

# 一种新颖的有核细胞边缘检测方法

冯 强 于盛林 黄晓晴 张 维

(南京航空航天大学自动化学院, 南京 210016)

**摘 要** 提出了一种基于细胞神经网络(CNN)的骨髓切片有核细胞边缘检测的新方法。该方法运用粒子群优化算法设计 CNN 模板,利用 CNN 对骨髓有核细胞进行边缘检测。为了避免粒子群算法的早熟,通过判断群体适应度,在早熟种群中引入混沌寻优,增强全局寻优能力。针对有核细胞的特点,采用三级由浅入深分步学习策略,从而得到最优的 CNN 模板。实验结果证明了该方法的有效性,有核细胞的检出率和边缘符合度都优于传统算法。

**关键词** 细胞神经网络 有核细胞 粒子群优化 混沌

中图法分类号: TN911.72, TP183 文献标识码: A 文章编号: 1006-8961(2009)10-2004-06

## A Novel Edge Detection Algorithm for Nucleated Cell

FENG Qiang, YU Sheng-lin, HUANG Xiao-qing, ZHANG Wei

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

**Abstract** In this paper, a novel edge detection algorithm based on cellular neural networks (CNN) is proposed for nucleated cell detection. This new algorithm applies particle swarm optimization (PSO) to design the CNN templates to identify the edge of a nucleated cell. In order to overcome the premature phenomenon of PSO, the variance of population's fitness is calculated, and chaos optimization theory is applied to enhance the PSO's global optimization. According to the characteristics of nucleated cell, a three-step study strategy is specially designed to obtain the best CNN templates. Experimental results show the new algorithm is effective; its edge fitness rates and checkout rates are better than former algorithms.

**Keywords** cellular neural networks, nucleated cells, particle swarm optimization, chaos

## 1 引 言

骨髓切片中的有核细胞数量是判断骨髓增生程度的重要指标,广泛应用于血液病、肿瘤化疗、骨髓移植等患者的骨髓增生或恢复情况判读中。图1是骨髓切片有核细胞图像。由图1可知,骨髓切片成分复杂,特别是图1(b)和图1(c)中只有颜色最深的部分为有核细胞,其他部分为不应检出的红细胞和其他组织成分。对于有核细胞的边缘检测,普通

图像处理方法效果不理想<sup>[1]</sup>。所以临床上采用的还是基于目测估计的方法——低倍镜估计法,该方法很大程度上取决于医师的经验和状态,主观性强,随意性大,准确性和重复性差。




图1 有核细胞图像

Fig. 1 Nucleated cell images

基金项目:航空基金(04D52032);江苏省自然科学基金(BK2001047)

收稿日期:2008-04-13;改回日期:2008-09-01

第一作者简介:冯 强(1980~),男,南京航空航天大学自动化学院测试计量技术及仪器专业博士研究生。主要研究方向为神经网络、图像处理。E-mail:fengqiang80@sina.com

文献[2]提出了一种采用细胞神经网络<sup>[3-4]</sup>(CNN)来进行骨髓有核细胞边缘检测的方法。该方法设计了一种新型的输出函数,能够有效地避免其他成分的干扰,并且通过遗传算法(GA)学习得到检测模板。虽然该方法细胞检出率高,但是由于GA容易陷入局部极值,所以往往得不到最优模板,因此检测边缘和目视观测的边缘常常差距较大,检测稳定性不佳。

为了提高边缘检测的准确率,提出了一种基于CNN的有核细胞检测新方法。该方法运用混沌混合粒子群优化(CPSO)算法来设计CNN的模板。通过混沌的引入使PSO具有强大的全局搜索能力,从而得到全局最优模板。并且通过精心设计的3组不同的训练样本,由浅入深地学习,得到最佳的CNN模板。实验结果表明本文方法有核细胞检出率高,而且边缘定位比较准。同时提出的基于混沌混合粒子群优化算法的CNN模板学习方法具有通用性,可以用在其他各种CNN模板设计中。

## 2 细胞神经网络模型

细胞神经网络是一种具有实时信号处理能力的大规模非线性模拟电路,具有时间域上的连续处理能力,又具有类似细胞自动机的局部连接的简单网络拓扑,所以它具有易于硬件实现和并行处理的能力。

一个标准的 $M \times N$ 的CNN阵列中, $C(i, j)$ 表示第 $i$ 行第 $j$ 列的细胞。每个细胞都有一个状态 $v_{xij}$ 、一个恒定的外界输入 $v_{uij}$ 和一个输出 $v_{vij}$ 。每个细胞的动态过程由如下的一阶微分方程表示:

$$C \frac{dv_{xij}(t)}{dt} = -\frac{1}{R_x} v_{xij}(t) + \sum_{(k,l) \in S_{i,j}(r)} A(i,j;k,l) v_{ykl}(t) + \sum_{(k,l) \in S_{i,j}(r)} B(i,j;k,l) v_{ukl} + I_{ij} \quad (1)$$

式中, $A(i, j; k, l)$ 表示细胞 $C(k, l)$ 的输出与细胞 $C(i, j)$ 之间的连接权, $B(i, j; k, l)$ 表示细胞 $C(k, l)$ 的输入 $v_{ukl}$ 与细胞 $C(i, j)$ 之间的连接权。 $C, R_x$ 表示等效电路中的电容和电阻, $I_{ij}$ 表示偏置电流。 $S_{i,j}(r)$ 表示细胞 $C(i, j)$ 的中心半径为 $r$ 的近邻影响区域,有

$$S_{i,j}(r) = \{C(k, l) \mid \max(|k - i|, |l - j|) \leq r\} \quad (2)$$

## 3 基于混合 PSO 算法的 CNN 模板学习

### 3.1 基于 PSO 的 CNN 模板学习

采用CNN进行有核细胞图像处理的核心问题是如何设计CNN模板。由于有核细胞的形状各向无规律,所以采用如下形式的对称模板:

$$A = \begin{bmatrix} a_2 & a_1 & a_2 \\ a_1 & a_0 & a_1 \\ a_2 & a_1 & a_2 \end{bmatrix} \quad B = \begin{bmatrix} b_2 & b_1 & b_2 \\ b_1 & b_0 & b_1 \\ b_2 & b_1 & b_2 \end{bmatrix} \quad I_{ij} = i \quad (3)$$

CNN的模板设计方法有规则学习法<sup>[5]</sup>,能量函数法<sup>[6]</sup>和基于GA的学习方法<sup>[7]</sup>。其中,前两种方法通常用在规则比较简单、容易建立对应关系的场合。由于骨髓切片的成分比较复杂,同时有核细胞的边缘变化比较缓慢,不容易判断,所以不适宜通过前两种方法获得CNN的模板。而基于GA的CNN模板学习方法计算复杂、容易陷入局部解,所以存在局限性,边缘的准确性较差<sup>[2]</sup>。为此,将PSO算法引入到CNN的模板学习过程中,期望利用它较强的全局优化能力得到全局最优模板。

PSO算法是1995年由Kennedy和Eberhart提出的一种新型的进化方法<sup>[8]</sup>。该算法具有寻优速度快、求解质量高的优点。同遗传算法相比,该方法没有复杂的编码和交叉、变异操作,参数少,更易于实现,而且收敛速度更快。

设PSO算法的搜索空间为 $D$ 维空间,种群的总粒子数为 $n$ ,第 $i$ 个粒子的位置表示为向量 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ;第 $i$ 个粒子的个体极值即该粒子的历史最优位置为 $\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ ,所有 $\mathbf{P}_i$  ( $i = 1, 2, \dots, n$ )中的最优解 $\mathbf{P}_g$ 即为全局最优解,第 $i$ 个粒子的位置变化率为 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 。每个粒子的位置按照下式进行变化:

$$v_{id}(t+1) = \omega v_{id}(t) + c_1 \times rand1 \times (p_{id}(t) - x_{id}(t)) + c_2 \times rand2 \times (p_{gd}(t) - x_{id}(t)) \quad (4)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (5)$$

式(4)中, $c_1$ 和 $c_2$ 为加速因子; $rand1$ 和 $rand2$ 为两个均匀分布在 $[0, 1]$ 间的随机数; $\omega$ 称为惯性因子,当 $\omega$ 取较大值时可使算法具有较强的全局搜索能力, $\omega$ 取较小值时则算法倾向于局部搜索。采

用式(6)对  $\omega$  进行自适应调整<sup>[9]</sup>,

$$\omega = \omega_{\max} - iter \times \frac{\omega_{\max} - \omega_{\min}}{iter_{\max}} \quad (6)$$

式中,  $iter$  表示迭代次数,  $iter_{\max}$  表示最大迭代次数,  $\omega_{\max}$  表示最大权重,  $\omega_{\min}$  表示最小权重。

PSO 算法中的粒子  $X_i$  向量形式为  $X_i = (a'_0, a_1, a_2, b_0, b_1, b_2, i)$ , 其中  $a_1, a_2, b_0, b_1, b_2, i$  6 个分量为式(3)中 CNN 的模板参数,  $a'_0$  与式(3)中的  $a_0$  有如下关系:

$$a_0 = 1 + |a'_0| \quad (7)$$

基于 PSO 的 CNN 模板学习算法的流程如下:

- (1) 产生一组初始位置和初始速度;
- (2) 计算每个粒子在当前位置的适应度;
- (3) 若粒子的当前适应度优于历史最优位置  $P_i$  的适应度, 则  $P_i$  更新为当前位置;
- (4) 若当前种群的最优适应度优于全局最优解  $P_g$  的适应度, 则  $P_g$  更新为当前种群中最优适应度的粒子位置;
- (5) 重复(2)~(4), 当适应度达到精度要求或者迭代次数达到最大迭代次数时停止迭代。输出当前的  $P_g$  作为 CNN 的模板。

### 3.2 3 步模板学习

由于有核细胞比较复杂, 若直接学习, 可能在最大迭代次数时停止而得不到合适结果, 从而应该最后边缘检测的结果, 导致检测准确性降低。为此, 采用 3 组样本进行由浅入深地学习。第 1 组学习样本如图 2 所示, 该组图像为简单的有规则图像, 用来决定模板的大致范围, 其中图 2(a)~图 2(e) 为输入图像, 图 2(f)~图 2(j) 为图 2(a)~图 2(e) 的期望边缘。在第 1 组样本学习的基础上, 再采用图 3 所示的类细胞图像进行学习。图 3(a)~图 3(e) 为 Matlab 图像库中的标准图像, 具有类似细胞图像的外形特点, 图 3(f)~图 3(j) 为图 3(a)~图 3(e) 的




图 2 第 1 组学习样本

Fig. 2 The first group of training samples

期望边缘。通过对图 3 的学习得到能够初步检测细胞的模板。然后采用如图 4 所示的 5 幅有核细胞图像作为样本进行学习。其中图 4(a)~图 4(e) 为有核细胞图像, 其中深颜色部分为有核细胞, 其他部分为细胞质和红细胞等其他成分, 图 4(f)~图 4(j) 为图 4(a)~图 4(e) 的期望边缘。




图 3 第 2 组学习样本

Fig. 3 The second group of training samples




图 4 第 3 组学习样本

Fig. 4 The third group of training samples

定义如式(8)和式(9)所示的  $E_1, E_2$  两个指标表示边缘的符合程度, 其中  $E_1$  表示真实边缘的检出率, 值越大表明检测出的真实边缘点越多, 检测效果越好;  $E_2$  表示误检率, 值越大表明检测出的非边缘点越多, 检测效果越差。

$$E_1 = \text{检出的真实边缘点数} / \text{真实边缘总点数} \quad (8)$$

$$E_2 = \text{非边缘检出点数} / \text{真实边缘总点数} \quad (9)$$

为了达到不同的目的, 对 3 组样本采用不同的误差适应度函数, 分别如式(10)~式(12)所示。目的是先使模板具备较高的正确边缘检测率, 在此基础上再逐步降低误检率。这样使第 1 组和第 2 组比较容易收敛得到输出。

$$f_1 = E_1 - \frac{E_2}{3} \quad (10)$$

$$f_2 = E_1 - E_2 \quad (11)$$

$$f_3 = E_1 - 3E_2 \quad (12)$$

采用的初始种群有 30 组,最大迭代次数设为 200 次。第 1 组的第 1 幅图的初始位置和初始速度为随机产生,然后 PSO 算法得到输出。其中,种群的前 1/3 的最优值作为学习成果看作下一幅图的初始状态,另外 2/3 粒子的初始状态随机生成。此外,第 2 组和第 3 组第 1 幅图的初始状态,采用前一组前 4 幅图的最优值加最后一幅图的种群前 1/3 最优值作为初始值,其他粒子初始状态随机产生。

### 3.3 混沌混合 PSO 算法

基本 PSO 算法中如果某粒子发现一个当前最优位置,其他粒子将迅速向其靠拢,因此陷入局部最优,出现早熟收敛现象。从而导致多组模板学习也停留在该点,形成“聚集”效应。为了使 PSO 算法具有强大的全局优化能力,避免陷入“聚集点”,设计了一种混沌混合 PSO 算法(简称 CPSO)<sup>[10]</sup>,该算法通过引入混沌搜索机制,增加了全局搜索能力。

采用式(13)所示的 Logistic 方程产生混沌随机数,其中  $\mu = [3.56, 4]$ 。

$$z^{n+1} = \mu z^n (1 - z^n) \quad (13)$$

式(13)产生的  $z \in [0, 1]$ ,式(14)和式(15)将混沌序列和 PSO 种群中的各个参数进行相互转换。其中, $z$  为产生的混沌序列中的随机数, $x_{ij}$  表示第  $i$  个粒子的第  $j$  个变量,其中  $1 < j \leq 7$ 。

$$z = \frac{1}{a'_0 - 1} \quad (14)$$

$$z = \begin{cases} \frac{x_{ij} + 1}{2} & |x_{ij}| < 1 \\ \frac{x_{ij} + 1}{2x_{ij}} & |x_{ij}| > 1 \end{cases} \quad (15)$$

粒子群的适应度方差  $\sigma^2$  如式(16)所示<sup>[9]</sup>,表示种群中所有粒子的聚集程度。 $\sigma^2$  越小,则粒子的聚集程度就越大。若此时算法不满足结束条件,则聚集效应将使种群陷入早熟状态。其中  $f_i^j$  表示当第  $i$  组标本的学习第  $j$  个粒子的适应度, $\bar{f}_i$  表示粒子群目前的平均适应度。

$$\sigma^2 = \sum [(f_i^j - \bar{f}_i) / f]^2 \quad (16)$$

式中, $f$  为归一化因子,其表达式为

$$f = \begin{cases} \max\{|f_i^j - \bar{f}_i|\} & \max\{|f_i^j - \bar{f}_i|\} \geq 1 \\ 1 & \text{其他} \end{cases} \quad (17)$$

CPSO 算法对普通 PSO 算法的改进点有:

(1) 随机初始状态的产生:每幅图的随机初始状态采用式(13)产生一组混沌随机序列,按照式(14)和式(15)反变换到粒子群空间,得到粒子的初始位置和初始速度。另外,基本 PSO 算法中的  $rand1()$  和  $rand2()$  也采用混沌随机数代替。

(2) 当方差  $\sigma^2$  小于设定值时,就认为该种群发生了聚集效应。此时对于每一个粒子,通过变换式(14)、式(15)将其从粒子群空间转换到区间  $[0, 1]$ ,作为  $z$  的初始值由式(13)产生混沌序列  $z_i^{(m)}$  ( $m = 1, 2, 3, \dots$ ),再将产生的混沌序列组反变换回粒子空间,计算混沌序列组粒子的适应度,采用具有更好适应度的粒子替代原粒子,从而避免聚集效应。

运用 CPSO 算法学习,得到 CNN 进行骨髓有核细胞切片图像边缘检测的模板如式(17)所示,其中  $A$  为反馈模板、 $B$  为控制模板、 $I$  为阈值。

$$A = \begin{bmatrix} -1.023 & 1 & -2.152 & 3 & -1.023 & 1 \\ -2.152 & 3 & 19.736 & 8 & -2.152 & 3 \\ -1.023 & 1 & -2.152 & 3 & -1.023 & 1 \end{bmatrix}$$

$$B = \begin{bmatrix} 0.132 & 4 & -0.039 & 7 & 0.132 & 4 \\ -0.039 & 7 & 0.684 & 5 & -0.039 & 7 \\ 0.132 & 4 & -0.039 & 7 & 0.132 & 4 \end{bmatrix}$$

$$I = 0.3965 \quad (18)$$

## 4 实验过程及结果

图 5 是一组有核细胞的灰度图像。其中深颜色的区域就是有核细胞,其余部分是其组织成分,图 5(a)~图 5(e)中分别有 5 个、8 个、13 个、10 个和 8 个有核细胞。对图 5 采用各种方法得到的边缘检测结果如图 6~图 8 所示。图 6 是采用最大类间方差法(OSTU)进行图像分割,然后用 Sobel 算子进行边缘检测的结果。其中图 6(a)的检测结果正确,图 6(b)出现了细小的边角,图 6(c)不仅出现了小干扰,还有细胞粘连,图 6(d)出现了细胞粘连的现




图 5 有核细胞图像  
Fig. 5 Nucleated cell images

象,图 6(e)除了小干扰,还出现了非有核细胞被误检测出现象。图 7 为基于 GA 的 CNN 模板学习法得到的边缘检测结果,其中图 7(a)、图 7(d)的结果基本正确,图 7(b)出现了小边角,图 7(c)不仅有粘连还出现了小的干扰,图 7(e)则出现了细胞粘连。图 8 为本文方法得到的结果,检测结果基本正确。由图 6 ~ 图 8 可知,本文方法的检测准确率最高。




图 6 OSTU 加 Sobel 边缘检测结果

Fig. 6 Edge detection results with OSTU and Sobel




图 7 基于 GA 的 CNN 边缘检测结果

Fig. 7 Edge detection results with GA and CNN




图 8 基于 CPSO 的 CNN 边缘检测结果

Fig. 8 Edge detection results with CPSO and CNN

为了定量地分析图 6 ~ 图 8 的检测精度,采用式(11)和式(12)所示的检出率和误检率两个指标来评价 3 种方法的优劣,3 种方法得到的结果如表 1 所示。其中 OSTU + Sobel 表示采用 OSTU 进行阈值分割、Sobel 算法进行边缘检测的结果;GA + CNN 表示基于 GA 的 CNN 模板优化法的结果;CPSO + CNN 表示基于混沌混合粒子群优化方法得到的 CNN 模板检测得到的结果。从表 1 中可以看出,OSTU + Sobel 的两项指标都最低,而本文方法的两项指标均优于 GA + CNN 方法。所以本文算法的检测效果和精度都最理想。其中,由于有核细胞的边缘是缓变的,所以人工定位边缘的时候将其边缘宽度定在 3 个像素左右,从而导致 3 种方法得到的结果  $E_1$  普遍都比较低。

表 1 检测精度比较

Tab. 1 Comparison of detection accuracy

图像	OSTU + Sobel		GA + CNN		PSO + CNN	
	$E_1$	$E_2$	$E_1$	$E_2$	$E_1$	$E_2$
图 5(a)	0.025 6	0.324 9	0.223 6	0.192 3	0.248 1	0.091 4
图 5(b)	0.003 4	0.365 2	0.201 3	0.252 7	0.236 8	0.127 1
图 5(c)	0.031 5	0.505 3	0.161 9	0.274 6	0.219 1	0.133 8
图 5(d)	0.015 8	0.392 4	0.081 9	0.269 0	0.195 8	0.121 2
图 5(e)	0.041 3	0.362 9	0.136 8	0.225 6	0.204 8	0.103 4

## 5 结论

提出了一种骨髓切片图像有核细胞边缘检测的新方法,该方法采用混沌混合粒子群优化算法,针对有核细胞图像特点采用 3 步学习法对 CNN 模板进行学习,取得了很好的效果。细胞检出率和边缘准确度都优于传统方法。由于 CNN 具有并行性,易于用大规模模拟电路实现,因此该方法完全可以满足实时性的要求。而且提出的 CNN 模板设计方法具有通用性,可以运用到其他的基于 CNN 的图像处理中,是一种非常具有应用前景的方法。

## 参考文献 (References)

- 1 Wang Feng-ji. Modern Blood Cell Diagnostics [M]. Tianjin: Tianjin Technological Translation Publication, 2004:11-14. [王凤计. 现代血液细胞诊断学 [M]. 天津:天津科技翻译出版社, 2004: 11-14.]
- 2 Feng Qiang, Yu Sheng-lin, Wang Huai-ying, et al. A new edge detection method of nucleated cells with improved cellular neural networks [J]. Chinese Journal of Biomedical Engineering, 2008, 27(1):29-32. [冯强,于盛林,王怀颖等. 基于细胞神经网络的有核细胞边缘检测方法研究 [J]. 中国生物医学工程学报, 2008, 27(1): 29-32.]
- 3 Chua L O, Yang L. Cellular neural networks: Theory [J]. IEEE Transactions on Circuit and System, 1988, 35(10): 1257-1272.

- 4 Chua L O, Yang L. Cellular neural networks: Applications [J]. IEEE Transactions on Circuit and System, 1988, **35** ( 10 ): 1273-1290.
- 5 Min L Q, Lei M, Dong X. New templates of CNN for extracting corners of objects in gray-scale images [J]. Journal of University of Science and Technology Beijing, 2003, **10**(3): 73-85.
- 6 Wang Huai-ying, Yu Sheng-lin, Feng Qiang. A new approach for shape from shading based on CNN [J]. Acta Electronica Sinica, 2006, **34**(11): 2120-2124. [王怀颖, 于盛林, 冯强. 基于细胞神经网络的从阴影恢复形状的新方法 [J], 电子学报, 2006, **34**(11): 2120-2124. ]
- 7 Hanggi M, Moschytz G S. Genetic optimization of cellular neural networks [ A ]. In: Proceedings of 1998 IEEE World Congress on Computational Intelligence [ C ], Piscataway NJ, USA: IEEE Press, 1998: 381-386.
- 8 Kennedy J, Eberhart R C. Particle swarm optimization [ A ]. In: Proceedings of IEEE Conference on Neural Network [ C ], Piscataway NJ, USA: IEEE Press, 1995: 1942-1948.
- 9 Lv Zhen-su, Hou Zhi-rong. Particle swarm optimization with adaptive mutation [J]. Acta Electronica Sinica, 2004, **32**(3): 416-420. [吕振肃, 侯志荣. 自适应变异的粒子群优化算法 [J]. 电子学报, 2004, **32**(3): 416-420. ]
- 10 Jia Dong-li, Zhang Jia-shu. Niche particle swarm optimization combined with chaotic mutation [ J ]. Control and Decision, 2007, **22** ( 1 ): 117-120. [贾东立, 张家树. 基于混沌变异的小生境粒子群算法 [J]. 控制与决策, 2007, **22**(1): 117-120. ]