

文章编号: 1671-251X(2025)02-0057-09

DOI: 10.13272/j.issn.1671-251x.2024110072

基于改进 Zero-DCE 模型的矿井低照度图像增强方法

王轶玮, 李晓宇, 翁智, 白凤山

(内蒙古大学 电子信息工程学院, 内蒙古 呼和浩特 010021)

摘要: 煤矿井下监控图像中存在噪声, 清晰度低, 且颜色和纹理信息缺失, 采用基于机器学习的图像增强方法时还面临低照度-正常照度图像配对数据集采集困难的问题。提出一种改进零参考深度曲线估计(Zero-DCE)模型, 并将其应用于矿井低照度图像增强。使用 Leaky ReLU 激活函数替换 Zero-DCE 模型中的 ReLU 激活函数, 以加快模型收敛速度, 提升低照度图像特征学习效率; 在 Zero-DCE 模型浅层与深层网络之间的跳跃连接处引入卷积块注意力模块(CBAM), 以提高模型对图像关键特征的表达; 在浅层网络中引入非对称卷积块(ACB), 以优化模型对局部图像特征的学习能力和细节特征的表现能力; 在深层网络中采用串联卷积核(CCK), 以降低模型参数量和计算量, 缩短模型训练时间。采用 LOL 公共数据集和矿井自建数据集进行实验验证, 结果表明: 改进 Zero-DCE 模型的均方误差(MSE)、峰值信噪比(PSNR)、结构相似性(SSIM)、自然图像质量评估器(NIQE)和视觉信息保真度(VIF)整体上优于典型图像增强模型, 在自建数据集上的 MSE 和 NIQE 较 Zero-DCE 模型分别降低 16.25% 和 2.93%, PSNR, SSIM 和 VIF 分别提高 2.87%, 1.87% 和 17.64%; 图像增强视觉效果较好, 可在提高图像亮度的同时有效保留细节纹理信息, 降噪效果明显; 对单幅图像的推理时间为 0.138 s, 可实现图像实时增强。

关键词: 矿井低照度图像; 图像增强; 零参考深度曲线估计网络; Zero-DCE 模型; 无监督学习

中图分类号: TD67

文献标志码: A

Low-light image enhancement method for underground mines based on an improved Zero-DCE model

WANG Yiwei, LI Xiaoyu, WENG Zhi, BAI Fengshan

(School of Electronic Information Engineering, Inner Mongolia University, Hohhot 010021, China)

Abstract: Underground coal mine surveillance images suffer from noise, low clarity, missing color, and texture information. Additionally, machine learning-based image enhancement methods face challenges in collecting paired low-light and normal-light image datasets. To address these issues, this paper proposes an improved Zero-Reference Deep Curve Estimation (Zero-DCE) model for enhancing low-light images in mines. The ReLU activation function in the Zero-DCE model was replaced with Leaky ReLU to accelerate model convergence and improve the efficiency of low-light image feature learning. A Convolutional Block Attention Module (CBAM) was introduced at the skip connections between the shallow and deep networks of the Zero-DCE model to enhance the model's ability to capture key image features. An Asymmetric Convolution Block (ACB) was incorporated into the shallow network to optimize the model's learning of local image features and its ability to represent fine details. A Cascaded Convolution Kernel (CCK) was employed in the deep network to reduce the number of model parameters and computational cost, thereby shortening the training time. Experimental validation was conducted using the LOL public dataset and a self-built mine dataset. The results showed that the

收稿日期: 2024-11-22; 修回日期: 2025-02-10; 责任编辑: 李明。

基金项目: 国家自然科学基金资助项目(52364017); 内蒙古自治区自然科学基金项目(2020MS06024, 2023QN05023); 2023 年度自治区本级引进高层次人才科研支持项目(12000-15042321); 2023 年高层次人才科研启动项目(10000-2311210105)。

作者简介: 王轶玮(1998—), 男, 内蒙古包头人, 硕士研究生, 研究方向为矿井 AI 视频分析, E-mail: wjianpo4579@163.com。通信作者: 李晓宇(1991—), 女, 内蒙古凉城人, 讲师, 博士, 主要从事矿井监控与监视方面的研究与教学工作, E-mail: L_xiaoyu@126.com。

引用格式: 王轶玮, 李晓宇, 翁智, 等. 基于改进 Zero-DCE 模型的矿井低照度图像增强方法[J]. 工矿自动化, 2025, 51(2): 57-64, 99. WANG Yiwei, LI Xiaoyu, WENG Zhi, et al. Low-light image enhancement method for underground mines based on an improved Zero-DCE model[J]. Journal of Mine Automation, 2025, 51(2): 57-64, 99.



扫码移动阅读

improved Zero-DCE model outperformed typical image enhancement models in terms of Mean Squared Error (MSE), Peak Signal-to-Noise Ratio (PSNR), Structural Similarity (SSIM), Natural Image Quality Evaluator (NIQE), and Visual Information Fidelity (VIF). Specifically, on the self-built dataset, MSE and NIQE decreased by 16.25% and 2.93%, respectively, while PSNR, SSIM, and VIF increased by 2.87%, 1.87%, and 17.64%, respectively. The enhanced images exhibited superior visual quality, effectively improving brightness while preserving detailed texture information and significantly reducing noise. The inference time for a single image was 0.138 seconds, enabling real-time image enhancement.

Key words: underground low-light images; image enhancement; Zero-Reference Deep Curve Estimation network; Zero-DCE model; unsupervised learning

0 引言

近年来,矿山信息化和计算机视觉技术的快速发展推动了矿井智能视频监控系统的开发与应用。开展井下重点区域精准监视与安全感知,对于促进煤矿企业安全高效生产具有重要作用^[1]。井下作业环境复杂,存在光照条件差、矿尘浓度大、喷雾扰动等特点^[2],导致摄像机采集的图像清晰度低、细节信息缺失,严重影响矿井视频监控系统的效果。对井下低照度图像进行增强预处理^[3-4],可有效提高图像的亮度和对比度,同时丰富图像场景的特征信息,为矿井目标检测、识别、跟踪等技术奠定基础。

目前,矿井低照度图像增强方法分为传统方法和深度学习方法。传统方法主要包括直方图均衡化和基于 Retinex 理论的方法。直方图均衡化通过重新分配低照度图像中像素分布范围的方式,达到提高图像局部对比度的目的^[4],但容易导致增强图像的局部亮度不均匀,影响图像的整体视觉效果。基于 Retinex 理论的方法认为摄像机采集的图像可分解为光照分量和反射分量,通过滤波方法估计图像中的光照分量,进而获取反射分量^[5],并实现图像增强。Guo Xiaojie 等^[6]基于 Retinex 理论提出了基于光照图像估计的低光图像增强算法(Low-Light Image Enhancement via Illumination Map Estimation, LIME),先确定输入图像各通道的最大值,再对初始化的光照图像进行结构先验处理,最后输出反射图像,得到增强图像,但存在过度增强现象。与传统方法相比,深度学习方法表现出更优越的图像增强性能。其中,以 Retinex-Net^[7]为代表的低照度图像增强方法得到广泛研究与应用。该方法采用构造的分解网络将矿井低照度图像分解成光照图像和反射图像,通过对光照图像进行增强处理,达到提升图像亮度的目的,但容易出现颜色失真、边缘模糊问题。Zhang Yonghua 等^[8]对 Retinex-Net 进行改进,提出了 KinD 模型,通过不同程度地改变曝光条件,灵活进行图像

增强,但需要合理划分图像区域,难以实现高质量增强。针对上述问题,Zhang Yonghua 等^[9]进一步提出 KinD Plus 模型,实现了低照度图像的有效增强,但该模型参数过多,导致推理速度较慢,在实时性方面表现较差。王满利等^[10]提出一种基于深度神经网络的矿井图像增强算法,该算法处理速度较快,但增强图像局部区域对比度不强。此外,现有基于深度学习的低照度图像增强方法大多对于低照度-正常照度配对图像数据集有较高的要求,这与井下配对图像数据集采集困难形成了冲突。基于无监督学习的图像增强方法能够较好地解决模型训练依赖大量低照度-正常照度配对数据集的问题,得到越来越多的研究与应用。Guo Chunle 等^[11]提出零参考深度曲线估计(Zero-reference Deep Curve Estimation, Zero-DCE)模型,能在实现轻量化训练的同时,完成高质量的图像增强,但增强图像的局部对比度不够明显,部分特征及细节信息丢失,影响全局质量。Jiang Yifan 等^[12]提出了 EnlightenGAN 网络,其基于生成对抗网络,在图像增强方面效果较好,但有时生成的增强图像较模糊,且训练网络对计算资源和时间的要求较高。Zhang Yu 等^[13]提出了自监督图像增强网络(Self-Supervised Image Enhancement Network, SSIENet),较高效地解决了图像增强问题,计算资源耗费较少,但增强图像存在一定程度的颜色失真与色差问题。

本文提出一种基于改进 Zero-DCE 模型的矿井低照度图像增强方法。在 Zero-DCE 模型的跳跃连接处引入卷积块注意力模块(Convolutional Block Attention Module, CBAM),增强图像细节信息和对比度,有效抑制无关信息,使跳跃连接融合图像不同层次的特征,丰富图像语义信息,提高模型对重要图像特征的表达力;引入非对称卷积块(Asymmetric Convolution Block, ACB),提高模型对图像特征的学习能力和细节特征表现力;将 3×3 卷积核替换为轻量级串联卷积核(Concatenated Convolution Kernel, CCK),减少模型参数量和计算量,缩短模型训练时间,实现图像实时增强。

1 Zero-DCE 模型

Zero-DCE 模型包括 7 个卷积层, 如图 1 所示。前 6 个卷积层由 32 个步长为 1 的 3×3 卷积核组成, 卷积层之间采用 ReLU 激活函数激活; 第 7 个卷积层由 24 个步长为 1 的 3×3 卷积核组成, 采用 tanh 激活函数激活。前 6 层网络之间使用跳跃连接, 将第 3 层和第 4 层、第 2 层和 5 层、第 1 层和第 6 层的输出拼接在一起, 分别作为第 5—7 层的输入。第 7 层输出 R, G, B (分别为红、绿、蓝) 共 3 个颜色通道。




图 1 Zero-DCE 模型结构

Fig. 1 Structure of Zero-DCE model

Zero-DCE 模型通过光线增强曲线 (Light Enhancement Curve, LE-curve) 对非均匀照度条件下的输入图像进行亮度调整。LE-curve 计算公式为

$$L_n(x) = L_{n-1}(x) + \alpha_n L_{n-1}(x)(1 - L_{n-1}(x)) \quad (1)$$

式中: $L_n(x)$ 为第 n 次迭代时的 LE-curve; x 为输入图像的像素坐标; α_n 为第 n 次迭代时的可训练参数, $\alpha_n \in [-1, 1]$ 。

通过式(1)的多次迭代, 输入图像的每个像素都会向最优化的目标曲线拟合, 图像亮度得以调整^[14]。

针对部分场景中图像配对数据集采集困难的问题, 设计 4 个非参考损失函数, 包括空间一致损失^[15]、曝光控制损失^[16]、颜色恒常损失和光照平滑损失^[17]。

空间一致损失 L_{spa} 用于确保图像增强后局部区域像素值不与相邻像素之间发生太大改变。

$$L_{spa} = \frac{1}{K} \sum_{i=1}^K \sum_{j \in \Omega(i)} (|Y_i - Y_j| - |I_i - I_j|)^2 \quad (2)$$

式中: K 为像素数量; $\Omega(i)$ 为第 i 个像素的上下左右 4 个相邻区域, 每个区域大小为 4×4 ; Y_i, Y_j 为低照度图像的第 i, j 个像素值; I_i, I_j 为增强图像的第 i, j 个像素值。

曝光控制损失 L_{exp} 为像素区域的亮度平均值与理想曝光程度 E 之间的距离^[18]。

$$L_{exp} = \frac{1}{m} \sum_{k=1}^m |B_k - E| \quad (3)$$

式中: m 为大小为 16×16 的不重叠区域数量; B_k 为增强图像中第 k 个局部区域的亮度平均值。

颜色恒常损失 L_{col} 用于根据灰度世界颜色恒常性假设, 修正增强图像潜在的颜色偏差, 使得增强图像 R, G, B 三通道平均值不存在显著差异。

$$L_{col} = \sum_{p,q} (J_p - J_q)^2 \quad (4)$$

式中 J_p, J_q 分别为增强图像通道 p, q 的亮度平均值, $p, q \in \{R, G, B\}, p \neq q$ 。

通过在每个 LE-curve 参数映射中添加光照平滑损失 L_{tva} , 可减小图像中相邻像素之间的亮度改变程度, 使相邻像素之间的亮度尽可能接近。

$$L_{tva} = \frac{1}{N} \sum_{n=1}^N \sum_c (|\nabla_1 A_n^c| + |\nabla_2 A_n^c|)^2 \quad (5)$$

式中: N 为迭代总次数; ∇_1, ∇_2 分别为水平方向和垂直方向的梯度算子; A_n^c 为 LE-curve 在图像色彩通道 c 第 n 次迭代得到的像素值, $c \in \{R, G, B\}$ 。

将上述 4 个损失函数线性叠加, 得到总的损失函数:

$$L_{total} = W_1 L_{spa} + W_2 L_{exp} + W_3 L_{col} + W_4 L_{tva} \quad (6)$$

式中 $W_1—W_4$ 为各损失函数的权重。

2 基于改进 Zero-DCE 模型的图像增强方法

针对矿井图像特点, 从改变激活函数和引入 ACB, CBAM, CCK 方面改进 Zero-DCE 模型, 改进结构如图 2 所示。




图 2 改进 Zero-DCE 模型结构

Fig. 2 Structure of improved Zero-DCE model

1) 激活函数。Zero-DCE 卷积层之间采用 ReLU 激活函数, 在梯度反向传导时存在负向神经元不学习的现象^[19]。Leaky ReLU 激活函数在负区间有一个很小的梯度, 可解决上述问题, 加快模型收敛速度, 提升模型对低照度图像特征的学习效率与计算资源的利用效率。因此, 在 Zero-DCE 模型的第 1—6 层卷积层采用 Leaky ReLU 激活函数。

Leaky ReLU 激活函数可表示为

$$R(X) = \begin{cases} X & X > 0 \\ lX & X \leq 0 \end{cases} \quad (7)$$

式中: X 为激活函数的输入; l 为斜率, 取 0.1。

2) ACB。ACB 由 3×3 卷积核、 1×3 矩形卷积核

和 3×1 矩形卷积核并联组成^[20]。3 个卷积核经批量归一化融合与分支融合处理,生成与 3×3 卷积过程等效的卷积层。该卷积层可强化网络模型对于图像局部特征的学习能力及细节特征的表现力,提高模型训练速度,实现实时增强。

ACB 可表示为

$$F' = \frac{\gamma}{\sigma} F \oplus \frac{\bar{\gamma}}{\bar{\sigma}} \bar{F} \oplus \frac{\hat{\gamma}}{\hat{\sigma}} \hat{F} \quad (8)$$

式中: F' 为融合后的卷积核; $\gamma, \bar{\gamma}, \hat{\gamma}$ 分别为 $3 \times 3, 3 \times 1, 1 \times 3$ 卷积核的可训练参数; $\sigma, \bar{\sigma}, \hat{\sigma}$ 分别为 $3 \times 3, 3 \times 1, 1 \times 3$ 卷积核的标准差; \oplus 为求和运算符号; F, \bar{F}, \hat{F} 分别为 $3 \times 3, 3 \times 1, 1 \times 3$ 卷积核。

针对井下低亮度、高噪声图像,Zero-DCE 模型在特征提取过程中存在部分有效特征信息表达缺失的问题。对此,在 Zero-DCE 模型的第 1—4 层浅层网络使用 ACB,将从低照度图像中学习到的特征信息融合相加,加深浅层网络对图像有效特征的提取。

3) CBAM。CBAM 是一种结合通道和空间注意力机制的注意力模块^[21],其主要思想:采用通道注意力模块将输入特征图降维,并对特征图进行全局最大池化与平均池化操作;将池化后的特征图拼接,产生通道注意力图;将通道注意力图与输入特征图逐元素相乘,生成的特征图输入空间注意力模块,进行全局最大池化与平均池化操作,对得到的特征图进行拼接,产生空间注意力图;对空间注意力图与空间注意力模块输入的特征图逐元素相乘,并对权重再分配,以提高特征图中有效通道的权重,最终得到注意力权重图。

CBAM 结构如图 3 所示。




图 3 CBAM 结构

Fig. 3 Structure of Convolutional Block Attention Module (CBAM)

CBAM 可表示为

$$\begin{cases} M_{ch} = \sigma(f_{mlp}(AP(M)) + f_{mlp}(MP(M))) \\ M_{sp} = \sigma(f_{conv}(AP(M), MP(M))) \end{cases} \quad (9)$$

式中: M_{ch}, M_{sp} 分别为通道注意力图和空间注意力图; σ 为 Sigmoid 激活函数; f_{mlp}, f_{conv} 分别为多层感知机和卷积运算;AP, MP 分别为平均池化和最大池化操作; M 为输入特征图。

Zero-DCE 模型在特征提取过程中会引入一些噪声,导致存在部分无效特征。针对该问题,在 Zero-DCE 模型的 3 个跳跃连接中引入 CBAM。CBAM 获取特征图通道的权重,模型根据这些权重融合图像不同层次的特征,增强图像有效特征,同时抑制无效特征,提高模型对井下低照度图像中关键特征的表达能力,强化图像细节信息^[22]。

4) CCK。为提高 Zero-DCE 模型的训练速度,将第 5—7 层深度网络的 3×3 卷积核拆分为 3×1 矩形卷积核与 1×3 矩形卷积核的 CCK^[23]。

CCK 可表示为

$$w * F^{(1)} + w * F^{(2)} = w * (F^{(1)} \oplus F^{(2)}) \quad (10)$$

式中: w 为矩形卷积核窗口; $*$ 为卷积运算符; $F^{(1)}, F^{(2)}$ 分别为 3×1 卷积核和 1×3 卷积核。

采用 CCK 可使每个卷积层要训练的参数量由原来的 9 个单位降为 6 个单位,减少了 1/3。当 Zero-DCE 模型训练到深层网络时,需处理大量参数,对卷积核等价替换后,在图像增强效果几乎不变的情况下,参数量和计算量大幅降低,减少了训练时间,有利于实现矿井低照度图像实时增强。

基于改进 Zero-DCE 模型的矿井低照度图像增强流程如图 4 所示。将采集的矿井低照度监控图像输入改进 Zero-DCE 模型进行卷积处理,并通过 LE-curve 进行图像亮度逐级调整,初步得到增强图像,采用 4 种非参考损失函数评估初步增强图像效果,通过无监督学习方式获得最终的增强图像。

3 实验及结果分析

3.1 实验条件及评价指标

本文所用自建数据集图像采集自国家能源集团宁夏煤业有限责任公司双马煤矿。选取 2 000 张像素大小为 512×512 的图像对改进 Zero-DCE 模型进行性能测试,其中 1 500 张为训练集(进行不同程度的曝光,使网络能对同一场景中不同光照条件下的图像进行拟合),其余 500 张为测试集。

实验硬件环境:操作系统为 Windows10, CPU 为 Intel Core i7-9700F, GPU 为 Nvidia GeForce RTX 2080 Ti, 内存为 16 GiB。实验使用 Pycharm 编译器, Adam 优化器,基于 Python 3.8 和 PyTorch v1.10.1 框架实现。网络初始学习率为 0.000 1,训练轮数为 200,批量大小为 8。经多次超参数调整和实验验证,设置改进 Zero-DCE 模型的理想曝光程度 E 为 0.6,损失函数权重 W_1-W_4 分别为 1, 10, 5, 200。

采用均方误差 (Mean Squared Error, MSE)、峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR)、结构相似

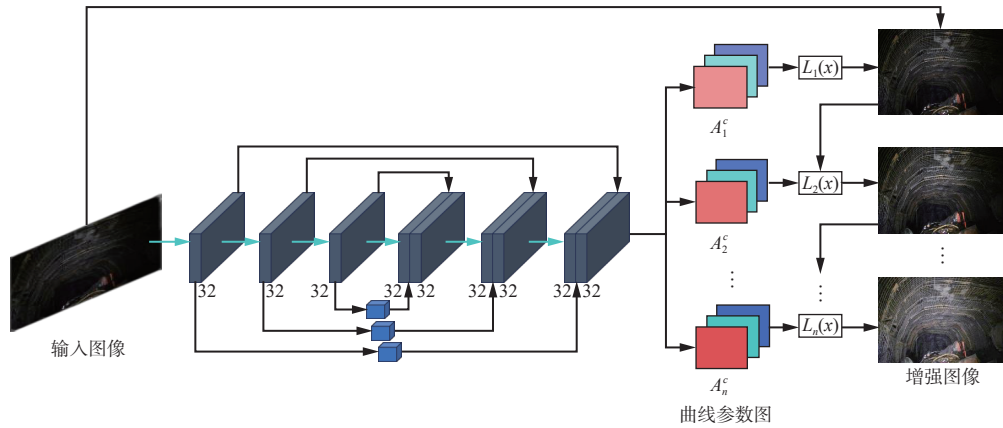


图 4 基于改进 Zero-DCE 模型的矿井低照度图像增强方法流程

Fig. 4 Process of low-light coal mine image enhancement method based on improved Zero-DCE model

性 (Structural Similarity, SSIM)、自然图像质量评估器 (Natural Image Quality Evaluator, NIQE) 和视觉信息保真度 (Visual Information Fidelity, VIF)^[24] 共 5 个指标评价基于改进 Zero-DCE 模型的矿井低照度图像增强方法的性能。MSE 反映增强图像与参考图像的差异程度, PSNR 用于评估图像增强后的颜色失真程度, SSIM 用于评估图像增强后的亮度提升程度, NIQE 用于评估增强图像的自然程度, VIF 反映增强图像细节信息量的保留程度。通常情况下 MSE, NIQE 越小, PSNR, SSIM, VIF 越大, 表明图像增强效果越好。

3.2 消融实验

为验证 Leaky ReLU 激活函数、CBAM、ACB、CCK 对 Zero-DCE 模型的改进性能, 从测试集中选取部分图像进行消融实验, 结果如图 5 所示, 评价指标见表 1。其中模型 1 为基准模型 Zero-DCE, 模型 2 为 Zero-DCE+Leaky ReLU, 模型 3 为 Zero-DCE+ACB, 模型 4 为 Zero-DCE+CBAM, 模型 5 为 Zero-DCE+CCK, 模型 6 为 Zero-DCE+CBAM+ACB, 模型 7 为 Zero-DCE+CBAM+ACB+Leaky ReLU, 本文模型为 Zero-DCE+CBAM+ACB+Leaky ReLU+CCK。

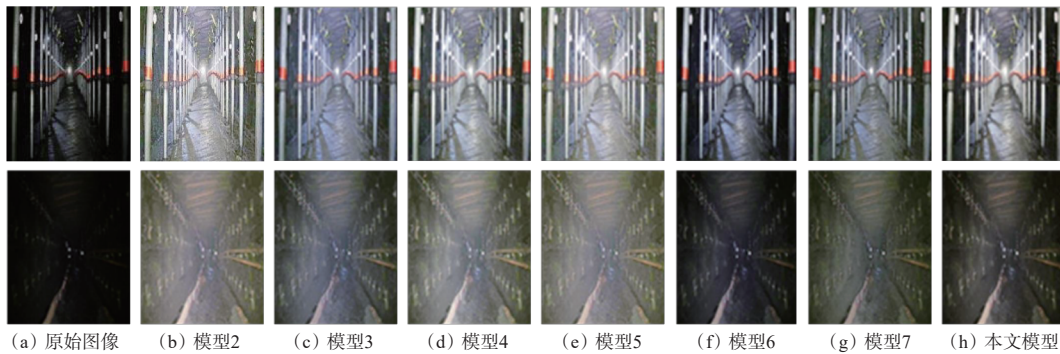


图 5 消融实验输出图像

Fig. 5 Output images of ablation experiments

表 1 消融实验指标对比

Table 1 Indicators comparison of ablation experiment

模型	MSE	PSNR	SSIM	NIQE	VIF
模型1	310.51	23.21	0.90	8.52	0.32
模型2	302.75	23.32	0.91	8.49	0.32
模型3	300.66	23.35	0.90	8.50	0.36
模型4	275.47	23.73	0.91	8.51	0.35
模型5	311.95	23.19	0.90	8.52	0.32
模型6	291.13	23.49	0.90	8.33	0.38
模型7	262.47	23.94	0.92	8.29	0.38
本文模型	260.06	23.98	0.92	8.27	0.38

从图 5 和表 1 可看出: 在 Zero-DCE 模型中加入 Leaky ReLU 后, 增强图像中巷道与工作面处亮度得到提升, 图像细节信息更加清晰, 但存在一定程度失真, PSNR 和 SSIM 提高, MSE 和 NIQE 降低; 在 Zero-DCE 模型中加入 ACB 后, 增强图像的 MSE 和 NIQE 降低, PSNR 小幅提高, VIF 大幅提高; 在 Zero-DCE 模型中加入 CBAM 后, 增强图像的色彩恢复程度较好, 井下细节信息得到增强, MSE 和 NIQE 降低, SSIM 和 VIF 小幅提高, PSNR 大幅提高; 在 Zero-DCE 模型中加入 CCK 后, 图像增强效果和指标几乎不变; 在 Zero-DCE 模型中同时加入 CBAM 和 ACB 时, 增强图像的亮度提升程度较明显, 颜色失真程度

降低, 井下细节信息恢复程度较高, MSE 小幅降低, NIQE 明显降低, PSNR, SSIM, VIF 小幅提高; 在 Zero-DCE 模型中同时加入 CBAM, ACB, Leaky ReLU 时, 与同时加入 CBAM 和 ACB 相比, 增强图像的亮度得到较好的提升, 颜色失真程度进一步降低, 图像细节信息恢复程度进一步提高, MSE 大幅降低, NIQE 小幅降低, PSNR 大幅提高, SSIM 小幅提高; 本文模型能更好地提高输出图像的亮度, 合理降低颜

色失真程度, 尽可能全面地强化井下细节信息, 各指标最优。

3.3 对比实验

为验证本文模型对公共低照度图像增强的适用性, 将其与 LIME^[6], Retinex-Net^[7], KinD^[8], KinD Plus^[9], Zero-DCE^[11], EnlightenGAN^[12], SSIENet^[13]这 7 种典型模型在公共数据集 LOL^[7]上进行测试, 选取 4 张图像进行分析, 如图 6 所示。




图 6 LOL 数据集图像增强效果对比

Fig. 6 Comparison of image enhancement effect for LOL dataset

从图 6 可看出: LIME 模型针对细节轮廓的恢复较好, 但在图像亮度提升方面效果不明显; Retinex-Net 模型可有效提升图像亮度, 但存在颜色失真现象; KinD 模型在图像亮度提升方面效果明显, 但图像整体偏白, 存在一定程度的过曝现象; KinD Plus 模型对图像细节的恢复能力较好, 但部分区域存在一定程度的失真; Zero-DCE 模型能较好地恢复纹理细节信息, 但图像亮度提升效果不明显; 经 EnlightenGAN 模型增强后的图像对比度提升明显, 但亮度提升不太均匀; 经 SSIENet 增强后的图像细节信息恢复较好, 但色调不太自然; 本文模型能较好地提升图像亮度, 增强图像的色调相对自然, 且能较完整地保留细节信息。

不同模型的图像增强性能评价指标见表 2。可看出本文模型在 LOL 数据集上表现良好, SSIM, NIQE, VIF 取得最优值, MSE 和 PSNR 仅次于 KinD Plus 模型。整体上, 本文模型对公共低照度图像数据集具有较好的增强效果。

在自建数据集上验证本文模型的图像增强效果, 并与其他 7 种模型进行对比。不同模型的矿井图像增强结果如图 7 所示。

从图 7 可看出: 经 LIME 模型增强后的图像产生

表 2 LOL 数据集图像增强指标对比

Table 2 Comparison of image enhancement indicators for LOL dataset

模型	MSE	PSNR	SSIM	NIQE	VIF
LIME	2 618.67	13.95	0.69	9.41	0.26
Retinex-Net	1 367.98	16.77	0.79	9.76	0.22
KinD	1 117.07	17.65	0.88	7.56	0.29
KinD Plus	739.74	19.44	0.89	9.41	0.29
Zero-DCE	1 069.25	17.84	0.88	9.90	0.27
EnlightenGAN	1 161.66	17.48	0.86	9.70	0.30
SSIENet	731.27	18.94	0.91	10.53	0.33
本文模型	776.39	19.23	0.91	9.28	0.37

较多噪点, 存在过度增强现象; 经 Retinex-Net 模型增强后的图像存在颜色失真与图像色彩恢复不理想的现象, 且颜色不太均匀; 经 KinD 模型增强后的图像在亮度和对比度提升方面不太明显, 且引入少量噪点; 经 KinD Plus 模型增强后的图像产生了光晕伪影现象, 同时丢失了较多的细节信息; 经 Zero-DCE 模型增强后的图像在明亮区域存在过度增强现象, 图像对比度较低; 经 EnlightenGAN 模型增强后的图像部分细节信息丢失, 局部图像亮度提升不明显; 经 SSIENet 增强后的图像在低照度区域亮度提升不太

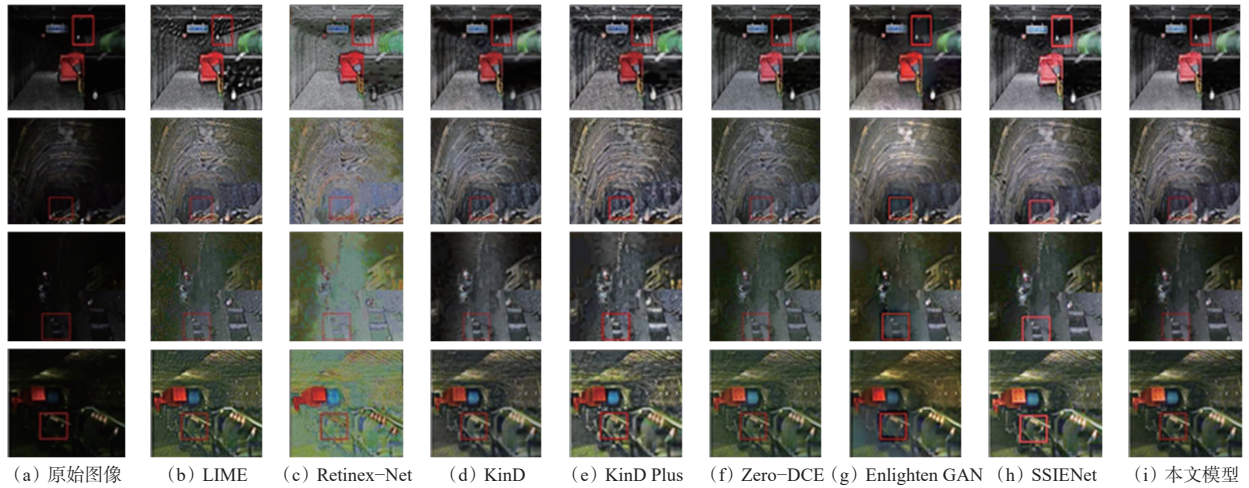


图 7 矿井数据集图像增强效果对比

Fig. 7 Comparison of image enhancement effect for mine dataset

明显；经本文模型增强后的图像纹理和细节信息清晰完整，色彩恢复较理想，全局增强效果好。

进一步使用图像质量评估指标客观分析各模型在测试集上的增强效果。从 8 种模型对测试集的图像增强结果中选取 NIQE 最优的图像作为近似参考图像^[10]。不同模型对矿井测试集图像进行增强后指标见表 3。可看出本文模型在 MSE, PSNR, NIQE, VIF 这 4 个指标方面优于对比模型，仅 SSIM 略低于 KinD 模型。相较于 Zero-DCE 模型，本文模型 MSE 和 NIQE 分别降低了 16.25% 和 2.93%，PSNR, SSIM, VIF 分别提高了 2.87%, 1.87%, 17.64%。综合主观视觉效果与客观评价指标可知，本文模型对于矿井恶劣环境中低照度图像增强具有显著优势。

表 3 矿井数据集图像增强指标对比

Table 3 Comparison of image enhancement indicators for mine dataset

模型	MSE	PSNR	SSIM	NIQE	VIF
LIME	992.84	18.16	0.72	9.30	0.31
Retinex-Net	1 742.93	15.72	0.74	9.27	0.34
KinD	318.48	23.10	0.94	9.29	0.37
KinD Plus	461.40	21.49	0.89	10.58	0.32
Zero-DCE	310.51	23.21	0.90	8.52	0.32
EnlightenGAN	322.167	23.05	0.90	8.73	0.31
SSIENet	314.109	23.16	0.91	8.62	0.32
本文模型	260.06	23.98	0.92	8.27	0.38

在测试集中随机选取 100 幅图像，采用不同模型进行图像增强，统计各模型的参数量和计算量及增强单幅图像的平均耗时，结果见表 4。可看出本文模型在推理时间、参数量和计算量上优于大部分对比模型。

表 4 各模型性能对比

Table 4 Performance comparison of various models

模型	推理时间/s	参数量/10 ⁶ 个	计算量/10 ⁹ 个
LIME	15.467	—	—
Retinex-Net	0.704	0.555	587.470
KinD	1.033	8.160	574.954
KinD Plus	12.716	8.275	12 238.026
Zero-DCE	0.123	0.079	84.990
EnlightenGAN	0.313	8.637	273.240
SSIENet	0.797	0.682	154.665
本文模型	0.138	0.052	55.738

综合实验结果可知，本文模型针对公共数据集和矿井自建数据集图像增强的视觉效果和评价指标整体表现优异，且在矿井智能监控应用中基本满足低照度图像增强的实时性要求。

4 结论

1) 采用改进 Zero-DCE 模型进行矿井低照度图像增强，能够解决井下复杂环境中低照度-正常照度图像配对数据集采集困难的问题。

2) 从主观和客观 2 个方面，对改进 Zero-DCE 模型的图像增强性能进行评价，结果表明，不论是公共数据集还是矿井自建数据集，该模型均能在提高图像亮度的同时，有效保留细节纹理信息，降噪效果明显，且 MSE, PSNR, SSIM, NIQE, VIF 指标整体优于对比模型。

3) 后续将进一步优化该模型，以便于进行高级矿井图像分析任务，如矿井目标检测、识别、跟踪等。

参考文献(References):

[1] 程德强, 钱建生, 郭星歌, 等. 煤矿安全生产视频 AI 识

- 别关键技术研究综述[J]. 煤炭科学技术, 2023, 51(2): 349-365.
- CHENG Deqiang, QIAN Jiansheng, GUO Xingge, et al. Review on key technologies of AI recognition for videos in coal mine[J]. Coal Science and Technology, 2023, 51(2): 349-365.
- [2] 范伟强, 刘毅. 基于自适应小波变换的煤矿降质图像模糊增强算法[J]. 煤炭学报, 2020, 45(12): 4248-4260.
- FAN Weiqiang, LIU Yi. Fuzzy enhancement algorithm of coal mine degradation image based on adaptive wavelet transform[J]. Journal of China Coal Society, 2020, 45(12): 4248-4260.
- [3] 吴佳奇, 张文琪, 陈伟, 等. 基于改进 CycleGAN 的煤矿井下低照度图像增强方法[J]. 华中科技大学学报(自然科学版), 2023, 51(5): 40-46.
- WU Jiaqi, ZHANG Wenqi, CHEN Wei, et al. Image enhancement method of underground low illumination in coal mine based on improved CycleGAN[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2023, 51(5): 40-46.
- [4] 程健, 李昊, 马昆, 等. 矿井视觉计算体系架构与关键技术[J]. 煤炭科学技术, 2023, 51(9): 202-218.
- CHENG Jian, LI Hao, MA Kun, et al. Architecture and key technologies of coalmine underground vision computing[J]. Coal Science and Technology, 2023, 51(9): 202-218.
- [5] 田会娟, 蔡敏鹏, 关涛, 等. 基于 YCbCr 颜色空间的 Retinex 低照度图像增强方法研究[J]. 光子学报, 2020, 49(2): 173-184.
- TIAN Huijuan, CAI Minpeng, GUAN Tao, et al. Low-light image enhancement method using Retinex method based on YCbCr color space[J]. Acta Photonica Sinica, 2020, 49(2): 173-184.
- [6] GUO Xiaojie, LI Yu, LING Haibin. LIME: low-light image enhancement via illumination map estimation[J]. IEEE Transactions on Image Processing : a Publication of the IEEE Signal Processing Society, 2016, 26(2): 982-993.
- [7] WEI Chen, WANG Wenjing, YANG Wenhan, et al. Deep Retinex decomposition for low-light enhancement[Z/OL]. [2024-10-11]. <https://doi.org/10.48550/arXiv.1808.04560>.
- [8] ZHANG Yonghua, ZHANG Jiawan, GUO Xiaojie. Kindling the darkness: a practical low-light image enhancer[C]. The 27th ACM International Conference, Torino, 2019. DOI: 10.1145/3343031.3350926.
- [9] ZHANG Yonghua, GUO Xiaojie, MA Jiayi, et al. Beyond brightening low-light images[J]. International Journal of Computer Vision, 2021, 129(4): 1-25.
- [10] 王满利, 张航, 李佳悦, 等. 基于深度神经网络的煤矿井下低光照图像增强算法[J]. 煤炭科学技术, 2023, 51(9): 231-241.
- WANG Manli, ZHANG Hang, LI Jiayue, et al. Deep neural network-based image enhancement algorithm for low-illumination images underground coal mines[J]. Coal Science and Technology, 2023, 51(9): 231-241.
- [11] GUO Chunle, LI Chongyi, GUO Jichang, et al. Zero-reference deep curve estimation for low-light image enhancement[C]. The IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, 2020: 1777-1786.
- [12] JIANG Yifan, GONG Xinyu, LIU Ding, et al. EnlightenGAN: deep light enhancement without paired supervision[J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2021, 30: 2340-2349.
- [13] ZHANG Yu, DI Xiaoguang, ZHANG Bin, et al. Self-supervised image enhancement network: training with low light images only[Z/OL]. [2024-10-11]. <https://doi.org/10.48550/arXiv.2002.11300>.
- [14] 田子建, 阳康, 吴佳奇, 等. 基于 LMIENet 图像增强的矿井下低光环境目标检测方法[J]. 煤炭科学技术, 2024, 52(5): 222-235.
- TIAN Zijian, YANG Kang, WU Jiaqi, et al. LMIENet enhanced object detection method for low light environment in underground mines[J]. Coal Science and Technology, 2024, 52(5): 222-235.
- [15] ZHANG Jian, CRAIGMILE P F, CRESSIE N. Loss function approaches to predict a spatial quantile and its exceedance region[J]. Technometrics, 2008, 50(2): 216-227.
- [16] YASHWANT K, VIJAYSHRI C. An image fusion approach based on adaptive fuzzy logic model with local level processing[J]. International Journal of Computer Applications, 2015, 124(1): 39-42.
- [17] BERLOFFA G, MODENA F. Income shocks, coping strategies, and consumption smoothing: an application to Indonesian data[J]. Journal of Asian Economics, 2013, 24: 158-171.
- [18] LI Zhengguo, ZHENG Jinghong, RAHARDJA S. Detail-enhanced exposure fusion[J]. IEEE Transactions on Image Processing, 2012, 21(11): 4672-4676.
- [19] XU Bing, WANG Naiyan, CHEN Tianqi, et al. Empirical evaluation of rectified activations in convolutional network[Z/OL]. [2024-10-11]. <https://doi.org/10.48550/arXiv.1505.00853>.
- [20] DING Xiaohan, GUO Yuchen, DING Guiguang, et al. ACNet: strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks[J]. International Conference on Computer Vision, Seoul, 2019. DOI: 10.1109/ICCV.2019.00200.

- [9] 雷亚国, 杨彬, 杜兆钧, 等. 大数据下机械装备故障的深度迁移诊断方法[J]. *机械工程学报*, 2019, 55(7): 1-8. LEI Yaguo, YANG Bin, DU Zhaojun, et al. Deep transfer diagnosis method for machinery in big data era[J]. *Journal of Mechanical Engineering*, 2019, 55(7): 1-8.
- [10] 陈湘源, 秦伟, 刘晏驰, 等. 融合卷积神经网络与线性回归的带式输送机托辊故障音频识别方法[J/OL]. *煤炭科学技术*: 1-9[2024-12-14]. <http://kns.cnki.net/kcms/detail/11.2402.TD.20240701.1327.001.html.html>. CHEN Xiangyuan, QIN Wei, LIU Yanchi, et al. Audio recognition method of belt conveyor roller fault based on convolutional neural network and linear regression[J/OL]. *Coal Science and Technology*: 1-9[2024-12-14]. <http://kns.cnki.net/kcms/detail/11.2402.TD.20240701.1327.001>.
- [11] 李羽蒙, 樊红. 基于 MFCC 特征与卷积神经网络的托辊故障诊断方法[J]. *武汉大学学报(工学版)*, 2024, 57(5): 691-698. LI Yumeng, FAN Hong. A fault diagnosis method of roller based on MFCC features and convolutional neural network[J]. *Engineering Journal of Wuhan University*, 2024, 57(5): 691-698.
- [12] SCHWENDEMANN S, AMJAD Z, SIKORA A. Bearing fault diagnosis with intermediate domain based layered maximum mean discrepancy: a new transfer learning approach[J]. *Engineering Applications of Artificial Intelligence*, 2021, 105. DOI: [10.1016/J.ENGAPPAI.2021.104415](https://doi.org/10.1016/j.engappai.2021.104415).
- [13] HABIC V, SEMENOV A, PASILIAO E L. Multitask deep learning for native language identification[J]. *Knowledge-based Systems*, 2020, 209. DOI: [10.1016/j.knsys.2020.106440](https://doi.org/10.1016/j.knsys.2020.106440).
- [14] LI Xuhong, GRANDVALET Y, DAVOINE F, et al. Transfer learning in computer vision tasks: remember where you come from[J]. *Image and Vision Computing*, 2020, 93. DOI: [10.1016/j.imavis.2019.103853](https://doi.org/10.1016/j.imavis.2019.103853).
- [15] 吴静然, 刘建华, 崔冉. 子域适应无监督轴承故障诊断[J]. *振动与冲击*, 2021, 40(15): 34-40. WU Jingran, LIU Jianhua, CUI Ran. Sub-domain adaptive unsupervised bearing fault diagnosis[J]. *Journal of Vibration and Shock*, 2021, 40(15): 34-40.
- [16] WANG Xu, SHEN Changqing, XIA Min, et al. Multi-scale deep intra-class transfer learning for bearing fault diagnosis[J]. *Reliability Engineering & System Safety*, 2020, 202. DOI: [10.1016/j.ress.2020.107050](https://doi.org/10.1016/j.ress.2020.107050).
- [17] ZHU Yongchun, ZHUANG Fuzhen, WANG Jindong, et al. Deep subdomain adaptation network for image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(4): 1713-1722.
- [18] FAN Cheng, SUN Yongjun, XIAO Fu, et al. Statistical investigations of transfer learning-based methodology for short-term building energy predictions[J]. *Applied Energy*, 2020, 262. DOI: [10.1016/j.apenergy.2020.114499](https://doi.org/10.1016/j.apenergy.2020.114499).
- [19] 于功也, 蔡伟东, 胡明辉, 等. 故障机理与领域自适应混合驱动的机械故障智能迁移诊断[J]. *航空学报*, 2023, 44(2): 321-332. YU Gongye, CAI Weidong, HU Minghui, et al. Intelligent migration diagnosis of mechanical faults driven by hybrid fault mechanism and domain adaptation[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(2): 321-332.
- [20] 张家安, 田家辉, 王铁成, 等. 基于改进 MFCC 算法的风力机叶片故障诊断方法[J]. *太阳能学报*, 2024, 45(1): 285-290. ZHANG Jia'an, TIAN Jiahui, WANG Tiecheng, et al. Wind turbine blade fault diagnosis method based on improved MFCC algorithm[J]. *Acta Energetica Solaris Sinica*, 2024, 45(1): 285-290.
- [21] LU Weining, LIANG Bin, CHENG Yu, et al. Deep model based domain adaptation for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(3): 2296-2305.
- [22] 赵征鹏, 李俊钢, 普园媛. 基于卷积神经网络的 Retinex 低照度图像增强[J]. *计算机科学*, 2022, 49(6): 199-209. ZHAO Zhengpeng, LI Jungang, PU Yuanyuan. Low-light image enhancement based on Retinex theory by convolutional neural network[J]. *Computer Science*, 2022, 49(6): 199-209.
- [23] SETIADI D R I M. PSNR vs SSIM: imperceptibility quality assessment for image steganography[J]. *Multimedia Tools and Applications*, 2020, 80(6): 1-22.

(上接第 64 页)

- [21] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]. *European Conference on Computer Vision*, Munich, 2018: 3-19.
- [22] 苗作华, 赵成诚, 朱良建, 等. 矿井井下非均匀照度图像增强算法[J]. *工矿自动化*, 2023, 49(11): 92-99. MIAO Zuohua, ZHAO Chengcheng, ZHU Liangjian, et al. Image enhancement algorithm for non-uniform illumination in underground mines[J]. *Journal of Mine Automation*, 2023, 49(11): 92-99.