

中图分类号: TP391.4 文献标识码: A 文章编号:

论文引用格式:

双重字典学习与自适应 PCNN 相结合的 医学图像融合

王丽芳, 窦杰亮, 秦品乐, 蔺素珍, 高媛, 张程程

(中北大学 大数据学院 中北大学山西省生物医学成像与影像大数据重点实验室, 山西 太原 030051)

摘要: **目的** 针对基于稀疏编码的医学图像融合方法存在的细节保存能力不足的问题, 提出了一种基于卷积稀疏表示双重字典学习与自适应PCNN的多模态医学图像融合方法。**方法** 该方法首先通过已配准的训练图像去学习卷积稀疏与卷积低秩字典, 在两个字典下使用交替方向乘法 (alternating direction multiplier method, ADMM) 求得其卷积稀疏表示系数与卷积低秩表示系数, 通过与对应的字典重构得到卷积稀疏与卷积低秩分量; 然后利用新颖的拉普拉斯能量和 (novel sum-modified Laplacian, NSML) 以及新颖的空间频率和 (novel sum-modified SF, NMSF) 去激励脉冲耦合神经网络 (pulse coupled neural network, PCNN) 分别对卷积稀疏与卷积低秩分量进行融合; 最后将融合后的卷积稀疏与卷积低秩分量进行组合得到最终的融合图像。**结果** 对灰度图像与彩色图像进行实验仿真并与其他融合方法进行比较, 实验结果表明, 所提出的融合方法在客观评估和视觉质量方面明显优于对比的6种方法, 在四种指标上都有最优的表现; 与6种多模态图像融合方法相比, 3组实验平均标准差分别提高了7%、10%、5.2%; 平均互信息分别提高了33.4%、10.9%、11.3%; 平均空间频率分别提高了8.2%、9.6%、5.6%; 平均边缘评价因子分别提高了16.9%、20.7%、21.6%。**结论** 本文算法相比较其他稀疏表示方法, 有效提高了多模态医学图像融合的质量, 更好的保留了源图像的细节信息, 使融合图像的信息更加丰富, 符合人眼的视觉特性, 有效地辅助医生进行疾病诊断。

关键词: 医学图像融合; 双重字典学习; 卷积稀疏; 卷积低秩; 脉冲耦合神经网络

Medical image fusion using double dictionary learning and adaptive pcnn

Wang Lifang¹, Dou Jieliang¹, Qin Pinle¹, Lin Suzhen¹, Gao Yuan¹, Zhang Chengcheng¹

(The Key Laboratory of Biomedical Imaging and Imaging on Big Data, North University of China, Taiyuan, Shanxi 030051 China)

Abstract: **Objective** Fusion of multimodal medical images is an important medical imaging method that integrates complementary information from multimodal images to produce new composite images. Sparse representation has also achieved great success in medical image fusion in the past few years. However, since the sparse representation method is based on sliding window technology, the preservation ability of the fused image details is insufficient. Therefore, a

基金项目: 山西省自然科学基金项目 (201701D121062)

收稿日期: ; 修回日期:

Supported by: Natural Science Foundation of Shanxi Province, China (201701D121062)

multi-modal medical image fusion method based on convolution sparse representation double dictionary learning and adaptive PCNN is proposed. **Method** According to the low rank and sparsity characteristics of the image, the method decomposes the source image into two parts, and constructs a double dictionary based on convolution sparse representation. The sparse component contains a lot of detail texture, and the low rank component contains basic information such as contour brightness. Firstly, the low-rank feature and sparse feature are extracted from the training image to form two basic dictionaries to represent the test image. At the same time, in order to enhance the discriminability of the double dictionary, the dictionary learning model is improved by adding low rank and sparse constraints to the low rank component and the sparse component respectively. In the process of dictionary learning, the method of alternating iterative updating is divided into three parts, including auxiliary variables update, sparse coding and dictionary updates. A convolutional sparse and convoluted low rank sub-dictionary for the training image is obtained by a three-part cyclic update. Then, the total variation regularization is incorporated into the image decomposition model, and the Fourier domain-based alternating direction multiplier method is used to obtain the representation coefficients of the source image sparse component and the low rank component in the respective sub-dictionaries. The process is divided into two parts alternately iteratively, including convolution sparse coefficient update and convolution low rank coefficient update. Secondly, the sparse component of the source image is obtained by convolving the convolutional sparse coefficient with the corresponding sub-dictionary. Similarly, the convolution low rank coefficient is convolved with the corresponding sub-dictionary to obtain the low-rank component of the source image. In order to preserve the details of the image, the novel sum-modified spatial frequency of the sparse component is calculated as external excitation of the pulse coupled neural network, and the link strength is adaptively determined by the regional average gradient to obtain a firing map of the sparse component. And the novel sum-modified Laplacian of the low rank component is calculated as the external excitation of the pulse coupled neural network, and the link strength is adaptively determined by the regional average gradient to obtain the firing map. By comparing the number of firings of different sparse components, the fused sparse components are obtained. Similarly, the low rank components of different source images are fused through the firing map. Finally, the fusion image is obtained by combining convolution sparse and convolution low rank components, which further improves the quality of the fused image. **Result** Three sets of brain multimodal medical images (including CT/MR images, MR/PET images and MR/SPECT images) were simulated and compared with other fusion methods. The experimental results show that the proposed fusion method is significantly superior to the six methods for objective evaluation and visual quality comparison, and has the best performance in four indicators. Compared with the six multi-mode image fusion methods, the mean standard deviation of the three groups of experiments was increased by 7%, 10% and 5.2%, respectively. The average mutual information increased by 33.4%, 10.9% and 11.3% respectively. The average spatial frequency increased by 8.2%, 9.6% and 5.6% respectively. The average marginal evaluation factors increased by 16.9%, 20.7% and 21.6% respectively. **Conclusion** Compared with other sparse representation methods, the proposed algorithm effectively improves the quality of multimodal medical image fusion, better preserves the detailed information of the source image, makes the information of the fused image richer, and conforms to the visual characteristics of the human eye, which can be better help the doctor to diagnose the disease.

Key words: Medical image fusion; Double dictionary learning; Convolution sparse; Convolution low rank; Pulse coupled neural network

0 引言

医学影像学在现代医学治疗和诊断等临床应用中有着至关重要的作用，而临床医生为了获取足够的信息，通常要用到多个模态的医学图像，

如计算机断层扫描（CT）、正电子发射断层扫描（PET）以及磁共振成像（MRI）等。然而不同的单一成像模态的医学影像都具有局限性，不能反

映医生所需的所有细节信息，因此整合来自不同模态的医学图像的信息到一张图像中将不同源图像中包含的互补信息相结合，能够帮助医生为医疗诊断做出更好的决策。

医学影像融合已经成为一种有效的信息融合技术。医学图像融合技术可以分为以下两大类：基于空间域的算法和基于变换域的算法^[1]。基于空间域的算法通常是通过图像块或者像素级的梯度信息去解决一个图像融合问题，但是容易导致图像细节丢失。与基于空间域的算法相比，基于变换域的算法在表征信号的局部特征方面有更多的优势，可以弥补基于空间域算法的细节表达不足的缺点，同时由于其更符合人类视觉系统（HVS）的生理机制，所以基于变换域的多尺度融合算法被认为是多模态图像融合中的主流融合方法^[2]。典型的基于变换域的方法包括基于多尺度分析的方法、基于稀疏表示的方法以及图像金字塔的方法。多尺度分析（MTA）的方法包括离散小波变换^[3]（DWT）、轮廓波变换^[4]（CT）、剪切变换^[5]（ST）等。这些方法能很好的表示源图像的结构信息，但是它们能提取的方向信息是有限的。此外，由于这些方法缺少平移不变性，容易导致伪吉布斯效应^[6]。而非下采样轮廓波变换（NSCT）和非下采样剪切变换（NSST）虽然具有平移不变的性质能够很好地克服伪吉布斯效应^[7,8]，但是这些方法有较高的计算复杂度，限制了它们的实际应用。

基于稀疏表示和字典学习的融合方法由于压缩感知理论^[9]的提出也被广泛应用于图像融合^[10-12]，并且它一般优于大多数传统融合方法^[13]。在基于稀疏表示的方法中，因为相邻的图像块是互相重叠的，导致每个像素的结果是多值的，在理想情况下，每个像素的多个值应该是相等的，以保持重叠图像块的一致性^[14]但由于稀疏编码是在每个图像块上分别独立执行的，忽略了图像像素之间的相关性，导致每个像素有多个不等的值同时大多融合方法是通过采取聚合和平均的策略来获得每个像素的最终值^[15]，这就将导致图像细节在融合中容易被平滑甚至丢失。Yin^[16]通过将源图像作为训练数据获得联合字典，然后使用最大加权多范数融合规则融合图像，但是其仍存在细节丢失的问题。Zong^[17]提出基于分类图像块的融合方法，使用方向梯度直方图（HOG）特征对图

像块分类建立子字典，虽然减少了细节丢失，但仍不可避免一些细节被平滑。Zhang^[18]提出一种改进的多任务鲁棒稀疏表示结合空间上下文信息的融合方法，但该方法与大多数基于稀疏表示的方法一样，针对局部图像块编码而不是对整个图像，因此仍会导致细节保存不佳的情况。并且通常的基于稀疏编码的融合方法都只采用了一个字典来表示源图像不同的形态部分，容易导致源图像固有信息的次优表示，不能充分地包含图像的特征信息，造成图像的信息丢失。Rong^[15]提出了对图像的不同成分采用不同的字典稀疏表示，但其字典是以解析的方式得到，难以实现自适应描述。

针对上述问题，本文提出了基于卷积稀疏表示双重字典学习与自适应PCNN的多模态医学图像融合方法（Multimodal medical image fusion method based on convolution sparse representation dual dictionary learning and adaptive PCNN, CSRDD-APCNN）。该方法将源图像分为稀疏与低秩两部分，构建了基于卷积稀疏表示的双重字典。其中，稀疏成分包含大量细节纹理，低秩成分包含轮廓亮度以及微小细节等基本信息。为了增强双重字典的区分性，分别对低秩成分与稀疏成分添加低秩与稀疏约束改进字典学习模型，并通过交替迭代求解，得到双重字典。然后，将总变分（total variation (TV) regularization）正则化纳入图像分解模型，并通过基于傅里叶域的ADMM算法^[19]求解，将源图像分解为卷积稀疏与卷积低秩分量。同时为了充分保留源图像的细节信息，分别将卷积稀疏分量的改进的空间频率（NMSF）与卷积低秩分量的改进的拉普拉斯能量和（NSML）作为自适应脉冲耦合神经网络的输入激励，通过输出的点火次数将各分量融合。最后通过组合卷积稀疏与卷积低秩分量来得到融合图像，进一步提高了融合图像的质量。

1 相关工作

1.1 卷积稀疏表示 (Convolution sparse representation, CSR)

在卷积稀疏表示中，其基本思想是将源图像 S 看做是一组特征响应 \mathbf{x}_m 与对应的字典过滤器 \mathbf{d}_m 的卷积之和。它的目的是实现对整个图像的稀疏表示，而不是针对于重叠的图像块去分别做稀疏逼近。其相应的最为广泛使用的形式是卷积基追踪去噪（Convolutional Basis Pursuit DeNoising, CBPDN），其定义为：

$$\arg \min_{\{\mathbf{x}_m\}} \frac{1}{2} \left\| \sum_m \mathbf{d}_m * \mathbf{x}_m - \mathbf{s} \right\|_2^2 + \lambda \sum_m \|\mathbf{x}_m\|_1 \quad (1)$$

式中的 $\{\mathbf{d}_m\}$ 是一组卷积核也就是卷积字典， \mathbf{x}_m 分别是对应卷积核的稀疏系数，* 号表示二维的卷积操作， λ 是正则化参数。为了对式 (1) 的求解问题进行优化，Bristow^[20] 提出了基于傅里叶域交替方向乘法器 (ADMM) 框架。Wohlberg^[21] 提出了一种联合使用空域和傅里叶域解决卷积稀疏表示 (CSR) 问题的算法。CBPDN 的自然字典学习优化形式为：

$$\arg \min_{\{\mathbf{d}_m\}, \{\mathbf{x}_{m,k}\}} \frac{1}{2} \sum_k \left\| \sum_m \mathbf{d}_m * \mathbf{x}_{m,k} - \mathbf{s}_k \right\|_2^2 + \lambda \sum_{m,k} \|\mathbf{x}_{m,k}\|_1$$

s.t. $\|\mathbf{d}_m\|_2 = 1 \quad \forall m \quad (2)$

上式 (2) 中的 \mathbf{s}_k 表示第 k 幅训练图像； $\mathbf{x}_{m,k}$ 表示对应于第 m 个卷积核与第 k 幅图像的卷积系数。其中对卷积字典 \mathbf{d}_m 的规范约束是为了避免滤波器和系数产生缩放歧义。

1.2 脉冲耦合神经网络 (Pulse coupled neural network, PCNN)

1.2.1 PCNN 模型




图 1 PCNN 模型的神经元结构


Fig. 1 Neuron structure of PCNN model

该 PCNN 模型主要反映在 F 通道处只考虑了外部图像像素的灰度值的影响。首先，在 PCNN 用于图像融合时，其中外部刺激 S_{ij} 输入对应像素 (i, j) 处的归一化灰度值。随后，在调制域中执行非线性调制，获得内部活动 U_{ij} ，然后与阈值 θ_{ij} 比较，若 U_{ij} 大于 θ_{ij} ，则神经元产生脉冲输出，也

就是神经元点火， $Y = 1$ 。反之， $Y = 0$ 。此过程反复迭代，达到设定的迭代次数为止。经过点火，最后由所有神经元的点火次数构成的点火映射图作为输出。

$$\begin{cases} F_{ij}(n) = S_{ij} \\ L_{ij}(n) = e^{-\alpha_L} L_{ij}(n-1) + V_L \sum_{k,l} W_{ijkl} Y_{kl}(n-1) \\ U_{ij}(n) = F_{ij}(n)(1 + \beta L_{ij}(n)) \\ \theta_{ij}(n) = e^{-\alpha_\theta} \theta_{ij}(n-1) + V_\theta Y_{ij}(n-1) \\ Y_{ij}(n) = \begin{cases} 1, & U_{ij}(n) > \theta_{ij}(n) \\ 0, & otherwise \end{cases} \end{cases} \quad (3)$$

式中， F_{ij} 和 L_{ij} 分别为 PCNN 神经元的反馈输入和连接输入； β 是链接强度， θ_{ij} 是动态阈值， W_{ijkl} 表示突触权重，来调整中心神经元附近每个神经元的影响程度； S_{ij} 、 Y_{ij} 以及 U_{ij} 分别是神经元的外部刺激、输出和内部活动； α_L 和 α_θ 是时间衰减常数； V_L 和 V_θ 是神经元连接输入和动态阈值的振幅增益。



就是神经元点火， $Y = 1$ 。反之， $Y = 0$ 。此过程反复迭代，达到设定的迭代次数为止。经过点火，最后由所有神经元的点火次数构成的点火映射图作为输出。

1.2.2 自适应链接强度 β

在 PCNN 融合算法中，链接强度 β 在融合过程中起关键作用。在传统的基于 PCNN 的融合过

程中, β 通常根据经验手动设置, 并且所有神经元设置相同的链接强度。而根据文献[22], β 的值在不同的神经元中不应该完全相同, 其与相应像素的特征有关。所以根据图像特征自适应确定 β , 有助于提升融合效果。关于自适应 β 的确定方法, 有空间频率、拉普拉斯能量、区域平均梯度和梯度能量等。其中, 区域平均梯度能很好的反映图像的清晰程度, 图像越清晰, 区域平均梯度越大。

2 多模态医学图像融合方法

针对目前基于稀疏表示的融合方法存在的细

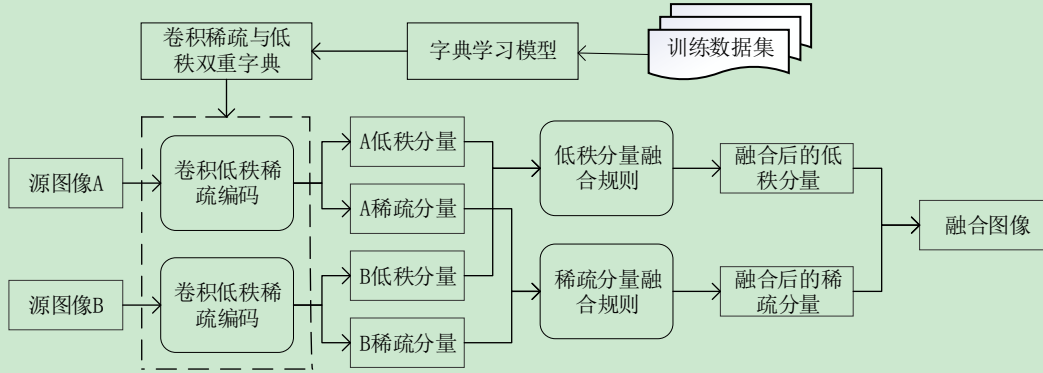


图2 多模态医学图像融合流程

Fig. 2 Multimodal medical image fusion process

2.1 判别性卷积低秩和卷积稀疏双重字典学习

2.1.1 双重字典学习模型的建立

定义 $\mathbf{y}_m \in \mathbf{R}^M$ ($i=1,2,\dots,N$) 为训练样本中第 m 幅图像 (大小为 $\sqrt{M} \times \sqrt{M}$), 在将源图像分解为卷积稀疏与低秩分量时, 为了保证字典的重构能力, 假设训练图像 \mathbf{y}_m 为两个不同分量的叠加:

$$\mathbf{y}_m = \mathbf{y}_m^c + \mathbf{y}_m^t$$

其中, \mathbf{y}_m^c 和 \mathbf{y}_m^t 分别是第 m 幅训练图像的低秩分量和稀疏分量, 低秩分量包含图像的本质低维空间, 稀疏分量包含图像的边缘纹理信息。为了保证两个分量在各自所对应的字典下系数的稀疏性, 采用了 l_0 范数的最优凸近似 l_1 范数作为正则项。定义 $\{\mathbf{x}_{m,k}^c\}$ 和 $\{\mathbf{x}_{m,k}^t\}$ 为第 m 幅训练图像的低秩系数与稀疏系数, 并引入 $\{\mathbf{d}_c\}$ 和 $\{\mathbf{d}_t\}$ 表示训练出的卷积稀疏与卷积低秩子字典, 使得

节保存能力有限的问题, 本文提出了一种基于卷积稀疏表示双重字典学习与自适应 PCNN 的多模态医学图像融合方法。其整体流程在下图 2 所示, 首先通过建立双重字典学习模型, 学习出具有判别性的卷积低秩子字典与卷积稀疏子字典, 然后通过图像分解模型, 将源图像 \mathbf{A} 、 \mathbf{B} 分别分解为卷积稀疏与卷积低秩分量。其次通过对 \mathbf{A} 、 \mathbf{B} 的卷积稀疏与卷积低秩分量采用不同的融合规则, 来得到融合后的稀疏与低秩图像, 最后通过组合不同分量来得到最终的融合图像。该方法通过对整幅图像进行建模, 从而能够实现更好的细节保存效果, 提高医学图像融合的质量。

$$\mathbf{y}_m^c = \sum_{k=1}^{K_c} \mathbf{d}_{c,k} * \mathbf{x}_{m,k}^c, \quad \mathbf{y}_m^t = \sum_{k=1}^{K_t} \mathbf{d}_{t,k} * \mathbf{x}_{m,k}^t. \quad \text{在图}$$

3 中给出了字典学习过程, 建立字典学习模型为:

$$\min_{\mathbf{d}_c, \mathbf{d}_t, \mathbf{x}_c, \mathbf{x}_t} \left\{ \frac{1}{2} \sum_{m=1}^M \left\| \mathbf{y}_m - \sum_{k=1}^{K_c} \mathbf{d}_k^c * \mathbf{x}_{m,k}^c - \sum_{k=1}^{K_t} \mathbf{d}_k^t * \mathbf{x}_{m,k}^t \right\|_2^2 + \lambda_c \sum_{k=1}^{K_c} \|\mathbf{x}_{m,k}^c\|_1 + \lambda_t \sum_{k=1}^{K_t} \|\mathbf{x}_{m,k}^t\|_1 \right\} \quad (4)$$

式中 λ_c 和 λ_t 为平衡参数。由文献[23]以及[24], 通过离散傅里叶变换可将空间域的卷积转化为频域的乘积运算, 因而定义频域变量 $\mathbf{Y} = (\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_m)$ 表示训练样本, m 是训练样本的数目; 字典 \mathbf{D}_k , 使得 $\mathbf{D}_k \mathbf{x}_{m,k} = \mathbf{d}_k * \mathbf{x}_{m,k}$; $\mathbf{D}_c = (\mathbf{D}_0^c \ \mathbf{D}_1^c \ \dots) \in \mathbf{R}^{M \times K}$ 和 $\mathbf{D}_t = (\mathbf{D}_0^t \ \mathbf{D}_1^t \ \dots) \in \mathbf{R}^{M \times K}$ 分别是卷积低秩与卷积稀疏子字典; 定义矩阵

$$\mathbf{x}_c = \begin{pmatrix} \mathbf{x}_{0,0}^c & \mathbf{x}_{0,1}^c & \cdots \\ \mathbf{x}_{1,0}^c & \mathbf{x}_{1,1}^c & \cdots \\ \vdots & \vdots & \ddots \end{pmatrix} \in \mathbf{R}^{K \times N} \quad \text{和}$$

$$\mathbf{x}_t = \begin{pmatrix} \mathbf{x}_{0,0}^t & \mathbf{x}_{0,1}^t & \cdots \\ \mathbf{x}_{1,0}^t & \mathbf{x}_{1,1}^t & \cdots \\ \vdots & \vdots & \ddots \end{pmatrix} \in \mathbf{R}^{K \times N}$$

分别表示低秩与卷积稀疏系数矩阵。将式 (4) 转化为:

$$\min_{\mathbf{D}_c, \mathbf{D}_t} \left\{ \frac{1}{2} \|\mathbf{Y} - \mathbf{D}_c \mathbf{x}_c - \mathbf{D}_t \mathbf{x}_t\|_2^2 + \lambda_c \|\mathbf{x}_c\|_1 + \lambda_t \|\mathbf{x}_t\|_1 \right\} \quad (5)$$

为了增强字典的判别能力, 通过对卷积稀疏与卷积低秩分量引入稀疏约束和低秩约束, 对卷积低秩字典添加低秩约束并引入辅助变量 \mathbf{Y}_c , \mathbf{Y}_t , 使得 $\mathbf{Y}_c = \mathbf{D}_c \mathbf{x}_c$, $\mathbf{Y}_t = \mathbf{D}_t \mathbf{x}_t$, 将式 (5) 改进为:

$$\min_{\mathbf{D}_c, \mathbf{D}_t} \left\{ \frac{1}{2} \|\mathbf{Y} - \mathbf{Y}_c - \mathbf{Y}_t\|_2^2 + \|\mathbf{Y}_c - \mathbf{D}_c \mathbf{x}_c\|_2^2 + \|\mathbf{Y}_t - \mathbf{D}_t \mathbf{x}_t\|_2^2 + \lambda_c \|\mathbf{x}_c\|_1 + \lambda_t \|\mathbf{x}_t\|_1 + \lambda_1 \|\mathbf{Y}_c\|_* + \lambda_2 \|\mathbf{Y}_t\|_1 + \lambda_3 \|\mathbf{D}_c\|_* \right\} \quad (6)$$

其中 $\|\cdot\|_*$ 是核范数, 表示矩阵奇异值的和。

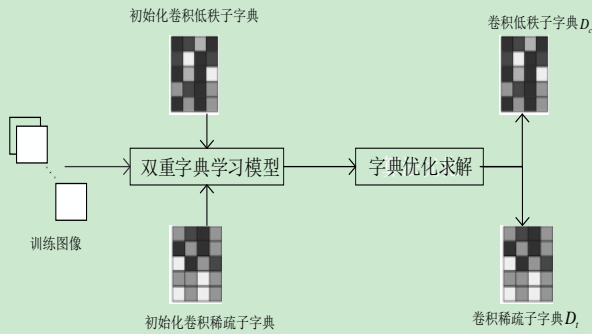


图 3 双重字典学习过程

Fig. 3 Dictionary learning process

2.1.2 双重字典学习模型求解

式 (6) 的求解对于各变量为非凸优化问题, 本文通过采用交替迭代的方式将式 (6) 分解为三个子问题求解^[25]。包括辅助变量更新、稀疏编码与字典更新三个阶段:

1) 随机初始化字典及其他变量, 在更新辅助

变量 \mathbf{Y}_c 时, 保持其他变量不变, 通过求解式 (7) 实现对 \mathbf{Y}_c 矩阵的更新:

$$\min_{\mathbf{Y}_c} \left\{ \|\mathbf{Y} - \mathbf{Y}_c - \mathbf{Y}_t\|_2^2 + \|\mathbf{Y}_c - \mathbf{D}_c \mathbf{x}_c\|_2^2 + \lambda_1 \|\mathbf{Y}_c\|_* \right\} \quad (7)$$

式 (7) 中, 通过引入辅助变量 $\hat{\mathbf{Y}}$, $\tilde{\mathbf{Y}}_c$, 使得 $\hat{\mathbf{Y}} = [\mathbf{Y} - \mathbf{Y}_t; \mathbf{D}_c \mathbf{x}_c]$, $\tilde{\mathbf{Y}}_c = [\mathbf{Y}_c; \mathbf{Y}_c]$ 。将问题 (7) 等价地转化为:

$$\min_{\tilde{\mathbf{Y}}_c} \left\{ \|\hat{\mathbf{Y}} - \tilde{\mathbf{Y}}_c\|_2^2 + \lambda_1 \|\tilde{\mathbf{Y}}_c\|_* \right\} \quad (8)$$

该式可看做为核范数最小化的问题, 通过奇异值阈值算法^[26]求解。更新变量 \mathbf{Y}_t 时, 通过保持其它变量不变, 以与更新 \mathbf{Y}_c 同样的方式可得优化问题:

$$\min_{\tilde{\mathbf{Y}}_t} \left\{ \|\hat{\mathbf{Y}} - \tilde{\mathbf{Y}}_t\|_2^2 + \lambda_2 \|\tilde{\mathbf{Y}}_t\|_1 \right\} \quad (9)$$

式中 $\hat{\mathbf{Y}} = [\mathbf{Y} - \mathbf{Y}_c; \mathbf{D}_t \mathbf{x}_t]$, $\tilde{\mathbf{Y}}_c = [\mathbf{Y}_t; \mathbf{Y}_t]$ 。该式通过迭代收缩算法^[27]求解, 从而得到更新的辅助变量 \mathbf{Y}_t 。

2) 稀疏编码阶段。在更新卷积低秩系数 \mathbf{x}_c 时, 通过保持其余变量不变, 得式 (10); 同理在更新卷积低秩系数 \mathbf{x}_t , 保持其余变量不变, 得式 (11):

$$\mathbf{x}_c = \arg \min_{\mathbf{x}_c} \left\{ \|\mathbf{Y}_c - \mathbf{D}_c \mathbf{x}_c\|_2^2 + \lambda_c \|\mathbf{x}_c\|_1 \right\} \quad (10)$$

$$\mathbf{x}_t = \arg \min_{\mathbf{x}_t} \left\{ \|\mathbf{Y}_t - \mathbf{D}_t \mathbf{x}_t\|_2^2 + \lambda_t \|\mathbf{x}_t\|_1 \right\} \quad (11)$$

显然两式为凸函数, 通过对字典与系数进行离散傅里叶变换, 将其变换到频域, 可将空间域的卷积转化为频域的乘积, 再通过交替方向乘法 (ADMM)^[19]求解, 从而得到更新的稀疏系数矩阵 \mathbf{x}_c 与 \mathbf{x}_t 。

3) 字典更新阶段。在更新卷积低秩字典 \mathbf{D}_c 时, 保持其余变量不变, 并引入辅助变量 \mathbf{Z} , 使得 $\mathbf{D}_c = \mathbf{Z}$, 得式 (12); 在更新卷积稀疏字典 \mathbf{D}_t

时, 保持其余变量不变, 得式 (13):

$$\min_{D_c} \|Y_c - D_c x_c\|_2^2 + \lambda_3 \|Z\|_* \quad \text{s.t. } D_c = Z \quad (12)$$

$$\min_{D_t} \|Y_t - D_t x_t\|_2^2 \quad (13)$$

式 (12) 为约束优化问题, 由增广拉格朗日乘法^[28]求解, 可得更新的子字典 D_c 。式 (13) 也以相同的方式求解, 得更新的卷积稀疏子字典 D_t 。最后, 循环执行上述三个步骤, 直至达到设定的循环次数停止, 输出卷积低秩与卷积稀疏子字典 D_c , D_t 。

2.2 卷积稀疏和低秩图像分解

根据 2.1 节学习到的卷积低秩和卷积稀疏子字典 $\{d_c\}$ 及 $\{d_t\}$, 将源图像 $A \in \mathbf{R}^{M \times N}$ 分解为卷积稀疏和卷积低秩两部分分量。建立图像分解模型:

$$\min_{x_c, x_t} \frac{1}{2} \left\| A - \sum_{k=1}^{K_c} d_{c,k} * x_{c,k} - \sum_{k=1}^{K_t} d_{t,k} * x_{t,k} \right\|_2^2 + \lambda_1 \sum_{k=1}^{K_c} \|x_{c,k}\|_1 + \lambda_2 \sum_{k=1}^{K_t} \|x_{t,k}\|_1 + \lambda_3 \text{TV} \left(\sum_{k=1}^{K_c} d_{c,k} * x_{c,k} \right) \quad (14)$$

其中 λ_1 、 λ_2 和 λ_3 表示正则化参数, 采用了总变分正则化(TV)的各向异性的规则, 即 $\text{TV}(x) = \|g_0 * x\|_1 + \|g_1 * x\|_1$, 其中 g_0 和 g_1 分别为计算图像沿 x 轴和 y 轴方向梯度的过滤器。

式 (14) 通过更新卷积稀疏与卷积低秩系数交替迭代进行, 分为以下两个步骤:

首先在更新 $x_{c,k}$ 时, 通过固定 $x_{t,k}$, 将式 (14) 转化为:

$$\min_{x_c} \frac{1}{2} \left\| A - \sum_{k=1}^{K_t} d_{t,k} * x_{t,k} - \sum_{k=1}^{K_c} d_{c,k} * x_{c,k} \right\|_2^2 + \lambda_1 \sum_{k=1}^{K_c} \|x_{c,k}\|_1 + \lambda_3 \text{TV} \left(\sum_{k=1}^{K_c} d_{c,k} * x_{c,k} \right) \quad (15)$$

该式可视为带 TV 正则的稀疏编码问题, 通过基于 DFT 的 ADMM^[19] 算法求解, 由此得到更新的低秩系数矩阵。

其次在更新 $x_{t,k}$ 时, 通过固定 $x_{c,k}$, 转化原

式 (14) 如下:

$$\hat{x}_{t,k} = \arg \min_{x_{t,k}} \frac{1}{2} \left\| A - \sum_{k=1}^{K_c} d_{c,k} * x_{c,k} - \sum_{k=1}^{K_t} d_{t,k} * x_{t,k} \right\|_2^2 + \lambda_2 \sum_{k=1}^{K_t} \|x_{t,k}\|_1 \quad (16)$$

为了便于优化, 引入辅助变量 y_r , 使得 $y_r = A - \sum_{k=1}^{K_c} d_{c,k} * x_{c,k}$, 将式 (16) 转化成如下的形式:

$$\hat{x}_{t,k} = \arg \min_{x_{t,k}} \frac{1}{2} \left\| y_r - \sum_{k=1}^{K_t} d_{t,k} * x_{t,k} \right\|_2^2 + \lambda_2 \sum_{k=1}^{K_t} \|x_{t,k}\|_1 \quad (17)$$

在求解式 (17) 时, 通过 ADMM 框架^[23] 交替迭代求解, 由此可得到更新的稀疏系数矩阵。最后循环执行上述两个步骤, 直至达到预设的循环次数为止, 输出源图像 A 的低秩系数矩阵与稀疏系数矩阵, 并通过 $\hat{y}_c = \sum_{k=1}^{K_c} d_{c,k} * \hat{x}_{c,k}$ 与

$\hat{y}_t = \sum_{k=1}^{K_t} d_{t,k} * \hat{x}_{t,k}$ 卷积操作, 来得到源图像 A 的卷积低秩分量与卷积稀疏分量。

2.3 基于自适应 PCNN 的融合过程

2.3.1 卷积稀疏分量融合规则

由上 2.2 节可得源图像 A 与 B 的稀疏分量分别为 S_A 与 S_B 。稀疏分量包含了图像大量细节纹理信息, 其将直接影响融合融合图像的视觉质量。由于改进的空间频率和 (NMSF) 能很好的反映图像的清晰度和活动水平, 同时也可检测输入纹理的梯度变化。因此对于稀疏分量的融合, 采用自适应 PCNN 算法进行纹理的提取, 先求出稀疏分量改进的空间频率和, 并作为 PCNN 的外部刺激, 再以反映图像清晰度的区域平均梯度确定链接强度 β 。最后通过 PCNN 输出的点火次数图对稀疏分量进行融合。

1) 计算稀疏分量改进的空间频率 $NMSF_A(i, j)$ 和 $NMSF_B(i, j)$ 。设卷积稀疏分量 S_A 和 S_B 的像素系数为 $S_A(i, j)$ 和 $S_B(i, j)$, 则首先通过式 (18) 计算各分量的对角频率 D_f^A 和 D_f^B , 然后通过式 (19) 求出卷积稀疏分量分别

为 $NMSF_A(i, j)$ 和 $NMSF_B(i, j)$ 。

$$D_f = \left[\sqrt{\frac{1}{(M-1)(N-1)} \left[\sum_{i=2}^M \sum_{j=2}^N (S(i, j) - S(i-1, j-1))^2 \right]} \right. \\ \left. + \sqrt{\frac{1}{(M-1)(N-1)} \left[\sum_{i=2}^M \sum_{j=2}^N (S(i-1, j) - S(i, j-1))^2 \right]} \right]^2 \quad (18)$$

$$NMSF = \sqrt{\frac{1}{M(N-1)} \left[\sum_{i=1}^M \sum_{j=2}^N (S(i, j-1) - S(i, j))^2 \right]} \\ + \frac{1}{(M-1)N} \left[\sum_{i=2}^M \sum_{j=1}^N (S(i, j) - S(i-1, j))^2 \right] + D_f \quad (19)$$

2) 计算区域平均梯度 $\bar{g}_A^S(i, j)$ 和

$\bar{g}_B^S(i, j)$ 。区域平均梯度能反映图像的清晰度，区域平均梯度越大，则该图像更清晰。对于稀疏分量系数 $S_A(i, j)$ 和 $S_B(i, j)$ ，区域平均梯度通过下式求得。

$$\left\{ \begin{aligned} \bar{g}(i, j) &= \frac{1}{9} \sum_{a=-1}^1 \sum_{b=-1}^1 \left\{ \frac{[g_1(i+a, i+b) + g_2(i+a, i+b)]}{2} \right\}^{1/2} \\ g_1(i, j) &= [S(i, j) - S(i+1, j)]^2 \\ g_2(i, j) &= [S(i, j) - S(i, j+1)]^2 \end{aligned} \right. \quad (20)$$

3) 采用 PCNN 模型求得卷积稀疏分量的点火频率图 $T_A^S(i, j)$ 和 $T_B^S(i, j)$ 。将 $NMSF_A(i, j)$ 和 $NMSF_B(i, j)$ 作为 PCNN 的刺激输入，并将 $\bar{g}_A^S(i, j)$ 和 $\bar{g}_B^S(i, j)$ 作为链接强度 β ，如下式 (21)、(22) 所示：

$$F_{i,j}^S[n] = NMSF_{i,j}^S \quad (21)$$

$$\beta(i, j) = \bar{g}^S(i, j) \quad (22)$$

4) 在 PCNN 达到迭代次数 n 时，根据输出点火频率图 $T_A^S(i, j)$ 和 $T_B^S(i, j)$ ，求得融合图像稀疏分量 F_S ：

$$F_S(i, j) = \begin{cases} S_A(i, j) & \text{if } T_{i,j,A}^S[n_{\max}] \geq T_{i,j,B}^S[n_{\max}] \\ S_B(i, j) & \text{if } T_{i,j,A}^S[n_{\max}] < T_{i,j,B}^S[n_{\max}] \end{cases}$$

(23)

2.3.2 卷积低秩分量融合规则

经 2.2 节后，源图像 A 、 B 的卷积低秩分量 C_A 和 C_B 包含了图像的大量基本信息，如图像的亮度信息和轮廓信息，其融合至关重要。传统的平均策略不仅会造成图像的细节模糊而且会导致亮度下降；邻域能量策略虽然较好地保留了图像重要边缘，但是会模糊较低亮度的边缘信息。改进的拉普拉斯能量和 (NSML) 可以较好的反映图像的边缘特征信息，在一定程度上能恰当地反应图像的聚焦特性和清晰度，因此对于卷积低秩分量的融合，先求出 C_A 和 C_B 改进的拉普拉斯能量和，并作为 PCNN 的外部刺激，再以区域平均梯度确定链接强度 β ，尽可能保留微小细节。最后通过 PCNN 输出的点火次数图对低秩分量进行融合。

1) 计算卷积低秩分量改进的拉普拉斯能量和 $NSML_A(i, j)$ 和 $NSML_B(i, j)$ 。对于卷积低秩分量系数 $C_A(i, j)$ 和 $C_B(i, j)$ ，其由式 (24)、(25) 求得 $NSML_A(i, j)$ 和 $NSML_B(i, j)$ 。

$$NSML(i, j) = \sum_a \sum_b w(a, b) F(i+a, j+b) \quad (24)$$

$$F(i, j) = |2C(i, j) - C(i-1, j) - C(i+1, j)| \\ + |2C(i, j) - C(i, j-1) - C(i, j+1)| \quad (25)$$

其中 $w(a, b)$ 表示滑动窗口区域对应的权重值， a 、 b 指窗口的大小，通常可以取 3×3 ， 5×5 或者 7×7 。为了更好地匹配变化不剧烈的区域对比度与体现卷积低秩分量的频率变化，本文选取窗口大小为 3×3 的矩阵，即

$$w(a, b) = \begin{bmatrix} 1/15 & 2/15 & 1/15 \\ 2/15 & 3/15 & 2/15 \\ 1/15 & 2/15 & 1/15 \end{bmatrix}$$

2) 计算 C_A 和 C_B 的区域平均梯度 $\bar{g}_A^C(i, j)$

和 $\bar{g}_B^C(i, j)$ 。其计算过程如上式 (20)。

$$\beta(i, j) = \bar{g}^C(i, j) \quad (27)$$

3) 通过 PCNN 模型计算 C_A 和 C_B 的点火频率图 $T_A^C(i, j)$ 和 $T_B^C(i, j)$ 。将 $NSML_A(i, j)$ 和 $NSML_B(i, j)$ 作为 PCNN 的刺激输入, 并将 $\bar{g}_A^C(i, j)$ 和 $\bar{g}_B^C(i, j)$ 作为链接强度 β , 如下式 (26)、(27) 所示:

$$F_{i,j}^C[n] = NSML_{i,j}^C \quad (26)$$

4) 同样根据 PCNN 输出的点火频率图 $T_A^C(i, j)$ 和 $T_B^C(i, j)$, 求得融合图像低秩分量 F_C :

$$F_C(i, j) = \begin{cases} C_A(i, j) & \text{if } T_{i,j,A}^C[n_{\max}] \geq T_{i,j,B}^C[n_{\max}] \\ C_B(i, j) & \text{if } T_{i,j,A}^C[n_{\max}] < T_{i,j,B}^C[n_{\max}] \end{cases}$$

2.4 融合过程

设已经配准的医学 CT/MR 源图像 A , $B \in \mathbf{R}^{M \times N}$, 融合过程如下:

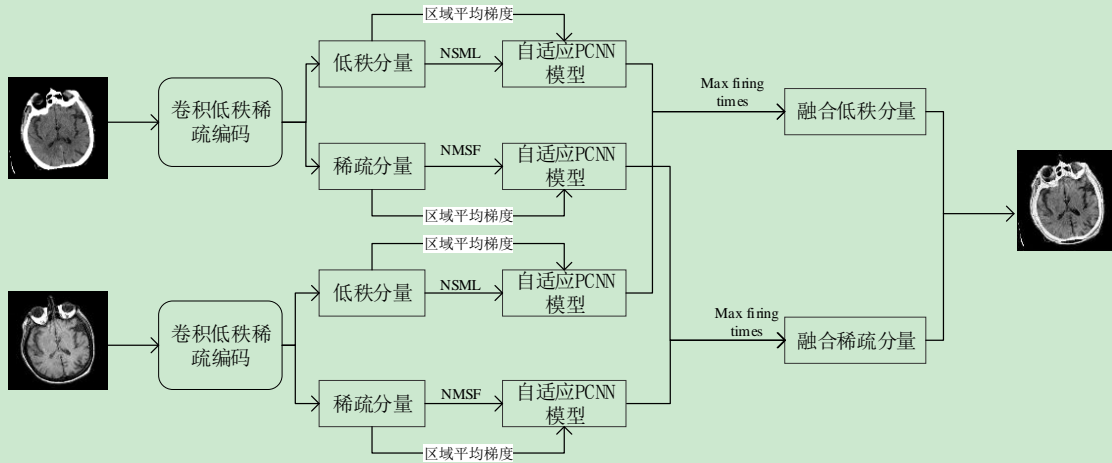


图4 多模态医学图像融合过程

Fig. 4 Multimodal medical image fusion process

1) 字典学习阶段。通过 2.1 节中的字典学习模型, 使用训练数据集 $\mathbf{Y} = (\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_m)$, 进行交替迭代求解得卷积稀疏字典 D_l 与卷积低秩字典 D_c 。

2) 图像分解阶段。对源图像 A 与 B 分别通过交替方向乘法 (ADMM) 求解其稀疏表示系数。使得源图像 A 的稀疏表示系数为 $\{\mathbf{x}_{c,k}^A, \mathbf{x}_{l,k}^A\}$, 源图像 B 的稀疏表示系数为 $\{\mathbf{x}_{c,k}^B, \mathbf{x}_{l,k}^B\}$, 然后通过卷积操作重构对应的分量。

3) 卷积稀疏分量融合阶段。求出卷积稀疏分量 S_A 与 S_B 改进的空间频率 $NMSF_A(i, j)$ 和

$NMSF_B(i, j)$ 以及区域平均梯度 $\bar{g}_A^S(i, j)$ 和 $\bar{g}_B^S(i, j)$, 分别作为 PCNN 的刺激输入和链接强度 β , 计算相应的点火频率图 $T_A^S(i, j)$ 和 $T_B^S(i, j)$, 最后通过融合规则求得融合卷积稀疏分量 F_s 。

4) 卷积低秩分量融合阶段。求出卷积低秩分量 C_A 与 C_B 改进的拉普拉斯能量和 $NSML_A(i, j)$ 和 $NSML_B(i, j)$ 以及区域平均梯度 $\bar{g}_A^C(i, j)$ 和 $\bar{g}_B^C(i, j)$, 分别作为 PCNN 的刺激输入和链接强

度 β ，计算相应的点火频率图 $T_A^C(i, j)$ 和 $T_B^C(i, j)$ ，通过融合规则求得融合卷积低秩分量 F_C 。

5) 最后通过进一步组合融合后的分量得到最终的融合图像 F ：

$$F = F_C + F_S$$

3 实验结果与分析

3.1 实验参数

为了验证所提出方法的性能，选取了三组经过配准的脑部多模态医学图像（大小均 256x256 像素）作为待融合的源图像，其中源图像数据来源于哈佛大学医学院^[29]，包括脑血管疾病 CT/MR 图像、脑部肿瘤 MR/PET 图像、脑部肿瘤 MR/SPECT 图像。同时采取了六种对比算法进行比较，选取的对比算法包括：1) 基于多尺度变换和稀疏表示的图像融合算法^[30]（Multi-Scale Transform and Sparse Representation based, MST-SR），2) 基于自适应稀疏表示的图像融合算法^[31]（Adaptive Sparse Representation based, ASR），3) 基于 NSCT 和单元链接 PCNN 的自适应医学图像融合算法^[32]（NSCT and Unit-Linking PCNN, NSCT-PCNN），4) 基于联合补丁聚类的医学图像融合算法^[33]（Joint patch clustering-based, JPC），5) 基于滑动窗口和稀疏表示的医学图像融合算法^[34]（SWT-SR），6) 基

于非下采样轮廓波变换算法^[35]（NSCT）。将本文的方法记作（CSRDD-APCNN）。

同时在训练卷积稀疏与低秩字典时，所需的训练图像如图 5 所示。对于 MSR-SR 方法而言，其字典训练样本是从 20 幅自然的图像中随机采样 10 万个图像块，其滑动步长设置为 1，滑动窗口大小设置为 8 x 8，字典的大小设置为 64 x 512，并设置误差 $\epsilon=0.03$ 和稀疏度 $\tau=8$ ，且 MST-SR 方法的多尺度变换选择 LP，分解水平设为 3。NSCT 方法使用“9-7”金字塔滤波器和“c-d”

方向滤波器，分解水平为 $\{2^2, 2^2, 2^3, 2^4\}$ 。对于其

余的 ASR、NSCT-PCNN、JPC 及 SWT-SR 方法，所有的参数分别根据[31]-[34]中的设置设定的。

对于本文所提出的方法所涉及到的参数是由多次实验调参所得，在这里对于字典学习模型的式(6)而言，将加权指数 λ_c 和 λ_l 都设置为 0.005，同时将低秩与稀疏分量的加权指数 λ_1 和 λ_2 分别设置为 1 和 0.01，将 λ_3 设置为 1。将如式（14）

所示的图像分解模型的参数 λ_1 、 λ_2 与 λ_3 设置为 0.38、3.37 和 0.05。在使用 ADMM 算法迭代求解时，将外循环迭代次数设置为 200，内循环次数设置为 100，在图像融合阶段所使用的 PCNN 的参数设置为 $\alpha_L=0.3$ ， $\alpha_T=0.1$ ， $\beta=0.2$ ， $V_L=1$ ， $V_T=10$ ，并将其迭代次数设置为 200。在图 6 中给出了所训练出的卷积稀疏与卷积低秩字典。



图 5 字典学习的训练样本

Fig. 5 Training samples for dictionary learning

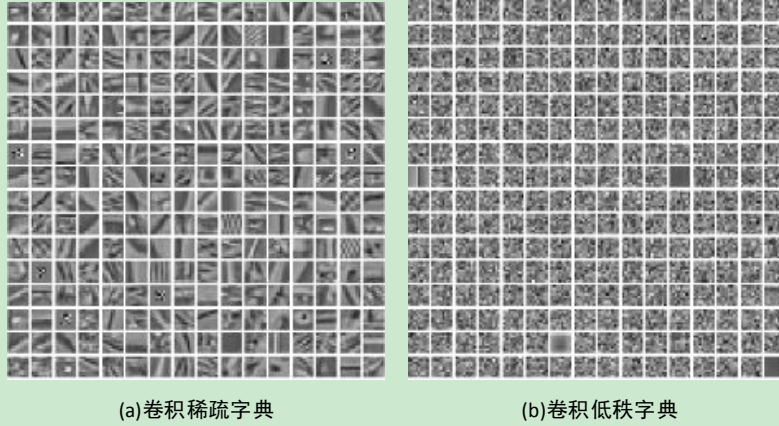


图 6 学习的卷积低秩字典与卷积稀疏字典

Fig. 6 Learned Convolutional Low Rank Dictionary and Convolutional Sparse Dictionary

(a) Convolution sparse dictionary; (b) Convolutional low rank dictionary)

3.2 评价标准

本文采用了四种评价指标对实验融合图像的质量进行定量地评价：标准差（Standard Deviation, SD）^[36]、标准化互信息（Normalized Mutual Information, MI）^[37]、空间频率（Spatial frequency, SF）以及边缘信息传递因子（ $Q^{AB/F}$ ）^[38]。其中标准差 SD 是用来测量融合图像的对比度，标准差越大则对应的对比度越高；互信息 MI 可以度量源图像和融合图像在灰度分布上的相似程度，提取的信息越多，融合质量越好，在计算互信息 MI 时，是首先分别计算融合图像 F 与源图像 A 和 B 的之间的互信息：

$$I_{FA}(f, a) = \sum_{f, a} p_{FA}(f, a) \log_2 \frac{p_{FA}(f, a)}{p_F(f) p_A(a)}$$

$$I_{FB}(f, b) = \sum_{f, b} p_{FB}(f, b) \log_2 \frac{p_{FB}(f, b)}{p_F(f) p_B(b)}$$

根据上式计算的结果得出图像融合质量测量指标结果：

$$M_F^{AB} = I_{FA}(f, a) + I_{FB}(f, b)$$

空间频率 SF 用来测量图像的整体活动和清晰度水平，该指标定义如下：

$$SF = \sqrt{RF^2 + CF^2}$$

其中 RF 表示图像的行频率, CF 表示列频率：

$$RF = \sqrt{\frac{1}{M(N-1)} \sum_{i=0}^{M-1} \sum_{j=0}^{N-2} (F(i, j+1) - F(i, j))^2}$$

$$CF = \sqrt{\frac{1}{(M-1)N} \sum_{i=0}^{M-2} \sum_{j=0}^{N-1} (F(i+1, j) - F(i, j))^2}$$

式中 M 和 N 表示图像的行数和列数，其中空间频率 SF 的值越大，则融合效果越好；边缘信息传递因子 $Q^{AB/F}$ 通过使用 Sobel 边缘检测算子来测量从源图像传递到融合图像的边缘和方向信息，该指标的定义如下：

$$Q^{AB/F} = \frac{\sum_{i=1}^M \sum_{j=1}^N [Q_{i,j}^{AF} w_{i,j}^x + Q_{i,j}^{BF} w_{i,j}^y]}{\sum_{i=1}^M \sum_{j=1}^N [w_{i,j}^x + w_{i,j}^y]}$$

上式中 Q^{AF} 与 Q^{BF} 的定义类似：

$$Q_{i,j}^{AF} = Q_{g,i,j}^{AF} Q_{\alpha,i,j}^{AF}$$

$$Q_{i,j}^{BF} = Q_{g,i,j}^{BF} Q_{\alpha,i,j}^{BF}$$

上式中的 Q_g^{*F} 和 Q_α^{*F} 表示源图像 A 和 B 分别在位置 (i, j) 处对应的边缘强度和方向保持值。其中 $Q^{AB/F}$ 的动态范围为 $[0, 1]$ ，越接近于 1，其融合效果越好。

3.3 实验结果分析

在图 7 中给出了脑血管疾病 CT/MR 图像的融合结果，其中图像 **a** 和 **b** 分别表示 CT 源图像和 MR 源图像。从 MST-SR、ASR、NSCT-PCNN、JPC、SWT-SR 方法以及 NSCT 方法的融合结果看，其图像都存在皮质细节平滑的问题，并且 MST 方法在组织和病灶部位存在一定的伪影；ASR、SWT-SR 方法以及 NSCT 方法都存在对比度降低的问题。从表 1 中可以看出以上方法在 MI 指标以及 $Q^{AB/F}$ 指标上都较低，表明其细节保留上存在缺陷，与主观视觉一致。其中 MST-SR、ASR 和 SWT-SR 方法细节保留不足的情况可能是在进行稀疏表示时，对每个像素对应的多值取平均时造成的细节平滑。本文提出的方法在对比度以及细节保留方面都优于前面的方法，其细节结构是清晰的，有利于医生诊断和观察脑部皮质结构，从表 3 量化评估上，也可以看出本文所提出的方法从源图像保留了较丰富的细节信息，融合质量较好。




图 7 脑血管疾病的 CT/MR 融合结果

Fig. 7 Fusion results of Cerebrovascular disease

CT/MR

((a) CT; (b)MR; (c) reference[30]; (d) reference[31]; (e) reference[32]; (f) reference[33]; (g) reference[34]; (h) reference[35]; (i) ours)

表 1 脑血管疾病 CT/MR 融合结果性能比较

Tab. 1 Comparison of Cerebrovascular disease CT/MR fusion results

图像	融合方法	评价指标			
		SD	MI	SF	$\theta^{AB/F}$
脑血管疾病	MST-SR	68.8573	2.3209	24.5461	0.5103
CT 和 MRI 图像	ASR	70.3849	2.5105	25.1562	0.6658
	NSCT-PCNN	62.2033	2.7618	23.1044	0.5502
	JPC	67.8543	2.7380	21.2350	0.5911
	SWT-SR	64.2070	3.3065	22.9582	0.5360
	NSCT	67.2510	2.1984	25.5173	0.6248
	CSRDD-APCNN	71.3652	3.4575	25.6012	0.6722

注：黑色字体表示最优结果。

在图 8 中给出了脑部肿瘤疾病 MR/PET 图像的融合结果，其中图像 **a** 和 **b** 分别表示 MR 源图像和 PET 源图像。其中 PET 图像提供关于病变代谢的详细信息，而 MR 图像显示软组织信息和病

灶的确切解剖位置，因此在融合过程中需要很好的保留颜色信息。从融合结果中可以看出 MST-SR、ASR、SWT-SR、NSCT、NSCT-PCNN 以及 JPC 方法都存在颜色丢失和对比度下降的问

题。同时，在 ASR 方法、SWT-SR 方法的结果中都出现不同程度的伪影现象。而在 NSCT-PCNN 方法和 JPC 方法中出现皮质细节区域平滑的问题，同时从表 2 的量化数据分析，MST-SR、ASR、SWT-SR 以及 NSCT 方法在 SD 指标上偏低，也说明了其对比度下降的问题，以及从 MI 指标和

$Q^{AB/F}$ 指标来看，NSCT、NSCT-PCNN 方法偏低，表明其保留的边缘信息较少，这也与主观视觉观察较为一致。本文的方法在颜色保留、对比度以及细节保留等方面表现的性能都较好，从表 2 中也可观察在各项指标都有较高的量值，融合质量较好，有利于医生对脑肿瘤疾病的诊断。




图 8 脑部肿瘤疾病的 MR/PET 融合结果

Fig. 8 Fusion results of Brain tumor disease MR/PET ((a) CT; (b)PET; (c) reference[30]; (d) reference[31]; (e) reference[32]; (f) reference[33]; (g) reference[34]; (h) reference[35]; (i) ours)

表 2 脑部肿瘤疾病 MR/PET 融合结果性能比较

Tab. 2 Comparison of Brain tumor disease MR/PET fusion results

图像	融合方法	评价指标			
		SD	MI	SF	$\theta^{AB/F}$
肿瘤性疾病	MST-SR	56.8427	2.6781	18.4792	0.6452
MRI 和 PET 图像	ASR	54.2416	2.6960	19.2107	0.6240
	NSCT-PCNN	57.5939	2.5681	20.5165	0.5208
	JPC	57.2043	2.6637	18.2355	0.5300
	SWT-SR	53.3361	2.5805	19.3152	0.5532
	NSCT	44.2512	2.3031	18.6407	0.5120
	CSRDD-APCNN	58.7982	2.8547	20.8710	0.6753

注：黑色字体表示最优结果。

在图 9 中给出的是脑部肿瘤疾病的 MR/SPECT 图像的融合结果，图像 a 和 b 分别表示 MR 源图像和 SPECT 源图像。这里同样要较

好的保留 SPECT 图像中颜色信息，而从融合结果观察来看，在 MST-SR、ASR、SWT-SR、NSCT-PCNN、JPC 以及 NSCT 方法的融合图像中

仍存在颜色传递失真的问题；在 MST-SR、SWT-SR 的融合图像中存在对比度下降以及细节模糊问题，这可能是字典信息不够丰富，不能提取充分的细节信息和医学图像特征导致的灰度不连续效应，以及 MST-SR 方法缺乏平移不变性和缺乏方向性等问题。同时从表 3 的指标分析，MST-SR 以及 SWT-SR 方法在 SD 指标上偏低，

也说明其对比度下降的问题，与主观视觉观察较为一致。相比之下，本文的方法从融合结果来看不会导致颜色和软组织信息失真，并且在融合结果中更好地保留了源图像中的补充信息，图像病灶部位细节清晰，对比度较高，没有伪影，融合质量较好，有利于医生进行诊断，在表 3 中的数据也佐证了这一点，与主观视觉观察一致。




图 9 脑部肿瘤疾病的 MR/SPECT 融合结果

Fig. 9 Fusion results of Brain tumor disease MR/SPECT

((a) CT; (b)SPECT; (c) reference[30]; (d) reference[31]; (e) reference[32]; (f) reference[33]; (g) reference[34]; (h) reference[35]; (i) ours)

表 3 脑部肿瘤疾病 MR/PET 融合结果性能比较

Tab. 3 Comparison of Brain tumor disease MR/SPECT fusion results

图像	融合方法	评价指标			
		SD	MI	SF	$\theta^{AB/F}$
肿瘤性疾病	MST-SR	65.2064	2.6271	16.5642	0.6021
MRI 和 SPECT 图像	ASR	67.5133	2.6593	15.6076	0.5477
	NSCT-PCNN	63.5978	2.4786	16.7406	0.3974
	JPC	66.7520	2.5672	15.8321	0.5720
	SWT-SR	65.1290	2.8546	16.8249	0.5490
	NSCT	63.4520	2.5751	16.4732	0.5727
	CSRDD-APCNN	68.6256	2.9177	17.2422	0.6446

注：黑色字体表示最优结果。

4 结论

针对基于稀疏的融合方法存在保留细节能力有限的问题,在本文中,提出了一种通过学习具有判别性的卷积低秩与卷积稀疏双重字典模型与自适应 PCNN 相结合的图像融合方法,通过字典学习与卷积系数编码将图像分解为低秩分量与稀疏分量,低秩分量融合规则采用新颖的拉普拉斯能量和 (NSML) 激励脉冲耦合神经网络的方法,稀疏分量融合规则采用新颖的空间频率和 (NMSF) 激励脉冲耦合神经网络的方法。从实验仿真可知,所提出的融合方法在客观评估和视觉质量方面明显优于对比的方法,保留了更丰富的特征和细节信息。但本文仍存在字典学习模型及分解模型上需预设参数的问题,若参数设置不合适,会很大的影响学习的字典效率以及影响图像融合质量。探索如何有效的自适应确定参数的问题,是我们下一步研究的重点。

参考文献(References)

- [1] Shutao Li, Xudong Kang, Jianwen Hu, Bin Yang. Image matting for fusion of multi-focus images in dynamic scenes[J]. Information Fusion, 2013, 14(2).
- [2] Lou J, Li J F, Dai W Z . Medical image fusion using non-subsampled shearlet transform[J]. Journal of Image and Graphics, 2017, 22(11): 1574-1583. [楼建强, 李俊峰, 戴文战. 非下采样剪切波变换的医学图像融合[J]. 中国图象图形学报, 2017, 22(11): 1574-1583.][DOI: 10.11834/jig.170014]
- [3] Li H, Manjunath B S, Mitra S K. Multi-Sensor Image Fusion using the Wavelet Transform.[C]// International Conference on Image Processing. IEEE, 2002:51-55 vol.1.
- [4] Do M N, Vetterli M. The contourlet transform: an efficient directional multiresolution image representation[J]. IEEE Transactions on Image Processing, 2005, 14(12):2091-2106.
- [5] Kong W, Liu J. Technique for image fusion based on nonsubsampling shearlet transform and improved pulse-coupled neural network[J]. Optical Engineering, 2013, 52(1):7001.
- [6] Baohua Z, Xiaoqi L, Weitao J. A multi-focus image fusion algorithm based on an improved dual-channel PCNN in NSCT domain[J]. Optik - International Journal for Light and Electron Optics, 2013, 124(20):4104-4109.
- [7] Bhatnagar G, Wu Q M J, Liu Z. Directive Contrast Based Multimodal Medical Image Fusion in NSCT Domain[J]. IEEE Transactions on Multimedia, 2013, 15(5):1014-1024.
- [8] Luo X, Zhang Z, Zhang B, et al. Image fusion with contextual statistical similarity and nonsubsampling shearlet transform[J]. IEEE Sensors Journal, 2017, PP(99):1-1.
- [9] Donoho D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4):1289-1306.
- [10] Zhu Z, Chai Y, Yin H, et al. A novel dictionary learning approach for multi-modality medical image fusion[J]. Neurocomputing, 2016, 214:471-482.
- [11] DONG X, WANG L F, QIN P L, et al . CT /MR brain image fusion method via improved coupled dictionary learning [J]. Journal of Computer Applications, 2017, 37(6) : 1722 — 1727. [董侠, 王丽芳, 秦品乐, 等. 改进耦合字典学习的脑部 CT /MR 图像融合方法 [J]. 计算机应用, 2017, 37(6) :1722 — 1727.]
- [12] Zhang X, Xue Y J, Tu S Q, Hu Y M, Ning X F . Remote sensing image fusion based on structural group sparse representation[J]. Journal of Image and Graphics, 2016, 21(8): 1106-1118. [张晓, 薛月菊, 涂淑琴, 胡月明, 宁晓锋. 基于结构组稀疏表示的遥感图像融合[J]. 中国图象图形学报, 2016, 21(8): 1106-1118.][DOI: 10.11834/jig.20160815]
- [13] Zhang H, Patel V M. Convolutional Sparse and Low-Rank Coding-Based Image Decomposition.[J]. IEEE Trans Image Process,

- 2018, PP(99):2121-2133.
- [14]Gu S, Zuo W, Xie Q, et al. Convolutional Sparse Coding for Image Super-Resolution[C]// IEEE International Conference on Computer Vision. IEEE, 2015:1823-1831.
- [15]Rong Y, Xiong S, Gao Y. Low-Rank Double Dictionary Learning from Corrupted Data for Robust Image Classification[J]. Pattern Recognition, 2017, 72.
- [16]Yin H, Li Y, Chai Y, et al. A novel sparse-representation-based multi-focus image fusion approach[J]. Neurocomputing, 2016, 216(C):216-229.
- [17]Zong J J, Qiu T S. Medical image fusion based on sparse representation of classified image patches[J]. Transducer & Microsystem Technologies, 2017, 34:195-205.
- [18]Zhang Q, Levine M. Robust multi-focus image fusion using multi-task sparse representation and spatial context.[M]. IEEE Press, 2016.
- [19]Garcia-cardona C, Wohlberg B. Convolutional Dictionary Learning: A Comparative Review and New Algorithms[J]. IEEE Transactions on Computational Imaging, 2018, PP(99):1-1.
- [20]Bristow H, Eriksson A, Lucey S. Fast Convolutional Sparse Coding[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2013:391-398.
- [21]Wohlberg B. Efficient Algorithms for Convolutional Sparse Representations[J]. IEEE Transactions on Image Processing, 2015, 25(1):301-315.
- [22]Chai Y, Li H F, Guo M Y. Multifocus image fusion scheme based on features of multiscale products and pcnn in lifting stationary wavelet domain[J]. Optics Communications, 2011, 284(5):1146-1158.
- [23]Wohlberg B. Efficient convolutional sparse coding[C]// IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2014:7173-7177.
- [24]Garcia-cardona C, Wohlberg B. Convolutional Dictionary Learning: A Comparative Review and New Algorithms[J]. IEEE Transactions on Computational Imaging, 2018, PP(99):1-1.
- [25]Gabay D, Mercier B. A dual algorithm for the solution of nonlinear variational problems via finite element approximation[J]. Computers & Mathematics with Applications, 1976, 2(1):17-40.
- [26]Cai J F, Candès, Emmanuel J, Shen Z. A Singular Value Thresholding Algorithm for Matrix Completion[J]. SIAM Journal on Optimization, 2010, 20(4):1956-1982.
- [27]Zhang Y, Wang S, Ji G, et al. Exponential wavelet iterative shrinkage thresholding algorithm with random shift for compressed sensing magnetic resonance imaging[J]. Information Sciences, 2015, 322(1):115-132.
- [28]Z. Lin, M. Chen, L. Wu, Y. Ma, The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices, Technical report, 2009.UILU-ENG-09-2215
- [29]<http://www.med.harvard.edu/AANLIB/home.html>
- [30]Liu Y, Liu S, Wang Z. A general framework for image fusion based on multi-scale transform and sparse representation[J]. Information Fusion, 2015, 24:147-164.
- [31]Liu Y, Wang Z. Simultaneous image fusion and denoising with adaptive sparse representation[J]. Image Processing Iet, 2014, 9(5):347-357.
- [32]Liu W. Adaptive Medical Image Fusion Method based on NSCT and Unit-Linking PCNN[C]// International Conference on Computer Engineering, Information Science & Application Technology. 2016.
- [33]Kim M, Han D K, Ko H. Joint patch clustering-based dictionary learning for multimodal image fusion[M]. Elsevier Science

Publishers B. V. 2016.

[34] Yang B, Li S. Multifocus Image Fusion and Restoration With Sparse Representation[J]. IEEE Transactions on Instrumentation & Measurement, 2010, 59(4):884-892.

[35] Qiang Zhang, Bao-long Guo. Multifocus image fusion using the nonsubsampling contourlet transform[J]. Signal Processing, 2009, 89(7):1334-1346.

[36] Shi W, Zhu C Q, Tian Y, et al. Wavelet-based image fusion and quality assessment[J]. International Journal of Applied Earth Observations & Geoinformation, 2005, 6(3):241-251.

[37] Qu G, Zhang D, Yan P. Information measure for performance of image fusion[J]. Electronics Letters, 2002, 38(7):313-315.

[38] Xydeas, C.S, Petrovic, V. Objective image fusion performance measure[J]. Military Technical Courier, 2000, 56(2):181-193.

第一作者简介:



王丽芳, 1977年生, 女, 副教授, 博士, CCF会员(48979M), 主要研究方向: 机器视觉、大数据处理、医学图像处理, E-mail: wsm2004@nuc.edu.cn

通信作者:



窦杰亮, 1995年生, 男, 中北大学大数据学院研究生, 主要研究方向为医学图像融合与机器学习。E-mail: liangdjsha@163.com

其他作者简介:

秦品乐, 男, 副教授, 主要研究方向: 机器视觉、大数据处理、三维重建。E-mail: QPL@nuc.edu.cn

蔺素珍, 女, 教授, 主要研究方向: 图像处理、文物虚拟修复。E-mail: lsz@nuc.edu.cn

高媛, 女, 副教授, 主要研究方向: 机器视觉、大数据处理、三维重建。E-mail: yuan_g@126.com

张程程, 女, 中北大学大数据学院研究生, 主要研究方向为医学图像配准与机器学习。E-mail: 1738490350@qq.com