

基于目标定位的眼睑肿瘤自动诊断

蒋杰伟¹, 刘海洋¹, 蔺彤彤¹, 裴梦杰², 魏戌盟³, 巩稼民^{1,4}, 李中文⁵

1. 西安邮电大学电子工程学院, 陕西 西安 710121; 2. 西安邮电大学计算机学院, 陕西 西安 710121; 3. 西安邮电大学通信与信息工程学院, 陕西 西安 710121; 4. 西安邮电大学现代邮政学院, 陕西 西安 710121; 5. 温州医科大学宁波市眼科医院, 浙江 宁波 315000

【摘要】眼睑肿瘤是导致视力下降甚至致盲的严重眼病, 良恶性结构的相似性导致缺乏临床经验的眼科医生不易区分。针对此问题, 提出一种基于两阶段目标定位算法和融合双重注意力机制的残差网络, 以实现眼睑肿瘤良恶性的自动诊断。首先, 利用FCOS算法自动定位眼眶的整体轮廓, 去除背景区域和周围噪声; 然后, 在眼眶内部精细化定位眼睑肿瘤病灶区域; 最后, 将病灶区域输入到融合双重注意力机制的残差网络(ResNet101_CBAM), 实现良恶性的自动诊断。实验结果表明目标定位算法对眼睑肿瘤病灶的定位平均精度为0.821; 与ResNet101相比, ResNet101_CBAM在眼睑肿瘤分类中的敏感度和准确率分别提高4.7%和3.0%, 表明该模型在眼睑肿瘤良恶性自动诊断中表现出较优性能。

【关键词】眼睑肿瘤; 精细化定位; 双重注意力模块; 残差网络

【中图分类号】R318; R739.71

【文献标志码】A

【文章编号】1005-202X(2023)12-1468-09

Automatic diagnosis of eyelid tumors based on target localization

JIANG Jiewei¹, LIU Haiyang¹, LIN Tongtong¹, PEI Mengjie², WEI Xumeng³, GONG Jiamin^{1,4}, LI Zhongwen⁵

1. School of Electronic Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China; 2. School of Computer Science and Technology, Xi'an University of Posts and Telecommunications, Xi'an 710121, China; 3. School of Communications and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China; 4. School of Modern Post, Xi'an University of Posts and Telecommunications, Xi'an 710121, China; 5. Ningbo Eye Hospital, Wenzhou Medical University, Ningbo 315000, China

Abstract: Eyelid tumor is a serious eye disease that leads to vision loss or even blindness. The similarity between benign and malignant characteristics makes it difficult for ophthalmologists lacking clinical experience to distinguish between them. To address the problem, a method (ResNet101_CBAM) based on two-stage target localization using fully convolutional one-stage object detection (FCOS) and residual network incorporating a dual attention mechanism is proposed to realize the automatic diagnosis of benign and malignant eyelid tumors. FCOS is used to automatically localize the overall contour of the orbit, removing the background and surrounding noise, and then finely localize the tumor lesion inside the orbit. The obtained lesion region is input into ResNet101_CBAM for the automatic diagnosis of benign and malignant eyelid tumors. The experimental results show that the average precision of the target localization algorithm for tumor lesion is 0.821, and that compared with ResNet101, ResNet101_CBAM improves the sensitivity and accuracy in eyelid tumor classification by 4.7% and 3.0%, respectively, indicating that the proposed model has superior performances in the automatic diagnosis of benign and malignant eyelid tumors.

Keywords: eyelid tumor; fine-grained localization; dual attention mechanism; residual network

【收稿日期】2023-08-06

【基金项目】国家自然科学基金(62276210, 82201148); 陕西省自然科学研究计划(2022JM-380); 陕西省大学生创新创业训练项目(S202311664128X); 浙江省自然科学基金(LQ22H120002); 浙江省医药卫生科技项目(2022RC069, 2023KY1140); 宁波市自然科学基金(2023J390); 西安邮电大学研究生创新基金(CXJJZL2022008)

【作者简介】蒋杰伟, 博士, 硕士生导师, 研究方向: 深度学习、机器学习和医疗图像处理, E-mail: jiangjw924@126.com

【通信作者】巩稼民, 博士, 教授, 研究方向: 光通信技术与图像处理, E-mail: gjm@xupt.edu.cn

前言

眼睑肿瘤的发生和发展严重影响视力和身体健康,其中恶性眼睑肿瘤具有较强的转移能力,容易侵袭眼睑、副鼻窦甚至远处器官,可致盲、致残、致畸,甚至是一类可以致死的眼科疾病^[1-2]。眼睑肿瘤若能尽早被发现和治疗,患者的5年生存率可超过99%^[3]。然而,目前我国的眼科医生严重不足,且人工诊断存在着费时、费力和主观性较强的缺陷^[4-6]。因此,基于人工智能算法进行良恶性眼睑肿瘤的自动诊断尤为重要,有望通过早期大规模筛查,为患者争取宝贵的治疗时间。

随着人工智能的发展和医疗图像的不断积累,深度学习算法被广泛应用于各种眼科疾病的自动诊断中,包括白内障^[7-8]、角膜炎^[9-11]、青光眼^[12-13]、糖尿病视网膜病变^[14-15]和眼睑肿瘤^[16-17]等。Jaya等^[18]利用缩放、对比度拉伸和阈值分割等方法预处理60张眼底图像,然后将极限学习机应用于视网膜母细胞瘤自动诊断,其诊断准确率为92%。Adampoulos等^[17]利用卷积神经网络(Convolutional Neural Network, CNN)处理全脸或半脸照片以识别基底细胞癌,其识别准确率为80%。本研究团队借助DenseNet121网络研发良恶性眼睑肿瘤的人工智能系统,其识别率为82.2%^[16]。

上述关于眼睑肿瘤的研究工作主要集中于原始的眼表图像,还缺少对病灶区域的自动定位,另外分

类模型都是基础的CNN,存在着准确率偏低的问题,难以满足临床应用的需求。通过与不同年资的眼科医生进行对比发现本研究团队前期研发的系统性能低于高年资专家水平。为提升眼睑肿瘤良恶性的分类准确率,本研究拟先基于FCOS(Fully Convolutional One-Stage Object Detection)模型^[19]处理眼表图像,对眼睑肿瘤病灶区域实行两阶段精细化定位,然后将定位的病灶区域输入到融合双重注意力机制的ResNet101网络(ResNet101_CBAM)中以区分眼睑肿瘤的良恶性。

1 方法

1.1 眼睑肿瘤自动诊断系统

基于两阶段目标定位算法的眼睑肿瘤自动诊断系统见图1,主要包括病灶定位和眼睑肿瘤良恶性自动分类。图1a是基于FCOS的眼睑肿瘤两阶段目标自动定位过程,先粗定位眼眶轮廓区域,后精细化定位眼睑肿瘤病灶区域,两阶段定位解决了眼睑肿瘤病灶区域较小而定位准确率不高的问题。图1b是眼睑肿瘤良恶性分类的网络结构图,通过在ResNet101网络首个卷积层和最后一个卷积层的后面各增加一个卷积块注意力模块(Convolutional Block Attention Module, CBAM),使CNN关注于眼睑肿瘤的特征,提高眼睑肿瘤良恶性的分类准确率。图1b中BET和MET分别表示良性和恶性眼睑肿瘤。

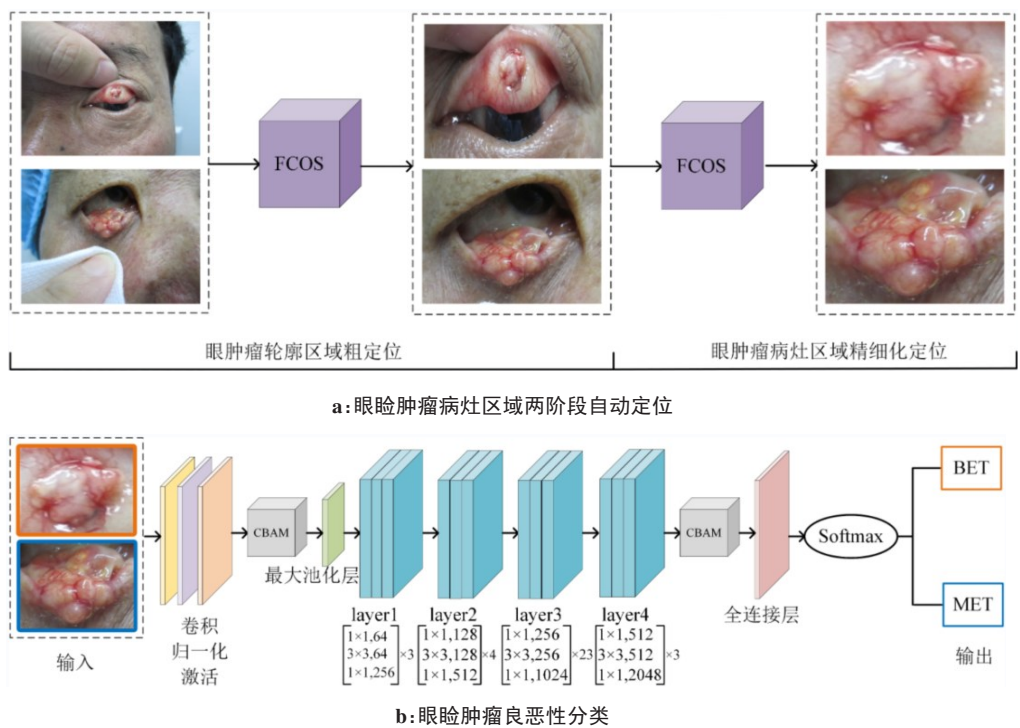


图1 眼睑肿瘤良恶性自动诊断框架图

Figure 1 Framework of automatic diagnosis of benign and malignant eyelid tumors

1.2 眼睑肿瘤目标病灶区域自动定位

FCOS展开后的网络框架如图2所示,其特征提取部分包含主干网络(Backbone)和特征图金字塔网络(Feature Pyramid)。Tian等^[19]证实FCOS是以逐像素预测的方式来检测目标的坐标,可直接预测从中心点到左、右、上和下侧边界框的距离。输入待检测的眼睑肿瘤图像,主干网络依次提取C1~C5层特征,通过下采样操作后其尺度分别缩小为原图像的1/2、1/4、1/8、1/16和1/32。将得到的C3~C5这三层特征经1×1卷积横向连接,双线性插值自顶向下,相邻特征图进行融合,得到包含更多语义信息的特征图P3~P5。对P5执行步长为2、padding为1的卷积操作得到P6,然后再通过一个类似的卷积层得到P7^[20]。在每个特征层后面都接一个检测头(Head),实现相应的检测功能,每个检测头包括3个分支,分别负责分类(Classification)、回归(Regression)和中心度

(Centerness)任务的预测。Centerness技术可以评估当前预测点距离目标中心的远近程度,通过降低远离目标中心的边界框的权重,低质量的边界框被非极大值抑制技术滤除,有助于筛选出质量较高的预测框,从而提升目标定位的精度。FCOS预测的坐标数值属特征图空间,需根据特征图和原图的关系,推算原图上的目标边界框,其计算如式(1)所示:

$$\begin{aligned}x_{\min} &= c_x - l \cdot s \\ y_{\min} &= c_y - t \cdot s \\ x_{\max} &= c_x + r \cdot s \\ y_{\max} &= c_y + b \cdot s\end{aligned}\tag{1}$$

其中, l 、 r 、 t 、 b 分别是预测点相对于目标左、右、上和下侧的距离, s 表示预测特征图相对于原图的步长, (c_x, c_y) 是当前预测点在原图的坐标位置, (x_{\min}, y_{\min}) 和 (x_{\max}, y_{\max}) 分别表示目标左上角和右下角的坐标。

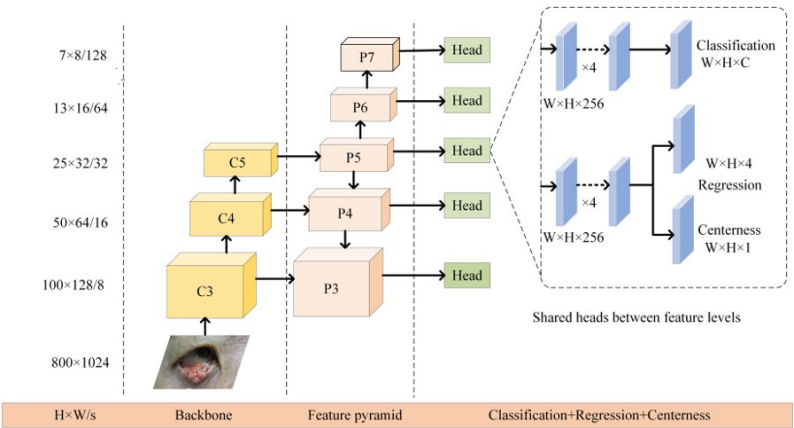


图2 FCOS的网络架构
Figure 2 FCOS network architecture

1.3 眼睑肿瘤良恶性自动诊断

将 CBAM 融入 ResNet101 中 构建 ResNet101_CBAM 网络,以提升眼睑肿瘤良恶性自动诊断的识别率。ResNet是He等^[21]提出的高性能

CNN,包含一条恒等不变的和一条修正偏差的连接,有效解决训练过程中出现的网络退化问题。CBAM的展开形式见图3。




图3 卷积块注意力模块
Figure 3 Convolutional block attention module

CBAM由通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM)级联构成。Ullah等^[22]验证了依次级联通道注意力和空间注意力可获得较优的分类性能。通道注意力 $M_c(F)$ 关注全局信息,通过分析不同通道之间的相互关系,自主选择更高语义的特征,以获取目标图像的显著特征。空间注意力 $M_s(F)$ 关注局部信息,通过分析输入特征对空间位置信息的重要程度,为关注的区域分配更大的权重^[23]。早期良恶性眼睑肿瘤之间的差异较小,容易引起网络的误判;CBAM使模型在学习过程中关注通道和空间维度上的注意力权重,自适应地调整通道权重,提高各个特征在通道和空间上的联系,使作用大的特征图对结果的影响更大一点,从而提升模型的分类性能。两种注意力机制的计算过程如式(2)和式(3)所示:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F)))$$
$$= \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (2)$$
$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F'), \text{MaxPool}(F')]))$$
$$= \sigma(f^{7 \times 7}([F_{\text{avg}}^s, F_{\text{max}}^s])) \quad (3)$$

其中, σ 表示Sigmoid函数,MLP代表多层感知机,AvgPool和MaxPool分别表示平均池化和最大池化操作, W_0 和 W_1 是可学习的权重, F_{avg}^c 和 F_{max}^c 分别表示通道平均池化和最大池化操作, $f^{7 \times 7}$ 表示卷积核大小为 7×7 的卷积操作, F_{avg}^s 和 F_{max}^s 分别表示空间平均池化和最大池化操作。

2 实验结果与分析

2.1 数据集

本研究使用的数据集来源于温州医科大学宁波市眼科医院,共包括1151张眼睑肿瘤图像,每张图像均由两名中等年资的眼科医生根据病灶的状况进行双盲标注,标注不一致的图像由一名高年资的医生审核确定。每张图像的位置、角度、背景等都存在一定的差异,确保数据的多样性。由于医学影像受噪声和成像质量的影响很大,因此,本实验采取随机裁剪、随机水平和垂直翻转、随机图像亮度变化等操作扩增数据集,以防止训练过程中可能出现的过拟合问题,增强网络的泛化性能。眼睑肿瘤良恶性自动分类的数据集是经过目标定位网络裁剪后的图像,且一张图像可能包含一个或多个病变标签,应用于眼睑肿瘤良恶性分类的数据集共有1248张图像。本研究按照70%、15%和15%的比例将数据集划分为训练集、验证集和测试集,数据集的具体分布见表1。

本研究的良性眼睑肿瘤共有4类:色素痣(Pigmented Nevus, PN)、脂溢性角化病(Seborrheic Keratosis, SK)、乳头状瘤(Squamous Cell Papilloma,

表1 眼睑肿瘤数据集的分布
Table 1 Distribution of eyelid tumor datasets

类型	训练集	验证集	测试集	总计
良性	677	144	126	947
恶性	193	47	61	301
总计	870	191	187	1248

SCP)、其它良性肿瘤(Other Benign Tumor, OBT);恶性肿瘤也包括4类:皮脂腺癌(Sebaceous Carcinoma, SC)、基底细胞癌(Basal Cell Carcinoma, BCC)、鳞状细胞癌(Squamous Cell Carcinoma, SCC)、其它恶性肿瘤(Other Malignant Tumor, OMT)。

2.2 实验设置和评价指标

实验硬件环境为4块Nvidia TITAN RTX GPU,软件环境为Ubuntu18.04 64bit操作系统、Pytorch 1.7.0和Python 3.8.0。在眼睑肿瘤病灶自动定位实验中,迭代次数(epoch)设置为36;在眼睑肿瘤良恶性自动分类中,总的epoch设置为30。优化算法选择批量梯度下降法,batch-size设置为32,动量为0.9,学习率采用逐渐递减方式,初始学习率设置为1e-03,每迭代10个epoch,学习率降为原来的1/10,以保证损失函数稳定地收敛。训练过程中利用验证集评估模型的性能,选择验证集上准确率最高的模型为最优的模型。

自动定位的评价指标为平均精度(Average Precision, AP)。分类模型的评价指标为敏感度(Sensitivity)、特异性(Specificity)、准确率(Accuracy)、精确率(Precision)、F1分数(F1-score)、接受者操作特征(Receiver Operating Characteristic, ROC)曲线、ROC曲线下的面积(AUC)、精准率-召回率(Precision-Recall, PR)曲线及混淆矩阵。这些评价指标的计算方法如式(4)~式(9)所示:

$$AP = \int_0^1 P(R) dR$$
(4)

$$\text{Sensitivity} = \frac{TP}{TP + FN}$$
(5)

$$\text{Specificity} = \frac{TN}{TN + FP}$$
(6)

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FN + FP}$$
(7)

$$\text{Precision} = \frac{TP}{TP + FP}$$
(8)

$$F1 - \text{score} = \frac{2 \times TP}{2TP + FP + FN}$$
(9)

其中, P 和 R 分别表示精准率和召回率,TP、FP、TN和FN分别代表真阳性、假阳性、真阴性和假阴性。

2.3 眼睑肿瘤病灶区域自动定位实验结果与分析

为验证FCOS在眼睑肿瘤病灶定位上的性能,本研究选择YOLOv3、Faster_RCNN、VfNet等作为对比模型。表2统计8种不同网络模型在眼睑肿瘤两阶段目标定位上的AP值。从实验对比上来看,第一阶段的AP值均优于第二阶段的AP值,这主要是由于第二阶段要实现眼睑肿瘤病灶区域的精细化定位,第二阶段的定位要难于第一阶段。纵向对比来看,FCOS在两阶段目标定位任务上优于其它对比算法,FCOS第一阶段定位AP值为0.872,第二阶段定位的AP值为0.821。

表2 不同定位网络在眼睑肿瘤两阶段目标定位上的AP值比较
Table 2 Comparison of AP values of different localization networks for two-stages target localization of eyelid tumors

网络模型	第一阶段定位 AP 值	第二阶段定位 AP 值
Deformable_DETR	0.632	0.624
RetinaNet	0.658	0.642
Fovea	0.706	0.687
Sparse	0.752	0.692
VfNet	0.846	0.738
Faster-RCNN	0.835	0.801
YOLOv3	0.854	0.810
FCOS	0.872	0.821

为直观地分析FCOS在眼睑肿瘤上的定位效果,图4展示部分典型的眼睑肿瘤定位结果。图中两个绿色的虚线框是由医生标注的真实框,紫色和红色的实线框代表FCOS两个阶段的定位结果,较大的紫色框是第一阶段定位的眼眶轮廓区域,较小的红色框是第二阶段精细化定位的病灶区域。FCOS的定位结果与医生标注的真实框几乎是重叠的,表明本文方法在眼睑肿瘤自动定位上具有较高的准确率。

2.4 眼睑肿瘤良恶性自动诊断实验结果与分析

2.4.1 模型性能分析 为深入对比不同深度学习算法在眼睑肿瘤上的诊断性能,统计5种模型在测试集上的敏感度、特异性、准确率、精确率和F1分数性能评价指标,见表3。在5种经典CNN对比方法中,DenseNet121的特异性和精确率较高,其值分别为87.4%和63.4%。AlexNet敏感度最高,其值为82.8%。ResNet101的性能较好,其准确率和F1分数分别为83.7%和69.9%。

对较优算法ResNet101融合双重注意力机制,以提高良恶性眼睑肿瘤的分类性能。ResNet101_CBAM在首个卷积层和在最后一个卷积层各添加CBAM,作为消融对比试验,分别表示为ResNet101_CBAM1和ResNet101_CBAM2。从表4可以看出,ResNet101_CBAM1的敏感度最高,其敏感度为93.8%;ResNet101_CBAM2的特异性和精确率最高,其值分别为88.3%和68.0%。相比

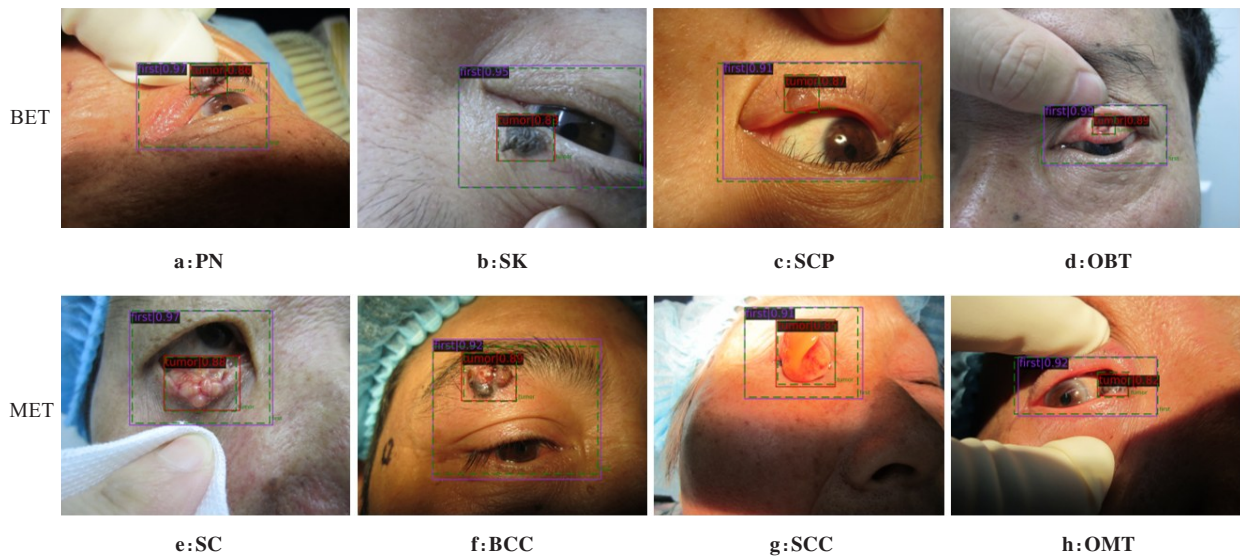


图4 FCOS对几种典型眼睑肿瘤的自动定位结果
Figure 4 Automatic localization results of several representative eyelid tumors using FCOS

ResNet101, ResNet101_CBAM 的敏感度、特异性、准确率、精确率和 F1 值分别提高 4.7%、2.4%、3.0%、5.3% 和 5.1%。ResNet101_CBAM 对良恶性眼睑肿瘤的识别准确率优于其它分类模型,融合双重注意力

表3 5种CNN在眼睑肿瘤测试集上的性能对比(%)

Table 3 Performance comparison among 5 CNN on the test set of eyelid tumors (%)

算法	敏感度	特异性	准确率	精确率	F1 分数
DenseNet121	70.3	87.4	83.3	63.4	66.7
Inception-v3	81.3	83.5	83.0	60.5	69.3
AlexNet	82.8	81.1	81.5	57.6	67.9
VGG19	79.7	83.5	82.6	60.0	68.5
ResNet101	79.7	85.0	83.7	62.2	69.9

表4 消融实验结果(%)

Table 4 Ablation experiment results (%)

算法	敏感度	特异性	准确率	精确率	F1 分数
ResNet101	79.7	85.0	83.7	62.2	69.9
ResNet101_CBAM1	93.8	82.0	84.8	61.9	74.5
ResNet101_CBAM2	79.7	88.3	86.3	68.0	73.4
ResNet101_CBAM	84.4	87.4	86.7	67.5	75.0

机制的ResNet能有效提升眼睑肿瘤的诊断性能。

为分析良恶性眼睑肿瘤正确和错误识别的具体数量,图5给出ResNet101_CBAM和其对比模型在测试集的混淆矩阵。相比ResNet101,ResNet101_CBAM1对恶性眼睑肿瘤的识别数量增加9例,显著提升对恶性眼睑肿瘤的识别准确率;ResNet101_CBAM2对良性眼睑肿瘤的识别数量增加7例;ResNet101_CBAM对良恶性识别同时达到最优,其对良恶性眼睑肿瘤识别错误的数量分别减少5例和3例。

为显示出本文方法的性能,图6统计ResNet101_CBAM和其对比方法分别对良恶性眼睑肿瘤的识别准确率。ResNet101_CBAM1对恶性眼睑肿瘤的识别准确率最高,为93.75%;ResNet101_CBAM2对良性眼睑肿瘤的识别准确率最高,为88.35%。综合对比来看,ResNet101_CBAM对两种眼睑肿瘤的识别达到最优。ResNet101_CBAM较ResNet101对良性眼睑肿瘤的识别准确率提升2.43%,对恶性眼睑肿瘤的准确率提升4.69%,表明ResNet101_CBAM有助于识别良恶性眼睑肿瘤,从而对患者进行及时的治疗和干预。ResNet101_CBAM对提高眼科医生的临床工作效率和诊断准确性具有积极作用,有望为良恶性眼睑肿瘤的早期发现和治疗提供更好的支持。

图7展示ResNet101_CBAM与5种性能优异的

CNN在眼睑肿瘤识别上的ROC和PR曲线对比图。ResNet101_CBAM的ROC曲线更靠近左上角,AUC值最大,表明该模型的诊断性能最优。相较对比方法中性能较好的ResNet101,ResNet101_CBAM的AUC值提高1.6%,达到0.951(95%CI:0.927-0.973)。图7b为PR曲线图,ResNet101_CBAM更偏向右上方,说明本文方法具有更优的性能。进一步从对比图中还发现一个有意义的结论:当Recall在0~0.7之间时,最佳算法ResNet101_CBAM的Precision均为1,表明ResNet101_CBAM在预测恶性眼睑肿瘤方面的性能优于其他5种CNN模型。

2.4.2 热图可解释性分析 为探索ResNet101_CBAM对眼睑肿瘤的诊断依据,本研究利用Grad-CAM (Gradient-Weighted Class Activation Mapping)可视化技术^[24]生成恶性眼睑肿瘤的可解释性热力图。观察深度学习模型对眼睑肿瘤关注的区域有助于分析模型是否学习到正确的眼睑肿瘤分类特征信息^[25]。图8是几种典型恶性眼睑肿瘤的可视化实验结果,图8a~图8d依次是原始的眼表图像、第一阶段粗定位后结果、第二阶段精细化定位结果和对应的可视化热图。结果发现:(1)离病灶中心区域愈近,颜色愈呈现出鲜明的深红色,表明模型对此区域更加关注;(2)无论眼睑肿瘤的位置、大小和形状如何,ResNet101_CBAM均能以热图的形式可视化眼睑肿瘤病灶区域,有助于病灶分类特征的学习。

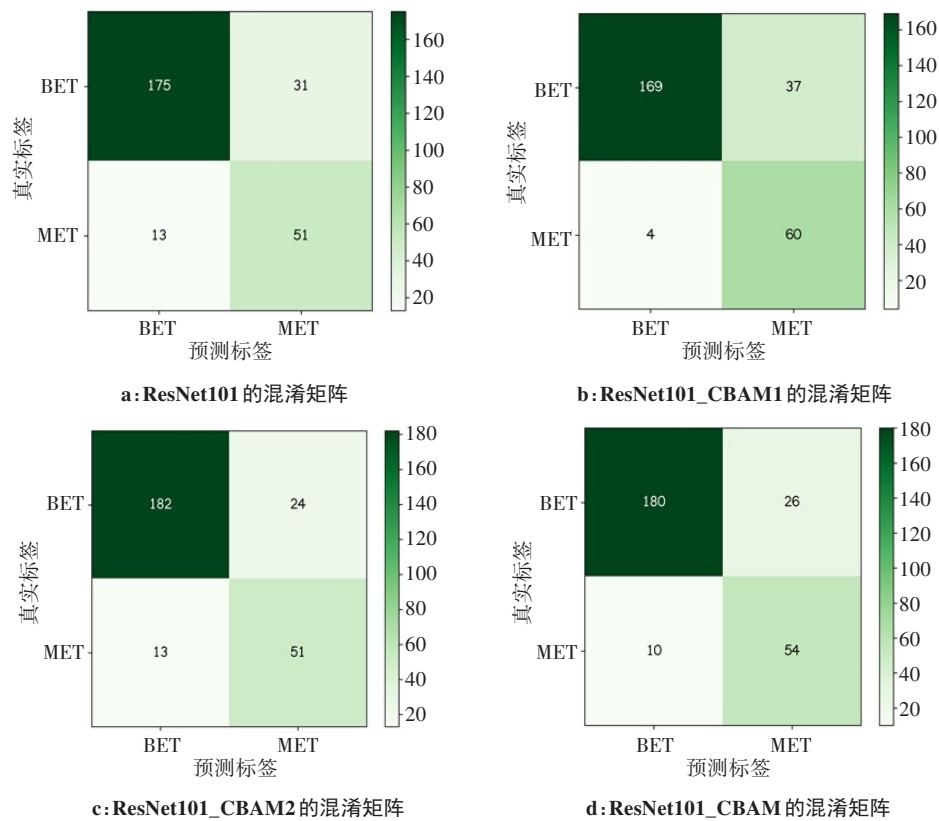


图5 ResNet101_CBAM和对比模型在测试集上的混淆矩阵

Figure 5 Confusion matrixes of ResNet101_CBAM and the other models on the test set




图6 ResNet101_CBAM和对比模型对良恶性眼睑肿瘤识别准确率

Figure 6 Accuracy of ResNet101_CBAM and the other models for distinguishing benign and malignant eyelid tumors

3 结 论

本研究提出一种两阶段目标定位算法,实现眼睑肿瘤病灶区域的自动定位并过滤了四周噪声;通过将双重注意力模块嵌入到 ResNet101 中,使模型更关注眼睑肿瘤病变区域,有效提高眼睑肿瘤良恶性的诊断性能。本文方法在一定程度上可以辅助眼科医生进行诊断,有利于人工智能算法应用于眼睑肿

瘤临床,同时也为其它疾病小病灶的诊断提供新思路。但由于良恶性眼睑肿瘤早期形态的相似性和眼睑肿瘤数据集相对较小,不利于模型提取有效的分类特征;下一步将分析诊断错误图像的原因,研究细分类及小样本处理算法,进一步提升眼睑肿瘤良恶性自动诊断的性能。

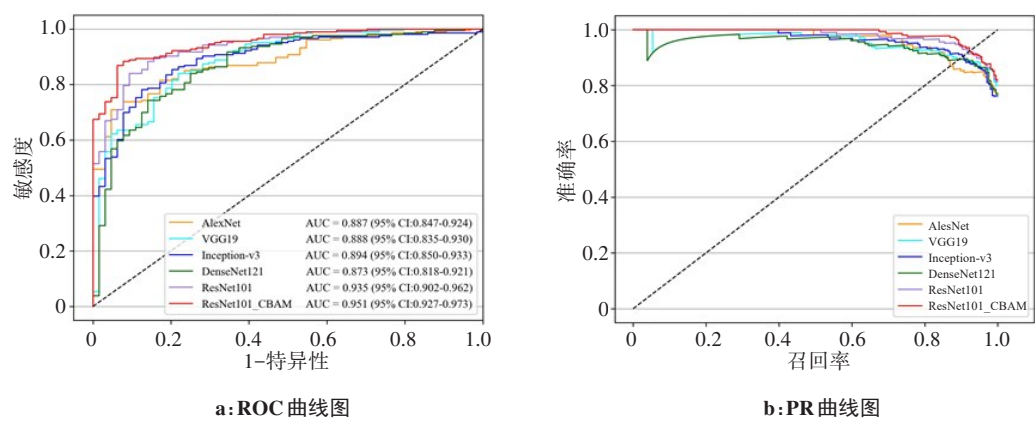


图7 ResNet101_CBAM与5种CNN在眼睑肿瘤自动诊断上的ROC和PR曲线对比

Figure 7 Comparison of ROC and PR curves of ResNet101_CBAM and 5 CNN on automatic diagnosis of eyelid tumors



图8 典型恶性肿瘤的原图、两阶段定位结果及可视化热图

Figure 8 Original images, two-stage localization results, and visualized heatmaps of typical malignant eyelid tumors

【参考文献】

[1] Huang YY, Liang WY, Tsai CC, et al. Comparison of the clinical characteristics and outcome of benign and malignant eyelid tumors: an analysis of 4521 eyelid tumors in a tertiary medical center[J]. Biomed Res Int, 2015, 2015: 453091.

[2] 范先群, 贾仁兵. 我国眼肿瘤专业70年发展和展望[J]. 中华眼科杂志, 2020, 56(9): 7.

[3] Fan XQ, Jia RB. The development and prospect of ophthalmic oncology specialty in my country in the past 70 years[J]. Chinese Journal of Ophthalmology, 2020, 56(9): 7.

[4] Cook BE, Bartley BG. Treatment options and future prospects for the management of eyelid malignancies: an evidence-based update[J]. Ophthalmology, 2001, 108(11): 2088-2098.

[5] Li W, Wang Z, Qu J, et al. Acanthamoeba keratitis related to contact lens use in a tertiary hospital in China[J]. BMC Ophthalmol, 2019, 19(1): 1-6.

[6] Singh R, Das S, Chodosh J, et al. Paradox of complex diversity: challenges in the diagnosis and management of bacterial keratitis[J]. Prog Retin Eye Res, 2021, 88: 101028.

[7] Kredics L, Narendran V, Shobana CS, et al. Filamentous fungal infections of the cornea: a global overview of epidemiology and drug sensitivity[J]. Mycoses, 2015, 58(4): 243-260.

[8] Jiang J, Wang L, Fu H, et al. Automatic classification of heterogeneous slit-illumination images using an ensemble of cost-sensitive convolutional neural networks[J]. Ann Transl Med, 2021, 9(7): 550.

- [8] Jiang J, Liu X, Zhang K, et al. Automatic diagnosis of imbalanced ophthalmic images using a cost-sensitive deep convolutional neural network[J]. Biomed Eng Online, 2017, 16(1): 132.
- [9] Li Z, Jiang J, Chen K, et al. Preventing corneal blindness caused by keratitis using artificial intelligence[J]. Nat Commun, 2021, 12(1): 3738.
- [10] Hung N, Shih AK, Lin C, et al. Using slit-lamp images for deep learning-based identification of bacterial and fungal keratitis: model development and validation with different convolutional neural networks[J]. Diagnostics, 2021, 11(7): 1246.
- [11] Natarajan R, Matai HD, Raman S, et al. Advances in the diagnosis of herpes simplex stromal necrotising keratitis: a feasibility study on deep learning approach[J]. Indian J Ophthalmol, 2022, 70(9): 3279-3283.
- [12] Asaoka R, Murata H, Hirasawa K, et al. Using deep learning and transfer learning to accurately diagnose early-onset glaucoma from macular optical coherence tomography images[J]. Am J Ophthalmol, 2019, 198: 136-145.
- [13] Kucur ŞS, Holló G, Sznitman R. A deep learning approach to automatic detection of early glaucoma from visual fields[J]. PLoS One, 2018, 13(11): e0206081.
- [14] Gulshan V, Peng L, Coram M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs[J]. JAMA, 2016, 316(22): 2402-2410.
- [15] Ting DS, Cheung YL, Lim G, et al. Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes[J]. JAMA, 2017, 318 (22): 2211-2223.
- [16] Li Z, Qiang W, Chen H, et al. Artificial intelligence to detect malignant eyelid tumors from photographic images[J]. NPJ Digit Med, 2022, 5(1): 23.
- [17] Adampoulos A, Chatzopoulos EG, Anastassopoulos G, et al. Eyelid basal cell carcinoma classification using shallow and deep learning artificial neural networks[J]. Evol Syst-Ger, 2021, 12(3): 583-590.
- [18] Jaya I, Andayani U, Siregar B, et al. Identification of retinoblastoma using the extreme learning machine[J]. J Phys Conf Ser, 2019, 1235 (1): 012057.
- [19] Tian Z, Shen C, Chen H, et al. FCOS: fully convolutional one-stage object detection[J]. arXiv: 1904.01355v5, 2019.
- [20] Yao S, Zhu Q, Zhang T, et al. Infrared image small-target detection based on improved FCOS and spatio-temporal features [J]. Electronics, 2022, 11(6): 933.
- [21] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.
- [22] Ullah KR, Sheng WW, Ullah I, et al. Evaluating the efficiency of CBAM-Resnet using Malaysian sign language[J]. Comput Mater Contin, 2022, 71(2): 2755-2772.
- [23] Xiao Y, Yin H, Wang SH, et al. TReC: transferred ResNet and CBAM for detecting brain diseases[J]. Front Neuroinform, 2021, 15: 781551.
- [24] Selvaraju RR, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks *via* gradient-based localization[J]. Int J Comput Vision, 2020, 128(2): 618-626.
- [25] Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead[J]. Nat Mach Intell, 2019, 1(5): 206-215.

(编辑:谭斯允)