

一种基于 ARD-GAN 的低照度图像增强方法

江泽涛¹, 钱 艺¹, 伍 旭¹, 张少钦²

(1. 桂林电子科技大学广西图像图形与智能处理重点实验室, 广西桂林 541004; 2. 南昌航空大学, 江西南昌 330063)

摘 要: 为解决低照度图像增强过程中噪声放大、细节不足以及色彩还原问题, 本文提出一种基于注意力机制残差密集生成对抗网络 (Attention Residual Dense-Generative Adversarial Networks, ARD-GAN) 的低照度图像增强方法. 首先, 该方法在全局光照估计模块 (Global Illumination Estimation Module, GIEM) 中生成全局曝光注意力图, 以引导后续模块更好地进行照度增强; 其次, 使用卷积残差模块 (Convolution and Residual Module, CRM) 和基于通道注意力的残差密集模块 (Channel Attention Residual Dense Module, CARDM) 分别提取浅层特征和深层特征, 并将不同层次的特征融合以获取更好的细节信息; 然后, 在 CARDM 基础上将密集连接与批归一化相结合抑制噪声; 最后改进了损失函数, 使增强后图像色彩还原更好. 实验表明, ARD-GAN 有与主流算法相比, 在主观视觉和客观评价指标上均得到更好的效果.

关键词: 低照度增强; 图像细节增强; 降噪; 色彩还原; 注意力机制; 残差密集网络

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112(2021)11-2160-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20200822

Low-Light Image Enhancement Method Based on ARD-GAN

JIANG Ze-tao¹, QIAN Yi¹, WU Xu¹, ZHANG Shao-qin²

(1. *The Key Laboratory of Image and Graphic Intelligent Processing in Guangxi, Guilin University of Electronic Technology, Guilin, Guangxi 541004, China*; 2. *Nanchang Hangkong University, Nanchang, Jiangxi 330063, China*)

Abstract: In order to solve the problems of noise amplification, insufficient detail and color restoration in the process of low-light image enhancement, this paper proposes a method of low-light image enhancement based on attention residual dense-generative adversarial networks (ARD-GAN). Firstly, the method generates a global exposure attention map in the global illumination estimation module (GIEM) to guide the subsequent modules to enhance the illumination better; secondly, it adopts the convolution and residual module (CRM) and the channel attention residual dense module (CARDM) to extract shallow features and deep features respectively, and fuses different features of levels to obtain better detailed information; furthermore, based on the CARDM, the dense connection and batch normalization are combined to suppress noise. Finally, the improved loss function restores the enhanced image color better. Comprehensive experiments are conducted, which show that ARD-GAN can significantly outperform mainstream algorithms in subjective vision and objective evaluation indicators.

Key words: low-light enhancement; image detail enhancement; noise reduction; color reproduction; attention mechanism; residual dense network

1 引言

在低光照环境获取的图像, 由于环境光照不足会导致采集到的图像存在亮度低、对比度低、信噪比低和噪声污染大等特点. 这类图像往往会严重影响图像分类、目标检测和图像理解等计算机视觉任务的算法

性能.

目前低照度增强方法可归纳为四类. (1) 基于直方图均衡化 (Histogram Equalization, HE) 的增强方法^[1]. 该方法通过对图像进行非线性拉伸, 重新分配图像像素值, 使一定灰度范围内的像素数量大致相同, 达到增

收稿日期: 2020-08-03; 修回日期: 2021-01-15; 责任编辑: 李勇锋

基金项目: 国家自然科学基金 (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 (No.GIIP2006, No.GIIP2007, No.GIIP2008); 广西研究生教育创新计划 (No.2019YCX043, No.YCBZ2018052); 桂林电子科技大学研究生科研创新 (No.2020YCX050)

强图像亮度和对比度的目的。(2)基于 Retinex 的增强方法^[2]是由 Land 等人在 1971 年提出. 该方法将人类视觉的颜色感知和亮度理解为由物体颜色对光线的反射率所决定的,与反射光强度无关。(3)基于伪雾图的增强方法^[3]. 该方法根据低照度环境下的图像取反后与雾天图像相似的特点,使用去雾算法进行增强。(4)基于深度学习的方法与其他方法最大的区别在于它利用数据作为驱动,将大量不同的低照度图像送到模型中进行训练,使其获得低照度图像增强的能力. 如 Tao L 等^[4]提出了 LLCNN,通过使用卷积结构实现低照度图像增强. 该类方法能对低照度图像进行照度增强,但增强后的图像往往在图像细节、噪声和色彩方面表现欠佳.

为了解决上述问题和更有效地增强图像细节、降噪和色彩还原,本文基于生成对抗网络,并结合注意力机制和残差密集块,提出一种基于 ARD-GAN 的低照度图像增强方法. 首先,该方法在 GIEM 中生成全局曝光注意力图,以引导后续模块进行照度增强并具有抑制噪声作用;其次,使用 CRM 和 CARDM 分别对浅层特征和深层特征进行提取以获取更丰富的细节信息;然后,在 CARDM 基础上将密集连接与批归一化相结合抑制噪声,采用 DnCNN^[5]监督生成网络,达到更好的降噪效果;最后改进损失函数并结合多个损失函数作为联合损失函数,使增强后图像色彩还原更好. 经实验结果表明,本文方法与主流算法相比,具有更好的增强图像细节、降噪和色彩还原性能.

2 相关工作

2.1 生成对抗网络

生成对抗网络 (Generative Adversarial Networks, GANs) 最先由 Ian Goodfellow^[6]提出,目前已广泛应用于图像的各个领域. GAN 由生成网络 (G) 和判别网络 (D) 组成. G 用于模拟目标图像真实数据的潜在分布. D 是一个二分类器,用于分辨输入数据是真实数据还是生成数据. 当 D 无法分辨输入数据是真实数据还是生成数据时,说明 G 生成的图像达到最优. GANs 的优化目标函数为:

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

其中, P_{data} 表示真实数据的分布, P_z 表示生成网络的输入. 整个目标函数的目的是让 P_z 尽可能的模拟 P_{data} 的数据分布.

2.2 残差密集块

残差密集块 (Residual Dense Block, RDB) 由 Yulun Zhang 等^[7]提出,用于超分辨率重建任务中提取低分辨率图像中的特征. 密集连接首先由 Huang 等^[8]提出,为

保证网络层与层之间信息传输的最大化,将前面所有层的输出作为后一层的输入. 残差连接^[9]是为了解决网络层数太深,导致信息丢失和梯度问题所提出的,它将本层的信息作为随后若干层的输入,保证了信息的完整性. 残差密集块将残差连接和密集连接进行融合,通过密集连接充分利用所有层的特征,并使用残差连接将原始输入与提取到的特征相融合,以获取更为丰富的特征.

3 基于 ARD-GAN 的低照度增强方法

3.1 ARD-GAN 网络结构

为更好地还原低照度图像细节、抑制噪声和色彩,本文基于 Attention、RDN 和 GAN 结构提出了 ARD-GAN 方法. 该方法由生成网络和判别网络组成,生成网络包含全局光照估计模块、卷积残差模块和基于通道注意力的残差密集模块,分别用于引导后续模块进行照度增强、提取浅层特征和深层特征,如图 1(a). 采用 DnCNN 作为判别网络,以进一步提高 ARD-GAN 对噪声的抑制作用.

3.2 改进的全局光照估计模块

GIEM 通过生成全局曝光注意力图去引导后续模块进行照度增强,同时也具有降噪的作用,GIEM 结构如图 1(b) 所示. 全局曝光注意力图根据图像不同位置的曝光强度,自适应地对各个位置进行加权. 由于低照度图像中的噪声多分布在较暗区域,故全局曝光注意力图在引导后续模块进行照度增强的同时也能起到抑制噪声的作用. GIEM 采用基于空间注意力机制的跳跃连接 (Spatial Attention Skip connection, SAS), 以突出编码阶段的关键信息,弥补信息丢失和准确定位曝光不足区域,如图 1(d).

首先,将低照度图像 x 送入 $F_{\text{BEM}}(x)$ 中得到光照分布图 x_{BEM} ,其中网络 $F_{\text{BEM}}(x)$ 采用了基于空间注意力机制的跳跃连接.

其次,将光照分布图 x_{BEM} 和低照度输入图 x 送入 Mask 中计算得到全局曝光注意力图 x_{Mask} ,采用通道注意力机制对 x_{Mask} 通道间的依赖关系进行建模,以提高重要通道的表征能力并抑制无关特征. 如式(2), $\max(\cdot)$ 返回三个颜色通道中的最大值.

$$x_{\text{Mask}} = \frac{|\max(x) - \max(x_{\text{BEM}})|}{\max(x)} \quad (2)$$

3.3 改进的卷积残差模块

CRM 用于提取输入图像中较为浅层的特征,由 3 个 CRB 和 1 个浅层特征融合块组成. CRB 包含 1×1 卷积层、ReLU 激活函数、平均池化层和跳跃连接,如图 1(e). 首先,由于 ReLU 激活函数对非正数输入会统一压缩为 0 且无法恢复,故将其放在 CRB 首位以压缩输入

特征;其次采用 1×1 卷积以便于编码通道间的信息;再为平均池化层,可减轻因邻域大小受限造成的估计值方差问题;最后,输入特征通过跳跃连接与平均池化层的输出相加,确保信息的完整性.此外,在CRM的第一

个卷积层中引入通道扩张系数 $\rho^{[10]}$,用于扩张通道数,如式(3), $\text{conv}(\cdot)$ 表示卷积操作, ρ 表示通道扩张系数.

$$x_0 = \rho \cdot \text{conv}(x_{-1}) \quad (3)$$

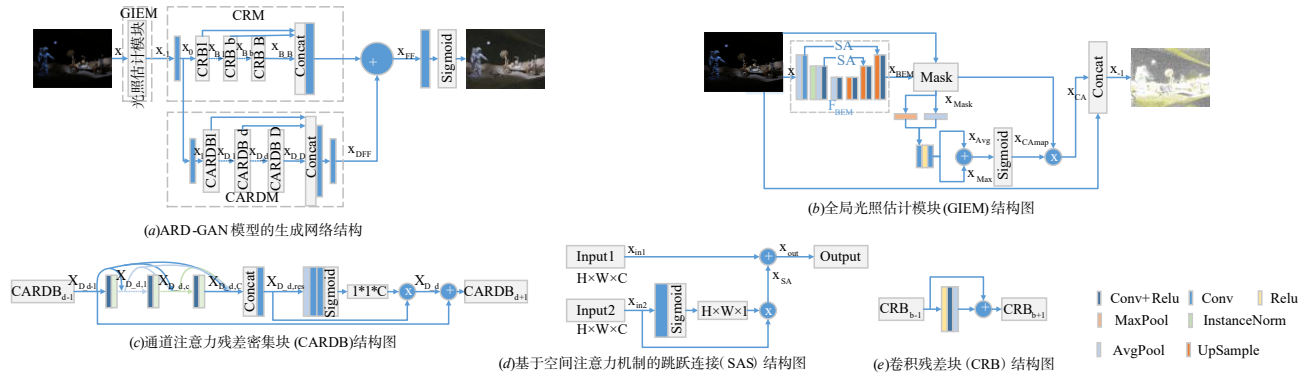


图1 ARD-GAN生成网络及子模块结构图

3.4 基于通道注意力的残差密集模块

CARDM用于提取输入图像的深层特征,由多个通道注意力残差密集块(Channel Attention Residual Dense Block, CARDB)组成. CARDB由密集连接层、深层特征融合、深层特征残差学习和通道注意力机制组成, CARDB结构如图1(c).

受启发于DnCNN,本文结合密集连接与批归一化进行降噪,其中密集连接通过在通道维度拼接前面所有层得到的特征来实现特征复用,批归一化可加快训练速度且提升网络降噪性能.密集连接层可提取丰富的深层特征信息,但并不是每个通道的特征都有助于图像增强,故使用通道注意力机制为每个通道特征赋予不同的权重,使网络对有助于图像增强的通道给予更多的关注.

3.5 改进的损失函数

ARD-GAN的训练目的是将低照度图像送入网络,使增强后的图像与相关正常照度图像尽可能的相近.为获得更好的增强效果,本文改进了损失函数,由生成网络和判别网络损失函数组成,如式(4).

$$L_{\text{total}} = L_{\text{Adv}} + L_{\text{Gen}} \quad (4)$$

生成网络损失函数由MSE、MAE、全变分损失(Total Variation, TV)损失和区域损失函数组成.其中, MSE通过计算增强图像和正常照度图像的均方误差,可较好地度量两张图像像素之间的差异;相较MSE, MAE对噪声具有更强的鲁棒性;TV能够对平滑噪声操作进行一定的约束,避免丢失细节信息;此外,本文引入区域损失函数将图像中最暗的40%像素和其他像素分开处理,以达到更好的增强效果.

$$L_{\text{Gen}} = \lambda_1 \times L_{\text{MAE}} + \lambda_2 \times L_{\text{MSE}} + \lambda_3 \times L_{\text{TV}} + \lambda_4 \times L_{\text{Region}} \quad (5)$$

$$L_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2 \quad (6)$$

$$L_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - f(x_i)| \quad (7)$$

$$L_{\text{TV}} = \frac{1}{CHW} \left\| \nabla_x \text{Fw}(I_s) + \nabla_y \text{Fw}(I_s) \right\| \quad (8)$$

$$L_{\text{Region}} = w_L \frac{1}{m_L n_L} \sum_{i=1}^{n_L} \sum_{j=1}^{m_L} \left\| E_L(i, j) - G_L(i, j) \right\| + \quad (9)$$

$$w_H \frac{1}{m_H n_H} \sum_{i=1}^{n_H} \sum_{j=1}^{m_H} \left\| E_H(i, j) - G_H(i, j) \right\|$$

其中, λ_1 、 λ_2 、 λ_3 和 λ_4 是各子损失函数的权重,参考文献[11]和文献[12]并在4.3.2节通过大量实验验证,最终确定各个权重为 $\lambda_1 = 1$ 、 $\lambda_2 = 1$ 、 $\lambda_3 = 10$ 和 $\lambda_4 = 3$.在式(8)中, ∇_x 和 ∇_y 分别代表 x 方向和 y 方向的梯度, C 、 H 和 W 分别代表生成图像 $\text{Fw}(I_s)$ 的维度;式(9)中, E_L 和 G_L 表示增强图像和真实图像的低照度区域, E_H 和 G_H 表示两种图像的其他区域, w_L 和 w_H 表示它们的权重系数.

判别网络损失函数采用最小二乘法损失函数^[13],用于引导生成网络和判别网络之间达到纳什均衡.如式(10),其中 E 为期望值, D 为判别网络, G 为生成网络.

$$L_{\text{Adv}} = \frac{1}{2} E \left[(D(x) - 1)^2 \right] + \frac{1}{2} E \left[(D(G(z)))^2 \right] \quad (10)$$

4 实验和结果分析

4.1 实验数据集

本文从COCO数据集中选取3525张正常照度的图像,对每张图片随机裁剪成16张 128×128 大小,将这些图像进行添加噪声、伽马校正和高斯模糊等操作,构成56000对低照度与正常照度对应的训练集和400对测试集(Syn_testSet).

4.2 训练细节及评价指标

本文实验基于 Pytorch、Windows Server 2016+NVIDIA GTX 1080Ti GPU 训练模型. 训练时,输入为 8 对 128×128 的低照度和正常照度图像,生成网络和判别网络采用交替训练的方式直至损失收敛,使用学习率为 1e-4 的 Adam 优化模型.

本文实验选用该领域最为常用的峰值信噪比

(PSNR)、结构相似度(SSIM)和均方误差(MSE)对有参照的合成数据集测试结果进行图像质量评价.

4.3 网络结构及损失函数评估

4.3.1 网络结构评估

为评估全局光照估计和注意力机制的增强效果,本文对 GIEM 和 CARDM 进行消融实验,并在合成数据集上进行测试. 由表 1 知,本文设计皆可有效提升网络性能.

表 1 不同的网络结构增强效果的客观评价指标

评估模块	模型	PSNR	SSIM	MSE
GIEM	ARD-GAN w/o GIEM	22. 11	0. 8363	0. 0063
	ARD-GAN w/o SAS(GIEM)	22. 47	0. 8334	0. 0069
	ARD-GAN w/o CA(GIEM)	22. 52	0. 8360	0. 0066
	ARD-GAN w/o CA(GIEM)& SAS(GIEM)	22. 23	0. 8382	0. 0062
CARDM	ARD-GAN w/o CA(CARDB)	22. 17	0. 8301	0. 0069
CRM	ARD-GAN w/o CRB	22. 68	0. 8354	0. 0061
Ours	ARD-GAN	23. 03	0. 8475	0. 0057

4.3.2 联合损失函数评估

ARD-GAN 的生成网络采用联合损失函数,本节通过固定判别网络损失函数,将其与不同联合损失函数组合的方式进行对比分析(见表 2~表 5),本文提出的联合损失函数,当权重为 $\lambda_1 = 1, \lambda_2 = 1, \lambda_3 = 10$ 和 $\lambda_4 = 3$ 时,增强效果可达到最优.

表 2 不同 MAE 损失权重增强效果的客观评价指标对比

ADV	MAE	PSNR	SSIM	MSE
1	1	22. 32	0. 8341	0. 0068
1	10	20. 37	0. 7951	0. 0105
1	100	20. 06	0. 7881	0. 0112

表 3 不同 MSE 损失权重增强效果的客观评价指标对比

ADV	MAE	MSE	PSNR	SSIM	MSE
1	1	1	22. 43	0. 8409	0. 0065
1	1	10	21. 83	0. 8302	0. 0079
1	1	100	22. 37	0. 8402	0. 0069

表 4 不同 Region 损失权重增强效果的客观评价指标对比

ADV	MAE	MSE	Region	PSNR	SSIM	MSE
1	1	1	1	22. 58	0. 8447	0. 0064
1	1	1	10	22. 62	0. 8391	0. 0064
1	1	1	100	22. 59	0. 8406	0. 0064

表 5 不同 TV 损失权重增强效果的客观评价指标对比

ADV	MAE	MSE	Region	TV	PSNR	SSIM	MSE
1	1	1	10	1	22. 69	0. 8452	0. 0062
1	1	1	10	3	23. 03	0. 8475	0. 0057
1	1	1	10	10	22. 82	0. 8436	0. 0060

由表 6 可知,除 $L_{Adv} + L_{TV}$ 之外,其他联合损失函数均取得较好的效果. 此外,无论 $L_{MAE}, L_{MSE}, L_{Region}$ 如何两

表 6 不同联合损失函数增强效果的客观评价指标

损失函数	PSNR	SSIM	MSE
$L_{Adv} + \lambda_1 L_{MAE}$	22. 32	0. 8341	0. 0068
$L_{Adv} + \lambda_2 L_{MSE}$	22. 43	0. 8409	0. 0065
$L_{Adv} + \lambda_3 L_{Region}$	22. 62	0. 8391	0. 0064
$L_{Adv} + \lambda_4 L_{TV}$	11. 61	0. 2450	0. 0743
$L_{Adv} + \lambda_1 \times L_{MAE} + \lambda_2 \times L_{MSE}$	22. 46	0. 8428	0. 0067
$L_{Adv} + \lambda_1 L_{MAE} + \lambda_3 L_{Region}$	22. 13	0. 8399	0. 0072
$L_{Adv} + \lambda_2 L_{MSE} + \lambda_3 L_{Region}$	22. 36	0. 8388	0. 0068
$L_{Adv} + \lambda_1 L_{MAE} + \lambda_2 L_{MSE} + \lambda_3 L_{Region}$	22. 67	0. 8431	0. 0063
$L_{Adv} + \lambda_1 L_{MAE} + \lambda_2 L_{MSE} + \lambda_4 L_{TV}$	22. 70	0. 8413	0. 0063
$L_{Adv} + \lambda_1 L_{MAE} + \lambda_3 L_{Region} + \lambda_4 L_{TV}$	22. 65	0. 8474	0. 0063
$L_{Adv} + \lambda_2 L_{MSE} + \lambda_3 L_{Region} + \lambda_4 L_{TV}$	22. 94	0. 8458	0. 0058
$L_{Adv} + \lambda_1 L_{MAE} + \lambda_2 L_{MSE} + \lambda_3 L_{Region} + \lambda_4 L_{TV}$	23. 03	0. 8475	0. 0057

两组组合,得到的增强效果都低于三者的组合,并且加入 L_{TV} 后,在三个指标上的测试结果都有明显地提高.

4.4 照度增强模型评估

为评估本文方法,将分别对合成低照度图像测试集和真实低照度图像测试集进行实验和对比分析. 将本文方法与常见低照度图像增强方法比较,包括基于学习的 GLADNet^[14]、MBLLEN、LLCNN 和 MSRNet^[15]方法和基于非学习的 LIME、Dehaze 和 CLAHE 方法.

4.4.1 合成低照度图像测试集增强结果评估

由图 2 可知,LLCNN、MBLLEN 和 MSRNet 都存在不同程度降噪效果差的问题. 由图 2 细节图可知,MSRNet 拥有较差的降噪效果,图像整体偏绿且伪影明显. LLCNN 和 MBLLEN 细节恢复较好,但照度提升不足. GLADNet 有较好的降噪效果,但图像整体也偏绿. 本文提出的 ARD-GAN,在视觉效果方面与真实图像最为接

近且客观评价指标均为最佳.




图2 基于学习的低照度增强算法在Syn_testSet上的主观视觉效果对比




图3 不同算法在VV数据集上的主观视觉效果对比

表7 不同方法在Syn_testSet上的客观评价指标

方法	PSNR	SSIM	MSE
GLADNet	20.90	0.7941	0.0090
LLCNN	20.63	0.8301	0.0098
MSRNet	20.01	0.8045	0.0108
MBLLEN	20.25	0.8026	0.0105
ARD-GAN	23.03	0.8475	0.0057

4.4.2 真实低照度图像增强结果评估

为评估ARD-GAN在真实场景下的低照度增强效果,本文从ExDark^[16]、SICE^[17]和TID2013^[18]数据集中选取多张图像进行增强效果对比,如图3所示.

LIME在亮度和对比度方面表现不错,但色彩过度增强和细节还原不够清晰. Dehaze图像亮度增强不足,在光照不均的逆光区域尤为明显. CLAHE方法增强效果整体偏暗且色彩还原较差,但在逆光条件下的图像增强效果较好. 由图3(b)可知,传统方法在对逆光场景进行图像增强时,能够较好地保留图像背景的亮度和色彩等信息,但

在图像亮度增强方面不如基于深度学习的方法.

由图3(c)可知,MSRNet亮度增强较好,但色彩还原方面表现较差. 而GLADNet方法在色彩还原方面表现较好,但从图3(b)可看出,该方法增强较暗图像时会出现伪影且对逆光图像不能很好地保留背景信息. LLCNN能有效提高图像的亮度和对比度,但从图3(c)可以看出LLCNN对伪影处理欠佳.

综上,从增强图像的亮度、对比度、图像细节、色彩恢复和噪声抑制等方面分析可知,ARD-GAN取得了最佳的增强效果.

5 结论

针对低照度图像存在的问题,本文提出了一种基于注意力机制、残差密集块和生成对抗网络的低照度增强方法——ARD-GAN. 首先,该方法利用GIEM生成全局曝光注意力图,以引导后续模块进行照度增强;其次,使用CRM和CARDM提取到的不同层次特征并融合从而获得更丰富地细节信息;然后,在CARDM基础上将密集

连接和批归一化相结合以达到降噪作用;最后改进损失函数并结合多个损失函数作为联合损失函数,使增强后的图像色彩还原更好.实验表明,本文方法能有效提升低照度图像的亮度、对比度并使噪声得到了有效抑制,在色彩和细节恢复上更加接近于真实图像水平.

参考文献

- [1] Reza A M. Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement[J]. Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology, 2004, 38(1): 35 – 44.
- [2] 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.
- [3] Dong X, Wang G, Pang Y, et al. Fast efficient algorithm for enhancement of low lighting video[A]. 2011 IEEE International Conference on Multimedia and Expo [C]. USA: IEEE, 2011. 1 – 6.
- [4] Tao L, Zhu C, Xiang G, et al. LLCNN: A convolutional neural network for low-light image enhancement[A]. 2017 IEEE Visual Communications and Image Processing (VCIP)[C]. USA: IEEE, 2017. 1 – 4.
- [5] Zhang K, Zuo W, Chen Y, et al. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142 – 3155.
- [6] Zhang H, Goodfellow I, Metaxas D, et al. Self-attention generative adversarial networks [EB/OL]. <https://arxiv.org/abs/1805.08318>, 2018.
- [7] Zhang Y, Tian Y, Kong Y, et al. Residual dense network for image super-resolution [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2018. 2472 – 2481.
- [8] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. USA: IEEE, 2017. 4700 – 4708.
- [9] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. USA: IEEE, 2016. 770 – 778.
- [10] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2018. 4510 – 4520.
- [11] 江泽涛,覃露露.一种基于 U-Net 生成对抗网络的低照度图像增强方法[J].电子学报,2020,48(2):258 – 264. Jiang Z T, Qin L L. Low-light image enhancement method based on U-net generative adversarial network[J]. Acta Electronica Sinica, 2020, 48(2): 258 – 264.(in Chinese)
- [12] Lv F, Lu F, Wu J, et al. MBLLEN: Low-light image/video enhancement using CNNs [A]. BMVC 2018 [C]. UK, 2018. 220.
- [13] Mao X, Li Q, Xie H, et al. Least squares generative adversarial networks [A]. Proceedings of the IEEE International Conference on Computer Vision (ICCV) [C]. USA: IEEE, 2017. 2794 – 2802.
- [14] Wang W, Wei C, Yang W, et al. GLADNet: Low-light enhancement network with global awareness [A]. 2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018) [C]. USA: IEEE, 2018. 751 – 755.
- [15] Shen L, Yue Z, Feng F, et al. Msr-net: Low-light image enhancement using deep convolutional network[J]. arXiv preprint arXiv:1711.02488, 2017.
- [16] 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.
- [17] Cai J, Gu S, Zhang L. Learning a deep single image contrast enhancer from multi-exposure images[J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049 – 2062.
- [18] Chen Z, Jiang T, Tian Y. Quality assessment for comparing image enhancement algorithms [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2014. 3003 – 3010.

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.



钱艺(通讯作者) 男,1993年6月出生,山东淄博人.桂林电子科技大学硕士研究生,主要从事图像增强方面的研究.
E-mail:Qyizos@163.com