

DOI:10.19651/j.cnki.emt.2211524

基于优化概率神经网络的驾驶员疲劳检测^{*}

王晗 邱联奎

(河南科技大学信息工程学院 洛阳 471023)

摘要:针对驾驶员面部疲劳检测问题,提出了一种基于遗传算法优化概率神经网络(PNN)的驾驶员疲劳检测算法。采用基于HOG特征的人脸检测器检测脸部,使用ERT算法进行关键点定位,计算PERCLOS值、眨眼频率、单位时间内打哈欠的时间占比、点头频率4个疲劳特征参数,将其输入到PNN中进行疲劳判别,并使用遗传算法优化PNN的平滑因子,提高疲劳分类准确率。使用NHTU-DDD数据集和YawDD数据集训练网络,使用自采集样本验证模型泛化性能,实验中与SVM、BP神经网络以及未优化的PNN模型对比,SVM、BP神经网络以及未优化的PNN的准确率分别为95.67%,97.67%,95.33%,所提的优化的PNN模型准确率为98.67%,验证了算法的有效性。

关键词:疲劳检测;面部特征;遗传算法;概率神经网络

中国分类号:TP391 文献标识码:A 国家标准学科分类代码:510.4050

Driver fatigue detection based on optimized probabilistic neural network

Wang Han Qiu Liankui

(School of Information Engineering, Henan University of Science and Technology, Luoyang 471023, China)

Abstract: Aiming at the problem of driver facial fatigue detection, a driver fatigue detection algorithm based on genetic algorithm optimized probabilistic neural network (PNN) was proposed. The face detector based on HOG feature is used to detect the face, and ERT algorithm is used to locate the key points. The four fatigue characteristic parameters including PERCLOS value, blink frequency, the proportion of yawning time per unit time and the frequency of nodding were calculated and input into PNN for fatigue discrimination, and the genetic algorithm was used to optimize the smoothing factor of PNN. Improve the accuracy of fatigue classification. NHTU-DDD dataset and YawDD dataset were used to train the network, and self-collected samples were used to verify the generalization performance of the model. Compared with SVM, BP neural network and unoptimized PNN model, the accuracy rates of SVM, BP neural network and unoptimized PNN were 95.67%, 97.67% and 95.33%, respectively. The accuracy of the proposed optimized PNN model is 98.67%, which verifies the effectiveness of the proposed algorithm.

Keywords: fatigue detection; facial features; genetic algorithm; probabilistic neural network

0 引言

驾驶疲劳是驾驶员在较长时间的驾驶过程中,随着身体和心理的机能消耗,表现出警觉性降低、注意力下降、反应迟钝等现象,致使驾驶员在紧急情况下不能有效及时控制车辆,进而导致道路交通事故的发生,不仅造成巨大的社会经济损失,还严重威胁到驾驶员的生命安全^[1]。因此,对驾驶员进行疲劳检测,及时给予驾驶员适当提醒尤为重要。

目前,疲劳检测方法使用的特征主要来源于以下3种:驾驶员的生理信号^[2-3]、车辆行驶数据^[4-5]、驾驶员的面部特征^[6-8],其中,基于驾驶员面部特征的疲劳检测方法具有非

接触性、成本低、实时性好等优点,是目前主流的疲劳检测研究方向。

根据人的先验知识而言,驾驶员进入疲劳状态时,经常伴随着眼睛闭合、频繁打哈欠以及歪头等现象。由此可以眼部、嘴部、头部姿态特征来进行驾驶员的疲劳判别。冯晓锋等^[9]通过使用背景差分法对多任务卷积神经网络(multi-task convolutional neural network, MTCNN)人脸检测算法优化,通过提取眼睛和嘴巴的疲劳参数,将其输入支持向量机(support vector machine, SVM)中进行疲劳状态判别,没有考虑头部姿态变化对疲劳的影响;陈小强等^[10]通过提取驾驶员眼睛和嘴巴的开合度以及眼动速率这3个参数,使

收稿日期:2022-09-26

*基金项目:国家自然科学基金(U1504617)项目资助

用模糊推理系统将这些参数进行融合,最终实现驾驶员疲劳状态判别,缺点是仅依靠单帧眼睛和嘴巴的开合度来判别疲劳,没有考虑疲劳时眼睛嘴巴状态的时序性变化的影响;胡峰松等^[11]通过提取眼睛、嘴巴以及头部姿态的特征参数,使用特征加权方式进行特征融合,实现驾驶员的疲劳判别,但由于特征权值的选择是固定的,使得该算法的普适性较差。

基于上述研究的不足,本文通过提取眼睛、嘴巴和头部姿态特征,提出一种基于遗传算法优化概率神经网络的疲劳检测方法,该算法具有模型简单、容错性强、实时性好等优势。本文主要工作如下:1)为了较充分的利用驾驶员的面部特征进行疲劳评估,通过提取眼部、嘴部以及头部特征的多个指标来判断驾驶员的疲劳状态。2)在疲劳判别阶段,以多个特征指标作为输入,使用概率神经网络进行疲劳分类,并使用遗传算法寻找概率神经网络的最优平滑因子,提高疲劳分类准确率。

1 脸部检测及关键点定位

1.1 脸部检测

脸部检测采用的是基于方向梯度直方图(histogram of oriented gradient, HOG)与 SVM 分类的人脸检测器, HOG 特征是用来描述图像中的局部纹理特征,其对图像的几何变换和光线变化具有良好的鲁棒性^[12]。对于 HOG 特征的提取首先通过将图像分块,然后计算各个图像块的方向梯度直方图,最后将其汇总得到的,其算法的本质是统计图像中的梯度信息,而梯度信息主要存在于图像中的边缘区域,图像中的局部目标能被梯度的方向密度分布来描述。在提取 HOG 特征后,使用 SVM 算法对其进行分类,实现脸部检测。脸部检测流程如图 1 所示。



图 1 脸部检测流程

1.2 关键点定位

疲劳时的面部表情主要是眼睛、嘴巴等特征区域体现出来的,因此,在检测的人脸区域中,通过关键点检测算法定位脸部五官及轮廓的特征点位置,根据特征点坐标即可计算眼睛、嘴巴、头部的疲劳参数,脸部关键点定位采用的是级联回归树(ensemble of regression trees, ERT)算法^[13],其通过建立一个级联的残差回归树 GBDT(gradient boosting decision tree),通过数次迭代,使人脸形状从当前的形状一步一步回归到真实形状,在每一个树的节点中都存储着一个残差回归值,当输入落在某一个节点上时,就将其残差值加入到其输入中,起到回归的目的,最后将所有的残差叠加在一起,就可以实现人脸对齐,迭代过程中的关键点坐标更新公式为:

$$\hat{S}(t+1) = \hat{S}(t) + \gamma_t(I, \hat{S}^{(t)}) \quad (1)$$

其中, $\hat{S}(t)$ 表示第 t 级回归器存储的脸部所有的关键点向量, γ_t 表示当前级的回归器,其输入为训练的图像与上一级回归器的关键点向量,输出则为当前级回归器的关键点位置更新量。脸部检测及脸部关键点定位效果如图 2 所示。

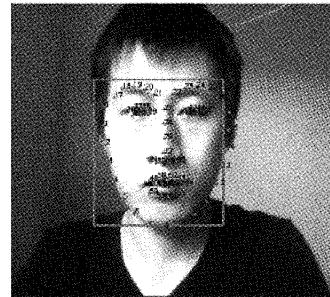


图 2 脸部检测与关键点定位效果

2 疲劳状态指标

2.1 眼部状态参数

眼睛的状态是衡量驾驶员是否处于疲劳的一个重要指标,驾驶员在长时间的车辆驾驶过程中,身体机能逐渐消耗,会出现眼睛睁开程度减小甚至趋近于眼睛完全闭合的疲劳状态。通常以眼睛纵横比(eye aspect ratio, EAR)来表征眼睛的状态,眼睛纵横比即眼睛睁开的宽度与长度的比值,当眼睛处于睁开状态时,EAR 值较大,当眼睛闭合时,眼睛长度基本不会发生变化,宽度变小,此时,EAR 值迅速减小。

在脸部的 68 个关键点中,左右眼睛区域的编号分别为 36~41,42~47。通过眼睛的关键点坐标计算眼睛的开合度 EAR,以左眼为例,右眼与其同理,眼睛关键点定位示意图如图 3 所示,其计算公式为:

$$EAR_{left} = \frac{P_{37} - P_{41} + P_{38} - P_{40}}{2P_{39} - P_{39}} \quad (2)$$

式中: $P_{36} \sim P_{41}$ 为左眼周围的特征点坐标。

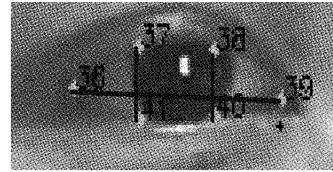


图 3 左眼关键点示意图

为了减小参数误差,实际中,通常取左右眼睛的 EAR 均值来计算眼睛睁开程度值,公式为:

$$EAR = \frac{1}{2}(EAR_{left} + EAR_{right}) \quad (3)$$

1) 眨眼频率

人在正常状态下,每分钟的眨眼次数在 10~25 次不等,每次眨眼所需的时间在 0.2~0.4 s 之间,而当人疲劳时,会出现频繁眨眼或眨眼减缓的现象,此时的眨眼频率较

清醒状态下有较明显的改变,本文根据 EAR 值的大小,通过设定阈值来判别眼睛的状态,通过在 ZJU 眨眼数据集^[14]上进行实验,最终将其阈值设置为 0.23,当 EAR 值小于 0.23 时,认为驾驶员处于闭眼状态,反之为睁眼状态,在计算眨眼频率时,为了能够有效的检测到短暂的眨眼状态,规定当眼睛处于闭合状态超过连续 3 帧及以上时,记作一次眨眼,本文以 20 s 为一周期统计眨眼次数,计算出眨眼频率,计算如下:

$$f_{eye} = \frac{n}{T} \quad (4)$$

式中: n 表示一个周期的眨眼次数, T 表示一个周期的总时间。

2) PERCLOS 值

PERCLOS(percentage of eyelid closure)准则是由卡内基梅隆研究所提出的^[15],是用来度量驾驶员疲劳状态最可靠、最有效的指标,其定义在单位时间内,眼睛处于闭合状态的时间占总时间的百分比。同样的,以 20 s 为一周期进行计算 PERCLOS 值,具体计算如下:

$$PERCLOS = \frac{N}{M} \times 100\% \quad (5)$$

式中: N 表示一个周期内眼睛处于闭合状态的视频帧数, M 表示一个周期内的视频总帧数。PERCLOS 值越大,意味着驾驶员疲劳程度越严重。

2.2 嘴部状态参数

打哈欠也是能够有效判断驾驶员疲劳状态的指标之一,疲劳时驾驶员经常会出现频繁的打哈欠行为,对比于正常状态的嘴部变化,打哈欠时,嘴部张开的幅度较大,由此可以通过计算嘴部纵横比(mouth aspect ratio, MAR)来表征驾驶员的嘴部状态,在关键点编号中,嘴部区域的特征点编号为 48~67,其中编号为 48~59 为嘴唇外轮廓索引,编号为 60~67 的为嘴部内轮廓索引,本文使用嘴巴内轮廓索引来计算嘴部开合度参数 MAR 值,嘴巴开合度计算示意图如图 4 所示,其计算公式为:

$$MAR = \frac{P_{61} - P_{67} + P_{63} - P_{65}}{2P_{60} - P_{64}} \quad (6)$$

式中: $P_{60} \sim P_{67}$ 为嘴巴内轮廓的特征点坐标。

本文根据 MAR 值的大小,通过设置阈值来区分嘴部是否处于打哈欠状态,在 YawDD 打哈欠数据集^[16]上进行实验,当嘴部闭合时,MAR 值的变化范围在(0, 0.15)之间,说话或者唱歌时,MAR 值的变化范围在(0.15, 0.4)之间,打哈欠时,MAR 值大于 0.4,因此将阈值设置为 0.4,当 MAR 值大于 0.4 时,就认为驾驶员此时处在打哈欠状态。

单位时间内打哈欠时间占比

打哈欠状态最显著的特征是嘴部张开程度大,持续时间长,由此根据 PERCLOS 值的计算方式来计算嘴部特征的疲劳指标,以 20 s 为一周期计算嘴巴处于打哈欠状态的时间占总时间的百分比,具体计算如下:

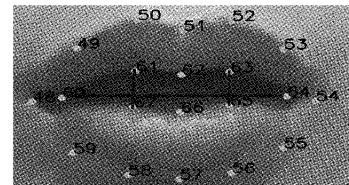


图 4 嘴巴关键点示意图

$$PERCLOS_{mouth} = \frac{X}{Y} \times 100\% \quad (7)$$

式中: X 表示一个周期内嘴巴处于打哈欠状态的视频帧数, Y 表示一个周期的视频总帧数。同样的,PERCLOS_{mouth} 值越大,表明驾驶员的疲劳程度越严重。

2.3 头部状态参数

随着疲劳程度的加深,驾驶员会出现频率点头的现象,当出现点头现象时,头部的运动幅度大,因此头部状态也是可以反映驾驶员的疲劳状态的一个指标。本文基于驾驶员在抬头或点头时,面部特征点在成像平面上的几何关系^[17]来计算头部姿态参数,平视、点头(低头状态)、抬头时面部特征点在成像平面上的位置关系如图 5 所示。 P_1P_3 、 P_1P_4 、 P_1P_2 分别为平视、点头、抬头状态下,鼻尖到眼睛的像素投影距离, P_3P_6 、 P_4P_5 、 P_2P_5 分别为平视、点头、抬头状态下,鼻尖到嘴巴的像素投影距离。当点头或抬头时, P_1P_6 的距离减小至 P_1P_5 ,对于点头状态下, P_1P_3 的距离会增大至 P_1P_4 ,抬头状态下, P_1P_3 的距离会减小至 P_1P_2 ,本文依据 P_1P_3/P_1P_6 的比值变化来判断头部姿态。计算如下:

计算双眼所在的直线方程 l_1 :

$$l_1: Ax + By + C = 0 \quad (8)$$

计算鼻尖特征点到双眼所在直线的距离 d :

$$d = \frac{|Ax_0 + By_0 + C|}{\sqrt{A^2 + B^2}} \quad (9)$$

同理,计算嘴巴所在的直线方程 l_2 :

$$l_2: A_1x + B_1y + C_1 = 0 \quad (10)$$

计算鼻尖特征点到嘴巴所在直线的距离 l :

$$l = \frac{|A_1x_0 + B_1y_0 + C_1|}{\sqrt{A_1^2 + B_1^2}} \quad (11)$$

计算头部姿态的参数 H :

$$H = \frac{d}{d + l} \quad (12)$$

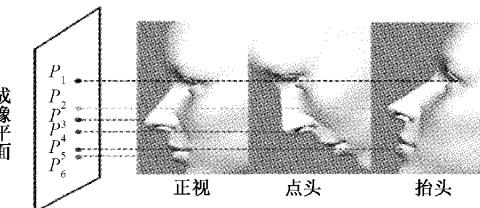


图 5 头部姿态的特征点成像示意图

点头频率

本文使用相邻帧的头部姿态参数的差值 $\Delta H = H_{t+1} - H_t$ 来判断是否发生了点头动作, 当 ΔH 值小于 0 时, 驾驶员在做抬头动作; 当 ΔH 值大于 0 时, 驾驶员在做点头动作, 当检测到连续 3 帧及以上的 ΔH 大于 0 时, 就记作一次点头, 以 20 s 为一周期计算点头频率, 计算如下:

$$f_{head} = \frac{m}{T} \quad (13)$$

式中: m 表示一个周期内点头的次数, T 表示一个周期的总时间。

3 基于优化概率神经网络的疲劳状态判别

3.1 概率神经网络

概率神经网络(probabilistic neural networks, PNN)属于有监督学习的前馈型网络的一种, 常被用在模式分类任务中, 它是将密度函数估计与贝叶斯决策理论, 融入在径向基函数(RBF)神经网络中发展而来的一种网络结构^[18], 模型结构简单、收敛速度快、容错性好, 并且当类别数增加时, 不需要重新训练网络。概率神经网络结构如图 6 所示。

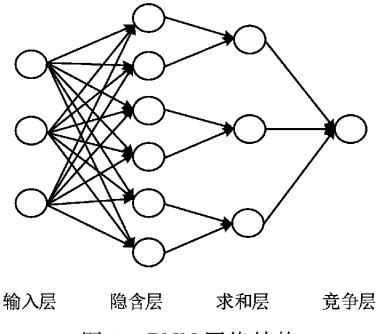


图 6 PNN 网络结构

网络共分 4 层, 分别为输入层、隐含层、求和层、输出层。

输入层的输入是相关疲劳参数组成的向量, 其神经元个数与每个样本中的疲劳特征参数的个数相等, 输入层不对数据进行任何操作。

隐含层又称为径向基层, 这一层的每一个神经元都拥有一个中心, 通过计算由输入层传入的样本向量与中心的欧式距离, 然后使用高斯函数进行激活, 最终返回一个标量值, 该层的神经元个数与训练样本个数相等, 对于向量 x 输入到该层, 该层中第 i 类模式的第 j 个神经元输入输出所对应的关系如下:

$$\phi_{ij}(x) = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} \exp\left(-\frac{\|x - \vec{x}_{ij}\|^2}{2\sigma^2}\right) \quad (14)$$

式中: σ 是平滑因子, 其取值影响到 PNN 模型的分类性能, 是网络中唯一需要调节的参数。

求和层是将隐含层中属于同一类的神经元的输出进行加权平均, 输出对应每个类别的平均概率, 这一层的神经元个数与所需分类的类别数相等。计算公式为:

$$p_i = \frac{\sum_{j=1}^L \phi_{ij}}{L} \quad (15)$$

式中: p_i 表示第 i 类的平均概率输出, L 表示属于第 i 类神经元的个数。

输出层又称为竞争层, 仅包含一个神经元, 其输出为与求和层神经元中输出的最大值相对应的类别, 计算如下:

$$y = \text{argmax}(p_1, p_2, \dots, p_c) \quad (16)$$

式中: c 为总的类别的个数。

3.2 遗传算法优化平滑因子

遗传算法(genetic algorithm, GA)是模拟生物进化机制发展而来的一种全局优化算法^[19], 借鉴了达尔文的生物进化机制和孟德尔遗传学说, 首先设置种群规模, 在每一代群体中, 计算种群中所有个体的适应度, 根据适应度大小进行选择、交叉、变异操作, 从而产生新的种群, 种群在多次的上述过程中得以进化, 同时, 通过全局并行的搜索方法寻找最优个体, 以求出问题的全局最优解。遗传算法在全局寻优的过程中, 不受函数是否连续与可微的约束, 算法的实用性好、稳定性强。因此本文使用遗传算法来寻找使概率神经网络性能最优的平滑因子。

使用遗传算法优化 PNN 的平滑因子的步骤如下:

1) 设定平滑因子的取值范围, 进行种群初始化, $\{\sigma_1, \sigma_2, \dots, \sigma_M\}$, M 为种群规模, 并设定当前代数 $t=1$;

2) 使用由染色体获得的平滑因子, 构建 PNN, 计算分类准确率, 即计算染色体的适应度函数;

3) 选择适应度强的个体, 进行交叉、变异, 得到后代种群;

4) 更新当前代数 $t=t+1$;

5) 检验 t 是否到达设定的迭代次数, 若满足则算法终止, 否则返回步骤 2) 继续运行;

6) 输出适应度最高的个体, 得到此个体对应的平滑因子数值, 确定 PNN 的最终模型, 用于疲劳检测任务中。

4 实验分析

4.1 实验平台与实验数据

本文的实验基于 CPU 型号为 Intel® Core™ i5-3230M, RAM 为 8 G, 编译语言为 Python, 使用 Pycharm 工具包在 Windows10 操作系统上进行。

实验所用数据集来源于 YawDD 数据集、NTHU-DDD 数据集以及自采集数据集。

YawDD 数据集是由车载摄像头录制的模拟驾驶员驾驶行为数据集, 根据视频录制的角度不同分为两组数据, 一组将摄像头置于汽车的前视镜下方, 用于录制驾驶员的侧面视频; 另外一组将摄像头置于仪表盘上, 正对驾驶员, 用于录制驾驶员的正面视频, 驾驶员的面部特征包括眼部是否佩戴普通眼镜或太阳镜、嘴部紧闭、说话或唱歌、打哈欠, 视频像素为 640×480 pixels, 帧率为 30 fps。

NTHU-DDD 数据集^[20]来源于台湾国立清华大学制

作,该数据集基于白天和黑夜两种场景下录制,包含驾驶员是否佩戴眼镜、打哈欠、点头等多种行为动作,包含驾驶员两种驾驶行为:正常驾驶、疲劳驾驶,视频像素为 640×480 像素,每段视频时长在60 s左右,帧率为15 fps(黑夜)或30 fps(白天)。

自采集数据集来源于6名志愿者基于实车模拟疲劳驾驶和实验室模拟疲劳状态两种场景下采集,包含受试者长时间未眨眼、频繁眨眼、打哈欠、点头的行为动作,视频像素为 640×480 pixels,每种场景下每人采集4段视频,每段视频时长在90 s左右,帧率为30 fps。

对上述视频数据集进行裁剪,使每个视频的时长固定为20 s,共得到1 747组数据样本,其中,1 447组样本来源于YawDD和NTHU-DDD数据集,包含清醒、疲劳样本分别为853组、594组,这部分数据用于网络训练,使用三折交叉验证法测试模型,因此训练集与测试集的比例是2:1,采用随机划分;其余300组样本来源于自采集数据集,包含清醒、疲劳状态样本分别为184组,116组。这部分数据仅用于验证网络泛化性能。

4.2 网络训练与模型验证

通过遗传算法优化概率神经网络(GA-PNN)模型参数如下:

PNN模型:输入层接收的是根据样本所提取的PERCLOS、眨眼频率、嘴部PERCLOS值、点头频率4个特征参数,因此输入层神经元数量为4个;隐含层与训练样本的数量相等,由于训练样本为样本总和的 $2/3$,即1 012组,所以隐含层神经元数量为1 012个;驾驶员的状态包括清醒和疲劳两类,则求和层神经元数量为2个;竞争层用于输出概率最大值所对应的类别。

遗传算法优化平滑因子模型参数:种群规模为350,染色体长度为8,交叉概率为0.6,变异概率为0.01,迭代次数为25次。以PNN的分类精度 φ_{acc} 作为适应度值,对PNN进行优化,为了快速找到最优平滑因子,设定平滑因子取值范围为(0,10),测试精度 φ_{acc} 随迭代次数的曲线如图7所示。在迭代次数为19次,即遗传代数 $t=19$ 代时,达到最高的测试精度,最高精度 $\varphi_{acc}=99.52\%$,对应的最优平滑因子 $\sigma=0.04706$ 。

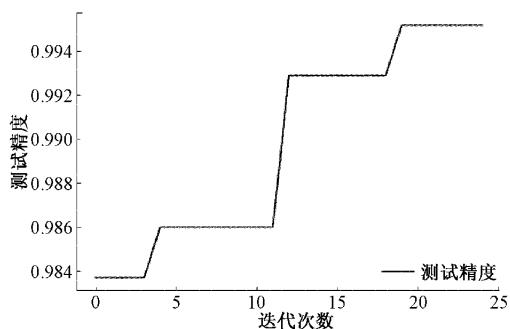


图7 测试精度 φ_{acc} 随迭代次数的变化

将优化后得到的平滑因子应用在训练好的概率神经网络中,使用验证样本验证网络的实际分类性能,本文方法(GA-PNN)与SVM、BP神经网络、未优化的PNN($\sigma=0.1$)分类器的疲劳分类精度对比如表1所示,使用未优化的PNN与使用SVM进行疲劳分类的性能相当,使用BP神经网络较未优化的PNN分类精度提升了2.34%,而本文使用GA-PNN的分类性能最优,比未优化的PNN的准确率提升了2.67%,比使用BP神经网络的分类准确率提升了1%。

表1 各种分类器的疲劳检测准确率

分类器	正确分类 样本数	错误分类 样本数	准确率/ %
SVM	287	13	95.67
BP神经网络	293	7	97.67
PNN($\sigma=0.1$)	286	14	95.33
GA-PNN	296	4	98.67

实时性是衡量疲劳检测方法实用性的一项指标,根据视觉暂留原理,当检测系统每秒处理画面超过24帧以上时,即可做到实时性的检测。本文疲劳检测各模块的平均检测耗时如表2所示,可以看出,本文算法的检测总耗时为35.6 ms,换算帧率为28 fps,满足实时性检测要求。

表2 疲劳检测系统各模块耗时

序号	模块	平均检测耗时/ms
1	人脸检测	26.8
2	特征点定位	4.0
3	疲劳参数计算	3.3
4	疲劳判定	1.5
5	总耗时	35.6

表3为本文的疲劳检测算法与现有文献的疲劳检测方法对比,文献[9]通过提取眼睛和嘴巴特征参数,使用SVM进行疲劳分类,准确率为95.40%;文献[21]通过提取眼睛和嘴巴特征的多个疲劳参数,使用特征加权的方式进行疲劳分类,准确率为97.50%;而本文通过提取眼睛、嘴巴和头部姿态特征的多个疲劳参数,使用遗传算法优化PNN的模型疲劳检测准确率为98.67%,疲劳检测时间更短。

表3 与现有文献的疲劳检测准确率对比

方法	准确率/%	检测时间/ms
文献[9]	95.40	64.0
文献[21]	97.50	—
本文算法	98.67	35.6

5 结 论

本文提出了一种使用遗传算法优化概率神经网络的疲劳检测算法,通过提取眼部、嘴部、头部姿态多个特征的疲劳指标,使用PNN进行疲劳判别,对于PNN平滑因子的选择,本文通过遗传算法来寻找最优平滑因子,进而确定最优PNN模型,通过与使用SVM、BP神经网络以及未优化的PNN模型的疲劳分类精度对比,优化后的PNN的分类精度有明显提升,实验表明,所提算法的泛化性能较好,检测实时性较高。但由于本文的研究是基于仿真实验来实现的驾驶员疲劳检测,下一步考虑将其移植在硬件平台上,使其应用在实际驾驶环境中,并根据实际驾驶中遇到的各种问题对算法进行补充与改进。

参考文献

- [1] SUN Y, TANG Z H. Traffic accident analysis and control countermeasures of fatigue driving on expressway[J]. Journal of Physics: Conference Series, 2021, DOI:10.1088/1742-6596/1906/1/012010.
- [2] LUO H, QIU T, LIU C, et al. Research on fatigue driving detection using forehead EEG based on adaptive multi-scale entropy[J]. Biomedical Signal Processing and Control, 2019, 51: 50-58.
- [3] SHEYKHIVAND S, REZAI T Y, MOUSAVI Z, et al. Automatic detection of driver fatigue based on EEG signals using a developed deep neural network [J]. Electronics, 2022, 11(14):2169.
- [4] HILAL A L, ALI A A, WALEED A N, et al. Modular design of fatigue detection in naturalistic driving environments [J]. Accident Analysis & Prevention, 2018, 120: 188-194.
- [5] MCDONALD A D, LEE J D, SCHWARZ C, et al. A contextual and temporal algorithm for driver drowsiness detection [J]. Accident and Prevention, 2018, 113: 25-37.
- [6] 吕秀丽, 刘希凤, 白永强. 基于SSD的多因素融合的驾驶疲劳检测研究[J]. 电子测量技术, 2022, 45(15): 138-143.
- [7] 张光远, 胡晋, 文原劲, 等. 高速铁路调度员疲劳程度分级及预测方法研究[J]. 铁道学报, 2021, 43(5): 18-26.
- [8] 李昭慧, 张伟良. 基于改进YOLOv4算法的疲劳驾驶检测[J]. 电子测量技术, 2021, 44(13): 73-78.
- [9] 冯晓锋, 方斌. 融合面部特征的机动车驾驶人疲劳检测[J]. 机械科学与技术, 2021, 40(11): 1767-1772.
- [10] 陈小强, 熊烨, 王英, 等. 面部多特征融合的列车司机疲劳检测方法研究[J]. 铁道学报, 2021, 43(12): 70-78.
- [11] 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.
- [12] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2005: 886-893.
- [13] KAZEMI V, SULLIVAN J. One millisecond face alignment with an ensemble of regression trees[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2014, DOI: 10.1109/CVPR.2014.241.
- [14] PAN G, SUN L, WU Z H, et al. Eyeblink-based anti-spoofing in face recognition from a generic web camera[C]. 2007 IEEE 11th International Conference on Computer Vision. Rio de Janeiro, Brazil: IEEE, 2007: 1-8.
- [15] WU Q, SUN B X, XIE B, et al. A PERCLOS-based driver fatigue recognition application for smart vehicle space[C]. 2010 Third International Symposium on Information Processing. Qingdao, China: IEEE, 2010: 437-441.
- [16] ABTAHI S, OMIDVEGANEH M, SHIMOHAMMADI S, et al. YawDD: A yawning detection dataset [C]. Proceedings of the 5th ACM Multimedia Systems Conference. MN, USA: IEEE, 2014: 24-28.
- [17] 刘世望. 基于卷积神经网络的驾驶员注意力监测方法研究[D]. 成都:西南交通大学, 2020.
- [18] SITU Y, GAO H, LI D, et al. Screw pairs condition monitoring based on integrated radial basis probabilistic neural networks [J]. Journal of Computational Information System, 2010, 6 (3): 913-920.
- [19] RUDOLPH G. Convergence analysis on canonical genetic algorithms[J]. Journal of IEEE Transactions on Neural Network, 1994, 5(1): 96-101.
- [20] WENG C H, LAI Y H, LAI S H. Driver drowsiness detection via a hierarchical temporal deep belief network[C]. Proceeding of the 2016 Asian Conference on Computer Vision, LNCS 10118. Cham: Springer, 2016:117-133.
- [21] 王红君, 白浩, 赵辉, 等. 基于计算机视觉的驾驶员疲劳状态检测预警技术[J]. 科学技术与工程, 2022, 22(12): 4887-4894.

作者简介

王晗,硕士研究生,主要研究方向为图像处理、计算机视觉。

E-mail:504505615@qq.com

邱联奎(通信作者),副教授,硕士生导师,主要研究方向为机器人视觉、智能计算。

E-mail:qiulk@yeah.net