DOI: 10.13718/j. cnki. xdzk. 2019.04.019

峰值皮层模型耦合 Weber 局部 描述符的图像融合算法[®]

黄建荣1, 印鉴2

1. 珠海城市职业技术学院 电子信息工程学院, 广东 珠海 519090;

2. 中山大学 数据科学与计算机学院,广州 510006

摘要:为了解决当前医学图像融合(Medical Image Fusion, MIF)方法易产生伪影,丢失部分图像细节,以及对比度 较低的问题,本文提出了一种新的峰值皮层模型(Spiking Cortical Model, SCM)耦合 WLD (Weber Local Descriptor)的图像融合算法. 首先,通过 SCM 对源图像进行分解,获得不同的二进制脉冲图像;其次,利用输出脉冲图像 生成点火映射图像,并构建了 SCM 脉冲输出点火数量的融合准则;然后,结合 SCM 脉冲输出的信息熵与点火映射 图像的 Weber 局部描述这二者的相似性来计算融合权重,完成图像融合. 通过实验表明:与当前常用的 MIF 算法 相比,本文所提算法具有更好的视觉效果,其融合图像质量与对比度更高,同时,在客观评价标准 IE,MI,AG, SSIM 方面也具有更大的优势,有效地保持了源图像的有效信息.

关键词:医学图像融合;Weber局部描述;峰值皮层模型;点火映射;信息熵;融合权重
 中图分类号:TP391
 文献标志码:A
 文章编号:1673-9868(2019)04-0130-09

不同成像机制得到的医学图像具有不一样的影像特性,例如 CT 用来显示非金属植入物和骨骼致密结构,并且在图像的显示过程中失真相对较少^[1];MRI 可以更好地观察病理软组织;而 PET 可以测量体内某一个部位的代谢活动量.为了对疾病进行全面、准确的诊断与治疗,单一种类的图像很难提供足够的判断依据,需要结合多种图像综合起来分析.因此,将不同类型的医学图像进行融合,可以获得更全面、更准确的输出图像,为疾病诊断与精确治疗等方面提供参考.例如 MRI-US 前列腺穿刺活检,PET-CT 肺癌检测, MRI-PET 脑疾病检测,CT-SPECT 乳腺癌检测^[2].MIF 作为一种模态医学影像的处理技术,可将不同的信息进行有效整合.结合各图像的互补信息,显示更清晰的细节.因此,如何获得细节丰富、信息全面的融合医学图像成为当前迫切需要解决的问题.

随着计算机技术的发展,学者们提出了多种 MIF 算法,例如基于金字塔分解(Pyramid Decomposition, PD)的算法、基于小波变换(Wavelet Transform, WT)的算法、基于 Curvelet 变换与变换的算法、基 于 PCNN^[3]等融合技术的算法.但 PD 技术存在冗余性^[4],其分解层间的关联性降低了其效果.WT 具有 良好的空频局域性^[5],并且可通过伸缩平移对图像进行多尺度分解.WT 与 PD 不同之处是,WT 具有方 向性,且不含冗余信息.所以,基于 WT 的融合算法具有优异的融合性能.但是,2 维 WT 只能得到水 平、垂直、对角线 3 种子带,导致其获取的方向信息不足,无法准确表示某些细节信息.近年来,有学者 将 Curvelet 变换与 Contourlet 变换应用于图像融合^[6-7]中,两者均具有多尺度性、多方向性,取得了较好 的融合性能.但是 Contourlet 变换采用了分解,缺乏平移不变性,易出现伪 Gibbs 问题.另外,神经网络在 MIF 方面得到了应用.如基于 PCNN 的 MIF 技术^[8],由于 PCNN 具有整体耦合、同步脉冲等优点,使其具有理想的融合性能.但是,PCNN 存在多变量,以及融合准则等设定问题,影响了其在图像融合中的使用.

为了解决上述图像融合方法的不足,本文根据加权融合法,提出了一种基于峰值皮层模型耦合 WLD的医学图像融合算法.根据峰值皮层模型的邻域神经元所产生的脉冲输出的多特征进行权重计 算,而不是单个神经元的脉冲输出特征.邻域神经元产生的脉冲输出的多特征包括可以表征源图像的灰 度信息,再利用脉冲图像生成点火映射图像(Ignition Mapped Image, IMI),构建 SCM 脉冲输出点火数的 融合准则.随后,结合 SCM 脉冲输出的信息熵与点火映射的 Weber 局部描述 WLD,根据信息熵与 WLD 的相似性计算融合权重.相比基于 PCNN 融合的方法,本文提出的峰值皮层模型具有更高的计算效率, 参数设定简单,细节丰富,符合人体视觉系统等优点,使其可以更好地保存源图像的细节特征.最后, 测试本文融合算法的性能.

1 峰值皮层模型

PCNN 具有整体耦合、脉冲同步性^[9]等优点,在图像融合方面取得了很大进步.但是其参数设置较多, 难以获得优异的效果.通过对 PCNN 的不断研究,人们提出了一种峰值皮层模型(SCM), SCM 保持了 PC-NN 的特性,同时简化了模型,降低了参数设置.

峰值皮层模型的结构见图 1,每个单元 S_{i,j} 在(*i*, *j*)处表示图像中的一个像素; I_{i,j} 作为输入的归一化强度,相邻单元作为连接输入的局部刺激. S_{i,j} 中的馈送输入 F_{i,j} 和类似输入结合在一起作为内部活动. 神经元 S_{i,i} 将信号和脉冲输出一起输出,上述过程可以表示为^[10]

$$F_{i,j}[n] = fF_{i,j}[n-1] + I_{i,j} + I_{i,j} \sum_{k,j} W_{i,j,k,l} \gamma_{k,j}[n-1]$$

$$\tag{1}$$

$$\gamma_{i,j} [n] = \begin{cases} 1 & \text{if } F_{i,j} [n] > \Theta_{i,j} [n-1] \\ 0 & \text{otherwise} \end{cases}$$
(2)

$$\Theta_{i,j}[n] = g^{\Theta}_{i,j}[n-1] + h\gamma_{i,j}[n-1]$$
(3)

其中, f,g 为衰减系数, h 为阈值放大因子; n 为迭代次数; $\gamma_{i,j}[n]$ 为脉冲输出; $\Theta_{i,j}[n]$ 为动态阈值.

通过迭代计算,SCM 神经元可输出二进制脉冲图像的时间序列,该序列包含许多有用的输入图像信息.为了更好地解释这一点,图 2显示的是在 f=0.9,g=0.3,h=20,n_{max}=7 的情况下所计算输出的二 值图像,如图 2a 所示.在图 2中,可以看到,在不同的迭代过程中,输出的二值图像包含不同的图像信息, 并且包含不同 SCM 的重要信息,例如输入图像的段和边.另外,从图 2 中还可知,SCM 可以描述人类的微 观组织,具有更高的描述能力.



图1 峰值皮层模型

在 SCM 网络中, 无激活时, $\Theta_{i,j}[n]$ 的值为 0, 不进行脉冲触发. 当 $F_{i,j}[0]$ 与 $\gamma_{i,j}[0]$ 均为 0 时, 进行一次脉冲, 得到了内部项 $S_{i,j}$, 通过不断迭代, $S_{i,j}$ 的能量不断增加, 当 $S_{i,j}$ 的能量大于 $\Theta_{i,j}[n]$ 时, 触发脉冲, 进行点火.





SCM 符合人体视觉的神经网络结构,在外部激励下,可完成脉冲同步触发,能够较好地提取输入图像的源信息.并且具有参数少、计算复杂度低等优点,具备完善的数学理论基础,更接近视觉神经元的 生物特性.

2 本文图像融合算法

本文提出的峰值皮层模型耦合 WLD 的医学图像 融合算法过程见图 3. 该方法的关键部分为图像的融 合准则与融合权重计算. 在本文算法中,根据 SCM 脉冲输出的点火次数建立融合准则,权重计算是根据 2 个源图像之间的相似性,并充分结合点火映射图像 输出的 WLD 与信息熵.

首先,利用 SCM 对源图像进行变换,得到一系 列的二进制脉冲图像.通过脉冲图像生成点火映射图 像,构建 SCM 脉冲输出点火数的融合准则.对于图 像 A 和 B 中坐标为(i, j)的图块,计算图像多次迭代 所输出的熵,生成 2 个特征向量 $V_{i,j}^{A}$ 和 $V_{i,j}^{B}$.然后, 根据 2 个特征向量之间的差异,计算中心为(i, j)的 2 个图块 $Q_{i,j}^{A}$ 和 $Q_{i,j}^{B}$ 之间的相似矩阵 $S_{i,j}^{En}$.对于在 2 个点火映射图像中(i, j)处的任何像素,分别计算像



素中心的 2 个图块的局部能量 $E_{i,j}^{A}$ 和 $E_{i,j}^{B}$. 再计算 2 个图块的 WLD, 通过 $Q_{i,j}^{A}$ 和 $Q_{i,j}^{B}$ 计算相似矩阵 $S_{i,j}^{WLD}$. 最后, 计算 $S_{i,j}^{E_{i,j}}$ 与 $S_{i,j}^{WLD}$ 的融合权重.

2.1 权重计算

为了获得适合的权重 $w_{i,j}$, 需要全面考虑源图像中(i, j)处大小为 $(2L_p+1) \times (2L_p+1)$ 的局部相邻域 $Q_{i,j}$ (图像块), 依据 2 个图像块相邻域 $Q_{i,j}^{A}$ 和 $Q_{i,j}^{B}$ 的相似性来计算权重.为了有效地确定这种相似性, 需

要同时利用 Q_{i,j} 的灰度信息与显著性特征.因此,对于脉冲输出的信息熵和 Weber 局部描述符分别采用 Q_{i,j} 的灰度分布与显著性特征来描述.

对于第*n*次迭代的脉冲图像像素(*i*,*j*),计算其大小为($2L_p$ +1)×($2L_p$ +1)的图像块 $G_{i,j}[n]$ 的中心. 利用熵 $H_{i,i}[n]$ 来描述 $G_{i,i}[n]$ 中包含的信息,其函数为^[11]

$$H_{i,j}[n] = -P_{i,j}^{1}[n]\log_2 P_{i,j}^{1}[n] - P_{i,j}^{0}[n]\log_2 P_{i,j}^{0}[n]$$

$$\tag{4}$$

其中, $P_{i,j}^1[n]$ 和 $P_{i,j}^0[n]$ 分别为对数为 1 和 0 的表达式. $P_{i,j}^1[n]$ 定义如下:

$$P_{i,j}^{1}[n] = \frac{K_{i,j}[n]}{(2L_{p}+1) \times (2L_{p}+1)}$$

$$\tag{5}$$

其中, $K_{i,j}[n]$ 表示 $G_{i,j}[n]$ 中对数为1的数量.

随后,利用不同迭代次数得到的熵值来形成不同的特征向量 $V_{i,j}(V_{i,j} = \{H_{i,j}[1], H_{i,j}[2], \cdots, H_{i,j}[N_{max}-1], H_{i,j}[N_{max}]\})$. 从公式(4)中可得出,所有源图像块 $Q_{i,j}$ 为同质区域,因此,所有迭代的熵 $H_{i,j}[n]$ 都为0,这是因为 $P_{i,j}^1[n]=1$ 或者 $P_{i,j}^0[n]=1$,将产生一个0向量 $V_{i,j}$. 另一方面,因为 $H_{i,j}[n]$ 迭代次数不会为0, $V_{i,j}$ 将包含非零元素,其值取决于灰度分布 $Q_{i,j}$.根据上述分析,灰度信息 $Q_{i,j}$ 可以被 $V_{i,j}$ 特征化.因此,可从 $Q_{i,j}$ 中来提取 $V_{i,j}$ 特征.

再根据 2 个图像块的 V_{i,j},获取其特征 D_{i,j} 为

$$D_{i,j} = \| V_{i,j}^{A} - V_{i,j}^{B} \|_{2}$$
(6)

其中, || · || 2 为 Euclidean 范数.

根据 $D_{i,i}$ 的不同, $Q_{i,i}^{A}$ 和 $Q_{i,i}^{B}$ 之间熵的信息相似度 $S_{i,i}^{E_{n}}$ 为

$$\boldsymbol{S}_{i,j}^{En} = 1 - \frac{D_{i,j}}{CS_1} \tag{7}$$

其中, CS_1 是一个变量,因 $D_{i,j}$ 是 2 个特征向量 $V_{i,j}$ 的差值,而 $V_{i,j}$ 与迭代次数有关,因此, CS_1 的取值与 最大迭代次数 N_{max} 密切相关,其计算函数为 $CS_1 = 2 * N_{max}$, CS_1 越大,则 $S_{i,j}^{En}$ 越大,可获得更大的权重; 反之, $S_{i,j}^{En}$ 越小.但是,较大的 CS_1 会增加其计算量,在本文实验中,取 $N_{max} = 20$,也就是 $CS_1 = 40$.

并根据 IMI 矩阵中 T^A 和 T^B 的像素(i, j)来计算当前像素与其相邻图像块 $(2L_p+1) \times (2L_p+1)$ 之间 的差异 $R_{i,j}$,其计算函数为^[12]

$$R_{i,j} = \sum_{m=L_p}^{L_p} \sum_{n=L_p}^{L_p} (T_{i+m, j+n} - T_{i,j})$$
(8)

根据式(8)可看出, $R_{i,j}$ 的计算与 Laplacian 相似, 遵循 Weber 定律, 对于 WLD 当前的像素差分激励 $\xi_{i,j}$ 为^[12]

$$\boldsymbol{\xi}_{i,j} = \arctan\left(\frac{R_{i,j}}{T_{i,j}}\right) = \arctan\left[\sum_{m=L_p}^{L_p} \sum_{n=L_p}^{L_p} \left(\frac{T_{i+m,j+n} - T_{i,j}}{T_{i,j}}\right)\right]$$
(9)

其中,反正切函数主要用来控制差分激励的大小,以确保 WLD 的描述能力.

WLD可以很好地表示局部邻域的显著性.对于 IMI, WLD 运算可以很好地展现源图像中局部图像的 结构特征,该特征有利于对不同的成像方式进行医疗诊断.通过提取的显著特征,确定源图像中 $Q_{i,j}^{A}$ 和 $Q_{i,j}^{B}$ 的相似性 $S_{i,j}^{WLD}$ 为

$$\boldsymbol{S}_{i,j}^{WLD} = 1 - \frac{|\boldsymbol{\xi}_{i,j}^{A} - \boldsymbol{\xi}_{i,j}^{B}|}{\mathrm{CS}_{2}}$$
(10)

其中, CS_2 是一个常数, 其大小与 $WLD_{(P,R)}$ 描述符中的 R 有关, 本文取 $CS_2 = 4 \times \pi$, 也就是 R = 4, 此时对 应的 WLD 具有较好的描述能力, 能更好地描述其局部显著性.

为了确定加权融合的权重,本文结合 $S_{i,j}^{En}$ 与 $S_{i,j}^{WLD}$,得到权重 $w_{i,j}$ 为

$$\boldsymbol{\omega}_{i,j} = \boldsymbol{S}_{i,j}^{E_n} \cdot \boldsymbol{S}_{i,j}^{WLD} \tag{11}$$

通过公式(11)可知,以(*i*,*j*)为中心的源图像中的2个图块具有相同的局部结构,这就意味着对于相同的

WLD, $\omega_{i,j}$ 将通过与源图像中图像块的强度分布有关的 $S_{i,j}^{En}$ 来决定.因此, $\omega_{i,j}$ 可表示灰度信息与局部结构的结合关系,有效地处理2幅图像的相似性问题.

2.2 融合规则

假设输入图像 A 与 B,作为 SCM 正规化的外部刺激. 通过进行 N_{max} 次 SCM 迭代计算,可获得每个源 图像在像素(i, j)处的点火次数 $T_{i,j}^{A}$ 和 $T_{i,j}^{B}$,

$$T_{i,j}^{A} = \sum_{k=1}^{N_{\max}} \gamma_{i,j}^{A} [k]$$
(12)

$$T_{i,j}^{B} = \sum_{k=1}^{N_{\text{max}}} \boldsymbol{\gamma}_{i,j}^{B} [k]$$
(13)

根据所得到的点火次数 $T_{i,j}^{A}$ 和 $T_{i,j}^{B}$,得到 2 个 FMI 所需要的 2 个矩阵 T^{A} 和 T^{B} .对于参数 N_{max} ,太小或者 太大的 N_{max} ,易产生较少的重要图像细节.一个合适的 N_{max} 可以很好地表示源图像中的细节,这对于 MIF 意义非凡.通过多次试验,本文取 $N_{max} = 20$.

对于 IMI 中的 \mathbf{T}^A 和 \mathbf{T}^B 矩阵的每个像素(*i*, *j*),在其像素中心 2 个大小为($2L_p$ +1)×($2L_p$ +1)的图 块,都将被认为是可以代表该图块的统计特性,该特征比独立的像素特征更有利于源图像的有效融合.故本文用 $E_{i,j}^A$ 和 $E_{i,j}^B$ 2 个局部能量来表示二者的统计特征 $E_{i,j}^A$ 和 $E_{i,j}^B$,即

$$E_{i,j}^{A} = \sqrt{\sum_{m=L_{p}}^{L_{p}} \sum_{n=L_{p}}^{L_{p}} (T_{i+m, j+n}^{A})^{2}}$$
(14)

$$E_{i,j}^{B} = \sqrt{\sum_{m=L_{p}}^{L_{p}} \sum_{n=L_{p}}^{L_{p}} (T_{i+m, j+n}^{B})^{2}}$$
(15)

由于图像融合是充分利用2幅源图像的有效信息,通过这些信息进行互补来提高复原图像的质量.因此, 在不同情况下,每幅图像的有效信息的贡献度是不同的,根据文献[13]~文献[14]的研究成果可知,利用 加权方法来完成图像融合,能够有效地避免融合失真,故本文根据 $E_{i,j}^{A}$ 与 $E_{i,j}^{B}$ 之间的关系,根据式(11)计 算的权重,设计了融合规则:

$$U_{i,j} = \begin{cases} \omega_{i,j} I_{i,j}^{A} (1 - \omega_{i,j}) I_{i,j}^{B} & E_{i,j}^{A} > E_{i,j}^{B} \\ (1 - \omega_{i,j}) I_{i,j}^{B} + \omega_{i,j} I_{i,j}^{B} & E_{i,j}^{A} \leqslant E_{i,j}^{B} \end{cases}$$
(16)

式中, $I_{i,j}^{A}$ 和 $I_{i,j}^{B}$ 分别表示在源图像 A 和 B 中(i, j)处的像素; $\omega_{i,j}$ 表示权重,其在融合过程中具有非常重 要影响,因为 $\omega_{i,j}$ 决定融合结果的贡献值.为保证良好的图像融合结果, $\omega_{i,j}$ 一般采取较大值来突出 $I_{i,j}^{A}$ 的贡献,此时 $E_{i,j}^{A} > E_{i,j}^{B}$, 否则将采用相对较小 $\omega_{i,j}$ 值来强调 $I_{i,j}^{B}$ 的贡献.

2.3 算法描述

1) 输入 2 个源图像的 SCMs, 然后运行 SCM 直到 N_{max} 次, 通过公式(1)~(4)可以获得源图像的二元脉冲图像序列;

2) 对于图像 A 和 B 中坐标为(*i*, *j*)的图块,通过公式计算输出加强图像多次迭代的熵,生成 2 个特征 向量 $V_{i,i}^{A}$ 和 $V_{i,i}^{B}$.根据 2 个特征向量之间的差异,计算(*i*, *j*)处 2 个图块 $Q_{i,i}^{A}$ 和 $Q_{i,j}^{B}$ 之间的相似矩阵 $S_{i,i}^{En}$;

3) 2 个输出脉冲图像被用来生成点火映射图像. 对于在 2 个 FMI 中(*i*, *j*)处的任何像素,分别用公式 计算像素中心的 2 个图块局部能量 $E_{i,j}^{A}$ 和 $E_{i,j}^{B}$. 同时通过计算 2 个图块的 WLD 来决定 $Q_{i,j}^{A}$ 和 $Q_{i,j}^{B}$ 之间的 相似矩阵 $S_{i,j}^{WLD}$;

4) 计算 $S_{i,i}^{En}$ 与 $S_{i,j}^{WLD}$ 的融合权重;

5) 根据 $E_{i,j}^{A}$ 与 $E_{i,j}^{B}$ 的关系,通过叠加 2 个源图像的权重来生成融合图像.

3 实验与讨论

为了衡量本文算法的有效性,进行了2组测试:(1)CT与MRI融合;(2)MRI与PET融合.测试图

像大小为 256 * 256. 仿真环境为: Intel I5, 2.3 GHz 四核处理器, 500GB 硬盘, 8GB 内存, Windows 8 系统, 仿真软件为 MATLAB 2012. 为体现提出方法的先进性, 通过与当前流行的 3 种 MIF 方法对比: 文献 [5]中的基于小波变换方法; 文献[7]中的基于 Contourlet 变换方法; 文献[8]中的基于 PCNN 方法, 分别标记为 WT 方法、Contourlet 方法、PCNN 方法. 实验中的参数设置如下: g = 0.3, h = 20, f = 0.9, $L_P = 1$, $CS_1 = 2 * N_{max}$, $CS_2 = 4 * \pi$, $N_{max} = 20$.

3.1 性能评价指标

为了对融合图像定量评价,通过常见的4种指标:信息熵(IE)、交互信息(MI)、平均梯度(AG)以及 结构相似度(SSIM)进行衡量,分别表示如下:

IE 表示图像信息量的大小, IE 越大表明质量越好^[15]

$$IE = -\sum_{i=1}^{M} \sum_{j=1}^{N} P(x_{i,j}) \log_2 P(x_{i,j})$$
(17)

式中, $P(x_{i,j})$ 为像素点 $x_{i,j}$ 在(i, j)处出现的概率.

MI 反应 2 个图像的信息共享量, MI 越大, 融合效果越佳, MI 表示为^[16]

$$MI = \sum_{i=1}^{L} \sum_{j=1}^{L} h_{i,j}^{x,y} \log_2 \frac{h_{i,j}^{x,y}}{h_{i,j}^x h_{i,j}^y}$$
(18)

 $h^{x,y}$ 为x,y的直方图; h^x 和 h^y 分别为x,y的边缘直方图; L为灰度级.

AG 主要表示融合图像中的细节, AG 越大, 表示图像越清晰^[17]

$$AG = \frac{1}{M \times N} \sum_{j=1}^{M} \sum_{i=1}^{N} \sqrt{\frac{\Delta I_x^2(i, j) + \Delta I_y^2(i, j)}{2}}$$
(19)

 $\Delta I_x(i, j)$ 与 $\Delta I_y(i, j)$ 为图像 x, y 的差分值.

SSIM 是反应图像亮度、对比度与结构的因子, SSIM 越大, 图像越好^[18],

$$SSIM = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \cdot \frac{2\mu_x \mu_y}{\mu_x^2 \mu_y^2} \cdot \frac{2\sigma_x \sigma_y}{2\sigma_x^2 + \sigma_y^2}$$
(20)

 μ_x, μ_y 表示平均亮度; σ_x, σ_y 和 σ_{xy} 表示标准差.

3.2 不同类型的图像融合实验

CT 的空间辨识能力较强,对骨骼与金属成像清晰;MRI 对软组织成像清晰.图 4 为脑部 CT 与 MRI 的融合结果,图 4(a),4(b)为 CT 和 MRI 图像;4(c)为基于 WT 的结果,4(d)为基于 Contourlet 的结果,4 (e)为基于 PCNN 方法的结果,4(f)为本文方法的结果.从图 4 可以看出,图 4(c)中的软组织较模糊,对比 度较低,没有很好地结合源 MRI 图像中的互补信息.图 4(d)中得到的新图像出现了失真,并且在一些局部 区域有伪 Gibbs 现象,降低了融合图像的质量.图 4(e)中出现了伪影,对比度不理想.图 4(f)为本文方法 获得的实验结果,其很好地保持了 CT 的骨骼信息与 MRI 的软组织信息,图像清楚,细节丰富,视觉效果 优异,如图中矩形框所示.主要原因是本文根据峰值皮层模型的邻域神经元产生的多特征来完成权重计 算,而不是单个神经元的脉冲输出特征.邻域神经元产生的脉冲输出的多特征包括可以表征源图像的灰度 信息.利用脉冲图像生成点火映射图像,构建了 SCM 脉冲输出点火数的融合准则.结合 SCM 脉冲输出的 信息熵与点火映射图像的 Weber 局部描述 WLD,根据信息熵与 WLD 的相似性计算融合权重.通过 WLD 与信息熵相结合得到的权重能够获取更优的局部细节.而基于 WT 方法只能获取水平、垂直、对角线 3 种的子带,其获取的方向信息不足,软组织被弱化.基于 Contourlet 变换采用了下采样分解,无平移不变性,易出现伪 Gibbs 问题,影响了纹理细节.基于 PCNN 方法存在多变量、融合准则等设定问题,不易得到最优的融合效果,细节还需进一步加强.

图 5 为 MRI 与 PET 的融合结果, PET 具有清晰表示生物分子代谢、神经介质等优势.图 5(a)、5(b) 为 MRI、PET 图像; 5(c)为基于 WT 的结果, 5(d)为基于 Contourlet 的结果, 5(e)为基于 PCNN 方法的结

果,5(f)为本文方法的结果. 从图 5 可知,图 5(c)的对比度较低,模糊不清,无法清晰表示源图像的信息. 图 5(d)在一些局部区域有伪 Gibbs 现象,出现了斑点,边缘模糊. 图 5(e)出现了伪影,对于一些细节表示 不明显. 图 5(f)为本文方法获得的实验结果,其很好地保持了 MRI 的软组织信息与 PET 的分子活动,得 到的融合图像清晰,细节较丰富,见图中矩形框.



(a) CT



(b) MRI



(c) WT



(d) Contourlet



(e) PCNN



(f) 本文算法

图 4 CT 与 MRI 融合结果



(a) MRI



(b) PET



(c) WT



(d) Contourlet



(e) PCNN



图 5 MRI 与 PET 融合结果

为了准确反映融合图像的质量,通过给出的4种评价标准对图4、图5中的图像进行测量,同时,为了 衡量算法效率,对算法运行时间进行统计,所得数据见表1与表2.依据表1、表2可知,对于这2种不同 类型的图像融合效果,相对于其他对照组,本文算法在*IE*,*MI*,*AG*,*SSIM*上均取得一定的提高,与图4、 图5得到的客观评价相印证,表明了本文方法融合性优良.另外,根据表1、表2可知,对于2组融合实验, 本文方法的运行时间分别为 5.63 s, 5.69 s, 均低于其他算法, 其运行效率更高.

算法	IE	MI	AG	SSIM	T/s	
WT	4.24	4.10	6.54	0.48	6.35	
Contourlet	5.18	3.68	6.21	0.51	8.84	
PCNN	5.46	5.34	6.64	0.52	14.45	
本文算法	5.91	5.87	7.85	0.59	5.63	

表1 CT与 MRI 融合实验结果对比

表 2 MRI 与 PET 融合实验结果对比

算法	IE	MI	AG	SSIM	T/s
WT	3.86	4.05	6.11	0.41	6.41
Contourlet	5.10	4.75	6.52	0.49	8.92
PCNN	5.35	5.31	6.95	0.54	14.48
本文算法	5.84	5.81	7.54	0.55	5.69

4 结 论

本文设计了一种新的峰值皮层模型耦合 WLD 的 MIF 算法. 首先,引入峰值皮层模型分别计算 2 幅待融合图像的信息熵、WLD 以及点火映射;随后,利用峰值皮层模型的邻域神经元产生的多特征来计算融合权重,最大程度地保留了源图像的灰度信息;然后,根据点火映射图像,建立了点火次数的融合准则.并联合权重系数与融合准则,对 2 个不同的图像实施融合;最后,通过对 CT 与 MRI 图像,以及 MRI 与 PET 图像进行融合测试,显示输出的融合图像细节丰富、边缘清晰,保持了源图像的有效信息,从而验证本文提出的方法具有优异的融合性能.

由于本文方法中只是针对像素点融合,忽略了像素与其邻域的联系,接下来需进一步研究,以大幅提 高融合的质量.

参考文献:

- [1] 汪方正,朱子卿.移动队列规则耦合角度约束的医学图像匹配 [J].西南大学学报(自然科学版),2017,39(12): 152-160.
- [2] 牛 玲,王雪华. 基于 SCM 模型的自适应医学图像融合方法 [J]. 西南师范大学学报(自然科学版),2017,42(2): 159-165.
- [3] 许良凤,林 辉,胡 敏. 基于差分进化算法的多模态医学图像融合 [J]. 电子测量与仪器学报, 2013, 27(2): 110-114.
- [4] 肖进胜,饶天宇,贾 茜,等. 基于图切割的拉普拉斯金字塔图像融合算法 [J]. 光电子・激光, 2014, 25(7): 1416-1424.
- [5] 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.
- [6] 杨 勇,童 松,黄淑英. 快速离散 Curvelet 变换域的图像融合 [J]. 中国图象图形学报, 2015, 20(2): 219-228.
- [7] 张 鑫,陈伟斌. Contourlet 变换系数加权的医学图像融合 [J]. 中国图象图形学报, 2014, 19(1): 133-140.
- [8] 江 平,张 强,李 静,等. 基于 NSST 和自适应 PCNN 的图像融合算法 [J]. 激光与红外, 2014, 44(1): 108-113.
- [9] WANG B, WAN L, LI Y. Saliency Motivated Pulse Coupled Neural Network for Underwater Laser Image Segmentation
 [J]. Journal of Shanghai Jiaotong University (Science), 2016, 21(3): 289-296.
- [10] ZHAO R C, MA Y D. Novel Region-Based Image Compression Method Based on Spiking Cortical Model [J]. Journal of Systems Engineering and Electronics, 2015, 26(1): 161-171.
- [11] 郭 明,王书满. 基于区域和方向方差加权信息熵的图像融合 [J]. 系统工程与电子技术, 2013, 35(4): 720-724.
- [12] CHEN J, SHAN S G, HE C, et al. WLD: A Robust Local Image Descriptor [J]. IEEE Transactions on Pattern Analy-

sis and Machine Intelligence, 2010, 32(9): 1705-1720.

- [13] 王惠群,周 涛,陆惠玲,等. 基于多分辨率变换和压缩感知的 PET/CT 融合方法 [J]. 电视技术, 2016, 40(3): 11-16.
- [14] 张 鑫,陈伟斌. Contourlet 变换系数加权的医学图像融合 [J]. 中国图象图形学报, 2014, 19(1): 133-140.
- [15] SHREYAMSHA KUMAR B K. Multifocus and Multispectral Image Fusion Based on Pixel Significance Using Discrete Cosine Harmonic Wavelet Transforms [J]. Signal Image and Video Processing, 2013, 7(6): 1125-1143.
- [16] HAGHIGHAT M B A, AGHAGOLZADEH A, SEYEDARABI H. A non-Reference Image Fusion Metric Based on Mutual Information of Image Features [J]. Computation and Electronically Engineering, 2014, 37(5); 744-756.
- [17] 吴一全,殷 骏,朱 丽. 基于 Shearlet 变换和 TV 模型的医学图像融合 [J]. 数据采集与处理, 2013, 28(5): 565-571.
- [18] ZHANG L, ZHANG L, MOU X Q, et al. FSIM: A Feature Similarity Index for Image Quality Assessment [J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2011, 20(8): 2378-2386.

The Image Fusion Algorithm Based on Peak Cortical Model Coupled with WLD

HUANG Jian-rong¹, YIN Jian²

1. College of Electronic and Information Engineering, Zhuhai City Polytechnic, Zhuhai Guangdong 519090, China;

2. College of Information Science and Technology, Sun Yat-Sen University, Guangzhou 510006, China

Abstract: Current medical image fusion (MIF) methods are prone to produce artifacts, lose some image details and have low contrast. In order to overcome these defects, a new image fusion algorithm based on spiking cortical model and Weber local descriptor was designed in this paper. Firstly, different binary pulse images were obtained by using the SCM to decompose the source image. Secondly, a fusion rule of SCM pulse output ignition number was constructed by using the output ignition image to generate an ignition mapping image. Then the image fusion was completed based on the similarity between the entropy of the SCM pulse and Weber local descriptor of the ignition mapping image to calculate the fusion weights. Experiment results showed that compared with the MIF methods which are now widely used, this algorithm has better visual effects and higher fused image quality and contrast. In addition, it has bigger advantage in the objective evaluation criteria as *IE*, *MI*, *AG* and *SSIM*, for it can effectively preserve the valid information of the source image.

Key words: medical image fusion; Weber local descriptor; spiking cortical model; ignition mapping; information entropy; fusion weight

责任编辑 崔玉洁