

一种新的 PCNN 模型参数估算方法

赵峙江¹, 赵春晖¹, 张志宏²

(1. 哈尔滨工程大学信息与通信工程学院, 黑龙江哈尔滨 150001;
2. 哈尔滨工程大学计算机科学与技术学院, 黑龙江哈尔滨 150001)

摘 要: PCNN 在图像处理领域得到广泛的应用, 对其展开研究具有重要的理论意义及应用价值. 在对 PCNN 的研究应用中, 其模型参数的合理确定是一个难点. 本文提出用灰度-信息量直方图来表征图像特征, 通过对信息量直方图的分析, 提出了估算 PCNN 时间衰减参数的自适应算法. 该算法可以仅在 PCNN 的一个运行周期中以最少的迭代次数有效地完成图像分割, 并且解决了对多目标进行分割时容易丢失目标的问题.

关键词: 图像分割; PCNN; 灰度; 信息量; 直方图

中图分类号: TN911.73 **文献标识码:** A **文章编号:** 0372-2112 (2007) 05-0996-05

A New Method of PCNN's Parameter's Optimization

ZHAO Zhi-jiang¹, ZHAO Chun-hui¹, ZHANG Zhi-hong²

(1. Department of Information & Communication, Harbin Engineering University, Harbin 150001, China;
2. Department of Computer Science & Technology, Harbin Engineering University, Harbin, 150001, China)

Abstract: Recent research in neuroscience has proposed a new artificial neural networks model, the pulse coupled neural networks, PCNN. Several PCNN structures for image processing have been proposed depending on the model's potential. In the research of the theories and the applications of PCNN, it isn't a trivial task to define the relative parameters properly, and people usually get the values by experience with many experiments. As a contribution to this research field, this paper presents a new method for image processing based on the image histogram of gray-level and amount of information. The histogram is used as a new tool to describe the image features and furthermore to define the decay time constant of PCNN. With this new algorithm, we can get perfect segmentation result with the fewest iteration times only in one computation period of PCNN, and also can resolve the problem in image segmentation that it is liable to loss some object while many objects exist. Experiments show that the new algorithm has good performance in image processing.

Key words: image segmentation; PCNN; gray-level; amount of information; histogram

1 引言

近年来, 被国际上称为第三代人工神经网络的脉冲耦合神经网络(PCNN)以其更接近生物机制的优越性, 被广泛地应用在图像处理、决策优化和通信等方面^[1]. PCNN 数学模型中各种门限系数、时间衰减常数、连接系数等参数, 控制着网络运行效率, 对它们的恰当设置是一个不容忽视的环节. 然而目前, 还鲜有文献对此进行讨论. PCNN 模型的参数选择基本还是靠经验设定^[2~6], 需要针对每一幅图像反复实验才能获得合适的数值, 由此导致人工交互的工作量很大, 无法实现自动化, 并且对处理结果的判定也会因人的主观评价不同而产生较大的差异. 因此如何合理计算参数是 PCNN 理论研究亟

待解决的一个难题.

采用 PCNN 进行图像分割的结果主要取决于图像特征, 因此可以将图像的自然属性作为确定其参数的重要依据. 文献[7]利用图像熵的方法就 PCNN 中循环迭代次数的确定准则问题进行了探讨. 本文利用一种全新的描述图像特征的工具—灰度-信息量直方图, 成功的估算出 PCNN 模型的时间衰减参数, 使计算迭代次数减至最少. 在此基础上, 还进一步阐述了 PCNN 时间衰减参数确定的自适应算法, 从而使 PCNN 应用于多目标分割时取得良好的效果.

本文首先简单介绍了 PCNN 模型, 接着在第 3 节给出了灰度-信息量直方图描述, 客观表达了图像的自然特征, 并且分别就单阈值图像分割和多阈值图像分割阐

述了确定 PCNN 模型时间衰减参数的自适应算法. 在第 4 节里结合仿真实验进行了分析. 最后是该文工作的简要总结.

2 PCNN 模型

Eckhorn 为解释在猫的大脑视觉皮层实验中所观察到的神经元同步行为现象^[8], 提出了展示同步脉冲发放现象的连接模型. 在对猴的大脑皮层所进行的实验中, 也得到了相似的实验结果^[8-11]. Johnson 等人对此连接模型进行变形得到了 PCNN 模型^[12-15]. PCNN 是由若干神经元组成的单层二维局部连接的反馈型网络. 图 1 为单个 PCNN 神经元的模型, 式(1)至式(5)为 PCNN 模型的数学方程描述. 每个神经元由三部分组成: 接收部分、调制部分和脉冲产生部分, 见图 1.

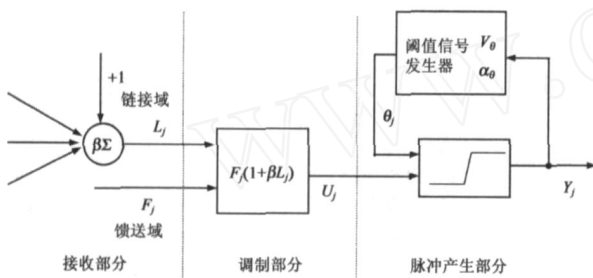


图 1 PCNN 神经元模型

$$F_j(t) = e^{-t} F_j(t-1) + V_F \quad MY(t-1) \quad (1)$$

$$L_j(t) = e^{-t} L_j(t-1) + V_L \quad WY(t-1) \quad (2)$$

$$U_j(t) = F_j(t) [1 + L_j(t)] \quad (3)$$

$$j_j(t) = e^{-t} j_j(t-1) + V_j Y_j(t) \quad (4)$$

$$Y_j(t) = \text{Step}(U_j(t) - j_j(t)) = \begin{cases} 1 & U_j(t) > j_j(t) \\ 0 & \text{否则} \end{cases} \quad (5)$$

神经元 j 的接收部分接收来自其它神经元与外部的输入, 将接收到的输入信号通过两条通道传输. 一通道称为 F 通道, 发送馈送输入; 另一通道称为 L 通道, 发送链接输入. 调制部分将来自 L 通道的信号 L_j 加上一个正的偏移量后与来自 F 通道的信号 F_j 进行相乘调制(模型中偏移量归整为 1, β 为链结强度系数), 得到内部状态信号 U_j , 接着, U_j 输入到脉冲产生部分.

脉冲产生部分由阈值信号发生器与脉冲产生器组成. 阈值信号发生器中的 V_j 与 α_0 分别表示阈值幅度系数与时间衰减参数, V_j 决定迭代计算中只发放一次的条件, α_0 决定一个周期中的迭代次数, 见式(4). 当脉冲产生器打开时, 其发放脉冲的频率是衡定的. 阈值 j_j 随着输出而改变. 当神经元输出一个脉冲, 神经元的阈值 j_j 就通过反馈而迅速得到提高, (见式(4)). 当阈值 j_j 超过 U_j 时, 脉冲产生器就被关掉, 停止发放脉冲, 紧接着, 阈值就开始下降; 当阈值 j_j 低于 U_j 时, 脉冲产生器

被打开, 神经元点火, 即处于激活状态, 输出一个脉冲或脉冲序列.

用 PCNN 进行图像分割时, 二维图像的每一个像素的灰度值对应为每个神经元的输入. 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, 则其中某一个像素激发产生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, 产生脉动序列输出 $Y[t]$. 显然序列 $Y[t]$ 包含有图像区域信息、边缘、纹理特征等信息. 这样, 相似的多个神经元就构成了一个神经元集群, 该神经元集群象一个巨大的神经元, 同步地发放出脉冲. 一个神经元集群对应着图像中相同的区域, 不同的神经元集群分别对应着图像中不同的区域. 故利用由 PCNN 的脉冲传播特性所引发的同步脉冲发放, 可以实现图像的分割.

基于 PCNN 的图像分割效果取决于 PCNN 中各参数的选择. 对不同类型的图像进行图像分割时, 要选取不同的参数, 然而 PCNN 参数的确定是困难的, 基本都是靠经验设定. 由于时间衰减参数 直接关系到运算效率, 所以如何迅速确定 是应用 PCNN 高效处理图像的难点之一.

3 时间衰减参数的估算

3.1 灰度-信息量直方图原理

3.1.1 图像的单元熵矢量

数字图像由一些像素点组成, 不同亮度的像素点在空间占据不同的区域, 使得图像表现出不同的内容. 不同内容的图像所包含的信息量是不同的. 一幅全黑或全白的图像, 可以看成是必然事件, 所包含的信息量为零, 具有确定性. 当图像各层亮度的像素出现的概率相等时, 图像形状的不确定性最大, 此时图像所包含的信息量最大, 具有极限性. 众所周知, 熵是图像统计特性的一种表现形式, 反映了图像包含信息量的大小, 所以本文采用信息熵来描述图像的信息量.

设 $f(x, y); x=1, 2, \dots, M; y=1, 2, \dots, N$ 是一个二维的图像像素矩阵, $f(x, y)$ 表示 (x, y) 处像素的灰度. 图像的像素灰度经量化后有一取值集合, 这个集合的熵定义为自信息的统计平均值, 即图像的信息熵. 根据 Shannon 熵的概念, 若每个像素的灰度量化为 K 层, 图像的各个像素是独立的, 且灰度为 L 的像素出现的概率为 p_L 时, 则每个像素的熵是 $H(p_0, p_1, \dots, p_K) = -\sum_{L=0}^K p_L \log p_L$. 当像素各层灰度的出现概率相等时, 图像的熵最大, 即 $H_{\max} = \log K$.

根据 Shannon 熵对称性质, 二值图像的熵 $H(p_0, p_1)$ 与图像中的目标图像像素点和背景图像像素点的数目有关, 而与像素点的位置无关. 为了反映图像灰度与其

邻域包含的信息量的关系,本文采用单元熵的概念,使得图像能用一个熵矢量来描述,从而灰度与信息量的关系可以用灰度-单元熵直方图来描述.所谓单元熵是指将大小为 $M \times N$ 的图像,划分为以每个像素,或其中的一些像素为中心的 $P \times Q$ 个子图像,每个子图像称为一个单元,每个单元实际上是原图像在空间的一个特定区域.

第 i, j 个单元记为:

$$\{ F(x_i, y_j); i=1, 2, \dots, P; j=1, 2, \dots, Q; \}$$

$$x_i = (i-1) \times [M/P] + 1, \dots, [M/P] \times i;$$

$$y_j = (j-1) \times [N/Q] + 1, \dots, [N/Q] \times j \quad (6)$$

其中 ' $[]$ ' 表示取整.该单元的面积

$$AREA_{i,j} = [M/P] \times [N/Q] \quad (7)$$

则该单元的熵 $H_{i,j}(p_0, p_1)$ 定义为:

$$H_{i,j}(p_0, p_1) = - \sum_{i=0}^{L-1} p_i(p_0, p_1) \ln p_i(p_0, p_1) \quad (8)$$

对每一单元都计算其单元熵后,图像可用一个 $P \times Q$ 维的单元熵矢量 H 表示:

$$H = \{ H_{11}, H_{12}, \dots, H_{1Q}, H_{21}, H_{22}, \dots, H_{2Q}, \dots, H_{P1}, H_{P2}, \dots, H_{PQ} \} \quad (9)$$

3.1.2 灰度-信息量直方图计算

直方图是进行图像分析的一种常用手段.灰度直方图是一个离散函数,它表示数字图像每一灰度级与该灰度级出现频率的对应关系,可以认为是图像灰度密度函数的近似,它反映了图像的灰度分布关系.这个分布具有位置不变性,旋转不变性的特点.利用传统的直方图峰谷特点,可以对图像进行阈值分割.但是该分割与图像的信息量没有必然的联系,无法使分割结果最大限度地保留图像的信息量.为了能够使信息量与图像的灰度分布发生联系,经过深入研究,我们借助直方图的思想,将图像分割为一系列子图像,每个子图像相当于灰度直方图所代表的图像中的一个像素,计算每个子图像包含的信息量,该信息量相当于原像素的灰度值,然后取图像中心点像素灰度值作为索引,建立灰度-信息量直方图.该直方图本质上是一种高阶直方图,反映的是灰度对应的局部信息量分布.

按照随机过程理论,图像可以看作是一个随机场,具有相应的统计特征,其中最重要的特征是熵.计算像素邻域的单元熵,以像素的灰度为索引统计其单元熵的和,即构成灰度-熵直方图.灰度-熵直方图代表的是图像中某一灰度值所相关的熵的大小,反映了灰度与信息量的分布关系,它具有二维直方图的本质,但形式上仍然是一维的,所以具有很高的搜索效率.

通常灰度-熵函数与像素所在的位置有关,设图像 I 在点 (x, y) 处的灰度-熵分布密度函数为 $h(I; x, y)$, 那么图像的灰度-熵密度函数为:

$$h(I) = \frac{1}{A} \int_D h(I; x, y) dx dy \quad (10)$$

其中 D 是图像的定义域, A 是区域 D 的面积.

一般地讲,要精确地得到图像的灰度-熵密度函数是比较困难的,所以我们用数字图像的灰度-单元熵直方图来代替,为了进一步加快计算速度,也可用灰度-单元梯度直方图来近似,它表明了数字图像每一灰度级与该灰度级所有像素相关的邻域熵或梯度和的对应关系.

假设一幅数字图像的像素总数为 N , 有 L 个灰度级,具有第 k 个灰度级的灰度 g_k 的像素有 n_k 个,这些像素所对应的单元熵为 H_{g_k} , 则第 k 个灰度级即 g_k 所代表的信息量为:

$$h_k = \sum_{n=1}^{n_k} H_{g_k}(k), \quad k=0, 1, \dots, L-1 \quad (11)$$

这个关系也可以用图形表示(见图2),该图由灰度轴及一系列垂直于灰度轴的线段组成,垂足 $f = g_k$, 各线段的长度与 h_k 成正比,此即为灰度-信息量直方图.该直方图表明了图像中每一灰度值与其相关的信息量的分布,表示每个灰度级在图像中所代表的信息量的大小,阈值分割总信息量为灰度-信息量直方图下的面积.由于后续计算利用的是相对值,所以可以采用计算邻域的梯度和或方差等方法来代替单元熵的计算,这样可以提高运算速度.本文单元熵的估算均采用计算邻域的梯度和得到.

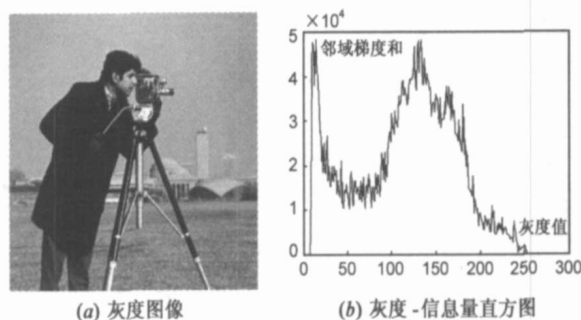


图2 灰度-信息量直方图示例

3.2 单阈值图像分割的参数估计

假设原某图像的信息总量为 H_{\max} , $H(O)$ 为分割目标的信息量, $H(B)$ 为分割背景的信息量, t 为搜索阈值,则:

$$H(O) = \sum_{i=0}^t h(i) \quad H(B) = \sum_{i=t}^{255} h(i) \quad (12)$$

当 $t=0$ 时,分割结果为全白, $H(O)=0$, $H(B)=H_{\max}$; 当 $t=255$ 时,分割结果为全黑 $H(B)=0$, $H(O)=H_{\max}$; 当 t 由 0 至 255 进行搜索时,分割结果的二值图像熵不断增加, $H(O)$ 不断增加, $H(B)$ 不断减少,其中 $H(O)$ 的增加量等于 $H(B)$ 的减少量.由熵的性质可知,

当像素各层灰度的出现概率相等时,图像的熵最大. 所以当 $H(O) = H(B)$ 时,分割熵为最大值. 继续搜索,分割熵单调递减至 0. 将搜索过程绘制成信息量面积曲线,如图 3 所示,其中实线为 $H(O)$,虚线为 $H(B)$,二者的交点上, $H(O) = H(B)$,所以交点的垂足 T 即为所求的分割阈值. 所以,如果要使分割结果的信息量最大化,可以在灰度-信息量直方图中搜索一个灰度值,使其左右两部分的直方图面积相等,这个灰度即为基于信息量的最佳灰度分割阈值.




图 3 灰度-信息量直方图的搜索过程示意图

单阈值分割阈
值估计算法过程如下:

- (1) 计算灰度-信息量直方图;
- (2) 搜索直方图,累计目标区域包含的直方图面积

$A_{\text{目标}}$;

- (3) 当 $A_{\text{目标}} = \frac{1}{2} A_{\text{总}}$ 时,即获得最佳分割阈值.

获得了最佳分割阈值后,采用如下方法确定 PCNN 的参数. 假设图像中灰度最大值为 g_{max} ,由灰度信息量直方图搜索的估计值为 $g_{\text{估计}}$,则 PCNN 参数可由下式获得:

$$= \ln g_{\text{max}} - \ln g_{\text{估计}} \quad (13)$$

3.3 多阈值图像分割的参数估计

对于图像中存在多个不同灰度的目标,需要采用多阈值进行分割的情况,的确定更为复杂一些. 首先计算灰度-信息量直方图,由于存在多个目标,所以直方图一定呈多峰形状,目标一定对应于其中的一些峰值. 如果依据经验来确定,那么在迭代的过程中,过小会造成迭代次数过多,而过大又会导致某些目标丢失. 为了解决这个问题,本文采用信息量直方图估算的办法预先计算出合理的值,然后再启动网络,从而避免了分割结果的随意性.

如果目标数量较少,峰值间隔点可以用一定的间隔宽度确定,假设 g 间隔代表灰度梯度间隔,那么,可以用式(14)来确定:

$$= \ln g_{\text{间隔}} \quad (14)$$

如果目标较多,或目标间灰度接近,则 $g_{\text{间隔}}$ 会很小,这样,很容易造成迭代次数过多,浪费很多计算时间. 本文提出一种自适应确定衰减参数的方法,使用信息量直方图估算出迭代落点,在迭代的过程中,自动调整,使 PCNN 网络迭代落点受到控制,以落到各个目标

灰度分割点的中间,这样,不仅可以保证分割出全部目标,而且迭代次数可以最少.

假设 i 为迭代次数, $g_{\text{估计}}[i]$ 为阈值估计值序列,则 $[i]$ 序列通过式(15)求得:

$$[i] = \ln g_{\text{估计}}[i] - \ln g_{\text{估计}}[i-1] \quad (15)$$

对于图像的多阈值分割,本文对具体估算方法如下:

- (1) 计算灰度-信息量直方图;
- (2) 计算直方图每个尖峰的顶点;
- (3) 取顶点之间的中点作为灰度估计点;
- (4) 计算由估计点得到的自适应参数序列.

3.4 计算量分析

采用本文方法对分割阈值进行估算,运算量较常用的一维信息熵阈值搜索算法大大减少. 假如对一幅数字灰度图像进行处理,不失一般性,图像的尺寸为 $M \times N$,灰度范围为 $0 \sim 255$,则采用一维信息熵阈值搜索算法需要进行 $[M \times N \times 255 \text{ 次加法运算} + 255 \times 2 \text{ 次除法运算} + 255 \text{ 次乘法运算} + 255 \text{ 次对数运算}]$. 而采用本文的算法,则对于一般的情况,取像素的 4 邻域,则共需的计算次数为 $[M \times N \times 4 \text{ 次加法} + M \times N \text{ 次加法} + 255 \text{ 次加法} + \text{最大} 255 \text{ 次搜索加法}]$. 由此可以看出,本文方法的运算量仅相当于一维信息熵法的 3% 左右.

4 实验

根据以上模型和算法,我们选取 Lena 图像和不同灰度多目标图像进行了实验. PCNN 模型的参数 $F = 693$, $V_L = 0.693$, $V_F = 0.01$, $V_L = 1$, $V = 0.2$, $\theta = 0.2$. 图像分块采用 8×8 方案,网络输出的单阈值分割结果和多阈值分割结果如图 4、图 5 所示.



图 4 PCNN 的单阈值分割结果




图 5 PCNN 对不同灰度目标多阈值分割结果

(1) 图 4 是对 PCNN 单阈值分割进行参数优化的结果. 图 4(b) 为没有进行优化的 PCNN 迭代 14 次之后的最佳分割结果. 图 4(c) 为参数优化后迭代一次的分割

结果. 我们可以看出在得到几乎完全相同的分割结果的情况下, 本文算法需要的迭代次数比传统的方法少的多.

(2) 图 5 是应用本文算法经过三次迭代得到的多门限分割结果, 如图 5 (b)、(c)、(d) 所示, 图中所有区域都被按顺序分割出来. 通常采用 PCNN 对图像进行分割, 是根据经验和需要对信息量等级进行调整. 一般地, 越小, 神经元发放的脉冲等级越多, 分割的图像信息量的级别也越多, 分割结果也较为精细, 层次性较好, 但迭代次数越多, 速度越慢; 越大, 分割的图像信息量的级别也越少, 分割速度快, 但结果就较为粗糙, 容易丢失目标. 本文的算法可以对 进行估算, 从而可以实现既不丢失目标, 又降低了计算量.

(3) PCNN 模型是仿生学研究的结果, 符合生物视觉习惯和原理, 在用于图像处理时, 每个神经元相当于一个视觉细胞, 由此带来了图像分割效果的改善. 但这是以牺牲速度为代价的, 生物视觉过程为并行过程, 而计算机处理过程为串行过程, 因此速度上计算机无法与生物神经网络相比. 另外实验表明, 本文方法的处理速度与图像内容的复杂程度相关, 复杂图像层次较多估值小, 迭代周期长, 所以耗时较多. 本文所有实验在 Pentium IV 1.7GHz CPU, 内存 256M 的计算机上完成, 处理 256 × 256 的灰度图像, 处理时间为 1 秒左右.

5 结论

PCNN 参数的选择和图像统计特性决定着分割图像的性能. 为此, 本文深入研究了 PCNN 的参数选择问题, 结合图像统计特性提出了一种新的描述图像特征的工具—灰度-信息量直方图, 并且以它为基础提出了 PCNN 模型参数估算方法. 该算法通过对图像的灰度-信息量直方图分析, 计算出网络的时间衰减参数, 可以实现在一个周期内, 以最少的迭代次数获取最佳分割, 有效的控制了系统运算量. 由实验可见, 该算法简单、通用, 可以实现基于 PCNN 的快速自动图像分割, 这对于 PCNN 的理论研究和实际应用具有重要的现实意义.

参考文献:

- [1] Johnson J L, Padgett M L. PCNN models and applications[J]. IEEE Trans on Neural Networks, 1999, 10(3): 480 - 498.
- [2] Jcaufield H, Kinser J M. Finding shortest path in the shortest time using PCNN 's [J]. IEEE Trans. on Neural Networks. 1999, 10(3): 604 - 606.
- [3] 顾晓东, 郭仕德, 余道衡. 一种基于 PCNN 的图像去噪新方法[J]. 电子与信息学报, 2002, 24(10): 1304 - 1309.
- [4] 张军英, 樊秀菊, 董继扬, 等. 一种改进型脉冲耦合神经网络及其图像分割[J]. 计算机工程与应用. 2003, (8): 7 - 8 转 44.
- [5] Mario I, Chacon M, Alijandro Z S. Image processing using the PCNN time matrix as a selective filter[J]. IEEE, 2003, 1: 877 - 880.
- [6] 杨智勇, 周琪云, 周定康. 基于 PCNN 的灰度图像边缘检测方法[J]. 计算机工程与应用. 2004, 21: 92 - 93 转 107.
- [7] 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, 1(23): 46 - 51.
- [8] Eckhorn R, Reitboeck H J, Arndt M, et al. Feature linking via synchronization among distributed assemblies: Simulation of results from cat cortex [J]. Neural Comput, 1990, 2(3): 293 - 307.
- [9] Kreiter A K, Singer W. Oscillatory neuronal responses in the visual cortex of the awake macaque monkey [J]. European J Neurosci, 1992, 4: 369 - 375.
- [10] Eckhorn R, Frien A, Bauer R, et al. High frequency oscillations in primary visual cortex of awake monkey [J]. NeuroRep, 1993, 4(3): 243 - 246.
- [11] Frien A, Eckhorn R, Bauer R, et al. Stimulus-specific fast oscillations at zero phase between visual areas V1 and V2 of awake monkey [J]. Neuro Rep, 1994, 5(17): 2273 - 2277.
- [12] Johnson J L, Ritter D. Observation of periodic waves in a pulse-coupled neural network [J]. Opt Lett, 1993, 18(5): 1253 - 1255.
- [13] Ranganath H S, Kuntimad G, Johnson J L. Pulse coupled neural networks for image processing [A]. Proc. 1995 IEEE Southeast Con[C]. Raleigh NC, 1995. 37 - 43.
- [14] Johnson J L, Ranganath H, Kuntimad G, et al. Pulse Coupled Neural Networks [A]. Omidvar O and Dayhoff J, Ed. Neural Networks and Pattern Recognition [C]. San Diego, CA: Academicpp, 1998. 1 - 56.
- [15] Kuntimad G, Ranganath H S. Perfect image segmentation using pulse coupled neural networks [J]. IEEE Trans on Neural Networks. 1999, 10(3): 591 - 598.