

基于 IVOCT 的动脉粥样硬化斑块识别与风险评估

韩泽君¹, 林兴康¹, 裘耀阳¹, 张晓¹, 高磊^{2*}, 李勤^{1*}¹北京理工大学医学技术学院, 北京 100081;²中国人民解放军总医院第六医学中心, 北京 100048

摘要 动脉粥样硬化引起的易损斑块破裂已经严重危害到人类的健康,而血管内光学相干断层成像(IVOCT)凭借其高分辨率已经成为识别冠脉易损斑块的主要工具,但图像判读费时费力,通常还依赖于医生的经验。目前已有基于传统机器学习的研究实现了对单帧图像的分类,但这些信息不足以辅助医生确定治疗方案,仍然需要医生二次判读。基于 Faster R-CNN(R-CNN,区域卷积神经网络),针对 IVOCT 图像中易损斑块的特点,在数据增强、预测框(BBox)编码、网络结构等方面进行了改进和优化,实现了对易损斑块的自动识别,并选取易损斑块的病变累积角度、纤维帽厚度、巨噬细胞浸润情况、浅表微钙化情况和血管狭窄程度作为指标,对易损斑块的破裂风险进行多方面评估。在公开数据集 CCCV2017 IVOCT 中进行训练,测试后取得了较好结果,该方法可推广应用于同类图像。

关键词 医用光学; 动脉粥样硬化; 血管内光学相干断层成像; 易损斑块; 自动识别; 风险评估

中图分类号 O436

文献标志码 A

DOI: 10.3788/CJL231452

1 引言

急性冠脉综合征(ACS)因其极高的致死率和致残率被认为是最危险的心血管疾病之一^[1],近 70% 的 ACS 是由冠状动脉粥样硬化的易损斑块破裂引起的^[2]。动脉粥样硬化是指血管壁中大量脂质、胆固醇、纤维成分、单核细胞和各种其他炎症细胞发生积聚并沉积,最终形成了灰黄色的粥样斑块^[3]。随着斑块内容的持续沉积和炎症反应的发生,斑块逐渐成熟、增大,进而发展成易损斑块^[4]。血管内光学相干断层成像(IVOCT)凭借其高分辨率(10~20 μm)能够准确识别薄帽纤维粥样(TCFA)斑块等易损斑块特征,逐渐成为诊断易损斑块的金标准^[5-7]。一方面,经验丰富的医生会在图像中标注斑块位置,然而这一过程不可避免地受到医生主观判断的影响^[8]。另一方面,医生的经验来自大量临床实践的积累,且一次回撒包含数百张 IVOCT 腔内截面图像^[9],手动判读严重影响了对易损斑块的诊断速度和精度。因此,研究人员正试图开发易损斑块的自动检测算法以减少医生负担,提高诊断精度。

随着深度学习技术的发展,卷积神经网络(CNN)如 Alexnet^[10-11]、VGG^[12-13]、ResNet^[14]和 DenseNet^[14]已经应用于斑块分类和检测^[15]。Chu 等^[8]使用 U 型编码器-解码器结构的深度学习网络,实现了对动脉粥样硬化斑块、巨噬细胞和胆固醇晶体的

分割;Shi 等^[16]提出了一种基于多任务深度卷积神经网络(DCNN)的 IVOCT 图像脆弱斑块自动检测系统。但是这些算法只能提供目标斑块的位置信息,其破裂风险及对应的治疗方案仍完全依赖于医生的主观经验。根据最新的 IVOCT 专家诊断共识^[17]和美国心脏病协会的研究^[18],易损斑块引起的最终结果与多种因素相关,并非所有易损斑块都会导致血管阻塞。据报道,在稳定型冠状动脉疾病患者中无症状破裂的发生率达到 58%^[19]。由于 IVOCT 的分辨率无法达到分子水平,不足以判断患者的生理生化状况,因此图像仅能表征易损斑块的结构特征。为了实现易损斑块破裂风险的量化评估、规范治疗措施和减轻医生负担,开发计算机辅助诊断(CAD)系统变得迫切且重要。

本文基于 Faster R-CNN(R-CNN,区域卷积神经网络)框架提出了一种用于 IVOCT 图像内易损斑块识别的端到端评估算法,该算法除了能够准确定位易损斑块外,还可以提示斑块的高危风险因素并量化评估斑块破裂风险,为临床医生提供诊断建议并辅助其制定治疗方案。

2 方法与原理

对 IVOCT 图像的处理流程如图 1 所示,主要包含自动定位易损斑块、对斑块进行风险评估以及模型测试。具体算法处理分为四个步骤:1)将原始图像转换

收稿日期: 2023-11-29; 修回日期: 2024-01-14; 录用日期: 2024-01-15; 网络首发日期: 2024-01-26

基金项目: 国家自然科学基金(61975017)、首都卫生发展科研专项(首发 2024-2-5072)

通信作者: *liqin@bit.edu.cn; *nkgaolei2010@126.com

为极坐标下的灰度图像。为便于观察,采用伪彩色处理一般的 IVOCT 图像,其颜色通道不包含任何病理信息;2) 在极坐标下检测易损斑块的位置,并在图中

输出预测框(BBox);3) 对自动定位后的斑块进行破裂风险评估;4) 对斑块的定位方法和风险评估方法进行测试并输出相应指标。

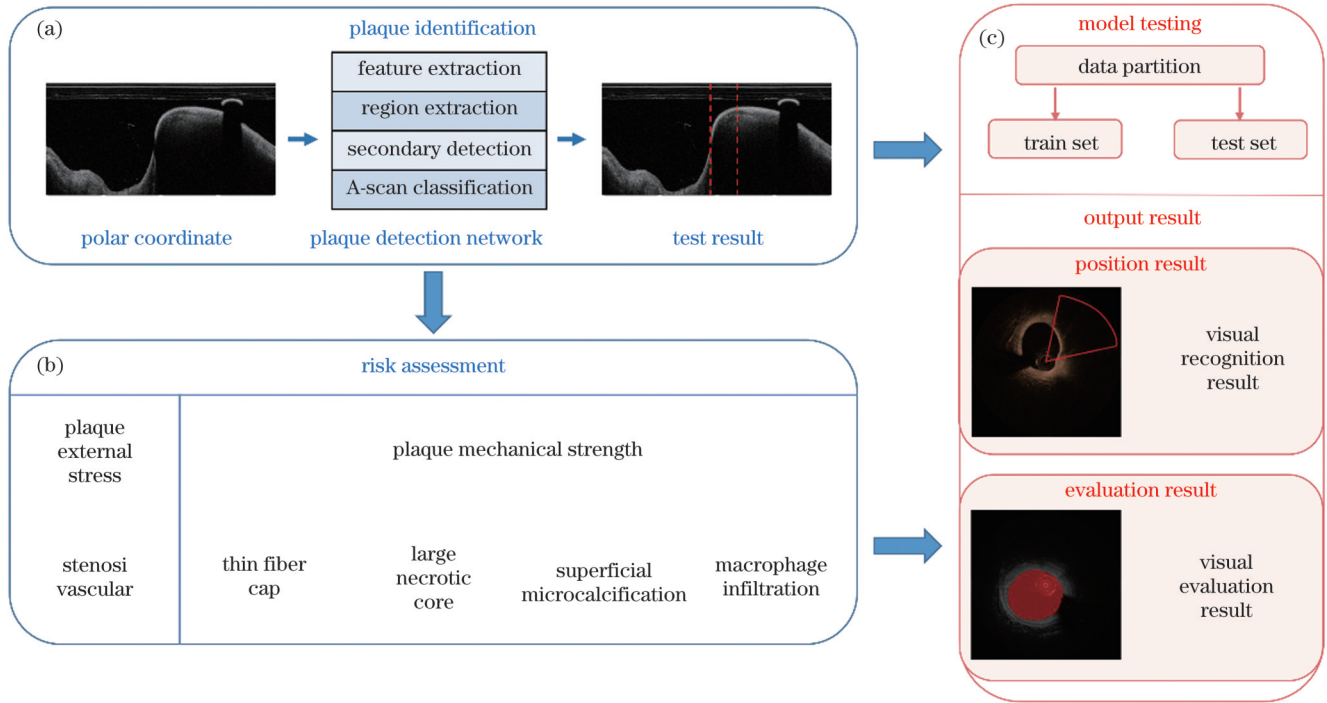


图 1 易损斑块的自动识别与风险评估流程。(a)斑块识别;(b)风险评估;(c)模型测试

Fig. 1 Automatic identification and risk assessment process of vulnerable plaque. (a) Plaque identification; (b) risk assessment; (c) model testing

2.1 易损斑块识别

Faster R-CNN 是目标检测领域中最经典的方案之一^[20],其通过区域建议网络(RPN)、区域提取网络和 R-CNN 联合训练来实现高效的目标检测,本文选择 Faster R-CNN 作为基线方法,根据 IVOCT 图像特点提出了循环移位增强数据、 (X, W) 编码 BBox 和引入额外语义分割头的改进策略,以提高网络对易损斑块定位的精度。所提网络的总体结构如图 2 所示,分为特征提取、区域提取、二次检测和 A-Scan 分类四个模块,其中 L 表示前部分得到的特征, S 表示与原图大小相同的特征。

特征提取模块用来接收输入图像,并生成压缩的特征图。本文选择 ResNet 作为主干网络。目前常用的 ResNet 结构包括 ResNet18、ResNet34、ResNet50、ResNet101、ResNet152,网络名称中的后缀数字表示网络层数,其数字越大,网络层数越多,对特征的表征能力越强。但层数增加也会导致网络参数增加,降低推理速度,同时会加大梯度回传的深度,使网络难以训练。对不同层数的网络使用数据测试后发现 ResNet18 在各指标下的测试结果均优于其他网络,且处理速度最快,因此最终选择 ResNet18 作为骨干网络。ResNet 包含四组堆叠的残差块,对输入图像逐层进行残差块运算后,能够提取到高级语义信息,同时压

缩特征图的大小。为了提高易损斑块的定位精度,本文使用了特征金字塔结构^[21],同时用残差块的输出特征图作为后续输入,保留底层纹理特征。在极坐标图像中,易损斑块的 BBox 只能通过横轴信息进行定位,因此本文选择改变原始网络中的 BBox 编码结构 (X, Y, W, H) ,其中 X 和 Y 表示 BBox 的中心坐标, W 和 H 表示 BBox 的宽和高,使用新的 BBox 编码方式 (X, W) 编码,去除冗余的纵坐标信息以提高网络处理速度。

区域提取模块负责在特征图中选择可能的候选区域,并将区域内提取到的特征尺寸映射为统一尺寸。候选区域的生成由 RPN 完成,通过在特征图上滑动卷积窗,RPN 对特征图上的每个特征点输出 $1 \times 2k$ 的分类输出和 $1 \times 2k$ 的坐标回归输出,其中 k 是对每个点预设的锚(Anchor)数量。Anchor 是每个特征点预设的初始检测框,其以特征点为中心,生成不同尺寸、不同长宽比的边框。然后用分类头对每个 Anchor 进行二分类,其中有目标是阳性,无目标是阴性,得到 $k \times 2$ 的分类结果,简单映射后便得到 $2k$ 的分类输出。坐标回归部分的操作与之类似,但每个 Anchor 的输出为 1×2 的坐标,对应的是真实边框的坐标偏移,因此映射后的坐标回归输出为 $1 \times 2k$ 。通过这种设计,RPN 便实现了前景 Anchor 的提取和边框回归,然后通

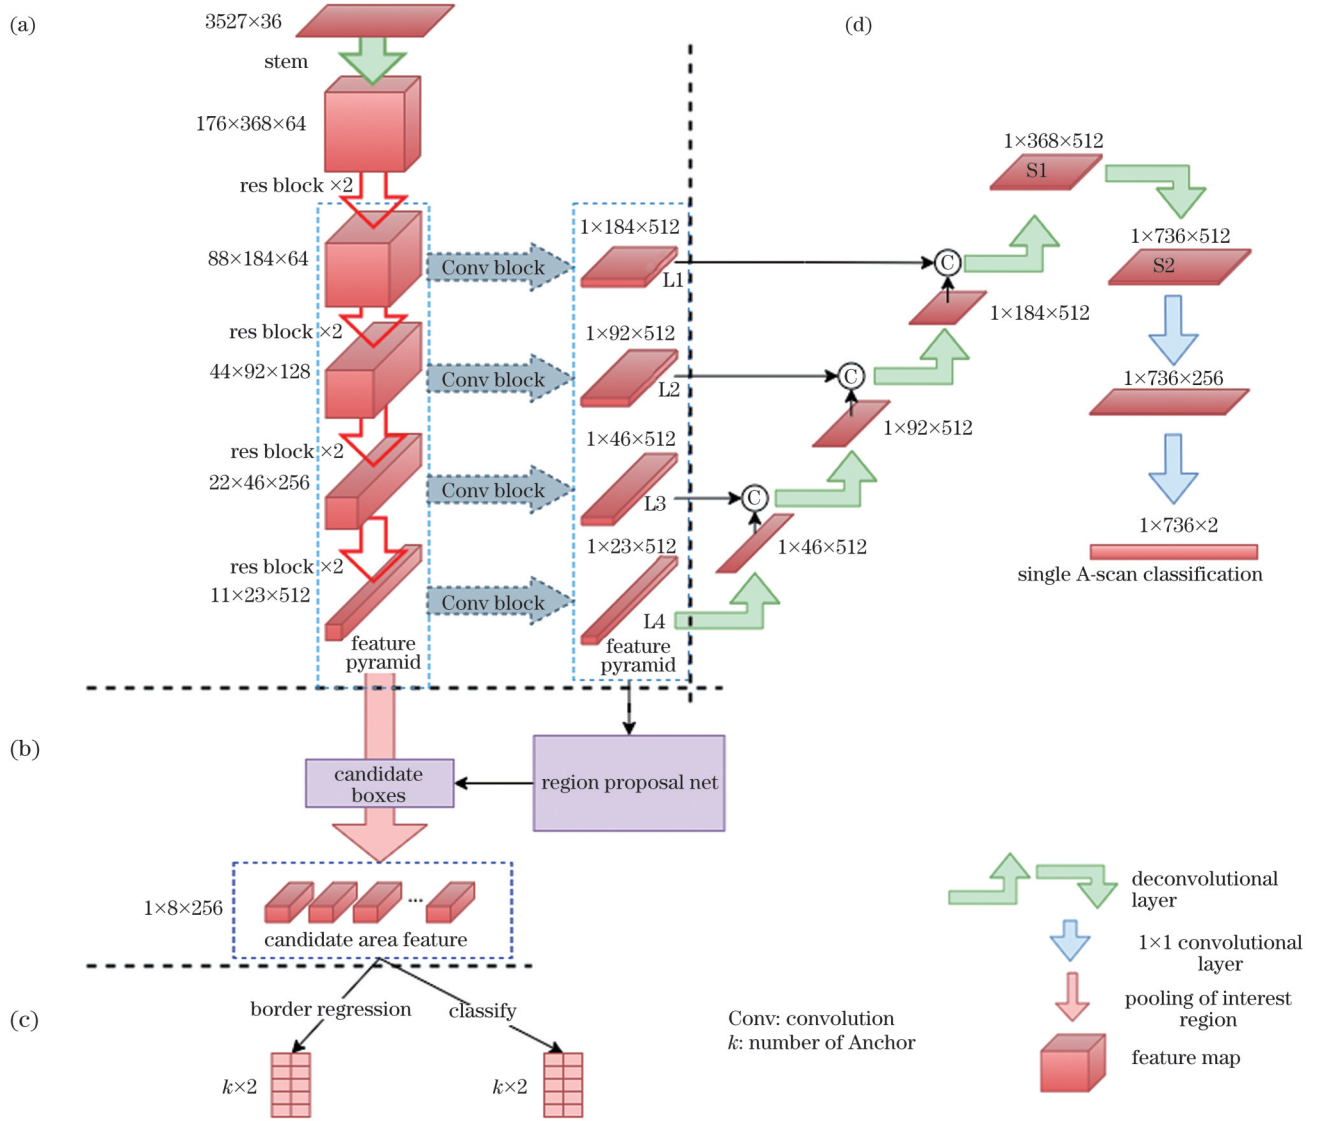


图 2 易损斑块检测网络。(a)特征提取模块;(b)区域提取模块;(c)二次检测模块;(d)A-Scan分类模块

Fig. 2 Vulnerable plaque detection network. (a) Feature extraction module; (b) region extraction module; (c) secondary detection module; (d) A-Scan classification module

过非极大值抑制(NMS)去除重叠率过高的 Anchor,得到互不重叠的候选区域。

第三部分是二次检测模块,用于从上述步骤提出的候选区域中进一步过滤出正确的区域。感兴趣区域(ROI)池化技术用于将不同区域的特征映射转化为相同大小的特征图。二次检测模块的原理与RPN相同,二者的差别在于RPN接收的待检测区域为预设的Anchor,而二次检测模块接收的待检测区域为RPN输出的候选区域。二次检测模块的输出结果存在大量重叠的可能,因此需要通过NMS操作去除重叠率过高的Anchor。考虑到在一幅IVOCT图像中仅存在1~2个易损斑块区域,最后只保留去重处理后得分最高的5个边框作为最终的定位输出结果。

最后一部分是A-Scan分类模块。由于易损斑块

标注的上下边界紧贴图像边缘,无法明确标注区域内易损斑块的具体形状,因此难以在像素级别上区分其是否为易损斑块。将图像的每一列像素视为一个整体,即单条A-Scan,显然此时落在标注区域内的A-Scan为阳性样本,落在标志区域外的A-Scan为阴性样本,从而得到A-Scan级的分类标签。对整张图像的所有单条A-Scan进行分类,其对应标签集合为 $\{x_1, x_2, \dots, x_j, \dots, x_{720}\}$ 的序列,其中 $x_j \in \{0, 1\}, j \in \{0, 1, \dots, 720\}$ 。本文借鉴了多任务卷积神经网络(MTCNN)^[22]的设计,在Faster R-CNN中额外引入了一个分割头,同时实现对易损斑块的定位和A-Scan分类。本文采用U-Net结构输出A-Scan分类结果。从图2中最高级特征L4开始,通过一次反卷积运算得到与低级特征图L3大小相同的语义特征图,并与特征图L3拼接得到混合特征M3。然后从M3重复反卷积、拼接操作,逐层融

合特征,得到尺寸为 $1 \times 184 \times 1024$ 像素点的混合特征图 M1。该特征图既包含高层语义特征,又保留了底层纹理特征,但宽度相比经过填充的输入图像增大了 4 倍,因此需通过两层反卷积层得到与原图尺寸相同的特征图 S2。在分支的最后使用两个 1×1 卷积层将通道数调整为 2,用来判断 A-Scan 是否为阳性。网络的总损失由区域提取部分、二次检测部分和单个 A-Scan 分类头三部分的平均权重组成,可表示为

$$L_{\text{total}} = \left(\frac{L_{\text{cls-RPN}} + L_{\text{loc-RPN}} + L_{\text{cls}} + L_{\text{loc}}}{2} + L_{\text{seg}} \right) / 3, \quad (1)$$

式中: L_{seg} 为分割头部分的分类损失; L_{cls} 和 L_{loc} 分别为二次检测头部分的分类损失和回归损失; $L_{\text{cls-RPN}}$ 和 $L_{\text{loc-RPN}}$ 分别为 RPN 部分的分类损失和回归损失。

表 1 易损斑块高危风险因素及 IVOCT 图像特点

Table 1 High-risk factors and IVOCT image characteristics of vulnerable plaques

Risk factor of plaque rupture	High risk factor	Image characteristic
Plaque external stress	Stenosis vascular	Lumen stenosis
Plaque mechanical strength	Thin fiber cap	Cap thickness $\leq 65 \mu\text{m}$
	Large necrotic core	Lesion accumulation angle $\geq 90^\circ$
	Superficial microcalcification	Superficial calcified nodules and bright spots
	Inflammatory response (macrophage infiltration)	Alternating light and dark stripes

本文使用光学血流分数(OFR)^[24]表征易损斑块处的血管狭窄程度。在介绍 OFR 之前,需要先介绍冠状动脉血流储备分数(FFR)。FFR 为在狭窄病变情况下该冠状动脉提供给心肌的最大血流量与理论上无狭窄病变情况时心肌所能获得最大血流量的比值^[25]。FFR 是目前公认评估冠脉狭窄生理学意义的金标准。OFR 则是基于 IVOCT 图像的 FFR,其意义是通过计算病变处的管腔横截面积与远端无狭窄病变处横截面积之比(后面面积均指横截面积),来表征病变处的狭窄情况。由于本研究使用的数据集图像是不连续的,仅可计算病变处的管腔面积,因此,本文选择在多个数据集上表现良好的 DeepLabV3+ 算法,网络结构如图 3 所示,该网络使用分割网络中常用的编码器-解码器结构。在获得管腔掩模后,需要对掩模区域进行一次形态学开闭操作,以消除边界毛刺、内部孔洞和外部噪声。然后对掩模区域的像素个数进行计数,结合图像比例尺度得到管腔面积(S),其计算公式为

$$S = N \times \left(\frac{D}{H} \right)^2, \quad (2)$$

式中: N 为掩模区域内的像素点数目; D 为设备穿透深度(5 mm); H 为极坐标系的图像高度,在本文数据集上为 352 个像素点。

纤维帽的主要成分是纤维组织,其对近红外光的反射系数较大,在图像中与坏死脂质核相比更亮,所以

2.2 易损斑块的破裂风险评估

冠心病患者的尸检结果^[23]和 IVOCT 的验证实验^[17]表明,斑块的破裂风险受两个因素影响:机械强度和外部应力。机械强度由易损斑块的内部压力和组织强度决定,其高危因素包括薄纤维帽(病理学研究将薄纤维帽厚度阈值定义为 $65 \mu\text{m}$)、大的坏死核心(病变累积角度 $\geq 90^\circ$)、浅表微钙化和严重炎症反应(巨噬细胞浸润)等。外部应力主要指斑块部位的血液压力,这通常由管腔的狭窄程度决定。在血流量固定的情况下,管腔越窄,血流速度越快,压力也越大。表 1 列出了 IVOCT 图像可以显示的易损斑块高危风险因素,这些因素综合影响了易损斑块的最终结果。由于目前尚无研究说明各个风险因素的权重,本文选择构建基于单一因素的斑块破裂多参数风险模型。

能够通过亮度阈值进行区分。由于不同成像设备的激光功率、接收探头的转换率均存在差异,因此不同批次图像中纤维组织和脂质组织的亮度阈值也可能不同。为了避免这种差异带来的影响,本文设计了一种自适应亮度阈值选择方法。利用前面得到的斑块位置和空腔掩模信息,得到去除空腔噪声后的易损斑块区域。将区域内的斑块表面对齐到同一水平线,并采用 5×5 高斯滤波器来去除噪声。然后,对表面一定范围内的像素点进行计数,以确定当前图像的纤维帽厚度。临床普遍认为纤维帽厚度小于 $65 \mu\text{m}$ 的易损斑块破裂风险较高,因此选取的范围在表面 5 个像素以内,对应的实际深度为 $71.02 \mu\text{m}$ ^[26]。亮度阈值(t)的具体计算公式为

$$t = \bar{X} - \sigma, \quad (3)$$

式中: \bar{X} 为区域内像素值的平均值; σ 为标准差。得到亮度阈值后,将超过亮度阈值的像素点定义为纤维帽区域,计算该区域内所有 A-Scan 的纤维帽厚度,得到平均纤维帽厚度和最薄纤维帽厚度。纤维帽划分的具体过程如图 4 所示。

斑块的起止角度在极坐标系下即为易损斑块区域的左右边界,因此病变累积角度(θ , 单位为 $^\circ$)可以用极坐标系下区域宽度衡量,可表示为

$$\theta = \frac{W_{\text{ROI}}}{W} \times 360, \quad (4)$$

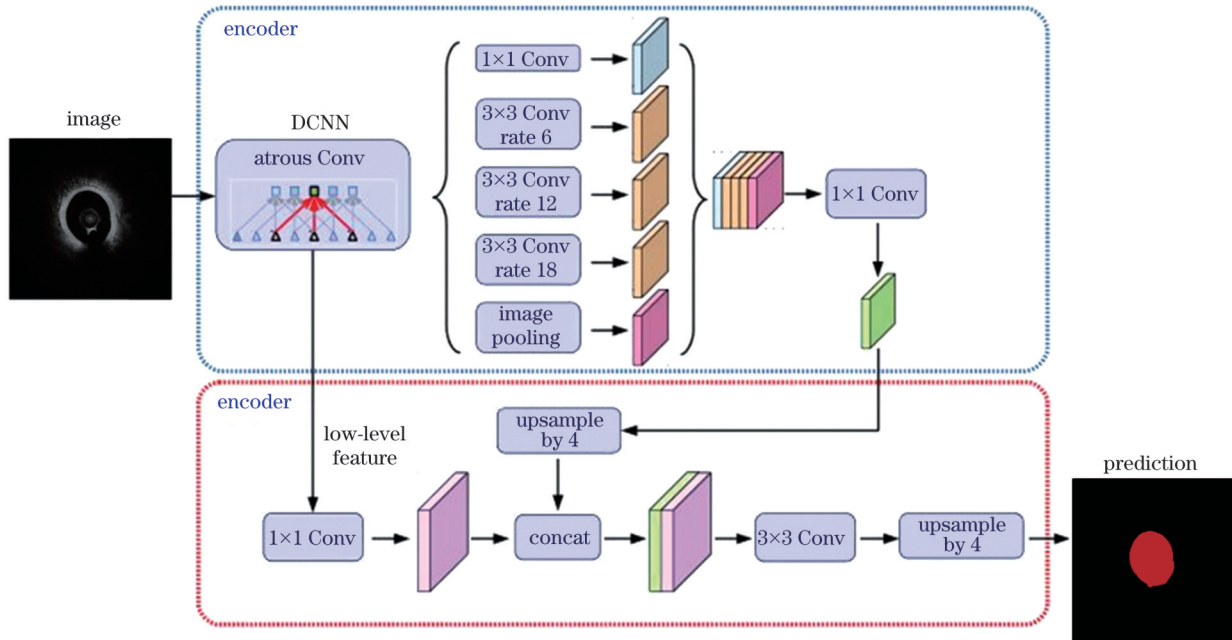


图 3 DeepLabV3+网络结构
 Fig. 3 Network structure of DeepLabV3+




图 4 易损斑块纤维帽厚度计算过程。(a)结合易损斑块位置信息去除导管噪声后的裁剪结果；(b)血管腔(上表面)对齐结果；
 (c) 5×5 高斯滤波器的去噪结果；(d)计算分割亮度阈值,将超过亮度阈值的像素点圈定为纤维帽区域,其中白线为纤维帽边界
 Fig. 4 Calculation process of fiber cap thickness of vulnerable plaque. (a) Crop result after removing catheter noise by combining vulnerable plaque location information; (b) alignment result of vascular lumen (upper surface); (c) result of noise removal by 5×5 Gaussian filter; (d) calculating segmentation brightness threshold and delineating pixel points exceeding brightness threshold as fiber cap region with fiber cap boundary shown by white line

式中： W_{ROI} 为板块区域宽度； W 为图像宽度(720个像素点)。显然,当区域定位准确时病变累积角度评估也相应准确。

浅表微钙化指易损斑块纤维帽附近的微小钙化结节,在IVOCT图像上表现为纤维帽底部边界清晰的灰暗区域或连续“亮点”。炎症反应涉及巨噬细胞的参与,而巨噬细胞对近红外光有强吸收作用,因此其在IVOCT图像上会形成暗带。浅表微钙化和巨噬细胞浸润的共同特点是它们破坏了斑块的均匀性并改变了其纹理特征。因此,本文采用图5所示的图像特征抽取再分类的方式对斑块的浅表微钙化和巨噬细胞浸润情况进行评估。易损斑块的特征包括两部分:第一部分由已经训练好的斑块检测网络的特征提取模块ResNet18提取。这部分不再使用金字塔设计输出多层特征图,只输出最顶层的特征图,通过全局平均池化得到 1×512 的一维特征向量,且该部分网络权值与2.1节中对应的子模块相同,并在训练过程中冻结参数。第二部分结合先验知识,即考虑到浅表微钙化和

巨噬细胞浸润都会改变图像的梯度大小和方向,使用梯度方向直方图(HOG)来抽取固定长度的一维特征向量。由于斑块区域的宽度不固定,且全连通层只能接收固定长度的输入,因此本节所呈现的HOG特征采用自适应窗口滑动步进,选择经过表面对齐后的斑块上部128 pixel深度的区域,使用大小为 32×32 的检测窗口滑动检测,保证垂直滑动采样4次,水平滑动采样12次,每个检测窗口有4个单元格,每个单元格的梯度方向划分为5个区间。因此,最终的特征向量长度应为 $4 \times 12 \times 4 \times 5$,即960像素点。将 1×512 的神经网络特征向量和 1×960 的HOG特征向量拼接后,通过3个全连通层映射到 1×2 的分类输出,分别对应浅表微钙化的概率和巨噬细胞浸润的概率。中间层激活函数为ReLU函数,设置Dropout策略。这两种概率并不相互排斥,即不排除该区域同时存在浅表微钙化和巨噬细胞浸润的情况。最后一层激活函数是Sigmoid,Sigmoid函数将每个输出限制在 $[0, 1]$ 范围内,符合概率形式且互不干扰。




图5 预测斑块浅表微钙化和巨噬细胞浸润的网络结构

Fig. 5 Network structure for predicting superficial plaque microcalcification and macrophage infiltration

3 结果与讨论

本文使用的数据集为CCCV2017 IVOCT数据集。该数据集由中国科学院西安光学精密机械研究所

提供,用于检测IVOCT图像中的薄纤维帽脂质斑块。该数据集分为训练集数据和测试集数据两部分,训练集数据包含2000张图片,测试集数据包含300张图片,两部分数据中均包含有易损斑块的阳性样本和没有易

损斑块的阴性样本。对于单个阳性样本,数据集为 $\{X_1, X_2\}$ 。斑块的 BBox 标记为 X_1 和 X_2 , 即左右边界。本文模型运行在 Linux 上的 Ubuntu 18.0.4, 并使用 RTX 3090 GPU。

3.1 斑块识别

在训练 Faster R-CNN 时, 采用带动量的随机梯度下降 (SGD) 法进行优化, 其优点是实现简单、效率高, 适用于小规模的数据集和简单模型。实验结果表明, 当批量大小为 8 时网络性能达到最优; 训练曲线表明, 在 70 个回合后网络性能趋于稳定, 并在最高点附近振

荡, 因此将训练回合数设置为 70。由于学习率呈梯度下降, 前 40 回合将其设置为 0.01, 帮助网络快速收敛; 在第 41 和 61 回合, 学习率衰减为前一回合的十分之一以逐步达到最优解, 同时稳定网络。本文还采用了线性 WarmUp 策略^[27], 使学习率在前两个训练回合中从 0.0001 逐渐增长至设定值 0.01。由于 IVOCT 图像中的血管在首尾端是相连的, 而极坐标图像忽略了这种空间上的连续, 为了增强数据的多样性, 本文采用随机循环移位法, 通过在图像尾端选择随机数目的 A-Scan 并移动到最左侧实现, 过程与结果如图 6 所示。

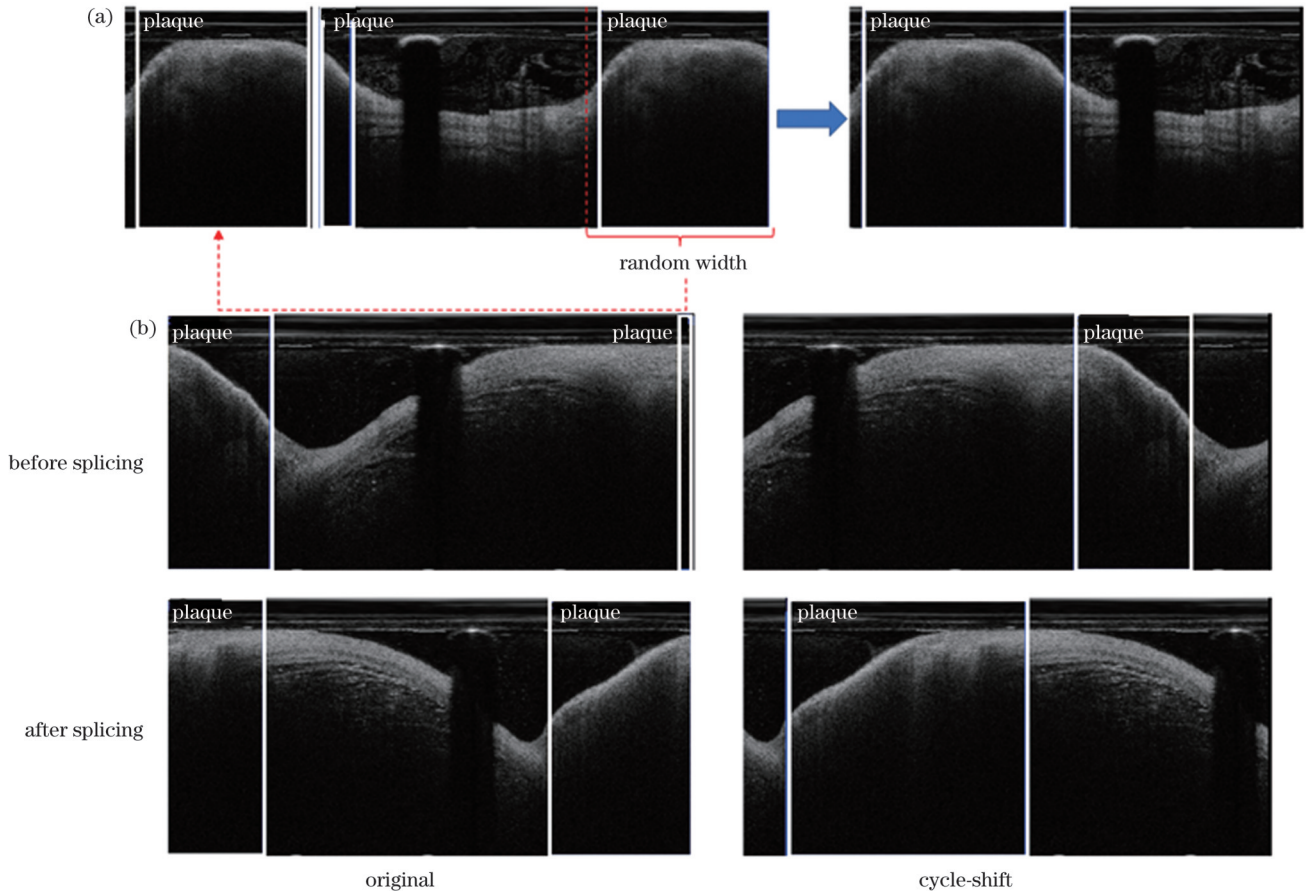


图 6 随机循环移位。(a) 实现过程, 将实线标记的区域裁剪并拼接到左侧; (b) 两个循环移位实例, 左边是初始图像, 右边是循环移位的结果

Fig. 6 Random cyclic shift. (a) Implementation process when area marked by solid line is cropped and spliced to left; (b) two cyclic shift instances, with initial image on left and result of cyclic shift on right

这种方法除了使易损斑块区域完整外, 还增加了斑块水平位置的多样性, 同时使网络学习到的图像首尾两端的空间联系起来。加入随机循环移位方法后, 网络表现出了更好的性能, 如表 2 所示, 对网络的评价指标包括用来衡量检测精度的均值平均精度 (mAP)、交并比阈值为 50 时的均值平均精度 (mAP50)、用来描述正例样本中被预测正确的召回率 (Recall)、用来表示样本相似度的 Dice 系数 (Dice)、帧速率。在表 2 中逐项给出了 2.1 节中对 Faster R-CNN 进行优化的消融实验结果。对比发现, 经过随机循环移位增强数据的方法改进后, 网络对易损斑块的定位效果更佳, 其中

mAP50 增加到 0.744, Dice 系数增加到 0.905。对比只加入单项改动的结果, 可以发现随机循环移位增强数据法对网络性能的提升最大, 这说明了先验知识的重要性。定位结果如图 7(a) 所示, 改进后的网络在实际测试中重合率更高, 对应笛卡儿坐标系下的预测, 如图 7(b) 所示。

此外, 本文提出的定位方法相比于弱监督检测 (WSD) 方法^[28]和基于显著区域的卷积神经网络 (SRCNN) 方法^[29]在召回率上分别提高了 0.028 和 0.012, Dice 系数分别提高了 0.075 和 0.018, 如表 3 所示。

表 2 引入各项改进后网络性能的对比

Table 2 Network performance comparison after introducing each improvement

Network	mAP	mAP50	Recall	Dice	Frame rate / (frame/s)
Baseline	0.462	0.717	0.861	0.890	52.0
Baseline + cyclic shift	0.482	0.716	0.895	0.895	51.9
Baseline + (X, W) encoding	0.465	0.728	0.853	0.882	56.7
Baseline + split branch	0.470	0.720	0.884	0.893	38.5
Baseline + cyclic shift + (X, W) encoding	0.495	0.733	0.891	0.901	56.7
Baseline + cyclic shift + (X, W) encoding + split branch	0.503	0.744	0.912	0.905	41.2

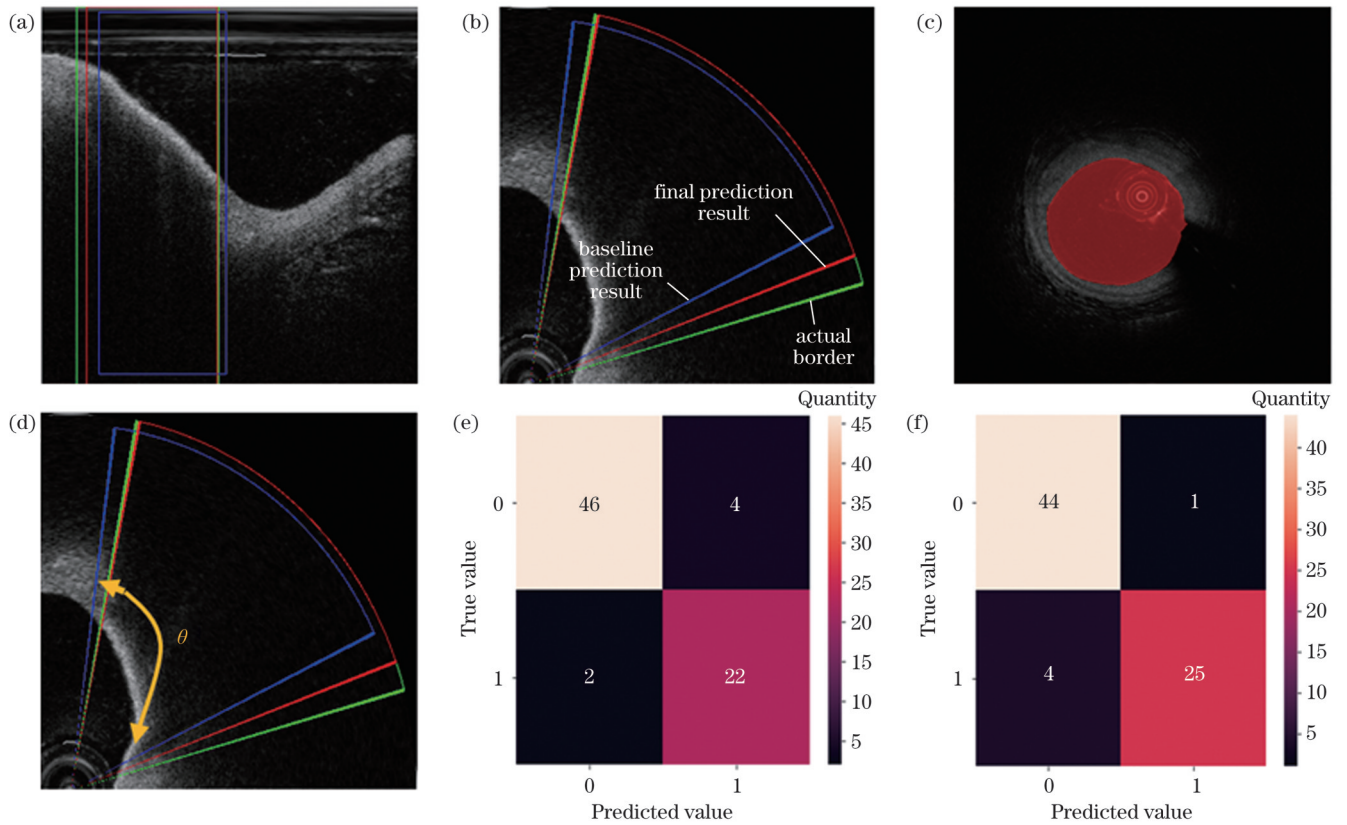


图 7 定位和风险评估结果 (绿色标注为真实边框, 蓝色标注为 Baseline 预测结果, 红色标注为最终预测结果)。 (a) 极坐标图定位; (b) 直角坐标图定位; (c) DeepLabV3+ 分割结果; (d) 病变累积角度; (e) 巨噬细胞浸润的混淆矩阵; (f) 浅表微钙化的混淆矩阵
Fig. 7 Positioning and risk assessment results (green mark is actual border, blue mark is Baseline prediction result, and red mark is final prediction result). (a) Polar map positioning; (b) cartesian map positioning; (c) DeepLabV3+ segmentation result; (d) angle of lesion accumulation; (e) confusion matrix of macrophage infiltration; (f) confusion matrix of superficial microcalcification

表 3 与现有方法的性能比较

Table 3 Performance comparison with existing methods

Network	Recall	Dice
WSD	0.884	0.830
SRCNN	0.900	0.887
Our method	0.912	0.905

3.2 易损斑块的破裂风险评估

在 CCCV2017 IVOCT 数据集中随机选择了 300 张图像并标注了管腔面积, 其中 200 张作为训练集, 100 张作为测试集。为了更直观地展示管腔面积的空间关系, 标记和分割过程均在笛卡儿坐标系中进行。

在极坐标系中, 图像的大小为 720×352 像素点, 转换到笛卡儿坐标系中, 其图像大小为 704×704 像素点。分割网络的训练优化器选择 SGD, 学习率设置为 0.01。训练回合基于批量 (batch) 计数, 总共训练 4000 个 batch, 批量大小设置为 4。管腔面积预测的评估指标为交并比 (IOU), 最终 IOU 值为 0.9445。网络的预测结果如图 7(c) 所示。可见红色掩模区域几乎与管腔区域完全一致。

在 3.2 节的子数据集上标记了纤维帽厚度, 并对 253 个易损斑块区域进行了纤维帽厚度测试。评价指标为均方根误差 (R_{MSE}) 和拟合优度 R^2 , 公式分别为

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{pre,i} - y_i)^2}, \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{pre,i} - y_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2}, \quad (6)$$

式中： n 为易损斑块数量； y_i 为第 i 个斑块纤维帽的平均厚度； $y_{pre,i}$ 为第 i 个斑块的预测纤维帽厚度； \bar{y} 为数据集中所有斑块纤维帽的平均厚度。测试结果 R_{MSE} 为 1.17 pixel, 即 16.62 μm , R^2 为 0.62, 验证了方法的可行性。

根据 2.2 节描述的病变累积角度计算方法可以看出, 当区域定位准确时, 对病变累积角度的评估也相应

准确, 如图 7(d) 所示。

使用 3.2 节所描述的子数据集, 共检测了 253 个易损斑块区域, 包括 71 个浅表微钙化斑块、58 个巨噬细胞浸润斑块和 16 个双阳性斑块。三种情况对应的样本标签分别定义为 $[0, 1]$ 、 $[1, 0]$ 、 $[1, 1]$, 阴性样本标签定义为 $[0, 0]$ 。对这部分少数阳性样本进行翻转扩增, 大致平衡阳性和阴性样本的数量。表 4 显示了正负样本的分布, 共计有 366 个样本, 不同样本又按照 4:1 的比例划分成测试集和验证集。在图 7(e) 和图 7(f) 中, 混淆矩阵显示了模型在预测斑块表面微钙化和巨噬细胞浸润方面的性能。预测微钙化的准确率为 0.962, 召回率为 0.862, F1 分数 0.909, 准确率为 0.932; 巨噬细胞浸润的准确率为 0.846, 召回率为 0.917, F1 分数为 0.880, 精密密度为 0.919。

表 4 用于评估浅表微钙化和巨噬细胞浸润的子数据集样本分布

Table 4 Subdataset sample distribution for assessing superficial microcalcification and macrophage infiltration

Sample	Number			Label
	Training set	Test set	Total	
Only superficial microcalcification sample	88	22	110	$[0, 1]$
Only macrophage infiltration sample	67	17	84	$[1, 0]$
Double positive sample	25	7	32	$[1, 1]$
Negative sample	112	28	140	$[0, 0]$
Total sample	292	74	366	-

4 结 论

基于临床诊断共识提出了一种识别易损斑块和评估破裂风险的算法。该算法在准确定位易损斑块区域的基础上, 选取管腔面积、纤维帽厚度、病变累积角度、浅表微钙化和巨噬细胞浸润等因素作为易损斑块破裂风险的评估指标。首先针对 IVOCT 图像的特点对 Faster R-CNN 进行了改进, 采用随机循环移位法, 简化了 BBox 编码方法, 并增加了语义分割头以提高易损斑块定位精度。同时根据临床判断依据, 建立了易损斑块破裂风险评估模型。

所提出的易损斑块定位算法在各项性能评价指标方面均优于以往研究人员提出的算法, 这将有助于临床医生准确定位易损斑块位置和评估斑块易损性, 减少工作量, 同时减少主观判断的影响。目前的研究工作聚焦于斑块的检测任务, 使用的数据集不能保证来源于同一病人, 后续工作将结合 IVOCT 成像的特性, 利用序列图像学习易损斑块的三维空间特征或相邻帧的序列特征, 从高维度对斑块进行精细分割。同时也将依托临床平台, 探寻易损斑块的各个单一风险因素对总破裂风险的影响, 构建全方面的斑块破裂风险评估模型。未来将进一步对序列 IVOCT 图像数据进行分析, 研究易损斑块的破裂机制, 争取实现对斑块的自动识别与评估, 为易损斑块破裂的早期诊断和急性冠脉综合症的预防提供参考。

参 考 文 献

- [1] Arbab-Zadeh A, Fuster V. From detecting the vulnerable plaque to managing the vulnerable patient[J]. Journal of the American College of Cardiology, 2019, 74(12): 1582-1593.
- [2] Libby P, Pasterkamp G, Crea F, et al. Reassessing the mechanisms of acute coronary syndromes[J]. Circulation Research, 2019, 124(1): 150-160.
- [3] Bentzon J F, Otsuka F, Virmani R, et al. Mechanisms of plaque formation and rupture[J]. Circulation Research, 2014, 114(12): 1852-1866.
- [4] Virmani R, Burke A P, Farb A, et al. Pathology of the vulnerable plaque[J]. Journal of the American College of Cardiology, 2006, 47(8): C13-C18.
- [5] Feldman M D, Cabe A G, Milner T E. IVOCT has a bright future in the identification of vulnerable plaques[J]. JACC: Cardiovascular Imaging, 2019, 12(8): 1529-1531.
- [6] 陆冬筱, 房文汇, 李玉瑶, 等. 光学相干层析成像技术原理及研究进展[J]. 中国光学, 2020, 13(5): 919-935.
Lu D X, Fang W H, Li Y Y, et al. Optical coherence tomography: principles and recent developments[J]. Chinese Optics, 2020, 13(5): 919-935.
- [7] 韦赢兆, 袁铨, 蓝公仆, 等. 心血管光学相干层析成像的研究进展和应用[J]. 激光与光电子学进展, 2021, 58(24): 2400002.
Wei Y Z, Yuan X, Lan G P, et al. Research progress and application of cardiovascular optical coherence tomography[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2400002.
- [8] Chu M, Jia H B, Gutiérrez-Chico J L, et al. Artificial intelligence and optical coherence tomography for the automatic characterisation of human atherosclerotic plaques[J]. EuroIntervention, 2021, 17(1): 41-50.
- [9] Boi A, Jamthikar A D, Saba L C, et al. A survey on coronary atherosclerotic plaque tissue characterization in intravascular optical coherence tomography[J]. Current Atherosclerosis Reports, 2018, 20(7): 33.

- [10] Cheimariotis G A, Riga M, Toutouzas K, et al. Automatic characterization of plaques and tissue in IVOCT images using a multi-step convolutional neural network framework[M]//Lhotska L, Sukupova L, Lacković I, et al. World congress on medical physics and biomedical engineering 2018. Singapore: Springer, 2019, 68: 261-265.
- [11] Wang J B. OCT image recognition of cardiovascular vulnerable plaque based on CNN[J]. *IEEE Access*, 2020, 8: 140767-140776.
- [12] Zhu G F, Chu T S, Ruan Z M, et al. Inflammation-related microRNAs are associated with plaque stability calculated by IVUS in coronary heart disease patients[J]. *Journal of Interventional Cardiology*, 2019, 2019: 9723129.
- [13] Kolluru C, Prabhu D, Gharaibeh Y, et al. Deep neural networks for A-line-based plaque classification in coronary intravascular optical coherence tomography images[J]. *Journal of Medical Imaging*, 2018, 5(4): 044504.
- [14] Gessert N, Lutz M, Heyder M, et al. Automatic plaque detection in IVOCT pullbacks using convolutional neural networks[J]. *IEEE Transactions on Medical Imaging*, 2019, 38(2): 426-434.
- [15] 孙正, 王树雁. 深度学习在血管内光学相干层析成像中的应用现状[J]. *激光与光电子学进展*, 2022, 59(22): 2200002.
- Sun Z, Wang S Y. Application of deep learning in intravascular optical coherence tomography[J]. *Laser & Optoelectronics Progress*, 2022, 59(22): 2200002.
- [16] Shi P W, Xin J M, Liu S J, et al. Vulnerable plaque recognition based on attention model with deep convolutional neural network [C]//2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), July 18-21, 2018, Honolulu, HI, USA. New York: IEEE Press, 2018: 834-837.
- [17] Tearney G J, Regar E, Akasaka T, et al. Consensus standards for acquisition, measurement, and reporting of intravascular optical coherence tomography studies: a report from the International Working Group for Intravascular Optical Coherence Tomography Standardization and Validation[J]. *Journal of the American College of Cardiology*, 2012, 59(12): 1058-1072.
- [18] Stefanadis C, Antoniou C K, Tsiachris D, et al. Coronary atherosclerotic vulnerable plaque: current perspectives[J]. *Journal of the American Heart Association*, 2017, 6(3): e005543.
- [19] Arbustini E, Grasso M, Diegoli M, et al. Coronary atherosclerotic plaques with and without thrombus in ischemic heart syndromes: a morphologic, immunohistochemical, and biochemical study[J]. *The American Journal of Cardiology*, 1991, 68(7): 36B-50B.
- [20] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [21] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [22] Yin X, Liu X M. Multi-task convolutional neural network for pose-invariant face recognition[J]. *IEEE Transactions on Image Processing*, 2018, 27(2): 964-975.
- [23] Dalen J E, Alpert J S, Goldberg R J, et al. The epidemic of the 20th century: coronary heart disease[J]. *The American Journal of Medicine*, 2014, 127(9): 807-812.
- [24] Gutiérrez-Chico J L, Chen Y D, Yu W, et al. Diagnostic accuracy and reproducibility of optical flow ratio for functional evaluation of coronary stenosis in a prospective series[J]. *Cardiology Journal*, 2020, 27(4): 350-361.
- [25] de Bruyne B, Sarma J. Fractional flow reserve: a review: invasive imaging[J]. *Heart*, 2008, 94(7): 949-959.
- [26] Xu M D, Cheng J, Wong D W K, et al. Automatic atherosclerotic heart disease detection in intracoronary optical coherence tomography images[C]//2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, August 26-30, 2014, Chicago, IL, USA. New York: IEEE Press, 2014: 174-177.
- [27] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [28] Shi P W, Xin J M, Zheng N N. Weakly supervised vulnerable plaques detection by IVOCT image[C] //2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI), April 3-7, 2020, Iowa City, IA, USA. New York: IEEE Press, 2020: 1983-1986.
- [29] Liu S J, Deng Y Y, Xin J M, et al. SRCNN: cardiovascular vulnerable plaque recognition with salient region proposal networks [C]//Proceedings of the 2nd International Conference on Graphics and Signal Processing, October 6-8, 2018, Sydney, NSW, Australia. New York: ACM Press, 2018: 38-45.

Identification and Risk Assessment of Atherosclerotic Plaques Based on IVOCT

Han Zejun¹, Lin Xingkang¹, Qiu Yaoyang¹, Zhang Xiao¹, Gao Lei^{2**}, Li Qin^{1*}

¹*School of Medical Technology, Beijing Institute of Technology, Beijing 100081, China;*

²*The Sixth Medical Center of PLA General Hospital, Beijing 100048, China*

Abstract

Objective The rupture of vulnerable plaques caused by atherosclerosis has become one of the most serious threats to human health. Intravascular optical coherence tomography (IVOCT) can accurately identify vulnerable plaque characteristics, such as thin-cap fibroatheroma plaques, owing to its high resolution, and has gradually become the gold standard for the diagnosis of vulnerable plaques. Typically, clinicians must manually mark the location of plaques in an image based on their experience. However, this method is time-consuming and labor-intensive and is susceptible to the subjective assessment of the clinician. Manual interpretation significantly reduces the speed and precision of vulnerable plaque diagnosis. Some studies based on traditional machine learning have been conducted for the detection of vulnerable plaques and have achieved the classification of single-frame images. However, the accuracy of frame-level information is insufficient to assist clinicians in determining treatment strategies. These methods require a second interpretation by clinicians. This study proposes an evaluation algorithm for vulnerable plaque identification in IVOCT images

based on an improved Faster R-CNN (regional convolutional neural network) framework. In addition to accurately locating vulnerable plaques, the algorithm can quantitatively assess the risk of plaque rupture, providing diagnostic suggestions to clinicians and assisting in the formulation of treatment plans. The comprehensive nature of this approach is expected to play an important role in improving the efficiency and precision of vulnerable plaque diagnosis.

Methods This study is divided into two parts: automatic identification of vulnerable plaques and assessment of vulnerable plaque rupture risk. To identify vulnerable plaques based on the Faster R-CNN, this study proposes an improved strategy for enhanced cyclic shift data, (X, W) encoding BBox, and the introduction of additional semantic segmentation heads according to the characteristics of IVOCT images. The network is generally divided into four parts (feature extraction, region extraction, secondary detection, and A-scan classification), allowing the network to locate vulnerable plaques with higher accuracy. In this study, the angle of accumulation of the lesion, the thickness of the fibrous cap, macrophage infiltration, superficial microcalcification, and vascular stenosis degree of vulnerable plaques are selected as indicators to assess the risk of rupture. The vascular lumen area is used to characterize the degree of vascular stenosis in vulnerable plaques; the smaller the lumen area, the more severe the stenosis. Furthermore, an adaptive threshold method is designed to calculate the thickness of the fibrous cap, which is considered thin when the thickness is less than $65\ \mu\text{m}$. The risk of plaque rupture is indicated by a lesion accumulation angle greater than 90° , and a polar graph is used to measure the lesion accumulation angle. To identify superficial microcalcifications and macrophage infiltration, features are extracted from the images and reclassified. The application of these methods makes our study more comprehensive and accurate.

Results and Discussions The proposed method is trained and tested using the public dataset CCCV2017 IVOCT. This study presents the results of the ablation experiment for Faster R-CNN (Table 2). The improved network performs well in positioning vulnerable plaques, with mAP50 increasing to 0.744 and the Dice value increasing to 0.905. Compared with weakly supervised detection (WSD) and salient-region-based convolutional neural network (SRCNN) methods, the method proposed in this study significantly improves the recall and Dice values (Table 3). The intersection of union (IOU) value of the lumen area is 0.9445, and the prediction result is consistent with actual result of the lumen area [Fig. 7(c)]. The root mean square error R_{MSE} and the goodness of fit R^2 are used to verify the feasibility of the calculation of the thickness of the fiber cap, and the test results are 1.17 pixel and 0.62, respectively. After positioning the region accurately, the cumulative angle of the lesion is also accurately assessed [Fig. 7(d)]. To evaluate the performance of the model in predicting superficial plaque microcalcifications and macrophage infiltration, a comprehensive analysis is performed using a confusion matrix [Figs. 7(e) and (f)]. These results demonstrate that the proposed method achieves satisfactory results for multiple evaluation metrics and provides a reliable solution for the identification of vulnerable plaques and rupture risk assessment.

Conclusions In this study, the cyclic shift, (X, W) , and encoding BBox are added, and additional semantic segmentation heads are introduced to the Faster R-CNN network to improve the detection performance for vulnerable plaques. Compared to the initial network and adding only a single change, the method proposed in this study significantly improves the mAP50 and Dice values of the network. Compared with WSD and SRCNN, our method also achieves significant improvements in the recall rate and Dice value. Furthermore, to obtain accurate location results for the vulnerable plaque region, the angle of the plaque region is used to measure the angle of accumulation of the lesion, and the cumulative pixels of the fiber cap are used to calculate the thickness of the fiber cap. Deep neural network features combined with gradient direction histogram features are used to analyze macrophage infiltration and superficial microcalcification, and the vascular stenosis degree is evaluated in the lesion lumen region. Multiple single-evaluation results are used to measure the risk of rupture of vulnerable plaques. The comprehensive method proposed in this paper achieves a significant breakthrough in vulnerable plaque detection and provides more comprehensive and reliable data support for clinical diagnosis in terms of rupture risk assessment.

Key words medical optics; atherosclerosis; intravascular optical coherence tomography; vulnerable plaques; automatic identification; risk assessment