

## 基于压缩感知与自适应 PCNN 的医学图像融合

高 媛, 贾紫婷, 秦品乐, 王丽芳

(中北大学 计算机与控制工程学院, 太原 030051)

**摘 要:** 针对非下采样轮廓波变换(NSCT)域内基于脉冲耦合神经网络(PCNN)的图像融合方法融合效果较差、计算复杂度较高等问题,提出一种在非下采样剪切波变换(NSST)域内基于压缩感知(CS)和自适应PCNN的融合算法。源图像在NSST域内被分解成高低频,采用改进的PCNN融合低频子带系数,使用像素的平方差总和当作其激励因素,选取方向梯度总和作为其链接强度,对计算量较大的高频子带系数采用CS进行处理,经过NSST逆变换获得融合图像。实验结果表明,与NSCT融合算法、NSST与PCNN相结合的算法等相比,该算法能获得较好的信息熵、空间频率、边缘信息评价因子,且运行时间较短。

**关键词:** 压缩感知;非下采样剪切波变换;脉冲耦合神经网络;图像融合;核磁共振成像

**中文引用格式:** 高 媛, 贾紫婷, 秦品乐, 等. 基于压缩感知与自适应 PCNN 的医学图像融合[J]. 计算机工程, 2018, 44(9): 224-229.

**英文引用格式:** GAO Yuan, JIA Ziting, QIN Pinle, et al. Medical image fusion based on compressive sensing and adaptive PCNN[J]. Computer Engineering, 2018, 44(9): 224-229.

## Medical Image Fusion Based on Compressive Sensing and Adaptive PCNN

GAO Yuan, JIA Ziting, QIN Pinle, WANG Lifang

(School of Computer and Control Engineering, North University of China, Taiyuan 030051, China)

**[Abstract]** Aiming at the problem of poor performance and high computational complexity in the image fusion algorithm which based on Pulse Coupled Neural Network(PCNN) in the Non-subsampled Contourlet Transform(NSCT) domain, an fusion algorithm based on Compressed Sensing(CS) and adaptive PCNN in NSST domain is proposed. The source image is decomposed into high and low frequencies in the NSST domain. An improved PCNN is used to fuse the low frequency subband coefficients. The sum of the squared differences of the pixels is used as the excitation. The sum of the direction gradients is used as the link strength, and the high frequency which need lots of calculations are processed using CS, and the fused image is obtained by inverse transform of NSST. Experimental results show that the algorithm performs better in information entropy, spatial frequency, edge information evaluation factor, and the running time is shorter compared with NSCT fusion algorithm, NSST combined with PCNN algorithm, and so on.

**[Key words]** Compressive Sensing(CS); Non-subsampled Shearlet Transform(NSST); Pulse Coupled Neural Network(PCNN); image fusion; Magnetic Resonance Imaging(MRI)

**DOI:** 10.19678/j.issn.1000-3428.0048000

### 0 概述

由于单个模态的图像信息存在局限性,只有利用多种模态的图像医生才能获得更加综合详细的信息,因此多模态图像融合应运而生。比如,计算机断层成像<sup>[1]</sup>(Computerized Tomography, CT)能清晰地呈现骨骼信息及其病变,但存在骨伪影而且对软组织分辨率不高。而核磁共振成像(Magnetic Resonance Imaging, MRI)中对软组织及其病变的显示较好,并且没有骨伪影的干扰。不同模态的医学图像有不同的

特点,其功能也呈现出多样性,将其取长补短整合成一张图像,不仅能够减少存储所占空间,而且有利于医生获得更全面的信息。

近期,多尺度分解算法成为了学者们的重点关注对象,基于该方法的融合技术也日益成熟<sup>[2-4]</sup>。其中轮廓波变换比小波变换具有更好的方向性和更高的分辨率,文献[5]提出了轮廓波变换,但其不具有平移不变性。NSCT的出现弥补了这一缺陷,大大缩小了伪吉布斯现象出现的概率<sup>[6]</sup>,能够更好地表示图像的细节,但该方法计算起来较为繁琐。非下采样剪切波

**基金项目:** 山西省自然科学基金(2015011045)。

**作者简介:** 高 媛(1972—),女,副教授,主研方向为图像处理、人工智能;贾紫婷,硕士研究生;秦品乐、王丽芳,副教授。

**收稿日期:** 2017-07-18 **修回日期:** 2017-09-02 **E-mail:** 949763497@qq.com

变换<sup>[7-8]</sup> (Non-subsampled Shearlet Transform, NSST) 具有更高的方向灵敏度和较少计算复杂度,这些优点使得其更适用于图像处理。

2006年,文献[9]提出了一种新的采样理论-压缩感知(Compressive Sensing, CS)。CS的出现大大减少了采取样本的次数。文献[10]将CS应用到图像融合中,显著地提高了运算效率。文献[11]将CS应用到NSST域,减少了算法的复杂度。

脉冲耦合神经网络(Pulse Coupled Neural Network, PCNN)是在文献[12]提出的。此网络不需要训练就可以进行相应的图像处理,相比于以往的融合方法性能更好。文献[13]将PCNN应用到图像融合中,并通过实验证明了该方法的可实施性。文献[14]将NSST与PCNN相结合,保留了图像的细节,但其忽略了人眼对特征敏感的特点,仅使用单个像素的灰度值当作PCNN的激励。文献[15]使用压缩感知和PCNN来融合PET/CT图像,减少了算法的计算复杂度,但PCNN中激励和链接强度均未改进严重影响了融合效果。文献[16]将提升小波与PCNN相结合,但NSST比提升小波具有更高的方向灵敏度和较少的计算复杂度。同样,该算法在PCNN中仅采用单个像素的灰度值作为其输入。

基于以上分析,本文利用人眼对特征敏感的特性,提出NSST域内CS和改进的PCNN相结合的医学图像融合算法。

## 1 相关理论

### 1.1 非下采样剪切波变换

NSST的离散化过程包括多尺度和多方向分解。多尺度部分由非下采样金字塔(Non-Subsampled Pyramid, NSP)来实现。源图像通过 $k$ 级分解后获得1个低频子带和 $k$ 个尺寸一样但尺度不相同的高频子带<sup>[17]</sup>。在多方向部分,NSST采用改进的剪切滤波器(Shearlet Filter, SF)进行分解,避免了下采样的操作,使NSST具有平移不变性<sup>[17-19]</sup>。

NSST的分解层数为3层,过程如图1所示。




图1 NSST多尺度多方向分解过程

### 1.2 压缩感知理论

假设任一图像矩阵 $S$  ( $S \in N \times 1$ ), 其基向量为 $\Psi$ , 在 $N \times N$ 的正交基 $\Psi$ 下, $S$ 可表示为:

$$S = \Psi x \quad (1)$$

其中, 矩阵 $S$ 是图像在时域的表示, $x$ 是图像在 $\Psi$ 域的表示。若式(1)中 $x$ 的非零系数有 $K$  ( $K < N$ )个, 则 $x$ 的稀疏度为 $K$ 。

采样过程可表示为:

$$y = \Phi S = \Phi \Psi x = \Theta x \quad (2)$$

其中, 测量矩阵为 $\Phi$ , 感知矩阵为 $\Theta$  ( $M \times N$ )。只有 $\Phi$ 符合等距约束(Restricted Isometry Property, RIP)准则才能求解 $S$ , 从而使压缩测量值得到精确恢复, 得到重构后的图像, 如式(3)所示。

$$\operatorname{argmin} \|S\|_{l_1} \text{ s. t. } y = \Phi S \quad (3)$$

### 1.3 脉冲耦合神经网络

PCNN模型包括接收域、调制域和脉冲产生域<sup>[20]</sup>。由于该模型较复杂, 参数较多, 因此本文采用其简化模型, 数学表达式如下:

$$F_{ij}[n] = S_{ij} + \sum_{r=-1}^1 \sum_{d=-1}^1 W_{rd} Y_{ijrd}[n-1] \quad (4)$$

$$L_{ij}[n] = \sum_{r=-1}^1 \sum_{d=-1}^1 M_{rd} Y_{ijrd}[n-1] \quad (5)$$

$$U_{ij}[n] = F_{ij}[n] (1 + \beta_{ij} L_{ij}[n]) \quad (6)$$

$$\theta_{ij}[n] = \alpha \theta_{ij}[n-1] + \nu Y_{ij}[n-1] \quad (7)$$

$$Y_{ij}[n] = \begin{cases} 1, & U_{ij}[n] \geq \theta_{ij}[n] \\ 0, & U_{ij}[n] < \theta_{ij}[n] \end{cases} \quad (8)$$

$$T_{ij}[n] = \begin{cases} n, & Y_{ij}[n] = 1 \\ T_{ij}[n-1], & \text{otherwise} \end{cases} \quad (9)$$

其中,  $F_{ij}[n]$ 为神经元的反馈输入,  $S_{ij}$ 为外部激励,  $(i, j)$ 是神经元的标号,  $r, d$ 表示与周围神经元连接的范围, 连接输入 $L_{ij}[n]$ 如式(5)所示,  $W$ 和 $M$ 是突触权重矩阵, 内部活跃项 $U_{ij}[n]$ 如式(6)所示,  $\beta_{ij}$ 为第 $ij$ 个神经元的链接强度, 内部活跃项 $U_{ij}[n]$ 和内部阈值 $\theta_{ij}[n]$ 进行比较如式(8)所示,  $Y_{ij}[n]$ 为 $(i, j)$ 神经元的二值输出, 内部阈值 $\theta_{ij}[n]$ 每次更新迭代根据式(7),  $\alpha$ 为时间衰减常数,  $\nu$ 为阈值放大系数,  $T$ 为神经元首次点火的时间矩阵。

## 2 算法设计

### 2.1 基于CS和自适应PCNN的医学图像融合算法

假定CT图像为 $A$ , MRI为 $B$ , 并且已经过几何配准处理。图2为本文融合算法基本框架, 具体操作如下:

1) 对 $A$ 和 $B$ 分别进行NSST分解, 得到各自分解后的系数:

$$\{A_L, A_H^{l,k}\}, l \geq 1$$

$$\{B_L, B_H^{l,k}\}, l \geq 1$$

其中,  $A_L$ 和 $B_L$ 为低频子带系数,  $A_H^{l,k}$ 和 $B_H^{l,k}$ 为 $l$ 尺度下 $k$ 方向上高频子带系数, 分解层数设为3层。

2) 低频子带通过PCNN模型来处理, 采用方向

梯度之和 (Sum of Directional Gradients, SDG) 作为图像中像素点所对应神经元处的链接强度  $\beta^L$ 。采用平方差总和 (Sum of Difference of Two Squares, SDS) 作为 PCNN 的外部激励  $S^L$ 。选取点火时间较早的系数为融合后低频子带系数  $F_L$ 。

3) 将  $A$ 、 $B$  的高频子带利用 CS 进行处理, 选用局部区域能量与全局梯度相结合的规则来融合<sup>[8]</sup>。使用光滑  $l_0$  范数 (Smooth  $l_0$  Norm, SL0) 重构算法从观测值中重构出高频子带系数  $F_H^{l,k}$ 。

4) 通过 NSST 逆变换, 获得融合图像  $F$ 。




图2 融合算法基本框架

## 2.2 低频子带融合规则

由于低频子带中信息携带量较大, 其处理效果将严重影响融合结果。如果低频子带采用传统算法, 比如加权平均法会导致部分信息丢失。PCNN的优势在于其具有强大的生物学背景, 但未经过改进的PCNN中, 每个神经元的链接强度是不变的。

而人眼对不同特征区域的响应程度存在差异, 导致所有神经元的链接强度不会完全一致。所以, 链接强度的取值并不是固定常数。因此, 本文采用每个神经元对应位置处的SDG特征, 如式(10)作为相应位置处的链接强度。

方向梯度函数定义如下:

$$SDG[I(x,y)] = dg_1 + dg_2 + dg_3 + dg_4 \quad (10)$$

$$dg_1 = \sqrt{(I(x,y) - I(x-1,y))^2 + (I(x,y) - I(x+1,y))^2} \quad (11)$$

$$dg_2 = \sqrt{(I(x,y) - I(x,y-1))^2 + (I(x,y) - I(x,y+1))^2} \quad (12)$$

$$dg_3 = \sqrt{((I(x,y) - I(x-1,y-1))^2 + (I(x,y) - I(x+1,y+1))^2)/2} \quad (13)$$

$$dg_4 = \sqrt{((I(x,y) - I(x-1,y+1))^2 + (I(x,y) - I(x+1,y-1))^2)/2} \quad (14)$$

在多数PCNN算法中, 均是将单个像素的灰度值当作该模型的激励。但相对于像素来说人眼对特征更加敏感。因此, 本文把SDS看作一种特征, 来作为该模型的外部激励。

令  $C_L(u,q)$  是位置  $(u,q)$  处的低频子带系数。像素的平方差如式(15)所示, 领域内的平方差总和如式(16)所示, 其中, 矩阵  $w$  如式(17)所示。

$$DS[C_L(u,q)] = \sum_{m=-1}^1 \sum_{n=-1}^1 |(C_L(u,q))^2 - C_L(u+m,q+n)^2| \quad (15)$$

$$SDS[fC_L(u,q)] = \sum_{i=-1}^1 \sum_{j=-1}^1 w(i+1,j+i) \cdot DS[C_L(u+i,q+j)] \quad (16)$$

$$w = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (17)$$

PCNN的参数设置如下:

经过多次实验表明在式(4)和式(5)中, 突触权重矩阵  $W$  和  $M$  被设置为式(18)时融合效果较好。

$$W = M = \begin{bmatrix} 0.1035 & 0.1465 & 0.1035 \\ 0.1465 & 0.0000 & 0.1465 \\ 0.1035 & 0.1465 & 0.1035 \end{bmatrix} \quad (18)$$

为了得到一个平稳的脉冲,  $\alpha$  设置为 0.75, 一旦神经元点火, 阈值就会通过  $v$  增加。因此, 为了避免神经元点火次数过多,  $v$  设置为 20。对于迭代次数而言, PCNN 的迭代方式选择自适应迭代, 直至全部神经元一次点火。

融合步骤为:

1) 初始化 PCNN: 反馈输入矩阵  $F$ 、链接输入矩阵  $L$ 、输出矩阵  $Y$  和 PCNN 的时间矩阵  $T$  初始化为 0。阈值  $\theta$  初始化为 1 来避免无效的迭代。

2) 计算链接强度  $\beta$ : 使用式(10)计算每个神经元

对应位置处的SDG将其作为PCNN的链接强度 $\beta$ 。

3) 采用SDS作为PCNN的外部激励,通过式(15)和式(16)实现。

4) 获取时间矩阵 $T$ :迭代使用式(4)~式(8)直到所有神经元点火。保存时间矩阵,PCNN处理过程中低频图像 $A_L$ 和 $B_L$ 的时间矩阵分别为 $T_A^L$ 和 $T_B^L$ 。

5) 融合后低频子带系数 $F_L$ :选取点火时间较早的系数作为 $F_L$ ,如式(19)所示。

$$F_L(i, j) = \begin{cases} A_L(i, j) \\ B_L(i, j) \end{cases} \quad (19)$$

### 2.3 高频子带融合规则

高频子带是源图像细节的体现,如边缘、纹理等,并且稀疏性较高,其系数值大都在零值上下浮动,近似为0值,非0数值占少数。压缩感知正好适合处理此类问题,本文中采样率为50%。高频部分通过融合观测值来获得,但简单的基于像素的融合规则不能较好地反映图像的空间信息,所以,本文使用基于特征的规则进行融合。最后,用SLO算法对融合后的观测值重构获得 $F_H^{l,k}$ 。

图像 $A$ 、 $B$ 的高频子带系数为 $A_H^{l,k}$ 和 $B_H^{l,k}$ 。通过高斯随机矩阵 $\Phi$ 后获得的观测值为 $y_{AH}^{l,k}$ 和 $y_{BH}^{l,k}$ ,如式(20)所示。融合后的观测值为 $y_{FH}^{l,k}$ 。

$$y_{PH}^{l,k} = \Phi \times P_H^{l,k} \quad P = A, B \quad (20)$$

$A$ 、 $B$ 的观测图像为 $y_{AH}^{l,k}(p)$ 和 $y_{BH}^{l,k}(p)$ ,它们的局部区域能量的计算算法如式(21)所示,选取 $3 \times 3$ 的矩阵 $g$ 作为窗函数,如式(22)所示。

$$E_{PH}^{l,k}(p) = \sum_{(m,n) \in \Omega(p)} g(m,n) [y_{PH}^{l,k}(m,n)]^2 \quad P = A, B \quad (21)$$

$$g = \frac{1}{8} \begin{bmatrix} 0 & 1 & 0 \\ 1 & 4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (22)$$

其中,矩阵 $\Omega$ 为邻域窗口,大小为 $m \times n$ ,一般为 $3 \times 3$ 或 $5 \times 5$ ,本文中选取 $3 \times 3$ 。图像在点 $(m, n)$ 处的观测值为 $y_{PH}^{l,k}(m, n)$ 。 $g(m, n)$ 为点 $(m, n)$ 处对应的窗函数。 $E_{PH}^{l,k}(p)$ 为观测图像的局部区域能量。

$y_{AH}^{l,k}(p)$ 和 $y_{BH}^{l,k}(p)$ 的梯度图像分别为 $G_{AH}^{l,k}(p)$ 和 $G_{BH}^{l,k}(p)$ 。梯度的计算采用Laplacian算子,如式(23)所示。

$$G_{PH}^{l,k}(p) = \nabla_x^2 y_{PH}^{l,k}(p) + \nabla_y^2 y_{PH}^{l,k}(p), \quad P = A, B \quad (23)$$

融合后的高频系数观测值 $y_{FH}^{l,k}(p)$ 由式(24)求得。其中,全局梯度的加权值 $\omega$ 的计算如式(25)所示。

$$y_{FH}^{l,k}(p) = \begin{cases} y_{AH}^{l,k}(p), E_{AH}^{l,k}(p) > E_{BH}^{l,k}(p) \\ y_{BH}^{l,k}(p), E_{AH}^{l,k}(p) < E_{BH}^{l,k}(p) \\ \omega \times y_{AH}^{l,k}(p) + (1 - \omega) \times y_{BH}^{l,k}(p), \text{else} \end{cases} \quad (24)$$

$$\omega = \frac{\left| \sum_k \frac{1}{n_R} \sum_{p \in R} G_{AH}^{l,k}(p) \right|}{\left| \sum_k \frac{1}{n_R} \sum_{p \in R} G_{AH}^{l,k}(p) \right| + \left| \sum_k \frac{1}{n_R} \sum_{p \in R} G_{BH}^{l,k}(p) \right|} \quad (25)$$

$$k = \{k_1, k_2, \dots, k_l\}, \quad l = 1, 2, \dots$$

其中,矩阵 $R$ 是 $m \times n$ 的一个矩形区域, $n_R = m \times n$ ,一般为 $3 \times 3$ 或 $5 \times 5$ ,本文选取 $3 \times 3$ 的邻域窗口, $l = 1, 2, \dots$ 为分解尺度, $k = \{k_1, k_2, \dots, k_l\}$ 表示在每个尺度上相应的方向数。

### 3 实验结果与分析

综上所述,对该算法进行了3组实验,分别选取了正常脑干、脑萎缩与脑梗患者的CT与MRI图像进行验证,结果如图3~图5所示。




图3 正常脑干的CT与MRI图像及融合结果




图4 脑萎缩的CT与MRI图像及融合结果




图5 脑梗的CT与MRI图像及融合结果

将本文算法与 NSCT 算法、文献[15]算法、NSST-PCNN 算法、文献[16]算法、文献[21]算法相比较。其中,基于 NSCT 的融合规则为高频子带系数能量取大,低频取平均。文献[15]算法是 NSCT 变换下把 CS 与 PCNN 相结合来融合图像。在 NSST-PCNN 算法中,高频采用压缩感知,低频采用没有改进的 PCNN 融合规则,其余条件与本文算法相同。文献[16]算法是把提升小波变换和 PCNN 相结合进行图像融合,该算法高频部分使用自适应 PCNN 算法,低频使用区域能量算法。而本文中,对于计算量较大的高频部分采用 CS 来减少计算复杂度,低频采用自适应 PCNN 算法。文献[16]使用梯度能量作为链接强度,但使用单个像素的灰度值来作为外部激励,而相对于单个像素来说人眼对特征更加敏感,所以,本文选取了 SDS 特征作为外部激励,采用 SDG 特征为图像中像素点所对应神经元处的链接强度。文献[21]算法是用 NSCT 分解图像,

分解后的高低频均通过 PCNN 处理。

由图3和图4可知,6种算法都成功地融合了2幅图像,图3(c)~图3(h)和图4(c)~图4(h)既突出了脑部的骨骼部分又包含了软组织的信息,取得了不错的效果。

可以发现,图3(c)和图4(c)中的成像质量一般,图像较暗,对比度较低,不利于人眼观察。图3(d)和图4(d)比图3(c)和图4(c)效果好,图像的对比度得到明显提升,但是纹理细节信息不清楚。NSST-PCNN 算法的融合结果较好,可以很好地保留图像的空间细节信息,骨骼信息突出,软组织对比度高,但是图3(e)有部分软组织信息缺失,图4(e)中骨组织没有完全融合到最终图像中。图3(f)、图3(g)、图4(f)、图4(g)融合效果不错,但相比之下,本文算法无论是边缘还是纹理信息都非常丰富,对比度、清晰度均高于其他算法,更有利于医生对病人的诊断。

图5(c)对比度较差,同时丢失了骨骼信息。图5(d)对比度增强,但软组织模糊,不利于病灶部位及类型的确定。图5(e)融合效果不错,但细节部分还是不够详尽。图5(f)、图5(g)融合效果和本文算法相差不大。但本文算法清晰度、对比度较高,图像中信息丰富成像质量较好。

为了更加全面地评价融合结果,本文采用了信息熵(IE)、空间频率(SF)、标准差(SD)、清晰度(MC)、边缘信息评价因子( $Q^{AB/F}$ )和运行时间(time)6项指标进行评价。其中,前5项指标的值与融合效果呈正相关,运行时间越短效率越高。结果如表1所示,该表所示为3组实验的客观评价指标均值。

表1 3组实验客观评价指标均值

| 算法<br>指标   | NSCT<br>算法 | 文献[15]<br>算法 | NSST-PCNN<br>算法 | 文献[16]<br>算法 | 文献[21]<br>算法 | 本文<br>算法 |
|------------|------------|--------------|-----------------|--------------|--------------|----------|
| IE         | 5.774 5    | 6.215 9      | 6.480 1         | 6.318 6      | 6.421 7      | 6.609 1  |
| SF         | 22.106 0   | 21.823 0     | 23.072 0        | 23.169 0     | 21.852 0     | 23.303 0 |
| SD         | 55.060 0   | 60.488 0     | 63.250 0        | 69.030 0     | 64.429 0     | 64.395 0 |
| MC         | 7.910 5    | 7.703 5      | 9.393 1         | 9.186 4      | 9.477 2      | 9.468 2  |
| $Q^{AB/F}$ | 0.419 7    | 0.580 1      | 0.671 9         | 0.690 5      | 0.702 4      | 0.710 2  |
| 时间/s       | 36.941 5   | 45.728 4     | 20.358 7        | 28.831 6     | 91.397 0     | 25.931 0 |

由表1可以看出,本文算法得到的指标在IE、SF、SD、MC、 $Q^{AB/F}$ 上均高于NSCT、文献[15]、NSST-PCNN算法。本文算法与文献[16]相比在IE、SF、MC、 $Q^{AB/F}$ 上均较优,在SD上低于该算法。而本文算法和文献[21]算法相比,在IE、SF、 $Q^{AB/F}$ 上高于对比算法,在SD、MC上低于该算法。同时,本文算法的运行时间较快于NSCT、文献[15]、文献[16],远快于文献[21],说明了压缩感知大大减少了本文算法的复杂度,而且融合效果与文献[21]相差不大。综合考虑算法的效率及效果,本文算法性能较优。本文算法不仅能够较好地融合图像信息而且保留了细节部分,客观评价与直观观察结果相符。为实现精确病灶定位及手术治疗提供有利的影像依据。

#### 4 结束语

本文提出一种医学图像融合算法。在NSST域内利用其方向灵敏性和平移不变性,能精确表示图像,高频部分使用CS,减少了算法复杂度,低频部分借助于PCNN的生物背景,有效地提取出图像的纹理细节信息,通过NSST逆变换得到融合图像。实验结果证明了算法的有效性。下一步将该算法应用于其他领域,如遥感图像、多聚焦图像进行验证。

#### 参考文献

- [1] 路晓军. 医学图像在体育研究中的应用简述[J]. 新西部月刊, 2011(1): 223-223.
- [2] WANG Jingjing, LI Qian, JIA Zhenhong, et al. A novel multi-focus image fusion method using PCNN in

nonsubsampled contourlet transform domain[J]. Optik-International Journal for Light and Electron Optics, 2015, 126(20): 2508-2511.

- [3] 宋瑞霞,王孟,王小春. V-变换和Contourlet变换相结合的图像融合算法[J]. 计算机工程, 2017, 43(4): 263-268.
- [4] 何文建,李岩. 结合小波变换的梯度场图像渐进融合算法[J]. 计算机工程, 2014, 40(4): 228-232.
- [5] DO M N, VETTERLI M. Contourlets: a directional multi-resolution image representation[C]//Proceedings of IEEE International Conference on Image. Washington D. C., USA: IEEE Press, 2002: 357-360.
- [6] STILLER C, LEON F P, KRUSE M. Information fusion for automotive applications-an overview[J]. Information Fusion, 2011, 12(4): 244-252.
- [7] CAO Yuan, LI Shutao, HU Jianwen. Multi-focus image fusion by nonsubsampled shearlet transform[C]//Proceedings of the 6th International Conference on Image and Graphics. Washington D. C., USA: IEEE Press, 2011: 17-21.
- [8] 邢笑雪. 基于NSST的图像融合算法研究[D]. 长春: 吉林大学, 2014.
- [9] 陈贞,邢笑雪. 基于非下采样Shearlet变换与压缩感知的图像融合[J]. 液晶与显示, 2015, 30(6): 1024-1031.
- [10] 殷明,庞纪勇,魏远远,等. 结合NSDTCT和压缩感知PCNN的图像融合算法[J]. 计算机辅助设计与图形学学报, 2016, 28(3): 411-419.
- [11] 赵学军,刘静. NSST域内基于压缩感知和PCNN的遥感图像融合[J]. 科学技术与工程, 2016, 16(14): 259-262.
- [12] 郝文超,贾年. NSCT域内基于自适应PCNN的红外与可见光图像融合方法[J]. 西华大学学报(自然科学版), 2014, 33(3): 11-15.
- [13] BROUSSARD R P, ROGERS S K, OXLEY M E, et al. Physiologically motivated image fusion for object detection using a pulse coupled neural network[J]. IEEE Transactions on Neural Networks, 1999, 10(3): 554-563.
- [14] 李美丽,李言俊,王红梅,等. 基于NSCT和PCNN的红外与可见光图像融合方法[J]. 光电工程, 2010, 37(6): 90-95.
- [15] 王文文,王惠群,陆惠玲,等. 基于压缩感知和NSCT-PCNN的PET/CT医学图像融合算法[J]. 重庆理工大学学报(自然科学版), 2016, 30(2): 101-108.
- [16] 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.
- [17] 欧阳宁,邹宁,张彤,等. 基于非下采样Shearlet变换与聚焦区域检测的多聚焦图像融合算法[J]. 计算机应用, 2015, 35(2): 490-494.
- [18] 温黎茗,彭力,徐红. 基于NSCT和PCNN的遥感图像融合算法[J]. 计算机工程, 2012, 38(11): 196-198.
- [19] 张强. 基于非下采样Shearlet变换域的图像融合及去噪算法研究[D]. 合肥: 合肥工业大学, 2014.
- [20] ZHAN Kun, SHI Jinhui, WANG Haibo, et al. Computational mechanisms of pulse-coupled neural networks: a comprehensive review[J]. Archives of Computational Methods in Engineering, 2016, 24(3): 1-16.
- [21] 屈小波,闫敬文,肖弘智,等. 非降采样Contourlet域内空间频率激励的PCNN图像融合算法[J]. 自动化学报, 2008, 34(12): 1508-1514.

编辑 刘冰