

文章编号: 2095-2163(2023)01-0136-06

中图分类号: TP391

文献标志码: A

基于生成对抗网络和注意力机制的医学图像超分辨率重建

冉文兵¹, 梁永超¹, 覃芹¹, 陈旋¹, 张利^{1,2}

(1 贵州大学 大数据与信息工程学院; 2 贵州大学 省部共建公共大数据国家重点实验室, 贵阳 550025)

摘要: 高分辨率的医学图像可以为临床应用和图像分析提供重要信息,然而医学成像受到硬件的限制,图像分辨率必须在扫描时间、信噪比以及空间覆盖等因素之间权衡。针对这一问题可以使用超分辨率重建技术进行解决,以实现感知真实的高分辨医学图像。本文对超分辨率重建生成对抗网络(SRGAN)模型中的残差结构进行优化,并结合混合注意力机制,提出一种具有空间和通道注意力的残差特征提取模块,并将该模块用于构建生成对抗网络(GAN)的生成器。除此之外,在SRGAN的损失函数的基础上加入全变分损失,以提升图像局部细节的锐度。为了考虑图像的真实退化过程,在数据处理中使用退化学习模拟CT低分辨率图像。本文采用肺结核患者的胸部CT图像进行训练和测试,实验结果表明该方法能够更好地重建CT图像中的细节部分,可以为患者提供更好的病变纹理,具有一定的临床诊断价值。

关键词: 生成对抗网络; 注意力机制; 超分辨率重建; 医学图像

Super resolution reconstruction of medical images based on generative adversarial network and attention mechanism

RAN Wenbing¹, LIANG Yongchao¹, QIN Qin¹, CHEN Xuan¹, ZHANG Li^{1,2}

(1 College of big data and Information Engineering, Guizhou University, Guiyang 550025, China;

2 State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China)

[Abstract] High-resolution medical images can provide important information for clinical application and image quantitative analysis. However, medical imaging is limited by hardware, and image resolution must be balanced among scanning time, signal-to-noise ratio and spatial coverage. To solve this problem, super-resolution reconstruction technology can be used to realize the perception of real high-resolution medical images. In this paper, the residual structure of super-resolution reconstruction generative adversarial network(SRGAN) model is optimized, and combined with the hybrid attention mechanism, a residual feature extraction module with spatial and channel attention is proposed, and the module is used to build the generator of generative adversarial network(GAN). In addition, total variation loss is added to SRGAN's loss function to improve the sharpness of local details. In data processing, degradation learning is used to simulate low-resolution CT images in order to consider the real degradation process of images. In this paper, the chest CT images of patients with pulmonary tuberculosis will be used for training and testing. The experimental results show that the method can better reconstruct the details in the CT images, can provide better lesion texture for patients, and has certain clinical diagnostic value.

[Key words] generative adversarial networks; attention mechanism; super-resolution reconstruction; medical image

0 引言

在临床医学中,电子计算机断层扫描(CT)技术是利用X射线对人体进行照射,并结合高精度的探测器检测射线能量的衰减情况,实现对人体内部的患病部位进行快速成像。但是由于临床CT设备的

分辨率、噪声和人体所能承受的辐射量等因素的限制,以及数据存储过程中信息丢失,导致在医学诊断中难以获得足够的病理信息。为了解决这一问题可以对成像设备进行提升或设计更好的软件算法,但更新成像设备的代价较大。因此,通过使用相关算法实现CT图像的超分辨率重建(SR)具有重要意

基金项目: 贵州大学引进人才科研基金(贵大人基合字(2018)60号)。

作者简介: 冉文兵(1997-),男,硕士研究生,主要研究方向:深度学习、医学图像处理;梁永超(1985-),男,博士,教授,主要研究方向:材料模拟及数据可视化;覃芹(1997-),女,硕士研究生,主要研究方向:深度学习、医学图像处理;陈旋(1997-),女,硕士研究生,主要研究方向:深度学习、医学图像处理;张利(1987-),男,博士,教授,主要研究方向:人工智能、大数据技术与应用。

通讯作者: 张利 Email: lizhang.science@gmail.com

收稿日期: 2022-09-11

义。

超分辨率重建技术最早出现在光学工程领域,是指从低分辨率(LR)图像重建出高分辨(HR)图像^[1]。1984年Tsai等人^[2]提出基于频域的超分辨率重建技术,使用多帧LR图像重建单帧HR图像。目前,关于图像超分辨率重建技术大致可以分为基于插值、重建模型以及深度学习3大类。插值方法主要包括临近插值、双三次插值和双线性插值等,这类方法重建的速度快,但重建图像存在模糊和伪影;重建模型主要包括迭代反投影(IBM)和凸集投影法(POCS)等,这类方法对于图像中细节部分的重建需要引入大量的先验知识;基于深度学习的重建方法比基于插值和重建模型的重建效果好很多,并且能够实现LR图像到HR图像端到端映射,是目前用于图像超分辨率重建的主流方法。

2014年,Dong等人^[3]首次提出使用深度学习技术用于图像的超分辨率重建,通过使用包含特征提取、非线性映射和图像重建3个部分的卷积神经网络实现单幅图像的超分辨率重建,但容易产生棋盘伪影;2017年,Ledig等人^[4]提出一种基于生成对抗网络(GAN)和残差学习的超分辨率重建生成对抗网络(SRGAN),并使用一个由对抗损失和内容损失组成的损失函数,解决了在较大缩放因子情况下的图像细节纹理的恢复问题;为了进一步提升图像的重建质量,2018年,Wang等人^[5]对SRGAN中的损失函数进行改进,并引入没有批归一化的残差中的残差密集块(RRDB)作为网络的基本单元,提出了增强的SRGAN(ESRGAN)。这些方法在自然图像的超分辨率重建中取得较好的效果。与此同时,Zheng等人^[6]基于CycleGAN提出一种无监督的GAN实现CT图像的超分辨率重建,在结构相似性(SSIM)上取得一定的提升。本文的目标是基于GAN和注意力机制提出一种有效的医学图像超分辨率重建方法,并在SRGAN的损失函数的基础之上引入全变分损失改善图像细节纹理的重构。除此之外,使用退化学习方法模拟图像的退化过程,弥补传统退化模型的缺陷,使本文方法更具有现实意义。

1 相关理论

1.1 生成对抗网络

2014年,Goodfellow等人^[7]首次提出生成对抗网络,是一种通过博弈过程估计生成的模型架构。GAN主要由生成器和鉴别器组成,模型结构如图1所示,生成器将输入的随机噪声或样本数据进行处

理后输出;鉴别器则将生成器的输出和真实的数据进行对比和判断生成器输出的真实性。通过生成器与鉴别器之间的相互对抗,最终生成器与鉴别器之间达到纳什均衡状态,并使得生成器产生的图像逐渐趋于真实图像。GAN与受限玻尔兹曼机(RBM)、生成随机网络(GSN)和深度信念网络(DBNs)等生成模型相比,具有较好的图像生成能力,故在图像风格迁移、图像合成、超分辨率重建和去噪等领域得以广泛应用。尤其在图像的超分辨率重建中,GAN在学习流行之间的映射有很好的效果,在一定程度上可以防止重建图像的高频细节和图像纹理缺失,以及图像平滑等问题^[8]。




图 1 生成对抗网络模型

Fig. 1 Generate adversarial network models

1.2 注意力机制

在生物的视觉系统中,对视场内的聚焦是有所区别的,通过关注场景中的关键区域获取有价值的信息,这种视觉特性在深度学习中也得到广泛应用。在深度学习中,注意力机制的实现主要通过权重掩膜标识出图像中的特殊区域。目前根据关注的细粒度可以划分为两大类:硬注意力机制和软注意力机制。软注意力机制在计算过程中具有可微性,因此,相对于硬注意力机制训练难度较小。Hu等人^[9]提出一种简单有效且开销小的通道注意力机制模块SENet,可以自适应地校准通道级的特征响应;Roy等人^[10]提出一种空间注意力机制,对空间特征进行压缩和激发,实现在空间中校准特征映射。除此之外,大量的研究表明,通过共同利用空间注意力机制和通道注意力机制可以提高网络的重构性能。如:Woo等人^[11]将通道注意力机制与空间注意力进行级联,提出卷积块注意力模块(CBAM),该模块先将输入特征通过通道注意力机制得到通道权重掩膜并与输入特征相乘,然后将结果与通过空间注意力机制获取空间权重掩膜相乘得到最终的输出特征。

受到以上研究的启发,本文提出一种能够实现医学图像超分辨率重建的网络模型,通过使用残差特征提取模块和CBAM模型在图像的特征空间中

进行特征提取和筛选,以减少冗余信息的学习和参数量,提升网络的性能和重建效果。

1.3 模拟观测

在一般的图像超分辨率重建过程中,通常是将原始的高分辨率图像通过模糊、降采样和加噪等方法进行处理,得到与原始高分辨率图像对应的低分辨率图像,最终得到理论退化模型数据集 (X, Y) , x 表示理论模型模拟的低分辨率图像,具体过程可以由式(1)表示为

$$x = B(y) \downarrow_f + n \tag{1}$$

其中, y 表示原始的高分辨率图像; \downarrow_f 表示尺度因子为 f 的双三次降采样操作; B 为高斯模糊算子; n 为方差 $\sigma = 0.025$ 的高斯噪声。

式(1)可以简化为

$$x = H(y) + n \tag{2}$$

其中, $H(\cdot)$ 为退化核。

但通过这种方式模拟的 LR 图像对真实场景中的噪声和压缩等因素的反映是明显不足的,而且实际生活中很难得到 HR 图像和 LR 图像之间完全对应的数据集。为了解决这一问题,采用未配对的原始图像集,将 HR 图像通过 DSGAN 进行退化学习模拟真实场景的 LR 图像 \hat{x} , 得到退化学习数据集 (\hat{X}, Y) 后用于超分辨率重建,具体过程如图 2 所示。 x 为实际的 LR 图像且与 HR 图像 y 并无映射关系,将 HR 图像经过下 4 倍采样的 LR 图像 s , 使用 DSGAN 模型和 LR 图像 x 对图像 s 进行矫正得到更符合真实场景的 LR 图像 \hat{x} 。





图 2 使用 DSGAN 模型模拟 LR 图像的具体过程

Fig. 2 DSGAN model is used to simulate the specific process of LR image

2 模型结构

2.1 本文模型

目前,大多数基于深度学习的超分辨率重建技术,在医学图像上重建的结果过于模糊且缺失大量的细节纹理,利用 GAN 较强的拟合能力可以在一定程度上解决这一问题。SRGAN 通过使用深度残差网络,能够提取自然图像中更丰富的细节信息,其生成器中的残差结构如图 3(a)所示。基于本文的应用背景,对 SRGAN 生成器和鉴别器进行优化。在生成器的残差模块中,由于批量归一化层(BN)增加模型的计算复杂度和开销,故在本文所使用的残差结构中将其去除,仅保留卷积层和 PReLU 层,并引入 CBAM 混合注意力模块,组成具有通道和空间注意力的残差块,称之为 RES-CB,如图 3(b)所示。



(a) SRGAN 中的残差结构 (b) 本文提出的残差结构 RES-CB

图 3 两种残差结构对比

Fig. 3 Comparison of two residual structures

生成器主要由 5 个 RES-CB 模块堆叠而成,具体结构如图 4 所示。输入图像通过退化学习或理论模型模拟的 LR 图像,经过采样因子 f 为 2、3 和 4 的上采样,再使用 5×5 的卷积,5 个 RES-CB 模块, 5×5 的转置卷积层(Tconv)和投影层(Proj)^[12]处理后,与只经过上采样的图像相加,最后通过剪切层(Clipping)将图像中的像素值约束在 0~255 之间得到重建后的 SR 图像 \hat{y} 。其中,Proj 层主要用于计算近端映射和数据的保真度,并在反向传播的过程中会对该层的参数进行微调。




图 4 生成器模型结构

Fig. 4 Generator model structure

鉴别器网络用于区分真实的 HR 图像和虚假的 SR 图像结构,如图 5 所示。鉴别器主要由 7 个卷积特征提取块(Conv、BN 和 LReLU)组成,各个特征提取块中的卷积层由卷积核大小为 4,步长为 2 以及

卷积核大小为 3 步长为 1 的卷积交替构成,能够把特征映射从 64 增加到 512,在鉴别器的末端,通过两个全连接层和 Sigmoid 函数得到最后的鉴别结果。




图 5 鉴别器模型结构

Fig. 5 Discriminator model structure

2.2 损失函数

为了使用本文提出 GAN 模型能够实现医学图像的超分辨率重建,使用以下损失函数计算重建误差并指导模型的优化。

感知损失 (L_{PER}): 使用预训练的 VGG-19 网络分别对 HR 图像和 SR 图像进行特征提取,计算二者之间的欧式距离,以此来关注图像的感知质量,公式为

$$L_{PER} = \frac{1}{N} \sum_i^N \|\Psi(\hat{y}_i) - \Psi(y_i)\|_1 \quad (3)$$

其中, y_i 表示第 i 张真实的 HR 图像; \hat{y}_i 表示第 i 张重建的 SR 图像; $\Psi(\cdot)$ 为 VGG-19 预训练网络所提取到的特征; N 为模型训练中小批量大小。

对抗损失 (L_{ADV}): 使用鉴别器对真实的 HR 图像和生成的 SR 鉴别结果,对生成器进行约束,以提升重建图像的视觉效果。公式为

$$L_{ADV} = -E_y [\log(1 - D_y(y, \hat{y}))] - E_{\hat{y}} [\log(D_{\hat{y}}(\hat{y}, y))] \quad (4)$$

其中, E_y 和 $E_{\hat{y}}$ 分别是对小批量的 HR 图像和 SR 图像求取均值,通过鉴别器 D_y 求取生成的 SR 图像与真实的 HR 图像之间的差距。

像素级 MSE 损失 (L_1): 在图像超分辨率重建中,经常使用 MSE 计算虚假的 SR 图像和真实的 HR 图像之间的像素级距离,以此来对生成器的训练进行约束,公式(5)为

$$L_1 = \frac{1}{N} \sum_i^N \|\hat{y}_i - y_i\|_1 \quad (5)$$

全变分损失 (L_{TV}): 主要可以使图像中梯度变化较小的区域,产生一定的锐度,在一定程度上提升图像的细节纹理,公式(6)为

$$L_{TV} = \frac{1}{N} \sum_i^N (\|\nabla_h(\hat{y}_i) - \nabla_h(y_i)\|_1 +$$

$$\|\nabla_v(\hat{y}_i) - \nabla_v(y_i)\|_1) \quad (6)$$

其中, ∇_h 和 ∇_v 分别为水平和垂直梯度算子。

最终模型训练所使用的损失函数为

$$L_{total} = \lambda_1 L_{PER} + \lambda_2 L_{ADV} + \lambda_3 L_{TV} + \lambda_4 L_1 \quad (7)$$

其中, λ_1 、 λ_2 、 λ_3 和 λ_4 为各部分损失的权重,其值分别为 1、1、1 和 10。

3 实验分析

3.1 实验数据集

本文实验数据采用公开的肺结节患者的胸部 CT 图像数据集 LIDC-IDRI,从中选取纹理清晰、结构复杂的 550 张图像,其中 400 张作为训练集,100 张作为验证集,50 张作为测试集。原始数据集中的 LR 图像集与 HR 图像集并无一一对应关系。在训练之前,通过公式(1)的理论模型得到与 HR 图像具有映射关系的理论退化模型数据集 (X, Y); 通过将 HR 图像下采样从理论上模拟 LR 图像 s , 通过 LR 图像 x 和 DSGAN 生成 LR 图像 \hat{x} 得到退化学习的数据集 (\hat{X}, Y)。

3.2 参数设置

在训练过程中,输入 LR 图像的尺寸为 $(\lceil \frac{512}{f} \rceil, \lceil \frac{512}{f} \rceil)$ 。每次训练时,数据加载的批量大小为 16,所使用 Adam 优化器的参数 $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$ 、 $\epsilon = 10^{-8}$ 。学习率的初始值为 10^{-4} ,分别在迭代次数为 5 000、10 000、20 000 和 30 000 次时乘以 0.5。投影层参数 α 的初始范围为 [1, 2], 并通过反向传播进行微调。实验采用峰值信噪比 (PSNR) 和 SSIM 作为 CT 图像超分辨率重建的客观评价指标。所使用的实验环境见表 1。

表1 实验环境

Tab. 1 Experimental environment

名称	版本
操作系统	Ubuntu 18.04.1
CUDA 版本	11.0
GPU	GTX 1080Ti
显存	11 G
Python	3.6.13
深度学习框架	Pytorch 1.8.0

3.3 实验结果与分析

首先将本文提出的重建模型与其它重建模型 Bicubic、SRCNN、SRGAN、ESRGAN 进行尺度因子为 4 的重建对比,实验结果见表 2。在理论退化模型数据集上,本文的重建模型相比于 Bicubic、SRCNN、SRGAN 和 ESRGAN 在 *PSNR* 上分别提升了 3.38 dB、2.54 dB、1.47 dB 和 0.74 dB,在 *SSIM* 上分别提升了 0.087 4、0.033 9、0.038 0 和 0.046 6,验证了本文的重建模型相对于其他重建模型能够更好地完成 CT 图像的重建;在退化学习数据集上,本文的重建方法的 *PSNR* 达到了 28.98 dB, *SSIM* 达到了 0.864 2。通过对比几种重建方法分别在两种数据集上的重建指标结果,表明本文的重建方法不仅在传统的理论退化模型的 LR 图像上得到不错的效果,还在使用退化学习模拟 CT 成像和存储过程中受到图像退化后的 LR 图像上也能取得很好的效果。

表 2 不同重建方法在理论退化模型数据集和退化学习数据集上的实验结果对比

Tab. 2 Comparison of experimental results of different reconstruction methods on theoretical degenerate model dataset and degenerate learning dataset

数据集 (LR/HR)	重建模型	<i>PSNR</i> (dB)	<i>SSIM</i>
理论退化模型数据集	Bicubic	25.17	0.760 9
	SRCNN	26.01	0.814 4
	SRGAN	27.08	0.810 3
	ESRGAN	27.81	0.801 7
	OUR	28.55	0.848 3
退化学习数据集	Bicubic	25.51	0.771 5
	SRCNN	26.53	0.821 7
	SRGAN	27.47	0.815 9
	ESRGAN	28.06	0.811 3
	OUR	28.98	0.864 2

为了定性分析几种方法重建的图像质量,给出了 5 种重建方法在退化学习数据集上,进行尺度因子为 4 的重建结果,如图 6 所示。图 6(a)为原始的

HR 图像,图 6(b)为通过 Bicubic 重建的图像,图 6(c)为通过 SRCNN 重建的图像,图 6(d)为通过 SRGAN 重建的图像,图 6(e)为通过 ESRGAN 重建的图像,图 6(f)为本文提出模型的重建结果。从图 6 可以看出,Bicubic 和 SRCNN 的结果过于模糊,且在组织结构的分界线上较为平滑;SRGAN 在组织的边界有明显的伪影;ESRGAN 的结果在组织边界较为尖锐且引入大量的噪声;本文提出的模型在这几种方法中的重建效果较为突出,但是与原始的 HR 图像相比,对于细节纹理的重建仍然略显不足。

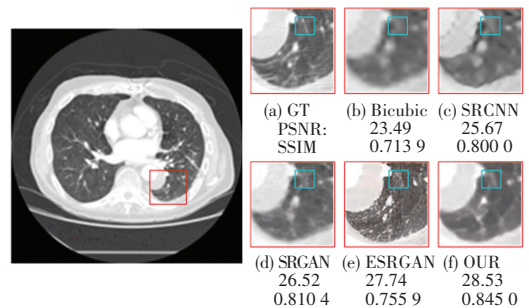


图 6 5 种方法重建的 CT 图像对比

Fig. 6 Comparison of CT images reconstructed by five methods

本文的重建方法可以实现不同尺度因子的超分辨重建,不同尺度重建的结果见表 3。除了使用 *PSNR* 和 *SSIM* 分析重建图像质量,还使用学习感知图像块相似度 (*LPIPS*) 对重建图像感知质量进行比较。*LPIPS* 的值越小,说明图像的感知质量越好。*LPIPS* 在重建尺度因子为 4 的 *LPIPS* 比 $\times 2$ 和 $\times 3$ 分别高出了 0.091 5 和 0.080 9。下采样因子为 2、3 和 4 的 LR 图像和通过本文重建方法得到的 SR 图像,如图 7 所示。尺度因子较小的 LR 图像保留的信息较多,通过对重建的图像进行对比,尺度因子为 2 的 SR 图像中的细节更为清晰。

表 3 本文的方法在退化学习数据集上进行不同尺度重建的实验结果对比

Tab. 3 The method in this paper compares the experimental results of reconstruction at different scales on degenerate learning datasets

重建尺度	<i>PSNR</i> (dB)	<i>SSIM</i>	<i>LPIPS</i>
$\times 2$	33.24	0.911 2	0.102 7
$\times 3$	32.49	0.893 9	0.113 3
$\times 4$	28.98	0.864 2	0.194 2

经过上述的客观指标评价和主观视觉分析,可见本文提出的超分辨重建算法,在 CT 图像的重建中具有一定的优越性,从而证明了本文提出网络模型和数据模拟方法的有效性。本文使用退化学习算法可以对真实场景的 LR 图像进行模拟,让重建方

法更具有现实意义;通过混合注意力机制从空间和通道两方面对指导特征有选择性地学习,提高网络性能和训练效果。

分辨重建方法与本文的方法进行对比分析,验证了该方法在医学图像超分辨重建方面具有一定的潜力。在未来的工作中,仍然需要探索更好的方法解决大尺度重建的部分细节丢失问题,以及需要使用更好的定量评估方法分析医学图像超分辨重建效果。

参考文献

[1] GERCHBERG R W. Super - resolution through error energy reduction[J]. Journal of Modern Optics, 1974, 21(9): 709-720.

[2] TSAI R. Multiframe image restoration and registration [J]. Advance Computer Visual and Image Processing, 1984, 1: 317-339.

[3] DONG C, LOY C C, HE K, et al. Learning a deep convolutional network for image super-resolution[C]//European conference on computer vision. Springer, Cham, 2014; 184-199.

[4] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2017; 4681-4690.

[5] WANG X, YU K, WU S, et al. Esrgan: Enhanced super-resolution generative adversarial networks [C] // Proceedings of the European conference on computer vision (ECCV) workshops. 2018.

[6] ZHENG T, ODA H, ODA M, et al. Micro CT Image-Assisted Cross Modality Super-Resolution of Clinical CT Images Utilizing Synthesized Training Dataset [J]. arXiv preprint arXiv: 2010.10207, 2020.

[7] GOODFELLOW I, POUGET - ABADIE J, MIRZA M, et al. Generative adversarial nets [J]. Advances in neural information processing systems, 2014, 27.

[8] LI C, WAND M. Combining markov random fields and convolutional neural networks for image synthesis [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016; 2479-2486.

[9] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2018; 7132-7141.

[10] ROY A G, NAVAB N, WACHINGER C. Concurrent spatial and channel ‘squeeze & excitation’ in fully convolutional networks [C] // International conference on medical image computing and computer-assisted intervention. Springer, Cham, 2018; 421-429.

[11] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module [C] // Proceedings of the European conference on computer vision (ECCV). 2018; 3-19.

[12] LEFKIMMIATIS S. Universal denoising networks: a novel CNN architecture for image denoising [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2018; 3204-3213.




图 7 不同尺度因子重建的 CT 图像对比

Fig. 7 Comparison of CT images reconstructed with different scale factors

3.4 消融实验

为了充分证明 CBAM 和全变分损失 (L_{TV}) 在本文方法中的重要性和效果,在消融实验中将对这两部分进行定量分析。通过在退化学习数据集进行 4 组尺度因子为 4 的对比实验,结果见表 4。通过比较第 1 组和第 4 组实验,本文网络模型通过结合 CBAM 和 L_{TV} 使得 PSNR 和 SSIM 分别提升了 0.62 dB 和 0.025 8, LPIPS 降低了 0.024 8。说明将 CBAM 和 L_{TV} 加入到本文的网络模型中,对医学图像的超分辨率重建是有效的。

表 4 对 CBAM 和 L_{TV} 进行消融实验的结果对比

Tab. 4 The results of ablation experiments were compared between CBAM and L_{TV}

	CBAM	L_{TV}	PSNR (dB)	SSIM	LPIPS
1	×	×	28.36	0.838 4	0.219 0
2	×	√	28.48	0.863 8	0.204 7
3	√	×	28.55	0.863 1	0.199 0
4	√	√	28.98	0.864 2	0.194 2

4 结束语

本文提出了一种用于医学图像超分辨率重建的深度学习方法,主要通过改进的 SRGAN 模型中的残差特征提取模块,并将其和混合注意力机制 CBAM 相结合,提出具有通道和空间注意力的残差特征提取模块。使用该模块构建 GAN 的生成器在对人体胸部 CT 图像进行超分辨率重建可以取得较好的效果。此外,通过退化学习模拟低分辨率数据,解决传统退化模型的局限性。通过将几种常用的超