

# 残差注意力聚合对偶回归网络超分辨率 计算机断层扫描重建

范金河<sup>1,2</sup>, 吴静<sup>1,2\*</sup>, 何茂林<sup>1,2</sup>

<sup>1</sup>西南科技大学信息工程学院, 四川 绵阳 621010;

<sup>2</sup>西南科技大学特殊环境机器人技术四川省重点实验室, 四川 绵阳 621010

**摘要** 为了改善计算机断层扫描(CT)影像重建质量不高的问题,提出一种基于残差注意力聚合对偶回归网络(RAADRNet)的超分辨率CT重建方法。多特征下采样提取模块(MFDEB)通过平均池化、最大池化和卷积运算完成多特征下采样提取,在多特征融合后嵌入通道学习注意力(CLA)和空间学习注意力(SLA),同时并入前级融合特征提取图像的浅层特征。CLA、SLA分别引入通道权重特征学习以及激活函数 $1+\tanh()$ 完成特征提取。残差注意力聚合模块(RAAB)通过CLA嵌入残差网络构成的残差通道学习注意力模块(RCLAB)与SLA构成的空间特征融合模块(SFFB)联合提取图像的深层特征。原始网络在浅层特征与通过亚像素卷积放大的深层特征进行特征融合后完成重建。对偶网络进一步约束重建映射函数的解空间。实验表明,所提算法在重建图像的峰值信噪比(PSNR)和结构相似度(SSIM)上都得到了较好的提升。

**关键词** 图像处理; 超分辨率计算机断层扫描重建; 多特征下采样; 通道学习注意力; 空间学习注意力; 残差注意力聚合

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP212865

## Super-Resolution Computed Tomography Reconstruction of Residual Attention Aggregation Dual Regression Network

Fan Jinhe<sup>1,2</sup>, Wu Jing<sup>1,2\*</sup>, He Maolin<sup>1,2</sup>

<sup>1</sup>College of Information Engineering, Southwest University of Science and Technology,

Mianyang 621010, Sichuan, China;

<sup>2</sup>Sichuan Key Laboratory of Special Environmental Robotics, Southwest University of Science and Technology, Mianyang 621010, Sichuan, China

**Abstract** A super-resolution computed tomography (CT) reconstruction method based on a residual attention aggregation dual regression network (RAADRNet) is proposed to improve the quality of CT image reconstruction. The multi-feature down-sampling extraction block (MFDEB) is used to complete multi-feature down-sampling extraction by employing average pooling, maximum pooling, and convolution operations, and channel learning attention (CLA) and spatial learning attention (SLA) are embedded after multi-feature fusion. Moreover, the shallow features of an image are extracted by combining the previous fusion features. CLA and SLA respectively introduce channel weight feature learning and activation function  $1+\tanh()$  to complete feature extraction. The residual attention aggregation block (RAAB) requires the use of the residual channel learning attention block (RCLAB) composed of a CLA-embedded residual network and the spatial feature fusion block (SFFB) composed of SLA for jointly extracting the deep features of the image. The primal network completes reconstruction after the feature fusion of shallow features and deep features amplified by sub-pixel convolution. The dual network further constrains the solution space of the reconstructed mapping function. Experiments show that the proposed algorithm improves the peak signal-to-noise ratio (PSNR) and structural similarity (SSIM) of the reconstructed image.

**Key words** image processing; super-resolution computed tomography reconstruction; multi-feature down-sampling; channel learning attention; spatial learning attention; residual attention aggregation

收稿日期: 2021-11-03; 修回日期: 2021-11-29; 录用日期: 2021-12-13; 网络首发日期: 2021-12-23

基金项目: 特殊环境机器人技术四川省重点实验室基金(13ZXTK07)

通信作者: \*1320958927@qq.com

# 1 引言

计算机断层扫描(CT)图像由于不同程度的移动伪影、线束硬化伪影及机器故障伪影等和部分容积效应均会导致重建图像的质量下降,可能掩盖病灶致使误诊、漏诊。超分辨率重建(SR)技术<sup>[1-2]</sup>的核心在于从观测的低分辨率(LR)图像重建出指定缩放因子的高分辨率(HR)图像,广泛应用于医学影像及人脸重建等领域。目前常用的重建算法包含:基于插值的方法<sup>[3]</sup>、基于重建的方法<sup>[4]</sup>、基于稀疏编码的方法<sup>[5]</sup>和基于深度学习<sup>[6-7]</sup>的方法。基于深度学习的超分辨率重建方法能够更好地恢复图像的细节纹理<sup>[8-9]</sup>,对于医学影像的重建具有重要意义<sup>[10-11]</sup>。

近来,残差网络被广泛应用于超分辨率领域改善图像的重建性能。Zhang等<sup>[12]</sup>利用基本残差单元进行堆叠,提出了残差密集网络(RDN)改善网络的重建性能。Zhang等<sup>[13]</sup>提出的残差通道注意力网络(RCAN),将通道注意力机制(CA)引入基本残差单元,形成残差通道注意力模块(RCAB),增强了网络的通道特征提取能力。Guo等<sup>[14]</sup>将RCAB引入对偶回归网络(DRN),用于分层次强化网络模型对图像深层特征的提取能力,更有利于CT图像细节纹理的恢复。

基于残差网络和注意力机制的超分辨率重建算法虽然取得了较好的重建效果。但仍存在以下问题:1)文献[13]的CA、文献[15]的高效通道注意力(ECA)及文献[16]的协调注意力(CoA)和文献[17]的空间注

意力(SAM)均无法实现原有通道权重特征信息的表达,以及利用激活函数 Sigmoid( $\cdot$ )在训练过程中易出现梯度消失的问题;2)由于单尺度下采样提取模块(SDEB)限于卷积核感受野的大小会丢失较多的信息特征,导致重建图像纹理突变、特征模糊等不良影响;3)由于级联RCAB(CRCAB)特征提取方式仅强化关注图像的通道特征,输入特征通过繁多的RCAB模块,丢失了较多空间特征信息,导致出现重建的CT图像感兴趣区域特征不显著等问题。

针对以上问题,本文提出了一种基于残差注意力聚合对偶回归网络(RAADRNet)的超分辨率CT重建算法。该方法无论在客观评价指标峰值信噪比(PSNR)与结构相似度(SSIM)上,还是在重建图像的主观评价上,均得到了较好的改善与提升。

## 2 RAADRNet

RAADRNet由原始网络(PN)和对偶网络(DN)组成,如图1所示。PN由通道变换Head、多特征下采样提取模块(MFDEB)、残差注意力聚合模块(RAAB)和输出重建部分组成。DN由DN1和DN2组成。RAADRNet包含 $\log_2 s$ 个上下采样模块, $s$ 为重建尺寸。输入数据包含HR图像与多尺度 $LR_{x_i}$ 图像, $LR_{x_i}$ 作为原始网络和对偶网络的约束样本, $i$ 为约束样本放大倍数, $i \in 2^n, n = 0, \dots, \log_2 s$ 。预处理阶段利用双三次插值法Bicubic对 $LR_{x_i}$ 进行上采样获取输入(input)特征图。

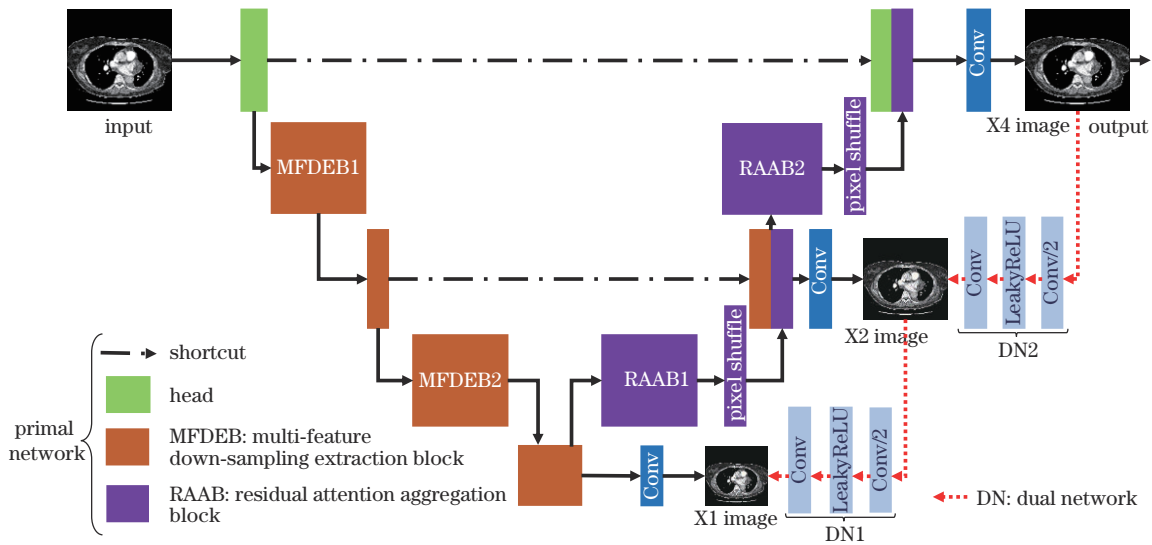


图1 4倍RAADRNet重建网络结构

Fig. 1 Reconstructed network structure diagram of RAADRNet for SRx4

### 2.1 PN

如图1所示,浅层特征 $F_{MFDEB1}$ 利用多特征下采样模块MFDEB获取,深层特征 $F_{RAAB1}$ 利用RAAB获取。 $F_{SRX1}$ 由 $F_{MFDEB2}$ 通过卷积核 $W_{SRX1}$ : Conv(3, 3)进行重建,可表示为

$$F_{SRX1} = F_{MFDEB2} * W_{SRX1} \quad (1)$$

$F_{SRX2}$ 由 $F_{MFDEB2}$ 与 $F_{RAAB1}$ 进行亚像素卷积 Pixelshuffle(2)放大后的特征进行融合,再通过卷积核 $W_{SRX2}$ : Conv(3, 3)进行重建,可表示为

$$F_{SRX2} = f_{use} \{ \text{Pixelshuffle}(F_{RAAB1}); F_{MFDEB2} \} * W_{SRX2} \quad (2)$$

$F_{SRX4}$  由通道变换特征  $\text{Head}(X)$  与  $F_{RAAB2}$  进行亚像素卷积 Pixelshuffle(2) 放大后的特征进行融合, 再通过卷积核  $W_{SRX3}$ : Conv(3, 3) 进行重建, 可表示为

$$F_{SRX4} = f_{\text{use}}\{\text{Pixelshuffle}(F_{RAAB2}); \text{Head}(X)\} * W_{SRX3} \quad (3)$$

式(1)~(3)中:  $f_{\text{use}}\{\cdot\}$  为按通道方式融合;  $*$  为卷积运算。PN 可获取  $F_{SRX1}$  (X1 image),  $F_{SRX2}$  (X2 image) 和  $F_{SRX4}$  (X4 image) 3 种尺寸的 CT 图像, 其中  $F_{SRX4}$  作为目标重建图像输出(output)。  $F_{SRX1}$ 、 $F_{SRX2}$  及  $F_{SRX4}$  分别用于 PN 中不同尺度重建时, LR 图像到 HR 图像映射函数解空间的约束。

## 2.2 DN

如图 1 所示, DN 可获取多尺寸低分辨率  $F_{LRXi}$ , 用于 HR 到 LR 映射函数的估计, 进一步约束重建过程中映射函数的解空间。  $F_{LRX2}$  (X2 image) 由  $F_{SRX4}$  利用对偶网络 DN2 生成, 可表示为

$$F_{LRX2} = f(F_{SRX4} * W_1) * W_1, \quad (4)$$

$F_{LRX1}$  (X1 image) 由  $F_{SRX2}$  利用对偶网络 DN1 生成, 可表示为

$$F_{LRX1} = f(F_{SRX2} * W_1) * W_2, \quad (5)$$

式中:  $*$  为卷积运算;  $W_1$  和  $W_2$  均为  $3 \times 3$  的卷积核 Conv(3, 3),  $W_1$  用于下采样,  $W_2$  将下采样特征图恢复至红绿蓝(RGB)通道;  $f$  为激活函数 LeakyReLU, 负斜率取 0.2。

## 2.3 损失函数

PN 通过  $F_{SRX4}$  与 HR、 $F_{SRX2}$  与  $LR_{X2}$ 、 $F_{SRX1}$  与  $LR_{X1}$




图 2 CLA 示意图

Fig. 2 Diagram of channel learning attention (CLA)

给定输入  $X \in \mathbb{R}^{C \times H \times W}$ 。首先, 利用全局平均池化 (GAP) 获取通道信息的统计量  $S_c \in \mathbb{R}^C$ , 将维度为  $C \times H \times W$  的输入特征  $X$  处理成一个维度为  $C \times 1 \times 1$  通道特征向量  $S_c$ , 可表示为

$$S_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j). \quad (7)$$

其次, 利用通道权重信息学习与偏置信息生成通道特征学习向量  $S_L$ , 可表示为

$$S_L = F_c(S_c) = w \otimes S_c + b, \quad (8)$$

式中:  $F_c(\cdot)$  为通道权重学习函数;  $\otimes$  表示按通道相乘; 通道权重  $w \in \mathbb{R}^{C \times 1 \times 1}$ , 通道偏置  $b \in \mathbb{R}^{C \times 1 \times 1}$ ,  $w$  与  $b$  均为学习参数。最后, 利用一维卷积  $C1D_k(1, 1, K)$  实现跨通道的信息交互,  $K$  取 3。通过激活函数  $G_c(\cdot) =$

之间的  $L1$  损失完成 LR 到 HR 多尺度映射函数的建模。DN 利用  $F_{LRX1}$  与  $LR_{X1}$ 、 $F_{LRX2}$  与  $LR_{X2}$  完成 HR 到 LR 多尺度映射函数的建模。其损失函数可表示为

$$L = \left\{ L_P[P(x_i), y_i] + \lambda L_D[D[P(x_i)], x_i] \right\}, \quad (6)$$

式中:  $L_P$ 、 $L_D$  分别表示原始损失与对偶过损失;  $\lambda$  为对偶损失权重。PN 由输入的 LR 像素块  $x_i$  生成超分辨率像素块  $P(x_i)$ , DN 由  $P(x_i)$  获取 LR 像素块  $D[P(x_i)]$ 。  $L_P$  中的多尺度  $P(x_i)$  包含  $F_{SRX4}$ 、 $F_{SRX4}$  和  $F_{SRX1}$ , 约束样本  $y_i$  由 HR、 $LR_{X2}$  和  $LR_{X1}$  组成。  $L_D$  中的多尺度  $D[P(x_i)]$  包含  $F_{SRX1}$  与  $F_{SRX2}$ , 约束样本  $x_i$  由  $LR_{X2}$  和  $LR_{X1}$  组成。  $i$  表示相互对应的重建图像与约束样本在第  $i$  通道的像素块。

## 3 RAADRNet 模块设计

RAADRNet 模块设计以 MFDEB 与 RAAB 为主, 分别嵌入通道学习注意力 (CLA) 和空间学习注意力 (SLA) 增强网络模型的特征提取能力, 使 CT 图像的重建质量得到了较好的提升。

### 3.1 CLA

文献[15]的 ECA 无法对原有通道的权重特征进行描述, 以及 Sigmoid( $\cdot$ ) 激活函数易出现的梯度消失问题, 导致出现重建图像的连续性差等问题。本文在 ECA 基础上加入通道权重特征学习函数  $F_c(\cdot)$ , 利用激活函数  $G_c(\cdot)$  进行非线性映射, 形成 CLA, 如图 2 所示。

$1 + \tanh(\cdot)$  完成通道门限设定, 输出特征  $S_G$  可表示为

$$S_G = G_c[C1D_k(S_L)] = 1 + \tanh[C1D_k(S_L)]. \quad (9)$$

$X$  的估计  $\hat{X}$  可表示为

$$\hat{X} = X \otimes S_G = X \otimes \{1 + \tanh[C1D_k(S_L)]\}. \quad (10)$$

### 3.2 SLA

文献[17]的 SAM 采用  $7 \times 7$  的卷积核融合平均池化特征和最大池化特征, 在融合特征后用 Sigmoid( $\cdot$ ) 激活函数进行非线性映射。为了降低算法复杂度, 本文在 SAM 上去掉了最大池化与  $7 \times 7$  融合卷积, 在平均池化特征提取后直接加入  $F_c(\cdot)$ , 利用  $G_c(\cdot)$  替代 Sigmoid( $\cdot$ ), 形成 SLA, 如图 3 所示。

输入  $X \in \mathbb{R}^{C \times H \times W}$ , 按通道平均池化将  $X$  处理为空




图3 SLA示意图

Fig. 3 Diagram of spatial learning attention (SLA)

间特征矩阵  $S \in \mathbb{R}^{1 \times H \times W}$  可表示为

$$S = \text{Avgpool}(X), \quad (11)$$

式中,  $\text{Avgpool}(\cdot)$  为按通道平均池化。特征矩阵  $S$  通过  $F_c(\cdot)$  生成带权重特征的空间特征学习矩阵  $S_L$ , 可表示为

$$S_L = F_c(S) = w \otimes S + b, \quad (12)$$

$S_L$  通过激活函数  $G_c(\cdot)$  生成空间特征矩阵  $S_s$ , 可表示为

$$S_s = G_c(S_L) = 1 + \tanh(w \otimes S + b), \quad (13)$$

式中, 通道权重  $w \in \mathbb{R}^{1 \times 1 \times 1}$ , 通道偏置  $b \in \mathbb{R}^{1 \times 1 \times 1}$ 。

### 3.3 MFDEB

SDEB 如图 4 所示。鉴于 SDEB 输入维度与输出维度的不同, 无法利用多尺度残差网络进行特征提取。为了缓解 SDEB 进行特征提取导致的像素信息丢失问题, 本文提出 MFDEB, 如图 5 所示。输入特征为  $X \in \mathbb{R}^{C \times H \times W}$ , 主干通道运用卷积运算生成的特征  $F_1 \in \mathbb{R}^{2C \times (H/2) \times (W/2)}$  可表示为

$$F_1 = f(W_{M1} * X) * W_{M2}, \quad (14)$$

式中,  $*$  为卷积运算。为确保特征张量(tensor)的大小一致, 对  $F_1$  采用边沿补 0 操作。 $W_{M1}$  是一个通道数和数量均为  $C$  的  $\text{Conv}(3, 3)$ , 步长为 2, 填充为 1。 $W_{M2}$  是数量为  $2C$ , 通道数为  $C$  的  $\text{Conv}(3, 3)$ , 步长为 1, 填充为 1。 $\text{Maxpool}(2)$  利用最大池化生成特征  $F_2 \in \mathbb{R}^{C \times (H/2) \times (W/2)}$  可表示为

$$F_2 = f[\text{Maxpool}(X)]. \quad (15)$$

$\text{Avgpool}(2)$  利用平均池化生成特征  $F_3 \in \mathbb{R}^{C \times (H/2) \times (W/2)}$  可表示为




图4 SDEB示意图

Fig. 4 Diagram of single scale down-sampling extraction block (SDEB)

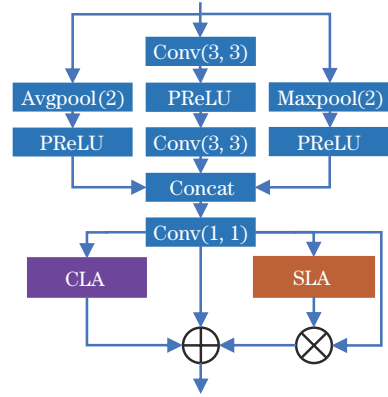


图5 MFDEB示意图

Fig. 5 Diagram of multi-feature down-sampling extraction block (MFDEB)

$$F_3 = f[\text{Avgpool}(X)], \quad (16)$$

式中,  $f$  均代表 PReLU 激活函数。在特征提取后, 将特征  $F_1$ 、 $F_2$  和  $F_3$  进行融合。然后利用数量为  $2C$ , 通道数为  $4C$  的  $\text{Conv}(1, 1)$  的卷积核  $W_{M3}$ , 生成初始融合特征  $F_{\text{sum}} \in \mathbb{R}^{2C \times (H/2) \times (W/2)}$  可表示为

$$F_{\text{sum}} = f_{\text{use}}\{F_1; F_2; F_3\} * W_{M3}, \quad (17)$$

式中:  $f_{\text{use}}\{\cdot\}$  为按通道方式进行融合;  $*$  为卷积运算。然后, 在初始融合特征  $F_{\text{sum}}$  后嵌入 CLA 与 SLA 强化通道与空间特征, 在末端引入初始融合特征  $F_{\text{sum}}$  进行恒等映射。由此完成多特征下采样提取, 输出特征  $F_{\text{MFDEB}} \in \mathbb{R}^{2C \times (H/2) \times (W/2)}$  可表示为

$$F_{\text{MFDEB}} = f_{\text{CLA}}(F_{\text{sum}}) + f_{\text{SLA}}(F_{\text{sum}}) \otimes F_{\text{sum}} + F_{\text{sum}}, \quad (18)$$

式中:  $f_{\text{CLA}}(\cdot)$  为 CLA 特征提取;  $f_{\text{SLA}}(\cdot)$  为 SLA 特征提取。

### 3.4 RAAB

级联 RCAB (CRCAB) 特征提取方式, 如图 6 所示。由于其仅强化关注图像深层次的通道特征, 丢失了较多的空间特征, 导致出现重建图像感兴趣区域的特征不显著的问题。




图6 级联 RCAB 模块

Fig. 6 Cascade residual channel attention network (RCAB) block



首先,为提升单个 RCAB 对通道特征的提取能力,将 CLA 插入残差网络中形成残差通道学习注意力模块(RCLAB)替代 RCAB。

其次,鉴于级联 RCLAB(CRCLAB)方式仍然无法利用网络中局部空间特征的缺点,本文进一步提出了 RAAB,如图 7 所示。




图 7 RAAB 示意图

Fig. 7 Diagram of residual attention aggregation block (RAAB)

区别于文献[18]的聚合特征仅为每一级的残差特征,RAAB的本级信息特征 $F_i$ 可表示为

$$F_i = X + \sum_{j=0}^i f_{\text{RCLAB}}(F_{j-1}), i = 0, \dots, n-1, \quad (19)$$

即本级特征 $F_i$ 包含前级局部残差特征之和以及输入恒等映射。式中, $f_{\text{RCLAB}}(\cdot)$ 为RCLAB特征提取用于获取图像通道特征信息,输入恒等映射 $X \in \mathbb{R}^{C \times H \times W}$ ,本级特征 $F_i \in \mathbb{R}^{C \times H \times W}$ , $F_i$ 为前级特征, $F_{-1}$ 为 $X$ 。 $F_{n-1}$ 为CRCLAB模型中主干通道提取的通道特征信息 $F_c$ 。

残差注意力聚合RARB特征提取实现原理为:首先,利用空间特征融合模块(SFFB)中的SLA提取级联RCLAB网络中不同阶段的空间特征信息,其中提取的前 $n-1$ 个空间特征信息 $F_{\text{spatial}}(i)$ 可表示为

$$F_{\text{spatial}}(i) = f_{\text{SLA}}(F_i), i = 0, \dots, n-2, \quad (20)$$

式中 $f_{\text{SLA}}(\cdot)$ 为SLA特征提取。在特征提取后,按通道融合方式融合空间特征信息 $F_{\text{spatial}}(i)$ ,融合特征通过 $n-1$ 个一维的Conv(1,1)卷积核 $W_{F1}$ ,将 $n-1$ 维空间特征矩阵映射为一维空间特征矩阵 $F_{\text{SFFB}} \in \mathbb{R}^{1 \times H \times W}$ ,可表示为

$$F_{\text{SFFB}} = f_{\text{use}}\{F_{\text{spatial}}(i)\} * W_{F1}, i = 0, \dots, n-2, \quad (21)$$

式中: $f_{\text{use}}\{\cdot\}$ 为按通道方式融合;\*为卷积运算。在空间融合特征 $F_{\text{SFFB}}$ 提取后,将主干通道特征信息 $F_c$ 与一维特征 $F_{\text{SFFB}}$ 相乘,生成包含通道信息的空间特征 $F_s \in \mathbb{R}^{C \times H \times W}$ ,可表示为

$$F_s = F_{\text{SFFB}} \otimes F_c, \quad (22)$$

最后,将通道特征 $F_c$ 与空间特征 $F_s$ 进行特征融合,并嵌入输入恒等映射,生成的残差注意力聚合特征 $F_{\text{RAAB}} \in \mathbb{R}^{C \times H \times W}$ 可表示为

$$F_{\text{RAAB}} = f_{\text{use}}\{F_c; F_s\} * W_{F2} + X, \quad (23)$$

式中, $W_{F2}$ 是数量为 $C$ 、通道数为 $2C$ 的Conv(1,1)。

## 4 实验及结果分析

本文及相关算法在Windows 10操作系统上搭载pytorch1.7框架进行训练和测试,电脑配置为AMD Ryzen 9 4900H with Radeon Graphics 3.30 GHz, NVIDIA GeForce RTX 2060, RAM(16 G)。

### 4.1 数据集

实验使用Kaggle数据库COVID-19 RADIOGRAPHY DATABASE中的Normal肺部扫描图像作为数据集Set1。从美国肿瘤基因组图谱数据库TCGA\_LAUD和LIDC\_IDRI分别选取肺中叶图像作为数据集Set2,肺结节图像作为数据集Set3。Set1选取520张肺部CT图像,其中500张用作训练集,20张用作测试集。数据集Set2与Set3分别选取500张CT图像,其中480张用作训练集,20张用作测试集。Set1数据源见文献[19],Set2数据源见文献[20],Set3数据源见文献[21]。

### 4.2 实验参数设置

DRN及RAADRNet算法、通道数 $F$ 及基本残差网络数量 $n$ 如表1所示,配置方式为:通道数 $F$ /基本残差网络数 $n$ 。使用Adam优化器进行参数优化( $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ),初始学习率为 $10^{-4}$ ,batchsize为32。

表 1 参数配置

Table 1 Parameter configuration

Algorithm	SRX2	SRX4	SRX8	SRX16
RAADRNet	16/30	16/30	8/30	8/15

由于图像纹理特征和尺寸相差较大,为了更加有效地重建CT图像,本文分别在3个数据集上进行训练和测试。参数配置详情可参考文献[14]。

### 4.3 消融实验

消融实验以Set1数据集为训练和测试数据集。在SRX4时,进行实验数据分析和测试。由于RGB通道的重建图像能够更加直观地反映图像的整体细节,因此本文及参考算法均在RGB通道完成测试和分析。

#### 4.3.1 注意力机制消融实验

注意力机制消融实验如表2所示。分别将CLA、SLA与ECA<sup>[15]</sup>、CoA<sup>[16]</sup>、SAM<sup>[17]</sup>替代CRCAB中的CA<sup>[13]</sup>进行对比分析。

在通道注意力实验中,利用激活函数Sigmoid( $\cdot$ )进行非线性映射的CLA,相比于改进前的ECA和PSNR平均提升0.283 dB,SSIM平均提升0.0006。在利用 $1 + \tanh(\cdot)$ 激活函数进行测试时,PSNR进一步提

表 2 注意力机制消融实验结果  
Table 2 Ablation test results of attention mechanism

Attentional mechanism	Activation function	Params /M	PSNR/ dB	SSIM	
Channel attention	CA <sup>[13]</sup>	Sigmoid( $\cdot$ )	4.80	37.303	0.9192
	CoA <sup>[16]</sup>	h_swish( $\cdot$ )	4.82	37.105	0.9186
	ECA <sup>[15]</sup>	Sigmoid( $\cdot$ )	4.77	37.396	0.9196
	CLA	Sigmoid( $\cdot$ )	4.77	<b>37.679</b>	<b>0.9202</b>
	CLA	1+tanh( $\cdot$ )	4.77	<b>37.746</b>	<b>0.9205</b>
Spatial attention	SAM <sup>[17]</sup>	Sigmoid( $\cdot$ )	4.78	36.374	0.9127
	SLA	Sigmoid( $\cdot$ )	4.77	<b>36.827</b>	<b>0.9141</b>
	SLA	1+tanh( $\cdot$ )	4.77	<b>36.954</b>	<b>0.9148</b>

升 0.067 dB, SSIM 进一步提升 0.0003, 且模型参数量保持不变。最终, 在采用 1+tanh( $\cdot$ ) 进行通道门限设定的 CLA, 相比于基线 CA 和 PSNR 平均提升 0.443 dB, SSIM 平均提升 0.0013, 模型参数量减少了 0.03 M。

在空间注意力(Spatial attention)实验中, SLA 采用原始激活函数 Sigmoid( $\cdot$ ) 的情况下, 相比于基线 SAM 和 PSNR 平均提升了 0.453 dB, SSIM 平均提升

了 0.0014。在采用 1+tanh( $\cdot$ ) 激活函数的 SLA 相比于基线 SAM, 参数量同样减少 0.01 M, 且 PSNR 平均提升 0.580 dB, SSIM 平均提升 0.0021。

#### 4.3.2 RAADRNet 消融实验

RAADRNet 特征提取消融实验如表 3 所示, 实验目的在于寻求最佳重建模型。本文将单尺度下采样提取 SDEB 与级联 RCAB(CRCAB) 方式作为基线算法。

表 3 算法消融实验结果  
Table 3 Ablation test results of algorithm

SDEB	MFDEB	CRCAB	CRCLAB	RAAB	Params /M	PSNR /dB	SSIM
✓		✓			4.80	37.303	0.9192
	✓	✓			4.81	37.549	0.9197
✓			✓		4.77	37.746	0.9205
	✓		✓		4.78	<b>37.787</b>	0.9207
✓				✓	4.79	37.770	<b>0.9210</b>
	✓			✓	4.80	<b>37.834</b>	<b>0.9210</b>

首先, 利用多特征下采样提取方式 MFDEB 与 CRCAB 进行融合测试, 在网络模型参数增加 0.1 M 的情况下, PSNR 平均提升 0.246 dB, SSIM 平均提升 0.0005。其次, 为了优化 CRCAB 的通道特征提取能力, 利用 CRCLAB 方式与 MFDEB 进行融合测试时, 网络模型参数量减少 0.02 M, PSNR 平均提升 0.484 dB, SSIM 平均提升 0.0015。最后, 为了解决 CRLCAB 网络中空间特征信息的丢失问题, 利用 RAAB 与 MFDEB 进行融合测试。与基线算法相比, PSNR 平均提升 0.531 dB, SSIM 平均提升 0.0018。最终由 MFDEB 与 RAAB 联合构建 RAADRNet 算法。

#### 4.3.3 对偶损失权重 $\lambda$ 消融实验

对偶损失权重因子  $\lambda$  消融实验分析如表 4 所示。DRN<sup>[14]</sup> 算法中  $\lambda$  取值为 0.01~1 时重建效果显著优于

其他区间, 本文将其重新划分 0.01~0.1 和 0.1~1 两个子区间, 并取两个子区间上限的 1/2 进行实验, 最后对  $\lambda$  取 0 验证对偶损失引入的有效性。

由表 4 可知, 在  $\lambda$  取 0 时, 重建精度显著低于  $\lambda$  在 0.01~0.1 区间的取值。证明了对偶损失的引入可以有效地约束超分辨率重建过程的解空间。随着  $\lambda$  值的增大, 在  $\lambda$  小于 0.1 以及大于 0.1 时重建质量均有下降, 尤其在  $\lambda$  大于 0.5 时, 其重建精度劣于  $\lambda$  取 0, 表明对偶损失阻碍了重建精度。最终, 在  $\lambda$  取 0.1 时取得极大值。本文选取 0.1 作为权重值。

#### 4.3.4 算法重建时间分析

RAADRNet 与基线 DRN 算法在 SRX4 模型中的重建时间如表 5 所示。Set1 数据集图像尺寸较大且分辨率较高, 重建速度相对较慢。Set2 与 Set3 数据集图像尺寸较小, 重建速度较快。

由表 5 可知, RAADRNet 相比于 DRN 平均每张图像的重建时间: 在 Set1 数据集上延长了 0.12 s; 在 Set2 数据集上延长了 0.02 s; 在 Set3 数据集上延长了 0.04 s。综合而言, 算法的重建时间可满足实际应用的需要。

表 4 权重因子  $\lambda$  配置

Table 4 Weight factor  $\lambda$  configuration

$\lambda$	0	0.01	0.05	0.1	0.5	1.0
PSNR	37.662	37.797	<b>37.818</b>	<b>37.834</b>	37.636	37.531

表 5 SRX4 重建时间分析

Table 5 Analysis of reconstruct time for SRX4

Dataset	Size / pixel	Number	DRN /s	RAADRNet /s	Time increment /s
Set1	1024×1024	20	3.01	3.13	0.12
Set2	512×512	20	0.30	0.32	0.02
Set3	512×512	20	0.53	0.57	0.04

#### 4.4 实验结果及分析

实验对比算法采用双三次插值法 Bicubic、基于卷积神经网络的方法 (SRCNN)<sup>[1][2]</sup>、基于密集残差网络的方法 (RDN)<sup>[12]</sup>、基于残差通道注意力网络的方法 (RCAN)<sup>[13]</sup>、基于二阶注意力网络的方法 (SAN)<sup>[22]</sup> 和基于对偶回归网络的方法 (DRN)<sup>[14]</sup>, 评价指标 (EI) 采用 PSNR 和 SSIM。

实验数据结果如表 6 所示, RAADRNet 算法在每个数据集的 3 种不同尺度上的重建效果相比于基线算法 DRN: 在 Set1 数据集上 PSNR 平均提升了 0.564

dB, SSIM 平均提升了 0.0025; 在 Set2 数据集上 PSNR 平均提升了 0.408 dB, SSIM 平均提升了 0.0029; 在 Set3 数据集上 PSNR 平均提升了 0.504 dB, SSIM 平均提升了 0.0028。

浮点数分析: 实验采用双精度浮点型数据, 可精确 15 位浮点数, 本文根据研究需要设置 PSNR 精度为  $10^{-3}$ , SSIM 精度为  $10^{-4}$ 。实验效率分析: 由表 3 可知 RAADRNet 模型参数量仍为 4.80 M, 即 RAADRNet 与 DRN 相比, 模型参数量不变。由表 5 可知 RAADRNet 算法的重建时间在 3 个数据集均有小幅增加。综合而言, 在 3 个数据集的 9 种不同尺寸上, RAADRNet 算法牺牲了平均每张约 0.06 s 的重建时间, 换取了 PSNR 平均提升 0.492 dB, SSIM 平均提升 0.0027。后续工作将在 RAADRNet 基础上, 以残差注意力聚合特征提取 RAAB 为主, 进一步降低算法的时间复杂度。

实验分别在 Set1、Set2、Set3 数据集的不同尺度上进行超分辨率重建, 重建效果如图 8~10 所示。

表 6 实验结果数据

Table 6 Data of experimental results

Algorithm	EI	Set1			Set2			Set3		
		X2	X4	X16	X2	X4	X8	X2	X4	X8
Bicubic	PSNR /dB	34.470	31.472	27.450	27.346	24.049	19.891	31.554	27.475	22.547
	SSIM	0.9008	0.8616	0.8141	0.9083	0.8233	0.7094	0.9313	0.8550	0.7401
SRCNN	PSNR /dB	35.339	31.940	28.000	29.296	25.780	21.488	32.783	30.317	25.071
	SSIM	0.9062	0.8714	0.8230	0.9269	0.8588	0.7739	0.9397	0.8940	0.8098
RDN	PSNR /dB	36.205	32.270	28.362	30.031	26.526	22.029	33.467	31.156	25.921
	SSIM	0.9095	0.8742	0.8272	0.9361	0.8703	0.7905	0.9442	0.9034	0.8039
RCAN	PSNR /dB	36.705	32.681	28.635	30.999	27.283	22.573	34.098	31.792	26.873
	SSIM	0.9161	0.8780	0.8283	0.9391	0.8788	0.8048	0.9471	0.9087	0.8423
SAN	PSNR /dB	37.008	33.041	28.866	31.743	27.832	22.935	34.601	32.223	27.347
	SSIM	0.9183	0.8818	0.8376	0.9420	0.8852	0.8122	0.9503	0.9091	0.8492
DRN	PSNR /dB	37.303	33.377	29.121	32.675	28.209	23.285	34.964	32.820	27.928
	SSIM	0.9192	0.8833	0.8414	0.9473	0.8885	0.8184	0.9541	0.9141	0.8566
RAADRNet	PSNR /dB	<b>37.834</b>	<b>34.176</b>	<b>29.483</b>	<b>33.402</b>	<b>28.449</b>	<b>23.544</b>	<b>35.434</b>	<b>33.480</b>	<b>28.312</b>
	SSIM	<b>0.9210</b>	<b>0.8866</b>	<b>0.8440</b>	<b>0.9498</b>	<b>0.8912</b>	<b>0.8219</b>	<b>0.9547</b>	<b>0.9176</b>	<b>0.8609</b>




图 8 Set1 数据集 SRX4 重建效果对比图

Fig. 8 Effect comparison of SRX4 reconstruction images in Set1



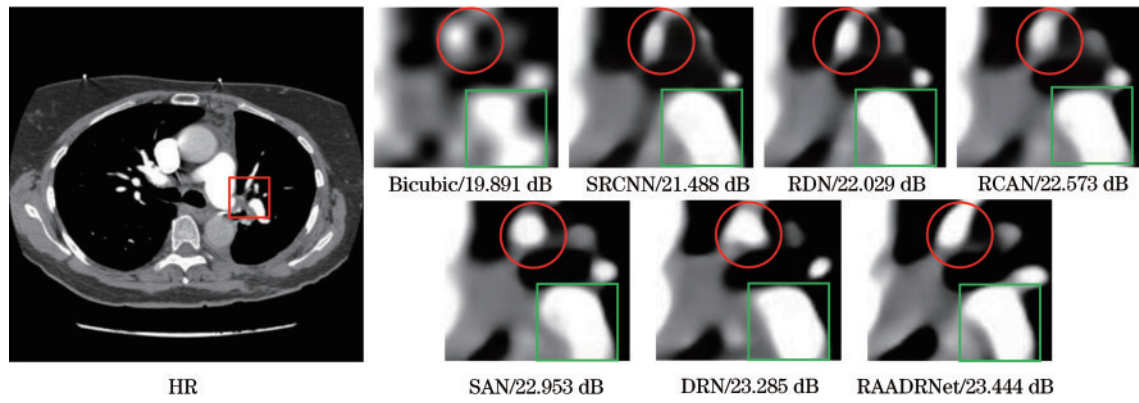


图9 Set2数据集SRX8重建效果对比图

Fig. 9 Effect comparison of SRX8 reconstruction images in Set2




图10 Set3数据集SRX8重建效果对比图

Fig. 10 Effect comparison of SRX8 reconstruction images in Set3

主观评价:在图8所示的放大尺寸为4倍的重建图像中,RAADRNet相比于其他算法具有更好的边缘锐化效果。图9所示的8倍的重建图像中,可辨识Bicubic获取的重建图像具有成块模糊等问题, SRCNN等深度学习的算法虽提升了重建性能,但图像的局部特征不显著且形变较严重,而RAADRNet重建图像的效果明显优于其他方法,如标注的顶部白色图像的大小,以及右下部分图像的形状均更接近于真实的高分辨率图像。图10所示的8倍重建效果中,可清晰地辨识RAADRNet算法能够更好地重建不规则椭圆部分的图像特征。

## 5 结 论

提出了一种基于RAADRNet的超分辨率CT图像重建算法。通过对ECA与SAM进行改进,得到CLA与SLA,增强了网络模型对通道及空间特征的提取能力,进一步将CLA与SLA分别嵌入MFDEB和RAAB中,获取了更好的重建效果。PSNR平均提升0.492 dB,SSIM平均提升0.0027。重建的CT图像边缘锐化效果好,局部特征更加显著,即使在大尺寸情况下仍能获取较好的重建效果,对病灶的诊断及相关医学影像的研究具有重要意义。后续工作将在确保

RAADRNet算法重建精度的同时进一步降低算法的复杂度以及重建时间。

## 参 考 文 献

- [1] Dong C, Loy C C, He K M, et al. Learning a deep convolutional network for image super-resolution[M]// Fleet D, Pajdla T, Schiele B, et al. Computer vision-ECCV 2014. Lecture notes in computer science. Cham: Springer, 2014, 8692: 184-199.
- [2] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [3] Zhang L, Wu X L. An edge-guided image interpolation algorithm via directional filtering and data fusion[J]. IEEE Transactions on Image Processing, 2006, 15(8): 2226-2238.
- [4] Tai Y W, Liu S C, Brown M S, et al. Super resolution using edge prior and single image detail synthesis[C]// 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 13-18, 2010, San Francisco, CA, USA. New York: IEEE Press, 2010: 2400-2407.
- [5] 李雨, 史娜, 孔慧华, 等. 基于全变分和梯度域卷积稀疏编码的稀疏角度CT重建算法[J]. 激光与光电子学进



- 展, 2021, 58(12): 1210031.
- Li Y, Shi N, Kong H H, et al. Sparse angle CT reconstruction algorithm based on total variation and convolutional sparse coding in gradient domain[J]. *Laser & Optoelectronics Progress*, 2021, 58(12): 1210031.
- [6] Dong C, Loy C C, Tang X O. Accelerating the super-resolution convolutional neural network[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9906: 391-407.
- [7] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1132-1140.
- [8] Shah Z H, Müller M, Wang T C, et al. Deep-learning based denoising and reconstruction of super-resolution structured illumination microscopy images[J]. *Photonics Research*, 2021, 9(5): 570-583.
- [9] Yang C S, Yao Y H, Jin C Z, et al. High-fidelity image reconstruction for compressed ultrafast photography via an augmented-Lagrangian and deep-learning hybrid algorithm[J]. *Photonics Research*, 2021, 9(2): B30-B37.
- [10] 刘可文, 马圆, 熊红霞, 等. 基于残差通道注意力网络的医学图像超分辨率重建方法[J]. *激光与光电子学进展*, 2020, 57(2): 021014.
- Liu K W, Ma Y, Xiong H X, et al. Medical-image super-resolution reconstruction method based on residual channel attention network[J]. *Laser & Optoelectronics Progress*, 2020, 57(2): 021014.
- [11] 席志红, 侯彩燕, 袁昆鹏. 基于残差网络的医学图像超分辨率重建[J]. *计算机工程与应用*, 2019, 55(19): 191-197.
- Xi Z H, Hou C Y, Yuan K P. Medical image super resolution reconstruction based on residual network[J]. *Computer Engineering and Applications*, 2019, 55(19): 191-197.
- [12] Zhang Y L, Tian Y P, Kong Y, et al. Residual dense network for image super-resolution[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2472-2481.
- [13] Zhang Y L, Li K P, Li K, et al. Image super-resolution using very deep residual channel attention networks[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 294-310.
- [14] Guo Y, Chen J, Wang J D, et al. Closed-loop matters: dual regression networks for single image super-resolution [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 5406-5415.
- [15] Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11531-11539.
- [16] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 13708-13717.
- [17] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 3-19.
- [18] Liu J, Zhang W J, Tang Y T, et al. Residual feature aggregation network for image super-resolution[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 2356-2365.
- [19] Tawsifur R, Dr. M C, Amith K. COVID-19 radiography database[DB/OL]. (2020-07-20) [2021-06-01]. <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>.
- [20] Albertina B, Watson M. Radiology data from the cancer genome atlas lung adenocarcinoma [TCGA-LUAD] collection//The cancer imaging archive [DB/OL]. (2020-06-03)[2021-06-01]. <http://doi.org/10.7937/K9/TCIA.2016.JGNIHEP5>.
- [21] Armato III, McLennan S G. Data from LIDC-IDRI//The cancer imaging archive [DB/OL]. (2021-05-24) [2021-06-01] <https://doi.org/10.7937/K9/TCIA.2015.LO9QL9SX>.