

一种多分类支持向量机在胎盘图像分级中的应用

林升梁 刘志 (浙江工业大学 软件学院 浙江杭州 310032)

摘要:本文通过在超半径的基础上进行优化的方法来确定二叉树的生成算法。实验表明,用该方法得到的二叉树多分类 SVM 在胎盘分级中具有很高的应用价值,具有很好的推广性。

关键词:灰度统计 分形 二叉树 支持向量机(SVM) 胎盘分级

1 引言

本文探索支持向量机^[2,3] (Support Vector Machine, SVM) 在胎盘分级中的应用,首先用灰度统计量分析和分形理论分析来提取胎盘 B 超图像的特征参数,以作为 SVM 的输入向量。因为胎盘分级分为 4 级,是个多分类 SVM 问题,文章采用二叉树多分类 SVM 进行模式分类,用超半径的方法来确定二叉树的节点顺序,并在这基础进行适当的优化去除一些奇异点。通过这样的方法希望能很好对胎盘图像进行自动分级。


总体趋向偏暗。当发育末期为 3 级(如图 2 所示),可以看出不同部位出现了亮点和亮斑,说明已经部分钙化和纤维化了,且图像总体偏亮。根据这样的特点,来确定特征提取的方法,在 ROI 区内进行特征提取,作为以后自动评估的参量。

2.1 灰度统计量特征提取^[4,5]

图像最基本的特征就是其灰度的统计特征,最常用的参数有以下四种:灰度的均值、灰度的方差、灰度的扭曲度和灰度的峰度。

用 200 例胎盘 B 超图(其中 0 级为 5 例,1 级 50 例,2 级 100 例,3 级 45 例)

作为分析对象,计算灰度的均值、方差、扭曲度和峰度。选取其中 4 副图片(如图 1 所示)所得到的四个参数(如表 1 所示)作为分析,图 1 中的图片分别是



(a)3 级图片 (b)2 级图片 (c)1 级图片 (d)0 级图片

图 1 从原始图片截取的 ROI 区域

截取的 ROI 区域,表 1 中所得到的参数就是从该

区域中所提取的。

2 特征提取

在胎盘图像的分级中,首先根据超声成像等知识,从 B 超图像中识别出胎盘的位置(如图 1 和图 2 中白线是医生勾勒出来,其内部区域为胎盘即要分析的区域),确定待分析区域,这个区域也称为感兴趣区域(Region Of Interest, ROI)。医生的人工分析,就是根据这个区域观察钙化程度、纤维化和有无血窦等来判别该胎盘的发育情况,并对其进行分级。发育早期的为 1 级(如图 1 所示),表现为:灰度变化比较小,图像

表 1 4 副不同级胎盘 B 超图用灰度统计量提取的特征参数

特征参数 级别	均值 M	方差 V	扭曲度 S	峰度 K
0 级	30.51035	8.798727	1.55519	-0.13183
1 级	78.67608	12.23819	1.719854	0.974881
2 级	102.4909	14.58082	2.023188	3.160049
3 级	116.9	24.54167	2.490417	5.468193

从表 1 可以看出,用这四个特征参数基本能反映出,各级胎盘图的特点。均值、方差、扭曲度、峰度随着级数的增加其对应的值也相应的增加,也说明了钙化程度、回声和纤维化程度等也随着级数的增加而增强

的特点。为了进一步说明这问题,用全部 200 例各级胎盘图得到的特征参数的均值和方差之间进行比较,如表 2 所示。

表 2 胎盘超声图灰度统计量参数结果的均值与方差

均值 ± 方差	均值 M	方差 V	扭曲度 S	峰度 K
0 级 (5 例)	20.221 28.342 7	11.610 23.154 7	1.342 30.171 2	-0.723 20.418 2
1 级 (50 例)	77.939 327.945 9	15.428 5 7.771 0	1.717 10.395 7	1.011 73.274 5
2 级 (100 例)	105.903 224.950 8	20.759 84.657 2	1.785 70.290 2	1.410 5 2.152
3 级 (45 例)	112.875 936.494 5	25.643 09.192 5	1.947 50.366 0	2.406 52.653 9

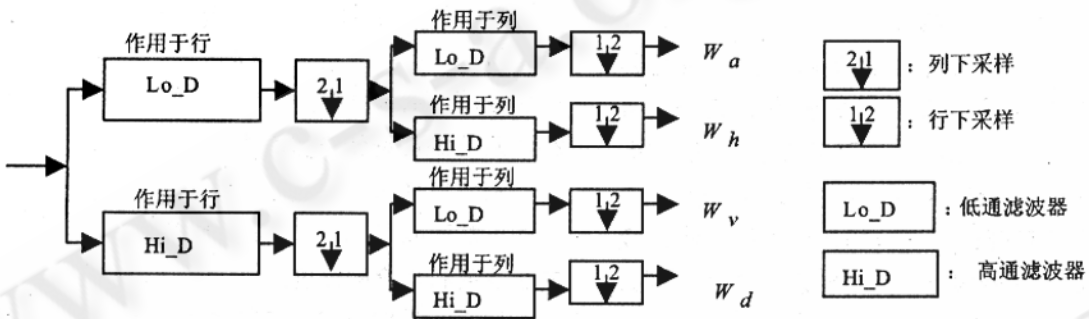


图 2 小波分解算法结构图

从表 2 中可以发现随着胎盘功能级数的增加,参数 M、V、S 和 K 的均值基本呈增加的趋势,这和前面分析是一致的。这表明了:在不同的胎盘功能分级情况下,参数 M、V、S 和 K 能表现胎盘 B 超图的特征,可以作为下一步模式识别的特征参数。

2.2 小波变换特征提取

利用灰度统计量提取图像特征,主要从空域的角度来分析胎盘 B 超图。现利用小波变换 (wavelet transform)^[6,7] 从频域的角度来分析胎盘 B 超图的特征。本文采用的是 SymletsA 小波^[8],它具有比较好的对称性,适合于图像处理。在选取的 ROI 中作一级分解并计算其系数,得到的小波系数为 W_o 、 W_h 、 W_v 、 W_d 。 W_o 主要反映图像的低频率信息, W_h 主要反映水平方向的低频信息和垂直方向的高频信息, W_v 主要反映垂直方向的低频信息和水平方向的高频信息, W_d 主要反映水平方向的高频信息和垂直方向的高频信息 (如图 2 所示)。对得到的 4 个系数矩阵,分别求其均

值为 W_{oe} 、 W_{he} 、 W_{ve} 、 W_{de} ,将其作为胎盘 B 超图特。

同样选取上述胎盘 B 超图进行分析提取参数 W_{oe} 、 W_{he} 、 W_{ve} 、 W_{de} ,其中对于图 1 这 4 副图的特征参数结果如表 3 所示。对于分别属于不同分级的四组数据,统计每组数据的小波参数、和、的均值和方差,如表 4 所示。

表 3 4 副不同级胎盘 B 超图用小波变换提取的特征参数

特征参数 级别	W_{oe}	W_{he}	W_{ve}	W_{de}
0 级	20.13388	3.09585	1.432738	0.53046
1 级	80.19815	7.644444	2.602041	1.664286
2 级	229.7035	7.896759	1.871876	2.21595
3 级	270.8721	9.270655	2.929545	2.223889

表 4 小波变换提取特征参数结果的均值和方差

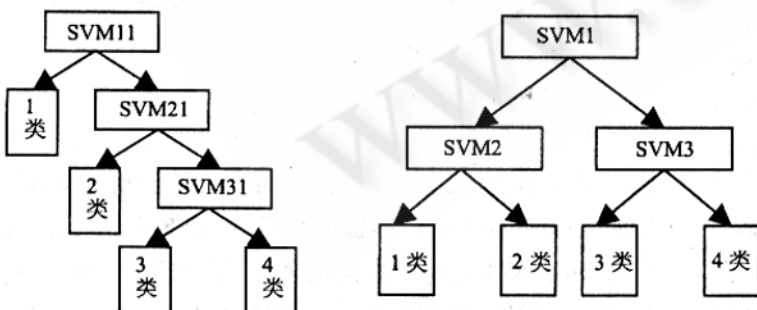
均值 ± 方差	W_{oe}	W_{he}	W_{ve}	W_{de}
0 级 (5 例)	40.680620.5468	4.76761.3282	1.91421.5186	1.43831.0922
1 级 (50 例)	155.283755.6984	5.19293.9261	2.12132.1431	1.85282.6797
2 级 (100 例)	211.251949.7896	5.27731.7961	1.79740.5121	2.29400.4890
3 级 (45 例)	225.162070.3906	6.27543.4535	2.22852.5531	2.82441.1350

从以上两表可以看出,随着胎盘图级数的增加,所得到四个特征参数总体也成增加的趋势。反映了胎盘图钙化程度、纤维化程度等变化的规律,将作为以下识别的输入特征参数。

3 多分类支持向量机(SVM)

支持向量机(SVM)与传统的机器学习相比,它具有更好的泛化能力,具有良好的推广性和较好的分类精确性,能有效的解决过学习问题,现已成为感知器、神经网络的替代性方法。支持向量机(SVM)方法最初是针对二类别的分类提出的,如何将有效的推广到多分类是当前支持向量机研究的重要内容之一。关于一类分类的问题主要有以下几种方法:

一对多方法(one-against-rest),针对不同的个分类,构造个分类器,第 m 个分类器是将第 m 类与其余的分类分开,也就是说将第 m 类重新标号为 1,其他类重新标号为 -1。完成这个过程需要计算个最优化问题,每个子分类器必须都要非常仔细地调整,如果某个分子类器不规范化,则整个分类系统将趋于过学习。



(a) 每个节点都分割出一类 (b) 到末节点处分割出每一类

图 3 两种不同结构的二叉树多分类 SVM

一对一方法(one-against-one),对于任意两个分类,构造一个分类器,仅识别这两个分类,完成这

个过程需要分类器,这样导致计算量就非常大了。

还有一种方法直接用一个优化公式同时考虑所有的子分类器来达到优化参数的目的。这种思想虽然简单,理论上可行,但是要找到这样的优化公式几乎不可能,而且速度上也很慢。特别是样本大子分类多的情况下,这样的问题更加突出了。

3.1 基于二叉树的多分类 SVM

基于二叉树的多分类 SVM 是建立在一对一(one-against-one)的基础上进行改进的。首先是将所有分类分成两个子类,再将子类进一步划分成两个次级子类,如此循环下去,直到所有的节点都只包含一个单独的类别为止。用这样的方法将原有的多分类问题分解成一系列的二类分类问题,其中两个子类间的分类函数采用 SVM。这种方法可避免不可分情况,而且只需构造 -1 个 SVM 分类器,测试时,也不需要计算所有的分类器,可节省测试时间。

基于这样思想的二叉树的结构主要有两种:第一种是在每个节点处,都分割出一个类,也就是有一个类和剩下的类构造分割超平面(如图 3(a)所示,以四类为例);另一种是在节点处不立刻进行分割,而是到在末节点处才分割(如图 3(b)所示,以四类为例)。

以上两种结构都有其各自的特点,本文采用图 4(a)结构的二叉树多分类 SVM。从以上图 4(a)结构图可以知道,分类的精确性跟每个节点 SVM 有关,越上层节点对分类性能的影响越大,这样分类顺序不同将直接影响整个分类器的推广性。比如,对本文胎盘分级来讲,是个 4 类识别问题。用 $1 \text{ 级} \rightarrow 2 \text{ 级} \rightarrow 3 \text{ 级} \rightarrow 0$ 级和 $3 \text{ 级} \rightarrow 2 \text{ 级} \rightarrow 1 \text{ 级} \rightarrow 0$ 级分类顺序来构造分类器得到的推广性是不同的,这就要求把最容易分割的类最早分割出来,即放在二叉树的最上层,依次类

推设置分类顺序。

3.2 基于超半径的二叉树结构

支持向量机分类思想是根据样本空间属性来构造




图 4 超半径及分类顺序

最优化超平面进行分类的,即的样本输入空间属性决定着超平面的确定。所以,为了更好的设置二叉树结构,即更好的确立分割顺序,要分析训练样本几何分布。对于多维数据的真实分布是无法得知的,只能通过样本数据分布的近似估计。超球体积是个很好的度量样本数据的几何分布,体积越大则数据分布越广,分类越容易。而衡量超球体积的量是超半径来确定,也就是说超半径越大超球体积也越大,则样本数据分布越广,分类也就越容易,用超半径来确定分类顺序不失是一个很好的方法(如图 4 所示)。

3.3 基于二叉树多分类 SVM 对胎盘 B 超图的分级

在基于二叉树多分类 SVM 的结构建立起来后,就可以利用第 1 节中得到的特征参数作为 SVM 的输入向量对胎盘 B 超图进行自动识别。本文是用灰度统计量

表 5 二叉树多分类 SVM 对胎盘 B 超图的识别率

训练集 (120 例)	各节点(SVM)	SVM1		SVM2		SVM3	
	参数(c, γ)	(3.1 × 10 ⁷ , 3.1 × 10 ⁻⁷)		(6.3 × 10 ⁵ , 1.5 × 10 ⁻⁵)		(3.1 × 10 ⁻⁴ , 3.1 × 10 ⁶)	
测试集(80 例)		0 级(无)	1 级(30 例)	2 级(30 例)	3 级(20 例)		
	错误数	NA	3	3	2		
	总体识别率	90%					
总体识别率(200 例)		92%					

分析和小波变换来提取胎盘 B 超图的特征参数的,总共有 8 个特征参数。这样,200 例胎盘 B 超图得到的参数集是个 200 × 8 数据阵。将其中 120 例(0 级 5 例,1 级 30 例,2 级 55 例,3 级 30 例)作为训练样本,80 例作为测试样本。首先在训练样本集中,计算各级胎盘 B 超图的超半径确定分类顺序,即 0 级超半径 R1 = 23.4189,1 级 R2 = 143.9037,2 级超半径 R3 = 98.4984,3 级超半径 R3 = 155.2567,则分类顺序为 3 级^{SVM1}→1 级^{SVM2}→2 级^{SVM3}→0 级。然后依此分类顺序建立二叉树多分类 SVM 分类器,每个节点 SVM 的核函数均采用 RBF 核函数(K(X₁, X₁) = exp(-γ||X₁ - X₁||)²)^[1],参数(c, γ)的确定参考《基于 RBF 核函数的 SVM 参数选择》^[12],其中 c 为惩罚因子,γ 为核函数参数。最后用测试样本进行识别来判断基于二叉树多分类 SVM 分类器的推广性(如表 5 所示)。

表 5 首先用 80 例测试样本来识别,最后用全部

200 例胎盘 B 超图作为测试样本,总体识别效果还是比较好的,基本达到预期要求。而如果将分类顺序改成 0 级^{SVM1}→2 级^{SVM2}→1 级^{SVM3}→3 级得到识别效果却不理想。这说明了,用基于超半径的二叉树多分类支持向量机在胎盘 B 超图自动分级的应用有一定的实用价值。

4 总结

本文从空域上和频域上用灰度统计分析和 SymletsA 小波变换来提取图像的特征,得到 8 个参数量作为多分类 SVM 的输入参数,然后用基于超半径的二叉树多分类 SVM 对胎盘进行分级能并得到比较好的推广性。所以,用 SVM 对胎盘图进行分级具有一定的现实意义。

但是,在特征提取方面只是简单的在空域和频域上提取,所以在反映图像特征方面还不是很全面,所以

(下转第 102 页)

(上接第 98 页)

可以在特征提取方面多用些方法,比如纹理特征的提取,从而能全面反映胎盘 B 超图特征。这方面可以作进一步研究。另一方面,文章只是采用了所提出的第一类二叉树结构,在以后的研究中可以用另一类二叉树结构进行优化算法的提取。

参考文献

- 1 Grannum PT, Berkowitz RL, Hobbins JC. The ultrasonic changes in the maturing placenta and their relation to fetal pulmonic maturity [J]. Am J Obstet Gynecol, 1979, 133(4): 915 - 917.
- 2 Vapink V N, The Nature of Statistical Learning Theory [M]. Springer Verlag, New York, Inc, 2000.
- 3 邓乃扬、田英杰, 数据挖掘中的新方法: 支持向量机 [M], 北京: 科学出版社, 2004.
- 4 赵荣椿、赵忠明等, 数字图象处理导论, 西安: 西北工业大学出版社, 1995. 6.
- 5 徐建华, 图像处理与分析, 北京: 科学出版社, 1992.
- 6 M. Unser, A. Aldroubi, A Review of Wavelets in Biomedical Applications, Proceedings of IEEE, 1996, 84(4): 626 ~ 638.
- 7 T. Kalayci, O. Ozdamar, Wavelet Preprocessing for Automated Neural Network Detection of EEG Spikes, IEEE Eng. Med. Bio., 1995, 14(2): 160 ~ 166.
- 8 董长虹, Matlab 小波分析工具箱原理和应用 [M], 北京: 国防工业出版社, 2005. 7.