



DOI: 10.12086/oe.2021.210211

多通道联合的广义总变分 能谱 CT 重建

连祥媛^{1,2}, 孔慧华^{1,2}, 潘晋孝^{1,2*},
高文波^{1,2}, 王攀³

¹中北大学理学院, 山西 太原 030051;

²信息探测与处理山西省重点实验室, 山西 太原 030051;


³湖南云箭集团有限公司, 湖南 辰溪 419503

摘要: 基于光子计数探测器的能谱 CT 在材料分解、组织表征、病变检测等应用中具有巨大的潜力。在重建过程中, 通道数的增加会造成单通道中光子数减少, 从而导致重建图像质量下降, 难以满足实际需求。本文从能谱 CT 重建的角度出发, 将广义总变分向量延伸, 利用奇异值的稀疏性, 促进图像梯度的线性依赖, 提出一种基于核范数的多通道联合广义总变分的能谱 CT 重建算法。在图像重建过程中, 多层共享结构信息, 同时保留独特的差异。实验结果表明, 本文提出的算法在抑制噪声的同时, 能够更有效地恢复图像细节及边缘信息。

关键词: CT 重建; 能谱 CT; 广义总变分; 核范数; 多通道联合

中图分类号: TP391

文献标志码: A



连祥媛, 孔慧华, 潘晋孝, 等. 多通道联合的广义总变分能谱 CT 重建[J]. 光电工程, 2021, 48(9): 210211

Lian X Y, Kong H H, Pan J X, et al. Joint multi-channel total generalized variational algorithm for spectral CT reconstruction[J].

Opto-Electron Eng, 2021, 48(9): 210211

Joint multi-channel total generalized variational algorithm for spectral CT reconstruction

Lian Xiangyuan^{1,2}, Kong Huihua^{1,2}, Pan Jinxiao^{1,2*}, Gao Wenbo^{1,2}, Wang Pan³

¹School of Science, North University of China, Taiyuan, Shanxi 030051, China;

²Shanxi Key Laboratory of Signal Capturing & Processing, North University of China, Taiyuan, Shanxi 030051, China;

³Hunan Vsngusrd Group. Co. Ltd, Chenxi, Hunan 419503, China

Abstract: Spectral computed tomography (CT) based on photon-counting detectors, has great potential in material decomposition, tissue characterization, lesion detection, and other applications. During the reconstruction, the increase of the number of channels will reduce the photon number in a single channel, resulting in the decline of the quality of the reconstructed image, which is difficult to meet the actual needs. To improve the quality of image reconstruction, joint multi-channel total generalized variational based on the unclear norm for spectral CT reconstruction was proposed in this paper. The algorithm will extend total generalized variation to the vector, and the sparsity of

收稿日期: 2021-06-23; 收到修改稿日期: 2021-08-26

基金项目: 国家自然科学基金资助项目(61801437, 61871351, 61971381)

作者简介: 连祥媛(1994-), 女, 硕士研究生, 主要从事图像重建与图像处理方面的研究。E-mail: 1393550566@qq.com

通信作者: 潘晋孝(1966-), 男, 博士, 教授, 主要从事信息处理与图像重建方面的研究。E-mail: panjx@nuc.edu.cn

版权所有©2021 中国科学院光电技术研究所

singular values is used to promote the linear dependence of the image gradient. The structural information of the multi-channel image is shared during the image reconstruction process while unique differences are preserved. Experimental results show that the proposed algorithm can effectively recover image details and marginal information while suppressing noise.

Keywords: CT reconstruction; spectral CT; total generalized variation; nuclear norm; joint multi-channel

1 引言

在基于光子计数探测器(photon-counting detector, PCD)的能谱 CT^[1]中, PCD 技术消除了电子噪声, 提供了比传统 CT 探测器更高的信噪比^[2]。然而, PCD 技术仍然存在两个主要的问题, 首先, 单个能量通道只包含总光子的一小部分; 其次, 大部分 PCD 只能承受有限的计数率, 所以从 PCD 获得的多通道投影通常包含非常强的泊松噪声。因此, 开发能谱 CT 重建算法对于改善临床应用具有重要意义^[3]。

压缩感知理论的出现, 使正则化约束项的迭代类重建算法发挥出巨大的潜力。能谱 CT 重建中, 正则化约束项以先验图像引导和稀疏性条件为主。先验图像引导以 Yu 采用全光谱图像作为先验图像的压缩感知(prior image constrained compressed sensing, PICCS)算法^[4]为代表, 稀疏性条件^[5-8]包括全变分、紧框架、小波和字典学习等已被应用于 CT 重建, 并取得了不同程度的成功。受空间域信息相关性的启发, Zhang 等^[9]将总变分与能谱均值相结合, 提高重建图像的质量。Li 等^[10]提出一种能谱非局部均值的方法, 利用图像相关性来抑制噪声和条纹伪影。Hu 等^[11]利用张量字典块的稀疏性表示来提高重建质量。陈佩君等^[12]提出一种总变分与传统张量字典学习结合的重建算法, 可进一步恢复图像的微小结构, 有效抑制噪声。为了更好地利用能谱 CT 在能量轴方向的信息相关性, Rigie 等^[13]将总变分向矢量延伸, 提出了总核变分(total nuclear variation, TNV)正则化方法, 可以更好地保存图像特征。Niu 等^[14]提出了一种 alpha 发散约束的广义总变分(total generalized variation, TGV)方法用于稀疏视角 X 射线 CT 图像重建, 有效地消除总变分正则化中经常出现的阶梯状和斑片状伪影。

为了更好地使用空间的结构信息, 本文将单通道的 TGV 向矢量延伸, 提出一种基于核函数的多通道联合 TGV 的能谱重建算法, 简称 Mutli-NTGV。利用核范数作为约束, 增强通道间耦合, 恢复图像的结构特征。

2 理论推导

2.1 单通道 TGV 正则化

2010 年, Kristian 等^[15]提出了 TGV 函数的新概念, 将 TGV 函数作为单通道图像重建的正则化, 克服了现有的基于导数的正则化方法的缺陷。TGV 正则化使用辅助变量来平衡图像的一阶和二阶导数, 同时仍然允许恢复锐利的边缘。对于大小为 $M \times N$ 单幅图像 $u_0 \in U$, $U = R^{M \times N}$, 二阶 TGV 函数表示为

$$R(u_0) = \min_{w_0} \alpha_0 \|\nabla u_0 - w_0\|_1 + \alpha_1 \|\varepsilon(w_0)\|_1, \quad (1)$$

其中: w_0 是图像域的二阶对称张量, $\varepsilon(w_0)$ 是对称梯度算子, $\|\cdot\|_1$ 为矩阵的“1”范数, α_0 和 α_1 为平衡系数。该正则项的平衡是通过减去向量场 w_0 来实现的, 而这个向量场又通过一个对称梯度算子 $\varepsilon(w_0) = \frac{1}{2}(\nabla w_0 + \nabla w_0^T)$ 来抵消。

2.2 基于核范数的多通道 TGV 正则化

对于多通道的能谱 CT 图像 $u = (u_1, u_2, \dots, u_L)^T \in U^L$ 来说, 梯度信息中包含图像结构化信息与特征。逐通道的重建算法, 会忽略通道间的结构相似性。2014, Rigie 等^[13]将单通道的梯度向量推广到矢量场, 定义出了离散的雅可比矩阵 $J_u \in U^{L \times 2}$, 形式如下:

$$J_u(i, j) = \begin{bmatrix} (u_1)_x(i, j) & (u_1)_y(i, j) \\ (u_2)_x(i, j) & (u_2)_y(i, j) \\ \vdots & \vdots \\ (u_L)_x(i, j) & (u_L)_y(i, j) \end{bmatrix}, \quad (2)$$

其中: $(u_l)_x(i, j)$, $(u_l)_y(i, j)$ 表示第 l 个通道中 u_l 的水平与垂直方向的梯度, L 表示能谱通道的通道数, $J_u(i, j)$ 表征各个通道下位置 (i, j) 处图像的梯度信息。

当两幅图像拥有相同的曲线时, 两幅图像具有相同方向的梯度, 反之亦然^[16]。如果各通道图像的所有梯度向量是平行的或反平行的, 那么雅可比矩阵的秩将是 1, 因此只有一个非零奇异值。在此基础上, 若各通道间图像梯度平行, 会使得核范数最小, 将 TGV 推向矢量场形式如下:

$$R_N(\mathbf{u}) = \alpha_0 \|\nabla \mathbf{u} - \mathbf{w}\|_{l, \text{nuc}} + \alpha_1 \|\varepsilon(\mathbf{w})\|_{l, \text{Frob}} \quad (3)$$

TGV 矢量化是通过对 $\nabla \mathbf{u} - \mathbf{w}$ 与 $\varepsilon(\mathbf{w})$ 的秩进行像素级惩罚来诱导图像通道之间的紧密耦合。第一项整理为更简单的形式:

$$\|\nabla \mathbf{u} - \mathbf{w}\|_{l, \text{nuc}} = \left\| \left\| (\nabla \mathbf{u} - \mathbf{w})(i, j) \right\|_{\text{nuc}} \right\|_l$$

类似地:

$$\|\varepsilon(\mathbf{w})\|_{l, \text{Frob}} = \left\| \left\| \varepsilon(\mathbf{w})(i, j) \right\|_{\text{Frob}} \right\|_l$$

其中:

$$\left\| (\nabla \mathbf{u} - \mathbf{w})(i, j) \right\|_{\text{nuc}} = \|\sigma\|_1$$

σ 是 $(\nabla \mathbf{u} - \mathbf{w})(i, j)$ 矩阵的奇异值向量, $\|\cdot\|_{\text{Frob}}$ 为矩阵中所有元素的平方和, 称为矩阵的 F 范数。

矢量场的离散梯度算子为

$$\nabla: U^L \rightarrow U^{L \times 2}$$

对称化梯度算子为

$$\varepsilon: U^{L \times 2} \rightarrow U^{L \times 4}$$

$$\nabla \mathbf{u}(i, j) = \mathbf{J}_u(i, j), \quad \mathbf{w} \in U^{L \times 2}, \quad \varepsilon(\mathbf{w}) \in U^{L \times 4}$$

若:

$$\mathbf{w} = \begin{bmatrix} w_{11} & w_{21} & \cdots & w_{L1} \\ w_{12} & w_{22} & \cdots & w_{L2} \end{bmatrix}^T$$

则:

$$\varepsilon(\mathbf{w}) = \begin{bmatrix} \partial_x^- w_{11} & \frac{\partial_x^- w_{11} + \partial_y^- w_{12}}{2} & \frac{\partial_y^- w_{11} + \partial_x^- w_{12}}{2} & \partial_y^- w_{12} \\ \partial_x^- w_{21} & \frac{\partial_x^- w_{21} + \partial_y^- w_{22}}{2} & \frac{\partial_y^- w_{21} + \partial_x^- w_{22}}{2} & \partial_y^- w_{22} \\ \vdots & \vdots & \vdots & \vdots \\ \partial_x^- w_{L1} & \frac{\partial_x^- w_{L1} + \partial_y^- w_{L2}}{2} & \frac{\partial_y^- w_{L1} + \partial_x^- w_{L2}}{2} & \partial_y^- w_{L2} \end{bmatrix}$$

其中: ∂_x^- , ∂_y^- 表示水平方向与垂直方向的一阶向后差分, $w_{ij} \in U$ 。

3 算法模型

3.1 基于核范数的多通道联合 TGV 能谱 CT 重建算法

在能谱 CT 的不同能量通道下, 图像的梯度信息是相似的。为了更好地克服基于导数的正则化方法的缺陷, 有效地利用通道间的结构化信息。提出一种基于核范数的多通道联合 TGV 能谱 CT 重建算法, 其目标函数可以表述为以下凸极小化问题:

$$\min_{\mathbf{u}} \lambda \|\mathbf{A}\mathbf{u} - \mathbf{g}\|_2^2 + R_N(\mathbf{u}) \quad (4)$$

其中: \mathbf{A} 为投影矩阵, $\mathbf{g} = (\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_L)^T$ 表示各通道的投影数据总体, \mathbf{g}_l 表示第 l 通道中的投影数据, L 代表通道的个数。式(4)中第一项为模型的数据保真项,

λ 为保真项系数, 第二项为多通道联合 TGV 正则化项。

3.2 模型求解

考虑到目标函数的不可微性与三维矩阵数据过大的计算量, 本文采用交替优化的方法求解。引入变量 \mathbf{v} , 将式(4)无约束化问题转变为约束化问题:

$$\min_{\mathbf{u}, \mathbf{v}} \frac{\lambda}{2} \|\mathbf{A}\mathbf{u} - \mathbf{g}\|_2^2 + R_N(\mathbf{v}) \quad \text{s.t. } \mathbf{u} = \mathbf{v} \quad (5)$$

式(5)通过增加惩罚项 $\frac{\mu}{2} \|\mathbf{u} - \mathbf{v}\|_2^2$, 可以转化为另一个无约束的优化函数, 整理为

$$\min_{\mathbf{u}, \mathbf{v}} \frac{\lambda}{2} \|\mathbf{A}\mathbf{u} - \mathbf{g}\|_2^2 + R_N(\mathbf{v}) + \frac{\mu}{2} \|\mathbf{u} - \mathbf{v}\|_2^2 \quad (6)$$

式(6)中含有两个变量, 可以采用交替迭代的方法优化, 将上述式子分裂成两个子问题:

$$\min_{\mathbf{u}} \frac{\lambda}{2} \|\mathbf{A}\mathbf{u} - \mathbf{g}\|_2^2 + \frac{\mu}{2} \|\mathbf{u} - \mathbf{v}\|_2^2 \quad (7)$$

$$\min_{\mathbf{v}} R_N(\mathbf{v}) + \frac{\mu}{2} \|\mathbf{u} - \mathbf{v}\|_2^2 \quad (8)$$

在式(7)中采用梯度下降法来求解 $\mathbf{u}^{(k+1)}$, 则:

$$\mathbf{u}^{(k+1)} = \mathbf{u}^{(k)} - \left[\lambda \mathbf{A}^T (\mathbf{A}\mathbf{u} - \mathbf{g}) + \mu (\mathbf{u}^{(k)} - \mathbf{v}^{(k)}) \right] \quad (9)$$

采用一阶原始-对偶算法^[17]来近似求解方程(8)的全局最优解, 将上述的最小化问题重新表述为鞍点问题。首先引入近端映射的概念, 对于函数 $f(\xi)$, 近端映射定义为

$$\text{prox}_{f, \gamma}(\xi) = \arg \min_{\psi} f(\psi) + \frac{\|\psi - \xi\|_2^2}{2\gamma} \quad (10)$$

重新整理正则项的形式, 将式(9)的最小化问题表述为

$$\min_{\mathbf{v}, \mathbf{w}} \alpha_0 \|\nabla \mathbf{u} - \mathbf{w}\|_{l, \text{nuc}} + \alpha_1 \|\varepsilon(\mathbf{w})\|_{l, \text{Frob}} + I_C(\mathbf{v}) \quad (11)$$

其中: $I_C(\mathbf{v})$ 为凸指标函数。为了更加便于计算, 令 $H(\mathbf{v}) = I_C(\mathbf{v})$ 引入辅助变量 \mathbf{p} , \mathbf{q} , 整理为

$$\min_{\mathbf{y}=(\mathbf{v}, \mathbf{w})} \min_{\mathbf{z}=(\mathbf{p}, \mathbf{q}, \mathbf{u})} \langle \nabla \mathbf{v} - \mathbf{w}, \mathbf{p} \rangle + \langle \varepsilon(\mathbf{w}), \mathbf{q} \rangle + \langle \mathbf{v}, \mathbf{u} \rangle + H(\mathbf{v}) \quad (12)$$

采用一阶原始-对偶算法解决上述鞍点问题。

具体的迭代步骤为

Step1: 利用近端映射函数, 更新辅助变量 $\mathbf{p}^{(k+1)}$, $\mathbf{q}^{(k+1)}$:

$$\mathbf{p}^{(k+1)} = \text{prox}_{\alpha_1}(\mathbf{p}^{(k)} + \sigma(\nabla(\bar{\mathbf{v}})^{(k)} - \bar{\mathbf{w}}^{(k)})) \quad (13)$$

$$\mathbf{q}^{(k+1)} = \text{prox}_{\alpha_0}(\mathbf{q}^{(k)} + \sigma(\varepsilon(\bar{\mathbf{w}}^{(k)}))) \quad (14)$$

Step2: 更新图像变量 $\mathbf{v}^{(k+1)}$ 与对称张量 $\mathbf{w}^{(k+1)}$

$$\mathbf{v}^{(k+1)} = \text{prox}_C \left(\frac{\mathbf{v}^{(k+1)} + \tau(\nabla^{-1}(\mathbf{p}^{(k+1)}) + \mu(\mathbf{u}^{(k+1)} - \mathbf{v}^{(k)}))}{1 + \tau\mu} \right) \quad (15)$$

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k+1)} + \tau(\mathbf{p}^{(k+1)} + \varepsilon^{-1}(\mathbf{q}^{(k+1)})) \quad (16)$$

其中：离散梯度算子的逆算子为

$$\nabla^{-1} : U^{L \times 2} \rightarrow U^L,$$

对称化算子的逆算子为

$$\varepsilon^{-1} : U^{L \times 4} \rightarrow U^{L \times 2}.$$

Step3: 更新图像变量与对称张量的对偶变量

$\bar{\mathbf{v}}^{(k+1)}, \bar{\mathbf{w}}^{(k+1)}$:

$$\bar{\mathbf{v}}^{(k+1)} = 2\mathbf{v}^{(k+1)} - \mathbf{v}^{(k)}, \quad (17)$$

$$\bar{\mathbf{w}}^{(k+1)} = 2\mathbf{w}^{(k+1)} - \mathbf{w}^{(k)}. \quad (18)$$

能谱的 Mutil-NTGV 算法步骤:

初始化:

$$p^0=0, q^0=0, w^0 = \bar{w}^0 = 0, u^0 = v^0 = 0,$$

$$\bar{v}^0 = 0, k=0, \text{maxloop}=30;$$

主循环: 当 $k < \text{maxloop}$ 时, 执行循环;

利用式(9)更新 $\mathbf{u}^{(k+1)}$;

利用式(13)、式(14)更新辅助变量 $\mathbf{p}^{(k+1)}, \mathbf{q}^{(k+1)}$;

利用式(15)、式(16)更新图像变量 $\mathbf{v}^{(k+1)}$ 与结构化变量 $\mathbf{w}^{(k+1)}$;

利用式(17)、式(18)更新 $\mathbf{v}^{(k+1)}, \mathbf{w}^{(k+1)}$ 的对偶变量 $\bar{\mathbf{v}}^{(k+1)}, \bar{\mathbf{w}}^{(k+1)}$;

直到 $k = \text{maxloop}$, 循环结束, 输出 $\mathbf{u}^{(\text{maxloop})}$ 。

4 实验结果

4.1 实验设置

为验证本文算法的有效性, 采用滤波反投影重建算法(FBP)、联合代数重建算法(SART)、总变分正则项的迭代重建算法(TV)、基于张量的字典学习算法(TDL)、广义总变分正则化的迭代重建算法(TGV)为比较算法。所用算法都是用 MATLAB 和 C++的混合模式实现的, 接口在 MATLAB 中实现, 所有的大规模计算部分在 C++中实现, 并通过 MEX 函数进行编译。本文采用峰值信噪比(PSNR)、归一化均方根误差(NRMSE)与结构相似度指数(SSIM)定量评价各方法性能, 验证算法的有效性。

4.2 小鼠胸腔仿真实验

仿真实验采用小鼠胸腔切片为测试模型, 血液循环中加入 1.2%的碘造影剂, 模拟电压设置为 50 kV, 将宽能谱分为 4 个通道: [11, 27) keV, [27, 32) keV, [32, 38) keV, [38, 50) keV。投影数据采用等距扇形束几何, 其中 X 射线源到旋转中心的距离为 100 mm, 物体半径为 10 mm, 探测器长度为 20 mm, 探测器有 320 个单元, 单次扫描在 $[0, 2\pi)$ 均匀收集 360 个角度的

投影, 每条 X 射线的光子数为 30000, 投影数据中产生的噪声服从泊松分布, 重建图像的分辨率为 512×512 。在 Mutil-NTGV 方法中, 参数值的选择, 通过多次实验确定, 分别为 $\lambda=50, \mu=0.2, \alpha_0=\sqrt{2}, \alpha_1=1, \sigma=10/\sqrt{12}, \tau=\sigma/100$ 。

图 1 为 FBP、SART、TV、TDL、TGV 与 Multi-NTGV 算法迭代 30 次的重建效果图。

从图 1 可以看出, FBP、SART 重建的结果中噪声很强, TDL、TGV 与 Mutli-NTGV 都可以不同程度地减少各个能谱通道下噪声的影响。在重建效果的对比中, 可以明显地看出 TV 在平滑噪声的过程中, 容易产生阶梯状伪影, 导致重建效果不佳。TDL 平滑效果较好, 但无法区别噪声与细节, 局部去噪效果不佳。TGV 很好地克服了 TV 中所产生的阶梯伪影的状况, 保存更多的细节, 但在边缘部分会产生一点弱化的效果。本文提出的方法利用了通道间的结构化信息, 不仅有效地抑制了噪声, 而且对于微小的结构也保持得很好, 边缘更加清晰。

五种算法重建过程中的 NRMSE、PSNR 与 SSIM 指标如图 2 所示, FBP 重建效果的评价指标如表 1 所示。由图 2 可以看出, 在前三个通道中, 本文所提出的算法明显优于其他算法, 在第四通道中, 虽然 Mutli-NTGV 算法与 TDL、TGV 的数量性评价结果相近, 但是从重建图效果可以看出 Mutli-NTGV 方法优于其他方法。实验结果表明, 本文所提的方法在各个通道中, 会保持较大的优势, 极大地提升了重建图像的质量。

4.3 临床小鼠实验

为了进一步验证所提出方法的有效性, 采用了 MARS(Medipix All Resolution System)微型 CT 上采集的来自真实临床前小鼠的投影。电压设置为 120 kV, 电流为 175 mA。从照射源到系统原点的距离为 158 mm, 到探测器的距离为 255 mm。在整个扫描范围内均匀收集了 13 个能量通道的 371 个投影视图。探测器一行 1024 个元素, 单位长度为 $55 \mu\text{m}$ 。

图 3 为各算法对临床前小鼠的重建效果图, 从上到下依次展示的是第 1、3、5 和 7 通道的效果图。实际小鼠切片实验中, 各算法重建结果与小鼠胸腔仿真实验类似, FBP 与 SART 重建效果中含有大量的噪声, 其余方法都在一定程度上达到了去噪的效果, 从实验结果可以明显看出, 在各个重建算法中, Mutli-NTGV 在临床小鼠的重建效果较好。

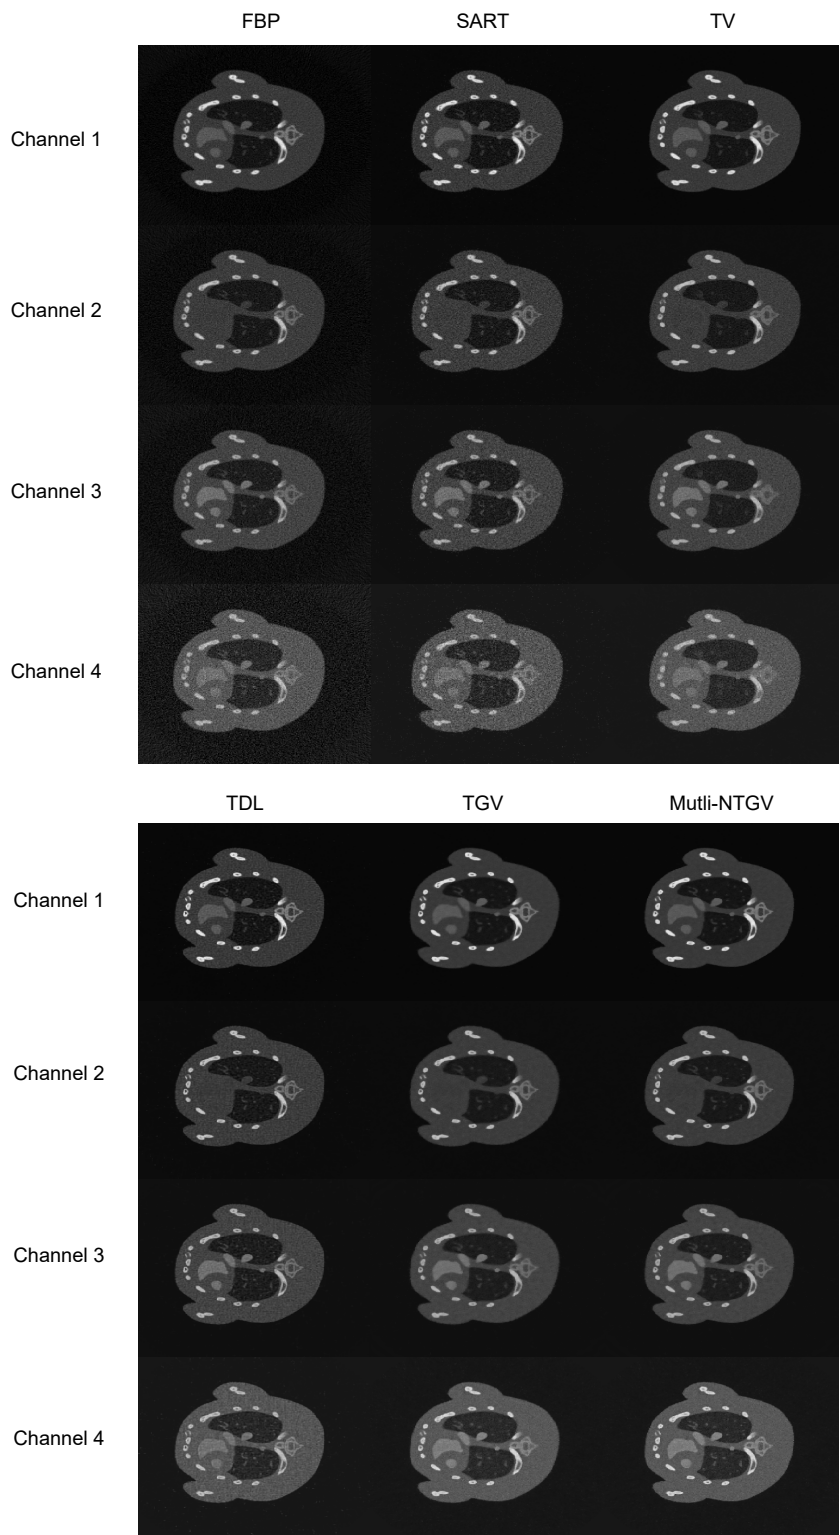


图 1 小鼠模型的重建结果。从左到右的方法依次为 FBP、SART、TV、TDL、TGV 与 Mutli-NTGV，
从上到下依次为 1 到 4 通道

Fig. 1 The reconstruction results of the mouse model. From left to right, the rows are FBP, SART, TV, TDL, TGV and Mutli-NTGV. From top to bottom, the columns are 1st, 2th, 3th and 4th energy channels

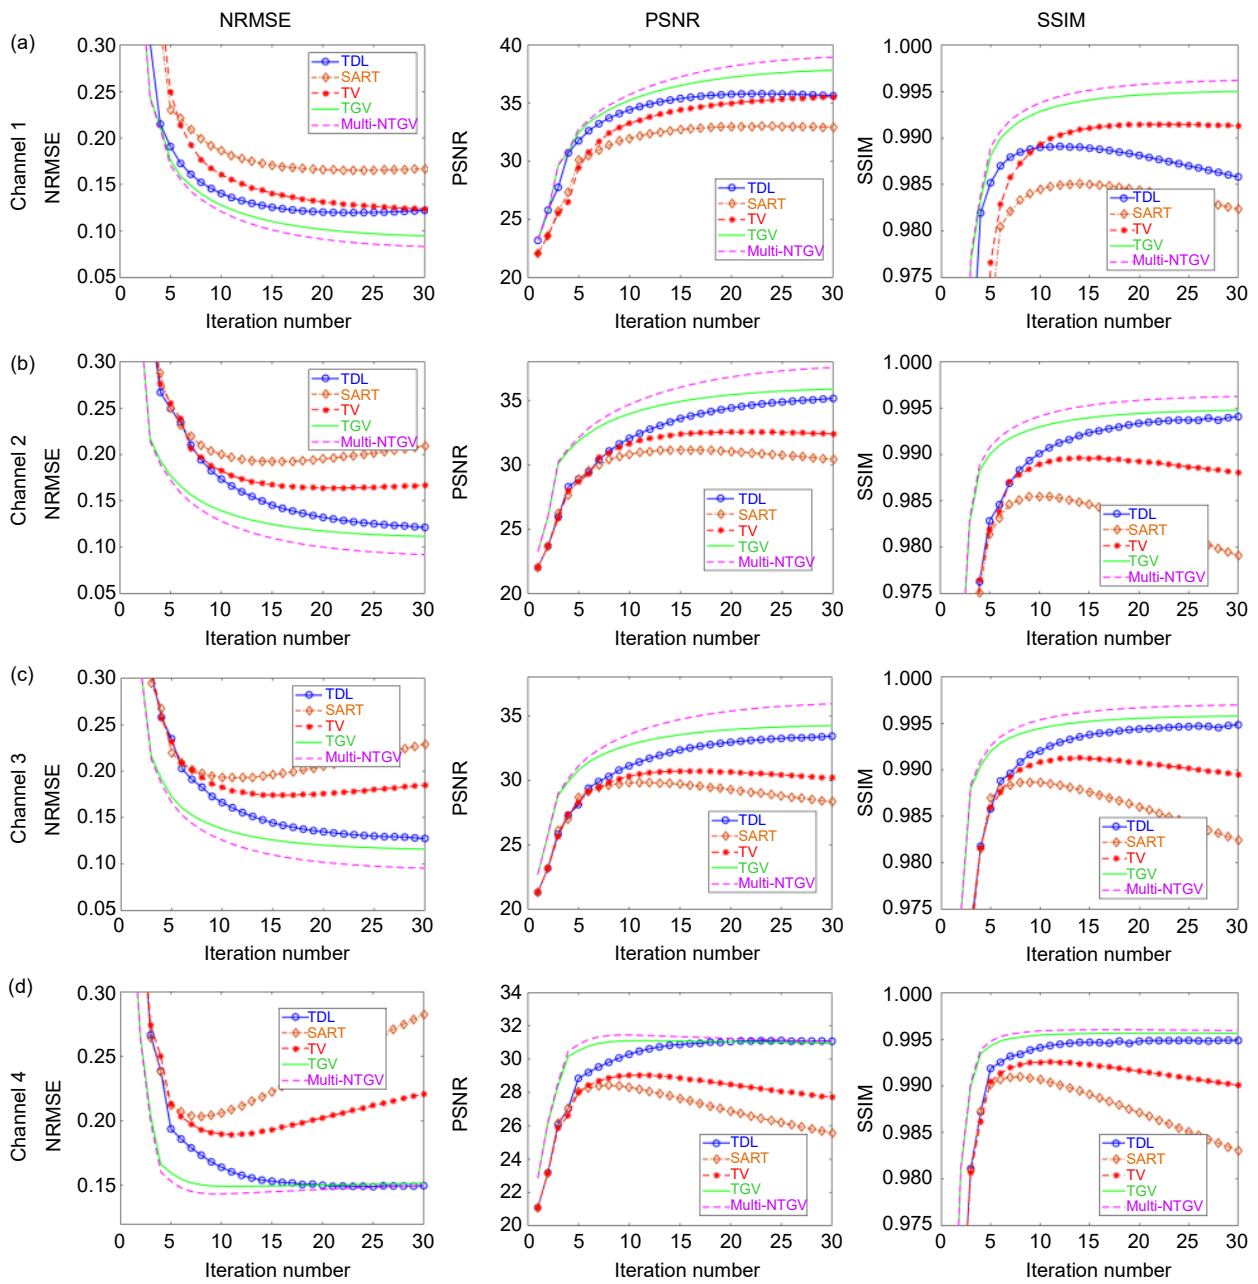


图 2 小鼠模型重建效果的数量性评价指标。

从左到右行依次为 NRMSE、PSNR、SSIM，从(a)到(d)行依次为 1 到 4 通道

Fig. 2 Quantitative evaluation index of reconstruction effect of the mouse model. From left to right, the rows are NRMSE, PSNR, SSIM. From (a) to (d), the columns are 1st, 2th, 3th and 4th energy channels

表 1 FBP 重建的数量性评价指标

Table 1 Quantitative evaluation index of FBP reconstruction

	Channel 1	Channel 2	Channel 3	Channel 4
NRMSE	0.2128	0.2795	0.3132	0.4059
PSNR	30.7993	27.8948	25.6016	22.4276
SSIM	0.9942	0.9625	0.9704	0.9702

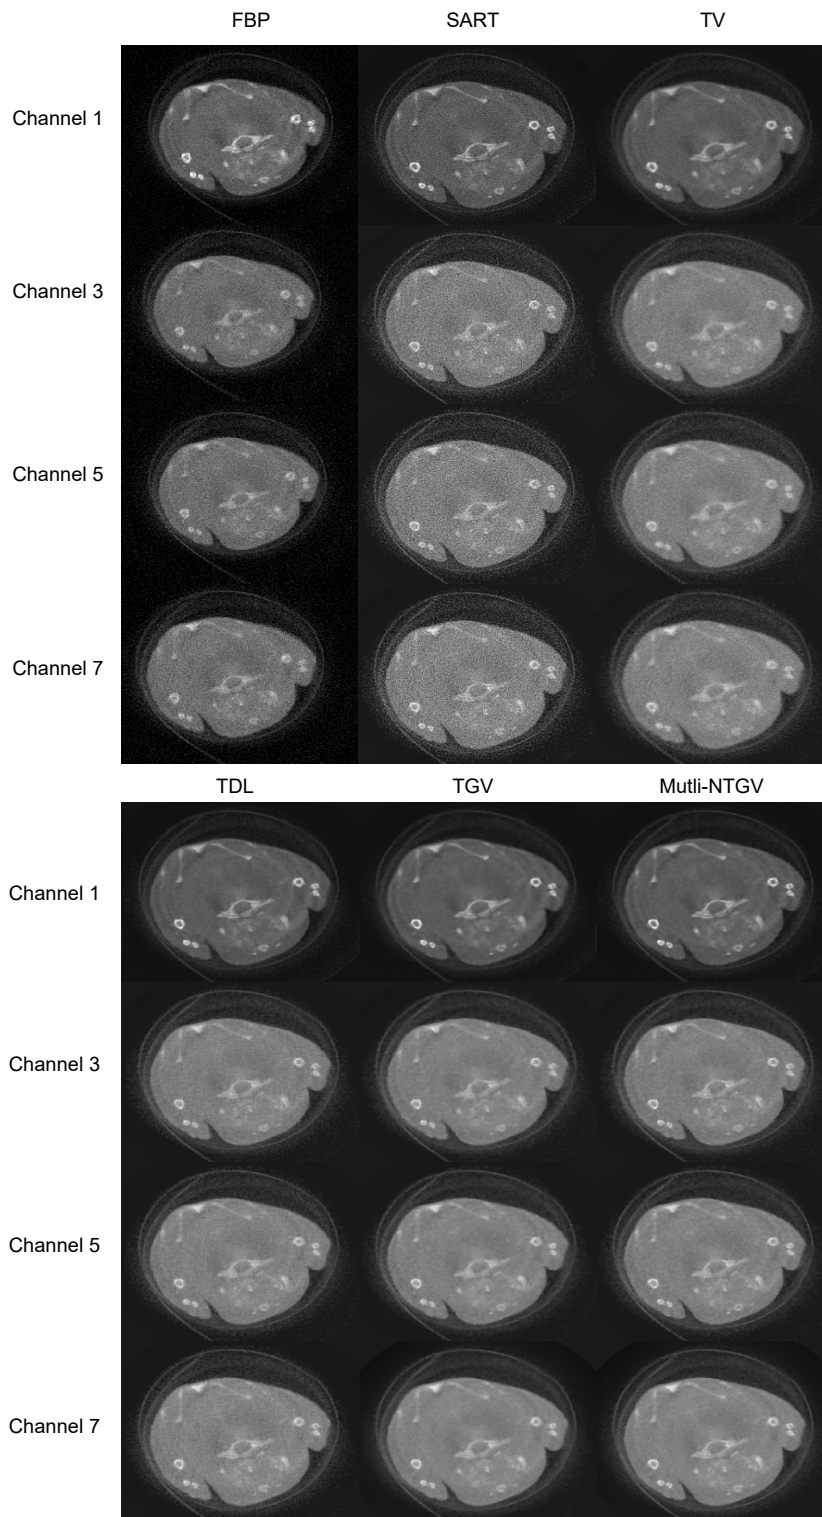


图3 临床小鼠模型的重建结果。从左到右的方法依次为FBP、SART、TV、TDL、TGV与Mutli-NTGV，
从上到下依次为1、3、5、7通道

Fig. 3 Reconstruction results of the clinical mouse model . From left to right, the methods are FBP, SART, TV, TDL, TGV, and Mutli-NTGV. From top to bottom, the columns are the 1st, 3th, 5th and 7th energy channels

5 结论

本文针对能谱 CT, 提出了一种基于核范数的多通道联合广义总变分能谱 CT 重建算法, 将 TGV 推向矢量化, 采用逐像素的更新方式, 使用多通道联合的二阶广义总变分作为专用的正则化函数在图像重建步骤中耦合多个通道, 耦合分别在一阶和二阶导数的水平上用核范数和 F 范数约束来实现, 促进了多个图像通道的梯度的线性依赖, 从而使边缘对齐。该方法在噪声条件下, 可以保持更多的细节与更清晰的边缘。仿真数据与实际数据的运行结果表明, 本文提出的算法具有较好的鲁棒性。但是, 本文算法中参数较多, 采用经验选取, 比较耗费时间, 后续研究中可以研究采用更灵活的参数选取模型。

参考文献

- [1] Niu S Z, Bian Z Y, Zeng D, *et al.* Total image constrained diffusion tensor for spectral computed tomography reconstruction[J]. *Appl Math Model*, 2019, **68**: 487–508.
- [2] Taguchi K, Iwanczyk J S. Vision 20/20: Single photon counting X-ray detectors in medical imaging[J]. *Med Phys*, 2013, **40**(10): 100901.
- [3] Dong X, Niu T Y, Zhu L. Combined iterative reconstruction and image-domain decomposition for dual energy CT using total-variation regularization[J]. *Med Phys*, 2014, **41**(5): 051909.
- [4] Yu Z C, Leng S, Li Z B, *et al.* Spectral prior image constrained compressed sensing (spectral PICCS) for photon-counting computed tomography[J]. *Phys Med Biol*, 2016, **61**(18): 6707–6732.
- [5] Zhang W K, Zhang H M, Wang L Y, *et al.* Limited angle CT reconstruction by simultaneous spatial and Radon domain regularization based on TV and data-driven tight frame[J]. *Nucl Instr Meth Phys Res A*, 2018, **880**: 107–117.
- [6] Luo X Q, Yu W, Wang C X. An image reconstruction method based on total variation and wavelet tight frame for limited-angle CT[J]. *IEEE Access*, 2018, **6**: 1461–1470.
- [7] Us D, Ruotsalainen U, Pursiainen S. Combining dual-tree complex wavelets and multiresolution in iterative CT reconstruction with application to metal artifact reduction[J]. *BioMed Eng On-Line*, 2019, **18**: 116.
- [8] Miao J Y, Cao H L, Jin X B, *et al.* Joint sparse regularization for dictionary learning[J]. *Cogn Comput*, 2019, **11**(5): 697–710.
- [9] Zhang Y, Xi Y, Yang Q S, *et al.* Spectral CT reconstruction with image sparsity and spectral mean[J]. *IEEE Trans Comput Imaging*, 2016, **2**(4): 510–523.
- [10] Li B, Shen C Y, Chi Y J, *et al.* Multienergy cone-beam computed tomography reconstruction with a spatial spectral nonlocal means algorithm[J]. *SIAM J Imaging Sci*, 2018, **11**(2): 1205–1229.
- [11] Hu D L, Wu W W, Xu M R, *et al.* SISTER: spectral-image similarity-based tensor with enhanced-sparsity reconstruction for sparse-view multi-energy CT[J]. *IEEE Trans Comput Imaging*, 2020, **6**: 477–490.
- [12] 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 Opt Sin*, 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.
- [13] Rigie D S, Patrick J L R. Joint reconstruction of multi-channel, spectral CT data via constrained total nuclear variation minimization[J]. *Phys Med Biol*, 2015, **60**(5): 1741–1762.
- [14] Niu S Z, Huang J, Bian Z Y, *et al.* Iterative reconstruction for sparse-view X-ray CT using alpha-divergence constrained total generalized variation minimization[J]. *J X-Ray Sci Technol*, 2017, **25**(4): 673–688.
- [15] Kristian B, Karl K, Thomas P. Total Generalized Variation[J]. *SIAM Journal on Imaging Sciences*, 2010, **3**(3): 492–526.
- [16] Ehrhardt M J, Arridge S R. Vector-valued image processing by parallel level sets[J]. *IEEE Trans Image Process*, 2014, **23**(1): 9–18.
- [17] Sidky E Y, Jørgensen J H, Pan X C. Convex optimization problem prototyping for image reconstruction in computed tomography with the Chambolle–Pock algorithm[J]. *Phys Med Biol*, 2012, **57**(10): 3065–3091.


Joint multi-channel total generalized variational algorithm for spectral CT reconstruction

Lian Xiangyuan^{1,2}, Kong Huihua^{1,2}, Pan Jinxiao^{1,2*}, Gao Wenbo^{1,2}, Wang Pan³

¹School of Science, North University of China, Taiyuan, Shanxi 030051, China;

²Shanxi Key Laboratory of Signal Capturing & Processing, North University of China, Taiyuan, Shanxi 030051, China;

³Hunan Vsngusrd Group. Co. Ltd, Chenxi, Hunan 419503, China



The reconstruction results of the mouse model by Multi-NTGV

Overview: Spectral computed tomography (CT) based on photon-counting detectors, has great potential in material decomposition, tissue characterization, lesion detection, and other applications. During the reconstruction, the increase of the number of channels will reduce the photon number in a single channel, resulting in the decline of the quality of the reconstructed image, which is difficult to meet the actual needs. To improve the quality of image reconstruction, this paper proposes a joint multi-channel total generalized variational based on the unclear norm for spectral CT reconstruction. Firstly, in the reconstruction for spectral CT, the image structure of each channel is highly similar, and the reconstruction of a single channel will ignore the structural information of each channel. Second, gradient information contains a lot of structured information and features of the image. When two images have the same curve, the two images have the same direction gradient and the converse is also true. In order to better utilize the image's structural information between channels, the new regularization function is applied to spectral CT reconstruction. The research shows that if the edges of the two images are aligned, the two images have the same gradient. The image gradients between channels are parallel, which will minimize the nuclear norm. The algorithm will extend total generalized variation to the vector, with the aim of overcoming defects of existing derivative-based regularization. The paper proposed a joint multi-channel total generalized variational for spectral CT reconstruction, employing a vectorial second-order total generalized variation function as joint regularization. The method adopts pixel-by-pixel updating in the image reconstruction, and the multi-channel image coupling is realized by kernel norm and F-norm constraints at the level of first and second derivatives. The nuclear norm and frobenius norm coupling promote joint sparsity of the edge sets and dependence of the gradients. Joint multi-channel total generalized variational is used to promote the linear dependence of the multi-channel image's gradient so that the image edges of each channel are aligned. The structural information of the multi-channel image is shared during the image reconstruction process while unique differences are preserved. The experiment was done on a numerical mouse thorax phantom and clinical mouse data. The quantitative results of peak signal to noise ratio (PSNR), normalized root mean square error (NRMSE) and structure similarity index (SSIM) show that the proposed algorithm greatly improves the image quality. Experimental results show that the proposed algorithm can effectively recover image details and marginal information while suppressing noise.

Lian X Y, Kong H H, Pan J X, *et al.* Joint multi-channel total generalized variational algorithm for spectral CT reconstruction[J]. *Opto-Electron Eng*, 2021, 48(9): 210211; DOI: 10.12086/oe.2021.210211

Foundation item: National Natural Science Foundation of China (61801437, 61871351, 61971381)

* E-mail: panjx@nuc.edu.cn