融合先验特征与多核残差注意力网络的矿尘浓度图像识别模型

徐剑坤[1],苏　毅[2],王和堂[1,3],王恩元[1],李　阳[1],王　珂[2],徐玉姣[1]
(1. 中国矿业大学 安全工程学院,江苏 徐州　221116;2. 中国矿业大学 计算机科学与技术学院,江苏 徐州　221116;
3. 中国矿业大学 煤矿灾害防控全国重点实验室,江苏 徐州　221116)

摘要: 矿尘浓度实时可靠检测是保障煤矿安全生产的关键问题. 针对现有基于图像的矿尘浓度检测方法存在可解释性差、准确性不高等问题,本文提出一种融合先验特征与可解释多核残差注意力网络的矿尘浓度图像识别模型. 首先,构建涵盖颜色、纹理、几何等多维特征的图像特征库,结合皮尔逊相关系数与互信息系数,筛选出与矿尘浓度显著相关的线性和非线性可解释特征子集;进而,设计多核学习框架,采用径向基核函数分别映射线性与非线性特征,通过加权融合策略兼顾特征表达能力与可解释性;引入残差连接促进梯度传播,结合通道注意力机制实现关键图像特征的动态强化,提升模型对复杂井下环境的适应性. 结果表明:模型在数据集上性能表现优异,均方误差(E_{MSE})、平均绝对误差(E_{MAE})和平均相对误差(E_{MRE})分别达到 0.90 mg^2/m^6,0.74 mg/m^3和 1.76%,拟合优度R^2为 0.916 0,显著优于支持向量机回归、随机森林等对比模型. 消融试验验证了多核融合、残差结构与注意力机制对模型性能的提升贡献. 本研究实现了模型可解释性与识别准确性的统一,为矿井粉尘浓度的智能检测提供了一种可靠、透明的高精度解决方案,对提升煤矿安全监测水平具有重要意义.

关键词: 矿尘浓度;图像识别;先验特征;深度学习;多核学习;注意力机制
中图分类号: TP 391.4;TD 78　**文献标志码:** A　**文章编号:** 1000-1964(2026)02-0419-16

A dust concentration image recognition model integrating prior features with a multi-kernel residual attention network

XU Jiankun[1], SU Yi[2], WANG Hetang[1,3], WANG Enyuan[1], LI Yang[1], WANG Ke[2], XU Yujiao[1]
(1. School of Safety Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China; 2. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China;
3. State Key Laboratory of Coal Mine Disaster Prevention and Control, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: Real-time and reliable detection of dust concentration is critical for ensuring safety in coal mine operations. However, existing image-based dust concentration detection methods often suffer from limited interpretability and insufficient accuracy. To address these challenges, a dust concentration image recognition model that integrates prior interpretable features with a multi-kernel re-

收稿日期: 2025-10-11　**修回日期:** 2025-12-24　**DOI:** 10.13247/j.cnki.jcumt.20250425
基金项目: 国家重点研发计划项目(2024YFC3015805);国家自然科学基金项目(52574288,52322404)
第一作者: 徐剑坤(1980—),男,江苏省徐州市人,正高级实验师,博士生导师.
通信作者: 王和堂(1985—),男,湖南省耒阳市人,教授,博士生导师. E-mail: wanghetang@cumt.edu.cn
引用格式: 徐剑坤,苏　毅,王和堂,等.融合先验特征与多核残差注意力网络的矿尘浓度图像识别模型[J].中国矿业大学学报,2026,55(2):419-434.
XU Jiankun, SU Yi, WANG Hetang, et al. A dust concentration image recognition model integrating prior features with a multi-kernel residual attention network[J]. Journal of China University of Mining & Technology, 2026, 55(2): 419-434.

sidual attention network was proposed in this study. First, an image feature library was constructed to capture multidimensional characteristics, including color, texture, and geometric features. The Pearson correlation coefficient and mutual information were then employed to select a subset of linear and nonlinear features that are highly correlated with dust concentration, thereby enhancing model interpretability. Subsequently, a multi-kernel learning framework was developed, in which radial basis function kernels were used to separately map the selected linear and nonlinear features into high-dimensional feature spaces. A weighted fusion strategy was introduced to balance representation capability and interpretability across different feature types. To further improve model performance, residual connections were incorporated to facilitate gradient propagation during training, and a channel attention mechanism was introduced to dynamically emphasize critical image features. These architectural designs enhanced the model's robustness and adaptability to complex underground mining environments. Experimental results demonstrate that the proposed model achieves superior performance on the benchmark dataset, with a mean squared error (E_{MSE}) of 0.90 mg^2/m^6, a mean absolute error (E_{MAE}) of 0.74 mg/m^3, and a mean relative error (E_{MRE}) of 1.76%. The coefficient of determination (R^2) reaches 0.916 0, significantly outperforming comparative models such as Support Vector Regression and Random Forest. Ablation experiments further confirm the effectiveness of the multi-kernel fusion strategy, residual architecture, and attention mechanism in improving prediction accuracy. Overall, this study achieves a unified framework that balances model interpretability and recognition accuracy, providing a reliable, transparent, and high-precision solution for intelligent dust concentration in coal mines. The proposed approach offers important practical value for enhancing mine safety monitoring and risk prevention.

Key words: dust concentration; image recognition; prior features; deep learning; multi-kernel learning; attention mechanism

煤炭井工开采过程中,回采、掘进、爆破、运输等环节会产生大量粉尘,严重威胁作业人员职业健康,并显著增加爆炸、火灾等安全风险.实现矿井粉尘浓度的实时监测与可靠评价,对保障煤矿安全生产具有重要意义[1].

目前,矿尘浓度检测方法主要包括离线检测与在线检测2类.离线检测方法以滤膜称重法[2]为代表,虽检测精度较高,但操作流程繁琐、检测结果滞后,难以满足井下实时监测的迫切需求.在线检测方法,如β射线法[3]、振荡天平法[4]、光散射法[5]、光透射法[6]、静电感应法[7]及超声波法[8]等,虽可实现连续监测,但普遍存在设备成本高、环境适应性差、检测范围窄等问题,在复杂多变的矿井环境中推广应用受限.

近年来,计算机视觉与图像处理技术的迅速发展为矿尘浓度检测提供了新的思路.学者们逐渐将研究重点转向基于图像的无损检测方法[9],借助计算机视觉技术实现矿尘浓度的自动化估算[10].该类方法通过采集井下矿尘图像,提取颜色[11]、纹理[12]、形态[13]等特征,实现对矿尘浓度的非接触、实时、低成本定量识别[14].早期研究多关注灰度均值等统计量与浓度的线性关系[15],后续逐渐引入更复杂的特征,如标准差、偏度与分形维数等[16].颜色特征(如众数、均匀性)用于描述色彩分布特性[12];纹理特征(如对比度、同质性、熵)用以刻画颗粒的空间分布复杂度[17];几何特征(如Hu不变矩)则用于表征颗粒形态的稳定性[10].此外,光学透射特征(如基于透射率或暗通道先验的模型)因其对粉尘衰减效应的直接反映,也展现出良好的应用潜力[18].

随着深度学习技术的广泛应用,卷积神经网络[19]、特征融合模型[20]等方法被引入,进一步提升了矿尘浓度识别的自动化水平和准确性[21].相关研究推动了该领域从单一特征分析向多维度、端到端的智能识别发展[22-25].然而,现有基于深度学习的模型多依赖"黑箱"结构,虽能自动完成特征提取与回归,却严重缺乏对识别结果与图像特征之间关联的合理解释[26],导致模型在实际工程中的可信度和可接受度较低.同时,井下环境光照变化剧烈、粉尘分布不均、背景干扰复杂,现有方法

的鲁棒性和泛化能力仍显不足，识别准确率与适应性有待进一步提高[27-29]。

针对上述问题，本文提出一种融合先验特征与可解释多核残差注意力网络的矿尘浓度图像识别模型。该模型的核心思路是：首先构建具有明确物理意义的先验特征库，并依据统计相关性筛选出关键特征子集；进而设计多核学习框架，分别处理线性和非线性特征，并通过残差连接与通道注意力机制增强模型的表达能力和训练稳定性。先验特征的引入旨在增强模型的可解释性，并降低其对大规模标注数据的依赖。本研究旨在为矿井粉尘浓度监测提供一种同时具备高精度、强鲁棒性与良好可解释性的智能视觉解决方案，对提升煤矿安全监测技术水平具有重要意义。

1　数据集的构建

1.1　现场矿尘图像数据采集

为构建真实矿井环境下的矿尘图像数据集，本文选取河南某煤业股份有限公司某矿的典型工作面进行现场数据采集。具体在31130工作面与31080工作面的回风巷处，分别布设矿用防爆高清摄像机（400万像素）与矿用粉尘浓度激光传感器（布设示意见图1），以同步获取矿尘环境的视频图像及对应的浓度数据。通过上述方法，共采集到矿尘浓度（本文中的矿尘浓度均指矿尘的质量浓度）在0～50 mg/m³范围内的有效数据1 146组。

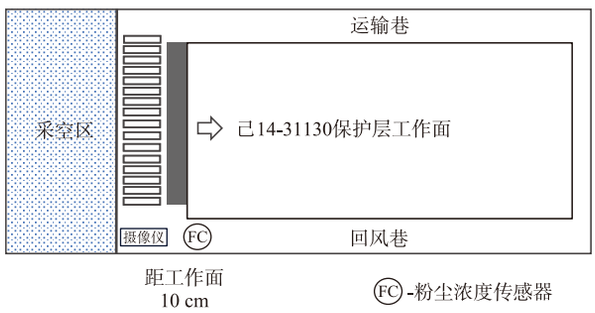


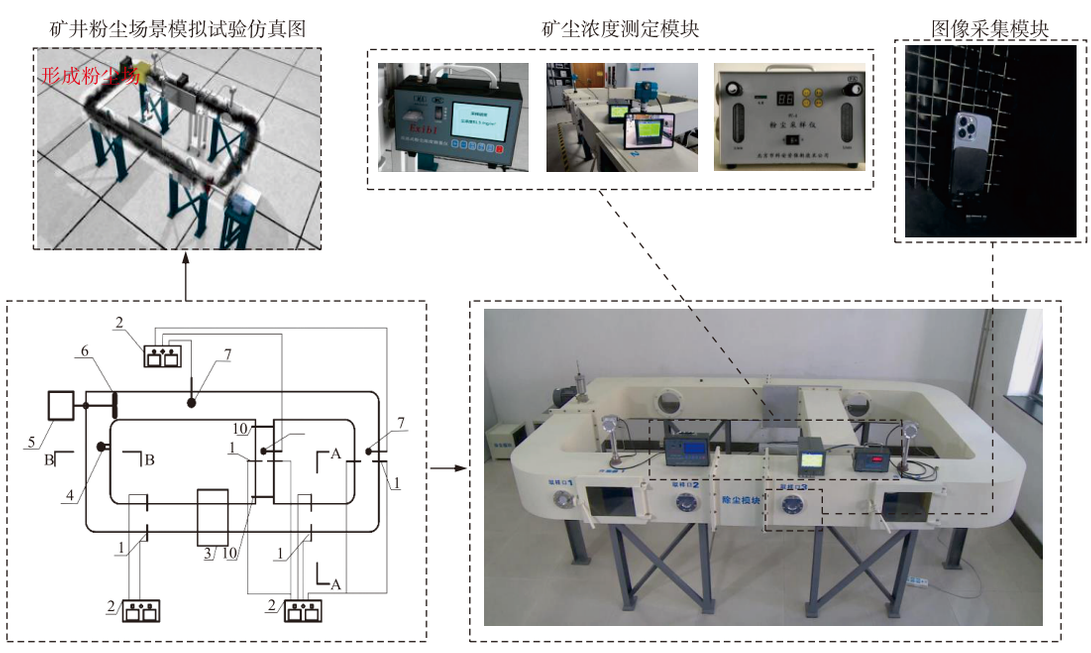
图1　31130工作面摄像机与粉尘浓度传感器布设示意

Fig. 1　Working face camera and dust sensor deployment diagram

1.2　实验室数据采集

1.2.1　矿井粉尘场景模拟试验系统

为丰富数据集场景多样性，补充样本数量，本文在中国矿业大学实验室自主搭建了矿井粉尘场景模拟试验系统。该系统旨在模拟不同浓度与光照条件下的矿尘环境，实现矿尘浓度数据与对应环境图像的同步采集，为后续特征提取与模型训练提供高可信度、多场景的数据支撑。试验系统主要由气流控制、产尘与给尘、图像采集与浓度识别等模块构成，如图2所示。



1：粉尘浓度传感器组件；2：数据采集仪；3：除尘模块；4：储尘罐；5：调速电机；6：风扇；7：风速传感器；8：调节旋钮；9：取样口；10：调节风门

图2　矿井粉尘场景模拟试验系统

Fig. 2　Diagram of mine dust scenario simulation experimental system

1.2.2 试验过程与数据采集

利用矿井粉尘场景模拟试验系统，按照产尘与给尘、气流控制、矿尘浓度与图像同步采集的步骤开展试验，具体如下：

1）产尘与给尘．选取经机械研磨的不同批次的标准煤尘，编号为样本 1～3，采用 Winner2000ZDE 型激光粒度仪测定其粒径分布，结果如图 3 所示．开展多批次试验，通过系统的储尘罐与精密阀控装置调节煤尘释放速率，以模拟井下矿尘产生过程，在试验段内形成分布均匀、浓度可调的悬浮粉尘场．

2）气流控制．利用可调速风机与变频调节模块构建封闭循环通风回路，模拟矿井巷道内典型风流条件，确保矿尘颗粒在气流作用下的扩散与运移特征接近井下实际情况．

3）矿尘浓度测定与图像采集．在气流稳定后，通过分级调节给尘阀门，使试验段内粉尘浓度从低到高（约 0～60 mg/m³）阶梯变化．采用高精度在线粉尘检测仪实时监测并记录浓度数据；同时，使用高分辨率相机（分辨率 2 160×3 840，帧率 60 fps）同步采集粉尘悬浮场图像．所有数据通过时间戳进行对齐，确保每张图像均对应一个准确的瞬时浓度值．

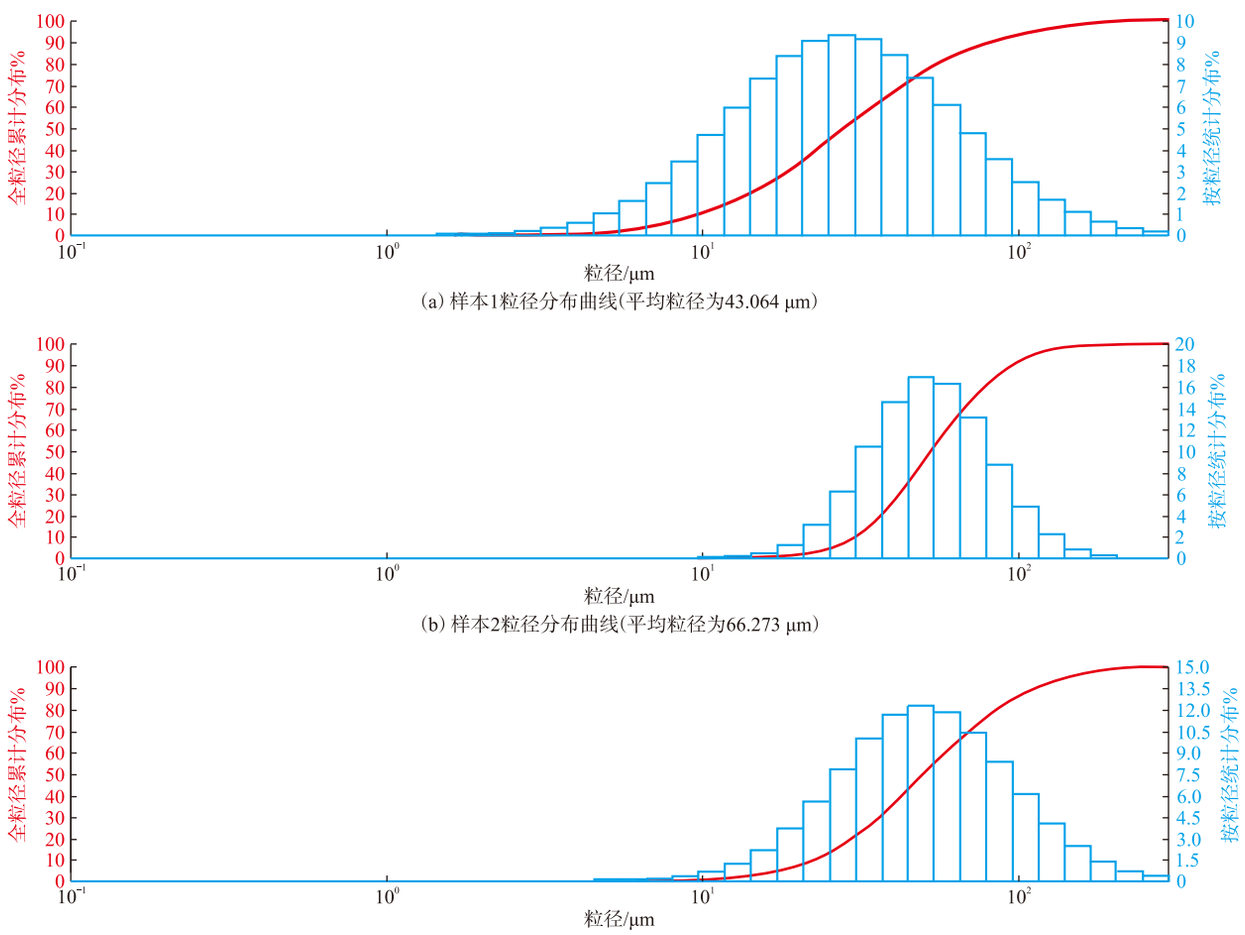


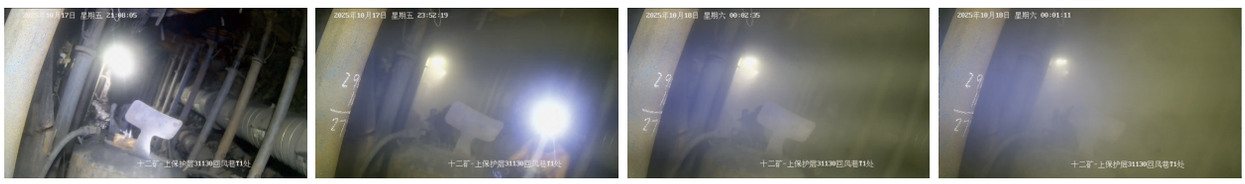
图 3 不同煤尘样本粒径分布曲线

Fig. 3 Particle size distribution curves of different coal dust samples

1.3 数据集标注与模型训练

对现场采集与实验室采集的原始矿尘图像及同步浓度数据进行整理与预处理，构建可用于模型训练与测试的数据集．

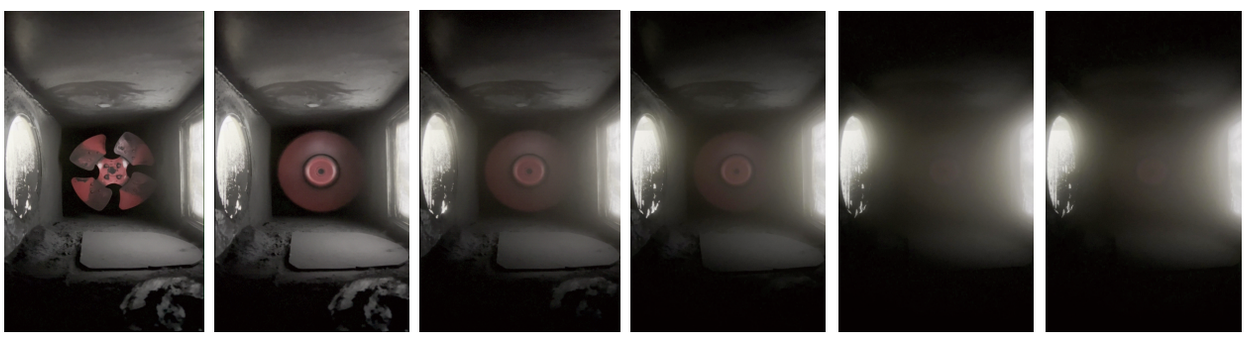
1）数据集构建．将同步采集的矿尘图像与对应的浓度监测数据进行时间对齐与精确配对，经过无效样本剔除与数据清洗后，最终构建一个包含 2 236 组样本的矿尘浓度-图像标注数据集．该数据集涵盖了从低浓度（0.01 mg/m³）到高浓度（60 mg/m³）的浓度范围，样本分布具有代表性，能够清晰呈现图像视觉特征随矿尘浓度变化的规律，示例如图 4～6 所示．



0.01 mg/m³　　22.65 mg/m³　　36.68 mg/m³　　44.15 mg/m³

图 4　现场矿尘图像

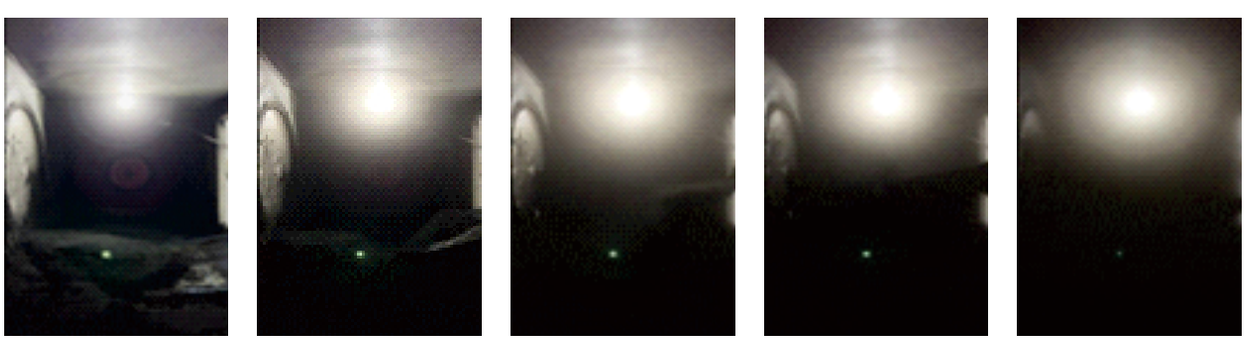
Fig. 4　In-situ mine dust images



2.81 mg/m³　　10.25 mg/m³　　26.51 mg/m³　　34.97 mg/m³　　48.77 mg/m³　　56.43 mg/m³

图 5　实验室矿尘图像

Fig. 5　Lab-acquired mine dust images



28.41 mg/m³　　34.97 mg/m³　　40.61 mg/m³　　50.17 mg/m³　　43.37 mg/m³

图 6　不同照度下的矿尘图像（外加 250 流明 LED 光源）

Fig. 6　Mine dust images captured under different illuminance conditions (supplemented by a 250-lm LED source)

2）模型训练环境．所有特征分析、模型构建与训练均在配备 Intel Core i9-13900K 处理器、NVIDIA GeForce RTX 3080 Ti 显卡的高性能工作站上完成．本文基于 Windows 11 操作系统，采用 Python 3.10 编程语言，并依托 PyTorch 深度学习框架与 CUDA 11.8 并行计算架构进行算法实现与加速计算．

2　矿尘图像先验特征

2.1　矿尘图像特征

为全面表征矿尘图像与浓度之间的复杂映射关系，本文系统梳理了现有研究成果，构建了一套多维度的图像特征库（表 1）．该特征库整合了颜色、纹理、几何、图像质量、灰度统计及透光率等 6 大类共 27 项特征指标．这些特征在物理意义上均具有明确的可解释性，能够从不同角度描述矿尘图像的视觉属性：颜色特征反映粉尘的色彩分布倾向；纹理特征刻画颗粒的空间结构与分布均匀性；几何特征描述粉尘区域的形态与矩特性；图像质量特征评估图像的清晰度与细节保留程度；灰度统计特征从像素强度分布反映整体浓度与对比度；透光率特征则直接关联粉尘对光线的衰减作用．通过构建特征集合，不仅为后续分析提供了统一基础，也确保了所提取特征具有明确的物理含义，支撑模型的可解释性．

表1 矿尘浓度图像特征库

Table 1 Image feature library for mine dust concentration

特征类别	图像特征	物理意义
颜色特征	众数[12]	图像中出现频率最高的颜色值,可反映矿尘图像中最显著的颜色倾向
	均匀度[12]	表示图像颜色分布的均衡程度,值越大说明颜色分布越集中
	偏度[12]	刻画颜色分布的对称性,反映矿尘图像亮度分布是否偏向暗部或亮部
	峰度[12]	衡量颜色分布的尖锐程度,数值越高表示像素分布越集中,矿尘图像对比度更强
	多样性[11]	描述图像颜色的丰富程度,反映矿尘场景的复杂性
纹理特征	对比度[30]	衡量相邻像素灰度差异大小,数值大说明图像纹理清晰,矿尘颗粒边界明显
	不相似度[30]	类似对比度,反映相邻像素差异性,数值高说明矿尘分布不均匀
	能量(角二阶矩)[30]	描述图像灰度分布的集中程度和规则性,能量值越大,说明图像灰度分布越集中、越均匀;能量值越小,则表明灰度分布较为分散,图像纹理更复杂
	同质性[12]	反映像素分布的局部一致性,值大时说明矿尘分布较均匀
	相关性[12]	度量灰度间的线性依赖,数值越高说明图像灰度分布规律性更强
	熵[30]	表示图像信息量和复杂度,值越大说明矿尘分布更随机,颗粒状态更复杂
几何特征	总能量矩[10]	反映图像整体灰度能量,描述矿尘分布的全局特性
	轴长度矩[10]	刻画图像中物体横向与纵向分布的差异,反映矿尘形态方向性
	角点特征矩[10]	刻画形状的不对称程度,用于反映矿尘分布的对称性特征
	第二角点特征矩[10]	衡量图像灰度的曲率变化,刻画矿尘分布的几何复杂性
	偏心性矩[10]	刻画矿尘分布的非对称性,数值大表示分布偏移明显
	紧凑度矩[10]	反映图像形态的紧凑性,值越大说明矿尘团块分布更集中
	不对称性矩[10]	用于表征图像的不对称性,反映矿尘分布形状的稳定性与差异性
图像质量	峰值信噪比[31]	衡量去噪或重建后的图像与原始图像之间的误差,值越高表示图像质量越好,矿尘细节信息保留越完整
	视觉信息保真度[32]	评价图像失真对视觉感知的影响程度,值越高表示人眼感知的图像质量越好,矿尘形态更接近真实
	调制指数[32]	反映图像中高频信息(如边缘、纹理)的强度,值越高说明矿尘颗粒的轮廓和细节越清晰
灰度统计特征	灰度均值[30]	描述图像的平均亮度水平,反映矿尘整体的浓度或厚度;值越低通常表示矿尘浓度越高,透光性越差
	灰度标准差[30]	衡量图像像素灰度值的离散程度,值越大说明图像对比度越强,矿尘分布越不均匀
	灰度偏度[30]	表征灰度分布的不对称性,正偏度表示图像偏亮(可能有高光或薄尘),负偏度表示图像偏暗(矿尘浓度高)
	灰度峰度[30]	描述灰度分布曲线与正态分布的差异,高峰度表示像素灰度集中分布在均值附近,低峰度表示分布较平缓
透光率特征[26]	透射均值[20]	表示光线透过矿尘介质后的平均强度,直接反映整体透光率,均值越低,浓度越高
	透射中位数[20]	表示透光强度分布的中间值,相比均值更能抵抗异常值(如极亮或极暗噪声点)的影响,反映典型透光情况

2.2 先验特征集构建

尽管特征库涵盖了多维度信息,但并非所有特征均对矿尘浓度具有同等表征能力.部分特征与浓度间存在较强线性或非线性关联,而另一些则相关性较弱.若将所有特征直接输入模型,不仅会增加计算复杂度与过拟合风险,也可能引入噪声,降低模型效率与可解释性.因此,需对特征进行筛选,构建信息量丰富、互补性强且物理意义明确的特征子集.

2.2.1 相关性分析

本文采用皮尔逊相关系数[33](Pearson Correlation Coefficient)与互信息系数[34](Mutual Information, MI)2种指标,分别从线性和非线性角度评价各图像特征与矿尘浓度之间的相关性.

1）皮尔逊相关系数用于度量特征与浓度之间的线性相关程度，其计算公式为

$$r_{x,y}=\frac{\sum_{i=1}^{n}(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i-\bar{x})^2}\sqrt{\sum_{i=1}^{n}(y_i-\bar{y})^2}},\quad(1)$$

式中：x为图像特征变量；y为对应的矿尘浓度变量；x_i为某一图像特征值，$\bar{x}$为其平均值；y_i为某一矿尘浓度值，$\bar{y}$为其平均值；n为样本数；$r_{x,y}$为图像特征x与粉尘浓度y的皮尔逊相关系数，用于度量二者的线性相关程度，其取值范围为[－1,1]，绝对值越接近1表明线性相关性越强，正号表示正相关，负号表示负相关.

2）互信息系数能够捕捉特征与矿尘浓度之间的非线性依赖关系或复杂分布依赖关系，其计算公式为

$$I(X;\ Y)=\sum_{x\in X}\sum_{y\in Y}p(x,y)\lg\left[\frac{p(x,y)}{p(x)p(y)}\right],\quad(2)$$

式中：X为某一特征在n个样本上的取值分布；Y为对应样本的矿尘浓度取值分布；$I(X;Y)$为X与Y之间的互信息，用于度量二者的统计依赖关系强度（包含非线性依赖），其值越大表示X对Y所包含的不确定性降低越多，即二者共享信息越多；$p(x,y)$为联合概率分布函数；$p(x)$和$p(y)$分别为边缘概率分布函数.

在具体筛选中，本文分两步进行. 首先，基于皮尔逊相关系数，筛选出与矿尘浓度线性相关性显著（$|r|>0.7$[35]，r为特征变量与矿尘浓度变量之间的皮尔逊相关系数）且物理意义明确的特征，构成线性特征子集. 随后，在剔除线性特征后的剩余特征中，计算各特征与浓度的互信息系数，并按互信息值降序排列，形成非线性特征候选集. 为在特征信息量与模型复杂度之间取得平衡，本文初步选取排名前30%[34]的特征构成非线性特征子集，并在后续试验中通过对比前10%，20%和30%这3种特征保留方案，验证了前30%方案在预测精度与稳健性方面的综合表现最优，从而确定其为最终的非线性特征子集. 基于表1计算所得各特征的皮尔逊系数与互信息系数汇总于表2.

表2　矿尘图像特征线性与非线性子集筛选结果

Table 2　Screening results of linear and nonlinear feature subsets for dust image features

图像特征	特征类别	皮尔逊系数	互信息系数	筛选结果
众数	颜色特征	－0.472 7	1.071 6	非线性子集
均匀度		－0.098 8	0.955 2	非线性子集
偏度		－0.436 4	0.838 6	
峰度		－0.425 4	0.741 6	
多样性		－0.684 6	1.401 4	非线性子集
对比度	纹理特征	－0.907 8	1.206 2	线性子集
不相似度		－0.686 3	0.765 6	
能量		0.638 9	0.556 1	
同质性		0.882 1	1.294 8	线性子集
相关性		0.662 4	0.763 4	
熵		－0.652 3	0.557 6	
总能量矩	几何特征	0.069 4	0.817 9	
轴长度矩		0.631 0	1.371 5	非线性子集
角点特征矩		－0.502 4	0.679 8	
第二角点特征矩		－0.492 4	0.751 6	
偏心性矩		－0.460 5	0.751 9	
紧凑度矩		－0.878 0	0.955 2	线性子集
不对称性矩		0.734 2	1.221 2	线性子集
峰值信噪比	图像质量	－0.612 5	0.801 1	
视觉信息保真度		0.416 2	0.654 8	
调制指数		－0.904 7	1.501 2	线性子集
灰度均值	灰度统计特征	－0.550 2	0.840 3	非线性子集
灰度标准差		0.463 9	0.622 9	
灰度偏度		－0.187 6	0.566 0	
灰度峰度		－0.291 8	0.206 5	
透射均值	透光率特征	0.636 6	0.840 3	
透射中位数		0.617 2	0.848 2	非线性子集

2.2.2　特征子集

根据上述筛选准则，最终保留5个与矿尘浓度线性相关性最强的特征，即对比度、同质性、紧凑度矩、不对称性矩、调制指数，构成线性特征子集. 这表明矿尘浓度变化在多维视觉特征上均存在显著的线性响应.

在剔除线性特征后，为充分挖掘剩余特征与矿尘浓度之间的非线性关联，依据互信息值筛选出排名前30%的特征，构成非线性特征子集，主要包括众数、均匀度、多样性、轴长度矩、灰度均值及

透射中位数. 该子集在后续试验中表现出较好的预测精度与鲁棒性,说明其在刻画复杂非线性关系方面具有重要作用.

图 7~10 分别展示了现场与实验室矿尘图像中筛选出的线性与非线性特征随矿尘浓度变化的趋势(受篇幅所限,仅展现部分浓度示例). 图中可见,随着矿尘浓度升高,线性特征呈现明显的单调变化规律,而非线性特征则表现出更复杂的响应模式,印证了线性与非线性特征并存的合理性,也为前述相关性筛选提供了直观依据.

通过上述筛选,本文最终构建了一个融合线性与非线性子集的先验特征集. 该特征集在保留明确物理意义的同时,在统计意义上与矿尘浓度保持高度相关,既为后续的多核残差注意力网络提供了可靠且高效的输入,也奠定了模型可解释性的重要基础.

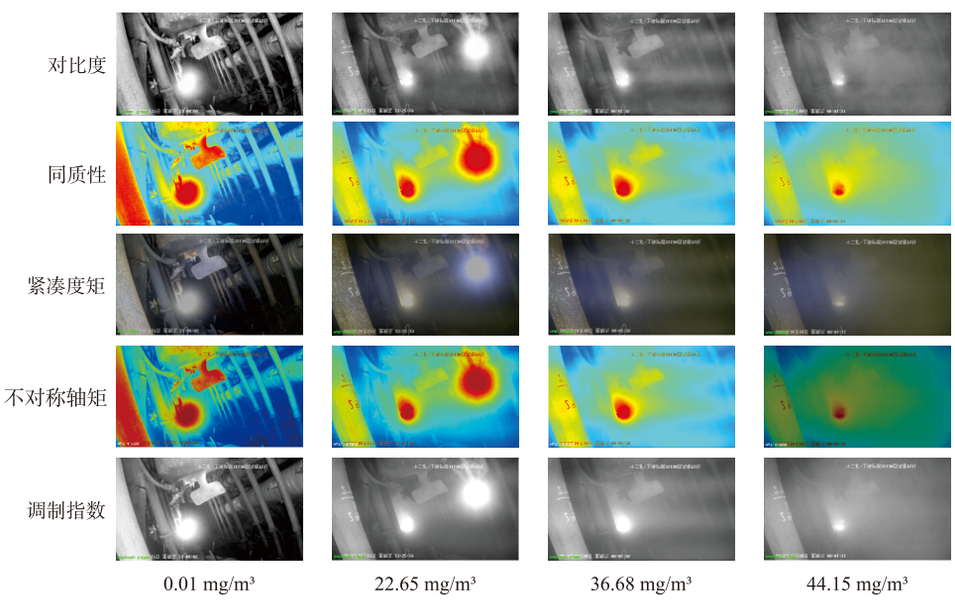


图 7 现场矿尘图像线性特征随矿尘浓度变化趋势

Fig. 7 Trend of linear feature descriptors extracted from in-situ mine dust images versus dust concentration

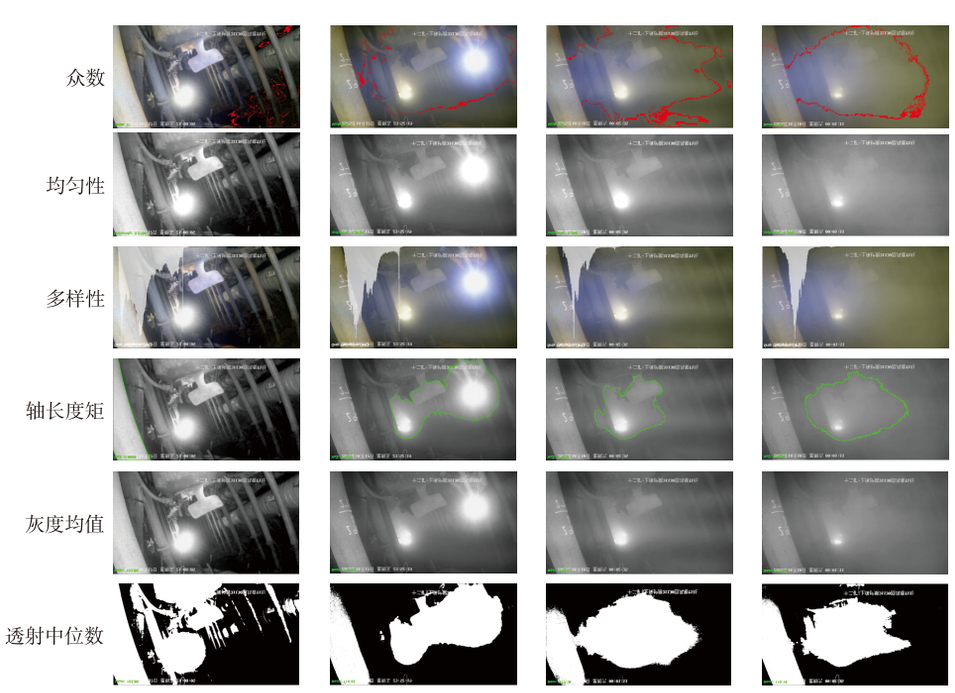


图 8 现场矿尘图像非线性特征随矿尘浓度变化趋势

Fig. 8 Trend of nonlinear feature descriptors extracted from in-situ mine dust images versus dust concentration

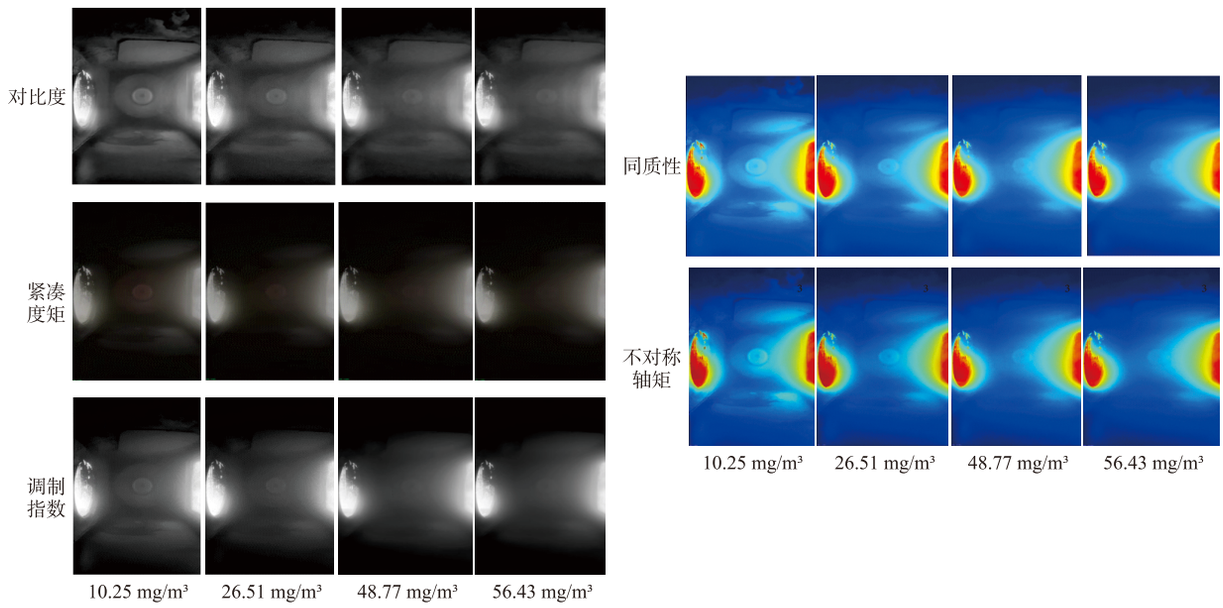


图 9　实验室矿尘图像线性特征随矿尘浓度变化趋势

Fig. 9　Trend of linear feature descriptors extracted from laboratory mine dust images versus dust concentration

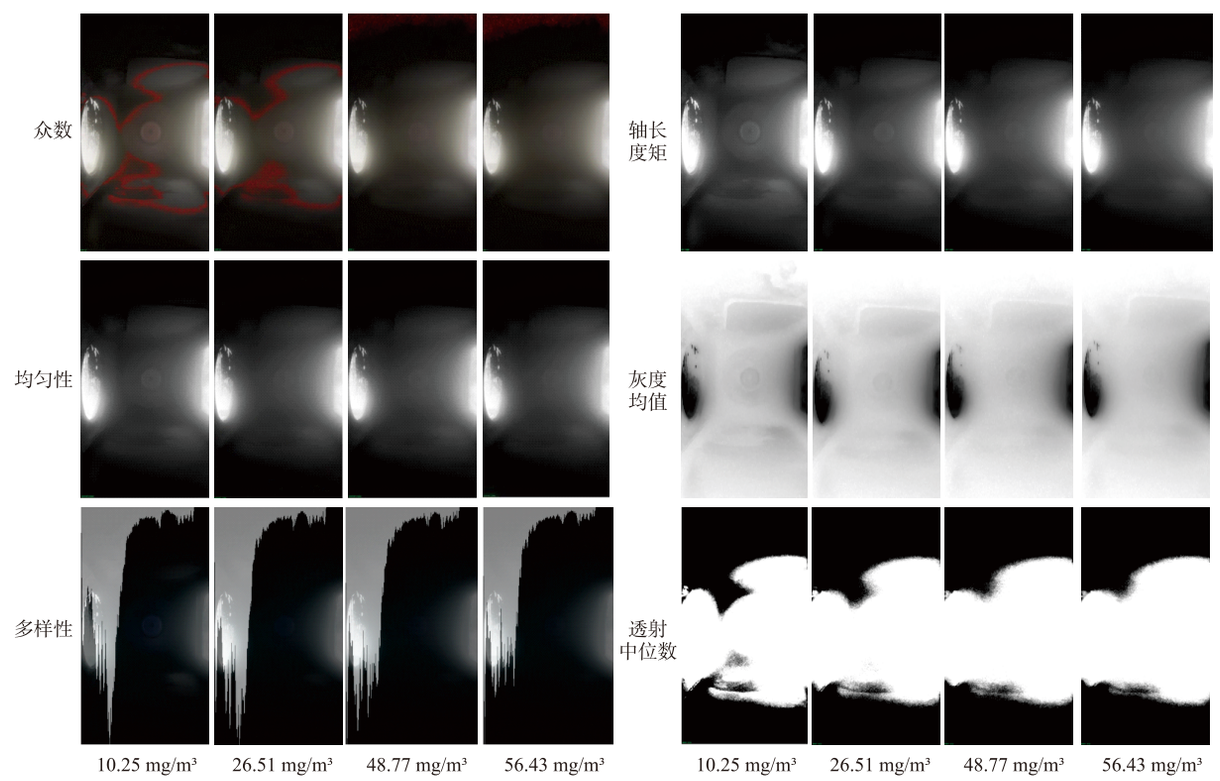
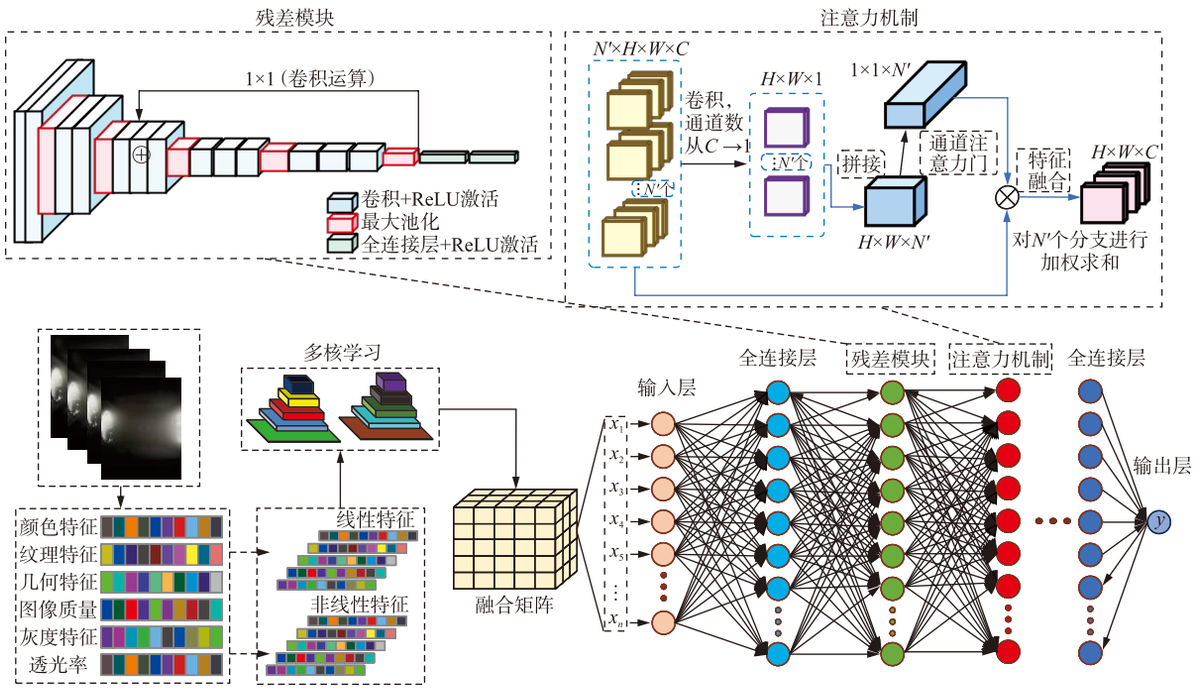


图 10　实验室矿尘图像非线性特征随矿尘浓度变化趋势

Fig. 10　Trend of nonlinear feature descriptors extracted from laboratory mine dust images versus dust concentration

3　基于多核残差注意力网络的矿尘浓度识别模型

在前文筛选出具有明确物理意义的先验特征集的基础上，本文提出了以先验特征为输入的多核残差注意力网络矿尘浓度识别模型，其整体结构如图 11 所示．该模型通过多核学习、残差连接与通道注意力机制的有机结合，实现对矿尘浓度的高精度识别．图 11 中 $F_k \in R^{H\times W\times C}$ 为第 k 个分支输出的特征张量（$k=1, \cdots, K$），其中 K 为多核数量，H，W，C 分别为特征张量的高、宽与通道数；N' 为特征分支数量；x_n 为第 n 个分支输入特征；y 为模型的真实输出值（标签值）．



注：⊕表示残差相加.

图 11 矿尘浓度图像识别模型

Fig. 11 Image recognition model for mine dust concentration

3.1 模型总体框架

模型由 4 个主要模块构成：1）图像特征提取模块：基于皮尔逊相关系数与互信息系数，分别构建线性与非线性特征子集；2）多核特征融合模块：采用径向基函数核分别映射线性与非线性特征，通过加权策略实现特征融合；3）残差-注意力融合回归模块：引入残差块结构增强梯度和信息流动，结合通道注意力机制实现特征权重动态分配；4）输出模块：通过全连接层回归矿尘浓度值.

3.2 多核特征融合

为充分挖掘图像特征与矿尘浓度之间的线性和非线性关系，本文分别从线性特征子集和非线性特征子集中提取特征，采用径向基函数（RBF）核进行高维映射. 设线性特征子集为 $\boldsymbol{X}_{\text{lin}}\in R^{N\times d_1}$、非线性特征子集为 $\boldsymbol{X}_{\text{nolin}}\in R^{N\times d_2}$，其中，$N$ 为样本数（即参与建模的图像样本数量），d_1 与 d_2 分别为线性特征子集与非线性特征子集的特征维度（特征数量），分别计算其 RBF 核矩阵：

$$(\boldsymbol{K}_{\text{lin}})_{ij}=k_{\text{rbf}}(\boldsymbol{X}_{\text{lin}}^{(i)},\boldsymbol{X}_{\text{lin}}^{(j)};\gamma_1), \tag{3}$$

$$(\boldsymbol{K}_{\text{nolin}})_{ij}=k_{\text{rbf}}(\boldsymbol{X}_{\text{nolin}}^{(i)},\boldsymbol{X}_{\text{nolin}}^{(j)};\gamma_2), \tag{4}$$

式中：$\boldsymbol{K}_{\text{lin}}\in R^{N\times N}$ 与 $\boldsymbol{K}_{\text{nolin}}\in R^{N\times N}$ 分别为基于线性特征矩阵 $\boldsymbol{X}_{\text{lin}}$ 与非线性特征矩阵 $\boldsymbol{X}_{\text{nolin}}$ 计算得到的 RBF 核矩阵，$(\boldsymbol{K}_{\text{lin}})_{ij}$ 与 $(\boldsymbol{K}_{\text{nolin}})_{ij}$ 分别为其第 i 行、第 j 列元素，$i,j=1,2,\cdots,N$；$\boldsymbol{X}_{\text{lin}}^{(i)}\in R^{d_1}$ 与 $\boldsymbol{X}_{\text{nolin}}^{(i)}\in R^{d_2}$ 分别为第 i 个样本的线性、非线性特征向量；$k_{\text{rbf}}(x)$ 为径向基核函数；γ_1 与 γ_2 为对应的核宽度（带宽）参数.

2 类特征采用加权融合策略，表达式为

$$\boldsymbol{K}_{\text{mkl}}=\alpha\boldsymbol{K}_{\text{lin}}+(1-\alpha)\boldsymbol{K}_{\text{nolin}}, \tag{5}$$

式中：$\boldsymbol{K}_{\text{mkl}}\in R^{N\times N}$ 为多核学习融合后的综合核矩阵，由线性特征核矩阵 $\boldsymbol{K}_{\text{lin}}$ 与非线性特征核矩阵 $\boldsymbol{K}_{\text{nolin}}$ 按融合权重 α 进行凸组合得到，用于后续模型训练与预测；$\alpha\in[0,1]$，通过网格搜索确定其最优值.

该融合策略既保留了线性特征的物理可解释性，又增强了模型对复杂非线性关系的表征能力，为后续深度学习模块提供了丰富的高阶特征输入.

3.3 残差注意力网络结构

1）残差块设计

在网络结构设计方面，本文构建了一个结合残差块与通道注意力机制的全连接神经网络. 残差块用于缓解深层网络训练中的梯度退化问题. 每个残差块包含 2 个全连接层与 ReLU 激活函数，表达式为

$$\boldsymbol{h}=\phi(\boldsymbol{W}_1\boldsymbol{x}+b_1), \tag{6}$$

$$\text{Res}(\boldsymbol{x})=\phi(\boldsymbol{x}+\boldsymbol{W}_2\boldsymbol{h}+b_2), \tag{7}$$

式中：$\boldsymbol{x}$ 为残差块输入特征向量；$\boldsymbol{h}$ 为隐藏层输出向

量；Res($\boldsymbol{x}$)为残差块输出；$\boldsymbol{W}_1$，$\boldsymbol{W}_2$为全连接的权重矩阵；b_1，b_2为偏置项，均为可学习参数；$\phi(\boldsymbol{x})$为ReLU激活函数.

2) 通道注意力机制

为增强特征的判别性并抑制冗余信息，引入通道注意力机制. 该机制通过对特征通道进行加权，实现动态特征选择，表达式为

$$a(x')=x'\odot\sigma\left\{\boldsymbol{V}_2\phi\left[\boldsymbol{V}_1\,\mathrm{pool}(x')\right]\right\},\tag{8}$$

式中：x'为输入特征；$a(x')$为通道注意力作用后的输出特征；pool(x')为全局平均池化算子，用于对空间维度进行聚合得到通道统计量；$\boldsymbol{V}_1$，$\boldsymbol{V}_2$为可学习参数矩阵；$\sigma(x')$为门控激活函数，采用Sigmoid函数将注意力权重映射至(0，1)区间；符号⊙表示逐元素乘，其中通道权重在空间维度上进行扩展，使其维度与输入特征x'一致. 该模块能够自动学习各特征通道的重要性权重，提升模型对关键特征的敏感性，同时增强输出结果的可解释性.

3.4　训练策略与损失函数

模型采用Adam优化器进行训练，学习率设置为2×10^{-2}，并使用均方误差(E_{MSE})作为损失函数，请表达式为

$$E_{\mathrm{MSE}}=\frac{1}{N}\sum_{i=1}^{N}\left(y_i-\hat{y}_i\right)^2,\tag{9}$$

式中：y_i为真实浓度；$\hat{y}_i$为预测浓度. 训练过程中采用早停策略防止过拟合，并监控训练与验证损失曲线以确保模型收敛的稳定性.

综上所述，该模型通过先验特征选择、多核特征融合、残差块结构以及通道注意力机制的有机结合，实现了对矿尘浓度的高精度识别，并在保证性能的同时增强了模型的可解释性.

4　识别模型性能检验

4.1　试验设置与评价指标

采用前文所构建的2 236组矿尘浓度-图像配对数据集，按8∶2的比例随机划分训练集与测试集，确保数据分布的随机性与代表性. 模型训练使用Adam优化器，初始学习率设置为2×10^{-2}，训练轮次为300次. 采用全批量训练策略，并引入早停策略以防止过拟合.

选用均方误差(E_{MSE})、平均绝对误差(E_{MAE})、平均相对误差(E_{MRE})和拟合优度(R^2)等评价指标，分别从误差幅度、相对偏差和拟合优度等多个角度全面评估模型性能.

4.2　识别结果与分析

将测试集输入本文构建的矿尘浓度识别模型，得到识别结果，以下从训练稳定性、识别精度、误差分布等方面进行分析，如图12所示.

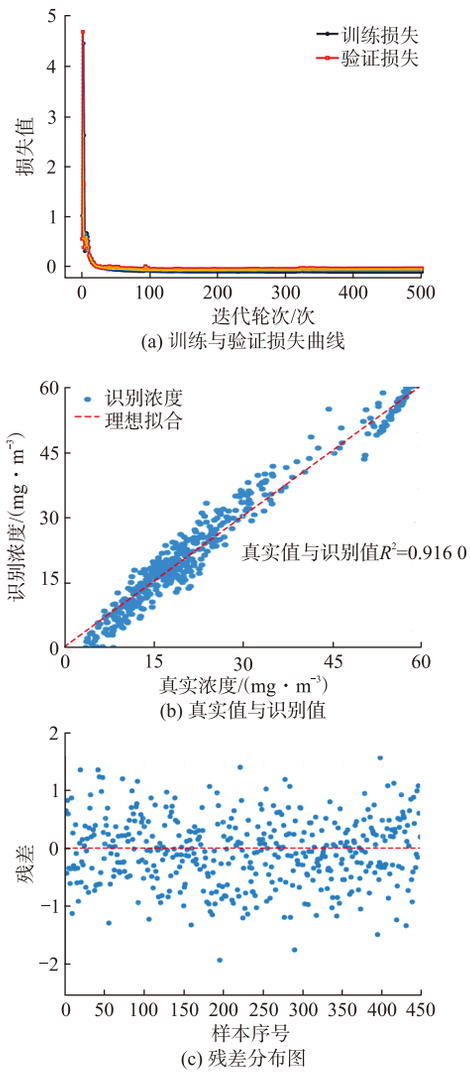


图12　矿尘浓度识别结果分析

Fig. 12　Result analysis of mine dust concentration recognition algorithm

1) 训练过程稳定性

训练损失与验证损失随迭代次数的变化如图12a所示. 可以看出，两者均随训练轮次增加而稳步下降，并在约100次后趋于收敛，未出现明显震荡或过拟合现象. 这表明模型结构合理、优化有效，具备良好的训练稳定性和泛化基础.

2) 识别精度

图12b展示了模型识别浓度与真实浓度的散点分布及拟合曲线. 样本点紧密分布在对角线$y=x$附近，拟合优度R^2达到0.916 0，说明模型能准确

捕捉浓度变化趋势,识别值与真实值具有高度一致性.在不同浓度区间内,模型未表现出明显的系统偏差,显示出良好的整体拟合能力.

3)误差分布与稳健性

残差(识别值与真实值的差值)分布如图12c所示.残差主要集中在零点附近,分布对称且无明显异方差趋势,表明模型在不同浓度水平下均保持稳定的识别性能.表3进一步列出了部分样本的识别结果,可知绝大多数样本的相对误差低于2%,全测试集的E_{MRE}为1.76%.例如,样本编号4的真实浓度为37.21 mg/m^3,识别值为37.08 mg/m^3,相对误差仅为0.35%;即使在误差较大的样本(如编号3)中,相对误差仍处于合理范围内,未出现极端异常值.

表3 识别结果残差分析

Table 3 Residual analysis of test results

图像编号	实际浓度/(mg·m^{-3})	识别浓度/(mg·m^{-3})	相对误差/%
0	44.47	41.52	6.65
1	39.74	39.56	0.44
2	40.40	40.93	1.31
3	40.65	42.97	5.70
4	37.21	37.08	0.35
⋮	⋮	⋮	⋮
444	38.53	38.29	0.61
445	36.56	36.82	0.72
446	37.08	36.90	0.47
447	41.74	41.17	1.36

综上所述,本文模型在测试集上取得了E_{MSE}为0.90 mg^2/m^6、E_{MAE}为0.74 mg/m^3、E_{MRE}为1.76%、R^2为0.916 0的优秀性能.损失曲线收敛平稳,识别结果准确且误差分布集中,表明模型能够稳健地实现从矿尘图像特征到浓度值的高精度映射,为矿井粉尘浓度的视觉检测提供了一种可靠方法.

4.3 对比试验

为客观评价本文所提模型的优越性,将其与当前主流的机器学习回归模型进行性能对比,包括支持向量机回归(SVR)、随机森林(RF)和极端梯度提升树(XGBoost).为保证对比的公平性,所有对比模型均采用与本文模型相同的多核融合特征作为输入,并在相同的数据集与试验环境下进行训练与测试.

性能对比如表4所示.从表中可以看出,本文模型在4项评价指标上均显著优于所有对比模型.具体而言,本文模型的E_{MSE}为0.90 mg^2/m^6,相较于SVR、RF和XGBoost分别降低了约43.5%、61.8%和57.6%;E_{MAE}和E_{MRE}也均为最低,分别仅为0.74 mg/m^{3}和1.76%.同时,本文模型的拟合优度最佳,R^2达到0.916 0,高于其他3种模型.这些结果表明,本文模型在捕捉矿尘浓度与图像特征间的复杂映射关系上具有更强的能力,展现出更优的拟合性能和泛化潜力.

表4 不同模型性能对比

Table4 Comparison of prediction performance among different models

模型名称	特征方案	E_{MSE}/(mg^2·m^{-6})	E_{MAE}/(mg·m^{-3})	E_{MRE}/%	R^2
本文模型	多核融合特征	0.90	0.74	1.76	0.916 0
SVR	多核融合特征	1.60	0.89	2.12	0.869 7
RF	多核融合特征	2.36	1.09	2.67	0.807 2
XGBoost	多核融合特征	2.13	0.88	2.06	0.826 5
本文模型	仅线性特征	1.52	0.92	2.23	0.876 2
本文模型	仅非线性特征	3.64	1.14	2.60	0.702 6

4.4 消融试验

为探究不同模块对模型性能的贡献,本文在特征层面和模型结构层面分别设计了消融试验.

1)特征消融试验

在特征层面,本文重点考察了非线性特征子集的不同保留比例对模型性能的影响.首先,基于互信息系数筛选出与矿尘浓度非线性相关性最强的6个特征(前30%),构成基础非线性特征集.随后,通过逐步减少输入特征的数量,构建了4种特征组合方案进行对比试验,具体包括:6个特征的方案1(前30%)、4个特征的方案2(前20%)和2个特征的方案3(前10%),以及完全不使用非线性特征的方案4(仅保留线性特征子集).试验结果如表5与图13a所示.分析可知,模型性能随输入特

征数量的减少而呈现下降趋势．其中，方案 1 在所有方案中表现最优．这表明多维非线性特征在刻画矿尘浓度与图像复杂关联时具有信息互补与协同增强的作用．与之相比，方案 2 和方案 3 在剔除部分特征后，各项误差指标明显上升，拟合优度 R^2 分别下降至 0.872 1 和 0.824 0；尤其方案 3 的性能退化最为显著．而仅使用线性特征的方案 4，其性能也明显劣于方案 1（E_{MSE}=1.52 mg²/m⁶，R^2=0.876 2）．上述结果充分说明，单一或少数特征难以全面、准确地表征矿尘图像随浓度变化的复杂响应规律，验证了融合多维度非线性特征的必要性．

表 5　图像特征组合方案及评价结果

Table 5　Image feature combination schemes and evaluation results

特征方案	非线性图像特征方案						模型评价结果			
	多样性	轴长度矩	众数	均匀度	透射中位数	灰度均值	E_{MSE}/(mg²·m⁻⁶)	E_{MAE}/(mg·m⁻³)	E_{MRE}/%	R^2
方案 1	√	√	√	√	√	√	0.90	0.74	1.76	0.916 0
方案 2	√	√	√	√	—	—	1.43	0.95	2.30	0.872 1
方案 3	√	√	—	—	—	—	2.16	0.97	2.28	0.824 0
方案 4	—	—	—	—	—	—	1.52	0.92	2.23	0.876 2

注：√表示使用该特征；—表示该特征未被选择使用．

2）结构消融试验

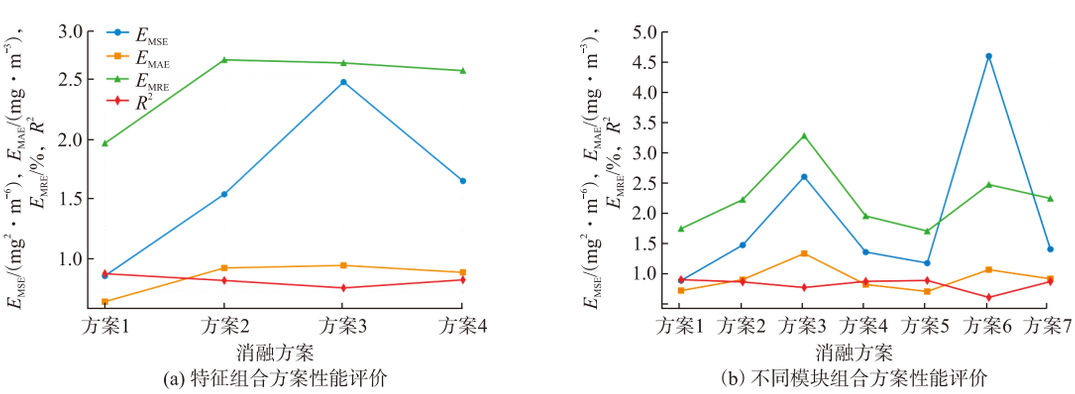
在模型结构层面，通过逐步移除多核融合、残差连接和通道注意力机制这 3 个核心模块，构建了 7 种不同的结构组合方案（方案 1～7），以量化评估各模块的贡献．完整模型（方案 1）集成了所有模块，其性能作为基准．其余方案则分别移除了一个或多个模块．试验结果详见表 6 及图 13b．

表 6　模型模块组合方案及评价结果

Table 6　Model module combination schemes and evaluation results

模型方案	模型模块组合方案			模型评价结果			
	多核融合	残差融合	注意力机制	E_{MSE}/(mg²·m⁻⁶)	E_{MAE}/(mg·m⁻³)	E_{MRE}/%	R^2
方案 1	√	√	√	0.90	0.74	1.76	0.916 0
方案 2	—	√	√	1.49	0.92	2.24	0.878 5
方案 3	√	—	√	2.62	1.35	3.30	0.786 2
方案 4	√	√	—	1.37	0.84	1.97	0.887 9
方案 5	√	—	—	1.19	0.72	1.72	0.902 8
方案 6	—	√	—	4.62	1.08	2.49	0.623 1
方案 7	—	—	√	1.42	0.93	2.26	0.884 1

注：√表示使用该特征；—表示该特征未被选择使用．



(a) 特征组合方案性能评价　　(b) 不同模块组合方案性能评价

图 13　特征组合方案和模块组合方案性能评估

Fig. 13　Performance evaluation of different feature schemes and model structure schemes

分析可知,完整模型(方案1)取得了最优的综合性能,移除任一核心模块均会导致模型性能下降.具体而言,当移除多核融合模块时(如方案2,6,7),模型误差显著增大,尤其是仅保留残差结构的方案6的性能最差(E_{MSE}=4.62 mg^2/m^6,R^2=0.623 1),凸显了多核融合在有效整合线性和非线性特征、提升模型表达能力方面的关键作用.移除残差连接模块后(如方案3,5),模型的E_{MSE}和E_{MAE}明显上升,R^2下降,表明残差结构对于促进梯度流动、增强模型对复杂非线性关系的拟合能力至关重要.此外,取消通道注意力机制的方案4(E_{MSE}=1.37 mg^2/m^6,R^2=0.887 9)的性能也低于完整模型,说明注意力机制通过动态加权强化关键特征、抑制冗余信息,对提升模型判别力与鲁棒性具有积极作用.

4.5 讨论

以上试验结果表明,本文所提出的模型在矿尘浓度识别任务中表现出色,不仅精度高、误差小,而且具有较强的鲁棒性和可解释性.多核融合机制有效整合了线性和非线性特征的优势,残差结构缓解了深层网络的梯度问题,注意力机制则增强了对关键图像特征的感知能力.此外,特征与结构层面的消融试验充分验证了模型设计的合理性与必要性.

5 结 论

1)构建了一套融合物理先验与统计相关性的可解释图像特征体系.通过引入颜色、纹理、几何等具有明确物理意义的先验特征,并结合皮尔逊相关系数与互信息系数进行双重筛选,构建了线性与非线性特征子集.该体系不仅为模型提供了可解释的输入基础,而且在一定程度上降低了对大规模训练样本的依赖,使模型在有限样本条件下仍能保持较高的准确性与稳健性.

2)设计了一种结合多核学习、残差连接与通道注意力机制的深度学习识别模型.该模型利用多核融合策略分别处理线性和非线性特征,通过残差结构促进梯度传播与特征复用,并借助通道注意力机制实现关键特征的动态强化与权重分配.这一设计在显著提升识别精度的同时,增强了模型决策过程的透明性与可解释性.

3)试验验证表明,多核融合、残差结构与注意力机制的协同作用显著提升了模型性能.在测试集上,完整模型取得了E_{MSE}为0.90 mg^2/m^6、E_{MAE}为0.74 mg/m^3、E_{MRE}为1.76%、R^2为0.916 0的优异表现,性能显著优于支持向量机回归、随机森林等传统机器学习模型及各类消融对比模型,充分证明了所提方法在准确性、鲁棒性与可解释性方面的综合优势.

4)明确了模型输出结果的物理意义与适用尺度.本文提取的图像特征主要为视场范围内的统计量,其物理含义对应于粉尘云的整体状态.因此,模型输出更适宜理解为摄像机视场内、在曝光时间内的空间平均浓度.然而,当前模型对粉尘空间非均匀分布及局部极值的刻画能力有限,未来需结合多视角、多尺度或分区特征提取等方法,进一步提升对浓度空间分布的解析能力.

本文致力于推动深度学习模型在矿尘灾害监测预警中的透明化和可信应用,为矿井粉尘浓度的智能检测提供了一种高可解释性的解决方案,具有良好的理论价值与工程应用潜力.未来将探索自动化特征选择、多模态信息融合、矿尘浓度空间分布检测等方向,以提升模型的泛化能力与实用价值,更好地服务于煤矿安全生产的现实需求.

参考文献:

[1] 聂百胜,张 豪,宫 婕,等.煤粉爆炸宏细观四阶段反应机理[J].中国矿业大学学报,2023,52(6):1129-1145.
NIE Baisheng, ZHANG Hao, GONG Jie, et al. Macro and meso four-stage reaction mechanism of pulverized coal explosion[J]. Journal of China University of Mining & Technology, 2023, 52(6): 1129-1145.

[2] WATSON J G, TROPP R J, KOHL S D, et al. Filter processing and gravimetric analysis for suspended particulate matter samples [J]. Aerosol Science and Engineering, 2017, 1(2): 93-105.

[3] LIU X, HUANG Y, WANG Z, et al. On-line measurement of ultralow mass concentration particulate based on light scattering coupled with beta ray attenuation method[J]. Fuel, 2022, 329: 125461.

[4] 周福宝,郑丽娜,冯子康,等.基于振荡天平原理的矿工个体粉尘连续监测仪的研制[J].煤炭学报,2024,49(2):876-884.
ZHOU Fubao, ZHENG Lina, FENG Zikang, et al. Development of a miner personal dust continuous monitor based on the principle of oscillation balance [J]. Journal of China Coal Society, 2024, 49(2): 876-884.

[5] YANG X H, YU H M, WANG Y H, et al. Study on the modularized airflow-diverging system and dust-

control technology in the fully mechanized heading face [J]. Powder Technology, 2022, 402: 117325.

[6] 才存良,王　洋,冯进良,等.基于光纤传感技术的矿井粉尘质量浓度检测[J].光学仪器,2017,39(2):10-15.
CAI Cunliang, WANG Yang, FENG Jinliang, et al. Optical fiber sensor for the coal mine dust mass concentration in well testing [J]. Optical Instruments, 2017, 39(2): 10-15.

[7] CHEN J, NIE Z, ZHAO F, et al. Improving the stability of electrostatic induction dust concentration detection using kalman filtering algorithm aided by machine learning [J]. Process Safety and Environmental Protection, 2023, 174: 882-890.

[8] 陈长江,阳小明,李天倩,等.相对时差超声法检测微量SF_6浓度及FPGA实现[J].西华大学学报(自然科学版),2014,33(3):54-56.
CHEN Changjiang, YANG Xiaoming, LI Tianqian, et al. Detection of concentration micro-SF_6 and FPGA implementation by relative time-difference ultrasonic method[J]. Journal of Xihua University (Natural Science Edition), 2014, 33(3): 54-56.

[9] 孙继平,李小伟.基于图像顺滑度的矿井外因火灾识别及抗干扰方法研究[J].中国矿业大学学报,2025,54(1):215-226.
SUN Jiping, LI Xiaowei. Research on identification and anti-interference method of mine external fire based on image smoothness [J]. Journal of China University of Mining & Technology, 2025, 54(1): 215-226.

[10] XANG Z, LI D Y, ZHENG X, et al. A novel coal dust characteristic extraction to enable particle size analysis [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.

[11] YANG B Q, CHEN Q. $PM_{2.5}$ concentration estimation based on image quality assessment [C]//4th IAPR Asian Conference on Pattern Recognition (ACPR), Nanjing, China. New York: IEEE, 2017.

[12] 屠陆阳,陈清华,程迎松,等.基于机器视觉的粉尘识别与浓度检测方法研究[J].煤矿安全,2025,56(8):48-58.
TU Luyang, CHEN Qinghua, CHENG Yingsong, et al. Research on dust indentification and concentration detection method based on machine vision [J]. Safety in Coal Mines, 2025, 56(8): 48-58.

[13] YIN J J, LEI J Y, FAN K X, et al. Integrating image processing and deep learning for effective analysis and classification of dust pollution in mining processes [J]. International Journal of Coal Science & Technology, 2023, 10(4): 17-33.

[14] LUO Z Y, HUANG F F, LIU H. $PM_{2.5}$ concentration estimation using convolutional neural network and gradient boosting machine [J]. Journal of Environmental Sciences, 2020, 31(1): 19-28.

[15] OBREGÓN L, VELÁZQUEZ C. Discrimination limit between mean gray values for the prediction of powder concentrations [J]. Powder Technology, 2007, 175(1): 8-13.

[16] WANG S F, YIN J J, LIANG Y T, et al. Dust pollution evaluation based on grayscale average and fractal dimension of digital image [J]. Journal of Cleaner Production, 2022, 379: 134691.

[17] YANG P, CHEN L, TIAN J, et al. Dust particle detection in surveillance video using salient visual descriptors [J]. Computers & Electrical Engineering, 2017, 62: 224-231.

[18] LI G H, WU J P, LUO Z W, et al. Vision-based measurement of dust concentration by image transmission [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(10): 3942-3949.

[19] BAI X S, ZHANG N, CAO X Y, et al. Prediction of $PM_{2.5}$ concentration based on a CNN-LSTM neural network algorithm[J]. PeerJ, 2024, 12: e17811.

[20] LI L F, GIRGUIS M, LURMANN F, et al. Ensemble-based deep learning for estimating $PM_{2.5}$ over California with multisource big data including wildfire smoke [J]. Environment International, 2020, 145: 106143.

[21] 张　帆,张嘉荣,程海星.基于深度学习的矿井智能目标检测技术研究综述[J].煤炭科学技术,2025,53(增1):284-296.
ZHANG Fan, ZHANG Jiarong, CHENG Haixing. Research review on intelligent object detection technology for coal mines based on deep learning [J]. Coal Science and Technology, 2025, 53(Sup 1): 284-296.

[22] ARJOMANDI H, KHEIRALIPOUR K, AMARLOEI A. Estimation of dust concentration by a novel machine vision system [J]. Scientific Reports, 2022, 12(1): 1-10.

[23] 龚晓燕,冯　浩,付浩然,等.基于图像分析的掘进工作面粉尘颗粒检测方法[J].工矿自动化,2024,50(4):55-62.
GONG Xiaoyan, FENG Hao, FU Haoran, et al. A method for detecting dust particles in excavation working face based on image analysis [J]. Journal of Mine Automation, 2024, 50(4): 55-62.

[24] 丁　震,李浩荡,张庆华.煤矿灾害智能预警架构及

关键技术研究[J].工矿自动化,2023,49(4):15-22.
DING Zhen, LI Haodang, ZHANG Qinghua. Research on intelligent hazard early warning architecture and key technologies for coal mine[J]. Journal of Mine Automation, 2023, 49(4): 15-22.

[25] HOUDOU A, EI B I, KHOMSI K, et al. Interpretable machine learning approaches for forecasting and predicting air pollution: A systematic review [J]. Aerosol and Air Quality Research, 2024, 24(1): 1-25.

[26] 赵 猛,魏玉忠,李 正,等.基于半监督网络的采煤工作面尘雾图像去雾算法[J].煤炭科学技术,2025,53(增1):346-353.
ZHAO Meng, WEI Yuzhong, LI Zheng, et al. Defogging algorithm for coal mining face dust and fog images based on a semi-supervised network[J]. Coal Science and Technology, 2025, 53(Sup 1): 346-353.

[27] 盖勇刚.基于暗通道引导滤波和光照校正的煤矿井下图像去雾算法[J].工矿自动化,2024,50(6):89-95.
GAI Yonggang. A defogging algorithm for coal mine underground images based on dark channel guided filtering and lighting correction [J]. Journal of Mine Automation, 2024, 50(6): 89-95.

[28] WANG Z, YANG S, ZHANG J, et al. Estimation of coal dust parameters via an effective image-based deep learning model [J]. Computers in Industry, 2025, 164: 104200.

[29] GRAVETTER F J, WALLNAU L B. Statistics for the behavioral sciences [M]. Boston: Cengage Learning, 2016: 768.

[30] 姚军财.基于人眼对比度敏感视觉特性的图像质量评价方法[J].液晶与显示,2011,26(3):390-396.
YAO Juncai. Image quality assessment method based on contrast sensitivity visual characteristics of human vision system[J]. Chinese Journal of Liquid Crystals and Displays, 2011, 26(3): 390-396.

[31] 丰明坤.基于视觉特性的图像质量综合评价方法研究[D].南京:南京邮电大学,2016.
FENG Mingkun. Research on methods of image quality comprehensive assessment method based on visual characteristics [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2016.

[32] 路庆昌,张 图,王 琴,等.时空角度下极端天气的可达性指标比较[J].浙江大学学报(工学版),2024,58(7):1387-1396.
LU Qingchang, ZHANG Tu, WANG Qin, et al. Comparison of accessibility indices for extreme weather events from spatiotemporal perspectives[J]. Journal of Zhejiang University (Engineering Science), 2024, 58(7): 1387-1396.

[33] ABU S A H, ZAINAL A, Al-RIMY B A S, et al. Intrusion detection in IoT using Gaussian fuzzy mutual information-based feature selection[J]. Engineering, Technology & Applied Science Research, 2024, 14(6): 17564-17571.

[34] HARALICK R M, SHANMUGAM K, DINSTEIN I H. Textural features for image classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1973, 3(6): 610-621.

[35] GULATI A, FELAHATPISHEH A, VALDERRAMA C E. Feature engineering through two-level genetic algorithm [J]. Machine Learning with Applications, 2025, 21: 100696.

(责任编辑 沈春妮 仝 腾)