

# 基于结构联合字典的肺部 LDCT 图像降噪

代晓婷, 龚 敬, 聂生东

(上海理工大学医疗器械与食品学院, 上海 200093)

**摘 要:** 肺部 LDCT (Low-Dose Computed Tomography) 图像中噪声及条状伪影等异常显著, 顶部和底部图像尤为严重. 为提高整个肺部 LDCT 图像的质量, 本文提出一种基于结构联合字典的图像降噪方法. 首先, 利用肺部 CT 图像的灰度特点, 将 HRCT (High Resolution Computed Tomography) 图像块分类并训练, 获得 4 类字典, 通过计算原子的信息熵和 HOG (Histogram of Oriented Gradient) 特征, 得到相应的结构字典, 进而构造出结构联合字典; 然后, 在对肺部 LDCT 图像进行非局部均值滤波的基础上, 将结构联合字典作为全局字典, 对图像进行稀疏表示及重构, 获得降噪后的图像. 为验证算法有效性, 选用模拟和临床两类数据进行实验, 并与 KSVD、AS-LNLM、BF-MCA 等 3 种算法对比. 对比发现, 本文算法在去除噪声和条状伪影以及保留细节方面效果较好, 特别是对序列顶层和底层图像处理优势更加明显. 该方法能够显著提升整个肺部 LDCT 图像的质量.

**关键词:** 肺部低剂量 CT 图像; 联合字典; 稀疏表示; 图像降噪

**中图分类号:** TP391      **文献标识码:** A      **文章编号:** 0372-2112 (2018)06-1445-09

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2018.06.025

## Low-Dose Lung CT Image Denoising Using Joint Structural Dictionary

DAI Xiao-ting, GONG Jing, NIE Sheng-dong

(School of Medical Instrument and Food Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** Noise and streak artifacts are serious in low-dose CT (LDCT) images of lung, especially for the top and bottom layers. To improve the quality of LDCT sequential images, we proposed a method to remove noise and streak artifacts by using a joint structural dictionary. Firstly, according to the gray-scale features of lung CT image, we divided high resolution CT (HRCT) images into four groups, and obtained four dictionaries for each group by dictionary training. Secondly, computed the information entropy and the histogram of oriented gradient (HOG) of each dictionary atom. And then obtained the structure dictionary of corresponding group by feature clustering. Finally, the joint structural dictionary can be obtained by combining these four structure dictionaries. On the basis of non-local mean filtering for LDCT images, the joint structural dictionary is used as a global dictionary to get the denoised image by sparse representation and reconstruction. In order to validate the effectiveness of the proposed method, simulated and clinical LDCT data are used. Compared with reported methods (KSVD, AS-LNLM and BF-MCA), our method performed better in denoising, streak artifact-removing and details-preserving for the whole LDCT scans, especially for the top and bottom layers. The proposed algorithm can significantly improve the quality of lung LDCT images.

**Key words:** low-dose lung CT image; joint dictionary; sparse representation; image denoising

## 1 引言

肺癌如今已是全球死亡率较高的恶性肿瘤之一, 作为其检查手段的计算机断层扫描 (Computed Tomography, CT) 却是医源性放射损伤的主要来源, 其辐射危害堪比核辐射<sup>[1]</sup>. 通常, 临床上采用降低 X 线管电流、

降低管电压、增大螺距、增加准直宽度、减小扫描范围等措施来降低 CT 检查带来的扫描辐射<sup>[2]</sup>, 基于低剂量 CT (Low-Dose Computerized Tomography, LDCT) 的相关研究便随之开展开来. 2011 年, 美国国家肺癌筛查试验 (National Lung Screening Trail, NLST) 的随机对照研究结果显示, 采用 LDCT 对肺癌高危人群进行筛查可使得肺癌

病死率下降 20%<sup>[3]</sup>. 因此, LDCT 在肺癌的预防和筛查中具有很重要的作用. 但剂量的降低又导致了图像的质量变差, 主要表现在: 图像对比度差、噪声及条状伪影严重<sup>[4]</sup>, 这些将严重影响基于图像分割、重建、特征提取等后处理的计算机辅助诊断研究的准确度. 因此, 对肺部 LDCT 图像的降噪研究刻不容缓. 目前, 对 LDCT 降噪大致有以下三种研究思路: (1) 直接对投影数据降噪, 然后用降噪后的数据进行重建<sup>[5-7]</sup>; (2) 在重建的同时对投影数据降噪<sup>[8,9]</sup>; (3) 对重建后的图像直接进行图像域降噪.

前两种思路均需要获取 CT 扫描的投影数据, 并且需要对投影数据中的噪声和伪影模型进行充分的分析和建模. 同时投影数据的获取也是个难题, 很多研究者无法得到原始的投影数据. 而图像域降噪则不需要考虑投影数据获取的问题, 可直接应用于重建后的 LDCT 图像, 具有更大的研究价值. 所以, 本文是基于第三种思路所做的研究, 不仅数据易得, 且在实际中更为实用. 但是在低剂量 CT 扫描的过程中, 由于探测器接收到的光子数目较少, 使得探测器端产生“光子饥饿”现象, 再加上投影数据的不完备也会给扫描之后的重建造成很大的影响, 进而在重建后的图像中会显现出如斑点、雪花状、条状伪影等结构异常, 其表现形式复杂且依赖于组织和器官分布, 难以用数学模型描述, 这也是 LDCT 图像域降噪的难点所在<sup>[10]</sup>.

近年来, 基于非局部相似性和稀疏表示两种思想的图像降噪算法受到了国内外研究者的广泛关注. 基于非局部相似性的非局部均值滤波 (Non-Local Mean, NLM)<sup>[11]</sup> 和三维块匹配滤波 (Block-Matching and 3D filtering, BM3D)<sup>[12]</sup> 在自然图像降噪领域中应用最广泛且具有较高的鲁棒性. 为提高 LDCT 图像的质量, 毕一鸣<sup>[13]</sup> 等利用低剂量和普通剂量图像的非局部相似性, 提出了一种基于标准剂量 CT 图像非局部权重先验的低剂量图像恢复算法, 该算法能够有效地消除脑灌注 LDCT 图像中的噪声, 但是对数据的要求较高, 需要同时具备同一条件下采集的低剂量和普通剂量的数据. 显然, 临床上这种数据十分难得, 难以在实际中得以应用. 而 Ha S 等<sup>[14]</sup> 和 Xu W 等<sup>[15]</sup> 则是先建立肺部标准剂量 CT 图像数据库, 并利用随机森林等分类算法对数据库中的图像块进行分类, 然后结合块匹配和非局部均值滤波实现降噪. 基于非局部相似性算法需要大数据库作为先验基础, 还涉及图像块匹配的问题, 算法复杂、计算量大, 且该类算法在对条状伪影的去除时效果不佳, 会导致图像的过平滑, 损失过多的图像细节.

在稀疏表示降噪的研究中, KSVD 是最经典的字典降噪算法, 是通过构造过完备字典来实现对图像的降噪. 朱永成等<sup>[16]</sup> 将其用于肺部 LDCT 图像降噪中, 该算

法能够有效去除图像中的噪声, 但是对条状伪影的去除却效果不佳. 后来, 陈阳等利用人体腹部组织相似性的特点, 先后提出了结合小波变换的大尺度非局部均值伪影抑制算法 (Artifact Suppressed Large-scale Nonlocal Means, AS-LNLM)<sup>[17]</sup> 和基于区别性字典的条状伪影去除算法 (Artifact Suppressed Dictionary Learning, ASDL)<sup>[18]</sup>, 在腹部图像的伪影抑制中取得了不错的效果. 但 ASDL 算法中训练字典的样本是根据临床医师经验选取的细节块和伪影块, 字典训练的效果难以控制, 实验的可重复性低. 崔学英等<sup>[19]</sup> 避免了训练样本的人为选取问题, 将待处理图像首先经过双边滤波 (Bilateral Filter, BF) 获得高频和低频子图, 然后将高频子图作为训练样本, 运用基于字典学习的形态分量分析 (Morphological Component Analysis, MCA) 算法实现图像的降噪和去伪影. 该类算法虽然不需要预先构造训练样本库, 但由于训练样本含有噪声和伪影, 这样会导致字典中提取的图像信息不全、带有较多的噪声和伪影残留等问题, 使得处理后的图像细节信息丢失过多. 此外, 由于在肺顶部和底部图像中, 肺实质所占比例较少, 再加上噪声和伪影的影响, 训练字典时就会受到样本提供信息的限制, 从而使得该类算法对肺顶部和底部图像的处理效果不佳.

综上所述, 目前针对肺部 LDCT 图像的图像域降噪算法均存在其局限性, 在保留图像中血管、气管等细节的同时, 如何有效地实现对整个肺部图像的噪声和条状伪影去除, 依然是近年来研究的热点和难点所在. 本文针对整个肺部 LDCT 图像, 从优化训练字典的角度出发, 结合非局部相似性和稀疏表示两种思想, 提出一种基于分类训练结构联合字典的降噪算法. 旨在训练一个能够尽可能完整地表征肺部图像结构信息的结构联合字典, 进而去除整个肺部 LDCT 图像中的噪声和条状伪影.

## 2 基于稀疏表示的图像降噪算法

给定一个由  $K$  个基向量  $\{\mathbf{d}_j\}_{j=1}^K$  组成的过完备向量集合  $\mathbf{D} \in \mathbf{R}^{m \times K}$  ( $m > K$ ), 使得任意输入信号  $\mathbf{Y} \in \mathbf{R}^m$  可以用  $\mathbf{D}$  中尽可能少的基向量线性表示, 即  $\mathbf{Y} = \mathbf{D}\mathbf{X}$ , 其中  $\mathbf{X}$  是稀疏系数矩阵. 过完备向量集  $\mathbf{D}$  被称为字典, 基向量被称为字典的原子. 基于字典学习的图像稀疏表示算法一般被描述为如下的带约束优化问题<sup>[20]</sup>:

$$\min_{\mathbf{D}, \alpha_j} \sum_j \|\mathbf{R}_j \mathbf{x} - \mathbf{D} \alpha_j\|_2^2, \text{ s. t. } \|\alpha_j\|_0 \leq T_0, \forall i, j \quad (1)$$

其中,  $\mathbf{x}$  是原图像;  $\mathbf{D}$  是待构造的字典;  $\mathbf{R}_j$  是图像块抽取算子, 完成从图像  $\mathbf{x}$  中抽取图像块的操作  $\mathbf{x}_j = \mathbf{R}_j \mathbf{x}$ ;  $\alpha_j$  是稀疏表示系数;  $T_0$  是稀疏约束项.

KSVD<sup>[21]</sup> 是最经典的字典学习算法, 首先假设系数

矩阵  $X$  和字典  $D$  都是固定的,然后根据误差最小原则,对误差项进行 SVD 分解,逐列更新固定字典的原子和对应的稀疏系数矩阵,经过数次迭代后得到过完备的冗余字典,该问题可以被描述为如下形式:

$$\begin{aligned} \|Y - DX\|_F^2 &= \left\| Y - \sum_{j=1}^K d_j x_j^T \right\|_F^2 \\ &= \left\| \left( Y - \sum_{j \neq k} d_j x_j^T \right) - d_k x_k^T \right\|_F^2 \\ &= \|E_k - d_k x_k^T\|_F^2 \end{aligned} \quad (2)$$

其中,  $d_k$  代表字典的第  $k$  列,  $x_k^T$  表示系数矩阵  $X$  中  $d_k$  相对应的第  $k$  行,矩阵  $E_k$  表示原子  $d_k$  的成分在所有样本中造成的误差。

图像的结构信息能够被过完备字典中的原子稀疏表示,而噪声是随机的,不具备这类性质<sup>[22]</sup>,这也是字典学习算法降噪的理论基础.然而,在肺部低剂量 CT 图像中,除噪声外还有条状伪影,其依附于图像的结构而存在,且具备一定结构特征.所以,必须对字典进行后处理,方能达到提高图像质量的目的。

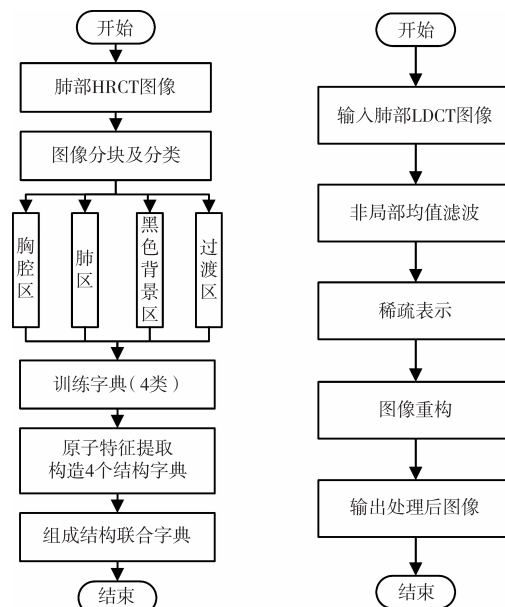
### 3 肺部 LDCT 图像降噪算法

研究表明,将理想的无噪图像作为样本库所训练的字典降噪效果更佳<sup>[16]</sup>.因此,本文结合标准库构造和稀疏表示两种思想,提出一种基于结构联合字典的肺部 LDCT 图像降噪算法。

算法分两个阶段:线下训练结构联合字典(图 1(a))和在线处理低剂量 CT 图像(图 1(b)).在训练结构联合字典阶段,首先将普通剂量的高分辨率 CT(High Resolution CT, HRCT)图像分块,得到包含大量重叠子块的样本库  $\Omega$ ,并根据肺部图像的灰度特点将  $\Omega$  分为 4 类(胸腔区  $\Omega_a$ 、肺区  $\Omega_b$ 、黑色背景区  $\Omega_c$ 、过渡区  $\Omega_d$ ),接着对 4 类样本分别进行字典训练,得到 4 类字典( $D_a$ 、 $D_b$ 、 $D_c$ 、 $D_d$ );然后提取原子的特征,将 4 类字典分别处理后,得到 4 个结构字典( $D_{as}$ 、 $D_{bs}$ 、 $D_{cs}$ 、 $D_{ds}$ ),进而构成结构联合字典  $D_s = [D_{as}, D_{bs}, D_{cs}, D_{ds}]$ .在处理低剂量 CT 图像阶段,首先对待处理图像进行非局部均值滤波预处理,然后将训练好的结构联合字典作为全局字典,采用正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法对待处理图像进行稀疏表示,最后通过图像重构得到降噪后的图像。

#### 3.1 HRCT 样本库分类训练

若将整幅图像作为样本直接进行训练,不仅计算量大、耗时长,而且样本结构复杂,难以得到最佳字典.研究中通常将待训练的图像分为若干个重叠图像子块,这样不仅可以减少计算量、简化训练样本的结构,还可以消除块边缘效应.假设样本图像的大小为  $512 \times 512$ ,图像子块通常设为  $16 \times 16$ ,将所有图像子块按列排列组成待训练的样本库  $\Omega$ .



(a) 结构联合字典训练流程(线下) (b) LDCT 图像降噪流程(在线)

图1 本文算法流程图

通过对基于字典学习的图像优化算法的研究发现,图像处理效果很大程度上取决于训练字典.理想条件下,采用最佳字典对图像的处理效果最好.而是否能够得到最佳的字典,一方面取决于训练字典的方法;另一方面取决于训练字典的样本库. KSVD 和在线字典是字典训练中常用的方法,对于大样本条件下的字典训练,研究中常采用在线字典.其次,训练字典的样本库,决定训练后字典所要表达的结构信息.研究表明,单一全局字典能够表示的结构信息有限,其原子组成很大程度上受样本库的限制<sup>[23]</sup>.因此,为了囊括图像中尽可能多的结构信息,需要对样本库进行分类,进而训练出能有效表达图像某种结构的紧字典。

目前,图像分类中最常用的两种方法是:聚类法和阈值法.肺部 CT 图像大致包括 3 个区域:黑色背景区域、肺实质区域、胸腔区域,且各区域的灰度范围差异明显.本文利用肺部 CT 图像的灰度特点,采用阈值分类法对样本库的图像块进行分类。

实验抽取大量 HRCT 图像子块,并统计它们的均值和均方差信息,可以发现:(1)处于黑色背景区域的图像块,其均值和均方差极小,几乎为零;(2)处于胸腔区域的图像块,其均值较大、方差较小;(3)处于肺实质区域的图像块,其均值适中,方差偏大;(4)处于以上三个区域的过渡区域,其均值和均方差均较大。

考虑到图像块均值和均方差的差异性,根据均值与均方差的差值设置阈值,将样本库中的图像块分为 4 类:胸腔区  $\Omega_a$ 、肺区  $\Omega_b$ 、黑色背景区  $\Omega_c$ 、过渡区  $\Omega_d$ .分类后,每个样本子库将各自具有相似的结构信息,接着




图2 4类样本子库训练得到的4类完备字典

通过在线字典训练得到4类字典 $D_a$ 、 $D_b$ 、 $D_c$ 、 $D_d$ 。图2显示了训练后的4类字典及其局部放大。4类字典差异明显,说明每个样本子库所代表的结构信息不同。因此,通过将图像块分类训练得到的字典能够更好更完整地表达图像的结构信息。

### 3.2 构造结构联合字典

虽然普通剂量 HRCT 图像噪声和伪影水平相对较低,但并不完全等价于理想的无噪图像,所得字典中仍存在一些条状伪影的成分,从图2所示的字典中亦可看出。由于条状伪影与自然图像中的雨纹结构类似,因此可借鉴雨纹去除的方法<sup>[24]</sup>,通过提取字典原子的特征来去除表征条状伪影的原子,进而得到仅含图像结构原子的结构字典。

字典原子重排列成矩阵后,便可将其看作是一个图像块。通过观察图2中的字典可以发现:在灰度信息层面上,条状伪影原子与图像结构原子相比,灰度信息较为复杂,具有较大的信息熵;在梯度信息层面上,条状伪影原子具有较强的方向特征。故此,本文通过计算信息熵(Information Entropy)和方向梯度直方图(Histogram of Oriented Gradient, HOG)两个特征来进行字典原子的分类。分类采用K-均值聚类法,根据梯度方差来判定结构原子的所属类别,将筛选出来的结构原子构成结构字典,如图3所示。最后,将4个结构字典联合并随机排列,得到一个表征肺部CT图像信息的结构联合字典 $D_s$ 。图4显示了结构联合字典 $D_s$ 和利用未经分类与筛选的样本库 $\Omega$ 直接训练得到的字典 $D_\Omega$ ,可以看出:结构联合字典 $D_s$ 中包含的图像信息比字典 $D_\Omega$ 丰富,且伪影和噪声的原子明显减少。

### 3.3 稀疏表示与图像重构

对肺部 LDCT 图像处理时,首先进行非局部均值预处理,然后将上一小节中获得的结构联合字典 $D_s$ (如图4(a))作为一个全局字典,进行稀疏表示及重构。即:式(1)中的字典 $D$ 固定,求解数 $\alpha_{ij}$ 的问题则被转化为图

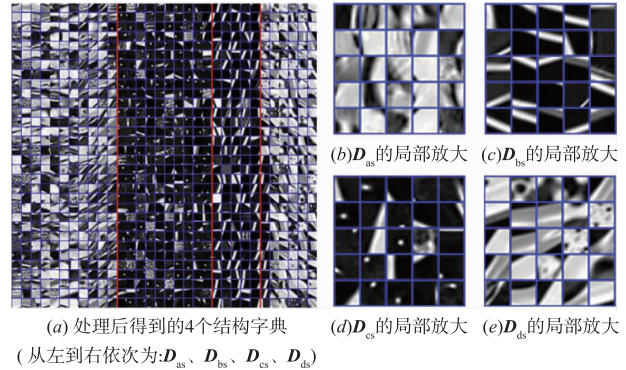


图3 处理后的4个结构字典及其局部放大

像在结构联合字典 $D_s$ 上稀疏表示的问题:

$$\begin{aligned} & \arg \min_{\alpha_j} \|\alpha_j\|_0 \\ \text{s. t. } & \sum_j \|R_j x - D_s \alpha_j\|_2^2 < \varepsilon \quad \& \quad \|\alpha_j\| \leq T_0, \forall i, j \end{aligned} \quad (3)$$

通过设置拉格朗日参数,式(3)可等价变换为无约束的形式,即:

$$\min_{\alpha_j} \|R_j x - D_s \alpha_j\|_2^2 + \lambda \|\alpha_j\|_0 \quad (4)$$

由于 $L_0$ 范数是非凸的,所以式(3)和式(4)是一个非凸优化问题,其求解过程是一个典型的 NP-hard 问题。目前解决该问题的方法很多,最常用的就是基追踪(Basis Pursuit, BP)算法、匹配追踪(Matching Pursuit, MP)算法以及在其基础上的改进算法,如 OMP, ROMP, TBP, TOBP 等。本文采用 OMP 算法来进行稀疏表示的求解,它克服了 MP 算法的过匹配问题,并对原子进行正交化处理,在保证每次迭代最优的基础上,减少了迭代次数。

利用得到的稀疏表示系数 $\alpha_j$ 以及结构联合字典 $D_s$ 对图像进行重构,便可得到最终处理后的图像 $\hat{x}$ :

$$\hat{x} = (\lambda I + \sum_{ij} R_j^T R_j)^{-1} (\lambda x + \sum_{ij} R_j^T D_s \alpha_j) \quad (5)$$




图4 不同方法训练的字典对比

## 4 实验环境与数据准备

### 4.1 实验环境与实验数据

实验平台配置如下:处理器为 Inter(R) Core(TM)

i5-3470 CPU @ 3.20GHz; 内存 (RAM) 为 8.00GB; 系统类型为 64 位 Winows 10 操作系统; 编程工具为 Matlab R2014a. 本文实验将用到两种图像数据:

(1) 肺部普通剂量 HRCT 图像: 从上海市肺科医院采集的 10 个病人的临床数据, 用于参与字典训练以及 LDCT 模拟实验. 由 SIEMENS 16 排螺旋 CT 胸部扫描方式获得, 图像数量平均为 500 张, 其中肺部图像平均为 380 张, 螺距为 1.2, 扫描层厚为 1mm, 管电压为 120KV, 管电流范围为 240 ~ 350mA, 重建方式为 FBP<sub>B31F</sub>.

(2) 真实肺部低剂量 CT 图像: 从美国国家肺癌筛查试验 (National Lung Screening Trial, NLST) 数据库 (<https://biometry.nci.nih.gov/cdas/nlst/>) 挑选 10 组临床数据. 挑选标准如下: 图像数量平均为 150 张, 螺距为 1.5, 扫描层厚为 2.5mm, 管电压为 120KV, 管电流范围为 40 ~ 80mA, 重建方式为 FBP<sub>B50F</sub>.

#### 4.2 LDCT 模拟实验

由于病人大多不愿意在同一时间段内同时接受高、低两种剂量的 CT 检查, 所以 LDCT 图像处理后会缺乏对应的参考图像. 又诸如峰值信噪比 (Peak Signal to Noise Ratio, PSNR)、结构相似度 (Structural Similarity Index, SSIM) 等常用的降噪性能评价指标均属于全参考评价方式, 其参考图像为理想的高质量图像. 为了解决参考图像缺失的问题, 研究中采用模拟实验, 利用普通剂量的 CT 图像获得与之对应的 LDCT 图像, 并将普通剂量的 CT 图像作为参考图像.

本文通过 LDCT 模拟实验对上海市肺科医院采集的 10 个病人的肺部普通剂量 HRCT 图像进行处理, 得到与之相对应的 LDCT 模拟图像, 为后续的模拟 LDCT 降噪实验做准备. 低剂量模拟图像中的噪声及伪影模型参照文献 [25, 26], 首先将 HRCT 图像通过 Fan-Beam 变换, 从图像域变换到投影域, 然后在投影域加噪后, 再变换回到图像域<sup>[25, 26]</sup>. 其投影域加噪后的模型为:

$$A_{\text{simulate}} = \log \left( \frac{Q_0(g)p(d)}{Q_0(g)p(d)\exp(-A_m) + G_{ij}} \right) \quad (6)$$

其中,  $A_m$  代表原图像的投影域变换结果,  $Q_0$  代表入射光子数,  $p(d)$  代表探测器  $d$  所在位置的蝶型滤波器,  $G_{ij}$  代表高斯随机噪声.

实验中通过设置入射光子数来控制低剂量的水平, 图 5 为 LDCT 模拟实验结果, 模拟 LDCT 图像的质量与  $Q_0$  成正比,  $Q_0$  的值越小, 模拟图像中的噪声和伪影就会越严重, 对比度也会越差.

选用 PSNR、SSIM 和图像熵差等 3 个指标来对实验结果进行客观评价. 其中, PSNR 是图像评价中最常用的客观指标, 用于衡量图像的失真程度, 值越大则失真越小; SSIM 是从亮度、对比度、结构三个方面来评价两张图像之间的相似程度, 值越大则相似程度越高; 熵差为两张图像信息熵的差值, 用于衡量两张图像所传递信息量的差异度, 值越小则信息量损失越小. 从表 1 的定量评价结果中可以看出, PSNR、SSIM 和熵差等三个指标可以对图像质量进行有效的评价.




图5 不同入射光子数  $Q_0$  水平下的 LDCT 图像模拟实验结果

表 1 不同入射光子数  $Q_0$  水平下的 LDCT 模拟图像客观评价结果

入射光子数 $Q_0$	$1.5 \times 10^4$	$3.0 \times 10^4$	$7.5 \times 10^4$	$3.0 \times 10^5$	$9.0 \times 10^4$	$3.0 \times 10^6$
PSNR	13.901	17.796	18.919	22.306	23.964	25.615
SSIM	0.513	0.338	0.460	0.482	0.535	0.608
熵差	0.644	0.571	0.501	0.465	0.340	0.236

## 5 实验与结果

为验证本文算法的有效性, 使用模拟和临床两类肺部 LDCT 数据进行实验, 并与目前常用的降噪、去伪影算法进行对比. 对比算法有以下 3 种: (1) KSVD<sup>[21, 16]</sup>, 目前最经典的字典降噪算法, 文中使用 LDCT 图像自身作为训练集, 训练出自适应的 KSVD 字典来进行降噪; (2) AS-LNLM<sup>[17]</sup>, 首先使用 SWT 变换将 LDCT

图像进行一阶小波分解, 接着对三个方向的高频分量进行非线性扩散, 然后使用 ISWT 进行图像重构, 最后召经过 LNLM 算法实现图像降噪和伪影去除; (3) BF-MCA<sup>[19]</sup>, 首先用双边滤波器 BF 将图像分为高频和低频两部分, 然后再使用 MCA 算法对高频子图进行分解, 得到高频子图的卡通成分, 最后与低频部分叠加, 得到降噪和去伪影后的图像.

### 5.1 实验参数设置

本文实验中, 不同算法的参数设置如表 2 所示. 需要指出的是, 模拟降噪实验中选取的是  $Q_0 = 3.0 \times 10^4$  的模拟图像.

训练字典的样本块尺寸均设置为  $16 \times 16$  ( $N_p = 256$ ), 字典冗余度  $R = 4$ , 最终得到的字典共有  $16 \times 16$

$\times 4(N_d = 1024)$  个原子, iter 为迭代次数,  $\sigma$  为噪声水平的估计值,  $C$  为噪声增益,  $\lambda$  为拉格朗日系数,  $T_0$  为稀疏约束项. 在 BF-MCA 算法中,  $w$  为双边滤波的窗口大小;  $\sigma_1$  和  $\sigma_2$  分别表示滤波器的几何距离和灰度值的标准差;  $N_{\text{HOG}}$  为方向梯度描述子的维数;  $n_L, n_H, n_{\text{bins}}$  是 HOG 特征计算的参数, 分别为: 每个区间中细胞单元的个数、每个细胞单元中图像像素点的个数、每个细胞单元的直方图通道个数;  $k$  表示分类个数. 此外, 在 AS-LNLM 算法中, 小波变换中使用的是 Harr 小波, 分解层数  $S = 2$ ,  $K$  为非线性扩散系数, inc 为扩散步长,  $h$  为衰减系数,  $n$  和  $N$  分别为 LNLM 的匹配窗和搜索窗大小. 在本文算中, 相应的参数意义同上.

表 2 各种算法的实验参数表

算法	模拟 LDCT 实验参数设置	临床 LDCT 实验参数设置
KSV D	$N_p = 256, R = 4, N_d = 1024,$ iter = 15, $\sigma = 35, C = 1.15,$ $\lambda = 0.15, T_0 = 10$	$N_p = 256, R = 4, N_d = 1024,$ iter = 15, $\sigma = 30, C = 1.15,$ $\lambda = 0.12, T_0 = 8$
BF-MCA	BF: $w = 5, [\sigma_1, \sigma_2] = [3, 0.2];$ MCA: $N_p = 256, R = 4, N_d = 1024,$ iter = 100, $\lambda = 0.15, T_0 = 10,$ $k = 5$ $N_{\text{HOG}} = 81, n_L = 3, n_H = 3,$ $n_{\text{bins}} = 9$	BF: $w = 5, [\sigma_1, \sigma_2] = [3, 0.1];$ MCA: $N_p = 256, R = 4, N_d = 1024,$ iter = 100, $\lambda = 0.15, T_0 = 10,$ $k = 5$ $N_{\text{HOG}} = 81, n_L = 3, n_H = 3,$ $n_{\text{bins}} = 9$
AS-LNLM	$S = 2, K = 50, \text{iter} = 10,$ inc = 0.05, $h = 30,$ $n = 7 \times 7, N = 81 \times 81$	$S = 2, K = 50, \text{iter} = 10,$ inc = 0.05, $h = 20, n = 7 \times 7,$ $N = 81 \times 81$
本文算法	非局部均值预处理: $n = 3 \times 3, N = 11 \times 11,$ $\sigma = 35;$ 结构联合字典训练: $N_p = 256, R = 4, N_d = 1024,$ iter = 10, $C = 1.15, \lambda = 0.1,$ $T_0 = 10$ $N_{\text{HOG}} = 81, n_L = 3, n_H = 3,$ $n_{\text{bins}} = 9, k = 9$	非局部均值预处理: $n = 3 \times 3, N = 11 \times 11,$ $\sigma = 30;$ 结构联合字典训练: $N_p = 256, R = 4, N_d = 1024,$ iter = 10, $C = 1.15,$ $\lambda = 0.1, T_0 = 10$ $N_{\text{HOG}} = 81, n_L = 3, n_H = 3,$ $n_{\text{bins}} = 9, k = 9$

## 5.2 模拟 LDCT 图像降噪实验

对 4.2 小节中得到的 10 组肺部 LDCT 模拟图像 ( $Q_0 = 3\%0 \times 10^4$ ) 进行处理, 并与 KSV D、AS-LNLM 和 BF-MCA 三种算法进行比较, 结果如图 6 所示. 从实验结果可以看出, KSV D 算法可以去除图像中的部分噪声, 但却不能去除条状伪影. AS-LNLM 和 BF-MCA 是针对 LDCT 图像中的条状伪影问题提出的, 对条状伪影的去除效果较为明显, 但对肺实质内部的细节保留效果却不佳, 其主要原因是: 在本实验选取的模拟图像的条状伪影较多, 而这两类算法的降噪和去伪影是以噪

声图像作为已知信息进行处理的, 所以当图像质量较差时, 处理效果不太令人满意. 本文算法是在一个全局的结构联合字典的基础上, 对噪声图像进行的降噪和去伪影, 即使在噪声和伪影较为严重的情况下, 也能够去除噪声和伪影的同时, 保留和恢复图像中更多的细节信息, 如图 6(h)、(i) 和表 3 所示.

另外, 如图 1(b) 所示, 本文算法在运用线下训练的结构联合字典进行降噪之前, 使用非局部均值滤波 (NLM) 对待处理图像进行预处理. 从图 6(f) 和 (g) 可以看出, NLM 算法对图像具有良好的边缘保留作用, 能够去除图像中的部分噪声, 但对条状伪影的去除效果不佳. 当 NLM 的参数  $n, N, \sigma$  较大时, 条状伪影虽能去除一部分, 但是图像的细节也会损失过多, 导致图像的过平滑. 在本文中 NLM 仅作为预处理, 目的是为了去除图像中的部分散点噪声, 但由于 NLM 也有一定的图像平滑效果, 所以需要设置较小的  $n, N, \sigma$ . 从表 3 的定量评价结果中可以看出, 基于结构联合字典的方法能够取得较高的 PSNR 值和 SSIM 值, 且熵差最小. 对比图 6(h) 和 (i), NLM 预处理虽然能够去除图像中更多的噪声和伪影, 但是也会损失部分细节信息, 如图中画圈部分所示.

## 5.3 临床 LDCT 图像降噪实验

从 NLST 数据库选取 10 组肺部 LDCT 临床数据进行实验, 并选用同一病人不同扫描层的图像 (如图 7 所示) 进行降噪结果的对比与分析. 由于本文研究的对象为肺, 故结果于肺窗内显示 (如图 8 所示, 其中 A 代表顶层图像, B 代表右肺中层图像, C 代表左肺中层图像, D 代表左肺底图像), 然后比较分析图像处理前后的噪声和伪影去除效果, 以及肺内血管、气管等细节保留效果. 由于临床 LDCT 图像缺乏相应的高质量图像, 所以 PSNR、SSIM 等全参考图像评价标准无法使用. 本文采用基于局部感兴趣区域的客观评价方式<sup>[18,27]</sup>对结果进行定量评价. 信噪比 (Signal-Noise Ratio, SNR), 其定义为局部区域块内像素的均值与方差的比值, 常用于医学图像的质量评价, 如表 4 所示.

对比图 8 和表 4 的结果, 可以发现, 本文提出的算法在临床 LDCT 图像的降噪和去伪影处理中, 定性和定量结果均优于其他算法. 从整个肺部 LDCT 图像处理的效果上看, 本文算法对不同扫描层的图像均有较好的降噪和去伪影效果, 且与其他算法相比, 对顶部和底部图像处理的优势更加明显, 其主要原因是: 在顶部和底部图像中肺实质较少, 而本文使用的是线下训练的结构联合字典, 不受噪声图像自身提供信息的约束, 因而能够更好地保留和恢复图像的细节.




图6 模拟LDCT图像降噪实验结果




图7 同一病人不同扫描层的肺部图像




图8 肺部不同扫描层的LDCT图像的降噪结果对比

表 3 模拟 LDCT 图像客观评价结果

评价指标	模拟图像	KSVD	AS-LNLM	BF-MCA	NLM ( $\sigma = 35$ )	NLM ( $\sigma = 65$ )	结构 联合字典	NLM + 结构 联合字典
PSNR	17.796	26.663	28.620	28.709	27.166	26.190	29.162	29.694
SSIM	0.338	0.684	0.739	0.791	0.715	0.625	0.811	0.836
熵差	0.571	0.380	0.294	0.307	0.362	0.419	0.285	0.254

表 4 同一病人不同扫描层的肺部 LDCT 图像的 SNR 评价结果

评价对象	ROI 编号	原图像	KSVD	AS-LNLM	BF-MCA	结构 联合字典	NLM + 结构 联合字典
图 7(a) 肺顶层	①	6.856	11.628	13.244	14.591	14.195	14.263
	②	5.380	7.059	7.643	6.960	7.927	8.226
	③	1.109	1.284	1.152	1.198	1.227	1.336
	④	1.463	3.265	2.180	1.681	3.695	3.316
图 7(b) 肺中层	①	10.627	13.062	13.497	12.680	13.952	14.007
	②	5.788	6.592	6.969	7.181	7.694	7.922
	③	1.010	1.906	3.360	3.294	3.612	3.580
	④	1.036	2.310	2.588	1.284	2.853	2.916
图 7(c) 肺底层	①	16.224	20.636	19.911	20.051	19.736	20.172
	②	8.666	9.953	10.281	10.285	10.707	10.813
	③	1.530	1.701	1.634	1.758	2.840	3.358
	④	1.694	1.889	1.732	1.935	2.318	2.433

## 6 总结与讨论

针对肺部 LDCT 图像存在严重的噪声和条状伪影问题,本文提出了一种基于结构联合字典的图像降噪算法.利用图像质量相对较高的 HRCT 图像块进行字典训练,通过一系列字典后处理获得一个全局的结构联合字典,并将其用于整个肺部 LDCT 图像.模拟和临床两类肺部 LDCT 数据的降噪实验结果验证了本文算法的有效性.对比同一病人不同层图像的处理结果后,可以发现:本文算法能够在有效去除肺部 LDCT 图像中噪声和伪影的同时,保留和恢复图像更多的细节,且对整个肺部图像均有效,与其他算法相比,本文算法对肺顶层和底层图像处理后的优势更为明显.因此,该算法能够提升整个肺部 LDCT 图像的质量,有利于 LDCT 图像后续的处理与分析.此外,线下训练结构联合字典,不仅能够提取出肺部图像更多的结构信息,提升图像的质量,还可以节省图像在线处理的时间,这对于肺部图像的大批量处理是很有意义的.

然而,结构原子是否完全提取会影响结构联合字典训练的效果,故开发高性能字典原子特征选取和优化方法、原子分类算法,将是下一步研究的主要方向.

### 参考文献

- [1] Pierce D A, Preston D L. Radiation-related cancer risks at low doses among atomic bomb survivors[J]. *Radiation Research*, 2000, 154(2): 178–186.
- [2] Yu L, Liu X, Leng S, et al. Radiation dose reduction in computed tomography: techniques and future perspective

[J]. *Imaging in Medicine*, 2009, 1(1): 65–84.

- [3] Russi E W. Lung cancer screening has the potential to save lives, but shall we do it? [J]. *Swiss Medical Weekly*, 2011, 141: w13185.
- [4] Mayo J R, Hartman T E, Lee K S, et al. CT of the chest: minimal tube current required for good image quality with the least radiation dose[J]. *American Journal of Roentgenology*, 1995, 164(3): 603–607.
- [5] Li T, Li X, Wang J, et al. Nonlinear sinogram smoothing for low-dose X-ray CT[J]. *IEEE Transactions on Nuclear Science*, 2004, 51(5): 2505–2513.
- [6] Hu S, Liao Z, Chen W. Sinogram restoration for low-dosed X-ray computed tomography using fractional-order perona-malik diffusion[J]. *Mathematical Problems in Engineering*, 2012, 2012(1): 243–253.
- [7] Liao Z, Hu S, Li M, et al. Noise estimation for single-slice sinogram of low-dose X-ray computed tomography using homogenous patch[J]. *Mathematical Problems in Engineering*, 2012, 2012(2): 208–212.
- [8] Tang J, Nett B E, Chen G-H. Performance comparison between total variation (TV)-based compressed sensing and statistical iterative reconstruction algorithms[J]. *Physics in Medicine and Biology*, 2009, 54(19): 5781–5804.
- [9] Lee H, Xing L, Davidi R, et al. Improved compressed sensing-based cone-beam CT reconstruction using adaptive prior image constraints[J]. *Physics in Medicine and Biology*, 2012, 57(8): 2287–307.
- [10] 张权. 低剂量 X 线 CT 重建若干问题研究[D]. 南京: 东南大学, 2015.

- ZHANG Quan. A study on some problems in image reconstruction for low-dose CT system[D]. Nanjing: South-east University, 2015. (in Chinese)
- [11] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[A]. Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on[C]. San Diego, CA, USA; IEEE, 2005. 60 – 65.
- [12] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080 – 2095.
- [13] 毕一鸣, 马建华, 路利军, 等. 基于标准剂量 CT 图像非局部权值先验的低剂量图像恢复[J]. 电子学报, 2010, 38(5): 1146 – 1151.
- BI Yi-ming, MA Jian-hua, LU Li-jun, et al. Low-dose CT image restoration using a non-local weights prior from previous normal-dose scan image[J]. Acta Electronica Sinica, 2010, 38(5): 1146 – 1151. (in Chinese)
- [14] Ha S, Mueller K. Low dose CT image restoration using a database of image patches[J]. Physics in Medicine and Biology, 2015, 60(2): 869.
- [15] Xu W, Ha S, Mueller K. Database-assisted low-dose CT image restoration[J]. Medical Physics, 2013, 40(3): 31109.
- [16] 朱永成, 陈阳, 罗立民, 等. 基于字典学习的低剂量 X-ray CT 图像去噪[J]. 东南大学学报(自然科学版), 2012, 42(5): 864 – 868.
- ZHU Yong-cheng, CHEN Yang, LUO Li-min, et al. Dictionary learning based denoising of low-dose X-ray CT image[J]. Journal of Southeast University (Natural Science Edition), 2012, 42(5): 864 – 868. (in Chinese)
- [17] Chen Y, Yang Z, Hu Y, et al. Thoracic low-dose CT image processing using an artifact suppressed large-scale nonlocal means[J]. Physics in Medicine and Biology, 2012, 57(9): 2667 – 2688.
- [18] Chen Y, Shi L, Feng Q, et al. Artifact suppressed dictionary learning for low-dose CT image processing[J]. IEEE Transactions on Medical Imaging, 2014, 33(12): 2271 – 2292.
- [19] Cui X Y, Gui Z G, Zhang Q, et al. Learning-based artifact removal via image decomposition for low-dose CT image processing[J]. IEEE Transactions on Nuclear Science, 2016, 63(3): 1860 – 1873.
- [20] Ravishanker S, Bresler Y. MR image reconstruction from highly undersampled  $k$ -space data by dictionary learning[J]. IEEE Transactions on Medical Imaging, 2011, 30(5): 1028 – 1041.
- [21] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311 – 4322.
- [22] 蔡泽民, 赖剑煌. 一种基于超完备字典学习的图像去噪方法[J]. 电子学报, 2009, 37(2): 347 – 350.
- CAI Ze-min, LAI Jian-huang. An over-complete learned dictionary-based image de-noising method[J]. Acta Electronica Sinica, 2009, 37(2): 347 – 350. (in Chinese)
- [23] Dong W, Zhang L, Shi G, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization[J]. IEEE Transactions on Image Processing, 2010, 20(7): 1838 – 1857.
- [24] Kang L W, Lin C W, Fu Y H. Automatic single-image-based rain streaks removal via image decomposition[J]. IEEE Transactions on Image Processing, 2012, 21(4): 1742 – 1755.
- [25] Massoumzadeh P, Don S, Hildebolt C F, et al. Validation of CT dose-reduction simulation[J]. Medical Physics, 2009, 36(1): 174 – 189.
- [26] Horiuchi T, Yamamoto S, Murase K. Development of DICOM image-based CT low dose simulator using fan-beam transform[J]. Technology and Health Care, 2013, 21(5): 441 – 454.
- [27] Ai D, Yang J, Fan J, et al. Adaptive tensor-based principal component analysis for low-dose CT image denoising[J]. Plos One, 2015, 10(5): e0126914.

#### 作者简介



代晓婷 女, 1993 年 10 月出生于河南驻马店. 2015 年于新乡医学院生物医学工程专业获得学士学位, 现为上海理工大学硕士研究生. 主要研究方向为: 医学图像处理.  
E-mail: dxting02041s@163.com



龚敬 男, 1990 年 6 月出生于河南南阳. 2013 年至今在上海理工大学硕博连读, 攻读博士学位. 主要研究方向为: 医学图像处理与分析.  
E-mail: gongjing1990@163.com



聂生东(通信作者) 男, 1962 年 7 月出生于山东泰安. 2000 年于上海交通大学医学院生物医学工程专业获得博士学位. 现为上海理工大学教授, 博士生导师, 校学术委员会委员. 主要研究方向为: 医学成像与图像处理.  
E-mail: nsd4647@163.com