

文章编号: 1671-251X(2023)04-0070-08

DOI: 10.13272/j.issn.1671-251x.2022080047

基于含噪 Retinex 模型的煤矿低光照图像增强方法

李正龙^{1,2}, 王宏伟^{2,3,4}, 曹文艳^{1,2}, 张夫净^{1,2}, 王宇衡^{1,2}

(1. 太原理工大学 矿业工程学院, 山西 太原 030024;

2. 太原理工大学 山西省煤矿智能装备工程研究中心, 山西 太原 030024;

3. 太原理工大学 机械与运载工程学院, 山西 太原 030024;

4. 山西焦煤集团有限责任公司 博士后工作站, 山西 太原 030024)

摘要: 低光照图像会导致许多计算机视觉任务达不到预期效果, 影响后续图像分析与智能决策。针对现有煤矿井下低光照图像增强方法未考虑图像现实噪声的问题, 提出一种基于含噪 Retinex 模型的煤矿低光照图像增强方法。建立了含噪 Retinex 模型, 利用噪声估计模块(NEM)估计现实噪声, 将原图像和估计噪声作为光照分量估计模块(IEM)和反射分量估计模块(REM)的输入, 生成光照分量与反射分量并对二者进行耦合, 同时对光照分量进行伽马校正等调整, 对耦合后的图像及调整后的光照分量进行除法运算, 得到最终的增强图像。NEM 通过 3 层 CNN 对含噪图像进行拜耳采样, 然后重构生成与原图像大小一致的三通道特征图。IEM 与 REM 均以 ResNet-34 作为图像特征提取网络, 引入多尺度非对称卷积与注意力模块(MACAM), 以增强网络的细节过滤能力及重要特征筛选能力。定性和定量评估结果表明, 该方法能够平衡光源与黑暗环境之间的关系, 降低现实噪声的影响, 在图像自然度、真实度、对比度、结构等方面均具有良好性能, 图像增强效果优于 Retinex-Net, Zero-DCE, DRBN, DSLR, TBEFN, RUAS 等模型。通过消融实验验证了 NEM 与 MACAM 的有效性。

关键词: 煤矿低光照图像; 图像增强; 含噪 Retinex 模型; 噪声估计; 拜耳采样; 多尺度非对称卷积; 注意力模块

中图分类号: TD67

文献标志码: A

A method for enhancing low light images in coal mines based on Retinex model containing noise

LI Zhenglong^{1,2}, WANG Hongwei^{2,3,4}, CAO Wenyan^{1,2}, ZHANG Fujing^{1,2}, WANG Yuheng^{1,2}

(1. College of Mining Engineering, Taiyuan University of Technology, Taiyuan 030024, China; 2. Center of Shanxi Engineering Research for Coal Mine Intelligent Equipment, Taiyuan University of Technology, Taiyuan 030024, China; 3. College of Mechanical and Vehicle Engineering, Taiyuan University of Technology, Taiyuan 030024, China; 4. Postdoctoral Workstation, Shanxi Coking Coal Group Co., Ltd., Taiyuan 030024, China)

Abstract: The low light images can lead to many computer vision tasks not achieving the expected results. This can affect subsequent image analysis and intelligent decision-making. The existing low light image enhancement methods for underground coal mines do not consider the real noise of the image. In order to solve this problem, a coal mine low light image enhancement method based on Retinex model containing noise is proposed. The Retinex model containing noise is established. The noise estimation module (NEM) is used to estimate real noise. The original image and estimated noise are used as inputs to the illumination component

收稿日期: 2022-08-16; 修回日期: 2023-03-29; 责任编辑: 胡娴。

基金项目: 国家重点研发计划项目(2020YFB1314004); 山西省揭榜招标项目(20201101008); 山西省重点研发计划项目(202102100401015)。

作者简介: 李正龙(1998—), 男, 山东潍坊人, 硕士研究生, 研究方向为机器视觉、视觉 SLAM、掘进机定位导航, E-mail: lizhenglong2293@outlook.com。通信作者: 王宏伟(1977—), 女, 黑龙江勃利人, 教授, 博士, 博士研究生导师, 主要研究方向为煤机装备智能化、人工智能与 5G+智慧矿山等, E-mail: lntuwhw@126.com。

引用格式: 李正龙, 王宏伟, 曹文艳, 等. 基于含噪 Retinex 模型的煤矿低光照图像增强方法[J]. 工矿自动化, 2023, 49(4): 70-77.

LI Zhenglong, WANG Hongwei, CAO Wenyan, et al. A method for enhancing low light images in coal mines based on Retinex model containing noise[J]. Journal of Mine Automation, 2023, 49(4): 70-77.



扫码移动阅读

estimation module (IEM) and reflection estimation module (REM) to generate and couple the illumination and reflection components. At the same time, gamma correction and other adjustments are made to the illumination components. And division operations are performed on the coupled image and adjusted illumination components to obtain the final enhanced image. NEM uses a three-layer CNN to perform Bayer sampling on noisy images. It reconstructs them to generate a three channel feature map which is the same size as the original image. Both IEM and REM use ResNet-34 as the image feature extraction network. The multi-scale asymmetric convolution and attention module (MACAM) is introduced to enhance the network's capability to filter details and important features. The qualitative and quantitative evaluation results indicate that this method can balance the relationship between light sources and dark environments, reduce real-world noise's impact, and perform well in image naturalness, realism, contrast, structure, and other aspects. The image enhancement effect is superior to models such as Retinex-Net, Zero-DCE, DRBN, DSLR, TBEFN, RUAS, etc. The effectiveness of NEM and MACAM is verified through ablation experiments.

Key words: low light image of coal mine; image enhancement; Retinex model containing noise; noise estimation; Bayer sampling; multi-scale asymmetric convolution; attention module

0 引言

煤矿视频监控系统是及时了解井下人员分布状况和机械设备运行工况的有效工具^[1-4]。煤矿井下生产过程中会产生大量粉尘,通常会喷洒大量水雾以达到降尘目的。受粉尘、水雾及光照等因素的影响,视频监控系统采集的图像多呈低光照特点。在低光照条件下,受背光、非均匀光照和弱光的影响,视频图像存在对比度低、噪声大、信息丢失、细节模糊等问题^[5]。低光照图像会导致许多计算机视觉任务(如目标检测、识别及追踪,语义分割,环境动态感知等)达不到预期效果,影响后续图像分析与智能决策。因此,研究煤矿井下低光照图像增强方法具有重要意义。

目前,针对煤矿低光照图像的增强算法主要有空域增强算法、频域增强算法、基于物理模型的增强算法、基于 Retinex 理论的增强算法等^[6]。空域增强算法根据像素对比度和亮度的概率分布,利用统计学方法对图像进行增强,难以对全局暗区和亮区进行均衡提升,对不同低光照场景的适应性较差^[7-8]。频域增强算法在频域修改图像系数对图像进行处理,再通过反变换得到增强图像,该类算法需要预先定义变换系数,并对图像进行多次空间转换,步骤较为繁琐^[9-10]。基于物理模型的增强算法利用滤波器对原图像中的光照分量进行估计,得到反射分量,并对反射分量进行空域变换,实现图像增强,该方法易导致增强图像边缘模糊,图像增强效果不理想^[11-12]。Retinex 模型具有色彩保真度高、图像增强效果更符合人眼感受的优点,但存在算法运行时间长、增强细节易丢失、色彩失真和对比度不均衡等问题。

随着深度学习技术在计算机视觉方面的应用,基于深度学习的低光照图像增强(Low-Light Image Enhancement, LLIE)技术快速发展^[13]。由于 Retinex 模型往往忽略噪声影响,结合基于深度学习的低光照图像增强算法,可通过卷积神经网络(Convolutional Neural Networks, CNN)来估计环境噪声、光照分量及反射分量。Wang Yang 等^[14]提出了一种渐进式 Retinex 网络以消除噪声影响,通过光照估计网络和噪声估计网络,以渐进式机制增强低光照图像,直至输出稳定结果。为了准确估计光照分量和反射分量, Fan Minhao 等^[15]将语义信息和 Retinex 模型结合,利用语义信息引导低光照图像估计过程,以提高对黑暗场景图像的增强性能。虽然深度学习结合 Retinex 理论的方法在分解光照分量和反射分量方面取得了一些进展,但还存在 Retinex 解耦不匹配、色彩还原差、图像失真等问题。为解决上述问题,本文提出一种基于含噪 Retinex 模型的煤矿低光照图像增强方法。利用 CNN 估计场景中的现实噪声,根据原图像和噪声估计出光照分量和反射分量,对二者进行耦合;同时对光照分量进行伽马校正等调整,对耦合后的图像及调整后的光照分量进行除法运算,得到最终的增强图像。

1 相关理论

1.1 Retinex 理论

根据 Retinex 理论,人眼视觉或摄像设备所感知的信息由物体本身的反射分量和光照分量决定^[16]。

$$S = RI \quad (1)$$

式中: S 为采集的图像; R 为反射分量; I 为环境光照分量。

根据 Retinex 的颜色恒常理论, 视觉感知到的物体颜色由物体对波长的反射能力决定, 与环境中的光照无关。因此, 若能估计环境中的光照分量 $I(x,y)$, 就可以根据颜色恒常理论, 将光照分量 $I(x,y)$ 去除, 得到物体本身的反射分量 $R(x,y)$ 。Retinex 理论如图 1 所示。




图 1 Retinex 理论

Fig. 1 Retinex theory

1.2 Retinex 解耦策略

Retinex 理论表明, 物体本身反射分量与环境中的光照分量互相耦合, 在分解二者时需要采用一定的解耦策略^[17]。Retinex 解耦策略包括直接解耦、间接解耦及改进间接解耦。直接解耦首先对图像执行分解操作, 生成反射分量和光照分量, 然后对光照分量进行调整, 最后对调整后的光照分量和反射分量重新耦合, 生成增强图像。间接解耦也是先对图像执行分解操作, 生成反射分量和光照分量, 再对光照分量进行调整, 用原图像除以调整后的光照分量, 生成增强图像。改进间接解耦是将噪声输入初始化网络, 生成光照分量和反射分量, 对 2 个分量进行耦合, 同时对光照分量进行校正, 然后对耦合后的图像及调整后的光照分量进行除法运算, 得到最终的增强图像。不同 Retinex 解耦策略如图 2 所示, 其中 \hat{I} 为调整后的光照分量, N_1 和 N_2 为噪声, 绿色框中为增强后的结果。




图 2 Retinex 解耦策略

Fig. 2 Retinex decoupling strategy

1.3 非对称卷积

CNN 是一种特殊的多层神经网络, 相比传统的卷积模式, 非对称卷积通过逼近现有正方形卷积的方式达到压缩模型和加速的目的。非对称卷积有 2 种方法近似标准卷积: 第 1 种方法将 $m \times m$ 的标准卷积等效地转换为 2 层序列: $m \times 1$ 层和 $1 \times m$ 层, 以降低网络复杂度; 第 2 种方法以非对称卷积为元素设

计深部 CNN, 如 initeption-v3^[18] 利用 1×7 和 7×1 的卷积核替代 7×7 的卷积核, 以减少图像识别参数, 进而降低运算量^[19]。本文中的非对称卷积网络采用第 1 种方法对模型进行压缩。

2 基于含噪 Retinex 模型的图像增强方法

2.1 含噪 Retinex 模型设计

含噪 Retinex 模型可表示为

$$S = RI + N \quad (2)$$

式中 N 为图像中的噪声。

传统的 Retinex 模型通常是对原图像进行高斯统计并建模得到增强概率函数, 然后与原图像进行卷积, 得到光照分量估计结果, 用原图像除以光照分量, 得到增强图像。这种基于先验概率模型的增强技术效果有限, 且没有考虑现实噪声, 鲁棒性比较差。本文通过估计低光照图像的现实噪声, 并以噪声为输入, 采用非对称卷积和注意力模块同时估计光照分量和反射分量。

含噪 Retinex 模型框架如图 3(a) 所示, 包括图像输入、噪声估计、光照分量估计、反射分量估计、光照分量调整、图像增强、图像输出 7 个部分。输入原图像, 建立图像噪声模型, 利用噪声估计模块 (Noise Estimation Module, NEM) 估计现实噪声; 再将图像和估计噪声作为光照分量估计模块 (Illumination Estimation Module, IEM) 和反射分量估计模块 (Reflection Estimation Module, REM) 的输入。IEM 与 REM 均以 ResNet-34 作为图像特征提取网络, 如图 3(b) 所示。IEM 引入多尺度非对称卷积与注意力模块 (Multi-scale Asymmetric Convolution and Attention Module, MACAM), 增强了网络的细节过滤能力及重要特征筛选能力。REM 基本结构及估计过程与 IEM 相似, 但由于反射分量包含较多高频信息, 所以 REM 在注意力模块中增加了 3 层结构: Conv(3×3) (卷积层) + ReLU (激活函数层) + Maxpool (最大池化层)。通过 IEM 与 REM 估计出光照分量 I 与反射分量 R 后, 将二者耦合, 得到图像 S , 对光照分量进行伽马校正等调整得到 \hat{I} , 将图像 S 去噪后除以 \hat{I} , 得到最终的增强图像。

2.2 现实噪声估计

噪声 N 对 Retinex 解耦过程中 R, I 的估计具有重要影响, 本文设计了一个 CNN 来估计噪声水平, 并加入 IEM, REM 中。对于噪声 N 的估计, 传统方法是将噪声建模为加性高斯白噪声 (Additive White Gaussian Noise, AWGN) 或 AWGN 与不同噪声水平的混合噪声。在低光照条件或高感光度模式下拍摄

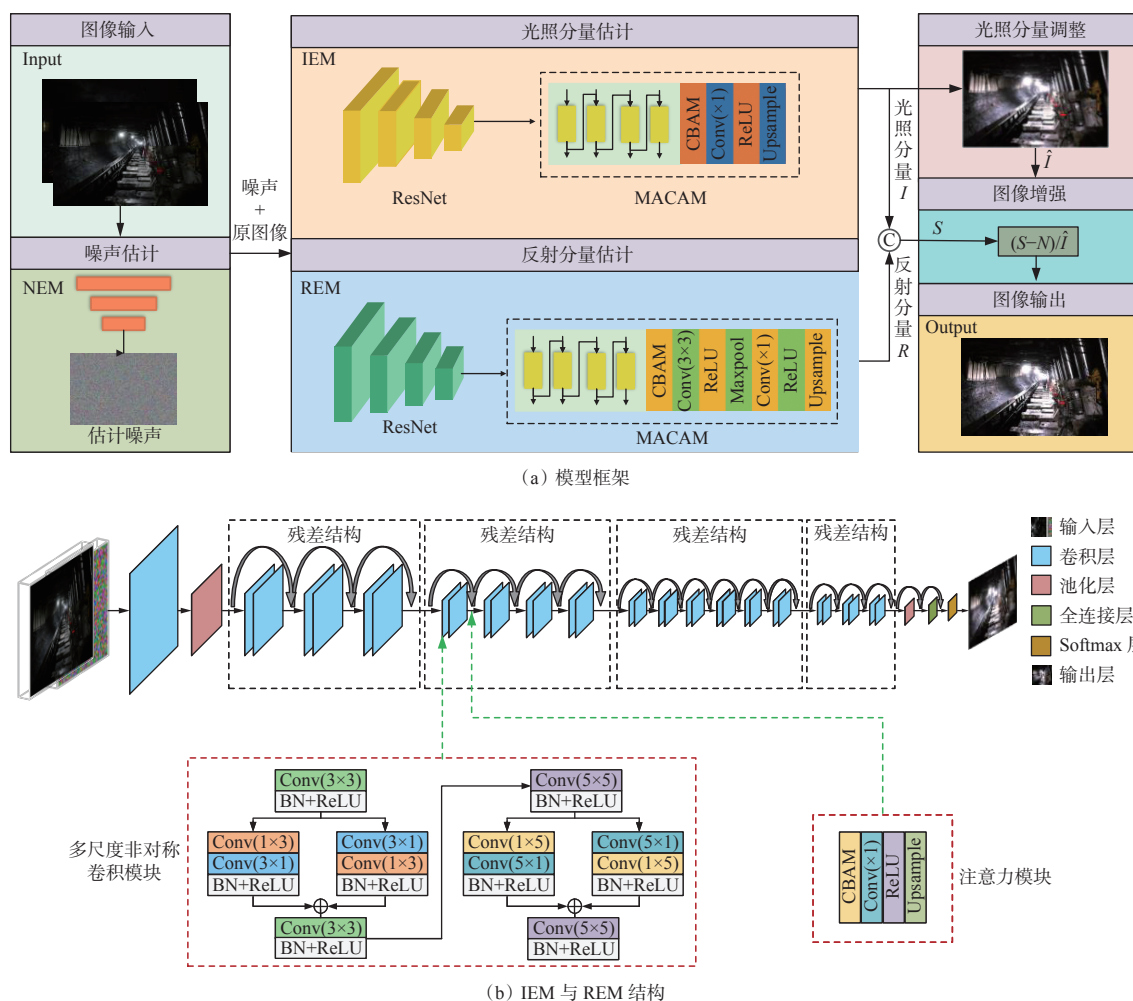


图3 含噪 Retinex 模型

Fig. 3 Retinex model with noise

的图像会引入现实场景的噪声,这种噪声与图像像素相关,同时会受相机参数设置影响,其复杂度比 AWGN 大得多,传统的 AWGN 去除方法不能直接处理这种噪声。

由于现实噪声标准差表现出拜耳模式统计特征,所以估计噪声水平时,采用拜耳模式进行下采样操作,如图4所示。分别提取含噪图像 R, G, B 三通道的值(即隔行提取近似值),生成新的特征图,使得3个通道的特征图标准差均呈现连续性,以降低训练难度。




图4 拜耳采样

Fig. 4 Bayer downsampling

现实噪声模型为

$$N = f(Z + N_s + N_c) + N_q \quad (3)$$

式中: f 为相机内参; Z 为辐射照度; N_s 为相机自身噪声; N_c 为电子噪声; N_q 为环境噪声。

NEM 结构如图5所示。先通过3层 CNN 对含噪图像进行拜耳采样,再重构生成与原图像大小一致的三通道特征图。为了学习图像真实噪声特征,需将输入图像特征与噪声估计特征融合,生成 $H \times W \times 6$ 的特征图。融合特征经过 Global Pooling (全局池化层)、ReLU 和 FC (全连接层) 后,使用 3×3 和 7×7 多尺度卷积模块扩大卷积滤波器的感受野,平衡去噪性能并计算复杂度。经过卷积与 Softmax 处理后得到与原始图像对应的噪声图。

2.3 低光照特征融合

2.3.1 非对称卷积模块

为高效提取低光照图像特征,设计了非对称卷积模块(Asymmetric Convolution Module, ACM),该模块以 ResNet 为基础网络。非对称网络能够在降低计算负载的同时,显著增强网络特征提取能力。ACM




图 5 NEM 结构

Fig. 5 Structure of noise estimation module

采用 2 层非对称结构, 卷积尺寸分别为 3×3 与 5×5 , 每个非对称结构包括 2 个并列非对称网络。如在 3×3 非对称结构中, 输入特征首先经过 $\text{Conv}(3 \times 3)$ 卷积模块, 然后经过并列非对称网络, 即 $\text{Conv}(1 \times 3)$ 与 $\text{Conv}(3 \times 1)$, $\text{Conv}(3 \times 1)$ 与 $\text{Conv}(1 \times 3)$, 最后将 2 个并列非对称网络通过 $\text{Conv}(3 \times 3)$ 卷积模块融合, 输出非对称卷积结果。ACM 能够从不同规模的特征细节中获得信息, 恢复低光照图像的局部细节特征。

2.3.2 通道注意力模块

在低光照图像中, 通常每个图像通道对应像素的亮度增强权重是统一的, 但这会使得有局部光源的图像曝光过度或失真。通道注意力机制能够从特征中筛选出关键信息, 通过调节权重大小, 使网络关注关键信息。本文引入通道注意力机制对局部光源进行抑制, 同时对局部极暗区域进行增强, 从而达到均衡增强的效果。

卷积块的注意力模块 (Convolutional Block Attention Module, CBAM) 作为一种轻量注意力网络模块, 能够从空间和通道 2 个维度计算特征图和注意力图。输入特征图 F 与通道注意力特征图 M_c 相乘, 得到特征图 F' , F' 再与空间注意力特征图 M_s 相乘, 得到最终输出特征图 F'' 。

$$F' = M_c(F)F \quad (4)$$

$$F'' = M_s(F')F' \quad (5)$$

CBAM 可以作为特征融合模块加入主干网络中, 将 ACM 输出的特征与注意力引导机制进行融合, 使得网络能够从特征中筛选出重要特征信息。

2.4 损失函数设计

为了减小真实值与预测值之间的误差, 设计了图像重建损失函数:

$$L_{\text{recon}} = \|G_I(N_1)G_R(N_2) - S\|_2^2 \quad (6)$$

式中 G_I 和 G_R 分别为 IEM 和 REM 的输出。

初始光照分量 I_0 不能代表真实光照分布, 为了约

束光照的一致性, 采用光照一致性损失函数^[17]:

$$L_{\text{ill}} = \|G_I(N_1) - I_0\|_1 \quad (7)$$

使用光照平滑损失函数对光照边缘进行平滑约束:

$$L_{\text{ill-smooth}} = \|Q\nabla G_I(N_1)\|_1 \quad (8)$$

式中: Q 为光滑梯度权重; ∇ 为一阶微分算子。

为了将反射分量的噪声降到最低, 定义反射分量损失函数:

$$L_{\text{ref}} = \|\nabla G_R(N_2)\|_1 \quad (9)$$

总的损失函数为

$$L_{\text{total}} = L_{\text{recon}} + L_{\text{ill}} + L_{\text{ref}} + L_{\text{ill-smooth}} \quad (10)$$

3 实验结果与分析

使用 Pytorch 框架实现 Retinex 模型, 用于模型训练的计算机配置如下: Ubuntu18 操作系统, 32 GiB 内存, 3.9 GHz CPU, NVIDIA GTX 2080Ti。训练网络模型的批大小设为 20, 迭代轮次为 60, 使用学习率为 10^{-3} 的 Adam 优化器进行参数优化。为了训练网络模型, 制作了煤矿场景数据集, 包括 100 张矿井图像、150 张矿井设备图像、100 张巷道图像和 150 张多光源场景图像, 共计 500 幅图像。

3.1 定性评估

为了验证本文方法的有效性, 选用 6 种模型对 4 种场景的实验图像进行分析处理, 并与本文方法处理结果进行对比。6 种模型分别为 Retinex-Net^[20], Zero-DCE^[21], DRBN^[22], DSLR^[23], TBEFN^[24], RUAS^[25]。4 种场景分别为井下人员工作场景(场景 1)、巷道多光源场景(场景 2)、有反光带场景(场景 3)、煤矿设备场景(场景 4)。各场景中的光源均为非自然光, 有 1 个或者多个光源, 且有些图像中物体周围背景为黑色。各模型的图像增强结果如图 6 所示。Retinex-Net 会在黑暗区域产生噪声、伪影, 颜色对比度明显失真。Zero-DCE 的增强质量明显提高, 但增强图像的明亮区域趋于饱和。DRBN 在黑暗部分和照度较高部分对比度调节效果较差。DSLR 可以将低质量图像还原为高质量图像, 但无法去除噪声。TBEFN 通过一种具有高度适应性的双分支模糊策略来增强低光照图像, 在对比度较高的图像中增强效果显著, 但色彩恢复效果不理想。RUAS 可以保持自然度, 并提高对比度, 但在光照较强的地方易出现曝光过度的情况。与其他 6 种模型对比可以看出, 本文方法能够平衡光源与黑暗环境之间的关系, 降低现实噪声对图像增强效果的影响, 同时能够平衡对比度和饱和度, 色彩更加真实。




图 6 煤矿不同场景下 6 种模型与本文方法的对比

Fig. 6 Comparison between six models and the method presented in this paper

选择具有代表性的巷道图像进行测试, 结果如图 7 所示。该场景中图像为逆光拍摄, 存在强光源与弱光源, 降低了图像对比度, 掩盖了黑暗背景中的图像纹理, 增加了背景中的噪声, 并且使得图像存在部分颜色失真。可看出 Retinex-Net, Zero-DCE, RUAS 的处理结果均受噪声影响而严重失真; RUAS 对光源进行了错误估计, 导致图像中其他信息被淹没; DSLR 方法虽然能够较好地抑制逆光光源, 同时恢复巷道周围图像, 但黑暗部分颜色失真。本文方法能够很好地对图像中光源和黑暗部分进行估计, 抑制噪声, 恢复真实图像。

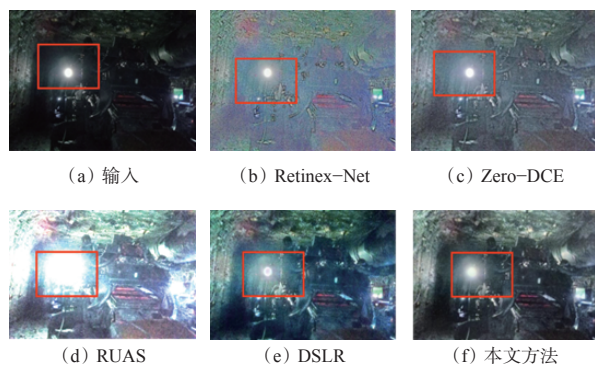


图 7 多光源、逆光条件下巷道图像增强效果对比

Fig. 7 Comparison of image enhancement effects in roadway under multiple light sources and backlight conditions

3.2 定量评估

采用自然图像质量评估指标 (Naturalness Image Quality Evaluator, NIQE)^[26]、对比度失真的无参考图像质量指标 (No-reference Image Quality Metric for Contrast distortion, NIQMC)^[27]、峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性 (Structural SIMilarity, SSIM) 4 种指标对各类算法的增强效果进行定量评估。其中, NIQE 利用图像的自然统计特征评价图像质量, 其值越低, 表示图像自然度越好, 该

指标与人眼主观质量评价一致性较好; NIQMC 用于对比度失真图像的质量评估, 其值越高, 表示图像质量越好; PSNR 是衡量图像失真程度或噪声水平的客观指标, 其值越大, 图像失真度越小; SSIM 从亮度、对比度和结构 3 个方面衡量图像的相似性, 其值越大, 图像失真度越小。

选择矿井图像、矿井中设备图像、巷道图像、多光源场景图像 4 组 (共计 500 张) 构建数据集, 其中 80% 为训练集, 20% 为测试集。实验结果见表 1。针对 NIQE, NIQMC, PSNR, SSIM, 本文方法相较于 Retinex-Net 模型平均提升了 -4.06%, 27.61%, 35.63%, 37.86%; 相较于 Zero-DCE 模型平均提升了 -9.9%, 21.94%, 32.06%, 36.56%; 相较于 DRBN 模型平均提升了 -7.11%, 13.92%, 20.67%, 16.56%; 相较于 DSLR 模型平均提升了 -7.65%, 8.74%, 30.39%, 37.96%; 相较于 TBEFN 模型平均提升了 -6.22%, 10.49%, 6.33%, 29.24%; 相较于 RUAS 模型平均提升了 -6.77%, 9.76%, 0.98%, 8.09%。可看出本文方法的 NIQE, NIQMC, PSNR, SSIM 均优于其他模型, 在图像自然度、真实度、对比度、结构等方面均具有良好性能, 整体图像增强效果最好。

3.3 消融实验

为进一步验证 NEM 与 MACAM 的有效性, 设计了消融实验, 对没有融合 NEM 与 MACAM 的基础模型、融合 NEM 的模型、融合 MACAM 的模型、融合 NEM 与 MACAM 的改进模型进行对比分析。结果见表 2。对于 NIQE, NIQMC, PSNR, SSIM 指标, 融合 NEM 与 MACAM 的改进模型相较于 ResNet 平均提升了 -3.88%, 26.86%, 34.24%, 37.25%; 相较于 ResNet+NEM 平均提升了 -2.4%, 13.31%, 12.63%, 22.81%; 相较于 ResNet+MACAM 平均提升了 -1.23%,

表 1 不同模型客观评价结果

Table 1 Objective evaluation results of different models

图像集	模型	NIQE	NIQMC	PSNR	SSIM
矿井图像	Retinex-Net	3.37	4.88	14.40	0.59
	Zero-DCE	3.62	4.67	15.51	0.58
	DRBN	3.54	4.98	15.32	0.70
	DSLR	3.68	5.26	13.93	0.49
	TBEFN	3.57	5.44	17.14	0.76
	RUAS	3.43	5.18	18.32	0.72
	本文	3.30	5.63	18.5	0.74
矿井设备图像	Retinex-Net	3.42	4.64	13.09	0.57
	Zero-DCE	3.69	4.83	14.58	0.55
	DRBN	3.50	5.03	15.66	0.66
	DSLR	3.66	5.64	15.38	0.78
	TBEFN	3.60	5.40	17.42	0.42
	RUAS	3.52	5.29	18.55	0.70
	本文	3.28	5.78	18.03	0.77
巷道图像	Retinex-Net	3.53	4.66	13.88	0.56
	Zero-DCE	3.76	4.83	13.56	0.54
	DRBN	3.53	4.95	15.32	0.68
	DSLR	3.60	5.18	14.95	0.73
	TBEFN	3.42	5.26	17.83	0.69
	RUAS	3.59	5.55	18.66	0.71
	本文	3.33	5.83	18.92	0.80
多光源场景图像	Retinex-Net	3.40	4.03	13.58	0.52
	Zero-DCE	3.54	4.62	13.04	0.59
	DRBN	3.60	5.33	15.42	0.61
	DSLR	3.33	5.19	13.11	0.40
	TBEFN	3.45	4.86	17.64	0.64
	RUAS	3.58	5.05	18.22	0.72
	本文	3.25	5.86	19.01	0.77

6.64%, 4.54%, 12.90%。可看出改进模型对低光照图像的整体增强效果均优于其他模型。

表 2 消融实验结果

Table 2 Results of ablation experiment

模型	NIQE	NIQMC	PSNR	SSIM
ResNet	3.35	4.43	14.02	0.51
ResNet+NEM	3.30	4.96	16.71	0.57
ResNet+MACAM	3.26	5.27	17.83	0.62
ResNet+NEM+MACAM	3.22	5.62	18.82	0.70

4 结论

1) 提出一种基于含噪 Retinex 模型的煤矿低光照图像增强方法。通过建立图像噪声模型估计场景

中真实环境噪声,并将其用于光照分量和反射分量估计。分量估计模块以 ResNet 作为基础网络,融合 ACM 与通道注意力模块,提取低光照图像中的细节特征,并对图像中的光源区域与黑暗区域进行注意力调节。对光照分量和反射分量进行耦合及相关处理,得到增强图像。

2) 定性评估结果表明,本文方法能够平衡光源与黑暗环境之间的关系,降低现实噪声对图像增强效果的影响,同时能够平衡对比度和饱和度,相比 Retinex-Net 等模型,色彩更加真实。

3) 采用 NIQE, NIQMC, PSNR, SSIM 作为评价指标进行定量评估,结果表明,本文方法在图像自然度、真实度、对比度、结构等方面均具有良好性能,图像增强效果优于 Retinex-Net 等模型。

4) 消融实验结果表明,融合 NEM 与 MACAM 模块的改进模型优于 ResNet 模型、ResNet+NEM 模型、ResNet+MACAM 模型,验证了 NEM 与 MACAM 模块的有效性。

参考文献(References):

- [1] 赵谦. 煤矿井下动态目标视频监控图像处理研究[D]. 西安: 西安科技大学, 2014.
ZHAO Qian. Study on video monitoring and image processing of coal mine dynamic targets[D]. Xi'an: Xi'an University of Science and Technology, 2014.
- [2] 孙继平. 煤矿安全生产监控与通信技术[J]. 煤炭学报, 2010, 35(11): 1925-1929.
SUN Jiping. Technologies of monitoring and communication in the coal mine[J]. Journal of China Coal Society, 2010, 35(11): 1925-1929.
- [3] 孙继平. 煤矿事故分析与煤矿大数据和物联网[J]. 工矿自动化, 2015, 41(3): 1-5.
SUN Jiping. Accident analysis and big data and Internet of things in coal mine[J]. Industry and Mine Automation, 2015, 41(3): 1-5.
- [4] 孙继平, 杜东璧. 基于随机特征的矿井视频图像中的人员跟踪技术[J]. 煤炭科学技术, 2015, 43(11): 91-94.
SUN Jiping, DU Dongbi. Tracing technology of personnel in mine video images based on random features[J]. Coal Science and Technology, 2015, 43(11): 91-94.
- [5] 张谢华, 张申, 方帅, 等. 煤矿智能视频监控中雾尘图像的清晰化研究[J]. 煤炭学报, 2014, 39(1): 198-204.
ZHANG Xiehua, ZHANG Shen, FANG Shuai, et al. Clearing research on fog and dust images in coal mine intelligent video surveillance[J]. Journal of China Coal Society, 2014, 39(1): 198-204.
- [6] 王殿伟, 韩鹏飞, 范九伦, 等. 基于光照-反射成像模型和形态学操作的多谱段图像增强算法[J]. 物理学报,

- 2018, 67(21): 104-114.
- WANG Dianwei, HAN Pengfei, FAN Jiulun, et al. Multispectral image enhancement based on illuminance-reflection imaging model and morphology operation[J]. *Acta Physica Sinica*, 2018, 67(21): 104-114.
- [7] 何畏. 基于改进直方图的低照度图像增强算法[J]. *计算机科学*, 2015, 42(增刊1): 241-242, 262.
- HE Wei. Low-light image enhancement based on improve histogram[J]. *Computer Science*, 2015, 42(S1): 241-242, 262.
- [8] ZUO Chao, CHEN Qian, SUI Xiubao. Range limited bi-histogram equalization for image contrast enhancement[J]. *Optik-International Journal for Light and Electron Optics*, 2013, 124(5): 425-431.
- [9] 刘晓阳, 乔通, 乔智. 基于双边滤波和Retinex算法的矿井图像增强方法[J]. *工矿自动化*, 2017, 43(2): 49-54.
- LIU Xiaoyang, QIAO Tong, QIAO Zhi. Image enhancement method of mine based on bilateral filtering and Retinex algorithm[J]. *Industry and Mine Automation*, 2017, 43(2): 49-54.
- [10] 范凌云, 梁修荣. 基于小波分解子带直方图匹配的矿井视频图像增强方法[J]. *金属矿山*, 2016(6): 130-133.
- FAN Lingyun, LIANG Xiurong. Mine video images enhancement method based on the histogram matching method of the sub-bands of wavelet transform[J]. *Metal Mine*, 2016(6): 130-133.
- [11] 程德强, 郑珍, 姜海龙. 一种煤矿井下图像增强算法[J]. *工矿自动化*, 2015, 41(12): 31-34.
- CHENG Deqiang, ZHENG Zhen, JIANG Hailong. An image enhancement algorithm for coal mine underground[J]. *Industry and Mine Automation*, 2015, 41(12): 31-34.
- [12] 智宁, 毛善君, 李梅. 基于照度调整的矿井非均匀照度视频图像增强算法[J]. *煤炭学报*, 2017, 42(8): 2190-2197.
- ZHI Ning, MAO Shanjun, LI Mei. Enhancement algorithm based on illumination adjustment for non-uniform illuminance video images in coal mine[J]. *Journal of China Coal Society*, 2017, 42(8): 2190-2197.
- [13] LYU Feifan, LU Feng, WU Jianhua, et al. MBLLEN: low-light image/video enhancement using CNNs[C]. *British Machine Vision Conference*, Newcastle, 2018: 220-233.
- [14] WANG Yang, CAO Yang, ZHA Zhengjun, et al. Progressive retinex: mutually reinforced illumination-noise perception network for low light image enhancement[C]. *Proceedings of the 27th ACM International Conference on Multimedia*, Nice, 2019: 2015-2023.
- [15] FAN Minhao, WANG Wenjing, YANG Wenhan, et al. Integrating semantic segmentation and Retinex model for low-light image enhancement[C]. *Proceedings of the 28th ACM International Conference on Multimedia*, Seattle, 2020: 2317-2325.
- [16] 樊占文, 刘波. 基于改进的Retinex低照度图像自适应增强技术研究[J]. *工矿自动化*, 2021, 47(增刊1): 126-130.
- FAN Zhanwen, LIU Bo. Research on adaptive enhancement technology of low illumination image based on improved Retinex[J]. *Industry and Mine Automation*, 2021, 47(S1): 126-130.
- [17] ZHAO Zunjin, XIONG Bangshu, WANG Lei, et al. RetinexDIP: a unified deep framework for low-light image enhancement[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2022, 32(3): 1076-1088.
- [18] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016: 2818-2826.
- [19] DING Xiaohan, GUO Yuchen, DING Guiguang, et al. ACNet: strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks[C]. *IEEE/CVF International Conference on Computer Vision*, Seoul, 2019: 1911-1920.
- [20] WEI Chen, WANG Wenjing, YANG Wenhan, et al. Deep Retinex decomposition for low-light enhancement [C]. *British Machine Vision Conference*, 2018.
- [21] GUO Chunle, LI Chongyi, GUO Jichang, et al. Zero-reference deep curve estimation for low-light image enhancement[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 2020: 1777-1786.
- [22] YANG Wenhan, WANG Shiqi, FANG Yuming, et al. From fidelity to perceptual quality: a semi-supervised approach for low-light image enhancement[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 2020: 3060-3069.
- [23] LIM S, KIM W. DSLR: deep stacked laplacian restorer for low-light image enhancement[J]. *IEEE Transactions on Multimedia*, 2020, 23: 4272-4284.
- [24] LU Kun, ZHANG Lihong. TBEFN: a two-branch exposure-fusion network for low-light image enhancement[J]. *IEEE Transactions on Multimedia*, 2020, 23: 4093-4105.
- [25] LIU Risheng, MA Long, ZHANG Jia'ao, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Nashville, 2021.
- [26] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a "completely blind" image quality analyzer[J]. *IEEE Signal Processing Letters*, 2013, 20(3): 209-212.
- [27] GU Ke, LIN Weisi, ZHAI Guangtao, et al. No-reference quality metric of contrast-distorted images based on information maximization[J]. *IEEE Transactions on Cybernetics*, 2017, 47(12): 4559-4565.