

文章编号:1004-4213(2010)06-1040-7

# 基于双树复数小波变换的微钙化诊断方法\*

杨威,高协平<sup>†</sup>

(湘潭大学 信息工程学院,湖南 湘潭 411105)

**摘要:**提出一种基于双树复数小波变换的微钙化分类方法.通过提取基于小波和灰度直方图的纹理特征,结合遗传算法进行特征优化,分别用神经网络,支持向量机和 KNN 分类器进行微钙化的良恶性分类.对三种不同的分类器进行对比,结果表明:KNN 分类器取得最好的效果,而支持向量机优于神经网络.KNN 分类器对比于神经网络和支持向量机,无需训练,可节约训练时间,最直接地利用了样本和样本之间的关系,减少了类别特征选择不当对分类结果造成的不利影响,可以最大程度地减少分类过程中的误差项.在类别决策时,KNN 分类器只与极少量的相邻样本有关,可以较好地避免样本数量的不平衡问题.与传统的小波比较,双树复数小波具有近似平移不变性和正则性,对图像信号具有良好的方向选择性,且冗余度有限,计算量较小.

**关键词:**微钙化;双树复数小波变换;纹理特征;分类

**中图分类号:**TP391

**文献标识码:**A

**doi:**10.3788/gzxb20103906.1040

## 0 引言

乳腺癌是当今女性最常见的恶性肿瘤疾病,也是引起中年妇女死亡最主要的疾病.为了降低发病率和死亡率,早期的检测和诊断至关重要.乳腺 X 线成像技术是乳腺癌早期诊断最有效的方法<sup>[1]</sup>.微钙化是乳腺癌早期最常见的症状,表现为极小的钙化颗粒,嵌入周围复杂的乳腺组织而难以分辨,医生和放射学家仅凭经验查看乳腺 X 影像很容易造成误诊和漏诊.计算机辅助诊断系统(Computer-aided Diagnosis,CAD)以“第二读者”的身份查阅乳腺 X 影像,给医生和放射学家一个有利的参考和辅助性的诊断,提高诊断的正确率.

目前人们已经提出很多计算机辅助诊断微钙化的算法.而小波分析作为一种有效的多分辨率分析方法,被很多研究者广泛运用.Dhawan 等<sup>[2]</sup>基于小波包来提取局部纹理特征,利用 Daubechies 小波的正交性去除多级分解后各特征之间的相关性;H. Soltanian-Zadeh 等<sup>[3]</sup>引入多小波变换,利用其正交,对称,紧支撑,高消失矩等特性,通过实验证明,基于多小波的分类方法优于传统的正交单小波;Zhang 等<sup>[4]</sup>考虑到小波变换的平移不变性,实验表明,平移不变小波变换的冗余信息能更好地刻画微钙化的纹理特征,提高分类准确度.

在前人提出的基于小波的方法中,特征之间的低相关性和平移不变的小波变换方式能取得更好的分类效果.为了使各特征之间相互独立,常用正交小波变换去除特征相关性,但离散正交小波方向选择性较差,且不具有平移不变性,然而在图像处理应用中平移不变性非常重要<sup>[5-7]</sup>.针对传统实数小波的局限,Kingsbury 提出了复数小波<sup>[8]</sup>的概念.复数小波很好地解决了 Mallat 小波变换不具备良好的方向选择性的缺点,兼具近似平移不变性,但是其所用的短时傅里叶滤波器不具备良好的重构性和频率域特性.因此,Kingsbury 进一步提出双树复数小波变换<sup>[9-11]</sup>(Dual-Tree Complex Wavelet Transform, DTCWT),它满足完全重构条件,且保留了复数小波的其他优点.双树复数小波的近似平移不变性能很好地表征微钙化的纹理特征,而相比于其他小波的平移不变的变换方式,双树复数小波的各变换带之间的相关性要低得多,这使得特征提取的效果更好,能得到更为精确的微钙化诊断结果.基于以上分析,本文提出一种新的基于双树复数小波变换的微钙化诊断方法:对每个 ROI(Region of Interest)进行双树复数小波变换<sup>[12]</sup>,对变换后的各个子图提取能量,熵和 1-4 阶灰度直方图矩等纹理特征,分别用神经网络,支持向量机和 K 最近邻(K-Nearest Neighbor,KNN)分类器进行分类,并结合遗传算法进行特征优化,采用 ROC 曲线对实验结果进行分析评价.实验数据采用 Nijmegen 和 MIAS 两个公用数据库,结果表明,对比前人的方法,本文运用 KNN 分类器取得更好的分类效果.

\*国家自然科学基金(60375021)和湖南省科技厅项目(2007FJ3033)资助

<sup>†</sup> Tel:0731-58293676

Email:xpgao@xtu.edu.cn

收稿日期:2008-10-07

修回日期:2008-12-29

## 1 双树复数小波变换

Kingsbury 根据傅里叶变换的思想提出在同一个数据上,用两个独立的小波变换平行作用来完成复数小波变换,即  $\psi(t)$  由式(1)计算<sup>[9-11]</sup>

$$\psi(t) = \psi_h(t) + i\psi_g(t) \quad (1)$$

式中  $\psi_h(t)$  是实数且为偶函数,  $i\psi_g(t)$  是虚数且为奇函数。

如图 1,一维双树复数小波变换可通过一对滤波器组同时作用在输入数据上来实现.它包含两个平行的小波树,即树 A 和树 B 两个分支.树 A 的叠加滤波器组表示复数小波变换的实部,树 B 的叠加

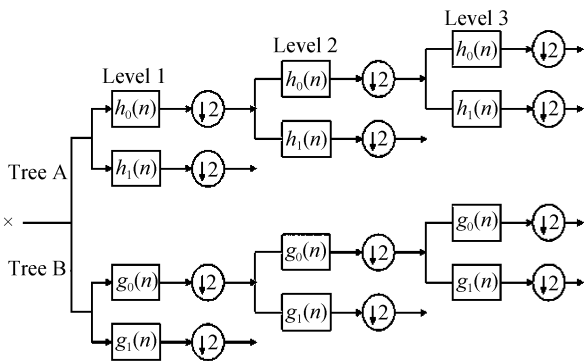


图 1 一维双树复数小波变换

Fig. 1 1-D dual-tree complex wavelet transform

滤波器组表示复数小波变换的虚部.实数滤波器  $h_0(n), h_1(n)$  代表了一个共轭正交滤波器对,对应于实部分解树,其对应的尺度函数  $\varphi_h(t)$  和小波函数  $\psi_h(t)$  为

$$\varphi_h(t) = \sqrt{2} \sum_n h_0(n) \varphi_h(2t-n),$$

$$\psi_h(t) = \sqrt{2} \sum_n h_1(n) \psi_h(2t-n).$$

而  $g_0(n), g_1(n)$  代表了一个共轭积分滤波器对,对应于虚部分解树,其对应的尺度函数  $\varphi_g(t)$  和小波函数  $\psi_g(t)$  为

$$\varphi_g(t) = \sqrt{2} \sum_n g_0(n) \varphi_g(2t-n),$$

$$\psi_g(t) = \sqrt{2} \sum_n g_1(n) \psi_g(2t-n).$$

这两个滤波器对的长度分别为奇数和偶数,而且相位都为线性,这样可以保证滤波器的冲击响应对应于复数小波变换的实数部分和虚数部分.  $\downarrow 2$  表示隔点取样,对树状结构的每一层滤波器输出做因子为 2 的子采样是为了使双树复数小波变换具有近似平移不变性。

二维双树复数小波实质上是在一维双树复数小波的基础上,通过对图像的行和列分别进行双树复数小波变换,即对行滤波器的输出再进行滤波器复共轭滤波.二维双树复数小波变换由四个平行的二维离散小波变换组成,可以得到六个方向子带

( $\pm 15^\circ, \pm 45^\circ, \pm 75^\circ$ ),前两个平行的二维离散小波变换产生这六个方向的实部,后两个产生虚部。

图 2 所示的两种小波基中,图 2(a)是二维离散小波基,有三个方向(水平,垂直和对角线),图 2(b)所示是二维双树复数小波基,有六个方向,第一行为六个方向的实部,第二行为虚部.由此可知,二维双树复数小波变换比二维离散小波变换具有更好的方向选择性,因此,二维双树复数小波变换能比二维离散小波变换更好地刻画纹理的方向特性。




图 2 两种小波基

Fig. 2 Two kinds of wavelet basis

二维双树复数小波变换的分解步骤如图 3,从图中可以看出,每一级分解得到两个低频部分和六个高频部分,而且无论二维双树复数小波变换分解层数为多少,冗余数都为 4:1(m 维信号的冗余数为  $2^m:1$ ),注意到二维复数小波变换由可分离小波实现,表明它具备较低的计算复杂度.双树复数小波变换具有与经典的 Gabor 小波变换相似的特性,但它的冗余度远小于 Gabor 小波变换.因此,双树复数小波变换的运算复杂度比 Gabor 小波变换要低得多。

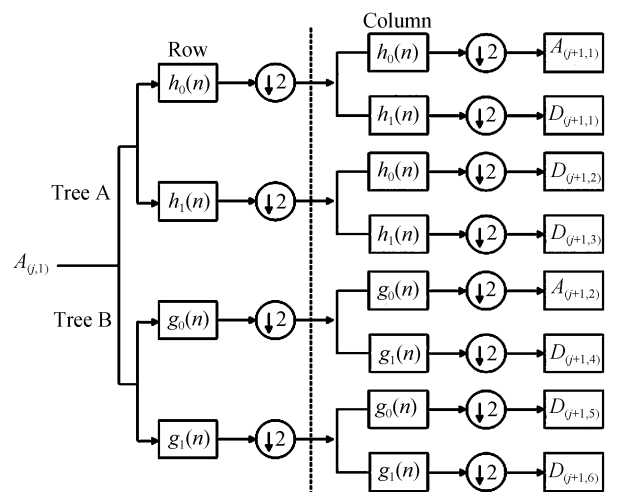


图 3 二维双树复数小波变换

Fig. 3 The 2-D dual-tree complex wavelet transform

## 2 微钙化诊断方法

本文提出一种新的微钙化诊断的方法,具体步骤为:

- 1) 对每个 ROI 进行 4 级双树复数小波变换;
- 2) 对分解后每个子图提取两组特征, 一组是能量和熵, 一组是 1-4 阶灰度直方图矩;
- 3) 用遗传算法进行特征优化;
- 4) 分别用神经网络, 支持向量机和 KNN 分类器进行分类.

## 2.1 特征提取

特征提取是模式识别过程中最难且最关键的过程, 直接影响分类效果. 在这个部分, 我们结合了基于小波和灰度直方图的统计特征来得到更好的效果. 具体分为以下三个步骤: 1) 提取感兴趣区域 (ROD); 2) 对每个 ROI 提取特征; 3) 结合遗传算法进行特征选择.

### 2.1.1 提取 ROI

微钙化诊断是对病变区域进行良恶性分类, 因此, 我们首先要提取出含微钙化簇的感兴趣区域 (ROD). 一般来说, 可以对所有的微钙化簇用相同的大小进行提取, 但因为微钙化簇的大小是不一致的, 小的微钙化簇区域边长只有十几个像素, 大的则可以达到几百个像素. 因此, 我们根据已知的微钙化簇区域的大致位置和大小来截取 ROI, 而且为了方便进行双树复数小波变换, 截取的 ROI 边长都为 2 的整数次幂. 这样, 我们提取了一系列尺度大小不等的 ROI.

### 2.1.2 特征提取

乳腺 X 影像的特征提取是一个很难的任务. 研究<sup>[13]</sup>表明, 乳腺 X 影像的纹理是一种不规则纹理, 在多尺度变换下提取能量, 熵, 对比度和一致性等特征, 可以提高分类效果. 现有的微钙化良恶性分类算法中, 能量和熵是最常见的基于小波的纹理特征. 然而, 能量和熵一般集中在低频部分, 不能够很好地表征高频部分的信息.

因此, 本文考虑了其他有效的特征来表征多尺度下高频部分的信息. 在多尺度下, 图像平滑区的灰度级比较接近, 粗糙区的灰度级变化较大, 考虑用区域直方图的统计矩来描述图像的信息. 在普通的灰度图像中, 区域内的灰度值可以描述该区域内的平均灰度水平. 在医学图像中, 量化的数据往往代表了受检目标的某一生理特性, 例如, 在多级小波分解下, 良性微钙化和恶性微钙化的密度表现和亮度表现可能有很大差别. 因此, 医学图像中的灰度值这一特征也有了新的含义. 文献<sup>[14-15]</sup>中, 都是直接对原始图像提取灰度直方图的统计特征. 在我们的实验方法中, 对每个 ROI 图像进行 4 级双树复数小波分解, 然后对小波分解得到的子图提取 6 个特征: 能量, 熵, 1-4 阶灰度直方图矩. 这些特征根据式(2)~

(7) 计算, 其中, 能量和熵分别为

$$E_{\text{Energy}} = \frac{\sum_i \sum_j x_{ij}^2}{N^2} \quad (2)$$

$$\varphi_{\text{Entropy}} = - \frac{\sum_i \sum_j \left( \frac{x_{ij}^2}{\text{norm}^2} \right) \log_2 \left( \frac{x_{ij}^2}{\text{norm}^2} \right)}{\log_2 N^2} \quad (3)$$

式中,  $x_{ij}$  为像素  $(i, j)$  的灰度值,  $\text{norm}^2 = \sum_i \sum_j x_{ij}^2$ ,  $N$  为图像中总的像素个数.

能量用于衡量灰度值重复的程度, 能量越大, 说明灰度值重复的概率越高; 熵信息用于衡量灰度值分布的随机情况, 灰度值分布的随机性越大, 熵信息越大. 1-4 阶灰度直方图矩为

$$M = \frac{1}{N} \sum_{k=1}^L f_k n_k \quad (4)$$

$$V = \frac{1}{N} \sum_{k=1}^L (f_k - u)^2 n_k \quad (5)$$

$$\delta_{\text{skewness}} = \frac{1}{N \times \sigma^2} \sum_{k=1}^L (f_k - u)^3 n_k \quad (6)$$

$$\delta_{\text{kurtosis}} = \frac{1}{N \times \sigma^4} \sum_{k=1}^L (f_k - u)^4 n_k - 3 \quad (7)$$

式中,  $L$  为灰度级数,  $f_k$  为第  $k$  个灰度级,  $n_k$  为像素值为  $f_k$  的像素的个数,  $N$  为图像中的总的像素个数.

$M$  表示灰度均值, 也称为 1 阶灰度直方图矩, 它描述了目标图像的平均灰度水平, 表征的是微钙化区域的平均幅度;  $V$  表示灰度方差, 也称为 2 阶灰度直方图矩, 它描述了目标图像整体偏离均值的程度, 反映图像的视觉粗糙程度, 表征测量幅度的局部活动性;  $\delta_{\text{skewness}}$  表示偏度, 也称为 3 阶灰度直方图矩, 它反映了目标区域整体灰度水平高于或低于平均灰度值的趋势, 可以用来表示由于少数极值引起的平均灰度水平的偏差, 反映了直方图的不对称性;  $\delta_{\text{kurtosis}}$  表示峰度, 也称为 4 阶灰度直方图矩, 它反映了直方图的均匀性, 描述了灰度水平分布的光滑程度.

本文对每个 ROI 进行 4 级双树复数小波变换, 得到 26 个子图, 其中有 24 个高频子图, 2 个低频子图. 对分解后的每个子图, 按照上述公式提取 6 个特征, 这样, 我们得到一个由 156 个纹理特征组成的特征集合.

### 2.1.3 特征选择

对图像提取特征之后, 可以得到一组特征参量, 不同的特征参量组合可能得到不同的诊断结果. 一般认为, 特征越多, 描述图像越充分, 诊断结果也越精确. 然而, 过多的特征数据不仅需要大量的时间和庞大的计算量, 一些冗余的和不相关的特征会影响分类的速度和分类器的泛化能力. 因此, 为了避免特

征空间过大而扩大计算量和降低分类准确度,我们运用遗传算法(Genetic Algorithm,GA)来进行特征选择,考虑到GA的全局优化能力,选择最适合的特征组合.遗传算法是一种新的全局优化搜索算法,具有简单通用、鲁棒性强、适于并行处理以及应用范围广等显著特点,本文的实验以ROC曲线面积的最大化作为GA的适应度函数,其他的参量设置如表1.

表1 遗传算法参量设置  
Table 1 The parameters of GA

Selection	Cross over	Probability of cross over	Mutation	Probability of mutation
Stochastic uniform	Two point	0.8	Boundary mutation	0.03

## 2.2 微钙化分类

分类阶段的目的是运用优化后的特征来区分微钙化的良恶性,实质是一个两分类问题.本文的实验分别采用神经网络,支持向量机和KNN分类器进行分类.

### 2.2.1 神经网络

目前应用最为广泛的神经网络学习算法是BP(Backpropagation)网络,它属于前馈神经网络.BP网络是一种具有三层或三层以上的单向传播的多层前向网络,包括输入层,中间层(隐层)和输出层.上下层之间实现全连接,而每层神经元之间无连接.当一对学习样本提供给网络后,神经元的激活值从输入层经中间层向输出层层传播,在输出层的各个神经元获得网络的输出响应.接下来,按照减少目标与实际误差的方向,从输出层经过各中间层逐层修正各连接权值,最后回到输入层.随着误差逆传播修正的不断进行,网络对输入模式响应的正确率也不断上升.

本文选用的神经网络就是三层BP网,其中,输入节点即为特征向量,隐层为十个Sigmoid节点,采用Levenberg-Marquardt反向传播训练方法,该方法通过Levenberg-Marquardt的最优化来更新权值和偏差.测试方法我们采用两倍交叉验证,即对于整个样本空间,一半作为训练集,一半作为测试集,然后交叉验证.

### 2.2.2 支持向量机

另一种分类器是近年来常用于模式识别的支持向量机(Support Vector Machine,SVM)<sup>[16-17]</sup>.SVM基于最优超平面,其线性地将训练数据分离以达到最小期望误差.与其他的分类模型不同,SVM将经验风险 $R_{emp}$ 最小化,同时使得相应的线性决策边界上的点数据之间距离最大化

$$R_{emp}(a) = \frac{1}{2l} \sum_{i=1}^l |y_i - f(x_i, a)|$$

式中 $x_i \in \mathbf{R}^N, i=1, \dots, l$ ,是训练向量, $y_i \in \{-1, 1\}$ 标明了 $x_i$ 的类别, $f$ 是决策函数. $\mathbf{R}^N$ 空间上的训练向量,通过函数 $\varphi: \mathbf{R}^N \rightarrow F$ ,非线性地映射到高维空间 $F$ ,在空间 $F$ 中计算决策超平面,其决策函数为

$$f(x) = \sum_{i=1}^l y_i a_i K(x_i, x) + b$$

式中 $K(x_i, x)$ 是核函数, $a_i$ 是权值, $b$ 是偏差.经过训练,大多数权值 $a_i=0$ ,这样,决策函数依赖于训练向量的子集,即支持向量集.从决策函数的定义可知,核函数的选取对分类效果至关重要,一般有多项式核函数,径向基函数,Sigmoid函数,Gaussian函数等.

采用leave-one-out的误差评价方法来评判SVM的性能,即对 $N$ 个样本,选取一个作为测试样本,剩余作为训练样本,直到每个样本都测试过,测试结束.

### 2.2.3 KNN分类器

KNN算法即K最近邻法,是一种无参量消极分类方法,属于最近邻分类方法的一种推广,是一种预测性的分类算法.它实际并不需要产生额外的数据来描述规则,它的规则本身就是数据样本.

K最近邻算法的思路非常简单直观.它的分类算法的基本原理为:首先把总样本分为测试样本和训练样本,测试样本和训练样本具有一致的特征向量;然后从测试样本点 $X$ 开始按距离函数计算测试样本和每个训练样本之间的距离,并选择与测试样本距离最小的 $K$ 个样本作为测试样本的 $K$ 个最近邻;最后把测试样本的类别归为这最近的 $K$ 个训练样本点中出现频率最大的类别.

值得注意的是,KNN分类算法需要确定两个基本的参量:最近邻样本的数目 $K$ 和距离的尺度. $K$ 表示选择参考样本的数目, $K$ 值的选择往往通过大量的独立测试数据,多个模型来验证最佳的选择;距离尺度对应于一个非负的函数,用来刻画不同数据间的相似性程度.通过实验对比不同 $K$ 值下的分类准确度,本文取 $K=7$ 时效果最好,和SVM类似,采用leave-one-out的误差评价方法.

对于上述三种分类模型,我们运用ROC曲线分析来评判分类效果,用ROC曲线下的面积 $A_c$ 来计算分类准确度.对于神经网络和SVM,阈值从-1.4到1,每次递增0.4,一共7级;对于KNN分类器,阈值从-1到 $K$ ,一共 $K+2$ 级(本实验取 $K=7$ ,即9级).当阈值变化的时候,相应的分类结果作为坐标点,形成ROC曲线.

### 3 实验结果分析

#### 3.1 数据库

本文所用的数据库是两个比较规范和完善的公用数字乳腺 X 影像数据库: 荷兰计算机学家 N. Karssemeijer 建立的 Nijmegen<sup>[18]</sup> 和英国的 The Mammographic Image Analysis Society (MIAS)<sup>[19]</sup>. 其中, Nijmegen 数据库有 40 张数字乳腺 X 影像, 由 21 个乳腺患者从两个不同的角度拍摄而成. 图片大小为  $2\ 048 \times 2\ 048$ , 每个像素具有 12 位(4 096)的灰度级, 经过噪声均衡化, 灰度级调节为 8 位(256). 本实验截取了 103 个 ROI, 其中 29 个为良性, 74 个为恶性. MIAS 数据库有 322 张数字乳腺 X 影像, 其中有 20 张是微钙化病变的情况. 每张图片都以  $50\ \mu\text{m}$  的空间分辨率进行数字化, 每个像素具有 8 位(256)的灰度级. 本实验截取了 26 个 ROI, 其中 12 个为良性, 14 个为恶性.

#### 3.2 结果分析

分别用本文提出的分类方法对上述两个数据库进行实验. 从每个 ROI 中提取的基于双树复数小波的特征向量, 结合 GA 进行特征选择, 将特征向量加权后输入三种不同的分类器进行分类, 表 2 所示是用 KNN 分类器分类时各特征对应的权值, 其中 1-12 行代表树 A 分支经过 4 级分解后的 12 个高频子图特征对应的权值, 分别为 1-4 级的 LH, HL, HH 子图, 第 13 行为 4 级分解时的 LL 子图, 14-26 行为树 B 分支的情况, 权值越大, 表示该特征越重要, 表 3 是具体的分类结果. 本文的实验对比了三种分类器的分类效果, 从表 3 中可以看出, 对于两个数据库, KNN 分类器的分类效果都最好, 分别达到了  $A_z = 0.946\ 9$  和  $A_z = 0.943\ 5$  的高分类准确度, 而支持向量机的效果要优于神经网络.

表 2 经过 GA 选择后各特征对应的权值(KNN 分类器)

Nijmegen					
Energy	Entropy	1 order	2 order	3 order	4 order
0.46	0.52	0.26	0.49	0.32	0.33
0.37	0.39	0.94	0	0.86	0.06
0.14	0.11	0.14	0.10	0.35	0.59
1	0.10	0.37	0.15	0	0
0.10	0.59	0.99	0.64	0.85	0.25
0.38	1	0.12	0.27	0.92	0
0.16	0.25	0.77	0.52	0.43	0.04
0.97	0.33	0.45	0.86	0.79	0.44
0.24	0.21	1	1	0	0.81
0.85	0.68	0.89	0.45	0.95	0.78
0.92	0	0.72	0.23	0.59	0.65
0.55	0.23	0.96	0.81	0.77	0.51

Nijmegen					
Energy	Entropy	1 order	2 order	3 order	4 order
0.32	0	0.40	0.92	0.15	0.85
0.46	1	0.40	0.14	0.45	0.61
0.83	0.44	0.99	0.41	0.04	0.50
0	0.37	0.96	0	0.04	0.87
1	0.60	0.42	0.71	1	0.93
0.41	0.54	0.50	0.28	0.05	0.62
0.26	0.03	0.40	0.80	0	0.79
0.21	0.52	0.28	0.97	0.60	0.41
0.75	1	0	0.58	0.67	0
0.89	0.90	1	0.37	0.88	0
0.95	0.39	0.14	0.52	0.84	0.12
0.84	0.62	0	0.25	0.96	0.79
0.10	1	0.12	1	1	0.46
0.18	0	0.95	0.62	0.29	0
0.35	0.59	0.28	0.36	0.31	0.71
0.06	0.99	0.22	0.42	0.12	0.74
0.07	0.39	0.95	0.42	0.86	0.77
0.95	0.05	0.11	0.68	0.70	0.75
0.45	0.11	0.28	0.74	0.06	0.44
0.85	0.45	0.88	0.82	0.69	1
0.91	0.76	0.90	0.20	0.71	1
0.28	0.65	0.26	0.78	0.08	0.90
0.13	0	0.82	0.85	0.99	0.06
0.03	0.05	0.76	0.80	0.25	0
0.25	0.65	0.91	1	0.22	1
0.96	0.50	0.73	0.59	0	0.80
0	0.78	0.07	0	0.69	0.84
0.79	0.68	0.13	0.98	0.22	0.19
0.07	0.93	0.53	0.88	0.13	0.54
0.07	0.24	0.23	0.60	0.84	0.73
0.40	0.75	0.74	0.48	0.22	0.12
0.34	0.73	0.17	0.48	0.08	0.35
1	0.44	0.87	0.64	0.15	0
0.10	0.24	0.92	0.79	0.21	0.38
0.42	0.35	0.38	0.69	0.19	0.77
0.67	0.50	0.41	0.13	0.52	0.04
0.08	0.44	0.66	0.50	0.36	0.96
0.45	0.76	0.73	0.15	0.43	1
0.90	0.26	0.75	0.43	0.20	0.72
1	0.26	0.60	0.94	0.12	0.51

表 3 ROC 曲线下的面积 ( $A_z$ )

	Neural Network	SVM	KNN
Nijmegen	0.858 3	0.907 0	0.946 9
MIAS	0.860 2	0.934 5	0.943 5

对比前人提出的传统的非小波的微钙化分类方法(表 4)和基于小波变换的微钙化分类方法(表 5), 本文提出的基于双树复数小波变换的方法取得更好的分类效果. 这是因为微钙化在图像中具有很高的空间频率, 经过小波分解, 能更好的提取表征微钙化的高频信息, 所以, 基于小波的方法优于传统的非小波方法; 而对比于其他小波, 双树复数小波具有近

似平移不变性,但在同样具有平移不变性的基础上,抽取的双树复数小波的各变换带的相关性比其他小波的平移不变和非抽取变换方式要低得多,因其冗余度最低,仅为抽取单小波的两倍,而相关性越低,特征提取的效果越好.所以,低相关的平移不变性是双树复数小波优于其他小波的原因.

表 4 传统的非小波微钙化分类方法的结果 ( $A_c$ )

Table 4 Results of the conventional microcalcification diagnosis methods not based on wavelet before ( $A_c$ )

Database	Method	Result
Nijmegen	Obtained ROIs through the detection of microcalcification clusters and extracted	0.79 <sup>[20]</sup>
MIAS	features from both single microcalcification and microcalcification clusters	0.82 <sup>[20]</sup>

表 5 基于小波变换的微钙化分类方法的结果 ( $A_c$ )

Table 5 Results of the microcalcification diagnosis methods based on wavelet before ( $A_c$ )

Database	Wavelet basis	Transform level	Result
Nijmegen	Multi-wavelet;GHM,CL,SA4	1 level	0.89 <sup>[3]</sup>
	Single wavelet;DB4,DB97	1 level TI	0.91 <sup>[4]</sup>

为了证明本文提出的算法的通用性和实用性,进一步对两个数据库进行了交叉检验:当用 Nijmegen 数据库作为训练集,MIAS 数据库作为测试集时,分类准确度高达  $A_c=0.9524$ ;交换两个数据库后,分类准确度有所下降,达到  $A_c=0.8478$ ,这是因为相比于测试集 Nijmegen 数据库,训练集 MIAS 数据库样本太少,导致对分类器网络训练不够充分,不能全面地表征 Nijmegen 数据库中微钙化的良恶性特征.这样,在对两个成像采集和预处理都完全不同的数据库进行交叉检验时,本文提出的算法仍然得到很高的分类准确度,说明其具有很强的实用性能.

## 4 结论

本文提出一种新的基于双树复数小波变换的微钙化分类方法,提取基于小波和灰度直方图的纹理特征,结合遗传算法进行特征优化,分别用神经网络,支持向量机和 KNN 分类器进行微钙化的良恶性分类,对比前人的方法,本文的方法运用 KNN 分类器取得更好的分类效果.

基于多尺度分析方法,将来可以更进一步对特征提取环节进行深入地研究,同时考虑同尺度内及尺度间的相关性,注入更有效的模型,针对不同尺度,不同频段提取不同的特征.

## 参考文献

- [1] ALAYHOGLU B A, AGHDASI F. A wavelet neural network for the detection of microcalcifications in multiscale enhanced digitized mammograms[C]. AFRICON, 1999:389-394.
- [2] DHAWAN A P, CHITRE Y, KAISER B C. Analysis of mammographic microcalcifications using gray-level image structure features [J]. *IEEE Transaction on Medical Imaging*, 1996, **15**(3):246-259.
- [3] ZADEH H S, RAD F R, NEJAD S P. Comparison of multiwavelet, wavelet, haralick, and shape feature for microcalcification classification in mammograms[J]. *Pattern Recognition*, 2004, **37**:1973-1986.
- [4] ZHANG Lei, GAO Xie-ping. Research on translation-invariant wavelet transform for classification in mammograms[C]. The 3<sup>rd</sup> International Conference on Natural Computation (ICNC'07), 2007, **3**:571-575.
- [5] LUO Peng, GAO Xie-ping. Image denoising algorithm based on dual tree complex wavelet transform [J]. *Acta Photonica Sinica*, 2008, **37**(3):604-608.  
罗鹏,高协平.基于双树复数小波变换的图像去噪方法[J].光子学报, 2008, **37**(3):604-608.
- [6] TAN Li-na, GAO Xie-ping. Study of MRI denoising based on TI multiwavelet thresholding[J]. *Acta Photonica Sinica*, 2007, **36**(8):1552-1556.  
谭利娜,高协平.基于平移不变多小波方法的磁共振去噪研究[J].光子学报, 2007, **36**(8):1552-1556.
- [7] WU Dong-mei. Noisy image estimation with translation invariant wavelet thresholding [J]. *Acta Photonica Sinica*, 2005, **34**(2):306-309.  
吴冬梅.基于平移不变小波阈值算法的噪声图像估计[J].光子学报, 2005, **34**(2):306-309.
- [8] MAGAREY J F A, KINGSBURY N G. Motion estimation using a complex-valued wavelet transform[J]. *IEEE Trans on Signal Processing, Special Issue on Wavelets and Filter Banks*, 1998, **46**(4):1069-1084.
- [9] KINGSBURY N G. The dual-tree complex wavelet transform: a new technique for shift invariance and directional filters[C]. IEEE Digital Signal Processing Workshop, DSP 98, Bryce Canyon, August 1998, paper No86.
- [10] KINGSBURY N G. Image processing with complex wavelets [C]. Phil. Trans. Royal Society London A, September 1999, on a Discussion Meeting on "Wavelets: the key to intermittent information?", London, February 24-25, 1999.
- [11] KINGSBURY N G. Complex wavelets for shift invariant analysis and filtering of signals[J]. *Journal of Applied and Computational Harmonic Analysis*, 2001, **10**(3):234-253.
- [12] SELESNICK I W, BARANIUK R G, KINGSBURY N G. The dual-tree complex wavelet transform [J]. *IEEE Signal Processing Magazine*, 2005, **22**:123-151.
- [13] RASHED E A, ISMAIL I A, ZAKI S I. Multiresolution mammogram analysis in multilevel decomposition[J]. *Pattern Recognition Letters*, 2007, **28**(2):286-292.
- [14] MINI M G, THOMAS T. A neural network method for mammogram analysis based on statistical features [C]. TENCON, 2003, **4**(4):1489-1492.
- [15] ANTONIE M L, ZAIANE O R, COMAN A. Application of data mining techniques for medical image[C]. Proceedings of the Second International Workshop on Multimedia Data Mining, 2001.
- [16] BURGESS C J C. A tutorial on support vector machines for pattern recognition [J]. *Data Mining and Knowledge Discovery*, 1998, **2**(2):121-167.
- [17] CRISTIANINI N, SHAWA T J. An introduction to support

- vector machines and other kernel-based learning methods [M], Cambridge University Press, 2000.
- [18] KARSSEMEIJER N. Adaptive noise equalization and recognition of microcalcification clusters in mammograms[J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 1993, 7(6):1357-1376.
- [19] SUCKLING J, PARKER J, DANCE D, *et al.* The mammographic images analysis society digital mammogram database[C]. Proceedings of the 2<sup>nd</sup> International Workshop on Digital Mammography, 1994:375-378.
- [20] PAPADOPOULOS A, FOTIADIS D I, LIKAS A. Characterization of clustered microcalcifications in digitized mammograms using neural networks and support vector machines[J]. *Artificial Intelligence in Medicine*, 2005, 34: 141-150.


## Microcalcification Diagnosis Based on Dual-Tree Complex Wavelet Transform

YANG Wei, GAO Xie-ping

(College of Information Engineering, Xiangtan University, Xiangtan, Hunan 411105, China)

**Abstract:** A new diagnosis method of microcalcification is applied based on dual-tree complex wavelet transform. A set of texture features are extracted, including the wavelet based features and gray-level histogram based features. Combining the genetic algorithm to optimize the features, the neural network, support vector machine and KNN classifier are used to distinguish the benign and malignant microcalcifications. The results of the three different classifiers are analyzed, which show that KNN classifier get the best result and support vector outperformed neural network. Compared with the other two classifiers, KNN classifier is a non-training method which can save much training time. It directly computes the distances between samples, which can reduce the adverse effects caused by inefficient selection of features and minimize the error in classification. The KNN classifier depends on a small quantity of samples when kind deciding, which can solve the problem caused by the imbalance of samples. Compared to traditional wavelet basis, the shift invariance and high regularity of dual-tree complex wavelet make it more helpful for direction selection of image signal, and dual-tree complex wavelet transform will get limited redundancy and less amount of calculation.

**Key words:** Microcalcification; Dual-tree complex wavelet transform; Texture feature; Classification



**YANG Wei** was born in 1985. He is a M. S. degree candidate, and his research interests focus on wavelet analysis, machine learning and medical image processing.



**GAO Xie-ping** was born in 1965. He received the Ph. D. degree from Hunan University of China in 2003. Now he is a professor and his current research interests focus on wavelets analysis, neural networks, evolution computation and image processing.