

基于注意力机制和 Retinex 的低照度图像增强方法

黄辉先, 陈凡浩*

湘潭大学信息工程学院, 湖南 湘潭 411105

摘要 低照度图像增强的主要目的是提升图像的整体光照度, 进而呈现更多有用的信息。针对低照度图像的整体照度低、对比度弱和噪声较高的问题, 提出基于注意力机制和 Retinex 算法的低照度图像增强方法。该方法首先将低照度图像分解为不变性反射图和缓变平滑性光照图; 再通过注意力机制提取图像的空间和局部物体信息, 从而能够保证增强过程中利用空间和局部物体信息进行约束; 同时增加色彩损失函数改善图像饱和度, 用以补偿和校准增强过程中的对比度细节; 改进低照度图像和合成方法, 加入真实噪声有效扩充训练数据集。最终在 LOL 和 SID 数据集上实验表明, 所提方法的主观感受和客观评价指标均有所提升。

关键词 图像处理; 图像增强; 低照度图像增强; Retinex 算法; 注意力机制

中图分类号 TN911.73

文献标志码 A

doi: 10.3788/LOP57.201004

Low-Illumination Image Enhancement Method Based on Attention Mechanism and Retinex

Huang Huixian, Chen Fanhao*

College of Information Engineering, Xiangtan University, Xiangtan, Hunan 411105, China

Abstract The goal of low-illuminance image enhancement is to increase the overall illuminance of the image, thereby presenting more useful information. Aiming at the problems of low illumination, low contrast and high noise in low-illumination images, a method of image enhancement method based on attention mechanism and Retinex algorithm is proposed. This method first decomposes the low-illumination image into an invariant reflection map and a slowly-varying smooth illumination map. Then, it uses the attention mechanism to extract the spatial and local object information of the image, so as to ensure that the spatial and local object information is used for constraints during the enhancement process. Moreover, it increases the color loss function to improve the image saturation to compensate and calibrate the contrast details in the enhancement process. Furthermore, it improves the low-illumination image and synthesis method, add real noise, and efficiently expands the training data set. Finally, the experiments on the LOL and SID data sets show that the subjective and objective evaluation indicators of the proposed method improved.

Key words image processing; image enhancement; low-illumination image enhancement; Retinex algorithm; attention mechanism

OCIS codes 100.2000; 100.2960; 100.2980

1 引言

军事任务和汽车自动驾驶等领域的智能化发展与计算机视觉算法息息相关。然而, 实际环境中存在夜晚光线较弱等外界因素, 所以在上述领域中经常会捕获到噪声高、对比度低和能见度差的图像。这些低照度图像在环境光照降低到一定程度后逐渐

发生扭曲, 环境噪声逐渐掩盖物体信息, 严重影响了系统的性能, 为此对于低照度图像的增强备受关注。

目前, 国内外已提出很多相关算法。在实验初期, 主要采用基于统计的增强方法来实现照度的矫正。该类型方法首先将像素看作未知分布的随机变量来统计每个灰度级出现的次数, 然后累计归一化的直方图, 最后建立统计变换以增加图像的全局对

收稿日期: 2020-01-16; 修回日期: 2020-02-19; 录用日期: 2020-02-24

* E-mail: chenfanhaohao@163.com

比度^[1]。近期,潘强等^[2]使用了权重约束决策来解决直方图均衡化初期的图像存在冲蚀效应与棋盘效应的问题,这种解决方式虽然易于解释,但是在增强有用信息的同时增加了背景噪声,目前已较少使用。基于暗原色模型的增强方法根据生物视觉和物理光学的先验知识对图像建立光照约束方程,以获得增强图像。暗原色模型是假设图像中除了红、绿、蓝三原色外,还存在亮度很低的像素,即暗原色。通过对暗原色所在的暗通道进行滤波,He等^[3]在去雾增强方面取得了较好的效果。梅英杰等^[4]结合了暗通道与多尺度 Retinex(MSRCR)算法,解决了雾霾浓度分布不均以及色彩失衡的问题。针对水下图像增强的问题,李黎等^[5]基于暗原色理论修复了暗通道,获得较好的增强效果;王鑫等^[6]在暗通道理论中融合稀疏表示来抑制噪声,进一步改善了水下增强图像的质量,但是暗通道计算资源耗费巨大。在 Retinex 理论中,假设图像由反射图和光照图构成,为此可以很好地描述低照度光线分布的情况,且计算资源消耗较少。近年来,司马紫菱等^[7]在基于色彩恢复的 MSRCR 算法的基础上,提出了低照度图像增强算法,该算法改善了部分低照度图像中整体亮度偏白、对比度差和视觉信息偏弱等问题。针对算法的快速性,Zotin^[8]提出了多尺度 Retinex(MSR)算法,大大提高了处理速度。在跟踪算法的准确性方面,张红颖等^[9]结合了颜色信息改善 Retinex 算法中“时空上下文跟踪算法”的准确性,然而图像的分离过程为病态问题,分解公式复杂且参数较多。

近年来,LLNet 算法^[10]与 RetinexNet 算法^[11]是基于 Retinex 模型的原理建立的,均采用中间过程生成光照图,利用卷积网络来分离反射图和光照图,并从正常的光照图上学习光照图。由于卷积网

络是一种依靠数据自提取特征的算法,只需要合适的数据集、网络结构和损失函数,网络就会自动指导图像分离。其中 LLNet 算法获得光照图后,直接将光照图作为增强图像;RetinexNet 算法获得光照图后,对光照图进行增强处理,对增强后的反射图与光照图上的像素进行点乘以得到照度增强后的图像。因此,Retinex 算法在一定程度上解决了参数繁多和公式复杂的问题。

本文在 RetinexNet 算法的基础上进行改进:结构上,使用注意力机制(AM)改善网络结构,提取空间信息;在损失函数中加入色彩损失函数以调整色彩饱和度,并与局部特征相结合;在数据集中使用合成数据以扩充数据量,提高模型的泛化性能。

2 AM 层

采用 RetinexNet 算法生成光照图 $L(i, j)$ 后,不断迭代卷积结构以学习照度特征,其中 (i, j) 表示对应的特征像素坐标。其中 $L(i, j)$ 中照度特征的感受野^[12]可以表示为

$$\mathbf{F}_{l+1}(i, j) = \mathbf{F}_l(i, j) \times \boldsymbol{\omega}_{l+1} + \mathbf{b} = \sum_{k=1}^K \sum_{i=1}^W \sum_{j=1}^H \mathbf{F}_{l,k}(i, j) \times \boldsymbol{\omega}_{l+1,k} + \mathbf{b}, \quad (1)$$

式中: \mathbf{F}_{l+1} 和 \mathbf{F}_l 分别表示第 $l+1$ 层卷积层的输出和第 l 层的输入; $\boldsymbol{\omega}$ 和 \mathbf{b} 分别表示卷积层的权重和偏置项; K 表示特征图的通道数; W 和 H 分别表示卷积核的总行数和总列数。相邻卷积之间通过激活函数 $\sigma(\mathbf{F}_{l+1}) = \max(0, \boldsymbol{\omega}_{l+1}^T \mathbf{F} + \mathbf{b})$ 来连接。卷积感受野生成照度特征的过程如图 1(a)所示。从图 1(a)可以看到,经过卷积操作处理后,原图像中 $3 \text{ pixel} \times 3 \text{ pixel}$ 大小的像素可以生成 1 个照度特征。照度特征可视化结果如图 1(b)所示。从图 1(b)可以看到,照度特征在空间上是不连续的形状。




图 1 照度特征的生成过程及结果。(a)生成过程;(b)照度特征可视化结果

Fig. 1 Generation process and results of illuminance characteristics. (a) Generation process; (b) illumination feature visualization result

空间上不连续的特征制约着 RetinexNet 等算法的表现能力。目前,沈旭等^[13]将 AM 层融合在红

外小目标的检测算法中,可以有效提高检测目标的亮度以及调整对比度,保证了红外小目标的高视觉

质量显示。万程等^[14]提出了 AM 层与卷积神经网络相结合的方式,在测试集上的分类准确率达到 97.65%。为了提取连续的空间特征,在 LLNet 算法和 RetinexNet 算法的基础上加入 AM 层进行实验。加入 AM 层可将原本特征信息扩大 $(\omega_{l,AM} + 1)$ 倍,其中 $\omega_{l,AM}$ 为第 l 层加入 AM 的权重,则卷积层之间的传递公式变为

$$F_{l+1,AM}(i, j) = (\omega_{l,AM} + 1) \times [F_l(i, j) \times \omega_{l+1} + b], \quad (2)$$

式中: $F_{l+1,AM}(i, j)$ 为第 $l + 1$ 层加入 AM 的特征图。

ω_{AM} 是在 Stentiford^[15]提出的 AM 层上进行的,对每一个像素点计算其中心与其他像素点间的距离,距离越小,则像素之间的相似度越高。图像块的距离可以表示为

$$d_i = \frac{1}{C(x)} \sum_{\forall j} f(x_i, x_j) x_j, \quad (3)$$

式中: x_i, x_j 表示输入图像的特征点; $C(x)$ 表示归一化系数, $C(x) = \frac{1}{\sum_{\forall i} \exp(x_i x_j)}$; $f(x_i, x_j)$ 表示

相似系数, $f(x_i, x_j) = \exp(x_i x_j)$,可以计算待测像素与其他像素点之间的距离。AM 层中图像块之间的距离,最终可表示为

$$d_i = \sum_{\forall j} \frac{f(x_i, x_j)}{C(x)} x_j = \sum_{\forall j} \frac{\exp(x_i x_j)}{\sum_{\forall i} \exp(x_i x_j)} x_j. \quad (4)$$

2.1 AM 层的可视化

可视化后的 AM 层可以将特征图中卡车和轨道等物体的空间信息权重化(红色区域表示 ω_{AM} 值较大,蓝色区域表示 ω_{AM} 值较小),结果如图 2 所示。相比于未加入 AM 层的算法,加入 AM 层的算法可将空间域上的相关性信息加入网络中,使得网络对物体的空间信息更敏感。

2.2 对光照图的影响

图 3 为加入 AM 层前后的光照图。从图 3 可以看到,加入 AM 层后的书柜和书本等物体表面光线分布比未加入 AM 层前更自然。在 Retinex 算法中假设图像由反射图和光照图构成,若光照图的效果越好,其增强效果越好,故添加 AM 层的网络更容易生成光线分布较好的光照图。




图 2 加入 AM 层的可视化结果。(a)原始图像;(b)可视化结果

Fig. 2 Add visual results of AM layer. (a) Original images; (b) visualized results




图 3 加入 AM 层前后对光照图的影响结果及其局部放大图。(a)光照图;(b)反射图;(c)未加入 AM 层的光照图;(d)加入 AM 层的光照图

Fig. 3 Results of influence on light map before and after adding attention mechanism layer and its partial enlarged maps. (a) Light maps; (b) reflection maps; (c) light maps without AM layer; (d) light maps with AM layer

3 AM-RetinexNet

3.1 AM-RetinexNet 结构与运行

AM-RetinexNet 结构如图 4 所示,该结构包含分解和增强两个子网络。分解网络是将图像对分解为光照图和反射图。随后,考虑到噪声的问题,对反射图采用基于 BM3D (Block-Matching and 3D filtering)^[16] 的图像去噪和增强的处理方法,将光照图输入增强网络中。增强网络采用加入 AM 层的 U-Net^[17] 架构。

U-Net 架构因其下采样路径(特征提取)与上采样路径(恢复图像)对称,形如一个 U 形结构故称 U-Net。因 U-Net 架构中上下采样层之间设有“复制与修剪通路(copy and crop)”,故特征图可以直接在采样路径之间传递,使上采样网络能够有效推断

丢失的像素,进而获得高分辨率的光照图像。

AM-RetinexNet 运行过程如图 4 所示。训练时,将图像对中的低照度图像(S_{low})和正常图像(S_{normal})送入卷积神经网络后,再送入分解网络中。其中 S_{normal} 作为真实标签,且只在训练时输入。根据低照度图像与正常图像反射率一致的原理且共享分解网络的权值,则分解网络输出反射图(R_{low})和光照图(I_{low})。利用增强网络对 I_{low} 进行照度增强,得到增强后的图像 \tilde{I}_{low} ,其骨架结构为 U-Net。其中在 AM 层生成的权重注意力图用以捕获空间结构关系,减少图像色块和边界扭曲情况的发生。采用 BM3D 算法对分解后的 R_{low} 进行去噪,得到去噪后的图像 \tilde{R}_{low} ,避免反射图像上的噪声与图像纹理混淆。将 \tilde{I}_{low} 和 \tilde{R}_{low} 相乘后得到增强图像 \tilde{S}_{low} 。

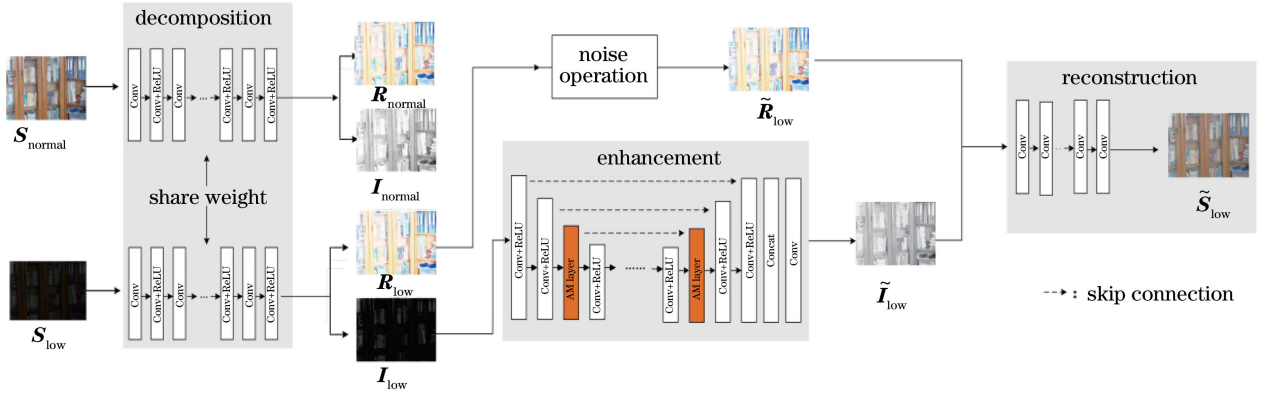


图 4 AM-RetinexNet 结构示意图

Fig. 4 AM-RetinexNet structure diagram

3.2 损失函数

3.2.1 色彩损失函数

颜色角度计算公式 $\angle(x, y)$ 是由 Dony 等^[18] 提出的,常用来评价增强图像之间的色彩差异。实验将其加入损失函数中,表达式为

$$L_c = \left\| \sum_p \angle [(S_{normal})_p, (\tilde{S}_{low})_p] \right\|_2, \quad (5)$$

式中: $(S_{normal})_p$ 和 $(\tilde{S}_{low})_p$ 分别表示在 S_{normal} 和 \tilde{S}_{low} 上与点 p 对应的像素; $\sum_p \angle [(S_{normal})_p, (\tilde{S}_{low})_p]$ 表示 $(S_{normal})_p$ 和 $(\tilde{S}_{low})_p$ 的颜色角度矢量和; $\|\cdot\|_2$ 表示 2-范数。

3.2.2 分解与重建损失函数

分解与重建损失函数是参考 RetinexNet 算法中损失函数部分而设计的。分解损失函数主要控制反射图与光照图的分解过程^[11],表达式为

$$L_d = \|R_{low} - R_{normal}\|_1, \quad (6)$$

式中: $\|\cdot\|_1$ 表示 1-范数。重建损失函数的表达式为

$$L_r = \|S_{normal} - \tilde{I}_{low} \times \tilde{R}_{low}\|_1, \quad s. t.$$

$$(S_{normal})_c \leq 1, (\tilde{I}_{low} \times \tilde{R}_{low})_c \leq 1, \quad (7)$$

式中: $I \sim low \times R \sim low$ c 表示 RGB 三通道; $(S_{normal})_c$ 表示图像归一化后的值; $(\tilde{I}_{low} \times \tilde{R}_{low})_c$ 表示图像归一化后的值。将图像归一化到 $[0, 1]$ 是为了保证所有颜色通道中的像素值都有一个上界,避免像素颜色超出色域,或者将原本曝光不足的图像区域变暗。

故总损失函数为

$$L = \omega_c L_c + \omega_d L_d + \omega_e L_e, \quad (8)$$

式中: L_e 、 L_d 和 L_r 分别表示色彩损失函数、分解损失函数和重建损失函数; ω_c 、 ω_d 、 ω_r 为相应的权重,设为 $\omega_c = 2$ 、 $\omega_d = 1.5$ 、 $\omega_r = 1$ 。

3.3 训练数据集

深度学习方法是一种数据驱动模型,模型的

性能与数据集密切相关。RetinexNet 算法在训练集上的表现较好,目前公开的低照度数据集有 LOL(数据集网址为 <https://github.com/weichen582/RetinexNet>)和 SID(数据集网址为 <https://github.com/cchen156/Learning-to-See-in-the-Dark>),训练集的数据量不到 5000,数据量较少。若直接使用现有的合成算法,则不能较好地拟合真实的光照分布,故实验在现有的合成算法中加入随机噪声,能够尽可能地合成趋近于真实的低照度图像。

3.3.1 合成数据的方法

合成图像来自 MEF^[19]、NPE^[20]、LIME^[21]、DICM^[22]和 VV(数据集网址为 <https://sites.google.com/site/vonikakis/datasets>)数据集,通过 Adobe Lightroom 软件来调节图像 YCbCr 色彩空间的 Y 值,公式为

$$I_{c,out} = \beta \times (\alpha \times I_{c,in})^\gamma, \quad (9)$$

式中: $I_{c,out}$ 表示在色彩通道 c 下输出的合成低照度图像; $I_{c,in}$ 表示色彩通道 c 下输入的待合成低照度图像; α 、 β 、 γ 服从均匀分布, $\alpha \sim U(0.9, 1.0)$ 、 $\beta \sim U(0.5, 1.0)$ 、 $\gamma \sim U(1.5, 5.0)$; $(\cdot)^\gamma$ 表示伽马变换。合成数据的光线分布近似高斯分布,使用伽马变换能够得到较为理想的低照度图像。由于(9)式的伽马变换无法考虑图像的局部信息,为了得到更加逼近真实的低照度图像,实验在合成数据中加入局部噪声。加入局部噪声后可表示为

$$I_{out} = M[P(I_{in}) + N_G], \quad (10)$$

式中: $P(\cdot)$ 表示加入的泊松分布噪声; N_G 表示加入的噪声; $M(\cdot)$ 表示拜尔(Bayer)格式转换函数。

3.3.2 合成图像的验证

为了验证合成低照度图像的真实性,计算比较正常光照图像、真实低照度图像和所提方法的合成图像的 Y 通道频率如图 5 所示,图中横轴代表 Y 通道的像素值,数值范围为 16~240。




图 5 三种图像的 Y 通道频率图

Fig. 5 Y channel frequency diagram of three images

从图 5 可以看到,合成低照度图像的频率与真实低照度图像接近(上下相差频率不超过 3%)。当增大 Y 通道像素时,光线趋近正常,合成低照度图像的拟合度仍然较好,说明所提方法可以较理想地

还原真实低照度图像的光线分布。

4 实验

4.1 实验环境

实验使用的计算机配置: Intel i7-8700 CPU、32 GB 内存和两块 NVIDIA 1080Ti GPU。实验时小批量设置为 16,使用 Adam 优化器进行优化,学习率的初始化值为 0.0001。其中 LLNet 算法使用 Theano^[17]框架来实现,MSR 算法和 LIME 算法是在 2017 版 MATLAB 上实现的,RetinexNet 算法和 AM-RetinexNet 算法均使用 TensorFlow 框架来实现。

4.2 主观视觉评价

实验主要对室内、外各两幅真实低照度图像进行主观评价,运用流行的基准方法与 AM-Retinex 分别对图像进行增强。对于室内低照度图像,主要检测色彩饱和度和复杂纹理增强的情况,如图 6 所示。对于室外低照度图像,主要检测线条和轮廓等结构增强的情况,如图 7 所示。

从图 6 可以看到,MSR 算法对图像亮度有一定的提升,但是在增强后的图像中马赛克壁画和调色盘的噪声明显,增强效果一般;LIME 算法和 LLNet 算法对于调色盘和水果等物体的增强效果更为自然;RetinexNet 算法的增强效果较上述三种方法均有所增强,在室内小噪声的场景下,能够获得较理想的结果。对于色彩跨度大的图像,能够较好地检测所提算法的性能。在调色盘、红书和牛奶盒等物体上,AM-RetinexNet 算法可以较好地还原色彩饱和度和高的物体。对比可以发现,不论从整体色彩,还是亮度恢复,所提算法均能保持最符合主观感受的增强效果,验证所提算法具有有效性。

从图 7 可以看到,在室外图像的增强方面,MSR 算法的增强效果一般;对于室外车辆和路标的增强效果来看,LIME 算法相较于 MSR 算法更为自然;LLNet 算法虽采用中间过程来生成光照图,但提升效果并不明显;由于篮球场图像上的前后景区分度小,对于篮板和铁丝网等物体的增强效果,RetinexNet 算法得到的图像与真实值有所差距;放大后的篮网部分由于空间特征缺失而出现边界扭曲的情况;AM-RetinexNet 算法在背景噪声中可以成功提取图像的空间信息,并且对篮网、路标和线条等模型的轮廓和边界的恢复情况均较为理想,从放大图的细节上来看,增强图像的噪声较小,对比度自然。

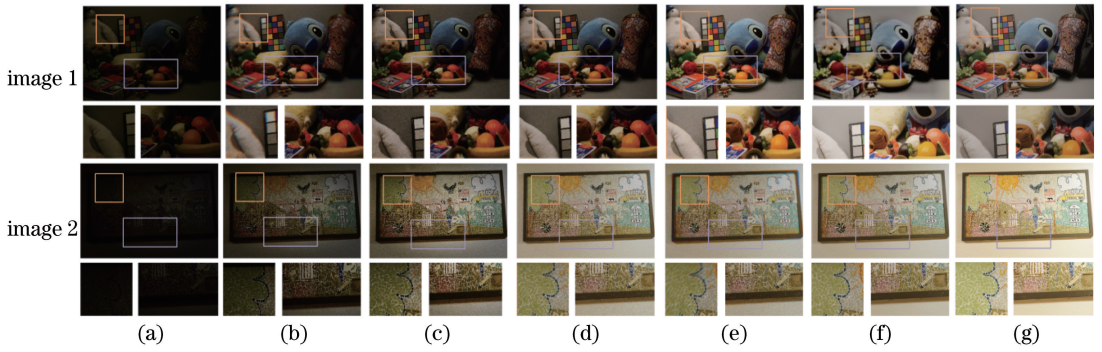


图6 真实室内低照度图像的增强效果对比及其局部放大图。(a)原始图像;(b) MSR算法;(c) LIME算法;(d) LLNet算法;(e) RetinexNet算法;(f) AM-RetinexNet算法;(g)真值图

Fig. 6 Comparison of enhancement effect of real indoor low-illumination images and its partial enlarged images. (a) Original images; (b) MSR algorithm; (c) LIME algorithm; (d) LLNet algorithm; (e) RetinexNet algorithm; (f) AM-RetinexNet algorithm; (g) ground truth




图7 真实室外低照度图像的增强效果对比及其局部放大图。(a)原始图像;(b) MSR算法;(c) LIME算法;(d) LLNet算法;(e) RetinexNet算法;(f) AM-RetinexNet算法;(g)真值图

Fig. 7 Comparison of enhancement effect of real outdoor low-illumination images and its partial enlarged images. (a) Original images; (b) MSR algorithm; (c) LIME algorithm; (d) LLNet algorithm; (e) RetinexNet algorithm; (f) AM-RetinexNet algorithm; (g) truth map

无论对于图6还是图7,所提算法的增强效果均最接近正常光照图像,颜色自然且细节清晰,从主观感知上验证所提算法的增强性能。

4.3 客观实验结果比较

在不同的光照条件以及不同的成像参数下进行实验,得到峰值信噪比(PSNR)和结构相似度(SSIM)的结果如表1所示,其中使用的真实低照度图像来自于LOL和SID数据集。通过控制色彩滤波阵列和曝光时间等成像参数,在4种特定的成像条件下各进行10次实验,PSNR和SSIM值为10次结果的平均值。其中X-Trans是由富士相机开发并在CMOS传感器中保存的格式。与大多数具有常规拜耳滤波器阵(Bayer)列的CMOS传感器不同,X-Trans传感器具有独特的 6×6 图案,这种

布局可以最大程度地减少莫尔效应,并通过消除对低通滤波器的需求来提高分辨率。从表1可以看到,成像参数X-Trans的分辨率为Bayer的1.4倍,故PSNR和SSIM值在X-Trans格式下的数值较高。

通过对比PSNR和SSIM两项指标,LLNet、RetinexNet算法和AM-RetinexNet等算法在减噪和保持图像结构的方面均略高于传统算法,但主观感受上LLNet算法和RetinexNet算法存在偏色且增强色彩范围小。AM-RetinexNet算法的PSNR值为21.95,相较于次优得分(LLNet: 18.99)提升15.5%;SSIM值为0.84,相较于次优得分(RetinexNet: 0.82)提升2.4%,从客观实验结果上验证所提算法的有效性。

表1 不同成像参数和模式下的对比结果

Table 1 Comparison results under different imaging parameters and modes

Method	Condition		PSNR	SSIM
	Filter array	Exposure time /s		
MSR	Bayer	1/25	14.67	0.63
		1/30	14.83	0.62
	X-Trans	1/25	15.33	0.64
		1/30	15.01	0.62
LIME	Bayer	1/25	14.69	0.62
		1/30	14.79	0.59
	X-Trans	1/25	14.88	0.65
		1/30	15.84	0.64
LLNet	Bayer	1/25	18.52	0.70
		1/30	18.04	0.69
	X-Trans	1/25	18.99	0.71
		1/30	19.02	0.70
RetinexNet	Bayer	1/25	18.02	0.80
		1/30	17.94	0.73
	X-Trans	1/25	18.11	0.82
		1/30	18.25	0.81
AM-RetinexNet	Bayer	1/25	20.90	0.83
		1/30	20.88	0.80
	X-Trans	1/25	21.95	0.84
		1/30	21.22	0.82

5 结 论

提出一种新的融合注意力机制的深度网络AM-RetinexNet。在网络结构方面,基于RetinexNet算法的两阶段网络策略,并采用AM层来捕捉图像的空间特征,可以有效增强光照图的深度信息;在损失函数上,因图像的色彩饱和度较低,为此增加色彩损失函数模块,可以有效提高色彩饱和度;最后,加入噪声的合成图像能够较好地逼近真实低照度图像的光线分布,实现数据量的扩充并且可以有效减少网络的过拟合。实验证明所提算法在主观方面的增强效果明显提升,客观指标上PSNR提升15.5%、SSIM提升2.4%。目前,实验中还存在:1)网络还不能调节亮度级别;2)依赖大量的数据进行实验;3)对于人脸等复杂场景的增强仍存在困难,未来将针对这些问题进行研究。

参 考 文 献

[1] Ren Y F. Application of histogram equalization in image processing [J]. Science and Technology Information, 2007(4): 37-38.

任艳斐. 直方图均衡化在图像处理中的应用[J]. 科技信息, 2007(4): 37-38.

[2] Pan Q, Yin J. An image enhancement algorithm based on weighted constraint decision [J]. Control Engineering of China, 2018, 25(11): 2017-2021. 潘强, 印鉴. 基于权重约束决策的图像增强算法[J]. 控制工程, 2018, 25(11): 2017-2021.

[3] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341-2353.

[4] Mei Y J, Ning Y, Chen J J. Block-adjusted image enhancement algorithm combining dark channel prior with MSRCR [J]. Acta Photonica Sinica, 2019, 48(7): 0710005. 梅英杰, 宁媛, 陈进军. 融合暗通道先验和MSRCR的分块调节图像增强算法[J]. 光子学报, 2019, 48(7): 0710005.

[5] Li L, Wang H G, Liu X. Underwater image enhancement based on improved dark channel prior and color correction [J]. Acta Optica Sinica, 2017, 37(12): 1211003. 李黎, 王惠刚, 刘星. 基于改进暗原色先验和颜色校正的水下图像增强[J]. 光学学报, 2017, 37(12): 1211003.

[6] Wang X, Zhu X C, Ning C, et al. Combination of dark-channel prior with sparse representation for underwater image restoration [J]. Journal of Electronics & Information Technology, 2018, 40(2): 264-271. 王鑫, 朱行成, 宁晨, 等. 融合暗原色先验和稀疏表示的水下图像复原[J]. 电子与信息学报, 2018, 40(2): 264-271.

[7] Sima Z L, Hu F. Low-light image enhancement method based on simulating multi-exposure fusion [J]. Journal of Computer Applications, 2019, 39(6): 1804-1809. 司马紫菱, 胡峰. 基于模拟多曝光融合的低照度图像增强方法[J]. 计算机应用, 2019, 39(6): 1804-1809.

[8] Zotin A. Fast algorithm of image enhancement based on multi-scale Retinex [J]. Procedia Computer Science, 2018, 131: 6-14.

[9] Zhang H Y, Hu W B. Spatio-temporal context tracking algorithm based on Retinex-enhanced gray information and color information [J]. Journal of Computer-Aided Design & Computer Graphics, 2017, 29(12): 2323-2329.

- 张红颖, 胡文博. 基于 Retinex 灰度增强和颜色信息的时空上下文跟踪算法[J]. 计算机辅助设计与图形学学报, 2017, 29(12): 2323-2329.
- [10] Lore K G, Akintayo A, Sarkar S. LLNet: a deep autoencoder approach to natural low-light image enhancement[J]. Pattern Recognition, 2017, 61: 650-662.
- [11] Wei C, Wang W J, Yang W H, et al. Deep retinex decomposition for low-light enhancement[EB/OL]. (2018-08-01) [2020-01-15]. https://www.researchgate.net/publication/327033239_Deep_Retinex_Decomposition_for_Low-Light_Enhancement.
- [12] LeCun Y, Boser B E, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [13] Shen X, Cheng X H, Wang X Z. Infrared dim-small object detection algorithm based on adaptive scale local contrast enhancement combined with visual attention mechanism[J]. Infrared Technology, 2019, 41(8): 764-771.
沈旭, 程小辉, 王新政. 结合视觉注意力机制基于尺度自适应局部对比度增强的红外弱小目标检测算法[J]. 红外技术, 2019, 41(8): 764-771.
- [14] Wan C, You Q J, Sun J, et al. Retinal image quality assessment based on FA-Net[J]. Chinese Journal of Experimental Ophthalmology, 2019, 37(8): 608-612.
万程, 游齐靖, 孙晶, 等. 基于 FA-Net 的视网膜眼底图像质量评估[J]. 中华实验眼科杂志, 2019, 37(8): 608-612.
- [15] Stentiford F W M. Attention-based similarity measure with application to content-based information retrieval[J]. Proceedings of SPIE, 2003, 5021: 221-232.
- [16] Dabov K, Foi A, Katkovnik V, et al. Image denoising with block-matching and 3D filtering[J]. Proceedings of SPIE, 2006, 6064: 606414.
- [17] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W, et al. Medical image computing and computer-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [18] Dony R D, Wesolkowski S. Edge detection on color images using RGB vector angles[C]//1999 IEEE Canadian Conference on Electrical and Computer Engineering, May 9-12, 1999, Edmonton, Alberta, Canada. New York: IEEE, 1999: 6505379.
- [19] Ma K D, Zeng K, Wang Z. Perceptual quality assessment for multi-exposure image fusion[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3345-3356.
- [20] 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.
- [21] 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, 2012: 965-968.
- [22] 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.