论 著

CT影像组学在嗜铬细胞瘤术前诊断及鉴别诊断中的诊断效能评估*

廖忠剑[1,2] 范存庚[2] 刘艳萍[2]
张 玲[1,*]
1.南方医科大学南方医院影像诊断科 (广东 广州 510515)
2.赣州市人民医院影像科 (江西 赣州 341000)

【摘要】**目的** 基于CT影像组学特征和临床资料，构建机器学习模型术前鉴别肾上腺嗜铬细胞瘤(PHEO)和乏脂腺瘤(LPAA)。**方法** 收集275例符合试验标准的患者的CT图像和临床资料，(PHEO:LPAA=109:166)，按7:3分成训练集与内部验证集。两位放射科医师使用ITK-SNAP勾画肿瘤并生成相应的ROI感兴趣区，训练nn-Uet实现ROI自动勾画。通过常规ROI获取到影像组学特征进行预处理和筛选。构建三个特征集：临床特征集、影像组学特征集的和临床特征+影像组学特征集以进行后续建模，对这3个特征集分别构建13个机器学习模型，选择最优模型进行对比评估。以AUC、准确率、F1值等评估模型性能。**结果** 与PHEO相比，LPAA在直径、CTu、CTa等上均有显著统计学差异(P<0.05)。融合了临床特征与影像组学特征的模型性能最佳，验证集的曲线下面积(AUC)高达0.96，分类的准确率为90.4%。**结论** 本研究构建了鉴别嗜铬细胞瘤和肾上腺乏脂型腺瘤的自动分割模型，能很好地辅助临床进行术前诊断。

【关键词】嗜铬细胞瘤；肾上腺乏脂型腺瘤；机器学习；影像组学
【中图分类号】R736.6
【文献标识码】A
【基金项目】广东省卫济医学发展基金会2025年度消化病学专项科研基金项目(K-202505-2-6)
DOI:10.3969/j.issn.1672-5131.2026.04.040

Value of CT Radiomics in Preoperative Diagnosis and Differential Diagnosis of Pheochromocytoma*

LIAO Zhong-Jian[1,2], FAN Cun-geng[2], LIU Yan-ping[2], ZHANG Ling[1,*].
1.Department of Radiology, Nanfang Hospital, Southern Medical University, Guangzhou 510515, Guangdong Province, China
2.Department of Medical Imaging,Ganzhou People's Hospital, Ganzhou 341000, Jiangxi Province, China

ABSTRACT
Objective To construct a machine learning model for the preoperative differentiation of adrenal pheochromocytoma (PHEO) and lipid-poor adrenal adenoma (LPAA) based on CT radiomic features and clinical data. ***Methods*** CT images and clinical data of 275 patients meeting the study criteria (PHEO:LPAA = 109:166) were collected and divided into a training set and an internal validation set at a ratio of 7:3. Two radiologists segmented tumors and generated corresponding regions of interest (ROIs) using ITK-SNAP, followed by training a nn-Unet model to achieve automatic ROI segmentation. Radiomic features were extracted from the conventional ROIs, then subjected to preprocessing and selection. Three feature sets were constructed for subsequent modeling: clinical feature set, radiomic feature set, and combined clinical + radiomic feature set. Thirteen machine learning models were built for each of the three feature sets, and the optimal models were selected for comparative evaluation. Model performance was assessed using metrics including area under the curve (AUC), accuracy, F1-score, and decision curve analysis (DCA). ***Results*** Compared with PHEO, LPAA showed statistically significant differences in tumor diameter, unenhanced CT value (CTu), and enhanced CT value (CTa) (*P*<0.05). The model integrating clinical and radiomic features achieved the best performance, with an AUC of 0.96 and a classification accuracy of 90.4% in the validation set. ***Conclusion*** This study developed an automatic segmentation model for differentiating pheochromocytoma from lipid-poor adrenal adenoma, which can effectively assist in clinical preoperative diagnosis.
Keywords: Adrenal Tumor; Pheochromocytoma; Lipid-Poor Adrenal Adenoma; Radiomics; Machine Learning

肾上腺偶发瘤定义为在影像诊断时偶然发现的无症状肾上腺腺瘤。随着影像诊断技术的不断进步，偶发瘤的检出率日益提高。其中肾上腺腺瘤占比约41%-52%，嗜铬细胞瘤占8%[1]。腺瘤包括功能性腺瘤、皮质醇腺瘤和醛固酮腺瘤，其中一小部分(15–30%)为乏脂型腺瘤(lipid-poor adrenal adenoma, LPAA)(CT值≤10 Hu)[2]。嗜铬细胞瘤(adrenal pheochromocytoma, PHEO)是分泌儿茶酚胺的肿瘤，若在手术或活检前未能发现，可能引起危及生命的高血压危象[3-5]。LPAA和PHEO的影像学特征、临床症状多有重叠，鉴别仍存在困难[6-8]，因此术前将二者进行准确区分尤为重要。

与常规影像学相比，影像组学作为一种新技术可以更好地提高肿瘤的诊断、分级、分期和预后预测[9-11]，用以辅助制定治疗方案。目前的影像组学研究鉴别LPAA和PHEO效能不一[12-13]。本研究拟基于CT影像组学与CT各期相定量值，构建机器学习模型鉴别肾上腺嗜铬细胞瘤和乏脂型腺瘤。

1 资料与方法

1.1 研究人群 收集我院2012年3月至2023年4月的275例患者，经手术病理确诊为PHEO的共109例，确诊为LPAA的共166例。将患者按7 : 3划分为训练集(PHEO:LPAA=76:116)和验证集(PHEO:LPAA=33:50)。

1.2 临床特征和影像学特征收集 所有患者的CT影像图像和测量数据均来自PACS系统，临床数据来自病例系统。

纳入标准：(1)平扫显示病灶CT值超过10HU；(2)图像质量优良，有完整的CT平扫及三期增强扫描图像；(3)患者未合并其它部位的原发恶性肿瘤，未接受过任何抗肿瘤治疗。排除标准：(1)肿瘤直径＜10mm；(2)弥漫性肾上腺增生；(3)影像检查与手术时间间隔超过1个月。本次的研究流程图如图1所示。临床特征包括：性别、年龄、体重指数、糖尿病史、高血压病史、手术方式、组织学亚型、 术前血压、术中血压、术后血压、Na+、K+等，并经过两位经验丰富的放射科医师(工作年限分别为18年和8年)共同评估，两人事先不知道患者病理结果。评估的影像语义特征包括：肿瘤位置、大小、边界、最大径、最小径、生长方式、单发/多发、钙化、囊变、出血、瘤内血管、平扫CT值(CTu)、动脉期CT值(CTa)、静脉期CT值(CTv)、延迟期CT值、APEA(动脉期增强幅度)、VPEA(静脉期增强幅度)、CTa-CTv、CTa-CTu、APW(绝对清除率)、RPW(相对清除率)等。患者存在多个病灶时，选取最大的病灶进行分析。两位医师存在分歧时，通过讨论达成一致。

【第一作者】廖忠剑，男，副主任医师，主要研究方向：腹部疾病影像诊断。E-mail：15079767892@qq.com
范存庚，男，副主任医师，主要研究方向：腹部疾病影像诊断。E-mail：fancungeng@mail.gzsrmyy.com
【通讯作者】张 玲，女，副主任医师，主要研究方向：腹部、骨关节病变影像诊断。E-mail：zhangling_smu@163.com

1.3 肾上腺肿瘤的勾画 由两位放射科医师使用ITK-SNAP在轴向平面手动勾画肿瘤边界，生成准确标注的ROI感兴趣区。基于这些被标注的肾上腺肿瘤ROI数据，训练nnU-Net模型用来实现自动勾画功能。通过分析训练数据构建基于U-Net的处理流程，选用该模型作为自适应分割框架。模型训练完成后，对各验证集依次进行推理，获得所有样本的肾上腺肿瘤自动分割结果，并将其作为常规感兴趣区(ROI)。

1.4 影像组学分析和特征提取 在使用nnU-Net自动勾画模型分割肾上腺肿瘤之后，基于常规ROI使用Pyradiomics开源Python软件包提取影像组学和常规特征。每例患者均提取CT平扫期、动脉期、静脉期和延迟期的图像特征。提取到影像组学特征包括：原始图像的形态特征、一阶统计量特征、灰度共生矩阵、灰度相关矩阵、灰度游程矩阵、灰度尺寸区域矩阵、相邻灰度差分矩阵、基于图像滤波变换的特征等。影像组学特征提取流程如图(图2)。

1.5 图像特征预处理 在模型开发前对提取的影像组学特征进行了预处理和筛选。首先，进行初步预处理，去掉设置信息以及一些无效列(空值、重复值列)。连续性特征经过标准化处理(强度归一到 0~255)，分类特征采用了独热编码技术。随后通过多重线性分析进行特征筛选，并使用最小绝对收缩算子(LASSO)回归法进一步筛选关键特征，最终包含了209 个影像组学特特征的影像组学数据集。

1.6 机器学习模型开发 针对临床及影像组学数据集，用scikit-learn软件包分别构建了临床、影像组学及临床与影像组学融合的各自十几个机器学习模型。传统模型包括线性判别分析(LDA)、逻辑回归(LR)、决策树算法(DT)、二次判别分析(QDA)、朴素贝叶斯算法(NB)和K近邻(KNN)。为了处理更复杂的特征，还采用了多种高级集成分类器：CatBoost、XGBoost、随机森林(RF)、Extra Trees(ET)、LightGBM、梯度提升分类器(GBC)、AdaBoost。病理学结果以PHEO与LPAA对比作为金标准。模型采用十折交叉验证进行训练，并在验证集上评估性能。

1.7 统计学分析与性能评估 分类变量的临床特征采用卡方检验进行比较，连续变量则使用独立样本t检验。临床模型、影像组学模型以及临床融合影像组学模型三者之间的性能以准确率(ACC)，受试者工作特征曲线下面积(AUC)、召回率、精确度、F1分数、Kappa值和马修斯相关系数(MCC)为评估标准进行评估。不同模型之间的性能差异通过DeLong检验进行验证，$P<0.05$视为具有统计学意义。

2 结 果

2.1 临床特征 详见表1，年龄、直径、CTu、CTa、CTv、APEA、CTa-CTv、CTa-CTu、APW、RPW、形态、病灶数量、位置、囊变、出血、及钙化均存在统计学差异($P<0.05$)；VPEA和性别则无统计学差异。

2.2 机器学习模型 在验证集里，基于临床特征构建的机器学习模型表现最优的是CatBoost Classifier，数值详情见图1A，表2。该模型的宏平均AUC值为0.94(图1B)，分类PHEO及LPAA(0代表PHEO，1代表LPAA)的子类AUC均高达0.93。分类报告(图1C)也显示分类PHEO的精确率与查全率分别为0.86和0.85，而分类LPAA的精确率与查全率分别为0.90和0.92。混淆矩阵(图3D)CatBoost Classifier模型在83例中准确分类了28+46=74例，分类的准确率为89.2%。

基于SOFT+AP+VP+DP四个序列影像组学特征建立的机器学习模型，在验证数据集例表现最优的是Extra Trees Classifier，其数据详情见表3。该模型的宏平均AUC为0.90(图2A)，分类PHEO及LPAA的AUC值均为0.90。分类报告(图2B)显示分类PHEO的精确率与查全率分别为0.79和0.82，而分类LPAA的精确率与查全率分别为0.88和0.86。混淆矩阵(图2C)Extra Trees Classifier模型在83例中准确分类了27+43=70例，分类的准确率为84.3%。

基于临床特征+四个序列影像组学特征建立的融合模型，在验证数据集例表现最优的是Extra Trees Classifier，其数值详见表4。该模型的宏平均AUC为0.96(图3A)，分类PHEO和LPAA的子类AUC均为0.96。分类报告(图3B)显示分类PHEO的精确率与查全率分别为0.86和0.91，而LPAA的精确率与查全率分别为0.94和0.90。混淆矩阵(图3C)显示Extra Trees Classifier模型在83例中准确分类30+45=83例，分类准确率为90.4%。

表1 临床及影像学基线数据

特征		疾病类型		t/χ^2	P
		PHEO(n=109)	LPAA(n=166)		
年龄		46.12±14.71	50.79±12.32	-2.739	0.007**
最小径		4.38±2.03	1.71±0.88	12.238	<0.001**
最大径		5.39±2.51	2.13±1.11	12.035	<0.001**
CTu		41.20±7.26	23.59±9.96	16.432	<0.001**
CTa		108.90±40.34	63.87±26.74	9.795	<0.001**
CTv		92.28±24.09	64.74±18.62	10.33	<0.001**
APEA		60.16±43.33	39.79±24.08	4.475	<0.001**
VPEA		45.46±28.09	40.65±15.23	1.636	0.104
CTa-CTv		14.79±27.28	-0.86±22.79	5.147	<0.001**
CTa-CTu		60.25±43.41	39.79±24.08	4.488	<0.001**
APW		0.93±113.80	-39.67±114.76	2.771	0.006**
RPW		8.89±29.66	-11.54±40.10	4.703	<0.001**
性别	男	50(45.87)	85(51.20)	0.749	0.387
	女	59(54.13)	81(48.80)		
形态	规则	87(89.69)	160(97.56)	7.437	0.006**
	不规则	10(10.31)	4(2.44)		
边界	清	93(95.88)	163(99.39)	4.005	0.045*
	不清	4(4.12)	1(0.61)		
数量	单发	94(96.91)	141(85.98)	8.121	0.004**
	多发	3(3.09)	23(14.02)		
位置	左侧	53(59.55)	107(65.24)	8.26	0.016*
	右侧	34(38.20)	41(25.00)		
	双侧	2(2.25)	16(9.76)		
囊性变	否	19(19.59)	161(98.17)	175.856	<0.001**
	是	78(80.41)	3(1.83)		
出血	否	87(89.69)	164(100.00)	17.581	<0.001**
	是	10(10.31)	0(0.00)		
钙化	否	88(90.72)	162(98.78)	9.805	0.002**
	是	9(9.28)	2(1.22)		
瘤内出血	否	71(73.96)	161(98.17)	36.942	<0.001**
	是	25(26.04)	3(1.83)		

表2 临床特征模型在验证集中的性能

模型	准确率	AUC	召回率	精确率	F1值	Kappa	MCC
CatBoost Classifier	0.8434	0.9303	0.8400	0.8936	0.8660	0.6780	0.6799
Gradient Boosting Classifier	0.8434	0.9130	0.7800	0.9512	0.8571	0.6875	0.7042
Light Gradient Boosting Machine	0.8313	0.9206	0.8200	0.8913	0.8542	0.6550	0.6582
Extreme Gradient Boosting	0.8434	0.9158	0.8400	0.8936	0.8660	0.6780	0.6799
Random Forest Classifier	0.8554	0.9136	0.8400	0.9130	0.8750	0.7043	0.7077
Naive Bayes	0.8554	0.9061	0.8400	0.9130	0.8750	0.7043	0.7077
Quadratic Discriminant Analysis	0.8675	0.9091	0.8600	0.9149	0.8866	0.7275	0.7296
Extra Trees Classifier	0.8675	0.9173	0.8400	0.9333	0.8842	0.7303	0.7358
Ada Boost Classifier	0.7952	0.8776	0.7800	0.8667	0.8211	0.5832	0.5876
K Neighbors Classifier	0.8313	0.8894	0.7800	0.9286	0.8478	0.6618	0.6745
Decision Tree Classifier	0.8675	0.8745	0.8400	0.9333	0.8842	0.7303	0.7358

表3 影像组学模型在验证集中的性能

模型	准确率	AUC	召回率	精确率	F1值	Kappa	MCC
CatBoost Classifier 0.8554	0.9127	0.8800	0.8800	0.8800	0.6982	0.6982	
Gradient Boosting Classifier	0.8193	0.8961	0.8400	0.8571	0.8485	0.6247	0.6249
Extreme Gradient Boosting	0.8313	0.8752	0.8600	0.8600	0.8600	0.6479	0.6479
Extra Trees Classifier	0.8554	0.9176	0.8800	0.8800	0.8800	0.6982	0.6982
Random Forest Classifier	0.8675	0.9018	0.8800	0.8980	0.8889	0.7248	0.7250
Ada Boost Classifier	0.8434	0.8836	0.8400	0.8936	0.8660	0.6780	0.6799
Naive Bayes	0.8554	0.9006	0.8800	0.8800	0.8800	0.6982	0.6982
Light Gradient Boosting Machine	0.8554	0.8964	0.8800	0.8800	0.8800	0.6982	0.6982
K Neighbors Classifier	0.8795	0.8958	0.9200	0.8846	0.9020	0.7459	0.7468
Quadratic Discriminant Analysis	0.8434	0.8921	0.8600	0.8776	0.8687	0.6747	0.6749
Decision Tree Classifier	0.7952	0.7939	0.8000	0.8511	0.8247	0.5789	0.5805

表4 临床+影像组学联合模型在验证集中的性能

模型	准确率	AUC	召回率	精确率	F1值	Kappa	MCC
Ada Boost Classifier	0.8434	0.9248	0.8400	0.8936	0.8660	0.6780	0.6799
Extra Trees Classifier	0.8434	0.9542	0.8400	0.8936	0.8660	0.6780	0.6799
Random Forest Classifier	0.8434	0.9297	0.8400	0.8936	0.8660	0.6780	0.6799
Extreme Gradient Boosting	0.8554	0.9421	0.8600	0.8958	0.8776	0.7013	0.7021
CatBoost Classifier	0.8434	0.9521	0.8400	0.8936	0.8660	0.6780	0.6799
Naive Bayes	0.8554	0.8912	0.9200	0.8519	0.8846	0.6918	0.6955
Light Gradient Boosting Machine	0.8434	0.9403	0.8400	0.8936	0.8660	0.6780	0.6799
Gradient Boosting Classifier	0.8434	0.9294	0.8400	0.8936	0.8660	0.6780	0.6799
Decision Tree Classifier	0.8916	0.8945	0.8800	0.9362	0.9072	0.7771	0.7792
K Neighbors Classifier	0.8193	0.9048	0.7400	0.9487	0.8315	0.6430	0.6662
Quadratic Discriminant Analysis	0.8313	0.9088	0.9400	0.8103	0.8704	0.6327	0.6472

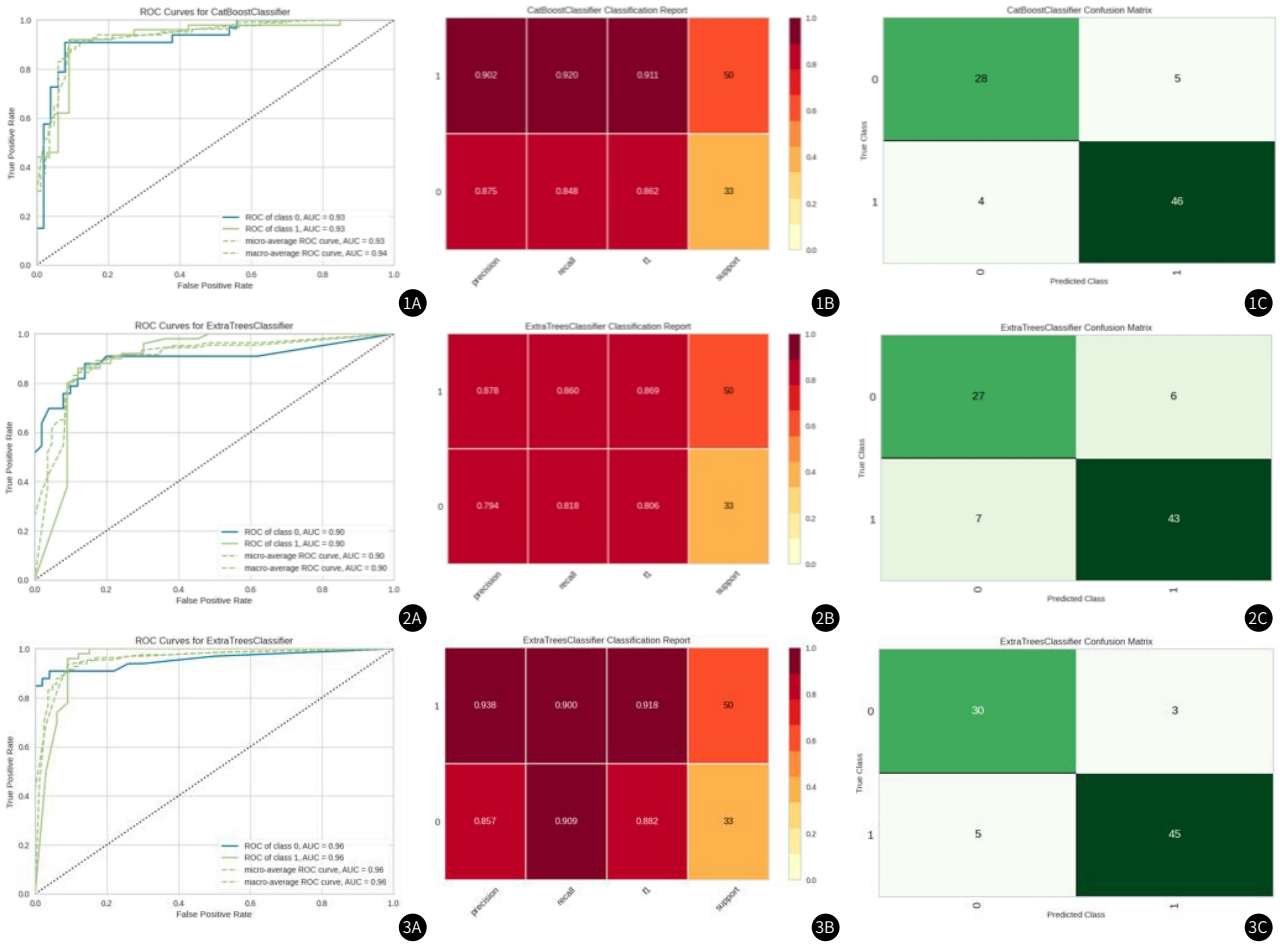

图1 临床特征模型；图1A: CatBoostClassifier AUC；图1B: CatBoostClassifier class report；图1C: CatBoostClassifier confusion matrix。
图2 影像组学特征模型；图2A: ExtraTreesClassifier AUC；图2B: ExtraTreesClassifier class report；图2C: ExtraTreesClassifier confusion matrix。
图3 临床+影像组学特征模型；图3A: ExtraTreesClassifier AUC；图3B: ExtraTreesClassifier class report；图3C: ExtraTreesClassifier confusion matrix。

3 讨 论

目前术前影像检查鉴别LPAA与PHEO存在着一定程度的困难。虽然通过生化检测能够提高二者鉴别的准确率，但会增加不必要的检查时间、费用和患者负担，且不能避免误诊[14-15]。

本研究显示，与LPAA相比，PHEO的CTu、CTa、CTv、APEA、CTa-CTv、CTa-CTu、APW、RPW的水平均相对较高，而发病年龄PHEO则相对较低。PHEO的直径更大、形态更不规则、边界更不清晰，囊变、出血、瘤内出血与钙化概率相对较高。嗜铬细胞瘤是一个高度富血供的肿瘤[16]，肿瘤生长较迅速，瘤体相对较大。而肿瘤中央区相对缺乏血供易坏死，导致瘤内出血较多。

An[17]等人通过多元逻辑回归分析评估了嗜铬细胞瘤的风险因素，并建立了基于风险因子奇数比(OR)的诊断评分模型，诊断评分模型的曲线下面积(AUC)为0.911。Yi[12]等人的对CT影像特征进行评估，提取影像组学特征用于构建Rad 评分，该特征标签在亚临床嗜铬细胞瘤(sPHEO)组与LPAA组间存在显著差异(AUC：训练集 = 0.907，验证集 = 0.902)。Shan[18]等人用影像学语义特征和影像组学特征构建了模型，来区分PHEO和LPAA，所有模型AUC值均超过0.8。Niu[19]等人计算两种肿瘤在增强前后CT值变化并建立模型，得出囊性病变、CTu以及动脉和静脉期增强峰值(DEpeak)是肾上腺PCC与LPA鉴别诊断的独立风险因素。Xiao[20]的研究仅提取了CT影像组学特征建立了多个机器学习模型，性能最优的模型AUC值高达0.979，但是研究并未分析临床特征建模进行对比。我们此次由两位高年制放射科医师勾画了肿瘤ROI后训练了uuU-Net自动勾画模型提取影像组学特征，接着分别构建了基于临床特征集、影像组学特征集以及临床特征融合影像组学特征集各自超过十个机器学习模型，分类性能均表现良好，临床模型与影像组学模型各自表现最佳的是CatBoost Classifier与Extra Trees Classifier，AUC值分别为0.9303、0.9176，表明CT影像语义特征加上CT定量值建立的模型有可能优于影像组学模型，而融合模型中的Extra Trees Classifier则表现出了更优秀性能，AUC值为0.9542，但是三种最优模型的差异没有统计学意义。

本研究有局限性，图像和数据来自单个医疗机构，缺乏外部验证，下一步将收集外院的数据进行多中心研究，以证明模型的普适性和鲁棒性。

综上所述，本研究建立了融合临床特征、多时相CT定量值与影像组学特征的模型，能够术前精确鉴别嗜铬细胞瘤和肾上腺乏脂型腺瘤，为临床决策提供了有价值的参考依据。

参考文献

[1]Alimu P,Fang C,Han Y,et al.Artificial intelligence with a deep learning network for the quantification and distinction of functional adrenal tumors based on contrast-enhanced CT images[J].Quant Imaging Med Surg,2023,13(4):2675-2687.

[2]Albano D,Agnello F,Midiri F,et al.Imaging features of adrenal masses[J].Insights into imaging,2019,10(1):1.

[3]Umanodan T,Fukukura Y,Kumagae Y,et al.ADC histogram analysis for adrenal tumor histogram analysis of apparent diffusion coefficient in differentiating adrenal adenoma from pheochromocytoma[J].J Magn Reson Imaging,2017,45(4):1195-1203.

[4]Blake MA,Kalra MK,Maher MM,et al.Pheochromocytoma:an imaging chameleon[J].Radiographics,2004,24 Suppl 1:S87-99.

[5]Lam AK.Update on adrenal tumours in 2017 World Health Organization (WHO) of Endocrine Tumours[J].Endocr Pathol,2017,28(3):213-227.

[6]Akbulut S,Erten O,Kahramangil B,et al.A critical analysis of computed tomography washout in lipid-poor adrenal incidentalomas[J].Ann Surg Oncol,2021,28(5):2756-2762.

[7]Altinmakas E,Perrier ND,Grubbs EG,et al.Diagnostic performance of adrenal CT in the differentiation of adenoma and pheochromocytoma[J].Acta Radiol,2020,61(8):1080-1086.

[8]Woo S,Suh CH,Kim SY,et al.Pheochromocytoma as a frequent false-positive in adrenal washout CT:a systematic review and meta-analysis[J].Eur Radiol,2018,28(3):1027-1036.

[9]Gillies RJ,Kinahan PE,Hricak H.Radiomics:images are more than pictures,they are data[J].Radiology,2016,278(2):563-577.

[10]Bibault JE,Xing L,Giraud P, et al.Radiomics:a primer for the radiation oncologist[J].Cancer Radiother,2020,24(5):403-410.

[11]Lambin P,Leijenaar RTH,Deist TM,et al.Radiomics:the bridge between medical imaging and personalized medicine[J].Nat Rev Clin Oncol,2017,14(12):749-762.

[12]Yi X,Guan X,Zhang Y,et al.Radiomics improves efficiency for differentiating subclinical pheochromocytoma from lipid-poor adenoma:a predictive,preventive and personalized medical approach in adrenal incidentalomas[J].EPMA J,2018,9(4):421-429.

[13]Araujo-Castro M,García Sanz I,Mínguez Ojeda C,et al.An integrated CT and MRI imaging model to differentiate between adrenal adenomas and pheochromocytomas[J].Cancers (Basel),2023,15(14).

[14]Feliciani G,Serra F,Menghi E,et al.Radiomics in the characterization of lipid-poor adrenal adenomas at unenhanced CT:time to look beyond usual density metrics[J].European radiology,2024,34(1):422-432.

[15]Eisenhofer G,Pamporaki C,Lenders JWM.Biochemical assessment of pheochromocytoma and paraganglioma[J].Endocrine Reviews,2023,44(5):862-909.

[16]Achote E,Arroyo Ripoll OF,Araujo-Castro M. Update on the diagnosis of the pheochromocytoma[J].Hipertens Riesgo Vasc,2025,42(1):43-51.

[17]An YY,Yang GZ,Lin B, et al.Differentiation of lipid-poor adenoma from pheochromocytoma on biphasic contrast-enhanced CT[J].Abdominal Radiology (New York),2021,46(9):4353-4361.

[18]Shan Z,Zhang X,Zhang Y,et al.Combined nomogram for differentiating adrenal pheochromocytoma from large-diameter lipid-poor adenoma using multiphase CT radiomics and clinico-radiological features[J].BMC Med Imaging,2025,25(1):313.

[19]Niu Z,Wang J,Yang Y, et al.Risk prediction model establishment with tri-phasic CT image features for differential diagnosis of adrenal pheochromocytomas and lipid-poor adenomas:Grouping method[J].Frontiers in Endocrinology,2022,13:925577.

[20]Xiao DX,Zhong JP,Peng JD,et al.Machine learning for differentiation of lipid-poor adrenal adenoma and subclinical pheochromocytoma based on multiphase CT imaging radiomics[J].BMC Med Imaging,2023,23(1):159.

(收稿日期：2025-12-17) (校对：赵望淇 排版：张鸿燊)