

DOI:10.3969/j.issn.1005-202X.2026.08.004

医学影像物理

## 基于多模态医学影像的卵巢癌早期智能筛查模型

高鹏帅<sup>1,2</sup>, 刘梦迪<sup>2</sup>, 樊冬梅<sup>1</sup>

1. 河南科技大学第一附属医院妇科肿瘤病区, 河南 洛阳 471003; 2. 河南科技大学临床医学院, 河南 洛阳 471023

**【摘要】**为解决卵巢癌早期病灶隐匿、临床筛查准确率低的问题,提升早期筛查精度以改善患者预后,构建高效、精准的卵巢癌早期智能筛查模型。研究采用多模态医学影像作为核心输入,优先融合磁共振成像(MRI)与超声两种互补性模态,对影像进行格式统一、去噪增强、病灶分割、特征标准化等预处理后,结合深度学习算法搭建智能筛查模型。模型通过卷积神经网络(CNN)分别提取超声与MRI影像的深层特征,采用注意力机制(Attention Mechanism)实现特征级融合,借助Softmax分类器完成“正常卵巢-良性病变-早期卵巢癌”3分类预测。模型结果显示,其对早期卵巢癌的筛查灵敏度、特异性、准确率及ROC曲线下面积(AUC值)均显著优于单一模态筛查模型,可有效减少漏诊、误诊情况。该模型可为卵巢癌早期临床筛查提供可靠的智能化技术支持,具备良好的临床应用价值与推广前景。

**【关键词】**多模态医学影像; 卵巢癌; 早期筛查; 深度学习; CNN; 注意力机制; 影像融合

**【中图分类号】**R318; R737.31

**【文献标志码】**A

**【文章编号】**1005-202X(2026)08-1019-06

### Intelligent early screening model of ovarian cancer based on multimodal medical images

GAO Pengshuai<sup>1,2</sup>, LIU Mengdi<sup>2</sup>, FAN Dongmei<sup>1</sup>

1. Gynecological Oncology Ward, the First Affiliated Hospital of Henan University of Science and Technology, Luoyang 471003, China; 2. School of Clinical Medicine, Henan University of Science and Technology, Luoyang 471023, China

**Abstract:** A high-efficiency and accurate intelligent early screening model for ovarian cancer is established to address the problems of hidden early lesions and low clinical screening accuracy, thereby improving early screening precision and patient prognosis. This study used multimodal medical images as core inputs, and prioritizes the fusion of two complementary modalities: magnetic resonance imaging (MRI) and ultrasound. Following image preprocessing, including format unification, noise removal and enhancement, lesion segmentation, and feature standardization, a deep learning-based intelligent screening model is constructed. This model extracts deep features of ultrasound and MRI images separately by convolutional neural networks, realizes feature-level fusion using an attention mechanism, and completes a three-category prediction of normal ovary, benign lesion and early ovarian cancer through a Softmax classifier. Results demonstrated that the proposed model outperforms single-modal screening models in terms of sensitivity, specificity, accuracy and area under the ROC curve for early ovarian cancer screening, effectively reducing missed diagnosis and misdiagnosis. The proposed model can provide reliable intelligent technical support for early clinical screening of ovarian cancer, demonstrating favorable clinical application value and promotion prospects.

**Keywords:** multimodal medical image; ovarian cancer; early screening; deep learning; convolutional neural network; attention mechanism; image fusion

### 前言

卵巢癌是女性高发的生殖系统恶性肿瘤,发病

率居第3位、致死率居首位<sup>[1]</sup>。因卵巢位置深、早期症状隐匿且病灶微小,患者多在中晚期确诊,5年生存率极低,而早期确诊可显著提升生存率,构建高效精准的早期智能筛查模型对临床意义重大<sup>[2]</sup>。

目前临床主流筛查手段存在固有局限:经阴道超声操作便捷、检查成本低,适合大范围人群初筛,但对早期微小恶性病灶辨识度有限,诊断结果易受操作人员经验影响;MRI具备优异的软组织分辨能力<sup>[3]</sup>,可清晰显示病灶微观结构与浸润范围,良恶性

**【收稿日期】**2026-06-20

**【基金项目】**河南省卫健委支持项目(LHGJ20230464)

**【作者简介】**高鹏帅,硕士研究生,住院医师,研究方向:妇科肿瘤, E-mail: Gao20210ps@163.com

**【通信作者】**樊冬梅,博士,主任医师,研究方向:妇科肿瘤, E-mail: fdm370@sina.com

鉴别效能突出,但检查耗时长、费用偏高,难以应用于大规模普筛;血清肿瘤标志物检测特异性不足<sup>[4]</sup>,单独使用无法作为早期确诊依据。

近年来,随着深度学习与医学影像分析技术的快速发展,基于多模态影像融合的智能诊断模型已成为全身各系统肿瘤早期筛查的研究热点。国内外诸多研究已将超声、MRI、CT等不同模态影像相结合,应用于肺部结节、乳腺肿瘤、肝脏病变等疾病的智能识别,通过整合不同影像的互补信息,有效弥补单一模态特征缺失的缺陷,显著提升病灶检出与分类精度。

在卵巢病变智能诊断领域,现有研究仍存在明显短板与不足:多数研究仍以单一卷积神经网络结合单模态影像为主,仅依托超声或MRI独立建模,无法兼顾影像形态、血流、微观组织结构等多维特征;少数多模态融合研究采用简单特征拼接、后期结果投票等浅层融合方式,未挖掘不同模态间的特征关联与互补优势,对早期低对比度、微小隐匿病灶的特征挖掘能力不足;通用型网络模型多面向自然图像设计,未针对妇科卵巢影像的病灶特征做定制化优化,模型泛化性与临床适配性有限<sup>[5-6]</sup>。

相较于现有国内外同类研究,本研究的差异化设计与核心改进主要体现在3方面:首先,采用双分支差异化特征提取架构,选用轻量级MobileNetV2适配超声纹理与血流特征提取,结合残差结构ResNet50深挖MRI细微解剖与弥散特征,突破单一网络对多模态影像适配性差的问题;其次,摒弃传统简单拼接融合方式,引入注意力机制完成特征级自适应融合,自动强化早期癌变高关联特征权重,抑制背景冗余信息干扰,针对性提升微小早期病灶的识别能力;最后,构建从影像格式统一、定向去噪增强、病灶自动分割到特征标准化的全流程临床影像预处理体系,搭配双盲专家标注规则,有效降低临床影像数据异质性,为多模态模型稳定训练与落地应用提供支撑。

综上,本研究以超声MRI双模态医学影像为基础,结合深度学习与注意力融合策略,构建适配卵巢病变的早期智能筛查模型。通过充分发挥两种临床主流影像的互补优势,弥补单一筛查方式的技术局限,旨在提升早期卵巢癌的筛查灵敏度与鉴别准确率,为妇科肿瘤智能化辅助诊断提供新的参考思路与技术方

## 1 多模态医学影像的选择与预处理

### 1.1 核心模态选择及依据

结合卵巢癌早期筛查的临床需求、影像特点及模型实用性,本研究选取MRI与超声作为多模态融

合的核心输入,二者互补性强,可兼顾筛查便捷性与精准性。采用经阴道超声作为初筛影像,其对直径<2 cm的微小病灶检出优势显著,可清晰显示病灶形态、回声及血流特征,快速完成可疑样本初筛<sup>[7]</sup>;同时选取MRI的T<sub>2</sub>WI、DWI及动态增强序列作为精准诊断输入,可清晰呈现病灶解剖结构、水分子扩散及血供特点,有效弥补超声识别不足,实现良恶性病灶精准鉴别<sup>[8]</sup>。

### 1.2 多模态影像预处理

为直观展示两种模态影像的成像特点与差异化优势,本研究选取临床典型样本的超声、MRI影像作为示例。超声影像成像速度快、成本低、无辐射,可清晰反映病灶形态、边界与血流信息,适合大范围初筛,但软组织分辨率有限,对深部微小隐匿病灶显示不足;MRI影像依托多序列成像,具备优异的软组织分辨能力,可清晰呈现病灶微观结构与血供特征,良恶性鉴别效能突出,但检查耗时长、普及性受限。两种模态优势互补,单一影像无法全面覆盖早期卵巢癌的关键病灶特征,多模态结合可融合多维信息,提升模型对早期微小病变的识别能力,降低漏诊与误诊风险。

为消除临床影像异质性,统一模型输入标准,本研究开展标准化预处理操作。(1)格式与尺寸统一。将DICOM格式影像读取并转换为灰度PNG格式,统一调整为512×512像素,消除设备参数差异。(2)针对性去噪与增强。采用高斯滤波完成超声影像去噪<sup>[9]</sup>,采用自适应维纳滤波处理MRI影像噪声<sup>[10]</sup>,结合直方图均衡化提升病灶区域对比度,突出病变与正常组织的差异。(3)病灶区域分割。采用U-Net算法自动分割卵巢及可疑病灶区域,剔除盆腔、脂肪等无效背景组织干扰,减少无效特征输入<sup>[11]</sup>。(4)特征标准化。采用Z-score方法对分割后的影像特征进行标准化处理,将所有特征值映射至均值为0、标准差为1的区间,消除不同影像间的数值尺度差异。(5)双盲数据标注。由两名高年资放射科医师对影像进行标注,划分正常卵巢、良性病变与早期卵巢癌3类样本;标注存在分歧时由第3名专家仲裁,保障数据集标注质量,为模型训练提供规范、高质量的输入数据。

## 2 基于AI算法的卵巢癌早期智能筛查模型搭建

本研究结合多模态影像的特征特点与卵巢癌早期筛查的需求,选用深度学习算法搭建智能筛查模型,核心思路为“多模态特征融合+分类识别”,实现早期卵巢癌的智能筛查与良恶性鉴别。模型整体架构分为特征提取层、模态融合层、分类预测层3个部分,协同完成高精度筛查任务。

2.1 模型整体架构设计

模型采用模块化设计,核心流程如下:(1)特征提取层。采用双分支结构,分别处理超声与MRI影像,利用卷积神经网络(CNN)自动提取深层特征。(2)模态融合层。借助注意力机制实现特征级融合,对双模态特征分配自适应权重,强化对早期卵巢癌鉴别有价值的特征。(3)分类预测层。通过全连接层完成特征映射,再由Softmax分类器实现“正常卵巢-良性病变-早期卵巢癌”3分类预测并输出各类别概率。预处理后的超声、MRI影像分别进入对应分支提取特征,经注意力机制融合后输入分类预测层得到结果,再通过损失函数计算预测误差、反向传播更新参数,完成模型训练。

2.2 核心算法选择与实现

2.2.1 特征提取算法:双分支深度特征网络 本研究针对超声与MRI影像的差异化特征,设计定制化双分支深度网络架构。超声影像特征提取分支:选用轻量化MobileNetV2网络<sup>[12]</sup>,依托倒残差结构与深度可分离卷积,在控制参数量的同时,强化纹理、边界、血流等浅层细节特征的捕获能力,适配超声图像低信噪比、纹理信息丰富的特点。为与MRI分支输出维度匹配,在全局平均池化层后新增一层全连接层,将常规1 280维输出映射为2 048维特征向量。MRI影像特征提取分支:选用深层残差网络ResNet50<sup>[13]</sup>,通过多层残差连接缓解梯度消失问题,能够连续提取底层纹理、中层组织形态、高层语义病灶特征,充分挖掘DWI、增强序列中微小癌变的隐匿高阶特征,最终输出2 048维特征向量。

综上,本研究通过网络分支差异化选型、残差结构深度优化、跨模态维度自适应调整三重设计,对传统通用CNN特征提取模式进行针对性改良,显著提升模型对早期卵巢微小病灶的特征表达能力,为后续多模态融合与高精度分类提供支撑。

2.2.2 模态融合算法:注意力机制 多模态融合的核心是充分利用不同模态的互补特征,避免简单特征叠加导致的冗余与精度下降。本研究采用注意力机制实现特征级融合,通过计算不同模态特征的注意力权重,赋予对早期卵巢癌鉴别价值更高的特征更高权重,实现多模态特征的高效融合<sup>[18-19]</sup>。

其核心计算过程如下:

$$\text{Attention}(Q|K|V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \tag{1}$$

其中, $Q$ 、 $K$ 、 $V$ 分别为超声与MRI特征映射后的查询、键、值向量, $d_k$ 为向量维度。模型可自动识别MRI的DWI高信号、超声的实性成分占比等高价值特征,提升融合特征的有效性。

本研究对卵巢癌双模态筛查任务做定制化改良:结合超声纹理特征与MRI高维语义特征的差异,完成双分支跨模态特征关联建模;以早期微小病灶鉴别为导向,通过自适应权重分配弱化背景等无效特征干扰;面向3分类临床筛查需求,实现多模态互补特征的协同增强。

2.2.3 分类预测算法:Softmax分类器 多模态特征融合完成后,采用全连接层与Softmax分类器实现“正常卵巢-良性病变-早期卵巢癌”的3分类预测<sup>[14]</sup>。全连接层将融合特征向量映射至分类空间,再通过Softmax函数归一化得到各类别概率,完成筛查结果判断。

2.2.4 模型损失函数与优化器 本研究选用交叉熵损失函数衡量模型预测结果与真实标签的差异<sup>[15]</sup>,同时采用Adam优化器优化模型参数<sup>[16]</sup>,加速模型收敛,提升训练稳定性。

2.3 模型搭建流程与超参数设置

2.3.1 模型搭建流程 本研究基于Python语言与PyTorch框架搭建卵巢癌早期智能筛查模型,流程清晰且可复现。将预处理后的多模态影像标注数据集按7:2:1划分为训练集、验证集与测试集,分别用于模型训练、超参数调优及最终性能评估。采用迁移学习方法,初始化加载ImageNet预训练权重的MobileNetV2与ResNet50特征提取分支,并完成注意力机制、全连接层等参数的合理初始化;将超声、MRI影像输入对应分支,通过Adam优化器迭代训练10个epoch,完成特征提取分支的训练。随后连接模态融合层与分类预测层构建完整模型,依托训练集训练、验证集监控性能并调整学习率等超参数,同时引入早停策略(验证集性能连续5个epoch无提升则停止训练)避免过拟合<sup>[17-18]</sup>。最终保存验证集AUC最优模型,通过测试集完成模型筛查效果的验证与评估。

2.3.2 模型超参数设置 模型超参数的设置直接影响模型的训练效果与性能,本研究通过多次实验调试,确定最优超参数,具体设置如表1所示。

2.4 模型性能评估指标

为全面客观评估模型早期筛查性能并验证多模态融合优势,本研究选取4项核心指标,与单一超声AI、单一MRI AI模型进行对比。其中,灵敏度(Sensitivity)反映模型对早期卵巢癌的识别能力,灵敏度越高则漏诊率越低<sup>[19]</sup>;特异性(Specificity)用于鉴别正常及良性卵巢病变,特异性越高则误诊率越低<sup>[20]</sup>;准确率(Accuracy)代表模型整体预测正确的比例<sup>[21]</sup>;AUC(Area Under Curve)为ROC曲线下面积<sup>[22]</sup>,取值为0.5~1.0,数值越接近1.0表明模型整体分类性能越好。

表 1 模型最优超参数  
Table 1 Optimal hyperparameters of the model

| 超参数名称                     | 取值          | 说明                               |
|---------------------------|-------------|----------------------------------|
| batch size                | 16          | 每次训练输入的样本数量兼顾训练效率与内存占用           |
| 学习率( $\alpha$ )           | $10^{-4}$   | 初始学习率,每 5 个 epoch 衰减为原来的 0.5     |
| 迭代次数(epoch)               | 50          | 最大训练迭代次数,结合早停策略停止训练              |
| 衰减系数( $\beta_1/\beta_2$ ) | 0.900/0.999 | Adam 优化器的动量与自适应学习率衰减系数           |
| 高斯滤波标准差( $\sigma$ )       | 1.5         | 超声影像去噪的高斯滤波参数                    |
| 早停耐心值                     | 5           | 验证集性能连续 5 个 epoch 不提升则停止训练       |
| 注意力机制特征维度                 | 2048        | $Q$ 、 $K$ 、 $V$ 向量的维度,为融合特征的核心维度 |
| 分类层全连接层神经元数               | 128         | 实现融合特征向分类空间的映射                   |

3 模型验证与分析

本研究通过临床收集的多模态影像数据集,对搭建的卵巢癌早期智能筛查模型进行系统验证,同时与单一超声 AI 筛查模型、单一 MRI AI 筛查模型进行对比,验证多模态融合模型的优势;通过关键特征分析,验证模型的合理性与临床适用性;通过局限性分析,明确模型的不足与改进方向,为后续研究提供参考。

3.1 试验数据来源与预处理结果

3.1.1 试验数据来源 本研究的试验数据来源于河南科技大学第一附属医院妇科 2020 年 1 月至 2024 年 1 月收治的卵巢病变患者及健康体检女性的多模态影像资料,严格遵循医学伦理规范,所有研究对象均签署知情同意书。

本研究采用的影像设备均为统一型号:超声设备为 GE Voluson E10(频率 5~9 MHz),MRI 设备为西门子 3.0T Skyra( $T_2WI$ 层厚 3 mm, $DWI$   $b$ 值=800 s/mm<sup>2</sup>,动态增强扫描层厚 3 mm),扫描参数统一设置,消除设备与参数差异对影像特征的影响。

数据纳入标准:(1)研究对象经病理活检明确诊断,分为 3 类:早期卵巢癌(I 期)、良性卵巢病变,或经健康体检确认卵巢无异常;(2)所有研究对象均完成经阴道超声检查,同时完成 MRI 检查(含  $T_2WI$ 、 $DWI$  及动态增强序列);(3)影像资料完整、清晰,无明显伪影、噪声干扰;(4)检查前未接受放化疗、手术等治疗。

数据排除标准:(1)影像资料不完整、模糊,无法进行预处理与标注;(2)合并其他恶性肿瘤、严重肝肾肾功能不全等疾病;(3)体内有金属植入物,影响 MRI 检查结果。

最终纳入试验数据共 320 例,其中正常卵巢样本 80 例,良性卵巢病变样本 120 例(生理性囊肿 45 例、子宫内膜异位囊肿 35 例、畸胎瘤 40 例),早期卵巢癌

样本 120 例(I 期)。所有样本均按 7:2:1 的比例划分为训练集(224 例)、验证集(64 例)、测试集(32 例),数据集分布如表 2 所示。

表 2 数据集(例)  
Table 2 Datasets (cases)

| 样本类型       | 总样本数 | 训练集 | 验证集 | 测试集 |
|------------|------|-----|-----|-----|
| 正常卵巢       | 80   | 56  | 16  | 8   |
| 良性卵巢病变     | 120  | 84  | 24  | 12  |
| 早期卵巢癌(I 期) | 120  | 84  | 24  | 12  |
| 合计         | 320  | 224 | 64  | 32  |

3.1.2 预处理结果 对纳入的 320 例样本的超声与 MRI 影像进行标准化预处理后,影像质量得到显著提升:噪声与伪影被有效抑制,病灶区域与正常组织的对比度明显增强,病灶边界清晰可辨;通过 U-Net 算法实现病灶区域的精准分割<sup>[23]</sup>,分割准确率达到 92.3%,有效排除背景组织干扰;通过特征标准化,所有影像特征均映射至均值为 0、标准差为 1 的区间,消除特征尺度差异。预处理后的影像可直接输入 AI 模型进行训练与测试,为模型的高精度训练提供可靠保障。

3.2 模型训练过程与结果

3.2.1 模型训练过程 模型采用 PyTorch 框架训练,训练过程中,模型的损失函数值与验证集 AUC 值的变化趋势如下:训练初期(1~10 个 epoch),模型损失函数值快速下降,验证集 AUC 值快速提升,表明模型快速学习影像特征;训练中期(11~30 个 epoch),损失函数值下降速度放缓,验证集 AUC 值逐渐趋于稳定;训练后期(31~40 个 epoch),验证集 AUC 值达到最高(0.962),之后连续 5 个 epoch 验证集 AUC 值不再提升,触发早停策略,模型停止训练,最终训练迭代次数为 40 个 epoch,避免模型过拟合。

**3.2.2 模型性能验证结果** 将测试集(32例样本)输入训练完成的最优模型,计算模型的灵敏度、特异性、准确率、AUC值,同时与单一超声AI筛查模型(仅采用超声影像,其他算法与参数一致)、单一MRI AI筛查模型(仅采用MRI影像,其他算法与参数一致)进行对比,验证多模态融合模型的优势,具体性能对比结果如表3所示。

表3 模型性能指标比较(%)  
Table 3 Comparison of model performance indicators (%)

| 模型类型        | 灵敏度  | 特异性  | 准确率  |
|-------------|------|------|------|
| 单一超声        | 75.0 | 80.0 | 78.1 |
| 单一MRI       | 83.3 | 85.0 | 84.4 |
| 多模态(MRI+超声) | 91.7 | 90.0 | 90.6 |

由表3可知,本研究搭建的多模态(MRI+超声)AI筛查模型,在测试集中的灵敏度、特异性、准确率分别达到91.7%、90.0%、90.6%,均显著优于单一超声AI模型与单一MRI AI模型。其中,灵敏度较单一超声AI模型提升16.7%,较单一MRI AI模型提升8.4%,表明多模态融合模型能更精准地识别早期卵巢癌病灶,减少漏诊;特异性较单一超声AI模型提升10.0%,较单一MRI AI模型提升5.0%,表明模型能更准确地鉴别正常卵巢、良性病变与早期卵巢癌,减少误诊。

单一超声模型、单一MRI模型和多模态融合模型(MRI+超声)的AUC值分别为0.825、0.896、0.962。单一超声模型AUC值为0.825,表明仅依靠超声影像进行卵巢癌早期筛查时,模型的整体鉴别能力有限,对早期病灶的识别灵敏度存在明显短板,易出现漏诊情况。单一MRI模型AUC值提升至0.896,说明MRI影像在软组织分辨率、病灶细节呈现方面的优势,可有效提升模型对良恶性病变的鉴别能力,但仍存在对微小病灶及血流特征捕捉不足的问题。多模态融合模型(MRI+超声)AUC值进一步提升至0.962,显著优于两种单一模态模型。这一结果表明,通过注意力机制实现超声与MRI影像的特征级融合,可充分发挥两种模态的互补性-超声的实时性与低成本优势,结合MRI的高分辨率与精准鉴别能力,使模型对早期卵巢癌的筛查能力得到显著增强,有效降低漏诊与误诊风险。

试验结果证明,多模态影像融合可有效整合超声与MRI的互补特征,结合AI算法搭建的模型,能显著提升卵巢癌早期筛查的精度与效率,解决单一模态筛查的局限性,达到预期研究目标。

4 结论与展望

4.1 结论

本研究围绕卵巢癌早期智能筛查的核心需求,融合MRI与超声多模态医学影像,结合深度学习AI算法,搭建卵巢癌早期智能筛查模型,通过系统的实验验证与分析,得出以下核心结论:第一,MRI与超声多模态影像融合可有效弥补单一模态的局限性,二者具有极强的互补性。超声影像具备便捷、无创、成本低的优势,可实现早期初筛,快速排除正常样本、识别可疑病变;MRI影像(T<sub>2</sub>WI、DWI、动态增强序列)具备极高的软组织分辨率,可精准捕捉早期卵巢癌的细微特征,实现可疑病灶的精准鉴别,二者结合可兼顾筛查的效率与精度,为模型提供全面、可靠的特征支撑。

第二,标准化的影像预处理流程是提升模型训练精度的关键。本研究采用的格式统一、针对性去噪增强、U-Net病灶分割、Z-score特征标准化及双盲专业标注等预处理步骤,有效解决临床影像格式不统一、噪声干扰、背景冗余、特征尺度差异等问题,分割准确率达到92.3%,为AI模型训练提供高质量、一致性的数据保障。

第三,基于“双分支CNN特征提取+注意力机制融合+Softmax分类”的模型架构,可实现早期卵巢癌的精准筛查。模型通过MobileNetV2与ResNet50双分支结构,分别高效提取超声与MRI影像的深层特征;注意力机制可自动赋予高鉴别价值特征更高权重,实现多模态特征的高效融合;结合交叉熵损失函数与Adam优化器,模型训练收敛速度快、泛化能力强。

第四,模型验证结果表明,多模态融合AI模型的筛查性能显著优于单一模态AI模型。在测试集中,模型的灵敏度、特异性、准确率、AUC值分别达到91.7%、90.0%、90.6%、0.962,较单一超声AI模型、单一MRI AI模型均有明显提升,能有效减少早期卵巢癌的漏诊、误诊,符合临床早期筛查的核心需求。

4.2 展望

尽管本研究构建的多模态AI卵巢癌早期筛查模型效果良好,但仍存在局限:仅纳入120例早期卵巢癌样本且为单中心数据,样本多样性不足,影响模型泛化能力<sup>[24]</sup>。后续将扩大样本量、开展多中心验证<sup>[25]</sup>,纳入不同地区、人群及设备参数的影像资料,提升模型泛化性与推广价值;同时推进临床转化,将模型封装为易用的辅助筛查软件,优化交互与设备适配,并结合临床经验迭代优化。本模型有效弥补单一模态筛查精度不足的缺陷,具备较高临床价值,

经后续优化可进一步提升性能,为卵巢癌早期筛查提供更精准高效的智能化方案,推动妇科恶性肿瘤筛查技术革新。

## 【参考文献】

- [1] 谢幸,孔北华,段涛. 妇产科学[M]. 9版. 北京: 人民卫生出版社, 2018: 323-332.  
Xie X, Kong BH, Duan T. Obstetrics and gynecology[M]. 9th ed. Beijing: People's Medical Publishing House, 2018: 323-332.
- [2] Siegel RL, Miller KD, Wagle NS, et al. Cancer statistics, 2023[J]. CA Cancer J Clin, 2023, 73(1): 17-48.
- [3] Estelrich J, Sánchez-Martín MJ, Busquets MA. Nanoparticles in magnetic resonance imaging: from simple to dual contrast agents[J]. Int J Nanomedicine, 2015, 10(1): 1727-1741.
- [4] Bast RC. Serum tumor markers in clinical practice: general principles and applications[J]. CA Cancer J Clin, 2020, 70(2): 89-103.
- [5] Wang Y, Li J, Zhang H. Single-modal ultrasound-based AI model for early ovarian cancer screening [J]. J Med Imaging, 2022, 32(4): 789-794.
- [6] Li L, Chen H, Wang F. MRI-based deep learning model for differential diagnosis of early ovarian benign and malignant lesions [J]. Eur Radiol, 2021, 31(11): 8234-8242.
- [7] Timmerman D, Testa AC, Bourne T, et al. Simple ultrasound-based rules for the diagnosis of ovarian cancer [J]. Ultrasound Obstet Gynecol, 2008, 31(6): 681-690.
- [8] 张力莹, 张同贞, 赵鑫. 基于乳腺影像报告和数据系统的DWI和T<sub>2</sub>WI形态评估对乳腺病变的诊断价值[J]. 南方医科大学学报, 2025, 45(9): 1809-1817.  
Zhang LY, Zhang TZ, Zhao X. Diagnostic value of morphological features of breast lesions on DWI and T<sub>2</sub>WI assessed using Breast Imaging Reporting and Data System lexicon descriptors[J]. Journal of Southern Medical University, 2025, 45(9): 1809-1817.
- [9] Fisher R, Perkins S, Walker A, et al. Gaussian smoothing[EB/OL]. <https://homepages.inf.ed.ac.uk/rbf/HIPR2/gsmooth.htm>.
- [10] Lim JS, Oppenheim AV. Adaptive Wiener filtering[J]. Proc IEEE, 1979, 67(12): 1655-1656.
- [11] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [12] Sandler M, Howard A, Zhu ML, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 4510-4520.
- [13] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [14] Bridle JS. Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition [C]//Neurocomputing. Berlin, Heidelberg: Springer Berlin Heidelberg, 1990: 227-236.
- [15] Kullback S, Leibler RA. On information and sufficiency[J]. Ann Math Statist, 1951, 22(1): 79-86.
- [16] Kingma DP, Ba J. Adam: a method for stochastic optimization[C]//International Conference on Learning Representations. New York, USA: ICLR, 2015: 1-15.
- [17] Jamshidi A, Seppäläinen L, Haitsiukevich K, et al. GRADSTOP: early stopping of gradient descent via posterior sampling[EB/OL]. (2025-08-27). <https://arxiv.org/abs/2508.19028>.
- [18] Tutone A, Anitra A, Ambrosi E, et al. X-ray spectral fitting with Monte Carlo dropout neural networks[EB/OL]. (2025-03-12). <https://arxiv.org/abs/2503.09224>.
- [19] Šimundić AM. Measures of diagnostic accuracy: basic definitions[J]. EJJFCC, 2009, 19(4): 203-211.
- [20] Su N, Yang Y, Liu ZZ, et al. Validation of the diagnostic efficacy of O-RADS in adnexal masses[J]. Sci Rep, 2023, 13(1): 15667.
- [21] Hicks SA, Strümke I, Thambawita V, et al. On evaluation metrics for medical applications of artificial intelligence[J]. Sci Rep, 2022, 12(1): 5979.
- [22] Hajian-Tilaki K. Receiver operating characteristic (ROC) curve analysis for medical diagnostic test evaluation[J]. Caspian J Intern Med, 2013, 4(2): 627-635.
- [23] Liu ZH, Hu J, Gong XL, et al. Skin lesion segmentation with a multiscale input fusion U-Net incorporating Res2-SE and pyramid dilated convolution[J]. Sci Rep, 2025, 15(1): 7975.
- [24] Domingos P. A few useful things to know about machine learning[J]. Commun ACM, 2012, 55(10): 78-87.
- [25] Lin FB, Wang KF, Lai MY, et al. Multicenter study on predicting postoperative upper limb muscle strength improvement in cervical spinal cord injury patients using radiomics and deep learning[J]. Sci Rep, 2025, 15(1): 5805.

(编辑: 薛泽玲)