

DOI:10.11784/tdxbz202403001

## 用于驾驶行为分析的驾驶员情绪识别算法

赵 华, 范鸿钢, 冯译方, 陈大昕, 刘志喜, 陈 韬

(天津大学先进内燃动力全国重点实验室, 天津 300350)

**摘要:** 驾驶员的情绪变化会直接影响其驾驶行为。目前对于驾驶员行为预测的研究依然采用统计分析的方式, 无法反映情绪状态对驾驶员行为的影响, 导致对驾驶员动力需求的预判存在信息偏差。为此, 针对实际驾驶过程中的驾驶员情绪状态判断, 提出了满足实车应用的驾驶员情绪识别算法, 同时设计试验研究了不同情绪间驾驶行为的特征差异。首先, 针对车载计算单元相对不足的问题, 结合人脸动作单元和面部表情编码系统, 简化了高兴和愤怒两种表情的面部关键点, 进而降低特征维度。然后, 使用支持向量机分别建立了两种情绪的识别模型, 通过网格搜索算法优化了模型参数, 提升离线识别准确率。最后, 结合情绪诱导设计了实车道路试验, 基于通用计算平台测试了模型的在线识别效果, 同时对比了驾驶员在高兴和愤怒时的驾驶行为以及车辆运行差异。结果表明: 利用简化特征建立的高兴和愤怒识别模型, 数据集离线测试的准确率分别达到了 84.45% 和 84.43%; 通用计算平台的测试结果显示该算法满足车载实时应用的需求, 与情绪诱导结果对应, 能够在线识别驾驶员的情绪状态; 与高兴情绪相比, 驾驶员在愤怒情绪下的驾驶行为更加激进, 加速踏板的操作从长期维持不变转为周期性的剧烈踩踏, 踏板频谱幅值最大提高了 165.1%, 整车油耗最大增加了 14.2%。

**关键词:** 驾驶员情绪识别; 人脸动作单元; 支持向量机; 道路试验; 驾驶行为分析

中图分类号: U471.3

文献标志码: A

文章编号: 0493-2137(2025)06-0619-10

## Driver Emotion Recognition Algorithm for Driving Behavior Analysis

Zhao Hua, Fan Honggang, Feng Yifang, Chen Daxin, Liu Zhixi, Chen Tao

(State Key Laboratory of Engines, Tianjin University, Tianjin 300350, China)

**Abstract:** Drivers' emotional changes considerably impact their driving behavior. However, current research on driver behavior prediction mainly relies on statistical analysis, failing to capture the influence of emotional states on driving behavior. This limitation introduces information bias in predicting driver power demand. To address this issue, a driver emotion recognition algorithm was developed for real-vehicle applications to assess drivers' emotional states during actual driving. Experiments were conducted to investigate variations in driving behavior characteristics across different emotional states. To overcome the challenge of limited onboard computing resources, the facial key points for happy and angry expressions were simplified by integrating the facial action coding system and face action units, effectively reducing the feature dimensions. Recognition models for the two emotions were separately developed using a support vector machine, with model parameters optimized via a grid search algorithm to enhance offline recognition accuracy. Subsequently, a real-vehicle road test incorporating emotion elicitation was conducted to evaluate the model online recognition performance using a general-purpose computing platform. In addition, the driving behaviors of drivers in happy and angry states were analyzed, and differences in vehicle operation under these emotional conditions were compared. The results indicate that the offline testing accuracy of the simplified feature dataset for recognizing happy and angry emotions reach 84.45% and 84.43%, respectively. Tests conducted on the general-

收稿日期: 2024-03-01; 修回日期: 2024-05-12.

作者简介: 赵 华 (1963—), 男, 教授, mesthzh@163.com.

通信作者: 陈 韬, tao.chen@tju.edu.cn.

基金项目: 天津市科技计划资助项目(24ZXZSS00090); 天津市研究生科研创新项目(2022BKY095).

Supported by the Tianjin Science and Technology Plan Project(No. 24ZXZSS00090), the Tianjin Graduate Student Research Innovation Program(No. 2022BKY095).

purpose computing platform demonstrate that the algorithm meets the requirements for in-vehicle real-time applications, successfully recognizing the driver's emotional state online and aligning with the outcomes of emotion elicitation. Furthermore, compared with happy state, drivers in angry state exhibit more aggressive driving behaviors. In particular, accelerator pedal operation changes from long-term steadiness to periodic vigorous pressing, with the pedal spectrum amplitude increasing by up to 165.1% and overall vehicle fuel consumption increasing by up to 14.2%.

**Keywords:** driver emotion recognition; facial action unit; support vector machine; road test; driving behavior analysis

道路交通系统是由人、车、路三者构成的复杂系统。驾驶员在道路交通系统中起着主导作用,是交通系统中主动变量<sup>[1]</sup>。驾驶员个体的区别主要体现在相同的交通场景下会产生不同的驾驶行为和动力需求。除了性格和习惯差异外,即使是同一个驾驶员,其情绪变化也会直接作用到驾驶行为的选择上<sup>[2]</sup>,使得当前基于预测信息的车辆及其动力系统控制建模存在信息盲区,无法适应驾驶员主观情绪的变化,影响精准的动力需求预测模型开发<sup>[3]</sup>。

早在 1982 年,国际驾驶人行为研究协会就在不同国家开展了调查,探究驾驶员的生理和心理因素对主观认知功能的影响。至今,已有许多学者针对特定情绪研究其与驾驶行为间的复杂关系。在过往的研究中,普遍认为负面情绪对驾驶行为的影响是不利的。Li 等<sup>[4]</sup>发现愤怒情绪会显著增加驾驶员的攻击性驾驶行为,愤怒驾驶会使碰撞风险增加 11.1 倍。Myounghoon 等<sup>[5]</sup>发现紧张情绪会使驾驶员对威胁性刺激的注意力提高,但会减弱对正常驾驶任务的关注。Arash 等<sup>[6]</sup>的研究表明焦虑情绪会降低注意力和危险判断能力,影响驾驶员的驾驶能力。相对而言,当前对正面情绪影响的研究较少。但 Zieger 等<sup>[7]</sup>证实了高兴情绪可以提高驾驶水平和感知能力。驾驶员情绪对驾驶行为的影响既可能是持续的也可能是突然的。因此,识别驾驶员情绪状态对于解析驾驶行为和预测驾驶员的动力需求具有重要意义。

辨识驾驶员情绪的途径主要有以下 3 种:面部表情、生物电信号<sup>[8]</sup>以及语音信号<sup>[9]</sup>。由于采集设备成本高昂且佩戴繁琐,甚至会影响驾驶员的正常操作,基于生物电信号的方法并不能很好地适应实际的驾驶场景<sup>[10]</sup>。而语音信号容易受外部环境的干扰,Tawari 等<sup>[11]</sup>的研究表明 15 dB 的外界噪声会使基于语音信号的情绪识别准确率下降 10% 以上,而在日常通勤中环境噪声普遍为 60 ~ 80 dB。因此,基于面部图像的识别分析方法具备更好的应用潜力。

人脸表情主要可分为宏表情和微表情。宏表情的持续时间较长,通常在 1 ~ 5 s 之间,面部肌肉动作

变化幅度大,相对容易识别。当前,宏表情识别方法主要分为 3 类。第 1 类是人工选取特征进行分类。He 等<sup>[12]</sup>使用流形散射变换来构建表达人脸样本的粗略结构,从局部坐标中捕获特征。该方法在计算过程中,不同特征之间会存在交叉重复。第 2 类是利用神经网络等智能辨识算法进行建模。Lasri 等<sup>[13]</sup>使用卷积神经网络(convolutional neural networks, CNN)对试验采集的人脸样本进行特征提取和表情分类,准确率较高。这类方法在更换实际数据检验时容易遇到准确率下降的问题。以上两类方法都是基于单帧图像进行分析的。第 3 类方法是基于时序图像进行估计。Ma 等<sup>[14]</sup>从表情变化的时序帧中估计面部动作的强度,结合各表情对应的强度变化进行分类,这类方法融合了连续帧间表情变化的强度特征,模型在线检验鲁棒性强,与基于单帧图像的识别方法相比,单步识别需考虑更多时序信息。

微表情的持续时间短,通常小于 1 s,动作强度低,难察觉。微表情的检测要求采样频率高且辨识速度快,导致特征选择上倾向于简单且低维度的特征<sup>[15]</sup>,这又与微表情难捕捉的特点相冲突。因此,在线捕捉微表情特征的挑战是巨大的,实际应用中将宏表情检测作为主要研究方法。

以往的面部宏表情研究主要为离线建模且计算复杂,实际应用中容易受到车载计算单元算力不足的限制。因此,需要设计轻量化的算法,来满足实际驾驶中情绪识别结果的实时性要求。同时,为了保障实时性,需要有针对性地建立不同情绪下面部特征的捕捉方法。进而开发对司机无干扰、快速、准确、客观的情绪识别方法,用于在真实场景下分析驾驶员情绪对驾驶行为的影响机制。

针对以上问题,采用单帧图像的、宏表情的简化几何特征进行驾驶员情绪识别,基于机器学习离线建立了情绪辨识模型并在嵌入式平台上进行了算力评估。为了验证模型的效果,设计实车试验识别情绪变化并分析了驾驶员在不同情绪下的驾驶行为差异,结果表明提出的算法能够用于实时识别驾驶员的情绪状态。

# 1 面部特征简化及提取

## 1.1 用于算法开发的表情数据集

中国科学院微表情二代 (Chinese Academy of Sciences micro-expression<sup>2</sup>, CAS(ME)<sup>2</sup>) 数据集是 2018 年由中科院心理研究所发布的基础数据集<sup>[16]</sup>, 具有以下特征.

(1) 数据集分为两部分, A 部分包括 87 个宏表情和微表情变化的长视频片段, B 部分包括 357 个剪辑后的图片序列, 并标注了表情起始帧、峰值帧和结束帧. 图像分辨率为 640 像素 × 480 像素, 30 帧/s. 表情标签分为厌恶、愤怒和高兴 3 种. 本研究基于愤怒和高兴两种情绪的宏表情数据进行建模.

(2) 数据集的建立结合了 3 种方法, 包括视频诱导、主观报告和动作单元 (action units, AU) 标注. 相

关面部编码专家对每段表情进行 AU 标注. AU 是依据肌肉学划分的一系列面部肌肉动作.

由于该数据集对表情变化的序列以及对应的面部动作单元进行了标注, 有利于对不同表情特征样本的提取, 从而进一步对比相应表情下的 AU 特征变化以及设计针对性的特征提取方法.

## 1.2 人脸关键点和面部表情编码系统

人类面部表情可以间接地传达内心情绪. 关键点检测, 是利用特征点定位脸部器官, 包括嘴巴、眼睛和眉毛等区域, 将面部区域简化为点的分布, 将器官运动简化为点的相对位移. 定位算法分为 5 点、68 点、186 点等. 特征点过少, 人脸特征不能被准确表达, 反之, 会面临特征冗余的问题. 为了兼顾计算速度和信息提取, 使用 68 点定位算法. 关键点依次输出为二维坐标, 坐标中心为图片的中心位置, 面部细节如图 1 所示.




图 1 面部的 68 个关键点位置  
Fig.1 Location of 68 facial key points

面部表情编码系统 (facial action coding system, FACS) 是心理学家 Ekman 提出的理论, 解释了人类的脸部肌肉运动和表情的关系<sup>[17]</sup>, 该理论自发布起被沿用至今. 人类表情变化的同时, 会出现一种或者多种 AU. 常见的 AU 有 25 种, 利用 AU 的特点, 可以将面部表情转换为脸部器官的运动. 因此, 利用关键点检测并识别 AU, 是相对方便且客观的方法. FACS 规定了高兴和愤怒的 AU 组合, 如表 1 所示.

表 1 面部表情与 AU 的对应关系  
Tab.1 Correlation between facial expressions and AU

表情	AU 组合
高兴	AU6——脸颊上升
	AU12——嘴角向上
愤怒	AU4——皱眉
	AU7——眼脸收紧
	AU23——双唇收紧

### 1.3 特征提取与归一化

通过对比 CAS(ME)<sup>2</sup> 数据集中由专家标注的 AU, 可以发现表情序列在面部肌肉学上具有显著特征. 如图 2 所示为其中一名实验人员在愤怒情绪下面部表情变化的起始帧、峰值帧和结束帧, 面部动作单元 AU4 的特征表现为两边眉毛下降和向眉心挤压. 同时, AU 的动作幅度从起始帧到结束帧之间表现为先增强后减弱的趋势.




图 2 面部动作单元 AU4 的特征

Fig.2 Characteristics of facial action unit AU4

利用面部关键点的位移和相对位置反映不同时刻面部的几何特征变化. 选取任意两个关键点间的欧氏距离作为特征量, 即

$$d_{i,j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (1)$$

式中:  $d_{i,j}$  为两点间距离;  $(x_i, y_i)$  和  $(x_j, y_j)$  分别为两个关键点的坐标.

基于 FACS 理论中不同表情的 AU 组合, 高兴时, 人脸器官特征为脸颊上升和嘴角上升, 关键点包括眼睛区域的点 37~48 和嘴巴区域的点 49~68, 共 32 个点. 而在愤怒时, 特征则表现为皱眉、眼睑收紧和双唇收紧, 关键点包括眉毛区域的点 18~27、眼睛区域的点 37~48 和嘴巴区域的点 49~68, 共 42 个点.

对于高兴和愤怒情绪, 不同区域的关键点两两组合, 并且计算距离特征, 特征维度分别为 256 和 301. 通过分析可知, 特征之间存在两个主要问题. 首先, 特征与所选 AU 的关联不大, 皱眉的动作主要考虑眉毛间距, 因此, 无需计算同一边眉毛上的特征. 其次, 特征之间存在交叉重复的情况, 计算眉毛间距时, 点 22 到点 23 的距离与点 21 到点 24 的距离表示的特征一致, 无需重复计算. 综合上述问题, 在考虑 AU 机理的前提下, 简化了两种情绪的人脸关键点和几何特征, 如表 2 所示.

基于数据集 B 中主观评价为高兴和愤怒的宏表情样本, 截取每个表情的起始帧到峰值帧之间的图片作为训练数据. 同时, 选取在每个表情的视频诱导过程中初始前 60 帧自然状态的图片作为对比数据. 将不同参与者的自然-高兴和自然-愤怒样本分组并去

表 2 不同情绪的关键点及特征简化  
Tab.2 Simplification of key points and characteristics corresponding to different emotions

情绪	关键点及特征简化
高兴	眼开度 (38,39,41,42,44,45,47,48) 上、下唇间距 (52,58) 嘴角间距 (49,55)
愤怒	眉毛间距 (22,23) 眼开度 (38,39,41,42,44,45,47,48) 上、下唇间距 (52,58)

除失真图像. 高兴样本图片 1839 张, 其对应的自然样本图片 1728 张; 愤怒样本图片 540 张, 其对应的自然样本图片 516 张. 对所有样本进行预处理, 包括人脸截取、灰度化及人脸对齐和关键点标记, 处理过程如图 3 所示.




图 3 数据集样本预处理过程

Fig.3 Sample preprocessing of the dataset

高兴的特征距离中, 眼睛开度分别对 (38-42、39-41、44-48、45-47) 这 4 对特征点计算欧氏距离并取均值, 上、下唇间距和嘴角间距分别对 (52-58、49-55) 这两对特征点计算欧氏距离. 基于前 60 帧自然状态的样本均值, 对所有特征进行归一化处理. 归一化计算公式为


$$d_{avg} = \sum_{m=1}^{60} d_m / 60 \quad (2)$$

$$d_{normal} = (d_m - d_{avg}) / d_{avg} \quad (3)$$


式中:  $d_{avg}$  为前 60 帧自然状态的样本均值;  $d_m$  为第  $m$  帧图片的原始距离;  $d_{normal}$  为归一化距离. 最后, 得到

( $d_{normal\_eye}$ ,  $d_{normal\_lip}$ ,  $d_{normal\_mouth}$ ) 的一组特征, 愤怒样本的特征计算与高兴相似, 仅在眉毛间距有所区分, 取(22-23)之间的距离.

同一种表情下的样本数据点构成了一个三维特征空间. 高兴-自然和愤怒-自然各自的样本分布如图4所示, 不同标签的数据点存在明显交叉现象.



(a) 高兴-自然样本三维空间分布



(b) 愤怒-自然样本三维空间分布

图4 不同样本的三维空间数据点分布

Fig.4 Three-dimensional spatial distribution of data points for different samples

## 2 表情识别建模

### 2.1 支持向量机的核函数选取

由图4可知, 样本的数据量较大且数据点交叉分布导致线性不可分, 因此选择带有核函数的支持向量机 (support vector machine, SVM) 处理该分类问题. SVM 是用于样本分类问题的有监督学习算法, 核函数主要有3种: 多项式 (poly)、径向基函数 (radial basis function, RBF) 和 sigmoid.

按4:1的比例划分训练集和测试集, 训练集和测试集中的正负样本比例遵循原始数据样本分布. 使用不同核函数, 设置默认参数, 分别进行模型的测试, 准确率如表3所示.

表3 不同核函数的模型准确率

Tab.3 Model accuracy with different kernel functions

核函数	高兴测试集	愤怒测试集
poly	68.77	78.32
RBF	79.18	78.55
sigmoid	60.22	65.57

从模型准确率对比可知, 设置默认参数时, 使用RBF建立的模型在准确率上明显优于poly和sigmoid核函数, 在高兴和愤怒测试集的准确率分别达到了79.18%和78.55%. 同时, 其在两组测试集之间的准确率差异较小, 仅有1%左右, 而使用poly和sigmoid核函数, 两组测试集的准确率差异在5%~10%左右. 因此, 选择RBF训练模型并进行参数优化.

### 2.2 模型参数优化和准确率检验

选用RBF核函数, SVM中可供调试的超参数主要包括两项:  $C$  和  $\gamma$ , 基于网格搜索法<sup>[18]</sup>对模型参数进行优化. 过程如下.

(1) 设置  $C = 0.01, 0.10, 1.00, 10.00, 100.00$  和  $\gamma = 0.010, 0.100, 1.000, 10.000, 100.000$ , 两个参数各自包括5个数值, 构成了25种参数组合. 基于以上组合进行参数遍历和模型训练, 对比不同参数组合训练出的模型十折交叉验证准确率, 检验模型的准确率表现. 高兴模型的最优数量级组合为  $C = 1.00$ 、 $\gamma = 0.100$ , 愤怒模型的最优数量级组合为  $C = 0.10$ 、 $\gamma = 0.010$ .

(2) 在对应的数量级组合下进一步搜索寻优, 网格间隔为第1步中所得的参数数值, 网格上、下限分别为  $10C(10\gamma)$  和  $C(\gamma)$ . 得到高兴模型的最优组合为  $C_i = 1.00$ ,  $\gamma_i = 0.200$ , 愤怒模型的最优组合为  $C_i = 0.50$ ,  $\gamma_i = 0.050$ . 这一步从数量级出发, 确定最优参数的范围.

(3) 在最优参数范围附近搜索, 网格间隔为对应数量级的20%, 网格上、下限分别为  $C_i + C(\gamma_i + \gamma)$  和  $C_i - C(\gamma_i - \gamma)$ . 搜索后确定高兴模型的最优参数为  $C_n = 0.80$ ,  $\gamma_n = 0.160$ , 愤怒模型的最优参数为  $C_n = 0.48$ ,  $\gamma_n = 0.048$ .

以上参数对应的模型准确率及测试集的混淆矩阵如图5所示. 经过参数优化后, 高兴和愤怒模型的识别准确率分别达到了84.45%和84.43%.

对比默认参数和网格搜索优化后的模型准确率表现, 高兴模型的测试集准确率由79.18%优化到了84.45%, 愤怒模型的测试集准确率由78.55%优化到了84.43%, 参数优化后模型的准确率分别提高了5.27%和5.88%.

为了进一步验证模型的泛化能力,防止模型存在过拟合问题,对训练好的模型作十折交叉验证. 检验结果如表 4、表 5 所示,结果显示,高兴模型仅有一次准确率低于 70.00%,愤怒模型仅有两次准确率低于

70.00%,整体准确率较优,基于 RBF 核函数建立的 SVM 情绪识别模型经过网格搜索参数优化后,具有较强的泛用性.




图 5 两组样本的测试集准确率及混淆矩阵

Fig.5 Test set accuracies and confusion matrix for two sample groups

表 4 参数优化后高兴样本的十折交叉检验结果

Tab.4 Ten-fold cross-validation results for the happy samples after parameter optimization

测试样本	错误分类	准确率/%
357	61	82.91
357	23	93.56
357	87	75.63
357	81	77.31
357	59	83.47
357	80	77.59
357	42	88.21
356	100	71.71
356	35	90.48
356	114	67.79
3 567	682	80.88

表 5 参数优化后愤怒样本的十折交叉检验结果

Tab.5 Ten-fold cross-validation results for the angry samples after parameter optimization

测试样本	错误分类	准确率/%
106	16	84.91
106	18	83.02
106	12	88.68
106	16	84.91
106	13	87.74
106	32	69.81
105	33	68.57
105	12	88.57
105	23	78.10
105	19	81.90
1 056	194	81.62

如表 6 所示为基于不同面部特征建立的表情识别模型的准确率对比. 其中,基于 CK+ 数据集(发布于 2010 年,包括 7 种宏表情的视频序列)使用神经网络的宏表情检测在不同样本间的准确率存在差异,同

时卷积计算过程也相对复杂. 基于人为设计特征的识别方法样本间的差异较小,但计算过程需要融合 0°、15°、30°等不同角度及方向下人脸的特征,模型训练需要特定的 Bosphorus 数据集(发布于 2008 年,包括 3D 面部图像),获取多角度下的面部数据在当前实际应用中存在很大的困难. 基于简化 AU 特征的算法使用单帧正面图像,针对高兴和愤怒两种极端情绪分别进行特征简化和提取,降低模型计算复杂度的同时确保了识别不同表情的准确率.

表 6 模型识别准确率对比

Tab.6 Comparison of model recognition accuracies

方法	图像帧	数据集	准确率/%
CNN <sup>[12]</sup>	单帧	CK+	高兴 88.00
			愤怒 65.00
人为设计特征 <sup>[11]</sup>	单帧	Bosphorus	高兴+愤怒
			混合 78.33
本文方法	单帧	CAS(ME) <sup>2</sup>	高兴 84.45
			愤怒 84.43

### 2.3 计算资源占用评估

考虑所建模型需要满足实车运行的需求,选用通用计算平台进行了资源占用评估. 在验证过程中从连续采集、频率为 30 Hz 的摄像头图像中,设置每间隔 30 帧(约合 1 s)读取一张 640 像素 × 480 像素的图片作为输入.

模型计算所部署的平台选择了树莓派 4 B,其具体参数如下:CPU 为 Broadcom BCM2711,4 核,主频为 1.5 GHz;GPU 为 Broadcom VideoCore VI,500 MHz;RAM 为 8 GB. 此平台的计算资源低于各主要企业披露的车载计算单元规划,因此,算法在该平台上的运算效果对于实际推广应用有较好的示范

作用。

测试结果显示,模型运行过程内存占用为140 MB,单次运算平均耗时 0.5 s 左右(最大不超过 0.6 s),远小于采样间隔。其满足车载在线辨识驾驶员情绪的需求。

### 3 模型实车验证及驾驶行为分析

#### 3.1 情绪诱导及主观评价

由于需要开展实车道路,分析不同情绪对驾驶行为以及车辆运行的影响,同时验证模型效果,因此必须采用有效手段激发驾驶员的特定情绪。类比 CAS(ME)<sup>2</sup> 数据集,在视频诱导的基础上加入了音频刺激。其中视频材料选自中国情绪影响材料库<sup>[19]</sup>,平均时长 3 min;而音频材料则是由互联网上获取的相声及交通冲突音频剪辑得到(分别对应高兴和愤怒),平均时长 5 min。

驾驶员通常不会在短期内出现频繁的情绪变化。因此,对于每一位参试人员,每天试验采集 3 组数据(1 组高兴,2 组愤怒)。愤怒试验进行连续 2 次测试主要是考虑到愤怒情绪的调动相对高兴情绪更为困难,且情绪转换也需时间。每次试验间隔 1 d 进行,避免当天内多组试验间的影响。

试验通过自我评价量表<sup>[20]</sup>(self-assessment manikin, SAM)来评估情绪诱导结果,如图 6 所示。SAM 量表由 3 个维度构成,各有 9 个强度等级,愉悦度对应高兴程度,唤醒度对应大脑兴奋程度,支配度则对应人面对事件主动或被动的地位,与愤怒相关。

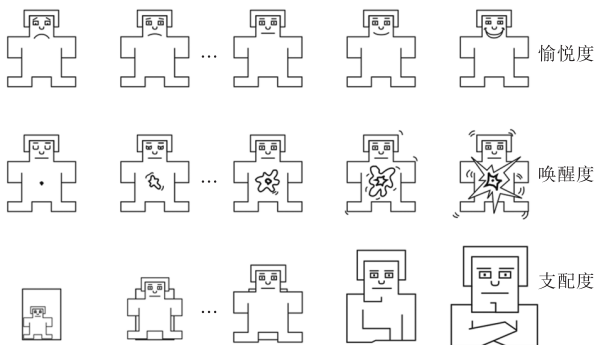


图 6 SAM 评价量表

Fig.6 SAM assessment scale

#### 3.2 实车试验设计

试验在一台大众公司生产的甲壳虫轿车和一台一汽丰田公司生产的卡罗拉轿车上进行。试验固定在工作日晴天的上午 10:00 开始,每天进行一名参试人员的 3 组试验并记录数据,分多次进行。试验的流

程设计如下。

(1) 试验流程介绍及注意事项说明。参试人员均详细了解完整试验流程,包括试验道路、情绪激发方式、驾驶要求、采集的数据等。

(2) 自由驾驶练习。参试人员在正式试验前进行驾驶练习,熟悉试验道路和车辆操作。此后,参试人员休息 5 min 来平复自身的情绪,准备正式开始试验。

(3) 高兴/愤怒情绪诱导。在情绪诱导开始时,参试人员随机观看一组视频片段。播放结束后车辆起步,数据记录开始,同时开始播放音频材料。

(4) 高兴/愤怒情绪驾驶。驾驶员被要求全程在右侧车道直线行驶,避免在对向单车道上的超车等违规操作。

(5) 数据记录。读取车辆车载诊断(on-board diagnostics, OBD)系统信号并记录车辆运行和驾驶行为参数。

(6) 情绪模型实时运行。模型搭载于树莓派 4B 平台,外接摄像头拍摄人脸,试验过程实时进行人脸的情绪识别。

(7) 主观量表填写及休息冷却。每组试验结束后,参试人员填写 SAM 量表。之后有 5 min 的时间平复情绪,准备下一组试验。

(8) 重复进行驾驶试验。驾驶员多次进行情绪诱导驾驶试验,直到完成当天 3 组数据(1 组高兴,2 组愤怒)的采集。

#### 3.3 情绪对驾驶行为及车辆运行的影响

试验一共有 3 位男性参试人员,平均年龄 25 岁,平均驾龄 5 a。参试人员未接受过专门的情绪诱导训练,能够保证采集到的面部特征均为自然表现。试验分为 5 d 进行,一共采集到 15 组数据,单组时长 4~6 min。其中,参试人员 A 进行 1 次试验,包括 1 组高兴和 2 组愤怒数据,参试人员 B 和参试人员 C 分别进行 2 次试验,各自包括 2 组高兴和 4 组愤怒数据(之后高兴以 Ha 指代,愤怒的两组分别以 An-1 和 An-2 指代)。A 和 C 的试验在大众甲壳虫上进行,B 的试验则在丰田卡罗拉上进行。

图 7 所示为高兴和愤怒两种情绪 SAM 量表结果的三维空间分布,从中可以看出,高兴的 5 组数据点和愤怒的 10 组数据点明显分布于不同的两个区域。由于部分试验组别间三维指标等级相同,高兴和愤怒存在相同数据点重合的情况。同时,在愤怒试验的指标中,支配度明显高于高兴试验;愉悦度则呈现出相反的特征,明显低于高兴试验。该结果与图 6 的量表指标特征对应,说明试验能够激发驾驶员的愤怒

以及高兴情绪并采集到了相应情绪下的驾驶行为和

车辆运行数据.




图 7 SAM量表的指标空间分布

Fig.7 Spatial distribution of SAM scale indicators

表 7 所示为参试人员的加速踏板开度分布数据,  $Q_1$  为 25 分位数,  $Q_3$  为 75 分位数. 由于车型的不同, B 的加速踏板数值要小于 A 和 C. 通过对比加速踏板开度及变化率的分布范围变化幅度可知, B 的操作相对平稳, C 的操作最为剧烈, A 则介于两者之间.

在多组试验中, B 和 C 试验 1 相比试验 2 的数据特征更加显著. 对于每位驾驶员, An-2 开度分布的离散程度相对 An-1 更大, 以其中一组试验说明, A 的加速踏板开度分布范围最大增加了 146.9%, 开度变化率分布范围最大增加了 100.9%. 因此, 之后主要针对 A、B 试验 1 和 C 试验 1 的驾驶行为和油耗数据做进一步的分析, 如表 8、表 9 所示.

表 7 参试人员的加速踏板开度分布对比

Tab.7 Comparison of participants' accelerator pedal opening distributions

人员	试验组别	加速踏板开度的 $Q_1, Q_3/\%$	开度变化率的 $Q_1, Q_3/\%$
A	Ha	7.65, 15.84	0, 1.09
	An-1	4.92, 17.49	0, 1.64
	An-2	0, 20.22	0, 2.19
B	试验 1, Ha	0, 7.84	-0.39, 0.78
	试验 1, An-1	0, 9.02	-0.79, 0.39
	试验 1, An-2	0, 10.58	-0.78, 1.57
	试验 2, Ha	0, 8.62	-0.39, 0.78
	试验 2, An-1	0, 7.45	-0.40, 0.80
	试验 2, An-2	0, 9.41	-0.69, 1.17
C	试验 1, Ha	8.20, 14.21	-1.10, 1.64
	试验 1, An-1	0, 21.85	-2.19, 2.73
	试验 1, An-2	0, 22.40	-1.82, 3.82
	试验 2, Ha	7.73, 16.39	-0.73, 1.64
	试验 2, An-1	1.91, 16.59	-1.64, 1.95
	试验 2, An-2	0, 23.50	-2.55, 2.91

表 8 所示为 3 位参试人员的频谱峰值及功率谱中心频率 (frequency center, FC), 频谱峰值反映了驾驶员操作加速踏板的幅度, 中心频率则反映驾驶员操作的周期. 以 A 的数据为例说明, Ha 的 FC 为 0.103 Hz, 而 An-2 的 FC 为 0.096 Hz, 加速踏板向低频变化. Ha 的频谱峰值为 3.05%, An-2 的频谱峰值为 6.49%, 操作幅度增大了 112.8%. B 和 C 也呈现低频高幅的特征, 且 B 在愤怒试验的操作幅度最大增加了 165.1%.

表 8 参试人员的加速踏板频谱及功率谱特征

Tab.8 Characterization of the accelerator pedal spectrum and power spectrum of participants

人员	试验组别	频谱峰值/%	中心频率/Hz
A	Ha	3.05	0.103
	An-2	6.49	0.096
B	试验 1, Ha	1.46	0.237
	试验 1, An-2	3.87	0.175
C	试验 1, Ha	1.92	0.209
	试验 1, An-2	4.93	0.175

两项指标说明, 在高兴情绪下驾驶员的需求为维持踏板保持稳定的行驶, 而在愤怒情绪下驾驶员的加速踏板不再是长期维持不变, 而是周期性的大幅踩踏操作, 由于受到负面情绪的影响, 操作剧烈程度明显增加.

在愤怒情绪下, 驾驶员对加速踏板的剧烈操作反映到动力系统上的主要表现为发动机工作状态大幅波动和燃油消耗率的上升. 表 9 所示为参试人员 A、B 试验 1 和 C 试验 1 的油耗结果. 对于每位参试人员来说, 高兴组别耗时最长, 平均车速最低, 驾驶相对稳定, 油耗最低. B 由于愤怒情绪的影响, 后两组试验的平均车速升高, 导致油耗增加了 7.6% ~ 10.7%. 与 B 不同的是, 在 A 和 C 的试验中, 尽管平均车速分别降低了 5.2%和 6.3%, 但油耗反而更高, A 的愤怒试验中油耗增加了 7.9% ~ 14.2%, C 的愤怒试验中油耗增加了 2.3% ~ 11.9%. 结合表 7 的加速踏板开度分布以及变化率分析, 原因在于驾驶员在 An-2

试验中的剧烈操作导致发动机瞬态切换工况的增加。

由于试验选择在郊区道路,同行车辆少,路况特征对驾驶行为的干扰较小,结合对驾驶行为的分析,这种油耗恶化明显是情绪对驾驶员的负面影响引起瞬态工况显著增加导致的结果。

表 9 整车油耗对比

Tab.9 Comparison of vehicle fuel consumption

人员	试验组别	平均车速/ (km/h)	油耗/ (L/km)
A	Ha	42.00	5.06
	An-1	45.82	5.46
	An-2	43.45	5.78
B	试验 1, Ha	35.38	5.78
	试验 1, An-1	39.43	6.22
	试验 1, An-2	44.43	6.40
C	试验 1, Ha	38.55	4.71
	试验 1, An-1	41.59	4.82
	试验 1, An-2	38.95	5.27

### 3.4 情绪识别模型的运行结果

选取情绪识别模型在参试人员 A 的 Ha 和 An-2 两组试验的实时运算结果进行比较,如图 8 所示. 情绪标签 0 对应自然, 1 对应愤怒, 2 对应高兴。




图 8 实车试验的模型识别结果

Fig.8 Results of model recognition for real vehicle tests

高兴试验全程处于高兴状态,原因在于高兴情绪的诱导相对简单,且面部特征动作幅度明显. 愤怒第 2 组试验的愤怒状态主要集中于 50~250 s,在 105 s 处存在短时的标签突变. 此处可能存在模型的局部误差. 总体上,模型的实时识别结果能够与 SAM 量表的评价结果对应,所建立的模型和算法具备应用于车载计算单元并在实际道路中实时识别驾驶员情绪的能力,能够与驾驶行为分析相结合,开发不同情绪下的驾驶员模型。

## 4 结 论

基于 CAS(ME)<sup>2</sup> 表情数据集和简化面部特征提取,搭建了高兴和愤怒的单帧驾驶员情绪在线识别模

型,并设计实车道路试验验证了情绪识别模型的有效性以及不同驾驶员情绪对驾驶行为以及车辆运行的影响. 得到主要结论如下。

(1)搭建了基于 RBF 核函数的 SVM 情绪辨识模型,结合网格搜索算法对模型进行参数优化以进一步提高辨识准确率,离线建立了高兴和愤怒的表情识别模型. 模型在测试集验证准确率分别为 84.45%和 84.43%. 模型能够满足车载应用条件并在线捕捉驾驶员的情绪状态。

(2)设计实车试验验证模型实时识别效果并分析情绪对驾驶行为的影响. 结果显示,与高兴相比,当驾驶员处于愤怒情绪时,加速踏板的操作幅值最大增加了 165.1%. 同时,同一驾驶员的剧烈操作使发动机瞬态工况增加,导致车辆油耗增幅最大可达 14.2%. 模型识别结果与主观评价结果对应。

### 参考文献:

- [1] 张 洁, 郭 钢, 李文博. 驾驶员危险感知研究现状及展望[C]//2020 中国汽车工程学会年会论文集(1). 上海, 中国, 2020: 174-179.  
Zhang Jie, Guo Gang, Li Wenbo. Research status and prospect of driver's hazard perception[C]//2020 Proceedings of the Annual Meeting of the Society of Automotive Engineering of China (1). Shanghai, China, 2020: 174-179 (in Chinese).
- [2] Singh H, Kathuria A. Analyzing driver behavior under naturalistic driving conditions: A review[J]. Accident Analysis & Prevention, 2021, 150: 105908.
- [3] 郑 奇. 智能驾驶中驾驶员风格识别及车辆行为预测研究[D]. 杭州: 浙江大学工程师学院, 2022.  
Zheng Qi. Research on Driver Style Recognition and Vehicle Behavior Prediction for Intelligent Driving[D]. Hangzhou: Polytechnic Institute, Zhejiang University, 2022 (in Chinese).
- [4] Li W B, Zhang B B, Wang P Z, et al. Visual-attribute-based emotion regulation of angry driving behaviors[J]. IEEE Intelligent Transportation Systems Magazine, 2022, 14(3): 10-28.
- [5] Myounghoon J, Bruce W, Yim J B, et al. Effects of specific emotions on subjective judgment, driving performance, and perceived workload[J]. Transportation Research Part F: Traffic Psychology and Behavior, 2014, 24: 197-209.
- [6] Arash T, Nathan L, Vahid B, et al. How are drivers' stress levels and emotions associated with the driving

- context? A naturalistic study[J]. *Journal of Transport & Health*, 2023, 31: 101649.
- [7] Zieger S, Dong J Y, Taylor S, et al. Happiness and high reliability develop affective trust in in-vehicle agents[J]. *Frontiers in Psychology*, 2023, 14: 1129294.
- [8] Zou B C, Wang Y X, Zhang X L, et al. Concordance between facial micro-expressions and physiological signals under emotion elicitation[J]. *Pattern Recognition Letters*, 2022, 164: 200-209.
- [9] Li J, Zhang X Y, Li F L, et al. Speech emotion recognition based on optimized deep features of dual channel complementary spectrogram[J]. *Information Sciences*, 2023, 649: 119649.
- [10] Li W B, Cui Y D, Ma Y T, et al. A spontaneous driver emotion facial expression(DEFE) dataset for intelligent vehicles: Emotions triggered by video-audio clips in driving scenarios[J]. *IEEE Transactions on Affective Computing*, 2023, 14(1): 747-760.
- [11] Tawari A, Trivedi M. Speech based emotion classification framework for driver assistance system[C]//2010 IEEE Intelligent Vehicles Symposium. La Jolla, USA, 2010: 174-178.
- [12] He Y, Fu K, Cheng P, et al. Facial expression recognition with geometric scattering on 3D point clouds[J]. *Sensors*, 2022, 22(21): 8293.
- [13] Lasri I, Solh A R, Belkacemi M E. Facial emotion recognition of students using convolutional neural network [C]//2019 Third International Conference on Intelligent Computing in Data Sciences(ICDS). Marrakech, Morocco, 2019: 1-6.
- [14] Ma J L, Li X S, Ren Y Y, et al. Landmark-based facial feature construction and action unit intensity prediction[J]. *Mathematical Problems in Engineering*, 2021: 6623239.
- [15] Wang S Y, Zhao X C, Zeng X M, et al. Micro-expression recognition based on EEG signals[J]. *Biomedical Signal Processing and Control Part B*, 2023, 86: 105037.
- [16] Qu F B, Wang S J, Li H, et al. CAS(ME)<sup>2</sup>: A database for spontaneous macro-expression and micro-expression spotting and recognition[J]. *IEEE Transactions on Affective Computing*, 2018, 9(4): 424-436.
- [17] Aleesa R S, Mahvash Mohammadi H, Monadjemi A, et al. Dataset classification: An efficient feature extraction approach for grammatical facial expression recognition[J]. *Computers and Electrical Engineering*, 2023, 110: 108891.
- [18] Ogunsanya M, Isichei J, Desai S. Grid search hyperparameter tuning in additive manufacturing processes[J]. *Manufacturing Letters*, 2023, 35: 1031-1042.
- [19] 胡乾静. 不同情绪在典型驾驶场景中对驾驶行为的影响研究[D]. 重庆: 重庆大学汽车工程学院, 2019.  
Hu Qianjing. Research on the Impact of Anger-Neutral Emotion on Driving Behavior in Typical Scene[D]. Chongqing: School of Automotive Engineering, Chongqing University, 2019(in Chinese).
- [20] Bradley M M, Lang P J. Measuring emotion: The self-assessment manikin and the semantic differential[J]. *Journal of Behavior Therapy and Experimental Psychiatry*, 1994, 25(1): 49-59.

(责任编辑: 王晓燕)