

DOI: 10.13606/j.cnki.37-1205/td.2025.01.008.

基于 SCI-XDNet-CFF 轻量化网络的井下运煤皮带异物识别

孙亚琳¹, 孙鹏翔¹, 薛 晔¹, 刘泽宇², 孙贵有²

(1. 太原理工大学 经济管理学院, 山西 太原 030000; 2. 山西汾西矿业集团正新煤焦有限责任公司, 山西 长治 046512)

摘 要: 矿井煤炭开采面与地面距离较长, 需要通过运煤皮带进行长距离运输, 在运输过程中, 存在大块矸石、锚杆等异物损坏皮带、堵塞落煤口的问题, 易引发安全问题, 因此, 运煤皮带运输异物分类具有重要意义。为克服井下环境光照强度弱、识别精度低、模型参数量大的问题, 提出一种结合低光照图像增强的 XDNet-CFF 轻量化网络。首先, 采用预训练的自校准光照图像增强模型对井下运煤皮带图像进行低光照图像增强, 有效提高图像质量; 其次, 设计一种基于 Xception-DenseNet121 和跨层特征融合的深度网络, 在提高特征提取能力的同时, 将底层细节特征与上层语义特征相结合, 减少信息丢失, 丰富特征表示; 然后, 通过全连接层和 softmax 完成运煤皮带异物识别; 最后, 为实现移动端部署和识别预警, 应用剪枝方法对模型进行压缩, 大幅减少模型参数量, 降低开销。结果表明, 所提模型在运煤皮带异物数据集上准确率、精度、召回率、F1 分数分别达到 0.9467、0.9512、0.9416、0.9464, 均优于主流模型, 同时, 参数量仅 8.98 M, 满足实际生产部署需求。

关键词: 低光照图像增强; XDNet-CFF; 跨层特征融合; 运煤皮带; 异物识别

中图分类号: TP391.41; TD679 **文献标志码:** A **文章编号:** 1009-0797(2025)01-0040-08

Identification of Foreign Objects in Underground Coal Transportation Belt Based on SCI-XDNet-CFF Lightweight Networks

SUN Yalin¹, SUN Pengxiang¹, XUE Ye¹, LIU Zeyu², SUN Guiyou²

(1. College of Economics and Management, Taiyuan University of Technology, Taiyuan 030000, China;

2. Shanxi Fenxi Mining Group ZhengXin Co., Ltd., Changzhi 046512, China)

Abstract: The coal mining face of the mine has a long distance from the ground, and needs to be transported over long distances by coal transport belts, and in the process of transport, there are problems such as large gangue, anchors and other foreign objects damaging the belts and blocking the coal drop openings, which are prone to cause safety problems, so the classification of foreign objects in the transport of coal transport belts is of great significance. In order to overcome the problems of weak light intensity, low recognition accuracy and large number of model parameters in the underground environment, an XDNet-CFF lightweight network combined with low-light image enhancement is proposed. Firstly, a pre-trained self-calibrated light image enhancement model is used to perform low-light image enhancement on underground coal transport belt images to effectively improve the image quality; secondly, a deep network based on Xception-DenseNet121 and cross-layer feature fusion is designed to improve the feature extraction capability while combining the underlying detail features with the upper layer semantic features to reduce the loss of information and enrich the feature representation; then, the coal belt foreign object recognition is completed by fully connected layer and softmax; finally, in order to achieve mobile deployment and recognition warning, the model is compressed by applying pruning method, which significantly reduces the number of model parameters and overheads. The results show that the proposed model achieves accuracy, precision, recall and F1 score of 0.9467, 0.9512, 0.9416, 0.9464 on the coal belt foreign object dataset, which are better than the mainstream model, and at the same time, the number of references is only 8.98 M, which meets the demand of actual production deployment.

Key words: Low-light image enhancement; XDNet-CFF; cross-layer feature fusion; coal transport belt; foreign object recognition

0 引 言

煤矿智能化是我国煤炭行业发展的必经之路, 是未来煤炭行业生产转型的核心支撑^[1]。《煤矿智能化建设指南 2021 版》提出科学规范有序开展煤矿

智能化建设, 加快建成一批多种类型、不同模式的智能化煤矿^[2]。在煤矿生产中, 运煤皮带是煤炭开采的“大动脉”, 直接影响生产效率, 因此, 运煤皮带的智能化风险预警研究具有重要意义。在实际生产中, 皮带异物主要为大块矸石和锚杆, 这些异物

基金项目: 教育部人文社会科学研究规划基金项目 (20YJAZH116); 国家自然科学基金青年科学基金项目 (41101507)。

可引起皮带撕裂和运煤口堵塞等问题。同时,近年来基于深度学习的图像识别方法因其出色表现而广泛应用于各个领域^[3-6],通过深度学习方法可完成自动化的运煤皮带异物识别,进而实现风险预警,有效避免因皮带异物造成的安全生产问题。

针对运煤皮带异物识别问题,程德强等^[7]构建了一种融合残差信息的轻量级模型实现运煤皮带异物分类,该模型虽参数量较小,但准确率为 85.1%,在精度方面无法满足实际生产的要求;贾尚锋等^[8]提出一种基于小样本的传送带异物检测算法,该方法的精度显著提升,但仅能识别一类异物且测试集数量有限,存在一定的局限性;卢学明等^[9]利用变分自编码器和对抗生成网络提出一种基于深度生成模型的运煤皮带异物检测方法,该方法通过重构误差检测异物,具有较高的精度和泛化性,但模型开销较大,难以在实际生产中部署。因此,现阶段运煤皮带异物识别研究存在一定不足,未兼顾精度和模型开销。

本文结合低光照图像增强方法,提出一种基于 SCI-XDNet-CFF 轻量化网络的井下运煤皮带异物识别模型。主要工作如下:

1) 针对井下环境昏暗,采集图像亮度较低的问题,采用低光照图像增强方法提升图像质量,有效提高模型的泛化性。

2) 为提高模型精度,设计 Xception 和 Densnet121 的融合网络,同时引入跨层特征融合 (Cross-layer Feature Fusion, CFF),有效增强模型特征提取能力。

3) 引入剪枝方法对模型进行压缩,保持模型精度的同时减少参数量。

1 井下运煤皮带异物识别模型

1.1 SCI 低光照图像增强

低光照图像增强旨在提高黑暗环境下的图像质量,传统低光照图像增强算法为基于模型优化的方法,设计先验正则项是基于模型优化方法的核心,但是其设计过程依赖于现实环境的假设条件,需要手动调整大量参数,导致先验表征能力有限,局限性较大^[10]。

随着深度学习在计算机视觉任务中的优势被广泛验证^[11],基于深度学习的方法成为低光照图像增强的主流,与传统方法相比,基于深度学习的方法

无需手动调整大量参数,且推理速度较快,具有一定的优势,但是泛化性较弱,在未知的现实场景中效果欠佳;针对该问题,Long Ma 等^[12]提出了自校准照明 (Self-Calibrated Illumination, SCI) 框架,用于快速、灵活和鲁棒的低光照图像增强,该方法基于自校准光照学习模块,其表达式为:

$$g(x^t): \begin{cases} z^t = y \oslash x^t \\ s^t = \kappa_\theta(z^t) \\ v^t = y + s^t \end{cases} \quad (1)$$

式中: y 为弱光观测, t 表示阶段, x^t 为第 t 阶段的光照, κ_θ 为可学习参数, v_t 为每个阶段转换后的输入。

由于现有成对数据的不准确性,采用无监督学习提升网络性能,无监督损失函数为:

$$\mathcal{L}_{\text{total}} = \alpha \mathcal{L}_f + \beta \mathcal{L}_s \quad (2)$$

$$\mathcal{L}_f = \sum_{t=1}^T \left\| x^t - (y + s^{t-1}) \right\|^2 \quad (3)$$

$$\mathcal{L}_s = \sum_{i=1}^N \sum_{j \in \mathcal{N}(i)} w_{i,j} |x_i^t - x_j^t| \quad (4)$$

式中: $\mathcal{L}_f$ 和 $\mathcal{L}_s$ 分别表示数据保真项和平滑正则项, α 和 β 为正平衡参数; T 为总阶段数, N 为像素总数, $\mathcal{N}(i)$ 表示 i 在 5×5 窗口中的相邻像素, $w_{i,j}$ 为权重,其计算公式为:

$$w_{i,j} = \exp \left(- \frac{\sum_c \left((y_{i,c} + s_{i,c}^{t-1}) - (y_{j,c} + s_{j,c}^{t-1}) \right)^2}{2\sigma^2} \right) \quad (5)$$

式中: c 为 YUV 颜色空间中的图像通道, $\sigma = 0.1$, 为高斯核的标准差。SCI 低光照图像增强方法采用无监督训练损失,在自校准模块的作用下约束各阶段的输出,赋予其不同场景的适应能力,使得 SCI 具有较强的泛化性,可在未知场景中保持其优越的性能。

1.2 Xception 网络

Xception 是由 Google 提出的对 InceptionV3 改进的模型^[13],它使用深度可分离卷积 (depthwise separable convolution) 替代 InceptionV3 中的多尺寸卷积核,大幅度减少模型参数量, Xception 整体结构如图 1 所示。Xception 包括 Entry flow、Middle flow、Exit flow 三部分,共 14 个 block。




图 1 Xception 网络结构

1.3 Densenet 网络

ResNet 是 CNN 的里程碑式的跨越,其核心为“跳跃连接”(skip connection),与 ResNet 相比,




图 2 Densenet 稠密连接机制

DenseNet 提出一种更为稠密的连接机制^[14],如图 2 所示。同时实现特征重用 (feature reuse),在保持计算成本较小的情况下实现了比 ResNet 更优的性能。

1.4 SCI-XDNet-CFF 运煤皮带异物识别模型

基于 SCI-XDNet-CFF 的井下运煤皮带异物识别模型如图 3 所示。共包括 4 个模块,分别为井下低光照图像增强模块、特征提取模块、特征融合模块以及运煤皮带异物分类模块。首先,采用低光照图像增强方法 SCI 实现运煤皮带图像增强,缓解低光照对模型的影响;其次,将增强后的图像大小处理为 224×224 并进行归一化,之后输入特征提取模块,该模块由 2 个并行的网络构成,分别为 Densenet121 和 Xception;然后,为提高表征能力,在特征融合模块,分别将 Densenet121 中 dense block2、dense block3、dense block4 的输出与 Xception 中 block2、block4、block14 的输出经过全局平均池化后再拼接,实现跨层特征融合;最后,将融合后的特征向量输入运煤皮带异物分类模块,该模块由全连接层、批标准化 (batch normalization, bn) 和 softmax 激活函数组成,其中,全连接层神经元个数依次为 512 和 128,引入批标准化的作用为避免梯度消失问题,softmax 激活函数将特征向量映射为多分类概率向量,实现运煤皮带异物分类。

1.5 模型剪枝

在实际井下生产中,运煤皮带异物识别模型应部署在摄像头等移动设备中,由于移动端计算资源有限,应尽可能减小模型所占资源,降低开销。同时,在深度网络模型中,卷积层和全连接层存在冗余参数,部分神经元激活值接近于 0,将这部分神经元摘除后,模型仍可保持相同或近似性能。因此,为满足实际生产的需求,使用剪枝方法对 SCI-XDNet-CFF 模型进一步压缩,模型剪枝的伪代码如算法 1 所示。

算法1 SCI-XDNet-CFF模型迭代剪枝算法

输入：初始稀疏度 $sparsity_{init}$ ；结束稀疏度 $sparsity_{final}$ ；剪枝开始步骤 $step_{begin}$ ；批次大小 $batch_size$ ；稀疏指数 ρ ；频率 $frequency$ ；训练集数量 num_{train} ；已训练的网络模型 m ；迭代次数 $epochs$ ；

输出：剪枝后的模型 m

$$end_step \leftarrow \text{ceil}\left(\frac{num_{train}}{batch_size}\right) \times epochs$$

$$step_{current} \leftarrow 0$$

$$step_{epoch} = \text{ceil}\left(\frac{num_{train}}{batch_size}\right)$$

for $epoch=1$ to $epochs$:

for $s=1$ to $step_{epoch}$:

if $step_{current} < step_{begin}$:

$m \leftarrow$ 更新模型

else:

if $\text{mod}((step_{current} - step_{begin}), frequency) == 0$:

$$sparsity_{current} \leftarrow sparsity_{final} + (sparsity_{init} - sparsity_{final}) \times \left(\frac{1 - (step_{current} - step_{begin})}{step_{end} - step_{begin}}\right)^{\rho}$$

$m \leftarrow$ 模型剪枝 $sparsity_{current}$ 并更新模型

else:

$m \leftarrow$ 更新模型

$$step_{current} \leftarrow step_{current} + 1$$

end for

end for




图3 基于 SCI-XDNet-CFF 的运煤皮带异物识别网络

算法 1 中, $\text{ceil}(\cdot)$ 表示向上取整, $\text{mod}(\cdot)$ 表示取余数, $\rho = 3$, $\text{sparsity}_{\text{init}} = 0.3$, $\text{sparsity}_{\text{final}} = 0.7$, $\text{epochs} = 100$, $\text{step}_{\text{begin}} = 30$, $\text{batch_size} = 16$, $\text{frequency} = 100$ 。

2 实验过程

2.1 数据集说明

CUMT-BelT 数据集为中国矿业大学开源的煤矿井下运煤皮带异物数据集, 图片像素均为 416×416 , 如图 4 所示。共包括 3 类, 分别为正常煤流、锚杆以及大块, 各个类别在训练集、验证集、测试集的分布情况见表 1。




图 4 CUMT-BelT 数据集

表 1 数据集划分

类别	训练集	验证集	测试集
正常煤流	1 040	262	300
锚杆	1 040	262	300
大块	1 040	262	300

2.2 迁移学习

为提升模型训练时的稳定性, 同时使其收敛更快, 引入迁移学习 (Transfer learning), 该方式将模型在源领域和源任务上学习到的知识迁移到目标领域和目标任务, 进而提升目标任务的学习收敛速度, SCI-XDNet-CFF 迁移学习的实现方式如图 5 所示。将 Densenet121 和 Xception 在 ImageNet 数据集上预训练的权重迁移到 SCI-XDNet-CFF 网络中, 固定该部分的权重, 仅训练运煤皮带异物模块的权重, 可有效减少训练时的内存占用。

2.3 训练参数设置

实验采用 Ubuntu 操作系统, Intel i9-6600 处理器, 内存 16 GB, GPU 为 Nvidia RTX3060, 代码




图 5 迁移学习

由 Python 语言编写。优化器采用 Nadam, 实验中 batch size 设置为 16; 学习率初始化为 0.01, 最小学习率为 0.0001, 最大迭代次数为 300, 热身迭代次数为 50, 学习率更新策略为预热阶段 (warm-up) 采用一维线性插值法, 预热阶段后采用余弦退火算法^[15], 学习率更新的伪代码如算法 2 所示。

算法2 学习率更新算法

输入: 学习率 lr ; 最小学习率 mlr ; 初始学习率 $initlr$; 最大迭代次数 m_iter ; 热身迭代次数 τ

输出: 更新学习率 lr

for $t=1$ to m_iter do:

if $t < \tau$

$$\text{更新 } lr \leftarrow \frac{lr \times m_iter}{initlr \times \tau}$$

else

$$\text{更新 } lr \leftarrow mlr + (initlr - mlr) * \left(\frac{1 + \cos\left(\pi \frac{t}{\tau}\right)}{2} \right)$$

end if

end for

算法 1 中, $t < \tau$ 时为预热阶段, 使用线性递增的学习率, 预热阶段过后, 采用余弦退火算法更新学习率。

3 实验结果及分析

3.1 模型评价指标

采用图像分类任务常用评价指标准确率 (Accuracy)、精度 (Precision)、召回率

(Recall)、F1 分数 (F1-Score) 评估井下运煤皮带异物识别模型的性能, 如公式 (6)、(7)、(8)、(9) 所示。

$$Accuracy = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (6)$$

$$Recall = \frac{T_P}{T_P + F_N} \quad (7)$$

$$Precision = \frac{T_P}{T_P + F_P} \quad (8)$$

$$F1\ score = \frac{2 \times precision \times Recall}{precision + Recall} \quad (9)$$

式中: T_P 为真阳性的数量, F_P 为假阳性的数量, T_N 为真阴性的数量, F_N 为假阴性的数量。

3.2 不同模型对比

为验证 SCI-XDNet-CFF 井下运煤皮带异物识别模型的有效性, 与 SwinTransformer^[16]、Vision-Transformer^[17]、ResNet152V2、Xception、ResNet50-V2、ConvNext^[18]、DenseNet121、NASNetLarge、InceptionV3、InceptionResNetV2、MobileNetV3-Large 对比。其中, SwinTransformer 和 Vision-Transformer 为 Transformer 在图像领域先进的网络模型, ConvNext 对标 SwinTransformer, 是 CNN 新兴的代表网络, 对比实验结果见表 2。可知, 所提 SCI-XDNet-CFF 网络优于主流模型, 与 SwinTransformer 相比, 准确率、精度、召回率、F1 分数分别提高 3.397%、3.301%、2.761%、3.127%。

表 2 不同模型对比

模型	准确率	精度	召回率	F1 分数
SCI-XDNet-CFF	0.9467	0.9512	0.9416	0.9464
SwinTransformer	0.9156	0.9198	0.9156	0.9177
VisionTransformer	0.9133	0.9179	0.9187	0.9183
ResNet152V2	0.8944	0.9070	0.8806	0.8936
Xception	0.8744	0.8913	0.8556	0.8731
ResNet50V2	0.8733	0.8901	0.8931	0.8916
ConvNext	0.8733	0.8904	0.8567	0.8731
DenseNet121	0.8711	0.8878	0.8541	0.8706
NASNetLarge	0.8711	0.8887	0.8513	0.8696
InceptionV3	0.8633	0.8802	0.8445	0.8620
InceptionResNetV2	0.8556	0.8764	0.8319	0.8536
MobileNetV3Large	0.7833	0.8446	0.7207	0.7778

3.3 消融实验

为进一步探究所提模型中各个模块对运煤皮带异物识别性能的影响, 由原始 Xception 网络依次增

加模块, 实验结果见表 3。首先, 将单模型 Xception 和 Densenet121 融合, 具体实现方式为分别将 2 个模型输出的特征向量全局平均池化, 然后将池化后的向量拼接, 实现特征融合, 可知, 融合后的模型性能大幅提升, 与 Xception 网络相比, 准确率、精度、召回率、F1 分数分别提高 4.963%、3.736%、6.463%、5.108%; 然后, 增加跨层特征融合, 与 XDNet 相比, 准确率、精度、召回率、F1 分数分别提高 1.329%、0.789%、1.888%、1.34%; 最后, 引入 SCI 图像增强方法, 与 XDNet-CFF 相比, 准确率、精度、召回率、F1 分数分别提高 1.80%、2.07%、1.43%、1.76%

表 3 消融实验

模型	准确率	精度	召回率	F1 分数
Xception	0.8744	0.8913	0.8556	0.8731
XDNet	0.9178	0.9246	0.9109	0.9177
XDNet-CFF	0.9300	0.9319	0.9281	0.9300
SCI-XDNet-CFF	0.9467	0.9512	0.9416	0.9464

3.4 模型参数量对比

模型参数量直接影响运煤皮带异物识别模型的资源开销, 表 4 为不同模型参数量的对比。其中, SwinTransformer 和 VisionTransformer 采用的版本分别为 swin_b 和 vit_b_16。可知, 所提模型参数量仅为 SwinTransformer 的 10.5%, 在保持较高精度的同时兼顾较小的开销。

表 4 模型参数量对比

实现框架	模型	参数量
torch2.0.1	SwinTransformer	86.75M
	VisionTransformer	85.80M
	ConvNext	87.57M
	SCI-XDNet-CFF	8.98M
tensorflow2.6.0	ResNet152V2	58.34M
	Xception	20.87M
	ResNet50V2	23.57M
	DenseNet121	7.04M
	NASNetLarge	23.57M
	InceptionV3	21.81M

3.5 模型可解释分析

为进一步解释 SCI-XDNet-CFF 模型的有效性, 将所提模型与 Xcption 和 DensNet121 进行定性分

析,首先,分别使用训练后的模型在测试集进行推理;然后,因最后一个全连接层通过 softmax 激活函数将特征向量映射为分类概率向量,故提取倒数第二个全连接层输出的特征向量作为模型最终的特征向量;最后,基于 t 分布随机邻近嵌入 (T-distributed Stochastic Neighbor Embedding, T-SNE)

计算边界点之间的接近程度,实现特征向量降维,如图 6 所示。图中 (a)、(b)、(c) 依次为 Densenet121、Xception、SCI-XDNet-CFF,结果表明,SCI-XDNet-CFF 模型所提取的全连接层特征分布协方差差异减少,可分离性显著提高,表示模型特征提取能力更强,验证了所提模型的有效性。




图 6 全连接层特征 T-SNE 降维可视化

4 结 论

提出一种基于 SCI-XDNet-CFF 轻量化网络的运煤皮带异物识别模型。针对井下环境昏暗,采集图像亮度较低的问题,结合低光照图像增强方法有效增强图像质量;利用跨层特征融合实现 Xception 网络和 Densenet121 网络融合,提升模型特征提取能力;同时应用剪枝方法压缩模型,有效减少模型参数量。经 CUMT-BELT 井下运煤皮带数据集验证,所提轻量化模型优于主流方法。

参考文献:

- [1] 李爽,薛广哲,方新秋,等.煤矿智能化安全保障体系及关键技术[J].煤炭学报,2020,45(6): 2320-2330.
- [2] 鲍久圣,章全利,葛世荣,等.煤矿井下无人化辅助运输系统关键基础研究及应用实践[J].煤炭学报,2023,48(2): 1085-1098.
- [3] 范冰倩,董秉聿,王彪,等.基于深度学习的地铁施工作业人员不安全行为识别与应用[J].中国安全科学学报,2023,33(1): 41-47.
- [4] 王金江,关鹏婷,陈卓,等.基于深度学习的检修作业过程风险智能预警[J].中国安全科学学报,2023,33(10): 16-22.
- [5] 孙鹏翔,毕利,王俊杰.基于改进深度残差网络的光伏板积

灰程度识别[J].计算机应用,2022,42(12): 3733-3739.

- [6] 林青,姚俊名,梁伟,等.基于深度学习的燃气发电机组剩余寿命预测[J].中国安全科学学报,2023,33(9): 113-121.
- [7] 程德强,徐进洋,寇旗旗,等.融合残差信息轻量级网络的运煤皮带异物分类[J].煤炭学报,2022,47(3): 1361-1369.
- [8] 贾尚锋,王志强,郝鑫宇.基于小样本的传送带异物视频检测算法[J].中国安全科学学报,2023,33(S1): 134-137.
- [9] 卢学明,于在川,许升起.基于深度生成模型的煤矿运输皮带异物检测[J].计算机系统应用,2022,31(5): 358-363.
- [10] 马龙,马腾宇,刘日升.低光照图像增强算法综述[J].中国图象图形学报,2022,27(5): 1392-1409.
- [11] Yasarla R, Sindagi V A, Patel V M. Semi-supervised image deraining using gaussian processes[J]. IEEE Transactions on Image Processing, 2021, 30: 6570-6582.
- [12] Ma L, Ma T, Liu R, et al. Toward fast, flexible, and robust low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 5637-5646.
- [13] Chollet F. Xception: Deep learning with depthwise separable convolutions[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 1251-1258.

(下转第 51 页)

确识别,对于常见的轴承振动异常,分水平振动和垂直振动,2种振动状态都可在上位机中显示出来,振动值的大小精确到 0.01 mm/s,现场振动发生后在上位机监控到振动,整个过程的故障响应时间仅为 1.28 s。通过系统运行 6 个月后统计实际异常数与上位机监控到的异常数,可以得出设备的故障发现率为 97.8%,能对潜在故障准确识别和判断,故障排除时间降低为 97.3%,降低了工人劳动强度。

5 结 论

针对掘进机电设备传统故障监测和诊断技术存在效率较低、监测结果不准确等问题,对故障智能诊断方法进行研究,提出了一种掘进机故障监测与智能诊断系统,完成了硬件系统选型和软件控制系统设计,实现了特征监测与故障诊断的归一化和集成化,由传感器实时采集设备的运行参数和状态信息,由数据发送模块将现场采集到的数据发送到上位机监控系统。通过在 EBZ200 悬臂式掘进机上进行现场布置传感器,现场应用结果表明:当掘进机关键部位出现异常趋势时可准确识别,利用该智能诊断技术可以改善传统设备日常巡检作业环境,保证设备的稳定运行,提高了设备故障诊断效率,降低故障排除时间,对提高煤矿产量和经济效益具有重要的参考价值,研究结论可以为后期开展智能化掘进机研究、智慧矿山建设提供参考依据。

参考文献:

[1] 侯磊.煤矿悬臂式掘进机智能监测系统设计与应用[J].江

西煤炭科技,2024(1): 181-183.

[2] 续江.矿用全断面掘进机监控系统设计与实现[J].江西煤炭科技,2024(1): 184-186,189.

[3] 王杰.煤矿掘进机电设备故障监测与方法研究[J].自动化应用,2023,64(15): 77-79.

[4] 齐振磊.智能控制技术在煤矿机电设备中的应用分析[J].中国高科技,2023(21): 62-64.

[5] 刘新文.煤矿掘进机常见故障分析及处理探讨[J].内蒙古煤炭经济,2023(12): 31-33.

[6] 李超同.煤矿井下掘进机电设备故障诊断及维护[J].能源与节能,2023(1): 191-193.

[7] 马忠强,李红勇,张俊峰.煤矿掘进机电设备的自动化集中控制技术[J].自动化应用,2023,64(12): 41-43.

[8] 凌家杭,陈先中.AM-50 型掘进机液压系统故障诊断专家系统原型的开发[J].淮南矿业学院学报,1994(3): 65-71.

[9] 卜宪伟.煤矿井下掘进机电设备故障诊断及维护研究[J].清洗世界,2023,39(12): 178-180.

[10] 弓武.煤矿掘进机电设备故障诊断与质量维护[J].中国石油和化工标准与质量,2019,39(16): 47-48.

[11] 杨晋平.煤矿井下掘进机电设备故障诊断及维护分析[J].矿业装备,2021(6): 256-257.

[12] 王凯.煤矿掘进机电设备故障诊断与质量维护分析[J].中国石油和化工标准与质量,2020,40(1): 22-23.

作者简介:

刘晓峰(1989-),男,山西高平人,2016年毕业于东北大学采矿工程专业,本科,采矿工程师,主要从事煤矿机电工作。

(收稿日期:2024-3-15)

(上接第 46 页)

[14] Qureshi A S, Khan A, Zameer A, et al. Wind power prediction using deep neural network based meta regression and transfer learning[J]. Applied Soft Computing, 2017(58): 742-755.

[15] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 4700-4708.

[16] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF international conference on computer vision. 2021: 10012-10022.

[17] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[J]. arxiv preprint arxiv: 2010.11929: 2020.

[18] Liu Z, Mao H, Wu C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2022: 11976-11986.

作者简介:

孙亚琳(1997-),男,河北邯郸人,硕士研究生,主要从事数据挖掘、灾害风险管理方面的研究。E-mail: sunpx88@163.com

(收稿日期:2024-3-18)