

RelightGAN: 基于生成对抗网络的暗图像增强^①

费致根, 宋晓晓, 郭兴, 鲁豪

(郑州轻工业大学 河南省机械装备智能制造重点实验室, 郑州 450002)

通信作者: 宋晓晓, E-mail: 1076648832@qq.com



摘要: 针对成像设备在夜间或低光环境下拍摄图像出现光照不足、对比度低和信息丢失等问题, 设计基于生成对抗网络 (generative adversarial network, GAN) 改进的暗图像增强网络 RelightGAN, 该网络包含两个判别器和一个生成器, 由两组对抗损失和循环损失共同约束生成器, 使之生成更优异的光照层。为增强网络训练过程中对图像细节信息的恢复能力, 引入残差网络解决梯度消失问题, 同时引入混合注意力机制 CBAM 结构, 提升生成器对图像中重要信息和结构的关注度增强网络表达能力。通过与其他暗图像增强网络增强后的暗图像进行对比, RelightGAN 网络增强后的图像, 相较于其他网络峰值信噪比 ($PSNR$) 值提高了 12.81%, 结构相似度 ($SSIM$) 值提高了 5.95%。实验结果表明 RelightGAN 网络结合了传统算法和神经网络的优点, 实现了暗场景图像的增强, 提高了图像可见度。

关键词: 暗图像增强; 生成对抗网络; 判别器; 生成器; 残差网络; 混合注意力机制

引用格式: 费致根, 宋晓晓, 郭兴, 鲁豪. RelightGAN: 基于生成对抗网络的暗图像增强. 计算机系统应用, 2024, 33(10): 263–269. <http://www.c-s-a.org.cn/1003-3254/9654.html>

RelightGAN: Generative Adversarial Network for Dark Image Enhancement

FEI Zhi-Gen, SONG Xiao-Xiao, GUO Xing, LU Hao

(Henan Key Laboratory of Intelligent Manufacturing of Machinery and Equipment, Zhengzhou University of Light Industry, Zhengzhou 450002, China)

Abstract: Aiming at the problems of insufficient light, low contrast, and information loss in images taken by imaging devices at night or in low-light environments, an improved dark image enhancement network named RelightGAN is designed based on generative adversarial network (GAN). It contains two discriminators and one generator, and the generator is jointly constrained by two sets of adversarial losses and cyclic losses to generate a better illumination layer. To enhance the recovery of image details during network training, a residual network is introduced to solve the gradient vanishing problem. At the same time, a hybrid attention mechanism CBAM structure is introduced to increase the generator's attention to important information and structures in the image, enhancing network expression capability. By comparing the image enhanced by RelightGAN with those enhanced by other dark image enhancement networks, the peak signal-to-noise ratio ($PSNR$) of the former is improved by 12.81% and the structural similarity ($SSIM$) is enhanced by 5.95%. Experimental results show that the RelightGAN network combines the advantages of traditional algorithms and neural networks to improve dark scene images and image visibility.

Key words: dark image enhancement; generative adversarial network (GAN); discriminator; generator; residual network (ResNet); hybrid attention mechanism

① 基金项目: 河南省科技攻关项目 (222102220050)

收稿时间: 2024-04-09; 修改时间: 2024-05-06; 采用时间: 2024-05-14; csa 在线出版时间: 2024-08-21

CNKI 网络首发时间: 2024-08-22

当成像设备在夜间或低光环境中捕获图像时,捕获的图像可能会出现内容模糊、可视性差和颜色丢失等问题。这些问题不仅阻碍了人类对捕获图像数据的感知,而且影响了计算机视觉中图像预处理和特征识别的后续阶段,给现代工业智能应用带来了挑战。为了减轻这些影响,许多学者已经提出了不同算法来增强暗图像。

当人们在低光环境下拍摄照片时,通常依靠人工照明或开启相机闪光灯的方法进行,其他外部条件保持不变。因此,在同一环境下,打光后的图像与不打光图像的亮度和图像呈现效果有很大差别。鉴于此,RelightGAN 暗图像增强网络使用卷积网络代替手动照明过程,进而点亮暗图像,该网络的目的是从正常图像中分离出照光层,同时保留图像本身有用的颜色信息,然后与暗图像融合,该方法摆脱了各种图像参数设置的限制,从周围环境的角度考虑图像恢复。特殊的双判别器的循环结构为网络提供两组内容损失和对抗性损失,两组损失函数共同作用于一个生成器,指导其生成最佳的光照层图像。通过测试,可以证明 RelightGAN 暗图像增强网络对来自不同领域的实时低光图像增强具有良好的适应性。

本文的主要贡献概括如下:1)提出了一个新的假设,并将其应用于暗图像增强领域。基于生成对抗网络设计了一种用于暗图像增强的网络 RelightGAN;2)设计特殊的双判别器循环结构约束生成器,与使用单个判别器相比,能够生成更有效的光照层图像;3)为了使增强后的图像保留更多的关键信息,向传统的 ResNet 网络结构中加入注意力机制(CBAM),设计出新型的残差结构 CBAM-Res。RelightGAN 增强暗图像的方法保留了原始图像的固有属性,避免了其他算法在增强过程中遇到的色彩失真、对比度降低和明显噪声等常见问题。实验证明与当前较流行的暗图像增强算法和网络相比,RelightGAN 网络能够实现更好的暗图像恢复效果。

1 研究现状

通常用于处理暗图像的方法可以分为传统算法和基于深度学习的神经网络方法两大类。传统的图像增强算法是从暗图像本身入手对图像直接增强,使处理后的图像具有更高的对比度,以此达到增强暗图像的目的,例如直方图均衡化(histogram equalization, HE)^[1]、拉普拉斯算法^[2,3]、对数 LOG 算子^[4-6],此类方法鲁棒

性较差,易出现颜色失真的问题,且增强后的图像边缘信息会丢失。Retinex 理论以颜色恒常性(色感一致性)为基础提出,该理论将图像分解为反射分量和光照分量,由此发展形成两种传统方法:单尺度 Retinex (SSR)^[7]通过高斯滤波器估计光照分量、多尺度 Retinex (MSRCR)^[8]在 SSR 的基础上引入不同尺度高斯滤波和颜色恢复因子,获得所估计照度图像。王以涵等人^[9]利用低秩矩阵估计实现了对 Retinex 模型分解出的反射层的噪声一致,进一步以光照层为引导进行图像融合保留图像原有细节。虽然上述方法在一定程度上都能解决暗图像质量低的问题,且能得到较好的亮度和颜色保留度,但是算法的适应性不强,应用场景有限。

基于深度学习的方法适应性较强。Wei 等人^[10]基于 Retinex 理论提出 RetinexNet,首先对暗图像分解,将其分为光照层和反射层,通过增强光照层,将其与分离出的反射层图像相结合实现暗图像增强。Wang 等人^[11]结合注意力机制和 Retinex 算法提出 CA&R 网络来增强暗图像。神经网络训练最重要的是训练数据集的质量,而成对的明暗图像采集几乎是不可能的,大多数网络采用的是合成数据集,这也限制了网络增强暗图像后的效果。随着生成式对抗网络(GAN)逐渐成为学术界研究热点,Guo 等人^[12]提出零参考深度曲线估计的方法将光照增强问题转化为使用深度网络对特定图像曲线的估计问题。GANs 在图像合成和图像转换方向上得到了快速的发展,近几年,利用生成式对抗网络增强暗图像的方法也逐渐被提出。Jiang 等人^[13]提出无监督生成对抗网络 EnlightenGAN,不需要成对数据集训练,利用自正则感知损失来约束生成器,减小暗图像与正常图像之间的特征距离。无监督学习虽然解决了成对数据集获取的难题,诸如稳定训练、颜色失真、跨域信息相关性等问题仍然存在。因此通过改变暗图像本身的物理性质同时恢复暗图像亮度、对比度、饱和度、锐化、分辨率是极其困难的。而且将暗图像完全转变为正常图像也是不可能实现的。

2 研究方法

2.1 RelightGAN 网络原理

在 RelightGAN 网络中,依据观察到的暗环境下打光后的图像与不打光的图像成像差异性,提出一个假设,即打光后的图像是由不打光图像和一个亮光层融合而成。将暗图像 I_{low} 视为没有亮光层 I_L 的正常图像

L_{nor} , 可以用式(1)表示:

$$I_L = L_{\text{nor}} + L_{\text{low}} \quad (1)$$

其中, I_L 表示亮光层. RelightGAN 网络生成器生成亮度层 I_L , 通过 L_{low} 与生成的 I_L 相结合, 便可得到一张正常图像 L'_{nor} . 用公式可表示为:

$$L'_{\text{nor}} = I_L + L_{\text{low}} \quad (2)$$

2.2 RelightGAN 网络结构

RelightGAN 网络结构如图 1 所示. 采用双判别器的循环结构, 网络以 L_{low} 作为输入, 由生成器生成 I_L , 将 I_L 与 L_{low} 相加生成假的正常图像 L'_{nor} , L'_{nor} 与正常图像

L_{nor} 一同输入判别器 D_n 中, 在对抗损失和内容损失函数的约束下将鉴别结果反馈回生成器 G , 使其生成更真实的亮光层 I_L . 另一侧将 L_{low} 与 I_L 相减生成假的暗图 L'_{low} , 与 L_{low} 一同输入判别器 D_l 中, 在对抗损失和内容损失函数的约束下将鉴别结果反馈回生成器 G , 使其生成更真实的亮光层 I_L .

2.3 生成器

生成器 G 的网络层结构如图 2 所示, 由 6 个卷积层和 6 个残差块组成, 每个 ResBlock 包含两个卷积操作, 提供更大的接受域, 并防止梯度消失问题. 其中 CBR 表示卷积层、归一化层和 ReLU 组合.

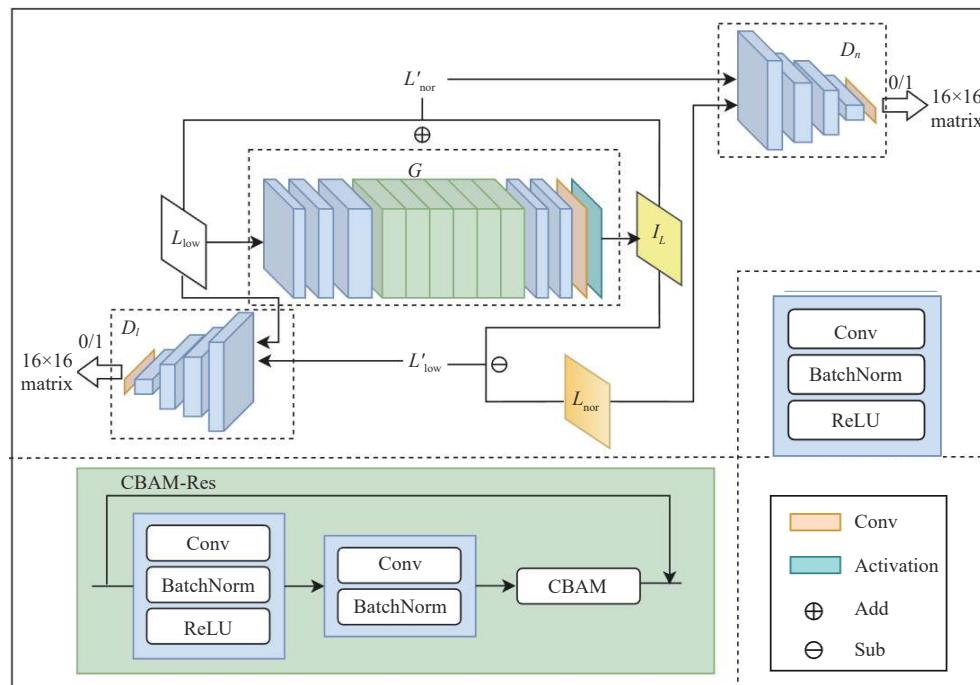


图 1 RelightGAN 网络结构

初始的残差结构在生成图像时容易受到其他因素的影响, 生成的图像中会产生伪影, 缺乏足够的关键信息还原能力. 为了解决这一问题, 在生成器的 ResBlock 中引入混合注意力机制 CBAM 模块构建 CBAM-Res 结构. CBAM 是一个由空间注意机制和通道注意机制组成的注意力机制模型. CBAM-Res 结构如图 3 所示, 引入的 CBAM-Res 模块利用通道注意力机制为每个通道的特征分配权重, 使得网络能够优先考虑重要的特征层, 并最大限度地减少来自次要通道的冗余信息对图像生成的影响. 通过在残差块中串联两个注意力模块, 生成器网络可以更有效地提取和表达重要特征, 抑

制不重要的特征, 提高生成图像的质量.

2.4 判别器

判别器 D_l 和 D_n 具有相同的网络结构, 每个判别器由 5 个卷积层组成, 如图 4 所示, 其最终输出为 16×16 矩阵.

2.5 损失函数

RelightGAN 网络依据 GAN 网络搭建, 该网络由一个生成器 G 和两个判别器 D_l 、 D_n 组成. 生成器与两个判别器之间的损失函数由两个部分组成: 对抗损失和内容损失.

对抗损失:

$$\begin{aligned} \min_G \max_{D_n} L_{GAND_n}(G, D_n) &= E_{L_{\text{nor}} \sim P_{\text{data}}(L_{\text{nor}})} [\log(D_n(L_{\text{nor}}))] \\ &+ E_{L_{\text{low}} \sim P_{\text{data}}(L_{\text{low}})} [\log(1 - D_n(L_{\text{low}} + G(L_{\text{low}})))] \end{aligned} \quad (3)$$

$$\begin{aligned} \min_G \max_{D_l} L_{GAND_l}(G, D_l) &= E_{L_{\text{low}} \sim P_{\text{data}}(L_{\text{low}})} [\log(D_l(L_{\text{low}}))] \\ &+ E_{L_{\text{nor}} \sim P_{\text{data}}(L_{\text{nor}})} [\log(1 - D_l(L_{\text{nor}} - G(L_{\text{low}})))] \end{aligned} \quad (4)$$

其中, $E(\cdot)$ 表示分布函数的期望值, $P_{\text{data}}(\cdot)$ 代表着样本的分布, G 、 D_l 、 D_n 分别表示生成器和两个判别器, 对抗性损失表示判别器 D_l 、 D_n 尽可能使生成正常图像和真正正常图像交叉熵损失最大, 而生成器 G 尽可能使其最小.

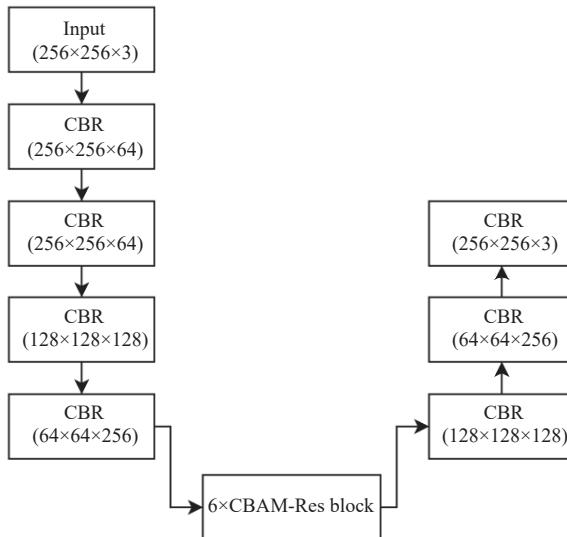


图 2 生成器网络层结构

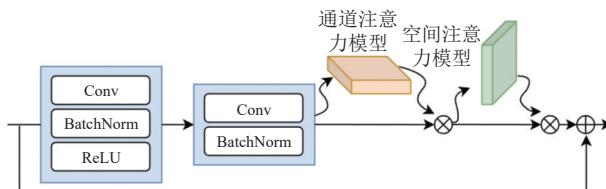


图 3 CBAM-Res 结构

两个内容损失函数用 L_1 损失来定义, L_1 损失在保持颜色和亮度稳定性方面更有效, 如式(5)、式(6)所示:

$$L_{\text{GANT}} = \frac{1}{WH} \sum_{j=1}^H \sum_{i=1}^W |L_{\text{nor}}(x_i, y_j) - G(L_{\text{low}}(x_i, y_j))| \quad (5)$$

$$L_{\text{GANI}} = \frac{1}{WH} \sum_{j=1}^H \sum_{i=1}^W |L_{\text{low}}(x_i, y_j) - G(L_{\text{low}}(x_i, y_j))| \quad (6)$$

暗图像增强网络的总损失函数可表示为式(7):

$$L = \lambda_1 L_{\text{GAND}_n} + \lambda_2 L_{\text{GAND}_l} + \lambda_3 L_{\text{GANT}} + \lambda_4 L_{\text{GANI}} \quad (7)$$

其中, $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ 为相应的自适应加权因子, 对应的值分别设置为 10, 10, 0.5, 0.5 时网络训练结果最好.

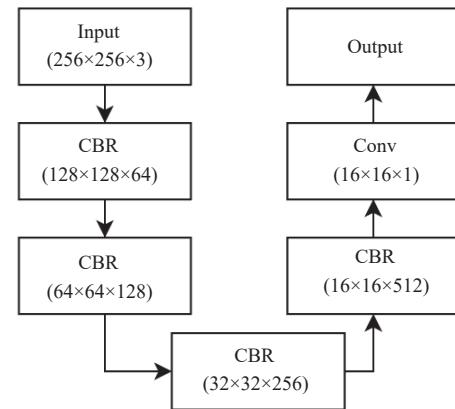


图 4 判别器网络层结构

3 研究结果

3.1 数据集

本文的训练集和测试集数据来自于 LOL^[10]公共数据集和由 RAISE^[14]在 RetinexNet 中合成的数据. 该数据集由 1429 张图像组成, 包括 1417 个训练集和 12 个测试集, 与训练集没有交集. 暗图像被输入到 Relight-GAN 网络中. 在训练时, 将每张图像归一化到 [0, 1] 的范围内. 网络的训练采用 Adam 随机优化, batch 大小为 2, 学习率为 0.000 2. 该网络在 Core i7-8700 CPU 和 NVIDIA GTX1060 GPU 上进行训练和测试, 代码基于 TensorFlow 框架编写. 图 5 展示了本文模型在训练过程中生成器损失和两个判别器损失的收敛曲线.

3.2 评价指标

图像增强算法通常使用峰值信噪比 ($PSNR$) 和结构相似性 ($SSIM$) 作为定量指标^[15]. 计算公式如下:

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (8)$$

$$SSIM(X, Y) = l(X, Y) \times c(X, Y) \times s(X, Y) \quad (9)$$

其中, MAX_I 表示像素最大值, MSE 为均方误差. $l(X, Y)$, $c(X, Y)$, $s(X, Y)$ 分别为:

$$\text{Brightness : } l(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1} \quad (10)$$

$$\text{Contrast : } c(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2} \quad (11)$$

$$\text{Structure : } s(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3} \quad (12)$$

其中, μ_X 、 μ_Y 表示图像 X 和 Y 的均值, σ_X 和 σ_Y 表示图像 X 和 Y 的方差, σ_{XY} 表示图像 X 与 Y 之间的协方差, 其中 C_1, C_2, C_3 为常数. $SSIM$ 取值范围为 0–1, 值越大表示图像失真越小. $PSNR$ 和 $SSIM$ 数值越高表明模型增强效果越好.

3.3 研究对比结果

为了评估 RelightGAN 网络的有效性, 选用 RetinexNet^[10]、Zero-DCE^[12], 以及流行的 EnlightenGAN^[13]图像增强算法使用同一数据集训练网络. 选用 LOL15 张数据集进行测试, 图像大小设置为 256×256 , 实验对比

从客观和主观两个方向评估增强后的图像质量. 图 6 展示了不同方法增强后的暗图像.

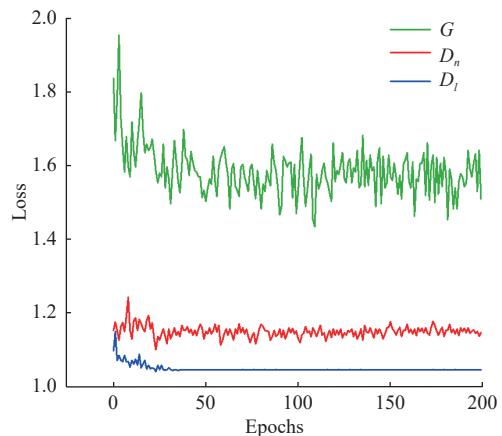


图 5 判别器和生成器 loss 值收敛曲线



图 6 对实验结果的主观视觉评价

由图 6 可以看出 RetinexNet 能够实现暗图像的增强, 然而, 增强后的图像存在更明显的色彩失真问题, 这是由于 Retinex 理论假设光照在整个图像内平缓变化, 但实际上图像的边缘区域光照变化更加剧烈. 因此, 网络生成的图像在边缘区域容易出现光晕现象. 此外, 增强后的图像还可能出现边缘模糊和边缘信息丢失的问题. 直接利用 EnlightenGAN 网络处理后的图像与 RetinexNet 相比没有出现颜色失真和边缘区域光晕现象, 但是增强后的图像亮度低, 颜色修复与真实颜色有色差, 基于 Zero-DCE 算法的暗图像增强效果较理想,

但与真实图像相比亮度过低, 亮度提升不明显. RelightGAN 网络从外界环境角度观察直接生成亮光层信息, 生成的打光后的图像保留了真实场景的大部分信息, 且不会发生亮度低、颜色失真、对比度低、噪声严重等问题. 利用梯度损失函数有效地避免了正常图像边缘信息丢失的问题.

为了更直观地看到每种方法的性能, 使用同一数据集训练不同网络, 然后对比图像增强后的测试集 $PSNR$ 和 $SSIM$ 平均值, 结果如表 1 所示.

从表 1 可以看出, Zero-DCE 算法的 $PSNR$ 值最低,

但 $SSIM$ 值优于 RetinexNet, 在这 3 种方法中, 综合来看 EnlightenGAN 是表现最好的, RelightGAN 网络 $PSNR$ 和 $SSIM$ 值均优于其他 3 种实验算法, 与 EnlightenGAN 算法相比, $PSNR$ 值提高了 12.81%, $SSIM$ 值提高了 5.95%. 这客观地证明了 RelightGAN 网络增强暗图像的有效性.

表 1 不同方法增强暗图像的实验结果对比

| 方法 | $PSNR$ (dB) | $SSIM$ |
|--------------|-------------|---------------|
| RetinexNet | 16.1657 | 0.7712 |
| Zero-DCE | 14.7431 | 0.7850 |
| EnlightenGAN | 17.1810 | 0.7494 |
| RelightGAN | 19.3817 | 0.7940 |

为验证 CBAM-Res 残差块的性能, 进行了网络有无通道注意力机制的对比实验, 如表 2 所示, 可以看出加入了 CBAM-Res 残差块的网络性能优于 ResNet 残差块, 验证了设计的 CBAM-Res 残差块的有效性.

表 2 网络有无通道注意力机制实验对比结果

| 方法 | $PSNR$ (dB) | $SSIM$ |
|------------|-------------|---------------|
| -CBAM | 19.0161 | 0.7748 |
| RelightGAN | 19.3817 | 0.7940 |

3.4 真实场景测试情况

为了验证 RelightGAN 网络在真实场景中的性能, 使用 5 个公开可用的数据集 DICM^[16], LIME^[17], NPE^[18], VV^[13] 和 MEF^[19] 进行测试. 使用 NIQE 对增强后的图像

进行客观评价, NIQE 是一种被广泛认可的无参考图像质量评估工具, 用于定量比较没有地面真实度的真实图像恢复. 对比过程中使用 256×256 像素的标准化图像尺寸进行评估. 表 3 显示了 5 个公开可用的数据集通过不同方法增强后的 NIQE 值. 较低的 NIQE 值表示较好的视觉质量, 从表 3 可知 RelightGAN 网络拥有最优的整体平均 NIQE 值.

表 3 NIQE 对比结果

| 方法 | DICM | LIME | NPE | VV | MEF | ALL |
|--------------|--------|--------|--------|--------|--------|---------------|
| 输入 | 42.771 | 36.174 | 34.330 | 35.007 | 35.356 | 35.242 |
| RetinexNet | 35.731 | 32.882 | 34.441 | 28.648 | 34.462 | 36.178 |
| Zero-DCE | 34.606 | 29.847 | 22.545 | 32.261 | 25.753 | 29.002 |
| EnlightenGAN | 28.948 | 32.404 | 27.959 | 28.382 | 30.381 | 29.602 |
| RelightGAN | 27.097 | 30.714 | 26.886 | 27.584 | 26.985 | 27.853 |

图 7 直观地显示了 5 种类型数据集的部分增强图像. 如图 7 所示, RetinexNet 增强后的图像确实恢复了一些暗图像场景信息, 但它往往会出现色彩失真、图像过曝或饱和等问题, 这些都可能会对图片的可见性产生负面影响. 与 RetinexNet 网络相比 EnlightenGAN 和 Zero-DCE 能够实现较好的增强效果, 但对于部分场景图像增强效果不明显. 与前 3 种网络相比, RelightGAN 网络具有更好的暗图像增强效果. 此外, 增强后的图像在最大程度上有效地保留了原始颜色信息和细节.

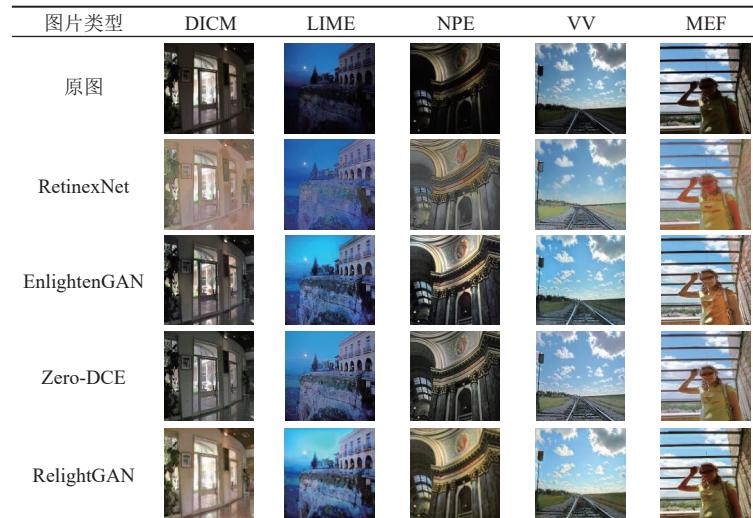


图 7 真实场景下暗图像增强效果对比

4 结论与展望

图像增强技术是当前工业和社会领域重要的研究内容, 基于生成对抗网络改进的 RelightGAN 网络不再把暗图像通过算法还原为正常场景图像, 而是通过算

法将未打光的暗场景图像转换为打光下拍摄的暗场景图像, 同样可增强暗图像的可视性. RelightGAN 暗图像增强网络利用两个判别器和一个生成器组成的循环结构, 构建对抗性损失和内容损失约束生成器生成最

优秀的照明层信息,生成器中加入的CBAM-Res结构使得网络训练过程中细节信息保留更完整。实验表明,在主观评价方面RelightGAN网络点亮后的暗图像效果明显增强,暗图像的可见性也得到了显著提高。在客观评价方面,与较流行的EnlightenGAN相比,RelightGAN网络增强后的暗图像PSNR值提高了约12.81%,SSIM值提高了5.95%。对真实暗场景图像增强后的NIQE值较低,充分证明了研究的有效性。

参考文献

- 1 Cheng HD, Shi XJ. A simple and effective histogram equalization approach to image enhancement. *Digital Signal Processing*, 2004, 14(2): 158–170. [doi: [10.1016/j.dsp.2003.07.002](https://doi.org/10.1016/j.dsp.2003.07.002)]
- 2 刘申澳, 韩永华. 基于MSRCR-拉普拉斯金字塔方法的低照度图像增强. *图像与信号处理*, 2022, 11(3): 113–124. [doi: [10.12677/JISP.2022.113013](https://doi.org/10.12677/JISP.2022.113013)]
- 3 Islam SM, Mondal HS. Image enhancement based medical image analysis. *Proceedings of the 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. Kanpur: IEEE, 2019. 1–5. [doi: [10.1109/ICCCNT45670.2019.8944910](https://doi.org/10.1109/ICCCNT45670.2019.8944910)]
- 4 Mitchell JN. Computer multiplication and division using binary logarithms. *IRE Transactions on Electronic Computers*, 1962, EC-11(4): 512–517. [doi: [10.1109/TEC.1962.5219391](https://doi.org/10.1109/TEC.1962.5219391)]
- 5 Nnolim UA. Design and implementation of novel, fast, pipelined HSI2RGB and log-hybrid RGB2HSI colour converter architectures for image enhancement. *Microprocessors and Microsystems*, 2015, 39(4–5): 223–236. [doi: [10.1016/j.micpro.2015.04.005](https://doi.org/10.1016/j.micpro.2015.04.005)]
- 6 Nnolim UA. Log-hybrid architecture for tonal correction combined with modified un-sharp masking filter algorithm for colour image enhancement. *Integration*, 2015, 48: 221–229. [doi: [10.1016/j.vlsi.2014.09.001](https://doi.org/10.1016/j.vlsi.2014.09.001)]
- 7 Dong X, Wang G, Pang Y, et al. Fast efficient algorithm for enhancement of low lighting video. *Proceedings of the 2011 IEEE International Conference on Multimedia and Expo (ICME)*. Barcelona: IEEE, 2011. 1–6. [doi: [10.1109/ICME.2011.6012107](https://doi.org/10.1109/ICME.2011.6012107)]
- 8 Rahman ZU, Jobson DJ, Woodell GA. Retinex processing for automatic image enhancement. *Proceedings of SPIE 4662, Human Vision and Electronic Imaging VII*. San Jose: SPIE, 2002. 390–401. [doi: [10.1117/12.469537](https://doi.org/10.1117/12.469537)]
- 9 王以涵, 郝世杰, 韩徐, 等. 基于低秩矩阵估计的暗光图像增强模型. *计算机科学*, 2022, 49(1): 187–193. [doi: [10.11896/j.sjkx.210600090](https://doi.org/10.11896/j.sjkx.210600090)]
- 10 Wei C, Wang WJ, Yang WH, et al. Deep Retinex decomposition for low-light enhancement. *Proceedings of the 2018 British Machine Vision Conference*. Newcastle: BMVA Press, 2018. 155.
- 11 Wang Y, Chen J, Han YJ, et al. Combining attention mechanism and Retinex model to enhance low-light images. *Computers & Graphics*, 2022, 104: 95–105. [doi: [10.1016/j.cag.2022.04.002](https://doi.org/10.1016/j.cag.2022.04.002)]
- 12 Guo CL, Li CY, Guo JC, et al. Zero-reference deep curve estimation for low-light image enhancement. *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle: IEEE, 2020. 1777–1786. [doi: [10.1109/CVPR42600.2020.00185](https://doi.org/10.1109/CVPR42600.2020.00185)]
- 13 Jiang YF, Gong XY, Liu D, et al. EnlightenGAN: Deep light enhancement without paired supervision. *IEEE Transactions on Image Processing*, 2021, 30: 2340–2349. [doi: [10.1109/TIP.2021.3051462](https://doi.org/10.1109/TIP.2021.3051462)]
- 14 Dang-Nguyen DT, Pasquini C, Conotter V, et al. RAISE: A raw images dataset for digital image forensics. *Proceedings of the 6th ACM Multimedia Systems Conference*. Portland: ACM, 2015. 219–224. [doi: [10.1145/2713168.2713194](https://doi.org/10.1145/2713168.2713194)]
- 15 Wang Z, Bovik AC, Sheikh HR, et al. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 2004, 13(4): 600–612. [doi: [10.1109/TIP.2003.819861](https://doi.org/10.1109/TIP.2003.819861)]
- 16 Lee C, Lee C, Kim CS. Contrast enhancement based on layered difference representation. *Proceedings of the 19th IEEE International Conference on Image Processing*. Orlando: IEEE, 2012. 965–968. [doi: [10.1109/ICIP.2012.6467022](https://doi.org/10.1109/ICIP.2012.6467022)]
- 17 Guo XJ, Li Y, Ling HB. LIME: Low-light image enhancement via illumination map estimation. *IEEE Transactions on Image Processing*, 2017, 26(2): 982–993. [doi: [10.1109/TIP.2016.2639450](https://doi.org/10.1109/TIP.2016.2639450)]
- 18 Wang SH, Zheng J, Hu HM, et al. Naturalness preserved enhancement algorithm for non-uniform illumination images. *IEEE Transactions on Image Processing*, 2013, 22(9): 3538–3548. [doi: [10.1109/TIP.2013.2261309](https://doi.org/10.1109/TIP.2013.2261309)]
- 19 Li JQ, Li JC, Fang FM, et al. Luminance-aware pyramid network for low-light image enhancement. *IEEE Transactions on Multimedia*, 2021, 23: 3153–3165. [doi: [10.1109/TMM.2020.3021243](https://doi.org/10.1109/TMM.2020.3021243)]

(校对责编: 孙君艳)