

# 基于选通图像的超分辨率重建算法研究

张 正 郑颖俏 田 青

(北方工业大学信息学院 北京 100144)

**摘 要:** 激光距离选通技术能突破传统成像在雨雪雾、低光照和逆强光等复杂环境中无法成像的限制,但生成的选通图像是低质量灰度图,需要超分辨率重建技术着重于边缘信息和空间细节的重建,以提升视觉效果。由于选通图像缺乏颜色和丰富纹理信息,传统的特征提取方法容易产生冗余特征,影响重建效率。针对上述问题,本文提出了一种双聚合深层特征提取网络。首先,通过空间和通道重建卷积(SCConv)进行浅层特征提取,提高信息含量并解决冗余问题;其次,设计了一种新的深层特征提取模块,增强对选通图像边缘和细节的捕捉;最后,采用连续的最近邻插值加卷积操作进行图像重建,有效避免伪影问题。在选通图像数据集上的实验表明,相比基线的 DAT 算法,本文所提方法 PNSR 指标在 2、3 和 4 倍分辨率退化情况下分别提升了 0.19 dB、0.12 dB 和 0.04 dB,SSIM 在 2、3 和 4 倍分辨率退化情况下分别提升了 0.000 5、0.000 8 和 0.001 0,结果表明本文方法可以取得较好的视觉效果。

**关键词:** 选通图像;超分辨率重建;边缘增强

**中图分类号:** TP391;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## Research on super-resolution reconstruction algorithm based on gated image

Zhang Zheng Zheng Yingqiao Tian Qing

(School of Information, North China University of Technology, Beijing 100144, China)

**Abstract:** Laser range gating technology can break through the limitations of traditional imaging in complex environments such as rain, snow and fog, low light and inverse glare, but the generated gated image is a low-quality grayscale map, which lacks color information and is difficult to distinguish between the subject and the background, so super-resolution reconstruction technology is needed to focus on the reconstruction of edge information and spatial details to improve the visual effect. Due to the lack of color and rich texture information in the gated image, the traditional feature extraction method is prone to redundant features, which affects the reconstruction efficiency. In order to solve the above problems, this paper proposes a bi-aggregation deep feature extraction network. Firstly, shallow feature extraction was carried out by spatial and channel reconstruction convolution (SCConv) to improve the information content and solve the redundancy problem. Secondly, a new deep feature extraction module was designed to enhance the capture of the edges and details of the gated image. Finally, continuous nearest neighbor interpolation and convolution operations are used for image reconstruction, which effectively avoids the problem of artifacts. Experiments on the gated image dataset show that compared with the baseline DAT algorithm, the PNSR index of the proposed method is increased by 0.19 dB, 0.12 dB and 0.04 dB under the condition of 2 fold, 3 fold and 4 fold resolution degradation, respectively, and the SSIM is increased by 0.000 5, 0.000 8 and 0.001 0, respectively, and the results show that the proposed method can achieve better visual effects.

**Keywords:** gated image;super-resolution reconstruction;edge enhancement

## 0 引 言

激光距离选通成像技术能克服传统成像在雨雪雾、低光照等复杂环境中的局限,但生成的选通图像通常分辨率低,边缘信息模糊。提高硬件精度虽可获得清晰图像,但成

本高昂,因此,通过优化超分辨率重建算法,可在低成本下获取清晰图像,便于后续处理。

图像超分辨率重建技术的目的是将给定的低分辨率的图像通过算法生成高分辨率的清晰图像<sup>[1]</sup>。目前,该技术在医学诊断成像、卫星遥感<sup>[2]</sup>和人脸识别<sup>[3]</sup>等领域发挥重

要作用。超分辨率重建方法主要分为基于插值<sup>[4]</sup>、重构<sup>[5]</sup>和学习<sup>[6]</sup>的方法。基于插值方法利用已知像素灰度值计算丢失像素,实现图像上采样放大,虽简单且速度快,但在非均匀灰度区域容易产生锯齿和模糊现象;基于重构的方法依赖低分辨率图像序列和图像先验知识,通过特定退化模型重建高分辨率图像,但放大因子增大时样本量剧增,效果难以提升;基于学习的方法通过学习低分辨率与高分辨率图像之间的映射关系实现,但模型复杂、特征提取能力有限,难以获得高质量图像。

2014 年,Dong 等<sup>[7]</sup>提出了 SRCNN 模型,模型通过浅层卷积网络实现了低分辨率图像的特征提取、非线性映射和高分辨率图像的重建。SRCNN 使用  $9 \times 9$  卷积核进行特征提取,能够捕捉较大的感受野,但由于网络结构较浅,对复杂图像的高频细节重建能力有限。2016 年,Dong 等<sup>[8]</sup>又提出 FSRCNN 模型,通过引入反卷积层加速上采样过程,有效提升了模型的计算效率,但仍难以处理图像中复杂的细节纹理。随着深度学习的发展,深层网络被引入超分辨率任务中以提升重建性能。2016 年,Kim 等<sup>[9]</sup>提出了 VDSR 模型,采用小卷积核( $3 \times 3$ )和深度残差网络结构,加深网络以提取更多高级特征。然而,过深的网络容易导致梯度消失或爆炸,同时对计算资源需求较高。随后,Lim 等<sup>[10]</sup>提出了 EDSR 模型,在 VDSR 的基础上去除了批归一化层,减少了计算开销,并通过增加卷积层提升了重建质量,但该模型在处理高频特征时仍存在细节模糊的问题。

针对传统卷积神经网络在捕捉全局特征方面的局限性,Goodfellow 等<sup>[11]</sup>提出了生成对抗网络的概念,开创了图像生成领域的新方向。Ledig 等<sup>[12]</sup>基于提出了 SRGAN 模型,通过生成器和判别器的对抗训练,显著提升了图像的视觉感知质量,但仍存在边缘模糊和伪影等问题,影响了图像的真实感。

近年来,为进一步提升超分辨率重建的整体性能,研究者们提出了包含浅层特征提取、深层特征提取和图像重建三个阶段的端到端流程算法。2018 年,Zhang 等<sup>[13-14]</sup>提出了 RDN 和 RCAN 网络。二者在浅层特征提取部分均采用  $3 \times 3$  标准卷积。其中,RDN 在深层特征提取中引入了残差密集块,有效复用了多尺度特征信息,提升了特征表示能力,但在处理高分辨率图像的高频细节时,容易引入特征冗余,导致重建结果在边缘和纹理区域出现模糊现象。RCAN 在深层特征提取通过残差通道注意力块引入通道注意力机制,自适应调整通道间的权重,有效提升了重建性能。然而,通道注意力机制主要针对通道间特征分配权重,缺乏对空间维度的精确建模,难以全面捕获复杂纹理的局部细节。为进一步优化空间与通道信息的联合建模,2020 年,Niu 等<sup>[15]</sup>提出了 HAN 网络,通过结合通道注意力与空间注意力机制,实现了通道与空间信息的协同建模,有效增强了边缘细节和高频纹理的重建能力。

随着 Transformer 结构在超分辨率任务中的广泛应

用,研究者们提出了多种基于 Transformer 的整体流程方法,这些方法在浅层特征提取阶段也普遍采用  $3 \times 3$  标准卷积进行初始特征提取,并通过不同的 Transformer 模块在深层特征提取阶段实现有效建模。2021 年,Liang 等<sup>[16]</sup>提出了 SwinIR 网络,深层特征提取通过残差 Swin Transformer 块实现,结合窗口化自注意力机制有效捕获局部和全局特征,提升了建模能力。2022 年,Zhang 等<sup>[17]</sup>提出了 ELAN 网络,通过引入高效长距离注意力机制,在降低计算复杂度的同时实现了长距离依赖特征的建模,进一步平衡了网络性能与效率。然而,ELAN 在图像重建任务中,局部细节的重建表现仍有待进一步优化。2023 年,Zhou 等<sup>[18]</sup>提出了 SRFormer,深层特征提取阶段创新性地引入了 PSA 机制,通过重新排列空间与通道信息实现了大窗口注意力建模,有效捕捉全局特征,但对局部细节的精细建模相对较弱,导致对高频细节的敏感性不足。同年,Chen 等<sup>[19]</sup>提出了 HAT 网络,在深层特征提取阶段通过交叉窗口自注意力机制优化全局建模效率,同时提升计算性能,减少了传统 Transformer 结构中冗余的计算开销,进一步增强了高分辨率图像的重建能力。2023 年,Chen 等<sup>[20]</sup>提出了 DAT 网络,该模型在深层特征提取阶段引入了空间与通道双重聚合机制,通过聚合空间维度和通道维度的信息,有效捕获了图像中的多层次特征,提升了特征表达能力。

尽管近年来超分辨率重建方法在整体流程上取得了显著进展,然而,这些方法主要针对彩色高分辨率图像展开,未能充分考虑选通图像的特殊性。在浅层特征提取阶段,现有算法普遍采用标准卷积,该方法能够有效提取彩色图像中的初始特征,但对于灰度图像的选通图而言,由于缺乏颜色信息,标准卷积提取出的特征往往存在冗余性,导致计算资源浪费且有效特征利用率低。此外,选通图像更依赖边缘和空间细节信息,而现有浅层特征提取方法未能针对这些特征进行有效建模,进一步限制了重建性能的提升。在深层特征提取阶段,现有超分辨率重建方法主要侧重于全局特征的建模,较少关注局部细节特征的精确表达,尤其在处理选通图像时,由于其灰度图像的特点,边缘和空间细节信息更为重要,单纯依赖全局建模容易导致细节信息的丢失或模糊。此外,现有方法未能有效融合全局与局部特征,忽略了两者的协同关系,难以充分适应选通图像的重建需求。在图像重建阶段,现有方法主要采用反卷积和像素重排,这些方法虽然能够重建高分辨率图像,但面对复杂退化的选通图像时,易引入伪影和纹理模糊问题,进一步影响图像的视觉一致性和细节表现。

针对这些问题,本研究提出一种新超分辨率重建算法,专为选通图像设计,重点增强边缘和空间细节纹理的重建效果,减少冗余特征,提高整体视觉质量和处理效率。创新点如下:

1) 基于 DAT 网络,提出深层特征提取模块,强化对选

通图像边缘和细节的捕捉,同时设计双门控深度卷积前馈网络,捕捉不同尺度的边缘与纹理信息,提升细节重建。

2) 在图像重建阶段,采用连续的最近邻插值加卷积操作,有效避免伪影问题。

3) 在浅层特征提取中引入空间和通道重建卷积,减少冗余信息,优化特征提取过程,以适应选通图像特点,提高处理效率。

## 1 本文方法

### 1.1 网络结构

本文提出一种双聚合深层特征提取网络(dual-aggregation deep feature extraction network,DDFEN),网络结构主要分为三部分:浅层特征提取、深层特征提取和图像重建,具体结构如图1所示。

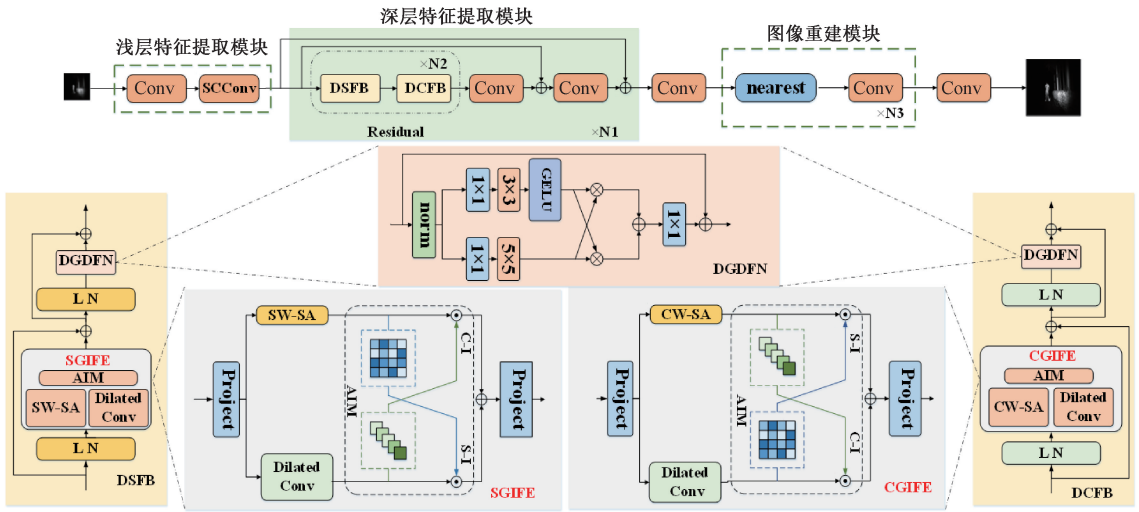


图1 DDFEN网络结构

Fig. 1 DDFEN network structure

### 1.2 浅层特征提取模块

目前的超分辨率重建算法在浅层特征提取阶段,主流方法通常采用  $3 \times 3$  标准卷积。 $3 \times 3$  卷积具有结构简单、计算高效的优势,能够有效捕获局部区域的初始特征,适用于包含丰富颜色信息的普通图像,且能够为后续深度特征提取提供稳定的基础。然而,选通图像作为灰度图像,缺少颜色通道信息,单纯依赖  $3 \times 3$  标准卷积进行浅层特征提取时,容易引入特征冗余,导致无效信息过多,影响后续深度特征提取阶段的性能表现。

针对这一问题,本文在  $3 \times 3$  标准卷积的基础上进行了改进,引入了 SCCConv<sup>[21]</sup>,该模块通过重建空间和通道特征,有效减少了特征图中的冗余信息,增强了对边缘和空间细节的建模能力。

SCCConv 由空间重建单元(spatial reconstruction units,SRU)和通道重建单元(channel reconstruction unit, CRU)两部分组成,二者顺序堆叠,如图2所示。

网络首先输入一张低分辨率(low-resolution, LR)图像  $I_{LR} \in R$ ,通过标准卷积处理之后使用空间与通道重建卷积(spatial and channel reconstruction convolution, SCCConv)对其进行处理,去除冗余特征,生成浅层特征。随后,浅层特征在深层特征提取模块内进行处理,获得深层特征。该模块由多个残差组(residual group, RG)堆叠,总数为  $N_1$ 。模块中采用残差策略以保证训练稳定。每个 RG 包含  $N_2$  个双聚合深层特征提取模块,分别利用空间和通道的自注意。在 RG 的末端引入了一个卷积层来细化从 Transformer 块中提取的特征。此外,对于每个 RG,都采用了残差连接。最后将深层特征输入到图像重建模块,重建出高分辨率(high resolution, HR)输出图像  $I_{HR} \in R_1$ ,在该模块中,通过两次连续的最近邻插值加卷积对深层特征进行上采样,并采用卷积层来聚合上采样操作前后的特征。




图2 浅层特征提取模块

Fig. 2 Shallow feature extraction module

输入一张低分辨率图像,通过标准卷积生成特征图  $X$ 。将  $X$  输入到 SCCConv 进行特征提取,通过空间重建单元,输出特征图  $X^w$ 。然后,  $X^w$  进入通道重建单元,输出特征图  $Y^w$ 。

#### 1) 空间重建单元

为了利用特征的空间冗余性,空间重建单元通过“分离-重建”的操作来抑制空间冗余并增强特征表达,如图3所示。

首先,对输入特征图  $X$  进行分组归一化,再利用缩放因子作为权重,通过归一化和 sigmoid 函数将其映射到



(0,1) 范围内,并通过门控机制将特征图分为信息丰富部分  $X_1^w$  和冗余部分  $X_2^w$ 。门控机制表达式为:

$$W = \text{Gate}(\text{Sigmoid}(W_y(\text{GN}(X)))) \quad (1)$$

其中,  $W$  为门控权重矩阵,  $W_y$  表示归一化后的缩放因子。

最后,将信息丰富部分和冗余部分通过交叉重建操作进行组合得到空间细化的特征图  $X^w$ ,以增强信息流动。通过这一过程,SRU 不仅分离出信息丰富的特征,还通过重建操作增强了这些特征,并抑制了冗余特征。

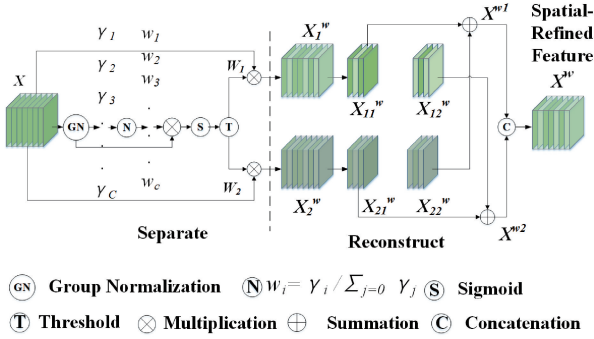


图 3 空间重建单元

Fig. 3 Spatial reconstruction units

## 2) 通道重建单元

空间细化的特征图  $X^w$  在通道维度上仍然保持冗余,为了减少特征的信道冗余,引入通道重建单元,该单元采用“分割-转换-融合”的方法,如图 4 所示。首先进行分割操作,将输入的空间细化特征  $X^w$  分割为两部分:一部分的通道数是  $aC$ ,另一部分的通道数是  $(1-a)C$ ,其中  $a$  是超参数,且  $0 \leq a \leq 1$ 。随后对两组特征的通道数使用  $1 \times 1$  卷积核进行压缩,分别得到  $X_{up}$  和  $X_{low}$ 。

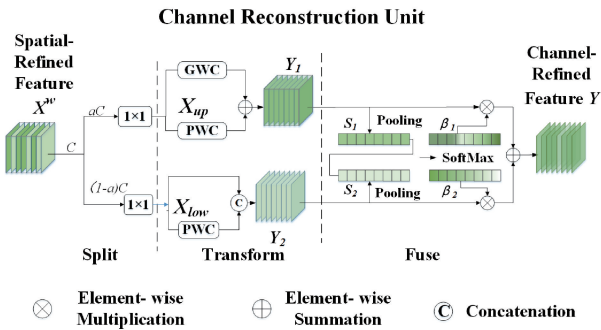


图 4 通道重建单元

Fig. 4 Channel reconstruction unit

转换操作将输入的  $X_{up}$  作为“丰富的提取特征”的输入,分别进行分组卷积(group-wise convolution, GWC)和点卷积(point-wise convolution, PWC)操作,然后相加得到输出  $Y_1$ 。将输入  $X_{low}$  作为“丰富的提取特征”的补充,进行 PWC,得到的结果和原来的输入取并集得到  $Y_2$ 。

融合操作使用简化的 SKNet<sup>[22]</sup>方法来自适应的合并

$Y_1$  和  $Y_2$ 。具体来说,首先使用全局平均池化,将全局空间信息和通道统计信息结合起来,得到经过池化的  $S_1$  和  $S_2$ 。然后对  $S_1$  和  $S_2$  做 Softmax 得到特征权重向量  $\beta_1$  和  $\beta_2$ 。最后使用特征权重向量得到输出,计算表达式为:

$$Y^w = \beta_1 Y_1 + \beta_2 Y_2 \quad (2)$$

SCConv 模块结合了 SRU 和 CRU,通过顺序方式减少卷积神经网络中的空间和通道冗余,在提升特征表达能力和模型性能的同时,显著减少不必要的计算,提高了特征的信息含量,实现了在特征提取初期阶段的信息优化。

## 1.3 深层特征提取模块

### 1) 整体结构

选通图像因为缺少颜色信息,其主体与背景区分不明显,因此在超分辨率重建过程中更依赖的边缘信息的重建。而现有的超分辨率重建算法大多基于彩色图像,因此没有着重针对边缘细节部分进行重建。针对此问题,本文提出一种深层特征提取模块,包含双空间自注意力特征提取模块(dual-space self-attention feature extraction blocks, DSFB)和双通道自注意力特征提取模块(dual-channel self-attention feature extraction module, DCFB)两部分,DSFB 模块的核心是空间全局和局部特征提取模块(spatial global and local feature extraction modules, SGIFE)和双门控深度卷积前馈网络(double-gated deep convolutional feedforward network, DGDFN)。全局和局部特征提取模块中采用空间窗口自注意力进行全局特征提取,然后采用卷积分支并联进行局部信息补充,最后采用自适应交互模块(adaptive interaction modules, AIM)自适应地融合空间和通道特征;而 DCFB 模块的结构与 DSFB 类似,但在进行全局特征提取时,采用通道窗口自注意力来代替空间窗口自注意力,具体结构如图 5 所示。同时,网络中创新性的采用空洞卷积替换了原本的深度可分离卷积进行局部信息提取,通过在卷积核中引入空间间隙,扩大其感受野,使得模型能够在不增加额外计算成本的情况下,捕捉更广泛的上下文信息,在保持细节清晰度的同时,增加对周围像素的感知能力。同时,提出双门控深度卷积前馈网络,引入深度卷积对空间相邻像素的信息进行编码,丰富局部信息。

### 2) 全局和局部特征提取模块

#### (1) 全局特征提取

空间窗口自注意力(space window self-attention, SW-SA)用于在局部窗口内计算自注意力,捕捉局部区域的特征关系。其目的是通过局部窗口操作,细化特征提取的局部性,并提高处理效率。对输入特征进行线性变换,生成查询(Query)、键(Key)和值(Value)矩阵,将矩阵划分为若干不重叠的窗口,计算每个窗口内的自注意力,输出特征:

$$Y_s = \text{softmax}(\frac{Q_s K_s^T}{\sqrt{d}} + D) V_s \quad (3)$$

其中,  $D$  是相对位置编码,  $Q_s$ 、 $K_s$  和  $V_s$  分别是窗口内






图5 深层特征提取模块

Fig. 5 Deep feature extraction module

的查询、键和值。通过这种方式,能够有效捕捉局部区域内的特征关系,提高特征提取的细粒度性。

通道窗口自注意力(channel windows self-attention, CW-SA)用于在通道维度上计算自注意力,捕捉全局特征关系。其目的是通过全局通道操作,增强对全局特征的感知能力。

对输入特征  $\mathbf{X}$  进行线性变换,生成查询(query,  $\mathbf{Q}$ )、键(key,  $\mathbf{K}$ )和值(value,  $\mathbf{V}$ )矩阵,将  $\mathbf{Q}$ 、 $\mathbf{K}$  和  $\mathbf{V}$  矩阵重塑为大小为  $(H \times W)C$  的矩阵,计算每个通道内的自注意力,输出特征:

$$\mathbf{Y}_c = \text{softmax}(\frac{\mathbf{Q}_c \mathbf{K}_c^T}{\alpha} + D) \mathbf{V}_c \quad (4)$$

其中,  $\mathbf{Q}_c$ 、 $\mathbf{K}_c$  和  $\mathbf{V}_c$  通道内的查询、键和值,  $\alpha$  是可学习的温度参数。模块通过增强对通道间全局特征的捕捉能力,提高模型对全局信息的感知和利用。

### (2) 局部特征提取

在图像超分辨率重建中,传统的特征提取过程主要侧重于全局特征的捕捉。但由于图像中的细节和纹理信息往往局部化且比较复杂,为了更准确地恢复这些细节,需要引入局部性。在此背景下,本文提出采用空洞卷积<sup>[23]</sup>进行局部特征提取,以增强模型对细节和纹理信息的捕捉能力。

传统的卷积神经网络在处理依赖边缘信息的灰度选通图像时,难以充分表达图像边缘细节。为了有效解决这一问题,引入空洞卷积进行局部特征增强。与深度可分离卷积相比,空洞卷积在不增加计算复杂度的情况下,能够扩大卷积核的感受野,有效捕捉和整合局部信息,从而提高选通图像的细节还原度。通过并行使用空洞卷积处理自注意力的值,可以获得更加细致的卷积输出。

与单纯依赖自注意力的分支相比,空洞卷积的引入不仅补充了空间自注意力的通道信息,还为通道自注意力增

加了额外的空间信息,从而有效提升了特征的表达能力。此外,空洞卷积在保持分辨率的同时,能够捕捉更广泛的上下文信息,确保模型在不增加计算成本的情况下,显著提升特征的细节和清晰度。具体结构如图6和7所示。




图6 空间全局和局部特征提取模块(SGIFE)

Fig. 6 Spatial global and local feature extraction modules(SGIFE)




图7 通道全局和局部特征提取模块(CGIFE)

Fig. 7 Channel global and local feature extraction modules (CGIFE)

在上述基础上引入自适应交互操作,包括空间交互(spatial interaction, S-I)和通道交互(channel interaction, C-I),自适应地重新加权两个分支的特征,有效地融合空间和通道特征,提升特征的表达能力和模型的泛化能力。

### (3) 双门控深度卷积前馈网络

在传统 Transformer 中,前馈神经网络通常包含两个线性变换层和一个非线性激活函数。第1个线性变换层用于扩展特征通道,第2个用于将通道减回原始输入维度。为了更好地捕捉输入图像的特征信息,本文提出了一个全新的 DGDFN 双门控深度卷积前馈网络,其结构如图8所示。




图8 双门控深度卷积前馈网络(DGDFN)

Fig. 8 Double-gated deep convolutional feedforward network (DGDFN)

DGDFN 通过双路并行处理和门控机制,有效增强了特征提取和融合的能力,提高了超分辨率重建的效果。DGDFN 的结构包括两个并行路径和一个门控融合单元。上面的分支采用  $1 \times 1$  卷积后接  $3 \times 3$  深度可分离卷积,同时应用 GeLU 激活函数,进行局部细节特征的提取;下面的分支通过  $1 \times 1$  卷积后接  $5 \times 5$  深度可分离卷积,扩大感

受野并捕捉更广泛的上下文信息。上述操作可以通过多样化的卷积核尺寸,捕捉不同尺度的边缘和纹理信息,增强选通图像细节重建。同时,在  $3 \times 3$  卷积分支加入 GELU 激活函数,提高了模型的非线性表达能力,有助于捕捉复杂特征。门控融合单元通过逐元素相乘和求和操作,有效地过滤掉信息量较少的特征,并融合两个路径中的有用信息,从而提高特征的表达能力和模型的泛化能力,从而显著提升边缘清晰度和细节表现,最终提高图像的整体视觉质量。同时由于双门控机制具有更强的非线性建模能力,因此可以学习更复杂的模式,提高模型的泛化性和建模能力。整个过程可以表示为:

$$Y_1 = \sigma(W_{d1}W_c(LN(X)))W_{d2}W_c(X) + W_{d2}W_c(X)\sigma(W_{d1}W_c(LN(X))) \quad (5)$$

$$Y = W_c(Y_1) + X \quad (6)$$

其中,  $\sigma()$  表示 GELU 激活函数,  $W_c()$  表示  $1 \times 1$  卷积,  $W_{d1}()$  表示  $3 \times 3$  深度可分离卷积,  $W_{d2}()$  表示  $5 \times 5$  深度可分离卷积。

#### 1.4 图像重建模块

现有的超分辨率重建算法在图像重建阶段大多采用像素重排或反卷积等上采样方法,这些方法虽然能够有效提升图像分辨率,但在处理复杂退化图像时容易引入伪影,导致重建图像的边缘细节模糊,影响图像重建效果。

针对上述问题,本文采用两次最近邻插值加卷积操作,如图 9 所示。首先,对低分辨率特征图进行最近邻插值操作,将其分辨率提升。然后,使用卷积层对插值后的特征图进行处理,进一步提升其细节和质量。接着,再次进行最近邻插值操作,继续提升分辨率。最后,通过第二

次卷积操作进行细化处理,生成最终的高分辨率图像。




图 9 图像重建模块

Fig. 9 Image reconstruction module

结合选通图像依赖纹理和边缘信息的特点,采用最近邻插值可以避免 PixelShuffle 和反卷积操作常见的伪影问题,通过卷积层后处理能生成更平滑的高分辨率图像,防止伪影对选通图像边缘信息造成干扰。同时针对选通图像的细节和边缘信息优化需求,通过插值后的卷积层调整,可以灵活优化灰度图像的细节和边缘,充分利用其纹理特点。而且,最近邻插值方法具有很高的稳定性,不会引入复杂的梯度问题,能够在各种复杂条件下稳定提供高质量的重建结果,有效应对选通图像这种由真实场景下复杂退化引起的图像质量问题。

## 2 实验结果及分析

### 2.1 数据集及训练细节

本文实验数据集采用激光距离选通相机采集,激光脉冲宽度和选通门宽为 150 ns,得到 800 幅选通图像,将这 800 幅选通图像作为高分辨率图像(HR),再将 HR 图像进行  $\times 2$ ,  $\times 3$  和  $\times 4$  的下采样操作,作为低分辨率图像(LR)与 HR 图像进行配对训练。部分图像如图 10 所示。

将数据集分割为 90% 的训练集和 10% 的验证集。此外,在训练过程中,随机利用  $90^\circ$ 、 $180^\circ$ 、 $270^\circ$  的旋转和水平翻转来增强数据。对 SR 结果的评估使用 PSNR 和 SSIM 两个指标进行<sup>[24]</sup>。

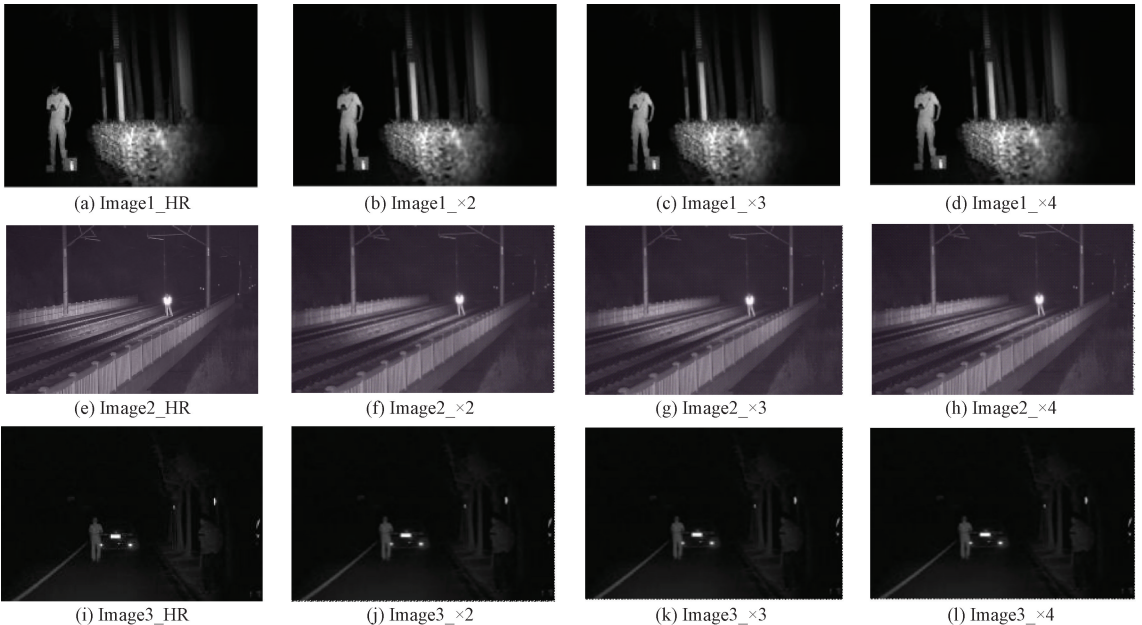


图 10 部分选通图像

Fig. 10 Partial gated image

2.2 实验结果分析

1)对比实验

(1)定量分析

为了保证实验结果公正,对比实验涉及的算法都使用选通图像数据集进行训练。在实验对比与分析部分,为了验证本文提出的算法性能及有效性,选取了 EDSR,RDN,RCAN,HAN,ELAN,SRFormer,HAT,SwinIR 和 DAT 等模型在 $\times 2$ 、 $\times 3$ 和 $\times 4$ 三个比例因子上进行对比。这几种方法同样采用了浅层特征提取、深层特征提取和图像重建的结构,与本文提出的算法具有相似的整体流程,具备较强的可对比性,能够全面反映本文算法的优势与改进点。

与这些方法相比,本文算法在浅层特征提取阶段引入空间与通道重建卷积,有效解决了特征冗余问题;在深层特

征提取阶段,通过全局与局部特征提取模块优化特征表达,强化了全局与局部信息的建模能力;在图像重建阶段,采用两次最近邻插值加卷积的方法,有效避免了伪影问题。

本文算法的评价指标采用 PNSR 和 SSIM 指标,PNSR 值越高,图像失真越小。SSIM 的范围为 $[-1, 1]$ ,数值越接近 1,重建图像与原 HR 图像的相似度越高。具体实验结果如表 1 所示。

因目前针对选通图像的超分辨率重建算法较少,从表 1 的实验可以看出本文提出的网络在选通图像超分辨率重建优于主流超分辨率重建方法,与具有代表性的 DAT 方法相比,本文 PNSR 指标在 2、3 和 4 倍分辨率退化情况下分别提升了 0.19、0.12 和 0.04 dB;SSIM 在 2、3 和 4 倍分辨率退化情况下分别提升了 0.000 5、0.000 8 和 0.001 0。该实验结果证明了本文所提出方法的有效性。

表 1 不同算法对比实验  
Table 1 Comparative experiments of different algorithms

倍数	方法	EDSR	RDN	RCAN	HAN	ELAN	SRFormer	HAT	SwinIR	DAT	DDFEN(本文方法)
$\times 2$	PNSR	34.92	35.12	35.21	35.29	35.41	35.47	35.32	35.62	35.70	<b>35.89</b>
	SSIM	0.925 3	0.925 5	0.926 2	0.927 6	0.930 5	0.932 0	0.929 7	0.932 7	0.933 5	<b>0.934 0</b>
$\times 3$	PNSR	31.62	31.65	31.71	31.75	31.90	31.96	31.99	32.27	32.31	<b>32.43</b>
	SSIM	0.853 1	0.854 3	0.855 5	0.856 1	0.858 9	0.859 9	0.859 0	0.862 9	0.863 5	<b>0.864 3</b>
$\times 4$	PNSR	29.95	29.93	29.99	30.10	30.17	30.23	30.12	30.41	30.47	<b>30.51</b>
	SSIM	0.803 7	0.804 3	0.804 7	0.805 9	0.807 6	0.808 9	0.807 9	0.810 2	0.811 2	<b>0.812 2</b>

(2)定性分析

图 11 和 12 展示了选通图像通过不同算法模型重建得到的图像。可以看到,Bicubic 算法所重建图像十分模糊,SwinIR 等网络可以重建出较为清晰的轮廓,但对于纹理结构的重建并不完善,DAT 网络虽重建纹理边缘较好,但图像模糊,DDFEN 网络所重建的图像不但轮廓清晰,结构合理,并且对于细节纹理的恢复也最接近 HR 图像。

2)消融实验

为了验证 DDFEN 网络中所添加的各个模块的有效性,本文在进行以下消融实验。实验中把 DAT 网络作为 Baseline;改进 1:在 Baseline 上引入 SCConv;改进 2:引入

深层特征提取模块 DSTG;改进 3:引入图像重建模块。消融实验结果如表 2 和图 13 所示。

首先为了证明 SCConv 模块的作用,在保持 DAT 模型整体网络结构不变的前提下,将浅层特征提取部分替换为 SCConv 卷积,从表 2 中指标可以看出 PNSR 和 SSIM 均有一定提升,从图 13 中可以看出图像整体模糊部分有一定减弱;在此基础上加入 DSFB 模块,从图中可以看到图像边缘和细节部分有所增强,但还是存在一定的噪声和伪影;最后,加入改进后的图像重建模块,可以看出指标提升的同时,图像线条边缘轮廓更加清晰,图像清晰度增强。

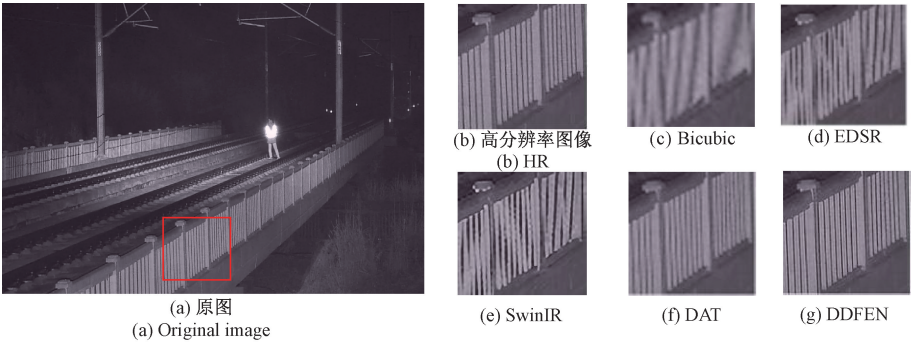


图 11 实验结果分析 1  
Fig. 11 Analysis of experimental results 1



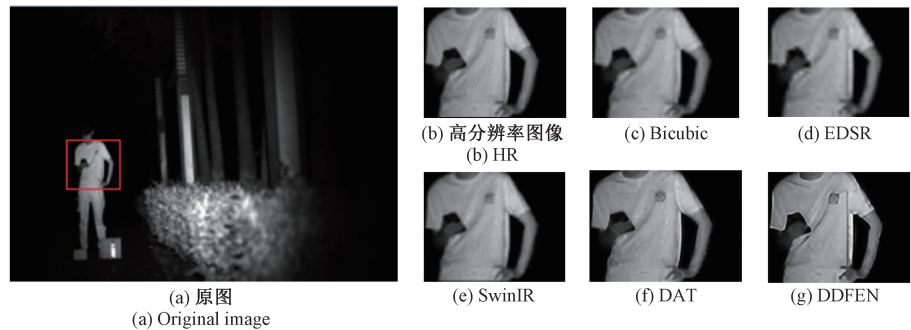


图 12 实验结果分析 2

Fig. 12 Analysis of experimental results 2

表 2 消融实验

Table 2 Ablation experiments

算法	+SCConv	+DSTG	+图像重建	PNSR	SSIM
DAT	—	—	—	35.70	0.933 5
改进 1	✓	—	—	35.76	0.933 6
改进 2	✓	✓	—	35.85	0.933 9
改进 3	✓	✓	✓	35.89	0.934 0




图 13 消融实验结果图(×2)

Fig. 13 Ablation test results (×2)

3 结 论

本研究通过对现有超分辨率重建网络模型的学习和分析,并结合选通图像特点,提出了一种新的超分辨率重建算法。具体而言,通过 SCConv 优化浅层特征提取过程,避免因信息冗余导致的效率低下;提出了一种新的深层特征提取模块 DSTG,增强对选通图像边缘和细节的捕捉能力;提出双门控深度卷积前馈网络(DGDFN),通过多样化的卷积核尺寸,捕捉不同尺度的边缘和纹理信息,增强选通图像细节重建的同时提高模型泛化性能。将 DAT 网络中图像重建部分的 PixelShuffle 替换为连续的最近邻插值加卷积操作,结合选通图像依赖纹理和边缘信息的特点,避免 PixelShuffle 和反卷积操作常见的伪影问题,有效应对选通图像这种由真实场景下复杂退化引起的图像质量

问题。大量实验结果表明,本文方法在客观指标、主观视觉和模型可解释性方面均优于目前主流的单图像超分辨率算法。未来的工作将侧重于在更多领域场景的图像和更轻量模型上进行多倍超分辨率重建,以进一步增强算法的泛化能力。

参考文献

[1] 杨彬,赵倩,赵琰.融合边缘检测的遥感图像超分辨率重建算法[J].电子测量技术,2023,46(10):136-143.  
YANG B, ZHAO Q, ZHAO Y. Remote sensing image super-resolution reconstruction algorithm with edge detection fusion [J]. Electronic Measurement Technology, 2023, 46(10): 136-143.

[2] 张天霖,逢征,陈红珍,等.面向舰船目标识别的遥感图像超分辨率重建[J].计算机工程与应用,2024,60(13):190-199.  
ZHANG T L, PANG ZH, CHEN H ZH, et al. Remote sensing image super-resolution reconstruction method for ship target recognition [J]. Computer Engineering and Applications, 2024, 60 ( 13 ): 190-199.

[3] 朱新峰,宋健.轻量级图像超分辨率研究综述[J].计算机工程与应用,2024,60(16):49-60.  
ZHU X F, SONG J. Review of research on lightweight image super-resolution [J]. Computer Engineering and Applications, 2024, 60(16): 49-60.

[4] 杨梦薇,肖秦琨,朱毅琳.基于深度残差网络的图像超分辨率重建[J].国外电子测量技术,2022,41(4):170-175.  
YANG M W, XIAO Q K, ZHU Y L. Image super-resolution reconstruction based on deep residual network [J]. Foreign Electronic Measurement Technology, 2022, 41(4): 170-175.

[5] 陈晓,荆茹韵.单图像超分辨率方法综述[J].电子测量技术,2022,45(9):104-112.  
CHEN X, JING R Y. A review of single image super-resolution methods [J]. Electronic Measurement

- Technology, 2022, 45(9): 104-112.
- [6] 李伟,张旭东. 基于卷积神经网络的深度图像超分辨率重建方法[J]. 电子测量与仪器学报, 2017, 31(12): 1918-1928.
- LI W, ZHANG X D. Depth image super-resolution reconstruction method based on convolutional neural network[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(12): 1918-1928.
- [7] DONG CH, LOY C C, HE K M, et al. Learning a deep convolutional network for image super-resolution [C]. European Conference on Computer Vision, 2014.
- [8] DONG CH, LOY C C, TANG X OU. Accelerating the super resolution convolutional neural network [C]. European Conference on Computer Vision, 2016.
- [9] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1646-1654.
- [10] 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.
- [11] GOODFELLOW I, POUGET A J, MIRZA M, et al. Generative adversarial networks[J]. ArXiv preprint arXiv: 1406.2661, 2014.
- [12] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]. IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2017: 105-114.
- [13] ZHANG Y L, TIAN Y P, KONG Y, et al. Residual dense network for image super-resolution[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2472-2481.
- [14] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks [C]. European Conference on Computer Vision(ECCV), 2018: 286-301.
- [15] NIU B, WEN W L, REN W, et al. Single image super-resolution via a holistic attention network[C]. Computer Vision-ECCV 2020: 16th European Conference, Glasgow: Springer International Publishing, 2020: 191-207.
- [16] LIANG J Y, CAO J ZH, SUN G L, et al. Swinir: Image restoration using swin transformer[C]. IEEE/CVF International Conference on Computer Vision, 2021: 1833-1844.
- [17] ZHANG X D, ZENG H, GUO S, et al. Efficient long-range attention network for image super-resolution [C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 649-667.
- [18] ZHOU Y P, LI ZH, GUO CH L, et al. Srformer: permuted self-attention for single image super-resolution [C]. IEEE/CVF International Conference on Computer Vision, 2023: 12780-12791.
- [19] CHEN X Y, WANG X T, ZHANG W L, et al. Hat: Pybrid attention transformer for image restoration[J]. ArXiv preprint arXiv:2309.05239, 2023.
- [20] CHEN ZH, ZHANG Y L, GU J J, et al. Dual aggregation transformer for image super-resolution [C]. IEEE/CVF International Conference on Computer Vision, 2023: 12312-12321.
- [21] LI J F, WEN Y, HE L H. SCConv: Spatial and channel reconstruction convolution for feature redundancy[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 6153-6162.
- [22] LI X, WANG W H, HU X L, et al. Selective kernel networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 510-519.
- [23] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. ArXiv preprint arXiv: 1511.07122, 2015.
- [24] 韩冉,曾广森,王荣杰. 基于残差块网络的图像去雨算法[J]. 仪器仪表学报, 2021, 41(8): 175-182.
- HAN R, ZENG G M, WANG R J. Image deraining algorithm based on residual block network[J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 175-182.

## 作者简介

张正, 博士, 副研究员, 主要研究方向为计算机视觉。  
Email: zhangzheng@ncut.edu.cn

郑颖俏(通信作者), 硕士研究生, 主要研究方向为计算机视觉。

E-mail: qq1398066277@163.com

田青, 博士, 教授, 主要研究方向为计算机视觉。

E-mail: tianqing@ncut.edu.cn