

基于深度学习方法OCT皮肤癌诊断: 发展与展望

张磊¹, 李笑然¹, 陈雯¹, 雷梁锌雯², 吴昊², 卢忠², 董必勤^{1*}

(1. 复旦大学生物医学工程与技术创新学院, 上海 200433;

2. 复旦大学附属华山医院皮肤科, 上海 200040)

摘要: 皮肤光学相干层析成像(Optical Coherence Tomography, OCT)为皮肤组织结构和病理特征分析提供了高分辨率影像基础。开发自动化图像分析方法(如分割与分类)对辅助皮肤病诊断及治疗评估具有重要临床价值, 可为医疗决策提供定量支持。相较于传统方法和早期机器学习(Machine Learning, ML)技术, 深度学习(Deep Learning, DL)显著提升了分析效率与可重复性, 有效减少人工耗时。该文系统综述了当前DL技术在皮肤OCT图像分析中的应用进展, 着重探讨其在图像降噪、皮肤分割和皮肤癌诊断中的技术路径, 并指出该领域亟待解决的模型泛化性、数据异构性等问题, 为后续研究提供理论参考与技术发展方向的指引。

关键词: 光学相干层析成像; 深度学习; 皮肤癌诊断; 皮肤分层; 图像降噪

中图分类号: TP183

文献标识码: A

Deep learning based skin cancer diagnosis in OCT: progress and prospects

ZHANG Lei¹, LI Xiao-Ran¹, CHEN Wen¹, LEI Liang-Xin-Wen², WU Hao²,

LU Zhong², DONG Bi-Qin^{1*}

(1. College of Biomedical Engineering, Fudan University, Shanghai 200433, China. ;

2. The Department of Dermatology, Huashan Hospital, Fudan University, Shanghai 200040, China.)

Abstract: Optical Coherence Tomography (OCT) provides high-resolution images of skin tissue structure and pathological features. Automated image analysis methods (such as segmentation and classification) are important for assisting skin disease diagnosis and treatment evaluation. These methods provide quantitative support for medical decisions. Compared with traditional methods and early machine learning (ML) techniques, deep learning (DL) improved analysis efficiency and reproducibility. It also reduced manual processing time significantly. This paper systematically reviewed the application progress of DL in skin OCT image analysis. It focused on technical approaches for image denoising, skin layer segmentation, and skin cancer diagnosis. The study identified key challenges including model generalization and data heterogeneity. The findings provide theoretical references and technical guidance for future research directions.

Key words: optical coherence tomography, deep learning, skin cancer diagnosis, skin segmentation, image denoising

引言

光学相干层析成像(Optical Coherence Tomography, OCT)作为一种非侵入性、高分辨率的实时成像技术,其原理基于宽带近红外光的低相干干涉技

术,通过测量样品的后向散射光与参考光的干涉强度来重建样品深度方向上光散射率的信息。由于生物组织不同层状结构具有独特的光散射特性,该技术能够实现微米级分辨率的组织微结构可视化^[1]。自20世纪90年代问世以来,OCT技术凭借其

收稿日期: 2025-04-19, 修回日期: 2025-05-09

Received date: 2025-04-19, Revised date: 2025-05-09

基金项目: 上海市自然科学基金(22ZR1404300, 22ZR1409500), 上海市“科技创新行动计划”(22S31905500), 复旦大学医工交叉项目(yg2021-032, yg2022-2), 上海市“卫生健康青年人才”(2022YQ043), 华山医院创新培育基金(2024CX06)

Foundation items: Supported by the Natural Science Foundation of Shanghai (22ZR1404300, 22ZR1409500); the Shanghai Science and Technology Innovation Action Plan (22S31905500); the Medical Engineering Fund of Fudan University (yg2021-032, yg2022-2); the Young Talents of Shanghai Health Commission (2022YQ043); the Huashan Hospital Innovation Fund (2024CX06).

作者简介(Biography): 张磊(1994—), 男, 安徽宣城人, 博士研究生在读, 主要研究领域为基于OCT的早期皮肤癌智能诊断. E-mail: 20110860027@fudan.edu.cn

*通讯作者(Corresponding author): E-mail: dongbq@fudan.edu.cn

优异的轴向分辨率(1~15 μm)和高探测灵敏度,已发展成为眼科和心血管疾病诊断的重要工具^[2-4]。随着光学技术和信号处理算法的进步,现代 OCT 系统已实现亚细胞级空间分辨率和兆赫兹量级的轴向扫描速率,这极大拓展了其在疾病诊断领域的应用潜力^[5]。近年来许多研究证明了 OCT 在皮肤病学领域中具有重要的发展潜力。其近红外工作波段(通常为 800~1300 nm)可实现皮肤组织的高对比度成像,清晰分辨角质层(20~30 μm)、表皮(50~150 μm)、真皮(1~2 mm)等关键组织结构,并能无创观测皮下血管网络的三维分布,许多研究者尝试将皮肤癌 OCT 与病理图像进行特征对应,并进行皮肤癌的诊断或者区分,结果显示 OCT 具有足够的细胞清晰度来诊断非黑色素瘤皮肤癌,且 OCT 也被证明可用于肿瘤边缘轮廓的提取,但在检测早期黑色素瘤方面的灵敏度较低,由于目前的数据有限,需要更一致的报告才能得出关于其诊断的明确结论^[6-7]。总的来说, OCT 很有希望作为一种相对快速和非侵入性的诊断皮肤肿瘤的方法。相较于传统组织活检, OCT 技术具有实时成像、无需标记、可重复检测、非侵入性等技术优势,可以为病人避免侵入性的损伤和节省时间与金钱成本。近年来的研究进展表明,功能 OCT(包括多普勒 OCT、偏振敏感 OCT 和光学相干层析扫描血管成像(Optical Coherence Tomography Angiography, OCTA))已突破结构成像的局限^[8-10],可实现对皮肤血流动力学、胶原纤维排列等功能的定量分析。结合人工智能算法, OCT 技术在皮肤病早期诊断、治疗监测和预后评估等方面展现出重要的临床应用价值,为皮肤病理学研究提供了全新的技术平台和研究范式。

近年来,大量研究表明 OCT 在皮肤分层结构高分辨率成像、疾病早期筛查及精准治疗评估等方面展现出突出优势^[11-20]。借助高分辨率成像, OCT 能够识别皮肤肿瘤的特征性结构变化,如血管分布异常、角化指数的改变以及胶原纤维的重塑情况。这些特征可以作为早期诊断的生物标志物,帮助医生在病变尚未明显可见时做出准确判断。 OCT 的一个重要优势在于其能够对皮肤病变进行定量分析。 OCT 可以计算皮肤厚度、胶原纤维密度、血管密度等关键参数,为疾病的严重程度评估和治疗方案制定提供科学依据。例如,在光老化研究中, OCT 能够通过分析胶原纤维的数量及其结构变化,评估紫外线对皮肤组织的影响,从而为抗衰老产品的研发

提供数据支持^[21, 22]。此外,动态 OCT (Dynamic OCT, D-OCT)技术的引入进一步提高了量化血管变化和皮肤厚度变化的能力。例如 D-OCT 能够提供更加精确的炎症评估指标,提高对炎症性皮肤病(如牛皮癣)的检测能力^[23-26],有助于炎症性皮肤病的早期诊断和疗效监测。 OCT 在药物疗效评估方面也具有巨大潜力。 D-OCT 技术能够动态监测药物在皮肤中的分布情况及其生物学效应。例如,在光动力疗法(Photodynamic therapy, PDT)中, OCT 能够跟踪药物注射后皮肤微循环的变化,并量化血管及皮肤厚度的变化,以此来评估治疗效果^[27, 28]。这种精准的监测方式使 OCT 成为皮肤药理研究和临床治疗评估的重要工具。 OCT 不仅能应用于病理性皮肤分层结构的检测,还能用于皮肤附属器的结构观察^[29, 30]。皮肤附属器,如毛囊、皮脂腺、汗腺等,在多种疾病(如毛囊炎、皮脂腺功能障碍)中会发生明显变化。 OCT 能够提供这些结构的高分辨率图像,使研究人员和临床医生能够清晰地观察其形态和功能异常。例如,在毛囊炎患者中, OCT 可以揭示毛囊周围炎症的扩展范围,而在皮脂腺疾病中, OCT 能够检测皮脂腺的体积变化及其分布异常,从而为临床诊断提供更多依据。此外,在伤口愈合监测方面 OCT 也发挥着重要作用, OCT 能够实时捕捉皮肤愈合过程中细胞外基质和血管网络的变化^[24]。研究表明, OCT 成像能够清晰地展示伤口愈合各阶段的组织修复情况,为临床医生提供及时反馈,有助于调整治疗方案,优化愈合过程^[31]。除了在临床诊断和治疗评估中的应用, OCT 还在皮肤生理学研究 and 化妆品功效评价等领域展现了广阔的前景。 OCT 可以无创地观察皮肤微循环、细胞外基质以及皮肤屏障功能的变化。例如, OCT 可以用于研究皮肤老化的过程,如分析皮肤厚度、胶原纤维密度等随年龄增长的变化,为抗衰老研究提供科学依据^[32]。

随着机器学习技术不断地被广泛应用,深度学习(Deep Learning, DL)作为机器学习的重要分支^[33],也在多个领域发挥出重要的作用,其核心优势在于能够自动提取特征,直接处理复杂或非结构化的数据。这种端到端的处理模式不仅避免了人工特征设置的局限性,还显著简化了传统多阶段分析流程。 OCT 在医学成像领域中已广泛引入深度学习方法,涉及数据预处理、图像降噪和疾病诊断等多个层面。其中眼科领域率先将 DL 技术应用于

OCT影像分析,实现了眼底结构自动分层和眼科疾病智能诊断^[32]。随后该技术逐步拓展至其他医学专科,研究者相继开发出基于DL的乳腺癌OCT诊断模型和口腔癌OCT诊断模型^[35-37]。近年来在皮肤科OCT领域也逐步引入DL技术,深度学习不仅被用于提升图像质量——通过去噪和分辨率增强技术显著改善病变区域的可视化效果,还在皮肤病变的自动化诊断方面展现出巨大潜力。基于深度学习的自动化诊断方法能够高效识别皮肤病变并提供更精确的分类结果,辅助临床医生进行早期诊断和治疗。本文将系统性回溯近年来深度学习技术在皮肤OCT图像处理中的应用进展,重点探讨其在图像降噪、皮肤层结构分割及皮肤癌辅助诊断中的关键方法与创新成果,并基于方法革新、性能突破及技术瓶颈等角度,系统梳理该领域的发展路径,并讨论其当前的发展限制以及未来的发展趋势,展望其临床转化潜力。

1 皮肤图像降噪

传统OCT图像质量受到散斑噪声和散粒噪声影响,其中散粒噪声是基于光子探测的量子随机性导致的,是具有一定的分布特性的,可以通过同一位置多次采集取平均的方式来降噪。而散斑噪声则是由于物体内部本身结构的各向异性散射导致的随机干涉形成的噪声,所以每次扫描采集的信号都是固定的,不能通过噪声分布或者平均的方式进行去除。这两种噪声是导致OCT图像信噪比下降的主要原因,需要采取各种降噪手段来提高图像质量。

传统OCT的图像降噪算法是通过各种滤波算法进行图像降噪,例如空间域滤波、频域滤波和自适应滤波,此外还有帧平均的降噪方式等^[38-41]。这些降噪方法的主要缺点是需要大量的计算成本或者多次采集,然而,临床OCT应用需要高速采集和快速重建,传统降噪方法的限制对其实际应用提出了挑战。深度学习的一大优势是端到端的处理过程,只需要在训练阶段进行大量时间的计算,测试过程则可以大大减少计算成本和时间,更好地满足OCT在临床采集中的需求。

基于生成对抗网络(Generative Adversarial Network, GAN)的监督学习框架在图像降噪中展现出显著优势。Dong等人通过搭建散斑调制OCT系统,生成低散斑图像作为监督基准,如图1(a)训练定制化GAN模型精准解析噪声分布特征,实现了噪声抑

制与组织结构的解耦优化,该方法在鸡肉样品上可以得到13.89 dB的CNR(Contrast-to-Noise Ratio)和28.6 dB的PSNR(Peak Signal-to-Noise Ratio)^[42]。这一思路在Hang等人提出的SNR-Net OCT中得到进一步延伸:通过融合残差密集块、通道注意力机制与U-Net-GAN混合架构,结合大规模无散斑高信噪比数据集,如图1(b),该网络在提升低光图像亮度的同时,通过多尺度特征融合机制有效保留皮肤角质层、汗腺等微观结构的拓扑完整性^[43]。

一些工作也提出使用基于编码-解码的网络提取图像特征并进行降噪,例如Unet, ResNet^[44-46]。为突破传统卷积神经网络的感知瓶颈, Mehdi zadeh等人创新性地引入深度特征先验知识,将VGG网络提取的高阶语义特征与DnCNN架构相结合。如图1(c),这种双路径学习策略通过强化高频细节的梯度约束,显著提升了毛细血管分叉点、分层交界等关键区域的边缘锐化度,在降噪过程中实现感知质量与结构保真度的动态平衡,相对于使用传统L1、L2损失函数,该方法在感知清晰度指数(Perceptual Sharpness Index, PSI)、明显可察觉模糊(Just Noticeable Blur, JNB)以及频谱和空间清晰度测量(Spectral and Spatial Sharpness measure, S3)这三种表示细节质量的评估特征上都表现更好^[47]。Bayhaqi等人利用ResNet网络不仅实现了接近帧平均的降噪效果,还在分类器上验证了其降噪后的真实性^[44]。此外,基于某些场景下难以获得高质量标签数据的情况,Yu等人使用B2Unet网络实现了自监督的降噪^[48],通过定义一个新奇的提纯策略,将单帧含噪的OCT图像变成多张OCT图像,并实现自监督的训练过程,该方法在皮肤上能达到43.36 dB的PSNR和2.69 dB的CNR。

目前基于深度学习的降噪方法在去除散斑噪声和散粒噪声上已经取得不错的效果。通过高质量的去噪标签数据,结合不同的卷积神经网络结构,可以适用于各种应用场景。即便是在某些缺乏高质量图像的场景下,也可以通过无监督或者自监督的训练方式达到不错的降噪效果。但是缺点是缺乏明确的评判标准,且模型迁移困难,对数据的噪声分布敏感,降噪后效果的可解释性较差。综上所述,深度学习的降噪方法已经能在皮肤OCT场景下达到不错的降噪效果,提高皮肤分层结构的对比度,为后续皮肤结构分割等任务提供高质量的OCT图像。




图1 基于深度学习进行图像降噪的方法或策略:(a) SM-GAN对皮肤表皮交界处的降噪效果,通过搭建散斑调制OCT系统生成的低散斑图像作为监督基准^[42]; (b) SNR-Net OCT的流程框图,使用大规模的无散斑高信噪比数据集作为训练标签^[43]; (c) DnCNN-VGG网络结构示意图,使用VGG网络提取的特征损失作为DnCNN网络降噪的损失函数^[47]

Fig. 1 Deep learning-based methods/strategies for image denoising: (a) the denoising effect of SM-GAN at the dermal-epidermal junction of the skin, using low-speckle images generated by a speckle-modulated OCT system as the supervisory benchmark^[42]; (b) flowchart of SNR-Net for OCT, using a large-scale speckle-free high-SNR dataset as training labels^[43]; (c) schematic diagram of the DnCNN-VGG network architecture, utilizing feature loss extracted by the VGG network as the loss function for denoising in the DnCNN network^[47]

2 皮肤分割

OCT的皮肤分层研究始于对皮肤解剖结构的量化需求。早期的技术探索虽未直接采用现代人工智能方法,但其自动化处理框架为后续深度学习技术的介入奠定了基础。例如,2006年Yasuaki Hori团队提出的全自动三维OCT分析算法集^[12],可视为传统图像处理技术在皮肤分层中的代表性实践。该研究通过多模块组合实现了皮肤表面定位、表皮厚度计算、毛囊漏斗分割及真皮衰减系数分析等功能。其核心流程包括:利用深度导向算法生成表皮分布图,通过正视阴影图增强毛囊对比度,并基于直方图阈值分割与距离映射量化毛囊数量与空间占比。尽管未引入机器学习,但该工作系统性展示了三维OCT数据的自动化处理潜力,尤其是毛囊三维分割与真皮纹理评估等功能,为后续研究提供了重要的技术参考与数据标注基准。然而,传统算法的局限性在于高度依赖人工设计的特征提取规则,例如毛囊分割需预设距离阈值,表皮边界检测易受

噪声干扰,导致在复杂病变皮肤中的泛化能力有限。

在皮肤OCT成像领域,早期研究使用机器学习的方法进行皮肤层的分层^[49],随着深度学习技术的成熟,OCT在多个医学领域的应用中开始引入深度学习方法,例如眼科领域已成功实现眼底OCT图像的自动化分层分析^[50-52],OCT在皮肤领域的分层也逐渐转向数据驱动的智能分割模型。这一阶段的进展并非完全颠覆传统,而是在其基础上进行优化与扩展。例如文献[12]中基于直方图的毛囊分割思想,在2020年Del Amor等人的研究中演变为频域滤波与形态学后处理结合的混合策略^[53],如图2(a)所示;其表皮厚度计算模块则被Lin等人^[54]的轻量化CNN直接替代,实现端到端的测量,图2(b)展示了其皮肤分割结果和厚度测量方法。这种技术迭代表明,早期传统算法在特定子任务(如毛囊定位、真皮纹理分析)上的成果,为深度学习模型提供了可解释性较强的中间特征或后处理约束,从而形成“传统方法定义问题,DL模型优化解决”的发展路

径。Kepp 等人就在自己之前提出的基于机器学习分割皮肤的方法^[55]上进一步展开使用深度学习进行分割,如图 2(c)所示,展示了他们提出的 DCU-net 结构^[56]。

深度学习技术的优势体现在对复杂解剖结构的自适应解析能力。以表皮-真皮交界(Epidermal-dermal junction, DEJ)检测为例,传统方法(如^[12]中的梯度导向算法)需依赖信号强度梯度,但在光老化或炎症皮肤中,DEJ 的弱信号区域易导致分割断

裂。Chou 等人的研究^[57]通过卷积神经网络和无向图捕捉 DEJ 的连续性的结构特征,构建了多向训练和交叉验证融合的分割框架,如图 2(d)所示,显示了其网络降噪流程以及 DEJ 的划分流程。类似地,毛囊分割任务从阈值驱动升级为频域-空间域联合分析^[53],通过 U-Net 初步定位毛囊区域,再以傅里叶滤波消除伪影,最终实现亚像素级精度的三维重建。这种渐进式创新表明,DL 技术在 OCT 皮肤分层中的发展并非简单的“替代”传统方法,而是融合传




图 2 基于深度学习分割皮肤分层结构的方法和策略:(a) Del Amor 等人的研究中后处理策略,该流程首先使用全卷积网络生成初步的分割图;随后提取上表皮区域;通过滤波函数对毛囊结构进行增强;接着应用傅里叶域滤波对毛囊结构进行平滑处理;最后进行后处理以获得最终的毛囊结构分割图^[53]; (b) 使用轻量化 CNN 替代表皮厚度计算,这里显示的是皮肤分层结果和厚度计算^[54]; (c) ^[56]中提出的 DCU-net 结构,替代了之前机器学习算法和基础 U-net 结合的复杂计算流程; (d) 利用卷积神经网络进行 DEJ 分层和捕捉 DEJ 的连续性的流程图^[57]

Fig. 2 Methods and strategies of skin structure segmentation based on deep learning: (a) Post-processing strategy proposed by Del Amor et al., the process begins with generating an initial segmentation map using a fully convolutional network; then, the upper epidermis region is extracted; filtering functions are applied to enhance the follicular structures; followed by Fourier domain filtering to smooth the follicular structures; finally, post-processing is performed to obtain the final follicular structure segmentation map^[53]; (b) replacing traditional methods with lightweight CNNs for skin thickness measurement, here showing the skin layer segmentation results and thickness calculations^[54]; (c) the proposed DCU-Net architecture replaces the complex computational process that previously combined machine learning algorithms with the basic U-Net^[56]; (d) flowchart for utilizing a convolutional neural network for dermo-epidermal junction segmentation and continuity capture^[57]

统方法的领域知识,实现更鲁棒的模型泛化。

当前研究的核心挑战在于临床实用性与技术普适性的平衡。早期工作虽未采用 DL,但其模块化设计展现了较强的可移植性——算法集可适配不同 OCT 设备数据,且真皮衰减系数计算等功能至今仍被用作皮肤老化的量化指标。相比之下,深度学习模型虽在特定数据集上表现优异,但其性能高度依赖训练数据的设备参数与疾病类型分布。例如,谱域 OCT 系统与扫频源 OCT 在分辨率与信噪比上的差异,导致直接迁移模型时出现特征失配。这一矛盾促使近期研究趋向“传统+DL”的混合架构:例如在 DEJ 检测中使用医学领域的先验知识作为交叉检验的依据^[57];将频域滤波与传统形态学操作作为 U-Net 输出的后处理步骤^[53]。此类策略兼具传统方法的可解释性和深度学习的适应性。

随着分层精度以及速度的提高^[58],基于 OCT 的深度学习分层技术由于其快速的分层效率,已经逐步发展到术中检测的应用之中^[59],通过判断切除的边界来帮助医生实时判断是否需要二次切除。此外,皮肤分层还能帮助进行皮肤癌的诊断工作^[60]以及研究激光损伤后的恢复情况^[31, 61]。

3 皮肤癌智能诊断

当前, OCT 技术与人工智能的融合发展已成为医学影像领域的重要趋势,尤其在皮肤癌早期诊断方向已取得突破性进展。例如,研究者通过构建基于深度学习的 OCT 影像分析模型,已能实现对基底细胞癌、黑色素瘤等皮肤恶性肿瘤的高灵敏度识别。基于深度学习的皮肤 OCT 图像降噪与皮肤结构分层的分析技术,也为皮肤癌的智能诊断奠定了重要基础。此外,基于 OCTA 分析病灶血管网络密度以及血管形态,进而诊断皮肤癌的方法也是屡见不鲜^[62-65]。随着深度学习的加入, OCTA 血管网络的可视化得到进一步增强^[66],但是鲜有利用深度学习在 OCTA 中进行自动皮肤癌诊断的工作。主要原因是 OCTA 数据采集对采集稳定性有极高的要求,而皮肤 OCT 临床采集的运动伪影消除仍是一大难点。此外,由于 OCT 设备在皮肤科临床场景的普及率较低,且存在操作专业性要求高、检测成本较高等现实因素,目前可用于模型训练的皮肤 OCT 数据主要来源于少数研究机构的自主采集,呈现出明显的数据私有化和碎片化特征。这种数据壁垒不仅导致样本量积累速度缓慢,更使得现有数据集存在样本多样性不足、病灶表征覆盖不全等缺陷,严重制约

了深度学习模型的泛化能力和临床应用可靠性。

为突破数据瓶颈,学界正积极探索基于深度学习的生成式数据增强技术。早期研究聚焦于数据生成范式的突破, Mekonnen 等人提出的势函数引导仿真算法,通过生成包含增强型毛细血管网络(Augmented capillary network, ACN)的合成 OCT 数据,解决了监督学习中高质量标注数据稀缺的限制^[67]。该算法在三维体积内同步生成增强型全场 OCT 图像及其毛细血管基准图,利用二维高斯函数模拟血流反射特征,为后续模型训练提供了规模化、多样化的数据支撑。

早期通常使用机器学习的方法对 OCT 皮肤癌进行诊断^[60, 68],随着深度学习的发展以及 OCT 图像分辨率、信噪比的提高, OCT 高质量的图像结合深度学习的诊断方法得以实现。Li 等人首次在高清晰度 OCT(High definition-OCT, HD-OCT)上实现了全自动的细胞基底癌(Basal cell carcinoma, BCC)检测(图 3(a)),填补了该领域的应用空白,他们针对医学图像数据稀缺性的问题,将预训练深度卷积网络与判别器分类器结合,通过特征迁移而非端到端训练实现小样本下的 BCC 检测,突破了数据量的限制,其尝试了多种卷积网络,并在 BCC 探测任务上得到了最高 0.935 的曲线下面积(Area under curve, AUC)^[69]。此外,相对于传统 OCT 的微米级分辨率和数个毫米的成像深度,另一种基于共聚焦技术的全场 OCT 技术(Full-field optical coherence tomography, FFOCT)具有更高的分辨率,但是更小的成像深度,其亚微米级的分辨率能让观察者更加清楚的观测到细胞形态,有利于皮肤癌的诊断。Mandache 等人针对 FFOCT 成像模态,首次系统性引入卷积神经网络(Convolutional neural network, CNN)实现 BCC 得自动诊断,可以达到 95.9% 的准确率^[70](图 3(b))。Ho 等人则首次实现基于 FFOCT 的鳞状细胞癌(Squamous cell carcinoma, SCC)自动检测,设计了多级感受野网络结构,通过自适应调整特征提取尺度,有效捕获 FFOCT 图像中细胞核形态、细胞排列等亚细胞级病理特征,引入热图(heat map)技术解析 CNN 的决策依据,首次在 FFOCT 诊断中实现模型行为的可视化解释,增强了深度学习模型在临床场景中的可信度,诊断准确率也能达到 80% 以上^[71](图 3c)。此外,利用 1 μm 级分辨率的线场共聚焦光学相干层析成像(Line-field Confocal Optical Coherence Tomography, LC-OCT)技术,结合深度学习




图3 基于深度学习的OCT皮肤癌诊断方法:(a) 使用预训练卷积网络结合判别器分类器,通过特征迁移实现小样本下的BCC自动检测^[69]; (b) 基于FFOCT的BCC自动检测的分类示例^[70]; (c) 基于FFOCT的SCC自动检测的病理标签以及OCT图像标签^[71]; (d) 光化性角化病病灶及其周围癌变区域中异常细胞(红色标记)与正常细胞核(绿色标记)的检测结果^[72]

Fig. 3 OCT skin cancer diagnosis based on deep learning: (a) automatic BCC detection under few-shot conditions using a pre-trained convolutional network integrated with a discriminator-classifier, leveraging feature transfer learning; (b) exemplary classification results of automatic BCC detection using full-field optical coherence tomography; (c) pathological labels and OCT image annotations for SCC automatic detection with FFOCT-based analysis; (d) detection results of abnormal cells (marked in red) and normal cell nuclei (marked in green) in an actinic keratosis lesion and its surrounding cancerous region

分割算法,已经实现细胞核分布、形态等异型特征的自动提取与量化^[72]。相比传统二维组织病理学对活检的依赖,此类方法可以避免切片手术,达到无创、快速(数分钟)、可重复性高的优点^[72, 73]。图 3(d)展示了该方法对日光性角化病(Actinic keratosis, AK)病损的细胞核进行识别并分割,红色点状代表 AK 的癌细胞核,绿色代表正常细胞核。虽然 FFOCT 和 LC-OCT 的高分辨率使它们更易于进行皮肤癌的诊断以及具有取代病理检测的潜力,但是其相对传统 OCT 来说,较慢的成像速度(数分钟)以及较浅的成像深度($\sim 200\ \mu\text{m}$)都不适合在临床中进行应用。此外,基于 OCT 技术发展的功能性 OCT,例如偏振敏感 OCT 和 OCTA,也在皮肤癌诊断领域有很多的研究成果^[8-10]。Marvdashti 等人提出了基于偏振敏感 OCT 的全自动 BCC 检测技术^[74]。揭示了皮肤双折射特性在癌症检测中的关键作用,结合强度与双折射特征的分类器表现出优异的诊断性能,灵敏度和特异性均达到 95.4%。验证了双折射特征在癌症检测中的普适性,为其他依赖组织双折射特性改变的疾病(如膀胱癌、乳腺癌、烧伤深度评估等)提供了自动化检测的新思路(图 4(a))。Zhang 等人最近从 OCT 图像中提取出光学衰减系数(Optical attenuation coefficient, OAC)图像,并通过自监督的降噪手段得到高质量的 OAC 图像,并结合病理变化从 OAC 图像中提取出概率密度分布特征,最后使用联合训练网络针对 OAC 图像和其概率密度分布特征实现 AK、BCC 和正常皮肤组织的自动诊断,准确率接近 100%(图 4(b))^[75]。这些工作证明了多模态 OCT 结合深度学习的技術路径在皮肤癌智能诊断领域的潜力。

目前在皮肤癌早期诊断领域中,基于 OCT 的无损成像手段已被证明可以识别皮肤癌的结构特征,随着深度学习的加入,基于 OCT 的皮肤癌自动诊断方法已成为当前很有潜力的发展方向,受广大研究者和临床医生的关注。随着 OCT 技术的发展,不断提高的图像质量以及分辨率会进一步增加皮肤癌诊断的准确率,基于 OCT 的功能成像也将提供皮肤癌的多维结构特征,从多个角度联合诊断皮肤癌,进一步提高准确率。

4 总结与展望

深度学习的出现给 OCT 成像技术带来了全新的技术路径,不仅可以用于 OCT 图像质量的增强,也能在图像分析领域以及疾病诊断领域替代很多

人工工作,提高诊断效率以及诊断准确率。在图像降噪方面,当前研究证实,以高信噪比 OCT 图像作为训练标签数据,通过基于 GAN 或 Unet 等编码-解码架构的卷积神经网络进行噪声分布的提取与去除,已成为行之有效的技术方案。同时,多尺度特征融合技术的应用,在实现有效去噪的同时能更好地保持组织结构的细节信息。在皮肤结构分层方面,研究趋势显示,“传统+DL”的混合策略在提升泛化能力和可解释性方面展现了巨大潜力。例如在传统解决皮肤分层的方法路径中,利用卷积神经网络来代替其中的某些步骤,做到优化方法速度,提高准确性的作用。但是缺点是神经网络的训练依赖训练集,不同场景或设备下获得的数据具有不同的图像质量,这会造成模型在不同设备之间迁移时产生特征适配,进而出现分层性能的下降。未来研究应致力于提升模型在不同质量图像间的泛化能力,通过增强算法对图像质量变化的适应性,建立更稳健的降噪模型。

OCT 结合深度学习为皮肤癌无创诊断提供了高效、精准的解决方案。前期的研究通过皮肤 OCT 图像的结构特征,结合深度学习进行特征自动提取,再利用机器学习的方法进行自动诊断。随着 OCT 系统的发展,图像质量和分辨率的进一步提高,以及基于深度学习的图像降噪方法的发展,将 OCT 图像与病理图像特征进行关联并诊断的研究相继展开,尤其是 FFOCT 的出现,其可以提供 $1\ \mu\text{m}$ 左右的轴向分辨率,可以很清晰的观察到细胞级别的结构特征,这对于皮肤癌的早期诊断提供了很重要依据。但是 FFOCT 的采集速度慢,让他在临床上的应用受到运动伪影的严重限制,更多的是用在实验室环境下的前沿研究,未来皮肤 OCT 的临床转化主要基于传统 OCT 以及功能性 OCT 技术的发展。未来研究需同步推进以下三方面:一是提升高分辨 OCT 的采集速度,减少采集中运动伪影的影响,降低临床采集的难度;二是提高传统 OCT 技术在皮肤癌智能诊断中的准确性,例如发展更先进的深度学习诊断框架;三是结合 OCT 功能成像,开展多模态诊断研究,例如结合 OCTA 的血管成像或者偏振 OCT 的偏振态成像等,融合偏振敏感成像与 OCTA 的多模态方法,可通过增强组织对比度和血管可视化,为精准诊断提供新途径。此外,由于数据的私有化以及临床数据采集的标准不统一,造成数据积累困难,建立一个完善并统一的临床 OCT 数据采集




图4 基于深度学习的多模态 OCT 皮肤癌诊断方法:(a) 使用偏振敏感 OCT 结合强度 OCT 信息进行特诊识别,在探测 BCC 上可以达到 95.4% 的准确率^[74]; (b) 从 OCT 中提取 OAC 图像,联合 OAC 图像和其 PDF 特征进行联合训练并进行 AK、BCC 和正常组织的三分类任务的网络框架,准确率可达 100%^[75]; (c) AK 和正常组织在病理图片、OAC 图像以及 PDF 之间的比较,反映了病理特征和 OAC、PDF 之间存在明显的映射关系^[75]

Fig. 4 Deep learning-based multimodal OCT method for skin cancer diagnosis: (a) using polarization-sensitive OCT combined with intensity OCT information for differential diagnosis, achieving an accuracy of 95.4% in detecting BCC^[74]; (b) extracting OAC images from OCT, and performing joint training using both OAC images and their PDF features for a three-classification task of AK, BCC, and normal tissue, achieving an accuracy of 100%^[75]; (c) the comparison between AK and normal tissues in pathological images, OAC images, and PDFs reflects a clear correlation between pathological features and both OAC and PDFs^[75]

流程是至关重要的。同时,在行业内发展具有高认同性的商用 OCT 设备也会帮助建立统一的临床数据格式,建立起可共享的 OCT 皮肤肿瘤数据库,提高数据的多样性和样本量,标准化数据标注和质量控制,加速所有基于深度学习的皮肤肿瘤诊断工作的研究和技术迭代,提高对技术评价标准的公平性和可解释性,增强模型的泛化能力。

总的来说,深度学习的出现给基于 OCT 的皮肤癌诊断带来了新的发展方向,可以有效降低人工成本、提高诊断的准确率,为 OCT 设备在皮肤病诊断领域的普及打下坚实的基础。当下主要的研究重点在于如何将 OCT 应用于实际的临床工作中,真正的帮助医生辅助诊断皮肤肿瘤,减少成本提高效率,以至于未来代替活检手术作为诊断的金标准。目前 OCT 技术在皮肤癌智能诊断领域面临的主要临床转化问题分别有临床采集时的运动伪影、数据标准化、智能诊断模型的可解释性、临床诊断准确性的验证以及医生的接受度。其中运动伪影的消除可以通过提高 OCT 系统的采集速度、额外增加运动校准的探测设备和发展适配皮肤 OCT 的校准算法等手段来实现。而随着皮肤肿瘤发病率的持续攀升,数据标准化的问题则亟待解决,建立一套融合人工智能辅助诊断的标准化流程,并研发便携式高分辨率 OCT 设备已成为该领域突破性发展的关键路径,有助于解决皮肤 OCT 中的数据标准不一致的问题。其次通过构建多模态数据整合平台与智能化分析系统,可显著缩短从影像采集到病理判读的周期,有效降低人为操作差异性,提高临床诊断准确性和模型诊断结果的可读性,加强医生的接受度;数据的标准化也将进一步促进数据库的建立以及研究组之间的数据共享,推动模型的快速迭代和评价标准的统一,加强模型泛化性;此外,进一步研发微型化 OCT 探头将突破传统设备在基层医疗场景的应用壁垒,其亚细胞级三维成像能力可为皮肤肿瘤边界界定和诊断提供实时可视化依据。这种"流程革新+技术创新"的模式,不仅能够加速科研数据的标准化积累与算法迭代,更重要的是通过建立医工交叉的转化通道,使前沿研究成果快速适配临床诊疗需求,最终实现精准医疗资源的下沉和患者生存预后的整体提升。

References

[1] Tomlins P H, Wang R K. Theory, developments and applications of optical coherence tomography [J]. Journal of

- Physics D: Applied Physics, 2005, 38(15): 2519-35.
- [2] Usman M, Fraz M M, Barman S A. Computer vision techniques applied for diagnostic analysis of retinal OCT images: a review[J]. Archives of Computational Methods in Engineering, 2017, 24(3): 449-65.
- [3] Bussell I I, Wollstein G, Schuman J S. OCT for glaucoma diagnosis, screening and detection of glaucoma progression [J]. British Journal of Ophthalmology, 2014, 98 (Suppl 2): ii15.
- [4] Monteiro-Henriques I, Rocha-Sousa A, Barbosa-Breda J. Optical coherence tomography angiography changes in cardiovascular systemic diseases and risk factors: A Review [J]. Acta Ophthalmologica, 2022, 100(1): e1-e15.
- [5] Wieser W, Biedermann B R, Klein T, et al. Multi-Megahertz OCT: High quality 3D imaging at 20 million A-scans and 4.5 GVoxels per second [J]. Opt Express, 2010, 18 (14): 14685-704.
- [6] Rajabi-Estarabadi A, Bittar J M, Zheng C, et al. Optical coherence tomography imaging of melanoma skin cancer [J]. Lasers in Medical Science, 2018, 34(2): 411-20.
- [7] Levine A, Wang K, Markowitz O. Optical coherence tomography in the diagnosis of skin cancer[J]. Dermatologic Clinics, 2017, 35(4): 465-88.
- [8] Yazdanfar S, Rollins A M, Izatt J A. In vivo imaging of human retinal flow dynamics by color doppler optical coherence tomography [J]. Archives of Ophthalmology, 2003, 121(2): 235-9.
- [9] Baumann B. Polarization sensitive optical coherence tomography: A review of technology and applications[J]. Applied Sciences, 2017, 7(5): 474.
- [10] De Carlo T E, Romano A, Waheed N K, et al. A review of optical coherence tomography angiography (OCTA) [J]. International Journal of Retina and Vitreous, 2015, 1 (1): 5.
- [11] Strasswimmer J, Pierce M C, Park B H, et al. Polarization-sensitive optical coherence tomography of invasive basal cell carcinoma [J]. J Biomed Opt, 2004, 9 (2): 292-8.
- [12] Hori Y, Yasuno Y, Sakai S, et al. Automatic characterization and segmentation of human skin using three-dimensional optical coherence tomography [J]. Opt Express, 2006, 14(5): 1862-77.
- [13] Mogensen M, Thrane L, Joergensen T M, et al. Optical coherence tomography for imaging of skin and skin diseases [J]. Semin Cutan Med Surg, 2009, 28(3): 196-202.
- [14] Dalimier E, Salomon D. Full-field optical coherence tomography: a new technology for 3D high-resolution skin imaging [J]. Dermatology, 2012, 224(1): 84-92.
- [15] Sattler E, Kastle R, Welzel J. Optical coherence tomography in dermatology [J]. J Biomed Opt, 2013, 18 (6): 061224.
- [16] Boone M A, Marneffe A, Suppa M, et al. High-definition optical coherence tomography algorithm for the discrimination of actinic keratosis from normal skin and from squamous cell carcinoma [J]. J Eur Acad Dermatol Venereol, 2015, 29(8): 1606-15.
- [17] Hussain A A, Themstrup L, Jemec G B. Optical coherence tomography in the diagnosis of basal cell carcinoma [J]. Arch Dermatol Res, 2015, 307(1): 1-10.

- [18] Ulrich M, Von Braunmuehl T, Kurzen H, et al. The sensitivity and specificity of optical coherence tomography for the assisted diagnosis of nonpigmented basal cell carcinoma: an observational study [J]. *Br J Dermatol*, 2015, 173(2): 428–35.
- [19] Gao W, Zakharov V P, Myakinin O O, et al. Medical images classification for skin cancer using quantitative image features with optical coherence tomography [J]. *Journal of Innovative Optical Health Sciences*, 2016, 09(02).
- [20] Batz S, Wahrlich C, Alawi A, et al. Differentiation of different nonmelanoma skin cancer types using OCT [J]. *Skin Pharmacol Physiol*, 2018, 31(5): 238–45.
- [21] Bromberger L, Heise B, Felbermayer K, et al. Radiation-induced alterations in multi-layered, in-vitro skin models detected by optical coherence tomography and histological methods [J]. *PLoS One*, 2023, 18(3): e0281662.
- [22] Tang H, Xu C, Ge Y, et al. Multiparametric quantitative analysis of photodamage to skin using optical coherence tomography [J]. *Sensors (Basel)*, 2023, 23(7).
- [23] Welzel J, Bruhns M, Wolff H H. Optical coherence tomography in contact dermatitis and psoriasis [J]. *Archives of Dermatological Research*, 2003, 295(2): 50–5.
- [24] Ulrich M, Themstrup L, De Carvalho N, et al. Dynamic optical coherence tomography in dermatology [J]. *Dermatology*, 2016, 232(3): 298–311.
- [25] Rajabi-Estarabadi A, Vasquez-Herrera N E, Martinez-Velasco M A, et al. Optical coherence tomography in diagnosis of inflammatory scalp disorders [J]. *Journal of the European Academy of Dermatology and Venereology*, 2020, 34(9): 2147–51.
- [26] Guida S, Longhitano S, Ardighò M, et al. Dermoscopy, confocal microscopy and optical coherence tomography features of main inflammatory and autoimmune skin diseases: A systematic review [J]. *Australasian Journal of Dermatology*, 2022, 63(1): 15–26.
- [27] Wang R K, Jacques S L, Ma Z, et al. Three dimensional optical angiography [J]. *Opt Express*, 2007, 15(7): 4083–97.
- [28] Zhou Y, Yin D, Xue P, et al. Imaging of skin microvessels with optical coherence tomography: potential uses in port wine stains [J]. *Exp Ther Med*, 2012, 4(6): 1017–21.
- [29] Gambichler T, Azem P, And Schmitz L. Recent advances in clinical application of optical coherence tomography of human skin [J]. *Clinical, Cosmetic and Investigational Dermatology*, 2015, 8(null): 345–54.
- [30] O'Leary S, Fotouhi A, Turk D, et al. OCT image atlas of healthy skin on sun-exposed areas [J]. *Skin Research and Technology*, 2018, 24(4): 570–86.
- [31] Wu J, Ma Q, Zhou X, et al. Segmentation and quantitative analysis of optical coherence tomography (OCT) images of laser burned skin based on deep learning [J]. *Biomed Phys Eng Express*, 2024, 10(4).
- [32] Lee C K, Tsai M T, Chang F Y, et al. Evaluation of moisture-related attenuation coefficient and water diffusion velocity in human skin using optical coherence tomography [J]. *Sensors*, 2013, 13(4): 4041–50.
- [33] Shrestha A, Mahmood A. Review of deep learning algorithms and architectures [J]. *IEEE Access*, 2019, 7: 53040–65.
- [34] Viedma I A, Alonso-Caneiro D, Read S A, et al. Deep learning in retinal optical coherence tomography (OCT): A comprehensive survey [J]. *Neurocomputing*, 2022, 507: 247–64.
- [35] Madani M, Behzadi M M, Nabavi S. The role of deep learning in advancing breast cancer detection using different imaging modalities: A systematic review [J/OL]. 2022, 14(21): 10.3390/cancers14215334
- [36] Fu Q, Chen Y, Li Z, et al. A deep learning algorithm for detection of oral cavity squamous cell carcinoma from photographic images: A retrospective study [J]. *eClinicalMedicine*, 2020, 27.
- [37] Chu C S, Lee N P, Ho J W K, et al. Deep Learning for clinical image analyses in oral squamous cell carcinoma: A review [J]. *JAMA Otolaryngology-Head & Neck Surgery*, 2021, 147(10): 893–900.
- [38] Gomez-Valverde J J, Sinz C, Rank E A, et al. Adaptive compounding speckle-noise-reduction filter for optical coherence tomography images [J]. *J Biomed Opt*, 2021, 26(6).
- [39] Pircher M, Gotzinger E, Leitgeb R, et al. Speckle reduction in optical coherence tomography by frequency compounding [J]. *J Biomed Opt*, 2003, 8(3): 565–9.
- [40] Liba O, Lew M D, Sorelle E D, et al. Speckle-modulating optical coherence tomography in living mice and humans [J]. *Nat Commun*, 2017, 8: 15845.
- [41] Winetraub Y, Wu C, Collins G P, et al. Upper limit for angular compounding speckle reduction [J]. *Appl Phys Lett*, 2019, 114(21): 211101.
- [42] Dong Z, Liu G, Ni G, et al. Optical coherence tomography image denoising using a generative adversarial network with speckle modulation [J]. *J Biophotonics*, 2020, 13(4): e201960135.
- [43] Huang S, Wang R, Wu R, et al. SNR-Net OCT: brighten and denoise low-light optical coherence tomography images via deep learning [J]. *Opt Express*, 2023, 31(13): 20696–714.
- [44] Bayhaqi Y A, Hamidi A, Canbaz F, et al. Deep-learning-based fast optical coherence tomography (OCT) image denoising for smart laser osteotomy [J]. *IEEE Trans Med Imaging*, 2022, 41(10): 2615–28.
- [45] Rahaman J, Lukas B, May J, et al. A fast normalization and de-speckled method for skin optical coherence tomography image via deep learning [Z]. *Photonics in Dermatology and Plastic Surgery* 2023. 2023.10.1117/12.2651211
- [46] Rahaman J, May J, Puyana C, et al. Novel denoising technique for optical coherence tomography images [Z]. *Photonics in Dermatology and Plastic Surgery* 2024. 2024. 10.1117/12.3003575
- [47] Mehdizadeh M, Macnish C, Xiao D, et al. Deep feature loss to denoise OCT images using deep neural networks [J]. *J Biomed Opt*, 2021, 26(4).
- [48] Yu X, Ge C, Li M, et al. Self-supervised Blind2Unblind deep learning scheme for OCT speckle reductions [J]. *Biomed Opt Express*, 2023, 14(6): 2773–95.
- [49] Landman B A, Angelini E D, Salma N, et al. Segmentation of subcutaneous fat within mouse skin in 3D OCT image data using random forests [Z]. *Medical Imaging 2018: Image Processing*. 2018.10.1117/12.2290085

- [50] Fang L, Cunefare D, Wang C, et al. Automatic segmentation of nine retinal layer boundaries in OCT images of non-exudative AMD patients using deep learning and graph search [J]. *Biomed Opt Express*, 2017, 8(5): 2732–44.
- [51] Liu X, Bi L, Xu Y, et al. Robust deep learning method for choroidal vessel segmentation on swept source optical coherence tomography images [J]. *Biomed Opt Express*, 2019, 10(4): 1601–12.
- [52] Awais M, Müller H, Tang T B, et al. Classification of SD-OCT images using a Deep learning approach; proceedings of the 2017 IEEE International Conference on Signal and Image Processing Applications (ICSIPA), F 12–14 Sept. 2017, 2017 [C].
- [53] Del Amor R, Morales S, Colomer A, et al. Automatic segmentation of epidermis and hair follicles in optical coherence tomography images of normal skin by convolutional neural networks[J]. *Front Med (Lausanne)*, 2020, 7: 220.
- [54] Lin Y, Li D, Liu W, et al. A measurement of epidermal thickness of fingertip skin from OCT images using convolutional neural network [J]. *Journal of Innovative Optical Health Sciences*, 2020, 14(01).
- [55] Timo K, Christine D, Malte C, et al. Segmentation of subcutaneous fat within mouse skin in 3D OCT image data using random forests; proceedings of the ProcSPIE, F, 2018 [C].
- [56] Kepp T, Droigk C, Casper M, et al. Segmentation of mouse skin layers in optical coherence tomography image data using deep convolutional neural networks [J]. *Biomed Opt Express*, 2019, 10(7): 3484–96.
- [57] Chou H Y, Huang S L, Tjiu J W, et al. Dermal epidermal junction detection for full-field optical coherence tomography data of human skin by deep learning [J]. *Comput Med Imaging Graph*, 2021, 87: 101833.
- [58] Lin C H, Lukas B E, Rajabi-Estarabadi A, et al. Rapid measurement of epidermal thickness in OCT images of skin [J]. *Sci Rep*, 2024, 14(1): 2230.
- [59] Liu X, Chuchvara N, Liu Y, et al. Real-time deep learning assisted skin layer delineation in dermal optical coherence tomography [J]. *OSA Contin*, 2021, 4 (7) : 2008–23.
- [60] Liu X, Ouellette S, Jamgochian M, et al. One-class machine learning classification of skin tissue based on manually scanned optical coherence tomography imaging [J]. *Sci Rep*, 2023, 13(1): 867.
- [61] Wang C, Ma Q, Wei Y, et al. Deep learning automatically assesses 2-microm laser-induced skin damage OCT images [J]. *Lasers Med Sci*, 2024, 39(1): 106.
- [62] Sigsgaard V, Themstrup L, Theut Riis P, et al. In vivo measurements of blood vessels' distribution in non-melanoma skin cancer by dynamic optical coherence tomography – a new quantitative measure?[J]. *Skin Res Technol*, 2018, 24(1): 123–8.
- [63] Schuh S, Holmes J, Ulrich M, et al. Imaging blood vessel morphology in skin: dynamic optical coherence tomography as a novel potential diagnostic tool in dermatology [J]. *Dermatol Ther (Heidelb)*, 2017, 7(2): 187–202.
- [64] Themstrup L, De Carvalho N, Nielsen S M, et al. In vivo differentiation of common basal cell carcinoma subtypes by microvascular and structural imaging using dynamic optical coherence tomography [J]. *Exp Dermatol*, 2018, 27 (2): 156–65.
- [65] Meiburger K M, Chen Z, Sinz C, et al. Automatic skin lesion area determination of basal cell carcinoma using optical coherence tomography angiography and a skeletonization approach: Preliminary results [J]. *Journal of Biophotonics*, 2019, 12(9): e201900131.
- [66] Xu J, Yuan X, Huang Y, et al. Deep-learning visualization enhancement method for optical coherence tomography angiography in dermatology [J]. *Journal of Biophotonics*, 2023, 16(10): e202200366.
- [67] Mekonnen B K, Hsieh T H, Tsai D F, et al. Generation of augmented capillary network optical coherence tomography image data of human skin for deep learning and capillary segmentation[J]. *Diagnostics (Basel)*, 2021, 11(4).
- [68] Jorgensen T M, Tycho A, Mogensen M, et al. Machine-learning classification of non-melanoma skin cancers from image features obtained by optical coherence tomography [J]. *Skin Res Technol*, 2008, 14(3): 364–9.
- [69] Li A, Cheng J, Yow A P, et al. Automated basal cell carcinoma detection in high-definition optical coherence tomography[C]. *Proceedings of the 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, F 16–20 Aug. 2016.
- [70] Mandache D, Dalimier E, Durkin J R, et al. Basal cell carcinoma detection in full field OCT images using convolutional neural networks [C]. *Proceedings of the 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, F 4–7 April 2018.
- [71] Ho C J, Calderon-Delgado M, Chan C C, et al. Detecting mouse squamous cell carcinoma from submicron full-field optical coherence tomography images by deep learning [J]. *J Biophotonics*, 2021, 14(1): e202000271.
- [72] Fischman S, Perez-Anker J, Tognetti L, et al. Non-invasive scoring of cellular atypia in keratinocyte cancers in 3D LC-OCT images using Deep Learning [J]. *Sci Rep*, 2022, 12(1): 481.
- [73] Yi J Y, Huang S L, Li S, et al. Discrimination of the skin cells from cellular-resolution optical coherence tomography by deep learning[J]. *Photonics*, 2025, 12(3).
- [74] Marvdashti T, Duan L, Aasi S Z, et al. Classification of basal cell carcinoma in human skin using machine learning and quantitative features captured by polarization sensitive optical coherence tomography [J]. *Biomed Opt Express*, 2016, 7(9): 3721–35.
- [75] Zhang L, Li X, Chen W, et al. A joint learning approach for automated diagnosis of keratinocyte carcinoma using optical attenuation coefficients [J]. *npj Digital Medicine*, 2025, 8(1): 232.