

基于双能 CT 图像域的 DL-RTV 多材料分解研究

降俊汝^{1,2,3}, 余海军^{2,3}, 龚长城⁴, 刘丰林^{2,3*}

¹重庆大学机械传动国家重点实验室, 重庆 400044;

²重庆大学光电技术及系统教育部重点实验室, 重庆 400044;

³重庆大学工业 CT 无损检测教育部工程研究中心, 重庆 400044;

⁴重庆工商大学数学与统计学院, 重庆 400067

摘要 双能计算机断层扫描(DECT)技术因能分解和识别材料,并提供量化的成像结果,广泛应用于医疗、安检、无损检测以及材料科学等领域。DECT 技术能提供物体在两种能谱下的衰减信息,可准确分解两种基材料。但当检测对象含有三种材料时,若对 DECT 图像直接求逆(DIMD)分解多材料,其基图像将含较多噪声和伪影。为此,提出了一种基于双能 CT 图像域的字典学习(DL)和相对总变分(RTV)的多材料分解算法,简称 DL-RTV 算法。通过直接求逆获得初始基图像,利用字典学习挖掘基图像的稀疏性,以提高材料分解的准确性;引进 RTV 进一步降低基图像的噪声和伪影,并保护图像细节;同时引入各基材料质量守恒和像素边界的约束项,提高材料分解精度。仿真和实验研究表明,DL-RTV 算法能较准确地分解三种材料,较好抑制基图像噪声和伪影,提高了材料区分度,从而验证了此算法的有效性和实用性,这对 DECT 技术的发展和具有重要的意义。

关键词 成像系统; 双能计算机断层扫描技术; 多材料分解; 图像域; 字典学习; 相对总变分

中图分类号 TP391

文献标志码 A

doi: 10.3788/AOS202040.2111004

Image-Domain Multimaterial Decomposition for Dual-Energy CT Based on Dictionary Learning and Relative Total Variation

Jiang Junru^{1,2,3}, Yu Haijun^{2,3}, Gong Changcheng⁴, Liu Fenglin^{2,3*}

¹State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, China;

²Key Laboratory of Optoelectronic Technology and Systems of the Ministry of Education, Chongqing University, Chongqing 400044, China;

³Engineering Research Center of Industrial Computed Tomography Nondestructive Testing, Ministry of Education, Chongqing University, Chongqing 400044, China;

⁴College of Mathematics and Statistics, Chongqing Technology and Business University, Chongqing 400067, China

Abstract Dual-energy computed tomography (DECT) has been widely used to medical imaging, security inspection, nondestructive testing, materials science and so on, with its capability to decompose and identify materials and provide quantified results. DECT technique can accurately decompose two basis materials due to its performance to acquire the attenuation information of the scanned object at low and high energies. However, when there are three basis materials, if the direct inverse material decomposition (DIMD) is used to decompose the materials, the material CT images will contain much noise and artifacts. Therefore, we propose an image domain multi-material decomposition algorithm for DECT based on dictionary learning (DL) and relative total variation (RTV), which is called DL-RTV for short. The method employs the DIMD to acquire original material images, and then trains a dictionary to explore the sparsity of the images and improve the accuracy of the material decomposition. Meanwhile, the RTV is introduced to further reduce the noise and artifacts of the images and preserve details. In addition, the constrains of mass conservation and the bounds of each pixel are added into the DL-RTV model to enhance the material decomposition accuracy. Simulation and experimental results indicate that the DL-RTV method can decompose three kinds of materials accurately, suppress the noise and artifact of the basis

收稿日期: 2020-05-27; 修回日期: 2020-07-07; 录用日期: 2020-07-15

基金项目: 国家自然科学基金(61471070)、国家重大仪器开发专项(2013YQ030629)

* E-mail: liufl@cqu.edu.cn

images and improve the material discrimination. The method is authenticated to be effective and practical, which has important significance for the development and application of DECT.

Key words imaging systems; dual-energy computed tomography; multi-material decomposition; image domain; dictionary learning; relative total variation

OCIS codes 110.6960; 340.7440; 300.6560

1 引 言

X 射线计算机断层扫描(CT)技术利用不同密度物质对穿过物体内部的 X 射线吸收不同的原理,实现对物体断层成像,因其成像直观、检测范围广等优点被广泛应用于生物医学、安全检查、无损检测、航空航天等领域。但传统 CT 系统只能重建物质衰减系数图,难以快速有效地分辨密度相近而原子序数不同的物质。1976 年,Alvarez 等^[1]首次提出双能计算机断层扫描(DECT)技术,它利用同一物质在不同 X 射线能谱下衰减系数不同的特性成像。与传统 CT 相比,双能 CT 能准确获得物质的电子密度和有效原子序数,实现材料分解和物质识别,在医学成像、安检和工业无损检测等领域具有重要应用潜力和研究价值。

双能 CT 技术利用光子计数探测器或积分探测器成像,探测器在采集数据时,易受康普顿散射效应、光子噪声以及电子噪声的影响,且不同射线下对应的散射效应和噪声水平不同,导致探测器采集投影数据不一致,影响重建图像质量和材料分解精度^[2]。双能 CT 重建算法可大致分为三类:迭代类重建算法、基于投影域预处理重建算法和基于图像域处理重建算法^[3]。迭代类重建算法对高、低能投影数据根据双能分解模型建模,使用统计迭代类算法获得与材料相关而与能量无关的基图像,该方法重建图像质量较高,但计算量大,求解耗时^[4]。基于投影域预处理重建算法,通过求解高、低能投影方程,将衰减系数分解为材料相关项和能量相关项,并对材料相关项投影运用传统 CT 图像重建算法重建得到基图像^[3]。理论上,该方法能有效抑制射束硬化伪影,得到较准确的图像,但它对双能投影数据的空间一致性和校正精度要求较高。基于图像域后处理重建算法,首先利用传统 CT 图像重建算法对高、低能投影数据分别重建,然后在图像域完成材料分解。此类方法对投影数据的一致性要求不高、计算简单、可消除部分硬化伪影。综合考虑以上算法,本文对第三类算法开展研究。

近年来,考虑到双能 CT 图像的全局相关性和局部相似性,提出了许多基于双能 CT 图像结构相

似性或非局部均值的优化算法,此类算法可在去噪去伪影时,保留图像细节信息,有效提高双能 CT 重建图像质量^[4-6]。压缩感知理论(CS)为不完备投影数据重建提供了新思路,被广泛用于医学图像重建,而基于字典学习(DL)的图像重建算法则是目前研究的热点。自 Xu 等^[7]运用该理论完成低剂量 CT 重建后,字典学习便开始用于双能 CT 和能谱 CT 图像重建,DL 利用图像的稀疏性能较好地抑制噪声,提高重建图像质量^[8-9]。近年来,深度学习算法在 CT 图像处理领域受到广泛关注,基于深度学习的神经网络的双能 CT 图像重建算法也应运而生,该类算法重建图像噪声小、伪影少,不足之处在于该类方法需大量数据集训练网络,且训练时间较长^[10-11]。在材料分解方面,因能量通道的频谱重叠及基函数的相关性,直接求逆分解(DIMD)易引起噪声放大^[12],为提高基图像质量,发展了许多基于正则项约束的分解算法,如总变分(TV)^[13]、总核变化- l_0 范数(TNV- l_0)^[14]、学习变换混合集(MULTRA)^[15]等。此外,随着卷积神经网络在 CT 成像方面的运用,深度学习也逐步用于材料分解,该类方法同样面临着训练样本多、时间长、存储空间大等问题^[16-17]。

双能 CT 能提供物体在两种能谱下的衰减信息,理论上可准确分解两种材料,而重建三种基材料图像的能力在临床和工业上都非常重要。对于三材料分解,可使用多能 CT 采集三组或三组以上的投影数据精确分解,但需要利用光子探测器进行数据采集。本文利用配备积分探测器的普通 CT 完成双能 CT 数据采集,并对采集到的数据进行三材料分解。使用双能 CT 分解三种材料属于不适定问题,易受噪声干扰,为了获得较好的基图像,通常需结合去噪方法,同时增加约束求取最优解。为重建多材料的基图像,Mendonca 等^[18]利用质量和体积分数守恒,假设每像素最多含三种材料,将滤波反投影(FBP)重建的双能 CT 图像直接分解获得多幅基材料图像。此方法在分解材料时忽略了双能图像的统计噪声以及基图像间的先验信息,导致获得的基图像存在较强噪声和伪影。使用类似的约束,Long 等^[19]提出一种惩罚似然函数完成多材料分解。实

验结果表明,该方法能保护基图像边缘,降低噪声和伪影,但存在计算量大,处理效率低等问题。Ding等^[14]利用惩罚加权最小二乘法(PWLS),结合总核变化(TNV)、 ℓ_0 范数以及各基物质体积分数为1的约束项,提出一种基于双能CT图像域的多材料分解算法。该方法实现了双能CT分解多种材料,但获得的基图像存在明显块状伪影,且其组织特征、边缘结构不清晰。

针对以上问题,本文从图像域出发,改进了基于字典学习的能谱CT分解方法,提出一种基于DL^[7]和相对总变分(RTV)^[20]的双能CT多材料分解算法,简称DL-RTV算法。该算法,对双能CT图像直接求逆获得初始基图像,再利用字典学习挖掘基图像之间的稀疏性和关联性,以提高材料分解的准确性;引进RTV正则项进一步降低基图像的伪影和噪声,并保护图像边缘和结构等细节特征;同时引入各基材料质量守恒和像素边界的约束项,提高材料分解精度。仿真和实验研究表明,该算法能使双能CT较准确地分解三种材料,并有效地抑制基图像噪声和伪影,保护图像细节信息,提高材料分解精度。

2 双能CT成像基本原理

2.1 双能CT图像重建原理

根据Lambert-Beer吸收定律^[21],射线 I 通过能量 E 的衰减满足下式,

$$I_{nl} = I_{nl}^{(0)}(E) \exp \left[\int_{r \in l} - \sum_{m=1}^M x_m(E, r) dr \right] dE, \quad (1)$$

式中: I_{nl} ($1 \leq n \leq N$)为第 n 能量通道下的出射强度; $I_{nl}^{(0)}(E)$ 为入射强度; l 为射线穿过物体的路径; M 为被扫描物体中所含材料种类; $x_m(E, r)$ 为第 m 种材料在 r 处的线性衰减系数,显然 $\sum_{m=1}^M x_m(E, r)$ 为所有材料在 r 处的线性衰减系数之和。能谱分解模型中,CT图像上每个像素的线性衰减系数近似等于所有基图像中对应像素的衰减系数之和,为此 $\sum_{m=1}^M x_m(E, r) dr$ 可写成如下形式,

$$\sum_{m=1}^M x_m(E, r) = \sum_{m=1}^M k_m(E) f_m(r), \quad (2)$$

式中: $k_m(E)$ 为能量 E 下第 m 种材料的线性衰减系数; $f_m(r)$ 为第 m 种材料中 r 处的像素。材料分解的最终目的就是求出所有路径下的 $f_m(r)$ ($1 \leq m \leq M$)。

根据(2)式,求 $f_m(r)$ 需先求出 $\sum_{m=1}^M x_m(E, r)$ 。为方

便求解,用物体的平均衰减系数 $\overline{x_n}(E_n)$ 替代 $\sum_{m=1}^M x_m(E, r)$, (1)式可简化为

$$I_{nl}/I_{nl}^{(0)} \approx \exp[-\mathbf{A}\mathbf{x}_n(\overline{E}_n)], \quad (3)$$

式中: \mathbf{A} 为投影矩阵。(3)式可写成投影函数模型,

$$\mathbf{p}_n = -\ln\left(\frac{I_n}{I_n^{(0)}}\right) \approx \mathbf{A}\mathbf{x}_n, \quad (4)$$

式中: \mathbf{x}_n 为通过投影 \mathbf{p}_n 重建的双能CT图像。目前双能CT的图像重建算法已有很多,如最大似然法^[22]、字典学习^[8]等,以及能谱重建相关的算法,如张量字典学习(TDL)^[9]、基于结构先验的加权NLTV重建算法^[23]。

2.2 基于图像域的双能CT分解模型

双效应分解和基材料分解是双能CT中两种常见的线性衰减模型,本文采用基材料分解模型进行材料分解。为从双能图像 \mathbf{x}_n 中获得基图像 f_m , (2)式可进一步写为

$$\begin{bmatrix} k_{11} & \cdots & k_{1M} \\ k_{21} & \cdots & k_{2M} \end{bmatrix} \begin{bmatrix} f_1 \\ \vdots \\ f_M \end{bmatrix} = \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \end{bmatrix}, \quad (5)$$

式中: $\begin{bmatrix} k_{11} & \cdots & k_{1M} \\ k_{21} & \cdots & k_{2M} \end{bmatrix}$ 为系统矩阵,通过从 \mathbf{x}_n 中选取均匀的基材料区域计算而得。(5)式可简化为

$$\mathbf{K}\mathbf{F}_{(3)} = \mathbf{X}_{(3)}, \quad (6)$$

式中: $\mathbf{K} \in \mathbb{R}^{N \times M}$ 代表物质的质量衰减系数,为二阶张量; $\mathbf{F} \in \mathbb{R}^{J_1 \times J_2 \times M}$ 和 $\mathbf{X} \in \mathbb{R}^{J_1 \times J_2 \times N}$ 分别代表基图像和双能CT图像,均为3阶张量; $J_1 \times J_2$ 为图像的宽度和高度。考虑到重建图像中的噪声,(6)式可简化为

$$\mathbf{K}\mathbf{F}_{(3)} + \boldsymbol{\omega} = \mathbf{X}_{(3)}, \quad (7)$$

式中: $\boldsymbol{\omega} \in \mathbb{R}^{J_1 \times J_2 \times M}$ 为图像所含噪声。若直接求解(6)式,则:

$$\mathbf{F}_{(3)} = (\mathbf{K}^T \mathbf{K})^{-1} \mathbf{K}^T \mathbf{X}_{(3)}. \quad (8)$$

此时获得的 $\mathbf{F}_{(3)}$ 含有较强噪声,会降低分解精度且不利于物质识别。为提高 $\mathbf{F}_{(3)}$ 的图像质量,本文采用正则项方法求解,公式为

$$\min_{\mathbf{F}} \left[\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2 + \lambda R(\mathbf{F}) \right], \quad (9)$$

式中: $\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2$ 为数据保真项; $R(\mathbf{F})$ 为正则项;参数 λ 用于平衡保真项和正则项。近年来,为获得高质量的基图像,提出了许多新的 $R(\mathbf{F})$ 如TV、TNV- ℓ_0 、MULTRA。

3 基于双能 CT 图像域的 DL-RTV 多材料分解模型

3.1 字典学习理论

近年来,字典学习在图像恢复、图像去噪、磁共振成像(MRI)等领域得到了广泛地运用。字典学习利用图像稀疏性,对含噪图像训练字典,并通过图像重构以达到去噪的目的。其数学模型为

$$\min_{\mathbf{D}, \boldsymbol{\alpha}} \frac{1}{2} \sum_{i=1}^I \|\mathbf{x}_i - \mathbf{D}\boldsymbol{\alpha}_i\|_F^2, \quad \text{s. t.} \quad \|\boldsymbol{\alpha}_i\|_0 \leq T_0, \quad (10)$$

式中: $\mathbf{x}_i \in \mathbb{R}^{s \times s}$, $i=1, \dots, I$, 为含噪的图像块; $\mathbf{D} \in \mathbb{R}^{s \times T}$ 为稀疏表示的字典; $\boldsymbol{\alpha} \in \mathbb{R}^{T \times I}$ 为稀疏表示系数; $\|\cdot\|_F$ 和 $\|\cdot\|_0$ 分别表示 F 和 ℓ_0 范数; T_0 表示 $\boldsymbol{\alpha}_i$ 的稀疏度水平。字典学习的目的就是训练一个字典 \mathbf{D} 使得每个图像块 \mathbf{x}_i 都可使用字典中的原子稀疏表示。(10)式可简化成无约束模型,

$$\min_{\mathbf{D}, \boldsymbol{\alpha}} \frac{1}{2} \sum_{i=1}^I (\|\mathbf{x}_i - \mathbf{D}\boldsymbol{\alpha}_i\|_F^2 + \beta \|\boldsymbol{\alpha}_i\|_0), \quad (11)$$

式中: β 用于控制 $\boldsymbol{\alpha}_i$ 的稀疏度水平。本文采用 K-奇异值(K-SVD)算法更新字典,利用正交匹配追踪(OMP)方法完成稀疏编码。迄今为止,字典学习在 CT 图像重建中已得到广泛运用,现也逐步用于材料分解。它通过探究基图像之间的稀疏性和相关性,利用图像重构完成去噪。但字典学习在处理复杂图像时因其稀疏表示能力不足,导致处理后的基图像依然含有明显噪声。

3.2 相对总变分理论

Xu 等^[20]通过改进全变分(TV)模型,提出一种相对总变分理论(RTV),用于提取图像结构。该理论是基于加窗总变分(WTV)和加窗固有变分(WIV)而定义的。图像 f 的 RTV 数学模型为

$$\text{RTV}(f_p) = \frac{Q_x(p)}{H_x(p) + \epsilon} + \frac{Q_y(p)}{H_y(p) + \epsilon}, \quad (12)$$

式中: p 为图像像素点; ϵ 用于避免除零。 $Q_x(p)$ 和 $Q_y(p)$ 为 p 在 x 和 y 方向的 WTV,其模型为

$$\begin{cases} Q_x(p) = \sum_{q \in \omega(p)} h_{p,q} \cdot |(\partial_x f)_q| \\ Q_y(p) = \sum_{q \in \omega(p)} h_{p,q} \cdot |(\partial_y f)_q| \end{cases}, \quad (13)$$

式中: $\omega(p)$ 表示以 p 为中心的矩形窗口; q 代表 p 的相邻像素点; $h_{p,q}$ 表示标准差为 σ 的高斯函数;WTV 用于表示 $\omega(p)$ 的梯度信息,其易受图像结构和噪声的影响。同理可知, $H_x(p)$ 和 $H_y(p)$ 为 p 在 x 和 y 方向的 WIV,其模型为

$$\begin{cases} H_x(p) = \left| \sum_{q \in \omega(p)} h_{p,q} \cdot (\partial_x f)_q \right| \\ H_y(p) = \left| \sum_{q \in \omega(p)} h_{p,q} \cdot (\partial_y f)_q \right| \end{cases}. \quad (14)$$

从 RTV 的模型可知,WIV 为 WTV 的自适应加权值,有助于保护图像结构和抑制伪影,为此 RTV 也用于 CT 图像重建以抑制噪声^[24-25]。

3.3 基于 DL-RTV 的多材料分解模型

字典学习因降噪能力不足,导致处理后的基图像依然含明显噪声;而 RTV 可降低图像噪声和伪影,并保护图像细节。为此,本文将 DL 和 RTV 组合,引入 DL+RTV 正则项作为(9)式中的 $R(\mathbf{F})$,提出基于 DL-RTV 的多材料分解算法。构建的目标函数表示为

$$\min_{\mathbf{F}, \{\boldsymbol{\alpha}_m\}_{m=1}^M} \left[\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2 + \sum_{m=1}^M \frac{\lambda_m}{2} \sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{F}_m) - \mathbf{D}\boldsymbol{\alpha}_{mi}\|_F^2 + \beta_{mi} \|\boldsymbol{\alpha}_{mi}\|_0) + \frac{\eta}{2} \|\mathbf{F}_{(3)}\|_{\text{RTV}} \right], \quad (15)$$

式中: \mathbf{F}_m 为第 m 种材料的基图像; $\mathbf{G}_i(\mathbf{F}_m)$ 表示从 \mathbf{F}_m 中提取的第 i 个图像块; $\boldsymbol{\alpha}_{mi}$ 为 $\mathbf{G}_i(\mathbf{F}_m)$ 的稀疏表示。为提高材料分解精度,在(15)式中引入不同基图像中同一位置像素和为 1 的约束项,且 \mathbf{F} 的像素值应在 $[0 \ 1]$,则(15)式可改写为

$$\min_{\mathbf{F}, \{\boldsymbol{\alpha}_m\}_{m=1}^M} \left[\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2 + \sum_{m=1}^M \frac{\lambda_m}{2} \sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{F}_m) - \mathbf{D}\boldsymbol{\alpha}_{mi}\|_F^2 + \beta_{mi} \|\boldsymbol{\alpha}_{mi}\|_0) + \frac{\eta}{2} \|\mathbf{F}_{(3)}\|_{\text{RTV}} \right], \quad \text{s. t.} \\ \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, \quad 1 \leq j_1 \leq J_1, 1 \leq j_2 \leq J_2, \quad 0 \leq \mathbf{F} \leq 1, \quad \forall j_1, j_2, \quad (16)$$

式中: $\mathbf{F}_{j_1 j_2 m}$ 为第 m 种基图像中 (j_1, j_2) 处的像素值; J_1 和 J_2 分别表示图像长度和宽度。为求解目标函数(16)式,引入辅助变量 \mathbf{V} 使得 $\mathbf{V} = \mathbf{F}$,则(16)式可写成如下带约束的函数。

$$\min_{\mathbf{F}, \{\boldsymbol{\alpha}_m\}_{m=1}^M, \mathbf{V}} \left[\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2 + \sum_{m=1}^M \frac{\lambda_m}{2} \sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{V}_m) - \mathbf{D}\boldsymbol{\alpha}_{mi}\|_F^2 + \beta_{mi} \|\boldsymbol{\alpha}_{mi}\|_0) + \frac{\eta}{2} \|\mathbf{V}_{(3)}\|_{\text{RTV}} \right], \\ \text{s. t.} \quad \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, \quad \mathbf{V} = \mathbf{F}, \quad 0 \leq \mathbf{F} \leq 1, \quad \forall j_1, j_2. \quad (17)$$

将(17)式写成无约束的优化模型,

$$\min_{\mathbf{F}, \{\alpha_m\}_{m=1}^M, \mathbf{V}} \left[\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2 + \frac{\theta}{2} \|\mathbf{V} - \mathbf{F}\|_F^2 + \sum_{m=1}^M \frac{\lambda_m}{2} \sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{V}_m) - \mathbf{D}\alpha_{mi}\|_F^2 + \beta_{mi} \|\alpha_{mi}\|_0) + \frac{\eta}{2} \sum_{m=1}^M \|\mathbf{V}_m\|_{\text{RTV}} \right], \text{ s. t. } \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, 0 \leq \mathbf{F} \leq 1, \forall j_1, j_2, \quad (18)$$

式中: θ 为惩罚参数。(18)式可分解为如下子问题,

$$\min_{\mathbf{F}} \left(\frac{1}{2} \|\mathbf{X}_{(3)} - \mathbf{K}\mathbf{F}_{(3)}\|_F^2 + \frac{\theta}{2} \|\mathbf{F} - \mathbf{V}^{(k)}\|_F^2 \right), \text{ s. t. } \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, 0 \leq \mathbf{F} \leq 1, \forall j_1, j_2, \quad (19)$$

$$\min_{\mathbf{V}, \{\alpha_m\}_{m=1}^M} \left[\frac{\theta}{2} \|\mathbf{V} - \mathbf{F}^{(k+1)}\|_F^2 + \sum_{m=1}^M \frac{\lambda_m}{2} \sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{V}_m) - \mathbf{D}\alpha_{mi}\|_F^2 + \beta_{mi} \|\alpha_{mi}\|_0) + \frac{\eta}{2} \sum_{m=1}^M \|\mathbf{V}_m\|_{\text{RTV}} \right]. \quad (20)$$

(19)式可进一步写成像素的形式,

$$\min_{\mathbf{F}} \frac{1}{2} \sum_{j=1}^J \|\mathbf{X}_{(3) \neq j} - \mathbf{K}\mathbf{F}_{(3) \neq j}\|_F^2 + \frac{\theta}{2} \sum_{j_1=1}^{J_1} \sum_{j_2=1}^{J_2} \|\mathbf{F}_{j_1 j_2 \#} - \mathbf{V}_{j_1 j_2}^{(k)}\|_F^2, \text{ s. t. } \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, 0 \leq \mathbf{F}_{j_1 j_2 \#} \leq 1, \forall j_1, j_2, \quad (21)$$

式中: $\mathbf{X}_{(3) \neq j} = [\overline{x_{1j}}, \dots, \overline{x_{Nj}}]^T$; $\mathbf{F}_{(3) \neq j} = [f_{1j}, \dots, f_{Mj}]^T$ 。同理 $\mathbf{F}_{j_1 j_2 \#} = [\mathbf{F}_{j_1 j_2 1}, \dots, \mathbf{F}_{j_1 j_2 M}]^T$, $\mathbf{V}_{j_1 j_2}^{(k)} = [\mathbf{V}_{j_1 j_2 1}^{(k)}, \dots, \mathbf{V}_{j_1 j_2 M}^{(k)}]^T$, $j = j_1 \times j_2$ 。即,

$$\min_{\mathbf{F}} \sum_{j_1=1}^{J_1} \sum_{j_2=1}^{J_2} \left(\frac{1}{2} \|\mathbf{X}_{j_1 j_2 \#} - \mathbf{K}\mathbf{F}_{j_1 j_2 \#}\|_F^2 + \frac{\theta}{2} \|\mathbf{F}_{j_1 j_2 \#} - \mathbf{V}_{j_1 j_2}^{(k)}\|_F^2 \right), \text{ s. t. } \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, 0 \leq \mathbf{F}_{j_1 j_2 \#} \leq 1, \forall j_1, j_2. \quad (22)$$

(22)式可进一步改写成:

$$\min_{\mathbf{F}_{j_1 j_2 \#}} \left(\frac{1}{2} \|\mathbf{X}_{j_1 j_2 \#} - \mathbf{K}\mathbf{F}_{j_1 j_2 \#}\|_F^2 + \frac{\theta}{2} \|\mathbf{F}_{j_1 j_2 \#} - \mathbf{V}_{j_1 j_2}^{(k)}\|_F^2 \right), \text{ s. t. } \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, 0 \leq \mathbf{F}_{j_1 j_2 \#} \leq 1, \forall j_1, j_2. \quad (23)$$

将(23)式化成最小二乘问题:

$$\min_{\mathbf{F}_{j_1 j_2 \#}} \frac{1}{2} \|(\mathbf{K}^T \mathbf{K} + \theta \mathbf{I})\mathbf{F}_{j_1 j_2 \#} - (\mathbf{K}^T \mathbf{X}_{j_1 j_2 \#} + \theta \mathbf{V}_{j_1 j_2}^{(k)})\|_F^2, \text{ s. t. } \left(\sum_{m=1}^M \mathbf{F}_{j_1 j_2 m} \right) = 1, 0 \leq \mathbf{F}_{j_1 j_2 \#} \leq 1, \forall j_1, j_2. \quad (24)$$

此时,(24)式为一个最小二乘函数,用最小二乘法即可求解。

对于(20)式, $\mathbf{V}, \{\alpha_m\}_{m=1}^M$ 的求解可分为两步,首先引入中间变量 \mathbf{J} 替代张量 \mathbf{V} ,可改写成:

$$\min_{\mathbf{V}_m, \{\alpha_m\}_{m=1}^M, \mathbf{J}_m} \left[\frac{\theta}{2} \|\mathbf{J} - \mathbf{F}^{(k+1)}\|_F^2 + \sum_{m=1}^M \frac{\lambda_m}{2} \sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{J}_m) - \mathbf{D}\alpha_{mi}\|_F^2 + \beta_{mi} \|\alpha_{mi}\|_0) + \frac{\omega}{2} \sum_{m=1}^M \|\mathbf{J}_m - \mathbf{V}_m\|_2^2 + \frac{\eta}{2} \sum_{m=1}^M \|\mathbf{J}_m\|_{\text{RTV}} \right]. \quad (25)$$

(25)式可又分为以下两个子问题:

$$\min_{\mathbf{J}, \{\alpha_m\}_{m=1}^M} \sum_{m=1}^M \left\{ \frac{1}{2} \|\mathbf{J}_m - \mathbf{F}_m^{(k+1)}\|_F^2 + \frac{\tau_m}{2} \left[\sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{J}_m) - \mathbf{D}\alpha_{mi}\|_F^2 + \beta_{mi} \|\alpha_{mi}\|_0) \right] \right\}, \quad (26)$$

$$\min_{\mathbf{V}} \sum_{m=1}^M \left(\frac{\omega}{2} \|\mathbf{J}_m - \mathbf{V}_m\|_2^2 + \frac{\eta}{2} \|\mathbf{J}_m\|_{\text{RTV}} \right). \quad (27)$$

(26)式可写成:

$$\min_{\mathbf{J}_m, \alpha_m} \left\{ \frac{1}{2} \|\mathbf{J}_m - \mathbf{F}_m^{(k+1)}\|_F^2 + \frac{\tau_m}{2} \left[\sum_{i=1}^I (\|\mathbf{G}_i(\mathbf{J}_m) - \mathbf{D}\alpha_{mi}^{(k+1)}\|_F^2 + \beta_{mi} \|\alpha_{mi}\|_0) \right] \right\}, 1 \leq m \leq M. \quad (28)$$

(28)式为典型的字典学习模型,求解过程参考文献[7]。通过(28)式求得 \mathbf{J}_m 和稀疏系数 α_m 。在字典学习过程中,需设置稀疏参数 L 和误差精度 ϵ 以及原子数 T 用于控制字典质量和材料分解精度。

(27)式可进一步写成:

$$\min_{\mathbf{V}_m} \|\mathbf{V}_m - \mathbf{J}_m\|_2^2 + \xi \|\mathbf{J}_m\|_{\text{RTV}}, 1 \leq m \leq M. \quad (29)$$

(29)式为典型的 RTV 数学模型,其求解过程参考文献[20]。DL-RTV 求解流程如表 1 所示。

表 1 DL-RTV 求解流程图

Table 1 Flow chart of the DL-RTV solution

Input: $\theta, \epsilon, T, L, K$, and other parameters;
Initialization: $\mathbf{F}^{(0)} = 0, \mathbf{V}^{(0)} = 0, \mathbf{J}^{(0)} = 0, k = 0$.
Step1: Train dictionary
1 Reconstruct dual-energy CT images;
2 Acquire original material images using the DIMD;
3 Train a dictionary employing the K-SVD method.
Step2: Decompose materials
0 For $k = 1:K$ do
1 Update $\mathbf{F}^{(k+1)}$ using Eq. (24);
2 Update $\mathbf{J}, \{\alpha_m\}_{m=1}^M$ using Eq. (28);
3 Update \mathbf{V} using Eq. (29);
4 End for;
Output: Material images tensor \mathbf{F} .

由表 1 可知,DL-RTV 分解算法的实现可分为两步:1)字典训练;2)材料分解。字典训练过程中,首先,需重建双能 CT 图像,本文使用到的重建算法有 FBP、联合迭代重建(SIRT)以及先验图像约束的压缩感知(PICCS)算法。然后,通过选取图像中材料均匀区域计算衰减系数矩阵 \mathbf{K} ,使用 DIMD 获得初始基图像。最后,从基图像中提取图像块并使用 K-SVD 算法训练字典,使得该字典包含基图像的所有信息。本文中,仿真和实验研究训练的字典原子数 T 均设为 512,字典块的大小为 8×8 ,训练 200 次。图 1 为实验所需字典,图 1(a)为仿真数据的字典,图 1(b)和(c)分别为实际数据乌龟和鸡爪的字典。

4 实 验

为验证 DL-RTV 分解算法的有效性和实用性,本节分别进行了仿真实验和实验研究。为评估 DL-RTV 算法,在仿真实验中将其与 DIMD^[12]、TVMD^[26]、DLMD、RTVMD 分解算法进行比较,同




图 1 实验所需字典。(a)仿真数据的字典;
(b)乌龟的字典;(c)鸡爪的字典

Fig. 1 Dictionaries used in the experiments. (a) Dictionary of physical phantom; (b) dictionary of turtle; (c) dictionary of chicken feet

时使用均方根误差(RMSE)、峰值信噪比(PSNR)、结构相似度(SSIM)和特征相似度(FSIM)等指标定量地评价不同算法的分解效果。算法编程环境为 Matlab R2016b Inter(R)Core(TM)i7-8550U CPU @1.80 GHz 2.00 GH。

4.1 仿真实验

为评估 DL-RTV 算法在双能 CT 图像域中分解三种材料的性能,本文使用老鼠胸腔模体作为待测物体,进行仿真实验。实验中,射线源到旋转轴和探测器的距离分别为 132 mm 和 180 mm,探测器单元数为 512,每个探测单元的长度为 0.1 mm,模拟得到模体在 25 kV 和 45 kV 下的 640 个投影,并在投影数据中加入高斯白噪声,以便观察各类算法抑制噪声的能力。此外,为便于评估各类算法,在老鼠体内注入碘对比剂^[27]。图 2 所示为 SIRT 重建的老鼠胸腔图像,图像大小为 $256 \times 256 \times 2$,显示窗口




图 2 老鼠胸腔模体在高、低能通道下的 SIRT 重建结果。
(a)高能重建图像;(b)低能重建图像

Fig. 2 Reconstruction results of mouse thorax phantom by SIRT in high and low energies. (a) High energy reconstruction image; (b) low energy reconstruction image

分别为 $[0 \ 0.046] \text{ cm}^{-1}$ 和 $[0 \ 0.0174] \text{ cm}^{-1}$ 。图 3 为不同算法下三种基材料(骨头、软组织、碘造影剂)的分解结果,每种基材料图像的显示窗口分别为 $[0 \ 0.95] \text{ cm}^{-1}$ 、 $[0 \ 0.9] \text{ cm}^{-1}$ 和 $[0 \ 0.7] \text{ cm}^{-1}$ 。

由图 3 可知,DIMD 获得的基图像含大量噪声,TVMD、DLMD、RTVMD 和 DL-RTV 算法均能降噪,但降噪水平和处理结果却有所不同。通过对比放大区域 A 可知,TVMD 算法虽能抑制图像噪声,但图像边缘模糊且存在明显的块状伪影;RTVMD 算法降噪时会模糊部分细节,但能在一定程度上保护图像边缘。软组织分解结果显示,DLMD 和 DL-

RTV 算法均能降低 DIMD 中所含噪声,同时保留 TVMD 模糊掉的细节信息,最终图像较清晰干净;而 RTVMD 的软组织图像虽边界清晰,但部分强噪声(箭头 1)未能去除,导致图像被噪声覆盖,整体效果较差。比较碘造影剂的放大区域 B 和箭头 2 所指可知,DL-RTV 算法能完全去除碘图像中的噪声,降噪能力明显强于 DLMD 算法,且图像清晰、边缘完整,效果优于 TVMD 和 RTVMD 算法。总的来说,DL-RTV 算法继承了 DLMD 和 RTVMD 算法各自的优点,且弥补了其不足,在提高降噪力度的同时,能保持图像边缘清晰,提高材料分解精度。




图 3 不同算法的材料分解结果。(a)骨头;(b)软组织;(c)碘造影剂

Fig. 3 Material decomposition results by different algorithms. (a) Bone; (b) soft issue; (c) iodine contrast agent

为了更客观地评价 DL-RTV 算法在材料分解中的性能,分别计算每种算法下基图像的 RMSE、

PSNR、SSIM 和 FSIM,其定量评价结果如表 2 所示。由表 2 可知,DIMD 获得的三种基材料图像 RMSE

表 2 不同算法材料分解的定量评估结果

Table 2 Quantitative evaluation results of material decomposition by different algorithms

Item	Material	Method				
		DIMD	TVMD	DLMD	RTVMD	DL-RTV
RMSE	Bone	0.0345	0.0460	0.0313	0.0337	0.0304
	Soft issue issue	0.1256	0.0975	0.0909	0.0957	0.0854
	I	0.0952	0.0655	0.0687	0.0444	0.0592
PSNR	Bone	29.243	26.752	30.103	29.437	30.353
	Soft issue issue	18.023	20.224	20.826	20.382	21.375
	I	20.430	23.678	23.256	27.057	24.555
SSIM	Bone	0.9612	0.9716	0.9822	0.9855	0.9855
	Soft issue issue	0.7228	0.9193	0.9325	0.9359	0.9364
	I	0.6754	0.9843	0.9755	0.9542	0.9904
FSIM	Bone	0.8860	0.9434	0.9528	0.9534	0.9628
	Soft issue issue	0.6637	0.8822	0.9036	0.8962	0.9040
	I	0.5907	0.9352	0.9312	0.9213	0.9358

值很大,PSNR、SSIM 和 FSIM 值均很小,可知该方法的材料分解精度最低。与 DIMD、TVMD、DLMD 各图像指标相比,DL-RTV 分解图像的 RMSE 值最小,SSIM 和 FSIM 值最大,说明此方法分解精度高;同时,其 PSNR 值较大,可知该方法去噪效果好。与 RTVMD 图像指标相比,在骨头和软组织图像中,DL-RTV 算法均较好;在碘图像中,RTVMD 中碘的 RMSE 和 PSNR 值优于 DL-RTV 算法,但其 SSIM 和 FSIM 值却比 DL-RTV 差,这主要是由于碘图像结构简单,RTVMD 通过调高平滑参数,可将图像噪声基本去除,使得其 PSNR 值较高,但平滑过渡,造成图像边缘结构损失,从而降低了 SSIM 和 FSIM 值。通过定性和定量的综合分析可知,DL-RTV 算法较其他四种方法具有更好的图像处理效果和更高的材料分解精度。

4.2 实验研究

为进一步验证 DL-RTV 算法的实用性,本小节进行了两组实验研究。第一组实验采集乌龟在 40 kV 和 80 kV 下的投影数据,该实验中射线源到旋转中心和探测器的距离分别为 100 mm 和 560 mm,探测器单元总数为 2176,每个探测单元的长度为 0.139 mm,使用等角全扫描方式采集 720 个

投影。扫描过程中由于乌龟还存在气息,导致两次扫描的结构存在差异。为不影响分解结果,截断乌龟的头部,图 4 为部分乌龟投影使用 PICCS^[28]重建的图像,其大小为 $512 \times 512 \times 2$,显示窗口分别为 $[0 \ 0.08] \text{ cm}^{-1}$ 和 $[0 \ 0.15] \text{ cm}^{-1}$ 。图 5 为不同算法对骨头、软组织和空气的分解结果,基图像的显示窗口分别为 $[0 \ 0.85] \text{ cm}^{-1}$ 、 $[0 \ 0.9] \text{ cm}^{-1}$ 和 $[0 \ 0.9] \text{ cm}^{-1}$,图 6 为感兴趣区域(ROI) C、D、E 在各算法下的放大图,其显示窗口分别为 $[0.05 \ 0.85] \text{ cm}^{-1}$ 、 $[0 \ 0.9] \text{ cm}^{-1}$ 和 $[0.1 \ 0.65] \text{ cm}^{-1}$ 。




图 4 部分乌龟投影在高、低能通道下的 PICCS 重建结果。

(a) 高能重建图像; (b) 低能重建图像

Fig. 4 Reconstruction results of partial turtle projection by PISCC in high and low energies. (a) High energy reconstruction image; (b) low energy reconstruction image




图 5 不同算法的材料分解结果。(a)骨头;(b)软组织;(c)空气

Fig. 5 Material decomposition results by different algorithms. (a) Bone; (b) soft issue; (c) air

由图 5 可知,DIMD 分解图像含有明显的噪声和伪影,而 DL-RTV 获得的图像噪声小,且边缘清晰,结构完整。对比放大区域 C 和 D 可知,TVMD 能降低图像噪声,但图像边缘模糊,细节损失严重,

且有块状伪影产生;DLMD 虽能降噪,但是降噪能力不足,导致图像中依然含有部分噪声;RTVMD 降噪时能在一定程度上保护图像边缘,但降噪强度过大时,亦会损失边缘和细节信息,并产生块状伪




图 6 放大后的 ROI 区域。(a) DIMD; (b) TVMD; (c) DLMD; (d) RTVMD; (e) DL-RTV
Fig. 6 Magnified ROI area. (a) DIMD; (b) TVMD; (c) DLMD; (d) RTVMD; (e) DL-RTV

影;DL-RTV 可降低噪声和伪影,同时保护骨头和软组织的结构、边缘等细节。比较放大区域 E 和箭头 3、4 可知,DL-RTV 通过降噪和结构处理,将气孔分离,说明该算法不仅去噪能力强,保护图像细节,还能提高材料分解精度,这对双能 CT 技术的发展与应用具有重要的意义。

为充分验证 DL-RTV 在材料分解中的优势,进行了第二组实验研究。本次实验扫描对象为一只鸡爪和 5.0 mg/mL 的碘溶液,采集其在 15 kV 和 25 kV 下的两组投影。该实验中射线源到旋转中心和探测器的距离分别为 352.7 mm 和 435.8 mm,探测器单元总数为 515,每个探测单元的长度为 0.15 mm,使用等角全扫描方式采集 720 个投影。使用 FBP 进行图像重建如图 7 所示,图像大小为 $512 \times 512 \times 2$,显示窗口分别为 $[0 \ 0.4] \text{ cm}^{-1}$ 和 $[0 \ 0.32] \text{ cm}^{-1}$ 。不同算法的材料分解结果如图 8 所示,基图像的显示窗口分别为 $[0 \ 0.95] \text{ cm}^{-1}$ 、 $[0 \ 0.9] \text{ cm}^{-1}$ 和 $[0.1 \ 0.85] \text{ cm}^{-1}$ 。图 9 为区域 F、G 在各算法下的放大图,其显示窗口分别为 $[0.05 \ 0.88] \text{ cm}^{-1}$ 和 $[0.15 \ 0.78] \text{ cm}^{-1}$ 。由图 8 可知,DIMD 获得的基图像含噪声最多,在软组织和碘溶液的图像中表现最明显。软组织分解结果表明,TVMD、DLMD、RTVMD 和 DL-RTV 算法均能降噪,但 TVMD 易造成图像过度平滑,产生块状伪影(如箭头 5 所示);RTVMD 难以去除一些较强噪声,使得图像整体效果较差,在放大区域 F 中表现尤为明显。对比 ROI-F 和箭头 6 可知,DL-RTV 能在降噪时,保护图像的结构并保持边缘清晰。比较放大

区域 G 可知,DL-RTV 降噪能力明显强于前四种。总的来说,与其他四种算法相比,DL-RTV 算法能抑制图像噪声,保护图像结构和边缘信息,提高材料分解精度,进而获得高质量的基图像。




图 7 鸡爪在高、低能通道下的 FBP 重建结果。
(a) 高能重建图像; (b) 低能重建图像

Fig. 7 Reconstruction results of chicken feet by FBP in high and low energies. (a) High energy reconstruction image; (b) low energy reconstruction image

5 结 论

本文针对双能 CT 分解三种材料存在精度低、噪声大等问题,提出一种基于双能 CT 的 DL-RTV 多材料分解算法。该算法从图像域出发,不仅继承了 DLMD 编码基图像的稀疏性和相似性的优势,而且通过引入 RTV 正则项,可进一步降低噪声并保护图像细节,同时在该模型加入基物质质量守恒和像素边界的约束,以提高材料分解精度。仿真实验结果表明,因能量通道的频谱重叠及基函数的相关性,DIMD 会引起基图像噪声放大,降低材料分解精




图 8 不同算法的材料分解结果。(a)骨头;(b)软组织;(c)碘溶液

Fig. 8 Material decomposition results by different algorithms. (a) Bone; (b) soft issue; (c) iodine




图 9 放大后的 ROI 区域。(a) DIMD; (b) TVMD; (c) DLMD; (d) RTVMD; (e) DL-RTV

Fig. 9 Magnified ROI area. (a) DIMD; (b) TVMD; (c) DLMD; (d) RTVMD; (e) DL-RTV

度;TVMD 能有效降噪,但由于其对所有图像梯度施加相同的惩罚,导致图像边缘模糊并产生块状伪影;DLMD 利用图像稀疏性,通过图像重构实现去噪,但因其稀疏表示能力有限,导致图像不能完全去噪。RTVMD 能在一定程度上把图像边界和图像噪声对应的梯度分开,并进行不同程度的惩罚,以此达到保护图像边界并抑制噪声的目的,但当图像噪声较强时,RTVMD 会因难以去除较强噪声导致图像被噪声覆盖,图像效果较差;若强制去噪,则会损失图像边缘等细节信息,并产生块状伪影。DL-RTV 通过组合字典学习和 RTV,先使用字典学习降噪,再利用 RTV 中 WIV 可进一步降低图像噪声和伪影,同时保护图像结构,与前四种算法相比,该算法在材料分解中更具优势。通过定量地对比各分解算法的图像指标,发现 DL-RTV 各项指标均较

好。为进一步验证该算法的有效性和实用性,进行了两组实验研究,结果均表明,DL-RTV 更能够提高基图像质量和材料分解精度。

DL-RTV 是一种基于图像域的材料分解算法,能从低质量的双能 CT 图像中较准确地分解三种材料,同时有效去除基图像中的噪声和伪影,但仍存在一些问题,如图像处理步骤较多,且模型中参数众多,难以调到最优;并且,该模型下的基图像仍存在噪声和伪影。另外,在实验中只分解了三种材料,当需重建三种以上材料的图像时,DL-RTV 算法的有效性还未评估和验证。总的来说,本文提出的 DL-RTV 算法,能较准确地分解三种材料,这对双能 CT 在图像域中进行材料分解和物质识别具有重要的意义。后续可继续改进该算法,优化参数,探究其分解三种以上材料时的性能,亦或探究新的正则项

$R(\mathbf{F})$, 继续分析双能 CT 分解多种材料的能力, 为扩展其在医疗、安检等方面的应用做理论研究。

参 考 文 献

- [1] Alvarez R E, Macovski A. Energy-selective reconstructions in X-ray computerized tomography [J]. *Physics in Medicine and Biology*, 1976, 21(5): 733-744.
- [2] Rebuffel V, Dinten J M. Dual-energy X-ray imaging: benefits and limits[J]. *Insight-Non-Destructive Testing and Condition Monitoring*, 2007, 49(10): 589-594.
- [3] Li L, Wang L Y, Cai A L, et al. Projection decomposition algorithm for X-ray dual-energy computed tomography based on isotransmission line fitting[J]. *Acta Optica Sinica*, 2016, 36(8): 0834001. 李磊, 王林元, 蔡爱龙, 等. 基于等值线拟合的 X 射线双能 CT 快速投影分解算法[J]. *光学学报*, 2016, 36(8): 0834001.
- [4] Sukovic P, Clinthorne N H. Penalized weighted least-squares image reconstruction for dual energy X-ray transmission tomography[J]. *IEEE Transactions on Medical Imaging*, 2000, 19(11): 1075-1081.
- [5] Zhang H, Zeng D, Lin J, et al. Iterative reconstruction for dual energy CT with an average image-induced nonlocal means regularization[J]. *Physics in Medicine and Biology*, 2017, 62(13): 5556-5574.
- [6] Li Y J, Hao J, Jin X, et al. Towards dose reduction for dual-energy CT: a non-local image improvement method and its application[J]. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 2015, 770: 211-217.
- [7] Xu Q, Yu H Y, Mou X Q, et al. Low-dose X-ray CT reconstruction via dictionary learning[J]. *IEEE Transactions on Medical Imaging*, 2012, 31(9): 1682-1697.
- [8] Xu Q, Xing L, Xiong G, et al. Dictionary learning based quantitative reconstruction for low-dose dual-energy CT (DECT) [J]. *Medical Physics*, 2015, 42(6): 3250-3251.
- [9] Zhang Y B, Mou X Q, Wang G, et al. Tensor-based dictionary learning for spectral CT reconstruction[J]. *IEEE Transactions on Medical Imaging*, 2017, 36(1): 142-154.
- [10] Han Y, Kang J G, Ye J C. Deep learning reconstruction for 9-view dual energy CT baggage scanner [J]. *Proceedings of SPIE*, 2018, 10632: 1063204.
- [11] Rogers T W, Jaccard N, Griffin L D. A deep learning framework for the automated inspection of complex dual-energy X-ray cargo imagery [J]. *Proceedings of SPIE*, 2017, 1018: 101870L.
- [12] Kelcz F, Joseph P M, Hilal S K. Noise considerations in dual energy CT scanning [J]. *Medical Physics*, 1979, 6(5): 418-425.
- [13] Dong X, Niu T Y, Zhu L. Combined iterative reconstruction and image-domain decomposition for dual energy CT using total-variation regularization [J]. *Medical Physics*, 2014, 41(5): 051909.
- [14] Ding Q Q, Niu T Y, Zhang X Q, et al. Image-domain multimaterial decomposition for dual-energy CT based on prior information of material images[J]. *Medical Physics*, 2018, 45(8): 3614-3626.
- [15] Li Z P, Ravishankar S, Long Y, et al. DECT-MULTRA: dual-energy CT image decomposition with learned mixed material models and efficient clustering[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(4): 1223-1234.
- [16] Zhang W K, Zhang H M, Wang L Y, et al. Image domain dual material decomposition for dual-energy CT using butterfly network [J]. *Medical Physics*, 2019, 46(5): 2037-2051.
- [17] Xu Y, Yan B, Zhang J F, et al. Image decomposition algorithm for dual-energy computed tomography via fully convolutional network [J]. *Computational and Mathematical Methods in Medicine*, 2018, 2018: 1-9.
- [18] Mendonça P R S, Lamb P, Sahani D V. A flexible method for multi-material decomposition of dual-energy CT images[J]. *IEEE Transactions on Medical Imaging*, 2014, 33(1): 99-116.
- [19] Long Y, Fessler J A. Multi-material decomposition using statistical image reconstruction for spectral CT [J]. *IEEE Transactions on Medical Imaging*, 2014, 33(8): 1614-1626.
- [20] Xu L, Yan Q, Xia Y, et al. Structure extraction from texture via relative total variation [J]. *ACM Transactions on Graphics*, 2012, 31(6): 1-10.
- [21] Mihailidis D. Computed tomography from photon statistics to modern cone-beam CT[J]. *Medical Physics*, 2009, 36(8): 3858.
- [22] Fessler J A, Elbakri I A, Sukovic P, et al. Maximum-likelihood dual-energy tomographic image reconstruction[J]. *Proceedings of SPIE*, 2002, 4684: 38-49.
- [23] Zhang H J, Kong H H, Sun Y G. Weighted NLTV reconstruction algorithm based on structural prior information for spectral CT [J]. *Acta Optica Sinica*, 2018, 38(8): 0811003. 张海娇, 孔慧华, 孙永刚. 基于结构先验的加权

- NLTV 能谱 CT 重建算法 [J]. 光学学报, 2018, 38(8): 0811003.
- [24] Gong C C, Zeng L, Wang C X. Image reconstruction model for limited-angle CT based on prior image induced relative total variation[J]. Applied Mathematical Modelling, 2019, 74: 586-605.
- [25] Gong C C, Zeng L. Adaptive iterative reconstruction based on relative total variation for low-intensity computed tomography[J]. Signal Processing, 2019, 165: 149-162.
- [26] Guo X Y, Zhang L, Xing Y X. A TV-constrained decomposition method for spectral CT[J]. Proceedings of SPIE, 2017, 1013: 101323F.
- [27] Chen P J, Feng P, Wu W W, et al. Material discrimination by multi-spectral CT based on image total variation and tensor dictionary[J]. Acta Optica Sinica, 2018, 38(11): 1111002.
陈佩君, 冯鹏, 伍伟文, 等. 基于图像总变分和张量字典的多能谱 CT 材料识别研究 [J]. 光学学报, 2018, 38(11): 1111002.
- [28] Lauzier P T, Tang J, Chen G H. Time-resolved cardiac interventional cone-beam CT reconstruction from fully truncated projections using the prior image constrained compressed sensing (PICCS) algorithm [J]. Physics in Medicine and Biology, 2012, 57(9): 2461-2476.