

徐轩,姚斌,韩典芝. 基于 Retinex 理论和残差网络的低照度图像增强方法[J]. 智能计算机与应用,2025,15(3):164-169.
DOI:10.20169/j.issn.2095-2163.250324

基于 Retinex 理论和残差网络的低照度图像增强方法

徐轩^{1,2},姚斌¹,韩典芝¹

(1 陕西科技大学 电子信息与人工智能学院,西安 710021; 2 陕西科技大学 陕西省人工智能联合实验室,西安 710021)

摘要:针对昏暗环境下拍摄的图像亮度及对比度低的问题,设计了一个基于 Retinex 理论和深度残差网络的低照度图像增强网络。首先,分解子网络依据 Retinex 理论分离输入图像的反射分量和照度分量作为后续输入;其次,使用编码器解码器架构的增强网络进行特征提取,通过自适应空间特征融合结构提高特征尺度的不变性;最后,设计了基于残差结构的降噪子网络对反射图去噪,通过残差结构的跳跃连接来弥补传统去噪方法的不足。实验结果表明,本文提出的方法能有效提升图像亮度以及对比度,增强效果细节突出,颜色失真不明显,不仅在主观视觉上有很好的展现,在客观指标上也领先于其他方法。

关键词:低照度图像增强; Retinex 理论; 深度学习; 残差网络

中图分类号: TP391.4

文献标志码: A

文章编号: 2095-2163(2025)03-0164-06

Low-light image enhancement method based on Retinex theory and residual network

XU Xuan^{1,2}, YAO Bin¹, HAN Dianzhi¹

(1 School of Electronic Information and Artificial Intelligence, Shaanxi University of Science and Technology, Xi'an 710021, China;
2 Shaanxi Joint Laboratory of Artificial Intelligence, Shaanxi University of Science and Technology, Xi'an 710021, China)

Abstract: Aiming at the problem of low brightness and contrast of images taken in dark environment, a low illumination image enhancement network based on Retinex theory and depth residual network is designed. Firstly, the decomposition sub-network decomposes the reflection component and illumination component of the input image as the subsequent input according to Retinex theory; Secondly, the enhanced network of encoder and decoder architecture is used for feature extraction, and the invariance of feature scale is improved through adaptive spatial feature fusion structure; Finally, a noise reduction network based on residual structure is designed to denoise the reflection map, and the deficiency of the traditional denoising method is compensated by the jump connection of residual structure. The experimental results show that the method proposed in this paper can improve the brightness and contrast of the image, the enhancement effect details are prominent, the color distortion is not obvious. To sum up, the method not only has a good display in the subjective vision, but also is ahead of other methods in the objective index.

Key words: low-light image enhancement; Retinex theory; deep learning; residual network

0 引言

在当今信息世界飞速运转的过程中,人类多是通过视觉系统从外界获取到一些有价值的信息,而图像则是视觉信息中最为直观的来源,也是人类最常用的信息载体。当环境状况较差、即在暗光、阴雨和大雾等恶劣条件时,并在一些噪声和其它因素的共同影响下,视觉系统采集到的图像会出现细节信息丢失严重、图像整体亮度偏暗、对比度下降等问

题^[1-2],导致人们提取图像中有效信息的能力减弱,进而给人眼的识别感知和计算机系统的后期处理带来了极大的困难。随着计算机视觉技术的快速发展,低照度图像增强成为了一种备受关注的解决方法。通过利用先进的算法和技术,可以改善低照度图像的质量,使其更加清晰、明亮,以及更接近真实场景的视觉效果。低照度图像增强不仅能提高可视性和影像品质,还能在许多领域中发挥重要作用,如安防监控、无人驾驶、医学影像等^[3]。本文对现有

基金项目:国家自然科学基金青年项目(61603234)。

作者简介:徐轩(2000—),男,硕士研究生,主要研究方向:图像处理,机器学习;韩典芝(1999—),男,硕士研究生,主要研究方向:图像处理。

通信作者:姚斌(1981—),男,博士,副教授,主要研究方向:图像特征提取,图像增强。Email:yaobin@sust.edu.cn。

收稿日期:2023-09-16

的低照度图像增强方法进行了深入分析,探讨了现有方法的优点、局限性以及存在的问题,提出了一种新的低照度图像增强方法,以期进一步提高图像质量和保持图像的自然性。

1 研究现状

目前,关于低照度图像增强的研究已经有很多成果。其中,基于传统图像处理方法的增强技术,以直方图均衡化^[4]和基于 Retinex(Retina & Cortex)理论^[5]的方法为代表。具体而言,直方图均衡化算法主要通过调整图像的直方图来提升图像的整体和局部亮度,例如全局直方图均衡化算法^[6]、局部直方图均衡化算法^[7]等,这类算法操作简单、易于实现,一定程度上能够提升图像的亮度,增强图像细节,但却忽略了图像的整体特性,不符合物体成像模型的规律,恢复出来的图像会出现亮度偏暗、细节丢失以及颜色失真等问题。Retinex 是一种图像增强算法,模拟了人类视觉系统的工作原理,其物理原型如图 1 所示。Retinex 将图像分解成反射和照度两个部分,原始图像由反射图和光照图相乘获得,具体公式如下:

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

其中, $S(x,y)$ 表示原始图像; $R(x,y)$ 表示反射分量; $I(x,y)$ 表示照度分量。

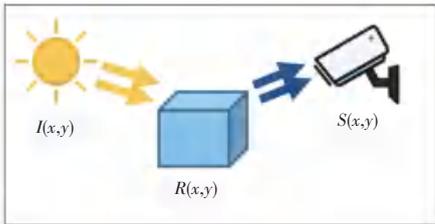


图 1 Retinex 理论模型图

Fig. 1 Retinex theoretical model diagram

Retinex 理论的核心是基于颜色恒常性假设,将图像分解为反射图和照度图,从而消除低光照对原始图像的影响,恢复出图像原本的细节信息并对照明信息进行增强,最终达到增强效果。基于该模型的 SSR (Single Scale Retinex) 算法、MSR^[8] (Multi Scale Retinex) 算法以及 MSRCP^[9] (Multi Scale Retinex with Color Preservation) 方法在不同的场景下各自有着较为优秀的效果。Retinex 算法推演出的物理模型简明有效,解释性好。基于 Retinex 理论的方法都是通过调整反射分量和亮度分量来增强图像的视觉效果,这类算法可以有效地提高低照度条件下的图像质量,同时保持图像的自然感觉。然而

该算法假设光照是缓慢变化的,实际情况通常并非如此,Retinex 算法在对图像中亮度骤变的区域增强后,容易产生光晕现象。

随着深度学习的发展,在图像处理领域已有越来越多的学者在将 Retinex 理论与深度学习相结合来展开研究,并取得了较好成效。He 等学者^[10]提出的残差网络 ResNet 通过向深度网络中插入残差块,有效解决了模型深度过深时导致的模型退化问题,首次将测试集准确率提高到了人眼水平以上。同样,在低照度图像增强领域,也涌现了很多基于深度学习的方法,例如 Wei 等学者^[11]提出的 RetinexNet 就首次结合了 Retinex 理论和 CNN 网络实现了低照度图像的亮度增强。但该方法同样会出现噪声被放大,以及部分细节丢失的现象。Zhu 等学者^[12]在 Retinex 理论的基础上提出 RRDNet 的零样本学习方法。该方法通过不断迭代损失函数来提升图像亮度。但该方法的图像亮度提升效果并不明显。Jiang 等学者^[13]在 RetinexNet 的基础上提出 R2RNet 网络,该网络将降噪网络单独列出,以达到降噪的效果。但真实比较结果发现,R2RNet 的增强结果泛白,效果不佳。

上述方法在噪声处理方面往往难以平衡噪声抑制和细节保留,导致图像过度模糊或仍存在噪点。同时,在保留细节方面,过度强调亮度增强而丢失细节,无法有效恢复和强调图像中的细节信息。为了解决这些问题,本文设计了一个基于 Retinex 理论和深度残差网络的低照度图像增强网络,并在当下主流的 LOL 数据集^[11]和 DICM 数据集上进行实验验证。实验结果表明,与其他方法相比,本文方法亮度提升明显,在图像细节恢复和噪声抑制方面具有更好的效果,不仅能够保持图像的自然性和真实感,而且在人眼视觉效果以及客观指标评价方面都领先于其他方法。

2 本文方法

本文提出一种基于深度学习和 Retinex 理论的低照度图像增强方法。该方法框架包含分解网络、增强网络和降噪网络三部分。分解网络基于 Retinex 理论将输入图像分解为反射图和照度图,然后将分解得到的照度图作为增强网络的输入,得到增强后的照度图,再将分解得到的反射图作为降噪网络的输入,得到去噪后的反射图。最后根据 Retinex 理论重建增强后的图像。算法流程如图 2 所示。

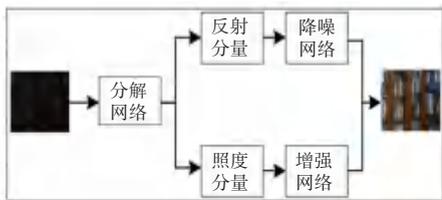


图 2 本文方法流程图

Fig. 2 Flowchart of the method in this paper

2.1 基于 Retinex 理论的分解网络

分解网络在训练阶段接收成对的低/正常光照图像,并学习低光照图片对应正常光照图像的分解。分解过程是使用配对数据集进行训练,在低照度图像和正常光图像共享相同反射率的情况下实现图像分解,但在测试阶段单独分解弱光输入。训练过程中,只需将反射图的一致性和光照图平滑嵌入到网络的损失函数中,其中并不涉及反射图像和真实对照图像之间的关系。

分解网络包含 7 个含有激活层 ReLU 的大小为 3×3 的卷积层和 1 个 Sigmoid 激活层,该模型同时输入低照度图像 S_{low} 和正常照度图像 S_{normal} 。输入的图片首先经过浅层特征提取模块来提取特征,然后在卷积模块中进行特征提取和特征映射操作,接下来在反射图和照度图的输出层进行输出,得到 2 组反射图和光照图 R_l, I_l, R_n 和 I_n 。分解过程中,分解网络以数据驱动的方式提取不同图像中一致的反射

分量。最后,在输出反射图和照度图的过程中,通过使用 Sigmoid 函数将分解出的反射图和照度图约束在 $0 \sim 1$ 之内。具体网络结构如图 3 所示。

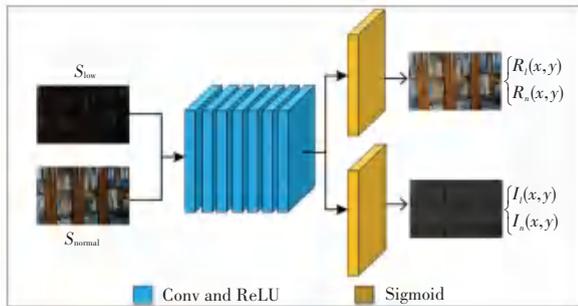


图 3 分解网络结构图

Fig. 3 Decomposing the network structure

2.2 基于编码器解码器架构的增强网络

增强网络的结构是基于编码器-解码器的架构,其结构如图 4 所示。图 4 中,编码器部分包含了 4 个 3×3 的卷积层进行下采样,用于提取输入图像 R_n, I_l 的特征。随后,解码器部分包含了 3 个 3×3 的反卷积层进行上采样,用于将特征图逐步上采样到原始图像的大小。最后,模型通过融合层将编码器和解码器的输出特征融合在一起,生成最终的灰度图像 I_n' 。编码器-解码器的架构能通过增加卷积层来增加特征提取深度,使得到的光照分量在保留图像细节的同时尽可能地平滑均匀。

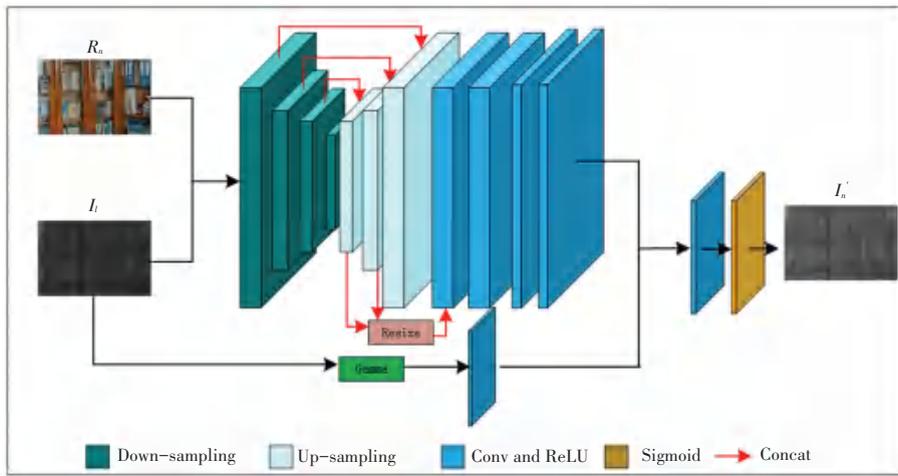


图 4 增强网络结构图

Fig. 4 Enhanced network structure

为了实现更好的照度图增强效果,增强网络使用了自适应融合模块(Adaptive Fusion)。该模块将解码器得到的特征图和经过 Gamma 校正得到的特征图按照一定的权重进行融合,以获得更加准确的输出结果。模型的最后一层是一个 1×1 的卷积层,

用于将特征图映射到灰度图像空间,并使用 Sigmoid 激活函数生成最终的输出。

2.3 基于残差结构的降噪网络

大部分传统方法以及基于 Retinex 理论的学习方法都没有处理好噪声,这会使得最终的增强图像

受反射图像中的噪声干扰。因此本文设计了一个降噪网络模块 RD,该网络充分使用图像的空间信息,从而避免了部分降噪方法在抑制图像中的高频信号时所导致的细节丢失问题。每个 RD 之前和之后有一个 $64 \times 3 \times 3$ 的卷积层,其结构如图 5 所示。

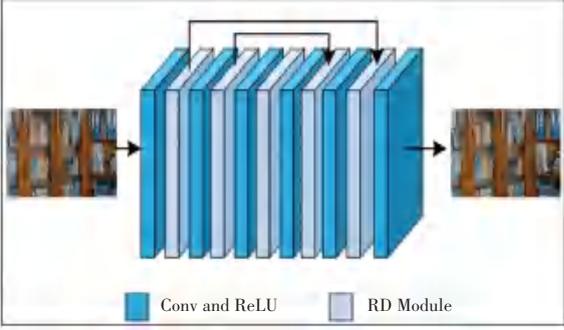


图 5 降噪网络结构图

Fig. 5 Denoise network structure

图 5 中,RD 结构受残差结构以及 Res-UNet 启发,Res-UNet 用具有残差连接的模块代替 U-Net 中的每个子模块。但是 Res-UNet 网络中采用了多个池化层,这会造成多个图像特征信息丢失,因此对其进行了改进,将池化层替换为卷积层,这将略微增加网络参数,但提高了性能。每个 RD 模块包含 5 个卷积层,内核大小为 $\{1, 3, 3, 3, 1\}$,内核数为 $\{64, 128, 256, 128, 64\}$ 。研究中,在快捷连接处添加了一个 $64 \times 1 \times 1$ 的卷积层。其结构如图 6 所示。

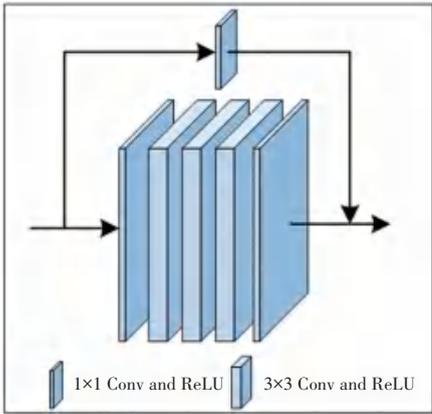


图 6 RD 子模块结构图

Fig. 6 RD submodule structure

2.4 损失函数

在训练阶段,对每个网络分别训练。整个网络的损失函数包括分解损失、增强损失和降噪损失,具体公式如下:

$$L_{re} = L_{Decom} + \lambda_1 L_{light} + L_{Denoise} \quad (2)$$

其中, L_{re} 表示总的损失函数; L_{Decom} 表示分解损失; L_{light} 表示增强损失; $L_{Denoise}$ 表示降噪损失; λ_1 表

示增强损失的权重,本文实验中设置为 0.1。

分解损失的公式如下:

$$L_{Decom} = \sum_{i=1}^N |I_{low} \circ R_{low} - S_{low}| + \sum_{i=1}^N |I_{nor} \circ R_{nor} - S_{nor}| + \sum_{i=1}^N |I_{low} \circ R_{nor} - S_{low}| + \sum_{i=1}^N |I_{nor} \circ R_{low} - S_{nor}| \quad (3)$$

其中, I_{low} 表示低照度图像分解得到的照度图; R_{low} 表示低照度图像分解得到的反射图; I_{nor} 和 R_{nor} 分别表示正常光照图像的照度图和反射图; S_{low} 和 S_{nor} 分别表示低照度图像和正常光照图像。

增强损失的公式如下:

$$L_{light} = \sum_{i=1}^N |S'_{low} - S_{nor}| + \sum_{n=low,nor} \|\nabla I_i \circ \exp(-\lambda_g \nabla R_i)\| \quad (4)$$

其中, S'_{low} 表示经过增强网络调整后的重建图像;“ ∇ ”表示水平和垂直梯度; λ_g 表示权重。

降噪损失的公式如下:

$$L_{Denoise} = \sum_{i=1}^N |R_{low} - R_{nor}| \quad (5)$$

其中, R_{low} 表示降噪后的反射图。

3 实验与结果

3.1 数据集

本次实验在网络训练过程中,使用了 LOL 训练集作为训练数据集,该数据集包含 485 对图像用于模型训练。同时,为了验证本方法在不同类型的低照度图像上的增强效果,在对比试验中选择 LOL 验证集和 DICM 数据集作为测试集合,分别包含了 15 张和 64 张具有不同暗部的低光照图像。

3.2 实验设置

本文实验的硬件环境配置为:GPU 为 NVIDIA GTX3090 16 GB 显存,CPU 为 Intel Core I9-10900K,使用 2022 版 Pycharm 编译器,Python 3.7 作为编程语言,并使用 Pytorch 作为开源框架。

3.3 对比试验

为了体现本文算法的效果,本实验分别与前文提到的具有代表性的传统方法 (MSR, MSRCR^[14], Retinex) 和深度学习的方法 (RetinexNet^[10], RRDNet^[11], R2RNet^[12]) 进行对比,从主观视觉和客观指标的角度进行分析。测试数据集选取 LOL 数据集和 DICM 数据集。

3.3.1 主观评价

首先,通过主观视觉实验对比了图 7 和图 8 分别

代表室内低照度场景和户外低照度场景。在图7中,研究发现所有方法都可以有效提升图像亮度,但不同方法的亮度提升效果有所差异。其中,RRDNet的图像亮度增强效果较差,其他方法的亮度提升效果更为明显。然而,随着图像亮度的提升,经Retinex方法增强的图像存在明显的噪声放大现象,视觉效果不自然。与RetinexNet的方法相比,本文方法在图像色彩

方面的增强效果更接近于对照图像。在图8中,原始图像更倾向于背光图像。在对比效果中,包括MSR、Retinex和R2RNet在内的方法出现了背景白云细节丢失的情况,而MSRCR和RetinexNet展示出的增强效果在颜色方面出现了失真现象,RRDNet的图像亮度增强效果不明显。相比之下,本文的增强效果在视觉感官上具有最大优势。

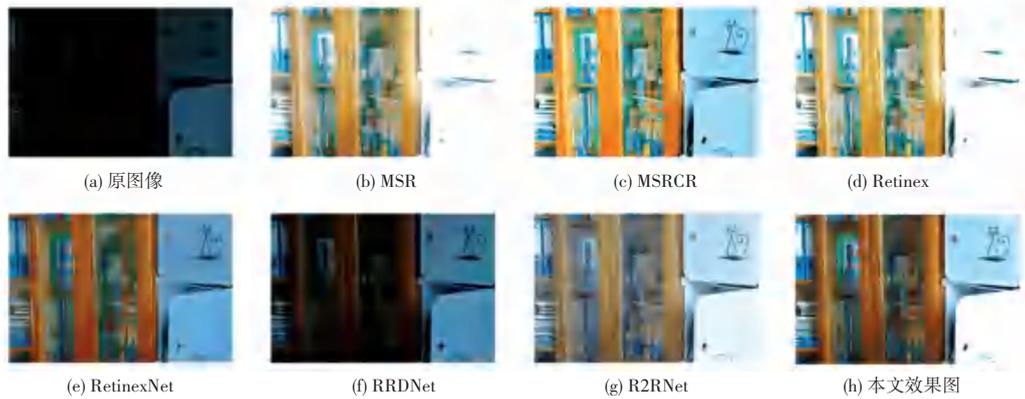


图7 LOL数据集的主观视觉实验对比

Fig. 7 Comparison of subjective visual experiments in the LOL dataset

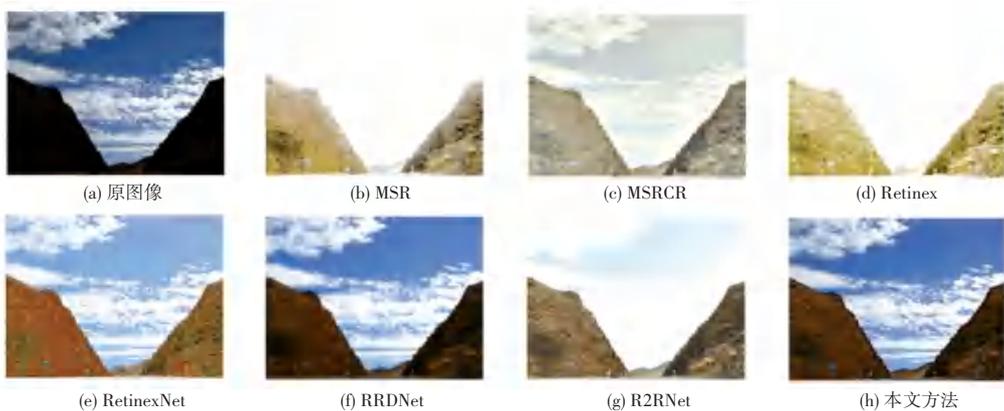


图8 DICM数据集的主观视觉实验对比

Fig. 8 Comparison of subjective visual experiments in DICM dataset

3.3.2 客观评价

本文选取全参考评价指标峰值信噪比($PSNR$)^[15],均方误差(MSE)和结构相似度($SSIM$)^[16]作为客观指标。 $PSNR$ 的值越大,说明增强后的图像失真越小,与对照图像越接近。 MSE 指标值越小,说明图像质量越好,2幅图像越相似。相对于 $PSNR$, $SSIM$ 更符合人类视觉观察到的直观效果, $SSIM$ 指标的值在0~1之间, $SSIM$ 的值越高说明2张图像之间的相似度更高。具体实验结果见表1,最好的结果加粗表示。

表1 客观评价指标对比表

Table 1 Comparison table of objective evaluation indicators

方法	$PSNR$	MSE	$SSIM$
原始图像	7.554	11 596.068	0.317
MSR	12.440	2 787.238	0.588
MSRCR	13.935	2 563.673	0.711
Retinex	13.642	3 993.284	0.880
RetinexNet	17.667	1 504.057	0.821
RRDNet	10.880	6 966.992	0.511
R2RNet	18.179	1 498.952	0.892
本文方法	18.562	1 467.178	0.932

从表1中可以看出,本文提出的方法在 *PSNR*, *MSE* 和 *SSIM* 指标上均取得了最佳分数,*PSNR* 和 *SSIM* 相较于次好结果分别提升了 2.1% 和 4.5%。相比于传统方法 MSR、MSRCR 以及 Retinex,本方法的 *PSNR* 以及 *SSIM* 均有较大提升,取得了更好的表现。相比于深度方法 RetinexNet,本方法的 *PSNR* 提升了 5.1%,这一点在图7中色彩方面的增强效果更接近于对照图像得以体现。同时,相比于 R2RNet 算法,本方法在 *SSIM* 上提升了 4.5%,图8中白云细节丢失的情况得到了显著改善。3个指标上的优势充分说明了本文增强方法的图像与对照图像更相似,说明了本文方法的优越性。

4 结束语

本文研究中,基于 Retinex 理论提出一种实现低照度图像增强的方法。该方法结合了 Retinex 理论和深度学习,网络包括分解网络、增强网络和降噪网络三部分组成。首先,分解网络基于 Retinex 理论将图像分解为反射和照度两个分量,并分别送入不同的网络进行运算,针对图像增强不同环节的问题分别进行处理。其次,增强子网络对照度图增强过程中使用了 U-Net 的网络结构,使用特征拼接的方式,可以更有效地提取特征信息,同时使用自适应融合模块,通过 Gamma 矫正得到更符合人眼感知曲线的输出结果,有效减少了色彩偏差。此外,通过去噪网络对照度图进行去噪,有效地降低了图像的噪声水平,使还原图像的颜色不失真,细节不丢失,使视觉效果更加平滑自然。实验结果表明,本文提出的方法在很大程度上提升了图像的暗部细节,在有效提升图像亮度的同时保留图像的纹理细节,生成的增强图像纹理清晰且色彩自然。

参考文献

- [1] FANG Ming, LI Hongna, LEI Lihong. A review on low light video image enhancement algorithms[J]. Journal of Changchun University of Science & Technology, 2016, 39(3): 56-64.
- [2] 王殿伟,王晶,许志杰,等.一种光照不均匀图像的自适应校正算法[J].系统工程与电子技术,2017,39(6):1383-1390.
- [3] LOH Y P, CHAN C S. Getting to know low-light images with the exclusively dark dataset[J]. Computer Vision and Image Understanding, 2019, 178: 30-42.
- [4] LEE C, LEE C, KIM C S. Contrast enhancement based on layered difference representation of 2D histograms[J]. IEEE Transactions on Image Processing, 2013, 22(12): 5372-5384.
- [5] RAHMAN Z, JOBSON D J, WOODSELL G A. Retinex processing for automatic image enhancement[J]. Journal of Electronic Imaging, 2004, 13(1): 100-110.
- [6] PIZER S M, AMBURN E P, AUSTIN J D, et al. Adaptive histogram equalization and its variations[J]. Computer Vision, Graphics, and Image Processing, 1987, 39(3): 355-368.
- [7] HUSSIAN K, RAHMAN S, KHALED S M, et al. Dark image enhancement by locally transformed histogram[C]//The 8th International Conference on Software, Knowledge, Information Management and Applications (SKIMA 2014). Piscataway, NJ: IEEE, 2014: 1-7.
- [8] SHEN Liang, YUE Zihan, FENG Fan, et al. MSR-Net: Low-light image enhancement using deep convolutional network[J]. arXiv preprint arXiv, 1711.02488, 2017.
- [9] RAHMAN Z, JOBSON D J. Multi-scale Retinex for color image enhancement[C]//Proceedings of 3rd IEEE International Conference on Image Processing. Piscataway, NJ: IEEE, 1996: 1003-1006.
- [10] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 770-778.
- [11] WEI Chen, WANG Wenjing, YANG Wenhan, et al. Deep Retinex decomposition for low-light enhancement[J]. arXiv preprint arXiv, 1808.04560, 2018.
- [12] ZHU Anqi, ZHANG Lin, SHEN Ying, et al. Zero-shot restoration of underexposed images via robust Retinex decomposition[C]//Proceedings of 2020 IEEE International Conference on Multimedia and Expo (ICME). Piscataway, NJ: IEEE, 2020: 1-6.
- [13] JIANG Hai, ZHU Xuan, REN Yang, et al. R2rnet: Low-light image enhancement via real-low to real-normal network[J]. Journal of Visual Communication and Image Representation, 2023, 90: 103712.
- [14] 云海姣,夏洋.结合自适应 Gamma 变换和 MSRCR 算法的低光照图像增强方法[J].中国科技论文,2022,17(11):1246-1253.
- [15] 鄢杰斌,方玉明,刘学林.图像质量评价研究综述:从失真的角度[J].中国图像图形学报,2022,27(5):1430-1466.
- [16] HORE A, ZIOU D. Image quality metrics: PSNR vs. SSIM[C]//2010 20th International Conference on Pattern Recognition. Piscataway, NJ: IEEE, 2010: 2366-2369.