

基于改进生成对抗网络的单帧图像超分辨率重建

陈宗航, 胡海龙, 姚剑敏, 严群, 林志贤

引用本文:

陈宗航, 胡海龙, 姚剑敏, 等. 基于改进生成对抗网络的单帧图像超分辨率重建[J]. 液晶与显示, 2021, 36(5): 705–712.

CHEN Zong-hang, HU Hai-long, YAO Jian-min, et al. Single frame image super-resolution reconstruction based on improved generative adversarial network[J]. *Chinese Journal of Liquid Crystals and Displays*, 2021, 36(5): 705–712.

在线阅读 View online: <https://doi.org/10.37188/CJLCD.2020-0250>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度卷积生成对抗网络的图像识别算法

Image recognition algorithms based on deep convolution generative adversarial network

液晶与显示. 2020, 35(4): 383–388 <https://doi.org/10.3788/YJYXS20203504.0383>

基于条件生成对抗网络的手写数字识别

Handwritten digit recognition based on conditional generative adversarial network

液晶与显示. 2020, 35(12): 1284–1290 <https://doi.org/10.37188/YJYXS20203512.1284>

基于密集连接生成对抗网络的图像颜色迁移

Image color transfer with dense connections generative adversarial networks

液晶与显示. 2020, 35(3): 272–280 <https://doi.org/10.3788/YJYXS20203503.0272>

基于多尺度残差网络的CT图像超分辨率重建

CT image super-resolution reconstruction based on multi-scale residual network

液晶与显示. 2019, 34(10): 1006–1012 <https://doi.org/10.3788/YJYXS20193410.1006>

基于小波域的图像超分辨率重建方法

Image super-resolution reconstruction based on wavelet domain

液晶与显示. 2021, 36(2): 317–326 <https://doi.org/10.37188/CJLCD.2020-0101>

文章编号:1007-2780(2021)05-0705-08

基于改进生成对抗网络的单帧图像超分辨率重建

陈宗航¹, 胡海龙¹, 姚剑敏^{1,2*}, 严 群^{1,2}, 林志贤¹

(1. 福州大学 物理与信息工程学院, 福建 福州 350108;

2. 晋江市博感电子科技有限公司, 福建 晋江 362200)

摘要: 为了获得更好的图像超分辨率重建质量, 提高网络训练的稳定性, 对生成对抗网络、损失函数进行研究。首先, 介绍了 SRGAN 和 DenseNet, 并设计了基于 DenseNet 的生成网络用以生成图像, 且将子像素卷积模块加入到 DenseNet 中。接着, 移除了原本 DenseNet 中冗余的 BN 层, 提高了模型的训练效率。最后, 介绍了 SRGAN 的损失函数并基于 Earth-Mover 距离来重新设计损失函数, 并且用 SmoothL1 损失取代 MSE 损失来计算 VGG 特征图, 以防止 MSE 放大最大误差和最小误差间的差距。实验证明: 该模型在网络训练过程中能够达到稳定收敛的状态。重建出的图像质量对比 SRGAN, 在 3 个基准测试集 SET5, SET14, BSD100 上的平均 PSNR 要高约 2.02 dB, SSIM 高约 0.042(5.6%)。重建出的图像不仅在指标上有所提升, 且拥有更好的清晰度, 高频细节更为丰富。

关键词: 图像超分辨率; 生成对抗网络; 深度学习

中图分类号: TP394.1; TH691.9 **文献标识码:** A **doi:** 10.37188/CJLCD.2020-0250

Single frame image super-resolution reconstruction based on improved generative adversarial network

CHEN Zong-hang¹, HU Hai-long¹, YAO Jian-min^{1,2*}, YAN Qun^{1,2}, LIN Zhi-xian¹

(1. College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China;

2. Jinjiang RichSense Electronic Technology Co., Ltd., Jinjiang 362200, China)

Abstract: In order to obtain better image super-resolution reconstruction quality and improve the stability of network training, the generation of confrontation networks and loss functions are studied. Firstly, SRGAN and DenseNet are introduced, a generation network is designed to generate image based on DenseNet, and the sub-pixel convolution module is added to DenseNet. Then, the redundant BN layer in the original DenseNet is removed to improve the training efficiency of the model. Finally, the loss function of SRGAN is introduced and the loss function is redesigned based on the Earth-Mover distance, and the SmoothL1 loss is used to replace the MSE loss to calculate the VGG feature map to prevent MSE from amplifying the gap between the maximum error and the minimum error.

收稿日期: 2020-09-24; **修订日期:** 2020-11-08.

基金项目: 国家重点研发计划课题(No.2016YFB0401503); 广东省科技重大专项(No.2016B090906001); 福建省科技重大专项(No.2014HZ0003-1); 广东省光信息材料与技术重点实验室开放基金(No.2017B030301007)

Supported by National Key Research and Development Program of China (No.2016YFB0401503); Science and Technology Major Program of Guangdong Province (No.2016B090906001); Science and Technology Major Program of Fujian Province (No.2014HZ0003-1); Open Fund of Guangdong Provincial Key Laboratory of Optical Information Materials and Technology (No.2017B030301007).

* 通信联系人, E-mail: yaojm@fzu.edu.cn

Experiments prove that the model can achieve a stable convergence state during the network training process. The quality of the reconstructed image is compared with SRGAN, the average PSNR on the three benchmark test sets SET5, SET14, and BSD100 is about 2.02 dB higher, and SSIM is about 0.042 (5.6%) higher. The reconstructed image not only has improved indicators, but also has better definition and richer high-frequency details.

Key words: image super-resolution; generative adversarial networks; deep learning

1 引言

生活中许多领域都对图像的分辨率有着较高的要求,如安防、医疗、航天、刑侦等,而图像超分辨率(Super Resolution, SR)重建技术也渐渐成为近年来研究的热门话题。图像超分辨率技术于1984年首次被提出^[1],其指的是通过某种方法将低分辨率的图像重建为高分辨率的图像,它是图像处理和计算机视觉领域的重要研究方向。图像超分辨率方法主要有基于差值的方法、基于重建的方法和基于学习的方法^[2]。基于差值的方法是利用某个像素点周围的像素值以及其中相对的位置关系,依据数学方法来进行评估,主要有最近邻插值法^[3]和双三次插值法^[4]。基于重建的方法主要是利用自然预想的先验知识(如平滑性),常见的方法有凸集投影^[5]以及最大后验概率法^[6]。基于学习的方法主要有传统的机器学习方法和近年来被广泛应用的深度学习的方法。基于机器学习的方法一般是结合矩阵变换的相关方法来学习其中复杂的映射关系,需要人为地提取特征进行学习。与传统方法相比,基于深度学习的超分辨率重建不需要手动进行特征提取,而是经过神经网络自动地提取复杂丰富的特征,然后学习两幅图片之间的映射关系,且通过深度学习方法还原的高分辨率图像具有更丰富的纹理信息和更清晰的视觉感知。

Dong 等人提出了 SRCNN (Super-Resolution using Convolutional Neural Network)^[7],其是深度学习应用在超分辨率领域的开山之作,对图像超分辨率的重建效果和速度取得了重大突破。而后 VDSR^[8]、LapSRN^[9-10]等又在 SRCNN 的基础上做出了许多改进,极大地推动了图像超分辨率技术的发展。之后 Ledig 等人^[11]将生成对抗网络^[12] (Generative Adversarial Networks, GAN)

应用在图像超分辨率重建中,提出了 SRGAN 算法,使得图像在重建后拥有更多的高频细节,感受野更好,但是其中 GAN 网络的训练不稳定,训练时间也较长。本文设计了不同于 SRGAN 的生成对抗网络,且在损失函数中使用了与 MSE^[13]不同的 SmoothL1 损失并引入了 Earth-Mover 距离^[14]的思想来稳定网络的训练,实验证明图像评价指标 PSNR 和 SSIM 都有提升。

2 网络模型设计

2.1 生成对抗网络

生成对抗网络是由 Goodfellow 提出的一种基于生成模型的网络。其灵感来自于零和博弈论中的纳什均衡^[15]。GAN 网络的训练目标就是生成网络 G 强大到可以混淆判别网络 D 的同时,判别网络 D 又能很好地分辨出生成网络 G 生成的图像和原始图像,GAN 的目标函数可以表示为:

$$\min_{G} \max_{D} V(D, G) = E_{x \sim P_{\text{data}}(x)} [\lg D(x)] + E_{z \sim P(z)} [\lg (1 - D(G(z)))] \quad (1)$$

其中: $P_{\text{data}}(x)$ 表示真实样本的分布,而 $P(z)$ 表示生成网络的分布。判别函数 D 希望真实数据的 $D(x)$ 概率更大, $D(G(z))$ 更小,对于 D 来说希望这个目标函数的值更大,生成网络函数 G 则希望 $G(z)$ 更接近 x ,使得 $D(G(z))$ 更大,这时目标函数的值就会更小。这也体现了 GAN 网络中的 G 网络和 D 网络一种对抗的特点。SRGAN 的训练流程如图 1 所示。




图 1 SRGAN 训练流程

Fig.1 Training process of SRGAN

首先,对原始的高分辨率图像 HR 进行某种方法的预处理以获得低分辨率图像 LR;后将低分辨率图像送入生成网络 G 中,得到生成高分辨率图像 SR;再将 SR 和原始高分辨率图像 HR 组成一个图像对送入判别网络 D 中。判别网络的输出实际上是一个判断图片是 HR 还是 SR 的二分类问题。在获得判别结果的误差后,调整模型的参数,以使模型能够在学习过程中自动更新参数信息。

2.2 基于 DenseNet 的生成网络

SRGAN 中使用的生成网络为 ResNet^[16],这是一种残差网络,而 DenseNet^[17] 提出了一个密集型的连接模型,具体来说就是每一层除了会接受上一层的输出作为输入还会接受之前所有层的输出作为输入。其简易原理图如图 2 所示。




图 2 DenseNet 简易原理图

Fig.2 Simple schematic diagram of DenseNet

DenseNet 每个层都会与之前所有层 channel 维度上相连接,并作为下一层的输入。当一个 DenseNet 网络有 L 层时,DenseNet 总共会包含 $L(L+1)/2$ 个连接,且 DenseNet 是直接合并来自不同层的特征图,这可以更好地实现特征复用,提升网络的训练效率。

2.2.1 子像素卷积

子像素卷积^[18] (Sub-pixel convolution) 是一种较为特别的图像和特征图的放大方法,其又可以

称作像素清洗(Pixel shuffle)。以往的 DenseNet 使用较多的上采样方法为逆卷积,但是逆卷积往往会掺杂过多的人工因素,而子像素卷积的过程是需要学习的,相比于逆卷积,这种通过样本学习的方式得到放大图像或者特征图所需参数的方法其放大性能更为准确。子像素卷积模块如图 3 所示。




图 3 子像素卷积模块

Fig.3 Module of sub-pixel convolution

2.2.2 生成网络模型

本文采用了 8×8 的密集连接模块,输入图像需要经过一个 4 倍的下采样过程。EDSR^[19] 中提出 BN 层(批规范化层)^[20] 用于解决较高层的计算机视觉问题,而 BN 层并不适合应用在图像超分辨率这类低层的计算机视觉问题中。如果将 BN 层加入到生成网络中,其会消耗与它之前的卷积层相同的计算资源,且并不会对重建出的图像质量有所帮助。因此本文的 DenseNet 网络与以往不同的是去除了冗余的 BN 层,之后在相同的硬件条件下,就可以在模型中加入更多的网络层或者增加各层提取的特征来提高模型性能。生成网络的整体的网络结构如图 4 所示。其中 k 代




图 4 生成网络结构图

Fig.4 Structure diagram of generator

表卷积核个数, n 代表通道数, s 代表步长。将高分辨率图像 HR 通过一定方法生成低分辨率图像 LR 之后, LR 和 HR 组成一个图像对送入网络训练。首先经过一个卷积模块, 用于提取低水平特征, 该卷积模块由一个卷积层和一个 Relu^[21] 激活函数构成; 之后进入密连接模块, 其中有 8 个密连接块 (DenseBlock), 每个密连接块中有 8 个密连接层, 每个密连接层也采用了一个卷积层加一个 Relu 激活函数的结构。其中各个块和层均采用了上文提到的 DenseNet 结构, 即各个块和层除了接受上一个块和层的输出还会接受之前每一个块和层的输出。通过两个子像素卷积块进行放大生成高分辨率图像。




图 5 判别网络结构图

Fig.5 Structure diagram of discriminator

3 损失函数

在 SRGAN 中, 其损失函数为:

$$l^{\text{SR}} = l_{\text{content-loss}}^{\text{SR}} + \text{beta} \times l_{\text{Gen}}^{\text{SR}}, \quad (2)$$

式(2)中第一项代表了内容损失, 可以表示为:

$$l_{\text{content-loss}}^{\text{SR}} = l_{\text{MSE}}^{\text{SR}} + l_{\text{VGG}}^{\text{SR}}, \quad (3)$$

式(3)的第一项是原始高清图像 HR 和生成网络生成的图像的像素之间的损失, 公式如下

$$l_{\text{MSE}}^{\text{SR}} = \frac{1}{r^2 WH} \sum_{x=1}^r \sum_{y=1}^H (I_{x,y}^{\text{HR}} - G_{\theta_G}(I^{\text{LR}})_{x,y})^2, \quad (4)$$

而由于单纯地使用 MSE 易使得图像过于平滑, 缺乏高频细节, 所以 SRGAN 提出了基于 VGG19 网络提取特征的特征损失, 公式如下

$$l_{\text{VGG}/i,j}^{\text{SR}} = \frac{1}{W_{i,j} H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\varphi_{i,j}(I_{x,y}^{\text{HR}}) - \varphi_{i,j}(G_{\theta_G}(I^{\text{LR}}))_{x,y})^2, \quad (5)$$

式(5)表示用 VGG19 对原始高清图 HR 和重建出的图像 SR 分别进行计算, 得到两幅图的特征

2.2.3 判别网络模型

在判别网络中, 保留了 BN 层以用于稳定训练。由于本文引入了 Earth-Mover 距离的思想, 因此判别网络的任务从判断生成图片和原始图片的二分类任务变为了拟合任务, 所以在最后一层不使用 sigmoid 层, 以保证损失的收敛。判别网络结构如图 5 所示。在判别网络中, 采用 8 个卷积核大小为 3×3 的卷积模块进行特征提取。s1 代表步长为 1, n 代表输出通道数。随着卷积层数的不断加深, 特征个数在第 3, 5, 7 层时加倍, 使用了 LeakyRelu 激活函数, 在第 2 至第 8 个层加入了 BN 稳定网络的训练, 最后通过一个全连接层输出一个一维的张量。

图, 之后再对其计算 MSE 值, 式中 H 和 W 分别代表图片的宽和长, $\varphi_{i,j}$ 表示通过截取 VGG19 网络的第 i 层最大池化和第 j 层卷积层后的特征图。

式(2)的第二项指的是低分辨率图像通过生成网络生成高分辨率 SR 图像后再经过判别网络得出的值与真实值的交叉熵。

由于 MSE 损失函数容易放大最大误差和最小误差之间的差距, 且对异常点较为敏感。本文采用 SmoothL1 损失来指导训练的过程。得到的感知损失为:

$$l^{\text{SR}} = l_{\text{smoothL1}}^{\text{SR}} + l_{\text{VGG}}^{\text{SR}} + \text{beta} \times l_{\text{Gen}}^{\text{SR}}, \quad (6)$$

其中第二项 $l_{\text{VGG}}^{\text{SR}}$ 也是通过 smoothL1 计算得到。

由于 GAN 网络训练不稳定, 不易通过观察损失来了解训练过程的好坏, 且 Matin^[22] 等人通过研究 GAN 的原理解释了 GAN 训练过程不稳定的原因。主要是由于等价优化的距离衡量 JS 散度不合理导致, 因此本文引入 Earth-Mover (EM) 距离进行优化。本文模型的 EM 距离定义为:

$$L = E_{x \sim P_g} [D_{\theta_D}(I^{HR})] - E_{x \sim P_r} [D_{\theta_D}(I^{LR})], \quad (7)$$

生成网络的目标就转变为尽可能最小化 EM 距离。

4 实验与分析

实验硬件资源为 i5-6500 处理器搭配一块 GTX 1060 6G 加速计算。软件环境有 cuda10.1 配合显卡加速,pytorch1.4.0 用于网络搭建和损失函数的定义,用 python3.6.10 进行编程。实验的训练集来自公开数据集 COCO2014 中随机选取的 5000 张图片,测试集采用 SET5、SET14、BSD100 基准测试集,用与生成效果图和对比评价指标。为验证本文模型的图像超分辨率效果,实验选取了经典的传统方法双三次插值(Bicubic)以及 3 种深度学习的方法 SRCNN、VDSR、SRGAN 进行实验对比。

4.1 评价指标

本文实验采用峰值信噪比(PSNR)与结构相似性(SSIM)^[23] 两项客观评价指标进行对比。PSNR 的定义为:

$$\text{PSNR} = 10 \times \lg \left(\frac{\text{MAX}_i^2}{\text{MSE}} \right), \quad (8)$$

本文计算 PSNR 的方法是先为图片转化为 YCbCr 格式,然后只对 Y 分量进行 PSNR 计算。

SSIM 针对 SR 和 HR 两张图片进行计算,其公式为:

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (9)$$

其中: μ_x 是 SR 的平均值, μ_y 是 HR 的平均值, σ_x^2 是 SR 的方差, σ_y^2 是 HR 的方差, σ_{xy} 是 SR 和 HR 的协方差。 $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$ 是用来维持稳定的常数, L 是像素值的动态范围, $k_1 = 0.01$, $k_2 = 0.03$, SSIM 的取值范围是 0~1,得到的值越接近 1 说明两幅图越相似。

4.2 结果分析

本文首先对模型的生成网络进行预先训练,之后才开始训练整个网络。训练过程中通过 tensorboard 观察网络训练稳定性和训练的程度。图 6 所示(横坐标为迭代轮数,纵坐标为损失值)为原始 GAN 训练过程的判别损失图,其损失值此起彼伏是因为判别网络和生成网络正在进行对

抗,所以很难通过观察损失来判定训练过程的好坏,GAN 的训练相当不稳定。




图 6 原始 GAN 判别损失

Fig.6 D_loss of original GAN

图 7 所示为本文模型训练过程的损失变化。可以看出随着训练的进程,损失逐渐趋于某一值开始收敛,这也符合了 Earth-Mover 距离的思想。




图 7 本文模型判别损失

Fig.7 Ours d_loss

本次实验通过 PIL 库对低分辨率图像进行双三次差值重建,并且重建了 SRCNN、VDSR、SRGAN 模型进行了实验对比,实验结果如图 8 所示,分别展示了每个模型在测试集中的重建效果。其中图 8(a)是通过双三次差值重建的高分辨率图像,图 8(b)是通过 SRCNN 模型重建的高分辨率图像,图 8(c)是通过 VDSR 模型重建的高分辨率图像,图 8(d)是通过 SRGAN 模型重建的高分辨率图像,图 8(e)是通过本文模型重建的高分辨率图像;图 8(f)是原始高分辨率图像。

可以看出通过双三次差值重建出的图像特征明显模糊,而 SRGAN 和本文的模型重建的图像不仅较为清晰且拥有许多的纹理细节。为了进一步比较各模型重建图像的效果,图 9 展示了放大图像某一部分后的图像对比。




图 8 重建图像
Fig.8 Reconstructed images




图 9 细节对比图
Fig.9 Detail comparison

从图(9)中可以看出本文的模型重建出的图像细节更加清晰,色彩亮度更加接近原始图像。

接着我们使用 PSNR 和 SSIM 两个图像评价指标对各算法的重建效果进行评估,从而更准确严谨地比较各个算法间的优劣。PSNR 越高代表重建出的图像质量越好,失真越少。SSIM 值越接近 1 代表生成的图像结构越接近于原始图像,原图的 SSIM 值为 1。本文采用的放大倍数为 4 倍,使用 skimage 工具包进行 PSNR 和 SSIM 的计算。表 1 和表 2 是各算法在各测试集上的平均

PSNR 和 SSIM 对比。从图像指标中可以看出传统的双三次差值方法的图像重建质量落后于深度学习方法,并且通过计算 3 个测试集指标的平均值,本文方法的 PSNR 高出 SRGAN 约 2.02 dB, SSIM 约高出 0.042(5.6%)。

表 1 在测试集 SET5、SET14 和 BSD100 上的 PSNR 对比
Tab.1 Comparison of PSNR on test sets SET5, SET14 and BSD100

算法	SET5	SET14	BSD100
Bicubic	26.509	25.169	25.379
SRCNN	28.182	26.144	25.943
VDSR	28.391	26.330	25.933
SRGAN	28.372	25.993	25.093
本文方法	30.747	27.804	26.978

表 2 在测试集 SET5、SET14 和 BSD100 上的 SSIM 对比
Tab.2 Comparison of SSIM on test sets SET5, SET14 and BSD100

算法	SET5	SET14	BSD100
Bicubic	0.787	0.697	0.665
SRCNN	0.822	0.736	0.707
VDSR	0.835	0.744	0.712

续 表

算法	SET5	SET14	BSD100
SRGAN	0.851	0.727	0.670
本文方法	0.875	0.771	0.728

通过损失函数、重建图像以及评价指标的对比,本文方法的网络训练的稳定性要优于SRGAN,且重建出的图像质量要优于其他算法。

5 结 论

本文提出了一种基于DenseNet的生成对抗网


络来进行图像超分辨率重建。与以往不同的是,本文将子像素卷积模块加入DenseNet的网络中,并且移除了冗余的BN层,提高了特征复用率的同时加快了模型训练的效率。本文引入了Earth-Mover距离,重新设计了损失函数,使得判别网络的任务由二分类任务转变为拟合任务。在损失函数中改用了SmoothL1来计算VGG提取的特征图,以防止MSE损失放大最大误差和最小误差之间的差距。最后通过实验验证,本文提出的方法在SET5、SET14以及BSD100三个基准测试集上的图像质量明显好于其他方法,且对比同样基于生成对抗网络的SRGAN,平均PSNR高出约2.02 dB,SSIM高出约0.042(5.6%)。

参 考 文 献:

- [1] 朱福珍,刘越,黄鑫,等.改进的稀疏表示遥感图像超分辨重建[J].光学精密工程,2019,27(3):718-725.
ZHU F Z, LIU Y, HUANG X, *et al.* Remote sensing image super-resolution based on improved sparse representation [J]. *Optics and Precision Engineering*, 2019, 27(3): 718-725. (in Chinese)
- [2] WAN X F, YANG Y. Super-resolution image reconstruction [C]//*Proceedings of 2010 International Conference on Computer Application and System Modeling*. Taiyuan, China: IEEE, 2010.
- [3] DUCHON C E. Lanczos filtering in one and two dimensions [J]. *Journal of Applied Meteorology and Climatology*, 1979, 18(8): 1016-1022.
- [4] HASAN M S, HAQUE S T. Single image super-resolution using back-propagation neural networks [C]//*Proceedings of 2017 20th International Conference of Computer and Information Technology*. Dhaka: IEEE, 2017.
- [5] 刘涛,钱锋,张葆.遥感图像的MAP超分辨重建[J].液晶与显示,2018,33(10):884-892.
LIU T, QIAN F, ZHANG B. MAP super-resolution reconstruction of remote sensing image [J]. *Chinese Journal of Liquid Crystals and Displays*, 2018, 33(10): 884-892. (in Chinese)
- [6] SCHULTZ R R, STEVENSON R L. Extraction of high-resolution frames from video sequences [J]. *IEEE Transactions on Image Processing*, 1996, 5(6): 996-1011.
- [7] DONG C, LOY C C, HE K M, *et al.* Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [8] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016.
- [9] LAI W S, HUANG J B, AHUJA N, *et al.* Fast and accurate image super-resolution with deep laplacian pyramid networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(11): 2599-2613.
- [10] TANG Y L, GONG W G, CHEN X, *et al.* Deep inception-residual laplacian pyramid networks for accurate single-image super-resolution [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(5): 1514-1528.
- [11] LEDIG C, THEIS L, HUSZÁR F, *et al.* Photo-realistic single image super-resolution using a generative adversarial network [C]//*Proceedings of 2017 Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, *et al.* Generative adversarial networks [C]//*Advances in Neural Information Processing Systems*. 2014: 2672-2680.
- [13] ZHAO H, GALLO O, FROSIO I, *et al.* Loss functions for image restoration with neural networks [J]. *IEEE*

- Transactions on Computational Imaging*, 2017, 3(1): 47-57.
- [14] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN [J]. *arXiv preprint arXiv*, 1701.07875, 2017.
- [15] 王功明, 乔俊飞, 王磊. 一种能量函数意义下的生成式对抗网络[J]. *自动化学报*, 2018, 44(5): 793-803.
WANG G M, QIAO J F, WANG L. A generative adversarial network based on energy function [J]. *Acta Automatica Sinica*, 2018, 44(5): 793-803. (in Chinese)
- [16] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition [C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016.
- [17] HUANG G, LIU Z, VAN DER MAATEN L, *et al.* Densely connected convolutional networks [C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017.
- [18] SHI W Z, CABALLERO J, HUSZÁR F, *et al.* Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016.
- [19] LIM B, SON S, KIM H, *et al.* Enhanced deep residual networks for single image super-resolution [C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops*. Honolulu: IEEE, 2017.
- [20] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//*Proceedings of the 32nd International Conference on International Conference on Machine Learning*. Lille: ACM, 2015.
- [21] SHAMIR O. Discussion of: Nonparametric regression using deep neural networks with ReLU activation function [J]. *The Annals of Statistics*, 2020, 48(4): 1911-1915.
- [22] ARJOVSKY M, BOTTOU L. Towards principled methods for training generative adversarial networks [J]. *arXiv preprint arXiv*, 1701.04862, 2017.
- [23] 吴磊, 吕国强, 赵晨, 等. 基于多尺度残差网络的 CT 图像超分辨率重建[J]. *液晶与显示*, 2019, 34(10): 1006-1012.
WU L, YU G Q, ZHAO C, *et al.* CT image super-resolution reconstruction based on multi-scale residual network [J]. *Chinese Journal of Liquid Crystals and Displays*, 2019, 34(10): 1006-1012. (in Chinese)

作者简介:



陈宗航(1996—),男,福建福州人,硕士研究生,2017 年于集美大学获得学士学位,主要从事图像超分辨率重建及服务器开发方面的研究。E-mail: czh1995czh@gmail.com



姚剑敏(1978—),男,福建莆田人,2005 年于中国科学院长春光学精密机械与物理研究所获得博士学位,主要从事深度学习、图像处理等方面的研究。E-mail: yaojm@fzu.edu.cn