

基于卷积神经网络的疲劳检测改进算法

周先春^{1,2} 邹清宇¹ 陆 滇¹

¹(南京信息工程大学电子与信息工程学院 江苏 南京 210044)

²(江苏省大气环境与装备技术协同创新中心 江苏 南京 210044)

摘要 为了解决当前的疲劳检测算法准确率低或实时性差的缺点,提出一种改进的卷积神经网络疲劳检测算法。使用 HOG 检测算法结合 KCF 跟踪算法对采集的人脸进行检测和跟踪;随后调用 Dlib 库进行脸部关键点的提取;通过引入可变形卷积神经网络对提取的眼部和嘴部进行状态识别;通过 CEW 和 YAWDD 数据集进行测试,疲劳检测准确率达到 94.36%。实验表明,与当前的疲劳检测算法相比,提出的方法能够实时地检测驾驶员疲劳,并且具有较高的准确率。

关键词 人脸检测 Dlib 可变形卷积 状态识别 疲劳检测

中图分类号 TP391.41

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.06.023

AN IMPROVED ALGORITHM FOR FATIGUE DETECTION BASED ON CNN

Zhou Xianchun^{1,2} Zou Qingyu¹ Lu Dian¹

¹(School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, Jiangsu, China)

²(Jiangsu Collaborative Innovation Center of Atmospheric Environment and Equipment Technology, Nanjing 210044, Jiangsu, China)

Abstract In order to solve the shortcomings of low accuracy or poor real-time performance of current fatigue detection algorithms, an improved convolution neural network fatigue detection algorithm is proposed. HOG detection algorithm combined with KCF tracking algorithm was used to detect and track the collected faces. The Dlib library was called to extract the key points of the face. A deformable convolution neural network was introduced to identify the extracted eye and mouth states. This algorithm was tested by CEW and YAWDD data set. The accuracy of fatigue detection reaches 94.36%. Experiments show that compared with the current fatigue detection algorithms, the proposed method can detect driver fatigue in real time with high accuracy.

Keywords Face detection Dlib Deformable convolution State recognition Fatigue detection

0 引言

随着经济的快速发展,人民生活水平得到了普遍提高,整个社会对于汽车的需求日益增长。但是汽车的增加,使得道路交通状况恶化,疲劳驾驶是导致道路交通事故的主要因素之一。疲劳驾驶引起的交通事故发生概率是正常驾驶的四到六倍,引起的交通事故约占事故总数的 20%,占重大交通事故的 40% 以上^[1]。

因此,对驾驶员的驾驶状况进行实时检测,当发生疲劳驾驶时给出有效的预警,对于减少交通事故的发

生有重要意义^[2-3]。常用的疲劳驾驶检测方法有三类^[4-7]:基于车辆驾驶状态检测、生理信号检测和驾驶员的面部特征检测。针对驾驶员面部特征的检测,国内外的研究人员提出了不同的检测方法。邹昕丹等^[8]提出了基于 Adaboost 算法提出人脸区域,通过灰度直方图统计特征法判断眼部区域,似圆度判断嘴部打哈欠,从而判断是否疲劳。顾王欢等^[9]使用多尺度池化卷积神经网络模型(MTCNN)提升图像的分辨率效果,进而根据嘴巴和眼睛状态判断是否疲劳。李长勇等^[10]采用了实时增强局部约束模型的多信息疲劳检测方法,解决了光线和姿态变化等影响疲劳检测的问

收稿日期:2021-01-15。国家自然科学基金项目(11202106,61302188);江苏省大学生创新创业训练计划项目(202010300128P)。

周先春,副教授,主研领域:图像处理。邹清宇,硕士生。陆滇,本科生。

题,能够实现对驾驶员的实时检测。基于驾驶员脸部特征的疲劳检测方法,主要是通过对驾驶员脸部状态的识别来判断驾驶员的状态。基于传统的疲劳检测的算法,检测的准确率低,基于深度学习的疲劳检测算法^[11],参数较多,模型比较大,失去了在实际应用中的时效性。

针对上述的问题,为了提高疲劳检测的效率的准确性,将传统的检测算法与深度学习方面相结合,提出了一种基于可变形卷积神经网络的疲劳检测方法。首先对脸部进行采集,通过 HOG 人脸检测器和 KCF 跟踪算法相结合,提取人脸的图像,随后调用 Dlib 库进行人脸关键点检测,提取眼部和嘴部的实时特征,然后引入可变形卷积神经网络对眼部和嘴部进行状态识别,最后通过 PERCLOS 和打哈欠的参数,判断驾驶员是否疲劳驾驶。实验表明,该算法实现了对驾驶员疲劳状态准确快速地检测判断,疲劳检测系统的整体框图如图 1 所示。

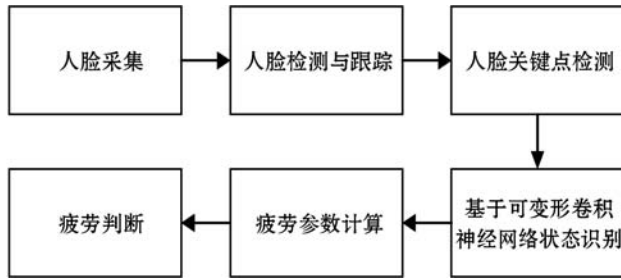


图 1 系统整体框图

1 人脸检测与跟踪

首先选取 HOG 算法进行人脸检测,方向梯度直方图(HOG)^[12]是使用统计图像的局部区域的梯度方向直方图来描述对象的特性,可以恰当地描述目标的轮廓,并且保持收集和光学转换的不变性。HOG 算法另外一个优点就是不容易受到噪声的干扰,下面是 HOG 算法对人脸进行检测的步骤^[13]:

(1) gamma 归一化。用 gamma 对采集的图像进行颜色空间的归一化,调节图像的对比度,抑制噪声,并减少局部阴影和光照的影响,如式(1)所示。

$$I(x, y) = I(x, y)^{\text{gamma}} \quad (1)$$

(2) 计算图像梯度,获取图像轮廓的信息,进一步减少光照的干扰。图像在 (x, y) 点的水平方向和竖直方向的梯度计算公式分别为式(2)和式(3)。

$$G_x = I(x+1, y) - I(x-1, y) \quad (2)$$

$$G_y = I(x, y+1) - I(x, y-1) \quad (3)$$

再由和计算得到梯度值和梯度方向,公式分别如式(4)和式(5)所示。

$$|\nabla f(x, y)| = \text{mag } \nabla f(x, y) = \sqrt{G_x^2 + G_y^2} \quad (4)$$

$$\theta = \arctan\left(\frac{G_x(x, y)}{G_y(x, y)}\right) \quad (5)$$

(3) 将图像分割成多个均匀大小的 Cell 单元格,相邻的单元格之间不重合,为每个单元构建梯度方向直方图。将固定数量的 Cell 单元形成大的块(block),块内归一化梯度直方图。

(4) HOG 特征的则是单元块内所有 block 的 HOG 描述符一起组合起来得到,通过滑动每个单元块窗口完成图像的人脸检测。

实际应用的疲劳检测系统对算法的实时性要求较高,为了缩短人脸检测的时间,提出将 HOG 人脸检测器和 KCF 跟踪算法结合,对人脸进行实时检测。这种方法可以减少人脸检测的次数,从而减少检测消耗的时间,同时增加了对人脸姿态变化、遮挡等的鲁棒性。

KCF 跟踪算法是一种实时性相关滤波算法^[14],相对主流的深度学习跟踪算法,运算速度更快。它一般在跟踪过程中训练一个目标检测器,用目标检测器检测下一帧的预测位置是否是目标,然后用新的检测结果更新训练集,再更新目标检测器。训练目标检测器时,一般选择目标区域作为正样本,而目标周围区域为负样本。这使得分类器能够专注于区分前景和背景,因此类鉴别器通常优于生成的类。在 KCF 跟踪算法中,以核回归分类器为核心,构造循环样本矩阵来训练分类器,并对样本进行巧妙的变换。通过使训练数据矩阵循环,离散傅里叶变换可以对角化,减少几个数量级的存储和计算,从而达到快速有效地检测和跟踪目标的目的^[15]。

因此,采用 HOG 人脸检测器结合 KCF 跟踪算法,大大地减少了人脸检测算法的计算量,可以缩短运算时间,使疲劳检测的实时性得到满足。

2 脸部关键点提取

脸部关键点的提取能够降低图像背景和环境的干扰,快速定位到人脸的眼部和嘴部。然后定位到人脸的关键点,增加了疲劳检测方法的准确性,在疲劳检测系统的研究中有重要的作用。

选取基于 Dlib 库^[14]的人脸特征点检测方法,可以直接调用 Dlib 库进行脸部关键点的提取。Dlib 是一个开源数据工具库,库中含有很多机器学习的成熟的算法和模型,Dlib 解决了学术界和工业界各种问题。相比 tensorflow 和 Pytorch,Dlib 用于人脸面部特征提取具有通用性和优越性。为了提高人脸的识别率,使用

shape_predictor_68_face_landmarks 人脸关键点模型, 结构如图 2 所示, 包括眼睛轮廓和嘴部轮廓等。在 Python 中直接调用 Dlib 库, 编程简单, 准确度也高, 并且消耗的时间很短。在许多情况下, 由于误报率很小, 因此 Dlib 比 Haar 级联更为准确。同样, 在测试时进行调整需要较少的参数。首先, 可以在各种物体中异常描述轮廓和边缘特征, 因此特别适用于面部检测。其次, 在区域单元上执行操作, 从而可以忽略对象的运动。基于 Dlib 库的脸部关键点检测效果如图 3 所示。




图 2 68 个面部标识点



图 3 人脸特征点定位效果

3 基于可变形卷积神经网络的眼部和嘴部状态识别

搭建的网络结构选择 LeNet5, 结构如图 4 所示。在卷积神经网络中引入可变形卷积, 就是在 CNN 的基础上加以改进, 将所设计的部分卷积层替换为可变形卷积层, 解决了脸部状态识别的问题。最终得到的网络结构包括 2 个卷积层(C)、2 个抽样层(S)、1 个可变形卷积层(DC)和一个全连接层(F)。改进后的网络命名 DC-CNN 网络, 使用 DC-CNN 网络提取特征之后, 将某一中间层作为特征描述, 然后通过 Softmax 分类器对眼部和嘴部进行分类。DC-CNN 输入需要 32×32 规格的图像, 经过每个网络层最终得到输出的结果, 脸

部状态识别的模型结构如图 5 所示。




图 4 LeNet5 网络结构




图 5 DC-CNN 脸部状态识别的模型结构

可变形卷积, 就是将偏移变量添加到标准的卷积核中的常规采样位置, 可以使采样网格自由变形, 卷积核采样点的位置分布如图 6 所示。图(a)是传统的卷积神经网络的卷积核, 图(b)是引入随机偏移变量的卷积核, 图(c)和图(d)是图(b)的特殊形式。与正常的卷积神经网络相比, 可变形卷积网络提取图像特征效率增加。DC-CNN 是根据输入图像提取特征, 得到的特征再作为输入, 对特征图再加一个卷积层, 是得到可变形卷积的变形偏移量。对眼部和嘴部训练时, 用于生成输出特征的卷积核和偏移量的卷积核同步学习, 提高脸部状态的识别率。




图 6 卷积核采样点的位置分布

选取的卷积核是 3×3 采样, 定义为: $R = \{(-1, -1), (-1, 0), \dots, (0, 1), (1, 1)\}$, 则每个元素表示卷积中每个位置相对于中心位置的偏移量, 则对于输出的特征图 y 上的每一个位置 p_0 , 通过式(7)得出结果。 p_n 表示区域内的任意位置, p_0 表示中心位置, w 表示卷积核的权重, x 表示输入, y 表示输出。对每个卷积核的采样位置增加额外的参数使采样位置能够自动向脸部目标区域偏移。可变形卷积得到的矩阵为式(8), 其中 Δp_0 是 p_0 的偏移量。

$$y(p_0) = \sum_{P_n \in R} w(p_n) \cdot x(p_0 + p_n) \quad (6)$$

$$y(p_0) = \sum_{P_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n) \quad (7)$$

图 7 是可变形卷积层的学习过程。在输入层中加入偏移变量,使用插值算法将任意位置的输出转换成对于特征图的插值操作,这样既可以保证得到的像素准确,还可以进行方向传播。然后使带偏移变量的输出特征图与输入特征图具有一致的空间分辨率,传递给下一个网络层,实现了对图像特征的提取。




图 7 可变形卷积原理

4 疲劳参数计算

驾驶员在行驶的过程中,出现眨眼次数减少,频率降低以及频繁打哈欠的行为时,可以判断此时的驾驶员是疲劳驾驶。通过基于可变形卷积神经网络的状态识别结果的基础上,计算 PERCLOS 值和打哈欠的数据,作为判断疲劳驾驶的依据。PERCLOS^[17]值的计算公式如式(9)所示,PERCLOS 疲劳判断原理是通过判断原理是通过计算眼睛处于闭合状态的时间与某段时间的比例来判断驾驶员的疲劳状态。打哈欠的参数统计如式(10)所示, n 是单位时间内嘴巴张开状态的总帧数, N 为单位时间内的总帧数,如果驾驶员打哈欠,那么 F 会达到最大值。

$$P_{\text{ERCLOS}} = \frac{\text{眼睛闭合帧数}}{\text{检测时间段总帧数}} \times 100\% \quad (8)$$

$$F_{\text{Mopen}} = \frac{n}{N} \quad (9)$$

5 实验和分析

5.1 实验环境

使用的硬件测试环境为 i7-4720H 四核 2.6 GHz, 显卡 GTX950, 内存 12 GB, 操作系统 Windows 10, 软件使用的是 PyCharm2019, PyThon3.7。

5.2 眼部和嘴部数据集和检测

为了构建眼部数据集和嘴部数据集,提高脸部状

态识别的准确率,提出的方法选取网上公开的 CEW 眼部数据集、YAWDD^[18] 打哈欠数据集和自制的数据集。公开的眼数据集和选取包含大量眼睛和嘴巴的样本,自制的数据集包括多名实验人员的眨眼、打哈欠的图片。最终共有 8 500 幅图片,包含眼睛样本 5 500 幅图像,嘴巴样本 3 000 幅图片。为了提升检测结果的效果,对图片进行归一化为 32×32 像素进行网络训练,部分眼部样本如图 8 所示,部分嘴部样本如图 9 所示。



图 8 部分眼部样本




图 9 部分嘴部样本

为验证提出的眼部和嘴部状态方法能否达到预期的效果,使用 DC-CNN 对训练好的数据集进行测试验证,表 1 为眼睛状态测试结果,表 2 为嘴巴状态测试结果。

表 1 眼睛状态测试结果

算法	眼睛状态	测试样本数量	识别错误数量	准确率/%
DC-CNN	睁眼	2 500	88	96.48
	闭眼	1 500	65	95.67

表 2 嘴巴状态测试结果

状态	测试样本数量	识别错误数量	准确率/%
嘴巴张开	750	39	95.47
嘴巴闭合	500	24	95.18

通过实验可知,该算法对眼睛和嘴巴正确的识别率较高。将表 1 的结果与基于 Adaboost 的眼睛状态识别^[8]和基于多尺度池化卷积神经网络的眼睛状态识别^[9]作对比,结果如表 3 所示,基于可变形卷积神经网络的眼睛状态识别优于上述两种算法。

表 3 不同算法对眼睛状态识别的结果(%)

算法	睁眼识别率	闭眼识别率
DC-CNN	96.48	95.67
Adaboost	85.57	86.34
MTCNN	94.56	93.81

5.3 疲劳检测

利用可变形卷积神经网络对眼部的状态作出准确分类,通过 PERCLOS 参数对眼睛闭合状态作出统计。使用 CEW 眼部数据集 YAWDD 视频数据集来测试疲劳检测算法的性能。疲劳状态的阈值是根据 PERCLOS

超过 0.4、一分钟眨眼频率超过 20 或打哈欠频率超过 3 来判断驾驶员是否疲劳。通过判断眼部和嘴部的状态,实现疲劳的判断,通过 CEW 部分数据集根据设定的阈值进行疲劳测试,实验仿真结果如图 10 所示,为眼部正常和疲劳状态以及嘴部正常和疲劳状态的结果。

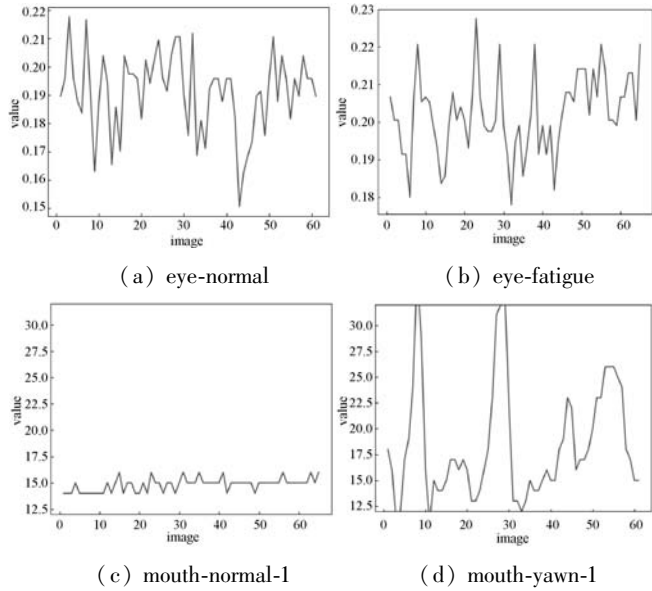


图 10 仿真结果图

为了验证文章提出的疲劳检测新方法的准确性,从实验人员自制了 6 个视频,包括非疲劳驾驶状态和疲劳驾驶状态,根据相应实验人员的状态分类器,可以判别眼部状态和嘴部状态。最后分别计算该视频中对应测试人员的 PERCLOS、眨眼频率、打哈欠频率,如果测试的指标超过设定的阈值,将确定疲劳,实验结果如表 4 所示。可以看出,10 个视频中疲劳驾驶的检测的准确率为 90%。

表 4 样本疲劳测试

视频	PERCLOS	眨眼频率	打哈欠频率	实际状态	测试状态
1	0.57	19	6	疲劳	疲劳
2	0.24	10	0	正常	正常
3	0.37	21	0	正常	疲劳
4	0.46	23	3	疲劳	疲劳
5	0.51	24	4	疲劳	疲劳
6	0.44	26	5	疲劳	疲劳
7	0.20	13	0	正常	正常
8	0.34	24	5	疲劳	疲劳
9	0.59	18	6	疲劳	疲劳
10	0.24	11	0	正常	正常

通过人脸检测和跟踪,眼部和嘴部状态的提取,眼部和嘴部状态识别工作,现实中统计多名测试人员的数

据,最终测试结果部分示意图如图 11 所示,(a)为模拟正常驾驶的图片,(b)、(c)模拟疲劳驾驶的图片,正常驾驶状态显示‘Normal’,疲劳驾驶状态显示‘Fatigue’。



图 11 模拟测试结果图

最后,实验疲劳检测系统对收集的 CEW 眼部数据集、YAWDD 打哈欠数据集进行测试,准确率达到 94.36%。该系统经过测试,达到了预期的设计目标,满足了实际应用的需求。实验结果表明,该设计的疲劳检测系统具有良好的优越性,能够准确判断驾驶员的疲劳状态。与传统的 Adaboost 的疲劳检测方法和 HOG + SVM 的疲劳检测方法相比,提出的新方法时效性和准确性都更优。与传统的 HOG + CNN 疲劳检测方法相比,新方法在人脸检测时,增加了 KCF 跟踪算法起到算法加速作用;与 MTCNN + CNN^[9]算法相比,引入了可变形卷积神经网络,增加了算法的准确性。由此可知,新方法提高了疲劳驾驶检测算法的准确性,具有较好的实时性,满足疲劳驾驶检测系统的要求,与上述四种疲劳检测方法对比结果如表 5 所示。

表 5 不同算法疲劳状态判断对比

驾驶疲劳检测算法	准确率/%	时间/s
Adaboost + SVM	89.28	0.28
HOG + SVM	91.85	0.32
MTCNN + CNN	92.35	0.54
HOG + CNN	93.60	0.44
新算法	94.36	0.35

6 结 语

通过上述实验的结果,提出的传统算法与深度学习方面相结合的疲劳检测方法取得了很好的效果。将传统算法 HOG 人脸检测器与 KCF 跟踪算法相结合,减少了人脸检测的次数,从而缩短检测消耗的时间。然后通过引入可变形卷积神经网络对提取的脸部关键部位进行状态识别,根据疲劳判断的准则,从而实现疲劳检测的判断。后期需要进一步研究结合多种疲劳特征综合检测疲劳状态,以确保算法更加可靠。

(下转第 168 页)

- [8] Ma C, Yang X K, Zhang C Y, et al. Long-term correlation tracking [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2015: 5388 – 5396.
- [9] 刘延飞, 何燕辉, 姜柯, 等. 采用异常值检测及重定位改进的 KCF 跟踪算法 [J]. 计算机工程与应用, 2018, 54 (20): 166 – 171.
- [10] 李响峰, 周东, 阮雅端, 等. 抑制船尾拖纹的船舶显著性视频检测方法 [J]. 北京邮电大学学报, 2017, 40 (S1): 72 – 76.
- [11] Wang Q, Zhang L, Bertinetto L, et al. Fast online object tracking and segmentation: A unifying approach [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2019: 1328 – 1338.
- [12] Bertinetto L, Valmadre J, Henriques J F, et al. Fully convolutional Siamese networks for object tracking [C] // European Conference on Computer Vision, 2016: 850 – 865.
- [13] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6): 1137 – 1149.
- [14] Bochkovskiy A, Wang C Y, Liao H. Yolov4: Optimal speed and accuracy of object detection [EB]. arXiv:2004. 10934, 2020.
- [15] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2009: 1956 – 1963.
- [16] Levin A, Lischinski D, Weiss Y. A closed-form solution to natural image matting [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2008, 30 (2): 228 – 242.
- [17] He K M, Sun J, Tang X O. Guided image filtering [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35 (6): 1397 – 1409.
- [18] Wu Y, Lim J, Yang M H. Online object tracking: A benchmark [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2013: 2411 – 2418.
- [19] Wu Y, Lim J, Yang M H. Object tracking benchmark [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1834 – 1848.
- [J]. Journal of Safety Research, 2008, 9 (3): 303 – 309.
- [3] Regan M A, Hallett C, Gordon C P. Driver distraction and driver inattention: Definition, relationship and taxonomy [J]. Accident Analysis and Prevention, 2011, 43 (5): 1771 – 1781.
- [4] 邹敏杰, 穆平安, 张彩艳. 基于眼睛和嘴巴状态的驾驶员疲劳检测算法 [J]. 计算机应用与软件, 2013, 30 (3): 25 – 27, 54.
- [5] 黄皓. 基于驾驶操作及车辆状态的疲劳驾驶行为检测研究 [D]. 南京: 东南大学, 2016.
- [6] 卢章平, 尹传斌, 李瑞, 等. 基于生理信号的驾驶疲劳分级检测研究 [J]. 重庆交通大学学报 (自然科学版), 2017, 36 (1): 77 – 81.
- [7] 周云鹏, 朱青, 王耀南, 等. 面部多特征融合的驾驶员疲劳检测方法 [J]. 电子测量与仪器学报, 2014, 28 (10): 1140 – 1148.
- [8] 邹昕彤, 王世刚, 赵文婷, 等. 基于眼睛与嘴部状态识别的疲劳驾驶检测 [J]. 吉林大学学报 (信息科学版), 2017, 35 (2): 204 – 211.
- [9] 顾王欢, 朱煜, 陈旭东, 等. 基于多尺度池化卷积神经网络的疲劳检测方法研究 [J]. 计算机应用研究, 2019, 36 (11): 3471 – 3475.
- [10] 李长勇, 吴金强, 房爱青. 基于多信息的疲劳状态识别方法 [J]. 激光与光电子学进展, 2018, 55 (10): 239 – 245.
- [11] 曾鸽. 基于深度学习的驾驶员疲劳状态检测研究 [D]. 长沙: 湖南大学, 2018.
- [12] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C] // IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005: 886 – 893.
- [13] 李澎林, 邹嘉程, 李伟. 基于 HOG 和特征描述子的人脸检测和跟踪 [J]. 浙江工业大学学报, 2020, 48 (2): 133 – 140.
- [14] Henriques J F, Caseiro R, Martins P, et al. High-speed tracking with kernelized correlation filters [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (3): 583 – 596.
- [15] Li Y, Zhu J K. A scale adaptive kernel correlation filter tracker with feature integration [C] // European Conference on Computer Vision, 2014: 254 – 265.
- [16] 刘梦佳, 赵建国. 基于 SVM 的疲劳驾驶人脸图像特征检测算法 [J]. 半导体光电, 2020, 41 (2): 278 – 282.
- [17] Trutschel U, Sirois B, Sommer D, et al. PERCLOS: An alertness measure of the past [C] // Driving Assessment Conference, 2017: 172 – 179.
- [18] Abtahi S, Omidyeganeh M, Shirmohammadi S, et al. YawDD: A yawning detection dataset [C] // 5th ACM Multimedia Systems Conference, 2014: 24 – 28.

(上接第 160 页)

参 考 文 献

- [1] 旷文腾, 毛宽诚, 黄家才, 等. 基于高斯眼白模型的疲劳驾驶检测 [J]. 中国图象图形学报, 2016, 21 (11): 1515 – 1522.
- [2] Vanlaar W, Simpson H, Mayhew D, et al. Fatigued and drowsy driving: A survey of attitudes, opinions and behaviors