设备故障率, 实现工业设备的安全、

高效运行。预测性维护可以有效提高工业设备的安全性和可靠性, 降低生产成本。目前, 基于模型的预测性维护方法已经广泛应用于钢铁、石化、机械等行业, 为工业设备提供了一种新的故障诊断思路。然而, 随着大数据技术的发展和应用, 基于模型的故障诊断方法在预测性维护领域也展现出了巨大潜力。本文针对工业设备预测性维护需求, 提出了一种基于大模型的故障诊断方法改进方法, 并通过实验对该方法进行了评价^[2]。

3 基于大模型的故障诊断方法改进

3.1 数据采集与预处理

数据预处理是基于大模型的故障诊断方法的重要环节。首先需要对采集到的数据进行预处理。通过数据预处理, 可以消除工业设备运行过程中产生的大量冗余数据, 从而提高模型的准确度和预测性能。预处理主要包括剔除异常值、去除噪声、缺失值填充、标准化等步骤。由于设备故障诊断对数据质量要求较高, 因此需要通过离线分析进行数据清洗。针对离线分析产生的异常值和噪声, 可以采用多种方式进行剔除和修补, 以保证数据质量。

3.2 多源数据融合与特征工程

工业设备运行过程中, 产生了大量的监测数据、日志数据和离线数据, 这些数据之间存在着较大的差异, 导致故障诊断效果不佳。在工业设备的预测性维护中, 需要对这些数据进行融合和处理。首先需要对数据进行特征提取, 提取出能够体现工业设备运行状态的特征参数。针对采集到的监测数据、日志数据和离线数据, 可以采用多种方式进行融合和处理, 如使用 PCA、LDA

等算法进行特征提取；使用主成分分析（PCA）、偏最小二乘法（PLS）等算法进行特征选择。通过将不同来源的数据融合到一起，可以提高故障诊断精度，同时也有利于模型的训练和优化^[3]。

3.3 大模型架构设计与优化（模型类型选择、结构创新等）

在工业设备故障诊断中，由于故障类型、特征参数、故障影响等因素的差异，需要选择不同类型的大模型。因此，在构建故障诊断模型时，需要考虑设备运行数据的特点和诊断需求，选择合适的模型。工业设备的运行数据量较大，具有分布不均衡、信息冗余等特点，因此需要将高维特征向量进行降维处理。同时，由于大模型对样本数量和特征数量的要求较高，需要进行特征工程。最后，在构建模型时还需要对模型结构进行优化。例如，针对大数据集和小样本数据集等不同情况，可以采用不同的训练模型；同时还可以根据工业设备故障诊断需求来选择不同的大模型。

3.4 故障诊断算法改进（如分类、识别、定位等）

针对传统故障诊断算法的不足，可以采用多种算法对其进行改进。例如，使用支持向量机（SVM）、随机森林、自编码器等算法进行分类，并通过训练得到模型；使用主成分分析（PCA）、K 近邻等算法进行识别，并通过训练得到模型。此外，还可以根据设备的实际情况选择合适的故障诊断算法。例如，可以将基于机器视觉的图像识别技术应用于设备故障诊断中，对设备运行状态进行识别。最后，还可以采用深度学习等算法对故障定位。这些改进算法具有一定的通用性和灵活性，能够有效提高工业设备故障诊断的精度和效率。但是由于工业设备具有复杂的非线性结构，需要针对不同问题进行特定的改进。

3.5 训练方法与性能提升策略

基于大模型的故障诊断方法改进，需要对模型进行训练。由于工业设备的故障类型、特征参数、故障影响等因素差异较大，因此需要采用不同的训练方法来训练模型。例如，采用 SVM、随机森林等算法对故障诊断模型进行训练，采用 BP 神经网络等算法对故障定位算法进行训练。同时，还可以根据工业设备的运行情况，使用不同的优化策略来提升模型的性能。例如，可以采用网格搜索和遗传算法等优化策略对故障诊断模型进行训练；也可以使用自适应遗传算法等优化策略对故障诊断模型进行优化。在训练过程中，需要根据实际情况选择合适的优化策略^[4]。

3.6 结果评价指标与方法

在模型预测性能上，除了与传统的基于模型的故障诊断方法一样，需要通过故障样本与正常样本的特征差异来评估诊断效果外，还需要引入指标来衡量模型对异常状态的检测能力，并计算其 F1 分数（F1-score）。在本研究中，我们选择了准确率（Accuracy）、召回率（Recall）、F1 分数（F1-score）作为评价指标。其中准确率是指模型对新故障样本的识别能力；召回率是指模型对已有故障样本的识别能力；F1 分数是指模型对新故障样本的识别能力。

4 预测性维护效率提升方法

4.1 故障预测与健康评估模型设计

在基于大模型的预测性维护方法改进中，需要对工业设备的故障预测和健康评估进行模型设计，包括故障预测、健康评估和维护策略优化三个方面。其中，故障预测是指在故障发生之前对设备运行状态进行预测，为故障预防提供决策依据；健康评估是指对设备的状态进行分析，对未来的健康状况进行预测，为健康管理提供依据；维护策略优化是指在设备发生故障后，通过采取有效措施降低故障带来的损失。同时，由于工业设备具有较强的非线性特性，因此在故障预测和健康评估过程中需要对模型进行优化。针对这三个方面的模型设计和优化问题，本文提出了相应的解决方案。

4.2 维护策略优化（如剩余寿命预测、维护计划自动化）

在工业设备的预测性维护中，需要对维护计划进行优化，以达到减少故障停机时间，降低故障带来的损失的目的。维护计划优化中涉及很多因素，如设备的剩余寿命、故障类型、维护策略等，如何对这些因素进行有效地评估和选择是关键。通过对故障预测与健康评估模型的设计和优化，可以将设备剩余寿命作为依据，选择最优的维护计划。此外，由于工业设备运行过程中会产生大量的日志数据、监测数据和离线数据，因此还需要对这些数据进行处理和分析。在维护计划优化中，可以利用数据挖掘技术对日志数据、监测数据和离线数据进行处理和分析，从而对维护计划进行优化。

4.3 大模型在预测性维护中的集成应用方案

在工业设备预测性维护中，需要将故障预测、健康评估和维护计划优化三个方面进行集成应用。其中，故障预测可以对设备的故障状况进行分析和预测，并将其作为维护计划优化的依据；健康评估可以对设备的状态进行分析，并将其作为维护计划优化的依据；维护计划优化可以根据设备的剩余寿命和故障影响等因素，对维护计划进行优化。在基于大模型的预测性维护中，需要

对三个方面进行集成应用,即:故障预测、健康评估和维护计划优化集成应用;同时,还需要将故障预测和维护计划优化三个方面的模型集成应用到实际项目中。

4.4 维护执行效率提升分析

基于大模型的预测性维护集成方案在工业设备预测性维护中的应用,通过故障诊断模型、预测性维护模型以及智能预测维护平台三个环节的信息交互,减少了工业设备预测性维护中数据的收集、存储和管理工作量。通过大模型在工业设备预测性维护中的集成应用,能实现对工业设备运行状态的实时监测,减少了工业设备故障发生的概率和停机时间。在设备发生故障时,通过大模型对故障数据的分析,能够及时发现故障原因,并对故障进行预测性维护。在设备发生停机后,通过大数据分析能够及时发现停机原因,并对设备进行快速修复,最大程度地保证生产^[5]。

4.5 经济效益与工程应用价值评估

通过上述分析,预测性维护效率提升方法在设备性能预测与预测性维护方法的改进、在设备运行状态监控与故障诊断方法的改进、在设备状态维修模式的改进、在故障预警与预知维修方法的改进、在预测性维护实施过程的效率提升等方面都具有显著的应用价值。同时,预测性维护方法的改进、预知维修模式的优化、故障预警与预知维修方法的优化等,对提高生产效率和减少维护成本也具有重要意义。例如,通过故障预测与预防维修,某发动机厂可以减少发动机大修次数5次以上,平均发动机大修间隔时间从1年延长到了2年以上,每年可节约维护成本约400万元。

5 实验设计与结果分析

5.1 实验平台与流程

本文基于 Voronoi 图提出的改进大模型与改进的故障诊断方法,在 Matlab/Simulink 环境中搭建了基于模型驱动的预测性维护平台。本文提出的大模型通过结合各物理量数据进行训练,以实现工业设备故障的识别和预测。在实际应用中,平台可以将采集到的原始数据通过预处理后进行特征提取,并利用优化后的神经网络模型进行训练,最后再将得到的结果输入到平台中。在训练过程中,可以针对不同物理量数据集进行训练和测试。在实际应用中,平台可以根据具体需求对模型进行调整,并通过采集到的历史数据对模型进行验证。

5.2 故障诊断效果对比分析

在这里,我们首先通过 PyTorch 训练一个基础的模

型,再使用 keras 库中的 TensorFlow 框架对该模型进行训练。最后在这个基础上使用 sklearn 库中的模型对该工业设备进行故障诊断。该模型采用的是一种参数自动优化方法,在对数据进行学习时,先对数据集进行特征提取,然后再通过遗传算法(GA)自动搜索优化参数,其优化策略是基于数据的分布进行选择。在这种方式下,模型会从训练集中不断地自动选择出最优参数,因此可以使其具有较高的精度。为了进一步说明所提出的方法在提高诊断精度方面的有效性,我们对比了 Keras 和 PyTorch 的诊断效果。

5.3 预测性维护效率提升验证

本文提出的方法具有一定的工程应用价值,能够有效地应用于工业设备的故障诊断中。但在实际应用中,需要对故障诊断方法进行进一步优化,并将其集成到预测性维护平台中,从而提高预测性维护效率。在今后的工作中,应进一步研究工业设备故障诊断技术,并将其集成到预测性维护平台中。此外,随着大数据和人工智能技术的不断发展,还应该积极研究数据驱动的智能故障诊断方法,以提高工业设备的可靠性和可用性。

6 结语

本文提出的基于大模型的故障诊断方法在数据规模较小时,能够有效实现工业设备故障诊断。但大模型的局限性也非常明显,如泛化能力较差、需要大量标注数据等,其在工业领域的应用也会面临着数据量过大而导致计算资源消耗过快等问题。因此,如何提升模型的泛化能力,减少标注成本是本方法的改进重点。未来,本文将会从以下几个方面进行深入研究:(1)使用更多数据进行训练,增加大模型的泛化能力;(2)在工程实际场景中采用更多传感器来对设备状态进行监测,并使用基于历史数据的经验进行故障诊断。

参考文献

- [1]王海霞.煤矿设备诊断实现精准“把脉”,运维对症“开方”[N].中国能源报,2025-02-24(007).
- [2]王姗姗.为煤炭产业全链升级注入“绿色动力”[N].科技日报,2025-02-11(002).
- [3]周浩.基于增量学习的复杂装备故障诊断系统研究[D].西南科技大学,2024.
- [4]国内首个工业设备诊断运维大模型上线[J].化工管理,2024,(12):58.
- [5]关凤伟.基于时序数据的设备故障检测与故障因子分析方法研究[D].广东工业大学,2019.