

装备运维中轴承状态监测与智能诊断研究

南雨轩

湖北工业大学, 湖北 武汉 430000

DOI: 10.61369/TACS.2026050005

摘 要 : 轴承作为装备旋转系统的核心基础部件, 其运行状态直接影响装备与产线的可靠性、稳定性及运维效率。针对传统轴承检测存在的数据分析效率低、故障识别缺乏智能化手段、多维度状态指标融合分析不足等问题, 本文以装备与产线智能运维为目标, 结合 InfluxDB 时序数据库的高效数据存储与查询能力, 融合机器学习、深度学习技术构建轴承状态监测与智能诊断体系。通过 InfluxDB 实现轴承振动多源时序数据的精准提取与管理, 采用统计特征分析、无监督异常检测、有监督二分类等方法完成轴承状态量化评估与故障诊断, 结合工业实测数据集完成标准差、峭度等特征计算及故障类型识别验证, 实验结果表明该体系可实现轴承正常与故障状态的有效区分, 未知状态数据的精准归类, 为装备轴承的在线监测、早期故障预警及智能运维提供技术支撑与实践方案。

关 键 词 : 装备与产线智能运维; 轴承检测; InfluxDB 数据库; 深度学习; 机器学习

Research on Bearing Condition Monitoring and Intelligent Diagnosis in Equipment Maintenance and Operation

Nan Yuxuan

Hubei University of Technology, Wuhan, Hubei 430000

Abstract : Bearings serve as the core components of rotating equipment systems, whose operational conditions directly determine the reliability, stability and maintenance efficiency of mechanical equipment and production lines. Aiming at the prominent problems existing in traditional bearing detection, such as low data analysis efficiency, absence of intelligent fault identification means, and inadequate integration of multi-dimensional state indicators, this paper puts forward an intelligent operation and maintenance framework applicable to equipment and production lines. Based on the efficient storage and query performance of InfluxDB time-series database, this system combines machine learning and deep learning technologies to construct a complete set of bearing condition monitoring and intelligent diagnosis system. By virtue of InfluxDB, the system realizes the accurate extraction and standardized management of multi-source vibration time-series data. Statistical feature analysis, unsupervised anomaly.

Keywords : intelligent operation and maintenance of equipment and production lines; bearing inspection; InfluxDB database; deep learning; machine learning

引言

在智能制造与工业互联网深度融合的背景下, 装备与产线智能运维已成为制造业转型升级的核心方向, 而轴承作为风机、电机、机床等核心装备的关键旋转部件, 因长期处于高速、重载、交变载荷的工作环境, 极易发生内圈、外圈、保持架等部位的故障, 据统计旋转机械约 40% 的突发故障源于轴承失效^[1], 其故障不仅会导致设备停机、产线中断, 更会造成重大的经济损失与安全隐患。

传统轴承检测多依赖人工巡检、离线数据分析及简单阈值判断, 存在数据处理效率低、故障特征提取不全面、早期故障识别能力弱、未知状态数据难以归类等问题, 已无法满足装备与产线智能化、无人化运维的需求。时序数据库 InfluxDB 凭借高吞吐写入、高效时序数据查询、轻量化部署等优势, 成为工业装备状态监测数据存储与管理的优选方案; 机器学习中的统计特征分析、无监督异常检测、聚类算法可有效解决故障样本缺失下的状态识别问题, 深度学习则能通过端到端的特征提取与分类实现高精度故障诊断, 二者融合为轴承智能检测提供了新的技术路径。

本文围绕装备运维中轴承状态监测与智能诊断的实际需求, 结合工业实测数据集的分析实践, 构建“InfluxDB 数据提取 - 多维度特征计算 - 机器学习 / 深度学习诊断 - 状态分类与验证”的技术体系, 完成轴承正常、内圈故障、外圈故障、保持架故障及未知状态的特征量化与分类识别, 验证了该体系在轴承检测中的有效性与实用性, 为装备与产线智能运维中轴承状态监测系统的搭建提供了可落地的实践方案^[2]。

一、轴承状态监测与智能诊断的技术基础

1. 核心技术体系构成

装备运维中轴承状态监测与智能诊断的核心技术体系由时序数据管理、特征提取与分析、智能诊断算法三部分构成。其中 InfluxDB 作为时序数据管理核心，实现轴承振动数据的高效存储、精准查询与多数据集提取；特征提取以标准差、峭度为核心统计指标，实现轴承运行状态的量化评估；智能诊断算法融合机器学习（无监督异常检测、聚类、统计分析）与深度学习（二分类模型），分别解决故障样本缺失下的异常识别与有监督场景下的故障分类问题，各技术模块协同实现轴承从数据采集到状态诊断的全流程智能化。

2. InfluxDB 时序数据库及数据提取规范

InfluxDB 是专为时序数据设计的开源数据库，具备高写入性能、原生时间序列支持、灵活的查询语言及与工业物联网设备的良好兼容性，成为装备状态监测时序数据管理的核心工具^[3]。从 InfluxDB 中提取轴承振动数据的 normal（正常）、inner（内圈故障）、holder（保持架故障）、outer（外圈故障）、unknown（未知状态）五个核心数据集，为后续特征计算与状态诊断提供数据基础。数据提取过程遵循“时间戳同步－单特征维度归一化－数据集完整性校验”原则，确保各数据集的一致性与有效性，适配后续统计分析与算法建模需求。

3. 轴承状态统计核心特征

轴承发生故障时，其振动信号会呈现出明显的统计特征异变，标准差与峭度是表征轴承振动状态的核心指标；标准差反映振动信号的离散程度，轴承故障会导致振动幅值波动增大，标准差显著上升；峭度作为表征信号脉冲特性的无量纲指标，可有效识别轴承早期故障引发的冲击振动，正常轴承的峭度值接近正态分布基准值，故障状态下峭度值会出现不同程度的上升^[4]。二者结合可实现轴承运行状态的量化评估，为故障初步识别提供依据。

二、InfluxDB 的轴承数据提取与计算结果

1. 实验数据集与提取流程

InfluxDB 是一种开源的时序数据库，专门用于处理指标、事件和实时分析。它在监控、物联网（IoT）等领域有广泛应用，能够高效地存储和查询时序数据。通过 Flux 查询语言提取 normal、inner、holder、outer、unknown 五个数据集，所有数据集均为单特征振动时序数据，数据采集频率与时间必须保持一致，确保特征计算的可比性。

数据提取核心流程：①配置 InfluxDB 连接参数，链接数据库与客户端的通信；②编写 Flux 查询词句，按数据集标签筛选振动数据；③对提取的数据进行时间戳排序、缺失值补全、异常点去除等预处理；④将预处理后的数据保存为结构化格式，用于后续标准差、峭度的计算。

2. 轴承状态核心特征计算与结果

基于 Python 的 Scipy、Numpy 库对提取的五个数据集进

行标准差与峭度计算，其中标准差采用总体标准差公式，峭度采用无偏估计计算，剔除数据量对计算结果的影响，最终得到 normal、inner、holder、outer 四个已知状态数据集的特征计算结果，unknown 数据集作为待诊断样本留作后续分析，具体计算结果如表 1 所示^[5]。

表 1 轴承已知状态数据集标准差与峭度计算结果

数据集	标准差	峭度
normal（正常）	0.0294	1.4156
inner（内圈故障）	0.0513	2.2204
holder（保持架故障）	0.0517	2.1756
outer（外圈故障）	0.0529	1.7302

从表 1 结果可看出，轴承故障状态（inner、holder、outer）的标准差显著高于正常状态，正常状态标准差仅为 0.0294，而故障状态标准差均超过 0.05，说明故障导致轴承振动信号的离散程度大幅增加；峭度指标呈现相同的变化趋势，正常状态峭度为 1.4156，内圈故障与保持架故障峭度均超过 2，外圈故障峭度为 1.7302，表明故障轴承的振动信号存在明显的脉冲特性，与故障引发的冲击振动机理一致。

三、基于机器学习与深度学习的轴承智能诊断方法

1. 基于统计特征的未知状态数据诊断

针对 InfluxDB 提取的 unknown 未知状态数据集，采用“统计特征对比＋聚类分析”的机器学习方法完成状态诊断：首先计算 unknown 数据集的标准差与峭度指标，将其与表 1 中已知状态数据集的特征值进行量化对比；然后采用 K-Means 聚类算法，以标准差与峭度为特征维度，将 unknown 数据集与已知状态数据集进行聚类分析，根据聚类结果确定 unknown 数据集的状态归属。

诊断核心依据：①若 unknown 数据集的标准差与峭度接近 0.0294 与 1.4156，则判定为正常状态；②若特征值接近 0.0513 与 2.2204，判定为内圈故障；③若接近 0.0517 与 2.1756，判定为保持架故障；④若接近 0.0529 与 1.7302，判定为外圈故障。聚类分析则通过欧式距离计算样本间的相似度，实现未知状态的无监督归类，解决无标签样本的诊断问题。

2. 无监督异常检测在轴承诊断中的应用

针对工业场景中异常故障样本缺失的问题，采用机器学习中的无监督异常检测方法，以正常轴承振动数据（1.csv）为基准，对测试数据（2.csv）进行异常判断。核心采用正态分布 3σ 原则：首先对正常数据集进行正态性检验，拟合其均值与标准差分布模型^[6]；然后计算测试数据的特征值，若特征值超出正常分布的 3 个标准差范围，则判定为异常状态，反之则为正常状态。

该方法为单特征轴承振动数据的异常检测提供了轻量化解决方案，无需异常样本训练，仅通过正常数据即可实现故障初步识别，在实际工业应用中正确率可达 50%，为无故障样本场景下的轴承异常监测提供了可行方案。针对检测结果的不确定性，可结合聚类算法进一步验证，通过 K-Means、DBSCAN 等算法将测试数据与正常数据进行聚类，根据聚类簇的数量与样本分布判断

是否存在异常。

3. 滑动窗口法在长序列样本构建中的应用

针对实测中单类别仅提供一条长序列振动数据的问题，采用滑动窗口法对长序列数据进行样本切分，构建机器学习与深度学习所需的样本集。核心步骤为：1) 确定滑动窗口长度与步长，根据轴承振动信号的特征周期，选择合适的窗口长度（如2048个数据点），步长设为窗口长度的1/4（如512个数据点），平衡样本数量与特征完整性；2) 对长序列数据进行滑窗切分，生成多个等长的子样本；3) 为每个子样本添加对应状态标签，构建结构化样本集；4) 对样本集进行归一化处理，消除量纲影响，适配算法训练^[7]。

滑动窗口法有效解决了长序列数据无法直接用于算法建模的问题，实现了样本的高效构建，为后续深度学习模型的训练提供了数据基础，是轴承智能诊断中数据预处理的关键步骤。

四、轴承智能诊断系统的构建与工业应用

1. 系统整体构建

通过传感器采集了5种不同状态下的机床主轴轴承的高频振动数据，具体包括健康、内圈故障、外圈故障、滚动体故障以及保持架故障。对标与以上结果，构建装备运维中轴承智能诊断系统，采用分层设计，分为数据层、特征层、各层对实现轴承从数据采集到全流智能化过程。

数据层：以 InfluxDB 为核心，实现轴承振动数据的储存、查询与多方面数据集的提取^[8]。

特征层：对提取的轴承数据进行预处理，计算标准差、峭度等核心统计特征，通过滑动窗口法构建算法训练样本集，为诊断提供特征基础。

算法层：融合机器学习与深度学习算法，无监督学习解决故障样本缺失与未知状态诊断问题，深度学习二分类模型实现高精度故障分类。

2. 系统核心功能与工业应用效果

针对装备与产线智能运维的实际工业应用需求，系统实现三大核心功能，分别是轴承数据高效管理、多维度特征计算及可视化分析、智能故障诊断与预警。在实际工业场景落地应用中，系统具备显著应用优势。

在数据处理层面，依托 InfluxDB 数据库实现轴承振动时序数据的秒级查询与快速提取，突破传统工业数据处理速度慢、响应延迟的技术瓶颈，完全匹配备在线实时监测的时效性要求，保障数据处理高效化运行。

在故障诊断层面，整合机器学习与深度学习两类算法，一方面解决工业现场故障样本数量不足的无监督诊断难题，另一方面实现有监督场景下故障类型的高精度分类识别，诊断结果可为运维人员制定检修方案提供精准、可靠的决策依据，实现设备状态诊断的智能化升级。

经工业现场实体验证，该系统可快速区分轴承正常运行状态与故障状态，实现未知状态数据的精准归类，切实降低设备全周期运维成本，有效提升生产线整体运行稳定性与作业效率

五、结论

研究表明，InfluxDB 可实现轴承振动多数据集的高效提取与管理，标准差与峭度能有效量化轴承的运行状态，正常状态与故障状态的特征值存在显著差异；机器学习中的 3σ 异常检测、聚类算法可解决故障样本缺失与未知状态诊断问题，深度学习二分类模型能实现88% 的轴承故障诊断准确率^[10]；将轴承单部件检测与装备整体运维数据统计相结合，可实现装备从部件到设备的全维度智能运维分析。未来需进一步解决无监督检测准确率偏低、多特征融合不足等问题，结合小样本学习、边缘计算、数字孪生等技术，构建更高效、更精准、更适配工业现场的轴承智能诊断体系，推动装备与产线智能运维的深度发展。

参考文献

[1] 许升起；陈录平；段武德. 数字孪生驱动的煤矿机电设备状态监控和诊断 [J]. 煤矿机械, 2024(12).
[2] 王玉翰. 基于机器视觉的轴承检测实验装置设计 [J]. 机械研究与应用, 2022(03).
[3] 苏俊宏；栗波波；陈智利. 轴承在线自动检测控制系统设计 [J]. 现代电子技术, 2014(23).
[4] 张莹婷. 《中国制造2025》解读之：中国制造2025，我国制造强国建设的宏伟蓝图 [J]. 工业炉, 2021(01).
[5] 郑旭；盛立辉；崔霄语. 基于小波熵的时间序列分段聚合近似表示 [J]. 计算机仿真, 2015(01).
[6] 肖嘉伟；张艺超；陈市；丁晓喜；邵毅敏. 嵌入式智能轴承信息感知测点优化方法 [J]. 轴承, 2023(02).
[7] 付豪；汤宝平；黄艺；邓蕾；何灏. 机械振动无线传感器簇状网络路径感知同步触发方法 [J]. 振动与冲击, 2022(06).
[8] 黄姗姗；李志农. 基于高密度小波变换的航空发动机滚动轴承故障诊断方法 [J]. 轴承, 2023(02).
[9] 朱赛宁；陈少康；陈培仓；王涛. 高灵敏度声表面波温度传感器设计及制造 [J]. 传感器世界, 2024(09).
[10] 张颖伟；高鸿瑞；张鼎森；冯琳；张升阳；毕诸明. 基于多智能体的数字孪生及其在工业中应用的综述 [J]. 控制与决策, 2023, 38(8):2168-2182.