

一种基于 U-Net 生成对抗网络的 低照度图像增强方法

江泽涛, 覃露露

(桂林电子科技大学广西图像图形处理与智能处理重点实验室, 广西桂林 541004)

摘要: 在低照度环境下采集的图像具有低信噪比、低对比度及低分辨率等特点, 导致图像难以识别利用. 为了提升低照度图像的质量, 本文提出一种基于 U-Net 生成对抗网络的低照度图像增强方法. 首先利用 U-Net 框架实现生成对抗网络中的生成网络, 然后利用该生成对抗网络学习从低照度图像到正常照度图像的特征映射, 最终实现低照度图像的照度增强. 实验结果表明, 与主流算法相比, 本文提出的方法能够更有效的提升低照度图像的亮度与对比度.

关键词: 低照度图像; 图像增强; 生成对抗网络; 深度学习

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2020)02-0258-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.02.005

Low-Light Image Enhancement Method Based on U-Net Generative Adversarial Network

JIANG Ze-tao, QIN Lu-lu

(The Key Laboratory of Image and Graphic Intelligent Processing in Guangxi, Guilin University of Electronic Technology, Guilin, Guangxi 541004, China)

Abstract: The images acquired in the low illumination environment have the characteristics of low signal-to-noise ratio, low contrast and low resolution, which make the image difficult to identify and utilize. In order to improve the image quality of low-light images, this paper proposes a low-light image enhancement method based on U-net generative adversarial network (GAN). First, the U-net framework is used to implement the generative network of GAN, and then the GAN is used to learn the feature mapping from the low-light image to the normal-light image, and ultimately achieve illumination enhancement for the low-light image. Finally, this method is verified by experiments. The experimental results show that, compared with the mainstream algorithm, the proposed algorithm can effectively improve the brightness and contrast of low-light image.

Key words: low-light image; image enhancement; generative adversarial network (GAN); deep learning

1 引言

可见光图像的成像过程受光照强度及环境影响, 低照度环境下采集的可见光图像存在信噪比、对比度、分辨率均较低等特点, 给进一步图像处理, 图像识别、目标检测等任务带来更严峻的挑战^[1].

目前国内外常见的低照度图像增强方法主要分为四种: (1) 基于直方图增强法 (Histogram Equalization, HE). 该方法通过整体调整图像直方图分布来增强图像亮度和对比度, 此类方法精简快捷, 但常出现颜色失真、

细节丢失等问题^[2]. (2) 基于 Retinex 增强法. Land^[3] 提出人眼视觉亮度与颜色感知由实际物体自身的反射率决定, 与环境光强度无关. 根据 Retinex 理论提出带色彩恢复的多尺度 Retinex (multi-scale Retinex with color restoration, MSRCR)^[4] 和 LIME^[5] 等多种经典算法. 此类方法容易出现颜色失真, 虽然有学者增加颜色校正模块, 但仍无法完全克服颜色失真问题. (3) 基于伪雾图增强法. 该方法利用低照度图像的反转图像通过去雾算法进行增强. 如 Dong^[6] 等提出增强方法取得较好的照度增强效果, 但在应对复杂场景增强时容易出现块效应和噪声. (4) 基于

收稿日期: 2019-04-03; 修改日期: 2019-08-10; 责任编辑: 李勇锋

基金项目: 国家自然科学基金 (No. 61572147, No. 61876049, No. 61762066); 广西科技计划 (No. AC16380108); 广西图像图形智能处理重点实验室 (No. GHP201701, No. GHP201801, No. GHP201802, No. GHP201803); 广西研究生教育创新计划 (No. YCBZ2018052, No. 2019YCXSO43)

神经网络的增强法. 此类方法利用神经网络学习低照度图像到正常照度图像的映射, 如刘超^[7]等提出利用卷积自编码网络从低照度图像训练集中学习图像特征. 此类方法能够有效的对低照度图像进行照度增强, 但增强的图像在细节及色彩方面有所欠缺.

生成对抗网络 (Generative Adversarial Nets, GAN) 是由 Goodfellow 等^[8]提出的新型生成模型, 它通过观测真实数据, 学习其潜在分布规律, 从而生成符合该分布规律的数据.

为了提高低照度图像的图像质量, 本文利用生成对抗网络的学习能力, 提出一种基于 U-Net 生成对抗网络的低照度图像增强方法. 该方法利用 U-Net 结构和深度卷积结构构造生成对抗网络, 实现利用低照度图像生成照度与正常照度图像拟合的增强图像. 实验表明, 该方法能够有效提高低照度图像的亮度、对比度.

2 生成对抗网络

GAN 由两个相互博弈的生成网络 (G) 和判别网络 (D) 构成, 其中 G 的目的是尽可能捕获真实数据的潜在分布; D 是一个二分类器, 其目的是正确判断输入数据是来源于真实数据还是生成数据. GAN 可视求极大极小博弈问题:

$$\min_G \max_D V(D, G) = E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [\log D(\mathbf{x})] + E_{\mathbf{z} \sim P_z(\mathbf{z})} [\log(1 - D(G(\mathbf{z})))] \quad (1)$$

其中, E 表示求期望; $\mathbf{x} \sim P_{\text{data}}(\mathbf{x})$ 来源于真实数据; \mathbf{z} 为服从某种先验分布 $P_z(\mathbf{z})$ (一般为高斯分布等) 的随机噪声.

条件生成对抗网络 (conditional GAN, cGAN)^[9] 是为了增加 GAN 的稳定性而提出的, 它在随机噪声 \mathbf{z} 中添加额外的条件变量 \mathbf{y} 作为约束条件. cGAN 目标函数如式(2)所示:

$$\min_G \max_D V(D, G) = E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [\log D(\mathbf{x} | \mathbf{y})] + E_{\mathbf{z} \sim P_z(\mathbf{z})} [\log(1 - D(G(\mathbf{z} | \mathbf{y})))] \quad (2)$$

文献[10]证明了省去随机噪声 \mathbf{z} 时, GAN 仍然会学习从条件变量 \mathbf{y} 到真实数据 \mathbf{x} 的一对一映射.

3 本文算法原理

在低照度图像增强问题中, 将低照度图像 \mathbf{dim} 作为网络中的条件变量, 输出为照度增强图像 $G(\mathbf{dim})$; 该低照度增强 GAN 目标函数为:

$$\min_G \max_D V(D, G) = E_{\mathbf{rgb}} [\log D(\mathbf{rgb})] + E_{\mathbf{dim}} [\log(1 - D(G(\mathbf{dim})))] \quad (3)$$

3.1 改进的 GAN 模型

本文提出的基于 U-Net 生成对抗网络的低照度图像增强网络模型 (Low Light Enhance GAN, LLEGAN),

如图 1 所示.

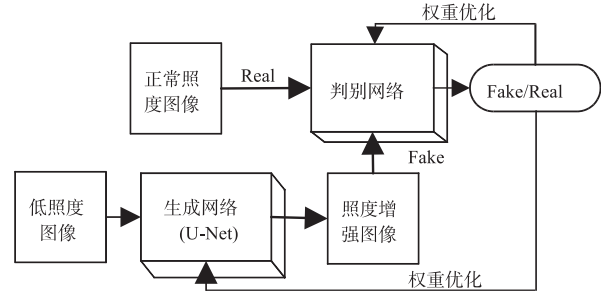


图1 基于U-Net生成对抗网络的低照度图像增强网络模型

一般生成网络使用编码-解码 (encode-decode) 网络, 如图 2(a) 所示. 在编码-解码网络中, 首先将图像进行编码, 然后将图像的全部信息压缩到瓶颈层的细长向量, 最后再解码得到结果图. 这种方式常导致信息瓶颈丢失问题, 即输入与输出之间出现大量信息丢失. U-Net^[11] 网络架构是在编码器和解码器相对称的层之间添加跳跃连接构成, 如图 2(b) 所示.




图2 构造生成网络架构的两种网络模型

为了避免在低照度图像增强的生成网络出现瓶颈层信息丢失问题, 本文利用 U-Net 跳跃连接结构构建 LLEGAN 的生成网络, 如图 3 所示, 其中 k 为卷积核尺寸, n 为卷积核数量, s 为步长.

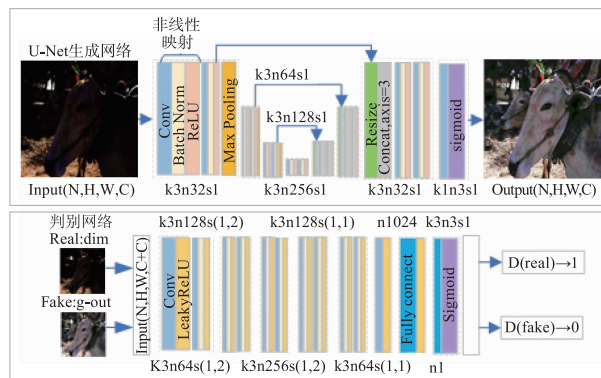


图3 本文改进的生成网络与判别网络结构图

在 LLEGAN 网络中, 将一个非线性映射定义为: 首先对输入进行卷积运算 ($*$); 然后用批量归一化 (BN) 对卷积结果进行规范化处理; 最后对结果应用激活函数. 在生成网络中, 除输出层使用 sigmoid 激活函数外, 其余均使用 ReLU 激活函数, 而判别网络使用 $\alpha = 0.2$ 的 LeakyReLU 激活函数. 这样的非线性映射结构能够

增加网络对图像特征的提取能力,且 BN 层的加入能够减少冗余信息、加快训练速度,增强网络的稳定性。

设 $gF(\mathbf{x})$ 为非线性映射单元, $gF_0(\mathbf{x}) = \mathbf{x}$, 即:

$$gF_j(\mathbf{x}) = \max\{0, BN_{\alpha_j, \beta_j}[W_j * gF_{j-1}(\mathbf{x}) + b_j]\} \quad (4)$$

其中 α_j, β_j 为 BN 的重构参数。若 $G_0(\mathbf{x}) = \mathbf{dim}$ 为生成网络的输入, $G_i(\mathbf{x})$ 为编码卷积单元的输出, 则:

$$\begin{aligned} skip(\mathbf{x}) &= gF_{i,2}[gF_{i,1}(G_{i-1}(\mathbf{x}))], \\ G_i(\mathbf{x}) &= \maxpooling\{skip(\mathbf{x})\}, 0 < i \leq 3 \end{aligned} \quad (5)$$

其中 $skip(\mathbf{x})$ 表示跳跃特征图。瓶颈卷积单元由两个非线性映射构成, 记为 $G_4(\mathbf{x})$ 。生成网络的解码部分在进行特征提取前, 需要对特征图进行放大 (resize) 并与跳跃特征图进行连接 (concat), 则有:

$$up(\mathbf{x}) = concat(resize(\mathbf{x}), skip(\mathbf{x})) \quad (6)$$

$$G_i(\mathbf{x}) = gF_{i,2}\{gF_{i,1}[up(G_{i-1}(\mathbf{x}))]\}, 4 < i \leq 7 \quad (7)$$

最后, 生成网络的输出层为:

$$G(\mathbf{dim}) = g_out(\mathbf{x}) = G_8(\mathbf{x}) = \frac{1}{1 + e^{-[W_8 * G_7(\mathbf{x}) + b_8]}} \quad (8)$$

判别网络的设计遵循 Radford 等在文献 [12] 中总结的架构指南构建, 使用步长为 2 的卷积层代替池化层; 第一个非线性映射不使用批量归一化层。设 $dF(\mathbf{x})$ 为 D 的非线性映射单元, $dF_0(\mathbf{x}) = G(\mathbf{dim})$ 或 rgb , 则:

$$\begin{aligned} dF_j(\mathbf{x}) &= \max(\alpha H(\mathbf{x}), H(\mathbf{x})), \alpha = 0.2; \\ H(\mathbf{x}) &= BN_{\alpha_j, \beta_j}[W_j * gF_{j-1}(\mathbf{x}) + b_j], 0 < j \leq 2 \end{aligned} \quad (9)$$

设 $D_i(\mathbf{x})$ 为判别网络中卷积单元输出, 且 $D_0(\mathbf{x}) = 0$, 则:

$$D_i(\mathbf{x}) = dF_{i,2}[dF_{i,1}(D_{i-1}(\mathbf{x}))], 0 < i \leq 5 \quad (10)$$

接着用 1×1 卷积对 $D_5(\mathbf{x})$ 进行通道压缩, 用两个全连接层将结果映射到一个值, 并用 sigmoid 函数将其映射到 (0, 1), 由此得到输出 $D(G(\mathbf{dim}))$ 和 $D(rgb)$ 。

3.2 改进的损失函数

均方误差 (MSE) 损失是计算机视觉任务重常用的损失函数, 它在图像内容增强表现较好; 感知对抗损失反映判别网络的“判伪”能力, 它能使生成图像视觉效果更接近于目标图像; L1 损失能够有效提升图像均匀区域的平滑度和对比度。

$$L_{MSE} = \frac{1}{wh} \sum_{i=1}^w \sum_{j=1}^h [rgb_{i,j} - G(\mathbf{dim})_{i,j}]^2 \quad (11)$$

$$L_{Adv} = \sum_{n=1}^N -\log D(G(\mathbf{dim})) \quad (12)$$

$$L_{L1} = \frac{1}{wh} \sum_{i=1}^w \sum_{j=1}^h |rgb_{i,j} - G(\mathbf{dim})_{i,j}| \quad (13)$$

单一 L_{MSE} 能够得到较好的增强效果, 但其结果较为平滑, 在视觉效果上有所欠缺。 L_{L1} 相对于 L_{MSE} 鼓励少量的噪声, 对于低照度图像增强任务, 这个特性能使像素均匀较暗区域得到更好的增强。

为了更好地实现低照度图像增强, 本文联合 L_{MSE} 、 L_{Adv} 和 L_{L1} 作为损失函数, 使增强结果保留更多的细节从而得到更好的视觉效果:

$$L_{total} = \lambda_1 * L_{MSE} + \lambda_2 * L_{Adv} + \lambda_3 * L_{L1} \quad (14)$$

其中 $\lambda_1, \lambda_2, \lambda_3$ 为各个损失函数的权重, 参考文献 [10] 和文献 [13], 并在 4.3.2 节通过大量实验验证, 最终将取值定为 $\lambda_1 = 1000.0, \lambda_2 = 1.0, \lambda_3 = 10.0$ 。

4 实验设置及结果分析

4.1 数据集

由于真实场景环境的不可控性, 要同时获取一个场景的低照度图像与正常照度图像难度极高。因此, 本文参考文献 [14] 的数据集构造方法, 从 COCO 数据库中选取 2200 张典型正常照度图像, 通过对图像进行高斯模糊、添加噪声和伽马校正来模拟真实情况下采集的低照度图像, 制作 40000 对低照度-正常照度图像的训练集, 200 对测试集 (Testdatas)。

4.2 训练细节及评价指标

本文实验使用 Tensorflow 开源框架在 Windows10 + NVIDIA GTX 960 GPU 上对网络进行训练。训练时每次使用 4 对 512×512 的低照度图像与正常照度图像对生成网络与判别网络进行交替训练直到损失收敛, 期间使用 $\beta_1 = 0.9$, 学习率为 $1e-4$ 的 Adam 优化算法对模型进行优化。

实验采用峰值信噪比 (PSNR)、结构相似度 (SSIM)、均方误差 (MSE) 对有参照的合成低照度图像测试结果进行评价; 采用信息熵 (Entropy)、NIMA^[15]、BIQI^[16]、RISQUE^[17] 对无参照的真实低照度图像测试结果进行图像质量评价。

4.3 网络结构评估

4.3.1 U-Net 跳跃结构作用评估

本节通过有跳跃连接的 U-Net 模型构造的 GAN 网络模型——LLEGAN (U-Net) 和没有跳跃连接的 encode-decode 模型构造的 GAN 网络模型——LLEGAN (encode-decode) 进行对比实验, 分析跳跃结构对增强效果的影响, 结果如图 4 和表 1 所示。

表 1 跳跃连接结构对照度增强效果影响的客观评价指标对比

评价指标	低照度图像	LLEGAN (U-Net)	LLEGAN (encode-decode)
SSIM	0.3516	0.7692	0.5540
PSNR	10.67	22.34	19.34
MSE	0.08947	0.0065	0.0131

从图 4 看出 LLEGAN (U-Net) 具有更好的图像细节, 且颜色增强效果更接近真实正常照度图像; 而 LLEGAN (encode-decode) 出现严重细节丢失且颜色严重失




图4 跳跃连接结构对低照度增强效果影响的主观视觉对比

真. 表 1 中用 U-Net 比用 encode-decode 的增强结果平均 SSIM 提升了 0.2153, 平均 PSNR 值提升 3.0, 平均 MSE 降低 0.0066. 由此证明使用跳跃连接结构的 U-Net, 能够有效保留增强图像的细节, 提高色彩真实度, 更好的拟合真实图像数据.

4.3.2 各损失函数作用评估

从图 5 和表 2 可知, 当 L_{MSE} 的权重取 $\lambda_1 = 1000$ 时增强效果最佳, 取其他值时出现不同程度的对比度低、细节模糊和颜色增强欠佳等问题.




图5 不同MSE损失权重增强效果的主观视觉对比

表 2 不同 MSE 损失权重增强效果的客观评价指标对比

MSE	ADV	L1	PSNR	SSIM	MSE
1	1	10	16.63	0.5664	0.02337
10	1	10	18.67	0.6135	0.01491
100	1	10	19.83	0.7004	0.01142
1000	1	10	22.34	0.7692	0.00649




图6 不同感知损失权重增强效果的主观视觉对比

表 3 不同感知损失权重增强效果的客观评价指标对比

MSE	ADV	L1	PSNR	SSIM	MSE
1000	0	10	21.56	0.7836	0.00748
1000	1	10	22.34	0.7692	0.00649
1000	10	10	19.21	0.6909	0.01286

从图 6 和表 3 可以看出, 当 L_{Adv} 的权重取 $\lambda_2 = 1$ 的图像细节更清晰且块效应得到改善, 同时客观评价指标得分有一定的提高.

从图 7 和表 4 可以看出, L_{L1} 对增强图像亮度的影响较小, 但能够增强图像的对比度, 综合视觉效果与客观评价指标得分, 最终 L_{L1} 权重取 $\lambda_3 = 10$.




图7 不同L1损失权重增强效果的主观视觉对比

表 4 不同 L1 损失权重增强效果的客观评价指标对比

MSE	Adv	L1	PSNR	SSIM	MSE
1000	1	1	21.79	0.7550	0.00776
1000	1	10	22.34	0.7692	0.00649
1000	1	100	22.41	0.7692	0.00657

从图 8 和表 5 可以看出, 取 $L_{MSE} + L_{Adv} + L_{L1}$ 为损失函数时得到的增强图像在亮度、对比度和色彩等方面更接近于原始正常照度图像. L_{MSE} 也能得到客观评价较好的增强图像, 但视觉上细节较平滑, 暗区域增强效果欠佳; $L_{MSE} + L_{Adv}$ 的增强图像细节部分的复原效果得到提升, 但客观评价略小于单一 L_{MSE} ; L_{L1} 和 $L_{Adv} + L_{L1}$ 也能得到较好的亮度增强, 但去噪和细节增强效果欠佳. 综上对比实验分析可知, 损失函数采用 $L_{MSE} + L_{Adv} + L_{L1}$ 时得到的增强效果最好.




图8 不同损失函数组合增强效果的主观视觉对比

表 5 不同损失函数组合增强效果的客观评价指标对比

MSE	ADV	L1	PSNR	SSIM	MSE
1000	0	0	22.03	0.7682	0.00718
1000	1	0	21.90	0.7445	0.00719
0	0	10	21.28	0.7681	0.00842
0	1	10	20.03	0.6475	0.01090
1000	0	10	21.96	0.7815	0.00716
1000	1	10	22.34	0.7692	0.00649

综合以上分析, 本文采用 $L_{MSE} + L_{Adv} + L_{L1}$ 且权重取值为 $\lambda_1 = 1000$, $\lambda_2 = 1$ 和 $\lambda_3 = 10$ 的联合损失函数.

4.4 照度增强模型评估

为了评估网络模型的性能, 本文复现 HE^[2]、

MSRCR^[4]、LIME^[5]、Dong^[6] 和刘超 (Liuchao)^[7] 等经典算法,并分别使用合成低照度图像测试集和真实采集的低照度图像测试集进行对比实验分析.

4.4.1 合成低照度图像增强对比实验

如图 9 所示,可以看出 HE、Dong、LIME 方法虽也能

改善照度问题,但出现颜色失真且无法应对噪声和模糊效应;MSRCR 应对复杂场景图像时结果较暗. Liuchao 方法能明显提升亮度,但结果图细节和对比度效果欠佳. LLEGAN 模型能更好的提升亮度、对比度,且效果图更接近于正常照度图像.

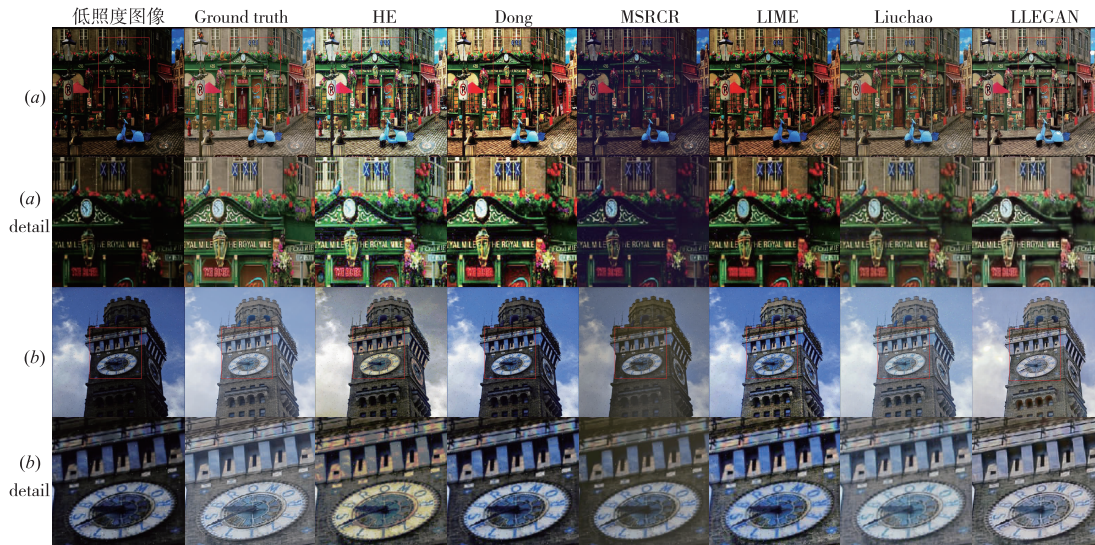


图9 不同算法在合成低照度图像测试集上的主观视觉对比

表 6 不同算法在合成低照度图像测试集上的客观评价指标对比

合成测试集	Ground truth	HE	Dong	MSRCR	LIME	Liuchao	LLEGAN
PSNR	10.67	17.06	17.47	13.16	17.14	23.55	22.34
SSIM	0.3496	0.5729	0.5995	0.5618	0.5811	0.7442	0.7692
MSE	0.0895	0.0225	0.0195	0.0511	0.0213	0.0050	0.0065

从表 6 可知,在同等条件下 LLEGAN 能得到较好的客观评价价值,即增强效果图更加接近真实图像. 虽然 PSNR 和 MSE 值比 Liuchao 欠佳,但视觉上 LLEGAN 的对比度和细节效果更佳.

4.4.2 真实低照度图像增强对比实验

本文从常见的低照度图像数据库 VV^[18]、DICM^[19] 和 LIME^[20] 中选出 100 幅图像,与搜集的包含夜景图像、逆光图像等 100 幅图像,构成 200 幅真实低照度图像测试集. 使用上述增强算法对该数据集的测试结果如图 10 和表 7 所示.

从视觉效果和客观指标可以看出,HE 能得到更高

的信息熵,但其视觉效果出现噪声、色彩偏差等现象; Dong 方法无法很好的应对光照不均匀图像的增强; MSRCR 方法的结果较平滑,没有出现块效应,但视觉和客观指标结果较差;而 LIME 方法出现颜色过度增强和暗区域增强效果欠佳的问题; Liuchao 方法结果图从视觉上有蒙上雾的效果,且客观评价指标欠佳于 LLEGAN 方法; LLEGAN 方法在客观评价指标中除了信息熵欠佳于 HE,其余指标均为最好,从视觉效果看 LLEGAN 能够有效提升图像的亮度、对比度且色彩增强效果较好. 综上,本文提出的 LLEGAN 方法在对真实低照度图像数据集的测试结果中得到比其他方法更好的结果.

表 7 不同算法在真实低照度图像上的客观评价指标对比

真实测试集	HE	Dong	MSRCR	LIME	Liuchao	LLEGAN
entropy	6.4128	5.5919	5.2698	5.6836	5.7127	5.9077
NIMA	5.24(2.54)	5.00(2.82)	5.71(2.79)	4.95(2.60)	5.96(2.80)	6.03(2.74)
BIQI	35.7540	35.2875	33.8887	35.6649	38.0494	31.9929
BRISQUE	33.4434	31.6632	33.8596	33.5851	38.0085	33.8256



图10 不同算法在真实低照度图像上的主观视觉对比

5 结论

针对低照度图像增强问题,本文提出了一种基于 U-Net 生成对抗网络的低照度图像增强方法——LLEGAN. 该方法利用 U-Net 跳跃结构对图像信息的保留优势改进生成网络,提升了照度增强模型性能,使其在颜色和细节的修复方面表现更好;利用不同损失函数的特性改进网络总损失函数,使网络得到视觉与客观评价都更佳的照度增强图像. 通过实验验证了本文方法切实可行,且相较于一些经典照度增强算法,本文的 LLEGAN 方法得到更好的照度增强图像.

参考文献

- [1] 马红强,马时平,许悦雷,朱明明. 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(02):99-108.
- Ma H Q, Ma S P, Xu Y L, Zhu M M. Low-light image enhancement based on deep convolutional neural network[J]. Acta Optica Sinica,2019,39(02):99-108. (in Chinese)
- [2] Gonzalez R C, Woods R E. Digital Image Processing[M]. Prentice-Hall, Inc. 2007.
- [3] Land E H E. Lightness andretinex theory[J]. Journal of the Optical Society of America,1971,61(1):1-11.
- [4] Jobson D J, Rahman Z, Woodell G A. A multiscale retinex for bridging the gap between color images and the human observation of scenes[J]. IEEE Transactions on Image Processing,1997,6(7):965-976.
- [5] 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.
- [6] Dong X, Guan W, Pang Y, et al. Fast efficient algorithm for enhancement of low lighting video[A]. 2011 IEEE ICME[C]. Barcelona,2011. 1-6.
- [7] 刘超,张晓晖. 超低照度下微光图像的深度学习自编码网络复原[J]. 光学精密工程,2018,26(04):951-961.
- LIUC, ZHANG X H. Deep convolution autoencoder networks approach to low-light level image restoration under extreme low-light illumination[J]. Optics and Precision Engineering,2018,26(04):951-961. (in Chinese)
- [8] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[A]. International Conference on Neural Information Processing Systems (NIPS)[C]. MIT Press,2014. 2672-2680.
- [9] Mirza M, Osindero S. Conditional generative adversarial nets[J]. Computer Science,2014:2672-2680.
- [10] P Isola, J Zhu, T Zhou, A A Efros. Image-to-image translation with conditional adversarial networks[A]. 2017 IEEE Conference on CVPR[C]. Honolulu, HI,2017. 5967-5976.
- [11] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[A]. Medical Image Computing and Computer-Assisted Intervention[C]. Munich, Germany: Springer,2015,9351. 234-241.
- [12] A Radford, L Metz, S Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks[A]. International Conference on Learning Representations (ICLR)[C]. arXiv:1511.06434v2.
- [13] Ledig C, Theis L, Huszar F, et al. Photo-realistic single image super-resolution using a generative adversarial network[A]. Computer Vision and Pattern Recognition[C]. IEEE,2016. 4681-4690.
- [14] W Hua, Y Xia. Low-light image enhancement based on joint generative adversarial network and image quality assessment[A]. 11th CISP-BMEI[C]. Beijing, China, 2018. 1-6.
- [15] Talebi H, Milanfar P. NIMA: neural image assessment

- [J]. IEEE Transactions on Image Processing, 2018, 27(8):3998–4011.
- [16] Moorthy A K, Bovik A C. A two-step framework for constructing blind image quality indices[J]. Signal Processing Letters, 2010, 17(5):513–516.
- [17] Mittal A, Moorthy A K, Bovik A C. No-reference image quality assessment in the spatial domain[J]. IEEE Transactions on Image Processing, 2012, 21(12):4695.
- [18] Vonikakis V, Kouskouridas R, Gasteratos A. On the evaluation of illumination compensation algorithms[J]. Multimedia Tools & Applications, 2017:1–21.
- [19] Lee C, Lee C, Kim C S. Contrast enhancement based on layered difference representation[A]. IEEE International Conference on Image Processing [C]. IEEE, 2013. 965–968.
- [20] Sheikh H R, Sabir M F, Bovik A C. A statistical evaluation of recent full reference image quality assessment algorithms[J]. IEEE Transactions on Image Processing, 2006, 15(11):3440–3451.

作者简介



江泽涛 男. 1961年3月出生, 江西九江人. 桂林电子科技大学教授, 博士生导师, 主要从事图像处理、计算机视觉、信息安全方面的研究.



覃露露 女. 1993年7月出生, 广西百色人. 桂林电子科技大学硕士研究生, 主要从事图像增强、图像理解方面的研究.
E-mail:luluqin766@qq.com