

基于语义属性的肺结节良恶性分类

巩 萍^{1,2}, 程玉虎¹, 王雪松¹

(1. 中国矿业大学信息与电气工程学院, 江苏徐州 221116; 2. 徐州医学院医学影像学院, 江苏徐州 221004)

摘 要: 现有肺结节良恶性计算机辅助诊断的依据通常为肺部 CT 图像的底层特征, 而临床医生的诊断依据为高级语义特征. 为克服这种图像底层特征和高级语义特征之间的不一致性, 提出一种基于语义属性的肺结节良恶性判别方法. 首先, 利用阈值概率图方法提取肺结节图像; 其次, 一方面提取肺结节图像的形状、灰度、纹理、大小和位置等底层特征, 组成样本特征集. 另一方面, 根据专家对肺结节属性的标注, 提取结节属性集; 然后, 根据特征集和属性集建立属性预测模型, 实现两者之间的映射; 最后, 利用预测的属性进行肺结节的良恶性分类. LIDC 数据库上的实验结果表明所提方法具有较高的分类精度和 AUC 值.

关键词: 底层特征; 语义属性; 属性预测模型; 肺结节; 分类

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2015)12-2476-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2015.12.020

Benign or Malignant Classification of Lung Nodules Based on Semantic Attributes

GONG Ping^{1,2}, CHENG Yu-hu¹, WANG Xue-song¹

(1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China;

2. School of Medical Imaging, Xuzhou Medical College, Xuzhou, Jiangsu 221004, China)

Abstract: The current computer aided diagnosis system classifies benign or malignant lung nodules mainly according to the low-level features of lung CT images. However, clinicians use the high-level semantic features of lung CT images. To overcome the inconsistency between the low-level features and high-level semantic features, a new approach of benign or malignant lung nodules classification based on semantic attributes is proposed. Firstly, lung nodule images are extracted using the threshold probability-map method. Secondly, on the one hand, some features including shape, gray, texture, size and position are extracted from lung nodule images to constitute the low-level feature set; on the other hand, according to the experts' annotation of lung nodules, the attributes are extracted to constitute the high-level attribute set. Thirdly, attribute prediction models are built to map the low-level features to the high-level attributes. Finally, the benign or malignant classification of lung nodules is performed using the predicted attributes. Experimental results on the LIDC dataset show that the proposed classification method possesses high classification accuracy and AUC value.

Key words: low-level feature; semantic attribute; attribute prediction model; lung nodule; classification

1 引言

肺癌是当今对人类生命健康危害最大的恶性肿瘤之一. 在世界的许多地区, 肺癌是癌症死亡的主要原因. 因此, 如何有效地诊断肺癌成为全人类关心的课题. 早期发现与诊断是提高肺癌患者存活率的关键. 临床研究表明, 肺癌早期的表现形式是肺结节. 因此, 肺结节的良恶性智能识别对肺癌的早期发现、早期诊断及提高 5 年

生存率至关重要.

在目前肺癌的计算机辅助诊断中, 大多数肺结节的良恶性分类依据是 CT 图像的底层特征, 如形状特征^[1]、灰度值^[2]、几何与纹理特征^[3]、多分辨率直方图^[4]、密度特征^[5]、CT 值的空间分布^[6]等. 基于图像底层特征的分类方法虽然在提高肺结节诊断准确率、减轻医生劳动强度、减少漏诊等方面起到了积极作用, 但底层特征的获取是通过计算机对图像像素之间的灰度关系或图像 CT

值进行不同计算得到的,与医生描述肺结节的语言有很大的差异.医生在诊断肺结节图像时主要依据肺结节的医学征象,通过对结节的边缘有无毛刺、分叶、钙化等高级语义特征进行良恶性判断.如恶性结节常表现为:边缘不规则或伴毛刺、针尖状或偏心性钙化;良性结节主要表现为边缘光滑、无明显分叶毛刺等,这些高级语义特征称为可视化属性.因此,基于底层特征的分类方法与医生建立的以可视化属性为主的诊断方式存在很大的差异,不能给医生诊断的合理性提供指导依据,很难得到医生易于接受并理解的结果,导致在临床的实际应用中存在一定的局限性.

近年来,属性学习被广泛关注,成为机器学习与模式识别领域的一个研究热点,被广泛应用于场景分类、图像检索、人脸识别、零样本学习等领域.根据 Babbie 的定义^[7],属性是“一种描述一个对象的特征或性质的量,其具体取值可以是离散,也可以是连续”.属性与底层特征的区别在于属性是建立在底层特征之上的一种对对象的高层描述,可以将语义关系嵌入进机器学习模型中,而底层特征不具有直接的语义意义,只能被机器识别但不能被人理解.目前,已有一些学者对肺结节底层特征与医生解释的高级属性之间的相关关系进行了研究.Horsthemke 等基于肺结节形状特征的傅里叶描述子与径向梯度指数,分别利用 Logistic 回归与决策树对专家定义的 3 个形状语义属性“分叶”、“毛刺”、“圆形度”进行了预测^[8].Li 等通过肺结节的 5 个纹理特征对

“纹理”和“精细度”两个属性进行了预测^[9].Zinovev 等首先从形状、大小、灰度、纹理 4 个方面共提取了 64 个底层特征,然后分别利用支持向量机和决策树对“精细度”、“边缘”、“恶性度”等语义属性进行了预测^[10].上述研究的目的是为了减少不同放射科医生在评估肺结节语义特征时存在的差异性,力图找到肺结节底层特征与语义属性之间的关系,实现对语义属性的自动预测,并没有将其进一步应用到肺结节良恶性分类的计算机辅助诊断上.另外,在底层特征提取方面,文献[8,9]仅从形状与纹理方面进行了特征提取,虽然文献[10]在特征提取方面比较全面,但在属性预测时并没有针对属性进行相应的特征选择.为此,针对目前肺结节良恶性计算机辅助诊断存在的局限性,结合属性学习,提出一种基于语义属性的肺结节良恶性分类方法.

2 基于语义属性的肺结节良恶性分类

基于语义属性的肺结节良恶性分类流程如图 1 所示.首先,利用阈值概率图方法提取肺结节感兴趣区域,得到肺结节图像;其次,一方面提取肺结节图像底层特征,组成样本特征集,另一方面,根据专家对结节语义属性的标注,提取肺结节语义属性集;然后,根据样本的特征集和属性集建立属性预测模型,实现两者之间的映射;最后,利用预测的属性进行肺结节的良恶性分类.

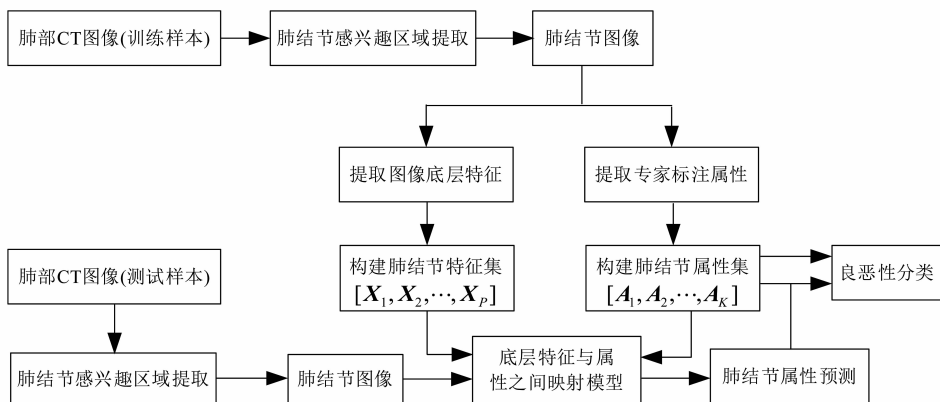


图1 基于语义属性的肺结节良恶性分类流程图

本文所有的肺部 CT 图像来源于美国肺部图像数据库联盟 (Lung Image Database Consortium, LIDC)^[11].LIDC 数据库中的每个病例对应一个文件夹,包括 100 ~ 300 张完整的肺部 CT 扫描图像以及一个注释文件.注释文件中对直径大于 3mm 的结节给出了 4 名放射学专家分别从“精细度”、“内部结构”、“钙化”、“圆形度”、“边缘”、“分叶”、“毛刺”、“纹理”及“恶性度”9 个方面的语义属性分级,如表 1 所示.

表 1 肺结节语义属性分级

属性	精细度	内部结构	钙化	圆形度	边缘	分叶	毛刺	纹理	恶性度
分级	5	4	6	5	5	5	5	5	5

2.1 肺结节底层特征提取

由于肺结节图像是灰度图像,而灰度图像的底层特征主要包括形状、灰度、纹理这三大类.进一步,肺结

节的大小和位置在其良恶性判断中起着重要作用,也是不容忽视的特征.为此,在对肺结节图像进行底层特征提取的时候,需要综合考虑形状、灰度、纹理、大小和位置特征,从而构成了一个 72 维的肺结节底层特征集,如表 2 所示.

在形状特征方面,与现有方法^[8,10]相比,本文还额外提取了 x_8 : 结节边界凸点最大弦弧比特征和 x_9 : 结节边界凹点最大弦弧比特征.这两个特征均是针对肺结节毛刺与分叶的语义定义提取的,具体步骤如下.

步骤 1 提取肺结节的轮廓点集;

步骤 2 从轮廓点集中找出关键点,即拐点;

步骤 3 判断拐点中相邻三个拐点构成的三角形

的凹凸情况;若为凹三角形,令 $\lambda_m = -1$;若为凸三角形,令 $\lambda_m = 1$;

步骤 4 根据式(1)计算每个三角形的弦弧比:

$$\chi_m = \lambda_m \frac{d_m}{c_m} \quad (1)$$

其中, d_m 为第 m 个拐点与相邻两拐点形成的连线间的垂直距离, c_m 为相邻两拐点间的距离.

步骤 5 根据毛刺与分叶的定义知^[12]:是毛刺的点一定是凸点,是分叶的点一定是凹点.为此, $\lambda_m = 1$ 时对应的 $\max\{\chi_m\}$ 即为 x_8 , 作为表征毛刺程度的特征; $\lambda_m = -1$ 时对应的 $\max\{-\chi_m\}$ 即为 x_9 , 作为表征分叶程度的特征.

表 2 肺结节底层特征集

形状特征($x_1 - x_{11}$)	大小特征($x_{12} - x_{18}$)	灰度特征($x_{19} - x_{29}$)	纹理特征($x_{31} - x_{72}$)	位置特征(x_{30})
x_1 : 充实度; x_2 : 粗糙度; x_3 : 离心率; x_4 : 矩形度; x_5 : 归一化径向距离均值; x_6 : 归一化径向距离方差; x_7 : 归一化径向距离面积比; x_8 : 结节边界凸点最大弦弧比; x_9 : 结节边界凹点最大弦弧比; x_{10} : 形状矩描述子; x_{11} : 傅里叶描述子.	x_{12} : 面积; x_{13} : 最小凸多边形面积; x_{14} : 周长; x_{15} : 最小凸多边形周长; x_{16} : 等效直径; x_{17} : 椭圆的长轴长度; x_{18} : 椭圆的短轴长度.	x_{19} : 结节区最小 CT 值; x_{20} : 结节区最大 CT 值; x_{21} : 结节区 CT 值均值; x_{22} : 结节区 CT 值标准差; x_{23} : 包含结节的最小矩形区内最小 CT 值; x_{24} : 包含结节的最小矩形区内最大 CT 值; x_{25} : 包含结节的最小矩形区内 CT 均值; x_{26} : 包含结节的最小矩形区内 CT 值标准差; x_{27} : 密度差; x_{28} : 不对称度; x_{29} : 峰度.	$x_{31} - x_{48}$: 从灰度共生矩阵得到的特征,包括能量、熵、惯性矩、逆差矩、相关性、和的熵、差的熵、共生和均值、共生差均值在 0° 、 45° 、 90° 和 135° 四个方向的平均值和方差; $x_{49} - x_{72}$: 24 个 Gabor 纹理特征.	x_{30} : 结节在 Z 轴上的相对位置.

2.2 肺结节语义属性预测模型的构建

在属性学习中,不同的属性所需的底层特征是不一样的.例如“纹理”属性主要与纹理特征有关,与形状特征关系不大.也就是说,对识别某个属性最具区别性的底层特征随属性的不同而不同^[13].若在属性预测模型中使用所有的底层特征,那么与该属性无关的特征极有可能成为噪声,从而影响模型的性能.针对属性与特征之间的关系,对底层特征进行有效的选择是属性预测模型中不可缺少的一步.

特征选择是基于某种评价标准从原始特征集中选择最优特征子集来表示数据.因此,特征选择可以看作是一个优化问题,其关键是建立一种评价标准来区分哪些特征有助于分类,哪些特征组合存在冗余.根据评价函数与分类器的关系,特征选择方法可分为三大类:过滤器式、封装器式以及混合式^[14].相对于封装器式与混合式特征选择方法,过滤器式是一种较为高效的方法^[15].为此,采用过滤器式方法对上述 72 维肺结

节底层特征集进行特征选择.首先采用 Pearson 相关系数^[16]衡量特征与属性之间的关联程度,然后根据相关系数大小进行选择.

设矩阵 $X = \{X_1, \dots, X_p, \dots, X_P\}$ 与 $A = \{A_1, \dots, A_k, \dots, A_K\}$ 分别表示肺结节的特征与属性矩阵,其中 P 为特征个数, K 为属性个数. $X_p = \{x_{p1}, \dots, x_{pN}\}$, $A_k = \{a_{k1}, \dots, a_{kN}\}$, N 为肺结节样本数, X_p 与 A_k 之间的 Pearson 相关系数定义为 X_p 与 A_k 之间的协方差和标准差的商.

$$R_{X_p A_k} = \frac{\sum_{n=1}^N (x_{pn} - \bar{x}_p)(a_{kn} - \bar{a}_k)}{\sqrt{\sum_{n=1}^N (x_{pn} - \bar{x}_p)^2} \sqrt{\sum_{n=1}^N (a_{kn} - \bar{a}_k)^2}} \quad (2)$$

其中, \bar{x}_p 和 \bar{a}_k 分别为 X_p 与 A_k 的均值.基于 Pearson 相关系数的特征选择算法如算法 1.

算法 1 基于 Pearson 相关系数的特征选择

输入: 特征矩阵 X , 属性矩阵 A , 相关性阈值 δ ($0 < \delta < 1$), 初始化特征

子集 X_s 为空.

- (1) For $k = 1$ to K
- (2) For $p = 1$ to P
- (3) 根据式(2), 计算特征 X_p 与属性 A_k 之间的 Pearson 相关系数;
- (4) 对相关系数从大到小进行排序;
- (5) 输出相关系数大于 δ 的特征索引 ind_p 和选择后的特征子集 $X_s[k, \text{ind}_p]$;
- (6) End
- (7) End

输出: 选择后的特征子集 X_s .

在属性学习中, 目前最主要的模型有直接属性预测(Direct Attribute Prediction, DAP)模型与间接属性预测(Indirect Attribute Prediction, IAP)模型两种^[17]. 在 DAP 中, 属性作为一个中间层把图像底层特征和类别标签连接起来. 首先通过训练样本的底层特征学习多个属性分类器, 然后通过属性分类器对测试样本进行属性预测, 最后通过属性与类别之间的关系将测试样本赋予最终的类别标签. 基于属性的肺结节良恶性分类过程与 DAP 类似, 把肺结节属性作为中间层连接肺结节底层特征与类别. 不同的是在 DAP 模型中, 所有属性都是二值属性, 用 0 和 1 表示. 类别与属性之间的关系是固定的, 学习的主要任务是得到多个二值属性分类器. 在本文中, 每个属性被量化为不同等级, 分别用一组离散的数表示. 如“边缘”属性被量化为 1、2、3、4、5 共五个不同的等级, 每个数值表示不同类型的边缘, 而且属性与类别的关系是未知的. 因此, 整个过程既要学习属性分类器, 又要学习属性与类别的关系.

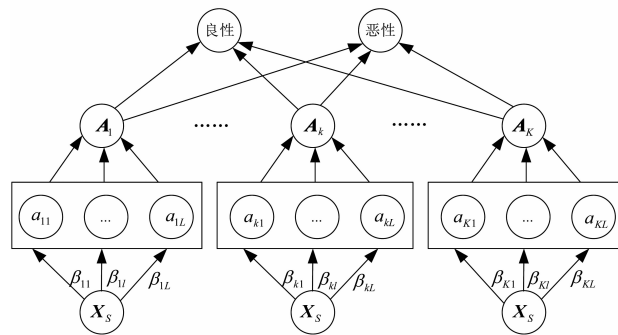


图2 肺结节语义属性预测模型

图 2 给出了构建的肺结节语义属性预测模型示意图, 图中 X_s 表示选择后的底层特征. 设 $Y \in \{-1, 1\}$ 表示肺结节的类别标签, “-1”和“1”分别代表良性和恶性. 基于语义属性的肺结节的良恶性分类转化为以下两个映射问题:

$$\begin{aligned}
 F &= S(\beta(\cdot)) \\
 \beta: X_s &\rightarrow A \\
 S: A &\rightarrow Y
 \end{aligned}
 \tag{3}$$

其中, β 为属性预测模型, 代表底层特征到属性的映射; S 代表属性到类别的映射. 属性预测模型是对每一个测试样本找到属性 A_k 的量化等级 a_{kl} . 把每一个属性看成是一个单独任务, 那么属性预测模型即可转化为多个单独任务的多分类问题. 人工神经网络、支持向量机、决策树、贝叶斯等分类方法都可以用于此模型. 此处利用支持向量机来进行建模. 支持向量机是一种高效的学习算法, 对小样本数据具有高效的学习性和推广性, 在很大程度上解决了传统学习算法中的泛化能力、过学习、维数灾难及非线性等问题. 采用支持向量机多分类中的一对一方法, 对于属性 A_k 的 L 个量化等级, 将有 $L(L-1)/2$ 个预测函数. 每个函数完成对任意两个量化等级的预测. 对量化等级 a_{kl_1} 和 a_{kl_2} 构造一个二值子分类器, 把属于量化等级 a_{kl_1} 的样本标记为正, 把属于量化等级 a_{kl_2} 的样本标记为负, 样本集用 (x_j, y_j) 表示, 问题转化为:

$$\begin{cases} \min_{\omega, b, \zeta} \frac{1}{2} \|\omega\|^2 + C \sum_{j=1}^M \zeta_j \\ \text{s.t.} \begin{cases} y_j(\omega^T \varphi(x_j) + b) \geq 1 - \zeta_j \\ \zeta_j \geq 0 \end{cases} \end{cases}
 \tag{4}$$

其中, x_j 为训练样本的特征, M 为样本数, ω 为权向量, b 为偏移量, C 是大于零的惩罚因子, ζ_j 为松弛变量, $\varphi(\cdot)$ 为核函数. 对一个未知样本进行属性预测时, 每个预测函数对其进行判断, 并为相应的等级“投上一票”, 得票最多的等级即作为该未知样本的属性预测结果. 对每一个属性分别进行上述操作, 即可得到所有的属性预测模型.

2.3 肺结节良恶性分类

为了建立属性与良恶性之间的分类模型, 根据专家对结节的属性标注, 选取恶性度作为良恶性判断依据, 其余属性作为判断输入. LIDC 数据库中, 恶性度被量化为 1、2、3、4、5 共五个等级, 对给定的阈值 T , 肺结节的良恶性判别如下:

$$Y = \begin{cases} 1, & \text{恶性度} > T \\ -1, & \text{恶性度} \leq T \end{cases}
 \tag{5}$$

其中, $Y = 1$ 代表恶性, $Y = -1$ 代表良性. 把恶性度之外的属性作为分类器输入, 由于所选数据库中样本的“内部结构”与“钙化”两个属性量化级别相同, 因此对“内部结构”和“钙化”这两个属性没有考虑. 为了消除专家定义的不一致, 目前较为流行的方法是选取多位专家评分中的中值或者众数^[18]. 此处采用众数的方法, 选取 LIDC 数据库中恶性度属性至少 3 位以上专家定义一致, 属性至少 2 个以上专家打分一致的结节进行建模, 基于专家语义属性的肺结节的良恶性分类模型转化为一个二分类问题. 然后用此模型对 2.2 中预测的属性进

行分类.

3 实验结果及分析

3.1 基于底层特征的肺结节属性预测

为测试基于底层特征的属性预测精度,从 LIDC 数据库中选取结节直径大于或等于 3mm,且每一个属性至少 3 位放射学专家定义一致的样本组成各个属性的样本集. “纹理”、“毛刺”、“精细度”、“分叶”、“圆形成度”、“边缘”6 个属性所选择样本数分别为 264、233、249、161、116 和 107. 对每个属性样本集,首先根据阈值概率图法提取阈值大于 0.75 的像素构成肺结节图像;然后分别提取肺结节五类特征,选取 Pearson 相关系数大于 0.95 的特征子集;最后采用 LibSVM 支持向量机对每个属性预测模型进行训练. 选择径向基核函数,采用网格搜索法对支持向量机的超参进行参数优化,五折交叉验证进行最优属性预测模型选择. 表 3 给出了不同特征下的

属性预测结果,表中“/”表示对应的方法对此属性没有进行预测.

由表 3 可以看出,采用特征子集的肺结节属性预测精度比使用全部 72 个底层特征的属性预测精度要高,这说明了属性与底层特征之间确实是存在某种对应关系的,亦即某个属性只依赖于某些方面的底层特征. 因此,在构建属性预测模型时,要有针对性地进行特征选择. 同时基于特征子集的方法获得了最高的属性预测精度. 另外,在“毛刺”、“分叶”这 2 个属性预测上,基于 72 个特征的方法要比文献[8,10]的要高,这也验证了本文方法在形状特征提取上的优势.

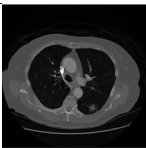

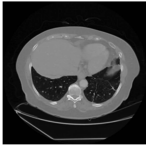
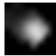
3.2 肺结节良恶性分类

选择 LIDC 数据库中恶性度属性至少 3 个专家评分一致的 156 个结节图像进行良恶性分类. 以两幅图像为例,表 4 给出了本文方法的主要分类过程.

表 3 不同特征下的肺结节属性预测精度对比

肺结节属性预测方法	纹理	毛刺	精细度	分叶	圆形成度	边缘	平均预测精度
基于 72 个底层特征	92.45%	57.78%	81.63%	68.75%	43.97%	85.05%	71.61%
基于特征子集	99.62%	93.13%	98.80%	96.27%	87.93%	94.39%	95.02%
基于傅里叶描述子 ^[8]	/	46.86%	/	57.57%	42.85%	/	56.43%
基于 5 个纹理特征 ^[9]	93.75%	/	89.80%	/	/	/	91.78%
基于 64 个底层特征 ^[10]	92.72%	56.52%	82.00%	65.63%	44.00%	81.82%	70.45%

表 4 基于语义属性的肺结节良恶性分类过程

原始 CT 图像	肺结节图像	底层特征提取	属性预测值						分类结果 ($T=3$)
			纹理	毛刺	精细度	分叶	圆形成度	边缘	
		$x_1:0.839; x_2:0.64;$ $x_3:0.741; x_4:0.633;$	5	2	5	3	3	4	恶性(1)
		$x_1:0.814; x_2:2.737;$ $x_3:0.541; x_4:0.749;$	5	1	5	1	4	5	良性(-1)

在临床的辅助诊断中,仅依靠分类精度有时难以准确反映分类模型的诊断价值. 为了更客观、全面、准确地评价分类结果,目前国际上较为流行的是采用受试者操作特性(Receiver Operating Characteristics, ROC)曲线. ROC 曲线是以假阳性率(False Positive Rate, FPR)为横坐标,真阳性率(True Positive Rate, TPR)为纵坐标绘制而成的. 自上世纪 80 年代起广泛应用于医学诊断性能的评价,尤其是医学图像诊断性能的评价. 对于一个二分类问题,如本文中良性和恶性,结果分别写成阴性和


阳性. 如果良性正确地诊断为阴性,就称为真阴性,如果良性被错误地诊断为阳性,就称为假阳性,如果恶性被正确地诊断为阳性,就称之为真阳性,如果恶性被错误地诊断为阴性就称之为假阴性. 分类的精度反映了真阳性和真阴性之和占样本总数的百分比,不能很好地揭示假阴性和假阳性的关系. 相同的分类精度可能有不同的假阴性和假阳性,为了总体反应分类结果的好坏,可根据 ROC 曲线形状和曲线下面积(Area Under Curve, AUC)对分类作进一步定量分析. AUC 值越大,说

明分类效果越好.表5给出了不同方法下的分类精度及 AUC 值,相应的 ROC 曲线如图3所示.


由表5可以看出,对于基于语义属性的肺结节良恶性分类方法来说,无论是分类精度还是 AUC 值,经过特征选择后的结果都比使用全部特征的要好.这也说明了在属性学习中,特征选择的重要性.除了 $T=3$ 处基于底层特征^[3]的方法取得最高的分类精度外,在其它各阈值处特征选择后的基于语义属性的分类方法无论是分类精度,还是 AUC 值均是最高.无论 T 取何值,

表5 不同方法下的肺结节分类精度及 AUC 值对比


肺结节良恶性分类方法	$T=1$		$T=2$		$T=3$		$T=4$	
	分类精度	AUC	分类精度	AUC	分类精度	AUC	分类精度	AUC
基于语义属性(全部特征)	94.87%	0.497	88.46%	0.527	68.59%	0.510	64.74%	0.509
基于语义属性(特征子集)	98.08%	0.905	89.10%	0.802	71.15%	0.958	92.31%	0.963
基于底层特征 ^[3]	67.50%	0.806	85.92%	0.564	84.70%	0.953	65.50%	0.890
基于底层特征 ^[5]	96.67%	0.420	87.10%	0.533	78.13%	0.700	70.97%	0.833




(a) 基于语义属性(全部特征)



(b) 基于语义属性(特征子集)



(c) 基于底层特征^[3]



(d) 基于底层特征^[5]

图3 肺结节良恶性分类ROC曲线

4 结论

目前计算机辅助诊断中肺结节的分类方法主要是

使用全部特征的基于语义属性的分类方法和文献[5]中方法的 AUC 值在四种方法中均是相对较低的,有的甚至低于 0.5. 从医学角度来看,AUC 值在 0.5 附近的,在临床中已没有任何辅助诊断价值.由表5还可以看出,无论是基于语义属性的(特征子集)分类方法,还是基于底层特征的方法,在 $T=3$ 和 $T=4$ 处的 AUC 值均比 $T=1$ 和 $T=2$ 时大,这也说明了根据恶性度进行良恶性分类时阈值的最佳选取应是 3 或 4,这个结果与恶性度的分级描述也是相一致的.

依据图像的底层特征,这种底层特征与对象的高层类别之间存在“语义鸿沟”.为此,提出一种基于语义属性的肺结节良恶性分类方法.该方法将肺结节的语义属

性作为一种中间表示,通过属性预测模型建立起底层特征与类别标签之间的映射关系.为了提高属性预测模型的性能,进而提高分类效果,针对不同属性进行了特征选择.LIDC 数据库上的实验结果表明,与基于语义属性(全部特征)和基于底层特征的分类方法相比,所提方法不仅具有较高的分类精度,而且获得了最高的 AUC 值,具有良好的临床使用价值.文中把每一个属性看成一个单独的任务,没有考虑到属性与属性之间的关系.在属性预测模型中如果能够充分挖掘属性与属性之间的关系,有望能相互帮助,提高预测能力,从而提高分类效果,这也是今后重点研究的内容.

参考文献

- [1] Tartar A, Akan A, Kilic N. A novel approach to malignant-benign classification of pulmonary nodules by using ensemble learning classifiers[A]. Proceedings of the 36th IEEE International Conference on Engineering in Medicine and Biology Society[C]. Piscataway: IEEE Press, 2014. 4651 – 4654.
- [2] Suzuki K, Li F, Sone S, Doi K. Computer-aided diagnostic scheme for distinction between benign and malignant nodules in thoracic low-dose CT by use of massive training artificial neural network[J]. IEEE Transactions on Medical Imaging, 2005, 24(9): 1138 – 1150.
- [3] 姜慧研, 何炜. 基于胸部 CT 图像的肺癌识别方法的研究[J]. 电子学报, 2009, 37(8): 1664 – 1668.
JIANG Hui-Yan, HE Wei. Research of lung cancer recognition based on chest CT images[J]. Acta Electronica Sinica, 2009, 37(8): 1664 – 1668. (in Chinese)
- [4] 刘露, 刘宛予, 楚春雨, 吴军, 周洋, 张红霞, 鲍 ■. 胸部 CT 图像中孤立性肺结节良恶性快速分类[J]. 光学精密工程, 2009, 17(8): 2060 – 2066.
LIU Lu, LIU Wan-Yu, CHU Chun-Yu, WU Jun, ZHOU Yang, ZHANG Hong-Xia, BAO Jie. Fast classification of benign and malignant solitary pulmonary nodules in CT image[J]. Optics and Precision Engineering, 2009, 17(8): 2060 – 2066. (in Chinese)
- [5] Shen W C, Yu Y H, Chuang C H. Computer aided diagnosis for pulmonary nodule on low-dose computed tomography (LDCT) using density features[A]. Proceedings of 2011 8th International Conference on Computer Graphics, Imaging and Visualization[C]. Piscataway: IEEE Press, 2011. 166 – 169.
- [6] El-Baz A, Gimel'farb G, Abou El-Ghar M, Falk R. Appearance based diagnostic system for early assessment of malignant lung nodules[A]. Proceedings of 2012 19th IEEE International Conference on Image Processing[C]. Piscataway: IEEE Press, 2012. 533 – 536.
- [7] Babbie E. The Practice of Social Research[M]. San Francisco: Wadsworth Publishing, 2009. 14 – 18.
- [8] Horsthemke W H, Raicu D S, Furst J D. Evaluation challenges for bridging semantic gap: shape disagreement on pulmonary nodules in the lung image database consortium[J]. International Journal of Healthcare Information Systems and Informatics, 2009, 4(1): 17 – 33.
- [9] Li G, Kim H, Tan J K, Ishikawa S, Hirano Y, Kido S, Tachibana R. Semantic characteristics prediction of pulmonary nodule using artificial neural networks[A]. Proceedings of 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society[C]. Piscataway: IEEE Press, 2013. 5465 – 5468.
- [10] Zinovev D, Raicu D S, Furst J, Lii S G A. Predicting radiological panel opinions using a panel of machine learning classifiers[J]. Algorithms, 2009, 2(4): 1473 – 1502.
- [11] Armato S G, McLennan G, McNitt-Gray M F, Meyer C R, David Y, Aberle D R, et al. Lung image database consortium: developing a resource for the medical imaging research community[J]. Radiology, 2004, 232(3): 739 – 748.
- [12] Shodayu T, Shusuke S, Feng L, Yuichiro M, Minoru H, Tsuyoshi M, et al. Small solitary pulmonary nodules (< or = 1cm) detected at population-based CT screening for lung cancer: reliable high-resolution CT features of benign lesions[J]. American Journal of Roentgenol, 2003, 180(4): 955 – 964.
- [13] Wosiak A, Zakrzewska D. Feature selection for classification incorporating less meaningful attribute in medical diagnostics[A]. Proceedings of the 2014 Federated Conference on Computer Science and Information Systems[C]. Piscataway: IEEE Press, 2014. 235 – 240.
- [14] 程玉虎, 全瑶瑶, 王雪松. 类相关性影响可变选择性贝叶斯分类器[J]. 电子学报, 2011, 39(7): 1628 – 1633.
CHENG Yu-hu, TONG Yao-yao, WANG Xue-song. A selective bayesian classifier based on change of class relevance influence[J]. Acta Electronica Sinica, 2011, 39(7): 1628 – 1633. (in Chinese)
- [15] Zhang D Q, Chen S C, Zhou Z H. Constraint score: a new filter method for feature selection with pair-wise constraints[J]. Pattern Recognition, 2008, 41(5): 1440 – 1445.
- [16] 陈洪波, 李蓓蕾, 陈真诚. 基于 ICA 的脑电信号 P300 少次自动提取[J]. 电子学报, 2012, 40(6): 1257 – 1262.
CHEN Hong-bo, LI Bei-lei, CHEN Zhen-cheng. Automatically extract P300 within several trials from EEG based on ICA[J]. Acta Electronica Sinica, 2012, 40(6): 1257 – 1262. (in Chinese)
- [17] Lampert C H, Nickisch H, Harmeling S. Learning to detect unseen object classes by between-class attribute transfer[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Piscataway: IEEE Press, 2009. 951 – 958.

- [18] Armato S G, Roberts R Y, Kocherginsky M, Aberle D R, Kazerooni E A, MacMahon H, et al. Assessment of radiologist performance in the detection of lung nodules [J]. *Academic Radiology*, 2009, 16(1): 28 - 38.

作者简介



巩 萍 女, 1980 年出生于江苏徐州, 现为徐州医学院讲师, 中国矿业大学信息与电气工程学院博士生, 研究方向为医学图像处理、属性学习等.

E-mail: gongpingcumt@126.com



程玉虎(通信作者) 男, 1973 年出生于安徽淮南, 中国矿业大学信息与电气工程学院教授, 博士生导师. 主要研究方向为机器学习与模式识别、智能系统等.

E-mail: chengyuhu@163.com

王雪松 女, 1974 年出生于安徽泗县, 中国矿业大学信息与电气工程学院教授, 博士生导师. 主要研究方向为机器学习与模式识别.

E-mail: wangxuesongcumt@163.com