

使用条件生成对抗网络的自然图像增强方法

贾玉福¹, 胡胜红², 刘文平¹, 王超², 向书成²

(1. 湖北经济学院信息管理与统计学院, 湖北 武汉 430205)

(2. 湖北经济学院信息与通信工程学院, 湖北 武汉 430205)

[摘要] 自然图像增强是计算机视觉领域中的一个研究热点. 针对以往图像增强方法计算过程复杂和参数需手工设置等缺陷, 提出一种基于条件生成对抗模型的图像增强(enhancement with conditional generative adversarial networks, E-CGAN)方法. 分别构建生成式神经网络和判别式神经网络, 其中, 生成模型直接对图像进行处理生成最终增强的图片结果, 判别模型在训练阶段对生成模型构建对抗型损失函数, 优化生成模型的参数. 在生成模型的结构中, 加入 $L1$ 距离误差函数作为生成模型的约束, 并提出连续多尺度跨层连接方式, 加快网络的训练速度, 提高生成模型的准确率. 在图像清晰度增强, 灰度图像着色两个图像增强问题上进行实验, 结果表明, E-CGAN 可以有效地保留图像特征, PSNR 和 SSIM 质量平均提高 9% 和 5%.

[关键词] 图像增强, 生成对抗网络, 深度学习, 图像质量

[中图分类号] TP391 **[文献标志码]** A **[文章编号]** 1001-4616(2019)03-0088-08

Wild Image Enhancement with Conditional Generative Adversarial Network

Jia Yufu¹, Hu Shenghong², Liu Wenping¹, Wang Chao², Xiang Shucheng²

(1. Information Management and Statistics School, Hubei University of Economics, Wuhan 430205, China)

(2. Information and Communication Engineering School, Hubei University of Economics, Wuhan 430205, China)

Abstract: Wild image enhancement technology is a hotspot in the field of computer vision. To overcome the defects on complexity of calculation and manual setting parameters of the conventional image enhancement methods, a novel image enhancement method with conditional generative adversarial network (E-CGAN) has been proposed. The generative neural network and the discriminant neural network are constructed respectively, where the generative model is used to generate the final images and the discriminant model is employed to construct the confrontation loss function in the training stage, so as to optimize the parameters of the two models. In the structure of the generative model, a successive-multiple skip connection method constrained by $L1$ error function is proposed, which speeds up the training speed of the network and improves the accuracy of the generative model. Two implementations on image sharpening and colorization have been implemented to evaluate the effectiveness of the proposed method, the experimental results show that E-CGAN can effectively highlight the characteristics of the image, and better quality promotion achieves up to 9% and 5% both on PSNR and SSIM index.

Key words: image enhancement, generative adversarial network, deep learning, image quality

图像增强是数字图像处理中非常重要的研究内容, 对于提高图像的质量起着重要的作用, 图像增强技术通过有选择地强调图像中的某些信息而抑制掉另一些信息, 以改善图像的视觉效果, 并将优化的结果呈现给计算机和使用者. 在一般情况下, 图像经过传输和转换, 容易造成质量下降和信息缺失, 在具体的应用中更会带来诸多问题, 例如图像去噪、不可逆的图像压缩等. 在自然图像取景摄影的过程中, 由于光照条件不足或过度, 会使图像过暗或过亮; 在运动取景, 大气流动等条件下, 也会造成摄影图像的模糊和失真. 在某些情况下, 需要复原图像缺失的信息, 例如黑白照片的彩色化、图像分辨率的提高、噪声点的消除

收稿日期: 2019-07-05.

基金项目: 国家自然科学基金(61572012)、教育部人文社科项目(18YJCZH050)、湖北省自然科学基金(D20182202)、教育厅科研计划(2018CFB721).

通讯联系人: 胡胜红, 博士, 副教授, 研究方向: 基于内容的视频检索与自适应传输、深度学习. E-mail: wuhanhush@126.com

等. 图像增强的目的是根据特定的需求强化原图像中的重要信息,使得图像具有更直观和有效的信息表达.

传统的图像增强方法基本上分为空域图像增强和频域图像增强两大类. 空域指图像的像素集合,空域图像增强是直接对图像像素进行处理,例如 Reinhard^[1]、Welsh^[2]等图像增强方法,直接对原始图像像素空间进行操作. 频域增强方法是通过对图像进行傅里叶变换后进行操作,例如低通滤波、高通滤波、小波变换等技术,这些方法至今仍在图像增强领域发挥着重要的作用^[3-4]. 然而,传统图像增强方法在图像增强领域的通用性较低,且需要人工设计调整参数、提取特征、存在不稳定性、增强效率和效果相对较低. 因此,本文提出了一种基于条件生成对抗神经网络的自然图像增强算法(enhancement with conditional generative adversarial networks, E-CGAN),该算法对于图像增强问题有很好的通用性,且与传统图像增强算法相比具有以下几个优势^[5-6]:

- 速度快,对单幅图像进行增强只需要对生成模型作一次前向运算,处理时间一般在毫秒级;
- 效果好,通过生成模型与判别模型的无监督对抗式训练,增强生成模型的图像生成能力和质量;
- 算法框架直观,便于实现,避免了手工调整参数,具有更强的实用性,易于完成复杂的图像增强任务.

1 生成对抗神经网络

生成对抗神经网络最早由 GoodFellow^[5]提出,该模型与传统神经网络模型最大的区别是将神经网络结构设计为生成模型和判别模型,利用判别模型对生成模型构建对抗损失函数,使得输出数据与目标数据具有一致的数据分布,例如 MNIST 手写数字的生成、CelebA 人脸图片的生成等. Goodfellow 等将对抗模型运用到卷积神经网络中,提出了深度卷积生成对抗网络模型(deep convolutional generative adversarial network, DCGAN),证明了对抗模型在卷积神经网络的适用性. Mirza 等人将输入图像与标签融合训练,设计出了条件生成对抗模型,在网络的输入端添加一定的约束,则可以生成相应的图像、文本等^[6]. 生成对抗模型在数据生成领域也获得越来越多的重视. Denton 使用拉普拉斯金字塔模型构建一个级联的生成模型,在大场景的处理生成获得了很好的效果^[7]. 条件生成对抗模型的结构如图 1 所示.

在条件式生成对抗模型中,一共有三种数据类型,分别为原始图像 x ,生成模型生成的图像 y' ,与原始图像对应的真实图像 y ,模型的工作原理如图 1 所示. 生成模型处理输入图像 x 得到生成图像 y' ,目标效果是越像真实图像越好^[8];判别模型是一个二分类器,其输入有两种来源:真实图像对(真实图像和原始图像融合结果)和生成图像对(生成图像和原始图像融合结果),判别模型的输出表示输入数据来自真实图像的概率,如果输入图像为真实图像时,输出大概率,反之输出小概率. 在训练阶段,生成模型和判别模型交替迭代,固定一方的参数,更新另一方的网络权重,直到达到纳什均衡. 此时生成模型生成的图像与训练样本的真实图像具有一致的样本分布空间,可以生成与真实图像类似的新图像.

在本文实验中,生成模型舍弃了随机噪声作为输入条件约束,因为添加随机噪声会使得模型每次生成的结果不一样,这与我们的需求是不一致的. 在条件式生成对抗模型中,直接使用原始图像 x 作为模型的输入即可.

本文使用条件生成对抗模型^[6]来研究图像的增强问题,生成模型的结构为一个全卷积神经网络^[9],判别模型结构为一个二分类卷积神经网络. 在生成模型中,本文提出了连续多尺度跨连方式(successive-multiple skip connection, SMSC),使得在网络的训练和测试中,能很好地保留源图像的细节信息,提高了生成模型的准确率,在反向传播阶段,低层网络也能很好地获取高层网络传递的误差损失,降低了梯度消失的风险,加快了网络收敛的速度.




图 1 条件生成对抗网络模型

Fig. 1 Conditional generative adversarial network model

2 E-CGAN 模型

将分别从如何构建多尺度生成模型和判别模型,设计条件型对抗损失函数,对抗网络的训练过程等方面介绍 E-CGAN 神经网络模型.

2.1 生成模型结构

生成模型用来对原始图像进行处理,生成增强后的输出图像,生成过程表示为: $G:x\rightarrow y'$. 本文所使用的生成模型为一个全卷积神经网络,网络中不存在全连接层,使用全连接神经网络的好处是,可以处理任意分辨率的图像.

生成模型的结构如图 2 所示,网络一共有 16 个卷积层,每个卷积层的参数在图中标明. 在本文的任务中,要求输出图像与输入图像的大小一致,因此不使用 pooling 层;激活函数使用 Relu,卷积操作的步长为 1,避免对特征图进行下采样. 中间特征层连接采用 SMSC,将邻近层之间的特征图作通道融合,构成新的特征层. 在生成模型向前传递的过程中,由于连续多尺度跨连层的存在,特征图的个数随网络的传播而增加,例如第 1 个特征层与第 4 个特征层作通道融合,将得到维度为 128 的特征层. 以此类推,在最后的跨连层,获得维度为 512 的特征层,此特征层具有贯穿整个神经网络的丰富的特征信息,从而大大提高生成模型的准确率.




图 2 生成模型结构
Fig. 2 Generative model

在参数数量上,使用 SMSC 的方式增加了特征图的数量,而没有增加网络模型中卷积核的个数,而对于特征层中每个特征图对于卷积核的权重是一样的,因此不会增加卷积层中参数的数量,产生过拟合,相反,由于使用跨层连接的方式,可以很好地抑制深层网络梯度消失的问题.

2.2 判别模型结构

仅使用生成模型对图像进行增强,仍存在目标不唯一的问题. 例如在灰度图像着色问题中,一部分图片草地的颜色为绿色,一部分草地的颜色为黄色,使用此数据集对生成网络进行训练,很容易使得处理后的图片产生介于绿色和黄色之间的某种色彩,而并不是常见的黄色或者绿色,这与实际情况是不符合的. 引入判别模型可以对生成模型处理的图像进行分类,当生成图像具有不真实的色彩时,判别模型将输出小概率表示此生成图像与真实图像相似度较低,并向生成模型传递对抗型损失函数,调整生成模型的参数,使得生成模型能产生与真实图像一致的结果.

判别模型以图像对作为输入,以概率值作为输出,表示为: $D:(x,y)\rightarrow 1 \& \& (x,y')\rightarrow 0$. 图像对是指两幅图像作通道融合生成的结果. 例如灰度图像的着色实验中,将单通道原始灰度图像与三通道彩色图像融合生成的四通道图像. 判别模型的结构如图 3 所示,包含 5 个卷积层和两个全连接层,每个卷积层后面连接一个池化层,降低特征图的大小,便于网络的分类. 网络的结构参数在图中标明,其中输入为原输入



图 3 判别模型结构
Fig. 3 Discriminant model

图像与生成图像作通道融合的结果,或者原输入图像与对应真实图像通道融合的结果.例如在灰度图像着色的实验中,将原始灰度图像与对应彩色图像作通道融合,处理成四通道图像,可作为判别模型的一个样本.

2.3 对抗型损失函数

当仅使用生成模型对数据集进行训练时,类似于训练一个全卷积神经网络,即传统的监督式学习,生成过程表示为: $G: x \rightarrow y'$, x 表示待处理图像, y' 表示生成图像,使用 $L1$ 距离损失函数表示误差项 $\ell_{L1}(G)$,如式(1)所示.

$$\ell_{L1}(G) = E_{x, y \sim p_{data}(x, y)} [\|y - y'\|_1]. \quad (1)$$

式中, y 表示与输出图像 x 对应的真实图像, $\|y - y'\|_1$ 表示真实图像与生成图像的 $L1$ 距离,网络的训练优化过程可以表示为不断减小 $\ell_{L1}(G)$ 误差函数的过程.

现有的研究方法^[10]表明,仅使用 $L1$ 距离对图像对之间的学习能力是不足的,很容易产生模糊^[11]甚至训练失败的结果.使用判别模型对生成模型进一步调优是必要的,图1所示的模型中,生成图像与原始图像融合作为判别模型的输入,判别模型判断该图像属于真实图像的概率,并产生对抗型损失误差,反向传播到生成模型中并优化参数,对抗型损失函数如式(2)所示.

$$\ell_{GAN}(G, D) = E_{x, y \sim p_{data}(x, y)} [\text{Log} D(x, y)] + E_{x \sim p_{data}(x)} [\text{Log}(1 - D(x, G(x)))]. \quad (2)$$

式中, $D(x, y)$ 表示将输入图像与真实图像融合输入判别模型的过程, $D(x, G(x))$ 表示将输入图像与生成图像融合之后输入判别模型的过程.误差函数表示,当输入为真实图像时,尽量使得判别模型输出大几率;当输入为生成图像时,尽量使得判别模型输出小几率,从而最小化对抗型损失函数.模型以交叉训练的方式进行,首先固定判别模型 D 的参数,优化 G 的参数,然后固定 G 的参数,优化 D 的参数,交替迭代直到收敛,最终判别模型无法判断图像是来源于真实图像还是生成图像,此时生成图像与真实图像具有基本一致的数据分布空间.

本文采用 $L1$ 损失函数与对抗型损失函数结合的方式对模型训练,避免图像生成过程中细节信息的丢失,最终的损失函数如式(3)所示.

$$\ell_{data}(G, D) = \ell_{L1}(G) + \lambda \ell_{GAN}(G, D). \quad (3)$$

生成模型的最优解如式(4)所示.

$$G^* = \text{argmin}_G \max_D [\ell_{L1}(G) + \lambda \ell_{GAN}(G, D)]. \quad (4)$$

式中, λ 为固定常数,表示对抗型损失函数和 $L1$ 距离损失函数的比重,通过调整 λ 的大小可以得到不同的训练结果.

3 实验结果和分析

为了验证本文图像增强方法的有效性,在两个图像增强问题上进行实验,分别是灰度图像着色、图像清晰度增强.实验数据来源于 ILSVRC^[11]数据集.

3.1 图像清晰度增强

图像清晰度增强是将低清晰度的图像转化为高清晰度的图像,在图像放大和图像传输、去噪等方面有很好的应用.随机从 ILSVRC 数据集中抽取 20 000 张图片作为训练集,确保模型训练有较大样本;另以 1 000 张图片作为测试集,用于验证模型的有效性.所有图片分辨率被调整为 256×256 ,并使用两种方法处理图片降低清晰度:(1)直接压缩图片到较低质量;(2)对图片进行先缩小后放大操作.使用两种方法处理图片的目的是扩大训练图片集,部分实验数据如图4所示.

在生成对抗模型的训练阶段,低清晰度图像作为生成模型的输入图像 x ,高清晰度图像作为与之对应的标签图像 y ,实验在 i7-4790, GTX1060 的环境上运行,采用 Tensorflow 框架实现生成对抗模型,误差权重常数 λ 设置为 0.01,在整个数据集上训练 50 代,训练时间约为 48 h.实验结果如图5所示.

为了验证对抗型误差对实验效果的影响,在相同的环境下进行实验,将误差权重常数 λ 设置为 0,表示不使用对抗型误差作为约束条件,实验结果如图6所示,初步判断, E-CGAN 模型具有更好的视觉效果.

从测试集图像中随机抽取 50 张图像,对其计算 PSNR 和 SSIM 指标^[8,13]并统计平均值,结果如表1所示.



图 4 实验数据示例

Fig. 4 Example images in the experiement



图 5 图像清晰度增强示例

Fig. 5 Example results for image enhancement

PSNR 是较为常用的客观图像质量评价方法,通过计算生成图像和参考图像间的峰值信噪比来评价图像失真情况,值越大表示生成图像质量越高. SSIM 是目前认为最接近用户主观体验的客观质量评价指标,通过计算生成图像和参考图像的结构相似度指数实现质量评价^[14]. SSIM 值越大质量越高,且 SSIM 变化对用户体验的影响极为敏感,即使 SSIM 差值提高 0.01 都表明用户体验有明显提升^[14]. 由表 1 可知,与仅使用 $L1$ -normal 误差函数的生成模型相比,E-CGAN 模型均取得了更高的 PSNR 值和 SSIM 值,质量改善率分别达到 9.01%和 5.26%,由此可以看出 E-CGAN 效果更好.



图 6 $L1$ 损失模型和本文 E-CGAN 模型结果对比

Fig. 6 Comparison between the results on $L1$ -normal model and the proposed E-CGAN

表 1 $L1$ -normal 和本文 E-CGAN 模型结果对比

| Table 1 Comparison between the results on $L1$ -normal model and the proposed E-CGAN | | | |
|--|--------------|---------|-------|
| 均值 | $L1$ -normal | E-CGAN | 改善率/% |
| PSNR | 29.40 | 32.05 | 9.01 |
| SSIM | 0.856 3 | 0.901 3 | 5.26 |

另外,将本文算法与直方图均衡图像增强模型^[12](histogram equalization approach,HEA)、超像素网格图像增强模型^[15](superpixel reseau,S-R)以及残差神经网络图像增强模型^[16](residual enhancement,R-E)进行对比,如图 7 所示,在测试图像上统计其增强后图像的 PSNR 和 SSIM 值,结果如表 2 所示. 从结果可以看出,本文模型的图像评价指标高于其他模型,从而证明了本文模型的图像增强质量更高.

表 2 4 种模型(HEA,S-R,R-E,E-CGAN)的图像增强指标比较

| Table 2 Comparison between image enhancement indexes with the four models(HEA ,S-R,R-E,E-CGAN) | | | | |
|---|---------|---------|---------|---------|
| 均值 | HEA | S-R | R-E | E-CGAN |
| PSNR | 27.32 | 29.38 | 30.54 | 32.05 |
| SSIM | 0.792 7 | 0.856 2 | 0.877 3 | 0.901 3 |



图7 4种模型(HEA, S-R, R-E, E-CGAN)增强效果对比

Fig. 7 Comparison between image enhancement results with the four models(HEA, S-R, R-E, E-CGAN)

3.2 灰度图像着色

灰度图像着色问题也是图像增强中的经典问题^[2,12]. 灰度图像着色的过程就是补充色彩信息的过程, 将单通道图像转化为三通道图像. 在着色的过程中, 需要利用灰度图像的语义信息和纹理信息生成色彩信息. 实验数据扩充至 100 000 张图像, 并将图像分辨率统一调整为 256×256 . 彩色图像使用式(5)处理得到灰度化的图像.

$$Gray = R \times 0.229 + G \times 0.587 + B \times 0.114. \quad (5)$$

式中, $Gray$ 表示灰度图像, R, G, B 分别表示彩色图像的三通道颜色值, 将处理得到的灰度图像作为生成模型的输入图像, 彩色图像作为与之对应的标签图像, 在同样的环境下进行实验, 对整个样本训练 20 代, 训练时间约为 100 h, 实验结果如图 8 所示.



图8 灰度图像着色示例

Fig. 8 Results on image colorization

从图 8 可以看出, 着色后的图像与自然场景非常类似, 具有很好的视觉效果, 尽管生成图像与源图像之间存在少许颜色不一致的情况, 但仍然可以满足大部分应用需求. 当然, 如果能借鉴传统图像着色方法的思路, 加入少量人工交互, 可以避免颜色不一致的问题. 另外, 本文方法还可以进一步扩展, 将图像从 RGB 颜色空间转换到 LAB 空间进行训练, 可以消除颜色通道之间的相关性, 图像质量会更好.

3.3 实验结果比较与分析

为验证实验中 $L1$ 距离损失函数的必要性, 设计不包含 $L1$ 损失函数的网络模型, 即生成对抗网络仅使用对抗型生成函数进行调优, 此时最优化生成模型如式(6)所示.

$$G^* = \operatorname{argmin}_G \max_D \ell_{\text{GAN}}(G, D). \quad (6)$$

在相同的环境下进行实验, 实验结果如图 9 所示, 此模型收到了失败的结果, 表示生成模型不收敛. 对判别模型进行单独测试, 使用 100 张真实图像对和 100 张生成图像对(随机选取训练过程中间产生的具有明显轮廓的图像)构成的小数据集, 判别模型准确率达到 100%, 表示判别模型很好的收敛. 极大的可能性在于, 在生成对抗模型的训练过程中, 判别模型过早地拟合, 导致输出层产生的误差饱和, 经过

sigmoid 计算的误差过小,反向传播的梯度逐渐消失,最后训练失败. 在很多的生成对抗模型中,使用减缓判别模型拟合速度的方法来控制训练,一般需要进行大量的实验反复的调整参数. 在本文的实验中,加入 *L1* 距离损失函数,对生成模型构造 *L1* 约束条件,在训练的过程中,即使判别模型过早地拟合,也可以通过 *L1* 损失函数优化生成模型,从而降低判别模型的准确率,避免产生误差饱和.

为验证连续多尺度跨连层对生成模型效果的影响. 额外设计两个类似的生成网络模型:第一个生成模型不包含跨连层,称为无跨连层 E-CGAN;第二个生成模型去掉第四个跨连层,消除跨连层的连续性,称为部分跨连层 E-CGAN. 在相同的环境下进行实验,图 10 所示为实验结果.



输入图像 生成图像
图 9 不包含 *L1* 损失函数的失败结果
Fig. 9 Failure result without *L1* loss



图 10 不同连接方式生成模型的结果对比
Fig. 10 Comparison between results on different connective generative models

图 10 中,(a)表示原始输入图像;(e)为真实高清晰度图像;(b)、(c)分别为新设计的两个无跨连层 E-CGAN 和部分跨连层 E-CGAN 模型生成的结果图;(d)为包含了连续多尺度跨连层的 E-CGAN 模型的生成结果图像. (b)效果与原始输入图像对比,甚至出现更差的效果,PSNR 值和 SSIM 值更低;(c)的部分区域特别是背景部分出现较明显的质量失真;(d)从数据和视觉对比观察,加入 SMSC 的 E-CGAN 模型都取得了更好的图像增强效果.

4 结语

本文提出的 E-CGAN 方法可以较好地解决自然图像增强问题,尤其适合一些变换复杂、增强效果要求较高的应用. 通过图像质量增强和图像着色问题的实验验证,E-CGAN 方法均取得了较好的增强效果,且平均质量更高. E-CGAN 为自然图像增强提供了新思路,进一步的研究工作还将尝试解决更多的图像增强应用^[17],如图像去雾、图像恢复、图像去马赛克等,针对性地设计符合该类应用的优化网络结构和损失函数模型.

[参考文献]

[1] REINHARD E,ASHIKHMIN M,GOOCH B,et al. Color transfer between images[J]. IEEE computer graphics & applications, 2002,21(5):34-41.

[2] WELSH T,ASHIKHMIN M,MUELLER K. Transferring color to greyscale images[J]. ACM Frans Graph,2002,21(3): 277-280.

[3] PANETTA K,WHARTON E J,ZHOU Y,et al. Parameterized logarithmic framework for image enhancement[J]. IEEE trans- actions on systems,man,and cybernetics,Part B:cybernetics,2011,41(2):460-473.

[4] ZHANG Q,NIE Y,ZHANG L,et al. Underexposed video enhancement via perception-driven progressive fusion[J]. IEEE transactions on image processing,2016,22(6):1773-1785.

[5] GOODFELLOW I J,POUGET A J,MIRZA M,et al. Generative adversarial nets[C]//2014 International Conference on Neural Information Processing Systems. Canada:MIT Press,2014:2672-2680.

[6] CRESWELL A,WHITE T,DUMOULIN V,et al. Generative adversarial networks:an overview[J]. IEEE signal processing

- magazine, 2018, 35(1):53–65.
- [7] DENTON E, CHINTALA S, SZLAM A, et al. Deep generative image models using a laplacian pyramid of adversarial networks[C]//2015 Advances in Neural Information Processing Systems(NIPS). Canada:ACM, 2015:1486–1494.
- [8] GUPTA P, SRIVASTAVA P, BHARDWAJ S, et al. A modified PSNR metric based on HVS for quality assessment of color images[C]//2011 International Conference on Communication and Industrial Application. Kolkata, West Bengal:IEEE, 2012:1–4.
- [9] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Boston, Ma:IEEE, 2015:3431–3440.
- [10] PATHAK D, KRAHENBUHL P, DONAHUE J, et al. Context encoders:feature learning by inpainting[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR). NV:IEEE, 2016:2536–2544.
- [11] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge[J]. International journal of computer vision, 2015, 115(3):211–252.
- [12] CHENG Z, YANG Q, SHENG B. Deep colorization[C]//IEEE International Conference on Computer Vision. Santiago:IEEE, 2015:415–423.
- [13] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment:from error visibility to structural similarity[J]. IEEE transactions on image processing, 2004, 13(4):600–612.
- [14] CHENG H D, SHI X J. A simple and effective histogram equalization approach to image enhancement[J]. Digital signal processing, 2004, 14(2):158–170.
- [15] YAN Z, ZHANG H, PARIS S, et al. Automatic photo adjustment using deep neural networks[J]. Acm transactions on graphics, 2016, 35(2):11.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas, NV:IEEE, 2016:770–778.
- [17] CHAI C, LIAO J, ZOU N, et al. A one-to-many conditional generative adversarial network framework for multiple image-to-image translations[J]. Multimedia tools and applications. 2018, 77(17):22339–22366.

[责任编辑:黄 敏]