doi:10.3772/j.issn.1002-0470.2023.07.004

基于生成对抗网络的 CT 图像无监督超分辨率分析 $^{ m O}$

李云鹤②* 陈伦强③* 赵慧岩** 吴绍华***

(*肇庆学院电子与电气工程学院 肇庆 526061)
 (**东北石油大学电气信息工程学院 大庆 163319)
 (*** 哈尔滨工业大学(深圳)电子与信息工程学院 深圳 518055)

摘要 提高计算机断层成像(CT)医疗影像的分辨率有助于医生更精确地识别病变部位,具有重要临床诊断意义。本文研究在没有高-低分辨率图像对数据的条件下,使用仅包含低分辨率图像的数据集,通过降质网络和注入噪声获得与真实图像同域的低分辨率图像,进而构造接近天然图像对的训练数据集。并且设计了包括超分辨生成器、超分辨鉴别器和超分辨特征提取器的超分辨率生成对抗网络(DeSRGAN),实现对 CT 影像 4 倍超分辨率分析。实验测试表明,超分辨率分析生成的 4 倍 CT 图像在 NIQE、BRISQUE 和 PIQE 等无参考图像质量评估指标的定量对比中,DeSRGAN 方法均优于最新的单图像超分辨率的增强型深度残差网络(EDSR)、残差信道注意力网络(RCAN)、增强型超分辨率生成对抗性网络(ESRGAN)等方法生成的图像。同时在直观视觉效果上,DeSRGAN 方法生成的图像具有更清晰细节和更好感知效果。

关键词 超分辨率分析;计算机断层成像(CT);生成对抗网络(GAN);深度学习

0 引言

计算机断层成像(computed tomography, CT)技 术是目前被广泛应用的临床诊断技术,能够非接触、 无创口地获取患者体内结构信息,是评估患者身体 情况的重要资料^[1]。高分辨率(high resolution, HR)的医疗影像细节信息更加丰富,可以使医生更 精确地识别病变部位,因此它的清晰度直接影响医 生对患者诊断的准确度。CT 成像系统受到 X 射线 焦点尺寸、探测器像元尺寸、图像重建等软、硬件因 素的制约,成像分辨率往往低于临床病理早期筛查 所需的理想分辨率^[2]。CT 成像设备一般都比较昂 贵,硬件系统复杂,通过硬件系统升级提升成像分辨 率成本较高。考虑到 CT 扫描过程中 X 射线对患者 有辐射,常常采用低剂量 CT 扫描以减少对人体的 伤害,例如通过改变管电压、管电流、扫描时间等降 低对患者的辐射剂量,但这会导致成像分辨率降 低^[3]。综合考虑诊断的准确性和低剂量辐射的需 求,如何从设备生成的低分辨率 (low resolution, LR)图像重构高分辨率图像的研究具有重要意义。

过去 10 年中,研究人员对高分辨率图像的重构 问题开展了大量工作,尤其是超分辨率分析方面。 文献[4]提出了基于字典学习的有监督超分辨率分 析技术。文献[5,6]提出了基于稀疏感知的超分辨 率分析技术。文献[7]提出了基于压缩感知的超分 辨率分析技术。文献[8,9]提出使用不同空间特征 获取更高性能的超分辨率分析技术。在生成对抗网

① 国家自然科学基金(61871147),广东省普通高校重点领域专项(2020ZDZX3078)和广东省空天通信与网络技术重点实验室 (2018B030322004)资助项目。

② 男,1983年生,博士,副教授;研究方向:图像处理,深度学习,生成对抗网络;E-mail: liyunhe@ zqu. edu. cn。

通信作者, E-mail: yicrane@qq.com。 (收稿日期:2022-05-31)

络(generative adversarial networks, GAN)^[10]被提出 来以后,很快有学者将生成对抗网络用于超分辨率 分析[11],并取得了开创性的成效,进而生成对抗网 络更多开始用于超分辨率分析。文献[12]研究了 超分辨率分析生成对抗网络(super-resolution generative adversarial networks, SR-GAN)的网络体系结 构、对抗性损失和知觉性损失,并对其进行了改进提 出了增强型超分辨率生成对抗性网络(enhanced SRGAN, ESRGAN)。ESRGAN 引入了不进行批标 准化的多致密残差模块,并通过使用激活之前的特 征值来改善感知损失函数,为亮度一致性和纹理恢 复提供更强的监督。相同时期,基于残余通道关注 网络的残差信道注意力网络(residual channel attention networks, RCAN)^[13]和基于加强深度残差网络 的单图像超分辨率的增强型深度残差网络(enhanced deep residual networks for single image superresalution, EDSR)等超分辨生成对抗网络也相继被 提出,并取得了较好的效果。文献[14,15]采用 ES-RGAN 的多致密残差块结构,构建 CT 图像的超分辨 率分析网络,减少了残差单元数量,并在残差块之间 建立了紧密的联系,减少了网络冗余。文献[16,17] 将 EDSR 网络用于 CT 图像超分辨率分析,在较好的 恢复边缘锐度的情况下,只丢失了部分高频细节。 文献[18-20]在CT图像的超分辨率分析中使用了

RCAN 网络的残余通道关注网络结构,使用具有多 个分支的多尺度注意力块,可以自动生成权重来调 整网络,取得了较好的视觉效果。现有典型算法如 ESRGAN、RCAN、EDSR,训练网络所用的高-低分辨 率图像对数据集,是通过已有的图像作为高分辨率 图像,然后通过双三次降采样(BiCubic)^[21]生成特 定倍数的低分辨率图像所生成,会丢失与频率相关 的轨迹细节,导致超分辨率成像过于平滑和模糊。

针对双三次降采样生成图像对的不足,本文首 先考虑接近天然高-低分辨率图像对数据集的构造 问题。本文设计核估计网络对 CT 图像做预处理, 包括学习 CT 图像内部像素块分布、探寻图像特异 性、注入噪声等,用源图像 *I*_{CT} 降质生成低分辨率图 像*I*_{LR};进而构造接近天然图像对的高-低分辨率图 像对(*I*_{HR},*I*_{LR});然后,本文借鉴 ESRGAN^[12]、Patch-GAN^[22]和 VGG-19^[23]等网络的设计思路,构建了包 括超分辨生成器、超分辨鉴别器和超分辨特征提取 器的超分辨率生成对抗网络;最后,利用训练所得生 成对抗网络的生成器处理 CT 图像,以获取 4 倍的 高分辨率 CT 图像。所设计深度学习网络被称为预 降质超分辨率生成对抗网络(predegraded super resolution generative adversarial networks, DeSRGAN), 其结构和操作流程如图 1 所示。



-705 -

1 高-低分辨率图像对数据预处理

1.1 降质模型

自然的高-低分辨率 CT 图像之间的对应关系,可以近似地表示为

$$I_{\rm LR} = (I_{\rm HR} \times DE_{\rm s}) \downarrow_{\rm s} + N_{\rm in} \tag{1}$$

其中, DE_s 和 N_{in} 分别表示降质核和注入噪声, s 表示缩放因子, \downarrow_s 表示下采样。寻求贴切于自然图像对的 DE_s 和 N_{in} 是获取更真实的高-低分辨率图像对的关键步骤,这决定了超分辨率分析所生成图像的质量。

1.2 注入噪声

虽然噪声是注入在降采样后的图像中,由于降 采样会抑制源图像的高频分量,为了让噪声分布更 自然,可从源图像 I_{CT} (即高分辨率图像 I_{HR})中提取 噪声块。在噪声提取过程中,需要关注 2 个参数,即 噪声块的最小均值 m_{min} 和最大方差 d_{max}。这 2 个参 数的设置,没有固定的选择模式,取决于不同应用场 景的图像对的实际情况。本文通过多组测试对比, 并基于测试结果选择合适的噪声提取参数。本文从 训练数据集(SET_{train})随机选取源图像 I_{CT} 提取噪声 图块,提取一定数量的噪声图块去构建噪声块数据 集(SET_{noise}),噪声注入过程通过从 SET_{noise} 数据集 随机选取噪声图块并应用于式(1)来执行。

1.3 核估计降质网络

为了更加贴切于自然图像对,本文使用生成对 抗网络(称之为核估计网络)训练生成式(1)中所用 的降质核 DE_s。因为没有可用于对照和监督的高-低 分辨率图像对数据集(仅有由源图像 I_{cr}构成的训 练数据集 SET_{train}),核估计网络使用无监督的生成 对抗网络训练降质核 DE_s。核估计网络的每一次训 练仅使用一个图片,训练结束后将核估计生成器提 取为1个降质核 DE_s。每次训练所用图片均从训练 数据集 SET_{train}随机选取,经过多次训练生成一定数 量的降质核,放在一起构成降质核数据集(SET_{ker}), 降质过程是通过从 SET_{ker}数据集随机选取降质核 DE_s应用于式(1)来执行的。

核估计网络的处理流程如图 2 所示,随机选取的源图像 *I*_{cr} 输入核估计网络后,一方面源图像 *I*_{cr} — 706 —

经由核估计生成器降采样为 s 倍的图像 I_{de} ,另一方面在源图像 I_{cr} 中随机位置裁切出和 I_{de} 相同大小的图像 I_{cr} 。鉴别器的目标是区分降质图 I_{de} 和裁切图 I_{cr} 的内部像素块在多个尺度上的分布是否一致。核估计网络的目标函数定义为

$$G^*(I_{CT}) = \arg\min_{G} \max_{D} \{E_{\text{patches}}(I_{CT}) [\mid D(ICT) - 1 \mid \\ + \mid D(G(I_{CT})) \mid] + l_{K} \}$$
(3)

其中 G 和 D 表示核估计生成器和核估计鉴别器,其 中 l_k 为损失函数,下标 K 指代核估计降质,可展开 表示为

$$l_{K} = \alpha_{S}l_{S} + \alpha_{M}l_{M} + \alpha_{SQ}l_{SQ} + \alpha_{CE}l_{CE}$$
(4)

$$\dot{\Sigma} \equiv l_{S} l_{M} l_{SQ} l_{CE} \beta \beta l_{E} \Sigma \beta$$

$$l_{\rm s} = |1 - \sum_{i,j} k_{i,j}| \tag{5}$$

$$l_{\rm M} = \sum_{i,j} |k_{i,j} \cdot m_{i,j}| \tag{6}$$

$$l_{\rm SQ} = \sum_{i,j} |k_{i,j}|^{\frac{1}{2}}$$
(7)

$$l_{CE} = \| (x_0, y_0) - \frac{\sum_{i,j} k_{i,j} \cdot (i, j)}{\sum_{i,j} k_{i,j}} \|_2 \quad (8)$$

其中, $k_{i,j}$ 表示降质核中每个节点的参数值; $m_{i,j}$ 是 节点权重的常数掩码, $m_{i,j}$ 随着与 $k_{i,j}$ 中心的距离 的增长呈指数增长; (x_0, y_0) 表示中心的索引。 α_s 、 $\alpha_M \propto \alpha_{sQ} \propto_{CE}$ 为常系数,下标 i, j 为像素的横纵坐标 索引值,对于(256×256)像素的图像而言, i, j 的取 值范围为[1, 256]区间的整数。



图 2 核估计网络处理流程图

本质上,核估计生成器是一个图像降采样模型。 为了能确保快速收敛,同时避免生成物理上无意义 的优化解,生成器网络全部采用线性激活单元,采用 多层线性卷积层结构。核估计生成器的实现结构如 图 3 所示。训练完成后,将生成器网络中的降质功 能层提取出来作为降质核。



图 3 多层线性卷积层组成的核估计生成器网络结构

核估计鉴别器的目标是鉴别生成器输出图像与 源图裁切图像的像素分布是否一致。核估计鉴别器 采用多层非池化卷积层结构,网路结构如图4所示, 同时搭配谱归一化、批归一化以及 ReLU 激活函数。 鉴别器的输出为一个热图,热图中的点代表像素从 原始像素块分布中提取周围的像素块的可能性,鉴 别器的损失函数定义为热图和标签图之间的逐像素 均方误差。



2 超分辨网络

本文采用生成对抗网络实现由低分辨率至4倍的高分辨率图像的超分辨率分析,将该网络称为超分辨网络。通过高-低分辨率图像对数据预处理,得到相对更接近天然的图像对,并以此为数据集训练超分辨网络。超分辨网络采用生成对抗网络结构,与常见的生成对抗网络不同,本文在生成器、鉴别器的基础上增加了特征提取器,以便于引入感知损失函数以增强图像的低频特征的视觉效果。超分辨特征提取器的结构参考 VGG-19 模型,超分辨生成器的结构参考 ESRGAN 模型,超分辨鉴别器参考PatchGAN 模型。

超分辨网络的损失函数由逐像素损失函数 lx^[26]、

感知损失函数 *l*_c 和对抗损失函数 *l*_A 等 3 个分量组成,可表示为

$$l_{\rm SR} = \alpha_{\rm X} l_{\rm X} + \alpha_{\rm C} l_{\rm C} + \alpha_{\rm A} l_{\rm A} \tag{9}$$

其中, α_x 、 α_c 、 α_A 为常系数。逐像素损失函数 l_x 使用 L1 距离, 评估生成图像 $G(I_{LR})$ 与真实图像 I_{HR} 之间的逐像素内容损失:

$$l_{\rm X} = E_{I_{\rm LR}} \| G(I_{\rm LR}) - I_{\rm HR} \|_{1}$$
(10)

感知损失函数 *l*_c 评估图像之间的内容和样式 上的感知差异,感知损失函数 *l*_c 由内容相关的特征 重构损失函数 *l*_F 和样式重构损失函数 *l*_T 组成:

$$l_{\rm C} = \lambda_{\rm F} l_{\rm F} + \lambda_{\rm T} l_{\rm T} \tag{11}$$

$$l_{\rm F} = \frac{1}{C_k H_k W_k} \| \phi_k (G(I_{\rm LR})) - \phi_k (I_{\rm HR}) \|_2^2$$
(12)

$$l_{\rm T} = \| \frac{1}{C_k H_k W_k} \sum_{h=1}^{H_k} \sum_{w=1}^{W_k} [\phi_k(G(I_{\rm LR}))_{h,w,c}]$$

$$\phi_k(G(I_{\rm LR}))_{h,w,c'} - \phi_k(G(I_{\rm HR}))_{h,w,c}$$

$$\phi_k(G(I_{\rm HR}))_{h,w,c'} \| \|_{F}^{2}$$
(13)

其中, λ_{F} 、 λ_{T} 为常系数, $\phi_{k}(I)$ 表示图像 I 输入感知 特征提取器后, 在第 k 层卷积层所得到的特征图。 假设该特征图的形状为 $C_{k} \times H_{k} \times W_{k}$ (通道数 × 高 × 宽), $\|\cdot\|_{F}^{2}$ 表示平方 Frobenius 范数, 式中 h、w、 c 分别代表像素点在特征图中的高、宽、通道数的索 引值, 其取值取决于特征图的形状。对抗损失函数 l_{A} 用于增强生成图像的纹理细节, 使其看起来更逼 真:

$$l_{\rm A} = \sum \left[-D(G(I_{\rm LR})) \right]$$
(16)

参考 ESRGAN 模型, 超分辨生成器采用如图 5 所示的 RRDB (residual-in-residual dense block) 结 构, 在预处理的高-低分辨率图像对数据集上训练 它, 可将 CT 图像最大放大至 4 倍。图 6 中 Conv 表 示卷积层, 搭配 Leacky-ReLU 激活函数, Upsample 表 示 2 倍插值上采样, β 和 θ 为常数系数。

本文发现使用 ESRGAN 处理 CT 图像时有几方 面的不足,包括产生较多的伪影,对局部特征的支持 较弱以及训练所支持的图像尺寸受限。经过分析与 测试,将 ESRGAN 的鉴别器更换为 PatchGAN 的鉴 别器结构可以解决上述问题。参考 PatchGAN 模 型,采用如图7所示结构的超分辨鉴别器。超分辨

— 707 —



图 5 超分辨生成器的结构



图 6 超分辨生成器(SR-GAN-D)的结构



图 7 超分辨特征提取器(SR-GAN-F)的结构

鉴别器中的所有卷积层使用相同的接收域,确保每 一层的输出值仅与局部固定区域的像素块相关,这 样可以强化网络对局部特征的感知。图中 Conv 表 示卷积层,同时搭配批归一化和 Leacky-ReLU 激活 函数。

引入感知损失函数 *l*。可以增强生成图像的低频特征,进而令生成的图像看起来更真实。为此本文 在生成对抗网络中增加超分辨特征提取器。参考 VGG-19模型,超分辨特征提取器的结构如图7所示。 图中 Conv 表示卷积层,同时搭配最大池化操作和 Re-LU 激活函数。

3 实验与结果

本文所提出方法面向 CT 医学图像,使用 QIN LUNG CT^[24]数据集来训练和测试模型,该数据集扫描 来自于接受癌症手术的术前诊断患者,包含 47 个病人 — 708 —

的 3954 张 512 × 512 分辨率图像和基于此构建训练集 (DS_TR)和验证集(DS_VA)的高分辨率图像部分。 QIN LUNG CT 数据集采用由文献[25,26]收集的数据, 为保护患者隐私已删除所有个人识别信息。虽然天然 的图像对的获取非常的困难,难以找到具有足够数量 的图像的训练数据集,但为了可以通过 峰值信噪比 (peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity,SSIM)等指标评价超分辨率分析方法的 优劣,找到了一组具有 60 对(512×512,128×128)高低 分辨率图像对的数据集作为测试集(DS TE)。测试 时将128×128分辨率图像放大4倍,与对应的512× 512 分辨率图像评测 PSNR、SSIM 等指标。另外,本文 更关心的是无高分辨率参照图像的场景,将测试集中 的512×512分辨率图像放大4倍,采用无参考图像质 量评估(IQA)指标来评测生成图像的质量。本文采用 的无参考图像质量评估(IQA)指标包括无参考图像评 价指标(natural image quality evaluator, NIQE),无参考 的空间域图像质量评估算法(blind/reference less image spatial quality evaluator, BRISQUE)和无参考图像质量 评价 (blind image quality evaluation using perception based features, PIQE)。评价值可通过 Matlab 中的相 应函数 niqe、brisque 和 piqe 计算,评价指标采用[0, 100]的正实数,低分值表示高感知质量。

在训练前的数据预处理阶段,对比方法 RCAN、 EDSR、ESRGAN 均通过 BiCubic 方法生成特定倍数的 训练集(DS_TR)和验证集(DS_VA)的低分辨率图 像,DeSRGAN 方法如前文所述通过核估计网络和噪声 注入生成相应的低分辨率图像。对比方法 BiCubic 不 需要训练,可直接插值放大图像,不需要数据预处理操作。

文中所涉及的算法实现的硬件环境包括 Intel i7-6700 CPU,64 GB 内存,和 NVDIA GeForce RTX2080S 显卡。BiCubic 方法通过 Matlab 函数直接插值放大 图像,DeSRGAN、RCAN、EDSR、ESRGAN 方法在 Pytorch 环境下实现,均使用了 github 库中"xinntao/ BasicSR"项目所提供的模块,DeSRGAN 方法还使用 了 github 库中" sefibk/KernelGAN"项目中的的模块。

DeSRGAN 方法中的核估计网络和超分辨网络的网络结构的设定如前文所述,网络中所涉及的卷积层的参数设置如表1所示。表中 in _ channels 代表输入通道数,out _ channels 代表输出通道数,kernel _ size 代表卷积核的尺寸,stride 代表步长,padding 代表输入数据各维度各边上要补齐0的层数。

参数	Conv-1	Conv-2	Conv-3	Conv-4	Conv-5	Conv-6	Conv-7	Conv-8
in _ channels	3	64	64	64	64	64	64	3
out _ channels	64	64	64	64	64	64	1	64
kernel $_$ size	7	5	3	1	1	1	1	7
stride	1	1	1	1	1	1	2	1
padding	0	0	0	0	0	0	0	0
参数	Conv-9	Conv-10	Conv-11	Conv-12	Conv-13	Conv-14	Conv-15	Conv-16
in _ channels	64	64	64	96	128	160	192	64
out _ channels	64	1	32	32	32	32	64	64
kernel $_$ size	1	1	3	3	3	3	3	3
stride	1	1	1	1	1	1	1	1
padding	0	0	0	0	0	0	0	0
参数	Conv-17	Conv-18	Conv-19	Conv-20	Conv-21	Conv-22	Conv-23	Conv-24
in _ channels	64	3	64	128	256	512	3	64
out $_{\rm channels}$	3	64	128	256	512	1	64	64
kernel $_$ size	3	4	4	4	4	4	3	3
stride	1	2	2	2	1	1	1	1
padding	0	0	0	0	0	0	0	0
参数	Conv-25	Conv-26	Conv-27	Conv-28	Conv-29	Conv-30	Conv-31	Conv-32
in _ channels	64	128	128	256	256	512	512	512
out _ channels	128	128	256	256	512	512	512	1
kernel $_$ size	4	4	4	4	4	4	4	4
stride	2	2	1	1	1	1	1	1
padding	0	0	0	0	0	0	0	0

表 1 DeSRGAN 方法中卷积层的参数设置

核估计网络的损失函数的常系数设定为 $\alpha_s = 0.5 \ \alpha_m = 0.5 \ \alpha_{sq} = 5 \ \alpha_{ce} = 1$,生成器和鉴别器采 用相同的 Adam 优化器,参数设定为 $\beta_1 = 0.5 \ \beta_2 = 0.999$,网络迭代训练 3000 代次,学习速率设定为 0.002,并且每750 次迭代缩减 10 倍。超分辨网络 的损失函数的常系数设定为 $\alpha_s = 0.01 \ \alpha_e = 1 \ \alpha_a$ = 0.005,生成器和鉴别器采用相同的 Adam 优化 器,参数设定为 $\beta_1 = 0.9$, $\beta_2 = 0.999$, 网络迭代训 练90000 代次,学习速率设定为0.0001。在图像对 预处理的噪声提取过程中,噪声块的最小均值和最 大方差 2 个参数的设置选用 $m_{min} = 12$ 和 $d_{max} = 96$ 。

RCAN 方法采用文献[18]的设定方案,生成器 采用 Adam 优化器,参数设定为 $\beta_1 = 0.9$ 、 $\beta_2 = 0.99$,网络迭代训练 300 000 代次,学习速率设定为 0.0001;EDSR 方法采用文献[15]的设定方案,生成 器采用 Adam 优化器,参数设定为 $\beta_1 = 0.9$ 、 $\beta_2 =$ 0.99,网络迭代训练 400 000 代次,学习速率设定为 0.0001;ESRGAN 方法采用文献[14]的设定方案, 生成器和鉴别器采用相同的 Adam 优化器,参数设 定为 $\beta_1 = 0.9$ 、 $\beta_2 = 0.99$,网络迭代训练 300 000 代次,学习速率设定为 0.0001。

实际应用中,更多的场景是提升现有的高分辨率的图像的分辨率,超分辨率分析生成的图像不存在对比参照的原图像。因为没有参照的原图像,超分辨率分析生成的图像的质量的评测,需要借助无参考图像质量评估(IQA)指标,例如 NIQE、BRIS-QUE 和 PIQE。除 BiCubic 方法不需要训练,RCAN、EDSR、ESRGAN 和 DeSRGAN 等方法在前述参数设

定条件下,分别训练网络。训练完成后,分别将测试 集(DS_TE)中的512×512分辨率图像超分辨率分 析至2048×2048分辨率图像。表2中记录了各方 法所生成图像的NIQE、BRISQUE和PIQE等指标的 最小值和平均值。图8、9和10给出了所有生成图 的无参考图像质量评估指标的分布情况。

表 2 和图 8~10 中的 NIQE、BRISQUE 和 PIQE 等指标通过 Matlab 软件评测,评估值区间为[0, 100]的正实数,越低的分值表示越高的感知质量。 从表 2 和图 8中的 NIQE 指标的分布情况可以看出, 在空间域自然场景统计模型的统计规律性测量上, DeSRGAN 方法在大部分测试图片的评估中具有最 好的得分,只有少部分测试图的得分近似于 RCAN 和 EDSR 方法。从表 2 和 图 9 中的 BRISQUE 指标

农~ NIQE、DRISQUE 种FIQE 守钼你的取小值种干场	表 2	NIQE, BRISQUE	E 和 PIQE	等指标的最	小值和平均
----------------------------------	-----	---------------	----------	-------	-------

	NIQE _ MIN	NIQE _ MEAN	BRISQUE _ MIN	BRISQUE _ MEAN	PIQE _ MIN	PIQE _ MEAN
BiCubic	6.34	7.54	47.85	49.80	82.87	86.93
EDSR	4.51	5.38	42.58	46.79	76.59	82.30
RCAN	3.40	4.64	41.80	45.77	71.76	78.82
ESRGAN	5.39	7.79	35.54	48.91	32.45	50.54
DeSRGAN	1.39	2.66	34.66	40.03	19.94	23.86













的分布情况可以看出,在局部归一化亮度系数的场 景统计方面,DeSRGAN 方法在评估中几乎全部测试 图都具有最好的得分,ESRGAN 在个别测试图上具 有近似的得分,但 ESRGAN 的分布稳定,在大部分 测试图上的得分差于其他方法。从表 2 和图 10 中 的 PIQE 指标的分布情况可以看出,在局部特征的 图像质量评估方面,BiCubi、EDSR、RCAN 方法得分 情况近似,ESRGAN 方法较优,DeSRGAN 方法得分 最优。综合来看, DeSRGAN 方法在无参考图像质量 评估指标的评测中具有最好的表现。另外, 图 11 给 出了各个方法生成图的视觉对比, 从直观的视觉感 官上可以看出, BiCubi、EDSR、RCAN 方法偏向于模 糊和平滑, ESRGAN 和 DeSRGAN 更清晰的同时也 生成了更多的细节, EDSR、RCAN、ESRGAN 在高光 边缘部分具有较多的毛刺伪影。综合来看, DeSR-GAN 方法在视觉效果上也具有明显优势。



图 11 生成图的视觉直观对比

4 结论

本文面向计算机断层成像技术,研究了从 CT 设备生成的低分辨率图像重构高分辨率图像的方 法。相较于新近提出的 RCAN、EDSR、ESRGAN 等 方法,本文采用不同的高-低分辨率图像对生成办 法,通过降质网络和注入噪声获得与真实图像同域 的低分辨率图像,进而构造接近天然图像对的训练 数据集。本文借鉴 ESRGAN、PatchGAN 和 VGG-19 等深度学习网络的设计思路,构建包括了超分辨生 成器、超分辨鉴别器和超分辨特征提取器的超分辨 率生成对抗网络(DeSRGAN)。本文提出的 DeSR-GAN 方法,通过无参考图像质量评估,在空间域自 然场景统计模型的统计规律性测量、局部归一化亮 度系数的场景统计以及局部特征等方面均优于传统 的 BiCubic 方法和新近提出的 RCAN、EDSR、ESR-GAN 等方法。同时,在直观的视觉对比上, DeSR-GAN方法也具有更清晰的细节和更好感知效果。 所以,本文提出的 DeSRGAN 方法利用现有的高分 辦率 CT 图像数据集,通过自我降质构建训练数据 集完成训练,将高分辨率 CT 图像进一步生成扩大4 倍的图像,更高的清晰度将直接提升医生对患者诊 断的准确度,具有重要的临床意义。

参考文献

- [1] BUZUG T M. Computed tomography [M]. Cham: Springer, 2011:311-42.
- [2] HASSAN A, NAZIR S A, ALKADHI H. Technical challenges of coronary CT angiography: today and tomorrow
 [J]. European Journal of Radiology, 2011,79(2):161-171.
- [3] MARSHALL H M, BOWMAN R V, YANG I A, et al. Screening for lung cancer with low-dose computed tomography: a review of current status[J]. Journal of Thoracic Disease, 2013,5(S5):S524.
- [4] YANG J, WRIGHT J, HUANG T, et al. Image superresolution as sparse representation of raw image patches [C] // Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage: IEEE, 2008:1-8.
- [5] GU S, ZUO W, XIE Q, et al. Convolutional sparse coding for image super-resolution [C] // Proceedings of the IEEE International Conference on Computer Vision. Santiago: IEEE, 2015:1823-1831.
- [6] OSENDORFER C, SOYER H, VAN DER SMAGT P. Image super-resolution with fast approximate convolutional sparse coding[C] // Proceedings of the International Conference on Neural Information Processing. Kuching: Springer, 2014:250-257.
- [7] BABCOCK H P, MOFFITT J R, CAO Y, et al. Fast compressed sensing analysis for super-resolution imaging using *L*1-homotopy[J]. Optics Express, 2013,21(23): 28583-28596.
- [8] ZHANG Y, DU Y, LING F, et al. Example-based superresolution land cover mapping using support vector regression [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7 (4): 1271-1283.
- [9] LI J, YUAN Q, SHEN H, et al. Hyperspectral image super-resolution by spectral mixture analysis and spatialspectral group sparsity[J]. IEEE Geoscience and Remote Sensing Letters, 2016,13(9):1250-1254.

- [10] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [EB/OL]. (2014-06-10)
 [2022-05-15]. https://arxiv.org/pdf/1406.2661.pdf.
- [11] 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. Taibei : IEEE, 2017:105-114.
- [12] WANG X, YU K, WU S, et al. ESRGAN: enhanced super-resolution generative adversarial networks [C] // Proceedings of the European Conference on Computer Vision. Munich: Springer, 2018:66-73.
- [13] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks [C] // Proceedings of the European Conference on Computer Vision. Munich: Springer, 2018:1-16.
- [14] JIANG X, XU Y, WEI P, et al. CT image super resolution based on improved SRGAN[C] // Proceedings of the 5th International Conference on Computer and Communication Systems . Shanghai: IEEE, 2020:363-367.
- [15] 柯舒婷, 陈明惠, 郑泽希, 等. 生成对抗网络对 OCT 视网膜图像的超分辨率重建[J]. 中国激光, 2022,49 (15):1-9.
- [16] DA WANG Y, ARMSTRONG R, MOSTAGHIMI P. Super resolution convolutional neural network models for enhancing resolution of rock micro-ct images [EB/OL]. (2019-04-16) [2022-05-15]. https://arxiv.org/pdf/ 1904.07470.pdf.
- [17] 李俊伯,秦品乐,曾建潮,等.基于超分辨率网络的 CT 三维重建算法[J]. 计算机应用, 2022,42(2):584-591.
- [18] ZHOU B, ZHOU S K, DUNCAN J S, et al. Limited view

tomographic reconstruction using a cascaded residual dense spatial-channel attention network with projection data fidelity layer[J]. IEEE Transactions on Medical Imaging, 2021,40(7):1792-1804.

- [19] WANG J, BAO Y, WEN Y, et al. Prior-attention residual learning for more discriminative COVID-19 screening in CT images [J]. IEEE Transactions on Medical Imaging, 2020,39(8):2572-83.
- [20] 陈胜娣. 基于生成对抗网络的医学图像超分辨率重建 [J]. 计算机时代, 2021(10):15-19.
- [21] KEYS R. Cubic convolution interpolation for digital image processing[J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1981,29(6):1153-60.
- [22] DEMIR U, UNAL G. Patch-based image inpainting with generative adversarial networks [EB/OL]. (2018-03-20) [2022-05-15]. https://arxiv.org/pdf/1803.07422.pdf.
- [23] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-04) [2022-05-15]. https://arxiv.org/pdf/ 1409.1556.pdf.
- [24] 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.
- [25] GOLDGOF D, HALL L, HAWKINS S, et al. Data from QIN_LUNG_CT[EB/OL].[2022-05-31]. https://wiki.cancerimagingarchive.net/display/Public/QIN + LUNG + CT.
- [26] KALPATHY-CRAMER J, NAPEL S, GOLDGOF D, et al. QIN multi-site collection of lung CT data with nodule segmentations[J]. Cancer Imaging Arch, 2015,10: K9.

Unsupervised super resolution analysis of CT images based on generative adversarial networks

LI Yunhe*, CHEN Lunqiang*, ZHAO Huiyan**, WU Shaohua***

(*School of Electronics and Eletrical Engineering, Zhaoqing University, Zhaoqing 526061)

(** School of Electrical Engineering and Information, Northeast Petroleum University, Daqing 163319)

(**** School of Electronics and Information Engineering, Harbin Institute of Technology (Shenzhen), Shenzhen 518055)

Abstract

Improving the resolution of computed tomography (CT) medical images can help doctors to identify the lesion more accurately, which has important clinical significance. This paper studies how to obtain a low resolution image in the same domain as the real image by using a dataset containing only low resolution images without high-low resolution image pair data, and then constructs a training dataset close to the natural image pair by degrading the network and injecting noise. And a super-resolution generative adversarial networks including a super-resolution generator, a super-resolution discriminator and a super-resolution feature extractor (DeSRGAN) is designed to achieve X4 times super-resolution analysis of CT images. Experimental tests show that the DeSRGAN method is superior to the latest EDSR, RCAN, ESRGAN and other methods in quantitative comparison of X4 times CT images generated by super-resolution analysis without reference image quality evaluation indicators such as NIQE, BRISQUE and PIQE. At the same time, in terms of intuitive visual effects, the images generated by DeSRGAN method have clearer details and better perceptual effects.

Key words: super-resolution, computed tomography (CT), generative adversarial network (GAN), deep learning