

DOI:10.19651/j.cnki.emt.2106998

# 基于残差混合域注意力网络的 PET 超分辨率重建方法<sup>\*</sup>

李浩然<sup>1</sup> 刘琨<sup>1,2,3</sup> 常世龙<sup>1</sup> 田兆星<sup>1</sup> 钱武侠<sup>1</sup> 薛林雁<sup>1,3</sup>(1. 河北大学质量技术监督学院 保定 071002; 2. 河北大学光学工程博士后科研流动站 保定 071002;  
3. 计量仪器与系统国家地方联合工程研究中心 保定 071002)

**摘要:** 正电子发射断层扫描(PET)设备的成像结果常受到扫描时间、示踪剂剂量等因素的制约,导致图像质量下降,影响医生的诊断结果。目前借助人工智能(AI)技术提升PET成像质量是研究的热点,针对现有方法训练参数多,浅层信息丢失,纹理细节损失等问题,提出了一种基于残差混合域注意力网络的PET超分辨率重建方法。该方法设计了一个轻量级的卷积网络,在其中加入残差学习结构并融入混合域注意力块,在增强神经网络的交互性的同时,提高了对高频信息区域的关注度,能够快速重建图像的高频细节。数据集包括网络中的开源数据和从医院获取的临床数据,由此建立PET图像超分辨率数据集,进行训练和测试。实验结果表明,该算法与对比网络在测试结果上有明显提升,当比例因子为4时,与CARN相比,PSNR和SSIM的平均值分别提高了0.09 dB和0.000 9,此外参数数量减少了50.26%,有效提升了模型的重建效率。

**关键词:** 卷积神经网络;PET成像;超分辨率重建**中图分类号:** TP391; TH7   **文献标识码:** A   **国家标准学科分类代码:** 520.60

## PET super-resolution reconstruction method based on residual mixed domain attention network

Li Haoran<sup>1</sup> Liu Kun<sup>1,2,3</sup> Chang Shilong<sup>1</sup> Tian Zhaoxing<sup>1</sup> Qian Wuxia<sup>1</sup> Xue Linyan<sup>1,3</sup>(1. College of Quality and Technical Supervision, Hebei University, Baoding 071002, China;  
2. Postdoctoral Research Station of Optical Engineering, Hebei University, Baoding 071002, China;  
3. National & Local Joint Engineering Research Center of Metrology Instrument and System, Baoding 071002, China)

**Abstract:** The imaging results of positron emission tomography (PET) equipment are often constrained by some factors such as tracer dose and scanning time, resulting in the image quality decline and affecting doctors' diagnostic results. At present, improving the quality of PET imaging with artificial intelligence (AI) technology is a hot research topic. Aiming at the problems of existing methods such as many training parameters, loss of shallow information, loss of texture details, etc., and proposes a method based on residual hybrid domain attention. The PET super-resolution reconstruction method of force network. This method designs a lightweight convolutional network, in which the residual learning structure is added and the mixed domain attention block is incorporated. While enhancing the interaction of the neural network, it also increases the attention to the high-frequency information area then quickly reconstruct the high-frequency details of the image. The data set includes open source data in the network and clinical data obtained from hospitals. As a result, a super-resolution data set of PET images is established for training and testing. The experimental results show that the test results of the algorithm and the comparison network are significantly improved. When the scale factor is 4, compared with CARN, the average values of PSNR and SSIM are increased by 0.09 dB and 0.000 9, respectively. In addition, the number of parameters is reduced by 50.26%, which effectively improves the reconstruction efficiency of the model.

**Keywords:** convolutional neural network; PET imaging; super-resolution reconstruction

## 0 引言

正电子发射断层扫描(positron emission tomography, PET)设备作为一种功能性成像工具已经被广泛应用于临

床,其通过收集人体新陈代谢过程的信息来检测肿瘤、心脏病及神经疾病<sup>[1-3]</sup>。现实中,PET设备会因扫描时间、

收稿日期:2021-06-21

\*基金项目:教育部“春晖计划”合作科研项目、河北省自然科学基金面上项目(H2019201378)、河北省高层次人才资助项目(B20190030010)、河北大学校长科研基金项目(XZJJ201917)、河北大学研究生创新项目(HBU2021ss079&amp;HBU2021ss078)资助

示踪剂剂量<sup>[4]</sup>等因素的影响导致 PET 图像的分辨率较低。尽管有这些限制,仍可以通过设计良好的超分辨率(super resolution, SR)算法应用到 PET 成像设备中来提高其分辨率。作为医学成像后的一种后处理方式,采用 SR 算法与升级医疗器械相比,具有成本低、效率高的优点。因此,图像超分辨率重建成为提升 PET 图像质量的重要手段。

通过图像超分辨率重建的手段,提升医学影像设备的成像质量是低成本和高效的。目前主流方法大致分为 3 类:基于插值的方法<sup>[5]</sup>、基于重构的方法<sup>[6-7]</sup> 和基于学习的方法<sup>[8]</sup>。基于插值的方法是处理图像超分辨率最传统的方法,最常见的插值是双三次插值(bicubic)<sup>[9]</sup>,计算速度很快,但是在边缘细节处理时易丢失高频细节信息,导致重建图像边缘模糊。基于重构的方法成像效果有所改善,但算法复杂冗余。由于上述两种方法均有不足之处,因此,基于学习的方法成为近年来的研究热点。深度学习凭借其强大的学习能力,在图像处理方面的应用越来越广泛<sup>[10-12]</sup>。2015 年,Dong 等<sup>[13]</sup>提出了一种三层的卷积超分辨率网络(super-resolution convolutional neural network, SRCNN),首次将深度学习应用到图像超分辨率方向,使图像的重建效果得到较大的提升。近年来,有学者相继提出加速卷积神经网络(fast super-resolution convolutional neural network, FSRCNN)<sup>[14]</sup>、亚像素卷积神经网络模型(efficient sub-pixel convolutional neural network, ESPCN)<sup>[15]</sup>,然而,对于医学图像来说,SRCNN、FSRCNN 和 ESPCN 的网络层太少,无法还原深层特征。更多的研究人员提出一些网络层数较深的模型,如宽泛激活超分辨率网络(wide activation for efficient and accurate image super-resolution, WDSR)<sup>[16]</sup> 和级联残差网络(cascading residual network, CARN)<sup>[17]</sup> 等,实现了更快速、更准确的图像超分辨率重建。然而,WDSR 和 CARN 网络的训练参数多,重建速度慢,无法满足医学图像重建快速准确的要求。

随着基于深度学习的超分辨率技术取得了良好的成果,一些学者根据医学图像的成像特点,开始研究利用此技术进行医学图像的超分辨率重建。2018 年,Wei 等<sup>[18]</sup>借鉴稠密卷积网络(dense convolutional network, DenseNet)<sup>[19]</sup>的思想对加深超分辨率网络(very deep network for super-resolution, VDSR)模型进行改进,提出了深度密集超分辨率网络(deep dense super-resolution, DDSR),应用于电子计算机断层扫描(computed tomography, CT)图像和核磁共振(magnetic resonance, MR)图像,均展示了良好性能。2019 年,Shi 等<sup>[20]</sup>结合全局残差学习和局部残差学习的思想,提出了渐进式宽残差网络(wide residual network with a fixed skip connection, FSCWRN),应用于 MR 图像,实现了更好的结果。深度学习在 PET 成像超分辨率应用中是

一个探索较少的研究领域,目前 Song 等<sup>[21]</sup>以高分辨率的 MR 信息和低分辨率的 PET 图像作为输入,提出了一种基于卷积神经网络的 PET 超分辨率成像技术,并得到较高分辨率的 PET 图像。但此技术需要与 PET 图像匹配的 MR 信息,数据获取难度较高。

综上,PET 设备末端图像的超分辨率重建方法存在如下局限性:1)深度卷积模型结构导致参数增加,极大增加了计算成本,可能导致 PET 设备的硬件资源的限制;2)重建后的 PET 成像结果存在高频细节损失。针对这两方面问题,本研究提出了一种基于混合域注意力卷积神经网络的轻量级 PET 超分辨率重建算法,首先,该算法通过替换卷积层结构,解决了训练参数多,难度大的问题;其次,设计了一种残差学习结构,并融入混合域注意力机制,不仅更容易训练深层的网络,还可以有效地保留浅层图像信息,增加各层之间的信息交互。

## 1 相关工作

超分辨率重建过程一般是基于卷积神经网络实现的,本研究为了进一步提升算法的计算效率,采用异构卷积替换普通卷积,同时在本文的重建算法中引入混合域注意力机制,有效提高重建性能和算法的学习能力。

### 1.1 异构卷积

异构卷积(heterogeneous kernel-based convolution, Hetconv)是 Singh 等<sup>[22]</sup>于 2019 年提出的,同等深度的异构卷积网络比普通卷积网络模型有更少的参数数量,实现计算效率的提升。异构卷积与普通卷积结构对比如图 1 所示。

图 1 中, $M$  表示总卷积层数; $P$  表示异构比例。在网络结构方面的区别,异构卷积主要是卷积核大小存在变化,层结构中总层数不变,卷积核的大小可以为  $3 \times 3$  和  $1 \times 1$  交替出现。 $3 \times 3$  大小的卷积核层数计算方式为  $M/P$ , $1 \times 1$  大小的卷积核层数计算方式为  $(P-1)M/P$ 。图 1 为异构比例  $P=2$  时, $3 \times 3$  大小的卷积核层数为  $M/2$ , $1 \times 1$  大小的卷积核层数为  $M/2$ 。

### 1.2 卷积块的注意力机制模型

卷积块的注意力机制模型(convolutional block attention module, CBAM)<sup>[23]</sup>是一种结合了空间(spatial)和通道(channel)的混合域注意力机制模型,其结构如图 2 所示。空间注意力机制可以使网络更加关注整个图像中更有意义的特征区域,加速网络收敛。通道注意力机制可以使网络在训练中更加关注含有丰富高频信息的通道,进一步提升网络性能。

图 2 中, $F$  为输入的特征图; $F''$  为运算之后输出的特征图; $M_c$  表示在通道维度上做注意力提取的操作; $M_s$  表示在空间维度上做注意力提取的操作; $\otimes$  表示张量的点乘操作。

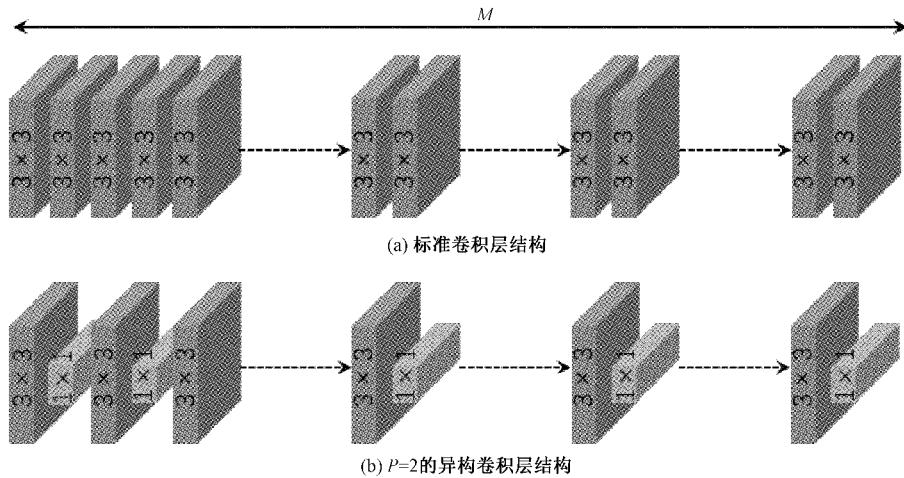


图1 异构卷积与普通卷积方式对比

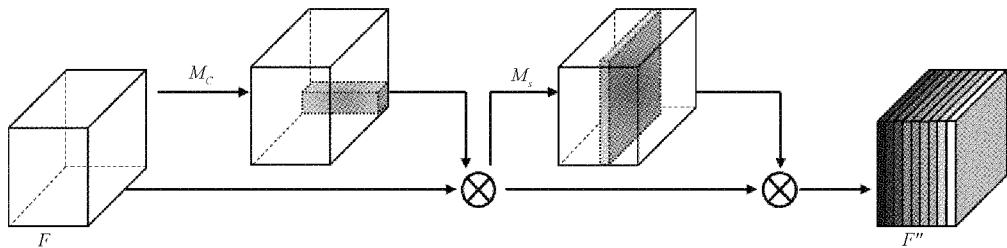


图2 CBAM混合域注意力模型

## 2 本文方法

### 2.1 网络模型

本网络主要由3个模块组成,分别为浅层特征提取

块(shallow information extraction block, SIEB)、深层信息细化块(deep information refinement block, DIRB)和重建块(reconstruction block, RB)。网络结构流程如图3所示。

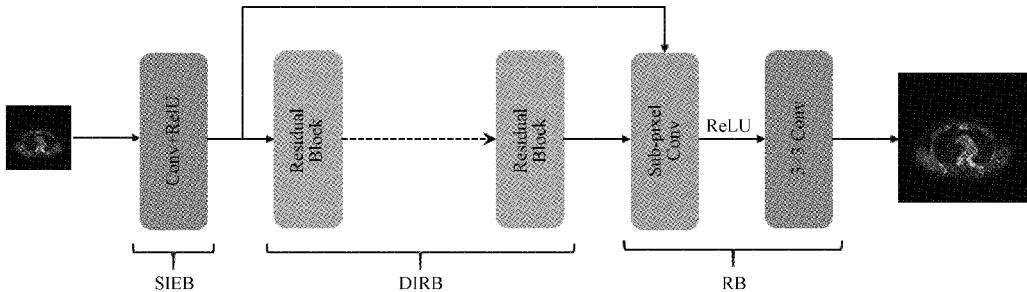


图3 本文提出的网络模型

#### 1) 浅层特征提取块

浅层特征提取块使用单层卷积网络来提取LR图像的浅层特征,如式(1)所示。

$$F_s = R(C_s(I_{LR})) \quad (1)$$

式中: $R(\cdot)$ 表示ReLU激活函数; $C_s(\cdot)$ 表示提取浅层特征的卷积; $I_{LR}$ 表示低分辨率图像; $F_s$ 表示SIEB的输出。

#### 2) 深层信息细化块

加深网络层数能够提取更深层的图像特征,但是随着网络的加深,容易丢失浅层信息,也会增加算法的计算时间和成本。为了解决上述问题,选择 $P=2, M=16$ 的异构

卷积搭建了一种轻量级的神经网络作为深层信息细化块的主网络。除此之外,为了更关注并还原PET图像的细节信息,在主网络中加入轻量级的混合域注意力模型CBAM,并加入ReLU激活函数<sup>[24]</sup>和跳过连接结构,构建一个残差学习块(Residual Block),如图4所示。深层信息细化块共包含8个残差学习块。该结构在不增加计算量的情况下,加强了网络各层之间的信息交互,使网络可以重建出更丰富的细节信息。

第1层残差学习块计算方法如式(2)所示。

$$F_1 = R(CM(C_{1 \times 1}(R(C_{3 \times 3}(F_s)))) + F_s) \quad (2)$$

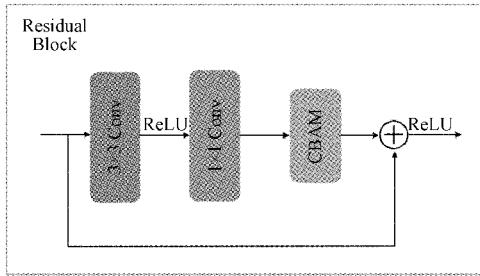


图 4 残差学习块

第 2 到 8 层残差学习块计算方法如式(3)所示。

$$F_i = R(CM(C_{1 \times 1}(R(C_{3 \times 3}(F_{i-1})))) + F_{i-1}), i \in [2, 8] \quad (3)$$

式中:  $F_i$  表示经过第  $i$  个残差学习块后的输出特征;  $CM(\cdot)$  表示使用混合域注意力模型 CBAM 提取深层特征;  $C_{1 \times 1}(\cdot)$  表示使用大小为  $1 \times 1$  的卷积核作卷积;  $C_{3 \times 3}(\cdot)$  表示使用大小为  $3 \times 3$  的卷积核作卷积;  $R(\cdot)$  表示 ReLU 激活函数。

### 3) 重建块

重建块采用亚像素卷积对浅层信息提取块的输出和深层信息细化块的输出分别进行上采样, 重建块如式(4)所示。

$$I_{SR} = C_{3 \times 3}(R(S(F_s) + S(F_8))) \quad (4)$$

式中:  $I_{SR}$  表示生成的超分辨率图像;  $C_{3 \times 3}(\cdot)$  表示使用大小为  $3 \times 3$  的卷积核作卷积;  $R(\cdot)$  表示 ReLU 激活函数;  $S(\cdot)$  表示亚像素卷积。

## 2.2 实验方法

### 1) 训练细节

本文代码在操作系统为 Ubuntu 18.04 的工作站上运行, 该工作站的核心配置为 Inter Core i7-7800 \* 1, NVIDIA RTX 2080Ti \* 2 以及 128 G 的运行内存。深度学习框架为 Pytorch0.41, 编程语言为 Python, 版本为 Python2.7。在训练过程中, 将初始参数设置如下。批处理大小(Batchsize)为 256, 本文网络使用 ADAM<sup>[25]</sup> 优化器, 动量参数设置为  $\beta_1 = 0.5, \beta_2 = 0.999, \epsilon = 10^{-8}$ , 培训过程设置为  $5 \times 10^3$  步, 初始学习率设置为  $10^{-4}$ , 每  $10^3$  步学习率减 1/2。

### 2) 数据集

本文采用全身 PET 数据建立了一组应用于 PET 图像超分辨率的数据集。研究所用数据使用 FDG-PET 扫描仪进行采集。检查前, 病人须禁食 4 h 后, 静脉注射 18F-FDG, 血糖水平低于 200 mg/dL。FDG 注射剂量在 0.14~0.21 mCi/kg 之间。在 FDG 注射后 50~70 min, 患者仰卧在 PET 扫描仪中, 开始进行全身放射性扫描。

训练集: 高分辨率 PET 数据来源于 TCIA(the cancer imaging archive)<sup>[26]</sup> 数据库中随机选择的两组 PET 数据<sup>[27 28]</sup>。在这两组数据中随机选择了 24 位患者的全身

PET 图像, 共 6 437 张, 作为训练集使用的高分辨率图像。然后使用 MATLAB 对上述采集数据作下采样处理, 分别得到原始图像的 1/2 和 1/4 大小, 作为训练集使用的低分辨率图像。

测试集: 测试集的高分辨率图像由 10 名患者的原始 PET 图像组成, 共 2 257 张。其中分为两部分, 第 1 部分随机选择上述 TCIA 数据库中除训练集之外的 5 名剩余患者的数据, 共 1 127 张图像。第 2 部分由河北大学附属医院提供, 同样随机选择 5 名患者的数据, 共 1 130 张图像。同样地, 使用 MATLAB 对上述数据作下采样处理, 分别得到原始图像的 1/2 和 1/4 大小, 作为相应的低分辨率图像。

## 2.3 损失函数

本文采用均方误差(MSE)<sup>[29]</sup> 来衡量所生成的超分辨率图像和原始的高分辨率图像之间的差异。MSE 损失函数可以表示为:

$$\mathcal{L}_{MSE}(HR, SR) = \frac{1}{2N} \sum_{i=1}^N \| HR^{(i)} - SR^{(i)} \|^2 \quad (5)$$

式中:  $N$  为训练图像的总数量;  $HR$  为原始高分辨率图像;  $SR$  为超分辨率生成的高分辨率图像。

## 2.4 评价指标

实验结果采用峰值信噪比(peak signal-to-noise ratio, PSNR)<sup>[30]</sup>、结构相似性系数(structural similarity index, SSIM)<sup>[31]</sup> 来进行评估。其中 PSNR、SSIM 可以表示为:

$$PSNR = 20 \times \lg\left(\frac{MAX}{MSE}\right) \quad (6)$$

$$SSIM = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (7)$$

其中,  $MAX$  代表图像中数值取值的最大值;  $MSE$  代表生成的图片和参考图片二者间的绝对均方误差, 如式(8)所示。

$$MSE = \frac{1}{N} \sum_{i=1}^N (y^{(i)} - \mu_y^{(i)})^2 \quad (8)$$

其中,  $\mu_x, \mu_y$  分别代表  $x$  和  $y$  的平均值;  $\sigma_{xy}$  代表  $x$  和  $y$  的协方差;  $\sigma_x, \sigma_y$  分别代表  $x$  和  $y$  的方差;  $c_1, c_2$  是 2 个来防止分母为 0 的常数;  $N$  代表样本总数。

对于上述两个评价指标, PSNR 值越大时, 表示其图片质量越高。SSIM 的取值范围是 [0, 1], 当其值越大时, 表示两张图像的结构相似度越高。

## 3 实验结果分析及讨论

### 3.1 对比试验

为了验证本方法在 PET 图像数据集的重建效果, 将该方法与其他图像超分辨率重建方法进行比较, 包括基于插值的传统超分辨率方法(Bicubic)和基于深度学习的超分辨率方法(SRCNN, ESPCN, FSRCNN, EDSR 和 CARN)。然后使用这些方法来重建比例因子是 2(X2 SR)和 4(X4 SR)的 PET 图像, 比较实验在相同的环境下进行, 实验结果如下。

图5所示为本文方法在PET数据集上训练后的损失函数曲线。随着迭代次数的增加,所提出方法的总体损失显示出了下降的趋势,曲线的后半部分逐渐平缓,且收敛后的Loss值较小,说明网络训练已经达到了最优状态。而且实验数据显示网络的收敛速度快,网络性能良好。

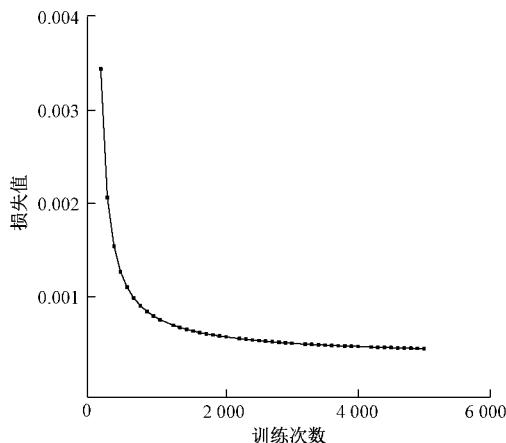


图5 本文所提出的方法在PET数据集上的损失曲线

各超分辨率方法的评价指标对比如表1所示。实验结果表明,对于X2 SR的任务,本文所提出的方法优于其他大多数方法,本文方法获得的PSNR和SSIM值分别为43.54/0.9873,与CARN的43.56/0.9877差异性不大,但是值得注意的是,本文的方法具有较少的参数(655 K VS 1 644 K),如表1所示,本文方法的参数量比CARN的参数量减少了50.26%,因此本文方法与CARN相比仍然非常具有竞争力。此外,对于X4 SR的任务,本文提出的方法在两个评估指标中均获得最佳性能,与CARN相比,PSNR和SSIM分别提升了0.09 dB和0.0009。与其他网络对比,获得的PSNR指标均有0.1~6 dB左右的提升,SSIM指标有0.001~0.1左右的提升。本文算法使用更少的参数量获得了好的重建结果,充分证明了本文所提出方法的优异性。

表1 各超分辨率方法的评价指标对比

方法	Scale×2		参数量 (K=10 <sup>3</sup> )
	PSNR/SSIM	Scale×4	
Bicubic	39.91/0.9802	33.13/0.9191	
ESPCN	32.50/0.8808	28.54/0.8051	25 K
SRCNN	42.78/0.9847	34.67/0.9354	57 K
FSRCNN	38.46/0.9676	32.49/0.9020	13 K
WDSR	43.53/0.9873	35.01/0.9381	1 187 K
CARN	<b>43.56/0.9877</b>	35.06/0.9398	962 K
Our method	43.54/0.9873	<b>35.15/0.9407</b>	477 K

就网络的运算复杂性而言,对比了几种深度学习方法的参数量。如表1所示,ESPCN、SRCNN和FSRCNN 3种

方法的网络层数少,参数量最少,但得到的PSNR值和SSIM值较低。WDSR和CARN两种网络的网络层数较多,更有利于图像恢复。本文方法比WDSR和CARN两种先进的超分辨率技术使用了更少的参数,这表明本文提出的方法在训练阶段具有更低的计算成本和更少的内存消耗。综上所述,所提出的方法在定量分析方面优于CARN等先进的超分辨率算法。

图6和7为本文所提出的网络在X4 SR任务上和其它对比网络的PSNR值和SSIM值,可以看出,在两个评价指标中,所提出的网络在测试过程中一直处于最优趋势,而且图中后一段中的曲线趋于平坦,所有的网络测试结果都达到了最佳效果,同时可以看出所提出网络的PSNR值和SSIM值在所有对比网络中最高。

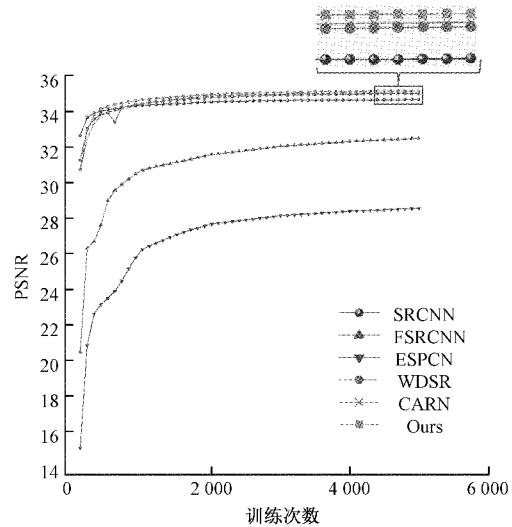


图6 比例因子为4时,各方法的平均PSNR值曲线

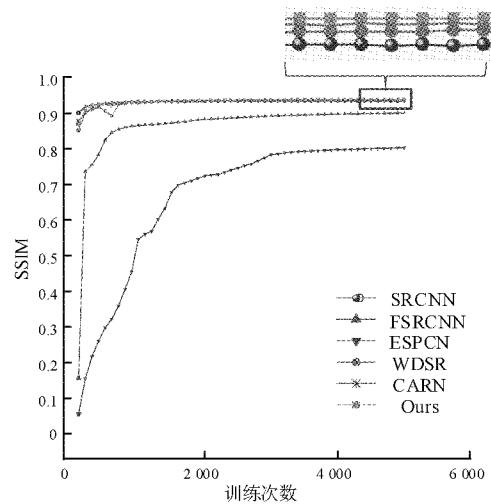


图7 比例因子为4时,各方法的平均SSIM值曲线

为了进一步验证每个超分辨率方法的视觉重建效果,分别选择X2 SR和X4 SR任务中具有丰富纹理的PET图像,所有超分辨率方法的结果对比如图8、9所示。

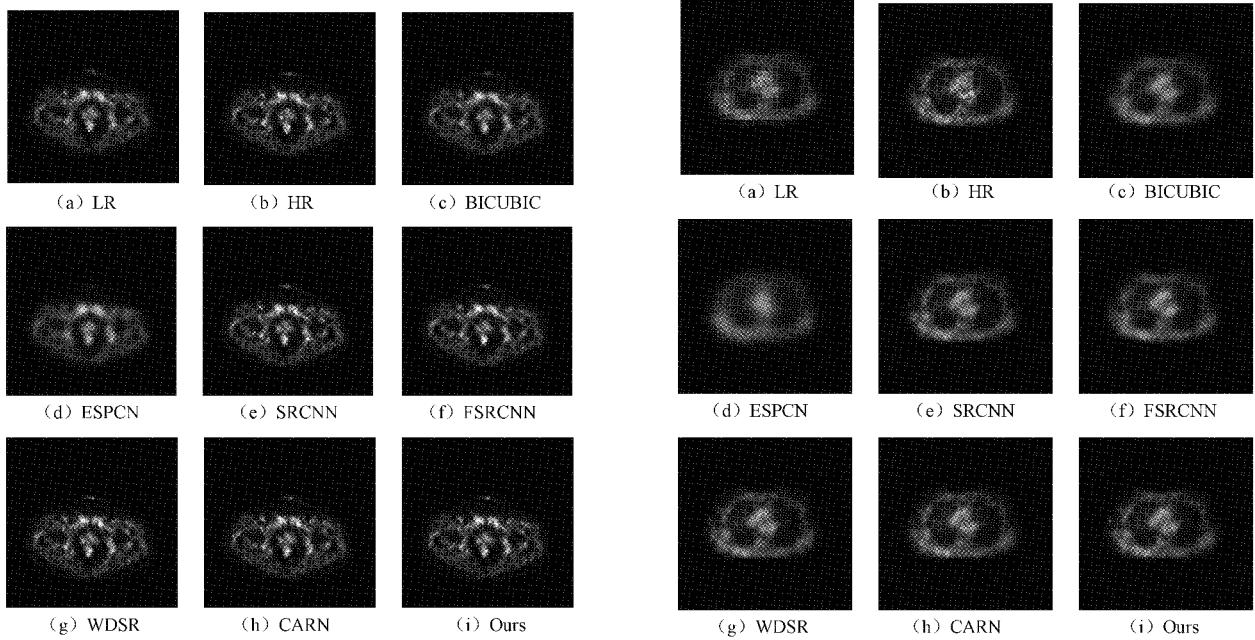


图 8 比例因子为 2 时,不同算法对 PET 图像重建效果对比

从图 8、9 中可以看出, BICUBIC、ESPCN、SRCNN 和 FSRCNN 方法的重建结果都比较模糊,验证了本文方法的重建结果要优于 BICUBIC、ESPCN、SRCNN 和 FSRCNN。原因在于,本网络相较于上述算法的层数较深,并且引入残差学习结构,有利于图像特征的提取。

在 PSNR 和 SSIM 两种评价指标上,本文所提出的方法比 CARN 重建出的图像表现优异,但在视觉效果上,CARN 和我们所提出的方法的重建结果差异性不大,因此

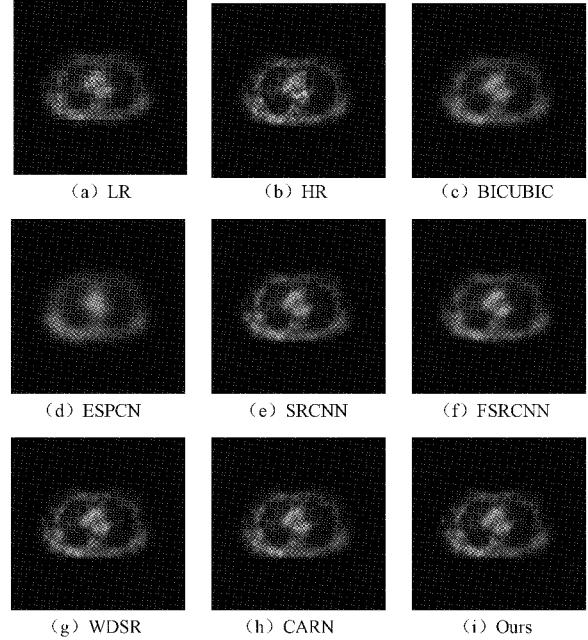


图 9 比例因子为 4 时,不同算法对 PET 图像重建效果对比

以 CARN 为例,当比例因子为 4 时,分别从 HR 图像中减去用 CARN 生成的 SR 图像和用本文提出的方法生成的 SR 图像,获得两个图像的绝对差值,并以热力图显示,如图 10 所示。差值图上的内容越少则表示与 HR 图像的差异越小。右侧图像中对应颜色的方框标记的位置比左侧图像中标记的位置像素点聚集少,这意味着通过本文算法生成的 SR 图像更接近于 HR 图像,进一步说明本文所提出的方法能够更好地重建细节特征。

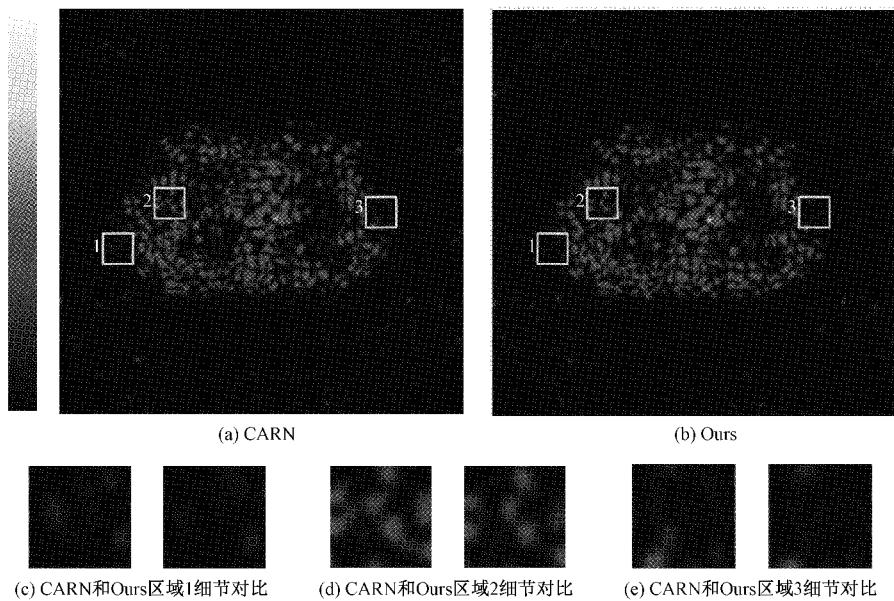


图 10 CARN 和本文提出的方法生成的 SR 图像之间和 HR 图像的差值图

### 3.2 消融实验

本文设计的残差学习块的主要部分在于跳过连接结构。为了验证所设计的残差学习块中跳过连接的优越性能,本文在不改变其他条件基础上,不加入跳过连接结构,与所提出的网络进行对比,以此来探究残差学习块中跳过连接结构的作用。

消融实验的定量比较结果如表 2 所示。与不加入跳过连接结构的网络相比,本文所提出的改进在两种评价指标 PSNR 和 SSIM 上均取得了更好的结果。PSNR 和 SSIM 分别提升了 0.42 dB 和 0.0007,有效证明了本文所设计的残差学习块的跳过连接能够使网络在训练过程中获取更丰富的细节信息,加强网络各层之间的信息交互,从而提升网络的性能。

表 2 所提出网络上的消融实验的定量比较

方法	Scale × 2	Scale × 2
	PSNR/dB	SSIM
不加入跳过连接	43.12	0.9866
加入跳过连接	43.54	0.9873

## 4 结 论

本研究通过级联 SIEB、DIRB 和 RB 模块为 PET 图像提出了一种基于残差混合域注意力的轻量级超分辨率卷积神经网络。针对以往方法在 PET 图像超分辨率领域中特征提取不充分,训练费时的问题,利用轻量级异构网络和残差学习,减少了网络训练时间,增强了特征提取能力。同时,添加了注意机制以进一步保留详细功能。本文利用建立的 PET 图像数据集进行了对比实验,实验结果表明,该方法比 ESPCN、SRCNN、FSRCNN 和 WDSR 具有更高的精度。此外,在保证重建精度的基础上,该方法的重建效率高于 CARN,这使我们的方法在实际应用中可以取得更好的效果。

## 参考文献

- [1] SOTOUDEH H, SHARMA A, FOWLER K J, et al. Clinical application of PET/MRI in oncology [J]. Journal of Magnetic Resonance Imaging, 2016, 44(2): 265-276.
- [2] CATANA C, DRZEZGA A, HEISS W D, et al. PET/MRI for neurologic applications [J]. Journal of Nuclear Medicine, 2012, 53(12): 1916-1925.
- [3] 朱旭艳,余洪山,赵科,等.基于 MR 和 PET 成像的轻度阿尔茨海默病分类方法 [J].电子测量与仪器学报,2013,27(9):850-858.
- [4] 杨昆,杜瑀,钱武侠,等.基于多尺度上下文信息融合的条件生成对抗神经网络用于低剂量 PET 图像去噪 [J].电子测量技术,2021,44(7):74-81.
- [5] PARKER J A, KENYON R V, TROXEL D E. Comparison of interpolating methods for image resampling [J]. IEEE Transactions on Medical Imaging, 1983, 2(1): 31-39.
- [6] BIAN J, LI Y, FENG J. Single image super-resolution using sparse prior[J]. MIPPR 2011: Pattern Recognition and Computer Vision, 2011, 8004(6): 80040L.
- [7] 王小玉,陈德运,冉起.基于内容的双字典学习及稀疏表示的图像重构 [J].仪器仪表学报,2013,34(8): 1690-1695.
- [8] BASHIR S M A, WANG Y, KHAN M. A comprehensive review of deep learning-based single image super-resolution[J]. Deep Learning for Image Super-Resolution, 2021: e621.
- [9] KEYS R G. Cubic convolution interpolation for digital image processing [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1981, 29(6): 1153-1160.
- [10] 王延年,李义婷,任劫.基于生成对抗网络的单帧图像超分辨率算法 [J].国外电子测量技术,2020,39(1): 26-32.
- [11] 刘正男,王凤随,付林军.改进的联合型图像超分辨率重建算法 [J].电子测量与仪器学报,2020,34(1): 111-120.
- [12] 王民,刘可心,刘利,等.基于优化卷积神经网络的图像超分辨率重建 [J].激光与光电子学进展,2017, 54(11):129-138.
- [13] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [14] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [J]. Lecture Notes in Computer Science ( Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2016, 9906 LNCS: 391-407.
- [15] SHI W, CABALLERO J, HUSZAR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 1874-1883.
- [16] YU J, FAN Y, YANG J, et al. Wide activation for efficient and accurate image super-resolution [J]. ArXiv, 2018, ArXiv.1808.08718.
- [17] AHN N, KANG B, SOHN K A. Fast, accurate, and lightweight super-resolution with cascading residual

- network[C]. Proceedings of the European Conference on Computer Vision(ECCV),2018: 252-268.
- [18] WEI S, WU W, JEON G, et al. Improving resolution of medical images with deep dense convolutional neural network[J]. Concurrency Computation, 2020, 32(1): 1-11.
- [19] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [ C ]. Proceedings-30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [20] SHI J, LI Z, YING S, et al. MR image super-resolution via wide residual networks with fixed skip connection[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(3): 1129-1140.
- [21] SONG T A, CHOWDHURY S R, YANG F, et al. Super-resolution PET imaging using convolutional neural networks [ J ]. IEEE Transactions on Computational Imaging, 2020, 6:518-528.
- [22] SINGH P, VERMA V K, RAI P, et al. Hetconv: Heterogeneous kernel-based convolutions for deep cnns[C]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2019: 4835-4844.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [ J ]. Lecture Notes in Computer Science(including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2018, 11211 LNCS: 3-19.
- [24] BROWN M J, HUTCHINSON L A, RAINBOW M J, et al. A comparison of self-selected walking speeds and walking speed variability when data are collected during repeated discrete trials and during continuous walking[J]. Journal of Applied Biomechanics, 2017, 33(5): 384-387.
- [25] KINGMA D P, BA J L. Adam: A method for stochastic optimization[J]. 3rd International Conference on Learning Representations, ICLR 2015-Conference Track Proceedings, 2015: 1-15.
- [26] CLARK K, VENDT B, SMITH K, et al. The cancer imaging archive(TCIA): Maintaining and operating a public information repository[J]. Journal of Digital Imaging, 2013, 26(6): 1045-1057.
- [27] KINAHAN P, MUZI M, BIALECKI B, et al. Data from the ACRIN 6668 Trial NSCLC-FDG-PET [Data set][EB/OL]. The Cancer Imaging Archive, 2019, <https://doi.org/10.7937/tcia.2019.30ilqfcl>.
- [28] LI P, WANG S, LI T, et al. A large-scale CT and PET/CT dataset for lung cancer diagnosis[Data set][EB/OL]. The Cancer Imaging Archive, 2020, <https://doi.org/10.7937/TCIA.2020.NNC2-0461>.
- [29] DOUILLARD C, JÉZÉQUEL M, BERROU C, et al. Iterative correction of intersymbol interference: Turbo-equalization [ J ]. European Transactions on Telecommunications, 1995, 6(5): 507-511.
- [30] HORÉ A, ZIOU D. Image quality metrics: PSNR vs. SSIM [ J ]. Proceedings-International Conference on Pattern Recognition, 2010: 2366-2369.
- [31] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.

### 作者简介

李浩然,硕士研究生,主要研究方向为仪器科学与技术、医学图像处理技术。  
E-mail:[792126641@qq.com](mailto:792126641@qq.com)