

DOI:10.16136/j.joel.2023.11.0464

结合潜在低秩分解和稀疏表示的脑部图像融合

张亚加^{1,2}, 邱启蒙¹, 刘恒¹, 邵建龙^{1*}

(1. 昆明理工大学 信息工程与自动化学院, 云南 昆明 650500; 2. 云南开放大学 城市建设学院, 云南 昆明 650500)

摘要:针对低秩分解和稀疏表示(space representation, SR)造成融合图像信息缺失的问题,提出一种结合潜在低秩分解和SR的脑部图像融合算法。首先,将源图像分解为低秩、稀疏和噪声3种成分,面对不同分解成分特性间的差异,分别构造低秩字典和稀疏字典进行描述;采用加权灰度值的方法处理低秩成分,以保持其轮廓和亮度特征;对于稀疏成分,设计一种多范数加权度量的方法对SR进行改进,以保持其高维信息,剔除噪声成分。比对当前主流的5种算法,在视觉效果和客观指标上,本文方法效果最优。

关键词:潜在低秩分解;多范数加权度量;脑部图像;稀疏表示(SR);融合指标

中图分类号:TP391 **文献标识码:**A **文章编号:**1005-0086(2023)11-1225-08

Brain image fusion combining latent low-rank decomposition and sparse representation

ZHANG Yajia^{1,2}, QIU Qimeng¹, LIU Heng¹, SHAO Jianlong¹

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China; 2. College of Urban Construction, Yunnan Open University, Kunming, Yunnan 650500, China)

Abstract:In order to solve the problem that the fusion algorithm of low-rank decomposition and sparse representation (SR) causes a lot of information missing, a brain image fusion algorithm combining latent low-rank decomposition and SR is proposed. Firstly, the source image is decomposed into low-rank, sparse and noisy components. In the face of the differences between the characteristics of different decomposition components, the low-rank and sparse dictionaries are constructed to describe the low-rank components respectively. The weighted gray value method is used to process low-rank components to maintain their contour and brightness features. For the sparse components, a multi-norm weighted metric method is designed to improve the SR to maintain the high-dimensional information. The noise components are eliminated. Compared with the current five mainstream algorithms, the proposed method has the best effect in terms of visual effects and objective indicators.

Key words:latent low-rank decomposition; multiple-norm weighted metric; brain images; sparse representation (SR); fusion indicators

0 引言

随着科学技术的进步,成像设备快速发展,临床医疗对病灶的检测精度和效率要求也越来越高^[1],多模态脑部图像融合技术在计算机辅助诊断和成像理论教学上发挥着重要作用,越来越多地受到研究者关注。图像融合就是将来自同一目标的两个或多个图像的信息整合到一个图像中,

使该图像包含更丰富的信息,适合人眼视觉感知及计算机分析^[2]。图像融合旨在减少歧义,使冗余输出最小化,同时实现对患者个性化病情特点的最大化描述,便于辅助临床治疗,降低诊断难度^[3]。

稀疏表示(sparse representation, SR)是在一个过完备字典的基础上,使用尽可能少的字典原子,把图像表示为稀疏项,获得稳定且稀疏的表示,这

* E-mail:sj-long@qq.com

收稿日期:2022-05-21 修订日期:2022-10-17

基金项目:国家自然科学基金(61302042)和昆明理工大学教育技术研究项目(2506100219)资助项目

种特性恰好满足图像特征提取的需要,有效弥补了多尺度变换的缺陷。但是,SR 并不能完全利用图像中的结构信息,也不能独立地应用每个输入信号。低秩表示(low-rank representation, LRR)不仅能够捕获数据的潜在低维结构,还可以稳健地处理高维数据。文献[4]使用 LRR 对重建样本的表示系数进行低秩约束,并对子空间的潜在相似性展开了探讨。文献[5]在进行两次低秩分解后,使用视觉显著性度量的方法来处理稀疏成分,但计算量大,信息丢失过多。文献[6]提出了潜在低秩分解的方法,并结合拉普拉斯正则化进行处理;文献[7]提出的正则化潜在低秩分解模型,从两个方向分解给定的数据矩阵;文献[8]提出的双图正则化 LRR 模型,较好地保留了环境空间和特征空间的信息。这些方法引入低秩分解,使字典进一步稀疏化,结合不同的工程需要进行设计,不仅能够消除边缘噪声,还能有效保留图像的细节信息。

在稀疏编码过程中,活跃度水平的计算决定了稀疏系数选择的灵活度。 L_0 范数表示稀疏系数中非零项的数量,反映图像信息的集中程度, L_0 范数越大,说明细节信息越集中。但是, L_0 范数会面临 NP 难问题,使用 L_1 范数对非凸的 L_0 范数进行替换,实现 NP 问题向凸优化问题的转换,可以降低计算的复杂度。 L_2 范数表示稀疏系数中各项的绝对值之和,反映细节信息量的多少, L_2 范数越大,表明细节信息越多^[9]。当前对稀疏活跃度水平的度量有两类方法:一是单一范数取极大,如文献[10]的 L_1 范数求极大,这种方法运用比较广泛,但不能很好地反应信息量的多少,容易造成图像的灰度不连续;二是多范数综合度量的方法,如文献[11]使用 L_1 和 L_2 的均值来度量;文献[12]“多范数”活跃度测量,结合“自适应加权平均”与“选择最大”两种规则,当相似度超过阈值,使用“自适应加权平均”,反之使用“选择最大”;文献[13]提出对 L_0 范数和 L_2 范数选取了两个线性相关权重系数 w_1 、 w_2 进行加权计算,对加权计算的结果进行取大。这些方法虽然也从多范数的角度对活跃度水平进行度量,但却不能很好地兼顾到图像信息量的多少和集中程度,往往顾此失彼。

在融合过程中,结合潜在低秩分解和 SR,不仅能更加“稀疏”地描述图像,还能更多地保留行和列上的视图信息。对稀疏系数进行多范数加权度量,兼顾图像信息的数量和集中程度,可以有效避免信息的丢失,全面准确地保留源图像的特征。基于以上考虑,本文提出一种基于潜在低秩分解和多范数加权度量的脑部图像融合算法,把图像分解为稀疏、低秩和噪声 3 种成分。低秩成分反

映图像的总轮廓和亮度信息,稀疏部分反映图像的高维成分,分别构造不同的字典对其进行描述,并设计了一种多范数权重度的方法对 SR 进行改进。本文剔除了噪声成分,灵活处理不同特性的分解成分,提高了图像的融合质量。

1 基本原理

1.1 潜在低秩分解

作为一种先进的空间分割算法,低秩分解其实就是核范数正则化的最小化问题。主要是把图像矩阵分解为低秩矩阵 L 和稀疏矩阵 S 。 L 中包含了图像的整体轮廓和亮度信息,属于低中维信息特征; S 则包含了高维成分以及噪声。由于低秩矩阵 L 与观测矩阵 X 有相同的秩,要从 X 恢复得到低秩矩阵 L ,则可以把问题描述为:

$$\begin{aligned} (L, S) = \operatorname{argmin}_{L, S} \|L\|_* + \xi \|S\|_0, \\ \text{s. t. } X = L + S, \end{aligned} \quad (1)$$

式中, $\operatorname{argmin} f(x)$ 表示使目标函数 $f(x)$ 取得最小值时的变量 x 的值, $\|S\|_0$ 表示稀疏矩阵 S 的零范数, ξ 为平衡参数,用以调节 L 和 S 的平衡。

由于上式(1)是非凸问题,无解,为此需转化为凸优化问题进行求解:

$$\min_{L, S} \|L\|_* + \xi \|S\|_1, \text{ s. t. } X = L + S, \quad (2)$$

式中, $\|L\|_*$ 表示低秩矩阵 L 的核范数, $\|S\|_1$ 表示稀疏矩阵 S 的 L_1 范数。

LRR 采用核范数作为低秩算子,这是一个近似逼近的问题。LatLRR 能够准确恢复子空间并检测奇异值。分解模型可描述为:

$$\begin{aligned} \min_{L, S, E} \|L\|_* + \|S\|_* + \xi \|E\|_1, \\ \text{s. t. } X = XL + SX + E. \end{aligned} \quad (3)$$

为了克服观测数据不足以及噪声干扰的问题,文献[14]将子空间分割和特征提取有机地统一起来,提供子空间分割和特征提取的解决方案。LatLRR 采用列和行两个数据视图作为样本,分别学习他们的 LRR。而 LRR 只用列这一个数据视图,而忽略了行的信息。LatLRR 作为 LRR 的替代方案,取得了快速发展。

1.2 SR

SR 理论是通过线性组合稀疏系数对信号进行描述的方法。通过从若干训练子集中学习来获取的字典,能更加准确和稳定地描述原始图像的特征。SR 的本质就是用字典中元素的线性组合去表示待测试样本,进而将原始图像通过字典 D 中的少量原子线性组合来表示,实现了用较少的资源表示更多知识。

图像变换的过程实质上就是其 SR 的过程,首先在过完备字典 D 上进行稀疏分解,在该字典上用尽

可能少的原子来表示这个图像,由此得到一个稀疏向量,称这个向量为图像在过完备字典下的 SR。因此,SR 不过是将原始图像在某一组字典基上进行分解变换,得到另一个 SR 而已。

SR 的简化模型可描述为:

$$\min_{\alpha} \|\alpha\|_0 + \lambda \|\mathbf{S}\|_0, \text{ s. t. } \mathbf{Y} = \mathbf{D}\alpha, \quad (4)$$

式中, α 是图像 $\mathbf{Y}$ 在字典 $\mathbf{D}$ 上的稀疏编码系数。

这同样是一个非凸问题,随着原子个数的增加,计算的复杂度会呈现爆炸性增长,依旧使用 L_1 范数对 L_0 范数进行替换,得到的凸优化转换如下

$$\min_{\alpha} \|\alpha\|_0 + \lambda \|\mathbf{S}\|_1, \text{ s. t. } \mathbf{Y} = \mathbf{D}\alpha. \quad (5)$$

1.3 加权灰度值处理

像素灰度值取极大(小)的方法是对两幅原始图像的像素灰度值逐一进行比较,选取灰度值大(小)的像素点作为融合后的像素点。但这种方法只是对灰度值做单纯的取极大(小)比较,在实际运用中受到很大限制。

灰度值加权法是对两幅图像同一点的灰度值进行加权处理,剔除图像中的冗余信息,优化后的灰度值作为该点的像素值,对所有像素点进行计算,获得融合图像。灰度值加权法计算量小、实时性强,但权重系数的选择是处理的关键所在。以源图像 $\mathbf{X}$ 和源图像 $\mathbf{Y}$ 在点 (a, b) 处的像素计算为例,融合图像 $\mathbf{I}$ 的像素值为:

$$\mathbf{I}_{(a,b)} = \mu g_{x_{a,b}} + \epsilon g_{y_{a,b}}, \quad (6)$$

式中, μ, ϵ 是权重系数,且 $0 \leq \mu, \epsilon \leq 1, \mu + \epsilon = 1$ 。

2 融合策略

2.1 融合框架

潜在 LRR 可以同时两个图像的低秩成分展

开学习,SR 可以改善图像的视觉效果。为保留图像的细节信息,提高融合图像的视觉效果,本文设计了一种有效的潜在低秩分解模型,将源图像分解为低秩、稀疏和噪声 3 种成分;面对不同分解成分特性间的差异,使用 K-SVD 构造低秩字典和稀疏字典进行特征描述;低秩成分采用灰度值加权处理的方法,稀疏成分设计了一种多范数加权重度的方法,剔除噪声成分,最终获得融合图像,算法框架如图 1 所示。

由上文可知,字典构造对于稀疏成分和低秩成分的处理起着决定性作用,字典的优劣直接决定了融合图像的质量。对样本数据集,逐一使用 LRR 对数据集进行分解,字典构建过程如图 2 所示。

图 2 中本文使用了稀疏字典 $\mathbf{D}_S$ 以及低秩字典 $\mathbf{D}_L$ 来表示分解得到的低秩和稀疏成分,使用 K-SVD 分别对字典展开训练^[10],训练目标可以表示为:

$$\min_{\mathbf{D}, \mathbf{X}} \{ \|\mathbf{Y} - \mathbf{D}\mathbf{X}\|_F^2 \}, \quad \text{ s. t. } \forall i, \|\mathbf{x}_i\|_0 \leq T_0, \quad (7)$$

式中, T_0 表示稀疏向量中的最大差异度。

在字典更新阶段,逐列更新字典中的所有原子。当求解低秩系数 $\mathbf{Y}_L$ 的最优解时,稀疏系数 $\mathbf{Y}_S$ 、字典 $\mathbf{D}_S$ 和 $\mathbf{D}_L$ 、向量 α_S 和 α_L 保持不变,获得如下最优问题:

$$\mathbf{Y}_L = \arg\min_{\mathbf{Y}_L} \|\mathbf{Y} - \mathbf{Y}_L - \mathbf{Y}_S\|_2^2 + \|\mathbf{Y}_L - \mathbf{D}_L \alpha_L\|_2^2 + \omega_1 \|\mathbf{Y}_L\|_*. \quad (8)$$

这个问题可以采用奇异值阈值算法^[8]进行求解。同理,当求解稀疏系数 $\mathbf{Y}_S$ 的最优解时,低秩系数 $\mathbf{Y}_L$ 、字典 $\mathbf{D}_S$ 和 $\mathbf{D}_L$ 、向量 α_S 和 α_L 保持不变,获得如下最优问题:

$$\mathbf{Y}_S = \arg\min_{\mathbf{Y}_S} \|\mathbf{Y} - \mathbf{Y}_L - \mathbf{Y}_S\|_2^2 +$$




图 1 基于潜在低秩分解和多范数加权重度的算法框架

Fig. 1 An algorithm framework based on latent low-rank decomposition and multi-norm weighted metric




图 2 字典构建流程

Fig. 2 Dictionary building process

$$\|Y_S - D_S \alpha_S\|_2^2 + \omega_2 \|Y_S\|_1. \quad (9)$$

与式(8)不同的是,式(9)是一个 L_1 范数求解最优的问题,可采用迭代收缩法进行求解。当低秩系数 Y_L 和稀疏系数 Y_S 更新完毕后,就可以用相同的方法对字典 D_S 和 D_L 、向量 α_S 和 α_L 进行求解。其中,求解向量 α_S 和 α_L ,获得如下最优问题:

$$\begin{aligned} \min_{\alpha_L} & \|Y_L - D_L \alpha_L\|_2^2 + \gamma_1 \|\alpha_L\|_1 \\ \min_{\alpha_S} & \|Y_S - D_S \alpha_S\|_2^2 + \gamma_2 \|\alpha_S\|_1 \end{aligned} \quad (10)$$

进而求解字典 D_S 和 D_L ,获得如下最优问题:

$$\begin{aligned} \min_{D_L} & \|Y_L - D_L \alpha_L\|_2^2 + \gamma_1 \|\alpha_L\|_1 \\ \min_{D_S} & \|Y_S - D_S \alpha_S\|_2^2 + \gamma_2 \|\alpha_S\|_1 \end{aligned} \quad (11)$$

结合上述式子,获得融合后的图像为:

$$I_F = D_L \alpha_{F,L} + D_S \alpha_{F,S}. \quad (12)$$

2.2 多范数加权度量改进的 SR

在稀疏重构^[13]的过程中,为了更好地获取稀疏系数,准确计算活跃度水平,保留有用的细节信息,设计了一种加权多范数度量的方法对 SR 进行改进,对 L_1 范数和 L_2 范数,分别用加权指数进行约束,再将两者的乘积作为综合度量结果。融合的步骤:

1) 滑动窗口划分稀疏成分为 $\sqrt{n} \times \sqrt{n}$ 的子块,步长为 1。

2) 使用 OMP 算法计算稀疏系数矩阵 (α_1^I, α_2^I) ,其中:

$$\begin{aligned} \alpha_1^I &= \operatorname{argmin}_{\alpha_1} \|\alpha_1\|_1 \\ \alpha_2^I &= \operatorname{argmin}_{\alpha_2} \|\alpha_2\|_1 \end{aligned} \quad (13)$$

3) 根据步骤 2) 计算加权多范数活跃度:

$$\begin{aligned} Y_1^I &= (\|\alpha_1^I\|_1)^{w_1} + (\|\alpha_2^I\|_2)^{w_2} \\ Y_2^I &= (\|\alpha_2^I\|_1)^{w_1} + (\|\alpha_1^I\|_2)^{w_2}, \\ w_1 &= \beta w_2 \end{aligned} \quad (14)$$

式中, Y_1^I, Y_2^I 是图像 I 的水平活跃度, $\|\cdot\|_1, \|\cdot\|_2$ 是向量的 L_1 和 L_2 范数, w_1 和 w_2 是权重系数, β 是比例系数。

4) 根据步骤 3) 的结果甄选稀疏系数如下:

$$\alpha_F^I = \begin{cases} \alpha_1^I, Y_1^I > Y_2^I \\ \alpha_2^I, \text{other} \end{cases} \quad (15)$$

5) 按照上述方法重构列向量 V_F^I :

$$V_F^I = D \alpha_F^I. \quad (16)$$

6) 循环以上步骤,直至所有子块被融合,得到最终的稀疏系数。

3 实验结果及分析

3.1 实验设置

本文在实验过程中,对参数进行了设置,其中加权灰度处理的权重参数 μ 取 0.65, ϵ 取 0.35;在字典学习的过程中,正则项参数可设置为相同的数值,根据具体实验,设置 w_1, w_2 为 0.01, γ_1, γ_2 取 1;加权范数度量时,比例系数设为 0.8。

为了验证本文算法的有效性,实验均在 Win10 操作系统和 Matlab 2019b 展开,组合了不同模式下的脑部图像:脑萎缩患者的计算机断层成像术(computered tomography, CT)和核磁共振(magnetic resonance imaging, MRI),见图 3(a)、(d);轻微阿兹海默症的 MRI 和正电子发射断层成像术(positron emission tomography, PET),见图 3(b)、(e);正常大脑的 MRI 和单光子发射计算机断层显像(single-

photon emission computed tomography, SPECT), 见图 3(c)、(f)。所有图像大小均为 256×256 pixel、深度 8 bit、已配准,源自哈佛医学院(<http://www.med.harvard.edu/AANLIB/>)。

为了突出本文算法的可比性,实验选取了国内外 5 种较为先进的算法与本文方法进行比对。其中,文献[5]对图像进行两次低秩分解,低秩部分采取传统“灰度值取极大”,稀疏部分设计了视觉显著性度量的方法。文献[9]利用潜在低秩模型来提取显著特征的方法。文献[15]采用 NSST 分解源图像,低频子带使用引导滤波和 sobel 算子改进的 SR 方法进行处理。文献[16]采用 NSCT 分解源图像,结合 SR 处理低频子带。文献[17]采用香农熵加权 SR 同步超分图像融合方法。




图 3 实验数据集
Fig. 3 Experimental dataset

此外,从主观视觉和客观指标两个角度对融合结果的质量展开定性与定量评估,本文评价指标:标准差 (standard deviation, SD) 和空间频率 (spatial frequency, SF),基于图像的统计特征对融合图像进行评价,值越大则图像的质量越好;互信息 (mutual information, MI)、边缘信息评价因子 $Q^{AB/F}$ 和结构相似性 (structural similarity, SSIM),基于源图像与融合结果间的关系进行评价,值越大则融合图像的质量越好。实验结果见图 4—图 6,每组实验执行 10 次,表 1—表 3 内依次列出上述指标平均值,用粗体标记其最优值。

3.2 CT 和 MRI 融合实验

本组实验中,使用不同方法对脑萎缩患者的 CT 和 MRI 图像进行融合。由图 3(a)、(b)可以看出,CT 提供致密的骨组织结构信息,但获得的软组织信

息却极为有限。MRI 可提供软组织信息,但 MRI 对骨骼等密度较大区域成像较为模糊。组合 CT-MRI 联合成像有助于诊断同一器官的软硬组织信息。融合结果如图 4 所示。




图 4 CT-MRI 联合成像融合结果
Fig. 4 Fusion results of CT-MRI combined imaging

表 1 CT-MRI 融合结果评价指标

Reference	SD	SF	SSIM	MI	$Q^{AB/F}$
[5]	28.4876	26.0168	0.6407	4.1648	0.7198
[9]	30.2148	22.1057	0.6347	3.6154	0.7019
[15]	31.4987	23.0034	0.6223	3.8421	0.7216
[16]	27.2198	23.0197	0.5021	3.4298	0.7144
[17]	30.4128	23.7498	0.5864	3.7872	0.7108
Proposed	31.5489	26.1053	0.6558	4.3584	0.7397

由图 4 可以看出,文献[5]与文献[15]和文献[17]方法相比,保留了更多有意义的细节信息,提高了图像质量,但依然存在伪影。文献[9]和文献[16]所得图像边缘的纹理结构保存较为完整,融合质量较好,亮度、对比度、清晰度,较源图像有一定的提升,但边缘存在失真,病灶区域出现伪影。较之多尺度变换,文献[15]和文献[17]方法,获得图像的组织结构更为清晰,解决了伪影问题,能很好地识别病灶特征。本文方法在亮度、对比度、清晰度上均优于其他方法,保持了细节信息,解决了伪影问题,骨组织、软组织和病灶得到清晰显示,能起到辅助诊断的作用,5 个指标均是最优。综合权衡主观、客观,本文算法分析效果最优。

3.3 MRI 和 PET 融合实验

本组实验中,使用不同方法对轻微阿兹海默症的 MRI 和 PET 图像进行融合。由图 3(b)、(e)可以

看出,PET 能反应病灶详尽的功能与代谢等分子信息,而 MRI 可以提供病灶的精确解剖定位。组合 PET-MRI 成像有利于提供体内器官活动功能和代谢物质的确切位置。融合结果如图 5 所示。




图 5 PET-MRI 联合成像融合结果

Fig. 5 Fusion results of PET-MRI combined imaging

表 2 PET-MRI 融合结果评价指标

Tab. 2 Evaluation indexes of PET-MRI fusion results

Reference	SD	SF	SSIM	MI	$Q^{AB/F}$
[5]	54.947 2	31.249 8	0.712 5	2.718 7	0.510 6
[9]	51.546 8	28.125 4	0.650 7	2.613 5	0.435 9
[15]	50.243 7	29.016 8	0.701 6	2.507 6	0.423 8
[16]	56.489 2	31.021 4	0.716 0	2.725 7	0.512 8
[17]	51.579 1	31.465 7	0.740 8	2.620 8	0.530 6
Proposed	56.658 9	31.979 5	0.758 2	2.734 5	0.529 7

由图 5 可以看出,文献[5]对不同分解成分设计了不同字典,融合结果得到改善,提高了对比度,但造成细节信息的缺失,以至出现伪影。文献[9]边缘信息丢失严重,不能有效保留脑部的代谢信息,整体比较模糊。较文献[5]方法,文献[15]和文献[17]虽然在保留细节信息方面有一定提高,但是整体较暗,对比度也比较低。文献[16]局部区域出现伪影比较严重,是因为分解时使用 NSCT 处理光谱信息时发生了光的畸变。本文方法的对比度、清晰度都明显优于其他几种方法,有效保留了代谢信息,清晰地显示了病灶的结构特征,没有出现伪影,能起到辅助诊断的作用,且 5 个指标上 4 个最优。综合权衡主观客观,本文算法分析效果最优。

3.4 MRI 和 SPECT 融合实验

在本组实验中,使用不同的方法对正常大脑的 MRI 和 SPECT 图像进行融合。由图 3(c)、(f)可以看出,SPECT 能提供人体组织和器官的血液流动状

况和新陈代谢功能信息,但其时空分辨率较低。组合 MRI-SPECT 图像可以同时呈现软组织信息和脑血流。融合结果如图 6 所示。




图 6 SPECT-MRI 联合成像融合结果

Fig. 6 Fusion results of SPECT-MRI combined imaging

表 3 SPECT-MRI 融合结果评价指标

Tab. 3 Evaluation indexes of SPECT-MRI fusion results

Reference	SD	SF	SSIM	MI	$Q^{AB/F}$
[5]	50.655 4	13.697 5	0.719 5	2.401 6	0.410 7
[9]	51.055 7	13.584 7	0.710 4	2.241 8	0.413 5
[15]	47.954 8	11.908 7	0.670 2	1.641 2	0.384 8
[16]	51.168 5	13.459 7	0.720 8	1.979 5	0.415 4
[17]	50.654 8	12.654 8	0.694 8	2.654 1	0.408 6
Proposed	51.358 4	13.680 4	0.726 7	2.754 6	0.420 7

由图 6 可以看出,文献[5]和文献[9]能够准确刻画边缘的细节特征,但是亮度不强,丢失了病灶的细节信息,存在伪影。文献[15]丢失了大量信息,图像中央极为模糊,说明该方法融合的局限性较大。文献[16]的对比度较前几种方法有了很大改善,细节信息刻画较为准确,但丢失了病灶处的细节信息。文献[17]边缘比较模糊,中心区域对比度低,纹理表现欠佳,不能体现细节特征。本文算法不仅在亮度、纹理清晰度、局部对比度上均优于其他方法,还保留了轮廓信息,体现了病灶的细节特征,对临床医学的诊断能够带来较大的便利,且 5 个指标上 4 个最优。综合权衡主观客观,本文算法分析效果最优。

3.5 活跃度水平实验

在稀疏编码的过程中,既要考虑到图像信息量的多少,又要兼顾信息分布的情况,现有的度量方法中,单一范数取极大的方法显然不能满足这种要求,而多范数综合度量的方法又很难灵活地兼顾到这两个方面,在实际应用中往往顾此失彼,不能达到理想

的效果。为验证本文新提出的加权多范数度量方法的优势及可行性,控制本文方法其他参数不变,对比当前先进的 4 种方法,记录结果见表 4—表 6。

表 4 CT-MRI 不同度量方法评价指标
Tab. 4 Evaluation indexes of CT-MRI
using different measures

Reference	SD	SF	SSIM	MI	$Q^{AB/F}$
[10]	31.6513	25.7598	0.5876	4.0897	0.6927
[11]	31.2487	24.8949	0.4986	3.9824	0.6829
[12]	31.5024	25.9815	0.6347	4.2478	0.7046
[13]	31.4451	25.3687	0.6073	4.1394	0.7237
Proposed	31.5489	26.1053	0.6558	4.3584	0.7397

表 5 PET-MRI 不同度量方法评价指标
Tab. 5 Evaluation indexes of PET-MRI
using different measures

Reference	SD	SF	SSIM	MI	$Q^{AB/F}$
[10]	56.8502	31.2547	0.7168	2.7034	0.5067
[11]	55.4695	30.9824	0.6824	2.6318	0.4832
[12]	56.4357	31.7435	0.7213	2.7139	0.5218
[13]	56.5176	31.8726	0.7354	2.7267	0.5159
Proposed	56.6989	31.9795	0.7582	2.7345	0.5297

表 6 SPECT-MRI 不同度量方法评价指标
Tab. 6 Evaluation indexes of SPECT-MRI
using different measures

Reference	SD	SF	SSIM	MI	$Q^{AB/F}$
[10]	51.6607	12.9614	0.6918	2.5684	0.4164
[11]	50.9745	12.6481	0.6572	2.2153	0.3891
[12]	50.8357	13.1476	0.7016	2.6984	0.3917
[13]	51.2486	13.5987	0.7358	2.7454	0.4167
Proposed	51.3584	13.6804	0.7267	2.7546	0.4207

由上表可以看出,5 种方法中,文献[11]范数取均值的方法效果最差,因为单纯地取均值操作不能灵活地考虑信息量的多少或集中程度。其次是文献[10] L_1 范数取极大的方法,4 组实验中,其 SD 均是最大,这也验证了 L_1 范数在度量过程中可以描述信息的集中程度,但这种方法显然不能够考虑信息量的多少。文献[12]和文献[13]采用多范数综合度量的方法,在现有的多范数度量方法中的效果最好,其结果也明显优于 L_1 范数取极大的方法,因为这两种方法也考虑了信息量多少和集中程度的问题。但总体上看,本文提出的方法,除 SD 和个别指标外所有指标外均是最优,且对信息集中程度的描述(SD)仅次于 L_1 范数取极大的方法,同时兼顾了信息的数量

和分布情况,对活跃度水平的度量最为准确和有效。

4 结 论

针对传统图像融合保留细节信息效果不完整,信息丢失过多,出现伪影,普适性较差等缺陷,提出了一种结合了潜在低秩分解和 SR 的脑部图像融合算法,构造不同的字典对不同的分解成分进行有效描述。选取不同病症下的 CT-MRI 联合成像、MRI-PET 联合成像、MRI-SPECT 联合成像,比对当前 5 种先进算法,分别对本文方法性能进行验证。本文设计了一种多范数加权度量的方法对稀疏活跃度水平进行计算,比对当前前沿的 4 种计算方法,本文方法能同时灵活地兼顾信息的数量和分布情况,优势显著。大量实验表明,本文算法在亮度、对比度、清晰度上均有所提高,保持了细节信息,解决了伪影的问题,凸出了病灶的细节特征,对于临床诊断和理论教学能起到辅助的作用,在医学上具有理论及实践应用价值。

参考文献:

[1] ZHAO D, DAI W Z, LI J F. Medical image fusion based on NSST and improved PCNN [J]. Journal of Optoelectronics • Laser, 2018, 29(1): 95-104.
赵丹, 戴文战, 李俊峰. 基于 NSST 和改进 PCNN 的医学图像融合[J]. 光电子 • 激光, 2018, 29(1): 95-104.

[2] DANIEL E, ANITHA J, KAMALESH WARAN K K, et al. Optimum spectrum mask based medical image fusion using Gray Wolf Optimization[J]. Biomedical Signal Processing and Control, 2017, 34: 36-43.

[3] JIN X, NIE R C, ZHOU D M, et al. Multifocus color image fusion based on NSST and PCNN [J]. Journal of Sensors, 2015, 2016: 8359602.

[4] ZHANG S Q. Medical image fusion algorithm based on L_0 gradient minimization for CT and MRI [J]. Multimedia Tools and Applications, 2021, 24(3): 1-30.

[5] DENG Z H, LI H F. Low-rank sparse decomposition and salience measure of medical image fusion [J]. Optical Technique, 2018, 44(4): 461-468.
邓志华, 李华锋. 低秩稀疏分解与显著性度量的医学图像融合[J]. 光学技术, 2018, 44(4): 461-468.

[6] SHEN Y, CHEN X P, YANG Q. Image fusion of multidirectional sum modified Laplacian and tetrolet transform [J]. Journal of Image and Graphics, 2020, 25(4): 721-731.
沈瑜, 陈小朋, 杨倩. 多方向 Laplacian 能量和 tetrolet 变换的图像融合[J]. 中国图像图形学报, 2020, 25(4): 721-731.

- [7] WANG D, TIAN G Q, WANG F Z. Probabilistic matrix factorization recommendation model incorporating multiple weighting factors[J]. *Journal of Electronics & Information Technology*, 2022, 44(2): 552-565.
王丹, 田广强, 王福忠. 融合多权重因素的低秩概率矩阵分解推荐模型[J]. *电子与信息学报*, 2022, 44(2): 552-565.
- [8] LI P, BU J, YU J, et al. Towards robust subspace recovery via sparsity-constrained latent low-rank representation[J]. *Journal of Visual Communication and Image Representation*, 2016, 271: 221-209.
- [9] GAN B, ZHENG C H, ZHANG J, et al. Sparse representation for tumor classification based on feature extraction using latent low-rank representation[J]. *BioMed Research International*, 2014, 2014(10): 420856.
- [10] ZHANG Z Y, CAO Y F, DING M, et al. Infrared and visible image fusion via multi-layer convolutional sparse representation[J]. *Journal of Harbin Institute of Technology*, 2021, 53(12): 51-59.
张洲宇, 曹云峰, 丁萌, 等. 采用多层卷积稀疏表示的红外与可见光图像融合[J]. *哈尔滨工业大学学报*, 2021, 53(12): 51-59.
- [11] CAO Y, LI S T, HU J W. Multi-focus image fusion by non-subsampled shearlet transform[C]//2011 Sixth International Conference on Image and Graphics(ICIG), August 12-15, 2011, Hefei, China. New York: IEEE, 2011: 17-21.
- [12] WANG L F, DONG X, QIN P L. Multi-modal brain image fusion based on adaptive joint dictionary learning [J]. *Journal of Computer Applications*. 2018, 38(4): 1134-1140.
王丽芳, 董侠, 秦品乐. 基于自适应联合字典学习的脑部多模态图像融合方法[J]. *计算机应用*, 2018, 38(4): 1134-1140.
- [13] PEI C Y, FAN K G, MA Z. Medical image fusion based on edge-preserving decomposition and improved sparse representation[J]. *Journal of Computer Applications*, 2021, 41(7): 2092-2099.
裴春阳, 樊宽刚, 马政. 基于边缘保留分解和改进稀疏表示的医学图像融合[J]. *计算机应用*, 2021, 41(7): 2092-2099.
- [14] LIU Y, WANG Z. Simultaneous image fusion and denoising with adaptive sparse representation[J]. *IET Image Processing*, 2015, 9(5): 347-357.
- [15] ZHU H W. Medical image fusion method based on NSST and improved sparse representation[J]. *Journal of Jilin University (Science Edition)*, 2020, 58(4): 931-936.
朱宏伟. 基于 NSST 与改进稀疏表示的医学图像融合方法[J]. *吉林大学学报(理学版)*, 2020, 58(4): 931-936.
- [16] SHIBU D S, PRIYANHARSINI S S. Multiscale decomposition based medical image fusion using convolutional neural network and sparse representation[J]. *Biomedical Signal Processing and Control*, 2021, 69: 102789.
- [17] LI Y, WU X J. Image fusion based on sparse representation using Shannon entropy weighting[J]. *Acta Automatica Sinica*, 2014, 40(8): 1819-1835.
李奕, 吴小俊. 香农熵加权稀疏表示图像融合方法研究[J]. *自动化学报*, 2014, 40(8): 1819-1835.

作者简介:

邵建龙 (1965—), 男, 教授, 研究方向为智能信息处理与虚拟现实.