

# 基于SPCNN与改进型矢量CV模型的乳腺X射线 肿块分割方法\*

韩振中<sup>1)†</sup> 陈后金<sup>1)</sup> 李艳凤<sup>1)</sup> 李居朋<sup>1)</sup> 姚畅<sup>1)</sup> 程琳<sup>2)</sup>

1)(北京交通大学电子信息工程学院, 北京 100044)

2)(北京大学人民医院乳腺中心, 北京 100044)

(2013年11月14日收到; 2013年12月19日收到修改稿)

作为乳腺癌计算机辅助诊断系统的重要环节, 肿块分割的结果严重影响到肿块良恶性的判别. 针对现有方法的不足, 本文提出了一种基于简化型脉冲耦合神经网络和改进型矢量无边缘活动轮廓模型的乳腺X射线肿块分割方法. 首先, 通过数学分析计算SPCNN的相关参数与终止条件, 进而利用SPCNN模型分割出肿块的初始轮廓. 然后, 针对传统CV模型的不足, 进行相应的修正得到改进型矢量CV模型. 最后, 结合SPCNN分割出的初始轮廓, 利用改进型的矢量CV模型处理ROI分割出肿块. 采用北京大学人民医院乳腺中心提供的临床图像以及DDSM数据库的图像进行对比实验, 实验结果表明, 本文方法相比较现有方法分割结果更为准确, 尤其是在处理东方女性致密性案例时, 本文方法更有优势.

**关键词:** 计算机辅助诊断, 肿块分割, 简化型脉冲耦合神经网络, 矢量无边缘活动轮廓模型

**PACS:** 87.57.N-, 42.30.Va, 07.05.Pj

**DOI:** 10.7498/aps.63.078703

## 1 引言

近年来, 乳腺癌发病率日益升高, 已成为当今妇女恶性肿瘤死亡的首位原因<sup>[1,2]</sup>. 科学证据表明, 在癌症治疗中, 发现越早成功治愈概率越大<sup>[3,8]</sup>. 目前, 应用于乳腺癌检测的方法有: X射线影像技术、计算机断层摄影术、光声成像、核磁共振成像、微波成像等技术<sup>[4-8]</sup>. 其中, 乳腺钼靶X射线摄影术是一种非常有效的乳腺成像技术, 联合先进的信息处理技术可辅助医师发现乳腺癌早期出现的肿块<sup>[8]</sup>.

乳腺癌最为显著的特征是肿块征, 肿块密度一般较高(相比于乳晕), 中心区域比正常组织高出约5%—20%, 而且肿块区域的亮度随远离中心不断减小, 因此多以亮斑形式出现在X射线图像中. 根据肿块的形态和边缘特点可有多种不同的表现: 毛

刺肿块、分叶肿块、透亮环肿块、钙化肿块、模糊肿块、花瓣形肿块和圆形肿块(以单项诊断率降序排列)<sup>[9]</sup>.

肿块的生长方式与生物学特征可以由边缘特征反映, 一般来说, 形状规则的肿块是良性的, 相反的恶性肿块往往拥有不规则的边缘. 因此, 肿块分割算法的准确性严重影响肿块良恶性判断.

目前, 已有很多学者对肿块分割进行了研究. 这些方法大致可以分为基于像素点的方法, 如Kupinski等提出的基于区域增长的肿块分割方法<sup>[10]</sup>; 基于区域的分割方法, 如Kobatake等提出的基于滤波的肿块检测与分割方法<sup>[11]</sup>; 以及基于边缘的方法, 如曹颖等提出的基于随机游走算法的乳腺肿块分割算法<sup>[12]</sup>. 这些方法往往基于单一的灰度信息或者一些其他的特征来获取分割结果. 这些方法实现起来比较简便, 但在处理复杂边缘肿块

\* 国家自然科学基金(批准号: 61271305, 61201363, 60972093)、国家高等学校博士学科点专项科研基金(批准号: 20110009110001)和中央高校基本科研业务费专项资金(批准号: 2014JBM020)资助的课题.

† 通讯作者. E-mail: 08111011@bjtu.edu.cn

时, 单一的简单特征不足以准确地描述肿块, 因此很难得到满意的分割结果.

为了得到更为精确的肿块轮廓, 大多数学者进一步引入了活动轮廓模型进行肿块分割. Xu等首先通过canny边缘算子得到肿块的粗边缘, 进而利用活动轮廓模型得到较为准确的肿块边缘<sup>[13]</sup>; Yu等在结合形态学、sobel边缘检测算子等操作获得肿块初始边缘的基础上, 引入梯度矢量流的方法分割肿块<sup>[14]</sup>. 这些方法都是首先利用像素点灰度信息结合一些方法得到肿块的粗边缘, 然后再结合像素点的梯度信息, 使用水平集方法对初始分割结果进行细化. 尽管这些方法使分割结果得到了一定改进, 然而它们或多或少都还存在着一定的问题. 这些细化分割结果的方法都是基于肿块区域的边缘梯度信息, 对于模糊边缘的肿块, 边缘梯度信息不明显, 很显然使用这些方法得到结果的可信度将会大打折扣. 更为值得注意的是, 目前的方法大多都是针对西方女性乳腺X射线图像进行的研究. 东西方女性由于地理环境、种族的不同, 乳腺组织结构特性存在很大差异. 通常西方女性乳腺脂肪含量较多, 体积较大, 多为脂肪腺体型乳房, 而东方女性乳腺普遍脂肪含量较少, 体积较小, 多为致密腺体型乳房. 肿块在不同腺体类型的乳腺X射线图像中的分割难度也有所不同. 与脂肪型乳房相比, 致密型乳腺X射线图像的背景更复杂、对比度更低. 因此, 使用现有的方法处理东方女性乳腺X射线图像时往往出现一定的问题. 虽然, 一些方法中使用到的无边缘活动轮廓(active contour without edge, CV)模型考虑到了背景与前景的灰度分布带来的影响, 然而CV模型有它自身不可避免的缺点, 即当前景和背景区域内的分布不均匀时, CV模型中水平集内外部的特性参数并不能准确的表示图像的局部特征. 很不幸的是, 乳腺X射线图像中肿块附近的正常组织往往与肿块具有相似特征, 且这些区域内的强度分布也很不均匀. 因此, 单一的基于区域或者边缘的分割方法处理肿块往往得不到理想结果.

此外, 先前的方法大多只使用到了肿块区域的灰度信息, 而忽视了区域的高阶特征. 文献<sup>[15]</sup>指出: 除了灰度强度信息, 纹理信息与梯度变化对于肿块的识别也非常的重要. 显然, 仅仅使用单一的灰度作为特征图进行分割, 得到的结果往往不理想. 为了使得肿块的描述更加准确, 就必须综合考

虑灰度特征、纹理特征以及梯度信息.

综合以上原因, 本文提出了一种基于简化型脉冲耦合神经网络(simplify pulse coupled neural networks, SPCNN)与改进型矢量无边缘活动轮廓(active contour without edge, CV)模型的乳腺X射线肿块分割方法. 本文方法一方面通过多特征分析建立感兴趣区域(region of interest, ROI)的矢量特征图, 进而克服传统方法仅仅基于单一特征所导致的描述肿块不准确的缺点, 另一方面对于矢量CV模型进行改进, 克服了传统CV处理强度分布不均匀图像时的不足, 同时综合考虑了区域和边缘信息来分割肿块. 本文立足于东方女性乳腺特征进行算法设计与实现, 是对传统方法仅仅基于西方女性乳腺图像进行研究的补充, 符合我国对于乳腺癌CAD系统的迫切需求.

## 2 算法设计与实现

从精确分割肿块的结果出发, 本文提出了一种基于SPCNN与改进型矢量CV模型的乳腺肿块分割方法. 1) 对于肿块区域, 综合考虑灰度特征、纹理特征和梯度信息, 构造可以详细表征ROI的矢量特征图, 从而将处理彩色图像的矢量CV模型引入来处理乳腺X射线灰度图像. 2) 由于传统的矢量CV模型在处理分布不均匀图像时的不足, 借鉴RSF(region-scalable fitting)模型思想, 使用局部拟合值代替原始CV模型中的区域均值, 使得改进型CV模型可以处理内外强度分布不均匀的肿块. 3) 由于使用局部拟合值代替原始CV模型中的区域均值, 使得改进型CV模型要求初始轮廓位于目标边缘附近. 因此, 使用SPCNN模型对ROI区域进行初始分割, 为矢量CV模型提供初始的水平集. 4) 针对SPCNN模型中参数选取问题, 通过数学分析得到参数的限制条件, 同时, 将CV模型中能量泛函思想引入迭代算法中, 通过最小化能量泛函方法寻找最优的SPCNN迭代结果.

算法模型如图1所示, 首先采用偏微分方程方法(PDE)对ROI进行多层对比度增强<sup>[16]</sup>, 然后分别对增强图像进行SPCNN迭代以及多特征分析, 将优化后SPCNN迭代的最佳分割结果作为初始水平集提供给改进型矢量CV模型. 最后基于得到的多特征子图和初始水平集, 使用改进型矢量CV模型进行处理, 得到最终的分割结果.




图1 算法模型

## 2.1 SPCNN 模型

由于传统的PCNN模型在处理问题时,需要设定的参数较多,因此在保证模型功能的情况下,使用简化之后的SPCNN模型<sup>[17]</sup>.此模型可以使用如下的离散数学方程描述:

$$F_{ij}[n] = I_{ij}, \quad (1)$$

$$L_{ij}[n] = Y_{ij}[n-1] \times \mathbf{M}, \quad (2)$$

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

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

$$E_{ij}[n] = \exp(-\alpha_E)E_{ij}[n-1] + V_E Y_{ij}[n], \quad (5)$$

其中,  $F[n]$  为  $n$  时刻反馈输入;  $I$  为输入(像素灰度值);  $i, j$  为神经元下标.

$L[n]$  为  $n$  时刻连接输入,  $V_L$  为连接输入固有电势;  $\mathbf{M}$  为连接矩阵.  $U[n]$  为  $n$  时刻内部活动项;  $\beta$  为连接权值.  $E[n]$  为  $n$  时刻动态门限矩阵;  $\alpha_E$  为控制动态门限衰减常数;  $V_E$  为动态门限固有电势.  $\mathbf{Y}[n]$  为  $n$  时刻输出矩阵.

### 2.1.1 SPCNN 最佳分割结果

SPCNN模型往往采用观察输出结果的方式来选取最佳迭代次数,缺乏客观性准则,因此,本文借鉴CV模型中最小化能量泛函思想,以能量泛函最小时对应的结果作为SPCNN的最佳分割结果.定义如下能量函数:

$$En(c_1, c_2) = \lambda_1 \iint_{\Omega_1} (I - c_1)^2 dx dy$$

$$+ \lambda_2 \iint_{\Omega_2} (I - c_2)^2 dx dy, \quad (6)$$

其中,  $\Omega_1$  和  $\Omega_2$  分别为当前时刻SPCNN输出矩阵  $\mathbf{Y}[n]$  中激活和未激活像素点集合;  $c_1$  和  $c_2$  分别为当前时刻激活和未激活像素点的平均强度(灰度值)

$$\lambda_1 = \frac{\sum \mathbf{Y}[n] = 1}{N_{\text{all}}},$$

$$\lambda_2 = 1 - \lambda_1. \quad (7)$$

当分割结果中前景部分大量混入背景部分时,(6)式中右边第二项较大,反之,则会使(6)式中右边第一项较大.当且仅当SPCNN输出结果接近最佳分割结果时,(6)式右边两项能量均较小.因此,对于每一次SPCNN迭代结果,求取(6)所示能量值,选取能量最小时的迭代时刻作为最佳的迭代次数,即选取此次迭代结果作为SPCNN的最佳分割结果.

### 2.1.2 SPCNN 参数设置

SPCNN处理乳腺X射线图像时,网络规模与图像大小一致,神经元与图像像素点一一对应,选取像素点灰度值作为相应神经元的惟一外部刺激(如(1)式所示),当前神经元  $N_{ij}$  的连接输入  $L_{ij}$  仅与其邻域神经元输出相关(如(2)式所示).

由(1)–(5)式可得当前神经元点火周期  $T_{ij}$  为

$$T_{ij} = \frac{1}{\alpha_E} \ln \left( \frac{V_E}{I_{ij}} \right). \quad (8)$$

观察(8)易得神经元点火周期与其神经元对应的像素点灰度值有关,且灰度值最大的像素点对应的神

经元点火周期最小,灰度值最小的像素点对应的神经元点火周期则最大.为了使所有神经元点火次数相同,需合理设定SPCNN中的参数,使灰度值最大的神经元在灰度值最小的神经元激活周期内仅能激活一次,即必须满足如下关系:

$$U_{\max}[t_2] \leq E_{\max}[t_2], \quad (9)$$

其中,  $t_2$  表示灰度值最小神经元点火时刻.

观察(5)式可以发现门限矩阵是一个类似周期性变化的函数,每当当前神经元  $N_{ij}$  激活之后,其取值会快速的提升一个定值  $V_E$ ,之后开始再以  $\alpha_E$  为参数进行指数衰减,因此,每个神经元对应的动态门限函数可采用若干个衰减系数相同的指数函数进行合成,如下所示:

$$\begin{aligned} & E_{ij}(aT_{ij} + b) \\ &= \sum_{i=0}^a \exp\{-\alpha_E[(a-i)T_{ij} + b]\} V_E \\ &= \frac{\exp[-\alpha_E(aT_{ij} + b)] - \exp[-\alpha_E(b - T_{ij})]}{1 - \exp(\alpha_E T_{ij})} V_E, \\ & a \in N, b \in \{0, \dots, T_{ij} - 1\}, \end{aligned} \quad (10)$$

其中,  $a$  为当前神经元  $N_{ij}$  点火次数,  $b$  为最近一次点火距离当前时刻的时间,显然当前时刻  $n = aT + b$ .

当灰度值最大像素点对应的神经元在  $t_1$  时刻点火( $t_1 = aT_{\max}$ )之后,在  $t_2$  时刻( $t_2 = aT + b$ )的门限值为

$$\begin{aligned} & E_{\max}(t_2) \\ &= V_E \exp(-\alpha_E t_2) \\ & \quad \times \frac{1 - \exp[(a+1)\alpha_E T_{\max}]}{1 - \exp(\alpha_E T_{\max})}. \end{aligned} \quad (11)$$

(11)式为一个关于  $a$  的函数,即对于不同的周期内,取值是有区别的,所以分析如下情况:

$$\frac{\partial E_{\max}(t_2)}{\partial a} = \frac{V_E \exp(-\alpha_E t_2)}{1 - \exp(\alpha_E T_{\max})} (-\alpha_E T_{\max}). \quad (12)$$

将(8)式代入(12)式分母部分可得

$$\frac{\partial E_{\max}(t_2)}{\partial a} = \frac{V_E \exp(-\alpha_E t_2)}{V_E - I_{\max}} \alpha_E T_{\max}. \quad (13)$$

在保证所有神经元点火次数相同的条件下,一般  $V_E$  的取值都比  $I_{\max}$  大,所以(13)式是一个大于0的关系式,即(11)式是关于  $a$  的增函数.为使(9)式关系恒成立,需使  $E_{\max}$  取最小值的情况满足关系即可,考虑第一次激活后的情况,即令  $a = 1$ (由

于SPCNN迭代开始阶段所有神经元同时激活一次,所以  $a = 0$  时整个系统还不稳定,因此,这里选择  $a = 1$ ),可得

$$\begin{aligned} & \min[E_{\max}(t_2)] \\ &= V_E \exp(-\alpha_E t_2) [1 + \exp(\alpha_E T_{\max})], \end{aligned} \quad (14)$$

$t_2$  时刻恰为灰度值最小像素点对应神经元激活时刻( $t_2 = aT_{\min}$ ),将(8)式代入(14)式可得

$$\min[E_{\max}(t_2)] = I_{\min} \left(1 + \frac{V_E}{I_{\max}}\right). \quad (15)$$

(15)式是  $E_{\max}$  是取最小值的情况.

为使(9)式关系恒成立,必须有

$$\begin{aligned} & I_{\min} \left(1 + \frac{V_E}{I_{\max}}\right) \geq U_{\max}[t_2] \\ &= I_{\max}(1 + \beta L_{\max}[t_2]). \end{aligned} \quad (16)$$

连接系数  $\beta$  的大小反映了邻域神经元对于当前神经元的影响,  $\beta$  较大会产生大范围脉冲同步,因此,其取值一般小于1.由(2)式可知,  $L_{\max}$  的取值与邻域神经元上一时刻输出  $\mathbf{Y}$  和连接矩阵  $\mathbf{M}$  有关,连接矩阵  $\mathbf{M}$  反映了邻域神经元对当前神经元的贡献,一般使用神经元间距离(像素距离)来表示,通常取值如下:

$$\mathbf{M} = \begin{bmatrix} 0.5 & 1 & 0.5 \\ 1 & 0 & 1 \\ 0.5 & 1 & 0.5 \end{bmatrix}.$$

由于前一时刻的输出矩阵  $\mathbf{Y}$  是二值图像,  $L_{\max}$  的取值范围为  $L_{\max} \in [0, 6]$ .

若要使(16)成立,仅需满足

$$\begin{aligned} & I_{\min} \left(1 + \frac{V_E}{I_{\max}}\right) \\ & \geq I_{\max} [1 + \max(\beta L_{\max}[t_2])] \\ &= 7I_{\max}, \end{aligned} \quad (17)$$

可得

$$V_E \geq \frac{I_{\max}}{I_{\min}} (7I_{\max} - I_{\min}). \quad (18)$$

连接系数  $\beta$  大小反映了邻域神经元对于当前神经元的影响,它体现了SPCNN的俘获特性.为保证点火脉冲可以传播,即当图像中灰度值最大像素点对应神经元点火之后,可以俘获其邻域神经元  $N_{xy}$ ,要求有

$$U_{xy}[n] = I_{xy}(1 + \beta L_{xy}[n]) > E_{xy}[n]. \quad (19)$$

此时  $n = aT_{\max}$ , 当前神经元  $N_{xy}$  邻域内至少有一个灰度值最大的神经元已经激活, 因此,  $L_{xy}[n]$  的取值范围为  $L_{xy}[n] \in [0.5, 6]$ , 另一方面由于同一时刻灰度值最大的神经元也被激活 ( $N_{xy}$  与  $N_{\max}$  点火节奏保持一致), 有  $E_{xy}[n] = E_{\max}[n] < U_{\max}[n] = I_{\max}$ . 为使 (19) 式关系恒成立, 须有

$$\beta > 2 \left( \frac{I_{\max}}{I_{xy}} - 1 \right). \quad (20)$$

通过上述数学分析, 可以确定 (1)–(5) 式中除  $\alpha_E$  外所有参数的取值范围.  $\alpha_E$  为门限衰减系数, 可以调节神经元点火周期, 用以控制单位时间内神经元点火次数, 一般采用实验方法确定, 取值范围为  $\alpha_E \in [0, 1.0]$ , 本文取 0.2.

## 2.2 改进型矢量 CV 模型

文献 [15] 指出: 除了灰度强度信息, 纹理信息与梯度变化对于肿块的识别也非常重要. 仅仅使用单一的灰度作为特征图来进行分割, 得到的结果往往不理想. 为更加准确地描述肿块, 需综合考虑灰度特征、纹理特征和梯度信息.

本文使用海森矩阵的 3 个元素  $I_{xx}$ 、 $I_{xy}$  和  $I_{yy}$  来描述区域的纹理特征, 使用  $X$  方向的梯度  $g_x$ 、 $Y$  方向的梯度  $g_y$  以及梯度模值  $|\nabla g|$  来描述区域的梯度特征, 再结合图像的灰度特征, 这样便构成了一个  $7 \times M \times N$  ( $M \times N$  是 ROI 的维数) 的矢量图像来描述区域.

使用变分水平集方法, 可以得到矢量 CV 模型的能量泛函如下 [16,18]:

$$\begin{aligned} E(\bar{c}_1, \bar{c}_2, u) &= \mu \iint_{\Omega} \delta(u) |\nabla u| dx dy \\ &+ \iint_{\Omega} \sum_{i=1}^m \lambda_1^{(i)} (I^{(i)} - c_1^{(i)})^2 H(u) dx dy \\ &+ \iint_{\Omega} \sum_{i=1}^m \lambda_2^{(i)} (I^{(i)} - c_2^{(i)})^2 \\ &\times [1 - H(u)] dx dy, \end{aligned} \quad (21)$$

其中

$$\bar{c}_j = (c_j^{(1)}, c_j^{(2)}, \dots, c_j^{(m)}), j = (1, 2).$$

选择的 Heaveside 函数为

$$H_{\varepsilon}(z) = \frac{1}{2} \left( 1 + \frac{2}{\pi} \arctan \frac{z}{\varepsilon} \right).$$

最小化 (21) 式的梯度下降流为

$$\begin{aligned} \frac{\partial u}{\partial t} &= \delta_{\varepsilon} \left[ \mu \operatorname{div} \left( \frac{\nabla u}{|\nabla u|} \right) - \sum_{i=1}^m \lambda_1^{(i)} (I^{(i)} - c_1^{(i)})^2 \right. \\ &\left. + \sum_{i=1}^m \lambda_2^{(i)} (I^{(i)} - c_2^{(i)})^2 \right]. \end{aligned} \quad (22)$$

(22) 式仅仅是将传统的 CV 模型由一维扩展到  $m$  维, 其仍然存在传统 CV 模型的缺点, 当图像中前景和背景区域的分布不均匀时, CV 模型只能大致的分割出前景的轮廓, 对于边缘细节的分割并不理想. 肿块的边缘信息对于判断肿块良恶性的影响是举足轻重的, 因此, 单纯的使用矢量 CV 模型对肿块进行分割无法满足要求.

分析发现, 造成这种分割不理想的主要原因是: 当前水平集内外分布不均匀时, 区域均值  $\bar{c}_j$  不能准确地表征图像的局部特征. 本文使用图像局部拟合值  $\bar{f}_j$  替代区域均值  $\bar{c}_j$ . 局部拟合值  $\bar{f}_j$  取决于图像当前像素点的邻域, 可以很好地表征图像局部信息. 局部拟合值  $\bar{f}_j$  定义如下:

$$\begin{aligned} f_1^{(i)} &= \frac{K_{\sigma} \times [H(u)I^{(i)}]}{K_{\sigma} \times H(u)}, \\ f_2^{(i)} &= \frac{K_{\sigma} \times [(1 - H(u))I^{(i)}]}{K_{\sigma} \times [1 - H(u)]}, \end{aligned} \quad (23)$$

其中,  $K_{\sigma}$  是参数为  $\sigma$  的高斯核函数.

为使曲线演化函数更好地逼近零, 选用负指数函数作为边缘停止函数, 如下式所示:

$$g(|\nabla I|) = \exp(-a|\nabla I|), \quad (24)$$

其中  $a$  为图像边缘梯度场对曲线演化速度的控制系数.

实验与分析表明, 相比通常使用的倒数形式停止函数, 负指数函数的边界逼近效果更好. 当轮廓曲线靠近边界时, 边界的高梯度值使负指数函数迅速趋于零, 而且此处理时的高斯平滑滤波对于噪声所产生的高梯度值有一定的抑制作用. 综合 (22)–(24) 式, 得到改进型矢量 CV 模型梯度下降流为

$$\begin{aligned} \frac{\partial u}{\partial t} &= \delta_{\varepsilon} \left[ \mu \operatorname{div} \left( \frac{\nabla u}{|\nabla u|} \right) - \sum_{i=1}^m \lambda_1^{(i)} (I^{(i)} - f_1^{(i)})^2 \right. \\ &\left. + \sum_{i=1}^m \lambda_2^{(i)} (I^{(i)} - f_2^{(i)})^2 \right] g(|\nabla I|). \end{aligned} \quad (25)$$

### 3 算法测试与结果分析

#### 3.1 测试图像库

为验证文中所提方法的有效性,共选取173幅包含肿块的乳腺X射线图像ROI进行肿块分割实验,其中100幅图像由北京大学人民医院乳腺中心提供,其余73幅图像从南佛罗里达大学乳腺X射线图像(Digital Database for Screening Mammography, DDSM<sup>[19]</sup>)数据库中随机选取.北京大学人民医院乳腺中心提供的100幅图像灰度级均为16 bit,图像尺寸均为2016×2816(像素),抽取的DDSM图像灰度级均为12 bit(转换完成的图像灰度级为16 bit,但实际只有12 bit),图像尺寸不统一,约为2600×4600(像素).

#### 3.2 模型参数

模型参数的选择对于整个分割方法有着至关重要的作用.使用2.2节中的数学分析计算SPCNN参数,其他参数通过大量实验得到,如表1所示.

表1 实验参数设置

参数	$V_E$	$\beta$	$M$	$\alpha_E$
取值	9000	0.3	$\begin{bmatrix} 0.5 & 1 & 0.5 \\ 1 & 0 & 1 \\ 0.5 & 1 & 0.5 \end{bmatrix}$	0.2
参数	$\epsilon$	$\mu$	CV时间步长 $\tau$	高斯核 $\sigma$
取值	1.0	250	0.1	1

由(18)式计算得 $\min(V_E) = 8848.5$ (使用PDE方法对ROI进行多层对比度拉伸之后,ROI中灰度级被拉伸到0—255,理论上代入(18)式计算得出 $V_E = \infty$ ,但是考虑到实际应用中,SPCNN迭代分割得到最佳结果时,灰度值较小的背景像素对应的神经元并没有激活,因此,并不用所有神经元都保证点火次数相同,这里选取 $I_{\min} = 50$ ,计算得 $\min(V_E) = 8848.5$ ,因此,实验中选取 $V_E = 9000$ ).

由(20)式计算得 $\beta$ 必须大于0.22(由实验与分析可知,当 $\beta$ 取定之后,随着点火神经元的灰度值逐渐减小,被其俘获的神经元的灰度值范围也越来越小,因此,选取的 $I_{xy}$ 应该尽量大一点,以保证低灰度的神经元可以俘获的神经元的灰度值范围足够,实验中选取 $I_{xy} = 230$ ),因此,实验中选取 $\beta = 0.3$ .

#### 3.3 实验结果与分析

为定量评价算法分割的质量,常用的方法是将算法分割结果与该领域专家手动分割结果进行像素级别比较.为此,特别邀请3名北京大学人民医院的专业医师组成专家组对图片进行手动分割,并将此手动分割结果作为实验的标准.本文使用误分率(misclassification rate, MR)作为实验结果的评价准则.MR的定义如下式所示:

$$MR = \frac{\text{Area}\{S_A \cup S_B\} - \text{Area}\{S_A \cap S_B\}}{\text{Area}\{S_A\}}, \quad (26)$$

其中, $S_A$ 为专家标注的肿块区域, $S_B$ 为算法分割出的肿块区域.

显然,MR的大小可以反映出分割结果的优劣,MR值越小,分割结果则越优异,当MR=0时,表明算法分割结果与手工分割结果一致(理论情况下).

##### 3.3.1 良恶性肿块实验与分析

肿块可分为良性与恶性两种,往往良性肿块具有较为规则的形状,且边界也比较清晰光滑,相反的恶性肿块往往拥有不规则且模糊的边缘.因此,评价算法的优劣程度必须同时对良性与恶性肿块进行(由于良性肿块的边界较为清晰,往往相比较恶性肿块,良性肿块的分割也比较容易,分割结果也较好).

图2和图3分别是本文方法与传统CV算法对于良性和恶性肿块的分割结果.其中迭代次数均为500次(对于图3(b)将原CV的迭代次数增加到1000次,仍然没有将肿块下半部分的毛刺分割出来).图2为两个良性肿块的分割结果对比:图2(a)肿块除左边边界外,总体上较为清晰,分割起来也较为容易,因此两种方法得到的结果也较为相似(本文方法的MR值较低),图2(b)ROI整体对比度较小,肿块边缘模糊程度较大,内外部分布不均匀,本文方法相比较原始CV的结果更为接近医师标注结果.图3为两个恶性肿块的分割结果对比:图3(a)肿块边缘较为清晰,边缘处波动较大,灰度分布不均匀,本文方法分割结果明显优于原CV模型.图3(b)肿块形状极为不规则,拥有放射状毛刺,虽然两种方法的分割结果与医师标注结果之间都存在一定的差异,但是本文方法的分割结果也明显较优异(医师标注结果为纯手工勾画,存在一定的抖动和主观偏差,尤其是对于恶性的形状不规则肿块更为明显,所以恶性肿块的分割结果与医师标注结果的差异也较良性肿块较大).此外,对于

图3(b)所示的恶性肿瘤,使用原始CV分割的肿块形状较为规则,若以此作为肿块分类的判断依据,

很有可能导致误判,将此肿块分类为良性,本文方法则不会出现这样的问题.

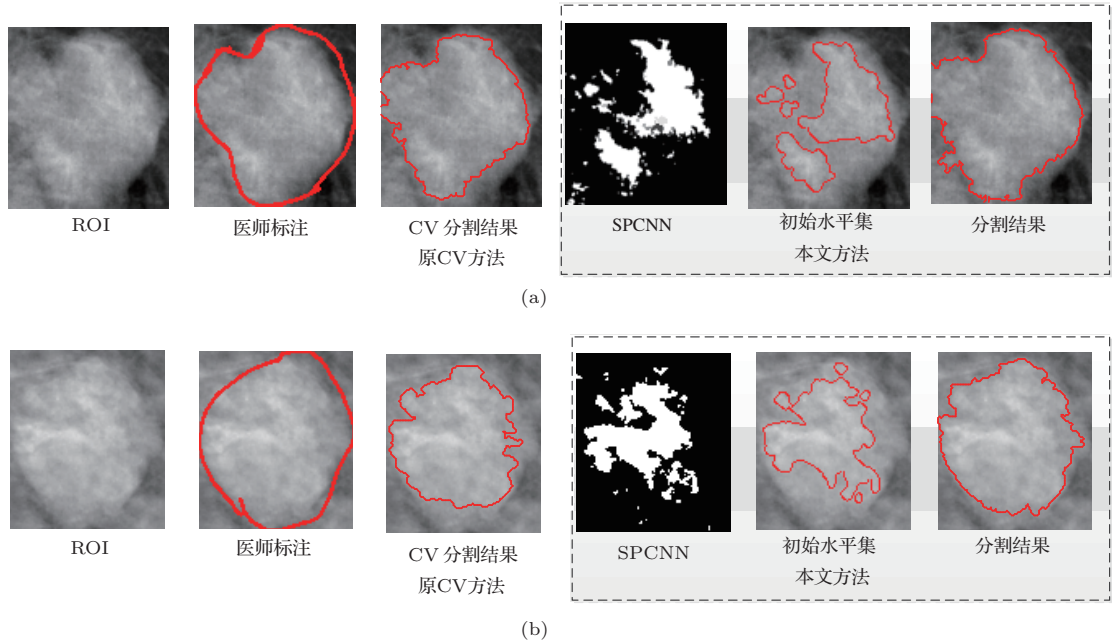


图2 良性肿块分割结果对照

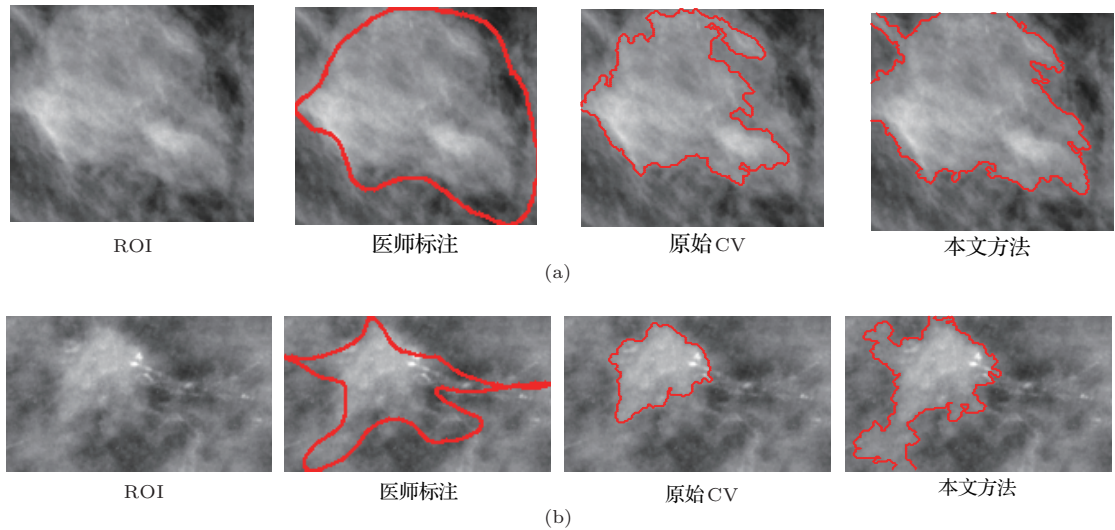


图3 恶性肿瘤分割结果对照

表2 不同方法实验结果(良恶性)

	良性	恶性	整体
CV模型	0.2732	0.4346	0.3668
本文方法	0.2161	0.3527	0.2953

对于北京大学人民医院乳腺中心提供的100幅包含肿块的乳腺X射线图像进行统计,得到原CV模型与本文方法关于MR的统计结果如

表2所示.

良性肿块边缘一般都较为清晰,且形状都较为规则,一方面减小了分割方法错误划分的概率,另一方面也减弱了医师勾画时的主观影响,因此良性肿块分割结果的平均MR较小.在进行测试的100幅肿块ROI图像中良性肿块共有42幅,统计得到CV模型方法分割结果的平均MR值为0.2732,本文方法分割结果的平均MR值为0.2161.对于

剩下的58幅恶性肿块ROI, 本文方法分割结果的平均MR值为0.3527, 而CV模型的平均MR值为0.4346. 对于整体用于测试的100幅肿块ROI, 本文方法分割结果的平均MR值为0.2953, 相对于CV模型的0.3668, 平均MR值降低了19.49%.

### 3.3.2 腺体类型实验与分析

根据乳房内腺体的含量, 乳房一般可分为致密型腺体乳房和脂肪型腺体乳房. 脂肪型乳房内脂肪含量较多, X射线成像时图像对比度较大, 因此这类乳房中的肿块也较为明显清晰, 相对来说易于分割, 相对的致密型乳房中肿块往往难以分割. 因此, 本节基于北京大学人民医院乳腺中心提供的乳腺X射线图像, 从腺体类型角度进行对比实验.

图4所示为本文方法与原CV模型对于不同腺体类型肿块的分割结果, 迭代次数均为1000次. 图4(a)是一般的脂肪腺体型乳腺肿块分割结果, 由于脂肪腺体型乳房内脂肪含量较高, 包含肿块的ROI对比度一般相对比较大. 然而由于图中恶性肿块内外灰度分布不均匀且拥有长毛刺, 导致原CV模型很难分割出肿块上方的毛刺, 本文方法通过详细的ROI特征描述等处理使得此问题得以解决. 图4(b)所示为一个致密腺体型案例的分割情况, 明显可见本文方法分割结果要优于CV方法.

对于北京大学人民医院乳腺中心提供的100幅包含肿块的乳腺X射线图像进行统计, 得到原CV模型与本文方法关于MR的统计结果如表3所示.




图4 不同腺体类型肿块分割结果对照

表3 不同方法实验结果(腺体类型)

	脂肪型腺体	致密型腺体	整体
CV模型	0.2347	0.4443	0.3668
本文方法	0.2051	0.3483	0.2953

脂肪腺体型乳腺图像对比度较大, 分割较致密型乳腺图像容易. 在进行测试的100幅肿块ROI图像中脂肪型腺体肿块共有37幅, 统计得到CV模型方法分割结果平均MR值为0.2347, 本文方法分割结果平均MR值为0.2051. 对于剩下的63幅致密型腺体肿块, 本文方法分割结果平均MR值为

0.3483, 而CV模型平均MR值为0.4443. 对整体用于测试的100幅肿块ROI, 本文方法分割结果平均MR值为0.2953, 明显优于CV模型的0.3668.

CV模型使用区域整体平均值描述水平集内外特性. 然而, 当肿块内外分布不均匀且灰度波动较大时, 肿块内外区域的灰度均值相对比较接近(致密型乳腺图像较易出现此情况), CV模型很难寻找到较优的值将内外区域分开.

### 3.3.3 东西方女性乳腺图像实验与分析

根据北京大学人民医院乳腺中心专业医师提供的资料显示: 由于地理环境、种族的不同, 东西方



女性乳腺组织结构特性存在很大的差异. 而且, 之前的方法大多基于西方数据库 (如南佛罗里达州立大学的 DDSM 数据库和欧洲影像学会的 MIAS 数据库 [19,20]), 这类乳腺图像大多以脂肪型乳腺图像为主, 而东方女性乳房中腺体含量一般较高, 多为致密型乳腺. 因此, 本节基于北京大学人民医院乳腺中心提供的 100 幅乳腺 X 射线图像以及从南佛罗里达州 DDSM 数据库中随机选取的 73 幅, 从数据库角度进行对比实验.

对于乳腺中心提供的 100 幅东方女性乳腺图像以及从 DDSM 数据库中随机抽取的 73 幅西方女性乳腺图像进行统计 (乳腺中心提供图像的良恶性比例约为 4:6, 由于肿块良恶性对于分割结果以及评价准则有一定影响, 为保证此项对比更具说服力, 选取的 DDSM 图像中良恶性肿瘤也基本保持这个比率), 得到原 CV 模型与本文方法关于 MR 的统计结果如表 4 所示.

表 4 不同方法实验结果 (数据库)

	乳腺中心	DDSM
CV 模型	0.3668	0.3187
本文方法	0.2953	0.2634

对乳腺中心提供的 100 幅包含肿块的东方女性乳腺 X 射线图像, 统计得到 CV 模型方法分割结果平均 MR 值为 0.3668, 而本文方法分割结果平均 MR 值为 0.2953, 即平均 MR 值降低了 19.49%; 对 DDSM 数据库中抽取的 73 幅包含肿块的西方女性乳腺 X 射线图像, 统计得到 CV 模型方法分割结果平均 MR 值为 0.3187, 而本文方法分割结果平均 MR 值为 0.2634, 即平均 MR 值降低了 17.35%.

通常情况下, 西方女性乳腺脂肪含量较多, 体积较大, 多为脂肪腺体型乳房, 而东方女性乳腺普遍脂肪含量较少, 体积较小, 多为致密腺体型乳房. 正如 3.3.2 节中讨论的结果: 脂肪腺体型乳腺图像对比度较大, 分割较致密型乳腺图像容易. 因此, 对于以对比度较高的脂肪型乳房为主的西方女性乳腺 X 射线图像, 两种方法分割结果之间的差别不如在处理以对比度较低的致密型乳房为主的东方女性乳腺 X 射线图像时明显.

### 3.3.4 毛刺肿块实验与分析

根据临床病理分析, 使用毛刺征作为独立因素进行单因素分析时, 发现有毛刺肿块相对无毛刺肿块恶性的可能性至少提高了 8 倍之多 [9,21]. 因此,

具有毛刺的肿块大多为恶性肿瘤, 有必要对其分析实验, 对比不同方法对毛刺的分割结果.

对于 46 幅毛刺肿块 (选自北京大学人民医院提供的 100 幅图像) 分割结果的 MR 值进行分析, 统计结果如表 5 所示.

表 5 不同方法实验结果 (毛刺肿块)

	毛刺肿块
CV 模型	0.4904
本文方法	0.3879

通过统计计算得出, CV 模型方法对于 46 幅毛刺肿块分割结果的平均 MR 值为 0.4904, 明显高于本文方法的 0.3879, 即本文方法较 CV 方法平均 MR 值降低了 20.90%.

对于拥有长毛刺的肿块, 即使毛刺部分灰度明显高于背景区域, 但 CV 模型使用的能量泛函中第一个约束项对于边界弧长的限定, 使得 CV 分割时往往会抛弃这一部分毛刺, 因为包含细长毛刺导致边界弧长能量项的增量远远大于舍弃它造成区域能量项的增量, 毛刺越细长这种情况就越明显. 在灰度图上, 引入和舍弃毛刺对于区域能量的影响也许不是很大, 但是在梯度图或者纹理图上, 这种舍弃所造成的整体能量增量要明显很多. 所以, 即使本文方法所使用的能量泛函中仍然有弧长能量约束项, 但是本文方法分割时所使用的特征图是综合了灰度信息、纹理信息以及梯度信息的矢量图, 分割毛刺肿块时也不会出现丢失毛刺情况.

## 4 结 论

本文从精确分割肿块结果出发, 提出了一种基于 SPCNN 与改进型矢量 CV 模型的乳腺肿块分割方法. 针对现有的基于单一灰度信息的乳腺 X 射线肿块分割方法在处理对比度较低图像 (大部分东方女性的乳腺呈现此特点) 时的不足, 引入综合灰度特征、纹理特征以及梯度信息的矢量 CV 模型处理, 克服了现有方法描述肿块不全面的缺点; 借鉴 RSF 模型思想改进传统矢量 CV 模型, 克服了传统 CV 模型固有的不足; 同时对 SPCNN 模型进行分析, 推导其部分参数的取值规则, 并借鉴 CV 模型中最小化能量泛函的思想, 得到 SPCNN 最佳分割结果, 解决改进型矢量 CV 模型对初始水平集的要求. 通过比较实验, 验证了本文方法相比较现有方法分割结果更为准确, 尤其是在处理较低对比度图

像(如大多数东方女性拥有的致密型乳腺)时,本文方法更有优势.

在本文的后续研究为:更进一步地分析肿块区域特征,建立更详细的肿块区域特征描述图,另一方面,合理地设定各个特征子图的权值(本文设定各个特征子图的权值相同),使分割结果更为精确.

此次研究工作是基于北京大学人民医院乳腺中心提供的乳腺X射线图像和南佛罗里达州立大学的DDSM数据库而展开,非常感谢乳腺中心以及南佛罗里达州立大学提供相关研究支持,同时对于乳腺中心给予本文相关指导与帮助的医师表示由衷的谢意.

### 参考文献

- [1] American Cancer Society, Breast Cancer Facts, Figures 2009-2010. <http://www.cancer.org/acs/groups/content/@nho/documents/document/f861009final90809pdf.pdf>. [2013.11.14]
- [2] Cancer Research U K, Breast Cancer Mortality Statistics. <http://info.cancerresearchuk.org/cancerstats/types/breast/mortality/index.htm>. [2013.11.14]
- [3] National Cancer Institute. SEER stat fact sheets: breast. <http://www.cancer.gov/cancertopics/types/breast>. [2013.11.14]
- [4] Xiang L Z, Xing D, Guo H, Yang S H 2009 *Acta Phys. Sin.* **58** 4610 (in Chinese) [向良忠, 邢达, 郭华, 杨思华 2009 物理学报 **58** 4610]
- [5] Xu X H, Li H 2008 *Acta Phys. Sin.* **57** 4623 (in Chinese) [徐晓辉, 李晖 2008 物理学报 **57** 4623]
- [6] Xiao X, Xu L, Liu B Y 2013 *Acta Phys. Sin.* **62** 044105 (in Chinese) [肖夏, 徐立, 刘冰雨 2013 物理学报 **62** 044105]
- [7] Liu G D, Zhang Y R 2011 *Acta Phys. Sin.* **60** 074303 (in Chinese) [刘广东, 张业荣 2011 物理学报 **60** 074303]
- [8] Yao C, Chen H J, Yang Y Y, Li Y F, Han Z Z, Zhang S J 2013 *Acta Phys. Sin.* **62** 088702 (in Chinese) [姚畅, 陈后金, Yang Yong-Yi, 李艳凤, 韩振中, 张圣君 2013 物理学报 **62** 088702]
- [9] Liu T S 2004 *Guangxi Medical Journal* **26** 1595 (in Chinese) [刘惕生 2004 广西医学 **26** 1595]
- [10] Kupinski M A, Giger M L 1998 *IEEE Trans. Med. Imag.* **17** 510
- [11] Kobatake H, Murakami M, Takeo H, Nawano S 1999 *IEEE Trans. Med. Imag.* **18** 369
- [12] Cao Y, Hao X, Zhu X E, Xia S R 2011 *Journal of Zhejiang University (Engineering Science)* **45** 1753 (in Chinese) [曹颖, 郝欣, 朱晓恩, 夏顺仁 浙江大学学报(工学版) **45** 1753]
- [13] Xu W D, Xia S R, Xiao M, Duan H L 2005 *Proceedings of the 27th Annual Conference on Medicine and Biology*. Shanghai, China September 1-4, 2005 p2543
- [14] Yu S S, Tsai C Y, Liu C C 2010 *Proceedings of 4th International Conference on New Trends in Information Science and Service Science (NISS)*. Gyeongju, South Korea May 11-13, 2010 p715
- [15] Wang Y, Tao D C, Gao X B, Li X L, Wang B 2011 *Pattern Recognition* **44** 1903
- [16] Wang D K, Hou Y Q, Peng J Y 2008 *Image processing using partial differential equations* (Beijing: Science Press) p103. (in Chinese) [王大凯, 侯榆青, 彭进业 2008 图像处理的偏微分方程方法(北京:科学出版社)第103页]
- [17] Ma Y D, Li L, Wang Z B 2008 *Pulse Coupled Neural Network and Digital Image Processing*(Beijing: Science Press) p44 (in Chinese) [马义德, 李廉, 王兆滨 脉冲耦合神经网络与数字图像处理(北京:科学出版社)第44页]
- [18] Hou K, Bao S L, Ma J F, Chen C 2011 *Chin. Phys. B* **20** 028701
- [19] University of South Florida. Digital database for screening mammography. <http://marathon.csee.usf.edu/Mammography/Database.html>. [2013.11.14]
- [20] Suckling J, Boggis C R M, Hutt I. Mammographic image analysis society (MIAS) database. <http://peipa.essex.ac.uk/ipa/pix/mias>. [2013.11.14]
- [21] Huang G, Tai Y C, Fang Q 2011 *Jilin Medical Journal* **32** 6979 (in Chinese) [黄贵, 邵亦成, 方琪 2011 吉林医学 **32** 6979]

# Mass segmentation in mammogram based on SPCNN and improved vector-CV\*

Han Zhen-Zhong<sup>1)†</sup> Chen Hou-Jin<sup>1)</sup> Li Yan-Feng<sup>1)</sup> Li Ju-Peng<sup>1)</sup>  
Yao Chang<sup>1)</sup> Cheng Lin<sup>2)</sup>

1) (*School of Electronics and Information Engineering, Beijing Jiaotong University, Beijing 100044, China*)

2) (*Center of Breast Disease, Peking University People's Hospital, Beijing 100044, China*)

( Received 14 November 2013; revised manuscript received 19 December 2013 )

## Abstract

Mass segmentation plays an important role in computer-aided diagnosis (CAD) system. The segmentation result seriously affects classifying mass as benign and malignant. By combining the simplified pulse coupled neural network (SPCNN) and the improved vector active contour without edge (vector-CV), a novel method of mass segmentation in mammogram is proposed in this paper. First, the parameters and termination conditions of SPCNN are obtained through mathematical analysis and the initial contour is segmented by SPCNN. Then, the vector CV model is accordingly modified to overcome the shortcomings of traditional CV model. Finally, combined with the initial contour, the improved vector-CV is used to segment the mass contour. The experiments implemented on the public digital database for screening mammography (DDSM) and the clinical images which are provided by the Center of Breast Disease of Peking University People's Hospital indicate that the proposed method is better than the existing methods, especially when dealing with the dense breasts of Oriental female.

**Keywords:** CAD, mass segmentation, SPCNN, vector-CV

**PACS:** 87.57.N-, 42.30.Va, 07.05.Pj

**DOI:** [10.7498/aps.63.078703](https://doi.org/10.7498/aps.63.078703)

---

\* Project supported by the National Natural Science Foundation of China (Grant Nos. 661271305, 61201363, 60972093), the Specialized Research Fund for the Doctoral Program of Higher Education of China (Grant No. 20110009110001), and the Fundamental Research Funds for the Central Universities (Grant No. 2014JBM020).

† Corresponding author. E-mail: [08111011@bjtu.edu.cn](mailto:08111011@bjtu.edu.cn)