

基于多尺度残差时空模型的乳腺肿瘤预测

张亮亮* 郑航 刘家伟 王朕朕 毕科健

(安庆师范大学计算机与信息学院, 安徽 安庆 246000)

摘要: 从动态对比增强磁共振成像 (DCE-MRI) 获得的空间特征和时间特征均有助于乳腺肿瘤的精准诊断。以往的研究主要集中在浅层时空特征上, 深层时空特征的有效性尚不清晰。针对上述问题, 本研究基于 ResNet (2+1) D, 提出了一种多尺度残差时空模型 (MRSM) 来预测乳腺肿瘤的良好性。本研究包括了台州中心医院的 232 例患者, 其中良性病例 85 例, 恶性病例 147 例。DCE-MRI 数据包括 1 张增强前的图像和 8 张增强后的图像。与原始的 ResNet (2+1) D 相比, MRSM 方法设计了多尺度模块和残差模块。特别地, 多尺度模块依次采用两个独立的双路径空间卷积和双路径时间卷积来有效地捕捉乳腺肿瘤的时空特征。采用受试者工作特征曲线 (ROC) 曲线下面积 (AUC) 来评估 MRSM 方法的诊断性能。结果表明, 与 ResNet (2+1) D 方法 (AUC=0.974 0) 或现有方法 (最佳 AUC=0.960 8) 相比, MRSM 方法获得了更高的 AUC=0.987 0。所提出的 MRSM 方法是一种有效的乳腺肿瘤诊断方法。

关键词: 多尺度残差模块; 时空模型; 乳腺肿瘤预测

中图分类号: R318 文献标志码: A 文章编号: 0258-8021(2025)01-0038-09

Breast Tumor Prediction Based on Multiscale Residual Spatiotemporal Model

Zhang Liangliang* Zheng Hang Liu Jiawei Wang Zhenzhen Bi Kejian

(School of Computer Science and Information Engineering, Anqing Normal University, Anqing 246000, Anhui, China)

Abstract: Spatial and temporal features obtained from dynamic contrast-enhanced magnetic resonance imaging (DCE-MRI) are both used for the prediction of breast tumors. Previous studies mainly focused on the shallow spatiotemporal features, and the effectiveness of the deep spatiotemporal features is still unclear. To this end, a multiscale residual spatiotemporal model (MRSM) based on ResNet (2+1) D was proposed for breast tumor prediction. This study included 232 patients from Taizhou Central Hospital, with 85 benign cases and 147 malignant cases. The DCE-MRI data consisted of one precontrast image and eight postcontrast images. Compared with the original ResNet (2+1) D, MRSM method added a multiscale module and residual module. Specifically, the multi-scale module employed two independent dual-path spatial convolutions and dual-path temporal convolutions to effectively capture the spatio-temporal features of the breast tumor. The performance of the MRSM method was evaluated using the area under the receiver operating characteristic (ROC) curve (AUC). Compared to the ResNet (2+1) D method (AUC=0.974 0) or existing methods (The best AUC=0.960 8), this method achieved a higher AUC of 0.987 0. In conclusion, the MRSM method is an effective approach for accurate prediction of breast tumors.

Key words: multiscale residual module; spatiotemporal model; breast tumor prediction

引言

乳腺癌是一种常见的恶性肿瘤, 对女性身体健

康产生较大的威胁, 已经造成了较高的死亡率^[1]。早期筛查和诊断可以有效减轻患者的痛苦, 降低死亡率。因此, 构建一个有效的预测模型对乳腺癌的

doi: 10.3969/j.issn.0258-8021.2026.01.004

收稿日期: 2025-03-28, 录用日期: 2025-07-03

基金项目: 国家自然科学基金 (62302014); 安徽省高校重点项目 (2023AH050492); 安庆师范大学“敬敷育英”创新业引领计划 (2025JFY006)

* 通信作者 (Corresponding author), E-mail: zll@aqnu.edu.cn

早期诊断和治疗有着非常重要的临床价值。

动态对比增强磁共振成像 (dynamic contrast-enhanced magnetic resonance imaging, DCE-MRI) 具有较高的空间分辨率,已经被广泛用于乳腺肿瘤的预测中^[2-3]。一般来说,DCE-MRI 数据包括一个增强的前图像和一系列增强后的图像。从这些图像可以提取出大量的放射学特征^[4],可揭示乳腺肿瘤的特性^[5-6],并构建机器学习分类器以预测肿瘤信息。与传统方法相比,深度卷积神经网络 (convolutional neural network, CNN) 模型可以自动提取有用的肿瘤特征以精准预测肿瘤信息^[7-9]。例如,Cong 等^[8]提出一个基于 CNN 和长短期记忆的级联网络来实现乳腺肿瘤的预测。Hasan 等^[9]提出了 CNN 方法提取肿瘤的深层特征,并利用这些特征构建支持向量机 (support vector machine, SVM) 分类器以预测分子亚型。上述研究结果均表明,CNN 方法可以有效地预测肿瘤信息。然而,这些研究主要关注肿瘤的空间信息,忽略了乳腺肿瘤的时间信息,可能影响肿瘤信息的预测性能。

近年来,相关研究开始分析乳腺肿瘤的空间信息和时间信息的结合对肿瘤诊断的有效性^[10-11]。例如,Banaie 等^[10]提取肿瘤的空间特征和时间特征,随后将其融合构建 SVM 分类器来诊断乳腺癌。Caballo 等^[11]将肿瘤的空间维度 (2D) 特征和时间维度 (1D) 特征整合为 3D 图像,从中计算出包括空间信息和时间信息的放射组学特征,以提高乳腺癌新辅助化疗病理完全缓解的预测性能。这些研究表明,空间信息与时间信息是互补的,两者的结合对肿瘤信息的精准预测是非常有效的。然而,这些研究主要关注于乳腺肿瘤的浅层时空信息上,深层时空特征是缺失的。此外,这些研究需要人工干预,每个中间步骤的结果都会影响肿瘤的预测性能,不利于实现乳腺肿瘤的智能诊断。

为了进一步有效捕捉深层时空特征,本研究采用 ResNet (2+1) D 来预测乳腺肿瘤的良好性^[12-13],这一想法最早用于动作识别领域^[13-14]。在此基础上,提出了一种多尺度残差时空网络模型来充分挖掘乳腺肿瘤的空间维度特征与时间维度特征,以进一步提高乳腺肿瘤的诊断性能。

1 材料与方法

1.1 患者信息

实验数据来自台州中心医院(台州学院医院)。共包括 232 例患者,其中良性病例 85 例,恶性病例

147 例。该数据集的详细信息请参见文献 [15]。

1.2 DCE-MRI 数据采集

本研究采用一个 3.0 T 扫描仪来获取 DCE-MRI 数据,扫描参数设置如下:重复时间 = 4.7 ms,回波时间 = 2.3 ms,翻转角度 = 10°,切片厚度 = 2.4 mm,视野 = 34 cm × 34 cm,采集矩阵 = 512 × 512。采集的 DCE-MRI 数据包括 1 张增强前的图像和 8 张增强后的图像。增强前的图像是在注射造影剂前获得的,增强后的图像是在静脉注射造影剂后获得的,在这里,注射速率为 2 mL/s。整个图像采集的时间为 2 min 55 s,图像分辨率介于 0.8 mm × 0.8 mm × 1.0 mm ~ 0.6 mm × 0.6 mm × 2.4 mm。

图 1 显示了一个良性肿瘤和一个恶性肿瘤 MRI 样例,在这里,良性肿瘤表现出形态规则,边界清晰,内部结构均匀,而恶性肿瘤的形态不规则,边界不清晰,内部结构不均匀,纹理特征表现出更高的复杂性和异质性。

1.3 图像预处理

本研究的图像预处理步骤与之前的研究类似^[15],包括空间归一化和强度归一化。特别地,将图像分辨率调整为 1.0 mm × 1.0 mm × 1.0 mm,并使用 Z-score 方法对信号强度进行归一化。此外,将原始乳房图像裁剪成带有肿瘤区域的新图像。将各切片的肿瘤图像 (2D) 和时间序列 (1D) 整合成包含乳腺肿瘤时空信息的图像时间序列 (3D),如图 2 所示。最后,总共得到 1160 个图像时间序列 (即样本)。这些样本被随机分为训练集 ($N = 812$) 和验证集 ($N = 348$)。

1.4 传统的 3D CNN 模型

许多 3D CNN 模型^[16-18]可以用于获得乳腺肿瘤的深层特征。ResNet、ResNeXt 和 DenseNet 模型在图像分类中有着较好的性能,因此,将这些模型选




图 1 良性肿瘤(左)和恶性肿瘤(右)样例

Fig.1 Examples for a benign tumor (the left) and a malignant tumor (the right)

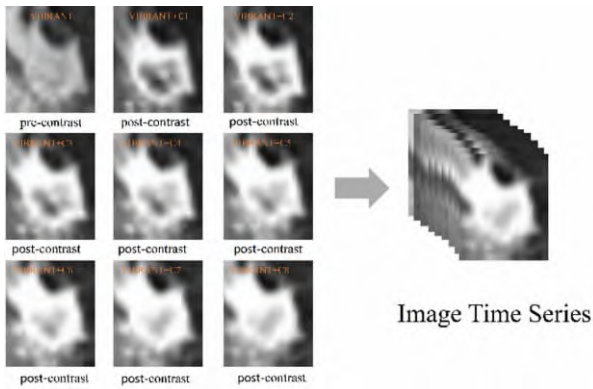


图 2 一个样本示例

Fig.2 An example for sample generation.

择为对照方法。具体来说,本研究选择 3DResNet18、3DResNet34、3DResNet152、3DResNeXt50、3DResNeXt152、3DdenseNet121 和 3DdenseNet169 来提取深层时空特征,以预测乳腺肿瘤的良好性。

1.5 ResNet (2+1) D

ResNet (2+1) D 是一个时空网络模型,适合于分析所采用的乳腺肿瘤数据(即图像时间序列)。该模型包括一个主干模块和 4 个(2+1) D 模块,其中,主干模块由一个空间卷积 $1 \times 7 \times 7$ 和一个时间卷积 $3 \times 1 \times 1$ 组成。该模型将 3D 卷积分解为 2D 空间卷积和 1D 时间卷积,3D 与(2+1) D 卷积的差异如图 3 所示,在这里, t 是指时间维度的大小, d 是指空间维度大小。ResNet (2+1) D 的详细信息可以在之前的研究中找到^[13]。

1.6 MRSM 方法

本研究提出一种改进的 ResNet (2+1) D 模型,即多尺度残差时空模型(multiscale residual spatiotemporal model, MRSM),用以提取更加有用的深层时空特征,进一步提高肿瘤信息的预测性能,网络架构如图 4 所示。本研究在原有的 ResNet (2+




图 3 3D 卷积与(2+1) D 卷积

Fig.3 3D convolution and (2+1) D convolution.

1) D 模型上加入了时空多尺度卷积,用于提取更深层次的时空特征信息。

该模型的损失函数 Loss 可以采用下面的式(1)-(2)计算得到。

$$Loss = - \sum_{c=1}^C w_c \cdot y_c \cdot \ln \hat{y}_c \quad (1)$$

$$w_c = \left[1 - \left(\frac{\text{sample}_c}{\sum \text{sample}_i} \right) \right] \quad (2)$$

式中, y 和 \hat{y} 是真实标签和预测标签, w_c 是类别 c 的权重。

与 ResNet (2+1) D 相比,MRSM 方法在初始模块方面有两个改进。第一,本研究针对空间维和时间维分别设计两条并行的通路模块来提取乳腺肿瘤的多尺度时空特征^[3,19-20],包括局部时空特征和全局时空特征。在这里,全局路径由 3 个连续的空洞空间卷积层(尺寸为 $1 \times 3 \times 3$)和两个连续的空洞时间卷积层(尺寸为 $3 \times 1 \times 1$)组成。这里,多尺度空间层的空洞率分别为 1、3、5,多尺度时间层的空洞率分别为 1、3。图 5 显示了不同位置下的多尺度模块架构,包括模型 A、模型 B 和模型 C。在模型 A 中,预处理后的图像依次经过空间 $1 \times 7 \times 7$ 卷积、空间多尺度卷积层,将得到的空间多尺度特征相加后经过时间 $3 \times 1 \times 1$ 卷积、时间多尺度卷积层,将得到

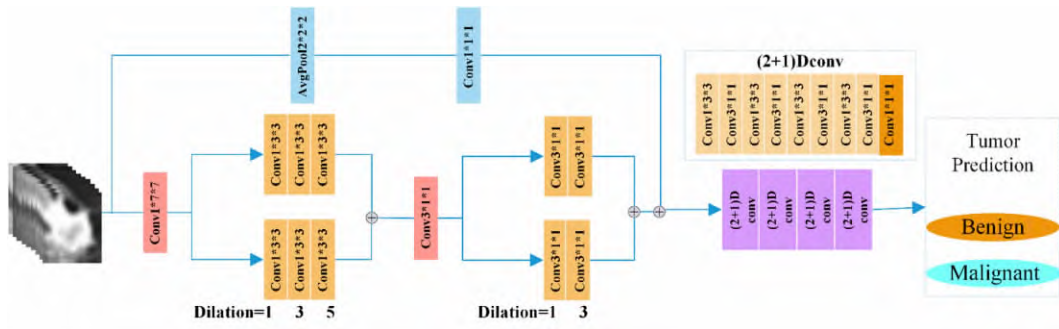


图 4 基于 MRSM 的乳腺肿瘤预测框架

Fig.4 Framework of MRSM for breast tumor classification.

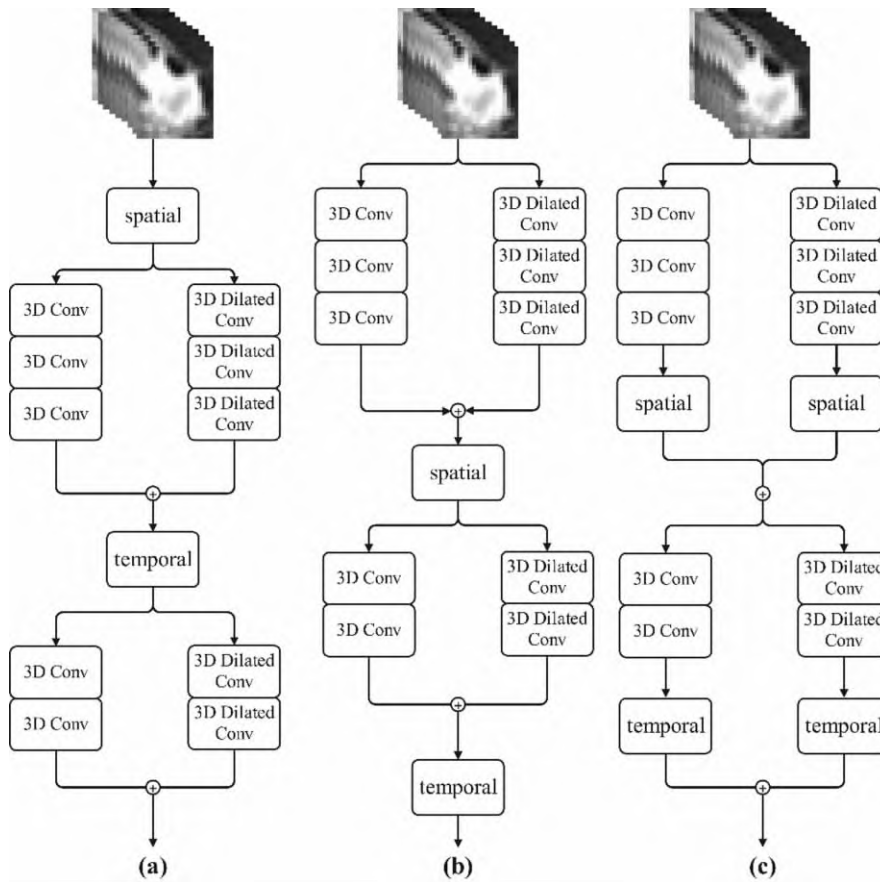


图 5 3 个多尺度模块的架构。(a) 模型 A; (b) 模型 B; (c) 模型 C

Fig.5 Architecture of three multiscale modules. (a) Model A; (b) Model B; (c) Model C

表 1 3 个多尺度模块的性能

Tab.1 Performance of three multiscales module under different positions

方法	AUC	Accuracy	Sensitivity	Specificity	Precision
模型 A	0.978 3	0.925 8	0.944 4	0.893 9	0.940 7
模型 B	0.975 0	0.923 6	0.958 8	0.861 5	0.925 0
模型 C	0.977 1	0.919 5	0.932 6	0.897 4	0.942 9

的时间多尺度特征进行相加。模型 B 将图像先经过空间/时间多尺度模块再进行空间/时间卷积。模型 C 将空间/时间卷积加入空间/时间多尺度模块内部。与其他两个模型相比,模型 A 经过一个空间卷积 $1 \times 7 \times 7$ 可以获得较大的感受野,从而可以提取更丰富的空间上下文信息,同时可以有效地减少数据的维度。因此,理论上来说,模型 A 可以得到更好的诊断性能。多尺度特征可以通过下面的公式 3 计算得到。其次,在时空模型中加入残差块来解决模型退化问题^[21]。

$$\begin{aligned}
 F_{total} &= F_{conv_i} + F_{dilation_i}, i = 3 \text{ or } 2 \\
 &= \text{ReLU}(\text{BN3d}(\text{Conv3d}(x_{in}^{(i)}))) + F_{dilation_i} \\
 &= \text{ReLU}(\text{BN3d}(\text{Conv3d}(x_{in}^{(i)}, d_i))) \quad (3)
 \end{aligned}$$

式中, F_{conv_i} 为局部时空特征, $F_{dilation_i}$ 为全局时空特

征, $x_{in}^{(i)}$ 为第 i 层的输入特征, d_i 为第 i 层空洞卷积的空洞率。

本实验是用 Python 和 Pytorch 实现的,在 NVIDIA GeForce RTX 4090D 上进行了训练。训练集用于训练模型,测试集用于评估模型的性能。该模型使用的最优超参数主要包括: dropout = 0.15, 最大 epoch = 10, 学习率 = 0.000 1, 批量大小 = 16, 以及 Adam 求解器。图 6 显示了最优参数 dropout 的选择过程。当 dropout = 0.15 时,模型的准确率最高。因此,本研究将 MRSM 的最佳参数 dropout 设置为 0.15。

为了验证多尺度模块和残差模块的有效性,本研究分析了不同模块组合后的性能,在这里,主要包括 3 种不同模块的组合。表 1 列出了多尺度模块




图 6 dropout 参数选择

Fig.6 Parameter selection for dropout

在不同位置下的预测性能。模型 A 的 AUC 为 0.978 3, 准确率为 0.925 8。该值是高于另外两个模型的性能。因此,本研究选择将模型 A 融合到 ResNet (2+1) D 中以实现乳腺肿瘤的精准预测。

1.7 统计分析

采用 Wilcoxon 检验来分析良性肿瘤组和恶性肿瘤组的深层特征差异。采用受试者工作特征 (receiver operating characteristic, ROC) 曲线下面积 (area under the ROC curve, AUC) 来评估 MRSM 方法的预测性能。采用 DeLong 检验^[22] 比较 MRSM 方法与 ResNet (2+1) D 或现有方法的性能。此外,本研究也计算了模型的准确率、灵敏度、特异性和精确率指标。在本研究中,以 $p < 0.05$ 为显著性差异。

2 结果

2.1 消融实验性能分析

表 2 列出了不同模块下 ResNet (2+1) D 的预测性能。图 7 为不同模块的 ROC 曲线。与多尺度模块相比,残差模块得到了更高的 AUC 为 0.981 3。通过两者的结合,本研究的 MRSM 方法得到了最高的 AUC 为 0.987 0, 此外,该模型的准确率为 0.936 8, 敏感性为 0.942 0, 特异性为 0.927 4, 精确率为 0.928 8。加入上述两个模块后,乳腺肿瘤的预




图 7 融入不同模块的 ResNet (2+1) D 的 ROC 曲线

Fig.7 ROC curves of ResNet (2+1) D with different module

测性能得到了提高。这些结果表明设计的两个模块对乳腺肿瘤的精准预测是非常有帮助的。

2.2 MRSM 与传统方法的性能比较

图 8 显示了 MRSM 方法和 ResNet (2+1) D 方法的损失函数曲线, 损失在开始时迅速下降。从图中可以看出, 与 ResNet (2+1) D 相比, MRSM 方法的损失函数曲线后期波动的较为平缓。

图 9 显示了 MRSM 方法和 ResNet (2+1) D 得到的代表性深度特征的盒型图。与基于 ResNet (2+1) D 的 Deepfeatures229 相比, MRSM 方法获得的 Deepfeatures105 具有更显著的差异。

表 3 列出了 MRSM 方法和传统方法的预测性能。图 10 显示了 MRSM 方法与传统方法的 ROC 曲线。在现有的方法中, 3DDenseNet169 得到了最高的 AUC = 0.960 8, 3DResNet18 得到了最高的准确率 = 0.902 3。与现有的方法相比, ResNet (2+1) D 得到了更高的 AUC = 0.974 0 和准确率 = 0.919 5, 模型性能也得到了显著性提升 (详见表 4)。此外, 本的结果表明 MRSM 方法的预测性能进一步提高乳腺肿瘤的预测性能。

表 2 融入不同模块的 ResNet (2+1) D 的预测性能

Tab.2 Performance of ResNet (2+1) D with different modules.

方法	AUC	Accuracy	Sensitivity	Specificity	Precision
ResNet (2+1) D	0.974 0	0.919 5	0.933 0	0.895 2	0.911 2
+ 残差	0.981 3	0.928 2	0.968 7	0.830 6	0.911 7
+ 多尺度	0.975 8	0.925 3	0.937 6	0.903 2	0.917 4
MRSM	0.987 0	0.936 8	0.942 0	0.927 4	0.928 8

注 粗体表示每列中最优指标。

Note The bold represents the optimal indicator in each column.




图 8 损失函数曲线。(a) MRSN; (b) ResNet (2+1) D
Fig.8 Loss function curves. (a) MRSN; (b) ResNet (2+1) D

为了增加模型结果的可解释性,采用 Grad-CAM 来可视化网络的中间层。图 11 显示了 3 个样本在不同时间点下的激活图,包括两个良性肿瘤和一个恶性肿瘤。从图中可以看出,肿瘤区域的特征对乳腺肿瘤分类任务起着更加重要的作用。

3 讨论

本研究采用 ResNet (2+1) D 方法来充分挖掘深度空间信息和时间信息,以精准预测乳腺肿瘤的良好性。在此基础上,提出 MRSN 方法(即改进的 ResNet (2+1) D 方法),以进一步提高肿瘤的预测性能。结果表明 MRSN 方法的预测性能优于传统方

法或 ResNet (2+1) D。该结果提示了 MRSN 方法是一种有效的乳腺肿瘤诊断方法。本研究的主要贡献包括:1) 针对空间维和时间维分别设计了两条并行通路模块来提取乳腺肿瘤的多尺度空间维度特征和时间维度特征,包括局部时空特征和全局时空特征;2) 在时空模型中加入残差块,以解决模型退化问题;3) 将所提出的多尺度残差时空模型(MRSN)用以预测乳腺肿瘤的良好性。

一个最近的研究将不同时间点的 2D 肿瘤图像整合为 3D 肿瘤图像,从中提取放射学特征,这些特征包含空间信息和时间信息^[11]。与此不同,ResNet (2+1) D 将纯 3D 卷积分解为 2D 空间卷积和 1D 时间卷积,从而提取有用的深层时间信息和空间信息,以实现乳腺肿瘤的精准预测。本研究结果表明,与传统的 3D CNN 模型相比,ResNet (2+1) D 可以得到更好的诊断性能。这一发现与之前在动作识别领域的研究结果一致^[13]。结果表明,ResNet (2+1) D 方法适用于 DCE-MRI 数据的分析。

在 ResNet (2+1) D 基础上,本研究提出 MRSN 方法来进一步提高肿瘤信息的预测性能。结果表明,与原始 ResNet (2+1) D 相比,MRSN 方法可以得到更好的诊断性能。一个可能的解释是与 3D CNN 模型不同,MRSN 方法使用不同的操作和设置来提取了空间信息和时间信息,从而得到更好的诊断性能。在这里,本研究分析了多尺度模块和残差模块对肿瘤预测的影响。通过加入这些模块,乳腺肿瘤的诊断性能得到了进一步提高。特别地,残差模块的预测性能要优于多尺度模块。这一发现表明残差模块在乳腺肿瘤的预测中发挥着更加重要的作用。

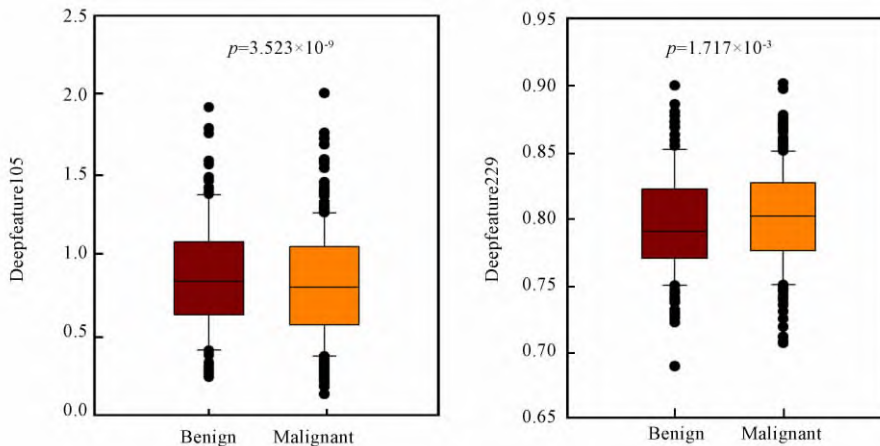


图 9 代表性深度特征的盒型图。(a) MRSN; (b) ResNet (2+1) D
Fig.9 Box plots of representative deep features. (a) MRSN; (b) ResNet (2+1) D

表 3 MRSM 方法与现有方法的性能比较

Tab.3 Performance comparisons between MRSM method and existing methods

方法	AUC	Accuracy	Sensitivity	Specificity	Precision
3DResNet18	0.948 1	0.902 3	0.946 4	0.822 6	0.900 4
3DResNet34	0.936 7	0.893 7	0.937 5	0.814 5	0.889 8
3DResNet152	0.761 8	0.773 0	0.817 1	0.693 5	0.752 7
3DResNeXt50	0.875 9	0.836 2	0.883 4	0.750 0	0.823 1
3DResNeXt152	0.761 8	0.649 4	0.580 4	0.774 2	0.664 1
3DDenseNet121	0.945 7	0.882 2	0.892 9	0.862 9	0.869 3
3DDenseNet169	0.960 8	0.876 4	0.906 4	0.822 6	0.865 6
时空特征-SVM ^[11]	0.916 3	0.864 9	0.905 0	0.795 3	0.827 9
时空特征-RF ^[11]	0.924 2	0.850 6	0.882 4	0.795 3	0.882 4
时空特征-LR ^[11]	0.775 2	0.712 6	0.796 4	0.566 9	0.761 9
ResNet (2+1) D	0.974 0	0.919 5	0.933 0	0.895 2	0.911 2
MRSM	0.987 0	0.936 8	0.942 0	0.927 4	0.928 8

注 粗体表示每列中最优指标。

Note The bold represents the optimal indicator in each column.




图 10 MRSM 方法与传统方法的 ROC 曲线

Fig.10 ROC curves of the MRSM method and traditional methods.

表 4 ResNet(2+1)D/MRSM 与传统方法的 P 值

Tab.4 P values between ResNet (2+1) D/MRSM and traditional method

	ResNet (2+1) D	MRSM
3DResNet18	0.029 7	0.000 2
3DResNet34	0.006 2	< 0.000 1
3DResNet152	< 0.000 1	< 0.000 1
3DResNeXt50	< 0.000 1	< 0.000 1
3DResNeXt152	< 0.000 1	< 0.000 1
3DDenseNet121	0.005 4	0.000 5
3DDenseNet169	0.191 1	0.002 8

本研究结果表明,在良恶性判别中,所提出模型对于恶性肿瘤的识别更容易,准确率更高。这是由于恶性肿瘤大多具有较为典型的特征,如形态不规则、边界不清晰、内部结构不均匀,模型对这种典型特征的判断会更准确。但部分良性肿瘤可能也会表现出边界不清或形态不规则等恶性特征,可能




图 11 3 个样本在不同时间点的激活图

Fig.11 Activation maps of three samples at different time points.

导致与恶性肿瘤的混淆,从而会降低模型对恶性肿瘤的预测性能。

然而,本研究也存在以下几个局限性。首先,本研究使用的数据集是有限的。在未来的研究中,将收集一个额外的数据集来验证 MRSM 方法的鲁棒性。其次,我们的本研究仅基于 DCE-MRI 数据集。在未来的研究中,可以结合多种成像技术,包括超声和其他成像技术^[23-24],提取互补信息以实现乳腺肿瘤的精准诊断。第三,作为一项初步的研究,本研究设计了一个简单的(2+1)D 模型用于乳腺肿瘤诊断。在未来的研究中,将该思想融入到更先进的 CNN 模型中,进一步提高模型的诊断性能^[25-26]。最后,由于样本有限,本研究使用由 2D 图像和 1D 时间序列组成的数据集作为所提出的 MRASM 的输入。后续将设计一个(3+1)D 模型^[27-28],以获得更加有用的空间信息,以精准地预测出乳腺肿瘤的良好性。

4 结论

本研究在 ResNet (2+1)D 的基础上,提出了一种 MRSM 方法来精准预测乳腺肿瘤的良好性。我们的结果表明,与传统方法相比,MRSM 方法在肿瘤信息的预测上得到了更好的诊断性能。这一发现表明提出的 MRSM 方法可以有效提高乳腺肿瘤的诊断性能,这对乳腺肿瘤的精准治疗有着非常重要的理论意义和临床价值。

参考文献

- [1] Siegel RL, Miller KD, Fuchs HE, et al. Cancer statistics [J]. *CA Cancer J Clin*, 2022, 72(1): 7-33.
- [2] Fan Ming, Xia Pingping, Clarke R, et al. Radiogenomic signatures reveal multiscale intratumour heterogeneity associated with biological functions and survival in breast cancer [J]. *Nature Communications*, 2020, 11(1): 4861.
- [3] Zhang Liangliang, Fan Ming, Li Lihua. Efficient estimation of pharmacokinetic parameters from breast dynamic contrast-enhanced MRI based on a convolutional neural network for predicting molecular subtypes [J]. *Physics in Medicine & Biology*, 2023, 68(24): 245001.
- [4] Lambin P, Leijenaar RT, Deist TM, et al. Radiomics: the bridge between medical imaging and personalized medicine [J]. *Nature reviews Clinical oncology*, 2017, 14(12): 749-762.
- [5] Fan Ming, Xia Pingping, Liu Bin, et al. Tumour heterogeneity revealed by unsupervised decomposition of dynamic contrast-enhanced magnetic resonance imaging is associated with underlying gene expression patterns and poor survival in breast cancer patients [J]. *Breast Cancer Research*, 2019, 21: 1-16.
- [6] Fan Ming, Yuan Chengcheng, Huang Guangyao, et al. A framework for deep multitask learning with multiparametric magnetic resonance imaging for the joint prediction of histological characteristics in breast cancer [J]. *IEEE Journal of Biomedical Health Informatics*, 2022, 26(8): 3884-3895.
- [7] Zhou Xinxiang, Zhang Lan, Cui Quanxiang, et al. A Channel-dimensional feature-reconstructed deep learning model for predicting breast cancer molecular subtypes on overall b-value diffusion-weighted MRI [J]. *Journal of Magnetic Resonance Imaging*, 2024, 59(4): 1425-1435.
- [8] Cong Chao, Li Xiaoguang, Zhang Chunlai, et al. MRI-based breast cancer classification and localization by multiparametric feature extraction and combination using deep learning [J]. *Journal of Magnetic Resonance Imaging*, 2024, 59(1): 148-161.
- [9] Hasan AM, Al-Waely NKN, Aljobouri HK, et al. Molecular subtypes classification of breast cancer in DCE-MRI using deep features [J]. *Expert Systems with Applications*, 2024, 236: 121371.
- [10] Banaie M, Soltanian-Zadeh H, Saligheh-Rad HR, et al. Spatiotemporal features of DCE-MRI for breast cancer diagnosis [J]. *Computer Methods and Programs in Biomedicine*, 2018, 155: 153-164.
- [11] Caballo M, Sanderink WBG, Han Luyi, et al. Four-dimensional machine learning radiomics for the pretreatment assessment of breast cancer pathologic complete response to neoadjuvant chemotherapy in dynamic contrast-enhanced MRI [J]. *Journal of Magnetic Resonance Imaging*, 2023, 57(1): 97-110.
- [12] Chatterjee S, Nizamani FA, Nürnberger A, et al. Classification of brain tumours in MR images using deep spatiotemporal models [J]. *Scientific Reports*, 2022, 12(1): 1505.
- [13] Tran D, Wang Heng, Torresani L, et al. A closer look at spatiotemporal convolutions for action recognition [C] // *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 6450-6459.
- [14] Qiu Zhaofan, Yao Ting, Mei Tao. Learning spatio-temporal representation with pseudo-3D residual networks [C] // *Proceedings of the IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 5533-5541.
- [15] Zhao Xiaoming, Liao Yuehui, Xie Jiahao, et al. BreastDM: A DCE-MRI dataset for breast tumor image segmentation and classification [J]. *Computers in Biology and Medicine*, 2023, 164: 107255.
- [16] Hara K, Kataoka H, Satoh Y. Can spatiotemporal 3D cnns retrace the history of 2d cnns and imagenet? [C] // *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE. 2018: 6546-6555.
- [17] Kopuklu O, Kose N, Gunduz A, et al. Resource efficient 3d convolutional neural networks [C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*. Venice: IEEE, 2019: 1910-1919.
- [18] Huang Gao, Liu Zhuang, Van Der Maaten L, et al. Densely

- connected convolutional networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 4700-4708.
- [19] 谈咏东, 王永雄, 陈姝意, 等. (2+1) D 多时空信息融合模型及在行为识别的应用 [J]. 信息与控制, 2019, 48(6): 715-722.
- [20] 庄建军, 吴晓慧, 景生华, 等. 多尺度特征融合的改进残差网络乳腺癌病理图像分类 [J]. 中国生物医学工程学报, 2024, 43(4): 419-428.
- [21] 王勇, 靳伟昭, 冯伟, 等. 一种改进 R(2+1) D 网络的暴力行为检测方法 [J]. 西安电子科技大学学报, 2022, 49(2): 155-163.
- [22] DeLong ER, DeLong DM, Clarke-Pearson DL. Comparing the areas under two or more correlated receiver operating characteristic curves: a nonparametric approach [J]. Biometrics, 1988, 44(3): 837-845.
- [23] Wang Xianyang, Lv Linlin, Tang Qingfeng, et al. A feature fusion method based on radiomic features and revised deep features for improving tumor prediction in ultrasound images [J]. Computers in Biology Medicine, 2025, 185: 109605.
- [24] Atrey K, Singh BK, Bodhey NK. Multimodal classification of breast cancer using feature level fusion of mammogram and ultrasound images in machine learning paradigm [J]. Multimedia Tools Applications, 2024, 83(7): 21347-21368.
- [25] Jiang Shengqin, Zhang Haokui, Qi Yuankai, et al. Spatial-temporal interleaved network for efficient action recognition [J]. IEEE Transactions on Industrial Informatics, 2024, 21(1): 178-187.
- [26] Xu Cheng, Yi Ke, Jiang Nan, et al. MDFF-Net: A multi-dimensional feature fusion network for breast histopathology image classification [J]. Computers in Biology Medicine, 2023, 165: 107385.
- [27] Nguyen S, Polat D, Karbasi P, et al. Preoperative prediction of lymph node metastasis from clinical DCE MRI of the primary breast tumor using a 4D CNN [C] // Medical Image Computing and Computer Assisted Intervention-MICCAI. Lima: MICCAI, 2020: 326-334.
- [28] Ulas C, Tetteh G, Thrippleton MJ, et al. Direct estimation of pharmacokinetic parameters from DCE-MRI using deep CNN with forward physical model loss [C] // International Conference on Medical Image Computing and Computer-Assisted Intervention. Granada: MICCAI, 2018: 39-47.