# 分层极化注意力网络的OCT视网膜图像 降噪研究

## 吴 桐,陈明惠\*, 胡亚兰, 周旭东, 马文飞, 陈思思, 李家昱

上海理工大学健康科学与工程学院,上海介入医疗器械工程技术研究中心,上海

收稿日期: 2024年12月15日; 录用日期: 2025年1月8日; 发布日期: 2025年1月16日

#### 摘要

目的: 光学相干断层成像技术(OCT)是视网膜疾病诊断中最常用的方法之一,由于OCT设备的光波多次前向和后向散射引起散斑噪声,斑点噪声的存在一般会模糊细微但重要的形态学细节,最终影响临床诊断。本文提出一种新的基于CNN的降噪网络,在对OCT图像进行降噪处理的同时,使得图像在保留空间结构细节的基础上能展示更多的信息,提高图像质量。方法:提出了一种基于改进的编码器 - 解码器(U-Net)分层网络的新型OCT图像降噪网络——DRS-Unet,加入由密集连接和局部残差连接组成的密集局部残差 块和极化注意力机制,并且在保留图像空间结构细节的基础上降低图像噪声。结果:实验表明,DRS-Unet 在客观评价指标方面要优于传统方法与其他深度学习方法,使用DRS-Unet对OCT图像进行降噪比其他深度学习降噪模型提高了2.7%左右,且拥有更强的边缘保持和泛化能力。证明该方法可以有效地保留OCT 图像中的边缘结构信息,同时可以有效地抑制噪声,提高图像质量。

#### 关键词

光学相干断层成像,图像降噪,编码器-解码器,注意力机制

# Research on De-Noising of OCT Retinal Images in Polarified U-Net

#### Tong Wu, Minghui Chen\*, Yalan Hu, Xudong Zhou, Wenfei Ma, Sisi Chen, Jiayu Li

Shanghai Engineering Research Center of Interventional Medical Device, School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Dec. 15<sup>th</sup>, 2024; accepted: Jan. 8<sup>th</sup>, 2025; published: Jan. 16<sup>th</sup>, 2025

\*通讯作者。

**文章引用:**吴桐,陈明惠,胡亚兰,周旭东,马文飞,陈思思,李家昱.分层极化注意力网络的 OCT 视网膜图像降噪研 究[J]. 建模与仿真, 2025, 14(1): 419-429. DOI: 10.12677/mos.2025.141039

### Abstract

OBJECTIVE: Optical coherence tomography (OCT) is one of the most commonly used methods in the diagnosis of retinal diseases, due to the scattering noise caused by multiple forward and backward scattering of light waves from the OCT device, the presence of speckle noise generally blurs subtle but important morphological details, which ultimately affects the clinical diagnosis. In this paper, a new CNN-based noise reduction network is proposed to improve the image quality by enabling the image to display more information while preserving the spatial structural details while performing noise reduction processing on OCT images. METHODS: A novel OCT image noise reduction network based on improved encoder-decoder (U-Net) hierarchical network, DRS-Unet, is proposed to incorporate a dense local residual block consisting of dense connections and local residual connections and a polarized attention mechanism, and to reduce the image noise based on the preservation of the spatial structural details of the image. CONCLUSION: Experiments show that DRS-Unet outperforms traditional methods and other deep learning methods in terms of objective evaluation indexes, and noise reduction of OCT images using DRS-Unet improves by about 2.7% compared with other deep learning noise reduction models, and possesses stronger edge preservation and generalization abilities. It has been proved that the method can effectively retain the edge structure information in OCT images, and at the same time, it can effectively suppress the noise and improve the image quality.

## **Keywords**

Optical Coherence Tomography, Image Denoising, Encoder-Decoder, Attentional Mechanism

Copyright © 2025 by author(s) and Hans Publishers Inc. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). http://creativecommons.org/licenses/by/4.0/

1. 引言

光学相干断层扫描(OCT)可以产生微米级分辨率的生物组织的横截面图像[1]。该方法近年来在临床 诊断方面取得飞速发展,现在已成为视网膜成像的重要工具。由于 OCT 设备的光波多次前向和后向散射 引起散斑噪声,斑点噪声的存在一般会模糊细微但重要的形态学细节,最终影响临床诊断。它还会降低 计算机后续的自动分析性能。尽管近二十年来光学相干断层扫描的成像分辨率、成像速度和成像深度都 有了很大的提高,但是散斑噪声作为成像的一个固有问题,一直影响着成像质量。商用扫描仪中最常见 的去斑方法是 B-scan 平均法。通过对从同一位置获取的多个配准的 B-scan 进行平均,可以获得高质量的 图像。然而,因为重叠的 B-scans 需要很长的采集时间,这种方法目前对于 3D 扫描是不切实际的。在本 文中重点关注另一类散斑抑制方法,它利用基于软件的图像处理算法来增强图像质量。

到目前为止,针对 OCT 图像降噪已经提出了大量的图像处理算法,大致可以分为几类,并且有一些 重叠:基于偏微分方程(PDE)的方法,如各向异性扩散滤波[2][3],基于块匹配的方法,如非局部均值(NLM) [4]或块匹配和 3D 滤波(BM3D)[5],基于小波的稀疏变换方法、连续曲边变换[6][7],或字典学习等方法 [8]。

OCT 图像降噪的主要目的是减少同质区域的颗粒外观,另一个重要问题是保留图像细节,特别是边缘,因为边缘是视觉检查和自动分析如分割、分类所需的最重要信息。由于光学相干断层扫描图像中的

散斑噪声,许多空间滤波器倾向于过度平滑图像,导致边缘对比度降低。基于块匹配的方法会由于不同 块中的边缘不一致而导致边缘失真。基于变换的方法也倾向于产生边缘附近具有变换基形状的伪影。近 年来,深度学习的卷积神经网络(CNN)为图像去噪提供了新思路。Mao 等[9]提出了具有对称跳跃连接的 深度卷积编解码网络(RED-Net)。Tai 等[10]提出了一种持久存储网络(Mem-Net)。张凯等[11]提出了深度 卷积神经网络(DnCNN)的残差学习用于自然图像去噪。该网络被设计成从噪声输入中预测残留图像。Liu 等人[12]提出了多层小波与深度学习结合的方法(MWCNN),将编码器 - 解码器(U-net) [13]结构和小波变 换应用到其模型中。虽然他们扩大了模型的接受范围,同时降低了计算复杂度,但他对小波变换的应用 会迫使它们的网络使用小波变换的特征信息,从而导致性能下降。代豪等[14]提出了一种基于模块化降噪 自编码器的渐进式 OCT 图像降噪方法。然而,在所有这些工作中,都使用了加性噪声假设,不能有效去 除 OCT 图像中的散斑噪声。

因此为了克服传统降噪方法的局限性,本文提出了一种新的基于 CNN 的降噪网络,对先前的单一下 采样的降噪卷积网络进行改进[15],添加了上采样的内容,将整个降噪网络改变成一个新的 U-Net 网络, 同时优化上采样模块,增加空间注意力机制模块,使其能更好地利用有限的存储空间,同时通过减少存 储特征地图信息的内存,使网络可以拥有更多的参数。本文将密集连接与残差连接应用到卷积块和网络 中,增强了网络的特征提取能力也缓解了梯度消失的问题,并且和经典算法与深度学习算法进行了比对, 验证了该方法的效果。

### 2. 网络模型方法与原理

随着深度学习研究开始应用图像处理,如何有效地利用有限的内存深化网络显得尤为重要。传统图像处理算法的解决方案之一是分层结构[16]。这种结构被用于众多图像处理研究,以降低算法的复杂度和内存消耗。对于 CNN 模型,Ronneberger 等人提出了 U-Net,它将层次结构的概念应用于 CNN 模型。U-Net 由两条路径组成:收缩路径和扩展路径。在收缩路径中,U-Net 使用步长为 2 的 2 × 2 卷积核进行最大池化将特征映射的大小减半,同时将特征映射的数量增加到两倍。因此,每个下采样步骤都会使 U-Net 要处理的特征图减半。它使 U-Net 能够使用比其他网络更多的参数。受 U-Net 的启发,本文提出的网络采用了层次化的结构,并在具体结构上做出了优化,提出基于空间注意力的密集残差连接分层去噪网络(Densely Residual-connected and Spatial attention U-Net, DRS-Unet),整体结构如图 1。

DRS-Unet 应用了改进的 U-Net 的分层结构。在收缩路径中,当输入图像进来时网络首先执行 1×1 卷积运算,然后是参数化整流线性单元(Parametric Rectified Linear Unit, PReLU)的激活层为本文所提出的密集局部残差块(Densely-connected Local-Residual Block, DLR Block)生成特征图,PReLU层是带可学习性参数的 ReLU层。这个初始卷积层使网络能够在 DLR 块中应用局部残差学习。如图 1 所示,初始卷积层为 DLR 块生成 64 个特征图。本文提出的网络的每一层中存在两个 DLR 块,下采样模块将经过两个 DLR 块的输出特征图下采样,对特征图进行下采样时会将输出特征图的数量增加一倍,以防止信息量严重减少。在扩张路径中,经过两个 DLR 块的操作之后,每个层次输出的特征图被上采样时,因为本文对上采样块应用了亚像素插值的方法[17],特征图的大小减少到四分之一,数量变为二分之一。为了防止特征图数量的严重减少,网络使用了在下采样特征图的信息,将下采样块的输出通过在跳跃路径上添加极化空间注意力机制模块(Polarized Filtering Attention Block, PFA Block)对特征图进行校准后连接到上采样块的输入,这样补足了右半部分的特征图数量。对于最底层,本文将上采样块的输入连接到下采样块的输出。在经过三层收缩与三层扩张路径后,通过 1×1 卷积和 PReLU 生成最终输出。并且本文将全局残差学习应用于提出的网络,通过将学习到的残差信息应用于输入图像来生成输出图像。其中实线箭头是特征图信息的直接叠加,虚线箭头是特征的融合。下面对各个模块进行具体介绍。



Figure 1. Architecture diagram of DRS-Unet 图 1. DRS-Unet 架构示意图

### 2.1. 密集连接与上下采样

随着 CNN 模型的深入,许多模型表现出的另一个问题是消失梯度问题,它造成了深层网络模型难以 训练的问题。为了解决这个问题,Huang [18]等人提出 ResNet 利用跳跃连接使网络能够学习残差函数解 决了梯度消失问题。DenseNet [19]与 ResNet 具有一定相似性,它通过前馈的方式将每一层与所有层连接 起来,让网络能重新利用先前的特征图信息。为了最大程度利用这两种网络,本文将跳跃连接与密集连 接进行组合形成 DLR Block。不同于一般的残差密集组合只采用直接相加的逻辑,本文将融合与相加一 起应用于模块中如图 2 所示,conv3 表示 3×3 卷积层,c表示特征图的数量。DLR 块由三个卷积层组成, 其后是 Prelu,通过融合使每次卷积的特征图数量增加 1/2c,又在最后一层回到 c 使得其也可使用局部残 差学习。最终本文改善了信息流通和解决了梯度消失问题,也强化了模型的学习能力。



Figure 2. Densely-connected local-residual block 图 2. 密集局部残差块

图 3 显示了下采样模块(Downsampling Block)的架构。下采样块由两层组成: 2×2 最大合并层和 3×3 卷积层, 然后是 PReLU。当特征图作为输入进入时,步长为2的2×2 最大池化操作会减小特征图的大小。然后, 3×3 卷积层将特征映射的数量加倍,以防止信息量的严重减少。因此,下采样块的输出特征

图的大小是输入特征图的四分之一,特征图的数量是输入特征图的两倍。



图 3. 下采样块

图 4 显示了上采样块(Upsampling Block)的架构。上采样块由两层组成,带 PReLU 的 3×3 卷积层和 亚像素内插值层,与使用 2×2 反卷积层的 U-Net 不同,本文采用亚像素插值层来更高效、更准确地扩展 特征图的大小。在亚像素内插层扩大特征图大小之前,3×3 卷积层对特征图进行细化,使亚像素插值层 能够准确地对特征图进行插值。因此,上采样块的输出特征图的大小是输入特征图的两倍,通道数是输入特征图的四分之一。



## 2.2. 空间极化注意力机制

目前,注意力机制主要分成两大类基于通道的和基于空间的[20],基于通道的注意力大部分与分类任 务相关,在本文中采用空间注意力机制,能突出图像的重要部分。本文中的空间注意力机制启发于极化 滤波(Polarized Filtering),只允许正交与横向的光通过,来提高对比度。它在一个方向上对特征进行压缩, 并让正交方向的维度保持高分辨率,再对损失的强度范围进行提高,本文的注意力机制类似光学透镜过 滤光一样,它会对它甄别到的重点区域的特征进行增强或削弱。具体结构如图 5 所示。



## **Figure 5.** Polarized filtering attention block 图 5. 空间极化注意力机制模块

极化注意力模块先采用  $1 \times 1$  卷积将输入的特征转换为 $W_q$ 和 $W_v$ , 再对 $W_q$ 的特征使用全局池化将其 在空间维度上被压缩,转换成了  $1 \times 1$ 的大小; 而 $W_v$ 特征的空间维度保持在 $H \times W$ , 一个比较大的水平。 然后再采用 Softmax 对被压缩的 $W_q$ 进行增强。然后将 $W_q$ 和 $W_v$ 进行矩阵乘法,这一步具体体现了极化滤 波的思想,滤波再增强。最后再与原始输入进行点乘完成整个注意力机制,同时也是完成了特征的再次 分配。具体权重公式如式下:

$$A^{sp}(X) = F_{SG}\left[\sigma_{3}\left(F_{SM}\left(\sigma_{1}\left(F_{GP}\left(W_{q}(X)\right)\right)\right) \times \sigma_{2}\left(W_{v}(X)\right)\right)\right]$$
(1)

X 是输入的特征图,经过标准 1×1 卷积层分成 $W_q$  和 $W_v$ ,  $\sigma_1$ 、 $\sigma_2$  和 $\sigma_3$  是三个张量整形算子,  $F_{GP}$  是 全局池化,  $F_{SM}$  是 Softmax 函数,  $F_{SG}$  是 Sigmoid 激活函数。最终通过注意力机制完成对整个模型的提升。

#### 3. 实验结果与分析

#### 3.1. 数据集及实验设置

运用本文方法对眼科的临床数据进行图像降噪处理。第一个数据集来自第四届 MICCAI 眼科医学图 像分析(OMIA)研讨会的开源数据集(https://retouch.grand-challenge.org/) [21]。数据集中可用的图像是使用 来自三个不同制造商的 OCT 成像设备获取的, Cirrus (Zeiss Meditec)进行 128 次 B 扫描、T-1000 和 T-2000 (Topcon)具有 128 次 B 扫描、Spectralis (Heidelberg Engineering)进行 49 次 B 扫描, 为数据集 1。数 据集 2 是由温州医科大学利用医用 OCT 设备采集的眼科视网膜图像的临床数据。

本文先对 OCT 数据集图片进行了初步的图像筛选与质量评估,去除其中伪影过多和有明显瑕疵的图像,最终筛选出训练集 1000 张、测试集 50 张图像。模型训练和测试实验之前对数据集中每张 OCT 图片进行预处理。载剪白色无关区域并把图片剪裁成合适的大小,保证 OCT 图片的主要特征信息,将所有训练集图像打乱顺序,进行随机翻转等操作再导入训练模型中。TensorFlow2.0 为本实验的开发框架,数据集的训练和测试在 Nvidia Tesla V100 GPU HPC 集群上进行,自适应矩估计为优化算法来训练该网络,设置训练时初始学习率为 0.001,训练得到的降噪网络模型,最后用客观图像质量指标峰值信噪比(Peak Signal to Noise Ratio, PSNR),结构相似性(Structural Similarity, SSIM)和边缘保持系数(Edge Preservation Index, EPI)评价其降噪性能。

$$PSNR = 10 * \log\left(\frac{255^2}{MSE}\right)$$
(2)

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \left\| I(i,j) - K(i,j) \right\|^2$$
(3)

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 - \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$
(4)

$$EPI = \frac{\sum_{i} \sum_{j} |\hat{I}(i+1,j) - \hat{I}(i,j)|}{\sum_{i} \sum_{j} |I(i+1,j) - I(i,j)|}$$
(5)

PSNR 是用来标定图像失真情况和噪声污染水平的一个客观标准,图像之间的 PSNR 越高则越相似。 均方差中 *I* 和 *K* 分别为原始图像和降噪后的图像,*m*\**n* 为图像的大小。SSIM 是用来描述图像相似度的客 观指标, $\mu_x$ 是降噪后图像 x 的平均值, $\mu_y$ 是原始图像 y 的平均值, $\sigma_x^2$ 是 x 的方差; $\sigma_y^2$ 是 y 的方差; $\sigma_{xv}$ 是 x 和 y 的协方差; $C_1$ 和  $C_2$ 是用来维持稳定的常数;EPI 越接近 1,图像边缘保持的越好。

#### 3.2. 降噪结果

本实验使用经典降噪算法 NLM、BM3D,深度学习算法 DnCNN、基于 Resnet 的方法和本文提出的 DRS-Unet 对 OCT 图像进行降噪处理,通过 EPI、PSNR 和 SSIM 评估以上五种算法对 OCT 图像降噪的

效果。由于散斑噪声是随机噪声,统计学上其加和为零,所以本文在原始图像中添加三种不同水平的均值为0,方差(Var)为0.006、0.008、0.01的散斑噪声,客观比较各个算法对含噪图片的降噪表现,实验结果如图6,表1~3。



(a) OCT 原始图像



(c) NLM



(b) 噪声图像(Var = 0.008)



(d) BM3D







(f) ResNet







模型	边缘保持系数 EPI	峰值信噪比 PSNR/dB	结构相似性 SSIM		
噪声图像	-	35.7	0.9698		
NLM	0.71	38.05	0.9473		
BM3D	0.77	37.68	0.9627		
ResNet	1.09	40.43	0.9865		
DnCNN	1.06	40.62	0.9873		
DRS-Unet	1.04	41.4	0.9928		

**Table 1.** Comparison of noise reduction performance of each model under the noise level of Var = 0.006 **表 1.** Var = 0.006 噪声水平下各模型降噪的性能比较

Table 2. Comparison of noise reduction performance of each model under the noise level of $Var = 0.003$	3
表 2. Var = 0.008 噪声水平下各方法降噪的性能比较	

模型	边缘保持系数 EPI	峰值信噪比 PSNR/dB	结构相似性 SSIM
噪声图像	-	34.46	0.9609
NLM	0.68	36.40	0.9300
BM3D	0.75	35.96	0.9564
ResNet	1.11	38.53	0.9825
DnCNN	1.09	38.75	0.9838
DRS-Unet	1.06	39.71	0.9896

**Table 3.** Comparison of noise reduction performance of each model under the noise level of Var = 0.010 **表 3.** Var = 0.01 噪声水平下各方法降噪的性能比较

模型	边缘保持系数 EPI	峰值信噪比 PSNR/dB	结构相似性 SSIM
噪声图像	-	33.49	0.9525
NLM	0.65	35.09	0.9123
BM3D	0.72	34.98	0.9249
ResNet	1.13	37.43	0.9784
DnCNN	1.12	37.23	0.9774
DRS-Unet	1.09	38.34	0.9851

在噪声方差为 0.008 噪声水平下从肉眼的直观效果上而言,相较其他算法,本文提出的 DRS-Unet 在 降低散斑噪声方面展现较好的图像品质,大大减少视网膜分层中的颗粒状分布的散斑噪声,同时视网膜 图像的分层信息和边缘结构特征也得到了保留。

在传统算法中,NLM、BM3D的降噪结果在图像视网膜分层和边界处都存在伪影,且都是通过减少 空间结构信息拉高图像质量。基于 Resnet、DnCNN 与 DRS-Unet 这三种方法在直观感受和客观评价上均 得到了比经典算法更好的效果,在图像分层结构处取得良好降噪效果,背景中也抑制了部分噪声。前两 种深度学习方法相比经典算法在客观参数指标上均有 8%的提升,DRS-Unet 又比 DnCNN 和基于 Resnet 的方法高了 2.7%左右。同时根据图 7 中的显示 DRS-Unet 在不同的噪声水平下都有较好的降噪表现,并 且随着噪声水平的增加它相较 DnCNN 等方法的优势也在变大,说明 DRS-Unet 拥有更强的泛化能力。



**Figure 7.** PSNR of each model after noise reduction at different noise levels 图 7. 不同噪声水平下各模型降噪后的 PSNR

为了客观的验证本方法的有效性,在第二个数据集中,我们对这五种方法进行验证,结果如表 4 所示,在相同噪声水平下,DRS-Unet 依然可以保持优势。证明在不同的数据集中,在 OCT 降噪方面 DRS-Unet 同样拥有更好的效能。

模型	边缘保持系数 EPI	峰值信噪比 PSNR/dB	结构相似性 SSIM
噪声图像	-	31.78	0.9731
NLM	0.72	34.05	0.9586
BM3D	0.78	33.49	0.9631
ResNet	1.15	35.87	0.9731
DnCNN	1.13	36.40	0.9753
DRS-Unet	1.10	37.20	0.9821

 Table 4. Comparison of the performance of each method for denoising in dataset 2

 表 4. 在数据集 2 中各方法降噪的性能比较

## 4. 结论

本研究提出的 DRS-Unet 网络是在基础的 U-Net 网络中添加密集连接和残差连接,并通过注意力机 制进一步加强了整个网络的噪声提取能力,最终实现了对视网膜图像的降噪。在实验中,将 DRS-Unet 与 经典算法和深度学习算法进行比对,通过客观图像质量指标 PSNR、SSIM 和 EPI 进行评估。结果显示, 在噪声方差为 0.008 噪声水平下, DRS-Unet 的 EPI、PSNR 和 SSIM 分别为 1.06、39.71、0.9896,与较优 的 DnCNN 算法相比,分别提高了 0.03、0.96、0.0058。DRS-Unet 在不同的噪声水平下都有较好的降噪表 现,并且随着噪声水平的增加,相较其他方法的优势也在变大,说明 DRS-Unet 拥有较强的边缘保持和泛 化能力。本文提出的 DRS-Unet 在降低散斑噪声方面展现较好的性能,应用在临床上,可以降低专业眼科 医生对患者眼科疾病的诊断难度,减少对患者的漏诊和误诊。

## 参考文献

- [1] Povazay, B., Bizheva, K., Unterhuber, A., Hermann, B., Sattmann, H., Fercher, A.F., *et al.* (2002) Submicrometer Axial Resolution Optical Coherence Tomography. *Optics Letters*, **27**, 1800-1802. <u>https://doi.org/10.1364/ol.27.001800</u>
- [2] Salinas, H.M. and Fernandez, D.C. (2007) Comparison of PDE-Based Nonlinear Diffusion Approaches for Image Enhancement and Denoising in Optical Coherence Tomography. *IEEE Transactions on Medical Imaging*, 26, 761-771. <u>https://doi.org/10.1109/tmi.2006.887375</u>
- [3] Puvanathasan, P. and Bizheva, K. (2009) Interval Type-II Fuzzy Anisotropic Diffusion Algorithm for Speckle Noise Reduction in Optical Coherence Tomography Images. *Optics Express*, **17**, 733-746. https://doi.org/10.1364/oe.17.000733
- [4] Aum, J., Kim, J. and Jeong, J. (2015) Effective Speckle Noise Suppression in Optical Coherence Tomography Images Using Nonlocal Means Denoising Filter with Double Gaussian Anisotropic Kernels. *Applied Optics*, 54, D43. https://doi.org/10.1364/ao.54.000d43
- [5] Zhang, X., Li, L., Zhu, F., Hou, W. and Chen, X. (2014) Spiking Cortical Model-Based Nonlocal Means Method for Speckle Reduction in Optical Coherence Tomography Images. *Journal of Biomedical Optics*, 19, Article 066005. https://doi.org/10.1117/1.jbo.19.6.066005
- [6] Zaki, F., Wang, Y., Su, H., Yuan, X. and Liu, X. (2017) Noise Adaptive Wavelet Thresholding for Speckle Noise Removal in Optical Coherence Tomography. *Biomedical Optics Express*, 8, 2720-2731. <u>https://doi.org/10.1364/boe.8.002720</u>
- [7] Kafieh, R., Rabbani, H. and Selesnick, I. (2015) Three Dimensional Data-Driven Multi Scale Atomic Representation of Optical Coherence Tomography. *IEEE Transactions on Medical Imaging*, 34, 1042-1062. <u>https://doi.org/10.1109/tmi.2014.2374354</u>
- [8] 吴广义, 袁卓群, 梁艳梅. 基于深度学习的视网膜 OCT 图像无监督去噪方法[J]. 光学学报, 2023, 43(20): 123-133.
- [9] Esmaeili, M., Dehnavi, A.M., Hajizadeh, F. and Rabbani, H. (2020) Three-Dimensional Curvelet-Based Dictionary Learning for Speckle Noise Removal of Optical Coherence Tomography. *Biomedical Optics Express*, **11**, 586-608. <u>https://doi.org/10.1364/boe.377021</u>
- [10] Mao, X., Shen, C. and Yang, Y.B. (2016) Image Restoration Using Very Deep Convolutional Encoder-Decoder Networks with Symmetric Skip Connections. *Advances in Neural Information Processing Systems*, 29, 2802-2810.
- [11] Tai, Y., Yang, J., Liu, X. and Xu, C. (2017) MemNet: A Persistent Memory Network for Image Restoration. 2017 IEEE International Conference on Computer Vision (ICCV), Venice, 22-29 October 2017, 4549-4557. https://doi.org/10.1109/iccv.2017.486
- [12] Zhang, K., Zuo, W., Chen, Y., Meng, D. and Zhang, L. (2017) Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Transactions on Image Processing*, 26, 3142-3155. https://doi.org/10.1109/tip.2017.2662206
- [13] Liu, P., Zhang, H., Zhang, K., Lin, L. and Zuo, W. (2018) Multi-Level Wavelet-CNN for Image Restoration. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Salt Lake City, 18-22 June 2018, 886-88609. <u>https://doi.org/10.1109/cvprw.2018.00121</u>
- [14] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention—MICCAI* 2015, Munich, 5-9 October 2015, 234-241. <u>https://doi.org/10.1007/978-3-319-24574-4\_28</u>
- [15] 代豪,杨亚良,岳献,等.基于模块化降噪自编码器的视网膜 OCT 图像降噪方法[J].光学学报,2023,43(1):58-65.
- [16] 周旭东,陈明惠,马文飞,等. 多尺度条件卷积的 OCT 视网膜图像降噪研究[J]. 光学技术, 2022, 48(1): 102.
- [17] Jeon, B.-W., Lee, G.-I., Lee, S.-H. and Park, R.-H. (2003) Coarse-to-Fine Frame Interpolation for Frame Rate Up-Conversion Using Pyramid Structure. *IEEE Transactions on Consumer Electronics*, **49**, 499-508. <u>https://doi.org/10.1109/tce.2003.1233761</u>
- [18] Shi, W., Caballero, J., Huszar, F., Totz, J., Aitken, A.P., Bishop, R., et al. (2016) Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 27-30 June 2016, 1874-1883. https://doi.org/10.1109/cvpr.2016.207
- [19] He, K., Zhang, X., Ren, S. and Sun, J. (2016) Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 27-30 June 2016, 770-778. https://doi.org/10.1109/cvpr.2016.90
- [20] Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K.Q. (2017) Densely Connected Convolutional Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, 21-26 July 2017, 2261-2269.

https://doi.org/10.1109/cvpr.2017.243

[21] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. Computer Vision— ECCV 2018, Munich, 8-14 September 2018, 3-19. <u>https://doi.org/10.1007/978-3-030-01234-2\_1</u>