

谢泽云, 李泽滔, 王薇, 等. 改进 3D-UNet 的 OCT 视网膜层分割[J]. 智能计算机与应用, 2026, 16(3): 115-120. DOI: 10.20169/j. issn. 2095-2163. 24040910

改进 3D-UNet 的 OCT 视网膜层分割

谢泽云¹, 李泽滔¹, 王薇², 牟刚³

(1 贵州大学 电气工程学院, 贵阳 550025; 2 重庆爱尔眼科医院(总院), 重庆 400020;

3 重庆公共运输职业学院 智慧交通学院, 重庆 402260)

摘要: 青光眼的早期诊断对于预防该病导致的视力丧失至关重要, 而光学相干断层扫描(OCT)为人们提供了一种高分辨率的成像手段, 以观察和分析视网膜层结构。本研究旨在通过改进的 3D-UNet 网络架构, 提高 OCT 图像中视网膜层结构识别和分割的精度。首先, 采用了密集连接架构来增强特征提取的能力, 确保了网络能够捕获从浅层到深层的丰富信息, 从而提高视网膜层结构识别的准确性。其次, 针对视网膜层间高度相似结构的有效区分问题, 本研究融合了残差学习机制和 Inception 模块, 通过加深网络深度和扩展网络宽度来提高模型的识别能力, 有效区分相似视网膜层结构。最后, 为了精确恢复高分辨率细节, 本文采用了新型的上采样方法, 通过精细调整上采样过程, 显著提升了细节恢复的质量。实验结果表明, 提出的改进 3D-UNet 网络在视网膜层结构识别和分割任务上, 相较于传统方法, 展现出了更高的精度。

关键词: OCT 视网膜层分割; 3D-UNet; 密集连接架构; 残差学习; Inception

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 2095-2163(2026)03-0115-06

Improved 3D-UNet for OCT retinal layer segmentation

XIE Zeyun¹, LI Zetao¹, WANG Wei², MOU Gang³

(1 School of Electrical Engineering, Guizhou University, Guiyang 550025, China;

2 Chongqing Aier Eye Hospital, Chongqing 400020, China;

3 School of Intelligent Transportation, Chongqing Vocational College of Public Transportation, Chongqing 402260, China)

Abstract: Early diagnosis of glaucoma is crucial for preventing vision loss caused by the disease, and Optical Coherence Tomography (OCT) offers a high-resolution imaging method for observing and analyzing retinal layer structures. This research aims to enhance the accuracy of retinal layer structure recognition and segmentation in OCT images through an improved 3D-UNet network architecture. Initially, a densely connected architecture is employed to enhance feature extraction capabilities, ensuring the capture of rich information from shallow to deep layers, thereby improving the accuracy of retinal layer structure recognition. Secondly, to effectively differentiate between highly similar retinal layer structures, this research integrates residual learning mechanisms with Inception modules, improving model differentiation capability by deepening and widening the network. Lastly, for precise high-resolution detail recovery, a novel upsampling method is adopted, significantly improving detail recovery quality through refined adjustments in the upsampling process. Experimental results demonstrate that the proposed improved 3D-UNet network exhibits higher precision and efficiency in retinal layer structure recognition and segmentation tasks compared to conventional methods.

Key words: OCT retinal layer segmentation; 3D-UNet; dense connection architecture; residual learning; Inception

0 引言

青光眼是一种眼内压增高导致的视神经损伤和视野缺失的疾病, 是全球致盲的主要原因之一^[1-3]。

据世界卫生组织(WHO)报道, 青光眼是仅次于白内障的第二大致盲性疾病^[4-6]。由于早期阶段症状不明显, 许多患者在明显视力受损前未能获得诊断, 因此, 早期发现和诊断对于预防青光眼相关视力丧失

基金项目: 国家自然科学基金(61963009)。

作者简介: 谢泽云(1997—), 男, 硕士研究生, 主要研究方向: 深度学习, 图像处理; 王薇(1988—), 女, 博士研究生, 副主任医师, 主要研究方向: 青光眼, 原发性闭角型青光眼; 牟刚(1977—), 男, 副教授, 主要研究方向: 人工智能。

通信作者: 李泽滔(1960—), 男, 博士, 教授, 博士生导师, 主要研究方向: 智能电网, 计算机控制技术。Email: 1462312250@qq.com。

收稿日期: 2024-04-09

至关重要^[7-9]。

尽管眼压测量^[10]、视野检查^[11]和视神经头评估^[12]等传统方法在青光眼诊断中起到了重要作用,但这些方法往往在疾病早期阶段难以提供准确的诊断信息^[13-15]。光学相干断层扫描(OCT)作为一种先进的成像技术,通过提供视网膜和视神经头的高分辨率横截面图像,为青光眼的早期诊断提供了一种非侵入性、精确的手段。特别是,视网膜神经纤维层(RNFL)的厚度变化被认为是青光眼发展的早期指标^[16-17],OCT能够有效测量RNFL厚度,为临床提供重要的诊断依据。

然而,尽管OCT技术的引入极大地促进了青光眼早期诊断的能力,但对OCT图像的解析仍面临一些挑战。其中包括如何提高视网膜层结构识别的准确性,如何有效区分视网膜层间高度相似的结构,以及如何精确恢复高分辨率细节等问题。这些挑战限制了OCT在青光眼早期诊断中的潜力。

鉴于此,本研究提出了一种基于改进3D-UNet^[18]的OCT特征提取网络,旨在克服现有技术的限制,进一步提升OCT在青光眼早期诊断中的应用价值。本文的方法采用了密集连接架构^[19]、融合残差学习机制^[20]与Inception模块^[21],并引入了一种新型的上采样技术,以期在提高视网膜层结构识别和分割的准确性的同时,有效区分视网膜层间的微妙差异,并精确恢复细节信息。通过这一改进,旨在为青光眼的早期诊断提供更为精确和可靠的工具,从而为早期干预和治疗提供坚实的基础。

1 方法

1.1 网络结构

OCT视网膜分割的架构设计如图1所示。网络由2个路径组成:编码路径作为下采样,解码路径作为上采样。

编码路径中下采样的目的是减少特征图的分辨率并增加接收字段。这通过3个密集块实现,每个密集块包括3个BN-ReLU-Conv(1×1×1)-BN-ReLU-Conv(3×3×3),增长率 $k=12$ 。2个连续块之间使用步长为2的卷积层来降低特征图分辨率,同时保留空间信息。转换块作为深度监督处理有限的数据集,但是较少复杂并忽略了辅助损失和主损失之间的权重平衡。在进入第一个密集块之前,使用卷积层提取特征,生成 $m_0=32$ 的输出特征图。

在解码路径中,上采样过程由残差初始块和上采样块的组合构成。具体来说,接近输入层的网络

负责捕获局部、细粒度特征,如边缘和纹理。更接近输出层的网络用以捕获全局、更抽象的特征,如对象的整体形状和场景的上下文信息。为了做出更好的预测,研究中在每个残差初始块后执行上采样。来自不同层级上采样特征图的连接允许捕获多种上下文信息,用于OCT视网膜层分割。分类器由用于将连接的特征分类为目标类别(即视网膜层的4个类别)的Conv(1×1×1)组成。最后,使用Softmax分类获取视网膜神经纤维层概率图。

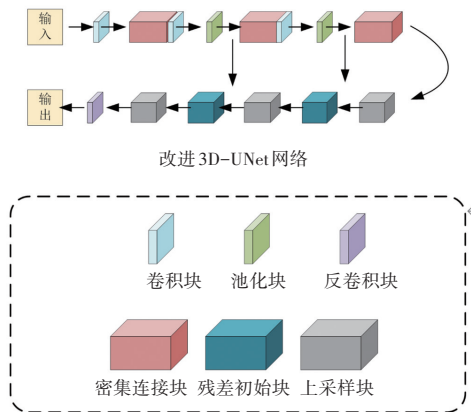


图1 改进3D-UNet网络结构

Fig. 1 Architecture of the improved 3D-UNet network

1.2 密集连接模块

进行高精度的视网膜层结构识别和分割时,从整体OCT图像中准确地识别视网膜层的各个层次,并对每个层次进行清晰的分割至关重要。这要求模型能够在多尺度上理解视网膜层结构,从宏观到微观都能精准捕捉包括视网膜层边界、形状和大小等细节。

常规的3D-UNet模型由于依赖于标准的卷积和池化操作,面临着在捕获细节特征过程中可能丢失关键信息的挑战。这一问题直接影响到模型在实现高精度视网膜层结构识别与分割方面的能力。

为了克服这一挑战,本研究引入了密集连接架构(Dense connected Network, DenseNet),以增强模型在深层网络中的信息流通能力。通过在网络的各个层之间建立直接连接,显著提升了对视网膜层结构相似性的识别精度。

DenseNet架构通过其密集连接的方式可以有效减少梯度消失问题,提升网络的深度学习能力;更为关键的是,通过融合不同层的特征图来捕捉多尺度的上下文信息,这对于精确分割OCT视网膜层尤为重要。此外,DenseNet能够使用所有层的特征来进行最终的分类决策。这种全面特征学习的方法,让

网络不再仅依赖于单一层级的特征,而是从广泛的特征集中进行学习,能够极大地提高3D-UNet图像分割的精度和效率。下面将对密集连接模块进行详细介绍。

(1)密集连接。密集连接提供了从一层到所有后续层的直接连接。第一层将其特征图发送到所有后续层。假设 y_l 是第 l 层的输出, $F(\cdot)$ 是包括操作如3D卷积、批量归一化和ReLU激活的复合函数。

密集连接是DenseNetks架构的核心理念。本文的方法继承了这一理念,并创建了用于OCT视网膜层分割的3D-DenseNet。

(2)复合函数。在本文的方法中,复合函数 $F(\cdot)$ 包含3个连续的操作:3D卷积、BN和ReLU。

①3D卷积。3D卷积是2D卷积向第三维度的扩展。3D卷积是2D卷积的一个扩展,即添加了一个第三维度。这意味着不仅在图像的高度和宽度上进行卷积,还在深度上进行卷积,使其能够处理3D体积数据。

②批量归一化(BN)^[22]。通过以下步骤完成:首先计算小批量数据的均值和方差,然后使用这些统计数据来归一化数据,使得输出的均值接近0且方差接近1。接着,通过学习到的2个参数、即缩放因子(γ)和偏移量(β)对归一化后的数据进行缩放和偏移。这一过程有助于减少内部协变量偏移,可能加速训练过程并提高准确性。在每个复合函数的ReLU层之前添加BN,意味着在激活前对数据进行归一化处理。

③ReLU(Rectified Linear Unit)激活函数^[23]。通过对输入 x 进行逐元素的最大化操作来输出 x 和0之间的最大值。形式上,ReLU可被定义为:

$$f(x) = \max(0, x) \quad (1)$$

这意味着如果输入 x 是正数,就会原样输出;如果是负数,则输出为0。这个简单的非线性变换有助于增加网络的复杂性和学习能力,同时保持计算效率。

(3)增长率。每个复合函数 F_l 在第 l 层产生 k 个特征图,那么第 l 层将有 $k \times (l-1) + k_0$ 个输入特征图,其中 k_0 是数据集中的通道数。 k 通常取一个较小的整数(例如, $k=12$),用于防止网络参数过快增长。在密集连接块内,输入通道的大小增长,这在训练时会导致内存问题。为了解决这个问题,引入了瓶颈层来减少输出大小。瓶颈层(Bottleneck Layer)是一种特殊的网络层,用于减少前一层输出

特征图的维度或数量,以此来降低网络中的参数量和计算复杂性。在本文中,将瓶颈层从 (1×1) 扩展到了 $3D(1 \times 1 \times 1)$ 卷积层。这个层通过减少训练参数和高效的计算来提高内存效率。

1.3 残差初始块

在对视网膜层间高度相似结构进行有效区分时,需要专注于区分视网膜内部那些在形态和信号强度上非常相似的层级结构。由于视网膜层次之间的界限非常微妙,这就要求模型能够捕捉到微妙的纹理、形态和强度变化。

常规的3D-UNet在处理具有相似性的视网膜层结构时,由于缺乏足够的特征区分能力,其性能可能受到限制。这些结构间的微妙差异对于青光眼的准确诊断至关重要。

为了克服这一局限性,本节采用了融合残差学习机制^[24]与Inception模块^[21]的方法,整合不同尺度的特征提取能力,增强模型对于视网膜多层结构细节的捕捉能力,以下将针对残差学习机制与Inception模块进行介绍。

残差学习机制允许深层架构的实现。残差初始块通过网络中的多尺度方法解决了OCT分割中视网膜神经纤维层之间对比度低的问题。在解码路径中,残差块的概念是不同核大小卷积特征图的聚合。残差单元允许信号从一个块传播到其他块,支持深度网络中有效的信息流动和学习。在这种机制中,每个层的输出由该层的输入加上一个残差函数的结果组成,即:

$$y_{l+1} = x_l + F(x_l + W_l) \quad (2)$$

其中, F 表示残差函数, x_l 和 W_l 分别表示第 l 个残差单元的输入特征和相关权重。学习相对于输入特征 x_l 的加性残差函数 F 是残差学习的主要概念。因此,通过解释任意更深层的特征 $x_L(L > l \geq 1)$,推导出残差单元通过网络平滑地创造信息传播。因此残差初始块的学习可描述为:

$$x_L = x_l + \sum_{i=1}^{L-1} F(x_i + W_i) \quad (3)$$

因此,浅层单元 x_l 加上汇总的残差函数 $\sum_{i=1}^{L-1} F(x_i + W_i)$ 可以表现为任何深层次的特征 x_L 。这些推导表明,残差单元通过网络平滑地创建信息传播。因此,残差初始块学习描述输入特征图的函数,有效地支持深度学习网络的学习和信息处理。

本文提出的残差初始模块用于分割网络。为了执行卷积操作,在初始模块中使用了不同大小的卷

积核。为了使网络能够接受多尺度的上下文信息,研究中累计使用了3种卷积核($1 \times 1 \times 1$, $2 \times 2 \times 2$, $3 \times 3 \times 3$)卷积得到的特征。并通过在标准卷积核和每个元素之间插入空格来增加卷积核的感受野,这种膨胀卷积的方式不增加参数数量或计算量,特别适合于处理图像分割任务中的大尺度信息。通过使用不同卷积核大小和膨胀操作,网络接收到多尺度的上下文信息,这有助于解决OCT分割中视网膜层对比度低的问题。此外,为了控制参数的增加,每个分支都引入了一个瓶颈卷积层。

1.4 上采样块

尽管3D-UNet在图像分割领域得到了广泛应用,但其上采样策略在恢复高分辨率细节、尤其四视网膜层边缘区域的精确性方面可能不够理想。这直接影响到分割质量和后续分析的准确性。本小节采用了一种新型的上采样机制优化模型在图像细节恢复方面的性能。

这就类似于初始模块,其中2个分支的上采样特征被组合。在每个分支中,输入特征分别与($1 \times 1 \times 1$)和($3 \times 3 \times 3$)不同核大小卷积。结果特征通过步长为2的反卷积操作进行上采样。在第2个分支中,使用膨胀卷积以从更宽的接收场获取更多上下文信息。瓶颈操作与残差初始块相同。上采样特征的组合操作通过连接层完成。上采样块的输出如下:

$$x_{l+1} = D^2(C_b(x_l)) \circ D^2(C_d(C_b(x_l))) \quad (4)$$

其中, D^2 表示步长为2的反卷积层。上采样块的主要优点是将不同未池化特征组合到网络中。创建了多尺度上下文信息以解决3D OCT视网膜神经纤维层分割的问题。通常,简单的反卷积层在上采样特征图时会产生错误。不同中间特征与不同核大小卷积并在组合之前分别上采样,以减少错误。

2 实验结果

2.1 实验数据集

本小节研究中使用的数据集由Mukherjee等学者^[25]收集,包括624名患者的OCT扫描,使用Cirrus SD-OCT扫描仪(Zeiss, Dublin, CA, USA)进行,使用OCT-Explorer专用软件对视网膜层进行分割。数据集中的扫描图像以视神经头(OH)为中心,物理尺寸为 $6 \times 6 \times 2$ (mm \times mm \times mm),对应于每个体积 $200 \times 200 \times 1024$ 的体积元素。出于对图像质量考虑,仅保留信号强度大于或等于7的扫描,最终共获得1110个扫描用于实验分析。从原始数据集

中,263个扫描被标记为健康,而847个被诊断为原发性开角型青光眼(POAG)。青光眼的判断基于至少2次连续的异常视野测试结果。为了训练和测试深度学习模型,数据集被划分为888个训练样本、112个验证样本和110个测试样本,采用10%用于验证,10%用于测试的标准比例,确保同一患者的眼睛不会存在于不同的数据集中。

2.2 实验参数设置

本小节所提出的方法是用Pycharm软件配备在32 GB DDR4 RAM和NVIDIA GeForce GTX3060 12 GB显卡的i7-11700K处理器上实现的。

研究中采用了推荐的方法初始化网络权重。权重从标准差为0.01的截断正态分布中初始化。学习率初始化为0.0002,权重衰减至 ϵ 为 $2e-6$,动量设置为0.99。使用Adam算法训练网络,批量大小为8。没有使用自适应的方法来调整学习率,而是设置了步长衰减并观察了训练中成本函数的增长。研究中发现这是呈现出指数级下降的曲线,因此保持了这种简单、但有效的策略。为了得到最终的预测结果,研究中对重叠的裁剪子体积的预测使用了投票方法。使用Adam优化器通过交叉熵和L2正则化作为成本函数来优化网络参数。

2.3 评价指标

为了评估本工作中图像分割任务的性能,本研究采用了多种评价指标,包括均方根误差(RMSE)、平均绝对误差(MAE)和豪斯多夫距离。

(1)均方根误差(RMSE):是评价预测精度的一种常用指标。通过计算预测值与实际值之间差值的平方后求平均,再取平方根得到。

(2)平均绝对误差(MAE):衡量的是预测值与实际值之差的绝对值的平均数,由此则提供了另一种衡量预测精度的方式。与RMSE相比,MAE对异常值、即大的偏差并不敏感。

(3)豪斯多夫距离(Hausdorff Distance):用于衡量2组点集(或轮廓)之间的最大差异,这是一种反映预测轮廓与真实轮廓最大局部偏差的指标。

2.4 实验结果及分析

在本研究中,针对3D-OCT视网膜层分割任务评估了4种算法:OCT-Explorer、2D-UNet、3D-UNet以及一种改进的3D-UNet。分析依据3个核心评价指标进行:均方根误差(RMSE)、平均绝对误差(MAE)以及豪斯多夫距离(Hausdorff Distance),旨在全面评估这些模型在精确性、一致性和形状匹配度方面的性能。

3D OCT 分割结果见表 1。表 1 中改进的 3D-UNet 的性能表现优越, RMSE、MAE 和豪斯多夫距离分别达到了 $0.85(\pm 0.51)$ 、 $0.48(\pm 0.16)$ 和 $1.84(\pm 2.26)$, 这一结果不仅凸显了其在精度上的优势, 也展示了其在预测一致性和形状匹配度方面的有效改进。这种改进版的 3D-UNet 通过针对性的网络结构优化, 显著提升了对 3D 视网膜层复杂结构的识别和分割能力。

表 1 3D OCT 分割结果

Table 1 Segmentation results of 3D OCT

方法	RMSE	MAE	Hasudorff distance
OCT-Explorer	4.71(± 6.76)	4.15(± 5.32)	5.85(± 8.08)
2D-UNet	3.00(± 4.12)	1.33(± 1.24)	3.55(± 7.34)
3D-UNet	1.58(± 1.72)	0.85(± 0.50)	2.98(± 5.30)
改进 3D-UNet	0.85(± 0.51)	0.48(± 0.16)	1.84(± 2.26)

相比之下, 标准的 3D-UNet、2D-UNet 和 OCT-Explorer 表现出较低的精确度和较大的结果变异性。尽管 3D-UNet 在这 3 个指标上的表现 ($1.58(\pm 1.72)$ 、 $0.85(\pm 0.50)$ 、 $2.98(\pm 5.30)$) 均要优于 2D-UNet ($3.00(\pm 4.12)$ 、 $1.33(\pm 1.24)$ 、 $3.55(\pm 7.34)$) 和 OCT-Explorer ($4.71(\pm 6.76)$ 、 $4.15(\pm 5.32)$ 、 $5.85(\pm 8.08)$), 但与改进的 3D-UNet 相比仍有较大的差距。这一差异强调了深度学习模型、特别是三维模型在处理复杂医学图像数据时的潜力, 以及继续优化这些模型以提高分割准确性和一致性的重要性。分割结果示意如图 2 所示。




图 2 OCT 分割示意图

Fig. 2 Diagram of OCT segmentation

3 结束语

本次研究开发了一种基于改进的 3D-UNet 网络架构的 OCT 视网膜层分割方法。通过密集连接架构、融合残差学习机制与 Inception 模块、及新型上采样技术, 本方法在视网膜层结构识别、相似结构区分以及高分辨率细节恢复方面展现出显著优势。这些成果不仅证明了深度学习在医学影像分析中的应用潜力, 也为未来 OCT 图像处理技术的发展提供了新的方向。

尽管取得了一定的成果, 但未来工作需进一步提升模型的泛化能力和处理效率。未来的工作将继续研发更高效、准确的 OCT 分析方法, 为眼科诊断和治疗提供更强大的支持。

参考文献

- [1] LIM R. The surgical management of glaucoma: A review[J]. *Clinical & Experimental Ophthalmology*, 2022, 50(2): 213-231.
- [2] CASSON R J. Medical therapy for glaucoma; A review[J]. *Clinical & Experimental Ophthalmology*, 2022, 50(2): 198-212.
- [3] CHOU R, SELPH S, BLAZINA I, et al. Screening for glaucoma in adults: updated evidence report and systematic review for the US preventive services task force[J]. *JAMA*, 2022, 327(20): 1998-2012.
- [4] GEORGE R, PANDA S, VIJAYA L. Blindness in glaucoma: primary open-angle glaucoma versus primary angle-closure glaucoma—a meta-analysis[J]. *Eye*, 2022, 36(11): 2099-2105.
- [5] JAYARAM H, KOLKO M, FRIEDMAN D S, et al. Glaucoma: Now and beyond[J]. *The Lancet*, 2023, 402(10414): 1788-1801.
- [6] HOLLITT G L, SIGGS O M, RIDGE B, et al. Attitudes toward glaucoma genetic risk assessment in unaffected individuals[J]. *Translational Vision Science & Technology*, 2022, 11(10): 38.
- [7] CHOUDHARI N S, KUMAR S, RICHHARIYA A, et al. Adaptive optics scanning laser ophthalmoscopy may support early diagnosis of glaucoma[J]. *Indian Journal of Ophthalmology*, 2022, 70(8): 2877-2882.
- [8] RAJA H, AKRAM M U, HASSAN T, et al. Glaucoma detection using optical coherence tomography images: A systematic review of clinical and automated studies[J]. *IETE Journal of Research*, 2023, 69(11): 7958-7978.
- [9] LEE S, MACKEY D. Glaucoma - risk factors and current challenges in the diagnosis of a leading cause of visual impairment[J]. *Maturitas*, 2022, 163: 15-22.
- [10] HODGSON M, DICKERSON S J, RIZZO P. Poster: Highly nonlinear solitary wave transducers for detecting eye pressure changes[C]//Proceedings of the 8th ACM/IEEE International Conference on Connected Health: Applications, Systems and Engineering Technologies. New York: ACM, 2023: 194-195.
- [11] ALEJANDRO J, CIDECIYAN A V, WU V, et al. Full-field stimulus testing: role in the clinic and as an outcome measure in clinical trials of severe childhood retinal disease[J]. *Progress in Retinal and Eye Research*, 2022, 87: 101000.
- [12] CHUANGSUWANICH T, TUN T A, BRAEU F A, et al. Differing associations between optic nerve head strains and visual field loss in patients with normal- and high-tension glaucoma[J]. *Ophthalmology*, 2023, 130(1): 99-110.
- [13] WU Yue, SZYMANSKA M, HU Yubing, et al. Measures of disease activity in glaucoma[J]. *Biosensors and Bioelectronics*, 2022, 196: 113700.
- [14] HAN F F, FU X X. Vitamin intake and glaucoma risk: A systematic review and meta-analysis[J]. *Journal Français D'ophtalmologie*, 2022, 45(5): 519-528.
- [15] HEIJL A, PETERS D, BENGTTSSON B, et al. Long-term impact of immediate versus delayed treatment of early glaucoma:

- Results from the early manifest Glaucoma trial [J]. *American Journal of Ophthalmology*, 2023, 252: 286–294.
- [16] THIERY A H, BRAEU F, TUN T A, et al. Medical application of geometric deep learning for the diagnosis of glaucoma [J]. arXiv preprint arXiv, 2204.07004, 2022.
- [17] VAZ P G, BREA L S, SILVA V B, et al. Retinal OCT speckle as a biomarker for glaucoma diagnosis and staging [J]. *Computerized Medical Imaging and Graphics*, 2023, 102: 102256.
- [18] 戴振晖, 简婉薇, 朱琳, 等. 基于3D UNet结合Transformer的肝脏及肝肿瘤自动分割[J]. *中国医疗设备*, 2023, 38(1): 42–47.
- [19] HUANG Gao, LIU Zhuang, MAATEN L V D, et al. Densely connected convolutional networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 2261–2269.
- [20] CUI Jiequan, LIU Shu, TIAN Zhuotao, et al. ResLT: Residual learning for long-tailed recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(3): 3695–3706.
- [21] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions [J]. arXiv preprint arXiv, 1409.4842, 2014.
- [22] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [J]. arXiv preprint arXiv, 1502.03167, 2015.
- [23] NEUFELD A, NGUYEN T A, WU sizhou. Deep ReLU neural networks overcome the curse of dimensionality when approximating semilinear partial integro-differential equations [J]. *Analysis and Applications*, 2025, 23(7): 1227–1278.
- [24] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 770–778.
- [25] MUKHERJEE S, SILVA T D, GRISSO P, et al. Retinal layer segmentation in optical coherence tomography (OCT) using a 3D deep-convolutional regression network for patients with age-related macular degeneration [J]. *Biomedical Optics Express*, 2022, 13(6): 3195–3210.