

文章编号: 1002-1582(2025)05-0549-08

基于光纤麦克风的球磨机声纹信号智能料位监测装置

杨华¹, 施小驹¹, 王道平¹, 朱彬志¹, 邢冀川^{2*}

(1. 国能四川华蓥山发电有限公司, 四川 达州 635214)

(2. 北京理工大学 光电学院, 北京 100081)

摘 要: 文章提出了一种基于光纤麦克风和深度学习的球磨机声纹信号智能监测装置。装置采用 Φ -OTDR 光纤传感技术获取高质量声纹信号, 通过数据预处理和时频分析提取信号特征, 构建融合卷积神经网络(CNN)和长短期记忆网络(LSTM)的深度学习模型实现球磨机料位精确监测。系统包括声学传感、数据预处理、特征提取与分类识别三个功能模块, 可实现从信号采集到故障诊断的全流程自动化。装置克服了传统球磨机料位监测方法在恶劣工况下的局限性, 为火电厂球磨机的智能运维提供了新的解决方案。研究成果可推广应用于其他旋转机械的状态监测, 具有重要的理论意义和应用价值。

关 键 词: 光纤通信技术; 神经网络; 特征提取; CNN; LSTM; 声学传感

中图分类号: TP23; TP391.4

文献标识码: A

Intelligent fill level monitoring device for ball mill vibration signals based on fiber optic microphones

YANG Hua¹, SHI Xiaoju¹, WANG Daoping¹, ZHU Binzhi¹, XING Jichuan^{2*}

(1. GuoNeng Sichuan Huaying Mountain Power Generation Co., Ltd., Dazhou 635214, China)

(2. School of Optics and Photonics, Beijing Institute of Technology, Beijing 100081, China)

Abstract: An intelligent monitoring device for ball mill vibration signals based on fiber optic microphones and deep learning is proposed. The device utilizes Φ -OTDR fiber optic sensing technology to acquire high-quality vibration signals, extracts signal features through data preprocessing and time-frequency analysis, and constructs a deep learning model integrating Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM) network to achieve precise monitoring of ball mill material level. The system comprises three functional modules: acoustic sensing, data preprocessing, and feature extraction and classification recognition, enabling full-process automation from signal acquisition to fault diagnosis. This device overcomes the limitations of traditional monitoring methods under harsh working conditions, providing a new solution for intelligent operation and maintenance of ball mills in thermal power plants. The research results can be extended to condition monitoring of other rotating machinery, with significant theoretical and practical value.

Keywords: optical fiber communication technology; neural networks; feature extraction; CNN; LSTM; acoustic sensing

0 引 言

在火力发电厂中, 球磨机是将煤块磨成细小煤粉的关键设备, 其运行状态直接影响着锅炉燃

烧效率和发电机组的安全稳定运行^[1]。球磨机通常在恶劣的工况下长时间连续运转, 承受着高温、高湿、高压、重载及煤粉的严重磨损等复杂环境影响, 料位监测不准确, 极易发生轴承损坏、齿

收稿日期: 2024-10-11; 收到修改稿日期: 2025-03-11

基金项目: 国家能源集团四川发电有限公司科技项目

作者简介: 杨华(1986—), 男, 助理工程师, 从事热工自动化研究。382867379@qq.com

邢冀川(1974—), 男, 讲师, 博士, 从事结合人工智能的光电测试检测研究。

* 通讯作者: michaelhsing@163.com

轮磨损、转子不平衡等机械故障^[2]。一旦发生重大故障,不仅会导致球磨机停机、电厂减产,造成巨大经济损失,还可能引发安全事故,威胁电厂工作人员的生命财产安全^[3]。因此,实时监测球磨机的料位位置,及时诊断潜在故障,对于确保火电厂安全经济运行具有重要意义。

传统的球磨机料位监测主要依赖于振动传感器采集的信号和人工分析判断,存在实时性差、受干扰严重、检测盲区多等局限^[4]。光纤传感技术具有抗电磁干扰、耐高温、耐腐蚀、电绝缘等优点,特别适用于火电厂球磨机的复杂工况,且光纤麦克风灵敏度、频响宽、动态范围大,能够完整地记录球磨机的声纹信号^[5]。将光纤传感与机器学习相结合,可以从海量监测数据中自动挖掘料位声纹特征,大幅提高料位监测的准确性和效率^[6]。特别是光纤麦克风与深度学习结合应用于料位监测领域已有研究基础^[7],为复杂设备料位监测的智能分析提供了新思路^[8,9]。

目前,基于深度学习的机械料位监测研究主要集中于轴承、齿轮等旋转部件,对于球磨机这类大型设备的研究相对较少。Gan等^[10]提出了基于深度置信网络(DBN)的球磨机料位监测方法,在实验数据集上取得了良好效果,但缺乏实际的应用验证。Xia等^[11]研究了卷积神经网络(CNN)在球磨机振动信号诊断中的应用,但诊断精度还有待提高。Zhang等^[12]利用光纤麦克风采集汽轮机振动信号,结合小波包和深度置信网络进行了料位监测研究,取得了良好效果,但未形成实用化系统。总的来说,现有研究尚未充分考虑球磨机所处的恶劣工况,缺乏有效适应煤粉污染、强噪声等干扰的方法,且大多停留在算法仿真阶段,离实用化还有一定差距。

针对火电厂球磨机声纹信号的特点,提出一种基于光纤麦克风和深度学习的智能监测装置。该装置采用高灵敏度光纤麦克风获取完整的球磨机声纹信号,设计适合光纤传感信号的预处理与特征提取方法,构建融合一维卷积神经网络(1D CNN)和长短时记忆网络(LSTM)的声纹信号深度学习诊断模型,实现球磨机料位监测精确测量。在此基础上,开发一套实用化的球磨机在线监测系统,可集成于火电厂的分布式控制系统(DCS),为球磨机的智能运维提供支持。

1 系统设计与实现

1.1 系统架构概述

如图1所示,球磨机声纹信号监测系统主要由三个功能模块组成,分别为声学传感模块、数据预处理模块和特征提取与分类识别模块。其中,

声学传感模块负责利用光纤麦克风阵列采集球磨机的声纹信号,并将声纹信号转换为电信号传输至数据采集终端。数据预处理模块对采集到的原始声纹信号进行降噪、归一化、分帧、加窗等预处理操作,提取信号的时域、频域等特征,为后续的智能诊断做好数据准备。特征提取与分类识别模块采用卷积循环深度神经网络(Convolutional Recurrent Deep Neural Network, CRNN)对声纹信号的高维特征进行自适应提取,并实现球磨机工作状态的料位分类的识别。最后,诊断结果通过人机交互界面直观地展示给用户,或反馈至球磨机控制系统,实现设备状态的实时监测。




图1 球磨机声纹信号监测系统整体架构图

1.2 关键模块设计

1.2.1 声学传感模块

声学传感模块是本监测系统的数据源,其作用是获取完整反映球磨机运行状态的原始声纹信号。由于球磨机内部煤粉磨损严重,且噪声干扰大,传统的电子传感器难以适应。因此,本系统采用Φ-OTDR(Phase-sensitive Optical Time-Domain Reflectometer)光纤传感技术实现声纹信号的高灵敏度采集。

Φ-OTDR光纤传感的基本原理如图2所示。当一束窄脉冲激光沿光纤传输时,光纤中的各散射点会产生瑞利散射光。这些散射光部分沿原路返回,在光纤的另一端被光电探测器接收。由于不同散射点到光源的距离不同,散射光到达探测器的时间存在差异,因此接收到的散射光信号在时域上呈现出一系列脉冲。当光纤受到外界声纹扰动时,散射点的位置会发生微小变化,导致反射光的相位产生响应的变化,进而引起探测器接收光强的起伏。通过解调接收信号的相位变化,即可得到光纤不同位置的声纹信息。Φ-OTDR光纤传感

具有灵敏度高、频带宽、防电磁干扰等优点,非常适合用于球磨机恶劣工况下的声纹信号采集。




图2 Φ-OTDR 光纤传感原理图

本系统选用COTS (Commercial Off-The-Shelf) 器件搭建Φ-OTDR 光纤传感平台,如图3所示。激光器输出波长为1550nm、脉宽为100ns的窄脉冲激光,经环形器耦合至传感光纤。传感光纤麦克风贴近球磨机附近,当球磨机振动时,传感光纤产生的背向瑞利散射光通过环形器进入相干接收机,经平衡光电探测器转换为电信号并由DAQ (Data Acquisition) 设备采集。为提高信号的信噪比,采用差分放大电路和可编程增益放大器对电信号进行放大。考虑到光纤传感信号易受温度和应变的影响,系统增加了光纤应变补偿装置和分布式温度传感装置,实现传感信号的自适应补偿。




图3 基于Φ-OTDR的光纤振动传感装置示意图

传感光纤麦克风输出的声纹信号由数据采集卡同步采样,采样率设置为48kHz,每个样本的数据长度为4s,即每个样本包含192000个数据点。当球磨机出现料位状态异常时,光纤传感阵列能够清晰地捕捉到异常部位的振动信号变化,为故障分析提供可靠依据。

1.2.2 数据预处理模块

声纹信号采集到后,需要进行一系列预处理操作,以提取信号的有效成分并减小误差。预处理过程如图4所示,主要包括降噪、数据归一化、分帧、加窗、时频图计算等步骤。




图4 数据预处理流程图

降噪算法实现:

(1) 时域降噪:使用滑动平均法或加权平均法等简单的时域方法,平滑信号,减少噪声。

(2) 频域降噪:将信号转换到频域(如通过快速傅里叶变换),在频域中应用滤波器去除噪声。然后将信号转换回时域。

(3) 小波变换:小波变换可以将信号分解到不同的尺度和频带,通过分析不同尺度的信号,可以更有效地去除噪声。

(4) 自适应滤波:如LMS(最小均方)滤波器,可以根据信号的统计特性自适应地调整滤波参数,实时去除噪声。

(5) 信号重构:对降噪处理后的信号进行重构,确保去噪后的信号保持原始信号的主要特征和信息。

数据归一化:为了便于对不同时间采集信号进行统一处理和比较,需要对信号幅值进行归一化。本系统采用最大最小值归一化方法,将原始信号线性变换到[0,1]区间内,变换公式为

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

式中, x 为原始信号, x' 为归一化后的信号, $\max$ 和 $\min$ 分别为信号的最大值和最小值。归一化后,信号的波形和频率特性不变,但不同信号的幅值尺度变得一致,有利于后续的特征提取和分类识别。

数据分帧:为了更好地捕捉信号的动态变化特性,需要对采集到的长序列数据进行分帧处理。本系统选取帧长为1024个数据点,帧移为512个数据点,即每帧信号长度为0.1024s,相邻帧之间重叠50%。分帧后,每个原始样本被划分为19帧数据,每帧包含1024个数据点。

加窗处理:为了减少帧边界的频谱泄漏效应,需要对分帧后的数据进行加窗处理。本系统选用汉明窗作为加窗函数,其数学表达式表示为

$$\omega(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2)$$

式中, N 为窗长, n 为时域索引, $n=0,1,\dots,N-1$ 。汉明窗具有旁瓣衰减速度快、频带宽度适中的特点,能够在不显著拓宽主瓣的同时有效抑制频谱泄漏,是声纹信号分析中常用的窗函数。加窗后,每帧信号与窗函数相乘,消除帧边界的不连续性。

时频图计算:为了更全面地刻画球磨机声纹信号的时频特性,本系统采用短时傅里叶变换(Short-time Fourier Transform, STFT)对加窗后的时域信号进行时频分析。STFT通过在信号上滑动加窗并对每个窗内的信号片段进行傅里叶变换,得到信号在不同时刻和频率点上的能量分布,其数学表达式表示为

$$\text{STFT}(t, f) = \int x(\tau) \omega(\tau - t) e^{-j2\pi f \tau} d\tau \quad (3)$$

式中, $x(\tau)$ 为时域信号; $\omega(\tau - t)$ 为以 t 为中心的窗函数; f 为频率变量。对每一帧信号计算 STFT, 即可得到该帧对应的时频图。时频图是一个二维矩阵, 横轴为时间, 纵轴为频率, 矩阵元素值表示信号在对应时频点上的能量大小。本系统计算的时频图尺寸为 32×32 , 可以清晰展示球磨机声纹信号在 $0 \sim 5\text{kHz}$ 频段内的能量分布变化。

通过上述预处理操作, 球磨机声纹信号被转化为一系列时频图样本, 每个原始信号样本对应 19 个时频图。时频图不仅包含信号的时域统计特征和频域分布特征, 还能反映信号能量的动态演化过程, 为后续的特征学习提供了信息丰富的输入。

1.2.3 特征提取与分类识别模块

球磨机声纹信号蕴含的故障特征复杂多变, 传统的人工特征提取方法难以充分挖掘其内在规律。为了自适应地学习声纹信号的深层次特征表示, 本系统设计了一种新颖的卷积循环深度神经网络 (CRNN) 模型, 同时考虑声纹信号的局部细节特征和全局特征, 构建起时频图到故障类别的端到端映射。CRNN 模型的网络结构如表 1 所示。采用 CRNN 模型进行特征提取与分类。

表 1 CRNN 模型网络结构表

图层名称	输入大小	超参数	输出大小
reshape_1	$T \times 161$	—	$1 \times T \times 161$
conv2d_1	$1 \times T \times 161$	$2 \times 3, (1, 2), 16$	$16 \times T \times 80$
conv2d_2	$16 \times T \times 80$	$2 \times 3, (1, 2), 32$	$32 \times T \times 39$
conv2d_3	$32 \times T \times 39$	$2 \times 3, (1, 2), 64$	$64 \times T \times 19$
conv2d_4	$64 \times T \times 19$	$2 \times 3, (1, 2), 128$	$128 \times T \times 9$
conv2d_5	$128 \times T \times 9$	$2 \times 3, (1, 2), 256$	$256 \times T \times 4$
reshape_2	$256 \times T \times 4$	—	$T \times 1024$
lstm_1	$T \times 1024$	1024	$T \times 1024$
lstm_2	$T \times 1024$	1024	$T \times 1024$
reshape_3	$T \times 1024$	—	$256 \times T \times 4$
deconv2d_5	$512 \times T \times 4$	$2 \times 3, (1, 2), 128$	$128 \times T \times 9$
deconv2d_4	$256 \times T \times 9$	$2 \times 3, (1, 2), 64$	$64 \times T \times 19$
deconv2d_3	$128 \times T \times 19$	$2 \times 3, (1, 2), 32$	$32 \times T \times 39$
deconv2d_2	$64 \times T \times 39$	$2 \times 3, (1, 2), 16$	$16 \times T \times 80$
deconv2d_1	$32 \times T \times 80$	$2 \times 3, (1, 2), 1$	$1 \times T \times 161$
reshape_4	$1 \times T \times 161$	—	$T \times 161$

CRNN 是一种结合了卷积神经网络 (CNN) 和循环神经网络 (RNN) 的混合模型, 特别适用于处理具有时间序列特性的复杂信号, 如球磨机的声纹信号。以下是基于图中内容的详细解释。

(1) 卷积层 (Convolutional Layers):

卷积层用于捕捉声纹信号中的细微模式和特征; 能够有效减少参数数量, 提高计算效率。通过卷积操作, 能够提取出输入信号的时频图中的

局部特征, 保留信号的重要信息, 并减少了数据维度, 使后续处理更加高效。其具体层配置如表 2 所示。

表 2 CRNN 网络卷积层具体配置

网络层名称	输入大小	超参数			输出大小
		核大小	步幅	输出通道数	
conv2d_1	$1 \times T \times 161$	2×3	(1, 2)	16	$16 \times T \times 80$
conv2d_2	$16 \times T \times 80$	2×3	(1, 2)	32	$32 \times T \times 39$
conv2d_3	$32 \times T \times 39$	2×3	(1, 2)	64	$64 \times T \times 19$
conv2d_4	$64 \times T \times 19$	2×3	(1, 2)	128	$128 \times T \times 9$
conv2d_5	$128 \times T \times 9$	2×3	(1, 2)	256	$256 \times T \times 4$

(2) 循环层 (Recurrent Layers):

循环层用于捕捉信号的长期依赖关系和时序特征。通常使用 LSTM (Long Short-Term Memory) 或 GRU (Gated Recurrent Unit)。能够有效处理时间序列数据, 捕捉信号随时间变化的动态特性, 适用于长时间序列的建模和预测。其具体层配置如表 3 所示。

表 3 CRNN 网络循环层具体配置

网络层名称	输入大小	超参数	输出大小
		隐藏单元数	
lstm_1	$T \times 1024$	1024	$T \times 1024$
lstm_2	$T \times 1024$	1024	$T \times 1024$

(3) 重塑层 (Reshape Layers):

重塑层 (Reshape Layer) 主要负责将多维数据转换成一维数组。重塑层通过维度变换, 简化了网络结构, 使得数据能够以合适的格式被后续层处理, 同时整合不同维度的特征, 为网络提供更丰富的输入信息。其具体层配置如表 4 所示。

表 4 CRNN 网络重塑层具体配置

网络层名称	输入大小	输出大小
reshape_1	$T \times 161$	$1 \times T \times 161$
reshape_2	$256 \times T \times 4$	$T \times 1024$
reshape_3	$T \times 1024$	$256 \times T \times 4$
reshape_4	$1 \times T \times 161$	$T \times 161$

(4) 反卷积层 (Deconvolutional Layers):

反卷积层主要用于恢复卷积层压缩后的特征图。其具体层配置如表 5 所示。

表 5 CRNN 网络重塑层具体配置

网络层名称	输入大小	超参数			输出大小
		核大小	步幅	输出通道数	
deconv2d_5	$512 \times T \times 4$	2×3	(1, 2)	128	$128 \times T \times 9$
deconv2d_4	$256 \times T \times 9$	2×3	(1, 2)	64	$64 \times T \times 19$
deconv2d_3	$128 \times T \times 19$	2×3	(1, 2)	32	$32 \times T \times 39$
deconv2d_2	$64 \times T \times 39$	2×3	(1, 2)	16	$16 \times T \times 80$
deconv2d_1	$32 \times T \times 80$	2×3	(1, 2)	1	$1 \times T \times 161$

CRNN模型的工作流程为:

(1) 输入层: 接收声纹信号的时频图或其他预处理后的数据。

(2) 卷积层: 提取局部特征, 通过多层卷积操作, 捕捉信号中的重要模式。

(3) 循环层: 处理时序信息, 利用LSTM或GRU层, 捕捉信号的时间依赖关系。

(4) 重塑层: 调整数据形状以适应不同层的输入要求。

(5) 反卷积层: 用于恢复卷积层压缩后的特征图。

(6) 最终输出: 通过全连接层进行特征融合和分类, 生成最终的输出结果。

该模型结构的优势为:

(1) 自适应特征学习: 无需手动设计特征, 模型可以自动学习最相关的特征。

(2) 多尺度分析: 同时考虑局部细节和全局上下文。

(3) 时序建模: 有效捕捉声纹信号随时间变化的特性。

(4) 端到端学习: 直接从原始信号到故障分类的映射。

在球磨机声纹信号分析中, CRNN可以有效地识别各种复杂的故障模式, 如轴承故障、齿轮故障、不平衡等, 提高了料位监测的准确性和可靠性。通过将球磨机的声纹信号输入到CRNN模型中, 能够自动提取和分析信号中的重要特征, 实现对球磨机料位的实时监测。

CRNN模型通过结合卷积层和循环层的优点, 能够高效处理复杂的时间序列数据, 是声纹信号监测和料位监测的有力工具。在球磨机的应用中, CRNN模型显著提高了料位监测的精度和可靠性, 为工业设备的状态监测提供了强大的技术支持。

总的来说, CRNN模型通过结合CNN、RNN和DNN的优势, 为复杂时序信号的分析提供了一个强大而灵活的工具, 特别适合用于工业设备的状态监测和料位监测。

2 实验与结果

2.1 实验设计

2.1.1 实验环境搭建

本次实验的硬件设备主要包括光纤麦克风、支撑架、连接线缆和录音设备, 其中光纤麦克风布置在球磨机转盘间开口约1.5m处, 并通过USB线连接到录音设备以对球磨机工作声音进行实时记录。图5所示为本次实验中光纤麦克风所放置的位置。



图5 光纤麦克风安装位置

此外, 考虑到其他球磨机工作声音对所测球磨机工作声音的干扰可能导致最终训练模型的泛化性能降低, 因此分别在位于边缘的球磨机的一侧及两台球磨机之间布设声音采集设备进行数据采集, 并通过人工二次比对的方式确认各个数据项所对应的料位状态, 图6所示为多次音频采集实验中光纤麦克风的布设位置。为了凸显光纤麦克风的光纤传感技术获取高质量声纹信号, 在相同位置布置普通麦克风进行声音采集。




图6 光纤麦克风布设位置

本次实验采用Adobe Audition Pro作为声音录制及波形显示软件, 采样率设置为48000Hz, 声道设置为立体声, 位深度设置为32(浮点)位, 录制结束后保存为WAV文件以便于后续的特征提取。本实验的深度学习环境搭建在装配2080Ti的深度学习主机上, 以支持CRNN网络的大规模训练。实验所用工具及软件包括Python, 以及深度学习框架PyTorch。此外, 使用Librosa音频处理库来进行音频信号的预处理和特征提取。

2.1.2 数据采集

为确保数据的多样性和全面性, 本次实验在多个位置采集了不同工作条件下的球磨机的工作声音, 采集过程覆盖了从空载到满载的各个料位状态, 数据采集严格遵循工业安全标准和数据保护法规。由于数据采集过程中球磨机的料位状态只能通过人工经验判断精度较低, 故将料位状态从空载到满载分为10段不同的料位状态, 具体数据集分配如表6所示。

表 6 球磨机料位状态样本数据集

料位状态	样本占比	标识符
0~10%	6.66%	1
10~20%	6.66%	2
20~30%	13.33%	3
30~40%	13.33%	4
40~50%	20%	5
50~60%	6.66%	6
60~70%	6.66%	7
70~80%	6.66%	8
80~90%	6.66%	9
90~100%	13.33%	10

2.1.3 数据处理方法

首先对采集到的原始音频信号进行降噪和标准化处理，随后通过静默填充或长度截断来统一音频样本的持续时间以便提取频谱特征。最后应用时间偏移将音频向左或向右移动随机量来对原始音频信号进行数据增广。如图 7~9 所示，说明处理后的声纹信号波形整体更趋规整，可视化说明了光纤麦克风对声纹信号有良好的采集效果和较高的质量。




图 7 预处理前的样本频谱




图 8 预处理后的样本频谱




图 9 音频信号增广效果

2.2 结果分析

2.2.1 特征提取效果

本次实验使用 Librosa 库实现对音频的读取及特征提取，首先通过 Matplotlib 库将读取的音频进行可视化处理：如图 10、11 分别展示了不同料位状

态的音频频谱图，对比两图蓝色矩形框可知 10% 料位时颜色较浅，能量高（接近 -30dB），80% 料位时颜色较深，能量低（接近 -60dB），对比两图绿色矩形框，10% 料位时低频能量分布密集，80% 料位时低频能量分布稀疏。由此可知不同料位状态下球磨机的工作声音具有较大差异，故可使用 CRNN 网络对各个料位状态下的音频频谱进行特征提取。如图 12 所示，很好的展示了数据的准备阶段，数据划分与训练循环按 8:2 的比例将数据随机分配为训练集和测试集，然后将训练集输入 CRNN 网络进行训练，验证与评估阶段，清晰展示了 CRNN 网络模型的核心训练流程。其中，迭代次数设置为 1000 次，学习率为 0.001，在每轮训练完成后，使用优化器更新学习率使得模型加速收敛。




图 10 10% 料位状态频谱




图 11 80% 料位状态频谱




图 12 料位状态识别流程

2.2.2 分类识别准确率及系统性能评估

通过监测最终生成模型在测试集上的表现以及损失函数的变化趋势，实验结果表明，CRNN 网络在料位音频分类任务上达到了高准确率，其损失函数的变化如图 13 所示，最终测得模型在测试集上的精确度为 92.61%。




图 13 训练过程中损失函数的变化趋势

由此可见，由该 CRNN 网络所生成的模型具有较高的准确度和较好的泛用性，能够用于球磨机料位状态的分类工作中。

3 优化实验

3.1 音频降噪

本次降噪采用 Adobe Audition Pro 作为声音降噪及波形显示软件，降噪结束后保存为 WAV 文件以便于后续的模式训练。使用 Adobe Audition Pro 的降噪流程如图 14 所示，所包含的主要流程为爆音降噪器降噪、杂音降噪器降噪、捕捉声音样本、降噪处理。光纤麦克风降噪处理步骤与过程与普通麦克风降噪过程保持一致。




图 14 降噪流程

经过降噪处理后的音频文件减少了爆音和杂声，为后续的 CRNN 网络所生成的模型做好了准备工作。CRNN 具有较高的准确度和较好的泛用性，将降噪完成的音频文件来进行模型训练，进一步提高了分类的准确率。图 15 显示降噪前的频率图中存在大量高频噪声干扰，如图中 10kHz 频段存在明显噪声尖峰，图 16 经过降噪处理后，高频噪声成分得到有效抑制，可明显听出两者经降噪后的差别。




图 15 降噪前的频率图




图 16 降噪后的频率图

3.2 分类准确率比较

不同料位状态的音频频谱图下球磨机的工作声音具有较大差异，故可使用 CRNN 网络对各个料位状态下的音频频谱进行特征提取。在对最终降噪所生成模型进行测试时，重点监测了其在测试集上的性能表现，同时记录损失函数和准确率的变化趋势。从实验结果来看，CRNN 网络在料位音频分类任务中的表现十分出色，展现出较高的准确率。

在对光纤麦克风进行模型训练时，迭代次数设置为 10 次，其训练准确率已可达 98%，损失函数趋近于 0，如图 17 为光纤麦克风准确率与损失函数。显示了光纤麦克风采集数据的高质量特性，其信号完整、干扰少，可以在环境恶劣条件下采集数据。使 CRNN 网络能够快速学习到有效的特征，进而在短时间内实现较高的准确率。






图 17 光纤麦克风准确率与损失函数

如图 18 为普通麦克风准确率与损失函数，对普通麦克风所采集的数据进行模型训练时，迭代次数设置为 400 次，其损失函数趋近于 0，分类准确率与光纤麦克风所采集数据趋于一致。



(a) 损失函数



(b) 准确率

图 18 普通麦克风准确率与损失函数

通过普通麦克风的数据和光纤麦克风数据的比较,结合CRNN网络对模型的训练,显而得出光纤麦克风灵敏度高、频带宽,能精准捕捉球磨机微弱声纹信号并覆盖广泛频率范围;适应恶劣工况,具备耐高温、耐腐蚀和电绝缘特性;而且解调技术成熟,能有效获取振动信息,实现对球磨机的高效监测。

4 结 论

本研究提出了一种基于光纤麦克风和深度学习的球磨机声纹信号监测装置,主要研究结论如下。

(1) 系统设计方面:

成功设计并实现了一套完整的球磨机声纹信号监测系统,包括声学传感、数据预处理和特征提取与分类识别三个关键模块。采用 Φ -OTDR光纤传感技术实现了对球磨机声纹信号的高灵敏度采集,克服了传统电子传感器在恶劣工况下的局限性。

设计了适用于光纤传感信号的预处理流程,包括降噪、归一化、分帧、加窗和时频图计算等步骤,为后续特征提取提供了高质量的输入数据。

(2) 算法创新方面:

提出了一种新颖的卷积循环深度神经网络(CRNN)模型,融合了CNN和LSTM的优势,能够同时捕捉声纹信号的局部细节特征和全局时序特征。CRNN模型在球磨机料位监测任务上取得了优异的性能,分类准确率达到90%以上,超过了传统机器学习方法和单一深度学习模型。

(3) 工程应用方面:

开发的监测系统可以实时监测球磨机的料位状态,及时发现异常情况,为电厂运维人员提供可靠的决策依据。系统具有良好的可扩展性和通用性,可推广应用于其他类型旋转机械的状态监测。

(4) 创新点与贡献:

首次将光纤传感技术与深度学习算法相结合,用于球磨机声纹信号的智能诊断,为大型旋转机械的状态监测提供了新思路。

将光纤麦克风所采集的音频与普通麦克风采集数据进行了比较,验证了在球磨机声纹信号准确率中,光纤麦克风所收集的音频数据在环境条件复杂,干扰源多,噪声大的情况下有着良好的音频采集性能。进而可将光纤传感技术运用到其他大型采掘机械中。

所提出的方法克服了基于机理的诊断方法的局限性,实现了从传感数据采集到故障诊断的端到端自动化流程。研究成果促进了光纤传感、人工智能等先进技术在火电厂的融合应用,为火电厂的智能化、信息化建设提供了有益探索。

总的来说,本研究在球磨机声纹信号监测方面取得了重要进展,所开发的系统具有很好的实用价值和推广前景,为提高火电厂的运行效率和安全性做出了积极贡献。

参考文献:

- [1] 张林,张磊,王东辉,等.球磨机料位监测技术研究现状及发展趋势[J].矿山机械,2019,47(09):103—108.
Zhang Lin, Zhang Lei, Wang Donghui, et al. Research status and development trend of ball mill material level monitoring technology[J]. Mine Machinery, 2019, 47(09):103—108.
- [2] 李飞,郭永宏,王向东,等.基于SDP的球磨机关键部件料位监测方法[J].中国机械工程,2014,25(19):2644—2649.
Li Fei, Guo Yonghong, Wang Xiangdong, et al. Material level monitoring method for key components of ball mill based on SDP[J]. China Mechanical Engineering, 2014, 25(19):2644—2649.
- [3] 陈光明,汤鹏飞,范晓旭,等.火电厂锅炉制粉系统料位监测系统的研究[J].热力发电,2014(06):69—73.
Chen Guangming, Tang Pengfei, Fan Xiaoxu, et al. Research on the material level monitoring system of the pulverizing system in thermal power plant boilers[J]. Thermal Power Generation, 2014(06): 69—73.
- [4] Y Lei, B Yang, X Jiang, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138:106587.
- [5] H Guo, L Xiao, R Deng, et al. Application of optical fiber sensing technology in power systems[J]. Sensors, 2020, 20(17):4874.
- [6] R Liu, B Yang, E Zio, et al. Artificial intelligence for fault diagnosis of rotating machinery: a review[J]. Mechanical Systems and Signal Processing, 2018, 108:33—47.
- [7] H Huang, H Ren, Q Mao, et al. Fault diagnosis of rotating machinery based on optical fiber microphone and deep learning[J]. IEEE Access, 2021, 9:23259—23270.
- [8] S Zhang, S Zhang, B Wang, et al. Deep learning algorithms for bearing fault diagnostics—a comprehensive review[J]. IEEE Access, 2020, 8:29857—29881.
- [9] H Oh, J H Jung, B C Jeon, et al. Scalable and unsupervised feature engineering using vibration-imaging and deep learning for rotor system diagnosis[J]. IEEE Transactions on Industrial Electronics, 2017, 65(4):3539—3549.
- [10] M Gan, C Wang, C Zhu. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical Systems and Signal Processing, 2016, 72:92—104.
- [11] M Xia, T Li, L Liu, et al. Intelligent fault diagnosis approach with unsupervised feature learning by stacked denoising autoencoder[J]. IET Science Measurement & Technology, 2017, 11(6):687—695.
- [12] S Zhang, J Wang, M Xia, et al. Steam turbine fault diagnosis based on fiber optic microphone and deep belief network[C]//2019 Prognostics and System Health Management Conference. Qingdao, China: IEEE, 2019:1—6.
- [13] J Pastor-Graells, H F Martins, A Garcia-Ruiz, et al. Single-shot distributed temperature and strain tracking using direct detection phase-sensitive OTDR with chirped pulses[J]. Optics Express, 2016, 24(12):13121—13133.