

文章编号 1004-924X(2018)10-2592-13

结合流形正则和变量分离近似稀疏重构的 荧光分子断层成像

侯榆青*, 张文元, 王晓东, 贺小伟, 曹 欣
(西北大学 信息科学与技术学院, 陕西 西安 710127)

摘要:为改善荧光分子断层成像的重建结果,本文采用联合稀疏-流形正则模型进行光源重建,该联合稀疏-流形正则模型能同时利用重建光源聚集性和稀疏性的先验信息。为有效求解该联合稀疏-流形正则模型,本文通过重新推导变量分离近似稀疏重构算法对其进行求解。为加快变量分离近似稀疏重构算法求解联合稀疏-流形正则模型的速度,本文在光源重建过程中采用了热启动策略。实验结果表明,相比变量分离近似稀疏重构算法求解范数模型,变量分离近似稀疏重构算法求解联合稀疏-流形正则模型将重建结果的对比噪声比从 6.45 提升至 9.18。另外,相比没有采用热启动策略,采用热启动策略的变量分离近似稀疏重构算法求解联合稀疏-流形正则模型的时间从 101.84 s 减至 50.10 s。本文方法显著提高了光源目标重建的精度和速度,取得了更优的重建结果。

关键词:流形正则;热启动策略;变量分离近似稀疏重构

中图分类号:Q63;TP394.1 **文献标识码:**A **doi:**10.3788/OPE.20182610.2592

Light source reconstruction method in fluorescence molecular tomography based on Laplacian manifold regularization and sparse reconstruction by separable approximation

HOU Yu-qing*, ZHANG Wen-yuan, WANG Xiao-dong, HE Xiao-wei, CAO Xin

(School of Information Sciences and Technology, Northwest University, Xi'an 710127, China)

* Corresponding author, E-mail: houyuqing@nwu.edu.cn

Abstract: To enhance reconstruction performance in fluorescence molecular tomography, a joint-norm and a Laplacian manifold regularization model that combined both sparsity and spatial aggregation information was utilized for light source reconstruction. In this report, sparse reconstruction by separable approximation (SpaRSA) was developed to investigate the joint model (SpaRSA-resolved Laplacian manifold regularization model, SpaRSALM). To improve the convergence speed of the SpaRSALM algorithm, a warm-start strategy was applied for light source reconstruction. The experimental results show that the SpaRSALM algorithm solved the joint model problem and improved the contrast to noise ratio (CNR) from 6.45 to 9.18 compared to using the SpaRSA algorithm to solve for the -norm regularization model. In addition, the reconstruction of the SpaRSALM algorithm using the

收稿日期:2018-01-14;修订日期:2018-03-02.

基金项目:国家自然科学基金资助项目(No. 11571012, No. 61640418) 陕西省教育厅服务地方专项资助项目(No. 17JF027)

warm-start strategy (compared to without the warm-start strategy) required 50.10 s (as opposed to 101.84 s). The accuracy and speed of light source reconstruction were significantly improved, and better reconstruction results were achieved using the presented method.

Key words: laplacian manifold regularization; warm-started strategy; sparse reconstruction by separable approximation

1 序 言

荧光分子断层成像(Fluorescence Molecular Tomography, FMT)是一种非侵入、低辐射的光学成像技术。在分子和细胞水平下,对生物的一系列生理过程进行无创探测。由于高灵敏度和低成本等优点^[1],FMT 被应用于癌症检测和新药研发等领域^[2]。

在生物组织中光传输有强散射特性,利用 FMT 重建荧光光源是一个病态性严重的逆向问题^[3]。为克服 FMT 逆向问题的病态性,研究人员采用正则化方法,来减少噪声对重建结果的影响。考虑到 L_2 范数正则化模型求解速度快和求解方法简单的优点,早期研究人员采用 L_2 范数正则化模型求解逆向问题。然而, L_2 范数存在一些缺点,如 FMT 重建结果过平滑,致使重建产生伪光源,严重影响重建荧光光源的准确性^[4]。由于 FMT 常应用于早期癌症检测,此时生物荧光光源呈现稀疏性分布特性,为改善 L_2 范数正则化重建结果的准确性,研究人员利用该先验特性,通过稀疏正则模型对荧光基团进行三维重建。利用稀疏正则范数改善重建结果的方法,主要包含基于 L_0 范数^[5], L_1 范数^[6]和 $L_p(0 < p < 1)$ 范数^[7]的逆向问题重建模型。 L_0 范数正则化的方法在稀疏性上最好,然而在大规模的 FMT 逆向问题中,计算上并不可行。由压缩感知理论可知,基于 L_1 范数正则化 FMT 逆向问题与基于 L_0 范数正则化逆向问题相比,在一定条件下等价^[8]。相比于 L_0 范数正则, L_1 范数正则化逆向问题有以下两个优点: L_1 范数正则化是凸问题,不存在局部最优解,重建结果更加准确;在光学重建领域,针对 L_1 范数正则化模型的求解,有很多传统最优优化算法^[9]。然而,相较 L_0 范数的全局最优解, L_1 范数对应的解并不足够稀疏和精确。为平衡 L_0 范数和 L_1 范数优缺点,取得更优的重建结果, $L_p(0 < p < 1)$ 范

数正则化被应用于逆向问题重建,与 L_1 范数正则化逆向问题的解相比, $L_p(0 < p < 1)$ 范数正则化的解更加稀疏^[10-11],通常重构精度更高,但同时也有局部最优、计算复杂度高(与 L_0 范数正则化逆向问题相似)的缺点。另外, L_{1-2} 范数同样也被提出作为稀疏正则化项,与 L_p 范数相比, L_{1-2} 范数正则化逆向问题的效果更加接近 L_0 范数,同时可利用非贪婪式的传统优化算法求解^[12-14]。除稀疏正则模型中所用到的生物体光源呈现稀疏的特性之外,生物体体内荧光光源分布的聚集性特征(生物体内一处发生病变,通常会对周围的组织产生影响)也应被用于光源重建模型中来进一步改善重建结果的精度。在文献[15],研究人员提出联合稀疏-流形正则模型。该模型能同时利用光源稀疏性和光源分布聚集性的先验信息(即一方面利用 L_1 范数正则项保证重建光源的稀疏性,一方面利用流形正则项保证重建光源的聚集性)。

现有压缩感知问题求解的最优化算法不能直接用于联合稀疏-流形正则模型的求解。本文主要工作是重新推导变量分离近似稀疏重构算法(Sparse Reconstruction by Separable Approximation, SpaRSA),使其适用于联合稀疏-流形正则方法的求解(SpaRSA-resolved Laplacian manifold regularization model, SpaRSALM),同时采用 SpaRSALM 算法的热启动策略使该算法在重建速度上得到提高。实验结果表明,本文提出的 SpaRSALM 算法能很好地求解联合稀疏-流形正则模型,其重建结果与 SpaRSA 算法应用于 L_1 范数稀疏正则模型所获得的结果相比更加精确。

2 理论方法

2.1 光的传输模型与逆向问题

近红外光在生物体内传输过程,通常用扩散传输方程(Diffuse Equation, DE)来近似描述^[16]。

FMT 通常包括激发和发射两个光传输过程。相对应的耦合扩散方程为:

$$\begin{cases} -\nabla[D_x \nabla \phi_x(r)] + \mu_{ax} \phi_x(r) = s(r) \\ -\nabla[D_m \nabla \phi_m(r)] + \mu_{am} \phi_m(r) = \phi_x(r) X(r) \end{cases} \quad (1)$$

第 1 个方程描述激发过程,第 2 个方程描述发射过程,分别用下角标 x 和 m 加以区别。在两个方程中 r 是三维的位置变量 $s(r)$ 是激发光源分布, $\phi_x(r)$ 是激发光的光子流率, $\phi_m(r)$ 是发射光的光子流率, μ_{ax} 和 μ_{am} 分别是激发和发射过程介质的吸收系数, D 是介质的扩散系数, 其值为 $D_x = 1/(\mu_{ax} + (1-g)\mu_{sx})$ 和 $D_m = 1/(\mu_{am} + (1-g)\mu_{sm})$, μ_{sx} 和 μ_{sm} 分别是激发和发射过程介质的散射系数, g 是各向异性参数。 $X(r)$ 是转换比例函数。对于某个具体的位置 r , 如果该位置没有荧光探针分布则 $X(r) = 0$, 否则 $0 < X(r) < 1$ 。

求解上述耦合扩散方程需要边界条件。在 FMT 的研究中, Robin 边界条件是使用率最高的边界条件, 其具体形式为^[17]:

$\phi_{x,m}(r) + 2A_n D_{x,m} \nabla \phi_{x,m}(r) \cdot \nu = 0$, 其中 ν 是生物组织边界的外法向量, \cdot 表示含义为内积运算, $A_n \approx (1 + R_n)/(1 - R_n)$, $R_n \approx -1.4399n^{-2} + 0.7099n^{-1} + 0.6681 + 0.9636n$, n 是生物组织与空气间的折射率, 约为 0.4258。利用有限元方法, 将耦合扩散方程转换为线性方程组^[17-18]:

$$\begin{cases} \phi_x = K_x^{-1} L_x \\ \phi_m = K_m^{-1} F X = A_m X \end{cases} \quad (2)$$

其中: K_x 和 K_m 是激发和发射过程对应的有限元系统矩阵, ϕ_x 和 ϕ_m 是激发光和发射光在有限元节点上的能量分布, $A_m = K_m^{-1} F$, L_x 是激发光源在有限元节点上的能量分布, X 是一个向量, 其的分量对应有有限元节点上的激发光-发射光转换比例, 若某个节点不是探针位置, 该节点对应的 X 的分量值为 0, 否则分量值为 $(0, 1)$ 之间的一个常数, F 是与 ϕ_x 有关的有限元系统矩阵, 其的每一列都包含 ϕ_x 在对应节点的分量值, 不同的激发节点 F 是不同的, 但 X 是相同的。这对于多激发光源条件下 FMT 逆向问题的求解至关重要。实际应用中, 只能获得生物外表面有限元节点对应的 ϕ_m 的分量, 内部节点的能量值是未知的。因此, 必须删去内部节点对应的方程, 剩余的方程组成一个欠

定的方程组, 记作:

$$\phi_m' = A_m' X. \quad (3)$$

选取多个激发点, 获取多个类似于式(3)的方程组, 增加解得鲁棒性。设第 sr 个激发点对应的欠定方程组为:

$$\phi_{m, sr}' = A_{m, sr}' X, \quad sr = 1, 2, \dots, SR.$$

由于这 SR 个方程组都有共同的解 X , 因此将其合并成一个大的方程组, 记为:

$$\phi = AX. \quad (4)$$

最后通过式(4)获得有效的光源分布 X 。

2.2 联合稀疏-流形正则模型

由于 FMT 应用在早期的癌症检测, 使 FMT 逆向问题的解呈现稀疏特性。由于某一部位的组织产生癌变, 其周围的组织可能受到影响, 从而发生癌变, 因此 FMT 逆向问题的解有聚集的特性。若 FMT 逆向问题重建结果为某个有限元节点是光源, 但是它周围的节点均不是光源, 则这个节点很可能是逆向问题病态性导致的伪光源。采用流形正则项可有效地利用组织的邻域信息; 采用 L_1 范数正则项可有效利用稀疏性先验信息, 因此联合稀疏-流形正则模型能改善 FMT 光源的重建效果^[15]。

首先介绍依托有限元网格建立的图模型。将有限元网格的节点作为图模型的顶点, 图模型的顶点值 x_i 是重建荧光的能量值。图模型的邻域(即构建图模型的边)有以下 3 种选择^[19], 如图 1 所示(彩图见期刊电子版)。第 1 种, 将当前节点为球心以恒定长度 r 为半径的球作为邻域, 球内

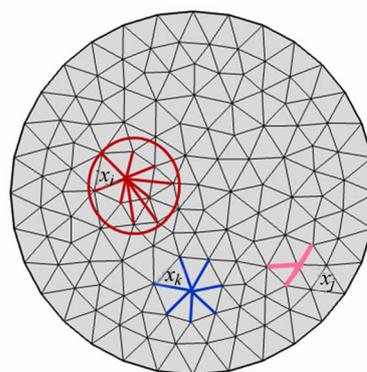


图 1 图的 3 种连接方式(基于二维有限元网格)
Fig. 1 Illustration of graph model based on 2-D finite element mesh, which contains three different paradigms

的其他节点视为和当前节点有边相连,即图 1 中,与 x_i 相对应红色边。第 2 种,选择距离当前节点最近的 t 个节点,将 t 个节点视为和当前节点有边相连,即图 1 中,与 x_j 相对应紫色边。第三,将位于同一个三角剖分网格的节点彼此作为邻域点,并建立相应的边,即图 1 中,与 x_k 相对应蓝色边。在本文中,第 3 种方法被用于构建图模型,该构图方法简单,参数少。

图模型建立后,给每一个边赋予权值,作为它连接的两个节点间的相似度,满足两个节点距离越近,权值越接近于 1,两个节点距离越远,权值越接近于 0,对于没有边相连的两个节点,权值为 0。本文中采用下面方法定义该权值。

$$\omega_{ij} = \begin{cases} e^{-\frac{|s_i - s_j| \cdot \sigma}{\sigma^2}}, & \text{若 } x_i \text{ 和 } x_j \text{ 有边相连} \\ 0, & \text{若 } i=j, \text{ 或 } x_i \text{ 和 } x_j \text{ 没边相连} \end{cases}, \quad (5)$$

其中: s_i 和 s_j 分别是节点 x_i 和 x_j 对应的空间坐标, $\sigma > 0$ 是参数。流形正则项为:

$$\sum_{i=1}^n \sum_{j=1}^n \omega_{ij} (x_i - x_j)^2, \quad (6)$$

其中 n 是图模型节点个数,如果 ω_{ij} 和 $(x_i - x_j)^2$ 值都很大, $\omega_{ij} (x_i - x_j)^2$ 值很大, ω_{ij} 值很大说明两个点距离短, $(x_i - x_j)^2$ 很大说明两个点能量差距大。将式(6)作为正则项,就会抑制上述情况的发生,最后得到距离近的两个点,它们的能量值差距通常会很小。经过推导^[19],式(6)可以写成:

$$2\mathbf{X}^T \mathbf{LX}, \quad (7)$$

公式(7) $\mathbf{X} = (x_1, x_2, \dots, x_n)^T$, \mathbf{X} 右上角的 T 表示矩阵或向量的转置, $\mathbf{L} = \mathbf{D} - \mathbf{W}$, $\mathbf{W} = (\omega_{ij})_{n \times n}$, $\mathbf{D} = \text{diag}(d_1, d_2, \dots, d_n)$, 其中:

$$d_i = \sum_{j=1}^n \omega_{ij} = \sum_{k=1}^n \omega_{ki} \quad (i = 1, 2, \dots, n).$$

通过整理,可知联合稀疏-流形正则模型的表示式:

$$\min_{\mathbf{X}} \|\mathbf{AX} - \boldsymbol{\phi}\|_2^2 + \tau \|\mathbf{X}\|_1 + \frac{\lambda}{4} \sum_{i=1}^n \sum_{j=1}^n \omega_{ij} (x_i - x_j)^2, \quad (8)$$

式(8)可以等价地写成:

$$\min_{\mathbf{X}} \frac{1}{2} \|\mathbf{AX} - \boldsymbol{\phi}\|_2^2 + \tau \|\mathbf{X}\|_1 + \frac{\lambda}{2} \mathbf{X}^T \mathbf{LX}. \quad (9)$$

2.3 SpaRSALM 算法与热启动策略

2.3.1 SpaRSALM 算法^[20]

将公式(9)中的第一项展开得到公式:

$$\min_{\mathbf{X}} f(\mathbf{X}) = \tau \|\mathbf{X}\|_1, \quad (10)$$

其中:

$$f(\mathbf{X}) = \frac{1}{2} \mathbf{X}^T \mathbf{A}^T \mathbf{A} \mathbf{X} + \frac{1}{2} \boldsymbol{\phi} \boldsymbol{\phi}^T - \boldsymbol{\phi}^T \mathbf{A} \mathbf{X} + \frac{\lambda}{2} \mathbf{X}^T \mathbf{LX}.$$

求解形如(10)式的优化问题,通常采用二次函数逼近 $f(\mathbf{X})$,从而获得迭代公式:

$$\mathbf{X}^{t+1} \in \operatorname{argmin}_{\mathbf{X}} f(\mathbf{X}^t) + (\mathbf{X} - \mathbf{X}^t)^T \nabla f(\mathbf{X}^t) + \frac{\alpha_t}{2} \|\mathbf{X} - \mathbf{X}^t\|_2^2 + \tau \|\mathbf{X}\|_1, \quad (11)$$

其中:上角标 t 是迭代序号, $\frac{\alpha_t}{2} \|\mathbf{X} - \mathbf{X}^t\|_2^2 = \frac{1}{2} (\mathbf{X} - \mathbf{X}^t)^T \alpha_t \mathbf{I} (\mathbf{X} - \mathbf{X}^t)$ 是 $f(\mathbf{X})$ 的二阶泰勒展开式中二次项的近似值,如下所示 $\frac{1}{2} (\mathbf{X} - \mathbf{X}^t)^T \nabla^2 f(\mathbf{X}^t) (\mathbf{X} - \mathbf{X}^t)$ 的近似, \mathbf{I} 是单位矩阵。上述替换两个好处,首先, $\frac{\alpha_t}{2} \|\mathbf{X} - \mathbf{X}^t\|_2^2$ 迭代过程计算成本更小,其次, $\frac{\alpha_t}{2} \|\mathbf{X} - \mathbf{X}^t\|_2^2$ 是解相关的,它使子问题(11)具有闭式解。

将 $\nabla f(\mathbf{X}^t) = (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{L}) \mathbf{X}^t - \mathbf{A}^T \boldsymbol{\phi}$ 带入式(11),再用常数 $\frac{1}{\alpha_t}$ 乘式(11)的目标函数,最后将一次项 $(\mathbf{X} - \mathbf{X}^t)^T \nabla f(\mathbf{X}^t)$ 和并入二次项 $\frac{\alpha_t}{2} \|\mathbf{X} - \mathbf{X}^t\|_2^2$,忽略掉式中的常数项,式(11)可以等价地写成:

$$\mathbf{X}^{t+1} \in \operatorname{argmin}_{\mathbf{X}} \frac{1}{2} \left\| \mathbf{X} - \left[\mathbf{X}^t - \frac{1}{\alpha_t} * (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{L}) \mathbf{X}^t + \frac{1}{\alpha_t} \mathbf{A}^T \boldsymbol{\phi} \right] \right\|_2^2 + \frac{\tau}{\alpha_t} \|\mathbf{X}\|_1. \quad (12)$$

令:

$$\mathbf{U}^t = \mathbf{X}^t - \frac{1}{\alpha_t} (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{L}) \mathbf{X}^t + \frac{1}{\alpha_t} \mathbf{A}^T \boldsymbol{\phi},$$

则式(12)变为:

$$\mathbf{X}^{t+1} \in \operatorname{argmin}_{\mathbf{X}} \frac{1}{2} \|\mathbf{X} - \mathbf{U}^t\|_2^2 + \frac{\tau}{\alpha} \|\mathbf{X}\|_1. \quad (13)$$

这是一个变量解相关的优化问题,可以按分量优化,并获得 \mathbf{X}^{t+1} 。

$$x_i^{t+1} = \begin{cases} \mu_i^t - \frac{\tau}{\alpha_t}, & \mu_i^t > \frac{\tau}{\alpha_t} \\ \mu_i^t + \frac{\tau}{\alpha_t}, & \mu_i^t < -\frac{\tau}{\alpha_t} \\ 0, & |\mu_i^t| \leq \frac{\tau}{\alpha_t} \end{cases}, \quad (14)$$

其中: x_i^{t+1} 是 \mathbf{X}^{t+1} 的第 i 个分量, μ_i^t 是 \mathbf{U}^t 的第 i 个分量。式(14)也被称为软阈值函数。

SpaRSALM 算法采用 Barzilai-Borwein 方法^[21]选择初始的 α_t , 该方法仍然是利用 $\alpha_t I$ 近似替代 $\nabla^2 f(\mathbf{X}^t)$ 。类似于式(11), 可以在 \mathbf{X}^t 处做一个二次近似:

$$f(\mathbf{X}) \approx f(\mathbf{X}^t) + (\mathbf{X} - \mathbf{X}^t)^T \nabla f(\mathbf{X}^t) + \frac{\alpha_t}{2} \|\mathbf{X} - \mathbf{X}^t\|_2^2. \quad (15)$$

对(15)式两侧关于 \mathbf{X} 求梯度, 并将 \mathbf{X}^{t-1} 带入得:

$$\nabla f(\mathbf{X}^{t-1}) \approx \nabla f(\mathbf{X}^t) + \alpha_t (\mathbf{X}^{t-1} - \mathbf{X}^t). \quad (16)$$

移项得超定方程组:

$$(\mathbf{X}^t - \mathbf{X}^{t-1}) \alpha_t \approx \nabla f(\mathbf{X}^t) - \nabla f(\mathbf{X}^{t-1}). \quad (17)$$

将式(17)两侧同时乘以 $(\mathbf{X}^t - \mathbf{X}^{t-1})^T$, 并将 α_t 的系数除到等式右侧, 可获得最小二乘解

$$\alpha_t = \frac{(\mathbf{X}^t - \mathbf{X}^{t-1})^T [\nabla f(\mathbf{X}^t) - \nabla f(\mathbf{X}^{t-1})]}{(\mathbf{X}^t - \mathbf{X}^{t-1})^T (\mathbf{X}^t - \mathbf{X}^{t-1})}. \quad (18)$$

将 $\nabla f(\mathbf{X}) = (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{L}) \mathbf{X} - \mathbf{A}^T \boldsymbol{\phi}$ 带入(18)可得

$$\alpha_t = \frac{(\mathbf{X}^t - \mathbf{X}^{t-1})^T}{(\mathbf{X}^t - \mathbf{X}^{t-1})^T (\mathbf{X}^t - \mathbf{X}^{t-1})} * (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{L}) (\mathbf{X}^t - \mathbf{X}^{t-1}). \quad (19)$$

为了数值的稳定性, 用经验设定的参数给 α_t 设置一个上限 α_{\max} 和下限 α_{\min} 。

值得指出的是, 按照式(19)获得的 α_t 并不能保证 \mathbf{X}^{t+1} 使目标函数单调下降, 或者使优化算法收敛。理论上, 当 α_t 充分大的时候, 获得的 \mathbf{X}^{t+1} 可以保证算法收敛。因此需要引入一个参数 $\eta > 1$, 当 α_t 不能保证算法收敛时, 用公式 $\alpha_t = \eta \alpha_t$ 不断更新 α_t , 在新的 α_t 对应的解 \mathbf{X}^{t+1} 满足一定的收敛条件时, 将此时的 \mathbf{X}^{t+1} 作为下一个迭代点。

SpaRSALM 算法判断条件为:

$$F(\mathbf{X}^{t+1}) \leq \max\{F(\mathbf{X}^k)\}_{k=\max\{t-M, 0\}}^t - \frac{\sigma}{2} \alpha_t \|\mathbf{X}^{t+1} - \mathbf{X}^t\|_2^2, \quad (20)$$

其中 M 是给定的非负整数。该条件并不能保证 \mathbf{X}^{t+1} 使目标函数单调下降, 但经验表明, 这种对于目标函数单调下降要求的放松, 经常可以加速算法的收敛。文献[20]也从理论上保证了 SpaRSALM 算法的总体收敛性。表 1 展现了 SpaRSALM 算法流程。

表 1 SpaRSALM 的算法流程

Tab. 1 Description of SpaRSALM algorithm

算法 I: SpaRSALM 的算法流程

Step 1: 给定参数 $\eta > 1$, 以及 α_{\max} 和 α_{\min} , 使它们满足 $0 < \alpha_{\min} < \alpha_{\max}$ 。给定初始光源分布 \mathbf{X}^0 , 并置 $t=0$ 。

Step 2: 利用(19)式计算 α_t , 并对其调整(如有必要), 使之满足 $\alpha_{\min} \leq \alpha_t \leq \alpha_{\max}$ 。

Step 3: 利用公式(14)计算 \mathbf{X}^{t+1} 。

Step 4: 如果 \mathbf{X}^{t+1} 不满足条件(20), $\alpha_t = \eta \alpha_t$, 转 Step 3。反之, 如果 \mathbf{X}^{t+1} 满足条件(20), 则转 Step 5。

Step 5: 如果 \mathbf{X}^{t+1} 不满足终止条件

$$\frac{\|\mathbf{X}^{t+1} - \mathbf{X}^t\|_2}{\|\mathbf{X}^{t+1}\|_2} \leq 10^{-5}, \quad (21)$$

则 $\mathbf{X}^t = \mathbf{X}^{t+1}$, $t = t + 1$, 转 Step 2。否则, 如果 \mathbf{X}^{t+1} 满足终止条件(21), 则停。并输出联合稀疏-流形正则模型(11)的解 $\mathbf{X}^* = \mathbf{X}^{t+1}$ 。

2.3.2 热启动策略

很多求解含 L_1 正则项的优化算法都面临一个问题, 就是当正则项系数 τ 较小, 并且初始解 \mathbf{X}^0 距离问题的真实解 \mathbf{X}^* 较远时, 算法收敛非常缓慢。热启动策略可以很好地解决这一问题。具体地, 按一定规则给出一系列的正则项系数 $\tau_0 > \tau_1 > \tau > \dots > \tau_s = \tau$ 。 τ_s 对应稀疏正则问题的解记为 \mathbf{X}_{s+1}^* , $s=0, 1, \dots, S$ 。在求解 $\tau_s (s > 0)$ 对应的稀疏正则问题时, 前一次的解 \mathbf{X}_s^* 被作为初始解。对于 τ_0 , 由于它很大, 优化算法可以快速求解, 而对于后续的 τ_s , 尽管被逐渐减小, 但由于初始解 \mathbf{X}_s^* 与 \mathbf{X}_{s+1}^* 距离很近, 后续的优化问题也可以很

表 2 热启动策略流程

Tab. 2 Description of warm-started strategy

算法 II: 热启动策略流程

Step 1: 令 $\boldsymbol{\phi} = \boldsymbol{\phi}$, 给定初始解 \mathbf{X}^0 , $0 < \zeta < 1$, 置 $s=0$ 。

Step 2: 计算 $\tau_s = \max\{\zeta \|\mathbf{A}^T \boldsymbol{\phi}\|_\infty, \tau\}$ 。

Step 3: 将 τ_s 作为模型(9)的 L_1 正则项的系数, 在 \mathbf{X}^0 作为初始解的条件下, 利用 SpaRSALM 算法对其进行求解, 获得的解记作 \mathbf{X}_{s+1}^* 。

Step 4: 如果 $\tau_s \neq \tau$, $\boldsymbol{\phi}^{t+1} = \boldsymbol{\phi} - \mathbf{A} \mathbf{X}_{s+1}^*$, $\mathbf{X}^0 = \mathbf{X}_{s+1}^*$, 置 $s = s + 1$, 转 Step 2。

如果 $\tau_s = \tau$, 则停。输出模型(9)的最终解 $\mathbf{X}^* = \mathbf{X}_{s+1}^*$ 。

快被求解。这使得热启动策略,可以在 τ 很小的时候,加速优化算法。对于不同的算法,序列 $\tau_0, \tau_1, \dots, \tau_s$ 选择方式并不相同,如 GPSR 算法^[18]采用按照一定比例缩小正则项系数的值。SpaR-SALM 算法采用另外一个规则选定正则项系数序列 $\tau_0, \tau_1, \dots, \tau_s$ 。表 2 展示了 SpaRSALM 算法的热启动策略流程。

3 实验

首先,使用两组单光源数字鼠光源重建问题验证提出算法的有效性,一组数字鼠具有较小的光源,另一组含有较大的光源。由于流形正则项使重建的光源有更好的聚集性,因此直观上它对较大光源会更有效,这就是增加一组较大光源数字鼠实验的原因。其次,进行一组双光源数字鼠光源重建问题验证算法的有效性。三组实验的具体参数将在下文中分别给出。为了比较提出算法的重建精度和效率,本文使用 2 种算法作比较。第 1 种是用于求解 L_1 正则逆向问题的 SpaRSA 算法,将其记为 SpaRSA-Basic。第 2 种是用于求解 L_1 正则逆向问题的带热启动策略的 SpaRSA 算法,记为 SpaRSA-Warm。为了表述方便,本文提出的用于求解联合稀疏-流形正则逆向问题的不含热启动策略的 SpaRSALM 算法被记为 SpaRSALM-Basic(SpaRSALM without a warm-started strategy),而用于求解联合稀疏-流形正则逆向问题的含热启动策略的 SpaRSALM 算法被记为 SpaRSALM-Warm(SpaRSALM with a warm-started strategy)。此外,本文对算法的鲁棒性进行了验证和研究。

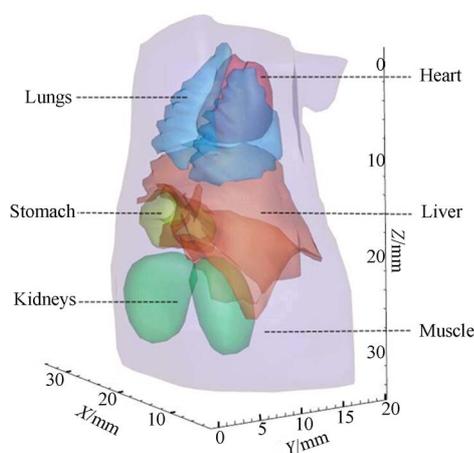
在实验中,本文采用以下客观参数对光源重建评价。第 1 个参数是定位误差 LE(location error),即重建目标的中心点和真实目标的中心点之间的欧氏距离。LE 越小,重建的结果越好。第 2 个参数是重建的时间 Time,重建结果近似的情况下,重建速度越快通常被认为更好。第 3 个参数是对比噪声比 CNR(Contrast to Noise Ratio),用来区分目标信息和背景信息差异^[22]。CNR 的计算公式为:

$$\text{CNR} = \frac{(\mu_{\text{noi}} - \mu_{\text{nob}})}{(\omega_{\text{noi}} \sigma_{\text{noi}}^2 + \omega_{\text{nob}} \sigma_{\text{nob}}^2)^{\frac{1}{2}}}, \quad (22)$$

其中: μ_{noi} 为重建光源在目标区域节点的荧光值的平均值, μ_{nob} 为重建光源在背景区域节点的荧光值的平均值。 ω_{noi} 为目标区域节点所占总节点的比例, σ_{noi}^2 为目标节点的方差。 ω_{nob} 为背景区域节点所占总节点的比例, σ_{nob}^2 为背景节点的方差。 CNR 越大,重建效果越好。

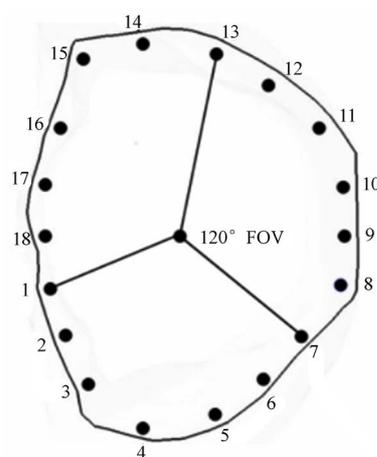
3.1 实验设置

本实验采用数字鼠构建光传输模型。在图 2 中展示了光源被设置在肝脏的位置,18 个激发点的分布情况。数字鼠器官的光学参数设置如表格 3 所示:



(a) 数字鼠模型中小鼠器官的分布

(a) Distribution of difference tissues in the digital mouse model



(b) 激发光源分布 $z=16.5$ mm

(b) Plane of excitation sources at $z=16.5$ mm

图 2 数字鼠模型

Fig. 2 Digital mouse model

表 3 数字鼠模型各个器官的光学参数

Tab. 3 Optical parameters of the mouse organs

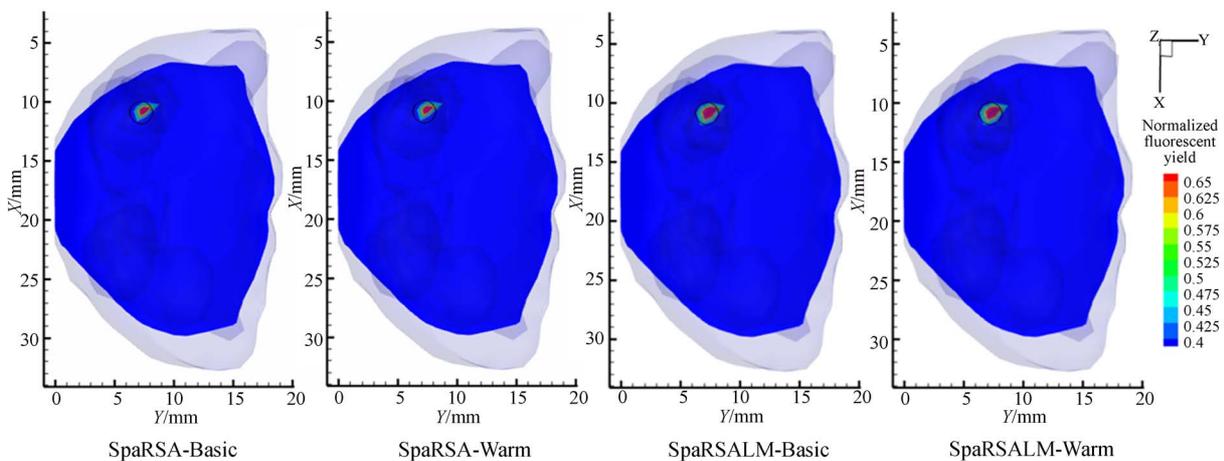
器官	(mm ⁻¹)			
	μ_{ax}	μ'_{sx}	μ_{am}	μ'_{sm}
肌肉	0.005 2	1.08	0.006 8	1.03
心脏	0.008 3	1.01	0.010 4	0.99
肝脏	0.032 9	0.70	0.017 6	0.65
胃	0.011 4	1.74	0.007 0	1.36
肾脏	0.006 6	2.25	0.038 0	2.20
肺脏	0.013 3	1.97	0.020 3	1.95

实验被分为 3 组,第 1 组采用半径 r 为 1 mm 的球形小光源,待重建目标真实中心为 (10.9, 7.4, 15.9) mm。激发点数目为 18 个,激发平面在 $z=16.5$ mm。前向网格选取 20 809 个节点和 113 339 个四面体,后向重建网格选取 3 186 个节点和 15 906 个四面体。第二组采用半径 r 为 2 mm 的球形大光源,空间坐标 (16.4, 11.9, 14.9) mm,前向问题选用网格 20 533 个节点和 114 532 个四面体,逆向网格选用 3 512 个节点和 17 793 个四面体。激发点数目为 18 个,激发平面在 $z=16.5$ mm。第三组采用底面半径 $r=1$ mm,高 $h=2$ mm 的两个圆柱形小光源,待重建目标真实中心分别为 (12, 6.5, 16) mm、(12, 10.5, 16) mm。激发点数目 18 个,激发平面在 $z=16$ mm,前向网格 31 362 个节点和 175 729 个四面体,逆向网格选用 3 186 个节点和 15 906 个四面体。本文所有数值验证都在同一台酷睿 i5 CPU, 6 G 内

存笔记本电脑上进行。

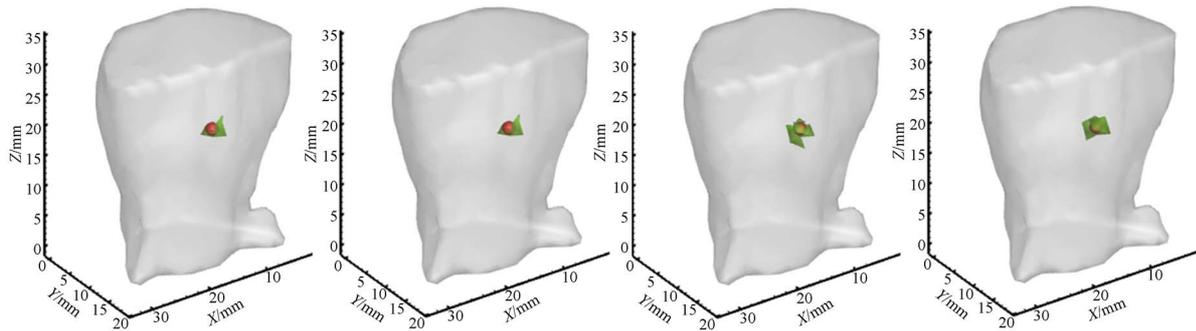
3.2 小目标重建结果

图 3(彩图见期刊电子版)分别展示了 SpaRSA-Basic 算法、SpaRSA-Warm 算法、SpaRSALM-Basic 算法、SpaRSALM-Warm 算法的重建结果。其中,黑色圆圈代表真实光源位置,彩色部分是重建光源。表格 4 是 4 种算法在单光源目标下客观指标: LE、CNR 和算法运行时间 (Time)。从图 3 可知,SpaRSALM-Basic 算法和 SpaRSALM-Warm 算法求解联合稀疏-流形正则模型的重建结果相比 SpaRSA-Basic 算法和 SpaRSA-Warm 算法求解范数稀疏正则模型的重建结果涵盖范围更大一些,契合度更高,这与流行正则项的聚集性是相符的。从表格 4 可知,SpaRSALM-Warm 算法的 LE 是 0.27 mm,优于 SpaRSA-Basic 算法 0.52 mm;在 CNR 上,SpaRSALM-Warm 算法的值为 8.70,相比 SpaRSA-Basic 算法的 6.45,有明显优势。由此可知,求解联合稀疏-流形正则模型的 SpaRSALM-Warm 算法,在重建光源的精度上,优于求解稀疏正则模型的 SpaRSA-Basic 算法。此外,通过表 4 可知,SpaRSALM-Warm 算法重建时间 50.10 s 优于 SpaRSA-Basic 算法的 77.36 s,说明本文的热启动策略,能够加速 SpaRSALM 算法的求解速度。综上可知,相较 SpaRSA-Basic 算法求解范数正则模型,本文提出的 SpaRSALM-Warm 算法求解联合稀疏-流形正则模型能在重建光源的精度和求解速度上,取得一定的比较优势。



(a) 4 种算法重建结果仿体截面图

(a) Cross-sections of phantom reconstructed by four methods



(b)相应的重建结果 3-D 视图

(b)Corresponding 3-D views of three reconstructed results

图 3 小目标下的 18 激发点的重建结果

Fig. 3 Reconstruction results of single-target experiments

表 4 小目标下重建结果 18 激发点结果

Tab. 4 Reconstruction results of single-target experiments

方法	LE/mm	CNR	Time/s
SpaRSA-Basic	0.52	6.45	77.36
SpaRSA-Warm	0.52	6.45	46.39
SpaRSALM-Basic	0.32	9.18	101.84
SpaRSALM-Warm	0.27	8.70	50.10

为测试 SpaRSALM-Warm 算法的抗噪性能,本文将不同水平的高斯白噪声加入表面近红外光分布信息中。五组不同的噪声比分别为 5%,10%,15%,20%和 25%。对每组不同的噪声水平的实验,本文均进行 10 次的独立实验保证重建结果可靠性。表 5 所示为不同噪声水平下,10 次独立实验的 LE 均值、LE 均方差、CNR 均值和 CNR 均方差。由表 5 可知,SpaRSALM-Warm 算法在不同噪声水平下,LE 均值相对稳定

表 5 单光源目标下 SpaRSALM-Warm 算法重建结果随噪声变化

Tab. 5 Variation with noise of SpaRSALM-Warm algorithm on single-target experiments

噪声水平/%	LE 均值	LE 均方差	CNR 均值	CNR 均方差
5	0.31	0.064 7	9.71	0.666 9
10	0.28	0.036 8	8.98	0.747 0
15	0.33	0.062 3	9.68	0.718 0
20	0.36	0.061 4	10.29	0.832 7
25	0.36	0.068 0	10.50	0.966 1

(0.28 ~ 0.36),其 LE 的均方差较小,SpaRSALM-Warm 算法在 LE 上对噪声鲁棒性较强;CNR 均值相对稳定(8.98~10.50),其 CNR 的均方差较小,SpaRSALM-Warm 算法在 CNR 上对噪声鲁棒性较强。综上可知,本文提出的 SpaRSALM-Warm 算法在光源重建的精度上,对噪声有较强的鲁棒性。

3.3 大目标重建结果

图 4 分别展示了 SpaRSA-Basic 算法、SpaRSA-Warm 算法、SpaRSALM-Basic 算法、SpaRSALM-Warm 算法的重建结果的截面图和空间分布图。表 6 是 4 种算法在单光源目标下的 LE、CNR 和 Time。从图 4 可知,SpaRSALM-Basic 算法和 SpaRSALM-Warm 算法求解联合稀疏-流形正则模型的重建结果相比 SpaRSA-Basic 算法和 SpaRSA-Warm 算法求解范数稀疏正则模型的重建光源更加接近于真实光源。从表 6 可知 SpaRSALM-Warm 算法的 LE 和 CNR 分别为 0.75 mm和 15.33,优于 SpaRSA-Basic 算法的 0.84 mm和 9.70。由此可知,相比 SpaRSA-Basic 算法求解范数正则化模型,SpaRSALM-Warm 算法求解联合稀疏-流形正则模型在重建精度上,取得更好的结果。由表 6 可知,SpaRSALM-Warm 算法重建时间 60.10 s,相比于 SpaRSA-Basic 算法的 121.15 s,有显著的优势。本文提出的 SpaRSALM-Warm 算法求解联合稀疏-流形正则模型,相比 SpaRSA-Basic 算法求解范数正则模型,在重建精度和速度上,均取得了明显的优势。

表 6 大目标下重建结果 18 激发点结果

Tab. 6 Reconstruction results of big-target experiments

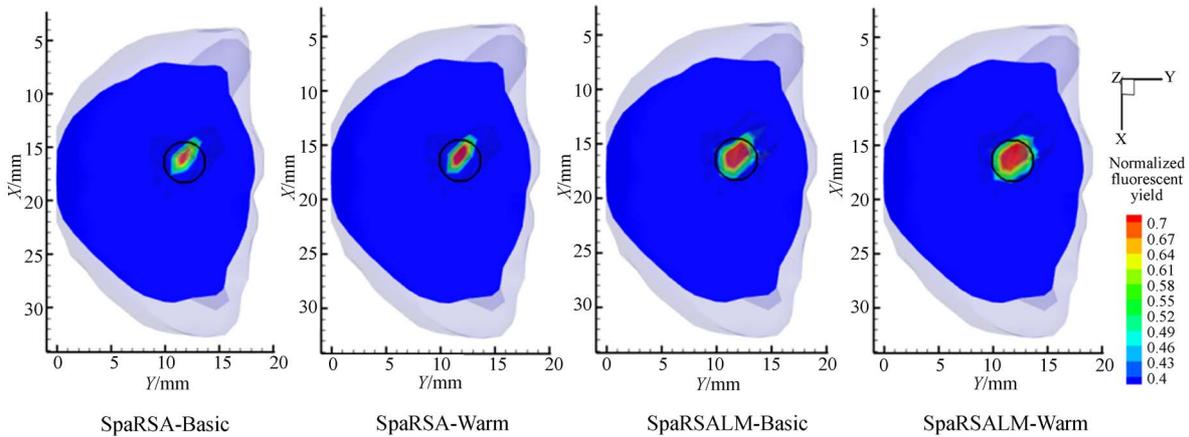
方法	LE/mm	CNR	Time/s
SpaRSA-Basic	0.84	9.70	121.15
SpaRSA-Warm	0.71	10.21	55.88
SpaRSALM-Basic	0.84	12.35	127.70
SpaRSALM-Warm	0.75	15.33	60.10

表 7 大光源目标下 SpaRSALM-Warm 算法重建结果随噪声变化

Tab. 7 Variation with noise of SpaRSALM-Warm algorithm on big-target experiments

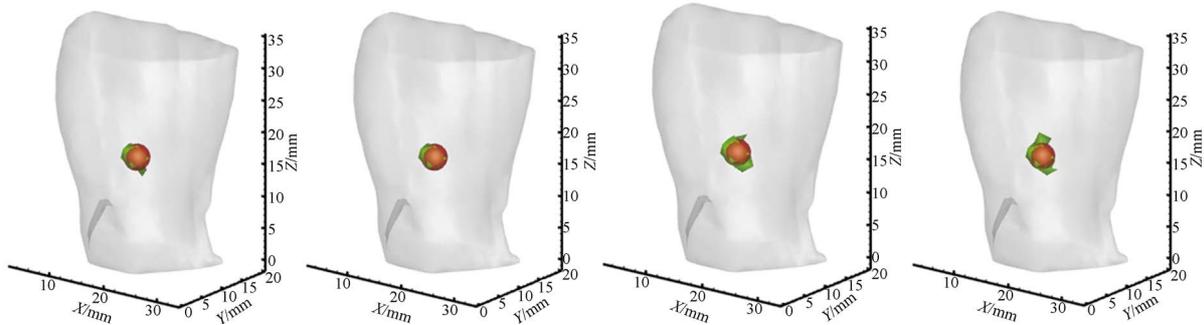
噪声水平/%	LE 均值	LE 均方差	CNR 均值	CNR 均方差
5	0.77	0.093 3	14.75	0.594 3
10	0.81	0.089 5	14.68	0.770 2
15	0.83	0.084 3	16.62	0.613 3
20	0.86	0.095 6	15.03	0.834 1
25	0.84	0.087 0	16.59	0.696 7

为测试 SpaRSALM-Warm 算法的抗噪性能,本文将不同水平的高斯白噪声加入表面近红外光分布信息中。五组不同的噪声比分别为 5%,10%,15%,20% 和 25%。对每组不同的噪声水平的实验,本文均进行 10 次的独立实验保证重建结果可靠性。表 7 所示为不同噪声水平下,10 次独立实验的 LE 均值、LE 均方差、CNR 均值和 CNR 均方差。由表 7 可知,SpaRSALM-Warm 算法在不同噪声水平下,LE 均值相对稳定(0.77~0.86),其 LE 的均方差较小,SpaRSALM-Warm 算法在 LE 上对噪声鲁棒性较强;CNR 均值相对稳定(14.68~16.62),其 CNR 的均方差较小,SpaRSALM-Warm 算法在 CNR 上对噪声鲁棒性较强。综上可知,本文提出的 SpaRSALM-Warm 算法在光源重建的精度上,对噪声有较强的鲁棒性。



(a) 4 种算法重建结果仿体截面图

(a) Cross-sections of phantom reconstructed by different methods



(b) 相应的重建结果 3-D 视图

(b) Corresponding 3-D views of three reconstructed results

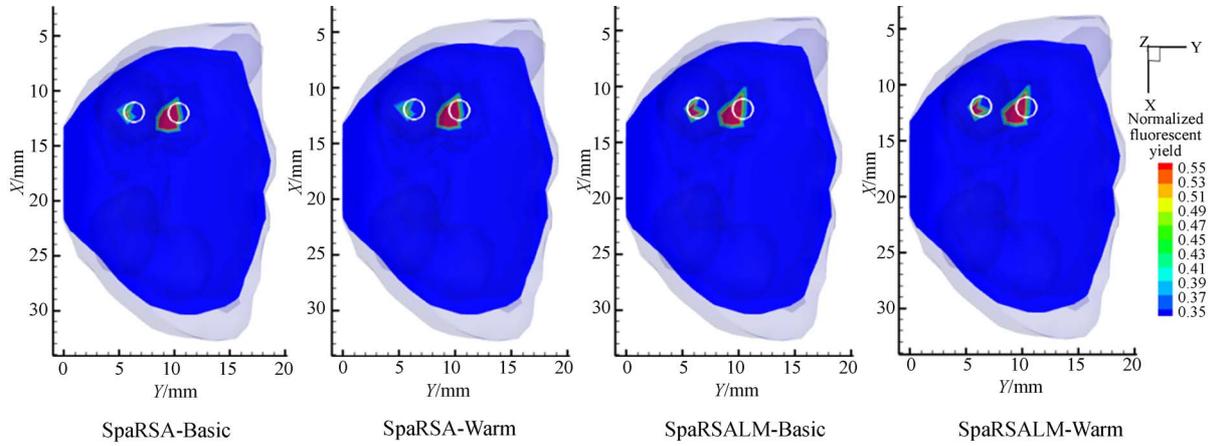
图 4 大目标的重建结果

Fig. 4 Reconstruction results of big-target experiments

3.4 双光源重建结果

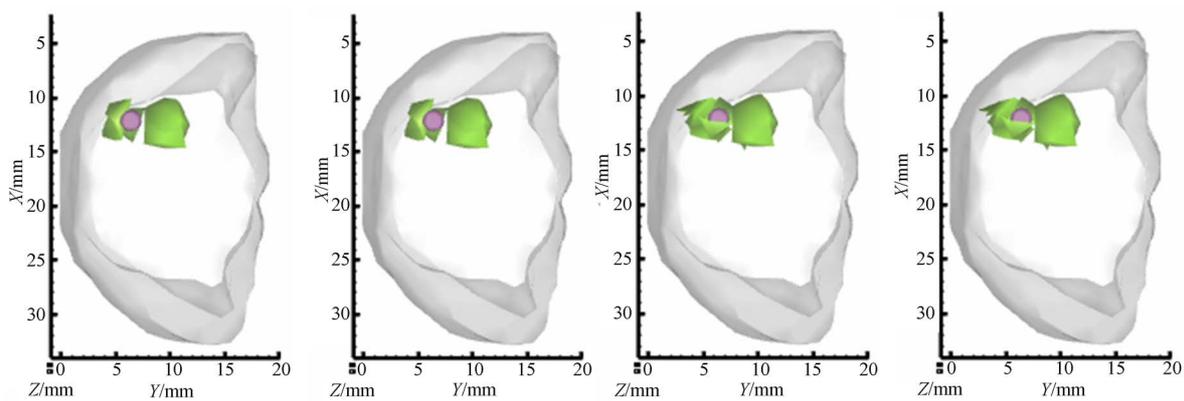
图 5 分别展示了 SpaRSA-Basic 算法、SpaRSA-Warm 算法、SpaRSALM-Basic 算法、SpaRSALM-Warm 算法的重建结果的截面图和空间分布图。表 8 是 4 种算法在单光源目标下的 LE、CNR 和 Time。从图 5 可知, SpaRSALM-Basic 算法和 SpaRSALM-Warm 算法求解联合稀疏-流形正则模型的重建结果相比 SpaRSA-Basic 算法和 SpaRSA-Warm 算法求解范数稀疏正则模型的重建光源更契合真实光源。从表 8 可知, SpaRSALM-Warm 算法两个重建光源的 LE 分别为 1.12 mm 和 0.97 mm, 优于 SpaRSA-Basic 算法

的两个重建光源的 LE 分别为 1.15 mm 和 1.25 mm; SpaRSALM-Warm 算法重建结果的 CNR 为 7.36 同样也优于 SpaRSA-Basic 算法的 3.78。由此可知, 相比 SpaRSA-Basic 算法求解范数正则化模型, SpaRSALM-Warm 算法求解联合稀疏-流形正则模型在重建精度上, 取得更好的结果。从表 8 可知, SpaRSALM-Warm 算法重建时间 50.26 s, 相比于 SpaRSA-Basic 算法的 107.13 s, 有明显的优势。综上所述, 本文提出的 SpaRSALM-Warm 算法求解联合稀疏-流形正则模型, 相比 SpaRSA-Basic 算法求解 L_1 范数正则模型, 在重建精度和速度上, 取得了明显的优势。



(a) 4 种算法重建结果仿体截面图

(a) Cross-sections of phantom reconstructed by different methods



(b) 相应的重建结果 3-D 视图

(b) Corresponding 3-D views of three reconstructed results

图 5 双目标下重建结果

Fig. 5 Reconstruction results of double-target experiments

为测试 SpaRSALM-Warm 算法的抗噪性能, 本文将不同水平的高斯白噪声加入表面近红

外光分布信息中。5 组不同的噪声比分别为 5%, 10%, 15%, 20% 和 25%。对每组不同的噪声水

表 8 双目标下重建结果 18 激发点结果

Tab. 8 Reconstruction results of double-target experiments

方法	LE/mm	CNR	Time/s
SpaRSA-Basic	1.15	3.78	107.13
	1.25		
SpaRSA-Warm	1.11	4.73	48.02
	1.39		
SpaRSALM-Basic	1.05	6.90	108.63
	0.95		
SpaRSALM-Warm	1.12	7.36	50.26
	0.97		

表 9 双光源目标下 SpaRSALM-Warm 算法重建结果随噪声变化

Tab. 9 Variation with noise of SpaRSALM-Warm algorithm on double-target experiments

噪声水平/%	LE		CNR	
	均值	均方差	均值	均方差
5	1.10	0.023 2	7.13	0.358 8
	1.06	0.015 3		
10	1.06	0.027 4	7.02	0.394 4
	1.05	0.014 2		
15	1.10	0.020 7	6.94	0.229 4
	1.06	0.013 1		
20	1.11	0.019 2	6.93	0.204 5
	1.06	0.012 0		
25	1.11	0.021 8	7.16	0.362 6
	1.06	0.014 4		

平的实验,本文均进行 10 次的独立实验保证重建结果可靠性。表 9 展示,不同噪声水平下,10 次独立实验的 LE 均值、LE 均方差、CNR 均值和 CNR 均方差。从表 9 的可知,SpaRSALM-Warm 算法在不同噪声水平下,LE 均值相对稳定(1.05~1.11),其 LE 的均方差较小,SpaRSALM-Warm 算法在 LE 上对噪声鲁棒性较强;CNR 均值相对稳定(6.93~7.16),其 CNR 的均方差较

小,SpaRSALM-Warm 算法在 CNR 上对噪声鲁棒性较强。综上可知,本文提出的 SpaRSALM-Warm 算法在光源重建的精度上,对噪声有较强的鲁棒性。

4 结 论

在 FMT 的逆向问题中,相比于稀疏正则模型,联合稀疏-流形正则模型能够利用更多的先验信息(光源分布的聚集性和光源目标的稀疏性),得到更加精确的光源重建结果。本文对联合稀疏-流形正则模型的原理进行详细的介绍,针对压缩感知最优化程序不能直接求解联合稀疏-流形正则模型的问题,本文重新推导了变量分离近似稀疏重构的方法使其适用于联合稀疏-流形正则模型的求解(即适用于公式(9)的求解,并将其命名为 SpaRSALM 算法。)

经过 3 组数字鼠模型的实验验证,SpaRSALM-Warm 算法求解联合稀疏-流形正则模型的解在 LE、CNR 和 Time 上均优于 SpaRSA-Basic 算法求解范数稀疏正则模型的解。如在单光源小目标时,SpaRSALM-Warm 算法的重建结果与 SpaRSA-Basic 算法相比 CNR 从 6.45 提升至 8.70;LE 从 0.52 mm 降至 0.27 mm;Time 从 77.36 s 减少至 50.10 s。

围绕流形正则项还有很多问题值得研究。很多用于求解正则模型的优化算法都可推广用于求解联合稀疏-流形正则模型,对这些算法的推广与重新设计是未来研究的重要方向;在本文中,公式(9)中的正则项可以被许多稀疏正则项所替代,如范数,范数等等。这些新模型的重建效果如何,需要进一步的分析与验证,因此这是未来研究的另一个重要方向。

参考文献:

[1] NTZIACHRISTOS V, BREMER C, GRAVES E E, *et al.*. In vivo tomographic imaging of near-infrared fluorescent probes[J]. *Molecular Imaging*, 2002,1(2):82-88.

[2] WILLMANN J K, VAN BRUGGEN N, DINKELBORG L M, *et al.*. Molecular imaging in drug development[J]. *Nature Reviews Drug Discovery*, 2008,7(7):591-607.

[3] HE X W, DONG F, YU J J, *et al.*. Reconstruction algorithm for fluorescence molecular tomography

- using sorted L-one penalized estimation[J]. *Journal of the Optical Society of America A Optics Image Science & vision*, 2015,32(11):1928-35.
- [4] BANGERTH W, JOSHI A. Adaptive finite element methods for the solution of inverse problems in optical tomography[J]. *Inverse Problems*, 2008, 24(3):657-682.
- [5] HAN D, YANG X, LIU K, *et al.*. Efficient reconstruction method for L1 regularization in fluorescence molecular tomography[J]. *Applied optics*, 2010,49(36):6930-6937.
- [6] HE X W, LIANG J M, WANG X R, *et al.*. Sparse reconstruction for quantitative bioluminescence tomography based on the incomplete variables truncated conjugate gradient method[J]. *Optics Express*, 2010, 18(24): 24825-24841.
- [7] 郭红波, 贺小伟, 侯榆青, 等. 基于非凸稀疏正则的荧光分子断层成像[J]. *光学学报*, 2015, 35(7): 252-259.
- GUO H B, HE X W, HOU Y Q, *et al.*. Fluorescence Molecular Tomography Based on Nonconvex Sparse Regularization [J]. *Acta Optica Sinica*, 2015,35(7): 252-259. (in Chinese)
- [8] YANG F G, OZTURK M S, ZHAO L L *et al.*. High-Resolution Mesoscopic Fluorescence Molecular Tomography Based on Compressive Sensing[J]. *IEEE Transactions on Biomedical Engineering*, 2015,62(1): 248-255.
- [9] ZHANG J L, SHI J W, GUANG H Z, *et al.*. Iterative Correction Scheme Based on Discrete Cosine Transform and L1 Regularization for Fluorescence Molecular Tomography With Background Fluorescence[J]. *IEEE Transactions on Biomedical Engineering*, 2016,63(6): 1107-1115.
- [10] YU J J, LI Q Y, WANG H Y. Source reconstruction for bioluminescence tomography via L1 / 2 regularization[J]. *Journal of Innovative Optical Health Sciences*, 2017, 1(11):1750014.
- [11] GUO H B, YU J J, HE X W, *et al.*. Improved sparse reconstruction for fluorescence molecular tomography with L1/2 regularization[J]. *Biomedical Optics Express*, 2015, 6(5):1648-1664.
- [12] ZHANG H B, GENG G H, WANG X D, *et al.*. Fast and Robust Reconstruction for Fluorescence Molecular Tomography via L1-2 Regularization [J]. *BioMed Research International*, 2016 (2016), Article ID 5065217.
- [13] YIN P H, LOU Y F, HE Q, *et al.*. Minimization of L1-2 for Compressed Sensing[J]. *Siam Journal on Scientific Computing*, 2015,37(1):A536-A563.
- [14] LOU Y F, YIN P H, HE Q, *et al.*. Computing Sparse Representation in a Highly Coherent Dictionary Based on Difference of L1 and L2[J]. *Journal of Scientific Computing*, 2015, 64(1): 178-196.
- [15] HE X L, WANG X D, YI H J, *et al.*. Laplacian manifold regularization method for fluorescence molecular tomography[J]. *Journal of Biomedical Optics*, 2017,22(4):45009.
- [16] ZHANG J L, SHI J W, ZUO S M, *et al.*. Fast reconstruction in fluorescence molecular tomography using data compression of intra- and inter-projections[J]. *Chinese Optics Letters*, 2015, 13(7): 52-56.
- [17] CONG W X, WANG G, DURAIRAJ K, *et al.*. Practical reconstruction method for bioluminescence tomography[J]. *Optics Express*, 2005, 13(18):6756-6771.
- [18] FIGUEIREDO M T, NOWAK R D, WRIGHT S J. Gradient Projection for Sparse Reconstruction: Application to Compressed Sensing and Other Inverse Problems [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2008, 1(4): 586-597.
- [19] WANG F, ZHANG C S, LI T. Clustering with Local and Global Regularization[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 21(12):1665-1678.
- [20] WRIGHT S J, NOWAK R D, FIGUEIREDO M T. Sparse Reconstruction by Separable Approximation [J]. *IEEE Transactions on Signal Processing*.

2009, 57(7):2479-2493.

- [21] 侯榆青, 贾涛, 易黄健, 等. 基于改进谱投影梯度算法的 X 射线发光断层成像[J]. 光学精密工程, 2017, 25(1):42-49.
- HOU Y Q, JIA T, YI H J, *et al.*. X-ray luminescence computed tomography based on improved

spectral projected gradient algorithm[J]. *Optics and Precision Engineering*, 2017, 25(1):42-49.

- [22] SONG X M, POGUE B W, JIANG S D, *et al.*. Automated region detection based on the contrast-to-noise ratio in near-infrared tomography[J]. *Applied Optics*, 2004, 43(5):1053-1062.

作者简介:



贺小伟(1977—),男,陕西米脂人,教授,博士生导师,2005年于西安交通大学获得硕士学位,2011年于西安电子科技大学获得博士学位,主要从事光学分子影像、医学图像处理及可视化、颅面形态学等方面的研究。E-mail: hexw@nwu.edu.cn

导师简介:



侯榆青(1963—),女,陕西榆林人,教授,博士生导师,1984年于西北大学获得学士学位,1990年于中国科学院西安光机所获得硕士学位,主要从事数字图像处理、医疗大数据相关影像组学研究。E-mail: houyuqing@nwu.edu.cn