

基于生成对抗网络的无监督图像超分辨率算法*

赵志博, 滕奇志, 任超, 何小海, 翟森

(四川大学 电子信息学院, 四川 成都 610065)

摘要: 目前, 大多数基于学习的图像超分辨率研究通常采用预定的降质类型(比如双三次下采样)处理高分辨率图像, 来产生成对的训练集。然而, 真实图像往往存在未知的模糊和噪声, 导致这些算法无法有效应用到真实场景中。为了实现真实图像的超分辨率重建, 提出了一种基于生成对抗网络的无监督图像超分辨率算法, 所提出的算法分为域转换子网络和重建子网络两个部分。同时设计了深度特征提取模块, 通过融合不同感受野所提取的图像特征来提升网络的性能。实验结果证明, 相比于目前多数的图像超分辨率算法, 本文算法能够实现真实降质图像(存在噪声、模糊等)的图像超分辨率, 在主观效果和客观指标上均能获得更好的性能。

关键词: 真实图像超分辨率; 域转换; 生成对抗网络; 无监督训练

中图分类号: TP183; TP391 文献标识码: A DOI: 10.19358/j.issn.2096-5133.2022.01.009

引用格式: 赵志博, 滕奇志, 任超, 等. 基于生成对抗网络的无监督图像超分辨率算法[J]. 信息技术与网络安全, 2022, 41(1): 55-62.

Unsupervised image super-resolution algorithm based on Generative Adversarial Network

Zhao Zhibo, Teng Qizhi, Ren Chao, He Xiaohai, Zhai Sen

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

Abstract: In most existing researches on learning-based image super-resolution, the pair of training datasets is generated by down-scaling high-resolution (HR) images through a predetermined operation (e.g., bicubic down-sampling). However, these algorithms cannot be effectively applied to real scenes since the real-world image contains unknown noise and blur. To this end, we propose an unsupervised image super-resolution algorithm based on Generative Adversarial Network in this paper. Our method contains two parts: domain conversion sub-network and reconstruction sub-network. In addition, the deep feature extraction module is proposed to improve the performance of the network by merging the image features captured by different receptive fields. Extensive experiments illustrate that compared with most current image super-resolution algorithms, the proposed method can be applied to real-world image (containing noise, blur, etc.) super-resolution, and achieves the start-of-the-art (SOTA) performance on both subjective and objective evaluations.

Key words: real-world image super-resolution; domain conversion; Generative Adversarial Network; unsupervised training

0 引言

图像是信息的重要载体, 随着数字图像在医学、监控、遥感等领域的迅速发展, 人们对图像质量的要求也越来越高。然而在实际的图像获取过程中, 比如在视频监控领域, 由于成像设备的限制, 无法获得满足实际需求的更高空间分辨率的图像, 不利

于后续对图像信息的进一步分析。同时, 在成像过程中由于受到成像条件等一系列因素影响, 导致获取的图像存在一定程度的模糊和噪声, 显著影响了图像的质量。图像超分辨率重建技术可以在不需要改变现有成像设备等条件的前提下, 根据低质量 (Low Quality, LQ) 图像重建出理想的高质量 (High Quality, HQ) 图像, 在成本、实时性以及便利性等方面具有显著的优势, 已经成为了数字图像处理技术

* 基金项目: 国家自然科学基金 (62171304, 61801316)

的主要研究内容。一般来说, LQ 图像的退化模型可以描述为:

$$y = Px + n \quad (1)$$

其中, y 和 x 分别表示 LQ 图像与对应的 HQ 图像, P 表示图像的退化矩阵, n 代表图像噪声。因此, 如果要重建出理想的 HQ 图像, 必须综合考虑模糊和噪声等影响图像质量的因素。

随着深度学习技术的发展, 基于深度学习的图像超分辨率算法取得了出色的重建结果, 通过深度学习来实现图像超分辨率重建逐渐成为一种主要趋势。具体地, Dong 等人^[1]第一次将卷积神经网络(Convolutional Neural Network, CNN)用于图像超分辨率任务中, 通过设计三个卷积层来直接学习从 LQ 图像到 HQ 图像的映射关系。Kim 等人^[2]引入了残差学习的策略, 提出了一种更复杂的图像超分辨率网络结构。Lim 等人^[3]在网络中移除批归一化层(Batch Normalization, BN)来提升网络的灵活性, 去除 BN 层也可以减少显存的消耗, 加快网络训练速度。为了关注更重要的图像特征信息, Zhang 等人^[4]引入了通道注意力机制对通道信息按照重要性进行加权。Zhang 等人^[5]结合传统的超分辨率重建算法, 将传统的求解问题展开为深度神经网络。然而这些方法大多都采用特定的下采样类型(比如双三次下采样)产生用于训练超分辨率网络的配对数据集。由于双三次下采样与实际情况下图像的退化模型存在较大的差异, 导致大多数算法无法有效地处理真实世界的 LQ 图像。

生成对抗网络(Generative Adversarial Network, GAN)主要通过生成器和鉴别器之间的相互博弈, 产生与目标输入属于相同分布的样本, 被广泛用于图像生成^[6]、图像风格迁移^[7]和图像超分辨率^[8-13]等图像任务中。具体地, Prajapati 等人^[8]提出了一种无监督的图像超分辨率算法, 通过引入 L1 损失函数, 感知损失函数和对抗损失函数在不需要配对数据集的情况下直接生成对应的高分辨率图像。Lugmayr 等人^[10]通过引入可逆操作和一致性损失函数, 进一步提升了无监督超分辨率的网络性能。虽然提出的这些算法能够在没有配对数据集的情况下实现图像超分辨率重建, 然而这些算法忽略了图像模糊和图像噪声对超分辨率结果的影响, 限制了其在真实场景的应用。

本文针对真实世界的降质图像, 提出一种基于

GAN 的无监督图像超分辨率算法。由于真实的 LQ 图像存在一定程度的模糊和噪声, 直接通过 LQ 图像生成 HQ 图像比较困难, 因此所提出的算法主要分为域转换子网络和重建子网络两个部分。域转换子网络通过 GAN 学习双三次下采样图像的分布, 从而将真实的 LQ 图像迁移到双三次降质的图像域中, 生成只存在双三次降质的图像。在重建子网络中, 通过学习真实 HQ 图像的分布, 对域转换子网络生成的图像进行空间分辨率的提升, 最终重建出理想的 HQ 图像。

1 无监督图像复原算法框架

1.1 网络框架简介

目前大多数基于 GAN 的图像复原方法直接学习从输入图像 I_{LQ} 所处的真实降质域到 I_{HQ} 所处的高质量图像域的迁移, 但是由于真实降质域和高质量图像域之间的跨度太大, 没有相应的损失函数来约束网络的效果, 再加上 GAN 网络本身很难训练和收敛, 因此这些方法的重建效果难以得到保证。基于此, 本文提出域转换子网络产生一个中间域(双三次降质域)作为过渡桥梁, 首先将输入的 LQ 图像转换到双三次降质域空间, 再通过重建子网络完成从双三次降质域到 HQ 图像域的迁移。如图 1 所示, 所提出的网络框架包含域转换子网络和重建子网络两个部分。其中, I_{LQ} 表示包含了模糊和噪声的 LQ 图像, I_{HQ} 代表的是理想状态下获取到的 HQ 图像, 并通过双三次下采样得到只包含双三次下采样降质类型的图像 y^{bic} 。

1.2 域转换子网络

如图 1 所示, 域转换的目的就是通过生成器 G_1 、 G_2 和鉴别器 D_1 , 将属于真实降质域的输入图像 I_{LQ} 转换成图像 y^{bic} 所处的双三次降质域, 即通过域转换子网络产生只存在双三次下采样降质的图像 O_1 。生成器和鉴别器的网络结构如图 2 和图 3 所示, 其中“Conv”代表卷积层, “LeakyReLU”代表激活函数。首先, I_{LQ} 通过 G_1 输出图像 O_1 , 然后 O_1 和 y^{bic} 一起送入鉴别器 D_1 中进行判别, 判断 O_1 是否和 y^{bic} 属于同一域空间, 从而调整 G_1 的参数, 使 O_1 只存在双三次下采样的降质类型。因此当输入图像是 O_1 时, D_1 要尽可能地判断其为域转换网络生成的图像, 其输出尽可能接近 0。当输入图像是 y^{bic} 时, D_1 要尽可能地判断其为双三次下采样的低分辨率图像, 其输出尽可能接近 1。对应生成器 G_1 和鉴别器 D_1 的损

失函数分别为：

$$L_{G1}^{LQ} = ||D_1(G_1(I_{LQ})) - 1||_2^2 \tag{2}$$

$$L_{D1}^{LQ} = ||D_1(G_1(I_{LQ})) - 1||_2^2 + ||D_1(y^{bic}) - 1||_2^2 \tag{3}$$

为了保证 G_1 生成图像的稳定性,增加了生成器 G_2 并引入了循环一致性损失函数 L_{eye}^{LQ} :

$$L_{eye}^{LQ} = ||G_2(G_1(I_{LQ})) - I_{LQ}||_2^2 \tag{4}$$

为了保证 G_1 生成图像和输入图像的色彩一致,引入了恒等映射损失函数 L_{idt}^{LQ} :

$$L_{idt}^{LQ} = ||G_1(y^{bic}) - y^{bic}||_2^2 \tag{5}$$

最后,加入了总变分损失函数(Total Variation loss, TV loss) L_{TV}^{LQ} 来确保 G_1 生成图像边缘信息的稳定性:

$$L_{TV}^{LQ} = ||\nabla_h O_1||_2^2 + ||\nabla_v O_1||_2^2 \tag{6}$$

其中, ∇_h 和 ∇_v 分别代表水平方向和垂直方向的梯度算子。综上所述,域转换子网络的损失函数如下:

$$L_1 = L_{G1}^{LQ} + L_{D1}^{LQ} + \lambda_1 L_{eye}^{LQ} + \lambda_2 L_{idt}^{LQ} + \lambda_3 L_{TV}^{LQ} \tag{7}$$

其中, λ_1^{LQ} 、 λ_2^{LQ} 、 λ_3^{LQ} 为权重系数。

1.3 重建子网络

重建子网络的目的就是通过生成器 G_3 、 G_4 和鉴别器 D_2 ,将 O_1 从双三次降质域转到 I_{HQ} 所处的高质量图像域空间,得到模型的最终输出结果 O_2 。生成器 G_4 的网络结构与图 2 保持一致,鉴别器 D_2 的网络结构与图 3 保持一致。由于生成器 G_3 的性能对输出结果至关重要,因此单独设计了如图 4 所示的 G_3 的网络结构。在 G_3 中引入了图 5 所示的深度特




图 1 本文算法的框架图




图 2 域转换子网络中生成器结构




图 3 域转换子网络中鉴别器结构

征提取模块(Deep Feature Extraction Module, DFEM)来融合图像不同感受野的特征,提升超分辨率重建效果。在 DFEM 中,首先通过不同尺寸的卷积核来提取输入特征,通过采用空洞卷积的形式在不增加额外参数量的情况下扩大卷积的感受野。通过引入通道注意力机制对不同感受野下得到的图像特征进行加权,最后通过残差连接来得到 DFEM 的输出结果。另外,为了考虑网络中间输出结果对图像复原的影响,通过将第 2 和第 4 个 DFEM 的输入和输出特征分别进行组合之后来辅助图像的重建过程。在生成器 G_3 的末尾使用了反卷积层来实现生成图像空间分辨率的提升,反卷积层的个数与超分辨率的倍数相关。与域转换子网络类似, O_1 通过 G_3 输出图像 O_2 , 然后 O_2 和 I_{HQ} 一起送入鉴别器 D_2 中进行

判别,判断 O_2 是否和 I_{HQ} 属于同一域空间,从而调整 G_3 的参数,使 O_2 转换到 HQ 图像域空间。针对生成器 G_3 ,目的是能实现从双三次降质域到 HQ 图像域的转换,因此引入 MSE 损失函数 L_{MSE}^{SR} 在像素层面上约束重建效果:

$$L_{MSE}^{SR} = ||G_3(y^{bic}) - I_{HQ}||_2^2 \quad (8)$$

同时,为了提升重建的视觉效果,引入了感知损失函数 L_{per}^{SR} :

$$L_{per}^{SR} = ||\Phi(G_3(y^{bic})) - \Phi(I_{HQ})||_2^2 \quad (9)$$

其中, Φ 代表图像特征提取网络,通常采用 VGG 网络来进行图像特征提取。另外, G_3 生成的图像 O_2 需要与高质量图像 I_{HQ} 处于同一域空间,因此引入 GAN




图 4 重建子网络中生成器的网络结构




图 5 重建子网络中 DFEM 模块的网络结构

损失函数 L_{GAN}^{SR} :

$$L_{GAN}^{SR} = ||D_2(G_3(O_1)) - 1||_2^2 \quad (10)$$

$$L_{D2}^{SR} = ||D_2(G_3(O_1))||_2^2 + ||D_2(I_{HQ}) - 1||_2^2 \quad (11)$$

最后,通过引入TV损失函数得到了生成器 G_3 的总的损失函数 L_{G3}^{SR} 为:

$$L_{G3}^{SR} = L_{MSE}^{SR} + 1e^{-3} \times L_{per}^{SR} + 6e^{-3} \times L_{GAN}^{SR} + 2e^{-8} \times L_{TV}^{SR} \quad (12)$$

同样地,为了保证生成器 G_3 的稳定性,在重建子网络中引入循环一致性损失函数:

$$L_{cyc}^{SR} = ||G_4(G_3(O_2)) - I_{LQ}||_2^2 \quad (13)$$

综上所述,重建子网络的损失函数 L_2 可以表示为:

$$L_2 = L_{G3}^{SR} + L_{D2}^{SR} + \lambda^{SR} L_{cyc}^{SR} \quad (14)$$

其中, λ^{SR} 为权重系数。

1.4 讨论

区别于大部分基于GAN的图像复原算法,本文考虑了真实图像中可能存在位置的模糊和噪声,采取域转换的策略将图像超分辨率问题拆解成两个子问题,并设计了DFEM模块来提升网络的性能,通过大量的实验来证明了本文所提方法的有效性。

2 实验分析

2.1 实验参数设置

本文主要在NTIRE 2018 track 2数据集上进行训练和测试,并采取随机旋转和翻转等操作对训练集进行数据增广。本文主要针对4倍超分辨率进行训练,因此在训练过程中输入图像 I_{HQ} 和 I_{LQ} 的尺寸被随机裁剪为 128×128 和 32×32 。式(7)和式(14)中的权重系数 λ_1^{LQ} 、 λ_2^{LQ} 、 λ_3^{LQ} 、 λ^{SR} 分别设置为10、5、0.5和0.1。

本文采取PyTorch的深度学习框架在GTX2080Ti显卡来搭建和训练所提出的图像复原模型,网络训练过程中的Batch Size设置为8,采用Adam($\beta_1=0.9$, $\beta_2=0.999$, $\varepsilon=1e^{-8}$)优化算子来优化损失函数,初始的学习率设置为 $1e^{-4}$,然后每隔4 000个迭代过程降低为之前的一半。

2.2 实验结果分析

本文选取了ESRGAN^[14]、RCAN、ZSSR^[15]、Self-ExSR^[17]和BM3D^[16]+ESRGAN作为对比算法。ESRGAN^[14]和RCAN分别是基于GAN和CNN图像复原方法,ZSSR^[15]为无监督的图像复原算法,BM3D^[16]+ESRGAN融合了图像去噪和超分辨率重建两个过

程。同时选取了传统的双三次上采样(Bicubic)作为对比算法。在数字图像处理过程中通常采用的峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)来评价模型在像素层面上的重建效果。由于传统的图像相似性指标如结构相似索引测度(Structure Similarity Index, SSIM)等不能很好地解释人类视觉感知的细微差异,因此引入了LPIPS指标来从深度特征的角度衡量图像的相似性,并选取NTIRE 2018 track 2的测试集来验证所提出的模型性能。值得注意的是,由于SelfExSR^[17]模型是基于重建的传统图像复原方法,重建速度慢、实时性低,因此表格中没有列出它的客观指标,但是在视觉效果对比图中给出了其重建后的图像。

表1中给出了不同算法在NTIRE2018 track 2的100张测试图像上的平均PSNR和LPIPS指标,从指标中可以看到,由于本文所提出的是基于GAN的图像超分辨率算法,因此在传统客观指标(比如PSNR)上比传统的Bicubic算法低0.03 dB,即便如此,本文的算法在所有深度学习的对比算法中仍然取得了最高的PSNR指标,比如RCAN和ESRGAN的PSNR指标相较于本文算法分别低了0.12 dB和0.97 dB。虽然Bicubic算法取得了最好的PSNR结果,但是在更能评价图像深度特征相似性的LPIPS指标和视觉效果上,本文算法明显优于其他对比算法。具体地,RCAN和ESRGAN的LPIPS指标相较于本文算法分别高了0.322和0.256,表明本文算法的重建图像与原图之间的相似度最大,而在PSNR指标上表现最好的Bicubic算法则在LPIPS指标上表现最差。

表2中具体地列举了各个对比算法在NTIRE 2018 track 2数据集中前10张测试图像上的PSNR和LPIPS指标。从表2中可以看到,本文所提的算法在大部分的图像上的PSNR和LPIPS指标均取得了最好的效果。相比较于LPIPS指标,本文算法在PSNR指标上的优势并不明显,这主要是因为本文算法主要基于GAN网络来进行实现。实验结果表明,无论是在图像的深度特征层面还是在图像的像素层面,本文算法的重建结果最接近高质量参考图。

为了更好地评价本文所提出模型的有效性,图6~图7分别给出了不同对比算法的主观视觉效果和对应的客观评价参数。从对比图中可以看出,Bicubic恢复出来的图像边缘较为模糊,RCAN的重建效果比Bicubic的结果稍微清晰一些,其PSNR值

要略高一些,但是 LPIPS 指标上却比 Bicubic 的结果要差。SelfExSR 与 ZSSR 的重建效果之间看不出明显的区别,但是客观指标上 SelfExSR 要比 ZSSR 算法优越。ESRGAN 虽然重建出了更多的图像细节,但是其重建结果引入了更加严重的噪声。BM3D+ESRGAN 的复原结果过于平滑,导致丢失了大量的图像信息,细节部分很模糊。这说明了当降质模型不匹配时,基于深度学习的图像算法很难取得理想的超分辨率效果。然而,本文算法不仅有效地去除了图像中的噪声信息,同时也保留了原始图像的大量细节,取得了最佳的视觉效果和客观指标结果。

3 结论

本文基于 GAN 网络提出了一种针对真实图像的无监督图像超分辨率算法,考虑到真实图像中存

在未知的模糊和噪声,很难通过 GAN 直接实现从 LQ 图像分布到 HQ 图像分布的转换,因此提出的图像的超分辨率算法包含域转换子网络和重建子网络两个部分。在域转换子网络中,经过双三次下采样得到的低分辨率图像与真实 LQ 输入图像构成不配对的训练集,通过 GAN 首先将输入的 LQ 图像的降质类型转换为双三次下采样。在重建子网络部分,将域转换子网络的输出结果进一步通过 GAN 网络迁移为高质量图像。为了进一步提升重建子网络的效果,本文设计了 DFEM 模块来融合不同感受野提取的特征,通过通道注意力机制对图像特征进行加权。实验结果表明,本文算法在处理含有未知噪声和模糊的真实低分辨率图像时,无论在客观评价指标还是直观视觉效果上,都取得了较为理想的结果。

表 1 不同对比算法结果的 PSNR(dB)/LPIPS 比较

测试集	评价指标	对比算法					
		Bicubic	RCAN	ZSSR	ESRGAN	BM3D+ESRGAN	本文算法
NTIRE	PSNR ↑	20.03	19.88	19.81	19.03	19.77	20.00
2018 track2	LPIPS ↓	0.786	0.772	0.754	0.703	0.667	0.447

表 2 不同对比算法在测试集 NTIRE 2018 track2 前 10 张重建结果的 PSNR(dB)/LPIPS 比较

测试图像	评价指标	对比算法					
		Bicubic	RCAN	ZSSR	ESRGAN	BM3D+ESRGAN	本文算法
0801	PSNR ↑	21.77	21.68	21.56	21.14	20.55	22.53
	LPIPS ↓	0.656	0.659	0.642	0.654	0.779	0.451
0802	PSNR ↑	27.74	26.83	26.88	21.83	26.3	21.44
	LPIPS ↓	0.357	0.347	0.368	0.630	0.455	0.269
0803	PSNR ↑	20.54	20.28	20.20	18.78	20.76	21.64
	LPIPS ↓	0.654	0.707	0.702	0.932	0.384	0.492
0804	PSNR ↑	20.10	20.00	19.92	18.86	19.35	20.68
	LPIPS ↓	0.786	0.757	0.726	0.681	0.714	0.391
0805	PSNR ↑	19.52	19.43	19.32	18.90	19.16	22.50
	LPIPS ↓	0.871	0.892	0.896	0.642	0.823	0.477
0806	PSNR ↑	22.38	22.18	22.08	21.05	21.99	22.66
	LPIPS ↓	0.728	0.732	0.726	0.725	0.520	0.378
0807	PSNR ↑	16.91	16.72	16.72	16.13	16.95	15.00
	LPIPS ↓	0.941	0.884	0.889	0.704	0.975	0.643
0808	PSNR ↑	20.20	20.18	20.07	19.42	19.76	20.39
	LPIPS ↓	0.707	0.716	0.689	0.633	0.532	0.419
0809	PSNR ↑	22.49	22.13	22.06	20.94	22.64	20.72
	LPIPS ↓	0.644	0.649	0.652	0.722	0.752	0.465
0810	PSNR ↑	19.73	19.48	19.46	18.93	20.83	16.67
	LPIPS ↓	0.918	0.929	0.932	0.856	0.703	0.599




图 6 不同算法在 0801 图像上的重建结果




图 7 不同算法在 0822 图像上的重建结果

参考文献

- [1] DONG C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution[C]//European Conference on Computer Vision, 2014: 184–199.
- [2] KIM J, KWON L J, MU L K. Accurate image super-resolution using very deep convolutional networks[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646–1654.
- [3] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017: 136–144.
- [4] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]//European Conference on Computer Vision, 2018: 286–301.
- [5] ZHANG K, GOOL V L, TIMOFTE R, et al. Deep unfolding network for image super-resolution[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2020: 3214–3223.
- [6] ISOLA P, ZHU J, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]//P IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125–1134.
- [7] ZHANG K, ZUO W, CHEN Y, et al. Beyond a gaussian denoiser: residual learning of deep cnn for image denoising[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142–3155.
- [8] PRAJAPATI K, CHUDASAMA V, PATEL H, et al. Unsupervised single image super-resolution network (usisresnet) for real-world data using generative adversarial network[C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2020: 464–465.
- [9] YOU C, LI G, ZHANG Y, et al. CT super-resolution GAN constrained by the identical, residual, and cycle learning ensemble (GAN-CIRCLE)[J]. IEEE Transactions on Medical Imaging, 2019, 39(1): 188–203.
- [10] LUGMAYR A, DANELLJAN M, TIMOFTE R. Unsupervised learning for real-world super-resolution[C]//IEEE International Conference on Computer Vision Workshop, 2019: 3408–3416.
- [11] CHEN S, HAN Z, DAI E, et al. Unsupervised image super-resolution with an indirect supervised path[C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2020: 468–469.
- [12] MAEDA S. Unpaired image super-resolution using pseudo-supervision[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2020: 291–300.
- [13] KIM G, PARK J, LEE K, et al. Unsupervised real-world super resolution with cycle generative adversarial network and domain discriminator[C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2020: 456–457.
- [14] WANG X, YU K, WU S, et al. Esrgan: enhanced super-resolution generative adversarial networks[C]//European Conference on Computer Vision Workshops, 2018: 1–9.
- [15] SHOCHER A, COHEN N, IRANI M. “Zero-shot” super-resolution using deep internal learning[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3118–3126, 35.
- [16] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising with block-matching and 3D filtering[C]//Image Processing: Algorithms and Systems, Neural Networks, and Machine Learning. International Society for Optics and Photonics, 2006, 6064: 606414.
- [17] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2015: 5197–5206.

(收稿日期: 2021-11-03)

作者简介:

赵志博(1996–), 男, 在读研究生, 主要研究方向: 图像超分辨率重建。

滕奇志(1961–), 女, 博士, 教授, 主要研究方向: 图像处理和图像通信。

任超(1988–), 通信作者, 男, 博士, 副研究员, 主要研究方向: 图像处理和图像通信。E-mail: chaoren@scu.edu.cn。

版权声明

经作者授权，本论文版权和信息网络传播权归属于《信息技术与网络安全》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《信息技术与网络安全》编辑部
中国电子信息产业集团有限公司第六研究所