

基于深度学习的多模态医学图像融合方法研究进展

薛湛琦, 王远军

上海理工大学医学影像工程研究所, 上海 200093

【摘要】医学图像融合方法可以将有用的信息整合到一张图像上,提高单张图像的信息量。对多模态医学图像进行融合时,如何对图像进行有效的变换,提取到不同图像中独有的特征,并施以适当的融合规则是医学图像融合领域研究的重点。近年随着深度学习的快速发展,深度学习被广泛应用于医学图像领域,代替传统方法中的一些人工操作,并在图像表示、图像特征提取以及融合规则的选择方面显示出独特优势。本文针对基于深度学习的医学图像融合进展予以探讨,介绍卷积神经网络、卷积稀疏表示、深度自编码和深度信念网络这些常用于医学图像融合的框架,对一些应用于融合过程不同步骤的深度学习方法进行分析 and 总结,最后,分析当前基于深度学习的融合方法的不足并展望了未来的研究方向。

【关键词】医学图像;图像融合;深度学习;卷积神经网络;深度信念网络

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2020)05-0579-05

Advances in multimodal medical image fusion method based on deep learning

XUE Zhanqi, WANG Yuanjun

Institute of Medical Imaging Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China

Abstract: The medical image fusion method can integrate useful information into a single image to increase the amount of information in a single image. When multimodal medical images are fused, how to effectively transform the images, extract the special features in different images, and apply appropriate fusion rules becomes the focus of research on medical image fusion. In recent years, with the rapid development of deep learning, deep learning has been widely used in medical images by replacing some manual operations in traditional methods and has shown unique advantages in image representation, image feature extraction and the selection of fusion rules. Herein the medical image fusion based on deep learning is discussed. Several deep learning methods that are commonly used in the framework of medical image fusion, such as convolutional neural network, convolutional sparse representation, deep self-encoding and deep belief network are introduced. Some deep learning methods that are applied to different steps of the fusion process are also summarized. Finally, the disadvantages of recent researches on the image fusion based on deep learning are analyzed, and the research direction in future is forecasted.

Keywords: medical image; image fusion; deep learning; convolutional neural network; deep belief network

前言

随着计算机和成像技术的发展,医学图像成为辅助医生诊断与治疗的重要工具。由于成像机制不同,不同成像设备得到的单一模态图像携带着可以互相补充的信息。多模态医学图像融合技术可以将这些信息结合到一起获得一幅同时包括功能信息与结构信息的

融合图像,由此帮助医疗工作者准确快速地诊断和治疗疾病^[1]。图像融合的内容包括图像分解与重建、图像融合规则和图像质量评价。其中决定融合效果的关键在于图像分解过程中特征的提取和特征权重的测量与分配,而针对融合后的图像建立统一的客观评价指标也是一项具有挑战性的工作^[2]。

图像融合中常用的方法包括拉普拉斯金字塔^[3]、离散小波变换^[4]、非下采样轮廓波变换^[5]、稀疏表示^[6]等,这些方法都广泛应用于医学图像融合,但也存在许多缺陷。例如就多尺度分解方法而言,其中一个问题就是难以确定分解级数,级数太小无法获得足够的空间信息,太大则会导致图像融合时对噪声和误配过于敏感。不同模态的图像在分解后的融合过程中可以通过机器学习的方法对特征的权重进行分配^[7]。

【收稿日期】2019-12-20

【基金项目】国家自然科学基金(61201067);上海市自然科学基金(18ZR1426900)

【作者简介】薛湛琦,硕士研究生,研究方向:基于深度学习的医学图像处理,E-mail: xuezhanqi17@163.com

【通信作者】王远军,博士,副教授,研究方向:生物医学工程、医学图像处理,E-mail: yjusst@126.com

目前图像融合技术仍然不够成熟,在实际中面临的融合问题需要根据实际应用具体分析采用何种融合方法。近年来,随着深度学习的发展,基于深度学习的图像处理方法在计算机视觉领域取得了巨大的成功。在医学图像融合领域,深度学习方法可以帮助我们解决传统方法的上述问题,尤其在特征提取、图像表示方面有更大的优势和更好的效果,可见深度学习在医学图像融合领域有极大的潜力。

本文首先对医学图像融合与深度学习方法做简要描述,然后着重介绍几种深度学习方法在图像融合中的应用,最后对目前的融合方法进行总结,分析其中存在的问题,并对深度学习在医学图像领域的发展做出展望。

1 医学图像融合方法

1.1 多尺度方法

多模态医学图像融合中,多尺度变换是一种广泛应用的工具。这种方法使用多尺度变换来获得输入图像的多尺度表示,其中图像特征在变换域中表示。然后,通过根据特定的融合规则融合不同模态图像各级表示来获得融合的多尺度表示,其中系数的权重,以及相邻像素之间的相关性和不同系数之间的相关性是需要考虑的重要问题。

Zhang等^[8]对早期的基于多尺度分解的图像融合方法进行分类,介绍了包括基于金字塔的方法和基于经典小波在内的常用方法。一些其他计算机视觉方法,如各向异性热扩散^[9]、log-Gabor变换^[10]和支持度变换^[11]也已成功应用于基于多尺度分解的图像融合。通常,这些方法的主要优点是它们能够准确地分离图像的细尺度纹理细节、中尺度边缘和大尺度空间结构。这些优点有助于减少融合过程中的混叠伪像,产生符合人类视觉感知的融合结果。

1.2 稀疏表示方法

稀疏表示是一种图像表示理论,已成功应用于许多图像处理问题,如去噪、插值和识别^[12-13]。基于稀疏表示的图像融合算法的主要思路是先通过字典下的稀疏表示来提取图像特征,然后按照某种规则融合特征,并重构出结果图像。

通过利用稀疏系数的特征,Yang等^[14]首先将稀疏表示理论应用于图像融合,为了获取局部显著特征并保持移位不变性,首先将不同的输入图像划分为多个重叠的块。接着,在同一个完整的字典上分解来自多个图像的重叠块,以获得相应的稀疏系数。然后,将融合过程应用于来自多个源的系数。最后,使用融合系数和字典重建图像。考虑到只有一个通

用字典无法准确地反映输入图像的复杂结构, Kim等^[15]将训练样本根据结构分为许多组,然后在每个组上训练一个特定的子字典,这样的子字典适合特定的结构,整个字典也具有更强的表示能力。

1.3 其他方法

一种直接的图像融合方法是将融合图像中的每个像素作为输入图像中相应像素的加权平均值。例如,在文献[6, 16]中,小波系数用作表示特征,支持向量机和神经网络用于选择具有最高活动度的像素。为了充分利用空间背景信息, Li等^[17]首先将输入图像分割成均匀的块,并最大化每个块中的空间频率。为了自适应地确定最佳块大小, De等^[18]利用四叉树结构来获得最佳细分的图像块。然而,这种方法可能会在对象边界上产生伪像^[17-19]。

2 图像融合常用的深度模型

2.1 卷积神经网络(Convolutional Neural Network, CNN)

目前, CNN是医学图像分析中研究最多的一种机器学习算法^[20]。浅层网络的模型一直到2006年才被深度网络替代, Hinton和他的学生指出,深度学习网络结构有两个主要特征:一个是多隐层的网络能够进行很好的特征学习;另一个是通过单层的受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)预训练,可以减小深度网络的训练难度。

CNN由输入层、隐藏层和输出层组成。隐藏层主要由输入与输出之间的卷积层和池化层构成,其中卷积层用于提取图像的特征,池化层用于简化信息。CNN的简单结构如图1所示,其中图像通过卷积核、激活函数和偏置的处理,生成特征映射图像;经过下采样,每个特征映射图像都可以在卷积和池化后获得其特征映射;再将其作为下一层的输入继续进行卷积和池化,重复该操作;最后,在输出层前,所有像素被光栅化为一列向量,在输出层得到输出结果^[21]。

2.2 卷积稀疏编码(Convolutional Sparse Coding, CSC)

CSC由Zeiler等^[22]提出,它的基本思想是基于稀疏约束条件下对图像进行卷积分解,并使用延续法放宽等式的约束,用共轭梯度法解决卷积最小二乘逼近问题。CSC用滤波器可以对整幅图像特征提取。在这个模型中,一个图像分解成一组卷积的和,即 $d_k * z_k$,即:

$$\arg\min_{d,z} \sum_{i=1}^2 \frac{1}{2} \left\| X - \sum_{k=1}^K d_k * z_k \right\|_2^2 + \gamma \sum_{k=1}^K \|z_k\|_1 \quad (1)$$

其中, X 表示输入图像, d_k 表示第 k 个滤波, z_k 是一组未知系数特征图,这种模型不再将图像拆分,避免稀疏编码时将图像分解为重叠的块时对图像整体性的




图1 CNN一般模型

Fig.1 General structure of convolutional neural network

破坏。通过从一组与特定的训练数据中学习字典，可以提高表示能力^[23]。与传统的稀疏表示相比，卷积稀疏表示 (Convolutional Sparse Representation, CSR) 提供的表示结构通过用一组卷积与字典过滤器的总和替代一组字典向量的线性组合，在 CSR 模型中计算出整个图像的稀疏表示，因此获得的表示是单值的，并且对整个图像进行了优化。

2.3 深度自编码

自动编码器是一种特殊类型的两层神经网络，通过最小化输入值与输出值之间的重构误差来学习输入的压缩表示。单层自动编码器结构简单，作用十分有限，当多个自动编码器堆叠在一起时，被称为栈式自动编码 (Stacked Auto-Encoders, SAE)，训练过程是逐层对各层编码器进行训练。

自动编码器的基本结构如图2所示。输入 x 通过第一层编码，数据的第一级特征可以被获取，表示为 h_1 ，然后将一级特征输入到第二层自动编码器以获得二级特征，表示为 h_2 ，重复该操作，可以得到 n 级特征 h_n 。编码后的不同级别的特征构成原始数据的分层描述。在训练 SAE 时，只需要通过单个自动编码器训练它的方式逐层训练，并用最后一层输出和期望之间的误差微调整个网络^[24]。




图2 栈式自动编码

Fig.2 Stacked auto-encoders

在深度自动编码器中，自动编码器作为一个基本组件，是一个只包含一个隐含层的单层结构，它的特征提取和抽象能力较为有限。在堆叠自动编码器的深层模型中，可以学习到层次化的特征，高层的特征由底层特征抽象而成。SAE 在许多视觉分类和图像恢复的问题中得到广泛应用。训练的过程通常包括两部分：无监督的预学习和有监督的微调。每一层中，训练 AE 通过学习编码器和解码器来获得一组特征^[25]。

2.4 深度信念网络

RBM 是一种包含两层无节点的随机神经网络模型，层之间全连接而层内没有连接。与 SAE 类似，深度信念网络可以通过叠加 RBM 建立。RBM 是一种基于能量的模型，在统计物理学中，由于系统倾向于处于能量较低的状态，因此如果其中某一种状态的能量低，系统就会有较大概率处在这一状态。将系统中抽象而复杂的各种状态出现的概率用一个简单的能量函数表示为：

$$E(v, h | \theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (2)$$

其中， $\theta = \{w, a, b\}$ 为未知参数， v_i 、 h_j 分别表示第 i 个可见单元的值和第 j 个隐藏单元的值， a_i 、 b_j 分别表示第 i 个可见单元和第 j 个隐藏单元的偏置， w_{ij} 为神经元 i 和 j 之间的连接权值。通过能量函数，即可得到系统在各状态的概率分布以及边缘分布^[26]。

RBM 的训练过程实际上就是求出一个能最大化拟合训练样本的概率分布，这一过程是无监督式的，通过最大化训练样本的似然函数来得到 RBM 的未知参数，这一过程需要遍历所有的训练样本。由于数据量大、计算复杂度过高而难以实现，实践中通常采用由 Hinton 提出的对比散度 (Contrastive Divergence, CD) 算法^[27]，这种简化的 Gibbs 采样方法解决了 RBM 学习效率的问题。近年来，CD 算法有许多改进，例如持续性对比散度和快速持续性对比散度等。

3 基于深度学习的医学图像融合

这些深度学习模型可以更好地表征输入医学图像，更好地处理弯曲形状和更高质量的融合细节。深度学习方法最大的优势在于它强大的特征学习能

力,因此可以将深度学习方法应用于医学图像融合中对特征的操作,以得到更好的融合结果。

3.1 从源图像提取特征

融合权重通常由不同图像的局部视觉特征的空间变化推导出,如像素方差、对比度和颜色饱和度等特征,这些方法都可以根据不同图像的图像特征来适应图像中不同位置处的不同内容并对其进行优先级排序。

分解后图像的特征以及像素的权重分配,直接影响到使用融合规则后的融合结果,在文献[28-30]中提出许多复杂的分解方法和细致的权重分配方法。Liu等^[31]从另一个角度解决了这个问题,通过训练CNN以编码从源图像到权重图的直接映射。以这种方式,权重值的获取与分配可以通过学习网络参数以“最佳”方式共同实现。文献[32]中提出的一种基于CNN的多焦点图像融合方法做出改进,将其应用于多模态图像,使用拉普拉斯金字塔分解方式和局部相似的融合方法,当源图像的内容具有高相似性时,CNN获得的权重比基于系数的方式更加可靠。

基于CNN的一般图像融合的通用框架如图3所示。卷积网络用于直接从源图像生成权重图,这避免了手动设计复杂的活动度测量和融合规则。具体地,网络的每个输出神经元表示归一化的权重分配结果。因此,网络的输出矢量可以表示权重分配的概率分布,并且其数学期望等于要计算的权重值。



图3 基于深度学习的图像融合

Fig.3 Image fusion based on deep learning

3.2 深度学习应用于融合中的图像变换

对医学图像做多尺度变换通常作为医学图像融合过程中的第一步,变换的结果直接影响到后续的特征提取与融合规则的制定,所以,通过深度学习方法获得合适的变换图像是一个重要的研究方向。针对CNN输出维度低而导致信息丢失的问题,Kai-jian Xia等使用基于Hek的方法初始化第一层以外的卷积核,把高斯拉普拉斯滤波器和高斯滤波器分解的子图像作为网络第一层,通过一个高频分量和一个低频分量,就可以在融合过程中自适应地分解和重建图像。并对于深度CNN难以训练的问题,借助深度自编码的思想,提出一种堆叠CNN的方法(DSCNN),该方法最终得到较好的融合结果且速度

快于NSCT和NSST,但是需要手动选择融合规则^[33]。

基于稀疏表示的图像融合方法有两个缺点,即对细节的保留能力有限和对位置偏差敏感,为了解决这些问题,Liu等^[34]提出一种基于CSR的融合框架,将原图像分解为基础层和细节层,用于多模态图像融合,并通过实验证明该方法的融合质量明显优于基于稀疏表示的方法。Liu等^[35]将MCA与CSR结合,提出一种基于CS-MCA的医学图像融合方法,同时实现了多分量和全局的稀疏表示。

图4中显示基于CSR的医学图像融合的通用框架。首先,对源图像执行特定图像变换。然后,通过一组离线学习字典过滤器对一些选定的变换频带执行CSC。图像变换和融合方式的选择都取决于具体的融合问题。在字典学习阶段,训练样例的生成和相关学习参数的设置对融合性能有重要影响。文献[36]提出一种新的字典学习方法,称为字典学习与组稀疏性和图形正则化(DL-GSGR)。通过交替稀疏编码和字典更新的方式,有效地对任何信号进行稀疏编码。文献中的实验将DL-GSGR组稀疏表示应用于三维医学图像的去噪和图像融合,结果表明这种方法的优越性。




图4 基于CSR的图像融合

Fig.4 Image fusion based on convolutional sparse representation

医学图像有对比度低、灰度分布不均等特点,因此全局训练字典对多模态医学图像的融合缺少普遍性,针对如何构建一个自适应源图像的过完备字典这一问题,宗静静等^[37]将两幅已经配准的源图像组成一个整体进行联合稀疏表示,获得一个供图稀疏部分和一个不同稀疏部分,对其中不同稀疏部分使用 l_1 范数最大规则进行融合,直接从已配准的源图像学习字典,提高字典对源图像的自适应性。

4 结 语

本文介绍了几种应用于医学图像融合的深度学习方法,包括CNN、CSC、SAE和深度信念网络。利用深度学习对特征提取的优势,在图像融合中运用深度学习方法对图像做变换或特征提取,提升图像融合的效果。针对应用这些框架或者改进的方法进行融合的多模图像,通过主观与客观评价对融合后的图像做出评价,从而判断融合质量。

这些深度学习模型为融合提供了更好的医学图像输入特征、更好的曲线形状处理和更高质量的融合细节。深度学习的总体优势在于提高图像的视觉质量,减少图像的伪影和噪声。通过分析可以发现,合适的深度学习方法应用到医学图像融合可以得到比传统方法更好的结果^[38-40]。深度神经网络能够在大量的训练数据中学习到最有效的特征,克服手工设计的困难之处,所以在图像融合领域有巨大的优势。但融合步骤间关联不大,多数方法也是针对像素级图像融合。将深度学习方法应用于融合全过程时,如何选择有效特征是研究的关键。未来深度学习与医学图像融合的结合程度有待进一步提高,代替更多手动设计工作。

【参考文献】

- [1] LI S, KANG X, FANG L, et al. Pixel-level image fusion: a survey of the state of the art[J]. *Inf Fusion*, 2017, 33(1): 100-112.
- [2] BURT P J, KOLCZYNSKI R J. Enhanced image capture through fusion [C]//1993 (4th) International Conference on Computer Vision. IEEE, 1993: 173-182.
- [3] GOSHTASBY A A. Fusion of multi-exposure images[J]. *Image Vis Comput*, 2005, 23(6): 611-618.
- [4] ASLANTAS V, KURBAN R. Fusion of multi-focus images using differential evolution algorithm[J]. *Expert Syst Appl*, 2010, 37(12): 8861-8870.
- [5] LIU Y, LIU S, WANG Z. A general framework for image fusion based on multi-scale transform and sparse representation[J]. *Inf Fusion*, 2015, 24(4): 147-164.
- [6] LI S, KWOK J T, WANG Y. Multifocus image fusion using artificial neural networks[J]. *Pattern Recognit Lett*, 2002, 23(8): 985-997.
- [7] YANG Y, YANG M, HUANG S, et al. Multifocus image fusion based on extreme learning machine and human visual system[J]. *IEEE Access*, 2017, 5(1): 6989-7000.
- [8] ZHANG Z, BLUM R S. A categorization of multiscale-decomposition-based image fusion schemes with a performance study for a digital camera application[J]. *Proc IEEE Inst Electr Electron Eng*, 1999, 87(8): 1315-1326.
- [9] LEWIS J J, O'CALLAGHAN R J, NIKOLOV S G, et al. Pixel- and region-based image fusion with complex wavelets[J]. *Inf Fusion*, 2007, 8(2): 119-130.
- [10] WANG Q, LI S, QIN H, et al. Robust multi-modal medical image fusion via anisotropic heat diffusion guided low-rank structural analysis[J]. *Inf Fusion*, 2015, 26(6): 103-121.
- [11] REDONDO R, ŠROUBEK F, FISCHER S, et al. Multifocus image fusion using the log-Gabor transform and a multisize windows technique[J]. *Inf Fusion*, 2009, 10(2): 163-171.
- [12] YANG S, WANG M, JIAO L. Fusion of multispectral and panchromatic images based on support value transform and adaptive principal component analysis[J]. *Inf Fusion*, 2012, 13(3): 177-184.
- [13] OLSHAUSEN B A, FIELD D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. *Nature*, 1996, 381(6583): 607.
- [14] YANG B, LI S. Multifocus image fusion and restoration with sparse representation[J]. *IEEE Trans Instrum*, 2009, 59(4): 884-892.
- [15] KIM M, HAN D K, KO H. Joint patch clustering-based dictionary learning for multimodal image fusion[J]. *Inf Fusion*, 2016, 27(1): 198-214.
- [16] LI S, KWOK J T, TSANG I W, et al. Fusing images with different focuses using support vector machines[J]. *IEEE Trans Neural Networ*, 2004, 15(6): 1555-1561.
- [17] LI S, KWOK J T, WANG Y. Combination of images with diverse focuses using the spatial frequency[J]. *Inf Fusion*, 2001, 2(3): 169-176.
- [18] DE I, CHANDA B. Multi-focus image fusion using a morphology-based focus measure in a quad-tree structure[J]. *Inf Fusion*, 2013, 14(2): 136-146.
- [19] BAI X, ZHANG Y, ZHOU F, et al. Quadtree-based multi-focus image fusion using a weighted focus-measure[J]. *Inf Fusion*, 2015, 22(2): 105-118.
- [20] KER J, WANG L, RAO J, et al. Deep learning applications in medical image analysis[J]. *IEEE Access*, 2018, 6(1): 9375-9389.
- [21] SHIN H C, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. *IEEE Trans Med Imaging*, 2016, 35(5): 1285-1298.
- [22] ZEILER M D, KRISHNAN D, TAYLOR G W, et al. Deconvolutional networks[C]. *Cvpr*, 2010: 7.
- [23] RUBINSTEIN R, BRUCKSTEIN A M, ELAD M. Dictionaries for sparse representation modeling[J]. *Proc IEEE Inst Electr Electron Eng*, 2010, 98(6): 1045-1057.
- [24] 简素珍, 韩泽. 基于深度堆叠卷积神经网络的图像融合[J]. *计算机学报*, 2017, 40(11): 2506-2518.
- [24] LIN S Z, HAN Z. Image fusion based on deeping stack convolutional neural network[J]. *Chinese Journal of Computers*, 2017, 40(11): 2506-2518.
- [25] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks [C]//Advances in Neural Information Processing Systems, 2007: 153-160.
- [26] HINTON G E. Training products of experts by minimizing contrastive divergence[J]. *Neural Comput*, 2002, 14(8): 1771-1800.
- [27] BHATNAGAR G, WU Q M, LIU Z. A new contrast based multimodal medical image fusion framework [J]. *Neurocomputing*, 2015, 157(1): 143-152.
- [28] LIU Y, LIU S, WANG Z. A general framework for image fusion based on multi-scale transform and sparse representation[J]. *Inf Fusion*, 2015, 24(4): 147-164.
- [29] YANG Y, QUE Y, HUANG S, et al. Multimodal sensor medical image fusion based on type-2 fuzzy logic in NSCT domain[J]. *IEEE Sens J*, 2016, 16(10): 3735-3745.
- [30] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proc IEEE Inst Electr Electron Eng*, 1998, 86(11): 2278-2324.
- [31] LIU Y, CHEN X, PENG H, et al. Multi-focus image fusion with a deep convolutional neural network[J]. *Inf Fusion*, 2017, 36(4): 191-207.
- [32] LIU Y, CHEN X, CHENG J, et al. A medical image fusion method based on convolutional neural networks [C]//International Conference on Information Fusion. IEEE, 2017.
- [33] XIA K, YIN H, WANG J. A novel improved deep convolutional neural network model for medical image fusion[J]. *Cluster Comput*, 2018, 22(3): 1-13.
- [34] LIU Y, CHEN X, WARD R K, et al. Image fusion with convolutional sparse representation[J]. *IEEE Signal Process Lett*, 2016, 23(12): 1882-1886.
- [35] LIU Y, CHEN X, WARD R K, et al. Medical image fusion via convolutional sparsity based morphological component analysis[J]. *IEEE Signal Process Lett*, 2019, 26(3): 485-489.
- [36] LI S, YIN H, FANG L. Group-sparse representation with dictionary learning for medical image denoising and fusion[J]. *IEEE Trans Biomed Eng*, 2012, 59(12): 3450-3459.
- [37] 宗静静, 邱天爽, 郭冬梅. 联合稀疏表示的医学图像融合及同步去噪[J]. *中国生物医学工程学报*, 2016, 35(2): 133-140.
- [37] ZONG J J, QIU T S, GUO D M. Simultaneous medical image fusion and de-noising with joint sparse representation[J]. *Chinese Journal of Biomedical Engineering*, 2016, 35(2): 133-140.
- [38] LI S, KANG X, HU J. Image fusion with guided filtering[J]. *IEEE Trans Image Process*, 2013, 22(7): 2864-2875.
- [39] LIU Y, LIU S, WANG Z. Multi-focus image fusion with dense SIFT [J]. *Inf Fusion*, 2015, 23(3): 139-155.
- [40] RANA D H, DEGADWALA S D. Medical image fusion using combined multi-resolution and multi-scaling transform [J]. *Int J Comput Appl*, 2014, 107(6): 26-29.

(编辑:陈丽霞)