

## 基于语义注意力的医学图像超分辨率方法

林毅, 周芃, 陈彦明

引用本文

林毅, 周芃, 陈彦明. [基于语义注意力的医学图像超分辨率方法](#)[J]. 计算机科学, 2023, 50(11A): 221200107-6.

LIN Yi,ZHOU Peng, CHEN Yanming. [Medical Image Super-resolution Method Based on Semantic Attention](#) [J]. Computer Science, 2023, 50(11A): 221200107-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [基于边缘引导的多尺度医学影像分割方法](#)

Medical Image Segmentation Based on Multi-scale Edge Guidance

计算机科学, 2023, 50(11A): 220900059-7. <https://doi.org/10.11896/jsjcx.220900059>

### [一种基于因果推理的垃圾分类方法](#)

Novel Method for Trash Classification Based on Causal Inference

计算机科学, 2023, 50(11A): 220800218-6. <https://doi.org/10.11896/jsjcx.220800218>

### [接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

### [基于LSTM神经网络的QPSK智能接收机设计](#)

Design of QPSK Intelligent Receiver Based on LSTM Neural Network

计算机科学, 2023, 50(11A): 230200219-5. <https://doi.org/10.11896/jsjcx.230200219>

### [一种噪声容忍的网络流量分类方法](#)

Noise Tolerant Algorithm for Network Traffic Classification Method

计算机科学, 2023, 50(11A): 220800120-7. <https://doi.org/10.11896/jsjcx.220800120>

# 基于语义注意力的医学图像超分辨率方法

林毅 周芃 陈彦明

安徽大学计算机科学与技术学院安徽省医疗成像先进技术国际联合研究中心 合肥 230601

(e20201049@stu.ahu.edu.cn)

**摘要** 在医学图像领域,清晰的医学图像能够帮助医生更好地诊断疾病。然而,由于受到成像设备的限制,生成的医学图像往往分辨率较低并可能影响后期诊断。因此,使用超分辨率方法提高图像的分辨率显得尤为重要。近些年来,随着深度学习的发展,基于深度学习的自然图像超分辨率方法被广泛研究,并取得了一定效果。然而,不同于自然图像超分辨率,医学图像超分辨率往往是下游医学任务服务。许多下游医学任务,例如疾病诊断、语义分割等等,往往会对某些区域感兴趣。但是传统图像超分辨率方法往往平等地对待图像中所有区域,没有考虑到感兴趣区域对于下游医学任务的重要性。针对此问题,提出了一种基于语义注意力的医学图像超分辨率方法。该注意力机制通过加权方式对图像中感兴趣区域进行额外关注,从而使得超分辨率图像更有助于下游医学任务。该方法在新冠肺炎数据集 COVID\_19 和胃肠息肉数据集 Kvasir-SEG 上都取得了领先于其他主流超分辨率方法的效果。

**关键词:** 医学图像;超分辨率;深度学习;感兴趣区域;语义注意力

中图分类号 TP391

## Medical Image Super-resolution Method Based on Semantic Attention

LIN Yi, ZHOU Peng and CHEN Yanming

Anhui Provincial Medical Imaging Advanced Technology National Joint Research Center, School of Computer Science and Technology, Anhui University, Hefei 230601, China

**Abstract** In the field of medical images processing, clear medical images can help doctors to diagnose diseases better. However, due to the limitations of imaging equipment, the generated medical images are often of low resolution and thus may be inappropriate for diagnosis. Therefore, it is very important to use super-resolution method to improve the image resolution. In recent years, with the development of deep learning, natural image super-resolution methods based on deep learning have been widely studied and achieved promising performance. However, unlike natural image super-resolution, medical image super-resolution often serves downstream medical tasks. The downstream medical tasks, such as disease diagnosis and semantic segmentation, tend to be of interest to certain regions. However, traditional image super-resolution methods often tend to treat all regions in the image equally, without considering the importance of the regions of interest for downstream medical tasks. To tackle this problem, this paper proposes a medical image super-resolution method based on semantic attention. The semantic attention module pays extra attention to the regions of interest in the image by weighting, so that the super-resolution image is more helpful for downstream medical tasks. Experimental results show that the proposed method outperforms other mainstream super-resolution methods on COVID-19 dataset and gastrointestinal polyps dataset Kvasir-SEG.

**Keywords** Medical image, Super-resolution, Deep learning, Region of interest, Semantic attention

## 1 引言

随着数字时代的到来,图像作为主要的传播媒介,已被广泛应用于遥感和医学等领域。尤其是在医学领域,一张高清的医学图像,能够帮助医生更好地诊断疾病。常见的医学图像成像方法有计算机断层扫描(Computed Tomography, CT)、磁共振成像(Magnetic Resonance Imaging, MRI)和正电子发射断层扫描(Positron Emission Computed Tomography, PET)等。由于硬件设备限制或成像方法等因素,实际采集到

的医学图像往往分辨率较低。例如,CT图像通过发射高能电磁射线完成扫描,需要长时间扫描才能获得高分辨率图像,并且会对人体产生辐射伤害,因此在实际操作中,往往会减少扫描时间,从而造成分辨率低下<sup>[1]</sup>。MRI使用强磁场和射频脉冲进行扫描,不会产生辐射,但是需要长时间扫描且人体需保持静止状态,否则会产生伪影<sup>[2]</sup>。为克服此问题,图像超分辨率通常被应用于医学图像处理。图像超分辨率指的是通过算法将低分辨率图像转化为高分辨率图像,能够以较低的成本提升图像的分辨率,并且不会对人体造成伤害。

基金项目:国家自然科学基金(62176001,61806003);安徽省高校优秀青年科研项目(2023AH030004)

This work was supported by the National Natural Science Foundation of China(62176001,61806003) and Natural Science Project of Anhui Provincial Education Department(2023AH030004).

通信作者:周芃(zhoupeng@ahu.edu.cn)

近些年来,随着深度学习的发展,在自然图像处理领域,出现了许多基于深度学习的图像超分辨率方法。例如,2014年,Dong等<sup>[3]</sup>使用1个三层卷积神经网络实现图像超分辨率,随后便出现了很多基于卷积神经网络(Convolutional Neural Network, CNN)的图像超分辨率方法。Kim等<sup>[4]</sup>首次提出用深度残差网络解决图像超分辨率问题,有效地防止了梯度消失和梯度爆炸等问题。2016年,Ledig等<sup>[5]</sup>提出用生成对抗网络(Generative Adversarial Network, GAN)进行图像超分辨率处理,能够恢复出图像更加逼真的纹理细节,并生成更加符合人眼感知的高清图像。此外,也有学者将注意力机制运用到图像的超分辨率中。例如,Zhang等<sup>[6]</sup>将通道注意力引入到图像超分辨率中,加强了通道之间的相关性,同时使用残差中的残差结构,跳过网络中的低频信息,更好地恢复出了图像中的高频细节。近些年来,Transformer<sup>[7]</sup>在自然语言处理领域取得了较好的效果,同样有许多工作将Transformer运用到计算机视觉领域,如Liang等<sup>[8]</sup>将Transformer应用到图像超分辨率任务中,增强了像素之间的相关性,通过较少的参数量,取得了领先于其他主流算法的效果。

这些方法虽然在自然图像领域取得了不错的效果,但是医学图像超分辨率不同于自然图像,其往往是下游医学任务(例如医学图像分割和疾病诊断等)服务。这些下游医学任务往往只对图像的某个区域特别感兴趣。例如,在新冠肺炎的诊断中,得到肺部CT图像(如图1(a)所示)后,医生往往只关注肺部区域情况,即图1(b)黄色区域,而不关心其他脏器和骨骼区域。在医学图像处理中,我们称这些区域为感兴趣区域(Regions of Interest, ROI)。因此,医学图像超分辨率也应关注这些感兴趣区域。然而,传统图像超分辨率方法往往平等地对待图像中所有区域,没有对这些感兴趣区域进行特别关注,因此,超分辨率的图像未必会有助于下游医学任务。



(a) 肺部 CT 图像



(b) 语义分割图像

图1 感兴趣区域示例

Fig. 1 Example of regions of interest

针对此问题,本文设计了一种基于语义注意力的医学图像超分辨率网络,该网络能够更加关注感兴趣区域。总的来说,本文提出的网络包括两个模块,即超分辨率模块(Super Resolution Module, SRM)和语义注意力模块(Semantic Attention Module, SAM)。超分辨率模块由多个残差块和上采样部分组成,每个残差块由多个残差通道注意力块组成,考虑通道间的相互依赖性自适应的调整特征,通过多个跳跃连接

使得网络越过大量的低频信息,使得网络更好地捕获图像中的高频细节,从而提高图像超分辨率的效果。语义注意力模块利用U-net<sup>[9]</sup>网络提取图像中的语义信息,得到图像的语义分割图,然后把语义分割图当作权重对特征图进行加权,使网络更加关注感兴趣区域的超分辨率,从而更好地为下游医学任务服务。

## 2 相关工作

### 2.1 自然图像超分辨率

自然图像超分辨率方法通常分为传统超分辨率方法和基于深度学习的超分辨率方法。传统超分辨率方法主要有基于插值的方法,目前主流的是基于深度学习的超分辨率方法,其又主要分为基于卷积神经网络的方法、基于生成对抗网络的方法和基于Transformer的方法。近些年来,随着深度学习的快速发展,其已经逐渐优于传统方法。

基于卷积神经网络的超分辨率方法由Dong等<sup>[3]</sup>于2014年首次提出,通过三层卷积神经网络SRCNN(Super-Resolution Convolutional Neural Network)实现图像超分辨率。Kim等<sup>[4]</sup>提出的VDSR(Deep Convolution for Super Resolution)首次将残差网络用于图像超分辨率,有效地防止了梯度消失和梯度爆炸的问题。Ledig等<sup>[5]</sup>提出的SRResnet(Super-Resolution Residual Network),改进了残差结构。Lim等<sup>[10]</sup>提出了EDSR(Enhanced Deep Residual Network for Super Resolution),去掉了SRResnet中残差块中的BN层,提高了模型的表达能力。Zhang等<sup>[6]</sup>提出了RCAN(Residual Channel Attention Network),通过残差中的残差结构跳过图像中的低频信息,同时使用通道注意力机制自适应调整通道间的关系。Dai等<sup>[11]</sup>提出的SAN(Second-order Attention Network)使用二阶注意力机制进行相关性学习,通过非局部增强残差组来捕获长距离空间内容信息。Niu等<sup>[12]</sup>提出了一个整体注意力网络(Holistic Attention Network, HAN),通过层次注意模块和通道-空间注意模块来模拟不同层、通道和位置之间的整体关系,获得更好的超分辨率效果。Mei等<sup>[13]</sup>提出了具有动态稀疏注意模式的非局部稀疏注意力(Non-local Sparse Attention, NLSA),NLSA既保留了非局部运算的远程建模能力,又具有鲁棒性和高效的稀疏表示。

基于卷积神经网络的图像超分辨率方法虽然在峰值信噪比(Peak Signal to Noise Ratio, PSNR)和结构相似性(Structural Similarity, SSIM)指标上取得了较好的效果,但是生成的图像往往过于平滑,不符合人眼视觉感知。于是基于生成对抗网络的超分辨率方法应运而生。Ledig等<sup>[5]</sup>提出了SRGAN,通过应用GAN,生成了更加接近真实图像的超分辨率图像。Wang等<sup>[14]</sup>提出ESRGAN(Enhanced SRGAN),使用残差中的残差密集块对SRGAN生成器中的残差块进行改进,同时提出用相对判别器替代传统的判别器,使得生成的图像更加逼真且纹理细节更加丰富。此外,Wang等<sup>[15]</sup>还将一阶退化模型拓展到高阶退化模型,同时将判别器改进为基于U-net的判别器,增强图像细节上的对抗学习,在盲超分领域取得了不错的效果。

2017年,Vaswani等<sup>[7]</sup>提出了Transformer,其在自然语言处理领域取得了较好的效果。目前也有很多工作把

Transformer 用到计算机视觉领域中。Yang 等<sup>[16]</sup>提出了 TTSR(Texture Transformer Super Resolution),将 Transformer 作为一种注意力机制,更好地将参考图像的纹理信息转移到高分辨率图像中。Liang 等<sup>[8]</sup>提出了 SWINIR(Image Restoration Using Swin Transformer),将 Transformer 引入到图像超分辨率中,仅仅使用了 1/3 的参数,就超过了其他主流的基于卷积神经网络的算法。

## 2.2 医学图像超分辨率

Yu 等<sup>[17]</sup>基于卷积神经网络和残差学习,提出单一 CT 图像超分辨率网络(Single-slice CT SR Networks,S-CTSRN)和多 CT 图像超分辨率网络(Multi-slice CT SR Network,M-CTSRN),S-CTSRN 引入残差学习,改进了高频特征的提取,M-CTSRN 进一步利用相邻 CT 图像之间的相关性,实现了更好的重建效果。Du 等<sup>[18]</sup>在超分辨率过程中充分利用梯度先验来提供高频细节信息,生成更精确的 MRI 图像。You 等<sup>[19]</sup>提出了一种半监督深度学习方法,以生成对抗网络为构建块,通过 Wasserstein 距离来加强周期一致性,

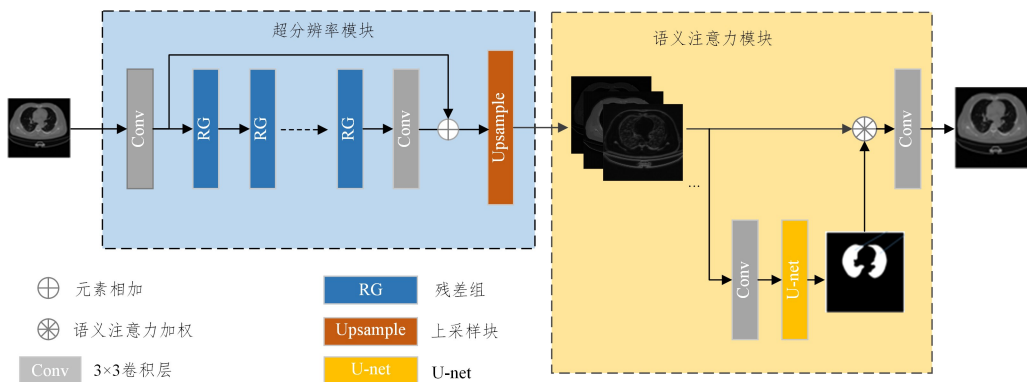


图 2 总体网络结构

Fig. 2 Overall network structure

其中,超分辨率模块通过通道注意力自适应地调节通道之间的关系,同时使用跳跃连接使网络越过图像中的低频信息网络,从而更好地提取图像中的高频细节,提升图像超分辨率效果。语义注意力模块中采用 U-Net<sup>[9]</sup>提取图像中的语义信息,分割出感兴趣区域,并利用提取到的语义信息对上采样后得到的特征图进行加权,使网络更加关注感兴趣区域的超分辨,从而使得超分辨率图像更有利于下游医学任务。

## 3.2 超分辨率模块

超分辨率模块主要由多个残差组(Residual Group, RG)和上采样块组成。每个残差组(如图 3 所示)包含若干个残差通道注意力块(Residual Channel Attention Block, RCAB)。

残差组最早由 Zhang 等<sup>[6]</sup>于 2018 年提出,通过考虑通道之间的相互依赖性,自适应地重新缩放通道特征,以改变不同通道特征对重建图像的影响权重;同时使用了跳跃连接越过图像中的低频信息,使得网络更好地恢复出图像中的高频信息,从而提高超分辨率效果。

上采样部分通过亚像素卷积提高特征图的分辨率,用于后续超分辨率重建。相比于反卷积,使用亚像素卷积能够避免在特征图在放大过程中引入过多的人工因素<sup>[21-22]</sup>。

建立了一个从噪声低分辨率图像到去噪高分辨率图像的非线性端到端映射,提高了 CT 图像的超分辨率效果。Wang 等<sup>[20]</sup>将超分辨率和疾病诊断相结合,提出了一种诊断导向的注意力机制,大大提高了医学图像中对医生诊断疾病有利的区域的超分辨率效果。

以往的超分辨率平等地对待图像中的各个区域,没有考虑到感兴趣区域对于疾病诊断等下游医学任务的重要性。针对此问题,本文设计了一种基于语义注意力的医学图像超分辨率网络,可以更加关注感兴趣区域的超分辨率。

## 3 本文方法

### 3.1 网络结构

本文提出的基于语义注意力的医学图像超分辨率方法主要包括超分辨率模块(Super Resolution Module, SRM)和语义注意力模块(Semantic Attention Module, SAM)两个部分,整体网络结构如图 2 所示。

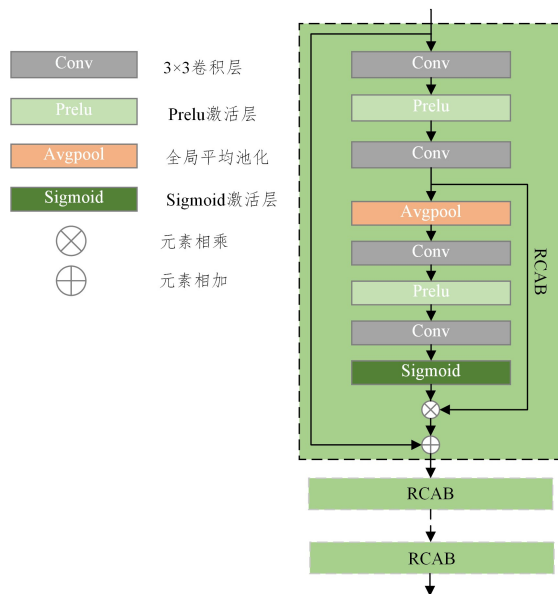


图 3 残差组

Fig. 3 Residual group

### 3.3 语义注意力模块

为了使网络更加关注感兴趣区域的超分辨率,本文提出了语义注意力模块,网络结构如图 4 所示。语义注意力

模块首先通过一个  $3 \times 3$  的卷积层,将通道数压缩为 1,然后通过 U-Net<sup>[9]</sup> 获得特征图对应的语义注意力权重。U-Net 采用编码-解码结构,左边网络为编码网络,使用卷积层和池化层提取图像的特征;右边网络为解码结构,通过

反卷积实现上采样,将低级特征和上采样特征进行连接,保证了最后恢复出来的特征图融合了更多的低级特征,同时也使得不同尺寸的特征得到融合,从而获得更好的分割效果。

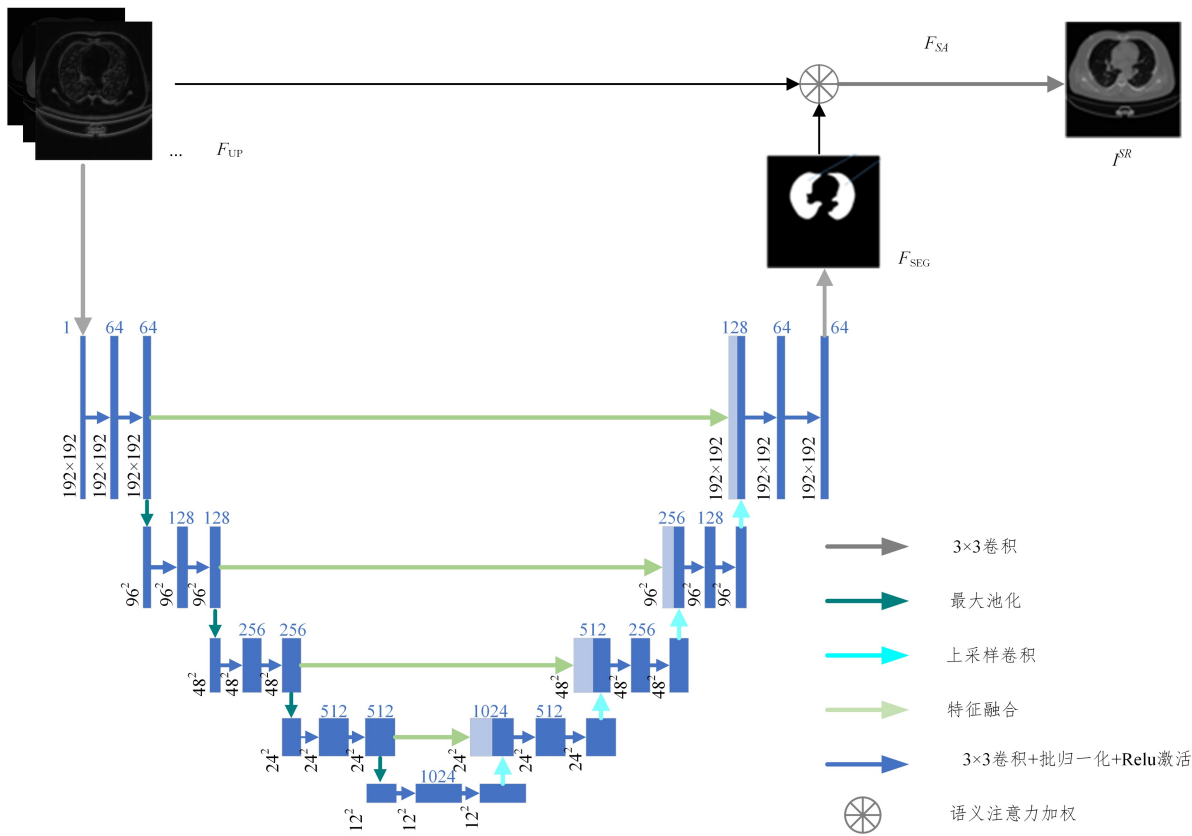


图 4 语义注意力模块

Fig. 4 Semantic attention module

本文提出的语义注意力机制,将通过 U-Net 网络提取到的语义注意力权重对上采样后的特征图进行加权,使得网络更加关注感兴趣区域的超分辨率。

$$F_{SA} = F_{UP} + \alpha F_{UP} * F_{SEG} \quad (1)$$

其中,  $F_{UP}$  表示经上采样块后得到的特征图,  $F_{SEG}$  表示经过 U-Net 提取到的语义注意力权重,  $\alpha$  为超参数。在语义注意力加权中,为了使网络尽可能保留上采样特征图的信息,本文采用  $\alpha$  来调节语义分割图对上采样特征图的加权程度。将加权结果作为残差来调节上采样特征图,使得经过语义特征加权后的特征图中拥有更多的语义信息。紧接着,将  $F_{SA}$  通过  $3 \times 3$  的卷积层重建出最终的超分辨率图像。

### 3.4 损失函数

本文提出方法的损失函数主要包括两个部分:超分辨率损失和语义分割损失。超分辨率损失如式(2)所示:

$$L_{SR} = \frac{1}{n} \sum_{i=1}^n \| I_i^{SR} - I_i^{HR} \|_1 \quad (2)$$

其中,  $L_{SR}$  表示超分辨率损失,  $I_i^{HR}$  表示第  $i$  幅图片的真实超分辨率图像,  $I_i^{SR}$  表示其超分辨率图像,  $\| * \|_1$  表示 L1 范数,  $n$  表示训练集中图片的数量。

语义分割损失如式(3)所示:

$$L_{SEG} = \frac{1}{n} \sum_{i=1}^n \| I_i^{RES} - I_i^{SEG} \|_1 \quad (3)$$

其中,  $L_{SEG}$  表示语义分割损失,  $I_i^{RES}$  表示第  $i$  幅图像通过网络得到的语义分割图像,  $I_i^{SEG}$  为真实的语义分割图像。

总体损失  $L_{total}$  如式(4)所示:

$$L_{total} = L_{SR} + \beta L_{SEG} \quad (4)$$

其中,  $\beta$  为超参数。

## 4 实验结果及分析

为了验证提出方法的有效性,在新冠肺炎数据集 COVID-19 和胃肠息肉数据集 Kvasir-SEG 上将其与其他主流算法进行对比实验。

### 4.1 数据集

本文提出的基于语义注意力的医学图像超分辨率算法和其他对比算法在新冠肺炎数据集 COVID-19<sup>1)</sup> 和胃肠息肉数据集 Kvasir-SEG<sup>2)</sup> 上进行实验。COVID-19 包含 20 张 3D 的 CT 扫描图像及其对应的分割图像,本文将这 20 张 3D 图像随机划分为训练集、验证集和测试集 3 个部分,其中训练集包括 16 张 3D 图像,验证集包括 2 张 3D 图像,测试集包括 2 张 3D 图像。本文将这些 3D 图像沿  $z$  轴方向按间隔 3 个单位切分为 2D 图像,切分过后,训练集包括 945 张

<sup>1)</sup> <https://aistudio.baidu.com/aistudio/datasetdetail/34221>

<sup>2)</sup> <https://datasets.simula.no/kvasir-seg/>

2D 图像,验证集包括 132 张 2D 图像,测试集包括 101 张 2D 图像。

Kvasir-SEG 包含 1000 张胃肠息肉 2D 图像和其对应的分割图像。本文将 Kvasir-SEG 随机划分为训练集、验证集和测试集,其中,训练集包括 800 张 2D 图像,验证集包括 100 张 2D 图像,测试集包括 100 张 2D 图像。

## 4.2 实验设置

由于缺少成对图像,本文采用和现在主流方法<sup>[3-6]</sup>同样的方法,由高清图像通过双三次下采样获取低清图像用于网络训练。实验在 Window10 系统下进行,使用的 GPU 型号为英伟达 GeForce RTX 3090 Ti,使用的 CPU 型号为英特尔酷睿 i5-12700k。训练过程中,将图像随机裁剪为  $48 \times 48$  大小,按批次进行训练,批次大小为 8,使用 Adam 优化器进行迭代优化,一阶矩估计的指数衰减率  $\beta_1 = 0.9$ ,二阶矩估计指数衰减率  $\beta_2 = 0.999$ ,学习率设置为  $10^{-4}$ ,迭代 20 000 次。本文方法

中的超分辨率模块中,残差组的个数为 10,每个残差组中残差通道注意力块的个数为 20。在 COVID\_19 上的超参数  $\alpha = 1, \beta = 0.005$ ,在 Kvasir-SEG 上超参数  $\alpha = 0.1, \beta = 0.01$ 。

## 4.3 实验结果

将本文提出的方法与现在主流超分辨率方法进行对比,在 COVID\_19 和 Kvasir\_SEG 上的客观评价指标 (PSNR/SSIM) 结果如表 1 所列。可以看到,本文方法在 COVID\_19 上相较于其他主流算法的最好结果,在  $\times 2$  放大倍数下 PSNR 和 SSIM 分别提升了 0.6 db 和 0.0016,在  $\times 4$  放大倍数下 PSNR 和 SSIM 分别提升了 0.35 db 和 0.0029;在 Kvasir\_SEG 上,相较于其他主流算法的最好结果,在  $\times 2$  放大倍数下 PSNR 和 SSIM 分别提升了 0.39 db 和 0.0013,在  $\times 4$  放大倍数下 PSNR 和 SSIM 分别提升了 0.48 db 和 0.0023。由此可见,本文提出的方法在  $\times 2$  和  $\times 4$  的放大倍数下都超越了其他主流方法,达到了最好的效果。

表 1 COVID\_19 和 Kvasir\_SEG 上的客观评价指标 (PSNR/SSIM)

Table 1 Objective evaluation indicators on COVID\_19 and Kvasir\_SEG (PSNR/SSIM)

Datasets	scale	Bicubic	SRRESNET <sup>[5]</sup>	EDSR <sup>[10]</sup>	RCAN <sup>[6]</sup>	SAN <sup>[11]</sup>	HAN <sup>[12]</sup>	NLSA <sup>[13]</sup>	SWINIR <sup>[8]</sup>	Ours
COVID_19	$\times 4$	28.99/ 0.8521	32.91/ 0.8915	36.06/ 0.9101	35.80/ 0.9121	35.92/ 0.9209	35.88/ 0.9244	35.38/ 0.9235	35.85/ 0.9185	36.41/ 0.9273
	$\times 2$	35.70/ 0.9503	39.92/ 0.9595	41.37/ 0.9689	41.29/ 0.9622	41.55/ 0.9649	41.37/ 0.9657	41.43/ 0.9651	41.40/ 0.9632	42.15/ 0.9705
Kvasir_SEG	$\times 4$	28.89/ 0.8615	30.97/ 0.8991	32.77/ 0.9217	33.16/ 0.9289	33.28/ 0.9303	33.43/ 0.9322	32.45/ 0.9272	32.69/ 0.9291	33.91/ 0.9345
	$\times 2$	35.26/ 0.9695	36.46/ 0.9703	39.77/ 0.9794	40.03/ 0.9782	40.29/ 0.9803	40.36/ 0.9795	39.47/ 0.9797	39.66/ 0.9790	40.75/ 0.9816

需要注意的是,相比于 RCAN<sup>[6]</sup>,本文方法在 COVID\_19 数据集  $\times 4$  放大倍数下 PSNR 和 SSIM 分别提升了 0.61 db 和 0.0172,  $\times 2$  放大倍数下,PSNR 和 SSIM 分别提升了 0.86 db 和 0.0088;在 Kvasir\_SEG 数据集  $\times 4$  放大倍数下 PSNR 和 SSIM 分别提升了 0.75 db 和 0.0056,在  $\times 2$  放大倍数下 PSNR 和 SSIM 分别提升了 0.72 db 和 0.0034。由此

可见,本文提出的方法在客观评价指标方面超过了 RCAN,从客观评价指标方面验证了本文提出的语义注意力模块的有效性。

COVID\_19 数据集  $\times 4$  放大倍数下的局部放大示例图如图 5 所示。相比于 RCAN,在感兴趣区域,PSNR 和 SSIM 分别提升了 1.8 db 和 0.0469。




图 5 COVID\_19 数据集  $\times 4$  放大倍数下的局部放大示例图 (PSNR/SSIM)

Fig. 5 Local zooming example of COVID\_19 dataset at  $\times 4$  magnification factor (PSNR/SSIM)




图 6 Kvasir\_SEG 数据集  $\times 4$  放大倍数下的局部放大示例图 (PSNR/SSIM)

Fig. 6 Local zooming example of Kvasir\_SEG dataset at  $\times 4$  magnification factor (PSNR/SSIM)

Kavdir\_SEG 数据集 $\times 4$  放大倍数下的局部放大示例图 6 所示。相比于 RCAN, 在感兴趣区域, PSNR 和 SSIM 分别提升了 1.95 db 和 0.021 1, 且均领先于其他方法。从示例图可以看出, 基于插值的方法 Nearest, Bicubic 重建的超分辨率图像比较模糊, 质量较差。本文方法相比于其他主流方法方法, 在感兴趣区域具有更好的视觉感知效果, 在边缘部分更加清晰。

**结束语** 本文提出了一种基于语义注意力的医学图像超分辨率方法, 该方法通过语义注意力对图像中不同区域进行加权, 使得网络更加关注感兴趣区域, 从而生成更加有利于下游医学任务的超分辨率图像。实验表明, 该方法在 COVID\_19 数据集和 Kavdir\_SEG 数据集上取得了较好的超分辨率效果。

在医学图像中, 获取医学图像所对应的分割图像比较困难, 往往需要专业的医生对图像进行像素级标注, 这大大地加大了工作量。在未来的研究中, 我们将尝试使用无监督或者弱监督的方法来设计语义注意力模块, 在保持分割和超分辨率效果的前提下, 尽可能降低医生标注的工作量。

### 参考文献

- [1] ZHU H, HAN G, PENG Y, et al. Functional-Realistic CT Image Super Resolution for Early-Stage Pulmonary Nodule Detection[J]. Future Generation Computer Systems, 2021, 115: 475-485.
- [2] FAN F, GAO Y, QIN P L, et al. Abdominal MRI Image Multi-Scale-Super-Resolution Reconstruction Based on Parallel Channel-Spatial Attention Mech-anism[J]. Journal of Computer Applications, 2020, 40(12): 3624-3630.
- [3] DONG C, LOY C C, HE K M, et al. Learning a Deep Convolutional Network for Image Super-Resolution[C]// European Conference on Computer Vision. Germany: Springer, 2014: 184-199.
- [4] KIM J, LEE J K, MU LEE K M. Accurate Image Super-Resolution Using Very Deep Convolutional Networks[C]// IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2016: 16 46-1654.
- [5] 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. USA: IEEE, 2017: 105-114.
- [6] 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. USA: IEEE, 2018: 286-301.
- [7] VASWANI A, NOAM S, PARMAR N, et al. Attention is All You Need[C]// Annual Conference on Neural Information Processing Systems. USA: NIPS, 2017: 5998-6008.
- [8] LIANG J Y, GAO J Z, SUN G L, et al. SwinIR: Image Restoration Using Swin Transformer[C]// IEEE International Conference on Computer Vision Workshops. USA: IEEE, 2021: 1833-1844.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]// International Conference on Medical Image Computing and Computer Assisted Intervention. Germany: Springer, 2015: 234-241.
- [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. USA: IEEE, 2017: 1132-1140.
- [11] DAI T, CAI J R, ZHANG Y B, et al. Second-Order Attention Network for Single Image Super-Resolution[C]// IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2019: 11065-11074.
- [12] NIU V, WEN W L, REN W Q, et al. Single Image Super-Resolution via a Holistic Attention Network[C]// European Conference on Computer Vision. Berlin: Springer, 2020: 191-207.
- [13] MEI Y Q, FAN Y C, ZHOU Y Q. Image Super-Resolution With No-Local Sparse Attention[C]// IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2021: 3517-3526.
- [14] WANG X T, YU K, WU S X, et al. Esrgan: Enhanced Super-Resolution Generative Adversarial Networks [C]// European Conference on Computer Vision Workshops. Germany: Springer, 2018: 701-710.
- [15] WANG X T, XIE L B, DONG C. Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic Data[C]// IEEE International Conference on Computer Vision Workshops. USA: IEEE, 2021: 1905-1914.
- [16] YANG F Z, YANG H, FU J L, et al. Learning Texture Transformer Network for Image Super-Resolution[C]// IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2020: 5790-5799.
- [17] YU H C, LIU D, SHI H H, et al. Computed Tomography Super-Resolution Using Convolutional Neural Networks[C]// IEEE International Conference on Image Processing. USA: IEEE, 2017: 3944-3948.
- [18] DU X F, HE Y F. Gradient-Guided Convolutional Neural Network for MRI Image Super-Resolution [J]. Applied Sciences, 2019, 9(22): 4874.
- [19] YOU C Y, LI G, ZHANG Y, et al. CT Super-Resolution GAN Constrained by the Identical, Residual, and Cycle Learning Ensemble(GAN-CIRCLE)[J]. IEEE Transactions on Medical Imaging, 2020, 39(1): 188-203.
- [20] WANG J W, ZHOU P, HAN X J, et al. Medical Image Super-Resolution via Diagnosis-Guided Attention[C]// International Conference on Multimedia and Expo. USA: IEEE, 2023: 1-6.
- [21] DAI Z X, LI J X, ZHANG X D, et al. Super-Resolution Reconstruction of MRI Based on DNGAN [J]. Computer Science, 2022, 49(7): 113-119.
- [22] SHI W Z, CABALLERO J, HUSZAR F, et al. Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network[C]// IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2016: 1874-1883.



**LIN Yi**, born in 1996, postgraduate. His main research interests include medical image processing and so on.



**ZHOU Peng**, born in 1989, Ph. D, is a member of China Computer Federation. His main research interests include machine learning and data mining.