

DOI:10.19651/j.cnki.emt.2211816

基于注意力机制和空洞卷积的瞳孔定位算法^{*}

孙语 刘文龙 蒋茂松

(大连理工大学信息与通信工程学院 大连 116081)

摘要: 瞳孔定位在人机交互中起着关键性作用,然而由于反射、眨眼和睫毛遮挡等噪声以及瞳孔位置不居中、运动导致模糊等问题,使得瞳孔中心定位的准确率下降、鲁棒性减弱,从而导致精确地定位瞳孔仍存在巨大困难。为此,本文提出一种基于注意力机制和空洞卷积的瞳孔检测定位算法。该算法以 U-Net 的编码-解码结构为基础,编码部分采用 VGG16 并引入空洞卷积,以充分地提取特征,解码部分加入 Attention Gate,使得模型具有更好的鲁棒性。然后,使用最小二乘法对网络输出的瞳孔分割图进行拟合,最终根据拟合图像获取瞳孔中心坐标。本算法使用 ExCuSe 公开的 24 个数据集进行验证,实验表明该算法可以准确的定位瞳孔位置,平均检测率可达到 92.6%。

关键词: 瞳孔中心定位;U-Net;注意力机制;空洞卷积;最小二乘法

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.6040

Pupil location algorithm based on Attention Gate and dilated convolution

Sun Yu Liu Wenlong Jiang Maosong

(School of Information and Communication Engineering, Dalian University of Technology, Dalian 116081, China)

Abstract: Pupil location plays a key role in Human-Computer Interaction. However, due to the noise of reflection, blink and eyelash occlusion, as well as the pupils at the edge of image and blurred due to movement, the accuracy and robustness of pupil center location are reduced, which leads to great difficulties in accurate pupil location. Therefore, this paper proposes a pupil detection and location algorithm based on attention mechanism and cavity convolution. The algorithm is based on the coding-decoding structure of U-Net, VGG16 is used in the coding part and dilated convolution is introduced to fully extract features, Attention Gate is added in the decoding part to make the model more robust. Then, the least square method is used to fit the pupil segmentation map output by the network. Finally, the pupil center coordinates are obtained according to the fitted image. The algorithm is verified by 24 data sets that are publicly available. Experiments show that the algorithm can accurately locate the pupil position, and the average detection rate can reach 92.6%.

Keywords: pupil center location; U-Net; Attention Gate; dilated convolution; least square method

0 引言

眼动跟踪技术是指测量凝视点或记录测量眼球运动的过程,被广泛应用于医学、心理学、军事等领域^[1],临幊上眼动指标的异常可以为诊断帕金森、精神分裂症等疾病提供重要依据^[2]。准确的定位瞳孔中心位置是实现眼动跟踪的前提,然而,眼睛的运动过程总是伴随着各种噪声,例如,光照条件不良、眼镜等导致的反射,睫毛以及眨眼的遮挡等噪声,以及瞳孔位置不居中引起的瞳孔模糊等问题^[3]。这些非理想环境对于瞳孔中心定位的精确度和鲁棒性产生了一定程度的影响,难以满足对注视点定位跟踪的准确性需求。

因此,如何能够在非理想环境下准确地定位瞳孔位置^[4],是一个难度较大且具有现实意义的问题。

目前,国内外已经提出了许多瞳孔检测算法。2015 年,Fuhl 等^[5]提出了 ExCuSe 算法,该算法通过角度积分投影函数计算的定向直方图,通过椭圆估计对粗瞳孔中心估计进行细化。2016 年,Fuhl^[6]提出一种基于边缘滤波和椭圆估计的瞳孔检测算法,该算法首先计算图像直方图,然后通过边缘检测找到瞳孔。2017 年,田耘等^[7]提出基于 SIFT 特征和 SVM 分类器的瞳孔定位算法。同年,臧晶等^[8]通过混合投影与 Hough 变换检测的方法来检测瞳孔。

收稿日期:2022-10-24

*基金项目:大连医科大学附属第二医院科临床能力提升“1+X”计划交叉学科创新项目(2022JCKZD03)、国家重点研发计划项目(2018YFE0197700)、中央高校基本科研业务费专项(DUT22YG110)资助

2019 年,李擎等^[9]提出等距离补偿的方法解决瞳孔遮挡问题。传统算法计算量大,难以满足实时性的需求,并且在嘈杂环境中难以准确地找到瞳孔位置。

随着深度学习的不断发展,其在图像分类、分割以及目标跟踪等领域取得了显著的成绩,部分学者将 CNN 和 YOLOv3 等网络应用于瞳孔定位中,例如,Fuhl 等^[10]、Chinsatit 等^[11]将眼睛图像作为 CNN 的输入,直接生成瞳孔中心最为回归结果,马启玮等^[12]提出通过 YOLOv3 模型和星射线法定位瞳孔。与传统方法相比,采用目标跟踪网络的方法有一定程度的改善,但是此类方法鲁棒性较低,得到的瞳孔中心波动较大,当瞳孔中心处于图像边缘位置时,经常造成较大的像素差。

为了更加准确地定位瞳孔位置,本文提出了一种基于注意力机制和空洞卷积的方法来定位瞳孔。该方法以 U-Net 分割网络为基础,编码部分将 VGG16 与空洞卷积结合,解码部分加入 Attention Gate(AG),使网络在减小信息损失,扩大感受野,能够聚焦有用特征,提高算法鲁棒性。再经过后处理操作最终得到瞳孔中心坐标。通过实验表明,相比于其他算法,本文算法在准确性和抗噪声性能方面均具有一定的优势。

1 基于注意力机制和空洞卷积的瞳孔定位算法

本文算法的总体流程如图 1 所示。首先,将原始的有

噪声眼睛图像作为网络模型的输入,输出为瞳孔分割图像;其次,使用最小二乘法拟合圆进行后处理操作,对瞳孔分割图像进行拟合;最后,根据拟合结果,得到瞳孔中心坐标。

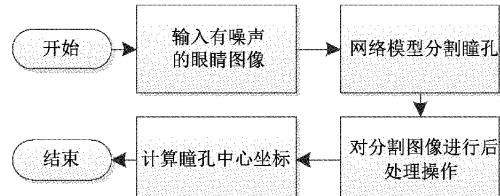


图 1 算法总体流程

1.1 网络模型

本文提出的基于注意力机制和空洞卷积的瞳孔定位算法的网络模型如图 2 所示。网络结构以 U-Net^[13]为基础。U-Net 因其结构呈“U”型而得名^[14],是在 FCN 基础上提出的应用于医学图像的分割网络,该网络简单、高效,容易构建,可以从小数据集中训练得到一个相对准确的结果。与细胞图像、CT 图像等其他复杂的医学图像相比,瞳孔的形状较规律,所以本文将原本 U-Net 网络层数从 5 层减少到 4 层,各层通道数设置为 32, 64, 128, 512, 以减少网络模型的复杂度,从而提高模型效率。

图 2 的左侧为编码部分,采用了结构规整且简单的 VGG16 来进行特征提取,使用的激活函数为 ReLU,在图

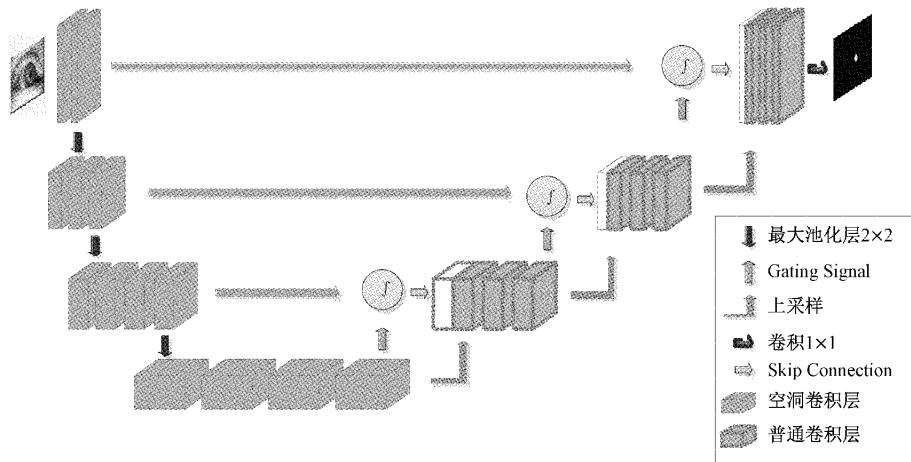


图 2 网络模型结构

像边界进行 2 个像素值为 0 的填充,从而保持原先的维度,并引入空洞卷积。具体来讲,第 1、2 层各有两个空洞卷积层和一个的最大池化层,第 3、4 层分别由 3 个空洞卷积层和一个的最大池化层组成,采用多个的小型卷积核串联,比单独使用一个较大的卷积核拥有更少的参数量和更多的非线性变换,可以增加网络的拟合能力。

图 2 右侧的解码部分的每一层由两个卷积层组成,卷积的激活函数为 ReLU,加入批量归一化处理和 Dropout^[15],并引入 Attention Gate(AG),其结构如图 3 所

示。将下层的 feature1 与上一层的 feature2 作为 AG 的输入,经过 AGs 后的输出与上采样后的 feature1 融合。其中,Dropout 可以有效地防止过拟合,在一定程度上达到正则化的效果。

1.2 空洞卷积

传统卷积的过程是通过滑动窗口从上到下,从左到右对输入图片进行遍历,如图 4(a)所示。空洞卷积也叫扩张卷积或者膨胀卷积^[16],与传统卷积不同的是,空洞卷积在卷积核之间加入一些 0 来扩大卷积核的过程,如图 4(b)所

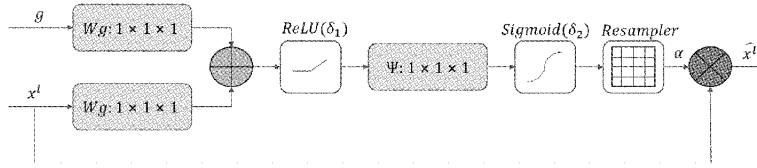


图 3 AG 模块结构

示。空洞卷积可以聚合更大尺度的信息,同样的卷积核尺寸,空洞卷积具有更大的感知域,可以减少信息丢失。本文算法网络结构的编码部分引入空洞卷积,网络 1 层和第 2 层为两个 3×3 的空洞卷积,第 3、4 层为单个 3×3 的空洞卷积,膨胀率均为 2,此时感受域变为 5×5 ,相当于 3×3 的空洞卷积等效于 5×5 的普通卷积,并且连续的几个空洞卷积串联,使得网络提取的特征更全面,能够获得更丰富的信息,提高分割的精度。

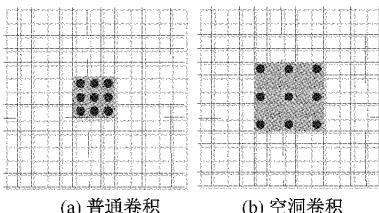


图 4 普通卷积和空洞卷积

1.3 Attention Gate

Attention Gate(AG)是由 Oktay 等^[17]提出的用于胰腺分割任务的注意力机制模块。在进行胰腺分割时,需要排除其他器官结构的干扰,准确地定位到目标位置,识别出其形状及大小,AG 模块通过基于网格的门控,可以使模型在训练时学会抑制不相关的区域,使注意力集中到位置、形状及大小等特征。对于本文中的瞳孔图像,虽然分割目标形状单一,但由于瞳孔大小的不确定以及在实际的图像采集过程中存在睫毛、眨眼遮挡,光线反射、运动导致的模糊等不同的噪声,常会导致 U-Net 网络难以准确地分割出目标瞳孔区域。本文使用 AGs 模块可以很大程度减小多种噪声的干扰,提高分割的精确度和准确率,并且应用到 U-Net 网络结构时简单方便、计算开销小。

如图 3 所示为 AG 的结构示意图, g 为门控向量,包含上下文的信息,以过滤低级别的特征响应, x^l 是输入的特征向量,两者分别经过一个的卷积,再将两个向量逐个元素相加,合成的向量经过一个 ReLU 激活函数和卷积,再经过一个 sigmoid 激活函数,最后得到一个注意力系数 $\alpha \in [0,1]$,将 α 和原始 x^l 逐元素相乘得到输出特征向量 $\hat{x}^l = \alpha \times x^l$,然后在 skip connection 中正常传递。注意力系数 α 的计算公式如下^[18]:

$$\alpha = \delta_2(\psi^T(\delta_1(\omega_x^T X^l + \omega_g^T g + b_1)) + b_2) \quad (1)$$

式中: δ_1 表示 ReLU 激活函数, δ_2 表示 sigmoid 激活函数, b_1 和 b_2 表示偏置, ψ 和 ω 表示卷积。

1.4 损失函数

本文使用基于 Dice 得分系数的 Dice Loss 函数^[19]来代替传统医学图像经常使用的交叉熵损失函数,式(2)是 Dice 系数表达式,式(3)为 Dice Loss 计算公式,Dice 系数的值取值范围为 $[0,1]$,越大表示预测结果与真实结果重合度越大。

$$D_c = \frac{2 \sum_i p_{ic} g_{ic}}{\sum_i p_{ic}^2 + \sum_i g_{ic}^2} \quad (2)$$

$$DL_c = \sum_c (1 - D_c) \quad (3)$$

式中, N 为像素点总个数, c 表示种类个数,本文设置为 2,即瞳孔区域和背景区域两类; p_{ic} 表示分割结果中像素为 c 类别的概率, g_{ic} 表示标签中像素为 c 类别的概率。

1.5 瞳孔中心定位

根据网络模型得到的瞳孔分割图像可以计算瞳孔中心坐标,但是分割图像可能存在边缘噪声、瞳孔区域不完整或不连续等问题,从而导致计算得到的瞳孔中心坐标存在误差,因此需要对分割图像进一步处理来精细化结果,以得到更准确的瞳孔坐标。本文采用最小二乘法拟合圆^[20]进行后处理操作,根据分割图像将完整的瞳孔区域拟合出来,再计算瞳孔中心坐标。如图 5(c)所示为标记的拟合后的瞳孔分割图像。

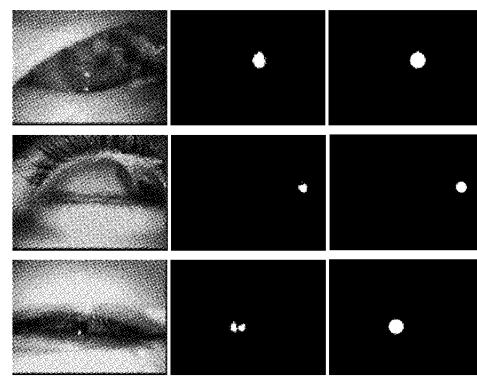


图 5 后处理结果

表 1 列出了上述 3 张图像不同处理后计算得到的坐标与真实坐标的欧式距离,用 $\rho(X, Y)$ 表示。由表可知,经过后处理得到的坐标值与真实值的欧式距离明显减小,这表明了经过后处理操作可以提供更加精确的结果,使得瞳孔定位更加准确。

表1 后处理前后坐标值比较

| | 图像1 | 图像2 | 图像3 |
|-------------|-----------|-----------|-----------|
| 未后处理(A) | (220,124) | (328,132) | (166,167) |
| 后处理(B) | (216,126) | (326,130) | (166,165) |
| 真实值(L) | (212,128) | (326,128) | (166,165) |
| $\rho(A,L)$ | 8.94 | 4.47 | 2 |
| $\rho(B,L)$ | 4.47 | 2 | 0 |

2 实验结果与分析

2.1 数据集

本文使用 ExCuSe^[5]公开的 24 个数据集进行验证与评估,从每个数据集中随机选取 100 张图片,共 2 400 张图片作为训练集。如图 6 所示为数据集中的图像实例,包含了不同形式的干扰,如光线不良引起的反射,眨眼和睫毛的遮挡,运动导致的模糊等。数据集中的图片分辨率均为 384×288,并提供了相应的真实值标签。

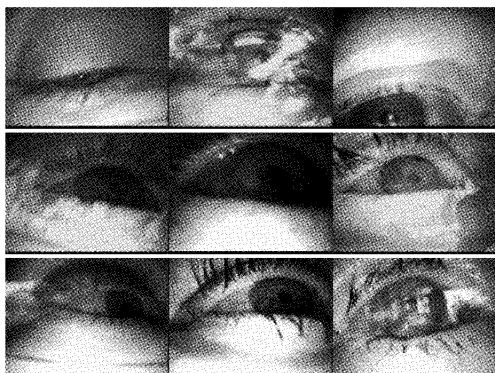


图 6 数据集中图像示例

2.2 实验环境与评价指标

本文使用处理器为 Inter(R) Core(TM) i9-10900X CPU@3.70 GHz, RAM 为 128 GB 的 PC 进行训练,以 tensorflow 为框架建立网络模型,使用 Adam 优化器来训练模型。

本文通过计算预测的瞳孔中心坐标与人工标记的坐标之间的欧氏距离判断算法是否准确,计算公式如下:

$$d = \sqrt{(x'_i - x_i)^2 + (y'_i - y_i)^2} \quad (4)$$

式中: (x'_i, y'_i) 为预测的瞳孔中心坐标, (x_i, y_i) 为人工标记的瞳孔中心坐标。

具体来讲,计算 N 个像素误差范围内的瞳孔中心数,将其表示为像素误差 N 下的检测率(Detectionrate)。由于在手动制作标签的过程中,不可避免地会存在一定的误差,因此,通常以欧氏距离不超过 5 个像素作为瞳孔定位准确的标准,即计算 $N=5$ 时的检测率,检测率计算公式如下:

$$\text{Detectionrate} = \frac{n}{N} \times 100\% \quad (5)$$

其中, n 表示在该数据集中欧氏距离不超过 5 的图片个数, N 表示该数据集的总图片数。

2.3 训练结果

本算法学习率设置为 1×10^{-5} , epoch 设置为 5, batch size 为 2。如图 7 所示为本文算法的 Loss 和准确率(IoU)曲线,可以看到 Loss 曲线收敛速度较快,随着迭代次数的增加,Loss 值不断下降,模型准确率上升,当迭代到第 3 次, Loss 值和准确率趋于稳定,表明了该模型具有良好的鲁棒性和稳定性。

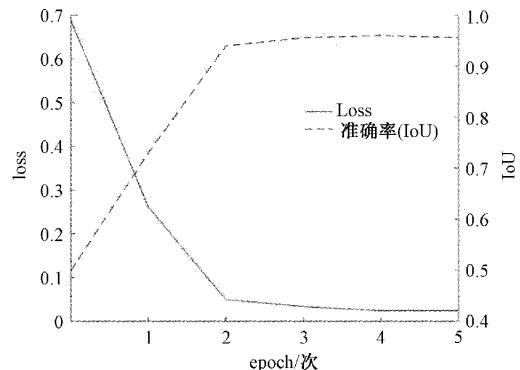
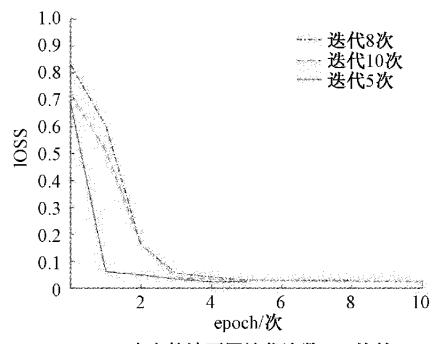
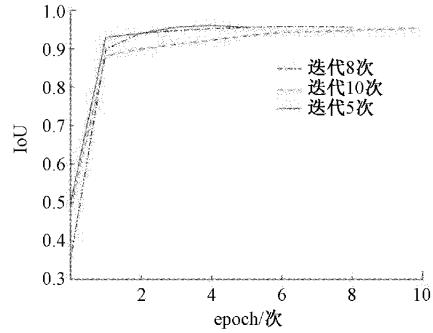


图 7 本文算法 Loss 与准确率(IoU)

为验证模型的收敛性与准确度,首先比较了本文算法不同迭代次数的 Loss 值与准确率(IoU)值的变化情况。如图 8 所示,为本文算法分别在迭代 5 次,迭代 8 次,迭代 10 次的情况下 Loss 值与准确率(IoU)比较。由图 8(a) 可知,本文算法 Loss 收敛速度较快,在迭代 3 次以后, Loss



(a) 本文算法不同迭代次数Loss比较



(b) 本文算法不同迭代次数准确率(IoU)比较

图 8 本文算法不同迭代次数 Loss 与准确率(IoU)比较

值趋于稳定;由图 8(b)可知,本文算法在迭代 3 次以后,准确率稳定,从而验证了本文算法模型的收敛性与准确率。

其次,为了进一步验证本文算法实时性上的改进,比较了 Attention U-Net, U-Net(baseline)以及本文算法 Loss 收敛所需要的迭代的次数。如图 9 所示为各算法训练时 Loss 的收敛情况,相比于其他算法,本文算法 Loss 值收敛所需的迭代次数更少。

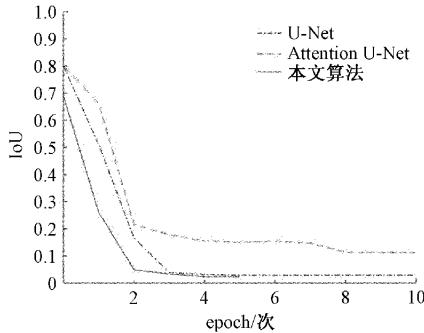


图 9 不同算法 loss 收敛需要的迭代次数

2.4 模型有效性验证

本文算法在 U-Net 网络的基础上,编码部分加入空洞卷积,解码部分引入 Attention Gate,为了验证算法在两个方面进行改进的有效性,本文进行了各模块消融实验的比较,如图 10、11 所示为加入各模块后的 Loss 值与准确率(IoU)曲线,可以看到本文算法融入空洞卷积和 AG 后的达到收敛时 Loss 值更小,训练模型的准确率更高。

2.5 实验结果与分析

本文比较了 Hough 算法、DeepEye^[21], U-Net(ConvexShape)^[22], U-Net(baseline), Attention U-Net^[17],

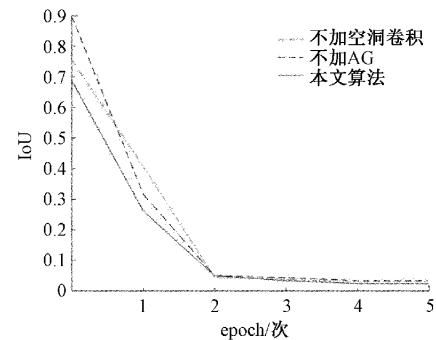


图 10 消融实验 Loss 值曲线

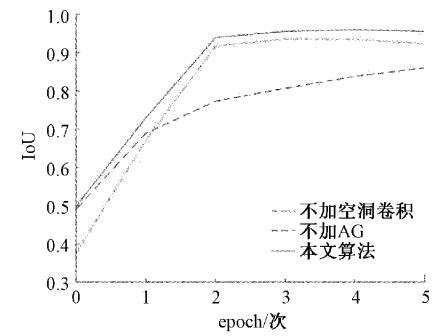


图 11 消融实验准确率(IoU)曲线

消融算法以及本文算法在 ExCuSe 的 24 个数据集的检测率。如图 12 所示,圆圈为标记的本文算法识别到的瞳孔位置,从图中可以看到,本文算法可以很准确地定位到瞳孔位置,对于具有一定反射的图像、抖动模糊图像、睫毛眨眼遮挡图像等高噪声干扰问题均表现了良好的性能。

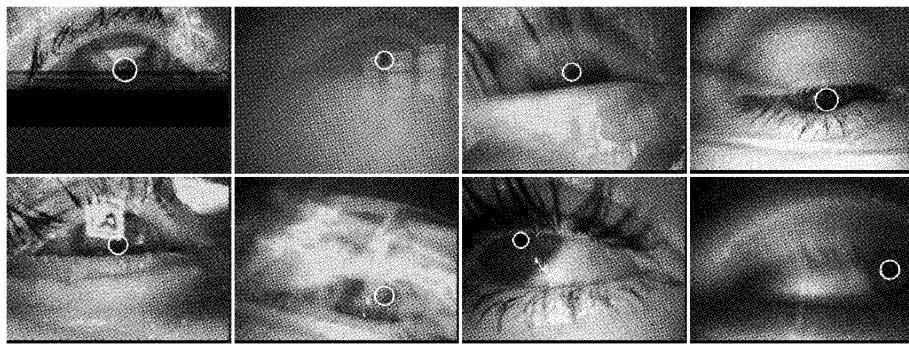


图 12 本文算法检测结果示例,圆圈为本文算法检测到的瞳孔位置

表 2 列出了几种算法在 24 个数据集上的检测率,由表 2 可知:

1)Hough 的传统算法鲁棒性较差,导致检测率较低,与传统算法相比,本文算法的检测率具有明显的优势,这是因为通过网络的学习可以尽可能多的学习到瞳孔特征,使网络保留完整的瞳孔区域,减少了噪声等问题的干扰,使检测率大幅度提高;

2)根据消融实验对比结果,相比于 U-Net(baseline),

加入空洞卷积和 AG 均能提高瞳孔中心定位的准确率,在 4 层 U-Net 网络结构中同时融入空洞卷积与 AG 对瞳孔中心定位的准确率上有明显的优势,从而验证了本文算法的可靠性。

3)相比于其他的基于神经网络的算法,本文算法的检测率也有明显优势,在 24 个数据集的检测率的平均值为 92.6%。这是因为本文算法中使用的 AG(s)模块,能够抑制模型学习与瞳孔无关的特征,同时还可以加强与目标特

表 2 不同算法检测率比较

| 数据集 | 算法 1 | 算法 2 | 算法 3 | 算法 4 | 算法 5 | 算法 6 | 算法 7 | 算法 8 |
|-------|-------|-------|-------|-------|------|-------|-------|-------|
| I | 22 | 86 | 90 | 98 | 96 | 94 | 97 | 98 |
| II | 10 | 83 | 81 | 81 | 91 | 90 | 90 | 93 |
| III | 37 | 93 | 91 | 94 | 97 | 91 | 97 | 98 |
| IV | 14 | 93 | 92 | 99 | 99 | 99 | 99 | 99 |
| V | 45 | 97 | 98 | 92 | 97 | 97 | 94 | 97 |
| VI | 44 | 93 | 95 | 96 | 95 | 98 | 97 | 99 |
| VII | 51 | 84 | 84 | 96 | 89 | 92 | 95 | 92 |
| VIII | 17 | 87 | 94 | 77 | 84 | 82 | 82 | 83 |
| IX | 13 | 92 | 93 | 89 | 96 | 96 | 97 | 99 |
| X | 39 | 92 | 94 | 92 | 95 | 96 | 82 | 96 |
| XI | 51 | 94 | 98 | 95 | 94 | 98 | 96 | 97 |
| XII | 22 | 85 | 87 | 88 | 96 | 98 | 98 | 99 |
| XIII | 44 | 79 | 85 | 80 | 97 | 98 | 99 | 99 |
| XIV | 45 | 96 | 98 | 97 | 93 | 92 | 97 | 97 |
| XV | 33 | 89 | 70 | 59 | 65 | 67 | 63 | 89 |
| XVI | 40 | 82 | 66 | 65 | 89 | 86 | 94 | 97 |
| XVII | 52 | 95 | 91 | 88 | 99 | 99 | 98 | 99 |
| XVIII | 10 | 74 | 95 | 80 | 88 | 86 | 97 | 95 |
| XIX | 20 | 78 | 97 | 88 | 90 | 90 | 90 | 87 |
| XX | 22 | 92 | 82 | 60 | 91 | 78 | 94 | 92 |
| XXI | 19 | 88 | 78 | 50 | 70 | 75 | 74 | 80 |
| XXII | 30 | 81 | 80 | 75 | 52 | 32 | 50 | 80 |
| XXIII | 29 | 95 | 98 | 99 | 99 | 99 | 99 | 99 |
| XXIV | 38 | 65 | 60 | 55 | 50 | 50 | 49 | 67 |
| 平均 | 31.25 | 87.21 | 87.38 | 83.04 | 88 | 86.79 | 88.67 | 92.96 |

征有关的任务。另外,空洞卷积可以增加感受野,减少信息的损失,这样一来,模型可以很准确地学习到瞳孔特征,从而实现精准分割瞳孔的目的。

4)对于数据集 XXIV,由于该数据集的图像较暗,反射严重,受噪声干扰较多,使得瞳孔难以观测,从而导致本文算法难以准确定位到瞳孔。同样地,其他算法在该数据集上的检测率也不理想。

其中算法 1 为 Hough 算法、算法 2 为 Deepeye,算法 3 为 U-Net(ConvexShape),算法 4 为 U-Net(baseline),算法 5 为 Attention U-Net,算法 6 为只引入空洞卷积的消融算法,算法 7 为只引入 AG 的消融算法,算法 8 为本文算法。

3 结 论

本文提出了一种检测定位瞳孔中心的方法,可以应用于许多交互系统中。该方法以 U-Net 网络为基础,在编码部分使用 VGG16,并加入空洞卷积,目的是减小信息丢失,扩大感受野,充分地提取特征。在解码部分引入 Attention Gate,通过注意力来抑制图像中的无关信息,突出重要特征。然后,使用最小二乘法根据分割图像拟合标

记出瞳孔区域,再获取瞳孔中心坐标。通过 ExCuSe 的 24 个数据集上进行验证,本文方法具有较高的检测率,可达到 92.96%。经过与其他算法定量比较,本文算法比其他算法在检测率方面有着明显提高。在未来的研究中心,我们会进一步提高算法的效率,将其应用于人机交互研究中。

参 考 文 献

- [1] 宁小鸽,牟莉. 基于梯度方向约束的瞳孔定位算法研究[J]. 国外电子测量技术,2021,40(7):115-121.
- [2] 童言,穆平安,林玉莹. 基于圆形滑动窗口的瞳孔定位算法[J]. 电子测量技术,2021,44(2):99-103.
- [3] 宋保全,杜文华,段能全,等. 非接触眼压计的人眼瞳孔定位算法研究[J]. 电子测量技术,2022,45(3):112-117.
- [4] 林舒欣,陆启桐,王尚媛,等. 基于空洞全卷积网络的非理想状态的瞳孔定位[J]. 激光杂志,2021,42(8):33-38.
- [5] FUHL W, T KÜBLER, SIPPEL K, et al. ExCuSe: Robust pupil detection in real-world scenarios [C].

- Computer Analysis of Images and Patterns, 2015.
- [6] FUHL W, SANTINI T C, KUEBLER T, et al. ElSe: Ellipse selection for robust pupil detection in real-world environments [J]. ACM, 2015, DOI: 10.1145/2857491.2857505.
- [7] 田耘,甄雯,赵海军.基于改进的SIFT算子和SVM分类器的瞳孔中心定位[J].液晶与显示,2017,32(6):499-505.
- [8] 贤晶,徐旭云,刘冠楠.一种融合混合投影和虹膜定位的瞳孔定位[J].电子世界,2017,(13):175.
- [9] 李擎,胡京尧,迟健男,等.视线追踪中一种新的由粗及精的瞳孔定位方法[J].工程科学学报,2019,41(11):1484-1492.
- [10] FUHLL W, SANTINI T, KASNECI G, et al. PupilNet: Convolutional neural networks for robust pupil detection[J]. Revista De Odontologia Da Unesp, 2016, 19(1):806-821.
- [11] CHINSATIT W, SAITO H. CNN-based pupil center detection for wearable gaze estimation system[J]. Appl. Comput. Intell. Soft Comput., 2017: 1-10.
- [12] 马启玮,韩慧妍,韩燮,等.基于星射线法的瞳孔中心定位[J].计算机工程与设计,2021,42(5):1409-1417.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computer and Computer-assisted Intervention. Springer, Cham, 2015:234-241.
- [14] 张宇豪,徐磊,白一清.基于融合U-Net和水平集的肝脏CT图像分割[J].电子测量技术,2021,44(9):116-121.
- [15] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1):1929-1958.
- [16] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[C]. ICLR, 2016.
- [17] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: Learning where to look for the pancreas [J]. ArXiv Preprint, 2018, ArXiv: 1804.03999.
- [18] JIN Q, MENG Z, SUN C, et al. RA-UNet: A hybrid deep attention-aware network to extract liver and tumor in CT scans[J]. ArXiv Preprint, 2018, ArXiv: 2020.605132.
- [19] MILLETARI F, NAVAB N, AHMADI S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation [J]. ArXiv Preprint, 2016, ArXiv:1606.04797.
- [20] FITZGIBBON A W, PILU M, FISHER R B. Direct least squares fitting of ellipses [C]. International Conference on Pattern Recognition, IEEE, 2002.
- [21] VERA-OLMOS F J, PARDO E, MELERO H, et al. DeepEye: Deep convolutional network for pupil detection in real environments [J]. Integrated Computer Aided Engineering, 2018, 26:1-11.
- [22] HAN S Y, KWON H J, KIM Y, et al. Noise-robust pupil center detection through CNN-based segmentation with shape-prior loss[J]. IEEE Access, 2020(99):1-1.

作者简介

孙语,硕士研究生,主要研究方向为图像处理。

E-mail:sunyu960902@163.com

刘文龙,教授,博士生导师,主要研究方向为生物医学信号处理,通信信号处理,图像处理,深度学习。

E-mail: liuwl@dlut.edu.cn

蒋茂松,博士研究生,主要研究方向为信号处理,图像处理。

E-mail: msjiang2879@mail.dlut.edu.cn