

文章编号: 2095-2163(2023)12-0144-05

中图分类号: TP391.4

文献标志码: A

基于特征增强的高血压视网膜病变分类方法研究

刘国强¹, 卓广平¹, 汪扬¹, 阚玉常¹, 张光华²

(1 太原师范学院 计算机科学与技术学院, 山西 晋中 030619; 2 太原学院 智能与自动化系, 山西 太原 030032)

摘要: 高血压视网膜病变是由高血压所引起的眼底疾病,传统分类方法主要是基于区域特征进行分析,识别依据较为单一,准确度不高。为提高分类准确度,本文提出了一种基于特征增强机制的高血压视网膜病变分类方法,设计了基于不同图像色彩空间的眼底图像特征增强方法,增强眼底照片中的病灶特征,提高模型的输入特征值,将处理后的图片输入改进的DenseNet模型中进行分类,从而提高高血压视网膜病变(HR)分类的准确度。采用公开数据集OIA-ODIR对本文提出的基于特征增强的高血压视网膜病变分类方法进行测试,其敏感性、特异性、准确率分别达到97.09%、98.79%、98.67%,与现有的HR分类方法进行分析对比,本文提出的分类方法效果更佳。

关键词: 高血压视网膜病变分类; 眼底图像特征增强; 图像色彩空间; DenseNet模型

Hypertensive retinopathy classification method based on feature enhancement mechanism research

LIU Guoqiang¹, ZHUO Guangping¹, WANG Yang¹, KAN Yuchang¹, ZHANG Guanghua²

(1 College of Computer Science and Technology, Taiyuan Normal University, Jinzhong Shanxi 030619, China;

2 Department of Intelligence and Automation, Taiyuan University, Taiyuan 030032, China)

Abstract: Hypertensive retinopathy is a fundus disease caused by high blood pressure, the traditional classification method is mainly based on the regional features to analyze, the identification basis is relatively single, and the accuracy is not high. In order to improve the classification accuracy, this paper proposes a classification method of hypertensive retinopathy based on the feature enhancement mechanism and designs a fundus image feature enhancement method based on different image color spaces, i.e., to enhance the lesion features in the fundus photographs, to increase the input feature value of the model, and to input the processed images into the improved DenseNet model for classification, so as to achieve the accuracy of the classification of hypertensive retinopathy (HR). lesion (HR) classification accuracy. The sensitivity, specificity, and accuracy of the proposed feature-enhanced classification method for hypertensive retinopathy (HR) were tested using the publicly available dataset OIA-ODIR and reached 97.09%, 98.79%, and 98.67%. Compared with the existing HR classification method, the classification method proposed in this article is better.

Key words: classification of hypertensive retinopathy; fundus image feature enhancement; image color space; DenseNet model

0 引言

高血压视网膜病变(Hypertensive Retinopathy, HR)是高血压中最常见的并发症之一,其特征是视网膜动静脉管径比率发生改变、动静脉交叉压迫、视网膜内出血^[1]。急性高血压可表现为视盘水肿、视网膜出血及水肿、棉绒斑,同时有高血压性脉络膜病变^[2]。视网膜病变严重影响视力和生活质量,因此早期的诊断和治疗非常重要。

高血压视网膜病变的传统诊断需要由专业的医

生通过手动检查眼底图像来完成^[3]。这种方法费时费力且存在主观性,利用深度学习算法对高血压视网膜病变进行诊断已经成为一个重要的研究领域^[4]。

使用深度学习算法可以将视网膜图像中的血管、病变区域和其他特征自动识别出来,实现对高血压视网膜病变的自动诊断和分类^[5]。针对高血压视网膜病变的分类问题,许多研究都采用深度学习算法自动地学习视网膜图像的特征,对发生了病变的图像和未发生病变的图像进行分类,提高了病变识别的准确性和效率。

基金项目: 山西省自然科学基金面上项目(201801D121147); 太原学院院级重点课题(21TYKZ01); 眼科学山西省重点实验室开放课题(2023SXXKLOS04)。

作者简介: 刘国强(1997-),男,硕士研究生,主要研究方向:医学图像处理、计算机视觉。

通讯作者: 卓广平(1972-),男,博士,副教授,主要研究方向:大数据分析 with 挖掘、认知与智能。Email: liugq0701@163.com

收稿日期: 2023-10-20

哈尔滨工业大学主办 ◆ 专题设计与应用

2014 年 Khitrn 等^[6]提出使用新的特征向量和混合分类器将视网膜血管分类为动脉和静脉的新方法,计算宽度进而得出动静脉比率(Arteryvein Ratio, AVR),实现对 HR 的识别与检测;2017 年 Syahputra M.F 等^[7]通过从彩色视网膜眼底图像中提取特征,将提取的特征用于训练前馈神经网络分类器;2019 年 Kiruthika 等^[8]通过使用 Radon 血管跟踪算法提取特征向量对动静脉进行分类,计算 AVR 实现 HR 病变检测;2022 年王伟等^[9]在整体 HR 分类模型的基础上,融合局部特征动静脉交叉压迫(Arteriovenous Nicking, AVN)分类模型来增强 HR 分类效果。以往的研究多是通过计算 AVR 和 AVN 对 HR 进行识别与检测,识别的依据主要是视网膜动静脉管径比率和是否交叉压迫,没有结合视网膜出血块和棉絮斑等症状,这些症状是高血压视网膜病变分级的重要参考因素。

基于 RGB 色彩空间的直方图均衡化(Histogram Equalization, HE)技术在图像增强领域取得了很好的效果。1994 年 Karel Zuiderveld 等^[10]提出了限制对比度自适应直方图均衡化(Contrast Limited Adaptive Histogram Equalization, CLAHE)方法对图像对比度进行增强,从而实现对图像特征的增强;2022 年任吉宏等^[11]引入基于极化统计 HSV 颜色特征的自适应超像素聚类算法,提出一种借助邻域相关性的样本特征增强方法;2023 年朱俊东等^[12]基于 RGB 色彩空间,采用高斯滤波和 CLAHE 等方法对眼底图像进行特征增强。以上方法均在 RGB 和 HSV 色彩空间对图像进行对比度增强,并没有考虑图像的亮度、色相等单一影响因素。通过转换到最优色彩空间 CIECAM 对图像的亮度、色相、色度等因素处理,从而实现眼底图像增强。

本文提出了一种新的眼底图像特征增强方法,将眼底图像转换到 CIECAM 色彩空间,对图像的亮度、色相、色度等单一因素进行调整,使得眼底照片上的病灶特征更加清晰,以便模型在提取特征阶段有较好的针对性,从而提高分类的准确性;基于 DenseNet 架构,对模型进行优化,通过在模型中增加通道注意力模块和空间注意力模块,强化模型对特征的学习,提高模型的预测性能。通过现有数据集对本文提出的分类方法进行评估,并且和现有方法进行对比实验,以验证该分类方法的性能。

1 眼底图像预处理

数据集中的视网膜眼底图像具有不同的光照和

不清楚的 HR 症状。由于不同的数据采集角度和光照强度导致眼底图像的 HR 成像不同。因此,本文采用图像预处理方法对眼底图像进行预处理,为后续的分类任务提供高质量输入眼底照片。

1.1 图像预处理

本文通过裁减去除掉眼底照片中多余的黑色边框,即遍历整张照片的像素点,找到有效图像数据的边界,从而判断需要裁减线的横纵坐标,进行正方形切割,将图像转换成正方形图片,如图 1 所示;重新调整每一张照片的分辨率为 $1\ 024 \times 1\ 024$,以便于操作;对 HR 眼底照片进行数据扩增,主要方法包括:水平翻转、垂直翻转、随机旋转等。

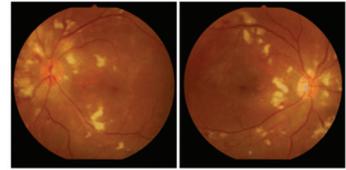


图 1 去黑边后的图像

Fig. 1 Image after going to the black edge

1.2 眼底图像特征增强

本文提出了一种新的眼底图像特征增强方法,如图 2 所示。



图 2 图像特征增强方法

Fig. 2 Image feature enhancement method

CIECAM02 是视觉感知上最先进的色彩感知空间^[13]。将读取到的视网膜眼底照片从 RGB 色彩空间转到 CIECAM02 色彩空间;对 CIECAM02 色彩空间中的 J(亮度)、H(色相)通道进行自适应直方图均衡化;当对 C(色度)通道进行处理时会导致图像特征消失,所以本文只对 J(亮度)、H(色相)通道进行处理,之后再转换回 BGR 色彩空间,最后通过如式(1)将处理过的图像和原图像进行有权重的融合,用 $new_image(x, y)$ 表示融合后图像的像素,式(1):

$$new_image(x, y) = RGB_{image}(x, y) * \alpha + CIECAM_{image}(x, y) * \beta + \gamma \quad (1)$$

其中, α 表示原图权重系数; β 表示特征增强处理后眼底图像的权重系数; γ 为调整图像亮度常数; $RGB_{image}(x, y)$ 表示原图的像素; $CIECAM_{image}(x, y)$ 表示经过处理后的像素。

公式(1)中 $\alpha = 0.8, \beta = 0.2, \gamma = 8$, 经过融合后的眼底图像有明显的病症特征,如图3所示。

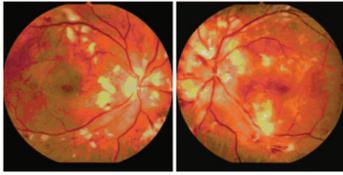


图3 特征增强后的眼底图像

Fig. 3 Fundus image after feature enhancement

2 改进 DenseNet 架构的分类模型设计

2.1 分类模型改进说明

对 DenseNet201 架构的改进主要通过添加具有通道注意力机制和空间注意力机制的密集的特征变换层对特征进行识别。最后,基于 SoftMax 层进行分类决策,对眼底照片分类进行预测。

本模型采用迁移学习方法,使用基于 ImageNet 数据集的预训练模型,为了不改变预训练模型结构,分别在第一层卷积层之后和最后一层卷积层之后添加了卷积注意力模块(CBAM),使得模型仍然可以使用预训练参数。卷积注意力模块(CBAM)是一种用于前馈卷积神经网络的简单而有效的注意力模块^[14]。CBAM 是一种结合了空间(spatial)和通道(channel)的注意力模块。

通道注意力机制(Channel Attention Module)将特征图在空间维度上进行压缩时,分别使用平均值池化(Average Pooling)和最大值池化(Max Pooling)。平均池化和最大值池化用来聚合特征映射的空间信息,分别送到一个共享网络,本文共享网络采用了两个二维卷积操作,如图4中 Conv1 和 Conv2,实现压缩输入特征图的空间维数,之后再逐元素求和合并,以产生通道注意力图。空间注意力机制(Spatial Attention Module)是对通道进行压缩,在通道维度分别进行了使用平均值池化和最大值池

化。MaxPool的操作是在通道上提取最大值,提取的次数是高乘以宽;AvgPool的操作是在通道上提取平均值,提取的次数也是高乘以宽。将前面所提取到的特征图(通道数都为1)合并得到一个2通道的特征图;经过一个卷积操作(Conv3)生成特征图,其中卷积核大小为7×7。经过池化操作的空间注意力模块有效凸显了信息丰富的区域。

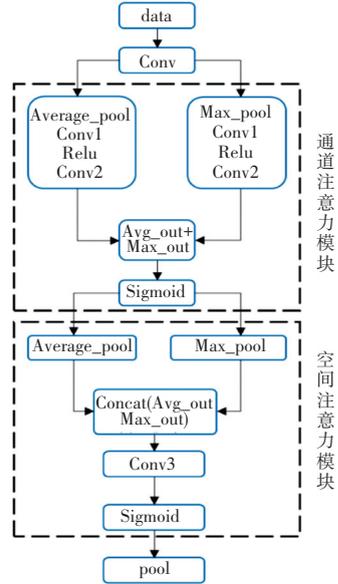


图4 模型注意力模块设计

Fig. 4 Design of attention module in the model

2.2 分类方法设计

本文将经过特征增强处理的图像作为输入图像,图像的基础分辨率为 1 024×1 024,在模型训练过程中将分辨率作为变量分析对模型的影响。HR 分类方法如图5所示,图5中每个 Dense Block 包含2层卷积,卷积 kernel 大小依次为 1×1、3×3,在卷积前进行 BatchNorm+Scale + ReLU 操作,第1、2个卷积输出 feature maps 分别为 128、32。因为 $k = 32$,所以每个 Dense Block 输出 feature maps 数会比上一个 Dense Block 多 32。每个 Dense Block 后做 Concat 操作^[15]。

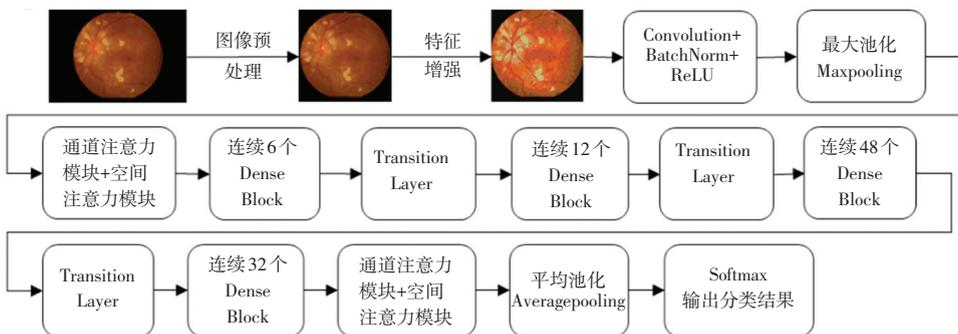


图5 HR 分类方法

Fig. 5 HR classification method

3 实验

DenseNet 架构中使用的参数设置值包括: 优化器:SGD, 增长率:32, 学习率:0.001, epoch:20, 损失函数:交叉熵损失函数 CrossEntropy Loss。

3.1 数据集的准备

本文数据集主要来源 OIA-ODIR 该公开数据集。其中, 训练集 4 086 张, 包括正常眼底照片 2 226 张、HR 眼底照片 1 860 张; 测试集 453 张, 包括正常眼底照片 247 张、HR 眼底照片 206 张。数据集代表眼底图像如图 6 所示。



(a) 正常眼底 (b) HR 眼底

图 6 数据集代表眼底图像

Fig. 6 Dataset represents fundus images

3.2 模型性能分析

本文用敏感性 (Sensitivity, SE)、特异性 (Specificity, SP)、准确率 (Accuracy, ACC) 3 个评价指标对模型的性能进行评估。 ACC 表示图像分类正确的识别率; SE 表示正确识别出 HR 的概率, 即实际眼底图像为 HR 且被模型预测为 HR 的概率, 高敏感性代表漏诊率低; SP 表示正确识别出正常眼底图像的概率, 即实际眼底图像正常且被模型预测为正常的概率, 高特异性代表误诊率低。敏感性 (SE)、特异性 (SP)、准确率 (ACC) 的计算见式 (2) ~ 式 (4):

$$SE = \frac{TP}{TP + FN} \quad (2)$$

$$SP = \frac{TN}{TN + FP} \quad (3)$$

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (4)$$

其中, TP 表示模型正确识别出 HR 眼底照片的数量; TN 表示模型正确识别出正常眼底照片的数量; FP 表示模型将正常眼底照片错误识别为 HR 眼底照片的数量; FN 表示模型将 HR 眼底照片错误识别为正常眼底照片。

训练过程中准确率曲线变化如图 7 所示, 训练过程中 loss 曲线变化如图 8 所示。

为了探究不同的分辨率对模型性能的影响, 使用不同的分辨率进行实验见表 1。

由表 1 可知, 分辨率对模型的训练有一定的影

响, 本文在实验过程中将输入图像的分辨率设置为 512×512, 该分辨率下模型的准确率、敏感性、特异性最好, 综合考虑最优。

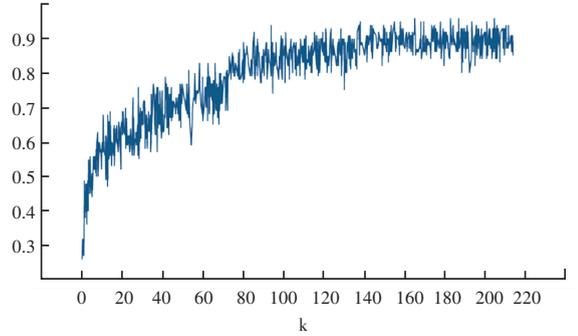


图 7 训练过程中准确率曲线变化图

Fig. 7 Accuracy curve change plot during training

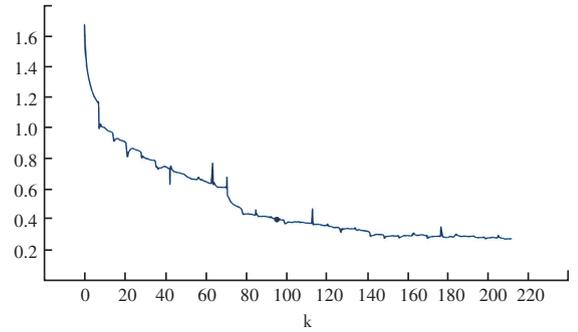


图 8 训练过程中 loss 曲线变化图

Fig. 8 Loss curve change plot during training

表 1 不同分辨率大小 HR 分类性能对比

Table 1 HR classification performance comparison of different resolution sizes

分辨率	准确率/%	敏感性/%	特异性/%
128×128	96.16	97.08	95.95
256×256	98.01	95.57	98.38
512×512	98.67	97.09	98.79
768×768	96.90	94.66	98.78
1 024×1 014	96.46	93.68	98.78

为了验证本文提出的特征增强方法对 HR 分类的影响, 将经过基本预处理后的图像和经过特征增强方法处理后的图像作为网络模型 DenseNet201 的输入图像进行对比实验, 实验结果见表 2。

表 2 本文图像处理方法与现有图像预处理方法的实验结果对比

Table 2 Comparison of experimental results between the image processing method in this paper and the existing image preprocessing methods

输入图像	准确率/%	敏感性/%	特异性/%
预处理图像	97.57	96.60	98.38
特征增强图像	98.67	97.09	98.79

由表 3 可知, 经过本文提出的特征增强方法处理

后的图像能够提升模型的性能,准确率提高了1.1%、敏感性提高了0.49%、特异性提高了0.41%。

为了说明改进 DenseNet201 模型对 HR 的分类结果的影响,将原来的 DenseNet201 与改进后的 DenseNet201 进行对比实验,数据集采用本文中经过特征增强处理后的数据集,实验结果见表3。

表3 改进 DenseNet201 模型与原始模型 DenseNet201 实验结果对比

Table 3 Comparison of experimental results between the improved model DenseNet201-CBAM and the original model DenseNet201

模型	准确率/%	敏感性/%	特异性/%
DenseNet201	96.47	93.20	99.19
改进的 DenseNet201	98.67	97.09	98.79

由表3可知,添加了通道注意力模块和空间注意力模块的 DenseNet201-CBAM 网络模型较原始 DenseNet201 模型在分类准确率方面有一定的提高。

为了验证本文提出的 HR 分类方法的性能,将本文提出的 HR 分类方法与现有的 HR 分类方法:反向传播神经网络^[7]、计算视网膜动静脉管径比率^[8]、融合区域特征(AVN)^[9]识别方法,进行对比实验;实验结果见表4。

表4 本文方法与其他 HR 分类方法实验结果对比

Table 4 Performance method with other HR classification methods

识别方法	准确率/%	敏感性/%	特异性/%
反向传播神经网络 ^[7]	95.00		
计算视网膜动静脉管径比率 ^[8]	92.55	93.80	
融合区域特征(AVN) ^[9]	93.50	69.83	98.33
本文方法	98.67	97.09	98.79

由表4可知,本文提出的分类方法准确率达到了98.67%、敏感性达到了97.09%、特异性达到了98.79%。准确率上高于其他方法,并且具有高特异性和高敏感性,这对于 HR 前期的诊断有积极的意义。

4 结束语

本文提出了一种基于特征增强机制的高血压视网膜病变分类方法。首先,对输入眼底图像进行去除黑色边框、调整图像分辨率、数据扩增等预处理;其次,通过颜色空间的转换,将眼底图像由 BGR 通道转换为 J(亮度)C(色度)H(色相)通道,对 JH 通道进行自适应直方图均衡化,将处理后的 JCH 通道图转换回 BGR 通道图;最后,按照权重将处理后的图像与预处理后的图像进行融合生成新的眼底图像。将新生成的图像归一化处理之后作为改进的 DenseNet201 模型的输入图像,经过模型后输出预测

结果。本文提出的 HR 分类方法的敏感性、特异性、准确率分别达到 97.09%、98.79%、98.67%,与现有的 HR 分类方法进行分析对比,本文提出的 HR 分类方法效果更佳。在下一步的工作中将采用更先进的图像分类模型对 HR 进行分类,在数据集有保障的情况下将尝试对 HR 进行 5 期分类,提高 HR 分类实验的实际应用价值。

参考文献

- [1] WONG T Y, MITCHELL P. Hypertensive retinopathy[J]. New England Journal of Medicine, 2004, 351(22):2310-2317.
- [2] BHARGAVA M, IKRAM M K, WONG T Y. How does hypertension affect your eyes? [J]. Journal of Human Hypertension, 2012, 26(2): 71-83.
- [3] 唐森. OCTA 应用于轻度高血压性视网膜病变微血管的筛查[J]. 南通大学学报(医学版), 2023, 43(2):189-191.
- [4] LI C, YE J, HE J, et al. Dense correlation network for automated multi-label ocular disease detection with paired color fundus photographs[C]//Proceedings of 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI). IEEE, 2020: 1-4.
- [5] 郭东琳. 人工智能在眼底影像分析中的研究进展及应用现状[J]. 眼科学报, 2022, 37(3):185-193.
- [6] KHITRAN S, AKRAM M U, USMAN A, et al. Automated system for the detection of hypertensive retinopathy[C]//Proceedings of 2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA). 2014:1-6
- [7] SYAHPUTRA M F, AMALIA C, RAHMAT R F, et al. Hypertensive retinopathy identification through retinal fundus image using backpropagation neural network [J]. Journal of Physics: Conference Series. IOP Publishing, 2018, 978(1): 012106.
- [8] KIRUTHIKA M, SWAPNA T R, SANTHOSH K C, et al. Artery and Vein classification for hypertensive retinopathy [C]//Proceedings of 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI). IEEE, 2019: 244-248.
- [9] 王伟,浦一雯. 区域特征融合的高血压视网膜病变分类方法[J]. 计算机工程与应用, 2022, 58(8):230-236.
- [10] KOKUFUTA K, MARUYAMA T. Real-time processing of contrast limited adaptive histogram equalization on FPGA [C]//Proceedings of 2010 International Conference on Field Programmable Logic and Applications. IEEE, 2010: 155-158.
- [11] 任吉宏,刘畅. 基于自适应超像素的少样本极化 SAR 图像特征增强方法研究[J]. 电子技术应用, 2022, 48(10):144-149.
- [12] 朱俊东,卓广平,吴诗雨,等. 基于迁移学习的糖尿病视网膜病变的分类检测[J]. 中北大学学报(自然科学版), 2023, 44(4): 478-486.
- [13] THWAITES A, WINGFIELD C, WIESER E, et al. Entrainment to the CIECAM02 and CIELAB color appearance models in the human cortex[J]. Vision Research, 2018, 145:1-10.
- [14] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision (ECCV). 2018: 3-19.
- [15] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 4700-4708.