

基于影像组学的机器学习方法预测腰背筋膜炎

车明昊, 宋明欣, 冉张申, 秦 健

山东第一医科大学第二附属医院医学影像科, 山东 泰安

收稿日期: 2026年3月17日; 录用日期: 2026年4月11日; 发布日期: 2026年4月20日

摘 要

目的: 腰背部筋膜炎是下背痛的常见但易被忽视的病因, 早期识别筋膜的异常变化对于发现下背痛的隐匿病因至关重要。因此, 本研究旨在采用基于腰椎软组织磁共振成像的影像组学机器学习方法, 分析下背痛患者腰背部筋膜的变化特征。方法: 我们对2021年9月至2023年9月期间380例腰痛患者的腰椎磁共振成像(MRI)进行了回顾性分析, 收集临床资料。使用七种不同的分类算法建立基于Radscore的分类预测模型, 并通过受试者工作特征(ROC)曲线评估其预测性能, 选择表现最佳的模型作为Radiomics模型。将患者随机分配到训练组(70%, n = 266)或验证组(30%, n = 114), 分别建立临床模型、Radiomics模型和Nomogram模型, 并通过ROC曲线评估其预测性能。结果: 在七种机器学习模型中, Lasso模型的诊断性能最好, 其曲线下面积(AUC)为0.83。因此, 我们选择Lasso模型来构建影像组学模型。Nomogram模型结合了临床和影像组学特征。在训练集和验证集中, 该模型表现良好, AUC分别为0.97和0.96。AUC和决策曲线分析(DCA)表明, Nomogram模型能够有效诊断腰筋膜炎。结论: 综上所述, 我们构建了一个基于临床特征和影像组学特征的Nomogram模型, 旨在帮助临床医生通过软组织磁共振成像来识别和预测腰背筋膜炎。

关键词

筋膜, 影像组学, 腰痛, Nomogram, 磁共振成像

Prediction of Low Back Fasciitis by Machine Learning Method Based on Radiomics

Minghao Che, Mingxin Song, Zhangshen Ran, Jian Qin

Department of Medical Imaging, The Second Affiliated Hospital of Shandong First Medical University, Tai'an Shandong

Received: March 17, 2026; accepted: April 11, 2026; published: April 20, 2026

Abstract

Objective: Lumbar and dorsal fasciitis is a common but often overlooked cause of lower back pain.

文章引用: 车明昊, 宋明欣, 冉张申, 秦健. 基于影像组学的机器学习方法预测腰背筋膜炎[J]. 临床医学进展, 2026, 16(4): 3547-3558. DOI: 10.12677/acm.2026.1641619

Early identification of abnormal changes in the fascia is crucial for discovering the hidden causes of lower back pain. Therefore, this study aims to use radiomics machine learning methods based on magnetic resonance imaging of lumbar soft tissues to analyze the changing characteristics of the lumbar and dorsal fascia in patients with lower back pain. Methods: We conducted a retrospective analysis of lumbar magnetic resonance imaging (MRI) of 380 patients with low back pain from September 2021 to September 2023 and collected clinical data. Seven different classification algorithms were used to establish a classification prediction model based on Radscore, and its prediction performance was evaluated through the receiver operating characteristic (ROC) curve. The model with the best performance was selected as the Radiomics model. Patients were randomly assigned to the training group (70%, n = 266) or the validation group (30%, n = 114). Clinical models, Radiomics models, and Nomogram models were established respectively, and their predictive performance was evaluated through the ROC curve. Result: Among the seven machine learning models, the Lasso model has the best diagnostic performance, with an area under the curve (AUC) of 0.83. Therefore, we chose the Lasso model to construct the radiomics model. The Nomogram model combines clinical and radiomics features. In the training set and validation set, the model performed well, with AUCs of 0.97 and 0.96 respectively. AUC and decision curve analysis (DCA) indicated that the Nomogram model could effectively diagnose lumbar fasciitis. Conclusion: In summary, we have constructed a Nomogram model based on clinical and radiomics features, aiming to assist clinicians in identifying and predicting lumbar fasciitis through soft tissue magnetic resonance imaging.

Keywords

Fascia, Radiomics, Lower Back Pain, Nomogram, Magnetic Resonance Imaging

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

腰痛是一种非常常见的问题，它对个人、家庭以及社会都有巨大的影响。在过去 25 年中，全球因腰痛导致的残疾增加了 54% [1][2]。腰痛可能由身体的任何解剖结构引起，骨骼、椎间盘、关节、韧带、肌肉等通常被认为是导致腰痛的常见原因[3]，但筋膜却常常被忽视。最近的研究表明，筋膜可能是导致腰痛的潜在根源，其组织内部的炎症反应与微观损伤被认为是引发疼痛的关键机制[4]。因此，有必要准确诊断由筋膜引起的腰痛，并尽早进行预防和治疗。

已有研究证明，常规的磁共振成像(MRI)能够更清晰地观察筋膜的解剖结构及其变化[5]-[7]。与计算机断层扫描(CT)相比，MRI 在筋膜及其相邻结构的解剖学区分度更高，并且在识别细微形态差异方面更为可靠。然而，MRI 的诊断结果往往取决于放射科医生的经验，这使得对筋膜进行早期和详细的观察变得困难。为了克服检查者经验及主观性对诊断结果的影响，对于影像医生而言，找到一种更客观、稳定且高效的诊断方法是一个挑战。

影像组学能够从影像图像中提取出大量定量特征，并通过定量分析来进行诊断和预测。它具有客观性、非侵入性和可利用性等优点[8]。在之前的研究中，我们通过建立影像组学 Nomogram 模型取得了良好的诊断效果[9]。

在本研究中，我们进一步扩大病例数量，并基于二维 MRI 影像提取放射组学特征。为筛选出最佳的影像组学模型，我们评估了 7 种不同的机器学习模型，包括：lasso、XGBlinear、SVMradial、SVMlinear、RF、NNet 和 KNN 模型。此外，我们还整合了临床因素，以构建一个更全面、更具临床实用性的预测模

型，从而有效降低漏诊率，并为临床治疗方案的选择提供精准依据。

2. 材料和方法

2.1. 病人

机构审查委员会批准了这项回顾性研究，并且未要求签署知情同意书。本研究的主要样本群是从本机构的图像存档与通信系统(PACS)数据库中获取的，这些样本来自 2021 年 9 月至 2023 年 9 月因腰痛而接受腰椎磁共振成像检查的患者。

本研究的纳入标准如下：

(1) 经临床及磁共振成像诊断确认为浅层腰肌筋膜炎(即下背痛症状)的患者作为实验组。背部浅层筋膜炎的定义标准如下：

临床表现为腰部压痛，局部软组织僵硬。部分患者能在疼痛部位触及颗粒状的质硬结节。磁共振成像(MRI)显示，在矢状面上，腰筋膜浅层出现条纹状或层状的异常信号，表现为 T1WI 低信号和 T2WI 高信号，在 T2 压脂像上显示为明显的高信号。在轴位 T2 成像中，沿中线排列的高信号呈三角形，靠近胸腰筋膜。

(2) 有下背部疼痛症状但腰椎磁共振成像未显示有筋膜炎的患者作为对照组。

本研究的排除标准如下：

- (1) 影像资料不全或影像质量欠佳。
- (2) 患有局部感染、腰椎骨折、脊柱肿瘤或转移病灶、脊柱手术、椎间盘手术以及下背部创伤的患者。
- (3) 近期接受的康复理疗可能会导致筋膜暂时性水肿。
- (4) 存在传染性水肿或与内脏疾病相关的水肿。

最后，共有 380 名患者符合标准，其中包括 193 名浅表筋膜炎患者和 187 名未患有浅表筋膜炎患者。然后，所有患者按照 7:3 的比例被随机分配到训练队列($n = 266$)和验证队列($n = 114$)中。

2.2. 检测仪器

本实验中的所有患者均接受了脊柱的磁共振成像检查，使用的是 3.0 T MR 系统(Discovery MR750，通用电气医疗集团，美国威斯康星州密尔沃基市)。矢状位 T1 加权像(T1WI)、矢状位 T2 加权像(T2WI)、矢状位 T2 加权脂肪抑制像(T2WI-fs)、轴位 T2 加权图像的参数如表 1 所示。

Table 1. Parameters of sagittal T1-weighted imaging

表 1. 矢状位 T1 加权像的参数

	TR (ms)	TE (ms)	NEX	层厚(mm)	层间距(mm)
矢状位 T1WI	560	Min Full	4.0	4	2
矢状位 T2WI	3000	100	2.0	4	2
矢状位 T2WI-fs	1800	120	2.0	4	2
轴位 T2WI	3414	120	2.0	3.5	0.5

TR: 重复时间; TE: 回波时间; NEX: 激励次数。

2.3. 图像及临床信息采集

通过医疗记录获取所有临床数据，包括年龄、性别、Cobb 角、平均脂肪厚度。平均脂肪厚度是根据韦斯特的研究方法在 L1 椎体的后上角和 L5 椎体的后下水平处测量得出[10]。从 PACS 中检索脊柱的磁

共振轴位图像，并将其以数字成像与通信医学(DICOM)格式保存下来。

所有的磁共振成像检查均由两名在骨骼肌肉成像领域拥有 10 年经验的放射科医生负责。如果出现分歧，将由两名阅片者共同对扫描结果进行评估以做出判断。

2.4. 放射组学模型中的病变分割与特征提取

在轴位磁共振成像(MRI)图像上，通过 ITK-SNAP 软件(版本 3.6.0，网址：<http://www.itksnap.org/>)手动绘制感兴趣区域(ROI)以进行分割[11]。将脊柱 MRI 的 DICOM 格式图像导入该软件进行轮廓勾勒。为了评估分割的可用性，由具有 3 年 MRI 解读经验的两名放射科医生绘制 ROI。ROI 包括竖脊肌和多裂肌以及位于肌肉后方、包含筋膜的脂肪部分，这些部分位于 L4/5 椎间盘中间水平(图 1)。一周后，由具有 5 年 MRI 解读经验的另一位放射科医生再次绘制这些 ROI。如有差异，需在协商后重新划定。




Figure 1. The mid-section of the L4/5 intervertebral disc was scanned using axial T2-weighted imaging technique to determine the region of interest (ROI). This region encompasses the erector spinae and multifidus muscles at the level of the intervertebral disc, as well as the portion of fat behind the muscles that includes the fascia

图 1. 采用轴位 T2 加权成像技术对 L4/5 椎间盘的中间部分进行扫描，以确定感兴趣区域(ROI)。该区域包括该椎间盘所在位置的竖脊肌和多裂肌，以及肌肉后方包含筋膜的那部分脂肪

在特征提取之前，所有图像均根据之前的协议[9]进行重新采样和标准化。为了避免数据异质性偏差，将体素大小重新采样为 $1 \times 1 \times 1 \text{ mm}^3$ ，使用 25 个灰度值宽度进行灰度值的离散化，并在特征提取前对灰度值进行标准化。使用 AK 软件(分析工具包，版本 3.2.0，通用电气医疗集团，中国)和 pyradiomics(版本 3.0.1，<https://pyradiomics.readthedocs.io/en/latest/>)进行影像组学特征提取。

2.5. 特征选择

采用最小冗余最大相关(mRMR)和最小绝对收缩和选择算子(LASSO)对提取出的特征进行筛选。首先，使用 mRMR 方法来剔除冗余和无关的特征，保留 30 个最具相关性的特征。然后，应用 LASSO 方法来选择最优的特征子集，以构建最终模型。

2.6. 预测模型的构建与评估

对降维后的特征进行 Radscore 计算，并将其导入 R(版本 4.0.2，<http://www.r-project.org/>)中，分别构建了 Lasso、XGBlinear、SVMradial、SVMlinear、RF、NNet 和 KNN 模型。采用 10 倍交叉验证进行训

练, 绘制了受试者工作特征(ROC)曲线。

通过比较曲线下面积(AUC)、准确率、灵敏度和特异性, 我们选择了最优的一项来建立最终的 Radiomics 模型。

2.7. 预测模型构建与诊断验证

临床变量包括年龄、性别、平均脂肪厚度以及磁共振矢状位 Cobb 角。首先, 对临床风险因素进行单因素逻辑回归分析, 选出具有统计学意义($p < 0.05$)的指标。然后, 将这些指标纳入多因素逻辑回归分析中, 筛选独立预测因子并构建临床模型。此外, 将最终的影像组学特征和独立的临床风险变量结合起来, 创建 Nomogram 模型。使用 DeLong 检验来区分不同模型的受试者工作特征曲线之间的差异。使用校准曲线分析和 Hosmer-Lemeshow 检验来评估 Nomogram 模型的拟合度。

2.8. 统计分析

本研究的所有统计分析均使用 R 软件(版本 4.0.2, 网址: <https://www.r-project.org/>)进行。所有统计学显著性水平设定为 $p < 0.05$ 。

3. 结果

3.1. 临床特征

将 380 名患者(男性 223 名, 女性 157 名; 平均年龄 45.5 ± 16 岁; 年龄范围 15~85 岁), 包括 187 名患有下背部浅层筋膜炎的患者以及 193 名符合标准的未患下背部浅层筋膜炎的个体, 随机分配到训练组 ($n = 266$)和验证组($n = 114$)。从表 2 中我们可以看出, 训练组和测试组在年龄、矢状面膝关节角和平均脂肪厚度方面的差异有统计学意义。性别方面无显著差异。

Table 2. Diagnostic performance table of radiomics, clinical, and Nomogram models in the training and validation groups
表 2. 在训练组和验证组中, 放射组学、临床和 Nomogram 模型的诊断效果表

特征	训练集($n = 266$)			测试集($n = 114$)			
	正常组	异常组	p -values	正常组	异常组	p -values	
病例数	129	137		58	56		
性别(%)	男性	52 (40.3)	28 (39.4)	29 (50)	22 (39.3)		
	女性	77 (59.7)	47 (60.6)	29 (50)	34 (60.7)	0.3362	
年龄	平均值 \pm 标准差	39.6 ± 14.6	51.8 ± 15.3	<0.0001	37.6 ± 15.1	51.6 ± 14.3	<0.0001
Cobb 角	平均值 \pm 标准差	32.9 ± 4.6	24.1 ± 4.6	<0.0001	32.4 ± 3.0	22.9 ± 6.5	<0.0001
平均脂肪厚度(cm)	平均值 \pm 标准差	1.5 ± 0.7	2.4 ± 0.9	<0.0001	1.5 ± 0.7	2.3 ± 0.8	<0.0001

3.2. Radiomics 模型的构建与验证

在特征选择与 Radscore 构建过程中, 首先利用 mRMR 算法去除冗余和不相关特征, 然后通过 10 倍交叉验证结合 LASSO 回归确定最优正则化参数 λ 。经测试, 选择对应于最小方差模型的 λ 值作为最佳值 ($\lambda = 0.014$) (图 2)。在此最优参数下, 共选择了 13 个具有非零系数的特征(图 3), 并计算出各特征的回归系数。通过将选定特征乘以其系数并求和来计算 Radscore, 最终的 Radscore 公式为:

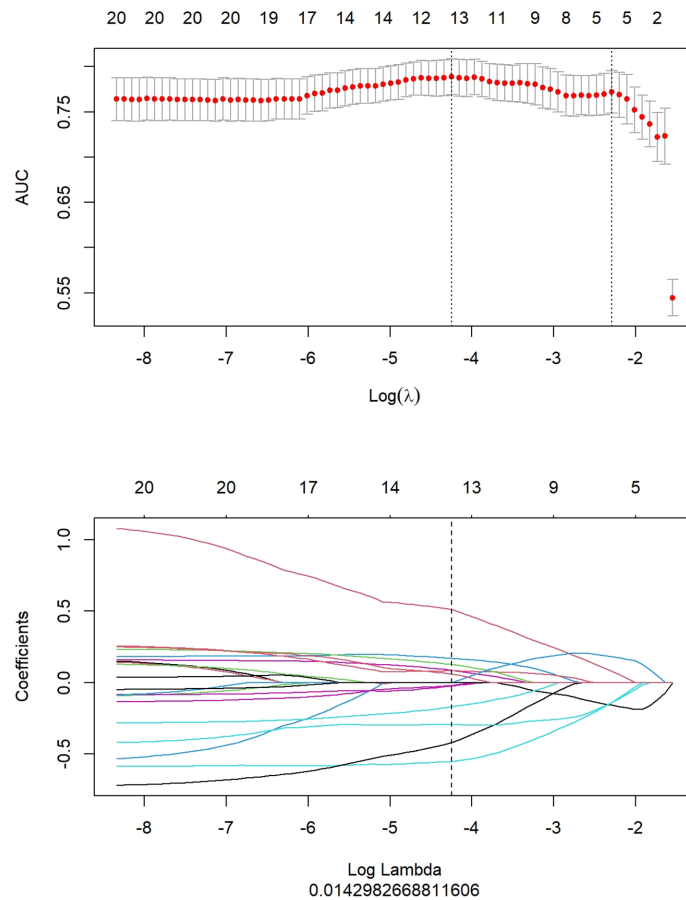


Figure 2. The hyperparameter (λ) in the LASSO model was selected through 10-fold cross-validation based on the binomial deviance minimization criterion. The binomial deviance was plotted as a function of $\log(\lambda)$. The finally selected optimal λ value was 0.0142. LASSO: Least Absolute Shrinkage and Selection Operator

图 2. 通过基于二项式偏差最小值标准的 10 倍交叉验证，对 LASSO 模型中的超参数(λ)进行了选择。二项式偏差被绘制成对数(λ)的函数。最终选定的最优 λ 值为 0.0142。LASSO：最小绝对收缩与选择算子

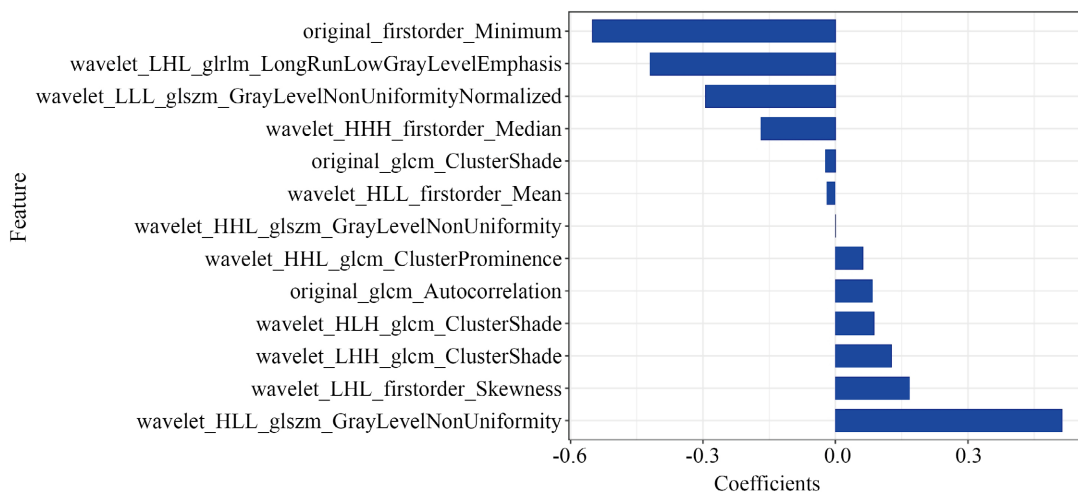


Figure 3. Rad-score histogram: The y-axis represents the 13 selected radiomic features, while the x-axis indicates the coefficients of these features

图 3. Rad-score 直方图: y 轴表示所选取的 13 项影像组学指标, x 轴表示这些指标的系数

$$\begin{aligned}
 \text{"Radscore} = & -0.551 * \text{original_firstorder_Minimum} \\
 & + 0.088 * \text{wavelet_HLH_glcm_ClusterShade} \\
 & + -0.419 * \text{wavelet_LHL_glrlm_LongRunLowGrayLevelEmphasis} \\
 & + 0.513 * \text{wavelet_HLL_glszm_GrayLevelNonUniformity} \\
 & + 0.169 * \text{wavelet_LHL_firstorder_Skewness} \\
 & + -0.294 * \text{wavelet_LLL_glszm_GrayLevelNonUniformityNormalized} \\
 & + -0.023 * \text{original_glcm_ClusterShade} \\
 & + 0.083 * \text{original_glcm_Autocorrelation} \\
 & + 0.128 * \text{wavelet_LHH_glcm_ClusterShade} \\
 & + 0 * \text{wavelet_HHL_glszm_GrayLevelNonUniformity} \\
 & + -0.169 * \text{wavelet_HHH_firstorder_Median} \\
 & + -0.02 * \text{wavelet_HLL_firstorder_Mean} \\
 & + 0.062 * \text{wavelet_HHL_glcm_ClusterProminence} + 0.069\text{"}
 \end{aligned}$$

将 Radscore 分别纳入 Lasso、XGblinear、SVMradial、SVMlinear、RF、NNet、KNN 这七种分类器中以构建分类模型，其 AUC、特异性、敏感性和准确率如图 4 和表 3 所示。




Figure 4. AUC curves of seven machine learning models
图 4. 七个机器学习模型的 AUC 曲线

Table 3. Accuracy, sensitivity, and specificity of seven models
表 3. 七种模型的准确率、灵敏度、特异性

模型	Radscore.lasso	Radscore.xgblinear	Radscore.svmRadial	Radscore.svmLinear	Radscore.rf	Radscore.nnet	Radscore.knn
准确率	0.86	0.79	0.79	0.77	0.76	0.74	0.76
灵敏度	0.76	0.60	0.52	0.68	0.48	0.72	0.44
特异性	0.94	0.94	1.0	0.77	0.92	0.69	1.0

最后，选择了 Lasso 分类器来构建最佳的 Radiomics 模型。Lasso 的 AUC、特异性、敏感性和准确率分别为 0.83、0.86、0.76 和 0.94 (图 4 和表 3)。Radiomics 模型的 AUC 在训练集中的值为 0.83 (95%置信区间: 0.79~0.88)，其特异性、敏感性和准确率分别为 82.2%、72.2% 和 77.06%。在测试集上，AUC 为 0.83 (95%置信区间: 0.76~0.91)，其特异性、敏感性和准确率分别为 84.4%、64.3% 和 74.5% (表 4、图 5)。

Table 4. Diagnostic performance of radiomics, clinical, and Nomogram models in the training and validation sets

表 4. 在训练集和验证集，放射组学、临床和 Nomogram 模型的诊断效果表

模型		准确率	准确率	准确率	灵敏度	特异性	AUC (95%CI)	p-value of DeLong-Test	
		(%)	Lower (%)	Upper (%)	(%)	(%)	(%)	vs 放射组学	vs Nomogram
临床模型	训练集	89.84	85.57	93.20	91.24	88.37	(0.63~0.81)	<0.001	0.064
	验证集	89.47	82.33	94.44	83.92	94.82	(0.59~0.85)	0.002	0.319
放射组学	训练集	77.06	71.54	81.98	72.26	82.17	(0.87~0.96)	-	<0.001
	验证集	74.56	65.55	82.25	64.28	84.48	(0.71~0.96)	-	<0.001
Nomogram	训练集	92.48	88.62	95.34	89.05	96.12	(0.88~0.96)	<0.001	-
	验证集	92.10	85.54	96.32	1.00	86.56	(0.73~0.96)	<0.001	-

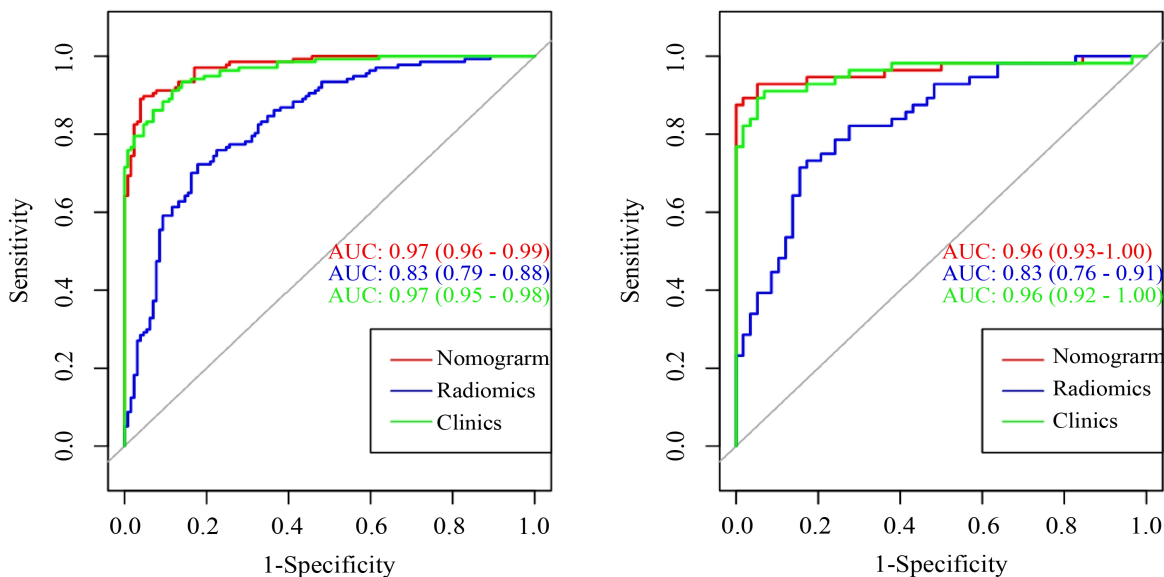


Figure 5. AUC values of clinical factors, radiomics model, and Nomogram model in the training and validation groups

图 5. 训练组和验证组中临床因素、影像组学模型以及 Nomogram 模型的 AUC 值

3.3. Nomogram 的构建

构建了一个包含影像组学特征和临床特征的 Nomogram 模型(图 6)。

$$\begin{aligned}
 \text{"Nomoscore} &= (\text{Intercept}) * 5.15088420107063 \\
 &+ \text{AGE} * 0.0908766909591725 \\
 &+ \text{cobb_sagittal_angle} * 0.434307849852666 \\
 &+ \text{Average_fat_thickness} * 1.61380017073753 \\
 &+ \text{Radscore} * 0.863471409335681\text{"}
 \end{aligned}$$




Figure 6. The Nomogram model integrates indicators such as age, sagittal Cobb angle, average fat thickness, and radiomic score, serving as a radiomics-based predictive model developed from training samples

图 6. Nomogram 模型结合了年龄、矢状面 Cobb 角、平均脂肪厚度以及放射评分等指标，基于训练样本开发的影像组学预测模型

Nomogram 模型在训练组中的 AUC 值为 0.97 (95%置信区间为 0.96~0.99)，其准确率、敏感度和特异度分别为 92.5%、89.0%和 96.1%。在验证组中，Nomogram 模型也表现出良好的预测性能，其 AUC 值为 0.96 (95%置信区间为 0.93~1.00)，准确率、敏感度和特异度分别为 92.1%、100.0%和 86.5% (图 5 和表 4)。

Nomogram 的预测性能情况如图 6 所示。校准曲线如图 7 所示。校准曲线在训练集和验证集中均表现出良好的校准效果，Hosmer-Lemeshow 检验的 p 值分别为 0.14 和 0.25，对于训练组和验证组而言，这些 p 值无显著差异。

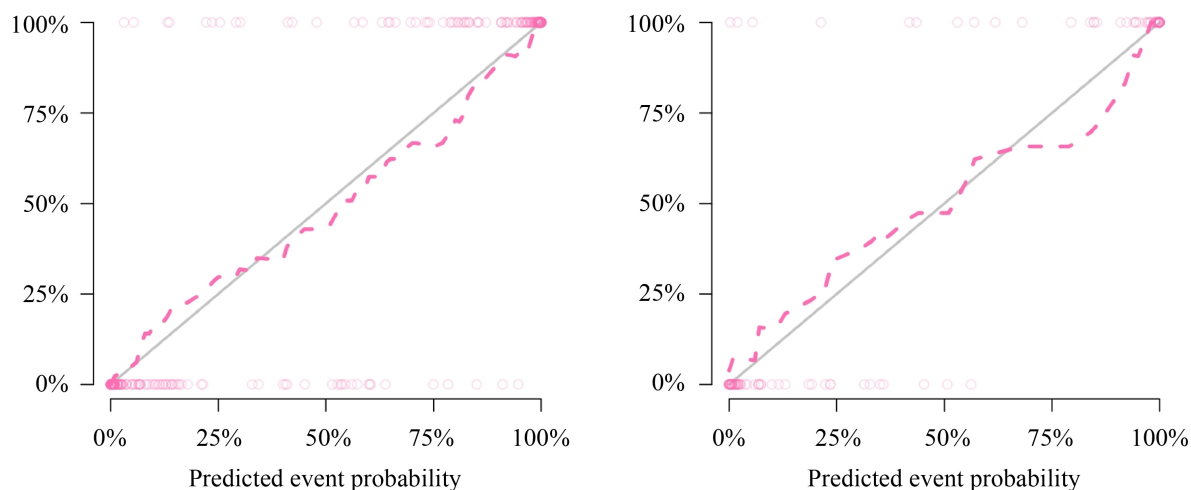


Figure 7. Calibration curves of the nomogram for the training set (left panel) and validation set (right panel), illustrating the relationship between predicted and observed values. The distance between the dashed line and the solid line reflects the model's predictive capability, with this distance being inversely proportional to predictive performance

图 7. 训练组(左图)和验证组(右图)的诺莫图校准曲线，展示了预测值与真实值之间的关系。虚线与实线之间的距离反映了模型的预测能力，该距离与预测能力呈反比关系

最后，我们利用决策曲线来评估该模型的临床实用性(图 8)。结果显示，在约 4%~25%及 50%~82% 的阈值概率范围内，Nomogram 模型的净获益始终明显高于临床模型，在约 25%~50%的阈值概率范围内，

Nomogram 模型与临床模型的决策曲线较为接近,提示两者在该区间内的增量获益有限;然而, Nomogram 模型在该范围内仍维持较高的净获益水平,说明即使在模型间差异不明显的情況下,其依然能够提供具有临床意义的决策支持。通过 DeLong 检验,放射组学模型与联合 Nomogram 模型在训练组和验证组中的 AUC 值均存在显著差异,其 p 值均小于 0.001 (表 4)。




Figure 8. Decision Curve Analysis (DCA) of the Radiomics Nomogram. The DCA demonstrates that the radiomics nomogram outperforms the clinical model in predicting lumbar fascial changes. The red and blue lines represent the net benefits of the radiomics model and the clinical model, respectively. The green line represents the hypothetical scenario where all patients have fascial changes, while the black line represents the scenario where none of the patients have fascial changes

图 8. 放射组学列线图的决策曲线分析(DCA)。DCA 显示放射组学列线图在预测腰筋膜改变方面优于临床模型。红色和蓝色线分别代表影像学模型和临床模型的净效益。绿色线代表所有患者均有筋膜改变的假设。黑色线代表所有患者均无筋膜改变的假设

4. 讨论

本研究旨在通过基于腰椎软组织磁共振成像的机器学习技术,分析腰背痛患者胸腰椎筋膜的变化情况。研究表明, Nomogram 模型在训练组和验证组中的 AUC 值分别为 0.97 和 0.96,显示出良好的诊断性能。该发现提示,基于 MRI 影像组学的 Nomogram 模型可能作为腰背筋膜炎的可靠诊断工具,为临床决策提供参考。

组织学研究已证实,椎旁韧带内存在无痛觉感受器神经末梢,椎旁韧带的微损伤和炎症可能会导致腰痛[4] [12]。深层筋膜容易出现炎症渗出,并可能刺激腰背筋膜内的肌筋膜疼痛触发点,从而引发腰痛症状。随着病情的缓解,炎症和水肿会消退,同时会出现诸如退化、萎缩和纤维增生等变化[13] [14]。筋膜变化所引起的下背部疼痛已引起专家学者们的广泛关注。现有研究表明,筋膜平均长度的变化会影响相邻椎旁腔室的横截面积,进而导致肌肉缺血性萎缩[15] [16]。此外,筋膜增厚与关节灵活性降低之间存在关联,这也被认为是导致患者下背部疼痛的原因之一。索利曼沃等人通过小鼠实验发现,反复的机械应力会导致肌筋膜出现微损伤[17]。因此,准确识别由筋膜引起的下背部疼痛对于早期缓解患者疼痛具有重要意义。

2012 年,荷兰学者兰宾等人[18]首次提出了“Radiomics”这一概念。它指的是从医学影像中提取高通量特征,并基于这些特征,运用各种统计分析和数据挖掘方法从大量特征中筛选出真正有效的特征,最后将其应用于疾病的诊断、分类和预后。在之前的研究[9]中,我们建立了腰背筋膜炎的诊断模型,并取得了良好的诊断性能。在本研究中,我们继续扩大了病例数量,并比较了不同机器学习模型的诊断性能。在我们的研究中,通过 LASSO 逻辑回归选择了 13 个特征来构建影像组学特征模型,以避免模型构

建中的过拟合问题。结果显示,该影像组学模型在通过腰椎 MRI 对患有筋膜改变的腰痛患者进行筛查时展现出良好的区分能力,在训练集和验证集中的受试者工作特征曲线下面积(AUC)均为 0.83。

进一步分析本研究纳入模型的影像组学特征可以发现,这些特征从影像表型角度仍可反映筋膜炎相关的潜在病理生理变化。首先,一阶统计特征(如 original_firstorder_Minimum、wavelet_HHL_firstorder_Median 和 wavelet_HLL_firstorder_Mean)主要反映感兴趣区域内的信号强度分布情况[19]。因此,上述特征可能在一定程度上反映组织内液体含量变化及炎症活动水平。其次,灰度共生矩阵(GLCM)相关特征(如 ClusterShade、ClusterProminence 和 Autocorrelation)用于描述像素之间的空间相关性及灰度分布的不对称性[20]。其中,ClusterShade 和 ClusterProminence 的升高通常提示灰度分布的不对称性[21],这可能与炎症导致的组织结构破坏及不均匀浸润有关。灰度区域大小矩阵(GLSZM)特征(如 GrayLevelNonUniformity 及其归一化形式)反映不同灰度区域分布的均匀性[20]。该类特征的增加通常提示组织内部灰度分布的不均匀性增强,可能与炎症反应引起的组织结构复杂性增加密切相关。此外,偏度(Skewness)作为描述灰度分布不对称性的指标[22],其变化可能反映炎症或水肿导致的信号分布向高灰度方向偏移。因此,这些特征可能从多角度综合反映筋膜炎中水肿、炎症及组织结构改变等多种病理过程。

在本研究中,我们发现年龄、矢状位 Cobb 角以及下背部平均脂肪厚度等临床特征与下背部筋膜的变化有关。Yu Mi Jeong 等人发现,筋膜的变化与脊柱不稳定存在显著相关性,筋膜功能减退是进行性脊柱不稳定恶性循环的因素之一[23]。在 West 的研究[10]中,发现下背部皮下水肿与平均脂肪厚度有关,脂肪越厚,水肿越易发生。Wilke 的研究[24]也揭示了健康青年和老年人之间筋膜厚度的显著差异,进一步证实年龄差异是影响筋膜形态和功能的一个潜在混杂因素。考虑到临床因素的影响,本研究构建了一个联合影像组学特征和临床特征的 Nomogram 模型,且联合 Nomogram 模型在下背部筋膜变化的区分方面表现出了良好的性能,在训练和验证队列中的 AUC 分别为 0.97 和 0.96,高于影像组学(训练集: AUC = 0.83; 验证集: AUC = 0.83)。尽管该列线图模型和临床模型的 AUC 值相似,但其准确度值和特异性却不同。临床模型的性能不如 Nomogram 模型。

我们的研究也存在一些局限性:这是一项单中心回顾性研究,这可能会导致研究结果缺乏普遍性,存在引入选择偏差。因此,需要大规模、多中心的前瞻性研究来验证我们的结论。我们的定量测量依赖于 2D 手动 ROI 分割。这种方法虽然在临床上很常见,但可能无法准确反映病变的三维(3D)异质性,特别是对于形状不规则的病变区域。对于下背部软组织的区域选择采用人工划分的方法,虽较为准确,但耗时较长,且对下背部筋膜炎的诊断具有很强的主观性,需要制定更严格的图像采集标准以获取更清晰、更符合要求的图像。

5. 结论

综上所述,我们构建了一个综合了临床模型和放射组学特征的 Nomogram 模型,能够帮助临床医生通过软组织磁共振成像来识别和预测腰椎筋膜炎。

参考文献

- [1] Hoy, D., Brooks, P., Blyth, F., et al. (2010) The Epidemiology of Low Back Pain. *Best Practice & Research: Clinical Rheumatology*, **24**, 769-781. <https://doi.org/10.1016/j.berh.2010.10.002>
- [2] Hartvigsen, J., Hancock, M.J., Kongsted, A., et al. (2018) What Low Back Pain Is and Why We Need to Pay Attention. *The Lancet*, **391**, 2356-2367. [https://doi.org/10.1016/S0140-6736\(18\)30480-X](https://doi.org/10.1016/S0140-6736(18)30480-X)
- [3] Knezevic, N.N., Candido, K.D., Vlaeyen, J.W.S., et al. (2021) Low Back Pain. *The Lancet*, **398**, 78-92. [https://doi.org/10.1016/S0140-6736\(21\)00733-9](https://doi.org/10.1016/S0140-6736(21)00733-9)
- [4] Wilke, J., Schleip, R., Klingler, W., et al. (2017) The Lumbodorsal Fascia as a Potential Source of Low Back Pain: A Narrative Review. *BioMed Research International*, **2017**, Article 5349620. <https://doi.org/10.1155/2017/5349620>

- [5] Karino, K., Kono, M., Kono, M., *et al.* (2020) Myofascia-Dominant Involvement on Whole-Body MRI as a Risk Factor for Rapidly Progressive Interstitial Lung Disease in Dermatomyositis. *Rheumatology (Oxford)*, **59**, 1734-1742. <https://doi.org/10.1093/rheumatology/kez642>
- [6] Schwarz-Nemec, U., Friedrich, K.M., Arnoldner, M.A., *et al.* (2020) When an Incidental MRI Finding Becomes A Clinical Issue: Posterior Lumbar Subcutaneous Edema in Degenerative, Inflammatory, and Infectious Conditions of the Lumbar Spine. *Wien Klin Wochenschr*, **132**, 27-34. <https://doi.org/10.1007/s00508-019-01576-x>
- [7] Yan, Y., Xu, R. and Zou, T. (2015) Is Thoracolumbar Fascia Injury the Cause of Residual Back Pain after Percutaneous Vertebroplasty? A Prospective Cohort Study. *Osteoporosis International*, **26**, 1119-1124. <https://doi.org/10.1007/s00198-014-2972-2>
- [8] Yip, S.S. and Aerts, H.J. (2016) Applications and Limitations of Radiomics. *Physics in Medicine and Biology*, **61**, R150-R166. <https://doi.org/10.1088/0031-9155/61/13/R150>
- [9] Song, M.X., Yang, H., Yang, H.Q., *et al.* (2023) MR Imaging Radiomics Analysis Based on Lumbar Soft Tissue to Evaluate Lumbar Fascia Changes in Patients with Low Back Pain. *Academic Radiology*, **30**, 2450-2457.
- [10] West, W., Brady-West, D. and West, K.P. (2018) A Comparison of Statistical Associations between Oedema in the Lumbar Fat on MRI, BMI and Back Fat Thickness (BFT). *Heliyon*, **4**, e00500. <https://doi.org/10.1016/j.heliyon.2017.e00500>
- [11] Yushkevich, P.A., Piven, J., Hazlett, H.C., Smith, R.G., Ho, S., Gee, J.C., *et al.* (2006) User-Guided 3D Active Contour Segmentation of Anatomical Structures: Significantly Improved Efficiency and Reliability. *NeuroImage*, **31**, 1116-1128. <https://doi.org/10.1016/j.neuroimage.2006.01.015>
- [12] Schilder, A., Hoheisel, U., Magerl, W., Benrath, J., Klein, T. and Treede, R. (2014) Sensory Findings after Stimulation of the Thoracolumbar Fascia with Hypertonic Saline Suggest Its Contribution to Low Back Pain. *Pain*, **155**, 222-231. <https://doi.org/10.1016/j.pain.2013.09.025>
- [13] Lam, W.W.M., Chan, H., Chan, Y.L., Fung, J.W.K., So, N.M.C. and Metreweli, C. (2016) MR Imaging in Amyopathic Dermatomyositis. *Acta Radiologica*, **40**, 69-72. <https://doi.org/10.3109/02841859909174406>
- [14] Dalakas, M.C. (1991) Polymyositis, Dermatomyositis, and Inclusion-Body Myositis. *New England Journal of Medicine*, **325**, 1487-1498. <https://doi.org/10.1056/nejm199111213252107>
- [15] El-Monajjed, K. and Driscoll, M. (2020) A Finite Element Analysis of the Intra-Abdominal Pressure and Paraspinal Muscle Compartment Pressure Interaction through the Thoracolumbar Fascia. *Computer Methods in Biomechanics and Biomedical Engineering*, **23**, 585-596. <https://doi.org/10.1080/10255842.2020.1752682>
- [16] Ranger, T.A., Teichtahl, A.J., Cicuttini, F.M., Wang, Y., Wluka, A.E., O'Sullivan, R., *et al.* (2016) Shorter Lumbar Paraspinal Fascia Is Associated with High Intensity Low Back Pain and Disability. *Spine*, **41**, E489-E493. <https://doi.org/10.1097/brs.0000000000001276>
- [17] Solomonow, M. (2012) Neuromuscular Manifestations of Viscoelastic Tissue Degradation Following High and Low Risk Repetitive Lumbar Flexion. *Journal of Electromyography and Kinesiology*, **22**, 155-175. <https://doi.org/10.1016/j.jelekin.2011.11.008>
- [18] Lambin, P., Rios-Velazquez, E., Leijenaar, R., Carvalho, S., van Stiphout, R.G.P.M., Granton, P., *et al.* (2012) Radiomics: Extracting More Information from Medical Images Using Advanced Feature Analysis. *European Journal of Cancer*, **48**, 441-446. <https://doi.org/10.1016/j.ejca.2011.11.036>
- [19] Zhang, N., Wu, M., Zhou, Y., Yu, C., Shi, D., Wang, C., *et al.* (2023) Radiomics Nomogram for Prediction of Glypican-3 Positive Hepatocellular Carcinoma Based on Hepatobiliary Phase Imaging. *Frontiers in Oncology*, **13**, Article 1209814. <https://doi.org/10.3389/fonc.2023.1209814>
- [20] Xie, X., Chen, L., Li, K., Shi, L., Zhang, L. and Zheng, L. (2025) A Clinical-Radiomics Nomogram for the Preoperative Prediction of Aggressive Micropapillary and a Solid Pattern in Lung Adenocarcinoma. *Current Oncology*, **32**, Article 323. <https://doi.org/10.3390/curroncol32060323>
- [21] Peng, Y., Huang, K., Gong, Z., Liu, W., Peng, J. and Gong, L. (2025) Nonenhanced CT-Based Radiomics Model Enhances PTC Detection in Hashimoto's Thyroiditis. *BMC Cancer*, **25**, Article No. 1760. <https://doi.org/10.1186/s12885-025-15206-5>
- [22] Xia, F., Guo, F., Liu, Z., Zeng, J., Ma, X., Yu, C., *et al.* (2023) Enhanced CT Combined with Texture Analysis for Differential Diagnosis of Pleomorphic Adenoma and Adenolymphoma. *BMC Medical Imaging*, **23**, Article No. 169. <https://doi.org/10.1186/s12880-023-01129-9>
- [23] Jeong, Y.M., Shun, M.Y., Lee, S.H. and Chung, H.W. (2013) Sagging Posterior Layer Thoracolumbar Fascia: Can It Be the Cause or Result of Adjacent Segment Diseases? *Journal of Spinal Disorders and Techniques*, **26**, E124-E129.
- [24] Wilke, J., Macchi, V., De Caro, R. and Stecco, C. (2018) Fascia Thickness, Aging and Flexibility: Is There an Association? *Journal of Anatomy*, **234**, 43-49. <https://doi.org/10.1111/joa.12902>