

· 影像 AI 多模态研究专题 ·

doi:10.3969/j.issn.1671-8348.2026.02.003

网络首发 [https://link.cnki.net/urlid/50.1097.R.20251009.1838.008\(2025-10-10\)](https://link.cnki.net/urlid/50.1097.R.20251009.1838.008(2025-10-10))CT 影像组学联合多种机器学习模型鉴别尘肺
大阴影与周围型肺癌的价值比较*王威¹ 谢武桃^{1△} 张洪² 毕朝虎¹ 黄娇¹ 周慧玲¹ 唐碧琼¹ 李倩³(重庆医药高等专科学校附属第一医院/重庆市职业病防治院/重庆市第六人民医院;1.放射科;
2.心内科;3.职业病科,重庆 400060)

[摘要] **目的** 构建基于 CT 影像组学的尘肺大阴影与周围型肺癌的鉴别诊断模型。**方法** 收集 2021 年 3 月至 2025 年 6 月来该院就诊的 103 例尘肺大阴影和 85 例周围型肺癌患者的常规 CT 资料,所有患者疾病经尘肺专家组、临床及病理结果证实。患者随机分为训练集($n=132$)和测试集($n=56$)。所有患者由两名放射科诊断医师(具备尘肺诊断资质)采用 ITK 软件对病灶进行勾画,从训练集的肺部病灶 CT 图像中提取领域灰度差矩阵(NGTDM)、一阶统计量、形状(shape,包括二维及三维特征)、纹理[包括灰度共生矩阵(GLCM)、灰度游程长度矩阵(GLRLM)、灰度大小区域矩阵(GLSZM)、灰度依赖矩阵(GLDM)]等影像组学特征,并进行特征降维以构建形态学影像生物标志物。在 Python 软件中使用逻辑回归(LR)、支持向量机(SVM)、自适应增强算法(AdaBoost)机器学习算法构建鉴别诊断模型。在测试集数据中使用受试者工作特性(ROC)曲线评估上述模型的鉴别诊断性能。**结果** 经分割得到 110 个尘肺大阴影感兴趣区(ROI)和 85 个周围型肺癌 ROI,共提取了 108 个影像组学特征,通过特征降维获得 8 个最优影像组学特征的特征子集,最后成功构建鉴别诊断模型。在训练集中 LR 模型、SVM 模型、AdaBoost 模型的准确度分别为 79.4%、84.0%、80.9%,灵敏度分别为 74.1%、74.1%、81.0%,特异度分别为 83.6%、91.8%、80.8%,ROC 曲线下面积(AUC)分别为 0.837、0.886、0.900。在测试集中 LR 模型、SVM 模型、AdaBoost 模型的准确度分别为 80.7%、82.5%、86.0%,灵敏度分别为 89.3%、89.3%、82.1%,特异度分别为 72.4%、75.9%、89.7%,ROC AUC 分别为 0.825、0.855、0.869,AdaBoost 模型的 ROC AUC 值高于 LR、SVM。AdaBoost 模型在训练集及测试集中的鉴别诊断性能最优。**结论** 基于 CT 影像组学特征的 AdaBoost 模型可以用于鉴别尘肺大阴影和周围型肺癌。

[关键词] 尘肺大阴影;CT 成像,AdaBoost;机器学习;影像组学**[中图分类号]** R445 **[文献标识码]** A **[文章编号]** 1671-8348(2026)02-0255-06

Comparison of the value of CT radiomics combined with multiple machine learning models in differentiating large opacities in pneumoconiosis from peripheral lung cancer*

WANG Wei¹, XIE Wutao^{1△}, ZHANG Hong², BI Chaohu¹, HUANG Jiao¹,
ZHOU Huiling¹, TANG Biqiong¹, LI Qian³

(1. Department of Radiology; 2. Department of Cardiology; 3. Department of Occupational Diseases, First Affiliated Hospital of Chongqing Medical and Pharmaceutical College/Chongqing Occupational Disease Hospital/Chongqing Sixth People's Hospital, Chongqing 400060, China)

[Abstract] **Objective** To construct a differential diagnosis model based on CT radiomics features for distinguishing large opacities in pneumoconiosis from peripheral lung cancer. **Methods** Conventional CT data from 103 patients with large opacities in pneumoconiosis and 85 patients with peripheral lung cancer, admitted to this hospital from March 2021 to June 2025, were collected. All diagnoses were confirmed by a pneumoconiosis expert panel, clinical evaluation, and pathological results. Patients were randomly divided into a training set ($n=132$) and a test set ($n=56$). Lesions were manually delineated by two radiologists (qualified in pneumoconiosis diagnosis) using ITK software. Radiomics features, including neighborhood gray stone difference matrix (NGTDM), first-order statistics, shape (2D and 3D) and texture [gray-level co-occurrence matrix (GLCM), gray-level run-length matrix (GLRLM), gray-level size zone matrix (GLSZM), gray-level depend-

* 基金项目:重庆市卫生健康委中医药科研项目(2026WSJK140);重庆市教育委员会科学技术研究项目(KJQN202302820, KJZD-K202302802, KJQN202502843);重庆医药职业教育集团教科研项目(CQZJ202337);重庆医药高等专科学校附属第一医院孵化基金(2025MS04)。

△ 通信作者, E-mail:1649905970@qq.com。

ence matrix (GLDM)] were extracted from the CT images of pulmonary lesions in the training set. Feature dimensionality reduction was performed to construct morphological imaging biomarkers. Differential diagnosis models were built using the logistic regression (LR), support vector machine (SVM), and adaptive boosting (AdaBoost) machine learning algorithms implemented in Python software. The performance of these models was evaluated on the test set using receiver operating characteristic (ROC) curve analysis. **Results** A total of 110 regions of interest (ROIs) for large pneumoconiosis opacities and 85 ROIs for peripheral lung cancer were segmented. A total of 108 radiomics features were extracted. After dimensionality reduction, an optimal subset of 8 key radiomics features was obtained, and the differential diagnosis models were successfully constructed. In the training set, the accuracy, sensitivity, specificity, and area under the ROC curve (AUC) of the LR, SVM, and AdaBoost models were 79.4%, 84.0%, 80.9%; 74.1%, 74.1%, 81.0%; 83.6%, 91.8%, 80.8%; and 0.837, 0.886, 0.900, respectively. In the test set, the corresponding values were 80.7%, 82.5%, 86.0% (accuracy); 89.3%, 89.3%, 82.1% (sensitivity); 72.4%, 75.9%, 89.7% (specificity); and 0.825, 0.855, 0.869 (AUC). The AdaBoost model achieved a higher AUC than both the LR and SVM models. AdaBoost demonstrated the best predictive performance in both the training and test set. **Conclusion** The AdaBoost model based on CT radiomics features can be used to differentiate large opacities in pneumoconiosis from peripheral lung cancer.

[Key words] large opacities in pneumoconiosis; computed tomography; AdaBoost; machine learning; radiomics

尘肺是在职业活动中长期吸入生产矿物性粉尘并在肺内滞留而引起的以肺组织弥漫性纤维化为主要特征的疾病^[1]。根据《中华人民共和国国家职业卫生标准》规定,在 X 线片上,肺野内长径 > 10 mm 的阴影为大阴影,而 3 期尘肺长径 \geq 20 mm,短径 > 10 mm。临床上,尘肺大阴影,即进入进行性大块纤维化 (progressive massive fibrosis, PMF) 的患者,可伴有肺功能进行性下降,呼吸困难及慢性咳嗽等表现^[2]。这些症状与肺癌的临床表现高度相似,容易混淆。更重要的是,尘肺大阴影在影像组学特征(如大小、形态、密度)上也常与肺癌相似,难以鉴别。影像组学概念由荷兰学者 LAMBIN 等^[3]于 2012 年提出,其核心是通过定量特征提取方法从医学影像,如 CT、MRI 等中挖掘海量信息,并借助机器学习技术进行处理和建模,为患者提供无创的诊断方案^[4]。鉴于尘肺大阴影与肺癌在临床及影像学表现上相似度较高,鉴别困难,本研究拟通过挖掘 CT 定量影像组学特征来构建鉴别诊断模型,旨在为临床提供一种可靠的鉴别诊断工具,以提升鉴别诊断的准确度。

1 资料与方法

1.1 一般资料

收集 2021 年 3 月至 2025 年 6 月经本院职业病鉴定专家组依据 GBZ70-2015《尘肺病的诊断》标准确诊的尘肺大阴影(尘肺大阴影组)和病理结果证实为周围型肺癌(周围型肺癌组)的患者的 CT 影像资料。188 例患者按 7:3 随机拆分为训练集 132 例,验证集 56 例。纳入标准:(1)尘肺大阴影,需经过职业病鉴定专家确诊为 3 期尘肺大阴影,其长径 \geq 20 mm,短径 > 10 mm;(2)周围型肺癌,经病理及临床证实,肿块 CT 图像阴影 \geq 3 cm。排除标准:(1)尘肺大阴影组排除 CT 影像不符合尘肺相关图像质量特征^[5]或合并肺结核、转移性病灶或其他相关并发症;(2)周围型肺

癌组排除合并肺结核、转移性病灶或其他相关并发症。本研究已通过本院伦理委员会批准[审批号:快审(2025 年第 23 号)],免除患者知情同意。

1.2 方法

1.2.1 CT 检查

所有对象接受 CT 检查,检查设备包括 GE Revolution ES 128 排螺旋 CT、GE Optima680 64 排螺旋 CT 及联影 860 160 排螺旋 CT。两组患者扫描范围均为双侧肺尖至肺底。扫描流程:核对患者身份证-患者准备-仰卧位-深吸气并屏气-曝光-停止扫描。扫描参数:管电压 120 Kv,每圈旋转时间 0.5 s,螺距 0.991:1.000,管电流(mA)为自动。扫描层厚及间距均为 5 mm,重建层厚 0.625 mm,重建间隔 0.625 mm。所有图像传至 GE ADW4.7 工作站,然后拷贝。

1.2.2 CT 图像处理与分析

(1)感兴趣区(region of interest, ROI)图像分割:由两名具备 10 年以上工作经验的放射科诊断医师(均具备尘肺诊断资质)将纳入研究对象的 CT 影像导入 ITK 软件(<http://www.itksnap.org/>),并对病灶进行标记,包括病灶的诊断、逐层勾画尘肺和周围型肺癌 ROI,尽量包括整个病灶。勾画完成后以 nii.gz 格式分别保存于 images 和 mask 文件夹。为评估两名医师勾画 ROI 的可重复性,采用组内相关系数(intra-class correlation coefficient, ICC)量化影像组学特征在观察者间的一致性。ICC > 0.75,提示一致性较好。(2)特征的选取:所有影像组学特征通过 Pyradiomic 内部特征分析程序(<http://pyradiomics.readthedocs.io>)提取,包括邻域灰度差矩阵(neighborhood gray tone difference matrix, NGTDM)、形状(shape)、一阶统计量(first-order statistics)、灰度共生矩阵(gray-level co-occurrence matrix, GLCM)、纹理[灰度依赖矩阵(gray-level dependence matrix,

GLDM)、灰度游程长度矩阵(gray-level run length matrix, GLRLM)、灰度大小区域矩阵(gray-level size zone matrix, GLSZM)]特征,大阴影与周围型肺癌获取的标签(label)分别为(0,1)。(3)数据处理:为了消除量纲影响,提高模型性能与异常值检测,数据统一标准化或归一化(Z-score)。(4)筛选特征:采用统计学 t 检验或 U 检验。(5)特征降维:对筛选出的影像组学特征进行特征降维,使用 Spearman 等级相关系数来分析特征间的相关性,并保留两个特征间相关系数的特征能力,使用最小绝对收缩与选择算子(least absolute shrinkage and selection operator, LASSO)回归模型降维。

1.2.3 分类器的建立

利用 onekey AI V5.1.25 平台,使用常见的支持向量机(support vector machine, SVM)、逻辑回归(logistic regression, LR)、自适应增强算法(adaptive boosting, AdaBoost)机器学习算法建立鉴别诊断模型。LR 是一种广义线性模型,主要是通过逻辑函数将线性回归的输出映射到概率空间^[6],从而进行分类决策。SVM 是一种基于最大间隔分类的监督学习算法,其目标是通过寻找最优化超平面,使不同类别的样本间隔最大化,从而在原始空间中实现对环形数据的有效分类^[7]。AdaBoost 是一种通过组合多个弱分类器来构建高准确度强分类器的机器学习算法。它通过加权训练样本的方式逐步优化分类器性能,每轮训练中增加对错误分类样本的重视程度,并最终通过加权投票组合所有弱分类器^[8]。AdaBoost 的主要优势在于其明显提升了分类器的泛化能力,即使在训练误差为零后,泛化误差仍可能继续下降,同时对过拟合具有较强的鲁棒性^[9]。

1.3 统计学处理

采用 onekey V5.1.25 平台提取数据和影像组学特征,采用 Kologoroy Smirnov 检验计量资料是否符合

正态分布,符合正态分布的计量资料以 $\bar{x} \pm s$ 表示,比较采用独立样本 t 检验,不符合正态分布的计量资料以 $M(Q_1, Q_3)$ 表示,比较采用 Mann-Whitney U 检验。计数资料以例数或百分比表示,组间比较采用 χ^2 检验。采用 MedCalc20.101 软件绘制受试者工作特征(receiver operating characteristic curve, ROC),通过曲线下面积(area under the curve, AUC)来评估模型的鉴别诊断效能。以 $P < 0.05$ 为差异有统计学意义。

2 结果

2.1 患者一般资料

本研究共纳入 188 例患者,尘肺大阴影组 103 例,均为男性,平均年龄(58.37 ± 7.34)岁;周围型肺癌组 85 例,其中肺腺癌 32 例、鳞癌 15 例、神经内分泌癌 1 例、腺鳞癌 1 例、小细胞肺癌 6 例、非小细胞癌 2 例、临床确诊肺癌病理分型不详 28 例,包含男 61 例、女 24 例,平均年龄(70.95 ± 10.82)岁。

2.2 训练集与验证集划分及特征筛选

103 例尘肺大阴影患者 CT 图像共勾画 110 个 ROI,85 例周围型肺癌患者 CT 图像共勾画 85 个 ROI。训练集筛选出了 85 个影像组学特征,经单因素初筛、Spearman 相关性分析与 LASSO 降维,最终保留 8 个影像组学特征用于后续模型构建,即 NGTDM 繁忙度(original_NGTDM_Busyness)、NGTDM 复杂度(original_NGTDM_Complexity)、NGTDM 对比度(original_NGTDM_Contrast)、三维最大径(original_shape_Maximum-3D-Diameter)、球形度(original_shape_Sphericity)、GLCM 聚类阴影(original_GLCM_ClusterShade)、GLCM 最大相关系数(original_GLCM_MCC)及小区域低灰度强调(original_GLSZM_Small Area Low Gray Level Emphasis),其中前 3 个属于 NGTDM 类,第 4、5 个属于 shape 类,第 6、7 个属于 GLCM 类,第 8 个属于 GLSZM 类,影像组学特征降维过程见图 1。

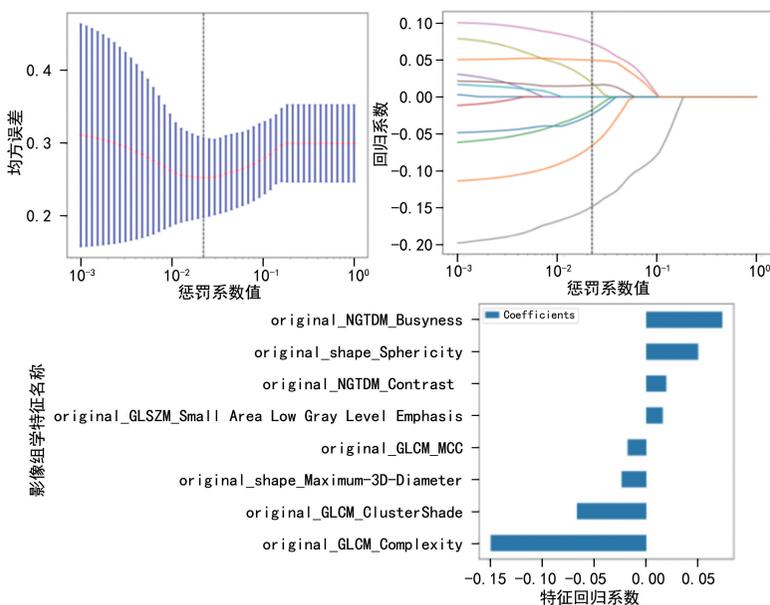


图 1 影像组学特征降维过程

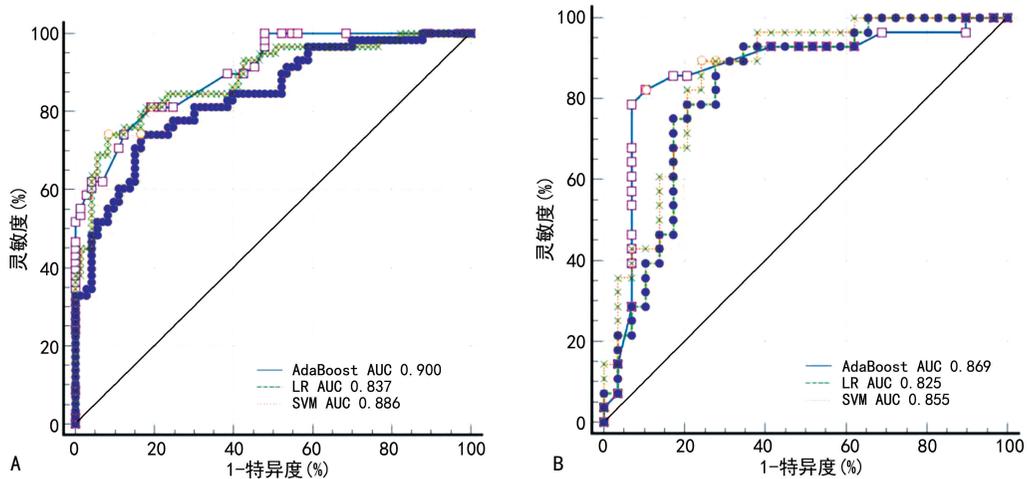
2.3 模型结果

3 种常见机器学习鉴别诊断模型在训练集与测试集中的诊断性能见表 1。ROC 曲线分析结果显示, AdaBoost 模型的 AUC 鉴别诊断高于 LR、SVM 模型。AdaBoost 模型在训练集及测试集中的预测性能均最优, 见图 2。AdaBoost 模型的临床决策曲线 (de-

cision curve analysis, DCA) 提示在低阈值概率 (0~0.4) 内, 模型的净收益明显高于“全治”策略, 表明模型在早期阶段能够有效识别需要治疗的个体。在中等阈值概率 (>0.4~0.6) 内, 尽管模型的净收益有所波动, 但仍然优于“全治”和“全不治”策略, 显示出一定的预测价值, 见图 3。

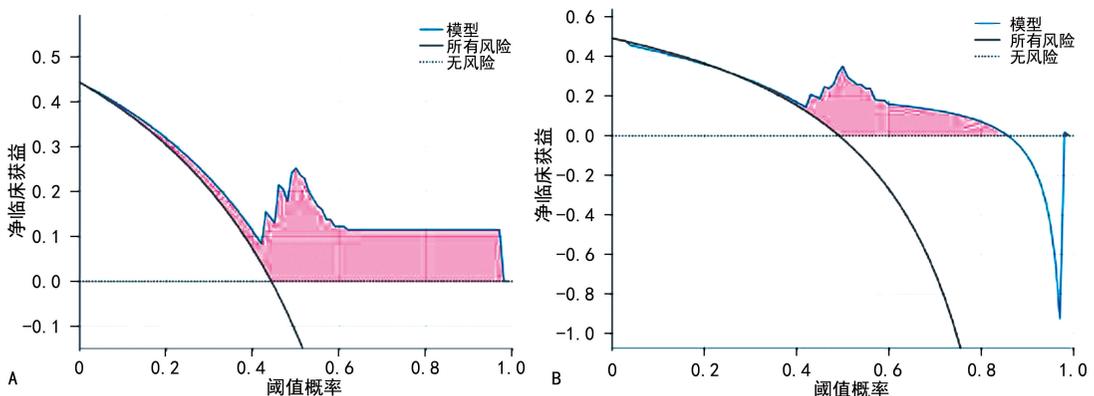
表 1 3 种机器学习模型在训练集与测试集中的诊断性能比较

模型名称	准确度	AUC	95%CI	灵敏度	特异度	阳性预测值	阴性预测值	调和平均数
LR 训练集	0.794	0.837	0.769~0.906	0.741	0.836	0.782	0.803	0.761
LR 测试集	0.807	0.825	0.712~0.938	0.893	0.724	0.758	0.875	0.820
SVM 训练集	0.840	0.886	0.828~0.944	0.741	0.918	0.878	0.817	0.804
SVM 测试集	0.825	0.855	0.755~0.955	0.893	0.759	0.781	0.880	0.833
AdaBoost 训练集	0.809	0.900	0.850~0.950	0.810	0.808	0.770	0.843	0.790
AdaBoost 测试集	0.860	0.869	0.763~0.976	0.821	0.897	0.885	0.839	0.852



A: 训练集; B: 测试集。

图 2 3 种机器学习鉴别诊断模型在训练集与测试集中的 ROC 曲线比较



A: 训练集; B: 测试集。

图 3 AdaBoost 模型训练集和测试集 DCA 分析

3 讨论

3.1 尘肺大阴影与肺癌临床鉴别诊断情况

尘肺大阴影代表严重的肺部纤维化改变, 其在影像学检查中呈现出诸多复杂特征, 这使得其与肺癌肺

块影的鉴别诊断面临巨大挑战。在实际影像学表现上, 尘肺大阴影与肺癌肿块影存在超过 10 种影像特征重叠, 具体包括 CT 值异常、病变钙化、卫星灶、棘突、胸膜肥厚、短毛刺、空洞等。当尘肺大阴影与肺癌

并发时,诊断难度会进一步增加^[10]。在尘肺合并肺大疱的患者中,部分病例因缺乏典型尘肺影像背景征象,或肺大疱壁出现局灶性、迅速增厚的结节样改变,易被误认为是肺癌新生病灶^[11]。相关研究指出,在平均 8 年的随访中,单纯尘肺患者中有 3.2% 进展为尘肺大阴影^[12];与始终停留在单纯尘肺阶段者比较,尘肺大阴影患者的死亡风险随年龄增长而明显升高。在国内外众多研究中,已有多位学者报道了尘肺大阴影与肺癌间因影像学相似而误诊的案例^[11,13]。也有不少研究认为当 CT 上难以区分尘肺大阴影和肺癌时,额外的 MRI 检查,特别是 T2 加权成像序列或 T1 加权 SE 成像和扩散加权成像(diffusion weighted imaging, DWD)的表观扩散系数(apparent diffusion coefficient, ADC),可以帮助区分尘肺大阴影和肺癌^[14]。然而在临床上,尘肺大阴影患者呼吸困难,喘息严重,患者难以配合完成 MRI 检查,因此大力推广也存在较大难度。

既往文献显示,依赖医师主观判读的传统 CT 征象在尘肺大阴影与肺癌鉴别中的准确度在 60%~80%^[15],稳定性受医师经验影响明显。本研究基于影像组学特征的 AdaBoost 模型在独立测试集上取得了 86.0% 的准确度(AUC 为 0.869,特异度为 89.7%),以可量化的纹理特征取代肉眼评估,既消除主观偏差,又挖掘人眼难辨的深层信息,实现客观、可重复的诊断突破。

3.2 机器学习在尘肺中的相关应用

影像组学可无创、定量地挖掘影像深层的多维信息,为早期诊断和精准治疗提供依据;精准鉴别尘肺大阴影与肺癌的影像组学差异对改善预后意义重大。人工智能(artificial intelligence, AI)的融入进一步释放了其在复杂鉴别中的潜力, WARKENTIN 等^[16]从 4 个国际肺癌筛查研究中得出利用机器学习方法进行影像组学分析以预测肺结节恶性肿瘤具有高度可行性的结论。DONG 等^[17]通过机器学习明显提升煤工尘肺风险预测及肺癌筛查的准确度。本研究基于 CT 图像,用 ITK 软件勾画 ROI 并提取降维特征后构建鉴别诊断预测模型。在独立测试集上,AdaBoost 模型表现出了良好的鉴别效能,其准确度、灵敏度、特异度及 AUC 别为 86.0%、82.1%、89.7% 和 0.869。

3.3 尘肺大阴影与肺癌鉴别诊断中病理影像相关性分析

尘肺大阴影为胶原-粉尘的均质纤维化团块,常伴钙化、卫星灶;肺癌肿块由恶性克隆增殖而成,其内含坏死、出血及异型细胞巢,密度与形态均不同。二者组织学差异为 CT 纹理定量鉴别提供了依据^[18-22]。本研究所用 4 类影像组学特征的病理-影像对应关系:

NGTDM 量化局部灰度变异:尘肺大阴影胶原纤维平行有序、粉尘沉积均一,纹理简单,复杂度、对比度低;肺癌内部的细胞巢、坏死、血管等杂乱交织,异质性强,NGTDM 各指标明显升高^[21-23]。shape 特征:反映三维趋球程度。尘肺大阴影由多结节融合-纤维收缩而成,呈分叶、多角形,球形度低;肺癌膨胀性生长,轮廓相对圆润,球形度较高^[15]。GLCM 是一种通过统计像素对联合概率来描述图像纹理的方法,给出均匀性、对比度、熵等值,尘肺大阴影层状胶原结构“有序”,均匀性高,对比度与熵值低;肺癌细胞巢排列紊乱,伴基因突变驱动的瘤内异质性,均匀性低而对比度、熵值高^[24-26]。GLSZM 描绘同质连通域尺寸分布:尘肺大阴影内部结构单一,同质区大小相近,值低;肺癌并存坏死、出血、增殖灶,尺寸-灰度差异大,大小区域混杂,值明显升高^[27-28]。

3.4 模型性能的横向对比与创新优势

本研究构建的 3 种机器学习鉴别诊断模型中,AdaBoost 模型在测试集上综合性能最优。该结果不仅验证了 AdaBoost 模型在复杂影像鉴别中的优势,也与近期相关医学影像研究^[29-30]结论一致。本研究首次将影像组学与 AdaBoost 结合应用于尘肺大阴影与肺癌的鉴别。相比以往依赖形态学特征(如“八字形”“长条索状”改变)的方法,本模型通过量化深层次纹理信息,降低了对医师经验的依赖。值得注意的是,AdaBoost 模型在测试集中特异度(89.7%)明显高于灵敏度(82.1%),这一特点在筛查中尤为重要,可减少尘肺误诊为肺癌所致的过度治疗。同时,较高的阴性预测值(83.9%)意味着模型判断为阴性时,实际为尘肺的置信度较高,有助于缓解患者心理负担。

当然本研究仍存在一定局限性:(1)本研究为单中心、回顾性研究,样本量有限,未来需要更大规模、多中心的数据集来进一步验证模型的泛化能力;(2)病灶的 ROI 为手动勾画,虽经验证具有良好的一致性,但仍可能引入人为偏差,需要进一步开发自动化分割算法(深度学习)来减少偏差;(3)需对尘肺患者进行长期随访,观察其病情变化和肺癌的进展情况,从而进一步验证模型的预测能力。

综上所述,基于 CT 影像特征的 AdaBoost 模型可以作为鉴别尘肺大阴影与周围型肺癌的新工具。

利益冲突:所有作者声明不存在利益冲突

参考文献

- [1] 原国家卫生和计划生育委员会. 职业性尘肺病的诊断:GBZ 70-2015[S]. 北京:中国标准出版社, 2016.

- [2] WEISSMAN D N. Progressive massive fibrosis: an overview of the recent literature[J]. *Pharmacol Ther*, 2022, 240:108232.
- [3] LAMBIN P, RIOS-VELAZQUEZ E, LEIJEN-AAR R, et al. Radiomics: extracting more information from medical images using advanced feature analysis[J]. *Eur J Cancer*, 2012, 48(4): 441-446.
- [4] 鲁慧民, 薛涵, 王奕龙, 等. 机器学习在影像组学分析中的应用综述[J]. *计算机工程与应用*, 2023, 59(17):22-34.
- [5] 金盛辉, 柳澄, 王焕强. 尘肺病胸部 CT 规范化检查技术专家共识(2020 年版)[J]. *环境与职业医学*, 2020, 37(10):943-949.
- [6] DOMÍNGUEZ-ALMENDROS S, BENÍTEZ-PAREJO N, GONZALEZ-RAMIREZ A R. Logistic regression models[J]. *Allergol Immunopathol*, 2011, 39(5):295-305.
- [7] HAO P Y, CHIANG J H, CHEN Y D. Possibilistic classification by support vector networks[J]. *Neural Netw*, 2022, 149:40-56.
- [8] SCHWENK H, BENGIO Y. Boosting neural networks[J]. *Neural Comput*, 2000, 12(8):1869-1887.
- [9] 刘真, 仇路, 王宁宁, 等. 叁期尘肺与肺癌肿块 CT 影像学特征对比分析[J]. *中国工业医学杂志*, 2024, 37(2):174-176, 185.
- [10] KANG S R, RHO J Y. Progressive massive fibrosis mimicking lung cancer: two case reports with potentially useful CT features for differential diagnosis[J]. *J Korean Soc Radiol*, 2022, 83(5):1175-1181.
- [11] 张宝玲, 曹殿凤. 7 例右上肺单发圆形大阴影尘肺叁期误诊误治分析[J]. *中国工业医学杂志*, 2019, 32(5):376-377.
- [12] YÜKSEL YAVUZ M, COŞKUN BEYAN A, AY-İK TÜRK M, et al. Survival analysis of patients with pneumoconiosis followed in occupational medicine clinics: 10 years experience[J]. *BMC Pulm Med*, 2025, 25(1):236.
- [13] PAKBAZ Y, MOODI F. Coal worker's pneumoconiosis mimicking lung cancer in a 75-year-old woman with a history of breast cancer: a clinical case report [J]. *Clin Case Rep*, 2025, 13(1): e70049.
- [14] OGIHARA Y, ASHIZAWA K, HAYASHI H, et al. Progressive massive fibrosis in patients with pneumoconiosis; utility of MRI in differentiating from lung cancer [J]. *Acta Radiol*, 2018, 59(1):72-80.
- [15] 王成霞, 靳毅, 柳澄, 等. 尘肺大阴影与原发肺癌肿块 CT 影像特征对比研究[J]. *中华劳动卫生职业病杂志*, 2024, 42(7):523-529.
- [16] WARKENTIN M T, AL-SAWAIHEY H, LAM S, et al. Radiomics analysis to predict pulmonary nodule malignancy using machine learning approaches[J]. *Thorax*, 2024, 79(4):307-315.
- [17] DONG H, ZHU B, KONG X, et al. Efficient clinical data analysis for prediction of coal workers' pneumoconiosis using machine learning algorithms[J]. *Clin Respir J*, 2023, 17(7):684-693.
- [18] HUA J T, COOL C D, GREEN F H Y. Pathology and mineralogy of the pneumoconioses[J]. *Semin Respir Crit Care Med*, 2023, 44(3):327-339.
- [19] WEISSMAN D N. Progressive massive fibrosis: an overview of the recent literature[J]. *Pharmacol Ther*, 2022, 240:108232.
- [20] SALLER J, BOYLE T A. Molecular pathology of lung cancer[J]. *Cold Spring Harb Perspect Med*, 2022, 12(3):a037812.
- [21] AGRAWAL R, AHUJA J, STRANGE C D, et al. Radiographic manifestations of lung cancer [J]. *Radiol Clin North Am*, 2025, 63(4):491-505.
- [22] AVANZO M, STANCANELLO J, PIRRONE G, et al. Radiomics and deep learning in lung cancer[J]. *Strahlenther Onkol*, 2020, 196(10):879-887.
- [23] BASHIR U, SIDDIQUE M M, MCLEAN E, et al. Imaging heterogeneity in lung cancer: techniques, applications, and challenges [J]. *AJR Am J Roentgenol*, 2016, 207(3):534-543.
- [24] OU X, PAN W, XIAO P. In vivo skin capacitive imaging analysis by using grey level co-occurrence matrix (GLCM)[J]. *Int J Pharm*, 2014, 460(1/2):28-32.
- [25] COOL C D, MURRAY J, VORAJEE N I, et al. Pathologic findings in severe coal workers' pneumoconiosis in contemporary US coal miners[J]. *Arch Pathol Lab Med*, 2024, 148(7):805-817.
- [26] LUCAS O, WARD S, ZAIDI (下转第 266 页)