

基于CT影像组学的机器学习模型在术前鉴别磨玻璃结节良恶性的研究

成雪^{1*}, 龚珊², 孙蓉锦², 邓琼², 贺彪², 王金花², 李正亮^{1#}

¹大理大学第一附属医院放射科, 云南 大理

²大理大学医学部, 云南 大理

收稿日期: 2025年11月23日; 录用日期: 2025年12月18日; 发布日期: 2025年12月24日

摘要

目的: 探究基于CT平扫影像组学的机器学习模型在术前鉴别磨玻璃结节良恶性中的价值。方法: 本研究采用回顾性分析, 分析2020年6月~2024年6月在大理大学第一附属医院行胸部CT平扫的121例明确GGN良恶性患者的CT影像。使用ITK-SNAP软件勾画感兴趣区(region of interest, ROI), 采用PyRadiomics软件提取特征, 通过Lasso回归算法降维。采用logistic回归算法建模, 对建立的模型分别用受试者工作特征曲线(receiver operating characteristic curve, ROC)和曲线下面积(area under the curve, AUC)评估诊断效能。结果: AUC在训练组中影像组学模型、临床模型和联合诊断模型分别为0.784 (95%CI: 0.692~0.872)、0.770 (95%CI: 0.660~0.856)和0.836 (95%CI: 0.755~0.908); 在验证组中分别为0.770 (95%CI: 0.410~1.000)、0.725 (95%CI: 0.455~0.946)和0.830 (95%CI: 0.658~0.968)。结论: 基于CT影像组学特征联合临床和常规CT影像特征构建的联合模型具有最佳预测肺GGN的良恶性的能力, 基于影像组学特征构建的机器学习模型具有良好术前区分良性和恶性GGN的诊断能力。

关键词

影像组学, 机器学习, 磨玻璃结节

A Study on Machine Learning Models Based on CT Radiomics for Preoperative Differentiation of Benign and Malignant Ground-Glass Nodules

Xue Cheng^{1*}, Shan Gong², Rongjin Sun², Qiong Deng², Biao He², Jinhua Wang², Zhengliang Li^{1#}

*第一作者。

#通讯作者。

文章引用: 成雪, 龚珊, 孙蓉锦, 邓琼, 贺彪, 王金花, 李正亮. 基于 CT 影像组学的机器学习模型在术前鉴别磨玻璃结节良恶性的研究[J]. 临床医学进展, 2025, 15(12): 2521-2530. DOI: 10.12677/acm.2025.15123684

Abstract

Objective: To explore the value of a machine learning model based on non-contrast CT radiomics in the preoperative differentiation of benign and malignant ground-glass nodules (GGNs). **Methods:** A retrospective analysis was performed in this study, involving the non-contrast chest CT images of 121 patients with pathologically confirmed benign or malignant ground-glass nodules (GGNs). These patients underwent non-contrast chest CT examinations at the First Affiliated Hospital of Dali University from June 2020 to June 2024. The region of interest (ROI) was segmented using ITK-SNAP software, and features were extracted with PyRadiomics software, followed by dimensionality reduction via the Lasso regression algorithm. A logistic regression algorithm was used for model construction, and the diagnostic performance of the established models was evaluated using the receiver operating characteristic (ROC) curve and the area under the curve (AUC). **Results:** In the training group, the AUC values of the radiomics model, the clinical model, and the combined diagnostic model were 0.784 (95%CI: 0.692~0.872), 0.770 (95%CI: 0.660~0.856), and 0.836 (95%CI: 0.755~0.908) respectively. In the validation group, the corresponding AUC values were 0.770 (95%CI: 0.410~1.000), 0.725 (95%CI: 0.455~0.946), and 0.830 (95%CI: 0.658~0.968). **Conclusion:** The combined model constructed by integrating CT radiomic features with clinical and conventional CT imaging features exhibits the optimal ability to predict the benignancy and malignancy of pulmonary GGNs. The machine learning model based solely on radiomic features demonstrates good diagnostic performance in the preoperative differentiation of benign and malignant GGNs.

Keywords

Radiomics, Machine Learning, Ground Glass Nodules

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

肺癌几十年来一直是全球最高发病率、死亡率的癌症之一[1]。随着 CT 影像检查技术逐渐发展并广泛应用于临床诊断,肺部结节可通过 CT 影像检查被发现[2]。既往研究显示,肺部结节中表现为磨玻璃样密度影的肺结节,部分病灶可长期保持稳定,但部分磨玻璃密度因病灶具有恶变潜能而逐渐进展[3][4]。根据有无实性成分,磨玻璃结节(ground-glass nodules, GGNs)分为纯磨玻璃结节(pure ground-glass nodules, pGGNs)和混合磨玻璃结节(mixed ground-glass nodules, mGGNs) [5]。已有研究[6]发现,早期诊断、早期治疗可提高肺癌患者生存率,因此术前准确评估肺 GGN 良恶性,对临床治疗方法的选择意义重大,进而影响患者预后。

早期表现为磨玻璃结节的肺癌,临床上通过临床特征和影像学特征(结节密度、是否有毛刺征和分叶征等)来判断其良恶性的方法效能并不理想[7]。文献报道[8] [9],影像组学技术能够通过提取并分析大量的、肉眼无法观察到的病灶特征,建立不受主观因素影响的模型,在癌症诊断方面具有重要价值。本研

究构建基于 CT 影像组学特征、临床和常规 CT 影像的模型,探究影像组学模型和联合模型在术前鉴别磨玻璃结节良恶性中的价值。

2. 方法

2.1. 研究对象

选取 2020 年 6 月至 2024 年 6 月在大理大学第一附属医院行胸部 CT 平扫的 121 例明确 GGN 良恶性患者进行回顾性分析,随机分为两组,比例为样本量 8:2,结果为训练组 $n = 96$,验证组 $n = 25$ 。纳入标准:(1) 具有完整的肺部 CT 平扫图像,且临床检查相关资料完整;(2) CT 图像上表现为包括纯磨玻璃结节(pGGNs)和部分实性结节(mGGNs)的磨玻璃结节;(3) CT 图像上 GGN 最大直径 ≤ 20 mm。排除标准:(1) 既往恶性肿瘤病史,患者术前曾接受相关治疗;(2) 无法获取病理资料;(3) 图像质量不佳,影响定量分析。

2.2. 检查方法

采用西门子双源 Force 高端螺旋 CT 检查设备进行肺部 CT 平扫。采集方法:100/Sn140kV,双能量模式扫描,扫描前嘱患者去除检查部位金属异物,并对患者进行呼吸与憋气训练,扫描时均采用仰卧位,统一采用“头-足”扫描方向,范围自锁骨上方约 2~3 cm 至肋膈角下约 2~4 cm,扫描过程中做好患者重要器官防护。扫描参数:A 球管:电压 100 kV、参考管电流 210 mAs, B 球管:电压 140 kV、参考管电流 160 mAs;层厚 5.0 mm,准直 $32 \text{ mm} \times 0.6 \text{ mm}$,视野 362 mm,重建层厚 1.0 mm;开启自动管电流调节(automatic tube current modulation, ATCM)技术,重建算法采用自适应迭代算法(adaptive statistical iterative reconstruction, ASIR),迭代强度 60%。

2.3. 图像分割、特征提取与建模

对 CT 图像进行预处理,CT 图像强度通过归一化转化到标准范围,并对所有 CT 图像进行重采样(体素大小 $1 \text{ mm} \times 1 \text{ mm} \times 1 \text{ mm}$)。预处理后的 CT 图像以 DICOM 格式导入 ITK-SNAP 软件,再由 2 名具有 5 年以上工作经验的影像学医师 A、B 分别对 30 例样本感兴趣区(ROI)进行独立逐层勾画,提取影像组学特征后通过组内/组间相关系数(Intra/inter-class correlation coefficient, ICC)计算组间一致性,得出组间 ICC (2, 1) = 0.89 (95%CI: 0.85~0.96);一周后由医师 A 对该 30 例样本再次进行勾画并提取影像组学特征,计算出组内 ICC (3, 2) = 0.91 (95%CI: 0.90~0.97)。结果表明两名医师之间具有良好勾画一致性,医师 A 自身具有重复勾画稳定性。基于上述一致性验证结果,剩余样本结节的分割及影像组学相关工作由医师 A 独立完成。分割后的图像导入 PyRadiomics 软件提取到 1130 个影像组学特征,包括形态学特征和二阶纹理特征:前者如肿瘤体积、最大表面积等;后者如灰度共生矩阵、灰度区域大小矩阵、灰度游程步长矩阵、灰度相关性矩阵等。对获得的影像组学特征在训练集和验证集分别进行 Z-Score 标准化处理,再通过 T 检验和套索回归(least absolute shrinkage and selection operator, LASSO)算法降维,五折交叉验证方法选择 Alpha,最终得到 12 个最有意义影像组学特征,影像组学模型构建采用 logistic 回归。

训练组依病理结果分为良性组($n = 58$)和恶性组($n = 38$),比较两组临床特征,通过单因素逻辑回归最终筛选出 3 个差异有统计学意义指标,采用 logistic 回归构建临床模型、影像组学特征 + 临床特征的联合模型。

2.4. 统计学处理

统计分析采用 Python 3.9.2。Shapiro-Wilk 检验分析计量资料的正态性,满足正态分布以 $\bar{x} \pm s$ 表示,不满足的以中位数或四分位间距描述。单因素分析比较计量资料,满足正态分布且通过方差齐性检验,

采用独立样本 t 检验(Student's t test); 不满足正态分布或未通过方差齐性检验, 采用独立样本秩和检验(Mann-Whitney U test)。计数资料以率(n%)表示, 卡方检验(Pearson's χ^2 test)进行单因素分析比较。比较三个模型训练组和验证组的效能, 评价指标为受试者工作特征曲线、曲线下面积、灵敏度、特异性、准确率、阳性预测率和阴性预测率, 并对三组模型的 AUC 进行德隆检验(Delong test), 对三组模型采用临床决策分析(Decision curve analysis, DCA)进行临床应用价值评价。P < 0.05 时差异有统计学意义。

3. 结果

3.1. 训练组和验证组临床和常规影像学基线特征

将患者随机分为训练组和验证组, 结果(见表 1)显示, 我们发现在训练组数据集上, 有 4 个临床和影像学参数在良性组和恶性组间显著不同(P < 0.05), 分别为年龄、密度、分叶征以及结节 - 肺界面。

Table 1. Comparison of clinical characteristics between benign and malignant groups in the training set and test set
表 1. 训练组和测试组患者良性组和恶性组临床特征比较


特征		训练组(n = 96)			测试组(n = 25)		
		良性(n = 58)	恶性(n = 38)	P 值	良性(n = 20)	恶性(n = 5)	P 值
性别	女	33 (56.59)	18 (47.37)	0.480	10 (50.00)	3 (60.00)	1.000
	男	25 (43.10)	20 (52.63)		10 (50.00)	2 (40.00)	
年龄(岁)		55.93 $\pm$ 15.92	63.95 $\pm$ 11.01	0.019	60.65 $\pm$ 16.10	66.00 $\pm$ 20.75	0.652
吸烟史	无	46 (79.31)	27 (71.05)	0.495	18 (90.00)	4 (80.00)	0.504
	有	12 (20.69)	11 (28.95)		2 (10.00)	1 (20.00)	
形态	圆形/类圆形	45 (77.59)	29 (76.32)	1.000	16 (80.00)	5 (100.00)	0.549
	不规则	13 (22.41)	9 (23.68)		4 (20.00)	0 (0.00)	
密度	均匀	39 (67.24)	12 (31.58)	0.001	14 (70.00)	1 (20.00)	0.120
	不均匀	19 (32.76)	26 (68.42)		6 (30.00)	4 (80.00)	
空泡征	无	56 (96.55)	33 (86.84)	0.109	20 (100.00)	5 (10.00)	1.000
	有	2 (3.45)	5 (13.16)		0 (0.00)	0 (0.00)	
分叶征	无	58 (100.00)	33 (86.84)	0.008	19 (95.00)	5 (100.00)	1.000
	有	0 (0.00)	5 (13.16)		1 (5.00)	0 (0.00)	
毛刺征	无	55 (94.83)	34 (89.47)	0.429	20 (10.00)	5 (100.00)	1.000
	有	3 (5.17)	4 (10.53)		0 (0.00)	0 (0.00)	
结节 - 肺界面	模糊	25 (43.10)	7 (18.42)	0.017	5 (25.00)	1 (20.00)	0.714
	光滑	23 (39.66)	26 (68.42)		13 (65.00)	4 (80.00)	
	毛糙	10 (17.24)	5 (13.16)		2 (10.00)	0 (0.00)	

续表


	右肺上叶	16 (27.59)	19 (50.00)		7 (35.00)	3 (60.00)	
	右肺中叶	4 (6.90)	3 (7.89)		0 (0.00)	0 (0.00)	
结节位置	右肺下叶	9 (15.52)	6 (15.79)	0.169	2 (10.00)	0 (0.00)	0.541
	左肺上叶	13 (22.41)	5 (13.16)		4 (20.00)	0 (0.00)	
	左肺下叶	16 (27.59)	5 (13.16)		7 (35.00)	2 (40.00)	

3.2. 影像组学特征筛选与模型建立

结果(见图 1)显示, LASSO 分析后在 PyRadiomics 软件提取到影像组学特征 1130 个, 将其在训练组和验证组分别进行 Z-Score 标准化处理, 确保各影像组学特征在相同标准上进行分析; 再通过 T 检验和 LASSO 算法降维、筛选出最有意义的影像组学特征 12 个(见表 2)。把 12 个特征纳入多因素 logistic 回归模型, 建立影像组学模型(见图 2), 其 AUC 在训练组中为 0.784, 在验证组中为 0.770。



(A)



(B)




Figure 1. Results of optimal radiomic feature selection via LASSO. (A) LASSO cross-validation plot; (B) Coefficient convergence plot; (C) Weighted coefficient plot
图 1. LASSO 筛选最优影像组学特征结果。(A) LASSO 交叉验证图; (B) 系数收敛图; (C) 加权系数图

Table 2. Radiomic features selected by LASSO regression
表 2. 经 LASSO 回归筛选出的影像组学特征

序号	影像组学特征参数名称
1	wavelet-HLL_gldm_SmallDependenceLowGrayLevelEmphasis
2	wavelet-HLH_glszm_GrayLevelNonUniformityNormalized
3	wavelet-HLH_glszm_SizeZoneNonUniformityNormalized
4	original_glrIm_HighGrayLevelRunEmphasis
5	original_glrIm_LowGrayLevelRunEmphasis

续表

6	log-sigma-1-mm-3D_glrml_LongRunLowGrayLevelEmphasis
7	wavelet-LHH_glcm_DifferenceEntropy
8	wavelet-LHH_glcm_SumEntropy
9	wavelet-HLH_glcm_MCC
10	wavelet-HHL_glcm_DifferenceVariance
11	wavelet-HHH_glcm_DifferenceEntropy
12	wavelet-HHH_glcm_SumEntropy




Figure 2. (A) ROC curves of each prediction model in the training set; (B) ROC curves of each prediction model in the validation set; (C) Calibration curves of the three prediction models; (D) Decision curve analysis (DCA) of the three prediction models. Note: Clinic = clinical model; Rad = radiomics model; Unite = combined model; Treat All = universal intervention; Treat None = no intervention

图 2. (A) 训练组各预测模型 ROC 曲线; (B) 验证组各预测模型 ROC 曲线; (C) 3 种预测模型校准曲线; (D) 3 种预测模型 DCA。注: clinic 为临床模型; rad 为影像学模型; unite 为联合模型; Treat All 为全干预; Treat None 为不干预。

3.3. 临床特征筛选与模型建立

本研究共纳入 121 例患者，良性组 78 例，恶性组 43 例。以 8:2 比例随机划分的 96 例训练组患者中，良性组 58 例，恶性组 38 例。对训练组良、恶性两组患者临床资料进行单因素分析和逻辑回归，筛选出 3 个 GGN 良恶性诊断的独立危险因素(见表 3)，分别为密度、年龄和结节位置。多因素 logistic 回归模型纳入这 3 临床特征后建立临床模型(见图 2)，其 AUC 在训练组中为 0.770，在验证组中为 0.725。

Table 3. Logistic regression results of clinical and conventional CT imaging data
表 3. 临床和常规 CT 影像资料逻辑回归结果

特征	P
年龄	0.012
性别	0.361
吸烟史	0.356
形态	0.885
密度	0.001
空泡征	0.095
分叶征	0.997
毛刺征	0.333
肺 - 结节界面	0.148
结节位置	0.014

3.4. 联合模型的建立与三种模型的比较

将筛选出的影像组学特征参数、临床和常规 CT 影像特征参数纳入多因素 logistic 回归模型中建立联合模型(见图 2)。校准曲线(见图 2(C))和 DCA 曲线(见图 2(D))结果显示，联合模型的临床净收益高于单一模型，在不同阈值下具有良好的临床效益。表 4 结果显示，三个模型中，联合模型诊断效能最高(AUC = 0.830)，高于影像组学模型(AUC = 0.770)及临床模型(AUC = 0.725)。因此，联合模型在术前区分良性和恶性 GGN 上具有最佳的诊断能力，影像组学模型在术前区分良性和恶性 GGN 上具有较好的诊断能力。

Table 4. Comparison of diagnostic performance among the three models
表 4. 三种模型诊断效能比较

模型名称		AUC	95%CI	SEN	SPE	ACC	PPV	NPV
训练组	影像组学模型	0.784	0.692~0.872	0.632	0.810	0.740	0.686	0.770
	临床模型	0.770	0.660~0.856	0.763	0.724	0.740	0.644	0.832
	联合模型	0.836	0.755~0.908	0.868	0.638	0.729	0.611	0.881
验证组	影像组学模型	0.770	0.410~1.000	0.600	1.000	0.920	1.000	0.909
	临床模型	0.725	0.455~0.946	1.000	0.400	0.520	0.294	1.000
	联合模型	0.830	0.658~0.968	1.000	0.750	0.800	0.500	1.000

4. 讨论

在胸部 CT 中,肺部磨玻璃结节表现为病灶密度轻度增高,其内的血管、支气管等结构仍清晰可见,不同特点(大小、位置、实性成分占比、边界特征以及胸膜牵拉等)的 GGN 具有不同随访策略和干预措施[7][10]。具有恶变潜能的 GGN 若能在术前预测其良恶性,可帮助临床医生根据患者病情选择更适合的治疗方案,对患者和临床均有重大意义。目前早期表现为 GGN 的肺腺癌的主要通过多层螺旋计算机断层扫描(computed tomography, CT)进行筛选,而可以定量描述影像特征信息的影像组学在 GGN 诊断中意义重大[11]。本研究基于影像组学、临床特征和常规 CT 影像特征构建机器学习模型并对诊断效能进行比较,探究影像组学模型、临床模型和联合模型在术前鉴别磨玻璃结节(GGN)良恶性中的价值。结果显示,联合模型诊断效能最佳,其次为影像组学模型,最后为临床模型;联合模型和影像组学模型在训练集和验证集 AUC 大于 0.7,表明能为临床诊断 GGN 提供一定帮助。

本研究回顾性选取行胸部 CT 平扫的 121 例明确 GGN 良恶性患者,对 CT 图像进行预处理后进行分割,将用 PyRadiomics 软件提取到的 1130 个影像组学特征先后进行 Z-Score 标准化处理、T 检验和 LASSO 回归筛选,得到 1 个灰度相关矩阵(wavelet-HLL_gldm_SmallDependenceLowGrayLevelEmphasis), 2 个灰度区域大小矩阵参数(wavelet-HLH_glszm_GrayLevelNonUniformityNormalized、wavelet-HLH_glszm_SizeZoneNonUniformityNormalized), 3 个灰度游程矩阵参数(original_glrml_HighGrayLevelRunEmphasis、original_glrml_LowGrayLevelRunEmphasis、log-sigma-1-mm-3D_glrml_LongRunLowGrayLevelEmphasis), 6 个灰度共生矩阵参数(wavelet-LHH_glcml_DifferenceEntropy、wavelet-LHH_glcml_SumEntropy、wavelet-HLH_glcml_MCC、wavelet-HHL_glcml_DifferenceVariance、wavelet-HHH_glcml_DifferenceEntropy、wavelet-HHH_glcml_SumEntropy),这些纹理特征体现了灰度值的变化及其空间联系,反应图像的均匀、细致、粗糙等特质,通过不同纹理信息能够捕捉病灶各个区域的特征,如 CT 纹理分析可通过评估灰度分布来帮助量化肿瘤异质性,可能间接反应肿瘤缺氧区域,为患者提供预后信息[7][12][13]。将以上 12 个影像组学特征导入 logistic 回归分析构建影像组学模型,得出训练组和验证组的 AUC 分别为 0.784 (95%CI: 0.692~0.872)、0.770 (95%CI: 0.410~1.000),表明影像组学模型具有良好术前预测 GGN 良恶性效能。

GGN 诊治过程中,需考虑如性别、年龄、家族史、既往病史、吸烟史等癌症危险因素,还需综合考虑 GGN 密度、数目、形态、大小、实性成分比例、边界情况、与邻近结构关系、有无明显恶性特征(如毛刺征、分叶征、胸膜牵拉征、支气管征)等 CT 影像特征[3][7][9][14]。本研究采用单因素分析和逻辑回归算法仅筛选出密度、年龄和结节位置 3 个特征是 GGN 良恶性诊断的独立危险因素。本研究密度特征为均匀/不均匀,密度均匀结节为 pGGN,密度不均匀结节为含有部分实性成分的磨玻璃结节(mGGN)。文献报道[3],mGGN 中的实性成分影响 GGN 的生长和预后,已成为临床诊断考虑关键因素。本研究基于将筛选出的 3 个临床和常规 CT 影像学特征纳入多因素 logistic 回归构建临床模型,该模型 AUC 在训练组中为 0.770 (95%CI: 0.660~0.856),在验证组中为 0.725 (95%CI: 0.455~0.946),表明临床模型在术前预测 GGN 良恶性效能一般。

Delong 检验显示,三种模型中影像组学联合临床模型 AUC 最高,临床模型 AUC 最低,表明联合模型术前预测 GGN 良恶性的诊断效能高于单一模型,为临床诊断 GGN 的准确性提供了更有效的方法和策略;影像组学模型 AUC 值低于联合模型但高于临床模型,表明影像组学模型具有良好诊断效能。

三种模型通过 DCA 进行临床应用价值评价,结果显示,本研究建立的三组模型中,联合模型具有最高的临床应用价值,优于影像组学模型、临床模型。

本研究局限性:为单中心回顾性研究,样本量较少,比例分配不平衡;排除无法获得病理结果和完整临床资料的患者,临床和常规 CT 影像特征没有家族史和胸膜牵拉征、支气管征;分割结节时,部分结

节边缘不清晰或受部分容积效应影响, 都会对勾画产生一定影响, 进而可能影响模型预测准确率; 构建联合模型时未采用逐步向前法分析。未来进行研究时, 将收集多中心、更大样本量、更完善临床和常规CT影像特征参数。

5. 结论

本研究基于影像组学及临床特征, 建立了影像组学模型、临床模型、联合模型 3 个模型研究术前鉴别磨玻璃结节良恶性诊断效能, 其中联合模型具有最佳预测效能, 影像组学模型高于临床模型, 影像组学模型可为临床诊断提供有效诊断方法。

致 谢

对云南省地方本科高校基础研究联合专项(202101BA070001-128)表示感谢!

声 明

本研究获得大理大学第一附属医院医学伦理委员会批准(审批号: DFY20241129007)。

参考文献

- [1] Liang, X., Zhang, C. and Ye, X. (2024) Overdiagnosis and Overtreatment of Ground-Glass Nodule-Like Lung Cancer. *Asia-Pacific Journal of Clinical Oncology*, **21**, 108-114. <https://doi.org/10.1111/ajco.14042>
- [2] 修妍, 王晓辉, 李昊, 刘婷婷. CT 影像对肺部磨玻璃结节良恶性的诊断价值[J]. 生命科学仪器, 2024, 22(4): 34-35, 38.
- [3] Chen, K. (2019) The Diagnosis and Treatment of Lung Cancer Presented as Ground-Glass Nodule. *General Thoracic and Cardiovascular Surgery*, **68**, 697-702. <https://doi.org/10.1007/s11748-019-01267-4>
- [4] Shah, H.P., Naqvi, A.S., Rajput, P., Ambra, H., Venkatesh, H., Saleem, J., et al. (2025) Artificial Intelligence-Based Deep Learning Algorithms for Ground-Glass Opacity Nodule Detection: A Review. *Narra J*, **5**, e1361. <https://doi.org/10.52225/narra.v5i1.1361>
- [5] Zheng, H., Zhang, H., Wang, S., Xiao, F. and Liao, M. (2022) Invasive Prediction of Ground Glass Nodule Based on Clinical Characteristics and Radiomics Feature. *Frontiers in Genetics*, **12**, Article ID: 783391. <https://doi.org/10.3389/fgene.2021.783391>
- [6] Tan, X. and Liu, B. (2021) Radiofrequency Ablation for Lung Ground-Glass Nodule. *Chinese Journal of Lung Cancer*, **24**, 677-682.
- [7] 朱明辉. 肺磨玻璃结节的影像组学特征与临床意义的初步研究[D]: [博士学位论文]. 北京: 中国人民解放军医学院, 2021.
- [8] 杨亚旭, 李跃华, 蒋璟璇, 等. 构建高分辨率 CT 影像组学模型预测肺部孤立性磨玻璃结节的良恶性[J]. 中国临床医学, 2023, 30(4): 676-682.
- [9] Nardone, V., Reginelli, A., Rubini, D., Gagliardi, F., Del Tufo, S., Belfiore, M.P., et al. (2024) Delta Radiomics: An Updated Systematic Review. *La Radiologia Medica*, **129**, 1197-1214. <https://doi.org/10.1007/s11547-024-01853-4>
- [10] Li, Q., Xiao, T., Li, J., Niu, Y. and Zhang, G. (2024) The Diagnosis and Management of Multiple Ground-Glass Nodules in the Lung. *European Journal of Medical Research*, **29**, Article No. 305. <https://doi.org/10.1186/s40001-024-01904-6>
- [11] 夏万城, 张婷婷, 陈爱华(审校). 影像组学在肺磨玻璃结节中的研究进展[J]. 国际医学放射学杂志, 2024, 47(1): 53-59.
- [12] Roy, S. and Maji, P. (2021) Multispectral Co-Occurrence of Wavelet Coefficients for Malignancy Assessment of Brain Tumors. *PLOS ONE*, **16**, e0250964. <https://doi.org/10.1371/journal.pone.0250964>
- [13] Ganeshan, B., Goh, V., Mandeville, H.C., Ng, Q.S., Hoskin, P.J. and Miles, K.A. (2013) Non-Small Cell Lung Cancer: Histopathologic Correlates for Texture Parameters at Ct. *Radiology*, **266**, 326-336. <https://doi.org/10.1148/radiol.12112428>
- [14] 刘倩倩, 黄小华, 潘珂. 磨玻璃样结节肺腺癌 CT 研究进展[J]. 影像研究与医学应用, 2023, 7(17): 4-6+11.