

黄承宁, 殷晓磊, 陈武. 基于 CNN 的多类别面部特征融合疲劳检测算法研究[J]. 智能计算机与应用, 2026, 16(2): 8-14.
DOI: 10.20169/j.issn.2095-2163.24050904

基于 CNN 的多类别面部特征融合疲劳检测算法研究

黄承宁¹, 殷晓磊², 陈武³

(1 南京工业大学 浦江学院, 南京 211222; 2 南京审计大学, 南京 211815; 3 中国建筑股份有限公司, 北京 100029)

摘要: 针对交通安全中的疲劳驾驶状态识别问题, 在单一特征指标下易受影响、在复杂环境下检测及时性和准确度仍待改进的问题, 结合典型 CNN 神经网络算法, 来实现高精度和速度目标, 提出一种基于脸部多特征状态分类的 CNN 模型。先使用 AdaBoost 检测算法进行面部局部特征检测, 使用改进的 CNN 模型引入 Dropout 层以避免过拟合, 再对眼睛和嘴巴进行状态判定, 对各疲劳特征进行描述, 并对其特征参数进行提取, 而在使用基于 Haar-like 脸部特征识别的同时, 又对图像数据实现了预处理, 以应对一些复杂因素影响。最后引入带权重的特征融合, 进行疲劳判定。实验结果表明, 该方法能够在复杂环境下提高检测面部疲劳特征状态准确度, 相较传统疲劳判定方法, 检测速度与精确度均得到有效提升。

关键词: 疲劳检测; 卷积神经网络; 特征点检测; 特征融合

中图分类号: TP391.41

文献标志码: A

文章编号: 2095-2163(2026)02-0008-07

Fatigue detection algorithm based on CNN multi-category facial feature fusion

HUANG Chengning¹, YIN Xiaolei², CHEN Wu³

(1 Nanjing Tech University Pujiang Institute, Nanjing 211222, China; 2 Nanjing Audit University, Nanjing 211815, China; 3 China State Construction Corporation Limited, Beijing 100029, China)

Abstract: Aiming at the problem of fatigue driving state recognition in traffic safety, which is easily affected under a single feature index, and in a complex environment, the detection timeliness and accuracy still need improvement. Combined with the typical CNN neural network algorithm to achieve high precision and speed goals, a CNN model for face multi-feature state classification is proposed. Firstly, the AdaBoost detection algorithm for facial local feature detection is used, and the improved CNN model with the addition of a Dropout layer is used to prevent overfitting. Secondly, status assessment on the eyes and mouth is performed, each fatigue feature is described, and their characteristic parameters are to be extracted. Simultaneously, Haar-like face feature recognition is used while preprocessing the image data to cope with some complex factors. Finally, weighted feature fusion is introduced for fatigue determination. The experimental results show that this method can improve the accuracy of detecting facial fatigue feature states in complex environments. Compared with traditional fatigue detection methods, the detection speed and accuracy are effectively improved.

Key words: fatigue detection; CNN; feature point detection; multi-features fusion

0 引言

驾驶员疲劳检测是一种利用生物信号、车辆行驶数据、人的面部特征及行为特征来识别驾驶员疲劳的技术^[1], 是智能驾驶系统和车联网中的重要研究领域。长期驾驶、单调乏味的路况会引起驾驶员出现困倦、打瞌睡等症状, 从而使得发生交通事故的

风险也随之上升。所以, 如何对驾驶人进行高效的疲劳状态检测, 提高道路交通安全性, 具有重要的现实意义^[2]。

使用单一的疲劳特征检测信息来对驾驶员的疲劳状态进行识别, 具有一定的局限性, 很容易引起误检、漏检的问题, 而且其检测精度也不高。当前, 信息融合的检测方法已经逐渐成为了一个研究热点,

基金项目: 江苏省高等学校自然科学研究项目(18KJD520001); 南京工业大学浦江学院科研重点培育课题(NJPJ2022-1-07); 南京工业大学浦江学院青年教师发展基金(PJYQ03); 2023年南京工业大学浦江学院科研创新团队建设项目(NJPJ20230203)。

作者简介: 殷晓磊(1987—), 男, 硕士, 工程师, 主要研究方向: 信息管理与信息系统; 陈武(1982—), 男, 硕士, 审计师, 主要研究方向: 大数据审计, 内控审计。

通信作者: 黄承宁(1985—), 男, 博士, 副教授, 主要研究方向: 知识发现, 人工智能, 神经网络等。Email: 361949048@qq.com。

收稿日期: 2024-05-09

将多种面部疲劳特征进行融合,以对抗在复杂环境下的影响,比如天气、光照、是否佩戴墨镜等。利用CNN算法^[3]来提高检测分析的速度、从而改善检测的实时性、准确性和鲁棒性具有重大意义。在准确性方面,采用单一的疲劳特征检测信息来判别驾驶员的疲劳状态存在局限性,容易造成误检、漏检的问题,且检测准确度不足。在环境变化方面,对抗在复杂环境下的影响,比如天气、光照、是否佩戴眼镜等因素,性能不足^[4]。为了提高疲劳检测的准确率,本文采用多种特征融合的疲劳检测,将提取出的关键特征进一步细化为眨眼频率、眼睛开合大小、打哈欠次数三个疲劳参数,利用加权特征融合完成疲劳判定,最后进行实验验证。结果表明该方法优于传统方法。

1 基于CNN的多类别面部特征融合疲劳检测算法

1.1 CNN的基本结构设置

卷积层是CNN中最为关键的一层,是利用卷积运算,从输入的图像中抽取出一组卷积的图像^[5]。卷积运算就是把一个滤波器与输入图像中的每一个像素点进行加权求和,在此基础上,获得了该图像的一个像素值。该方法是将多个卷积层叠加在一起,每个卷积层都含有多个特征面。卷积运算是对上一层的图像利用卷积核和偏置,来产生当前层的特征图。CNN能够逐渐提取出输入图像的高层次特征,该过程可以表示为:

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} \times K_{ij}^l + b_j^l\right) \quad (1)$$

其中, X_j^l 表示了第 l 层第 j 个特征图的输入; K_{ij}^l 表示下一层的权重卷积核; b_j^l 表示偏置。

降采样技术可以通过多种方式实现,目前最常用的方法是平均池化和最大池化^[6]。池化层将每个卷积核的输出降采样为一个单独的值,并将其用作下一层的输入。降采样层的一般表达形式为:

$$X_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (2)$$

其中, $\text{down}(\cdot)$ 函数为抽样函数; β_j^l , b_j^l 表示对输出特征的偏置; $f(\cdot)$ 表示激活函数(降采样层激活函数)。

激活函数可以用来建立神经网络的输出和输入的非线性关系^[7]。神经网络中的每一个神经元都含有一个对输入信号进行处理和输出的激励函数。

为了克服梯度消失的问题,这里采用 ReLU 激活函数,定义为:

$$\text{ReLU}(x) = \max(0, x) \quad (3)$$

该函数可以在处理大量数据时显著提高训练速度,被广泛应用于深度神经网络中。

Dropout 层是一种常用于深度神经网络中的正则化方法,其作用是通过在训练过程中随机丢弃一部分神经元,以避免过拟合^[8]。Dropout 层原理示意图如图 1 所示。具体来说,Dropout 层会在每一次前向传播时,以一定的概率 p (通常为 0.2 ~ 0.5) 随机将一部分神经元的输出设置为 0,从而将其“丢弃”。如此避免出现一些特殊的神经元对于特定的输入数据过于敏感的情况。这一过程可用如下公式来进行描述:

$$r_j^{(l)} \sim f(p) \quad (4)$$

$$\tilde{y}^{(l)} = r^{(l)} \times y^{(l)} \quad (5)$$

其中, $f(\cdot)$ 函数可以生成概率向量,即 0 或 1。




图 1 Dropout 层原理示意图

Fig. 1 Schematic diagram of Dropout layer principle

在测试阶段,Dropout 层不会进行随机丢弃,而是保留所有的神经元,并将其输出值乘以训练阶段的丢弃概率,以保持输出的期望值不变。这样一来,就可以使模型在测试阶段获得更加稳定的预测结果。

全连接层又叫做全连接神经层,功能是将上一层的所有神经元和下一层的所有神经元全部连接起来。每一个神经元输出的计算公式为:

$$h_{w,b}(x) = f(\mathbf{w}^T \mathbf{x} + b) \quad (6)$$

其中, \mathbf{x} 表示神经元输入; $h_{w,b}(x)$ 表示输出; \mathbf{w} 表示连接权重矩阵; b 表示偏置函数; $f(\cdot)$ 表示激活函数。

全连接层通常用于最后一层,将其转换为一个向量,再通过一个或多个全连接层对其进行处理。

1.2 疲劳参数设置

对于疲劳程度的衡量标准,是在特定的某个时间间隔内,对驾驶员的状态进行分析,从而对其疲劳程度做出判断。而以视觉特征为基础的检测方法,主要是通过检测面部相关特征,比如眼睛、嘴巴、头部姿态等。本文将通过使用眼部疲劳状态和嘴巴疲劳状态的提取特征作为疲劳驾驶的判定标准。

1.2.1 眼部疲劳特征

人眼的主要动作就是眨眼睛,眨眼睛是人类必不可少的动作之一。眨眼的时间非常短,在这个短暂的时间内,人眼可以得到充分的休息,还可以清理眼睛内的灰尘,在眨眼的同时,可以避免一些微小颗粒对眼球的伤害,而且人眼的眨眼状态与人当前是否疲劳有着密切的关系。当人处于疲劳状态时,人的眨眼次数会减少,且人眼闭合的时间会随之变长。

1.2.2 PERCLOS 参数

PERCLOS(PERcent of eye CLOSure over time)是一种描述眼睛闭合程度的疲劳参数^[9-10]。在驾驶员疲劳检测中,PERCLOS 被广泛应用于评估驾驶员的疲劳程度。

首先,通过计算驾驶员双眼的纵向和横向坐标,确定驾驶员的视线方向;然后,又使用一个阈值来确定什么程度的眼睛闭合被视为疲劳。通常状况下,人类感到疲劳时,眼睛的闭合时间在单位时间内比率会明显升高,也就是说从眼睛睁开、到闭合、再到睁开这一段时间变长来看,那么驾驶员的疲劳程度在一定情况下可以凭借眼睛的闭合时间来判断。

20世纪70年代,Wierwille 等学者对眼睛的光学参数与疲劳之间的关系进行了研究^[11],发现疲劳与睡眠不足、眼球的快速旋转、瞳孔的直径、注意力的集中方向、以及眼睛的眨动等多种因素有关。在驾驶模拟器上展开了模拟实验,对眼睛闭合所持续的时间与事故发生前后的关系进行了统计,如图2所示。




图2 眼睛闭合时间与事故发生前后时间关系图

Fig. 2 Graph of the relationship between eye closure time and the time before and after an accident

观察图2中事故发生前后的眼睛闭合时间变化,可以发现闭眼时间的测量可用于准确评估驾驶员的疲劳状态,因为在事故发生前,闭上眼睛的时间明显要高于事故发生之后。

在具体的测试中通常有3个测量标准:P70、P80、EM。

(1)P70^[12]:通过基于 PERCLOS 曲线的百分位

数来确定疲劳程度。这意味着在 PERCLOS 曲线上,70%的观察值高于 PERCLOS 阈值。通过统计眼睛闭合时间占测量时间的百分比作为判断疲劳程度的标准。

(2)P80^[13]:P80 是类似于 P70 的方法,但是使用的是 PERCLOS 曲线上的 80%百分位数来确定疲劳的程度。原理如图3所示。

(3)EM^[14]:基于 PERCLOS 曲线上的指数移动平均值(Exponential Moving Average)来确定疲劳的程度。这种方法利用过去一段时间内的 PERCLOS 值来计算移动平均值,并根据移动平均值是否超过某个阈值来判定疲劳状态。




图3 PERCLOS 值的测量原理图

Fig. 3 Schematic diagram of the PERCLOS value measurement principle

通过计算 $t_1 \sim t_4$ 的值就可以计算 PERCLOS 的值。在此基础上可以推得:

$$f = \frac{t_3 - t_2}{t_4 - t_1} \times 100\% \quad (7)$$

式(7)限定在一次眨眼过程中,常常会以预设的检测周期为单位时间来判断人是否疲劳,这就是需要统计该时间段内闭眼情况,用到的公式为:

$$f_1 = \frac{\sum_{i=1}^n t_i}{T} \quad (8)$$

其中, $\sum_{i=1}^n t_i$ 表示时间 T 内眼睛睁开度小于 20% 的时间之和。

眼睛长宽比(Eye Aspect Ratio, EAR)是一种常用的判定眼部疲劳的指标^[15]。具体地,EAR 是通过计算眼睛区域内特定的特征点之间的距离比值值得出的。一般来说,当眼睛疲劳或闭眼时,EAR 值会降低。眼部特征如图4所示,从人眼的左上角开始,围绕眼眶顺时针标记6个坐标,依次为 P_1 、 P_2 、 P_3 、 P_4 、 P_5 、 P_6 , EAR_{left} 的定义公式为:

$$EAR_{left} = \frac{\|P_2 - P_6\| + \|P_3 - P_5\|}{2 \|P_1 - P_4\|} \quad (9)$$

EAR_{right} 的定义公式同式(9)。在此基础上,推

得的 EAR 的定义公式具体如下:

$$EAR = \text{Mean}(EAR_{\text{left}}, EAR_{\text{right}}) \quad (10)$$



图 4 眼部特征图

Fig. 4 Map of the eye feature

在本文视频图像数据集中,对连续 200 帧左右眼的纵横比进行计算,眨眼时 EAR 值会迅速降低至接近于 0,然后慢慢恢复至睁眼时正常的 EAR 值。这种变化趋势可以通过图 5 来呈现。




图 5 EAR 指数采集图

Fig. 5 Chart of EAR index collection

根据 EAR 值的计算结果可知,眨眼时 EAR 值会先逐渐降低、直至接近于 0,然后再逐渐恢复至正常睁眼状态值。借鉴 PERCLOS 算法的思想,可以通过一个阈值来判断眼睛是否闭合。为了避免误差,本文采用动态阈值设定的方式,先采集驾驶员在疲劳状态下的眼部 EAR 数据,取其平均值,根据 PERCLOS 的 P80 标准得到自适应阈值,使用 EAR 阈值对自适应阈值进行修正,最后将二者算数平方值作为最终阈值,用 EAR_P80 表示。PERCLOS P80 标准就等效为如下公式:

$$EAR \leq EAR_P80 \quad (11)$$

EAR 值满足式(11),则表明驾驶员处于疲劳状态;此时计算这段时间在单位时间占比即可得出 PERCLOS 值。

1.2.3 BlinkFreq 参数

BlinkFreq 是指眨眼频率,也是一种常用的判定眼部疲劳的指标。具体地说,BlinkFreq 是通过计算一定时间内(通常为 1 min)眨眼的次数得出的^[16]。

通过研究可知,正常人每分钟眨眼的次数大约在 10~30 次之间。当 BlinkFreq 低于 10 次时,说明眼睛已经处于疲劳状态。

确认发生眨眼的连续帧数,以帧数为横坐标,

EAR 为纵坐标可绘出疲劳状态下一段时间内的驾驶员状态变化波形(参见图 5),统计波形突变次数得到眨眼次数 BF,并得出该疲劳参数的判断阈值为:

$$f_{BF} = \begin{cases} 0, & 10 \leq BF < 30 \\ 1, & BF < 10 \parallel BF \geq 30 \end{cases} \quad (12)$$

1.2.4 嘴部疲劳特征

除了对眼睛进行检测之外,当人在疲劳的时候,经常会出现打哈欠的情况。在正常的开车过程中,嘴巴是紧闭的,但是在说话的时候,嘴巴是正常状态下张开的。在打哈欠的时候,嘴巴会张得很大,并且会保持一定的时间。

1.2.5 嘴巴开合度

打哈欠时候嘴巴张开程度明显变大,其计算公式如下:

$$O_i = \frac{H_i}{W_i} \quad (13)$$

其中, H_i 表示嘴巴张开高度, W_i 表示嘴巴宽度。

嘴巴张开持续时间统计公式如下:

$$T_0 = nt \quad (14)$$

其中, n 表示嘴巴张开的帧数, t 表示每帧张开的时间。

1.2.6 打哈欠频率

本文基于嘴部动作的驾驶员疲劳检测方法是先检测嘴巴区域,根据嘴巴开合程度判断是否在打哈欠,通常使用嘴部纵横比 MAR 来衡量嘴巴开闭程度,嘴部特征点 $M_1 \sim M_6$,如图 6 所示。



图 6 嘴部特征图

Fig. 6 Map of mouth feature

研究推得的打哈欠频率公式为:

$$F = \frac{W}{T} \quad (15)$$

其中, W 表示打哈欠的次数, T 表示单位时间。嘴部纵横比公式为:

$$MAR = \frac{\|M_2 - M_6\| + \|M_3 - M_5\|}{2 \|M_1 - M_4\|} \quad (16)$$

原理同上面眼部 EAR 相似,这里不再解释。根据本文视频图像数据集的实验结果如图 7 所示。

根据 MAR 的值来识别嘴部状态, MAR 值小于等于 0.4 时嘴巴处于闭合状态; MAR 值在 0.4~0.8

之间时,嘴巴处于正常讲话状态;MAR 值大于 0.8 时则处于打哈欠状态。




图7 MAR 指数采集图

Fig. 7 Chart of MAR index collection

1.3 多特征融合加权的疲劳状态检测

疲劳特征汇总见表1。本文提出了基于多特征融合加权的疲劳等级识别方法,将眼部、嘴部的3个疲劳特征指标各自取权重值,经实验可得其权重取值见表2。

表1 疲劳特征汇总表

Table 1 Summary table of fatigue characteristics

局部位置	特征	说明	信息来源
眼睛	眼睛闭合度	EAR	图像信息
	眨眼频率	BF	图像信息
嘴巴	嘴巴张开度	MAR	图像信息
	打哈欠频率	YF	图像信息

表2 疲劳参数权重取值表

Table 2 Table of fatigue parameter weight value

特征参数	眼睛		嘴巴
	EAR	BF	YF
权重 W_i	0.3	0.3	0.4

根据最后疲劳判定结果的不同,将状态分为3个等级:清醒、疲劳、重度疲劳。研究推得特征参数加权和计算公式为:

$$F = \sum V_i \times W_i, \quad i = (\text{EAR}, \text{BF}, \text{YF}) \quad (17)$$

根据最后加权值 F 将状态分为3个等级,见表3。

表3 疲劳程度划分表

Table 3 Fatigue level classification table

疲劳等级	清醒	疲劳	
	不疲劳	疲劳	重度疲劳
特征参数加权值 (F)	$F < 0.3$	$0.3 \leq F < 0.7$	$F \geq 0.7$

2 实验仿真

2.1 数据集准备

采集10位测试人员的人脸视频,包括、不限于佩戴墨镜、眼镜、以及无眼镜三种情况,配合多种光

照条件下的视频图像设置为第1组数据集 DATA1;网络爬取实际驾驶视频的图像视频作为第2组数据集 DATA2;选取10 000张图片进行训练,其中睁眼、闭眼、张嘴和闭嘴的图片数量分别为3 500、2 500、2 000和2 000张。在训练之前,对所有样本进行灰度化处理,并将其尺寸调整为36×28。面部特征图采样如图8所示。



图8 面部特征图采样

Fig. 8 Facial feature map sampling

2.2 网络结构选取

为了得到不同卷积核心对特征提取时候所产生的影响,以及采取 Dropout 层对网络复杂度的影响,将选取不同的卷积核组成网络 CNN1、CNN2、CNN3、以及没有 Dropout 层的 CNN4,详见表4。表4中,C类表示卷积层,S类表示 Dropout 层。

表4 CNN 网络结构表

Table 4 CNN network architecture table

网络	C1	S1	C2	S2
CNN1	3×3	2×2	3×3	2×2
CNN2	5×5	2×2	5×5	2×2
CNN3	9×9	2×2	9×9	2×2
CNN4	5×5	-	5×5	-

2.3 数据预处理

在图像预处理中,本文选用的 MinMax 归一化可以将图像的像素值缩放到[0,1]的范围内,以减少光照变化的结果。同时通过数据增强,生成更多的训练数据,从而提高模型的性能和精度。

2.4 加权融合处理

为了验证本文所提出的加权融合判断方法的性能,每组数据包含清醒、疲劳和重度疲劳状态,在测试数据中包含4种测试场景,每组数据为10个检测周期,每个周期间隔15 s。

2.5 实验结果分析

(1)在实验中,每个网络结构所选取的在卷积核的大小有差异的情况下,所提取的图像特征信息存在差异,同时也会对特征的分类结果造成一定的影响,所以要对比实验识别率,以选取合适的卷积核。

(2)实验中应包含增加 Dropout 层的实验组,以

观察引入 Dropout 层后 CNN 网络的泛化能力是否有所增长。网络识别率如图 9 所示。测试结果见表 5、表 6。




图 9 网络识别率

Fig. 9 Network recognition rate

表 5 眼睛状态测试结果

Table 5 Eye condition test results

数据库	眼睛状态	测试样本数量	准确率/%
DATA1(无眼镜)	睁开	2 597	99.75
	闭合	987	99.68
DATA1(有眼镜)	睁开	2 697	98.87
	闭合	896	95.77
DATA2(无眼镜)	睁开	4 756	99.67
	闭合	2 434	99.46
DATA2(有眼镜)	睁开	3 257	97.77
	闭合	1 352	97.96

表 6 嘴巴状态测试结果集

Table 6 Oral condition test results set

状态	测试样本数量/张	准确率/%
嘴巴张开	527	98.95
嘴巴闭合	497	99.07

实验结果表明,选取 CNN2 网络模型对眼睛和嘴巴状态的识别率在不同环境下的表现都比较好。在 DATA1 数据集无眼镜的测试中,对测试样本中眼睛睁开的识别准确率可达 99.75%,对眼睛闭合的识别率也高达 99.68%。在嘴巴状态的测试结果中,对嘴巴张开检测准确率高达 98.95%,对嘴巴闭合检测准确率为 99.07%。

将测试结果的平均值网络结构的识别率与基于多特征融合的 Multi-feature fusion 的眼睛状态识别方法和基于颜色相关的 AdaBoost 眼睛状态识别方法进行对比,结果见表 7。

表 7 实验结果对比表

Table 7 Comparison table of experimental results %

方法	睁眼睛识别率	闭眼识别率	平均识别率
CNN2	99.12	98.73	98.93
Multi-feature fusion	96.76	84.44	91.90
Color Adaboost	-	-	98.39

实验结果显示,本文所选用的改进 CNN2 网络结构,对睁眼和闭眼平均识别率可达 98.93%,相较于基于多特征融合的 Multi-feature fusion 的眼睛状态识别方法,识别率提高了 7.03%,相较于单一的 AdaBoost 算法识别率提高 0.54%。

不同场景下疲劳的识别结果见表 8。由表 8 可以看出本小节所使用的加权融合方法在白天识别准确率要高于夜晚。在白天情景下,无论是否佩戴眼镜,在文本数据集上识别率都可以高达 100%。夜间识别效果有所下降,夜间戴眼镜的状态下识别率仅为 90%,在无眼镜状态下识别率可达 95%,总体识别效果较好。

表 8 不同场景下疲劳的识别结果

Table 8 Recognition results of fatigue under different scenarios

场景	真实状态	清醒次数	疲劳次数	重度疲劳次数	检测准确率/%
白天,戴眼镜	清醒	10	0	0	100.0
	疲劳	0	10	0	100.0
	重度疲劳	0	0	10	100.0
白天,不戴眼镜	清醒	10	0	0	100.0
	疲劳	0	10	0	100.0
	重度疲劳	0	0	10	100.0
晚上,戴眼镜	清醒	10	0	0	90.0
	疲劳	0	10	0	90.0
	重度疲劳	0	3	7	90.0
晚上,不戴眼镜	清醒	10	0	0	96.7
	疲劳	0	10	0	96.7
	重度疲劳	0	1	9	96.7

3 结束语

本文提出了一种基于特征点的驾驶员面部识别方法。利用 CNN 实现了眼睛特征与口形的识别,并在原来的原始识别结构上做出改进,引入 Dropout 层,保留精度的同时大幅度提升检测效率,使用的改进 CNN 模型层次结构结合实验选出较优神经网络结构 CNN2。根据统一实验测试结果显示,本文所选用的改进 CNN2 网络结构,对睁眼和闭眼平均识别率可达 98.93%,相对传统识别方案,精确度提升 0.54%。最后采用一种融合三类疲劳参数指标加权的疲劳识别方法,相对于传统的单个疲劳指标的识别方法,其识别精度和识别速度都有较大提高。

参考文献

[1] 胡峰松,程哲坤,徐青云,等. 基于多特征融合的疲劳驾驶状

- 态识别方法研究[J]. 湖南大学学报(自然科学版), 2022, 49(4):100-107.
- [2] LIANG M A. Fatigue driving detection algorithm based on support vector machine [J]. Review of Computer Engineering Studies, 2019, 64:87-92.
- [3] DUA M, SHAKSH I, SINGLA R, et al. Deep CNN models-based ensemble approach to driver drowsiness detection [J]. Neural Computing & Applications, 2021, 33(8):3155-3168.
- [4] DOUDOU M, BOUABDALLAH A, BERGE-CHERFAOUI V. Driver drowsiness measurement technologies; current research, market solutions, and challenges [J]. International Journal of Intelligent Transportation Systems Research, 2020, 18(2):297-319.
- [5] ABDULLAH M H, RAMAN K J, AZMAN A, et al. Driver fatigue detection [M]//KIM K, JOUKOV N. Information Science and Application (ICISA). Lecture Notes in Electrical Engineering. Cham: Springer, 2016, 376:269-278.
- [6] HUANG Jieyuan, CEN Yigang, ZHANG Linna, et al. Eye state detection based on convolutional neural network [J]. Journal of Yangzhou University (Natural Science Edition), 2018, 21(3):25-29.
- [7] 李慧楠. 基于人脸识别的船舶驾驶员疲劳检测系统的研究[D]. 北海:桂林电子科技大学, 2022.
- [8] 张威特, 李俊松, 刘雁飞. 基于随机森林和BP神经网络的船舶驾驶员疲劳检测算法 [J]. 智能计算机与应用, 2024, 14(2):140-143.
- [9] 靳明浩. 基于人脸识别的驾驶人员疲劳检测系统设计 [J]. 智能计算机与应用, 2020, 10(2):172-173.
- [10] 王康, 樊继东. 基于多特征融合的疲劳驾驶检测 [J]. 湖北汽车工业学院学报, 2023, 37(1):39-44.
- [11] 张博, 李鸿, 李会超. 基于多类别特征融合的疲劳检测系统研究 [J]. 现代电子技术, 2019, 42(1):152-156.
- [12] 王彦博, 张剑书, 孙新元. 基于机器视觉的疲劳驾驶检测算法研究 [J]. 智能计算机与应用, 2023, 13(6):130-132.
- [13] 许小鹏, 黄巧亮. 基于人眼状态信息的疲劳检测方法研究 [J]. 计算机与数字工程, 2022, 50(9):2048-2052.
- [14] 陆荣秀, 张笔豪, 莫振龙. 基于脸部特征和头部姿态的疲劳检测方法 [J]. 系统仿真学报, 2022, 34(10):2279-2292.
- [15] 胡习之, 黄冰瑜. 基于面部特征分析的疲劳驾驶检测方法 [J]. 科学技术与工程, 2021, 21(4):1629-1636.
- [16] 任俊, 魏霞, 黄德启, 等. 基于眼睛状态多特征融合的疲劳驾驶检测 [J]. 计算机工程与设计, 2022, 43(11):3187-3194.