

基于深度学习的火电机组汽轮机叶片振动故障预测模型研究

王伟

大唐鲁北发电有限责任公司

DOI:10.32629/etd.v7i2.18927

[摘要] 针对火电机组汽轮机叶片振动故障预测难题,提出一种基于CNN-LSTM混合架构的深度学习模型。该模型通过一维卷积提取振动信号局部特征,结合双向LSTM捕捉长时依赖,实现端到端的故障预测。实验结果表明,模型在测试集上的均方根误差为 0.42 m/s^2 ,相关系数达0.96,提前预警准确率94.3%,性能优于传统方法。研究为汽轮机叶片振动故障的智能预测提供了有效解决方案。

[关键词] 汽轮机叶片; 振动故障预测; 深度学习; CNN-LSTM; 故障诊断

中图分类号: O32 文献标识码: A

Research on a Deep Learning-Based Prediction Model for Vibration Faults in Steam Turbine Blades of Thermal Power Units

Wei Wang

Datang Lubei Power Generation Co., Ltd.

[Abstract] Addressing the challenge of predicting vibration faults in steam turbine blades of thermal power units, this study proposes a deep learning model based on a CNN-LSTM hybrid architecture. The model employs one-dimensional convolutions to extract local features from vibration signals, while incorporating bidirectional LSTMs to capture long-term dependencies, thereby achieving end-to-end fault prediction. Experimental results demonstrate that the model achieves a root mean square error of 0.42 m/s^2 on the test set, with a correlation coefficient of 0.96 and an early warning accuracy of 94.3%, outperforming conventional methods. This research provides an effective solution for the intelligent prediction of turbine blade vibration faults.

[Key words] Turbine blades; Vibration fault prediction; Deep learning; CNN-LSTM; Fault diagnosis

引言

火电机组作为电力系统的核心设备,其安全稳定运行直接关系到能源供应的可靠性。汽轮机叶片是机组的关键部件,长期承受高温、高压和交变载荷,极易发生振动故障。据统计,叶片振动引发的事故占汽轮机总故障的30%以上,不仅造成巨大经济损失,还可能危及人员安全。传统故障预测方法依赖人工提取特征,难以应对复杂工况下的非平稳振动信号。随着深度学习技术的发展,基于数据驱动的智能预测模型为解决这一问题提供了新途径。本研究旨在构建高效的振动故障预测模型,实现对叶片故障的早期预警,保障机组安全运行。

1 汽轮机叶片振动故障预测模型总体框架

1.1 模型设计原则与整体架构

火电机组汽轮机叶片长期处于高温高压和高转速工况下,叶片振动故障已成为影响机组安全稳定运行的主要隐患之一。振动过度会导致叶片疲劳裂纹扩展乃至断裂,进而引发严重事故。为实现对振动故障的提前预测,本研究提出一种基于深度学习的预测模型。该模型以端到端的方式直接从原始振动信号中学

习特征,避免传统方法依赖人工设计的统计特征所带来的局限性^[1]。整体架构采用卷积神经网络与长短期记忆网络相结合的混合结构,其中卷积神经网络负责提取振动信号中的局部时空特征,长短期记忆网络则专注于捕捉信号的长时依赖关系和动态演化趋势。

1.2 数据采集与预处理流程

振动信号采集主要依靠安装在汽轮机轴承座和机壳关键位置的高精度加速度传感器,采样频率设定为10000Hz,以充分覆盖叶片振动的高频成分和可能的谐波。采集系统实时记录多个测点的振动加速度数据,形成多通道时间序列。预处理是模型训练的基础,首先采用小波软阈值去噪算法去除背景噪声和电磁干扰,保留有效振动成分^[2]。随后,将连续信号按固定时间窗口分割,每个窗口长度为2048个采样点,对应约0.2秒的物理时间,确保序列长度适中且包含完整周期信息。为增强数据集多样性,采用多种数据增强技术,包括在原始信号上叠加不同强度的高斯白噪声、随机时间平移以及轻微幅度缩放。

1.3 模型训练与优化策略

模型训练过程采用Adam优化器作为核心梯度下降算法,初始学习率设定为0.001,并结合余弦退火学习率调度策略,使学习率在训练后期逐步衰减至接近零,从而实现更精细的参数调整并避免震荡。损失函数设计为均方误差与L1正则化项的组合,具体形式如下式1:

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 + \lambda \sum |w| \quad (1)$$

其中, y_i 表示真实振动幅值, \hat{y}_i 为模型预测值, λ 取0.0001用于控制模型复杂度,抑制过拟合风险。该损失函数在保证预测精度的同时,促进参数稀疏性,提升模型在噪声环境下的稳定性。训练采用小批量随机梯度下降,批量大小为64,总训练轮数上限设为200轮。训练过程中实时监控验证集损失,引入早停机制,当连续10个epoch验证损失无下降时自动终止训练。

2 振动信号特征提取与模型构建

2.1 振动信号特性分析

汽轮机叶片振动信号具有典型的非线性、非平稳特性,其频谱成分主要集中在基频及其整数倍频上,单位为Hz。正常运行状态下,振动加速度幅值通常维持在较低水平,均方根值小于 5m/s^2 。随着运行时间增加,叶片表面可能出现微小裂纹或材料疲劳,导致低频不平衡成分显著增强,同时高频谐波能量上升^[3]。信号时域波形呈现出周期性脉冲叠加随机噪声的特征,峰值因子和峭度等统计量对早期故障较为敏感。频域分析显示,功率谱密度在转频附近出现尖锐峰值,而宽带随机成分则反映蒸汽涡流激励的复杂影响。这些特性决定了传统傅里叶变换或统计阈值方法难以准确捕捉故障演化趋势,而深度学习模型可以通过多层非线性变换自动学习信号内在模式,为后续故障预测提供丰富且高抽象度的特征表示。

2.2 CNN模块的特征提取机制

卷积神经网络模块采用一维卷积结构,专为时间序列设计。第一层卷积核大小为7,通道数扩展至32,随后通过最大池化层将序列长度减半,保留最显著的局部特征。第二层和第三层卷积核大小分别为5和3,通道数逐步增加至64和128。每层卷积操作后均接ReLU激活函数和批量归一化层,以加速收敛并增强非线性表达能力。卷积计算过程可表示为式2:

$$f_{out}(t) = \sum_k w_k \cdot x(t-k) + b \quad (2)$$

其中, w_k 为可学习卷积核权重, b 为偏置项。该模块通过多尺度核的堆叠,能够同时捕捉短时冲击和长周期趋势,实现从低级边缘特征到高级语义特征的逐层抽象。池化操作进一步压缩冗余信息,降低计算负担,同时突出振动信号中的异常峰值。经过三级卷积池化处理后,原始信号被转化为高维紧凑特征图,为后续时序建模提供高质量输入。

2.3 LSTM模块的时序预测机制

长短期记忆网络模块接收卷积神经网络输出的特征序列,隐藏单元数设为128,并采用双向结构以同时利用过去和未来的

上下文信息。每个LSTM单元包含遗忘门、输入门和输出门三种门控机制,有效解决传统循环神经网络的梯度消失问题,适合处理长达数百步的振动序列。细胞状态通过加法操作更新,确保长期信息的稳定传递^[4]。序列预测采用多步递归方式,在训练阶段使用教师强制策略,在推理阶段则通过自回归方式逐步生成未来振动序列。该模块对振动幅值的渐进增长和突发异常具有极强的建模能力,尤其适用于捕捉故障从萌生到发展的完整动态过程。最终通过全连接层将隐藏状态映射到预测目标维度,实现高精度的多步前方振动趋势预测。

表1 CNN-LSTM模型各层详细参数配置

层序号	层类型	核大小/隐藏单元数	输入维度	输出维度	激活函数	其他参数
1	输入层	-	1×2048	1×2048	-	-
2	卷积层 1	7	1×2048	32×2048	ReLU	步长 1, 填充 3
3	池化层 1	2	32×2048	32×1024	-	最大池化
4	卷积层 2	5	32×1024	64×1024	ReLU	步长 1, 填充 2
5	池化层 2	2	64×1024	64×512	-	最大池化
6	卷积层 3	3	64×512	128×512	ReLU	步长 1, 填充 1
7	LSTM层(双向)	128	128×512	256×512	Tanh	dropout 0.3
8	全连接层	-	256	100	Linear	-

上表1详细列出了模型各层的参数配置。该配置经过多次超参数搜索优化,在特征提取深度与计算资源消耗之间取得良好平衡,确保模型在实际硬件平台上高效运行。

3 模型性能评估与故障预测应用

3.1 性能评估指标与实验结果

模型性能评估主要采用均方根误差、平均绝对百分比误差以及相关系数三项指标。在独立测试集上,CNN-LSTM混合模型的均方根误差达到 0.42m/s^2 ,平均绝对百分比误差为4.8%,相关系数高达0.96,表明预测序列与实际振动趋势高度一致。相比单一LSTM模型,混合模型的均方根误差降低了约25%,相比纯卷积模型降低了近46%。实验还验证了模型在不同负载工况下的稳定性,当机组负荷从50%变化至100%时,预测误差波动小于8%。这些结果充分证明了卷积模块在前置特征提取方面的关键作用,以及整体架构对复杂振动模式的强大表达能力。

3.2 故障类型识别与预测流程

为实现更精细的故障诊断,模型在回归任务基础上扩展了分类分支,通过在全连接层后添加softmax层输出常见故障类型的概率分布,主要包括叶片裂纹、不平衡、动静碰摩和松动四类。实际预测流程分为四个阶段:一是实时采集多通道振动信号并完成预处理;二是将当前时间窗口输入训练好的模型,得到未来10个时间步的振动幅值预测序列;三是计算预测序列的均方根值并与预设阈值比较,阈值设定为历史正常均值的1.5倍;四是若连续三个窗口超过阈值或分类概率超过0.8,则触发故障预警。该流程支持每分钟一次的滚动更新,能够提前24小时以上捕捉故障征兆,为检修调度提供充足决策时间^[5]。

3.3 模型鲁棒性与实际部署考虑

为进一步提升模型鲁棒性,在训练阶段引入多种噪声注入策略,并在测试阶段模拟传感器故障和工况突变场景。结果显示,

即便在信噪比降低20%的情况下,预测均方根误差仅上升至 0.58m/s^2 ,精度保持率超过86%。模型参数总量控制在500万以内,通过量化感知训练将权重压缩至8位整数,推理速度在边缘计算设备上达到每秒处理50个窗口^[6]。部署时采用容器化技术,便于集成到现有分布式控制系统,实现与传统振动监测模块的无缝对接。这些措施确保模型在火电机组实际运行环境中的长期稳定性和可靠性。

表2 不同预测模型在测试集上的性能对比

模型类型	均方根误差 (m/s^2)	平均绝对百分比 误差(%)	相关系数	提前预警 准确率(%)	单次推理 时间(ms)
CNN-LSTM(本研究)	0.42	4.8	0.96	94.3	12
纯LSTM	0.56	6.5	0.91	87.6	18
纯CNN	0.78	9.2	0.85	79.2	9
传统ARIMA	1.15	12.7	0.72	65.8	5
支持向量回归	0.89	10.4	0.81	74.5	25

上表2对比了多种预测模型在相同测试数据集上的关键性能指标。本研究提出的CNN-LSTM模型在预测精度、预警准确率和综合表现上均显著优于对比方法,验证了混合深度学习架构在汽轮机叶片振动故障预测领域的先进性。

4 结束语

本研究成功构建了基于CNN-LSTM混合架构的汽轮机叶片振动故障预测模型,通过多尺度特征提取和长时依赖建模,实现了对叶片振动故障的高精度预测。模型在实际测试中表现出优异

的性能,能够提前24小时以上预警故障,为机组的安全运行提供了有力保障。未来研究可进一步优化模型结构,探索多模态数据融合方法,并结合边缘计算技术实现模型的实时部署,推动火电机组智能化运维水平的提升。

【参考文献】

- [1]臧利永,张涛.超超临界火电机组给水泵汽轮机20Cr13钢动叶片断裂原因[J].理化检验-物理分册,2024,60(05):74-78.
- [2]刘云锋,杨晓辉,李宇峰,等.大型核电汽轮机末级长叶片开发中若干问题讨论[J].热能动力工程,2022,37(03):81-85.
- [3]谢利明.基于相控阵技术的电站汽轮机叶片检验关键技术研究.内蒙古自治区,内蒙古电力(集团)有限责任公司内蒙古电力科学研究院分公司,2021-08-18.
- [4]杨其国.大型核电汽轮机低压通流、末级长叶片研究、设计及验证.黑龙江省,哈尔滨汽轮机厂有限责任公司,2021-01-29.
- [5]张兴凯.600MW火电机组汽轮机回热加热器泄漏原因分析及解决措施[J].河南科技,2025,52(13):29-32.
- [6]付业东.火电厂机组汽轮机运行维护与节能指标分析[J].电力设备管理,2025,(11):239-241.

作者简介:

王伟(1986--),男,汉族,山东德州人,本科,研究方向:火电厂智能化解决方案,先进技术研究与应用落地。