

# PCNN 参数自适应设定及其模型的改进

邓翔宇<sup>1,2</sup>, 马义德<sup>1</sup>

(1. 兰州大学信息科学与工程学院, 甘肃兰州 730000; 2. 兰州工业学院电子信息工程系, 甘肃兰州 730050)

**摘 要:** 脉冲耦合神经网络(PCNN)模型在数字图像处理中有着广泛应用,但基本都是从网络的外在特性出发并结合一定的实际应用对其进行研究和改进,缺乏对模型本身数学特性的分析.本文从 PCNN 模型的迭代方程出发,对无耦合连接和耦合连接两种状态下的 PCNN 数学模型进行了点火机理分析,揭示了 PCNN 模型本身的数学耦合特性(点火阶梯)以及其对网络生物学特性(脉冲发放特性)会造成干扰和影响的现象,并分析了这种干扰和影响产生的机理和消除方法,同时提出 PCNN 用于图像分割时参数自适应设定的方法.最后给出了更能体现神经网络生物学特性的 PCNN 改进模型,将其用于 Lena 等图像的分割处理中,取得了良好的效果.

**关键词:** 神经元点火机理; 模型数学耦合特性; 参数自适应确定; PCNN 改进模型

**中图分类号:** TP183; TP391      **文献标识码:** A      **文章编号:** 0372-2112 (2012) 05-0955-010

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2012.05.015

## PCNN Model Automatic Parameters Determination and Its Modified Model

DENG Xiang-yu<sup>1,2</sup>, MA Yi-de<sup>1</sup>

(1. School of Information Science and Engineering, Lanzhou University, Lanzhou, Gansu 730000, China;

2. Department of Electronics and Information Engineering, Lanzhou Institute of Technology, Lanzhou, Gansu 730050, China)

**Abstract:** Pulse Coupled Neural Network (PCNN) model has been widely used in digital image processing, but most of the study and the improvement of the model are based on the external characteristic of PCNN, ignoring the shortage resulted from the discretization of the neuron firing time. For both the non-linking PCNN and coupled linking PCNN, this paper analyzed the firing mechanism of neurons from the point of PCNN iterative equations, and the modified formulas of the neuron firing time are proposed. The phenomenon that the mathematics coupled characteristic of model itself has an overwritten effect on its biological characteristics is revealed. On that basis, the method of eliminating the mathematics coupled characteristic is proposed and the automatic parameters determination of PCNN is implemented. Then, a new modified PCNN model is proposed, and it is used in image segmentation and a good result is obtained.

**Key words:** neuron firing mechanism; mathematics coupled characteristic; parameter adaptive determination; PCNN modified model

### 1 引言

1990年, Eckhorn等人提出基于猫的视觉皮层神经元信号传导特性的神经网络模型<sup>[1]</sup>; 1999年, Johnson等人将其改进成适合于图像处理的模型, 并命名为 PCNN<sup>[2]</sup>. PCNN 网络由多个基本神经元模型组合而成, 广泛应用于数字图像的分割、边缘检测、编码、增强、融合、目标识别等处理中<sup>[3,4]</sup>. 每一个神经元对应一个像素点, 当本神经元激发时会引起相邻区域中相近灰度级像素点的激发, 称这种现象为 PCNN 网络的同步脉冲发放

特性, 有控制地利用这种特性就可以实现数字图像的各种处理. 单个神经元模型可以分成五个离散子系统: 耦合连接子系统、反馈输入子系统、调制子系统、动态门限子系统和点火子系统, 其中, 点火子系统的状态决定了神经元的状态: 激发(点火)或抑制. 其模型如图 1 所示.

PCNN 模型参数的设置决定了其性能的好坏, 已经有许多文献对 PCNN 网络参数的自动设定做了研究. 赵峙江等提出了用灰度-信息量直方图来表征图像特征, 利用信息量直方图自动估算 PCNN 时间衰减参数的自适应算法<sup>[5]</sup>, 而其对 PCNN 其他参数的设定仍采用经验

方式;Kuntimad G等提出基于PCNN实现图像完美分割的算法<sup>[6]</sup>,但只对参数 $\beta$ 的设定进行了讨论;于江波等虽对PCNN模型参数的设定进行了理论研究<sup>[7]</sup>,但其用于图像处理时算法比较复杂;Min Li等采用灰度分布的分水岭思想<sup>[8]</sup>,用动态阈值代替PCNN的动态门限,并对内部活动项的连接系数进行了参数自适应讨论,从而实现了多灰度的图像分割;马义德等提出了基于最大熵准则的PCNN循环迭代次数自动确定方法<sup>[9]</sup>,但其他参数没有讨论;马义德等还将简化的PCNN模型与遗传算法结合提出一种基于遗传算法的PCNN自动图像分割算法,实现简化模型参数的寻优设定<sup>[10]</sup>;陈煜笠等提出简化PCNN模型实现图像多层自动分割的方法<sup>[11]</sup>,即无需训练就可根据待分割图像的统计特性成功确定所有可调整的参数.总之,目前有关PCNN图像自动分割算法大都以图像本身统计特性等为侧重点进行研究,忽视了对网络特性的进一步分析和讨论,从而导致了现有算法的特定局限性.

## 2 PCNN模型及其点火机理

### 2.1 PCNN网络数学模型

图1所示的神经元模型中,各子系统均可以描述成一个离散系统模型<sup>[12-14]</sup>,即可以用迭代差分方程表示如下:

$$F_{ij}(n) = e^{-a_f} F_{ij}(n-1) + V_f \sum M_{ijkl} Y_{kl}(n-1) + S_{ij} \quad (1)$$

$$L_{ij}(n) = e^{-a_l} L_{ij}(n-1) + V_l \sum W_{ijkl} Y_{kl}(n-1) \quad (2)$$

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

$$E_{ij}(n) = e^{-a_e} E_{ij}(n-1) + V_E Y_{ij}(n-1) \quad (4)$$

$$Y_{ij}(n) = \epsilon [U_{ij}(n) - E_{ij}(n)] \quad (5)$$

其中,式(1)为反馈输入子系统模型,式(2)为耦合连接子系统模型,式(3)为调制子系统模型,式(4)为点火子系统模型,式(5)为动态门限子系统模型.下标 $i, j$ 表示数字图像中的某一个像素, $k, l$ 表示中心像素的邻域像素, $M, W$ 表示中心像素和邻域像素的连接权矩阵. $a_f$ 和 $V_f, a_l$ 和 $V_l, a_e$ 和 $V_E$ 分别表示对应子系统的迭代衰减时间常数和连接权放大系数. $\beta$ 为调制子系统的内部活动项连接系数, $S_{ij}$ 为神经元对应像素点的灰度值.

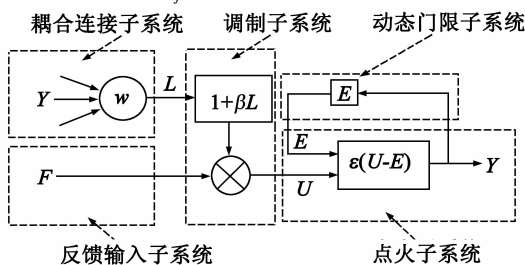


图1 脉冲耦合神经元模型

耦合连接子系统和反馈输入子系统共同作用于调制子系统,神经元的状态即点火子系统的输出状态取决于由 $U$ 和 $E$ 所构成的阶跃函数 $\epsilon [U_{ij}(n) - E_{ij}(n)]$ .本神经元的状态会通过邻域神经元的耦合连接子系统对邻域神经元产生作用,当与邻域像素的灰度值相近时,又会引起邻域像素的点火,这称为PCNN网络的捕获特性和同步脉冲发放特性<sup>[15,16]</sup>.

### 2.2 神经元点火机理分析

对于无耦合连接的PCNN网络,模型往往将式(1)简化为 $F_{ij}(n) = S_{ij}$ 常数形式,即:

$$U_{ij}(n) = F_{ij}(n) = S_{ij} \quad (6)$$

$$E_{ij}(n) = e^{-a_e} E_{ij}(n-1) + V_E Y_{ij}(n-1) \quad (7)$$

$$Y_{ij}(n) = \epsilon [U_{ij}(n) - E_{ij}(n)] \quad (8)$$

由式(6)、(7)、(8)可组成式(9)所示迭代方程:

$$Y_{ij}(n) = \epsilon [S_{ij} - e^{-a_e} E_{ij}(n-1) - V_E Y_{ij}(n-1)] \quad (9)$$

其中, $Y_{ij}(n)$ 表示第 $ij$ 个像素在第 $n$ 次迭代中的点火状态.令动态门限 $E$ 初值为0,点火状态初值为0,则各迭代时刻 $n$ 神经元的点火状态分别为:

(1) 初始状态时  $E_{ij}(0) = 0, Y_{ij}(0) = 0$ , 神经元未点火.

(2)  $n = 1$  时  $E_{ij}(1) = e^{-a_e} E_{ij}(0) + V_E Y_{ij}(0) = 0, Y_{ij}(1) = \epsilon [S_{ij} - E_{ij}(0)] = 1$ , 即神经元第一次点火.

(3)  $n = 2$  时  $E_{ij}(2) = e^{-a_e} E_{ij}(1) + V_E Y_{ij}(1) = V_E, Y_{ij}(2) = \epsilon [S_{ij} - E_{ij}(2)] = \epsilon [S_{ij} - V_E]$

(4)  $n = 3$  时

$$\begin{aligned} E_{ij}(3) &= e^{-a_e} E_{ij}(2) + V_E Y_{ij}(2) \\ &= e^{-a_e} (e^{-a_e} E_{ij}(1) + V_E Y_{ij}(1)) + V_E Y_{ij}(2) \\ &= e^{-2a_e} E_{ij}(1) + e^{-a_e} V_E Y_{ij}(1) + V_E Y_{ij}(2) \\ &= e^{-a_e} V_E + V_E Y_{ij}(2) \end{aligned}$$

$$Y_{ij}(3) = \epsilon [S_{ij} - e^{-a_e} V_E - V_E Y_{ij}(2)]$$

(5)  $n = 4$  时

$$\begin{aligned} E_{ij}(4) &= e^{-a_e} E_{ij}(3) + V_E Y_{ij}(3) \\ &= e^{-a_e} (e^{-a_e} V_E + V_E Y_{ij}(2)) + V_E Y_{ij}(3) \\ &= e^{-2a_e} V_E + e^{-a_e} V_E Y_{ij}(2) + V_E Y_{ij}(3) \end{aligned}$$

(6) 假设直到 $n = n_2$ 时神经元第二次点火,则有:

$$\begin{aligned} E_{ij}(n_2) &= e^{-a_e} E_{ij}(n_2-1) + V_E Y_{ij}(n_2-1) \\ &= e^{-(n_2-2)a_e} V_E + e^{-(n_2-3)a_e} V_E Y_{ij}(2) + \dots \\ &\quad + e^{-a_e} V_E Y_{ij}(n_2-2) + V_E Y_{ij}(n_2-1) \end{aligned}$$

$$Y_{ij}(n) = 0, (n \leq n_2 - 1 \text{ 且 } n \neq 1)$$

根据点火条件可得:  $e^{-(n_2-2)a_e} V_E + \dots + e^{-a_e} V_E Y_{ij}(n_2-2) + V_E Y_{ij}(n_2-1) = S_{ij}$

即:  $e^{-(n_2-2)a_e} V_E = S_{ij} \Rightarrow n_2 = 1 - \frac{1}{a_e} \ln \frac{S_{ij}}{V_E e^{a_e}} = 2 - \frac{1}{a_e} \ln \frac{S_{ij}}{V_E}$ , 其中 $n_2 - 1$ 为从第一次点火到第二次点火的样点间隔 $T_2$ .

(7) 又假设在 $n_2$ 样点点火之后直到 $n_3$ 样点神经元

第三次点火,则有:

$$\begin{aligned} E_{ij}(n_3) &= e^{-a_E} E_{ij}(n_3 - 1) + V_E Y_{ij}(n_3 - 1) \\ &= e^{-(n_3-2)a_E} V_E + e^{-(n_3-3)a_E} V_E Y_{ij}(2) + \\ &\quad \cdots + V_E Y_{ij}(n_3 - 1) \end{aligned}$$

$$Y_{ij}(n) = 0, (n \leq n_3 - 1, n \neq 1, n_2)$$

根据点火条件可得:

$$e^{-(n_3-2)a_E} V_E + \cdots + e^{-(n_3-n_2-1)a_E} V_E Y_{ij}(n_2) + \cdots + V_E Y_{ij}(n_3 - 1) = S_{ij}$$

$$\text{即: } e^{-(n_3-2)a_E} V_E + e^{-(n_3-n_2-1)a_E} V_E = S_{ij} \Rightarrow n_3 = 1 - \frac{1}{a_E} \ln$$

$$\frac{S_{ij}}{V_E(e^{a_E} + e^{n_2 a_E})}$$

故由前两次点火时刻可推得神经元在无耦合状态下的第二个点火间隔  $T_3$  为:

$$T_3 = n_3 - n_2 = \frac{1}{a_E} \ln \left( \frac{e^{a_E} + e^{n_2 a_E}}{e^{a_E}} \right)$$

对以上点火过程进行归纳,可得神经元在无耦合状态下点火样点  $n_m$  及其各样点间隔  $T_m$  为:

$$n_m = 1 - \frac{1}{a_E} \ln \frac{S_{ij}}{V_E(e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \cdots + e^{n_{m-1} a_E})}, \quad (m = 2, 3, 4, \cdots) \quad (10)$$

$$\begin{aligned} T_m &= n_m - n_{m-1} = \frac{1}{a_E} \ln \left( \frac{e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \cdots + e^{n_{m-1} a_E}}{e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \cdots + e^{n_{m-2} a_E}} \right) \\ &= \frac{1}{a_E} \ln \left( 1 + \frac{e^{n_{m-1} a_E}}{e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \cdots + e^{n_{m-2} a_E}} \right), \quad (m = 2, 3, 4, \cdots) \end{aligned} \quad (11)$$

以上是理论计算时间,而模型在计算机上运行时,由于计算机离散化处理时只能对整数时刻进行迭代输出,所以实际的点火时刻应修正为:

$$n_m = \text{fix} \left[ 1 - \frac{1}{a_E} \ln \frac{S_{ij}}{V_E(e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \cdots + e^{n_{m-1} a_E})} \right] + 1 \quad (m = 2, 3, 4, \cdots) \quad (12)$$

其中,第一次点火为 1 样点(时刻),第二次点火为  $n_2$  样点,第  $m$  次点火为  $n_m$  样点.由式(12)可见,在数字图像处理中,具有相近灰度值的像素在无耦合连接 PCNN 网络的迭代序列中具有相同的点火样点  $n_m$ .同时,无耦合连接 PCNN 神经元的点火间隔  $T_m$  与  $m$  无关,称其为 PCNN 网络对某个灰度值  $S_{ij}$  的点火周期  $T$ ,对  $T$  进一步分析发现:假设  $S_{ij} = 0$  和  $S_{ij} = 255$  的第 2 次点火时刻分别为  $n_{2,0}$ 、 $n_{2,255}$ ,则当参数  $a_E$ 、 $V_E$  选取某些不同值时,会出现  $n_{2,0} - n_{2,255} < n_{2,255}$  和  $n_{2,0} - n_{2,255} \geq n_{2,255}$  两种情况,而点火周期  $T$  与这两种情况是相关的,即某个灰度值  $S_{ij}$  的实际点火周期为:

$$T = \begin{cases} n_{m+1} - n_m = n_2 - 1 & , n_{2,0} - n_{2,255} < n_{2,255} \\ n_{m+1} - n_m & , n_{2,0} - n_{2,255} \geq n_{2,255} \end{cases}, \quad (m = 2, 3, 4, \cdots) \quad (13)$$

总之,对于 PCNN 网络,输入值越大点火时刻越早、点火周期也越小.当参数  $a_E$ 、 $V_E$  给定常数时,由式(10)和式(12)可得 PCNN 模型中各灰度值的第 2 次理论和实际点火时刻分别如图 2(a)、(b)所示.




图2 PCNN灰度点火时刻图

### 2.3 PCNN 的点火时刻阶梯特性分析

由图 2 可见,当 PCNN 的参数设置不能保证数学模型的理论特性时,模型的实际运行特性图 2(b)将与 PCNN 模型的算法特性图 2(a)不能吻合,即算法程序的执行情况并没有真实反映算法的特性.

当令参数  $a_E = 3.45$ 、 $V_E = 375$  时,灰度值  $S_{ij}$  分别为 200、255(归一化)的阈值变化和点火情况如图 3 所示.

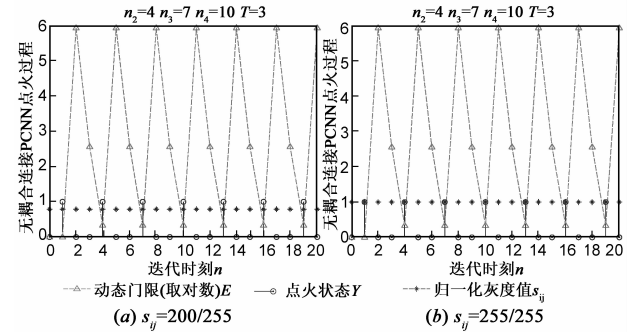
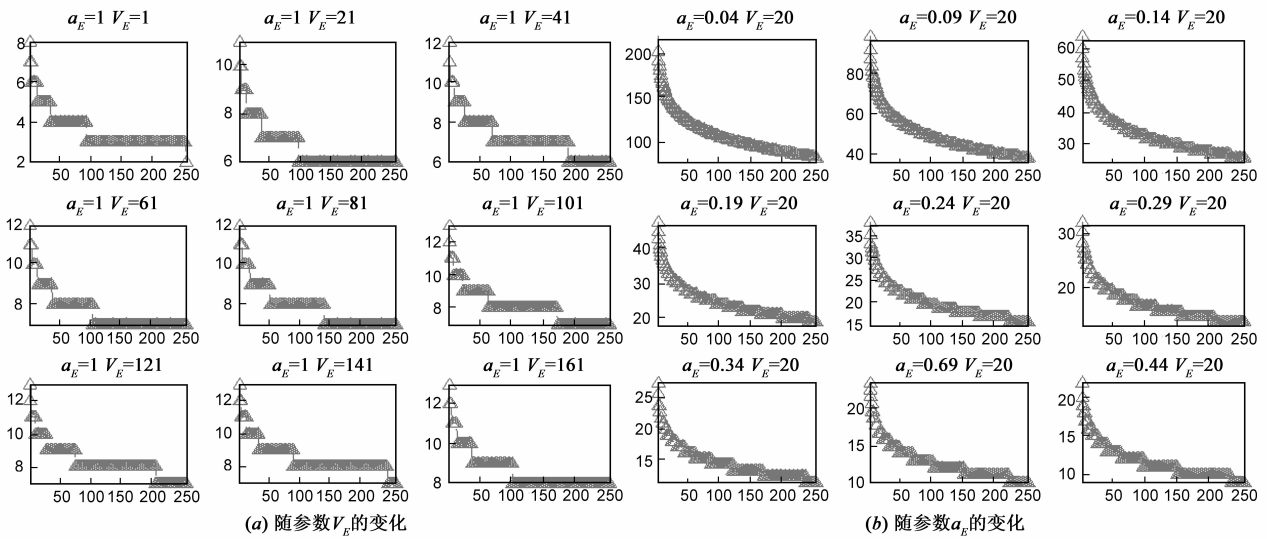


图3 不同灰度值的阈值变化和点火时刻图

由图 3 可见,对于  $S_{ij} = 200$  和  $S_{ij} = 255$  的灰度值,均在第一次迭代发生点火(所有灰度值均如此),称为无效点火(不予考虑),称其后各次点火为有效点火.同时发现,在这种参数设置下,这两种灰度值具有相同的点火时刻和点火周期,取其他不同区间的灰度值也会发现这种类似现象,即灰度值(归一化)在某一区间的像素将在同一迭代时刻点火,但这种灰度区间的大小会随着灰度值范围的变化而不同,可见无耦合连接 PCNN 模型具有点火分辨率的特性,其中低灰度值区间的点火分辨率高、高灰度值区间的点火分辨率低,从而使整个灰度区间的点火时刻呈阶梯变化,这一现象可以由图 2(b)所示点火阶梯得以充分体现.又由式(12)可见,点火阶梯完全受到参数  $a_E$  和  $V_E$  的影响,各灰度值的第 2 次点火(第 1 次有效点火)时刻分别随参数  $a_E$  和  $V_E$  变化的情况如图 4 所示.

图4 点火阶梯随参数 $V_E$ 、 $a_E$ 的变化曲线图

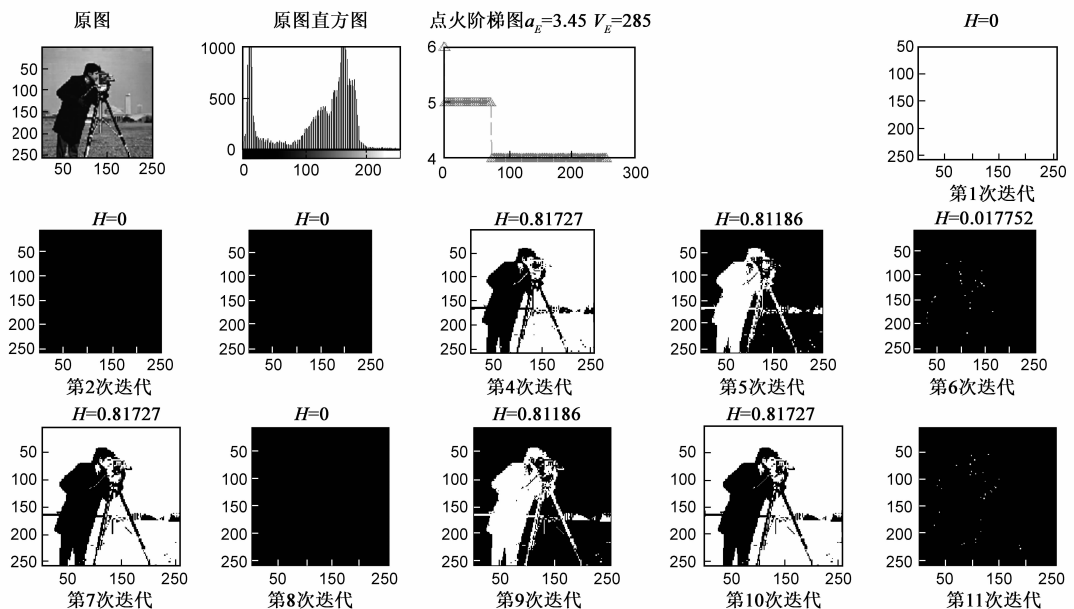
由图4可见,  $V_E$  主要影响了各个点火阶梯的宽度, 并且  $V_E$  越小阶梯的起始高度越小, 也即点火时刻越早(从右到左), 当  $V_E=1$  (归一化灰度的最大值) 时点火阶梯从第二次迭代开始; 而  $a_E$  主要影响了点火阶梯的台阶数量和上升的高度。

总之, 对于无耦合连接 PCNN 模型, 当其算法在计算机上实际执行时, 在适当参数设置情况下, 灰度值从 255 到 0 的各像素其点火时刻为阶梯上升方式, 对相近灰度值的像素具有相同的点火时刻, 故而其实现了耦合连接 PCNN 模型的效应, 并且随着灰度值的减小, 各个阶梯的宽度减小、耦合特性减弱。因此, 无耦合连接 PCNN 模型可以呈现耦合连接 PCNN 模型的效果, 但需要注意到, 这种耦合特性是由差分方程的数学特性所

决定的, 并没有完全反映神经元之间的耦合作用, 在此将这种耦合特性称为 PCNN 的“数学耦合特性”。

当参数  $a_E$  和  $V_E$  给定时, 最小灰度值 0 的第 2 次点火时刻也是确定的, 称其为无耦合连接 PCNN 的迭代周期。若在一个 PCNN 迭代周期内, 整个灰度值区间在第  $x$ 、 $y$ 、 $z$ ... (假设  $n_{2,0} - n_{2,255} < n_{2,255}$ ) 次迭代时刻有效点火, 则各灰度值区间的点火周期分别为  $x-1$ 、 $y-1$ 、 $z-1$ ... , 对应灰度值区间的第  $m$  次点火时刻分别为  $m(x-1)+1$ 、 $m(y-1)+1$ 、 $m(z-1)+1$ ... ( $m=1, 2, 3$ ...)。若在迭代过程中各灰度值区间的点火时刻发生重叠, 则不同阶梯区间的灰度像素会发生同时点火现象。

取  $a_E=3.45$ 、 $V_E=285$  时各次迭代输出如图 5 所示, 可见, 在这种参数下整个灰度值区间在一个 PCNN

图5 点火阶梯及各次迭代图像( $H$ 为分割后图像熵)

迭代周期内被分成三个点火阶梯,对应的点火时刻分别为第 4、5、6 次迭代,点火周期分别为 3、4、5. 其中第 7、9、11 次迭代为对应灰度值区间的第 2 次有效点火,第 10 次迭代为第一个阶梯的第 3 次有效点火.

### 3 耦合连接 PCNN 网络特性分析

#### 3.1 耦合连接 PCNN 点火机理

PCNN 是一种多参数神经网络模型,参数的设置决定了其应用效果的好坏,在保证原有模型生物特性基础上,为分析方便,模型简化为如下式(14)~(18):

$$F_{ij}(n) = S_{ij} \quad (14)$$

$$L_{ij}(n) = V_L \sum W_{ijkl} Y_{kl}(n-1) \quad (15)$$

$$U_{ij}(n) = F_{ij}(n)(1 + \beta L_{ij}(n)) \quad (16)$$

$$E_{ij}(n) = e^{-a_E} E_{ij}(n-1) + V_E Y_{ij}(n-1) \quad (17)$$

$$Y_{ij}(n) = \epsilon [U_{ij}(n) - E_{ij}(n)] \quad (18)$$

由式(14)到式(18)可组成式(19)所示迭代方程:

$$Y_{ij}(n) = \epsilon [S_{ij} + \beta S_{ij} V_L \sum W_{ijkl} Y_{kl}(n-1) - e^{-a_E} E_{ij}(n-1) - V_E Y_{ij}(n-1)] \quad (19)$$

令动态门限  $E$  初值为 0、点火状态初值为 0、连接子系统初值为 0,则各迭代时刻神经元的点火状态分别为:

(1) 设初始状态时  $E_{ij}(0) = 0$ 、 $Y_{ij}(0) = 0$ 、 $L_{ij}(0) = 0$ , 神经元未点火.

(2)  $n = 1$  时  $E_{ij}(1) = e^{-a_E} E_{ij}(0) + V_E Y_{ij}(0) = 0$

$$L_{ij}(1) = V_L \sum W_{ijkl} Y_{kl}(0) = C_{ij1}$$

$$U_{ij}(1) = S_{ij} + \beta S_{ij} C_{ij} = S_{ij}(1 + \beta C_{ij1})$$

其中,  $Y_{kl}(0)$  表示在本次迭代的前一次邻域神经元的状态,  $W_{ijkl}$  通常取  $[0.5 \ 1 \ 0.5; 1 \ 0 \ 1; 0.5 \ 1 \ 0.5]$  的  $3 \times 3$  矩阵,  $C_{ij1}$  取决于邻域像素的点火状态,取值范围在  $[0, 6V_L]$  之间. 此时,  $Y_{ij}(1) = \epsilon [U_{ij}(1) - E_{ij}(1)] = 1$ , 故神经元第一次点火.

(3) 假设直到  $n = n_2$  迭代时刻神经元第二次点火,根据点火条件可得:

$$e^{-(n_2-2)a_E} V_E + \dots + e^{-a_E} V_E Y_{ij}(n_2-2) + V_E Y_{ij}(n_2-1) = S_{ij}(1 + \beta C_{ijn_2})$$

即:  $e^{-(n_2-2)a_E} V_E = S_{ij}(1 + \beta C_{ijn_2}) \Rightarrow n_2 = 1 - \frac{1}{a_E} \ln \frac{S_{ij}(1 + \beta C_{ijn_2})}{V_E e^{a_E}}$ , 其中,  $n_2 - 1$  也是从第一次点火到第二次点火的样点间隔  $T_2$ .

对以上点火过程进行归纳,可得神经元在有耦合连接下点火样点  $n_m$  及其各样点间隔  $T_m$  为:

$$n_m = 1 - \frac{1}{a_E} \ln \frac{S_{ij}(1 + \beta C_{ijn_m})}{V_E (e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \dots + e^{n_{m-1} a_E})}, \quad (m = 2, 3, 4, \dots) \quad (20)$$

$$T_m = n_m - n_{m-1}$$

$$\begin{aligned} &= \frac{1}{a_E} \ln \left[ \frac{e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \dots + e^{n_{m-1} a_E}}{e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \dots + e^{n_{m-2} a_E}} \times \frac{(1 + \beta C_{ijn_{m-1}})}{(1 + \beta C_{ijn_m})} \right] \\ &= \frac{1}{a_E} \ln \left( 1 + \frac{e^{n_{m-1} a_E}}{e^{a_E} + e^{n_2 a_E} + e^{n_3 a_E} + \dots + e^{n_{m-2} a_E}} \right) \\ &\quad + \frac{1}{a_E} \ln \left( \frac{1 + \beta C_{ijn_{m-1}}}{1 + \beta C_{ijn_m}} \right), \quad (m = 2, 3, 4, \dots) \end{aligned} \quad (21)$$

由式(20)可见,  $n_m$  取决于  $S_{ij}$  和  $\beta C_{ijn_m}$  的影响,可知这仍然是一个非线性系统,耦合连接 PCNN 模型的神经元点火时刻受到了  $\beta C_{ijn_m}$  的(调制)扰动影响,在无耦合连接模型点火时刻基础上发生了 1 到  $(1 + 6\beta V_L)$  的偏移影响,从而可能使本不能点火的神经元由于邻域神经元的耦合作用而被提前点火,这样就形成了耦合连接 PCNN 网络的捕获特性和同步脉冲发放特性.

#### 3.2 PCNN 模型数学耦合特性的消除

通过前面对无耦合连接和耦合连接两种 PCNN 网络点火特性的分析,可以发现,PCNN 网络中神经元的点火状态受到了三个因素的影响:(1)是模型本身的数学耦合特性;(2)是模型数学耦合特性的周期重叠;(3)是网络自身的同步脉冲发放特性.这三个特性叠加在一起决定了网络实际特性的体现,其中第(1),(2)个特性都来源于模型本身的数学性质,其对 PCNN 网络生物学特性的正常体现构成了一种干扰和影响,因此必须对其加以消除.

##### 3.2.1 无数学耦合特性 PCNN 的参数设定

由图 4(b)可见,当  $a_E$  取接近于 0 的较小值时,整个灰度值区间的点火周期会很大,点火阶梯越多越窄,模型本身的数学耦合特性会越弱,从而使网络自身的捕获特性和同步脉冲发放特性得以正常体现.根据式(10)可知,灰度值越大点火时刻越小,为提高网络点火效率同时又阻止产生数学耦合点火干扰,应使整个图像中的最大归一化灰度值  $S_{\max}$  在第 2 次迭代就点火,即  $n_2$  的理论值需满足:

$$1 < n_2 \leq 2$$

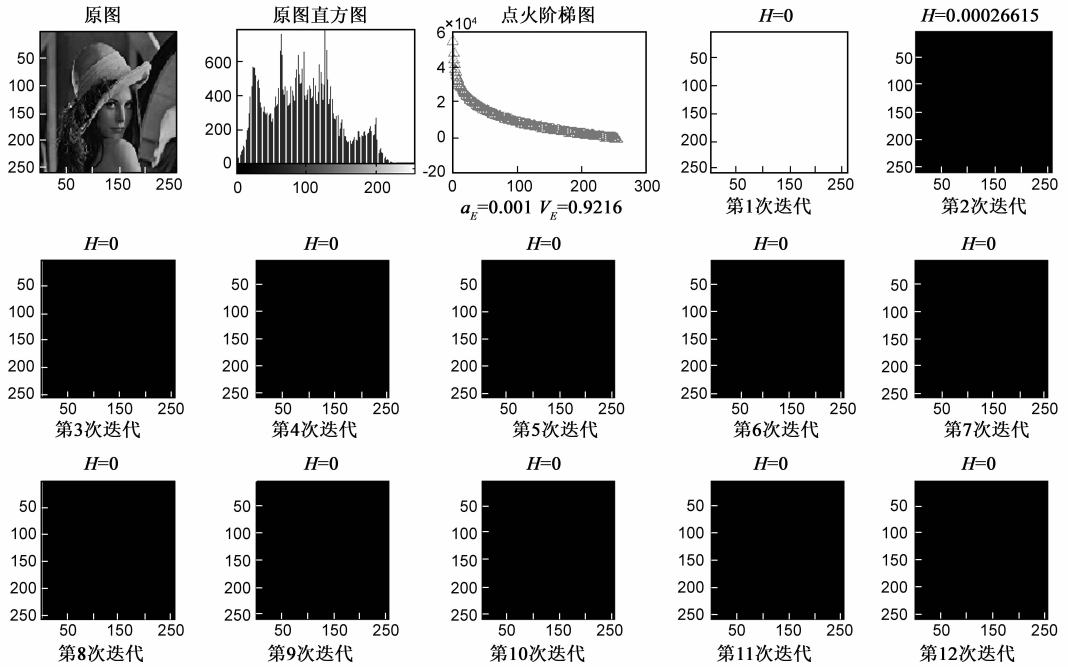
$$\begin{aligned} \text{即: } \quad 1 < 1 - \frac{1}{a_E} \ln \frac{S_{\max}}{V_E e^{a_E}} &= 1 - \frac{1}{a_E} \ln \frac{S_{\max}}{V_E} + \frac{1}{a_E} \ln e^{a_E} \\ &= 2 - \frac{1}{a_E} \ln \frac{S_{\max}}{V_E} \leq 2 \end{aligned}$$

$$\frac{S_{\max}}{e^{a_E}} < V_E \leq S_{\max}$$

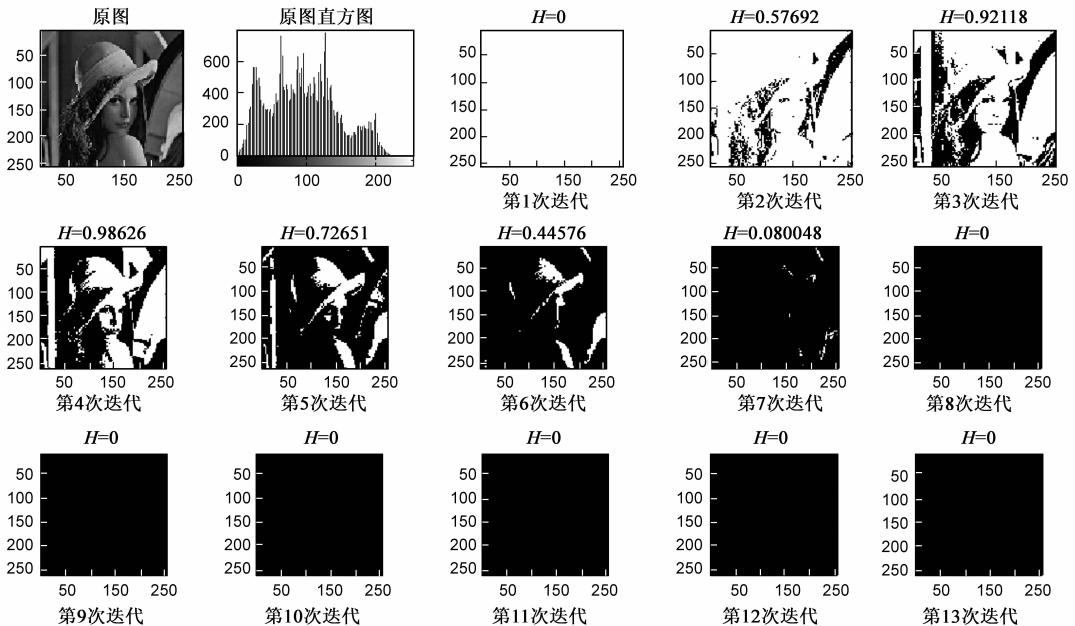
上式中  $e^{a_E}$  略微大于 1,所以当取  $V_E = S_{\max}$  时,上述条件可得以满足.以 Lena 图像为例,无数学耦合特性 PCNN 网络在无耦合连接和耦合连接情况下的迭代输出如图 6 所示.由图 6(a)可见,图像中的最大灰度值像素在第 2 次迭代点火,而且由于在这种参数的设置下,各灰度值的点火时刻间隔增大,使得 PCNN 网络的迭代周期很

大(此时满足  $n_{2,0} - n_{2,255} \geq n_{2,255}$  的条件),基本消除了网络本身的数学耦合特性及其周期重叠,同时又由 Lena 图像的直方图可见,高灰度值的像素分布较少,即当迭代次数较小时仅有最大灰度值像素点火一次;由图 6(b)可见,第一次所有像素全部点火,在第二次迭代

时由于  $E$  值的上升,使得个别灰度值较小的像素不能点火,然后随着迭代的进行,这些未点火的像素会将它自身的状态向邻域灰度值相近的像素传播,这种现象就是 PCNN 的捕获特性的体现.



(a) 无耦合连接网络的数学特性



(b) 耦合连接网络的生物学特性

图6 无数学耦合PCNN网络的实际特性

### 3.2.2 PCNN 的改进模型及其参数设定

对式(14)~(18)所示的 PCNN 模型进行参数的规整,将式(15)、(16)中的参数  $V_L$  和  $\beta$  归为一个参数  $D$ ,

即  $D = V_L\beta$ ,并改进连接项,取  $w_{ij} = 1$ ,设  $\sum W_{ijkl}Y_{ijl}(n-1) = L_{0ij}(n)$ ,对  $W_{ijkl}$  采用弱耦合方式设置,此时式(16)可类比为一调幅系统.其中,  $F_{ij}(n)$  为待调制信号,

$(1 + DL_{0ij}(n))$ 近似为带有直流分量(为 1)的调制载波. 为获得这一调幅系统的输入输出特性,并且考虑到两个信号在实际图像处理中的变化特点,在此用  $0.5 + 0.5\sin(\omega t)$ 来表示  $F_{ij}$ 的缓慢变化(类比归一化灰度值)、 $DL_{0ij}\sin(\omega t)$ 来表示  $DL_{0ij}(n)$ 的随机快速变化(类比邻域像素点火状态的随机变化),若进一步假设直流分量为  $a$ ,对其过程进行仿真,则发现以下现象:在直流分量  $a$ 与载波幅度  $D$ 相等情况下,如果本像素邻域无像素点火,则调制输出负向波形归零,而如果邻域点火像素越多,则调制输出的负向波形幅度就越大,也即已调信号  $F_{ij}(n)(a + DL_{0ij}(n))$ 的波形在  $Y$ 轴负向变化的幅度与邻域点火像素数目增加的趋势相一致,这一现象恰恰为参数  $a$ 和  $D$ 的设定提供参考依据.如图 7 所示为  $a = D$ 取不同值时,邻域像素点火状态对调幅输出的影响.由图 7(a)、(c)可见,当邻域无像素点火时,调幅系统无负轴波形输出,即可表示为本神经元不被捕

获,其点火状态取决于自身的灰度值大小;由图 7(b)、(d)可见,当邻域有像素点火时,调幅系统负轴有波形输出,即本神经元被捕获,捕获的程度取决于邻域像素的点火状态,邻域点火的像素越多,负轴波形越大,被捕获的概率就越大.

另外还发现,当  $a$ 值不同时,邻域像素同样的点火情况下,对本神经元的捕获程度不同. $a$ 越小负轴波形的变化比例越大,即捕获跨度越大,脉冲发放的速度越快、越不平滑.因此,为获得较精准的图像处理效果,应选择较大的直流分量  $a$ .基于以上分析,可将 PCNN 模型改进为式(22)~(25)所示:

$$F_{ij}(n) = S_{ij} \quad (22)$$

$$U_{ij}(n) = F_{ij}(n)[D + D \sum W_{ijkl} Y_{ijkl}(n-1)] \quad (23)$$

$$E_{ij}(n) = e^{-a_n} E_{ij}(n-1) + V_E Y_{ij}(n-1) \quad (24)$$

$$Y_{ij}(n) = \varepsilon [U_{ij}(n) - E_{ij}(n)] \quad (25)$$




图7  $a=D$ 时邻域像素点火状态对调幅输出的影响

根据 3.2.1 中对模型数学耦合特性消除分析的讨论,并结合  $D$  的取值对改进 PCNN 模型特性的影响分析,同时,这里用  $D$  值完成弱耦合连接特性的约束,则网络中的各参数可设置为:

$$\begin{cases} a_E = 0.0001, & V_E = S_{\max} \\ W = \begin{bmatrix} \frac{0.5}{D} & \frac{1}{D} & \frac{0.5}{D} \\ \frac{1}{D} & 1 & \frac{1}{D} \\ \frac{0.5}{D} & \frac{1}{D} & \frac{0.5}{D} \end{bmatrix} \end{cases}$$

这里要注意直流分量  $a$  的大小是相对于被调制信号  $F_{ij}(n)$  而言的.在改进模型中为保障脉冲发放的精细性和时效性,应根据像素灰度值选择相对较大的  $D$  值.如果  $D$  值对于图像最大灰度值而言是一个较大的值时,那么对于其他灰度值也都是较大的值,因此取  $D = kS_{\max}$ ,其中,  $k$  决定了直流分量  $D$  大于被调制信号  $F_{ij}(n)$  的程度,通常取经验值 25 即可满足大部分图像.

### 4 实验仿真及图像分割算法

不同  $D$  值下的网络迭代输出的时间序列  $G(n)$ <sup>[17]</sup> (点火像素的个数)如图 8 所示.由图 8(a)可见,当参数  $a_E$  和  $V_E$  取值不能消除模型的数学耦合特性时,网络的脉冲发放特性就被模型本身的数学耦合特性所掩盖;由图 8(b)可见,当网络本身的数学耦合特性被消除时,


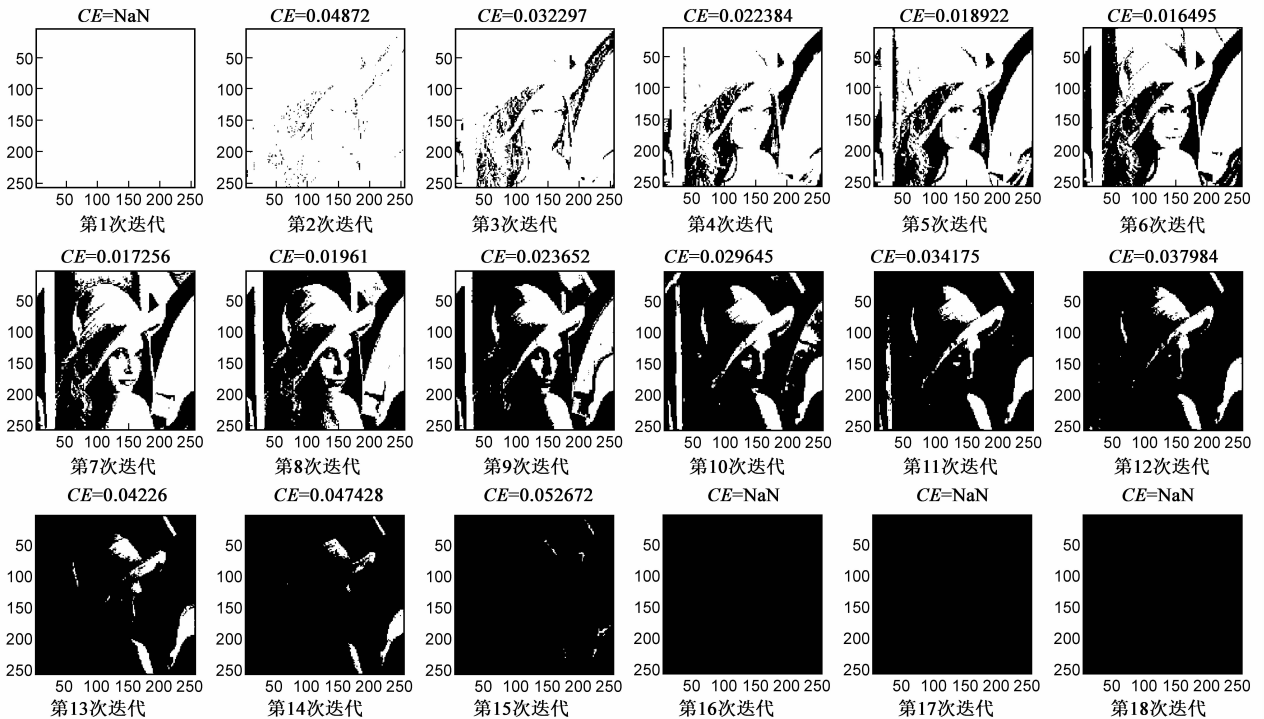


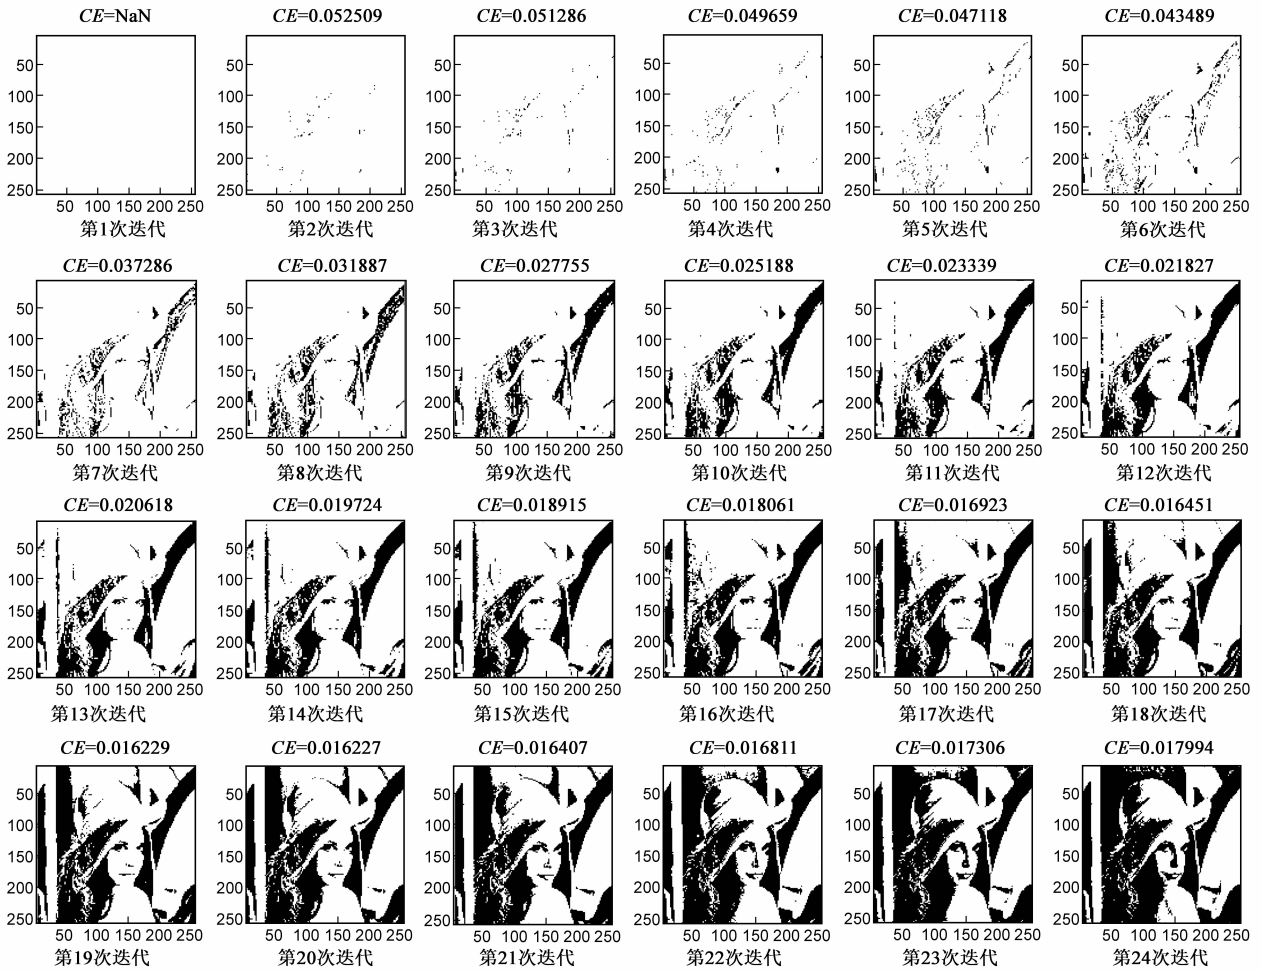
图 8 不同  $D$  值下 PCNN 迭代图像的时间序列

不同的  $D$  值决定了网络不同的捕获(灭火)能力,  $D$  值越小曲线的斜率越大捕获能力越强发放越快,反之则越弱迭代过程越精细,随着迭代的进行图像全部像素将被捕获(灭火).以 Lena 图像为例,按照改进模型取不同  $D$  值对图像进行迭代处理,输出效果如图 9 所示.图 9(a)中第 6 次迭代和图 9(b)中第 20 次迭代为最小交叉熵输出<sup>[18]</sup>,分割效果如图 10 所示.很显然较大  $D$  值的分割结果表现了更清晰的目标细节,可见,当图 9(b)所示的曲线斜率越小时,对应的图像分割过程就越精细,越能得到最佳的分割结果.

综合以上分析,将改进模型用于图像分割时,算法流程可归纳如下:(1)将原始图像做归一化处理,并求出最大灰度值  $S_{\max}$ ; (2)设定参数  $a_E = 0.0001$ 、 $V_E = S_{\max}$ 、 $D = kS_{\max}$ ; (3)设定一个较大的迭代次数  $N$ ,并启动 PCNN; (4)计算每一次迭代输出的交叉熵,当本次迭代



(a)  $D=5$



(b)  $D=5$   
图9 不同 $D$ 值下改进PCNN模型的迭代输出( $CE$ 为交叉熵)



(a) Lena原图

(b)  $D=5$ 时的最佳分割

(c)  $D=25$ 时的最佳分割

图10 不同 $D$ 值下的分割效果

的交叉熵大于前一次迭代的交叉熵时停止 PCNN 迭代。

表 1 算法性能

	Lena	Cameramen	Blood
迭代次数	19	16	20
运行时间(s)	1.9370	1.5940	2.1710
最小交叉熵	0.0162	0.0105	0.0064

为测试本算法的可靠性,做了大量的实验,这里选用 3 幅 8bit 的原始灰度图像作为实验图像,在主频 2.0GHz(双核)、内存 1G 的计算机上使用 MATLAB 7.0 平台对上述算法进行计算机仿真,以 PCNN 网络迭代的

次数、算法运行时间为标准评价本算法的时效性能,结果如表 1 所示。

## 5 结论

本文从 PCNN 模型的迭代方程出发,对耦合连接和无耦合连接两种状态下的 PCNN 数学模型进行了点火机理分析,给出了神经元的理论点火时刻及其修正公式,揭示出 PCNN 网络神经元的点火状态受到了三个因素的影响:(1)是模型本身的数学耦合特性;(2)是模型数学耦合特性的周期重叠;(3)是网络自身的同步脉冲

发放特性.同时,对模型数学耦合特性的消除进行了分析,完成了简化 PCNN 参数的自适应设定,给出了更能体现神经网络生物学特性的 PCNN 改进模型,并将其用于 Lena 等图像的分割处理中,取得了比传统模型更好的效果.为进一步提升改进模型的图像处理效果,在以后的工作中应从图像的特性出发,进行脉冲发放速度和参数  $D$  之间关系的进一步研究,完成能使网络性能更好的  $D$  值自适应确定.

## 参考文献

- [1] Eckhorn R, Reitboeck H J, Arndt M, Dicke P. Feature linking via synchronization among distributed assemblies: simulation of results from cat visual cortex[J]. *Neural Computation*, 1990, 2(3):293 – 307.
- [2] Johnson J L, Padgett M L. PCNN models and applications[J]. *IEEE Trans on Neural Networks*, 1999, 10(3):480 – 498.
- [3] Broussard R P, Rogers S K, Oxley M E, et al. Physiologically motivated image fusion for object detection using a pulse coupled neural network [J]. *IEEE Trans on Neural Networks*, 1999, 10(3):554 – 563.
- [4] Ranganath H S, Kuntimad G. Object detection using pulse coupled neural networks [J]. *IEEE Trans on Neural Networks*, 1999, 10(3):615 – 620.
- [5] 赵峙江,赵春晖,张志宏.一种新的 PCNN 模型参数估算方法[J]. *电子学报*, 2007, 35(5):996 – 1000.  
ZHAO Zhi-jiang, ZHAO Chun-hui, ZHANG Zhi-hong. A new method of PCNN's parameter's optimization [J]. *Acta Electronica Sinica*, 2007, 35(5):996 – 1000. (in Chinese)
- [6] Kuntimad G, Ranganath H S. Perfect image segmentation using pulse coupled neural networks [J]. *IEEE Trans Neural Networks*, 1999, 10(3):591 – 598.
- [7] 于江波,陈后金,王巍,等.脉冲耦合神经网络在图像处理中的参数确定[J]. *电子学报*, 2008, 36(1):81 – 85.  
YU Jiang-bo, CHEN Hou-jin, WANG Wei, LI Ju-peng. Parameter determination of pulse coupled neural network in image processing [J]. *Acta Electronica Sinica*, 2008, 36(1):81 – 85. (in Chinese)
- [8] Min Li, Wei Cai, Zheng Tan. Adaptive parameters determination method of pulse coupled neural network based on water valley area [A]. *Neural Information Processing pt. 2* [C]. Hong Kong, 2006:713 – 720.
- [9] 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.  
MA Yi-de, DAI Ruo-lan, LI Lian. Automated image segmentation using pulse coupled neural networks and image entropy [J]. *Journal of China Institute of Communications*, 2002, 23(1):46 – 51. (in Chinese)
- [10] 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[J]. *系统仿真学报*, 2006, 18(3):722 – 725.  
MA Yi-de, QI Chun-liang. Study of automated PCNN system based on genetic algorithm [J]. *Journal of System Simulation*, 2006, 18(3):722 – 725. (in Chinese)
- [11] Yuli Chen, Sung-Kee Park, Yide Ma. A new automatic parameter setting method of a simplified PCNN for image segmentation [J]. *IEEE Transactions on Neural Networks*, 2011, 22(6):880 – 892.
- [12] 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.  
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. (in Chinese)
- [13] Shuo Wei, Qu Hong, Mengshu Hou. Automatic image segmentation based on PCNN with adaptive threshold time constant [J]. *Neurocomputing*, 2011, 74(9):1485 – 1491.
- [14] Berg H, Olsson R, Lindblad T, Chilo J. Automatic design of pulse coupled neurons for image segmentation [J]. *Neurocomputing*, 2008, 71(10–12):1980 – 1993.
- [15] Eckhorn R, Frien A, Bauer R, et al. High frequency oscillations in primary visual cortex of awake monkey [J]. *NeuroReport*, 1993, 4(3):243 – 246.
- [16] 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: Aca2 demicpp, 1998. 1 – 56.
- [17] Johnson J L. Pulse-coupled neural nets: translation, rotation, scale and intensity signal invariances for image [J]. *Applied Optics*, 1994, 33(26):6239 – 6253.
- [18] MA Yi-de, LIU Qing, Qian Zhi-bai. Automated image segmentation using improved PCNN model based on cross-entropy [A]. *Proceedings of 2004 International Symposium on Intelligent Multimedia, Video and Speech Processing* [C]. Hong Kong, 2004. 743 – 746.

## 作者简介

邓翔宇 男,副教授,兰州大学无线电物理专业博士研究生,主要研究方向为数字图像处理和通信工程. E-mail: dengxy000@126.com



马义德(通讯作者) 男,博士,兰州大学教授,博士生导师.长期从事数字图像处理与嵌入式系统、智能信息处理与软计算理论等方面的研究,在相关领域发表学术论文 80 余篇,SCI、EI 索引 20 余篇,主持完成国家、省部级基金及科技计划项目 7 项,获教育部新世纪优秀人才计划支持,宝钢优秀教师奖等多项奖励.  
E-mail: ydma01@126.com