

基于深度学习的往复式压缩机振动信号故障诊断方法优化

史粲若

塔里木油田塔中采油气管理区 新疆 塔里木 223299

摘要：文章聚焦基于深度学习的往复式压缩机振动信号故障诊断方法优化。阐述了往复式压缩机振动信号故障诊断的必要性，分析了传统诊断方法与深度学习方法的应用现状及工程应用挑战。提出数据预处理、模型结构与训练策略的优化方法，并通过实验验证。实验表明，优化后的模型在准确率、泛化能力等方面表现优异，能有效满足工业现场实时监测需求，为往复式压缩机故障诊断提供新思路。

关键词：往复式压缩机；振动信号；深度学习；故障诊断方法优化

引言

往复式压缩机在工业生产中地位关键，其运行状态关乎生产流程的稳定与安全。准确及时的故障诊断至关重要，而基于振动信号的故障诊断是重要手段。传统诊断方法在复杂工况下存在局限性，深度学习虽带来革新，但在工业应用中仍面临挑战。因此，对基于深度学习的往复式压缩机振动信号故障诊断方法进行优化，提高诊断准确性与可靠性，具有重要的现实意义，有助于保障设备安全运行，提升生产效率。

1 往复式压缩机振动信号故障诊断方法的必要性

往复式压缩机作为工业生产中的关键设备，在石油炼化、天然气输送、制冷等诸多领域发挥着不可替代的作用。其运行状态直接关系到整个生产流程的稳定性与安全性，对往复式压缩机进行准确、及时的故障诊断具有至关重要的意义，而基于振动信号的故障诊断方法更是其中的重要环节。从设备安全运行角度来看，往复式压缩机内部结构复杂，包含众多运动部件，如活塞、连杆、曲轴等。在长期运行过程中，这些部件会因磨损、疲劳、腐蚀等因素出现故障。若不能及时发现和处理，故障会进一步恶化，导致设备损坏甚至引发严重的安全事故。振动信号包含了压缩机运行过程中各部件的运动状态和相互作用信息，通过对振动信号的分析，可以捕捉到设备早期故障的特征，提前发出预警，避免事故的发生。在生产效率方面，往复式压缩机的故障会导致生产中断，影响生产进度和产量。及时的故障诊断能够快速定位故障原因，缩短维修时间，减少停机损失。基于振动信号的故障诊断方法具有非接触、实时性强的特点，在设备运行过程中进行在线监测，及时发现潜在的故障隐患，合理安排维修计划，提高设备的可用性和生

产效率。从经济效益角度考虑，有效的故障诊断可以降低维修成本。传统的定期维修方式往往存在过度维修或维修不足的问题，造成资源浪费。而基于振动信号的故障诊断方法能够实现按需维修，根据设备的实际运行状态进行精准维修，减少不必要的维修费用和备件更换成本，提高企业的经济效益。

2 往复式压缩机振动信号故障诊断现状

2.1 传统诊断方法技术现状

传统故障诊断技术在往复式压缩机振动信号分析中已形成成熟体系，但在复杂工况下暴露出明显局限性。时域分析通过计算振动信号的均值、方差、峰值等统计参量实现状态评估，如通过均方根值监测设备运行平稳性，但该类特征对早期故障的敏感性不足，难以捕捉微弱异常。频域分析借助傅里叶变换将时域信号映射至频域，通过分析频谱能量分布识别故障特征频率，例如气阀泄漏故障在频谱中表现为低频段能量异常，但对具有非平稳特性的振动信号处理效果有限，无法反映故障特征的时变规律。时频分析方法通过构建时间-频率二维分布实现非平稳信号处理。短时傅里叶变换通过滑动窗口实现局部频谱分析，然而窗口函数的固定性导致时频分辨率矛盾；小波变换凭借多分辨率分析能力，在轴承故障诊断中展现优势，但基函数类型选择与分解层数确定高度依赖经验，计算复杂度制约实时诊断应用。这些方法在面对复合故障时，难以有效分离耦合特征，且人工特征提取过程存在主观性，难以适应工业现场的多样化需求^[1]。

2.2 深度学习方法应用现状

(1) 深度学习驱动故障诊断模式革新，实现从“人工特征提取与分类器组合”到“端到端”智能诊断的跨

越。卷积神经网络（CNN）凭借局部感受野和权值共享机制，可有效提取振动信号时频域局部特征，如采用一维CNN解析活塞磨损故障的高频冲击特性；长短时记忆网络（LSTM）通过门控结构克服循环神经网络梯度消失问题，对压缩机启停阶段的非平稳振动序列具有良好建模能力。注意力机制与CNN-LSTM的融合架构，增强了关键故障特征的捕捉效能，在气阀故障诊断中识别精度可达95%以上。（2）迁移学习技术为跨工况故障诊断提供新路径，通过预训练模型适应不同设备振动特性差异。（3）然而，深度学习在工业应用中仍面临多重挑战：原始振动信号易受环境噪声干扰，未经优化的预处理流程显著降低模型训练效率；故障样本采集成本高昂，小样本场景下模型过拟合风险加剧；模型架构设计缺乏系统性理论支撑，超参数优化依赖经验试错，导致对新型故障模式的适应性不足。

2.3 工程应用面临的现实挑战

当前故障诊断技术在工业现场应用中面临多重制约。数据层面，传感器安装位置与采样频率影响信号质量，非同步采样导致频谱泄漏，强电磁干扰引发信号畸变，而设备正常运行数据与故障数据的不均衡分布（正常样本占比超80%）加剧了模型诊断偏差。模型层面，深度神经网络的黑箱特性使得故障特征可解释性不足，难以满足工业安全规范对诊断结果溯源的要求；边缘计算设备的算力限制与深度学习模型的高计算复杂度形成矛盾，制约实时诊断系统的部署。工况动态变化对诊断模型鲁棒性提出严峻考验。压缩机负荷波动导致振动信号时频特征漂移，传统基于固定阈值的诊断策略失效；多故障耦合时，振动信号特征交互叠加，现有模型难以准确区分故障类型。设备健康状态评估缺乏统一标准，不同企业的故障定义与严重程度划分存在差异，导致诊断模型的跨场景适应性不足，阻碍技术的规模化推广。

3 深度学习的往复式压缩机振动信号故障诊断方法优化策略

3.1 数据预处理优化

（1）原始振动信号在采集阶段易受环境电磁干扰与传感器固有噪声影响，导致信号中包含大量冗余信息和噪声，这些干扰因素会显著阻碍深度学习模型对故障特征的有效学习。小波阈值去噪技术基于多分辨率分析原理，在时频域内对信号进行精细处理。通过合理选择小波基函数，可将振动信号分解至不同频率子带，对高频系数设置阈值进行筛选，既能有效去除高频噪声，又能完整保留活塞磨损等故障产生的关键特征信号。（2）归一化处理通过线性变换将信号幅值映射至指定区间（如[-1,1]

或[0,1]），能够消除不同信号间的幅值差异，降低数据尺度效应对模型训练的影响，进而提升模型训练的收敛速度与稳定性。实际应用时，可依据数据分布特性，灵活选用最小-最大归一化或Z-score归一化方法。（3）针对训练样本不足的问题，数据增强技术发挥着关键作用。除采用随机裁剪、添加高斯噪声等常规手段外，还可通过时频域变换实现数据扩充，对信号进行短时傅里叶变换后，在时频图上实施旋转、缩放操作，再经逆变换转换回时域，生成具有不同时间特征的新样本^[2]。

3.2 模型结构优化

往复式压缩机振动信号兼具局部特征与复杂时序特征，单一模型难以全面提取有效信息。融合CNN与LSTM的混合模型架构，可充分发挥两者优势。CNN部分采用多层卷积层与池化层级联结构，通过不同尺寸的卷积核（如 3×1 、 5×1 ）提取信号多尺度局部特征。例如，小尺寸卷积核聚焦于捕捉信号的高频细节特征，大尺寸卷积核则用于提取低频趋势特征，实现对活塞异常、气阀故障等不同类型故障特征的有效提取。池化层通过下采样操作，在保留关键特征的同时降低数据维度，减少计算量。LSTM部分接收CNN提取的特征序列，通过门控机制（输入门、遗忘门、输出门）对序列信息进行选择性记忆与遗忘，能够有效捕捉振动信号的长短期时序依赖关系，适用于分析压缩机启停过程、负载变化等工况下的非平稳信号。引入注意力机制进一步提升模型性能。自注意力机制通过计算特征向量间的相似性权重，使模型能够自适应地关注对故障诊断起关键作用的特征与时序信息。如处理多故障耦合信号时，模型可自动增强对主导故障特征的权重，抑制次要或干扰信息，从而更准确地识别故障类型与严重程度，显著提高诊断准确率。

3.3 训练策略优化

（1）深度学习模型的训练效率与收敛稳定性在很大程度上受制于训练策略的选择，Adam算法融合自适应梯度算法（AdaGrad）与均方根传播算法（RMSPProp）特性，通过对梯度一阶矩和二阶矩的动态估计，实现学习率的自适应调整。在训练初始阶段，较高的学习率可加速模型参数更新；随着训练进程推进，学习率自动衰减，既能规避参数更新幅度过大，又能防止模型陷入局部最优解。（2）早停策略通过持续监测验证集损失函数变化趋势，当验证损失不再降低或呈现上升态势时，即刻终止训练进程，以此有效规避训练集上的过拟合现象。该策略不仅节约计算资源，还能保障模型在测试集上维持良好的泛化性能。（3）批量归一化技术对神经网络各层输入进行标准化处理，通过校正输入数据分布，

缓解内部协变量偏移问题。这一操作增强了模型对输入数据波动的鲁棒性，降低网络对参数初始化的依赖，进而支持更大学习率的应用，加速模型收敛。批量归一化具备的正则化效应，可提升模型在多元工况下的泛化能力，增强其在工业故障诊断场景中的实用性^[3]。

4 实验验证与分析

4.1 实验数据

实验数据源自某工业企业连续运行的往复式压缩机监测系统，采用高精度加速度传感器采集振动信号。采样频率设定为12.8kHz，满足奈奎斯特采样定理对压缩机故障特征频率的捕捉需求。数据集覆盖正常工况、活塞磨损、气阀泄漏、曲轴不对中、连杆松动等8种运行状态，共计获取12,000组信号样本，其中正常状态样本占比35%，各故障类型样本按实际故障发生概率分布。数据预处理阶段，采用分层抽样策略将数据集按7:1:2比例划分为训练集（8,400组）、验证集（1,200组）和测试集（2,400组），确保各子集的故障类别分布与总体保持一致。对原始信号进行长度标准化处理，统一截取包含1024个采样点的信号片段，消除信号时长差异对模型训练的影响。利用傅里叶变换生成对应的频域数据，构建时频融合特征矩阵，为模型训练提供多模态信息。为评估模型泛化能力，从不同运行时段、不同负载工况（轻载、额定负载、过载）下采集数据，其中包含因环境温度变化、润滑油黏度波动导致的信号特征漂移样本。

4.2 实验结果

(1) 本次探究对基础CNN-LSTM模型、融合注意力机制的改进深度学习模型，以及支持向量机(SVM)、随机森林(RF)等传统方法开展对比实验，以准确率、召回率、F1值和AUC作为评估指标，并通过10次重复实验取均值以降低随机误差。(2) 实验数据表明，原始CNN-LSTM模型在测试集的平均准确率为89.3%，对活塞磨损、气阀泄漏等常见故障诊断效果良好，但在连杆松动(识别率78.6%)和复合故障(识别率65.2%)诊断中存在较高误判率。经注意力机制优化及数据预处理改

进后，新型模型整体准确率提升至96.7%，F1值从0.87跃升至0.95，尤其在曲轴不对中这类低频特征主导的故障诊断上，识别率从82.1%提升至94.3%。相比之下，传统SVM模型经特征工程优化后准确率达83.2%，但处理非平稳信号能力有限；RF算法在单一故障场景下准确率为86.5%，多故障耦合时骤降至58.7%。ROC曲线分析显示，改进模型AUC值达0.982，明显优于SVM(0.815)和RF(0.843)。(3) 泛化能力测试中，改进模型对新工况数据仍保持92.4%的诊断准确率，而传统方法下降至71.6%。优化后的模型通过结构调整将单样本诊断时间缩短至128ms，兼顾诊断性能与计算效率，有效满足工业现场实时监测需求^[4]。

结束语

通过对基于深度学习的往复式压缩机振动信号故障诊断方法进行优化，在数据预处理、模型结构与训练策略等方面取得显著成效。实验结果表明，优化后的模型在诊断准确率、泛化能力等方面均优于传统方法，且能满足工业现场实时监测需求。未来，进一步探索更先进的深度学习算法与优化策略，结合多源信息融合技术，提高故障诊断的智能化水平，为往复式压缩机的安全稳定运行提供更有力的保障。

参考文献

- [1] 李彦阳,王金东,宁留洋,马磊.基于GMDE和MFO-MKELM算法的往复压缩机轴承故障诊断研究[J].机械传动,2025,49(2):170-176.
- [2] 吴晨雨,韩雪.基于多源信息融合的往复式压缩机故障诊断方法[J].中文科技期刊数据库(文摘版)工程技术,2024(12):171-174.
- [3] 李浩,魏繁荣,王浩,李旭东.基于振动信号与深度学习的电力变压器故障诊断方法[J].电工电能新技术,2024,43(10):1-12.
- [4] 丁承君,张家梁,冯玉伯,王鑫.基于PSO优化RBF神经网络的往复式压缩机故障诊断[J].制造业自动化,2020,42(6):47-52.