

· 实验研究 ·

基于多尺度卷积神经网络的糖尿病视网膜病变病灶检测算法及应用

杨叶辉¹ 刘佳² 许言午¹ 黄艳¹ 王磊³

¹百度 AI 创新业务部, 北京 100085; ²清华大学医学院生物医学工程系, 北京 100084; ³百度上海研发中心, 上海 201210

通信作者: 王磊, Email: wanglei15@baidu.com

【摘要】 目的 提出一种基于多尺度卷积神经网络(CNN)的眼底图像病灶检测算法,并探讨其在糖尿病视网膜病变(DR)中的应用。**方法** 对比现有眼底病灶检测方法,提出一种基于 CNN 的眼底图像病灶检测算法。本算法不仅克服了基于阈值分割和形态学分割方法鲁棒性差的问题,同时在不依赖人工逐像素标注的前提下,采用多尺度图像块的检测思路,显著提升检测器对小病灶目标检测的性能。此外,提出的新型损失函数在弱标签、小数据集的条件下,实现多类型、高准确率的 DR 病灶检测。**结果** 从病灶水平来看,该算法对硬性渗出病灶检测的敏感性和特异性分别为 92.17% 和 97.17%;相较于单尺度方法,本研究中提出的多尺度方法的敏感性和准确率分别提升了 7.41% 和 5.02%;在公开数据集 IDRiD 上较其他检测方法特异性提高了 55.82%。本方法能够将眼底图像中的病变有效地检测出来,且能够给出病灶的基本范围,对于有大量病灶眼底图像的平均检测时间为 1.59 s。**结论** 基于多尺度 CNN 的眼底图像病灶检测算法能够快速、可靠地识别出眼底图像中的 DR 病灶并标注出病灶的位置信息,降低主观因素的影响,辅助临床医生更加高效、准确地进行 DR 病变筛查。

【关键词】 人工智能; 糖尿病视网膜病变/诊断; 彩色眼底照相; 多尺度卷积神经网络

DOI:10.3760/cma.j.issn.2095-0160.2019.08.007

A novel lesion detection algorithm based on multi-scale input convolutional neural network model for diabetic retinopathy

Yang Yehui¹, Liu Jia², Xu Yanwu¹, Huang Yan¹, Wang Lei³

¹Baidu AI Innovation Business Department, Beijing 100085, China; ²Department of Biomedical Engineering, Medical College of Tsinghua University, Beijing 100084, China; ³Baidu Shanghai R&D Center, Shanghai 201210, China

Corresponding author: Wang Lei, Email: wanglei15@baidu.com

【Abstract】 Objective To propose a multi-scale convolutional neural network (CNN) based lesions detection method of fundus image, and evaluate its application in diabetic retinopathy (DR) assisted diagnosis. **Methods** A multi-scale CNN based on lesions detection method of fundus image was proposed. Compared with the existing detection methods, the problem of poor robustness based on threshold segmentation and morphological segmentation was overcome. The idea of multi-scale grids detection without relying on manual pixel-by-pixel labeling was adopted in this algorithm, and the detection performance of small lesions was significantly improved. In addition, multiple DR lesions with high accuracy could be detected by the proposed loss function under the condition of weak labels and small data sets. **Results** At the level of lesions, the sensitivity and specificity of hard exudation lesions detection were 92.17% and 97.17%, respectively. Compared with single-scale method, the sensitivity and accuracy of multi-scale method proposed in this paper increased by 7.41% and 5.02%, respectively, and compared with other algorithm using the same public dataset IDRiD, the specificity of this algorithm increased by 55.82%. This method could effectively detect the lesions in fundus images, and could give the basic range of the lesions. The average detection time of fundus images with a large number of lesions was 1.59 seconds. **Conclusions** The DR lesions in the fundus image can be quickly and reliably identified, the location information of the lesions can be marked, and the influence of subjective factors can be reduced by using this algorithm, and it can be used to assist the clinician to conduct more effectively.

[Key words] Artificial intelligence; Diabetic retinopathy/diagnosis; Fundus color photograph; Multi-scale convolutional neural network

DOI:10.3760/cma.j.issn.2095-0160.2019.08.007

糖尿病视网膜病变(diabetic retinopathy, DR)是糖尿病严重的微血管并发症之一,其主要特征是视网膜屏障破坏所致的微血管瘤、硬性渗出物和出血等,早期发现和及时干预具有重要的临床意义^[1]。对视网膜彩色照片上异常病灶进行分析是诊断 DR 的重要方法,但 DR 病变表现种类多样,病变复杂,且眼科医生对眼底图像判断存在主观因素多、效率低等问题^[2]。眼底图像病灶检测技术是指对彩色眼底图像中出现的渗出、出血及微动脉瘤等常见病灶与正常眼底组织进行区分和识别,并能够精确定位病灶位置的人工智能(artificial intelligence, AI)技术^[3]。目前 DR 眼底图像病灶检测方法主要包括基于阈值分割^[4-5]、基于形态学分割^[6-7]、基于分类^[8-9]和基于深度学习^[10-12]方法,但阈值法泛化能力很差,基于形态学分割的方法不能很好地区分渗出和反光干扰,基于分类的方法训练模型和检测的过程中计算量大且耗时。因此,传统的检测方法需要针对每种病变设计单独的检测算法,还需要人工设计特征,这些都导致算法的复杂度高、鲁棒性差。基于深度学习的方法,目前有很多研究是进行病灶的像素级分割,但由于该方法很难获得大量的像素级标注数据,训练数据少,常导致算法泛化能力和临床可推广性较差。针对目前算法存在的一系列问题,本研究中提出一种新的基于多尺度输入卷积神经网络(convolutional neural network, CNN)的 DR 眼底图像病灶检测算法,同时探讨基于多尺度 CNN 的眼底图像病灶检测算法在 DR 诊断中的应用。

1 方法

1.1 基于多尺度输入 CNN 的 DR 图像病灶检测算法

1.1.1 预处理 为了解决不同采集设备获取的图像分辨率及图像尺寸差异性大的问题,首先计算原始采集到的眼底图像 I_{ori} 中眼底区域掩膜的尺寸,包括宽和高;然后根据该图像的眼底区域的尺寸计算缩放比例 R ,将原始眼底图像 I_{ori} 按照比例 R 进行重新设置尺寸得到图像 I_{resize} 。由于不同的采集设备采集得到的图像在眼底图像的边缘会有不同的形状标记,以及采集过程中光线的影响造成一些图像的边缘曝光过度而导致很强的噪声,故去除眼底区域的圆形边缘。基于红、绿、蓝(red-green-blue, RGB)的图像中绿色通道信息最丰富、最重要,故对 G 通道的图像进行限

制对比度自适应直方图均衡(contrast limited adaptive histogram equalization, CLAHE),得到 I_f ,减少图像采集造成的图像偏暗、对比度差的问题。根据眼底掩膜尺寸等比例放缩到统一尺寸,降低不同采集设备差异性带来的干扰。

1.1.2 输入数据设计 为了解决医生像素级标注数据的难题,对病灶检测的问题解析为对网格是否有病灶进行分类标记。采用基于等尺寸网格(尺寸为 $patch_size$)的病灶标记方法对病灶进行标记,即首先将 I_f 进行等尺寸网格划分和显示(图 1)。临床眼科医生利用鼠标点击具有病灶的网格,点击后该方格及该 grid 在图像的位置信息同时被保存。然后根据医生标注网格的位置信息获取每个医生标注的网格为中心的 2 个尺寸(尺寸分别为 $patch_size$ 和 $patch_size \times 2$),最终完成每个医生标注的病灶网格数据。




图 1 基于等尺寸网格的 DR 病灶标记方法

对于非病灶的数据获取,考虑到医生标注的时间成本较高,可以直接从正常人眼底图像直接获取,无需医生标注。此外,考虑到糖尿病筛查真实应用场景中大多数为正常人的彩色眼底照片,要求图像的特异性很高,非病灶的 grid 数据获取非常容易,可以获取远超病灶数量的大量非病灶网格。如果网格中包含病变,该网格为正样本,标记为 1;相反则为负样本,标记为 0。此外,考虑到医生标注的样本较少,很多方法采用较少的非病灶样本导致特异性不高的问题,本研究中加入大量易于采集的非病灶样本用于提高算法特异性(图 2)。

1.1.3 模型设计 为了精准、高效地检测识别出病变区域,本研究中提出一种基于多尺度网格联合输入的深度学习病灶分类模型(图 3),具体网络结构组成见

表 1。首先对 2 个不同尺度的网格利用 CNN 分别提取特征,由于现有的 start-of-art 分类网络 (GoogleNet、ResNet、DenseNet 和 XceptionNet 等)均为为图像尺寸 >197 的输入图像设计的,因此根据输入的 2 个尺寸 grids 分别设计 2 个特征提取网络 (图 3)。将 2 个尺度 grids 输入图像获取的特征进行级联,然后利用全局平均池化将最后一层的每个特征图进行一个平均池化操作,形成一个特征点,再将这些特征点组成的特征向量送入深度学习分类器 softmax 进行分类。

本模型的训练目标是不断调整网络参数形成网络学习图像和标签之间的映射关系,使预测值无限接近目标值。考虑到训练数据中负样本比例明显大于正样本、同类样本内部病灶类型较多、同一类病灶也存在较大差异以及不同的病灶数量差异性较大 (即病灶分类任务是一个类间样本分布不均衡、类内样本差异性大且不均衡的问题),其中一部分采用 Lin 等^[13]提出的 focal loss 解决样本不均衡的问题,另一部分采用 Yuan 等^[14]提出的 Jaccard loss 用于提高分类模型的敏感性。

表 1 多尺度病灶检测模型的网络结构参数

输入尺寸为 $(N \times 2, N \times 2)$ 网络		输入尺寸为 (N, N) 网络	
层类型	(滤波器个数) Kernel	层类型	(滤波器个数) Kernel
Input	-	Input	-
Convolution	(64) 3×3		
Convolution	(64) 3×3		
Max pooling	2×2		
Batch Normalization	-		
Convolution	(128) 3×3	Convolution	(64) 3×3
Batch Normalization	-	Convolution	(64) 3×3
Max pooling	2×2	Max pooling	2×2
Convolution	(256) 3×3	Convolution	(128) 3×3
Global Average pooling	-	Global average pooling	-
Dropout (50%)	-	Dropout (50%)	-
Fully connection (output) + softmax			




图 2 预处理及输入数据模块框架图




图 3 模型设计框架图 GAP:全局平均池化层

1.1.4 后处理设计 通过 CNN 提取的特征建立类别映射图 (category map, CAM)^[15],识别出对识别病灶类别重要的关注区域。在最后一个卷积层后面连接全局平均池化层 (global average pooling, GAP),在 GAP 之后是 softmax 激活函数层。将 GAP 的每个像素与 softmax 激活函数层得到每个类别的权重进行加权乘积求和,进而得到每个类别的 CAM。

将每个网格获取到的 CAM 图映射到原图中,原始图像的每个网格替换成 CAM,得到图 4。对网格划分造成的不连续图像采用均值滤波算法进行滤波,使原始图像中相邻网格的病灶关注区域连续且平滑,得到新的病灶区域的重点关注区域,且病灶位置及大小一致性良好的图像。基于该 CAM 图进行迭代阈值处理,获取病灶分割结果,然后再利用轮廓检测算法提取病灶的轮廓信息,将轮廓信息与原图进行叠加 (图 4)。

1.1.5 模型训练设计 采用多步式训练,第一步采用文献[13]中聚焦损失函数的参数设置进行模型训练,当损失函数逐渐收敛、准确率不再增长达到 M 个 epoch 时减小学习率,直到最后学习率改变模型的误差也不再减小则停止训练。然后观察通过第一步训练学习得到的模型敏感性和特异性,如果存在一定的差异性,则减小学习率,同时增大聚焦损失函数中的参数数值,以第一步得到的模型作为初始化模型参数继续进行训练,最终使得敏感性和差异性之间保持平衡。针对敏感性和特异性之间的不平衡,逐步改变聚焦损失函数参数进行优化迭代,不满足于一歩式训练迭代得到的模型结果,进一步提高模型的鲁棒性。

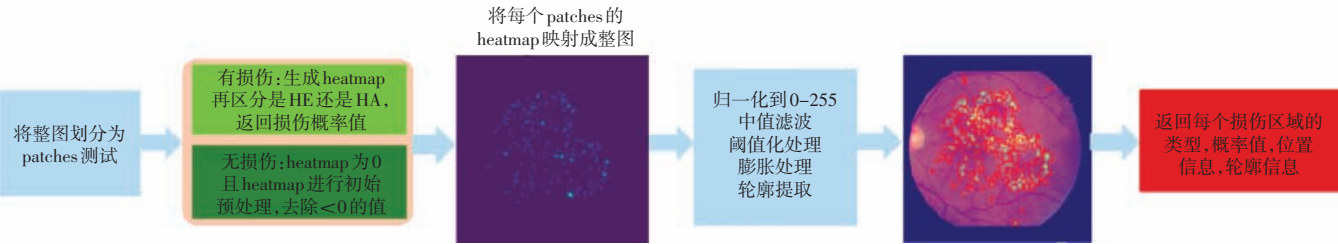


图 4 后处理模块框架图 HE:硬性渗出;HA:出血斑

1.2 实验设置与评价标准

1.2.1 实验数据及设置 采用公开的眼底疾病数据集 IDRiD^[16]。基于临床相关性的国际标准为数据库中的每幅图像提供关于 DR 的疾病严重程度分级和糖尿病性黄斑水肿信息。IDRiD 数据集中的眼底图像来源于印度马哈拉施特拉邦南德的一家眼科诊所采用 Kowa VX-10 alpha 数码眼底照相机用 50°视场拍摄,分辨率为 4 288×2 848,为 24 位彩色 JPG 格式,所有图像均为黄斑区周围。该数据集划分为训练集和测试集,分别包含 54 幅训练集彩色眼底图像以及 27 幅测试集彩色眼底图像。该数据集提供了典型 DR 和正常视网膜结构的专家标记,给出硬性渗出、软性渗出、出血斑以及微动脉瘤的精确像素级标注。将该数据集原始基于像素级标注的训练集数据转换成不同尺寸网格级标注的训练图像,采用该数据库的测试集图像进行测试。

采用 Python 语言,利用 Pycharm 与 Opencv 开发环境,通过 Keras 及 Tensorflow 实现,采用 1 个 Nvidia Tesla K40 GPU 用于模型的训练。

1.2.2 评价标准 本研究中使用病灶水平的评价标准,即判断一个候选区域是否为 DR 病灶,侧重于算法能正确检测出病灶的数量,评价指标包括敏感性、特异性和准确率。

2 结果

2.1 不同尺寸网格级图像分类

从病灶水平来看,本研究提出的多尺度方法比单尺度方法性能更好,具有较高的病灶检测敏感性(表 2),多尺度模型在测试集上对硬性渗出和出血斑等病灶总体检测结果的受试者工作特征曲线(receive operating charastic curve, ROC 曲线)曲线下面积(area under curve, AUC)为 0.952 9(图 5A)。本研究中对硬性渗出的病灶检测的敏感性和特异性分别为 92.17% 和 97.17%,硬性渗出检测模型的 ROC 曲线 AUC 为 0.981 6(图 5B)。

2.2 图像整体病灶检测

从 IDRiD 数据集中挑选 3 组不同患者的彩色眼底

照片,进行本研究中提出算法的有效性验证,结果显示本研究算法可将眼底图像中的病变检测出来,且能够给出病灶的基本范围,其中蓝色轮廓为算法对病灶区域的描绘(图 6)。

表 2 不同网络结构评价指标结果的比较(%)			
网络模型	敏感性	特异性	准确率
单尺度法	82.68	88.27	85.71
多尺度法	90.09	91.67	90.73




图 5 多尺度模型在测试集上的 ROC 曲线 A:测试集上对硬性渗出和出血斑等病灶总体检测结果的 ROC 曲线 AUC 为 0.952 9 B:测试集上对硬性渗出病灶检测结果的 ROC 曲线 AUC 为 0.981 6




图 6 本研究算法的病灶检测结果 Ground Truth 中蓝色代表硬性渗出,绿色代表出血,红色代表微动脉瘤;本研究算法中蓝色轮廓为检测到的病灶区域

2.3 与其他算法及传统病灶检测方法的比较

将本研究算法与同样使用 IDRiD 数据集的基于深度学习算法进行病灶检测的文献[17]的结果进行了比较,文献[17]中仅对硬性渗出病灶进行检测,故仅对硬性渗出病灶检测的敏感性和特异性进行比较,结果显示本研究算法特异性较文献[17]中提高了 55.82% (表 3)。此外,每张眼底图像进行病灶检测的平均时间为 1.59 s,与传统病灶检测方法相比明显缩短。

表 3 与同样使用 IDRiD 其他文献方法评价指标结果的比较 (%)

不同网络模型	敏感性	特异性
本研究	92.17	97.17
文献[17]	98.29	41.35

3 讨论

尽管一些研究者采用基于深度学习的网格分类方法进行病灶检测,但是这些研究采用的网格一般为单一尺寸^[18],而眼底中的病灶种类多,不同种类的病灶尺寸差异性大,采用单一尺寸的网格进行分类和分割一般适合单一类型且病灶形态变化不大的检测。此外,目前深度学习中一些流行的方法,如 Faster-RCNN、YOLO 等也被应用于病灶检测任务中,Faster-RCNN 尽管在自然图像中的目标识别领域中表现优秀,但其需要与高鲁棒性生成候选区域的算法结合才能具有较好的效果,而生成候选区域的算法一般比较耗时,且目前的候选网格生成算法是针对较大目标的,而微动脉瘤和较小出血点等的检测属于小目标检测,在高分辨率眼底视网膜图像中,即使是 Faster-RCNN 也不容易检测出来。对于硬性渗出和出血斑的病灶,不仅尺寸变化较大,也可能成片出现,因此单一尺寸的网格操作易造成漏诊和误诊,Faster-RCNN 等算法更适用于外观、形态具有一致性的目标,因此目前的基于深度学习算法在眼底图像的病灶检测上鲁棒性较差^[19]。因此,目前基于眼底彩色图像的病灶检测方法依然存在下列问题:(1)高质量的眼底图像和标注数据依然较难获取;(2)传统阈值分割、基于形态学的检测算法复杂度高,鲁棒性差;(3)微动脉瘤、小出血点等小目标病变的检出率低;(4)现存算法还不能同时检测出 4 种 DR 病变;(5)高分辨率眼底视网膜图像检测计算量大、速度慢、效率低;(6)现有方法的特异性不高,很多正常区域被误认为病灶。

针对目前算法仍然存在的一系列问题,本研究中

提出一种新的基于多尺度输入 CNN 的 DR 眼底图像病灶检测算法,结果显示从病灶水平来看,本研究提出的多尺度方法比单尺度方法性能更好,敏感性提高了 7.41%,本方法具有较高的病灶检测敏感性。本研究对硬性渗出病灶检测的特异性明显优于文献[17]的结果。该方法可使医生不用手动勾画病灶的像素级轮廓,能够大大节约时间;此外,对于某些病灶边界难以划分的情况,该方法也可以降低标记标准不统一的情况。一个病灶为中心区域的多尺寸网格获取及 3 个尺寸的网格能够包含不同类型的病灶,最小尺寸的 grid 可以更好地检测微动脉瘤的小病灶,中尺寸的网格适合小区域的渗出及出血,最大尺寸的网格用于区分病灶与生理结构的差异,尤其是视盘、交叉血管及黄斑区。

本研究主要有 3 点贡献:(1)以弱监督的方式得到病灶检测及分割的结果,提出的多尺度的网格联合输入病灶分类模型,能够克服病灶种类多、差异性大的问题;(2)考虑到病灶检测的实际应用场景中负样本多的问题,在数据集的创建没有进行类均衡的情况下,采用的目标函数结合方式能够克服为了模拟临床场景造成的类不均衡、特异性差的问题。(3)目前应用在真实病灶检测使用场景中,较传统的单尺度分类、分割模型,该方法是一种弱监督、可循证的病灶分割方式,在没有医生进行手动像素级标注的情况下能够有效获得病灶位置和轮廓信息,大大减少医生标注时间,且有效提高了病灶检测精度,尤其是更好地提高了特异性。

综上所述,本研究中提出了一种基于多尺度 CNN 的眼底图像病灶检测算法。针对微动脉瘤、小出血点等小目标病变的检出率低,眼底病灶种类多、形态各异的问题,本研究中采用同一个中心区域的多尺度图像块输入,同时兼顾不同尺寸的病灶,尤其是小病灶,综合考虑病灶的局部信息以及所在区域的全局信息。此外,提出一种新的目标函数,迭代优化模型,显著提升算法鲁棒性。在公开数据集上的实验结果表明该算法能够有效、高效地进行眼底图像的病灶检测。尽管该方法与形态学和传统的深度学习分割方法相比具有一定的优势,但是目前的算法还不能完全达到像素级精度的定位。此外,该算法仅在少量数据集上进行了测试,对于更加多变、复杂数据集的鲁棒性需要进一步验证。在今后的研究中,一方面会对 CNN 的结构做出改进,更加适应病变检测任务;另一方面也会采集更多实际的眼底图像数据库,使 DR 病变检测更加准确和高效,以更好地应用于临床。

利益冲突 所有作者均声明不存在利益冲突

参考文献

- [1] Xie XW, Xu L, Jonas JB, et al. Prevalence of diabetic retinopathy among subjects with known diabetes in China: the Beijing Eye Study [J]. Eur J Ophthalmol, 2009, 19(1): 91-99.
- [2] Duh EJ, Sun JK, Stitt AW. Diabetic retinopathy: current understanding, mechanisms, and treatment strategies[J/OL]. JCI Insight, 2017, 2(14): pii:93751 [2019-02-10]. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5518557/>. DOI: 10.1172/jci.insight.93751.
- [3] 蒋升, 张莉, 克麦尔·艾则孜. 免散瞳眼底照相技术在糖尿病视网膜病变筛查中的应用研究[J]. 国际眼科杂志, 2008, 8(10): 2037-2039. Jiang S, Zhang L, Aizezi K. Research of non-mydriasis photography for diabetic retinopathy screening [J]. Int J Ophthalmol, 2008, 8(10): 2037-2039.
- [4] Akram MU, Khan SA. Multilayered thresholding-based blood vessel segmentation for screening of diabetic retinopathy[J]. Engineer Computers, 2013, 29(2): 165-173.
- [5] 薛岚燕, 刘杜鹃, 陈艺慧. 基于 Canny 边缘检测和外观特征的微血管检测[J]. 现代电子技术, 2017, 40(6): 103-108. DOI: 10.16652/j.issn.1004-373x.2017.06.026. Xue LY, Liu DJ, Chen YH. Microaneurysm detection method based on Canny edge detection and appearance feature [J]. Modern Electron Tech, 2017, 40(6): 103-108. DOI: 10.16652/j.issn.1004-373x.2017.06.026.
- [6] Niemeijer M, van Ginneken B, Staal J, et al. Automatic detection of red lesions in digital color fundus photographs [J]. IEEE Trans Med Imaging, 2005, 24(5): 584-592. DOI: 10.1109/TMI.2005.843738.
- [7] Sopharak A, Uyyanonvara B, Barman S, et al. Automatic detection of diabetic retinopathy exudates from non-dilated retinal images using mathematical morphology methods [J]. Comput Med Imaging Graph, 2008, 32(8): 720-727. DOI: 10.1016/j.compmedimag.2008.08.009.
- [8] García M, López MI, Alvarez D, et al. Assessment of four neural network based classifiers to automatically detect red lesions in retinal images [J]. Med Eng Phys, 2010, 32(10): 1085-1093. DOI: 10.1016/j.medengphys.2010.07.014.
- [9] Usman AM, Khalid S, Tariq A, et al. Detection and classification of retinal lesions for grading of diabetic retinopathy [J]. Comput Biol Med, 2014, 45: 161-171. DOI: 10.1016/j.compbiomed.2013.11.014.
- [10] Gargeya R, Leng T. Automated identification of diabetic retinopathy using deep learning [J]. Ophthalmology, 2017, 124(7): 962-969. DOI: 10.1016/j.ophtha.2017.02.008.
- [11] Orlando JI, Prokofyeva E, Del Fresno M, et al. An ensemble deep learning based approach for red lesion detection in fundus images [J]. Comput Methods Programs Biomed, 2018, 153: 115-127. DOI: 10.1016/j.cmpb.2017.10.017.
- [12] Orlando JI, Prokofyeva E, Del FM, et al. An ensemble deep learning based approach for red lesion detection in fundus images [J]. Comput Methods Programs Biomed, 2018, 153: 115-127. DOI: 10.1016/j.cmpb.2017.10.017.
- [13] Lin TY, Goyal P, Girshick R, et al. Focal loss for dense object detection [J/OL]. IEEE Trans Pattern Anal Mach Intell, 2018, 1 [2019-01-23]. <https://ieeexplore.ieee.org/document/8417976>. DOI: 10.1109/TPAMI.2018.2858826.
- [14] Yuan Y, Chao M, Lo YC. Automatic skin lesion segmentation using deep fully convolutional networks with Jaccard distance [J]. IEEE Trans Med Imaging, 2017, 36(9): 1876-1886. DOI: 10.1109/TMI.2017.2695227.
- [15] Kondo R, Yamakawa S, Masuoka Y, et al. Microstructure recognition using convolutional neural networks for prediction of ionic conductivity in ceramics [J]. Acta Materialia, 2017, 141: 29-38.
- [16] Porwal P, Pachade S, Kamble R, et al. Indian diabetic retinopathy image dataset (IDRiD): a database for diabetic retinopathy screening research [J/OL]. Data, 2018, 3(3): 25 [2019-02-12]. <https://doi.org/10.3390/data3030025>.
- [17] Benzaamin A, Chakraborty C. Detection of hard exudates in retinal fundus images using deep learning [C]//2018 IEEE International Conference on System, Computation, Automation and Networking (ICSCA). IEEE, 2018: 1-5.
- [18] 蔡震震, 唐鹏, 胡建斌, 等. 深度卷积神经网络实现硬性渗出的自动检测 [J]. 计算机科学, 2018, 45(z2): 203-207. Cai ZZ, Tang P, Hu JB, et al. Auto-detection of hard exudates based on deep convolutional neural network [J]. Comput Sci, 2018, 45(z2): 203-207.
- [19] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149. DOI: 10.1109/TPAMI.2016.2577031.

(收稿日期: 2019-02-22 修回日期: 2019-06-30)

(本文编辑: 刘艳)

读者·作者·编者

本刊对来稿中作者署名的著录要求

作者向本刊投稿时署名应符合以下条件: (1) 参与课题的选题和实验设计, 参与实验资料的收集、分析和论证。 (2) 参与论文的起草或能够对论文中的方法学或关键部分进行修改。 (3) 能对审稿专家和编辑提出的修改意见进行核修, 能够答辩并承担责任。仅参与筹得资金或收集资料者以及仅对科研小组进行一般管理者均不宜署名为作者。文中如有外籍作者, 应附外籍作者亲笔签名在本刊发表的同意函。集体署名的文章应于题名下列出署名单位, 于文末列出论文整理者的姓名, 并须明确该文的主要责任者。

作者署名的名次应按对论文贡献大小顺序排列于文题下方, 每篇论文须列出通信作者 1 名。如无特殊约定, 则视第一作者为通信作者。作者 (包括通信作者) 的署名及其排序应在投稿前由所有研究者共同讨论确定, 在编排过程中不宜变更或增减, 尤其是通信作者和前三名作者, 若确需变动者须提供所有署名作者的签名同意函并出示单位证明。有英文文题的论著和综述应有全部作者姓名的汉语拼音, 列于英文文题之下。

本刊对实验研究中动物使用方面的要求

为了提高实验研究论文中实验动物这个基础环节在国际上的认可度, 本刊要求作者投稿时提供以下相应信息: (1) 实验动物的种属、来源、一般信息及饲养条件; (2) 实验动物的等级; (3) 实验所遵循的相关实验动物保护条例或法规的具体名称以及颁布的机构名称。

(本刊编辑部)