



基于深度神经网络的煤矿井下低光照图像增强算法

王满利 张航 李佳悦 张长森

引用本文:

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. Deep neural network-based image enhancement algorithm for low-illumination images underground coal mines[J]. Coal Science and Technology, 2023, 51(9): 231-241.

在线阅读 View online: <https://doi.org/10.12438/cst.2022-1626>

您可能感兴趣的其他文章

Articles you may be interested in

基于Transformer和自适应特征融合的矿井低照度图像亮度提升和细节增强方法

An illuminance improvement and details enhancement method on coal mine low-light images based on Transformer and adaptive feature fusion

煤炭科学技术. 2024, 52(1): 297-310 <https://doi.org/10.13199/j.cnki.cst.2023-0112>

基于LMIENet图像增强的矿井下低光环境目标检测方法

LMIENet enhanced object detection method for low light environment in underground mines

煤炭科学技术. 2024, 52(5): 222-235 <https://doi.org/10.12438/cst.2023-0675>

基于深度神经网络的煤岩显微图像划痕检测与修复

Scratch detection and restoration of coal photomicrograph via deep neural network

煤炭科学技术. 2023, 51(S2): 275-284 <https://doi.org/10.13199/j.cnki.cst.2023-0058>

基于同态滤波方法的煤矿井下图像增强技术研究

Research on coal mine underground image recognition technology based on homomorphic filtering method

煤炭科学技术. 2023, 51(3): 241-250 <https://doi.org/10.13199/j.cnki.cst.2021-0774>

基于深度学习的多产品煤料图像分类方法研究

Study on multi-product coal image classification method based on deep learning

煤炭科学技术. 2021, 49(9): 117-123 <http://www.mtkxjs.com.cn/article/id/3ceaf1e6-7be5-4bd9-8238-18b18fe8b9c1>

基于遗传算法与BP神经网络的支架跟机自动化研究

Research on automation of support based on genetic algorithm and BP neural network

煤炭科学技术. 2021, 49(1): 272-277 <https://doi.org/10.13199/j.cnki.cst.2021.01.024>



关注微信公众号, 获得更多资讯信息



移动扫码阅读

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.

基于深度神经网络的煤矿井下低光照图像增强算法

王满利,张航,李佳悦,张长森

(河南理工大学 物理与电子信息学院, 河南 焦作 454000)

摘要: 由于煤矿井下空间环境的复杂性与恶劣的光照条件, 视觉设备获取的图像容易存在对比度不足、纹理细节差等问题, 严重影响了视觉设备的工作可靠性, 限制了进一步的基于图像的智能视觉应用。为提高矿井下低照度图像的对比度, 同时强化其纹理细节, 提出一种基于深度神经网络的矿井下低光照图像增强模型, 该模型包含有 3 个子网络, 分别为分解网络、光照调整网络和反射重构网络。分解网络将煤矿井下图像分解为光照分量和反射分量; 光照调整网络利用深度可分离卷积结构有效减少了模型的参数, 强化了网络特征提取能力, 此外, 引入了 MobileNet 网络结构, 进一步使光照调整网络轻量化, 同时保持其特征提取精度, 有效实现光照分量对比度调整; 反射重构网络引入了残差网络结构, 提升了网络特征学习性能与反射分量纹理细节恢复能力; 最后, 将处理过后的光照分量和反射分量基于 Retinex 理论融合, 获得增强图像, 实现矿井下图像的对比度提高与细节的增强, 克服了现有增强算法中所存在的增强图像细节丢失、边缘模糊、对比度和清晰度不足等问题。数值试验表明, 提出的模型能够在提高矿井下图像对比度的同时有效强化图像的纹理细节, 并且具有良好的稳定性和鲁棒性, 能够很好地满足煤矿井下低光照图像增强的需求。

关键词: 图像增强; 图像分解; Retinex 理论; 亮度调整; 卷积神经网络

中图分类号: TP391.41; TD67

文献标志码: A

文章编号: 0253-2336(2023)09-0231-11

Deep neural network-based image enhancement algorithm for low-illumination images underground coal mines

WANG Manli, ZHANG Hang, LI Jiayue, ZHANG Changsen

(School of Physics & Electronic Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: Due to the complexity of the spatial environment and poor lighting conditions in underground coal mines, the images obtained by vision devices are prone to problems such as insufficient contrast and poor texture details, which seriously affect the reliability of the work of vision devices and limit further image-based intelligent applications. To improve the contrast of low-illumination images in underground mines while enhancing their texture details, a deep neural network-based low-illumination image enhancement model is proposed, which contains three sub-networks, namely, decomposition network, illumination adjustment network and reflection reconstruction network. The decomposition network decomposes the underground coal mine image into light and reflection components; the light adjustment network effectively reduces the parameters of the model using depth-separable convolutional structure and strengthens the feature extraction ability of the network; in addition, the MobileNet network structure is introduced to further lighten the light adjustment network while maintaining its feature extraction accuracy and effectively realizing the contrast adjustment of light components; the reflection reconstruction network introduces a residual network structure to improve the contrast adjustment of light components. Finally, the processed illumination and reflection components are fused based on Retinex theory to obtain enhanced images, which achieve contrast enhancement and detail enhancement of underground mine images, overcoming the problems of detail loss, blurred edges, and lack of con-

收稿日期: 2022-10-07

责任编辑: 周子博

DOI: 10.12438/cst.2022-1626

基金项目: 国家自然科学基金资助项目(52074305); 河南省科技攻关资助项目(212102210005); 山西省重点研发计划资助项目(2020XXX001)

作者简介: 王满利(1981—), 男, 河南焦作人, 副教授, 博士。E-mail: wml920@163.com

通讯作者: 张航(1998—), 男, 河南新乡人, 硕士研究生。E-mail: zh15225981618@163.com

trast and clarity of the enhanced image that exist in existing enhancement algorithms. Numerical experiments show that the proposed model can effectively enhance the texture details of the image while improving the contrast of underground mine images, and has good stability and robustness, which can well meet the needs of low-light image enhancement in coal mines.

Key words: image enhancement; image decomposition; retinex theory; illumination adjustment; convolutional neural networks

0 引 言

随着煤炭科学开采理论的发展^[1],智能化无人开采技术稳步推进,越来越多的数字图像、视频设备应用于矿井下,用来进行煤炭识别、危险行为识别和灾害警报等重要任务,但是由于这些设备需要依赖良好的正常光输入图像,而矿井下环境复杂,光照条件差,这些都可能会导致采集的图像对比度低、细节损失严重,严重影响了数字图像、视频设备的工作可靠性,为提高矿井下图像的质量,图像增强成为建设智慧矿山需要攻克的关键环节。目前低光照图像增强领域研究的热点主要包括基于模型的传统增强方法和基于深度机器学习的增强网络。

基于模型的方法主要集中在直方图均衡化和基于 Retinex 理论的方法。直方图均衡化的方法容易引起图像过增强,影响图像的视觉质量,随着理论与技术的不断发展,研究热点逐渐转移至基于 Retinex 理论的方法。Retinex 理论认为成像设备采集到的图像可分为光照分量和反射分量,反射分量由物体本身的反射性质决定的,实现图像增强就是通过去除图像的场景光照信息,消除光照分量的干扰,获取反射图像分量。GUO 等^[2]基于 Retinex 理论提出 LIME 算法,选取输入图像各像素通道中的最大值,对光照图初始化处理,再用结构化的先验知识对光照图进行处理,将反射图的输出作为增强结果,但容易出现过增强的现象。SHU 等^[3]提出名为 NPE 的算法,在增强图像对比度的同时保持了照明的自然度,但没有考虑不同场景中照明的关系。CHULWOO 等^[4]提出一个用于低光照图像增强的多曝光融合框架,采用双曝光融合算法,来提供准确的对比度和照度增强,但增强结果亮度较低。LI 等^[5]基于 Retinex 理论,提出 RRM 算法,它采用基于增广 Lagrange 乘子的 ADM 算法代替对数变换,考虑噪声的影响,提出 Robust Retinex 模型,首次对噪声进行预测,同时估计反射图和分段平滑的照明图来进行图像增强,但增强结果不够清晰。基于去雾的算法^[6]利用了光照不足的图像与有雾环境下图像之间的反向联系来达到低光照图像增强的效果。

虽然传统的增强算法在图像增强领域取得了良好的成效,但随着机器学习的快速发展,基于深度学

习的网络在图像增强视觉任务中表现出更为优越的性能。其中,文献 [7] 在去噪自编码的基础上提出一种堆叠式去噪自编码来实现低光照图像增强和去噪功能,但只针对单通道灰度图。文献 [8] 提出的 MBLLEN 网络,通过 CNN 卷积层将图像丰富的特征提前到不同的层次,使用多个子网同时进行增强,最后将多分支输出的结果融合成最终的增强图像,但算法的运行时间过长。文献 [9] 提出的 TBEFN 网络,估计了两个分支的一个传递函数,可以得到两个增强结果,然后采用一种简单的平均方法对两幅图像进行融合,并通过一个细化单元进一步细化结果,但网络的训练过程较为复杂。文献 [10] 提出的 GLAD 网络,首先基于全局先验和原始输入图像,再采用卷积网络进行细节重建,得到增强结果,但增强结果的清晰度不够。Retinex-Net 网络^[11]是基于 Retinex 理论深度学习网络模型在低光照图像增强领域的首次尝试,通过一个分解网络将图像分解成光照图和反射图,然后对光照图单独进行增强,但增强结果容易出现颜色失真的现象。同样受 Retinex 理论的启发,文献 [12] 提出了一种新颖的渐进式 Retinex 网络框架,而后文献 [13] 又在此基础上对反射模块进行改进。文献 [14] 受到 Retinex 模型和信息熵理论的启发,提出一个基于 Retinex 的最大熵模型 (DLN),来分解光照度和反射率,但增强后的图像容易出现细节损失。由于矿井下成像环境光照条件差,导致目前的多数增强网络不能在提升图像对比度的同时保持良好的纹理细节。

尽管有很多优越的低光照增强算法被提出,但由于矿井下环境的复杂性、图像的特殊性,以及缺少相应的数据集,未能出现一种效果显著的针对矿井下图像增强的模型。

鉴于以上分析,提出一种基于深度神经网络的矿井下低光照图像增强算法模型,该模型包含有 3 个子网络,分别为分解网络、光照调整网络和反射重构网络。分解网络将输入的煤矿井下图像分解为对应的光照图和反射图;光照调整网络结构利用深度可分离卷积有效减少了模型的参数,强化了网络的特征提取能力,从而对光照图进行更好的亮度调整;此外,引入 MobileNet 网络结构,进一步使光照调整网络轻量化,并保持其特征提取精度,有效实现光照

分量对比度调整；反射重构网络加入了残差网络结构，提升了网络特征学习性能与反射分量纹理细节恢复能力。最后，将处理过后的光照图和反射图基于 Retinex 理论进行融合，来实现矿井下图像的对比度提高和细节的增强，克服了现有增强算法存在的增强图像细节丢失、边缘模糊、对比度和清晰度不足的问题，算法在提高增强图像的对比度情况下，充分保留增强图像的细节与边缘信息。

1 模型原理

1.1 总体网络结构

由于矿井下的复杂环境，导致矿井下图像容易出现光照不足的问题和退化现象，为了解决这些问

题，构建出一种如图 1 所示的基于深度神经网络的图像增强模型，该网络主要由 2 个分支组成，分别是光照分量分支和反射分量分支，其中，光照分量分支由分解网络模块 (Decomposition Module)、光照调整网络模块 (Illumination Adjustment Module) 构成，反射分量分支由分解网络模块和反射重构网络模块 (Reflection Restoration Module) 构成。输入的矿井下图像进入分解网络模块，分解为光照图和反射图，再分别通过光照调整网络模块和反射重构模块进行亮度调整和细节增强。该网络在光照调整网络模块中引入了深度可分离卷积，以便进行更好地提取特征；在反射重构网络模块使用了残差结构，更好地保存了原图的纹理细节。

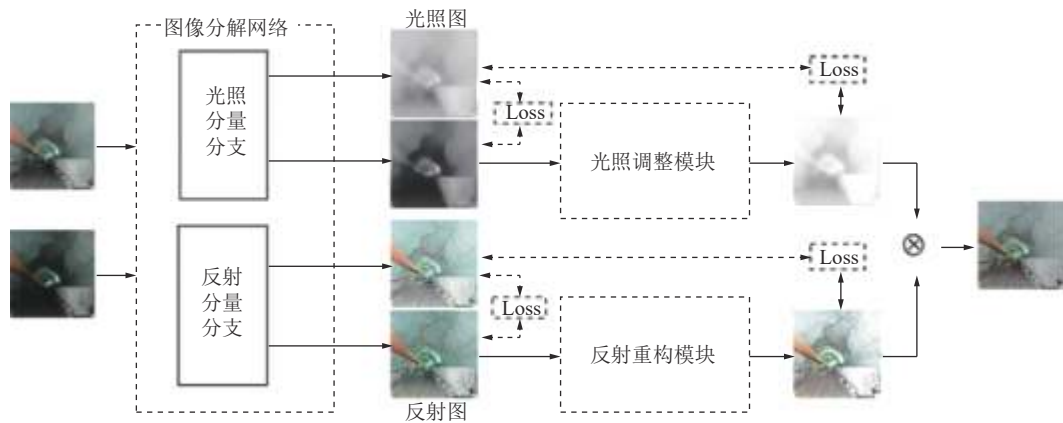


图 1 矿井下增强网络结构

Fig.1 Underground mine enhancement network structure

Retinex 理论认为人们观测到的图像可以分解成光照分量和反射分量：

$$S(x,y) = R(x,y)L(x,y) \quad (1)$$

其中： $S(x,y)$ 为原始图像； $R(x,y)$ 为反射分量，描述了观测图像的固有信息，可以被视为常量，与光照无关； $L(x,y)$ 为光照分量，描述了观测图像的不同光照程度。由于没有真实图像的光照信息和反射信息作为参考，这就导致了解析结果的不确定性，因此在分解网络模块中正确使用先验正则化因子是很重要的。假设图像没有退化现象，那么按照 Retinex 理论，相同场景下所拍摄图像的反射图应相同，不同光照条件则导致了光照图有很大的差别，但它们的结构仍应具有一致性，且相对简单。所以，我们使用正常光照条件下图像作为网络中各个模块的学习对象，从成对的低光照和普通光照图像中自动学习参数。

1.2 分解模块

分解网络模块存在于 2 个分支之中，用来提取光照图和提取反射图，其中用来提取反射图的结构

是由经典的 U-Net 结构^[15]和一个 1×1 的卷积层加 Sigmoid 激活函数组成；用来提取光照图的结构是由一个 Conv+ReLU 层^[16]和一个 Conv 层组成，最后加上一个 Sigmoid 层^[17]，总体结构如图 2 所示。由于使用了配对的低光照和正常光照的图像 $[S_l, S_h]$ 做出参考，同一场景的不同光照图像的反射图 $[R_l, R_h]$ 一致，而分解出来的 $[L_l, L_h]$ 应该是分段平滑的。

此模块的损失函数设计为

$$L^D = L_{re}^D + \omega_{rs} L_{rs}^D + \omega_{mc} L_{mc}^D + \omega_{is} L_{is}^D \quad (2)$$

其中， ω_{rs} 、 ω_{mc} 和 ω_{is} 分别为规范反射分量相似性、光照分量平滑性和相互一致性损失的系数。

L_{re}^D 是重构误差函数，具体形式是：

$$L_{re}^D = \|S_l - R_l \otimes L_l\|_1 + \|S_h - R_h \otimes L_h\|_1 \quad (3)$$

其中， S_l 和 S_h 分别为矿井下和正常光照条件下的图像； R_l 、 R_h 、 L_l 和 L_h 分别为矿井下和正常光照下的图像分解出的反射分量和光照分量； $\|\cdot\|_1$ 为采取的是 l_1 损失，重构误差函数约束了解析产生的反射分量和光照分量重构之后尽量和分解前保持一致。

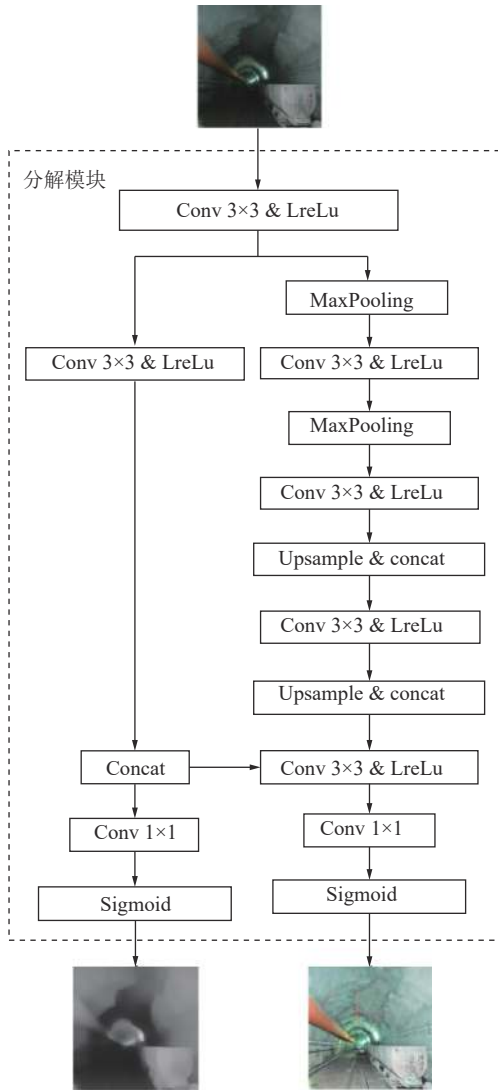


图 2 分解模块结构

Fig.2 General diagram of decomposition module structure

L_{rs}^D 是用来规范反射分量的相似性,具体形式可以表示为

$$L_{rs}^D = \|R_l - R_h\|_1 \quad (4)$$

L_{mc}^D 是相互一致性损失函数,矿井下低光照和正常光的光照分量梯度和在较小或较大的时候表示此时的光照在平滑物体表面(分布均匀)或者边缘(光照分布差异较大),只有在梯度和不大不小时才惩罚,也就是两个光照分量存在差异且差异不是特别大的区域。具体形式为

$$L_{mc}^D = \|M \otimes \exp(-cM)\|_1 \quad (5)$$

其中, $M = |\nabla L_l| + |\nabla L_h|$ 。

L_{is}^D 是光照分量平滑性函数,具体形式为

$$L_{is}^D = \left\| \frac{\nabla L_l}{\max(|\nabla S_l|, \varepsilon)} \right\|_1 + \left\| \frac{\nabla L_h}{\max(|\nabla S_h|, \varepsilon)} \right\|_1 \quad (6)$$

其中, ∇ 为一阶导,包含了 ∇_x (水平方向)和 ∇_y (垂直方

向), ε 是一个很小的正常数,为了避免 0 作为被除数, $|\cdot|$ 表示绝对值。理想的光照分量应该在纹理细节上尽可能地平滑,同时在整体结构上

应该得到较好的保留,这个平滑性的测量光照是基于输入图像的结构来说的,其中在输入图像 S 中,边缘位置的 L 惩罚较小,而 S 中的平坦区域位置, L 的惩罚就会变大,采用式(6)中的结构,可以减少边界过度平滑的风险,因为它会以原始输入图像作为参考,光照在平滑的物体上分布应平滑。

分解网络训练时初始学习率大小设置为 10^{-6} ,训练轮数设置为 100,批处理图像数量为 48,训练时损失函数曲线如图 3 所示。由图 5 可知,网络训练至 60 轮时,损失值趋于稳定,达到收敛状态。

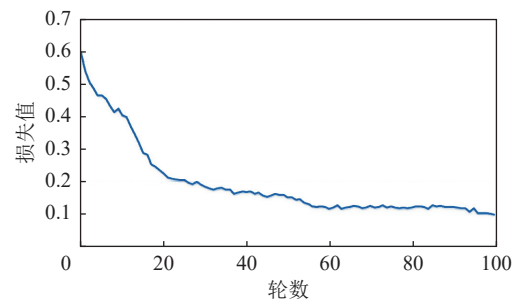


图 3 分解网络损失函数曲线

Fig.3 Loss function graph of decomposition network

1.3 光照调整模块

光照调整网络模块网络结构采用了 MobileNet 结构^[18],它拥有更小的体积,更少的计算量,更高的精度,在轻量级神经网络中拥有极大的优势。其采用了深度可分离卷积 (Depthwise separable convolution)^[19]构成的卷积层作为特征提取网络结构,深度可分离卷积结构如图 4 所示,它相较于普通卷积,大幅减少了模型的参数,并加深了特征提取网络的深度,整个 MobileNet 模块结构如图 5 所示,其中的 depthwise conv block 就是分层卷积,之后会经过 Batch normalization 层和 ReLU 激活函数层,在之后添加一个 1×1 的卷积进行通道处理。而光照调整模块采用 MobileNet 网络进行 5 个特征层的提取,然后再分别进行上采样和特征层的融合,最终通过 Sigmoid 激活函数输出,总体结构如图 6 所示。此模块的损失函数设计为

$$L^A = E_{MS}(\hat{L}, L_k) + E_{MS}(\nabla \hat{L}, \nabla L_k) \quad (7)$$

其中, L_k 为 L_l 或 L_h , \hat{L} 为光照调整模块的输出, E_{MS} 为均方误差,它是预测值 $f(x)$ 与目标值 y 之间差值平方的均值,其计算公式为

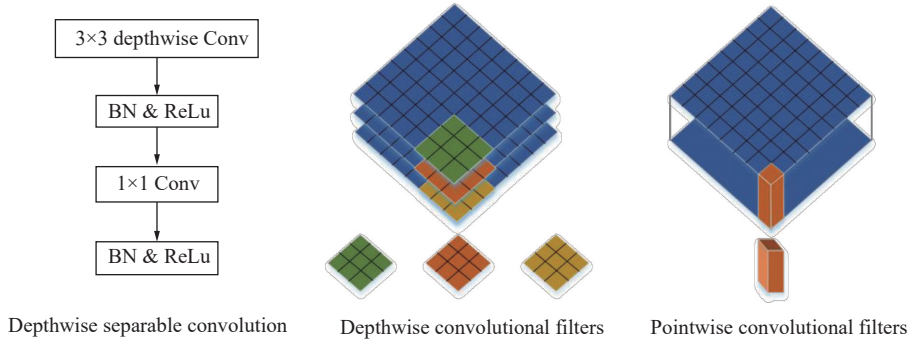


图 4 深度可分离卷积块结构

Fig.4 Deeply separable convolutional block structure

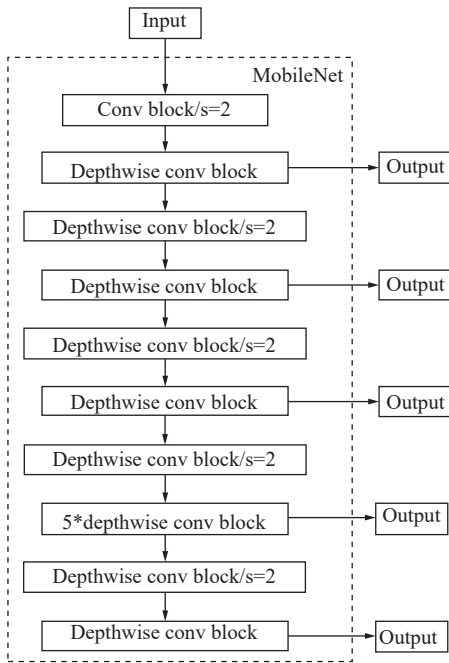


图 5 MobileNet 模块结构

Fig.5 MobileNet module structure

$$E_{MS} = \frac{\sum_{i=1}^n [(f(x) - y)]^2}{n} \quad (8)$$

1.4 反射重构模块

基于 Retinex 理论,从数学的角度出发,退化的低光照图像可以表示为

$$\begin{aligned} S(x, y) &= R(x, y) * L(x, y) + E(x, y) \\ &= \tilde{R}(x, y) * L(x, y) \\ &= (R + \tilde{E}) * L(x, y) \end{aligned} \quad (9)$$

式中, \tilde{R} 为存在退化现象的反射图; E 为图像解耦后的退化现象,其中 $E(x, y) = \tilde{E}(x, y) * L(x, y)$ 。假设此时的退化由加性高斯白噪声 (AWGN) 引起^[20], 则 $E \sim N(0, \sigma^2)$, 那么 \tilde{E} 即与每个像素点 i 上的 L 、 $\frac{\sigma^2}{L_i}$ 等值密切相关。这就说明,反射图的恢复并不能在整个图像上均匀地处理,而需要光照图的引导和参考。

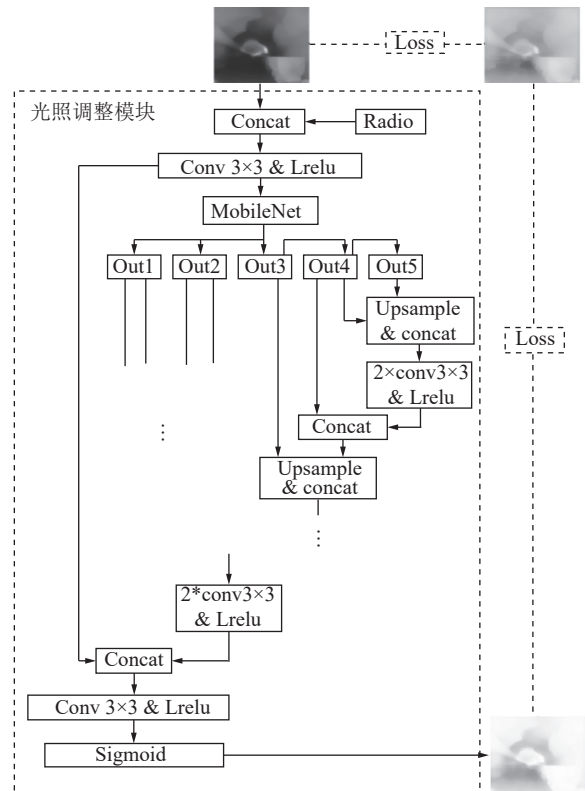


图 6 光照调整模块网络结构

Fig.6 Illumination adjustment module network structure

反射重构网络模块利用更清晰的反射率作为混乱反射率的参考,类似于层分解子网中更深层次的反射分支。退化在反射上的分布复杂,且强烈依赖于照明分布,将光照信息和退化的反射一起引入到恢复网络中,可以解决颜色失真的问题,进而去除黑暗区域的退化,实现图像细节的重构。针对矿井下环境的特殊性,图像纹理信息较弱,容易出现对比度低、细节损失,边缘信息丢失等问题,并提升网络的特征表达能力,在网络结构中加入了残差层模块,具体结构如图 7 所示,它使得网络层空置不会使得网络性能下降,然而实际上的输出特征存在一定的数值,使网络在除输出特征外还能学到新的特征,在图

像重建的过程中利用底部细节,提升了对网络的细节处理能力。采用了 LN(Layer Normalization) 的归一化方法,使每一层的维度分布更稳定并起到了正则化的作用,使得模型不容易出现过拟合的现象。最后通过 Swish 激活函数获得输出结果。反射重构网络总体结构如图 8 所示。

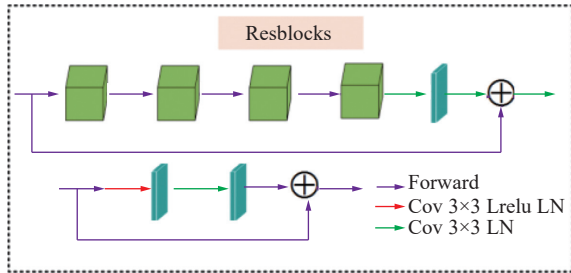


图 7 残差块结构

Fig.7 Residual block structure

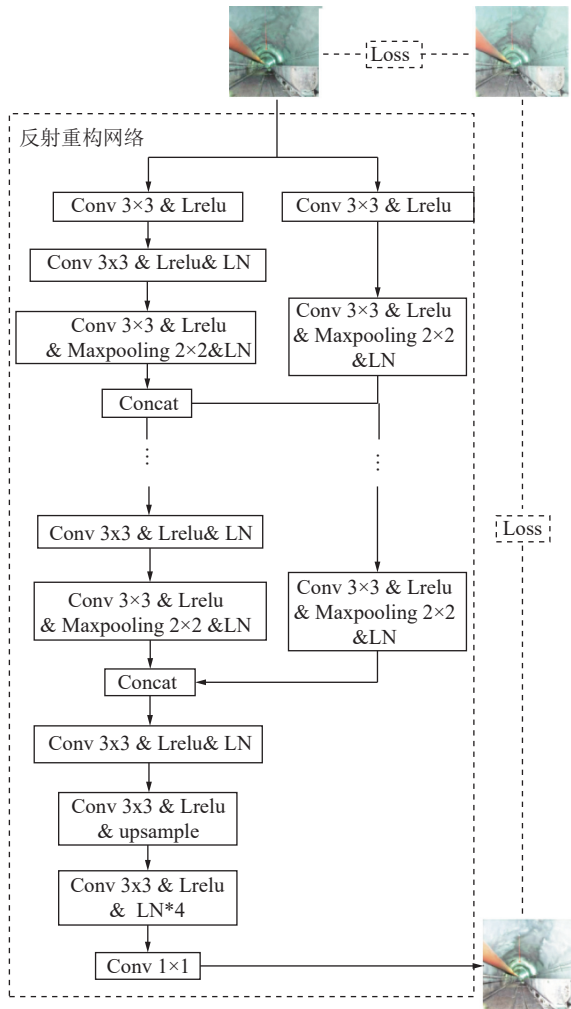


图 8 反射重构网络结构

Fig.8 Reflection reconfiguration network structure

激活函数的选取十分关键,因为它是深度学习的核心单元,即使激活函数只有少量的提升,但它也会因为大量的使用而获得极大的收益。现在深度神

经网络中常用的激活函数为 Sigmoid 激活函数,它可以把输入的连续实值变换为 0 ~ 1 间的输出,具有单调连续的特点。但它存在一定的缺陷,在深度神经网络中梯度反向传导时,可能会出现梯度爆炸和梯度消失的现象,其中梯度爆炸发生的概率较小,而梯度消失发生的概率比较大。而且 Sigmoid 函数不是关于原点中心对称的,这会导致后面一些网络层的输入也不是以 0 为中心的,从而对梯度下降的运作产生影响。同时 Sigmoid 函数需要进行指数运算,计算耗时较长。考虑到上述原因,选取 Swish 来取代 Sigmoid 作为网络的激活函数。

Swish 激活函数为一种复合的激活函数,它的表达式为

$$f(x) = x\sigma(x) \quad (10)$$

其中, $\sigma(x)$ 为 Sigmoid 激活函数,因为 Sigmoid 函数的饱和性,会导致梯度消失的发生,当 x 非常大时,就有 $f(x)$ 趋近于 x ,但当 x 趋于 $-\infty$ 时,则 $f(x)$ 趋于 0,从而解决了梯度消失的问题。同时,Swish 函数的有助于防止慢速训练期间,梯度逐渐趋近于 0 导致饱和,它的优势在于无上界有下界、非单调且平滑的特性,在模型的优化和泛化中起到重要作用,并在深层模型上的效果表现较好。

此模块的损失函数设计为

$$L^R = \sum \|\widehat{R} - R_h\|_2^2 - SSIM(\widehat{R}, R_h) + \|\nabla \widehat{R} - \nabla R_h\|_2^2 \quad (11)$$

其中, \widehat{R} 为恢复后的重构图; $SSIM^{[21]}$ 为低光照图像增强后与对应的正常光图像之间的 SSIM 值。

2 数值试验

由于矿井下采集的低光照图像没有对应正常光照图像,无法直接获得低光照-正常光照成对数据集,经过大量试验发现,利用多种杰出的低光照图像增强算法增强矿井低光照图像,根据 NIQE 评价指标,选取 NIQE 指标最优图像与矿井原低光照图像构成训练数据集对,可近似获得矿井低光照图像成对数据集(Mine-data),作为网络的训练集与验证集。试验中选用的杰出算法包括: LIME、RRM、MBLEN、Retinex-Net^[11]、KinD^[12]、DLN 与 KIND_plus,经过测试,NIQE 指标最佳的图像主要分布于 3 种算法,分别是 KIND、DLN、KIND_plus,占比大致分别为 23%、22%、11%。制作的 Mine 数据集由大小为 600×400 的近似正常光照图像和低光照图像对组成,数据集包含 240 组图像对。

试验中网络的初始学习率设置为 10^{-6} , 训练轮数设置为 3 000, 批量大小设置为 16。试验采用 Python 编写算法代码, 使用 Adam 作为优化器, 基于 Tensorflow 框架实现, 在 NVIDIA GeForce RTX 3090 GPU 下进行训练。

为了验证算法的有效性与实用性, 进行了矿井下图像增强效果的对比; 为了验证制作的煤矿井下图像数据集的有效性, 分别进行了不同数据集测试图像的主观视觉效果对比与客观指标对比; 为了验证算法的适应性及可行性, 进行了各算法在不同数据集中增强图像的指标对比; 为了验证每部分网络结构的必要性, 进行了相关的消融试验; 为了验证算法的实时性, 进行了各算法耗时性的对比。

2.1 矿井下图像的增强效果对比

通过将此网络的增强结果和目前最先进的低光

照增强算法进行比较来说明该网络的有效性和实用性, 比较算法包括: BIMEF、GLAD、MBLLEN、RRM、DLN、Retinex-Net、LIME 和 KinD。采用 PSNR、SSIM、NIQE 和 LOE 作为图像质量评价指标。其中峰值信噪比 PSNR 和结构相似度 SSIM 这两个指标, 是广泛使用的 2 种图像质量指标, 都需要有对应的正常图像作为参考, 值都是越大越好; 自然图像质量评估器 NIQE, 用于评估真实图像恢复, 不需要其他图像作为参考, 值越小越好; 亮度顺序误差 LOE, 表示增强后图像自然度的亮度顺序误差, LOE 值越小, 说明该图像亮度顺序保持得越好, 也就是说该图像的质量越高。

对矿井下低照度图像进行测试, 在由矿井下低照度图像组成的 MI 数据集中随机抽取 T1、T2、T3 图像增强效果如图 9 所示。

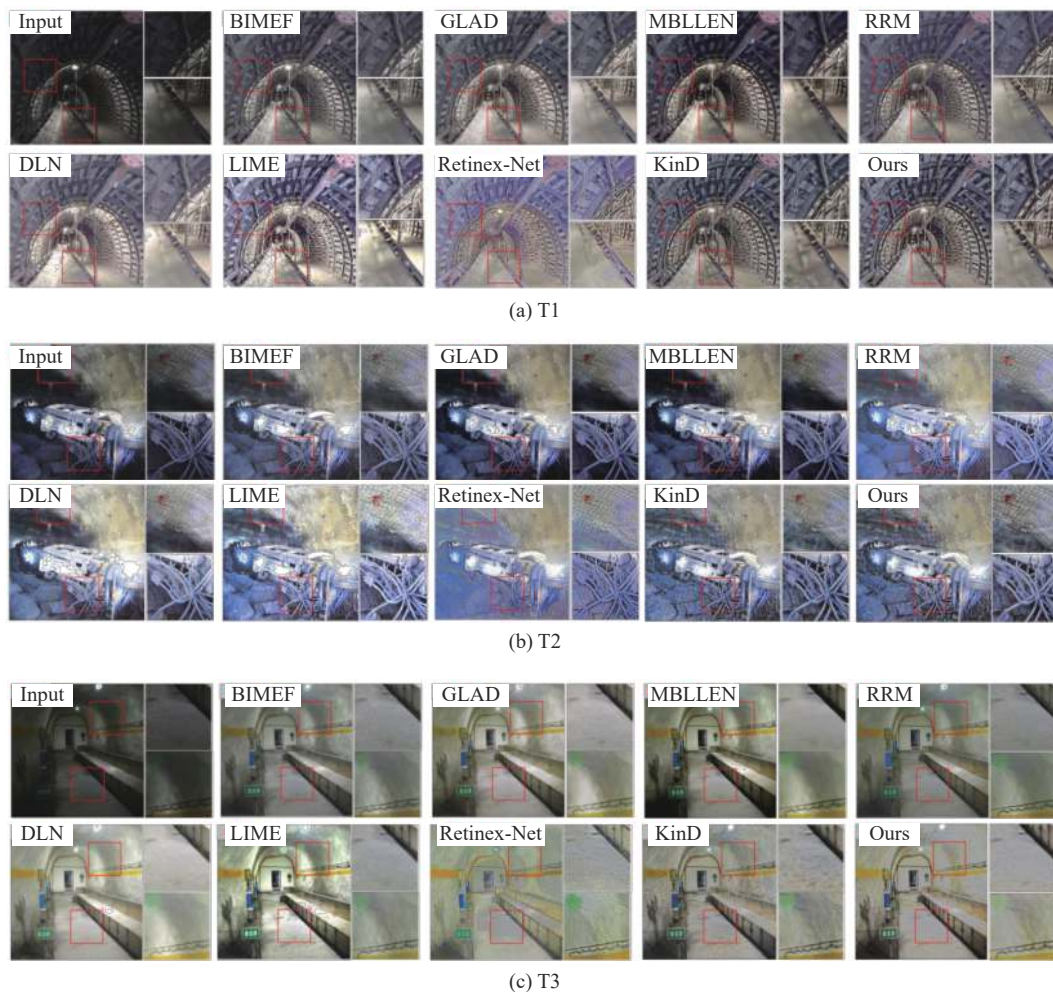


图 9 矿井下测试图像增强效果

Fig.9 Image enhancement effect of underground test in mine

图 9a、图 9b、图 9c 中的第 1 行从左到右依次对应输入的矿井下低照度图像, BIMEF, GLAD,

MBLLEN, RRM 增强图像; 第 2 行从左到右依次对应 DLN、LIME、Retinex-Net、KinD 与本文算法对应

的增强图像。

视觉分析图 9a 可以看出, 增强 T1 时, 传统的增强算法中, LIME 相较于 BIMEF、RRM 视觉效果表现较好, 但它增强过后灯光处的明亮区域被过度增强, BIMEF 增强后的图像的饱和度和对比度过强, 导致图像整体偏暗, 地板的黑暗处并没有得到很好的增强。RRM 对低光照图像的亮度改善有所欠缺, 墙上部分细节模糊。而深度学习算法中, Retinex-Net 增强后, 整张图像出现了较为严重的颜色失真; GLAD 增强后的图像中地板和墙壁周围仍存在噪声, 部分区域的颜色和边缘也出现了一定的失真现象; MBLLEN 增强过后的图像对比度过强, 亮度增强的效果不明显, 尤其是在图像中的角落等黑暗处; KinD 的结果在边缘存在伪影, 会影响了增强效果的视觉美感; DLN 对图像色调的恢复程度较高, 但对图像色彩的恢复程度较低。算法增强后的图像较为清晰, 并且增强图的整体色调和细节恢复程度较为理想。

视觉分析图 9b 知, 增强 T2 时, LIME 算法在视觉上的增强效果仍然是最好的, 但它增强过后的强光区域仍会出现过度增强的现象, 而其他的传统算法 BIMEF、RRM 增强后的图像效果相近, 图像整体偏暗, 增强效果不明显。而基于深度学习的 Retinex-Net 网络对图像的色彩恢复程度明显比较弱, 一定程度上引起了图像的颜色出现不均与失真; 从图中放大区域看出, GLAD 增强后的图像仍存在噪声, 对比度提升不明显; MBLLEN 增强过后的图像仍然出现了亮度增强的效果不明显的情况; 由局部放大图可知, KinD 增强后结果在图 9b 的通道右侧出现伪影, 对视觉效果产生影响; DLN 增强后的图像存在色差, 饱和度提升不明显。由图 8b 的局部放大图可看出, 本文算法增强后的图像纹理细节更加丰富, 增强效果较为理想。

视觉分析图 9c 可以看出, 传统的增强算法中, LIME 在图 9c 的明亮区域出现了明显的过增强现象, 对视觉效果产生一定的影响, 但增强效果比 BIMEF 与 RRM 增强后的图像的效果好, BIMEF 和 RRM 增强后的图像整体偏暗。在深度学习算法中, 由图 9c 中局部放大图可知, Retinex-Net 对图像的色彩恢复能力较差, 容易出现颜色失真的现象; GLAD 增强后的图像噪声含量大, 在图像边缘细节处较为模糊; MBLLEN 增强过后的图像对比度过强, 亮度增强的效果不明显; 由图 9c 中局部放大图可知, KinD 增强后的结果在地面上有仍会出现伪影, 这同样对增强效果的视觉美感产生了影响; DLN 增强后的图像引

起了较大的色差, 在强光区域出现了过度增强的现象。算法增强后的图像对比度、清晰度与纹理细节相较 KinD 都有不同程度的提高, 整体增强效果较为理想。

考察煤矿井下图像^[22]可以发现, 图像的质量与 NIQE 指标密切相关, NIQE 指标越低的图像质量越好, 故这里从各算法的增强结果中选取 NIQE 指标最佳的图像作为正常光参考图像, 组成煤矿井下图像数据集, 作为训练集与测试集。为验证其有效性, 从该数据集中随机抽取了 T4、T5 图像进行测试, 并将它们与其他 8 种算法的结果进行对比, 具体效果如图 10 所示。

从图 10 可以看出各算法在矿井下测试图像增强中出现的问题, 在煤矿数据集 (Mine-data) 中同样存在, 由于 Mine-data 选取了各增强算法中 NIQE 指标最佳的图像, 作为对应的正常光照下的图像进行参考, 所以可以计算出它们的 PSNR 和 SSIM 值, 从图 11 能够直观地看出, 提出的算法在 PSNR 值的对比中列居首位, 在 SSIM 值的对比中列居第 2, 而排在前位的还有 GLAD、KIND、DLN、MBLLEN, 而相对来说结果不太理想的算法是 BIMEF、RRM、LIME 和 Retinex-Net 算法。

为了防止抽取图像的随机性和偶然性, 这里又将 Mine-data 数据集中低照度图像作为测试图像, 分别计算出它们的 PSNR、SSIM 的值, 并与其他 8 种算法做出比较, 通过不同图像质量指标数据, 来对这些算法的增强性能进行比较, 具体数据如见表 1。

分析表 1 中数据可知, 提出的算法在 PSNR 和 NIQE 两个指标中均位于 9 种算法的首位, KinD 算法均排行第 2, 而在 SSIM 指标上仅以微弱的差距落后于 KinD 算法, 在 LOE 指标上, 仅低于 MBLLEN 算法, 而优于 KinD 算法。综合分析, 提出的算法无论是从视觉效果上还是指标分析上都表现出很大的优势。

2.2 不同数据集图像增强对比

为验证算法的适应性与可行性, 将 LOL 数据集作为测试图像, 分别计算出它们的 PSNR、SSIM、NIQE 和 LOE 的值, 并与其他 8 种算法做出比较, 通过 4 个图像质量指标数据分析这些算法的增强性能^[23], 具体数据见表 2。

分析表 2 中数据可知, 提出的算法在 SSIM 和 NIQE 两个指标中均位于 9 种算法的首位, KinD 算法均排行第 2, 而在 PSNR 指标上仅以微弱的差距落后于 KinD 算法, 在 LOE 指标上, 仅低于 MBLLEN




图 10 煤矿数据集测试图像增强结果
Fig.10 Mine-data test image enhancement results

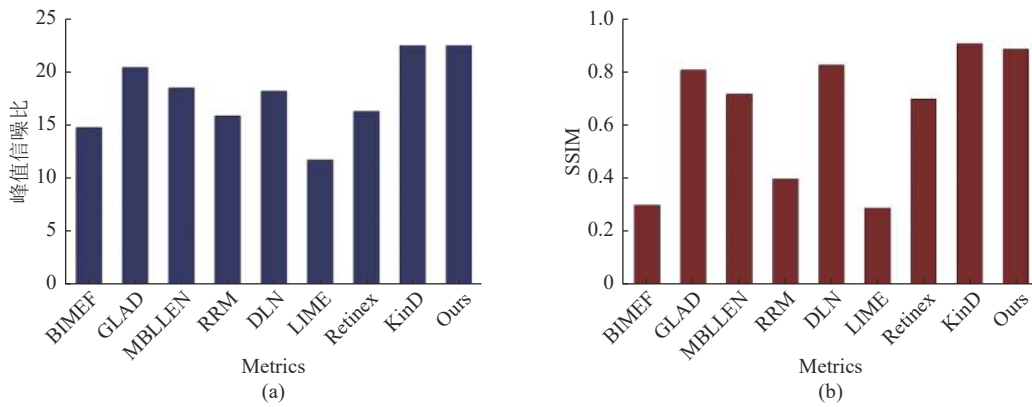


图 11 Mine 数据集测试图像增强结果的峰值信噪比和 SSIM 值
Fig.11 PSNR and SSIM values of the Mine-data test image enhancement results

表 1 矿井下图像质量指标数据比较

Table 1 Comparison of underground image quality index data

Metrics	BIMEF	GLAD	MBLEN	RRM	DLN	LIME	Retinex-Net	KinD	Ours
PSNR↑	14.73	17.73	20.25	14.93	16.57	13.31	18.38	24.11	24.40
SSIM↑	0.42	0.74	0.76	0.44	0.74	0.43	0.77	0.87	0.86
NIQE↓	3.78	3.71	4.87	4.32	3.63	3.65	4.42	3.52	3.47
LOE↓	409.98	251.79	226.22	447.23	289.11	514.82	467.91	237.65	228.72

表 2 LOL 数据集图像质量指标比较

Table 2 Comparison of image quality indicators in LOL dataset

Metrics	BIMEF	GLAD	MBLEN	RRM	DLN	LIME	Retinex-Net	KinD	Ours
PSNR↑	13.84	19.72	14.13	13.88	19.15	16.76	16.77	19.8	19.77
SSIM↑	0.58	0.7	0.49	0.66	0.71	0.56	0.56	0.77	0.79
NIQE↓	7.52	6.94	4.73	5.94	4.79	9.13	9.73	4.7	4.51
LOE↓	305.2	714.8	280.9	958.7	1210.8	817.2	1712.6	977.3	304.46

注：↑表示数值越大越好；↓表示数值越小越好。

算法,而远远超过 KinD 算法。总体看来,算法在不同客观指标上的综合表现较好。

对于 LIME、NPE 数据集和 MI 数据集,由于没有可用的参考图像。因此,仅采用 NIQE 来评估各个算法的之间的性能差异,试验结果见表 3。

表 3 各数据集图像质量指标数据比较

Table 3 Comparison of image quality index data among different datasets

Algorithm	NIQE		
	LIME-data	NPE-data	MI-data
BIMEF	4.26	4.19	3.4
GLAD	4.12	3.98	2.87
MBLLEN	4.51	4.54	4.91
RRM	4.64	4.84	4.64
DLN	4.51	4.32	2.97
LIME	4.15	4.26	4.64
Retinex-Net	4.59	4.56	3.76
KinD	4.25	4.12	3.09
Ours	4.07	4.05	3.03

分析表 3 数据可知,在 NIQE 指标的对比中,本文所提出的算法位列首位,GLAD 算法排名第 2,对于 NPE 数据集,排名仅次于 GLAD 算法,对于 MI 数据集,排名第 1 的是 GLAD 算法,DLN 排名第 2,本文提出的算法排名第 3。

综上所述,提出的算法在不同数据集上表现良好,从而证实了此算法的适应性、可行性与优越性。

2.3 消融试验

文中的网络结构中加入了 Mobile-Net 与残差块等结构,为体现每部分网络结构对最终生成增强图像的影响,进行了相关的消融试验,来验证每部分网络结构的必要性和有效性,所选测试质量指标的图片取自于矿井下低光照图像数据集(Mine-data)中的部分图像,消融试验每种情况下的数值质量指标对比结果见表 4。

从表 4 中的数据可以直观看出,缺少网络的任一部分都会对最终增强图像的指标质量产生不同程度的影响,这也证明了每一部分网络结构的必要性和有效性。

2.4 算法耗时性分析

为比较 9 种增强算法的平均耗时,分别使用 9 种算法增强 50 幅 600×400 的测试图像,统计其增强单幅图像的平均耗时,具体数据比较结果见表 5。

表 4 消融试验指标对比

Table 4 Comparison of ablation experiments

Model	w/o part	PSNR↑	SSIM↑	NIQE↓	LOE↓
Proposed	Mobile-Net	19.59	0.81	3.82	230.57
	Resblocks	15.62	0.81	3.11	247.89
	Mobile-Net and Resblocks	20.31	0.89	3.21	263.24
	—	24.39	0.9	2.93	213.41

表 5 各算法耗时性比较

Table 5 Time consuming comparison of all algorithms

Method	耗时/s
BIMEF	2.931
GLAD	0.232
MBLLEN	17.518
RRM	18.809
DLN	0.142
LIME	15.256
Retinex-Net	0.183
KinD	0.286
Ours	0.237

由表 5 数据可知,本文算法平均计算速度 0.237 s,略低于 DLN、Retinex-Net、GLAD,位居第四,算法运行速度较好。

3 结 论

1)该网络为双分支结构,分别与 Retinex 理论的光照分量和反射分量相对应,在光照分量网络分支和反射分量网络分支分别实施光照分量调整和反射分量重构。

2)光照调整网络利用深度可分离卷积强化轮廓特征提取能力;反射重构网络利用残差网络结构强化纹理细节信息提取,提升重构反射分量纹理细节清晰度。

3)试验表明,文中针对矿井图像纹理细节弱特征,构建的深度神经网络模型,相比目前公认 8 种图强增强方法,更加适合矿井下低光照图像的增强,本文模型增强图像在细节信息增强、对比度提高方面具有一定的优势。

参考文献(References):

- [1] 钱鸣高. 煤炭的科学开采[J]. 煤炭学报, 2010, 35(4): 1-6.
QIAN Minggao. Scientific mining of coal[J]. Journal of China Coal Society, 2010, 35(4): 1-6.

- [2] GUO X, LI Y, LING H. LIME: Low-Light image enhancement via illumination map estimation[J]. *IEEE Transactions on Image Processing*, 2017, 26(2): 982–993.
- [3] SHU Hang, WANG Jin, ZHENG Haimiao, *et al.* Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. *IEEE Transactions on Image Processing*, 2013, 22(9): 3538–3548.
- [4] CHULWOO L, CHUL L, YOUNG-YOON L, *et al.* A power-constrained contrast enhancement for emissive displays based on histogram equalization[J]. *IEEE Transactions on Image Processing*, 2012, 21(1): 80–93.
- [5] LI Mading, LIU Jiaying, YANG Wenhai, *et al.* Structure-revealing low-light image enhancement via robust retinex model[C]// *IEEE Transactions on Image Processing*, 2018, 27(6): 2828–2841.
- [6] XUAN D, PANG Y A, WEN J G. Fast efficient algorithm for enhancement of low lighting video[C]// *IEEE International Conference on Multimedia & Expo*, 2011: 1–6.
- [7] LORE K G, AKINTAYO A, SARKAR S. LLNet: A deep autoencoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61(6): 650–662.
- [8] LI C, GUO C, HAN L, *et al.* Low-light image and video enhancement using deep learning: a survey[J]. *Computer Vision and Pattern Recognition*, 2021, 61(4): 1–12.
- [9] LU Kun, ZHANG Lihong. TBEFN: A two-branch exposure-fusion network for low-light image enhancement[J]. *IEEE Transactions on Multimedia*, 2021(23): 4093–4105.
- [10] WANG W, CHEN W, YANG W, *et al.* GLADNet: Low-light enhancement network with global awareness[C]// *2018 13th IEEE International Conference on Automatic Face & Gesture Recognition*, 2018: 1–13.
- [11] WEI C, WANG W, YANG W, *et al.* Deep retinex decomposition for low-light enhancement[J]. *Computer Vision and Pattern Recognition*, 2018: 1–12.
- [12] ZHANG Y, ZHANG J, GUO X. Kindling the darkness: a practical low-light image enhancer[C]// *ACM MM*, 2019: 1632–1640.
- [13] ZHANG Y, GUO X, MA J, *et al.* Beyond brightening low-light images[J]. *International Journal of Computer Vision*, 2021, 129(4): 1013–1037.
- [14] ZHANG Y, DI X, ZHANG B, *et al.* Self-supervised image enhancement network: training with low light images only, 2020: 1–14.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[J]. *Springer International Publishing*, 2015, 99: 1–1.
- [16] CLEVERT D, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (ELUs)[J]. *Computer Science*, 2015: 1–14.
- [17] IMTIAZ M S, WAHID K A. Image enhancement and space-variant color reproduction method for endoscopic images using adaptive sigmoid function[C]// *Engineering in Medicine & Biology Society, Conf Proc IEEE Eng Med Biol Soc*, 2014: 3905–3908.
- [18] HOWARD A G, ZHU Menglong, CHEN Bo, *et al.* MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications[J]. *Computer Vision and Pattern Recognition*, 2017: 1–9.
- [19] CHEN LC, ZHU Y, PAPANDREOU G, *et al.* Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// *Proceedings of the European conference on computer vision (ECCV)*, 2018: 801–818.
- [20] 王满利, 田子建. 基于非下采样轮廓波变换的矿井图像增强算法[J]. *煤炭学报*, 2020, 45(9): 3351–3362.
- WANG Manli, TIAN Zijian. Mine image enhancement algorithm based on non-subsampled contourlet transform[J]. *Journal of China Coal Society*, 2020, 45(9): 3351–3362.
- [21] SETIADI D. PSNR vs SSIM: imperceptibility quality assessment for image steganography[J]. *Multimedia Tools and Applications*, 2020: 1–22.
- [22] 曹现刚, 郝朋英, 王 鹏, 等. 多因素光照条件下高质量图像获取方法研究[J]. *煤炭科学技术*, 2023, 51(1): 455–463.
- CAO Xiangang, HAO Mingying, WANG Peng, *et al.* Study on high quality image acquisition under multi - factor illumination[J]. *Coal Science and Technology*, 2023, 51(1): 455–463.
- [23] 龚 云, 颀昕宇. 基于同态滤波方法的煤矿井下图像增强技术研究[J]. *煤炭科学技术*, 2023, 51(3): 241–250.
- GONG Yun, XIE Xinyu. Research on coal mine underground image recognition technology based on homomorphic filtering method[J]. *Coal Science and Technology*, 2023, 51(3): 241–250.