

基于 MR 超分重建图像的影像组学模型术前预测早期宫颈癌淋巴血管浸润的价值

何月明, 罗锦文, 张婷, 戚莹莹

【摘要】 目的:探讨基于 MR 深度迁移学习超分重建图像的影像组学模型术前预测早期宫颈癌(CC)淋巴血管间隙浸润(LVSI)的价值。**方法:**回顾性分析经术后病理证实的 100 例早期 CC 患者的 MRI 及临床资料,对矢状面 T₂WI 抑脂非增强序列原始图像(OI)进行深度迁移学习超分重建图像(SRI),并采用 ITK-SNAP 软件在 OI 及 SRI 上对全肿瘤区域进行 3D 标注,根据病理结果分为 LVSI 阳性与 LVSI 阴性组,并按照 8:2 比例随机分为训练集(80 例)和验证集(20 例)。对 OI、SRI 标注图像 3D VOI 进行特征提取及最小绝对收缩与选择算子(LASSO)回归筛选影像组学特征,并分别建立 LightGBM 影像组学模型,使用 AUC 评估模型的诊断效能,使用决策曲线分析(DCA)评估模型的临床价值。**结果:**基于 OI 影像组学模型预测宫颈鳞癌 LVSI 状态,训练集 AUC=0.795(95%CI:0.696~0.894),敏感度为 0.533,特异度为 0.920;验证集 AUC=0.637(95%CI:0.350~0.924),敏感度为 0.429,特异度为 0.923。基于 SRI 影像组学模型预测宫颈鳞癌 LVSI 状态,训练集 AUC=0.817(95%CI:0.722~0.913),敏感度为 0.920,特异度为 0.717;验证集 AUC=0.815(95%CI:0.625~1.000),敏感度为 0.667,特异度为 0.786。两组图像训练集和验证集中均显示出良好的校准和区分能力,SRI 较 OI 影像组学模型的诊断效能明显提高,DCA 结果表明模型具有较高的临床价值。**结论:**基于 MR 深度迁移学习 SRI 影像组学模型对术前预测宫颈癌 LVSI 状态具有良好的应用价值,较 OI 影像组学模型的诊断效能有所提高,有助于更好地指导临床治疗决策。

【关键词】 宫颈癌;磁共振成像;超分重建;影像组学;淋巴血管浸润

【中图分类号】 R737.33;R445.2 **【文献标志码】** A **【文章编号】** 1000-0313(2024)09-1213-08

DOI:10.13609/j.cnki.1000-0313.2024.09.015

开放科学(资源服务)标识码(OSID):



The value of radiomics model based on MR hyperresolution reconstructed images in preoperative prediction of lymphatic vascular infiltration in early cervical cancer HE Yue-ming, LUO Jin-wen, ZHANG Ting, et al. Department of Gynecology, the Fifth Affiliated Hospital of Guangzhou Medical University, 510735 Guangzhou, China

【Abstract】 Objective: To explore the value of a radiomics model based on deep transfer learning super-reconstructed images of MR for preoperative prediction of lymphatic vessel infiltration (LVSI) of early cervical cancer (CC). **Methods:** A retrospective analysis was conducted on the MR images and clinical data of 100 early CC patients confirmed by postoperative pathology. The original images (OI) of sagittal T₂WI lipid-pressure non enhanced sequence were reconstructed using deep transfer learning (SRI). The entire tumor area was labeled in 3D on both OI and SRI using ITK-SNAP software. According to the pathological results, the patients were divided into LVSI positive and LVSI negative groups, and randomly divided into a training set (80 cases) and a validation set (20 cases) in a 8:2 ratio. Feature extraction and Least Absolute Shrinkage and Selection Operator (LASSO) regression were performed on the annotated 3D VOI images from OI and SRI to screen for radiomics features. LightGBM radiomics models were established, and the diagnostic efficacy of the models was evaluated using AUC. The clinical value of the models was evaluated using Decision Curve Analysis (DCA). **Results:** The diagnostic efficacy of the OI radiomics model in CC was evaluated with a training set AUC of 0.795(95% CI:0.696~0.894), sensitivity of 0.533, and specificity of 0.920. The validation set AUC=

作者单位:510735 广州,广州医科大学附属第五医院妇科(何月明、张婷、戚莹莹),影像科(罗锦文)

作者简介:何月明(1981-),女,广东清远人,硕士,副主任医师,主要从事妇科肿瘤治疗与影像诊断工作。

通讯作者:罗锦文, E-mail:13929580986@163.com

基金项目:广东省医学科学技术研究基金(编号:A2024300);广州市基础与应用基础研究项目(项目编号 202102080250)

0.637 (95% CI:0.350~0.924), with a sensitivity of 0.429 and a specificity of 0.923. The diagnostic efficacy of SRI radiomics classification in CC was evaluated with training set AUC = 0.817 (95% CI: 0.722~0.913), sensitivity of 0.920, specificity of 0.717, validation set AUC = 0.815 (95% CI: 0.625~1.000), sensitivity of 0.667, specificity of 0.786. The two sets of image training sets and validation sets showed good calibration and discrimination abilities, and the diagnostic efficiency of SRI compared to OI's radiomics model was significantly improved. The DCA results showed that the model had high clinical value. **Conclusion:** The SRI radiomics model based on MR deep transfer learning has good application value in predicting LVSI of cervical cancer before surgery, which improves the diagnostic efficiency compared to OI and can help better guide clinical treatment decisions.

【Key words】 Cervical cancer; Magnetic resonance imaging; Hyper resolution reconstructed; Radiomics; Lymphatic vessel infiltration

宫颈癌(cervical carcinoma, CC)在亚洲地区的发病率和死亡率均排在第 3 位^[1],正在成为癌症死亡的主要原因之一,全球每年有超过 30 万人死亡。淋巴脉管间隙侵犯(lymphatic vessel infiltration, LVSI)是 CC 的中危因素^[2],包括血管侵犯和淋巴管侵犯,与 CC 淋巴结转移和远处转移密切相关^[3],往往导致预后不良。由于转移性 CC 的 5 年生存率仅为 16.5%^[4],LVSI 的早期诊断对于宫颈癌的早期精准诊断至关重要,及时、准确的治疗决策可以改善患者预后。然而,由于缺乏特异性影像生物标志物及影像特征,放射科医生仍然无法通过术前影像可靠地预测 LVSI 的风险。基于 MRI 的 CC 评估已取得进展,然而传统的 MRI 基于主观视觉评估,整体效能较低,主要原因可能是一些与 LVSI 相关的预测定量特征隐藏在更高维度中,很难通过目视检查识别。大数据分析技术与医学影像有机结合,影像组学方法应运而生,通过从影像中提取高通量信息进行深层挖掘分析,以实现肿瘤的无创诊断和预后预测。然而,由于数据在采集过程中设备参数或设备质量的问题,可能会使采集的原始图像(original image, OI)存在模糊、不清晰等问题。超分辨率图像(super resolution image, SRI)是计算机视觉领域提高图像分辨率的重要处理方法之一,在医学图像领域有重要的研究意义和应用价值。高质量和高分辨率(high resolution, HR)的医学影像图像在当前的临床过程中非常重要。近年来,基于深度学习的医学 MR 影像超分辨率(super resolution, SR)重建技术取得了显著进展,明显提高了图像质量,SR 技术对于提高图像的视觉质量和细节信息非常有帮助。HR 图像可以呈现更多细节,使图像更加清晰、逼真,改善图像处理结果,有助于更准确地进行分析和研究。本研究拟采用深度学习 SR 的技术,对原始 MR 数据进行重建,使之得到高清的图像数据以提高图像质量、改善图像处理结果,在研究和图像分析中得到更精准的结果,结合轻量级梯度提升机算法(light gradient boost-

ing machine, LightGBM)影像组学模型,与 OI 进行对比,旨在评估 SRI 影像组学模型对早期 CC 中 LVSI 的诊断效能。

材料与方法

1. 研究对象

回顾性分析 2018 年 1 月至 2023 年 7 月本院 100 例经手术病理证实的早期 CC(FIGO 分期 I—II A 期)患者的病理及 MR 影像资料,年龄 42~69 岁,平均(57±11)岁。所有 CC 患者病理类型均为鳞癌。病例纳入标准:①术前均行盆腔 MR 平扫+增强扫描,且 MR 检查与手术间隔<2 周;②术前未行任何放、化疗等治疗;③MR 图像各序列清晰,满足影像组学特征提取及影像诊断的要求;④术后病理学诊断明确,有 LVSI 的描述性病理报告;⑤患者临床资料完整。病例排除标准:①全身多发肿瘤患者;②腺癌、腺鳞癌等宫颈非鳞癌病例;③未行手术或病理活检^[5-7];④CC 病灶较小,最大径<10 mm;⑤MR 图像显示不清,无法进行影像评价与影像组学特征提取。100 例患者按照 8:2 比例随机分为训练集(80 例)和验证集(20 例)。本研究已通过本院伦理委员会审核(伦理批件编号:GYWY-K2024-43),由于是回顾性分析,免除患者知情同意。

2. 检查方法

所有盆腔 MRI 检查均在西门子 3.0T 或 1.5T MR 扫描仪上进行,行平扫、增强 MRI 检查,使用自由呼吸、频率选择性脂肪抑制单次旋转回波回声平面成像序列,扩散敏感 b 值分别取 50、800、1000 s/mm²。

MR 扫描常规序列包括横轴面 T₁WI、横轴面 T₂WI、横轴面抑脂 T₂WI、横轴面 DWI、冠状面 T₂WI、矢状面抑脂 T₂WI 等。

增强序列包括横轴面 T₁WI、冠状面 T₁WI、矢状面 T₁WI、横轴面 T₁WI 减影等。扫描完成后获得 MR

最小化生成图像与真实图像之间的差异,使得判别器无法区分它们。这可以通过最小化生成器的损失函数来实现。常用的损失函数包括均方误差损失(mean squared error, MSE)或感知损失,可以表示为: $L_G = \lambda_1 \times L_{p_ixel} + \lambda_2 \times L_{p_perceptual}$,其中 L_{p_ixel} 表示像素级别的损失,衡量生成图像与真实图像之间的差异; $L_{p_perceptual}$ 表示感知损失,基于预训练的特征提取网络(如 VGG 网络)计算生成图像与真实图像的特征差异; λ_1 和 λ_2 是损失权重,用于平衡两种损失的贡献。⑨ 判别器优化目标:判别器的目标是准确地区分生成图像与真实图像,以最大化其判别能力。判别器的损失函数可以表示为: $L_D = L_{real} + L_{fake}$,其中 L_{real} 表示真实图像被正确判别为真实图像的损失, L_{fake} 表示生成图像被正确判别为生成图像的损失。⑩ 对抗训练:在训练过程中,生成器和判别器交替进行训练。生成器尝试最小化生成器的损失函数,同时判别器尝试最大化判别器的损失函数。通过对抗训练,生成器逐渐学习到生成逼真的高分辨率图像,使得判别器难以区分生成图像与真实图像。

测试阶段包括:①输入 LR 图像:将待处理的 LR 图像表示为 x_{lr} ;②生成 HR 图像:通过训练好的生成器网络,将 LR 图像输入生成器,得到生成的 HR 图像表示为 x_{hr} ;③输出结果:根据需要对生成的 HR 图像进行后续处理,如去噪、增强等,以获得最终的 SR 重建结果 y_{final} 。

建结果 y_{final} 。

5. 影像组学特征提取及数据标准化、组学特征的选择

在 SR 的算法基础上,使用基于传统手工特征流程对算法进行验证:①对 OI 及 SRI(nii 或 nii.gz)数据使用 pyradiomics 进行特征提取^[10],分别得到 rad_feature;②对这些特征进行正则化(Z-score),将数据变化到服从 $N(0,1)$ 。计算每列特征的均值 mean、方差 std; $feature = (feature - mean) / std$,转化到 0 均值,1 方差;③对提取的组学特征 rad_feature,使用 spearman 相关系数,计算特征之间的相关性;对于相关系数大于 0.9 的特征^[10],两者保留其一,得到 rad_sel_feature。使用 LASSO 算法对数据进行交叉验证,筛选最好的惩罚系数 λ ;④筛选出系数不为 0 的特征^[10],对 rad_sel_feature 行进一步降维得到 rad_final。系数不为 0 的特征,组合成 rad_score 公式;⑤对数据进行交叉验证。使用 LightGBM 机器学习算法模型对 rad_final_train 进行训练。对 rad_final_train 进行训练,在 rad_final_val 上进行不同算法模型验证,建立预测模型;对比 LightGBM 算法预测模型,得到最佳模型。

6. 病理学诊断

患者均行宫颈癌根治性手术,有明确的病理学诊断报告,包括肿瘤病理类型,分化程度,宫体、宫旁浸润

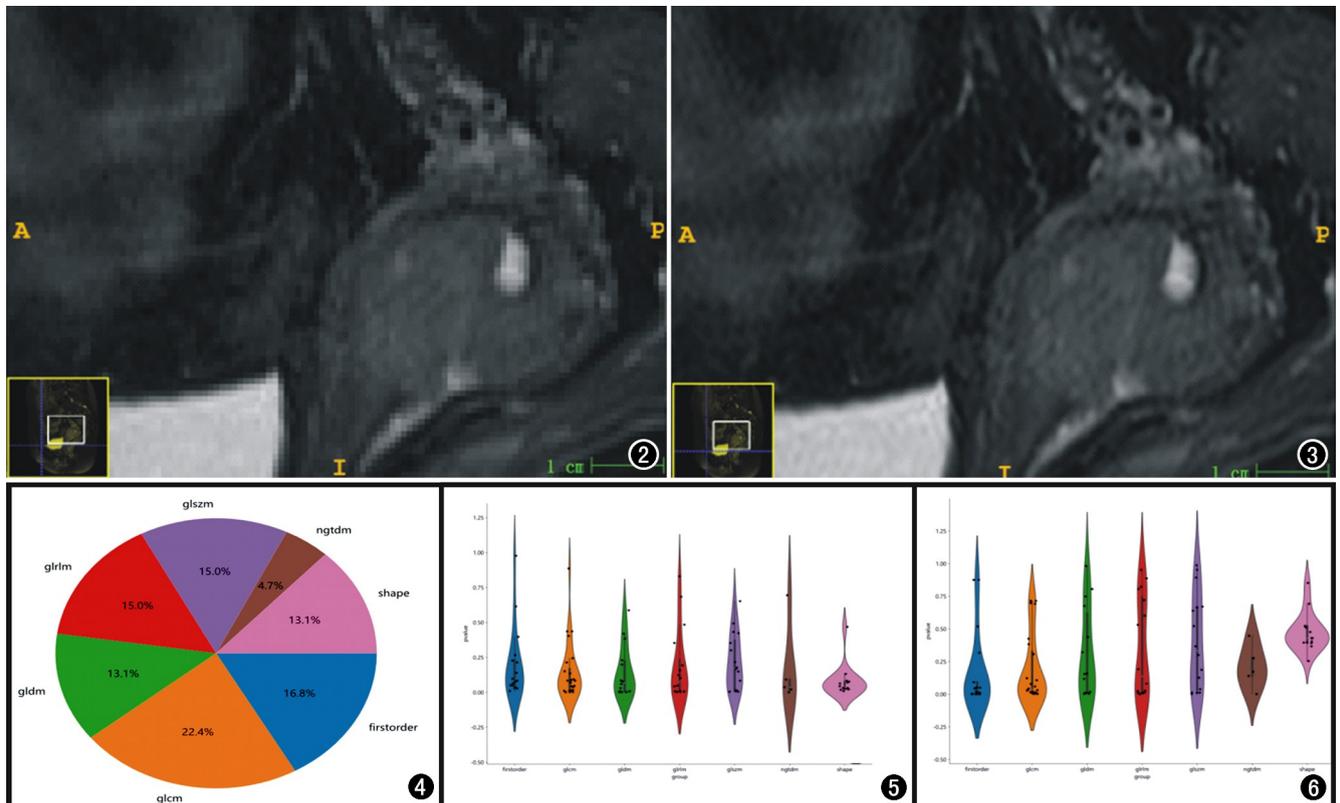


图 2 原始图像。图 3 超重建图像。图 4 OI 及 SRI 影像组学特征百分比。图 5 OI 所提取的影像组学特征分布图。图 6 SRI 所提取的影像组学特征分布图。

程度,淋巴结情况及淋巴结转移、LVSI 情况及肿瘤的各种免疫组化信息等^[6-9]。

7. 机器学习预测模型建立及统计学分析

使用 R 语言及 SPSS 22.0 软件得到常见指标验证及结果可视化,得到各模型的准确率、AUC、ROC 曲线、DCA 曲线、混淆矩阵、阳性预测值、阴性预测值、精确率、召回率、F1 分数等,给出模型预测结果。

结 果

1. 超分重建图像

本研究采用 4 倍超分重建的方法,对原始图像进行分辨率提升。经 SR 重建的图像,相比于原始图像(图 2)更加清晰。SR 重建之后的数据,具有更精细的细节表现(图 3)。

2. 基于 OI 及 SRI 影像组学特征提取及降维

分别从 OI 及 SRI 的 T₂WI 抑脂矢状面非增强序列图像中提取影像组学特征,共提取出 6 大类 MR 影像组学特征,所占百分比分别为 firstorder 16.8%, glcm 22.4%, gldm 13.1%, glszm 15.0%, glrlm 15.0%, ngtdm 4.7%, shape 13.1%(图 4)。2 种图像提取的影像组学特征分布图见图 5、6,采用 LASSO 回归分析分别对从 OI 及 SRI 提取的影像组学特征进行初步筛选,随后应用十折交叉验证筛选 LASSO 回归模型得到最优超参数 λ 值,特征系数的绝对值越大,表明其与宫颈癌 LVSI 状态之间的相关性越大,预测价值越高。LVSI 阳性组与 LVSI 阴性组输出的特征 LASSO 回归见图 7(OI)和图 8(SRI)。将获得的影像组学特征,使用 spearman 相关系数计算特征之间的相关性。对于相关系数大于 0.9 的特征,两者保留其一,得到降维后 ad_sel_feature,然后代入 LASSO 回归分析中,以 α 为惩罚系数,以 λ 为惩罚系数,以 $\lambda = 0.0222$ (OI)/ 0.0193 (SRI) 得出与 LVSI 相关的影像学特征。最终分别得到 10 个(图 9)和 5 个(图 10)具有最大预测效能的特征。

3. 评价影像组学模型预测效能、决策效能及预测概率分数

将上述最优特征建立 LightGBM 影像组学模型,应用 ROC 曲线评估 Light-GBM 影像组学模型在 OI 与 SRI 上对宫颈鳞癌

LVSI 状态的诊断效能。Delong 检验结果显示,基于 OI 与基于 SRI 建立的 LightGBM 影像组学模型预测宫颈鳞癌 LVSI 状态的 ROC 曲线下面积(area under curve, AUC)差异具有统计学意义($P = 0.0025$),且基于 SRI 影像组学模型训练集及验证集 AUC 均大于基于 OI 的影像组学模型,提示基于 SRI 预测模型的预测效能明显优于基于 OI 的预测模型。基于 OI 影像组学模型预测宫颈鳞癌 LVSI 状态,训练集 AUC = 0.795(95%CI:0.696~0.894),敏感度为 0.533,特异度为 0.920;验证集 AUC = 0.637(95%CI: 0.350~0.924),敏感度为 0.429,特异度为 0.923。基于 SRI 影像组学模型预测宫颈鳞癌 LVSI 状态,训练集 AUC = 0.817(95%CI:0.722~0.913),敏感度为 0.920,特异度为 0.717;验证集 AUC = 0.815(95%CI: 0.625~1.000),敏感度为 0.667,特异度为 0.786(图 11、12)。

使用 DCA 来评价 OI 与 SRI 所构建的基于 T₂WI 抑脂矢状面非增强序列 LightGBM 影像组学模型的临床应用价值,LightGBM 预测模型的 DCA 曲线图中训练集及验证集 SRI 均较 OI 大,有很高的决策效能。DCA 曲线图显示阈值在 0~0.2 时模型的净收益较高(图 13),即在这个阈值范围内使用该列线图对预测宫颈鳞癌 LVSI 状态的临床应用价值较高。

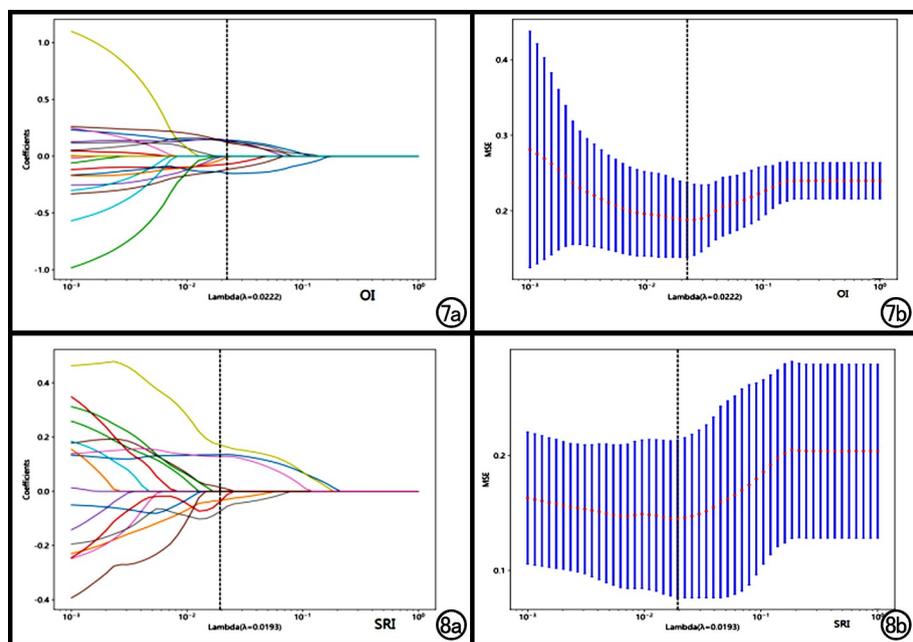


图 7 OI 图像 LASSO 回归筛选影像组学特征。LVSI 阳性组与 LVSI 阴性组输出的特征 LASSO 回归, α 为惩罚系数, $\lambda = 0.0222$ 。a) LASSO 回归系数分布图; b) LASSO 回归交叉验证图。图 8 SRI 图像 LASSO 回归筛选影像组学特征。LVSI 阳性组与 LVSI 阴性组输出的特征 LASSO 回归, α 为惩罚系数, $\lambda = 0.0193$ 。a) LASSO 回归系数分布图; b) LASSO 回归交叉验证图。

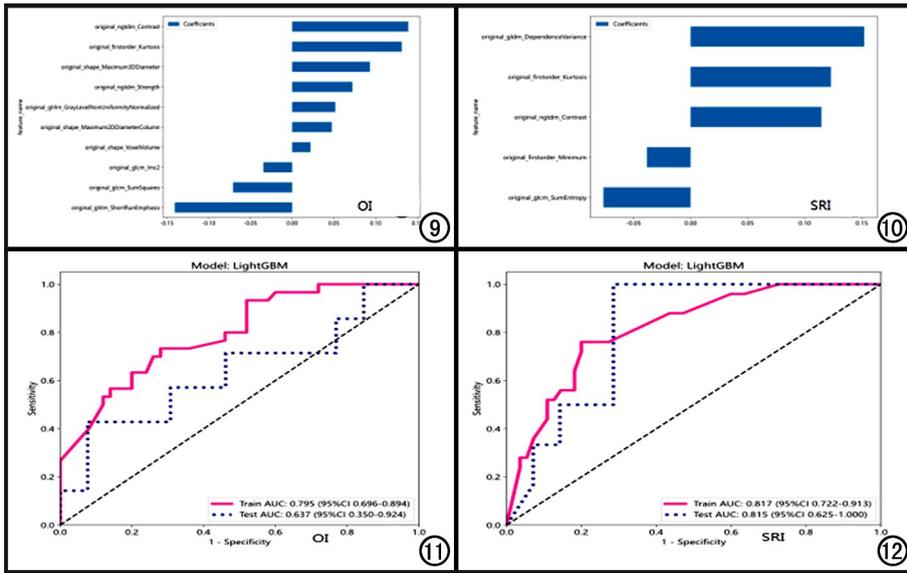


图 9 OI 所提取特征预测模型特征权重图。图 10 SRI 所提取特征预测模型特征权重图。图 11 基于 OI 影像组学模型预测宫颈鳞癌 LV-SI 状态的 ROC 曲线。图 12 基于 SRI 影像组学模型预测宫颈鳞癌 LVSI 状态的 ROC 曲线。

基于 OI 与 SRI 的 Light-GBM 影像组学模型的样本预测概率,基于 SRI 的训练集及验证集的样本预测概率均优于基于 OI(图 14)。

讨论

1.SR、LR、HR 的概念、关系及 SR 实现的方法

SR 是指在保留图像特征的前提下,将 LR 图像恢复成 HR 图像的过程。SR 是一种低级计算机视觉任务,旨在为给定 LR 图像找到相应的 HR 图像。SR 可应用于各种领域,如天文、声纳和卫星成像^[11-12],并且对于用于准确诊断的医学成像尤为重要。SR 的 MRI 往往能够为诊断提供最佳效能,但由于硬件限制,需要花费大量时间来获取这些图像,并且需要更庞大、更昂贵的设备。因此,人们对 MRI 的 SR 进行了许多研究,通常采用基于深度学习的 SR 重建方法来提高 SRI 性能。随着临床实践对医学图像 HR 的要求,基于 LR 医学图像的 SR 重建算法成为研究热点,此类方法无需改进硬件设备即可显著提高图像 SR。

实现 SR 有多种方法,其中深度学习是近年来应用较广泛的一种方式。通过训练神经网络模型,

将 LR 图像映射到 HR 图像的空间中,从而实现图像的 SR。深度学习 SR 方法通常基于卷积神经网络(convolutional neural networks, CNN)或 GAN,通过对大量 HR 图像和对应的 LR 图像进行学习,可以得到一个映射函数,将 LR 的图像映射到 HR 图像的空间中。常见的深度学习 SR 方法有 SRCNN、VDSR、ESPCN、SRGAN 等。

2.SR 重建技术的方法及临床应用

在医学图像成像过程中,由于医疗设备的成像分辨率、图像采集时间、患者所接受的辐射剂量等多种因素的限制,所获得的医学图像的分辨率是有限的^[13],但临床对 HR 医学图像有进一步的需求^[14,15]。图像分辨率是指图像中

像素的数量,它可以直接反映图像所包含的信息。图像的分辨率越高,图像的外观越清晰,单位区域包含的细节越多,从图像中可以获得的信息也越多。提高医学图像分辨率常用的方法有 3 种^[16]:①最直接的方法就是增加传感器的像素数或增加传感器的感光面积,然而这种方法往往会带来更严重的散射噪声并增加成像装置的尺寸;②通过改变影像设备的扫描方式,这种

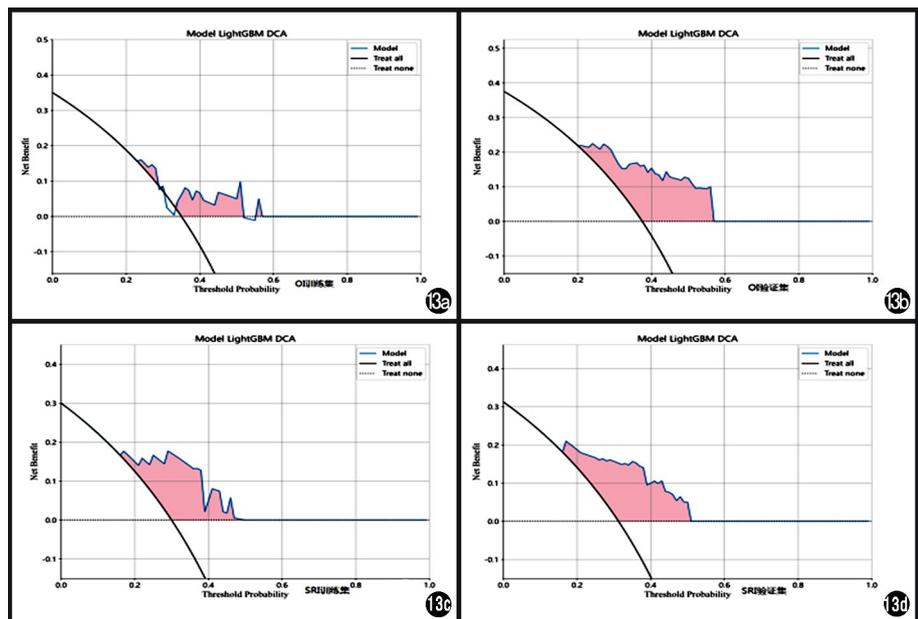


图 13 LightGBM 预测模型的 DCA 曲线图,横坐标代表阈值概率,纵坐标代表净收益,DCA 曲线训练集及验证集 SRI 均较 OI 大,有很高的决策效能。a)OI 训练集;b)OI 验证集;c)SRI 训练集;d)SRI 验证集。

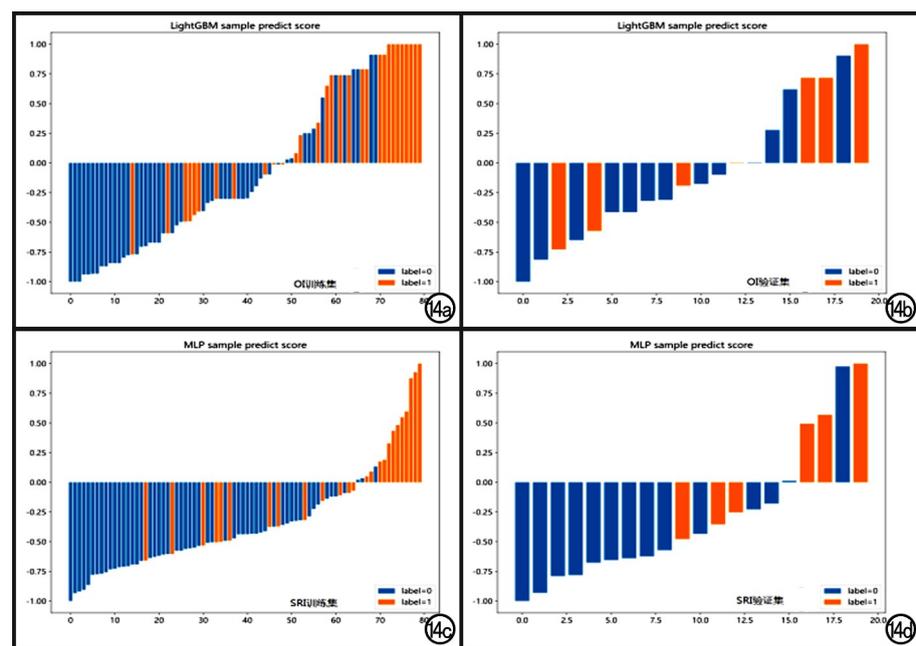


图 14 LVSI 阳性组与 LVSI 阴性组 LightGBM 机器学习模型的样本预测图,基于 SRI 的训练集及验证集的样本预测概率均优于基于 OI。a) OI 训练集;b)OI 验证集;c)SRI 训练集;d)SRI 验证集。

方式对医疗器械的精度要求较高,并且会增加辐射剂量^[13],增加医疗设备的投入;③SR 重建技术是通过从 LR 中提取信息来重建 HR 医学图像并提高医学图像的质量。Wang 等^[17]探讨使用密集残差单轴 SR 算法进行腹部 CT 三维重建在非腹膜化结直肠癌(CRC)诊断中的价值,研究发现使用该算法处理的 CT 图像清晰,取得了较好的效果,提示深度学习算法下 CT 的 HR 图像在评价 CRC 的 T 分期、EMD、EMVI 诊断效能上较原始图像有提升。Liu 等^[18]搜集 75 例膀胱患者的 CT 资料并对图像进行 SR 处理,恢复图像缺失的细节,建立 ResNet 结构结合非局部注意力机制的模型,基于深度残差网络的高分辨率 CT 图像,以高效、准确地预测膀胱肿瘤的分期;结果显示基于深度残差网络的 CT 在膀胱癌的诊断和分期中具有很高的应用价值,能有效提高诊断准确率,值得临床推广应用。Xu 等^[19]利用深度学习对基于肺癌的图像进行 SR 重建,提出稀疏编码方法用于重建 HR 纹理图像,使用全局和局部优化模型进一步提高重建图像的质量,设计了自适应多尺度遥感影像 SR 网络,所提出的工作不仅改善了主观视觉效果,还通过更准确的边缘构造增强了鲁棒性。统计评估器用于测试所提议方案的可行性。Zhu 等^[20]提出了用于单图像 SR 的双重注意力机制网络(dual attention mechanism network,DAMN),直接提取 LR 图像的特征以保留特征信息,构建了几个独立的 DAMN 模块来提取高频细节,通过上采样操作得到重建的 HR 图像。DAMN 能够更好地还原

图像轮廓特征,获得更高的峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性(structural similarity,SSIM)和更好的视觉效果。通过 DAMN 重建方法,放射科医师可以在不增加辐射暴露和扫描时间的情况下获得更高的图像质量,增加诊断早期肺癌的信心,为临床专家选择治疗方案、制定随访策略提供依据。

3.MR 超分辨率方法

传统 MRI 存在加速因子低、迭代重建时间长、参数选择困难、计算复杂度高问题^[21]。深度学习可以从大量数据中自动学习特征表示,从而实现高度非线性映射。深度学习引入快速 MRI 重建中,得到了业界的广泛关注和支持^[21]。基于 DL 的 MRI 重建方法避免了传统基于模型的重建算法

中手动调整参数的困难,在实际临床应用中可以显著缩短扫描时间和重建时间,具有潜在的临床应用前景^[22]。目前,基于深度学习的 MRI 重建方法主要分为两类:①数据驱动的端到端深度学习重建方法;②基于模型的深度学习重建方法^[21]。

4.SR 重建技术在本研究中的应用

针对医学图像领域独特的 SR 重建算法,基于 MR 图像,本研究使用 GAN 进行影像数据的 SR 重建。基于 GAN 的 SR 重建技术是一种通过学习 LR 图像和对应的 HR 图像之间的映射关系,实现将 LR 图像转换为 HR 图像的方法。GAN 由生成器(Generator)和判别器(Discriminator)两个神经网络组成^[8]。生成器网络接受输入的 LR 图像,并尝试生成一个 HR 图像,而判别器网络则评估生成的图像与真实 HR 图像之间的差异。生成器的目标是生成逼真的 HR 图像,使得判别器无法区分生成图像与真实图像之间的差异。本研究通过四倍的 SR 重建,显示图像的分辨率越高,图像的外观越清晰,单位区域包含的细节越多;并在 OI 与 SRI 中建立 LightGBM 影像组学模型。基于 OI 影像组学模型预测宫颈鳞癌 LVSI 状态,训练集 AUC=0.795(95%CI:0.696~0.894),敏感度为 0.533,特异度为 0.920;验证集 AUC=0.637(95%CI:0.350~0.924),敏感度为 0.429,特异度为 0.923;基于 SRI 影像组学模型预测宫颈鳞癌 LVSI 状态,训练集 AUC=0.817(95%CI:0.722~0.913),敏感度为 0.920,特异度为 0.717;验证集 AUC=0.815

(95%CI:0.625~1.000), 敏感度为 0.667, 特异度为 0.786。两组图像训练集和验证集中均显示出良好的校准和区分能力, SRI 较 OI 影像组学模型的诊断效能明显提高, DCA 结果表明模型具有较高的临床应用价值。本研究结果表明, 基于 MR 深度迁移学习 SRI 影像组学模型对术前预测宫颈癌 LVSI 状态具有良好的应用价值, 较 OI 影像组学模型的诊断效能有所提高, 有助于更好地指导临床治疗决策。基于深度学习的医学图像 SR 重建技术能够提供更丰富的病灶信息, 减轻专家的诊断压力, 提高诊断效率和准确性。基于深度学习的医学图像 SR 重建技术有助于提高图像质量, 为专家的诊断提供帮助, 为计算机后续的分析识别任务打下坚实的基础^[23]。

本研究存在以下局限性: 首先, 本研究为单中心研究, 样本量相对较小, 尽管本研究的样本量足以显示 GAN 的主观和客观优越性, 但仍需要进一步的大规模多中心研究进行验证; 其次, 采用了厂商特定的商业化 SR-DLR 算法, 目前尚不清楚该算法的详细训练和验证过程; 最后, 诊断性能尚需要进一步提高。

综上所述, 本研究采用超分重建技术对原始数据进行重建, 得到较高清的 HR 图像数据, 提高了图像质量, 通过对 OI 与 SRI 图像的对比分析, 提示由 SRI 图像得到的结果更加精准。基于深度学习的 SR 技术在医学图像领域仍有很大发展空间, 但有很多尚未完善的工作, 需要更多的研究者开展富有创新性的工作来提升 SR 技术。

参考文献:

[1] Ferlay J, Colombet M, Soerjomataram I, et al. Cancer statistics for the year 2020: An overview[J]. *Int J Cancer*, Apr 5. DOI:10.1002/ijc.33588.

[2] 杨易, 冯峰, 傅爱燕, 等. 基于 T₂WI 和增强 MRI 影像组学列线图预测宫颈鳞癌淋巴脉管间隙浸润[J]. *放射学实践*, 2021, 36(4): 494-501.

[3] 栾一祎, 卢佳翔, 秦凤英, 等. DCE-MRI 联合临床及血管病理参数预测早期宫颈癌淋巴结转移的价值[J]. *放射学实践*, 2023, 38(9): 1145-1150.

[4] Li Z, Li H, Wang S, et al. MR-based radiomics nomogram of cervical cancer in prediction of the lymph vascular space invasion preoperatively[J]. *J Magn Reson Imaging*, 2019, 49(5): 1420-1426.

[5] 何月明, 陈思琳, 马跃昆, 等. 基于 MR 组学特征的诺模图(Nomogram)在术前预测宫颈癌淋巴脉管间隙侵犯中应用的初步研究[J]. *临床放射学杂志*, 2022, 41(8): 1565-1574.

[6] 罗锦文, 朱光斌, 关玉宝, 等. 基于 MR 纹理特征的 RBF 神经网络在 FIGO II 期宫颈癌宫旁浸润中的诊断价值[J]. *中国医学计算机成像杂志*, 2022, 28(4): 390-396.

[7] 何月明, 范良生, 罗锦文, 等. 基于 MR-T₂WI 纹理特征的决策树分类分析在 FIGO-II 期宫颈癌宫旁浸润中的诊断价值[J]. *放射学实践*, 2020, 35(12): 1560-1565.

[8] 傅继彬, 曹玉笠. 基于门控卷积和 SENet 的双判别生成对抗网络图像修复模型[J]. *计算机应用*, 2023, 43(S1): 212-216.

[9] 林俊, 何港华, 蔡耀仪, 等. 基于 SA-VAEGAN 的浮选精矿品位检测[J]. *矿业研究与开发*, 2023, 43(1): 177-183.

[10] 林子淮, 李欣明, 全显跃. 基于机器学习 CT 影像组学特征联合血清学特征模型预测高出血风险食管静脉曲张[J]. *中国 CT 和 MRI 杂志*, 2023, 21(6): 93-96.

[11] Park J, Bonhwa KU, Jin Y, et al. Side scan sonar image super resolution via region-selective sparse coding [J]. *IEICE T INF SYST*, 2019, 102(1): 210-213.

[12] Shermeyer J, Etten AV. The effects of super-resolution on object detection performance in satellite imagery[J]. 2019, arXiv:1812.04098v2.

[13] 成云凤, 汪伟. 基于医学图像的超分辨率重建算法综述[J]. *北京生物医学工程*, 2019, 38(5): 535-543.

[14] Qiu D, Zhang S, Liu Y, et al. Superresolution reconstruction of knee magnetic resonance imaging based on deep learning [J]. *Comput Methods Programs Biomed*, 2019, 187: 105059.

[15] Dencks S, Piepenbrock M, Opacic T, et al. Clinical pilot application of super-resolution us imaging in breast cancer [J]. *IEEE Trans Ultrason Ferroelectr Freq Contro*, 2019, 66(3): 517-526.

[16] Qiu D, Zheng L, Zhu J, et al. Multiple improved residual networks for medical image super-resolution [J]. *Future Gener Comput Syst*, 2021, 116(1): 200-208.

[17] Wang X, Guo C, Zha Y, et al. Diagnosis of non-19 computer engineering and applications peritonealized colorectal cancer with computerized tomography image features under deep learning [J]. *Contrast Media Mol Imaging*, 2022, 2022: 1886406.

[18] Liu D, Wang S, Wang J. The effect of CT high-resolution imaging diagnosis based on deep residual network on the pathology of bladder cancer classification and staging [J]. *Comput Methods Programs Biomed*, 2022, 215: 106635.

[19] Xu J, Liu W, Qin Y, et al. Image super-resolution reconstruction method for lung cancer CT-scanned images based on neural Network [J]. *Biomed Res Int*, 2022, 2022: 3543531.

[20] Zhu D, Sun D, Wang D. Dual attention mechanism network for lung cancer images super-resolution [J]. *Comput Methods Programs Biomed*, 2022, 226: 107101.

[21] 施俊, 汪琳琳, 王珊珊, 等. 深度学习在医学影像中的应用综述 [J]. *中国图象图形学报*, 2020, 25(10): 1953-1981.

[22] Qiu D, Cheng Y, Wang X. Gradual back-projection residual attention network for magnetic resonance image super-resolution [J]. *Comput Methods Programs Biomed*, 2021, 208: 106252.

[23] 刘伟, 文戈, 董天发, 等. 基于 MRI 影像组学预测宫颈癌 Ki-67 表达水平 [J]. *放射学实践*, 2023, 38(11): 1436-1441.

(收稿日期: 2023-08-14 修回日期: 2023-11-29)