

基于域适应的真实场景图像超分辨率方法

董中华, 刘 恒

安徽工业大学计算机科学与技术学院, 安徽 马鞍山

收稿日期: 2023年5月22日; 录用日期: 2023年6月21日; 发布日期: 2023年6月29日

摘 要

本研究针对目前图像超分辨率技术广泛应用于医疗、遥感等领域, 但已有的图像超分辨率方法大多采用退化假设的方式来训练模型, 导致训练出的超分辨率网络对真实场景下的图像的重建效果不理想这一问题, 提出了一种基于域适应的真实世界图像超分辨率方法。真实场景图像超分辨率方法分为两阶段, 第一阶段, 通过设计退化网络, 利用高分辨率图像经过退化网络合成低分辨率图像, 并引入域适应损失来使得合成的低分辨率图像逼近真实世界低分辨率图像; 第二阶段利用第一阶段合成的高分辨率-低分辨率图像对以监督学习的方式训练重建网络, 并通过频率分离技术, 提取图像高频信息, 送入判别器网络, 通过频域对抗损失来促进重建网络恢复出图像中的更多细节, 并减少伪影, 来使得训练出的超分辨率网络对真实场景图像有着很好的泛化性。在RealSR数据集的子数据集上进行训练并进行验证测试, 实验结果表明, 与现有方法先比, 所提出的方法在定量指标与定性效果方面都取得了最优的效果。因此, 基于域适应的真实场景图像超分辨率方法能够有效的缩小合成图像与真实场景图像间的域分布差异, 使得超分辨率网络能够适应具有多样分布的真实场景图像, 大大提高了图像的重建质量。

关键词

深度学习, 域适应, 频率分离, 图像超分辨

Real-World Image Super-Resolution Method Based on Domain Adaptation

Zhonghua Dong, Heng Liu

School of Computer Science and Technology, Anhui University of Technology, Ma'anshan Anhui

Received: May 22nd, 2023; accepted: Jun. 21st, 2023; published: Jun. 29th, 2023

Abstract

This study proposes a real-world image super-resolution method based on domain adaptation for

the problem that image super-resolution technology is widely used in medical, remote sensing, and other fields, but most of the existing image super-resolution methods use degradation hypothesis to train the model, which leads to the unsatisfactory reconstruction of the trained super-resolution network for real scene images. The real-world image super-resolution method is divided into two stages. In the first stage, the high-resolution image is synthesized into a low-resolution image by designing a degradation network, and the domain adaptation loss is introduced to make the synthesized low-resolution image approximate the real-world low-resolution image; The second stage uses the high-resolution-low-resolution image pairs synthesized in the first stage to train the reconstruction network in a supervised learning manner, and extracts the high-frequency information from the images through frequency separation techniques and feeds it into the discriminator network, which facilitates the reconstruction network to recover more details in the images and reduce artifacts through frequency-domain adversarial loss to make the trained super-resolution network have good generalization to the real scene images. The experimental results of training and validation tests on a subset of the RealSR dataset show that the proposed method achieves optimal results in terms of quantitative metrics and qualitative effects compared with the existing methods. Therefore, the super-resolution method based on domain adaptation of real scene images can effectively reduce the difference of domain distribution between synthetic images and real scene images, which enables the super-resolution network to adapt to real scene images with diverse distribution and greatly improves the reconstruction quality of images.

Keywords

Deep Learning, Domain Adaptation, Frequency Separation, Image Super-Resolution

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

图像超分辨目的在于将一张 LR (low-resolution) 图像重建到 HR (high-resolution) 版本, 从而改善图像质量。图像超分辨作为重要的底层视觉任务, 其在医疗、遥感等领域有着重要作用, 因此受到越来越多的学者的广泛关注。

传统的图像超分辨方法有很多, 包含基于预测的方法, 基于边缘的方法, 基于统计的方法以及基于稀疏表示的方法等。近些年, 随着深度学习技术的快速发展, 出现很多基于深度学习的图像超分辨方法, 并且这些方法在多样的基准上取得了很好的重建性能。Dong 等[1]开创性地提出了第一个基于 CNN (convolutional neural network) 的图像超分辨网络 SRCNN。该网络仅用简易的三个卷积层将 LR 图像映射到 HR 图像。随后, 研究学者们发现更深更复杂的网络有利于图像特征信息的提取以及重建, 因此在 SRCNN 的基础上, 很多更深更复杂的方法[2]-[9]陆续被提出。这些方法利用密集连接残差块的不同变体作为网络的重建模块, 一方面可以避免网络模型在训练过程可能出现的梯度消失问题; 另一方面利用深层网络强大的特征提取传递能力, 保证网络输入的图像特征信息在网络的传输过程中得以保持, 从而重建出质量更高的图像。然而, 需要指出的是, 上述提到的方法大多基于 L1 或者 L2 损失去优化 SR (super-resolution) 图像与真实 HR 图像之间的距离。尽管这种方法可以在图像定量指标(如 PSNR、SSIM)取得最优的结果, 但重建出的图像往往过于模糊或平滑。主要原因是人类对视觉相似性的感知与这种像素级的误差的关联性不大。因此, 研究者们逐渐关注于如何重建出视觉感知质量好的图像。Johnson 等[10]通

过设计新的感知损失从特征空间而非像素空间来缩小两张图像之间的距离, 使得训练出的超分辨率网络可以重建出视觉感知更好的图像。Ledig 等[11]提出基于生成对抗网络(GAN)的模型 SRGAN, 利用 GAN 强大的生成能力, 使得超分辨出的图像具有更真实的细节。随后 Wang 等[12]提出的 ESRGAN 在 SRGAN 的基础上加以改进, 取得了当时最优的超分辨性能。随后研究学者利用注意力机制来进一步提高网络模型的性能。其中最具代表性的方法当属最近流行的 transformer 模型。其一开始应用于自然语言处理任务, 主要利用 Self-Attention (自注意力)结构来取代传统的循环神经网络结构, 最大的特点是可以实现并行计算。后来, 在研究学者的尝试努力下, 将其运用到计算机视觉领域。如基于 transformer 机制的图像超分辨方法[13][14]进一步提高了图像的恢复质量。

值得注意的是, 上述提到的方法虽然在常用的基于合成的图像数据集上能够取得优良的超分辨效果, 但是在真实场景图像上的重建效果不佳。其主要原因是通过这些模型合成的图像与真实场景下的图像之间存在域距离, 这种域距离主要反映在图像退化的复杂度上。通常来说, 通过上述方法合成的低分辨率图像的退化样式单一, 例如双三次插值。然而, 在真实场景中采集到的真实图像由于传感器噪声、相机抖动等因素的影响, 往往存在多样未知且复杂的退化(噪声、模糊、压缩等因素的结合)。

因此, 近年来, 研究者着力于真实场景图像超分辨的研究。一些工作[15][16]通过调整相机焦距来获得真实图像成对的数据集, 进而以监督的方式训练网络。然而, 这些数据集的收集依赖于复杂的硬件设备并且对于不同相机均需要采集新数据, 采集的难度较大且成本较高。一些方法则利用测试图像调整模型。Shocher 等[17]设计出轻量级的 CNN 模型 ZSSR, 仅用测试数据训练该模型, 使得该模型关注于图像具体细节。然而, 通过直接利用测试图像训练网络模型的方式存在很大的问题。因为现实生活中的图像种类以及数量非常庞大, 要想模型对某一类图像数据的重建效果好, 就要使用这类数据重新训练模型, 这大大提高了训练的时间及成本。另有一些工作提出盲超分算法[18][19], 假定低分辨率图像是由高分辨图像经过某种退化而来, 这些盲超分方法比基于合成数据训练的模型有着更好的泛化性。然而, 这种固定退化估计并不能有效作用于拥有复杂且未知退化的图像上。随后出现了一些基于域适应的方法来缓解这一问题。

域适应是指源任务与目标任务相同, 但源域数据与目标数据的分布不同。并且, 源域有许多标签样本, 而目标域没有或者有很少的标签样本。需要注意的是这里所说的数据分布的不同指的是物体相同而来源不同。比如, 对于自行车图像数据集, 有些来自相机采集, 有些来自互联网。近年来域适应广泛应用于计算机视觉任务, 例如分类[20][21][22], 目标分割[23][24]。因为这些任务所处理的图像虽然来源不同(通常是背景存在差异), 但是图像中的主体内容相同, 因此这类域适应任务较易实现。然而, 在真实场景图像超分辨任务中, 一般能获取到的 HR-LR 图像对是不配对的, 即源域图像与目标域图像的主体与背景均不相同, 因此很难去训练出一个鲁棒性好的模型去适应具有多样域的图像。

Yuan 等[25]提出循环对抗网络(CinCGAN), 主要的做法是利用 GAN 网络去将具有复杂退化样式的输入图像映射到干净的图像域(双三次插值域), 然后再送入超分辨率网络进行重建。其运用两个循环一致性去限制域之间的映射。不同于 CinCGAN, 在基于频率分离的真实场景图像超分辨方法[26](FSSR)中, 作者利用图像的高频信息去合成与目标域图像相似的 LR 图像, 随后以合成的 HR-LR 图像对去训练重建网络, 使得训练出的模型可以适应真实场景下的图像。然而, 上述的两种方法虽然采用生成对抗技术以及高频信息逼近来缩小源域图像与目标域图像间的域距离, 但由于源域图像与目标域图像的内容不同, 这种利用图像中具体信息的方式进行域逼近会在一定程度上会使得源图像丢失信息, 从而导致重建出的 SR 图像丢失细节并且存在伪影。

基于上述研究, 本文探索了一种更合理的缩小源域图像与目标域图像之间域距离的方式, 提出了一种基于域适应的真实场景图像超分辨率网络模型。模型主要由两部分组成: 退化网络以及重建网络。第一阶段利用非配对的 HR-LR 图像, 经过退化网络合成与真实 LR 图像分布相近的 LR 图像。第二阶

段则利用第一阶段合成的图像对训练超分辨率网络, 重建得到 SR 图像。本文通过设计退化网络以及重建网络, 并引入域适应损失来缩小域距离, 以提高源域图像与目标域图像分布的相似性, 从而改善重建效果。

综上, 本方法在构建一个高效的图像超分辨率网络的基础上, 引入域适应损失函数。在第一阶段合成 LR 图像的过程中, 通过域适应损失函数去优化退化网络, 从而约束生成空间。在第二阶段利用合成的 HR-LR 图像对去训练重建网络。在重建网络训练完成后, 输入测试集中的具有复杂退化样式的真实 LR 图像, 能够重建出清晰的高分辨率图像。通过定量与定性实验, 与其他常见方法进行对比, 实验结果表明, 本文的方法取得了更好的重建效果。此外, 本文还对引入的域适应损失进行了消融实验, 以验证所提出方法的有效性。

2. 模型介绍

本文所提出的网络模型分为两部分: 退化网络以及重建网络。退化网络的输入是 HR 图像, 经过退化网络合成与其配对的 LR 图像。并通过引入域适应损失来缩小合成的 LR 图像与真实 LR 图像之间的域距离, 获得 HR-LR 图像对。随后, 将合成的 LR 图像作为输入送入重建网络, 利用与其对应的 HR 标签进行监督训练, 从而使得训练出的重建网络可以适应真实场景下的图像, 超分辨率重建出高质量的 SR 图像。

2.1. 退化网络

本节将介绍所提出的退化网络的具体细节。如图 1 所示, 退化网络主要由卷积层与激活层构成。首先对输入的高分辨率图像(HR)进行预处理, 随机裁剪成 256×256 大小的图像块。然后经过第一对卷积层与激活层(退化网络中所用的激活层均为 PReLU), 将特征图维度从初始的 3 通道变换到 56 通道。得到的高维度特征图经过第二个卷积层, 对应的参数为 k5s4p2 (卷积核大小为 5, 步长为 4, 填充为 2), 因此可以得到原尺寸四分之一大小, 即 64×64 的特征图。然后再经过激活层以及第三对卷积激活层, 最后经过一层卷积, 将特征图维度变回 3 通道, 从而得到退化后的低分辨率图像(LR)。

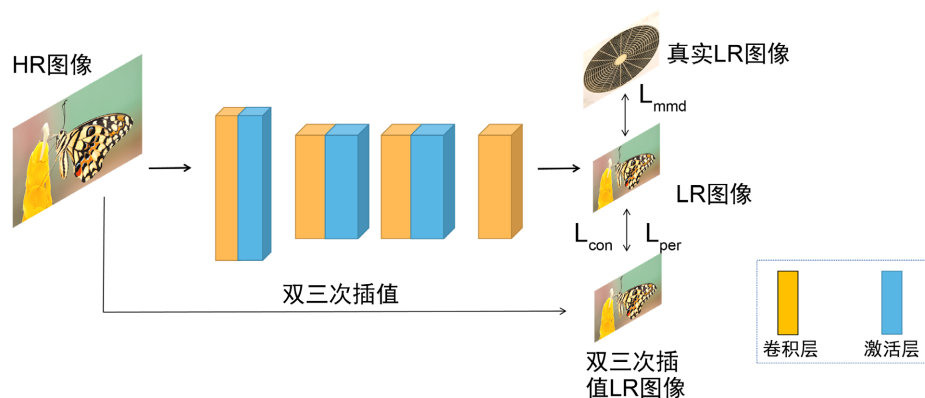


Figure 1. The structure of degradation network

图 1. 退化网络结构图

退化网络通过多种损失函数进行优化, 这里采用的损失包含内容损失, 感知损失以及域适应损失。内容损失采用常用的 L1 损失, 来计算 HR 图像经过退化网络合成的 LR 图像 LR_d 与 HR 图像经过双三次插值生成的 LR 图像 LR_b 间的距离, 从而使得合成的 LR 图像与原 HR 图像保持内容一致。内容损失 L_{con} 的计算公式如下:

$$L_{con} = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W \left\| \text{LR}_d^{ij} - \text{LR}_b^{ij} \right\| \quad (1)$$

其中, H , W 分别代表 LR 图像的高和宽。 LR_d^{ij} 代表输入的 HR 图像经退化网络生成的 LR 图像, LR_b^{ij} 代表 HR 图像经双三次插值生成的 LR 图像。对于感知损失 L_{per} , 采用通用的计算方法, 即采用大规模图像识别的深度卷积网络 VGG19 网络中的中间卷积层来提取特征进行损失计算。其由 19 层网络层组成, 包含 5 个卷积块, 每个卷积块由多个卷积层组成, 输入输出的通道数不同, 共 16 层卷积层。每个卷积块后面跟随一个最大池化层。最后的 3 层是全连接层。卷积块中统一采用 3×3 的卷积核, 卷积层的步长均为 1, 池化层窗口大小统一采用 2×2 , 步长为 2。VGG19 凭借较深的网络层数可以很好的提取图像信息的局部特征。本文具体采用的是 conv5_3 层, 即第五个卷积块的第三层卷积层。感知损失 L_{per} 的计算公式如下所示:

$$L_{per} = \left\| \varphi(\text{LR}_d) - \varphi(\text{LR}_b) \right\| \quad (2)$$

其中, $\varphi(\cdot)$ 表示 VGG19 特征提取器。

除了上述提到的两种损失以外, 还新提出了域适应损失。考虑到由上述构建的退化网络合成的低分辨率图像 LR_d 与真实世界中的 LR 图像 LR_r 存在较大的域分布差异, 因此, 本文新提出一种域适应损失, 来使得生成的 LR 图像更逼近真实场景下 LR 图像的分布。具体来说, 利用最大均值差异(MMD)来衡量两个数据的分布差异。最大均值差异的主要思想是如果两个随机变量的任意阶矩都相同的话, 那么这两个随机变量的分布一致。若两个随机变量的分布不相同, 那么使得两个分布之间差距最大的那个矩被用来作为度量两个随机变量距离的标准。其在先前的工作里主要用在迁移学习中。如风格迁移任务。本文创新性地将其应用到超分辨任务中。主要做法是: 寻找一个映射函数, 此映射函数可以将变量映射到高维空间, 随后求两个变量在高维空间的分布距离, 通过减小该距离使得合成的图像更符合真实分布。具体的域适应损失函数 L_{mmd} 如下:

$$L_{mmd} = \left\| \frac{1}{n} \sum_{i=1}^n k(\text{LR}_d) - \frac{1}{m} \sum_{i=1}^m k(\text{LR}_r) \right\| \quad (3)$$

其中, $k(\cdot)$ 代表高维空间转换函数, 这里具体将源域数据与目标域数据转化为高维核空间。 n , m 分别表示源域图像 LR_d 以及目标域图像 LR_r 的维度, 这里 $n = m$ 。

退化网络的总损失为上述列举损失的加权求和:

$$L_{total} = L_{con} + L_{per} + \lambda_1 L_{mmd} \quad (4)$$

其中, λ_1 用于控制域适应损失的权重。

2.2. 重建网络

经过退化网络合成的 LR 图像, 将送入重建网络进行超分辨重建。本节将介绍重建网络的具体细节。考虑到较深的网络有着更好的特征提取以及重建能力, 因此, 本文采用残差密集块(RRDB)作为重建网络的主要部分。如图 2 所示, 重建网络由卷积层, RRDB (残差密集块) 以及上采样块组成。输入的 LR 图像首先经过一层卷积层, 将特征图的维度从 3 (RGB) 变换到 64。然后将得到的高维特征图送入 23 个残差密集块进行特征提取, 每一个残差密集块由多个卷积层和激活层组成。然后将残差密集块输出的特征图送入上采样模块进行尺度变换。本文用的上采样方式是最近邻插值, 经过两次尺度因子为 2 的最近邻插值, 得到的特征图大小是原输入的 4 倍。最后经过两层卷积层, 将特征图维度降为 3, 得到最终的重建结果。




Figure 2. The structure of reconstruction network
图 2. 重建网络结构图

与退化网络类似, 训练重建网络的损失包含内容损失、感知损失。内容损失的计算公式如下:

$$L_{con} = \|HR - SR\| \quad (5)$$

其中, HR 表示源高分辨图像, SR 代表重建网络重建出的高分辨图像。感知损失的计算公式如下:

$$L_{per} = \|\varphi(HR) - \varphi(SR)\| \quad (6)$$

经过实验发现, 如果仅使用上述两种损失来优化重建网络, 重建出的图像效果不是很理想, 在一定程度上有细节的丢失。因此, 为了使得重建出的 SR 图像具有更丰富的细节信息, 除了上述提到的两种损失外, 还引入了频域对抗损失。具体来说, 提取 HR 图像以及 SR 图像的高频信息, 送入判别器 D , 让重建出的 SR 图像具有与 HR 图像相近的细节。通过利用线性滤波器来分离出图像中的低频与高频信息。为此, 首先定义一个低频滤波器 W_L , 用于提取 SR 图像中的低频信息。然后将源图像与提取到的低频信息进行差值操作, 从而得到该图像所包含的高频信息。对标签 HR 图像进行相同的滤波高频提取, 然后将二者的高频信息送入判别器 D 。其中, 将输入判别器的 HR 高频信息作为真样本, 将 SR 中的高频信息作为假样本, 通过频域对抗损失来让 SR 中的高频信息逼近 HR。具体的频域对抗损失如下:

$$L_{adv} = E \left[\log(1 - D((1 - W_L) * SR)) \right] \quad (7)$$

其中, E 代表取一个批大小的均值。 W_L 代表低通滤波器, 这里具体采用的是高斯低通滤波器。因此, 重建网络的总损失为:

$$L_{total} = L_{con} + \lambda_2 L_{per} + \lambda_3 L_{adv} \quad (8)$$

其中, λ_2 , λ_3 是用于控制感知损失和对抗损失的权重。

3. 实验验证与仿真分析

3.1. 数据集

由于本研究是针对真实场景下的图像超分辨率重建, 因此采用的数据集并非常用的基于合成的数据集, 而是已有的利用相机在真实场景中采集的图像数据, 具有多样的图像类型, 如建筑, 动物等。具体用于模型训练的是 RealSR 数据集。RealSR 数据集中包含真实的 LR-HR 图像对, 是作者在不同的场景下通过调整相机焦距获得, 其中包含由佳能和尼康相机采集的 595 对 LR-HR 图像对。本文采用的训练集包

含 DIV2K 中 800 张高分辨图像作为 HR 图像, 以及 RealSR 尼康子集下的 200 张低分辨图像作为 LR 图像, 验证集包含 50 对图像对。实验的评估标准包含定量指标(PSNR、SSIM)以及定性的视觉质量对比。

3.2. 训练细节

本实验在 NVIDIA 1080TI GPU 图形显卡平台下开展。使用 Adam 优化器更新退化网络以及重建网络。其中对主要的参数 β_1 , β_2 分别进行设置。在退化网络中 β_1 设为 0.5, 在重建网络中设为 0.9, β_2 均设为 0.999。对于退化网络, 输入的 HR 图像裁剪为 256×256 , 批大小设为 6; 对于重建网络, 输入的 LR 图像裁剪为 128×128 , 批大小设为 6。超参数 λ_1 , λ_2 , λ_3 分别设置为 0.005, 0.01, 0.005。退化网络训练 300 轮, 学习率初始为 0.0002, 150 轮后逐渐减少至 0。重建网络训练迭代 50,000 次, 学习率分别在 5 k, 10 k, 30 k 迭代后减半。

3.3. 对比实验

本文主要与现有的基于频率分离的真实图像超分辨方法 FSSR, 以及基于监督训练的模型 ESRGAN 进行对比实验。需要说明的是上述两种方法的预训练模型没有在 RealSR 数据集上进行训练, 因此为了公平比较, 将上述模型在 RealSR 的 Nikon 子数据集下进行重新训练。训练完成后, 在验证集上进行模型性能测试, 从定量与定性两个方面进行比较。表 1 展示的是图像超分辨结果的定量比较, 衡量的指标为 PSNR, SSIM。越高的 PSNR 以及 SSIM 指标代表超分辨出的图像越不失真。从表中可以看出, 本文所提出的方法取得了最优的 PSNR 以及 SSIM。除了定量的比较外, 为了验证提出方法重建图像的视觉效果, 与其他方法进行定性实验比较, 定性的图像视觉质量的比较如图 3 所示。第一列为 FSSR 的结果, 第二列为 ESRGAN 的结果, 第三列为本文所提出方法得到的结果, 最后一列为原图。

从图 3 中可以看出, FSSR 以及 ESRGAN 重建出的图像具有明显的伪影, 导致视觉效果不理想。本文所提出的方法可以有效减少伪影的生成, 重建出的图像清晰且拥有更丰富的细节。如图中第一行的建筑图, 与其他方法相比, 本文的方法更能保留建筑的边缘以及轮廓信息; 对于下面的字母和文字图像, 前面两种方法重建出的效果有伪影且失真, 所提出的方法在保持图像不失真的情况下, 更多的恢复出图像细节。

3.4. 消融实验

为验证所提出的域适应损失的有效性, 对新加入的域适应损失进行了消融实验, 实验结果如表 2 所示。其中第一行的 w/o L_{mmd} 代表的是在没有引入域适应损失的情况下, 模型取得的结果。第二行的 w L_{mmd} 则表示加入域适应损失后的结果。从表中结果可以看出, 在加入域适应损失后, 重建出的图像具有更高的 PSNR 以及 SSIM。图 4 是视觉效果的对比, 可以看出, 加入域适应损失后, 重建的图像更清晰并且能更好保持原图中的颜色等信息, 从而证实了所加入的域适应损失提升了模型的重建性能。

Table 1. Quantitative analysis

表 1. 定量分析

方法	RealSR 数据集	
	PSNR \uparrow	SSIM \uparrow
FSSR	23.424	0.597
ESRGAN	24.890	0.673
Ours	25.077	0.705




Figure 3. The vision comparison with other methods
图 3. 其他方法的视觉对比图

Table 2. Ablation study
表 2. 消融实验

方法	RealSR 数据集	
	PSNR↑	SSIM↑
w/o L_{mmd}	24.315	0.701
w L_{mmd}	25.077	0.705




Figure 4. The comparison results of ablation experiments
图 4. 消融实验结果对比图

4. 结论与展望

本文在分析出现有的图像超分辨方法不能很好适应真实场景中图像的原因后, 在已有方法的基础上, 以缩小图像间域距离为出发点, 提出了基于域适应的真实世界图像超分辨方法。设计的网络结构由两部分组成: 退化网络以及重建网络。网络的训练分为两阶段。第一阶段, 先设计退化网络, 在训练退化网络的过程中加入域适应损失, 使得 HR 图像经过退化网络合成的 LR 图像与真实场景中的 LR 图像拥有相似分布。第二阶段, 利用第一阶段已合成的 HR-LR 图像对训练重建网络, 使得训练出的重建网络可以适应真实场景中的图像。实验结果证明了所提出方法的可靠性和可行性。

需要指出的是, 本文通过域适应损失来缩小源域图像与目标域图像之间二者的域距离, 使得模型对真实世界图像有很好的泛化性, 取得了令人满意的超分辨重建效果, 但这样可能会导致源域图像丢失一些信息。因此, 寻找一种更适合的指标去度量不同域图像间的距离, 这是下一步研究的主要内容。

基金项目

安徽省自然科学基金资助(2008085MF190); 安徽省高校协同创新项目(GXXT-2022-044)。

参考文献

- [1] Dong, C., Loy, C.C., He, K., *et al.* (2014) Learning a Deep Convolutional Network for Image Super-Resolution. *Computer Vision—ECCV 2014: 13th European Conference*, Zurich, 6-12 September 2014, 184-199. https://doi.org/10.1007/978-3-319-10593-2_13
- [2] Ahn, N., Kang, B. and Sohn, K.A. (2018) Fast, Accurate, and Lightweight Super-Resolution with Cascading Residual Network. *Proceedings of the European Conference on Computer Vision (ECCV)*, Munich, 8-14 September 2018, 256-272. https://doi.org/10.1007/978-3-030-01249-6_16
- [3] Ahn, N., Kang, B. and Sohn, K.A. (2018) Image Super-Resolution via Progressive Cascading Residual Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Salt Lake City, 18-22 June 2018, 791-799. <https://doi.org/10.1109/CVPRW.2018.00123>
- [4] Dong, C., Loy, C.C., He, K., *et al.* (2015) Image Super-Resolution Using Deep Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **38**, 295-307. <https://doi.org/10.1109/TPAMI.2015.2439281>
- [5] Fan, Y., Shi, H., Yu, J., *et al.* (2017) Balanced Two-Stage Residual Networks for Image Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Honolulu, 21-26 July 2017, 161-168. <https://doi.org/10.1109/CVPRW.2017.154>
- [6] Haris, M., Shakhnarovich, G. and Ukita, N. (2018) Deep Back-Projection Networks for Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 1664-1673. <https://doi.org/10.1109/CVPR.2018.00179>
- [7] Kim, J., Lee, J.K. and Lee, K.M. (2016) Accurate Image Super-Resolution Using Very Deep Convolutional Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 27-30 June 2016, 1646-1654. <https://doi.org/10.1109/CVPR.2016.182>
- [8] Lai, W.S., Huang, J.B., Ahuja, N., *et al.* (2017) Deep Laplacian Pyramid Networks for Fast and Accurate Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 624-632. <https://doi.org/10.1109/CVPR.2017.618>
- [9] Lim, B., Son, S., Kim, H., *et al.* (2017) Enhanced Deep Residual Networks for Single Image Super-Resolution. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 136-144. <https://doi.org/10.1109/CVPRW.2017.151>
- [10] Johnson, J., Alahi, A. and Li, F.-F. (2016) Perceptual Losses for Real-Time Style Transfer and Super-Resolution. *Computer Vision—ECCV 2016: 14th European Conference*, Amsterdam, 11-14 October 2016, 694-711. https://doi.org/10.1007/978-3-319-46475-6_43
- [11] Ledig, C., Theis, L., Huszár, F., *et al.* (2017) Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 21-26 July 2017, 4681-4690. <https://doi.org/10.1109/CVPR.2017.19>
- [12] Wang, X., Yu, K., Wu, S., *et al.* (2018) Esrgan: Enhanced Super-Resolution Generative Adversarial Networks. *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, Munich, 8-14 September 2018, 63-79.

-
- https://doi.org/10.1007/978-3-030-11021-5_5
- [13] Liang, J., Cao, J., Sun, G., *et al.* (2021) SwinIR: Image Restoration Using Swin Transformer. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Montreal, 11-17 October 2021, 1833-1844. <https://doi.org/10.1109/ICCVW54120.2021.00210>
- [14] Yang, F., Yang, H., Fu, J., *et al.* (2020) Learning Texture Transformer Network for Image Super-Resolution. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 13-19 June 2020, 5791-5800. <https://doi.org/10.1109/CVPR42600.2020.00583>
- [15] Cai, J., Zeng, H., Yong, H., *et al.* (2019) Toward Real-World Single Image Super-Resolution: A New Benchmark and a New Model. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Seoul, 27 October-2 November 2019, 3086-3095. <https://doi.org/10.1109/ICCV.2019.00318>
- [16] Chen, C., Xiong, Z., Tian, X., *et al.* (2019) Camera Lens Super-Resolution. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Long Beach, 15-20 June 2019, 1652-1660. <https://doi.org/10.1109/CVPR.2019.00175>
- [17] Shocher, A., Cohen, N. and Irani, M. (2018) “Zero-Shot” Super-Resolution Using Deep Internal Learning. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 3118-3126. <https://doi.org/10.1109/CVPR.2018.00329>
- [18] Gu, J., Lu, H., Zuo, W., *et al.* (2019) Blind Super-Resolution with Iterative Kernel Correction. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Long Beach, 15-20 June 2019, 1604-1613. <https://doi.org/10.1109/CVPR.2019.00170>
- [19] Zhang, K., Zuo, W. and Zhang, L. (2018) Learning a Single Convolutional Super-Resolution Network for Multiple Degradations. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 3262-3271. <https://doi.org/10.1109/CVPR.2018.00344>
- [20] Ghifary, M., Kleijn, W.B., Zhang, M., *et al.* (2016) Deep Reconstruction-Classification Networks for Unsupervised Domain Adaptation. *Computer Vision—ECCV: 14th European Conference*, Amsterdam, 11-14 October 2016, 597-613. https://doi.org/10.1007/978-3-319-46493-0_36
- [21] Ren, J., Hacihaliloglu, I., Singer, E.A., *et al.* (2018) Adversarial Domain Adaptation for Classification of Prostate Histopathology Whole-Slide Images. *Medical Image Computing and Computer Assisted Intervention—MICCAI 2018: 21st International Conference*, Granada, 16-20 September 2018, 201-209. https://doi.org/10.1007/978-3-030-00934-2_23
- [22] Saito, K., Watanabe, K., Ushiku, Y., *et al.* (2018) Maximum Classifier Discrepancy for Unsupervised Domain Adaptation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 3723-3732. <https://doi.org/10.1109/CVPR.2018.00392>
- [23] Chen, Y., Li, W., Sakaridis, C., *et al.* (2018) Domain Adaptive Faster r-cnn for Object Detection in the Wild. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 3339-3348. <https://doi.org/10.1109/CVPR.2018.00352>
- [24] Gopalan, R., Li, R. and Chellappa, R. (2011) Domain Adaptation for Object Recognition: An Unsupervised Approach. *2011 International Conference on Computer Vision IEEE*, Barcelona, 6-13 November 2011, 999-1006. <https://doi.org/10.1109/ICCV.2011.6126344>
- [25] Yuan, Y., Liu, S., Zhang, J., *et al.* (2018) Unsupervised Image Super-Resolution Using Cycle-in-Cycle Generative Adversarial Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Salt Lake City, 18-23 June 2018, 701-710. <https://doi.org/10.1109/CVPRW.2018.00113>
- [26] Fritsche, M., Gu, S. and Timofte, R. (2019) Frequency Separation for Real-World Super-Resolution. *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, Seoul, 27-28 October 2019, 3599-3608. <https://doi.org/10.1109/ICCVW.2019.00445>