

基于生成对抗网络的 QR 码去模糊算法

林凡强, 陈柯成, 陈丹蕾, 杨斯涵, 陈凡曾
(成都理工大学, 成都 610059)

摘要: **目的** 针对包装产品上 QR 码在采集过程中的运动模糊、失焦模糊, 长期磨损形成的自模糊和环境中的噪声等因素, 导致 QR 码无法识别的问题, 提出一种基于生成对抗网络的 QR 码去模糊算法。**方法** 采用深度学习模型生成对抗网络对模糊核和环境噪声具有的强大拟合和估计能力, 提取模糊 QR 码图像与真实图像的深层特征和差距, 并通过生成器与判别器不断迭代对抗, 使生成器具有由输入的模糊 QR 码产生与之对应的去模糊 QR 码图像的能力。**结果** 生成器能较好地对模糊核和环境噪声进行估计, 而且能够实现对数据集内多种不同模糊程度 QR 码的去模糊, 去模糊 QR 码图像效果较好, 处理时间快, 识别率较高。**结论** 采用基于生成对抗网络的 QR 码去模糊算法能够广泛应用于包装产品外壳上 QR 码的预处理过程, 泛化能力较好, 能有效提高扫描识别率。

关键词: 深度学习; 生成对抗网络; QR 码; 去模糊

中图分类号: TS206 **文献标识码:** A **文章编号:** 1001-3563(2018)21-0222-07

DOI: 10.19554/j.cnki.1001-3563.2018.21.038

QR Code Deblur Algorithm Based on Generative Adversarial Network

LIN Fan-qiang, CHEN Ke-cheng, CHEN Dan-lei, YANG Si-han, CHEN Fan-zeng
(Chengdu University of Technology, Chengdu 610059, China)

ABSTRACT: Aiming that QR codes on shell packaging products in the process of collecting, motion blur, out-of-focus blur caused by long exposure and wear the fuzzy and environmental factors such as noise, QR code can't identify the problem, the paper aims to put forward a kind of QR codes to fuzzy algorithm based on generative adversarial network. Adversarial network generated by deep learning model had strong fitting and estimation ability on fuzzy core and environmental noise. Deep characteristics and the gap between fuzzy QR code images and real images were extracted. Through constant iterative against generator and discriminator, the generator had the ability of deblurring QR codes of different fuzzy degrees in the dataset. The generator could estimate the fuzzy core and environmental noise well and deblur multiple kinds of QR codes. It was featured with good effect, fast treatment, and high recognition rate on deblurring QR code images. The QR code deblur algorithm based on generative adversarial network can be widely used in the preprocessing of QR codes on the packaging product case and improve the scanning recognition rate.

KEY WORDS: deep learning; generative adversarial network; QR code; deblur

近年来, QR 码因其具有快速响应、信息承载量大等特点, 被广泛应用于移动支付、仓储物流、产品包装等领域^[1-2]。由于相机扫描过程中存在运动模糊、失焦模糊等问题, 包装产品外壳上 QR 码长期暴露和磨损易造成自模糊, 图像采集过程中的环

境噪声等, 导致 QR 码无法正常识别, 大大降低了用户体验和识别率, 所以有必要对采集到的模糊 QR 码图像进行去模糊处理, 以提高包装外壳上的 QR 码识别率。

目前, 已有多种方法被应用于模糊 QR 码图像的

收稿日期: 2018-06-12

基金项目: 成都理工大学 2016 年人才培养质量与教学改革项目 (201629); 成都理工大学 2018 年度大学生课外科技立项项目 (2018KJC0398)

作者简介: 林凡强 (1978—), 男, 硕士, 成都理工大学副教授, 主要研究方向为信号与信息处理、电子信息科学与技术。

通信作者: 陈柯成 (1996—), 男, 成都理工大学本科生, 主攻图像的智能化处理。

去模糊。涂丹等提出了通过模糊图像的边缘响应计算得到 PSF 函数,再进行图像恢复的方法,该方法较为快速,但是难以实现大量、多种类的 QR 码去模糊^[3]。李人哲等^[4]提出基于图像峰值特点的 NAS-RIF 去模糊算法,但该算法工作量较大。同时,对图像模糊核的估计思路被广泛应用,如杜菲等利用强度和梯度先验的 L0 正则化方法对模糊核尺寸进行估计,实现了模糊 QR 码的去模糊,但计算较为复杂而且没有考虑环境噪声^[5]。卷积神经网络由于其具有强大的深层特征提取能力^[6],也被应用于模糊核的估计,如 Sun 等使用 CNN 对模糊核进行估计,实现对运动模糊图像的去模糊^[7]。较为复杂和多样本情况下对模糊核和随机噪声的估计较为困难。因深度学习具有强大的拟合和对数据集深层特征的提取能力而被广泛应用^[8],所以文中提出一种基于深度学习模型生成对抗网络的 QR 码去模糊算法。该算法通过生成对抗网络的生成器和判别器进行迭代对抗,将整体损失和细节损失设置为损失函数,迫使模型执行 QR 码去模糊任务,并对数据集中模糊 QR 码的模糊核和环境噪声进行估计,使训练好的生成器具有对模糊 QR 码去模糊的能力,即将模糊 QR 码输入到生成器就可产生相应的去模糊图像。同时实现单一模型对多种类 QR 码的去模糊,模型固化后响应速度快、泛化能力较好。

1 基于生成对抗网络的 QR 码去模糊算法

1.1 生成对抗网络

生成对抗网络(GAN)是由 Goodfellow 于 2015 年提出,由 2 个相互竞争的网络组成,即生成器网络 G 和鉴别器网络 D ^[9],通常生成器的输入为噪声 z 。

$$f(z) = G(z; \theta_g) \quad (1)$$

式中: θ_g 为生成器中的参数,判别器感知 f 与真实数据 x ,并做出判断,由此产生一个区间为 $[0,1]$ 的标量,值越接近 0 一般代表输入为伪数据。

$$y(z) = D(G(z; \theta_g); \theta_d) \quad (2)$$

同时判别器的输出越接近 1 代表输入越真实。

$$h(x) = D(x; \theta_d) \quad (3)$$

判别器训练的目标是最大化真实数据 x 作为输出的输出标量值 h ,最小化生成器输出 f 作为输入的输出标量值 y ,也可以说生成器的目标是最小化 y 与标量 1 的差距 $\log(1 - D(G(z)))$,即:

$$\min_G \min_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (4)$$

生成器捕获数据的分布特征,判别器推测输入的数据是生成器产生的还是真实数据,2 个模型相互竞

争,最终实现生成器具有产生的数据能让判别器无法分辨的能力。传统生成对抗网络的生成器输入为噪声,而最近提出 SRGAN(Super Resolution GAN),将低分率的图像作为输入实现了端到端的超分辨率^[10],这也得益于 DCGAN(Deep Convolution GAN)将 CNN(Convolution Neural Network)引入而能够使模型获取到数据高阶的特征,使生成器能够表征更为细节和深层的特征^[11]。最近,基于 CGAN 的去模糊网络实现了良好的图像锐化工作^[12],其设计的损失函数能够使对模糊核和环境噪声进行估计。

1.2 采集图像模糊原理

模糊 QR 码图像表示为 I_B ,原始 QR 图像表示为 I_0 ,运动模糊、失焦模糊和自模糊等因素可表示为 K (模糊核),随机的环境噪声可表示为 N ,模糊模型可表示为:

$$I_B = K * I_0 + N \quad (5)$$

式中: $*$ 为卷积,通过生成对抗网络的生成器和判别器的迭代对抗,可对 K 和 N 进行估计,并由 I_B 通过反卷积求出 I_0 。

1.3 模型结构和算法流程

文中将具有深层特征提取能力的深度卷积生成对抗网络和具有去模糊能力的条件生成对抗网络相结合,对模型进行搭建,包括生成器、判别器架构和损失函数。

1) 判别器结构。判别器网络为标准的深度卷积生成对抗网络的判别器结构,通过卷积运算提取输入的深层特征,判别器的结构和深度说明见图 1。包含 5 个卷积层,每个卷积层 filter 的尺寸都为 4×4 。第 1 个卷积层的步长(stride)为 2,输出通道深度为 64,填充方式为‘SAME’;第 2 个卷积层的步长(stride)为 2,输出通道深度为 128,填充方式为‘SAME’;第 3 个卷积层的步长(stride)为 2,输出通道深度为 256,填充方式为‘SAME’;第 4 个卷积层的步长(stride)为 1,输出通道深度为 512,填充方式为‘SAME’;第 5 个卷积层的步长(stride)为 1,输出通道深度为 1,填充方式为‘SAME’;再经过 2 个神经元数为 1024 的全连接层输出相应的标量值。值得注意的是采用了被普遍认为在 GAN 中表现更好的激活函数 LeakyReLU^[13],并经过 2 个全连接层输出一个单标量值。

2) 生成器结构。生成器网络以模糊的 QR 码作为输入,利用深度网络结构对模糊核和环境噪声进行估计,执行去模糊任务,该算法采用基于 CGAN 的去模糊网络,该网络包括上采样部分、ResNet 部分和下反卷积部分。上采样部分包括 2 个卷积采样层,第 1 个卷积层的步长(stride)为 1,输出通道深度为

128, filter 的尺寸为 7×7 , 填充方式为 'SAME', 再进行批归一化和 ReLu 激活函数; 第 2 个卷积层的步长 (stride) 为 1, 输出通道深度为 256, filter 的尺寸为 3×3 , 填充方式为 'SAME', 再进行批归一化和 ReLu 激活函数。

ResNet 网络部分包含 9 个 ResBlock, 每一个 ResBlock 的结构为 2 个卷积层, 第 1 个卷积层的步长 (stride) 为 1, 输出通道深度为 256, filter 的尺寸为 3×3 , 填充方式为 'SAME', 再进行批归一化和 ReLu 激活函数; 第 2 个卷积层的步长 (stride) 为 1, 输出通道深度为 256, filter 的尺寸为 3×3 , 填充方式为 'VALID', 再进行批归一化, 而后与这个 ResBlock 的输入相加, 这 9 个 ResBlock 都为这种学习方式。

下反卷积部分包括 2 个反卷积层。第 1 个反卷积层输出通道深度为 128, filter 的尺寸为 4×4 , 再进行批归一化和 ReLu 激活函数; 第 2 个反卷积层输出通道深度为 3, filter 的尺寸为 4×4 , 再进行批归一化和 ReLu 激活函数, 之后输出。

因为模型较为复杂, 所以每层都采用了批归一化

加快运算速度^[14], 为避免过拟合引入了 Dropout^[15]。ResNet 部分由 9 个 ResBlocks 组成, 每个 ResBlocks 都为残差学习模块, 使参数的优化更加容易^[16]。下反卷积层通过多层的反卷积最后输出图像矩阵。具体架构见图 2。

3) 损失函数。损失函数不仅为参数更新提供梯度, 同时也决定着模型收敛的方向。对于 QR 码的去模糊任务, 既需要使生成器产生的去模糊 QR 码图像尽量与真实 QR 码图像的大体轮廓相接近, 即大体内容的差距被定义为整体损失 (Overall_loss, O)。

$$O = \sum_{n=1}^N -D_{\theta}(G_{\theta}(I_B)) \quad (6)$$

同时去模糊 QR 码图像的细节也必须较为准确, 这样才能完成识别, 所以也需要考虑深层细节的损失。应用 VGG16 模型的 'block3_conv3' 层作为输出来计算生成器产生图像与原始图像的细节损失 (Detail_loss, D_{-})^[17]

$$D_{-} = VGG16_{\text{block3_conv3}}(G(z; \theta_g)) - VGG16_{\text{block3_conv3}}(x) \quad (7)$$




图 1 判别器网络结构

Fig.1 Network structure of discriminator




图 2 生成器网络结构

Fig.2 Network structure of generator

算法流程: 基于前述理论, 文中提出一种基于生成对抗网络的 QR 码去模糊算法, 用于包装产品外壳上 QR 码的去模糊。核心关键步骤在于数据集获取、模型的训练、后期去模糊。

1) 数据集获取。生成对抗网络的训练需要较多的训练样本, 但是对于包装外壳, 想得到大量的真实 QR 码相对于模糊 QR 码数据集则较难。文中提出一种获取包装外壳上 QR 码数据集的方法, 可以用于生

成对抗网络的训练。首先将多种类的真实 QR 码进行前期采集,进行数值矩阵化为 I_0 ,并由式(5)利用 Python 的 Numpy 库和 PIL 库的 Image 模块将 I_0 与模拟的一定范围值内的随机模糊核值 K 和高斯噪声 N 进行计算,得到大量的 I_B ,再将 I_B 进行图像化编码,就得到了大量的真实 QR 码和与之对应的模拟模糊 QR 码数据集,使用此方法可以得到大量的随机基于模糊核和环境噪声的模糊 QR 码和真实的 QR 码,其中对模糊核 K 和高斯噪声 N 进行模拟的函数是 `fspecial('motion', LENTH, THETA)` 和高斯模糊半径 ($\sigma=\text{value}$)。 `fspecial('motion', LENTH, THETA)` 模拟模糊核水平, THETA 为相机逆时针移动的角度, LENTH 为相机移动的像素值,高斯模糊半径越大,高斯模糊越强。实现过程见图 3。

2) 模型训练。通过模糊 QR 码数据集和真实 QR

码数据集训练生成对抗网络,随着训练的进行,生成器逐渐具有对模糊核和随机噪声水平进行估计的能力,同时具有将输入模糊 QR 码图像转换为去模糊 QR 码图像的能力。当损失函数值逐渐平稳趋于收敛后,模型达到较好的能力,固化模型,用于后期的直接使用。

3) 后期去模糊。经过固化的生成对抗网络的生成器可以直接应用于实际模糊 QR 码的去模糊,对于包装产品外壳上的 QR 码而言,使用与录入种类相同的不同模糊程度和类型的实际模糊 QR 码作为生成器的输入,生成器的参数网络都可以根据式(2)估计出一个对应的锐化 QR 码图像,即实现 QR 码的去模糊。训练好的生成器具有由单一固化模型,对多种类的模糊 QR 码的去模糊的能力,泛化能力好,能显著提高识别率。算法流程见图 4。




图 3 数据集获取
Fig.3 Dataset acquisition




图 4 算法流程
Fig.4 Algorithm flow

2 实验与分析

文中应用深度学习框架 Tensorflow 进行模型的搭建,基于 python 3.6.3,版本为 1.2.0,同时选用 3 张内容不同的 QR 码进行测试,图像分辨率为 80×80 的 RGB 编码图像,并使用上述数据集获取方法进行训练数据集的扩充,在进行模拟时将 Length 值、Theta 值设置为 $0 \sim 20$ 的随机数,将 σ 值也设置为 $1 \sim 3$ 的随机数。这样每次由真实 QR 码模拟产生的模糊 QR 码都是具有不同程度。文中数据集中包含 3 种不同内容的模糊各异的 QR 码,将一种 QR 由文中方法产生的 3 种不同模糊程度的数据集图像见图 5。得到 10 000 张模糊等级各异的训练样本和 10 000 张与之对应的真实 QR 码。同时,设置生成器学习率 0.0001,

判别器学习率 0.0001,学习率衰减率设置为 0.99, batch_size 设置为 10, epoches 设置为 10,批归一化指数 epsilon 为 0.000 01,权重初始化标准差 0.002,偏置项为常数 0.1,优化函数采用 SGD 的优化算法 Adam^[18]。




图 5 样本
Fig.5 Sample

遭受运动模糊 (LENGTH=10, $\sigma=10$) 和环境高

斯噪声影响的模糊 QR 码见图 6, 随着生成器和判别器不断对抗进行网络权重更新, 生成器产生去模糊图像的迭代过程。可以通过框内图像变化发现, 随着迭代次数的增加, 生成器对模糊核和环境噪声的估计越来越准确, 图像内容的锐化程度不断提高, 图像边缘越来越锋利, 相应的去模糊的 QR 码的效果也越来越好, 到 1000 次迭代已经可以实现识别。




图 6 迭代过程
Fig.6 Iterative process

生成器的损失 (整体损失和细节损失的和) 与迭代次数的关系见图 7。通过图 7 可以发现, 生成器损失从 7000 左右开始振荡下降, 并逐渐趋于收敛。同时, 结合图 6 和图 7 分析可以得到, 随着生成器与判别器的迭代对抗, 生成器对模糊核和环境噪声的估计能力就越强, 去模糊 QR 码整体上与真实 QR 码越来越接近, 同时细节差异也在变小, 因此总损失逐渐振荡下降。由于生成对抗网络的表征能力也是有限的, 因此损失逐渐趋于收敛。




图 7 生成器损失
Fig.7 Loss of generator

去模糊 QR 码图像与原始 QR 码图像的像素值的平均绝对误差 (QR-MAE, Q) 在迭代过程中的变化见图 8。MAE 越小去模糊 QR 码图像越接近于真实图像, 同时图 8 可以在图 6 的基础上量化的反映生成对抗网络对模糊核和环境噪声估计能力变化的过程。

$$Q = \frac{\left(\frac{\sum_{i=1}^{N_1} |\bar{A}_i - A_i|}{N_1} + \frac{\sum_{i=1}^{N_2} |\bar{A}_i - A_i|}{N_2} + \frac{\sum_{i=1}^{N_3} |\bar{A}_i - A_i|}{N_3} \right)}{3} \quad (8)$$

QR 码为 RGB 编码三通道图像, $\bar{A}$ 为去模糊后的单通道像素值, A 为原始单通道像素值, N 为像素点数 (80×80)。

通过图 8 的变化可以发现, QR-MAE 值的变化与图 6 QR 码直观去模糊效果的变化相同, 随着迭代次数的增加, QR-MAE 值逐渐减小。同时与图 7 生成器变化相同, 由于生成器网络的估计能力趋于停滞和收敛, 相应的由生成器产生的去模糊图像的 QR-MAE 值也趋于收敛。综述图 6—8 可以发现, 生成器网络对模糊核和环境噪声的估计能力是逐渐提高并趋于收敛的, 去模糊 QR 图像的效果遵从此规律。

将 3 种不同的模糊 QR 码作为输入见表 1, 经过相同的单一生成器的输出去模糊效果。环境高斯噪声半径统一为 1.0, 相机移动角度值越大运动模糊效果越强。通过表 1 发现, 训练好的生成器较好对模糊核和环境噪声进行估计, 能实现对于数据集内不同 QR 码的去模糊, 即单一生成器对多类 QR 码的去模糊; 对同一种 QR 码的不同模糊程度图像, 生成器都能够实现有效的去模糊, 识别率高, 反映了生成对抗网络良好的泛化能力, 能够被广泛应用于数据集内不同模糊程度 QR 码的去模糊; 输出耗时较短都为 1 s 左右, 能够极大地减小预处理时间, 提高工作效率和识别率。

生成器去模糊的泛化能力, 主要表现为对数据集内不同模糊程度的 QR 码都具有较好的去模糊效果。如表 1, 对相机移动角度 $5^\circ/10^\circ$ 的具有不同模糊程度 QR 码, 经过生成器后都产生了锐化、可识别的去模糊 QR 码, 说明生成器具有较好的泛化能力。同时, 文中使用 2 张实际采集 QR 码进行验证 (不在数据集内), 通过图 9 实验结果发现, 将采集到的模糊 QR 码的图像部分裁剪后, 通过生成器的模糊 QR 码能够实现较好的去模糊效果, 可实现识别, 说明模型对模糊核和环境噪声有较好的拟合, 泛化性能好。




图 8 QR-MAE 变化
Fig.8 Trend chart of QR-MAE

表 1 多种类 QR 码输出
Tab.1 Table for multiple types of QR code output

真实 QR 码	相机移动角度 5°/10°	生成器输出	输出耗时/s
		 可识别	1.41
		 可识别	1.52
		 可识别	1.52
		 可识别	1.54
		 可识别	1.49
		 可识别	1.55



图 9 数据集外 QR 码去模糊效果
Fig.9 Deblurring effect of QR code outside dataset

3 结语

基于生成对抗网络的 QR 码去模糊算法通过深度

学习模型对数据集较强的感知和深层特征提取能力，能够较好地数据集内 QR 码图像的模糊核和环境噪声进行估计，实现由生成器网络输出与模糊 QR 码图像对应的去模糊 QR 码图像的过程。同时，生成器网络能够实现对数据集内多种类不同模糊程度 QR 码的去模糊，泛化能力好，速度快。文中同时提出了 QR 码图像数据集获取方法用于模型的训练，只需要提前录入所需要高频次扫描的包装产品外壳上的 QR 码，就可实现模型的训练，显著避免由于相机运动模糊等因素造成的包装产品上 QR 码无法识别的问题，能够广泛适用于大型商场、物流等包装产品外壳上高频次 QR 码扫描的领域。

参考文献：

[1] 孟猛, 孙继华, 邓志声. 基于二维码技术的热带水果质量安全追溯系统设计与实现[J]. 包装工程, 2014, 35(5): 13—20.
MENG Meng, SUN Ji-hua, DENG Zhi-sheng. Design and Implementation of Tropical Fruit Quality and Safety Traceability System Based on Two Dimensional Code Technology[J]. Packaging Engineering, 2014, 35(5): 13—20.

[2] 凌康杰, 岳学军, 刘永鑫, 等. 基于移动互联的农产品二维码溯源系统设计[J]. 华南农业大学学报, 2017, 38(3): 118—124.
LING Kang-jie, YUE Xue-jun, LIU Yong-xin, et al. Design of a Farm Product Traceability System with QR Code Based on Mobile Internet[J]. Journal of South China Agricultural University, 2017, 38(3): 118—224.

[3] 涂丹, 甘亚莉, 徐宗琦. 一种快速的 QR 码图像去模糊方法[J]. 计算机工程与科学, 2007, 29(3):43—45.
TU Dan, GAN Ya-li, XU Zong-qi. A Real Time Deblurring Algorithm for the QR Barcode Images[J]. Computer Engineering & Science, 2007, 29(3): 43—45.

[4] 李人哲, 许刚. 模糊 QR 码图像的恢复[J]. 计算机应用与软件, 2013, 30(6): 258—261.
LI Ren-zhe, XU Gang. Recovery of Image with Blurred QR Code[J]. Computer Applications & Software, 2013, 35(5): 13—20.

[5] 杜菲, 曾台英. 基于强度和梯度先验的 L₀ 正则化模糊 QR 码识别[J]. 包装工程, 2017, 38(3): 150—154.
DU Fei, ZENG Tai-ying. Recognition of Fuzzy L₀-Regularized QR Code Based on Intensity and Gradient Priori[J]. Packaging Engineering, 2017, 38(3): 150—154.

[6] YOO H J. Deep Convolution Neural Networks in Computer Vision[J]. Ieie Transactions on Smart Processing & Computing, 2015, 4(1): 35—43.

[7] SUN J, CAO W, XU Z, et al. Learning a Convolutional

- Neural Network for Non-uniform Motion Blur Removal[J/OL]. (2015-04-12) [2018-06-12]. <https://arxiv.org/abs/1503.00593>.
- [8] LECUN Y, BENGIO Y, HINTON G. Deep Learning[J]. *Nature*, 2015, 521(7553): 436.
- [9] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets[C]// International Conference on Neural Information Processing Systems, MIT Press, 2014: 2672—2680.
- [10] WU B, DUAN H, LIU Z, et al. SRPGAN: Perceptual Generative Adversarial Network for Single Image Super Resolution[J/OL]. (2017-12-20) [2018-06-12]. <https://arxiv.org/abs/1712.05927>.
- [11] CHANG J, SCHERER S. Learning Representations of Emotional Speech with Deep Convolutional Generative Adversarial Networks[J/OL]. (2017-04-22) [2018-06-12]. <https://arxiv.org/abs/1705.02394>.
- [12] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: Blind Motion Deblurring Using Conditional Adversarial Networks[J/OL]. (2017-04-03) [2018-06-12]. <https://arxiv.org/abs/1711.07064>.
- [13] XU B, WANG N, CHEN T, et al. Empirical Evaluation of Rectified Activations in Convolutional Network[J/OL]. (2015-11-27) [2018-06-12]. <https://arxiv.org/abs/1505.00853>.
- [14] ULYANOV D, VEDALDI A, LEMPITSKY V. Instance Normalization: The Missing Ingredient for Fast Stylization[J/OL]. (2017-11-06) [2018-06-12]. <https://arxiv.org/abs/1701.02096>.
- [15] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a Simple Way to Prevent Neural Networks from Overfitting[J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929—1958.
- [16] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[J/OL]. (2015-12-10) [2018-06-12]. <https://arxiv.org/abs/1512.03385>.
- [17] JOHNSON J, ALAHI A, LI F F. Perceptual Losses for Real-Time Style Transfer and Super-Resolution[M]. Springer International Publishing, 2016.
- [18] KINGMA D P, BA J. Adam: a Method for Stochastic Optimization[J/OL]. (2017-01-30) [2018-06-12]. <https://arxiv.org/abs/1412.6980>.