



在线全文

一种用于创面检测的改进Faster R-CNN方法*

张斯斯¹, 史忠祥², 江峰², 丁敏¹, 刘聪聪¹, 段飞^{3△}

1. 山东第一医科大学附属省立医院中心院区 重症医学科一病区(济南 250021); 2. 青岛科技大学信息科学技术学院(青岛 266061);
3. 山东第一医科大学附属省立医院奥体院区 重症医学科(济南 250000)

【摘要】目的 通过引入注意力增强机制和改进后处理策略,对更快的基于区域的卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)进行改进,即用于创面检测的改进Faster R-CNN方法(wound detection method based on improved faster R-CNN, WD-IFRCNN),以提高创面检测的准确性和稳定性。**方法** ①算法构建:以50层残差网络(50-layer residual network, ResNet-50)为主干网络,在第4残差阶段(convolutional stage 4, Conv4_x)和第5残差阶段(convolutional stage 5, Conv5_x)嵌入模糊注意力引导模块(fuzzy mask attention module, FMAM)协同的卷积块注意力模块(convolutional block attention module, CBAM),以增强模型对创面关键区域及边界模糊区域的特征表达能力;同时采用软非极大值抑制(soft non-maximum suppression, Soft-NMS)替代传统非极大值抑制策略,以减少重叠目标场景中的漏检。②算法验证:实验数据集由开源创面图像和临床采集图像构成,共740张原始图像,经数据增强后扩展至5920张,并采用十折交叉验证进行评估。通过内部验证、外部验证、超参数调优和消融实验,采用精确率、召回率、平均精确率和F1分数等指标对模型性能进行评价。**结果** ①内部验证表明,同时在ResNet-50的Conv4_x和Conv5_x阶段嵌入CBAM时模型性能最佳;采用ResNet-50-CBAM作为主干网络时,模型检测效果优于VGG16和ResNet-50。②外部验证表明,WD-IFRCNN的精确率、召回率、平均精确率和F1分数分别达到92.31%、93.95%、92.33%和0.93,其中平均精确率较SSD、YOLOv4、YOLOv5、YOLOv8、DETR、RT-DETR和FR-CNN-FPN分别提高3.21%、2.30%、1.39%、0.86%、0.82%、0.37%和0.63%。③消融实验表明,CBAM、FMAM和Soft-NMS均对模型性能提升具有积极作用,三者联合时检测效果最佳。**结论** WD-IFRCNN能够有效增强模型对创面关键区域及模糊边界区域的特征表达能力,提高创面检测的准确性和稳定性,对复杂创面场景具有较好的适应性,可为临床创面评估与辅助诊断提供一定的技术支持。

【关键词】 创面检测 Faster R-CNN 卷积块注意力模块 模糊注意力引导模块 软非极大值抑制

An Improved Faster R-CNN Method for Wound Detection

ZHANG Sisi¹, SHI Zhongxiang², JIANG Feng², DING Min¹, LIU Congcong¹, DUAN Fei^{3△}. 1. Ward I, Department of Critical Care Medicine, Central Hospital District, Shandong First Medical University Affiliated Provincial Hospital, Jinan 250021, China; 2. College of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, China; 3. Intensive Care Medicine Department of the Olympic Sports Institute District, Shandong First Medical University Affiliated Provincial Hospital, Jinan 250000, China

△ Corresponding author, E-mail: sashuang444@163.com

This study was supported by the National Natural Science Foundation of China (No. 61973180, No. 62172249).

[Abstract] Objective By introducing an attention enhancement mechanism and improving the post-processing strategy, the Faster Region-based Convolutional Neural Network (Faster R-CNN) is enhanced. The resulting improved Faster R-CNN method for wound detection (WD-IFRCNN) increases the accuracy and stability of wound detection. **Methods** ① Algorithm construction: The 50-layer residual network (ResNet-50) is used as the backbone. In the fourth residual stage (convolutional stage 4, Conv4_x) and fifth residual stage (convolutional stage 5, Conv5_x), the fuzzy mask attention module (FMAM) and convolutional block attention module (CBAM) are embedded together to enhance the model's ability to represent features in key areas and blurry regions of the wound surface. At the same time, soft non-maximum suppression (Soft-NMS) replaces the traditional non-maximum suppression strategy to reduce missed detections in overlapping target scenarios. ② Algorithm validation: The experimental dataset consists of open-source wound images and clinically collected images, totaling 740 original images. After data augmentation, the dataset expands to 5920 images and is evaluated using ten-fold cross-validation. Model performance is assessed through internal validation, external validation, hyperparameter tuning, and ablation experiments, using metrics such as precision, recall, average precision, and F1 score. **Results** ① Internal validation showed that the model performs best when CBAM is embedded in both the Conv4_x and Conv5_x stages of ResNet-50. When ResNet-50-CBAM is used as the backbone, the

* 国家自然科学基金(No. 61973180, No. 62172249)资助

△ 通信作者, E-mail: sashuang444@163.com

出版日期: 2026-05-20

model's detection performance surpasses that of VGG16 and ResNet-50. ② External validation showed that WD-IFRCNN achieves an precision of 92.31%, recall of 93.95%, average precision of 92.33%, and F1 score of 0.93. The average precision was 3.21%, 2.30%, 1.39%, 0.86%, 0.82%, 0.37%, and 0.63% higher than SSD, YOLOv4, YOLOv5, YOLOv8, DETR, RT-DETR, and FR-CNN-FPN, respectively. ③ Ablation experiments showed that CBAM, FMAM, and Soft-NMS each positively impact model performance, with the best results achieved when all are used together. **Conclusion** WD-IFRCNN effectively enhances the model's ability to represent features in key areas and blurry regions of the wound surface, improves the accuracy and stability of wound detection, and demonstrates good adaptability to complex wound scenarios. It can provide technical support for clinical wound assessment and auxiliary diagnosis.

[Key words] Wound detection Faster R-CNN CBAM Fuzzy mask attention module Soft-NMS

创面检测在现代临床医学中占据着非常重要的地位,尤其是在创伤处理、慢性病管理以及术后护理等领域^[1]。对创面进行准确检测及评估,不仅能够为医护人员提供重要的诊断依据,而且还能显著提升患者的治疗效果和康复质量。当前的临床中的创面检测主要依赖于医护人员的经验和直觉,这种方法不仅主观性强,而且容易受外界因素的干扰,导致诊断结果的准确性不高,并且大量消耗人力资源。此外,创面类型繁多,加之创面形态的复杂性以及创面位置的多样性,进一步增加了检测的难度。因此,通过机器学习技术来提高创面检测的准确性和效率,已经成为当前的研究热点^[2-3]。

近年来,随着深度学习技术的发展,基于卷积神经网络(convolutional neural network, CNN)的目标检测为医学图像分析提供了更为有效的新方法^[4]。作为典型的目标检测模型,更快的基于区域的卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)在医学图像处理中表现良好。ZAOUK等^[5]将Faster R-CNN应用于白血病和淋巴瘤分类, TALAAT等^[6]将其用于前列腺癌检测, SARMUN等^[7]则将其引入糖尿病足溃疡检测任务,均取得了较好效果。然而,现有方法在创面检测中仍存在一定不足:小目标特征在深层卷积和下采样过程中容易丢失;复杂背景、边界模糊及目标重叠等问题容易导致误检和漏检;医疗图像标注成本较高,数据集规模有限,也会影响模型的泛化能力。

针对上述问题,本文提出一种用于创面检测的改进Faster R-CNN方法(wound detection method based on improved faster R-CNN, WD-IFRCNN)。该方法以50层残差网络(50-layer residual network, ResNet-50)为主干网络,在网络中嵌入卷积块注意力模块(convolutional block attention module, CBAM)^[8]和模糊注意力引导模块(fuzzy mask attention module, FMAM),并采用软非极大值抑制(soft non-maximum suppression, Soft-NMS)^[9]算法抑制冗余边界框,以增强模型对创面区域尤其是小目标和模糊边界区域的检测能力。同时,本文结合多种数据增强方法扩展创面数据集规模和多样性,从而提升模型的泛化

性能。实验结果表明,WD-IFRCNN能够更准确地识别和定位创面区域。

1 对象和方法

1.1 数据集

本研究经山东省立医院涉及人的生物医学研究伦理委员会批准,批准号省医伦批第SWYX:NO.2026-188号。通过开源数据集和医院临床采集两种方式构建实验数据集。其中,开源数据集包含创面图像284张,包括烧伤52张、割伤48张、擦伤80张和压疮104张;临床采集创面图像456张,其中急性创面157张、慢性创面299张。最终共获得740张原始创面图像。为提升数据集规模和多样性,本文对原始图像进行数据增强。经数据增强后,最终得到5920张创面图像。我们采用十折交叉验证法对数据集进行划分,在每一折中按照创面类型对样本进行分层采样,以保证训练集与测试集中不同创面比例分布基本一致。数据增强仅用于训练集,以扩展特征空间并降低过拟合风险,每一折测试集均保留74张原始图像,用于评价模型在真实临床场景下的检测性能。数据增强效果如网络资源附件附图1所示。

本文使用的开源数据集图像无遮挡且均为单一类型创面,分辨率为512×512;临床图像由智能手机和高清相机采集,原始分辨率范围为640×480至1 280×960。我们采用统一标注规则,使用LabelImg对所有图像中的创面区域进行边界框标注,以PASCAL VOC格式保存;对于存在遮挡或边界模糊的样本,由两位标注人员协商确定目标范围。

1.2 WD-IFRCNN框架

本文提出的WD-IFRCNN算法整体框架如网络资源附件附图2所示。WD-IFRCNN主要包括特征提取、候选区域生成与目标识别、后处理与结果输出三个阶段。首先,将输入创面图像送入以ResNet-50-CBAM为主干网络的特征提取模块,并在中高层特征提取阶段引入CBAM和FMAM,以增强模型对创面模糊边界的感知能力;其次,利用区域建议网络(region proposal network, RPN)生

成候选区域,并完成边界框回归与目标分类;最后,采用Soft-NMS对检测结果进行后处理,抑制冗余框并输出最终创面定位结果。

下面对WD-IFRCNN的关键组成部分进行介绍。

1.3 基于ResNet-50的特征提取网络

传统Faster R-CNN采用的VGG16网络在高分辨率和细粒度图像任务中容易受到限制。为提高创面检测的特征提取能力,本文选取ResNet-50作为主干网络。ResNet-50引入残差连接缓解了梯度退化问题,更适合创面检测任务中对细粒度信息的表达需求。考虑到深层网络带来的参数冗余,本文进一步对ResNet-50的卷积通道进行结构化剪枝,以批归一化层中的缩放因子作为判据,对贡献较低的通道进行裁剪,从而降低模型参数量和计算复杂度。

在此基础上,本文将FMAM协同的CBAM嵌入ResNet-50中,具体结构如网络资源附件附图3所示。对第4残差阶段(convolutional stage 4, Conv4_x)和第5残差阶段(convolutional stage 5, Conv5_x)的每个残差块,在其输出后依次插入CBAM和FMAM,以增强中高层特征表达能力和对创面边界模糊区域的感知能力。Conv2_x和Conv3_x主要提取低级边缘信息,对全局语义特征增强作用有限,因此本文未在这些残差块中引入注意力模块。

1.4 模糊注意力引导模块

在创面检测任务中,目标区域常存在边界模糊和结构不清晰的问题。为增强模型对模糊边界区域的感知能力,本文设计了模糊注意力引导模块(FMAM),其整体结构如网络资源附件附图4所示。

FMAM在CBAM空间注意力路径前引入模糊引导分支。具体地,首先对输入特征图进行 1×1 卷积以实现通道降维,在降低冗余特征的同时保持空间分辨率不变;然后利用 3×3 卷积提取模糊边界区域的空间特征,并经Sigmoid函数激活生成取值范围为 $[0,1]$ 的模糊掩码图 M 。掩码图反映了不同空间位置的相对模糊程度,掩码值越大,表示该区域越需要被重点关注。最后,将 M 与CBAM空间路径中由平均池化和最大池化生成的基础特征逐元素相乘,以引导空间注意力生成过程更加关注边界模糊区域,其表达式如公式(1)所示。

$$A_s = \text{Sigmoid}(f_{7 \times 7}([f_{\text{avg}}(X) \| f_{\text{max}}(X)] \cdot M)) \quad (1)$$

其中, A_s 表示最终的空间注意力图, $f_{7 \times 7}(\cdot)$ 表示 7×7 卷积操作, $f_{\text{avg}}(\cdot)$ 和 $f_{\text{max}}(\cdot)$ 分别表示平均池化和最大池化操作。 $\parallel$ 表示通道拼接操作。

在参数设置上,FMAM通过 1×1 卷积进行通道降维,以平衡特征表达能力与计算复杂度;在降维后,采用

3×3 卷积进行局部空间建模,以增强对创面边界信息的感知能力。FMAM与CBAM空间注意力紧密结合,在保留原有注意力机制全局感知能力的同时,加强了对模糊边界区域的建模能力。

1.5 Soft-NMS

传统非极大值抑制(non-maximum suppression, NMS)需人为设置阈值 N_t ,阈值过大易引入误检,阈值过小则导致漏检。当两个检测框的交并比(intersection over union, IoU)超过阈值时,NMS会直接删除得分较低的候选框,这在创面边界模糊或区域变化较大的情况下会丢失有效结果。为减轻上述问题,本文采用Soft-NMS替代传统NMS,并使用线性衰减策略对候选框置信分数进行更新,其计算公式如公式(2)所示。

$$S_i = \begin{cases} S_i, & \text{if } \text{IoU}(R, b_i) \leq N_t \\ S_i \times [1 - \text{IoU}(R, b_i)], & \text{if } \text{IoU}(R, b_i) > N_t \end{cases} \quad (2)$$

其中, b_i 表示第 i 个检测框, S_i 表示第 i 个检测框所对应的置信分数, R 表示得分最高的候选框, N_t 表示所给定的阈值。Soft-NMS不会直接删除重叠候选框,而是通过降低其置信分数来保留更多潜在目标。

1.6 验证方案

内部验证:通过不同CBAM嵌入位置及不同主干网络的对比实验,验证WD-IFRCNN关键结构设计的合理性。

外部验证:通过比较WD-IFRCNN与SSD^[10]、YOLOv4^[11]、YOLOv5^[12]、YOLOv8^[13]、DETR^[14]、RT-DETR^[15]和IFR-CNN-FPN^[16]算法,验证本文方法的有效性。

超参数调优:通过分析不同参数设置下模型性能的变化,确定超参数的最优取值。

消融实验:通过不同模块配置实验,验证各组成模块对模型性能的贡献。

1.6.1 评价指标

为验证WD-IFRCNN的有效性,本文采用精确率(precision, P)、召回率(recall, R)、平均精确率(average precision, AP)和F1-分数(即P与R的调和平均数)作为性能评价指标。

1.6.2 操作方法

本文基于深度学习框架Pytorch 1.7.1和Python 3.8.0对模型进行搭建,使用Nvidia RTX 4060 GPU实现算法。

WD-IFRCNN采用随机梯度下降(stochastic gradient descent, SGD)优化器进行训练,动量因子为0.9,批大小为4,初始学习率为0.0001,每迭代80次衰减为原来的一半,训练轮数(epoch)为250。RPN和检测器中的边界框回归损失均采用Smooth L1损失,Soft-NMS中的抑制系数和IoU阈值均设为0.5,CBAM采用默认参数。考虑到主干网

络经过结构化剪枝,本文在剪枝后进行了少量微调训练。

对比实验选取的基线方法均采用原论文或官方实现推荐的参数设置与训练策略,以保证实验比较的合理性和公平性。

2 结果

2.1 内部验证

2.1.1 CBAM嵌入位置对模型性能的影响

为验证CBAM嵌入位置对模型性能的影响,本文以ResNet-50为主干网络的Faster R-CNN模型为基础框架,分别将CBAM模块嵌入在Conv4_x、Conv5_x及Conv4_x+Conv5_x残差块之后,实验结果如表1所示。在Faster R-CNN中嵌入CBAM之后,模型的各项评价指标均得到了一定程度的提升。其中,在Conv4_x与Conv5_x的残差块之后嵌入CBAM模块,模型的性能最佳,模型精确率、召回率和F1分数分别达到87.23%、93.34%和0.90。说明在Conv4_x与Conv5_x阶段同时引入CBAM,能够更有效提升模型的特征表达能力和创面检测性能。

表 1 CBAM嵌入位置的不同对Faster R-CNN (ResNet-50)模型的影响
Table 1 The impact of different CBAM embedding positions on the model Faster R-CNN (ResNet-50)

Embedding position	P/%	R/%	F1-score
None	80.56	87.63	0.83
Conv4_x	84.72	91.35	0.87
Conv5_x	86.21	92.57	0.89
Conv4_x + Conv5_x	87.23	93.34	0.90

P: precision; R: recall. The F1 score is the harmonic mean of precision and recall.

2.1.2 三种主干网络对模型性能的影响

为比较不同主干网络对模型性能的影响,本文选取VGG16、ResNet-50和ResNet-50-CBAM作为Faster R-CNN的主干网络进行实验,结果如表2所示。采用ResNet-50-CBAM作为主干网络时,模型性能最佳。与VGG16和ResNet-50相比,其精确率和召回率均有不同程度提升,表明引入CBAM后,主干网络对创面区域特征的

表 2 三种主干网络对Faster R-CNN模型的影响
Table 2 The impact of three main network structures on the model Faster R-CNN

Backbone	P/%	R/%	AP/%	Detection time/ms
VGG16	79.15	86.29	81.34	340
ResNet-50	80.56	87.63	85.63	352
ResNet-50-CBAM	87.23	93.34	90.07	358

P: precision; R: recall; AP: average precision.

提取能力得到了进一步增强。

综合各项指标,本文最终选择ResNet-50-CBAM作为主干网络。

2.2 外部验证

2.2.1 性能比较

在相同的数据集和测试平台上,本文将WD-IFRCNN算法与其他基线算法进行了实验对比,每一折测试样本量设置为 $n=74$ 。实验结果如表3所示。

表 3 不同算法的性能比较
Table 3 Performance comparison of different algorithms

Model	P/%	R/%	AP/%	F1-score	Detection time/ms
YOLOv4 (CSPDarkNet53)	91.94	88.75	90.03	0.90	323
SSD (VGG16)	87.67	90.28	89.12	0.88	387
YOLOv5 (CSPDarkNet53)	92.15	89.87	90.94	0.91	287
DETR (ResNet-50)	91.20	93.80	91.51	0.92	495
YOLOv8 (Modified Backbone)	92.49	91.12	91.47	0.92	293
RT-DETR (ResNet-50)	91.58	93.10	91.96	0.92	418
FR-CNN-FPN (ResNet-50)	91.61	93.13	91.70	0.92	405
WD-IFRCNN	92.31	93.95	92.33	0.93	295

P: precision; R: recall; AP: average precision. The F1 score is the harmonic mean of precision and recall.

WD-IFRCNN在精确率、召回率、平均精确率和F1分数等指标上均达到最优或近似最优。尤其是召回率达到93.95%,表明该方法能够检测到更多真实创面,有效降低漏检率。与YOLO系列的算法相比,WD-IFRCNN在各评价指标上均有提升,说明WD-IFRCNN在边界模糊和形态复杂创面目标检测中表现更好。

此外,在Transformer类检测方法中,DETR和RT-DETR在召回率方面表现较为突出,说明基于全局建模的注意力机制有助于覆盖潜在目标区域,但由于缺乏基于候选区域的局部关注机制,其精确率和识别时间仍低于WD-IFRCNN和FR-CNN-FPN。

FR-CNN-FPN作为两阶段检测方法,在精确率和召回率方面同样取得了较好结果,但其对创面边界模糊问题缺乏针对性建模,因此平均精确率和召回率仍低于WD-IFRCNN。

2.2.2 P-R曲线比较

图1给出了WD-IFRCNN与其他基线算法的P-R曲线。在召回率处于0.2至0.8区间时,WD-IFRCNN的精确率整体高于其他基线算法,尤其在召回率接近0.8时仍能保持较高精确率。

YOLOv5和YOLOv8在高召回率区间具有较好的精




图1 不同算法的P-R曲线

Fig 1 P-R curves of different algorithms

P-R: precision-recall.

准确率稳定性。DETR和RT-DETR在较高召回率范围内表现较稳定,说明基于Transformer的全局建模有助于提升目标覆盖能力。FR-CNN-FPN整体性能优于除WD-IFRCNN外的其他算法。

总体来看,WD-IFRCNN在大多数召回率区间内均保持较优的精确率表现,尤其在中高召回率阶段能够较好平衡漏检与误检,体现出更稳定的创面检测性能。

2.2.3 损失曲线比较

图2给出了WD-IFRCNN与各基线算法在250轮训练中的损失曲线。各算法在训练初期损失值均快速下降,中期下降速度减缓,至150个epoch后逐渐趋于稳定,说明模型基本收敛。




图2 不同算法的训练损失曲线

Fig 2 Training loss curves for different algorithms

从整体趋势看,WD-IFRCNN在训练过程中始终保持较低的损失水平,在训练初期下降更快,说明该方法能够更早聚焦于创面区域;在训练后期,其损失值稳定在较低水平,表明模型具有较好的收敛稳定性。

2.3 超参数调优

为提升WD-IFRCNN在创面检测任务中的整体性能,我们对超参数进行了调优分析。每项超参数均通过控制

变量法设置不同取值,并记录其在评价指标上的变化,从而探究超参数对创面检测的具体影响并选取适当的超参数。

2.3.1 Soft-NMS中IoU阈值对性能的影响

为分析Soft-NMS中IoU阈值对模型性能的影响,本文将IoU阈值设置在0.3至0.7之间,步长为0.05,实验结果如图3所示。




图3 不同IoU阈值下模型性能指标的变化趋势

Fig 3 Trends in model performance indicators at different IoU thresholds

IoU: intersection over union.

随着IoU阈值由0.3增大到0.7,模型精确率呈现先升后降的趋势,召回率持续下降,F1分数在IoU=0.5附近达到最高。较低的IoU阈值对预测框容忍度较高,虽有助于提高召回率,但也容易引入更多误检,导致精确率偏低;随着阈值增大,模型的精确率与召回率逐渐达到较优平衡,并在IoU=0.5时取得最佳检测效果。当阈值继续增大时,部分边界偏移较大的预测框被抑制,导致召回率下降。综合考虑各项性能指标,本文选取IoU=0.5作为Soft-NMS的默认阈值。

2.3.2 Soft-NMS中抑制系数对性能的影响

抑制系数 σ 用于控制候选框高度重叠时非极大值候选框置信度的衰减幅度,其取值会影响模型在保留潜在目标与抑制冗余框之间的平衡。为分析 σ 对检测性能的影响,本文以0.1为步长设置不同 σ 值进行实验,结果如图4所示。

随着 σ 增大,模型召回率持续上升,而精确率呈下降趋势,说明较小的 σ 对冗余框抑制更强,虽能减少误检,但也可能漏检真实目标;较大的 σ 则有助于保留更多候选框,从而提高召回率,但同时会带来更多误检。F1分数在 $\sigma=0.5$ 附近达到最高,表明此时模型在精确率与召回率之间取得了较好平衡。

考虑到创面目标数量较少,且部分样本存在边界模糊和预测偏移现象,适当减弱抑制强度有助于提高检测




图 4 不同抑制系数下模型性能指标的变化趋势

Fig 4 Trends in model performance indicators under different suppression coefficients (σ)

The F1-score is explained in the footnote to Table 1.

完整性。故本文选取 $\sigma=0.5$ 作为默认设置。

2.3.3 CBAM中通道压缩比对性能的影响

CBAM的通道注意力机制通过两层全连接网络对特征通道进行压缩与恢复,通道压缩比(r)影响注意力表达能力与参数复杂度之间的平衡。为分析该参数对检测性能的影响,本文分别设置 r 为8、16和32进行实验,每一折测试集样本量设置为 $n=74$,结果如表4所示。

表 4 不同通道压缩比下的模型性能指标

Table 4 Model performance indicators at different channel compression ratios (r)

r	P/%	R/%	F1-score	Detection time/ms
8	92.32	92.1	0.92	354
16	92.31	93.95	0.93	295
32	91.27	94.52	0.92	282

P, R, F1-score: abbreviations are given in the footnote to Table 1.

当 $r=16$ 时,模型各项指标表现良好,F1分数达到0.93,略高于 $r=8$ 和 $r=32$ 的情况,但识别时间比 $r=32$ 时略低。考虑到创面图像通常具有边界模糊、形态不规则等特点,我们综合各项性能指标,选取 $r=16$ 作为默认设置。

2.3.4 FMAM中通道降维比对性能的影响

为验证FMAM中采用 1×1 卷积进行降维的有效性,本文进一步对其通道降维比进行了选型实验。在保持其他网络结构与训练参数不变的条件下,分别设置不同通道降维比进行性能评估,每一折测试集样本量设置为 $n=74$,结果如表5所示。

当通道降维比 $r_f=8$ 时,模型能够保留较多通道信息,但计算开销较大,识别时间明显增加;当通道降维比为 $r_f=32$ 时,虽然推理速度有所提升,但压缩程度过高,部分判别性特征丢失,导致检测精确率下降。相比之下,当通

表 5 不同通道降维比下的模型性能指标

Table 5 Model performance indicators for different channel dimension reduction ratios (r_f)

r_f	P/%	R/%	F1-score	Detection time/ms
8	92.61	93.52	0.93	363
16	92.31	93.95	0.93	295
32	91.80	93.10	0.92	284

P, R, F1-score: abbreviations are given in the footnote to Table 1.

道降维比为16时,模型在检测性能与计算效率之间取得了较好平衡。

综合各项指标,本文最终选取通道降维比为16作为FMAM的默认设置。

2.4 消融实验

为评估WD-IFRCNN各组成模块对检测性能的影响,本文设计了多组消融实验,分别验证CBAM、FMAM和Soft-NMS单独及组合使用时的效果,每一折测试集样本量设置为 $n=74$,实验结果如表6所示。

表 6 WD-IFRCNN在不同组件配置下的性能指标

Table 6 Performance Indicators of WD-IFRCNN with different component configurations

No.	CBAM	FMAM	Soft-NMS	P/%	R/%	AP/%	F1-score
1	√	×	×	87.23	93.34	90.07	0.90
2	×	×	√	88.35	90.47	89.12	0.90
3	×	√	×	90.12	92.40	90.20	0.91
4	√	×	√	90.23	92.34	90.87	0.92
5	√	√	×	91.08	93.82	91.75	0.92
6	√	√	√	92.31	93.95	92.33	0.93

All abbreviations are given in the footnote to Table 3.

仅引入CBAM时,模型已取得较高召回率,说明CBAM能够有效增强通道与空间特征表达,但由于缺乏后处理与模糊边界引导机制,精确率较低。仅引入Soft-NMS时,模型精确率有所提高,表明该方法能够在一定程度上抑制冗余检测,但整体性能提升有限。仅引入FMAM时,模型在各方面均有所改善,特别地,召回率达到92.40%,说明FMAM能够有效增强模型对边界模糊区域的关注,降低漏检率。

当同时引入CBAM和Soft-NMS时,模型F1分数提升至0.92,AP达到90.87%,表明注意力机制与候选框抑制策略具有较好的互补性;当引入CBAM和FMAM时,召回率提升至93.82%,AP提高至91.75%,说明FMAM能够在CBAM基础上进一步增强对模糊创面边界的感知能力。完整模型融合CBAM、FMAM和Soft-NMS后取得了最优性能,表明三者在特征增强、模糊边界建模和后处理抑制方面具有良好

的协同作用,能够显著提升创面检测的稳定性和准确性。

3 讨论

目前,基于深度学习的目标检测方法已广泛应用于医学图像分析领域。但是,传统特征提取与NMS策略仍易导致表征不足和漏检。近年来,研究者已将CNN、Faster R-CNN及YOLO系列模型应用于压力性溃疡^[17]、烧伤^[18]、肺结节^[19]、胰腺病灶^[20]和其他医学目标检测任务^[21-22],并通过注意力机制以及多尺度特征融合提升检测性能。然而,现有方法在复杂创面场景下的边界表征能力及模型稳定性方面仍存在不足。针对上述问题,本文提出了WD-IFRCNN算法,以ResNet-50为主干网络,在高层特征提取阶段引入FMAM协同的CBAM,并采用Soft-NMS替代传统NMS,提升模型对复杂创面区域的检测能力。

在实验对比中,WD-IFRCNN在内部验证、外部验证和消融实验中均表现出较好性能。该方法有助于提高创面检测的效率与准确性,减轻医护人员的人工判读负担,并可为创面评估、愈合监测及治疗方案制定提供一定的辅助支持。

然而,WD-IFRCNN仍存在一定局限性。首先,实验数据集规模相对有限,且部分创面图像来源于不同设备和场景,可能会对模型的泛化能力产生影响;其次,对于复杂背景、严重遮挡及边界极不清晰的创面样本,模型检测性能仍有进一步提升空间。后续工作将进一步扩大数据集规模,优化模型结构与参数设置,并结合轻量化设计提高模型在实际临床场景中的适应性和应用价值。

* * *

作者贡献声明 张斯斯负责论文构思、数据审编和初稿写作,史忠祥负责正式分析、软件和验证,江峰负责经费获取、监督指导和审读与编辑写作,丁敏负责调查研究和可视化,刘聪聪负责研究方法和验证,段飞负责研究项目管理和提供资源。所有作者已经同意将文章提交给本刊,且对将要发表版本进行最终定稿,并同意对工作的所有方面负责。

Author Contribution ZHANG Sisi is responsible for conceptualization, data curation, and writing--original draft. SHI Zhongxiang is responsible for formal analysis, software, and validation. JIANG Feng is responsible for funding acquisition, supervision, and writing--review and editing. DING Min is responsible for investigation and visualization. LIU Congcong is responsible for methodology and validation. DUAN Fei is responsible for project administration and resources. All authors consented to the submission of the article to the Journal. All authors approved the final version to be published and agreed to take responsibility for all aspects of the work.

利益冲突 所有作者均声明不存在利益冲突

Declaration of Conflicting Interests All authors declare no competing interests.

参 考 文 献

- [1] RIPPON M G, FLEMING L, CHEN T, *et al.* Artificial intelligence in wound care: diagnosis, assessment and treatment of hard-to-heal wounds: a narrative review. *J Wound Care*, 2024, 33(4): 229-242. doi: 10.12968/jowc.2024.33.4.229.
- [2] CARRIÓN H, JAFARI M, BAGOOD M D, *et al.* Automatic wound detection and size estimation using deep learning algorithms. *PLoS Comput Biol*, 2022, 18(3): e1009852. doi: 10.1371/journal.pcbi.1009852.
- [3] SONG Y, ZHENG S, LI L, *et al.* Deep learning enables accurate diagnosis of novel coronavirus (covid-19) with CT images. *IEEE Trans Comput Biol Bioinform*, 2021, 18(6): 2775-2780. doi: 10.1109/TCBB.2021.3065361.
- [4] RAWAT W, WANG Z. Deep convolutional neural networks for image classification: a comprehensive review. *Neural Comput*, 2017, 29(9): 2352-2449. doi: 10.1162/neco_a_00990.
- [5] ZAOUK S A, MATAR T, ALI M A, *et al.* Classification of leukemia and lymphoma using Faster R-CNN//International Conference on Microelectronics. Casablanca, Morocco: IEEE, 2022: 25-29. doi: 10.1109/ICM56065.2022.10005371.
- [6] TALAAT F M, EL-SAPPAGH S, ALNOWAISER K, *et al.* Improved prostate cancer diagnosis using a modified ResNet50-based deep learning architecture. *BMC Med Inform Decis Mak*, 2024, 24(1): 23. doi: 10.1186/s12911-024-02420-4.
- [7] SARMUN R, CHOWDHURY M E H, MURUGAPPAN M, *et al.* Diabetic foot ulcer detection: combining deep learning models for improved localization. *Cogn Comput*, 2024, 16(3): 1413-1431. doi: 10.1007/s12559-024-10267-3.
- [8] WOO S, PARK J, LEE J Y, *et al.* CBAM: convolutional block attention module//European Conference on computer vision. Munich, Germany: Springer, 2018: 3-19. doi: 10.1007/978-3-030-01234-2_1.
- [9] BODLA N, SINGH B, CHELLAPPA R, *et al.* Soft-nms--improving object detection with one line of code//IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 5561-5569. doi: 10.1109/ICCV.2017.593
- [10] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: single shot multibox detector//European Conference on Computer Vision, Amsterdam, Netherlands: Springer, 2016: 21-37. doi: 10.1007/978-3-319-46448-0_2.
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection. (2020-04-23)[2025-05-10]. <https://arxiv.org/abs/2004.10934>.
- [12] JOCHER G. YOLOv5: Github repository. (2020-05-29)[2025-05-10]. <https://github.com/ultralytics/yolov5>.
- [13] JOCHER G, CHAURASIA A, QIU J, *et al.* YOLOv8: ultralytics yolov8. (2023-01-10) [2026-01-20]. <https://github.com/ultralytics/ultralytics>.
- [14] CARION N, MASSA F, SYNNAEVE G, *et al.* End-to-end object detection with transformers//European Conference on Computer Vision. Glasgow, UK: Springer, 2020: 213-229. doi: 10.1007/978-3-030-58452-8_13.
- [15] ZHAO Y, LV W, XU S, *et al.* Detsr beat yolos on real-time object detection//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2024: 16965-16974. doi: 10.1109/CVPR52733.2024.01605.
- [16] FENG L, WANG Q, YU N. An object detection method based on multilayer attention mechanism. *Alex Eng J*, 2025, 133: 338-348. doi: 10.1016/j.aej.2025.10.028.
- [17] ALDUGHAYFIQ B, ASHFAQ F, JHANJHI N Z, *et al.* Yolo-based deep learning model for pressure ulcer detection and classification. *Healthcare (Basel)*, 2023, 11(9): 1222. doi: 10.3390/healthcare11091222.
- [18] 王瑞, 张嘉炜, 张克诚, 等. 基于深度学习的皮肤烧伤创面图像分割与分类及检测的研究进展. *中华损伤与修复杂志*, 2024, 19(2): 172-175. doi: 10.3877/cma.j.issn.1673-9450.2024.02.014.
- [19] WANG R, ZHANG J W, ZHANG K C, *et al.* Advances in deep learning-based image segmentation, classification and detection of skin burn and

- scald wounds. *Chin J Inj Repair Wound Healing*, 2024, 19(2): 172-175. doi: [10.3877/cma.j.issn.1673-9450.2024.02.014](https://doi.org/10.3877/cma.j.issn.1673-9450.2024.02.014).
- [19] 宋方方, 孙兆永, 田益民, 等. 基于改进的YOLOv5肺结节检测方法. *软件工程与应用*, 2023, 12(2): 257-263. doi: [10.12677/SEA.2023.122026](https://doi.org/10.12677/SEA.2023.122026).
- SONG F F, SUN Z Y, TIAN Y M, *et al.* Based on the improved yolov5 lung nodule detection method. *SEA*, 2023, 12(2): 257-263. doi: [10.12677/SEA.2023.122026](https://doi.org/10.12677/SEA.2023.122026).
- [20] KARRI C, SANTINHA J A A, PAPANIKOLAOU N, *et al.* Pancreatic cancer detection through semantic segmentation of CT images: a short review. *Discov Artif Intell*, 2024, 4: 101. doi: [10.1007/s44163-024-00148-x](https://doi.org/10.1007/s44163-024-00148-x).
- [21] LALINIA M, SAHAFI A. Colorectal polyp detection in colonoscopy images using yolo-v8 network. *Signal Image Video Process*, 2024, 18(3): 2047-2058. doi: [10.1007/s11760-023-02835-1](https://doi.org/10.1007/s11760-023-02835-1).
- [22] 李家昱, 陈明惠, 杨瑞君, 等. 糖尿病视网膜病变眼底图像筛查研究. *中国激光*, 2022, 49(11): 1107001. doi: [10.3788/CJL202249.1107001](https://doi.org/10.3788/CJL202249.1107001).

LI J Y, CHEN M H, YANG R J, *et al.* Research on fundus image screening for diabetic retinopathy. *Chin J Lasers*, 2022, 49(11): 1107001. doi: [10.3788/CJL202249.1107001](https://doi.org/10.3788/CJL202249.1107001).

(2025-03-02收稿, 2026-04-02修回)

编辑 吕 熙



开放获取 本文使用遵循知识共享署名—非商业性使用 4.0国际许可协议(CC BY-NC 4.0), 详细信息请访问

<https://creativecommons.org/licenses/by-nc/4.0/>。

OPEN ACCESS This article is licensed for use under Creative Commons Attribution-NonCommercial 4.0 International license (CC BY-NC 4.0). For more information, visit <https://creativecommons.org/licenses/by-nc/4.0/>.

© 2026《四川大学学报(医学版)》编辑部

Editorial Office of *Journal of Sichuan University (Medical Sciences)*