

基于注意力机制和卷积神经网络的低照度图像增强

吴若有, 王德兴*, 袁红春**

上海海洋大学信息学院, 上海 201306

摘要 为了提高低照度图像的清晰度和避免颜色失真, 提出了基于注意力机制和卷积神经网络(CNN)的低照度图像增强算法, 以改善图像质量。首先根据 Retinex 模型合成训练数据, 将原始图像从 RGB (red-green-blue) 颜色空间变换到 HSI (hue-saturation-intensity) 颜色空间, 然后结合注意力机制和 CNN 构建 A-Unet 模型以增强亮度分量, 最后将图像从 HSI 颜色空间变换到 RGB 颜色空间, 得到增强图像。实验结果表明, 所提算法可以有效改善图像质量, 提高图像的清晰度, 避免颜色失真, 在合成低照度图像和真实低照度图像的实验中均能取得较好的效果, 主观和客观评价指标均优于对比算法。

关键词 图像处理; 卷积神经网络; 低照度图像增强; 注意力机制; HSI 颜色空间; Retinex 模型

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP57.201022

Low-Light Image Enhancement Based on Attention Mechanism and Convolutional Neural Networks

Wu Ruoyou, Wang Dexing*, Yuan Hongchun**

School of Information, Shanghai Ocean University, Shanghai 201306, China

Abstract To improve the clarity of low-light images and avoid color distortion, a low-light image enhancement algorithm based on the attention mechanism and convolutional neural network (CNN) is proposed to improve image quality. First, the training data is synthesized based on the Retinex model, and the original image is transformed from RGB (red-green-blue) color space to HSI (hue-saturation-intensity) color space. Then, an A-Unet model is constructed to enhance the brightness component by combining the attention mechanism and CNN. Finally, the enhanced image is obtained by transforming images from the HSI color space to the RGB color space. Experimental results show that the proposed algorithm can effectively improve the image quality, improve the image clarity, and avoid the color distortion. Good results can be obtained in the experiments of synthesizing low-light images and real low-light images, and the subjective and objective evaluation indexes are better than that of the comparison algorithm.

Key words image processing; convolutional neural networks; low-light image enhancement; attention mechanism; HSI color space; Retinex model

OCIS codes 100.2980; 100.4996

1 引言

在光线较差的环境中拍摄的图像通常能见度较低, 影响许多高级计算机视觉任务, 如目标检测^[1]、图像分割和视频监控等。目前, 数字视频技术已广泛应用于各种场合, 如重要场所的安全监控、辅助驾驶和交通管理等。在光照条件良好的条件下, 所拍摄的图像可以满足应用要求。而在弱光或夜间等条

件下所获得的图像质量往往较差, 给后续的图像处理带来较大挑战^[2]。

目前, 国内外针对低照度图像增强的方法主要有三种: 基于直方图均衡化(HE)的方法、基于 Retinex 理论的方法和基于数据驱动的方法。HE 的基本思想是使图像像素的直方图分布基本符合均匀分布, 它可以分为基于全局的方法和基于局部的方法。基于全局的直方图均衡化^[3]方法利用整个输

收稿日期: 2020-03-02; 修回日期: 2020-03-27; 录用日期: 2020-04-15

基金项目: 国家自然科学基金(41776142)

* E-mail: dawang@shou.edu.cn; ** E-mail: hcyan@shou.edu.cn

入图像的直方图信息进行变换函数估计,这种方法适用于整体增强,但会使某些高频灰度信息主导其他低频灰度信息。基于局部的直方图均衡化^[4]方法在图像上使用一个滑动窗口,仅考虑窗口内的像素,这种方法的计算代价较高,而且会使图像的某些部分过度增强。Retinex^[5]理论假设人眼观察到的图像可以表示为光照分量和反射分量的乘积^[6],光照分量反映光照的情况,而反射分量反映图像的固有属性。基于该理论的方法根据各种先验信息获取光照,然后通过调整光照来获取增强图像^[7]。Guo等^[8]首先通过RGB通道中每个像素的最大强度来估计光照图,然后利用光照的结构来细化输出。虽然基于Retinex理论的方法可以有效突出图像细节,但该方法可能会破坏图像的自然性,且仅把反射分量作为增强图像不太合理^[9]。基于数据驱动的方法需要构造成对的低光照图像和清晰图像数据集,然后通过各种模型学习它们之间的映射关系,以达到图像增强的目的。Kang等^[10]提出了一种基于示例的方法,该方法使用距离度量学习技术来确定相似性度量,从而增强相似区域的部分,然而这种方法是无参数的。此外,其他一些算法通过将图像从RGB色彩空间变换到HSI颜色空间来实现图像增强^[11],获得了较好的效果。深度学习在图像分类^[12]和图像超分辨率成像^[13]等领域应用广泛,而卷积神经网络具有局部连接、权值共享和池化等特性,可以有效学习低光照图像和清晰图像之间的映射关系,使模型的泛化能力更强。文献^[14]利用一个多尺度特征映射的特殊模块来构建低照度图像增强的神经网络,该方法的图像增强效果较好。文献^[15]提出了基于深度神经网络的低照度图像增强算法,通过卷积神经网络增强亮度分量,从而改善图像质量,但该方法会导致对图像的过度增强。

基于以上分析,本文提出了一种基于注意力机制^[16]和卷积神经网络的低照度图像增强算法。首先将图像转化为HSI图像,再利用构造的A-Unet模型对亮度分量进行增强,最后将图像从HSI空间变换到RGB空间以获得增强图像。该模型有效地利用了HSI图像的优势来避免色彩失真,通过加入注意力机制来有效提高增强效果。

2 基本原理

2.1 Retinex 理论

Retinex理论认为物体的颜色是由物体表面的反射属性决定的,与光照情况无关,它解释了人眼视

觉系统获取图像的过程,根据该理论可以合成需要的训练数据集。Retinex模型可以表示为

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

式中: $I(x, y)$ 表示人眼观察到的低光照图像; $L(x, y)$ 表示外界环境的光照分量; $R(x, y)$ 表示图像的反射分量,反映了图像的固有属性。

2.2 HSI 颜色模型

HSI颜色模型是由孟赛尔提出的,它反映了人的视觉系统感知彩色的方式,使用色调、饱和度和亮度描述物体的颜色。色调描述纯色的属性,饱和度表示纯色被白光稀释的程度,亮度表示颜色的明亮程度。HSI模型有两个重要特性:1)I分量与图像的彩色信息无关;2)H和S分量与人感受颜色的方式紧密相连。

2.3 注意力机制

2.3.1 通道注意力

给定一幅低照度图像,图像经过几个卷积层后,将生成一幅多通道特征图 $F \in \mathbf{R}^{C \times H \times W}$ (其中 C 、 H 和 W 分别表示通道数、高度和宽度; \mathbf{R} 为实数集)。每个通道的特征图所表达的信息是不同的。通道注意力是利用特征图中每个通道之间的关系来学习一个一维权重 $\mathbf{W}_c \in \mathbf{R}^{C \times 1 \times 1}$,然后将其乘以相应的通道。这样,通道注意力可以更加关注当前任务的有意义的语义信息。为了学习有效的权重表示,首先通过全局平均池化和全局最大池化来聚合空间维度信息,为每个通道生成两个特征描述符,然后将这两个特征描述符输入一个隐层(隐层单元数为 $C/8$)的共享多层感知器,生成具有代表性的特征向量,通过元素求和操作合并输出特征向量,最后利用一个sigmoid函数得到最终的通道注意力图。该计算过程可以描述为

$$\mathbf{W}_c(F) = \text{sigmoid}\{\text{MLP}[\text{AvgPool}(F)] + \text{MLP}[\text{MaxPool}(F)]\}, \quad (2)$$

式中: $\mathbf{W}_c(F)$ 为通道注意力图;MLP为多层感知器;AvgPool为平均池化;MaxPool为最大池化。

2.3.2 空间注意力

对于空间注意力,它关注的是对当前任务有价值的地方。空间注意力利用不同空间位置之间的关系来学习二维空间权重图 \mathbf{W}_s ,然后将其与相应的空间位置相乘,以学习更具代表性的特征。为了有效地学习空间权重关系,首先通过全局平均池化和全局最大池化操作为每个空间位置生成两个特征描述符。然后通过 7×7 的卷积运算($f^{7 \times 7}$)将两个特征描述符集中在一起生成空间注意力图。最后使用一

个 sigmoid 函数将空间注意力图缩放到 0~1。 W_s 的计算公式可以表示为

$$W_s(\mathbf{F}) = \text{sigmoid}\{f^{7 \times 7}\{[\text{AvgPool}(\mathbf{F}); \text{MaxPool}(\mathbf{F})]\}\} \quad (3)$$

3 A-Unet 网络增强模型

3.1 模型结构

本文将 HSI 颜色空间和卷积神经网络的优点相结合,对低照度图像进行增强。首先将原始图像从 RGB 空间变换到 HSI 空间,得到色调分量 H、饱和度分量 S 和亮度分量 I,再利用构造的 A-Unet 网络对亮度分量进行增强,最后将图像从 HSI 空间变换到 RGB 空间,得到增强的图像。

A-Unet 网络结构如图 1 所示,由 U 型结构的卷积神经网络组成。整个网络的输入为亮度分量 I,输出为经过增强后的亮度分量,为了学习低光照图像和正常光照图像之间的映射关系,要保证网络输入和输出尺寸相同。整个网络的结构借鉴了 U-net^[17] 网络,删除了 copy 和 crop 操作,在上采样后添加了注意力模块用来提高增强效果,网络深度为 3。在卷积部分添加了 padding 操作来保证卷积前后的图像尺寸相同,除了最后一层卷积核的大小为 1×1 ,其他卷积核的大小都为 3×3 。池化层都采用 2×2 的池化来减少参数的数量。此外,添加了跳跃连接和 concatenate 操作,激活函数为 Mish^[18],Mish 函数没有硬零边界,从而使得梯度更加平滑。整个算法的流程如图 2 所示。

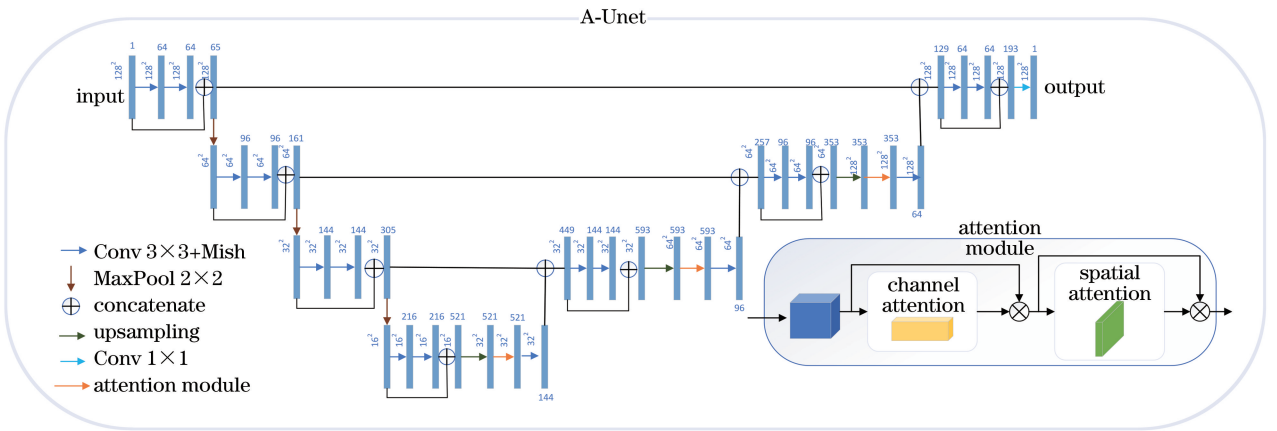


图 1 A-Unet 网络结构

Fig. 1 A-Unet network structure

3.2 损失函数

本文通过在代价函数中最小化损失函数和最大化结构相似性来提高图像整体感知质量。均方误差是为了度量增强后的图像和真实图像之间的像素值的差异,其计算过程可以描述为

$$L_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N |G(\mathbf{I}) - \mathbf{A}| \quad (4)$$

式中: \mathbf{I} 表示输入图像; $G(\mathbf{I})$ 和 \mathbf{A} 分别表示增强分量和地面真实分量; N 为输入图像数量。通过引入结构损失 L_{SSIM} 可以保持图像细节,避免图像模糊,其计算过程可以描述为

$$L_{\text{SSIM}} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

式中: μ_x 和 μ_y 为像素平均值; σ_x^2 和 σ_y^2 为方差; σ_{xy} 为协方差; C_1 和 C_2 为防止分母为 0 的常量。本文总的损失函数定义为

$$L_{\text{total}} = \lambda_{\text{MSE}} L_{\text{MSE}} + \lambda_{\text{SSIM}} (1 - L_{\text{SSIM}}) \quad (6)$$

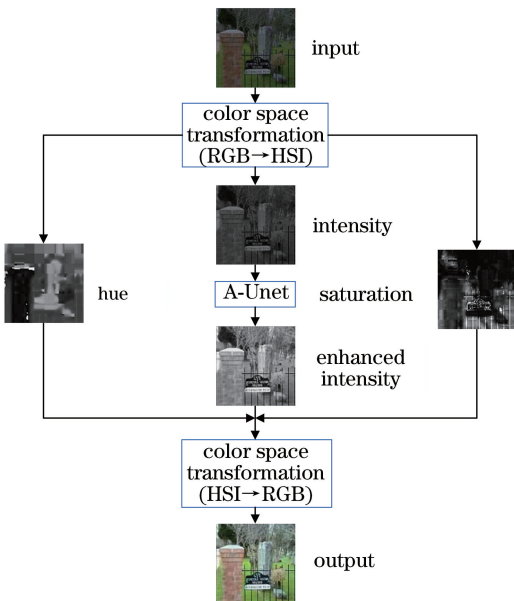


图 2 算法流程图

Fig. 2 Algorithm flowchart

式中: λ_{MSE} 和 λ_{SSIM} 表示 MSE、SSIM 对应的平衡权重。

3.3 实验设置

本文实验以 Pycharm 为实验平台,利用 Keras 和 Tensorflow 深度学习开源框架,CPU (Central Processing Unit) 为 Inter Core I5-9300H,主频为 2.40 GHz,内存为 24 GB,GPU(Graphics Processing Unit)为 NVIDIA GeForce RTX2060(6 GB)。

在训练中,本文的 batch_size 为 6,所有输入图像的尺寸为 128×128 ,并且被归一化为 0 到 1。(6) 式中的权重 $\lambda_{MSE} = 0.7, \lambda_{SSIM} = 0.3$ 。在每个卷积操作后都添加批归一化(BN)来提高模型的训练速度,从而减小网络中间数据分布的改变对模型参数训练的影响;通过添加 Dropout 操作来减少训练时间,解决过拟合问题。在训练过程中使用 Adam 优化器并采用 Lookahead^[19] 优化策略。Lookahead 优化策略通过提前观察另一个优化器生成的权重序列来选择搜索方向,它不仅能够提高学习稳定性,还能提升

收敛速度和效果。此外,本文还采用学习率衰减策略,初始学习率为 0.001,每经过 10 个 epoch 就将学习率缩小为前一个 epoch 的 10%,总计训练 50 个 epoch。

4 实验结果分析

4.1 实验数据

由于标准参考图像不易采集,如何生成真实的训练数据是低光照图像增强的主要挑战。从(1)式可以看出,低光照图像为光照分量和反射分量(地面真实图像)的乘积。为了保证合成数据的有效性,本文从 COCO image dataset^[20] 中挑选了 14106 张覆盖大多数场景的光照充足图像作为标签数据,然后让光照分量 L 的元素值服从 $[0,1]$ 的均匀分布,得到对应的低照度图像数据集。图 3 给出了部分图像的合成图和标签图,上面 4 张为标签图,下面 4 张为合成图。然后按约 4:1 的比例将数据集划分为训练集和验证集,即训练集为 11284 张,验证集为 2822 张。




图 3 样本数据示例

Fig. 3 Examples of sample data

4.2 模型参数对比

不同的损失函数会给模型的性能带来不同的影响,好的损失函数会使增强后的图像更加接近原始图像。为了比较不同损失函数的增强性能,本文从定性和定量的角度对 L_{MSE} 、 L_{SSIM} 和 L_{total} 三种损失函数进行实验,从 LIVE1 数据集中挑选了 5 张图片进行实验,实验结果如表 1 所示,其中最后一行表示平均值±标准差(SD)。总体而言, L_{total} 损失函数结合了 L_{MSE} 和 L_{SSIM} 损失函数的优势,得到的 PSNR 和 SSIM 的平均值都优于 L_{MSE} 和 L_{SSIM} 损失函数。其中,采用 L_{MSE} 、 L_{SSIM} 、 L_{total} 得到的 PSNR 平均值分别为 24.5200 ± 1.3800 、 23.2200 ± 2.0900 和 26.4500 ± 0.5700 ,SSIM 平均值分别为 0.8180 ± 0.0550 、 0.8600 ± 0.0410 和 0.8660 ± 0.0450 。由于 MSE 求的是两张图片之间的像素值的差,所以在峰

值信噪比指标上,采用 L_{MSE} 得到的值比 L_{SSIM} 高一些;而 SSIM 求的是两张图片之间的结构差异性,所以在结构相似性指标上,采用 L_{SSIM} 得到的值要比 L_{MSE} 大一些。此外,从 SSIM 指标可以看出,采用 L_{SSIM} 和 L_{total} 得到的值比较接近,说明采用 L_{total} 时 SSIM 值占了主要部分。综合考虑,本文选用 L_{total} 损失函数。

4.3 实验分析

通过大量实验,将本文方法与现有方法进行比较。在定量对比中,本文使用 MSE、PSNR 和 SSIM,以及最近提出的一些评价指标,包括 GMSD (Gradient Magnitude Similarity Deviation)^[21]、LOE (Lightness Order Error)^[22]、TMQI (Tone Mapped Image Quality Index)^[23]、IE (Information Entropy)、NIQE (Natural Image Quality

表1 不同损失函数的性能对比

Table 1 Performance comparison of different loss functions

Image	PSNR /dB			SSIM		
	L_{MSE}	L_{SSIM}	L_{total}	L_{MSE}	L_{SSIM}	L_{total}
img151	23.0820	23.4980	25.8330	0.7353	0.8126	0.8161
img165	22.7292	25.3378	26.5570	0.7832	0.8118	0.8115
img167	25.4330	22.8350	27.4850	0.8459	0.8929	0.9000
img168	26.3010	19.4620	26.1940	0.8943	0.9110	0.9253
img169	25.0620	24.9640	26.1580	0.8328	0.8734	0.8752
Average±SD	24.5200±1.3800	23.2200±2.0900	26.4500±0.5700	0.8180±0.0550	0.8600±0.0410	0.8660±0.0450

Evaluator)^[24]和SSEQ(Spatial-Spectral Entropy-Based Quality)^[25]。首先,进行合成低照度图像实验,然后再进行真实低照度图像实验,从主观视觉和客观评价指标两方面对实验结果进行对比,对比算法包括CLAHE、NPE^[7]、LIME^[8]、LLCNN^[14]和Ma^[15]。

4.3.1 合成低照度图像实验

本文首先对人工合成的低照度图像进行实验,为了与其他算法进行对比,从公开数据集LIVE1中选取13张图片作为测试集,实验结果如图4和表2所示。在定性对比中,从测试集中选取4幅图像作为示例来进行说明,如图4(a)~(d)所示。从图4可以看出,NPE、LIME、LLCNN、Ma和本文算法都可以对合成低照度图像进行增强,从而提高图像清晰度,而CLAHE算法对图像的增强效果较差,而且还出现颜色失衡现象。在图4(b)中,飞机周围出

现明显的阴影区域,影响整体的视觉感官。从图像亮度来看,NPE、LIME、LLCNN和本文算法的图像增强效果明显;Ma算法增强后的图像在亮度方面有所改善,但出现了阴影区域,如图4(b)和图4(d)中,飞机和塔的周围出现了阴影条。NPE和LLCNN算法在局部区域的亮度增强方面效果稍差一些,在图4(d)中,房子窗户区域和围栏处的亮度提高不明显。整体来看,LIME和本文算法对低照度图像改善效果最为明显,图像的清晰度明显提高,也没有出现颜色失衡现象;但LIME算法增强后的图像在部分区域出现曝光现象,在图4(c)和图4(d)中,屋顶区域和塔壁部分区域图像被过度增强;而本文算法结合SSIM和MSE损失函数的优势,可以有效增强低照度图像的亮度,提高图像的清晰度,避免颜色失衡。

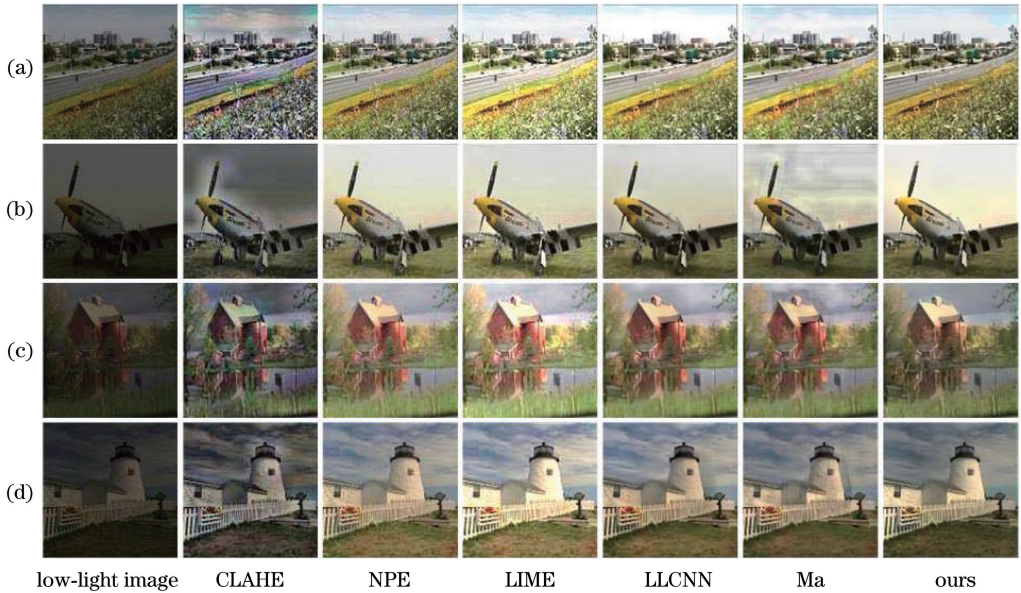


图4 不同算法在合成低照度图像方面的定性对比。(a)图像“flowersonih35”;
(b)图像“plane”;(c)图像“house”;(d)图像“lighthouse”

Fig. 4 Qualitative comparison of synthetic low-light images obtained by different algorithms. (a) Image “flowersonih35”;
(b) image “plane”; (c) image “house”; (d) image “lighthouse”

在定量对比中,由于参考图像已知,因此可以通过比较增强图像和参考图像来说明各种算法的性能。本文实验选取 MSE、PSNR、SSIM、TMQI 和 GMSD 作为合成低照度图像的定量评价指标。TMQI 用于评估图像质量,其值越大表示结构保真度越高,图像质量越好。GMSD 可以反映图像的质

表 2 不同算法在合成低照度图像上的定量对比

Table 2 Quantitative comparison of synthetic low-light images obtained by different algorithms

Image	MSE	PSNR /dB	SSIM	TMQI	GMSD
Input image	7600.19	9.83	0.46	0.82	0.115
Image obtained by CLAHE	2799.89	15.75	0.76	0.83	0.087
Image obtained by NPE ^[7]	463.44	22.06	0.85	0.87	0.034
Image obtained by LIME ^[8]	1885.24	16.34	0.79	0.82	0.052
Image obtained by LLCNN ^[14]	463.49	22.17	0.87	0.86	0.054
Image obtained by Ma ^[15]	417.77	22.64	0.82	0.88	0.085
Image obtained by our method	146.56	26.72	0.88	0.88	0.033

4.3.2 真实低照度图像实验

为了验证本文算法在真实低照度图像上的有效性,实验从 DICM^[26]、LIME^[8] 和 MEF^[27] 数据集中挑选 15 幅图像作为测试集,实验结果如图 5 和表 3 所示。在定性对比中,从测试集中挑选 4 幅图像作为示例来进行说明,如图 5(a)~(d)所示。从图 5 可以看出,不同算法都可以提高图像的清晰度,但

量,其值越小表示图像质量越好。表 2 为不同算法在测试集上获得的指标平均值。从表 2 可知,本文算法在 MSE、PSNR、SSIM 和 GMSD 指标上的平均值均优于其他算法,虽然其在 TMQI 指标上不占优势,但总体来说本文算法的泛化性能较好,增强后的图像更加接近于原始图像。

NPE 算法对亮度的增强效果稍差一些,且 CLAHE、NPE 和 LIME 算法增强后的图像颜色不协调。在图 5(a)和 5(c)中,教堂墙壁和矿井轨道的颜色和原始图像相差较大,并且矿井中灯的颜色泛红,出现光晕现象。相反,基于神经网络的方法(LLCNN、Ma 和本文算法)在图像细节处理方面效果较好,增强后的图像更符合人的视觉感官。




图 5 不同算法在真实低照度图像上的定性对比。(a)(c)图像来自 DICM 数据集;
(b)图像来自 LIME 数据集;(d)图像来自 MEF 数据集

Fig. 5 Qualitative comparison of different algorithms on real low-light images. (a)(c) Images from DICM dataset;
(b) image from LIME dataset; (d) image from MEF dataset

在对真实低照度图像进行定量对比时,选取了无参考评价指标,包括 IE、NIQE、LOE 和 SSEQ。其中,IE 表征图像所含信息量的大小,其值越大,则图像所含信息量越丰富;NIQE 用来评估图像的失真程度,其值越小表示图像失真程度越小;LOE 用

来评估图像自然度的保持能力,其值越小表示图像越自然;SSEQ 用于评估图像的失真程度,其值越小表示图像失真程度越小。表 3 为不同算法在测试集上各种评价指标的平均值。从表 3 可知,本文算法除了在 IE 上略低于 CLAHE 算法,在 NIQE、LOE

表3 不同算法在真实低照度图像上的定量对比

Table 3 Quantitative comparison of different algorithms on real low-light images

Method	IE	NIQE	LOE	SSEQ
CLAHE	7.59	8.08	1279.36	15.64
NPE ^[7]	7.44	6.64	997.36	19.79
LIME ^[8]	7.55	8.24	875.33	13.50
LLCNN ^[14]	7.21	7.42	805.73	17.93
Ma ^[15]	7.27	7.06	942.97	14.84
Ours	7.56	6.29	664.76	11.06

和 SSEQ 指标上都高于其他算法,说明本文算法得到的增强图像失真程度更小,图像更加自然。

5 结 论

为了解决低照度图像清晰度不高、颜色失衡的问题,提出了一种基于注意力机制和卷积神经网络的低照度图像增强算法。首先根据人的视觉特征,将原始低照度图像从 RGB 空间变换到 HSI 空间,充分利用 HSI 空间的优势来解决颜色失衡问题,通过构建一个 A-UNet 模型对亮度分量进行增强,再将图像从 HSI 空间变换到 RGB 空间,得到增强图像。实验结果表明,本文算法可以有效提高图像清晰度,改善图像质量,避免颜色失真,在图像细节增强方面表现较好。下一步研究将继续优化模型,以改善图像阴影区域的增强效果。

参 考 文 献

- [1] Li L H, Lun M Z, Lian J, et al. Convolutional neural network-based vehicle detection method [J]. Journal of Jilin University (Engineering and Technology Edition), 2017, 47(2): 384-391.
李琳辉, 伦梅智, 连静, 等. 基于卷积神经网络的道路车辆检测方法[J]. 吉林大学学报: 工学版, 2017, 47(2): 384-391.
- [2] Li Q Z, Liu Q. Adaptive enhancement algorithm for low illumination images based on wavelet transform [J]. Chinese Journal of Lasers, 2015, 42(2): 0209001.
李庆中, 刘清. 基于小波变换的低照度图像自适应增强算法[J]. 中国激光, 2015, 42(2): 0209001.
- [3] Celik T, Tjahjadi T. Contextual and variational contrast enhancement [J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2011, 20(12): 3431-3441.
- [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] Dong X, Wang G, Pang Y, et al. Fast efficient algorithm for enhancement of low lighting video[C]//2011 IEEE International Conference on Multimedia and Expo, July 11-15, 2011, Barcelona, Spain. New York: IEEE Press, 2011: 12301290.
- [6] Li Y, Brown M S. Single image layer separation using relative smoothness[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 2752-2759.
- [7] Wang S H, Zheng J, Hu H M, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images[J]. IEEE Transactions on Image Processing, 2013, 22(9): 3538-3548.
- [8] Guo X J, Li Y, Ling H B. LIME: low-light image enhancement via illumination map estimation [J]. IEEE Transactions on Image Processing, 2017, 26(2): 982-993.
- [9] Yue H J, Yang J Y, Sun X Y, et al. Contrast enhancement based on intrinsic image decomposition [J]. IEEE Transactions on Image Processing, 2017, 26(8): 3981-3994.
- [10] Kang S B, Kapoor A, Lischinski D. Personalization of image enhancement [C]//2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 13-18, 2010, San Francisco, CA, USA. New York: IEEE Press, 2010: 1799-1806.
- [11] Song R X, Li D, Wang X C. Low illumination image enhancement algorithm based on HSI color space[J]. Journal of Graphics, 2017, 38(2): 217-223.
宋瑞霞, 李达, 王小春. 基于 HSI 颜色空间的低照度图像增强算法[J]. 图学学报, 2017, 38(2): 217-223.
- [12] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [13] Li S M, Lei G Q, Fan R. Depth map super-resolution reconstruction based on convolutional neural network [J]. Acta Optica Sinica, 2017, 37

- (12): 1210002.
李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图超分辨率重建 [J]. 光学学报, 2017, 37(12): 1210002.
- [14] Tao L, Zhu C, Xiang G, et al. LLCNN: a convolutional neural network for low-light image enhancement [C] // 2017 IEEE Visual Communications and Image Processing (VCIP), December 10-13, 2017, St. Petersburg, FL, USA. New York: IEEE Press, 2017: 17614346.
- [15] Ma H Q, Ma S P, Xu Y L, et al. Low-light image enhancement based on deep convolutional neural network [J]. Acta Optica Sinica, 2019, 39(2): 0210004.
马红强, 马时平, 许悦雷, 等. 基于深度卷积神经网络的低照度图像增强 [J]. 光学学报, 2019, 39(2): 0210004.
- [16] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [M] // Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [17] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M] // Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 234-241.
- [18] Misra D. Mish: a self regularized non-monotonic activation function [EB/OL]. (2019-08-23) [2020-03-02]. <https://arxiv.org/abs/1908.08681>.
- [19] Zhang M R, Lucas J, Hinton G, et al. Lookahead Optimizer: k steps forward, 1 step back [EB/OL]. (2019-12-03) [2020-03-02]. <https://arxiv.org/abs/1907.08610>.
- [20] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: common objects in context [EB/OL]. (2015-02-21) [2020-03-02]. <https://arxiv.org/abs/1405.0312>.
- [21] Xue W F, Zhang L, Mou X Q, et al. Gradient magnitude similarity deviation: a highly efficient perceptual image quality index [J]. IEEE Transactions on Image Processing, 2014, 23(2): 684-695.
- [22] Ying Z Q, Li G, Gao W. A bio-inspired multi-exposure fusion framework for low-light image enhancement [EB/OL]. (2017-11-02) [2020-03-02]. <https://arxiv.org/abs/1711.00591>.
- [23] Yeganeh H, Wang Z. Objective quality assessment of tone-mapped images [J]. IEEE Transactions on Image Processing, 2013, 22(2): 657-667.
- [24] Mittal A, Soundararajan R, Bovik A C. Making a "completely blind" image quality analyzer [J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.
- [25] Liu L X, Liu B, Huang H, et al. No-reference image quality assessment based on spatial and spectral entropies [J]. Signal Processing: Image Communication, 2014, 29(8): 856-863.
- [26] Lee C, Lee C, Kim C S. Contrast enhancement based on layered difference representation [C] // 2012 19th IEEE International Conference on Image Processing. September 30-October 3, 2012, Orlando, FL, USA. New York: IEEE Press, 2012: 965-968.
- [27] Ma K D, Zeng K, Wang Z. Perceptual quality assessment for multi-exposure image fusion [J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2015, 24(11): 3345-3356.