

DOI: 10. 19650/j. cnki. cjsi. J2412639

基于全方位深层加权轻量化网络的冠脉造影 图像超分辨率重建方法*

张博伟^{1,2}, 何彦霖^{1,2}, 王 康^{1,2}, 黄宇辰^{1,2}, 祝连庆^{1,2}

(1. 北京信息科技大学光电测试技术与仪器教育部重点实验室 北京 100192;
2. 北京信息科技大学广州南沙光子感知技术研究院 北京 511462)

摘要: 针对介入手术中对冠状动脉造影图像纹理清晰的需求, 本文提出一种基于全方位深层加权轻量化网络的超分辨率图像重建方法。首先通过设计局部卷积模块, 降低特征图的维度减小其参数量, 加快模型的处理速度; 接着采用自注意力机制模块, 融合图像的通道和空间信息, 获得图像的丰富高频细节特征; 此外, 为了进一步提取图像的深层特征信息, 研究设计了级联和权重匹配的层注意力结构, 为图像不同深度的特征分配不同的权重, 实现图像的超分辨率重建。最后为了使本文所研究方法在真实介入手术冠脉造影图像中有更强的泛化能力, 本文构建了冠脉造影图像数据集 (CAID) 用于网络模型的训练和测试。实验测试结果表明, 与 Omni-SR 算法相比, 本文所提出算法在参数量减少 32.3%、运行时间减少 17.74% 的同时, 其重建图像的质量在客观指标和主观感受上均优于其他对比算法, 且在放大倍数为 4 时, PSNR 和 SSIM 的平均值在 CAID 数据集上分别提高了 0.72 dB 和 0.012 2, 在公共数据集上分别提高了 0.13 dB 和 0.004 4。

关键词: 冠脉造影图像; 超分辨率重建; 局部卷积; 注意力机制; 轻量化

中图分类号: TP212 TH89 文献标识码: A 国家标准学科分类代码: 460.4020

Super resolution reconstruction of coronary angiography images based on the omnidirectional deep weighted lightweight network

Zhang Bowei^{1,2}, He Yanlin^{1,2}, Wang Kang^{1,2}, Huang Yuchen^{1,2}, Zhu Lianqing^{1,2}

(1. Beijing Laboratory of Optical Fiber Sensing and System, Beijing Information Science & Technology University, Beijing 100192, China; 2. Guangzhou Nansha Intelligent Photonic Sensing Research Institute, Beijing Information Science and Technology University, Beijing 511462, China)

Abstract: To meet the requirement of clear texture of coronary angiography images in interventional surgery, this article proposes a super-resolution image reconstruction method based on the omnidirectional deep weighted and lightweight network. Firstly, the local convolution module is designed to reduce the dimension of the feature map to reduce its parameter quantity and speed up the processing speed of the model. Then, the self-attention mechanism module is used to fuse the channel and spatial information of the image to obtain the rich high-frequency detail features of the image. In addition, to further extract the deep feature information of the image, a cascade and weight matching layer attention structure is designed to assign different weights to the features of different depths of the image to realize the super-resolution reconstruction of the image. Finally, to make the method have a stronger generalization ability in real interventional coronary angiography images, a coronary angiography image dataset (CAID) is constructed for training and testing the network model. The experimental results show that, compared with the Omni-SR algorithm, the proposed algorithm reduces the number of parameters by 32.3% and the running time by 17.74%. Meanwhile, the quality of the reconstructed image is better than other comparison algorithms in terms of objective indicators and subjective feelings. The average values of PSNR and SSIM are increased by 0.72 dB and 0.0122 on the CAID dataset, and 0.13 dB and 0.004 4 on the public dataset, respectively.

Keywords: coronary angiography images; super resolution reconstruction; local convolution; attention mechanism; light weight

0 引言

心血管疾病目前是全球范围内第一大疾病,冠心病(coronary artery disease, CAD)患者数量近年来急速增加。随着信息技术的飞速发展,用于冠心病诊疗的科学医疗技术也不断增多。其中最有效的是冠状动脉造影技术,被称为判断冠状动脉狭窄的金标准^[1]。冠状动脉造影成像需要使用数字减影血管造影(digital subtraction angiography, DSA)的方法,虽然 DSA 已经在心血管介入手术中被广泛应用,但是仍然存在一些问题^[2]:如术中大量使用造影剂,会对医生和患者产生辐射危害。但是在注入较低造影剂剂量时,图像质量不清晰,使得医生在操作时增加患者并发症发生的概率。因此有必要对冠脉造影图超分辨率重建技术进行研究,通过图像超分辨率重建技术提升医学影像清晰度,为后续病人的精准治疗奠定基础。

图像超分辨率(super resolution, SR)^[3]是一种计算机视觉和图像处理技术,它将低分辨率(low resolution, LR)图像重建为高分辨率(high resolution, HR)图像,可以在不改变成像设备物理特性的情况下提高显示图像的清晰度。目前按照算法原理可以分为基于非学习的重建方法和基于学习的重建方法。基于非学习的方法有双三次插值^[4]、最近邻插值^[5]、迭代反向投影法^[6]等,这些方法虽然计算简单但无法对大批图像进行快速重建。基于学习的方法有稀疏表示法^[7]、字典学习法^[8]等浅层学习方法和基于卷积神经网络^[9]的深度学习方法,基于浅层的学习方法计算复杂度低,但特征表达能力弱,近年来基于深度学习的超分辨率重建方法为解决传统方法的难点提供了更多思路。2014年 Dong 等^[10]首次提出了一种超分辨率卷积神经网络(super-resolution convolution neural network, SRCNN)算法,这是一种端到端的方法,层次结构简单,但重建出的图像不清晰。2016年 Shi 等^[11]通过引入亚像素卷积层,可以有效放大图像,但容易丢失局部细节。2017年 Vanswani 等^[12]提出了 Transformer,该方法采用自注意力机制捕获图像的全局内容信息,但是存在大量的参数量。2021年 Liu 等^[13]提出了 Swin Transformer 模型, Swin Transformer 采用分层设计和移位窗口的方法可以与广泛的视觉任务兼容,但不能提取深层次的通道和空间信息,无法充分表示出细节信息。2021年 Liang 等^[14]提出了 SwinIR 首次将 Swin Transformer 应用于 SR, SwinIR 主要由多个残差窗口移位转换模块组成,虽然网络框架灵活,图像超分辨率重建结果有了较大提高,但该算法对图像边缘信息的提取能力差。2022年 Yu 等^[15]提出了基于注意力机制的 Transformer 网络用于注入造影剂后的医学成像,没有受

到卷积算子固有属性的限制,重建的血管图像清晰度有了一定提高,但算法运行时间较长。2023年 Wang 等^[16]提出了 Omni-SR,它关注空间和通道全面的相互作用,但无法对深层纹理信息进行有效处理。同年 Baccarelli 等^[17]提出了一种孪生残差自编码器结构进行医学影像病变位置的超分辨率重建,但计算复杂度较高。2023年 Zhao 等^[18]提出了一种基于残差注意力网络的医学图像超分辨率重建方法来增强医学组织的弱边界并抑制噪声,但算法的需要较长时间的运行。

针对以上研究存在的问题,本文提出了一种全方位深层加权的轻量化图像超分辨率重建算法。通过设计局部卷积模块对输入特征降维处理,减少网络参数。融合通道和空间信息获得图像丰富的高频细节特征,通过不同权重的深度特征分布提高图像特征的提取能力,最后构建冠脉造影图像数据集(coronary angiography image dataset, CAID)用于网络模型的训练和测试。

1 基于全方位深层加权轻量化网络的超分辨率重建方法

本文提出的基于全方位深层加权轻量化网络的超分辨率重建方法如图 1 所示,网络整体结构由 3 部分组成,即浅层特征提取、深层特征提取和图像重建模块。首先由单个卷积层进行浅层特征提取;然后设计局部卷积模块,采用全方位自注意力(omni self-attention, OSA)模块与层注意力模块结合,充分利用通道和空间的信息,为 K 个级联的全方位自注意力模块组赋予不同的权重,即使随着网络的加深重要信息分散到不同的通道也能够得到及时的处理;最后通过亚像素卷积模块生成超分辨率重建图像。

1.1 浅层特征提取模块

在浅层特征提取阶段,给定 LR 输入 $I_{LR} \in R^{H \times W \times C_m}$,首先使用单个 3×3 卷积提取浅层特征 $X_0 \in R^{H \times W \times C}$,提取出来的浅层特征图通道数为 64,如式(1)所述。

$$X_0 = H_{CONV}(I_{LR}) \quad (1)$$

其中, C_m 表示输入特征的通道数; C 表示浅层特征的通道数; H_{CONV} 表示卷积操作。卷积层提供了一种简单的方法将输入从图像空间转换到高维特征空间。

其次,在图像重建部分,增加了压缩激励(squeeze excitation, SE)模块,能够以轻微的计算性能损失带来优秀的重建效果。为了挖掘隐藏在潜在变量中的所有相关性,一种称为全方位自注意力模块同时建立了空间和通道关联信息,确定的二维关系对于轻量化模型有一定的必要性和帮助。一方面,随着网络的加深,重要信息分散到不同的通道中^[19],及时处理至关重要。另一方面,

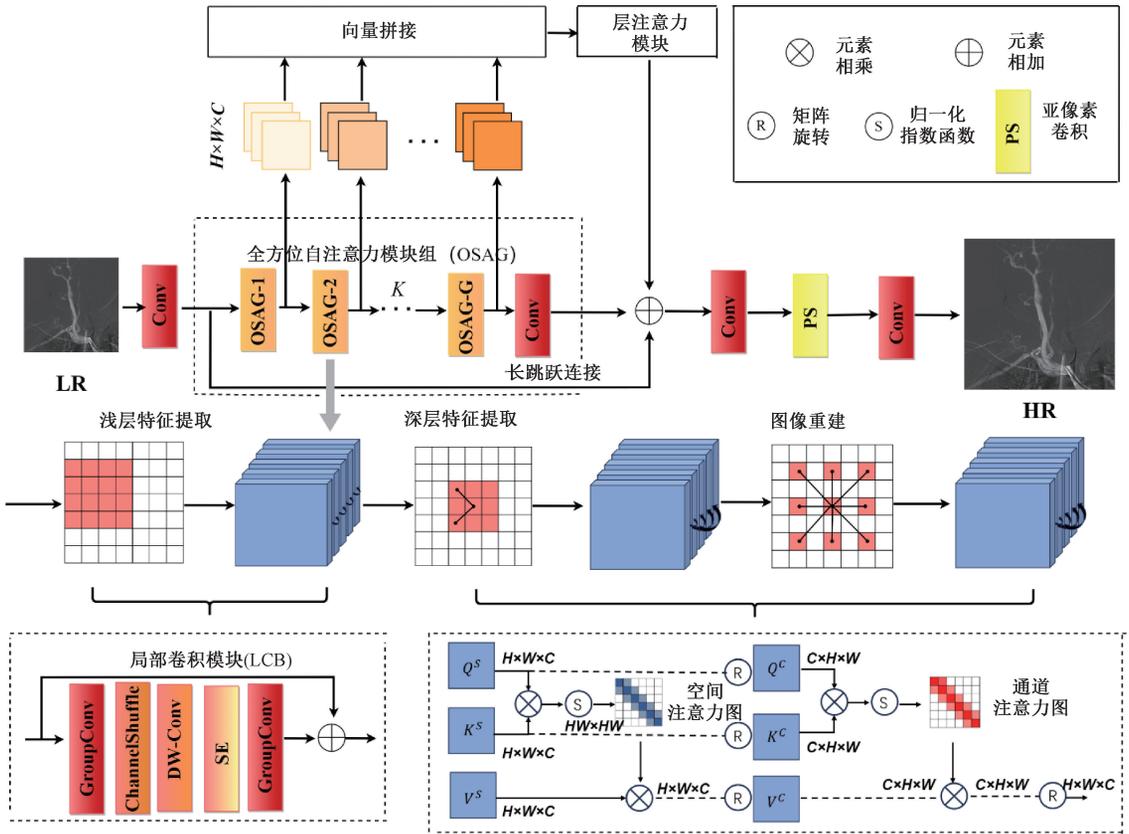


图1 全方位深层加权超分辨率重建网络结构

Fig. 1 Omnidirectional deep weighted super resolution reconstruction network architecture

虽然空间自注意力机制在计算协方差时利用了通道维度,但它并没有在通道之间传递信息。鉴于上述条件,全方位自注意力模块旨在以紧凑的方式传递空间和维度信息。

1.2 深层特征提取模块

考虑到冠脉造影图像本身像素信息比较单调,边缘特征较弱,且部分深层特征信息容易在特征重建过程中随着网络的加深而丢失,从而导致重建后的冠脉造影图像出现纹理模糊和边缘锯齿效应的问题,因此在深层特征提取模块中设计局部卷积模块,并采用全方位自注意力机制,进一步设计了层注意力模块,加强各网络层之间的信息交互,不同网络深度的特征信息能够得到有效利用。

1) 局部卷积模块

本文设计的局部卷积模块示意图如图2所示,首先采用数目为2的组卷积和通道混洗的方法可以有效降低逐点卷积的计算量,然后利用深度可分离卷积(depthwise convolution, DW-Conv)^[20]进一步降低参数量,最后增加压缩激励^[19]模块,能够以轻微的计算性能损失带来优秀的重建效果,再使用分组卷积恢复到与输入相同的维度,通过残差结构与初始特征融合。

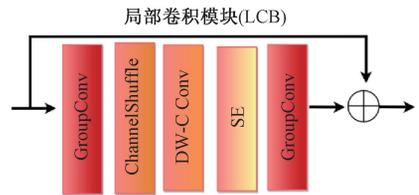


图2 局部卷积结构

Fig. 2 Local convolution structure

2) 全方位自注意力机制

部分研究表明^[21],空间注意力和通道注意力所提取的特征具有互补性,可以实现深层次的特征提取。本文采用全方位自注意力(omni self-attention, OSA)模块同时建立了空间和通道关联信息。OSA块遵循典型的Transformer设计,采用前馈网络(feedforward network, FFN)和层归一化。具体设 $X \in R^{H \times W \times C}$ 为输入特征, H 和 W 分别为输入的宽度和高度 C 为通道数。首先,通过线性投影将 X 嵌入查询、键和值矩阵, $Q^S, K^S, V^S \in R^{H \times W \times C}$,通过计算查询和键矩阵得到大小为 $R^H \times R^W$ 的空间注意力图。然后进行空间注意力计算,得到中间聚合结果,一般采用窗口策略来显著减少资源开销。之后旋转输入的查询

和键矩阵,得到转置的查询和键矩阵 $Q^C, K^C \in R^{C \times H \times W}$,之后将旋转的值矩阵 $V^C \in R^{C \times H \times W}$ 用于后续的通道自注意力,并对所获得的通道注意力图的大小 $R^{C \times C}$ 从通道关系方面进行了建模。最后,通过通道注意力输出 Y_C 的反向旋转矩阵得到最终聚合的结果 Y_{OSA} 。过程如以下公式所述:

$$Q^S = X \cdot W_q, V^S = X \cdot W_v \quad (2)$$

$$Y_S = A^S(Q^S, K^S, V^S) = \text{SoftMax}(Q^S K^{ST}) \cdot V^S \quad (3)$$

$$Q^C = R(Q^S), K^C = R(K^S), V^C = R(V^S) \quad (4)$$

$$Y_C = A^C(Q^C, K^C, V^C) = \text{SoftMax}(K^C Q^{CT}) \cdot V^C \quad (5)$$

$$Y_{OSA} = R^{-1}(Y_C) \quad (6)$$

$$X_i = H_{OSA_i}(X_{i-1}), i = 1, 2, \dots, K \quad (7)$$

$$X_{DF} = H_{CONV}(X_i) \quad (8)$$

其中, W_q, W_k, W_v 分别表示查询、键和值的线性投影

矩阵; Q', K', V' 是通道自注意力的输入嵌入矩阵,它们由空间自注意力嵌入或直接从 Q^S, K^S, V^S 复制; $R(\cdot)$ 表示围绕空间轴的旋转操作, $R^{-1}(\cdot)$ 表示逆旋转; H_{OSA_i} 表示第 i 个 OSAG 块。

全方位自注意力模块组由局部卷积模块和全方位自注意力机制构成,本文使用 3 个堆叠的全方位自注意力模块组提取深度特征。

3) 层注意力模块

本文将每个层的特征图视为对特定类的响应,并且来自不同层的响应彼此相关,层注意力(layer attention, LA)模块如图 3 所示。通过获得不同深度的特征之间的依赖关系,网络可以为不同深度的特征分配不同的注意力权重,并自动提高提取特征的代表能力。

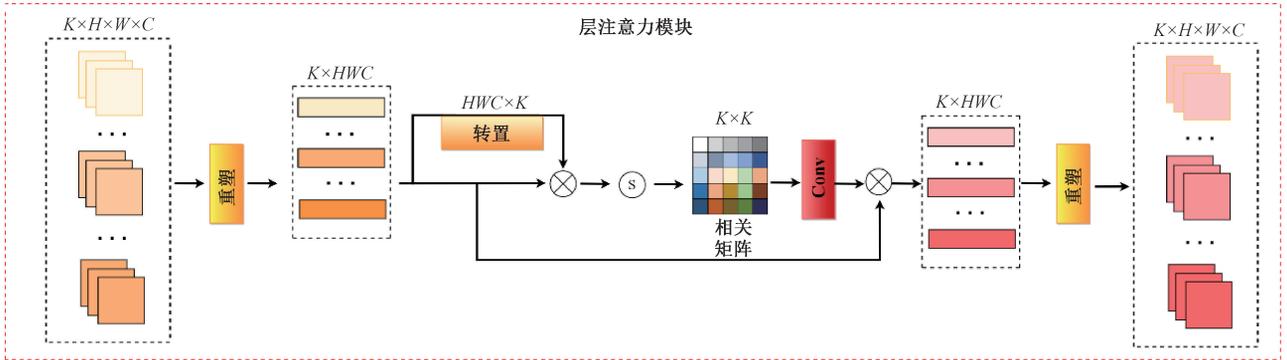


图3 层注意力模块示意图

Fig. 3 Diagram of the layer attention block

本文所设计的层注意结构输入为提取的中间特征组 OSAGs,维度为 $K \times H \times W \times C$,然后将中间特征组重塑为一个 $K \times HWC$ 的二维矩阵,采用矩阵乘法和相应的转置运算计算各个层间的相关性如下公式所示:

$$\omega_{i,j} = \delta(\psi(OSAG))_j^i, i, j = 1, 2, \dots \quad (9)$$

其中, δ 和 ψ 表示归一化指数函数和重塑操作; $\omega_{i,j}$ 表示第 i 个和第 j 个特征组之间的相关指数。最后,本文将重构后的特征组 OSAGs 乘以带有尺度因子 α 的预测相关矩阵,并添加输入特征 OSAGs。

$$O_{L_j} = \alpha \sum_{i=1}^K \omega_{i,j} OSAG_i + OSAG_j \quad (10)$$

最终本文将图像的浅层特征和深层特征聚合:

$$I_{DR} = H_{Rec}(X_0 + X_{DF} + O_L) \quad (11)$$

1.3 图像重建模块

本文的网络模型输入的是原始低分辨率图像,经过浅层特征提取模块和深层特征提取模块后,利用亚像素卷积方法对图像进行上采样,具体实现方法是:首先通过卷积得到与输入图像尺寸一致、通道数为 r^2 的特征图像,再将特征图的每个像素的 r^2 个通道重新排列成一个 $r \times r$ 的区域,对应高分辨图像中一个 $r \times r$ 大小的子块,从而

大小为 $H \times W \times r^2$ 的特征图像被重新排列成 $rH \times rW \times r$ 的高分辨率图像,重建出高分辨率的图像,过程如式(12)所示。

$$I_{SR} = G_{sub}(H_{CONV}(I_{DR})) \quad (12)$$

其中, G_{sub} 表示亚像素卷积操作; I_{SR} 表示生成的超分辨率重建图像。

1.4 损失函数

为了在图像超分辨率重建过程中增强图像的细节、提高图像的清晰度,本文选择对异常值具有较好的鲁棒性、有助于降低模型过拟合的风险的 L1 绝对值误差损失函数。本文网络在训练过程中采用 L1 绝对值误差损失函数来训练网络模型,对于给定冠脉造影图像训练集 $\{I_{LR}^i, I_{HR}^i\}_{i=1}^N$ 有 N 组高低分辨率对应的图像,损失函数具体计算如式(13)所示。

$$L_1(\theta) = \frac{1}{N} \sum_{i=1}^N \|\{I_{HR}^i - I_{SR}^i\}_{i=1}^N\|_1 \quad (13)$$

其中, θ 表示网络参数包括各层权值 w_i 和偏置参数的集合 b_i ,即 $\theta = (w_1, w_2, \dots, w_i, b_1, b_2, \dots, b_i)$; I_{HR}^i 表示原始高分辨率图像; I_{SR}^i 表示经本文算法重建后的超分辨率图像。

2 实验设置与模型训练

目前先进的图像超分辨率重建算法都是基于公共数据集包括 91-image、ImageNet、DIV2K 等进行网络模型训练的,这些数据集包括自然风景、生活建筑、人类行为等图像,然而当面对灰度较低的低分辨率造影图像时,这些超分辨率算法往往达不到较好的重建效果,对医学影像重建任务具有局限性。因此,本文构建了一种冠脉造影图像数据集用于训练和测试,部分图像如图 4 所示,另外在公共数据集 DIV2K 上与其他超分辨率算法进行了对比实验,使模型在真实手术场景中具有更好的泛化能力。冠脉造影图像数据由北京安贞医院提供,然后对图像集进行筛选处理,剔除掉损坏图像和极其模糊图像,并且将图像统一裁剪成 1 024×942 尺寸的图像,最终生成 1 000 张造影图像,随机抽取 800 张造影图像 CAID800 通过旋转 90°、180°、270°和水平翻转进行数据增强扩充成 4 000 张用于网络的训练。使用 OpenCV 对这些 HR 图像进行 m ($m=2, 3, 4$)倍下采样得到 LR 图像集。采用剩余的 CAID 数据集 100 张图像构成 CAID100 进行测试。

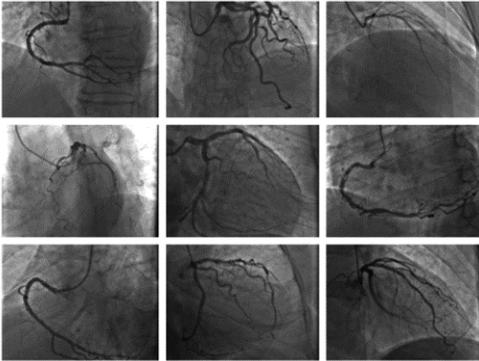


图 4 冠脉造影图像数据集部分图像

Fig. 4 Images of coronary angiography image dataset

在训练过程中 OSAG 的数目设置为 3,整个网络的通道数设置为 64,注意力的头数设置为 4,窗口的大小设置为 4,分组卷积的数目设置为 2,采用 1×1 卷积使通道维度匹配,采用 AdamW^[22] 优化器对批量大小为 64 的模型进行 800 K 次迭代训练,初始学习率 5×10^{-4} 同时每 200 K 次迭代减半,在每个训练批次中,随机裁剪大小为 64×64 的 LR 块作为输入,本文的方法采用 Pytorch 实现,所有实验均在 NVIDIA4090 上进行。

3 实验结果分析与讨论

3.1 评价指标

本文采用均方误差(mean square error, MSE)^[23]和

峰值信噪比(peak signal to noise ratio, PSNR)^[24]以及结构相似性(structural similarity, SSIM)^[25]客观对比重建算法的性能。

MSE 一般用来计算两张图像中每个位置的像素差异,在对图像的质量评估时,MSE 越小待评估图像的质量越好,计算公式如式(14)所示。

$$MSE = \frac{1}{M \cdot N} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [I(i,j) - K(i,j)]^2 \quad (14)$$

其中, M 和 N 分别表示图像 I 和 K 的像素总数,MSE 值越小图像越相似。

PSNR 基于两幅图像像素的差异,是评估重建图像和原始图像之间差异的一种度量方法,单位为 dB,其数值越高,代表重建图像的质量越好,计算公式如式(15)所示。

$$PSNR = 10 \lg \frac{255^2 \times W \times H \times C}{\sum_{i=1}^W \sum_{j=1}^H \sum_{k=1}^C [\bar{x}(i,j,k) - x(x,j,k)]^2} \quad (15)$$

其中, W, H, C 分别表示图像的宽度、长度和通道数, \bar{x} 表示 SR 图像, x 表示原图像。

结构相似性是一种全参考评估方法,考虑了亮度、对比度和结构等因素,能够更好地模拟人眼对图像质量的感知,其数值越接近 1 效果越好,计算公式如式(16)所示。

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + c_1)(\sigma_{xy} + c_2)}{(\mu_x^2\mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (16)$$

其中, μ_x 和 μ_y 分别表示图像 x 和 y 的均值,表示亮度; σ_x^2 和 σ_y^2 分别表示为图像 x 和 y 的方差,表示对比度; σ_{xy} 为图像 x 和 y 的协方差,表示结构; c_1, c_2 为常数, $c_1 = (k_1 \times L)^2, c_2 = (k_2 \times L)^2$,通常取 $k_1 = 0.01, k_2 = 0.03; L = 255$ 。

3.2 重建效果与性能对比

为了评估本文提出的超分辨率重建方法的有效性,将本文的模型与传统方法 Bicubic 和基于深度学习的 SR 重建方法分别是 CARN^[26]、RFDN-L^[27]、RLFN^[28]、SwinIR^[14]、Omni-SR^[16]在 2 倍、3 倍和 4 倍比例因子的情况下进行了对比,图 5、6 为 4 倍放大因子下各种算法 PSNR、SSIM 值评价统计图,从图中可以直观看出,本文所提出方法的 PSNR 和 SSIM 值均高于其他算法,可以有效提取图像深层特征丰富的细节信息,进而更好的重建图像的边缘细节。

表 1 为本文算法与其他算法在构建的 CAID100 数据集上重建后的性能评价指标对比。从表 1 的结果可以看出,本文的算法模型在不同的放大倍数上都超越了其他几种算法,相比于 Bicubic、CARN、RFDN-L、SwinIR、Omni-SR 算法在 4 倍放大因子下 PSNR 平均值分别提升了 2.26、1.36、0.66、0.58 和 0.72 dB;SSIM 平均值分别提高

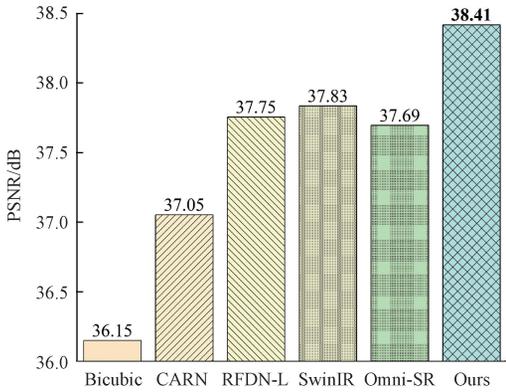


图 5 在 4 倍放大因子下各算法的 PSNR 值评价统计图
Fig. 5 Statistical graph of PSNR value evaluation of each algorithm under 4 times magnification

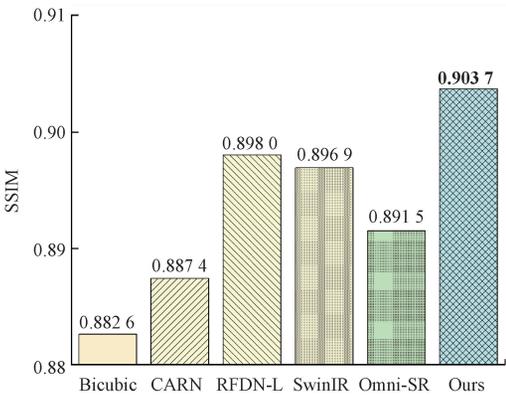


图 6 在 4 倍放大因子下各算法的 SSIM 结果评价统计图
Fig. 6 Statistical graph of SSIM value evaluation of each algorithm under 4 times magnification

了 0.021 1、0.016 3、0.005 7、0.006 8 和 0.012 2。

视觉主观比较:为了进一步验证本文提出的全方位深层加权网络对冠脉造影图像边缘细节信息重建能力的提升,分别选取了 CAID100 测试集上随机两位患者的造影图像进行可视化分析比较。图 7 中显示了其他算法在重建冠脉造影的血管分支结构时,模糊感较重,层次不分明,而本文算法可以清晰地看到冠脉造影血管的分支细节部分。在图 8 中其他算法重构的图像难以定位冠脉造影图像中含有介入导丝的末端部分,而本文的算法可以定位到介入导丝的末端位置。这些比较结果表明,本文算法在客观指标和主观视觉对比上均优于其他超分辨率重建算法,之所以能够预测更多的边缘高频细节,主要得益于局部卷积模块、自注意力模块和层注意力结构能够提取丰富的高频信息并赋予不同的权重,将得到的分层特征信息融合,可以更好地重建冠脉造影图像的结构特征和纹理细节。

表 1 在 CAID 数据集上使用不同的 SR 算法的定量比较
Table 1 Quantitative comparison of the most advanced lightweight image SR on CAID datasets

Scale	Method	Params	MSE	PSNR	SSIM
×2	Bicubic	75	4.879 7	41.13	0.935 5
	CARN	1 592	4.280 4	42.22	0.931 1
	RFDN-L	643	3.960 5	42.57	0.939 1
	SwinIR	897	3.626 8	43.26	0.931 8
	Omni-SR	792	3.157 2	43.95	0.938 1
	本文	536	2.392 9	45.39	0.975 5
×3	Bicubic	75	8.579 9	38.35	0.905 6
	CARN	1 592	6.535 7	39.65	0.910 2
	RFDN-L	643	6.034 5	39.97	0.912 6
	SwinIR	897	5.795 8	40.15	0.914 8
	Omni-SR	792	5.222 3	40.59	0.915 5
	本文	536	4.136 2	41.51	0.935 4
×4	Bicubic	75	15.888 8	36.15	0.882 6
	CARN	1 592	12.153 5	37.05	0.887 4
	RFDN-L	643	10.074 5	37.75	0.898 0
	SwinIR	897	9.763 8	37.83	0.896 9
	Omni-SR	792	10.325 7	37.69	0.891 5
	本文	536	8.241 9	38.41	0.903 7

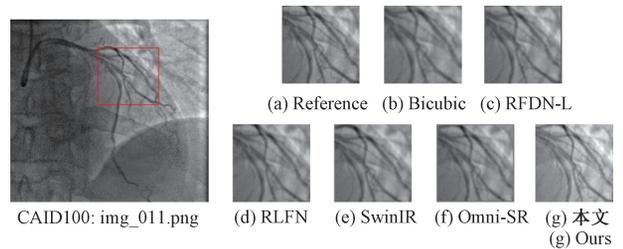


图 7 CAID100 数据集中 img_011 放大 4 倍效果对比图
Fig. 7 Comparison of img_011 magnified 4 times in CAID100 dataset

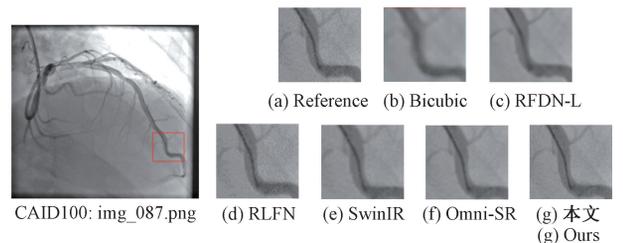


图 8 CAID100 数据集中 img_087 放大 4 倍效果对比图
Fig. 8 Comparison of img_087 magnified 4 times in CAID100 dataset

另外本文算法还在公共数据集 DIV2K^[29] 上与其他超分辨率算法进行了对比实验。DIV2K 数据集已被广泛应用于图像超分辨率领域,该数据集包括 800 张训练图像,100 张验证图像,100 张测试图像。本文算法使用该

数据集中的 800 张训练图像通过旋转 90°、180°、270° 和水平翻转进行数据增强用于网络的训练,并且使用基准数据集 Set5^[30]、Set14^[31] 和 Urban100^[32] 进行测试,实验结果具体数据如表 2 所示。

表 2 在基准数据集上使用不同的 SR 算法的定量比较

Table 2 Quantitative comparison of different SR algorithms on the baseline datasets

Scale	Method	Params	Set5	Set14	Urban100
			PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
×2	Bicubic	75	33.66/0.929 9	30.24/0.868 8	26.88/0.840 3
	CARN	1 592	37.81/0.959 5	33.55/0.917 0	31.97/0.925 5
	RFDN-L	643	38.10/0.960 8	33.64/0.918 9	32.25/0.929 1
	RLFN	543	38.07/0.960 7	33.75/0.919 0	32.33/0.929 9
	SwinIR	897	38.16/0.961 3	33.86/0.920 7	32.77/0.934 3
	Omni-SR	792	38.29/0.961 7	34.27/0.923 8	33.30/0.938 6
	本文	536	38.35/0.963 5	34.33/0.925 3	33.36/0.940 9
×3	Bicubic	75	30.39/0.868 2	27.55/0.774 2	24.46/0.734 9
	CARN	1 592	34.31/0.925 7	30.31/0.841 0	28.06/0.849 3
	RFDN-L	643	34.46/0.927 9	30.35/0.842 1	28.34/0.855 2
	RLFN	543	34.51/0.928 3	30.45/0.844 1	28.49/0.859 4
	SwinIR	897	34.65/0.929 1	30.55/0.846 5	28.67/0.862 4
	Omni-SR	792	34.76/0.930 4	30.70/0.848 9	29.12/0.871 0
	本文	536	35.84/0.932 1	30.76/0.849 8	29.17/0.872 9
×4	Bicubic	75	28.42/0.810 4	26.00/0.702 7	23.14/0.657 7
	CARN	1 592	32.15/0.895 1	28.55/0.779 3	26.15/0.788 2
	RFDN-L	643	32.34/0.898 7	28.65/0.782 5	26.35/0.789 7
	RLFN	543	32.31/0.897 7	28.65/0.784 5	26.34/0.789 3
	SwinIR	897	32.51/0.899 0	28.79/0.786 1	26.27/0.808 5
	Omni-SR	792	32.59/0.899 7	28.97/0.792 1	26.96/0.812 8
	本文	536	32.63/0.901 3	29.06/0.803 3	27.09/0.817 2

由表 2 结果可知,在公共数据集上本文算法的重建效果均优于其他超分辨率重建算法。在基准测试集 Urban100 上进行放大倍数为 4 的重建结果中,本文算法比 Bicubic、CARN、RFDN-L、RLFN、SwinIR 和 Omni-SR 算法在 PSNR 值上分别提升了 3.95、0.94、0.74、0.75、0.82 和 0.13 dB,在 SSIM 上分别提升了 0.159 5、0.029 0、0.027 5、0.027 9、0.008 7 和 0.004 4。在图 9 中,其他算法重建出的鸟喙存在边缘不清的虚化问题,而本文重建出来的算法鸟喙结构较为清晰。在图 10 中,其他算法重建出来的婴儿睫毛边缘粗糙,本文算法重建出来的睫毛边缘清晰度有了很大提高。在图 11 中其他算法重建出来的高楼窗户边缘模糊感较重,而本文算法重建的窗户条纹更加合理,同时降低了模糊感。实验结果表明本文

提出的全方位深层加权超分辨率重建网络相较于其他算法在网络性能上有一定的提升。

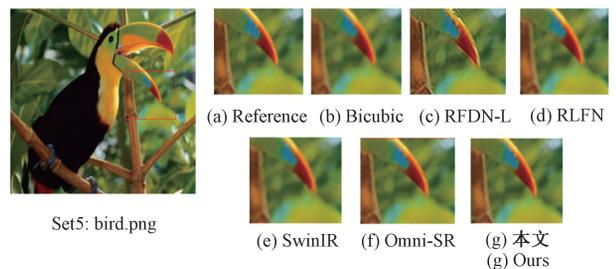


图 9 Set5 数据集中 bird 放大 4 倍效果对比图

Fig. 9 Comparison of bird magnified 4 times in Set5 dataset

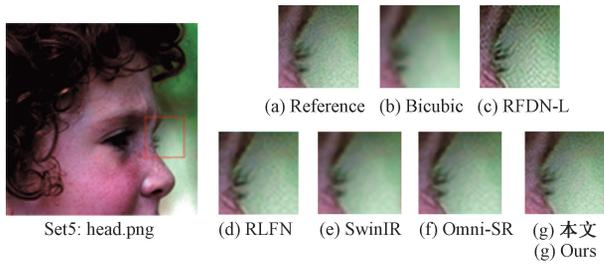


图 10 Set5 数据集中 head 放大 4 倍效果对比图

Fig. 10 Comparison of head magnified 4 times in Set5 dataset

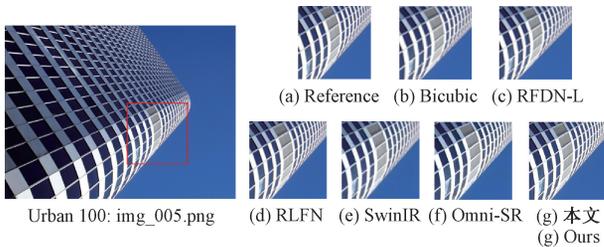


图 11 Urban100 数据集中 img_005 放大 4 倍效果对比图

Fig. 11 Comparison of img_005 magnified 4 times in Urban100 dataset

为验证本文所提出基于全方位深层加权轻量化网络的超分辨率重建方法的性能,与 CARN、RLFN、SwinIR 和 Omni-SR 等图像超分辨率重建算法进行参数量、运行时间 (running time) 和性能的对比如表 3 所示,其中性能指标使用的是各算法在冠脉造影测试集上的 PSNR 平均值。图 12 为各算法模型参数量和性能的对比如表 3 和图 12 中可以看出本文算法模型在参数量较低的水平下,在重建性能上高于对比的各类算法。相对于当前主流的超分辨率重建算法,本文所提出的算法模型在性能、参数量和计算复杂度之间达到了更好的平衡。该模型在提高网络重建性能的同时具备较低的参数量和运行时间,从而使网络更加轻量。

表 3 算法复杂度对比

Table 3 Algorithm complexity comparison

算法	参数量/K	运行时间/ms	PSNR/dB
CARN	1 592	39.96	37.05
RLFN	543	16.41	37.75
SwinIR	897	28.63	37.83
Omni-SR	792	19.90	37.69
本文	536	16.37	38.41

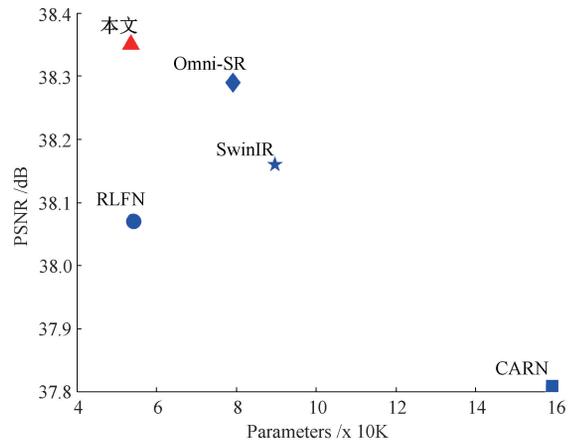


图 12 各算法参数量在冠脉造影数据集上对应 PSNR 值比较

Fig. 12 The number of algorithm parameters is compared with the corresponding PSNR value on the coronary angiography dataset

3.3 消融实验

为了分析局部卷积模块、自注意力模块和层注意力结构对本文提出的网络性能的影响,本文将去除局部卷积模块、去除自注意力模块与去除层注意力结构的 4 种网络模型在放大倍数为 4 的冠脉造影测试集上的超分辨率重建结果进行了对比。由于去除自注意力模块参数会相应减少,为了公平比较,对去除注意力模块的网络增加相应的通道数来保持两种情况下的参数一致,结果如表 4 所示。模型 a 表示未加入局部卷积模块、自注意力模块和层注意力结构;模型 b 表示未加入自注意力模块和层注意力结构;模型 c 表示未加入局部卷积模块和层注意力结构;模型 d 表示未加入局部卷积模块和自注意力模块。可以看出,增加自注意力模块比增加层注意力结构在测试集上提升了 0.07 dB,说明融入自注意力结构比融入层注意力结构的提升更大;增加自注意力模块和增加层注意力结构比增加局部卷积模块在测试集上分别提升了 0.23、0.13 dB,说明采用深层加权的特征提取网络可以有效提高网络的表达能力;将三者组合可以显著提升网络对冠脉造影图像的重建效果。

表 4 消融实验对比

Table 4 Comparison of ablation experiments

模型	LCB	OSA	LA	PSNR/dB
a	×	×	×	36.15
b	√	×	×	38.10
c	×	√	×	38.33
d	×	×	√	38.26

4 结 论

本文针对血管介入手术冠脉造影图像纹理不清晰的问题,提出了一种基于全方位深层加权轻量化网络的图像超分辨率重建方法。通过结合局部卷积、全方位自注意力机制以及不同深度特征的权重系数分配,在减少参数使网络轻量化的同时加快了模型的处理速度,提高了图像高频细节特征的提取和处理能力,实现了具有清晰纹理的冠脉造影图像超分辨率重建。实验结果表明,与Omni-SR算法相比,本文所提出算法在参数量减少32.3%、运行时间减少17.74%的同时,其重建图像的质量在客观指标和主观感受上均优于其他对比算法,且在放大倍数为4时,PSNR和SSIM的平均值在CAID数据集上分别提高了0.72 dB和0.012 2,在公共数据集上分别提高了0.13 dB和0.004 4。本文所提出方法可以实现冠脉造影图像的超分辨率重建,可为提升介入手术精准导航提供一定的方法和技术支撑。

参考文献

- [1] KHAN S U, AGARWAL S, ARSHAD H B, et al. Intravascular imaging guided versus coronary angiography guided percutaneous coronary intervention; Systematic review and meta-analysis[J]. *BMJ*, 2023, 383:077848.
- [2] 董兆苒,董明利,何彦霖,等. 血管介入手术导丝末端检测方法研究[J]. *仪器仪表学报*, 2023, 44 (2): 221-229.
DONG ZH R, DONG M L, HE Y L, et al. Study on the detection method of putting guide wire endin vascular interventional surgery[J]. *Chinese Journal of Scientific Instrument*, 2023, 44 (2): 221-229.
- [3] 程德强,陈杰,寇旗旗,等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. *仪器仪表学报*, 2022, 43(8): 73-84.
CHENG D Q, CHEN J, KOU Q Q, et al. Lightweight super-resolution reconstruction method based on hierarchical features fusion and attention mechanism for mine image[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(8): 73-84.
- [4] GANESAN P, RAVICHANDRAN M, SATHISH B, et al. Comparative study of implementation of very deep super resolution neural network and bicubic interpolation for single image super resolution quality enhancement[C]. 2023 IEEE 3rd International Conference on Applied Electromagnetics, Signal Processing, & Communication (AESPC), 2023: 1-7.
- [5] YU L. Application of infrared image detection based on high-resolution image processing in motion recognition[J]. *Optical and Quantum Electronics*, 2024, 56 (4): 1-17.
- [6] RASTI P, DEMIREL H, ANBARJAFARI G. Iterative back projection based image resolution enhancement[C]. 2013 8th Iranian Conference on Machine Vision and Image Processing(MVIP), 2013: 237-240.
- [7] ZHANG ZH, XU Y, YANG J, et al. A survey of sparse representation; Algorithms and applications[J]. *IEEE Access*, 2015,3: 490-530.
- [8] MAIRAL J, BACH F, PONCE J. Task-driven dictionary learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 34 (4): 791-804.
- [9] 苑玮琦,王安. 基于并联多尺度卷积神经网络的微动脉瘤检测方法[J]. *仪器仪表学报*, 2023, 44 (11): 224-233.
YUAN W Q, WANG AN. Microaneurysm detection method based on parallel multi-scale convolution neural network[J]. *Chinese Journal of Scientific Instrument*, 2023, 44 (11): 224-233.
- [10] DONG C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution [C]. *Computer Vision-ECCV 2014: Part IV*, 2014: 184-199.
- [11] SHI W ZH, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.
- [12] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [13] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 9992-10002.
- [14] LIANG J Y, CAO J ZH, SUN G L, et al. Swinir: Image restoration using swin transformer[C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 1833-1844.
- [15] YU P X, ZHANG H Y, KANG H, et al. Rplhr-CT dataset and transformer baseline for volumetric super-resolution from ct scans[C]. *Medical Image Computing and Computer-Assisted Intervention*, 2022: 344-353.
- [16] WANG H, CHEN X H, NI B B, et al. Omni aggregation networks for lightweight image super-resolution [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 22378-22387.
- [17] BACCARELLI E, SCARPINITI M, MOMENZADEH A. Twinned residual auto-encoder (TRAE)—A new DL

- architecture for denoising super-resolution and task-aware feature learning from COVID-19 CT images [J]. *Expert Systems with Applications*, 2023, 225: 120104.
- [18] ZHAO D X, WANG W, XIAO ZH T, et al. Medical images super resolution reconstruction based on residual network [J]. *2021 7th International Conference on Computing and Artificial Intelligence*, 2021:119-126.
- [19] HU J, LI SH, GANG S. Squeeze-and-excitation networks[C]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020,42(8):2011-2023.
- [20] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 1800-1807.
- [21] LI H F, QIU K J, CHEN L, et al. SCAAttNet: Semantic segmentation network with spatial and channel attention mechanism for high-resolution remote sensing images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 18 (5): 905-909.
- [22] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization[J]. *ArXiv preprint arXiv: 1711.05101*, 2017.
- [23] CHICCO D, WARRENS M J, JURMAN G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation [J]. *Peerj Computer Science*,2021: 623.
- [24] ZHANG K, ZUO W M, ZHANG L. Learning a single convolutional super-resolution network for multiple degradations[C]. *2018 IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 3262-3271.
- [25] 陈哲,周旭,沈洁,等. 基于梯度先验的水下图像恢复[J]. *仪器仪表学报*, 2022, 43(8): 39-46.
CHEN ZH, ZHOU X, SHEN J, et al. Underwater image restoration based on gradient prior[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(8): 39-46.
- [26] AHN N, KANG B, SOHN K-A. FAST, accurate, and lightweight super-resolution with cascading residual network[C]. *Computer Vision-ECCV 2018*, 2018: 256-272.
- [27] LIU J, TANG J, WU G SH. Residual feature distillation network for lightweight image super-resolution [C]. *Computer Vision-ECCV 2020 Workshops*, 2020: 41-55.
- [28] KONG F Y, LI M X, LIU S W, et al. Residual local feature network for efficient super-resolution [C]. *2002 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 2022: 765-775.
- [29] TIMOFTE R, AGUSTSSON E, GOOL L V, et al. Ntire 2017 challenge on single image super-resolution: Methods and results [C]. *30th IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2017: 1110-1121.
- [30] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning [C]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2016 [2024-08-21]. DOI: 10.48550/arXiv.1602.07261.
- [31] ZEYDE R, ELAD M, PROTTER M. On single image scale-up using sparse-representations [C]. *Curves and Surfaces*, 2012: 711-730.
- [32] HUANG J B, SINGH A, AHUJA N. Single image super-resolution from transformed self-exemplars [C]. *2015 IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 5197-5206.

作者简介



张博伟,2021年于青岛理工大学取得学士学位,现为北京信息科技大学硕士研究生,主要研究方向为计算机视觉和生物医学图像处理。

E-mail: bovans@126.com

Zhang Bowei received his B.Sc. degree from Qingdao Technological University in 2021. He is currently a master student at Beijing Information Science and Technology University. His research interests include computer vision and biomedical image processing.



何彦霖(通信作者),2011年于兰州交通大学获得工学学士学位和文学学士(双学位),2018年于北京理工大学获得博士学位,现为北京信息科技大学教授、博士生导师,主要研究方向为软体手术机器人导航、光机电一体化与智能系统等。

E-mail: heyanlin@bistu.edu.cn

He Yanlin (Corresponding author) received her B.Sc. degree from Lanzhou Jiaotong University in 2011, and Ph.D. degree from Beijing Institute of Technology in 2018. She is currently a professor and a Ph.D. advisor at Beijing Information Science and Technology University. Her main research interests include soft surgical robot navigation, opto-mechatronics and intelligent systems, etc.