

基于卷积神经网络的宫颈CT图像的金属伪影去除

黄霞¹, 许乙凯¹, 张煜^{2,3}

1. 南方医科大学南方医院影像中心, 广东 广州 510515; 2. 南方医科大学生物医学工程学院, 广东 广州 510515; 3. 广东省医学图像处理重点实验室, 广东 广州 510515

【摘要】目的:为了消除宫颈CT图像中存在的金属伪影,提出一种利用卷积神经网络(CNN)去除金属伪影的策略。**方法:**首先通过数值仿真得到金属伪影图像与目标图像(无伪影图像),构造训练测试数据集,利用含金属伪影的宫颈CT图像和对应的无伪影图像训练已搭建的CNN,进而得到去除宫颈CT图像金属伪影的CNN模型。**结果:**训练网络之前金属伪影图像与目标图像峰值信噪比(PSNR)平均值为26.0980 dB。不同尺寸(25×25、50×50、100×100)的图像块训练网络得到去除金属伪影的图像与目标图像PSNR平均值分别为34.6079、38.3751、38.1838 dB。**结论:**通过对仿真数据和临床数据进行实验,研究结果表明,本文方法能够快速有效地消除宫颈CT图像中的金属伪影,并且可以保留完整的组织结构信息。

【关键词】金属伪影;数据仿真;卷积神经网络;宫颈CT图像

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2022)12-1466-07

Metal artifact reduction in cervical CT images using convolutional neural network

HUANG Xia¹, XU Yikai¹, ZHANG Yu^{2,3}

1. Medical Imaging Center, Nanfang Hospital, Southern Medical University, Guangzhou 510515, China; 2. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 3. Guangdong Provincial Key Laboratory of Medical Image Processing, Guangzhou 510515, China

Abstract: Objective To reduce metal artifacts in cervical CT images using convolutional neural network. **Methods** The metal artifact images and the target images (artifact-free images) were generated using numerical simulation for constructing training and test data sets. The cervical CT images with metal artifacts and paired cervical CT images without metal artifacts were input into the constructed convolutional neural network for training, and then a convolutional neural network model for metal artifact reduction in cervical CT images was obtained. **Results** Before network training, the average peak signal-to-noise ratio (PSNR) of the metal artifact images and the target images was 26.0980 dB. The average PSNR of the metal artifact reduction images and the target images obtained by the training network trained by image patches of different sizes (25×25, 50×50, 100×100) was 34.6079, 38.3751, and 38.1838 dB, respectively. **Conclusion** Through experiments on simulation data and clinical data, it is revealed that the proposed method can effectively reduce metal artifacts and can retain relatively complete tissue texture information in cervical CT images.

Keywords: metal artifact; data simulation; convolutional neural network; cervical CT image

前言

宫颈癌作为一种常见的恶性肿瘤,中国每年新增宫颈癌病例超过13万,对女性的生命健康产生了巨大的威胁,针对宫颈癌患者的放射疗法是较为有效的治疗方案^[1-2]。在放疗方案的制定过程中和放射剂量

投射过程中,CT图像具有重要的参考价值。在近距离放射治疗前,一般都需要在病人的宫颈病灶内植入高密度的金属施源器。然而,CT扫描部位存在的金属植入物会产生光束硬化、光子不足和散射,造成投影数据不完整,使重建后的宫颈CT图像产生条纹伪影,或称为金属伪影。这些金属伪影会掩盖植入物周围组织中的重要诊断信息,使得医生难以对靶区进行精准勾画,进而导致临床对放射剂量的计算精度较低,这些因素对放射治疗的精度和临床治疗效果产生诸多负面影响^[3]。因此,去除金属伪影对提高临床诊断和放射治疗的准确性有重要意义。

【收稿日期】2022-06-17

【基金项目】国家自然科学基金(61971213)

【作者简介】黄霞,硕士研究生,助理工程师,E-mail: 983956235@qq.com

【通信作者】张煜,教授,博士,博士生导师,E-mail: yuzhang@smu.edu.cn

现有的去除CT图像金属伪影方法(Metal Artifacts Reduction, MAR)有投影插值法^[4-7]、迭代校正法^[8-11]和深度学习法^[12-15]。但是这些方法大多数应用于其他部位CT图像,而非针对宫颈CT图像。少数针对宫颈CT图像金属伪影去除的研究,如Roeske等^[16]尝试利用投影插值算法去除宫颈CT图像中的金属伪影。该方法第一步将去除施源器污染的投影数据区域,再通过插值方法得到新的投影数据,最后对更新后的投影数据重建得到去除金属伪影的图像,随后利用像素修正因子作用于原始图像,以达到去除伪影的目的。然而,该方法的缺点是带来了新的条纹伪影,降低了图像质量。迭代方法是通过不断迭代更新参数达到最小化重建目标函数与正弦图之间的误差^[17]。Xia等^[18]提出一种混合算法策略,即在原始投影数据的基础上,利用该算法实现金属和非金属区域的有效分离,通过插值算法更新金属区域的投影数据,最后重建新的投影数据,进而将金属施源器造成的金属伪影去除。但是,这些方法会降低原图像的质量并且运行效率低。

近年来,深度学习成为研究的热点,卷积神经网络(Convolutional Neural Network, CNN)也适用于去除CT图像的金属伪影。例如,Lars Gjestebj等^[19]将CNN与MAR算法相结合以减少图像中的金属伪影,可以显著地改善图像质量,但是该方法运用的是体模数据,不是真实的医学CT图像。Zhang等^[20]提出一种基于CNN的MAR框架,通过融合原始图像和矫正图像信息来消除CT图像的金属伪影。Yu等^[21]利用基于图像域和基于正弦图域的去金属伪影方法的优点,提出了一个通用的去除CT图像金属伪影框架。受此类技术启发,本文提出基于CNN的去金属伪影方法。该方法面临的一个主要问题是CNN网络的训练需要对应的伪影图像和干净图像,然而对于宫颈CT图像而言,临床上缺乏含金属伪影的CT图像(深度学习模型的输入数据)和对应的无伪影CT图像(训练模型的参考标签,用于计算损失函数)。为了解决这个问题,本文利用仿真手段构建带有金属伪影的CT图像数据集,并且设计和训练基于此数据集的CNN伪影模型。首先,为了确保仿真数据的真实性和准确性,仿真过程中不使用体模图像,而是在无伪影的CT图像上人工模拟金属植入物的形状、尺寸和位置信息,随后经由数值仿真技术,生成条纹金属伪影整合到原始图像之中,得到带有金属伪影的宫颈CT图像,进而可以构建所需的训练和测试数据集。在此基础上,笔者设计并训练CNN去除宫颈CT金属伪影。在仿真和真实图像上的实验结果表明,基于这套仿真数据训练出来的金

属伪影去除模型能快速有效地去除宫颈CT图像中的金属伪影,恢复组织结构信息。

1 材料与方法

1.1 宫颈CT金属伪影图像仿真

本文方法需要创建宫颈CT图像数据集,用于CNN训练。在该数据集中,包括目标图像(无伪影图像)和金属伪影图像。来源于临床获得的宫颈CT图像没有与之对应的目标图像,因此需要通过图像仿真来创建用于网络训练的数据集。

没有带金属伪影的宫颈CT图像在患者植入金属施源器前扫描获取。为了仿真金属伪影图像,笔者在临床医生的指导下,手动模拟金属形状、大小和金属所在的位置,然后将这些参数存储为二值图像,即对应CT图像中金属伪影的真实金属信息。接着利用二值图像含有的金属信息覆盖到目标图像适当的位置,依据特定的金属材料属性对金属的投影区域赋予像素值,生成插入金属的图像,表示为 X 。通过对图像 X 进行软阈值的分割^[22],将其分为金属和其余组织信息(如骨骼、水等组织),分别记为 X_m 和 X_r 。本文仿真的目标仅针对金属区域,其他组织区域保持一样。为此,假定骨骼和其他组织衰减系数 $\mu_r(E)$ 一致,即 $\mu_r(E) = \mu_r(E_0)$ 。在此过程中,笔者设定一个像素阈值 W ,高于其值的像素被定义为金属区域组织,低于该值的像素将定义为其余组织区域。阈值函数表示为:

$$T(X_i) = \begin{cases} 0, & X_i \leq W \\ 1, & X_i > W \end{cases} \quad (1)$$

其中, X_i 表示 X 中的第 i 个像素值。由此, X_m 和 X_r 可表示为:

$$\begin{aligned} X_m &= T(X_i) X_i \\ X_r &= (1 - T(X_i)) X_i \end{aligned} \quad (2)$$

通过雷登变换,分别将 X_m 和 X_r 的像素值转变为线性衰减系数,即:

$$\begin{aligned} X_{(\varphi,S)}^m &= \text{radon}(X_m) \\ X_{(\varphi,S)}^r &= \text{radon}(X_r) \end{aligned} \quad (3)$$

进一步地,需要量化金属在各个能量处的衰减系数。此处,笔者认为其余组织的像素值保持恒定,而金属材料的衰减系数则可以用已知能量相关质量衰减系数和未知能量密度的乘积来定义^[23]:

$$X_m(E) = \mu_m(E) \rho(m) \quad (4)$$

其中, $\rho(m)$ 代表某个特定像素点的金属密度, $\mu_m(E)$ 代表金属在能量 E 处的质量衰减系数。利用特定的多色X射线成像系统,其单色能量为 E_0 。 X_m 可以写成:

$$X_m(E_0) = \mu_m(E_0) \rho(m) \quad (5)$$

式(4)和式(5)联立,则可以去除未知参数 $\rho(m)$ 。

所以,金属材料的能量相关线性衰减系数可以简化如下:

$$X_m(E) = \frac{X_m(E_0) \mu_m(E)}{\mu_m(E_0)} \quad (6)$$

对于给定的X射线路径 $L_{\varphi,s}$,投影数据由Lambert-Beer定律给出^[24]:

$$P(\varphi, s) = -\ln \int_{L_{\varphi,s}} \frac{I(E)}{\int I(E) dE} \exp \left(- \int_{L_{\varphi,s}} (X_m(E) + X_r(E)) dl \right) dE$$

$$= -\ln \int_{L_{\varphi,s}} \frac{I(E)}{\int I(E) dE} \exp \left(- \frac{\mu_m(E) F_{(\varphi,s)}^m}{\mu_m(E_0)} - X_{(\varphi,s)}^r \right) dE \quad (7)$$

其中, $I(E)$ 指代X射线的强度值,由入射光源和探测器灵敏度所决定。

最终,经由雷登逆变换即可以重建得到包含金属伪影的CT图像,即:

$$I_{\text{金属伪影}} = R^{-1} P(\varphi, s) \quad (8)$$

图1显示了仿真得到的4组含金属伪影的宫颈CT图像。其中图1a~c分别表示无伪影目标图像、金属二值图和仿真生成的金属伪影图像。从图中可以看出,本研究能很好地从目标图像仿真出其对应的金属伪影图像,从而构建用于神经网络训练的数据集。




图1 数值仿真金属伪影的结果

Figure 1 Results of metal artifacts generated by numerical simulation

1.2 宫颈CT金属伪影去除CNN

本文方法采用网络结构如图2所示,包括输入层,中间层,输出层。首先将尺寸大小为 50×50 的仿真CT金属伪影图像块输送到网络,通过网络的第一层卷积计算得到特征图。该层中卷积核的个数是64,其尺寸是 3×3 。本方法在进行卷积操作之前执行零填充,目的是卷积之后得到的特征图大小与输入图像相同。在本文方法中,采用的激活函数是修正

线性单元(ReLU),其可以表示为 $\text{ReLU} = \max(0, x)$ 。

输入的图像块通过卷积和ReLU之后的结果为:

$$C_1(p) = \text{ReLU}(W_1 * p + b_1) \quad (9)$$

其中, W_1 为权重, b_1 为偏置,*表示卷积, p 是输入的图像块。 $C_1(p)$ 表示通过卷积之后得到的新特征图。

通过对第1层卷积得到的特征图获取局部信息,网络的第2~ $D-1$ 层采用与第1层数目与尺寸大小相

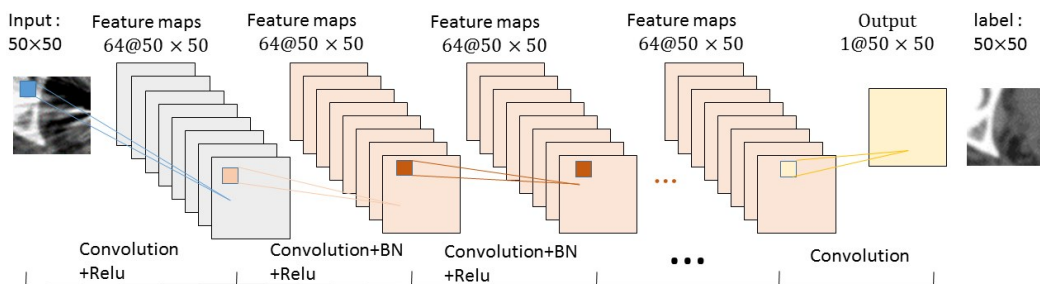


图2 去除金属伪影的卷积神经网络结构

Figure 2 Architecture of convolution neural network for metal artifact reduction

同的卷积核,与第1层不同的是,这些层中在卷积和ReLU之间增加批标准化(Batch Normalization, BN),因为它有良好的性能,加快网络训练速度以及对初始化的低灵敏度^[25]。经过2~D-1层的输出为:

$$C_d(p) = \text{ReLU}(W_d * C_{d-1}(p) + b_d), d = 2, \dots, D-1 \quad (10)$$

其中, W_d 为第 d 层中的权重, b_d 为第 d 层中的偏置, $*$ 为卷积, $C_d(p)$ 是第 $d-1$ 层得到的新特征图。

对于最后一层,在本方法中采用一个卷积层产生输出,卷积核大小是 $3 \times 3 \times 64$,即:

$$C_D(p) = W_D * C_{D-1}(p) + b_D \quad (11)$$

搭好网络结构之后,接着训练网络,其训练过程主要是优化可调参数,如卷积层中的卷积核权重和偏置。网络训练面临的主要问题是参数初始化,损失函数和优化算法。在本文中所有的特征图偏置都设置为0,所有权重初始化采用Xavier^[26]:

$$W = (\text{random}(0, 1) - 0.5) \times 2 \times \sqrt{\frac{6}{\text{neuron_in} + \text{neuron_out}}} \quad (12)$$

其中, $\text{random}(0, 1)$ 的作用是在 $(0, 1)$ 之间产生随机数。 neuron_in 和 neuron_out 分别表示该层的输入神经元数目和该层的输出神经元数目。代价函数用来估量模型的预测值与真实值的不一致程度。优化算法最小化损失函数以提高分类器的作用。代价函数定义为 $(\theta) = \frac{1}{2N} \sum_{i=1}^N \|R(p'_i; \theta) - p'_i\|_F^2$, 其中 p'_i 是输入

层的仿真金属伪影的图像块。 p'_i 是作为网络标签的无伪影图像块,其是从目标图像对应位置提取的。参数 θ 可通过训练网络得到。在本研究中,本文使用Adam的优化算法^[27],该方法是在训练数据过程中迭代地更新网络权重的一阶优化算法。Adam是对计算梯度的一阶矩估计和二阶矩进行综合考虑,计算出更新步长。在本文中,网络参数的学习率设置为0.01,权重衰减为 $\log - 5$, Adam算法的动量设置为0.9和0.999。批量大小为64,确保充分运用GPU内存。网络的训练周期为100,最后笔者可以直接用训

练好的网络模型去除宫颈CT图像的金属伪影。

2 实验

2.1 实验平台与数据集

训练网络的进程中有巨大的矩阵运算,本文方法在图像处理单元(Graphics Processing Unit, GPU)进行网络的训练。本文做实验的服务器参数为:8 G内存的Intel(R)Core(TM) i5-6500k 3.20 GHz中央处理单元和12 G内存的NVIDIA TITANX Pascal GPU。本文网络结构是在MatConvNet深度学习的框架上实现的。

本方法所使用的数据图像来自地区医院放疗科,制作训练网络数据集的图像是宫颈癌患者在近距离放射治疗前未植入施源器时CT扫描得到的图像,共250张CT图像。Brilliance Big Bore CT扫描仪设备的扫描参数是:管电压大小120 kV, X射线管电流大小375 mA,断层的厚度为3 mm。经过数值仿真技术得到目标图像对应的金属伪影数据集,再从数据集随机选取190张图像作为训练集,选取40张图像作为验证集,其他图像用作测试集。训练所使用的输入输出数据均为图像块,本文方法获取图像块的方式是采用滑动窗口,其大小为 50×50 ,步长为25。对训练集和验证集进行相同的操作得到图像块,通过对训练集和测试集乱序操作,加强网络学习能力。

2.2 视觉评价

首先用测试数据集中的20张仿真金属伪影CT图像来验证本文提出的算法,这些图像未参与网络训练。图3显示了本文方法去除仿真金属伪影图像的结果。如图所示,本文方法能很好地去除金属伪影,而且能够很好地保留图像中原有的组织信息。同时,本文方法也能应用于临床真实的宫颈CT金属伪影图像。图4显示了不同临床实例图像(此类图像是已植入施源器后的宫颈CT图像)去除金属伪影的结果。其中图4b、d分别表示图4a、c对应红框处的放大图像。从结果中可以看到,本文方法能有效去除

图像中的金属伪影。图 5 同样显示了本文方法去除另一组临床实例图像金属伪影的结果。这些结果表明本文方法可以有效去除 CT 图像的金属伪影,并较好地保留了图像中原有的组织结构。




图 3 本文方法去除仿真金属伪影图像的实验结果
Figure 3 Results of metal artifact reduction by the proposed method

2.3 量化评价

源于临床真实的金属伪影图像缺乏与之相对应的无伪影图像,在本文中,通过对仿真数据集进行峰值信噪比(PSNR)计算来评估算法去除 CT 图像金属伪影的效果^[28],量化评价的指标分别为:

$$\text{MSE} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (X(i,j) - Y(i,j))^2$$
$$\text{PSNR} = 10 \log_{10} \frac{(2^n - 1)^2}{\text{MSE}} \tag{13}$$

其中,MSE 是去除金属伪影之后的图像 X 和无金属伪影图像 Y 的均方误差, H 、 W 代表是图像的高度和宽度; n 是每像素的比特数,一般设为 8。PSNR 的单位是 dB,数值越大表示失真越小。表 1 给出了不同尺寸的图像块训练网络去除金属伪影的 PSNR 比较。

从表 1 可得到的结论是图像块尺寸为 50×50 时训练得到网络模型去除宫颈 CT 图像金属伪影的效果更好。

3 结 论

本文提出一种基于 CNN 的深度学习架构去除宫颈 CT 图像金属伪影。有效去除金属伪影有利于医

生精准勾画靶区,以提升临床放射剂量计算的准确性。利用深度学习模型研究宫颈 CT 图像金属去伪影方法的一个难点在于临床上难以获得含金属伪影的宫颈 CT 图像和对应的无金属伪影宫颈 CT 图像。因此,本文针对这个难点问题,首先提出利用数值仿真实验,在无伪影宫颈 CT 图像上构建能用于训练深度学习模型且接近临床真实情况的含金属伪影宫颈 CT 图像。其次,基于这套仿真数据,笔者设计并训练了一个基于 CNN 的金属伪影去除模型,实验结果表明基于这套仿真数据训练出来的金属伪影去除网络能快速有效地去除临床真实宫颈 CT 图像中的金属伪影。

同时,对于一张大小为 512×512 的图像,去除金属伪影时间小于 1 s,无需额外的处理。本文提出的基于 CNN 去除宫颈 CT 图像金属伪影的方法简单且灵活,不需要特殊的 CT 扫描设计,也不需要原始 CT 投影数据,易于实现。在下一步工作中,采用扩大数据来改善网络去除 CT 图像金属伪影的性能。同时也可以考虑引入组织先验信息来更好地去除图像中的金属伪影。

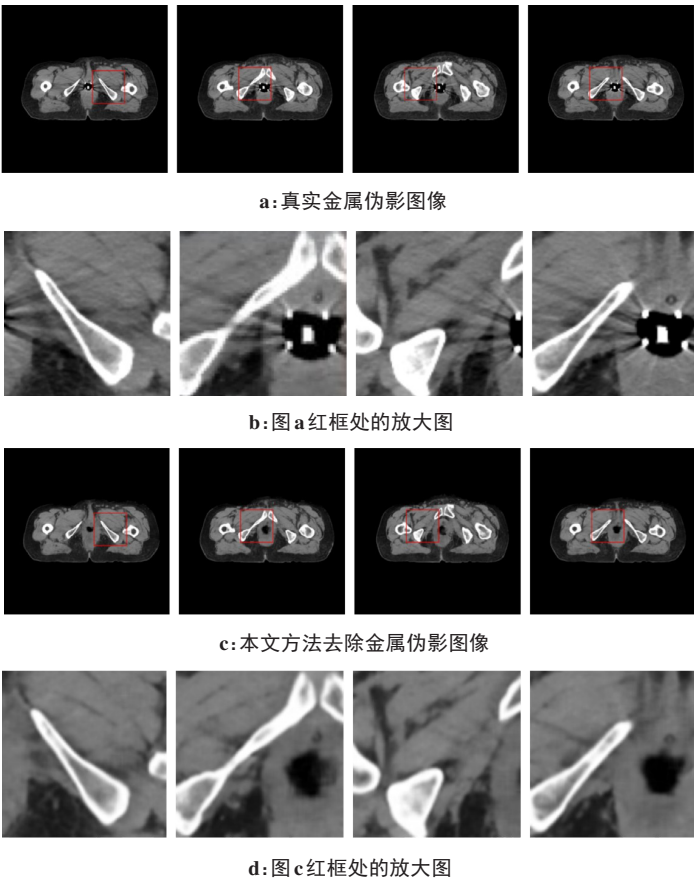


图4 本文方法去除临床真实金属伪影图像的实验结果 1

Figure 4 Example 1 of reducing metal artifacts in clinic by the proposed algorithm

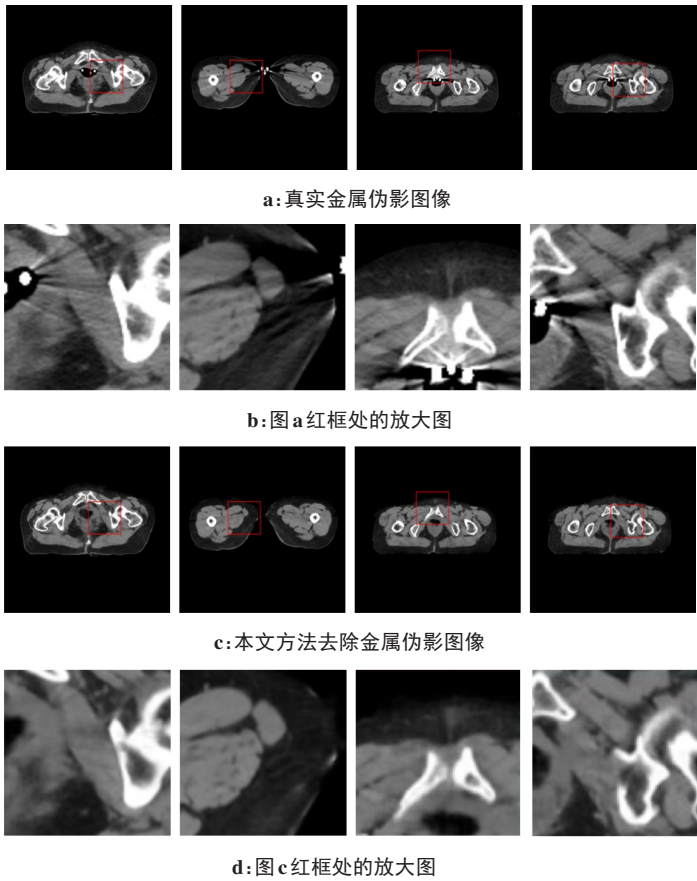


图5 本文方法去除临床真实金属伪影图像的实验结果 2

Figure 5 Example 2 of reducing metal artifacts in clinic by the proposed algorithm

表 1 不同尺寸的图像块训练网络去除金属伪影的 PSNR 均值比较(dB)

Table 1 Comparison of mean PSNR of the training network based on different image patches for metal artifact reduction (dB)

PSNR 均值	25×25	50×50	100×100
金属伪影图像-目标图像	26.098 0	26.098 0	26.098 0
去除金属伪影图像-目标图像	34.607 9	38.375 1	38.183 8

【参考文献】

[1] Kannappan S, Lee JH, Lakshmanakumar M, et al. Cervical cancer[M]. Biomarkers and Biosensors for Cervical Cancer Diagnosis. Singapore: Springer, 2021: 13-22.

[2] Jemal A, Bray F, Center MM. Global cancer statistics, 2012[J]. Ca Cancer J Clin, 2013, 65(2): 87-108.

[3] Rodriguez-Gallo Y, Orozco-Morales R, Perez-Diaz M. Analysis of objective quality metrics in computed tomography images affected by metal artifacts[J]. Biomed Tech (Berl), 2022, 67(1): 1-9.

[4] Park C, Lee D, Lim Y, et al. A normalized metal artifact reduction method using an artifact-reduced prior for dental computed tomography[J]. Journal-Korean Physical Society, 2019, 74(3): 298-304.

[5] Liang KC, Zhang L, Yang HK, et al. Metal artifact reduction for practical dental computed tomography by improving interpolation-based reconstruction with deep learning[J]. Med Phys, 2019, 46(12): e823-e834.

[6] 余晓镔, 李婵娟, 陈武凡. 运用混合插值法降低金属伪影[J]. 南方医科大学学报, 2009, 29(1): 29-31.

Yu XE, Li CJ, Chen WF. Using hybrid interpolation to reduce metal artifacts[J]. Journal of Southern Medical University, 2009, 29(1): 29-31.

[7] Karimi S, Cosman P, Wald C, et al. Segmentation of artifacts and anatomy in CT metal artifact reduction[J]. Med Phys, 2012, 39(10): 5857-5868.

[8] Fang JM, Zhang D, Wilcox C, et al. Metal implants on CT: comparison of iterative reconstruction algorithms for reduction of metal artifacts with single energy and spectral CT scanning in a phantom model[J]. Abdom Radiol (NY), 2017, 42(3): 742-748.

[9] Chang Z, Ye DH, Srivastava S, et al. Prior-guided metal artifact reduction for iterative X-Ray computed tomography[J]. IEEE Trans Med Imaging, 2018, 38(6): 1532-1542.

[10] Zeng GL. A projection-domain iterative algorithm for metal artifact reduction by minimizing the total-variation norm and the negative-pixel energy[J]. Vis Comput Ind Biomed Art, 2022, 5(1): 1-11.

[11] Ge T, Medrano M, Liao R, et al. A metal artifact reduction scheme for accurate iterative dual-energy CT algorithms[J]. arXiv preprint arXiv: 2202.00116, 2022.

[12] Gjestebj LA, Shan HM, Yang QS, et al. A dual-stream deep convolutional network for reducing metal streak artifacts in CT images

[J]. Phys Med Biol, 2019, 64(23): 235003.

[13] Ghani MG, Karl WC. Fast enhanced CT metal artifact reduction using data domain deep learning[J]. IEEE Trans Comput Imaging, 2020, 6: 181-193.

[14] Yu LQ, Zhang ZC, Li XM, et al. Deep sinogram completion with image prior for metal artifact reduction in CT images[J]. IEEE Trans Med Imaging, 2021, 40(1): 228-238.

[15] Arabi H, Zaidi H. Deep learning-based metal artefact reduction in PET/CT imaging[J]. Eur Radiol, 2021, 31(8): 6384-6396.

[16] Roeske JC, Lund C, Pelizzari CA, et al. Reduction of computed tomography metal artifacts due to the Fletcher-Suit applicator in gynecology patients receiving intracavitary brachytherapy [J]. Brachytherapy, 2003, 2(4): 207-214.

[17] Shinohara Y, Ohmura T, Sasaki F, et al. Appropriate iMAR presets for metal artifact reduction from surgical clips and titanium burr hole covers on postoperative non-contrast brain CT[J]. Eur J Radiol, 2021, 141: 109811.

[18] Xia D, Roeske JC, Yu L, et al. A hybrid approach to reducing computed tomography metal artifacts in intracavitary brachytherapy [J]. Brachytherapy, 2005, 4(1): 18-23.

[19] Lars Gjestebj QY, Yan X, Bernhard C, et al. Reducing metal streak artifacts in CT images via deep learning: pilot results[C]//The 14th International Meeting on Fully Three-Dimensional Image Reconstruction in Radiology and Nuclear Medicine. 2017: 611-614.

[20] Zhang Y, Yu H. Convolutional neural network based metal artifact reduction in X-ray computed tomography [J]. IEEE Trans Med Imaging, 2018, 37(6): 1370-1381.

[21] Yu L, Zhang Z, Li X, et al. Deep sinogram completion with image prior for metal artifact reduction in CT images [J]. IEEE Trans Med Imaging, 2020, 40(1): 228-238.

[22] Schüller S, Sawall S, Stannigel K, et al. Segmentation-free empirical beam hardening correction for CT [J]. Med Phys, 2015, 42(2): 794-803.

[23] Chen B, Bian ZY, Zhou XH, et al. A new mumford-shah total variation minimization based model for sparse-view X-ray computed tomography image reconstruction[J]. Neurocomputing, 2018, 285: 74-81.

[24] Ehn S, Sellerer T, Mechlem K, et al. Basis material decomposition in spectral CT using a semi-empirical, polychromatic adaption of the Beer-Lambert model[J]. Phys Med Biol, 2017, 62(1): 1-17.

[25] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//In International Conference on International Conference on Machine Learning. 2015: 448-456.

[26] Gong M, Liu J, Li H, et al. A Multiobjective sparse feature learning model for deep neural networks[J]. IEEE Trans Neural Netw Learn Syst, 2017, 26(12): 3263-3277.

[27] Kingma D, Ba J. Adam: a method for stochastic optimization [J]. Computer Science, 2014. DOI: 10.48550/arXiv.1412.6980.

[28] Podgorsak AR, Shiraz Bhurwani MM, Ionita CN. CT artifact correction for sparse and truncated projection data using generative adversarial networks[J]. Med Phys, 2021, 48(2): 615-626.

(编辑:薛泽玲)