

基于 CycleGAN 的低照度人脸图像增强

朱克亮¹, 张天忠², 石雪梅¹, 张树涛^{3,4}, 陈良锋³

(1. 国网安徽省电力有限公司建设分公司, 安徽 合肥 230022;

2. 国网安徽省电力有限公司, 安徽 合肥 230061;

3. 中国科学院合肥物质科学研究院, 安徽 合肥 230026;

4. 中国科学技术大学, 安徽 合肥 230031)

摘要:人脸识别系统经常会受到光照环境的影响。为了提高低照度条件下的人脸识别性能,提出了一种基于循环生成对抗网络的低照度人脸图像增强方法,利用循环生成对抗网络将低照度条件下的人脸图像转换成正常光照下的人脸图像。模型包含生成器和判别器,生成器由包含4个卷积层、9个残差网络层和2个转置卷积层的卷积神经网络组成,判别器由包含5个卷积层的卷积神经网络组成。在循环生成对抗网络训练的过程中,采用改进的损失函数,并结合梯度惩罚项来训练网络模型,提升了稳定性,加快了网络收敛速度,并且提高了生成人脸图像的质量。在 VV 数据集上的实验结果表明,该方法能够有效地实现低照度条件下的人脸图像增强,对比 HE、MSR 和 MSRCR 算法在 PSNR、SSIM 和 MSE 指标上有较大提高。

关键词:循环生成对抗网络;图像增强;低照度;梯度惩罚;深度学习

中图分类号:TP311.5

文献标识码:A

文章编号:1673-629X(2021)11-0095-06

doi:10.3969/j.issn.1673-629X.2021.11.016

Low Illumination Face Image Enhancement Based on CycleGAN

ZHU Ke-liang¹, ZHANG Tian-zhong², SHI Xue-mei¹, ZHANG Shu-tao^{3,4}, CHEN Liang-feng³

(1. State Grid Anhui Electric Power Co., Ltd. Construction Company, Hefei 230022, China;

2. State Grid Anhui Electric Power Co., Ltd., Hefei 230061, China;

3. Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230026, China;

4. University of Science and Technology of China, Hefei 230031, China)

Abstract: Face recognition systems are often affected by the lighting environment. To improve the performance of face recognition under low illumination conditions, a low illumination face image enhancement method based on cycle-consistent adversarial network is proposed. The network that consists of generators and discriminators is used to transfer low illumination face images to normal illumination face images. The generators consist of convolutional neural networks with four convolution layers, nine residual network layers and two transposed convolution layers, and the discriminators consist of convolutional neural networks with five convolution layers. In the training process of the cycle-consistent adversarial network, the improved loss function and the gradient penalty are used to train the network, which improves the stability, speeds up the network convergence and improves the quality of the generated face image. Experimental results on VV dataset show that the proposed method can effectively achieve face image enhancement under low illumination conditions, and compared with HE, MSR and MSRCR, it improves PSNR, SSIM and MSE values.

Key words: cycle generative adversarial networks; image enhancement; low illumination; gradient penalty; deep learning

0 引言

随着深度学习的不断发展,人脸识别系统的准确率越来越高,其被广泛应用于安防监控、自助终端、社交和娱乐等领域。但在实际应用场景中,人脸识别的

准确率往往会受到光照、表情、遮挡、人脸姿势等各种因素的影响,其中光照环境的影响尤为严重。由于环境光照变化的影响,使得现有大部分人脸识别方法在实际应用中受到很大的限制,在恶劣情况下(例如光

收稿日期:2020-12-28

修回日期:2021-04-28

基金项目:国家电网公司科技项目(B3120A190005)

作者简介:朱克亮(1964-),男,高级工程师,研究方向为电力系统、信息技术;通信作者:陈良锋(1985-),男,博士,工程师,研究方向为人工智能、机器视觉。

照不足)常导致人脸识别失败。

为了提高低照度条件下人脸识别系统的性能,研究者通常采用图像增强算法对人脸图像进行光照调整或补偿,增强图像对比度。例如传统的图像增强方法采用直方图均衡化(histogram equalization, HE)^[1]调整图像的灰度值,使其均匀分布在图像灰度空间。Zhou 等人^[2]提出了基于 HE 的全局亮度和局部对比度的低照度图像增强方法。Lin 等人^[3]改进 He 方法用于提高低照度图像的对比度。还有研究者提出了基于 Retinex 理论^[4-6]的图像增强方法,例如 Jobson 等人^[7]提出了单尺度色彩恢复的 Retinex 算法(single-scale retinex, SSR),其采用高斯环绕函数对图像的三个色彩通道进行滤波,然后将原始图像与滤波后的图像相减得到增强后的图像。之后该研究者又提出了多尺度色彩恢复算法(multi-scale retinex, MSR)和带色彩恢复的 MSR 算法(multi-scale retinex with color restoration, MSRCR)^[8]。近年来,深度学习技术被广泛应用于各种图像领域^[9-11],也有很多研究者提出了基于深度学习的图像增强方法。例如 Lore 等人^[12]首次采用深度学习解决图像增强,其训练深度自动编码器来学习低照度图像特征和自适应地提高亮度。Li 等人^[13]提出了卷积神经网络(CNN)图像增强方法,将低照度图像作为网络输入,然后将输出的结果利用 Retinex 模型进行图像增强。Liu 等人^[14]采用卷积自编码网络学习低照度图像特征和图像增强。Tao 等人^[15]在卷积神经网络中加入了残差学习提高图像增强的效果。

不同于以上的方法,文中从图像生成的角度解决现实人脸识别场景下的光照过暗的问题,提出一种基于循环生成对抗网络的低照度人脸图像增强方法。利用循环生成对抗网络提取低照度人脸图像的底层特征,调整图像的亮度,并且保持生成的人脸图像的真实性。同时针对生成对抗网络在训练过程中的收敛问题,对网络模型的损失函数进行改进,加入了梯度惩罚项以稳定网络模型的训练,提高了图像生成的效果,使得增强后的人脸图像更加接近于正常光照条件下的真实人脸图像。

1 相关理论

1.1 生成对抗网络

生成对抗网络(generative adversarial network, GAN)由 Goodfellow 等人^[16]在 2014 年提出,其由一个生成器和一个判别器组成。生成器负责从随机噪声学习真实图像样本的分布并输出与真实样本分布相同或者相似的图像,判别器负责判断生成的图像和真实图像是否为真实的样本分布,并将结果反馈给生成器和

判别器自身,对生成器和判别器的参数进行优化,通过生成器和判别器的博弈过程达到全局最优。在生成对抗网络的训练阶段,首先固定判别器的参数,调整生成器的参数使得判别器的判别结果为真实样本,然后固定生成器的参数,调整判别器的参数使得判别器将生成器的输出结果判别为假样本,而真实样本判别为真实样本。重复进行交替训练,此过程的优化目标如下:

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

其中, G 为生成器, D 为判别器, x 为真实图像样本, z 为随机噪声, $G(z)$ 为生成器输出的图像, $P_{\text{data}}(x)$ 为真实图像的分布, $P_z(x)$ 为噪声分布。

近年来, GAN 及其变体在计算机视觉领域取得巨大的成功,在图像生成、图像修复、图像增强等方面取得了令人瞩目的成绩,弥补了传统方法的不足。但是 GAN 在训练的过程中会存在梯度消失、模式崩溃等问题。Mao 等人^[17]提出了最小二乘生成对抗网络(LSGAN),使用最小二乘损失函数取代原始的 GAN 的损失函数,解决了 GAN 训练不稳定的问题。Arjovsky 等人^[18]提出了 Wasserstein GAN(WGAN),使用 Wasserstein 距离代替 JS 散度来衡量生成样本分布与真实样本分布之间的差异,缓解了出现梯度消失的问题。Gulrajani 等人^[19]提出了 WGAN-GP,增加梯度惩罚项来限制判别器的梯度,使得 WGAN 的训练过程更加稳定,保证了生成样本的质量。

1.2 CycleGAN

循环生成对抗网络(cycle generative adversarial network, CycleGAN)是 GAN 的一种变体,在 2017 年由 Zhu 等人^[20]提出,由两个 GAN 组成,即包含两个生成器和两个判别器。与 GAN 不同的是, CycleGAN 的输入是图像,而不是随机噪声,其实现图像在不同域之间的转换,例如将马转换成斑马,风景图像转换成油画等。CycleGAN 学习两个映射 $X \rightarrow Y$ 和 $Y \rightarrow X$, 生成器将图像从 X 域转换到 Y 域,判别器判断生成的图像是否是真实的 Y 域图像,同理,生成器将图像从 Y 域转换到 X 域,判别器判断生成的图像是否是真实的 X 域图像。为了保证生成图像样本的多样性,引入循环一致性损失函数,将转换到目标域后的图像再转换回源域,构成了一个双向环状结构。CycleGAN 不需要成对的数据集进行训练,应用十分广泛。例如 Wu 等人^[21]提出了一种基于 CycleGAN 的卡通人脸生成模型,其输入是正常人脸图像,输出为卡通风格的图像,采用全局判别器和局部判别器提高生成的卡通人脸图像质量。Lu 等人^[22]提出了条件 CycleGAN 用于超分辨率重建,从低像素的图像生成高像素的图像,并且可以根据输

入参数控制生成人脸的属性。Engin 等人^[23]采用改进的 CycleGAN 对图像进行去雾,加入循环感知一致性损失保证图像的清晰度。

2 基于 CycleGAN 的低照度人脸图像增强

2.1 低照度图像增强模型

给定一个数据集 $U \in \{X, Y\}$, 由低照度人脸图像和正常光照下的人脸图像对组成。文中采用 CycleGAN 将其中的低照度人脸图像转换成正常光照下的人脸图像,其模型如图 1 所示。生成器 G_1 的输入

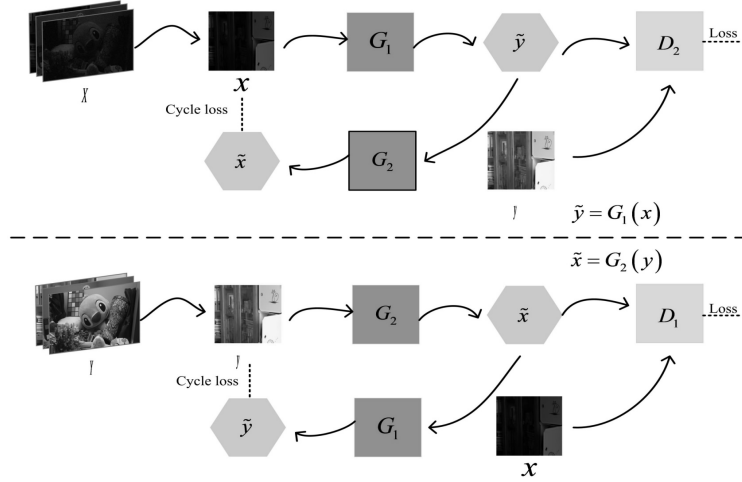


图 1 基于 CycleGAN 的低照度人脸图像增强模型

生成器 G_1 和 G_2 包含 3 个卷积层、9 个残差网络层、2 个转置卷积层和 1 个卷积层,如图 2 所示。第一个卷积层 Conv 1 和最后一个卷积层 Conv 4 的卷积核大小为 7×7 ,步长为 2。卷积层 Conv 2 和 Conv 3 的卷积核大小为 3×3 ,步长为 1。转置卷积层 Deconv1 和 Deconv2 的卷积核大小为 3×3 ,步长为 2。每个残差网络层有两个卷积操作,其卷积核大小均为 3×3 ,步长均为 1。在每个卷积结束后都对卷积结果进行实例归一化,以及采用 LeakyReLU 作为激活函数。




图 2 生成器结构




图 3 判别器结构

判别器 D_1 和 D_2 包含 5 个卷积层,如图 3 所示。前 4 个卷积层的卷积核大小为 4×4 ,步长为 2,最后一

是低照度人脸图像 $x \in X$,输出为生成的正常光照下的人脸图像 \tilde{y} 。生成器 G_2 的输入是正常光照下的人脸图像 $y \in Y$,输出为生成的低照度下的人脸图像 \tilde{x} 。其过程表示为:

$$\tilde{y} = G_1(x), \tilde{x} = G_2(y) \quad (2)$$

而判别器 D_1 判断生成的图像 \tilde{x} 是否属于真实的低照度人脸图像,判别器 D_2 判断生成的图像 \tilde{y} 是否属于真实的正常光照下的人脸图像。在训练过程中,生成器和判别器不断进行对抗,最终使得生成器输出的图像接近于真实人脸图像。

个卷积层的卷积核大小为 4×4 ,步长为 1。前 4 个卷积层在每个卷积结束后都对卷积结果进行实例归一化,以及采用 LeakyReLU 作为激活函数。

2.2 损失函数

为了学习式 (2) 中的两个映射,对生成器和判别器进行交替训练,每次训练中将生成器和判别器的损失函数的梯度传递回生成器和判别器进行网络参数的优化。

其中生成器的损失函数为:

$$L_{G_1} = -\log D_2(G_1(x)) + \lambda L_{\text{cycle}} \quad (3)$$

$$L_{G_2} = -\log D_1(G_2(y)) + \lambda L_{\text{cycle}} \quad (4)$$

其中, $D_2(G_1(x))$ 表示生成器 G_1 生成的图像是正常光照下的图像的概率, $D_1(G_2(y))$ 表示生成器 G_2 生成的图像是低照度图像的概率。此损失函数由两部分组成,第一项为生成器的交叉熵损失,对于生成器 G_1 保证生成的人脸图像接近真实的正常光照下的人脸图像,对于生成器 G_2 保证生成的人脸图像接近真实的低光照下的人脸图像;第二项为循环一致性损失,保证生成器 G_1 生成的人脸图像能够经过生成器 G_2 还原成原始低照度图像,即 $G_2(G_1(x)) \approx x$,同理,生成器 G_2 生成的人脸图像能够经过生成器 G_1 还原成原始正常照度下的人脸图像,即 $G_1(G_2(y)) \approx y$ 。循环一致性损失表示为:

$$L_{\text{cycle}} = \|G_2(G_1(x)) - x\|_1 + \|G_1(G_2(y)) - y\|_1 \quad (5)$$

判别器的损失函数为:

$$L_{D_1} = -\log(D_1(G_2(y)) - 1) - \log D_1(x) + \gamma p_1 \quad (6)$$

$$L_{D_2} = -\log(D_2(G_1(x)) - 1) - \log D_2(y) + \gamma p_2 \quad (7)$$

其中, $D_1(x)$ 表示输入的低照度图像是真实低照度图像的概率, $D_2(y)$ 表示输入的正常光照下的图像是真实正常光照下的图像的概率。 x 为低照度条件下的人脸图像, y 为对应的正常光照下的人脸图像, γ 为惩罚项系数。 p_1 和 p_2 为梯度处罚函数, 分别表示为:

$$p_1 = (\|\nabla D_1(x + \alpha(x - G_2(y)))\|_2 - 1)^2 \quad (8)$$

$$p_2 = (\|\nabla D_2(y + \alpha(y - G_1(x)))\|_2 - 1)^2 \quad (9)$$

其中, ∇ 表示判别器 D_1 和 D_2 的梯度, α 表示均匀分布 $[0, 1]$ 之间的随机数。

2.3 算法流程

基于 CycleGAN 的低照度人脸图像增强方法的步骤如下:

输入: 低照度人脸图像和正常光照人脸图像;

输出: 生成器 G_1 和低照度对应的正常光照人脸图像。

步骤 1: 图像预处理, 将输入的低照度人脸图像和正常光照人脸图像裁剪成相同像素大小 $\Phi(x) \in R^{h \times w \times 3}$, 其中 x 为输入的低照度人脸图像或正常光照人脸图像, $\Phi(x)$ 为预处理后的人脸图像, h 和 w 分别为图像的高度和宽度, 并且对像素值的取值范围进行归一化;

步骤 2: 训练生成器 G_1 , 固定判别器 D_2 的网络参数不变, 采用 Adam 优化生成器的损失函数 L_{G_1} ;

步骤 3: 训练生成器 D_2 , 固定生成器 G_1 的网络参数不变, 采用 Adam 优化判别器的损失函数 L_{D_2} ;

步骤 4: 训练生成器 G_2 , 固定判别器 D_1 的网络参数不变, 采用 Adam 优化生成器的损失函数 L_{G_2} ;

步骤 5: 训练生成器 D_1 , 固定生成器 G_2 的网络参数不变, 采用 Adam 优化判别器的损失函数 L_{D_1} ;

步骤 6: 重复步骤 2 到步骤 5, 直到达到设置的迭代次数。

3 实验结果与分析

3.1 实验环境配置

文中的实验硬件环境配置为 Intel(R) Xeon(R) CPU, 32 GB 内存, 显卡 NVIDIA TITAN Xp 12 GB, 500 GB 固态硬盘和 2 TB 磁盘。软件环境配置为 Ubuntu 16.04, Cuda 9.0 GPU 并行计算库, 模型训练工具采用

TensorFlow-GPU 1.6.0。生成对抗网络模型训练的 batch size 设置为 10, 学习率为 0.000 2, 采用 Adam 优化器, 其衰减率为 0.5, 生成器和判别器的损失函数的损失项参数 λ 设置为 10, γ 设置为 10。

3.2 数据集

数据集采用低光照图像数据集 VV dataset^[24], 其中包括 789 张低照度图像和对应的 789 张正常光照下的图像, 所有图像都为 PNG 格式, 像素大小统一裁剪为 256×256。

3.3 评价指标

为了验证文中方法的有效性, 采用结构相似度(SSIM)、均方误差(MSE)和峰值信噪比(PSNR)作为评价指标, 对生成的正常光照下的人脸图像进行图像质量评价。

SSIM 反映两幅图像结构上的相似度, 取值范围为 0 ~ 1, SSIM 值越大, 说明图像的结构越相似, 公式为:

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (10)$$

其中, x 为增强后的图像, y 为正常光照下的图像, μ_x 为图像 x 的像素平均值, μ_y 为图像 y 的像素平均值, σ_{xy} 为 x 和 y 的协方差, σ_x^2 为图像 x 的方差, σ_y^2 为图像 y 的方差, c_1 和 c_2 为常数, 取 $c_1 = 0.000 1$, $c_2 = 0.000 9$ 。

MSE 为两幅图像之间的均方误差值, MSE 值越小, 说明两幅图像越相似, 公式为:

$$\text{MSE} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |R(i, j) - F(i, j)|^2 \quad (11)$$

其中, M 为图像的高度, N 为图像的宽度, $R(i, j)$ 为正常光照下的图像第 i 行第 j 列的灰度值, $F(i, j)$ 为增强后的图像第 i 行第 j 列的灰度值。

PSNR 是图像处理中信号重建质量的评价指标, PSNR 值越大, 说明图像失真越小, 图像的重建质量越高, 公式如下:

$$\text{PSNR} = 10 \log \frac{(2^n - 1)^2}{\text{MSE}} \quad (12)$$

其中, n 为图像像素的比特数, MSE 为均方误差。

3.4 结果与分析

文中将 VV dataset 中的低照度图像和对应的正常光照下的图像输入 CycleGAN 中进行训练, 得到修复后的无遮挡人脸图像, 如图 4 所示。

图中第 1 列为低照度条件下的人脸图像, 后面 4 列为分别采用 HE、MSR、MSRCR 和文中算法增强后的人脸图像。可以看出文中算法生成的对抗网络模型能够有效地对低照度条件下的人脸图像进行图像增强, 生成接近真实的正常光照下的人脸图像。相比较而言, HE 算法得到的图像出现局部亮度过曝, MSR 算

法得到的增强图像出现颜色失真,整体色彩偏红,MSRCR 算法得到的图像同样存在局部细节色彩失真

的问题,文中算法得到的图像更加接近于真实场景下的人脸图像。




图 4 人脸图像修复效果图

分别采用式(10)~式(12)对生成的人脸图像进行比较,结果如表 1 所示。行图像质量评价,并且与 HE、MSR 和 MSRCR 算法进

表 1 不同方法的评价指标对比

方法	SSIM	MSE	PSNR
HE	0.481 2	1 978.70	19.94
MSR	0.492 7	10 469.96	12.70
MSRCR	0.411 3	9 178.16	13.28
文中	0.576 5	518.69	25.75

从表 1 中可以看出,文中方法相比 HE、MSR 和 MSRCR 算法在增强后的图像质量方面有较大提升。文中方法在 SSIM 指标上相比 HE 算法提高了 0.095 3,相比 MSR 算法提高了 0.083 8,相比 MSRCR 算法提高了 0.165 2,平均提升了约 25.66%。在 MSE 指标上相比 HE 算法降低了 1 460.01,相比 MSR 算法降低了 9 951.27,相比 MSRCR 算法降低了 8 659.47,平均优化了约 87.73%。在 PSNR 指标上相比 HE 算法提高了 5.81,相比 MSR 算法提高了 13.05,相比 MSRCR 算法提高了 12.47,平均提升了约 75.26%。因此,文中方法的图像失真相对较小,与正常光照场景下的图像相似度更高。

4 结束语

针对低照度条件下人脸识别系统准确率低的问题,提出了一种基于循环生成对抗网络的低照度人脸图像增强方法,其主要贡献在于:

(1)将 CycleGAN 用于人脸图像增强,相比于传统方法,CycleGAN 生成的图像效果更加真实,与其他深度学习方法相比,CycleGAN 不需要成对的数据集进行训练;

(2)通过改进 CycleGAN 的损失函数,能够有效地稳定网络的训练过程;

(3)实验表明,文中方法能够将低照度条件下的

人脸图像转换成正常照度下的人脸图像,并且保证转换后的人脸图像在结构、亮度和色彩上更加接近于真实场景下的图像。

参考文献:

- [1] 吴成茂.直方图均衡化的数学模型研究[J].电子学报,2013,41(3):598-602.
- [2] ZHOU Z,SANG N,HU X. Global brightness and local contrast adaptive enhancement for low illumination color image [J]. Optik,2014,125(6):1795-1799.
- [3] LIN S C F,WONG C Y,RAHMAN M A,et al. Image enhancement using the averaging histogram equalization (AVHEQ) approach for contrast improvement and brightness preservation [J]. Computers & Electrical Engineering, 2015,46:356-370.
- [4] 马 康,崔子冠,干宗良,等.基于图像融合策略的 Retinex 背光图像增强算法[J].计算机技术与发展,2017,27(8):73-78.
- [5] 刘佳敏,何 宁,尹晓杰.基于 Retinex-UNet 算法的低照度图像增强[J].计算机工程与应用,2020,56(22):211-216.
- [6] 谢凤英,汤 萌,张 蕊.基于 Retinex 的图像增强方法综述[J].数据采集与处理,2019,34(1):1-11.
- [7] JOBSON D J,RAHMAN Z. Properties and performance of a center/surround Retinex [J]. IEEE Transactions on Image Processing,1997,6(3):451-462.

- [8] JOBSON D J, RAHMAN Z. 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.
- [9] 田 莹, 王 亮, 丁 琪. 基于深度学习的图像语义分割方法综述[J]. 软件学报, 2019, 30(2):440-468.
- [10] 郑远攀, 李广阳, 李 晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12):20-36.
- [11] 孙 旭, 李晓光, 李嘉峰, 等. 基于深度学习的图像超分辨率复原研究进展[J]. 自动化学报, 2017, 43(5):697-709.
- [12] LORE K G, AKINTAYO A, SARKAR S. LLNet: a deep autoencoder approach to natural low-light image enhancement[J]. Pattern Recognition, 2015, 61:650-662.
- [13] LI C, GUO J, PORIKLI F, et al. LightenNet: a convolutional neural network for weakly illuminated image enhancement[J]. Pattern Recognition Letters, 2018, 104:15-22.
- [14] LIU C, ZHANG X H. Deep convolutional autoencoder networks approach to low-light level image restoration under extreme low-light illumination[J]. Optics and Precision Engineering, 2018, 26(4):951-961.
- [15] TAO L, ZHU C, XIANG G Q, et al. LLCNN: a convolutional neural network for low-light image enhancement[C]//Proceedings of 2017 IEEE visual communications and image processing. St. Petersburg, FL, USA: IEEE, 2017:1-4.
- [16] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 27th international conference on neural information processing systems. Cambridge, MA: MIT Press, 2014:2672-2680.
- [17] MAO X D, LI Q, XIE H R, et al. Least squares generative adversarial networks[C]//Proceedings of the IEEE international conference on computer vision (ICCV). Venice, Italy: IEEE, 2017:2794-2802.
- [18] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[J]. Neural Information Processing Systems Foundation, 2017(12):5768-5778.
- [19] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein GANs[C]//Proceedings of the 31st international conference on neural information processing systems (NIPS). Long Beach, California, USA: [s. n.], 2017:5769-5779.
- [20] ZHU J Y, ISOLA P, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA: IEEE, 2017:5967-5976.
- [21] WU R, GU X, TAO X, et al. Landmark assisted CycleGAN for cartoon face generation[J]. arXiv:1907.01424, 2019.
- [22] LU Y, TAI Y W, TANG C K. Attribute-guided face generation using conditional CycleGAN[C]//Proceedings of the European conference on computer vision (ECCV). Berlin, German: Springer, 2018:293-308.
- [23] ENGIN D, GENC A, EKENEL H K. Cycle-dehaze: enhanced CycleGAN for single image dehazing[C]//Proceedings of the IEEE conference on computer vision and pattern recognition workshops. Salt Lake City, UT, USA: IEEE, 2018:825-833.
- [24] VONIKAKIS V, KOUSKOURIDAS R, GASTERATOS A. On the evaluation of illumination compensation algorithms[J]. Multimedia Tools and Applications, 2018, 77(8):9211-9231.