

深度卷积神经网络实现硬性渗出的自动检测

蔡震震 唐 鹏 胡建斌 金炜东

(西南交通大学 成都 610036)

摘 要 为实现硬性渗出的自动检测,构建糖尿病计算机辅助诊断系统,文中提出了一种基于深度卷积神经网络的硬性渗出提取方法。该方法主要分为两个部分:线下训练硬性渗出分类模型和在线检测硬性渗出。线下训练分类模型是利用深度卷积神经网络自动提取特征训练出硬性渗出的分类模型;在线检测硬性渗出使用训练好的分类模型对眼底影像中的硬性渗出进行检测,并获取硬性渗出的概率图以及伪彩色图。利用文中方法在标准数据集 DIARETDB1 和自选数据集上进行验证,结果表明所提方法行之有效,鲁棒性较好,具有很强的临床实践意义。

关键词 糖尿病,硬性渗出,卷积神经网络,概率图,伪彩色图

中图分类号 TP181 文献标识码 A

Auto-detection of Hard Exudates Based on Deep Convolutional Neural Network

CAI Zhen-zhen TANG Peng HU Jian-bin JIN Wei-dong

(Southwest Jiaotong University, Chengdu 610036, China)

Abstract A hard exudates (HEs) detection method based on deep convolution neural network was proposed in this paper, which achieves the purpose of automatic detection for HEs and contributes to the creation of diabetic retinopathy (DR) computer-aided diagnostic system. This method includes training the classification model for HEs offline and detection for HEs online. In order to train HEs classification model offline, CNN is adopted to extract HEs features automatically. Then, HEs in fundus image are detected by HEs classification model which has been trained offline, meanwhile, HEs probability graph and HEs pseudo-color map are obtained. The method was verified on standard data set and self-built data set respectively. Compared with other methods, the proposed method is profitable with strong robustness, and has very strong clinical practice significance.

Keywords Diabetic retinopathy, Hard exudates, Convolutional neural network, Probability graph, Pseudo-color map

糖尿病性视网膜病变(Diabetic Retinopathy, DR)简称糖尿病网病,是糖尿病最常见和最严重的微血管并发症之一,也是 40~60 岁人群视力损害的首要原因^[1-2]。硬性渗出(Hard Exudates, HEs)是 DR 患者早期最明显的眼底病变症状,在眼底影像中表现为视网膜内边界清晰的黄白色小点和斑块。实现 HEs 有效的自动检测,构建 DR 自动诊断系统,对于基数庞大、发病率较高的 DR 患者来说具有非常重要的临床意义^[3]。

根据 DR 患者眼底影像中 HEs 的形态特征,从图像处理的角度,目前硬性渗出自动检测的方法大致可以分为 3 类:基于形态学的方法、基于区域增长的方法和基于机器学习的方法。基于形态学的硬性渗出的提取方法: Ravishankar 等^[4]通过不同尺度的形态学开闭运算操作确定目标边界,最终通过硬性渗出的高亮度和边缘属性训练线性分类器,从而对候选区域实现 HEs 的精确提取; Gandhi 等^[5]通过多种形态学算子提取 HEs。该类方法的运算速度相对较快,但是过多依赖于 HEs 在眼底影像中的亮度、灰度、与背景的对比如等特征,忽视了其他特征,准确率较低。基于区域增长的方法: Li 等^[6]先采用主成分分析法对视盘进行定位并建立眼底影像的坐标系统,然后采用区域增长并结合 Canny 边缘检测的方法

对 HEs 进行提取; Tamilarasi 等^[7]提出一种基于遗传模糊种子区域生长分割的 HEs 检测方法。该类方法需先选定种子点,且区域增长停止条件和规则不容易确定,容易造成过度分割。基于机器学习的方法:高玮玮等^[8]使用改进的 FCM 算法粗分割获取 HEs 区域,然后选取特征利用 SVM 实现 HEs 分类器的训练;张磊等^[9]首先获取硬性渗出候选区域,然后利用集成分类的方法对候选区域进行分类,获得最终的硬性渗出区域;肖志涛等^[10]提出了一种基于背景估计和 SVM 分类器的眼底影像中 HEs 的提取方法。该类方法是目前的主流研究方向,一般与其他方法结合使用,但是目前见诸文献中机器学习的方法属于浅层学习,检测结果依赖于人工选取的特征,为了提高准确率,会选取几十种特征。

眼底影像中 HEs 自动检测的难点主要有两个方面,一方面眼底病变复杂多样以及眼底影像获取的环境及方式不同,浅层机器学习的方法受人工选定的特征影响较大,难以适应复杂多变的临床实际环境;另一方面眼底影像数据资源的获取相对较难,含有特定病变(如 HEs 等)的眼底影像资源更少。近年来,相对于浅层机器学习算法,深度学习算法表现出诸多优势。在 NIPS2012 上, Hinton 等^[11]将卷积神经网络(Convolutional Neural Networks, CNN)应用于图像识别领域

本文受中央高校基本科研业务费创新项目基金(2682014CX027)资助。

蔡震震(1990—),硕士生,主要研究方向为图像处理等;唐 鹏(1979—),讲师,主要研究方向为智能信息处理;胡建斌(1964—),主要研究方向为模式识别与智能系统, E-mail: hujbin@163.com(通信作者);金炜东(1959—),教授,主要研究方向为智能信息处理。

最大的数据库 ImageNet 上,取得了当时最好的结果。目前深度学习中的目标检测方法主要有 CNN,RCNN(Regions with CNN)^[12],Fast-RCNN^[13],Faster-RCNN^[14]等,其中 CNN 是深度学习最早的应用模型,RCNN, Fast-RCNN, Faster-RCNN 是 Girshick 等在 CNN 的基础上不断改进的目标检测算法。相对于浅层学习,深度学习不需要人工设定需要提取的特征,具有较强的泛化能力,因此,本文借助于深度学习的方法,自动学习 HEs 深层次的特征并训练 HEs 分类模型,该方法可以达到比较好的效果,并且鲁棒性较强,与浅层学习相比具有明显的优势。

1 硬性渗出识别网络

本文选用的 HEs 识别网络为在 CNN 的经典 LeNet5 网络的基础上进行改进的网络,以适应本文中 HEs 的自动检测。本文选用该方法主要有两方面原因。一方面,RCNN 等在检测目标时首先获取目标区域的候选区域,然后再利用 CNN 对图片中的目标进行精确识别,此类方法在目标检测中可以快速定位识别目标。但是它更适合于图片中目标相对较大且个数相对较少的定位检测。观察眼底影像发现,HEs 在眼底影像中根据病变程度的不同,病灶区域分布不均匀,大小不一且相差较大。若 RCNN 等方法获取的候选区域较小且注重细节,则算法性能降低,相当于蜕化成 CNN 遍历检测目标;若其在获取的候选区域比较笼统则检测不出 HEs 的细节轮廓,容易造成过多的漏检。另一方面,在深度学习网络中,网络越复杂需要的样本数量相对越多,而医学影像相对较难获得,含有病变的医学影像相对更少,RCNN 等在训练模型时要求的数据量比较大,并且相对于 ImageNet 中的样本数据,HEs 在眼底影像中的外观形态特征相对简单(呈斑状或者块状的不规则橙黄色区域),其背景虽然受其他病灶特征的影响相对复杂,但是相对于深度学习中的复杂环境而言其背

景相对简单。综合上述分析,本文认为针对 HEs 的自动定位检测,CNN 更适合并且可以使用相对简单的网络结构。

图 1 为一个 7 层卷积神经网络的示意图。输入层为 64×64 像素的样本图片,每个卷积层由多个特征图组成,前一层获得的特征图 X_{i-1}^l 与可学习的卷积核 k_{ij}^l 进行卷积,卷积的结果经非线性函数 $f(\cdot)$ 生成特征图 X_j^l ,具体形式如下:

$$X_j^l = f\left(\sum_{i \in M_j} X_{i-1}^l * k_{ij}^l + b_j^l\right) \quad (1)$$

其中, X_j^l 为第 l 层的第 j 特征图的输出; b_j^l 为 X_j^l 对应的偏置; $*$ 代表卷积运算; k_{ij}^l 为卷积核,可与 $(l-1)$ 层的多个特征图进行卷积; M_j 代表与 X_j^l 对应的输入特征图集合。抽样层(也称为下采样层)对每个特征图进行降采样处理,在该层本文选取最大值的抽样方法,以保留较强的边缘信息,其计算公式如下:

$$X_j^l = f\left(\max_{i \in n \times n} X_{i-1}^{l-1} u(n, n)\right) \quad (2)$$

其中, $u(n, n)$ 为抽样层输入的窗口函数。最后全连接层对前面逐层变换和映射提取的特征进行回归分类等处理,并将其作为输出层,将训练得到的特征图汇总成特征向量,训练 HEs 分类模型。




图 1 7 层卷积神经网络的示意图

2 硬性渗出自动检测过程

本文中 HEs 的提取过程主要分为两个部分:线下训练 HEs 分类模型和在线检测 HEs,其具体流程如图 2 所示。

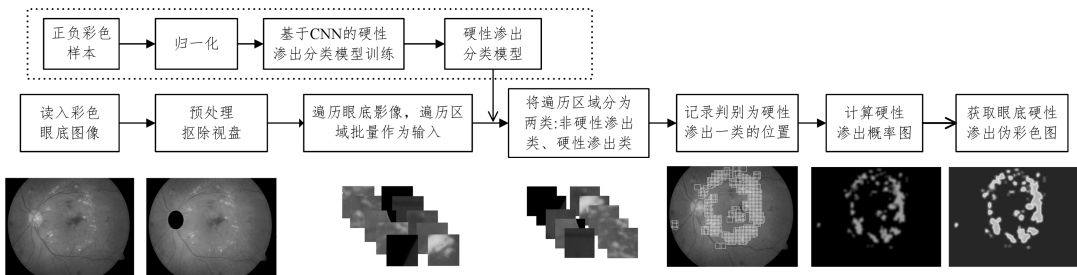


图 2 硬性渗出自动检测方法流程图

2.1 线下训练 HEs 分类模型

样本是训练 HEs 分类模型的关键。由于患者眼底病变的多样性以及每个医生对病变的判断标准不同,对于某些位置,不同的医生会有不同的判断。在 HEs 正负样本的获取过程中明确区分与 HEs 形态相近的非硬性渗出区域,如棉绒斑。由于 DR 最佳的治疗时机是在早期,因此在选取训练分类模型所用的正负样本时,本文遵循只要有眼科医师判定为 HEs 的位置就将其作为正样本的原则,以保证最大限度地发现早期患者,减少漏检。本文在标准数据集中获取的正样本为含有 HEs 的样本即 HEs 样本,共 3600 张;负样本为不含 HEs 的样本(可以含有其他病变)即非 HEs 样本,共 14300

张。对选取的正负样本尺寸进行归一化,图 3 给出获取的正负样本示例。




图 3 硬性渗出正负样本图片

利用 CNN 训练 HEs 分类模型。首先,本文根据 HEs 正负训练样本的尺寸(64 * 64 像素),设计了一个 9 层的 CNN 网络结构,该网络是在经典 LeNet 网络的基础上改进的,其结构及参数设计如表 1 和表 2 所列。本文网络的输入层为 64 * 64 的三通道样本图片;网络中的卷积核尺寸统一设为 5 * 5,在经过下采样层不断降低特征维度的过程中保持局部感受野不变,可以获取到 HEs 由局部到整体的信息;下采样层采用最大值抽样方法,在降低特征维度的同时可以保留较强的边缘信息;激活函数选用 ReLU(Rectified Layer Units),其优势在于可以提高网络的训练速度,同时避免由梯度消失导致的网络退化。然后,本文利用该改进的 CNN 网络结构计算 HEs 的输出值,再反向传播调整权重和偏置,基于实验过程中损失函数的变化规律,将该调整过程设计为 5000 次,初步获得 HEs 的分类模型。最后,预测试该分类模型的有效性。由于不同眼底影像数据获取的条件不同,HEs 和背景区域在眼底影像中表现的特征略有差异,而标准数据集有一定的代表性并且其他干扰的病变特征的复杂度较高,因此本文在标准数据集上训练出初步的 HEs 分类模型后,根据在不同数据集上预测试的结果再对该 HEs 分类模型进行微调。首次训练的分类模型参数都是随机初始化的,而微调是在训练好的模型参数的基础上进行调整,本文在自选数据集中重新获取正负样本图片(正样本 2000 张,负样本 10000 张)。在原设计网络的基础上降低学习速率,将迭代次数设为 3000,微调初步获得的分类模型以获得最终适用于自选数据集的 HEs 分类模型,该调整过程可以增强分类模型的有效性和鲁棒性。

表 1 卷积层结构及参数设计

层号	层类型	尺寸参数(通道数 或者个数 * 高 * 宽)	各层输出参数
1	输入层	输入图像 3 * 64 * 64	3 * 64 * 64
2	卷积层	滤波器 20 * 5 * 5	20 * 60 * 60
3	下采样层	抽样器 2 * 2	20 * 30 * 30
4	卷积层	滤波器 50 * 5 * 5	50 * 26 * 26
5	下采样层	抽样器 2 * 2	50 * 13 * 13
6	卷积层	滤波器 20 * 5 * 5	20 * 9 * 9
7	下采样层	抽样器 2 * 2	20 * 5 * 5

表 2 全连接层和输出层设计

层号	类型	参数
8	全连接层	激活函数为 ReLU
9	输出层	该层为线性层,输出单元数为 2
	损失函数	类型:Softmax WithLoss

2.2 在线自动检测硬性渗出

2.2.1 眼底影像预处理

不同医院由于眼底拍摄距离及拍摄角度不同,获取的眼底影像中有效信息的位置以及所占区域大小不同,为提高 HEs 的自动检测效率,本文对眼底影像进行预处理:去除多余背景区域并去除视盘。眼底影像中的眼球位置与黑色背景对比非常明显,本文采用阈值结合形态学的方法将多余黑色背景去除。硬性渗出表现为亮黄色且具有明显边界的区域,其亮度、色彩以及边界特征与视盘的极为相似,在识别 HEs 时视盘是最大的干扰因素,本文采用文献[15]的方法基于最大轮廓分析并结合外接矩形剔除干扰源定位视盘,然后利用椭圆拟合去除视盘。预处理操作如图 4 所示。




图 4 预处理结果图

2.2.2 硬性渗出检测

在预处理后的眼底影像中,利用线下训练好的硬性渗出的分类模型对眼底影像中的 HEs 进行识别,并记录其在眼底影像中的位置。本文中的滑动窗尺寸设为 64 * 64 像素,滑动步长设为 16 像素,由于滑动窗滑动步长相对于滑动窗的大小小很多,同一个 HEs 的位置会被检测到多次,为降低误检结果,将只被一个滑动窗检测到的位置剔除。检测结果如图 5 所示,图 5(a)为原始眼底影像,图 5(b)为使用本文方法对 HEs 的检测结果。由图 5 可以看出本文算法对眼底影像中的 HEs 的检测结果较好。




图 5 眼底影像中对硬性渗出的识别结果

2.2.3 硬性渗出概率图以及伪彩色图

HEs 概率图是将被检测的眼底影像中 HEs 出现在眼底中的位置以及可能性直观地表现出来。HEs 概率图是根据记录的 HEs 位置,在创建的一张与眼底影像同样尺寸的图像 I_0 中将 HEs 的位置及概率表现出来, $I(x, y)$ 中的像素值越大(即亮度越高)说明 HEs 的可能性越大,其计算公式如下:

$$I(x, y) = I_0 \sum_{\substack{(x, y) \in A \\ A \in HEs}} G(x, y) \quad (3)$$

其中, $I(x, y)$ 为 HEs 概率图; I_0 为与眼底影像同样大小且像素灰度值全为 0 的图像; $G(x, y)$ 为 64 * 64 的高斯灰度图; A 为 64 * 64 的窗口;HEs 为记录的 HEs 位置。

根据记录的 HEs 位置,结合式(1)计算出 HEs 的概率

图,并对其进行平滑处理,将处理后的 HEs 概率图转化为 HEs 伪彩色图,伪彩色图相对于概率图更加直观,可以使眼科医师更加方便地获取病人的病情状况,如图 6(b)、图 6(c)所示。图 6(d)为在数据集中 4 位眼科专家对硬性渗出的标注图。




图6 硬性渗出概率图及伪彩色图

3 实验结果分析

3.1 评价方法

目前评价 HEs 自动检测方法有效性的指标主要分为两类:基于图像的评价指标和基于病灶区域的评价指标。基于图像的评价指标是对整张眼底影像进行分析评价,即根据识别结果中 HEs 的存在与否来判定该眼底影像是否患病;基于病灶区域的评价指标是将眼底影像的每个区域与眼科医师的标注图进行对比,统计分析每个区域中是否存在 HEs 来分析 HEs 检测算法的有效性。

自动检测方法的评价指标主要有 4 个:准确率(Accuracy, AC)、敏感性(Sensitivity, SE)、特异性(Specificity, SP)、预测率(Positive Predictive Value, PPTV),其计算公式分别如下:

$$AC = \frac{TP + TN}{TP + TN + FP + FN}$$

$$SE = TP / (TP + FN) \quad (4)$$

$$SP = TN / (FP + TN)$$

$$PPTV = TP / (TP + FP)$$

其中,TP,FP,FN,TN 分别为真阳性、假阳性、假阴性、真阴性,在基于图像的评价指标中其单位为整张眼底影像的个数,在基于病灶区域的评价指标中其单位为区域的个数;SE 体现了不被漏判的概率;SP 表征正常眼底影像不被误判的概率;AC 表示算法的准确率;PPTV 一般作为基于病变区域的评价指标,该指标体现了眼底影像中硬性渗出区域被检测到的概率,可以更好地评价算法的有效性。

3.2 实验结果分析

为研究本文方法的有效性,本文分别在标准数据集 DIARETDB1^[16]和从成都某合作医院获取的自选数据集上进行测试。DIARETDB1 包含 89 张 1500 * 1152 像素的眼底影像,其中含 HEs 病变的 47 张,不含 HEs 病变的图像 41 张。自选数据集包含 103 张 2048 * 1536 像素的眼底影像,其中 41 张含 HEs 病变,62 张正常的眼底影像。实验过程中,尽量保证训练样本和测试样本的多样性,本文在 DIARETDB1 中选取 45 张(其中 29 张含 HEs 病变)用于获取训练 HEs 分类模型的样本,其余 44 张用来测试;在自选数据集中选取 48 张(其中 20 张含 HEs 病变)用于获取微调 HEs 分类模型的样本,其余 55 张用来测试微调后的 HEs 模型。

本文基于某眼科医生对自选数据集的判定结果以及标准数据集中给出的病变判定结果,采用本文方法对两个测试集进行测试。由于标准数据集中有 4 位眼科专家对每个病变区域的位置给出了评价结果,而自选数据集中由某眼科专家给出了整张眼底影像是否含有 HEs 的评价结果,而对每个病变区域的评价需要更多的专家给出评价结果才有更高的可信度,因此未给出自选数据集中的基于病变区域的统计结果。表 3 列出了本文方法在两种评价标准下的结果。

表3 本文方法基于两种评价标准的实验结果

(单位:%)

数据集	基于图像水平			基于病灶水平	
	SE	SP	AC	SE	PPTV
自选数据集	100	88.24	92.73	—	—
DIARETDB1	100	88.46	93.12	97.05	95.26

基于图像水平的评价指标用于评价算法对病变眼底影像和正常眼底影像的识别能力;基于病灶区域的评价指标用于评价算法对眼底影像中 HEs 的检测能力。由表 3 可知,本文方法在基于图像水平的敏感性指标上均达到 100%,即漏检率为 0;在基于病灶水平的敏感性指标上分别达到 97.05%,该结果体现了本文算法检测眼底影像中 HEs 的有效性。文献[9]、文献[10]中给出在 DIARETDB1 中检测的实验结果中基于病灶水平的敏感性指标分别为 94.08%和 84.6%,从实验结果来看,本文方法优于上述两种方法;文献[9]、文献[10]使用的机器学习的方法均需要人工选定特征,文献[9]选用了 38 种特征,文献[10]选用了 12 种特征,检测过程中受选定的特征影响较大,鲁棒性不够强,而本文采用深度卷积神经网络的方法不需要人工参与过程去选择或者设计合适特征作为输入,通用性较强,并且可以获得相对较好的实验结果。深度学习方法在大量样本的背景下可以发挥其更多的优势,目前本文在有限数据集的条件下已经实现较好的检测结果,表明本文方法在临床大量样本实践中可以实现其更大的价值。

结束语 本文通过观察和总结现有 HEs 提取方法的不足,即训练的分类模型受人工选取的特征影响较大,提出了基于深度卷积神经网络实现硬性渗出自动检测的方法。该方法的优势在于不需要额外的人工参与过程来选择或者设计合适的特征作为输入,其自动地从原始图像中提取特征、学习训练分类模型,大大减少了人工预处理过程,并且相对于传统的神经网络来讲,CNN 大大减少了权重参数,弥补了现有机器学习类方法提取 HEs 的不足。本文方法在自动检测 HEs 的同时获取了 HEs 的概率图和伪彩色图,更加直观地提供了患者的眼底病况。

利用本文方法在自选数据集和标准数据集上进行验证。其在自选数据集上基于图像评价的准确率、敏感性、特异性分别为 100%,88.24%,92.73%,在标准数据集上基于图像的敏感性、特异性、准确率分别为 100%,88.46%,93.12%;基于病灶区域的敏感性、预测率分别为:97.05%,95.26%。通过与其他文献方法对比发现,本文方法可以有效地检测出眼底影像中的硬性渗出,满足糖尿病自动筛查系统的基本要求。由于各方面条件的限制,本文的方法并未在糖尿病实时筛查中进行验证,但是本文方法具有一定的优势,可以为进一步推进糖尿病自动诊断系统的实现提供一种新的方向。

参 考 文 献

- [1] 美丽巴努·玉素甫,陈雪艺. 视力损害的流行病学研究[J]. 国际眼科杂志, 2010, 10(2): 304-307.
- [2] 丁山,宋丽晓. 一种改进的视网膜图像中微小动脉瘤的检测算法[J]. 计算机科学, 2014, 42(12): 269-274.
- [3] GREENSPAN H, GINNEKEN B, SUMMERS R M. Guest Editorial Deep Learning in Medical Imaging: Overview and Future Promise of an Exciting New Technique [J]. IEEE Transactions on Medical Imaging, 2016, 5(35): 1153-1159.
- [4] RAVISHANKAR S, JAIN S, MITTAL A. Automated feature extraction for early detection of diabetic retinopathy in fundus images[C]// IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops. Anchorage Alaska, America; CVPR, 2009: 210-217.
- [5] GANDHI M, DHANASEKARAN R. Diagnosis of diabetic retinopathy using morphological process and SVM classifier[C]// IEEE International Conference on Communication and Signal Processing. Washington, America; ICCSP, 2013: 873-877.
- [6] LI H, CHUTATAPE O. Automated feature extraction in color retinal images by a model based approach [J]. IEEE Transactions on Biomedical Engineering, 2004, 51(2): 246-254.
- [7] TAMILARASI M, DURAISWAMY K. Genetic based Fuzzy Seeded Region Growing Segmentation for Diabetic Retinopathy Images [C]// International Conference on Computer Communication and Informatics. Tamil Nadu, India; ICCCI, 2013.
- [8] 高玮玮,沈建新,程武山,等. 基于改进的模糊 C-均值聚类算法

及支持向量机的眼底图像中硬性渗出检测方法[J]. 北京生物医学工程, 2017, 36(4): 331-337.

- [9] 张磊,卜巍,郭向前,等. 基于背景估计和集成分类的眼底硬性渗出检测[J]. 智能计算机与应用, 2017, 7(5): 66-69.
- [10] 肖志涛,王雯,耿磊,等. 基于背景估计和 SVM 分类器的眼底图像硬性渗出物检测方法[J]. 中国生物医学工程学报, 2015, 34(6): 720-728.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolution neural networks[J]. Advances in Neural Information Processing System, 2012, 25(2): 1097-1105.
- [12] ZHANG N, DONAHUE J, GIRSHICK R, et al. Part-Based R-CNNs for Fine-Grained Category Detection[C]// European Conference on Computer Vision. Springer, Cham, 2014: 834-849.
- [13] GIRSHICK R. Fast R-CNN[C]// IEEE International Conference on Computer Vision. IEEE Computer Society. 2015: 1440-1448.
- [14] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[C]// International Conference on Neural Information Processing Systems. MIT Press, 2015: 91-99.
- [15] 蔡震震,唐鹏,胡建斌,等. 基于形态学轮廓分析的眼底影像中视盘的定位[C]// 中国控制会议. 2016: 9434-9438.
- [16] KAUPPI T, KALESNYKIENE V, KAMARAINEN J K, et al. DIARETDB1 diabetic retinopathy database and evaluation protocol[C]// British Machine Vision Conference. 2007.

(上接第 184 页)

AKAZE 算法的特征提取算法,提高了图像边缘区域提取特征点的稳定性;使用二值匹配的方法匹配特征点,提高了匹配的效率;使用全局式方法替代增量式方法,解决了误差积累的问题。实验结果表明:本文方法相比于传统方法能得到更好的重建结果,体现了更好的稳定性,明显优于基于 SIFT 特征提取的增量式重建方法。如何进一步提高不同环境中三维重建算法的鲁棒性与三维重建精度是今后研究的重点。

参 考 文 献

- [1] CHENG X J, ZHANG H F, XIE R. Study on 3D laser scanning modeling method for Large-Scale history building[C]// International Conference on Computer Application and System Modeling. IEEE, 2010: V7-573-V7-577.
- [2] GRACIÁ L, SAEZ-BARONA S, CARRIOÓN D, et al. A System for Real-Time Multi-View 3D Reconstruction[C]// Workshops on Database and Expert Systems Applications. IEEE Computer Society, 2010: 235-239.
- [3] SCHÖNING J, HEIDEMANN G. Evaluation of multi-view 3D reconstruction software[C]// Computer Analysis of Images and Patterns. 2015: 450-461.
- [4] HÄMING K, PETERS G. The structure-from-motion reconstruction pipeline-A survey with focus on short image sequences [J]. Kybernetika-Praha, 2010, 5(5): 926-937.
- [5] SABZEVARI R, BUE A D, MURINO V. Structure from Motion and Photometric Stereo for Dense 3D Shape Recovery [M]// Image Analysis and Processing - ICIAP 2011. Springer Berlin Heidelberg, 2011: 660-669.
- [6] SCHÖNBERGER J L, FRAHM J M. Structure-from-Motion

Revisited [C] // Computer Vision and Pattern Recognition. IEEE, 2016.

- [7] MOULON P, MONASSE P, MARLET R. Adaptive Structure from Motion with a Contrario, Model Estimation [M]// Computer Vision-ACCV 2012. Springer Berlin Heidelberg, 2012: 257-270.
- [8] MOULON P, MONASSE P, MARLET R. Global Fusion of Relative Motions for Robust, Accurate and Scalable Structure from Motion [C]// IEEE International Conference on Computer Vision. IEEE Computer Society, 2013: 3248-3255.
- [9] ALCANTARILLA P F, BARTOLI A, DAVISON A J. KAZE Features [M]// Computer Vision - ECCV 2012. Springer Berlin Heidelberg, 2012: 214-227.
- [10] JIANG G, LIU L, ZHU W, et al. A 127 fps in full hd accelerator based on optimized AKAZE with efficiency and effectiveness for image feature extraction [C]// IEEE Design Automation Conference. 2015: 1-6.
- [11] CHEN Y, CHAN A B, LIN Z, et al. Efficient tree-structured SfM by RANSAC generalized Procrustes analysis [J]. Computer Vision & Image Understanding, 2017, 157(C): 179-189.
- [12] 许可乐. 图像局部不变特征检测与描述技术研究 [D]. 长沙: 国防科学技术大学, 2013.
- [13] 吴鹏,于秋则,闵顺新. 一种快速鲁棒的 SAR 图像匹配算法 [J]. 计算机科学, 2017, 44(7): 283-288.
- [14] SHI L M, GUO F S, HU Z Y, et al. An Improved PMVS through Scene Geometric Information [J]. Acta Automatica Sinica, 2011, 37(5): 560-568.
- [15] 田歌,赵阳,张浩,等. 基于 Delaunay 算法三角形网格划分的角点优化处理 [C]// 北京力学学会学术年会. 2010.