

文章编号: 1671-251X(2025)02-0100-06

DOI: [10.13272/j.issn.1671-251x.2023090025](https://doi.org/10.13272/j.issn.1671-251x.2023090025)

基于卷积自编码器的煤矿带式输送机 异常声音检测方法

申龙, 单浩然, 裴文良, 杨贵翔, 王永利

(中信重工开诚智能装备有限公司, 河北 唐山 063020)

摘要: 针对煤矿带式输送机异常声音样本缺少导致训练模型难以进行异常识别的问题, 提出一种基于卷积自编码器(CAE)的煤矿带式输送机异常声音检测方法。首先, 采集煤矿带式输送机托辊、减速机、电动机正常运行的声音信号, 通过 WebRTC 降噪算法过滤信号中的背景噪声, 计算降噪后信号的梅尔频率倒谱系数(MFCC), 获得设备正常运行的音频特征并输入到 CAE 中进行训练, 得到训练好的 CAE 及重构的正常运行音频特征。其次, 将正常运行音频特征和重构的正常运行音频特征输入均方损失函数(MSELoss), 得到重构误差, 并取重构误差最大值作为正常运行音频特征的重构阈值。然后, 采集待检测的煤矿带式输送机托辊、减速机、电动机运行的声音信号, 经 WebRTC 降噪、MFCC 特征提取后输入到训练好的 CAE, 获得重构的待检测音频特征, 将待检测音频特征与重构的待检测音频特征输入 MSELoss, 得到待检测音频的重构误差。最后, 将待检测音频的重构误差与正常运行音频特征的重构阈值进行比较, 若前者大于后者, 则判断煤矿带式输送机存在异常。实验结果表明: 在没有异常声音样本参与训练的情况下, 该方法在带式输送机托辊、减速机、电动机运行声音数据集上的检测精确率分别达 92.55%, 94.98%, 93.60%, 单组声音检测时间为 1.230 s, 实现了检测精度和检测速度之间的平衡。

关键词: 煤矿带式输送机; 故障诊断; 异常声音检测; 卷积自编码器; MFCC

中图分类号: TD528/634

文献标志码: A

Abnormal sound detection method for coal mine belt conveyors based on convolutional autoencoder

SHEN Long, SHAN Haoran, PEI Wenliang, YANG Guixiang, WANG Yongli

(CITIC Heavy Industries Kaicheng Intelligence Equipment Co., Ltd., Tangshan 063020, China)

Abstract: To address the issue of insufficient abnormal sound samples for coal mine belt conveyors, which makes it difficult for training models to recognize anomalies, an abnormal sound detection method for coal mine belt conveyors based on Convolutional Autoencoder (CAE) is proposed. First, sound signals from the normal operation of the belt conveyor's idlers, reducer, and motor were collected. Background noise in the signals was filtered using the WebRTC noise reduction algorithm, and Mel-Frequency Cepstral Coefficients (MFCC) were calculated from the denoised signals to obtain audio features of normal operation. These features were then input into the CAE for training, resulting in a trained CAE and reconstructed audio features of normal operation. Next, the normal operation audio features and the reconstructed normal operation audio features were input into the Mean Squared Error Loss function (MSELoss) to obtain the reconstruction error, with the maximum reconstruction error set as the reconstruction threshold for normal operation audio features. Then, sound signals from the operation of the coal mine belt conveyor's idlers, reducer, and motor to be inspected were collected. After noise reduction using WebRTC and MFCC feature extraction, they were input into the trained CAE to obtain the

收稿日期: 2023-09-06; 修回日期: 2025-02-26; 责任编辑: 盛男。

基金项目: 河北省高端装备制造技术创新专项项目(23311805D)。

作者简介: 申龙(1987—), 男, 河北唐山人, 现从事煤矿智能装备方面的工作, E-mail: cedyi2088@126.com。

引用格式: 申龙, 单浩然, 裴文良, 等. 基于卷积自编码器的煤矿带式输送机异常声音检测方法[J]. 工矿自动化, 2025, 51(2):

100-105.

SHEN Long, SHAN Haoran, PEI Wenliang, et al. Abnormal sound detection method for coal mine belt conveyors based on convolutional autoencoder[J]. Journal of Mine Automation, 2025, 51(2): 100-105.



扫码移动阅读

reconstructed audio features of the inspected samples. The inspected audio features and the reconstructed audio features were then input into the MSELoss to calculate the reconstruction error of the inspected audios. Finally, the reconstruction error of the test audio was compared with the reconstruction threshold of normal operation audio features. If the former exceeded the latter, the coal mine belt conveyor was identified as abnormal. Experimental results showed that, without abnormal sound samples involved in training, the proposed method achieved detection accuracies of 92.55%, 94.98%, and 93.60% for the idlers, reducer, and motor, respectively. The detection time for a single sound sample was 1.230 seconds, achieving a balance between detection accuracy and speed.

Key words: coal mine belt conveyor; fault diagnosis; abnormal sound detection; convolutional autoencoder; MFCC

0 引言

煤矿带式输送机包括电动机、减速机、托辊等设备,随着运行状态的变化,这些设备发出的声音存在差异^[1-4]。人工巡检时可根据设备运行声音来判断设备状态,但依赖巡检人员的个人经验,且仅靠人工巡检不能保证对设备的实时监测,无法及时发现故障。

深度学习通过神经网络学习设备运行中异常声音信号的特征^[5-8],进而表达数据中更抽象的特征。基于深度学习的带式输送机异常声音检测方法不仅在数据的特征提取与特征选择上降低了对人工经验的依赖,还提高了故障诊断实时性^[9]。倪旺旺^[10]提出了一种结合梅尔频率能量系数与图卷积网络的异常声音检测模型,该模型选取梅尔频率能量系数对声音进行特征提取,基于图卷积网络对图结构进行分类,提高了异常声音检测的精确率。曾锃等^[11]提出了一种基于卷积神经网络的放电声音检测方法,通过终端边缘节点实时监控电力设备状态,提高了对正常工作、局部放电和故障3种状态识别的准确率。卢安琪^[12]提出了一种基于注意力机制的泵机设备异常声音检测方法,提高了检测准确率。

上述方法在设备异常声音检测领域取得了很好的效果,但需要大量的异常声音样本,而在煤矿正常生产过程中,煤矿设备异常声音具有偶发性和多样性,难以获取满足模型训练的大量异常声音样本^[13],且现场采集的声音有一部分被淹没在噪声中,导致设备异常声音不能被有效检测。自编码器^[14]是一种在半监督和无监督任务中广泛应用的异常数据检测算法,能够在只有少量或没有异常样本的情况下检测数据中的异常^[15]。黄光球等^[16]提出了一种基于时域卷积网络的深度自编码器,解决了异常数据不足的问题。因此,本文提出一种基于卷积自编码器(Convolutional AutoEncoder, CAE)的煤矿带式输送机异常声音检测方法。对带式输送机正常运行的声

音信号进行WebRTC降噪并提取梅尔频率倒谱系数(Mel Frequency Cepstral Coefficient, MFCC)特征,经过CAE训练获得重构特征,进而通过均方误差损失函数(Mean Squared Error Loss, MSELoss)确定重构阈值;待检测声音信号经过降噪和特征提取后输入到训练好的CAE,计算重构误差并与重构阈值比较,从而判断带式输送机运行状态。

1 方法原理

基于CAE的煤矿带式输送机异常声音检测流程如图1所示。将煤矿带式输送机正常运行的声音信号通过WebRTC降噪进行噪声抑制处理,计算降噪后信号的MFCC特征,获得带式输送机正常运行的音频特征;将正常运行的音频特征输入到CAE中进行训练,获得重构的正常运行音频特征和训练好的CAE;将正常运行音频特征和重构的正常运行音频特征输入MSELoss,得到重构误差,取重构误差最大值作为正常运行音频特征的重构阈值。进行煤矿带式输送机异常声音检测时,待检测的带式输送机运行声音信号经WebRTC降噪和MFCC特征提取后,输入到训练好的CAE中进行推理,获得重构的待检测音频特征;将待检测音频特征与重构的待检测音频特征输入MSELoss,得到待检测音频的重构误差,并与正常运行音频特征的重构阈值进行比较,若重构误差大于重构阈值,则判断煤矿带式输送机运行异常。

1.1 WebRTC 降噪

WebRTC降噪支持8, 16, 32 kHz采样率,其他声音信号采样率可通过重采样的方式进行转换。WebRTC降噪的核心思想是对噪声进行估计并通过维纳滤波器抑制估计的噪声^[17]。

1.2 MFCC 特征提取

MFCC特征提取流程^[18]如图2所示。具体步骤:①使用预加重方式提高声音信号高频分量。②对

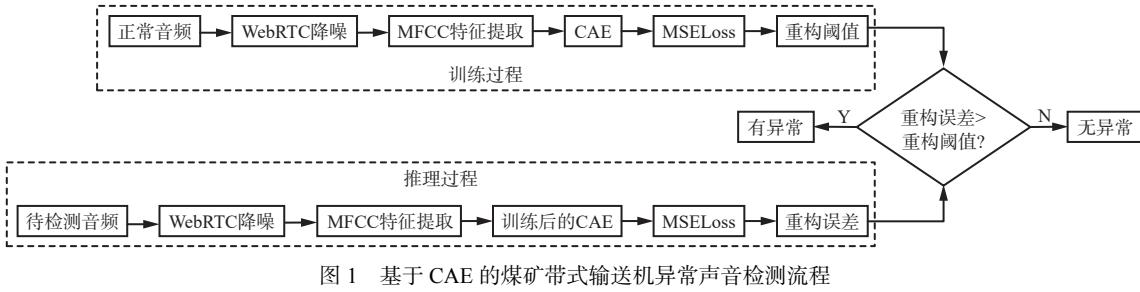


图 1 基于 CAE 的煤矿带式输送机异常声音检测流程

Fig. 1 Abnormal sound detection process of coal mine belt conveyor based on Convolutional AutoEncoder(CAE)

声音信号进行分帧、加窗, 设置帧长为 25 ms、帧移为 10 ms, 窗函数选择汉明窗以防止信号失真。③ 使用离散傅里叶变换对信号进行处理。④ 通过多个梅尔滤波器进行滤波。⑤ 计算每个滤波器输出频带的对数能量, 根据各个梅尔频带中的能量, 得到一定维数的特征。⑥ 通过反傅里叶变换, 对梅尔滤波器输出的对数能量进行倒谱分析, 获得 MFCC。⑦ 通过差分方式计算动态特征并与 MFCC 合并, 最终输出 MFCC 特征。

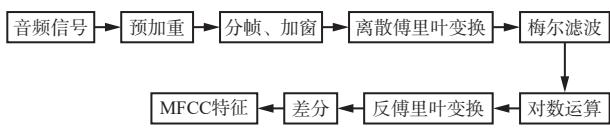


图 2 MFCC 特征提取流程

Fig. 2 Mel Frequency Cepstral Coefficient(MFCC) feature extraction process

1.3 CAE

CAE 由编码器和解码器 2 个部分组成^[19], 如图 3 所示。

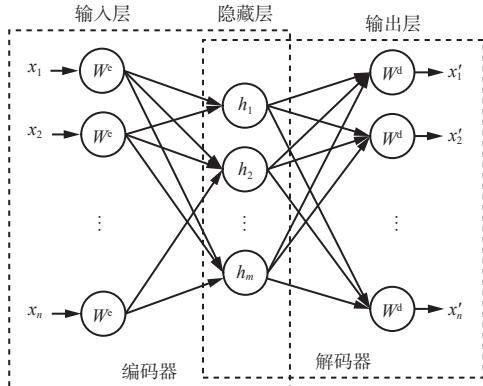


图 3 CAE 结构

Fig. 3 CAE structure

假设提取的 MFCC 特征训练集为 $\{x_1, x_2, \dots, x_n\}$, $x_j (j=1, 2, \dots, n, n \text{ 为输入层神经元数量})$ 为输入层第 j 个神经元的输入值, $x_j \in \mathbf{R}^n$ 。通过编码方式, 将训练集数据转换到低维子空间, 再通过解码的方式重新生成数据, 得到重构的数据 $\{x'_1, x'_2, \dots, x'_n\}$, x'_j 为输出层第 j 个神经元的输出值。

在编码器中, 高维特征向量 x_j 输入到编码器后被

压缩为低维特征向量 $h_i (i=1, 2, \dots, m, m \text{ 为隐藏层神经元数量})$ 。编码器压缩特征的过程可表示为

$$h_i = \text{sigmoid} \left(\sum_{i=1}^m \sum_{j=1}^n W_{ij}^e x_j + b_i^e \right) \quad (1)$$

式中: W_{ij}^e 为输入层第 j 个神经元指向隐藏层第 i 个神经元的权重; b_i^e 为隐藏层第 i 个神经元的偏置参数。

在解码器中, 将 h_i 映射到原始的输入空间 \mathbf{R}^n 上。解码器的映射过程可表示为

$$x'_j = \text{sigmoid} \left(\sum_{i=1}^m \sum_{j=1}^n W_{ij}^d h_i + b_j^d \right) \quad (2)$$

式中: W_{ij}^d 为隐藏层第 i 个神经元指向输出层第 j 个神经元的权重; b_j^d 为输出层第 j 个神经元的偏置参数。

CAE 通过优化 MSELoss 实现重构误差最小化。重构误差为

$$E = \sum_{j=1}^n (x_j - x'_j)^2 \quad (3)$$

2 实验验证

2.1 实验平台

煤矿带式输送机异常声音检测实验平台中, 拾音器的拾音距离为 5 m, 声音采样率设置为 16 kHz。拾音器搭载于矿用隔爆兼本安型轨道巡检机器人上, 随机器人在煤矿巷道设备日常巡检工作(机器人运行速度为 0.3 m/s)同步采集声音。拾音器将声音信号以 3 s 为 1 段进行分段处理, 并传输至服务器进行带式输送机异常声音检测。服务器硬件配置: 处理器 12th Gen Intel(R) Core(TM) i7-12700@ 2.1 GHz、32 GiB RAM、Windows 10、显卡 NVIDIA RTX 5000(显存 16 GiB, 核心频率 1 350 MHz, Turbo 频率 1 815 MHz)。

2.2 数据集

带式输送机运行声音来自于中煤陕西榆林大海则煤业有限公司大海则煤矿和神木市大柳塔东川矿业有限公司大柳塔煤矿。拾音器随巡检机器人行走到设备附近并采集声音信号后, 由经验丰富的矿方巡检人员将采集的声音信号去噪后分为设备正常声

音和设备异常声音。

煤矿带式输送机异常声音主要包括电动机、减速机、托辊的异常声音。电动机异常声音主要由轴承磨损、缺油、轴挡圈未装或松动、水泵盖擦碰等异常造成;减速机异常声音主要由电动机负载过重或负载不平衡及轴承损坏、润滑不良或安装不当等异常导致;托辊异常声音主要由托辊润滑不足、托辊轴承故障、托辊堵转等异常导致。

煤矿带式输送机运行声音数据集见表1。每组声音信号时长为1 s。从每组声音信号中提取384维MFCC特征。

表1 煤矿带式输送机运行声音数据集

Table 1 Operation sound data set of coal mine belt conveyor

标签	训练集/组	测试集/组
托辊正常	400	100
托辊异常	0	44
减速机正常	400	100
减速机异常	0	46
电动机正常	400	100
电动机异常	0	52

2.3 实验方案

为验证基于CAE的煤矿带式输送机异常声音检测方法的有效性,将其分别与基于支持向量数据描述(Support Vector Data Description, SVDD)^[20]和深度高斯混合模型(Deep Gaussian Mixture Model, DGMM)^[21]的煤矿带式输送机异常声音检测方法进行对比。

参数设置:① CAE。学习率为0.001;批大小为64;迭代轮数为300;编码器和解码器的卷积层数均为5,训练优化器选择Adam优化器,L2正则化参数为 5×10^{-4} 。② SVDD。学习率为0.001;批大小为64;迭代轮数为200;惩罚因子范围为 $[2^{-6}, 2^0]$,核参数范围为 $[2^{-6}, 2^3]$ 。③ DGMM。各个高斯分量的混合系数为0.1,初始化聚类中心的个数为10。

2.4 实验结果

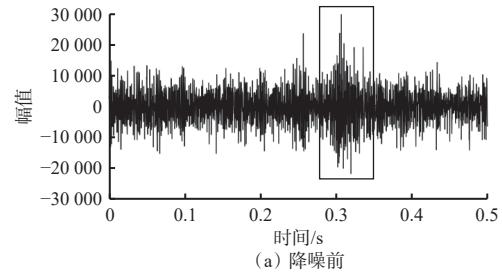
2.4.1 降噪效果

为减少环境噪声对带式输送机异常声音检测效果的干扰,对采集的声音信号进行降噪处理。降噪前后的声音信号波形如图4所示(矩形框部分为有效声音信号,其余为背景噪声)。可看出降噪前的声音信号中背景噪声比较明显,经过降噪处理后,背景噪声得到抑制,同时保留了音频特征。

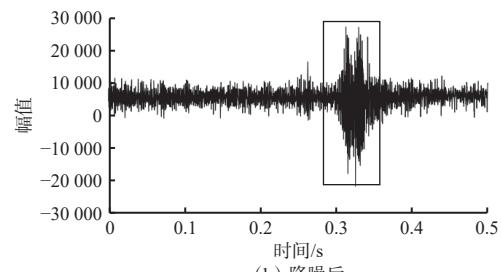
2.4.2 MFCC特征

提取降噪后的带式输送机托辊、减速机和电动机正常声音和异常声音的MFCC特征,分别如图5—图7所示。可看出带式输送机托辊、减速机和电动

机异常声音的MFCC特征范围明显高于正常声音的MFCC特征范围。



(a) 降噪前



(b) 降噪后

图4 降噪前后声音信号波形

Fig. 4 Waveforms of sound signal before and after noise reduction

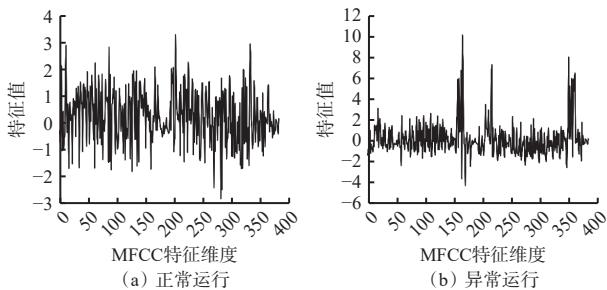


图5 托辊MFCC特征

Fig. 5 MFCC features of idler

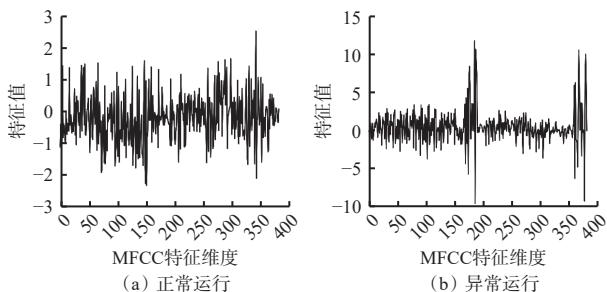


图6 减速机MFCC特征

Fig. 6 MFCC features of reducer

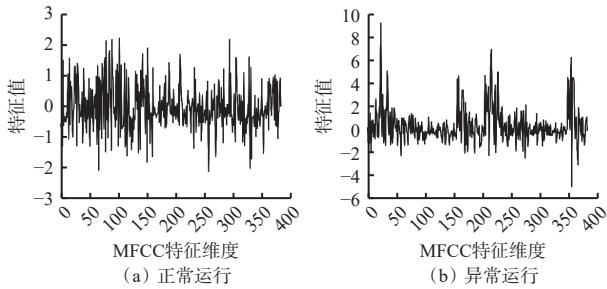


图7 电动机MFCC特征

Fig. 7 MFCC features of motor

2.4.3 检测性能

在带式输送机托辊、减速机和电动机运行声音数据集上, 分别基于 CAE, SVDD, DGMM 的带式输送机异常声音检测结果见表 2—表 4, 可看出 CAE 的精确率、召回率和 F_1 分数均为最优。

表 2 托辊异常声音检测结果

Table 2 Abnormal sound detection results of idler %

方法	精确率	召回率	F_1 分数
CAE	92.55	92.33	92.32
SVDD	83.12	81.28	82.19
DGMM	89.12	85.96	87.51

表 3 减速机异常声音检测结果

Table 3 Abnormal sound detection results of reducer %

方法	精确率	召回率	F_1 分数
CAE	94.98	94.61	94.63
SVDD	85.32	83.18	84.23
DGMM	90.87	88.15	89.48

表 4 电动机异常声音检测结果

Table 4 Abnormal sound detection results of motor %

方法	精确率	召回率	F_1 分数
CAE	93.60	93.11	93.06
SVDD	84.12	81.76	82.92
DGMM	90.07	89.22	89.64

分别基于 CAE, SVDD, DGMM 的带式输送机异常声音检测时间见表 5。可看出 CAE 耗时比 DGMM 少了 0.82 s, 略高于 SVDD, 但 CAE 在带式输送机托辊、减速机和电动机运行声音数据集上的检测精确率最高, 实现了检测精度和检测速度之间的平衡。

表 5 带式输送机异常声音检测时间

Table 5 Detection time of abnormal sound in belt conveyor s

方法	单组声音检测时间
CAE	1.230
SVDD	0.907
DGMM	2.050

3 结论

1) 提出了一种基于 CAE 的煤矿带式输送机异常声音检测方法。通过计算带式输送机正常声音的重构阈值及其训练后的 CAE 模型, 提取待检测声音的 MFCC 特征并经过 CAE 推理, 计算其重构误差, 将重构误差与正常声音的重构阈值进行比较, 若前者大于后者, 则判断带式输送机存在异常。

2) 采集某煤矿带式输送机托辊、减速机、电动机正常运行和异常声音, 开展了基于 CAE, SVDD, DGMM 的煤矿带式输送机异常声音检测实验。结果表明, 在没有异常样本参与训练的情况下, 相比于 SVDD 和 DGMM, CAE 在托辊、减速机、电动机运行声音数据集上的检测精确率最高, 分别达 92.55%, 94.98%, 93.60%, 单组声音检测时间为 1.230 s, 实现了检测精度和速度之间的平衡。

参考文献(References):

- [1] 高伟. 选煤厂带式输送机故障预测系统设计[J]. 自动化应用, 2020(5): 108-109.
GAO Wei. Design of fault prediction system for belt conveyor in coal preparation plant[J]. Automation Application, 2020(5): 108-109.
- [2] 孙斌辉, 姚海庆. 基于机器多源感知的带式输送机故障智能监测系统[J]. 港口科技, 2024(4): 5-10.
SUN Binhu, YAO Haiqing. Intelligent monitoring system for belt conveyor faults based on machine multi-source perception[J]. Port Science & Technology, 2024(4): 5-10.
- [3] 苗长云, 邵琦. 基于声音的带式输送机输送带纵向撕裂检测方法[J]. 天津工业大学学报, 2021, 40(6): 70-75, 82.
MIAO Changyun, SHAO Qi. Detection method of longitudinal tear of belt conveyor belt based on sound[J]. Journal of Tiangong University, 2021, 40(6): 70-75, 82.
- [4] 蒋文利. 基于声音识别技术的煤矿瓦斯抽采施工安全监测方法设计[J]. 电声技术, 2024, 48(11): 45-47.
JIANG Wenli. Design of safety monitoring method for coal mine gas extraction construction based on voice recognition technology[J]. Audio Engineering, 2024, 48(11): 45-47.
- [5] 徐浩, 刘岳镭. 基于深度学习的无人机声音识别算法[J]. 计算机科学, 2021, 48(7): 225-232.
XU Hao, LIU Yuelei. UAV sound recognition algorithm based on deep learning[J]. Computer Science, 2021, 48(7): 225-232.
- [6] BARCHIESI D, GIANNOULIS D, STOWELL D, et al. Acoustic scene classification: classifying environments from the sounds they produce[J]. IEEE Signal Processing Magazine, 2015, 32(3): 16-34.
- [7] 杨小彬, 周世禄, 李娜, 等. 深度学习及其在煤矿安全领域的应用[J]. 煤矿安全, 2019, 50(1): 253-256.
YANG Xiaobin, ZHOU Shilu, LI Na, et al. Deep learning and its application in coal mine safety[J]. Safety in Coal Mines, 2019, 50(1): 253-256.
- [8] 杨磊, 赵红东. 基于轻量级深度神经网络的环境声音识别[J]. 计算机应用, 2020, 40(11): 3172-3177.
YANG Lei, ZHAO Hongdong. Environment sound recognition based on lightweight deep neural network[J]. Journal of Computer Applications, 2020,

- 40(11):3172-3177.
- [9] 卢万杰,付华,赵洪瑞.基于深度学习算法的矿用巡检机器人设备识别[J].工程设计学报,2019,26(5):527-533.
LU Wanjie, FU Hua, ZHAO Hongrui. Equipment recognition of mining patrol robot based on deep learning algorithm[J]. Chinese Journal of Engineering Design, 2019, 26(5): 527-533.
- [10] 倪旺旺.基于音频的矿井提升机异常检测方法研究及应用[D].淮南:安徽理工大学,2023.
NI Wangwang. Research and application of anomaly detection method for mine hoists based on audio [D]. Huainan: Anhui University of Science and Technology, 2023.
- [11] 曾锃,张震,缪巍巍,等.基于卷积神经网络的放电声音故障检测[J].电子器件,2024,47(1):176-181.
ZENG Zeng, ZHANG Zhen, MIAO Weiwei, et al. Fault detection of discharge sound based on convolutional neural network[J]. Chinese Journal of Electron Devices, 2024, 47(1): 176-181.
- [12] 卢安琪.基于集成学习与注意力机制的泵机设备异常声音检测方法研究[D].合肥:合肥学院,2023.
LU Anqi. Research on abnormal sound detection method for pump equipment based on ensemble learning and attention mechanism[D]. Hefei: Hefei University, 2023.
- [13] 翟洪婷,张庆锐,卞若晨,等.基于图聚类的电力设备异常声音检测方法[J].南京理工大学学报,2022,46(3):270-276.
Zhai Hongting, Zhang Qingrui, Bian Ruochen, et al. Abnormal sound detection method of power equipment based on graph clustering[J]. Journal of Nanjing University of Science and Technology, 2022, 46(3):270-276.
- [14] 宁永安.堆栈自编码器下机电故障信号多尺度滤波方法研究[J].自动化仪表,2024,45(8):42-46,51.
NING Yong'an. Research on Multi-scale filtering method of electromechanical fault signals under stack self-encoder[J]. Process Automation Instrumentation, 2024, 45(8):42-46, 51.
- [15] 郝洪涛,倪凡凡,陈亮,等.远程带式输送机托辊故障巡检方法[J].煤矿机械,2018,39(11):133-135.
HAO Hongtao, NI Fanfan, CHEN Liang, et al. Investigation of inspection method on roller of remote belt conveyor[J]. Coal Mine Machinery, 2018, 39(11): 133-135.
- [16] 黄光球,赵梦娜,陆秋琴.融合时域卷积网络和深度自编码器的VOCs数据异常检测[J].安全与环境学报,2023,23(10):3749-3759.
HUANG Guangqiu, ZHAO Mengna, LU Qiuqin. VOCs data anomaly detection based on time-domain convolutional network and depth self-encoder[J]. Journal of Safety and Environment, 2023, 23(10) : 3749-3759.
- [17] 李斌,朱杰,马志贤.WebRTC中一种基于DNN的噪声抑制算法的研究[J].信息技术,2019,43(5):1-5.
LI Bin, ZHU Jie, MA Zhixian. Research on noise suppression algorithm based on DNN in WebRTC[J]. Information Technology, 2019, 43(5): 1-5.
- [18] 陶瀚宇,陈换过,彭程程,等.基于MFCC-IMFCC混合倒谱的托辊轴承故障诊断[J].机电工程,2024,41(7):1215-1222.
TAO Hanyu, CHEN Huanguo, PENG Chengcheng, et al. Fault diagnosis of idler bearings based on MFCC-IMFCC hybrid cepstral coefficients[J]. Journal of Mechanical & Electrical Engineering, 2024, 41(7) : 1215-1222.
- [19] 史爱武,马淑然.基于多特征融合与插值卷积自编码器的机械异常声音检测研究[J].软件导刊,2025,24(2):40-47.
SHI Aiwu, MA Shuran. Research on detection of mechanical abnormal sounds based on multifeature fusion and interpolation convolutional neural auto-encoder[J]. Software Guide, 2025, 24(2): 40-47.
- [20] TAX D M J, DUIN R P W. Support vector data description[J]. Machine Learning, 2004, 54: 45-66.
- [21] VIROLI C, MCLACHLAN G J. Deep Gaussian mixture models[J]. Statistics and Computing, 2019, 29(1) : 43-51.

(上接第 83 页)

- [16] WANG Jiaqi, SHI Enze, YU Sigang, et al. Prompt engineering for healthcare: methodologies and applications [EB/OL]. [2024-07-25]. <https://arxiv.org/abs/2304.14670?context=cs>.
- [17] TONEVA M, SORDONI A, DES COMBES R T, et al. An empirical study of example forgetting during deep neural network learning [EB/OL]. [2024-07-25]. <https://arxiv.org/abs/1812.05159>.
- [18] LI Lei, JIN Li, ZHANG Zequn, et al. Graph convolution over multiple latent context-aware graph structures for event detection[J]. IEEE Access, 2020, 8:171435-171446.
- [19] ZHANG Qianjin, WANG Ronggui, YANG Juan, et al. Structural context-based knowledge graph embedding for link prediction[J]. Neurocomputing, 2022, 470: 109-120.
- [20] 张吉祥,张祥森,武长旭,等.知识图谱构建技术综述[J].计算机工程,2022,48(3):23-37.
ZHANG Jixiang, ZHANG Xiangsen, WU Changxu, et al. Survey of knowledge graph construction techniques[J]. Computer Engineering, 2022, 48(3):23-37.
- [21] LU Yaojie, LIU Qing, DAI Dai, et al. Unified structure generation for universal information extraction[C]. The 60th Annual Meeting of the Association for Computational Linguistics, Dublin, 2022: 5755-5772.