



(12) 发明专利申请

(10) 申请公布号 CN 115578361 A

(43) 申请公布日 2023. 01. 06

(21) 申请号 202211305327.0

(22) 申请日 2022.10.24

(71) 申请人 浙大宁波理工学院

地址 315100 浙江省宁波市鄞州区钱湖南
路1号

(72) 发明人 胡秋 蔡卫明 胡绍海 白杨
邹欢清 金婧 马新莉

(74) 专利代理机构 宁波甬致专利代理有限公司
33228

专利代理师 黄亦磊

(51) Int.Cl.

G06T 7/00 (2017.01)

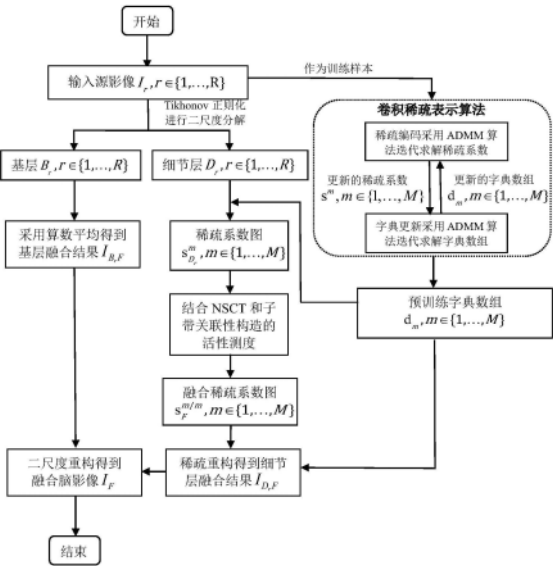
权利要求书4页 说明书12页 附图6页

(54) 发明名称

一种基于卷积稀疏表示的脑影像融合方法

(57) 摘要

本发明公开了一种基于卷积稀疏表示的脑影像融合方法,该方法将自适应卷积稀疏算法作为融合框架,将脑影像既作为训练样本得到预训练字典,又作为测试样本参与融合过程;采用非下采样轮廓波变换,即NSCT,结合子带关联性构造新的活性测度;最后,通过二尺度重构得到融合的脑影像;通过以上方法可有效改善局部失配和纹理结构丢失对卷积稀疏脑影像融合的影响,并可显著降低算法耗时。



1. 一种基于卷积稀疏表示的脑影像融合方法,其特征在于,包括以下步骤:

S1、输入源影像 $I_r, r \in \{1, \dots, R\}$, R 表示影像样本数, r 表示第 r 个影像样本数;

S2、将所述源影像 I_r 作为训练样本通过卷积稀疏表示算法得到预训练字典数组 $d_m, m \in \{1, \dots, M\}$, M 表示字典数组中元素个数, m 表示字典数组中的第 m 个元素,并对源影像 I_r 进行二尺度分解得到基层 B_r 和若干个细节层 D_r ;

S3、每一个所述细节层 D_r 均通过所述预训练字典数组 d_m 进行稀疏编码得到稀疏系数图 $s_{D_r}^m, m \in \{1, \dots, M\}$,并通过NSCT结合子带关联性构造的活性测度得到融合的稀疏系数图 $s_F^{m/m}, m \in \{1, \dots, M\}$;

S4、所述基层 B_r 通过算术平均法得到基层融合结果 $I_{B,F}$,每一个所述细节层 D_r 均对所述融合的稀疏系数图 $s_F^{m/m}$ 进行稀疏重构得到细节层融合结果 $I_{D_r,F}$;

S5、对所述基层融合结果 $I_{B,F}$ 以及所述细节层融合结果 $I_{D_r,F}$ 进行二尺度重构得到融合脑影像 I_F 。

2. 根据权利要求1所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,所述步骤S2中的所述卷积稀疏表示算法包括以下步骤:

S201、定义初始字典数组 $d_m, m \in \{1, \dots, M\}$ 与带约束的辅助变量 y^m ,并构建满足交替方向乘子法的稀疏迭代优化代价函数如下:

$$\arg \min_{\{s^m\}, \{y^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \lambda \sum_m \|y^m\|_1 \quad s.t. \quad s^m - y^m = 0,$$

其中, $\|\cdot\|_2$ 表示向量的内积操作, $*$ 表示卷积操作, λ 表示正则化参数, I 即源影像 I_r , s^m 为稀疏系数;

S202、对所述稀疏迭代优化代价函数中的所述辅助变量 y^m 以及稀疏系数 s^m 求解,并通过所述交替方向乘子法对所述辅助变量 y^m 和所述稀疏系数 s^m 进行迭代优化以及稀疏系数更新;

S203、定义带约束的辅助变量 g_m ,构建满足所述交替方向乘子法的字典迭代优化代价函数如下:

$$\arg \min_{\{d_m\}, \{g_m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \sum_m \iota_{C_{PN}}(g_m) \quad s.t. \quad d_m - g_m = 0, \text{ 其中, 字典范数约束集 } C_{PN} =$$

$\{s \in \mathbb{R}^N : (I - PP^T)s = 0, \|s\|_2 = 1\}$, 可保证优化得到的字典数组结果在空间域具有适当的约束支持, P 表示补零操作, I 表示单位矩阵, s 表示字典数组 d_m 的范数, 和所述辅助变量求解, 并通过所述交替方向乘子法对和所述辅助变量进行迭代优约束集 C_{PN} 的指标函数 $\iota_{C_{PN}}$ 定义为:

$$\iota_{C_{PN}}(g_m) = \begin{cases} 0 & \text{if } g_m \in C_{PN} \\ \infty & \text{if } g_m \notin C_{PN} \end{cases};$$

S204、对所述字典迭代优化代价函数中的所述初始字典数组 d_m 和所述辅助变量 g_m 求解, 并通过所述交替方向乘子法对 d_m 和所述辅助变量 g_m 进行迭代优化以及字典数组更新;

S205、当所述辅助变量 y^m 等于所述稀疏系数 s^m 且所述初始字典数组 d_m 等于所述辅助变量 g_m 时,结束迭代优化更新,得到所述预训练字典数组 d_m 。

3.根据权利要求1所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,所述步骤S3中的稀疏编码的公式如下:

$$\argmin_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \lambda \sum_m \|s^m\|_1;$$

NSCT对每一稀疏系数图 $s_{D_r}^m, m \in \{1, \dots, M\}$ 进行多尺度多方向分解的公式为:

$$f_{\text{NSCT}^K}(s) = (s_{D_r L}, s_{D_r H}^1, \dots, s_{D_r H}^K),$$

其中, f_{NSCT^K} 表示进行K层NSCT分解操作, $s_{D_r L}$ 表示低频子带部分, $s_{D_r H}^1, \dots, s_{D_r H}^K$ 表示具有 2^K 个分解方向的高频子带部分;

子带关联性测度定义为:

$$\rho(s_{D_r H}^k, s_{D_r H}^{k'}) = \frac{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_r H}^k(i, j) - \bar{s}_{D_r H}^k] [s_{D_r H}^{k'}(i, j) - \bar{s}_{D_r H}^{k'}]}{\sqrt{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_r H}^k(i, j) - \bar{s}_{D_r H}^k]^2 \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_r H}^{k'}(i, j) - \bar{s}_{D_r H}^{k'}]^2}},$$

其中 $s_{D_r H}^k$ 和 $s_{D_r H}^{k'}$ 分别表示第k和k'方向的相邻子带; $\bar{s}_{D_r H}^k$ 和 $\bar{s}_{D_r H}^{k'}$ 分别表示 $s_{D_r H}^k$ 和 $s_{D_r H}^{k'}$ 的均值;i和j表示多尺度变换子带系数图的大小。

4.根据权利要求1所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,

所述步骤S2中的所述源影像 I_r 通过Tikhonov正则化方法进行二尺度分解得到基层 B_r 和细节层 D_r ,公式如下:

$$\argmin_{B_r} \|I_r - B_r\|_F^2 + \eta (\|T_x * B_r\|_F^2 + \|T_y * B_r\|_F^2),$$

其中, $T_x = [-1 \ 1]$ 和 $T_y = [-1 \ 1]^T$ 分别表示沿x方向和y方向的梯度算子,得到基层 B_r 后,最终得到相应的细节层为:

$$D_r = I_r - B_r.$$

5.根据权利要求1所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,所述步骤S4中的算术平均法公式为:

$$I_{B_r F}(i, j) = \frac{1}{R} \sum_{r=1}^R B_r(i, j);$$

得到细节层融合结果的公式为:

$$I_{D_r F} = \sum_{m=1}^M d_m * s_F^{m/m}.$$

6.根据权利要求1所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,

所述步骤S5中的二尺度重构即 $I_F = I_{D_r F} + I_{B_r F}$ 。

7.根据权利要求2所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,

所述步骤S202中的所述稀疏系数 s^m 求解的具体过程如下,将所述步骤S202中的稀疏迭

代优化代价函数中所述稀疏系数 s^m 的迭代优化过程表示为:

$$\{s^m\}^{(j+1)} = \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \frac{\rho}{2} \sum_m \|s^m - y^{m(j)} + u_m^{(j)}\|_2^2,$$

并化简为:

$$\arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \frac{\rho}{2} \sum_m \|s^m - z^m\|_2^2,$$

其中,令 $z^m = y^m - u_m$,定义线性操作子 D_m ,则 $D_m s^m = d_m * s^m$,此时上式通过DFT卷积定理可转化为:

$$\arg \min_{\{\hat{s}^m\}} \frac{1}{2} \left\| \sum_m \hat{D}_m \hat{s}^m - \hat{I} \right\|_2^2 + \frac{\rho}{2} \sum_m \|\hat{s}^m - \hat{z}^m\|_2^2,$$

其中, \hat{D}_m 、 \hat{s}^m 、 \hat{I} 和 \hat{z}^m 分别为 D_m 、 s^m 、 I 和 z^m 的离散傅里叶变换,将该式转化为集合形式为:

$$\arg \min_{\{\hat{s}\}} \frac{1}{2} \left\| \hat{D} \hat{s} - \hat{I} \right\|_2^2 + \frac{\rho}{2} \left\| \hat{s} - \hat{z} \right\|_2^2,$$

其中,定义:

$$\hat{D} = (\hat{D}_0 \ \hat{D}_1 \ \dots) \quad , \quad \hat{s} = \begin{pmatrix} \hat{s}^0 \\ \hat{s}^1 \\ \vdots \end{pmatrix} \quad , \quad \hat{z} = \begin{pmatrix} \hat{z}^0 \\ \hat{z}^1 \\ \vdots \end{pmatrix} \quad ,$$

此时,可得稀疏系数解的线性形式:

$$(\hat{D}^H \hat{D} + \rho I) \hat{s} = \hat{D}^H \hat{I} + \rho \hat{z}, \text{ 其中, 矩阵 } \hat{D} \text{ 由 } M \text{ 个串联的 } R \times R \text{ 对角矩阵组成。}$$

8. 根据权利要求2所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,所述步骤S202中的所述辅助变量 y^m 通过收缩软阈值法求解,公式如下:

$$y^{m(j+1)} = S_{\gamma/\rho}(s^{m(j+1)} + u_m^{(j)}),$$

其中,收缩阈值算子满足 $S_{\gamma}(\varphi) = \text{sign}(\varphi) \odot \max(0, |\varphi| - \gamma)$, \odot 表示矩阵元素乘法操作。

9. 根据权利要求2所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,

所述步骤S203中的初始字典数组 d_m 求解的具体过程如下,将所述步骤S203中的字典迭代优化代价函数中的初始字典数组 d_m 迭代优化过程表示为:

$$\{d_m\}^{(j+1)} = \arg \min_{\{d_m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \|d_m - g_m^{(j)} + h_m^{(j)}\|_2^2,$$

并化简为:

$$\arg \min_{\{d_m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \|d_m - z^m\|_2^2,$$

此时上式通过DFT卷积定理可转化为:

$$\arg \min_{\{\hat{\mathbf{d}}_m\}} \frac{1}{2} \sum_r \left\| \sum_m \hat{\mathbf{d}}_m \hat{\mathbf{S}}_r^m - \hat{\mathbf{I}}_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \left\| \hat{\mathbf{d}}_m - \hat{\mathbf{z}}^m \right\|_2^2,$$

其中,满足 $\hat{\mathbf{S}}_r^m = \text{diag}(\hat{\mathbf{s}}_r^m)$, $\hat{\mathbf{s}}_r^m$ 、 $\hat{\mathbf{I}}_r$ 和 $\hat{\mathbf{z}}^m$ 分别为 \mathbf{s}_r^m 、 \mathbf{I}_r 和 \mathbf{z}^m 的离散傅里叶变换;将上式转化为集合形式为:

$$\arg \min_{\{\hat{\mathbf{d}}\}} \frac{1}{2} \sum_r \left\| \hat{\mathbf{d}} \hat{\mathbf{S}}_r - \hat{\mathbf{I}}_r \right\|_2^2 + \frac{\sigma}{2} \left\| \hat{\mathbf{d}} - \hat{\mathbf{z}} \right\|_2^2,$$

其中,定义:

$$\hat{\mathbf{S}}_r = (\hat{\mathbf{S}}_{r,0} \ \hat{\mathbf{S}}_{r,1} \ \cdots) \quad , \quad \hat{\mathbf{d}} = \begin{pmatrix} \hat{\mathbf{d}}^0 \\ \hat{\mathbf{d}}^1 \\ \vdots \end{pmatrix} \quad , \quad \hat{\mathbf{z}} = \begin{pmatrix} \hat{\mathbf{z}}^0 \\ \hat{\mathbf{z}}^1 \\ \vdots \end{pmatrix} \quad ,$$

此时,可得字典数组解的线性形式:

$$\left(\sum_r \hat{\mathbf{S}}_r^H \hat{\mathbf{S}}_r + \sigma \mathbf{I} \right) \hat{\mathbf{d}} = \sum_r \hat{\mathbf{S}}_r^H \hat{\mathbf{I}}_r + \sigma \hat{\mathbf{z}} \quad .$$

10. 根据权利要求2所述的一种基于卷积稀疏表示的脑影像融合方法,其特征在于,所述步骤S204中的所述辅助变量 \mathbf{g}_m 通过prox函数求解,公式如下:

$$\arg \min_x \frac{1}{2} \left\| x - y \right\|_2^2 + \iota_{C_{PN}}(x) = \text{prox}_{\iota_{C_{PN}}}(y) \quad , \text{且需满足:}$$

$$\text{prox}_{\iota_{C_{PN}}}(y) = \begin{cases} PP^T y & \text{if } \|PP^T y\|_2 \leq 1 \\ \frac{PP^T y}{\|PP^T y\|_2} & \text{if } \|PP^T y\|_2 > 1 \end{cases} \quad .$$

一种基于卷积稀疏表示的脑影像融合方法

技术领域

[0001] 本发明涉及脑功能成像技术领域,具体而言,涉及一种基于卷积稀疏表示的脑影像融合方法。

背景技术

[0002] 包括人类在内的动物行为涉及动机、感知、决策、运动控制、反馈等一系列复杂的神经环路功能,如何更好地理解动物的神经环路活动与行为之间的联系,是系统神经科学的重点目标。以鱼类动物的捕食行为为例,现有的对鱼类动物的全脑神经活动的记录都是在头部固定有检测装置的活体鱼上完成的,对脑功能结构的研究有助于提高对鱼类全脑神经活动的理解。脑功能成像处理技术中的脑影像融合,是通过将多模态的脑功能成像关于同一场景的互补信息融合到单一影像中,能够有效提升对脑功能结构信息的立体感知,从而对理解鱼类全脑神经活动与行为之间的联系提供了必要的研究基础。因多模态脑影像成像机制不同,脑影像间往往存在明显的亮暗对比、纹理差异和相似度低等特点。脑影像自身的成像特点使得已有融合方法效果并不理想,因此研究适合于多模态脑影像成像特点的融合方法非常必要。

[0003] 近年来,研究者对多模态脑影像融合进行了广泛的研究。根据所采用的图像变换策略不同,此类研究主要集中在四个方面:基于多尺度变换的方法、基于稀疏表示的方法、基于深度学习的方法以及三者的混合方案。不同于基于基函数假设的多尺度变换,也不同于深度特征选择依赖于人工设计规则的深度学习,稀疏表示通过对不同样本集的训练来学习获得完备字典并用于影像融合,能够实现对源影像更加稳定和灵活的表示,并且稀疏表示方式更符合人类视觉系统的生理机制。然而,传统的稀疏表示因采用分块处理方式进行影像重构,会存在多值性的问题,未能实现影像的全局优化。而卷积稀疏表示(CSR)中字典数组和稀疏系数通过卷积能够实现影像全局优化的目的,所得重构影像具有单值性的特点,既有利于融合结果中的纹理信息,又提高了对影像适配的鲁棒性。

[0004] 基于CSR的脑影像融合性能主要由过完备字典和活性测度表征两个关键因素决定。其中,过完备字典的获取方式通常可分为两种,一种是通过离散余弦变换和小波变换等预先构造的固定字典,另一种是由高质量的自然图像训练得到的学习字典。已有研究表明由源影像训练得到的自适应字典在脑影像融合性能改善方面要优于固定字典。基于此,研究者提出了多种高效的字典学习算法,如联合稀疏模型、同步正交匹配追踪算法、全局字典学习算法和基于梯度信息的分类自适应字典学习算法等。除了过完备字典因素外,活性测度主要用于识别融合过程中源影像的显著特征。不合理的活性测度策略会降低稀疏系数融合的权重精度,如已有基于CSR的脑影像融合中采用 L_1 范数的局部窗平均法构造活性测度,因 L_1 范数采用相同权重使得稀疏显著特征不能有效突出,易造成融合结果中有效信息丢失,此外局部窗平均减弱了CSR图像变换的平移不变性,易造成融合结果在失配区域产生振铃伪影即伪吉布斯现象,并且人为控制的窗口大小也很难获得对配准理想的鲁棒性效果。基于此,结合多模态脑影像成像特点,设计一种字典冗余度低、对配准鲁棒性高的卷积稀疏

脑影像融合方法是非常必要的。

发明内容

[0005] 本发明解决的问题是提供一种基于卷积稀疏表示的脑影像融合方法,字典冗余度低、对配准鲁棒性高,有效改善局部失配和纹理信息丢失对基于卷积稀疏表示的脑影像融合的影响,使得融合结果保留更完备的纹理结构信息,获得满足鱼类捕食行为分析的脑功能成像。

[0006] 为解决上述问题,本发明提供一种基于卷积稀疏表示的脑影像融合方法,,包括以下步骤:

[0007] S1、输入源影像 $I_r, r \in \{1, \dots, R\}$, R 表示影像样本数, r 表示第 r 个影像样本数;

[0008] S2、将源影像 I_r 作为训练样本通过卷积稀疏表示算法得到预训练字典数组 $d_m, m \in \{1, \dots, M\}$, M 表示字典数组中元素个数, m 表示字典数组中的第 m 个元素,并对源影像 I_r 进行二尺度分解得到基层 B_r 和若干个细节层 D_r ;

[0009] S3、每一个细节层 D_r 均对预训练字典数组 d_m 进行稀疏编码得到稀疏系数图 $s_{D_r}^m, m \in \{1, \dots, M\}$,并通过NSCT结合子带关联性构造的活性测度得到融合的稀疏系数图 $s_F^{m/m}, m \in \{1, \dots, M\}$;

[0010] S4、基层 B_r 通过算术平均法得到基层融合结果 $I_{B,F}$,每一个细节层 D_r 均对融合的稀疏系数图 $s_F^{m/m}$ 进行稀疏重构得到细节层融合结果 $I_{D,F}$;

[0011] S5、对基层融合结果 $I_{B,F}$ 以及细节层融合结果 $I_{D,F}$ 进行二尺度重构得到融合脑影像 I_F 。

[0012] 进一步地,步骤S2中的卷积稀疏表示算法包括以下步骤:

[0013] S201、定义初始字典数组 $d_m, m \in \{1, \dots, M\}$ 与带约束的辅助变量 y^m ,并构建满足交替方向乘子法的稀疏迭代优化代价函数如下:

$$[0014] \quad \argmin_{\{s^m\}, \{y^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \lambda \sum_m \|y^m\|_1 \quad s.t. \quad s^m - y^m = 0,$$

[0015] 其中, $\|\cdot\|_2^2$ 表示向量的内积操作, $*$ 表示卷积操作, λ 表示正则化参数,

[0016] S202、对稀疏迭代优化代价函数中的辅助变量 y^m 以及稀疏系数 s^m 求解,并通过交替方向乘子法对辅助变量 y^m 和稀疏系数 s^m 进行迭代优化以及稀疏系数更新;

[0017] S203、定义带约束的辅助变量 g_m ,构建满足交替方向乘子法的字典迭代优化代价函数如下:

$$[0018] \quad \argmin_{\{d_m\}, \{g_m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \sum_m \iota_{C_{PN}}(g_m) \quad s.t. \quad d_m - g_m = 0, \text{ 其中, 字典范数约束集}$$

$C_{PN} = \{s \in \mathbb{R}^N: (I - PP^T)s = 0 \mid \|s\|_2 = 1\}$, 可保证优化得到的字典数组结果在空间域具有适当的约束支持, P 表示补零操作, I 表示单位矩阵, 约束集 C_{PN} 的指标函数 $\iota_{C_{PN}}$ 定义为:

$$[0019] \quad t_{C_{PN}}(g_m) = \begin{cases} 0 & \text{if } g_m \in C_{PN}; \\ \infty & \text{if } g_m \notin C_{PN}; \end{cases}$$

[0020] S204、对字典迭代优化代价函数中的初始字典数组 d_m 和辅助变量 g_m 求解,并通过交替方向乘法对 d_m 和辅助变量 g_m 进行迭代优化以及字典数组更新;

[0021] S205、当辅助变量 y^m 等于稀疏系数 s^m 且初始字典数组 d_m 等于辅助变量 g_m 时,结束迭代优化更新,得到预训练字典数组 d_m 。

[0022] 进一步地,步骤S3中的稀疏编码的公式如下:

$$[0023] \quad \underset{\{s^m\}}{\operatorname{argmin}} \quad \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \lambda \sum_m \|s^m\|_1;$$

[0024] NSCT对每一稀疏系数图 $s_{D_r}^m, m \in \{1, \dots, M\}$ 进行多尺度多方向分解的公式为:

$$[0025] \quad f_{\text{NSCT}^K}(s) = (s_{D_r, L}, s_{D_r, H}^1, \dots, s_{D_r, H}^K)$$

[0026] 其中, f_{NSCT^K} 表示进行K层NSCT分解操作。 $s_{D_r, L}$ 表示低频子带部分, $s_{D_r, H}^1, \dots, s_{D_r, H}^K$ 表示具有 2^K 个分解方向的高频子带部分。

[0027] 子带关联性测度定义为:

$$[0028] \quad \rho(s_{D_r, H}^k, s_{D_r, H}^{k'}) = \frac{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_r, H}^k(i, j) - \bar{s}_{D_r, H}^k] [s_{D_r, H}^{k'}(i, j) - \bar{s}_{D_r, H}^{k'}]}{\sqrt{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_r, H}^k(i, j) - \bar{s}_{D_r, H}^k]^2 \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_r, H}^{k'}(i, j) - \bar{s}_{D_r, H}^{k'}]^2}}$$

[0029] 其中, $s_{D_r, H}^k$ 和 $s_{D_r, H}^{k'}$ 分别表示第k和k'方向的相邻子带; $\bar{s}_{D_r, H}^k$ 和 $\bar{s}_{D_r, H}^{k'}$ 分别表示 $s_{D_r, H}^k$ 和 $s_{D_r, H}^{k'}$ 的均值; i和j表示多尺度变换子带系数图的大小。

[0030] 进一步地,步骤S2中的源影像 I_r 通过Tikhonov正则化方法进行二尺度分解得到基层 B_r 和细节层 D_r ,公式如下:

$$[0031] \quad \underset{B_r}{\operatorname{argmin}} \quad \|I_r - B_r\|_F^2 + \eta (\|T_x * B_r\|_F^2 + \|T_y * B_r\|_F^2),$$

[0032] 其中, $T_x = [-1 \ 1]$ 和 $T_y = [-1 \ 1]^T$ 分别表示沿x方向和y方向的梯度算子,得到基层 B_r 后,最终得到相应的细节层为:

$$[0033] \quad D_r = I_r - B_r。$$

[0034] 进一步地,步骤S4中的算术平均法公式为:

$$[0035] \quad I_{B_r, F}(i, j) = \frac{1}{R} \sum_{r=1}^R B_r(i, j);$$

[0036] 得到细节层融合结果的公式为:

$$[0037] \quad I_{D_r, F} I_{D_r, F} = \sum_{m=1}^M d_m * s_F^{m/m}。$$

[0038] 进一步地,步骤S5中的二尺度重构即 $I_F = I_{D_r, F} + I_{B_r, F}。$

[0039] 进一步地,步骤S202中的稀疏系数 s^m 求解的具体过程如下,将步骤S202中的稀疏迭代优化代价函数中稀疏系数 s^m 的迭代优化过程表示为:

$$[0040] \quad \{s^m\}^{(j+1)} = \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \frac{\rho}{2} \sum_m \|s^m - y^{m(j)} + u_m^{(j)}\|_2^2,$$

[0041] 并化简为:

$$[0042] \quad \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \frac{\rho}{2} \sum_m \|s^m - z^m\|_2^2,$$

[0043] 其中,令 $z^m = y^m - u_m$,定义线性操作子 D_m ,则 $D_m s^m = d_m * s^m$,此时上式通过DFT卷积定理可转化为:

$$[0044] \quad \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m \hat{D}_m \hat{s}^m - \hat{I} \right\|_2^2 + \frac{\rho}{2} \sum_m \|\hat{s}^m - \hat{z}^m\|_2^2 \quad \text{其中, } \hat{D}_m, \hat{s}^m, \hat{I} \text{ 和 } \hat{z}^m \text{ 分别为 } D_m, s^m, I \text{ 和 } z^m \text{ 的}$$

离散傅里叶变换,将该式转化为集合形式为:

$$[0045] \quad \arg \min_{\{\hat{s}\}} \frac{1}{2} \left\| \hat{D} \hat{s} - \hat{I} \right\|_2^2 + \frac{\rho}{2} \left\| \hat{s} - \hat{z} \right\|_2^2$$

[0046] 其中,定义:

$$[0047] \quad \hat{D} = (\hat{D}_0 \hat{D}_1 \dots) \hat{s} = \begin{pmatrix} \hat{s}^0 \\ \hat{s}^1 \\ \vdots \end{pmatrix} \quad \hat{z} = \begin{pmatrix} \hat{z}^0 \\ \hat{z}^1 \\ \vdots \end{pmatrix}$$

[0048] 此时,可得稀疏系数解的线性形式:

$$[0049] \quad (\hat{D}^H \hat{D} + \rho I) \hat{s} = \hat{D}^H \hat{I} + \rho \hat{z}, \quad \text{其中,矩阵 } \hat{D} \text{ 由 } M \text{ 个串联的 } R \times R \text{ 对角矩阵组成。}$$

[0050] 进一步地,步骤S202中的辅助变量 y^m 通过收缩软阈值法求解,公式如下:
 $y^{m(j+1)} = S_{\gamma/\rho}(s^{m(j+1)} + u_m^{(j)})$,其中,收缩阈值算子满足 $S_\gamma(\varphi) = \text{sign}(\varphi) \odot \max(0, |\varphi| - \gamma)$, \odot 表示矩阵元素乘法操作。

[0051] 进一步地,步骤S203中的初始字典数组 d_m 求解的具体过程如下,将步骤S203中的字典迭代优化代价函数中的初始字典数组 d_m 迭代优化过程表示为:

$$[0052] \quad \{d_m\}^{(j+1)} = \arg \min_{\{d_m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \|d_m - g_m^{(j)} + h_m^{(j)}\|_2^2,$$

[0053] 并化简为:

$$[0054] \quad \arg \min_{\{d_m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \|d_m - z^m\|_2^2,$$

[0055] 此时上式通过DFT卷积定理可转化为:

$$[0056] \quad \arg \min_{\{\hat{d}_m\}} \frac{1}{2} \sum_r \left\| \sum_m \hat{d}_m \hat{S}_r^m - \hat{I}_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \|\hat{d}_m - \hat{z}^m\|_2^2,$$

[0057] 其中,满足 $\hat{S}_r^m = \text{diag}(\hat{s}_r^m)$, \hat{s}_r^m 、 \hat{I}_r 和 \hat{z}^m 分别为 s_r^m 、 I_r 和 z^m 的离散傅里叶变换;将上式

转化为集合形式为：

$$[0058] \quad \arg \min_{\{\hat{\mathbf{d}}\}} \frac{1}{2} \sum_r \left\| \hat{\mathbf{d}} \hat{\mathbf{S}}_r - \hat{\mathbf{I}}_r \right\|_2^2 + \frac{\sigma}{2} \left\| \hat{\mathbf{d}} - \hat{\mathbf{z}} \right\|_2^2,$$

[0059] 其中,定义:

$$[0060] \quad \hat{\mathbf{S}}_r = (\hat{\mathbf{S}}_{r,0} \ \hat{\mathbf{S}}_{r,1} \ \cdots) \ \hat{\mathbf{d}} = \begin{pmatrix} \hat{\mathbf{d}}^0 \\ \hat{\mathbf{d}}^1 \\ \vdots \end{pmatrix} \ \hat{\mathbf{z}} = \begin{pmatrix} \hat{\mathbf{z}}^0 \\ \hat{\mathbf{z}}^1 \\ \vdots \end{pmatrix}$$

[0061] 此时,可得字典数组解的线性形式:

$$[0062] \quad \left(\sum_r \hat{\mathbf{S}}_r^H \hat{\mathbf{S}}_r + \sigma \mathbf{I} \right) \hat{\mathbf{d}} = \sum_r \hat{\mathbf{S}}_r^H \hat{\mathbf{I}}_r + \sigma \hat{\mathbf{z}}.$$

[0063] 进一步地,步骤204中的辅助变量 \mathbf{g}_m 通过prox函数求解,公式如下:

$$[0064] \quad \arg \min_x \frac{1}{2} \left\| \mathbf{x} - \mathbf{y} \right\|_2^2 + \iota_{C_{PN}}(\mathbf{x}) = \text{prox}_{\iota_{C_{PN}}}(\mathbf{y}), \text{ 且需满足:}$$

$$[0065] \quad \text{prox}_{\iota_{C_{PN}}}(\mathbf{y}) = \begin{cases} PP^T \mathbf{y} & \text{if } \|PP^T \mathbf{y}\|_2 \leq 1 \\ \frac{PP^T \mathbf{y}}{\|PP^T \mathbf{y}\|_2} & \text{if } \|PP^T \mathbf{y}\|_2 > 1 \end{cases}.$$

[0066] 本发明带来的有益效果为,采用自适应卷积稀疏表示来降低算法耗时和融合性能的不确定性;采用NSCT结合子带关联性构造新的活性测度来改善融合结果对失配的敏感性和保留更完备的有效信息。通过以上措施可有效改善局部失配和纹理结构丢失对卷积稀疏脑影像融合的影响,并可显著降低算法耗时

附图说明

[0067] 图1为基于NSCT和子带关联性的自适应卷积稀疏脑影像融合系统框架图;

[0068] 图2为本发明方法的流程示意图;

[0069] 图3为活性测度表征对融合性能的影响示意图;

[0070] 图4为局部失配对融合性能的影响示意图;

[0071] 图5为对CT/MRI脑影像对采用不同融合方法的性能对比示意图;

[0072] 图6为对CT/MR-T1脑影像对采用不同融合方法的性能对比示意图;

[0073] 图7为对CT/MR-T2脑影像对采用不同融合方法的性能对比示意图;

[0074] 图8为不同融合方法的整体客观统计结果示意图;

[0075] 图9为不同融合方法在三组脑影像对下的客观性能对比示意图;

[0076] 图10为不同方法融合空间分辨率为 256×256 的两脑影像时的CPU耗时示意图。

具体实施方式

[0077] 为使本发明的上述目的、特征和优点能够更为明显易懂,下面结合附图对本发明的具体实施例做详细的说明。

[0078] 需要说明的是,以下实施例假设多模态脑影像间已完成严格的配准,该假设是此类融合方案的典型情况,非本发明的特殊要求;以下定义的第一辅助变量 y^m 和第二辅助变量 g^m 仅是为了区分两个辅助变量,并不是表示该两个变量有某种先后关系;以下实施例将交替方向乘子法简称为ADMM算法,离散傅里叶变换卷积定理简称为DFT卷积定理。

[0079] 本实施例提供一种基于卷积稀疏表示的脑影像融合方法,包括以下步骤:

[0080] 输入源影像 $I_r, r \in \{1, \dots, R\}$;其中, R 表示影像样本数, r 表示第 r 个影像样本数;

[0081] 将输入的源影像 I_r 作为训练样本通过卷积稀疏表示算法得到预训练字典数组 $d_m, m \in \{1, \dots, M\}$;

[0082] 对源影像 I_r 通过Tikhonov正则化方法进行二尺度分解得到基层 B_r 和细节层 D_r ;

[0083] 每一所述细节层 D_r 均通过对预训练字典数组 d_m 进行稀疏编码得到稀疏系数图 $s_{D_r}^m, m \in \{1, \dots, M\}$,并通过NSCT结合子带关联性构造的活性测度得到融合的稀疏系数图 $s_F^{m/m}, m \in \{1, \dots, M\}$;

[0084] 基层 B_r 通过算术平均法得到基层融合结果 I_{B_rF} ,细节层 D_r 通过对稀疏系数图 $s_F^{m/m}, m \in \{1, \dots, M\}$ 进行稀疏重构得到细节层融合结果 I_{D_rF} ;对基层融合结果 I_{B_rF} 以及细节层融合结果 I_{D_rF} 进行二尺度重构得到融合脑影像 I_F 。

[0085] 其中,卷积稀疏表示算法包括以下步骤:

[0086] 定义初始字典数组 $D_m, m \in \{1, \dots, M\}$ 与带约束的第一辅助变量, M 表示字典数组中元素的个数, m 表示第 m 个元素,并构建满足所述交替方向乘子法的稀疏迭代优化代价函数;

[0087] 对稀疏迭代优化代价函数中的第一辅助变量通过收缩软阈值法求解,对稀疏系数通过离散傅里叶变换卷积定理求解,并通过ADMM算法对第一辅助变量和稀疏系数进行迭代优化以及稀疏系数更新;

[0088] 定义字典数组 D_m 中带约束的第二辅助变量,构建满足ADMM算法的字典迭代优化代价函数;

[0089] 对字典迭代优化代价函数中的字典数组 D_m 通过离散傅里叶变换卷积定理求解,对第二辅助变量prox函数求解,并通过ADMM算法对 D_m 和第二辅助变量进行迭代优化以及字典数组更新;

[0090] 当时第一辅助变量等于稀疏系数时,得到预训练字典数组 $d_m, m \in \{1, \dots, M\}$ 。

[0091] 还需要说明的是,以下为简化描述,将初始字典数组 D_m 与预训练字典数组 d_m 均用 d_m 表示,上述的各算法的具体实施方式如下:

[0092] 卷积稀疏表示算法:

[0093] 卷积稀疏表示算法采用一组稀疏系数图 s_r^m 和相应的字典数组 $d_m, m \in \{1, \dots, M\}$ 的卷积和的形式对脑影像 $I_r, r \in \{1, \dots, R\}$ 进行近似,公式如下:

$$[0094] \quad \argmin_{\{d_m\}, \{s_r^m\}} \frac{1}{2} \sum_r \left\| \sum_m d_m * s_r^m - I_r \right\|_2^2 + \lambda \sum_r \sum_m \|s_r^m\|_1 \quad s.t. \quad \|d_m\|_2 = 1$$

[0095] 其中, $\|\cdot\|_2^2$ 表示向量的内积操作, $*$ 表示卷积操作, λ 表示正则化参数, M 表示字典数组中元素个数, m 表示字典数组中的第 m 个元素, R 表示影像样本数, r 表示第 r 个影像样本数。

[0096] 具有稀疏惩罚项 $\|s\|_1$ 形式的稀疏编码算法,即卷积基追踪去噪问题,定义为:

$$[0097] \quad \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \lambda \sum_m \|s^m\|_1 \quad (1)$$

[0098] 通过引入带约束的第一辅助变量 y^m 以采用ADMM算法迭代求解上述优化问题,此时稀疏编码的代价函数可转化为:

$$[0099] \quad \arg \min_{\{s^m\}, \{y^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \lambda \sum_m \|y^m\|_1 \quad s.t. \quad s^m - y^m = 0$$

[0100] 相应的变量迭代优化过程可表示为:

$$[0101] \quad \{s^m\}^{(j+1)} = \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \frac{\rho}{2} \sum_m \|s^m - y^{m(j)} + u_m^{(j)}\|_2^2 \quad (2)$$

$$[0102] \quad \{y^m\}^{(j+1)} = \arg \min_{\{y^m\}} \lambda \sum_m \|y^m\|_1 + \frac{\rho}{2} \sum_m \|s^{m(j+1)} - y^m + u_m^{(j)}\|_2^2 \quad (3)$$

$$[0103] \quad u_m^{(j+1)} = u_m^{(j)} + s^{m(j+1)} - y^{m(j+1)} \quad (4)$$

[0104] 上述迭代循环过程中,变量 y^m 可采用收缩软阈值法来求解:

$$[0105] \quad y^{m(j+1)} = S_{\gamma/\rho}(s^{m(j+1)} + u_m^{(j)})$$

[0106] 其中,收缩阈值算子满足 $S_\gamma(\varphi) = \text{sign}(\varphi) \odot \max(0, |\varphi| - \gamma)$, \odot 表示矩阵元素乘法操作。

[0107] 稀疏系数 s^m 可采用DFT卷积定理来求解,此时 (2) 式可简化为:

$$[0108] \quad \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m d_m * s^m - I \right\|_2^2 + \frac{\rho}{2} \sum_m \|s^m - z^m\|_2^2 \quad (5)$$

[0109] 其中,令 $z^m = y^m - u_m$ 。定义线性操作子 D_m , 则 $D_m s^m = d_m * s^m$, 此时 (5) 式通过DFT卷积定理可转化为:

$$[0110] \quad \arg \min_{\{s^m\}} \frac{1}{2} \left\| \sum_m \widehat{D}_m \widehat{s}^m - \widehat{I} \right\|_2^2 + \frac{\rho}{2} \sum_m \|\widehat{s}^m - \widehat{z}^m\|_2^2 \quad (6)$$

[0111] 其中, \widehat{D}_m 、 \widehat{s}^m 、 \widehat{I} 和 \widehat{z}^m 分别为 D_m 、 s^m 、 I 和 z^m 的离散傅里叶变换。将 (6) 式转化为集合形式为:

$$[0112] \quad \arg \min_{\{\widehat{s}\}} \frac{1}{2} \left\| \widehat{D} \widehat{s} - \widehat{I} \right\|_2^2 + \frac{\rho}{2} \left\| \widehat{s} - \widehat{z} \right\|_2^2 \quad (7)$$

[0113] 其中,定义:

$$[0114] \quad \widehat{D} = (\widehat{D}_0 \quad \widehat{D}_1 \quad \dots) \quad \widehat{s} = \begin{pmatrix} \widehat{s}^0 \\ \widehat{s}^1 \\ \vdots \end{pmatrix} \quad \widehat{z} = \begin{pmatrix} \widehat{z}^0 \\ \widehat{z}^1 \\ \vdots \end{pmatrix}$$

[0115] 此时,通过 (7) 式可得稀疏系数解的线性形式:

$$[0116] \quad (\hat{\mathbf{D}}^H \hat{\mathbf{D}} + \rho \mathbf{I}) \hat{\mathbf{s}} = \hat{\mathbf{D}}^H \hat{\mathbf{I}} + \rho \hat{\mathbf{z}} \quad (8)$$

[0117] 其中,矩阵 $\hat{\mathbf{D}}$ 由M个串联的 $R \times R$ 对角矩阵组成,M表示字典数组中的元素个数,R表示图像 $\hat{\mathbf{I}}$ 中的样本数。 \mathbf{I} 表示单位矩阵。

[0118] 由于(8)式中的线性形式符合Sherman-Morrison公式求解线性系统的要求,因此采用Sherman-Morrison公式快速得到迭代的稀疏系数。最后,通过离散傅里叶逆变换得到迭代的稀疏系数。(2)-(4)式迭代循环实现稀疏系数更新,直至第一辅助变量 y^m 等于稀疏系数 s^m ,结束迭代循环。

[0119] 稀疏编码得到稀疏系数后,相应的字典更新算法为最优方向法(MOD)的卷积形式,定义为:

$$[0120] \quad \underset{\{\mathbf{d}_m\}}{\operatorname{argmin}} \quad \frac{1}{2} \sum_r \left\| \sum_m \mathbf{d}_m * \mathbf{s}_r^m - \mathbf{I}_r \right\|_2^2 \quad s.t. \quad \mathbf{d}_m \in C_{PN}$$

[0121] 其中,字典范数约束集 $C_{PN} = \{\mathbf{s} \in \mathbb{R}^N : (\mathbf{I} - \mathbf{P}\mathbf{P}^T) \mathbf{s} = 0, \|\mathbf{s}\|_2 = 1\}$ 可保证优化得到的字典数组结果在空间域具有适当的约束支持,P表示补零操作, \mathbf{I} 表示单位矩阵。

[0122] 通过引入带约束的第二辅助变量 \mathbf{g}_m 以采用ADMM算法迭代求解上述优化问题,此时字典更新的代价函数可转化为:

$$[0123] \quad \underset{\{\mathbf{d}_m\}, \{\mathbf{g}_m\}}{\operatorname{argmin}} \quad \frac{1}{2} \sum_r \left\| \sum_m \mathbf{d}_m * \mathbf{s}_r^m - \mathbf{I}_r \right\|_2^2 + \sum_m \iota_{C_{PN}}(\mathbf{g}_m) \quad s.t. \quad \mathbf{d}_m - \mathbf{g}_m = 0$$

[0124] 其中,约束集 C_{PN} 的指标函数 $\iota_{C_{PN}}$ 定义为:

$$[0125] \quad \iota_{C_{PN}}(\mathbf{g}_m) = \begin{cases} 0 & \text{if } \mathbf{g}_m \in C_{PN} \\ \infty & \text{if } \mathbf{g}_m \notin C_{PN} \end{cases}$$

[0126] 此时,利用ADMM算法原理得到的变量迭代优化过程可表示为:

$$[0127] \quad \{\mathbf{d}_m\}^{(j+1)} = \underset{\{\mathbf{d}_m\}}{\operatorname{argmin}} \quad \frac{1}{2} \sum_r \left\| \sum_m \mathbf{d}_m * \mathbf{s}_r^m - \mathbf{I}_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \left\| \mathbf{d}_m - \mathbf{g}_m^{(j)} + \mathbf{h}_m^{(j)} \right\|_2^2 \quad (9)$$

$$[0128] \quad \{\mathbf{g}_m\}^{(j+1)} = \underset{\{\mathbf{g}_m\}}{\operatorname{argmin}} \quad \sum_m \iota_{C_{PN}}(\mathbf{g}_m) + \frac{\sigma}{2} \sum_m \left\| \mathbf{d}_m^{(j+1)} - \mathbf{g}_m + \mathbf{h}_m^{(j)} \right\|_2^2 \quad (10)$$

$$[0129] \quad \mathbf{h}_m^{(j+1)} = \mathbf{h}_m^{(j)} + \mathbf{d}_m^{(j+1)} - \mathbf{g}_m^{(j+1)} \quad (11)$$

[0130] 上述迭代循环过程中,变量 \mathbf{g}_m 的求解满足几何关系:

$$[0131] \quad \underset{x}{\operatorname{argmin}} \quad \frac{1}{2} \|x - y\|_2^2 + \iota_{C_{PN}}(x) = \operatorname{prox}_{\iota_{C_{PN}}}(y)$$

[0132] 则可直接采用prox函数来求解该问题,满足:

$$[0133] \quad \operatorname{prox}_{\iota_{C_{PN}}}(y) = \begin{cases} \mathbf{P}\mathbf{P}^T y & \text{if } \|\mathbf{P}\mathbf{P}^T y\|_2 \leq 1 \\ \frac{\mathbf{P}\mathbf{P}^T y}{\|\mathbf{P}\mathbf{P}^T y\|_2} & \text{if } \|\mathbf{P}\mathbf{P}^T y\|_2 > 1 \end{cases}$$

[0134] 字典数组 \mathbf{d}_m 的求解可通过DFT卷积定理来求解,此时(9)式可简化为:

$$[0135] \quad \arg \min_{\{\mathbf{d}_m\}} \frac{1}{2} \sum_r \left\| \sum_m \mathbf{d}_m * \mathbf{s}_r^m - \mathbf{I}_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \left\| \mathbf{d}_m - \mathbf{z}^m \right\|_2^2 \quad (12)$$

[0136] 通过DFT卷积定理, (12) 式可转化为:

$$[0137] \quad \arg \min_{\{\hat{\mathbf{d}}_m\}} \frac{1}{2} \sum_r \left\| \sum_m \hat{\mathbf{d}}_m \hat{\mathbf{S}}_r^m - \hat{\mathbf{I}}_r \right\|_2^2 + \frac{\sigma}{2} \sum_m \left\| \hat{\mathbf{d}}_m - \hat{\mathbf{z}}^m \right\|_2^2 \quad (13)$$

[0138] 其中, 满足 $\hat{\mathbf{S}}_r^m = \text{diag}(\hat{\mathbf{s}}_r^m)$, $\hat{\mathbf{s}}_r^m$ 、 $\hat{\mathbf{I}}_r$ 和 $\hat{\mathbf{z}}^m$ 分别为 \mathbf{s}_r^m 、 \mathbf{I}_r 和 \mathbf{z}^m 的离散傅里叶变换。将 (13) 式转化为集合形式为:

$$[0139] \quad \arg \min_{\{\hat{\mathbf{d}}\}} \frac{1}{2} \sum_r \left\| \hat{\mathbf{d}} \hat{\mathbf{S}}_r - \hat{\mathbf{I}}_r \right\|_2^2 + \frac{\sigma}{2} \left\| \hat{\mathbf{d}} - \hat{\mathbf{z}} \right\|_2^2 \quad (14)$$

[0140] 其中, 定义:

$$[0141] \quad \hat{\mathbf{S}}_r = (\hat{\mathbf{S}}_{r,0} \hat{\mathbf{S}}_{r,1} \dots) \hat{\mathbf{d}} = \begin{pmatrix} \hat{\mathbf{d}}^0 \\ \hat{\mathbf{d}}^1 \\ \vdots \end{pmatrix} \hat{\mathbf{z}} = \begin{pmatrix} \hat{\mathbf{z}}^0 \\ \hat{\mathbf{z}}^1 \\ \vdots \end{pmatrix}$$

[0142] 此时, 通过 (14) 式可得字典数组解的线性形式:

$$[0143] \quad \left(\sum_r \hat{\mathbf{S}}_r^H \hat{\mathbf{S}}_r + \sigma \mathbf{I} \right) \hat{\mathbf{d}} = \sum_r \hat{\mathbf{S}}_r^H \hat{\mathbf{I}}_r + \sigma \hat{\mathbf{z}} \quad (15)$$

[0144] 由于 (15) 式中的线性形式符合Sherman-Morrison公式求解线性系统的要求, 因此采用Sherman-Morrison公式快速得到迭代的字典数组。利用上述DFT卷积定理和重复Sherman-Morrison公式循环, 可得到 (8) 式中迭代的字典数组。

[0145] 通过上述稀疏编码和字典更新的循环迭代, 直至第一辅助变量 \mathbf{y}^m 等于稀疏系数 \mathbf{s}^m , 结束迭代循环, 获得卷积稀疏表示下的预训练字典。

[0146] 影像二尺度分解:

[0147] 每一源影像 $\mathbf{I}_r, r \in \{1, \dots, R\}$ 通过如下代价函数分解得到基层 \mathbf{B}_r 和细节层 \mathbf{D}_r :

$$[0148] \quad \arg \min_{\mathbf{B}_r} \left\| \mathbf{I}_r - \mathbf{B}_r \right\|_F^2 + \eta \left(\left\| \mathbf{T}_x * \mathbf{B}_r \right\|_F^2 + \left\| \mathbf{T}_y * \mathbf{B}_r \right\|_F^2 \right)$$

[0149] 其中, $\mathbf{T}_x = [-11]$ 和 $\mathbf{T}_y = [-11]^T$ 分别表示沿x方向和y方向的梯度算子。这是一个Tikhonov正则化问题, 可通过傅里叶变换得到有效解决。得到基层 \mathbf{B}_r 后, 可得到相应的细节层为:

$$[0150] \quad \mathbf{D}_r = \mathbf{I}_r - \mathbf{B}_r。$$

[0151] 细节层 \mathbf{D}_r 融合:

[0152] 对于每一细节层 \mathbf{D}_r , 其对应的稀疏系数图 $\mathbf{s}_{D_r}^m, m \in \{1, \dots, M\}$ 通过稀疏编码中的 (1) 式得到。由于多尺度变换通常利用低分辨率成分来分析图像的近似特征, 利用高分辨率成分来分析图像的细节特征, 即通过多尺度和多方向分解得到的含有不同分辨率的分解层包含了图像的不同特征。受此启发, 可将多尺度变换理解为特征分类过程, 并且同一分解层的相似特征的融合有助于提高融合结果的准确性。因此, 首先采用NSCT对每一稀疏系数图进行多尺度多方向分解:

$$[0153] \quad f_{\text{NSCT}^K}(\mathbf{s}) = (s_{D_rL}, s_{D_rH}^1, \dots, s_{D_rH}^K)$$

[0154] 其中, f_{NSCT^K} 表示进行K层NSCT分解操作。 s_{D_rL} 表示低频子带部分, $s_{D_rH}^1, \dots, s_{D_rH}^K$ 表示具有 2^K 个分解方向的高频子带部分。

[0155] 源影像对应稀疏系数图的低频子带部分 s_{D_rL} 采用平均策略进行融合:

$$[0156] \quad s_{FL}(i, j) = \frac{1}{R} \sum_{r=1}^R s_{D_rL}(i, j)$$

[0157] 高频子带部分 $s_{D_rH}^k (k \in K)$ 采用子带关联性测度(即稀疏系数图的相同尺度下相邻方向子带的相关性)来表征活性测度,其中子带关联性测度定义为:

$$[0158] \quad \rho(s_{D_rH}^k, s_{D_rH}^{k'}) = \frac{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_rH}^k(i, j) - \bar{s}_{D_rH}^k] [s_{D_rH}^{k'}(i, j) - \bar{s}_{D_rH}^{k'}]}{\sqrt{\sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_rH}^k(i, j) - \bar{s}_{D_rH}^k]^2 \sum_{i=0}^{I-1} \sum_{j=0}^{J-1} [s_{D_rH}^{k'}(i, j) - \bar{s}_{D_rH}^{k'}]^2}}$$

[0159] 其中, $s_{D_rH}^k$ 和 $s_{D_rH}^{k'}$ 分别表示第k和k'方向的相邻子带。 $\bar{s}_{D_rH}^k$ 和 $\bar{s}_{D_rH}^{k'}$ 分别表示 $s_{D_rH}^k$ 和 $s_{D_rH}^{k'}$ 的均值。i和j表示多尺度变换子带系数图的大小。此时,对应稀疏系数图的NSCT高频子带 $s_{D_rH}^k$ 的融合规则为:

$$[0160] \quad s_{FH}^k = s_{D_rH}^k, \quad r^* = \arg \max_r (\rho(s_{D_rH}^k, s_{D_rH}^{k'}))$$

[0161] 在得到融合的NSCT低频子带和高频子带后,通过NSCT逆变换得到融合的稀疏系数图 $s_F^{m/m}, m \in \{1, \dots, M\}$ 。最后,通过稀疏重构得到细节层的融合结果为:

$$[0162] \quad I_{D_rF} = \sum_{m=1}^M d_m * s_F^{m/m}$$

[0163] 基层 B_r 融合:

[0164] 由于多模态脑影像间在同一位置的亮度和纹理差异普遍较大,传统的取大融合策略可能会由于局部像素的微小变化导致视觉不一致性,因此,采用平均策略得到基层的融合结果为:

$$[0165] \quad I_{B_rF}(i, j) = \frac{1}{R} \sum_{r=1}^R B_r(i, j)$$

[0166] 二尺度重构:

[0167] 得到融合的基层 I_{D_rF} 和融合的细节层 I_{B_rF} 后,通过二尺度重构可得最终的融合影像为:

$$[0168] \quad I_F = I_{D_rF} + I_{B_rF}$$

[0169] 为了验证本发明所提方法中活性测度对融合性能的有效性,实验设计以人脑影像为例,实验设置条件如下:(1)多模态脑影像来自哈佛医学院创建的全脑图谱脑影像数据库(WBAMI),且影像的空间分辨率均为 256×256 ; (2)在本发明的融合框架下,基于单变量控制

的思想,对比活性测度包括:子带关联性测度、结合NSCT和 L_1 范数的测度和本发明所提结合NSCT和子带关联性的测度;(3)实验均是在电脑配置为3.3GHz CPU和16.0GHz RAM,且MATLAB版本为R2017a和Win7 64位操作系统的实验环境下进行。活性测度表征对融合性能的影响实验如附图3所示。由附图3可见,对比本发明所提活性测度和子带关联性测度所得融合结果,可知本发明所提活性测度的融合结果能够保留更完备的结构信息,因此NSCT有助于促进结构信息的保留。对比本发明所提活性测度和结合NSCT和 L_1 范数的测度所得融合结果,可知本发明所提活性测度的融合结果能够保留更完备的纹理信息,因此子带关联性相比于 L_1 范数有助于纹理信息的保留。综上,本发明所提融合方法中的活性测度有助于保留更完备的纹理和结构信息。

[0170] 为了验证本发明所提方法的融合结果对失配的鲁棒性和保证实验的公平性,实验设计采用了与对比方法在失配的鲁棒性验证时相同的多聚焦图像对,实验设置条件如下:(1)对比方法包括:采用与本发明相同融合框架的基于子带关联性测度的方法,有代表性的基于卷积稀疏的脑影像融合方法CSMCA法和CSR法;(2)多聚焦图像对的空间分辨率均为 256×256 ;(3)实验均是在电脑配置为3.3GHz CPU和16.0GHz RAM,且MATLAB版本为R2017a和Win7 64位操作系统的实验环境下进行。局部失配对脑影像融合性能的影响实验如附图4所示。由附图4可见,CSMCA法和CSR法的融合结果在失配区域边缘均存在明显的振铃伪影,即伪吉布斯现象。这是因为CSMCA和CSR采用的局部窗平均法减弱了图像变换的移不变性,这使二者所得融合结果对失配的敏感性降低,并且人为控制的窗口大小也很难获得对配准理想的鲁棒性效果,而在基于子带关联测度的方法和本发明所提方法中,子带关联性采用全局子带保证了移不变性,可有效消除伪吉布斯现象。

[0171] 为了验证本发明所提融合方法的合理性,实验设计以人脑影像为例,实验条件的设置包括:(1)从哈佛医学院创建的全脑图谱脑影像数据库的“Acute stroke”数据集、“Hypertensive encephalopathy”数据集和“Multiple embolic infarctions”数据集中随机选取了30组多模态脑影像,且影像的空间分辨率均为 256×256 ;(2)对比方法包括:采用与本发明相同融合框架的基于子带关联性测度的方法,有代表性的基于卷积稀疏的脑影像融合方法CSMCA法和CSR法;(3)算法参数设置:每一字典数组的空间大小为 8×8 ,字典数组设置为32,正则化参数 λ 设置为0.01,上述参数设置均与CSR法和CSMCA法的设置相同。(5)客观评价指标包括:熵EN、联合熵 Q_0 、互信息MI、结构相似度SSIM,上述客观指标的值越大表明融合性能越好;(6)实验均是在电脑配置为3.3GHz CPU和16.0GHz RAM,且MATLAB版本为R2017a和Win7 64位操作系统的实验环境下进行。此外,采用主观评价和客观评价相结合的方式对融合性能进行分析。其中,主观评价的融合结果如附图5、附图6和附图7所示,客观评价的性能指标如附图9(加粗字体表示最优指标,下划线表示次优指标)、附图8和附图10所示。由附图5、附图6和附图7可见,CSMCA法和CSR法的融合结果在纹理清晰度和亮度信息方面保留更完备,而边缘纹理的连续性遭到破坏,但均存在局部细节丢失的情况。基于子带关联性测度的方法在细节纹理的清晰度和结构完整性方面都不占有优势,但在边缘结构纹理方面保留更完备。相比之下,本发明所提融合方法保留了更完备的结构和纹理信息。由附图9、附图8和附图10可见,本发明所提方法在算法耗时偏低情况下,四个客观指标在三个脑影像数据集实验中得分均比较突出。其中,本发明所提方法的MI指标优势最明显,表明本发明所提方法既能够保留更完备的纹理结构信息,又能够保持较高的算法执行效率。

[0172] 虽然本公开披露如上,但本公开的保护范围并非仅限于此。本领域技术人员,在不脱离本公开的精神和范围的前提下,可进行各种变更与修改,这些变更与修改均将落入本发明的保护范围。

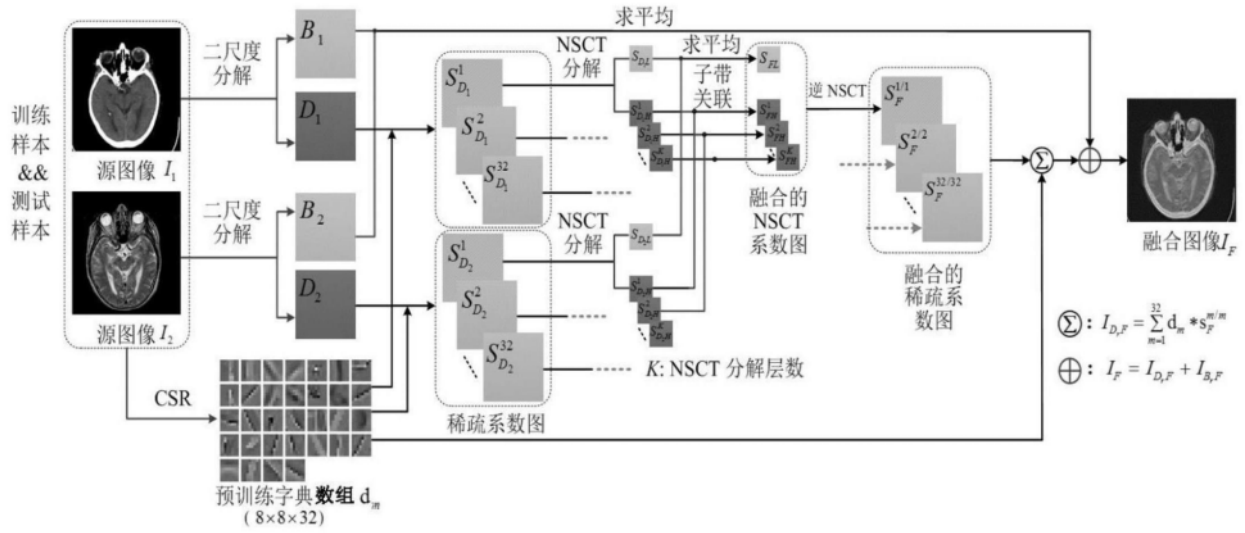


图1

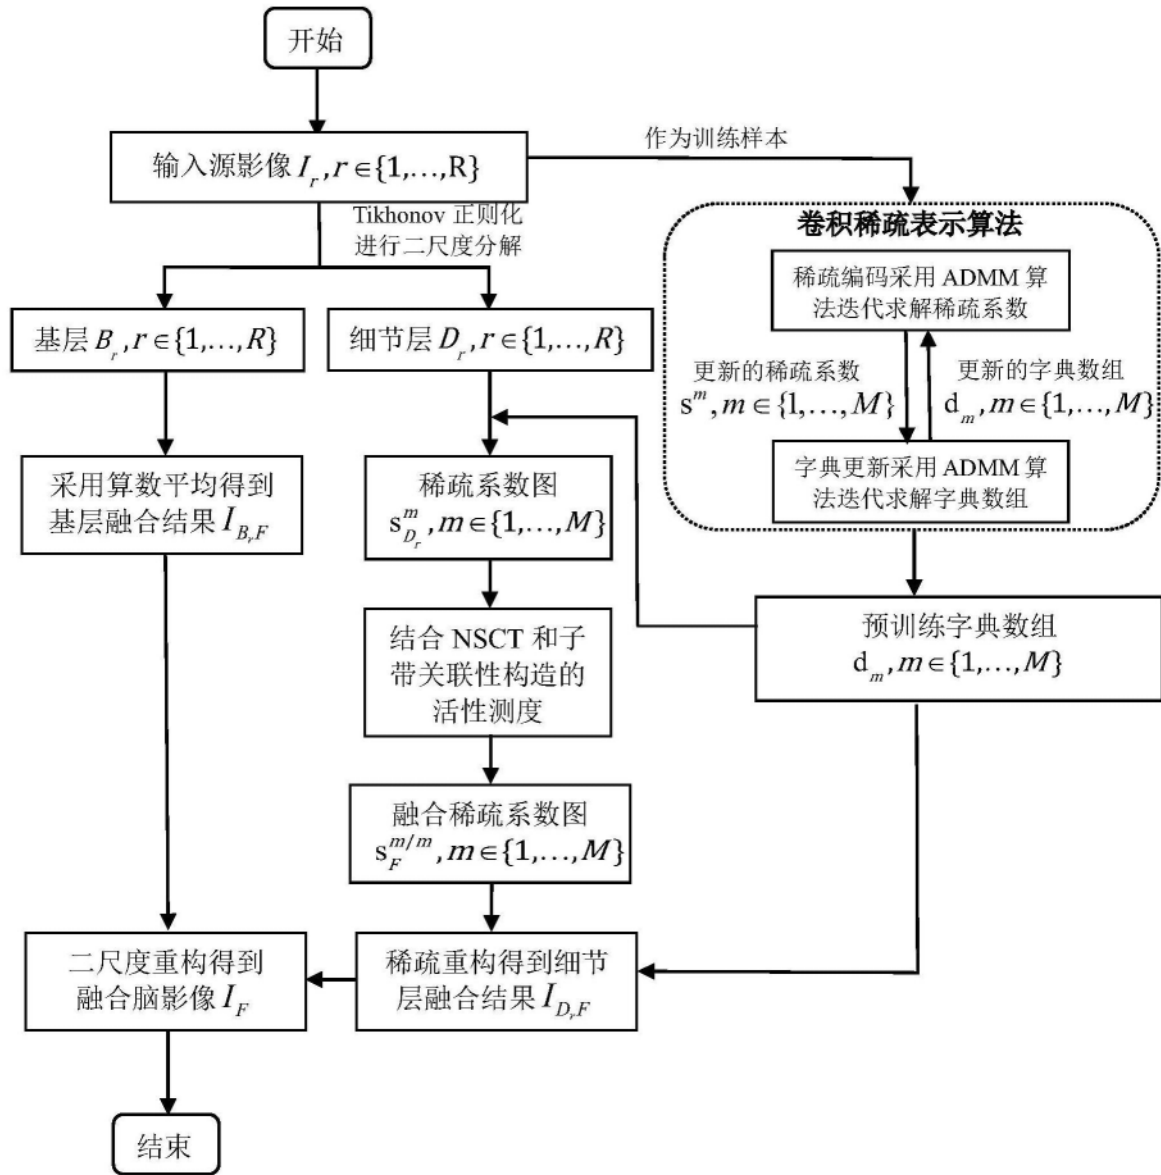


图2

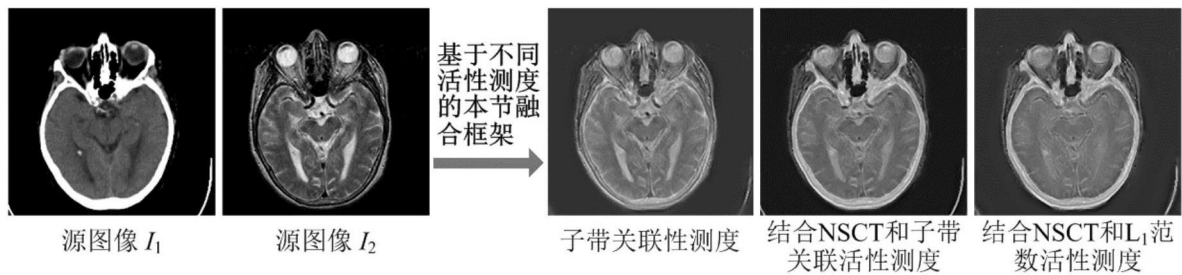


图3




图4




图5

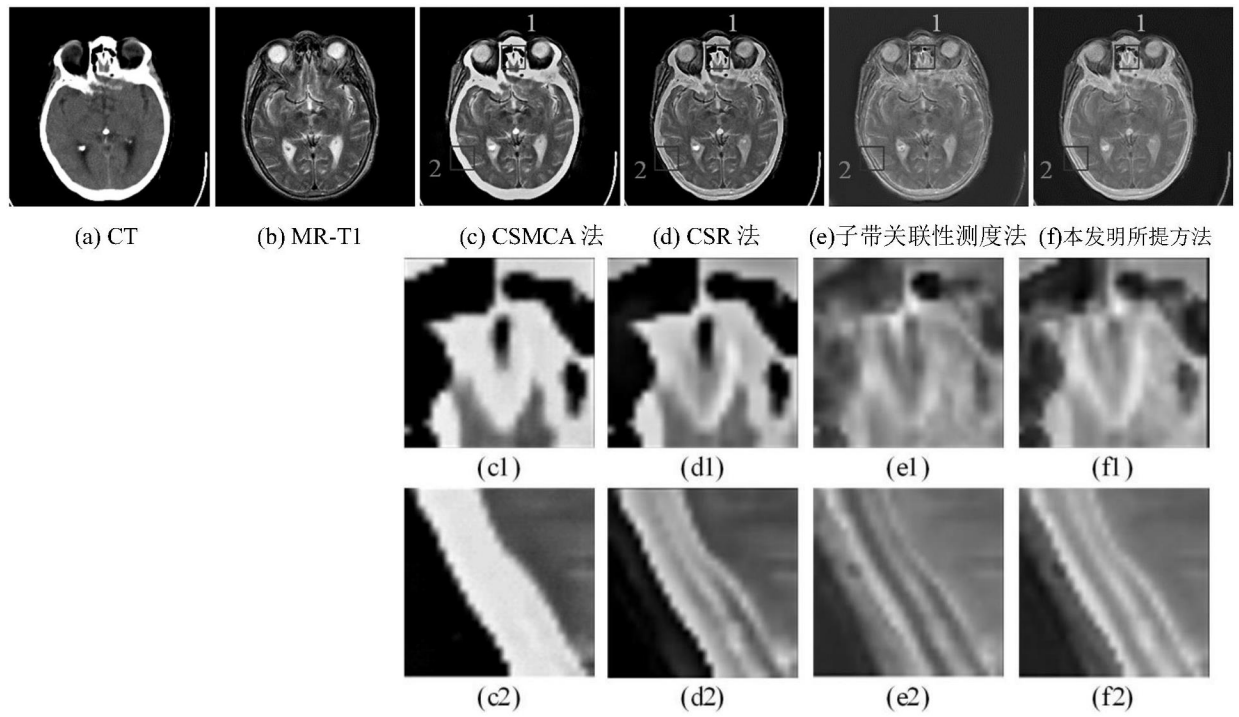


图6




图7

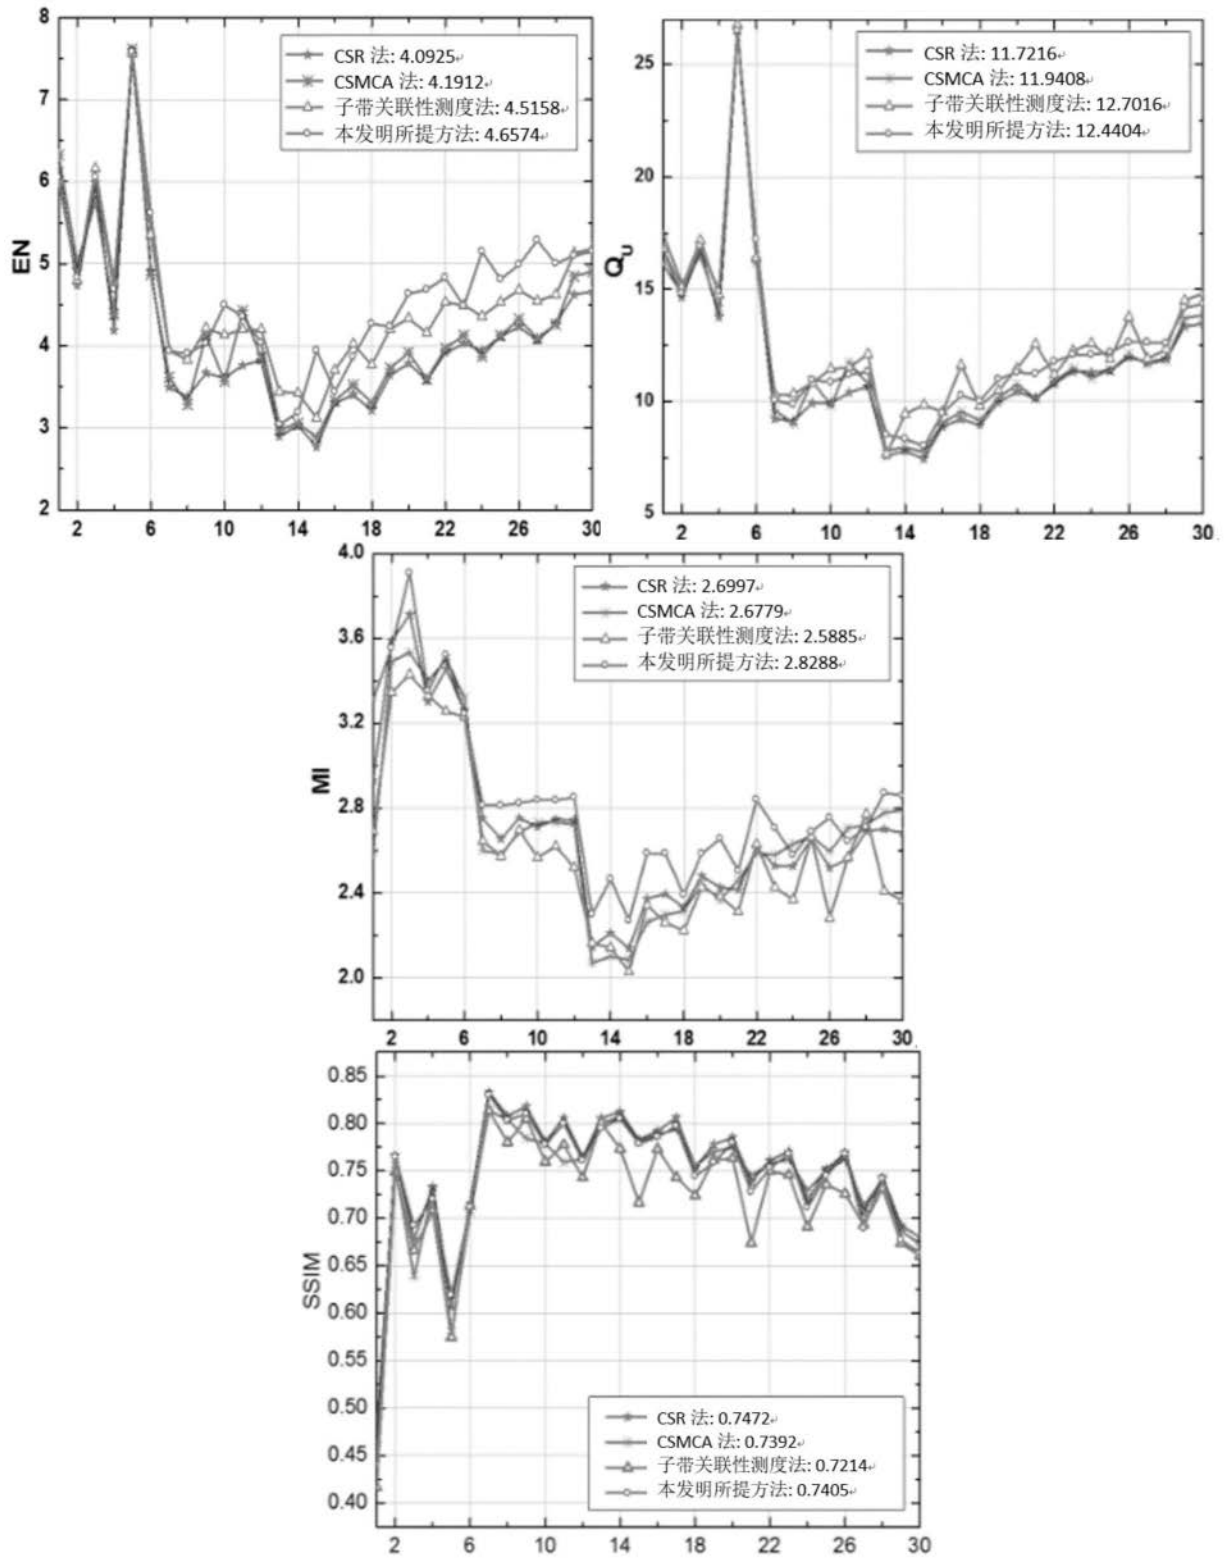


图8

WBAMI 数据库	指标	CSMCA 法	CSR 法	子带关联性测度法	本发明所提方法
CT/MRI	EN	5.0045	4.7355	4.7895	<u>4.8162</u>
	Q _U	15.2742	14.6406	14.7183	<u>15.0626</u>
	MI	3.4919	<u>3.5876</u>	3.3276	3.6184
	SSIM	0.7548	<u>0.7661</u>	0.7492	0.7663
CT/MR-T1	EN	4.8522	4.6246	<u>5.0936</u>	5.1084
	Q _U	13.7096	13.3316	<u>14.1869</u>	14.4821
	MI	<u>2.7777</u>	2.7003	2.5174	2.7832
	SSIM	<u>0.6868</u>	0.6925	0.6723	0.6759
CT/MR-T2	EN	4.9063	4.6637	<u>5.1117</u>	5.2153
	Q _U	13.8438	13.4659	<u>14.2136</u>	14.8376
	MI	<u>2.7899</u>	2.6826	2.4140	2.8308
	SSIM	<u>0.6728</u>	0.6800	0.6467	0.6664

图9

融合方法	CSMCA 法	CSR 法	子带关联性测度法	本发明所提方法
耗时(秒)	101.98	36.14	41.18	67.50

图10