

# 大数据的机械制造设备故障预测与智能维护技术

周小华

抚州比亚迪实业有限公司 江西抚州 344000

**【摘要】**机械制造设备的故障预测与维护对现代工业生产具有重要意义。随着大数据技术的快速发展,基于设备运行数据的智能预测维护体系逐渐成熟。研究采用多源传感数据采集、深度学习算法和智能决策系统相结合的方法,构建了一套完整的故障预测与维护方案。通过对某制造企业数控机床的实验研究表明,该方案显著提高了设备故障预测准确率,有效提升了维护效率,明显减少了设备停机时间。实验结果证实,融合大数据分析的智能维护技术能够全面提升制造设备的可靠性与生产效率,为制造业的智能化转型提供了有力支撑。

**【关键词】**大数据分析;故障预测;智能维护;机械制造;深度学习

## 引言:

工业4.0时代,制造业设备智能化程度不断提高,其可靠性与维护效率直接影响企业生产效益。传统的设备维护方式主要依赖定期检查和经验判断,难以适应现代制造业对设备维护精确性、实时性的要求。大数据技术为解决这一问题提供了新思路。通过采集和分析设备运行过程中的多维数据,结合人工智能算法,可以实现对设备状态的实时监测、故障的提前预警以及维护方案的智能决策。相关研究表明,预测性维护较传统维护方式可显著降低维护成本,提高设备利用率。因此,研究基于大数据的设备故障预测与智能维护技术具有重要的理论价值和实践意义。

## 1 数据采集与预处理

### 1.1 多源传感器数据采集系统设计

机械制造设备的多源传感器数据采集系统采用分布式架构设计,主要包括传感层、数据采集层、通信层和存储层四个部分。传感层部署振动传感器、温度传感器、声音传感器、电流传感器和油液监测传感器,实时采集设备运行状态数据,采样频率设定在100Hz-10kHz范围内,并根据不同传感器特性进行适应性调整。数据采集层采用PLC控制器与工控机结合的方式,PLC负责数据实时采集与简单逻辑控制,工控机进行数据预处理与本地存储。通信层采用工业以太网作为数据传输介质,基于Modbus TCP协议实现设备间通信,通信速率可达100Mbps。存储层包含数据缓存和数据服务器两部分,数据缓存采用环形缓冲区设计,具备掉电保护功能,数据服务器采用分布式存储架构,支持数据分片与备份。系统设计中采用了冗余备份机制,在关键节点

部署双机热备,同时建立了断点续传机制,有效防止数据丢失,确保采集系统稳定可靠运行<sup>[1]</sup>。

### 1.2 数据清洗与标准化处理

数据清洗过程针对采集到的原始数据进行系统性处理,确保数据质量满足分析要求。通过设计的异常值检测算法,对超出设备正常运行范围的数据进行标记与筛选,采用移动平均法处理短时噪声,使用插值算法修复数据缺失点。数据标准化处理采用Z-score标准化方法,将不同量纲的传感器数据转化为统一尺度。针对时序数据的特殊性,设计了基于滑动窗口的数据分段处理方法,窗口大小根据设备特性动态调整。同时,建立了数据质量评估体系,从完整性、准确性、时效性三个维度对处理后的数据进行评估。

### 1.3 特征提取与数据融合

特征提取环节采用多层次特征提取策略,从时域、频域和时频域三个维度挖掘设备状态特征。时域特征包括均值、标准差、峭度、偏度等统计量;频域特征通过快速傅里叶变换提取频谱特征;时频域特征则运用小波包分解方法,获取设备状态的动态特征。数据融合采用层次化融合框架,底层使用D-S证据理论实现异构数据的融合,中层采用主成分分析降低特征维度,高层通过模糊推理方法实现多源信息的综合集成<sup>[2]</sup>。特征选择过程中引入遗传算法优化特征子集,提高特征表达能力。

## 2 故障预测模型构建

### 2.1 深度学习算法选择与优化

机械制造设备故障预测模型采用深度学习中的长短期记忆网络(LSTM)与卷积神经网络(CNN)混合架构。LSTM网络包含

三层隐藏层，每层设置128个神经元，用于捕获设备状态数据的时序特征。CNN网络由两个卷积层和一个最大池化层构成，卷积核大小设为 $3 \times 3$ ，步长为1，用于提取故障特征的空间相关性。模型优化过程中引入注意力机制，增强对关键时序特征的学习能力。采用Adam优化器进行参数更新，初始学习率设为0.001，并结合余弦退火策略动态调整。为防止过拟合，在全连接层中加入Dropout层，失活率设为0.3，同时引入L2正则化约束。模型训练过程中采用批量归一化技术，每个batch大小设为64，提升模型收敛速度和泛化性能。

## 2.2 故障特征分析与分类

故障特征分析采用多尺度分析方法，构建了分层特征提取框架。在时域分析中，计算信号的峰值、均方根、峭度、偏度等统计特征；频域分析采用小波包分解方法，对设备振动信号进行多尺度分解，提取能量熵、奇异值和频带能量比等特征；时频域分析则运用希尔伯特-黄变换，获取信号的瞬时频率和幅值信息。故障分类系统采用层次化结构，将设备故障划分为轴承故障、齿轮故障、电机故障等主要类别，每类下设具体故障模式。分类器采用支持向量机与随机森林的集成方式，支持向量机采用RBF核函数，核参数通过网格搜索优化确定，随机森林设置500棵决策树，采用Gini系数作为节点分裂准则。

## 2.3 预测模型性能评估

预测模型性能评估体系从预测准确性、实时性和可靠性三个维度构建。准确性评估采用混淆矩阵分析方法，计算准确率、召回率、F1分数等指标；实时性评估通过测量模型推理时间和系统响应延迟进行量化；可靠性评估则基于模型预测结果的置信度分析。评估过程中采用滑动时间窗口机制，窗口大小设为24小时，步长为1小时，实时计算模型性能指标。同时设计了基于指数加权移动平均的趋势分析方法，对模型性能变化趋势进行动态监测。在异常工况下，触发模型自适应调整机制，通过在线学习方式更新模型参数，确保预测性能的稳定性。评估结果通过可视化dashboard呈现，支持性能指标的实时监控和历史追溯。

# 3 智能维护决策系统

## 3.1 维护策略优化算法

维护策略优化采用强化学习与遗传算法相结合的方法，构建了动态维护决策框架。强化学习模型采用深度Q网络结构，状态空间包含设备健康度、维护成本、生产计划等多维特征，动作空间涵盖即时维护、计划维护、推迟维护三

类决策。奖励函数设计综合考虑设备可靠性、维护成本和生产效率，通过折扣因子平衡长短期收益。遗传算法用于优化维护时间窗口，染色体编码采用实数编码方式，种群规模设置为100，交叉概率为0.8，变异概率为0.1。算法迭代过程中引入精英保留策略，保留最优解的同时维持种群多样性<sup>[3]</sup>。策略优化过程中设置了动态自适应机制，根据设备状态实时调整维护决策参数，并通过蒙特卡洛树搜索扩展决策空间，提升策略鲁棒性。维护策略执行模块采用分布式架构，支持多设备协同决策，实现设备群组的整体维护效能最优化。

## 3.2 资源调度与任务分配

资源调度系统基于混合整数规划模型设计，建立了多目标优化框架。目标函数包含维护成本最小化、设备停机时间最小化和维护质量最大化三个维度，约束条件包括人力资源限制、备件库存水平、设备运行时间要求等。任务分配采用改进的匈牙利算法，将维护任务与维护人员进行最优匹配。算法设计中考虑维护人员的技能等级、工作负载和地理位置等因素，通过权重系数进行量化。系统采用滚动时间窗口机制，实时更新调度方案，应对突发维护需求。资源调度过程中引入了应急响应机制，针对高优先级维护任务启动快速响应通道。调度算法采用分层优化策略，先进行粗粒度资源分配，再进行细粒度任务调整，提高调度效率<sup>[4]</sup>。系统支持多维度资源约束建模，包括时间窗口、技能匹配度、工具设备等，确保调度方案的可执行性。

## 3.3 维护效果评估体系

维护效果评估体系采用层次分析法构建综合评价模型。评价指标体系包含设备性能提升度、维护成本控制率、维护时效性三个一级指标，下设设备故障率、平均修复时间、备件利用率等多个二级指标。指标权重通过专家评分法确定，采用一致性检验确保权重分配合理性。评估过程采用模糊综合评价方法，建立隶属度函数刻画指标模糊性，评价结果分为优秀、良好、一般、较差四个等级。系统引入了时序评估机制，通过时间序列分析方法挖掘维护效果的动态变化规律。评估框架中集成了多源数据分析功能，将设备运行数据、维护记录、成本数据等进行关联分析，生成多维度评估报告。同时设计了评估结果可视化模块，提供交互式数据展示界面，支持评估结果的钻取分析<sup>[5]</sup>。

# 4 实验验证与结果分析

## 4.1 实验环境与数据集说明

某大型制造企业的数控机床生产线作为实验平台，选取10台CNC加工中心作为验证对象。数据采集设备包括PCB-141A振动传感器、PT100温度传感器、MK715声音传感器等。采集系统运行于Linux服务器集群，配置Intel Xeon E5-2680 v4处理器，128GB内存，采用MySQL数据库存储。数据集包含设备运行数据、维护记录和生产数据三类，时间跨度为2023年3月至2023年11月，采样频率为200Hz，数据量达到2.5TB。数据集涵盖正常运行数据及轴承故障、齿轮磨损、主轴失准等典型故障工况数据，经过数据清洗和标注后共形成850,000条有效记录，按7:2:1比例划分训练集、验证集和测试集。

#### 4.2 预测准确率分析

基于深度学习的故障预测模型在生产线实际运行数据验证中展现出显著的预测性能，如表1所示。模型对轴承故障的预测准确率最高，达到94.6%，预测提前期平均为36小时，误报率和漏报率分别为3.2%和2.2%；齿轮故障预测准确率为92.3%，预测提前期为28小时，误报率和漏报率分别为4.5%和3.2%；主轴故障预测准确率为90.8%，预测提前期为32小时，误报率和漏报率分别为5.1%和4.1%。模型在不同工况下表现出较强的泛化能力，置信度分布显示，89.5%的预测结果置信度高于0.85，对突发性故障的预警准确率达到88.6%，对渐进性故障的预警准确率高达95.2%。

表1 不同类型故障预测性能指标统计表

故障类型	预测准确率 (%)	预测提前期 (h)	误报率 (%)	漏报率 (%)	置信度均值
轴承故障	94.6	36	3.2	2.2	0.92
齿轮故障	92.3	28	4.5	3.2	0.89
主轴故障	90.8	32	5.1	4.1	0.87

#### 4.3 维护效率提升效果

智能维护系统在生产线投入使用后，设备平均故障间隔时间 (MTBF) 由原来的720小时提升至1150小时，提升幅度达59.7%。平均修复时间 (MTTR) 从4.5小时降低至2.8小时，降幅达37.8%。计划性维护比例从原有的45%提升至78%，维护人员平均响应时间从40分钟缩短至15分钟。备件库存周转率提升了45%，维护工具利用率提高了52%。通过智能调度系统，维护人员工作负载均衡性提升了63%，维护任务完成及时率从82%提升至95%。系统还实现了维护知识的智能积累，形成了包含2000多条故障案例的知识库，有效

支撑维护决策。

#### 4.4 经济效益分析

智能维护系统在该生产线的应用产生显著经济效益。设备非计划停机时间减少42.5%，年均减少停机损失约280万元。维护成本降低35.8%，包括备件费用减少95万元，人工成本降低68万元。设备使用寿命平均延长18%，折算年度设备更新成本节约达180万元。生产线综合设备效率 (OEE) 从原有的78%提升至89%，年产值提升约420万元。维护人员效率提升使人工成本降低23%，同时质量损失降低约32%。系统运行后，设备故障导致的产品质量损失降低了45%，年节约质量成本156万元。预防性维护投入与故障维修成本比例优化至3:1，体现出良好的成本控制效果。能源消耗降低15.6%，年节约能源成本85万元。设备保养成本减少28.5%，年节约资金125万元。投资回收期分析显示，系统投资在1.8年内可完全收回，投资回报率 (ROI) 达到235%。

#### 结语

通过对大数据驱动的机械制造设备故障预测与智能维护技术研究，成功构建了一套完整的预测维护解决方案。该方案在数据采集、算法优化、决策支持等方面均取得突破性进展，显著提高了故障预测准确率和维护效率。实验结果表明，基于大数据的智能维护技术不仅能够有效降低设备非计划停机时间，还可以优化维护资源配置，减少维护成本。这些研究成果为制造业设备管理现代化提供了可行方案，具有广泛的应用前景。未来研究将进一步探索多设备协同预测与维护优化问题，为智能制造提供更强有力的技术支撑。

#### 参考文献:

- [1] 安长永. 化工机械设备管理及维修保养技术的相关分析[J]. 设备管理与维修, 2020, (12): 14-16.
- [2] 姚京书. 轧钢机械设备运行监测与维护分析[J]. 山西冶金, 2022, 45 (09): 197-199.
- [3] 李正. 机械制造加工设备的安全管理及维修策略探索与研究[J]. 大众标准化, 2023, (17): 34-36.
- [4] 沈锋. 基于机器视觉的机械设备运行状态监测与故障预警研究[J]. 造纸装备及材料, 2023, 52 (05): 28-30.
- [5] 梁伟阁, 张钢, 王健, 等. 复杂机械设备健康状态预测方法研究综述[J]. 兵器装备工程学报, 2022, 43 (07): 67-77.