

基于LEDNet的露天矿监控低光照图像增强模型

郭鸣翔¹, 赵文博¹, 袁启彤¹, 侯豆豆², 吴旭楚^{3*}

¹中联润世新疆煤业有限公司, 新疆 昌吉

²太原(钢铁)集团有限责任公司矿业分公司尖山铁矿, 山西 太原

³中国矿业大学(北京)能源与矿业学院, 北京

收稿日期: 2024年8月7日; 录用日期: 2024年9月2日; 发布日期: 2024年10月18日

摘要

露天矿监控视频常受到图像严重退化造成的影响, 图像退化起因包括防爆要求对监控设备性能的限制、矿区内大型设备和建筑物的遮挡, 以及生产作业多在夜间进行导致的光照不足等。这些因素共同导致监控图像出现噪点多、分辨率低、照度不足, 影响图像的清晰度和可见度, 从而对生产调度和安全监控产生负面影响。为解决这一问题, 本研究引入了一个针对露天矿监控视频特有退化问题的高效图像恢复技术。开发了一个新颖的模拟露天矿监控视频退化流程, 专门模拟露天矿环境中的光照不足和遮挡造成的图像退化情况, 包括针对夜间低光照和防爆限制下的图像质量改善。在此基础上, 构建了一个大规模数据集, 提出了LEDNet深度学习网络, 该网络专为联合提升低光照图像的亮度和清晰度而设计, 考虑到了低光照增强和去模糊任务之间的相互作用。通过这一创新方法, 不仅显著提高了露天矿监控图像的质量, 而且为在恶劣环境下提高监控系统性能提供了有效途径, 这对于提高生产效率和确保作业安全具有重要意义。大量实验证明, 本文方法在处理真实露天矿监控视频中的图像时表现出色, 有效地提升了图像的可见度和清晰度。

关键词

露天矿监控, 图像恢复, 低照度增强, 去模糊, 安全生产

A Low-Light Image Enhancement Model for Open-Pit Mine Monitoring Based on LEDNet

Mingxiang Guo¹, Wenbo Zhao¹, Qitong Yuan¹, Doudou Hou², Xuchu Wu^{3*}

¹Zhonglian Runshi Xinjiang Coal Industry Co., Ltd., Changji Xinjiang

²Jianshan Iron Ore Mine of Taiyuan Iron & Steel (Group) Co., Ltd. Mining Branch, Taiyuan Shanxi

³School of Energy and Mining Engineering, China University of Mining and Technology (Beijing), Beijing

*通讯作者。

文章引用: 郭鸣翔, 赵文博, 袁启彤, 侯豆豆, 吴旭楚. 基于 LEDNet 的露天矿监控低光照图像增强模型[J]. 矿山工程, 2024, 12(4): 824-832. DOI: 10.12677/me.2024.124097

Abstract

Open-pit mine monitoring videos are often severely affected by image degradation, mainly due to the limitations on monitoring equipment performance imposed by explosion-proof requirements, the obstruction by large equipment and structures within the mining area, and inadequate lighting caused by nighttime operations. These factors collectively lead to noisy images, low resolution, and insufficient illumination, which affect the clarity and visibility of the images, thereby negatively impacting production scheduling and worker safety monitoring. To address this issue, this study introduced an efficient image restoration technique specifically tailored to the degradation problems unique to open-pit mine monitoring videos. A novel simulation of the degradation process in open-pit mine monitoring videos was developed, designed to replicate image degradation scenarios caused by low light and obstructions typical in the mining environment, including image quality improvements under low-light conditions and explosion-proof constraints. Based on this, a large-scale dataset was constructed, and a deep learning network named LEDNet was proposed. The network was specifically designed to jointly enhance the brightness and clarity of low-light images, taking into account the interaction between low-light enhancement and deblurring tasks. This innovative approach not only significantly improves the quality of open-pit mine monitoring images but also provides an effective means to enhance the performance of monitoring systems in harsh environments, which is of great significance for improving production efficiency and ensuring operational safety. Extensive experiments demonstrate that the method performs excellently in processing images in real open-pit mine monitoring videos, effectively enhancing image visibility and clarity.

Keywords

Open-Pit Mine Monitoring, Image Restoration, Low Light Enhancement, Deblurring, Safety Production

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

露天矿区的生产作业班组通常是在夜间工作，但夜间监控面临着图像质量退化的显著问题。导致图像质量退化的原因一方面是由于低光照条件下的不足，另一方面是摄像设备为了满足防爆标准而牺牲的性能。这种图像质量退化不仅包括光照不足造成的图像可见度降低，同样包括生产过程中的震动造成的运动模糊。这两种因素的叠加造成了露天煤矿监控图像的严重退化。

葛军超[1]等人的研究发现，井下瓦斯、粉尘和照度不足等复杂环境因素会导致井下图像质量下降，图像变暗且模糊，无法清晰观察到图像中的细节。为了解决这一问题，他们提出了一种基于自适应 Retinex 算法的解决方案，结合使用 Unet 网络提取多尺度图像特征，从而恢复图像质量。苗作华[2]团队在研究中发现，随着井工开采逐渐进入深部开采阶段，巷道内存在光照不均且开采过程中尘雾飞扬等现象，导致巷道中的图像对比度低、细节不清晰等问题。针对这些问题，该研究团队提出了一种基于 CLAHE-PCA 的图像增强算法。该算法能够有效优化处理后图像的对比度和亮度，使其相比处理前的图像有明显改善，从而大大提高了井下作业的安全性。Wei Yang 等人[3]的研究聚焦于提升煤矿井下人员安全监控的图像质

量与检测精度。研究团队发现, 由于井下光照不足, 传统的监控图像往往存在识别困难和检测精度低的问题。为此, 他们提出了一种创新的低照度图像增强方法。该方法采用了自适应增强策略, 包括一个本地增强模块和一个基于 Transformer 的全局调整模块。通过本地增强模块, 该方法能够在像素级别上将低照度映射为正常照度, 尽可能保留图像的细节。而全局调整模块则用于防止亮区的过度增强和暗区的照度不足, 同时避免色彩偏差。此外, 为确保图像增强不会对人员检测产生负面影响, 研究团队还引入了特征相似性损失, 来维持目标特征的一致性。

在现有的方法中, 大多数是独立处理低光照增强和图像去模糊这两个问题, 而没有考虑到它们之间的相互作用和共同退化现象。大多数方法主要通过提高亮度和去噪来改善图像, 但往往忽略了由运动引起的空间退化问题, 特别是在过曝的区域中, 增强后的图像可能会因为模糊而变得更加模糊。此外, 过度平滑的去噪过程有可能移除对去模糊有用的高频信息。大多数的去模糊方法大多基于仅包含白天场景的数据集训练, 难以直接应用于夜间图像去模糊任务, 因为暗区域中的运动线索不易察觉, 加之夜间模糊图像中的饱和区域与白天数据学习的模糊模型不吻合, 使得这些方法在夜间图像上的效果大打折扣[4]。

为了解决这些问题, 特别是在露天矿这种特殊环境下的图像增强需求, 提出了一个新型的数据合成流程, 专门模拟低光照和运动模糊共存的场景; 通过结合露天矿监控的特定需求, 设计了一种新的模糊模拟方法, 着重模拟饱和区域的模糊, 以更真实地反映夜间图像的特点; 进而提出了一个统一的网络架构 Low-light Enhancement and Deblurring Network (LEDNet), 该网络旨在联合处理低光照增强和去模糊任务, 通过一个专门的编码器对图像中的模糊及低照度部分进行评估及信息压缩拆分, 和一个解码器对模糊及低照度信息进行处理, 二者通过多尺度特征融合相连, 确保了增强的光照特征能有效用于去模糊[4]-[6]。

2. 图像增强算法

在图像去模糊方面, 随着专门的训练数据集的开发, 无核的端到端网络成为了主流方法, 其能够有效处理由于摄像机抖动或场景动态变化导致的模糊问题。尤其是多尺度策略和无下采样的层次结构被广泛采用来应对大模糊, 而基于 GAN 的方法则旨在增强图像细节。为了更好地处理空间变化模糊, 提出了空间变化 RNN 和滤波自适应卷积(FAC)层, 这些方法为动态处理非均匀模糊提供了新的途径。

在低光照增强领域, 深度学习网络已经成为推动技术进步的主要力量。早期的 LL-Net 通过自编码器学习去噪和光照增强, 而后续研究则基于 Retinex [7]-[9]理论, 通过分解图像为反射和照明图来独立处理, 进而提高图像的整体亮度和清晰度。此外, 还探索了无监督学习方法, 如 EnlightenGAN 和 Zero-DCE, 这些方法通过灵活的训练策略能够在没有成对训练数据的情况下进行光照调整, 提高了方法的泛化能力[10][11]。

虽然低光照增强和去模糊通常被视为两个独立的任务, 但在实际应用中, 这两个问题往往是相互关联的, 特别是在动态场景和低光照条件下拍摄的图像中。因此, 结合这两项技术的研究具有重要意义。在神经网络的发展过程中, 残差网络的出现, 解决了因为网络结构过深而出现的特性特征丢失问题[12]-[15]。这种问题在图像处理领域就表现为, 图像中物体的细节丢失, 边缘模糊, 经过神经网络处理后的图像, 尽管在亮度上已经出现了明细的改善, 但是在物体的边缘上出现了大量的模糊。而残差网络的出现, 能够将神经网络浅层的信息传递给网络的深部, 在一定程度上避免了特性信息丢失的问题。受到残差网络的启发, LEDNet 采用了残差网络的信息交流能力, 在去模糊和图像增强的编码结构中, 引入了类残差的结构, 使得两种功能的编码结构在联合处理上实现了可能。

随着 Diffusion Model 和 Transformer 大模型的发展, 给出了图像增强及去模糊联合处理的解决思路。Diffusion Model 和 Transformer 展现出了极强的表达能力。Diffusion Model 的图像处理方法主要通过在前

向传播的过程中添加多轮高斯噪音，将图像转化为纯高斯噪声图，其反向传播则是通过减少高斯噪声，并对减后的部分进行微分，调整模型参数，从而生成图像。而 Transformer 的主要发展方向是不断提高模型的表达能力，并非生产式网络[16]。Transformer 的核心结构是自注意力模型，基本单元包括 Q、K、V 三个向量矩阵。这三个矩阵的设计灵感来源于信息检索，其中 Q 代表查询，其目的是向 K 提供一个关系查找的指令，K 中则记录着所有 token 之间的关系。Q 与 K 的矩阵相乘实际上代表了所需检索的向量与其他向量之间的关系，即注意力程度。QK 的结果与 V 相乘后，便得到了最终的注意力输出。通过 QKV 三个矩阵，不同 token 之间的关系被显式地分类、查询和表达，从而获得非常强大的泛化能力。这两种方法在露天矿环境下的监控图像退化处理同样能实现图像增强及去模糊联合处理的目的，但是在数据的真实性方面，Diffusion Model 不及 Transformer 大模型。

3. 基于 LEDNet 的图像增强模型

3.1. 数据集准备

数据集的准备主要分为，训练数据集，以及验证数据集。其都是来自于 GoPro 相机拍摄拍摄的高帧率高清视频，及矿区监控系统拍摄的真实视频。

首先，在露天矿区的不同位置 and 不同时间段，特别是在放煤期间，使用 GoPro 相机拍摄了一系列高帧率的视频。这些视频能够反应在放煤过程中的具体场景。同时，还收集了矿区监控系统在夜间光照不足条件下记录的低质量视频，这些视频进一步补充了的数据集，确保了数据的多样性和真实性。

通过这些步骤，共获得了一定数量的视频用于训练和测试。每个视频包含多帧，通过这些连续的帧，能够模拟不同程度的放煤，而产生的视觉退化，如尘雾遮挡造成的亮度降低，以及放煤过程中的大量震动造成的图像模糊。与现有方法相比，采用的数据收集策略更加贴近露天矿实际工作环境，能够更真实地反映该环境下所面临的图像退化问题。

在数据集的制作阶段，LEDNet 选取放煤过程中的图像质量最好的帧作为标签图像。选取连续的图像帧，并进行进一步退化，作为原始图像。因标签图像及原始图像在时间尺度上距离极近，因此可以组成图像对。原始处理如下。

$$B = g \left(\frac{1}{T} \sum_{i=0}^{T-1} S_i \right) = g \left(\frac{1}{T} \sum_{i=0}^{T-1} \hat{s}_i g^{-1} \right) \quad (1)$$

其中：B 表示生成的模糊图像；T 是被平均的帧数； $\hat{s}_i$ 是观测到的 sRGB 图像序列的第 i 帧；g() 是相机响应函数用于将潜在的信号 s_i 映射到观测到的 sRGB 图像 $\hat{s}_i$ 中； $g^{-1}()$ 是 g() 的逆函数，用于从 sRGB 图像中恢复原始的潜在信号。

原始图像并且经过伽马变换模拟夜间的环境，其变换公式如下：

$$I_{out} = c I_{in}^\gamma \quad (2)$$

其中： I_{out} 为处理后的图像；c 为常数系数； I_{in} 为模糊处理后的图像。

最终，成功构建了一个包含多种动态场景、不同尘雾浓度和光照条件下的数据集。

3.2. 网络结构

在处理露天矿监控中捕获的低质量照片时，面对的主要挑战包括由于光照不足产生的图像低照度现象，以及由于监控设备固有性能限制和环境因素(如风吹或设备振动)引起的图像模糊。这些因素导致从露天矿监控系统获得的图像往往存在可见性差和纹理细节丢失的问题，进而影响了监控效果和后续分析的准确性。

为了有效改善监控视频中的低质量问题, 本文提出了一种名为 Low-light Enhancement and Deblurring Network (LEDNet) 的统一网络架构。这是一个专为联合处理低光照增强和去模糊设计的 Transformer 网络结构。LEDNet 的主体包括一个编码器和一个解码器, 其基本结构为轴向 Transformer 块。编码器和解码器通过多尺度特征融合块, 将不同尺度地特征, 通过重要性的不同有选择地融合在一起, 其目的是对图像模糊的特征进行一个丢弃, 让编码和解码阶段有用特征得以保留。并且 LEDNet 在中间加入中间监督层, 将 8 倍下采样的图像和监督图像的 8 倍下采的图进行损失计算, 其目的是在编码阶段对图像的照度进行恢复, 以便在之后解码阶段能够跟容易的对图像模糊进行去除。

LEDNet 中的轴向 Transformer 块结构是一种小型化的 Transformer 结构, 它通过将图像张量信息分别投影到两个正交的维度(水平和垂直方向), 有效地降低了信息处理的复杂性。这种方法不仅保留了 Transformer 结构强大的表达能力, 还能够充分利用图像的二维特性, 使得模型在处理图像时更加高效。

LEDNet 网络结构如图 1 所示:




Figure 1. Network architecture diagram

图 1. 网络结构图

3.2.1. 轴向 Transformer 结构

在图一中红色块部分代表最基础的 Transformer 单元, 因为 Transformer 网络的规模很大, 如果采用将所以像素展开, 从而建立自注意力关系, 那么网络的大小是随着像素的数量几何倍数增加的。LEDNet 基本为轴向 Transformer 块结构, 基本的轴向 Transformer 块结构是一种针对图像处理的小型 Transformer 结构, 它不仅保留了 Transformer 结构强大的表达能力, 而且通过将张量信息分别投影到水平和竖直两个正交方向上, 有效降低了信息处理的复杂性。这种方法的核心优势在于, 图像的像素本质上是二维的, 将注意力结构同样投影到二维空间, 能够更自然地处理图像信息, 从而优化了计算和存储资源。

轴向 Transformer 的思想来源于传统的 Transformer 结构, 后者通过将信息分别投影到查询(Query)、键(Key)和值(Value)三个不同的维度, 进行属性分类处理, 具备了极强的表达能力。轴向 Transformer 结构类似于这种处理方法, 它将图像信息沿着水平方向和竖直方向分别应用注意力机制。这种处理方法不仅能够对图像信息进行分类处理, 减少了因展开处理(如平铺和卷积)带来的高维数据的计算和存储开销, 而且在保持或提高模型的表达能力的同时, 显著提高了模型的计算效率。

通过这种方式, 轴向 Transformer 结构能够充分利用图像的二维特性, 从而在计算效率、存储需求和表达能力之间取得平衡。由于图像信息天然二维的, 将注意力机制投影到两个正交的方向可以最大限度地保留图像的空间结构信息, 降低了传统高维展开方式带来的计算复杂性, 同时也保留了 Transformer 模型处理复杂关系的能力。这种方法不仅提高了模型对图像特征的表达能力, 还降低了内存和计算资源

的消耗, 使得在图像处理任务中更加高效。

因此 LEDNet 使用轴向 Transformer 结构, 这种结构的应用主要分为两个部分, 高轴自注意力结构和宽轴自注意力结果, 其结果为将, 全特征图注意力正交分解为两个轴的注意力。其具体结构为: 将输入的特征图($C \times H \times W$)分别卷积为 QKV 三个矩阵, 在经过变形得到高轴注意力得分在乘以值, 再以同样的方式得到宽轴注意力分数及最后的结果。其结构图 2 所示。

3.2.2. 多尺度特征融合结构

图 3 所示结构为编码器和解码器特征选择性相互融合结构。首先, LEDNet 将经过上采样后的解码特征 L_1 和同尺寸的编码阶段的特征 L_2 输入这个结构。并且使用 1×1 的卷积使得两个特征图的通道数保持一致。之后进行矩阵相加融合, 目的是计算出不同特征图内通道的重要性。LEDNet 将加和后的特征图进行全局平均池化, 得到一个 $1 \times 1 \times c$ 的逐通道统计矩阵。接下来, 应用一个通道缩减卷积层来生成紧凑的特征表示 z , 最后, 特征向量 z 通过两个并行的通道增强卷积层(每个分辨率流一个)并提供了两个特征描述符 v_1 和 v_2 。之后作应用 softmax 函数到 v_1 和 v_2 上, 产生注意力激活 s_1 和 s_2 , 使用它们来自适应地重新校准多尺度特征图 L_1 和 L_2 。特征重新校准和聚合的整个过程定义为: $U = s_1 * L_1 + s_2 * L_2$ 。完成编码阶段和解码阶段不同尺寸特征图融合。




Figure 2. Axial Transformer architecture
图 2. 轴向 Transformer 结构




Figure 3. Multi-scale feature fusion architecture
图 3. 多尺度特征融合结构

3.2.3. 损失函数

LEDNet 的总损失包括低光照增强损失和模糊损失。低光照增强的损失在编码阶段的最小特征图与

监督图像的 8 倍下采样进行 L1 损失和感知损失的计算。模糊损失是计算监督图像与推断图像的 L1 损失和感知损失。

1) 低光照增强损失

为了在编码阶段对图像的照度进行恢复，LEDNet 使用中间特征监督，LEDNet 在 8 倍降采样尺度上使用 L1 损失和感知损失。LEDNet 在编码阶段预测的最小尺度的图像 $\hat{y}_{\downarrow 8}$ ，使用与尺度对应的真实图像 $y_{\downarrow 8}$ 进行损失计算，具体如公式所示：

$$L_{en} = \|\hat{y}_{\downarrow 8} - y_{\downarrow 8}\|_1 + \lambda_{per} \|\phi(\hat{y}_{\downarrow 8}) - \phi(y_{\downarrow 8})\| \quad (3)$$

其中： $\phi()$ 表示预训练的 VGG19 网络。起作用是对 VGG19 网络进行蒸馏，加快网络的收敛。

2) 去模糊损失

使用 L1 损失和感知损失作为去模糊损失 L_{deb} ：

$$L_{deb} = \|\hat{y} - y\|_1 + \lambda_{per} \|\phi(\hat{y}) - \phi(y)\| \quad (4)$$

然后通过对低光照增强损失与模糊损失进行加权相加，计算总损失函数如下：

$$L = \alpha L_{en} + \beta L_{deb}$$

4. 实验与讨论

LEDNet 针对露天矿监控场景下低光照与运动模糊的共存问题，提出了一种将光照增强和去模糊任务在网络结构中分离处理的方法，从而实现联合处理的效果。在编码阶段，LEDNet 对最小的下采样特征图和 8 倍下采样的监督图进行损失计算，以增强图像的照度。其原理在于，由于 8 倍下采样的特征图尺寸极小，运动模糊的影响已被忽略，因此只需在中间层恢复图像的照度。在解码阶段，通过多尺度特征融合，LEDNet 通过全局平均池化和卷积，对不同尺度的特征图赋予不同的重要性。该网络也类似于 Transformer 结构，通过为不同通道分配注意力分数，从而舍弃或弱化某些通道内的特征图。在去模糊阶段，LEDNet 保留了增强图像清晰度的特征图，并去除了对图像清晰度无益的特征图。

为了全面评估该网络的效果，LEDNet 采用了四种关键评价指标，并在两种典型的实验场景中进行了验证：一是露天矿的室外监控图像，二是生产系统内筒仓的监控图像。所采用的评价指标包括峰值信噪比(PSNR)、结构相似性指数(SSIM)、平均绝对误差(MAE)以及学习感知图像块相似度(LPIPS)，以确保 LEDNet 的方法能够在这些挑战性场景下实现高质量的图像恢复与增强。

实验结果如下图 4 所示。

在图 4 中的露天矿监控图像中可以清晰地看出，在极低照度的情况下，依旧可以清晰分辨出物体的轮廓。如第一行放煤图像中的货车，构筑物以及放煤口。第二行受煤坑的下部阴影部分，以及最后一行坑内工作面情况。并没有现大面积噪点。其他方法在亮度较高的地方出现了噪点，在亮度较低的地方出现了大面积的无法识别区域。如图 4 第一行的车辆阴影面与车厢内，出现了大面积无法识别的区域。而在第三行的矿卡车身亮度较高出，则出现了大面积噪点。在图 4 第一和第三行车辆运动部分，尤其是第三行的轮胎，我们可以清晰看出轮胎的轮廓，其他方法在轮胎部分以及严重丢失细节。因此，LEDNet 在去模糊方面也有不错的表现。

通过使用峰值信噪比(PSNR)、结构相似性指数(SSIM)、平均绝对误差(MAE)和学习感知图像块相似度(LPIPS)四种关键指标进行评估，方法结果对比如表 1 所示。

通过将 LEDNet 的方法与其他技术在露天矿的室内外环境中对比，结果显示 LEDNet 的方法在这两种场景中均显著超越了比较的方法，特别是在 PSNR 和 MAE 两个指标上，展示了其在图像恢复与增强任务中的高精度和优质输出。同时，SSIM 和 LPIPS 指标的良好表现进一步证实了 LEDNet 的技术能够




Figure 4. Results of experiments
图 4. 实验结果图

Table 1. Results comparison table
表 1. 结果对比表

方法	露天矿室内场景				露天矿室外场景			
	PSNR	SSIM	MAE	LPIPS	PSNR	SSIM	MAE	LPIPS
论文方法	41.8	0.93	0.002	0.1136	43.58	0.97	0.002	0.1210
DRBN	26.65	0.82	0.044	0.2104	22.65	0.51	0.051	0.2154
DSLR	23.56	0.83	0.028	0.3502	24.71	0.73	0.018	0.4312
EnlightGAN	25.12	0.79	0.024	0.3211	22.02	0.80	0.024	0.3121
EBDB	25.23	0.80	0.024	0.2901	25.23	0.82	0.020	0.1501
PDPD	27.34	0.90	0.035	0.2145	22.34	0.76	0.022	0.2200
JNB	22.53	0.86	0.023	0.3416	23.53	0.76	0.029	0.1862

有效地重建图像，同时优秀地保留了图像的结构和感知质量。这些成果强调了 LEDNet 提出的网络架构在应对图像恢复、增强及去模糊任务方面的高效性和先进性。

5. 结论

本研究通过融合在网络中间层提升照度，在解码阶段遗忘不重要特征，从而实现图像的去模糊与照

度提升。相关方法显著提升了在复杂露天矿监控环境下的图像质量,特别是在低光照和运动模糊场景中。该方法不仅显著提高了图像的亮度和清晰度,还保留了关键特征,如设备细节和人员特征,确保了高质量图像恢复的实用性。

相比现有技术,LEDNet的方法在增强后的图像中更接近于真实场景,极大提高了露天矿监控系统的可靠性和准确性。同时在极端低光照条件下展现出卓越的抗噪能力,显著减少了噪点和图像失真,优于DRBN、DSLR和EnlightGAN等现有方法。经过在多种露天矿场景和不同光照条件下的测试,该方法证明了其广泛的适用性和灵活性,能够在各种复杂环境中实现高效图像处理。

研究的LEDNet在去除伪影方面仍有一定的不足,在后续研究中将持续改进,针对性地提升LEDNet的伪影去除能力。

参考文献

- [1] 葛君超, 王利鹏. 基于自适应 Retinex 算法的煤矿低光照图像增强研究[J]. 金属矿山, 2024(8): 152-157.
- [2] 苗作华, 张立, 徐厚友, 等. 基于 CLAHE-PCA 的矿井低照度图像增强研究[J]. 金属矿山, 2024(6): 165-172.
- [3] Yang, W., Wang, S., Wu, J., Chen, W. and Tian, Z. (2024) A Low-Light Image Enhancement Method for Personnel Safety Monitoring in Underground Coal Mines. *Complex & Intelligent Systems*, **10**, 4019-4032. <https://doi.org/10.1007/s40747-024-01387-2>
- [4] 成丽波, 董伦, 李喆, 等. 基于 NSST 与稀疏先验的遥感图像去模糊方法[J]. 吉林大学学报(理学版), 2024, 62(1): 106-115.
- [5] 龚颖, 许文韬, 赵策, 等. 生成对抗网络在图像修复中的应用综述[J]. 计算机科学与探索, 2024, 18(3): 553-573.
- [6] 许润泽, 罗守华, 鄢志鸿, 等. 基于光线重排的印制电路板高速扫描成像迭代去模糊方法研究[J]. 国外电子测量技术, 2024, 43(1): 52-59.
- [7] Funt, B.V., Ciurea, F. and McCann, J.J. (2004) Retinex in Matlab™. *Journal of Electronic Imaging*, **13**, 48. <https://doi.org/10.1117/1.1636761>
- [8] Provenzi, E., Marini, D., De Carli, L. and Rizzi, A. (2005) Mathematical Definition and Analysis of the Retinex Algorithm. *Journal of the Optical Society of America A*, **22**, 2613-2621. <https://doi.org/10.1364/josaa.22.002613>
- [9] Wei, C., Wang, W., Yang, W., et al. (2018) Deep Retinex Decomposition for Low-Light Enhancement.
- [10] 高小强, 常侃, 凌铭阳, 等. 多模态自适应特征融合的目标检测[J]. 激光与光电子学进展, 2023, 60(24): 108-117.
- [11] 王均利, 李佳悦, 李秉天, 等. 基于深度学习的煤矿井下低光照人脸检测方法[J]. 工矿自动化, 2023, 49(11): 145-150.
- [12] 闫晓阳, 王华珂, 侯兴松, 等. YCbCr 空间分治的双分支低照度图像增强网络[J]. 中国图象图形学报, 2023, 28(11): 3415-3427.
- [13] 李健, 成雅清. 基于注意力机制的多阶段低照度图像增强方法[J]. 计算机时代, 2023(11): 83-89.
- [14] 袁玉龙. 一种零参考样本的深度图像增强算法[J]. 工业控制计算机, 2023, 36(10): 91-93.
- [15] 程德强, 张华强, 寇旗旗, 等. 基于层级特征融合的室内自监督单目深度估计[J]. 光学精密工程, 2023, 31(20): 2993-3009.
- [16] Sohl-Dickstein, J., Weiss, E.A., Maheswaranathan, N., et al. (2015) Deep Unsupervised Learning using Nonequilibrium Thermo-Dynamics. Cornell University Library, Ithaca.