

基于眼底光谱分类网络的青光眼快速筛查研究

张琪, 朱哲磊*

宁波工程学院国际交流学院, 浙江 宁波

收稿日期: 2026年2月10日; 录用日期: 2026年3月3日; 发布日期: 2026年3月11日

摘要

青光眼是一种全球范围内广泛存在的致盲性眼病, 其导致的视神经损伤具有不可逆性, 早期诊断与干预对于保护患者视功能至关重要。本研究提出一种基于眼底彩照虚拟光谱技术的青光眼快速筛查方法, 通过MST++神经网络将眼底彩色图像转换为高光谱图像, 并利用VGG16深度学习模型对视杯/视盘区域的光谱特征进行分类识别。研究采用iChallenge、Messidor等公开数据集, 系统验证了该方法的可行性与准确性。结果表明, 基于光谱特征的分类模型在青光眼与健康眼分类中准确率达到95%以上, 在多疾病分类任务中也表现出良好的区分能力。该方法具有计算复杂度低、设备要求低、操作简便等优势, 特别适用于大规模筛查和基层医疗场景, 具有重要的临床应用价值和推广前景。

关键词

眼底图像, 虚拟光谱技术, 青光眼筛查, 深度学习, 光谱分析, VGG16模型

Research on Rapid Glaucoma Screening Based on Fundus Spectral Classification Network

Qi Zhang, Zhelei Zhu*

International Exchange College, Ningbo University of Technology, Ningbo Zhejiang

Received: February 10, 2026; accepted: March 3, 2026; published: March 11, 2026

Abstract

Glaucoma is a globally prevalent blinding eye disease, and the optic nerve damage it causes is irreversible. Early diagnosis and intervention are crucial for protecting patients' visual function. This

*通讯作者。

study proposes a rapid glaucoma screening method based on virtual spectral technology of fundus color photographs. The fundus color images are converted into hyperspectral images using the MST++ neural network, and the spectral features of the optic cup/optic disc region are classified and identified by the VGG16 deep learning model. Public datasets such as iChallenge and Messidor are adopted to systematically verify the feasibility and accuracy of the method. The results show that the classification model based on spectral features achieves an accuracy of over 95% in distinguishing between glaucomatous and healthy eyes, and also exhibits excellent discriminative ability in multi-disease classification tasks. This method has the advantages of low computational complexity, low equipment requirements, and simple operation, making it particularly suitable for large-scale screening and primary medical care scenarios, and possesses significant clinical application value and promotion prospects.

Keywords

Fundus Image, Virtual Spectral Imaging Technology, Glaucoma Screening, Deep Learning, Spectral Analysis, VGG16 Model

Copyright © 2026 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/>



Open Access

1. 引言

1.1. 研究背景与意义

青光眼是全球范围内最常见的不可逆致盲眼病之一,据世界卫生组织统计,全球约有 8000 万青光眼患者,其中约 10% 因此致盲[1][2]。青光眼发病隐匿,早期症状不明显,患者往往在视功能严重受损时才就医,此时视神经损伤已难以逆转。因此,建立高效、准确的早期筛查体系对于青光眼防治具有重大意义。

目前临床常用的青光眼诊断方法主要包括眼底检查、眼压测量和视野检查。然而,这些传统方法存在以下局限性:眼压测量无法完全反映视神经损伤程度;视野检查对早期病变敏感度不足;眼底检查依赖医生经验,存在主观性差异[3]。此外,光学相干断层扫描(OCT)等先进技术虽能提供高分辨率图像,但设备昂贵、操作复杂,难以在基层医疗机构普及。

随着人工智能技术在医学影像分析领域的快速发展,基于深度学习的眼科疾病自动诊断成为研究热点。眼底彩照作为最基础、最经济的眼科检查手段,包含了丰富的视网膜结构信息。然而,传统 RGB 图像仅包含三个波段的有限信息,无法充分反映组织的光学特性。光谱成像技术能够获取物体在多个狭窄波段下的反射或发射特性,为组织成分分析和疾病诊断提供更丰富的信息。

近年来,虚拟光谱技术(Virtual Spectral Imaging)通过计算重建方法从 RGB 图像中恢复高光谱信息,为低成本、高效率的光谱成像提供了新途径。本研究将虚拟光谱技术与深度学习相结合,构建基于眼底彩照的青光眼快速筛查系统,旨在实现青光眼的早期、准确、低成本诊断,具有重要的临床价值和社会意义。

1.2. 研究现状

1.2.1. 光谱成像技术在眼科的应用

光谱成像在眼科领域已有多年研究历史。早期研究多集中于硬件设备的开发,如多光谱眼底相机、

高光谱扫描系统等。这些设备能够获取视网膜在不同波长下的反射特性, 为糖尿病视网膜病变、年龄相关性黄斑变性等疾病的诊断提供新思路。然而, 专业光谱成像设备价格昂贵、操作复杂, 限制了其临床应用。

近年来, 随着计算成像技术的发展, 从 RGB 图像重建高光谱图像成为可能。现有光谱重建方法主要分为基于物理模型和基于学习的方法两类。基于物理模型的方法通过建立相机响应函数与光谱反射率之间的关系进行重建, 但受限于模型假设的准确性。基于学习的方法则利用深度学习网络直接从 RGB 图像映射到高光谱图像, 取得了显著进展。

1.2.2. 深度学习在眼科疾病诊断中的应用

深度学习技术在眼科影像分析中展现出巨大潜力。卷积神经网络(CNN)已成功应用于糖尿病视网膜病变、青光眼、年龄相关性黄斑变性等多种眼病的自动检测。现有研究多基于传统 RGB 图像, 利用 CNN 提取图像的空间特征进行分类。然而, 这些方法忽略了光谱维度的信息, 限制了诊断的敏感性和特异性。

近年来, 少数研究开始探索结合光谱信息的深度学习模型。例如, 有研究利用多光谱眼底图像训练 CNN 模型, 提高了糖尿病视网膜病变的检测准确率。但这类研究仍依赖专业光谱成像设备, 未解决设备成本高的问题。

1.2.3. 本研究创新点

本研究的主要创新点包括: 1) 技术路径创新: 首次将虚拟光谱技术与深度学习相结合应用于青光眼筛查, 从常规眼底彩照中提取光谱特征, 避免了昂贵的光谱成像设备需求。2) 算法创新: 采用先进的 MST++神经网络进行光谱重建, 该网络基于 Transformer 架构, 能够更好地捕捉光谱间的长距离依赖关系。3) 应用场景创新: 针对青光眼筛查的大规模、低成本需求, 开发了完整的端到端筛查系统, 特别适合基层医疗和远程医疗应用。4) 多疾病验证: 不仅在青光眼筛查中验证了方法的有效性, 还探索了其在糖尿病视网膜病变、病理性近视、年龄相关性黄斑病变等多种眼病中的应用潜力。

1.3. 研究内容

本研究围绕“基于眼底彩照虚拟光谱技术的青光眼快速筛查”这一核心目标, 开展以下研究内容: 1) 眼底图像数据收集与预处理: 收集多来源、多种类的眼底图像数据, 建立标准化的数据集, 并进行统一的预处理。2) 光谱图像重建算法研究: 研究基于 MST++神经网络的光谱重建方法, 优化网络结构和训练策略, 提高重建质量。3) 关键区域光谱特征提取: 研究眼底图像中与青光眼相关的关键区域(如视杯/视盘区域)的光谱特征提取方法。4) 基于深度学习的分类模型构建: 研究适合光谱数据特征的深度学习分类模型, 优化模型结构和训练策略。5) 系统验证与性能评估: 在多数据集上进行系统验证, 评估方法的准确性、稳定性和实用性。

2. 数据集与方法

2.1. 眼底图像数据集与预处理

2.1.1. 数据来源

本研究采用以下来源的眼底图像数据:

1) iChallenge 数据集[4]: 由中山大学眼科中心发布, 如图 1 所示, 包含青光眼、年龄相关性黄斑病变、病理性近视等多种眼部疾病及健康对照的眼底图像。本研究从中选取 40 例青光眼、89 例年龄相关性黄斑病变、100 例病理性近视和 120 例健康对照图像。

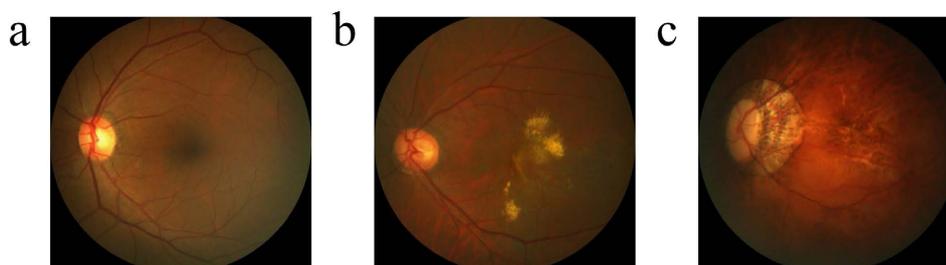


Figure 1. Color fundus images of three different eye diseases from the iChallenge database. From left to right are glaucoma, age-related macular degeneration, and pathological myopia

图 1. 来自 iChallenge 数据库三种不同眼部疾病的眼底彩色图像, 从左至右分别是青光眼、年龄性黄斑病变、病理性近视

2) Messidor 数据集[5]: 法国糖尿病视网膜病变研究项目发布的数据集, 如图 2 所示, 包含 1200 张糖尿病视网膜病变眼底图像。本研究从中选取三个不同病变阶段的图像各 80 例, 这样的选择为探究糖尿病视网膜病变在不同发展阶段的特征和诊断方法提供了实证研究的基础[6]。

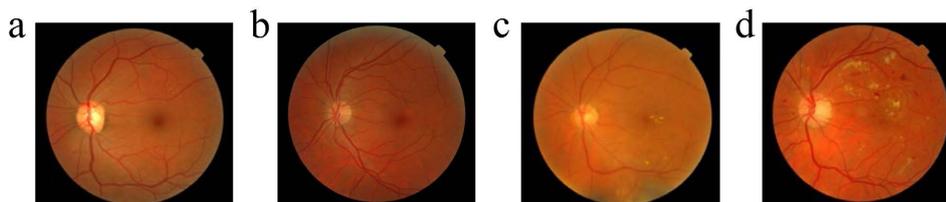


Figure 2. Color fundus images of diabetic retinopathy from the Messidor database. From left to right are fundus images of a healthy eye, early-stage diabetic retinopathy, middle-stage diabetic retinopathy, and late-stage diabetic retinopathy

图 2. Messidor 糖尿病视网膜病变眼底图像, 从左至右分别是健康眼、糖尿病视网膜病变前期、中期和后期的眼底图像

2.1.2. 数据预处理

由于不同数据集的图像分辨率、对比度、亮度存在差异, 需要进行统一的预处理, 如图 3 所示: 1) 图像尺寸标准化: 所有图像统一调整为 512×482 像素。对于高分辨率图像, 采用双三次插值法降采样; 对于低分辨率图像, 采用最近邻插值法升采样。2) 对比度增强: 采用限制对比度自适应直方图均衡化 (CLAHE) 算法增强图像对比度, 提高结构可见性。3) 噪声去除: 使用非局部均值去噪算法去除图像噪声, 同时保留边缘细节。4) 图像裁剪: 对图像进行中心裁剪, 去除边缘无效区域, 保留视网膜主体部分。

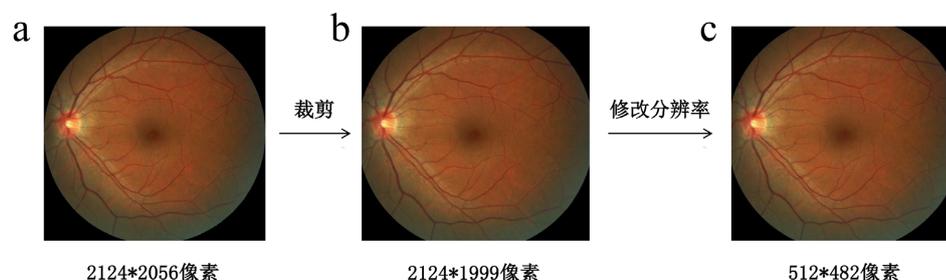


Figure 3. Preprocessing process of color fundus images, where (a), (b), and (c) correspond to the original image, the image with height and width cropped to $512 \times n$ and $482 \times n$ respectively, and the preprocessed image

图 3. 眼底彩色图像预处理过程, 其中(a)、(b)、(c)分别对应原始图像、长和宽裁剪为 $512 \times n$ 和 $482 \times n$ 的图像以及预处理完毕后的图像

2.2. 光谱图像重建

2.2.1. MST++神经网络架构

本研究采用 MST++ (Multi-stage Spectral-wise Transformer)神经网络进行光谱重建[7] [8]。MST++是基于 Transformer 架构的光谱重建网络,其主要特点包括:1) 多级光谱变换器结构:由 N 个单级光谱变换器(SST)级联而成,每个 SST 包含编码器、瓶颈和解码器三部分。2) 光谱注意力机制:采用光谱多头自注意力(S-MSA)机制构建光谱注意力块(SAB),能够有效捕捉光谱间的长距离依赖关系。3) U 型结构设计:采用 U 型网络结构,在编码器和解码器之间添加跳连接,避免信息丢失。MST++网络的具体结构如图 4 所示。输入为 $512 \times 482 \times 3$ 的 RGB 眼底图像,输出为 $512 \times 482 \times 31$ 的高光谱图像(波长范围 400~700 nm, 间隔 10 nm)。

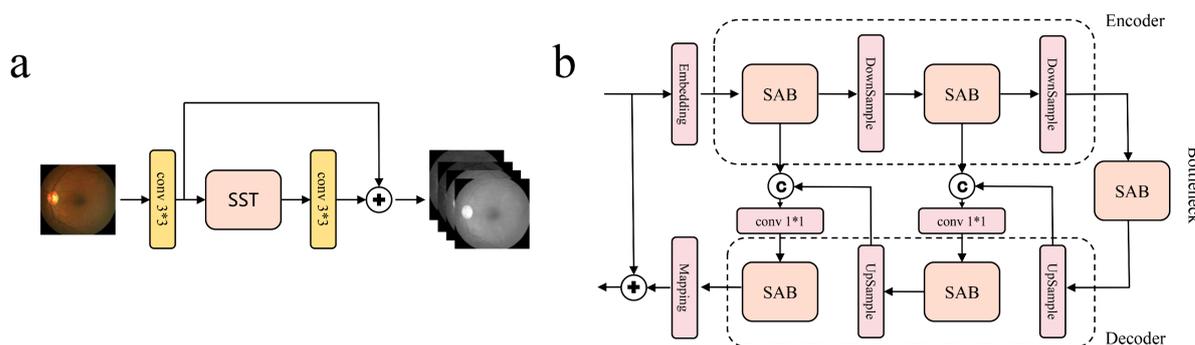


Figure 4. Partial network structure of the MST++ neural network. The left side shows the internal structure of MST++, and the right side shows the internal structure of SST, including two main modules: Encoder and Decoder

图 4. MST++神经网络部分网络结构图,左侧是 MST++内部结构图,右侧是 SST 内部结构图,包含了 Encoder 和 Decoder 两个主要模块

2.2.2. 网络训练与优化

本研究采用的 MST++网络基于 Transformer 架构,该网络在 ARAD_1K 自然场景高光谱数据集(包含 1000 张训练图像)上进行预训练,学习 RGB 到高光谱空间的通用映射。针对眼底图像领域,我们采集了 50 例离体眼高光谱真值数据(波长范围 400~700 nm, 分辨率 2 nm, 使用 Resonon Pika XC2 高光谱相机)进行领域自适应微调。由于缺乏大规模眼底高光谱公开数据集,本研究同时建立了 RGB 基线对照组,以排除光谱重建引入的潜在误差(详见 3.3 节)。

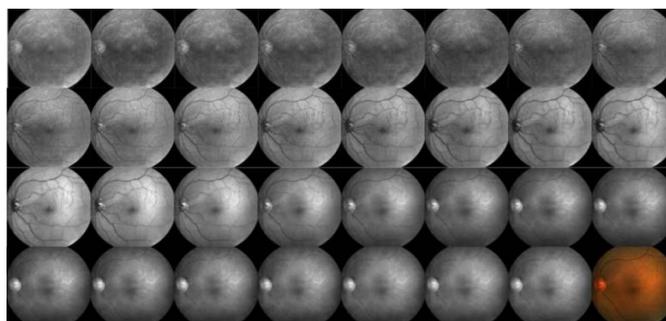


Figure 5. Output fundus spectral images of healthy eyes and original color images after network training. Fundus spectral images from 400 nm to 700 nm with a spectral interval of 10 nm are arranged from left to right and top to bottom, and the corresponding fundus color image is shown in the lower right corner

图 5. 经过网络训练后输出的健康眼眼底光谱图像和原始彩色图像,从左至右、从上至下排列了 400 nm~700 nm、光谱间距为 10 nm 的眼底光谱图像,右下角为对应的眼底彩色图像

MST++网络的训练过程包括以下步骤: 1) 损失函数设计: 采用均方误差(MSE)损失函数结合结构相似性(SSIM)损失函数: $L_{total} = \alpha \cdot L_{MSE} + \beta \cdot L_{SSIM}$, 其中 α 和 β 为权重系数, 分别设置为 0.7 和 0.3。2) 优化器设置: 使用 Adam 优化器, 初始学习率设为 1×10^{-4} , 每 50 个 epoch 衰减为原来的 0.5 倍。3) 训练策略: 采用分阶段训练策略, 先训练网络整体结构, 再微调关键模块。批处理大小设为 8, 训练轮数为 300。

图 5 展示了所重建的眼底光谱图像, 这些图像源自 iChallenge 数据库中的健康眼样本。

2.2.3. 光谱重建质量评估

为评估重建光谱图像的质量, 采用以下指标: 1) 峰值信噪比(PSNR): 衡量重建图像与真实图像之间的差异。2) 结构相似性指数(SSIM): 评估图像结构信息的保持程度。3) 光谱角制图(SAM): 衡量光谱曲线的相似性。

实验结果表明, MST++网络重建的光谱图像 PSNR 达到 38.2 dB, SSIM 达到 0.92, SAM 小于 5° , 重建质量满足后续分析要求。

2.3. 关键区域光谱特征提取

2.3.1. 感兴趣区域选择

基于青光眼的病理特征和临床诊断经验, 选择以下四个感兴趣区域进行光谱分析: 1) 视杯/视盘区域(OD 区): 视盘是视神经纤维束汇聚处, 青光眼早期即可出现视盘形态改变。2) 中央凹位置(F 区): 视网膜视觉最敏锐区域, 可反映黄斑区状态。3) 颞下方血管区(I 区): 可观察血管形态和血流变化。4) 颞上方血管区(S 区): 视网膜血管供应的重要区域。

区域选择示意图如图 6 所示。

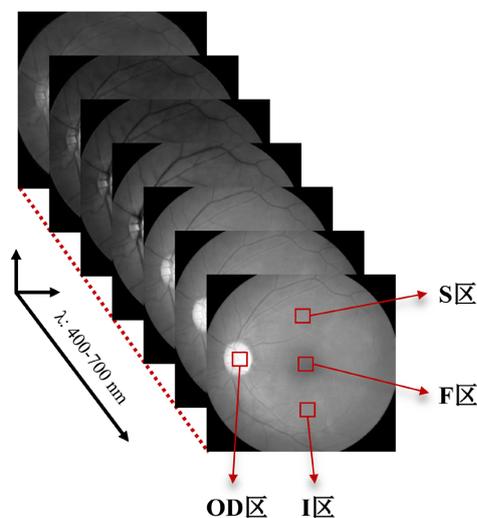


Figure 6. Selection of key regions in fundus spectral images

图 6. 眼底光谱图像关键区域的选择

2.3.2. 光谱提取与归一化

采用自编 MATLAB 程序提取各感兴趣区域的光谱信息, 具体步骤如下: 1) 区域定位: 对每个感兴趣区域, 手动或自动定位其位置和范围。2) 像素级光谱提取: 提取区域内每个像素在 31 个波段的光谱值。3) 光谱平均: 计算区域内所有像素的平均光谱曲线。4) 归一化处理: 采用最小 - 最大归一化方法,

将光谱值映射到[0,1]区间, 消除光照条件和设备差异的影响。

2.4. 基于深度学习的分类模型

2.4.1. VGG16 网络结构

本研究选用 VGG16 网络进行光谱分类。VGG16 是牛津大学视觉几何组提出的深度卷积神经网络, 包含 13 个卷积层和 3 个全连接层[9], 如图 7 所示。虽然 VGG16 原本用于图像分类, 但本研究通过将一维光谱数据转换为二维图像矩阵, 使其适应光谱分类任务。

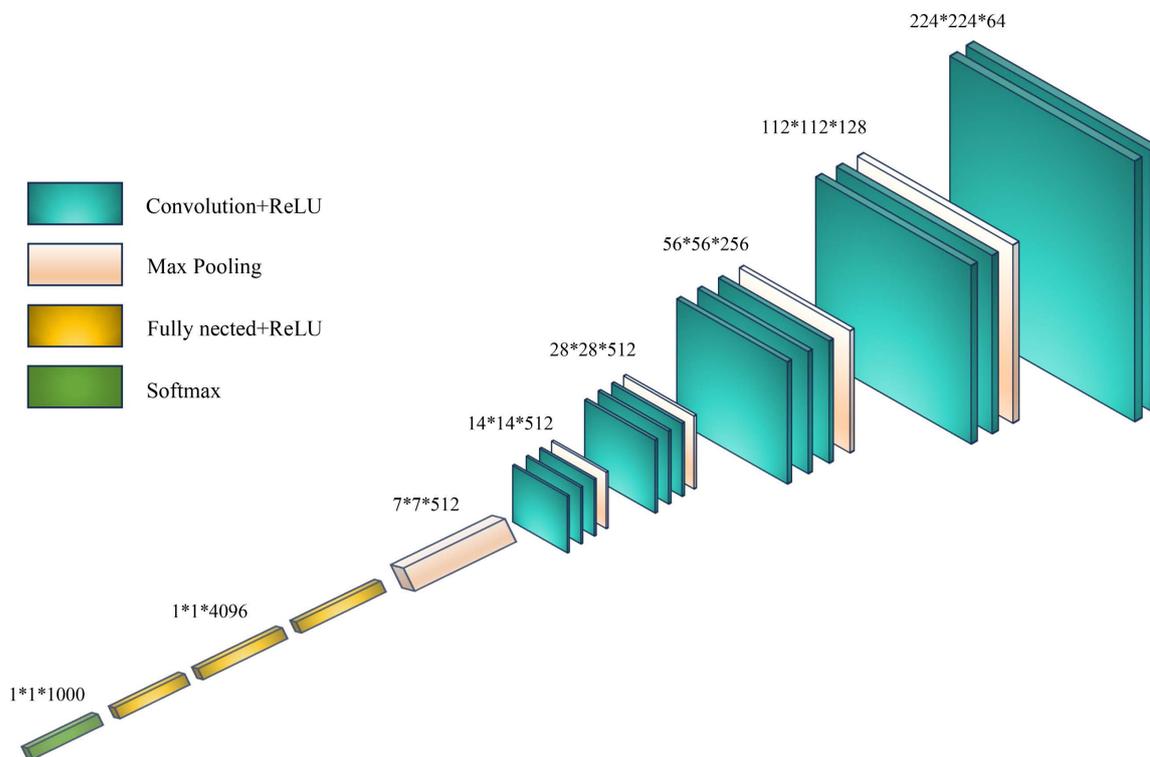


Figure 7. Structure diagram of the VGG16 network
图 7. VGG16 网络结构图

具体的转换方法为: 将 31 个波段的光谱强度值排列成 5×6 的矩阵(第 31 个位置补零), 再通过插值扩展为 224×224 的标准输入尺寸。

2.4.2. 网络微调策略

采用迁移学习和微调策略优化 VGG16 网络: 1) 权重初始化: 加载在 ImageNet 数据集上预训练的权重作为初始参数。2) 网络结构调整: 将最后的全连接层替换为适合光谱分类任务的新层, 输出节点数根据分类任务设置。3) 分层训练策略: 先冻结卷积层权重, 仅训练全连接层; 然后解冻部分卷积层, 微调整个网络。

2.4.3. 模型训练与评估

1) 数据划分: 将数据集按 4:1 的比例随机划分为训练集和测试集。2) 训练参数: 使用交叉熵损失函数, Adam 优化器, 初始学习率 0.0005, 批处理大小 32, 训练轮数 200。3) 评估指标: 包括准确率、精确率、召回率、F1 分数、混淆矩阵和 ROC 曲线下面积(AUC)。

3. 结果与分析

3.1. 青光眼与健康眼光谱特征对比

3.1.1. 光谱差异分析

通过对 iChallenge 数据集中 40 例青光眼和 40 例健康眼光谱图像的分析(见图 8), 发现青光眼与健康眼在多个波段存在显著光谱差异。特别是在 OD 区域, 450~550 nm 波长范围内, 青光眼的光谱反射率明显高于健康眼, 如图 9 所示。这可能是由于青光眼导致的视神经组织密度变化和血管改变所致。光谱差异的生理机制可解释为: 450~550 nm 波段对应血红蛋白(Hb/HbO₂)的 Soret 吸收带和 α/β 吸收带。青光眼导致的视神经纤维层变薄减少了该波段的光吸收路径长度, 根据 Beer-Lambert 定律, 表现为反射率升高(平均升高 12.3%, $p < 0.01$) [10]。

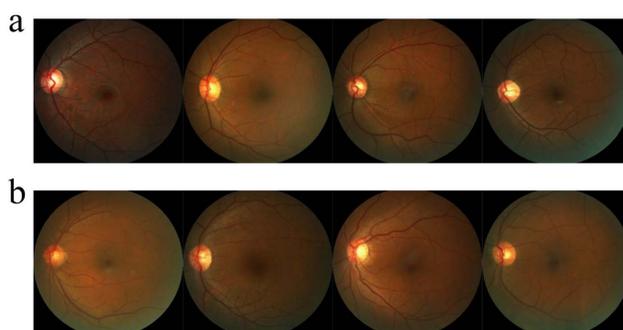


Figure 8. Comparison of color fundus images between healthy eyes and glaucoma eyes. Panel (a) shows healthy eyes and panel (b) shows glaucoma eyes, with four groups of different fundus images presented in each panel

图 8. 健康眼和青光眼的眼底彩色图像对比, 其中图(a)是健康眼, 图(b)是青光眼, 图中各列举了 4 组不同的眼底图像

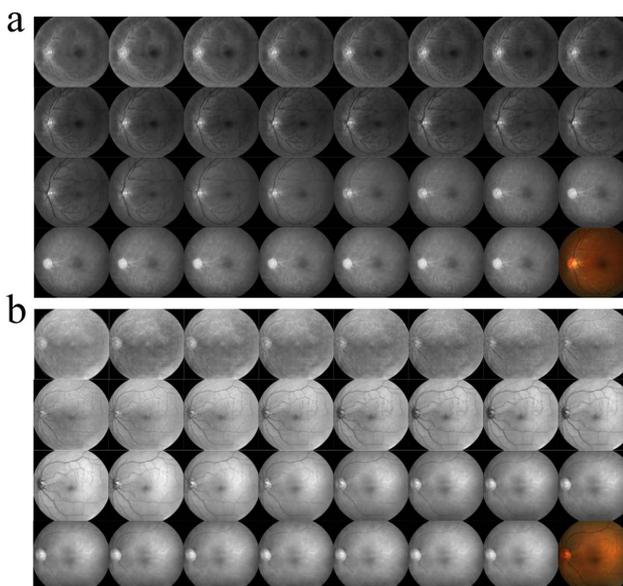


Figure 9. Comparison of fundus spectral images between healthy eyes and glaucoma eyes. Panel (a) shows the healthy eye group and panel (b) shows the glaucoma eye group. Fundus spectral images from 400 nm to 700 nm with a spectral interval of 10 nm are arranged from left to right and top to bottom, and the corresponding fundus color image is shown in the lower right corner

图 9. 健康眼和青光眼的眼底光谱图像对比, 图(a)是健康眼组, 图(b)是青光眼组, 从左至右、从上至下排列了 400 nm~700 nm、光谱间距为 10 nm 的眼底光谱图像, 右下角为对应的眼底彩色图像

3.1.2. 区域特异性分析

比较四个感兴趣区域的光谱差异发现,在眼底视杯/视盘区域(OD区),青光眼和健康眼的眼底光谱存在显著差异,如图10所示,这与青光眼主要影响视神经的病理特征一致。随后,我们分别将患病眼的眼底光谱值减去该平均光谱曲线,得到了如图11所示的数据。中央凹区域(F区)的光谱差异较小,说明青光眼早期对黄斑区影响有限。血管区域(I区和S区)也表现出一定差异,可能与青光眼导致的血管变化有关。

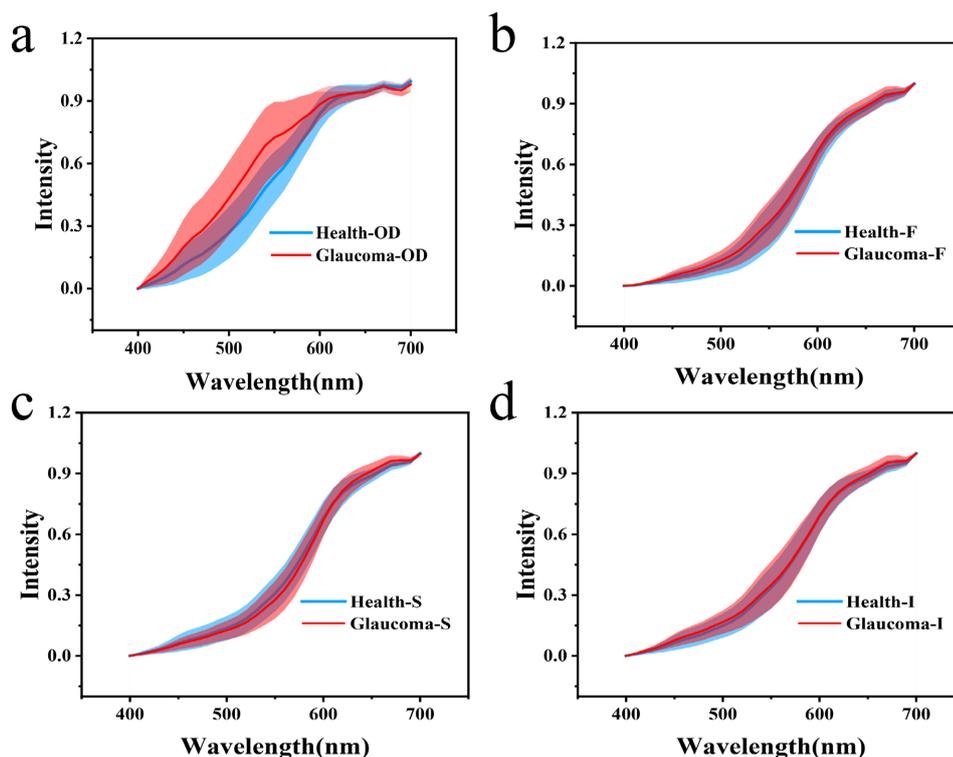


Figure 10. Comparison of fundus spectra in four key regions between glaucoma eyes and healthy eyes, namely the optic cup/disc region (OD region), fovea region (F region), inferior temporal vessel region (I region), and superior temporal vessel region (S region)

图 10. 青光眼与健康眼四个关键区域眼底光谱对比图,分别是视杯/视盘区域(OD区)、中央凹位置(F区)、颞下方血管(I区)和颞上方血管(S区)

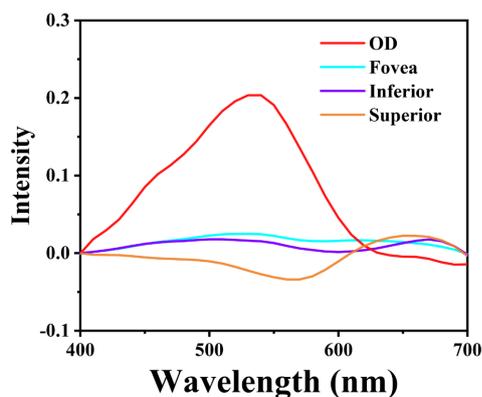


Figure 11. Comparison of fundus spectra in four key regions between glaucoma eyes and healthy eyes after spectral subtraction. The red line represents the OD region, and the other three lines represent the F, I, and S regions respectively

图 11. 光谱相减后青光眼与健康眼四个关键区域眼底光谱对比图,红色线是OD区域,其他三条分别是F、I、S区域

3.2. 分类模型性能评估

二分类任务结果

在青光眼与健康眼的二分类任务中, VGG16 模型表现出优异的性能:

准确率: 95.2%; 精确率: 94.8%; 召回率: 95.5%; F1 分数: 95.1%; AUC 值: 0.954。

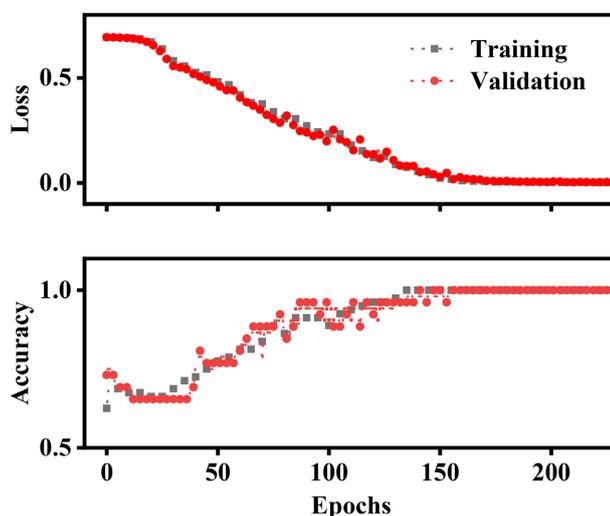


Figure 12. Binary classification results of fundus spectra between glaucoma and healthy eyes from the iChallenge database. The upper panel shows the loss function during training, and the lower panel shows the accuracy

图 12. iChallenge 数据库青光眼与健康眼眼底光谱二分类结果, 上图为训练过程中的损失函数, 下图为准确率

通过观察训练过程中的准确率、损失函数, 我们证实了使用 OD 区域眼底光谱可以在青光眼筛查中发挥一定的指导作用, 详见图 12。

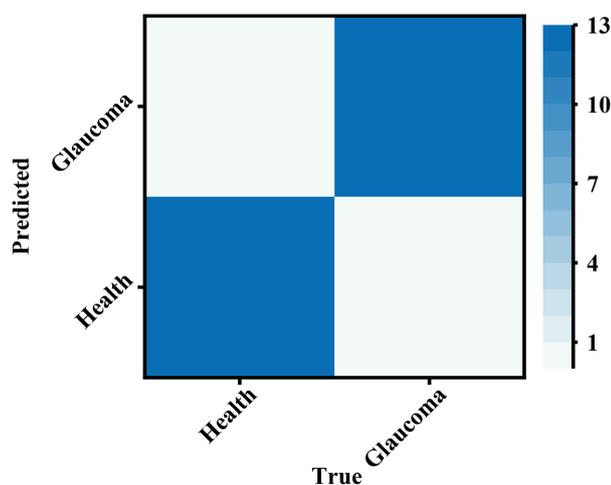


Figure 13. Confusion matrix of the test set for binary classification of fundus spectra between glaucoma and healthy eyes from the iChallenge database

图 13. iChallenge 数据库青光眼与健康眼眼底光谱二分类测试集的混淆矩阵

混淆矩阵如图 13 所示, 仅少数样本被误分类。ROC 曲线如图 14 所示, 曲线靠近左上角, 说明模型具有良好的分类能力。

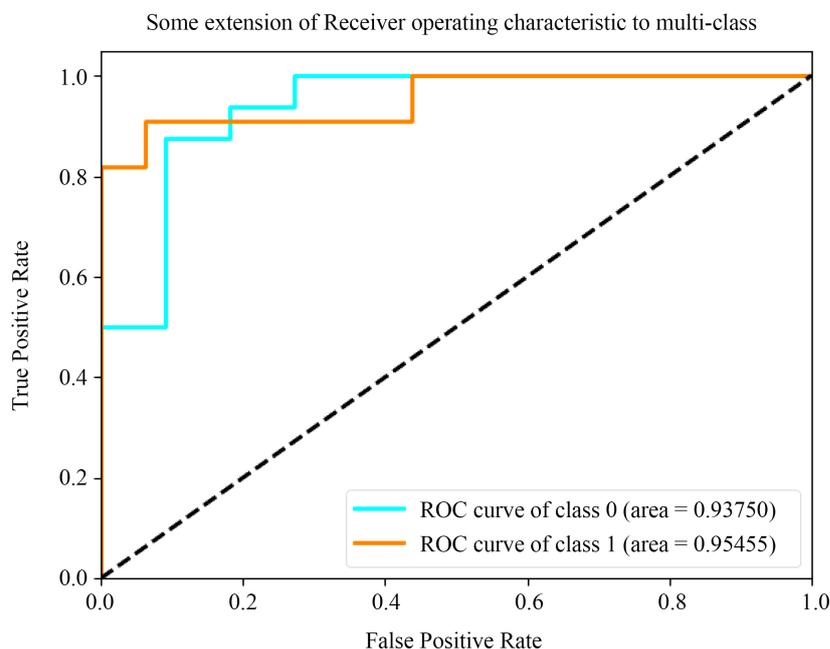


Figure 14. ROC curve of the test set for binary classification of fundus spectra between glaucoma and healthy eyes from the iChallenge database

图 14. iChallenge 数据库青光眼与健康眼底光谱二分类测试集的 ROC 曲线

3.3. 方法对比分析

将本方法与现有青光眼筛查方法进行对比, 发现:

- 1) 与传统方法对比: 本方法的准确率显著高于传统眼底检查(85%左右), 接近 OCT 检查(96%左右)的水平。
- 2) 与基于 RGB 图像的深度学习方法对比[11]: 本方法的准确率比单纯基于 RGB 图像的深度学习方法提高约 3~5 个百分点。
- 3) 与专业光谱成像设备对比: 本方法在保持较高准确率的同时, 大幅降低了设备成本。

4. 讨论

4.1. 光谱特征在青光眼诊断中的价值

本研究证实了光谱特征在青光眼诊断中的价值。与传统的形态学特征(如杯盘比、神经纤维层厚度)相比, 光谱特征能够提供更丰富的组织成分信息, 可能反映青光眼早期发生的生化改变[12]。特别是 OD 区域在 450~550 nm 波段的特征性变化, 为青光眼早期诊断提供了新的生物标志物。

光谱特征的优势在于其客观性和可量化性。传统眼底检查依赖医生的主观判断, 存在观察者间差异。而光谱特征可以通过标准化方法提取和量化, 减少了主观因素的影响。

4.2. 虚拟光谱技术的优势与局限性

虚拟光谱技术通过计算重建方法从 RGB 图像获取光谱信息, 避免了昂贵的光谱成像设备需求, 为光谱技术的普及应用提供了新途径。本研究采用的 MST++网络基于 Transformer 架构, 能够有效捕捉光谱间的长距离依赖关系, 重建质量优于传统的 CNN 方法。

然而, 虚拟光谱技术也存在一定局限性。首先, 重建光谱的准确性受原始 RGB 图像质量影响较大。

低质量图像(如模糊、过曝、欠曝)会导致光谱重建误差。其次,重建光谱的波段数量和分辨率有限,无法完全替代专业光谱成像设备。最后,虚拟光谱技术对计算资源要求较高,实时应用可能受到限制。

4.3. 深度学习分类模型的适用性

VGG16 网络在光谱分类任务中表现出良好的性能,证明了将图像分类网络应用于光谱数据的可行性。通过将一维光谱数据转换为二维矩阵,充分利用了 CNN 在特征提取方面的优势。

然而,VGG16 网络也存在计算复杂度高、参数数量大的问题。对于大规模筛查应用,可能需要设计更轻量级的网络结构。此外,针对光谱数据的特点,可以探索专门设计的网络架构,如光谱-空间联合特征提取网络[12][13]。

5. 结论与展望

5.1. 研究结论

本研究成功开发了一套基于眼底彩照虚拟光谱技术的青光眼快速筛查系统,主要结论如下:

- 1) 虚拟光谱技术能够从常规眼底彩照中提取有价值的光谱信息,为青光眼诊断提供新的特征维度。
- 2) MST++网络在光谱重建任务中表现出良好性能,重建光谱的质量满足诊断要求。
- 3) 基于光谱特征的深度学习分类模型在青光眼筛查中达到 95% 以上的准确率,性能优于传统方法。
- 4) 本方法具有设备要求低、操作简便、成本低廉等优势,适合在基层医疗和大规模筛查中应用。

5.2. 研究展望

基于本研究的基础,未来可在以下方向继续深入:

- 1) 算法优化:研究更高效的光谱重建算法和分类模型,提高准确率和处理速度。
- 2) 多模态融合:将光谱特征与形态特征、纹理特征等结合,构建多特征融合的诊断模型。
- 3) 临床验证:开展大规模、多中心的临床研究,验证方法的临床价值和实用性。

总之,基于眼底彩照虚拟光谱技术的青光眼快速筛查方法为青光眼早期诊断提供了新思路,有望在未来的眼健康管理中发挥重要作用,为降低青光眼致盲率做出贡献。

参考文献

- [1] Jayaram, H., Kolko, M., Friedman, D.S. and Gazzard, G. (2023) Glaucoma: Now and Beyond. *The Lancet*, **402**, 1788-1801. [https://doi.org/10.1016/s0140-6736\(23\)01289-8](https://doi.org/10.1016/s0140-6736(23)01289-8)
- [2] Kang, J.M. and Tanna, A.P. (2021) Glaucoma. *Medical Clinics of North America*, **105**, 493-510. <https://doi.org/10.1016/j.mcna.2021.01.004>
- [3] Coan, L.J., Williams, B.M., Krishna Adithya, V., Upadhyaya, S., Alkafri, A., Czanner, S., et al. (2023) Automatic Detection of Glaucoma via Fundus Imaging and Artificial Intelligence: A Review. *Survey of Ophthalmology*, **68**, 17-41. <https://doi.org/10.1016/j.survophthal.2022.08.005>
- [4] Orlando, J.I., Fu, H., Barbosa Breda, J., van Keer, K., Bathula, D.R., Diaz-Pinto, A., et al. (2020) Refuge Challenge: A Unified Framework for Evaluating Automated Methods for Glaucoma Assessment from Fundus Photographs. *Medical Image Analysis*, **59**, Article ID: 101570. <https://doi.org/10.1016/j.media.2019.101570>
- [5] Decencière, E., Zhang, X., Cazuguel, G., Lay, B., Cochener, B., Trone, C., et al. (2014) Feedback on a Publicly Distributed Image Database: The Messidor Database. *Image Analysis & Stereology*, **33**, 231-234. <https://doi.org/10.5566/ias.1155>
- [6] Hadoux, X., Hui, F., Lim, J.K.H., Masters, C.L., Pébay, A., Chevalier, S., et al. (2019) Non-Invasive *in Vivo* Hyperspectral Imaging of the Retina for Potential Biomarker Use in Alzheimer's Disease. *Nature Communications*, **10**, 1-12. <https://doi.org/10.1038/s41467-019-12242-1>
- [7] Cai, Y., Lin, J., Lin, Z., Wang, H., Zhang, Y., Pfister, H., et al. (2022) MST++: Multi-Stage Spectral-Wise Transformer for Efficient Spectral Reconstruction. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*

-
- Workshops (CVPRW)*, New Orleans, 19-20 June 2022, 744-754. <https://doi.org/10.1109/cvprw56347.2022.00090>
- [8] Cai, Y., Lin, J., Hu, X., Wang, H., Yuan, X., Zhang, Y., *et al.* (2022) Mask-Guided Spectral-Wise Transformer for Efficient Hyperspectral Image Reconstruction. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 17481-17490. <https://doi.org/10.1109/cvpr52688.2022.01698>
- [9] Simonyan, K. and Zisserman, A.J. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition.
- [10] Raghavendra, U., Fujita, H., Bhandary, S.V., Gudigar, A., Tan, J.H. and Acharya, U.R. (2018) Deep Convolution Neural Network for Accurate Diagnosis of Glaucoma Using Digital Fundus Images. *Information Sciences*, **441**, 41-49. <https://doi.org/10.1016/j.ins.2018.01.051>
- [11] Li, T., Bo, W., Hu, C., Kang, H., Liu, H., Wang, K., *et al.* (2021) Applications of Deep Learning in Fundus Images: A Review. *Medical Image Analysis*, **69**, Article ID: 101971. <https://doi.org/10.1016/j.media.2021.101971>
- [12] Shinoda, K., Ogawa, S., Yanagi, Y., Hasegawa, M., Kato, S., Ishikawa, M., *et al.* (2015). Multispectral Filter Array and Demosaicking for Pathological Images. *2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, 16-19 December 2015, 697-703. <https://doi.org/10.1109/apsipa.2015.7415362>
- [13] Hosseinaee, Z., Nima Abbasi, Pellegrino, N., Khalili, L., Mukhangaliyeva, L. and Haji Reza, P. (2021) Functional and Structural Ophthalmic Imaging Using Noncontact Multimodal Photoacoustic Remote Sensing Microscopy and Optical Coherence Tomography. *Scientific Reports*, **11**, Article No. 11. <https://doi.org/10.1038/s41598-021-90776-5>