

## 基于标记脉冲耦合神经网络的乳腺肿块分层检测方法

韩振中<sup>①</sup> 陈后金<sup>\*①</sup> 李居朋<sup>①</sup> 姚畅<sup>①</sup> 程琳<sup>②</sup>

<sup>①</sup>(北京交通大学电子信息工程学院 北京 100044)

<sup>②</sup>(北京大学人民医院乳腺中心 北京 100044)

**摘要:** 乳腺X线图像中的肿块检测是乳腺癌早期诊断的重要手段。该文提出了一种新的肿块检测方法。将脉冲耦合神经网络(Pulse Coupled Neural Networks, PCNN)与标记符相结合设计了标记PCNN图像分层方法,继而利用多同心层(Multiple Concentric Layers, MCL)模型得到可疑区域。最后,借助肿块的形态学特征剔除假阳性区域得到最终的肿块。实验结果表明,该文方法在保证假阳性率(False Positive Rate, FPR)的同时,肿块真阳性率(True Positive Rate, TPR)达到92.08%。同时针对东方女性致密型乳腺案例中检测结果明显优于MCL方法和MCA方法。

**关键词:** 乳腺X线图像; 乳腺癌早期诊断; 肿块检测; 标记脉冲耦合神经网络; 多同心层模型

**中图分类号:** TP391; R814

**文献标识码:** A

**文章编号:** 1009-5896(2013)07-1664-07

**DOI:** 10.3724/SP.J.1146.2012.01473

## Mass Detection in Mammogram Based on Marker-pulse Coupled Neural Networks

Han Zhen-zhong<sup>①</sup> Chen Hou-jin<sup>①</sup> Li Ju-peng<sup>①</sup> Yao Chang<sup>①</sup> Cheng Lin<sup>②</sup>

<sup>①</sup>(School of Electronics and Information Engineering, Beijing Jiaotong University, Beijing 100044, China)

<sup>②</sup>(Center of Breast Disease, Peking University People's Hospital, Beijing 100044, China)

**Abstract:** Mass detection in mammogram plays an important role in early breast cancer diagnosis. A novel method of mass detection in mammogram is proposed. Combined with Pulse Coupled Neural Network (PCNN) model and marker-controlled watershed method, an image slicing method based on Marker-PCNN is presented. Then the suspicious regions are extracted through the Multiple Concentric Layers (MCL) analysis. Finally, the morphological features of mass are employed to eliminate the false positive areas. The experimentation results show that the detected method is excellent and the False Positive (FP) is low. The detection correction rate reached 92.08%. Compared with the original MCL method and Morphological Component Analysis (MCA) method, the proposed method has evident advantage, especially in diagnoses of dense breast cancer.

**Key words:** Mammogram; Early breast cancer diagnosis; Mass detection; Marker-Pulse Coupled Neural Network (PCNN); Multiple Concentric Layers (MCL)

### 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>。据世界卫生组织统计,2008年全世界就有138万女性确诊患有乳腺癌,达到了所有女性癌症(不包括黑素瘤和皮肤癌)的22.9%,且2008年内全球因乳腺癌死亡的女性案例达到了惊人的45.8万,占有癌症致死女性案例的13.7%<sup>[3]</sup>。据美国国家癌症研究所的统计估计2012

年将有226870人被确诊患有乳腺癌,39510名女性将因乳腺癌丧生<sup>[4]</sup>。可见,乳腺癌严重地威胁到女性的健康。科学证据表明,在癌症治疗当中,发现越早,成功治愈的几率就越大<sup>[5]</sup>。乳腺钼靶X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,使得乳腺癌的早期检出率达到90%以上,死亡率降低30%左右,是当今公认的乳腺癌检测的金标准<sup>[6]</sup>。然而,肿块在大小、形状和对比度方面的变化性以及其模糊的边缘,使得乳腺X线图像肿块的检测过程中往往会出现漏判或者误判的情况。因此,一个高检测率、低假阳性率的肿块检测算法是必须的。

在乳腺X线图像中,肿块往往以亮斑的形式存在,中心区域灰度值较高,一般比正常组织高出约

2012-11-14收到,2013-02-01改回

国家自然科学基金(61271305, 61201363, 60972093), 国家高等学校博士学科点专项科研基金(20110009110001), 中央高校基本科研业务费专项资金(2011JBM003, 2012JBM012)和北京交通大学人才基金(2012RC036)资助课题

\*通信作者: 陈后金 ljchen@bjtu.edu.cn

5%~20%，而且肿块区域像素点的灰度值随着远离中心而不断地减小<sup>[7-11]</sup>。依此特点，对图像进行二值化的过程中，随着门限的不断减小，图像中肿块区域的像素点相比较正常组织来说会较先激活，而且肿块区域像素点是一种中心发散的方式依次激活的。Eltonsy等人<sup>[7]</sup>提出了一种多同心层(Multiple Concentric Layers, MCL)的肿块检测方法。该方法首先将乳腺X线图像颗粒化，然后从颗粒化的图像上提取形态学特征，采用多同心层分析方法检测可疑肿块区域。虽然MCL方法对于检测恶性肿块具有较好的结果，但该方法在检测良性肿块方面有其局限性。其主要原因是该方法中采用简单灰度颗粒化处理，导致图像对比度降低和马赛克效应的出现。在Eltonsy的基础上文献[9,10]提出了一种基于形态学成分分析(Morphological Component Analysis, MCA)和多同心层分析的肿块检测方法。此方法相比较MCL方法有一定的改进，但采用形态学成分分析提取图像分段平滑成分，降低了肿块的多层特性，使得同心层数减少，定位到的肿块区域可信度下降。同时，MCL, MCA方法在处理对比度极低的图像(如致密型乳腺图像)时，由于肿块原本已经很模糊地存在于背景当中，再加之处理过程中对于对比度的牺牲，使得其漏检与误检的情况出现概率加大。

不幸的是，乳腺X线图像是一种对比度低，受噪声影响大的医学图像。而且东方女性多为脂肪含量较少，体积较小的致密型腺体乳房。如果单纯地通过降门限的同轴中心分析很有可能得不到预期的肿块检测结果，且往往有较多的假阳性区域出现。于是，本文借鉴标记分水岭算法中的区域标记的思想，将其引入脉冲耦合神经网络(Pulse Coupled Neural Network, PCNN)算法中，设计了一种基于标记符的乳腺肿块PCNN分层检测方法。首先，分层处理时PCNN算法并不仅仅依赖单独像素点的灰度信息，还考虑了周围像素的影响，使得分层结果更为合理。其次，分水岭标记符的引入，一方面准确快速地搜寻感兴趣区域减少了假阳性区域，另一方面加入了梯度信息使得那些相对于组织对比度不明显的肿块也可以被找出来。

本文组织安排如下：第2节主要是本文提出的标记PCNN肿块分层算法介绍；在第3节中给出了本文方法的一些实验结果及分析；第4节是本文的结论。

## 2 标记 PCNN 肿块分层分割方法

介于MCL, MCA方法在处理图像(MCL方法中的简单灰度颗粒化处理以及MCA方法中形态学成分分析提取图像分段平滑成分)时，或多或少地降低

了图像对比度，使得分割结果不是很理想，尤其是在处理对比度极低的图像(如致密型乳腺图像)时，由于图像内部肿块原本已是很不明显，再加之这两种方法在分割过程中对图像对比度都有一定的牺牲，很容易在这些降低对比度操作过程中遗漏肿块或者误检出其他组织成分。

结合PCNN模型、同轴形态学模型以及分水岭标记符，本文提出了一种基于标记PCNN的乳腺X线肿块分层检测方法。应用标记分水岭当中的标记符来标记待处理图像，通过内部标记符的引入，准确地找到感兴趣区域(Region Of Interest, ROI)，由于标记分水岭内部标记符是通过梯度信息获得的，所以分割方法能克服乳腺X线图像对比度不明显的缺点。继而结合改进型PCNN降门限迭代操作逐层的将乳腺图像的各个区域分割出来。最后基于得到的图层，应用MCL方法进行肿块的定位。

### 2.1 标记 PCNN 模型

**2.1.1 改进型 PCNN** 借鉴分水岭算法中不断提高门限的思想，改进 PCNN 的动态门限矩阵。传统 PCNN 模型中动态门限矩阵采用指数衰减特性，而且一旦神经元被激活之后，动态门限矩阵被调制增加有一个固有电势 $V_\theta$ ，使得此神经元在之后的迭代过程中周期的被激活。本文中放弃了这种动态门限矩阵的指数衰减机制，而是采用了一种单调递减的阈值函数，使得神经元由不激活状态逐渐地转变成激活状态，而且一旦某一神经元步入激活状态之后，便永远进入此状态。通过不停的迭代使得图像中处于激活状态的点越来越多，逐层分割出来了图像中的区域。最后再从这些分割结果中选择出所需的分割结果。其可以用离散数学方程描述如下：

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

$$L_{ij}[n] = V_L Y_{ij}[n-1] * M \quad (2)$$

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

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

$$\theta_{ij}[n] = I_{\max} - a * n \quad (5)$$

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； $M$ 为连接矩阵。 $U[n]$ 为 $n$ 时刻内部活动项； $\beta$ 为连接权值。 $\theta[n]$ 为 $n$ 时刻动态门限矩阵； $\alpha$ 为控制动态门限矩阵递减常数； $I_{\max}$ 为图像中最大的灰度值。

相比较传统的PCNN模型，改进型PCNN模型的反馈输入直接采用像素灰度值；连接输入舍去衰

减项；动态门限矩阵采用逐次线性递减形式，保证了能够按灰度值大小逐层地将图像信息提取出来。

**2.1.2 标记符修正输出结果** 在PCNN迭代过程中，随着门限不断地降低，激活的区域也越来越大、越来越多，干扰项也相应地增多，在之后的应用分层评判标准的时候无形中增加了产生假阳性区域的可能性和计算量。

介于这种改进型降门限PCNN模型与分水岭算法在许多地方有相似之处，PCNN迭代时门限递减过程与分水岭算法中的注水过程非常相似。因此，参照分水岭算法中的一些改进进一步优化PCNN分层模型。

传统的分水岭方法通常会由于噪声和其他诸如梯度的局部不规则性的影响造成过度分割的现象。于是，为解决这一问题便诞生了标记分水岭算法。标记分水岭算法通过加入标记信息来控制分割中允许存在的区域数目，从而很好地克服了之前过度分割的问题。因此，借鉴标记分水岭算法中的标记符的思想，利用标记分水岭算法中的内部标记符来控制各层中的激活区域，从而克服之前所提到的直接应用改进型PCNN分层的不足，如图1(a)至图1(d)所示。

同时，如果不采用标记符修正，而直接使用基于灰度的PCNN分层方法处理低对比度乳腺图像，则需要非常小的灰度分辨率(控制动态门限矩阵递减常数 $\alpha$ )，这无疑便会产生更多的待分析图层，无形中加大了之后同心层分析的计算复杂度。即便如此，一些处于更低对比度环境中的肿块还是无法被检测出来。所以，一味加大灰度分辨率来处理低对比度图像是一个治标不治本的方法。但如果使用梯度这种对灰度波动非常敏感的信息便可以很好地解决这一问题。采用了利用图像梯度信息所得到的标记分水岭内部标记符来修正分层结果，使得处于低

对比度中的肿块可以被标记出来。因此，本文方法较之传统的基于灰度分层的方法(MCL, MCA)在处理低对比度乳腺图像(如致密型乳腺图像)时更具备检测敏感性，具有更高的真阳性率。如图1(e)所示。

图1(a)是一幅临床拍摄乳腺X线图像在PCNN迭代过程中门限等于106(灰度值，下同)时的输出结果，很明显其中已经有很多的小区域出现，如果直接对这所有的区域进行筛选的话，一方面计算量很大，另一方面大大地增加了出现假阳性区域的可能性；图1(b)是通过标记符修正后的输出结果，显然输出区域数目减少了93.75%(标记符处理前共有112个小区域，处理之后剩下7个区域)。随着PCNN迭代门限的不断降低，激活的区域越来越多，如图1(c)所示，此时激活的门限是66，这时激活的区域已经达到了一个很大数目，但是经过标记符修正后的输出结果(如图1(d)所示)，区域数目较图1(c)减少了90.58%(标记符处理前共有191个小区域，处理之后剩下18个区域)。这种情况在门限更低的时候更为明显。由此可见，标记符的引入一方面将计算量减小了，另一方面又使得假阳性区域产生的可能性也随之减小了。图1(e)所示是一幅不明显肿块的最终分割结果图，由于肿块区域与部分背景在灰度级上偏差小，直接通过MCL方法进行处理，此肿块会被遗漏，然而，通过标记符的限制，丢失情况则不会发生。

## 2.2 分层肿块检测

**2.2.1 判断准则** 在乳腺X线图像当中，肿块往往以亮斑的形式存在，中心区域亮度较高，且从中心向四周亮度逐渐发散降低，由此可以假设构成肿块的每一层是由相同或者相似的像素组成，并且中心层是最亮的区域，以中心层为轴的同心层亮度逐渐降低。因此，在降门限PCNN迭代得到的图层中，肿块区域在不同门限值L下得到的各个图层中应该存在同轴关系，如式(6)所示。




图1 标记符PCNN修正输出结果

$$A_L \subset A_{L-1} \subset \dots \subset A_1 \quad (6)$$

进而可以通过判断包含标记点的区域是否存在不断增大的同轴中心关系来确定此区域是否是肿块区域。如图2所示。

**多层评判标准：**那些拥有同轴中心图层，且随着PCNN迭代门限不断的降低，范围不断增大的区域是肿块区域。以每个焦点区域质心周围是否有亮度逐渐降低的同心层包围作为判断标准，即：如果包含有焦点区域质心的同心层数大于阈值  $N_{MCL}$ ，则该焦点区域被认作为肿块区域。由于同一区域在不同层的质心大多情况下是不一样的，所以设定参数  $D_{MCL}$  进行容错。当前层中焦点区域质心与上一层焦点区域质心在当前层的投影距离小于  $D_{MCL}$  时，认定为同轴情况。

在实际操作中，由于一些误差的引入使得比较小的肿块往往会在多层同轴中心判断中被误判掉，所以单一的多层评判标准来判断可疑区域是否是肿块是不够的，因此还得加入单层评判标准来补充多层标准的不足。

**单层评判标准：**如果这些可疑区域虽然没有同轴中心图层，但是他们严格地满足肿块的形态学特征和对比度要求，这些区域也将被看成是肿块区域。

**2.2.2 形态学特征和对比度标准** 肿块区域往往是具有一个圆盘或者椭圆形的边界，而且他们内部灰度的分布是连续递减的。因此，这些先验知识提供了很重要的信息来检测肿块的位置。

**离心率(eccentricity)：**与区域具有相同标准二阶中心矩的椭圆的离心率。这个参数相当的重要，它关系到区域形状。离心率门限细小的变化对于肿块的有效检测率和假阳性率都有很大的影响。计算公式如式(7)所示。

$$EC = F/L \quad (7)$$

其中  $F$  表示椭圆的焦距， $L$  表示椭圆的长轴长度。

**延展度(extent)：**区域内的像素总数与包含区域的最小矩形大小的比。由于正常区形状是不固定的，而肿块区域往往是拥有圆形或者椭圆形的形状，所以肿块区域比正常区域占有较大的范围。很明显，这个参数对于肿块的有效检测率有很大的影响，而

且如果这个参数设置的过低会引入大量的假阳性区域。计算公式如式(8)所示。

$$EX = \frac{AR}{AB} \quad (8)$$

其中  $AR$  表示区域内像素点的总数， $AB$  表示包含此区域的最小矩形的大小。

**刚度(solidity)：**区域内像素点总数与孔洞填充区域后像素点总数的比率。由于肿块区域内部灰度分布是连续且距中心递减的，而正常区域不具备这样的性质。所以，肿块区域较正常区域拥有比较大的刚度。这个门限对于假阳性率有所影响。计算公式如式(9)所示。

$$SO = \frac{AR}{AR + AH} \quad (9)$$

其中  $AR$  表示区域内像素点的总数， $AH$  表示区域内孔洞的像素点总数。

**对比度(contrast)：**焦点区域与其膨胀区域亮度值(灰度值)的差比。肿块区域较正常区域较亮，因此对比度也比较大。因此，对比度对于检测出较小的肿块很有帮助。对比度门限的大小直接关系到肿块的有效检测率。计算公式如式(10)所示。

$$CON = \frac{GF - GI}{GI} \quad (10)$$

其中  $GF$  表示焦点区域的灰度值， $GI$  表示其膨胀区域的灰度值。

**2.2.3 假阳性区域去除** 由于检测到的可疑肿块区域中存在假阳性区域，所以需要进行假阳性区域去除。因此使用到了两个评判标准：相对发生概率(relative incidence)<sup>[7]</sup>和焦点区域质心间的最小距离。

**相对发生概率：**焦点活动层相对于整个乳腺区域的发生概率。计算公式如式(11)所示。

$$P_k = \frac{\sum_k \rho(i, j)}{\sum_k \rho(i, j)} \quad (11)$$

其中，分子部分为当前检测的焦点区域像素点个数，分母部分为整个乳房区域像素点个数。当相对发生概率低于所设定的阈值  $T_{RI}$  的时候保留该区域，反之，则认定此区域是假阳性区域。由于门限值不断降低过程中，激活的区域越来越多，越来越大，通




图2 肿块区域的分层显示

过相对发生概率的引入保证了所有的可疑区域不会增大到过大,以至于包含了乳房区域内其他的组织部分。

区域质心间最小距离:在当前焦点层中,如果检测到两个区域的质心间距小于设定阈值  $D_{CC}$ ,则很有可能这两个区域属于同一个肿块(在较低门限时合并为同一个区域),或者是假阳性区域的干扰,因此,只需要保留其中质心灰度值最大的区域或者同心层数最多的区域。

### 3 算法测试与结果分析

#### 3.1 测试图像库及实验流程

为验证文中所提方法的有效性,使用南佛罗里达大学乳腺 X 线图像 (Digital Database for Screening Mammography, DDSM) 数据库提供的图像<sup>[2]</sup>,以及部分东方女性临床图像(由北京大学人民医院乳腺中心提供,国内目前没有乳腺 X 线图像数据库)进行仿真实验。实验中从图像库中随机抽取 300 幅图像,并将其分为两个子集(每个子集 150 幅图像),一个用于参数训练,另一个用于结果测试。实验流程如图 3 所示。

#### 3.2 模型参数

模型参数的选择对于整个检测方法有着非常重要的作用。因此,实验中每一个参数都是通过训练集中大量实验得到的经验参数。如表 1 所示。

### 3.3 检测结果

在图像库中随机选取的测试图像共 150 幅(脂肪型乳腺图像 119 幅,致密型乳腺图像 31 幅),其中有 70 幅图像包含有肿块(共 101 个肿块,17 个致密型乳腺肿块,84 个脂肪型乳腺肿块),80 幅正常图像。部分分割案例如图 4 所示。

实验中从肿块的有效检测率和检测的假阳性方面进行方法性能分析。图 5 为本文方法、MCL 方法和 MCA 方法对测试图像检测结果的 ROC 曲线。可以看出本文方法的 ROC 曲线在这两种方法之上。

表 2 所示为整个测试集检测的统计结果。使用本文方法对测试集进行肿块检测,将 101 个肿块中的 93 个成功地检测到,即检测真阳性率(TP)达到了 92.08%,相比较 MCL 方法和 MCA 方法分别提高了 9%和 6%(MCL 方法成功检测到 101 个肿块中的 84 个,MCA 方法成功检测到 101 个肿块中的 87 个)。同时试验中一共得到了 413 个假阳性区域,即平均每幅图像的假阳性(FPsI)为 2.75,相比较 MCL 方法的 7.02(150 幅图像中一共得到 1053 个假阳性区域)降低不少,相比较 MCA 方法的 3.55(150 幅图像中一共得到 532 个假阳性区域)同样有所改善。

实验中分别对脂肪型乳腺图像与致密型乳腺图像进行了对比分析。对于脂肪型乳腺图像,本文方法检测到 84 个肿块中的 81 个,同时对于这 119 幅图像得到了 332 个假阳性区域,即 TP 与 FPsI 分别

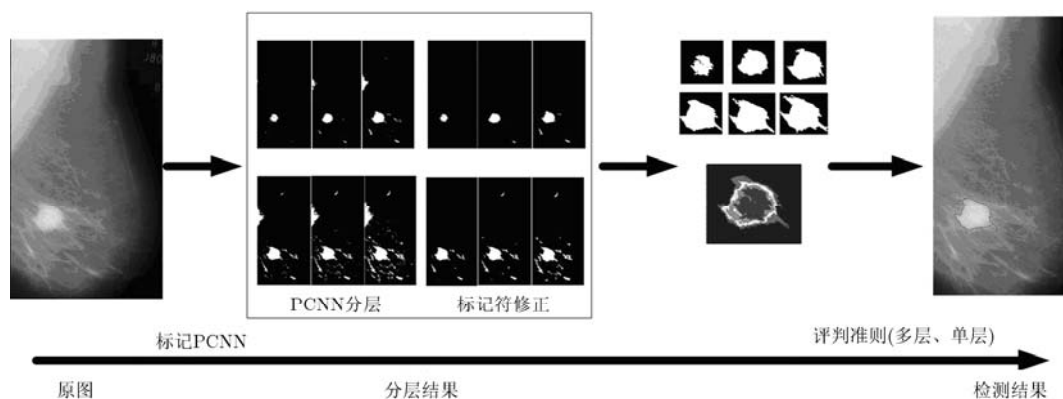


图 3 肿块检测流程

表 1 实验中参数设置

参数	$V_L$	$M$	$\beta$	$\alpha$ (灰度值)	EC	EX	SO	CON	$T_{RI}$	$D_{CC}$ (像素)	$N_{MCL}$	$D_{MCL}$ (像素)
取值	1	$\begin{bmatrix} 0.5 & 1 & 0.5 \\ 1 & 0 & 1 \\ 0.5 & 1 & 0.5 \end{bmatrix}$	0.1	10	<0.9	>0.6	>0.7	>0.5	<0.1	75	4	63




图 4 肿块分割实例




图 5 分割方法的 ROC 曲线

表 2 不同方法实验结果

	脂肪型乳腺图 像(TP/FPsI)	致密型乳腺图 像(TP/FPsI)	所有案例 (TP/FPsI)
MCL 方法	92.86%/7.50	35.29%/5.16	83.16%/7.02
MCA 方法	95.24%/3.01	41.18%/5.61	86.14%/3.55
本文方法	96.43%/2.79	70.59%/2.61	92.08%/2.75

为 96.43%和 2.79，相比较 MCL 方法的 92.86%和 7.50，在假阳性方面有所改善；对于致密型乳腺图像，本文方法检测到 17 个肿块中的 12 个，同时对于这 31 幅图像得到了 81 个假阳性区域，即 TP 与 FPsI 分别为 70.59%和 2.61，而 MCL 方法的测试结果为 35.29%和 5.16。

从表 2 中可以发现本文方法在检测真阳性率和假阳性方面优于 MCL 与 MCA 方法，这主要是由于这两种方法都是依赖于图像的灰度信息来进行分层，而且分层时也仅仅利用了单个点的灰度信息，而本文方法一方面使用 PCNN 模型来进行图像分层，分层过程不仅使用到单个点灰度还综合了周围点的影响，使得分层过程更为合理；另一方面分层过程同时借鉴了标记分水岭算法的改进——引入标记符，梯度信息的加入提高了分割算法对于对比度的敏感性。因此，本文方法具有较其他两种方法更

高的检测真阳性率。同时，由于另两种方法在检测过程中为了得到较高的检测真阳性率，就必须加大分层所需的灰度分辨率，这必然导致一些类似肿块的正常组织被误检，所以，这两种方法相对拥有比较高的假阳性。这两点在致密型图像中尤其明显。

因此，本文方法改善了 MCL 方法假阳性区域较多的问题，而且，在处理低对比度图像时，本文方法较 MCL, MCA 方法在保证较低的假阳性的同时，拥有更高的真阳性率。

#### 4 结论

依据肿块中心区域亮度较高，并由中心向四周逐渐发散降低的特性，本文提出了一种基于标记符修正的乳腺 X 线肿块 PCNN 分层检测方法。利用改进型 PCNN 降门限迭代操作将图像分离为多层结构，并对每一层利用标记符进行修正，然后使用改进的同轴中心标准对焦点区域进行筛选。一方面通过引入改进型 PCNN 模型对图像进行分层处理，不仅仅依赖单独像素点的灰度信息，还考虑了周围像素的影响，使得分层结果更为合理。另一方面，利用分水岭算法内部标记符修正每次分层结果既减小了计算量和假阳性区域出现概率，又在一定程度上提高了分割的真阳性率。通过实验比较，本文方法较 MCL 方法和 MCA 方法在保证低假阳性的情况下，有效地提高了检测的真阳性率。尤其是处理低对比度图像时，本文方法更有优势。

#### 参考文献

[1] American Cancer Society. Breast cancer facts and figures 2009-2010 [R]. Atlanta: American Cancer Society, 2010.  
 [2] Cancer Research UK. Breast cancer mortality statistics [OL]. Available: <http://info.cancerresearchuk.org/cancerstats/types/breast/mortality/index.htm>, 2010.

- [3] World Health Organization. Breast cancer incidence and mortality worldwide in 2008 summary [OL]. Available: <http://globocan.iarc.fr/factsheets/cancers/breast.asp>, 2008.
- [4] National Cancer Institute. Estimated new cancer cases and deaths for 2012 all races, by sex [OL]. Available: [http://seer.cancer.gov/csr/1975\\_2009\\_pops09/results\\_single/sect\\_01\\_table.01.pdf](http://seer.cancer.gov/csr/1975_2009_pops09/results_single/sect_01_table.01.pdf), 2012.
- [5] National Cancer Institute. SEER stat fact sheets: breast [OL]. Available: <http://www.cancer.gov/cancertopics/types/breast>, 2008.
- [6] Lewis C. FDA sets higher standards for mammography[J]. *FDA Consumer*, 1999, 245(1): 13-17.
- [7] Eltonsy N H, Tourassi G D, and Elmaghraby A S. A concentric mammography model for the detection of masses in mammography[J]. *IEEE Transactions on Medical Imaging*, 2007, 26(6): 880-889.
- [8] Xu S Z and Pei C D. Hierarchical matching for automatic detection of masses in mammograms[C]. International Conference on Electrical and Control Engineering (ICECE), Yichang 2011: 4523-4526.
- [9] Gao X B, Wang Y, Li J, *et al.* On combining morphological component analysis and concentric morphology model for mammographic mass detection[J]. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 2(14): 266-273.
- [10] 王颖, 李洁, 高新波. 基于MCA的乳腺X线图像中肿块的自适应检测方法[J]. *电子学报*, 2011, 39(3): 525-530.  
Wang Y, Li J, and Gao X B. An adaptive mass detection method on mammography based on MCA[J]. *Acta Electronica Sinica*, 2011, 39(3): 525-530.
- [11] Han Z Z, Chen H J, Li J P, *et al.* A novel method of mass segmentation in mammogram[C]. 2012 International Conference on Systems and Informatics (ICSAI), Yantai, 2012: 1412-1416.
- [12] University of South Florida. Digital database for screening mammography[OL]. 2012. Available: <http://marathon.csee.usf.edu/Mammography/Database.html>, 2012.
- 韩振中: 男, 1987年生, 博士生, 研究方向为生物医学图像处理.
- 陈后金: 男, 1965年生, 教授, 研究方为向生物医学图像处理、数字信号处理.
- 李居朋: 男, 1981年生, 讲师, 研究方向为信号与信息处理、生物医学图像处理.
- 姚 畅: 男, 1980年生, 讲师, 研究方向为生物医学图像处理.
- 程 琳: 男, 1976年生, 副主任医师, 乳腺肿瘤、乳腺癌早期诊断和综合治疗.