

面向医学图像融合的多尺度特征频域分解滤波^{*}

刘慧^{1,2}, 朱积成^{1,2}, 王欣雨^{1,2}, 盛玉瑞³, 张彩明^{2,4}, 聂礼强^{2,5}



¹(山东财经大学 计算机科学与技术学院, 山东 济南 250014)

²(山东省数字媒体技术重点实验室 (山东财经大学), 山东 济南 250014)

³(山东第一医科大学第一附属医院, 山东 济南 250014)

⁴(山东大学 软件学院, 山东 济南 250101)

⁵(哈尔滨工业大学 (深圳) 计算机学院, 广东 深圳 518055)

通信作者: 刘慧, Email: liuh_lh@sdufe.edu.cn

摘要: 多模态医学图像融合技术可以实现不同模态数据反映的组织结构与病变信息的融合, 为后续医疗诊断、手术导航等临床应用提供更为全面和准确的医学图像分析. 针对现有融合方法中存在的部分光谱退化、黏连病变侵袭区域边缘和细节缺失和色彩还原不足等问题, 提出一种在多尺度特征频域分解滤波域内实现图像多特征增强和色彩保留的多模态医学图像融合方法. 该方法将源图像分解为平滑、纹理、轮廓和边缘 4 个特征层, 分别利用特定融合规则并通过图像重构产生融合结果. 特别地, 鉴于平滑层所含潜在特征信息, 提出视觉显著性分解策略, 多尺度多维度地挖掘平滑层图像能量、部分纤维纹理等特征, 提升源图像信息利用率; 在纹理层中, 提出纹理增强算子, 通过空间结构和信息度量提取细节及其层次信息, 解决现有融合方法中对黏连病变区域侵袭状态难以区分等问题. 此外, 针对缺乏公开腹部数据集的问题, 配准 403 组腹部图像可供公开访问和下载. 在 Atlas 公开数据集和腹部数据集上与 6 种基准方法对比及消融实验结果表明, 所提方法相较于最先进的方法在融合图像与源图像相似度提升 22.92%, 边缘保持度提升 35.79%, 空间频率提升 28.79%, 对比度提升 32.92%, 并在视觉和计算效率方面有较好的效果, 明显优于其他方法.

关键词: 医学图像融合; 多尺度特征频域分解滤波; 视觉显著性分解策略; 纹理增强算子; 多模态腹部数据集
中图法分类号: TP391

中文引用格式: 刘慧, 朱积成, 王欣雨, 盛玉瑞, 张彩明, 聂礼强. 面向医学图像融合的多尺度特征频域分解滤波. 软件学报. <http://www.jos.org.cn/1000-9825/7083.htm>

英文引用格式: Liu H, Zhu JC, Wang XY, Sheng YR, Zhang CM, Nie LQ. Multi-scale Feature Frequency Domain Decomposition Filtering for Medical Image Fusion. Ruan Jian Xue Bao/Journal of Software (in Chinese). <http://www.jos.org.cn/1000-9825/7083.htm>

Multi-scale Feature Frequency Domain Decomposition Filtering for Medical Image Fusion

LIU Hui^{1,2}, ZHU Ji-Cheng^{1,2}, WANG Xin-Yu^{1,2}, SHENG Yu-Rui³, ZHANG Cai-Ming^{2,4}, NIE Li-Qiang^{2,5}

¹(School of Computer Science and Technology, Shandong University of Finance and Economics, Jinan 250014, China)

²(Shandong Key Laboratory of Digital Media Technology (Shandong University of Finance and Economics), Jinan 250014, China)

³(The First Affiliated Hospital of Shandong First Medical University, Jinan 250014, China)

⁴(School of Software, Shandong University, Jinan 250101, China)

⁵(School of Computer Science, Harbin Institute of Technology, Shenzhen, Shenzhen 518055, China)

* 基金项目: 国家自然科学基金 (62072274, U22A2033); 中央引导地方科技发展项目 (YDZX2022009); 山东省泰山学者特聘专家计划 (tstp 20221137)

收稿时间: 2023-07-13; 修改时间: 2023-09-11; 采用时间: 2023-10-24; jos 在线出版时间: 2024-03-06

Abstract: Multi-modal medical image fusion provides a more comprehensive and accurate medical image description for medical diagnosis, surgical navigation, and other clinical applications by effectively combining human tissue structure and lesion information reflected by different modal datasets. This study aims to address partial spectral degradation, lack of edges and details and insufficient color reproduction of adhesion lesion-invaded regions in current fusion methods. It proposes a novel multi-modal medical image fusion method to achieve multi-feature enhancement and color preservation in the multi-scale feature frequency domain decomposition filter domain. This method decomposes the source image into four parts: smoothing, texture, contour, and edge feature layers, which employ specific fusion rules and generate fusion results by image reconstruction. In particular, given the potential feature information contained in the smoothing layer, the study proposes a visual saliency decomposition strategy to explore the energy and partial fiber texture features with multi-scale and multi-dimensionality, enhancing the utilization of source image information. In the texture layer, the study introduces a texture enhancement operator to extract details and hierarchical information through spatial structure and information measurement, addressing the issue of distinguishing the invasion status of adherent lesion areas in current fusion methods. In addition, due to the lack of a public abdominal dataset, 403 sets of abdominal images are registered in this study for public access and download. Experiments conducted on public dataset Atlas and abdominal datasets are compared with six baseline methods. Compared to the most advanced methods, the results show that the similarity between the fused image and the source image is improved by 22.92%, the edge retention, spatial frequency, and contrast ratio of fused images are improved by 35.79%, 28.79%, and 32.92%, respectively. In addition, the visual and computing efficiency of the proposed method are better than those of other methods.

Key words: medical image fusion; multi-scale feature frequency domain decomposition filtering; visual saliency decomposition strategies; texture enhancement operator; multi-modal abdominal datasets

随着传感器和计算机技术的应用与发展,医学成像技术在现代临床应用中发挥着越来越重要的作用.由于成像机理和技术限制,单一传感器只能捕获组织结构与病变区域的局部特征.例如,计算机断层扫描(computed tomography, CT)图像主要反映骨骼等致密器官病变信息.磁共振(magnetic resonance, MR)图像根据弛豫时间不同可分为MR-T1和MR-T2.其中MR-T1图像主要反映器官与组织的解剖结构;MR-T2图像对组织出血比较敏感,主要反映器官与组织的像素灰度变化情况.而正电子发射型计算机断层扫描(positron emission computed tomography, PET)图像侧重描述器官生物活性和代谢活动.然而,每种成像方式所提供的病变描述无法使医生对类型多样且复杂的病情做出全方位诊断,极大降低了医学诊断效率,增加了患者就医成本.幸运的是,不同模态医学图像的关键特征之间在一定程度上存在着信息互补,这些互补信息为多模态医学图像融合技术的发展提供了有效途径,使得融合图像能够提供更全面、更可靠的病变描述,以便更好地服务于临床应用.

目前多模态医学图像融合技术大致分为传统方法和深度学习方法^[1,2]两大类.其中,传统方法主要利用空间像素或频域变换系数的数值计算产生融合图像,对数据规模、系统开销和硬件要求较低,并有效减少融合图像失真.其大致分为空域技术和频域技术^[3,4].空域技术是指对医学图像像素级或颜色空间的融合操作,目前常见的包括稀疏表示^[5]、主成分分析^[6]和独立成分分析^[7]等.空域技术能够有效保留像素之间空间和深度距离信息,但在融合时也常会出现图像对比度降低、部分光谱退化等情况.

频域技术的引入明显改善了上述问题,通过对医学图像多尺度分解产生多种频谱子带,并利用特定规则计算其频谱系数,随后将频率信息重构为融合图像,从而增强融合图像边缘与细节表达,提升其在医学诊断视觉感知和辅助治疗决策的能力.目前常见的频域技术包括金字塔变换^[8]、小波变换^[9]、边缘保持滤波(edge preserving filtering, EPF)^[10]、多尺度变换(multi-scale transform, MST)^[11]和多级分解滤波^[12]等.多级分解滤波作为一种新型频域技术近年来受到广泛研究和关注,通过对医学图像多级特征层分解以及融合,减少了融合过程中产生的伪影和块状效应,提升了融合图像的边缘保留和精细化表达.然而,现有多级分解滤波缺乏对图像纹理空间特征的描述,同时融合规则与特征关联性弱,往往导致融合图像出现黏连病变区域侵袭细节模糊、纹理稀疏和色彩不足等问题.如图1所示,该多级分解滤波将CT/MR图像、CT/PET图像分解为细结构层、粗结构层和基层,并对各特征层分别采用像素及其能量规则进行融合.图1(c)中的CT/MR融合图像双侧额叶和脑沟回黏连病变区域缺失了大量病变侵袭信息,甚至难以从图像放大区域中判断神经末梢纤维形态和位置,这在医学诊断中是不可接受的;而对于CT/PET融合,图1(f)中的横结肠和肝脏区域相较于源图像丢失大部分代谢活性信息,从而出现融合图像色彩暗淡和细节模糊等问题.




图1 多级特征分解滤波融合图像

深度学习方法基于其强大的特征学习能力,通过模拟人脑的感知行为来调整内部节点的相互联系,从而产生融合图像,主要包括卷积神经网络^[13]、生成对抗网络^[14]和深度信念网络^[15]等.深度学习方法具有良好的抗噪性,可以根据需求主动突出相应特征.然而,深度学习方法还存在诸多缺点,首先,其需要大量训练数据和较高硬件环境支持,降低了实际应用场景中的使用效率和可行性;其次,其通常具有复杂网络模型结构,所提取的特征往往高度抽象,使得人类无法解释模型内部工作机制、组件实现功能和决策过程^[14],影响了对融合结果的准确性评估和多特征表达.

为了解决上述问题,本文提出了一种基于多尺度特征频域分解滤波(multi-scale feature frequency domain decomposition filtering, MSFDF)的医学图像融合方法.该方法在避免大规模时空开销的基础上,既解决了空域技术中融合图像部分光谱退化问题,又克服了现有频域技术中出现的部分特征缺失和色彩还原不足等情况.此外,鉴于当下研究缺乏公开腹部数据,本文还配准并发布了多模态腹部医学图像数据集,为后续医学图像融合方法的普适性研究提供了有力支撑.

本文主要贡献包含以下4个方面.

(1) 提出了一种医学图像融合方法 MSFDF,将源图像细化为平滑层、纹理层、轮廓层和边缘层,有效解决了因图像分解不充分而导致后续特征融合侵袭细节难以区分、边缘与细节特征缺失等问题.

(2) 为了充分利用平滑层的结构性信息,提出了一种视觉显著性分解策略,更好地保持图像整体结构,极大丰富了融合图像的多特征表达;相应地,提出一种基于视觉显著性、脉冲耦合神经网络和相位一致性的 NSCT 融合策略,进一步提升了融合图像与源图像的结构相似程度.

(3) 为了准确区分纹理层的细节层次,提出了一种纹理增强算子,从图像空间与强度方面提取细节及其层次信息,增强了融合方法对纤维质感的感知能力,解决了黏连病变侵袭区域细节层次无法区分的问题,有助于神经系统疾病的辅助诊断及后续临床微创技术研究.

(4) 通过患者数据采集、隐私脱敏及其图像配准,课题组已将 403 对腹部多模态医学图像发布在 <https://github.com/jchengzhu/Abdominal-multimodal-medical-images> 供研究使用,进一步验证了本文方法在腹部医学图像融合中的优势,为后续医学图像融合方法普适性的研究提供有力支撑.

本文第1节具体阐述频域图像融合技术现有相关方法.第2节详细介绍本文提出的融合方法 MSFDF.第3节通过参数分析、消融和对比实验,分析并验证本文方法的有效性.第4节总结全文,并对未来研究做出展望.

1 相关工作

频域技术作为医学图像融合领域中一个极具特色的研究分支,近年来受到广泛关注,其主要包括图像分解、各特征层融合和图像重构这3个步骤.早期频域技术大多拘泥于图像双尺度分解及其像素级决策融合规则,忽视了对图像特征的描述,往往导致边缘、纹理等关键信息丢失,具有较强的局限性.后来,频域技术开始趋向图像多尺度、多级分解,通过提取融合医学图像各类复杂特征,有效实现融合图像多特征表达.目前常见的图像分解框架包括 MST^[11]、EPF^[4]和多级分解滤波^[12]等.同时,各特征层融合规则也在提升特征精细化表达等方面进行探索,目前常见的包括基于能量^[4]、基于脉冲耦合神经网络^[3]和基于视觉显著性^[16]的融合规则等.

1.1 多模态医学图像分解框架

随着多尺度理论的发展, MST 正作为一种新型的信号处理手段广泛应用于医学图像融合领域, 其主要包括轮廓波变换^[17]、剪切波变换^[18]和非下采样轮廓波变换 (non-subsampled contourlet transform, NSCT)^[11]等. 与传统平均滤波和低通滤波不同, MST 通过图像多尺度分解、频率系数选择和图像重构, 构建了一种与人类视觉感知极其相似的融合方式, 解决了在基本细节分离时出现全局模糊、边缘结构特征不理想等问题. 文献 [19] 提出了一种基于 NSCT 的图像融合方法, 针对高低频段分别采用相位一致性和局部拉普拉斯能量规则进行融合, 有效提升了对源图像的边缘提取和融合图像的纹理表达. 然而, MST 在图像分解时只关注单个像素频率情况, 忽视了像素之间相似程度、空间邻域信息的表达, 限制了其在突出边缘、降噪平滑方面的作用.

EPF 改善了上述问题, 其主要包括双边滤波^[4]、引导滤波^[10]和加权最小二乘滤波^[20]等. 滚动引导滤波 (rolling guidance filtering, RGF)^[21]通过引导图像计算各像素点及其邻域的相似程度, 以此保留边缘信息并消除噪声, 解决了传统引导滤波在平滑过程中容易出现边缘细节模糊等失真问题. 引导方差加权平均滤波 (guide variance weighted average filtering, GVWAF)^[22]的出现开启了 EPF 新纪元, 虽然目前未被广泛应用于图像融合领域, 但其通过迭代过滤能够有效保留源图像边缘和纹理特征. 然而, 由于 EPF 图像分解能力有限, 其产生的各分解层通常包含多类复杂特征, 使得后续融合规则无法准确处理各层信息, 出现图像特征缺失、细节扭曲等问题.

近年来, 多级分解滤波在图像融合领域取得了较好的效果, 其结合 MST 和 EPF 优势, 通过提取和融合医学图像不同尺度和方向的特征分量, 增强融合图像边缘、轮廓以及纹理等多特征表达, 具有计算效率高、可调控性强的优点. 目前常见的多级分解滤波包括多级边缘保留滤波^[12]、多级高斯曲率滤波^[23]和多尺度特征保留滤波^[24]等. 文献 [23] 提出了一种基于多级高斯曲率滤波的图像融合方法, 针对图像小尺度、大尺度和基础层, 分别采用了像素比较和局部能量算子进行融合操作. 通过该方法, 融合图像获得更加丰富的特征描述, 为下游任务提供更准确、更全面的信息.

在医学影像辅助诊断中, 其纤维、纹理等微小结构表达对于医生捕捉病变、形态分析与量化异常起着至关重要的作用, 能够在术前规划中帮助医生准确定位手术目标、避开重要血管和神经结构. 然而, 现有的多级分解滤波通常将图像粗略地分为大尺度、小尺度和基础层, 其特征描述较为笼统且忽视了对重要纹理特征的描述, 导致融合图像常出现黏连病变侵袭区域边缘模糊、细节缺失等问题, 违背了融合图像细节感知的要求. 此外, 通过多级分解产生的基础层蕴藏了大量的潜在特征信息, 目前的滤波方法未能充分利用基础层中所含的复杂特征, 限制了融合方法在多特征表达方面的应用. 然而, MST 在不同尺度上能够对含有复杂特征的图像信息进行分解重构, 从而达到滤除高频噪声并减少伪影的目的, 进一步提高了图像信息的利用率和方法的鲁棒性. 基于此, 本文拟探索一种高效的多级分解滤波框架, 并改进和应用 MST, 以解决现有方法中存在的黏连病变侵袭区域纹理区分不足、细节与色彩缺失等问题.

1.2 各特征层融合规则

在多模态医学图像融合中, 多级分解滤波将图像分解为不同尺度的特征层, 且不同特征层所包含的医学信息各异. 例如, 小尺度特征层通常包含更多的纤维纹理、微小病变等细节信息; 大尺度特征层通常包含较明显的骨折创伤、肿瘤肿块等边缘轮廓情况; 基础层则通常包含由器官组织感染和炎症引起的像素灰度变化等. 不同特征层侧重表达不同类型的病变特征, 因此选择适合各特征的融合规则非常重要.

其中, 基于能量的融合规则通过计算图像强度、梯度来描述图像细节信息, 具有较高的计算效率和细节表达能力. 文献 [7] 提出了一种基于局部梯度能量算子的图像融合方法, 该方法通过计算结构张量和邻域能量实现特征选择与融合, 提升了融合图像纹理表达和对噪声的鲁棒性. 然而, 现有的融合规则仅通过图像强度获取图像信息, 忽视对黏连病变侵袭区域微小病变和层次信息的描述, 极大影响医学诊断的准确性.

作为一种神经元传递机制的模型, 基于脉冲耦合神经网络 (pulse coupled neural network, PCNN) 的融合规则^[6]具有噪声鲁棒性和全局耦合的优点, 能够在复杂背景下提取微小结构信息, 并可以突出显示这些包含较少纹理的图像中的细节信息. 文献 [18] 提出了一种基于 PCNN 融合规则的形态学滤波图像融合方法, 通过形态学多尺度分

解并采用 PCNN 进行融合,充分保留了来自医学图像的复杂纹理及其细节特征.然而,PCNN 在融合图像时通常需要进行大量的迭代计算.特别是对于包含大量纹理细节的大规模医学图像数据而言,如果单独并完全地使用 PCNN,将会严重影响医学诊断的效率.

此外,随着视觉注意机制的发展,基于视觉显著性 (graph based visual saliency, GBVS) 的融合规则^[25]通过生物视觉注意机制,在特征层生成激活图模型并归一化,兼顾图像融合过程中颜色、纹理、亮度等多维度视觉特征,有效识别医学图像显著目标或感兴趣区域,帮助医生快速且准确地定位重要的解剖结构、病变区域或其他关键信息.文献^[26]使用引导滤波将医学图像分解为一系列不同尺度图像子带,利用 GBVS 提取融合子带显著性信息,增强多特征表达,同时防止对比度过低的问题.然而,GBVS 通过对图像信息重要性分析来选择焦点区域,且医学图像高频子带组织、纹理相似,过度依赖 GBVS 可能导致融合图像出现误差聚焦、图像失真等问题.

基于上述规则的应用与不足,本文拟探索一种纹理增强算子,从图像空间与强度方面提取纹理层的微小结构信息,提高融合方法对纤维质感的感知能力,并有效区分其细节层次.此外,为了有效提取平滑层的潜在特征,本文拟探索一种视觉显著性分解策略,通过 GBVS、PCNN 和相位一致性规则来刻画图像信息,进一步增强了融合图像与源图像的结构相似程度,解决当前融合方法中存在无法适用于特征层描述的问题.

2 本文方法

为了获得边缘清晰、细节丰富、色彩还原高的融合图像,本文提出了基于多尺度特征频域分解滤波的多模态医学图像融合方法 MSFDF.该方法包括 MSFDF 分解、各特征层融合、逆 MSFDF 重构这 3 个模块,如图 2 所示.首先,通过 MSFDF 将源图像分解为平滑层、纹理层、轮廓层和边缘层;其次,分别通过视觉显著性分解策略、纹理增强算子、相位一致性和局部梯度能量算子对上述特征层进行融合;最后,通过逆 MSFDF 重构获得融合图像.

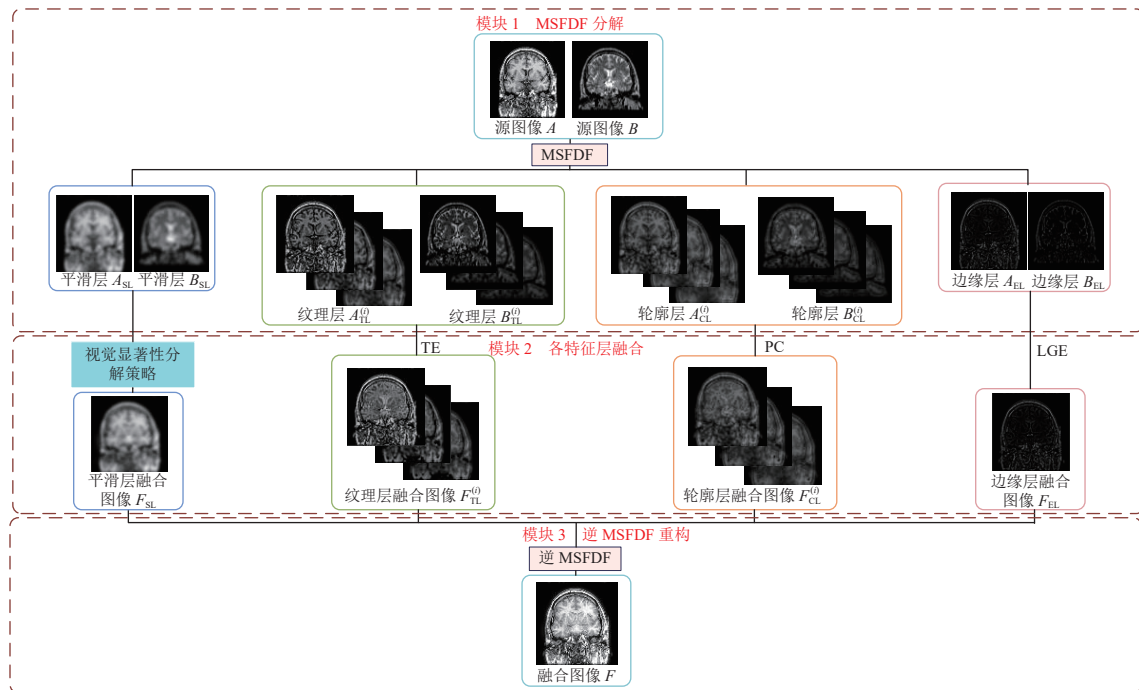


图 2 本文方法框架

2.1 MSFDF 分解

为了充分捕捉源图像的各类特征,通过对源图像 A, B (以下统称为 I_m) 进行模糊处理、提取边缘和层间差值,

获得具有明显特征的平滑、纹理、轮廓和边缘层图像,如图3所示,其中,橙色实心圆圈表示两类图像通过作差生成新图像的操作.首先,通过方差为 σ_n^2 的高斯滤波器 G_m 对源图像 I_{in} 进行全局模糊生成平滑结果 S_m ,即:

$$S_m = G_m * I_{in} \quad (1)$$

其中,*表示高斯滤波器 G_m 的图像滤波操作.同时,通过加权平均高斯滤波器生成全局模糊图像 $I_{gau}(j)$,即:

$$I_{gau}(j) = \frac{1}{H_j} \sum_{i \in N(j)} \exp\left(-\frac{\|j-i\|^2}{2\sigma_u^2}\right) I_{in}(i) \quad (2)$$

其中, j 表示像素 i 的邻接像素坐标; H_j 表示归一化操作; $N(j)$ 表示由像素 i 的邻接像素组成的像素集合; σ_u^2 表示像素方差.

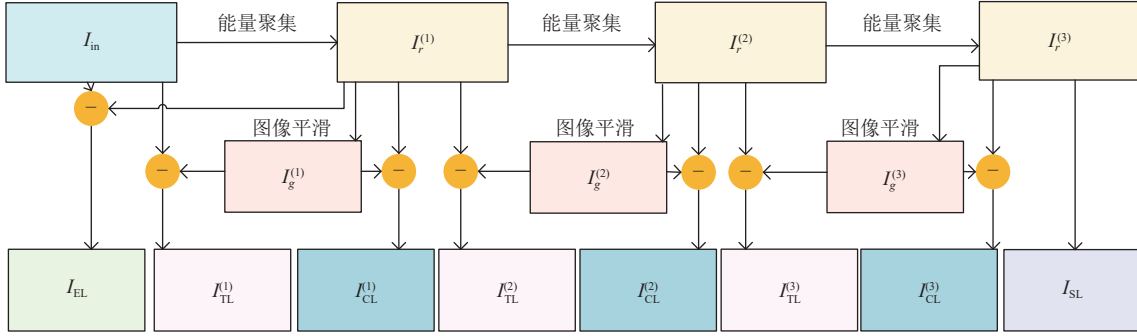


图3 MSFDF 分解框架

其次,为恢复全局模糊图像 $I_{gau}(j)$ 中边缘轮廓等大结构特征,通过公式(3)产生边缘强度信息相对集中的能量聚集图像 I_r ,即:

$$I_r = \frac{1}{Z_j} \sum_{i \in N(j)} \exp\left(-\frac{\|j-i\|^2}{2\sigma_s^2} - \frac{\|I_{gau}(j) - I_{gau}(i)\|^2}{2\sigma_r^2}\right) \quad (3)$$

其中, Z_j 表示归一化操作; σ_s^2 , σ_r^2 分别表示双边滤波器的空间和范围权重,分别设置为3和0.1^[7].

随后,通过引导滤波局部线性变换实现由能量聚集图像 I_r 产生滤波图像 I_{gui} ,即:

$$(I_{gui})_k = a_i M_k + b_i, \forall k \in \omega_i \quad (4)$$

其中, i 表示像素坐标; M 表示引导图像; a_i 和 b_i 表示局部线性变换系数; ω_i 表示以像素 i 为中心的局部窗口,窗口半径为3; M_k 表示局部窗口内位置为 k 的像素点对应的灰度值; $(I_{gui})_k$ 表示位置 k 所对应的像素点的引导滤波局部线性变换输出.通过最小化代价函数 E 寻优求解,即:

$$E(a_i, b_i) = \sum_{k \in \omega_i} [(a_i M_k + b_i - I_r)^2 + \lambda a_i^2] \quad (5)$$

其中, λ 为正则化系数.在保证线性参数不过大的前提下,使得基于引导图像 M 获得的滤波图像 I_{gui} 与能量聚集图像 I_r 之间的差异尽可能减小,并通过平均滤波 F_m 处理得到其各像素点的方差 $\sigma_{I_{gui}}^2$.

$$\sigma_{I_{gui}}^2 = F_m(I_{gui} * I_{gui}) - F_m(I_{gui}) * F_m(I_{gui}) \quad (6)$$

其中,*表示卷积运算.

此时,对于每一个输入图像,根据其像素方差得到一个合适的权值 c .

$$c = \frac{1}{1 + (\sigma_{I_{gui}}^2 / \sigma_m^2)^2} \quad (7)$$

其中, σ_m^2 表示为:

$$\sigma_m^2 = s * F_m(\sigma_{I_{gui}}^2) \quad (8)$$

其中, s 表示平滑尺度参数, 设置为 $0.2^{[4]}$. 平滑图像 I_g 可以表示为:

$$I_g = G_m(c.*I_r) \quad (9)$$

以上述过程产生的第 1 级能量聚集图像作为输入图像, 循环产生第 2, 3 级能量聚集图像 $I_r^{(i)}$ ($i = 2, 3$) 和平滑图像 $I_g^{(i)}$ ($i = 2, 3$). 综上, 多模态医学图像经过 MSFDF 分解产生平滑层 I_{SL} 、纹理层 I_{TL} 、轮廓层 I_{CL} 和边缘层 I_{EL} , 即:

$$I_{SL} = I_r^{(3)} \quad (10)$$

$$I_{TL}^{(i)} = \begin{cases} I_{in} - I_g^{(i)}, & i = 1 \\ I_r^{(i-1)} - I_g^{(i)}, & i = 2, 3 \end{cases} \quad (11)$$

$$I_{CL}^{(i)} = I_r^{(i)} - I_g^{(i)}, \quad i = 1, 2, 3 \quad (12)$$

$$I_{EL} = I_{in} - I_r^{(1)} \quad (13)$$

2.2 各特征层融合

2.2.1 平滑层融合规则

经过 MSFDF 分解, 平滑层包含器官组织病变产生的灰度变化以及集中能量信息. 同时, 其分解的局限性导致平滑层包含少量纤维等纹理特征. 因此, 平滑层信息的复杂性有必要通过 NSCT 再度分解, 产生第 1-4 层高频子带、第 5 层高频子带和低频子带, 并采用纹理增强算子、PCNN 和相位一致性分别对纹理特征、器官骨骼等轮廓结构进行处理, 进一步提高平滑层信息利用率, 提升融合效果. 该平滑层视觉显著性分解策略, 如图 4 所示.

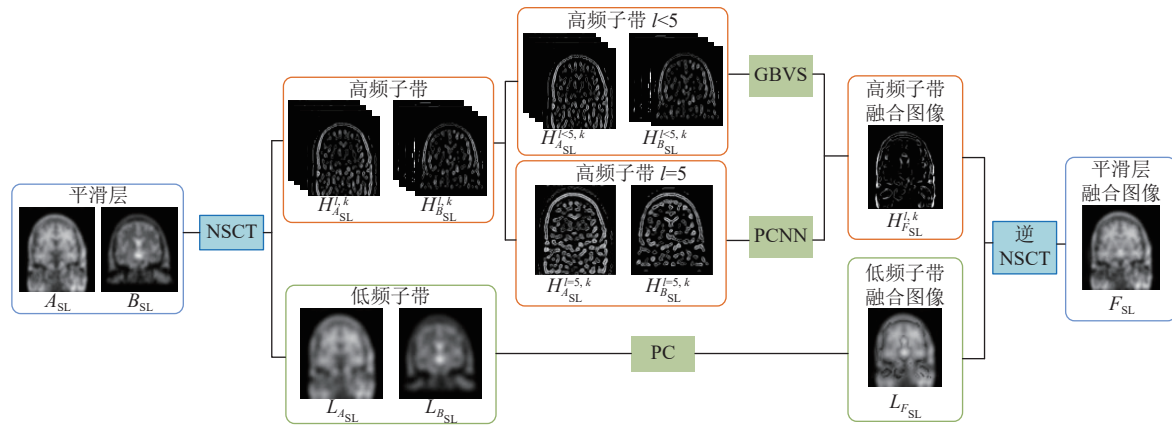


图 4 平滑层视觉显著性分解策略

通过 NSCT 分解, 平滑层高频子带包含不同尺度的器官轮廓结构和纤维纹理特征, 同时各高频子带出现了随子带层数升高, 图像尺度信息减小的情况, 导致融合规则难以有效提取最高层子带特征信息. 而 PCNN 作为一种生物启发神经网络, 能够高效判别并提取在复杂背景中的少量小尺度结构信息, 优于大部分传统融合规则^[3]. 基于此, 将 PCNN 嵌入到高频子带的处理中, 提升融合规则对第 5 层高频子带信息的提取能力, 从而达到提高融合图像结构与纹理特征的目的. 同时, 提出纹理增强算子对第 1-4 层高频子带进行融合, 进一步提高融合规则对源图像器官轮廓、纤维纹理的还原程度. 通过大量实验^[19]证实, 平滑层第 1-4 层高频子带采用纹理增强算子, 第 5 层采用 PCNN 对结构与纹理信息的提取与融合具有显著优势.

对于第 1-4 层高频子带而言, GBVS 作为一种结合生物视觉注意机制的图像感知方法, 综合考虑各类特征对融合图像视觉显著性贡献, 以此突出描述医学图像重要特征, 在融合图像特征增强、提升与源图像相似度等方面具有显著优势. 因此, 将 GBVS 用于处理含有复杂特征的第 1-4 层高频子带中, 进一步提升融合图像与源图像特征相似程度. 对于第 1-4 层高频子带, 通过高斯滤波得到特征图 S_M , 并连接所有像素点生成有向图 S_A . 随后, 在 S_A 上定义马尔可夫链, 通过马尔可夫链的稳定状态来反映图像轮廓特征的显著性, 并对每个特征映射归一化和叠加.

其中, S_A 中任意顶点 p 到 q 有向边的权值定义为:

$$\omega_N(p, q) \triangleq A(p) \cdot F(p_i - q_i, p_j - q_j) \quad (14)$$

其中, $A(p)$ 表示顶点的显著性数值, F 表示由顶点 p 和 q 通过指数计算得到的变量参数. 最后通过计算马尔可夫链的平衡状态, 得到归一化特征显著图 M .

通过比较显著性数值大小突出更为明显的轮廓特征, 得到平滑层第 1-4 层高频子带决策矩阵 $S_{Hmap}(x, y)$, 定义为:

$$S_{Hmap}(x, y) = \begin{cases} 1, & \text{if } M_{F_{ASL}^{l<5,k}}(x, y) > M_{F_{BSL}^{l<5,k}}(x, y) \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

根据以下规则得到平滑层第 1-4 层高频子带融合图像 $H_{F_{SL}^{l<5,k}}(x, y)$, 即:

$$H_{F_{SL}^{l<5,k}}(x, y) = \begin{cases} H_{ASL}^{l<5,k}(x, y), & \text{if } S_{Hmap}(x, y) = 1 \\ H_{BSL}^{l<5,k}(x, y), & \text{otherwise} \end{cases} \quad (16)$$

对于第 5 层高频子带采用 PCNN 进行融合, 迭代处理每个神经元的馈线输入和链接输入, 得到当前的内部活动项 $W_{ij}(n)$.

$$W_{ij}(n) = e^{-\eta_f} W_{ij}(n-1) + H_{ij}(n)(1 + \beta K_{ij}(n)) \quad (17)$$

其中, n 表示 PCNN 迭代次数; η_f 表示指数衰减系数; β 表示链接强度; $H_{ij}(n)$ 和 $K_{ij}(n)$ 分别表示神经元的馈电输入和链接输入, 即:

$$H_{ij}(n) = [H_{ISL}^{l,k}(x, y)]_{l=5} \Big|_{ij} \quad (18)$$

$$K_{ij}(n) = V_L \sum_{op} U_{ijop} R_{op}(n-1) \quad (19)$$

其中, V_L 表示馈电输入幅值; R_{op} 表示 PCNN 输出模型; U_{ijop} 表示八邻域神经元先前的兴奋状态, 即:

$$U_{ijop} = \begin{bmatrix} 0.5 & 1.0 & 0.5 \\ 1.0 & 0.0 & 1.0 \\ 0.5 & 1.0 & 0.5 \end{bmatrix} \quad (20)$$

同时, 迭代更新当前动态阈值 $E_{ij}(n)$, 即:

$$E_{ij}(n) = e^{-\eta_e} E_{ij}(n-1) + V_E R_{ij}(n) \quad (21)$$

其中, η_e 和 V_E 分别表示指数衰减系数和 $E_{ij}(n)$ 的振幅.

利用当前内部活动项 $W_{ij}(n)$ 与第 $n-1$ 次迭代时的动态阈值 $E_{ij}(n-1)$ 进行大小比较, 判断 PCNN 输出模型 $P_{ij}(n)$ 的状态, 并迭代产生第 5 层高频子带 PCNN 激励次数 $T_{ij}(n)$.

$$P_{ij}(n) = \begin{cases} 1, & \text{if } W_{ij}(n) > E_{ij}(n-1) \\ 0, & \text{otherwise} \end{cases} \quad (22)$$

$$T_{ij}(n) = T_{ij}(n-1) + P_{ij}(n) \quad (23)$$

根据以下规则得到平滑层第 5 层高频子带融合图像 $H_{F_{SL}^{l=5,k}}(x, y)$, 即:

$$H_{F_{SL}^{l=5,k}}(x, y) = \begin{cases} H_{ASL}^{l=5,k}(x, y), & \text{if } T_{ASL}^{l,k}(n) \geq T_{BSL}^{l,k}(n) \\ H_{BSL}^{l=5,k}(x, y), & \text{otherwise} \end{cases} \quad (24)$$

因此, 平滑层高频子带融合图像 $H_{F_{SL}^{l,k}}(x, y)$ 定义为:

$$H_{F_{SL}^{l,k}}(x, y) = H_{F_{SL}^{l<5,k}}(x, y) + H_{F_{SL}^{l=5,k}}(x, y) \quad (25)$$

与高频子带不同, 平滑层低频子带含有大量像素灰度变化信息, 可以通过相位一致性对其图像信息进行增强处理, 以此进一步提升低频子带信息量. 其中, 相位作为一种无量纲测量, 被用于反映图像的清晰度和图像特征的重要性^[19]. 在 (x, y) 处的相位定义为:

$$PA(x, y) = \frac{\sum_m E_{\theta_m}(x, y)}{\omega + \sum_n \sum_m A_{n, \theta_m}(x, y)} \quad (26)$$

其中, m 和 n 分别表示非下采样方向滤波器组和非下采样金字塔分解层数; θ_m 表示位于 m 处的方向角; A_{n, θ_m} 表示第 n 个傅里叶分量的振幅和角 θ_m 大小; ω 表示用于去除图像的相位分量的参数; $E_{\theta_m}(x, y)$ 定义为:

$$E_{\theta_m}(x, y) = \sqrt{F_{\theta_m}^2(x, y) + H_{\theta_m}^2(x, y)} \quad (27)$$

$$F_{\theta_m}(x, y) = \sum_n a_{n, \theta_m}(x, y) \quad (28)$$

$$H_{\theta_m}(x, y) = \sum_n b_{n, \theta_m}(x, y) \quad (29)$$

其中, $a_{n, \theta_m}(x, y)$ 和 $b_{n, \theta_m}(x, y)$ 分别表示位于 (x, y) 处像素的卷积结果, 即:

$$[a_{n, \theta_m}(x, y), b_{n, \theta_m}(x, y)] = [A, B] \quad (30)$$

$$A = L_{\text{Isl}}(x, y) \cdot D_n^a \quad (31)$$

$$B = L_{\text{Isl}}(x, y) \cdot D_n^b \quad (32)$$

其中, D_n^a 和 D_n^b 表示二维尺度大小为 n 的 Log-Gabor 的奇偶对称滤波器组.

然而, 相位作为一种对比度不变量, 无法反映局部对比度变化情况, 因此引入局部锐度变化量, 即:

$$LSCM(x, y) = \sum_{m=-3}^3 \sum_{n=-3}^3 SCM(x+m, y+n) \quad (33)$$

$$SCM(x, y) = \sum_{(x, y) \in \Omega_1} (L_{\text{Isl}}(x, y) - L_{\text{Isl}}(x, y))^2 \quad (34)$$

其中, Ω_1 表示以像素 (x, y) 为中心的局部窗口, 窗口半径为 3. 此外引入局部能量反映局部信号强度, 即:

$$LE(x, y) = \sum_{m=-3}^3 \sum_{n=-3}^3 (L_{\text{Isl}}(x+m, y+n))^2 \quad (35)$$

综上, 低频综合测量算子 LM 表示为:

$$LM(x, y) = (PA(x, y))^p \cdot (LSCM(x, y))^p \cdot (LE(x, y))^q \quad (36)$$

由此, 通过比较相位一致性得到平滑层低频子带决策矩阵 $S_{Lmap}(x, y)$, 定义为:

$$S_{Lmap}(x, y) = \begin{cases} 1, & \text{if } LM_{L_{\text{Asl}}}(x, y) > LM_{L_{\text{Bsl}}}(x, y) \\ 0, & \text{otherwise} \end{cases} \quad (37)$$

根据以下规则得到平滑层低频子带融合图像 $L_{F_{\text{sl}}}(x, y)$, 即:

$$L_{F_{\text{sl}}}(x, y) = \begin{cases} L_{\text{Asl}}(x, y), & \text{if } S_{Lmap}(x, y) = 1 \\ L_{\text{Bsl}}(x, y), & \text{otherwise} \end{cases} \quad (38)$$

最后, 通过逆 NSCT 对融合后的高频子带 $H_{F_{\text{sl}}}^{lk}(x, y)$ 和低频子带 $L_{F_{\text{sl}}}(x, y)$ 进行线性重构, 得到平滑层融合图像 $F_{\text{sl}}(x, y)$.

2.2.2 纹理层融合规则

纹理层包含病灶大量组织纤维、纹理等微小结构, 其表达效果对于医生捕捉病变、形态分析与量化异常起着至关重要的作用. 图像能量作为刻画图像细节的重要方法, 常被用于反映图像纤维纹理分布情况. 然而, 单一且传统的图像能量融合规则常受到纹理层各类微小结构的干扰, 在一定程度上导致融合图像细节缺失. 同时, 该融合规则无法识别纹理空间层次信息, 进一步限制了对黏连病变的后续诊断. 据此, 本文提出纹理增强算子, 通过计算图像能量属性、图像熵和边缘密度等多维度信息, 有效提取其纹理特征并增强细节表达. (x, y) 处的图像能量属性定义为:

$$EM(x,y) = \exp(M|I_{TL}(x,y) - P|) \quad (39)$$

其中, M 表示测量系数; P 表示纹理层经过模糊处理产生的粗粒度图像, 即:

$$P = (I_{TL}(x,y))_m + (I_{TL}(x,y))_a \quad (40)$$

其中, $(I_{TL}(x,y))_m$ 和 $(I_{TL}(x,y))_a$ 表示纹理层图像像素中值和平均值.

为反映纹理层全局病变细节信息, 引入图像熵, 通过计算各像素点熵值大小, 反映其细节信息, 即:

$$IE(x,y) = \frac{1}{256 \times 256} \sum_{x=1}^{256} \sum_{y=1}^{256} \log_2 |I_{TL}(x,y)| \quad (41)$$

然而, 图像能量属性和熵作为图像细节信息的估计量, 无法表达其纹理层次信息, 导致黏连病变区域常出现侵袭状态难以区分等问题. 因此, 纹理增强算子引入边缘密度, 突出融合图像纹理结构的层次感. (x,y) 处的边缘密度定义为:

$$ED(x,y) = \sqrt{g_x(x,y)^2 + g_y(x,y)^2} \quad (42)$$

$$g_x = I_{TL} * h_x \quad (43)$$

$$g_y = I_{TL} * h_y \quad (44)$$

其中, h_x 和 h_y 分别表示在 x 和 y 方向上的 Sobel 算子.

综上, 第 i 层的纹理增强算子表示为:

$$TE_i(x,y) = \frac{DM_i(x,y)}{\sum_{i=1}^p DM_i(x,y)} \quad (45)$$

其中, i 和 p 分别表示纹理层当前层数和总层数; DM_i 表示第 i 层纹理层测量值, 即:

$$DM_i(x,y) = EM_i(x,y) + IE_i(x,y) + ED_i(x,y) \quad (46)$$

由此, 通过计算各层纹理增强算子, 突出不同模态医学图像中更为明显的纹理细节与空间特征, 纹理层决策矩阵 $T_{map}(x,y)$ 定义为:

$$T_{map}(x,y) = \begin{cases} 1, & \text{if } TE_{A_{TL}}(x,y) > TE_{B_{TL}}(x,y) \\ 0, & \text{otherwise} \end{cases} \quad (47)$$

根据以下规则得到纹理层融合图像 $F_{TL}^{(i)}(x,y)$, 即:

$$F_{TL}^{(i)}(x,y) = \begin{cases} A_{TL}^{(i)}(x,y), & \text{if } T_{map}(x,y) = 1 \\ B_{TL}^{(i)}(x,y), & \text{otherwise} \end{cases} \quad (48)$$

2.2.3 轮廓层融合规则

轮廓层包含大部分生理组织以及肿瘤等非致密性病变的外围轮廓信息, 通过采用相位一致性计算轮廓层决策矩阵 $C_{map}(x,y)$, 即:

$$C_{map}(x,y) = \begin{cases} 1, & \text{if } LM_{A_{CL}}(x,y) > LM_{B_{CL}}(x,y) \\ 0, & \text{otherwise} \end{cases} \quad (49)$$

根据以下规则得到轮廓层融合图像 $F_{CL}^{(i)}(x,y)$, 即:

$$F_{CL}^{(i)}(x,y) = \begin{cases} A_{CL}^{(i)}(x,y), & \text{if } C_{map}(x,y) = 1 \\ B_{CL}^{(i)}(x,y), & \text{otherwise} \end{cases} \quad (50)$$

2.2.4 边缘层融合规则

边缘层包含全局致密性器官及其大尺度病变的边缘信息, 通过对其精准融合有助于高效定位和判断患者的大致病变情况. 局部梯度能量算子通过计算边缘层局部能量和结构张量显著性, 能够有效反映器官、组织的边缘及其几何结构特征^[4], 即:

$$LGE(x, y) = LE(x, y) \cdot ST(x, y) \quad (51)$$

其中, ST 表示结构张量显著性 (structural tensor significance, STS) 图像; LE 表示以 (x, y) 为中心的局部能量, 定义为:

$$LE(x, y) = \sum_{m=-3}^3 \sum_{n=-3}^3 I_{EL}(x+m, y+n) \quad (52)$$

在 STS 中, 通过局部变化率 $r(\alpha)$ 来刻画边缘层的局部几何特征, 即:

$$r(\alpha) = \sum_{\Omega_2(x, y)} [(I_{EL})_x \cos \alpha + (I_{EL})_y \sin \alpha]^2 = (\cos \alpha, \sin \alpha) \cdot \mathbf{S} \cdot (\cos \alpha, \sin \alpha)^T \quad (53)$$

其中, \mathbf{S} 表示结构张量, 即:

$$\mathbf{S} = \sum_{\Omega_2(x, y)} \nabla f \nabla f^T = \begin{bmatrix} A & B \\ B & C \end{bmatrix} \quad (54)$$

其中, $\nabla f \nabla f^T$ 表示二阶矩的半正定矩阵, 即:

$$A = \sum_{\Omega_2(x, y)} ((I_{EL})_x)^2 \quad (55)$$

$$B = \sum_{\Omega_2(x, y)} (I_{EL})_x (I_{EL})_y \quad (56)$$

$$C = \sum_{\Omega_2(x, y)} ((I_{EL})_y)^2 \quad (57)$$

其中, ∇f 表示边缘层的局部梯度向量, 定义为:

$$\nabla f = [(I_{EL})_x, (I_{EL})_y]^T \quad (58)$$

作为结构张量 \mathbf{S} 的特征值, λ_1, λ_2 描述局部区域梯度特征, 分别表示为:

$$\lambda_1 = \frac{1}{2} \left[(A+C) + \sqrt{(A-C)^2 + 4(B)^2} \right] \quad (59)$$

$$\lambda_2 = \frac{1}{2} \left[(A+C) - \sqrt{(A-C)^2 + 4(B)^2} \right] \quad (60)$$

综上, STS 定义为:

$$STS = \sqrt{(\lambda_1 + \lambda_2)^2 + 0.5(\lambda_1 - \lambda_2)^2} \quad (61)$$

由此, 通过计算 LGE 实现对边缘层所反映器官组织边缘的有效提取, 提升其对边界的完整清晰表达, 边缘层决策矩阵 $\mathbf{E}_{map}(x, y)$, 定义为:

$$\mathbf{E}_{map}(x, y) = \begin{cases} 1, & \text{if } LGE_{A_{EL}}(x, y) > LGE_{B_{EL}}(x, y) \\ 0, & \text{otherwise} \end{cases} \quad (62)$$

根据以下规则得到边缘层融合图像 $F_{EL}(x, y)$, 即:

$$F_{EL}(x, y) = \begin{cases} A_{EL}(x, y), & \text{if } \mathbf{E}_{map}(x, y) = 1 \\ B_{EL}(x, y), & \text{otherwise} \end{cases} \quad (63)$$

2.3 逆 MSFDF 重构

如图 2 所示, 经过 MSFDF 分解和融合, 产生特征层融合图像 $F_{SL}, F_{TL}^{(i)}, F_{CL}^{(i)}$ 和 F_{EL} , 并通过设置不同权重系数 α, β, γ 和 δ 重构得到融合图像 F .

$$F(x, y) = \alpha F_{SL}(x, y) + \beta \sum_{i=1}^3 F_{TL}^{(i)}(x, y) + \gamma \sum_{i=1}^3 F_{CL}^{(i)}(x, y) + \delta F_{EL}(x, y) \quad (64)$$

MSFDF 融合方法的核心思想和具体实现步骤, 如算法 1 所示.

算法 1. MSFDF 方法步骤.

输入: 源图像 A, B ;

输出: 融合图像 F .

1. 读入源图像 A, B , 采用 MSFDF 分解产生平滑层 $\{A_{SL}, B_{SL}\}$, 纹理层 $\{A_{TL}, B_{TL}\}$, 轮廓层 $\{A_{CL}, B_{CL}\}$ 和边缘层 $\{A_{EL}, B_{EL}\}$.
2. 对平滑层 $\{A_{SL}, B_{SL}\}$ 采用视觉显著性分解策略生成平滑层融合图像 F_{EL} .
 - 2.1. 对平滑层 $\{A_{SL}, B_{SL}\}$ 采用 NSCT 分解产生平滑层高频子带 $\{H_{ASL}^{lk}, H_{BSL}^{lk}\}$ 和平滑层低频子带 $\{L_{ASL}, L_{BSL}\}$.
 - 2.2. 对第 1-4 层高频子带 $\{H_{ASL}^{l<5,k}, H_{BSL}^{l<5,k}\}$ 采用公式 (14) 的 GBVS 规则对其进行融合.
 - 2.3. 对第 5 层高频子带 $\{H_{ASL}^{l=5,k}, H_{BSL}^{l=5,k}\}$ 采用公式 (23) 的 PCNN 规则对其进行融合.
 - 2.4. 对低频子带 $\{L_{ASL}, L_{BSL}\}$ 采用公式 (36) 的低频综合测量算子 LM 规则对其进行融合.
 - 2.5. 对融合后的高低频子带 $\{H_{FSL}^{lk}, L_{FSL}\}$ 采用 NSCT 逆变换生成平滑层融合图像 F_{SL} .
3. 对纹理层 $\{A_{TL}, B_{TL}\}$ 采用公式 (45) 的纹理增强算子 TE 规则融合生成纹理层融合图像 F_{TL} .
4. 对轮廓层 $\{A_{CL}, B_{CL}\}$ 采用公式 (49) 的 PC 规则融合生成轮廓层融合图像 F_{CL} .
5. 对边缘层 $\{A_{EL}, B_{EL}\}$ 采用公式 (51) 的局部梯度能量算子 LGE 规则融合生成边缘层融合图像 F_{EL} .
6. 对融合后的特征层图像 F_{SL}, F_{TL}, F_{CL} 和 F_{EL} , 采用公式 (64) 的逆 MSFDF 重构生成最终的融合图像 F .

3 实验及结果分析

3.1 实验设置

3.1.1 测试图像

为了充分验证本文方法的性能, 实验选取 584 对多模态医学图像, 包括来自颅脑和腹部的 4 种模态图像, 分辨率设置为 256×256 . 颅脑图像基于 Harvard medical school website (<http://www.med.harvard.edu/AANLIB/home.html>) 公开发布的人脑图像数据集, 其中包括 59 对 CT/MR 图像和 86 对 MR/PET 图像. 此外, 由于缺乏公开腹部数据集的问题, 本文对 403 组不同成像机制获取的腹部图像数据集进行配准并验证, 其中包括 74 对 MR-T1/MR-T2 图像和 329 对 CT/PET 图像. 所有实验由 Matlab 2018 编写, 运行环境为 AMD Ryzen 7 5800 with Radeon Graphics 3.20 GHz, RAM 为 16.0 GB, 并对比分别从视觉和客观指标进行分析.

3.1.2 客观评价指标

本文使用 6 种常用的客观评价指标来全面定量评估不同融合方法的性能, 其大致分为基于图像结构相似性的峰值信噪比 (peak signal to noise ratio, PSNR)^[27]、结构相似性 (structural similarity, SSIM)^[28]、互信息 (mutual information, MI)^[29] 指标, 基于图像特征的空间频率 (spatial frequency, SF)^[30]、标准差 (standard deviation, SD)^[31] 指标和基于人类视觉感知的边缘保留 (Qabf)^[32] 指标 3 大类. 其中, PSNR 通过计算源图像与融合图像之间的均方误差来衡量其相似程度; SSIM 通过比较源图像与融合图像之间的相似性数值来评估融合图像特征及其色彩还原程度; MI 通过计算融合图像的信息熵以及融合图像与源图像的联合信息熵来度量两者相关性; SF 通过多尺度频谱分析评估融合图像病变侵袭区域层次区分及其细节刻画能力; 而 SD 和 Qabf 作为色彩评价指标, 分别用于度量融合图像色彩对比度及其色彩感知效果. 因此, 上述指标数值越高, 说明融合图像与源图像特征更为相似, 其融合图像边缘与纹理细节信息表达更为丰富, 同时, 病变侵袭区域层次区分更为显著和色彩还原程度更好, 更有利于提升医学诊断效率.

3.2 参数设置

参数 α, β, γ 和 δ 作为 MSFDF 特征层权重系数, 其取值大小直接影响着融合图像多特征之间的信息表达, 决定着融合图像纹理层次结构和与源图像的相似程度. 因此, 设置合适的权重系数 α, β, γ 和 δ 显得尤为重要. 以 MR-T1/

MR-T2 图像融合结果为例, 通过固定其他参数并调整一个参数的方法, 对多模态医学图像进行一系列融合^[12], 分析其融合图像与源图像相似程度, 并以相似性评价曲面的形式呈现, 如图 5 所示。




图 5 参数 α, β, γ 和 δ 不同取值下 MR-T1/MR-T2 图像融合相似性评价

首先, 参数 α, β 数值分别设定在 0.5–1.3 范围内和 0.1–0.5 范围内进行实验, 实验结果图 5(a)–图 5(c) 所示。随着参数 α, β 取值增加, 相似性评价曲面显著提升。在参数 α, β 值为 0.9 和 0.3 时, 该曲面达到峰值状态, 此时融合图像与源图像的像素灰度与结构相似程度最高, 融合表现最佳。然而, 当参数 α 超过 0.9 或 β 超过 0.3 时, 融合图像与源图像的相似程度下滑, 并且随着参数取值增大, 其图像融合性能下滑越严重。其次, 参数 γ, δ 数值分别设定在 0.6–1.4 范围内和 0.2–0.6 范围内进行实验, 实验结果图 5(d)–图 5(e) 所示。当参数 γ, δ 值为 0.4 和 1 时, 相似性曲面达到峰值状态, 此时融合图像与源图像的相似程度最高。然而, 当参数 γ, δ 为其他取值时, 融合图像与源图像的相似程度较低, 融合性能较差。

此外, 本文从视觉角度出发, 对不同特征层权重系数 α , β , γ 和 δ 取值下的融合效果进行评价, 以更加全面地分析其最佳取值. 以参数 α 变化下的融合图像为例, 如图 6 所示. 从图 6(c)–图 6(d) 的特写区域可以观察到, 当参数 α 低于 0.9 时, 颅脑基底核区域伴有明显的椒盐噪声, 腹部主动脉区域细节严重缺失. 同时其融合图像对比度过低, 导致无法辨别纹理病变情况, 严重影响医学诊断的可靠性. 从图 6(f)–图 6(g) 可以观察到, 当参数 α 超过 0.9 时, 融合图像出现严重失真, 且与源图像相似程度较差, 甚至可能导致脑沟回信息缺失. 然而, α 取值为 0.9 时, 从图 6(e) 可以观察到, 其融合图像极大还原了源图像特征信息, 并在增强纤维纹理表达、突出轮廓结构等方面具有较好的效果. 此外, 本文通过大量实验分析不同 β , γ 和 δ 取值下的视觉效果, 结果表明当 β , γ 和 δ 分别取值为 0.9、0.3、0.4 和 1 时, 无论是在相似性评价还是融合图像视觉效果, 融合图像与源图像的相似度最高, 多特征表达效果最好. 因此, 将特征层权重系数 α , β , γ 和 δ 的最优取值设定为 0.9、0.3、0.4 和 1.

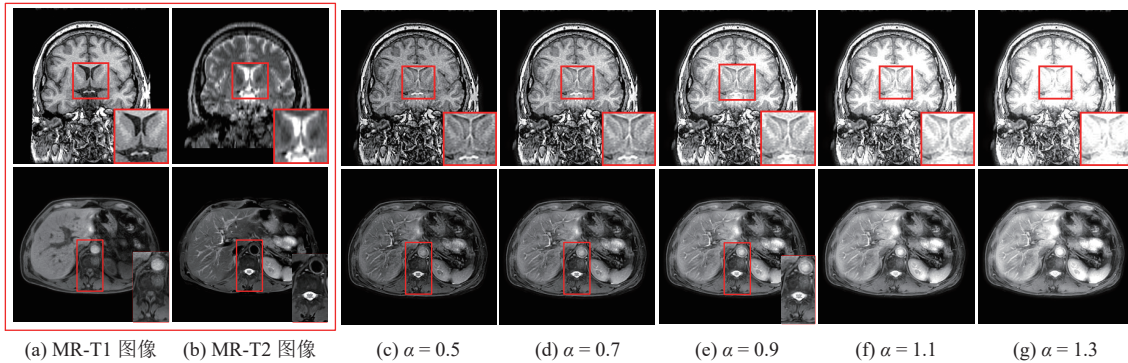


图 6 参数 α 不同取值下 MR-T1/MR-T2 图像融合结果

3.3 消融实验

3.3.1 MSFDF 框架消融实验

为验证 MSFDF 框架的有效性, 通过各特征层消融并与 MSFDF 框架比较分析, 验证 MSFDF 各特征层在图像融合中的作用, 实验结果如图 7 所示. 其中, 图 7(c)–图 7(f) 分别表示不含平滑、纹理、轮廓和边缘层的融合图像.

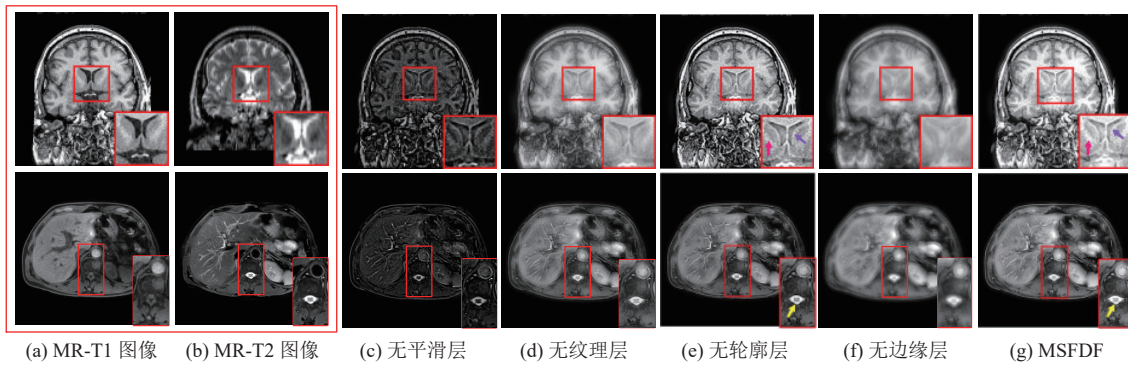


图 7 不同框架结构下 MR-T1/MR-T2 图像融合结果

从图 7(c) 可以观察到, 该融合图像包含大量边缘轮廓特征与纹理信息, 缺乏灰度变化情况, 难以判断患者腰椎组织水肿状态; 图 7(d) 中融合图像黏连病变区域的纤维细节模糊, 难以识别 MR-T1/MR-T2 融合所反映出的患者脑部与腹部生理结构与出血状态; 图 7(e) 中融合图像具有明显的细节纹理信息, 但在组织轮廓及其周围微小纤维纹理表现欠佳, 特别是相较于图 7(g) 的 MSFDF 框架, 位于红色和紫色箭头所指的右侧内囊区域和左侧基底节缺乏囊壁轮廓描述, 且黄色箭头所表示的椎管内部缺乏脊髓及其结缔组织信息; 图 7(f) 中融合图像有丰富的纹理细

节与灰度变化,但在颅脑基底核区域缺乏边缘特征.然而,从图 7(g)可以观察到,通过本文 MSFDF 框架产生的融合图像在灰度变化、器官边缘、组织轮廓以及纤维纹理表达等方面均有显著提升,特别是位于红色、紫色和黄色箭头所表示的组织区域处,该框架能够更全面地反映其生理结构及其病变信息.

在客观评价指标方面,从表 1 可以观察到,本文 MSFDF 框架在 PSNR, SSIM 和 SD 方面优异,表明 MSFDF 框架无论在图像特征保留、结构保持,还是对比度都具有更好的性能.特别地,相较于没有纹理层的框架,MSFDF 框架所产生的融合图像在 SF 和 Qabf 方面有所提升,这说明其通过纹理层提升了对纹理细节的空间层次描述和对纤维的感知能力,改善了当下多级滤波中存在的黏附病变区域侵袭状态区分程度低、纹理稀疏等问题.然而,尽管 MSFDF 框架增强了融合图像与源图像之间的相似程度,但其 MI 指标相对较低.这是因为随着融合图像细节和层次信息的增加,相似性指标 MI 往往会下降.因此,与没有纹理层的框架相比,MSFDF 融合图像包含了大量病变侵袭区域的细节层次信息,从而导致 MSFDF 融合图像的 MI 指标较低.此外,MSFDF 框架在其他相似性指标 PSNR 和 SSIM 方面优异,更加印证了 MSFDF 框架在提升图像相似程度的同时,增强了对病变侵袭区域细节和空间层次的描述.综上可以说明,MSFDF 框架中各个特征层起着重要作用:平滑层包含患者生理组织及其病变的大量灰度变化情况;纹理层感知纤维纹理和小结构病变,并描述黏附病变区域侵袭状态与细节信息;轮廓层反映大尺度病变信息,而边缘层则反映病变部位的边界特征.

表 1 不同框架结构下 MR-T1/MR-T2 图像融合的客观评价

融合框架	PSNR (dB)	SSIM	MI	SF	SD (pt)	Qabf
无平滑层	11.7315	0.4564	8.6438	0.1312	0.1479	0.5612
无纹理层	11.7542	0.4578	11.7914	0.0761	0.2397	0.5110
无轮廓层	11.7545	0.4576	11.4323	0.1321	0.2566	0.5973
无边缘层	11.7525	0.4578	11.5683	0.0363	0.2235	0.1445
MSFDF	11.7611	0.4579	11.6097	0.1334	0.2922	0.5975

注:粗体表示最优值

3.3.2 平滑层 NSCT 视觉显著性分解策略消融实验

为验证本文提出的平滑层 NSCT 视觉显著性分解策略的有效性,将 5 种具有代表性的 NSCT 融合规则运用到平滑层的融合中,与本文 NSCT 视觉显著性分解策略进行比较分析.其中,NSCT-DC^[11]表示经典 NSCT 融合策略;NSCT-PC^[19]表示基于相位一致性和局部拉普拉斯能量的 NSCT 融合策略;NSCT-EN^[33]表示基于局部能量和相位一致性的 NSCT 融合策略;NSCT-SML-SR^[5]表示基于稀疏表示和修正拉普拉斯的 NSCT 融合策略;NSCT-SR-PCNN^[3]表示基于稀疏表示和 PCNN 的 NSCT 融合策略.

实验结果如图 8 所示,其中,图 8(c) NSCT-DC^[11]表示经典 NSCT 融合策略;图 8(d) NSCT-PC^[19]表示基于相位一致性和局部拉普拉斯能量的 NSCT 融合策略;图 8(e) NSCT-EN^[33]表示基于局部能量和相位一致性的 NSCT 融合策略;图 8(f) NSCT-SML-SR^[5]表示基于稀疏表示和修正拉普拉斯的 NSCT 融合策略;图 8(g) NSCT-SR-PCNN^[3]表示基于稀疏表示和 PCNN 的 NSCT 融合策略;图 8(h) MSFDF 表示本文方法.图 8(c) 放大区域显示融合图像处于随机噪声中,其中红色箭头指向的右侧外侧裂区域被大量噪声笼罩,无法识别其病变情况.从图 8(d)–图 8(e)可以观察到,NSCT-PC 和 NSCT-EN 使这一情况得到明显改善,但仍可以明显看出红色箭头所指向的右侧外侧裂纹路不清晰,且蓝色箭头表示的双侧顶叶与脑沟回交界处灰度信息不连贯,均出现了严重的失真问题.从图 8(e)–图 8(g)可以观察到,来自源图像强度水平信息被明显削弱,对比度较低,无法识别较小的纤维信息;同时从放大区域可以观察到,由黄色箭头指向的主动脉信息偏向于 MR-T2 图像,且绿色箭头表示的椎管管内信息丢失,这在医学诊断中是不可取的.然而,从图 8(f)可以观察到,本文方法所提的 NSCT 视觉显著性分解策略产生的融合图像无论是在清晰度表达还是对比度方面都表现出更好的效果,能够准确表达细节、边缘、轮廓、灰度变化等各类特征.客观指标方面,表 2 显示本文平滑层 NSCT 融合规则在 PSNR, SSIM, MI, SF 和 SD 方面均取得了理想的结果,说明本文方法在结构相似性和细节纹理保持方面具有更好的性能.综上,本文方法所提的平滑层 NSCT 视觉显著性分解策略优于其他代表性 NSCT 融合规则.

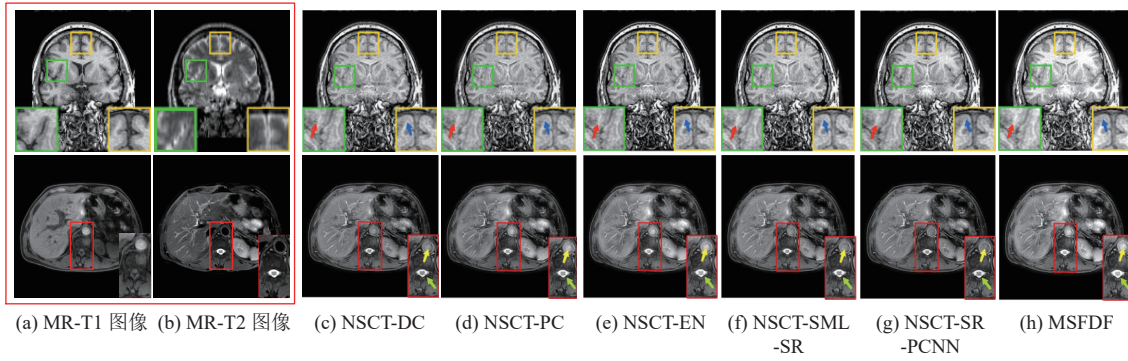


图8 不同平滑层方法下 MR-T1/MR-T2 图像融合结果

表2 不同平滑层方法下 MR-T1/MR-T2 图像融合的客观评价

方法	PSNR (dB)	SSIM	MI	SF	SD (pt)	Qabf
NSCT-DC ^[11]	11.7552	0.4578	11.2011	0.1303	0.2562	0.5973
NSCT-PC ^[19]	11.7562	0.4577	11.4571	0.1305	0.2657	0.6319
NSCT-EN ^[33]	11.7495	0.4575	11.0920	0.1297	0.2282	0.5891
NSCT-SML-SR ^[5]	11.7570	0.4578	11.4044	0.1309	0.2672	0.5992
NSCT-SR-PCNN ^[3]	11.7553	0.4578	11.3371	0.1305	0.2582	0.6019
本文方法	11.7611	0.4579	11.6097	0.1334	0.2922	0.5975

注: 粗体表示最优值

3.4 融合结果分析

3.4.1 比较方法

对比实验将 MSFDF 与近 3 年来发表的 6 种具有代表性的多模态医学图像融合方法进行比较, 如 MLCF^[12], PNSTCF^[34], NSST-IMSMG-VSM^[16], IFCNN^[13], DDIFN^[1], DAMFN^[14], 包括 3 种类型: 基于多级分解、基于 MST 以及基于深度学习的方法. 其中, MLCF 表示多级边缘保持滤波融合方法, PNSTCF 表示基于脉冲耦合神经网络的非下采样轮廓变换融合方法, NSST-IMSMG-VSM 表示基于视觉显著性多尺度形态学梯度融合方法; 作为深度学习的方法, IFCNN 表示卷积神经网络融合方法, DDIFN 表示基于双鉴别器的生成对抗网络融合方法, DAMFN 表示预训练模型特征提取的生成对抗网络融合方法.

为证明本文方法的有效性, 实验分别在 CT/MR, MR-T1/MR-T2, MR/PET, CT/PET 这 4 组图像融合任务中与上述方法进行比较, 实验结果如表 3 所示. 从表 3 可以观察到, 本文方法量化指标高、耗时最少. 这说明本文方法无论在图像特征转移、边缘轮廓保留和细节纹理的表达, 还是在计算效率方面具有更好的性能. 下面详细分析本文方法在 CT/MR, MR-T1/MR-T2, MR/PET, CT/PET 图像融合任务中的结果.

表3 不同方法下多模态医学图像融合的客观评价

融合类别	方法	PSNR (dB)	SSIM	MI	SF	SD (pt)	Qabf	ART (s)
CT/MR 图像	MLCF ^[12]	9.2891	0.5179	8.6617	0.1154	0.3318	0.4701	9.58
	PNSTCF ^[34]	9.2907	0.5180	9.7329	0.1231	0.3459	0.5410	5.96
	NSST-IMSMG-VSM ^[16]	9.2881	0.5176	10.1448	0.1231	0.3252	0.5436	6.31
	IFCNN ^[13]	9.2881	0.5177	9.0440	0.1178	0.3040	0.5395	8.13
	DDIFN ^[1]	9.2913	0.5178	8.6494	0.1232	0.3333	0.4940	6.95
	DAMFN ^[14]	9.2865	0.5170	8.8603	0.1135	0.3118	0.5666	6.56
	MSFDF	9.2972	0.5188	10.5566	0.1239	0.3792	0.5514	5.52

表3 不同方法下多模态医学图像融合的客观评价(续)

融合类别	方法	PSNR (dB)	SSIM	MI	SF	SD (pt)	Qabf	ART (s)
MR-T1/MR-T2图像	MLCF ^[12]	11.7491	0.4572	10.2449	0.1047	0.2258	0.5273	14.37
	PNSTCF ^[34]	11.7531	0.4573	10.8865	0.1113	0.2491	0.5659	22.19
	NSST-IMSMG-VSM ^[16]	11.7523	0.4572	10.5480	0.1142	0.2508	0.5926	9.25
	IFCNN ^[13]	11.7513	0.4573	10.3983	0.1118	0.2335	0.5646	10.94
	DDIFN ^[1]	11.7256	0.4569	9.6717	0.0570	0.2322	0.3518	9.09
	DAMFN ^[14]	11.7490	0.4570	10.1095	0.1113	0.2305	0.6281	8.73
	MSFDF	11.7611	0.4579	11.6097	0.1334	0.2922	0.5975	8.69
MR/PET图像	MLCF ^[12]	7.9202	0.5158	1.5833	0.3912	0.4259	0.1381	13.50
	PNSTCF ^[34]	7.9188	0.5148	1.7033	0.4477	0.1610	0.2003	10.01
	NSST-IMSMG-VSM ^[16]	7.9223	0.5149	1.7373	0.4449	0.4537	0.2341	10.33
	IFCNN ^[13]	7.9214	0.5165	1.5632	0.3657	0.4222	0.2090	11.60
	DDIFN ^[1]	7.9047	0.5160	1.2007	0.3223	0.3534	0.1589	10.98
	DAMFN ^[14]	7.8936	0.5156	0.9692	0.3033	0.3066	0.1829	10.52
	MSFDF	7.9281	0.5187	1.8702	0.4814	0.4770	0.2344	9.98
CT/PET图像	MLCF ^[12]	10.5581	0.5836	1.3867	0.2648	0.3890	0.1236	9.39
	PNSTCF ^[34]	10.5643	0.5840	1.5083	0.2531	0.2810	0.1635	17.67
	NSST-IMSMG-VSM ^[16]	10.5532	0.5830	1.2744	0.2796	0.3674	0.1789	6.24
	IFCNN ^[13]	10.5325	0.5820	0.7652	0.2593	0.2624	0.1483	7.69
	DDIFN ^[1]	10.5199	0.5817	0.3951	0.1511	0.1722	0.1137	6.89
	DAMFN ^[14]	10.5281	0.5820	0.6863	0.2445	0.3420	0.1432	6.11
	MSFDF	10.5715	0.5843	1.6326	0.2868	0.4345	0.2084	5.85

注: 粗体表示最优值

3.4.2 CT/MR 图像融合

CT 图像侧重描述骨骼致密结构, 而 MR 图像对软组织、血管等非骨骼结构及其像素强度分布有更好的描述效果, 其融合图像可以综合两者的优势, 以此高效识别患者颅脑骨骼、肿瘤等致密性器官与病变情况。

图 9 展示了本文方法与 6 种代表性融合方法在 CT/MR 图像中的融合结果, 其中, 图 9(c) MLCF^[12]表示多级边缘保持滤波融合方法; 图 9(d) PNSTCF^[34]表示基于脉冲耦合神经网络的 NSCT 融合方法; 图 9(e) NSST-IMSMG-VSM^[16]表示基于视觉显著性多尺度形态学梯度融合方法; 图 9(f) IFCNN^[13]表示卷积神经网络融合方法; 图 9(g) DDIFN^[1]表示基于双鉴别器的生成对抗网络融合方法; 图 9(h) DAMFN^[14]表示预训练模型特征提取的生成对抗网络融合方法; 图 9(i) MSFDF 表示本文方法。通过图 9(c) 中 MLCF 方法产生的融合图像双侧额叶边缘和纹理出现严重的模糊扭曲, 甚至在黏附病变区域和桥脑区域出现不同程度的细节缺失, 这在医学诊断中是不可接受的; 通过图 9(d) 中 PNSTCF 方法生成的融合图像颅脑边缘轮廓出现明显的伪影和失真, 无法准确体现其颅骨病变情况, 同时在双侧额叶和桥脑等区域只反映出 CT 图像信息, 严重影响了辅助诊断的可靠性; 然而, NSST-IMSMG-VSM 方法改善了这一问题, 但从图 9(e) 看出, 其融合图像对细节描述仍不够充分, 甚至在颅脑轮廓区域出现密度失真的状况; 对于深度学习融合方法, 图 9(f) 所示的 IFCNN 方法对噪声鲁棒性较差, 其融合图像组织纹理、纤维等处细节表达模糊; 图 9(g) 所示的 DDIFN 方法产生的融合图像存在着部分组织区域引入错误边缘信息的问题; 此外, 通过图 9(h) 中 DAMFN 方法, 源图像能量损耗严重, 导致融合图像对比度较差, 无法识别脑部血管瘤等微小病变结构。然而, 从图 9(i) 可以观察到, 本文方法 MSFDF 相较于其他方法, 融合图像无论是在边缘细节和黏附病变侵袭表达, 还是与源图像相似程度都有所提升, 同时也更好地权衡了 CT/MR 图像之间的病变描述信息。

此外, 从表 3 客观指标评价可以看出, MSFDF 方法在 PSNR、SSIM、MI、SD 和 SF 方面结果优异, 说明其在图像特征转移、结构保持和细节保留等方面都具有较好表现。特别地, MSFDF 方法在 SD 和 SF 方面具有优势, 这

表明其对纹理层次与细节、黏连病变区域侵袭状态的表达具有更好效果. 但 Qabf 指标度量方面表现不足. 分析其原因, MSFDF 方法一大优势是在提高融合图像与源图像相似度的基础上, 平衡融合图像中 CT/MR 图像特征的比例. 对于医学诊断, 融合图像尽可能均衡且细致地反映 CT/MR 图像信息, 对医生深入判断患者病情是至关重要的. 从表 4 可以观察到, 本文方法在各特征中尽可能地以相同程度保留了 CT/MR 图像信息, 然而, 其他方法融合图像更倾向于 CT 或 MR 图像信息. 特别地, 对于 DAMFN 方法, 其融合图像与各多模态图像相似度差距较大, 且更偏向于表达 CT 图像信息, 因此难免出现伪影等错误信息和 Qabf 指标度量过高的情况. 通过以上分析, 本文方法 MSFDF 在 CT/MR 图像融合中表现最佳.

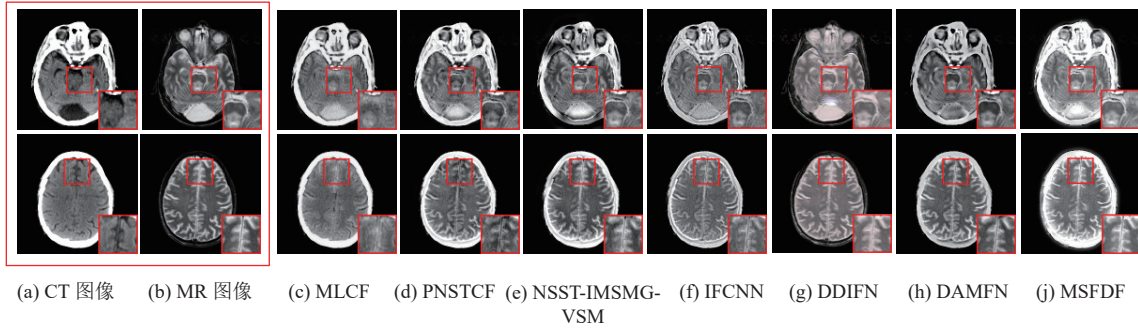


图 9 不同方法下 CT/MR 图像融合结果

表 4 不同方法下 CT/MR 图像融合的相似性评价

方法	PSNR (dB)		SSIM	
	CT	MR	CT	MR
MLCF ^[12]	7.4777	11.1005	0.5198	0.5159
PNSTCF ^[34]	7.4789	11.1024	0.5197	0.5163
NSST-IMSMG-VSM ^[16]	7.4754	11.1009	0.5197	0.5156
IFCNN ^[13]	7.4750	11.1013	0.5197	0.5157
DDIFN ^[1]	7.4778	11.1049	0.5197	0.5160
DAMFN ^[14]	7.4630	11.1100	0.5194	0.5147
MSFDF	7.4930	11.1013	0.5201	0.5174

注: 粗体表示最优值 (同种指标数值整体最大且数值之间差值最小)

3.4.3 MR-T1/MR-T2 图像融合

MR-T1 图像通过描述器官轮廓结构和细节纹理特征识别病灶位置, 而 MR-T2 图像通过描述组织像素强度分布侧重表现病程信息, 其融合图像能够较为全面地判断患者腹部、肝脏及其软组织区域的病变性质.

图 10 展示了本文方法与 6 种代表性融合方法在 MR-T1/MR-T2 图像中的融合结果, 其中, 图 10(c) MLCF^[12]表示多级边缘保持滤波融合方法; 图 10(d) PNSTCF^[34]表示基于脉冲耦合神经网络的 NSCT 融合方法; 图 10(e) NSST-IMSMG-VSM^[16]表示基于视觉显著性多尺度形态学梯度融合方法; 图 10(f) IFCNN^[13]表示卷积神经网络融合方法; 图 10(g) DDIFN^[1]表示基于双鉴别器的生成对抗网络融合方法; 图 10(h) DAMFN^[14]表示预训练模型特征提取的生成对抗网络融合方法; 图 10(i) MSFDF 表示本文方法. 从图 10(c) 放大区域可以看出, 通过 MLCF 方法产生的融合图像普遍存在着血管边缘与组织纹理等多处信息丢失, 甚至在椎管区域缺失骨髓和主动脉信息; 通过图 10(d) 中 PNSTCF 方法产生的融合图像动脉、脊椎轮廓出现伪影和失真, 且过度侧重对 MR-T1 图像细节纹理特征表达, 导致融合图像缺乏病变侵袭和病程信息; 对于图 10(e) 中的 NSST-IMSMG-VSM 方法, 其产生的融合图像出现了腹部盆腔轮廓密度失真等问题. 图 10(f)–图 10(h) 中 3 种深度学习融合方法产生的融合图像存在不同程度的信息缺失. 对于 IFCNN 和 DDIFN 方法, 融合图像边缘轮廓伪影、细节缺乏, 且过多偏向于 MR-T1 图像信息, 缺乏对 MR-T2

图像中对出血情况的描述, 违背了医学图像融合的本质; 对于 DAMFN 方法, 融合过程中源图像能量被极大削弱, 导致椎体附着区域被阴影笼罩. 然而, 从图 10(i) 可以观察到, 本文方法 MSFDF 相较于其他方法, 融合图像无论是对图像特征转移与表达、对比度描述, 还是刻画空间信息等方面都具有更好的效果. 此外, 在客观指标评价方面, MR-T1/MR-T2 图像融合表现类似于 CT/MR 融合情况. 同样, MSFDF 方法目的在于提升 MR-T1/MR-T2 图像信息平衡程度的前提下, 提高融合图像质量, 因此, 在平衡图像信息的过程中, MSFDF 方法容易出现融合图像 Qabf 指标略低于其他方法的情况. 通过以上分析, 本文方法 MSFDF 在 MR-T1/MR-T2 图像融合中表现最佳.

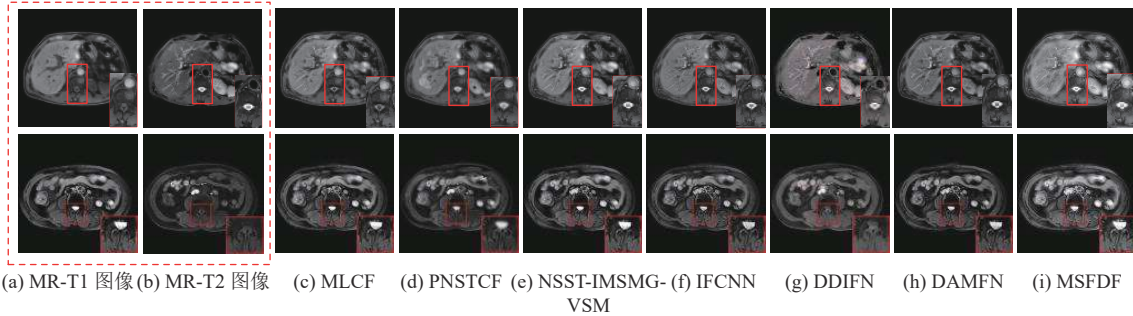


图 10 不同方法下 MR-T1/MR-T2 图像融合结果

3.4.4 MR/PET 图像融合

MR 图像侧重描述患者非致密性病灶位置及其性质, 而 PET 作为彩色图像, 侧重描述其病变侵袭程度, 两者的融合不同于灰度医学图像的融合, 其融合图像可以更加全面地判断非致密性病灶的病变情况. 在 MSFDF 分解中, 引入 RGB 和 YUV 颜色空间转换. 首先, 将 PET 图像由 RGB 颜色空间转换为 Y、U、V 这 3 个层. 其次, 利用 MSFDF 方法将灰度层 Y 图像与 MR 图像进行融合. 最后, 将融合后的 Y 层和 PET 图像的 U 层、V 层转换到 RGB 空间, 得到最终的融合图像.

图 11 展示了本文方法与 6 种代表性融合方法在 MR/PET 图像中的融合结果, 其中, 图 11(c) MLCF^[12]表示多级边缘保持滤波融合方法; 图 11(d) PNSTCF^[34]表示基于脉冲耦合神经网络的 NSCT 融合方法; 图 11(e) NSST-IMSMG-VSM^[16]表示基于视觉显著性多尺度形态学梯度融合方法; 图 11(f) IFCNN^[13]表示卷积神经网络融合方法; 图 11(g) DDIFN^[1]表示基于双鉴别器的生成对抗网络融合方法; 图 11(h) DAMFN^[14]表示预训练模型特征提取的生成对抗网络融合方法; 图 11(i) MSFDF 表示本文方法. 通过图 11(c) 中 MLCF 方法产生的融合图像边缘纹理及其色彩出现较为严重的失真情况; 通过图 11(d) 中 PNSTCF 方法产生的融合图像大部分区域存在过度表达 MR 图像的问题, 无法在脑沟回区域附近识别出纤维纹理、毛细血管等位置信息; 然而, NSST-IMSMG-VSM 方法通过对 PET 色彩显著性提取, 改善了这一问题, 但图 11(e) 中的融合图像细节特征描述仍不够充分; 对于深度学习的融合方法, 图 11(f) 所示的 IFCNN 方法产生的融合图像丢失了大量色度信息, 出现了侵袭状态色彩还原不足和细节模糊的情况, 此外其被椒盐噪声所笼罩, 严重影响对细小结构病变的观察; 图 11(g)–图 11(h) 中 DDIFN 和 DAMFN 方法产生的融合图像对比度和色彩区分度极差, 甚至出现了仅描述 PET 图像信息, 未体现 MR 图像信息的情况, 导致无法准确识别部分病灶情况. 然而, 从图 11(i) 可以看出, 本文方法 MSFDF 相较于其他方法, 融合图像无论是对源图像的色度、纤维纹理的保留与还原, 还是在刻画病灶位置、状态和新陈代谢的平衡能力方面都有显著提升, 有助于医生对当下病灶状态做出更加全面的诊断.

此外, 从表 3 客观指标评价可以观察到, 本文方法 MSFDF 相较于对比方法指标优异, 表明其在突出特征转移、增强色彩饱和度、表达边缘和细节纹理等方面都具有优势. 特别地, 其在 MI、SD 和 Qabf 方面指标较为突出, 说明 MSFDF 方法提升了融合图像与源图像之间的色彩相似程度和对色彩变化的感知能力, 改善了现有融合方法所面临的边缘细节丢失、色彩还原不足的问题. 通过以上分析, 本文方法 MSFDF 在 MR/PET 图像融合中表现最佳.

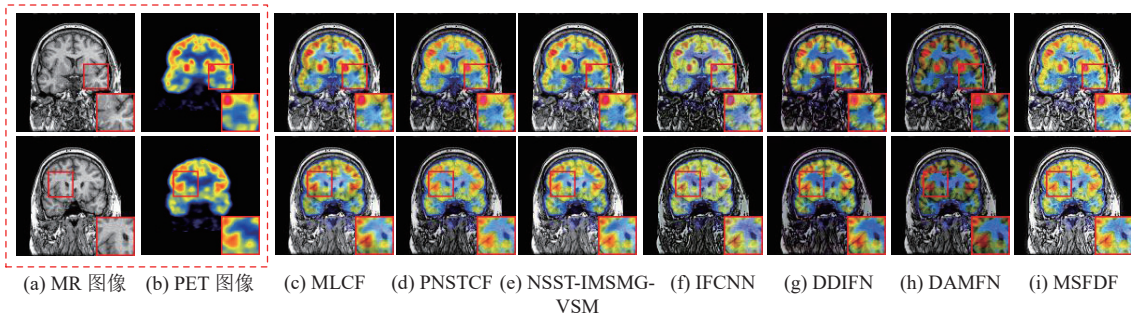


图 11 不同方法下 MR/PET 图像融合结果

3.4.5 CT/PET 图像融合

CT 图像侧重描述骨骼致密结构, 而 PET 图像通过放射性标记药物追踪和测量组织的代谢活动水平, 描述病灶周围病变侵袭程度, 其融合图像可以帮助医生高效评估腹部致密性病灶位置、范围以及性质。

图 12 展示了本文方法 MSFDF 与 6 种代表性融合方法在 CT/PET 图像中的融合结果, 其中, 图 12(c) MLCF^[12] 表示多级边缘保持滤波融合方法; 图 12(d) PNSTCF^[34] 表示基于脉冲耦合神经网络的 NSCT 融合方法; 图 12(e) NSST-IMSMG-VSM^[16] 表示基于视觉显著性多尺度形态学梯度融合方法; 图 12(f) IFCNN^[13] 表示卷积神经网络融合方法; 图 12(g) DDIFN^[1] 表示基于双鉴别器的生成对抗网络融合方法; 图 12(h) DAMFN^[14] 表示预训练模型特征提取的生成对抗网络融合方法; 图 12(i) MSFDF 表示本文方法。图 12(c) 所示的 MLCF 方法, 其融合图像出现肾脏区域色度边缘模糊, 脊柱对比度不足的问题; 通过图 12(d) 中 PNSTCF 方法产生的融合图像难以观察毛细血管和脊髓病变情况; 从图 12(e) 中 NSST-IMSMG-VSM 方法产生融合图像可以看出, 脊髓色度与纹理失真, 同时无法较好地反映来自 CT 图像纹理信息, 严重影响了医学诊断的准确性; 通过图 12(f) 中 IFCNN 方法产生的融合图像可以观察到, 脊柱、肾脏等区域过度表达 PET 图像信息, 使得在医学诊断中无法识别病变具体的位置信息和器官结构; 在图 12(g)–图 12(h) 中, 通过 DDIFN 和 DAMFN 方法产生的融合图像纹理细节被随机噪声所掩盖, 右侧肾脏和脊髓纹理信息缺失严重, 同时源图像能量损耗严重, 使得医生无法通过融合图像识别侵袭色彩所表现的病程信息。然而, 从图 12(i) 可以观察到, 本文方法 MSFDF 明显改善了上述问题, 融合图像不仅更好地增强致密性结构, 也充分还原病变色彩侵袭状况, 同时提高了融合图像对比度和纹理细节, 充分表达 CT/PET 图像的特征信息。此外, 表 3 中的客观评价指标也验证了上述结论。通过以上分析, 本文方法 MSFDF 在 CT/PET 图像融合中表现最佳。

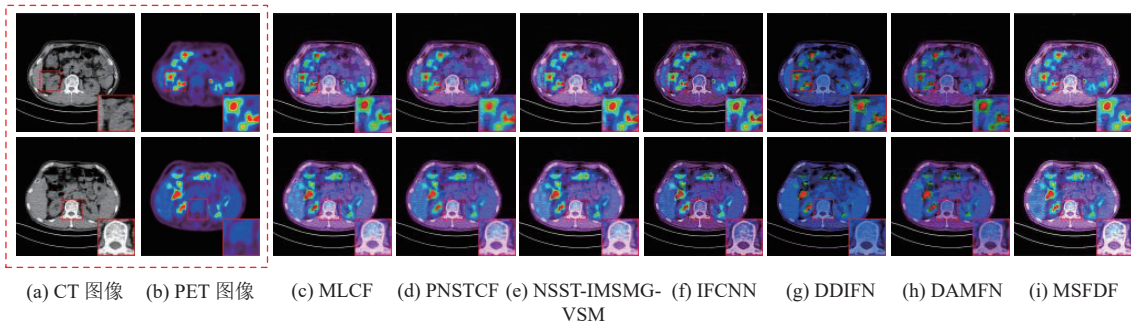


图 12 不同方法下 CT/PET 图像融合结果

3.4.6 算法效率

为进一步分析本文方法的有效性, 本文对各组融合方法所需的时间和资源开销进行对比与分析。表 3 列举了各组融合方法的平均运行时间。在多模态医学图像融合中, 本文方法 MSFDF 的平均运行时间为 7.51 s, 相较于其他方法具有优势。分析其原因: 首先, MSFDF 方法通过设计纹理增强算子等简单运算规则进行同时的逐层融合, 避

免了因融合规则复杂和融合计算分步而导致的时间冗余. 其次, MSFDF 框架简单且精炼, 并针对不同特征层进行了有针对性的处理, 兼顾了该方法融合效果与计算效率. 例如, 在该框架中, 仅针对平滑层的潜在特征信息进行处理, 处理方法为具有快速和并行计算能力的视觉显著性分解策略, 极大地平衡了融合效果与计算效率. 相比之下, PNSTCF 和 NSST-IMSMG-VSM 方法多次使用脉冲耦合神经网络对图像地各个分解层进行计算, 并且缺乏并行性; MLCF 方法采用复杂的多级形态学分解框架, 并对分解层使用能量和脉冲耦合神经网络方法, 进一步增加了该方法的计算量; IFCNN 方法使用多层卷积神经网络提取图像特征, 需要进行大量的矩阵乘法和卷积操作; 而 DDIFN 和 DAMFN 方法使用生成对抗神经网络结合卷积计算对图像进行融合, 具有大量参数计算和较慢的推理速度.

对于计算资源开销, 本文方法 MSFDF 与其他方法处于同一规模水平. MSFDF 方法通过简单的滤波、特征决策融合以及较低层次的 NSCT 进行融合操作, 其中未涉及较复杂的数据结构、大规模嵌套循环以及递归操作, 算法的空间复杂度为 $O(n)$, n 为源图像 I_m 像素点数量. 同时, MSFDF 方法以特征模块为单位进行融合, 减少了全局变量的使用, 降低了算法造成的资源开销. 在对比方法中, PNSTCF、NSST-IMSMG-VSM 和 MLCF 方法使用多尺度分解滤波以及多级分解滤波对图像进行分解, 并对分解层使用较低参数量的脉冲耦合神经网络、能量等规则进行融合, 未使用大规模的数据结构, 一定程度上保证了与 MSFDF 方法一致的资源开销; 而 IFCNN、DDIFN 和 DAMFN 方法使用图神经网络, 虽然在特征提取和融合过程中产生并使用了大量参数, 但这些方法的量级并未超出 MSFDF 方法的规模. 综上所述, 在多模态医学图像融合中, 本文方法 MSFDF 在融合效果和算法效率上均优于其他方法.

4 总结与展望

为解决现有融合方法中存在的部分光谱退化、黏连病变侵袭区域边缘细节缺失和色彩还原不足等问题, 本文提出了 MSFDF 融合方法, 实现多模态医学图像融合领域中细化和增强多特征表达. 首先, 提出 MSFDF 框架细化图像特征, 解决了因图像分解不充分而导致后续特征侵袭细节难以区分、边缘与细节特征缺失等问题; 其次, 提出一种视觉显著性分解策略, 多尺度多维度地挖掘平滑层图像能量、部分纤维纹理等特征, 提升源图像信息利用率; 同时, 提出纹理增强算子, 从图像空间与强度方面提取纹理层微小结构信息, 增强了融合方法对纤维质感的感知能力, 解决了黏连病变侵袭区域细节无法区分等问题. 实验结果表明, 该方法在视觉效果、客观评价和计算效率等方面均优于其他方法, 是一种有效且可行的频域医学图像融合方法. 此外, 鉴于当下研究缺乏公开腹部数据, 本文还配准并发布了多模态腹部医学图像数据集, 为后续医学图像融合方法的普适性研究提供了有力支撑.

然而, 本文方法 MSFDF 在保持更高的融合图像与源图像相似程度的基础上, 侧重增强图像特征保留与表达. 在这个过程中, 对于 CT/MR 和 MR-T1/MR-T2 灰度医学融合图像的边缘指标 Q_{abf} 存在一定牺牲. 因此, 在接下来的工作中进一步研究灰度医学图像的边缘表达, 重点改进边缘层融合规则, 并在保证现有方法优势的前提下, 进一步提升边缘表达等融合性能, 减少时间开销, 为医学诊断提供更加清晰有效的影像信息.

References:

- [1] Liu H, Li SS, Zhu JC, Deng K, Liu M, Nie LQ. DDIFN: A dual-discriminator multi-modal medical image fusion network. *ACM Trans. on Multimedia Computing, Communications, and Applications*, 2023, 19(4): 145. [doi: [10.1145/3574136](https://doi.org/10.1145/3574136)]
- [2] Gao XH, Taylor S, Pang W, Hui R, Lu X, Braden B. Fusion of colour contrasted images for early detection of oesophageal squamous cell dysplasia from endoscopic videos in real time. *Information Fusion*, 2023, 92: 64–79. [doi: [10.1016/j.inffus.2022.11.023](https://doi.org/10.1016/j.inffus.2022.11.023)]
- [3] Xia JM, Chen YM, Chen AY, Chen YC. Medical image fusion based on sparse representation and PCNN in NSCT domain. *Computational and Mathematical Methods in Medicine*, 2018, 2018: 2806047. [doi: [10.1155/2018/2806047](https://doi.org/10.1155/2018/2806047)]
- [4] Li XS, Zhou FQ, Tan HS, Zhang WN, Zhao CY. Multimodal medical image fusion based on joint bilateral filter and local gradient energy. *Information Sciences*, 2021, 569: 302–325. [doi: [10.1016/j.ins.2021.04.052](https://doi.org/10.1016/j.ins.2021.04.052)]
- [5] Li YY, Sun YJ, Huang XH, Qi GQ, Zheng MY, Zhu ZQ. An image fusion method based on sparse representation and sum modified-Laplacian in NSCT domain. *Entropy*, 2018, 20(7): 522. [doi: [10.1016/10.3390/e20070522](https://doi.org/10.1016/10.3390/e20070522)]
- [6] Xu LN, Xie GQ, Zhou ST. Panchromatic and multispectral image fusion combining GIHS, NSST, and PCA. *Applied Sciences*, 2023, 13(3): 1412. [doi: [10.1016/10.3390/app13031412](https://doi.org/10.1016/10.3390/app13031412)]

- [7] Li JJ, Wang Q. Intra-group and inter-group electrocardiograph coding image fusion and classification based on multi-scale group convolution feature fusion network. *Biomedical Signal Processing and Control*, 2022, 72: 103374. [doi: [10.1016/j.bspc.2021.103374](https://doi.org/10.1016/j.bspc.2021.103374)]
- [8] Wang ZB, Cui ZJ, Zhu Y. Multi-modal medical image fusion by Laplacian pyramid and adaptive sparse representation. *Computers in Biology and Medicine*, 2020, 123: 103823. [doi: [10.1016/j.compbimed.2020.103823](https://doi.org/10.1016/j.compbimed.2020.103823)]
- [9] Chao Z, Duan XG, Jia SF, Guo XJ, Liu H, Jia FC. Medical image fusion via discrete stationary wavelet transform and an enhanced radial basis function neural network. *Applied Soft Computing*, 2022, 118: 108542. [doi: [10.1016/j.asoc.2022.108542](https://doi.org/10.1016/j.asoc.2022.108542)]
- [10] Dogra A, Kumar S. Multi-modality medical image fusion based on guided filter and image statistics in multidirectional shearlet transform domain. *Journal of Ambient Intelligence and Humanized Computing*, 2023, 14(9): 12191–12205. [doi: [10.1016/10.1007/s12652-022-03764-6](https://doi.org/10.1016/10.1007/s12652-022-03764-6)]
- [11] Bhatnagar G, Wu QMJ, Liu Z. Directive contrast based multimodal medical image fusion in NSCT domain. *IEEE Trans. on Multimedia*, 2013, 15(5): 1014–1024. [doi: [10.1109/TMM.2013.2244870](https://doi.org/10.1109/TMM.2013.2244870)]
- [12] Tan W, Thiton W, Xiang P, Zhou HX. Multi-modal brain image fusion based on multi-level edge-preserving filtering. *Biomedical Signal Processing and Control*, 2021, 64: 102280. [doi: [10.1016/j.bspc.2020.102280](https://doi.org/10.1016/j.bspc.2020.102280)]
- [13] Zhang Y, Liu Y, Sun P, Yan H, Zhao XL, Zhang L. IFCNN: A general image fusion framework based on convolutional neural network. *Information Fusion*, 2020, 54: 99–118. [doi: [10.1016/j.inffus.2019.07.011](https://doi.org/10.1016/j.inffus.2019.07.011)]
- [14] Liu H, Li SS, Gao SS, Deng K, Xu G, Zhang CM. Research on dual-adversarial MR image fusion network using pre-trained model for feature extraction. *Ruan Jian Xue Bao/Journal of Software*, 2023, 34(5): 2134–2151 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6772.htm> [doi: [10.13328/j.cnki.jos.006772](https://doi.org/10.13328/j.cnki.jos.006772)]
- [15] Kaur M, Singh D. Fusion of medical images using deep belief networks. *Cluster Computing*, 2020, 23(2): 1439–1453. [doi: [10.1007/s10586-019-02999-x](https://doi.org/10.1007/s10586-019-02999-x)]
- [16] Zhang Y, Jin MM, Huang G. Medical image fusion based on improved multi-scale morphology gradient-weighted local energy and visual saliency map. *Biomedical Signal Processing and Control*, 2022, 74: 103535. [doi: [10.1016/j.bspc.2022.103535](https://doi.org/10.1016/j.bspc.2022.103535)]
- [17] Yang CX, He YN, Sun C, Jiang S, Li Y, Zhao P. Infrared and visible image fusion based on QNSCT and guided filter. *Optik*, 2022, 253: 168592. [doi: [10.1016/j.ijleo.2022.168592](https://doi.org/10.1016/j.ijleo.2022.168592)]
- [18] Tan W, Zhang JJ, Xiang P, Zhou HX, Thiton W. Infrared and visible image fusion via NSST and PCNN in multiscale morphological gradient domain. In: *Proc. of the 2020 SPIE Photonics Europe—Optics, Photonics and Digital Technologies for Imaging Applications VI*, Vol. 11353. SPIE, 2020. 297–303. [doi: [10.1117/12.2551830](https://doi.org/10.1117/12.2551830)]
- [19] Zhu ZQ, Zheng MY, Qi GQ, Wang D, Xiang Y. A phase congruency and local Laplacian energy based multi-modality medical image fusion method in NSCT domain. *IEEE Access*, 2019, 7: 20811–20824. [doi: [10.1109/ACCESS.2019.2898111](https://doi.org/10.1109/ACCESS.2019.2898111)]
- [20] Jiang Y, Wang MH. Image fusion using multiscale edge-preserving decomposition based on weighted least squares filter. *IET Image Processing*, 2014, 8(3): 183–190. [doi: [10.1049/iet-ipr.2013.0429](https://doi.org/10.1049/iet-ipr.2013.0429)]
- [21] Zhang Q, Shen XY, Xu L, Jia JY. Rolling guidance filter. In: *Proc. of the 13th European Conf. on Computer Vision*. Zurich: Springer, 2014. 815–830. [doi: [10.1007/978-3-319-10578-9_53](https://doi.org/10.1007/978-3-319-10578-9_53)]
- [22] Galetto FJ, Deng G, Al-Nasrawi M, Waheed W. Edge-aware filter based on adaptive patch variance weighted average. *IEEE Access*, 2021, 9: 118291–118306. [doi: [10.1109/ACCESS.2021.3106907](https://doi.org/10.1109/ACCESS.2021.3106907)]
- [23] Tan W, Zhou HX, Song JLQ, Li H, Yu Y, Du J. Infrared and visible image perceptive fusion through multi-level Gaussian curvature filtering image decomposition. *Applied Optics*, 2019, 58(12): 3064–3073. [doi: [10.1364/AO.58.003064](https://doi.org/10.1364/AO.58.003064)]
- [24] Yan HB, Li ZM. Infrared and visible image fusion based on multi-scale feature decomposition. *Optik*, 2020, 203: 163900. [doi: [10.1016/j.ijleo.2019.163900](https://doi.org/10.1016/j.ijleo.2019.163900)]
- [25] Harel J, Koch C, Perona P. Graph-based visual saliency. In: *Proc. of the 19th Int'l Conf. on Neural Information Processing Systems*. MIT Press, 2006. 545–552.
- [26] Li WS, Jia LH, Du J. Multi-modal sensor medical image fusion based on multiple salient features with guided image filter. *IEEE Access*, 2019, 7: 173019–173033. [doi: [10.1109/ACCESS.2019.2953786](https://doi.org/10.1109/ACCESS.2019.2953786)]
- [27] Hore A, Ziou D. Image quality metrics: PSNR vs. SSIM. In: *Proc. of the 20th Int'l Conf. on Pattern Recognition*. Istanbul: IEEE, 2010. 2366–2369. [doi: [10.1109/ICPR.2010.579](https://doi.org/10.1109/ICPR.2010.579)]
- [28] Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. Image quality assessment: From error visibility to structural similarity. *IEEE Trans. on Image Processing*, 2004, 13(4): 600–612. [doi: [10.1109/TIP.2003.819861](https://doi.org/10.1109/TIP.2003.819861)]
- [29] Qu GH, Zhang DL, Yan PF. Information measure for performance of image fusion. *Electronics Letters*, 2002, 38(7): 313–315. [doi: [10.1049/el:20020212](https://doi.org/10.1049/el:20020212)]
- [30] Eskicioglu AM, Fisher PS. Image quality measures and their performance. *IEEE Trans. on Communications*, 1995, 43(12): 2959–2965.

[doi: [10.1109/26.477498](https://doi.org/10.1109/26.477498)]

- [31] Rao YJ. In-fibre Bragg grating sensors. *Measurement Science and Technology*, 1997, 8(4): 355–375. [doi: [10.1088/0957-0233/8/4/002](https://doi.org/10.1088/0957-0233/8/4/002)]
- [32] Xydeas CS, Petrovic V. Objective image fusion performance measure. *Electronics Letters*, 2000, 36(4): 308–309. [doi: [10.1049/el:20000267](https://doi.org/10.1049/el:20000267)]
- [33] Huang XH, Qi GQ, Wei HY, Chai Y, Sim J. A novel infrared and visible image information fusion method based on phase congruency and image entropy. *Entropy*, 2019, 21(12): 1135. [doi: [10.3390/e21121135](https://doi.org/10.3390/e21121135)]
- [34] Ibrahim SI, Makhlof MA, El-Tawel GS. Multimodal medical image fusion algorithm based on pulse coupled neural networks and nonsubsampling contourlet transform. *Medical & Biological Engineering & Computing*, 2023, 61(1): 155–177. [doi: [10.1007/s11517-022-02697-8](https://doi.org/10.1007/s11517-022-02697-8)]

附中文参考文献:

- [14] 刘慧, 李珊珊, 高珊珊, 邓凯, 徐岗, 张彩明. 预训练模型特征提取的双对抗磁共振图像融合网络研究. *软件学报*, 2023, 34(5): 2134–2151. <http://www.jos.org.cn/1000-9825/6772.htm> [doi: [10.13328/j.cnki.jos.006772](https://doi.org/10.13328/j.cnki.jos.006772)]



刘慧(1978—), 女, 博士, 教授, 博士生导师, CCF 专业会员, 主要研究领域为图像处理, 数据挖掘与可视化.



盛玉瑞(1994—), 女, 硕士, 主要研究领域为医学图像诊断.



朱积成(1999—), 男, 硕士生, CCF 学生会会员, 主要研究领域为医学图像处理.



张彩明(1965—), 男, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为计算机图形学, 计算机视觉, 医学影像处理, 时序数据分析.



王欣雨(1999—), 女, 博士生, CCF 学生会会员, 主要研究领域为大模型知识增强.



聂礼强(1985—), 男, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为计算机视觉, 关联模态的显性融合, 数据模型的知识引导.