

深度学习在血管内光学相干层析成像中的应用现状

孙正^{1,2*}, 王树雁^{1,2}

¹华北电力大学电子与通信工程系, 河北 保定 071003;

²华北电力大学河北省电力物联网技术重点实验室, 河北 保定 071003

摘要 血管内光学相干层析成像(IVOCT)是目前分辨率最高的血管内成像技术,可以清晰地显示管腔的几何形态及具有近显微特征的血管壁结构。在临床常规应用中,对每段血管会获得数百或上千帧B扫描图像,而人工分析图像耗时费力,结果还可能受到临床医生专业能力的影响。近年来,深度学习技术在医学影像领域不断取得重大突破,也被应用于IVOCT图像的自动分析和处理中。对深度学习在IVOCT研究中的应用现状进行了归纳和总结,主要包括图像分割、组织标定、斑块分类和目标检测,分析了目前存在的问题,并展望了未来可能的发展方向。

关键词 血管内光学相干层析成像;深度学习;卷积神经网络;图像分割;组织标定;斑块分类;目标检测

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.2200002

Application of Deep Learning in Intravascular Optical Coherence Tomography

Sun Zheng^{1,2*}, Wang Shuyan^{1,2}

¹Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, Hebei, China;

²Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, Hebei, China

Abstract Intravascular optical coherence tomography (IVOCT) is a minimally invasive imaging model that currently has the highest resolution. It is capable of providing information of the vascular lumen morphology and near-microscopic structures of the vessel wall. For each pullback of the target vessel, hundreds or thousands of B-scan images are obtained in routine clinical applications. Manual image analysis is time-consuming and laborious, and the findings depend on the operators' professional ability in some sense. Recently, as deep learning technology has continuously made significant breakthroughs in the medical imaging field, it has also been used in the computer-aided automated analysis of IVOCT images. This study outlines the applications of deep learning in IVOCT, primarily involving image segmentation, tissue characterization, plaque classification, and object detection. The benefits and limitations of the existing approaches are discussed, and the future possible development is described.

Key words intravascular optical coherence tomography; deep learning; convolutional neural network; image segmentation; tissue characterization; plaque classification; object detection

1 引言

血管内光学相干层析成像(IVOCT)是目前分辨率最高的介入血管成像技术,可清晰显示血管内壁,在评估冠状动脉血管病变程度、准确分型粥样硬化斑块、识别易损斑块、指导置入支架和评价介入治疗效果等方面发挥着重要作用。目前,临床上常用的IVOCT基于扫频光源的频域OCT系统,其工作原理如下:在

X射线透视指导下,将特制导管插入待测血管腔内并推送至远端,在回撤导管的过程中,位于导管顶端的探头发射近红外激光照射周围组织,当激光遇到不同性质的组织或分界面时,会产生不同深度的后向散射光,利用宽带光源的低相干特性,采用光电探测器探测光强和时间延迟,由样品光和参考光的干涉光谱获得组织的光散射特性分布图,显示血管横截面的形态结构^[1]。

收稿日期: 2021-08-12; 修回日期: 2021-09-05; 录用日期: 2021-10-13

基金项目: 国家自然科学基金(62071181)

通信作者: *sunzheng@ncepu.edu.cn

对常规采集的 IVOCT 图像(B 扫描图像序列和沿管腔长轴方向的纵向视图)进行分割,提取病变区域和感兴趣目标(如血管分叉和支架),并进行组织分类和标定,是准确诊断病变的严重程度、制定合理的治疗计划及实现定量成像的关键步骤,临床上一般由有经验的医学专家手动完成。但是单次回撤导管采集的 B 扫描图像序列中通常包含数百帧图像,而且图像中存在亮度不均匀、不同类型支架的存在和缺失、血液残留、不规则管腔形状、导丝和导管伪影、运动伪影及血管分叉等影响图像分析精度的因素,人工分析的难度较大,耗时费力,且结果的客观性和可重复差,对操作者的专业知识和临床经验的要求较高。因此,基于计算机辅助的自动图像分析对于提高处理精度和效率具有重要意义。

近几年,深度学习(DL)技术在医学影像领域中得到了广泛应用^[2-3]。在图像识别与分类方面,与基于对象/特征的机器学习(ML)方法相比,DL 能够将原始输入图像直接映射为最终的分类结果,避免了由细微或复杂对象所致的不准确特征计算和图像分割错误^[4]。目前,常用 DL 方法的核心都是人工神经网络(ANN),不同的网络结构适用于不同的任务,在实际应用中,可以根据目标任务(如分类或分割)选择最适合的特定网络结构或体系。尤其需要重点考虑网络的类型、深度(层数)或系数的数量[如 ANN 中的节点数量、卷积神经网络(CNN)中卷积滤波器的数量]^[5]。本文对 DL 在 IVOCT 图像分割、组织标定、斑块分类和目标检测等方面的应用现状进行了归纳和总结,分析了目前存在的问题,并展望了未来可能的发展方向。

2 图像分割

对 IVOCT 图像进行准确分割,去除不相关的背景和导管等信息,提取出血管腔、管壁、斑块和支架轮

廓是计算机辅助诊断的第 1 步,对于判断管腔是否狭窄、识别易损斑块、定量测量血管几何形态和血流动力学参数、指导置入支架等具有重要意义,其精度直接影响后续处理效果。获取图像的关键特征信息,还可以降低后续处理数据量、提高图像分析效率。虽然 IVOCT 图像分辨率很高、噪声较少,但仍然存在灰度分布不均匀和伪影(包括导管伪影和运动伪影)等问题,而且由于血管结构及其周围组织成分的多变性,血管边界的内部和外部区域在不同图像中具有不一致的外观。因此,IVOCT 图像自动分割的难度仍然很大。

传统的自动图像分割方法包括基于边缘^[6]、区域^[7]、形态学特征^[8]、聚类^[9]、曲面拟合^[10]及特定理论等方法,其中特定理论包括图论^[11]、中性(NS)理论^[9]、随机游走(RW)理论^[12]、马尔可夫随机场(MRF)模型^[13]、活动轮廓模型(ACM)^[14]和高斯纹理模型(GMM)^[15]等。传统分割方法对各种对象特征都具有普适性,但其时间和空间复杂度较高,需要根据经验预先设置相关参数,而且不能适应复杂的血管环境,当血管腔轮廓不规则或管腔内存在血栓或支架时,分割效果较差。

与传统方法相比,DL 技术对结构变化的容忍度更高,对输入图像结构的先验知识要求更少^[16],而且可以充分利用图像的语义信息实现语义分割,所以 DL 特别是全卷积神经网络(FCN)在自动图像分割领域很有发展潜力^[17]。但是医学图像中的目标边界一般较模糊且梯度复杂,需要较多的高分辨率信息用于精准分割,而 FCN 的可训练参数随着网络深度的增加呈指数增长,增大了训练难度。基于上述原因,用于 IVOCT 图像分割的深度神经网络(DNN)多是在 FCN 的基础上改进的,本小节重点介绍 6 种网络模型,即 U-Net、SegNet、胶囊网络(CapsNet)、N-Net、残差压缩多尺度网络(RSM-Network)和双向金字塔网络(BPN),如表 1 所示。

表 1 6 种基于 DL 的 IVOCT 图像分割方法的对比
Table 1 Comparison of six DL-based methods for IVOCT image segmentation

Method	Advantage	Disadvantage
U-Net	Having simple structure and easy to operate; Capable of incorporating features of different scales	Image details might be lost as the network deepens
SegNet	Having fewer parameters and capable of preserving high-frequency details	Incapable of segmenting objects with complex categories
CapsNet	Requiring less training data; capable of processing with high speed; capable of preserving a large amount of image details	Having high computational burden; Incapable of accurately distinguishing objects close to each other; having outstanding performance only on small data sets
N-Net	Capable of fusing multiscale feature maps	Segmentation accuracy needs to be further improved
RSM-Network	Having strong ability of learning detail features; capable of segmenting boundaries with high robustness and accuracy	Having bad performance in segmenting hierarchical features
BPN	Capable of effectively extracting the semantic features of vessels and preserving the high-resolution image information of vascular boundaries	Requiring complex training process

2.1 U-Net

U-Net 是用于语义分割的经典 CNN 架构之一,由编码和解码单元两个部分组成,执行基本的卷积运算,进而激活 ReLU。该网络模型较小,参数少,可输入任意大小的图像,并且允许同时使用全局位置和上下文信息,还可以避免出现过拟合。如上文所述,医学图像分割中需要较多的高分辨率信息用于精准分割,同时由于人体内部解剖结构相对固定,待分割目标在图像中的分布具有明显的规律性,语义简单明确,可由低分辨率信息提供。而 U-Net 融合了不同尺度的特征,结合了低分辨率信息(提供目标类别识别依据)和高分辨率信息(提供精准分割定位依据),同时跳级连接(skip connection)保证上采样恢复出的特征更加精细,非常适合于医学图像分割^[18]。

例如, Li 等^[16]搭建了一个分割内窥 OCT 图像的并行 DNN, 该网络包含 3 个 U-Net, 并对其并行训

练, 保证分割结果在训练数据集有限的情况下具有鲁棒性。Li 等^[19]设计了一种用于从 IVOCT 图像中分割易损斑块的深度残差 U-Net, 该网络由预先训练的 ResNet101 代替编码器, 由残差块组成解码器, 通过双线性插值实现两个相邻残差解码器之间的上采样操作, 网络的最后一层是一个 1×1 的卷积核, 用于调整通道数并输出一个像素级的概率图。实验选取 2000 帧已被专家标注的图像组成数据集, 将其中包含易损斑块的 1000 帧图像按照 8:2 的比例随机划分成训练集和测试集。采用顺时针旋转图像的方式对训练集进行增强, 并对图像灰度值进行归一化处理。在训练过程中, 使用随机梯度下降(SGD)法优化网络, 其中动量参数、权重衰减、学习率和批量大小分别设置为 0.0005、0.0002、0.001 和 1。此外, 为提高目标边界分割的精度, 使用由加权交叉熵和 Dice 系数组成的损失函数, 结果如图 1 所示。




图 1 原始 IVOCT 图像及 5 种分割方法的结果对比^[19]。(a) 原始图像; (b) 专家手动分割结果; (c) 原型 U-Net 分割结果; (d) 有损失函数的原型 U-Net 分割结果; (e) 深度残差 U-Net+ResNet101 分割结果; (f) 有损失函数的深度残差 U-Net+ResNet101 分割结果
Fig. 1 Original IVOCT image and comparison of segmentation results of five methods^[19]. (a) Original image; (b) manual segmentation by specialists; (c) segmentation by prototype U-Net; (d) segmentation by prototype U-Net with proposed loss function; (e) segmentation by deep Residual U-Net and ResNet101; (f) segmentation by deep Residual U-Net and ResNet101 with proposed loss function

U-Net 的优点是结构简单且易于根据具体问题的要求调整结构单元, 既可以利用高级语义信息, 又具有全局定位能力, 非常适合于有限图像数据的分割任务。其缺点在于只是简单地将下采样过程中编码器的特征图拼接至上采样的特征图以形成梯形网络结构来获取更丰富的特征, 但是医学图像中通常包含大量细节信息, 因此随着网络的加深, 可能逐渐丢失细节信息。

2.2 SegNet

SegNet 是一种修改 VGG-16 网络得到的语义分割网络, 具有编码器网络和相应的解码器网络及最终像素的分类层, 如图 2 所示^[20]。解码器执行上采样和卷积, 最后每个像素送入 Softmax 分类器, 对特征图进

行上采样时使用去池化的方法, 很大程度上保持了高频细节的完整性。编码器执行卷积和最大池化, 不使用全连接层, 因此 SegNet 是具有较少参数的轻量级网络^[21]。

Lee 等^[20]提出了一种从 IVOCT 图像中分割钙化斑块的两步法, 第 1 步是搭建一个由 5 个卷积层、5 个最大池化层和 2 个全连接层构成的三维 CNN, 训练网络使其能够将整个图像序列中的各帧划分为“含钙化”和“无钙化”两类; 第 2 步是采用由 26 个卷积层、5 个最大池化层和 5 个最大反池化层组成的 SegNet 从被标记为“含钙化”的图像中分割出钙化斑块。实验中采用一个包括 8231 帧在体图像和 4320 帧离体图像的大型数据集训练和测试网络, 采用自适应矩估计优化器分别优化分类网络和分割网络, 设置初始学习率、下降因子和下降周期分别为 0.001、0.2 和 5, 最终图像分割的敏感度、精确度和 F1 分数为 0.862、0.758 和 0.781。Gharaibeh 等^[22]使用预训练的 SegNet 对 IVOCT 图像中的血管腔和钙化点进行语义分割, 网络考虑了上下文信息以确定包含钙化的区域, 然后使用条件随机场(CRF)对分割结果进行优化。采用由专家标注的包含钙化、脂质及混合斑块的 2640 帧 IVOCT 图像组成的数据集进行验证, 结果如图 3 所示, 对钙化、管腔和

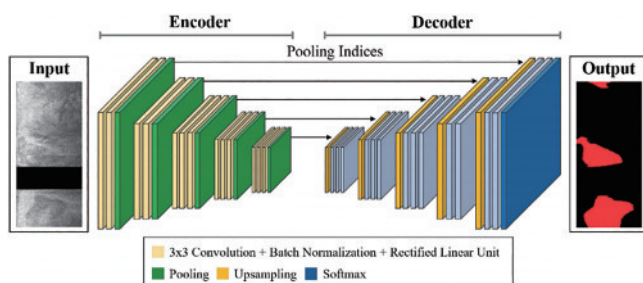


图 2 SegNet 体系结构示意图^[20]

Fig. 2 Illustration of SegNet architecture^[20]




图3 SegNet的分割结果^[22]。(a)原始图像;(b)标准分割图像;(c) SegNet分割结果;(d) CRF 优化后的输出图像

Fig. 3 Segmentation results of SegNet^[22]. (a) Original image; (b) ground truth; (c) initial segmentation by SegNet; (d) output after CRF processing

其他组织类别的识别敏感度分别达到了 0.85 ± 0.04 、 0.99 ± 0.01 和 0.97 ± 0.01 ,有效减少了图像伪影对确定目标边界造成的影响。SegNet的参数较少,且很大程度上保持了高频细节的完整性,但在对复杂类别进行分割时不确定性会增大。

2.3 CapsNet

CapsNet是近几年提出的ANN架构,它与CNN的不同之处在于将特征属性存储在向量而不是标量中,同时使用动态路由(dynamic routing)而不是最大池化来关联层,较底层的特征只被传送到相关的高层中加以利用。这些向量或胶囊包含有关提取特征的大小、空间方向及其他属性(如姿态、倾斜和厚度)信息^[23]。

例如,Balaji等^[17]设计了一个基于胶囊的完全训练的图像分割模型,并将其命名为DeepCap,用于从IVOCT图像中分割血管腔。DeepCap的输入为3个不同图像的组合:增强的输入图像、输入图像的二维高斯导数(即带通滤波和空间导数的组合)及输入图像在

轴向平面上的前向和后向差分图像。采用12011帧包含血液、伪影、金属支架及生物可降解支架的图像构成数据集,并按照8:2的比例随机划分成训练集与验证集。对图像进行随机剪裁、高斯模糊和顺/逆时针旋转等实现训练集的增强,计算图像的二维高斯导数和轴向平面上的前向和后向差分,最后将其输入网络模型中进行训练。在训练阶段,采用自适应矩估计优化器优化网络,设置批量大小为1,遍历训练集的次数为20,直到总损失值不再变化即得到最终模型。实验结果表明,在图像中存在伪影和支架的情况下,该模型仍然可以高质量地分割出血管腔,且Dice系数可达到96%以上,如图4所示。

CapsNet使用很少的训练数据就能实现泛化,而且能够保存大量细节信息(比如对象的位置、厚度和倾斜度等)。存在的问题是计算量很大,不能准确区分相距很近的物体,且目前只在小数据集上表现出了良好的性能。




图4 DeepCap模型对IVOCT图像的分割结果^[17]

Fig. 4 Segmentation results of IVOCT images by DeepCap^[17]

2.4 N-Net

Tang等^[24]提出了一种基于多尺度特征的端到端DNN,并根据网络架构的外形将其命名为N-Net,用于实现IVOCT图像中血管腔的自动分割。N-Net由3部分组成:第1部分是多尺度输入层,用于构建图像金字塔输入,以实现多层次感受野的融合;第2部分是N型CNN层,可以提取多层次的图像特征;第3部分是交叉熵损失函数,用于比较网络分割结果和人工分割结果之间的差异。N-Net改进了传统U-Net只是简单拼接上下采样阶段特征图的特点,在每次上采样操作时都使用一个特征图,该特征图可以结合上采样的

3个特征。上采样操作后,特征图的长度和宽度会增加一倍。选取800帧专家标注的图像构成数据集,并等分为训练集和测试集,然后采用旋转、缩放、镜面翻转和平移等数据增强方法扩展训练集,进而将20000帧图像输入N-Net中。设置训练过程中的批量大小、遍历训练集的次数和迭代次数依次为4、10和5000。使用基于动量的SGD法优化网络,其中动量参数、学习率和学习率衰减分别为0.8、0.01和0.001。与U-Net的对比实验结果表明,N-Net对包含支架和血栓的图像分割精度高于U-Net,如图5所示。

N-Net通过融合多尺度特征图,丰富了网络的细




图 5 对含支架的一帧 IVOCT 图像的管腔分割结果^[24]。(a)原始图像;(b)标准分割结果;(c) U-Net 分割结果;(d) N-Net 分割结果
Fig. 5 Segmentation results of lumen contour in an IVOCT image with metal stent^[24]. (a) Original image; (b) ground truth; (c) U-Net output; (d) N-Net output

节特征,提高了分割准确性和泛化能力。未来可以探索新的损失函数,以提高分割精度。

2.5 RSM-Network

Huang 等^[25]提出了一种基于注意力机制的用于分割 IVOCT 图像中的血管腔的多尺度特征融合深度残差网络 RSM-Network。RSM-Network 以 U-Net 作为主体,引入残差结构和全局注意力机制提高全局特征提取能力,解决梯度弥散问题;引入金字塔特征提取结构,提高多尺度特征的学习能力;使用交叉熵损失函数提高实际输出和预期输出之间的匹配度。将临床采集的 1286 帧已被医生标注的在体 IVOCT 图像作为数据

集,并将其划分为训练集和测试集。通过水平翻转、旋转和垂直翻转等 3 种数据增强方式对训练集进行扩充,然后输入 RSM-Network 中。在训练过程中,将批量大小、遍历训练集的次数、迭代次数、基于动量的 SGD 法的学习率和学习率衰减分别设置为 4、10、5000、0.01 和 0.2,并将分割结果与 3 种不同网络进行了比较。实验结果表明,RSM-Network 有效提高了 U-Net 的性能,而且整体性能优于 FCN 和 SegNet,可以更精准地学习管腔轮廓的细节特征,使其形状更平滑,对管腔轮廓分割具有很强的鲁棒性和准确性,如图 6 所示。




图 6 IVOCT 管腔轮廓的分割结果^[25]。(a)原始图像;(b)标准分割结果;(c) U-Net 分割结果;(d) FCN 分割结果;(e) SegNet 分割结果;(f) RSM-Network 分割结果

Fig. 6 Segmentation results of IVOCT lumen contour^[25]. (a) Original images; (b) ground truth; (c) U-Net output; (d) FCN output; (e) SegNet output; (f) RSM-Network output

2.6 BPN

IVOCT 图像中的血管及其所处的环境复杂多样,而常用的前向传播神经网络产生的高级特征图具有固定大小的感受野,不能有效地表示复杂多变的血管区域信息,因而不适合提取图像中大小不一的血管区域的语义特征。此外,当特征图层次更深时,所提取的信息对应于下降的输入图像分辨率,而低分辨率图像信息的丢失可能会降低管腔和管壁中外膜边界检测的准确性。基于此,Gao 等^[26]提出了一种提取血管壁轮廓的特权模态蒸馏(PMD)框架,使用特权成像模态[如血管内超声(IVUS)成像]的知识帮助实现目标成像模态(如 IVOCT)的学习模型,将单模态图像中血管壁轮廓提取的“单输入单任务”学习问题转化为“多输入多任务”学习问题。该策略可以提高学习

模型对血管环境多样性的适应性,同时解决由于临床图像数据有限导致的模型过拟合问题。同时,为了实现 PMD,他们设计了一种结构可变的神经网络(BPN),该网络的双向金字塔结构能有效地提取不同尺寸冠脉血管的语义特征,并保留血管边界的高分辨率图像信息。采用由 2018 帧 IVUS 图像和 2018 帧 IVOCT 图像组成的数据集进行训练和测试。在训练阶段,定义损失函数为加权交叉熵、平均绝对误差及广义 Dice 系数的和,优化算法使用动量参数为 0.9 的 SGD,设置权重衰减为 1×10^{-3} ,遍历训练集的次数为 20,学习率从初始时的 1×10^{-3} ,到第 10 代训练后的 1×10^{-4} ,再到第 15 代后的 1×10^{-5} 。实验结果表明,该方法比其他方法具有更好的分割性能,如图 7 所示。




图 7 PMD 方法与其他方法提取 IVOCT 图像中血管轮廓的结果对比^[26]。(a)血管分叉;(b)白血栓;(c)红血栓;(d)复杂血栓
Fig. 7 Comparison of segmentation results of vessel border from IVOCT images by different methods^[26]. (a) Vessel bifurcation;
(b) white thrombus; (c) red thrombus; (d) complex thrombus

3 组织标定和斑块分类

相比于其他介入血管成像, IVOCT 的显著优势是其微米级(10~15 μm)的高分辨率,有助于对各种组织成分进行识别和分类,例如冠状动脉血管壁的内膜、中膜、外膜、薄纤维帽、坏死核、钙化结节、巨噬细胞和脂肪组织等。经典的自动组织标定方法采用 ML 技术对提取出的图像特征(包括纹理、几何和光学特征)进行自动分类,一般包括 3 个步骤:特征提取、特征选择和像素分类。常用的分类器包括支持向量机(SVM)^[27]、决策树(DT)^[28]、随机森林(RF)^[29-31]和线性判别分析(LDA)^[32]等。临床图像的实验结果表明,在按照成分将斑块划分为混合、脂质和纤维等 3 种类型方面,RF 的性能优于神经网络和 SVM^[31]。此外,根据背向散射信号或灰阶图像定量估算组织的光学特性参数(即背向散射系数和衰减系数),有助于提高组织标定和斑块分类的精度^[33],主要方法有曲线拟合法^[34]、深度分辨法(DR)^[35]和数值优化法^[36],上述方法可准确标定至少 6 种斑块成分(混合型、钙化、纤维、脂质、巨噬细胞和坏死核)。但是仅根据组织的光学特征参数进行标定会导致不同组织类型之间的重叠,不同的光源和物理模型也会导致结果产生偏差。而将光学特征参数、纹理特征和像素的

相对位置结合起来,可有效提高分析和识别斑块成分的精度^[37-38],但需要更多的特征参数解释组织成分的异质性。综上所述,传统的 ML 方法用特征工程技术从图像数据中提取出特征,但很难提取更深层的抽象特征,不能提供精确和全面的组织分类结果,而且每个步骤中存在的误差都会影响最终分类精度。

不同于 ML 方法,基于 CNN 的自动组织标定将预处理后的图像直接输入训练后的网络,仅通过一个步骤即可实现组织分类,而且还可以从各种抽象层中提取特征的深层结构^[39]。常用的 CNN 模型有 AlexNet^[40]、VGG^[41]、GoogleNet^[42]、ResNet^[43]和 DenseNet 等^[43]。按照预训练的 CNN 在组织标定过程中的作用可将基于 CNN 的自动组织标定方法分为两类:CNN 作为分类器的方法和 CNN 作为特征提取器的方法。

3.1 CNN 作为分类器

此类方法对预训练的 CNN 进行微调并将其作为分类器。首先对原始图像进行预处理,包括图像增强、去除伪影及分割血管壁;然后将分割后的图像分解成正交图像块,并对其进行标定[斑块(纤维、钙化、脂质和混合型)或正常组织];最后,将标定后的图像块输入训练后的 CNN 中,对 CNN 进行微调,学习如何对这些图像块分类,并输出完成组织分类的图像^[43-48],如

图 8 所示。

CNN 作为分类器可以稳定地完成组织分类,而且预训练的 CNN 降低了计算成本且避免了收敛问题。




图 8 完成组织标定的 IVOCT 图像极坐标视图,红色表示斑块组织,绿色表示正常管壁^[48]。(a)脂质斑块;(b)钙化和纤维斑块;(c)混合斑块;(d)钙化斑块

Fig. 8 Polar views of IVOCT images after tissue characterization where the patches with red represent plaque tissue and those with green are normal vessel wall^[48]. (a) Lipid plaque; (b) calcified and fibrous plaque; (c) mixed plaque; (d) calcified plaque

3.2 CNN 作为特征提取器

此类方法将预训练的 CNN 作为特征提取器,再用提取出的深层特征训练其他分类器(如 SVM^[49]和 RF^[50])完成组织分类。

例如,Abdolmanafi 等^[50]设计了 4 个实验:对预训练的 CNN (AlexNet、VGG-19 和 Inception-v3) 进行微调完成组织分类、利用预训练 CNN 提取的深度特征训练 RF、对 RF 的分类结果进行加权多数投票、将 AlexNet 和 VGG-19 提取的特征结合起来训练 RF。每个实验都是基于前一个实验的局限性而设计的。实验中采集了 33 个川崎病患者的 IVOCT 图像序

但是,在微调期间重新训练网络需要很长时间,而且深度微调网络时存在过拟合问题,如何为每层找到合适的学习率也是需要解决的关键问题。

列,每个序列包括 270 帧图像,从中选择出 120 帧包含病变的图像构成数据集。将迭代次数设置为 10。实验结果表明,使用预训练的 CNN 进行特征提取,再用 RF 进行特征分类,并对结果进行多数投票得到的分类结果最佳(准确度、敏感度和特异度高达 0.99 ± 0.01),且不增大计算量,如图 9 所示。后来,他们又在此基础上设计了一个全自动组织标定模型,训练了一个可以提取所有病变组织但不考虑病变类型的 FCN,然后使用文献[50]中的组织标定模型进行组织分类,实现了正常和病变血管壁的分类^[51]。




图 9 对 IVOCT 图像极坐标视图中的组织分类结果^[50]。(a)血管壁内膜;(b)血管壁中膜;(c)纤维斑块

Fig. 9 Classification results for each coronary artery tissue type in polar views of IVOCT images^[50]. (a) Intima; (b) media; (c) fibrosis

4 目标检测

传统目标检测方法大多以图像识别为基础,使用穷举法在图像中选出所有目标可能出现的区域框,然后对这些区域框进行特征提取和分类。这种方法依赖于人工设计的特征,而在基于 DL 的目标检测框架中,新的表示模式或模型会自动从底层特征中学习高级语义,提高了检测精度和鲁棒性。

4.1 检测支架

支架置入是粥样硬化性心血管疾病的常用介入治

疗方法,目前使用的支架类型有金属支架、药物洗脱支架(DES)和生物可降解支架(BVS)。金属支架存在难以移除及晚期血栓形成和支架内再狭窄的潜在风险;DES 虽然显著降低了支架内再狭窄的风险,但仍可能形成晚期血栓;BVS 因其可吸收性和无害性成为最有潜力的支架。病人在置入支架后可能会出现不良反应,甚至导致不良心血管事件的发生,因此在介入手术后检测支架是否贴壁和存在错位是至关重要的。IVOCT 在清晰显示血管支架方面的性能明显优于其他介入血管成像技术^[52],对支架术后的血管进行成像

时,一次回撤导管可采集 100~200 帧图像,需要检测和分析上千个支架支柱,若完全由人工手动完成全部支架柱的分析是非常耗时的,且无法保证精度。

为了提高处理效率,可以采用 ML 的方法实现自动支架检测。首先,从原始图像中提取纹理特征[如 Haar-like 特征^[53-54]或局部二值模式(LBP)],并训练分类器(如 AdaBoost^[53,55]、SVM^[56]或 DT^[57])用于识别支架柱;然后从图像中自动分割出支架柱轮廓^[53-54]或者角点^[58],进而自动分析是否存在支架贴壁不良。此类方法需要对每帧图像进行详细的像素标注,并针对特定支架类型设计多样化的特征,因此会限制这些方法的适用范围。

U-Net^[59]、基于区域的卷积神经网络(R-CNN)^[60]和 you only look once(YOLO)系列算法^[61]在自动目标检测方面表现出了优越性能。R-CNN 是第 1 个成功将 DL 应用于目标检测的算法,它遵循传统目标检测的思路,通过对每个提取框进行 CNN 特征提取、分类

和非极大值抑制实现目标检测。Fast R-CNN 和 Faster R-CNN 都是对 R-CNN 的改进,且 Faster R-CNN 是 R-CNN 系列中目标检测性能最优的。例如,Zhang 等^[62]采用 Faster R-CNN 实现了 IVOCT 图像中斑块位置的检测。

基于区域的全卷积网络(R-FCN)由于其位置敏感型的分数图和在整个图像上共享卷积层的设计,准确性和即时性优于 Fast R-CNN 和 Faster R-CNN^[60]。Cao 等^[63-64]提出了一种基于 R-FCN 的 BVS 支柱自动检测模型,由区域候选网络(RPN)和检测模块两部分构成,利用迁移学习(TL)训练检测模型以获得支柱检测结果。Jiang 等^[61]分别使用 YOLOv3 和 R-FCN 对由 165 帧包含金属支架的 IVOCT 图像组成的数据集进行测试,按照 3:1:1 的比例将数据集划分为训练集、测试集和验证集。实验结果表明,无论支架特征清晰与否,两种算法都具有较好的性能,并且 R-FCN 在检测精确度、召回率和平均精度上均优于 YOLOv3,如图 10 所示。




图 10 IVOCT 图像中金属支架的自动检测结果^[61]。(a) YOLOv3; (b) R-FCN

Fig. 10 Detection result of metallic stents in IVOCT images^[61]. (a) YOLOv3; (b) R-FCN

Gessert 等^[65]利用一个预训练的 ResNet 对 IVOCT 图像序列中的每帧图像进行标注,从而判断其是否包含金属支架或 BVS,网络的输入是图像的极坐标视图,输出图像类别(金属支架、BVS 和无支架),无需像素级标注。进而采用基于像素块的图像偏移方法

生成高质量的显著图(SM),并通过弱监督定位来获取局部支架柱信息,最终分类准确度可达 99%,如图 11 所示。当需要增加新支架类型时,只需要在学习问题中添加一个类,无需增加新的特征,因此这种图像标记方法的速度快且容易扩展到新的支架类型。




图 11 IVOCT 图像中的支架检测结果^[65]。(a)无支架;(b)金属支架;(c) BVS

Fig. 11 Results of stent detection in IVOCT images^[65]. (a) No stent; (b) metal stent; (c) BVS

4.2 识别血管分叉

动脉血管分叉与血流速度的改变密切相关,在动脉粥样硬化的进展中起着重要作用,因此检测 IVOCT 图像中的血管分叉对于评估动脉粥样硬化严重程度和预测其进展、制定介入治疗计划及分析支架置入效果等具有重要意义,同时血管分叉也是对不同模态图像之间进行配准时的可靠标志^[66-67]。

早期研究通过分析管腔中心与管壁之间的距离实现全自动血管分叉和侧支血管检测,当管腔中心和管壁之间的距离急剧增加时表明可能存在分叉^[68]。但当存在支架时,因为贴壁不良的支架柱和组织覆盖会封闭侧支血管,所以仅使用基于距离的检测方法可能无法检测出一些侧支血管。与检测支架类似,基于 ML 的血管分叉自动检测也包括两个步骤:首先分割出管腔轮廓,并提取其几何特征;然后,采用分类器(如 SVM^[66]、神经网络^[66]、Adaboost^[67]和 RF^[67])进行特征分类,确定图像集中的分叉帧和非分叉帧,如图 12 所示。

Miyagawa 等^[69]首次将 CNN 用于 IVOCT 图像中血管分叉的自动识别与分类,搭建了如图 13 所示的 CNN 框架,并利用训练后的 CNN 将数据集中的图像划分为包含分叉和不含分叉两类。采用由 157 个分叉帧和 1204 个非分叉帧组成的数据集对网络进行训练和测试,通过旋转分叉帧实现数据增强。在训练阶段,使用 SGD 法优化网络,设置最小批量、初始学习率、学

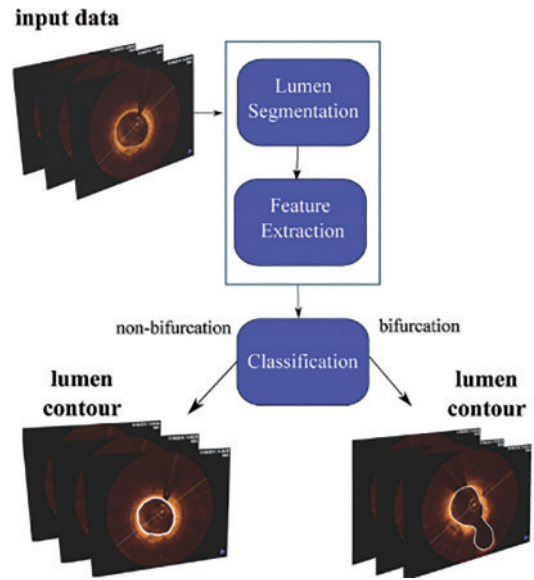


图 12 采用 ML 方法自动识别血管分叉的流程图^[67]

Fig. 12 Flowchart of ML-based method for automatic identification of vascular bifurcations^[67]

习率下降因子、学习率下降因子周期和迭代次数分别为 32、0.001、0.5、40 和 5000,最终训练后的网络模型在受试者工作特征(ROC)曲线下的面积达到了 99.7%。由于数据集中分叉帧的数量较少,后来他们又应用 TL 将来源于管腔分割任务的知识整合到网络训练中,进一步提高了 CNN 检测血管分叉的性能^[70]。




图 13 用于识别 IVOCT 图像中血管分叉的 CNN 结构^[69]

Fig. 13 CNN architecture used to classify bifurcation regions in IVOCT images^[69]

5 结 论

随着计算能力的不断提高和开源数据的日益增长及模型和算法的不断改进,DL 越来越多地应用于 IVOCT 图像后处理领域中,通过构建更深层的学习模型,利用大量样本数据训练网络使其学习更加精准的特征,可提高组织分类或预测的准确性。同时,DL 在 IVOCT 中的应用也面临一些挑战。例如,训练神经网络时要进行许多决策,比如图像预处理、构建网络模型和优化网络参数等,不同的决策会导致不同的处理结

果,因此即使采用相同数据集,不同研究人员获得的结果也不同。其次,在算法评价指标(如准确率、召回率和 Dice 系数等)方面也具有显著的特异性,例如针对同一个问题,在不同数据集上使用不同度量标准得到的结果有所差别,因此也无法对不同算法的性能进行公平对比。此外,目前针对 IVOCT 图像后处理的研究使用的数据集大都来源于全球各大医疗机构的临床图像数据库,因图像信息涉及病人的隐私保护等问题,目前还没有形成一个可供研究者们广泛使用的规范的公共数据集。为了对不同算法进行客观、公正地测试

和比较,加速 DL 技术在 IVOCT 图像分析领域的发展,迫切需要构建一个大型共享数据库。

参 考 文 献

- [1] Otsuka K, Villiger M, Nadkarni S K, et al. Intravascular polarimetry: clinical translation and future applications of catheter-based polarization sensitive optical frequency domain imaging[J]. *Frontiers in Cardiovascular Medicine*, 2020, 7: 146.
- [2] 胡芬, 林洋, 侯梦迪, 等. 基于深度学习的细胞骨架图像超分辨重建[J]. *光学学报*, 2020, 40(24): 2410001.
Hu F, Lin Y, Hou M D, et al. Super-resolution reconstruction of cytoskeleton image based on deep learning[J]. *Acta Optica Sinica*, 2020, 40(24): 2410001.
- [3] 肖康, 田立君, 王中阳. 基于深度学习的低信噪比下的快速超分辨荧光显微成像[J]. *中国激光*, 2020, 47(10): 1007002.
Xiao K, Tian L J, Wang Z Y. Fast super-resolution fluorescence microscopy imaging with low signal-to-noise ratio based on deep learning[J]. *Chinese Journal of Lasers*, 2020, 47(10): 1007002.
- [4] Fedewa R, Puri R S, Fleischman E, et al. Artificial intelligence in intracoronary imaging[J]. *Current Cardiology Reports*, 2020, 22(7): 46.
- [5] Litjens G, Ciompi F, Wolterink J M, et al. State-of-the-art deep learning in cardiovascular image analysis[J]. *JACC: Cardiovascular Imaging*, 2019, 12(8): 1549-1565.
- [6] Bologna M, Migliori S, Montin E, et al. Automatic segmentation of optical coherence tomography pullbacks of coronary arteries treated with bioresorbable vascular scaffolds: application to hemodynamics modeling[J]. *PLoS One*, 2019, 14(3): e0213603.
- [7] Dallalazar N, Ayatollahi A, Habibi M, et al. Automatic vessel wall segmentation of IVOCT images using region detection EREL algorithm[C]//2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI), February 28-March 1, 2019, Tehran, Iran. New York: IEEE Press, 2019: 611-616.
- [8] Zhao H S, He B, Ding Z Y, et al. Automatic lumen segmentation in intravascular optical coherence tomography using morphological features[J]. *IEEE Access*, 2019, 7: 88859-88869.
- [9] Habibi M, Ayatollahi A, Dallalazar N, et al. Lumen boundary detection using neutrosophic c-means in IVOCT images[C]//2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI), February 28-March 1, 2019, Tehran, Iran. New York: IEEE Press, 2019: 599-604.
- [10] Olender M L, Athanasiou L S, de la Torre H J M, et al. Simultaneous multi-surface fitting for vessel wall layer delineation[C]//2019 IEEE EMBS International Conference on Biomedical & Health Informatics, May 19-22, 2019, Chicago, IL, USA. New York: IEEE Press, 2019.
- [11] Sun S H, Sonka M, Beichel R R. Graph-based IVUS segmentation with efficient computer-aided refinement[J]. *IEEE Transactions on Medical Imaging*, 2013, 32(8): 1536-1549.
- [12] Roy A G, Conjeti S, Carlier S G, et al. Lumen segmentation in intravascular optical coherence tomography using backscattering tracked and initialized random walks [J]. *IEEE Journal of Biomedical and Health Informatics*, 2016, 20(2): 606-614.
- [13] Tsantis S, Kagadis G C, Katsanos K, et al. Automatic vessel lumen segmentation and stent strut detection in intravascular optical coherence tomography[J]. *Medical Physics*, 2012, 39(1): 503-513.
- [14] Joseph S, Adnan A, Adlam D. Automatic segmentation of coronary morphology using transmittance-based lumen intensity-enhanced intravascular optical coherence tomography images and applying a localized level-set-based active contour method[J]. *Journal of Medical Imaging*, 2016, 3(4): 044001.
- [15] Wang P Y, Zhu H Q, Ling X F. Intravascular optical coherence tomography image segmentation based on Gaussian mixture model and adaptive fourth-order PDE [J]. *Signal, Image and Video Processing*, 2020, 14(1): 29-37.
- [16] Li D W, Wu J M, He Y F, et al. Parallel deep neural networks for endoscopic OCT image segmentation[J]. *Biomedical Optics Express*, 2019, 10(3): 1126-1135.
- [17] Balaji A, Kelsey L J, Majeed K, et al. Coronary artery segmentation from intravascular optical coherence tomography using deep capsules[EB/OL]. (2020-03-13) [2021-06-27]. <https://arxiv.org/abs/2003.06080>.
- [18] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[EB/OL]. (2015-05-18) [2021-06-27]. <https://arxiv.org/abs/1505.04597>.
- [19] Li L C, Jia T. Optical coherence tomography vulnerable plaque segmentation based on deep residual U-net[J]. *Reviews in Cardiovascular Medicine*, 2019, 20(3): 171-177.
- [20] Lee J, Gharaibeh Y, Kolluru C, et al. Segmentation of coronary calcified plaque in intravascular OCT images using a two-step deep learning approach[J]. *IEEE Access*, 2020, 8: 225581-225593.
- [21] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [22] Gharaibeh Y, Prabhu D S, Kolluru C, et al. Coronary calcification segmentation in intravascular OCT images using deep learning: application to calcification scoring[J]. *Journal of Medical Imaging*, 2019, 6(4): 045002.
- [23] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules[EB/OL]. (2017-10-26) [2021-06-27]. <https://arxiv.org/abs/1710.09829>.
- [24] Tang J J, Lan Y S, Chen S R, et al. Lumen contour segmentation in IVOCT based on N-type CNN[J]. *IEEE Access*, 2019, 7: 135573-135581.
- [25] Huang C X, Lan Y S, Xu G W, et al. A deep segmentation network of multi-scale feature fusion based

- on attention mechanism for IVOCT lumen contour[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2021, 18(1): 62-69.
- [26] Gao Z F, Chung J, Abdelrazek M, et al. Privileged modality distillation for vessel border detection in intracoronary imaging[J]. IEEE Transactions on Medical Imaging, 2020, 39(5): 1524-1534.
- [27] Prabhu D S, Bezerra H G, Kolluru C, et al. Automated A-line coronary plaque classification of intravascular optical coherence tomography images using handcrafted features and large datasets[J]. Journal of Biomedical Optics, 2019, 24: 106002.
- [28] Kolluru C, Prabhu D, Gharaibeh Y, et al. Voxel-based plaque classification in coronary intravascular optical coherence tomography images using decision trees[J]. Proceedings of SPIE, 2018, 10575: 105752Y.
- [29] Ughi G J, Adriaenssens T, Sinnaeve P, et al. Automated tissue characterization of *in vivo* atherosclerotic plaques by intravascular optical coherence tomography images[J]. Biomedical Optics Express, 2013, 4(7): 1014-1030.
- [30] Zhou P, Zhu T J, He C L, et al. Automatic classification of atherosclerotic tissue in intravascular optical coherence tomography images[J]. Journal of the Optical Society of America. A, Optics, Image Science, and Vision, 2017, 34(7): 1152-1159.
- [31] Athanasiou L S, Bourantas C V, Rigas G, et al. Methodology for fully automated segmentation and plaque characterization in intracoronary optical coherence tomography images[J]. Journal of Biomedical Optics, 2014, 19(2): 026009.
- [32] Rico-Jimenez J J, Campos-Delgado D U, Villiger M, et al. Automatic classification of atherosclerotic plaques imaged with intravascular OCT[J]. Biomedical Optics Express, 2016, 7(10): 4069-4085.
- [33] Gong P J, Almasian M, van Soest G, et al. Parametric imaging of attenuation by optical coherence tomography: review of models, methods, and clinical translation[J]. Journal of Biomedical Optics, 2020, 25(4): 040901.
- [34] 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.
- [35] Liu J, Ding N, Yu Y, et al. Optimized depth-resolved estimation to measure optical attenuation coefficients from optical coherence tomography and its application in cerebral damage determination[J]. Journal of Biomedical Optics, 2019, 24(3): 035002.
- [36] Sun Z, Yang F, Sun J. Method for parametric imaging of attenuation by intravascular optical coherence tomography [J]. Biomedical Optics Express, 2021, 12(4): 1882-1904.
- [37] Gan Y, Tsay D, Amir S B, et al. Automated classification of optical coherence tomography images of human atrial tissue[J]. Journal of Biomedical Optics, 2016, 21(10): 101407.
- [38] He C L, Li Z L, Wang J Q, et al. Atherosclerotic plaque tissue characterization: an OCT-based machine learning algorithm with *ex vivo* validation[J]. Frontiers in Bioengineering and Biotechnology, 2020, 8: 749.
- [39] He S H, Zheng J, Maehara A, et al. Convolutional neural network based automatic plaque characterization for intracoronary optical coherence tomography images [J]. Proceedings of SPIE, 2018, 10574: 1057432.
- [40] Litjens G, Kooi T, Bejnordi B E, et al. A survey on deep learning in medical image analysis[J]. Medical Image Analysis, 2017, 42: 60-88.
- [41] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-06-27]. <https://arxiv.org/abs/1409.1556>.
- [42] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [43] 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.
- [44] Abdolmanafi A, Duong L, Dahdah N, et al. Deep feature learning for automatic tissue classification of coronary artery using optical coherence tomography[J]. Biomedical Optics Express, 2017, 8(2): 1203-1220.
- [45] Gessert N, Heyder M, Latus, et al. Plaque classification in coronary arteries from IVOCT images using convolutional neural networks and transfer learning[EB/OL]. (2018-04-11)[2021-06-27]. <https://arxiv.org/abs/1804.03904>.
- [46] He C L, Yin Y F, Wang J Q, et al. Automatic calcified plaques detection in the OCT pullbacks using convolutional neural networks[J]. Journal of Medical Biomechanics, 2019, 34(S1): 109-110.
- [47] Liu X L, Du J X, Yang J L, et al. Coronary artery fibrous plaque detection based on multi-scale convolutional neural networks[J]. Journal of Signal Processing Systems, 2020, 92(3): 325-333.
- [48] Cheimariotis G A, Riga M, Toutouzas K, et al. Deep learning method to detect plaques in IVOCT images[J]. IFMBE Proceedings, 2020, 74: 389-395.
- [49] Xu M D, Cheng J, Li A N, et al. Fibroatheroma identification in intravascular optical coherence tomography images using deep features[C]//2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, July 11-15, 2017, Jeju, Korea (South). New York: IEEE Press, 2017: 1501-1504.
- [50] Abdolmanafi A, Duong L, Dahdah N, et al. Characterization of coronary artery pathological formations from OCT imaging using deep learning[J]. Biomedical Optics Express, 2018, 9(10): 4936-4960.
- [51] Abdolmanafi A, Duong L, Ibrahim R, et al. A deep learning-based model for characterization of atherosclerotic plaque in coronary arteries using optical coherence tomography images[J]. Medical Physics, 2021, 48(7): 3511-3524.
- [52] 韦赢兆,袁研,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): 2400001.
- 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): 2400001.
- [53] Lu Y F, Cao Y H, Jin Q H, et al. Adaboost-based detection and segmentation of bioresorbable vascular scaffolds struts in IVOCT images[C]//2017 IEEE International Conference on Image Processing, September 17-20, 2017, Beijing, China. New York: IEEE Press, 2017: 4432-4436.
- [54] Cao Y H, Jin Q H, Lu Y F, et al. Automatic analysis of bioresorbable vascular scaffolds in intravascular optical coherence tomography images[J]. *Biomedical Optics Express*, 2018, 9(6): 2495-2510.
- [55] 鲁逸峰, 金琴花, 荆晶, 等. 基于机器学习的可降解支架检测与分割算法[J]. *光学学报*, 2018, 38(2): 0215005.
- Lu Y F, Jin Q H, Jing J, et al. Detection and segmentation algorithm for bioresorbable vascular scaffolds struts based on machine learning[J]. *Acta Optica Sinica*, 2018, 38(2): 0215005.
- [56] Lu H, Lee J, Ray S, et al. Automated stent coverage analysis in intravascular OCT (IVOCT) image volumes using a support vector machine and mesh growing[J]. *Biomedical Optics Express*, 2019, 10(6): 2809-2828.
- [57] Lu H, Lee J, Jakl M, et al. Application and evaluation of highly automated software for comprehensive stent analysis in intravascular optical coherence tomography[J]. *Scientific Reports*, 2020, 10(1): 2150.
- [58] Qin X J, Yao L L, Jin Q H, et al. Corner detection based automatic segmentation of bioresorbable vascular scaffold struts in IVOCT images[C]//Proceedings of 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), July 17-21, 2018, Hawaii, USA. New York: IEEE Press, 2018: 604-607.
- [59] Zhou W, Chen F, Zong Y S, et al. Automatic detection approach for bioresorbable vascular scaffolds using a U-shaped convolutional neural network[J]. *IEEE Access*, 2019, 7: 94424-94430.
- [60] Li L C, Jia T, Meng T Q, et al. Deep convolutional neural networks for cardiovascular vulnerable plaque detection[J]. *MATEC Web of Conferences*, 2019, 277: 02024.
- [61] Jiang X L, Zeng Y Q, Xiao S X, et al. Automatic detection of coronary metallic stent struts based on YOLOv3 and R-FCN[J]. *Computational and Mathematical Methods in Medicine*, 2020, 2020: 1793517.
- [62] Zhang H Q, Wang G L, Li Y, et al. Faster R-CNN, fourth-order partial differential equation and global-local active contour model (FPDE-GLACM) for plaque segmentation in IV-OCT image[J]. *Signal, Image and Video Processing*, 2020, 14(3): 509-517.
- [63] Cao Y H, Lu Y F, Li J N, et al. Deep learning based bioresorbable vascular scaffolds detection in IVOCT images[C]//2018 24th International Conference on Pattern Recognition (ICPR), August 20-24, 2018, Beijing, China. New York: IEEE Press, 2018: 3778-3783.
- [64] Cao Y H, Lu Y F, Jin Q H, et al. Deep learning-based detection and segmentation for BVS struts in IVOCT images[C]//Seventh Joint International Workshop, CVII-STENT 2018 and Third International Workshop, LABELS 2018, September 16, 2018, Granada, Spain. Heidelberg: LNCS, 2018, 11043: 55-63.
- [65] Gessert N, Latus S, Abdelwahed Y S, et al. Bioresorbable scaffold visualization in IVOCT images using CNNs and weakly supervised localization[J]. *Proceedings of SPIE*, 2019, 10949: 109492C.
- [66] Porto C D N, Filho C F F C, Macedo M M G, et al. Classification of bifurcations regions in IVOCT images using support vector machine and artificial neural network models[J]. *Proceedings of SPIE*, 2017, 10134: 101344D.
- [67] Macedo M M G, Guimaraes W V N, Galon M Z, et al. A bifurcation identifier for IV-OCT using orthogonal least squares and supervised machine learning[J]. *Computerized Medical Imaging and Graphics*, 2015, 46: 237-248.
- [68] Wang A C, Eggermont J, Reiber J H C, et al. Fully automated side branch detection in intravascular optical coherence tomography pullback runs[J]. *Biomedical Optics Express*, 2014, 5(9): 3160-3173.
- [69] Miyagawa M, Costa M G F, Gutierrez M A, et al. Using convolutional neural networks for classification of bifurcation regions in IVOCT images[C]//Proceedings of IEEE Engineering in Medicine and Biology Society Conference, July 23-27, 2019, Berlin, Germany. New York: IEEE Press, 2019, 2019: 5597-5600.
- [70] Miyagawa M, Costa M G F, Gutierrez M A, et al. Detecting vascular bifurcation in IVOCT images using convolutional neural networks with transfer learning[J]. *IEEE Access*, 2019, 7: 66167-66175.