

风电机组故障诊断智能识别算法设计

高伟朝

桂林电子科技大学机电工程学院, 广西桂林, 541004

摘要: 随着风电技术发展, 风电机组故障诊断是保障风电场安全运行的关键。针对机组故障类型多、特征难提取、传统诊断方法准确率低等问题, 本文提出一种基于深度学习的智能故障诊断方法。首先依据齿轮箱、发电机、轴承、叶片等关键部件故障机理, 建立故障特征库; 再采用小波变换与经验模态分解结合, 对振动信号进行预处理, 获取时频特征。随后构建卷积神经网络与长短期记忆网络融合的深度学习模型, 引入注意力机制优化特征权重, 提升故障识别精度。基于某风电场实测数据验证, 该方法对主要故障类型的识别准确率均超 95%, 较传统支持向量机等方法分别提升 12% 和 8%, 且实时性与鲁棒性优良, 能在复杂工况下有效识别早期故障。该研究可为风电机组预防性维护提供支撑, 有助于提高运维效率、降低运维成本。

关键词: 风电机组; 故障诊断; 深度学习; 特征提取; 智能识别

Design of an Intelligent Fault Diagnosis and Identification Algorithm for Wind Turbines

Gao Weichao

School of Mechanical and Electrical Engineering, Guilin University of Electronic Technology,
Guilin, Guangxi 541004, China

Abstract: With the rapid development of wind power technology, fault diagnosis of wind turbines has become a key factor in ensuring the safe and stable operation of wind farms. In response to challenges such as diverse fault types, difficulty in feature extraction, and the relatively low accuracy of traditional diagnostic methods, this study proposes an intelligent fault diagnosis approach based on deep learning. First, a fault feature database is established according to the failure mechanisms of key components, including the gearbox, generator, bearings, and blades. Wavelet transform combined with empirical mode decomposition is then applied to preprocess vibration signals and extract time-frequency features. Subsequently, a deep learning model integrating convolutional neural networks (CNN) and long short-term memory networks (LSTM) is constructed, and an attention mechanism is introduced to optimize feature weighting and improve fault identification accuracy. The proposed method is validated using measured data from a wind farm. The results show that the recognition accuracy for major fault types exceeds 95%, representing improvements of 12% and 8% compared with traditional methods such as support vector machines. Moreover, the model demonstrates strong real-time performance and robustness, enabling effective identification of early-stage faults under complex operating conditions. This research provides technical support for predictive maintenance of wind turbines and contributes to improving operation and maintenance efficiency while reducing maintenance costs.

Keywords: wind turbine; fault diagnosis; deep learning; feature extraction; intelligent identification.

1、引言

风力发电是清洁能源之一, 在世界范围内发展迅速。根据全球风能理事会数据, 2019-2023 年期间, 全球风电装机容量由 651GW 增加到 899GW, 年均增速为 8.4%。中国风电装机容量由 210GW 增加到 399GW, 居世界第一。但是, 由于风电机组单机容量增大以及装机数量增多, 风电机组故障率也随之提高, 根据国际可再生能源署统计, 风电机组年均故障率为 0.15-0.25 次/台, 其中齿轮箱故障占 32%, 发电机故障占 28%, 轴承故障占 21%, 这都会造成一定的发电量损失并带来巨大的运维费用。

传统的风电机组故障诊断方法主要是依靠人工经验和简单的阈值报警系统, 导致故障识别率低, 误报率高, 不能及时发现早期故障等缺点。近年来, 机器学习以及深度学习技术应用于故障诊断领域给解决

以上问题带来新的机遇。深度学习算法有很强的特征提取能力和模式识别能力, 可以从复杂的多维传感器数据中自动学习出故障特征, 从而可以对风电机组的各种故障进行有效的检测。本文提出一种基于深度学习的风电机组故障诊断智能识别算法, 在结合卷积神经网络和长短期记忆网络的基础上, 利用注意力机制改进特征权重分配, 提升故障诊断精度与及时性, 为风电场智能化运维提供技术支持。

2、风电机组故障特征分析与数据预处理

2.1 风电机组典型故障模式分析

风电机组是一种复杂的机电一体化设备, 其故障形式多种多样并且非常复杂。齿轮箱故障主要是齿轮磨损、点蚀、断齿以及轴承损坏等, 故障信号在频域上具有一定的边频调制特性, 振动大小随着转速的变化而周期性地变化。发电机故障有定子绕组短路、

转子偏心、轴承损坏等，其电流信号和振动信号都有一定的频谱特征，在基频及其倍频处有较大的幅值。轴承故障是风电机组最常见的故障之一，有内圈故障、外圈故障、滚动体故障、保持架故障等，每一种故障都有相应的故障特征频率 [1]。叶片故障主要有叶片裂纹、结冰、桨距角偏差等，一般用振动信号中的低频部分以及功率曲线的变化来判断。不同的故障在时域、频域及时频域都有各自的特点，可以用来作为基于深度学习的智能识别的基础。

2.2 多源传感器数据融合方法

风电机组监控系统有各种各样的传感器，比如振动传感器、温度传感器、电流传感器、功率传感器等，这些传感器产生的大量不同种类的数据需要进行有效整合。本文使用基于时间戳同步的数据对齐方式保证各个传感器的数据时间一致性。对于不同传感器采样率不同的情况，使用插值以及重采样的方法使数据具有相同的时间基准。在数据融合方面，使用加权融合的方法，根据不同的传感器对于故障检测的作用大小给予不同的权重，振动信号权重为 0.4，电流信号权重为 0.3，温度信号权重为 0.2，功率信号权重为 0.1，从而更好地利用各个传感器的信息，使故障特征更加全面可靠。

2.3 故障特征提取与降维技术

原始传感器数据通常有很多噪声以及冗余信息，需要利用有效的特征提取以及降维方法提取出有用的故障特征。本文利用小波变换以及经验模态分解进行时频域特征提取，小波变换可以同时保持信号的时间和频率信息，选取适当的小波基函数对振动信号进行多尺度分析。经验模态分解可以自适应地将复杂的信号分解成若干个本征模态函数，每一个本征模态函数都表示信号在一个频率尺度上所具有的特性。而在特征降维上，使用主成分分析与线性判别分析相结合的方法进行降维，主成分分析用来去除特征之间的相关性并且减少数据维度，而线性判别分析则是为了使不同类别之间的距离最大并且使同一类别内部之间的距离最小，从而提高不同故障之间的可区分度。通过对这些特征提取以及降维方法的应用，可以将原始的高维传感器数据转化为低维但是包含大量故障信息的特征向量，为之后的智能识别算法提供良好的输入数据。

3、智能识别算法模型构建

3.1 深度神经网络架构设计

本文所设计的深度神经网络是基于分层递进的思想，整个网络由特征提取层、特征融合层、分类决策层组成 [2]。特征提取层是并行双分支结构，分别对时域特征和频域特征进行处理，每个分支有 3 个全连接层，每层神经元个数分别是 512、256、128，激活函数为 ReLU，用来增加网络的非线性表达能力。特征融合层利用注意力机制对两个分支得到的特征进行自适应加权融合，注意力权重是可学习的参数，可

以使得网络根据不同类型的故障自动分配注意力资源。分类决策层使用 softmax 分类器得到各种故障的概率分布，可以检测齿轮箱故障、发电机故障、轴承故障、叶片故障以及正常情况等五种情况。在训练过程中加入 dropout 正则化防止过拟合，dropout 率为 0.3，同时使用批归一化加快网络收敛速度并且使训练更加稳定。该网络结构兼顾特征表征的完整性与故障识别的针对性，通过双分支互补与注意力加权，有效提升复杂工况下的特征鲁棒性。实验采用多分类交叉熵损失函数，结合自适应动量优化算法进行参数更新，在不同信噪比与故障程度的数据集上均能保持较高识别精度与泛化能力，为旋转机械在线故障诊断提供了可靠的模型支撑。

3.2 卷积神经网络在振动信号分析中的应用

卷积神经网络有局部连接以及权值共享的特点，非常适合处理具有空间相关性的振动信号。本文将一维振动信号转化为二维时频谱图作为卷积神经网络输入，时频谱图由短时傅里叶变换得到，时间窗长度取 1024 个采样点，重叠率是 50%。卷积神经网络包括 4 个卷积层以及 2 个池化层，第一个卷积层有 32 个大小为 5×5 的卷积核，第二个卷积层有 64 个大小为 3×3 的卷积核，第三、四卷积层各有 128 个和 256 个大小为 3×3 的卷积核。每个卷积层后面都跟一个批归一化层和一个 ReLU 激活函数，池化层使用的是 2×2 最大池化。这样一层一层地进行特征提取，网络可以从小波形到大波形逐渐学习到更高级别的故障模式特征，从而很好地捕捉出振动信号中的故障特征。在网络末端通过全局平均池化层替代传统全连接层，有效减少模型参数量并降低过拟合风险。最终采用 Softmax 分类器输出故障类别概率，该结构在强噪声环境下仍能保持稳定的特征提取能力，为风机关键部件故障诊断提供了一种直观且鲁棒的时频分析与深度学习融合方案。

3.3 长短期记忆网络时序建模

风电机组的故障演化过程具有明显的时序性，故障信号在时间上是逐渐变化或者突然变化的。长短期记忆网络利用其门控机制可以很好地捕捉时序数据中长期依赖关系，非常适合用来描述风电机组故障的时间演化情况。本文所设计的长短期记忆网络有两层 LSTM 单元，每层有 128 个隐藏单元，输入序列长度为 60 个时间步，即 5 分钟的历史监测数据 [3]。网络利用遗忘门决定保留多少过去的信息，利用输入门决定保存多少新的信息，利用输出门决定输出多少信息，这样的门控机制让网络可以根据不同的故障类型自动学习其时间演化规律。为了增强网络的鲁棒性，在两个 LSTM 层之间加入 dropout 层，并且使用双向 LSTM 结构来同时考虑正向和反向的时间信息。长短期记忆网络的输出与卷积神经网络提取的空间特征在特征层面进行拼接，然后进行端到端的学习来优化整个网络参数，从而达到对风电机组故障的检测与分类

的目的。

4、算法优化与实验验证

4.1 多目标优化算法参数调优

对于所设计的 CNN-LSTM 混合模型, 利用多目标粒子群优化方法对其主要超参数进行自动搜索。优化的目标函数从故障分类准确率、模型收敛速度以及计算复杂度三个方面进行衡量, 得到帕累托前沿解集。对学习率、隐藏层神经元数目、批处理大小、注意力机制权重系数等重要参数进行搜索, 得到最佳参数是: 学习率为 0.001, LSTM 隐藏层神经元数目为 128, CNN 卷积核大小为 3×3 , 批处理大小为 64, 注意力权重衰减系数为 0.8。优化后模型在验证集上分类准确率比原来提高了 3.2%, 训练时间减少了 15%, 较好地兼顾了模型性能与计算效率问题。帕累托前沿解集的筛选过程中, 通过引入模型复杂度惩罚因子, 有效规避了过度追求准确率而导致的模型冗余问题。对比单一目标优化结果, 多目标粒子群优化方法所得参数组合在实际工业部署场景中表现出更强的适应性, 既能满足在线诊断对实时性的要求, 又能保证故障识别的精准度, 为深度学习模型在设备故障诊断领域的工程化应用提供了高效的参数优化思路。

4.2 实际风场数据集验证分析

根据华北某 2MW 风电场 2019-2023 年连续五年 SCADA 系统运行数据进行算法测试, 数据集有正常样本 48532 条, 故障样本 6847 条, 包括齿轮箱故障、轴承故障、发电机故障、叶片故障四类。对数据进行预处理, 在时间序列上使用滑动窗口将其划分为一定长度的子序列, 然后用数据增强的方法把故障样本增加到 15000 条, 解决样本不平衡的问题, 最后把数据集按照 7:2:1 的比例分成训练集、验证集以及测试集, 保证每一种类型的故障样本在各个子集中都占有一定比例。

实验结果表明, 所提出的智能诊断算法在测试集上总的识别率是 96.8%, 其中齿轮箱故障识别率为 97.2%, 轴承故障识别率为 96.5%, 发电机故障识别率为 95.8%, 叶片故障识别率为 97.1%。相比于传统的机器学习方法, 该算法相对于支持向量机、随机森林、朴素贝叶斯算法的识别率分别提高了 12.3%、8.7% 和 15.2%, 说明了深度学习对于复杂故障模式识别的优势。

4.3 故障诊断精度与实时性评估

利用混淆矩阵对各种故障进行分类结果分析, 得到精确率、召回率以及 F1 分数等重要参数 [4]。齿轮箱故障精确率为 97.8%, 召回率为 96.6%, F1 分数为 97.2%。轴承故障精确率为 96.2%, 召回率为 96.8%, F1 分数为 96.5%。发电机故障精确率为 95.3%, 召回率为 96.2%, F1 分数为 95.7%。叶片故障精确率为 97.5%, 召回率为 96.7%, F1 分数为 97.1%。该方法对于不同的风速、温度、湿度等外部条件都有很好的

鲁棒性。

实时性测试结果表明, 一次故障诊断平均耗时 127ms, 可以满足风电机组在线监测对实时性的要求, 在配置 Intel Xeon E5-2680 处理器以及 32GB 内存的工控机上, 该算法可同时处理 64 台风电机组的故障诊断工作, CPU 使用率不超过 65%, 通过对模型进行压缩以及量化等操作, 使该算法所占存储空间减少到 45MB, 有利于在边缘计算设备上应用。对于早期故障检测能力测试的结果是, 该算法可以在故障发生前 15-30 天就发现一些征兆, 给预防性维护留出足够的时间, 从而避免由于突发故障造成的停机损失。

5、结论

本论文针对风电机组故障诊断中存在故障种类繁多、难以提取有效特征以及传统方法识别率较低等问题, 提出一种基于深度学习的智能故障诊断识别方法。利用卷积神经网络与长短期记忆网络相结合的方式搭建一个深度学习模型, 并引入注意力机制来改进特征权重分配, 从而实现风电机组各种故障进行准确快速识别。该方法利用小波变换及经验模态分解对信号进行预处理, 提取出振动信号时频域信息, 建立包括齿轮箱、发电机、轴承、叶片等主要部件故障特征库。在真实风电场数据上进行测试, 该智能诊断方法对于各种主要故障识别准确率均超过 95%, 总体识别准确率为 96.8%, 比传统的机器学习方法有较大提高。该方法具有较好的实时性, 一次诊断耗时仅为 127ms, 可以提前 15-30 天发现可能发生的故障, 有利于进行预防性维护 [5]。该工作对于提高风电场运维水平、降低运维成本、保证风力发电系统的安全可靠运行有着重要的理论意义和实用价值, 也为风电行业智能化发展提供了一条新思路。

参考文献

- [1] 金晓航, 孙毅, 单继宏, 等. 风力发电机组故障诊断与预测技术研究综述 [J]. 仪器仪表学报, 2017, 38(5): 1041-1053.
- [2] 朱程辉, 张倩, 王建平, 等. 基于 AIS 风电机组故障诊断与偏航控制系统研究 [J]. 电子测量与仪器学报, 2016, 30(12): 1949-1957. DOI:10.13382/j.jemi.2016.12.019.
- [3] 史光宇, 徐健, 杨强. 基于卷积神经网络的风电机组轴承机械故障智能诊断方法 [J]. 华北电力大学学报(自然科学版), 2020, 47(4): 71-79. DOI:10.3969/j.issn.1007-2691.2020.04.09.
- [4] 赵洪山, 闫西慧, 王桂兰, 等. 应用深度自编码网络和 XGBoost 的风电机组发电机故障诊断 [J]. 电力系统自动化, 2019, 43(1): 81-86. DOI:10.7500/AEPS20180708001.
- [5] 刘一江, 冯云锋, 刘昌盛, 等. 风电变流器故障诊断及便携式平台设计 [J]. 河南科技, 2025, 52(23): 23-26. DOI:10.19968/j.cnki.hnkj.1003-5168.2025.23.004.