

DOI:10.3969/j.issn.1005-202X.2026.02.007

医学影像物理

## 放射组学与深度学习在局部晚期直肠癌 TRG 评分预测中的应用

李晨<sup>1,2</sup>, 宋轶鹏<sup>2</sup>

1. 山东第二医科大学临床医学院, 山东 潍坊 261042; 2. 烟台毓璜顶医院放射肿瘤科, 山东 烟台 264000

**【摘要】目的:**将放射组学特征与深度学习相结合,进行局部晚期直肠癌的肿瘤退变程度(TRG)评分预测,评估该方法在癌症治疗反应中的应用效果。**方法:**首先通过ITK-SNAP软件对CT图像进行处理,通过Spearman相关分析去除冗余特征,并结合Lasso回归进行特征降维。然后,采用改进的ResNet50模型进行特征提取,增强网络对肿瘤关键信息的关注,并与支持向量机(SVM)结合,进行TRG评分预测。通过多指标评估,比较不同特征筛选方法和模型架构的效果。**结果:**在对比实验中,本文提出的方法在特异性(0.82)、敏感性(0.78)、准确度(0.80)和AUC(0.84)上均表现最佳,明显优于其他对比方法。特别是在TRG评分预测的精确度和稳定性上,结合深度学习的特征提取和Lasso特征筛选的优势凸显,显著提升肿瘤反应评估的准确性。**结论:**本研究证明结合放射组学特征与深度学习模型,并通过Spearman相关分析与Lasso降维进行特征筛选,利用改进的ResNet50与SVM模型,能有效提升局部晚期直肠癌TRG评分的预测性能,实现精准的治疗反应预测,具有较高的临床应用价值,可为个体化治疗决策提供支持。

**【关键词】**放射组学;深度学习;局部晚期直肠癌;肿瘤退化程度评分

**【中图分类号】**R318;R735.3

**【文献标志码】**A

**【文章编号】**1005-202X(2026)02-0189-07

### Application of radiomics and deep learning in predicting tumor regression grade of locally advanced rectal cancer

LI Chen<sup>1,2</sup>, SONG Yipeng<sup>2</sup>

1. School of Clinical Medicine, Shandong Second Medical University, Weifang 261042, China; 2. Department of Radiation Oncology, Yantai Yuhuangding Hospital, Yantai 264000, China

**Abstract: Objective** To integrate radiomic features with deep learning for predicting tumor regression grade (TRG) scores of locally advanced rectal cancer, and evaluate its efficacy in assessing cancer treatment responses. **Methods** The CT images were processed using the ITK-SNAP software, followed by redundant feature removal through Spearman correlation analysis and feature dimensionality reduction using Lasso regression. Then, an improved ResNet50 model was employed for feature extraction to enhance the network's focus on key tumor information. This model was further combined with a support vector machine (SVM) for TRG score prediction. The performance of different feature selection methods and model architectures was evaluated with multi-parameter assessments. **Results** In the comparative experiment, the proposed method exhibited the optimal performance in specificity (0.82), sensitivity (0.78), accuracy (0.80), and AUC (0.84), significantly outperforming the other comparative methods. Especially in terms of the accuracy and stability of TRG score prediction, the advantages of combining deep learning-based feature extraction and Lasso-based feature selection were highlighted, which significantly improves the accuracy of tumor response assessment. **Conclusion** The integration of radiomic features and deep learning model, coupled with feature selection through Spearman correlation analysis and Lasso dimensionality reduction, and the utilization of the improved ResNet50 combined with SVM, can effectively enhance the predictive performance for TRG scores of locally advanced rectal cancer. This approach enables the accurate prediction of treatment responses, holds significant clinical application value, and provides robust support for individualized treatment decision-making.

**Keywords:** radiomics; deep learning; locally advanced rectal cancer; tumor regression grade score

**【收稿日期】**2025-07-24

**【基金项目】**山东省自然科学基金联合基金(ZR2022LSW012)

**【作者简介】**李晨, 硕士研究生, 研究方向: 直肠癌新辅助治疗疗效预测因素, E-mail: L85015chen@163.com

**【通信作者】**宋轶鹏, 博士, 教授, 研究方向: 肿瘤放射治疗, E-mail: syp1972@sina.com

## 前言

直肠癌是全球范围内发病率和死亡率较高的恶性肿瘤之一。随着诊断和治疗技术的不断进步,新辅助治疗已成为局部晚期直肠癌治疗的重要手段<sup>[1]</sup>。新辅助治疗通常包括放疗、化疗或放化疗联合应用,旨在通过减少肿瘤体积、改善局部控制率以及减少术后复发的风险。然而,由于患者对新辅助治疗的反应存在显著差异,如何有效预测患者的治疗反应,特别是肿瘤退变程度(Tumor Regression Grade, TRG),成为一个关键问题<sup>[2]</sup>。随着计算机视觉技术和人工智能的快速发展,放射组学和深度学习的结合为医学影像分析提供新的解决思路<sup>[3]</sup>。放射组学通过从医学影像中提取多维度的定量特征,能够为肿瘤的诊断、预后及治疗反应评估提供重要的信息<sup>[4]</sup>。深度学习尤其是卷积神经网络,则通过自动学习图像的深层特征,在医学图像分类、回归和预测任务中展现出优秀的性能<sup>[5]</sup>。近年来,许多研究者尝试将深度学习与放射组学相结合,以期提高对癌症治疗反应的预测精度<sup>[6-9]</sup>。特别是在直肠癌的研究中,CT影像作为一种常用的影像学检查手段,能够提供肿瘤形态、大小、位置等信息,通过合理的图像处理和特征提取方法,结合机器学习算法,可以实现对TRG评分的高效预测<sup>[2]</sup>。

本研究旨在探索放射组学与深度学习在局部晚期直肠癌TRG评分预测中的应用,特别是结合改进的ResNet50网络模型,优化TRG评分的预测效果。通过图像分割、特征提取、特征筛选以及XGBoost分类等步骤,提出一种新的方法框架,为临床治疗决策提供辅助支持。

## 1 研究资料

### 1.1 研究对象

选取2022年~2024年期间于烟台毓璜顶医院接受治疗的局部晚期直肠癌患者100例。研究中所有患者均符合放疗前分期标准,即根据cTNM临床分期系统,确定患者原发肿瘤的局部侵犯程度、区域淋巴结转移情况和远处转移状态。所有患者接受新辅助治疗,包括放疗、化疗或放化疗联合应用,治疗过程中进行定期CT扫描,评价肿瘤的治疗反应,并在治疗结束后根据TRG评分对患者的肿瘤退变情况进行评估。对于纳入标准的患者,必须确保治疗前、治疗中及治疗后的CT图像完整,并且能获得准确的TRG评分。本研究已获得烟台毓璜顶医院伦理委员会审核批准(批准文号:202400207)。

### 1.2 纳入与排除标准

本研究严格按照以下标准进行纳入和排除。纳入的患者必须是临床诊断为局部晚期直肠癌,并计

划接受新辅助治疗的患者。所有患者的影像学检查结果需要符合研究要求,并能提供治疗前和治疗后的CT影像数据。患者必须在治疗结束后获取TRG评分。如果患者的影像数据因其他原因未能完整或质量较差,或者患者在治疗过程中由于其他疾病无法继续治疗,则排除出本研究。

### 1.3 CT图像信息

使用的CT图像数据来源于患者在治疗后进行的CT扫描。通过这些CT图像,研究人员能够提取出肿瘤的形态、大小、位置等空间信息。治疗后的TRG评分用于反映肿瘤对新辅助治疗的反应,根据病理学评估标准,评分分为两类:良好反应(TRG为2~3,表示肿瘤有明显的退变,肿瘤细胞显著减少或坏死)和差反应(TRG为0~1,表示肿瘤退变不完全或仅有轻微变化)。治疗后的TRG评分由两位具有10年以上临床诊断经验的专业医师进行评分。每位医师根据标准化的TRG评分标准,对每例病例的CT图像进行独立评估,评分时重点考虑肿瘤的形态变化、肿瘤体积的缩小、肿瘤的坏死情况等多个因素。如果两位医师的评分一致,则该评分被认为是最终评分。如果两位医师的评分存在差异,则会请第3位同样具有10年以上临床经验的医师进行独立评估,最终根据3位医师的评估结果,综合确定TRG评分。

## 2 研究方法

### 2.1 图像预处理

在进行CT图像分割时,首先通过ITK-SNAP软件加载原始CT扫描图像,使用其半自动区域生长功能,基于预设的灰度阈值生成肿瘤的初步分割结果。分割过程中,软件结合图像的灰度梯度和邻近器官边界确定肿瘤轮廓。若初步分割出现漏分或过分割,研究人员会参考医生的标注指南,手动调整感兴趣区域边界,确保其精确覆盖肿瘤区域。最终分割结果需经两位独立评审的医师确认。

在完成肿瘤区域的分割后,通常需要从图像中提取多模态特征,以表征肿瘤的生物学特性。在此期间,提取的特征主要包括形态学特征、一阶统计特征以及纹理特征。形态学特征是描述肿瘤几何结构的基本属性,能够反映肿瘤的大小、形状以及空间分布特性。一阶统计特征主要包括图像中像素灰度值的统计分布特性,常见的统计特征包括图像灰度的均值和标准差。纹理特征用于描述图像中局部区域的灰度空间分布规律,常见的纹理特征包括灰度共生矩阵。除了灰度共生矩阵外,其他纹理特征如灰度依赖矩阵、灰度游程矩阵和邻域灰度差矩阵也用于肿瘤的异质性分析。

## 2.2 改进 ResNet50 网络

ResNet50 网络的基本结构由多个残差块组成,每个残差块包含两个 $3 \times 3$ 卷积层,并通过直接的捷径连接将输入与卷积输出相加,构成最终的输出。每个残差块的计算公式为 $F(x) = H(x, W) + x$ ,其中 $x$ 为输入, $H(x, W)$ 为卷积和非线性变换后的输出, $W$ 为卷积核, $F(x)$ 是该残差块的输出<sup>[10-11]</sup>。每个卷积层的卷积核大小为 $3 \times 3$ ,并且使用步幅1,以保持特征图的尺寸不变。原始 ResNet50 包含有多个这样的残差块,结构中每个块的输出与输入通过相加方式形成最终输出<sup>[12]</sup>。在 ResNet50 中,卷积层的输出通道数逐层增加:最初是64个通道,然后逐步增加到256、512和1024个通道。

为了提高模型对局部晚期直肠癌 TRG 评分的预测准确性,本研究对 ResNet50 进行改进,具体的网络结构见图1,主要从以下几个方面进行优化:(1)原始 ResNet50 网络以全局平均池化层为特征提取的最终步骤,输出一维向量到全连接层,在网络的最后增加一个全连接层,该全连接层可以进一步处理从卷积网络中提取的高维特征;(2)为了防止过拟合,增加 Dropout 层,随机丢弃一部分神经元。

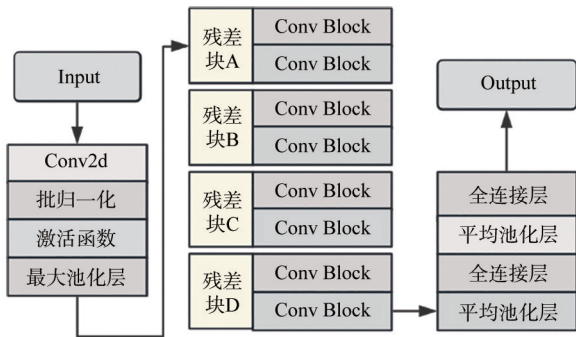


图1 改进的 ResNet50 网络结构

Figure 1 Improved ResNet50 network architecture

## 2.3 空间注意力模块

为了进一步提升网络对关键区域的关注,本文在每个残差块后加入空间注意力模块。空间注意力机制通过计算每个像素位置的注意力权重,突出显示肿瘤区域及其相关特征,从而优化模型对肿瘤反应的预测<sup>[13]</sup>。空间注意力模块首先使用最大池化和平均池化对输入特征图进行处理,然后通过卷积操作计算每个像素位置的注意力值,最后通过 Sigmoid 函数生成空间注意力图<sup>[14-15]</sup>。空间注意力模块的计算公式为:

$$A_s = \sigma \left( \text{Conv}_{7 \times 7} \left( M_p(F) + A_p(F) \right) \right) \quad (1)$$

式中, $A_s$ 为空间注意力图, $\sigma$ 为激活函数, $\text{Conv}_{7 \times 7}$ 是一个 $7 \times 7$ 卷积操作, $M_p(F)$ 和 $A_p(F)$ 分别表示对特征图 $F$ 进行最大池化和平均池化操作<sup>[16]</sup>。通过空间注意力机制,网络能够对肿瘤区域进行聚焦,使得模型能够更加专注于肿瘤相关的区域,提升模型的诊断准确度<sup>[17]</sup>。

## 2.4 特征筛选与降维

采用 Spearman 相关分析和 Lasso 回归两种方法来对提取的特征进行筛选与降维。首先,利用 Spearman 相关分析计算所有特征之间的相关系数。Spearman 相关系数能够衡量两个变量的单调关系,计算公式为:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (2)$$

式中, $\rho$ 表示特征之间的 Spearman 相关系数, $d_i$ 是第 $i$ 个特征的排名差异, $n$ 是特征数量。通过计算相关系数,可以识别和剔除那些相关系数大于0.9的特征。高度相关的特征往往存在冗余信息,保留这些特征可能导致模型在训练过程中出现过拟合现象。因此,通过去除冗余特征,确保模型训练时能够有效利用每个特征的独立性和区分度。

使用 Lasso 回归进行特征降维<sup>[18]</sup>。L1 正则化通过对特征系数施加惩罚,强制将不重要的特征系数收缩为0。Lasso 回归的目标函数为:

$$L(\beta) = \min_{\beta} \frac{1}{2n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{j=1}^p |\beta_j| \quad (3)$$

式中, $\beta_j$ 为模型的特征系数, $\lambda$ 是正则化参数。Lasso 回归通过调整 $\lambda$ 值,能够有效筛选出最具代表性的特征,并将不相关或冗余特征的系数压缩为零<sup>[19]</sup>。通过这一过程,保留具有重要预测能力的特征,减少输入维度,从而提高模型的训练效率和稳定性。

## 2.5 分类模型的构建

在特征筛选与降维后,采用支持向量机(Support Vector Machine, SVM)作为主要的分类模型,用于 TRG 评分的预测任务。SVM 是一种广泛应用于分类任务的监督学习方法,特别适用于高维数据的分类问题<sup>[20]</sup>。本研究选择使用线性核的 SVM,因其在保证分类性能的同时具有模型简单、计算高效的优势,以简化模型并提高计算效率。

在训练过程中,SVM 的目标是找到一个能够有效分隔不同类别的超平面。对于训练样本 $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$ ,其中 $\mathbf{x}_i$ 是输入特征向量, $y_i \in \{-1, 1\}$ 是类别标签,SVM 通过优化以下目标函数来确定超平面, $\min_{\mathbf{w}, b} \|\mathbf{w}\|^2 / 2$ <sup>[21]</sup>。同时,满足约束条件:

$$y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \forall i = 1, 2, \dots, n \quad (4)$$

式中,  $w$  为超平面的法向量,  $b$  为偏置项。

为了处理约束条件, SVM 引入拉格朗日乘子法, 将目标函数和约束条件合并为拉格朗日对偶问题<sup>[22]</sup>。拉格朗日函数为:

$$L(w, b, \lambda) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \lambda_i [y_i (w \cdot x_i + b) - 1] \quad (5)$$

式中,  $\lambda_i \geq 0$  是拉格朗日乘子。通过对拉格朗日函数分别对  $w$ 、 $b$  和  $\lambda_i$  求偏导数并令其为 0, 得到对偶问题的解。最终目标是最大化拉格朗日对偶函数:

$$D(\lambda) = \max_{\lambda} \left( \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j=1}^n \lambda_i \lambda_j y_i y_j \langle x_i, x_j \rangle \right) \quad (6)$$

式中,  $\langle x_i, x_j \rangle$  表示样本点的内积。通过求解这个对偶问题, SVM 能够得到最优的拉格朗日乘子, 从而确定最终的决策超平面<sup>[23]</sup>。

训练完成后, SVM 模型通过决策函数来对新样本进行分类。线性 SVM 的决策函数为  $f(x) = w \cdot x + b$ , 根据该函数的输出, SVM 将样本分为两类: (1) 如果  $f(x) > 0$ , 则预测为类别 1 (TRG 为 2~3, 良好反应); (2) 如果  $f(x) \leq 0$ , 则预测为类别 -1 (TRG 为 0~1, 差反应)。综上, 本研究设计的流程图见图 2。

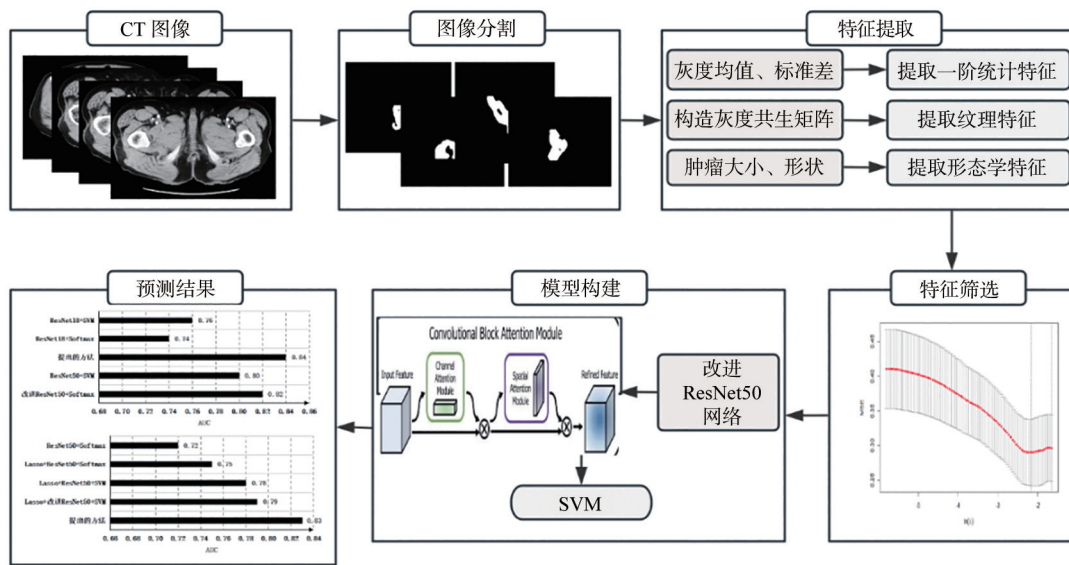


图 2 本研究设计的流程图  
Figure 2 Research flowchart

### 3 结果

#### 3.1 实验环境

实验使用的计算平台为具有 NVIDIA GeForce RTX 3090 显卡的工作站, 配备 Intel Xeon 处理器和 128 GB 内存。操作系统为 Ubuntu 20.04, 深度学习框架采用 TensorFlow 2.x 和 Keras。

#### 3.2 实验数据与处理

纳入 100 例患者, 每例患者在治疗后均提供 CT 影像数据。根据治疗反应, 患者被分为两组: 其中 66 例为良好反应组, 34 例为差反应组。其中, 男 63 例, 女 37 例。两组患者的年龄分布相近, 良好反应组平均年龄为 (60.40±9.87) 岁, 差反应组平均年龄为 (61.30±10.15) 岁。

对于图像数据, 从每例患者的 CT 图像中提取 3 401 个特征, 包括形态学特征、纹理特征等。随后, 采用 Spearman 相关分析方法对特征之间的相关性进行分析, 去除相关性较大的冗余特征。最终, 通过

Lasso 回归对特征进行降维, 筛选出 13 个最具代表性的深度学习特征。图 3 展示 Lasso 算法在特征筛选中的  $\lambda$  值曲线。横轴表示  $\ln(\lambda)$ , 纵轴表示均方误差 (MSE), 图中红点表示对应的 MSE, 红点的灰色竖线表示该点对应的 MSE 范围。

#### 3.3 对比实验

为了评估所提方法的性能, 将数据集划分为训练集和测试集, 比例为 4:1, 并与以下几种方法进行对比。对比方法包括: (1) 改进 ResNet50+Softmax, 该方法使用改进的 ResNet50 结构, 并在其后利用 Softmax 进行分类; (2) ResNet50+SVM, 该方法使用 ResNet50 作为特征提取网络, 之后采用 SVM 进行分类任务; (3) ResNet18+Softmax, 采用较浅的 ResNet18 结构与 Softmax 组合; (4) ResNet18+SVM。实验的评估指标包括: AUC、特异度、敏感度以及准确度。实验结果见表 1 与图 4。




图3 Lasso算法的特征筛选λ值曲线

Figure 3 The λ-value curve of Lasso algorithm for feature selection

表1 对比实验中不同方法的评估指标结果

Table 1 Comparison results of evaluation indicators for different methods in comparative experiments

特征筛选	方法	特异度	敏感度	准确度
Spearman+Lasso	本文方法	0.82	0.78	0.80
Spearman+Lasso	改进 ResNet50+Softmax	0.80	0.76	0.78
Spearman+Lasso	ResNet50+SVM	0.78	0.74	0.77
Spearman+Lasso	ResNet18+Softmax	0.71	0.68	0.70
Spearman+Lasso	ResNet18+SVM	0.73	0.70	0.71

根据表1可知,本文方法在特异度、敏感度和准确度上均表现出色,优于其他所有对比方法。本文方法特异度达到0.82,显著高于其他方法,这表明本文方法能更有效地区分差反应类患者,降低误判为良好反应的风险。本文方法的敏感度优于 ResNet50+SVM 和 ResNet18+SVM,意味着提出的方法能够更准确地识别良好反应类患者,减少漏诊的情况。本文方法的准确度在所有方法中位居前列,特别是相较于 ResNet18+Softmax 和 ResNet18+SVM,提高诊断的一致性。综合来看,本文方法在对局部晚期直肠癌 TRG 评分的分类中,具有更高的正确性和更强的诊断能力。根据图4可知,本文方法在 AUC 指标上达到0.84,显著优于其他对比方法。这一结果验证模型在整体分类能力上的优势,其在不同分类阈值下均表现出稳定的预测性能。该模型能够有效区分 TRG 评分中的良好反应(TRG 为2~3)与差反应(TRG 为0~1)患者,且在数据分布不平衡时仍保持较高的判别准确性。

### 3.4 消融实验

为了进一步验证不同方法模块对模型性能的影响,进行消融实验,将数据集按照 7:3 的比例划分为训练集和测试集。在消融实验中,与以下几种方法进行比较:  
(1)Lasso+改进 ResNet50+SVM,使用 Lasso 进行特征降




图4 对比实验中不同方法的 AUC 指标对比结果

Figure 4 Comparison results of AUC indicators of different methods in comparative experiments

维后,结合改进 ResNet50 和 SVM 进行分类;(2)Lasso+ResNet50+SVM,使用 Lasso 进行特征降维后,之后用 ResNet50 提取特征,并在最后加入 SVM 进行分类;(3)Lasso+ResNet50+Softmax,使用 Lasso 进行特征降维,之后通过 ResNet50 提取特征并加入 Softmax 进行分类;(4)ResNet50+Softmax。评估指标与对比实验相同。

根据表2可知,在消融实验中,采用 Spearman 相关分析和 Lasso 降维的特征筛选流程显著提升模型

的特异度、敏感度和准确度。基于此筛选出的特征输入到改进的 ResNet50+SVM 分类模型后,模型在区分差反应和良好反应患者时达到0.81的特异度、0.77的敏感度和0.78的准确度,均优于仅使用 Lasso 或无筛选的对照方法。Spearman 相关分析有效剔除冗余特征,Lasso 回归进一步压缩无关特征系数至0,使得最终输入 SVM 的特征既精简又具备判别力,从而在医学影像中精确捕捉肿瘤退缩的影像学差异。根据

表2 消融实验中不同方法的评估指标对比结果

Table 2 Comparison results of evaluation indicators for different methods in ablation experiments

特征筛选	方法	特异度	敏感度	准确度
Spearman+Lasso	本文方法	0.81	0.77	0.78
Lasso	改进 ResNet50+SVM	0.76	0.73	0.75
Lasso	ResNet50+SVM	0.76	0.73	0.74
Lasso	ResNet50+Softmax	0.72	0.68	0.70
无	ResNet50+Softmax	0.69	0.65	0.67

图5可知,改进的 ResNet50 网络结合 SVM 分类模型,最终 AUC 值提升至 0.83,超越所有对照方法。通过增强对肿瘤关键区域的注意力机制与深层特征提取能力,并结合 Spearman 相关性分析与 Lasso 回归的特征筛选策略,模型获得更强的判别效能。实验表明,该联合策略在不同分类阈值下均具有高稳定性与准确性,证实多步特征优化与深度学习网络改进对局部晚期直肠癌 TRG 评分预测的协同提升作用,凸显其临床应用潜力。




图5 消融实验中不同方法的 AUC 指标对比结果

Figure 5 Comparison results of AUC indicators of different methods in ablation experiments

### 4 结论

本研究通过将放射组学特征与深度学习方法相结合,提出一种有效的局部晚期直肠癌 TRG 评分预测模型。通过采用 Spearman 相关分析和 Lasso 特征筛选,对 CT 图像中提取的特征进行精确筛选,去除冗余特征,保留具有高度区分度的信息。结合改进的 ResNet50 网络,并加入 SVM 分类模型,优化肿瘤反应的预测精度。实验结果表明,本文方法在特异度、敏感度、准确度和 AUC 等多个指标上均优于其他对比方法。特别是通过深度学习的增强特征提取和高效的特征筛选,本研究模型在 TRG 评分预测任务中展现较高的稳定性与可靠性。相比于传统方法,改进后的网络不仅能够有效提高对良好反应和差反应患者的分类准确性,还能处理复杂的医学影像数据,从而为临床提供更为精确的治疗反应预测工具。

未来的研究可以进一步优化深度学习模型的架构,并结合更多的临床数据,以提升局部晚期直肠癌 TRG 评分预测的准确性和泛化能力。探索不同成像技术与多模态数据的结合,可能会进一步增强治疗反应预测的精确度和临床应用价值<sup>[24-26]</sup>。

### 【参考文献】

- [1] 梁玉汶,杜小波.局部晚期直肠癌新辅助治疗反应评估及预测研究进展[J]. 华西医学, 2024, 39(5): 825-832.  
Liang YW, Du XB. Research progress on response evaluation and prediction of neoadjuvant therapy for locally advanced rectal cancer [J]. West China Medical Journal, 2024, 39(5): 825-832.
- [2] Lee YD, Kim HG, Seo M, et al. Machine learning-based response assessment in patients with rectal cancer after neoadjuvant chemoradiotherapy: radiomics analysis for assessing tumor regression grade using T2-weighted magnetic resonance images [J]. Int J Colorectal Dis, 2024, 39(1): 78.
- [3] Park HJ, Park B, Lee SS. Radiomics and deep learning: hepatic applications[J]. Korean J Radiol, 2020, 21(4): 387-401.
- [4] Shen C, Liu ZY, Guan M, et al. 2D and 3D CT radiomics features prognostic performance comparison in non-small cell lung cancer[J]. Transl Oncol, 2017, 10(6): 886-894.
- [5] Zhang BH, Qi SL, Pan XH, et al. Deep CNN model using CT radiomics feature mapping recognizes EGFR gene mutation status of lung adenocarcinoma[J]. Front Oncol, 2021, 10: 598721.
- [6] Yardimci AH, Kocak B, Sel I, et al. Radiomics of locally advanced rectal cancer: machine learning-based prediction of response to neoadjuvant chemoradiotherapy using pre-treatment sagittal T<sub>2</sub>-weighted MRI[J]. Jpn J Radiol, 2023, 41(1): 71-82.
- [7] Hou M, Zhou L, Sun JH. Deep-learning-based 3D super-resolution MRI radiomics model: superior predictive performance in preoperative T-staging of rectal cancer[J]. Eur Radiol, 2023, 33(1): 1-10.
- [8] Lu HD, Yuan Y, Liu ML, et al. Predicting pathological complete response following neoadjuvant chemoradiotherapy (nCRT) in patients with locally advanced rectal cancer using merged model integrating MRI-based radiomics and deep learning data[J]. BMC Med Imaging, 2024, 24(1): 289.

- [9] Zhong H, Wang TY, Hou MY, et al. Deep learning radiomics nomogram based on enhanced CT to predict the response of metastatic lymph nodes to neoadjuvant chemotherapy in locally advanced gastric cancer[J]. *Ann Surg Oncol*, 2024, 31(1): 421-432.
- [10] Elpeltagy M, Sallam H. Automatic prediction of COVID-19 from chest images using modified ResNet50[J]. *Multimed Tools Appl*, 2021, 80(17): 26451-26463.
- [11] Abou El-Maged L, Elsonbaty AA, Elbelkasy M. Enhanced CT-image for COVID-19 classification using ResNet50[J]. *J Theor Appl Inf Technol*, 2022, 100: 12.
- [12] Hossain MB, Iqbal SM, Islam MM, et al. Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images[J]. *Inform Med Unlocked*, 2022, 30: 100916.
- [13] Farag MM, Fouad M, Abdel-Hamid AT. Automatic severity classification of diabetic retinopathy based on DenseNet and convolutional block attention module[J]. *IEEE Access*, 2022, 10: 38299-38308.
- [14] Chu XX, Tian Z, Wang YQ, et al. Twins: revisiting the design of spatial attention in vision transformers[C]//*Advances in Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2021: 9355-9366.
- [15] Wu Z, Zhu H, He LL, et al. Real-time stereo matching with high accuracy *via* spatial attention-guided upsampling[J]. *Appl Intell*, 2023, 53(20): 24253-24274.
- [16] Liu ZG, Fu YM, Pan Q, et al. Orientational distribution learning with hierarchical spatial attention for open set recognition[J]. *IEEE Trans Pattern Anal Mach Intell*, 2023, 45(7): 8757-8772.
- [17] Jiang M, Yin SL. Facial expression recognition based on convolutional block attention module and multi-feature fusion[J]. *Int J Comput Vision Robot*, 2023, 13(1): 21-37.
- [18] Shi YH, Gao YZ, Liao S, et al. Semi-automatic segmentation of prostate in CT images *via* coupled feature representation and spatial-constrained transductive lasso[J]. *IEEE Trans Pattern Anal Mach Intell*, 2015, 37(11): 2286-2303.
- [19] Zhao F, Wang P, Yu CR, et al. A LASSO-based model to predict central lymph node metastasis in preoperative patients with cN0 papillary thyroid cancer[J]. *Front Oncol*, 2023, 13: 1034047.
- [20] Kareem HF, AL-Huseiny MS, Mohsen FY, et al. Evaluation of SVM performance in the detection of lung cancer in marked CT scan dataset[J]. *Indones J Electr Eng Comput Sci*, 2021, 21(3): 1731-1738.
- [21] Demet Mutlu G, Asirdizer M, Kartal E, et al. Sex estimation from the hyoid bone measurements in an adult Eastern Turkish population using 3D CT images, discriminant function analysis, support vector machines, and artificial neural networks[J]. *Leg Med (Tokyo)*, 2024, 67: 102383.
- [22] Hoque R, Billah M, Debnath A, et al. Heart disease prediction using SVM[J]. *Int J Sci Res Arch*, 2024, 11(2): 412-420.
- [23] Lai ZH, Liang GF, Zhou J, et al. A joint learning framework for optimal feature extraction and multi-class SVM[J]. *Inf Sci (Ny)*, 2024, 671: 120656.
- [24] Behrad F, Sanice Abadeh M. An overview of deep learning methods for multimodal medical data mining[J]. *Expert Syst Appl*, 2022, 200: 117006.
- [25] Wang M, Zhou XH, Jin MM, et al. MultiRoiMix: a data augmentation method for PET/CT multimodal medical images[J]. *J Med Biol Eng*, 2024, 44(3): 366-374.
- [26] Abdelaziz M, Wang TF, Elazab A. Alzheimer's disease diagnosis framework from incomplete multimodal data using convolutional neural networks[J]. *J Biomed Inform*, 2021, 121: 103863.

(编辑:陈丽霞)