

# 基于CT的影像组学模型用于预测胃癌生存预后

安静怡, 靳春昊, 毛涛\*

青岛大学附属医院消化内科, 山东 青岛

收稿日期: 2026年3月21日; 录用日期: 2026年4月16日; 发布日期: 2026年4月22日

## 摘要

目的: 胃癌(gastric cancer, GC)仍是我国的主要死亡原因之一。本研究的目的是建立基于计算机断层扫描图像(computed tomography, CT)的影像组学模型结合临床特征来预测胃癌术后患者总生存期(overall survival, OS)。方法: 本研究回顾性纳入2015年1月至2020年12月青岛大学附属医院确诊GC并接受手术治疗的117例患者, 按7:3随机分为训练集与验证集。收集患者临床资料及术前腹部CT图像, 经GAN重建预处理后勾画感兴趣区域, 提取放射组学特征并LASSO回归筛选, 分别构建影像组学模型、临床风险模型及综合模型。采用C-index、Kaplan-Meier生存分析等评估模型效能。结果: 影像组学模型预测效能最优, 在验证集中C-index为0.758, 优于临床预测模型(0.703)及综合模型(0.739)。Kaplan-Meier分析显示, 各模型高低风险组OS差异均有统计学意义( $P < 0.05$ )。同时, Cox多因素分析证实, 淋巴血管浸润是OS的独立危险因素。结论: 基于术前CT的影像组学模型可有效、无创预测GC患者术后OS, 为临床预后评估及个体化治疗提供重要参考。

## 关键词

影像组学, 胃癌, 总生存期, 计算机断层扫描

# CT-Based Radiomics Model for Predicting Gastric Cancer Survival Prognosis

Jingyi An, Chunhao Jin, Tao Mao\*

Department of Gastroenterology, The Affiliated Hospital of Qingdao University, Qingdao Shandong

Received: March 21, 2026; accepted: April 16, 2026; published: April 22, 2026

## Abstract

**Objective:** Gastric cancer (GC) remains one of the major causes of death in China. The purpose of this

\*通讯作者。

文章引用: 安静怡, 靳春昊, 毛涛. 基于 CT 的影像组学模型用于预测胃癌生存预后[J]. 临床医学进展, 2026, 16(4): 4281-4294. DOI: 10.12677/acm.2026.1641696

study was to establish a radiomics model based on computed tomography (CT) images combined with clinical features to predict the overall survival (OS) of patients after gastric cancer surgery. **Methods:** A total of 117 patients diagnosed with GC and treated with surgery at the Affiliated Hospital of Qingdao University from January 2015 to December 2020 were retrospectively enrolled. They were randomly divided into a training set and a validation set at a ratio of 7:3. Clinical data of patients and preoperative abdominal CT images were collected. After preprocessing with GAN reconstruction, the regions of interest (ROI) were delineated, radiomic features were extracted and screened by LASSO regression, and a radiomics model, a clinical risk model, and an integrated model were constructed respectively. The model performance was evaluated using C-index, Kaplan-Meier survival analysis, and other methods. **Results:** The radiomics model showed the best predictive performance, with a C-index of 0.758 in the validation set, which was superior to the clinical prediction model (0.703) and the integrated model (0.739). Kaplan-Meier analysis showed that there were statistically significant differences in OS between the high-risk and low-risk groups of each model ( $P < 0.05$ ). Meanwhile, multivariate Cox analysis confirmed that lymph vascular invasion was an independent risk factor for OS. **Conclusion:** The radiomics model based on preoperative CT can effectively and non-invasively predict the postoperative OS of GC patients, providing important reference for clinical prognosis evaluation and individualized treatment.

## Keywords

Radiomics, Gastric Cancer, OS, CT

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

胃癌(gastric cancer, GC)是第五大常见恶性肿瘤,同时也是第三大癌症相关死亡的原因[1]。早期胃癌通常无明显症状,胃癌被确诊时通常已发展至晚期[2]。晚期胃癌目前认为的主要治疗方式为外科手术治疗、放疗、化疗等,根治性切除术为最主要的外科手术方式[3]。胃癌患者的根治性切除术后5年总生存率为30%~40% [4]。在过去的几十年里,随着全球预防、筛查和治疗计划的实施,胃癌总体的发病率和死亡率稳步下降,但东亚、东南亚地区仍为胃癌的高发地区[4]。

根据AJCC指南,TNM(T: 原发肿瘤, N: 淋巴结, M: 远处转移)分期系统被公认为是评估胃癌患者预后的有效工具,可以起到辅助临床决策的作用[5]。近年来,一些新的生物标志物也被发现用于评估[6],但这些方式仍有一定的局限性[7]。因此,尽快寻找更可靠的生物标志物来对胃癌患者预后实现更准确的预测是十分重要的。这有助于制定治疗策略,降低胃癌患者的死亡率、延长生存时间[2] [3]。

近年来,影像组学飞速发展,其可以从医学图像中提取定量特征指标,即所谓的放射组学特征[8]。目前已在许多疾病的病理分型、淋巴结转移、生存预后、疗效评估上表现出优秀性能,如肝细胞癌[9]、肺癌[10]、乳腺癌[11]、淋巴瘤[12]等。计算机断层扫描图像(computed tomography, CT)是胃癌术前临床分期的首选方式。已有研究证明,胃癌患者的CT的部分纹理特征与预后有一定的关系[13] [14]。Zhang等人[14]建立了基于影像组学模型预测淋巴血管浸润。Shi等人[15]验证影像组学模型用于预测GC患者的无病生存期(disease-free survival, DFS)。但关于影像组学模型预测GC患者预后仍需更多的验证。

因此,本研究的目的是基于术前CT图像结合临床特征以预测GC患者的总生存期(overall survival, OS)。

## 2. 标准和方法

### 2.1. 患者入组

本文回顾性研究纳入了 2015 年 1 月至 2020 年 12 月于青岛大学附属医院经组织病理学诊断为胃癌的患者。所有患者均接受了胃的外科手术治疗。纳入标准：(1) 术后组织病理学确诊为胃癌的患者，(2) 术前 1 月内接受过腹部动态增强 CT 检查的患者。排除标准如下：(1) 术前缺乏 CT 图像或图像不合格(序列不完整或图像质量差)，(2) 临床资料不全的患者，(3) CT 检查前行抗肿瘤治疗的患者，(4) 病变太小而无法划定感兴趣区域(region of interest, ROI)。

本研究共纳入了 117 名患者(86 名男性，31 名女性)，按 7:3 随机分为训练集和验证集。

### 2.2. 随访

在术后前 2 年，患者每 3 个月监测一次，然后每 6 个月监测一次。常规随访包括实验室检查(血清肿瘤标志物)和影像学检查(CT 或内镜检查)。最后一次随访时间为 2024 年 12 月 31 日。OS 定义为从手术到因任何原因死亡或最后一次就诊于医院的时间。

### 2.3. 观测指标

收集了患者的人口统计学数据及临床实验室检查，包括：性别、年龄、身高、体重、BMI、年龄校正 Charlson 合并症指数(age-adjusted Charlson comorbidity index, aCCI)、首次就诊时的症状、基础疾病(如高血压、糖尿病、心血管疾病等)、癌症家族史、临床 TNM 分期、组织学类型和分级、幽门螺杆菌感染状态、病灶位置、周围神经浸润、淋巴血管浸润、血清肿瘤标志物(CEA、AFP、CA-724、CA-125、CA-199 和 CA-242)、Lauren 分型、免疫组化染色结果(表皮生长因子受体和人表皮生长因子受体-2)、Ki-67 指数和手术后是否接受化疗等。TNM 分期根据美国癌症联合委员会(AJCC, 第 8 版)指南定义。aCCI 是一种应用较广泛的合并症评分体系，基于患者年龄、所患疾病数目及严重程度，对合并症进行量化，可用于预测疾病的死亡风险。GC 的外科手术术式包括远端胃切除术(Roux-en-Y 手术)、近端胃切除术、胃次全切除术(Billroth I)、胃次全切除术(Billroth II)、全胃切除术联合食管空肠吻合术、腹腔镜胃切除术、胃镜下贲门切除术。

### 2.4. CT 扫描方案

禁食 6 h 后，患者取仰卧位平扫后，使用双管高压注射器以 3.0 mL/s 的速度通过肘正中静脉注射 75~80 mL 放射性造影剂。碘海醇(Yangtze River Pharmaceutical Group, Jiangsu, China)用作增强 CT 扫描的造影剂。扫描范围从膈穹顶到髂前上棘。动脉期、门静脉期和平衡期分别注射造影剂后 30 s、60 s 和 180 s 获得。使用的 CT 扫描设备包括 Siemens 和 Philips 型号。参数如下：管电压：120 KV，管电流：100~400 mA，管速：0.5 秒，层厚为 5 mm，层间距为 5 mm，切片厚度为 1 mm，矩阵为 512 × 512。

### 2.5. 图像预处理及 ROI 勾画

扫描的 CT 图像以 Digital Imaging and Communications in Medicine 格式导出。在图像强度归一化处理之后，我们对图像进行了 3D 超分辨率重建从而提高图像的空间分辨率。该技术以生成对抗网络(generative adversarial network, GAN)作为其基本架构。GAN 是一种深度学习模型，由两个网络组成：生成器网络和鉴别器网络。生成器网络从低分辨率图像生成高分辨率图像，而鉴别器网络区分真实图像和生成图像。这两个网络以对抗的方式训练，这一过程有助于生成器网络学习低分辨率和高分辨率图像之间的映射。对图像进行预处理后将图像分为低分辨率和高分辨率对，其中低分辨率图像是通过高分辨率图像进行

下采样获得的。该技术可以在保持原始图像大小的同时将空间分辨率提高 4 倍。这意味着  $1 \times 1 \times 1 \text{ mm}$  的像素体积可以转换为  $1 \times 1 \times 0.25 \text{ mm}$ 。

两名经验丰富的放射科医生使用 ITK-SNAP 软件(3.8 版, <http://www.itksnap.org>)在静脉期 CT 图像上对肿瘤进行手动分割。注意排除相邻的气体和脂肪,沿肿瘤病灶的边界进行描绘,勾勒出整个肿瘤病灶以获得 ROI。他们对患者的相关信息均不知情。在 1 月后对 30 名随机选择的患者进行重复分割以评估观察者间和观察者内的可重复性。在整个勾画过程中产生的任何异议都由一位拥有 20 多年经验的放射科主任医生解决。

## 2.6. 特征提取和选择

使用 PyRadiomics (3.0.1)从 ROI 中提取了 117 个放射学特征(RF)。根据图像生物标志物标准化倡议 (IBSI)指南[16]进行特征提取。RF 涵盖了 7 个特征类: shape, first-order, grey level co-occurrence matrix (GLCM), grey level difference matrix (GLDM), grey level run length matrix (GLRLM), grey level size zone matrix (GLSZM), and neighborhood grey tone difference matrix (NGTDM)。对所有患者的放射组学数值通过 Z 评分进行标准化,并使用类内相关系数(ICC)评估其可重复性。认为  $ICC \geq 0.85$  的特征为高度一致的特征,这些特征被用于后续分析,这减轻了 ROI 勾画中医生的潜在主观性。

## 2.7. 模型开发和验证

为了降低特征的维度,使用最小绝对收缩和选择运算符(least absolute shrinkage and selection operator, LASSO)回归方法识别最具有预测 OS 值的特征。采用十倍交叉验证确定最佳参数( $\lambda$ ),具体来说,我们使用  $k = 10$  将数据集划分为 10 个子集,确保每个子集都用作训练集和验证集。通过在  $k - 1$  折叠上迭代训练模型并在剩余折叠上验证,我们获得了平均性能测量,减轻了过度拟合的影响,并对模型在不同数据子集中的预测能力进行了可靠的估计。

使用最有价值的放射组学特征创建 Cox 风险模型(radiomics model, RM),用于预测 OS。使用单变量 Cox 回归分析筛选出具有统计学意义( $P < 0.05$ )的临床特征,然后通过多变量 Cox 回归分析分析这些参数。最终方程中留下的特征用于构建临床特征的风险模型(clinical risk model, CRM)。此外,我们通过将有价值的放射组学特征与临床特征相结合,开发了综合模型(integrated model, IM)。随后,这些模型在完全独立的队列上进行了验证。

## 2.8. 统计分析

使用独立 t 检验(正态分布的连续变量)和 Mann-Whitney U 检验(非正态分布的连续变量)比较不同组别患者之间特征的差异。分类变量采用卡方检验( $\chi^2$ )进行分析。使用单变量和多变量 Cox 比例风险模型用于确定影响结果的独立危险因素。根据模型预测的风险比(hazard ratio, HR)中位数,将患者分为低风险组或高风险组。使用 Cox 回归模型计算 HR 和 95%置信区间。使用 Kaplan-Meier (K-M)方法构建生存曲线,并通过 Log-rank 检验评估不同模型的生存差异。使用一致性指数(C-index)分析评估模型性能,并计算曲线下面积(AUC)。所有模型构建及统计分析均使用 Python 软件(版本 3.7.12, <http://www.python.org/>)进行。双侧 P 值  $< 0.05$  被认为具有统计学意义。

## 3. 结果

### 3.1. 患者特征

本研究共纳入 117 名患者,随机分为训练集( $n = 81$ )和验证集( $n = 36$ )。平均年龄分别为  $60.47 \pm 9.38$  和  $60.22 \pm 13.78$ 。训练集中包括 62 名男性和 19 名女性,验证集中有 24 名男性和 12 名女性。在训练集


和验证集中，中位随访时间分别为 51.17 个月和 58.13 个月，统计学分析均没有显著差距。

### 3.2. 模型构建及性能评估

本研究共构建了三个 OS 预测模型：基于临床特征的预测模型、基于放射组学特征的影像组学模型和基于临床和放射组学特征的综合模型。模型(CRM、RM 和 IM)使用完全独立的测试队列进行了验证。

#### 3.2.1. CRM 的构建及性能

在训练集中，对 33 个临床变量进行了 Cox 比例风险分析(表 1、图 1)。单因素 cox 结果显示，首次就诊的症状、CEA、AFP、CA199、CA724、CA242、CA125、T 分期、N 分期、M 分期、Lauren 分型、是否化疗、周围神经浸润、淋巴血管浸润和 KI-67 指数是 OS 的重要预后因素。Cox 多变量分析确定淋巴血管浸润(HR: 1.709, 95% CI 1.074~2.721, P < 0.05)是 OS 的独立危险因素。




**Figure 1.** Forest plot of multivariate Cox regression for the clinical model  
**图 1.** 临床模型多因素 Cox 回归森林图


**Table 1.** Univariate and multivariate Cox regression for predicting OS in the training set  
**表 1.** 训练集中预测 OS 的单因素和多因素 cox 回归

临床特征	HR (95% CI)	P 值	HR (95% CI)	P 值
首次就诊症状	1.225 (1.041~1.418)	<0.05	1.094 (0.959~1.249)	0.18
性别	0.880 (0.464~1.669)	0.696		
年龄	1.003 (0.974~1.032)	0.847		
身高	1.216 (0.021~70.58)	0.925		
体重	0.996 (0.969~1.023)	0.758		
BMI	0.932 (0.639~1.361)	0.717		
高血压	1.157 (0.601~2.228)	0.662		
心脏病	0.908 (0.391~2.112)	0.823		
糖尿病	1.014 (0.484~2.127)	0.97		
脑血管病	1.273 (0.424~3.819)	0.666		
aCCI	1.036 (0.770~1.394)	0.814		
胃癌家族史	1.344 (0.769~2.351)	0.3		
CEA	1.014 (1.001~1.019)	<0.05	1.001 (0.999~1.003)	0.484
AFP	1.025 (1.007~1.043)	<0.05	1.003 (0.987~1.020)	0.726
CA-199	1.002 (1.000~1.003)	<0.05	1.000 (0.999~1.002)	0.721
CA-724	1.023 (1.010~1.037)	<0.05	1.002 (0.989~1.015)	0.775
CA-242	1.008 (1.002~1.014)	<0.05	1.002 (0.996~1.009)	0.509
CA-125	1.040 (1.019~1.062)	<0.05	1.010 (0.990~1.032)	0.325
幽门螺杆菌	1.318 (0.764~2.274)	0.322		
T 分期	1.428 (1.181~1.728)	<0.05	1.095 (0.930~1.289)	0.274
N 分期	1.690 (1.183~2.414)	<0.05	1.246 (0.896~1.732)	0.191
M 分期	5.781 (2.593~12.887)	<0.05	2.102 (0.993~4.451)	0.052
病灶位置	0.677 (0.428~1.070)	0.095		
分化程度	0.822 (0.568~1.191)	0.301		
组织学分类	1.117 (0.918~1.358)	0.270		
形态特征	0.771 (0.559~1.066)	0.115		
Lauren 分型	1.355 (1.088~1.688)	<0.05	1.078 (0.896~1.297)	0.428
是否化疗	2.470 (1.443~4.229)	<0.05	1.205 (0.743~1.954)	0.449
EGFR	1.664 (0.849~3.258)	0.138		
HER2	1.014 (0.682~1.508)	0.946		
周围神经浸润	2.374 (1.374~4.101)	<0.05	1.151 (0.714~1.856)	0.565
淋巴血管浸润	3.917 (2.171~7.069)	<0.05	1.709 (1.074~2.721)	<0.05
Ki-67	1.023 (1.009~1.037)	<0.05	1.005 (0.994~1.017)	0.373


CRM 在 OS 预测中表现较好，训练集和验证集 C-index 分别为 0.794 和 0.703。Kaplan-Meier 生存分析显示，依据临床风险评分分层后，高风险组与低风险组 OS 差异明显，说明该模型具有较好的风险区分能力和一定稳定性(图 2)。




(a)




(b)




(c)



(d)



(e)




(f)

注：(a) 为影像组学模型训练集结果；(b) 为影像组学模型验证集结果；(c) 为临床模型训练集结果；(d) 为临床模型验证集结果；(e) 为组合模型训练集结果；(f) 为组合模型验证集结果。

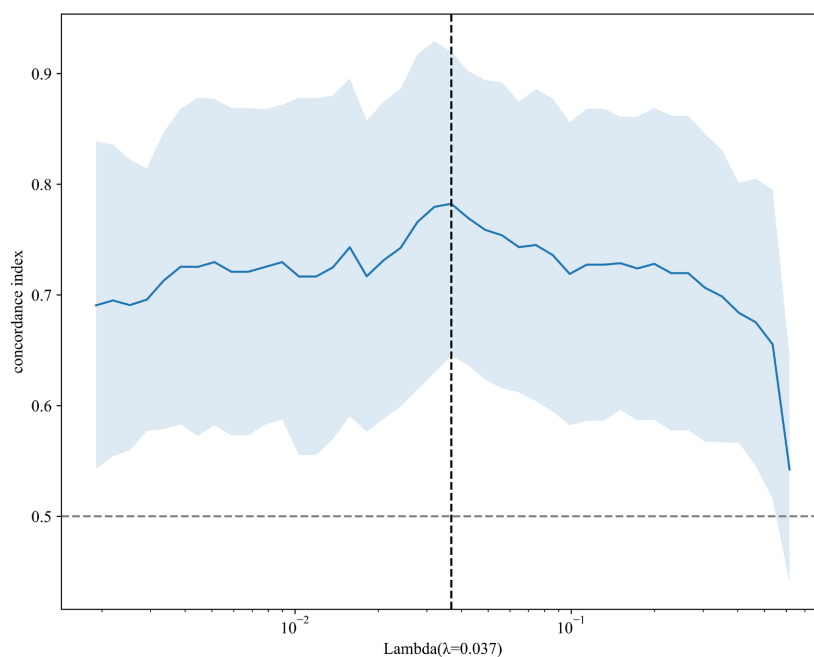
**Figure 2.** Kaplan-Meier curves of each model  
**图 2.** 各模型 K-M 曲线

### 3.2.2. RM 构建及性能


利用通过 LASSO-COX 回归分析从患者的 CT 图像中共提取了 117 个特征，最终筛选出 8 个特征：intra\_original\_shape\_SurfaceVolumeRatio、intra\_original\_shape\_LeastAxisLength、intra\_original\_glrlm\_RunVariance、intra\_original\_shape\_MinorAxisLength、intra\_original\_glszm\_SizeZoneNonUniformity、intra\_original\_glrlm\_RunEntropy、intra\_original\_shape\_Maximum3DDiameter、intra\_original\_glrlm\_LongRunLowGrayLevelEmphasis。图 3 为放射组学特征筛选过程。




(a)



(b)



(c)



(d)

注：(a) 为 LASSO 回归系数路径图；(b) 为基于交叉验证的最优惩罚参数  $\lambda$  选择图；(c) 为 LASSO 筛选后特征系数条形图；(d) 为纳入模型特征的多因素 Cox 回归森林图。

Figure 3. Radiomic feature selection and model establishment process

图 3. 影像特征筛选及模型建立过程

在 RM 预测 OS 中, 训练集和验证集 C-index 分别为 0.760 和 0.758。Kaplan-Meier 生存曲线显示, 基于影像风险评分的高低风险组 OS 存在明显差异, 提示术前 CT 的影像特征能够为患者术后总体生存评估提供有价值的无创信息(图 2)。与此同时, 放射组学模型在验证集中的区分度高于临床模型, 提示其稳定性的优秀。

### 3.2.3. IM 构建及性能

基于临床和放射组学特征, 我们还构建了 IM。其 C-index 在训练集与验证集中分别为 0.768 和 0.739, 整体表现优于单独临床模型、低于放射组学模型, 这可能与临床因素干扰所致。K-M 曲线见图 2。同时我们构建了综合模型预测 OS 的列线图(图 4)。

上述结果提示, 临床信息与 CT 放射组学特征在预后评估中具有一定互补性。前者反映患者基础状态和传统分期信息, 后者提供肿瘤宏观形态及异质性信息, 放射组学在无创预测患者总生存期上有极大的参考价值。




Figure 4. Nomogram based on IM prediction

图 4. 综合模型预测列线图

## 4. 讨论

本研究构建并验证了基于术前 CT 的 RM、CRM 及 IM, 用于预测 GC 术后患者 OS。结果显示, RM 在训练集与验证集中均表现出良好的预测效能与稳定性, 验证集 C-index 达 0.758, 优于 CRM, 提示术前 CT 影像组学特征可作为无创、定量的生物学标志物, 有效评估 GC 患者预后, 为临床个体化诊疗提供重要参考。

当前, TNM 分期仍是胃癌预后评估的核心依据, 但存在一定局限性, 其无法全面反映肿瘤内部异质性、生物学侵袭性等关键信息。本研究中, 单因素 Cox 分析显示 T 分期、N 分期、M 分期、肿瘤标志物及淋巴血管浸润等均与患者生存相关, 多因素分析证实淋巴血管浸润为独立危险因素, 与既往研究结论一致[14]。但单纯临床模型在外部验证中效能有所下降, 提示传统临床指标难以完全满足精准预后评估需

求。影像组学通过高通量提取 CT 图像中的形态、纹理及高阶特征,可量化肿瘤空间结构、密度异质性及侵袭潜能,弥补传统影像学主观评估与临床分期的不足。本研究通过 LASSO 回归筛选出 8 个核心放射组学特征,主要涵盖肿瘤形态与纹理参数,反映肿瘤体积、空间分布及异质性特征,证明 CT 纹理信息与胃癌患者生存密切相关,为无创预后评估提供客观量化指标。

本研究引入了基于 GAN 的超分辨率方法预处理模型。使用模型损失函数融合梯度损失、L1 损失与感知损失,从梯度、像素、特征层面保障生成图像的高视觉相似度。该方法已在多项研究中表现出较好的成像能力[17][18]。

本研究 RM 在验证集中 C-index 高达 0.758,且高低风险组 OS 差异显著,稳定性优于临床模型,提示基于 CT 的放射组学特征具有较强的预后预测价值。IM 效能介于两者之间,可能与以下几个原因有关。第一,影像组学特征已高度包含临床信息。影像组学特征已充分反映肿瘤异质性及侵袭性等深层生物学信息,额外引入临床变量反而增加模型复杂度,易引发过拟合。第二,本研究采用基础特征拼接策略进行多模态融合,未通过加权或注意力机制优化特征贡献度,可能影响综合模型性能。第三,样本量限制导致高维特征过拟合。影像组学本身已是高维特征,再加入临床变量会进一步提升特征维度。在有限样本下,综合模型更容易过拟合训练集。但仍体现出临床信息与影像组学特征的互补潜力。临床指标反映患者整体状况与疾病分期,影像组学特征揭示肿瘤微观结构与生物学行为,二者联合有望进一步提升预后评估准确性。

但本研究存在一定局限性。首先,本研究为一项单中心、回顾性研究,可能存在选择偏倚,结果不具备普遍性,未来需开展多中心、前瞻性研究验证模型通用性。第二,纳入的样本量相对有限,这可能会影响预测模型的稳健性,因此在未来将纳入更大样本 GC 患者入组。第三,ROI 勾画采用手动分割,虽经 ICC 验证确保一致性,但仍存在一定主观性,自动化分割工具可进一步提高效率与稳定性。第四,综合模型构建中采用基础特征拼接策略,未来可引入加权或注意力机制优化性能。最后,未来可整合基因组学、转录组学等数据精准进行预后评估。

## 5. 结论

本研究构建并验证了 RM、CRM 和 IM,用于预测 GC 患者术后 OS。其中 RM 预测效能最优;IM 效能介于两者之间,体现了临床特征与影像组学特征的互补价值。并且多因素 Cox 回归证实,淋巴管浸润是 GC 患者 OS 的独立危险因素。本研究证实,术前 CT 影像组学特征可作为无创、定量的生物学标志物,为胃癌患者术后预后评估提供可靠参考,助力临床个体化诊疗决策。

## 声明

本研究获得了青岛大学附属医院伦理委员会的批准(伦理号 QYFYWZLL42298)。

## 参考文献

- [1] Bray, F., Laversanne, M., Sung, H., Ferlay, J., Siegel, R.L., Soerjomataram, I., et al. (2024) Global Cancer Statistics 2022: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, **74**, 229-263. <https://doi.org/10.3322/caac.21834>
- [2] Ajani, J.A., D'Amico, T.A., Bentrem, D.J., Chao, J., Cooke, D., Corvera, C., et al. (2022) Gastric Cancer, Version 2.2022, NCCN Clinical Practice Guidelines in Oncology. *Journal of the National Comprehensive Cancer Network*, **20**, 167-192. <https://doi.org/10.6004/jnccn.2022.0008>
- [3] Japanese Gastric Cancer Association (2021) Japanese Gastric Cancer Treatment Guidelines 2018 (5th Edition). *Gastric Cancer*, **24**, 1-21. <https://doi.org/10.1007/s10120-020-01042-y>
- [4] Yang, W., Zhao, H., Yu, Y., Wang, J., Guo, L., Liu, J., et al. (2023) Updates on Global Epidemiology, Risk and Prognostic Factors of Gastric Cancer. *World Journal of Gastroenterology*, **29**, 2452-2468.

- <https://doi.org/10.3748/wjg.v29.i16.2452>
- [5] Röcken, C. and Behrens, H. (2015) Validating the Prognostic and Discriminating Value of the TNM-Classification for Gastric Cancer—A Critical Appraisal. *European Journal of Cancer*, **51**, 577-586. <https://doi.org/10.1016/j.ejca.2015.01.055>
- [6] Luo, Y., Zhang, X., Tan, Z., Wu, P., Xiang, X., Dang, Y., *et al.* (2015) Astrocyte Elevated Gene-1 as a Novel Clinicopathological and Prognostic Biomarker for Gastrointestinal Cancers: A Meta-Analysis with 2999 Patients. *PLOS ONE*, **10**, e0145659. <https://doi.org/10.1371/journal.pone.0145659>
- [7] Zhu, Z., Gong, Y. and Xu, H. (2020) Clinical and Pathological Staging of Gastric Cancer: Current Perspectives and Implications. *European Journal of Surgical Oncology*, **46**, e14-e19. <https://doi.org/10.1016/j.ejso.2020.06.006>
- [8] Mayerhoefer, M.E., Materka, A., Langs, G., Häggström, I., Szczypiński, P., Gibbs, P., *et al.* (2020) Introduction to Radiomics. *Journal of Nuclear Medicine*, **61**, 488-495. <https://doi.org/10.2967/jnumed.118.222893>
- [9] Bo, Z., Song, J., He, Q., Chen, B., Chen, Z., Xie, X., *et al.* (2024) Application of Artificial Intelligence Radiomics in the Diagnosis, Treatment, and Prognosis of Hepatocellular Carcinoma. *Computers in Biology and Medicine*, **173**, Article 108337. <https://doi.org/10.1016/j.combiomed.2024.108337>
- [10] Masson-Grehaigne, C., Lafon, M., Palussière, J., Leroy, L., Bonhomme, B., Jambon, E., *et al.* (2024) Single- and Multi-Site Radiomics May Improve Overall Survival Prediction for Patients with Metastatic Lung Adenocarcinoma. *Diagnostic and Interventional Imaging*, **105**, 439-452. <https://doi.org/10.1016/j.diii.2024.07.005>
- [11] Xiong, L., Tang, X., Jiang, X., Chen, H., Qian, B., Chen, B., *et al.* (2024) Automatic Segmentation-Based Multi-Modal Radiomics Analysis of US and MRI for Predicting Disease-Free Survival of Breast Cancer: A Multicenter Study. *Breast Cancer Research*, **26**, Article No. 157. <https://doi.org/10.1186/s13058-024-01909-3>
- [12] Giganti, F., Tang, L. and Baba, H. (2019) Gastric Cancer and Imaging Biomarkers: Part 1—A Critical Review of DW-MRI and CE-MDCT Findings. *European Radiology*, **29**, 1743-1753. <https://doi.org/10.1007/s00330-018-5732-4>
- [13] Shin, J., Lim, J.S., Huh, Y., Kim, J., Hyung, W.J., Chung, J., *et al.* (2021) A Radiomics-Based Model for Predicting Prognosis of Locally Advanced Gastric Cancer in the Preoperative Setting. *Scientific Reports*, **11**, Article No. 1879. <https://doi.org/10.1038/s41598-021-81408-z>
- [14] Zhang, W., Wang, S., Dong, Q., Chen, W., Wang, P., Zhu, G., *et al.* (2024) Predictive Nomogram for Lymph Node Metastasis and Survival in Gastric Cancer Using Contrast-Enhanced Computed Tomography-Based Radiomics: A Retrospective Study. *PeerJ*, **12**, e17111. <https://doi.org/10.7717/peerj.17111>
- [15] Shi, S., Miao, Z., Zhou, Y., Xu, C. and Zhang, X. (2022) Radiomics Signature for Predicting Postoperative Disease-Free Survival of Patients with Gastric Cancer: Development and Validation of a Predictive Nomogram. *Diagnostic and Interventional Radiology*, **28**, 441-449. <https://doi.org/10.5152/dir.2022.211034>
- [16] Zwanenburg, A., Vallières, M., Abdalah, M.A., Aerts, H.J.W.L., Andrearczyk, V., Apte, A., *et al.* (2020) The Image Biomarker Standardization Initiative: Standardized Quantitative Radiomics for High-Throughput Image-Based Phenotyping. *Radiology*, **295**, 328-338. <https://doi.org/10.1148/radiol.2020191145>
- [17] Xing, X., Li, L., Sun, M., Yang, J., Zhu, X., Peng, F., *et al.* (2024) Deep-Learning-Based 3D Super-Resolution CT Radiomics Model: Predict the Possibility of the Micropapillary/Solid Component of Lung Adenocarcinoma. *Heliyon*, **10**, e34163. <https://doi.org/10.1016/j.heliyon.2024.e3416>
- [18] Wang, L., Guo, T., Wang, L., Yang, W., Wang, J., Nie, J., *et al.* (2024) Improving Radiomic Modeling for the Identification of Symptomatic Carotid Atherosclerotic Plaques Using Deep Learning-Based 3D Super-Resolution CT Angiography. *Heliyon*, **10**, e29331. <https://doi.org/10.1016/j.heliyon.2024.e29331>