

寇旗旗, 张海龙, 陈加鹏, 等. 基于雾气分级与域间差异的采掘工作面图像去雾方法[J]. 采矿与岩层控制工程学报, 2026, 8(2): 026531.

KOU Qiqi, ZHANG Hailong, CHEN Jiapeng, et al. Dehazing method for working face images based on haze grading and domain differences[J]. Journal of Mining and Strata Control Engineering, 2026, 8(2): 026531.

基于雾气分级与域间差异的采掘 工作面图像去雾方法

寇旗旗^{1,2}, 张海龙^{1,2}, 陈加鹏^{1,2}, 宋天舒^{2,3}, 江鹤^{2,3}, 程德强^{2,3}, 陈亮亮^{2,3}

(1. 中国矿业大学 计算机科学与技术学院, 江苏 徐州 221116; 2. 深地科学与工程云龙湖实验室, 江苏 徐州 221003; 3. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221116)

摘要: 矿井采掘工作面粉尘、高湿度和烟雾等复杂环境会导致监控图像特征退化, 且不同雾气浓度产生的退化也会有差异。同时, 由于当前图像去雾模型的训练主要基于合成雾数据, 其获得的先验知识与矿井真实雾气之间存在固有的域间差异。这些问题严重制约了矿井智能监控的效果, 对安全生产构成隐患。基于此, 提出一种基于雾气分级与域间差异的采掘工作面图像去雾方法。①基于不同浓度尘雾图像在解空间上的差异, 构建雾气评价指标以指导尘雾图像分级, 并自动匹配不同规模的网络结构, 实现采掘工作面轻雾场景的快速去雾和浓雾场景的深度细节恢复。②改进对比学习策略, 利用雾气评价指标对轻雾与浓雾图像进行负样本分级, 细化不同浓度雾气特征的对比学习, 从而强化模型对不同雾气特征的判别能力和跨域泛化表现。③针对合成雾与尘雾图像之间的数据域差异, 提出无需真实数据标注的无监督微调策略, 通过循环一致性约束校正去雾映射函数, 有效缓解模型在采掘工作面场景中的性能衰减。试验结果表明, 此方法在合成数据集和采掘工作面尘雾图像的去雾效果均优于现有主流方法, 可为煤矿井下智能监控和安全生产提供参考。

关键词: 采掘工作面; 雾气分级; 对比学习; 无监督微调; 真实尘雾图像; 图像去雾

中图分类号: TP391

文献标志码: A

文章编号: 2096-7187(2026)02-6531-13

Dehazing method for working face images based on haze grading and domain differences

KOU Qiqi^{1,2}, ZHANG Hailong^{1,2}, CHEN Jiapeng^{1,2}, SONG Tianshu^{2,3}, JIANG He^{2,3},
CHENG Deqiang^{2,3}, CHEN Liangliang^{2,3}

(1. School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China; 2. Yunlong Lake Laboratory of Deep Underground Science and Engineering Project, Xuzhou 221003, China; 3. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: The complex environment of mining working faces—including dust, high humidity, and smoke—causes severe feature degradation in monitoring images under varying fog concentrations. Moreover,

收稿日期: 2025-06-11

修回日期: 2025-08-23

责任编辑: 许书阁

DOI: 10.13532/j.jmsce.cn10-1638/td.2025-1198

基金项目: 深地科学与工程云龙湖实验室资助项目(104024005); 国家自然科学基金资助项目(52204177, 52304182); 江苏省卓越博士后计划资助项目(2024ZB423); 博士后科学基金资助项目(2024M763543)

作者简介: 寇旗旗(1988—), 男, 河南襄城人, 副教授, 硕士生导师。E-mail: kouqiqi@cumt.edu.cn


通信作者: 陈亮亮(1993—), 男, 江苏徐州人, 讲师。E-mail: chenll01@cumt.edu.cn

existing dehazing models trained mainly on synthetic data exhibit domain gaps with real mining fog, limiting intelligent monitoring effectiveness and posing safety risks. This study proposes a dehazing method for working face images based on fog grading and domain differences. First, fog evaluation metrics guide image grading, enabling adaptive network selection for light and dense fog scenarios. Second, a contrastive learning strategy refines negative samples based on fog concentration, improving feature discrimination and cross-domain generalization. Finally, an unsupervised fine-tuning strategy with cyclic consistency mitigates domain bias between synthetic and real fog images without requiring annotations. Experiments show that the proposed method outperforms existing approaches on both synthetic and real datasets, supporting safe and intelligent monitoring in coal mines.

Key words: working face; haze grading; contrastive learning; unsupervised fine-tuning; real haze images in coal mines; image dehazing

采掘工作面场景去雾^[1]作为矿井视觉安全中的重要任务,在矿井安全监控场景中同样至关重要。不仅有助于消除井下粉尘烟雾造成的图像模糊,恢复监控画面的视觉质量^[2],还为后续的图像超分辨技术^[3]、场景理解^[4]、目标识别^[5]等应用提供重要支持。随着矿井智能监控需求的提升,如何在复杂多变的井下雾气条件下实现高效且稳健的去雾,已成为亟待解决的行业难题。

图像去雾的核心目标是将尘雾图像转化为清晰的无雾图像,这一过程可以视为在高维特征空间中构造一个映射函数,将“带雾图像”映射为“清晰图像”。由于不同浓度雾气对图像特征的影响程度不同,会造成特征退化程度的不均衡,因此该映射函数需要针对不同雾气浓度进行自适应调整。图1展示了选取的若干尘雾图像及其亮度和对比度信息,可以看到:在薄雾条件下,图像主要表现为对比度轻微下降且只有少量细节被遮挡;而在浓雾条件下,图像则出现显著的整体退化和大量细节丢失。这表明薄雾和浓雾图像在特征空间中分别对应着两个复杂度和范围各异的子解空间。



浓雾图像



薄雾图像



清晰图像

(b)

图1 清晰图像、薄雾图像和浓雾图像的对比展示
Fig. 1 Comparative display of clear images, light fog images, and dense fog images

在对浓雾图像分别采用轻量模型和复杂模型进行去雾推理时,去雾效果差异明显,如图2所示。




图2 轻量模型与复杂模型推理结果

Fig. 2 Inference results of lightweight and complex models

图 2(b) 中, 轻量模型在浓雾场景下效果非常有限, 产生了较强的块状伪影与纹理失真, 图像噪声明显增多, 部分区域出现结构断裂和边缘模糊; 图 2(c) 表明复杂模型能够去除更多雾气, 但其庞大的参数量导致推理速度显著下降。现有的深度学习去雾方法中, 复杂网络结构虽然能够取得较好的去雾效果, 但往往以牺牲推理效率为代价。对于采掘工作面需要实时视频监控以保障安全生产的场景而言, 上述性能取舍进一步限制了去雾算法的实际应用。

另一方面, 现有的对比学习方法虽在表征学习方面取得了一定成果, 但未能充分考虑轻雾与浓雾图像在特征空间中的差异, 从而限制了模型的判别力与泛化能力。此外, 目前训练数据主要来自合成雾, 与尘雾之间存在显著的域差异, 导致模型在矿井场景中的去雾性能难以保持稳定。

针对以上不足, 笔者面向采掘工作面场景提出了一种基于雾气分级与域间差异的图像去雾方法。与一般井下图像相比, 采掘工作面在粉尘粒径分布广、湿热环境与定向光源的耦合作用下, 更易出现大面积高亮低纹理与非均匀散射区域。这导致在不同雾气浓度下, 图像的可见度和细节保持呈现明显跃迁, 难以通过单一模型统一适配。为此, 笔者通过将雾气分级、分级对比学习策略与无监督微调策略相结合, 可有效解决合成雾与尘雾之间的域间差异问题, 提升模型在采掘工作面复杂雾气条件下的适应性与鲁棒性。

1 研究背景

目前, 尘雾图像去雾的研究主要可分为基于物理模型和基于深度学习的方法。

1.1 基于物理模型的方法

基于物理模型的方法为图像去雾研究奠定了

坚实的理论基础。这类方法以大气散射模型为核心, 通过详细分析光在雾天中的散射过程, 构建出描述图像降质机制的数学模型, 如式 (1) 所示。

$$I(x) = J(x)t(x) + A[1 - t(x)] \quad (1)$$

式中, $I(x)$ 为观测到的带雾图像; $J(x)$ 为无雾图像; A 为大气光强度值; $t(x)$ 为透射率, 描述光线穿透场景的能力, 即

$$t(x) = e^{-\beta d(x)} \quad (2)$$

其中, β 为散射系数; $d(x)$ 为场景深度。

通过估计 $t(x)$ 和 A , 可以从带雾图像中 $I(x)$ 复原无雾图像 $J(x)$, 同时也可以将无雾图像 $J(x)$ 加雾为带雾图像 $I(x)$ 。

何恺明等^[6]提出的暗通道先验算法是这一领域的里程碑式工作, 该算法利用图像中局部区域至少存在一个颜色通道强度值极低的先验信息, 有效估计透射率, 进而恢复出清晰图像。色线^[7]和雾线^[8]从不同角度分析了 RGB 色彩空间中无雾通道的线性关系, 从而估计透射图。而颜色衰减先验^[9]则分析了模糊图像在 HSV 色彩空间中 S-V 通道差异与场景深度之间的关系, 从而推导出透射图。Rank-one 先验^[10]考虑接近 Rank-one 矩阵的透射图, 该矩阵可以通过计算图像在统一辐射上的投影得到。此后, 导向滤波算法^[11]的引入进一步细化了透射率图, 显著提升了去雾效果。TAREL 等^[12]提出的快速去雾算法, 通过估计大气光和透射率图来恢复清晰图像, 取得了较好的实时性; FATTAL^[13]则提出了一种基于颜色线索的去雾方法, 该方法利用图像中的颜色信息来估计透射率, 并实现了较好的去雾效果。

然而, 这类方法通常依赖于特定的先验假设, 当雾气浓度极大或场景结构复杂时, 先验信息的有效性显著下降, 导致去雾不彻底、细节丢失或颜色

失真等问题。

1.2 基于深度学习的方法

该方法近年来在图像去雾领域取得了显著突破, 这类方法利用深度神经网络模型从大量成对数据中学习去雾的规律。DehazeNet^[14] 和 MSCNN^[15] 是基于学习的图像去雾方法的先驱。樊红卫等^[16] 创新性地通过通道差阈值分割与伽马变换修正通道差, 结合暗通道与亮通道透射率分区域融合策略, 避免了传统方法在边缘像素归属上的模糊性; 赵猛等^[17] 针对采煤工作面尘雾浓度分布不均问题, 提出基于半监督网络的去雾算法。生成器采用编解码结构, 编码器引入空间注意力机制以处理非均匀尘雾, 解码器通过像素混洗层逐步恢复高分辨率特征, 判别器以概率图形式评估生成图像真实性。现有深度学习方法多为单一网络结构, 缺乏对不同雾气场景的针对性处理, 导致轻雾图像处理速度慢或浓雾图像处理不足。

对比学习作为一种深度学习无监督学习方法, 近年来在计算机视觉领域得到广泛应用。如, WU 等^[18] 提出了基于对比学习的去雾框架, 引入负样本的概念于图像去雾中, 通过设计清晰图像为正样本, 雾图像为负样本, 在轻量化网络中利用对比损失增

强去雾性能; LIU 等^[19] 提出了多对比正则化, 其根据锚点和负样本之间的距离来定义软对比正则化和硬对比正则化; ZHENG 等^[20] 提出了一种新的对比度损失变体, 其利用来自现有去雾模型的输出作为负片样本, 称为“困难负样本”, 而输入的带雾图像被用作“简单负样本”; WANG 等^[21] 引入了一种对比度损失机制, 在像素和图像块级别运行, 其中像素损失利用真实世界的无雾图像和带雾图像分别作为正样本和负样本, 而图像块损失则从输入图像中选择图像块, 将重建图像中的相应图像块视为正样本, 而将所有其他图像块视为负样本。

这些方法仍然存在一个局限性, 并未考虑到不同雾气水平的图像在特征空间上存在着不同, 这会导致特征表示的泛化能力不足。因此, 笔者提出分级对比学习框架, 通过引入薄雾和浓雾图像作为双重负样本, 扩大不同雾气图像在特征空间的距离, 增强模型对不同雾气特征的区分能力, 从而弥补了这一不足。

2 基于分级门控双分支网络架构的去雾模型

面向采掘工作面尘雾图像, 笔者采用分级门控双分支网络架构(图 3)作为去雾模型, 以兼顾井下

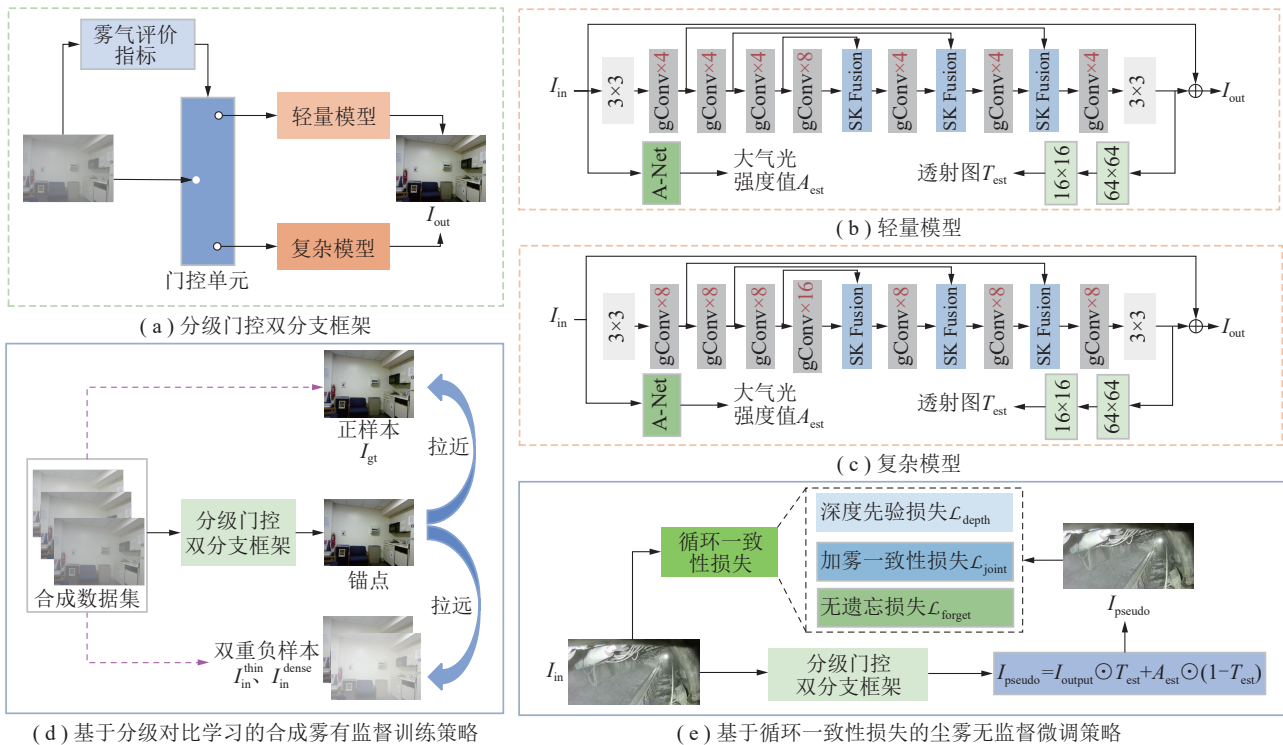


图 3 整体框架

Fig. 3 Overall framework of this study

轻雾场景与浓雾场景下的去雾效果和实时性能,并设计了分级对比学习策略用于合成雾数据的有监督训练。此外,针对采掘工作面尘雾图像与合成雾图像之间的域间差异,笔者提出了一种无需真实标签数据的无监督微调策略。与现有在特征层面进行多尺度或通道加权的门控框架不同,笔者的门控依据雾气评价指标在样本级完成雾域划分,并将轻雾样本与浓雾样本分别匹配轻量与复杂子网络;进一步地,该样本级门控信号被分级对比学习回灌为监督信息,从分级判别、结构调度到对比学习形成闭环,从而稳定提升跨域泛化能力。

基于分级门控双分支网络的整体框架如图3所示,首先使用合成数据集预训练去雾模型,而后将其进行无监督微调,使之面向采掘工作面场景的尘雾图像具有更佳的效果。其中分级门控双分支框架的图像去雾网络(图3(a)),以GUNet^[22]中的GUNet-s和GUNet-b分别作为基准的轻量模型和复杂模型,并在此基础上增加了物理先验信息估计模块^[23](图3(b), (c))。

2.1 分级门控双分支框架

首先评估图像雾气浓度,随后为其选择轻量或复杂网络结构,其过程如图3(a)所示。

2.1.1 雾气评价指标

由图1(b)可知尘雾对图像成像过程的物理影响,随着雾气浓度的增加,图像整体亮度提升,同时边缘和纹理的对比度逐渐减弱。为验证雾气浓度与亮度、对比度的相关性,首先对757张图像(随机挑选于RESIDE数据集^[24])进行人工标注,根据视觉感知将其分为薄雾图像与浓雾图像两个类别。对每幅雾图 I_{in} ,定义其亮度 L 和对比度 C 为

$$L(I_{in}) = \frac{1}{N} \sum_{i \in \Omega} I_{in}(i) \quad (3)$$

$$C(I_{in}) = \sqrt{\frac{1}{N} \sum_{i \in \Omega} [I_{in}(i) - L(I_{in})]^2} \quad (4)$$

式中, N 为图像像素总数; Ω 为图像所包含的像素集合; $I_{in}(i)$ 为第 i 个像素的强度值。

随后对757张图像的亮度与对比度进行统计,其结果如图4所示,薄雾图像通常具有较高的对比度和适中的亮度,浓雾图像则表现出低对比度和高亮度的特点。

基于此,提出雾气评价指标 F 来实现雾气的评估,如式(5)所示。




图4 亮度与对比度的聚合显示

Fig. 4 Aggregation display of brightness and contrast

$$F(I_{in}) = \omega_L L(I_{in}) + \omega_C C(I_{in}) \quad (5)$$

式中, ω_L 和 ω_C 为权重参数。

采用网格搜索确定权重与阈值,设定 $\omega_L \in [0, 1]$, $\omega_C = 1 - \omega_L$, 阈值 $T \in [0, 1]$, 步长均为0.01。以标注集的二分类 $F1$ 分数最大化为目标,最终取值为 $\omega_L = 0.67$, $\omega_C = 0.33$, $T = 0.04$ 。最后并通过阈值 T 来区分轻雾与浓雾图像,如式(6)所示。

$$I_{type}(I_{in}) = \begin{cases} \text{薄雾图像}, & F(I_{in}) < T \\ \text{浓雾图像}, & F(I_{in}) \geq T \end{cases} \quad (6)$$

基于该分级方法对采掘工作面带雾图像进行雾气分级,其结果如图5所示。笔者提出的雾气评价指标能够较好地刻画雾气在图像中的退化特性,实现不同雾气级别间的有效区分。

2.1.2 门控双分支网络

基于对图2的分析,单一网络模型难以同时兼顾轻雾和浓雾场景的复原需求,通常会导致两者效率与效果的不平衡。因此,针对解空间匹配不同网络结构,对薄雾图像和浓雾图像分而治之是一种有效策略。其过程如式(7)所示。

$$I_{out}(I_{in}) = \begin{cases} f_{thin}(I_{in}), & F(I_{in}) < T \\ f_{dense}(I_{in}), & F(I_{in}) \geq T \end{cases} \quad (7)$$

式中, f_{thin} 为轻量模型; f_{dense} 为复杂模型。

在两个分支中均嵌入物理先验估计模块,该模块用于增强模型对成像物理过程的建模能力,估计出带雾图像的物理先验信息大气光强度值及透射图。

(1) 薄雾网络: 在每个阶段都使用更少的卷积核数量,减少模型的参数量和计算量。这种设计使薄雾网络能够专注于快速处理薄雾图像,同时不降低去雾网络的性能。

(2) 浓雾网络: 针对浓雾图像选择更深层次的网络结构,以深入挖掘复杂场景中的细节信息。通过




图 5 分级后的轻雾和浓雾图像示例

Fig. 5 Examples of fog images after classification

多尺度特征提取模块和跳跃连接机制,使得能够更有效地恢复因严重遮挡而丢失的纹理信息。

这种针对解空间匹配网络的策略为后续的对比如学习和无监督微调提供了更优的特征表示,从而进一步提升了模型在不同雾气条件下的去雾性能。

2.2 训练过程

介绍基于分级对比学习的合成雾模型预训练策略以及基于循环一致性损失的尘雾无监督微调策略。

2.2.1 基于分级对比学习的合成雾模型预训练策略

在合成雾预训练阶段,首先通过雾气分级门控机制对输入图像进行雾气浓度划分,然后匹配对应的网络结构,网络输出的去雾图像作为锚点样本,其对应的薄雾和浓雾图像作为双重负样本,其过程如图 3(d) 所示。

在对比学习框架中,正样本和负样本的选择对于模型的训练至关重要。图 6 为薄雾和浓雾图像使用 t-SNE 方法^[25]后在低维特征空间的分布展示。t-SNE 为一种将高维的复杂数据降维为二维的算法,用于低维空间的可视化。可知,薄雾图像和浓雾图像在特征空间中存在一定的异质性,这表明它们具有不同的特征表示。

传统对比学习方法(图 7(a))将清晰图像与带雾图像作为正负样本进行训练,采用双元组损失函




图 6 薄雾与浓雾图像的低维特征可视化

Fig. 6 Visualization of low-dimensional features for light fog and dense fog images

数来进行约束,但这种方法未能充分考虑不同雾气浓度之间的差异,导致模型对不同雾气特征的区分和泛化能力不足,其计算如式(8)所示。

$$\ell_{\text{double}} = \sum_{i=1}^n \omega_i \frac{D(P_i, a_i)}{D(N_i, a_i)} \quad (8)$$

$$a_i = V_i[f(I_{\text{in}})]$$

$$P_i = V_i(I_{\text{gt}})$$

式中, $V_i(\cdot)$ 为使用 VGG19 提取的第 i 个隐藏特征; $D(\cdot)$ 为计算两个特征之间的 L_1 距离; ω_i 为权重系数,使得锚点特征与正样本拉近,脱离负样本。

为确保负样本的有效性,利用不同雾气浓度下图像的特征分布存在差异的特性,设置了相同场景

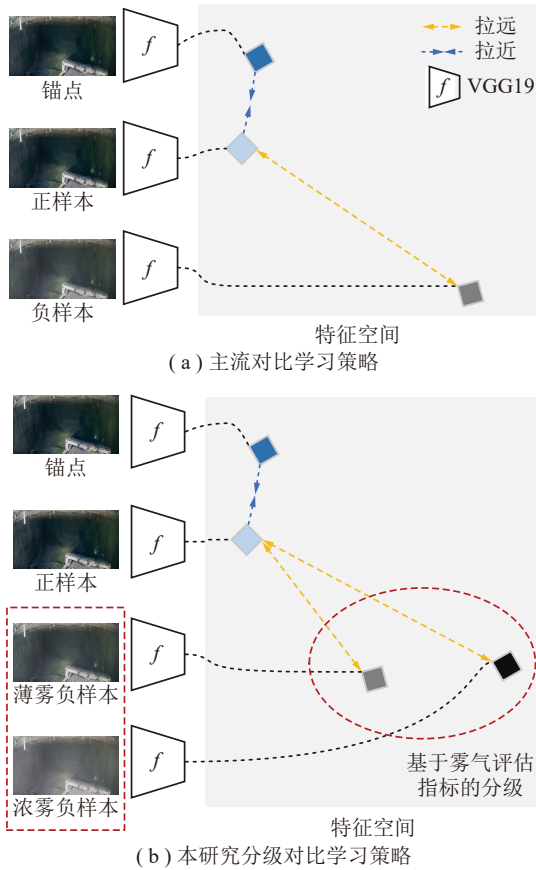


图7 分级对比学习机制

Fig. 7 Graded contrastive learning mechanism

下的轻雾图像和浓雾图像作为双重负样本, 帮助网络学习不同雾气的特征。图 7(b) 展示分级对比学习的机制, f 为特征提取器 VGG19^[26]。为了实现上述学习机制, 设计一种基于三元组损失的对比学习损失函数, 如式 (9) 所示。

$$\ell_{\text{Triple}} = \sum_{i=1}^n \alpha_i \frac{D(P_i, a_i)}{D(N_{\text{thin},i}, a_i)} + \sum_{i=1}^n \beta_i \frac{D(P_i, a_i)}{D(N_{\text{dense},i}, a_i)} + \sum_{i=1}^n \delta_i \frac{D(P_{\text{thin},i}, a_i)}{D(N_{\text{dense},i}, a_i)} \quad (9)$$

$$N_x = V_i(I_{\text{in}}^x)$$

式中, $I_{\text{in}}^{\text{thin}}$ 为薄雾图像; $I_{\text{in}}^{\text{dense}}$ 为浓雾图像; I_{gt} 为正样本图像; α_i 、 β_i 、 δ_i 为权重系数。

通过该损失函数, 使得恢复图像的特征 a 尽可能地接近清晰图像的特征 P , 同时尽可能地远离薄雾图像的特征 N_{thin} 和浓雾图像的特征 N_{dense} 。与四元组损失相比, 笔者三元组损失函数已将两类负样本显式纳入并通过权重配比调控梯度贡献, 兼顾计算代价与收敛稳定性。

笔者在预训练过程, 将待训练图像分类为薄雾与浓雾图像, 每个批的图像构成分类相同, 同时给

该批图像配置清晰图像、薄雾图像、浓雾图像这 3 张训练过程中需要的图像信息。

2.2.2 基于循环一致性损失的尘雾无监督微调策略

为解决合成雾与采掘工作面场景带雾图像在雾气域分布上的差异对去雾性能的影响, 提出无监督微调策略。其过程如图 3(e) 所示, 该策略利用大气散射模型实现基于循环一致性损失的无监督微调, 调整合成雾模型参数以获得真实尘雾图像域先验知识, 提升尘雾图像去雾的效果。

输入的尘雾图像 I_{in} 首先经过分级门控双分支框架进行处理, 生成去雾图像 I_{out} 。随后, 利用模型中的物理先验估计网络生成尘雾图像的物理信息, 即透射图 T_{est} 及大气光强度值 A_{est} , 如式 (10) 所示。

$$[I_{\text{out}}, A_{\text{est}}, T_{\text{est}}] = f_{\text{net}}(I_{\text{in}}), \text{net} \in \{\text{thin}, \text{dense}\} \quad (10)$$

使用大气散射模型对初步恢复的去雾图像进行加雾操作, 生成与输入测试图像对应的尘雾图像, 即伪标签图像 I_{pseudo} , 如式 (11) 所示。

$$I_{\text{pseudo}} = I_{\text{out}} \odot T_{\text{est}} + A_{\text{est}} \odot (1 - T_{\text{est}}) \quad (11)$$

为了约束模型的微调过程, 提出循环一致性损失函数 ℓ_{com} 来进一步提升去雾效果, 其计算方法如式 (12) 所示, 由深度先验损失 ℓ_{depth} 、加雾一致性损失 ℓ_{joint} 和无遗忘损失 ℓ_{forget} 等 3 部分组成。

$$\ell_{\text{com}} = \lambda_1 \ell_{\text{depth}} + \lambda_2 \ell_{\text{joint}} + \lambda_3 \ell_{\text{forget}} \quad (12)$$

式中, λ_i 为比例系数, $i = 1, 2, 3$ 。

深度先验损失 ℓ_{depth} 用于约束网络预测的加雾图像深度图与输入真实尘雾图像深度图的一致性, 提升深度信息的准确性, 深度图使用经典单目深度估计网络 MiDas^[27] 预测得到, 记为 Φ_{depth} , 对真实雾图像和伪标签图像分别提取深度图, 如式 (13) 所示。

$$\begin{cases} D = \Phi_{\text{depth}}(I_{\text{in}}) \\ \tilde{D} = \Phi_{\text{depth}}(I_{\text{pseudo}}) \end{cases} \quad (13)$$

深度先验损失计算方法如式 (14) 所示。

$$\ell_{\text{depth}} = \|\tilde{D} - D\|_1 + m \|\nabla_x \tilde{D} - \nabla_x D\|_2^2 + n \|\nabla_y \tilde{D} - \nabla_y D\|_2^2 \quad (14)$$

式中, $\|\cdot\|_1$ 为 L_1 损失; $\|\cdot\|_2^2$ 为 L_2 损失。

式 (14) 中第 1 项用于确保深度值的整体一致性, 第 2 项和第 3 项约束深度图在 x 和 y 方向的梯度变化, 以维持深度图的空间一致性。参数 m 和 n 用于平衡各项损失的权重。

加雾一致性损失 ℓ_{joint} 用来计算伪标签与输入的尘雾图像的 L_1 损失, 其计算如式 (15) 所示。

$$\ell_{\text{joint}} = \|I_{\text{in}}, I_{\text{pseudo}}\|_1 \quad (15)$$

无遗忘损失 ℓ_{forget} 为了避免灾难性遗忘, 对原始模型 M 进行拷贝得到 M_1 , 不对 M 模型进行反向传播, 通过对齐原始模型 M 与新模型 M_1 的输出, 来防止灾难性遗忘, 其计算方法如式(16)所示。

$$\ell_{\text{forget}} = \|M(I_{\text{in}}), M_1(I_{\text{in}})\|_1 \quad (16)$$

去雾网络与加雾过程通过循环一致性约束形成闭环优化机制, 当模型初始参数无法生成与原始尘雾图像匹配的伪标签图像时, 循环一致性损失将产生双向梯度信号: ①通过逆向加雾路径将梯度反传至物理先验估计模块, 校正物理参数估计偏差; ②梯度经去雾网络反传至特征提取层, 迫使网络学习能够学习到满足去雾结果合理性的特征表示。

3 试验分析

3.1 试验细节

笔者基于 Pytorch 框架实现, 使用 NVIDIA 3090 训练去雾网络。初始学习率设置为 8×10^{-4} , batchsize 设置为 16, epoch 设置为 1 000。训练时采用 256×256 的图像块, 性能评估时采用图像原尺寸, 不做裁切。

3.2 数据集及评价指标

在合成雾模型预训练阶段, 为验证所提模型的有效性, 试验选取公开数据集进行预训练和验证效果。选取真实尘雾图像用于评估采掘工作面场景的去雾效果。

3.2.1 合成雾数据集

该部分使用了 RESIDE 和 Haze4K^[28] 数据集, RESIDE 数据集中包含室内和室外场景。SOTS 作为该数据集的基准测试集, 用于评估模型在典型合

成雾条件下的去雾效果。

3.2.2 采掘工作面尘雾图像

图像采集自山东地区的 3 处采掘工作面, 分辨率 $1\,920 \times 1\,080$, 抽帧得到 2 000 张尘雾图像, 因为此为真实作业情景, 无法提供清晰图像, 计划公开一个包含 300 张代表性帧的小规模子集以供测试模型性能。在实际采掘工作面场景采集的真实尘雾图像, 该环境湿度高且粉尘质量浓度大, 图像出现严重的雾气和模糊现象, 能够有效检验模型在采掘工作面复杂环境下的去雾效果。

3.2.3 评价指标

在性能量化方面, 采用全参考评价指标 PSNR 和 SSIM。PSNR 值越高代表像素级恢复质量越优, SSIM 值趋近 1 则表示亮度、对比度及结构信息的还原度更佳。

F 指标为笔者提出的雾气衡量指标, 用于表示图像中的雾气浓度。考虑到矿井图像缺乏参考图像的实际情况, 试验还额外引入两种无参考评价指标: NIQE^[29] 和 BRISQUE^[30]。NIQE 通过分析图像统计特征评估其与自然图像的偏离程度, 数值越低表明视觉自然度越高; BRISQUE 基于空间域特征量化图像清晰度与纹理完整性, 分值低表征更优的视觉质量。

3.3 预训练模型效果

3.3.1 使用 RESIDE 合成雾数据集预训练效果

表 1 展示了预训练模型与代表性对照方法在 SOTS 室内与室外场景上的性能对比结果, 其中最佳结果以加粗表示。PSNR 和 SSIM 指标在室内外分别达到了 41.14、0.996 和 37.03、0.994 的性能, 均取得去雾最佳效果, 充分证明了所提预训练模型具

表 1 预训练模型在 SOTS-Indoor、SOTS-Outdoor 数据集效果对比

Table 1 Comparison of pre-trained model performance on the SOTS-Indoor and SOTS-Outdoor datasets

Method	Year	SOTS-Indoor		SOTS-Outdoor		Overhead	
		PSNR/dB	SSIM	PSNR/dB	SSIM	Params/M	FLOPs/G
Maxim ^[31]	2022	38.11	0.991	34.19	0.985	14.1	216
PMNet ^[32]	2021	38.41	0.99	34.74	0.985	18.9	81.13
DehazeFormer-M ^[33]	2023	38.46	0.994	34.29	0.983	4.634	28.64
TUSR-Net ^[34]	2023	38.67	0.991	—	—	5.62	—
SDBAD-Net ^[35]	2023	37.87	0.988	34.33	0.981	2.23	11.51
WSAMF-Net ^[36]	2023	38.65	0.993	—	—	5.58	—
DFR-Net ^[37]	2024	—	—	35.34	0.993	42.11	286.6
DEA-Net ^[38]	2024	40.2	0.993	36.03	0.989	3.653	32.23
笔者方法	2025	41.14	0.996	37.03	0.994	4.022	8.25

有良好的基础性能。

由图 8(a) 可知, 笔者在细节恢复和颜色校正方面表现出色, 更好地恢复了门框的边缘和纹理细节。图 8(b) 为在 SOTS-Outdoor 数据集上去雾结果应用阈值后的二值差异图, 白色部分表示差异大于阈值

的部分。在对比中, 其他方法所恢复的图像整体较为模糊, 细节处理不够精细, 难以准确还原原始图像中的细节信息。表明本预训练模型不仅能够有效去除雾气, 还在保持图像细节和结构方面具有优势, 能够为接下来的无监督微调提供良好的基础。

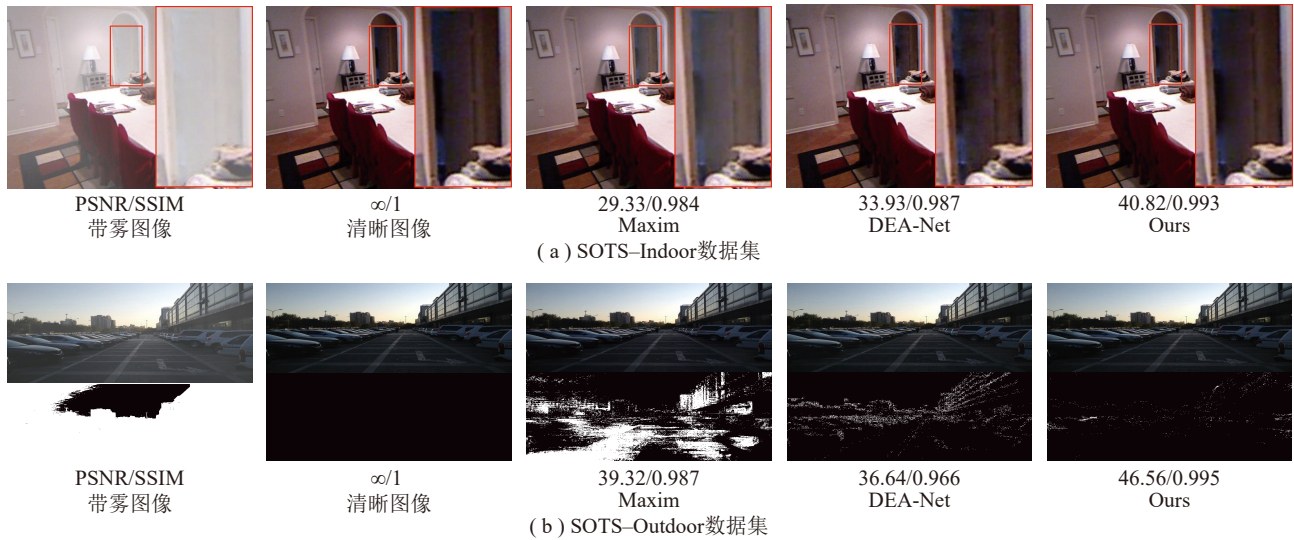


图 8 预训练模型在 SOTS-Indoor、SOTS-Outdoor 数据集效果对比

Fig. 8 Comparison of pre-trained model performance on the SOTS-Indoor and SOTS-Outdoor datasets

3.3.2 使用 Haze4K 合成雾数据集预训练效果

为进一步验证所提预训练模型的有效性, 笔者将进一步使用 Haze4K 数据集进行训练与测试。表 2 结果显示本方法在这两项指标上均超过多种代表性对照方法, 充分证明预训练模型的优越性, 其中最佳结果以加粗表示, 次优结果以下划线标注, 下同。

3.4 无监督微调尘雾图像去雾效果

为适应采掘工作面复杂环境中的图像退化问题, 笔者在合成雾预训练模型的基础上, 利用真实

表 2 在 Haze4K 数据集评估对比

Table 2 Comparison on the Haze4K dataset (best results in bold, and second-best results underlined)

Method	PMNet ^[32]	DEA-Net ^[38]	ConvIR-S ^[39]	EENet ^[40]	笔者方法
Year	2021	2024	2024	2025	2025
PSNR	33.49	33.19	33.36	<u>33.73</u>	34.50
SSIM	<u>0.980</u>	0.990	0.990	0.990	0.990

尘雾图像对模型进行无监督微调, 以缓解合成-尘雾图像之间的域间差异。表 3 则从多个无参考指标对各方法进行了定量评估, 图 9 展示了不同方法

表 3 采掘工作面场景去雾算法对比

Table 3 Comparison of dehazing algorithms for working face scenes

测量图像	评价指标	Hazy	ZHU 等 ^[9]	DANA 等 ^[8]	DAD ^[41]	SSLD ^[42]	笔者方法
I	$F\downarrow$	0.302	0.083	0.270	0.296	0.325	<u>0.255</u>
	NIQE \downarrow	2.971	5.439	3.631	<u>2.896</u>	2.938	2.774
	BRISQUE \downarrow	27.353	50.336	29.779	<u>28.653</u>	29.362	26.217
II	$F\downarrow$	0.391	0.219	0.367	0.385	0.396	<u>0.365</u>
	NIQE \downarrow	3.577	5.695	3.949	3.021	3.526	<u>3.447</u>
	BRISQUE \downarrow	23.717	39.441	31.174	24.236	25.689	<u>24.377</u>
III	$F\downarrow$	0.302	0.095	<u>0.178</u>	0.236	0.196	0.247
	NIQE \downarrow	3.099	4.456	2.962	2.964	<u>2.924</u>	2.899
	BRISQUE \downarrow	32.033	60.381	30.437	29.362	<u>28.996</u>	28.656



图9 采掘工作面尘雾图像去雾效果可视化对比

Fig. 9 Visual comparison of dehazing results for working face dust and fog images

在采掘工作面场景图像去雾任务中的可视化效果。

表3列出了各方法在3幅真实尘雾图像上的去雾评估结果。由表3可知, F 值在笔者方法处理后明显降低, 表明模型能够有效削弱图像中的残留雾气。此外, 在NIQE与BRISQUE两个指标上, 笔者方法也取得了最优的表现, 说明其在图像清晰度、纹理结构及视觉质量方面具有明显优势。

图9中, ZHU等方法虽在 F 指标上表现最优, 但整体图像偏暗, 遗失较多场景信息。DANA等方法恢复效果较为均衡, 但图像色彩恢复不足。相比之下, 笔者方法在3幅图像上均实现了较好的可视化效果, 图像细节更加丰富、边缘轮廓清晰, 色彩还原良好, 显示出较强的鲁棒性与适应性。

综上所述, 笔者方法在真实采掘工作面尘雾图像上的去雾效果具备良好的适应性与稳定性, 能有

效提升图像的可视化质量, 满足煤矿安全监控中对图像清晰度的实际需求。

3.5 计算开销对比

在分级门控双分支框架中, 提升推理效率是关键考量之一。该机制依据输入图像的雾气浓度, 将其匹配轻量或复杂网络结构, 实现推理计算的自适应优化。具体而言, 对于薄雾图像, 通过分配轻量网络进行推理, 使得单张图像的平均推理时间从0.027 s降至0.017 s, 推理耗时减少约37%, 提升了整体处理效率。

3.6 消融试验

本节为验证分级门控双分支框架与分级对比学习策略在预训练模型中的作用, 设计了一系列消融试验。表4汇总了各消融配置的结果, 为更科学地评估模型性能, 将子网络的测试结果也作展示,

表4 消融试验结果展示

Table 4 Ablation experiment results

项目	Baseline		A		B		
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	
模块配置	分级门控双分支框架		√		√		
	分级对比学习				√		
Indoor	轻量模型推理薄雾图像	37.53	0.988	38.46	0.990	41.14	0.990
	复杂模型推理浓雾图像	39.56	0.995	39.99	0.995	41.14	0.996
	整体效果	39.32	0.994	39.82	0.994	41.14	0.995
Outdoor	轻量模型推理薄雾图像	33.21	0.977	35.83	0.992	42.47	0.996
	复杂模型推理浓雾图像	33.56	0.989	35.67	0.991	36.61	0.993
	整体效果	33.54	0.988	35.75	0.991	37.03	0.994

同时展示“整体效果”代表模型在整个测试集上的推理表现。

笔者在 Baseline 模型的基础上引入了分级门控双分支框架。与 Baseline 模型相比, 模型在室内数据集的 PSNR 提升了 0.50 dB; 在室外数据集的 PSNR 提升了 2.21 dB、SSIM 提升 0.003, 这表明分级门控双分支框架能够根据不同雾气浓度自适应地分配合适的网络结构, 帮助模型更好地应对轻雾与浓雾图像, 从而实现更高的去雾质量。

进一步引入分级对比学习策略后, 室内数据集的 PSNR 指标提高 1.32 dB、SSIM 提高 0.001; 室外数据集的 PSNR 提高 1.28 dB、SSIM 提高 0.003。可知, 分级对比学习策略能够利用同一场景下不同雾气浓度图像的差异信息, 学习到更具判别性的特征表示, 进一步增强了去雾能力。当雾气分级机制与分级对比学习策略结合使用时, 模型最终在 PSNR 与 SSIM 指标上均获得最高提升, 说明这两个模块之间具有较强的互补性, 能够在不同程度的雾气场景下协同提升去雾效果。

3.7 无监督微调策略的有效性分析

为验证无监督微调策略的有效性, 使用了采掘工作面尘雾图像进行系统验证, 其结果见表 5。

表 5 展示了在采掘工作面场景下, 无监督微调前后 F 指标、NIQE 和 BRISQUE 等 3 项评价指标的对比。结果表明, 3 项指标均显示去雾性能有所提升。未进行无监督微调时, 由于训练所使用的合成

表 5 无监督微调有效性分析

Table 5 Analysis of unsupervised fine-tuning effectiveness

项目	$F\downarrow$	NIQE \downarrow	BRISQUE \downarrow
无监督微调前	0.308	3.157	29.366
无监督微调后-移除深度先验	0.254	3.105	29.089
无监督微调后-使用深度先验	0.251	3.082	29.103

雾图像与测试中的真实雾图像存在显著的域间差异, 模型在实际场景中的去雾效果较差。

图 10 为预训练模型无监督微调前后效果对比, 可见, 微调前的结果表现为色彩饱和度不足, 细节模糊。相比之下, 微调后的图像色彩还原效果明显提升, 高频细节恢复效果也得到了加强。此外, 雾度评价指标在微调后普遍下降, 表明去雾后的图像雾气浓度降低, 视觉效果明显改善。同时, 可以得到在无监督微调的过程中, 加入深度先验后在 NIQE 与 F 指标上进一步提升, 验证了深度估计信息在指导图像结构恢复方面的积极作用。加入先验与否对 BRISQUE 的差异较小, 表明该主观质量指标对深度先验并不敏感。在具体实现中, 选择 MiDaS 作为深度先验模型, 原因在于其在单目深度估计任务中具有良好的跨场景泛化性能, 并且已在大量图像复原与去雾相关研究中被采用作为基准先验, 减少模型选择的随意性, 确保试验结果具有可比性和可重复性。

这一结果表明, 通过引入无监督微调策略, 模




图 10 预训练模型无监督微调前后效果对比

Fig. 10 Comparison of pre-trained model performance before and after unsupervised fine-tuning

型能够根据采掘工作面尘雾图像的分布特征调整网络参数, 缓解由合成雾到尘雾的域间差异问题,

进一步验证了该方法在采掘工作面实际环境中的有效性和鲁棒性。

4 结 语

面向采掘工作面复杂的雾气场景, 提出了一种基于雾气分级与域间差异的尘雾图像去雾方法, 融合了分级门控双分支框架、分级对比学习策略和无监督微调策略, 构建出多阶段去雾模型。分级门控双分支框架根据雾气浓度自适应切换子网络, 实现了对轻雾场景的高效去雾以及对浓雾场景的深度去雾; 分级对比学习策略通过对不同雾气浓度下图像的负样本进行精细化选取, 增强了模型对不同雾气特征的区分能力和跨域泛化表现; 无监督微调策略利用循环一致性损失, 无需参考清晰图像即可有效校正去雾映射函数。试验结果表明, 该方法在采掘工作面图像上均取得了优于现有主流方法的去雾效果。该研究成果可应用于采掘工作面的视频监控, 提高复杂恶劣环境下监控图像的清晰度, 为智能监控和安全生产提供可靠保障。

参考文献 (References):

- [1] 赵猛, 任志浩, 褚海峰, 等. 基于大气散射模型的采煤工作面尘雾图像清晰化算法[J]. 煤炭学报, 2023, 48(8): 3312–3322.
ZHAO Meng, REN Zhihao, CHU Haifeng, et al. Dust and fog image-sharpening algorithm based on atmospheric scattering model in coal face[J]. Journal of China Coal Society, 2023, 48(8): 3312–3322.
- [2] 张旭辉, 解彦彬, 杨文娟, 等. 煤矿井下采掘工作场景非均质图像去雾与增强技术[J]. 煤田地质与勘探, 2025, 53(1): 245–256.
ZHANG Xuhui, XIE Yanbin, YANG Wenjuan, et al. A dehazing and enhancement algorithm for heterogeneous images of underground mining environments in coal mines[J]. Coal Geology & Exploration, 2025, 53(1): 245–256.
- [3] 寇旗旗, 汪鹏, 崔文, 等. 矿井复杂环境下低质图像超分辨率重建关键技术及研究展望[J]. 煤炭学报, 2025, 51(2): 1757–1786.
KOU Qiqi, WANG Peng, CUI Wen, et al. Key technology and research outlook for super-resolution reconstruction of low-quality images in complex mine environments[J]. Journal of China Coal Society, 2025, 51(2): 1757–1786.
- [4] DINGWEN Z, WWENYUAN Z, JIERU Y, et al. Weakly supervised object detection using proposal and semantic-level relationships[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 44(6): 3349–3363.
- [5] 张斌, 苏学贵, 段振雄, 等. YOLOv2 在煤岩智能识别与定位中的应用研究[J]. 采矿与岩层控制工程学报, 2020, 2(2): 026531.
ZHANG Bin, SU Xuegui, DUAN Zhenxiong, et al. Application of YOLOv2 in intelligent recognition and location of coal and rock[J]. Journal of Mining and Strata Control Engineering, 2020, 2(2): 026531.
- [6] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[A]. 2009 IEEE Conference on Computer Vision and Pattern Recognition[C]. 2009: 1956–1963.
- [7] RAANAN, FATTAL. Dehazing using color-lines[J]. ACM Transactions on Graphics, 2014, 34(1): 1–14.
- [8] BERMAN D, TREIBITZ T, AVITAN S. Non-local image dehazing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2016: 1674–1682.
- [9] ZHU Q S, MAI J M, SHAO L. A fast single image haze removal algorithm using color attenuation prior[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3522–3533.
- [10] LIU J, LIU R W, SUN J N, et al. Rank-one prior: real-time scene recovery[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(7): 8845–8860.
- [11] 宁贝, 杨明. 基于多尺度引导滤波的实时视频去雾算法[J]. 中北大学学报 (自然科学版), 2024, 45(4): 439–447.
NING Bei, YANG Ming. Real time video defogging algorithm based on multi-scale guided filtering[J]. Journal of North University of China (Natural Science Edition), 2024, 45(4): 439–447.
- [12] TAREL J P, NICOLAS H. Fast visibility restoration from a single color or gray level image[A]. IEEE International Conference on Computer Vision[C]. 2010: 2201–2208.
- [13] FATTAL R. Single image dehazing[J]. ACM Transactions on Graphics, 2008, 27(3): 253–268.
- [14] CAI B, XU X M, JIA K, et al. DehazeNet: an end-to-end system for single image haze removal[J]. IEEE Transactions on Image Processing, 2016, 25(11): 5187–5198.
- [15] REN W Q, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks[A]. European Conference on Computer Vision[C]. 2016: 154–169.
- [16] 樊红卫, 张超, 曹现刚, 等. 一种基于暗亮通道分割融合的低照度环境图像去尘雾及增强方法[J]. 煤炭学报, 2024, 49(4): 2167–2178.
FAN Hongwei, ZHANG Chao, CAO Xiangang, et al. An imagedust removal and enhancement method in low illumination environment based on dark-bright channel segmentation and fusion[J]. Journal of China Coal Society, 2024, 49(4): 2167–2178.
- [17] 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(S1): 17–24.
- ZHAO Meng, WEI Yuzhong, LI Zheng, et al. Dehazing algorithm for coal mining face dust and fog images based on a semi-supervised network[J]. Coal Science and Technology, 2025, 53(S1): 17–24.
- [18] WU H Y, QU Y Y, LIN S H, et al. Contrastive learning for compact single image dehazing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2021: 10546–10555.
- [19] LIU X N, LI H, ZHU C. Joint contrast enhancement and exposure fusion for real-world image dehazing[J]. IEEE Transactions on Multimedia, 2021, 24: 3934–3946.
- [20] ZHENG Y, ZHAN J H, HE S F, et al. Curricular contrastive regularization for physics-aware single image dehazing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2023: 5785–5794.
- [21] WANG Y Z, YAN X F, WANG F L, et al. UCL–Dehaze: towards real-world image dehazing via unsupervised contrastive learning[J]. IEEE Transactions on Image Processing, 2024, 33: 1361–1374.
- [22] SONG Y D, ZHOU Y, QIAN H, et al. Rethinking performance gains in image dehazing networks[Z/OL]. DOI: 10.48550/arXiv.2209.11448.
- [23] CHEN Z, WANG Y, YANG Y, et al. PSD: principled synthetic-to-real dehazing guided by physical priors[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2021: 7176–7185.
- [24] LI B Y, REN W Q, FU D P, et al. Benchmarking single image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2019, 28(1): 492–505.
- [25] LAURENS V D M, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579–2605.
- [26] NAH S, KIM H T, LEE M K. Deep multi-scale convolutional neural network for dynamic scene deblurring[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2017: 257–265.
- [27] RANFTL R, LASINGER K, HAFNER D, et al. Towards robust monocular depth estimation: mixing datasets for zero-shot cross-dataset transfer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(3): 1623–1637.
- [28] ZHANG Z, JIA X. 4K–HAZE: a dehazing benchmark with 4 k resolution hazy and haze-free images[Z/OL]. DOI: 10.48550/arXiv.2303.15848.
- [29] MITTAL A, SOUNDARARAJAN R, C. BOVIK A. Making a "completely blind" image quality analyzer[J]. IEEE Signal Processing Letters, 2012, 20(3): 209–212.
- [30] MITTAL A, MOORTHY A K, BOVIK A C. No-reference image quality assessment in the spatial domain[J]. IEEE Transactions on Image Processing, 2012, 21(12): 4695–4708.
- [31] TU Z H, TALEBI H, ZHANG H, et al. MAXIM: multi-axis mlp for image processing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2022: 5759–5770.
- [32] YE T, JIANG M C, ZHANG Y C, et al. Perceiving and modeling density is all you need for image dehazing[Z/OL]. DOI: 10.48550/ArXiv.2111.09733.
- [33] SONG Y D, HE Z Q, QIAN H, et al. Vision transformers for single image dehazing[J]. IEEE Transactions on Image Processing, 2023, 32: 1927–1941.
- [34] SONG X B, ZHOU D F, LI W, et al. TUSR–Net: triple unfolding single image dehazing with self-regularization and dual feature to pixel attention[J]. IEEE Transactions on Image Processing, 2023, 32: 1231–1244.
- [35] ZHANG G Q, FANG W X, ZHENG Y H, et al. Sdbad-net: a spatial duabranh attention dehazing network based on meta-former paradigm[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 34(1): 60–70.
- [36] SONG X B, ZHOU D F, LI W, et al. Wsamf-net: wavelet spatial attention-based multistream feedback network for single image dehazing[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(2): 575–588.
- [37] WANG Z Z, ZHAO H T, YAO L J, et al. DFR–Net: density feature refinement network for image dehazing utilizing haze density Difference[J]. IEEE Transactions on Multimedia, 2024, 26: 7673–7686.
- [38] CHEN Z X, HE Z W, LU Z M. DEA–Net: single image dehazing based on detail-enhanced convolution and content-guided attention[J]. IEEE Transactions on Image Processing, 2024, 33: 1002–1015.
- [39] CUI Y N, REN W Q, CAO X C, et al. Revitalizing convolutional network for image restoration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 9423–9438.
- [40] CUI Y N, WANG Q, LI C P, et al. EENet: an effective and efficient network for single image dehazing[J]. Pattern Recognition, 2025, 158: 111074.
- [41] SHAO Y, LI L, REN W, et al. Domain adaptation for image dehazing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. 2020: 2808–2817.
- [42] LI L, DONG Y L, REN W Q, et al. Semi-supervised image dehazing[J]. IEEE Transactions on Image Processing, 2023, 29: 2766–2779.