

一种基于生成对抗网络的感知增强型电力设备 红外图像超分辨率模型

李云洪¹,徐十三悦¹,童超²,胡蕾¹,伍湖^{1*}

(1.江西师范大学人工智能学院(数字产业学院),江西 上饶 334000;2.国网江西省电力有限公司电力科学研究院,江西 南昌 330096)

摘 要:针对电力设备监测红外图像分辨率低的问题,提出一种基于生成对抗网络的感知增强型电力设备红外图像超分辨率模型,在生成器端构建双路径融合注意力架构,在原始分辨率与下采样分支并行提取多尺度依赖,结合双层残差结构(residual in residual dense block,RRDB)密集残差块,实现全局结构与局部细节的协同重建;在判别器端构建门控细粒度通道-空间(gated fine-grained channel-spatial,GFCS)判别器,在U-Net跳跃连接中嵌入细粒度通道-空间注意力(fine-grained channel-spatial attention,FCSA)模块与注意力门控模块,通过并行建模全局-局部通道依赖关系与方向敏感空间上下文,强化对设备发热区域关键特征的判别能力;实验中采用符合人眼感知的NIQE和LPIPS指标,在电力设备伪彩色红外图像上开展的多倍率超分辨率实验。结果表明,所提模型的NIQE和LPIPS指标分别达到5.568和0.054 1,消融实验进一步验证了各个模块的有效性。

关键词:红外图像;超分辨率重建;生成对抗网络;增强感知

中图分类号:TP 727;TP 391 **文献标志码:**A **文章编号:**1006-348X(2026)03-0076-06

0 引言

近年来,变电站巡检人员已开始利用热红外相机采集变基于卷积神经网络的超分辨率,其优化过程易导向过度平滑的重建结果,感知质量欠佳。为此,超分辨率生成对抗网络(super-resolution generative adversarial network, SRGAN)将生成对抗网络(generative adversarial network, GAN),引入超分辨率任务,构建了生成器与判别器的对抗博弈框架:生成器以低分辨率图像为输入,重建高分辨率结果,判别器则负责甄别真伪图像分布,从而引导重建结果逼近真实图像流形^[1]。

通过对SRGAN的生成网络、判别网络及损失函数三个方面进行升级,增强型超分辨率生成对抗网络(enhanced super-resolution generative adversarial network, ESRGAN)有效增强了纹理细节的恢复能力,显著提升

了图像重建的真实感^[2];而进一步增强型超分辨率生成对抗网络(further improving enhanced super-resolution generative adversarial network, ESRGAN+)则着眼于生成器部分的改进,具体策略是在密集块中部署层级残差跳跃,对ESRGAN进行了针对性优化^[3];基于梯度指导的结构保留超分辨率(structure-preserving super resolution with gradient guidance, SPSR)方法进一步引入了梯度特征,凭借额外的梯度分支,确立了从低分辨率图像到高分辨率图像的梯度特征映射机制^[4];盲超分辨率生成对抗网络(blind super-resolution generative adversarial network, BSRGAN)率先提出手工设计的随机置换退化模型,在模糊、降采样与噪声的基础上大幅扩展退化空间^[5]。

针对电力设备红外图像的特性,基于GAN网络,文中设计了一种双路径融合注意力生成器网络和门控细粒度通道-空间判别器网络。

收稿日期:2026-02-10

基金项目:国家自然科学基金项目(62362040);江西省自然科学基金面上项目(20242BAB25080);江西省教育厅研究生创新基金项目(YJS2025067)。

作者简介:李云洪(1972),女,硕士,副教授,从事图像超分辨率重建技术研究。

1 方法

1.1 模型总体网络

文中提出一种面向电力设备红外监测图像的感知增强型超分辨率模型(见图1),使用基于对抗生成网络,进行图像超分辨率重建。其中,生成器设计为一个双路融合的注意力网络,通过主注意力路径和下采样分支注意力路径进行操作,同时捕获图像多尺度长程依赖信息;其中,判别器设计为门控细粒度通道-空间(gated fine-grained channel-spatial, GFCS)网络,通过在U-Net判别器的跳跃连接中嵌入GFCS网络,实现判别能力的精细化提升。GFCS网络包含两个核心组件:1) 细粒度通道-空间注意力(fine-grained channel-spatial attention, FCSA),并行建模全局-局部通道依赖关系与方向敏感的空间上下文;2) 注意力门控,通过可学习的门控机制融合高低层特征,增强语义连贯性并抑制背景噪声干扰。




图1 超分辨率网络结构图

具体来说,首先将低分辨率电力设备红外图像输入到生成器网络中,经过多层的双层残差结构和双路融合注意力模块的特征学习,输出高清的电力设备红外图像;随后,生成的高清图像与真实高清图像之间计算损失函数,对生成器进行优化;最后,将生成的高清图像与真实高清图像一同输入GFCS网络中,对判别器网络和生成器网络进行不断的对抗优化。

1.2 双路融合注意力生成器网络

为增强的生成器网络对低分辨率图像进行超分辨率重建的能力,文中设计了一种结合主干注意力路径和下采样分支,且融合了全局自注意力和局部卷积特征的生成器网络,网络结构主干由多个堆叠的双层残差结构(residual in residual dense block, RRDB)^[2]和双路融合注意力模块构成,网络结构模型如图2所示。




图2 超分辨率网络生成器结构

为实现全局上下文与局部细节信息的协同感知,文中基于注意力与卷积融合模块(attention and convolution fusion module, ACFM)^[6],设计了一个双路融合注意力模块(见图3)。在ACFM中并行地添加一个下采样分支(二分之一分辨率),该下采样分支与原路径均基于自注意力机制,捕获长程依赖,区别在于处理尺度不同,主干路径保留精细空间细节以定位微小目标,下采样分支通过压缩分辨率扩大感受野、捕获宏观上下文,二者的输出相加后形成最终的全局注意力表达。




图3 双路融合注意力模块

具体而言,在局部分支内使用卷积操作和通道混洗,以实现局部特征的提取,在全局分支中使用两条注意力计算路径,即主干路径(原始分辨率)与下采样分支(二分之一分辨率)。在原始分辨率路径中,模块保留完整的精细特征,利用自注意力机制,捕获像素级长程依赖,确保微小目标的精确定位不受下采样干扰;与此同时,并行运行的下采样分支以二分之一分辨率对特征图进行高效处理,通过独立的QKV投影层提取宏观上下文信息,再将粗粒度的注意力响应上采样回原始尺寸,从而为细粒度路径提供跨尺度的语义支撑。这种显式的多路径设计不仅避免了单一感受野的表达能力瓶颈,更通过尺度互补机制,显著提升了模型对孤立小目标与密集分布模式的判别能力。

双路融合注意力模块全局分支可表示为:

$$f_{\text{att}} = W_{1 \times 1} \text{Attention}(Y) + D + Y \quad (1)$$

$$D = \text{Upsample}(W_{1 \times 1} \text{Attention}(\text{AvgPool}(Y))) \quad (2)$$

式中: f_{att} 表示全局分支的输出; $W_{1 \times 1}$ 表示 1×1 卷积; D 表示下采样路径输入的特征; Y 表示输入的特征; Attention、Upsample、AvgPool 均为深度学习中的运算函数, 其中, Attention 表示自注意力模块, Upsample 表示上采样, AvgPool 表示平均池化操作。

双路融合注意力模块局部分支可表示为:

$$f_{\text{conv}} = W_{3 \times 3 \times 3}(\text{CS}(W_{1 \times 1}(Y))) \quad (3)$$

式中: f_{conv} 表示局部分支的输出; $W_{3 \times 3 \times 3}$ 表示 $3 \times 3 \times 3$ 卷积; CS 表示通道混洗操作。

1.3 门控细粒度通道-空间判别器网络

红外图像经多级卷积后, 特征图包含大量重复性模式与低判别性信息, 传统 U-Net 判别器对跳跃连接中的特征图各像素赋予均等权重, 无法区分电力设备主体与复杂背景区域, 导致判别器过度关注冗余背景特征而忽略关键发热部位。文中提出了一种门控细粒度通道-空间判别器网络(见图4)分析 U-Net 网络中的特征图信息, 进一步使用软门控机制计算注意力分数, 并使用 FCSA 模块捕获图像的空间和通道信息。




图4 门控细粒度通道-空间判别器网络

1) 注意力门控模块

该模块的软门控机制通过注意力分数 α 对特征图进行逐元素加权, 形成特征筛选效应: 高注意力区域的信息得以完整保留甚至增强, 低注意力区域的特征响应被显著衰减。这种选择性强化策略有效过滤传递至判别器决策层的噪声成分, 迫使判别器聚焦于具有高温梯度变化或微小结构异常的关键区域, 提升对设备缺陷纹理的敏感度。

设编码器第 i 层输出的特征图为 f^i , 解码器对应

层的门控输入为 g , 注意力分数 F^i 计算过程如下:

$$F^i = C_f(f^i) + C_g(g) \quad (4)$$

$$\alpha^i = \sigma_2(C_q(\sigma_1(F^i))) \quad (5)$$

式中: C_f 与 C_g 分别为 1×1 卷积层, 用于对齐编码器与解码器特征维度; $\sigma_1(\cdot)$ 为修正线性单元激活函数(rectified linear unit, ReLU)激活函数; $\sigma_2(\cdot)$ 为 s 型生长曲线激活函数(sigmoid)函数, 确保注意力分数 $\alpha \in (0, 1)$; C_q 为 $1 \times 1 \times 1$ 卷积函数, 生成最终注意力权重。注意力门控通过反向传播学习像素级重要性, 在训练过程中赋予设备发热区域高权重, 抑制背景区域干扰, 提升判别器对关键特征的敏感度。

2) 细粒度通道空间注意力 FCSA 模块

FCSA 模块(见图5)是文中判别器网络中的核心特征校准模块, FCSA 模块根据风车卷积(pinwheel-shaped convolution, PConv)^[7]和自适应细粒度通道注意力(adaptive fine-grained channel attention, FCA)^[8]设计而成, 其目的是通过提取空间方向性细节与通道跨维度依赖关系, 实现对红外图像中微弱温度梯度与微小结构特征的精细化增强。该模块处理空间几何信息与通道信息特性, 并通过动态权重融合机制完成特征提取。




图5 FCSA 模块

为解决红外图像中边缘与纹理的方向性表征问题, 输入特征图首先经历非对称填充策略, 即在特征图左、右、上、下四个方向施加差异化填充参数, 如 $P(1, 0, 0, 3)$ 表示在特征图的左侧和下方分别填充 1 个和 3 个像素点, $P(0, 1, 3, 0)$ 表示在特征图的右侧和上方分别填充 1 个和 3 个像素点, 以此类推。随后, 经过两组轻量级卷积核: 水平方向的 1×3 卷积核专注于捕获特征图横向的温度突变与边缘轮廓, 垂直方向的 3×1 卷积核则提取纵向的结构线条与梯度变化。在卷积后统一使用批归一化(Batch Normalization, BN)和 sigmoid 线性单元激活函数(sigmoid linear unit, SiLU)激活函数, 具体执行如下:

$$X_1^{(h', w', c')} = \text{SiLU}(\text{BN}(X_{P(1,0,0,3)}^{(h_1, w_1, c_1)} \otimes W_1^{(1,3,c')})) \quad (6)$$

$$X_2^{(h',w',c')} = \text{SiLU}(\text{BN}(X_{P(0,3,0,1)}^{(h_1,w_1,c_1)} \otimes W_2^{(3,1,c')})) \quad (7)$$

$$X_3^{(h',w',c')} = \text{SiLU}(\text{BN}(X_{P(0,1,3,0)}^{(h_1,w_1,c_1)} \otimes W_3^{(1,3,c')})) \quad (8)$$

$$X_4^{(h',w',c')} = \text{SiLU}(\text{BN}(X_{P(3,0,1,0)}^{(h_1,w_1,c_1)} \otimes W_4^{(3,1,c')})) \quad (9)$$

式中： h_1, w_1, c_1 表示输入的张量 $X^{(h_1, w_1, c_1)}$ 的高度、宽度和通道数； $\otimes$ 表示卷积运算； $W_1^{(1,3,c')}$ 表示输出通道数为 c' 的 1×3 卷积核。在经过归一化和激活函数后，此时特征图的大小变为：

$$h' = \frac{h_1}{s} + 1, w' = \frac{w_1}{s} + 1, c' = \frac{c_2}{4} \quad (10)$$

式中： h' 和 w' 表示此时特征图的高和宽； s 表示卷积操作的步长； c_2 表示空间信息提取模块的输出特征图的通道数。输出的张量经过拼接(Cat)，计算过程如下：

$$X^{(h',w',4c')} = \text{Cat}(X_1^{(h',w',c')}, \dots, X_4^{(h',w',c')}) \quad (11)$$

接着，使用大小为 $W^{(2,2,C_2)}$ 的卷积核对拼接的张量进行卷积操作，输出最终特征图 $Y^{(h_2, w_2, C_2)}$ ，计算过程如下：

$$h_2 = h' - 1 = \frac{h_1}{s}, w_2 = w' - 1 = \frac{w_1}{s} \quad (12)$$

$$Y^{(h_2, w_2, C_2)} = \text{SiLU}(\text{BN}(X^{(h',w',4c')} \otimes W^{(2,2,C_2)})) \quad (13)$$

在通道维度拼接后，经由 2×2 卷积层进行特征融合与通道降维，生成空间注意力图，此过程形成的有效感受野会呈现类高斯分布衰减特性，中心区域聚焦能力强，外围区域感知范围逐步扩展，这种设计使得小目标的特征响应更加集中，实现局部细节与全局语境的权衡。

FCSA模块的通道信息提取过程通过“全局-局部”协同的通道依赖建模，实现对红外图像通道的精细化校准。假设此时特征图为 $F \in R^{C \times H \times W}$ ， C, H, W 分别表示特征图的通道数、高和宽，对其进行全局平均池化操作，此时，第 n 个通道元素 M_n 表示为：

$$M_n = \text{GAP}(F_n) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_n(i, j) \quad (14)$$

式中： $F_n(i, j)$ 表示为输入特征图的第 n 个通道的特征图；GAP表示全局平均池化操作，全局平均池化操作把特征图的形状由 $C \times H \times W$ 变为 $C \times 1 \times 1$ ，接着，使用带状矩阵进行局部通道信息提取，设 $B=[b_1, b_2, \dots, b_k]$ ：

$$M_{\text{band}} = \sum_{i=1}^k M \cdot b_i \quad (15)$$

式中： M_{band} 表示局部信息矩阵； M 表示通道信息向量； k 表示相邻通道的数量， b_i 表示带状矩阵 B 的第 i 个基向量。实验中使用对角矩阵来捕获全局通道信

息，设 $D=[d_1, d_2, \dots, d_q]$ ：

$$M_{\text{diag}} = \sum_{i=1}^q M \cdot d_i \quad (16)$$

式中： M_{diag} 表示全局通道信息矩阵； q 表示通道数量； d_i 表示对角矩阵 D 的第 i 个基向量。为促成对角矩阵全局信息与带状矩阵局部信息的互补结合，利用下述机制在差异化粒度上评估二者间的交互关系：

$$C = M_{\text{diag}} \cdot M_{\text{band}}^T \quad (17)$$

C 为相关矩阵，利用该矩阵及其转置形式挖掘行列信息，将其映射为全局和局部特征的权重向量，并借助可学习因子完成特征的自适应聚合，公式如下：

$$M_{\text{diag}}^W = \sum_j^k C_{ij}, i \in 1, 2, 3, \dots, k \quad (18)$$

$$M_{\text{band}}^W = \sum_j^k (M_{\text{band}} \cdot M_{\text{diag}}^T) \sum_j^k C_{ij}^T, i \in 1, 2, 3, \dots, k \quad (19)$$

$$W = \sigma(\sigma(\theta) \times \sigma(M_{\text{diag}}^W)) + (1 - \sigma(\theta)) \times \sigma(M_{\text{band}}^W) \quad (20)$$

式中： M_{diag}^W 和 M_{band}^W 是全局通道权重和局部通道权重信息； σ 为sigmoid激活函数； k 为通道数量； θ 为可学习参数，用于分配两条径的权重。该方法促进了局部和全局信息的相互作用，并且突出有用通道信息，通过剔除冗余通道特征，完成了对关键特征更为精细的权重重校准。权重 W_{ch} 与空间特征图 F 逐通道相乘，对输入特征图 F 实施加权操作完成通道-空间双重校准，得到最后输出的特征图 F^* ：

$$F^* = W_{\text{ch}} \otimes F \quad (21)$$

此操作使高权重通道(对应关键温度信息)的特征响应得以放大，低权重通道(对应背景噪声或冗余信息)则被抑制，从而在保留空间几何细节的同时，实现通道维度的动态重分配。如此输出的特征图 F^* 兼具方向敏感的空间梯度捕捉能力与“全局-局部”协同的通道依赖建模能力，使判别器能够精确识别电力设备红外图像中真实的细微纹理特征，并有效抑制背景噪声干扰。

2 实验结果与分析

2.1 实验数据与实验设置

文中使用电力设备红外图像数据集，共有3 039张红外图像，所有图像大小都是1 024×768像素，覆盖了多种常见的电力设备，比如变压器套管、电阻器、断路器、接地扁铁等，按照7:2:1的比例划分训练集、验证集和测试集，其中训练集有2 127张图片，验证集

有 607 张图片,测试集有 305 张图片。

文中所有实验均在配备 NVIDIA GeForce RTX 4090 显卡的高性能计算服务器上完成。实验环境基于 windows 10 操作系统构建,使用 Anaconda 对训练中的 Python 包和环境管理,确保了实验过程中依赖项的准确配置和环境的稳定性。实验过程采用 PyTorch 作为深度学习框架并配置 CUDA 工具包以支持 GPU 加速计算。在模型训练过程中,选用了 Adam 优化器,通过双三次插值下采样生成 2 倍和 4 倍两种尺度的低分辨率样本,这些样本与原始分辨率图像一同构成了训练集,其中模型训练总的迭代次数为 500 000。

2.2 对比实验

在实验过程中,针对超分辨率重建的不同放大因子,构建并训练了涵盖 2 倍及 4 倍的重建模型。通过将文中模型与现有主流超分辨率模型的关键性能指标进行对比,从而实现对文中网络性能的有效验证。对比包括基于插值的图像超分辨率重建算法 Bicubic,基于卷积神经网络的图像超分辨率重建算法(residual channel attention network,RCAN)^[9],基于 Transformer 的图像超分辨率重建算法(permuted self-attention for single image super-resolution,SRFormer)^[10]、密集残差连接 Transformal (dense-residual-connected transformer, DRCT)^[11],基于扩散模型的图像超分辨率重建算法(efficient diffusion model for image restoration, DiffIR)^[12]、(diffusion-based image super-resolution in a single step, SinSR)^[13]和基于生成对抗网络的图像超分辨率重建算法(real-world enhanced super-resdution generative adversarial network, Real-ESRGAN)^[14]。

表 1—2 详细列出了各模型在电力设备红外图像上 2 倍及 4 倍的自然图像质量评估器(natural image quality evaluator, NIQE)和学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)指标评估数据质量,NIQE 和 LPIPS 指标数值越低,表示该方法性能越优。基于生成对抗网络的超分辨率算法在 NIQE 和 LPIPS 指标上均取得了一定优势。鉴于这两项指标主要用于衡量图像与人眼视觉感知的契合度,这证实了该类算法能有效提升图像的视觉感知效果。此外,文中提出的模型在超分辨率任务中展现了较高的重建精度,对复杂图像场景具有良好的适应性,切实增强了图像的视觉质量。

表 1 2 倍超分辨率下的评价指标结果

网络模型	NIQE	LPIPS
Bicubic	6.912	0.186 4
RCAN	6.846	0.044 8
SRFormer	6.851	0.046 4
DRCT	7.036	0.047 0
DiffIR	5.465	0.044 5
SinSR	5.295	0.061 6
Real-ESRGAN	5.289	0.039 4
文中方法	5.194	0.035 7

表 2 4 倍超分辨率下的评价指标结果

网络模型	NIQE	LPIPS
Bicubic	7.206	0.273 8
RCAN	7.045	0.064 1
SRFormer	7.031	0.066 1
DRCT	7.404	0.065 6
DiffIR	5.810	0.064 8
SinSR	5.685	0.091 6
Real-ESRGAN	5.670	0.059 4
文中方法	5.568	0.054 1

图 6—7 给出了文中模型在电力设备红外图像 4 倍超分辨率的视觉效果。




图 6 4 倍重建效果局部细节对比图




图 7 4 倍重建效果局部亮度和细节对比图

2.3 消融实验

为了评估文中提出的判别器网络和生成器网络对 GAN 模型性能的作用和影响,文中做了相关消融实验,结果如表 3 和表 4 所示。

表 3 判别器网络消融实验(4 倍)

生成器模型	NIQE	LPIPS
VGG19	5.736	0.059 0
U-Net	5.651	0.057 1
U-net+注意力门控	5.628	0.056 3
U-net+FCSA 模块	5.582	0.055 7
U-net+注意力门控+FCSA 模块	5.568	0.054 1

表4 生成器网络消融实验(4倍)

生成器模型	NIQE	LPIPS
RRDB	5.572	0.056 3
双路融合注意力生网络	5.568	0.054 1

4 结语

面向电力设备红外监测的图像质量增强需求,文中提出了一种基于生成对抗网络的超分辨率算法,通过设计判别器与生成器核心模块,有效解决了红外图像细节模糊、背景干扰强等关键问题。算法核心体现在两个层面:判别器部分采用GFCS装置,在U-Net跳跃连接中嵌入FCSA模块与注意力门控,通过门控细粒度通道-空间注意力机制,强化对设备发热区域关键特征的判别能力;生成器部分设计为双路径融合注意力架构,采用原始分辨率与下采样分支并行处理,结合RRDB密集残差块与自注意力机制,实现全局结构与局部细节的协同重建。

参考文献:

- [1] Ledig C, Theis L, Huszar F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]// Proceedings of the IEEE/CVF international conference on computer vision and pattern recognition. Honolulu, HI, USA. IEEE/CVF.2017:4681-4690.
- [2] Wang X, Yu K, Wu S, et al. ESRGAN: Enhanced super-resolution generative adversarial networks[C]// Proceedings of the European conference on computer vision workshops. Munich, Germany. ECVA. 2018: 63-79.
- [3] Rakotonirina N C, Rasoanaivo A. ESRGAN+ : Further improving enhanced super-resolution generative adversarial network[C] //2020 IEEE international conference on acoustics, speech and signal processing (ICASSP). Barcelona, Spain. IEEE.2020:3637-3641.
- [4] Ma C, Rao Y, Cheng Y, et al. Structure-preserving super resolution with gradient guidance[C] // Proceedings of the IEEE/ CVF conference on computer vision and pattern recognition. Seattle, Washington, USA. IEEE/CVF.2020: 7769-7778.
- [5] Zhang K, Liang J, Van Gool L, et al. Designing a practical degradation model for deep blind image super-resolution[C]

//Proceedings of the IEEE/CVF international conference on computer vision. Montreal, QC, Canada. IEEE/CVF. 2021 : 4791-4800.

- [6] Chen Z, Lu S. Caf-YOLO: A robust framework for multi-scale lesion detection in biomedical imagery[C] //2025 IEEE international conference on acoustics, speech and signal processing (ICASSP). Hyderabad, India. IEEE.2025: 1-5.
- [7] Yang J, Liu S, Wu J, et al. Pinwheel-shaped convolution and scale-based dynamic loss for infrared small target detection [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Philadelphia, Pennsylvania, USA. AAAI. 2025, 39 (09):9202-9210.
- [8] Sun H, Wen Y, Feng H, et al. Unsupervised bidirectional contrastive reconstruction and adaptive fine-grained channel attention networks for image dehazing[J]. Neural Networks, 2024, 176:106314.
- [9] Zhang Y, Li K, Li K, et al. Image super-resolution using very deep residual channel attention networks [C]//Proceedings of the European conference on computer vision(ECCV). Munich, Germany, ECVA.2018:286-301.
- [10] Zhou Y, Li Z, Guo C L, et al. SRFormer: Permuted self-attention for single image super-resolution[C]//Proceedings of the IEEE/CVF international conference on computer vision. Paris, France. IEEE/CVF.2023:12780-12791.
- [11] Hsu C C, Lee C M, Chou Y S. DRCT: Saving image super-resolution away from information bottleneck[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA. IEEE/CVF.2024:6133-6142.
- [12] Xia B, Zhang Y, Wang S, et al. DiffIR: Efficient diffusion model for image restoration[C]//Proceedings of the IEEE/ CVF international conference on computer vision. Paris, France. IEEE/CVF.2023:13095-13105.
- [13] Wang Y, Yang W, Chen X, et al. SinSR: diffusion-based image super-resolution in a single step[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. seattle, WA, USA. IEEE/CVF.2024: 25796-25805.
- [14] Wang X, Xie L, Dong C, et al. Real-ESRGAN: Training real-world blind super-resolution with pure synthetic data[C]// Proceedings of the IEEE/CVF international conference on computer vision. Montreal, QC, Canada. IEEE/CVF. 2021 : 1905-1914.