

论 著

基于XGBoost机器学习算法的肺结节浸润性预测模型构建与验证：一项双中心研究*

夏志颖¹ 刘子蔚² 胡秋根²
包陈政任³ 张 榕^{2,*}1.海南省中医院放射科(海南海口570203)
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.南方医科大学顺德医院附属陈村医院(佛山市顺德区第一人民医院附属陈村医院)放射科(广东佛山528313)

【摘要】目的 采用XGBoost机器学习算法构建一个临床影像模型，预测肺结节病理浸润性，并在一个外部验证组中对模型进行泛化性验证。方法 回顾性纳入CT诊断为孤立性肺结节患者248例，分别提取肺结节区域和结节周围3mm、5mm区域的放射组学特征。经过从粗到细的特征选择后，使用最小绝对收缩和选择算子(LASSO)方法计算Radscore。采用单因素和多因素Logistic回归分析筛选与肺结节浸润性相关的临床放射学因素。然后，利用Logistic和XGBoost算法构建临床-放射组学联合模型，在一个独立的外部验证组(n=147)中评估模型的泛化性能。结果 综合Radscore、CT值、肺结节长度、月牙征的临床放射学XGBoost联合模型对肺结节浸润性的预测效果优于放射组学模型、临床放射学Logistic联合模型，在训练队列中的曲线下面积AUC为0.889(95% CI, 0.848~0.927)，在外部验证组中曲线下面积AUC为0.889(95% CI, 0.823~0.942)。结论 我们采用XGBoost机器学习算法构建了一种预测肺结节浸润性的临床放射学模型，结果显示令人满意的预测效能，并在一个独立外部验证组中得到了良好的泛化性验证，可以帮助临床医生指导肺结节的诊疗并制定评估策略。

【关键词】肺结节；极端梯度上升；机器学习；放射组学

【中图分类号】R445

【文献标识码】A

【基金项目】广东省中医药局科研项目(20241312)；
佛山市科技计划项目(2220001005383)；
南方医科大学顺德医院科研启动项目(SRSP2021021)

DOI:10.3969/j.issn.1672-5131.2024.08.054

Construction and Verification of Pulmonary Nodules Invasion Prediction Model Based on XGBoost Machine Learning Algorithm: A Two-center Study*

XIA Zhi-ying¹, LIU Zi-wei², HU Qiu-gen², BAO Chen-zhengren³, ZHANG Rong^{2,*}.

1.Department of Radiology, Hainan Traditional Chinese Medicine Hospital, Haikou 570203, Hainan Province, China

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

3.Department of Radiology, Shunde Hospital of Southern Medical University Affiliated Chencun Hospital (the First People's Hospital of Shunde Affiliated Chencun Hospital), Foshan 528313, Guangdong Province, China

ABSTRACT

Objective To construct a clinical radiomics model using XGBoost machine learning algorithm to predict the pathological invasion of pulmonary nodules, and to validate the model generically in an external cohort. **Methods** 248 patients with isolated pulmonary nodules diagnosed by CT were retrospectively included, and the radiological features of the pulmonary nodules and the surrounding 3mm and 5mm areas were extracted respectively. After feature selection from coarse-to-fine, Radscore is calculated using the least absolute shrinkage and selection operator (LASSO) logistic regression. Univariate and multivariate logistic regression analyses were used to determine the clinical radiological factors associated with pulmonary nodules invasion. A joint clinical-radiomics model was then constructed using Logistic and XGBoost algorithms, and the generalization of the model was evaluated in an independent external validation cohort (n=147). **Results** The clinical radiology XGBoost combined model with Radscore, CT value, lung nodule length and lunate sign was superior to the radiomic model and Logistic combined model of clinical radiology in predicting pulmonary nodules invasion. The area under the curve (AUC) in the training cohort was 0.889 (95% CI, 0.848~0.927), and the AUC in the external validation cohort was 0.889 (95% CI, 0.823~0.942), showing satisfactory predictive efficacy. **Conclusion** We used the XGBoost machine learning algorithm to construct a clinical radiomics model for predicting pulmonary nodules invasion. The results showed satisfactory predictive efficacy and were well generalized in an independent external validation group, which can help clinicians guide the diagnosis and treatment of pulmonary nodules and develop evaluation strategies.

Keywords: Pulmonary Nodules; Extreme Gradient Boosting; Machine Learning; Radiomics

全球癌症统计报告显示^[1]，2020年肺癌新发病例220.68万例，死亡179.67万例，位于癌症致死率之首，严重威胁世界人民健康安全，其中肺腺癌是最常见的肺癌病理组织学亚型^[2]。根据2021年世界卫生组织肺癌新分类标准^[3]，将非典型腺瘤样增生(atypical adenomatous hyperplasia, AAH)和原位癌(adenocarcinoma in situ, AIS)定义为腺体前驱病变，其术后5年生存率为100%^[4]。微浸润性肺腺癌(minimally invasive adenocarcinoma, MIA)归纳为肺腺癌范畴，术后5年生存率为95%-100%；肺腺癌还包括浸润性非粘液性肺腺癌、浸润性粘液腺癌、胶样腺癌、胎儿型腺癌、肠型腺癌，5年生存率为38%-86%^[5]。腺体前驱病变，临床建议积极随访是必要的，然而对于肺腺癌，则建议进行手术干预。

计算机断层扫描(CT)是一种常用的影像检查方法，在评估肺结节的浸润性方面起着重要的作用。然而，许多结节在CT图像上的形态相似，可能会影响初步诊断及后续治疗决策，是胸外科及放射科医师面临的一个具有挑战性的问题^[5-7]。放射组学能将影像数据转化为高维可挖掘的特征空间，可以帮助评估肺结节的良恶性、浸润性和预后^[5,8]。基于树的极端梯度上升(XGBoost)机器学习算法是一类由基函数与权重进行组合形成对数数据拟合效果佳的合成算法，其使用梯度上升框架，适用于分类和回归问题，优点是速度快、效果好、预测准确性等。XGBoost机器学习已经应用于部分领域中，并表现出较好的预测效能。

本研究旨在采用XGBoost机器学习算法建立和验证一个临床放射学模型，用于精准区分腺体前驱病变与浸润性肺腺癌，为准确评估肺结节的病理浸润性提供一种无创工具，有助于辅助临床个体化诊疗。

1 资料和方法

1.1 一般资料 孤立性肺结节来自两家机构，分别是南方医科大学顺德医院，纳入为训练组，南方医科大学顺德医院附属陈村医院，纳入为外部验证组。由于该研究属于回顾性研究，经两个机构审查委员会同意，并放弃了患者知情同意。

纳入标准：肺结节<30mm；病理证实为AAH/AIS/MIA或IAC；具有完整的影像

【第一作者】夏志颖，男，主治医师，主要研究方向：胸部CT影像诊断。E-mail: 170004821@qq.com

【通讯作者】张 榕，男，主治医师，主要研究方向：胸部CT影像诊断。E-mail: 1257693891@qq.com

学、病理及临床资料；既往无与相关的肺结节治疗；无其他恶性肿瘤病史。排除标准：图像存在伪影；其病理证实的其他类型肺癌(如鳞状细胞癌、小细胞肺癌)。

1.2 CT扫描设备及图像分析 使用两台CT扫描仪进行扫描，分别是80层(Aquilion Prime, Toshiba)、64层(Smoatom Definition AS, Siemens)多层CT扫描仪进行检查。采集参数设置：管电压120kv；管电流，250~300 mAs；FOV，350~400mm；扫描层厚1~5 mm；重建图像厚度，0.6~0.8 mm；螺距0.8~1.0。扫描上下范围由肺尖到膈面，左右范围包括双侧胸廓。扫描结束后由两位具有10年经验的胸部影像诊断医师进行双盲法阅片，记录肺结节的临床因素及影像学特征，如年龄、性别、结节长度(mm)、成分(纯磨玻璃/混合磨玻璃/实性)、位置(右肺上/中/下叶、左肺上/下叶)、CT值(Hu)、胸膜凹陷征、微血管征、瘤肺边界征、月牙征、空气支气管征、空泡征等，遇到意见分歧时，通过统一协商解决。




图1A-图1D 肺结节图像分割及放射组学特征提取；(图1A)肺结节靶区及瘤周3mm、5mm区域VOI勾画；(1B)对肺结节区域及瘤周3mm、瘤周5mm区域中提取的放射组学特征使用LASSO套索算法筛选出效能最好的放射组学特征集合，纵坐标LASSO系数代表放射组学特征，根据 λ 序列绘制系数剖面图，虚线垂直线绘制在10次交叉验证中的最优 λ 处；(1C)特征筛选模型校准曲线；(1D)肺结节区域及瘤周3mm、瘤周5mm区域提取的放射组学特征筛选过程中的特征系数收敛图。

1.5 单区域放射组学构建 为了避免模型过拟合和提高模型的泛化性，对数据进行上采样和一系列从粗到细的特征筛选。最初，使用类内相关系数法(intraclass correlation coefficient, ICC)评估特征稳定性。随后，进行独立样本t检验或秩和检验，选择AAH/AIS组与MIA/IAC组之间的显著特征。利用Spearman相关分析减少特征集之间的冗余度，当特征对之间的相关性大于0.6时，去除平均相关性较高的特征。此外，使用最小绝对收缩和选择算子(LASSO)逻辑回归方法选择放射组学特征的优化子集，并构建单区域放射组学模型(VOI_{nodule} 为 Rad_{nodule} ， VOI_{3mm} 为 Rad_{3mm} ， VOI_{5mm} 为 Rad_{5mm})。

1.6 多区域放射组学模型构建 为了进一步消除不同区域放射组学特征的冗余性，采用方差膨胀因子(variance inflation factor, VIF)方法量化放射组学特征对之间的共线性。在此基础上，利用Logistic方法构建了多区域放射组学模型。使用ROC曲线评估四种放射组学模型的预测性能，通过对最佳模型的特征系数进行加权来确定Radscore。

1.7 临床放射组学模型构建 对临床及影像学特征进行单因素Logistic回归分析，筛查肺结节病理浸润性相关因素($P<0.05$)。采用多因素Logistic回归分析筛选出重要因素并建立临床模型(clinical model)。采用Logistic回归和XGBoost两种算法整合重要临床-放射学因素和Radscore，构建临床-放射组学联合模型，并使用曲线下面积(area under the receiver operating characteristic curve, AUC)来评价模型的性能。

1.8 统计分析 AAH/AIS组与MIA/IAC组间变量差异采用独立t检验或秩和检验，分类变量采用卡方检验。采用受试者工作特征曲线(ROC)下面积AUC评价模型的性能。采用Python(3.7.3)和R(4.1.3)软件进行统计分析。 $P<0.05$ 差异具有统计学意义。

2 结果

2.1 临床资料比较 患者的临床和放射学基线信息资料见(表1)。本研究共纳入了395例术前孤立性肺结节患者的影像学、病理学

1.3 病理组织学分析 根据世界卫生组织2021年肺肿瘤新分类，所有病理组织学均由两名具有10年肺部病理学经验的高级病理学家进行评估和诊断，将肺结节分类为AAH、AIS、MIA和IAC。

1.4 图像分割及特征提取 从医院的图像存档和通信系统(PACS)中检索出术前CT图像。将CT图像导入Deepwise软件(<https://keyan.deepwise.com/login>)。根据每位患者的信息，由两位具有10年经验的胸部放射诊断医师使用半自动分割方法对肺结节感兴趣区进行勾画(VOI_{nodule})，遇到分歧时统一协商解决，勾画完 VOI 后，向肿瘤周围外扩3mm(VOI_{3mm})和5mm(VOI_{5mm})。然后使用Deepwise软件自动生成两个结节周围区域，避开大血管、胸膜组织、周围器官，使用Pyradiomics软件包从3个 VOI 中提取了3045个放射组学特征，包括一阶特征、形状特征、灰度纹理特征、小波滤波特征等(图1)。

及临床资料。训练组包括来自南方医科大学顺德医院的248名患者，外部验证组来自南方医科大学顺德医院附属陈村医院147名患者。25.8% (64/248)、15.0% (22/147)患者在训练组和外部验证组中被诊断为AAH/AIS，74.2% (184/248)、85% (125/147)患者在训练组和外部验证组中被诊断为MIA/IAC。

2.2 放射组学模型的构建与验证 经过由粗到细的特征筛选，每个区域分别得到1个、1个和1个非零系数特征(original glem MaximumProbability_Omm; wavelet; HHH_ngtdm_Coarseness_3mm; HHH_ngtdm_Coarseness_5mm)。瘤周3mm和瘤周5mm的两个放射组学特征表现出高共线性($VIF>10$)，后者被剔除。最后，利用Logistic回归，构建多区域放射组学模型($Rad_{nodule+3mm}$)。通过与三个单区域放射组学模型相比， $Rad_{nodule+3mm}$ 预测性能最佳，AUC为0.791 (95% CI, 0.718~0.852) (表2)。因此，由多区域放射组学模型($Rad_{nodule+3mm}$)的预测结果来确定Radscore(图2)。

2.3 临床模型的构建与验证 单因素Logistic分析显示，CT值、肺结节长度、空泡征、月牙征、微血管征、胸膜凹陷征等临床及影像学因素与肺结节病理浸润性显著相关($P<0.05$) (表3)。随后，选择CT值、肺结节长度和月牙征三个重要因素，采用逐步Logistic回归构建临床模型(clinical model)，在训练组和外部验证组中临床模型的ACU分别为0.851 (95% CI, 0.801~0.899)和0.875 (0.808~0.936) (表4)。

2.4 临床-放射组学联合模型的构建与验证 整合重要临床影像因素和Radscore，采用Logistic和XGBoost算法构建临床-放射组学联合模型。Logistic联合模型(Logistic-C)和XGBoost联合模型(XGBoost-C)在训练组AUC分别为0.853 (95% CI, 0.804~0.898)和0.889 (95% CI, 0.848~0.927)，在外部验证组AUC分别为0.876 (95% CI, 0.802~0.937)和0.889 (95% CI, 0.823~0.942)。这表明XGBoost-C模型比临床模型、单区域和多区域放射组学模型以及Logistic-C模型具有更好的预测效能(表4，图3)。

表1 两个中心患者临床和放射学基线资料表

		训练组			外部验证组		
	level	AAH/AIS	MIA/IAC	P	AAH/AIS	MIA/IAC	P
n		64	184		22	125	
年龄	女性	43 (67.2%)	128 (69.6%)	0.723	17 (77.3%)	84 (67.2%)	0.347
	男性	21 (32.8%)	56 (30.4%)		5 (22.7%)	41 (32.8%)	
空泡征	0	60 (93.8%)	151 (82.1%)	0.024	19 (86.4%)	95 (76.0%)	0.425
	1	4 (6.2%)	33 (17.9%)		3 (13.6%)	30 (24.0%)	
空气支气管征	0	62 (96.9%)	157 (85.3%)	0.013	21 (95.5%)	110 (88.0%)	0.507
	1	2 (3.1%)	27 (14.7%)		1 (4.5%)	15 (12.0%)	
月牙征	0	57 (89.1%)	120 (65.2%)	<0.001	22 (100.0%)	107 (85.6%)	0.122
	1	7 (10.9%)	64 (34.8%)		0 (0.0%)	18 (14.4%)	
瘤肺边界征	0	18 (28.1%)	40 (21.7%)	0.299	2 (9.1%)	8 (6.4%)	0.998
	1	46 (71.9%)	144 (78.3%)		20 (90.9%)	117 (93.6%)	
微血管征	0	18 (28.1%)	17 (9.2%)	<0.001	1 (4.5%)	5 (4.0%)	>0.999
	1	46 (71.9%)	167 (90.8%)		21 (95.5%)	120 (96.0%)	
胸膜凹陷征	0	60 (93.8%)	111 (60.3%)	<0.001	19 (86.4%)	96 (76.8%)	0.47
	1	4 (6.2%)	73 (39.7%)		3 (13.6%)	29 (23.2%)	
成分	实性	0 (0.0%)	41 (22.3%)	<0.001	0 (0.0%)	10 (8.0%)	0.055
	混合磨玻璃	14 (21.9%)	76 (41.3%)		6 (27.3%)	57 (45.6%)	
	纯磨玻璃	50 (78.1%)	67 (36.4%)		16 (72.7%)	58 (46.4%)	
位置	左肺下叶	3 (4.7%)	23 (12.5%)	0.289	4 (18.2%)	13 (10.4%)	0.533
	左肺上叶	17 (26.6%)	42 (22.8%)		9 (40.9%)	39 (31.2%)	
	右肺下叶	12 (18.8%)	41 (22.3%)		2 (9.1%)	19 (15.2%)	
	右肺中叶	3 (4.7%)	13 (7.1%)		1 (4.5%)	5 (4.0%)	
	右肺上叶	29 (45.3%)	65 (35.3%)		6 (27.3%)	49 (39.2%)	
CT值		-589.8 [-644.2, -478.6]	-370.6 [-539.2, -144.4]	<0.001	-594.4 [-665.7, -508.5]	-486.4 [-595.5, -365.4]	0.001
年龄		55.0 [47.0, 60.0]	56.5 [47.0, 65.3]	0.31	54.5 [47.3, 59.8]	56.0 [48.0, 65.0]	0.281
长度		6.00 [5.0, 7.0]	10.0 [7.0, 15.03]	<0.001	8.50 [7.3, 10.0]	10.0 [8.0, 13.0]	0.021

表2 放射组学模型性能分析

模型	AUC (95% CI)	准确度	灵敏度	特异度
Rad _{nodule}	0.741 (0.664-0.810)	0.819	0.903	0.517
Rad _{3mm}	0.747 (0.672-0.815)	0.707	0.722	0.65
Rad _{5mm}	0.776 (0.708-0.835)	0.605	0.532	0.867
Radscore	0.791 (0.718-0.852)	0.757	0.778	0.683

表4 训练组及验证组中模型性能分析

队列	模型	AUC (95 % CI)	准确度	灵敏度	特异度
训练组	临床模型	0.851 (0.801-0.899)	0.746	0.718	0.850
	放射组学模型	0.791 (0.718-0.852)	0.757	0.778	0.683
	Logistic-C模型	0.853 (0.804-0.898)	0.768	0.759	0.800
	XGBoost-C模型	0.889 (0.848-0.927)	0.772	0.741	0.883
外部验证组	临床模型	0.875 (0.808-0.936)	0.756	0.720	0.885
	放射组学模型	0.773 (0.678-0.862)	0.689	0.699	0.654
	Logistic-C模型	0.876 (0.802-0.937)	0.756	0.731	0.846
	XGBoost-C模型	0.889 (0.823-0.942)	0.773	0.742	0.885

表3 临床、放射学特征单因素及多因素Logistic分析

因素	Uni_OR	Uni_95%CI	Uni_P	Mul_OR	Mul_95%CI	Mul_P
性别 (male)	1.291	(0.685~2.545)	0.443	-	-	-
空泡征 (Yes)	3.379	(1.294~11.6)	0.026	3.208	(1.04~12.423)	0.06
空气支气管征 (Yes)	2.264	(0.753~9.787)	0.196	-	-	-
月牙征 (Yes)	7.477	(2.631~31.45)	0.001	4.408	(1.381~19.907)	0.025
瘤肺边界 (Yes)	1.296	(0.621~2.578)	0.473	-	-	-
微血管征 (Yes)	3.153	(1.388~7.05)	0.005	1.415	(0.492~4.159)	0.52
胸膜凹陷征(Yes)	3.041	(1.449~7.21)	0.006	0.709	(0.273~1.966)	0.489
CT值	1.005	(1.004~1.008)	<0.001	1.005	(1.002~1.008)	<0.001
年龄	1.021	(0.996~1.047)	0.1	-	-	-
长度	1.435	(1.272~1.651)	<0.001	1.214	(1.048~1.44)	0.017
Radscore	2.718	(2.038~3.761)	<0.001	1.524	(1.071~2.262)	0.026






图2 瘤灶及瘤周放射组学预测肺结节浸润性的ROC曲线分析; Rad_{nodule}: 瘤灶放射组学, Rad_{3mm}: 瘤周3mm放射组学, Rad_{5mm}: 瘤周5mm放射组学, Radscore: 多区域(Rad_{nodule}+3mm)放射组学。

图3A-图3B 训练组和外部验证组模型性能ROC曲线分析 (图3A) 训练组模型性能分析; (图3B) 外部验证组模型性能分析。Clinical model: 临床模型; Radscore: 放射组学模型; Logistic-C: 临床-影像Logistic联合模型; XGBoost-C: 临床-影像XGBoost联合模型。

3 讨论

在这项多中心研究中,我们结合重要的临床-放射学因素和Radscore构建了一个临床-放射组学XGBoost联合模型,来区分AAH/AIS与MIA/IAC。XGBoost联合模型是一种可靠的临床治疗决策支持工具,最后,我们在一个独立的外部验证组对模型进行了泛化性验证,并得到了较好的预测效能。

肿瘤的浸润性可引起结节形态及微环境的改变^[9],如长度、CT值、月牙征、微血管征、胸膜凹陷征等,进而导致预后不良^[7,10-11]。在本研究中,长度、CT值和月牙征被认为是预测肺结节浸润性的重要因素,最新第八版肺肿瘤TNM分期中^[12-14],肿瘤T分期是以长度为标准进行评估,早期肺结节呈纯磨玻璃样密度,随着肺结节浸润性的增加,其体积增大,密度增加,其内实性成分增加,CT值增高,逐渐从纯磨玻璃结节变为实性结节。俞慧波^[14]等研究表明,月牙征是预测纯磨玻璃结节浸润性的独立危险因素,我们与之研究一致。近些年研究表明^[15],瘤周放射组学可以捕捉肿瘤周围微环境信息。我们的研究结果显示,肺结节周围放射组学对肺结节的浸润性也有较好预测价值,瘤周3mm放射组学的预测效能优于瘤周5mm,这可能是因为我们研究的结节相对较小,因此浸润性信息有限,瘤周异质性主要集中在3mm区域,这与Wu^[16]等人的研究结果部分一致。在本研究中,瘤周3mm和瘤周5mm放射组学的粗糙度都被选择为最佳的结节周围特征,粗糙度捕获肺结节周围区域的纹理信息,与肺癌的浸润性和复发率呈正相关,这反映了肿瘤的异质性。经过放射组学模型性能分析结果显示,多区域放射组学模型(Rad_{nodule+3mm})具有较高的AUC,说明了结节周围放射组学预测肺结节浸润性的可行性,证明了肺结节与周围肿瘤信息存在互补。

Logistic回归因其高效和可解释性而成为应用最广泛的模型构建方法^[17]。然而,在应用Logistic回归构建模型时存在几个缺点。首先,Logistic回归的线性假设很少成立。其次,使用Logistic回归中存在的系数作为比值比,不考虑与其他自变量的关联。此外,当存在有强烈影响的异常值时,Logistic回归模型不够稳健。极端梯度上升(XGBoost)算法是一种大规模机器学习算法,是梯度增强的一种高效且可扩展的变体,可用于分类和回归问题^[18]。Ogunleye^[19]等人使用XGBoost方法设计了用于慢性肾脏病诊断的模型,并取得了很高的准确性、敏感性和特异性。Zhong^[20]等人应用XGBoost方法提出了一个框架,结果表明,结合多变量特征在蛋白质预测中具有很大的优势。Ji^[21]等人发现,XGBoost模型对药物组合效果的分类具有显著优势,这些研究证明了XGBoost机器学习在疾病诊断和预后预测方面具有较大潜力。在本研究中,我们分别采用Logistic回归和XGBoost机器学习两种算法构建临床-放射组学联合模型(Logistic-C模型和XGBoost-C模型),在训练组中两个模型的AUC分别为0.853(0.804-0.898)和0.889(0.848-0.927),长度、CT值和Radscore是预测肺结节浸润性的三个最重要因素,所有特征均与肺结节浸润性呈正相关,在外部验证组中两个模型的AUC分别为0.876(0.802-0.937)和0.889(0.823-0.942),通过模型性能分析结果显示,XGBoost-C模型在预测肺结节浸润性中表现出的性能优于Logistic-C模型,值得临床推广应用。

我们的研究具有一些局限性。首先,本研究是回顾性研究,在筛选病例中存在偏倚。其次,在勾画肺结节VOI中,对于较小的肺结节,血管、空泡和支气管不可避免地包括在内,这可能会影响放射组学特征的提取。第三,我们只考虑了3 mm和5 mm肺结节周围区域,后续我们应该考虑多区域瘤周放射组学信息进行研究。

综上所述,我们使用XGBoost机器学习算法构建了一个用于术前评估肺结节浸润性的预测模型,并在一个独立的外部验证组中成功验证了模型,并得到令人满意的泛化性能。因此,我们的XGBoost预测模型可以辅助临床医生对肺结节患者的评估,并制定合适的诊疗和管理方案。

参考文献

- [1] Sung H, Ferlay J, Siegel R L, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA Cancer J Clin, 2021, 71(3): 209-249.
- [2] 彭弘, 李圣博, 赵旭. 周围型肺癌CT征象与病理的对照相关性研究[J]. 罕少疾病杂志, 2022, 29(12): 42-43.
- [3] 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.
- [4] Zhang Y, Ma X, Shen X, et al. Surgery for pre-and minimally invasive lung adenocarcinoma[J]. J Thorac Cardiovasc Surg, 2022, 163(2): 456-464.
- [5] Fan L, Fang M, Li Z, et al. Radiomics signature: a biomarker for the preoperative discrimination of lung invasive adenocarcinoma manifesting as a ground-glass nodule[J]. Eur Radiol, 2019, 29(2): 889-897.
- [6] Huang L, Lin W, Xie D, et al. Development and validation of a preoperative CT-based radiomic nomogram to predict pathology invasiveness in patients with a solitary pulmonary nodule: a machine learning approach, multicenter, diagnostic study[J]. Eur Radiol, 2022, 32(3): 1983-1996.
- [7] Beig N, Khorrami M, Alilou M, et al. Perinodular and intranodular radiomic features on lung CT images distinguish adenocarcinomas from granulomas[J]. Radiology, 2019, 290(3): 783-792.
- [8] Aerts H J, Velazquez E R, Leijenaar R T, et al. Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach[J]. Nat Commun, 2014, 5: 4006.
- [9] Nishino M. Perinodular radiomic features to assess nodule microenvironment: does it help to distinguish malignant versus benign lung nodules? [J]. Radiology, 2019, 290(3): 793-795.
- [10] Wang T, She Y, Yang Y, et al. Radiomics for survival risk stratification of clinical and pathologic stage Ia pure-solid non-small cell lung cancer[J]. Radiology, 2022, 302(2): 425-434.
- [11] 张禹, 朱友志, 路祥伟. 周围型小细胞肺癌的CT征象分析[J]. 中国CT和MRI杂志, 2022, 20(12): 60-62.
- [12] 叶波, 赵珩. 第八版国际肺癌TNM分期修订稿解读[J]. 中国肺癌杂志, 2016, 19(6): 337-342.
- [13] 吴春燕, 何川东, 陈正国, 等. 肺炎性假瘤、周围型肺癌的CT影像学特征及其鉴别诊断[J]. 中国CT和MRI杂志, 2022, 20(4): 51-52.
- [14] 俞慧波, 陈中港, 李琼, 等. 月牙征预测纯磨玻璃结节肺腺癌浸润性的价值[J]. 中华放射学杂志, 2021, 55(4): 403-408.
- [15] Tang X, Huang H, Du P, et al. Intratumoral and peritumoral CT-based radiomics strategy reveals distinct subtypes of non-small-cell lung cancer[J]. J Cancer Res Clin Oncol, 2022, 148(9): 2247-2260.
- [16] Wu L, Gao C, Ye J, et al. The value of various peritumoral radiomic features in differentiating the invasiveness of adenocarcinoma manifesting as ground-glass nodules[J]. Eur Radiol, 2021, 31(12): 9030-9037.
- [17] Ma B, Meng F, Yan G, et al. Diagnostic classification of cancers using extreme gradient boosting algorithm and multi-omics data[J]. Comput Biol Med, 2020, 121: 103761.
- [18] Li Y, Zou Z, Gao Z, et al. Prediction of lung cancer risk in Chinese population with genetic-environment factor using extreme gradient boosting[J]. Cancer Med, 2022, 11(23): 4469-4478.
- [19] Ogunleye A, Wang Q G. XGBoost Model for Chronic Kidney Disease Diagnosis[J]. IEEE/ACM Trans Comput Biol Bioinform, 2020, 17(6): 2131-2140.
- [20] Zhong J, Sun Y, Peng W, et al. XGBFEMF: an XGBoost-based framework for essential protein prediction[J]. IEEE Trans Nanobiosci, 2018, 17(3): 243-250.
- [21] Ji X, Tong W, Liu Z, et al. Five-feature model for developing the classifier for synergistic vs. antagonistic drug combinations built by XGBoost[J]. Front Genet, 2019, 10: 600.

(收稿日期: 2023-11-07)

(校对编辑: 姚丽娜)