



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象 图形学报

2021
09
VOL.26

ISSN1006-8961
CN11-3758/TB



“深度学习+智慧医疗”专刊



第26卷第9期（总第305期）
2021年9月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn


Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ


国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



肺部影像解剖结构分割数据集及应用(第2111页)



LFSCA-UNet: 基于空间与通道注意力机制的肝纤维化区域分割网络(第2121页)



语义拉普拉斯金字塔多中心乳腺肿瘤分割网络(第2193页)

编者按 I

综述

深度医学图像配准研究进展: 迈向无监督学习

马露凡, 罗凤, 严江鹏, 徐哲, 罗捷, 李秀 2037

U-Net网络医学图像分割应用综述

周涛, 董雅丽, 霍兵强, 刘珊, 马宗军 2058

医学图像深度学习技术: 从卷积到图卷积的发展

唐朝生, 胡超超, 孙君顶, 司马海峰 2078

多尺度变换像素级医学图像融合: 研究进展、应用和挑战

周涛, 刘珊, 董雅丽, 霍兵强, 马宗军 2094

数据集论文

肺部影像解剖结构分割数据集及应用

覃文军, 李小硕, 周庆华, 刘盼, 杨金柱 2111

计算机断层扫描图像

LFSCA-UNet: 基于空间与通道注意力机制的肝纤维化区域分割网络

陈弘扬, 高敬阳, 赵地, 吴忌, 陈金军, 全显跃, 李欣明, 薛峰, 周沐瑶, 柏冰冰 2121

融合上下文和多尺度特征的胸部多器官分割

吉淑滢, 肖志勇 2135

注意力机制下密集空洞卷积的肺部图像分割

郭宁, 柏正尧 2146

融合注意力机制和特征金字塔网络的CT图像肺结节检测

张福玲, 张少敏, 支力佳, 周涛 2156

改进Faster R-CNN模型的CT图磨玻璃密度影目标检测

杨淑莹, 邓东升, 郑清春 2171

融合注意力机制与可变形卷积的多尺度骨病变检测

方成, 柏正尧 2181

磁共振图像

语义拉普拉斯金字塔多中心乳腺肿瘤分割网络

王黎, 曹颖, 郭顺超, 唐雷, 鄧子翔, 王荣品, 王丽会 2193

引入注意力机制和多视角融合的脑肿瘤MR图像U-Net分割模型

罗恺锴, 王婷, 叶芳芳 2208

集成注意力增强和双重相似性引导的多模态脑部图像配准

田梨梨, 程欣宇, 唐堃, 张健, 王丽会 2219

LRUNet: 轻量级脑肿瘤快速语义分割网络

何康辉, 肖志勇 2233

自适应多模态特征融合胶质瘤分级网络

王黎, 曹颖, 田梨梨, 陈祈剑, 郭顺超, 张健, 王丽会 2243

研究应用

面向运动想象脑电图识别的镜卷积神经网络

罗靖, 王耀杰, 刘光明, 王晓帆, 鲁晓峰, 黑新宏 2257

先验权重共享码本下内窥镜图像大肠病变分类

朱霆威, 李胜, 何熊熊 2270

融合空洞卷积与注意力的胃癌组织切片分割

陈颖锲, 李晗, 周雪婷, 万程 2281

视觉显著性的眼底图像视盘检测


吕鹏飞, 王莹, 王思齐, 于晓升, 吴成东 2293

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Pulmonary image anatomical structure segmentation dataset and applications(P2111)



LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms(P2121)



Semantic Laplacian pyramids network for multicenter breast tumor segmentation(P2193)

Review

- Deep-learning based medical image registration pathway: towards unsupervised learning
Ma Lufan, Luo Feng, Yan Jiangpeng, Xu Zhe, Luo Jie, Li Xiu 2037
- U-Net and its applications in medical image segmentation:a review
Zhou Tao, Dong Yali, Huo Bingqiang, Liu Shan, Ma Zongjun 2058
- Deep learning-based medical images analysis evolved from convolution to graph convolution
Tang Chaosheng, Hu Chaochao, Sun Junding, Sima Haifeng 2078
- Research on pixel-level image fusion based on multi-scale transformation: progress application and challenges
Zhou Tao, Liu Shan, Dong Yali, Huo Bingqiang, Ma Zongjun 2094

Dataset

- Pulmonary image anatomical structure segmentation dataset and applications
Tan Wenjun, Li Xiaoshuo, Zhou Qinghua, Liu Pan, Yang Jinzhu 2111

Computerd Tomography Image

- LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms
Chen Hongyang, Gao Jingyang, Zhao Di, Wu Ji, Chen Jinjun, Quan Xian Yue, Li Xinming, Xue Feng, Zhou Muyao, Bai Bingbing 2121
- Integrated context and multi-scale features in thoracic organs segmentation
Ji Shuying, Xiao Zhiyong 2135
- The integration of attention mechanism and dense atrous convolution for lung image segmentation
Guo Ning, Bai Zhengyao 2146
- Detection of pulmonary nodules in CT images by combining an attention mechanism and a feature pyramid network
Zhang Fuling, Zhang Shaomin, Zhi Lijia, Zhou Tao 2156
- Ground-glass opacity target detection in CT scans based on improved Faster R-CNN model
Yang Shuying, Deng Dongsheng, Zheng Qingchun 2171
- Multi-scale bone lesion detection based on attention mechanism and deformable convolution
Fang Cheng, Bai Zhengyao 2181

Magnetic Resonance Image

- Semantic Laplacian pyramids network for multicenter breast tumor segmentation
WANG Li, CAO Ying, Guo Shunchao, Tang Lei, Kuai Zixiang, Wang Rongpin, Wang Lihui 2193
- U-Net segmentation model of brain tumor MR image based on attention mechanism and multi-view fusion
Luo Kaikai, Wang Ting, Ye Fangfang 2208
- Multimodal brain image registration with integrated attention augmentation and dual similarity guidance
Tian Lili, Cheng Xinyu, Tang Kun, Zhang Jian, Wang Lihui 2219
- LRUNet: a lightweight rapid semantic segmentation network for brain tumors
He Kanghui, Xiao Zhiyong 2233
- Adaptive multi-modality fusion network for glioma grading
Wang Li, Cao Ying, Tian Lili, Chen Qijian, Guo Shunchao, Zhang Jian, Wang Lihui 2243

Research and Application

- Mirror convolutional neural network for motor imagery electroencephalogram recognition
Luo Jing, Wang Yaojie, Liu Guangming, Wang Xiaofan, Lu Xiaofeng, He Xinhong 2257
- Colorectal lesion classification of endoscopic images based on priori weight shared codebook application
Zhu Tingwei, Li Sheng, He Xiongxiang 2270
- The fusing of dilated convolution and attention for segmentation of gastric cancer tissue sections
Chen Yingsi, Li Han, Zhou Xueting, Wan Cheng 2281
- Optic disc detection based on visual saliency in fundus image
Lyu Pengfei, Wang Ying, Wang Siqi, Yu Xiaosheng, Wu Chengdong 2293

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2021)09-2293-12

论文引用格式: Lyu P F, Wang Y, Wang S Q, Yu X S and Wu C D. 2021. Optic disc detection based on visual saliency in fundus image. Journal of Image and Graphics, 26(09): 2293-2304 (吕鹏飞, 王莹, 王思齐, 于晓升, 吴成东. 2021. 视觉显著性的眼底图像视盘检测. 中国图象图形学报, 26(09): 2293-2304) [DOI:10.11834/jig.200444]

视觉显著性的眼底图像视盘检测

吕鹏飞¹, 王莹¹, 王思齐¹, 于晓升^{2*}, 吴成东²

1. 东北大学信息科学与工程学院, 沈阳 110819; 2. 东北大学机器人科学与工程学院, 沈阳 110819

摘要: 目的 青光眼是导致失明的主要疾病之一, 视盘区域的形状、大小等参数是青光眼临床诊断的重要指标。然而眼底图像通常亮度低、对比度弱, 且眼底结构复杂, 各组织以及病灶干扰严重。为解决上述问题, 实现视盘的精确检测, 提出一种视觉显著性的眼底图像视盘检测方法。方法 首先, 依据视盘区域显著的特点, 采用一种基于视觉显著性的方法对视盘区域进行定位; 其次, 采用全卷积神经网络 (fully convolutional neural network, FCN) 预训练模型提取深度特征, 同时计算视盘区域的平均灰度, 进而提取颜色特征; 最后, 将深度特征、视盘区域的颜色特征和背景先验信息融合到单层元胞自动机 (single-layer cellular automata, SCA) 中迭代演化, 实现眼底图像视盘区域的精确检测。结果 在视网膜图像公开数据集 DRISHTI-GS、MESSIDOR 和 DRIONS-DB 上对本文算法进行实验验证, 平均相似度系数分别为 0.965 8、0.961 6 和 0.971 1; 杰卡德系数分别为 0.934 1、0.922 4 和 0.937 6; 召回率系数分别为 0.964 8、0.958 9 和 0.967 4; 准确度系数分别为 0.996 6、0.995 3 和 0.996 8, 在 3 个数据集上均可精确地检测视盘区域。实验结果表明, 本文算法精确度高, 鲁棒性强, 运算速度快。结论 本文算法能够有效克服眼底图像亮度低、对比度弱及血管、病灶等组织干扰的影响, 在多个视网膜图像公开数据集上进行验证均取得了较好的检测结果, 具有较强的泛化性, 可以实现视盘区域的精确检测。

关键词: 眼底图像; 显著性检测; 特征融合; 视盘检测; DRISHTI-GS; MESSIDOR; DRIONS-DB

Optic disc detection based on visual saliency in fundus image

Lyu Pengfei¹, Wang Ying¹, Wang Siqi¹, Yu Xiaosheng^{2*}, Wu Chengdong²

1. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China;

2. Faculty of Robot Science and Engineering, Northeastern University, Shenyang 110819, China

Abstract: Objective Glaucoma is a type of disease characterized by atrophy and depression of the nipple, visual field defect, and visual loss. It is one of the main diseases that cause blindness and visual impairment. The clinical diagnosis of glaucoma includes the optic disc, optic cup, intraocular pressure, and the angle between the cornea and iris. Early detection and treatment are crucial for avoiding visual impairment and blindness. In a fundus image, the optic disc is a bright yellow-white spot that resembles a circle, and it is the birthplace of the fundus blood vessels. The shape, size, and depth of the optic disc area and other parameters are important indicators in the clinical diagnosis of glaucoma. Detection of the optic disc can also help determine the location of other lesions, such as fundus hemorrhage and micro aneurysm. Thus, precise detection of the optic disc area is also vital. However, the fundus image is often not bright, and its contrast is poor. In

收稿日期: 2020-08-06; 修回日期: 2020-10-12; 预印本日期: 2020-10-19

* 通信作者: 于晓升 yuxiaosheng@mail.neu.edu.cn

基金项目: 国家自然科学基金项目 (61701101, 61973063, U1713216, 61901098, 61971118); 中央高校基本科研业务费专项资金资助 (N2026005, N181602014, N2026004, N2026006, N2026001, N2011001)

Supported by: National Natural Science Foundation of China (61701101, 61973063, U1713216, 61901098, 61971118)

addition, the fundus structure is complex, and the overlapping of tissues and lesions is serious. These problems pose great challenges to the accurate detection and segmentation of the optic disc. The traditional single visual saliency method is considerably affected by color and brightness; hence, tissues, such as blood vessels, and bright lesions easily interfere in optic disc detection. Fully convolutional neural networks (FCNs) classify images at the pixel level, thus solving the problem of image segmentation at the semantic level. In the process of FCN optic disc testing, the detection results are minimally affected by tissues (e. g., vascular lesions), the borders are rough, and the accuracy is low. To overcome these difficulties and achieve accurate detection of the fundus image optic disc, this study combines the advantages of the visual saliency method and FCN, and a visual saliency disc detection method based on the fusion of deep and shallow features is proposed.

Method First, on the basis of the prominent characteristics of the optic disc area, a method based on visual saliency detection is used to locate the optic disc area. The saliency detection method based on morphological open reconstruction is utilized to extract the candidate solutions of the optic disc so that the enhanced optic disc becomes conspicuous and appears as a bright circular structure. The center of gravity of the optic disc is obtained and marked, and an image with a pixel size of 400×400 with the center of gravity as the center is extracted to segment the optic disc. Second, the Matconvnet computer vision neural network toolbox is used to extract deep features from the pre-trained model. The pre-trained model uses the pascal-fcn8s-dag. mat file provided on the official website of the Matconvnet toolbox, which uses the PASCAL VOC (pattern analysis, statistical modeling and computational learning visual object classes) 2011 dataset for training. Moreover, the average grayscale of the disc area is calculated for the 400×400 pixel size images to obtain color features. Lastly, by fusing the color feature, depth feature, and background prior information into a single-layer cellular automaton, the similarity is judged based on the distance between different cells in the feature space. Iterative evolution is performed to achieve accurate detection of the optic disc area in the fundus image. **Result** The proposed algorithm is experimentally verified on public datasets of fundus images, namely, DRISHTI-GS, MESSIDOR, and DRIONS-DB. The three datasets are mainly used for optic nerve head detection, including optic cup and optic disc. The optic disc area can be accurately detected in all datasets. The proposed algorithm detects the optic disc area in these datasets, and the evaluation indicators include Dice, Jaccard, recall, and accuracy. In the DRISHTI-GS dataset, Dice is 0.965 8, Jaccard is 0.934 1, recall is 0.964 8, and accuracy is 0.996 6. In the MESSIDOR dataset, Dice, Jaccard, recall, and accuracy have values of 0.961 6, 0.922 4, 0.958 9, and 0.995 3, respectively. In the DRIONS-DB dataset, Dice is 0.971 1, Jaccard is 0.937 6, recall is 0.967 4, and accuracy is 0.996 8. In addition, the proposed algorithm is compared with three algorithms, namely, improved circular Hough transform with Hough peak value selection and red channel superpixel segmentation for optic disc segmentation, accurate optic disc and cup segmentation from fundus images by using a multi-feature-based approach for glaucoma assessment, and dense fully convolutional with U-shape segmentation of the optic disc and cup in color fundus for glaucoma diagnosis. The proposed algorithm has higher accuracy, robustness, and calculation speed than the compared algorithms. **Conclusion** We propose a single-layer cellular automaton optic disc detection algorithm that integrates deep and shallow features. Experimental results show that the proposed algorithm can effectively overcome the effects of low brightness and low contrast of fundus images and the interference of blood vessels, lesions, and other tissues. The algorithm is verified on multiple public datasets of fundus images and achieves good detection results. It has strong generalization and realizes accurate detection of the optic disc area.

Key words: fundus image; saliency detection; feature fusion; optic disc detection; DRISHTI-GS; MESSIDOR; DRIONS-DB

0 引言

青光眼是造成人眼视力下降、失明的主要疾病之一,至2020年全球约有8千万人患有青光眼。青光眼是以视神经头(optic nerve head, ONH)萎缩、视

网膜神经节细胞病变以及视力下降为共同特征的疾病(Jasty 等,2020),眼压升高、视盘内视神经供血不足是其发病的重要原因,其他原因包括家族病史、遗传、种族和年龄等因素。对于现有的医疗手段来说,青光眼带来的视力下降是不可逆的,且危害极大。早期诊断发现青光眼,并及时采取合适的治疗方法,

可以有效减小其对视神经组织的伤害,保护视功能。在临床治疗中,从眼压大小(正常范围是10~21 mmHg)、视杯(optic cup, OC)与视盘(optic disc, OD)垂直直径比(cup to disc ratio, CDR)、视盘有无出血、角膜与虹膜间夹角大小(Tekeli 等,2016)等方面诊断青光眼,其中眼底图像中视盘区域(如图1所示)的检测对青光眼的诊断有着非常重要的意义。目前在临床诊断中,视盘区域的检测主要依靠手动标注,不仅耗时长,而且消耗大量精力。随着计算机以及人工智能等学科的发展,利用计算机视觉技术辅助医疗、进行医疗图像处理成为热点,其中对眼底图像进行视盘区域的检测是一个重要课题。




图1 眼底图像中的视杯与视盘

Fig. 1 Optic cup and optic disc in fundus image

现有的眼底图像视盘检测方法可以分为无监督学习方法和有监督学习方法两类。

基于传统无监督学习的视盘检测方法主要分为基于自适应阈值的方法(Issac 等,2015)、基于形态学的方法(Welfer 等,2013; Ramani 和 Shanthamalar, 2020)和基于活动轮廓模型的方法(Yu 等,2015; Gao 等,2019; Thakur 和 Juneja, 2019; 王莹 等,2020)等。Issac 等人(2015)提出了一种自适应阈值检测视盘的方法,利用眼底图像均值、标准差等特征,去除红色通道中其他多余结构,并只保留视盘区域,之后利用灰度直方图确定阈值,从而进行视盘检测。Welfer 等人(2013)提出了一种采用自适应形态学进行视盘检测的方法,首先利用视盘的亮度特征对视盘边界进行粗检测,之后利用形状特征对视盘进行精确检测。Ramani 和 Shanthamalar(2020)提出一

种结合形态学与像素密度计算的方法对视盘区域进行定位,并提出一种基于霍夫峰值选择的改进圆形霍夫变换与超像素分割方法,在眼底图像红色通道中对视盘进行检测。基于活动轮廓模型的视盘检测方法通常是将传统的活动轮廓模型与视盘的先验形状特征或视盘边缘粗检测的方法相结合进行视盘的精确检测。Yu 等人(2015)采用基于血管汇聚与像素强度相结合的形态学处理方法,得到一个近似于视盘区域的圆形结构作为其初始检测结果,并在初始检测结果的基础上,提出一种基于距离正则化窄带的水平集演化方法进行视盘检测。Gao 等人(2019)考虑到眼底图像血管阻塞、病理变化等影响,提出一种融合多特征与有效强度局部聚类的新模型(local intensity clustering model extended, LICE),结合改进的鲁棒自适应水平集初始化的方法提高活动轮廓的演化能力,实现对视盘检测。Thakur 和 Juneja(2019)提出基于水平集的自适应正则化核直觉模糊C均值聚类的方法实现视盘检测,首先使用聚类的方法对视盘区域提取初始轮廓,之后使用水平集方法对视盘初始边界进行修正。王莹等人(2020)考虑到视杯、视盘几何结构的关系,提出一种双层水平集描述眼底图像中视盘和视杯区域的方法,在双层椭圆形状先验的基础上,采用改进的局部强度聚类模型(local intensity clustering, LIC)对视杯和视盘边界同时进行检测。

基于有监督学习的视盘检测方法分为基于传统机器学习的视盘检测方法(Mohammad 等,2013; Acharya 等,2017)和基于深度学习的视盘检测方法(Sevastopolsky, 2017; Edupuganti 等,2018; Fu 等,2018; Al-Bander 等,2018; Yu 等,2019)。Mohammad 等人(2013)提出一种基于像素分类与模板匹配相融合的视盘检测方法,首先对眼底图像特征提取,之后使用分类器对每个像素分类,最后使用圆形模板进行匹配。Acharya 等人(2017)提出一种基于纹理和眼底图像局部形态特征进行视盘检测的方法,首先使用 Leung-Malik 滤波器, Schmid 滤波器与最大响应滤波器进行卷积得到特征,再选择 K 最邻近(K-nearest neighbor, KNN)分类器进行分类。Sevastopolsky(2017)提出了一种改进的 U 型网络(U-Net)视盘检测方法,在不损失分割精度的情况下,去除多余的滤波器,实现网络的轻量化。Edupuganti 等人(2018)使用全卷积神经网络(fully convo-

lutional neural network, FCN) 对全分辨率的眼底图像进行视盘检测,并在网络特定区域根据专家标注进行最优边界检索。Fu 等人(2018)提出一种联合多标记 M 型网络(M-Net)和极坐标变化的视盘检测算法,将多尺度输入层构建的图像金字塔与 U 型网络(U-Net)、多标签损失函数组成 M-Net,进一步提升了视盘检测性能。Al-Bander 等人(2018)提出了一种将稠密网络(DenseNet)与全卷积神经网络(FCN)相结合,构建 U 型网络(U-Net),从而实现像素级别分类的深度学习视盘检测方法,主要使用 DenseNet 进行特征的重复利用,并在神经层之间建立直接链接促进特征传播。Yu 等人(2019)提出一种改进的 U 型网络(U-Net)结构,核心是将预训练模型 Res-Net-34 模型作为编码层,与传统的 U-Net 解码层相连进行眼底图像视盘检测,避免了网络的重新训练,从而进一步防止过拟合的发生,提高了算法的鲁棒性。

以上算法虽然在一定情况下实现了视盘区域检测,但仍然存在不足。无监督学习的方法普遍精度较低,鲁棒性较差,受眼底图像光照不均、对比度低、亮病灶以及血管等组织影响较大;传统的机器学习方法非常依赖于研究人员的经验,在特征选取与算法检验过程中耗时巨大,且容易受眼底图像组织重叠的影响,在视盘区域感官特征不明显的情况下,算法精度受到较大影响;深度学习方法的模型设计复杂、计算量大,对于训练样本的数量与质量均有很高要求,同时需要很强的计算资源来实现算法。针对以上视盘检测中的问题,本文提出一种基于视觉显著性的眼底图像视盘检测方法。首先根据眼底图像视盘区域显著的特点,采用一种基于视觉显著性的视盘定位方法(Zhou 等,2017)对视盘区域进行定位;在完成视盘定位的基础上,提出一种融合深度特征与浅层特征的单层元胞自动机(single-layer cellular automata, SCA)的视盘检测方法,将眼底图像视盘区域的颜色特征与深度特征相融合,根据特征空间中不同元胞间的距离判断其相似性,利用单层元胞自动机进行迭代演化,从而实现视盘区域的精确检测。本文算法可以有效克服眼底图像光照不均、对比度低、亮病灶和血管等组织干扰的影响,所耗硬件资源、时间较少,且对不同样本检测的鲁棒性强、精度高。大量实验结果验证了本文算法的有效性。

1 背景介绍

1.1 全卷积神经网络

卷积神经网络在计算机视觉领域取得了显著成绩,一个重要原因是卷积神经网络有着强大的表达能力和深层架构能力,有助于学习具有语义信息的高级特征(Hariharan 等,2017)。而高级语义特征通常是图像较为深层、抽象的特征,受光照、姿态和背景等的影响较小,可以从多角度对图像进行描述,多方面对图像目标进行表达。本文从全卷积神经网络(FCN)(Long 等,2015)的不同神经层中提取深度特征,并将深度特征和图像浅层特征融合到单层元胞自动机中,以度量图像不同区域间的相似性。

FCN 是一个可以接受任意大小输入、端到端的语义分割神经网络。它将传统卷积神经网络的全连接层替换为卷积层,并使用反卷积的方法对传统卷积神经网络最后一个卷积层的特征图像进行上采样,使其逐步恢复到输入图像相同的尺寸大小,从而在这些抽象的特征中判断出每个像素的类别,即实现了像素级别的分类,如图 2 所示。




图2 FCN 实现像素级别预测

Fig. 2 FCN realizes pixel-level prediction

在传统卷积神经网络(convolutional neural network, CNN)结构中,第1~5层为卷积层,第6层和第7层都是长度为4 096的1维向量,第8层是长度为21的1维向量,分别表示21个像素类别的预测

概率;在FCN中,传统CNN的第6层替换为 $4096 \times 1 \times 1$ 维度的卷积核,第7层同样替换为 $4096 \times 1 \times 1$ 维度的卷积核,第8层替换为 $21 \times 1 \times 1$ 维度的卷积核,使所有层都变成了卷积层,所以称为全卷积神经网络。而且FCN是一个多层次的神经网络,不同卷积层能够输出包含浅层特征和深度抽象特征等不同尺度的特征图。

1.2 基于背景的单层元胞自动机显著性检测

元胞自动机是一个结构简单、自组织行为复杂的动态系统,由多个具有离散状态的元胞组成,这些元胞按照特定的更新规则进化。为了更好地在空间中表达,每个元胞都需要将当前状态和周围元胞状态作为参考,从而决定下一时刻的变化。考虑到显著目标在图像空间中同样是相关的,Qin等人(2015)提出一种基于背景的单层元胞自动机算法(background-based map optimized via single-layer cellular automata, BSCA),将元胞自动机作为无监督传播机制引入到视觉显著性检测领域中,将显著性值作为元胞的状态,有效地将全局颜色和距离整合到基于背景的图模型中。由于图像中突出的物体与背景有着较高的反差,所以利用局部相似性将元胞自动机应用于优化先验信息,更新显著性值,形成动态系统,从而区分目标与背景。

BSCA使用简单线性迭代聚类(simple linear iterative clustering, SLIC)算法(Achanta等,2012)将图像分割为 N 个超像素,利用像素平均颜色特征与坐标描述每个超像素。

首先,使用K-means算法根据图像颜色特征将边界划分为 K 个簇族以获取更优的背景种子,边界上属于簇族 k 的超像素数量表示为 $p^k(k=1,2,\dots,K)$,并构建 K 个全局颜色区分矩阵(global color distinction, GCD),表示为

$$\mathbf{S} = [s_{k,i}]_{K \times N} \quad (1)$$

式中, $s_{k,i}$ 为第 k 个GCD矩阵中超像素 i 的显著性值,表示为

$$s_{k,i} = \frac{1}{p^k} \sum_{j=1}^{p^k} \frac{1}{e^{-\frac{\|c_i, c_j\|}{2\sigma_1^2}} + \beta} \quad (2)$$

式中, c_i 是超像素 i 在颜色空间中的特征描述, $\|c_i, c_j\|$ 为颜色空间中超像素 i 与 j 的欧氏距离; σ_1 与 β 为手动设置的权重参数。同时,构建全局空间距离矩阵(global spacial distance, GSD)来平衡

GCD矩阵,GSD矩阵表示为

$$\mathbf{W} = [w_{k,i}]_{K \times N} \quad (3)$$

式中, $w_{k,i}$ 表示超像素 i 与第 k 个簇族中所有边界上的超像素的空间距离,表示为

$$w_{k,i} = \frac{1}{p^k} \sum_{j=1}^{p^k} e^{-\frac{\|r_i, r_j\|_2^2}{2\sigma_2^2}} \quad (4)$$

式中, r_i 与 r_j 表示超像素 i 与 j 的坐标; σ_2 为手动设置的权重参数。

接着,构建包含颜色信息 $s_{k,i}$ 和距离信息 $w_{k,i}$ 的基于背景的图模型,具体为

$$S_i^{\text{bg}} = \sum_{k=1}^K w_{k,i} \times s_{k,i} \quad (5)$$

当 $t=0$ 时,所有超像素经历过一次迭代、在加入颜色信息和空间信息后, S_i^{bg} 记为 S_i^1 ,代表超像素 i 在0时刻的初始显著性值。

最后,基于颜色空间中超像素 i 与 j 的欧氏距离 $\|c_i, c_j\|$ 构造影响因子矩阵和相干矩阵,在每个超像素初始显著性值的基础上,根据同步更新规则,对每个超像素的显著性值进行动态演化,实现图像的视觉显著性检测。

2 基于视觉显著性的眼底图像视盘检测

本文提出了一种基于视觉显著性的眼底图像视盘检测算法,算法流程图如图3所示。首先,依据视盘显著的特点,采用一种视觉显著性的方法对视盘区域进行定位并提取红色通道图像;其次,采用全卷积神经网络(FCN)预训练模型对红色通道图像提取深度特征,同时在基于超像素分割构建的图模型的基础上,提取视盘区域的颜色特征并获取背景先验信息;最后将提取的深度特征、颜色特征和背景先验融合到单层元胞自动机(SCA)中进行迭代演化,从而精确地检测视盘区域。

2.1 基于视觉显著性的视盘区域定位

在眼底图像中,红色通道的视盘区域与背景区域对比度较强,且血管、病灶的对比度较弱,因此选用眼底图像红色通道进行后续检测,如图4所示。

本文采用一种基于视觉显著性的方法(Zhou等,2017)进行视盘区域的定位。首先使用限制对比度自适应直方图均衡技术对红色通道图像进行增

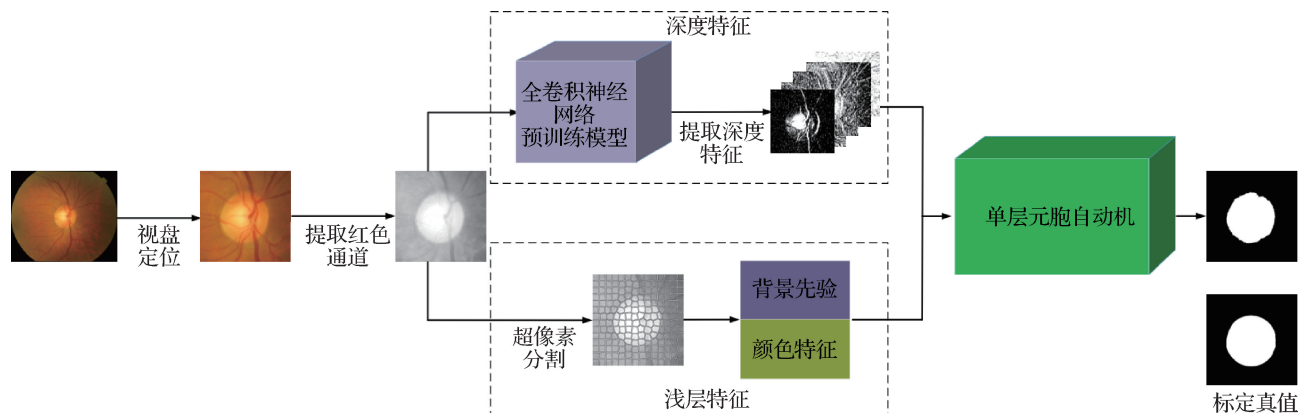



图3 算法流程图

Fig. 3 Algorithm flowchart




(a) 原始眼底图 (b) 红色通道图

图4 原始眼底图以及红色通道图

Fig. 4 Original fundus image and red channel image

((a) original fundus image; (b) red channel image)

强;之后使用基于形态学开重构的方法加大视盘可见性,得到一个视盘区域明亮的眼底图像,且视盘区域最少包含一个区域最大值;最后在重构图像的基础上,进行H极大值变换从而消除所有相连的峰值,得到一组视盘候选区并标记每个区域重心,利用最大系数判据(Kao等,2014)得到视盘重心。为了更好地提取视盘边缘,以视盘重心为中心提取出分辨率为 400×400 像素的正方形区域,如图5所示。



(a) 增强后红色通道图 (b) 形态学重构图 (c) 视盘候选区域二值图 (d) 视盘区域重心 (e) 视盘区域

图5 提取视盘区域

Fig. 5 Extract optic disc area((a) red channel image after enhancement; (b) morphological reconstruction image; (c) binary image of candidate regions; (d) center of optic disc area; (e) optic disc area)

2.2 融合深度特征与浅层特征的视觉显著性视盘检测

2.2.1 颜色特征和背景先验

首先,采用简单线性迭代聚类(SLIC)算法将图像分割为 n 个超像素,以获取图像的基本信息。之后,使用大津阈值(Otsu)算法计算图像灰度阈值。

令 $s_i \in \mathbf{R}$ 为 $t=0$ 时,超像素 i 的初始显著性值, s_i 的值域为 $[0,1]$ 。对平均灰度大于之前所求阈值的超像素,赋予一个接近于1的初始显著性值;基于图像边界的超像素大概率为背景的假设,对处于边界

的超像素赋予一个接近于0的初始显著性值;对于其他超像素,赋予一个统一的初始显著性值,因此

$$s_i = \begin{cases} 0.99 & i \in \text{平均灰度大于阈值的超像素块} \\ 0.5 & i \in \text{其他超像素块} \\ 0.01 & i \in \text{边界超像素块} \end{cases} \quad (6)$$

2.2.2 FCN中深度特征的提取

卷积神经网络最后一层的特征有着抽象的语义信息,这些高级特征可以有效区分不同背景下的对象,并提供对象的位置信息,但分辨率较低;而初始

的神经层中包含颜色、纹理等低级特征。因此将神经网络中不同神经层的深度特征相融合,更有利于对目标的多角度刻画。本文使用全卷积神经网络(FCN)pascal-fcn8 s-dag 预训练模型(该模型由 Matconvnet 团队提供),选择第1个池化层 pool1 和第5个池化层 pool5(分别对应网络的第5层和第31层)进行深度特征提取。图6为从图5(e)中提取的部分深度特征。




图6 所提取的部分深度特征图像

Fig.6 Part of the extracted depth feature images

因为全卷积神经网络中卷积和池化等操作的影响,导致每个卷积层输出结果的分辨率都不同,所以针对网络的不同层,需要对相应的特征图进行裁剪或使用最邻近插值法放大,达到与输入图像同分辨率的目的。因此将 pool1 与 pool5 的特征图进行线性组合,具体为

$$g(\mathbf{r}_i, \mathbf{r}_j) = \rho \cdot \|\mathbf{d}\mathbf{f}_i^5 - \mathbf{d}\mathbf{f}_j^5\|_2 + (1 - \rho) \cdot \|\mathbf{d}\mathbf{f}_i^{31} - \mathbf{d}\mathbf{f}_j^{31}\|_2 \quad (7)$$

式中, $\mathbf{d}\mathbf{f}_i^5$ 和 $\mathbf{d}\mathbf{f}_i^{31}$ 表示超像素 i 的第5层和第31层深度特征; ρ 表示第5层和第31层深度特征的权重,其值域为 $[0, 1]$; $\mathbf{r}_i$ 是超像素 i 的特征描述子, $g(\mathbf{r}_i, \mathbf{r}_j)$ 用来衡量不同超像素间的相似性。

2.2.3 单层元胞自动机

在单层元胞自动机(SCA)中,每个超像素的显著性值代表其当前状态。在这里,给出一个新的邻域定义,类似于图论中的 z 层邻域(本文 $z = 2$),一个超像素的邻域包括与其相邻的超像素,以及与其相邻超像素共享边界的超像素。每个超像素的下一个状态受其邻域超像素状态所影响,这种影响基于特征空间中邻域超像素间的相似性,相似性大小由影响因子矩阵和相干矩阵决定。

1) 影响因子矩阵。邻域中超像素间特征越相

似,则下一个状态相互间的影响越大。邻域中超像素间的相似性大小,由其所在特征空间中的距离决定。在共有 n 个超像素的图像中,构建影响因子矩阵 $\mathbf{F} \in \mathbf{R}^{n \times n}$ 。影响因子矩阵 $\mathbf{F}$ 中的每个元素 f_{ij} 代表超像素 i 与 j 间的影响因子大小,定义为

$$f_{ij} = \begin{cases} \exp\left(\frac{-g(\mathbf{r}_i, \mathbf{r}_j)}{\sigma_f^2}\right) & j \in \mathbf{NB}(i) \\ 0 & j = i \text{ 或其他} \end{cases} \quad (8)$$

式中, $\mathbf{r}_i$ 是超像素 i 的特征描述子, $g(\mathbf{r}_i, \mathbf{r}_j)$ 用来计算特征空间中超像素 i 与 j 的距离,并代表其相似性; σ_f 表示控制相似性强度的参数; $\mathbf{NB}(i)$ 表示超像素 i 邻域中的超像素集合。为了规范化影响因子,建立度矩阵

$$\mathbf{D} = \text{diag}\{d_1, d_2, \dots, d_n\} \quad (9)$$

式中, $d_i = \sum_j f_{ij}$, 则行规范化影响因子矩阵表示为

$$\mathbf{F}^* = \mathbf{D}^{-1} \cdot \mathbf{F} \quad (10)$$

2) 相干矩阵。由于每个超像素的下一个状态是由其当前状态以及其邻域超像素状态共同决定的,所以需要平衡这两个因素的重要性。如果一个超像素在特征空间中与其邻域的超像素完全相同,那么它的下一个状态主要取决于其本身;如果一个超像素与其邻域内的超像素相似,则它的下一个状态受邻域内其他超像素影响较大。根据以上原则,建立相干矩阵 $\mathbf{C}$ 促进超像素的状态更新,具体为

$$\mathbf{C} = \text{diag}\{c_1, c_2, \dots, c_n\} \quad (11)$$

式中,每个超像素当前状态的相干性 c_i 表示为

$$c_i = \frac{1}{\max(f_{ij})} \quad (12)$$

为了将每个超像素相干性状态规范化到 $c_i \in [b, a + b]$, 其中 $[b, a + b] \subseteq [0, 1]$, 因此

$$c_i^* = a \cdot \frac{c_i - \min(c_j)}{\max(c_j) - \min(c_j)} + b \quad (13)$$

式中,最大值与最小值为 $j = 1, 2, \dots, n$ 时所得。规范化相干矩阵表示为

$$\mathbf{C}^* = \text{diag}\{c_1^*, c_2^*, \dots, c_n^*\} \quad (14)$$

3) 同步更新规则。所有超像素都会根据更新规则更新自己的状态,所以更新规则的制订决定着每个超像素演化的方向。依托影响因子矩阵和相干矩阵,同步更新规则定义为

$$\mathbf{s}^{(t+1)} = \mathbf{C}^* \mathbf{s}^{(t)} + (\mathbf{I} - \mathbf{C}) \mathbf{F}^* \mathbf{s}^{(t)} \quad (15)$$

式中, $\mathbf{I}$ 表示 n 维单位矩阵, $\mathbf{C}^*$ 与 $\mathbf{F}^*$ 分别表示规范

化后的相干矩阵与影响因子矩阵; $s^{(t)} \in \mathbf{R}^n$ 表示 t 时刻的显著图, 当 $t = 0$ 时, 各超像素的显著值 $s^{(0)}$ 由式(6)计算得到。其中, 同步更新规则不随时间变化, 超像素的显著性值 $s^{(t)}$ 随迭代次数而改变。

虽然存在亮病灶的干扰, 但属于视盘区域的超像素仍具有相似的特征表示, SCA 利用相邻区域的相关性, 增强相似区域的显著性, 在内部形成稳定的局部环境。同时, 深度特征在不同背景下对视盘均有好的表现, 可以看到视盘与背景间有清晰的边界, 加强了视盘区域的连通性。即使在融合颜色特征时, 亮病灶被赋予很高的显著性值, 也可以在局部环境的影响下自适应地逐渐减小其显著性值。

3 实验结果与分析

为验证本文算法的有效性, 与基于霍夫峰值选择的改进圆形霍夫变换方法 (Ramani 和 Shanthamar, 2020) (以下简称算法 1)、融合多特征与灰度强度局部聚类模型 (LICE) (Gao 等, 2019) (以下简称算法 2) 和结合稠密网络 (DenseNet) 与全卷积神经网络 (FCN) 的 U 型网络 (U-Net) 算法 (Al-Bander 等, 2018) (以下简称算法 3) 等视盘检测算法进行定性与定量比较。

实验使用的视网膜图像来自公开的 DRISHTI-GS、MESSIDOR 和 DRIONS-DB 眼底图像数据集。DRISHTI-GS 数据集 (Sivaswamy 等, 2014) 由印度马杜赖 Aravind 眼科医院提供并注释, 主要用于验证计算机辅助诊疗算法对包括视杯、视盘在内的视神经头等组织检测的有效性和鲁棒性, 数据集中共包含以视盘为中心视野为 30° 的 101 幅彩色视网膜图像, 每幅图像分辨率为 $2\,896 \times 1\,944$ 像素, 视杯与视盘的标定真值由具有多年临床经验的专家手工标注; MESSIDOR 数据集 (Decencière 等, 2014) 由法国国防研究部资助研究的 TECHNO-VISION 项目建立, 主要用于验证计算机辅助诊疗算法, 数据集中共包含以视盘为中心视野为 45° 的 1 200 幅彩色视网膜图像, 图像分辨率共 3 种, 分别是 $1\,440 \times 960$ 像素、 $2\,240 \times 1\,488$ 像素和 $2\,304 \times 1\,536$ 像素, 同时给出了专家手工标定的视盘; DRIONS-DB 数据集主要用于从视网膜眼底图像中对视神经头 (ONH) 进行

分割, 包含 110 幅彩色视网膜图像, 图像分辨率为 600×400 像素, 视盘的标定真值由专家手工标注。

为验证本文算法的准确性, 对视盘检测结果进行定量分析, 采用平均相似度 (Dice) 系数、杰卡德 (Jaccard) 系数、召回率 (recall) 系数、灵敏度 (sensitivity) 系数和准确度 (accuracy) 系数作为评价指标 (Taha 和 Hanbury, 2015)。其中, Dice 系数表示分割结果与标定真值数据之间重叠面积占总面积的比值。Jaccard 系数表示分割结果与标定真值数据之间的相似度。recall 系数用来衡量算法分割目标区域的能力, 灵敏度 (sensitivity) 系数与 recall 系数有同样的定义, 二者等价。accuracy 系数表示正确分割的部分占总体的比值。以上各评价指标的值域均为 $[0, 1]$, 越接近 1, 表示性能越好。

令 TP 代表真阳性值 (true positive), FP 代表假阳性值 (false positive), TN 代表真阴性值 (true negative), FN 代表假阴性值 (false negative), 则 Dice 系数 (Di)、Jaccard 系数 (J)、recall 系数 (R , sensitivity 系数) 和 accuracy 系数 (A) 分别定义为

$$Di = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (16)$$

$$J = \frac{TP}{TP + FP + FN} \quad (17)$$

$$R = Sen = \frac{TP}{TP + FN} \quad (18)$$

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (19)$$

本文算法参数设置为 $n = 200$, $\rho = 0.35$, $1/\sigma_f^2 = 23$, $a = 0.9$, $b = 0$; 实验均在 MATLAB2019a 上运行测试, 计算机配置为 i7-4710MQ 2.50 GHz CPU, 内存为 8 GB。

图 7 展示了数据集中部分血管干扰严重的眼底图像以及本文算法和对比算法的检测结果。由实验结果可知, 算法 1 在对视盘区域检测时, 倾向于将其预测为一个椭圆, 当遇到血管干扰严重的情况, 椭圆会过度发散或收敛; 算法 2 易受较粗的血管干扰, 导致边界粗糙 (如图 7 中第 1 行与第 3 行图像所示), 当盘沿、血管和背景三者灰度相近时, 会出现难以收敛的情况 (如图中第 2 行图像的盘沿底部所示); 算法 3 受粗血管干扰比较严重, 使检测结果血管侧边缘变得粗糙, 当视盘区域的血管较细时, 则对算法检测结果影响很小。如图 7 中第 2 行图像所示, 视盘区域




图7 血管干扰图像及检测结果

Fig. 7 Blood vessel interference images and detection results

((a) test images; (b) ground truth; (c) ours; (d) algorithm 1; (e) algorithm 2; (f) algorithm 3)

右侧两根较细的血管对检测结果干扰较小。与以上算法相比,本文算法可以有效克服血管干扰,获得较好的结果。

图8展示了数据集中部分视盘区域与背景对比度低、边界不清晰的眼底图像以及本文算法和对比算法的检测结果。对实验结果分析可知,算法1在

图像对比度不高时不能有效检测到视盘边界,会出现过度收敛或发散情况(如图8中第1行图像上方所示);算法2在对比度低时没有利用视盘的形状信息,在检测不到视盘边界的一侧会出现不收敛情况(如图8中第2行图像下方所示);算法3在检测由于对比度低导致视盘边缘不清晰的眼底图像时,边缘




图8 弱对比度图像及检测结果

Fig. 8 Weak contrast images and detection results

((a) test images; (b) ground truth; (c) ours; (d) algorithm 1; (e) algorithm 2; (f) algorithm 3)

不清晰的一侧会产生过度收缩情况(如图8中第3行图像下方所示)。对比以上算法,本文算法受眼底图像对比度低、视盘边界不清晰的影响较小,结果较好。

图9展示了数据集中部分存在病灶干扰、视盘边界不规则的眼底图像以及本文算法和对比算法的检测结果。由实验结果可以看出,当因青光眼导致视盘形状不规则时,算法1仍然将其检测为椭圆,并且将视盘周围的病灶也检测为视盘,鲁棒性较差;算法2受周围病灶影响较大,当病灶与视盘灰度相近

时,检测结果会将病灶区域包含在内;算法3受病灶干扰较为严重,在视盘边缘出现病灶时,会将视盘与病灶灰度相似的部分检测为视盘。相比于以上3种算法,本文算法可以有效克服病灶干扰的影响,较为准确地提取视盘边界。

由以上定性实验的结果及分析可知,本文算法可以有效克服眼底图像灰度不均、亮度不强、血管以及病灶等多组织的干扰,实现视盘区域的精确检测,并且本文算法鲁棒性强,检测效果好。




图9 病灶区域干扰图像及检测结果

Fig. 9 Interference images of lesion area and detection results

((a) test images; (b) ground truth; (c) ours; (d) algorithm 1; (e) algorithm 2; (f) algorithm 3)

为进一步验证本文算法的有效性,根据本文算法和对比算法在3个公开数据集中眼底图像视盘区域的检测结果对各算法性能进行定量分析,不同算法的各项评价指标及处理单幅图像所用时间如表1—表3所示。

表1 不同算法在 DRISHTI-GS 数据集中的评价指标对比
Table 1 Comparison of evaluation indicators in DRISHTI-GS dataset among different algorithms

算法	D_i	J	R	A	时间/s
算法1	0.884 3	0.846 7	0.958 2	0.993 1	1.39
算法2	0.920 0	0.854 1	0.935 2	0.967 9	327.7
算法3	0.949 0	0.904 2	0.926 8	0.996 9	27.49
本文	0.965 8	0.934 1	0.964 8	0.996 6	5.346

注:加粗字体表示各列最优结果。

可以看出,本文算法的 Dice 系数、Jaccard 系数和 recall 系数均优于其他算法;本文算法的 accuracy 系数较高,与算法1和算法3接近,高于算法2;在检测单幅图像时,算法1所用时间最短,本文算法

表2 不同算法在 MESSIDOR 数据集中的评价指标对比
Table 2 Comparison of evaluation indicators in MESSIDOR dataset among different algorithms

算法	D_i	J	R	A	时间/s
算法1	0.854 2	0.805 8	0.837 6	0.997 2	1.25
算法2	0.923 7	0.866 9	0.931 3	0.978 4	336.2
算法3	0.939 8	0.883 5	0.920 7	0.995 8	28.11
本文	0.961 6	0.922 4	0.958 9	0.995 3	5.714

注:加粗字体表示各列最优结果。

表3 不同算法在 DRIONS-DB 数据集中的评价指标对比
Table 3 Comparison of evaluation indicators in DRIONS-DB dataset among different algorithms

算法	D_i	J	R	A	时间/s
算法1	0.896 2	0.859 3	0.924 9	0.993 7	1.41
算法2	0.922 9	0.854 6	0.942 1	0.975 2	321.5
算法3	0.941 5	0.891 2	0.923 2	0.996 6	26.43
本文	0.971 1	0.937 6	0.967 4	0.996 8	5.465

注:加粗字体表示各列最优结果。

次之,较算法2和算法3大幅减少。上述实验结果分析表明,本文算法能够在实现快速检测的同时,具有较高的检测精度;同时,在多个公开的数据集上进行算法验证,均取得了较好的检测结果,具有很强的泛化性。本文算法的检测性能明显优于其他3种算法。

4 结 论

本文提出一种基于视觉显著性的眼底图像视盘检测算法,在完成视盘定位的基础上,通过将全卷积神经网络(FCN)预训练模型中提取的深度特征、眼底图像视盘区域的浅层特征与背景先验信息三者相融合,利用特征空间中元胞间的距离判断其相似性,在单层元胞自动机中进行模型的迭代演化。本文算法在视网膜图像公开数据集 DRISHTI-GS、MESSIDOR 和 DRIONS-DB 上进行有效性验证,实验结果表明,本文算法可以很好地克服眼底图像亮度低、对比度弱、血管以及病灶干扰等问题的影响,具有较强的鲁棒性、较高的准确性和较好的泛化性,取得了较好的检测结果。但是,在对眼底图像视盘区域提取颜色特征时,会出现极少数图像由于红色通道亮度过大导致特征提取失败的现象。在今后的工作中,将进一步对特征的融合与提取、视觉显著性的模型演化展开研究,以提升算法对眼底图像视杯、视盘检测的快速性、稳定性和普适性。

参考文献 (References)

- Achanta R, Shaji A, Smith K, Lucchi A, Fua P and Süsstrunk S. 2012. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11): 2274-2282 [DOI: 10.1109/TPAMI.2012.120]
- Acharya U R, Bhat S, Koh J E W, Bhandary S V and Adeli H. 2017. A novel algorithm to detect glaucoma risk using texton and local configuration pattern features extracted from fundus images. *Computers in Biology and Medicine*, 88: 72-83 [DOI: 10.1016/j.combiomed.2017.06.022]
- Al-Bander B, Williams B M, Al-Nuaimy W, Al-Tae M A, Pratt H and Zheng Y L. 2018. Dense fully convolutional segmentation of the optic disc and cup in colour fundus for glaucoma diagnosis. *Symmetry*, 10(4): #87 [DOI: 10.3390/sym10040087]
- Decencière E, Zhang X W, Cazuguel G, Lay B, Cochener B, Trone C, Gain P, Ordonez R, Massin P, Erginay A, Charton B and Klein J C. 2014. Feedback on a publicly distributed image database: the messidor database. *Image Analysis & Stereology*, 33(3): 231-234 [DOI: 10.5566/ias.1155]
- Edupuganti V G, Chawla A and Kale A. 2018. Automatic optic disc and cup segmentation of fundus images using deep learning//*Proceedings of the 25th IEEE International Conference on Image Processing (ICIP)*. Athens, Greece: IEEE; 2227-2231 [DOI: 10.1109/ICIP.2018.8451753]
- Fu H Z, Cheng J, Xu Y W, Wong D W K, Liu J and Cao X C. 2018. Joint optic disc and cup segmentation based on multi-label deep network and polar transformation. *IEEE Transactions on Medical Imaging*, 37(7): 1597-1605 [DOI: 10.1109/TMI.2018.2791488]
- Gao Y, Yu X S, Wu C D, Zhou W, Wang X N and Zhuang Y M. 2019. Accurate optic disc and cup segmentation from retinal images using a multi-feature based approach for glaucoma assessment. *Symmetry*, 11(10): #1267 [DOI: 10.3390/sym11101267]
- Hariharan B, Arbeláez P, Girshick R and Malik J. 2017. Object Instance segmentation and fine-grained localization using hypercolumns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4): 627-639 [DOI: 10.1109/TPAMI.2016.2578328]
- Issac A, Parthasarathi M and Dutta M K. 2015. An adaptive threshold based algorithm for optic disc and cup segmentation in fundus images//*Proceedings of the 2nd International Conference on Signal Processing and Integrated Networks (SPIN)*. Noida, India: IEEE; 143-147 [DOI: 10.1109/SPIN.2015.7095384]
- Jasty U, Harris A, Siesky B, Rowe L W, Vercellin A C V, Mathew S and Pasquale L R. 2020. Optic disc haemorrhage and primary open-angle glaucoma: a clinical review. *British Journal of Ophthalmology*, 104(11): 1488-1491 [DOI: 10.1136/bjophthalmol-2019-314583]
- Kao E F, Lin P C, Chou M C, Jaw T S and Liu G C. 2014. Automated detection of fovea in fundus images based on vessel-free zone and adaptive Gaussian template. *Computer Methods and Programs in Biomedicine*, 117(2): 92-103 [DOI: 10.1016/j.cmpb.2014.08.003]
- Long J, Shelhamer E and Darrell T. 2015. Fully convolutional networks for semantic segmentation//*Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, USA: IEEE; 3431-3440 [DOI: 10.1109/CVPR.2015.7298965]
- Mohammad S, Morris D T and Thacker N. 2013. Texture analysis for the segmentation of optic disc in retinal images//*Proceedings of 2013 IEEE International Conference on Systems, Man, and Cybernetics*. Manchester, UK: IEEE; 4265-4270 [DOI: 10.1109/SMC.2013.727]
- Qin Y, Lu H C, Xu Y Q and Wang H. 2015. Saliency detection via cellular automata//*Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, USA: IEEE; 110-119 [DOI: 10.1109/CVPR.2015.7298606]
- Ramani R G and Shanthamalar J J. 2020. Improved image processing

- techniques for optic disc segmentation in retinal fundus images. *Bio-medical Signal Processing and Control*, 58; #101832 [DOI: 10.1016/j.bspc.2019.101832]
- Sevastopolsky A. 2017. Optic disc and cup segmentation methods for glaucoma detection with modification of U-net convolutional neural network. *Pattern Recognition and Image Analysis*, 27(3): 618-624 [DOI: 10.1134/S1054661817030269]
- Sivaswamy J, Krishnadas S R, Joshi G D, Jain M and Tabish A U S. 2014. Drishti-GS: retinal image dataset for optic nerve head (ONH) segmentation//*Proceedings of the 11th IEEE International Symposium on Biomedical Imaging (ISBI)*. Beijing, China: IEEE: 53-56 [DOI: 10.1109/ISBI.2014.6867807]
- Taha A A and Hanbury A. 2015. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC Medical Imaging*, 15(1): #29 [DOI: 10.1186/s12880-015-0068-x]
- Tekeli O, Savku E and Abdullayev A. 2016. Optic disc area in different types of Glaucoma. *International Journal of Ophthalmology*, 9(8): 1134-1137 [DOI: 10.18240/ijo.2016.08.08]
- Thakur N and Juneja M. 2019. Optic disc and optic cup segmentation from retinal images using hybrid approach. *Expert Systems with Applications*, 127: 308-322 [DOI: 10.1016/j.eswa.2019.03.009]
- Wang Y, Yu X S, Chi J N, Lei X L and Wu C D. 2020. Segmentation of optic cup and disc based on two-layer level set describer in retinal fundus images. *Journal of Image and Graphics*, 25(6): 1260-1270 (王莹, 于晓升, 迟剑宁, 雷晓亮, 吴成东. 2020. 双层水平集描述眼底图像视杯视盘分割. *中国图象图形学报*, 25(6): 1260-1270) [DOI: 10.11834/jig.190396]
- Welfer D, Scharcanski J and Marinho D R. 2013. A morphologic two-stage approach for automated optic disk detection in color eye fundus images. *Pattern Recognition Letters*, 34(5): 476-485 [DOI: 10.1016/j.patrec.2012.12.011]
- Yu T, Ma Y D and Li W. 2015. Automatic localization and segmentation of optic disc in fundus image using morphology and level set//*The 9th International Symposium on Medical Information and Communication Technology (ISMICT)*. Kamakura, Japan: IEEE: 195-199 [DOI: 10.1109/ISMICT.2015.7107527]
- Yu S, Xiao D, Frost S and Kanagasigam Y. 2019. Robust optic disc and cup segmentation with deep learning for glaucoma detection. *Computerized Medical Imaging and Graphics*, 74: 61-71 [DOI: 10.1016/j.compmedimag.2019.02.005]
- Zhou W, Wu C D, Gao Y and Yu X S. 2017. Automatic optic disc boundary extraction based on saliency object detection and modified local intensity clustering model in retinal images. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, E100, A(9): 2069-2072 [DOI: 10.1587/transfun.E100.A.2069]

作者简介



吕鹏飞, 1995年生, 男, 硕士研究生, 主要研究方向为计算机视觉。

E-mail: lvpengfei1995@163.com



于晓升, 通信作者, 男, 讲师, 主要研究方向为计算机视觉、医学影像处理、活动轮廓模型、无线传感器网络。

E-mail: yuxiaosheng@mail.neu.edu.cn

王莹, 女, 博士研究生, 主要研究方向为图像处理和模式识别。E-mail: wangying0337@163.com

王思齐, 男, 硕士研究生, 主要研究方向为计算机视觉。

E-mail: wangsiqi047@163.com

吴成东, 男, 教授, 主要研究方向为机器视觉、智能机器人系统、无线传感器网络、建筑智能化技术。

E-mail: wuchengdong@mail.neu.edu.cn