

论著·胸部

开发并验证基于CT的深度学习联合模型预测肺腺癌气道播散:一项多中心、回顾性研究*

谭国光¹ 高镇伟¹ 张榕²
叶辉映³ 杨少民^{1,*}1.南方医科大学顺德医院附属杏坛医院
(佛山市顺德区第一人民医院附属杏坛
医院)放射科 (广东佛山 528308)2.南方医科大学顺德医院(佛山市顺德区
第一人民医院)放射科 (广东佛山 528308)3.广东医科大学附属第二医院放射科
(广东湛江 524003)

【摘要】目的 开发一种基于CT的深度学习联合模型预测肺腺癌气道播散。**方法** 纳入2019年1月至2023年12月3家医院经CT扫描和手术诊断为肺腺癌593例患者,分为训练组、内部验证组、外部验证组。基于Resnet-101为基础模型,从肺腺癌患者CT图像中构建一个深度学习标签(DL-score),使用7种机器学习算法,包括逻辑回归(LR)、极端梯度增强(Xgboost)、支持向量机(SVM)、随机森林(RF)、决策树(DT)、k近邻(KNN)和人工神经网络(ANN)构建联合模型预测肺腺癌STAS。**结果** 对比训练队列中7种不同机器学习模型,ANN模型表现出最佳预测效能,在训练组和内部验证组的受试者工作特征(ROC)曲线下面积(AUC)分别为0.906 (95% CI: 0.873~0.936)和0.903 (95% CI: 0.855~0.944)。在外部验证组中,AUC为0.841 (95% CI: 0.757~0.923),显示出令人满意的推广效果。**结论** 基于CT的深度学习联合模型(ANN)可以准确评估肺腺癌患者气道播散,可成为指导临床术前诊疗的有效辅助工具。

【关键词】 肺腺癌; 气道播散;
人工神经网络; 深度学习; 机器学习

【中国分类号】 R445

【文献标识码】 A

【基金项目】 广东省医学科研基金项目
(A2024112);

佛山市科技计划项目

(2320001006640);

南方医科大学顺德医院科研启动项目
(SRSP2023003)

DOI:10.3969/j.issn.1672-5131.2025.11.015

Development and Validation of A CT-based Deep Learning Combined Model for Predicting Airway Spread of Lung Adenocarcinoma: A Multicentre, Retrospective Study*

TAN Guo-guang¹, GAO Zhen-wei¹, ZHANG Rong², YE Hui-ying³, YANG Shao-min^{1,*}.

1.Department of Radiology, Xingtan Hospital Affiliated to Shunde Hospital of Southern Medical University (The First People's Hospital of Shunde,Foshan), Foshan 528308, Guangdong Province, China

2.Department of Radiology, Shunde Hospital of Southern Medical University (The First People's Hospital of Shunde,Foshan),Foshan 528308, Guangdong Province, China

3.Department of Radiology, The Second Affiliated Hospital of Guangdong Medical University, Zhanjiang 524003, Guangdong Province, China

ABSTRACT

Objective To develop a Ct-based deep learning combined model for predicting airway spread of lung adenocarcinoma. **Methods** From January 2019 to December 2023, 593 patients diagnosed with lung adenocarcinoma by CT scan and surgery in 3 hospitals were included and divided into training group, internal verification group and external verification group. Based on RESNET-101-based model, a deep learning label (DL-score) was constructed from CT images of lung adenocarcinoma patients. Seven machine learning algorithms including logistic regression(LR), extreme gradient enhancement(Xgboost), support vector machines(SVM), random forest(RF), decision trees(DT), K-nearest neighbors(KNN), and artificial neural networks(ANN) were used to construct a combine model to predict lung adenocarcinoma STAS. **Results** Compared with 7 different machine learning models in the training cohort, ANN model showed the best predictive efficiency. The area under receiver operating characteristic (ROC) curves (AUC) in the training and internal validation groups were 0.906 (95% CI: 0.873~0.936) and 0.903 (95% CI,0.855~0.944), respectively. In the external validation group, the AUC was 0.841 (95% CI: 0.757~0.923), showing a satisfactory generalization effect. **Conclusion** The Ct-based deep learning combine model (ANN) can accurately evaluate the airway spread of lung adenocarcinoma patients, and can be an effective auxiliary tool to guide the preoperative diagnosis and treatment.

Keywords: Lung Adenocarcinoma; Spread Through Air Spaces; Artificial Neural Network; Deep Learning; Machine Learning

非小细胞肺癌(non-small-cell lung cancer, NSCLC)是全球范围内癌症相关死亡的主要原因,严重威胁着全世界人民的健康和安全^[1],其中肺腺癌是最常见的病理组织学亚型,手术是其最主要治疗方法,然而,肺腺癌患者即使在术后,其长期复发率仍然很高^[2]。2015年,世界卫生组织(world health organization, WHO)报道肺癌另一种侵袭方式,通过气道播散(spread through air spaces, STAS),并将其定义为肿瘤细胞(如微乳头状簇状、实体巢状或单个癌细胞)在肺泡中扩散到主要肿瘤边缘以外的气道^[3-4]。随后一些研究表明,STAS阳性患者肿瘤生物学侵袭性更强,肿瘤复发和淋巴结转移风险率更高,患者生存率更低^[3,5-7]。因此,肺腺癌患者STAS的评估可以影响临床决策,如手术方式的选择、淋巴结清扫程度以及术后放疗的需要。目前评估STAS的金标准主要依赖病理学分析。然而,由于病理的多样性、标准的不一致性以及术中对标本的影响,术中冷冻切片对STAS检测敏感性较低,不能为临床尤其是手术决策提供可靠的指导^[3,8],因此,需要制定术前STAS预测新策略。

既往研究表明^[9-10],STAS与CT影像征象具有相关性,如肿瘤实性成份百分比、空泡征、肿瘤边界、支气管充气征对STAS具有预测价值。然而,传统影像学诊断指标和征象存在诸多局限性,如CT扫描技术参数差异、成像标准的不一致性及对征象主观判断的差异等。Jiang等^[11]利用CT影像组学构建模型预测肺腺癌STAS,模型AUC达到0.754。Liu等^[12]基于92例IA期肺腺癌患者CT影像组学建立随机森林模型,预测IA期肺腺癌术前STAS表达,模型的误诊率仅为7.69%,以上研究证实了CT影像组学预测肺腺癌STAS的可行性。

深度学习是机器学习领域的一个新的研究方向,是一种更细致的机器学习算法,用于学习样本数据的内在规律、特征识别和模型构建^[13]。近十年来,影像组学和深度学习在医学影像诊断和相关个体医学方面做出了有价值的临床贡献^[14]。然而,目前还没有研究采用深度学习预测肺腺癌STAS,本研究基于多中心队列,旨在构建并验证一种深度学习模型,用于肺腺癌STAS的精确预测,以提高临床医生对临床决策支持工具的可接受性和实用性,为肺腺癌患者的个性化、精准治疗和减少过度治疗提供理论依据和参考意见。

1 资料和方法

【第一作者】谭国光,男,副主任医师,主要研究方向:胸部CT影像诊断。E-mail: 452184037@qq.com

【通讯作者】杨少民,男,主任医师,主要研究方向:胸部CT影像诊断。E-mail: ysmsin@aliyun.com

1.1 一般资料 本研究是根据赫尔辛基宣言(2013年修订)进行,并获得了机构伦理审查委员会的批准,由于该研究属于回顾性研究,患者放弃了知情同意要求。纳入2019年1月至2023年12月南方医科大学顺德医院(中心 I)、南方医科大学顺德医院附属杏坛医院(中心 II)及广东医学院附属第二医院(中心 III)确诊为肺腺癌患者。符合以下条件之一的患者被排除在外:(1)影像和临床资料缺失;(2)既往肺部手术史;(3)多灶性肺腺癌;(4)既往肺腺癌新辅助化疗;(5)有其他恶性肿瘤。见图1。

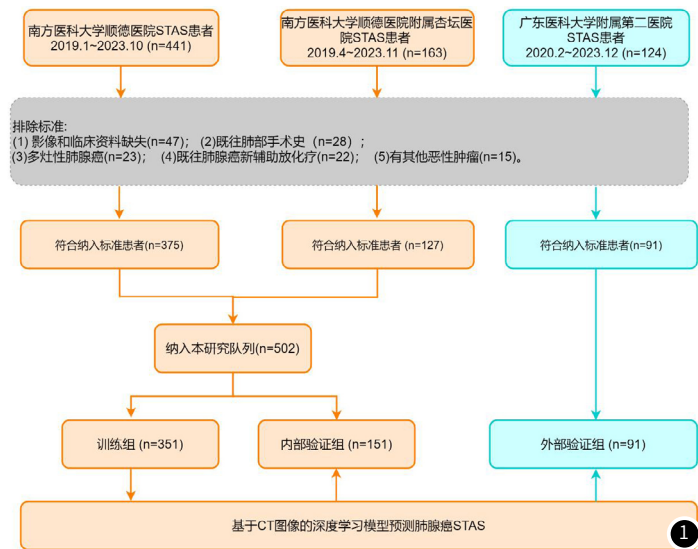


图1 纳入和排除标准流程图。

1.2 CT扫描设备及图像分析 所有患者使用三家医院的三台CT扫描仪进行检查,分别是64层(SOMOATOM Definition Flash,Siemens)多层CT扫描仪,64层(SOMOATOM Definition AS,Siemens)CT扫描仪和256层(GE Revolution, GE)多层螺旋CT扫描仪。CT扫描参数为:管电压120kV;管电流200~300mAs;FOV350~400mm;扫描厚度1~5mm;重建图像厚度0.6~0.8mm;螺距1.0~1.5。术前CT图像从三家医院的图像存档和通信系统(PACS)中获取,将CT图像以DICOM格式导入深睿软件(<https://keyan.deepwise.com>)进行标注,由三名高年资放射科医生进行独立感兴趣区勾画(窗位:-500HU;窗宽:1500HU),任何分歧通过咨询具有超过15年经验的放射科医生协商解决。本研究评估了肺腺癌的临床及放射学因素,如年龄、性别、肿瘤直径、肿瘤位置、肿瘤成份、瘤肺边界、分叶征、毛刺征、胸凹陷征、空气支气管征、空泡征、月牙征、微血管征、CT值和肿瘤实性成分占比(consolidation tumor ratio, CTR)。

1.3 病理组织学评价 所有肿瘤病理按照世界卫生组织和国际肺癌研究协会(international association for the study of lung cancer,IASLC)最新定义进行分类^[15],将切除的标本用10%福尔马林固定,置于石蜡块上,切片为5μm,苏木精和伊红染色。当肿瘤细胞与主要肿瘤分离并在主要肿瘤周缘以外的肺泡间隙内发现时,认为存在STAS,所有病理组织切片由具有15年经验的肺部病理学家阅片。

1.4 构建深度学习DL-score 将中心 I 和中心 II 患者按7:3随机比例分为训练组和内部验证组,中心 III 归纳为外部验证组。在本研究中,使用的迁移学习模型为ResNet-101,预训练的初始权值来自ImageNet数据集(图2)。在设置特定任务部分参数时,采用余弦退火的输出作为深度学习得分(DL-score)进行下一步分析。




图2 深度学习CT图像分析。左图为CT图像肿瘤ROI靶区勾画;中图为深度学习激活热图;右图为深度学习ResNet-101网络结构。

1.5 临床放射组学模型构建 采用单因素logistic回归分析筛选STAS阳性肺癌患者临床及影像学因素($P < 0.05$),采用多因素logistic回归筛选独立危险因素,并构建临床模型。

1.6 统计分析 采用Student's t检验的参数检验和Mann-Whitney u检验的非参数检验来比较STAS阳性组与阴性组的差异,分类变量采用卡方检验。多因素logistic回归分析确定独立危险因素。采用受试者工作特征(ROC)曲线下面积(area under receiveroperating characteristic, AUC)、准确度、灵敏度和特异度比较模型性能。采用Python(3.7.3)和R(4.1.3)软件进行统计分析。双侧 P 值 < 0.05 认为有统计学意义。

2 结果

2.1 一般资料比较 患者临床和放射学基线信息汇总见表1。

2.2 深度学习模型的构建与验证利用Resnet-101模型作为深度学习架构,完成图像检测、语义分割等计算机任务,利用残差链接改进信息传播和学习,并进一步建立深度学习模型(DLmodel)。DL-model模型在训练队列和内部验证队列中的AUC分别为0.861(95% CI: 0.822~0.897)和0.735(95% CI:0.652~0.815)。

2.3 临床模型的构建与验证 单因素logistic分析显示,年龄、肿瘤直径、分叶征、毛刺征、胸膜凹陷征、空气支气管征、空泡征、微血管征与STAS有显著相关性($P < 0.05$)。随后,通过多因素logistic回归分析,显示分叶征、空泡征和微血管征是预测STAS三个独立危险因素(表2)。最后,选择三个独立危险因素,采用逐步logistic回归构建临床模型。临床模型在训练组和内部验证组中的AUC分别为0.859(95% CI:0.821~0.893)和0.837(95% CI: 0.779~0.887)。

2.4 构建多机器学习联合模型及验证 基于多元logistic回归结果,整合三个独立危险因素和DL-score,采用7种机器学习算法在训练组中构建联合模型,比较7种多机器学习联合模型性能,ANN模型获得了最佳预测效能。在训练组和内部验证组中,ANN模型具有令人满意的泛化性能。对比临床模型及深度学习模型,ANN模型是预测肺腺癌STAS最佳模型(表3)。

3 讨论

在这项多中心、回顾性研究中,我们开发并验证了一种基于CT影像的深度学习模型(ANN模型)预测肺腺癌STAS,并与常规6种传统机器学习模型进行比较,ANN模型表现出最佳的预测效能,并在内部验证组和外部验证组中模型得到了泛化性验证。

CT是评估肺腺癌的常规检查方式,已有研究报道,CT影像学征象对肺腺癌STAS的评价和预测具有潜在价值。Kim等^[9]报道肺腺癌中实性成分百分比与STAS相关。Sun等^[16]发现肿瘤CT值与STAS相关,因此也可用于评估STAS。在我们的研究中,分叶征、空泡征和微血管征是预测STAS的独立危险因素,这与以往的研究一致。我们推测可能是以下原因,分叶征是由于肿瘤细胞分化程度不同,生长速度不同,肿块边缘不均匀,可以向周围多个方向生长,STAS阳性患者恶性程度较高,肿瘤细胞生长活跃,可全方位反映不同肿瘤细胞的浸润和生长情况。空泡征是鉴别肺腺癌与其他良性肿瘤的重要征象,特别是在早期肺癌的鉴别诊断中^[17]。Kim等^[9]发现STAS与空泡征等CT征象相关,我们与之研究一致,表明STAS与空泡征之间存在关联。在肺腺癌中,微血管征象可以提示肿瘤相关微血管生成,即新生血管的形成,为肿瘤提供营养和氧分^[18-19],这些征象可能包括肿瘤内部或周围血管扩张或异常血管分支,肺腺癌影像学征象中微血管征对预测STAS具有诊断和预后意义^[20],微血管增生可能表明肿瘤更具侵袭性,而微血管侵袭的特定模式可能影响治疗计划及对治疗的反应,因此,STAS阳性患者预后较差,这与肿瘤内微血管生成有关。

机器学习技术是一种处理复杂和广泛数据的强大计算方法,它可以处理高度可变的数据集,并以灵活且可训练的方式理解变量之间的复杂关系^[21]。深度学习是机器学习的一个子领域,其注重人脑神经网络结构和功能启发算法^[22],ResNet是一种经典的人工神经网络,已广泛应用于医学图像识别和语义分割,其中

ResNet-101作为一种深度残差网络架构,其关键创新在于引入了跳过连接或残差连接^[23-24],这些连接允许梯度在训练过程中更容易地在网络中流动,减少梯度消失问题,并在许多基准数据集上获得最先进的性能。ResNet-101可应用于放射组学中的医学图像分析等任务,并可以作为特征提取器,从医学图像中自动学习和提取有意义的特征,并用于解决深度网络在训练过程中由于梯度消失而无法获得更好性能时遇到的退化问题^[25-26]。因此,作为特征提取工具,它具有其他神经网络所不具备的优势。本研究使用由大型计算机视觉数据集ImageNet预训练的ResNet-101模型来提取深度学习特征,我们采用了7中机器学习算法构建联合模型,研究表明,ANN模型比其他机器学习模型具有优势,AUC为0.906(95%CI: 0.873~0.936),准确度为0.849,灵敏度为0.839,特异度为0.858。在内部验证组和外部验证组中,ANN模型表现出最佳的预测性能和泛化能力,结果令人满意。因此,基于深度

学习ANN模型比传统的六种机器学习模型具有优势。本研究结果证实了深度学习模型在肺腺癌STAS中的可靠性,具有较高的准确性。本研究有一些局限性,首先,需要进行前瞻性分析,以进一步确定ANN模型的性能。其次,临床资料收集不够全面(如吸烟史),忽略了潜在的预测因素。第三,没有对所有纳入的患者进行预后分析,尚不清楚深度学习特征是否与生存结果相关,将在未来的工作中进一步进行研究,以充分评估我们提出模型的预测效率。本研究采用ResNet-101进行迁移学习并输出DL-score,结合7种机器学习方法构建联合模型。其中ANN模型在预测肺腺癌STAS方面优于传统模型,且在多中心数据中验证了良好泛化能力,有助于早期识别STAS高危患者,具有重要预测价值。该模型可辅助临床优化肺腺癌患者的评估与管理,值得通过大型前瞻性研究进一步验证,以推动个体化诊疗决策。

表1 三个中心患者临床和放射学基线资料表

Items	训练组(N=351)			内部验证组(N=151)			外部验证组(N=91)		
	STAS(-) (N=190)	STAS(+) (N=161)	P值	STAS(-) (N=82)	STAS(+) (N=69)	P值	STAS(-) (N=50)	STAS(+) (N=41)	P值
性别			<0.001			0.678		0.053	
男	69(36.3)	93(57.8)		33(40.2)	31(44.9)		18(36.0)	24(58.5)	
女	121(63.7)	68(42.2)		49(59.8)	38(55.1)		32(64.0)	17(41.5)	
年龄(years)	63.0 (53.0,71.0)	66.0 (58.0,71.0)	0.020	61.0 (51.8,70.3)	63.0 (56.0,72.0)	0.086	62.0 (56.0,70.0)	65.0 (57.0,69.0)	0.696
肿瘤位置			0.778			0.957			0.486
左肺下叶	22(11.6)	25(15.5)		8(9.8)	9(13.0)		8(16.0)	8(19.5)	
左肺上叶	50(26.3)	37(23.0)		23(28.0)	21(30.4)		10(20.0)	8(19.5)	
右肺下叶	42(22.1)	32(19.9)		15(18.3)	11(15.9)		7(14.0)	11(26.8)	
右肺中叶	11(5.8)	11(6.8)		8(9.8)	6(8.7)		6(12.0)	4(9.8)	
右肺上叶	65(34.2)	56(34.8)		28(34.1)	22(31.9)		19(38.0)	10(24.4)	
肿瘤成份			<0.001			<0.001			<0.001
实性	39(20.5)	104(64.6)		18(22.0)	33(47.8)		15(30.0)	29(70.7)	
磨玻璃	68(35.8)	5(3.1)		25(30.5)	4(5.8)		18(36.0)	0(0.0)	
部分实性	83(43.7)	52(32.3)		39(47.6)	32(46.4)		17(34.0)	12(29.3)	
分叶征			<0.001			<0.001			<0.001
无	145(76.3)	21(13.0)		64(78.0)	16(23.2)		32(64.0)	6(14.6)	
有	45(23.7)	140(87.0)		18(22.0)	53(76.8)		18(36.0)	35(85.4)	
毛刺征			1.000			1.000			1.000
无	114(60.0)	27(16.8)		45(55.6)	18(26.1)		25(50.0)	11(26.8)	
有	76(40.0)	134(83.2)		36(44.4)	51(73.9)		25(50.0)	30(73.2)	
胸膜凹陷征			<0.001			0.543			0.027
无	86(45.3)	37(23.0)		36(43.9)	26(37.7)		26(52.0)	11(26.8)	
有	104(54.7)	124(77.0)		46(56.1)	43(62.3)		24(48.0)	30(73.2)	
空气支气管征			1.000			1.000			0.006
无	86(45.3)	58(36.0)		36(43.9)	31(44.9)		38(76.0)	20(48.8)	
有	104(54.7)	103(64.0)		46(56.1)	38(55.1)		12(24.0)	21(51.2)	
月牙征			0.031			0.270			0.320
无	143(75.3)	137(85.1)		66(80.5)	61(88.4)		43(86.0)	31(75.6)	
有	47(24.7)	24(14.9)		16(19.5)	8(11.6)		7(14.0)	10(24.4)	
空泡征			<0.001			<0.001			0.201
无	111(58.4)	135(83.9)		40(48.8)	61(88.4)		36(72.0)	35(85.4)	
有	79(41.6)	26(16.1)		42(51.2)	8(11.6)		14(28.0)	6(14.6)	
微血管征			0.011			0.103			0.012
无	12(6.3)	1(0.6)		5(6.1)	0(0.0)		9(18.0)	0(0.0)	
有	178(93.7)	160(99.4)		77(93.9)	69(100.0)		41(82.0)	41(100.0)	
瘤肺边界			0.409			0.959			0.011
无	37(19.5)	25(15.5)		20(24.4)	18(26.1)		25(50.0)	9(22.0)	
有	153(80.5)	136(84.5)		62(75.6)	51(73.9)		25(50.0)	32(78.0)	
肿瘤直径(mm)	15.5 (11.2,21.9)	18.0 (14.0,26.0)	0.001	14.2 (11.3,20.7)	15.0 (12.0,23.0)	0.312	15.0 (10.0,19.2)	18.0 (11.0,31.0)	0.017
CT 值	-382.3 (-551.6,-187.3)	5.4 (-90.4,26.7)	<0.001	-392.9 (-500.8,-222.8)	-29.0 (-240.2,23.0)	<0.001	-330.1 (-570.7,-84.9)	15.4 (-60.3,40.4)	<0.001
CTR	0.3(0.0,0.6)	1.0(0.7,1.0)	<0.001	0.3(0.0,0.8)	0.9(0.4,1.0)	<0.001	0.4(0.0,1.0)	1.0(0.8,1.0)	<0.001

表2 临床、放射学特征单因素及多因素logistic分析

因素	单因素logistic分析			多因素logistic分析		
	OR	95% CI	P值	OR	95% CI	P值
年龄(years)	1.02	1.01~1.04	0.013	1.00	0.98~1.03	0.845
肿瘤直径(mm)	1.04	1.01~1.06	0.004	0.99	0.96~1.03	0.709
分叶征(有)	21.48	12.18~37.90	<0.001	13.41	6.64~27.08	<0.001
毛刺征(有)	7.44	4.49~12.34	<0.001	1.98	0.95~4.16	0.070
胸膜凹陷征(有)	2.77	1.74~4.41	<0.001	1.19	0.62~2.29	0.604
空气支气管征(有)	1.47	0.96~2.26	0.080	~	~	~
空泡征(有)	0.27	0.16~0.45	<0.001	0.29	0.15~0.55	<0.001
微血管征(有)	10.79	1.39~83.76	0.023	15.03	1.61~139.94	0.017

注: OR, odds ratio; CI, confidence interval

表3 临床、深度学习及联合模型性能分析

	模型	性能指标			
		AUC (95% CI)	准确度	灵敏度	特异度
训练组	临床模型	0.859 (0.821~0.893)	0.818	0.863	0.779
	深度学习模型	0.861 (0.822~0.897)	0.792	0.851	0.742
	ANN模型	0.906 (0.873~0.936)	0.849	0.839	0.858
内部验证组	临床模型	0.837 (0.779~0.887)	0.781	0.768	0.793
	深度学习模型	0.735 (0.652~0.815)	0.662	0.681	0.646
	ANN模型	0.903 (0.855~0.944)	0.821	0.739	0.89
外部验证组	临床模型	0.800 (0.713~0.878)	0.769	0.854	0.7
	深度学习模型	0.753 (0.652~0.861)	0.692	0.878	0.54
	ANN模型	0.841 (0.757~0.923)	0.791	0.854	0.74




图3 多机器学习模型性能ROC曲线分析。(图3A) 训练组模型性能分析; (图3B) 内部验证组模型性能分析; (图3C) 外部验证组模型性能分析。

参考文献

[1] Saad M B, Hong L, Aminu M, et al. Predicting benefit from immune checkpoint inhibitors in patients with non-small-cell lung cancer by CT-based ensemble deep learning: a retrospective study[J]. *Lancet Digit Health*, 2023, 5(7): e404-e420.

[2] 张庆团, 郭兴全, 王家鹏. 低剂量CT联合血清肿瘤标志物在早期非小细胞肺癌诊断中的应用价值[J]. *中国CT和MRI杂志*, 2023, 21(2): 58-60.

[3] Kadota K, Nitadori J I, Sima C S, et al. Tumor spread through air spaces is an important pattern of invasion and impacts the frequency and location of recurrences after limited resection for small stage I lung adenocarcinomas[J]. *J Thorac Oncol*, 2015, 10(5): 806-814.

[4] 徐跻京, 丁瀚林, 黄兴, 等. 肺癌的气腔内播散[J]. *临床与病理杂志*, 2022, 42(7): 1764-1768.

[5] Wang Y, Ding Y, Liu X, et al. Preoperative CT-based radiomics combined with tumour spread through air spaces can accurately predict early recurrence of stage I lung adenocarcinoma: a multicentre retrospective cohort study[J]. *Cancer Imaging*, 2023, 23(1): 83.

[6] Villalba J A, Shih A R, Sayo T, et al. Accuracy and reproducibility of intraoperative assessment on tumor spread through air spaces in stage I lung adenocarcinomas[J]. *J Thorac Oncol*, 2021, 16(4): 619-629.

[7] Jiang C, Luo Y, Yuan J, et al. CT-based radiomics and machine learning to predict spread through air space in lung adenocarcinoma[J]. *Eur Radiol*, 2020, 30(7): 4050-4057.

[8] Jin W, Shen L, Tian Y, et al. Improving the prediction of Spreading Through Air Spaces (STAS) in primary lung cancer with a dynamic dual-delta hybrid machine learning model: a multicenter cohort study[J]. *Biomark Res*, 2023, 11(1): 102.

[9] Kim S K, Kim T J, Chung M J, et al. Lung adenocarcinoma: CT features associated with spread through air spaces[J]. *Radiology*, 2018, 289(3): 831-840.

[10] de Margerie-Mellon C, Onken A, Heidinger B H, et al. CT manifestations of tumor spread through airspaces in pulmonary adenocarcinomas presenting as subsolid nodules[J]. *J Thorac Imaging*, 2018, 33(6): 402-408.

[11] Jiang C, Luo Y, Yuan J, et al. CT-based radiomics and machine learning to predict spread through air space in lung adenocarcinoma[J]. *Eur Radiol*, 2020, 30(7): 4050-4057.

[12] Liu Q, Qi W, Wu Y, et al. Construction of pulmonary nodule CT radiomics random forest model based on artificial intelligence software for STAS evaluation of stage IA lung adenocarcinoma[J]. *Comput Math Methods Med*, 2022, 2022: 2173412.

[13] Lundervold A S, Lundervold A. An overview of deep learning in medical imaging focusing on MRI[J]. *Z Med Phys*, 2019, 29(2): 102-127.

[14] Ben jamens S, Dhunoo P, Mesko B. The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database[J]. *NPJ Digit Med*, 2020, 3: 118.

[15] Detterbeck F C, Nicholson A G, Franklin W A, et al. The IASLC lung cancer staging project: summary of proposals for revisions of the classification of lung cancers with multiple pulmonary sites of involvement in the forthcoming eighth edition of the TNM classification[J]. *J Thorac Oncol*, 2016, 11(5): 639-650.

[16] Sun F, Huang Y, Yang X, et al. Solid component ratio influences prognosis of GGO-featured IA stage invasive lung adenocarcinoma[J]. *Cancer Imaging*, 2020, 20(1): 87.

[17] Deng L, Tang H Z, Luo Y W, et al. Preoperative CT radiomics nomogram for predicting microvascular invasion in stage I non-small cell lung cancer[J]. *Acad Radiol*, 2024, 31(1): 46-57.

[18] 孙耀煌. 肺原位腺癌与微浸润腺癌的病理分化情况及超高分辨率CT鉴别效果[J]. *罕见疾病杂志*, 2023, 30(4): 46-47.

[19] Shi Y, Zou Y, Liu J, et al. Ultrasound-based radiomics XGBoost model to assess the risk of central cervical lymph node metastasis in patients with papillary thyroid carcinoma: individual application of SHAP[J]. *Front Oncol*, 2022, 12: 897596.

[20] Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine[J]. *N Engl J Med*, 2019, 380(14): 1347-1358.

[21] Kang D, Gweon H M, Eun N L, et al. A convolutional deep learning model for improving mammographic breast-microcalcification diagnosis[J]. *Sci Rep*, 2021, 11(1): 23925.

[22] Kumar V, Prabha C, Sharma P, et al. Unified deep learning models for enhanced lung cancer prediction with ResNet-50-101 and EfficientNet-B3 using DICOM images[J]. *BMC Med Imaging*, 2024, 24(1): 63.

[23] Haennah J, Christopher C S, King G. Prediction of the COVID disease using lung CT images by Deep Learning algorithm: DETS-optimized Resnet 101 classifier[J]. *Front Med (Lausanne)*, 2023, 10: 1157000.

[24] 李大瑞, 胡万均, 刘光耀, 等. 基于多中心MRI的3D-ResNet101深度学习模型预测脑胶质瘤术前分级的研究[J]. *磁共振成像*, 2023, 14(05): 25-30.

[25] 刘梦秋, 伍志发, 丁虎, 等. 基于卷积神经网络的胸片肺野分割与肺结核的筛查研究[J]. *临床放射学杂志*, 2023, 42(04): 671-677.

[26] Rahaman M M, Millar E, Meijering E. Breast cancer histopathology image-based gene expression prediction using spatial transcriptomics data and deep learning[J]. *Sci Rep*, 2023, 13(1): 13604.

(收稿日期: 2024-06-15)

(校对编辑: 赵望淇)