引用:许宾,王宏兴. 基于多尺度的生成对抗网络图像超分辨率重建算法[J]. 聊城大学学报(自然科学版),2026,39(6):847-854.
Citation: Xu Bin, Wang Hongxing. Multi-scale generative adversarial network-based algorithm for image super-resolution reconstruction[J]. Journal of Liaocheng University (Natural Science Edition),2026,39(6):847-854.
文章编号 1672-6634(2026)06-0847-08 **DOI** 10.19728/j.issn1672-6634.2025030002

基于多尺度的生成对抗网络图像超分辨率重建算法

许宾[1],王宏兴[2]

(1. 广西职业师范学院 教育学院,广西 南宁 530006;2. 广西民族大学 数学科学学院,广西 南宁 530006)

摘要 针对深度学习超分辨率重建中存在多尺度特征融合效率低,空间自适应能力不足导致的纹理细节缺失问题,本研究提出一种多尺度生成对抗网络增强方法。生成器采用 U-net 架构,通过嵌入自适应特征模块和多尺度通道混合模块实现跨层级特征交互与多分辨率信息整合。在损失函数设计中引入焦点频率损失,强化高频细节的优化约束。实验表明,所提模型在标准测试集上的 PSNR 和 SSIM 指标显著优于现有对比模型,重建后的图像更加清晰,视觉效果更好。

关键词 自适应特征模块;焦点频率损失;多尺度通道混合;生成对抗网络
中图分类号 TP391.41 **文献标志码** A

Multi-scale generative adversarial network-based algorithm for image super-resolution reconstruction

XU Bin[1], WANG Hongxing[2]

(1. School of Education, Guangxi Vocational Normal University, Nanning 530006, China; 2. School of Mathematics Sciences, Guangxi Minzu University, Nanning 530006, China)

Abstract To address the issues of low efficiency in multi-scale feature fusion and insufficient spatial adaptability leading to texture detail loss in deep learning-based super-resolution reconstruction, this study proposes an enhanced multi-scale generative adversarial network. The generator employs a U-net architecture incorporating an Adaptive Feature Module and a Multi-scale Channel Mixing Module to achieve cross-level feature interaction and multi-resolution information integration. A Focal Frequency Loss is introduced in the loss function design to enhance optimization constraints on high-frequency details. Experimental results demonstrate that the proposed model significantly outperforms existing benchmark models in PSNR and SSIM metrics on standard test datasets, producing reconstructed images with enhanced clarity and visually superior results.

Keywords adaptive feature module; focal frequency loss; multi-scale channel mixing; generative adversarial network

---

收稿日期:2025-03-02
基金项目:国家自然科学基金项目(2112461089)资助
通信作者:王宏兴,男,汉族,博士,教授,研究方向:数值计算,E-mail: winghongxing0902@163.com。

0 引言

图像超分辨率重建(Image Super Resolution,ISR),是计算机视觉与图像处理领域的重要研究领域,主要致力于从低分辨率图像(Low Resolution,LR)中恢复出高分辨率图像(High Resolution,HR)。图像超分辨率修复重建的过程要重建图像的宏观结构,还必须捕捉到图像的微观细节和边缘纹理,从而生成更高质量的图像。

图像超分辨率重建的方法可以分为基于传统的插值重建和基于深度学习的重建。基于插值的重建方法包括最近邻近值[1],双线性插值[2]和双三次插值[3]。对深度学习的超分辨率重建方法的技术演进脉络进行了梳理。Dong 团队[4]开创性地构建了端到端映射的三层卷积架构(SRCNN),奠定了深度学习在该领域应用的基础,但其存在细节重构能力不足与训练效率低下的局限性。EDSR 模型[5]通过移除批量归一化层与优化残差块设计,实现了模型容量与训练稳定性的协同提升,但在复杂纹理场景仍存在过度平滑现象。随着注意力机制的引入,RCAN 模型[6]构建通道注意力引导的特征选择机制,实现特征通道的动态加权优化,但其空间关联建模能力仍待加强。在生成式模型方向,SRGAN[7]率先将对抗训练范式引入超分辨率领域,通过感知损失函数驱动视觉质量优化。Lu 等[8]提出了一种改进的 U-net 架构,结合混合梯度损失函数(Mixed Gradient Loss),旨在通过优化网络结构与损失设计,提升高频细节的恢复能力,同时抑制重建伪影。ESRGAN[9]采用密集连接模块与边缘保持约束,在结构保真度方面实现突破。Thaker 等[10]提出的 FASR-GAN 创新性地融合残差特征注意力模块,通过显著性特征引导机制实现边缘与纹理的精准重建,在计算效率与重建质量间取得显著平衡。Li 等学者[11]研发了一种结合多尺度双注意力机制的残差密集 GAN 结构(MARDGAN),该模型通过多路径分支架构实现图像特征提取,其创新点在于引入通道与空间双重注意力机制,通过特征复用策略有效增强了高频细节的还原能力,从而提升重建图像的真实性表现。Basu 等[12]通过创新的特征融合策略和散度度量,显著提升了 GAN 在图像超分辨率中的性能,平衡了生成质量与计算效率。上述方法在图像超分辨率修复任务中已经取得了显著的效果,但是仍然会存在多尺度特征融合效率低,空间自适应能力不足,损失函数对频率细节的约束薄弱等问题。针对上述问题,本文提出了一种基于多尺度的生成对抗网络图像超分辨率重建模型,在网络结构上,生成器采用 U-net 架构,并嵌入自适应特征模块(SAFMM)和多尺度通道混合模块(MCCM)。SAFMM 模块能够根据图像内容的空间变化自适应地调整特征响应,从而实现对关键区域的聚焦;MCCM 模块通过高效的通道分离与混合操作,实现了跨层级、多分辨率信息的深度融合。在损失函数上,引入了焦点频率损失(Focal Frequency Loss),该损失函数在频域中对重建图像与真实图像的高频成分进行显式且强化的约束,迫使生成器优先恢复对人类视觉系统敏感的边缘和纹理细节。本文通过充分的实验表明,所提模型在多个标准测试集上,其 PSNR 和 SSIM 指标均显著优于现有方法,并且重建后的图像在视觉上展现出更清晰的纹理和更自然的视觉效果。

1 本文模型

生成对抗网络[13](Generative Adversarial Networks,GAN)是由 Ian Goodfellow 等人受到零和博弈的启发而提出的一种机器学习模型。生成对抗网络(GAN)采用双模块架构:生成器通过噪声输入生成拟真数据,判别器则对输入数据的真实性进行二值判别(0 为生成,1 为真实)。二者通过对抗性博弈实现动态优化,其中生成器旨在使判别器无法区分其输出与真实数据,判别器则不断强化分类精度。生成对抗网络的结构如图 1 所示。

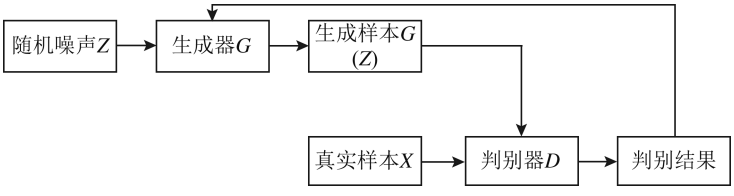


图 1 生成对抗网络的结构图

Fig. 1 Generative adversarial network architecture

生成器以随机噪声为输入生成图像,判别器输出概率值表征输入真实性,二者在迭代对抗中提升整体模

型性能。目标函数为 $\min\limits_{G}\max\limits_{D}V(D,G)=E_{x\sim P(x)}[\log D(x)]+E_{z\sim p(z)}[\log(1-D(G(z)))]$，其中，$x$ 为真实样本；z 为输入噪声；G 生成的去噪图像为 $G(z)$，$E_{x\sim p(x)}$ 表示对真实样本进行期望操作，$E_{z\sim p(z)}$ 表示对生成样本进行期望操作；$D(x)$ 表示判别器判定真实图像的概率；$G(x)$ 表示生成器输出的样本；$V(D,G)$ 表示真实数据和生成输入的差异程度。

1.1　通道混合模块与空间自适应特征混合模块

通道混合模块由激活函数和两个卷积层组成。空间自适应特征调制模块（Spatially-Adaptive Feature Modulation，SAFM）[14]，可以根据图像内容的空间变化自适应地调整特征，识别图像中的关键区域，对图像的不同区域应用不同的注意力权重。本文设计的空间自适应特征混合模块（SAFMM）模块如图 2 所示。

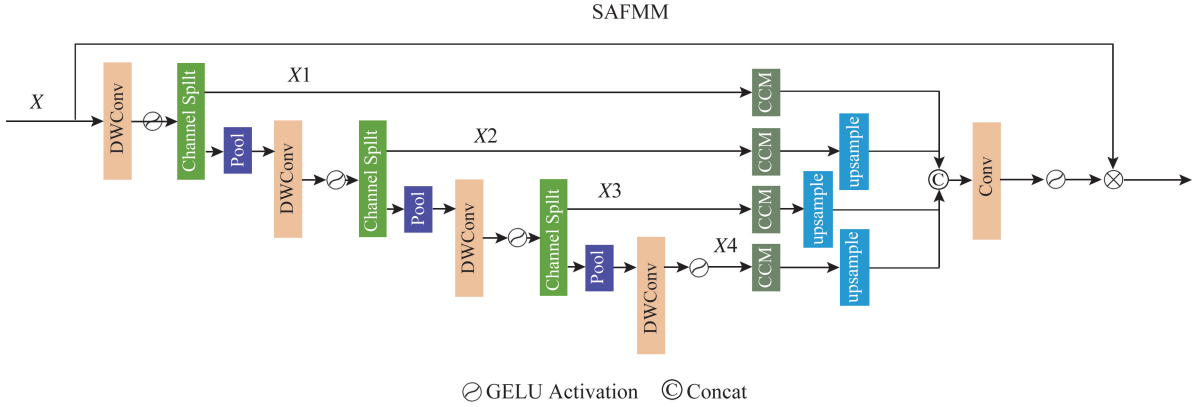


图 2　空间自适应特征混合模块结构图

Fig. 2　Architectural diagram of the spatially-adaptive feature mixing module

1.2　多尺度分离通道混合模块

多尺度分离通道混合模块（MCCM），是在卷积通道中加入了多尺度特征提取模块和通道分离模块。结构如图 3 所示，MCCM 有效地融合了多尺度信息并提高了通道利用率，增强了模型的空间表达能力。

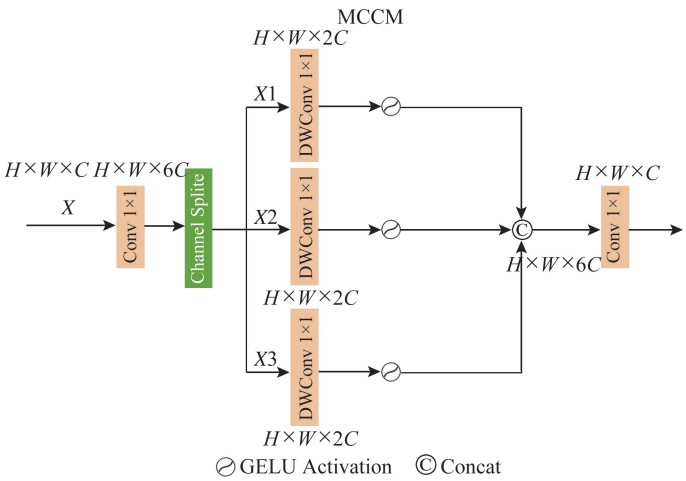


图 3　多尺度分离通道混合模块结构图

Fig. 3　Architectural diagram of the multi-scale separation channel mixing module

1.3　特征混合模块

特征混合模块（FMM）由 SAFMM 和 MCCM 组成，并用 LayerNorm[15] 进行归一化操作，并引入残差连接。如图 4 所示。

SAFMM 专注于通过空间自适应调制确定“在何处融合”，为特征赋予空间权重；MCCM 则专注于通过多尺度操作解决“如何融合”，构建丰富的上下文信息。SAFMM 和 MCCM 解决了高效特征利用中的两个关键问题，共同形成了一条完整的优化路径。采用 Layer-

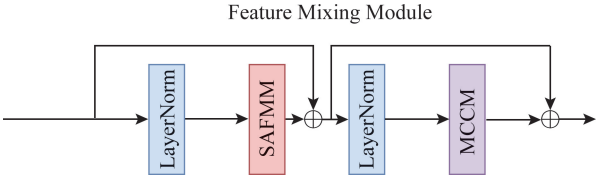


图 4　特征混合模块结构图

Fig. 4　Architectural diagram of the feature mixing module

Norm 可以提高训练的稳定性,加快训练速度;引入残差连接可以提高模型的鲁棒性。

1.4 生成器

本文设计的生成器如图 5 所示。生成器为 U-net 类型,首先采用卷积层作为浅层特征提取层,然后输入 FFM 模块,将输出与浅层特征提出相加,输入 Upsampler 模块进行超分辨率重建,输出结果。

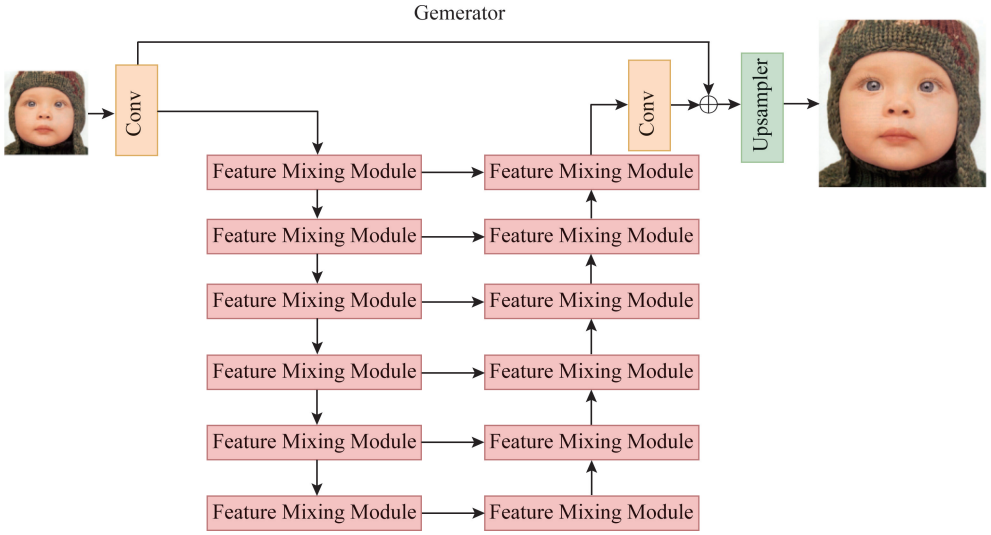


图 5 生成器结构图

Fig. 5 Architectural diagram of the generator

1.5 判别器

本文设计的判别器网络如图 6 所示。BN[16]层在判别任务中表现比较好,能够稳定网络,因此在卷积层和激活函数层中间添加 BN 层。

1.6 损失函数

1.6.1 对抗损失。对抗生成网络的损失函数 L_G 是由生成器和判别器的综合对抗损失组成,具体公式为 $L_G = E_{I^{HR}\sim P(I^{HR})}[\log D(I^{HR})] + E_{I^{LR}\sim P_G(I^{LR})}[\log(1 - D(G(I^{LR})))]$,式中 I^{HR} 表示真实的图像,I^{LR} 表示低分辨率图像。

1.6.2 内容损失。对图像进行超分重建,是将生成器超分重建后的图像与真实图像进行像素误差判断。本文中,内容损失采用 MSE 损失函数 $L_{MSE} = \frac{1}{W \times H}\sum_{i=1}^{W}\sum_{j=1}^{H}(G(I^{LR}) - I^{HR})^2$,式中 $G(I^{LR})$ 表示生成器重建的图像。

1.6.3 感知损失。本文采用预训练好的 VGG_{16}[17]网络 V_{GG} 计算感知损失,感知损失函数 $L_{perceptual}$ 可以定义为两个特征提取结果之间的均方误差 $M_{SE}(\cdot)$,表达式为 $L_{perceptual} = M_{SE}(V_{GG}(G(I^{LR})) - V_{GG}(I^{HR}))$。

1.6.4 总变分损失。总变分损失(Total Variation Loss) L_{TV} 有助于减少图像中的噪声,还可以避免局部区域的过度细化而导致的不自然边缘,使得图像在视觉上更加自然,表达式为:$L_{TV} = \sum_{i=1}^{N}(\| \nabla_h G_{\theta G}(I^{LR}) - \nabla_h I^{HR} \|_1 + \| \nabla_v G_{\theta G}(I^{LR}) - \nabla_v I^{HR} \|_1)$,式中 ∇_h 表示图像的水平梯度,∇_v 表示图像的垂直梯度,$G_{\theta G}(I^{LR})$ 表示生成器重建的图像。

1.6.5 焦点频率损失。焦点频率损失(Focal Frequency Loss FFL)会更关注图像的高频信息,而高频信息通常与图像的细节和边缘相关联,因此,焦点频率损失 L_{FEL} 有助于恢复图像的细节。具体公式如下

$$\omega(u,v) = |F_r(I^{HR},G(I^{LR})) - F_f(I^{HR},G(I^{LR}))|^{\alpha},$$

$$L_{FFL} = \frac{1}{H \times W}\sum_{i=1}^{H}\sum_{j=1}^{W}|F_r(I^{HR},G(I^{LR})) - F_f(I^{HR},G(I^{LR}))|^2,$$

式中 $\omega(\cdot)$ 表示实数频域和复数频域的差异,$F_r(\cdot)$ 表示实数频率,$F_f(\cdot)$ 表示复数频率。

1.6.6　综合损失。生成对抗网络的生成损失为 $L=\lambda_1 L_G+\lambda_2 L_{MSE}+\lambda_3 L_{perceptual}+\lambda_4 L_{TV}+\lambda_5 L_{FFL}$，式中 λ_i，$i=1,2,\cdots,5$，为权重系数。

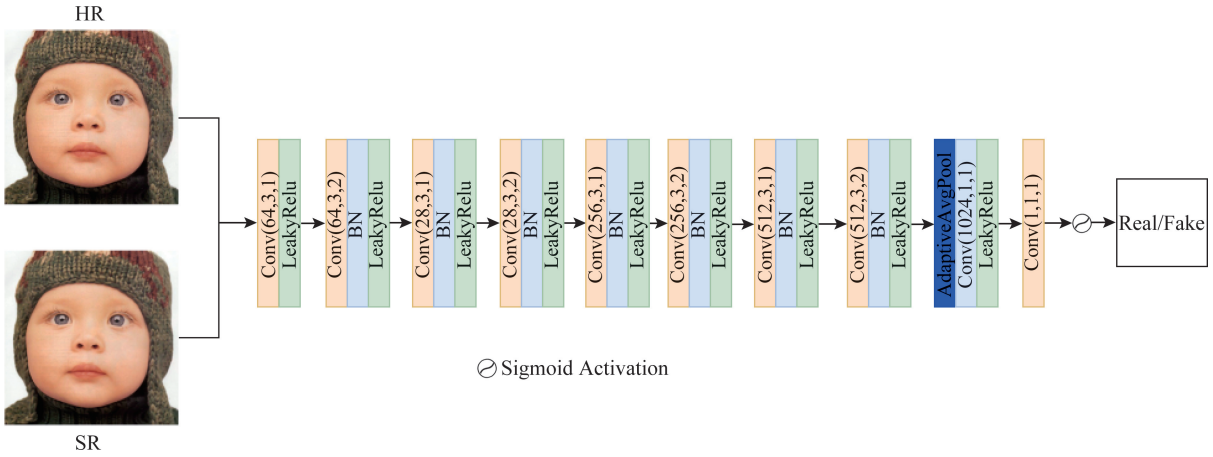


图 6　判别器结构图

Fig. 6　Architectural diagram of the discriminator

2　实验结果分析

2.1　数据集和实验环境

本实验使用 PyTorch1.11 框架，并在一台配置为 Intel Core i9-13900K CPU（主频 3.00 GHz，内存大小 48GB）以及 NVIDIA 4090 GPU（显存总大小 24 GB，CUDA 版本为 11.8）的设备上进行实验。实验使用 DIV2K 数据集作为主要的训练数据集，其中包含 800 张用于图像超分辨率修复的高质量图像。为了使重建后的图像具有更多丰富的纹理，使用 Flickr2K 数据集来扩充数据集，扩充后训练数据集一共包括 3 450 张图像，验证集为 100 张的 DIV2K 图像。测试集使用 5 个广泛的基准数据集 Set5、Set14、BSDS100、Urban100 和 Manga109。

2.2　实验数据分析

验证本文提出的重建方法的有效性，本文选取了 6 种算法进行对比实验，算法分别是：Bicubic[3]、EDSR[9]、RCAN[11]、SRGAN[12]、ESRGAN[13] 和 FASRGAN[14]。平均 PSNR 值和 SSIM 值分别如表 1 和表 2 所示，由表 1 和表 2 可以看出本文提出的方法在×2、×4、×8 的重建任务中效果都优于其它算法。

图像超分辨率修复后进行细节实验对比，选取对比图像的区域进行超分辨率修复后进行纹理细节对比。在 4 倍超分辨率修复实验中，选择 Urban100 中的 img042。在 8 倍超分辨率修复实验中，选择 Urban 中的 img082。如图 7、8 所示。

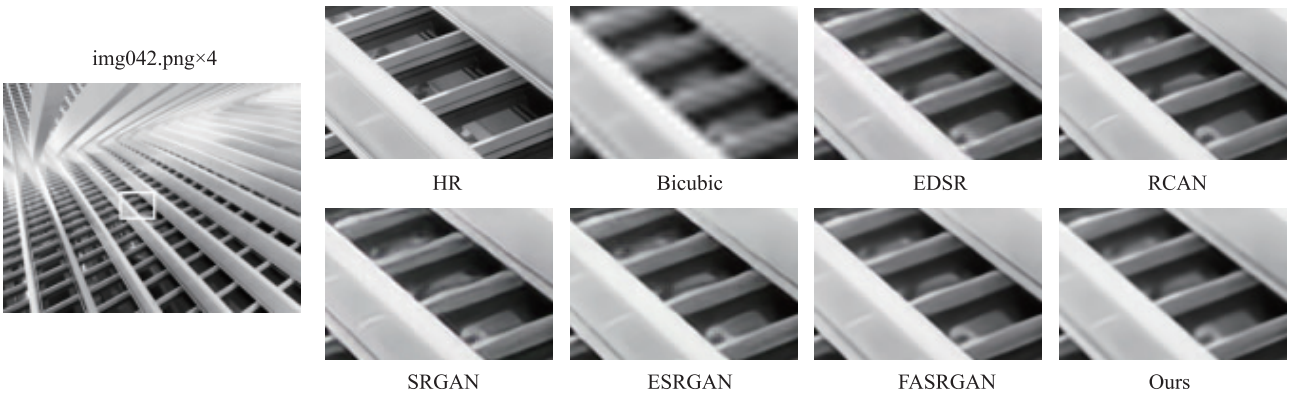


图 7　4 倍重建图像细节对比

Fig. 7　Visual comparison of details in ×4 reconstructed images

为验证本文提出的重建方法在复杂环境下的有效性,本文选取了 Rain100L 和 LOL 数据集进行对比实验,对比算法分别是:ESRGAN[13]和 FASRGAN[14]。结果如表 3 所示。

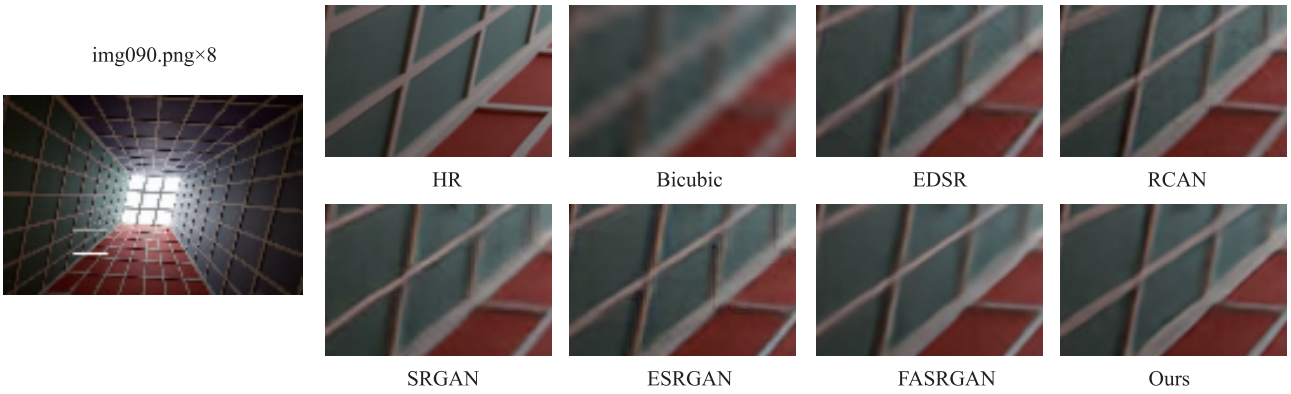


图 8　8 倍重建图像细节对比

Fig. 8　Visual comparison of details in ×8 reconstructed images

表 1～3 数据表明,本文提出的方法不仅在理想数据集上表现优异,在面对真实世界中的复杂退化时,也展现出更强的鲁棒性和泛化能力。

2.3　消融试验

消融实验中,引入策略 A～D,A 表示 SAFM 中添加 CCM,B 表示多尺度通道混合模块,C 表示 FFLoss,D 表示 LN。用测试集 Set5 和 Set14 来验证试验效果,如表 4 所示。通过消融试验对比,验证了本文提出的模型可以提高图像超分辨率修复后的效果。

表 1　不同算法在不同测试集上的平均 PSNR 值(dB)

Tab. 1　Average PSNR (dB) values of different algorithms across test datasets

Methods	Scale	Set5	Set14	BSD100	Urban100	Manga109
Bicubic		32.04	28.71	28.40	25.61	29.68
EDSR		35.17	31.30	30.52	29.60	35.20
RCAN		35.46	31.43	30.62	30.18	35.95
SRGAN	2	34.80	30.87	30.20	29.11	34.85
ESRGAN		35.31	30.37	30.58	29.90	35.62
FASRGAN		35.63	31.61	30.79	30.33	36.15
Ours		**35.82**	**31.93**	**30.87**	**30.55**	**36.70**
Bicubic		26.88	24.46	24.74	21.8	23.52
EDSR		29.62	26.33	26.03	24.14	27.90
RCAN		30.04	26.69	26.23	24.72	28.72
SRGAN	4	29.46	26.31	26.00	24.05	27.71
ESRGAN		29.81	26.50	26.15	24.44	28.33
FASRGAN		30.21	26.76	26.30	24.72	28.86
Ours		**30.42**	**26.89**	**26.36**	**24.86**	**29.13**
Bicubic		22.86	21.53	22.46	19.38	19.95
EDSR		24.73	22.88	23.36	20.75	22.38
RCAN		24.91	23.06	23.45	20.98	22.75
SRGAN	8	24.83	22.95	23.41	20.84	22.62
ESRGAN		24.89	23.06	23.44	20.92	22.72
FASRGAN		25.01	23.12	23.52	21.07	22.93
Ours		**25.18**	**23.22**	**23.61**	**21.07**	**23.16**

表 2　不同算法在不同测试集上的平均 SSIM 值

Tab. 2　Average SSIM values of different algorithms across test datasets

Methods	Scale	Set5	Set14	BSD100	Urban100	Manga109
Bicubic		0.920 3	0.865 0	0.850 8	0.842 5	0.927 2
EDSR		0.945 1	0.899 9	0.897 0	0.915 0	0.962 7
RCAN		0.946 1	0.902 2	0.898 7	0.920 8	0.965 8
SRGAN	2	0.941 6	0.893 6	0.889 4	0.907 5	0.958 0
ESRGAN		0.945 2	0.900 4	0.897 3	0.917 6	0.964 3
FASRGAN		0.949 2	0.905 2	0.901 3	0.923 4	0.968 2
Ours		**0.950 0**	**0.907 1**	**0.902 3**	**0.926 2**	**0.969 4**
Bicubic		0.792 8	0.700 5	0.666 1	0.655 2	0.772 3
EDSR		0.861 9	0.760 8	0.725 3	0.762 2	0.866 1
RCAN		0.871 2	0.770 0	0.732 4	0.782 4	0.879 5
SRGAN	4	0.861 2	0.759 7	0.724 9	0.761 0	0.860 7
ESRGAN		0.866 4	0.766 3	0.729 1	0.773 4	0.874 5
FASRGAN		0.874 7	0.775 0	0.735 0	0.783 9	0.885 9
Ours		**0.877 8**	**0.777 2**	**0.737 8**	**0.788 5**	**0.887 6**
Bicubic		0.598 6	0.534 1	0.510 0	0.478 4	0.606 8
EDSR		0.698 2	0.596 5	0.554 8	0.566 4	0.701 3
RCAN		0.704 2	0.601 0	0.559 2	0.577 6	0.711 7
SRGAN	8	0.707 6	0.603 8	0.558 4	0.576 2	0.721 5
ESRGAN		0.708 2	0.605 1	0.559 2	0.578 3	0.720 1
FASRGAN		0.719 3	0.613 7	0.565 2	0.589 5	0.735 6
Ours		**0.725 7**	**0.617 3**	**0.570 3**	**0.593 2**	**0.740 3**

表 3　Rain100H 和 LOL 数据集上的 PSNR 和 SSIM 值

Tab. 3　PSNR and SSIM Values on the Rain100H and LOL Datasets

Methods	Scale	Rain100L		LOL	
		PSNR	SSIM	PSNR	SSIM
ESRGAN		25.04	0.721 6	39.63	0.926 8
FASRGAN	4	25.19	0.729 1	39.82	0.927 6
Ours		25.22	0.719 2	39.89	0.929 2
ESRGAN		22.06	0.488 9	37.28	0.886 1
FASRGAN	8	22.11	0.494 0	37.74	0.895 3
Ours		22.15	0.496 5	37.80	0.897 0

表 4　4 倍消融试验对比

Tab. 4　Comparison of ×4 ablation studies

Test Set	Set5		Set14	
Configuration	PSNR	SSIM	PSNR	SSIM
A+B+C+D	**30.42**	**0.877 8**	**26.89**	**0.777 2**
A+B+C	30.28	0.876 7	26.86	0.776 0
A+B+D	30.01	0.868 6	26.61	0.766 4
B+C+D	30.25	0.874 8	26.71	0.772 7
A+C+D	30.11	0.873 3	26.65	0.771 5
C+D	30.03	0.872 2	26.65	0.771 7

2.4　定量分析

在 U-net 结构中,探究 FMM 的数量对模型的影响,本文选取 FMM 的数量为 4,8,10,12,14 进行分析,在测试集 Set5 和 Set14 上测试,如表 5 所示,选择 FMM 数量为 12 作为模型的默认值。

表 5 FMM 数量对性能的影响

Tab. 5 Impact of the number of FMMs on performance

FMM	Params/M	FLOPs/G	Set5		Set14	
			PSNR	SSIM	PSNR	SSIM
4	0.654	38.12	29.88	0.869 0	26.50	0.766 6
8	2.944	177.15	30.20	0.872 2	26.72	0.770 7
10	5.12	308.22	30.24	0.871 8	26.86	0.772 5
12	8.20	494.59	30.42	0.877 8	26.89	0.777 2
14	12.349	746.5	30.42	0.878 5	26.89	0.777 1

3 结束语

为了提高图像超分辨率修复的纹理细节信息,本文提出了基于生成对抗网络的超分辨率重建模型,在生成器中采用 U-net 结构,并引入自适应特征模块和多尺度通道注意力,损失函数增加焦点频率损失,并加入 LN 归一化。实验结果表明,本文提出的模型与 EDSR,RCAN,SRGAN,ESRGAN,FASRGAN 相对比,在 PSNR 和 SSIM 指标上都有提高,特别在 4 倍和 8 倍重建中,SSIM 提高明显,重建后的图像,纹理更加清晰。此外,在 Rain100H 和 LOL 等复杂场景数据集上的额外实验进一步证明,本模型具有良好的鲁棒性和实际应用潜力。

参 考 文 献

[1] Chang H, Yeung D Y, Xiong Y, et al. Super-resolution through neighbor embedding[C]//Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition,2004:1-1.

[2] Kirkland E J. Bilinear Interpolation[M]//Advanced Computing in Electron Microscopy. Boston, MA: Springer US, 2010: 261-263.

[3] Han D Y. Comparison of commonly used image interpolation methods[C]//Proceedings of the 2nd International Conference on Computer Science and Electronics Engineering,2013,319: 1556-1559.

[4] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution[C]//FLEET D, PAJDLA T, SCHIELE B, et al Eds. Computer Vision-ECCV 2014. 2014Cham: Springer, 2014: 184-199.

[5] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017: 136-144.

[6] Zhang Y L, Li K P, Li K, et al. Image super-resolution using very deep residual channel attention networks[C]//Proceedings of the European conference on Computer Vision (ECCV). 2018: 286-301.

[7] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. 2017: 105-114.

[8] Lu Z Y, Chen Y. Single image super-resolution based on a modified U-net with mixed gradient loss[J]. Signal, Image and Video Processing, 2022, 16(5): 1143-1151.

[9] Wang X T, Yu K, Wu S X, et al. ESRGAN: enhanced super-resolution generative adversarial networks[C]//Proceedings of the European Conference on Computer Vision (ECCV) Workshops. 2019: 63-79.

[10] Thaker A, Mahajan A, Sanyal A, et al. FASRGAN: feature attention super resolution generative adversarial network[C]//DAS S, SAHA S, COELLO COELLO C A, et al Eds. Advances in Data-Driven Computing and Intelligent Systems. 2024Singapore: Springer, 2024: 231-240.

[11] Li H A, Wang D, Zhang J, et al. Image super-resolution reconstruction based on multi-scale dual-attention[J]. Connection Science, 2023, 35(1): 2182487.

[12] Basu A, Bose K, Mullick S S, et al. Fortifying fully convolutional generative adversarial networks for image super-resolution using divergence measures[EB/OL]. arXiv preprint arXiv:arXiv:2404.06294, 2024.

[13] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. arXiv preprint arXiv:arXiv:1406.2661, 2014.

[14] Sun L, Dong J X, Tang J H, et al. Spatially-adaptive feature modulation for efficient image super-resolution[EB/OL]. arXiv preprint arXiv:arXiv:2302.13800,2023.

[15] Ba J L, Kiros J R, Hinton G E. Layer normalization[EB/OL]. arXiv preprint arXiv: arXiv:1607.06450, 2016.

[16] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[EB/OL]. arXiv preprint arXiv: arXiv:1502.03167, 2015.

[17] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. arXiv preprint arXiv:arXiv:1409.1556, 2014.

(责任编辑:刘庆松)