

DOI:10.3969/j.issn.1005-202X.2025.11.018

医学人工智能

基于MRI的深度影像组学集成学习预测高风险产妇产后出血

张琪^{1,2}, 王海杰³, 梁晓云³, 朱好⁴, 杨光^{1,2}

1. 华东师范大学物理与电子科学学院上海市磁共振重点实验室, 上海 200062; 2. 华东师范大学医学磁共振与分子影像技术研究院, 上海 200062; 3. 上海东软医疗科技有限公司创新研究院, 上海 201100; 4. 复旦大学附属妇产科医院, 上海 200011

【摘要】目的: 基于T₂WI开发一种结合临床特征、深度学习(DL)和放射组学的预测模型,用于产前评估高风险产妇的产后出血(PPH)风险。**方法:** 回顾性收集538名超声报告胎盘植入高风险孕妇,分别作为训练集、内部测试集和外部测试集。训练一个nnUNet模型进行自动胎盘分割。对临床特征进行单变量和多变量分析,选出与PPH相关的特征。从胎盘区域提取定量影像组学特征,并构建随机森林模型预测失血量(EBL)和PPH风险。基于DenseNet训练了一个多任务DL模型预测PPH风险、EBL和胎盘前置状态。最后结合临床特征、DL输出和放射组学评分构建深度-影像组学集成模型(DRE)。通过受试者工作特征曲线(ROC)下面积(AUC)和DeLong检验评估诊断性能。**结果:** DRE模型在内部和外部测试中的AUC分别为0.874(95% CI: 0.792~0.951)和0.836(95% CI: 0.648~0.974),显著优于单独的临床、DL和放射组学模型。结合EBL回归,改善了PPH分类模型的表现,外部测试AUC从0.261~0.788提高到0.836。**结论:** DRE模型结合DL和放射组学,能高效预测PPH风险,有助于高风险妊娠的临床管理。

【关键词】 产后出血; 胎盘植入; 深度学习; 影像组学; 失血量

【中图分类号】 R318; R714.46

【文献标志码】 A

【文章编号】 1005-202X(2025)11-1523-09

MRI-based deep learning-radiomics ensemble model for predicting postpartum hemorrhage in high-risk pregnancies

ZHANG Qi^{1,2}, WANG Haijie³, LIANG Xiaoyun³, ZHU Hao⁴, YANG Guang^{1,2}

1. Shanghai Key Laboratory of Magnetic Resonance, School of Physics and Electronic Science, East China Normal University, Shanghai 200062, China; 2. Institute of Magnetic Resonance and Molecular Imaging in Medicine, East China Normal University, Shanghai 200062, China; 3. Innovation Institute, Shanghai Neusoft Medical Systems Co., Ltd., Shanghai 201100, China; 4. Obstetrics and Gynecology Hospital of Fudan University, Shanghai 200011, China

Abstract: Objective To develop a predictive model integrating clinical features, deep learning (DL), and radiomics based on T₂-weighted imaging for prenatal assessment of postpartum hemorrhage (PPH) risk in high-risk pregnant women. **Methods** A total of 538 pregnant women with ultrasound-reported high-risk placenta accrete were retrospectively enrolled and divided into training, internal test, and external test cohorts. A nnUNet model was trained for automatic placental segmentation. Univariate and multivariate analyses were conducted on clinical features to identify those associated with PPH. Quantitative radiomic features were extracted from the placental region, and a random forest model was developed to predict estimated blood loss (EBL) and PPH risk. A DenseNet-based multi-task DL model was trained to predict PPH risk, EBL, and placenta previa status. Finally, a DL-radiomics ensemble (DRE) model was constructed by integrating clinical features, DL outputs, and radiomics scores. Diagnostic performance was evaluated using the area under the receiver operating characteristic curve (AUC) and DeLong test. **Results** The DRE model achieved AUC values of 0.874 (95% CI: 0.792-0.951) and 0.836 (95% CI: 0.648-0.974) in the internal and external test cohorts, respectively, significantly outperforming the standalone clinical, DL, and radiomics models. Incorporation of EBL regression improved the performance of the PPH classification model, with the external test AUC increasing from 0.261-0.788 to 0.836. **Conclusion** The DRE model integrating DL and radiomics can efficiently predict PPH risk and assist in the clinical management of high-risk pregnancies.

Keywords: postpartum hemorrhage; placenta accreta; deep learning; radiomics; blood loss

【收稿日期】 2025-03-21

【基金项目】 国家自然科学基金(61731009)

【作者简介】 张琪, 硕士研究生, 研究方向: 医学图像处理、人工智能, E-mail: zqchina@163.com

【通信作者】 杨光, 博士, 副研究员, 研究方向: 医学图像处理、人工智能, E-mail: gyang@phy.ecnu.edu.cn

前言

产后出血(Postpartum Hemorrhage, PPH)是全球范围内导致产妇并发症和死亡的重要原因^[1-2]。根据美国妇产科学会(the American College of Obstetricians and Gynecologists, ACOG)指南, PPH定义为:(1)剖宫产术中累积预估失血量(Estimated Blood Loss, EBL) $\geq 1\ 000$ mL;(2)不论分娩方式,产妇产后24 h内出现出血伴低血容量症状^[3]。胎盘植入(Placenta Accreta Spectrum, PAS)是指胎盘绒毛组织异常黏附或侵入子宫肌层的病理状态,其核心病理特征为胎盘剥离不全及子宫收缩功能障碍^[4]。PAS的发病率与产妇年龄、流产次数及剖宫产次数的增加以及胎盘前置(Placenta Previa, PP)等因素密切相关^[5-6]。此类患者在剖宫产术中易并发PPH,严重者可进展为子宫切除或死亡^[4, 7-9]。因此,早期识别PPH高危患者对制定分娩计划、备血输血准备、优化资源配置及减少孕产妇并发症具有重要意义^[10-11]。

超声检查是产前评估PAS的首要手段^[12],当超声结果不明确时,磁共振成像(Magnetic Resonance Imaging, MRI)通常作为补充检查方法^[13]。MRI无辐射风险且具有卓越的软组织对比度,是理想的产前检查方式^[14-16]。然而,随着孕周增加,子宫肌层变薄及胎盘信号异质性增加,使得MRI对PAS的评估更具挑战性。此外,影像判读的准确性高度依赖放射科医师的经验^[17]。

近年来,影像组学与深度学习作为新型预测与诊断技术,已在多个领域得到广泛研究^[13, 18-23]。影像组学能够从医学影像中提取定量信息,分析并量化肉眼难以辨识的高维度组织特征^[24]。一项多中心影像组学研究证实了该技术在预测PPH中的有效性^[13]。与影像组学相比,深度学习能够自动提取图像特征,无需依赖人工设计特征^[20, 22-23],这一技术优势使其在胎盘前置患者的PPH预测中得到成功应用^[20]。

尽管深度学习与影像组学在胎盘相关疾病诊断及PPH预测中展现出潜力,但既往研究通常以1 000 mL作为阈值,根据患者EBL分成两组,缺少了对EBL更精细的信息挖掘^[13, 20-21, 25]。由于EBL是PPH的量化诊断标准之一,笔者假设通过联合预测PPH与EBL可提升模型性能。同时,构建了融合影像组学与深度学习优势的集成学习模型,以期进一步提高模型的准确性与可靠性^[26-27]。

1 材料与方法

1.1 患者与分组

回顾性地收集2015年1月~2022年6月的794名

经过MRI检查的孕妇,得到复旦大学附属妇产科医院伦理委员会的批准(编号2022-113),并豁免了患者的知情同意书。纳入标准包括:(1)单胎妊娠;(2)超声检查提示PAS高风险;(3)接受产前MRI检查;(4)接受剖宫产术;(5)实施输血方案并记录EBL。排除标准包括:(1)终止妊娠;(2)MRI图像质量不佳;(3)未接受剖宫产术;(4)临床资料缺失。最终538例患者被纳入试验。

从医学影像存档与通信系统中收集了患者临床资料,包括(1)一般资料:年龄、孕周、妊娠次数、产次、既往剖宫产次数以及胎盘位置;(2)病理资料:术中EBL和基于产后病理检查的PAS诊断结果。本研究中PPH组定义为EBL $\geq 1\ 000$ mL的全部患者。

基于一台1.5T(Magnetom Avanto, Siemens, 德国)或一台3.0T(Ingenia 3.0T, Philips Healthcare, 荷兰)磁共振设备扫描的512例患者,根据PPH状态按8:2的比例进行分层随机拆分,得到训练集($n=409$)和内部测试集($n=103$)。基于不同扫描参数的另一台1.5T(Optima MR 360, GE Healthcare, 美国)磁共振设备扫描的26例患者作为外部测试集。患者筛选流程见图1。PAS风险的超声判断标准定义为以下8项特征^[12]:(1)胎盘后高回声带消失;(2)子宫肌层变薄;(3)胎盘陷窝;(4)膀胱壁中断;(5)胎盘隆起;(6)外生性团块;(7)宫膀胱区血管高灌注;(8)胎盘血管异常。

1.2 MRI图像分割与预处理

本研究选用矢状位 T_2 加权快速自旋回波序列(T_2 WI)。该序列凭借优异的软组织对比度,可清晰显示子宫肌层-胎盘界面结构。感兴趣区域(Volume of Interest, VOI)定义为 T_2 WI上胎盘内表面与子宫壁外表面之间的所有胎盘组织。两位分别具有3年和8年盆腔MRI诊断经验的放射科医师通过ITK-SNAP软件(v3.6.0, <http://www.itksnap.org>)手动勾画VOI,每个勾画结果都由另一位具有12年经验的资深放射科医师对模糊边缘进行审核修正。所有影像经过偏置场校正、像素值归一化以及对比度限制自适应直方图均衡^[28]。层内图像尺寸基于双线性插值算法重采样为 768×768 。为解决训练数据PPH组与非PPH组类别不平衡问题,对训练集中患者数量较少的PPH组进行了随机上采样。

2 模型构建

2.1 深度学习模型构建

本研究的深度学习流程图见图2。首先训练了一个3D nnUNet模型对 T_2 WI图像进行胎盘自动分割。nnUNet是一个自动化医学影像分割框架,可根

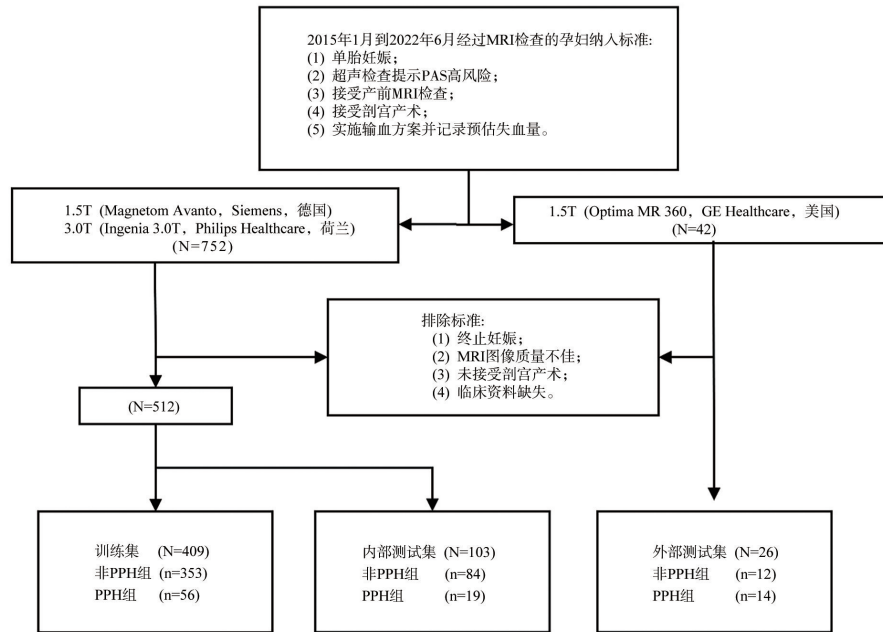


图1 研究样本收集流程

Figure 1 Recruitment flowchart

据输入数据特性动态优化网络架构与超参数,从而实现高效、鲁棒的分割性能^[29]。模型训练以放射科医师手动勾画的VOI为金标准,使用训练集数据完成模型训练。

为了提取影像中与EBL相关的特征信息,笔者采用DenseNet-264作为主干网络进行特征提取。DenseNet的核心架构特点在于其密集跨层连接机制,即每一层的输出均与后续所有层直接连接。这种设计不仅增强了特征传播效率,还促进了特征复用,同时有效缓解了深层网络中的梯度消失问题^[30]。

为了提高PPH预测的准确性,本研究构建了一种多任务深度学习框架,通过联合学习机制整合以下3个具有明确临床指向的子任务:(1)PPH分类(PPH-DL):基于二元交叉熵损失函数(Binary Cross-Entropy Loss, BCE),直接预测PPH的发生。该任务主要捕捉PPH患者和非PPH患者的组间特征差异,提升模型对PPH的预测能力;(2)EBL回归(EBL-DL):该回归任务使用均方误差(Mean Squared Error, MSE)损失函数,旨在准确预测EBL,并捕捉与EBL相关的特征。MSE的特性使大出血样本在模型训练中占据更高权重,从而优化对危重病例的识别效能;(3)PP分类(PP-DL):基于BCE损失函数识别PP状态。

采用了标准差为0.05的高斯噪声和伽马值在0.8~1.2之间的对比度调整进行数据增强,优化器使用Adam算法,初始学习率为 10^{-3} 。训练与测试在配备NVIDIA RTX2080Ti显卡和Intel Xeon CPU的工作

站上进行。PPH-DL、EBL-DL和PP-DL 3个任务基于不同损失函数进行训练。为增强模型的可解释性,采用Grad-CAM(Gradient-weighted class activation mapping)对T₂WI中间卷积层激活区域进行可视化^[31]。

2.2 影像组学特征提取与模型构建

使用Python中的PyRadiomics 3.0.1包,从每个VOI中提取了386个符合影像生物标志物标准化倡议(IBSI)^[32]的影像组学特征,包括原始图像特征和3种拉普拉斯-高斯滤波图像特征($\sigma=1, 3, 5$)。采用z-score算法进行特征矩阵标准化,通过阈值设为0.95的皮尔森相关系数(Pearson Correlation Coefficient, PCC)与递归特征消除法剔除冗余特征并与筛选与EBL高度相关的特征。

影像组学模型构建部分如图2所示,基于随机森林算法(Random Forest, RF),分别学习PPH分类任务和EBL回归任务,开发了3种不同的影像组学模型:(1)PPH分类(PPH-RF):以最小化基尼指数为目标的RF分类模型,旨在减少PPH预测的分类误差;(2)EBL回归(EBL-RF):以最小化EBL预测的MSE为目标的RF回归模型,旨在充分拟合不同患者的EBL分布;(3)联合影像组学模型:整合PPH-RF、EBL-RF的结果及PP诊断的多元逻辑回归(Logistic Regression, LR)模型。

2.3 临床模型与集成模型构建

使用术前临床资料进行了LR单变量分析,并将那些在PPH组和非PPH组之间存在显著差异的特征

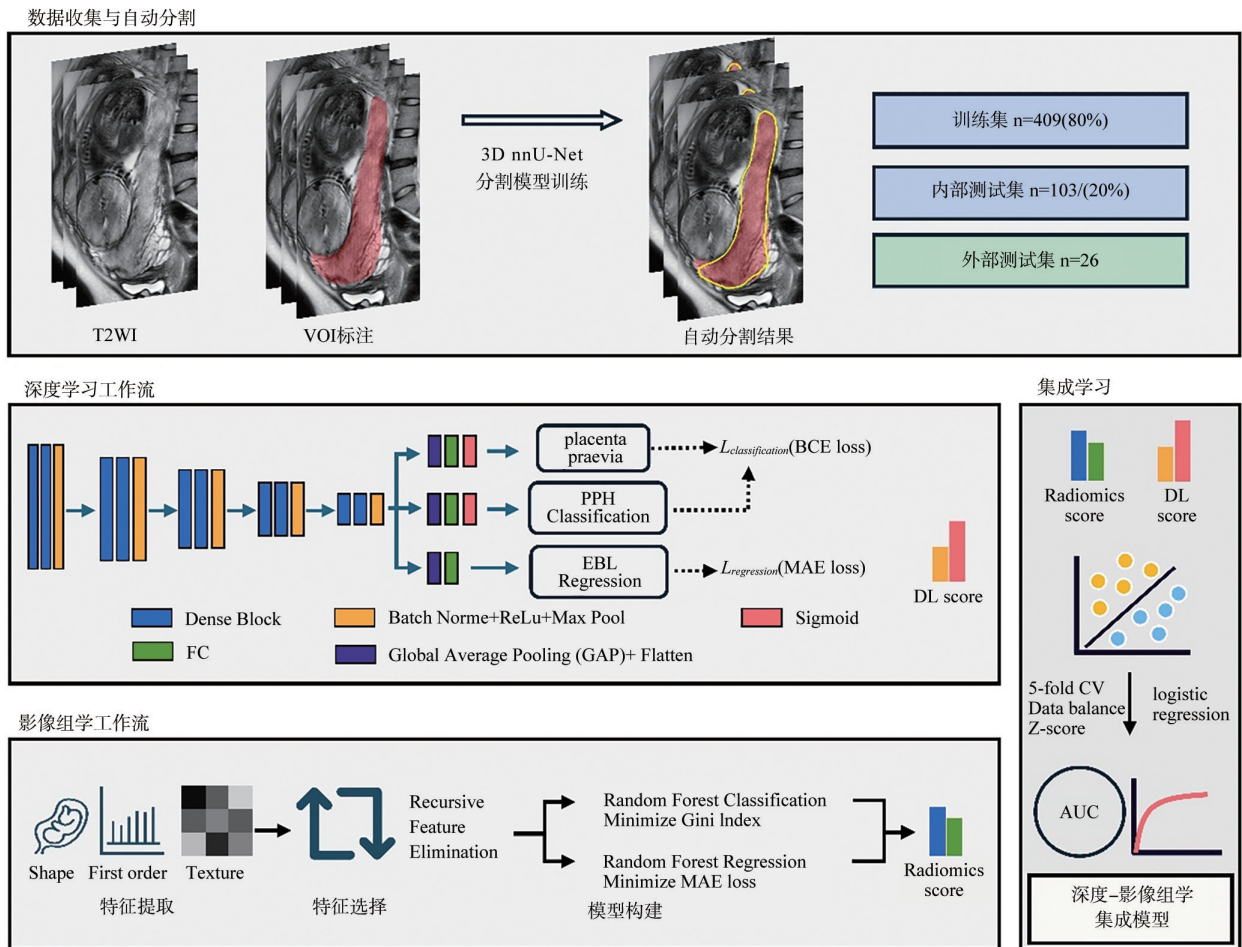


图2 结合自动分割的深度影像组学集成模型构建流程图

Figure 2 Flowchart of DL-radiomics ensemble model constructed with automatic segmentation

纳入多元LR分析中,经过PCC剔除共线性较大的特征后,构建临床模型。

将深度学习模型归一化输出设为DL-score,影像组学归一化输出设为Radiomics-score,联合DL-score、Radiomics-score和临床模型特征,通过LR分类器最终构建深度学习-影像组学集成模型(DL Radiomics Ensemble, DRE)。

2.4 模型评估

使用Dice系数评估胎盘自动分割模型性能。使用受试者工作特征曲线(Receiver Operating Characteristic, ROC)和曲线下面积(Area Under the Curve, AUC)评估模型性能,基于训练集最大约登指数确定分类阈值并计算灵敏度(Sensitivity, SEN)、特异性(Specificity, SPE)、阳性预测值(Positive Predictive Value, PPV)及阴性预测值(Negative Predictive Value, NPV)。对于回归模型的评估,预测的EBL值通过min-max归一化转换为0~1的PPH预测概率,并基于约登指数确定阈值。由于正负样本数量不平衡,采用平衡准确率(Balanced Accuracy,

BA)评估非平衡数据的分类准确率。使用SHAP(SHapley additive explanation)方法评估模型的可解释性以及特征对模型的贡献^[33]。所有模型均通过五折交叉验证和超参数空间的网格搜索上进行优化。

2.5 统计学分析

对于不同特征,PPH组与非PPH组的组间差异采用独立样本t检验(符合正态分布)或Mann-Whitney U检验(不符合正态分布)进行分析,符合正态分布的计量资料以均值±标准差表示,组间比较采用独立样本t检验;不符合正态分布的计量资料以中位数(四分位数间距) $[M(Q1, Q3)]$ 表示。计数资料以例数(百分比)表示,组间比较采用 χ^2 检验或Fisher精确检验(当期望频数 <5 时)。使用DeLong检验对模型间的AUC值进行比较。 $P<0.05$ 表示差异具有统计学意义。深度学习流程基于MONAI框架(v1.3, <https://github.com/Project-MONAI>^[34]实现,统计学分析使用R软件(v3.5.0)及Python(v3.11)的SciPy(v1.10.1)与scikit-learn(v0.22)包。

3 实验结果

3.1 基线特征与临床模型结果

3个数据集间的临床资料均无统计学意义($P>0.05$)。不同数据集的PPH组和非PPH组临床信息见表1。PP、孕周及产次在PPH组与非PPH组间存在显著差

异,被纳入临床模型。如表2所示,临床模型在内部测试集和外部测试集中的AUC分别为0.782(95% CI: 0.675~0.882)和0.715(95% CI: 0.488~0.911)。PPH患者的EBL中位数在训练集、内部测试集和外部测试集分别为2 200、1 800和1 800 mL。经验证PAS与EBL显著相关。

表1 不同数据集产妇基线资料

Table 1 Baseline characteristics of the pregnant women in different cohorts

临床资料	训练集			内部测试集			外部测试集		
	PPH($n=56$)	非PPH($n=353$)	P 值	PPH($n=19$)	非PPH($n=84$)	P 值	PPH($n=14$)	非PPH($n=12$)	P 值
年龄/岁	33.7±4.6	33.3±4.7	0.508	33.4±3.6	32.8±4.3	0.579	36.6±2.9	35.2±3.9	0.662
孕次/次	3.9±2.1	3.6±2.1	0.239	3.6±1.6	3.6±2.1	0.543	4.2±1.7	2.9±1.2	0.232
产次/次	1.9±0.6	1.8±0.7	0.089	1.7±0.5	1.8±0.8	0.893	1.6±0.8	0.8±0.7	0.008
孕周/周	35.3±4.1	38.0±1.8	0.001	36.4±2.1	37.8±2.0	0.001	35.4±2.0	37.0±2.5	0.001
PP	51(91)	111(31)	<0.001	16(84)	28(33)	<0.001	14(100)	17(100)	1
PAS	44(78)	79(22)	<0.001	17(89)	17(20)	<0.001	14(100)	17(100)	1
EBL中位数/mL	2200(1000~10000)	300(200~800)	<0.001	1800(1000~5000)	300(200~800)	<0.001	1800(1000~7500)	500(130~800)	<0.001

PP:前置胎盘;PAS:胎盘植入;EBL:预估失血量;PPH:产后出血

表2 不同PPH诊断模型的表现

Table 2 Performance of different models for PPH prediction

指标	内部测试集				外部测试集			
	临床模型	DL模型	影像组学模型	DRE模型	临床模型	DL模型	影像组学模型	DRE模型
AUC(95% CI)	0.782 (0.675~0.882)	0.860 (0.762~0.940)	0.870 (0.786~0.942)	0.874 (0.792~0.951)	0.715 (0.488~0.911)	0.758 (0.542~0.939)	0.782 (0.575~0.964)	0.836 (0.648~0.974)
BA	0.752	0.783	0.774	0.814	0.743	0.776	0.776	0.785
SEN	0.790	0.684	0.632	0.842	0.667	0.733	0.733	0.933
SPE	0.714	0.881	0.917	0.786	0.818	0.818	0.818	0.636
PPV	0.385	0.565	0.632	0.471	0.833	0.846	0.846	0.778
NPV	0.938	0.925	0.917	0.956	0.643	0.692	0.692	0.875

BA:平衡准确率;DRE:深度-影像组学集成模型

3.2 深度学习模型结果


两位放射科医生勾画VOI的Dice相似系数(DSC)为0.940。胎盘分割模型在测试集中的平均DSC为0.856,如图3a所示,模型的分割结果与真实标注高度一致,呈现出较强的视觉相似性。

深度学习模型的结果见表2。在结合了PPH分类、EBL回归和PP分类3项任务的综合深度学习模型(DL模型)中,在内部和外部测试集中的AUC值分别为0.860(95% CI: 0.762~0.940)和0.758(95% CI: 0.542~0.939),显著高于单独的PPH分类模型(PPH-

DL)和EBL回归模型(EBL-DL), $P=0.015$ 。深度学习模型比较实验详细结果请见表3。图4展示了DRE模型在与不同模型比较的ROC曲线。图3c和3d展示了PPH-DL和EBL-DL在不同患者中的Grad-CAM激活图。

3.3 影像组学模型结果

在影像组学分析中,PPH-RF和EBL-RF分别选出了11个特征和10个特征。这些影像组学特征的重要性,通过SHAP值进行评估,结果如图5所示,SHAP值反映了特征对模型输出的影响方向和大小。



a: 自动分割结果 b: 显示PAS风险的影像特征 c: PPH-DL Grad-CAM d: EBL-DL Grad-CAM

图3 深度学习自动分割结果、MRI特征与Grad-CAM可解释性

Figure 3 DL automatic segmentation results, MRI features, and Grad-CAM interpretability

联合影像组学结合了PPH分类、EBL回归和PP状态来预测PPH。通过整合这3项任务的输出得分,联合影像组学模型在内部和外部测试集上的AUC分别为0.870(95% CI: 0.786~0.942)和0.782(95% CI: 0.575~0.964),超过了PPH-RF, $P=0.121$ 。与EBL-RF相比,外部数据AUC接近,但BA从0.730增加到0.776(表3)。

3.4 DRE模型结果

DRE模型整合影像组学评分与深度学习评分,在内部和外部测试集上的AUC分别为0.874(95% CI: 0.792~0.951)和0.836(95% CI: 0.648~0.974),显著优于其他模型。在外部测试集上将AUC从0.715~0.782提升到0.836,在不同设备的数据上表现出更高的泛化性。

4 讨论

本研究基于T₂WI数据构建了全自动DRE模型,用于预测高危妊娠患者的PPH风险。通过联合分类与回归损失函数,该模型能够从T₂WI图像中更全面、

更稳健地提取出血相关特征,在内部和外部测试集分别获得0.874和0.836的AUC。在深度学习与影像组学方法中,笔者分别训练了基于分类损失的PPH分类模型和基于回归损失的EBL预测模型。结果表明,二者结合优于单一模型,表现出更强的鲁棒性。

在深度学习模型方面,笔者整合了3项任务来辅助预测PPH。尝试了多种网络,最终选择了表现最优的DenseNet-264。尽管PPH预测是一个分类任务,但传统分类模型难以充分捕捉不同EBL水平患者之间的组内差异。回归网络能够为不同出血程度的PPH患者赋予不同的权重,特别是对那些出血量极大的患者(>2 000 mL)给予更高的权重,有助于模型更好地从影像数据中提取出血量相关特征。PPH-DL模型在内部数据集上的表现良好,但在外部测试集上的AUC显著下降,在不同数据集之间的泛化能力有限。相比之下,EBL-DL模型通过回归损失函数有效地利用了患者之间的EBL差异,获得了更高的AUC和BA。此外,Grad-CAM可视化结果(图3)清晰展示了分类模型与回归模型的差异:分类模型倾向于聚

表 3 深度学习和影像组学消融实验结果
Table 3 Results of the ablation study of DL and radiomics

算法	模型结构			内部测试集		外部测试集	
	PPH分类	EBL回归	PP信息	AUC(95% CI)	BA	AUC (95% CI)	BA
DL DenseNet	√			0.778(0.670~0.877)	0.738	0.261(0.069~0.473)	0.533
		√		0.818(0.698~0.927)	0.785	0.722(0.481~0.927)	0.773
	√	√		0.786(0.672~0.884)	0.723	0.752(0.555~0.923)	0.763
	√	√	√	0.860(0.762~0.940)	0.783	0.758(0.542~0.939)	0.776
Radiomics RF	√			0.858(0.766~0.933)	0.727	0.721(0.506~0.923)	0.730
		√		0.837(0.746~0.922)	0.649	0.788(0.594~0.959)	0.730
	√	√		0.861(0.776~0.938)	0.787	0.794(0.588~0.970)	0.788
	√	√	√	0.870(0.786~0.942)	0.774	0.782(0.575~0.964)	0.776

PP:前置胎盘;BA:平衡准确率;RF:随机森林

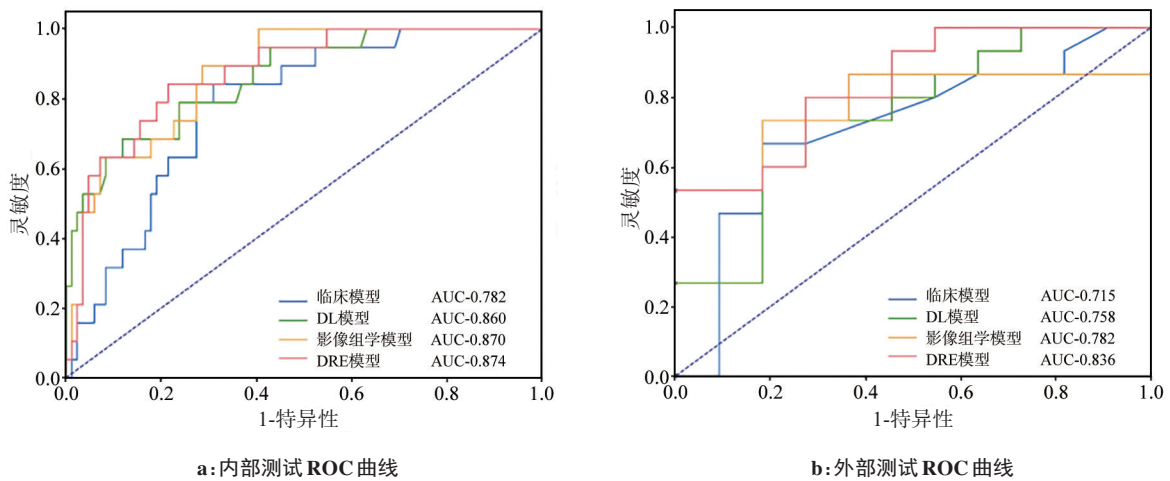


图 4 不同模型在内部测试集和外部测试集的 ROC 曲线
Figure 4 ROC curves of different methods over the internal and external test cohorts

焦特定区域(如胎盘内 T2 暗带、外生性胎盘肿块及胎盘床异常血管),这些区域在严重出血患者中可能提示 PAS 的 MRI 形态学特征;而回归模型则整合全胎盘信息,通过全局特征预测失血量。这表明,利用回归损失进行 PPH 预测可使网络学习到比传统二分类损失更广的感受野。当进一步结合分类和回归损失函数时,联合深度学习模型在外部测试集上的表现优于单独的 EBL-DL 模型。这表明,结合分类和回归损失能够让网络同时识别关键的 MRI 特征,并考虑胎盘的整体背景,从而提高其泛化能力。

相对于影像组学模型,PPH-RF 模型在外部测试集上的 AUC 明显下降,而 EBL-RF 模型在外部数据集上表现更好,同样表明回归方法具有更好的泛化能力。此外,结合 PPH-RF 和 EBL-RF 的分数,获得了比单独的 PPH-RF 和 EBL-RF 模型更高的 AUC 和 BA

值。这些发现与深度学习模型的结论一致。

已有多项研究尝试基于 T₂WI 开发影像组学或深度学习模型来预测高危妊娠中的 PPH 风险。尽管这些模型主要集中在二分类问题上,但有研究表明预测失血量与实际 EBL 存在强相关性^[20]。PPH 患者的失血量差异显著(1 000~10 000 mL),这些差异可能蕴含有助于 PPH 预测的信息。为了更好地利用这种差异,通过回归任务使网络直接学习失血量信息。通过拟合 EBL,回归模型能够提取与 EBL 相关的特征,这些特征比单纯 PPH 分类任务蕴含更多信息。相比之下,分类模型旨在将数据分为不同类别,这可能无法充分利用 EBL 中隐藏的信息。

然而,既往研究指出手术中的 EBL 存在不准确性,且缺乏标准化评估方法^[35]。因此,临床记录中报告的 EBL 精度可能无法满足回归模型的要求。

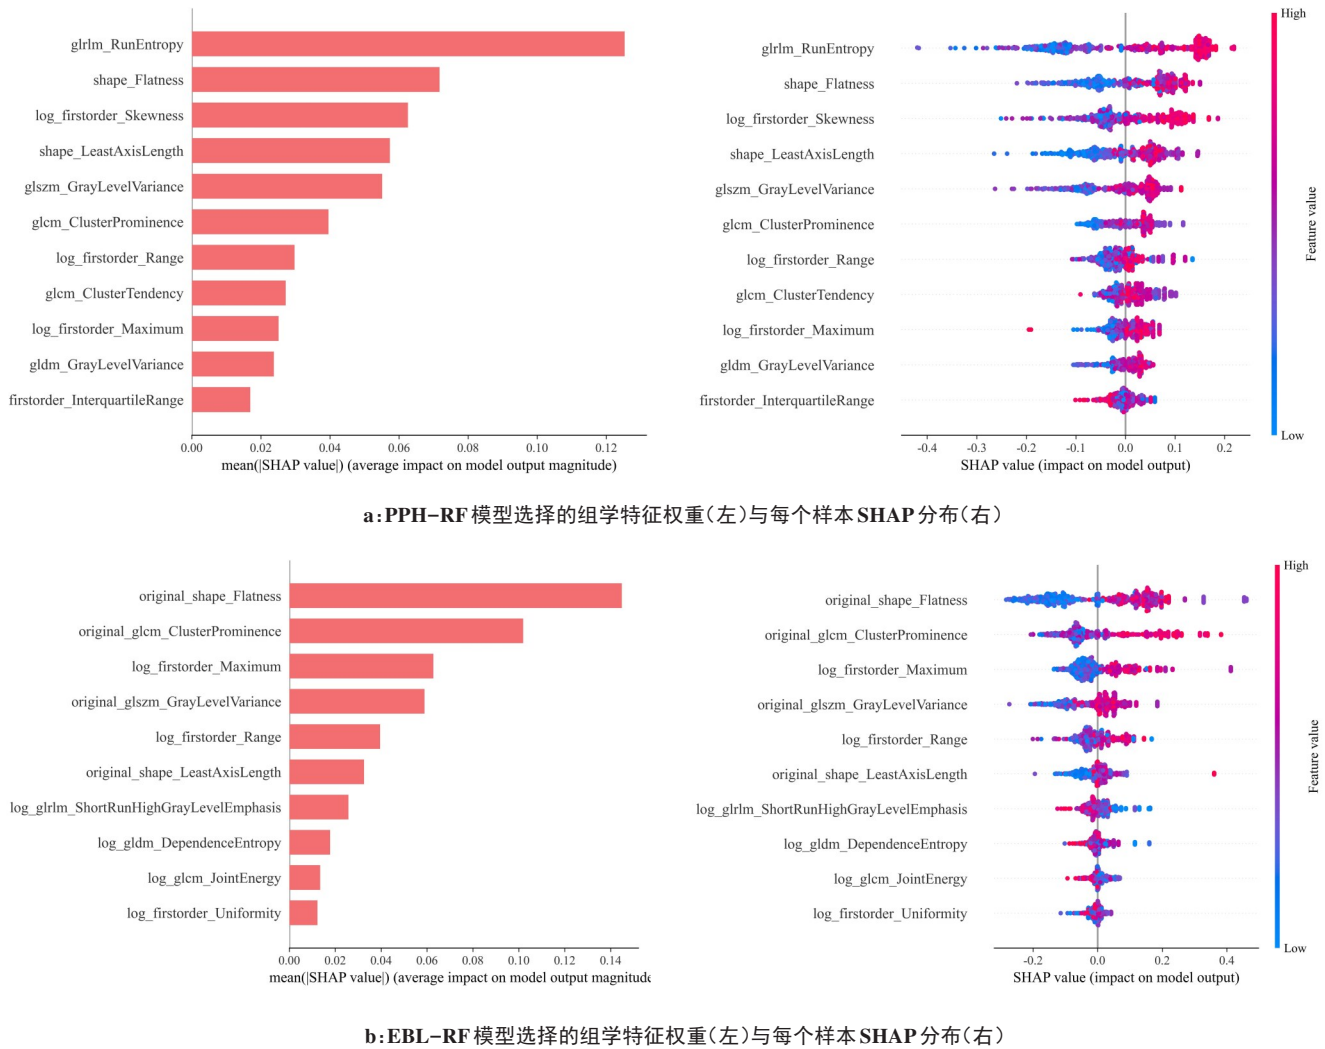


图 5 影像组学 SHAP 分析结果
Figure 5 SHAP analysis in the radiomics model

为更好预测 PPH,通过联合分类与回归任务整合两者优势,同时训练回归和分类任务的模型。根据 Grad-CAM 结果,分类模型聚焦于决策边界,而回归模型则对这些边界之外的区域做出更大贡献。与单独使用回归模型相比,加入分类任务提高了影像组学和深度学习模型的稳健性和泛化能力。此外,已有研究已确认胎盘前置是 PPH 的独立预测因子^[20-21]。通过增加 PP 分类任务,引导网络关注胎盘位置,为 EBL 预测提供额外的空间信息支持。

在本研究中,影像组学模型整体表现优于深度学习模型,这可能源于本研究所用数据集规模相对较小。影像组学模型通过人工设计特征从胎盘 VOI 中提取特征,而深度学习则自动从整个影像中提取特征,因此对于有限的数据集,深度学习模型可能更敏感。通过将影像组学评分与深度学习评分整合至 DRE 模型,实现了两种技术优势的协同效应。与既往单一依赖影像组学或深度学习的研究^[13, 20-21, 25]相

比,本研究采用更大规模的训练集,并展现出更优的预测性能。更重要的是,DRE 模型融合了影像组学的可解释性与特征提取优势,以及深度学习在复杂模式识别与预测性能上的强项,最终实现更稳健的预测效能。

本研究也存在一些局限性。首先,仅使用 T₂WI 数据可能限制模型性能。已有研究表明,结合影像、临床和医师诊断的多模态深度学习方法可以带来更好的结果^[36];其次,外部测试集较小且扫描设备不一致,未来需更大规模的多中心数据集进行验证,并分析不同成像系统对模型性能的影响。最后,本文数据集包含了 PAS 和非 PAS 患者。尽管 PAS 与 PPH 和并发症密切相关,但并非所有 PPH 病例都仅由 PAS 引起。

5 结论

本研究提出的自动化 DRE 模型整合了影像组学与深度学习的优势,能够基于产前 MRI 无创识别

PPH高风险个体,可以为产前确定高风险产妇并设计合理的临床决策提供重要支持。

【参考文献】

- [1] Green L, Knight M, Seeney FM, et al. The epidemiology and outcomes of women with postpartum haemorrhage requiring massive transfusion with eight or more units of red cells: a national cross-sectional study[J]. *BJOG*, 2016, 123(13): 2164-2170.
- [2] Gatta LA, Lockhart EL, James AH. Blood products in the management of abnormal placentation [J]. *Clin Obstet Gynecol*, 2018, 61(4): 828-840.
- [3] Nyflot LT, Sandven I, Stray-Pedersen B, et al. Risk factors for severe postpartum hemorrhage: a case-control study[J]. *BMC Pregnancy Childbirth*, 2017, 17(1): 17.
- [4] Sentilhes L, Kayem G, Chandraran E, et al. FIGO consensus guidelines on placenta accreta spectrum disorders: conservative management[J]. *Int J Gynaecol Obstet*, 2018, 140(3): 291-298.
- [5] Morlando M, Sarno L, Napolitano R, et al. Placenta accreta: incidence and risk factors in an area with a particularly high rate of cesarean section[J]. *Acta Obstet Gynecol Scand*, 2013, 92(4): 457-460.
- [6] Jauniaux E, Chantraine F, Silver RM, et al. FIGO consensus guidelines on placenta accreta spectrum disorders: Epidemiology [J]. *Int J Gynaecol Obstet*, 2018, 140(3): 265-273.
- [7] Li P, Tang YB, Jiang YR, et al. Analysis of clinical features of 231 cases with pernicious placenta previa: a retrospective cohort study[J]. *Medicine (Baltimore)*, 2021, 100(11): e25023.
- [8] Jauniaux E, Bhide A. Prenatal ultrasound diagnosis and outcome of placenta previa accreta after cesarean delivery: a systematic review and meta-analysis[J]. *Am J Obstet Gynecol*, 2017, 217(1): 27-36.
- [9] Chu CT, Liu M, Zhang YZ, et al. Quantifying magnetic resonance imaging features to classify placenta accreta spectrum (PAS) in high-risk gravid patients[J]. *Clin Imaging*, 2021, 80: 50-57.
- [10] Fitzpatrick KE, Sellers S, Spark P, et al. The management and outcomes of placenta accreta, increta, and percreta in the UK: a population-based descriptive study[J]. *BJOG*, 2014, 121(1): 62-71.
- [11] Shamshirsaz AA, Fox KA, Salmanian B, et al. Maternal morbidity in patients with morbidly adherent placenta treated with and without a standardized multidisciplinary approach[J]. *Am J Obstet Gynecol*, 2015, 212(2): 218.e1-218.e9.
- [12] Jauniaux E, Collins S, Burton GJ. Placenta accreta spectrum: pathophysiology and evidence-based anatomy for prenatal ultrasound imaging[J]. *Am J Obstet Gynecol*, 2018, 218(1): 75-87.
- [13] Wu QX, Yao K, Liu ZY, et al. Radiomics analysis of placenta on T₂WI facilitates prediction of postpartum haemorrhage: a multicentre study [J]. *EBioMedicine*, 2019, 50: 355-365.
- [14] Zaidi SF, Moshiri M, Osman S, et al. Comprehensive imaging review of abnormalities of the placenta[J]. *Ultrasound Q*, 2016, 32(1): 25-42.
- [15] Bulas D, Egloff A. Benefits and risks of MRI in pregnancy[J]. *Semin Perinatol*, 2013, 37(5): 301-304.
- [16] Lax A, Prince MR, Mennitt KW, et al. The value of specific MRI features in the evaluation of suspected placental invasion[J]. *Magn Reson Imaging*, 2007, 25(1): 87-93.
- [17] Zaghaf AA, Hussain HK, Berjawi GA. MRI evaluation of the placenta from normal variants to abnormalities of implantation and malignancies[J]. *J Magn Reson Imaging*, 2019, 50(6): 1702-1717.
- [18] Sun HQ, Qu HB, Chen L, et al. Identification of suspicious invasive placentation based on clinical MRI data using textural features and automated machine learning[J]. *Eur Radiol*, 2019, 29(11): 6152-6162.
- [19] Do QN, Lewis MA, Xi Y, et al. MRI of the placenta accreta spectrum (PAS) disorder: radiomics analysis correlates with surgical and pathological outcome [J]. *J Magn Reson Imaging*, 2020, 51(3): 936-946.
- [20] Akazawa M, Hashimoto K. A multimodal deep learning model for predicting severe hemorrhage in placenta previa[J]. *Sci Rep*, 2023, 13(1): 17320.
- [21] Zhang Y, Hu MD, Wen XH, et al. MRI-based radiomics nomogram in patients with high-risk placenta accreta spectrum: can it aid in the prenatal diagnosis of intraoperative blood loss? [J]. *Abdom Radiol (NY)*, 2023, 48(3): 1107-1118.
- [22] Qiu SR, Miller MI, Joshi PS, et al. Multimodal deep learning for Alzheimer's disease dementia assessment[J]. *Nat Commun*, 2022, 13(1): 3404.
- [23] Artzi M, Redmard E, Tzemach O, et al. Classification of pediatric posterior fossa tumors using convolutional neural network and tabular data[J]. *IEEE Access*, 2021, 9: 91966-91973.
- [24] Gillies RJ, Kinahan PE, Hricak H. Radiomics: images are more than pictures, they are data[J]. *Radiology*, 2016, 278(2): 563-577.
- [25] Lu YL, Zhou LP, Wang XY, et al. Magnetic resonance imaging-based radiomics nomogram to predict intraoperative hemorrhage of placenta previa[J]. *Am J Perinatol*, 2024, 41(S01): e2174-e2183.
- [26] Gu WC, Chen YL, Zhu HB, et al. Development and validation of CT-based radiomics deep learning signatures to predict lymph node metastasis in non-functional pancreatic neuroendocrine tumors: a multicohort study[J]. *EClinicalMedicine*, 2023, 65: 102269.
- [27] Li MS, Fan YH, You HY, et al. Dual-energy CT deep learning radiomics to predict macrotrabecular-massive hepatocellular carcinoma [J]. *Radiology*, 2023, 308(2): e230255.
- [28] Zuiderveld K. Contrast limited adaptive histogram equalization[C]// *Graphics Gems IV*. USA: Academic Press Professional, Inc., 1994: 474-485.
- [29] Isensee F, Wald T, Ulrich C, et al. nnU-Net revisited: a call for rigorous validation in 3D medical image segmentation[EB/OL]. (2024-07-25). <https://arxiv.org/abs/2404.09556>.
- [30] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 2261-2269.
- [31] Selvaraju RR, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[J]. *Int J Comput Vis*, 2020, 128(2): 336-359.
- [32] Zwanenburg A, Vallières M, Abdalah MA, et al. The image biomarker standardization initiative: standardized quantitative radiomics for high-throughput image-based phenotyping [J]. *Radiology*, 2020, 295(2): 328-338.
- [33] Lundberg SM, Erion G, Chen H, et al. from local explanations to global understanding with explainable AI for trees[J]. *Nat Mach Intell*, 2020, 2(1): 56-67.
- [34] Cardoso MJ, Li WQ, Brown R, et al. MONAI: an open-source framework for deep learning in healthcare[EB/OL]. (2022-11-04). <https://arxiv.org/abs/2211.02701>.
- [35] Wang T, Li H, Liu Y, et al. Quantitative blood loss measurement methods for early detection of primary postpartum haemorrhage following vaginal birth: a scoping review[J]. *J Clin Nurs*, 2024, 33(10): 3869-3885.
- [36] Xu X, Li JQ, Zhu ZC, et al. A comprehensive review on synergy of multi-modal data and AI technologies in medical diagnosis [J]. *Bioengineering (Basel)*, 2024, 11(3): 219.

(编辑:薛泽玲)