

# 基于对称性理论的医学图像多阶段分类算法

荣晶施<sup>1)</sup> 潘海为<sup>1)</sup> 高琳琳<sup>1)</sup> 韩启龙<sup>1)</sup> 冯晓宁<sup>1)</sup> 李 青<sup>2)</sup>

<sup>1)</sup>(哈尔滨工程大学计算机科学与技术学院 哈尔滨 150001)

<sup>2)</sup>(香港城市大学计算机科学与技术系 香港)

**摘 要** 利用影像归档和通信系统收集的大量医学 CT 图像被广泛应用于临床诊断,从中提取的 ROI 区域和 ROI 区域的特征可以用来对医学 CT 图像进行分类,从而辅助医生提高诊断精度.医学图像的成像结果显示一张医学图像关于中垂线两侧近似对称.基于这一脑部医学领域知识的指导,文中提出了基于对称性理论的医学图像多阶段分类(Multi-Stage Classification, MSC)方法.首先,文中提出了弱对称性和强对称性的定义,从不同粒度对医学图像的对称性进行了描述;然后,给出了基于灰度直方图相交性的弱对称性判定算法,对医学图像在较粗粒度上进行了第 1 阶段的分类;接着,提出了基于点对称的强对称性判定算法,结合弱对称性判定算法,对第 1 阶段分类结果为异常的图像进行了更细粒度的第 2 阶段分类,定位了病变区域的位置;最后,利用对病变区域所提取的特征,对病变区域进行了第 3 阶段的分类,以达到辅助医生诊断的效果.实验结果表明,基于对称性理论的医学图像多阶段分类方法提高了医学图像分类的准确度,同时减少了医生诊断决策的时间.

**关键词** 医学图像;弱对称性;强对称性;多阶段分类

中图法分类号 TP391 DOI号 10.11897/SP.J.1016.2015.01809

## Medical Image Multi-Stage Classification Algorithm Based on the Theory of Symmetric

RONG Jing-Shi<sup>1)</sup> PAN Hai-Wei<sup>1)</sup> GAO Lin-Lin<sup>1)</sup> HAN Qi-Long<sup>1)</sup> FENG Xiao-Ning<sup>1)</sup> LI Qing<sup>2)</sup>

<sup>1)</sup>(College of Computer Science and Technology, Harbin Engineering University, Harbin 150001)

<sup>2)</sup>(Department of Computer Science, City University of Hong Kong, Hong Kong)

**Abstract** A large number of medical CT images collected by PACS are widely used in clinical diagnosis. ROI and the features of ROI extracted from CT images can be utilized to classify these medical images so as to assist doctors to improve the efficiency and precision of the diagnosis. Brain imaging shows that it is approximately symmetrical about the brain stem. Based on this practical knowledge guidance, a medical image multi-stage classification (MSC) based on the theory of symmetry is presented in this paper. First of all, weak symmetry and strong symmetry is defined to describe the symmetry from the different granularities. Then, the weak symmetry decision algorithm was given to finish the first-stage classification for medical image in the coarse granularity. Further, the strong symmetry decision algorithm based on the point symmetry is proposed, combining with the weak symmetry decision algorithm, to complete the second-stage classification for the abnormal images classified from the first-stage in the fine granularity in order to locate lesion area. Finally, the features extracted from the lesions are used for the third-stage

收稿日期:2014-05-07;最终修改稿收到日期:2015-04-30.本课题得到国家自然科学基金(61272184,61202090,61100007)、新世纪优秀人才支持计划(NCET-11-0829)、中央高校自由探索计划项目(HEUCF100602,HEUCFT1202)资助.荣晶施,女,1988年生,硕士研究生,主要研究方向为数据挖掘、多媒体数据挖掘. E-mail: rongjingshi1988@sohu.com.潘海为(通信作者),男,1974年生,博士,副教授,主要研究方向为数据挖掘、数据库技术、智能信息处理. E-mail: panhaiwei@hrbeu.edu.cn.高琳琳,女,1989年生,博士研究生,主要研究方向为数据挖掘、多媒体数据挖掘.韩启龙,男,1974年生,博士,副教授,主要研究方向为时空数据挖掘、图挖掘、隐私保护.冯晓宁,男,1976年生,博士,副教授,主要研究方向为数据库、数据挖掘、软件工程.李青,男,1962年生,博士,教授,主要研究领域为对象建模技术、多媒体数据库、社交网络、推荐系统.

classification to help the doctor's diagnosis. Experimental results show that multi-stage classification method based on the theory of symmetry can increase the accuracy of the classification and reduce the time of the doctor's diagnosis.

**Keywords** medical image; weak symmetry; strong symmetry; multi-stage classification

## 1 引 言

由于医学图像中蕴含着丰富的图像和医学信息,近年来面向医学图像的数据挖掘技术成为医学和计算机交叉学科研究的热点.随着医疗数字化设备的快速发展,医学信息数据库被广泛使用.病人的结构化文本信息以及大量的非结构化医学图像信息,为医学图像的数据挖掘提供了丰富的数据资源.医学图像可以有效地辅助医师在诊断过程中对病理变化区域进行检测、定位以及判断它的良恶性,因此被广泛应用于临床诊断过程中.人体的对称性不但体现在外形上,而且在身体器官和人体组织成像上也体现出近似的对称性.如果某一个人的某种器官与其他人的相同器官进行对比,表现出更不对称的结构,那么就认为这是一种病理学的症状.因此在医学诊断和临床应用中,对称性理论有很重要的价值,即通过观察医学图像的对称性可以辅助医生诊断和决策.然而,具有不同知识背景的医生即使对同一张医学图像也可能存在不同的判断.所以,运用数据挖掘方法研究医学图像分类算法,对辅助医生根据医学图像进行诊断,提高其效率和精度,具有较高的学术价值和实际应用前景.

目前,国内外在医学图像分类研究方面,常用的分类方法有神经网络、朴素贝叶斯、遗传算法和决策树算法等.Chen 等人<sup>[1]</sup>利用贝叶斯分类器对多类文本数据集进行分类,该分类方法对特征选择高度敏感.Yang 等人<sup>[2]</sup>利用贝叶斯随机变量选择方法对大量的基因数据进行分类.Osman 等人<sup>[3]</sup>在乳腺癌分类研究中应用了神经网络和关联规则挖掘技术.Mitsuru 等人<sup>[4]</sup>提出了应用逻辑回归算法提取关联规则,挖掘出脑部功能与手指活动和肢体行为之间的关系.Rajendran 等人<sup>[5]</sup>基于决策树使用关联规则挖掘算法的混合医学图像分类,从脑图像中挖掘频繁模式,基于这些频繁模式将脑图像进行分类.Al-Hadidi 等人<sup>[6]</sup>提出一个基于神经网络的改进技术混合人工神经网络方法来分离乳腺癌,模拟结果表明混合人工神经网络技术有很高的灵敏度和特异性,但神经网络分类器的分类结果是在训练时间上将

比其他分类器消耗更多的时间<sup>[7]</sup>.Qurat-Ul-Ain 等人<sup>[8]</sup>应用纹理的灰度共生矩阵将脑肿瘤进行分割和分类.Saha 等人<sup>[9]</sup>利用模糊对称性对磁共振脑图像进行分割和聚类.Fallahi 等人<sup>[10]</sup>将形态学的方法应用到分类特征的提取上(SVM with Morphological operations, SVM-MPO),将脑部 CT 图像分为两类:正常和异常,并与很多现有的分类方法做了分类准确率的对比.Saha 等人<sup>[11]</sup>应用快速边界盒方法(Fast Bounding Box, FBB)定位 MRI 中肿瘤和水肿的位置.Nanthagopal 等人<sup>[12]</sup>利用二级小波纹理图像(Wavelet Statistical Texture feature, WST)提取游程矩阵和灰度共生矩阵共 6 个特征作为将肿瘤分类为良恶性的特征.

本文提出了基于对称性理论的医学图像多阶段分类(Multi-Stage Classification, MSC)方法.首先,本文提出了弱对称性和强对称性的定义,从不同粒度对医学图像的对称性进行了描述;然后,给出了基于灰度直方图相交性的弱对称性判定算法,对医学图像在较粗粒度上进行了第 1 阶段的分类;接着,提出了基于点对称的强对称性判定算法,结合弱对称性判定算法,对第 1 阶段分类结果为异常的图像进行了更细粒度的第 2 阶段分类,定位了病变区域的位置;最后,利用对病变区域所提取的特征,对病变区域进行了第 3 阶段的分类,以达到辅助医生诊断的效果.实验结果表明,基于对称性理论的医学图像多阶段分类方法提高了医学图像分类的准确度,同时减少了医生诊断决策的时间.

本文第 2 节为医学图像的预处理过程;第 3 节介绍本文的基本概念:弱对称性和强对称性等;第 4 节提出弱对称性判定算法和强对称性判定算法;第 5 节医学脑部 CT 图像多阶段分类器的构造;第 6 节实验结果分析;第 7 节总结本文.

## 2 预处理过程

通过对大量脑部 CT 图像的观察得知,脑部 CT 图像具有以下特点:CT 图像是由一定数目由黑到白不同灰度的像素按矩阵排列所构成;健康脑部图像的左右两侧灰度值分布近似相似;相似图像在相

近位置具有相似的纹理信息. 图 1(a)是一张原始的脑部 CT 图像, 医生在根据脑部 CT 图像做诊断的过程中, 往往认为图像中较暗和较亮区域的变化是最为重要的. 根据这一医学领域知识, 本文给予这些区域更多的关注.

假设一张脑部 CT 图像  $M$  包含  $m \times n$  个像素点,  $M(i, j)$  是图像  $M$  位于坐标  $(i, j)$  的像素点的灰度值.  $M(i, j)$  的值越小, 表示图像  $M$  位于坐标  $(i, j)$  的灰度值越小(即越黑), 也就表明位置  $(i, j)$  在图像  $M$  中更为重要. 本文借鉴了本组内的医学图像的分级纹理提取算法<sup>[13]</sup>. 以图 1 中的图像为例, 图 1(a)是原始脑部 CT 图像, 首先提取图 1(a)的 ROI 区域得到图 1(b), 从而去除脑部 CT 图像中无用或干扰区域. 然后通过计算 ROI 区域的灰度直方图的波峰、波谷自动得到分级数组  $par[k]$ . 按照  $k$  层分级数组使用 canny 算法<sup>[14]</sup>得到的分级纹理图像. 图 1(c)是经过校正<sup>[15]</sup>的分级纹理图像. 最后, 为了便于后续的建模和分类过程, 将该分级纹理图像规范化为统一大小  $Column \times Row$  的规范化大小纹理图像, 如图 1(d)所示. 根据对原始图像数据集规格的统计, 本文采用  $Column=160, Row=150$ .

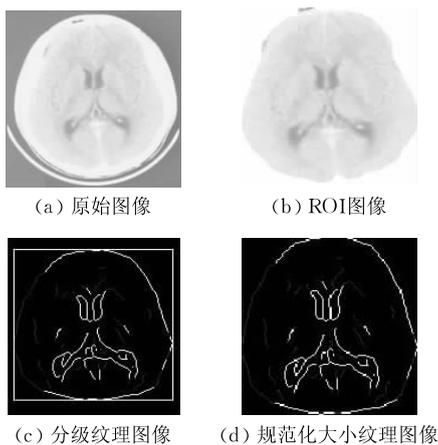


图 1 预处理过程

Pan 等人<sup>[16]</sup>提出了一种基于脑部 CT 图像的纹理特征的不确定定点图的模型. 一个不确定定点图(Uncertain Location Graph, ULG)是一个五元组  $N=(V, E, U, P, Q)$ , 其中  $V$  是顶点集,  $E$  属于  $V \times V$  的边集,  $U: V \rightarrow \{1, 2, 3, \dots, n\}$  为顶点分配标签函数,  $P: V \rightarrow [0, 1]$  是点的重要性指数函数,  $Q = \{Q(1), Q(2), \dots, Q(m)\}$  是  $V$  的一个划分, 其中  $Q(i)$  是  $V$  的真子集. 在 ULG 中, 点  $V(i) \in V$  的位置  $(x, y)$  具有不确定性, 且其不确定性依赖于  $P(V(i))$ . 当一个点对于整个图较为重要时(即若该点移动, 则会严重影响原图), 那么该点具有较高的  $P(V(i))$ . 当一个点不重要时(即使它有较大的移动也不会对原图构

成影响)这样的点具有较低的  $P(V(i))$ . 因为点的重要性与点的可移动性成反比, 所以, Quddus 等人<sup>[17]</sup>定义点的可移动性半径  $mob$  如下:

$$mob(V(i)) = 1/P(V(i)) \quad (1)$$

人类大脑可以分为两个半球, 两侧具有近似对称性, 在一侧的大多数结构相应的在另一侧相近位置存在相似结构. Ruppert 等人<sup>[18]</sup>通过实验证明在 MRI 中, MRI 图像切片的对称轴即为纵向裂缝的位置, 由于肿瘤的存在, 大脑的一侧受到压缩, 使裂缝发生弯曲但不会影响到中垂线的选取<sup>[19]</sup>. Tuzikov 等人<sup>[20]</sup>应用块匹配算法和最小二乘法找出 MR 图像的中垂线, 大量实验结果证明纵向裂缝的位置可以定义为中垂线. 通过对大量健康脑 CT 图像的观察, 近似中垂线位置的定义可以应用 Ruppert 和 Tuzikov 等人提出的方法. 视觉上左右半球可以由纵向裂缝分割, 纵向裂缝是充满脑髓脊液的脑干形成的. 因此分离图像为左右两侧可以通过沿裂缝定义一个中垂线. 事实上, 纵向裂缝通常是弯曲的, 主要是因为脑部肿瘤的存在, 但定位近似中垂线足够可以标记出肿瘤和不对称性<sup>[21-22]</sup>. 如图 2 所示, 其中图 2(a)是脑部 ROI 区域, 图 2(b)是图 2(a)的规范化后的纹理图像, 图 2(c)是图 2(a)的关于中垂线对称分割后的图像, 图 2(d)是图 2(b)的关于中垂线对称分割后的图像.

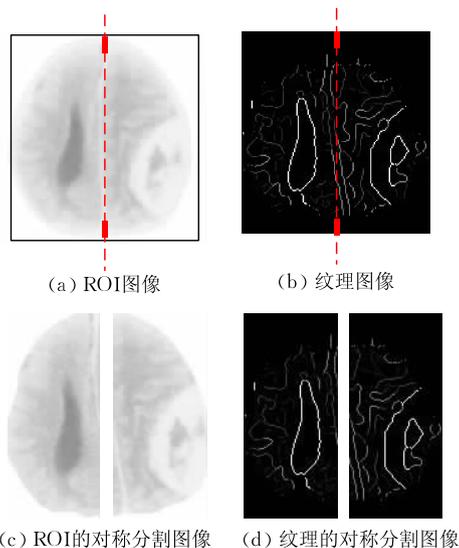


图 2 中垂线对称分割的过程

### 3 基本概念

根据医学脑部 CT 图像的特征可知, 正常脑部 CT 图像中存在的结构关于对称轴是近似对称的, 经过预处理后得到的纹理图像显示的纹理信息也是

近似对称的<sup>[23]</sup>. 如果脑部 CT 图像发生病变, 那么就会引起这种近似对称结构的改变, 由于病变区域的存在使其内部结构存在不对称性<sup>[24]</sup>. 本文给出医学图像的定义, 结合医学图像的定义提出了弱对称性和强对称性的概念.

脑部图像发生病变后有这样一个常识, 正常脑部图像左右两侧的结构是近似对称的. 如果一侧出现病变, 在形状上另一侧也会发生相应的变化, 如挤压变形、覆盖变小等. 我们称病变的脑部图像为异常图像, 病变的区域称为异常区域. 是否出现异常区域是区别正常脑部图像和异常脑部图像的关键. 在正常脑部图像中不会出现异常区域, 而异常图像中一定会出现异常区域. 根据这一医学常识我们给出了医学图像的定义.

**定义 1.** 一个医学图像  $MI$  (Medical Image) 是一个集合  $G = \{(L, R, T) \mid L = \{v_1, v_2, \dots, v_n\}, n$  是  $MI$  左侧像素点的个数,  $v_i \in [0, 255]$ ,  $R = \{u_1, u_2, \dots, u_m\}, m$  是  $MI$  右侧像素点的个数,  $u_i \in [0, 255]$ ,  $T = \{w_1, w_2, \dots, w_p\}, 0 < p < n$  或  $0 < p < m, w_i \in [0, 255]\}$ .

其中  $L$  和  $R$  分别是  $MI$  被中垂线垂直平分后左侧和右侧像素的集合.  $T$  是  $MI$  中异常区域的像素集合,  $T \subseteq R$  或  $T \subseteq L$ . 若  $MI$  是正常的, 则  $T$  集合为空; 否则  $T$  集合不空.

在  $G$  中, 由于器官中的某些基因出现异常, 当正常细胞的染色体碰上了这一基因就能诱使细胞发生异常繁殖, 阻碍正常细胞的生长, 从而异常的一侧细胞迅速生长, 而另一侧则由于挤压覆盖等原因阻碍了正常细胞的生长, 使其被动发生形变. 由于  $T$  区域的存在使  $L$  和  $R$  集合发生变化. 这一医学知识体现在图像上即是异常的一侧像素集合发生较大变化, 而非异常的一侧像素集合发生的变化较异常的一侧小. 图 3(a) 为正常的医学脑部图像关于脑中垂线垂直平分分为  $Left$  和  $Right$  两部分, 在  $G$  中  $L$  和  $R$  集合中像素的分布均匀. 图 3(b) 为异常脑部图像示例, 我们可以发现在  $G$  中存在一个异常区域  $T$  集合. 由于  $T$  集合的存在,  $G$  中  $L$  和  $R$  集合中像素的

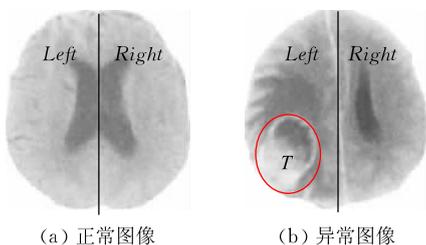


图 3  $MI$  图像模型

分布存在很大的差异.

**定义 2.** 在异常图像  $AMI$  (Abnormal Image) 中, 若  $T \subseteq L$ , 则  $AMI$  的左侧发生的变化称为主动变化, 右侧发生的变化称为被动变化; 若  $T \subseteq R$ , 则  $AMI$  的右侧发生的变化称为主动变化, 左侧发生的变化称为被动变化.

定义 2 是对  $G$  中的异常图像  $AMI$  主动变化和被动变化的定义. 在图 3(b) 中,  $L$  和  $R$  像素集合差别很大, 导致  $T$  区域的存在.  $T \subseteq L$ , 即异常出现在左侧, 所以图 3(b) 中左侧发生的变化就是主动变化, 右侧是被动变化. 如何确定  $G$  中  $L$  和  $R$  像素集合的差别呢? 设  $D(X)$  是一个像素集合  $X$  的含有  $K$  个组距的灰度直方图, 下面给出弱对称性的定义.

**定义 3.** 对于一个医学图像  $G$ , 弱对称性是指  $G$  中  $D(L)$  和  $D(R)$  在每个组距  $K$  中共有的像素数目, 用它们相交的距离来衡量弱对称性

$$d(L, R) = \sum_{i=1}^K \min(D(L), D(R)) \quad (2)$$

其中, 组距  $K$  是直方图每组的宽度.

图 4 为图 3(a) 中  $Left$ 、 $Right$  部分图像的灰度

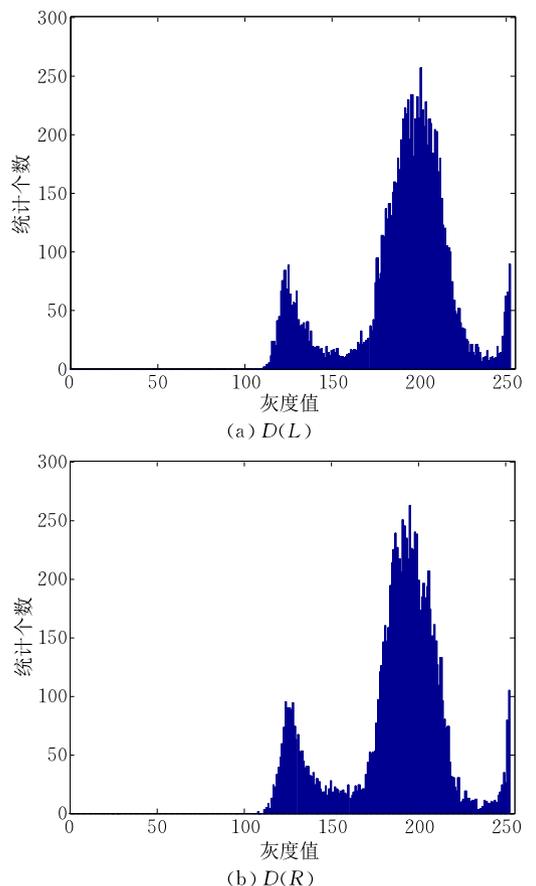


图 4 图 3(a) 中  $L$  和  $R$  的直方图

直方图. 横坐标表示灰度值的分布, 取值范围 $[0, 255]$ , 纵坐标表示在某一灰度值上像素点的个数  $K$ . 根据式(2)可以得知  $L$  和  $R$  的像素集合相交的距离. 弱对称性  $d(L, R)$  越大说明  $L$  和  $R$  相交的部分越多, 差别越小. 弱对称性  $d(L, R)$  越小说明  $L$  和  $R$  相交的部分越少, 差别越大.

在  $G$  中包括正常的医学图像  $NMI$  (Normal Medical Image) 和异常的医学图像  $AMI$  (Abnormal Medical Image), 怎么对它们进行区分呢, 下面的性质给出  $NMI$  和  $AMI$  中主动变化和被动变化的关系.

**性质**(主动变化和被动变化的关系). 主动变化和被动变化的关系存在于  $NMI$  和  $AMI$  弱对称性的对比中, 且主动变化小于被动变化.

主动变化和被动变化的关系如图 5 所示. 图 5(a) 是  $NMI$ , 图 5(b) 是  $AMI$ . 图 5(c)、(d) 是图 5(a) 左侧和右侧的直方图, 图 5(e)、(f) 是图 5(b) 左侧和右侧的直方图. 若已知  $NMI$  的左侧和右侧像素集合为  $L$  和  $R$ ,  $AMI$  的左侧和右侧像素集合为  $L'$  和  $R'$ . 定位异常区域  $T \subseteq L$  或  $T \subseteq R$  应用式(3).

$$val = d(L, L') - d(R, R') \quad (3)$$

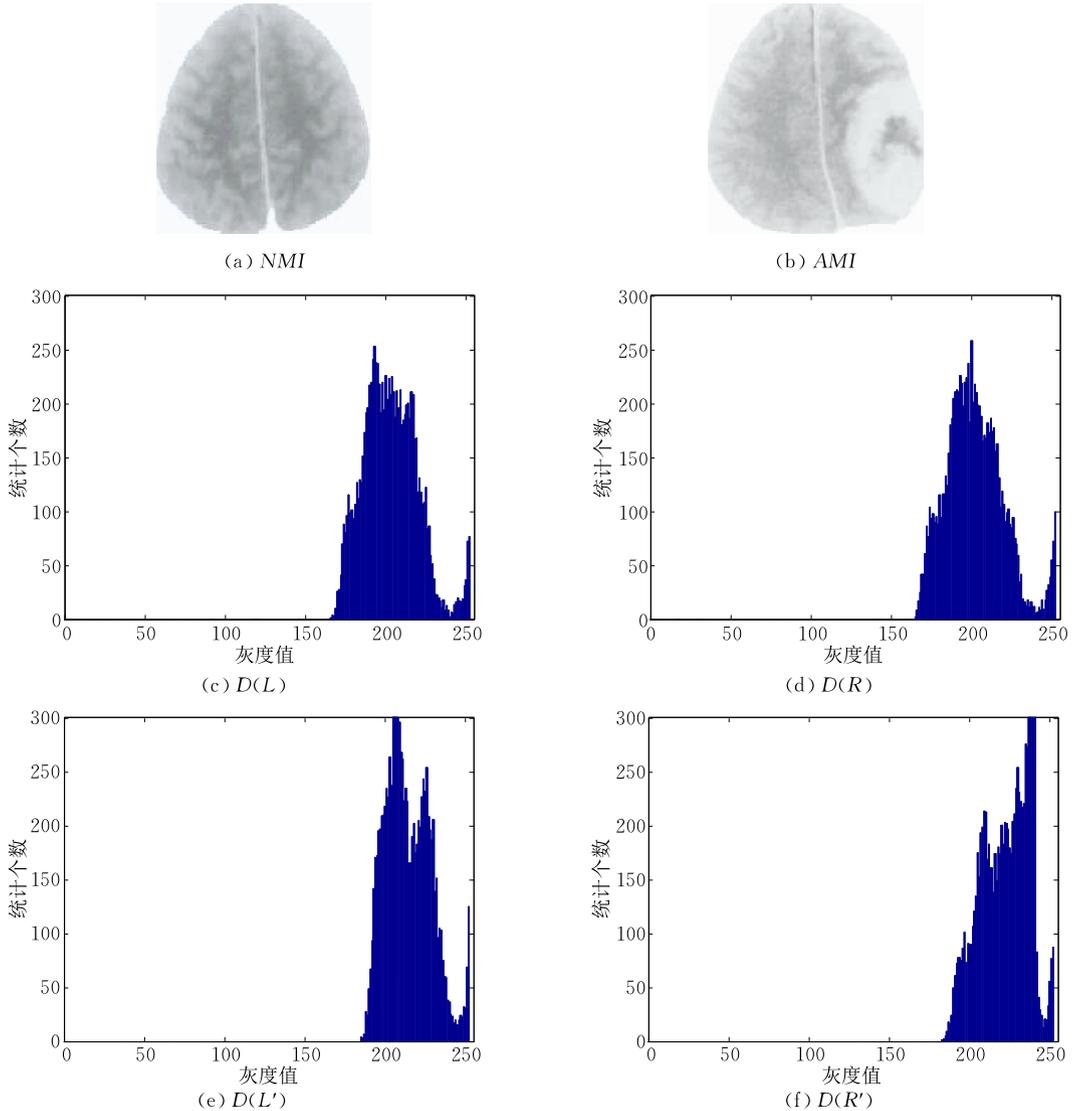


图 5 主动变化和被动变化示例

结合定义 2 和性质, 若  $val < 0$ , 则  $AMI$  的  $L'$  中发生的是主动变化,  $R'$  发生的是被动变化. 那么  $T$  区域存在于  $AMI$  的  $L'$  中. 否则当  $val > 0$ ,  $T$  区域存在于  $R'$ . 根据主动变化和被动变化的关系可以定位灰度级医学图像中异常区域  $T$  的位置. 根据式(3), 图 5 中 (a) 和 (b) 的  $val > 0$ , 即  $T$  区域出现在图 5(b) 的右侧.

医学图像的纹理图像由多条纹理组成, 每条纹理由若个点组成.  $NMI$  对应的纹理图像关于脑中垂线垂直平分后的左右两侧近似对称, 根据这一原理给出了强对称性的定义.  $AMI$  的纹理图像中, 发生主动变化的一侧呈现的纹理条数比被动变化的一侧纹理条数多.

**定义 4.** 一个纹理图像  $TI$  (Texture Image) 是一个集合  $F = \{(Lh, Rh) | Lh = \{Lh_1, Lh_2, \dots, Lh_n\}, Lh_i$  是  $Lh$  中的第  $i$  条纹理,  $Lh_i = \{v(1), v(2), \dots, v(n)\}, v(i)$  表示组成  $Lh_i$  纹理的点.  $Rh = \{Rh_1, Rh_2, \dots, Rh_n\}, Rh_i$  是  $Rh$  中的第  $i$  条纹理,  $Rh_j = \{v(1), v(2), \dots, v(m)\}, v(i)$  表示组成  $Rh_i$  纹理的点}, 其中  $Lh$  和  $Rh$  是关于中垂线垂直平分的左侧和右侧纹理的集合.

在纹理图像  $TI$  中, 以组成纹理的点  $v(i)$  为圆心, 点  $v(i)$  的可移动性  $mov(v(i))$  为半径做圆. 在圆内或圆上的点都认为是与该点对称的. 下面给出强

对称性的定义.

**定义 5.** 强对称性是指  $TI$  中圆内或圆上的点的个数的多少, 用它们的半径范围来衡量强对称性  $rad(v(i)) = mov(v(i))$ .

图 6(a) 是一个纹理图像  $TI$ , 图 6(b) 和图 6(c) 是图 6(a) 的局部放大图且关于中垂线对称. 选择  $TI$  中纹理点多的一侧即左侧作为模板, 根据强对称性的概念标记每个点的  $rad(v(i))$ , 如图 6(d) 所示, 图中用不同颜色的点表示点的重要性指数不同. 图 6(f) 是图 6(d) 关于中垂线的对称图. 图 6(g) 是强对称性  $rad(v(i))$  的示例图.

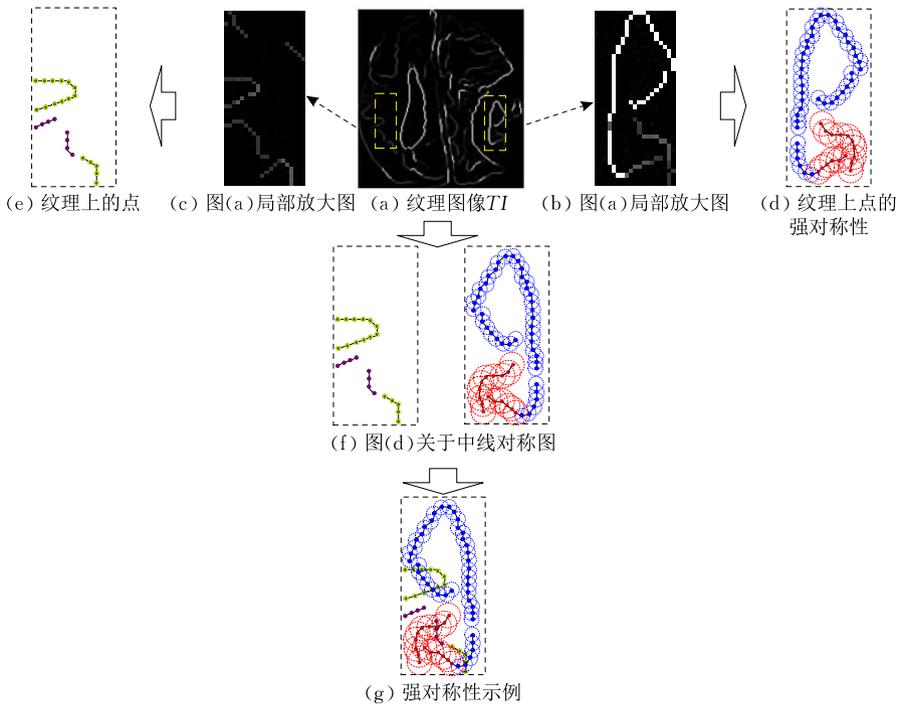


图 6 强对称性示例

算法 1 是在纹理图像中, 根据强对称性  $rad(v(i))$  消去纹理上的点的消去算法. 消去算法的主要思想是计算  $Lh$  和  $Rh$  点的个数, 其中以点的个数多的一侧作为模板. 计算出模板中每个点的强对称性, 落在强对称性范围内的点都认为是与该点近似对称的. 消去算法的输入是纹理图像  $TI$ , 输出为纹理图像左右两侧剩余点的个数. 纹理图像中纹理点的消去算法的伪代码见算法 1.

**算法 1.** 纹理点的消去算法.

输入: 纹理图像  $TI$

输出: 纹理点的个数  $suml$  和  $sumr$

1. 将  $TI$  关于中垂线分割为  $L_h$  和  $R_h$
2.  $H(i, j) = \delta$  //  $H(i, j)$  是纹理图像中纹理点的灰度值的阈值
3.  $suml = 0; sumr = 0$  //  $suml, sumr$  分别统计左侧和右侧纹理图像中纹理点的个数

4. 遍历左侧图像  $L_h$
5. IF  $Tl(i, j) \neq 0 \& \& Tl(i, j) > \delta$   
//  $Tl(i, j)$  是  $L_h$  位于坐标  $(i, j)$  的像素点的灰度值
6.  $suml++$
7. END IF
8. 遍历右侧图像  $R_h$
9. IF  $Tr(m, n) \neq 0 \& \& Tr(m, n) > \delta$   
//  $Tr(i, j)$  是  $R_h$  位于坐标  $(i, j)$  的像素点的灰度值
10.  $sumr++$
11. END IF
12. 比较  $suml$  和  $sumr$  的大小
13. 将  $suml$  和  $sumr$  中值较大的一个赋给  $tem$ , 并作为模板
14. 计算模板  $tem$  中每个纹理点的强对称性  $rad(v(i))$
15. 在非模板中将  $rad(v(i))$  范围内的点  $Tr(i, j) = 0$

或  $Tl(i, j) = 0$

16. 循环步 4 到步 15, 统计纹理点消去后  $suml$  和  $sumr$  的值

根据算法 1, 将  $rad(v(i))$  范围内的点消去后, 统计左侧和右侧剩余点的个数  $suml$  和  $sumr$ . 图 7(a) 是强对称性示例图, 图 7(b) 和图 7(c) 分别是根据消去算法将  $rad(v(i))$  范围内的点消去后左侧和右侧剩余的点  $suml$  和  $sumr$ .

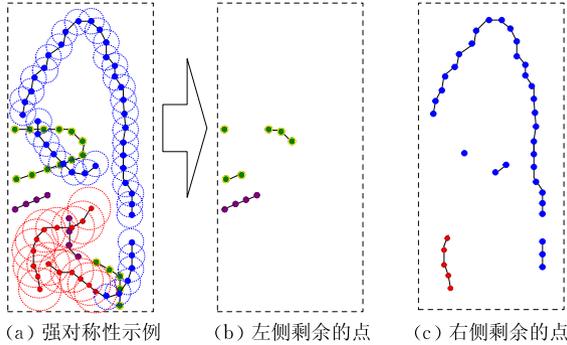


图 7 消去算法示例

## 4 对称性判定算法

根据强对称性和弱对称性的概念, 引出强对称性判定算法和弱对称性判定算法. 结合两个判定算法对医学图像实现多阶段的分类.

### 4.1 弱对称性判定算法

对于  $G$  来说, 像素的分布是很重要的特征. 通过弱对称性  $d(L, R)$  判断  $T$  区域是否存在, 其可以判定医学图像是否正常. 对于  $T$  区域存在的图像应用第 3 节中的性质比较  $NMI$  和  $AMI$  中主动变化和被动变化的关系. 已知  $L$  和  $R$  是  $NMI$  中的左侧和右侧像素的集合,  $L'$  和  $R'$  是  $AMI$  中左侧和右侧像素的集合. 计算  $L$  和  $L'$  的弱对称性  $d(L, L')$  与  $R$  和  $R'$  的弱对称性  $d(R, R')$ , 若  $d(L, L') < d(R, R')$ , 则在  $L$  和  $L'$  中像素分布发生的变化大于  $R$  和  $R'$  中像素分布发生的变化, 表明  $T$  区域出现在  $AMI$  的  $L'$  中, 即  $T \subseteq L$ . 否则出现在  $AMI$  的  $R'$  中, 即  $T \subseteq R$ . 基于灰度图像的弱对称性判定算法描述如下.

**算法 2.** 弱对称性判定算法 (WSDA).

输入: 输入图像  $L$  和  $R$ , 病人在同一时期拍摄的图像分割后的左右两部分  $L'$  和  $R'$

输出: 异常区域  $T \subseteq L$  或  $T \subseteq R$  的值  $val$

1. 计算  $L$  和  $R$  的直方图  $D(L)$  和  $D(R)$
2. 根据弱对称性的定义求出  $d(L, R)$  的值
3. IF  $d(L, R) > \epsilon$
4. output: 输入的图像为正常的医学图像

5. ELSE

6. output: 输入的图像中存在异常区域  $T$ , 即异常的医学图像

7. IF 异常图像

8. THEN 计算异常图像左侧和右侧的直方图  $D'(L)$  和  $D'(R)$

9. 根据弱对称性的定义, 计算  $L$  和  $L'$  的  $d(L, L')$  值  $dl$  和  $R$  和  $R'$  的  $d(R, R')$  的值  $dr$

10. 异常区域  $T \subseteq L$  或  $T \subseteq R$  的值  $val$

11. END IF

算法 2 描述了弱对称性的判定算法, 其中步 1 到 6 实现了医学图像粗粒度的第 1 阶段的分类, 第 5 节将详细描述如何利用弱对称性判定算法实现医学图像的多阶段分类. 算法 2 实现了在灰度图像上对异常区域定位的功能, 但是由于灰度图像中的灰度信息不能很好的捕捉图像中的局部属性, 所以 4.2 节给出强对称性判定算法进一步确定医学图像上异常区域  $T$  的位置.

### 4.2 强对称性判定算法

由于弱对称性特征对图像或图像区域的方向、大小、位置等变化不敏感, 所以弱对称性特征不能很好地捕捉图像中对象的局部属性. 本文提出图像的强对称性判定算法可以解决这一问题. 与灰度直方图特征不同, 纹理特征不是基于像素点的特征, 它需要在包含多个像素点的区域中进行统计计算. 纹理特征能局部的定位图像中灰度级像素点的位置. 每一条纹理都是由灰度剧烈变化的点组成的, 通过强对称性的定义来判断纹理图像的整体对称性. 纹理上每个点  $v(i)$  关于中垂线垂直平分映射到另一侧的点  $v'(i)$ , 根据强对称性的定义可以得出点  $v'(i)$  的可移动范围. 那么在可移动范围内的点都认为是与原点对称的.

纹理图像集合  $F = \{Lh, Rh\}$  中, 正常医学图像的纹理图像中  $Lh$  和  $Rh$  是近似对称的. 如果出现病变区域  $T$ , 那么  $T$  的一侧纹理条数将较多, 即组成纹理的点数增多. 根据这一性质, 算法 3 给出了强对称性判定算法的算法描述. 扫描  $Lh$  和  $Rh$  中组成纹理的点的个数, 假设以点的个数多的一侧作为第 1 次的模板. 关于对称轴映射到另一侧应用算法 1 消去所有在可移动范围内的点. 第 1 次消去后剩余的点  $markf = suml - sumr$ . 然后计算  $Lh$  和  $Rh$  中剩余的点的个数, 以非模板的一侧作为第 2 次的模板消去另一侧的点. 第 2 次消去后剩余的点  $markl = suml - sumr$ . 比较两侧剩余点的个数  $sum = markf + markl$ , 若  $sum \geq 0$  说明左侧存在  $T$  区域,  $sum < 0$  说

明右侧存在  $T$  区域. 这就是基于纹理图像的强对称性判定算法的基本思想. 算法 3 给出了强对称性判定算法的算法描述.

### 算法 3. 强对称性判定算法(SSDA).

输入: 纹理图像  $L_h$  和  $R_h$

输出: 剩余点的个数  $sum$

1. 对纹理图像  $L_h$  和  $R_h$  预处理, 消去纹理图像的最外边缘得  $L'_h, R'_h$
2. 遍历  $L'_h$  和  $R'_h$  图像中所有组成纹理的点的个数分别为  $sum\_image\_1$  和  $sum\_image\_2$
3. 比较  $sum\_image\_1$  和  $sum\_image\_2$  的大小, 以点数多的一侧作为模板, 即模板中的点数为  $model$
4. 利用算法 1 消去计算  $sum_l$  和  $sum_r$  的值
5.  $markf = sum_l - sum_r$
6. 以非模板作为新的模板, 新模板中的点数为  $unmodel$ . 再次执行算法 1 计算  $sum_l$  和  $sum_r$  的值
7.  $markl = sum_l - sum_r$
8. 剩余点的个数  $sum = markf + markl$

算法 3 中, 输出强对称性判定结果剩余纹理点的个数  $sum$ . 通过对标签数据的学习得知当  $sum \geq 0$  说明  $T$  区域在  $L_h$  中的可能性较大, 而  $sum < 0$  说明  $T$  区域在  $R_h$  中的可能性较大.

## 5 多阶段分类器的构造

通过对医生的调查得知, 其利用医学图像进行诊断的过程为: 首先根据医生的医学知识判断该医学图像  $MI$  是否正常. 其次, 对  $AMI$  继续研究, 根据医生的临床诊断经验判断异常出现在  $Left$  或者  $Right$  中. 最后, 对  $AMI$  中的区域  $T$  做进一步的研究, 根据医生以往的诊断经验判断  $T$  区域的良恶性. 本文模拟医生的诊断过程提出了  $MI$  多阶段分类器 (Multi-Stage Classification, MSC) 的分类方法, 其实现过程如图 8 所示.

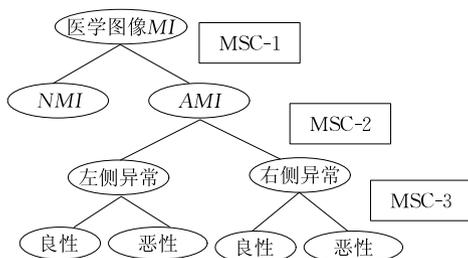


图 8 多阶段分类器的分类阶段

MSC-1. 应用 WSDA 对医学图像  $MI$  进行了第 1 阶段分类, 即对  $MI$  分类为  $NMI$  和  $AMI$ .

MSC-2. 对标记为异常的图像  $AMI$  进一步处理得到对应的纹理图像  $F$ , 同时应用 WSDA 和 SSDA 判断出异常区域  $T$  在医学图像中的左侧或者右侧.

MSC-3. 本文根据异常区域  $T$  的边缘轮廓等信息, 提取  $T$  的多个特征实现对  $AMI$  进行良恶性分类.

### 5.1 医学图像正异常分类方法(MSC-1)

医生判断一个  $MI$  的正异常是根据他们的诊断经验通过  $MI$  左右两侧视觉上颜色和形状等信息的对比得出的. 根据这一医学常识, 结合 WSDA 我们给出了 MSC-1 的分类规则 1, 将  $MI$  分类为正常和异常.

#### 分类规则 1.

- (1)  $MI$  是正常的, 如果  $d(L, R) \geq \epsilon$ ;
- (2)  $MI$  是异常的, 如果  $d(L, R) < \epsilon$ ;

其中  $\epsilon$  是一个阈值变量, 本文将通过实验来确定合适的  $\epsilon$  值.

利用分类规则 1 可以将医学图像分类为正常和异常两类. 医学图像  $MI$  根据中线垂直平分分为  $L$  和  $R$ , 其对应的分量为  $D(L)$  和  $D(R)$ , 根据  $L$  和  $R$  的弱对称性  $d(L, R)$  的值, 可以初步将医学图像分类为正常和异常. 图 9 中 (a)、(b) 分别为图 3 中 (a) 和 (b) 的  $D(L)$  和  $D(R)$ , 其中图 9 (a) 的  $d(L, R) = 0.9085 \geq \epsilon$ , 图 9 (b) 中  $d(L, R) = 0.7731 < \epsilon$ .

### 5.2 医学图像异常定位分类方法(MSC-2)

MSC-1 过程将  $MI$  分类为正常和异常, 接下来, 我们对 MSC-1 过程所得结果中的异常图像做进一步分类处理, 判断图像中发生异常区域  $T$  所处的位置. 该阶段选用对样本数量要求较低的 SVM (Support Vector Machine) 作为分类器. 该方法在解决小样本、高维度、非线性的模式识别中表现出诸多优点, 它的基本模型是一个二分类模型, 是一个定义在特征空间上的最大间隔线性分类器. 这种方法根据有限的样本信息在模型的复杂性和学习能力之间寻求最佳折衷, 以期获得最好的推广能力. 由于医生在诊断过程中往往通过对比同一个人的多张图像或同一图像左右两侧的颜色和位置等信息判断异常区域出现的位置, 本文基于对称性理论提出了 WSDA 和 SSDA 两个判定算法. 分类规则 2 是通过提取 WSDA 和 SSDA 的两个特征值  $val$  和  $sum$  作为 SVM 分类器的特征输入, 训练分类模型  $model$ , 最后输出测试集图像所属类别, 如图 10 所示.

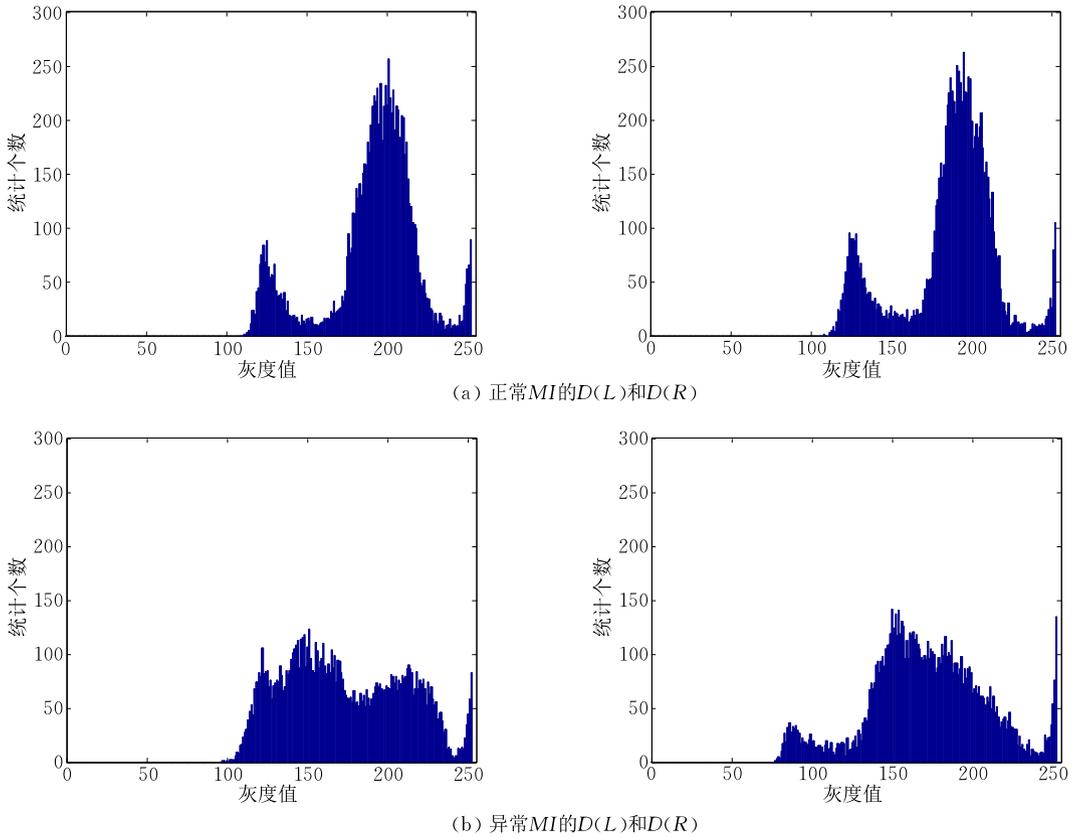


图 9 图 3 中(a)、(b)的  $D(L)$  和  $D(R)$

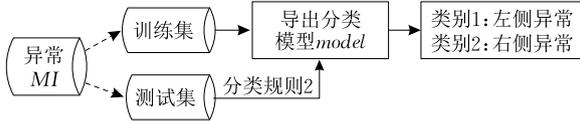


图 10 MSC-2 分类器模型

**分类规则 2.**

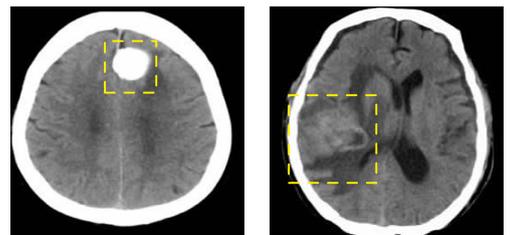
- (1) 如果测试集的两个特征  $val$  和  $sum$  满足  $model$  中的左侧异常特征, 则  $MI$  左侧异常;
- (2) 如果测试集的两个特征  $val$  和  $sum$  满足  $model$  中的右侧异常特征, 则  $MI$  右侧异常.

图 10 为 MSC-2 的分类模型, 对训练集的学习可以导出一个分类模型  $model$ , 测试集中的两个特征  $val$  和  $sum$  根据分类规则 2 应用分类模型  $model$  分类为左侧异常和右侧异常两类. 基于医学图像对称性理论的 WSDA 和 SSDA 提取医学图像异常定位分类器模型的两个特征  $val$  和  $sum$ , 应用分类规则 2 即可对异常的  $MI$  图像定位异常区域  $T$  的位置.

可见, 通过 MSC-2 的分类方法可以对 MSC-1 中异常图像定位其异常区域  $T$  的位置在  $MI$  的左侧或右侧, 这样有助于医生对病变区域存在于左侧或右侧做出尽早的判断, 从而减少医生用于诊断的时间和精力.

**5.3 医学图像良恶性分类方法(MSC-3)**

判断出异常区域的位置后, 为了避免异常区域阻碍正常细胞的生长, 医生要及时的诊断异常区域的良恶性并做出诊断决策. 模拟医生诊断的这一过程, 本小节将对异常区域  $T$  进行分类处理, 选用 SVM 作为分类器.



(a) 良性肿瘤 (b) 恶性肿瘤

图 11 良恶性肿瘤形态特征

虽然在脑部医学图像中肿瘤有很多类, 但是目前脑膜瘤和胶质瘤最为常见. 胶质瘤是最为常见的恶性肿瘤之一, 脑膜瘤则是最为常见的良性脑肿瘤之一. 术前对肿瘤的良恶性程度进行评估对治疗方案的制定和术后诊断有重要临床意义. 由于这两种肿瘤在临床诊断中最为常见, 所以本小节针对这两种肿瘤特征对异常的医学脑部 CT 图像切片分类为良性和恶性. 图 11(a) 为良性肿瘤, 其具有以下特

征:形态规则、边缘清晰光滑、肿瘤呈现近似圆形;而图 11(b)为恶性肿瘤其形态不规则、边缘模糊粗糙. 本文中采用紧凑度  $C$ 、平均标准化半径  $d_{\text{avg}}$ 、粗糙度  $Ro$ 、方差  $\delta^2$ 、偏斜度  $Sk$ 、峰值  $Pe$  共 6 个特征<sup>[25-26]</sup> 区分  $AMI$  的良恶性.

紧凑度  $C$  是一个粗略描述物体边缘规则度的特征参数,较多地应用于识别物体形状领域. 其定义如下:

$$C = 1 - \frac{4\pi A}{p^2} \quad (4)$$

其中  $A$  是肿瘤轮廓的面积,  $p$  是肿瘤轮廓的周长. 当  $C \rightarrow 0$  时,形态接近于规则. 上式也表明,紧凑度  $C$  与平移、旋转和缩放无关.

平均标准化半径  $d_{\text{avg}}$  是宏观描述物体边缘规则度的特征参数,但相比于紧凑度,它还可以反映一些细微的边缘变化. 其定义如下:

$$d_{\text{avg}} = \frac{1}{N} \sum_{i=1}^N d(i) \quad (5)$$

其中,  $N$  为边缘上点的个数,设 ROI 区域的最小外接矩形的中心为  $(x_0, y_0)$ ,半径  $d(i)$  是各边缘点  $(x_i, y_i)$  到图像中心  $(x_0, y_0)$  的距离,可以根据下式计算.

$$d(i) = \frac{\sqrt{(x(i) - x_0)^2 + (y(i) - y_0)^2}}{\max(d(i))}, \quad i = 1, 2, \dots, N \quad (6)$$

其中  $\max(d(i))$  是半径中的最大值.

粗糙度  $Ro$  的大小反映了边缘毛刺的多少和边缘的光滑程度. 其定义如下:

$$Ro = \frac{1}{N} \sum_{i=1}^N |d(i) - d(i+1)| \quad (7)$$

其中  $N$  和  $d(i)$  的定义与式(5)相同.

方差  $\delta^2$  反映的是边缘点和中心的偏离程度,用来衡量边缘数据的波动大小,方差越大说明边缘点的波动越大,肿瘤的边缘形状越不稳定,此特征的计算见式(8).

$$\delta^2 = \frac{1}{K} \sum_{i=1}^K (L_i - \mu)^2 \quad (8)$$

其中,  $K$  是边缘上点的数量,  $L_i$  是边缘上点和点之间的欧氏距离,  $\mu$  是均值,可以通过下列公式计算得到

$$\mu = \frac{1}{K} \sum_{i=1}^K L_i \quad (9)$$

偏斜度  $Sk$  反映边缘的形状是否规则,以平均值为中心数据分布的对称性. 当偏斜度为正值时,说明肿瘤边缘的形状为圆或椭圆形,当偏斜度为负值时说明肿瘤边缘的形状不规则. 此特征的计算见式(10).

$$Sk = \frac{1}{\delta^3} \sum_{i=1}^K (L_i - \mu)^3 \quad (10)$$

其中  $\delta$  是式(8)中的方差,  $\mu$  是式(9)中的均值,  $K$  是

边缘上点的数量,  $L_i$  是边缘上点和点之间的欧氏距离.

峰值  $Pe$  反映边缘的光滑程度,峰值越大,边缘越不光滑;峰值越小,边缘越趋于光滑. 此特征的计算见式(11).

$$Pe = \frac{1}{\delta^4} \sum_{i=1}^K (L_i - \mu)^4 \quad (11)$$

其中,  $\delta$  是式(8)中的方差,  $\mu$  是式(9)中的均值,  $K$  是边缘上点的数量,  $L_i$  是边缘上点和点之间的欧氏距离.

根据异常区域  $T$  的以上 6 个特征  $C$ 、 $d_{\text{avg}}$ 、 $Ro$ 、 $\delta^2$ 、 $Sk$ 、 $Pe$  的提取,我们给出异常  $MI$  良恶性区分的分类规则 3.

### 分类规则 3.

(1) 如果测试集的 6 个特征满足  $model$  中的良性特征,则  $MI$  为良性;

(2) 如果测试集的 6 个特征满足  $model$  中的恶性特征,则  $MI$  为恶性.

图 12 为 MSC-3 的分类器模型. 其中图 12(a)为  $MI$  左侧异常区域分类为良恶性的模型,图 12(b)为  $MI$  右侧异常区域分类为良恶性的模型. 应用分类规则 3 判断异常区域的良恶性. 根据左侧和右侧异常的  $MI$  的训练集分别训练出相应的  $model$ . 测试集中的 6 个特征满足  $model$  中良性的概率大于恶性的概率时,我们认为其属于良性,否则属于恶性.

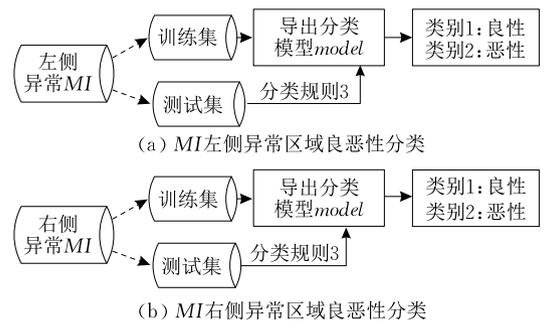


图 12 MSC-3 良恶性分类器模型

## 6 实验结果及分析

为了验证基于对称性理论的医学图像多阶段分类方法的效率,本节将分为 3 个实验来予以说明. 因为没有实现对医学图像的多阶段分类的方法,所以实验将每个阶段分别作了对比. 文献[10]提出的基于形态学操作的分类方法 SVM-MPO 将医学图像分类为正常和异常. 文献[11]中的 FBB 方法可以快速定位 MR 图像中的肿瘤位置. FBB 方法的前提是知道肿瘤在图像的左侧还是右侧,然后应用

FBB 方法将肿瘤区域标记出来. 该方法只适合 MR 图像中, 在 CT 图像中效果不是很好. 文献[12]基于小波统计纹理 WST 方法分割和分类脑 CT 图像, 提出一种基于小波图像的游程矩阵和灰度共生矩阵的混合方法将肿瘤分类为良性和恶性. 本文为了更好地利用大量未标注图像样本信息来提高分类器性能, 采用的是随机半监督采用算法<sup>[27]</sup>. 该算法采用迭代随机采样方法, 每次采用中通过谱聚类估计未标注样本的类别值, 使用 SVM 进行模型学习, 逐步优化模型, 以提高分类准确度. 本文所使用的图像数据集来自于医院真实脑部 CT 图像. 实验数据包括 1500 张医学脑部图像. 其中 1000 张作为训练集, 并做相应的标记如左侧异常、右侧异常、良性和恶性, 500 张作为测试集.

实验的硬件环境: Intel(R) Core(TM)2 Quad CPU Q8400@2.66 GHz, 2.0 GB RAM, 采用 Microsoft Windows 7 操作系统. 实验软件开发环境: VS2010, opencv2.3.1, Matlab R2009.

### 6.1 MSC-1 中阈值 $\epsilon$ 选取

根据弱对称性将脑部 CT 图像分类为正常和异常两类. 这时阈值的选取很重要. 阈值的不同导致分类的精度有所改变. 根据弱对称性的定义  $d(L, R)$ , 得知图 3(a) 的  $d(L, R) = 0.9112$ . 通过弱对称性  $d(L, R)$  的值可以判断图像的对称性, 式(12)是判定图像正常或异常. 大量实验得出当  $d(L, R)$  的阈值为 0.88 时, 测试集的分类精度达到 98.2%. 阈值  $\epsilon$  的选择做了以下两组实验, 如图 13 所示. 每组图像显示了随着阈值  $\epsilon$  的改变, 分类精度的变化情况. 实验结果表明当阈值  $\epsilon$  的范围选择的适当时, 测试集中的脑部 CT 图像初步分类为正常和异常的准确率可以达到 98.2%.

$$d(L, R) \begin{cases} < 0.88, \text{ 异常} \\ \geq 0.88, \text{ 正常} \end{cases} \quad (12)$$

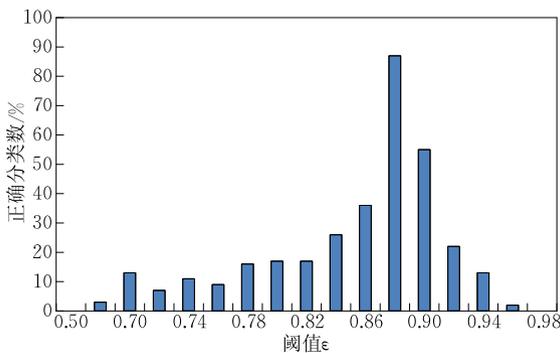


图 13 阈值  $\epsilon$  和分类精度的关系

图 13 显示的结果表明, 不同阈值下脑部 CT 图像正确分类的百分比. 当阈值  $\epsilon < 0.6$  和  $\epsilon > 0.96$

时, 正确分类的 CT 图像数为 0. 当阈值  $\epsilon$  为 0.6 时正确分类数只占 3%,  $\epsilon$  为 0.96 时正确分类数只占 2%. 当阈值  $\epsilon = 0.88$  时, 训练集中的脑部 CT 图像的正确分类数达到 87%. 当阈值选为 0.88 时测试样本中的 500 张图像的正异常分类精度达到 98.2%.

### 6.2 分类器性能评价

分类器的设计好坏由分类结果的准确率和召回率来评估. 准确率即图片库中相关的图片, 被检索到的越多越好, 而召回率是检索到的图片中, 相关的越多越好, 不相关的越少越好. 准确率和召回率的公式如下:

$$precision = TP / (TP + FP) \quad (13)$$

$$recall = TP / (TP + FN) \quad (14)$$

其中,  $TP$  是检索到的相关图像,  $FP$  是检索到的但不相关的图像,  $FN$  是未检索到但相关的图像,  $TN$  是未检索到也不相关的图像. 准确率和召回率虽然没有必然的关系, 然而在大规模的数据集中, 这两个指标是相互制约的.

文献[10]将脑部 CT 图像分类为正常和异常两类. 而本文提出的 MSC 分类方法包括将脑部 CT 图像分类为正常和异常, 又将异常的分类为左侧异常和右侧异常. 然后将异常的肿瘤分类为良恶性两类. 通过实验表明 MSC-1 中使用 WSDA 将脑部 CT 图像分类为正常和异常的精度并不低于文献[10]提出的基于形态学操作的分类方法 SVM-MPO 的分类结果. 如图 14 所示. 文献[10]的方法应用在本文中的数据集中进行分类精确度的测试时显示的分类精确度不是很高, 而本文的方法对各类数据都比较适用. 实验中共有 1500 个样本, 其中 1000 个样本用作分类器的训练, 500 个样本用来测试分类器. 当训练样本为 50 时, SVM-MPO 的分类精确度为 54%, 而 MSC-1 的分类精确度为 70.8%. 随着训练样本的不断增大, 两种分类方法的分类精度逐渐上升. 但是实验结果显示 MSC-1 的分类精度在任何数据集的情况下都比 SVM-MPO 的分类精度高.

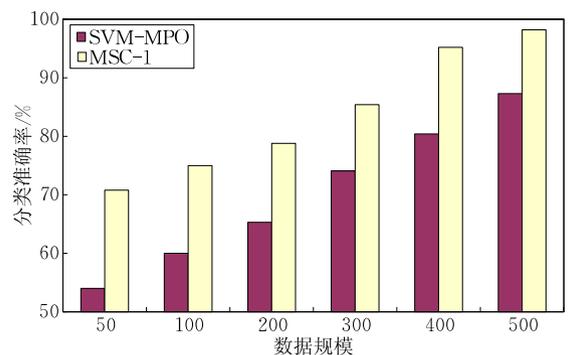


图 14 图像数量与精度的关系

文献 [10]提出的分类方法只是本文分类的第 1 阶段. 第 2 阶段 MSC-2 是通过弱对称性和强对称性将脑部 CT 图像病变的位置进行分类为左侧病变和右侧病变. 得出测试样本的准确率和召回率的关系图像为图 15 所示. 图 16 为 MSC-2 与 FBB 方法的分类准确率的对比实验.

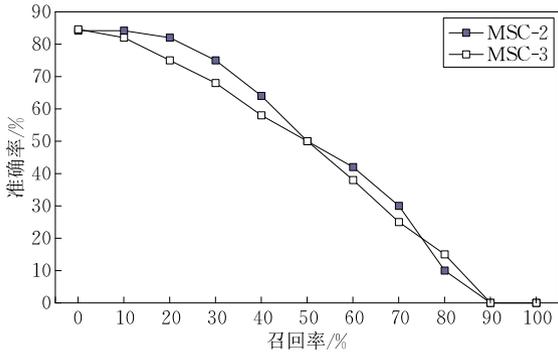


图 15 MSC-2、MSC-3 准确率和召回率的关系

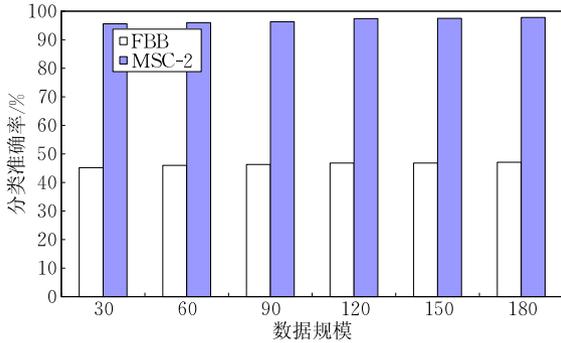


图 16 MSC-2 分类准确率对比实验

图 16 实验结果表明, 在同样的训练集下, FBB 方法的分类准确率很低, 而本文提出的 MSC-2 的分类方法准确率都在 95% 以上. 在测试集为 180 时, MSC-2 的分类准确率为 97.8%, 而 FBB 方法的分类准确率为 47.1%. FBB 方法前提是知道肿瘤发生在图像的哪一侧, 然后才能精确的在 MR 图像中定位肿瘤的区域. 而本文直接通过弱对称性和强对称性就可以将肿瘤的区域定位在左侧或者右侧, 而不是精确的定位肿瘤的区域, 有利于第 3 阶段良恶性分类精度的提高.

第 3 阶段 MSC-3 是将病变的肿瘤分类为良恶性两类. 本文基于灰度图像提取病变肿瘤的 6 个特征作为良恶性分类的特征. 其测试样本的准确率和召回率的关系图像为图 15 所示. 图 17 是本文与 WST 分类准确率的对比.

图 17 结果表明, 当测试数据为 180 时, MSC-3 的分类准确率是 91.2%, 而 WST 的分类准确率是 83%. 这说明在训练样本 1000 下训练的 MSC-3 分类模型的准确率高于 WST 分类模型的准确率.

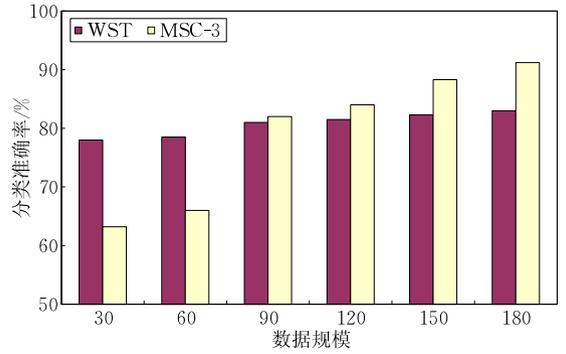


图 17 MSC-3 分类准确率对比实验

### 6.3 时间复杂性分析

为了验证基于对称性理论的医学图像多阶段的分类算法的效率, 将文献 [10] 中的 SVM-MPO 方法、文献 [11] 中的 FBB 方法和文献 [12] 中的 WST 方法分别与本文的 MSC-1、MSC-2 和 MSC-3 在时间复杂度上做对比. 实验结果如图 18~图 20 所示.

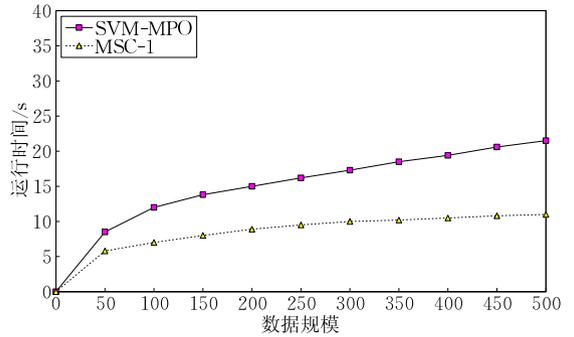


图 18 MSC-1 与 SVM-MPO 时间复杂度对比

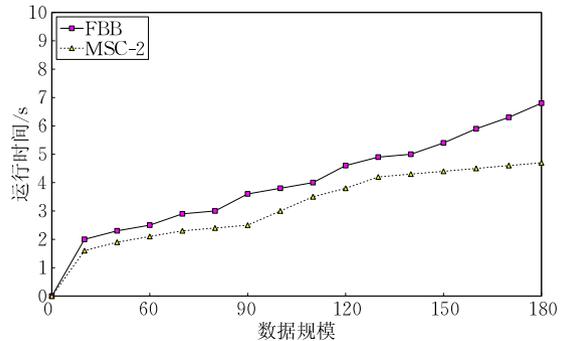


图 19 MSC-2 与 FBB 时间复杂度对比

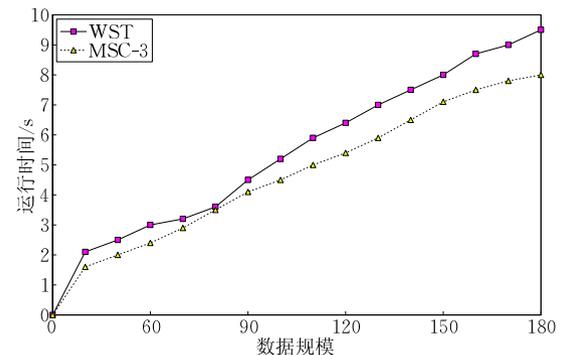


图 20 MSC-3 与 WST 时间复杂度对比

图 19 结果表明 MSC-1 方法的时间效率优于 SVM-MPO 的时间效率. 随着数据集的增大, SVM-MPO 的运行时间呈线性递增的趋势增长, 而 MSC-1 方法在数据集达到 300 时, 运行时间几乎不再变化, 数据集达到 500 时运行时间为 11s 而 SVM-MPO 的运行时间为 21.5s. 所以本文的方法 MSC-1 要比 SVM-

MPO 方法时间效率高. 在数据集继续增大的情况下, MSC-1 的运行时间将不会变化很大. 图 20 是 MSC-2 与 FBB 方法在运行时间上的对比, 当数据集达到 130 时, 两个方法的运行时间几乎呈直线增长, 但数据集继续增大时, MSC-2 运行时间变化很小. 图 20 表明 MSC-2 的运行效率高于 FBB 定位肿瘤的方法. 图 21

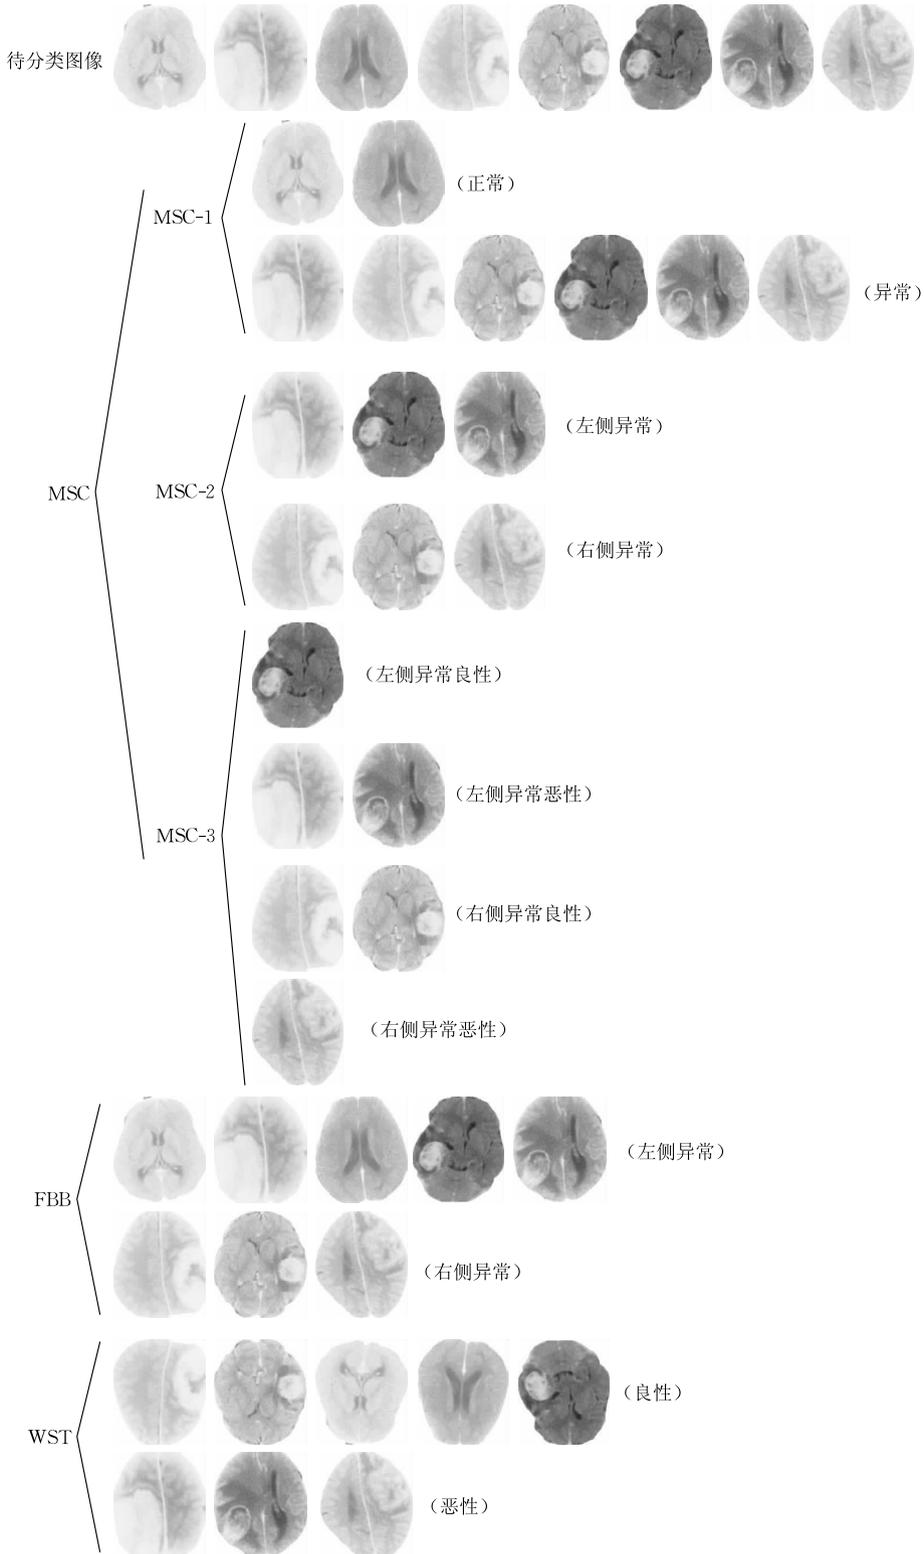


图 21 分类结果实例

是 MSC-3 与 WST 方法在运行时间上的对比. 因为 WST 方法要提取二级小波纹理图像, 然后在小波纹理图像上提取游程矩阵和共生矩阵共 17 个特征作为分类特征集. 效率要比 MSC-3 低很多. 在准确率一定的情况下, MSC-3 在运行时间上有更好的效率.

图 21 给出了一些分类结果的实例, 其中第 1 部分是待分类图像, 其他 3 部分是分类结果, 待分类图像取自不同的病人. 第 2 部分为本文的分类方法, 其中包括分类的 3 个阶段: MSC-1、MSC-2、MSC-3. 第 3 部分为 FBB 方法的分类结果, 第 4 部分为 WST 方法的分类结果. 通过实例可以发现, 基于对称性理论的医学图像多阶段分类算法可以更为准确地实现模拟医生的诊断过程并将医学图像分类. FBB 方法实现的是将待分类的医学图像分类为左侧异常和右侧异常, WST 方法是将待分类的医学图像分为良性和恶性两类. 而本文通过模拟医生的诊断过程实现由粗粒度到细粒度的将医学图像分类.

## 7 总 结

医学图像的成像结果显示一张医学图像关于中垂线两侧近似对称. 基于这一脑部医学领域知识的指导, 本文提出了基于对称性理论的医学图像多阶段分类 (Multi-Stage Classification, MSC) 方法. 首先, 本文提出了弱对称性和强对称性的定义, 从不同粒度对医学图像的对称性进行了描述; 然后, 给出了基于灰度直方图相交性的弱对称性判定算法, 对医学图像在较粗粒度上进行了第 1 阶段的分类; 接着, 提出了基于点对称的强对称性判定算法, 结合弱对称性判定算法, 对第 1 阶段分类结果为异常的图像进行了更细粒度的第 2 阶段分类, 定位了病变区域的位置; 最后, 利用对病变区域所提取的特征, 对病变区域进行了第 3 阶段的分类, 已达到辅助医生诊断的效果. 实验结果表明, 基于对称性理论的医学图像多阶段分类方法提高了医学图像分类的准确度, 同时减少了医生诊断决策的时间.

## 参 考 文 献

- [1] Chen Jingnian, Huang Houkuan, Tian Shengfeng, et al. Feature selection for text classification with Naïve Bayes. *Expert Systems with Applications*, 2009, 36(3): 5432-5435
- [2] Yang Ai-Jun, Song Xin-Yuan. Bayesian variable selection for disease classification using gene expression data. *Bioinformatics*, 2010, 26(2): 215-222
- [3] Megalooikonomou V, Ford J, Shen L, et al. Data mining in brain imaging. *Statistical Methods in Medical Research*, 2000, 9(4): 359-394
- [4] Zaiiane O R, Antonie M L, Coman A. Mammography classification by an association rule-based classifier//*Proceedings of the International Workshop on Multimedia Data Mining (with ACM SIGKDD 2000)*. Edmonton, Canada, 2002: 62-69
- [5] Rajendran P, Madheswaran M. Hybrid medical image classification using association rule mining with decision tree algorithm. *Computing Research Repository*, 2010, 2(1): 1001-3503
- [6] Al-Hadidi M R A, Al-Gawagzeh M Y, Alsaaidah B A. Solving mammography problems of breast cancer detection using artificial neural networks and image processing techniques. *Indian Journal of Science and Technology*, 2012, 5(4): 2520-2528
- [7] Kharat K D, Kulkarni P, Nagori M B. Brain tumor classification using neural network based methods. *International Journal of Computer Sciences and Informatics*, 2012, 4(1): 85-90
- [8] Qurat-Ul-Ain, Ghazanfar Latif, et al. Classification and segmentation of brain tumor using texture analysis//*Proceedings of the 9th WSEAS International Conference on Recent Advances in Artificial Intelligence, Knowledge Engineering and Data Bases*. Cambridge, UK, 2010: 147-155
- [9] Saha S, Bandyopadhyay S. MRI brain image segmentation by fuzzy symmetry based genetic clustering technique//*Proceedings of the IEEE Congress on Evolutionary Computation (CEC)*. Los Alamitos, CA, 2007: 4417-4424
- [10] Fallahi A R, Pooyan M, Khotanlou H. A new approach for classification of human brain CT images based on morphological operations. *Journal of Biomedical Science & Engineering*, 2010, 3(1): 78-82
- [11] Saha B N, Ray N, Greiner R, et al. Quick detection of brain tumors and edemas: A bounding box method using symmetry. *Computerized Medical Imaging and Graphics*, 2012, 36(2): 95-107
- [12] Nanthagopal A P, Sukanesh R. Wavelet statistical texture features-based segmentation and classification of brain computed tomography images. *IET Image Processing*, 2013, 7(1): 25-32
- [13] Pan Hai-Wei, Li Peng-Yuan, Han Qi-Long, et al. A novel model for medical image modeling and similarity retrieval. *Chinese Journal of Computers*, 2013, 36(8): 1745-1756 (in Chinese)  
(潘海为, 李鹏远, 韩启龙等. 一种新颖的医学图像建模及相似性搜索方法. *计算机学报*, 2013, 36(8): 1745-1756)
- [14] Canny J. A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986, 8(6): 679-698
- [15] Fitzgibbon A W, Pilu M, et al. Direct least square fitting of ellipses. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21(5): 476-480

- [16] Pan Haiwei, Li Pengyuan, Li Qing, et al. Brain CT image similarity retrieval method based on uncertain location graph. *IEEE Journal of Biomedical and Health Informatics*, 2013, 18(2): 574-584
- [17] Quddus A, Basir O. Semantic image retrieval in magnetic resonance brain volumes. *IEEE Transactions on Information Technology in Biomedicine*, 2012, 16(3): 348-355
- [18] Ruppert G C S, Teverovskiy L, et al. A new symmetry-based method for mid-sagittal plane extraction in neuroimages // *Proceedings of the 2011 IEEE International Symposium on Biomedical Imaging*, Chicago, USA, 2011: 285-288
- [19] Kropatsch W G, Torres F, Ramachandran G. Detection of brain tumors based on automatic symmetry analysis // *Proceedings of the 18th Computer Vision Winter Workshop*, Hernstein, Austria, 2013: 4-6
- [20] Tuzikov A V, Colliot O, Bloch I. Evaluation of the symmetry plane in 3D MR brain images. *Pattern Recognition Letters*, 2003, 24(14): 2219-2233
- [21] Bergo F P G, Falcão A X, et al. FCD segmentation using texture asymmetry of MR-T1 images of the brain // *Proceedings of the 5th IEEE International Symposium Biomedical Image*, Paris, France, 2008: 424-427
- [22] Teverovskiy L, Becker J T, et al. Quantified brain asymmetry for age estimation of normal and AD/MCI subjects // *Proceedings of the 5th IEEE International Symposium Biomedical Image*, Paris, France, 2008: 1509-1512
- [23] Bianchi A, Miller J V, Tan E T, et al. Brain tumor segmentation with symmetric texture and symmetric intensity-based decision forests // *Proceedings of the IEEE International Symposium on Biomedical Imaging*, San Francisco, California, 2013: 748-751
- [24] Liu Sheena Xin. Symmetry and asymmetry analysis and its implications to computer-aided diagnosis: A review of the literature. *Journal of Biomedical Informatics*, 2009, 42(6): 1056-1064
- [25] Amini A A, Weymouth T E, Jain R C. Using dynamic programming for solving variational problems in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, 12(9): 855-867
- [26] Yang Shu-Jun, Liu Dong-Quan. Ultrasonic image edge detection for breast neoplasm. *Computer Applications and Software*, 2013, 30(5): 283-286 (in Chinese)  
(杨舒珺, 刘东权. 乳腺肿瘤超声图像的边缘检测. *计算机应用与软件*, 2013, 30(5): 283-286)
- [27] Han Dong-Feng, Zhu Zhi-Liang, Li Wen-Hui. Image classification: A random semi supervised sampling approach. *Journal of Computer-Aided Design & Computer Graphics*, 2009, 21(9): 1333-1338 (in Chinese)  
(韩东峰, 朱志良, 李文辉. 图像分类的随机半监督采样方法. *计算机辅助设计与图形学学报*, 2009, 21(9): 1333-1338)



**RONG Jing-Shi**, born in 1988, M. S. candidate. Her main research interests include data mining, multimedia mining.

**PAN Hai-Wei**, born in 1974, Ph.D., associate professor. His main research interests include data mining, database technology and intelligent information processing.

**GAO Lin-Lin**, born in 1989, Ph.D. candidate. Her

main research interests include data mining, multimedia mining.

**HAN Qi-Long**, born in 1974, Ph.D., associate professor. His main research interests include data mining, sensitive data protection.

**FENG Xiao-Ning**, born in 1976, Ph.D., associate professor. His research interests include database, data mining, software engineering.

**LI Qing**, born in 1962, Ph.D., professor. His research interests include object modeling, multimedia databases, social medial and recommender systems.

## Background

In recent years, medical Computed Tomography (CT) Images has been applied in clinical diagnosis widely. That can assist physicians to detect and locate pathological changes with higher accuracy. There are many factors in the process of the physicians' diagnosis. Firstly, the physicians' diagnosis is subjective, because the diagnosis' result is affected by the doctors' experience and ability. Secondly, the physicians' diagnosis tends to omit some tiny changes that the human's

eyes can't find. Thirdly, the different physicians would get the different diagnosis' conclusions to the same medical image. As manually processing medical images requires expertise and is thus expensive and slow, computerized image processing in this domain is of great need. Automatic diagnosis may help to decrease human-based diagnosis error and assist physicians to focus on the correct disease and its treatment and to avoid wasting time on diagnosis. With more medical images, by

using images-to-image comparison doctors will find out the similar images which come from different patients. These patients may have high possibility to get same disease because they have the similar pathological characteristics in their images. The aim of classification is to group items which have similar feature values into categories. So classifying these medical images will assist doctors to make diagnoses according to the same group items.

In this paper, a method based on theory of symmetry to classify the medical brain CT image with the multi-stage strategy is proposed. First of all, the definitions of the weak symmetry and strong symmetry were given while distinguish the symmetry were given. Then, the weak symmetry was applied to the first stage classification of the CT images, which makes classified images label as the normal and abnormal. Secondly, we proposed the combination of weak symmetry feature obtained from gray-level intensity histogram and strong symmetry features obtained from texture

images for the classification of abnormal brain images into left lesions or right lesions of CT images for the second stage classification. Finally, according to the tumor edge profile, tumors are divided into benign and malignant lesions by extracting some features of the tumor in the third stage classification. In this paper, sample size requirements of SVM (Support Vector Machine) classifier were selected to classify the CT images in the second and third stage classification. Experimental results showed that medical images multi-stage classification methods based on the theory of symmetry can improve the accuracy of the medical image classification and while reduce the time of the doctor's decision.

The paper is partly supported by the National Natural Science Foundation of China under Grant Nos. 61272184, 61202090, 61100007; the Program for New Century Excellent Talents in Universities (NCET-11-0829); the Fundamental Research Funds for the Central Universities under Grant Nos. HEUCF100602, HEUCFT1202.