

## 基于深度学习的视网膜 OCT 图像的疾病自动分类

邹 突<sup>1,2</sup>, 曹婷婷<sup>2</sup>, 张国坚<sup>2</sup>, 钱陆佳<sup>2</sup>, 林 林<sup>2,3</sup>

1. 广州市老人院医务部, 广东广州 510900

2. 广东医科大学生物医学工程学院, 广东东莞 523808

3. 东莞市医学电子与医学影像设备重点实验室, 广东东莞 523808

**摘要:** **目的** 实现视网膜疾病光学相干断层扫描图像(OCT)的自动化分类。**方法** 整合公开数据集和临床医院收集的视网膜OCT图像,构建包含3类视网膜疾病的标准化数据集:正常(Normal)、息肉样脉络膜血管病变(PCV)和糖尿病黄斑水肿(DME)。对图像进行系统性预处理,包括数据规范化、分类标签筛查和数据增强,随后系统评估并比较了6种主流卷积神经网络(VGG、ResNet、DenseNet、MobileNet、EfficientNet和Inception)的分类性能。**结果** VGG16模型实现了98.92%的准确率;ResNet50和ResNet50\_V2均实现了99.79%的准确率,但ResNet50的精度和召回率均稍微优于ResNet50\_V2;Densenet121的准确率为99.94%,精度为99.90%,召回率为99.95%,F1分数为0.999 2,均高于其他经典卷积神经网络模型;EfficientNetB0、EfficientNetV2S、MobileNetV1、MobileNetV2、MobileNetV3和Inception\_V3的准确率分别为99.75%、99.83%、99.72%、99.85%、99.43%和99.35%。**结论** Densenet121模型在视网膜OCT图像自动化分类中性能最优异,实现了对视网膜OCT图像的高效准确诊断。

**关键词:** 视网膜疾病; 光学相干断层; 深度学习; 图像分类

**DOI:** 10.20227/j.cnki.2096-3610.2025.03.002

### Automated disease classification in retinal OCT images using deep learning

ZOU Tu<sup>1,2</sup>, CAO Tingting<sup>2</sup>, ZHANG Guojian<sup>2</sup>, QIAN Lujia<sup>2</sup>, LIN Lin<sup>2,3</sup>

1. Medical Department of Guangzhou Nursing Home, Guangzhou 510900, China

2. School of Biomedical Engineering, Guangdong Medical University, Dongguan 523808, China

3. Key Laboratory of Medical Electronics and Medical Imaging Equipment, Dongguan 523808, China

**Abstract:** **Objective** To develop an automated classification system for retinal diseases using optical coherence tomography (OCT) images. **Methods** A standardized dataset was constructed from both public repositories and clinical hospitals, comprising OCT images categorized into three classes: Normal, Polypoidal Choroidal Vasculopathy (PCV), and Diabetic Macular Edema (DME). Systematic preprocessing steps including data normalization, label verification, and augmentation were applied. Six convolutional neural network (CNN) architectures (VGG, ResNet, DenseNet, MobileNet, EfficientNet, Inception) were rigorously evaluated for classification performance. **Results** The VGG16 model achieved an accuracy of 98.92%, while ResNet50 and ResNet50\_V2 attained 99.79%. Notably, ResNet50 exhibited marginally superior precision and recall compared to ResNet50\_V2. DenseNet121 outperformed all other models, achieving an accuracy of 99.94%, precision of 99.90%, recall of 99.95%, and an F1-score of 0.999 2. Among EfficientNet variants, EfficientNetB0 and EfficientNetV2S reached accuracies of 99.75% and 99.83%, respectively. MobileNetV2 achieved the highest accuracy (99.85%) within its variants, followed by MobileNetV1 (99.72%) and MobileNetV3 (99.43%). Inception\_V3 yielded an accuracy of 99.35%. **Conclusion** DenseNet121 demonstrates optimal performance for automated retinal OCT image classification, offering high accuracy and diagnostic efficiency for clinical applications.

**Key words:** retinal diseases; optical coherence tomography; deep learning; image classification

收稿日期: 2024-12-05

基金项目: 广东省自然科学基金(2014A030310258), 东莞市企业特派员项目(20231800500312), 松山湖医工融合创新专项项目(4SG22318P)

作者简介: 邹 突, 工程师, E-mail: tuzou\_zt@163.com

通信作者: 林 林, 博士, 教授, E-mail: linlin\_bme@gdmu.edu.cn

息肉状脉络膜血管病变(PCV)<sup>[1-2]</sup>与糖尿病黄斑水肿(DME)<sup>[3-4]</sup>是两种具有高致盲风险的视网膜疾病。PCV好发于亚洲老年人群,其特征性表现为脉络膜层异常血管增生;DME则属于糖尿病视网膜微血管并发症,其发病机制与慢性高血糖诱导的血-视网膜屏障破坏密切相关,最终导致视网膜液体积聚和进行性视力下降。由于这两种疾病均可造成不可逆性视功能损伤,建立高效筛查体系并实现早期精准诊断已成为当前眼健康管理的重要课题。目前眼科疾病的诊断可分为传统医学诊断和人工智能辅助诊断<sup>[5-6]</sup>。其中,传统医学诊断准确性受限于影像设备和临床医生经验,在基层医疗机构和资源匮乏地区中的应用面临挑战。而人工智能因眼部影像易获取性,展现出显著优势<sup>[7]</sup>。深度学习作为人工智能的重要组成部分,其通过卷积神经网络(CNN)分析数据特征,为疾病诊断提供了新思路<sup>[8-9]</sup>。视网膜早期病变可以通过光学相干断层扫描(OCT)观察,病变特征可在图像中得到反映<sup>[10]</sup>。例如, Schlegl等<sup>[11]</sup>开发的OCT图像自动分析方法,对黄斑水肿的定量准确率达0.94。Shih等<sup>[12]</sup>采用两种方法对常见的4种眼科视网膜疾病OCT图像进行图像分类,实验结果表明,各种组合均可达到99.48%的准确率。尽管Schlegl和Shih等团队的研究在特定数据集上取得了较高的诊断准确率<sup>[11-12]</sup>,但这些模型在临床实际应用中仍面临显著挑战:(1)泛化能力受限,由于训练数据来源单一,模型在跨设备、跨人群验证时可能出现性能下降;(2)可解释性不足,其决策过程缺乏透明性,难以满足临床医生对诊断依据的需求;(3)性能仍有提升空间,特别是在灵敏度和特异性方面需进一步优化<sup>[13-14]</sup>。这些局限性表明,深度学习模型仍需改进,以推动人工智能在眼科诊疗中的规模化临床应用。

## 1 数据集和方法

### 1.1 数据集与主要仪器

数据集来自2021年全球人工智能系列挑战赛

之亚太眼科学会大数据竞赛获取的公开数据集<sup>[15]</sup>和深圳市宝安区人民医院眼科室不断累积而来的眼睛视网膜OCT数据集,本研究已通过医院的伦理审查。主要仪器是光学相干断层扫描仪,基于低相干干涉术<sup>[16-17]</sup>,可进行在体眼组织显微结构的高清晰的断层成像。从竞赛获取的数据图像,已经有经验丰富的医生进行分类并打好标签,包含本研究所需的数据Normal图像、DME图像<sup>[18-19]</sup>和PCV图像<sup>[20-22]</sup>。所有图像均经过去标识化处理,确保不包含患者的个人信息,如姓名、性别和年龄等。3种眼睛视网膜OCT图像如图1所示,图1A为Normal的视网膜OCT图像,通过图像可以清晰地看出视网膜中心凹和每一层的纹理;图1B为PCV的视网膜OCT图像,其主要表现为视网膜色素上皮(RPE)层呈现像单个“拱桥”一样的突起和所谓的“双层征”(红色矩形区域部分);图1C为DME的视网膜OCT图像,其通常表现为视网膜厚度发生变化(增厚隆起)、视网膜内部存在液体聚集以及视网膜浅层部分有多个硬性渗出物,在OCT图像上以白色亮点状呈现(黄色矩形区域部分)。所有图像分辨率统一为265×172像素。

### 1.2 图像预处理

1.2.1 图像规范化 两种不同渠道获得的眼睛视网膜OCT图像有所不同(图2),需要进一步进行规范化处理。从原始数据图像可以看出,本研究所需的图像区域为右侧区域部分(图1)。同时,临床医院和亚太眼科竞赛的图像在图像生成和显示上灰度值相反。因此在进行训练前,需要将所有的原始数据集进行处理,采用自动分割(固定尺寸裁剪)的方法以及图像灰度值反转的方法,灰度值反转由以下方法计算:

$$I_{\text{new}} = 255 - I_{\text{original}}$$

1.2.2 图像筛查 而非经过所有以上处理后的视网膜OCT图像均能被用于训练,仍需要进一步进行人工筛查,在拍摄时眼睛有轻微运动而在图像上



图1 Normal、PCV和DME的视网膜OCT图像  
A、B、C分别为Normal、PCV和DME的视网膜OCT图像。

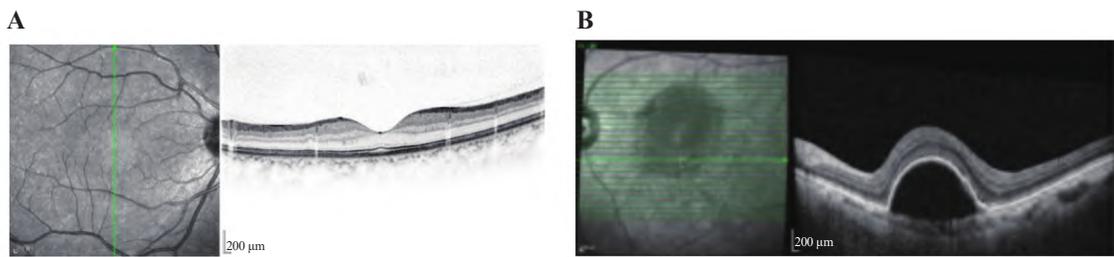


图2 原始数据集样例

A. 临床数据图像;B. 亚太眼科竞赛图像。

出现重影现象,如图 3A 红色标注区域所示。图 3B 中黄色标注区域(指外层视网膜结构)与图 1A 对比可见,因拍摄时焦距调节失准,仅拍摄视网膜外层结构信息。此类图像因无法完整呈现视网膜病变区域特征,不符合分类标准要求,建议予以删除。

**1.2.3 数据增强** 由于 CNN 的鲁棒性依赖大量数据,本研究采用水平镜像翻转增强样本多样性。数据的不足会导致模型训练时出现过拟合问题,导致模型不具备良好的泛化性,也就不具有实际应用价值。本研究对筛选后的视网膜 OCT 图像进行水平镜像翻转处理,不仅达到了数据扩充的目的,更符合实际人体不同侧眼睛拍摄出来视网膜 OCT 图像的目的。

收集的 3 种疾病的病例数分别为 929 例(3 303 张 Normal 视网膜 OCT 图像)、436 例(1 367 张 PCV 视网膜 OCT 图像)和 844 例(2 841 张 DME 视网膜 OCT 图像)。对视网膜 OCT 图像实施了切割、灰度值反转、筛查以及数据增强等一系列处理操作后,获取到了有统一规格的数据集,同时为这些数据集赋予了相应的标签,最终所得到的结果是 Normal 类型的视网膜 OCT 图像数量为 6 310 张,PCV 类型的视网膜 OCT 图像数量为 2 584 张,DME 类型的视网膜 OCT 图像数量为 5 068 张,这 3 种类型的图像数量总计为 13 962 张。

### 1.3 网络架构

**1.3.1 基础卷积神经网络结构** 卷积神经网络作为一种被应用于图像处理领域的深度学习模型,其

核心优势在于有自动提取多尺度特征的能力<sup>[23]</sup>,典型的卷积神经网络结构包含 3 个关键组件,其中卷积层凭借利用局部感受野来提取图像特征,池化层则可实现特征降维,最终借助 softmax 函数完成分类决策。

**1.3.2 自注意力机制模块改进** 在深度学习范畴内,自注意力机制<sup>[24-27]</sup>可依靠动态计算特质间的依赖关系,提高模型对全局以及局部信息的捕获能力,在此次针对视网膜 OCT 图像的研究里,PCV 的息肉状病灶或许与远离中心的位置存在某种关联,自注意力机制可直接构建起这种跨区域的联系。黄斑区水肿的细微变化也可凭借注意力权重得以放大。

### 1.4 模型训练机制

在实验中为了对比不同模型的性能,对模型训练时的超参数进行标准化。训练过程中的梯度优化算法均采用 Adam 算法,学习率设置为 0.001,训练轮次为 10,选择交叉熵作为损失函数,同时均增加自注意力机制来优化模型。整个网络的模型训练流程如图 4 所示。

### 1.5 评价指标

在开展实验设计工作时,运用了严谨的随机 3 分类数据策略。训练集(占 80%,11 170 张):用于模型参数学习;验证集(占 10%,1 396 张):优化超参数,判断是否提前终止训练,通过准确率、召回率等指标多维度监控模型性能;测试集(占 10%,1 396 张):全程隔离于训练流程,仅用于最终评估模型泛化能

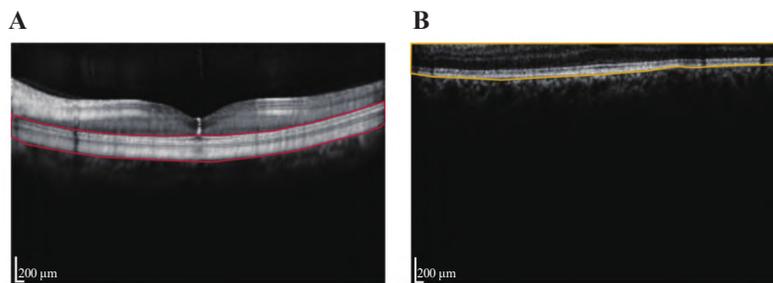


图3 没有分类价值的图像示例

A. 重影现象;B. 图像特征缺失示意图。

力。模型训练时仅通过训练集更新梯度,每轮训练结束后通过验证集监控优化方向。测试集数据始终保持不可见状态。

模型在测试集的准确率、精度、召回率、F1分数等指标可用于衡量模型的识别性能。真阳性:实际为正样本且被模型正确判定为正样本的实例;真阴性:实际为负样本且被模型正确判定为负样本的实例;假阳性:实际为负样本但被模型误判为正样本的实例(即误报);假阴性:实际为正样本但被模型误判为负样本的实例(即漏报)。准确率等指标可由如下方法计算:

$$\text{准确率} = \frac{\text{真阳性} + \text{真阴性}}{\text{真阳性} + \text{真阴性} + \text{假阳性} + \text{假阴性}} \times 100\%$$

$$\text{精度} = \frac{\text{真阳性}}{\text{真阳性} + \text{假阳性}} \times 100\%$$

$$\text{召回率} = \frac{\text{真阳性}}{\text{真阳性} + \text{假阴性}} \times 100\%$$

$$\begin{aligned} \text{F1分数} &= \frac{2 \times \text{精度} \times \text{召回率}}{\text{精度} + \text{召回率}} \times 100\% \\ &= \frac{2 \times \text{真阳性}}{2 \times \text{真阳性} + \text{假阳性} + \text{假阴性}} \times 100\% \end{aligned}$$

## 2 结果

### 2.1 模型对比

通过对比实验评估多种卷积神经网络模型,包括VGG、ResNet、DenseNet、MobileNet、EfficientNet、

Inception模型。Densenet121的准确率为99.94%,精度为99.90%,召回率为99.95%,分数为0.999 2(表1)。

### 2.2 类别对比

基于1 396张涵盖Normal、DME和PCV的视网膜OCT图像测试集,采用混淆矩阵评估DenseNet121模型的性能(表2、图5)。如表2对比结果显示,该模型对正常视网膜样本分类准确率为100.00%(631/631),模型对两类病变样本的鉴别存在0.07%(1/1 396)的误分类率,其表现为1例DME图像样本被误判为PCV。尽管如此,99.94%的整体正确分类率仍优于对比模型(表2),证实DenseNet121在医学图像分析中的适用性。

### 2.3 模型性能分析

为了对DenseNet121模型的训练进程展开评估,绘制了训练集以及验证集的准确率随着训练轮次而产生变化的曲线(图6),训练集的准确率曲线与验证集的准确率曲线都呈现出一种稳定收敛的态势,最终训练集的准确率达到99.96%,验证集的准确率达到99.94%,表明模型在训练过程中未出现过拟合,99.94%的验证集准确率进一步验证了其泛化性能。

## 3 讨论

DenseNet是一种深度学习架构<sup>[28]</sup>,主要解决传统卷积神经网络里梯度消失以及计算效率方面的问题,DenseBlock是DenseNet架构的关键部分,由

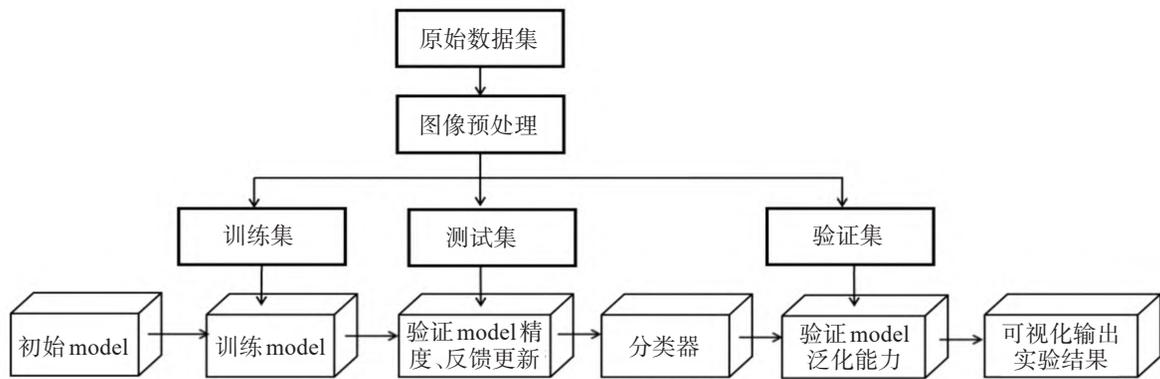


图4 模型训练流程图

表1 卷积神经网络模型对比结果

卷积神经网络	准确率(%)	精度(%)	召回率(%)	F1分数	卷积神经网络	准确率(%)	精度(%)	召回率(%)	F1分数
VGG16	98.92	98.67	98.84	0.987 5	EfficientNetV2S	99.83	99.85	99.70	0.997 7
ResNet50	99.79	99.80	99.78	0.997 9	MobileNetV1	99.72	99.70	99.61	0.996 5
ResNet50_V2	99.79	99.72	99.75	0.997 3	MobileNetV2	99.85	99.83	99.83	0.998 3
DenseNet121	99.94	99.90	99.95	0.999 2	MobileNetV3	99.43	99.38	99.06	0.992 2
EfficientNetB0	99.75	99.78	99.57	0.996 7	Inception_V3	99.35	99.30	99.14	0.992 2

表 2 混淆矩阵

类别	预测类别			精度 (%)	召回率 (%)	F1 分数
	DME	Normal	PCV			
真实类别 DME	506	0	1	100.00	99.80	0.999 0
真实类别 Normal	0	631	0	100.00	100.00	1.000 0
真实类别 PCV	0	0	258	99.61	100.00	0.998 0

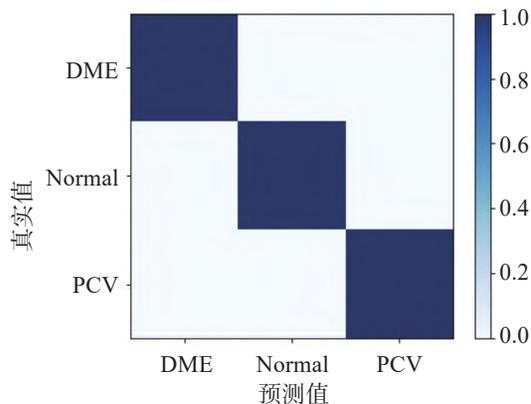


图 5 DenseNet121 模型的混淆矩阵

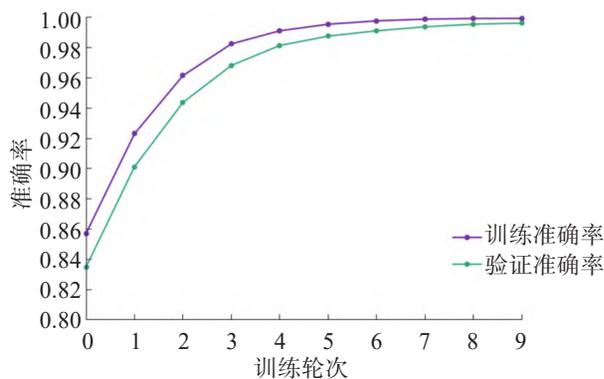


图 6 DenseNet121 模型的学习曲线

多个卷积层紧密堆积构成,每一层都和之前所有层的输出进行整合,这种架构推动了特征信息在网络里的持续积累,对特征传递以及整体网络效能起到优化作用。在 OCT 图像分类任务当中,密集连接机制可有效整合视网膜不同层次的局部特征与全局特征,比如底层网络可捕捉 PCV 病变里“双层征”的细微纹理差别,高层网络则凭借累积的多尺度特征识别 DME 的视网膜内液体聚集区域,和传统 CNN 的链式连接相比,传统 CNN 在逐层传递时容易丢失细粒度特征,DenseNet 的密集拓扑结构更契合医学图像中病灶位置多变、特征尺度差异十分突出的特性,也是本研究中 DenseNet121 模型达到 99.94% 准确率的优势所在。

基于 DenseNet121 的上述优势,本研究将其应用于 OCT 图像分类任务,以构建自动化诊断系统,

以辅助医生完成门诊初步筛查(如区别 Normal、PCV 和 DME)。诊断技术的信息化是新时期生物医学工程领域的重要研究内容<sup>[9,29]</sup>,相对于 Shih 等<sup>[12]</sup>采用的 ResNet18 结构简单,对复杂特征提取能力较弱,而本研究采用的 ResNet50 和 ResNet50\_V2 在面对复杂任务或大数据集上,比 ResNet18 更加具备优势。同时,本研究预先训练模型包括 VGG、ResNet、DenseNet、MobileNet、EfficientNet、Inception 等 11 种模型,更多的模型覆盖能够增强结果的可靠性,也能够更系统地评估不同架构在目标任务上的性能差异。对比各网络对不同类别分类的精确率、召回率、特异性以及准确率,判断各网络的分类性能,其中 DenseNet121 网络在 6 种网络中表现出较好的性能,准确率能够达到 99.94%。最后对 DenseNet121 网络模型通过可视化的混淆矩阵直观的分析网络的分类性能和模型的学习曲线验证该模型的泛化能力。

本研究虽在 DenseNet121 网络算法上得到准确率高达 99.94%,在各项评价指标中表现良好,但为了适应现实临床的多样性和复杂性,因此下一步研究的计划为:(1)在后续的工作中可以多增加几类常见的视网膜疾病,例如脉络膜新生血管和玻璃膜疣,这些都均有很大的临床研究意义。(2)本研究针对的是单一病变图像分类,即在 OCT 图像中表示的是唯一病变,当多种病变同时存在于一张 OCT 图像时,人工智能辅助诊断容易将病变区域较小的或特征不明显的病变忽略,因此开发多病变共存场景的识别算法,提升模型对复杂病例的诊断能力是后续的研究方向<sup>[30-31]</sup>。

参考文献:

[1] KENICHIRO S, KANJI T, HARUHIKO Y, et al. Polypoidal choroidal vasculopathy: incidence, demographic features, and clinical characteristics[J]. Arch Ophthalmol, 2003, 121 (10): 1392-1396.  
 [2] GEMMY C C M. Macular neovascularization and polypoidal choroidal vasculopathy: phenotypic variations, pathogenic mechanisms and implications in management[J]. Eye (Lond), 2023, 38(4): 659-667.  
 [3] OUM L, ZDEK E, ENG U, et al. Optical coherence tomo-

- graphic assessment of diabetic macular edema: comparison with fluorescein angiographic and clinical findings[J]. *Ophthalmologica*, 2005, 219(2): 86-92.
- [4] GLASSMAN A R, BECK R W, BROWNING D J, et al. Comparison of optical coherence tomography in diabetic macular edema, with and without reading center manual grading from a clinical trials perspective[J]. *Invest Ophthalmol Vis Sci*, 2009, 50(2): 560-566.
- [5] SHEN D, WU G, SUK H I. Deep learning in medical image analysis[J]. *Annu Rev Biomed Eng*, 2017, 19(1): 221-248.
- [6] LITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis[J]. *Med Image Anal*, 2017, 42: 60-88.
- [7] LIN D R, WU X H, LIU Z Z. Discipline advantage of medical artificial intelligence in ophthalmology research[J]. *Chin J New Clin Med*, 2020, 13(2): 127-129.
- [8] AWAIS M, MULLER H, TANG T B, et al. Classification of sd-oct images using a deep learning approach[C]//In 2017 IEEE international conference on signal and image processing applications (ICSIPA). IEEE, 2017: 489-492.
- [9] FAUW J D, LEDSAM J R, ROMERA-PAREDES B, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease[J]. *Nat Med*, 2018, 24(9): 1342-1350.
- [10] YU H M, ZHANG X M. Application of choroidal thickness measured by optical coherence tomography in diagnosis and treatment of ocular diseases[J]. *Med Recapitul*, 2019, 25(3): 583-587.
- [11] SCHLEGL T, WALDSTEIN S M, BOGUNOVIC H, et al. Fully automated detection and quantification of macular fluid in OCT using deep learning[J]. *Ophthalmology*, 2018, 125(4): 549-558.
- [12] SHIH F Y, PATEL H. Deep learning classification on optical coherence tomography retina images[J]. *Int J Pattern Recognit Artif Intell*, 2020, 34(8): 59-68.
- [13] 王诗惠, 郝晓凤, 谢立科. 人工智能在视网膜疾病中应用的研究现状与展望[J]. *中华眼科医学杂志(电子版)*, 2020, 10(6): 321-326.
- [14] ESTEVA A, CHOU K, YEUNG S, et al. Deep learning-enabled medical computer vision[J]. *NPJ Digit Med*, 2021, 4(1): 5.
- [15] 阿里云天池. 2021 亚太眼科学会大数据竞赛赛题与数据[EB/OL]. (2021-03-15)[2023-05-01]. <https://tianchi.aliyun.com/competition/entrance/531929/information>.
- [16] HUANG D, SWANSON E A, LIN C P, et al. Optical coherence tomography[J]. *Science*, 1991, 254(5035): 1178-1181.
- [17] FERCHER A F, DREXLER W, HITZENBERGER C K, et al. Optical coherence tomography-principles and applications[J]. *Rep Prog Phys*, 2003, 66(2): 239.
- [18] GULSHAN V, PENG L, CORAM M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs[J]. *JAMA*, 2016, 316(22): 2402-2410.
- [19] LI X, SHEN L, WANG M, et al. Deep learning-based classification of diabetic macular edema using optical coherence tomography images[J]. *IEEE J Biomed Health Inform*, 2021, 25(6): 2184-2192.
- [20] KLEPININA O B, VOLODIN P L, KOLESNIK A I. The multimodal approach to the diagnosis and assessment of the effectiveness of the treatment of polypoid choroidal vasculopathy[J]. *Vestn Oftalmol*, 2020, 136(5): 348-349.
- [21] 刘洋, 陈晓峰, 赵静. 多模态眼科影像融合技术在息肉样脉络膜血管病变诊断中的应用[J]. *中国医学影像技术*, 2022, 38(3): 456-460.
- [22] WANG Y, ZHANG H, LIU J, et al. Multi-scale feature fusion network for polypoidal choroidal vasculopathy segmentation in OCT images[J]. *Med Image Anal*, 2022, 80: 102486.
- [23] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. *Neural Netw*, 2015, 61: 85-117.
- [24] SHEN Z, ZHANG M, ZHAO H, et al. Efficient attention: attention with linear complexities[C]//In 2021 IEEE winter conference on applications of computer vision (WACV). IEEE, 2021: 357-366.
- [25] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Adv Neural Inf Process Syst*, 2017, 30: 5998-6008.
- [26] ALENEZI A M, ALOQALAA D A, SINGH S K, et al. Multiscale attention-over-attention network for retinal disease recognition in OCT radiology images[J]. *Front Med*, 2024, 11: 1499393.
- [27] WANG K, XU C, LI G, et al. Combining convolutional neural networks and self-attention for fundus diseases identification[J]. *Sci Rep*, 2023, 13(1): 76.
- [28] HUANG G, LIU Z, LAURENS V D M, et al. Densely connected convolutional networks[C]//In 2017 IEEE conference on computer vision and pattern recognition (CVPR). IEEE, 2017: 2261-2269.
- [29] WALLIS C. How artificial intelligence will change medicine[J]. *Sci Am*, 2020, 322(2): 28-35.
- [30] KEENAN T D, PENG Y, CHEN Q, et al. Real-world validation of artificial intelligence algorithms for ophthalmic imaging: current status and perspectives[J]. *Surv Ophthalmol*, 2023, 68(1): 1-11.
- [31] TING D S W, PENG L, VARADARAJAN A V, et al. Deep learning in ophthalmology: the technical and clinical considerations[J]. *Prog Retin Eye Res*, 2019, 72: 100759.

(责任编辑:李阳飞)