

• 临床研究 • doi:10.3969/j.issn.1671-8348.2025.08.015

网络首发 [https://link.cnki.net/urlid/50.1097.R.20250424.1350.002\(2025-04-24\)](https://link.cnki.net/urlid/50.1097.R.20250424.1350.002(2025-04-24))

基于人工智能鉴别 CT 表现为混合磨玻璃结节的腺体前驱病变与微浸润腺癌模型建立^{*}

陈永华¹, 陈 坚², 林了一¹, 陈 聪¹, 刘瑾瑾¹, 孙厚长¹, 杨运俊¹, 傅钢泽^{1△}

(1. 温州医科大学附属第一医院放射科, 浙江温州 325000; 2. 泰顺县中医院放射科, 浙江温州 325500)

[摘要] **目的** 基于人工智能建立鉴别 CT 表现为混合磨玻璃结节(mGGN)的腺体前驱病变(PGL)与微浸润腺癌(MIA)的有效模型。**方法** 回顾性分析温州医科大学附属第一医院 2017 年 1 月至 2023 年 6 月经手术病理证实且 CT 表现为 mGGN 的 180 例肺腺癌患者的临床和 CT 影像资料, 包括 PGL 患者 66 例和 MIA 患者 114 例。采用完全随机法以 8 : 2 的比例将患者分为训练集($n=144$)和测试集($n=36$)。使用 AI 软件(联影科研平台 uRP)全自动提取 CT 图像中病灶的定量参数及影像组学特征; 通过降维纳入组学的最明显相关特征, 建立 5 种机器学习分类器, 包括逻辑回归(LR)、支持向量机(SVM)、随机森林(RF)、高斯过程(GP)及决策树(DT), 以训练集曲线下面积(AUC)最高的分类器作为最佳影像组学模型, 并将其结果输出为影像组学评分(Rad-score)。将两组患者的临床信息、CT 形态特征及定量数据纳入多因素 logistic 回归分析, 筛选有效鉴别 PGL 和 MIA 的独立影响因素, 并建立临床模型。最终基于 Rad-score 和临床危险因素构建综合预测模型。采用受试者工作特征(ROC)曲线的 AUC、灵敏度、特异度和准确度评价三种模型的诊断性能。**结果** 通过 LASO 降维得到 11 个鉴别 PGL 与 MIA 的影像组学特征。在 5 种机器学习分类器中, GP 具有最佳的诊断效能, 其在训练集和测试集的 AUC 分别为 0.865、0.762。单因素、多因素 logistic 回归分析进行临床特征筛选, 使用 mGGN 的平均 CT 值、长短径平均值和实性部分长径构建的临床模型, 得到训练集和测试集的 AUC 分别为 0.870 和 0.794。综合预测模型表现出更优的诊断效能, 在训练集中的 AUC、灵敏度、特异度、准确度分别为 0.948、81.1%、91.2%、87.5%; 在测试集中的 AUC、灵敏度、特异度、准确度分别为 0.883、76.9%、91.3%、86.1%。**结论** 基于人工智能对肺结节定量及组学特征分析建立的综合预测模型能够较好地鉴别 CT 表现为 mGGN 的 PGL 与 MIA, 可用于指导临床治疗决策。

[关键词] 肺腺癌; 腺体前驱病变; 微浸润腺癌; 人工智能; 影像组学

[中图法分类号] R734.2 **[文献标识码]** A **[文章编号]** 1671-8348(2025)08-1848-06

Establishment of a model for distinguishing glandular prodromal lesions mixed with ground-glass nodules from micro-invasive adenocarcinoma on CT based on artificial intelligence^{*}

CHEN Yonghua¹, CHEN Jian², LIN Liaoyi¹, CHEN Cong¹, LIU Jinjin¹, SUN Houzhang¹,
YANG Yunjun¹, FU Gangze^{1△}

(1. Department of Radiology, the First Affiliated Hospital of Wenzhou Medical University, Wenzhou, Zhejiang 325000, China; 2. Department of Radiology, Taishun County Hospital of Traditional Chinese Medicine, Wenzhou, Zhejiang 325500, China)

[Abstract] **Objective** To establish an effective model for distinguishing glandular prodromal lesions (PGL) mixed with ground-glass nodules (mGGN) from minimally invasive adenocarcinoma (MIA) on CT based on artificial intelligence. **Methods** A retrospective analysis was conducted on the clinical and CT image data of 180 patients with lung adenocarcinoma confirmed by surgical pathology and with CT manifestations of mGGN in the First Affiliated Hospital of Wenzhou Medical University from January 2017 to June 2023, including 66 patients with PGL and 114 patients with MIA. Patients were divided into the training set ($n=144$) and the test set ($n=36$) in an 8 : 2 ratio using a completely random method. The quantitative parameters and

^{*} 基金项目: 浙江省温州市基础性公益科研项目(Y2023537)。 [△] 通信作者, E-mail: x2g2@163.com。

radiomics features of the lesions in CT images were automatically extracted using artificial intelligence software (United Imaging Research Platform uRP). By incorporating the most obvious correlation features of omics through dimensionality reduction, five machine learning classifiers were established, including logistic regression (LR), support vector machine (SVM), Random forest (RF), Gaussian process (GP), and Decision Tree (DT). The classifier with the training set highest area under the curve (AUC) was selected as the best radiomics model, and output the result as radiomics score (Rad-score). The clinical information, CT morphological characteristics and quantitative data of the two groups were included in the multivariate logistic regression analysis to screen the independent influencing factors for effectively differentiating PGL and MIA, and a clinical model was established. Finally, a comprehensive prediction model was constructed based on Rad-score and clinical risk factors. The diagnostic performance of the three models was evaluated by using the AUC, sensitivity, specificity and accuracy of receiver operating characteristic (ROC) curve. **Results** Eleven radiomics features for distinguishing PGL from MIA were obtained through LASSO dimensionality reduction. Among the five machine learning classifiers, GP has the best diagnostic performance, with AUC of 0.865 in the training set and 0.762 in the test set, respectively. Univariate and multivariate logistic regression analyses were used for clinical feature screening. The clinical model was constructed by using the average CT value, average long and short diameter, and solid partial long diameter of mGGN, and the AUCs of the training set and the test set were 0.870 and 0.794, respectively. The comprehensive prediction model demonstrated superior diagnostic performance, with AUC, sensitivity, specificity, and accuracy in the training set being 0.948, 81.1%, 91.2% and 87.5% respectively, while 0.883, 76.9%, 91.3% and 86.1% respectively in the test set. **Conclusion** The comprehensive prediction model established based on the quantitative and omics feature analysis of pulmonary nodules by artificial intelligence can well distinguish mGGN mixed with PGL from MIA on CT, and can be used to guide clinical treatment decisions.

[Key words] lung adenocarcinoma; proglandular disease; microinvasive adenocarcinoma; artificial intelligence; radiomics

肺癌是世界范围内发病率与病死率最高的恶性肿瘤,2022 年我国新发肺癌约 106.06 万例,死亡 73.33 万例,新发及死亡人数均居恶性肿瘤之首^[1]。肺癌中腺癌最为多见,根据《WHO 胸部肿瘤分类(第 5 版)》,腺癌分为腺体前驱病变(precursor glandular lesions, PGL)、微浸润性腺癌(minimally invasiveadenocarcinoma, MIA)和浸润性腺癌(invasiveadenocarcinoma, IAC)。PGL 包括非典型腺瘤样增生(atypical adenomatous hyperplasia, AAH)和原位腺癌(adenocarcinoma in situ, AIS)^[2]。PGL 属于癌前病变,不需立即手术治疗,可采取 CT 定期随访,当磨玻璃结节增大、密度增高,出现实性成分或实性部分增多时,再考虑是否手术切除, PGL 术后 5 年生存率为 100%; MIA 为孤立性小腺癌,需及时对亚肺叶进行切除(如肺段或楔形切除术)^[3-4]。肺腺癌在薄层 CT 上可表现为纯磨玻璃结节(pure ground-glass nodule, pGGN)、混合磨玻璃结节(mixed ground-glass nodule, mGGN)或实性结节。有研究显示 CT 检查中偶发的 mGGN 为恶性的概率约 63%^[5],所以临床上对 mGGN 的诊断倾向于 MIA 或 IAC,一般建议手术切除,然而在临床工作中 PGL 有时也表现为 mGGN; ZHANG 等^[6]报道一组经肺穿刺病理证实的 mGGN

患者中 PGL 占比为 21.3%。准确鉴别 mGGN 中的 PGL 可以避免患者不必要的心理压力与过度治疗。

目前,表现为 mGGN 的 PGL 与 MIA 在 CT 鉴别诊断上有一定的难度,两者不仅在影像特征上存在相互重叠,而且常规的二维平面手动测量也存在较大的误差且重复性不佳。近年来人工智能(artificial intelligence, AI)在医学领域的运用更加深入,它可以深度学习影像图像中隐含的特征信息、挖掘规律,并对未知数据进行预测,在肺癌研究中具有广阔的应用前景^[7]。故本研究利用深度学习自动分割肺部结节,自动提取 mGGN 的 CT 定量及影像组学特征,并结合 CT 形态特征构建综合预测模型,以期鉴别诊断 PGL 与 MIA。

1 资料与方法

1.1 一般资料

回顾性分析 2017 年 1 月至 2023 年 6 月在温州医科大学附属第一医院经手术病理证实的肺腺癌患者。纳入标准:(1)病理类型为 PGL 或 MIA,病理切片资料保存完整,并可复阅;(2)CT 上表现为 mGGN,结节最大径≤3 cm;(3)临床和 CT 图像资料完整、清晰。排除标准:(1)既往有肺癌或其他恶性肿瘤史;(2)严重慢性阻塞性肺疾病或肺部感染;(3)CT 检查前接受过放化疗或靶向、免疫治疗等。最终 180 例肺

腺癌患者纳入本研究,根据病理诊断结果分为 PGL 组 66 例(其中 AIS 59 例)和 MIA 组 114 例。本研究通过温州医科大学附属第一医院临床研究伦理委员会批准[审批号:临床研究伦审(YS2018)第(041)号]。

1.2 方法

1.2.1 检查方法

患者取仰卧位,双臂上举,头先进,采用 Toshiba Aquilion ONE 320 层、GE LightSpeed VCT 64 层中进行低剂量胸部 CT 扫描。检查前训练患者呼吸,在吸气末屏气后行肺尖至肺底的连续扫描。扫描范围包括肺尖至肺底的全部区域。扫描参数:管电压 120 kV,管电流 50~150 mAs,重建层厚为 1.25(GE)或 1.00(Toshiba),重建间隔 1.0 mm,螺距 0.99~1.20,矩阵 512×512。

1.2.2 CT 形态特征分析

由 2 名经验丰富的放射科医师在报告工作站上以盲法对各个 mGGN 病灶的 CT 形态特征进行评估,主要观察的特征包括分叶征、毛刺征、空泡征、空气支气管征、血管集束征及胸膜凹陷征。当意见不同时由另 1 名具有 15 年影像诊断经验的副主任医师对结果进行判定。

1.2.3 定量及组学特征筛选与机器学习

将所有图像上传至联影科研平台(uRP)对整个肺结节进行全自动勾画并进行三维定量及影像组学特征提取。获取定量特征包括肺结节的平均 CT 值(HU)、质量(mg)、容积(mm^3)、长径(mm)、短径(mm)、长短径平均值(mm)及实性部分长径(mm)。平台中影像组学利用广泛使用的 Pyradiomics3.0.0 版(<http://www.radiomics.io/pyradiomics.html>)对分割完成的肺部结节进行 CT 纹理特征提取。组学特征采用 Z 分数归一化对特征进行标准化处理,并使用 K 最佳、最小冗余最大相关、最小绝对收缩和选择算子回归(least absolute shrinkage and selection operator, LASSO)对高维特征进行降维, LASSO 回归使用 5 折交叉验证确定最优参数,以筛选得到最佳组学特征。随后,建立 5 种常见的机器学习分类器,包括逻辑回归(logistic regression, LR)、支持向量机(support vector machine, SVM)、随机森林(random forest, RF)、高斯过程(Gaussian process, GP)和决策树(decision tree, DT)。选择训练集中受试者工作特征(receiver operator characteristic, ROC)曲线中曲线下面积(area under the curve, AUC)最高的分类器作为最佳影像组学模型,并将其结果转换为相应的影像组学评分(radiomics score, Rad-score)。

1.2.4 临床模型及综合预测模型构建

将两组患者单因素分析中 $P<0.05$ 的临床资料、CT 形态及定量特征纳入多因素 logistic 回归分析,以

筛选区分 PGL 与 MIA 的独立危险因素,并建立临床模型。为了进一步提升预测模型的准确性,建立基于 Rad-score 和临床危险因素的综合预测模型。

1.3 统计学处理

采用 SPSS26.0 进行数据处理。对符合正态分布的计量资料以 $\bar{x} \pm s$ 表示,两组比较采用独立样本 t 检验。对不符合正态分布的计量资料以 $M(Q_1, Q_3)$ 表示,两组比较采用 Mann-Whitney U 检验。计数资料以例数或百分比表示,两组比较采用 χ^2 检验或 Fisher 确切概率法。对临床、CT 形态及定量特征筛选采用单因素及多因素分析,对各模型进行 ROC 曲线分析,采用 AUC、灵敏度、特异度和准确度评价不同模型的诊断性能。采用 Delong 检验比较不同模型间的 AUC。以 $P<0.05$ 为差异有统计学意义。

2 结果

2.1 CT 特征

对 180 例 CT 表现为 mGGN 的肺腺癌患者采用完全随机法以 8:2 的比例分为训练集 144 例和测试集 36 例。在训练集中, MIA 组和 PGL 组分叶征、空气支气管征和胸膜凹陷征、平均 CT 值、质量、容积、长径、短径、长短径平均值及实性部分长径间差异均有统计学意义($P<0.05$);在测试集中,仅质量、容积、长径、短径、长短径平均值及实性部分长径在两组间差异有统计学意义($P<0.05$)。其余特征在两组间差异无统计学意义($P>0.05$),见表 1。

2.2 特征筛选及模型构建

从每个肺结节内提取 2 264 个影像组学特征,通过 LASSO 回归筛选得到 11 个鉴别 PGL 与 MIA 的组学特征。ROC 曲线结果显示, GP 具有最佳的诊断效能,其在训练集和测试集的 AUC 分别为 0.865 和 0.762。多因素分析显示 mGGN 的平均 CT 值($OR=2.524, 95\%CI=1.287 \sim 4.853$)、长短径平均值($OR=2.639, 95\%CI=1.472 \sim 4.493$)和实性部分长径($OR=3.796, 95\%CI=1.896 \sim 7.513$)是鉴别 PGL 和 MIA 的独立影响因素,并以此建立临床模型,其在训练集和测试集的 AUC 分别为 0.870 和 0.794,见表 2。


进一步基于 Rad-score 与上述危险因素构建的综合预测模型在训练集中的 AUC、灵敏度、特异度、准确度分别为 0.948、81.1%、91.2%、87.5%,在测试集中分别为 0.883、76.9%、91.3%、86.1%;DeLong 检验结果显示,在训练集中,综合预测模型的 AUC 高于组学模型 GP 和临床模型($Z=3.519, 3.221, P<0.05$),在测试集中综合预测模型的 AUC 也高于组学模型 GP 和临床模型($Z=2.631, 3.412, P<0.05$),而组学模型 GP 与临床模型比较差异无统计学意义($Z=1.437, 1.738, P>0.05$),见表 2、图 1。

表 1 训练集和测试集中临床及 CT 影像特征比较

项目	训练集(<i>n</i> =144)				测试集(<i>n</i> =36)			
	PGL 组(<i>n</i> =53)	MIA 组(<i>n</i> =91)	<i>t</i> / χ^2 / <i>Z</i>	<i>P</i>	PGL 组(<i>n</i> =13)	MIA 组(<i>n</i> =23)	<i>t</i> / χ^2 / <i>Z</i>	<i>P</i>
年龄($\bar{x}\pm s$,岁)	53.47±11.49	55.46±10.97	−1.032	0.304	53.62±15.751	57.39±7.178	−2.300	0.408
性别[<i>n</i> (%)]			0.201	0.654			0.358	0.549
男	15(28.3)	29(31.9)			7(53.8)	10(43.5)		
女	38(71.7)	62(68.1)			6(46.2)	13(56.5)		
分叶征[<i>n</i> (%)]	45(84.9)	88(96.7)	6.607	0.019	12(92.3)	23(100.0)	1.820	0.361
毛刺征[<i>n</i> (%)]	5(9.4)	17(18.7)	2.213	0.137	2(15.4)	7(30.4)	1.003	0.438
空泡征[<i>n</i> (%)]	2(3.8)	10(11.0)	2.283	0.211	2(15.4)	4(17.4)	0.024	>0.999
血管集束征[<i>n</i> (%)]	1(1.9)	1(1.1)	0.152	0.700	0	1(4.3)	0.581	>0.999
空气支气管征[<i>n</i> (%)]	3(5.7)	22(24.2)	8.003	0.005	1(7.7)	5(21.7)	1.180	0.385
胸膜凹陷征[<i>n</i> (%)]	8(15.1)	33(36.3)	7.370	0.007	2(15.4)	8(34.8)	1.558	0.270
平均 CT 值($\bar{x}\pm s$,HU)	−529.70±98.91	−488.00±119.52	−2.119	0.036	−522.65±147.33	−500.00±132.21	0.447	0.658
质量[<i>M</i> (<i>Q</i> ₁ , <i>Q</i> ₃),mg]	0.38(0.23,0.61)	0.67(0.40,1.08)	−3.962	<0.001	0.52(0.23,0.73)	0.79(0.49,2.16)	−2.158	0.031
容积[<i>M</i> (<i>Q</i> ₁ , <i>Q</i> ₃),mm ³]	671.91 (402.87,972.60)	1 140.80 (615.50,1 140.80)	−2.578	0.011	776.87 (495.27,1 198.50)	1 508.39 (915.90,4 695.97)	−2.639	0.014
长径($\bar{x}\pm s$,mm)	12.18±4.07	14.99±5.25	−3.354	0.001	12.78±3.58	17.10±6.33	−2.255	0.031
短径($\bar{x}\pm s$,mm)	9.55±2.97	11.30±3.60	−3.019	0.003	9.72±1.80	13.20±4.77	−2.516	0.017
长短径平均值($\bar{x}\pm s$,mm)	10.86±3.34	13.14±4.29	−3.326	0.001	11.25±2.47	15.15±5.38	−2.458	0.019
实性部分长径($\bar{x}\pm s$,mm)	3.39±1.60	7.99±4.46	−7.236	<0.001	3.78±1.75	7.35±3.02	−3.900	<0.001

表 2 训练集和测试集中不同模型诊断性能的比较

模型	训练集				测试集			
	AUC	灵敏度(%)	特异度(%)	准确度(%)	AUC	灵敏度(%)	特异度(%)	准确度(%)
LR	0.833	66.0	82.4	76.4	0.732	76.9	73.9	75.0
SVM	0.817	60.4	83.5	75.0	0.712	61.5	87.0	74.8
RF	0.819	84.3	83.4	73.8	0.706	61.5	73.9	69.4
GP	0.865	76.6	89.0	77.9	0.762	69.2	82.6	77.9
DT	0.854	64.2	85.7	76.8	0.575	56.2	69.6	61.1
临床模型	0.870	71.7	83.5	78.2	0.794	71.5	86.0	77.8
综合预测模型	0.948	81.1	91.2	87.5	0.883	76.9	91.3	86.1



A:训练集;B:测试集。

图 1 不同预测模型在训练集和测试集的 ROC 曲线

3 讨 论

随着 CT 成像技术的普及与发展,肺结节的检出率越来越高,特别是磨玻璃结节,目前关于其临床诊断及治疗尚未达成统一共识,过度手术治疗较为常见。既往关于 AIS 与 MIA 鉴别的研究文献较少,且少有关于对 CT 表现为 mGGN 的类型进行单独研究;而在广泛用于评估肺结节恶性风险的 Brock 模型中,mGGN 是一个重要的癌症预测因子,为腺癌的一种独特亚型^[5,8],识别 mGGN 中的良性病变具有特别的临床意义。陈妙勤等^[9]分析 CT 表现为 mGGN 的 AIS 与 MIA,发现两者在胸膜凹陷征、空气支气管征及结节的直径、磨玻璃成分 CT 值比较差异有统计学意义($P<0.05$);而王欢等^[10]报道 AIS 与 MIA 在分叶征、毛刺征、胸膜牵拉征、空气支气管征、结节 CT 值、实性成分 CT 值、实性部分最大径及结节最大径差异均有统计学意义。可见除了不同的研究结果存在差异,基于医师的视觉观察及人工测量存在主观因素的影响且人工可测量的定量参数亦不全面,对鉴别 PGL 与 MIA 的可靠性有限。

近年来以深度学习为代表的 AI 技术在医学领域得到了应用与发展,基于 CT 图像的肺结节筛查、分析和诊断已进入精准化、智能化时代^[7,11]。同时,AI 可进行精准的病灶分割、定量参数的测量和敏感的影像组学特征识别,也为准确预测肺结节的病理侵袭性提供了更丰富和可重复的客观指标^[12]。已有研究显示,影像组学联合临床特征构建的预测模型对鉴别 mGGN 中的 IAC 具有较好的诊断效能(AUC 为 0.72~0.88)^[13-14],但以前的研究大多采用人工分割,耗时长,不利于临床应用。本研究采用的联影 uRP 软件,是一款商用的人工智能科研平台,能够一站式提供全自动化的病灶分隔、定量测量、影像组学特征提取及深度学习等技术,为本研究与今后临床实际运用提供了硬件支持。

本研究中,训练集的 MIA 组和 PGL 组在分叶征、空气支气管征和胸膜凹陷征、平均 CT 值、质量、容积、长径、短径、长短径平均值及实性部分长径之间的差异均有统计学意义。本研究结果与王欢等^[10]报道相符,MIA 更易出现分叶征、空气支气管征、胸膜凹陷征等形态特征,并且结节的大小、CT 值及实性部分长径等定量数据存在差异;本研究基于联影 uRP 软件还获取并验证了结节质量与容积参数的鉴别价值。多因素 logistic 回归分析显示,mGGN 的平均 CT 值、长短径平均值和实性部分长径是鉴别 PGL 与 MIA 的独立影响因素,而分叶征、空气支气管征和胸膜牵拉或凹陷征等因素被剔除,这可能与 MIA、PGL 的肿瘤细胞侵袭性和病灶内纤维化程度不高或样本量有限有关,也提示了定量参数比形态特征对鉴别 CT 表现为 mGGN 的 MIA 与 PGL 更有价值。本研究结果与 ZHANG 等^[15]与 SUN 等^[16]的研究相符,结节的大小

及 mGGN 的实性部分长径与肿瘤的浸润等级高度相关;也与 LI 等^[17]的研究结果一致,亚实性结节的平均 CT 值越高,恶性的可能性更高。本研究据此建立的临床模型在训练集和测试集的 AUC 分别为 0.870 和 0.794,诊断效能均较高。LIU 等^[18]近期对 CT 表现为亚实性结节(包括 pGGN 和 mGGN)的 MIA 与 PGL 影像图像采用 3D slicer 软件手动分割结节并行定量分析,同样对患者的临床因素与 CT 形态和定量特征通过单因素分析和多因素 logistic 回归分析,显示分叶征、实性部分长径、CT 值和实性占比为区分 MIA 与 PGL 的独立影响因素,建立的临床模型在训练集和测试集的 AUC 分别为 0.837 和 0.796,这与本研究结果基本相似,但是分叶征存在差异,推测原因是本研究中分叶征在表现为 mGGN 的 MIA 组和 PGL 组中占比较高,分别为 96.7%和 84.9%,从而降低了分叶征的鉴别价值。

ZHU 等^[19]对 129 例表现为 pGGN 的患者行组学研究,建立预测 MIA 和 PGL 的组学模型,其在训练集和验证集的 AUC 值分别为 0.884、0.872。目前还未有基于 AI 鉴别 CT 表现为 mGGN 的 PGL 与 MIA 的研究。本研究基于深度学习 AI 对 CT 表现为 mGGN 目标结节进行深度挖掘和量化分析,共提取 2 264 个影像组学特征,通过 LASSO 回归筛选,降维得到 11 个鉴别 PGL 和 MIA 最明显相关的纹理特征,其中灰度级带矩阵(gray level size zone matrix, GLSZM)和灰度级长矩阵(gray level run-length matrix, GLRLM)特征所占比例最高,主要反映病灶的表面粗糙程度、病灶内灰度分布及局部非均匀性,其值越大通常代表肿瘤异质性越高;这与 ZHU 等^[19]研究结果存在差异,其研究中筛选的影像组学特征中灰度依赖矩阵(gray level dependence matrix, GLDM)和灰度共生矩阵(gray level co-occurrence matrix, GLCM)所占比例最高,可见 mGGN 具有独特的组学特征,有必要与 pGGN 区分并分类研究。在本研究中建立的 5 种机器学习分类器中,GP 具有更高的诊断效能,其在训练集和测试集的 AUC 分别为 0.865 和 0.762。可见,基于组学特征构建的模型对鉴别 CT 表现为 mGGN 的 MIA 与 PGL 一样具有较高的诊断效能。为了进一步提高预测模型的可解释性和准确性,本研究基于 Rad-score 和临床危险因素建立了综合预测模型,ROC 曲线结果显示综合预测模型相较于组学模型或临床模型,表现出更优的诊断效能。

本研究存在一些局限性:(1)本研究为回顾性单中心研究,数据可能存在选择性偏倚;(2)样本量不大,未来需要收集多中心数据来验证模型的泛化能力;(3)本研究中的 CT 图像由不同品牌 CT 机器扫描所得,可能存在一定的偏差。

综上所述,基于 AI 对肺结节定量及影像组学特征分析建立的综合预测模型能够较好地鉴别 CT 表现

为 mGGN 的 PGL 与 MIA,其诊断效能较单一的临床模型或组学模型更高,可用于临床日常工作、指导治疗决策。

参考文献

- [1] 郑荣寿,陈茹,韩冰峰,等. 2022 年中国恶性肿瘤流行情况分析[J]. 中华肿瘤杂志, 2024, 46(3): 221-231.
- [2] NICHOLSON A G, TSAO M S, BEASLEY M B, et al. The 2021 WHO classification of lung tumors: impact of advances since 2015 [J]. J Thorac Oncol, 2022, 17(3): 362-387.
- [3] YANKELEVITZ D F, YIP R, SMITH J P, et al. CT screening for lung cancer: nonsolid nodules in baseline and annual repeat rounds[J]. Radiology, 2015, 277(2): 555-564.
- [4] LEE S M, PARK C M, GOO J M, et al. Invasive pulmonary adenocarcinomas versus preinvasive lesions appearing as ground-glass nodules: differentiation by using CT features[J]. Radiology, 2013, 268(1): 265-273.
- [5] MACMAHON H, NAIDICH D P, GOO J M, et al. Guidelines for management of incidental pulmonary nodules detected on CT images: from the fleischner society 2017[J]. Radiology, 2017, 284(1): 228-243.
- [6] ZHANG H, SI T, GUO Z. Clinicopathologic characteristics of pulmonary ground glass opacity located preoperatively using a Hook-wire guide-wire[J]. J Interv Med, 2020, 3(2): 89-92.
- [7] HU X, GONG J, ZHOU W, et al. Computer-aided diagnosis of ground glass pulmonary nodule by fusing deep learning and radiomics features [J]. Phys Med Biol, 2021, 66(6): 065015.
- [8] MCWILLIAMS A, TAMMEMAGI M C, MAYO J R, et al. Probability of cancer in pulmonary nodules detected on first screening CT[J]. N Engl J Med, 2013, 369(10): 910-919.
- [9] 陈妙勤. 高分辨率 CT 在肺原位腺癌及微浸润腺癌鉴别诊断中的价值分析[J]. 现代医用影像学, 2024, 33(4): 648-651.
- [10] 王欢, 陈志军, 王兆宇, 等. 表现为混杂密度磨玻璃结节的肺原位腺癌和微浸润腺癌的 HRCT 影像学表现[J]. 现代实用医学, 2019, 31(9): 1227-1229.
- [11] WANG Y, YAN F, LU X, et al. IILS: intelligent imaging layout system for automatic imaging report standardization and intra-interdisciplinary clinical workflow optimization [J]. EBioMedicine, 2019, 44: 162-181.
- [12] XU Y, LI Y, YIN H, et al. Consecutive serial non-contrast CT scan-based deep learning model facilitates the prediction of tumor invasiveness of ground-glass nodules[J]. Front Oncol, 2021, 11: 725599.
- [13] WENG Q, ZHOU L, WANG H, et al. A radiomics model for determining the invasiveness of solitary pulmonary nodules that manifest as part-solid nodules [J]. Clin Radiol, 2019, 74(12): 933-943.
- [14] WU G, WOODRUFF H C, SHEN J, et al. Diagnosis of invasive lung adenocarcinoma based on chest CT radiomic features of part-solid pulmonary nodules: a multicenter study[J]. Radiology, 2020, 297(2): 451-458.
- [15] ZHANG Y P, HEUVELMANS M A, ZHANG H, et al. Changes in quantitative CT image features of ground-glass nodules in differentiating invasive pulmonary adenocarcinoma from benign and in situ lesions: histopathological comparisons[J]. Clin Radiol, 2018, 73(5): 504.
- [16] SUN F, XI J, ZHAN C, et al. Ground glass opacities: imaging, pathology, and gene mutations[J]. J Thorac Cardiovasc Surg, 2018, 156(2): 808-813.
- [17] LI X, ZHANG W, YU Y, et al. CT features and quantitative analysis of subsolid nodule lung adenocarcinoma for pathological classification prediction[J]. BMC Cancer, 2020, 20(1): 60.
- [18] LIU M, DUAN R, XU Z, et al. CT-based radiomics combined with clinical features for invasiveness prediction and pathological subtypes classification of subsolid pulmonary nodules [J]. Eur J Radiol Open, 2024, 13: 100584.
- [19] ZHU Y Q, LIU C, MO Y, et al. Radiomics for differentiating minimally invasive adenocarcinoma from precursor lesions in pure ground-glass opacities on chest computed tomography [J]. Br J Radiol, 2022, 95(1134): 18.

(收稿日期: 2024-11-16 修回日期: 2025-04-18)

(编辑: 成 卓)