

DOI: 10.19650/j.cnki.cjsi.J2311740

基于并联多尺度卷积神经网络的微动脉瘤检测方法

苑玮琦¹, 王安^{1,2}

(1. 沈阳工业大学视觉检测技术研究所 沈阳 110870; 2. 佳木斯大学信息电子技术学院 佳木斯 154007)

摘要: 由于视网膜图像中微动脉瘤尺寸小、背景干扰多,导致传统方法检测时准确率低,现阶段的深度学习模型大多针对大尺寸目标进行检测,存在结构复杂、对小目标的检测效果不佳的问题。为解决以上问题,提出了一种基于并联多尺度卷积神经网络的微动脉瘤检测方法。首先,建立微动脉瘤尺寸与检测用理论感受野之间的对应关系;然后,根据微动脉瘤的类型和尺寸范围构建包含两个感受野尺度的并行卷积网络;最后,提出了一种基于主动学习的训练集构建与数据增广方式,以提高模型的检测性能。方法在两个公开数据集和1个自采眼底数据集中进行了对比实验,实验结果表明,该方法能有效实现微动脉瘤的检测,相比于同类方法对于小尺寸和与血管粘连的微动脉瘤具有更好的检测效果。

关键词: 卷积神经网络;微动脉瘤检测;感受野;数据增广

中图分类号: TP391.41 TH786 **文献标识码:** A **国家标准学科分类代码:** 510.40

Microaneurysm detection method based on parallel multi-scale convolution neural network

Yuan Weiqi¹, Wang An^{1,2}

(1. Computer Vision Group, Shenyang University of Technology, Shenyang 110870, China; 2. College of Information Science and Electronic Technology, Jiamusi University, Jiamusi 154007, China)

Abstract: Due to the small size and high background interference of microaneurysms in retinal images, traditional methods have low detection accuracy. Currently, deep learning models mostly focus on detecting large-sized targets, which have complex structures and poor detection performance for small targets. To address these issues, a micro aneurysm detection method based on parallel multi-scale convolutional neural networks is proposed. Firstly, a corresponding relationship between the size of microaneurysms and the theoretical receptive field used for detection is established. Then, a parallel convolutional network consisted of two receptive field scales is constructed, which is based on the type and size range of microaneurysms. Finally, a training set construction and data augmentation method based on active learning is proposed to improve the detection performance of the model. The method is compared on two public datasets and one self-collected fundus dataset. The experimental results show that the method can effectively detect microaneurysms, and has better detection performance compared to similar methods for small and vascular adherent microaneurysms.

Keywords: convolution neural network; microaneurysm detection; receptive field; data augmentation

0 引言

微动脉瘤是血管壁削弱而引起的毛细血管膨胀,多位于视网膜深层,是眼底图像中一种典型的眼底异常表现,与糖尿病视网膜病变、高血压性视网膜病变和老年性黄斑病变等多种疾病密切相关^[1]。利用计算机技术对微

动脉瘤进行准确检测,对于眼底疾病的诊疗和病情的评估具有重要意义。

视网膜图像中微动脉瘤的检测方法一般可以分为基于传统图像处理的方法、基于分类器的方法和基于深度学习的检测方法。基于传统图像处理的方法主要根据微动脉瘤的灰度形态分布建立数学模型,并采用传统图像处理算法进行分割。Lazar等^[2]提出了一种基于微动脉

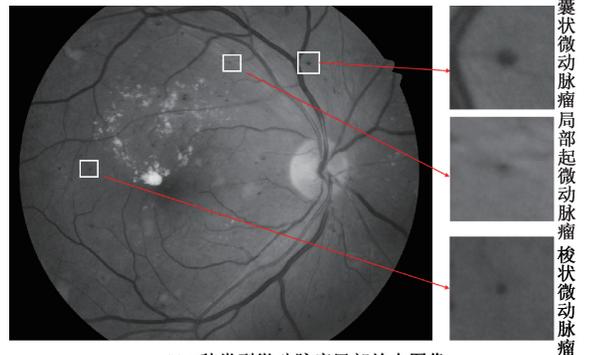
瘤剖面轮廓形态的方法来检测视网膜图像上的微动脉瘤,方法对于与微动脉瘤剖面轮廓形态类似的出血点和背景中的暗点易出现误检。张东波等^[3]采用背景估计和血管提取技术进行微动脉瘤检测,方法受背景估计时选用的阈值影响,存在低对比度微动脉瘤的漏检和血管片段的误检。基于分类器的方法首先对微动脉瘤候选目标进行提取,然后通过不同分类器对候选目标进行分类。Dashtbozorg 等^[4]使用梯度加权法和迭代阈值提取微动脉瘤候选点,通过 boosting 分类器区分出真正的微动脉瘤。Pendekal 等^[5]首先使用形态学重构方法提取微动脉瘤候选点,然后采用集成分类器对候选点进行分类。这两种方法受微动脉瘤候选点提取的准确性和分类器特征的有效性影响,对于小尺寸和低对比度的微动脉瘤存在漏检。基于深度学习的方法主要包含基于语义分割的方法和基于目标检测的方法。基于语义分割的方法主要通过不同结构的卷积神经网络模型对微动脉瘤进行像素级分割。Chudzik 等^[6]提出了一种基于全卷积神经网络的微动脉瘤检测方法,方法由于使用了多次池化操作,造成小尺寸微动脉瘤信息的缺失和漏检。赵学功等^[7]提出一种简单结构的全卷积网络进行微动脉瘤检测,由于网络感受野尺度单一导致检测结果中出现漏检。基于目标检测的方法通过卷积神经网络预测目标的位置和类别。Jung 等^[8]采用 Faster-RCNN 模型对微动脉瘤进行检测,受网络结构的影响小尺寸微动脉瘤存在漏检。Rohan^[9]提出了一种基于 YOLO 的微动脉瘤检测方法,受锚框尺寸和网络结构影响,存在小尺寸微动脉瘤漏检和定位精度不高的问题。Pal 等^[10]提出了改进的 YOLOv3 的微动脉瘤检测算法,通过使用多尺度特征融合的结构,提高了小尺寸微动脉瘤的检测精度。

综上所述,传统图像处理和分类器方法受参数和人工特征选择的影响较大,对于低对比度和小尺寸微动脉瘤存在较多漏检。深度学习方法存在如下问题:1)网络感受野与目标尺寸不匹配,导致目标特征信息提取不准确;2)通用卷积神经网络模型包含多次池化,对于直径仅为几个像素的小尺寸微动脉瘤易导致特征消失;3)视网膜图像中微动脉瘤与背景之间的像素比例以及不同类型微动脉瘤的数量存在严重不均衡,直接使用原始图像进行训练易导致模型分类能力下降。为解决以上问题,本文提出了一种基于并行多尺度卷积神经网络的微动脉瘤检测方法。首先,通过实验建立微动脉瘤尺寸与检测网络理论感受野之间的关系,解决了网络感受野与微动脉瘤尺寸的匹配问题;然后,检测模型采用由 1 个滤波层和 3 个卷积层构成的简单结构,在简化模型复杂度的同时,避免了池化造成的小尺寸目标漏检;最后,按微动脉瘤类型剪裁出图像块,并通过主动学习方法从中筛选出训练集样本,解决了样本分布不均匀和训练集构建的问题。

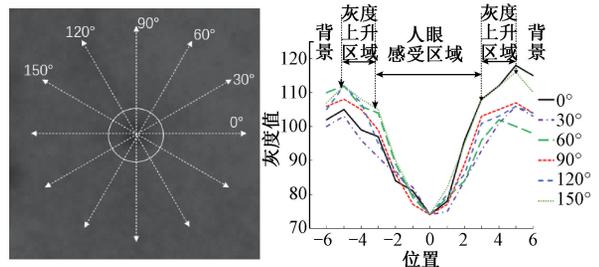
1 微动脉瘤分类与图像特征分析

为了简化网络结构,首先采用双线性插值方法将视网膜图像的水平分辨率调整为 1 440 pixels,然后按水平分辨率缩放比例对垂直分辨率进行缩放,最后提取彩色图像 RGB 3 个通道中微动脉瘤和背景对比度最高的绿色通道进行微动脉瘤检测。

根据微动脉瘤与血管的位置关系,微动脉瘤通常被分为 3 类,局部隆起、囊状和梭状^[11]。当微动脉瘤直径 < 2 倍其所围绕的血管宽度时,被归类为局部隆起;当微动脉瘤直径 > 2 倍其所围绕的血管宽度,且围绕血管长轴呈现不对称扩张时,被归类为囊状;当微动脉瘤直径 > 2 倍其所围绕的血管宽度,且围绕血管长轴呈现对称扩张时,被归类为梭状。3 种类型微动脉瘤的局部放大图像如图 1(a) 所示。



(a) 3 种类型微动脉瘤局部放大图像
(a) Localized enlarged images of three types of microaneurysms



(b) 微动脉瘤沿不同方向灰度分布
(b) Gray distribution of microaneurysms in different directions

图 1 微动脉瘤图像示例

Fig. 1 Image example of microaneurysm

图库分析发现,微动脉瘤沿不同方向的剖面灰度分布曲线均呈现倒置高斯曲线形态,包含人眼感受区域、灰度值持续上升区域和背景区域 3 个部分,如图 1(b) 所示。人眼感受区域是人眼对微动脉瘤所在区域的直观感受,其边缘为目标内部梯度变化最大的部分;灰度持续增高区域包含了微动脉瘤在梯度产生最大变化后持续的梯度变化信息;灰度平缓变化区域完全反映了微动脉瘤外部的背景信息。分辨率调整后的图像中,人眼感受微动

脉瘤区域的直径范围为5~16 pixels,其中囊状和梭状微动脉瘤的直径范围为9~16 pixels,局灶性隆起微动脉瘤的直径范围为5~9 pixels。

2 检测模型的建立与相关算法

2.1 微动脉瘤尺寸与检测网络感受野关系的建立

卷积神经网络利用卷积获取图像特征,并利用提取特征进行目标分类,卷积在图像中的覆盖区域表示网络提取出的特征范围,可以近似的用理论感受野表示^[12],当理论感受野与目标尺寸相匹配时,模型能获得最佳检测性能。微动脉瘤在水平和垂直方向剖面曲线中人眼感受区域之间距离的最大值定义为微动脉瘤的尺寸,微动脉瘤尺寸与检测所用理论感受野关系的表达式定义为:

$$T = k \times G \quad (1)$$

式中: G 为理论感受野直径; T 为微动脉瘤尺寸; k 为微动脉瘤尺寸与理论感受野直径的比值。

实验采用的卷积神经网络模型如图2所示,通过比较不同 k 值下模型分类的准确率,选择最佳 k 值范围。选取IDRiD眼底数据集中 $T=7$ 的局部隆起微动脉瘤、 $T=11$ 的囊状和梭状微动脉瘤,通过中心点裁剪为132 pixels×132 pixels的图像块后建立3组实验图像库。每组图像库的训练集包含正、负样本图像块各480张,测试集包含正、负样本图像块各120张。实验通过重新进行中心点剪裁调整微动脉瘤占图像比例 k ,通过改变卷积层中卷积核大小调整理论感受野直径 G 。

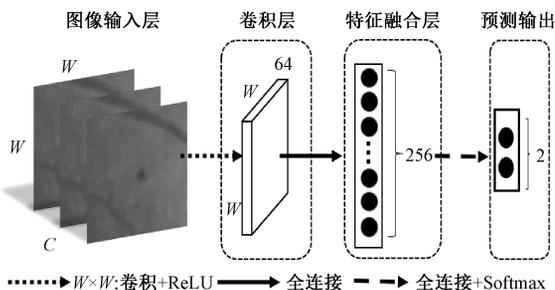


图2 实验用卷积神经网络模型

Fig. 2 Convolutional neural network model for experiment

3组图库中测试集分类准确率随 k 值的变化曲线如图3所示,3个曲线均呈现相同的变化趋势。当 k 值较小时,测试结果中正负样本的分类错误数量均较多,导致准确率较低;随着 k 值增大,准确率逐渐上升,在 $k=0.4\sim 0.7$ 时准确率达到最高且基本保持恒定;当 k 值大于0.7后,负样本分类错误数量增加,导致准确率下降。因此,为了让模型分类准确率最高, k 的最佳取值区间选择为0.4~0.7。

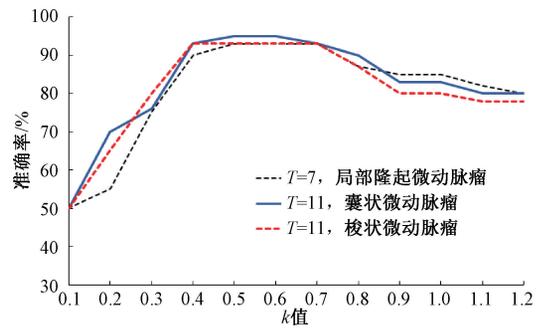


图3 不同 k 值的准确率曲线

Fig. 3 Accuracy curves for different k values

2.2 网络理论感受野的选择

根据式(1)和 k 的取值范围,计算得到的不同尺寸微动脉瘤检测所需的最佳理论感受野范围如图4所示。局部隆起、囊状和梭状3类微动脉瘤检测所用最佳理论感受野的选取方法如下:首先为尺寸5~9 pixels的局部隆起微动脉瘤选取检测所需理论感受野,直径为13 pixels的感受野刚好能覆盖局部隆起微动脉瘤的全部尺寸范围,故选择直径为13 pixels的感受野构建局部隆起微动脉瘤的检测网络;然后为尺寸9~16 pixels的囊状和梭状微动脉瘤选取检测所需理论感受野,直径为23 pixels的感受野刚好能覆盖囊状和梭状微动脉瘤的全部尺寸范围,故选择直径为23 pixels的感受野构建囊状和梭状微动脉瘤的检测网络。

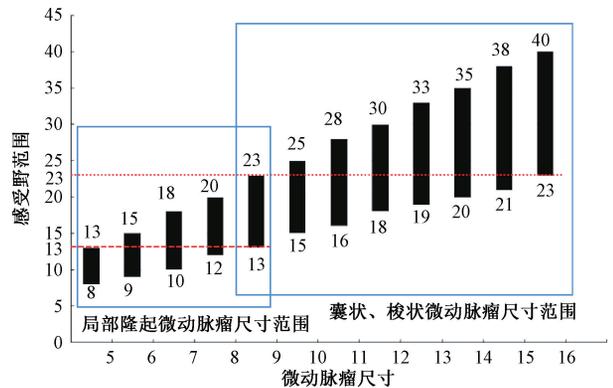


图4 不同尺寸目标的感受野范围

Fig. 4 Receptive field range of different sizes targets

2.3 检测模型结构设计

根据微动脉瘤尺寸与所用理论感受野的关系,检测模型采用两个感受野尺度并联的卷积神经网络进行3种类型微动脉瘤的检测,使用13×13感受野网络检测局部隆起微动脉瘤,使用23×23感受野网络检测囊状和梭状微动脉瘤。两个感受野尺度检测网络结构相同,仅特征提取层使用的卷积核大小和最终输出通道数量不同,检测网络整体结构如图5所示。

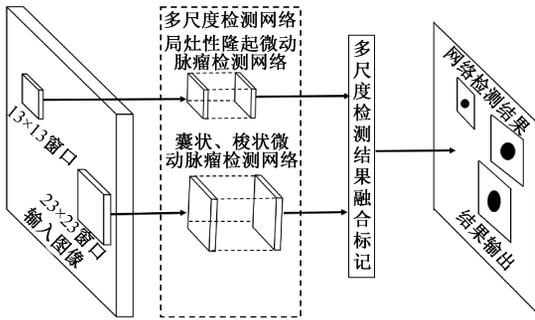


图 5 检测模型整体结构

Fig. 5 Structured design diagram of detection model

本文改进了图 2 中的模型结构,作为两个并行尺度的检测模型。图 2 中的模型采用剪裁后的图像块进行训练,能有效改善样本分布不均衡对检测性能的影响,但对于大尺寸图片需要通过逐点滑动方式在图像上裁剪出图像块送入网络进行类别判断,时间成本较高。针对这一问题,本文用 1×1 卷积替代全连接,通过卷积方式实现滑动窗口检测,并加入滤波层以降低微动脉瘤内部曲面的复杂度。改进后的两个并行检测网络结构如图 6 所示,包括图像输入层、滤波层、卷积层、特征融合层和预测输出层 5 个部分。

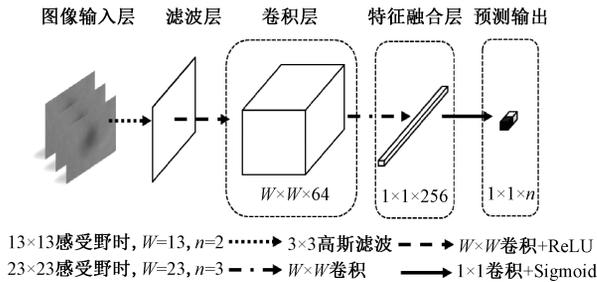


图 6 并行卷积网络分支结构

Fig. 6 Branch Structure of parallel convolution network

1) 图像输入层。图像输入层负责提取图像块送入网络进行分类,本文中两个尺度输入层的图像尺寸和模型卷积层卷积核大小一致,分别为 13×13 、 23×23 。

2) 滤波层。滤波层负责对微动脉瘤曲面内部干扰进行抑制,降低曲面的复杂度,减小样本之间的形态差异。高斯滤波器的形态与微动脉瘤剖面灰度分布形态相似,将其与视网膜图像卷积,可实现微动脉瘤内部干扰的抑制和曲线平滑。高斯卷积滤波公式为:

$$r(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{-(x-k-1)^2 + (y-k-1)^2}{2\sigma^2}} \cdot f(x, y) \quad (2)$$

式中: $r(x, y)$ 为滤波后图像; $f(x, y)$ 为视网膜图像中坐标为点 (x, y) 的灰度值; σ 为高斯函数的标准差; 高斯滤波器的窗口大小为 $(2k + 1) \times (2k + 1)$ 。根据对微动脉

瘤内部噪声的观察,其宽度位于 $1 \sim 3$ pixels 之间。故滤波器的窗口大小选择 3 pixels,即 $k = 1$ 。标准差 σ 采用文献[13]的方法,计算公式为:

$$\sigma = 0.3 \times (k - 1) + 0.8 \quad (3)$$

3) 卷积层。卷积层负责提取目标特征,参考文献[14]分析大尺度卷积核比多个小尺度卷积核串联使用更易获取目标的形状特征,因此本文使用单个 64 通道尺寸为 $W \times W$ 的卷积核进行特征提取, W 与网络的感受野尺寸一致,每个卷积层后应用 ReLU 函数以解决梯度消失和过拟合。两个尺度网络中 W 的取值为 13 和 23。

4) 特征融合层。特征融合层负责对卷积层提取的多通道特征进行融合和降维。特征融合层采用一个与网络感受野大小一致的卷积层,将特征图尺寸压缩为 $1 \times 1 \times 256$,实现不同层特征之间的非线性组合。

5) 预测输出层。预测输出采用一个通道数为 n 的 1×1 卷积将特征映射为不同类别目标与背景,并通过 Softmax 函数逻辑回归,将输出结果调整到 $0 \sim 1$,以表示结果属于不同类别微动脉瘤和背景的概率, 13×13 感受野网络中 $n = 2$, 23×23 感受野网络中 $n = 3$ 。

2.4 检测结果的融合与标记

视网膜图像在经过模型检测后会输出 3 个类别微动脉瘤检测结果的概率图,如图 7(a)~(c)所示,图中像素点颜色的深浅反映该点为微动脉瘤中心点的概率,白色表示概率值高,黑色表示概率值低。本文首先根据式(4)对 3 个类别概率图像分别进行二值化,去除所有低概率检测结果;其次对分割后的二值化图像进行连通域检测,寻找目标可能存在区域;再次对连通域内每个像素点的概率值进行排序,保留概率值最大的点作为目标中

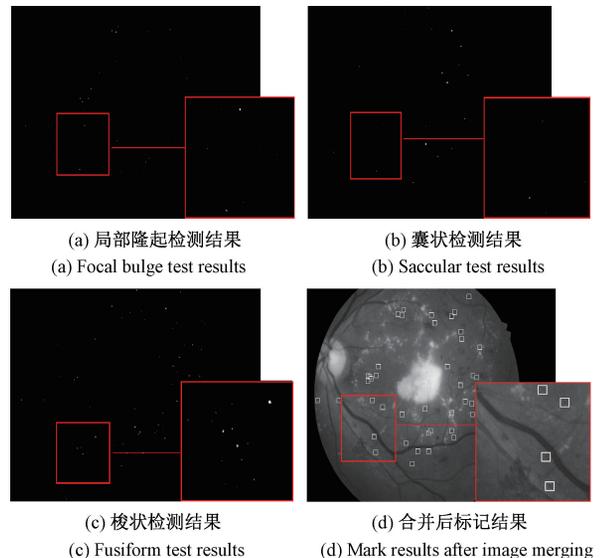


图 7 检测结果与标记

Fig. 7 Detection result and mark

心点,当存在多个最大值点时保留位置最接近连通域中心的点作为目标中心点;最后以提取目标中心点为中心,以 16×16 大小方框对目标所在位置进行标记,标记后的结果如图7(d)所示。

$$I_b = \begin{cases} 1, & I(x, y) > T_0 \\ 0, & I(x, y) \leq T_0 \end{cases} \quad (4)$$

式中: $I(x, y)$ 为结果概率图; T_0 为分割概率阈值,根据实验在局部隆起、囊状和梭状3个类别概率图中取值分别为0.92、0.85、0.86; I_b 为二值化后的图像。

2.5 损失函数

本文在训练过程中使用交叉熵损失函数^[15]分别对两个尺度网络模型计算损失,损失函数为:

$$C(w, p(w|y)) = - \sum_{i=1}^N [w_i \ln p(w_i | y_i) + (1 - w_i) \ln (1 - p(w_i | y_i))] \quad (5)$$

式中: w 表示预测概率值; y 表示像素标签; $p(w|y)$ 表示标签为 y 的概率; N 表示每个小批量样本数量。

3 数据来源与训练数据集构建

3.1 数据来源

本文实验所用数据来自公开眼底图像数据集 e_ophtha_MA^[16]、IDRiD^[17]和自采眼底数据集。e_ophtha_MA数据集是法国研究机构在2008~2009年由多种型号眼底相机拍摄得到,视场角为 $35^\circ \sim 50^\circ$,包括148幅含有微动脉瘤的图像,分辨率为 $1\,440 \times 960$ 、 $2\,048 \times 1\,360$ 、 $2\,544 \times 1\,696$ 、 $1\,504 \times 1\,000$ 。IDRiD数据集是印度 Sushrushta 医院在2009~2017年由 Kowa VX-10 alpha 眼底相机拍摄得到,视场角为 50° ,包含81幅图像并划分出54幅训练集图像和27幅测试集图像,每幅图像的分辨率均为 $4\,288 \times 2\,848$ 。自采眼底数据集是中国医科大学附属第一医院在2018~2020年由 TRC-NW300 眼底相机拍摄得到,视场角为 45° ,共包括90幅包含微动脉瘤的图像,分辨率为 $2\,048 \times 1\,536$ 。本文按类别对 IDRiD、e_ophtha_MA 和自采眼底数据集中的微动脉瘤进行标注,标注后3个数据集中局部隆起、囊状和梭状3种类型微动脉瘤的数量如表1所示。

表1 不同类别微动脉瘤数量

Table 1 Number of microaneurysms in different categories

图像块类别	局部隆起	囊状	梭状
IDRiD 训练集	555	435	345
IDRiD 测试集	388	240	172
e_ophtha_MA	347	201	143
自采眼底数据集	189	165	123

3.2 训练集图像块裁剪与标注

本文从 IDRiD 数据集的54幅训练集图像中裁剪图像块用于模型训练,采用 IDRiD 测试集、e_ophtha_MA 数据集和自采眼底数据集中所有图像用于模型测试。训练集图像块裁剪与标注方法如下。

1) 微动脉瘤样本图像块裁剪。以图像中微动脉瘤中心点为中心,裁剪出 41×41 大小的图像块。

2) 背景样本图像块裁剪。以非微动脉瘤区域为中心,裁剪出 41×41 大小的图像块作为背景样本。

3) 样本标注与图像块二次裁剪。 13×13 感受野网络用于检测局灶性隆起微动脉瘤,将裁剪出的局部隆起微动脉瘤图像块标记为“1”,裁剪出的背景样本、囊状微动脉瘤和梭状微动脉瘤标记为“0”,采用中心裁剪为 13×13 大小后用于训练。 23×23 感受野网络采用多分类方式同时检测囊状和梭状微动脉瘤,将裁剪出的囊状微动脉瘤图像块标记为“2”,梭状微动脉瘤图像块标记为“3”,背景图像块和局灶性隆起微动脉瘤图像块标记为“4”,采用中心裁剪为 23×23 大小后用于训练。裁剪出的局部隆起微动脉瘤、囊状微动脉瘤、梭状微动脉瘤和背景图像块示例如图8所示。

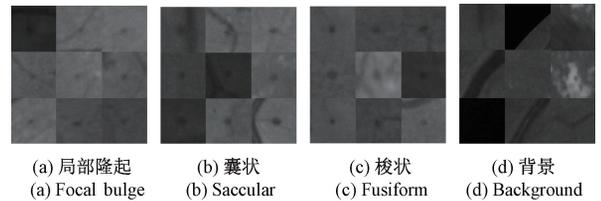


图8 不同类别图像块示例

Fig. 8 Examples of image block of different categories

3.3 训练集数据选择与增广

为了提高网络模型的检测性能,减少训练集中裁剪图像块的数量,本文设计了一种基于主动学习的训练集数据选择与增广策略。

1) 初始化训练样本。通过人工筛选的方式从原始未裁剪训练图像集 Ω 中挑选形态相差较大的正、负样本,裁剪出图像块后采用水平和垂直翻转将样本数量扩大为原来的4倍,作为初始化训练集样本 X 。

2) 模型训练。将训练集 X 中所有样本图片送入模型进行训练,当损失函数平稳不再下降时停止训练,保存模型 M 。

3) 图像测试。将原始未裁剪训练图像集 Ω 中的所有图片送入模型 M 进行检测,输出图像中每个像素点 y_i 的分类概率 $P_{y_i}^{cls_j}$,公式为:

$$P_{y_i}^{cls_j} = M(y_i) \quad (6)$$

式中: cls_j 表示第 j 个类别; j 表示类别个数。

4) 像素点类别确定。选择像素点 y_i 分类概率 $P_{y_i}^{cls}$ 最大的类别作为该点类别 C_{y_i} , 公式为:

$$C_{y_i} = \arg \max(P_{y_i}^{cls_1}, P_{y_i}^{cls_2}, P_{y_i}^{cls_3}, \dots) \quad (7)$$

5) 寻找分类错误样本。对每个类别检测结果进行连通域检测, 每个连通域作为一个目标, 并与图像中原始类别标记结果比较, 寻找分类错误样本。

6) 对分类错误样本进行图像块裁剪和标记, 采用水平和垂直翻转进行数据扩充后放入训练集 X , 从步骤 2) 开始重新迭代, 直到分类错误样本不再变化时停止。最终得到 392 张局部隆起微动脉瘤图像块、588 张囊状微动脉瘤图像块、512 张梭状微动脉瘤图像块和 1 812 张背景图像块。

4 实验结果与分析

4.1 实验系统配置与参数设置

本文实验系统配置为 Windows10 操作系统、2.6 GHz Intel Core i5-11400F CPU、32 G DDR 内存、NVIDIA RTX 3060 12 G 独立显卡配置的计算机, 编程语言为 Python 3.8, 模型的训练和测试均采用 Pytorch 框架。两个尺度网络均采用带动量因子的小批量梯度下降法训练, 动量设置为 0.9, 初始学习率设置为 0.01。

4.2 实验评价标准

本文采用微动脉瘤的正确检测数量 (true positive, TP)、漏检数量 (false negative, FN)、误检数量 (false positive, FP) 和精确率 (precision, P)、召回率 (recall, R)、F-score 指标作为模型检测性能的评价标准, 同时采用浮点运算数 (FLOPs) 对算法计算量进行评价, 并结合参数量和推理时间对算法效率进行评价^[18]。

TP 为检测结果区域存在某一类微动脉瘤且实际也存在该种类微动脉瘤的个数; FP 为检测结果区域存在某一类微动脉瘤而实际在该位置不存在该种类微动脉瘤的个数; FN 为检测结果区域不存在某一类微动脉瘤而实际存在该种类微动脉瘤的个数。

P、R 和 F-score 的定义为:

$$P = TP / (TP + FP) \quad (8)$$

$$R = TP / (TP + FN) \quad (9)$$

$$F - Score = 2 \times P \times R / (P + R) \quad (10)$$

4.3 不同训练集构建方法性能对比实验

为了检验本文所提出训练集构建方法的有效性, 与随机剪裁方法^[19]、选择性采样方法^[20]在 IDRiD 数据集上进行对比验证, 并从正确检测数量、漏检数量、误检数量、精确率、召回率和 F-score 指标上进行对比验证, 结果如表 2 所示。通过观察可知, 本文方法在各项指标上均优于其他两种方法, 证明了本文训练集构建方法的有效性。

表 2 不同训练集构建方法性能对比

Table 2 Performance comparison of different training set construction methods

指标	方法	局部隆起	囊状	梭状	总体
TP	文献[19]	297	216	154	697
	文献[20]	345	219	158	722
	本文	363	228	165	756
FN	文献[19]	91	24	18	133
	文献[20]	43	21	14	78
	本文	25	12	7	44
FP	文献[19]	97	55	39	191
	文献[20]	70	38	26	134
	本文	48	25	19	92
P	文献[19]	0.776	0.797	0.801	0.791
	文献[20]	0.831	0.865	0.859	0.851
	本文	0.883	0.901	0.897	0.893
R	文献[19]	0.869	0.901	0.912	0.894
	文献[20]	0.889	0.913	0.905	0.902
	本文	0.936	0.950	0.959	0.945
F-score	文献[19]	0.820	0.846	0.853	0.840
	文献[20]	0.859	0.888	0.881	0.876
	本文	0.909	0.925	0.926	0.920

4.4 模型滤波层消融实验

为了检验本文模型中滤波层对检测性能的影响, 采用消融实验对比分析了本文模型在去除滤波层前后的漏检总数和误检总数, 实验使用本文提取的训练集图像块进行训练, 使用 IDRiD 测试集进行测试, 结果如表 3 所示。由表 3 可知, 本文模型检测结果中的漏检和误检数量均明显小于去除滤波层的模型, 具有更好的检测性能。性能提高的主要原因是滤波层对微动脉瘤内部曲线进行了平滑, 降低了微动脉瘤内部曲面的复杂程度, 提高了微动脉瘤之间的相似程度。

表 3 滤波层消融实验中微动脉瘤漏检和误检数量
Table 3 Microaneurysms number of missed and false detection in filter layer ablation experiments

指标	去除滤波层模型	本文模型
FN	108	44
FP	168	92

4.5 同图库测试实验结果与漏检、误检情况分析

1) 同图库测试实验结果

使用本文训练集构建方法从 IDRiD 训练集中提取的图像块进行训练,使用 IDRiD 测试集图像进行测试,得到微动脉瘤 3 个类别和总体的检测结果如表 4 所示。

表 4 微动脉瘤检测结果

Table 4 Microaneurysm detection results

指标	局部隆起	囊状	梭状	总体
总数量	388	240	172	800
<i>TP</i>	363	228	165	756
<i>FN</i>	25	12	7	44
<i>FP</i>	48	25	19	92
<i>P</i>	0.883	0.901	0.897	0.893
<i>R</i>	0.935	0.950	0.958	0.945
F-score	0.909	0.925	0.926	0.920

2) 漏检、误检和异常目标检测情况分析

部分微动脉瘤由于受到光照和病变干扰,在图像中的形态发生改变,训练集中缺少相应形态的样本,无法获得该类微动脉瘤的有效特征出现漏检,漏检样本如图 9(a)所示。后期通过向训练集添加对应样本可降低该类漏检发生。眼底病变有时会使血管断裂出现孤立的血管片段,其在形态和尺寸上均符合微动脉瘤的特征,从而产生误检,如图 9(b)所示。将误检样本作为负样本添加进训练集重新训练,可降低该类型误检的发生。测试集中存在个别尺寸大于 30 pixels 的异常微动脉瘤,因为与感受野不匹配出现漏检,异常样本如图 9(c)所示。该类目标数量极少,缺少训练和测试数据,在增加对应感受野网络进行检测的情况下也难以获得较好性能。

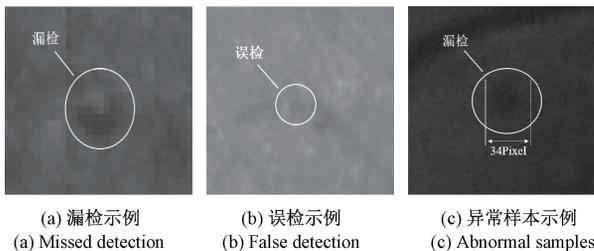


图 9 漏检和误检图像示例

Fig. 9 Missed and false detection image example

4.6 算法效率分析

对比了本文方法和 Faster-RCNN 方法^[8]、YOLOv3 模型^[10]的计算量 (FLOPs)、参数量和推理时间指标,如表 5 所示。推理时间为 IDRiD 测试集中所有图片推理时

间的平均值。本文方法在计算量 (FLOPs)、参数量上较另外两种方法均有所减小,原因是本文方法使用了简单的卷积神经网络结构,模型的参数量得到了降低所致。在推理时间上本文方法多于其他两种方法,原因是本文方法在后续处理中的分割和标记增加了时间消耗。

表 5 算法复杂度对比

Table 5 Algorithm complexity comparison

方法	FLOPs/G	参数量/M	推理时间/s
文献[8]	295.3	60.1	0.415
文献[10]	343.4	62.0	0.383
本文	196.8	41.7	0.812

4.7 同图库测试实验中相关算法检测能力对比

为了验证所提出方法在采用 IDRiD 图库中图像进行训练和测试时的性能,与分类器方法^[5]、Faster-RCNN 模型^[8]、YOLOv3 模型^[10]进行对比实验。4 种方法检测结果中的漏检和误检情况如图 10 所示,图中未标注的为正确检测结果。图 10(a)为包含微动脉瘤标记的原始图像块,图 10(b)~(e)依次为分类器方法、Faster-RCNN 模型、YOLOv3 模型和本文方法检测结果中的漏检和误检情况。图 10A 行中包含两个与血管粘连的微动脉瘤,分类器方法对与血管粘连严重的微动脉瘤出现了漏检,原因是微动脉瘤与血管紧密粘连后形态不再孤立,人工选择特征与其相似度变低;Faster-RCNN 模型和 YOLOv3 模型对两个微动脉瘤均出现了漏检,原因是两种方法没有对训练样本进行选择,训练集中与血管粘连样本数量存在不均衡的问题;本文方法对包含与血管粘连样本的囊性微动脉瘤进行单独训练,解决了样本不均衡的问题。图 10B 行包含 6 个小尺寸微动脉瘤,分类器方法和本文方法将其全部检测出来,Faster-RCNN 模型和 YOLOv3 模型受限于模型结构对小尺寸微动脉瘤检测能力不足,出现了不同程度的漏检。图 10C 行包含出血干扰,分类器方法因为人工选择特征的分类能力不足,出现了较多误检;其他 3 种方法有效的学习到了微动脉瘤的特征,避免了漏检。综上所述,在同图库测试实验中,本文方法和其他几种方法对于形态孤立且尺寸较大的微动脉瘤能有效检测;对于与血管粘连和小尺寸微动脉瘤,本文方法检测效果优于其他几种方法。

表 6 为本文方法和分类器方法^[5]、Faster-RCNN 模型^[8]、YOLOv3 模型^[10]在同图库测试实验中总体检测结果的定量分析。分类器方法受人工选则分类特征限制,结果中存在较多误检,导致精确率降低从而影响 F-score 指标。Faster-RCNN 模型、YOLOv3 模型和本文方法具有更强的特征学习能力,检测结果比传统分类器方法精确,使得误检数量更低、精确率更高,但 Faster-RCNN 模型、

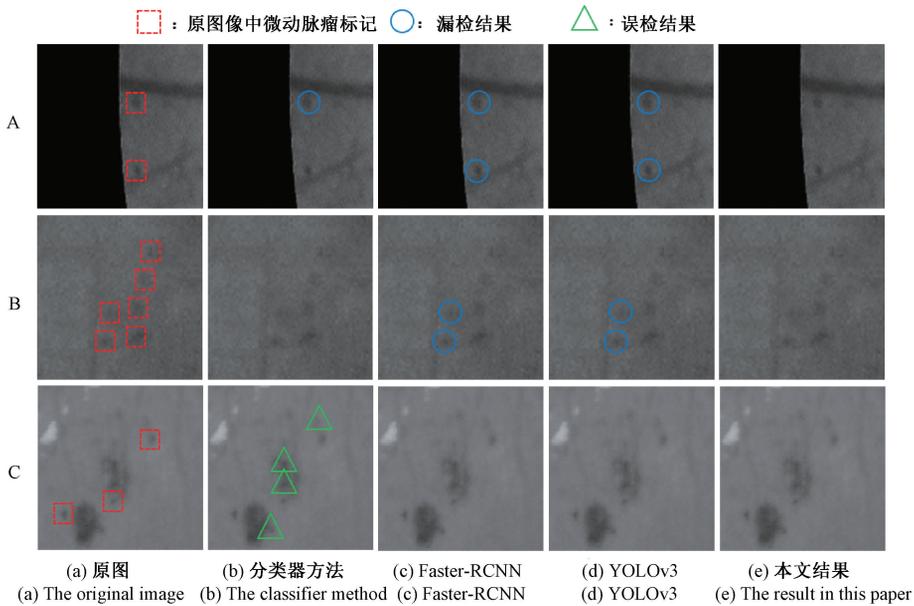


图 10 同图库测试实验中不同方法测试结果的漏检和误检

Fig. 10 Missed and false detection results of different methods in the same dataset testing experiment

表 6 同图库测试结果定量指标

Table 6 Quantitative indicators of testing results in the same library

方法	TP	FN	FP	P	R	F-score
文献[5]	721	79	315	0.696	0.901	0.785
文献[8]	679	121	158	0.811	0.848	0.829
文献[10]	680	120	176	0.794	0.850	0.821
本文	756	44	92	0.893	0.945	0.920

YOLOv3 模型受模型结构和训练集影响,对小尺寸微动脉瘤存在漏检,使得召回率低于分类器方法,而本文方法在一定程度上克服了以上问题,降低了漏检数量和误检数量,提高了召回率。本文方法具有更优越的检测性能。

4.8 交叉训练实验中相关算法检测能力对比

为了进一步验证模型的泛化性,使用本文选择出的 IDRiD 训练集样本进行训练,使用 e_ophtha_MA 数据集和自采眼底数据集进行测试,与分类器方法^[5]、Faster-RCNN 模型^[8]、YOLOv3 模型^[10]进行比较和定量分析,结果如表 7 所示。两个数据集中本文方法在漏检数量、误检数量、精确率和 F-score 指标上均优于其他 3 种方法,相比于采用同一图库进行训练和测试时,分类器方法不依赖于训练集数据提取特征,6 个指标变化较小;Faster-RCNN 模型、YOLOv3 模型和本文方法在检测时,测试集中出现了训练集中未曾包含的微动脉瘤形态和背景干扰,造成检测结果中的漏检数量和误检数量增加,导致精确率和召回率下降,F-score 指标随之下降。对比同一图

库测试实验,本文方法由于受到训练集样本影响,在各项指标上出现了小幅度下降,但对于多数微动脉瘤仍然能够实现正确检测,且性能明显优于 Faster-RCNN 模型、YOLOv3 模型在同一图库测试实验中的表现,结果说明本文方法对于不同数据集具有较好的泛化能力,对微动脉瘤的检测性能提升具有重要作用。

表 7 交叉训练结果定量指标

Table 7 Quantitative indicators of cross training results

数据集	方法	TP	FN	FP	P	R	F-score
e_ophtha_MA	文献[5]	622	69	296	0.678	0.900	0.797
	文献[8]	574	117	180	0.761	0.831	0.794
	文献[10]	563	128	197	0.741	0.825	0.776
	本文	624	67	126	0.831	0.903	0.864
自建数据集	文献[5]	411	66	213	0.658	0.862	0.746
	文献[8]	373	104	142	0.722	0.782	0.751
	文献[10]	368	109	156	0.702	0.771	0.735
	本文	417	60	103	0.802	0.874	0.836

5 结 论

本文提出了一种基于并行多尺度卷积神经网络的微动脉瘤检测方法,在国际公开的 e_ophtha_MA 和 IDRiD 数据集和自采眼底数据集上进行模型训练与验证。本文提出的并行多尺度卷积神经网络模型,能有效提高小尺

寸微动脉瘤的检出率,模型的构建方法可以应用于类似小目标的检测领域。模型中的滤波层,降低了目标内部曲面复杂度,提高了样本之间的相似性和模型的检测性能。基于主动学习的训练集构建方式,减少了训练数据的使用量,提高了模型的检测性能。本文模型相比于 Faster-RCNN 和 YOLOv3 检测模型结构简单,具有更小的计算量、参数量和更优异的检测性能指标,能有效降低与血管粘连微动脉瘤和小尺寸微动脉瘤的漏检数量,具有较好的泛化性能。

参考文献

- [1] RIM T H, TEO A W J, YANG H H S, et al. Retinal vascular signs and cerebrovascular diseases[J]. *Journal of Neuro-Ophthalmology*, 2020, 40(1): 44-59.
- [2] LAZAR I, HAJDU A. Retinal microaneurysm detection through local rotating cross-section profile analysis[J]. *IEEE Transactions on Medical Imaging*, 2012, 32(2): 400-407.
- [3] 张东波,彭英辉,尚星宇,等. 基于背景估计和血管提取眼底图像微脉瘤检测[J]. *仪器仪表学报*, 2013, 34(2):455-461.
ZHANG D B, PENG Y H, SHANG X Y, et al. Microaneurysm detection based on background estimation and finer vessel extraction in retinal image[J]. *Chinese Journal of Scientific Instrument*, 2013, 34(2):455-461.
- [4] DASHTBOZORG B, ZHANG J, HUANG F, et al. Retinal microaneurysms detection using local convergence index features [J]. *IEEE Transactions on Image Processing*, 2018, 27(7): 3300-3315.
- [5] PENDEKAL M J, GUPTA S. An ensemble classifier based on individual features for detecting microaneurysms in diabetic retinopathy [J]. *Indonesian Journal of Electrical Engineering and Informatics*, 2022, 10(1): 60-71.
- [6] CHUDZIK P, MAJUMDAR S, CALIVÁ F, et al. Microaneurysm detection using fully convolutional neural networks [J]. *Computer Methods Programs Biomed*, 2018, 158:185-192.
- [7] 赵学功,邓佳坤,魏浩然,等. 基于卷积神经网络的眼底图像微血管瘤检测方法[J]. *电子科技大学学报*, 2021, 50(6): 915-920.
ZHAO X G, DENG J K, WEI H R, et al. CNN-based microaneurysm detection in fundus images[J]. *Journal of University of Electronic Science and Technology of China*, 2021, 50(6): 915-920.
- [8] JUNG Y, KIM D. Feature extraction of non-proliferative diabetic retinopathy using faster R-CNN and automatic severity classification system using random forest method[J]. *Journal of Information Processing Systems*, 2022, 18(5): 599-613.
- [9] ROHAN R A. FILM: Finding the location of microaneurysms on the retina [J]. *Biomedical Engineering Letters*, 2019, 9(5): 497-506.
- [10] PAL P, KUNDU S, DHARA A K. Detection of red lesions in retinal fundus images using YOLOv3 [J]. *Current Indian Eye Research*, 2020, 7(2): 49-53.
- [11] MOORE J, BAGLEY S, IRELAND G, et al. Three dimensional analysis of microaneurysms in the human diabetic retina [J]. *The Journal of Anatomy*, 1999, 194(1): 89-100.
- [12] LINDEBERG T. A computational theory of visual receptive fields[J]. *Biological Cybernetics*, 2013, 107: 589-635.
- [13] WANG S, ZHU M, HU Y, et al. Accurate detection and localization of curved checkerboard-like Marker based on quadratic form [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-11.
- [14] DING X, ZHANG X, HAN J, et al. Scaling up your kernels to 31×31 : Revisiting large kernel design in cnns[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 11963-11975.
- [15] 刘行谋,田浩,杨永明,等. 复杂环境背景下绝缘子缺陷图像检测方法研究[J]. *电子测量与仪器学报*, 2022,36(2):57-67.
LIU X M, TIAN H, YANG Y M, et al. Research on image detection method of insulator defects in complex background[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(2): 57-67.
- [16] DECENCIERE E, CAZUGUEL G, ZHANG X, et al. TeleOphta: Machine learning and image processing methods for teleophthalmology [J]. *IRBM*, 2013, 34(2):196-203.
- [17] PORWAL P, PACHADE S, KOKARE M, et al. Idrid: Diabetic retinopathy-segmentation and grading challenge[J]. *Medical Image Analysis*, 2020, 59: 1-26.
- [18] 程德强,陈杰,寇旗旗,等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. *仪器仪表学报*, 2022,43(8):73-84.

CHENG D Q, CHEN J, KOU Q Q, et al. Lightweight super-resolution reconstruction method based on hierarchical features fusion and attention mechanism for mine image [J]. Chinese Journal of Scientific Instrument, 2022, 43(8):73-84.

- [19] EFTEKHARI N, POURREZA H R, MASOUDI M, et al. Microaneurysm detection in fundus images using a two-step convolutional neural network [J]. Biomedical Engineering Online, 2019, 18: 1-16.
- [20] VAN GRINSVEN M, VAN GINNEKEN B, HOYNG C B, et al. Fast convolutional neural network training using selective data sampling: Application to hemorrhage detection in color fundus images [J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1273-1284.

作者简介



苑玮琦, 1982 年于湖南大学获得学士学位, 分别在 1988 年和 1997 年于东北大学获得硕士学位和博士学位, 现为沈阳工业大学教授、博士生导师, 主要研究方向为机器视觉和生物特征识别。

E-mail: yuan60@126.com

Yuan Weiqi received his B. Sc. degree from Hunan University in 1982, and received his M. Sc. and Ph. D. degree both from Northeastern University in 1988 and 1997, respectively. He is currently a professor and a Ph. D. advisor at Shenyang University of Technology. His main research interests include machine vision and biometric identification.



王安(通信作者), 2006 年于中南民族大学获得学士学位, 2014 年于哈尔滨理工大学获得硕士学位, 现为佳木斯大学讲师, 沈阳工业大学视觉检测技术研究所博士研究生, 主要研究方向为机器视觉和生物特征识别。

E-mail: wangan8468@126.com

Wang An (Corresponding author) received his B. Sc. degree from South Central University for Nationalities in 2006, and received his M. Sc. degree from Harbin University of Science and Technology in 2014. He is currently a lecturer at Jiamusi University and a Ph. D. candidate in the Computer Vision Group at Shenyang University of Technology. His main research interests include machine vision and biometric identification.