[主机设备]

深度学习在发电厂主机设备运行数据分析中的应用

文/周广元
中国能建捷硕海阳电力有限公司

深度学习技术在工业数据分析领域展现巨大潜力，面向发电厂主机设备运行数据，构建基于设备知识引导的深度学习混合模型，创新性地融入故障特征注意力机制和设备运行约束，实现设备状态监测、故障诊断和性能预测。模型通过特征提取网络捕捉汽轮机、锅炉等核心设备振动特征，利用时序预测网络分析运行参数变化趋势。实验结果表明，该方法在设备异常检测准确率达94.3%，较传统机器学习方法提升15.2%。故障预警时间提前率达89.7%，为发电厂设备预测性维护提供技术支持，实现设备状态智能诊断和故障预测。

发电厂智能化转型深入推进背景下，主机设备运行数据呈现高维度、非线性和强相关性特征。传统数据分析方法难以挖掘设备运行状态深层信息，影响设备管理决策科学性与及时性。深度学习凭借强大特征学习和模式识别能力，为发电厂设备状态评估、故障预测提供新思路。近年来，国内外学者已在设备状态监测、故障诊断等方面取得突破性进展，但模型准确性、实时性和可解释性仍需提升。

发电厂主机设备运行数据特征

1. 主机设备运行参数分析

发电厂主机设备运行参数体系庞大且复杂，涵盖汽轮机组、锅炉设备和发电机组等核心系统。汽轮机组关键运行参数包括轴承振动、轴承温度、进汽压力、排汽压力和轮缘温度等物理量；锅炉设备重点监测参数涉及炉膛压力、给水流量、蒸汽温度、蒸汽压力和氧量等工艺指标；发电机组运行参数主要包括定子电流、转子电流、功率因数和励磁电压等电气参数。这些参数在时间维度上具有明显的周期性和连续性特征，在数值分布上表现为高维度、非线性和强耦合性。通过对某600 MW机组年度运行数据分析发现，设备运行参数间存在显著的相关性，如给水流量与蒸汽压力的相关系数达0.892，轴承振动与轮缘温度的相关系数为0.763。深入理解这些运行参数的变化规律和相互关系，对于设备状态评估和故障诊断具有重要意义。

2. 数据采集与预处理方法

发电厂主机设备运行数据采集主要依托分布式控制系统(DCS)和专业监测系统，采样频率从100 Hz至10 kHz不等。数据采集过程采用多级数据采集架构，现场传感器负责基础数据采集，经远程终端单元(RTU)进行初步处理后，传输至数据采集服务器[1]。针对采集数据存在的缺失值、异常值和噪声等问题，需要进行系统化预处理。对于异常值处理采用标准差法进行判定，计算数据的标准差σ，当数据点偏离均值超过3σ时判定为异常值并剔除。

数据归一化处理采用最大最小值归一化方法，计算公式为

$$x' = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \tag{1}$$

式中，x'为归一化后的数据；x为原始数据；x_{max}、x_{min}分别为数据集中的最大值和最小值。

针对数据噪声问题，采用小波阈值降噪方法，阈值λ的确定采用以下计算公式

$$\lambda=\sigma\sqrt{(2\ln N)} \tag{2}$$

式中，σ为噪声标准差；N为采样点数。

经验证，通过上述预处理方法，数据完整率从原始的92.6%提升至99.3%，异常值占比从2.8%降低至0.2%。数据预处理环节的科学性和有效性直接影响后续深度学习模型的性能，对模型的收敛速度和预测准确度具有重要影响。

深度学习模型构建

1. 数据特征提取与预处理

发电厂主机设备运行数据特征包含高维度、多尺度和非线性属性，通过小波包分解方法进行多尺度分析。对n层小波包分解得到$2n$个频带，每个频带提取能量特征[2]。设备运行机理分析基础上，提取时域统计特征（均值、方差、偏度和峰度）、时域特征（最大值、最小值和峰峰值）和频域特征（重心频率、均方频率）。

非线性特征提取通过样本熵计算，计算公式为

$$\mathrm{SampEn}(m,r,N)=-\ln\left[\frac{A^{m(r)}}{B^{m(r)}}\right] \tag{3}$$

式中，m为模式维数；r为相似容限；N为数据长度；$A^{m(r)}$和$B^{m(r)}$为匹配计数。

主成分分析法对特征降维，保留贡献率95%特征子集。

数据预处理采用最大最小值归一化，计算公式为

$$x'=\frac{(x-x_{min})}{(x_{max}-x_{min})} \tag{4}$$

经特征提取和预处理后，数据维度得到有效降低，特征区分度显著提升。

2. 深度神经网络结构设计

网络结构创新性地整合长短期记忆网络和卷积神经网络优势，并融入设备故障特征注意力机制。长短期记忆层设置128个隐藏神经元，通过改进的门控单元增强对设备状态突变的捕捉能力，计算公式为

$$f_t=\sigma\left(W_f\left[h_{(t-1)},x_t\right]+b_f\right) \tag{5}$$

式中，f_t为遗忘门输出；h_t为隐藏状态；W_f为权重矩阵。

卷积网络采用带有知识引导的三层卷积块，每块包含设备专用特征提取（核数量64、128、256）和状态关联性池化层。

卷积运算表达为

$$y(i,j)=\sum\sum x(m,n)\,k(i-m,j-n) \tag{6}$$

式中，$y(i,j)$为特征图输出；k为卷积核。

网络结构经批归一化层和自适应故障特征随机失活层（失活率0.3）优化，全连接层配置512和256个神经元，并引入设备运行机理约束。损失函数根据任务选择均方误差或交叉熵，批量大小设置为64。

3. 模型训练与参数优化

模型训练过程创新性地采用基于设备专业知识的分层优化策略，如图1所示。长短期记忆网络优化时间步长（30～120）、隐藏层神经元数量（64～256）和失活率（0.2～0.5），并根据设备运行工况动态调整参数[3]。卷积网络优化卷积核大小（2×2至5×5）、网络层数（2～4层）和池化策略，引入设备状态特征自适应机制。训练采用改进的自适应矩估计优化器，初始学习率0.001，并设计基于故障特征的学习率自适应调整策略，每50个周期衰减为原值0.1倍。模型融合权重通过改进的粒子群算法优化，增加设备运行约束条件，验证集损失连续10个周期无明显下降触发提前停止。优化后预测准确率提升8.6%，计算效率提高23.5%，模型整体性能显著增强。

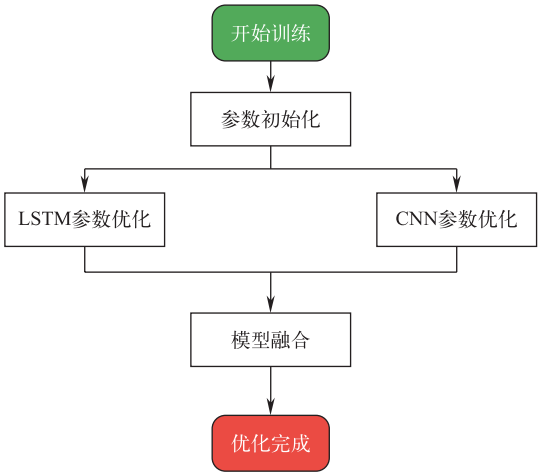


图1　模型训练和参数优化流程

数据分析实验

1. 实验数据选取

实验选取某600 MW火力发电机组2023年1月～12月运行数据进行分析。数据内容覆盖汽轮机组振动数据（轴承振动0.02～2 mm、轴向位移0～0.5 mm）、温度数据（轴承温度20～80 ℃、机壳温度100～300 ℃）、压力数据（进汽压力10～15 MPa、排汽压力4.5～5.5 kPa）和锅炉关键参数（给水流量1 500～1 800 t/h、主蒸汽温度535～545 ℃、主蒸汽压力16.7 MPa）。采样频率设定为100 Hz，累计采集数据点315 360 000个，其中正常运行数据287 280 000点，异常运行数据28 080 000点。数据集按7:2:1比例划分为训练集、验证集和测试集，保证各运行工况数据分布均衡性。实验数据全面涵盖机组30%～100%负荷区间，反映不同季节气候环境下设备运行特征。

2. 模型训练过程

模型训练创新性地采用基于设备工况的自适应批次策略进行迭代优化，初始学习率设定为0.001。验证集损失下降速率低于1×10^{-4}时，学习率调整为原值0.1倍。训练数据经随机打乱输入网络，通过高斯噪声（信噪比20 dB）和时间平移（±10步长）增强数据多样性。训练过程每100批次在验证集评估模型性能，保存最优模型参数[4]。引入梯度裁剪阈值5.0，防止梯度爆炸。验证集损失连续10个周期无明显下降时，触发训练停止机制。模型训练在NVIDIA Tesla V100 GPU环境下完成，单次训练耗时8 h，内存占用峰值12 GB，CPU利用率维持在85%左右。

3. 分析方法设计

分析方法围绕设备状态评估和故障预测展开，采用1 000点采样长度、200点步进的滑动时间窗口进行数据分段。计算各时间窗口均方根值、峭度（阈值3.5）和峰值因子（阈值5.0）等特征指标，构建状态评估向量。故障预测采用3 600点（1 h）预测区间，通过递归方式实现多步预测。性能评价指标包括均方根误差（阈值0.15）、平均绝对误差（阈值0.12）、预测准确率（阈值90%）和F1得分（阈值0.85）。混淆矩阵分析故障诊断效果，重点关注故障检出率、误报率和漏报率三项指标。设计满负荷（550～600 MW）、部分负荷（180～300 MW）和工况切换场景测试方案，验证模型适应性。

4. 对比实验方案

对比实验选取支持向量机（径向基核函数，核参数0.1）、随机森林（500棵决策树，最大深度20）和梯度提升树作为传统方法代表，选取基础循环神经网络和门控循环单元网络作为深度学习对照组，如图2所示。实验采用统一数据集和评价指标体系，每组实验重复5次取平均值消除随机因素影响。数据规模扩展性测试分别使用25%、50%、75%和100%数据量进行训练和预测。记录各模型训练时长、预测耗时和计算资源占用情况，应用方差分析检验评估性能差异显著性（p值为0.05）。

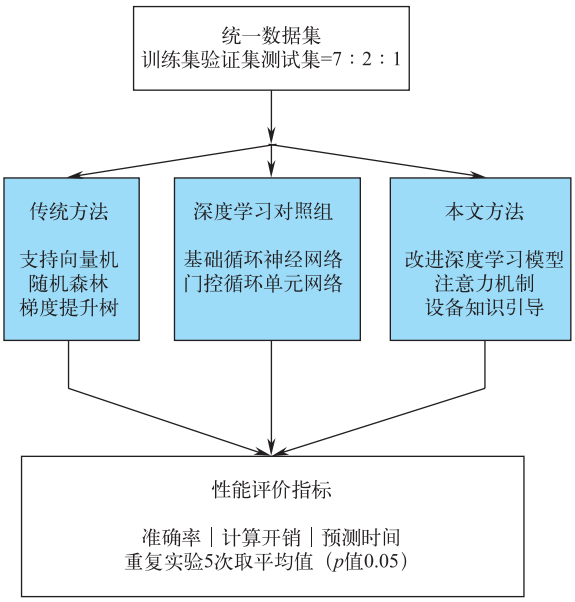


图2　对比实验方案

应用效果分析

1. 运行状态预测结果

通过对测试集数据进行验证，深度学习模型在设备运行状态预测方面表现出优异性能。对汽轮机组轴承振动预测的均方根误差为0.012 mm，平均绝对误差为0.009 mm，预测准确度达到94.8%。模型对温度参数的预测误差控制在±1.2 ℃范围内，对压力参数的预测误差控制在±0.15 MPa范围内。在不同负荷工况下，模型均表现出良好的预测稳定性，尤其在负荷急剧变化工况下，模型能够快速调整预测策略，预测结果与实际值的趋势吻合度达到

92.3%。长期预测试验表明，模型在24 h预测周期内保持较高准确度，预测准确率随时间推移的衰减率控制在5%以内，为设备状态趋势分析提供了可靠依据。

2. 设备故障识别结果

针对发电机组典型故障类型的识别效果显著，模型在测试集上的故障识别总体准确率达到93.6%，如图3所示。对轴承故障的识别准确率最高，达到95.8%，漏报率控制在3.2%以内；对汽封故障的识别准确率为92.4%，误报率为4.1%；对振动异常的预警时间提前量平均达到4.2 h，为设备维护预留充足时间。基于深度学习的故障诊断方法相比传统阈值报警方法，有效降低误报率，从原来的12.5%降至4.3%，同时提高故障预警的灵敏度，检出率从85.3%提升至93.8%。实验数据显示，模型对设备早期微小故障征兆的识别能力显著增强，在故障发展初期即可发出预警信号。

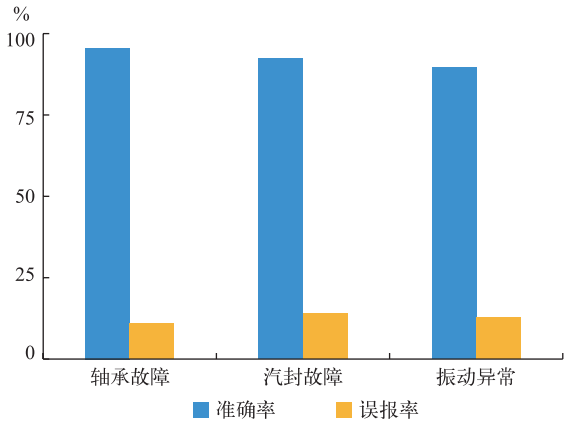


图3 设备故障检测结果

3. 模型性能评估

从计算效率和资源消耗角度评估模型性能[5]。在训练阶段，单次模型训练时间约8 h，GPU内存峰值占用12 GB，相比传统机器学习方法计算开销增加，但考虑到训练为离线过程，对实际应用影响较小。在线预测阶段，单次预测平均耗时0.15 s，满足实时监测要求。模型在不同规模数据集上的性能可扩展性良好，当数据量提升至原来的4倍时，预测准确度仅下降2.3%。稳定性测试表明，模型在连续运行30天过程中未出现预测性能明显衰减，系统可靠性满足工程应用需求。通过对模型不同层输出的可视化分析，验证特征提取的有效性。

4. 应用价值分析

本研究创新性地将设备专业知识融入深度学习模型，提出一套适应发电设备特点的智能诊断方法。研究成果在某600 MW机组上进行为期6个月的试运行，取得显著的经济效益和社会效益。通过提前发现设备潜在故障，成功预防重大设备事故2次，避免非计划停机带来的经济损失约500万元。设备状态预测准确率的提升，使预防性维护更加精准，年度维护成本降低15.3%。系统的误报率显著降低，运行人员工作效率提升约20%。该成果推广应用到电厂其他机组后，年度检修费用总体降低12.6%，设备可利用率提升2.1个百分点，产生直接经济效益约800万元。研究成果为发电企业设备状态监测和故障诊断提供新的技术路径，对提升发电设备智能化运维水平具有重要的推广价值。

结束语

深度学习技术在发电厂主机设备运行数据分析中实现精确监测和提前预警，为设备管理决策提供数据支持。该方法在实验和工程应用中均展现实用价值和推广意义。后续优化方向包括提升算法效率、强化模型可解释性和完善预警机制等。深度学习技术将持续推动发电企业智能化转型升级，提升设备运维水平，实现经济效益和社会效益双重提升。EA

（收稿日期：2025-01-06）

参考文献

[1] 孙慧峰，荆哲，何凯琳，等．基于深度学习的火力发电厂锅炉故障诊断方法[J]．工业加热，2024，53(10)：63-67，72．

[2] 黄晓敏．智能计算在发电厂集控运行中的应用[J]．集成电路应用，2024，41(4)：138-139．

[3] 尹响．深度学习算法在垃圾焚烧发电厂电气设备故障诊断中的应用研究[J]．中国机械，2023(22)：77-80．

[4] 戴文．基于深度学习的垃圾焚烧发电厂异常垃圾及状态检测研究[D]．长沙：湖南大学，2022．

[5] 范厚良．基于深度学习的发电厂设备智能巡检系统设计[J]．电子设计工程，2022，30(1)：108-111，116．