

基于增强 CT 深度学习特征与临床因素构建机器学习模型术前预测胃癌脉管侵犯

杨超帆, 潘霖, 甄思雨, 杨鑫森, 杨紫晴, 梁长华

【摘要】 目的:探讨基于增强 CT 深度学习特征与临床指标构建的机器学习模型术前预测胃癌脉管侵犯(LVI)的临床价值。方法:回顾性分析 2018 年 7 月—2024 年 5 月在本院经病理证实的 225 例胃癌患者的临床和影像资料,所有患者行腹部平扫及双期(动、静脉期)增强扫描。根据病理检测的 LVI 状态,将患者分为 LVI 阳性组($n=139$)和 LVI 阴性组($n=86$)。按 7:3 的比例将总样本随机分为训练集($n=157$)和测试集($n=68$)。采用多因素 logistic 回归分析从临床资料和影像特征中筛选胃癌 LVI 的独立预测因子。基于静脉期 CT 增强图像利用深度学习提取特征,采用最大相关最小冗余(mRMR)和最小绝对收缩选择算子(LASSO)进行特征降维和筛选,并分别建立深度学习评分。然后,基于逻辑回归机器学习算法分别构建 ResNet18、ResNet50 和 ResNet101 模型。采用 ROC 曲线评估各模型对胃癌 LVI 状态的预测效能,模型间 AUC 的比较采用 DeLong 检验。基于效能最佳模型中的深度学习评分和临床独立危险因素,采用逻辑回归分析构建联合模型,并采用校准曲线分析联合模型的拟合优度。结果:多因素 Logistic 回归分析显示 CT 评估的淋巴结转移状态($OR=8.814, 95\%CI:4.178\sim 18.595, P<0.001$)和 CT-T 分期($OR=1.582, 95\%CI:1.022\sim 2.448, P=0.039$)是 LVI 的独立危险因素。ResNet18、ResNet50 和 ResNet101 模型在训练集中的 AUC 分别为 0.765、0.898 和 0.867,在测试集中分别为 0.748、0.791 和 0.748。ResNet50 模型在测试集中的 AUC 最高,综合效能最优,为最佳模型。ResNet50 模型的深度学习评分结合临床独立危险因素构建的联合模型在训练集和测试集中的 AUC 分别提升至 0.962 和 0.899。校准曲线显示联合模型在训练集及测试集中均具有较好的拟合度。结论:ResNet50 模型术前预测胃癌脉管侵犯的效能最佳,将其联合 CT 评估的淋巴结转移状态和 CT-T 分期构建的联合模型能进一步提高预测效能。

【关键词】 胃肿瘤;体层摄影术,X 线计算机;脉管侵犯;深度学习

【中图分类号】 R814.42;R735.2 **【文献标志码】** A **【文章编号】** 1000-0313(2026)04-0429-06

DOI:10.13609/j.cnki.1000-0313.2026.04.012

开放科学(资源服务)标识码(OSID):



Value of a machine learning model based on deep learning features extracted from contrast-enhanced CT and clinical factors in preoperative prediction of lymphovascular invasion of gastric cancer YANG Chao-fan, PAN Ben, ZHEN Si-yu, et al. Department of Radiology, the First Affiliated Hospital of Xinxiang Medical University, Henan 453100, China

【Abstract】 Objective: To investigate the clinical value of a machine learning model integrating deep learning features based on contrast-enhanced CT and clinical indicators for preoperative prediction of lymphovascular invasion (LVI) in gastric cancer. **Methods:** A retrospective analysis was performed on 225 pathologically confirmed gastric cancer patients in our hospital from July 2018 to May 2024. All patients underwent plain scan and dual-phase (arterial and venous) CECT scans. According to pathological LVI status, patients were stratified into LVI-positive group ($n=139$) and LVI-negative group ($n=86$). The total sample was randomly divided into a training set ($n=157$) and a test set ($n=68$) at a ratio of 7:3. Multivariate logistic regression was used to identify independent predictors of LVI from clinical data and imaging features. Deep learning features were extracted from venous-phase contrast-enhanced CT images, followed by feature reduction using maximum relevance minimum redundancy (mRMR) and least absolute shrinkage and selection operator (LASSO), and deep learning scores were established, respectively. Subsequently, features extracted by ResNet18, ResNet50, and ResNet101 were respectively used to build classifiers based on logistic regression algorithm. The predictive performance of each model was evaluated by ROC curve. The AUC of the models were compared using DeLong test. A combined model was constructed using logistic regression analysis based on the deep learning score from the optimal model and clinical independent risk factors. The deep learning features selected from the best-performing model were then integrated with independent clinical risk factors to build a combined model using logistic regression. Calibration curve was used to assess the goodness-of-fit of the combined model. **Results:** Multivariate logistic regression analysis revealed that CT-assessed lymph node metastasis status ($OR=8.814, 95\%CI:4.178\sim 18.595, P<0.001$) and CT-T stage ($OR=1.582, 95\%CI:1.022\sim 2.448, P=0.039$) were independent clinical risk factors. The AUCs of ResNet18, ResNet50 and ResNet101 models were 0.765, 0.898 and 0.867 in the

作者单位:453100 河南新乡,新乡医学院第一附属医院放射科(杨超帆、潘霖、甄思雨、杨鑫森、杨紫晴、梁长华);450018 河南郑州,河南省慢病防治与智慧健康管理重点实验室(杨超帆、梁长华)

作者简介:杨超帆(1998—),男,河南新乡人,硕士研究生,主要从事研胸腹部肿瘤及肺部感染性疾病的影像诊断工作。

通讯作者:梁长华, E-mail: liangchanghua12345@163.com

基金项目:河南省慢病防治与智慧健康管理重点实验室 2024 年度开放基金课题(ZYYC2024MB)

training set, and 0.748, 0.791 and 0.748 in the test set, respectively. ResNet50 model achieved the highest AUC in the test set with optimal comprehensive performance, thus was selected as the optimal model. The combined model, constructed by integrating the deep learning score of the ResNet50 model with clinical independent risk factors, achieved AUC values of 0.962 and 0.899 in the training and test sets, respectively. The calibration curve indicated good calibration of the combined model in both training and test sets. **Conclusion:** The ResNet50 model demonstrates optimal efficacy for pre-operative prediction of LVI in gastric cancer. The combined model integrating the ResNet50-selected features with CT-assessed lymph node metastasis status and CT-T stage can further improve the predictive efficacy.

【Key words】 Gastric neoplasm; Tomography, X-Ray computed; Lymphovascular invasion; Deep learning

在全球恶性肿瘤中,胃癌发病率位列第五,致死率居于第三^[1]。随着病程进展,肿瘤细胞可通过侵袭血管及淋巴系统引发转移扩散,其中脉管侵犯(lymphovascular invasion, LVI)在肿瘤演进中具有关键作用^[2-3]。LVI是胃癌的独立预后因素,与术后复发转移风险显著相关,可为临床手术范围优化和辅助治疗决策提供关键的病理依据^[4-8]。目前诊断LVI的金标准为术后肿瘤组织病理检查,但其结果具有滞后性,难以满足术前精准干预的需求。因此,开发一种能在术前无创性评估胃癌LVI状态的成像技术以优化个体化治疗策略已成为临床研究的重点。

深度学习技术的发展驱动医工交叉,助力肿瘤影像分割、分型及预后评估^[9-11]。不同于依赖手动特征提取的传统影像组学分析方法,深度学习技术可直接从图像中自动学习信息特征,进一步揭示图像与临床问题之间的高维关系^[12]。深度迁移学习(deep transfer learning, DTL)通过迁移预训练知识至医学领域,提升了小样本的泛化性能^[13-14]。本研究基于静脉期增强CT图像,通过DTL提取深度学习特征构建预测模型,通过多模型比较,探讨基于深度学习评分联合临床独立危险因素构建的联合模型术前预测胃癌LVI的临床价值。

材料与方法

1. 研究对象

回顾性将2018年7月—2024年5月在本院确诊的225例胃癌患者纳入本研究。纳入标准:①接受根治性手术切除术;②术后病理证实为胃癌,并且有明确的脉管侵犯(LVI)病理结果;③术前2周内行腹部CT增强扫描。排除标准:①术前接受了放疗、化疗等抗肿瘤治疗;②病灶较小或图像质量差,无法满足评估要求;③临床病理资料不完整。最终共纳入了符合研究要求的225例胃癌患者,男178例、女47例。

本研究经本院伦理委员会批准(EC-025-379),检查前患者均知情同意。

2. CT检查方法

使用GE Revolution CT、Somatom Force或Toshiba Aquilion ONE CT扫描仪。常规行腹部CT

平扫和双期增强扫描,扫描参数:120 kVp, 375 mAs, 螺距 1.375, 矩阵 512×512, 探测器宽度 80.0、57.6 或 40.0 mm, 准直器宽度 0.625 mm×128、0.600 mm×96 或 0.500 mm×80。采用 5.00 mm 层厚扫描后行 1.25 mm 薄层重建。增强扫描前经肘静脉以 3.5 mL/s 的流率注射碘佛醇注射液(320 mgI/mL), 剂量 1.5 mL/kg, 延迟 30 和 70 s 分别采集动脉期和静脉期图像。

3. 临床及 CT 观察指标

搜集和记录患者的临床资料,包括年龄、性别、癌胚抗原(carcinoembryonic antigen, CEA)、糖类抗原 125(carcinoembryonic antigen 125, CA125)和 CA199。基于CT图像评估肿瘤的形态学特征,主要包括位置(贲门、胃体和胃窦),淋巴结转移状态(若胃周淋巴结短轴直径超过 10 mm;或无论淋巴结大小,淋巴结出现坏死和强化不均、纵径与横径之比小于 1.5 和呈簇状/聚集分布等征象时,均评估为 cN+)和原发肿瘤 T 分期(CT-T 分期);CT 定量分析基于横轴面图像中肿瘤最大横截面所在层面,测量肿瘤的厚度、长度及增强 CT 值(平扫、动脉期、静脉期),所有定量指标经 3 次测量后取平均值。

4. 深度学习模型的构建

将患者静脉期 CT 图像导入 ITK-SNAP 4.0 医学影像分析软件(<http://www.itksnap.org>)。由 1 位具有 5 年诊断经验的放射科医师 A 在静脉期图像中选取肿瘤最大层面,沿肿瘤轮廓手动勾画 ROI,并由另 1 位具有 10 年工作经验的放射科医师 B 确认并校正。本研究基于 Python 3.6 环境下的 TensorFlow 2.5.0 深度学习框架(<https://www.tensorflow.org>),可基于 ResNet18、ResNet50 及 ResNet101 三种不同深度的残差神经网络模型进行运算,它们分别包含 18、50 和 101 个可训练权重层的深度网络结构。针对医学影像数据量有限的特点,引入迁移学习方法:首先加载包含 128 万帧图像的 ImageNet 数据集对权重初始化网络参数进行预训练,通过冻结除顶层卷积层外的所有预训练参数而保留通用特征,仅微调网络深层及新构建的任务特定分类层,在目标领域数据中实现模型适应性优化,既利用预训练模型的强大特征表示能力,又

通过有限数据调整高层语义空间以适配下游任务。数据预处理阶段,对静脉期 CT 图像肿瘤最大层面 ROI 区域进行空间标准化处理至 224×224 矩阵中并归一化,通过通道复制,将单通道灰度图像转换为三通道输入,以适配预训练模型的结构要求。网络架构优化方面,移除原始 ResNet 末端的全连接层 (fully connected layer),通过深度卷积网络逐层提取特征,最终在最后一个卷积块输出三维特征图,沿空间维度执行两次全局最大池化 (global maximum pooling),分别生成 512 维 (ResNet18)、2048 维 (ResNet50) 和 2048 维 (ResNet101) 特征向量,每个特征值代表通道内空间域的最大响应强度。

1 个月后随机选择 30 例患者的图像,由医师 A 再次进行 ROI 的勾画和深度学习特征的提取,采用组内相关系数 (intra-class correlation coefficient, ICC) 评价深度学习特征的观察者内一致性,保留 ICC > 0.75 的特征。进行 Z-score 标准化并采用最大相关最小冗余 (maximum relevance and minimum redundancy, mRMR) 和最小绝对收缩选择算子 (least absolute shrinkage and selection operator, LASSO) 方法,通过 10 折交叉验证进行特征筛选。基于 Logistic 回归分别构建 ResNet18、ResNet50 和 ResNet101 预测模型,对 3 种模型的预测效能进行比较,得到效能最佳的模型,再结合临床独立危险因素构建联合模型并绘制其列线图。

5. 统计学分析

使用 SPSS 27.0、Python 3.6 和 R4.3.0 软件完成统计分析。符合正态分布的连续变量以均数±标准差表示,采用独立样本 *t* 检验进行组间比较;非正态分布的连续变量以 M(Q1, Q3) 描述,组间比较采用 Mann-Whitney *U* 检验;分类变量采用 χ^2 检验或 Fisher 精确概率法评估组间差异。采用 ROC 曲线分析评估各模型诊断胃癌 LVI 的效能,并采用 DeLong 检验对各模型的 AUC 进行比较,采用校准曲线检验联合模型的校准度。基于 R 语言环境实现以下分析:采用 glmnet 包执行 LASSO 回归进行特征降维,通过 pROC 包生成 ROC 曲线,利用 ResourceSelection 软件包进行 Hosmer-Lemeshow (HL) 拟合优度检验。以 $P < 0.05$ 为差异有统计学意义。

结果

1. 临床资料及 CT 表现分析

LVI 阳性组与阴性组之间临床资料和常规 CT 征象的比较结果见表 1。统计分析结果显示:Lauren 分型、CT-N、CT-T 分期、肿瘤长度和肿瘤静脉期 CT 值在两组间的差异均有统计学意义 ($P < 0.05$)。

将组间差异有统计学意义的指标纳入多因素 Logistic 回归分析,结果显示 CT 评估的淋巴结转移状态 (CT-N) 和 CT-T 分期是预测胃癌 LVI 的临床独立危险因素 (P 均 < 0.05),详见表 2。

表 1 两组患者临床资料和常规 CT 征象的比较

指标	LVI 阴性组 (n=86)	LVI 阳性组 (n=139)	统计量	P 值
年龄/岁	63.01±8.51	64.65±8.66	-1.392 ^a	0.165
性别比(男/女)	69/17	109/30	0.106 ^b	0.745
Lauren 分型/例			19.958 ^b	<0.001
肠型	54	45		
弥漫型	15	43		
混合型	17	51		
肿瘤位置/例			0.695 ^b	0.706
贲门	50	76		
胃体	21	41		
胃窦	15	22		
CT-N+/例	38	126	58.037 ^b	<0.001
CT-T 分期/例			24.419 ^b	<0.001
T1	13	2		
T2	16	13		
T3	40	71		
T4	17	53		
CEA/ng/mL	2.80(1.48, 4.35)	2.73(1.67, 5.81)	-0.936 ^c	0.349
CA125/U/mL	10.17(7.44, 13.25)	10.63(7.53, 15.82)	-1.337 ^c	0.181
CA199/U/mL	10.62(6.59, 20.10)	12.20(6.71, 29.91)	-1.256 ^c	0.209
肿瘤厚度/mm	15.12(10.71, 17.62)	15.66(12.23, 18.75)	-1.504 ^c	0.133
肿瘤长度/mm	42.56(32.63, 60.18)	50.35(40.18, 65.32)	-2.909 ^c	0.004
CT 值平扫/HU	41.93±7.86	42.24±8.49	-0.273 ^a	0.785
CT 值动脉期/HU	68.82(59.06, 81.47)	70.84(60.46, 81.11)	-0.680 ^c	0.497
CT 值静脉期/HU	92.50(75.85, 105.40)	97.94(84.62, 116.83)	-2.066 ^c	0.039

注:^a 为 *t* 值,^b 为 χ^2 值,^c 为 Z 值。

2. 模型预测效能的比较

经特征筛选后, ResNet18、ResNet50 和 ResNet101 模型分别得到 9、24 和 20 个深度学习特征, 分别计算其深度学习评分并纳入逻辑回归构建预测模型。

3 个深度学习模型及联合模型的效能指标值详见表 3。ResNet50 模型的整体表现优于 ResNet18 模型和 ResNet101 模型(图 1)。测试集中, ResNet50 模型达到了最优的预测性能, AUC 为 0.791 (95% CI:

0.680~0.902), 高于 ResNet18 模型和 ResNet101 模型, 且符合率(0.750)和特异度(0.920)均较高, 在训练集和测试集中模型表现较稳定。ResNet101 模型过拟合现象较明显: 在训练集中的 AUC 为 0.867(95% CI: 0.809~0.925), 而在测试集中 AUC 下降至 0.748 (95% CI: 0.633~0.864), 降幅达 13.7%; 且特异度从训练集中的 0.722 降至测试集中的 0.656, 表明模型过度依赖训练数据, 模型泛化能力不足。而 ResNet18 模型因网络深度较浅, 特征提取能力受限, 其在测试集中的敏感度(0.535)与符合率(0.674)均低于 ResNet50 模型(分别为 0.651 和 0.750)。

将 ResNet50 模型的深度学习评分(DL-score)与 CT 评估的淋巴结转移状态和 CT-T 分期共同纳入逻辑回归, 构建联合模型, 其在测试集中的 AUC 提升至 0.899。校准曲线显示联合模型在训练集中预测胃癌 LVI 与实际 LVI 发生率之间具有较高的一致性; 在测试集中, 校准曲线在 0.4~0.8 概率区间存在一定波动, 但整体趋势仍保持良好的—致性; 整体而言, 联合模型在训练集中的校准表现优于测试集(图 2)。绘制联合模型的列线图(图 3)。DeLong 检验结果显示, 在训练集和测试集中, ResNet50 模型与联合模型之间 AUC 的差异均具有统计学意义($Z =$

表 2 多因素逻辑回归分析结果

自变量	回归系数	标准误	Wald χ^2 值	OR(95%CI)	P 值
CT-N	2.176	0.381	32.645	8.814(4.178~18.595)	<0.001
CT-T 分期	0.459	0.223	4.241	1.582(1.022~2.448)	0.039

表 3 不同模型在训练集与测试集中的预测效能

模型类型	AUC(95%CI)	符合率	敏感度	特异度
ResNet18 模型				
训练集	0.765(0.688~0.842)	0.720	0.698	0.754
测试集	0.748(0.625~0.871)	0.674	0.535	0.920
ResNet50 模型				
训练集	0.898(0.850~0.946)	0.841	0.813	0.885
测试集	0.791(0.680~0.902)	0.750	0.651	0.920
ResNet101 模型				
训练集	0.867(0.809~0.925)	0.854	0.922	0.722
测试集	0.748(0.633~0.864)	0.706	0.750	0.656
联合模型				
训练集	0.962(0.934~0.990)	0.917	0.927	0.902
测试集	0.899(0.828~0.969)	0.809	0.767	0.880

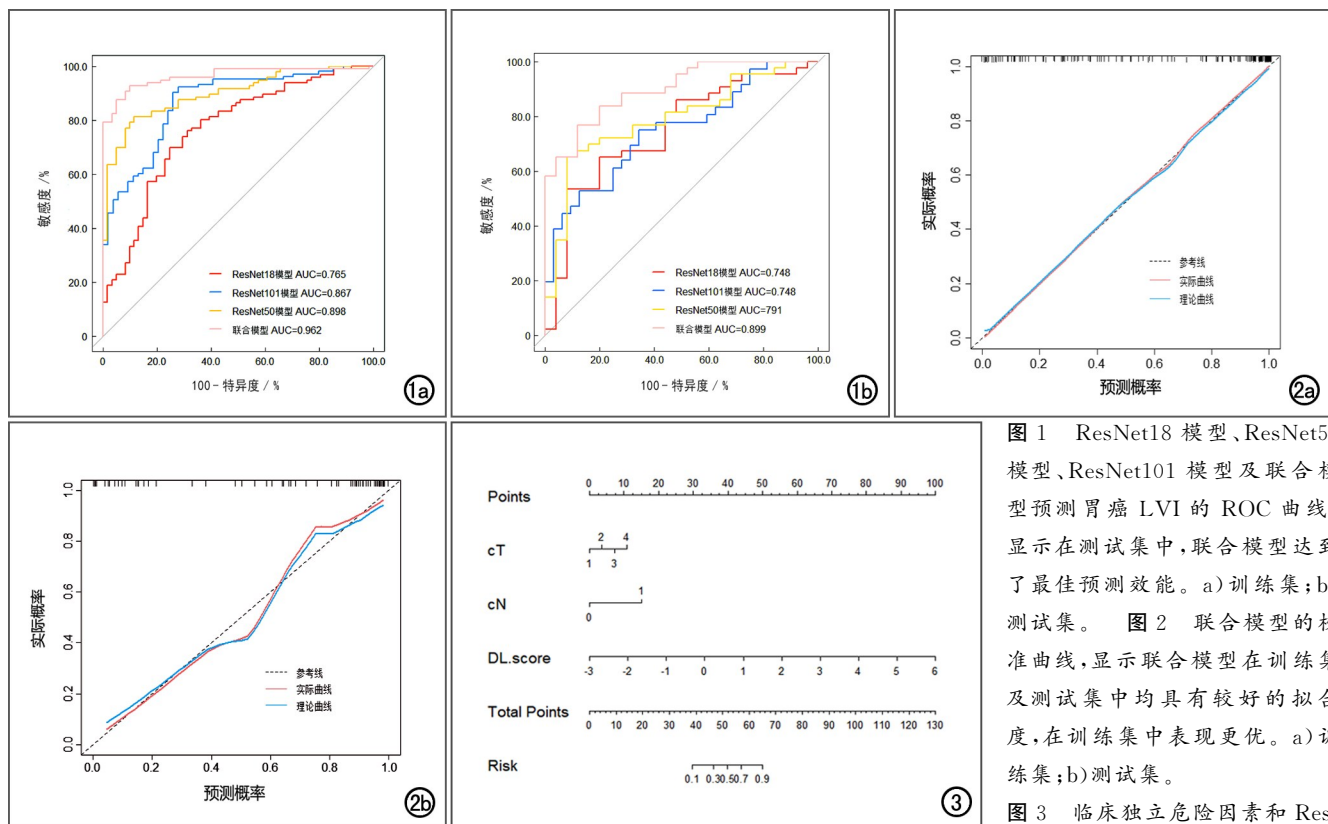


图 1 ResNet18 模型、ResNet50 模型、ResNet101 模型及联合模型预测胃癌 LVI 的 ROC 曲线, 显示在测试集中, 联合模型达到了最佳预测效能。a) 训练集; b) 测试集。图 2 联合模型的校准曲线, 显示联合模型在训练集及测试集中均具有较好的拟合度, 在训练集中表现更优。a) 训练集; b) 测试集。

Net50 模型的深度学习评分(DL-score)构建的联合模型预测胃癌 LVI 的列线图。

-3.164, $P=0.002$; $Z=-2.607$, $P=0.009$ 。

讨论

本研究通过系统评估不同深度 ResNet 模型在胃癌 LVI 术前预测中的效能,发现 ResNet50 模型在测试集中展现出最优的综合预测能力,其 AUC 达 0.791, 高于 ResNet18 模型 (0.748) 与 ResNet101 模型 (0.748)。通过将 ResNet50 模型的深度学习评分与临床独立危险因素结合构建的联合模型测试集 AUC 提升至 0.899, 提示联合深度学习特征和临床独立危险因素能够有效提升 LVI 预测效能,为术前精准评估提供重要依据。

肿瘤 T 分期与浸润深度密切相关,随着 T 分期进展,肿瘤突破肌层侵犯浆膜层的风险显著增加,同时 LVI 发生率也上升。深浸润性胃癌病灶呈现病理性血管增生,其异常增生的微血管网络可能通过重塑肿瘤微环境,促进癌细胞的侵袭性生长与转移潜能。本研究通过多因素逻辑回归分析发现,CT 评估淋巴结转移状态与 CT-T 分期可作为胃癌 LVI 的临床独立危险因素,该结论与既往文献的研究结果基本一致^[15-16]。肿瘤淋巴结转移数目越多、浸润程度越深,发生 LVI 的可能性越大。为了更有效地评估发生 LVI 的风险,本研究建立的联合模型在测试集的表现 (AUC = 0.899) 优于梁盼等^[17]的机器学习模型 (AUC = 0.877) 及 Zhen 等^[18]的临床-影像组学模型 (AUC = 0.742)。传统方法的局限性可能源于两方面:其一,人工勾画 ROI 的手工特征提取流程依赖操作者主观经验,存在效率低、可重复性差及系统性偏倚风险;其二,传统影像组学特征多局限于肿瘤形态学(如体积、形状)及纹理特征(如灰度共生矩阵)的表征,难以有效解析肿瘤微环境异质性等高维生物学信息,导致模型泛化能力受限,而深度学习通过自动提取高维数据深层抽象特征,有效提升了预测模型的可靠性及泛化性能。既往研究证实 IVIM-DWI 通过定量参数无创量化肿瘤细胞密度和微循环灌注状态^[19],而生境影像组学通过划分不同亚区解析肿瘤空间异质性^[20],两者在胃癌生物学评估中应用日益增多;未来影像组学可通过数据融合(如高维特征、功能成像及异质性分析)构建多模态预测模型,为胃癌个体化治疗提供支持。

目前,已有研究中采用深度学习技术构建肿瘤 LVI 预测模型,实现术前无创评估^[21-23]。Kang 等^[21]通过整合多模态数据(内镜、病理、CT 及临床信息),构建基于 Transformer 的深度学习模型来预测早期胃癌淋巴结转移和淋巴血管侵犯,其 AUC 达 0.91, 优于传统单模态模型(基于内镜图像的 CNN 模型, AUC = 0.59)及随机森林多模态模型 (AUC = 0.75),

但该研究中未与临床医师诊断效能进行对比,需进一步验证人工智能辅助决策的实际价值。Shi 等^[22]基于多参数 MRI(T₂WI+DWI)构建双模态深度学习模型 (ResNet-18),进一步联合临床特征构建联合模型,在多中心 489 例直肠癌患者中实现 LVI 术前精准预测,其联合模型内部验证集与外部测试集 AUC 分别达 0.899 和 0.848, 优于单模态模型。该研究存在以下局限性:首先,采用的 ResNet-18 网络架构较浅,特征抽象能力有限,可能影响肿瘤异质性等高阶特征的充分提取;其次,该研究排除了新辅助治疗患者群体,可能导致模型泛化性能在临床应用中受限。袁权等^[23]基于直肠癌患者 T₂WI 图像,提取深度迁移学习特征 (ResNet-34) 和传统影像组学特征,并构建机器学习模型术前预测脉管浸润 (LVI),结果表明在验证集中基于组合特征的自适应增强 (adaptive boosting, AdaBoost) 模型的效能最高 (AUC = 0.924), 其预测效能高于本研究中采用的 logistic 回归分析构建的模型。

理论上,更深层的 ResNet101 (101 层) 应具有更强的非线性特征提取能力,但本研究结果显示此方法构建的深度学习模型在胃癌 LVI 预测任务中,在测试集中的预测效能低于 ResNet50 (Δ AUC = -0.043)。这是由于 ResNet101 模型的深度和复杂度较高,参数量较大,需要更多的训练数据,而本研究中训练数据集样本量较小、标注有限 ($n=157$),致使深度网络的架构潜力未能转化为实际诊断增益,模型判别效能衰减。本研究中呈现的这一现象与文献结论相符,即 ResNet 模型预测精度随层数增加而提升,但超过 50 层时,因计算复杂度与过拟合风险增加,模型效能反而下降^[24-25]。ResNet18 虽参数量少、训练效率高,但因网络深度不足,特征提取能力受限,测试集灵敏度 (0.535) 与准确度 (0.674) 均低于 ResNet50,表现出欠拟合倾向。ResNet50 通过平衡模型复杂度与数据规模,在有限样本条件下实现较高的泛化性能,验证了中等复杂度模型在医学影像小数据场景中的适用性,成为胃癌脉管侵犯 (LVI) 术前无创预测的优选方案。该模型的临床转化路径具体表现为:作为 PACS 系统辅助诊断模块输出高精度 LVI 风险量化报告;同时纳入诊疗指南指导局部进展期胃癌新辅助治疗决策。该方案规避了浅层网络 (ResNet18) 的特征提取局限与深层网络 (ResNet101) 的过拟合风险,为医疗 AI 的临床转化提供可推广的范式,其核心突破取决于多中心验证中的模型泛化能力的提升。为了获得更高的预测准确性,本研究中将 ResNet50 模型的深度学习评分联合临床独立危险因素来构建联合模型,对模型的 AUC 进行评估和比较 (DeLong 检验),结果显示联合模型的预测效能较单纯的深度学习模型进一步提升 ($P<0.01$)。

本研究的局限性:①训练集的小样本规模可能限制深度学习模型对影像潜在特征的代表能力;②尽管引入迁移学习策略,但因跨域知识迁移的有限性,模型仍存在局部过拟合风险,泛化能力未达理论预期;③采用三维卷积网络架构在处理高维医学影像数据时因模型复杂度高导致可解释性分析存在技术瓶颈。

综上所述,本研究中通过联合 ResNet50 模型的深度学习评分与临床独立危险因素构建的联合模型有效提升了胃癌 LVI 预测的精准性和临床适用性,为术前个体化诊疗决策提供了可靠的理论依据和技术支持,填补了传统病理评估在术前无创预测中的局限性。

利益冲突:全体作者声明无利益冲突。

作者贡献:杨超帆查阅文献、研究设计和实施、统计分析、撰写文章;潘霖、甄思雨、杨鑫森、杨紫晴图像处理和数据分析;梁长华指导、修改和审阅文章。

参考文献:

- [1] Sung H, Ferlay J, Siegel RL, 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] Fujikawa H, Koumori K, Watanabe H, et al. The clinical significance of lymphovascular invasion in gastric cancer[J]. *In Vivo*, 2020, 34(3): 1533-1539.
- [3] Jiao X, Wang Y, Fu H, et al. Prognostic significance of lymphovascular invasion in pN0 stage gastric cancer: a propensity score matching analysis[J/OL]. *BMC Surg*, 2024, 24(1): e402[2024 Dec 21]. DOI: 10.1186/s12893-024-02705-8.
- [4] Zhang F, Chen H, Luo D, et al. Lymphovascular or perineural invasion is associated with lymph node metastasis and survival outcomes in patients with gastric cancer[J]. *Cancer Med*, 2023, 12(8): 9401-9408.
- [5] Sumiyoshi S, Ohashi T, Kubota T, et al. Lymphovascular invasion is associated with poor long-term outcomes in patients with pT1N0-3 or pT2-3N0 remnant gastric cancer: a retrospective cohort study[J/OL]. *World J Surg Oncol*, 2024, 22(1): e86[2024 Apr 5]. DOI: 10.1186/s12957-024-03371-z.
- [6] Meng Y, Huang X, Liu J, et al. A novel nomogram for individually predicting of vascular invasion in gastric cancer[J/OL]. *Technol Cancer Res Treat*, 2021, 20: e15330338211004924[2021 Jan-Dec]. DOI: 10.1177/15330338211004924.
- [7] Yang S, Zou X, Li J, et al. The application value of CE-MDCT in the diagnosis of gastric cancer extramural vascular invasion and its influencing factors[J/OL]. *J Health Eng*, 2022, 2022: e4239600[2022 Jan 7]. DOI: 10.1155/2022/4239600.
- [8] Choi S, Song J H, Lee S, et al. Lymphovascular invasion: traditional but vital and sensible prognostic factor in early gastric cancer[J]. *Ann Surg Oncol*, 2021, 28(13): 8928-8935.
- [9] Jiang Y, Zhang Z, Yuan Q, et al. Predicting peritoneal recurrence and disease-free survival from CT images in gastric cancer with multitask deep learning: a retrospective study[J]. *Lancet Digit Health*, 2022, 4(5): 340-350.
- [10] Cui Y, Zhang J, Li Z, et al. A CT-based deep learning radiomics nomogram for predicting the response to neoadjuvant chemotherapy in patients with locally advanced gastric cancer: a multi-center cohort study[J/OL]. *EClinical Medicine*, 2022, 46: e101348[2022 Mar 21]. DOI: 10.1016/j.eclinm.2022.101348.
- [11] Zhang K, Wang H, Cheng Y, et al. Early gastric cancer detection and lesion segmentation based on deep learning and gastroscopic images[J/OL]. *Sci Rep*, 2024, 14(1): e7847[2024 Apr 3]. DOI: 10.1038/s41598-024-58361-8.
- [12] Shi B, Grimm LJ, Mazurowski MA, et al. Prediction of occult invasive disease in ductal carcinoma in situ using deep learning features[J]. *J Am Coll Radiol*, 2018, 15(3 Pt B): 527-534.
- [13] Kim HE, Cosa-Linan A, Santhanam N, et al. Transfer learning for medical image classification: a literature review[J/OL]. *BMC Med Imaging*, 2022, 22(1): e69[2022 Apr 13]. DOI: 10.1186/s12880-022-00793-7.
- [14] 朱正群, 巩萍, 黄栋有, 等. 联合 CT 影像组学与深度学习特征建立列线图预测食管鳞癌放疗近期疗效[J]. *放射学实践*, 2024, 39(2): 233-238.
- [15] Zhou Y H, Liu Y, Zhang X, et al. Dual-phase contrast-enhanced CT-based intratumoral and peritumoral radiomics for preoperative prediction of lymphovascular invasion in gastric cancer[J/OL]. *BMC Med Imaging*, 2025, 25(1): e43[2025 Feb 10]. DOI: 10.1186/s12880-025-01569-5.
- [16] 范晓东, 陈小凤, 廖玉婷, 等. 基于增强 CT 影像组学评分和临床分期的列线图预测胃癌脉管浸润的价值[J]. *国际医学放射学杂志*, 2021, 44(6): 644-648.
- [17] 梁盼, 雍刘亮, 程铭, 等. 基于静脉期增强 CT 影像组学的机器学习模型术前预测局部进展期胃癌脉管侵犯[J]. *中华放射学杂志*, 2023, 57(5): 535-540.
- [18] Zhen SY, Wei Y, Song R, et al. Prediction of lymphovascular invasion of gastric cancer based on contrast-enhanced computed tomography radiomics[J/OL]. *Front Oncol*, 2024, 14: e1389278[2024 Sep 5]. DOI: 10.3389/fonc.2024.1389278.
- [19] 杨慧远, 曲金荣, 王艺, 等. IVIM-DWI 对可切除性胃癌脉管侵犯的预测价值[J]. *放射学实践*, 2024, 39(4): 503-508.
- [20] 任梦婷, 陈基明, 何昌杰, 等. 基于 CT 生境影像组学和深度学习模型预测进展期胃癌 HER2 表达状态的价值[J]. *放射学实践*, 2025, 40(4): 501-508.
- [21] Kang D, Jeon HJ, Kim JH, et al. Enhancing lymph node metastasis risk prediction in early gastric cancer through the integration of endoscopic images and real-world data in a multimodal AI model[J/OL]. *Cancers (Basel)*, 2025, 17(5): e869[2025 Mar 3]. DOI: 10.3390/cancers17050869.
- [22] Shi S, Singh A, Ma J, et al. Development and validation of a multi-parametric MRI deep-learning model for preoperative lymphovascular invasion evaluation in rectal cancer[J]. *Quant Imaging Med Surg*, 2025, 15(1): 427-439.
- [23] 袁权, 吴树剑, 范莉芳, 等. 基于 MRI 深度迁移学习影像组学术前预测直肠癌脉管浸润的研究[J]. *磁共振成像*, 2025, 16(1): 54-60.
- [24] 王丹丹, 王海波, 孙中琪, 等. 术前 CT 图像影像组学联合深度学习预测肝细胞癌经动脉化疗栓塞术后疗效的价值[J]. *中华放射学杂志*, 2024, 58(2): 209-215.
- [25] Korfiatis P, Kline TL, Lachance DH, et al. Residual deep convolutional neural network predicts MGMT methylation status[J]. *J Digit Imaging*, 2017, 30(5): 622-628.