

基于在线字典学习的自适应医学图像融合算法

殷鑫华¹,戴文战²,李俊峰¹

(1. 浙江理工大学机械与自动控制学院,杭州 310018;2. 浙江工商大学信息与电子工程学院,杭州 310018)

摘 要: 针对医学图像复杂多样的特点,提出一种基于在线字典学习的自适应医学图像融合算法。该算法首先利用在线字典学习理论训练源图像的过完备字典;然后利用正交匹配追踪算法对源图像进行稀疏分解得到稀疏编码,根据源图像之间稀疏编码的能量差异程度和梯度差异程度自适应调整融合准则,若能量差异程度大于梯度差异程度,则根据能量取大准则融合稀疏编码,反之,根据梯度取大准则融合稀疏编码;最后将融合后的稀疏编码与过完备字典进行重构得到融合图像。实验结果表明:与多尺度几何分析、K 奇异值分解等图像融合算法比较,该算法融合的图像客观评价指标信息熵、边缘评价因子均有所提高,主观上纹理清晰、对比度高,能够很好地保留源图像的边缘信息。

关键词: 医学图像融合;在线字典学习;正交匹配追踪;梯度差异;能量差异

中图分类号: TP391.41

文献标志码: A

文章编号: 1673-3851(2017)02-0246-09

0 引言

随着医学成像技术的飞速发展,医学影像学已经从一种临床辅助检查手段逐渐发展为临床诊断疾病的主要方法。然而不同成像原理呈现的医学图像存在一定的局限性,单一模态医学图像的诊断效果并不理想。例如,电子计算机断层扫描(computed tomography,CT)图像具有较高的空间密度分辨率和良好的几何特性,可以清晰地显示人体骨骼组织,但由于人体软组织密度差别小,对 X 射线吸收程度相接近,导致它对人体软组织的显示效果欠佳。核磁共振成像(magnetic resonance imaging,MRI)图像能够清晰地显示软组织结构,有利于医生确定病灶范围,但它对人体骨骼的显示效果不尽如人意。单光子发射计算机断层成像(single-photon emission computed tomography,SPECT)图像可呈现出人体不同组织活性强度的差异,反映人体代谢功能^[1]。因此,将不同模态的医学图像进行融合,有利于病灶精确定位和观察疾病发展情况,为医生诊

断疾病提供直观可靠的依据^[2]。

近年来,多尺度几何分析应用于医学图像融合领域的研究越来越广泛,常见的多尺度几何分析主要有提升小波变换^[3]、Contourlet 变换^[4]、非下采样剪切波变换^[5]等。杨艳春等^[6]提出基于提升小波变换与自适应 PCNN 的医学图像融合算法,提升小波变换属于小波变换的一种改进,其改进之处主要是降低小波变换的运算复杂度,但是对于图像结构中的边缘、曲线等二维信息并不是最稀疏表达。Xing 等^[7]提出基于非下采样剪切波变换(non-subsampled shearlet transform,NSST)的医学图像融合算法,从图像各个方向、各个尺度上进行分解,且无方向数限制,对图像边缘具有良好的稀疏表达能力,有效克服了提升小波变换的不足之处,但是该方法在实时性方面不佳,图像在 NSST 分解过程比较费时,而且医学图像存在复杂多样性特点,例如 MRI 图像中脂肪组织呈白色,脑脊髓呈灰白色,对于图像区域纹理稀疏表示方面 NSST 有所欠佳。严春满等^[8]提出自适应字典学习的多聚焦图像融合

收稿日期:2016-08-03 网络出版日期:2017-01-03

基金项目:国家自然科学基金项目(61374022)

作者简介:殷鑫华(1993-),男,浙江丽水人,硕士研究生,主要从事图像融合方面的研究。

通信作者:戴文战,E-mail:dwz@zisu.edu.cn

算法,利用 K 奇异值分解(k-singular value decomposition,K-SVD)^[9]算法训练过完备字典,由正交匹配追踪(orthogonal matching pursuit,OMP)^[10]算法对信号稀疏分解,根据模值取大准则融合稀疏编码。该算法的融合准则未考虑源图像之间的差异性,容易导致融合图像能量过高,在训练过完备字典环节比较耗时,主要原因是 K-SVD 训练字典过程中需访问整个样品集合。吴双等^[11]提出利用在线字典学习(online dictionary learning,ODL)^[12]算法和最小角回归算法^[13]对图像进行稀疏分解,根据稀疏编码向量的 1 范数取大准则融合稀疏编码,在图像分解环节中算法效率明显提升,但是过于单一的融合规则导致图像纹理丢失,在医学图像中通常存在灰暗交接的纹理区域,若根据稀疏编码 1 范数取大规则就容易忽略图像中灰度较低的纹理。

针对上述算法存在的不足,本文提出一种利用 ODL 算法和 OMP 算法对图像稀疏表示并结合自适应融合规则的医学图像融合算法。ODL 算法是训练过完备字典的一种方法,图像的稀疏表示是由过完备字典中若干个原子经过线性组合而成。相比多尺度几何分析,ODL 算法能够很好地提取图像边缘和区域纹理特征,对图像具有较好的稀疏表达能力,在每次字典迭代更新时只从样本集合中随机选取一个样本,迭代效率高于 K-SVD 算法,在面对大批量信号数据时,ODL 算法的优势就凸显出来。分析源图像之间稀疏编码的能量差异程度和梯度差异程度,提出一种自适应的融合规则。若能量差异程度高于梯度差异程度,说明相同位置区域的亮度差异明显,为保留源图像的显著能量特征,应采用能量取大准则融合稀疏编码。同理,若梯度差异程度高于能量差异程度,应该采用梯度取大准则融合稀疏编码,保留源图像的显著纹理特征,包括图像中重要的低灰度纹理。

1 在线字典学习算法

传统的字典构造方法主要有两种:解析方法和学习方法。解析方法通常由数学函数计算得到过完备字典,如离散余弦变换(discrete cosine transform,DCT)字典、高斯随机字典等,得到的字典往往比较单一,不能与医学图像的复杂多样结构最优匹配。学习方法是通过对图像信号训练过完备字典,如 K-SVD 算法、ODL 算法等,得到的字典形态丰富,能很好的匹配医学图像结构^[14]。根据信号的

处理方式,学习方法又分为批处理方式和在线学习方式,常见的学习方法如最优字典(method of optimal directions,MOD)算法、K-SVD 算法等都是二阶批处理过程,在每次迭代过程中需访问整个训练集合用以寻找在某种约束条件下最小化的代价函数,虽然二阶批处理过程比一阶梯度下降法处理速度要快,但是对于大量的数据而言,其处理时间比较长^[11]。Mairal 等^[12]在 2010 年提出在线字典学习算法,该算法每次迭代运算只从样本集合中选取一个样本进行训练,并非取所有的训练集合,因此它在处理数据效率上远高于批处理方式的学习方法。

设样本集合 $\mathbf{X} = \{x_i\}_1^N \in \mathbf{R}^{M \times N}$,为防止字典 \mathbf{D} 中原子数值过大从而导致稀疏编码的数值过小,对字典 \mathbf{D} 加以约束条件: $\|d_i\|_2 \leq 1$,在线字典学习算法模型为:

$$\min_{\mathbf{D} \in \mathbf{C}, \alpha \in \mathbf{R}^{K \times N}} \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x_i - \mathbf{D}\alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \right) \quad (1)$$

其中: α_i 为样本 x_i 在字典 \mathbf{D} 下的稀疏编码; λ 为正则化参数; N 为样本总数。

在线字典学习算法首先需设定初始化字典 \mathbf{D}_0 和迭代次数停止 T ,从样本集合 \mathbf{X} 中随机选取样本 x_i ,利用 OMP 算法计算样本 x_i 在字典 \mathbf{D}_0 下的稀疏表示系数 α 。再将 α 代入公式(2)中,并按列更新字典 \mathbf{D} ,得到更新的字典 \mathbf{D}_t :

$$\mathbf{D}_t = \arg \min_{\mathbf{D} \in \mathbf{C}} \frac{1}{t} \sum_{i=1}^t \frac{1}{2} \|x_i - \mathbf{D}_{t-1}\alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \quad (2)$$

其中: t 为迭代次数; \mathbf{D}_{t-1} 为更新前的字典; λ 为正则化参数; x_i 为样本; α_i 为稀疏编码。再从样本集合中随机选取另一个样本,重复按公式(2)迭代上述过程,直至满足迭代次数 T 停止。

2 图像的稀疏分解

正交匹配追踪(orthogonal matching pursuit,OMP)算法是匹配追踪(matching pursuit,MP)算法的一种改进,并广泛应用于信号稀疏分解和重构领域。该算法是一种贪婪追踪算法,其主要思想是从过完备字典中选择与残差信号最匹配的原子,从残差信号中除去最匹配原子相关部分,更新残差并反复迭代直至满足迭代次数或满足残差小于设定的阈值,初始残差为待分解信号^[10]。与 MP 算法不同之处在于,OMP 算法每次从残差信号中除去最匹配原

子相关部分时,对原子支撑集进行正交化以保证迭代的最优性,因此本文选择 OMP 算法对图像进行稀疏分解。

基于 ODL 算法和 OMP 算法相结合图像稀疏分解流程如图 1 所示。首先将 $M \times M$ 大小的滑动窗,以步长为 Z ,按照列优先方式对图像 1 进行分块处理,得到的图像块排成列向量 \mathbf{x}_i ,将所有列向量构成矩阵 $\mathbf{I}_1 = [\mathbf{x}_{11}, \mathbf{x}_{12}, \dots, \mathbf{x}_{1N}]$ 。同理,对图像 2 亦按上述进行

相同操作,构成矩阵 $\mathbf{I}_2 = [\mathbf{x}_{21}, \mathbf{x}_{22}, \dots, \mathbf{x}_{2N}]$ 。为提高字典训练效率,先将矩阵 \mathbf{I}_1 作为训练样本进行字典训练,初始字典为 \mathbf{D}_0 ,通过 ODL 算法训练后得到字典 \mathbf{D}_1 ,再将矩阵 \mathbf{I}_2 作为训练样本,字典 \mathbf{D}_1 作为初始字典,通过 ODL 算法训练后得到字典 \mathbf{D}_2 。将矩阵 \mathbf{I}_1 和矩阵 \mathbf{I}_2 构成联合矩阵 \mathbf{I} ,设定稀疏误差为 ϵ ,利用 OMP 算法对联合矩阵 \mathbf{I} 进行稀疏分解,得到稀疏编码矩阵 $\boldsymbol{\alpha} = [\boldsymbol{\alpha}_{11}, \boldsymbol{\alpha}_{12}, \dots, \boldsymbol{\alpha}_{1N}, \boldsymbol{\alpha}_{21}, \boldsymbol{\alpha}_{22}, \dots, \boldsymbol{\alpha}_{2N}]$ 。

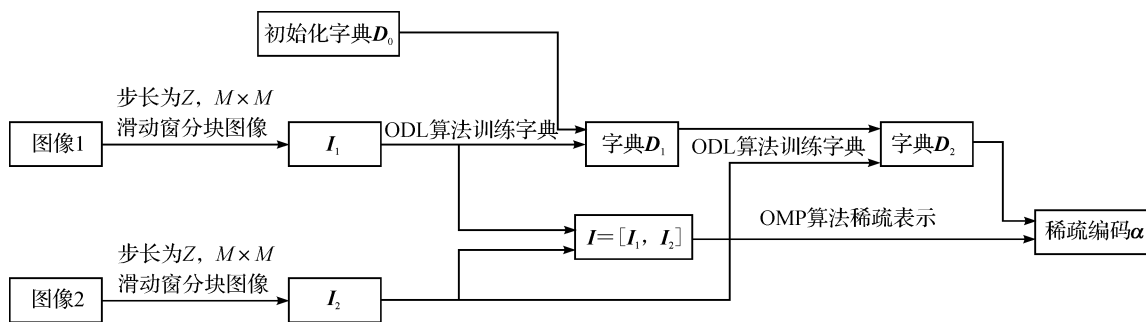


图 1 图像稀疏分解流程

3 图像的自适应融合

融合准则的设计在图像融合中是非常关键的一步,特别是对于医学图像融合,既要满足信息之间的互补性,又要满足人类视觉特性。图像的稀疏分解主要是从过完备字典中选择一部分原子线性组合来逼近源图像,稀疏编码由该部分原子线性组合的系数构成向量,因此稀疏编码中往往包含大量的图像特征信息,在融合过程中有必要对稀疏编码进行特征分析。

稀疏编码的梯度是将稀疏编码与过完备字典相结合重构后图像块的梯度特征,能有效反映医学图像块中软组织区域的纹理细节和边缘变化程度,如式(3)、式(4)所示。稀疏编码的能量同样是将编码与字典相结合重构后图像块的能量特征,能有效反映区域内总体信息含量,如式(5)所示。单一的选择一种准则容易造成信息融合不完整,故本文以稀疏编码梯度和能量的变化程度为依据自适应调整融合准则。

稀疏编码的重构矩阵为:

$$\mathbf{s}_{ij} = [\mathbf{D}\boldsymbol{\alpha}_{ij}]_{M \times M} \quad (3)$$

其中: \mathbf{D} 为已训练的过完备字典; $\boldsymbol{\alpha}_{ij}$ 为稀疏编码; M 为图像块尺寸; \mathbf{s}_{ij} 为稀疏编码重构后的灰度值矩阵, i, j 表示稀疏编码的下标。

稀疏编码的梯度公式为:

$$g_{ij} = \frac{1}{M \times M} \sum_{m=1}^M \sum_{n=1}^M ((s(m, n)_{ij} - s(m+1, n)_{ij})^2 + (s(m, n)_{ij} - s(m, n+1)_{ij})^2)^{\frac{1}{2}} \quad (4)$$

其中: $s(m, n)_{ij}$ 表示灰度值矩阵在 (m, n) 处的值; g_{ij} 表示稀疏编码的梯度值。

稀疏编码的能量公式为:

$$e_{ij} = \frac{1}{M \times M} \sum_{m=1}^M \sum_{n=1}^M s(m, n)_{ij}^2 \quad (5)$$

其中: e_{ij} 表示稀疏编码的能量值。

对于一组待融合的稀疏编码 $(\boldsymbol{\alpha}_{1j}, \boldsymbol{\alpha}_{2j})$, 根据式(3)分别重构其灰度值矩阵 $(\mathbf{s}_{1j}, \mathbf{s}_{2j})$, 再根据式(4)式(5)得到该组稀疏编码的梯度值 (g_{1j}, g_{2j}) 和能量值 (e_{1j}, e_{2j}) 。为量化稀疏编码的梯度变化程度和能量变化程度,本文引入梯度权重 λ_j^g 和能量权重 λ_j^e , 如式(6)、式(7)所示。

$$\lambda_j^g = \frac{|g_{1j} - g_{2j}|}{g_{1j} + g_{2j} + C_g} \quad (6)$$

其中: g_{1j}, g_{2j} 分别为一组待融合稀疏编码 $(\boldsymbol{\alpha}_{1j}, \boldsymbol{\alpha}_{2j})$ 的梯度值; C_g 为防错系数,避免分母为零。


$$\lambda_j^e = \frac{|e_{1j} - e_{2j}|}{e_{1j} + e_{2j} + C_e} \quad (7)$$

其中: e_{1j}, e_{2j} 分别为一组待融合稀疏编码 $(\boldsymbol{\alpha}_{1j}, \boldsymbol{\alpha}_{2j})$ 的能量值; C_e 为防错系数,避免分母为零。

梯度权重 λ_j^g 主要反映待融合图像在相同区域内梯度的差异程度, λ_j^g 越大表明两图像在相同区域内纹理差异也就越大。例如,图 2(b) 中的黑框区域为病变组织,将该区域与图 2(a) 同一位置相比较,清晰发现两处区域灰度能量差异不明显,但是图 2(b) 区域梯度明显高于图 2(a) 对应区域,说明 $\lambda_j^g > \lambda_j^e$, 故应该选择梯度取大的融合准则,选取图

2(b) 中病变组织区域作为融合图像的主要成分。

能量权重 λ_j^e 主要反映待融合图像在相同区域内能量的差异程度, λ_j^e 越大表明两图像在相同区域内能量差异也就越大。例如, 图 2(a) 中的黑框区域为骨骼区域, 将该区域与图 2(b) 同一位置相比较, 发现两区域的能量差异程度大于梯度差异程度, 即 $\lambda_j^e > \lambda_j^g$, 故应该选择能量取大的融合准则, 选取图 2(a) 中骨骼区域作为融合图像的主要成分。



(a) 脑部CT图像

(b) 脑部MRI图像

图 2 人体脑部 CT 图像与 MRI 图像

基于在线字典学习的自适应医学图像融合算法实施步骤如下:

步骤 1 根据图 1 所述对图像稀疏分解, 将稀疏编码 $\alpha = [\alpha_{11}, \alpha_{12} \dots \alpha_{1N}, \alpha_{21}, \alpha_{22} \dots \alpha_{2N}]$ 拆分, 得到图像 1 的稀疏编码 $\alpha_1 = [\alpha_{11}, \alpha_{12}, \dots, \alpha_{1N}]$, 图像 2 的稀疏编码 $\alpha_2 = [\alpha_{21}, \alpha_{22}, \dots, \alpha_{2N}]$, 设融合后的稀疏编码为 $\beta = [\beta_{11}, \beta_{12}, \dots, \beta_{1N}]$ 。利用函数 $L(\alpha_j)$ 计算稀疏编码 α_1, α_2 中各列的稀疏度, 即向量中非零系数的数量。

步骤 2 当待融合稀疏编码的稀疏度相差两倍以上时, 根据式(8) 稀疏度取大原则, 初步融合稀疏编码。

$$\beta_j = \begin{cases} \alpha_{1j}, L(\alpha_{1j}) > 2L(\alpha_{2j}) \\ \alpha_{2j}, L(\alpha_{2j}) > 2L(\alpha_{1j}) \\ f(\alpha_{1j}, \alpha_{2j}), \text{else} \end{cases} \quad j = 1, 2, \dots, N \quad (8)$$

其中: $L(\alpha_{ij})$ 表示稀疏编码 α_{ij} 的稀疏度; $f(\alpha_{1j}, \alpha_{2j})$ 表示 α_{1j}, α_{2j} 的融合函数。

步骤 3 当求解 $f(\alpha_{1j}, \alpha_{2j})$ 时, 根据式(3) 将稀疏编码与过完备字典重构大小为 $M \times M$ 的矩阵 s_{1j}, s_{2j} 。

步骤 4 根据式(5) 分别计算矩阵 s_{1j}, s_{2j} 的能量为 e_{1j}, e_{2j} ; 根据式(4) 分别计算矩阵 s_{1j}, s_{2j} 的梯度为 g_{1j}, g_{2j} 。

步骤 5 根据式(6)、式(7) 计算稀疏编码的梯度权重 λ_j^g 和能量权重 λ_j^e 。稀疏编码融合函数 $f(\alpha_{1j}, \alpha_{2j})$ 表达式为:

$$f(\alpha_{1j}, \alpha_{2j}) = \begin{cases} \arg\max(g_{1j}(\alpha_{1j}), g_{2j}(\alpha_{2j})), \lambda_j^g > \lambda_j^e \\ \arg\max(e_{1j}(\alpha_{1j}), e_{2j}(\alpha_{2j})), \lambda_j^e > \lambda_j^g \end{cases} \quad (9)$$

其中: $g_{1j}(\alpha_{1j})$ 表示稀疏编码 α_{1j} 的梯度值; $g_{2j}(\alpha_{2j})$ 表示稀疏编码 α_{2j} 的梯度值; $e_{1j}(\alpha_{1j})$ 表示稀疏编码 α_{1j} 的能量值; $e_{2j}(\alpha_{2j})$ 表示稀疏编码 α_{2j} 的能量值;

步骤 6 根据式(8) 得到融合后的稀疏编码 $\beta = [\beta_{11}, \beta_{12}, \dots, \beta_{1N}]$, 结合过完备字典, 根据式(3) 重构灰度矩阵, 并将各个灰度矩阵放到对应位置, 对重叠区域取均值, 最终得到融合图像。

4 实验结果与分析

4.1 融合算法对比实验

为验证本文算法的可比性, 所有实验均以 Window 7 操作系统为平台, 使用 Matlab R2012a 进行仿真。实验选取 3 组经配准的医学图像作为源图像, 大小为 256×256 像素, 颜色深度为 8 位灰度, 如图 3—图 5 所示。图 3(a) — (b) 为急性脑卒中患者的脑部 CT 图像和 MRI 图像; 图 4(a) — (b) 为正常人体脑部 CT 图像和 MRI 图像; 图 5(a) — (b) 为多发性脑梗塞患者的脑部 MR-T1 图像和 MR-T2 图像;

在图像稀疏分解过程中, 过完备字典大小、滑动窗大小直接影响最终融合图像的质量。过完备字典是一种非正交且具有冗余性的矩阵, 其原子数量与原子长度的比称为冗余度(即矩阵的列数与行数的比)。通过提高冗余度可增强字典对信号的稀疏分解能力, 但是冗余度过高将会增加字典的训练时间, 提高算法复杂度, 因此冗余度通常设为 4。滑动窗中像素数量等于原子的长度, 因此滑动窗的大小直接影响字典大小, 滑动窗主要用于选取图像的基元作为信号 x , 若滑动窗选取过大则无法作为基元反应图像基础特征, 若滑动窗过小则将丢失图像中的基础纹理特征。Yang 等^[15] 提出当滑动窗大小为 8×8 , 步长 1 时融合图像效果最佳。因此本文算法具体参数设置为: 滑动窗大小同样设定为 8×8 , 步长为 1, 冗余度设为 4, 则过完备字典大小为 64×256 , 初始字典为高斯随机矩阵, 字典训练迭代次数为 1000 次, 稀疏编码的稀疏误差为 0.01, 防错系数 C_g, C_e 均为 0.01。

为了检测本文算法的有效性, 选用 5 种已有算法作为实验对比。图 3(c)、图 4(c)、图 5(c) 为应用 Xing 等^[7] 提出的基于 NSST 变换分解图像, 低频子带根据区域能量加权融合系数, 高频子带根据平均梯度和区域能量加权融合系数, 从而得到的融合图像, 实验中 NSST 分解层数设定为 3 层, 每一层方向

数分别为 6、10、18;图 3(d)、图 4(d)、图 5(d)为应用李俊峰等^[3]提出的基于提升小波变换分解图像,对低频子带采用区域能量加权规则,对不同噪声的高频子带采用计盒分维法和区域梯度的融合规则的融合图像,实验中提升小波分解层数为 1,即得到 1 组低频系数和 3 组不同方向的高频系数;图 3(e)、图 4(e)、图 5(e)为应用杨艳春等^[6]提出的基于提升小波变换和自适应 PCNN 医学图像融合方法的融合图像,实验中 PCNN 参数设置为:链接输入振幅增益为 1,动态阈值振幅增益为 25,时间衰减常数为

0.2,最大迭代次数为 200;图 3(f)、图 4(f)、图 5(f)为应用吴双等^[11]提出的利用在线字典学习算法和最小角回归算法对图像稀疏分解,根据稀疏编码模值取大规则算法的融合图像,其参数设置与本文算法参数一致;图 3(g)、图 4(g)、图 5(g)为应用严春满等^[8]提出利用 K-SVD 算法和 OMP 算法对图像稀疏分解,并根据稀疏编码模值取大规则算法的融合图像,其参数设置亦与本文算法参数一致;图 3(h)、图 4(h)、图 5(h)为应用本文算法得到的融合图像。




图 3 急性脑卒中患者的脑部 CT/MRI 图像的融合结果




图 4 正常人体脑部 CT/MRI 图像的融合结果




图 5 多发性脑梗塞患者的脑部 MR-T1/ MR-T2 图像的融合结果

从图 3—图 5 可以清晰地看出,利用本文融合算法得到的图像在边缘轮廓方面比较清晰,图像纹理与源图像保持基本一致,说明在融合过程中图像信息丢失较少,图像整体对比度也有所提高。在图 3 中,本文算法得到的图 3(h)不仅保留图 3(b)中绝大多数的脑组织纹理,而且在其骨骼区域中依然可见脑组织外轮廓。在图 4(c)的骨骼区域灰度较小,对比度不明显,图 4(d)和图 4(g)在骨骼区域附近出现大面积的黑色区域,导致软组织区域的纹理被覆盖,图像信息丢失严重。图 4(e)下方软组织区域比较模糊,图 4(f)纹理清晰,对比度高,但是其右下角骨骼区域与软组织区域区分不明显,而图 4(h)几乎保留源图像中所有的信息,图像清晰,对比度高,而且骨骼区域与组织区域区分明显,存在明显轮廓。在图 5(c)的中间组织区域较为模糊,图 5(d)中脑部纹理丢失严重,图 5(e)整体灰度偏小,对比度低,图 5(f)和图 5(g)存在噪声导致图像纹理不够清晰。

为进一步比较图像的质量,通过放大图 3 局部区域,如图 6 所示。从图 6 中可以清晰发现六种算法得到的融合图像存在一定差别,图 6(a)、图 6(d)、图 6(e)虽然能清晰观察到病变组织,但是其脑部组织纹理丢失严重,图像过于平滑,无法较好的保留源图像纹理特征。图 6(b)的纹理虽然丰富,对比源图像发现其存在较多虚假纹理,而且病变组

织灰度较暗。图 6(c)可以清晰显示脑部组织纹理和病变组织,但是图像中脑骨部分被明显削弱。图 6(f)为利用本文算法得到的融合图像,其脑部组织纹理清晰,病变组织灰度高,很大程度上保留源图像信息,而且在图像脑骨部分中可以清晰观察到脑部软组织的外轮廓,因此可以为病变组织定位提供较大帮助。




图 6 急性脑卒中患者脑部 CT/MRI 医学图像融合结果的局部区域

为了定量比较融合结果图 3—图 5 的质量,采用信息熵、标准差、空间频率、边缘评价因子^[16]、算法运行时间进行定量分析,具体图像质量数据见表 1—表 3。

表1 图3急性脑卒中患者脑部CT/MRI医学图像融合的质量评价

评价指标	图3(c)	图3(d)	图3(e)	图3(f)	图3(g)	图3(h)
信息熵	5.906	5.374	4.961	5.421	5.587	6.281
标准差	80.889	86.122	63.542	85.394	86.336	82.814
空间频率	32.151	33.126	20.086	26.518	30.428	27.571
边缘评价因子	0.534	0.448	0.415	0.461	0.517	0.624
运行时间/s	77.120	31.250	149.510	41.660	95.370	51.340

表2 图4正常人体脑部CT/MRI医学图像融合的质量评价

评价指标	图4(c)	图4(d)	图4(e)	图4(f)	图4(g)	图4(h)
信息熵	6.512	6.145	5.142	6.751	6.495	6.731
标准差	59.314	64.512	50.861	60.784	59.458	63.314
空间频率	18.401	18.483	14.254	16.468	17.942	18.819
边缘评价因子	0.760	0.644	0.547	0.717	0.776	0.792
运行时间/s	76.830	31.230	150.420	42.350	96.540	48.140

表3 图5多发性脑梗塞患者脑部MR-T1/MR-T2医学图像融合结果的质量评价

评价指标	图5(c)	图5(d)	图5(e)	图5(f)	图5(g)	图5(h)
信息熵	6.128	5.347	4.431	5.446	5.117	6.317
标准差	71.310	75.012	62.919	75.109	74.426	75.294
空间频率	34.129	30.105	21.748	26.511	31.758	33.571
边缘评价因子	0.575	0.531	0.488	0.571	0.634	0.659
运行时间/s	78.480	33.852	151.370	41.160	96.480	52.880

从表1—表3同样可以看出:应用本文提出的融合算法得到的医学图像,其信息熵、空间频率、边缘评价因子都有所提高,表明融合图像保留了源图像大部分信息,图像纹理轮廓清晰,灰度变化剧烈,对比度较高,具有更好的视觉效果。特别是边缘信息评价因子均大于其余五种算法,说明本文提出的算法对应的融合图像与源图像之间的边缘信息传递情况最好,最大程度上保留源图像的边缘信息。

4.2 字典训练效率对比实验

为验证 ODL 算法的高效性,实验选取一组经配准的人体甲状腺结节 B 超图像和 SPECT 图像作为源图像,大小为 256×256 像素,颜色深度为 8 位灰度,如图 7(a) — (b) 所示。实验采用控制变量法验证 ODL 算法的高效性,即 MOD 算法、K-SVD 算法、ODL 算法分别对图 7(a) — (b) 图像融合,实验参数均一致设为:滑动窗大小为 8×8 ,步长为 1,过完备字典大小为 64×256 ,初始化字典为高斯随机矩阵,字典训练迭代次数为 1000 次,稀疏编码的稀疏误差为 0.01,防错系数 C_g 、 C_e 均为 0.01。稀疏分解算法均采用 OMP 算法,融合规则均采用本文提出的自适应融合规则。人体甲状腺结节 B 超/SPECT 图像融合结果结果如图 7 所示,图像融合结果的质量评价见表 4。




图7 人体甲状腺结节B超/SPECT图像融合结果

表4 图7人体甲状腺结节B超/SPECT图像融合结果的质量评价

评价指标	图7(c)	图7(d)	图7(e)
信息熵	4.612	5.614	5.601
标准差	54.873	53.221	53.112
空间频率	7.318	11.524	12.387
边缘评价因子	0.3523	0.7036	0.7127
运行时间/s	134.214	96.425	47.691

从图7可以看出:利用MOD算法得到的融合图像纹理较模糊,存在细节丢失。利用K-SVD算法得到的融合图像与ODL算法融合图像相接近,并且两者纹理清晰,较大程度地保留SPECT图像中的信息。从表4同样可以看出,K-SVD算法和ODL算法在相同条件下得到的融合图像十分接近,然而ODL算法所用时间为K-SVD算法所用时间的49%。因此利用ODL算法可以加快字典学习的效率,从而减少图像融合算法整体所需时间。

5 结 语

医学图像融合是将多模态医学图像之间的互补信息体现在同一幅图像中,使得融合后的图像拥有更加丰富的信息。结合医学图像复杂性特点本文提出基于在线字典学习的自适应医学图像融合算法,利用在线字典学习算法和OMP算法对图像进行稀疏分解,使得图像的边缘纹理得以很好地保存,根据稀疏编码的能量和梯度特征,自适应调整融合规则,使得融合算法适用于各种复杂的医学图像。实验结果表明:利用本文算法得到的融合图像具有丰富的信息量,主观上纹理清晰,对比度高,较好的保留源图像边缘信息,图像客观评价指标信息熵平均提高14.3%,边缘信息评价因子平均提高21.6%。本文算法虽然实时性方面有所提高,但是算法整体时间偏长,在后续的工作中,将简化算法复杂度,进一步提高算法的性能。

参考文献:

- [1] 王远军,姜博宇,靳珍怡,等. 基于小波变换的医学图像融合方法综述[J]. 中国医学物理学杂志,2013,30(6): 4530-4536.
- [2] JAMES A P, DASARATHY B V. Medical image fusion:a survey of the state of the art[J]. Information Fusion,2014,19(3):4-19.
- [3] 李俊峰,姜晓丽,戴文战. 基于提升小波变换的医学图像融合[J]. 中国图象图形学报,2014,19(11):1639-1648.
- [4] YANG S Y, WANG M, JIAO L C, et al. Image fusion based on a new contourlet packet [J]. Information Fusion,2010,11(2):78-84.
- [5] MIAO Q G, SHI C, XU P F, et al. A novel algorithm of image fusion using shearlets [J]. Optics Communications,2011,284(6):1540-1547.
- [6] 杨艳春,党建武,王阳萍. 基于提升小波变换与自适应PCNN的医学图像融合方法[J]. 计算机辅助设计与图形学学报,2012,24(4):494-499.
- [7] XING X, CAO F, SHANG W. Multi-modal medical image fusion based on non-subsampled shearlet transform [J]. International Journal of Signal Processing, Image Processing and Pattern Recognition, 2015,8(2):41-48.
- [8] 严春满,郭宝龙,易盟. 自适应字典学习的多聚焦图像融合[J]. 中国图象图形学报,2012,17(9):1144-1149.
- [9] AHARON M, ELAD M, BRUCKSTEIN A M. The K-SVD: an algorithm for designing of overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.
- [10] TROPP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit [J]. IEEE Transaction on Information Theory, 2007, 53(12):4655-4666.
- [11] 吴双,邱天爽,高珊. 基于在线字典学习的医学图像特征提取与融合[J]. 中国生物医学工程学报,2014,33(3):283-288.
- [12] MAIRAL J, BACH F, PONCE J, et al. Online learning for matrix factorization and sparse coding[J]. Journal of machine learning research, 2010, 11(1):19-60.
- [13] 刘建伟,崔立鹏,罗雄麟. 结构稀疏模型及其算法研究进展[J]. 计算机科学,2016,43(6A):1-16.
- [14] 练秋生,石保顺,陈书贞. 字典学习模型、算法及其应用研究进展[J]. 自动化学报,2015,41(2):240-260.
- [15] YANG B, LI S. Multifocus image fusion and restoration with sparse representation [J]. IEEE Transactions on Instrumentation and Measurement (S0018-9456), 2010, 59(4):884-892.
- [16] 王林艳,陶玲,王惠南. CT与MRI图像融合的评价方法研究[J]. 生物医学工程研究,2006,43(4):247-250.

Adaptive Medical Image Fusion Algorithm Based on Online Dictionary Learning

YIN Xinhua¹, DAI Wenzhan², LI Junfeng¹

(1. Faculty of Mechanical Engineering & Automation, Zhejiang Sci-Tech University,
Hangzhou 310018, China; 2. School of Information & Electronic Engineering,
Zhejiang Gongshang University, Hangzhou 310018, China)

Abstract: According to characteristics of complexity and diversity of medical image, the paper proposed an adaptive medical image fusion algorithm based on online dictionary learning. The algorithm first applies the theory of online dictionary learning to train over complete dictionary of source images, and then adopts orthogonal matching pursuit algorithm for sparse decomposition of source images to gain sparse codes. Besides, it adjusts the fusion rules adaptively according to the degree of energy difference and gradient difference of sparse codes between source images. If the degree of energy difference is more than that of gradient difference, the sparse codes are fused on the basis of the rules of maximum energy. On the contrary, the sparse codes are fused according to the rule of maximum gradient. Finally, the fused sparse codes and over complete dictionary are reconstructed to obtain fused images. The experiment result shows that compared with multiscale geometric analysis, k-singular value decomposition and other image fusion algorithms, objective evaluation indexes of images fused by this algorithm-information entropy and edge evaluation factor improve. Subjectively, the texture of the fused image is clearer, and the contrast ratio is higher. In addition, this algorithm can well preserve edge information of source images effectively.

Key words: medical image fusion; online dictionary learning; orthogonal matching pursuit; gradient difference; energy difference

(责任编辑: 康 锋)