

# 基于并行点火 PCNN 模型的图像 分割新方法

彭真明<sup>1</sup> 蒋彪<sup>1</sup> 肖峻<sup>1</sup> 孟凡斌<sup>2</sup>

**摘要** 提出一种并行点火脉冲耦合神经网络 (Parallelized firing pulse coupled neural networks, PFPCNN) 模型的图像分割方法. 首先用改进的 Unit-linking PCNN (ULPCNN) 模型对图像进行增强, 便于后续的图像分割. 然后采用 PFPCNN 新模型对增强后的图像进行分割, 最后用最大香农熵方法判定最佳分割结果. 各种复杂场景下的仿真实验及定量评价表明, 本文提出的图像分割方法, 其效果明显优于常规的 PCNN 分割方法.

**关键词** 脉冲耦合神经网络, 并行点火模型, 图像增强, 最大香农熵, 图像分割

中图分类号 TP391

## A Novel Method of Image Segmentation Based on Parallelized Firing PCNN

PENG Zhen-Ming<sup>1</sup> JIANG Biao<sup>1</sup> XIAO Jun<sup>1</sup>  
MENG Fan-Bin<sup>2</sup>

**Abstract** A novel method for image segmentation based on parallelized firing pulse coupled neural networks (PFPCNN) is presented in this paper. At first, the improved unit-linking PCNN (ULPCNN) is used to enhance the image. Then, PFPCNN model is adopted to segment the enhanced image by the improved ULPCNN. Finally, the maximal Shannon entropy is used to determine the optimal result from the segmented images. Experimental results show that the proposed method is more effective than the traditional PCNN and other improved PCNN models by quantitatively evaluating their performance.

**Key words** Pulse coupled neural networks (PCNN), parallelized firing model, image enhancement, image segmentation, maximum Shannon entropy

脉冲耦合神经网络 (Pulse coupled neural networks, PCNN), 是一种不同于传统人工神经网络的新型神经网络, 它有着生物学的背景, 是依据猫、猴等动物的大脑视觉皮层上的同步脉冲发放现象提出的<sup>[1]</sup>. 迄今 PCNN 已广泛应用于机器视觉、模式识别、故障诊断以及决策优化<sup>[2-3]</sup> 等方面. PCNN 神经元可与图像中的像素一一对应, 故尤其适合于图像处理<sup>[4]</sup>, 如图像分割<sup>[5-8]</sup>、图像融合<sup>[9-10]</sup>、图像压缩<sup>[11]</sup> 和目标检测<sup>[12]</sup> 等. 目前已有许多文献对原 PCNN 模型进行了诸多改进, 如 Unit-linking PCNN (ULPCNN)<sup>[13]</sup>, 并将其应用于图像分割. 这些方法虽然能取得较好的效果, 但对于对比度较低、背景或目标灰度分布较复杂的图像, 目前的

PCNN 图像分割方法仍难以获得好的效果. 在实际的各种传感器成像过程中, 特别是光学成像时, 经常由于光照条件 (如光照强度, 照射角度)、传播介质和目标表面的反射特性等因素的影响, 使成像背景的灰度在成像平面上呈连续缓慢变化, 且分布范围延伸较广, 这给图像分割带来了极大的困难. 现有的基于 PCNN 的图像分割方法无法解决此类难题.

本文提出了一种基于并行点火 PCNN (Parallelized firing PCNN, PFPCNN) 模型的图像分割新方法. 首先用改进的 PCNN 模型对图像进行增强, 其中, 对原 PCNN 模型做了改进和简化, 并结合边界增强方法, 取得了较常规方法更好的预处理效果, 为后续图像分割做准备. 然后采用 PFPCNN 新模型对增强后的图像进行分割, 这里 PFPCNN 新模型, 解决了灰度均匀缓慢变化的图像分割难题. 最后, 用最大图像熵的方法判定最佳分割结果. 各种仿真实验结果表明, 本文提出的方法, 其效果明显优于传统 PCNN 及一些改进 PCNN 的图像分割方法.

## 1 PCNN 基本原理

PCNN 是一种不同于传统人工神经网络的新型神经网络, 它是在 Eckhorn 提出的连接模型基础上得到的<sup>[1]</sup>. 构成 PCNN 的单个神经元模型如图 1 所示, 图中  $F_{ij}$  是第  $i, j$  个神经元的第  $n$  次反馈输入,  $I_{ij}$  为输入刺激信号,  $L_{ij}$  为连接项,  $\beta$  为连接系数,  $U_{ij}$  为内部活动项,  $T_{ij}$  为动态门限,  $Y_{ij}$  为 PCNN 脉冲输出值.

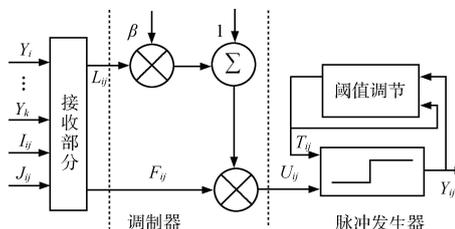


图 1 构成 PCNN 的单个神经元模型  
Fig. 1 The single neuron model of PCNN

PCNN 神经元的输入部分接收来自反馈输入  $F_{ij}$  和连接输入  $L_{ij}$ ; 连接部分主要是形成内部活动项  $U_{ij}$ ; 脉冲产生部分由阈值调节器、比较器、脉冲发生器组成. 当  $U_{ij}$  大于动态门限  $T_{ij}$  时, PCNN 神经元产生输出  $Y_{ij}$ . 将图 1 所示的神经元相互连接, 就构成了 PCNN.

PCNN 的数学方程描述为式 (1)~(5), 其中,  $M_{ijkl}$ ,  $W_{ijkl}$  是神经元之间的联接权系数,  $\alpha, \beta$  分别为对应项的衰减系数和放大系数.

$$F_{ij}[n] = \exp(-\alpha_F)F_{ij}[n-1] + V_F \sum M_{ijkl}Y_{kl}[n-1] + I_{ij} \quad (1)$$

$$L_{ij}[n] = \exp(-\alpha_L)F_{ij}[n-1] + V_L \sum W_{ijkl}Y_{kl}[n-1] \quad (2)$$

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]) \quad (3)$$

$$Y_{ij}[n] = \begin{cases} 1, & U_{ij}[n] > T_{ij}[n] \\ 0, & \text{其他} \end{cases} \quad (4)$$

$$T_{ij}[n] = \exp(-\alpha_T)F_{ij}[n-1] + V_T \sum Y_{kl}[n-1] \quad (5)$$

其中  $n$  代表迭代次数.

将一幅图像的每个像素视为 1 个神经元, 像素的灰度值为外部刺激输入  $I_{ij}$ , 假设所有神经元的初始状态值为 0, 第一次迭代时, 内部活动项  $U_{ij}$  等于外部刺激输入  $I_{ij}$ , 所有神

收稿日期 2007-06-15 收修稿日期 2007-11-12  
Received June 15, 2007; in revised form November 12, 2007  
航空科学基金 (20060112116), 国防预研基金 (9140A01060108DZ02) 资助  
Supported by the Aeronautic Science Foundation of China (20060112116) and National Defence Pre-research Foundation of China (9140A01060108DZ02)  
1. 电子科技大学光电信息学院 成都 610054 2. 吉首大学物理科学与信息工程学院 吉首 416000  
1. College of Opto-electronic Information, University of Electronic Science and Technology of China, Chengdu, 610054 2. College of Physics Science and Information Engineering, Jishou University, Jishou 416000  
DOI: 10.3724/SP.J.1004.2008.01169

神经元的阈值  $T_{ij}$  从初始值开始衰减, 当某一个神经元的阈值衰减到小于或等于相应的  $U_{ij}$  时, 该神经元点火 (称自然点火), 即输出一个脉冲,  $Y_{ij} = 1$ ; 同时, 该神经元的阈值  $T_{ij}$  急剧增大, 脉冲输出停止, 然后  $T_{ij}$  又开始衰减, 当阈值  $T_{ij}$  再次衰减到小于或等于  $U_{ij}$  时, 脉冲再次产生. 如此周期往复, 神经元就输出了一个脉冲序列信号. 在脉冲产生的过程中, 点火的神经元会通过相互连接作用 ( $L_{ij}$ ) 激励邻近的神经元点火 (称捕获点火), 而邻近的神经元点火后又会激励周围的神经元点火, 从而在激活区中产生一个脉冲波向外传播, 称此脉冲波为自动波. 在图像中, 灰度相似位置邻近的像素点趋向于同步点火, 利用该同步性质可实现图像分割.

## 2 PFPCNN 模型及图像分割方法

在进行图像分割之前, 为了能得到更好的分割效果, 先用改进的 PCNN 模型对图像进行增强 (预处理), 然后再采用 PFPCNN 新模型对增强后的图像进行分割, 最后用最大香农熵的方法判定最佳分割结果.

### 2.1 简化 PCNN 模型及图像增强

在图像预处理阶段, 采用改进的 PCNN 模型对原图像进行增强, 目的是为了改善图像对比度, 使图像的灰度分布更具有层次, 便于后续图像分割. 为此, 将原 PCNN 模型做如下改进和简化, 即

$$F_{ij}[n] = I_{ij} \quad (6)$$

$$L_{ij}[n] = \sum W_{ijkl} Y_{kl}[n-1] \quad (7)$$

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]) \quad (8)$$

$$Y_{ij}[n] = \begin{cases} F_{\text{high}}, & U_{ij}[n] > T_{ij}[n] \\ 0, & \text{其他} \end{cases} \quad (9)$$

$$T_{ij}[n] = T_{ij}[n-1] - \Delta + V_T \sum Y_{kl}[n-1] \quad (10)$$

式中,  $F_{\text{high}}$  为本次迭代过程中点火像素的最大灰度值,  $Y_{ij}$  为增强后的图像, 阈值采用线性衰减方式,  $\Delta$  为衰减步长. 参数设置的原则是:  $V_T$  应足够大, 以保证每个神经元只点火一次;  $\Delta$  应足够小, 以确保阈值衰减得足够慢, 以便把相邻的灰度级通过不同的点火时刻区分出来.  $\Delta$  值如果太大, 会丢失图像信息.

### 2.2 边界增强

用以上方法进行增强图像, 边界附近的像素没有得到很好的增强, 不利于后续的图像分割. 改进的 PCNN 图像增强方法在对图像进入 PCNN 迭代之前, 先对其边界进行增强, 使其在边界处的对比度更大, 使 PCNN 增强方法能得到更好的效果. 当某个神经元受到的激励较强 (较弱), 而邻近神经元受到的激励较弱 (较强), 则增加 (减小) 该神经元的灰度值, 使它的点火时刻提前 (推后), 从而使该点在增强图像中显得更亮 (更暗). 为此, 先将拉普拉斯算子与初始图像进行卷积以定位边界像素, 得到卷积后的图像  $F_L$ , 并采用如下规则更新灰度值

$$\begin{cases} F_{ij} = F_{\text{max}}, & F_{Lij} > \theta_L \\ F_{ij} = F_{\text{min}}, & F_{Lij} < -\theta_L \end{cases} \quad (11)$$

式中,  $F_{ij}$  是更新后的像素灰度值,  $F_{\text{max}}$ 、 $F_{\text{min}}$  分别为  $(i, j)$  邻域内的最大灰度值和最小灰度值,  $F_{Lij}$  为拉普拉斯卷积后的像素灰度值,  $\theta_L$  为判定其是否为边界像素的阈值. 对图像

中两个灰度级发生跳变的区域, 受到亮像素激励的神经元,  $F_{Lij}$  大于 0, 灰度值升高, 从而提前点火得到更亮的灰度值; 受到暗像素激励的神经元,  $F_{Lij}$  小于 0, 灰度值降低, 从而推后点火得到更暗的灰度值. 本文采用的 PCNN 图像增强方法具有如下特点:

1) 由于捕获的存在, 使得灰度值相差很小的像素在同一时刻点火, 于是这些像素在增强图像中表现出相同的灰度值, 从而增强了这些点的相似性. 配合使用边界增强方法, 使得图像的灰度值分布显得更有层次, 图像的边缘更加突显, 视觉效果得到了明显改善, 更利于下一步的图像分割.

2) 由于 PCNN 对图像的平滑作用, 使该方法能够消除图像中个别像素灰度值与周围像素灰度值的差异, 具有一定的去噪作用.

3) PCNN 模型符合实际的生物视觉神经系统, 且在此方法中引进了人眼视觉感知的基本特征, 故能获得更好的视觉效果.

图 2(a)~(c) 为改进的 PCNN 模型图像增强方法与常用的直接对比度增强 (Direct contrast enhancement, DCE) 方法的实验结果对比. 可以看出, 改进的 PCNN 模型图像增强方法的结果明显优于 DCE 方法, 它不仅较好地保留了图像细节, 也突显了图像的边缘, 明显改善了视觉效果, 更利于后续的分割.

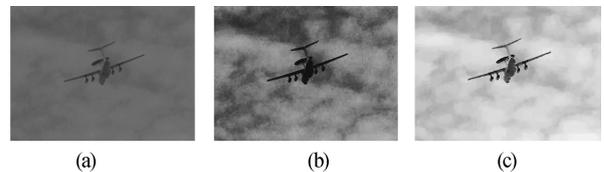


图 2 改进型 PCNN 图像增强效果对比 ((a) 原图; (b) DCE 结果; (c) 改进型 PCNN 增强结果)

Fig. 2 Comparison of image enhancement using improved PCNN ((a) Original image; (b) The enhanced image using DCE; (c) The result using improved PCNN)

### 2.3 PFPCNN 模型的原理、实现及特点

在传统的 PCNN 模型迭代过程中, 假设某神经元在某次迭代中自然点火, 则被该神经元捕获的神经元只能在下一次迭代时点火. 这样, 自然点火的神经元和被捕获的神经元不能同时点火. 这会导致在图像分割结果中出现不连续的区域或断点, 而这是我们所不希望的. 文献 [2] 中提到快速连接机制以解决此问题, 在同一次迭代中, 使自然点火的神经元引起的自动波充分传播后再进入下一次迭代, 即所有被捕获的神经元都在同一次迭代过程中点火. 在此过程中, 每个神经元的阈值不变 ( $T_{ij}$ ). 但是, 对于均匀缓慢变化的背景 (或目标), 如图 2(a) 为灰度从 43 ~ 151 缓慢变化的背景, 用上述方法, 设  $\Delta = 0.2$ ,  $T = 0.6$ ,  $\beta = 0.2$ , 第一次迭代时, 全部抑制. 第二次迭代时,  $T = 0.4$ , 灰度值处于 151 ~ 102 的像素自然点火, 然后自动波从它们向外传播, 在此过程中阈值 ( $T_{ij}$ ) 不变. 根据调制公式

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]) \quad (12)$$

则在此次迭代过程中被捕获的像素的最小灰度值满足

$$U_{ij}[n] = T_{ij}[n] \quad (13)$$

$$F_{ij\text{min}}[n] = \frac{T_{ij}[n]}{(1 + \beta L_{ij}[n])} \quad (14)$$

式中,  $T = 0.6$  (归一化),  $\beta = 0.2$ , 设此时为 ULPCNN, 则  $L$

的最大值取 1, 故  $F_{ij\min} = 0.33$ , 自动波的最大传播范围为灰度区间  $102 \sim 84$ . 综上, 灰度区间为  $151 \sim 84$  的像素在第二次迭代过程中点火, 同理, 灰度处于  $83 \sim 43$  的像素在第三次迭代时点火. 如图 3(a)~(c) 所示, 整个背景被分割成了两部分, 而实际上, 整个区域都是背景, 应在同一次迭代过程中点火.

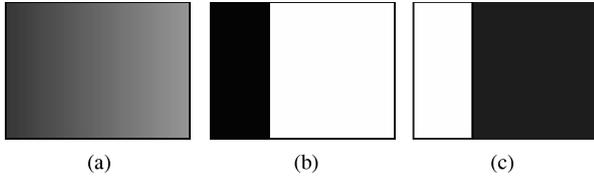


图 3 缓慢均匀变化背景图像 PCNN 分割结果 ((a) 背景原图; (b) PCNN 分割结果 ( $n = 2$ ); (c) PCNN 分割结果 ( $n = 3$ ))

Fig. 3 The segmented results under the continuously spatial-varying background using PCNN ((a) The background; (b) The segmented result using PCNN ( $n = 2$ ); (c) The segmented result using PCNN ( $n = 3$ ))

在实际的各种传感器成像过程中, 特别是针对光学成像系统, 经常由于光照条件 (如光照强度, 照射角度)、传播介质和目标表面的反射特性等因素的影响, 使成像背景的灰度呈均匀缓慢变化, 但分布范围又较广. 这样使得上述方法不能得到理想的效果, 同时也给后续图像分割带来了较大的困难.

针对此问题, 本文提出了 PFPCNN 模型, 目的是使自然点火的神经元与被其捕获的神经元在同一次迭代过程中点火, 使灰度均匀缓慢变化的背景 (或目标) 也在同次迭代时点火, 而无论其分布范围有多广, 故称其为并行点火 PCNN (PFPCNN) 模型. PFPCNN 模型分为两级: 主级和次级. 整体思路为: 反馈输入  $F_{ij}[n]$ 、连接输入  $L_{ij}[n]$  和内部活动项  $U_{ij}[n]$  仍采用简化模型公式 (式 (6)~(8)) 计算. 将 PCNN 的迭代过程分为两层循环 (外层和内层), 外层循环对应 PFPCNN 模型的主级, 内层循环对应次级, 主级和次级拥有各自独立的阈值矩阵  $T$  和  $T_n$ , 当模型开始迭代时, 令  $T_n = T$ , 进入外层循环 (主级), 主级采用无链接模式, 且只迭代一次, 在此过程中, 灰度值大于阈值的像素自然点火, 然后以自然点火的神经元为种子向外传播自动波, 进入内层循环 (次级), 在次级中, 未点火的神经元接收邻阈内的链接输入, 灰度值与相邻点火神经元相似的神经元被捕获, 每迭代一次, 次级阈值  $T_n$  调整一次 (非线性衰减), 自动波向外传播一个神经元, 如此迭代直到没有新的神经元被捕获, 即让自动波充分传播. 然后, 跳出次级 (内层循环) 进入主级 (外层循环), 未点火的神经元恢复次级调整前的阈值, 令  $T = T_n$ , 主级阈值  $T$  衰减一次,  $T_n = T$ , 此时, 结束主级循环, 完成分级 PCNN 模型的一次迭代, 进入第二次主级循环,  $n = n + 1$ . 这样就能保证均匀缓慢变化的背景神经元在次级迭代中全部点火. 具体实现步骤见图 4 所示的算法流程.

综上, PFPCNN 模型的特点是: 主级 (分割阶段) 采用无链接模式, 只能自然点火, 只迭代一次, 阈值衰减快于次级. 次级 (预处理阶段) 采用链接模式, 只能捕获点火, 迭代多次直到没有新的神经元被捕获, 阈值衰减慢, 以防止过分割.

#### 2.4 阈值衰减方式

主级: 传统的 PCNN 模型的阈值采用指数衰减方式, 虽然符合实际生物的非线性视觉特征, 但是用于图像分割, 结

果却不太理想, 因为它开始衰减快, 后来衰减慢, 这样对一些灰度值范围内的目标有失“公平”. 为了得到更好的图像分割效果, 本文主级采用线性衰减方式 (式 (10)), 使其更适合于图像分割.

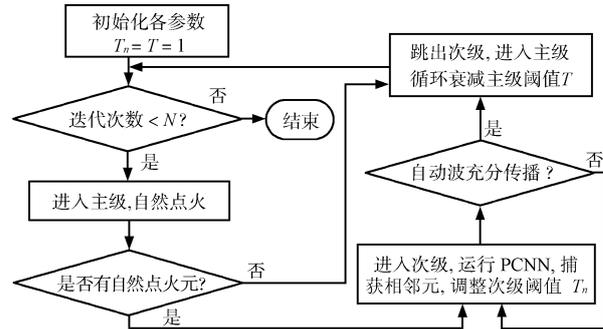


图 4 并行点火 PCNN 模型的算法流程

Fig. 4 The flow chart of the parallelized firing PCNN model

次级: 由于背景均匀缓慢变化, 故次级阈值衰减应较小, 以防止捕获属于目标的像素. 因为, 次级每迭代一次, 自动波只能传播一个单元, 则其迭代次数可能很大, 如果按常规的阈值衰减方式 (线性衰减和指数衰减), 可能使其变得很小而造成过分割. 新方法采用以下规则调整次级阈值

$$\begin{cases} T_{n_{ij}}[n] = Fm_{ij}[n-1], & \text{若 } Fm_{ij} < T \\ T_{n_{ij}}[n] = T_{n_{ij}}[n-1], & \text{否则} \end{cases} \quad (15)$$

$$Fm_{ij}[n] = \frac{1}{m} \sum_{p,q \in \text{fire}} F_{pq}[n] \quad (16)$$

式中,  $i, j, p, q$  为像素 (神经元) 坐标,  $\text{fire}$  为在像素  $(i, j)$  的邻域内已经点火的神经元的坐标集合,  $m$  表示邻域内已经点火的神经元的数量,  $T$  为主级 PCNN 阈值,  $Fm_{ij}[n]$  表示第  $n$  次迭代邻域内已点火像素的灰度平均值.

根据上述规则, 如果邻域内已点火的像素灰度的平均值小于主级阈值, 则衰减次级阈值使其等于该平均值, 反之, 则保持不变. 可以看出, 此衰减方式带有一定的随机性, 但主要还是按灰度值的分布规律衰减, 属非线性衰减方式. 采用此方法, 既能使灰度均匀缓慢变化的区域同时点火, 保持了区域的完整性, 又不会造成过分割. 采用非线性衰减方式, 能保持改进模型的非线性特征, 使其既与实际生物的非线性视觉特征一致, 又不会影响图像分割效果.

#### 2.5 最佳分割结果判定

PCNN 迭代结果为二值图像序列, 即一系列的图像分割结果, 需从此序列中选取最佳分割结果, 不同文献提出了一些判定准则, 如最大香农熵准则、最大交叉熵准则, 最小交叉熵准则、最大类间差准则、最大边缘数准则等. 本文采用常用的最大香农熵方法<sup>[14]</sup> 确定最佳分割结果.

$$H(P) = -P_1 \ln P_1 - P_0 \ln P_0 \quad (17)$$

其中,  $P_0$  和  $P_1$  分别表示分割图像二值输出  $Y[n]$  为 0 和 1 的概率. 对大多数图像而言, 香农熵代表了图像的信息量, 如果分割后的图像的香农熵越大, 分割图像从原始图像中得到的信息量越大, 其分割图像的细节越丰富, 且总体分割效果越好. 故利用该准则判优, 对 PCNN 迭代结果计算  $H$ , 当  $H$  取最大时 ( $H_{\max}(p)$ ) 的迭代结果为总体最佳分割结果.

### 3 仿真实验与结果分析

选用尺寸为  $256 \times 256$  的几幅不同应用中的图像 (Bacteria, ore, sea-fish, elephants, dragonfly and airplane), 如图 5 (a)~(f) 所示, 分别代表在医学、采矿、海洋生物等不同领域中用于分割的原图. 所选图像存在对比度低、目标区域灰度分布不均匀、背景连续空变等较高复杂度. 用 Visual C++ .NET 开发工具进行仿真, 分别用 PFPCNN 和常用的改进 PCNN (ULPCNN) 图像分割方法进行实验, 并对实验结果进行了对比评价. 实验参数:  $N = 10, \Delta = 0.15, \beta = 0.25, V_T = 1, \theta_L = 0.1$ , 矩阵  $W_{ijkl}$  中的元素为离中心的欧几里德

距离平方的倒数, 实验结果及其效果对比如图 6 和图 7 所示.

从图中可以看出, 基于 PFPCNN 模型的分割结果中, 目标轮廓清楚、完整, 保持细节的同时, 也能很好地去除背景杂波. 即使在对比度低、背景呈大范围内连续变化等更为复杂背景的情况下, 也能准确分割出完整目标. 而传统的 PCNN 方法结果中目标不完整, 受复杂或大灰度范围的背景干扰大. 可见, PFPCNN 分割结果在视觉效果上明显优于传统的 PCNN 分割方法.

为了定量评价图像分割的效果, 本文采用几个常用的图像分割评价标准<sup>[14-15]</sup> 分别对两种方法的分割结果进行评价, 并作出对比, 结果如表 1 所示.

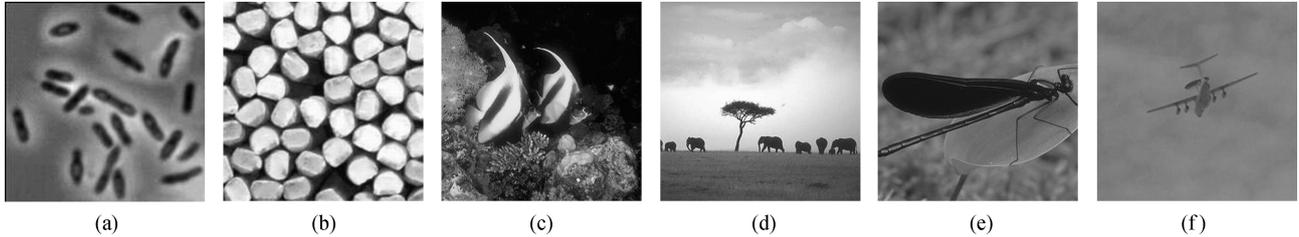


图 5 各种复杂场景图像  
Fig. 5 Various original images under complex background

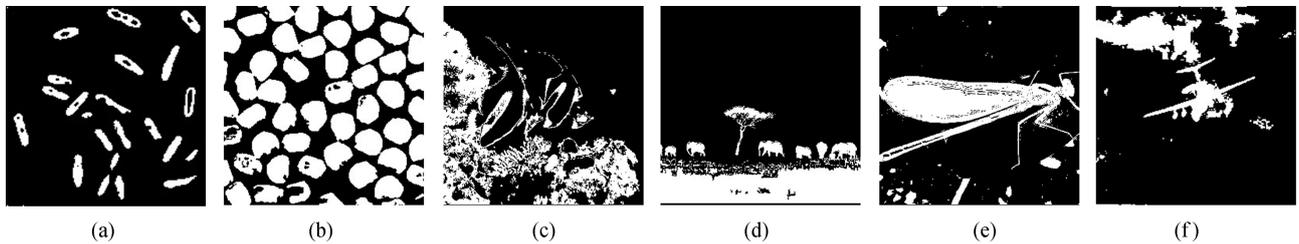


图 6 ULPCNN 模型的最佳分割结果  
Fig. 6 The optimal segmented results using ULPCNN

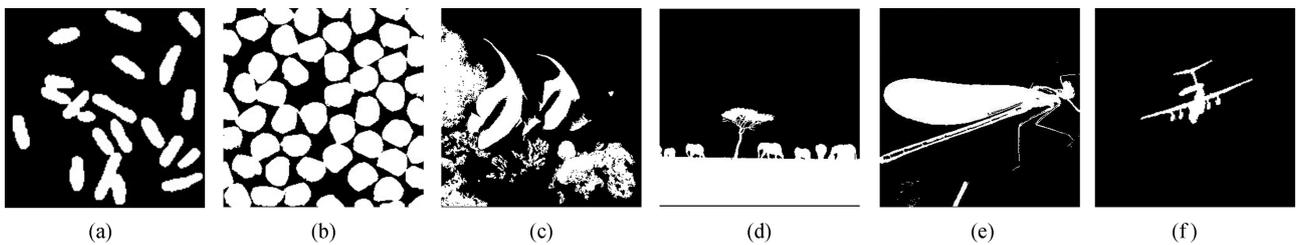


图 7 PFPCNN 模型的最佳分割结果  
Fig. 7 The optimal segmented results using PFPCNN

表 1 PFPCNN 的性能评价  
Table 1 The performance evaluation of PFPCNN

图像名称	ULPCNN 模型			PFPCNN 模型		
	$H_{max}$	$U_r$	$C_r$	$H_{max}$	$U_r$	$C_r$
Bacteria	0.928	0.946	0.768	0.953	0.995	0.824
Ore	0.957	0.979	0.761	0.981	0.991	0.856
Sea-fish	0.975	0.982	0.623	1.998	0.997	0.754
Elephants	0.952	0.978	0.766	0.983	0.989	0.798
Dragonfly	0.964	0.980	0.613	0.998	0.996	0.802
Airplane	0.892	0.961	0.562	0.915	0.987	0.623

表 1 中各参数的意义如下:

- 1) 最大香农熵  $H_{\max}$  (见式 (17)).
- 2) 区域一致性参数  $U_r$ , 即

$$U_r = 1 - \frac{\sigma_1^2 + \sigma_2^2}{A} \quad (18)$$

式中,  $A$  为归一化因子, 这里指整幅图像的像素数.  $\sigma_i^2 = \sum_{(x,y) \in R_i} [f(x,y) - \mu_i]^2$ ,  $\mu_i = \sum_{(x,y) \in R_i} f(x,y) / B_i$ ,  $f(x,y)$  为像素  $(x,y)$  的灰度值,  $B_i$  为对应分割区域  $R_i$  内的像素数.

- 3) 区域对比度  $C_r$ , 即

$$C_r = \frac{|f_o - f_b|}{|f_o + f_b|} \quad (19)$$

式中,  $f_o$ ,  $f_b$  分别为目标区和背景区的平均灰度级.

从表 1 可以看出, 本文方法的分割结果在各个标准上都优于传统的 PCNN 图像分割方法, 表明 PFPCNN 图像分割方法是有效和可行的.

## 4 结束语

本文提出了利用 PFPCNN 模型进行图像分割的方法. 首先用改进的 PCNN 模型对图像进行增强, 然后采用 PFPCNN 新模型对增强后的图像进行分割, 最后用最大香农熵的方法判定最佳分割结果. 通过实验仿真, 证明了 PFPCNN 图像分割方法的有效性. 由于 PCNN 的脉冲激发(点火)与否, 对应分割图像的 0 和 1 输出, 因此很容易建立二值图像分割模型. 对于利用 PCNN 模型进行图像多值分割问题, 虽然还没有文献进行专门的论述, 但只要从多个区域的二值分割进行描述, 多值分割问题也是可以实现的. 对此问题的深入研究, 应该是 PCNN 图像分割方法的重要发展方向.

## References

- 1 Eckhorn R, Reitboeck H J, Arndt M, Dicke P. Feature linking via synchronization among distributed assemblies: simulation of results from cat cortex. *Neural Computation*, 1990, **2**(3): 293–307
- 2 Johnson L J, Padgett M L. PCNN models and applications. *IEEE Transactions on Neural Networks*, 1999, **10**(3): 480–498
- 3 Caulfield H J, Kinser J M. Finding the shortest path in the shortest time using PCNN's. *IEEE Transactions on Neural Networks*, 1999, **10**(3): 604–606
- 4 Fang Yong, Qi Fei-Hu, Pei Bing-Zhen. PCNN implementation and applications in image processing. *Journal of Infrared and Millimeter Waves*, 2005, **24**(4): 291–295  
(方勇, 戚飞虎, 裴炳镇. 一种新的 PCNN 实现方法及其在图像处理中的应用. 红外与毫米波学报, 2005, **24**(4): 291–295)
- 5 Gu X D, Yu D H, Zhang L M. Image shadow removal using pulse coupled neural network. *IEEE Transactions on Neural Networks*, 2005, **16**(3): 692–698
- 6 Kuntimad G, Ranganath H S. Perfect image segmentation using pulse coupled neural networks. *IEEE Transactions on Neural Networks*, 1999, **10**(3): 591–598
- 7 Zhao Zhi-Jiang, Zhang Tian-Wen, Zhang Zhi-Hong. A study of a new image segmentation algorithm based on PCNN.

*Acta Electronica Sinica*, 2005, **33**(7): 1342–1344

(赵峙江, 张田文, 张志宏. 一种新的基于 PCNN 的图像自动分割算法研究. 电子学报, 2005, **33**(7): 1342–1344)

- 8 Zhang J Y, Fan X J, Dong J Y, Shi M H. Image segmentation based on modified pulse-coupled neural networks. *Chinese Journal of Electronics*, 2007, **16**(1): 119–122
  - 9 Li M, Cai W, Tan Z. A region-based multi-sensor image fusion scheme using pulse-coupled neural network. *Pattern Recognition Letters*, 2006, **27**(16): 1948–1956
  - 10 Huang W, Jing Z L. Multi-focus image fusion using pulse coupled neural network. *Pattern Recognition Letters*, 2007, **28**(9): 1123–1132
  - 11 Ma Yi-De, Qi Chun-Liang, Qian Zhi-Bai, Shi Fei, Zhang Zai-Feng. A novel image compression coding algorithm based on pulse-coupled neural network and Gram-Schmidt orthogonal base. *Acta Electronica Sinica*, 2006, **34**(7): 1255–1259  
(马义德, 齐春亮, 钱志柏, 史飞, 张在峰. 基于脉冲耦合神经网络和施密特正交基的一种新型图像压缩编码算法. 电子学报, 2006, **34**(7): 1255–1259)
  - 12 Ranganath H S, Kuntimad G. Object detection using pulse coupled neural networks. *IEEE Transactions on Neural Networks*, 1999, **10**(3): 615–620
  - 13 Gu X D, Yu D H, Zhang L M. Image thinning using pulse coupled neural network. *Pattern Recognition Letters*, 2004, **25**(9): 1075–1084
  - 14 Ma Yi-De, Qi Chun-Liang. Study of automated PCNN system based on genetic algorithm. *Journal of System Simulation*, 2006, **18**(3): 722–725  
(马义德, 齐春亮. 基于遗传算法的脉冲耦合神经网络自动系统的研究. 系统仿真学报, 2006, **18**(3): 722–725)
  - 15 Cardoso J S, Luls C R. Toward a generic evaluation of image segmentation. *IEEE Transactions on Image Processing*, 2005, **14**(11): 1773–1782
- 彭真明** 博士, 电子科技大学光电信息学院副教授. 主要研究方向为图像处理、数据挖掘、目标识别与跟踪. 本文通信作者.  
E-mail: zmpeng@uestc.edu.cn  
(**PENG Zhen-Ming** Ph. D., associate professor at University of Electronic Science and Technology of China. His research interest covers image processing, data mining, target recognition, and tracking. Corresponding author of this paper.)
- 蒋彪** 电子科技大学光电信息学院硕士研究生. 主要研究方向为图像处理, 神经网络. E-mail: humjb.1983@163.com  
(**JIANG Biao** Master student at the College of Optoelectronic Information, University of Electronic Science and Technology of China. His research interest covers image processing and neural networks.)
- 肖峻** 博士, 电子科技大学光电信息学院教授. 主要研究方向为非线性光学、集成光学. E-mail: junxiao@uestc.edu.cn  
(**XIAO Jun** Ph. D., professor at University of Electronic Science and Technology of China. His research interest covers non-linear optics and integrated optics.)
- 孟凡斌** 吉首大学物理科学与信息工程学院副教授. 主要研究方向为计算机网络. E-mail: mfb00368@yahoo.com.cn  
(**MENG Fan-Bin** Associate professor at the College of Physics Science and Information Engineering, Jishou University. His main research interest is computer network.)