

基于优化 PCNN 与区域特征引导法则的图像融合

李文, 叶坤涛, 李晟

(江西理工大学理学院, 江西 赣州 341000)

摘要:针对传统红外与可见光图像融合算法存在着边缘信息缺失、目标特征不够突出等问题,本文提出一种基于优化脉冲耦合神经网络(PCNN)与区域特征引导法则的红外与可见光图像融合算法。首先,对红外与可见光图像分别进行非下采样剪切波变换(NSST),获取相应的低频分量和高频分量。其次,低频分量采用基于优化PCNN模型的融合规则进行融合;对于高频分量,利用图像的区域能量、改进空间频率和区域方差匹配度等特征,提出自适应的区域方差匹配度阈值和调节因子,构造区域特征引导法则完成融合。最后,对融合后的低高频分量进行NSST逆变换,获取融合图像。实验结果表明,本文算法可有效综合图像的优势信息,并在主观视觉和客观指标上均具有明显的优势。

关键词:图像融合;非下采样剪切波变换;优化脉冲耦合神经网络;区域特征引导法则

中图分类号:TP391.41 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2021.08.021

Image fusion based on optimized PCNN and region feature guided rule

LI Wen, YE Kun-tao, LI Sheng

(School of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: Aiming at the traditional infrared and visible image fusion algorithms have problems in the edge information missing and the target feature being not prominent enough, et al, a novel infrared and visible image fusion algorithm based on optimized pulse coupled neural network(PCNN) and region feature guided rule is proposed. Firstly, non-sub-sampled shearlet transform(NSST) is applied to infrared and visible images to obtain the corresponding low-frequency components and high-frequency components. Secondly, the low-frequency components are fused by using the fusion rules based on the optimized PCNN model. Moreover, for the high-frequency components, use the feature of image, such as region energy, improved spatial frequency and region variance matching degree, et al, an adaptive threshold of region variance matching degree and new regulator factors are proposed, thus the region feature guided rule is constructed to fuse the high-frequency components. Finally, the fused image is obtained by inverse NSST of the low-frequency and high-frequency fused components. Experimental results show that the proposed algorithm can effectively integrate dominant information in infrared and visible images, and has the obvious advantages in subjective vision and objective index.

Keywords: image fusion; non-sub-sampled shearlet transform; optimized pulse coupled neural network; region feature guided rule

基金项目:江西省教育厅科学技术研究项目(No. GJJ170526)资助。

作者简介:李文(1997-),男,硕士研究生,研究方向为图像处理。E-mail:13986775110@163.com

通讯作者:叶坤涛(1972-),男,博士,副教授,主要研究方向为MEMS,信号处理等。E-mail:mems_123@126.com

收稿日期:2020-11-12; **修订日期:**2020-06-22

1 引言

图像融合技术表示为获取同一场景下的多幅传感器图像后,在图像配准基础上采取某种方法融合成一幅对场景信息描述更为清晰、准确的图像^[1]。图像融合技术中应用较广的一类为红外与可见光图像融合,红外图像的细节信息丢失较严重,对比度和空间分辨率低,但成像时不受反射光的影响;而可见光图像能够捕获场景中的丰富细节信息,对比度和空间分辨率高,但成像时易受外界环境的干扰。红外与可见光图像融合所形成的融合图像可将二者的优势信息进行互补,获取更全面的场景信息,在目标跟踪、军事、医学和航空等领域均有着重要应用^[2]。

当前,图像融合方法一般分为三类,即基于空间域、基于变换域和基于神经网络等其他相关方法。虽然后两类融合方法均属于研究的热点,但第三类方法的参数较多且相关配置较复杂,融合效果也十分依赖相关参数的选取,因此,基于多尺度多方向的变换域方法一直深受研究学者们青睐。从早期的金字塔变换^[3]起,一系列的多尺度分析方法相继被研究学者们所提出,如离散小波变换、脊波变换、曲波变换、轮廓波变换、非下采样轮廓波变换(non-sub-sampled contourlet transform, NSCT)及剪切波变换等^[4]。早期的金字塔变换缺乏方向性、融合后的图像冗余度较高,且与离散小波变换、脊波变换、曲波变换、轮廓波变换及剪切波变换均易在图像边缘处产生伪吉布斯现象,从而丢失融合图像的部分边缘信息。NSCT 属于轮廓波的改进,虽然能够克服伪吉布斯现象外,具有平移不变性,但计算的复杂度偏高且分解的方向数有限,无法实现对图像的实时处理。

近期由剪切波变换改进而来的非下采样剪切波变换^[5](non-subsampled shearlet transform, NSST)得到广泛应用,NSST 不仅能够克服图像边缘处的伪吉布斯现象,而且具有平移不变性与各向异性,还具有良好的稀疏表示性能与低计算成本的特点^[6],成为应用于图像融合当中的一种更为理想的多尺度分析方法。研究表明 NSST 能在红外与可见光图像融合时获取更多的源图像细节信息,但仍存在着融合图像的纹理细节与边缘信息缺失、目标特征不够突出的现象^[7-8]。

为了解决上述可见光图像纹理细节与边缘信息缺失、红外目标不够突出问题,同时改善融合图像视

觉信息保真度,综合更多的红外与可见光图像优势信息,本文提出一种基于优化脉冲耦合神经网络(pluse coupled neural network, PCNN)与区域特征引导法则的红外与可见光图像融合算法。通过 NSST 将红外与可见光图像分解为低高频分量,利用图像低高频成分不同的特点,提出优化 PCNN 模型和区域特征引导法则分别对图像低高频分量进行融合。最后,对融合后的低高频分量进行 NSST 逆变换获取融合图像。实验对比其他 7 种传统及流行融合算法,表明了本文算法的优越性与可行性。

2 基本原理

2.1 NSST 分解

2007 年 Guo 等^[9]在传统的仿射系统基础上结合几何与多尺度变换,构造了剪切波变换。具有合成膨胀的仿射系统 $M_{AB}(\psi)$ 在空间维数 $n=2$, 满足如下条件:

$$M_{AB}(\psi) = \{\psi_{j,l,k}(x) = |\det A|^{j/2} \psi(B^l A^j x - k) : j, l \in \mathbb{Z}, k \in \mathbb{Z}^2\} \quad (1)$$

式(1)中, $\psi \in L^2(\mathbb{R}^2)$, $L^2(\mathbb{R}^2)$ 表示可积空间,通过对基函数 $\psi_{j,l,k}(x)$ 进行旋转、剪切和平移变换来构造仿射系统, A 与 B 为 2×2 的可逆矩阵,且 $|\det B| = 1$, A 为各向异性膨胀矩阵, B 为剪切矩阵, j 为分解尺度, l 为方向参数, k 为平移参数, \mathbb{Z} 为整数域。

Kutyniok 等^[10]对剪切波变换的详细理论作过阐述,并指出当 $M_{AB}(\psi)$ 具有紧框架, $M_{AB}(\psi)$ 的元素称为合成小波,其中 $A = \begin{bmatrix} a & 0 \\ 0 & a^{1/2} \end{bmatrix}$, $B = \begin{bmatrix} 1 & s \\ 0 & 1 \end{bmatrix}$, 此时的合成小波为剪切波,实际应用中,常取 $a = 4$, $s = 1$ 。

图 1 为 2 级 NSST 分解的示意图。




图 1 2 级 NSST 分解示意图

Fig. 1 Schematic two level decomposition of NSST

由图 1 可知 NSST 分解主要由非下采样金字塔 (non-subsampled pyramid, NSP) 分解和方向局部化组成^[11]。NSP 分解是采用非下采样金字塔滤波器组对源图像进行 k 级多尺度分解, 产生 1 个低频子带和 k 个高频子带, $k+1$ 个子带图像的尺寸与源图像相同。方向局部化是通过剪切滤波器 (shearlet filter, SF) 对高频子带进行 1 级多方向分解, 每个高频子带的 SF 分解都将产生 2^l 个不同方向的子带图像, 其尺寸与源图像相同。

2.2 优化 PCNN

PCNN 称为第三代人工神经网络, 是由若干个神经元相互链接形成的二维反馈型神经网络, 每个神经元由接收域、调制域和脉冲发生器共三部分组成。目前, PCNN 已被广泛运用在图像分割、图像融合及图像细化等方面^[12], 尤其在多尺度分析方法相结合进行图像融合时取得突出效果。

PCNN 中的每个神经元对应源图像中的每个像素, 本文在传统 PCNN 模型基础上简化, 同时对 PCNN 中的阈值函数进行改进, 使图像中较亮像素与较低像素之间的部分处理更为平滑, 提出优化 PCNN 模型, 其示意图如图 2 所示。




图 2 优化 PCNN 模型

Fig. 2 Optimized PCNN model

优化 PCNN 模型对应的数学表达式如下:

$$F_{ij}[n] = D_{ij} \quad (2)$$

$$L_{ij}[n] = e^{-\alpha_L} L_{ij}[n-1] + V_L \sum_{kl} W_{ijkl} Y_{kl}[n-1] \quad (3)$$

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]) \quad (4)$$

$$Y_{ij}[n] = \begin{cases} 1, & U_{ij}[n] > T_{ij}[n-1] \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

$$T_{ij}[n] = T_{ij}[n-1] - \Delta + V_T Y_{ij}[n] \quad (6)$$

式(2)~(6)中, (i, j) 为神经元位置; F_{ij} 、 D_{ij} 、 L_{ij} 、 U_{ij} 、 T_{ij} 分别为神经元的反馈输入、外部输入激励、链接项输入、内部活动项和动态阈值; β_{ij} 为链接强度; n 为迭代次数; (k, l) 为神经元的周围连接; α_L 为链

接衰减常数; Δ 为阈值衰减因子, 用于控制阈值的衰减程度; V_L 为链接放大系数; V_T 为阈值放大系数; W_{ijkl} 为神经元之间的突触链接权值; Y_{ij} 为神经元的脉冲输出, 其值 1 或 0 表示神经元成功点火与否。

Y_{ij} 为 1 时, 表示神经元成功点火一次。在 n 次迭代中, 计算 PCNN 输出的点火总次数, 作为低频融合系数选取的依据, n 次迭代中点火总次数 $Z_{ij}[n]$ 为:

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

3 本文融合算法设计

本文算法首先对已配准的红外图像 A 和可见光图像 B 进行 NSST 分解, 获取相应的低频分量和高频分量。其次, 对源图像 A 和 B 分解后所获取的低频分量采用优化 PCNN 模型进行融合, 对于高频分量采用区域特征引导法则进行融合。最后, 对融合后的低频高频分量进行 NSST 逆变换, 获取融合图像 F。图 3 显示了本文算法的融合过程。

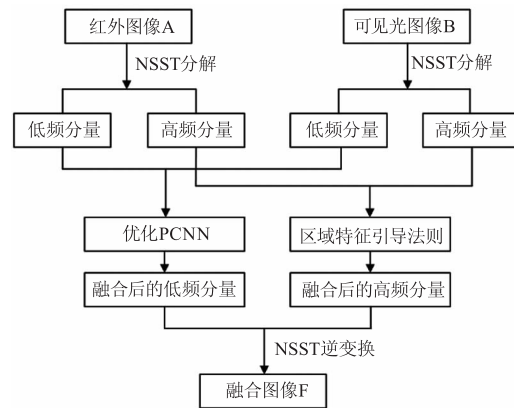


图 3 本文算法的融合过程

Fig. 3 The fusion process of this algorithm

3.1 低频分量的融合规则

NSST 分解后的低频分量为源图像的近似成分, 包含着图像的主要信息和大部分能量。传统的融合算法为简单加权或取平均的融合规则, 这类方法融合后将丢失图像的细节信息, 还降低图像的整体亮度, 而 PCNN 能够突出图像的细节部分, 同时保留图像的轮廓部分, 适用于低频分量融合, 因此, 本文提出一种基于优化 PCNN 模型的融合规则进行低频分量融合。

改进拉普拉斯能量和 (sum of modified Laplacian, SML)^[13] 一定程度上反映着图像的局部清晰度, SML 越大, 图像就相对越清晰。图像中的像素点与神经元相对应, 但每个神经元的链接强度不完全相同, 通过图像的区域特征自适应调整链接强度, 充分对应着神经元链接特性。图像处理中, 区域平均梯度可以敏锐地感知细节差异, 反映着图像的纹理信息变化。本文将 SML 作为 PCNN 的输入激励, PCNN 的链接强度 β 由区域平均梯度自适应调整。 $C_L^i(i, j)$ 表示红外与可见光图像 NSST 分解后的低频分量, $I = (A, B, F)$, A 为红外图像、B 为可见光图像、F 为融合图像。SML 定义为:

$$SML_L^i(i, j) = \sum_{x=-M}^M \sum_{y=-N}^N [ML_L^i(i+x, j+y)]^2 \quad (8)$$

$$ML_L^i(i, j) = |2C_L^i(i, j) - C_L^i(i-d, j) - C_L^i(i+d, j)| + |2C_L^i(i, j) - C_L^i(i, j-d) - C_L^i(i, j+d)| \quad (9)$$

式(8)~(9)中, $ML_L^i(i, j)$ 为改进拉普拉斯; d 为可变空间距离, 本文取 $d = 1$ 。 M 和 N 为区域窗口测度, 表示区域窗口大小为 $(2M+1) \times (2N+1)$, 本文取为 3×3 。

区域平均梯度 $\bar{G}_L^i(i, j)$ 定义为:

$$\bar{G}_L^i(i, j) = \frac{1}{(2M) \times (2N)} \sum_{i=1}^{2M} \sum_{j=1}^{2N} \{ [C_L^i(i, j) - C_L^i(i+1, j)]^2 + [C_L^i(i, j) - C_L^i(i, j+1)]^2 \}^{1/2} \quad (10)$$

设定链接强度 β_{ij}^l 由区域平均梯度自适应调整, 但又不完全依赖区域平均梯度, 这样既可以较好地表现出神经元之间的链接关系, 也可以反映出区域窗口内灰度的变换差异情况, 对应着被刺激神经元的点火先后。链接强度 β_{ij}^l 表示为:

$$\beta_{ij}^l = \beta_0 + \frac{1}{1 + \exp(-\bar{G}_L^i(i, j))} \quad (11)$$

式(11)中, β_0 为初始链接强度, 本文使用以往文献的经验取值, 取 $\beta_0 = 3.0$ 。

基于优化 PCNN 模型的融合规则, 包括以下 4 步:

Step1: 利用式(8)~(10)计算出红外与可见光低频子带在 3×3 区域内的 $SML_L^i(i, j)$ 和 $\bar{G}_L^i(i, j)$, 将 $SML_L^i(i, j)$ 作为 PCNN 模型的输入激励, 由 $\bar{G}_L^i(i, j)$ 与式(11)确定 PCNN 模型的链接强度;

Step2: 对优化 PCNN 模型的参数进行初始化设置, $L_{ij}[0] = U_{ij}[0] = T_{ij}[0] = Y_{ij}[0] = 0, Z_{ij}[0] = 0$, 设模型最大迭代次数为 N_{\max} ;

Step3: 根据式(2)~(7)进行 N_{\max} 次迭代, 计算最终的点火总次数 $Z_{ij}^A[N_{\max}]$ 、 $Z_{ij}^B[N_{\max}]$ 。

Step4: 低频分量融合系数 $C_L^f(i, j)$ 表示为:

$$C_L^f(i, j) = \begin{cases} C_L^A(i, j) Z_{ij}^A[N_{\max}] > Z_{ij}^B[N_{\max}] \\ C_L^B(i, j) Z_{ij}^B[N_{\max}] \leq Z_{ij}^A[N_{\max}] \end{cases} \quad (12)$$

3.2 高频分量的融合规则

图像的高频分量存储着图像绝大部分纹理细节与边缘信息, 反映着图像的突变特性, 高频分量融合效果直接关系着融合图像的清晰程度和视觉感官。为了更好地融合高频分量, 本文提出利用图像的区域能量、改进空间频率和区域方差匹配度等特征, 对图像间的关联性进行分析, 提出自适应的区域方差匹配度阈值和调节因子, 并将分析结果作为选择不同融合规则的引导信息, 由此构造区域特征引导法则对高频分量进行融合。

$C_{k,l}^i(i, j)$ 表示红外与可见光图像 NSST 分解后的高频分量, $I = (A, B, F)$, A 为红外图像、B 为可见光图像、F 为融合图像, 其中 k 为分解尺度, l 为 k 尺度上的方向数。高频分量的区域能量 $E_{k,l}^i$ 、改进空间频率 $MSF_{k,l}^i$ 、区域方差匹配度 $R_{k,l}^{AB}$ 分别为:

$$E_{k,l}^i = \sum_{x=-M}^M \sum_{y=-N}^N w(x+M+1, y+N+1) \cdot [C_{k,l}^i(i+x, j+y)]^2 \quad (13)$$

式(13)中, w 为窗口掩膜矩阵, 越靠近中心点其权

值相对越大, 本文取 $w = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}$ 。

$$MSF_{k,l}^i = \frac{1}{(2M+1) \times (2N+1)} \sum_{i=1}^{2M+1} \sum_{j=1}^{2N+1} \cdot (RF_{k,l}^i + CF_{k,l}^i + \eta_1 MDF_{k,l}^i + \eta_2 SDF_{k,l}^i) \quad (14)$$

$$RF_{k,l}^i(i, j) = [C_{k,l}^i(i, j) - C_{k,l}^i(i, j-1)]^2 \quad (15)$$

$$CF_{k,l}^i(i, j) = [C_{k,l}^i(i, j) - C_{k,l}^i(i-1, j)]^2 \quad (16)$$

$$MDF_{k,l}^l(i,j) = [C_{k,l}^l(i,j) - C_{k,l}^l(i-1,j-1)]^2 \quad (17)$$

$$SDF_{k,l}^l(i,j) = [C_{k,l}^l(i,j) - C_{k,l}^l(i-1,j+1)]^2 \quad (18)$$

式(14)~(18)中, $RF_{k,l}^l$ 、 $CF_{k,l}^l$ 、 $MDF_{k,l}^l$ 、 $SDF_{k,l}^l$ 分别为当前区域内的行、列、主对角和副对角频率, η_1 、 η_2 为距离因子, 本文取 $\eta_1 = \eta_2 = 1/\sqrt{2}$ 。

$$R_{k,l}^{AB} = \frac{2\sigma_{k,l}^A \sigma_{k,l}^B + R_0}{(\sigma_{k,l}^A)^2 + (\sigma_{k,l}^B)^2 + R_0} \quad (19)$$

式(19)中, $\sigma_{k,l}^A$ 和 $\sigma_{k,l}^B$ 分别为红外与可见光图像高频分量在某区域窗口内的方差, 取窗口大小为 3×3 ; R_0 为一较小常数, 避免式(19)出现分母为0的情况, 本文取 $R_0 = 0.0001$ 。

在 $E_{k,l}^l$ 、 $MSF_{k,l}^l$ 及 $R_{k,l}^{AB}$ 的基础上构造的区域特征引导法则, 包括以下4步:

Step1: 由式(13)~(19)可计算出高频分量 $C_{k,l}^A(i,j)$ 、 $C_{k,l}^B(i,j)$ 在 3×3 窗口内的区域能量 $E_{k,l}^A$ 、 $E_{k,l}^B$, 改进空间频率 $MSF_{k,l}^A$ 、 $MSF_{k,l}^B$ 以及区域方差匹配度 $R_{k,l}^{AB}$;

Step2: 计算出 $\frac{E_{k,l}^A}{E_{k,l}^A + E_{k,l}^B}$ 与 $\frac{E_{k,l}^B}{E_{k,l}^A + E_{k,l}^B}$ 之间的差值绝对值 $E_{k,l}^{AB}$, $\frac{MSF_{k,l}^A}{MSF_{k,l}^A + MSF_{k,l}^B}$ 与 $\frac{MSF_{k,l}^B}{MSF_{k,l}^A + MSF_{k,l}^B}$ 之间的差值绝对值 $MSF_{k,l}^{AB}$;

Step3: 分别将 $E_{k,l}^{AB}$ 、 $MSF_{k,l}^{AB}$ 与高频分量间的关联性阈值 θ 比较, θ 为介于0和1之间的常数, 具体取值可根据融合效果调整确定。若 $E_{k,l}^{AB}$ 、 $MSF_{k,l}^{AB}$ 全小于 θ , 表明 $C_{k,l}^A(i,j)$ 与 $C_{k,l}^B(i,j)$ 之间的关联性较强, 此时融合规则定义为:

$$C_{k,l}^F(i,j) = \lambda_1 C_{k,l}^A(i,j) + \lambda_2 C_{k,l}^B(i,j) \quad (20)$$

式(20)中, λ_1 为红外调节因子; λ_2 为可见光调节因子, 二者满足条件 $\lambda_1 + \lambda_2 = 1$ 。由于可见光图像相比于红外图像有更丰富的细节信息, 而图像的高频部分主要为细节信息, 设定可见光调节因子 λ_2 大于红外调节因子 λ_1 , 即 $\lambda_2 > 0.5$, 保证融合图像有较多细节信息。

λ_1 、 λ_2 具体取值取决于区域方差匹配度阈值, 江平^[7]等提出将区域方差匹配度阈值设为0.5~1之间的固定常数, 因不同尺度和不同方向上的高

频子带系数并不相同, 单一阈值不能较好地表现出多个高频子带之间的差异性。在此基础上, 本文构造自适应的区域方差匹配度阈值 $TR_{k,l}^{AB}$, 能够显现不同尺度及不同方向上高频子带的差异性, 同时度量区域方差匹配度 $R_{k,l}^{AB}$ 之间的相关性, $TR_{k,l}^{AB}$ 表示为:

$$TR_{k,l}^{AB} = \text{mean}(R_{k,l}^{AB}) + K \cdot \text{std}(R_{k,l}^{AB}) \quad (21)$$

式(21)中, $\text{mean}(R_{k,l}^{AB})$ 为 $R_{k,l}^{AB}$ 的均值, $\text{std}(R_{k,l}^{AB})$ 为 $R_{k,l}^{AB}$ 的标准差; K 为标准差系数, 为0~1之间的常数, 本文取 $K=0.5$ 。

确定 $TR_{k,l}^{AB}$ 后, 为给予 λ_2 较大值, 如文献[7]所描述, 若 $R_{k,l}^{AB}$ 大于 $TR_{k,l}^{AB}$ 时, λ_2 等价于较大的自适应因子 W_{\max} 。即 λ_2 表示为:

$$\lambda_2 = W_{\max} = \frac{1}{2} + \frac{1}{2} \cdot \frac{1 - R_{k,l}^{AB}}{1 - TR_{k,l}^{AB}} \quad (22)$$

由 $R_{k,l}^{AB}$ 大于 $TR_{k,l}^{AB}$ 时 λ_2 的表示方法, 进行推演变换, 若 $R_{k,l}^{AB}$ 不大于 $TR_{k,l}^{AB}$ 时, λ_2 表示为:

$$\lambda_2 = \frac{1}{2} + \frac{1}{2} \cdot \frac{1 - TR_{k,l}^{AB}}{1 - R_{k,l}^{AB}} \quad (23)$$

式(22)~(23)可确保 λ_2 总是大于 λ_1 , 保证融合图像有较多细节信息。

确定 λ_2 后, 根据 $\lambda_1 + \lambda_2 = 1$ 获得相应的 λ_1 。本文提出的红外调节因子 λ_1 与可见光调节因子 λ_2 , 可以保证融合图像有较多细节信息。

Step4: 若 $E_{k,l}^{AB}$ 、 $MSF_{k,l}^{AB}$ 不全小于关联性阈值 θ , 说明 $C_{k,l}^A(i,j)$ 与 $C_{k,l}^B(i,j)$ 之间的关联性一般, 此时融合规则定义为:

$$C_{k,l}^F(i,j) = \begin{cases} C_{k,l}^A(i,j), \alpha_1 > \alpha_2 \\ C_{k,l}^B(i,j), \alpha_1 < \alpha_2 \\ \Omega C_{k,l}^A(i,j) + (1 - \Omega) C_{k,l}^B(i,j), \alpha_1 = \alpha_2 \end{cases} \quad (24)$$

式(24)中, α_1 与 α_2 为选择因子, Ω 为权重系数。初始 $\alpha_1 = \alpha_2 = 0$, 若 $E_{k,l}^A \geq E_{k,l}^B$, $\alpha_1 = \alpha_1 + 1$, 否则 $\alpha_2 = \alpha_2 + 1$; 若 $MSF_{k,l}^A \geq MSF_{k,l}^B$, $\alpha_1 = \alpha_1 + 1$, 否则 $\alpha_2 = \alpha_2 + 1$ 。权重系数 Ω 表示为:

$$\Omega = \begin{cases} 1 & |C_{k,l}^A(i,j)| > |C_{k,l}^B(i,j)| \\ 0 & |C_{k,l}^A(i,j)| \leq |C_{k,l}^B(i,j)| \end{cases} \quad (25)$$

通过上述区域特征引导法则, 完成高频分量的融合。最后, 对融合后的低高频分量进行 NSST 逆

变换,获取融合图像 F。

4 实验结果与分析

为了验证本文算法的优势与有效性,对多组已配准的红外与可见光图像进行融合实验,实验环境为: Intel Core i5 - 9750H, CPU 主频为 2.60GHz, 内存 16GB, Windows10 操作系统, Matlab2019a 仿真平台。

实验中,本文算法与 LP^[3]、CVT^[14]、DTCWT^[15]、NSCT^[16]、NSCT-PCNN^[17]、NSST-PCNN^[2]、NSST-EOG-PCNN^[18] 共 7 种融合算法进行了比较,由于篇幅所限,现给出其中 3 组经典的红外与可见光图像融合结果为例,对 8 种算法的融合性能进行分析。

图 4、图 5 和图 6 为上述 7 种融合算法及本文算法分别对三组红外与可见光图像进行融合所获取的




图 4 Camp 图像的 8 种算法融合结果

Fig. 4 Fusion results of eight algorithms of Camp images

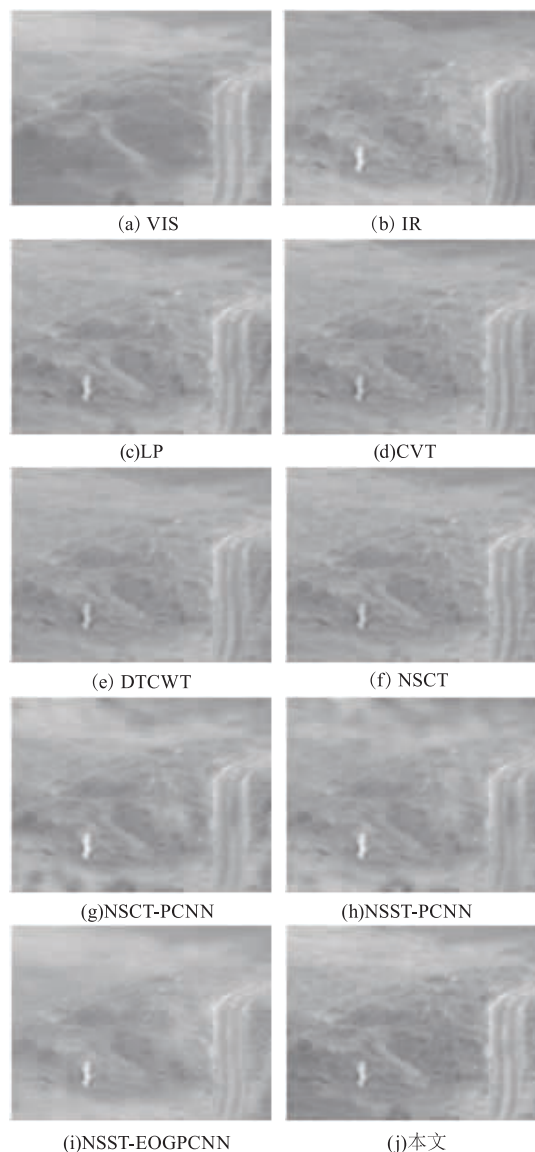


图 5 Dune 图像的 8 种算法融合结果

Fig. 5 Fusion results of eight algorithms of Dune images

融合图像。实验中,本文算法的参数设置为: NSST 分解中,选用 maxflat 为 NSST 分解滤波器,分解层数为 4 层,分解方向数为 {4,4,8,8}; 优化 PCNN 模型参数设置为: $W_{ijkt} = [0.707 \ 1 \ 0.707; 1 \ 0 \ 1; 0.707 \ 1 \ 0.707]$ 、 $N_{max} = 200$ 、 $\alpha_L = 1.0$ 、 $\Delta = 0.01$ 、 $V_L = 1.0$ 、 $V_T = 20$ 、 β 自适应选取。

从主观视觉效果比较图 4、图 5 和图 6,发现基于 LP 算法、CVT 算法、DTCWT 算法和 NSCT 算法所获取的融合图像整体偏暗,对比度较低,存在着纹理细节与边缘信息的丢失,同时基于 CVT 算法、DTCWT 算法和 NSCT 算法的融合图像在人物目标周围有较明显的伪影现象;基于 NSCT-PCNN 算法和 NSST-PCNN 算法融合效果较好,能够大体保留




图 6 Sandpath 图像的 8 种算法融合结果

Fig. 6 Fusion results of eight algorithms of Sandpath images

图像的人物目标特征和显著信息,但围栏、树木、山路等背景细节信息有部分丢失,山坡轮廓不够清晰;基于 NSST-EOGPCNN 算法的融合图像整体亮度过高且人物目标较模糊;本文算法的融合图像具有较高的对比度,亮度适中,综合了红外图像与可见光图像各自的有效信息,捕获了更多的纹理细节与边缘信息,人物目标更清晰突出,同时围栏、树木、山坡及山路等背景细节信息保留更完整。由此表明本文算法在主观视觉上优于其他 7 种融合算法。

同时,本文选取平均梯度 AG、空间频率 SF、信息熵 EN、标准差 SD、总体交叉熵 RCE 和视觉信息

保真度 VIFF 共 6 项客观指标对 7 种算法及本文算法的性能进行客观评价。表 1、表 2 和表 3 为 3 组经典红外与可见光图像融合时的客观指标结果。由表 1~3 中的 6 项客观指标对比分析,发现本文算法仅在 RCE 上略高于 NSCT-PCNN、NSST-PCNN 或 LP 算法,其余 5 项客观指标均明显优于另外 7 种传统及流行算法,说明本文算法在 6 项指标上表现更好,表明了本文算法具有较强的优越性。综合主观视觉和客观指标对比分析而言,本文算法具有明显优于另外 7 种算法的融合效果,有效地提取融合图像的红外目标特征、同时保留可见光边缘细节信息。

表 1 Camp 图像融合的客观指标结果

Tab. 1 Objective index results of Camp image fusion

算法	AG	SF	EN	SD	RCE	VIFF
LP	6.4548	12.3741	6.6610	29.1564	0.4684	0.4159
CVT	6.3384	12.0606	6.5437	27.0202	0.5833	0.3520
DTCWT	6.1245	11.8344	6.4973	26.3371	0.6625	0.3274
NSCT	6.3048	12.1009	6.5554	27.1715	0.6113	0.4110
NSCT-PCNN	6.0401	11.4953	6.8954	31.4998	0.2512	0.3370
NSST-PCNN	6.3166	11.9131	6.9612	32.8838	0.2074	0.3417
NSST-EOGPCNN	6.1441	11.2799	6.7460	30.0373	1.4604	0.3349
本文算法	6.7504	12.7687	7.1563	38.6913	0.3210	0.5303

表 2 Dune 图像融合的客观指标结果

Tab. 2 Objective index results of Dune image fusion

算法	AG	SF	EN	SD	RCE	VIFF
LP	3.6562	6.4323	5.9978	15.6159	0.2065	0.5826
CVT	3.4173	6.0109	5.9439	15.0151	0.2373	0.4992
DTCWT	3.3445	5.9805	5.9083	14.6614	0.2680	0.4749
NSCT	3.5309	6.2205	5.9480	15.0765	0.2381	0.5742
NSCT-PCNN	3.2489	5.8171	5.891	14.4748	0.2961	0.4097
NSST-PCNN	3.3919	6.0067	5.9190	14.7369	0.2690	0.4293
NSST-EOGPCNN	3.3045	5.9086	5.9863	15.4985	0.4702	0.3822
本文算法	3.7181	6.5115	6.3998	21.0332	0.1404	0.6187

表 3 Sandpath 图像融合的客观指标结果

Tab. 3 Objective index results of Sandpath image fusion

算法	AG	SF	EN	SD	RCE	VIFF
LP	7.3256	12.1258	6.5898	25.6275	0.2181	0.3399
CVT	6.9874	11.6176	6.4714	23.2817	0.3057	0.3053
DTCWT	6.7580	11.3237	6.4147	22.5029	0.3568	0.2706
NSCT	6.9913	11.6344	6.4561	23.0364	0.3215	0.3466
NSCT-PCNN	6.5033	10.9797	6.9256	34.8862	0.1761	0.3515
NSST-PCNN	6.9206	11.5252	6.9126	35.0347	0.1885	0.3410
NSST-EOGPCNN	6.4256	10.6795	6.7114	30.8759	0.8409	0.2776
本文算法	7.4578	12.3526	7.1255	39.4012	0.2734	0.4385

5 结论

本文提出一种基于优化 PCNN 与区域特征引导法则的红外与可见光图像融合算法,充分利用了 NSST 的多分辨率特性及各向异性,将图像分解为低高频分量,针对低高频成分各自的特点,提出优化 PCNN 模型和区域特征引导法则分别对图像低高频分量进行融合。采用 3 组经典红外与可见光图像对本文算法、7 种传统及流行算法进行融合性能对比实验为例,实验结果表明本文算法有效综合了红外与可见光图像各自的优势信息,解决红外与可见光图像融合所存在的边缘信息缺失、目标特征不够突出问题,并在主观视觉和客观指标上均具有明显的优势。

参考文献:

- [1] Goshtasby A A, Nikolov S. Image fusion: advances in the state of the art [J]. Information Fusion, 2007, 8 (2): 114 - 118.
- [2] Li Min, Yuan Xianjie, Luo Zhidan, et al. Infrared and visible image fusion method based on NSST and improved PCNN [J]. Journal of Optoelectronics · Laser, 2019, 30 (2): 185 - 191. (in Chinese)
李敏,苑贤杰,骆志丹,等.基于 NSST 与改进 PCNN 的红外与可见光图像融合方法 [J]. 光电子·激光, 2019, 30(2): 185 - 191.
- [3] Burt P J, Adelson E H. The laplacian pyramid as a compact image code [J]. IEEE Transactions on Communications, 1983, 31(4): 532 - 540.
- [4] Liu Zhijia, Jia Peng, Xia Yuhui, et al. Development and performance evaluation based on infrared and visible image fusion technology [J]. Laser & Infrared, 2019, 49 (5): 633 - 640. (in Chinese)
刘智嘉,贾鹏,夏寅辉,等.基于红外与可见光图像融合技术发展与性能评价 [J]. 激光与红外, 2019, 49 (5): 633 - 640.

- [5] Yin M, Liu W, Zhao X, et al. A novel image fusion algorithm based on nonsubsampling shearlet transform[J]. *Optik*, 2014, 125(10): 2274 – 2282.
- [6] Jiao Jiao, Wu Lingda, Yu Shaobo, et al. Image fusion method using multi-scale analysis and improved PCNN [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(6): 988 – 996. (in Chinese)
焦姣, 吴玲达, 于少波, 等. 混合多尺度分析和改进 PCNN 相结合的图像融合方法[J]. *计算机辅助设计与图形学学报*, 2019, 31(6): 988 – 996.
- [7] Jiang Ping, Zhang Qiang, Li Jing, et al. Fusion algorithm for infrared and visible image based on NSST and adaptive PCNN[J]. *Laser & Infrared*, 2014, 44(1): 108 – 113. (in Chinese)
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.
- [8] Deng Linuan, Yao Xinfeng. Research on the fusion algorithm of infrared and visible images based on non-sampled shearlet transform [J]. *Acta Electronica Sinica*, 2017, 45(12): 2965 – 2970. (in Chinese)
邓立暖, 尧新峰. 基于 NSST 的红外与可见光图像融合算法[J]. *电子学报*, 2017, 45(12): 2965 – 2970.
- [9] Guo K, Labate D. Optimally sparse multidimensional representation using shearlets [J]. *SIAM Journal on Mathematical Analysis*, 2007, 39(1): 298 – 318.
- [10] Kutyniok G, Labate D. *Shearlets: multiscale analysis for multivariate data*[M]. Switzerland: Birkhäuser Basel, 2012.
- [11] Yin M, Liu X, Liu Y, et al. Medical image fusion with parameter-adaptive pulse coupled neural network in non-sampled shearlet transform domain[J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 68(1): 49 – 64.
- [12] Wang Z, Ma Y, Cheng F, et al. Review of pulse-coupled neural networks[J]. *Image & Vision Computing*, 2010, 28(1): 5 – 13.
- [13] Huang W, Jing Z L. Evaluation of focus measures in multi-focus image fusion[J]. *Pattern Recognition Letters*, 2007, 28(4): 493 – 500.
- [14] Nencini F, Garzelli A, Baronti S, et al. Remote sensing image fusion using the curvelet transform [J]. *Information Fusion*, 2007, 8(2): 143 – 156.
- [15] Lewis J J, O'Callaghan R J, Nikolov S G, et al. Pixel- and region-based image fusion with complex wavelets[J]. *Information Fusion*, 2007, 8(2): 119 – 130.
- [16] Zhang Q, Guo B. Multifocus image fusion using the non-sampled contourlet transform [J]. *Signal Process*, 2009, 89(7): 1334 – 1346.
- [17] Qu X B, Yan J, Xiao H Z, et al. Image fusion algorithm based on spatial frequency-motivated pulse coupled neural networks in non-sampled contourlet transform domain [J]. *Acta Autom Sin*, 2008, 34(12): 1508 – 1514.
- [18] Zheng Wei, Zhao Chengchen, Hao Dongmei. Thyroid image fusion based on NSST and improved PCNN[J]. *Opto-Electronic Engineering*, 2016, 43(10): 42 – 48, 55. (in Chinese)
郑伟, 赵成晨, 郝冬梅. NSST 和改进 PCNN 相结合的甲状腺图像融合[J]. *光电工程*, 2016, 43(10): 42 – 48, 55.