

基于修正 PCNN 的多传感器图像融合方法

李敏^{1,2)} 蔡骋¹⁾ 谈正¹⁾

¹⁾ (西安交通大学电信学院信息工程研究所, 西安 710049) ²⁾ (第二炮兵工程学院计算机系, 西安 710025)

摘要 多传感器图像融合技术作为信息融合的重要分支和研究热点, 已广泛应用于机器视觉、医疗诊断、军事遥感等领域。为了更好地进行多传感器图像融合, 将在图像分割、目标识别等领域具有独特优势的脉冲耦合神经网络 (pulse coupled neural network, PCNN) 引入到多传感器图像融合领域中来, 提出了一种基于修正 PCNN 的多源图像融合方法, 该方法在区域分割的基础上, 先提取区域特征, 然后由特征指导融合过程; 同时, 从目标区域相对于背景显著性出发, 提出了一种反映目标区域突出性的新特征, 并针对传统 PCNN 参数无法自动设定的难题, 提出了基于修正 PCNN 的参数自动设定方案。实验结果表明, 该方法无论在主观视觉效果, 还是客观评价参数上均优于基于多分辨分析的融合算法, 且克服了传统像素级融合方法中融合图像模糊、对噪声敏感等不足, 尤其适用于图像不能严格配准的应用场合。这对于拓宽 PCNN 的理论研究和实际应用具有一定价值。

关键词 多传感器图像融合 脉冲耦合神经网络 参数设定 客观评价准则

中图分类号: TN911.73 TP391.41 文献标识码: A 文章编号: 1006-8961(2008)02-0284-07

Modified PCNN Based Multisensor Image Fusion Scheme

LIM in^{1,2)}, CAI Cheng¹⁾, TAN Zheng¹⁾

¹⁾ (School of Electrics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049)

²⁾ (Computer Science Department, The Second Artillery Engineering College, Xi'an 710025)

Abstract Being an efficient method of information fusion, multisensor image fusion has been used in many fields such as machine vision, medical diagnosis, military applications and remote sensing. In this paper, PCNN is introduced in this research field for its interesting properties in image processing, including segmentation, target recognition et al., and a multisensor image fusion scheme based on modified PCNN is proposed. The basic idea of the scheme is to segment all different input images by PCNN and to use this segmentation to guide the fusion process. At the same time, a new region feature, which emphasized the salience of target regions and its neighbors is proposed. Focusing on the famous difficult problem of PCNN, how to determine PCNN parameters adaptively, an adaptive PCNN parameters determination algorithm is also presented in this paper. Experimental results demonstrate that the proposed fusion scheme outperforms the multiscale decomposition based fusion approaches, both in visual effect and objective evaluation criteria. It avoids some of the well-known problems in pixel-level fusion such as blurring effects and high sensitivity to noise, particularly when there is mis-registration of the source images. The research fruits have certain value on the theory research and practical application of PCNN.

Keywords multisensor image fusion, pulse-coupled neural network (PCNN), parameter determination, objective evaluation criteria

1 引言

多传感器图像融合作为信息融合的重要分支和

研究热点, 已广泛应用于机器视觉、医疗诊断、军事遥感等领域^[1]。传统的像素级多分辨图像融合方法, 包括基于拉普拉斯金字塔、比率低通金字塔、梯度金字塔和小波变换等融合方法^[2], 它们在对源图

基金项目: 军队预研项目 (403050203); 国防“十五”重点预研项目 (41322029); 国防“十一五”重点预研项目 (513220208)

收稿日期: 2006-05-20 改回日期: 2006-10-17

第一作者简介: 李敏 (1971~), 女, 副教授, 博士。研究领域为图像处理、模式识别、信息融合等。E-mail: limin@mailst.xjtu.edu.cn

像进行多尺度分解和系数选取时, 由于大都孤立地处理各像素, 从而割裂了像素间的联系。此外, 尽管基于小波变换的图像融合方法在多分辨图像融合方法中是十分有效的, 但是由于传统的小波变换不具有平移不变性, 因此在源图像不能严格配准的情况下, 将直接影响融合效果。

脉冲耦合神经网络 (pulse coupled neural network, PCNN) 是对 Eckhom 等人根据猫的视觉皮层神经元脉冲串同步振荡现象提出的神经元模型^[3,4]加以修改和变化得到的, 因其在图像分割、目标识别等领域具有显著优势, 已成为近年来的研究热点。

本文提出了一种将 PCNN 应用于多传感器图像融合的具体方法, 即在对源图像进行配准的基础上, 对感兴趣区域进行分割, 首先提取区域特征; 然后由特征指导融合过程, 同时从目标区域相对于背景的显著性出发, 提出了一种反映目标区域突出性的新特征, 并针对传统 PCNN 参数无法自动设定的难题, 提出了基于修正 PCNN 的参数自动设定方案。文末结合同源和异源多传感器图像融合的应用实例, 给出了对比实验效果。

2 融合算法结构

本文提出的算法基本结构流程如图 1 所示。




图 1 本文算法结构图

Fig 1 Schematic diagram of the proposed fusion method

具体算法步骤如下:

(1) 对来自多传感器的源图像 I_1, I_2, \dots, I_M , 在经过配准的基础上, 利用修正 PCNN 进行区域分割, 并将各分割结果进行整合。设 $R_{m,i}$ 为第 m 个源图像 I_m ($m = 1, 2, \dots, M$) 经分割后所得的第 i 个区域;

(2) 提取以下能反映图像分割区域 $R_{m,i}$ 性能和清晰度的特征: 显著性因子 S 和可见性因子 V ;

(3) 将特征作为主要依据用于确定该区域在融合图像中的贡献系数, 即融合权值;

(4) 根据像素所属区域的融合权值, 通过自适

应加权平均最终得到融合图像。

3 基于修正 PCNN 的自适应图像分割

3.1 PCNN 模型及图像分割原理

构成 PCNN 的神经元是一个综合的动态非线性系统, 它包括接受域、内部活动项 (调制部分) 和脉冲发生器 3 部分 (如图 2 所示)。

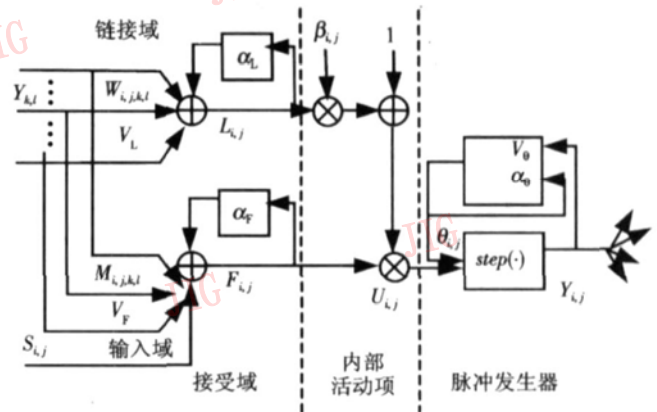


图 2 PCNN 神经元模型

Fig 2 PCNN neuron model

接受域包括输入域和链接域, 输入域接受来自外界的刺激 $S_{i,j}$ 和相邻神经元的输出 $Y_{i,j}$, 链接域仅接受相邻神经元的输出 $Y_{i,j}$ 。内部活动部分先将来自输入域和链接域的信号进行调制得到内部活动信号 $U_{i,j}$; 然后脉冲发生器将 $U_{i,j}$ 与动态门限 $\theta_{i,j}$ 进行比较, 若 $U_{i,j}$ 大于 $\theta_{i,j}$, 则脉冲发生器打开 (称该神经元点火), 输出为 1, 之后 $\theta_{i,j}$ 在阈值信号发生器中通过反馈迅速提高, 当其提高到大于 $U_{i,j}$ 时, 则脉冲发生器关闭, 输出为 0 从而形成脉冲信号。神经元 $N_{i,j}$ 的活动可由下式表述:

$$F_{i,j}(n) = \exp(-\alpha_F) \cdot F_{i,j}(n-1) + S_{i,j} +$$

$$V_F \cdot \sum M_{i,j,k,l} Y_{k,l}(n-1) \quad (1)$$

$$L_{i,j}(n) = \exp(-\alpha_L) \cdot L_{i,j}(n-1) +$$

$$V_L \cdot \sum W_{i,j,k,l} Y_{k,l}(n-1) \quad (2)$$

$$U_{i,j}(n) = F_{i,j}(n) (1 + \beta_{i,j} \cdot L_{i,j}(n)) \quad (3)$$

$$\theta_{i,j}(n) = \exp(-\alpha_0) \theta_{i,j}(n-1) + V_0 Y_{i,j}(n-1) \quad (4)$$

$$Y_{i,j}(n) = \text{step}(U_{i,j}(n) - \theta_{i,j}(n)) \quad (5)$$

式中, $F_{i,j}$ 为输入项, $L_{i,j}$ 为链接项, $U_{i,j}$ 为内部活动项, $\theta_{i,j}$ 为动态门限, $Y_{i,j}$ 表示该神经元产生的输出时序脉冲序列, n 为迭代次数, $\alpha_F, \alpha_L, \alpha_0$ 分别为输入项、链接项、门限时间衰减常数, V_F, V_L, V_0 为放大系

数, $M_{i j k l}$ 、 $W_{i j k l}$ 表示神经元 $N_{i+k, j+l}$ 与 $N_{i j}$ 的连接权值, $\beta_{i j}$ 是神经元 $N_{i j}$ 的连接系数, $step(\cdot)$ 表示单位阶跃函数。

$M \times N$ 大小的 2 维图像矩阵可以理解为 $M \times N$ 个 PCNN 神经元模型, 若将每个像素对应一个 PCNN 神经元, 则其每一个像素的灰度值对应为每个神经元的输入刺激 $S_{i j}$ 。若将这些神经元按一定方式连接, 就得到一个单层脉冲耦合神经网络, 当内部连接矩阵 M 、 W 所在邻域内有灰度值相近的像素存在时, 则其中某一个像素的脉动输出将会引起附近其他类似灰度像素对应神经元的激发, 并产生脉动序列输出 $Y(n)$ 。序列 $Y(n)$ 包含有图像区域、边缘、纹理等特征信息。这样由输出序列 $Y(n)$ 构成的二值图像序列就是 PCNN 输出的分割图像。

从以上分析可知, 传统的 PCNN 模型需要恰当设置其数学模型中各种放大系数、衰减时间常数、连接权值矩阵、连接系数等, 才能实现最佳分割。然而, 要自适应地确定这些参数是非常困难的。迄今为止, 解决这一问题的主要方法还停留在根据多次试验的人工调整参数阶段, 这显然不利于 PCNN 的应用。因此, 参数的自动确定问题已成为限制 PCNN 模型应用的一个难点^[4, 5]。

3 2 修正 PCNN 模型

近年来, 已有专家就 PCNN 参数自动设定问题进行了研究, 目前 PCNN 参数自动设定方法主要集中在以下两类: 一类是在固定其他参数的情况下, 只讨论某单个参数的自动设定方法^[5~7]; 另一类是采用简化 PCNN 模型, 在减少参数个数的情况下, 讨论参数的自动设定方法^[8, 9], 这也是目前的重要研究方向。然而目前此类方法要么对图像本身要求高, 缺乏自适应性; 要么如作者在论文中提到的, 需要通过许多图像数据进行大量的训练, 才能得到较好的参数定义, 进而获得满意的分割结果。

通过大量实验, 本文建立了一种基于多阈值预设的修正 PCNN 模型, 其神经元 $N_{i j}$ 的活动可用下式描述:

$$L_{i j}[n] = \sum W_{i j k l} Y_{k l}[n-1] \quad (6)$$

$$U_{i j}[n] = S_{i j} (1 + \beta_{i j}[n] L_{i j}[n]) \quad (7)$$

$$Y_{i j}[n] = \begin{cases} 1 & U_{i j}[n] > T_{i j}[n] \\ 0 & \text{其他} \end{cases} \quad (8)$$

其中, i, j 为图像中像素的位置, k, l 是指邻域内其他像素位置, n 为迭代次数。 $L_{i j}[n]$ 为像素 (i, j) 的邻

域链接项, $U_{i j}[n]$ 是像素 (i, j) 的内部活动项, 它由像素值 $S_{i j}$ 和链接项决定, $\beta_{i j}[n]$ 为链接系数, $Y_{i j}[n]$ 为 PCNN 在点 (i, j) 处的神经元输出, $T_{i j}[n]$ 是一组阈值, 其可通过 3.3 节中的水域法求得。

每个 PCNN 神经元接受其 3×3 邻域以内的神经元链接输入, 其内部链接矩阵 W 是一个 3×3 的方阵, 且每一个元素的值为对应像素到中心像素的欧几里德距离的倒数 (归一化处理)。链接系数 β_m 的值由下式决定:

$$\beta_m = \frac{T_m}{P_m} - 1 \quad (m = 1, \dots, M) \quad (9)$$

考虑到最小阈值 T_1 处, 其对应的左侧峰值处的灰度值 P_1 有可能为 0 因此可以选择 $\beta_1 = 0.1 \sim 0.3$ 。

3 3 水域法求图像多分割阈值

本文提出用水域概念来求取多分割阈值。

记 $P_{\max} = \{P_i^{\max}, i = 1, 2, \dots, K\}$ 为与图像 $f(x, y)$ 对应的灰度直方图 $hist(f(x, y))$ 中极大值点集合; $P_{\min} = \{P_j^{\min}, j = 1, 2, \dots, N\}$ 为极小值点集合; $P = \{P_m, m = 1, 2, \dots, M+1\}$ 为待求的峰值点集合, 且 $g_{P_1} < g_{P_2} < \dots < g_{P_{M+1}}$; $T = \{T_n, n = 1, 2, \dots, M\}$ 为待求的阈值点集合, 且 $g_{T_1} < g_{T_2} < \dots < g_{T_M}$, $P \subseteq P_{\max}$, $T \subseteq P_{\min}$ 。

定义 (水域 water-valley)。如图 3 所示, 对第 i 幅图像直方图 $hist(f(x, y))$ 中的两个极大值点 $P_{i_1}^{\max}$ 和 $P_{i_2}^{\max}$, 其对应的灰度值分别为 $g_{P_{i_1}^{\max}}$ 和 $g_{P_{i_2}^{\max}}$, 且 $g_{P_{i_1}^{\max}} < g_{P_{i_2}^{\max}}$, 如果在区间 $(g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}})$ 内不存在其他极大值点或灰度均小于 $\min\{g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}}\}$, 则两者之间可构成一个水域 R_{valley} ——即以 $hist(f(x, y))$ 包络线为底, 以 $\min\{g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}}\}$ 为水域高度, 用假想的水充满该空间的水域, 而整个水域的蓄水量则定义为水域面积 $area(g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}})$, 其计算公式为

$$area(g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}}) = \frac{1}{2} \int_{g_{P_{i_1}^{\max}}}^{g_{P_{i_2}^{\max}}} \{[\min\{g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}}\} - hist(x)] + |\min\{g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}}\} - hist(x)|\} dx \quad (10)$$

设 P_j^{\min} 为区间 $(g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}})$ 内的最小值点, 即对 $\forall g_x \in (g_{P_{i_1}^{\max}}, g_{P_{i_2}^{\max}})$, 均满足 $hist(g_x) \geq g_{P_j^{\min}}$ 。相应地, 可将水域表示为 R_{valley} , 其在直方图上的灰度区间为 $(g_{P_{i_1}^{\max}}, g_{P_j^{\min}}, g_{P_{i_2}^{\max}})$, 如图 3 中所示的深色区域。

峰值和阈值的求取过程如下:

- (1) 绘制图像 $f(x, y)$ 的直方图 $hist(f(x, y))$, 并根据需要对其进行平滑处理, 以减小噪声的影响。
- (2) 求出 $hist(f(x, y))$ 中所有极值点, 包括极

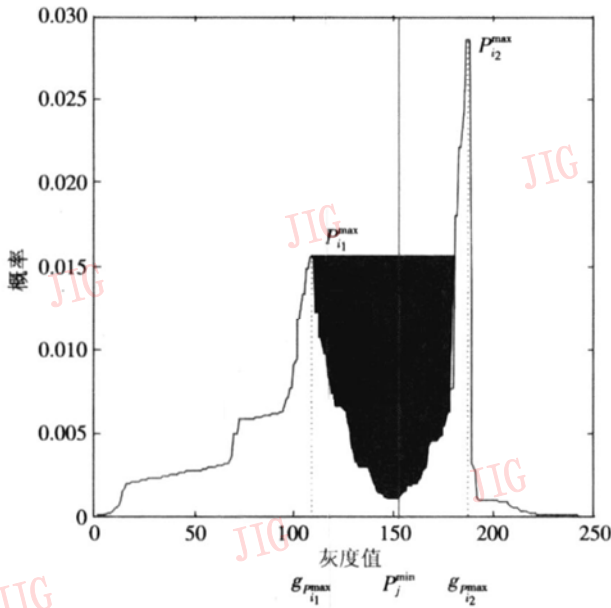


图 3 水域模型示意图

Fig 3 Figure of water valley

大值点集合 P_{max} 和极小值点集合 P_{min} 。为了构筑水域的需要, 本文规定直方图两侧的极值点必须是极大值点, 即 $K = N + 1$ 。

(3) 取最左侧极小值点 P_L^{min} 及其两侧的极大值点 P_1^{max} 和 P_2^{max} , $g_{P_1^{max}} < g_{P_L^{min}} < g_{P_2^{max}}$, 构建灰度区间为 $(g_{P_L^{max}}, g_{P_C^{max}}, g_{P_C^{max}})$ 的水域 R_{valley} , 并由式 (10) 计算水域面积 $A = area(g_{P_L^{max}}, g_{P_C^{max}})$ 。

(4) 阈值和峰值判定

1) 如果 $A > \Theta$ (Θ 为某一限值), 则认为灰度区间为 $(g_{P_L^{max}}, g_{P_C^{max}}, g_{P_R^{max}})$ 的水域 R_{valley} 为理想分割水域, P_C^{min} 为理想分割阈值, 将其存入阈值数组 T 中, 同时将相应的左侧极大值 $g_{P_L^{max}}$ 存入峰值数组 P 中; 分别取 P_R^{max} , P_R^{min} , P_R^{max} 作为新水域的左侧极大值点、最小值点和右侧极大值点。

2) 如果 $A < \Theta$, 则认为该水域为伪分割水域, 比较两侧极大值点 P_L^{max} 和 P_R^{max} 的大小:

① 如果 $g_{P_L^{max}} > g_{P_R^{max}}$, 则取 P_L^{max} 为新水域的左侧极大值点, 取 P_R^{max} 为新水域的右侧极大值点; 再比较 P_C^{min} 与 P_R^{min} 的灰度值, 取小者作为新水域的最小值点。

② 如果 $g_{P_L^{max}} \leq g_{P_R^{max}}$, 则分别取 P_R^{max} , P_R^{min} , P_R^{max} 作为新水域的左侧极大值点、最小值点和右侧极大值点。

(5) 由式 (10) 计算新水域的面积, 并重新执行步骤 (4), 直至所有的极小值点被处理完。

最终获得的阈值数组 $\{T_k, k = 1, 2, \dots, M\}$ 中就保存着图像的 M 个阈值, 并且有 $g_{T_1} < g_{T_2} < \dots < g_{T_M}$, 同

时还获得峰值数组 $\{P_m, m = 1, 2, \dots, M + 1\}$, 且 $g_{P_1} < g_{P_2} < \dots < g_{P_{M+1}}$ 。由此可知, 一个灰度区间为 $(g_{P_m}, g_{T_m}, g_{P_{m+1}})$ 的有效的水域 R_{valley} 包括两个相邻的峰值点 P_m, P_{m+1} 和一个阈值点 $T_m (g_{P_m} < g_{T_m} < g_{P_{m+1}})$ 。

3.4 自适应参数设定方法

该算法的基本思想是从最大的阈值 g_{T_M} 开始, 利用 PCNN 算法将平均值大于 g_{T_M} 的目标首先从图像中提取出来, 即保持 g_{T_M} 不变用 PCNN 算法进行迭代计算, 直至不再有新的神经元被点火。试验发现, 在同一个阈值处的迭代次数可根据图像特性不同而有一定差异, 通常为 20~70 次。在最大阈值点 T_M 处的迭代完成后, 再将所有自然点火和受激点火的神经元收集到一起, 这就是 PCNN 算法分割的第 1 个目标, 也是亮度最大的目标。接下来, 就可以在 T_{M-1} 处采用同样的算法分割出第 2 个目标, 如此反复, 直至所有的阈值被分析完毕。最后就获得了总共 $M + 1$ 个亮度不同的目标。

4 特征提取

4.1 显著性因子

通过对同源和异源图像融合的实例分析发现, 对同一目标而言, 它在不同源图像中的边缘清晰程度与相应源图像在融合过程中的贡献系数成正比。本文依据目标区域边界相对于背景邻域的突出性, 提出显著性因子作为区域的提取特征之一。

对于各分割区域 R_m , 先将其边缘进行 8 邻域扩张, 形成一条宽约为 3 个像素的边缘带, 然后求取带内所有属于和不属于该目标区域的像素平均灰度值之差, 其绝对值即定义为相应目标区域的显著性因子:

$$S = \left| \frac{1}{M} \sum_{i=1}^M f_i - \frac{1}{N} \sum_{j=1}^N g_j \right| \quad (11)$$

式中, f_i 为区域边缘带上任一属于该区域的像素灰度值, M 为其像素总个数; g_j 为区域边缘带上任一不属于该区域的像素灰度值, N 为其像素总个数。

4.2 可见性因子

根据人眼生理视觉特性, 本文采用的可见性因子 V 定义如下^[10]:

$$V_{R_m, i} = \frac{1}{H} \sum_{(x, y) \in R_{m, i}} \left| \frac{1}{m_i} \right|^\alpha \frac{|f(x, y) - m_i|}{m_i} \quad (12)$$

式中, α 为视觉常数 (0.6~0.7), H 是分割区域 $\sum R_{m, i}$ 中的像素总数, m_i 为区域中像素平均灰度值。以显著性因子和可见性因子作为区域融合依

据,通过自适应确定权值即可得到融合图像。

图 4 为未精确配准的多聚焦图像融合实例。由图 4 可见,图 4(a)所示的图片左前方的物体聚焦,

右后方的物体离焦,而图 4(b)所示的图片则刚好相反。采用人工剪切和粘贴的方法合成的聚焦清晰的参考图片如图 4(c)所示。

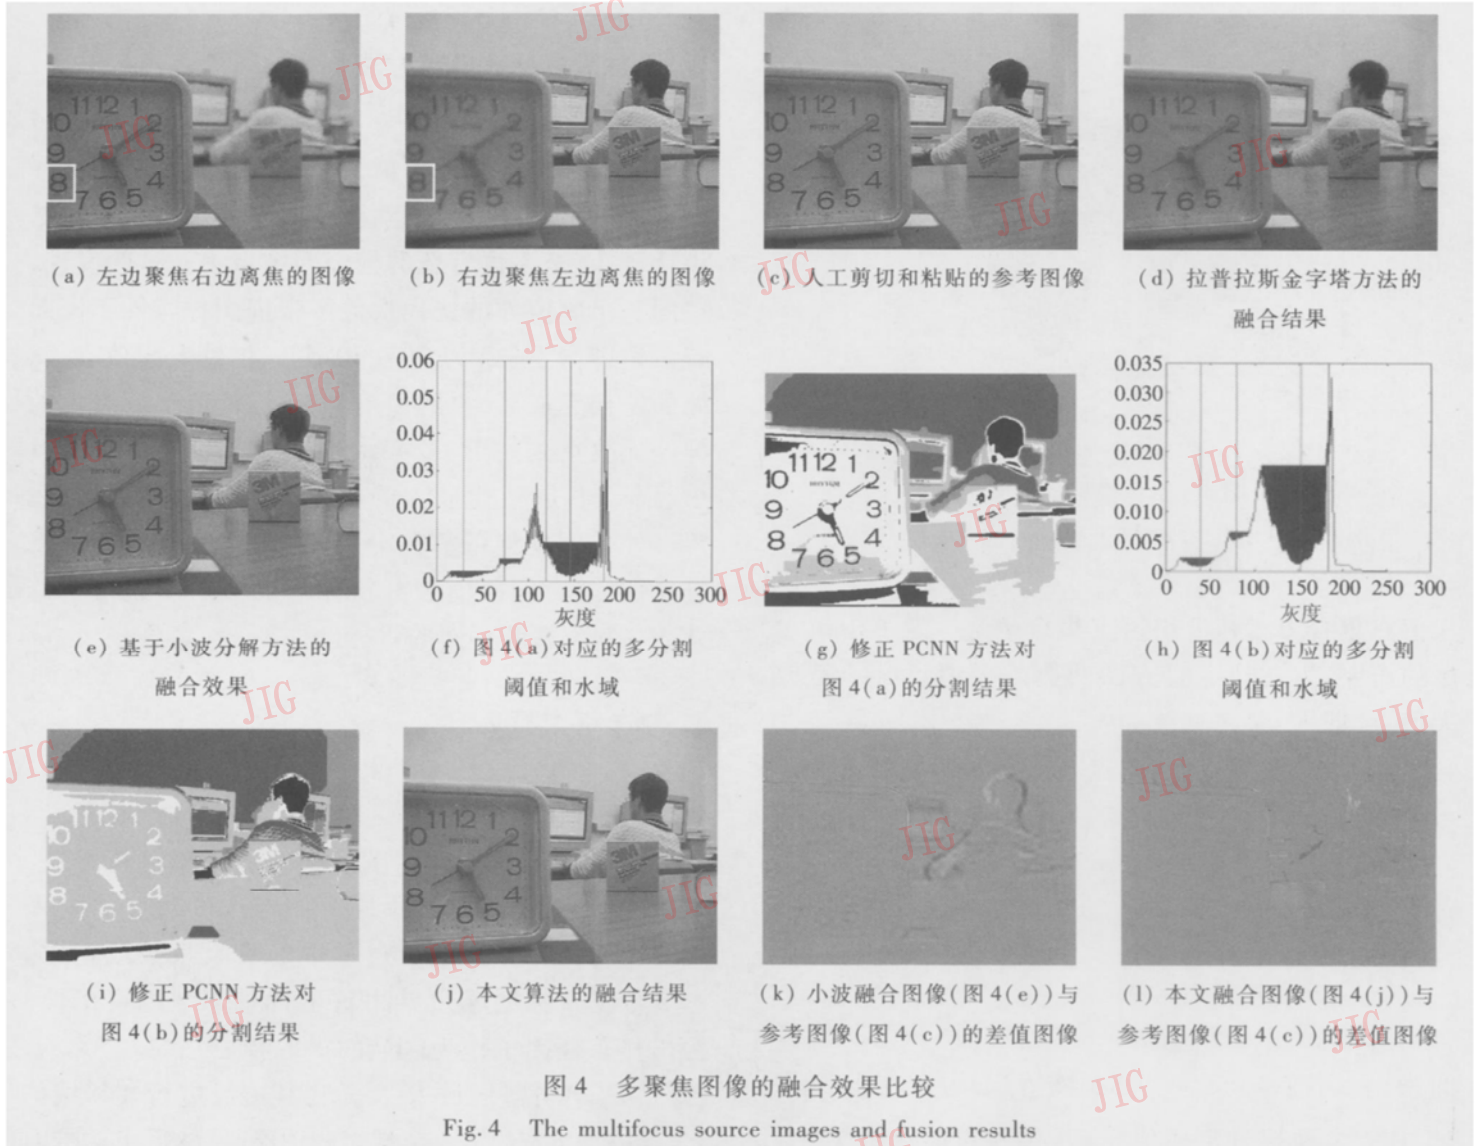


图 4 多聚焦图像的融合效果比较

Fig. 4 The multifocus source images and fusion results

本文分别对图 4(a)和图 4(b)中表盘字符“8”所在区域的 S 值和 V 值进行计算,实验结果见表 1。由表 1 可知若对应区域越清晰,则其 S 值就越大,且 S 值与视觉效果吻合良好。

表 1 显著性因子和可见性因子示例

Tab 1 S and V values for special region in Fig 4

| 区域 | S | | V | |
|--------------|--------|--------|----------|----------|
| | 图 4(a) | 图 4(b) | 图 4(a) | 图 4(b) |
| 图 4 中表盘字符“8” | 53 002 | 13 668 | 0 036 18 | 0 007 29 |

5 实验与讨论

5.1 多分辨分析融合方法

目前,基于多分辨分析的图像融合算法是多传感

器图像融合领域应用非常广泛和极其重要的一类。本文利用拉普拉斯金字塔分解融合法和小波分解融合法与本文方法进行了融合对比实验。其中小波变换采用 Daubechies 的 8 系数小波,分解层数为 3 并采用基于区域能量匹配度的融合规则^[2]进行融合, α 取值为 0.7。金字塔分解采用拉普拉斯金字塔,分解层数为 3 采用灰度值平均融合规则进行融合。

5.2 融合效果客观评价准则

为了更好地评价不同方法的融合效果,本文引入了一些用于融合图像效果客观评价的准则,其中包括均方根误差 (root mean square error, RMSE)、灰度标准差 σ_g 、交叉熵 (cross entropy, CEN) 和互信息 (mutual information, MI),各参数定义如下:

$$RMSE = \sqrt{\frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} [R(i, j) - F(i, j)]^2}$$

$$CEN(P:Q) = \sum_{g=0}^{L-1} p(g) \log_2 \frac{p(g)}{q(g)}$$

$$\sigma_g = \sqrt{\sum_{g=0}^{L-1} \left(g - \sum_{g=0}^{L-1} gp(g) \right)^2 p(g)}$$

$$MI = \sum_{i=1}^L \sum_{j=1}^L h_{R,F}(i,j) \log_2 \frac{h_{R,F}(i,j)}{h_R(i)h_F(j)}$$

其中, $R(i, j)$ 和 $F(i, j)$ 分别为理想融合图像(参考图像)和实际融合图像 (i, j) 点的值, M 和 N 为图像的尺寸, L 为图像的灰度级数, $P = \{p(0), p(1), \dots, p(g), \dots, p(L-1)\}$ 和 $Q = \{q(0), q(1), \dots, q(g), \dots, q(L-1)\}$ 分别为两幅图像的概率分布, $p(g)$ 为灰度等于 g 的像素数与图像总像素数的比值, $h_{R,F}(i, j)$ 为图像 R 和 F 间的归一化联合灰度直方图分布, $h_R(i)$ 和 $h_F(j)$ 分别为两幅源图像的归一化边缘直方图分布。均方根误差越小, 说明融合图像与理想图像越接近; 交叉熵直接反映了两幅图像对应像素的差异, 若差异越小, 则融合方法从原始图像中提取的信息越多; 灰度标准差反映了相对灰度均值的离散状况, 即标准差越大, 灰度分布越分散; 互信息衡量的是融合图像对标准参考图像不确定性的减少量, 故其值越大越好。

5.3 同源多传感器图像融合实验

以多聚焦图像为例。图 4 给出了非精确配准同源多传感器图像融合效果比较, 由图 4 可见, 图 4(a)和图 4(b)中学生的头部有相对位移。采用不同融合方法所得融合结果见图 4(d)~图 4(f)。图 4(k)、图 4(l)分别为基于小波变换的融合图像、

基于本文方法的融合图像与参考图像的差值图。

由图 4 可以看出, 利用本文算法所得的融合图像边缘最清晰、细节最丰富, 由于人的头部存在相对运动, 利用拉普拉斯金字塔和小波变换的融合方法所得的融合效果中该位置都较模糊, 而在用本文算法所得的融合图像中则基本无此现象, 这是因为本文提出的基于修正 PCNN 的融合方法充分考虑到像素间的相关性, 克服了多分辨分析方法割裂像素间联系的不足的缘故, 这一点在差值图像(图 4(k)和图 4(l))中体现得更加明显。

根据融合效果客观评价公式计算出的量化指标如表 2 所示。

表 2 图 4 中不同方法的图像融合效果对比


Tab 2 Performance of the different methods on Fig 4

| 融合方法 | 均方根误差 | 灰度标准差 | 互信息量 |
|---------|--------|---------|--------|
| 拉普拉斯金字塔 | 7.1126 | 45.5013 | 7.0815 |
| 小波变换 | 4.6622 | 46.7919 | 6.7239 |
| 本文方法 | 3.5002 | 47.7826 | 8.3126 |

从表 2 可知, 利用本文方法融合后的图像的均方根误差最小, 灰度标准差和互信息量最大, 优于基于多分辨分析的融合效果。通过人眼的主观判断也可以确定, 基于本文方法的融合结果最清晰。

5.4 异源多传感器图像融合实验

如图 5 所示, 针对不同波段的遥感图像融合示例, 融合后的图像同时具有两种不同波段源图像的信息。融合效果的客观评价参数见表 3。



(a) 遥感波段 1 图像 (b) 遥感波段 2 图像 (c) 基于小波分解的融合结果 (d) 本文算法的融合结果

图 5 某地区多波段遥感图像的融合效果比较

Fig. 5 The multi-wave band remote sensor source images and fusion results

表 3 图 5 中不同方法的图像融合效果对比

Tab 3 Performance of different fusion methods on Fig 5

| 融合方法 | 交叉熵 | 灰度标准差 | 互信息量 |
|------|--------|---------|--------|
| 小波变换 | 2.1765 | 65.3594 | 3.6022 |
| 本文方法 | 0.3632 | 67.4870 | 5.8372 |

综上所述, 由主观视觉效果和客观评价量化指

标上都可以看出, 本文方法融合效果优于基于小波变换的融合方法。

6 结论与展望

脉冲耦合神经网络是近年来逐渐兴起的一个研

究热点,其理论模型和应用领域都有待进一步深入研究和拓展。本文提出一种将 PCNN 应用于多传感器图像融合的具体方法,并针对传统脉冲耦合神经网络参数无法自动设定的难题,提出了基于修正 PCNN 的参数自动设定方案。

结合多传感器图像融合的大量实验结果表明,本文方法充分考虑到了像素间的相关性,其无论在主观视觉效果,还是客观评价参数上均优于基于多分辨分析的融合算法,尤其适用于源图像无法严格配准的应用场合。此外,本文提出的水域面积算法对于成功解决 PCNN 参数难以自动确定的难题具有理论和实际应用价值。

参考文献 (References)

- 1 Hall D L, Llinas J. An introduction to multisensor data fusion [J]. Proceedings of the IEEE, 1997, 85(1): 6~23
- 2 Zhang Z, Blum R S. A categorization of multiscale-decomposition-based image fusion schemes with a performance study for a digital camera application [J]. Proceedings of IEEE, 1999, 87(8): 1315~1326
- 3 Eckhom R, ReilBoeck H J. Feature linking via synchronization among distributed assemblies: simulation of results from cat visual cortex [J]. Neural Computation, 1990, 2(3): 293~307
- 4 Kuntimad G, Ranganath H S. Perfect image segmentation using pulse-coupled neural networks [J]. IEEE Transactions on Neural Networks, 1999, 10(3): 591~598
- 5 Ma Y rde, Dai Ruo-lan, Li Lian. Automated image segmentation using pulse-coupled neural networks and image's entropy [J]. Journal of China Institute of Communications, 2002, 23(1): 46~51. [马义德, 戴若兰, 李廉. 一种基于脉冲耦合神经网络和图像熵的自动图像分割方法 [J]. 通信学报, 2002, 23(1): 46~51.]
- 6 Liu Q in, Ma Y rde, Qian Zhir-bai. Automated image segmentation using improved PCNN model based on cross-entropy [J]. Journal of Image and Graphics, 2005, 10(5): 579~584. [刘勃, 马义德, 钱志柏. 一种基于交叉熵的改进型 PCNN 图像自动分割新方法 [J]. 中国图象图形学报, 2005, 10(5): 579~584.]
- 7 Gu X D, Guo S D, Yu D H. A new approach for automated image segmentation based on unit-linking PCNN [A]. In: Proceedings of the first International Conference on Machine Learning and Cybernetics [C], Beijing, China, 2002, 175~178
- 8 Bi Ying-wei, Qiu Tian-shuang. An adaptive image segmentation method based on a simplified PCNN [J]. ACTA Electronica Sinica, 2005, 33(4): 647~650. [毕英伟, 邱天爽. 一种基于简化 PCNN 的自适应图像分割方法 [J]. 电子学报, 2005, 33(4): 647~650.]
- 9 Karvonen J A. Baltic sea ice SAR segmentation and classification using modified pulse-coupled neural networks [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(7): 1566~1574
- 10 Huang J W, Shi Y Q, Dai X H. A segmentation-based image coding algorithm using the features of human vision system [J]. Journal of Image and Graphics, 1999, 4(5): 400~404. [黄继武, Shi Y Q, 戴宪华. 基于视觉系统特性的图像分割编码算法 [J]. 中国图象图形学报, 1999, 4(5): 400~404.]