

融合改进 Retinex 图像增强与深度学习的糖尿病视网膜分类检测方法

王文静¹, 张莉钊¹, 王欣¹, 刘玉红^{1,2}

1. 成都医学院生物医学工程教研室, 四川 成都 610500; 2. 电子科技大学信息与软件工程学院, 四川 成都 610054

【摘要】目的:提出一种基于图像增强算法和深度学习的糖尿病视网膜分类检测方法,对糖尿病视网膜病变图像进行自动分类,实现对眼底病变程度的等级划分。**方法:**采用一种经过改进的 Retinex 图像增强算法,对原始图像进行预处理操作,从而显著提高图像质量,有效增强图像的视觉效果,使其更具清晰度和对比度。并结合深度学习方法,对不同时期的病变程度进行自动分类检测。**结果:**本文方法在提高分类准确率、灵敏度和特异性方面具有显著优势。与传统 Retinex 方法相比,本文方法的准确率、灵敏度和特异性分别提高 5.4%、7.4% 和 16.6%。**结论:**利用本文方法可以有效实现糖尿病视网膜病变的自动分类和检测,从而提高其准确性和效率。

【关键词】深度学习; 图像分类; 图像增强; 糖尿病视网膜病变

【中图分类号】R318; TP751

【文献标志码】A

【文章编号】1005-202X(2024)09-1086-07

Classification and detection method for diabetic retinopathy based on the combination of improved Retinex image enhancement and deep learning

WANG Wenjing¹, ZHANG Lichuan¹, WANG Xin¹, LIU Yuhong^{1,2}

1. Department of Biomedical Engineering, Chengdu Medical College, Chengdu 610500, China; 2. School of Information and Software Engineering, University of Electronic Science and Technology of China, Chengdu 610054, China

Abstract: Objective To present a novel method based on the image enhancement algorithm and deep learning for automatically classifying diabetic retinopathy images, and realizing the graded classification of fundus lesions. **Methods** An improved Retinex image enhancement algorithm was employed to preprocess the original images for significantly improving image quality and visual effect, and enhancing image clarity and contrast. Then, deep learning method was used to automatically detect and classify the degree of lesions in different periods. **Results** The proposed method was advantageous in improving classification accuracy, sensitivity, and specificity which were 5.4%, 7.4%, and 16.6% higher than those of traditional Retinex method. **Conclusion** The proposed method can effectively realize the automatic detection and classification of diabetic retinopathy, which is helpful to enhance diagnostic accuracy and efficiency.

Keywords: deep learning; image classification; image enhancement; diabetic retinopathy

前言

糖尿病对人类健康产生深远影响,由其引发的糖尿病视网膜病变(Diabetic Retinopathy, DR)等并发症,更是给人们的日常生活带来诸多困扰。据统计,2020年全球范围内患有DR的成年人数量已达到10.31亿人,预计到2045年将增至16.05亿人^[1]。这种疾病有潜在风险导致眼部组织受损,造成视力衰退,并且在严重情况下,可能引发病理性的视网膜脱落和失明,对患者日常生活造成严重影响。因此,对糖尿病患者通过光学相干断层扫描血流成像技术等进行定期的眼底筛查和诊断,可以有效降低糖尿病引起的眼部损害状况^[2-3]。然而,对于彩色眼底图像的

【收稿日期】2024-02-23

【基金项目】国家自然科学基金(82001906, 82173753);四川省自然科学基金(2021YJ0138);四川省级创新创业训练计划项目(S202313705079, S202213705102)

【作者简介】王文静,研究方向:图像处理, E-mail: 3030645509@qq.com

【通信作者】刘玉红,博士,教授,研究方向:医学图像及信号处理, E-mail: amberliu@cmc.edu.cn

病灶识别和诊断,主要依赖医生的主观评价和判别。这种评价方式受到多种不确定因素的影响,如光照不均匀、成像过程中的复杂环境干扰等,从而导致获取的图像质量下降。彩色眼底图像是血管、视盘、视杯等疾病诊断的关键依据,因此,图像质量低会增加医生诊断的难度^[4]。在这种情况下,图像增强技术的应用和发展显得尤为重要。图像增强技术能够提高图像的视觉效果,使医生能够更清晰地观察到病灶的细节信息,从而提高诊断的准确性和效率。目前国内外主要的眼底图像增强方法有直方图均衡化、对比度受限自适应直方图均衡化(CLAHE)、Retinex图像增强算法等。直方图均衡化通过重新分布图像的像素值,使得各个灰度级在图像中更加均衡地分布,但可能改变图像的颜色分布,导致图像的色彩失真。CLAHE算法通过引入对比度限制机制,避免传统直方图均衡化在增强图像对比度时没有限制,可能会导致过度增强和噪声放大等问题。传统的Retinex图像增强算法模拟人眼感知,具有保留细节信息和适用于多种任务等优点,但计算复杂度高、不能在压缩动态范围的同时保持色调恢复,易产生光晕现象。因此,本文提出改进的Retinex图像增强方法,提高眼底图像血管对比度,同时保护色彩信息,以获得高质量的眼底图像,帮助医生更准确地定位病变区域,为治疗眼底疾病提供客观依据。

另外,传统的人工分类方法在处理大量眼底图像需要耗费大量的时间和精力。由于医生的主观因素可能会影响分类的准确性,可能导致分类错误的情况^[5]。而深度学习算法能够从眼底图像中提取特征并进行分类识别,极大地提高诊断的效率和准确性^[6]。Pratt等^[7]基于卷积神经网络(Convolutional Neural Networks, CNN)模型的眼底图像分类研究,实现DR的五分类问题,通过在反向传播过程中采用类加权策略,对DR图像进行准确分类。陈亚浩等^[8]使用ODIR数据集,对获取到的眼底图像进行一系列预处理后,输入到ResNet50网络中进行训练,利用残差网络模型的优势,较好地分析视网膜图像以提取丰富的图像信息,实现分类识别。庞浩等^[9]对ResNet网络进行改进,通过引入Inception结构,提出一种新的多分支结构的CNN用于彩色眼底图像分类,取得较好的效果。虽然当前彩色眼底图像的分类工作已经有了比较深入的研究并取得不错的效果,但在分类的准确率方面依然达不到理想要求,主要由于很多研究对眼底图像的预处理过于简单,无法获取图像中的细微特征,导致模型的性能下降,降低病变检测和诊断的准确率。本文提出通过结合新的图像增强技术和深度学习算法,更好地改善图像质量,

提高分类结果的准确性,以提供客观的数据支持,辅助医生做出更准确的诊断和决策。因此,基于图像增强算法和深度学习的糖尿病视网膜分类检测方法具有重要的研究价值和应用前景。

1 方法

1.1 数据预处理

数据预处理是在深度学习训练之前对原始数据进行的一系列处理步骤,目的是为了提高数据的质量,改善模型性能^[10]。在糖尿病视网膜分类任务中,由于采集的眼底图像可能受到多种因素的影响,如噪声、光照不均等,因此需要进行数据预处理,以提高原始数据的质量、减少数据中的噪声,使数据更适合进行机器学习和数据分析^[11]。数据预处理的流程主要包括数据归一化、数据均衡化和数据扩增等步骤,如图1所示。

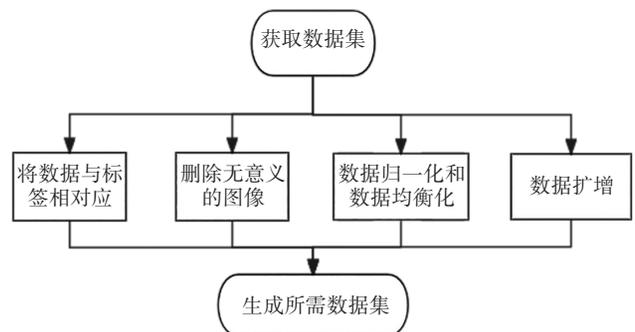


图1 图像分类预处理流程图

Figure 1 Image classification preprocessing flowchart

1.1.1 数据归一化和数据均衡化 在机器学习领域中,数据归一化和数据均衡化是必不可少的预处理步骤。数据归一化是一种预处理方法,主要消除不同图像间存在的数值差异,以加快模型的收敛速度。在本次实验中,选用Min-Max归一化法,该方法通过缩放图像的像素值至0~1间,能够有效地保持原始数据的分布结构,从而提升模型的性能。另一方面,由于不同类别样本的数量不一致会导致模型训练时对于少数类别的样本学习不足,从而影响模型的性能。为了解决这个问题,可以采用数据均衡化的方法,即使用SMOTE过采样法,增加少数类样本的数量来实现数据类别的均衡^[12]。

1.1.2 数据扩增 数据扩增是一种在机器学习和深度学习中常用的技术,通过对原始数据进行一系列变换生成新的样本,从而扩大数据集的规模。应用深度学习进行分类时,为了获得良好的模型性能,需要大量的数据样本进行训练^[13]。为了增加数据集的图像数量,提高分类模型的准确率和泛化能力,对现有

的低照度视网膜图像进行扩增处理。将800张图片均分为4份,每份200张图片,对每份图片分别采用水平翻转、镜像翻转、失真和切割方法来扩增数据样本量,使每份200张图片随机扩增为300张。通过这些处理,将原有数据库中的样本量从800张扩增到1200张,提供更多的数据样本,这将有助于模型更好地学习到数据的多样性,提高其对新数据的泛化能力^[14]。

数据预处理是提高深度学习模型性能关键步骤之一。通过归一化、均衡化和扩增等处理方法,可以有效地提升模型对糖尿病视网膜分类任务的准确性和泛化能力,为后续的模型训练和分类提供有力的支持。

1.2 改进的Retinex图像增强算法

眼底图像的采集和成像受环境和成像设备的限制,可能导致图像中的细节难以识别,影响后期的图像分类识别和医生的诊断结果^[15]。为了解决这一问题,本文在研究过程中采用改进的Retinex图像增强

算法,对低照度的眼底图像进行预处理,目的是为了改善图像的整体质量,消除可能存在的噪声干扰,并突出图像的细节部分。通过这些处理,提升后续分类识别中病灶检测的精确性和准确性。本文采用改进的Retinex方法更好地保留细节信息,避免在增强过程中引入噪声减少颜色偏差。通过这种方法提高图像的质量,从而提高分类的准确性和鲁棒性。

1.2.1 算法流程 由于HSI模型能将亮度、色调、饱和度分离开,这样进行图像处理时不会改变图像原本的颜色^[16]。首先将RGB图像转化为HSI模型,并从中提取亮度信息,接着采用多尺度Retinex算法(MSR)对提取到的亮度信息进行处理,以进一步增强图像的对比度和细节^[17]。为了校正亮度值,采用基于直方图的简单颜色平衡算法(Simplest Possible Color Balance algorithm, SCB)进行映射校正。最后,对亮度通道(R通道)进行恢复处理,以确保颜色的准确性,进一步提高图像分类的准确性^[18]。具体算法流程如图2所示。

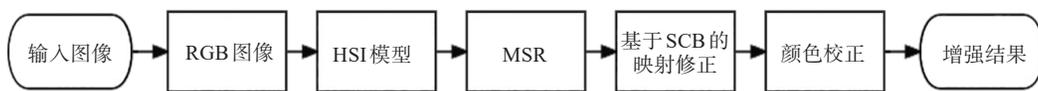


图2 改进的Retinex算法流程图
Figure 2 Improved Retinex algorithm flowchart

(1)亮度调整:首先将RGB图像转化为HSI模型以提取亮度信息 $I(x,y)$:

$$I(x,y) = (R(x,y) + G(x,y) + B(x,y))/3 \quad (1)$$

式中, $R(x,y)$ 、 $G(x,y)$ 和 $B(x,y)$ 对应于图像中 (x,y) 坐标位置的红色、绿色和蓝色像素分量。然后采用MSR算法对提取到的亮度信息进行处理:

$$R_{MSR}(x,y) = \sum_{n=1}^N W_n (\ln(x,y) - \ln(I(x,y)*G(x,y,\delta))) \quad (2)$$

式中, $R_{MSR}(x,y)$ 为多尺度的输出结果,通过对不同尺度的亮度信息进行处理来获得。 W_n 为不同尺度的加权系数, N 为尺度个数。 $G(x,y,\delta)$ 表示高斯核,用于在不同尺度下对亮度信息进行平滑处理。

(2)GAIN/OFFSET修正方法的改进:通过基于直方图的SCB方法对亮度值进行映射校正,有:

$$R'_{MSR_i} = 255 \frac{R_{MRS_i} - N(S_1/100)}{(N(1 - (S_2/100)) - 1) - N(S_1/100)} \quad (3)$$

式中, R_{MRS_i} 代表第 i 个颜色通道多尺度的输出图像, R'_{MSR_i} 则表示第 i 个颜色通道经过映射校正后的值, S_1

和 S_2 分别代表两端的截取百分比,用于调整图像亮度和对比度。 N 表示输入图像的像素总数。

(3)颜色恢复因子的改进:增强图像的亮度信息后,还需对图像进行颜色恢复处理,以解决颜色失真问题,表达式如下所示:

$$I'_i(x,y) = \alpha(x,y) I(x,y) \quad (4)$$

式中,颜色恢复因子 $\alpha(x,y) = \frac{R'_{MSR_i}(x,y)}{I(x,y)}$,用于描述点 (x,y) 处的颜色恢复情况; $I(x,y)$ 表示的是式(1)得到的亮度值; $I_i(x,y)$ 代表第 i 个通道的原始图像像素值在点 (x,y) 处的像素值。

(4)红色通道的恢复:经过对颜色处理后的图像质量有了很大提高,但R通道的亮度信息却丢失严重,因此需要对R通道进行颜色恢复处理。其表达式如下:

$$R_{MSR_r} = \sum_{n=1}^N W_n (\ln(I_r(x,y)) - \ln(I_r(x,y)*G(x,y,\delta_i))) \quad (5)$$

式中, $I_r(x,y)$ 代表红色通道在点 (x,y) 处的亮度值;而 N 则对应于尺度的数目。

1.2.2 增强效果 实验结果表明,采用改进的 Retinex 方法对原始图像进行增强处理后,眼底图像血管对比度得到进一步提高,图像的对比度和细节突出使

得整体图像具有更好的视觉效果,有助于后期的图像分类。增强效果对比如图3所示。

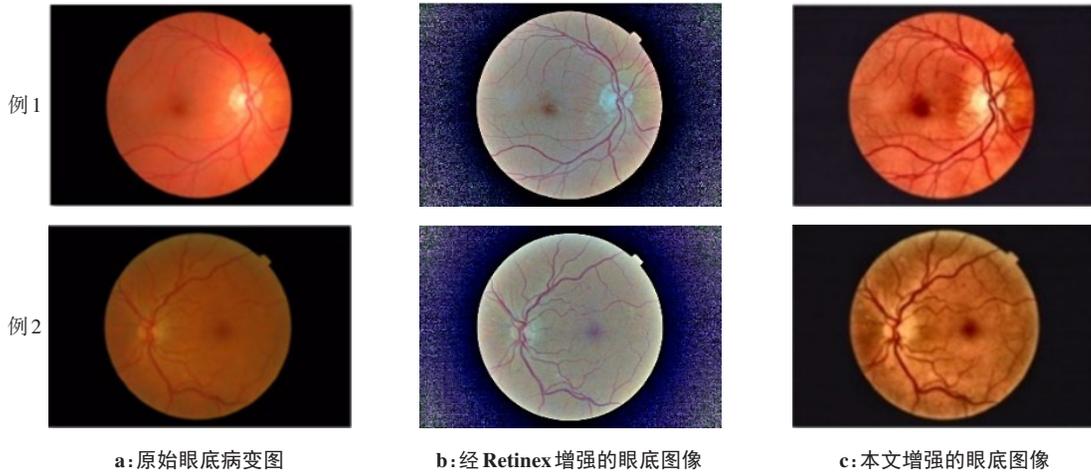


图3 原始图像与增强后图像对比

Figure 3 Comparison of original images and the enhanced images

1.3 CNN 网络分类检测

1.3.1 CNN 网络模型 目前 CNN 网络已广泛运用于计算机视觉等多个领域,并取得良好的效果^[19-21]。本研究模型以 CNN 网络中的 ResNet50 为基础框架,解决网络全连接层能获取不同维度的特征表达,减弱网络所带来的特征损失,并进一步提取眼底图像的细节特征,有利于 CNN 最大化提取眼底图像特征^[22-24]。CNN 模型的基本结构包含输入层、用于特

征提取的卷积层、用于降维的池化层、用于分类的全连接层以及输出层。具体的运作流程如下:首先,数据通过输入层进入网络;然后,经过卷积层的处理,数据被提取出特征;接着,通过池化层的操作,数据得到进一步降维;此后,数据进入全连接层,进行更高层次的特征整合;最后,经由输出层产生网络的最终输出。CNN 网络流程如图4所示。

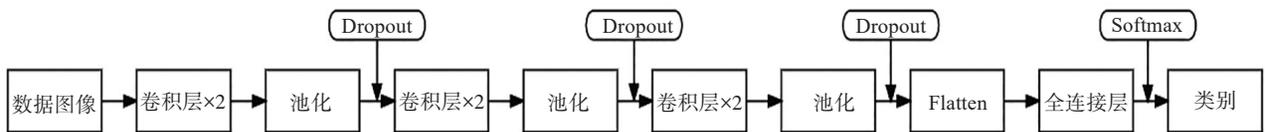


图4 CNN网络流程图

Figure 4 CNN flowchart

1.3.2 分类训练流程 本文将增强处理后的图像作为 CNN 网络的输入,其尺寸大小为 224×224,按照 7:1:2 的比例将这些图像划分为训练集、验证集和测试集,以确保模型的泛化能力和性能评估的准确性。其中,训练集是用于训练机器学习模型的数据集,以使模型能够对输入数据进行正确的预测或分类,在训练过程中,根据训练集的表现来调整超参数,帮助选择最佳的超参数配置。验证集则帮助选择最佳的超参数配置,以提高模型的泛化能力。测试集主要用于评估模型性能的数据集。具体流程图如图5所示。

2 结果与分析

2.1 数据集

本次实验采用的数据集为 Messdiior 数据集,是一个在 DR 领域被广泛应用的数据集,主要包含眼底视网膜图像和与之对应的病变标记信息,其 DR 分级标准有 4 个级别(0~3),包括不同时期的病变图像,如正常、轻度、中度和重度病变。

2.2 实验过程及评价指标

本研究采用的数据集共包含 1 200 张眼底图片,其

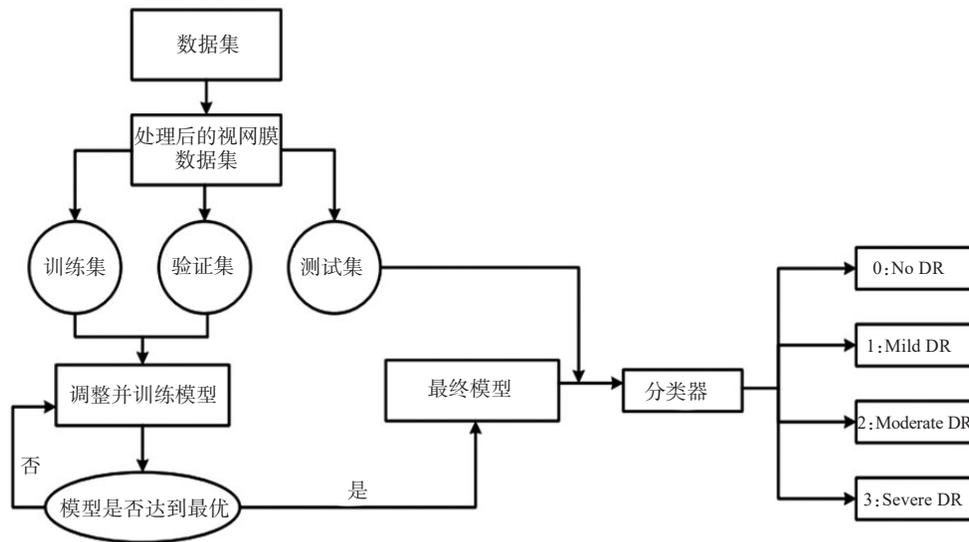


图 5 分类算法模型流程图

Figure 5 Classification algorithm model flowchart

中 800 张作为训练集,286 张作为测试集以及 114 张作为验证集。准确率(Accuracy, ACC)、灵敏度(Sensitivity, SEN)和特异性(Specificity, SPE)作为重要的评价指标,常被用来对系统性能进行综合性评估^[25]。在进行图像分类实验的过程中,针对不同的情况选择适当的分类算法、特征提取方法以及模型优化策略,以提升分类的准确性。准确率衡量了正确分类目标类和背景类的能力;灵敏度反映了正确识别目标类的概率;特异性表示正确识别背景类的概率。这 3 个指标在评估分类模型性能时通常是相辅相成的。准确率可以直观表示整体预测的准确程度,而灵敏度和特异性则分别关注分类器对正例和负例的识别能力,有助于深入了解分类器的表现情况。3 项指标的具体计算公式如下:

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (6)$$

$$SEN = \frac{TP}{TP + FN} \quad (7)$$

$$SPE = \frac{TN}{FP + TN} \quad (8)$$

式中,TP 表示真阳性,即分类器将患有 DR 的病例正确地识别出来;FN 表示假阴性,即分类器将患有 DR 的病例错误地预测为正常;TN 表示真阴性,即分类器将未患有 DR 的病例正确地识别出来;FP 表示假阳性,即分类器将未患有 DR 的病例错误地预测为患有 DR。这些指标是评估分类器性能的重要指标。

2.3 实验结果对比

应用本文的增强技术对数据集进行处理和分类,与未使用任何增强方法、CLAHE 增强方法以及传统 Retinex 方法进行增强的 3 类图像进行分类结果对比。实验结果数据如表 1~表 3 所示。

表 1 不同方法分类准确率对比(%)

Table 1 Comparison of classification accuracy of different methods (%)

方法	未裁剪前分类准确率	裁剪后分类准确率
无增强方法	59.0	61.7
CLAHE	60.8	62.5
Retinex	60.1	61.9
本文方法	65.7	67.3

表 2 不同方法分类灵敏度对比(%)

Table 2 Comparison of classification sensitivity of different methods (%)

方法	未裁剪前分类灵敏度	裁剪后分类灵敏度
无增强方法	49.2	51.1
CLAHE	53.2	54.5
Retinex	49.3	50.8
本文方法	57.4	58.2

表 3 不同增强方法分类特异性对比(%)

Table 3 Comparison of classification specificity of different methods (%)

方法	未裁剪前分类特异性	裁剪后分类特异性
无增强方法	72.4	74.1
CLAHE	74.7	76.2
Retinex	61.2	63.5
本文方法	75.6	80.1

2.3.1 准确率指标结果对比 根据表 1 的实验结果,使用不同的图像增强处理方法对实验分类结果产生

显著的影响。未裁剪的不同增强的方法结果对比:本文方法的准确率为65.7%,与无增强方法相比提高6.7%,与CLAHE方法相比提高4.9%,与Retinex方法相比提高5.6%。裁剪后的不同增强的方法结果对比:本文方法的准确率为67.3%,与无增强方法相比提高5.6%,与CLAHE方法相比提高4.8%,与Retinex方法相比提高5.4%。未裁剪与裁剪后的结果相比,本文增强方法在准确率上提高1.6%。

2.3.2 灵敏度指标结果对比 根据表2的实验结果,使用不同的图像增强处理方法对实验分类结果产生显著的影响。未裁剪的不同增强的方法结果对比:本文方法的灵敏度为57.4%,与无增强方法相比提高8.2%,与CLAHE方法相比提高4.2%,与Retinex方法相比提高8.1%。裁剪后的不同增强的方法结果对比:本文方法的灵敏度为58.2%,与无增强方法相比提高7.1%,与CLAHE方法相比提高3.7%,与Retinex方法相比提高7.4%。未裁剪与裁剪后的结果相比,本文增强方法在灵敏度上提高0.8%。

2.3.3 特异性指标结果对比 根据表3的实验结果,使用不同的图像增强处理方法对实验分类结果产生显著的影响。未裁剪的不同增强的方法结果对比:本文方法的特异性为75.6%,与无增强方法相比提高3.2%,与CLAHE方法相比提高0.9%,与Retinex方法相比提高14.4%。裁剪后的不同增强的方法结果对比:本文方法的特异性为80.1%,与无增强方法相比提高6.0%,与CLAHE方法相比提高3.9%,与Retinex方法相比提高16.6%。未裁剪与裁剪后的结果相比,本文增强方法在特异性上提高4.5%。

3 讨论

本文提出一种基于改进的Retinex图像增强方法结合深度学习技术对DR的自动分类和病变程度的分类检测。实验结果表明,该方法在提高分类结果的准确率、灵敏度和特异性方面具有显著优势。与传统的Retinex方法相比,经裁剪后,本文的改进方法在准确率、灵敏度和特异性上分别提高5.4%、7.4%和16.6%,证明本文提出的模型在处理眼底图像时,能够更准确地识别和分类病变,从而为医生提供更可靠的诊断依据。本研究为眼底图像处理技术的发展和應用提供新的可能性,通过结合改进的图像增强方法和深度学习技术,能够有效地提高眼底图像的质量并实现病变的自动分类。这不仅有助于提高糖尿病患者的诊断准确性,还为推动医学图像处理技术的发展和應用提供支持。

综上所述,本文提出一种有效的眼底图像处理方法,有望为DR的早期诊断和治疗提供重要的支

持。未来还需要进一步优化模型,在更大的数据集上进行验证,以确保其在更广泛场景下的应用性能。

【参考文献】

- [1] 师铖,秦光浩,林铁柱.糖尿病视网膜病变眼年检障碍因素分析[J].国际眼科杂志,2023,23(4):677-681.
Shi C, Qin GH, Lin TZ. Factors associated with poor participation in annual eye examination for diabetic retinopathy [J]. International Eye Science, 2023, 23(4): 677-681.
- [2] 唐森,李淑婷.光学相干断层血管造影成像应用于非增殖期糖尿病视网膜病变微血管的临床筛查[J].西安交通大学学报(医学版),2023,44(2):271-274.
Tang M, Li ST. Application of OCTA in screening microvascular changes in non-proliferative diabetic retinopathy [J]. Journal of Xi'an Jiaotong University (Medical Sciences), 2023, 44(2): 271-274.
- [3] Shankar K, Zhang YZ, Liu YW, et al. Hyperparameter tuning deep learning for diabetic retinopathy fundus image classification [J]. IEEE Access, 2020, 8: 118164-118173.
- [4] 刘玉红,李梓妍,王欣,等.具有颜色保真性的彩色眼底图像增强方法[J].电子科技大学学报,2022,51(2):290-294.
Liu YH, Li ZY, Wang X, et al. Hue preserving algorithm for color fundus image enhancement method [J]. Journal of University of Electronic Science and Technology of China, 2022, 51(2): 290-294.
- [5] 王明智,马志强,赵锋锋,等.基于代价敏感正则化和EfficientNet的糖尿病视网膜病变分类方法[J].液晶与显示,2022,37(12):1626-1635.
Wang MZ, Ma ZQ, Zhao FF, et al. Diabetic retinopathy classification method based on cost sensitive regularization and EfficientNet [J]. Chinese Journal of Liquid Crystals and Displays, 2022, 37(12): 1626-1635.
- [6] 卢宏涛,张秦川.深度卷积神经网络在计算机视觉中的应用研究综述[J].数据采集与处理,2016,31(1):1-17.
Lu HT, Zhang QC. Applications of deep convolutional neural network in computer vision [J]. Journal of Data Acquisition and Processing, 2016, 31(1): 1-17.
- [7] Pratt H, Coenen F, Broadbent DM, et al. Convolutional neural networks for diabetic retinopathy [J]. Procedia Comput Sci, 2016, 90: 200-205.
- [8] 陈亚浩,张东.基于ResNet的彩色眼底图片分类算法研究[J].计算机应用与软件,2023,40(8):250-254.
Chen YH, Zhang D. Research on classification algorithm of color fundus images based on ResNet [J]. Computer Applications and Software, 2023, 40(8): 250-254.
- [9] 庞浩,王枫.用于糖尿病视网膜病变检测的深度学习模型[J].软件学报,2017,28(11):3018-3029.
Pang H, Wang C. Deep learning model for diabetic retinopathy detection [J]. Journal of Software, 2017, 28(11): 3018-3029.
- [10] Sraddha D, Kirty K, Suchetha M, et al. Deep learning architecture based on segmented fundus image features for classification of diabetic retinopathy [J]. Biomed Signal Process Control, 2021, 68: 102600.
- [11] 郭妮妮,乔钢柱,张光华,等.基于生成对抗网络与双注意力的糖尿病分类方法[J].中北大学学报(自然科学版),2023,44(1):39-47.
Guo NN, Qiao GZ, Zhang GH, et al. Classification of diabetic retinopathy using generative adversarial networks and dual attention network [J]. Journal of North University of China (Natural Science Edition), 2023, 44(1): 39-47.
- [12] Feng S, Keung J, Yu X, et al. Investigation on the stability of SMOTE-based oversampling techniques in software defect prediction [J]. Inf Softw Technol, 2021, 139: 106662.
- [13] 陈宇,周雨佳,丁辉.一种XNet-CNN糖尿病视网膜图像分类方法[J].哈尔滨理工大学学报,2020,25(1):73-79.
Chen Y, Zhou YJ, Ding H. An XNet-CNN diabetic retinal image classification method [J]. Journal of Harbin University of Science and Technology, 2020, 25(1): 73-79.
- [14] 王琮智,许梓壁,马祥园,等.基于数据扩增和迁移学习的Mask R-CNN脑CT图像自动分割研究[J].中国生物医学工程学报,2021,40(4):410-418.
Wang CZ, Xu ZB, Ma XY, et al. Mask R-CNN and data

- augmentation and transfer learning [J]. Chinese Journal of Biomedical Engineering, 2021, 40(4): 410-418.
- [15] Shen ZY, Fu HZ, Shen JB, et al. Modeling and enhancing low-quality retinal fundus images[J]. IEEE Trans Med Imaging, 2021, 40(3): 996-1006.
- [16] Yu X, Zhuang HY, Cui YN, et al. A dichotomy color quantization algorithm for the HSI color space[J]. Sci Rep, 2023, 13(1): 8135.
- [17] Hu K, Zhang YW, Lu FY, et al. An underwater image enhancement algorithm based on MSR parameter optimization [J]. J Mar Sci Eng, 2020, 8(10): 741.
- [18] 刘玉红, 颜红梅. 基于 Retinex 理论的眼底彩色图像增强算法 [J]. 中国生物医学工程学报, 2018, 37(3): 257-265.
Liu YH, Yan HM. The color fundus image enhancement algorithm based on Retinex theory [J]. Chinese Journal of Biomedical Engineering, 2018, 37(3): 257-265.
- [19] Ozcanli AK, Baysal M. Islanding detection in microgrid using deep learning based on 1D CNN and CNN-LSTM networks [J]. Sustainable Energy, Grids and Networks, 2022, 32: 100839.
- [20] Jiao FY, Gui ZG, Li KP, et al. A dual-domain CNN-based network for CT reconstruction[J]. IEEE Access, 2021, 9: 71091-71103.
- [21] Ahlawat S, Choudhary A, Nayyar A, et al. Improved handwritten digit recognition using convolutional neural networks (CNN)[J]. Sensors, 2020, 20(12): 3344.
- [22] 于旭燕, 刘建霞, 薛文渲, 等. 基于改进 CNN 的糖尿病视网膜病变图像分类模型研究[J]. 现代电子技术, 2021, 44(20): 168-172.
Yu XY, Liu JX, Xue WX, et al. Diabetic retinopathy image classification model for based on improved CNN [J]. Modern Electronics Technique, 2021, 44(20): 168-172.
- [23] Gayathri S, Gopi VP, Palanisamy P. A lightweight CNN for diabetic retinopathy classification from fundus images [J]. Biomed Signal Process Control, 2020, 62: 102115.
- [24] Alnaanah M, Wahdow M, Alrashdan M. CNN models for EEG motor imagery signal classification [J]. Signal Image Video Process, 2023, 17(3): 825-830.
- [25] 李大湘, 张振. 基于改进 U-Net 视网膜血管图像分割算法 [J]. 光学学报, 2020, 40(10): 58-66.
Li DX, Zhang Z. Improved U-Net segmentation algorithm for the retinal blood vessel images [J]. Acta Optica Sinica, 2020, 40(10): 58-66.

(编辑:陈丽霞)