

疲劳演化影响下基于 1DCNN 的驾驶人辨识研究

陈青云¹, 孙一帆¹, 郭军华^{1,2*}, 严利鑫², 李少鹏², 李琴剑¹, 石翔³

(1. 华东交通大学交通运输工程学院, 江西南昌 330013; 2. 江西飞行学院, 江西南昌 330088; 3. 长安大学交通运输工程学院, 陕西西安 710018)

摘要: 汽车正转变为以用户为核心的智能服务载体, 能实时感知用户身份的驾驶人辨识模型是实现个性化服务的关键, 其辨识效果受到疲劳状态演化的影响。然而, 多数现有研究仅利用清醒数据建立模型, 未考虑疲劳影响。因此, 本文提出一种适应疲劳演化的驾驶人辨识方法。首先采集驾驶人的操作、面部行为及疲劳评分等多模态数据, 然后基于 Kruskal-Wallis 检验筛选身份特征指标, 最后整合不同驾驶状态数据训练基于主成分分析与一维卷积神经网络的驾驶人辨识模型。结果表明所提出的模型对 3、9、15、21 人组的平均准确率、精确率和召回率分别达到 88.72%、89.97% 和 88.80%, 较传统模型提高 23.34%、22.53% 和 23.24%, 有效提升辨识精度和对疲劳演化的适应能力, 支撑驾驶人精准感知和个性化驾驶系统研发。

关键词: 驾驶人身份辨识; 疲劳状态演化; 深度学习; 多源数据融合; 智能交通

中图分类号: U471

文献标志码: A

Research on a 1DCNN-Based Driver Identification Method under the Influence of Fatigue Evolution

Chen Qingyun¹, Sun Yifan¹, Guo Junhua^{1,2*}, Yan Lixin², Li Shaopeng², Li Qinjian¹, Shi Xiang³

(1. School of Transportation Engineering, East China Jiaotong University, Nanchang 330013, China; 2. Jiangxi Flight University, Nanchang 330088, China; 3. School of Transportation Engineering, Chang'an University, Xi'an 710018, China)

Abstract: Automobiles are becoming user-centered intelligent service platforms, and driver identification models identifying drivers in real time are key to achieving personalized services. The identification performance of these models can be affected by variations in fatigue states. However, most existing models are trained using data collected under alert states, without considering the effects of fatigue. Therefore, this study proposes a driver identification method that adapts to fatigue evolution. First, multimodal data, including driving operation behaviors, facial behaviors, and fatigue ratings, were collected. Then, the Kruskal-Wallis test was employed to select discriminative driver identification features. Finally, by integrating driving data from different driving states, a driver identification model based on principal component analysis and a one-dimensional convolutional neural network was developed. The results show that the proposed model achieved average accuracy, precision, and recall of 88.72%, 89.97%, and 88.80%, respectively, for driver groups of 3, 9, 15, and 21 participants, representing increases of 23.34%, 22.53%, and 23.24%, respectively, over the conventional model. The proposed method effectively improves identification accuracy and adaptability to fatigue, supporting accurate driver identification and the development of personalized driving systems.

Key words: Driver identification; Fatigue state evolution; Deep learning; Multi-source data fusion; Intelligent transportation

随着传感器、人工智能及大数据等技术的发展, 汽车正由传统出行工具向以用户需求为核心的综合服务载体转变, 成为交通行业新质生产力发展的关键抓手^[1]。精准感知用户身份并提供个性化服务成为智能汽车发展的重要方向。驾驶人作为智能汽车服务的核心对象, 其个体特征直接影响车辆功能适配与服务体验, 准确辨识驾驶人身份是实现个性化服务的前提^[2]。基于驾驶数据的驾驶人辨识模型可建立驾驶数据与

收稿日期: 2026-09-09

基金项目: 国家自然科学基金项目(52502418); 江西省自然科学基金项目(20252BAC200360, 20262BAC240512); 江西省社会科学基金项目(26GL43); 中国博士后科学基金项目(2025M771635)

身份标签的映射关系,可为共享出行、人机协同及辅助驾驶等应用提供支撑,已成为智能汽车领域的重要研究方向^[3]。

基于驾驶数据的驾驶人辨识研究主要包括特征提取与模型构建两方面^[4]。在驾驶人特征提取方面,现有研究主要通过模拟驾驶与自然驾驶实验采集多模态数据^[5],从中挖掘能反映驾驶人独特属性的关键特征。常用于表征驾驶人身份的数据以驾驶操作和车辆运行数据为主,包括方向盘转角、油门与制动信号、车速、加速度、车道位置及跟车间距等^[4-5]。近年来,部分研究开始引入面部行为与生理信号,如眼部运动与心率等^[5]。在获取身份表征数据后,学者通过方差分析、相关性分析等统计方法或机器学习筛选关键特征^[4,6]。此外,疲劳识别与身份辨识所使用的数据(如方向盘转角、车速、眼部运动等)存在重合,且疲劳会改变操作行为与面部特征,影响指标与驾驶人的相关性^[5,7]。因此,有必要构建适应疲劳演变的身​​份特征指标体系。

驾驶人身份辨识模型主要包括参数模型、图论模型、机器学习与深度学习模型^[5],其本质是学习驾驶人独特的驾驶数据特征,建立驾驶数据与驾驶人之间的对应关系^[8]。参数模型利用特定场景中的车辆运动参数,刻画驾驶人特有的驾驶模式^[5],将驾驶数据与驾驶人的运动参数模式进行匹配,辨识驾驶人身份。图论模型则是将驾驶数据转化为由节点与边等元素构成的图结构,进行个性化表达^[8],通过图相似性分析辨识驾驶人。参数模型与图论模型虽具有一定可解释性,但其对大规模数据的处理能力有限,且对复杂特征的辨识能力不足。近年来,机器学习与深度学习成为驾驶人辨识的重要技术方案。机器学习依赖人工设计特征,在中小规模数据下表现较好^[9-10];深度学习则具备更强的特征挖掘能力,在处理高维复杂数据上优势显著^[4,11]。例如,Xu等采集模拟驾驶环境下的驾驶操作和眼睛运动等数据,训练基于卷积神经网络的驾驶人辨识模型,达到90.91%的辨识准确率^[2]。

以往研究多假设驾驶人处于清醒状态,通常仅采用清醒阶段数据进行特征提取与模型训练,忽视了由清醒到疲劳的驾驶状态演化的影响。然而,在实际交通场景中,特别是在高速公路长途运输等长时间连续驾驶场景中,驾驶人难以始终保持清醒,多数会经历疲劳的累积过程,导致生理、心理、驾驶操作及面部行为特征发生变化^[12-13]。现有研究从机理分析角度探讨疲劳对驾驶人身份特征的影响,利用疲劳样本分析驾驶人身份特征在不同状态下的稳定性,发现疲劳对驾驶人身份特征的分布、贡献度和辨识精度有重要影响,为考虑疲劳的驾驶人辨识提供了理论依据^[5]。但面向实际应用场景,关于如何融合疲劳状态信息进行驾驶人辨识建模,提高不同驾驶状态下驾驶人辨识实时性和稳定性的研究仍相对较少。

针对上述问题,本文利用模拟驾驶实验平台,开展考虑疲劳影响的驾驶人辨识研究,基于主成分分析(PCA)与一维卷积神经网络(1DCNN),分别建立忽视疲劳与考虑疲劳两类驾驶人辨识模型,对比两类模型的辨识性能,验证考虑疲劳演化对模型精度和鲁棒性的重要意义。

1 实验和方法

本文将驾驶人辨识归为有监督分类问题,提出基于PCA与1DCNN的驾驶人辨识研究框架,分别使用清醒样本、清醒与疲劳的混合样本训练忽视疲劳与考虑疲劳的驾驶人辨识模型,并使用包含清醒和疲劳的样本测试两类模型的辨识效果。

1.1 实验与数据采集

1) 被试

本文通过问卷调查选拔被试,筛选标准包括持合法驾驶证、无睡眠相关疾病及无 3D 眩晕等,共获得 24 名有效被试(男 16 名,女 8 名),平均年龄 30.54 岁,平均驾龄 8.79 年,职业涵盖企业职员、职业驾驶人、自由职业者及高校学生。

2) 实验设备与场景

实验依托驾驶模拟系统与驾驶人监测系统开展。参考相关研究^[5,7],设计全长约 57.76 km 的高速公路场景,包含长直线、圆曲线及缓和曲线,双向六车道,弯道布设限速标志。道路两侧景观单调,以增强长时间连续驾驶下的疲劳累积效应。

3) 实验过程

被试进行上午和下午两组实验,分别逆时针和顺时针驾驶 5 圈,累计驾驶时长约 300 分钟。实验前要求被试保持正常作息,并进行预驾驶训练。正式实验中,被试按日常习惯驾驶,避免因模拟环境中安全风险较低、约束较少而故意频繁变道与超车,以减少非必要驾驶操作对正常驾驶过程的干扰。播放器每 5 分钟询问被试 KSS 评分。

4) 数据采集与指标计算

实验数据包括驾驶数据、面部数据和疲劳数据。驾驶数据选用方向盘转角、油门、刹车、速度等 10 类数据,面部数据包含闭眼频率、嘴巴开度、面部转动角度等 20 类数据。疲劳数据以 KSS 量化:KSS 小于 5 为清醒状态,大于 6 为疲劳状态^[7]。采用双层滑动时间窗进行数据切分与指标计算,具体过程见参考文献^[5],最终获得 162 种操作行为指标和 324 种面部行为指标。

1.2 基于 PCA 与 1DCNN 的驾驶人辨识模型

如图 1 所示,本文以 1DCNN 为核心算法构建驾驶人辨识模型。1DCNN 能融合不同模态数据,通过卷积运算挖掘深层特征信息,在复杂模式分类中具有较好表现,被广泛应用于驾驶人辨识及危险驾驶状态检测等研究^[4]。




图 1 基于 PCA 和 1DCNN 的驾驶人身份辨识模型

Fig.1 Driver identification model based on PCA and 1DCNN

1) Kruskal-Wallis (KW) 检验

本文使用 KW 检验筛选身份特征指标。KW 检验是非参数检验方法, 无需满足正态分布等假设, 适合非线性和高波动的驾驶数据, 其统计量绝对值越高, 表示个体差异越明显, 对区分驾驶人越重要^[5]。为满足不同驾驶状态下的驾驶人辨识需求, 分别在清醒状态与疲劳状态下对指标进行 KW 检验。 $P_value < 0.05$ 表示该指标在驾驶人之间差异显著, 选择在清醒和疲劳状态下均 $P_value < 0.05$ 的指标作为驾驶人身份特征指标。对于第 j 个指标, 假设共有 α 名驾驶人参与实验, 每名驾驶人作为一个独立样本组。设第 q 名驾驶人的该指标样本数量为 N^q ($q=1, 2, \dots, \alpha$)。将所有驾驶人的该指标观测值进行排序, 计算统计量 H , H 的绝对值越大, 指标的个体差异程度越大, 计算公式如下:

$$H = \frac{12 \sum_{q=1}^{\alpha} \frac{(R_{Oj}^q)^2}{N^q}}{A_N (A_N + 1)} - 3(A_N + 1) \sim \chi^2(\alpha - 1) \quad (1)$$

式中: R_{Oj}^q 是第 q 名驾驶人的第 j 个指标的秩和, $A_N = \sum_{q=1}^{\alpha} N^q$ 表示第 j 个指标的总观测样本数量, $\chi^2(\alpha - 1)$

是自由度为 $\alpha - 1$ 的卡方分布。

2) PCA 算法

对 KW 检验筛选的特征指标先后进行归一化处理和 PCA 降维, 降低数据冗余, 并将降维后的主成分输入 1DCNN。PCA 是一种简单高效的降维方法, 常用于降低驾驶行为等复杂数据的冗余信息^[5,9]。多次测算发现累计方差贡献率超过 85% 后, 主成分维度增加较快, 但模型精度提升趋缓, 因此累计方差贡献率取 85%。

如图 1 所示, 输入层设置 d 个神经元, $A_j^{[t-v:t]} = [a_j^{t-v}, a_j^{t-v+1}, \dots, a_j^{t-1}, a_j^t]$ ($1 \leq j \leq d$) 表示第 j 个主成分前 v 个时间步长的数据向量, a_j^t 是第 j 个主成分在时间步 t 上的数值。第 1 层卷积层包含 64 个卷积核, 第 2 层卷积层包含 128 个卷积核。第 1 层池化层采用最大值池化操作, 在第 2 层卷积层后采用全局平均池化。

为了降低过拟合风险, 设置随机失活层, 按一定失活率随机丢弃一些神经元的输出, 提高模型的泛化能力, 对全局平均池化层的输出 $\mathbf{G}$ 进行随机失活操作见公式 (2):

$$\begin{cases} \mathbf{D} = \text{Bernoulli}(1 - l_p) \\ \tilde{\mathbf{G}} = \mathbf{D} \odot \mathbf{G} \end{cases} \quad (2)$$

式中: Bernoulli 是成功率为 l_p 的伯努利分布, $\mathbf{D}$ 是含有 0 和 1 的随机向量, 0 表示输入特征被丢弃, 概率为 l_p , 1 表示输入特征被保留, 其概率为 $1 - l_p$, $\odot$ 表示对应位置上的元素相乘, $\tilde{\mathbf{G}}$ 是随机失活后的输出向量。

随机失活层通过全连接层与输出层相连, 输出层的神经元个数与组内驾驶人数量相等。使用 Softmax 函数计算身份标签的概率, 以概率最大的类别为最终的驾驶人身份, 输出层的计算公式如下:

$$\begin{cases} \mathbf{O} = \text{Softmax}(\mathbf{O}_w \mathbf{Z}_F^2 + \mathbf{o}_b) \\ S = \text{argmax}(\mathbf{O}) \end{cases} \quad (3)$$

式中： $\mathbf{O} \in \mathbb{R}^C$ 是组内 C 名驾驶人类别概率的向量， $\mathbf{Z}_F^2$ 是第 2 层全连接层的输出向量， $\mathbf{O}_w$ 和 $\mathbf{o}_b$ 分别是输出层的权重矩阵和偏置向量， S 是输出的身份标签。

将 S 与样本的真实身份标签 S' 对比，采用误差反向传播算法修正模型参数。通过迭代测试，设置初始学习率为 0.0036，为避免收敛震荡，每 5 次迭代，学习率乘以 0.36。模型 A 和 B 训练结束条件均是达到最佳验证结果。

2 结果与讨论

考虑实际情况并参考以往研究^[5,10,14]，设置 3 人、9 人、15 人及 21 人 4 种人数组合进行驾驶人辨识。限于篇幅，在特征筛选与模型训练等环节，以 3 人组为例进行详细阐述。

2.1 考虑疲劳影响的身份特征指标提取结果

为平衡精度和计算量，本文设置时间窗为：外层时间窗设为 20 秒，外层步长设为 2 秒，内层时间窗设为 10 秒，内层步长设为 1 秒。分别对清醒和疲劳状态下的指标进行 KW 检验。以操作行为指标为例，展示指标在清醒和疲劳状态下的 $|H|$ ，探索疲劳对身份特征指标的影响，如图 2 所示。鉴于指标种类较多，选取在清醒状态下 $|H|$ 排名前 50 的指标进行展示，所有指标均满足 $P_value < 0.05$ 。




图 2 操作行为特征指标的 KW 检验统计量

Fig.2 KW test of operational behavior features

在图 2 中，清醒与疲劳状态下各指标 $|H|$ 分布差异显著，且在疲劳状态下的 $|H|$ 均高于清醒状态的 $|H|$ ，说明疲劳放大了操作行为的个体差异。其原因在于清醒状态下驾驶人遵循较为一致的安全驾驶策略，而疲劳导致操作稳定性下降，行为波动增大^[7]。多数面部行为指标在疲劳状态下的 $|H|$ 也有所增加，表明疲劳增强了面部行为指标的身份辨识能力。但疲劳状态下头部行为指标的 $|H|$ 略有下降，可能由于疲劳状态下驾驶人普遍出现打哈欠、点头等共性头部运动^[13,15]，降低了头部运动特征的个体差异。可见疲劳演化对驾驶人身份特征指标的辨识能力有重要影响。

2.2 驾驶人辨识模型的训练及整体辨识结果

为规避随机划分导致的信息泄露,契合驾驶人在线辨识的实际场景,本文采用时间分隔5折交叉验证划分训练集和测试集。在达到最佳性能时,模型A训练样本和验证样本的准确率分别达到97.76%和96.07%,训练样本和验证样本的损失分别降至 4.7×10^{-2} 和 6.7×10^{-2} 。模型B训练样本和验证样本的准确率分别为97.10%和96.32%,训练样本和验证样本的损失分别降至 5.2×10^{-2} 和 6.5×10^{-2} 。模型A和B损失曲线均平稳下降并趋于稳定,且未出现过拟合现象。表明二者均有良好的特征挖掘效果,能够有效学习驾驶人身份特征。

测试样本是包含清醒阶段、清醒到疲劳过渡阶段和疲劳阶段的全周期数据,采用准确率、精确率和召回率全面评估模型的驾驶人辨识效果,计算公式见文献[8]。如图3所示,在所有驾驶人组合的全周期测试样本上,模型B在各个评价指标上均明显优于模型A。模型B所有人数组合的平均准确率、精确率和召回率分别为88.72%、89.97%和88.80%,比模型A分别提升23.34%、22.53%和23.24%,可见对于4种人数组合的驾驶人辨识任务,考虑疲劳能提高整体辨识精度,有效降低误判和漏判情况,显著增强模型对驾驶状态变化的适应能力,证明了疲劳演化对驾驶人辨识的重要影响。




图3 模型A和B对全周期测试样本的驾驶人辨识效果对比

Fig.3 Driver identification performance of Model A and Model B

此外,对比不同人数组的辨识结果可知,随着组内人数增加,两类模型的评价指标均有所下降。以往研究也有类似发现^[8,16],原因可能是人数越多,对特征学习的要求越高,增加了驾驶人辨识的难度。并且组内人数越多,模型 B 的提升幅度越高,当组内人数为 21 人时,模型 B 准确率、精确率和召回率的提升幅度最高,分别为 24.99%、24.56%和 25.04%。可见组内人数越多,疲劳对驾驶人辨识影响越大,越有必要考虑疲劳演化的影响。

对比相关研究可知,本模型在人数较多的组合中表现较好。例如,文献[5]中 3 人组的辨识准确率为 94.61%,与本文较为接近。然而,其 9、15 和 21 人组的辨识准确率分别下降至 60.05%、56.86%和 50.46%。本文对应组别的辨识准确率分别达到 90.52%、86.12%和 84.15%,均明显高于文献[5]。这表明,本模型在组内人数增加和个体差异更加复杂的情况下仍具有较好的辨识精度和稳定性,更适用于实际驾驶场景。

上述差异可能与理论模型、时间窗及数据集划分方法有关。文献[5]采用长短时记忆神经网络(LSTM),侧重利用时间依赖关系刻画疲劳状态下驾驶特征的时序变化,采用 40 秒外层时间窗,对时间信息的学习要求更高。本文采用 1DCNN 的卷积操作,提取驾驶特征中的局部模式和个体差异,并将外层时间窗缩短至 20 秒,提高了驾驶人辨识的精细度和时效性。相比 LSTM,1DCNN 结构更简单、计算效率更高,更适合长时间连续驾驶场景下的实际应用。此外,研究采用时间分隔的交叉验证,降低相邻时间样本之间的信息交叉风险,使性能评价更符合实际驾驶过程。

2.3 不同驾驶状态下驾驶人辨识模型的性能对比

为深入分析模型 B 优于模型 A 的原因,以 3 人组{11、14、22}为例,本文分别绘制模型 A 和模型 B 对清醒状态样本、清醒到疲劳过渡阶段样本、疲劳状态样本的混淆矩阵。

如图 4 所示,模型 A 对清醒状态样本的辨识效果较好,准确率、精确率和召回率均达 93%以上。然而,随着疲劳样本的增加,模型 A 的辨识性能明显下降,对于疲劳样本,模型 A 的准确率仅为 55.19%,原因可能是随着疲劳加深,驾驶人的操作及面部行为数据发生较大变化,导致模型 A 无法将疲劳阶段的数据与清醒阶段的身份特征匹配,难以适应疲劳特征的变化。




图 4 模型 A 对不同驾驶状态样本的驾驶人辨识混淆矩阵

Fig.4 Driver identification confusion matrices of Model A for test samples under different driving states

如图 5 所示, 模型 B 在过渡样本集和疲劳样本集上的辨识效果优异, 各类评价指标均维持在 93%以上, 误判和漏判风险低。疲劳样本并未显著降低模型 B 的辨识精度, 表明模型 B 能适应疲劳状态演化。但模型 B 在清醒样本集上的性能略有下降, 误判与漏判风险有轻微上升, 原因可能是模型 A 仅基于清醒数据训练, 其训练数据与清醒状态测试样本具有较高的一致性, 对清醒状态下身份特征的学习更有效。而模型 B 不仅同时学习清醒和疲劳状态下的身份特征, 还需要学习疲劳状态下个体特征的变化, 其处理的数据分布和特征变化更复杂, 对清醒测试样本的针对性相对较弱, 辨识效果也有所下降。总体而言, 模型 B 在不同驾驶状态下均能较准确地辨识驾驶人, 鲁棒性较好, 尤其在疲劳样本上仍保持较高辨识精度, 有效提高整体辨识效果。




图 5 模型 B 对不同驾驶状态样本的驾驶人辨识混淆矩阵

Fig.5 Driver identification confusion matrices of Model B for test samples under different driving states

两种模型的性能差异主要源于对疲劳状态信息的处理方式不同。模型 A 沿用多数现有研究的思路^[4,8], 忽略实际交通场景中常见的疲劳演化过程, 仅采集清醒状态下的驾驶数据训练模型。由于疲劳会显著改变驾驶人的生理、心理及行为表现^[7], 使得模型 A 难以适应疲劳状态下的特征变化, 导致辨识效果较差, 而模型 B 在训练时引入疲劳状态信息, 全面挖掘不同驾驶状态下的身份特征, 可将清醒到疲劳演化全过程中的驾驶数据与身份进行匹配, 提升整体辨识准确性。

3 结论

疲劳是常见的危险驾驶状态, 会显著影响驾驶数据分布, 降低基于驾驶数据的驾驶人辨识性能。因此, 本文通过模拟驾驶实验采集多模态数据, 基于深度学习算法, 建立考虑疲劳演化的驾驶人辨识模型, 得到如下结论:

- 1) 考虑疲劳演化的影响, 采用 KW 检验提取清醒和疲劳状态下均有显著个体差异的身份特征指标, 研究发现疲劳会改变驾驶人辨识特征指标的分布, 显著影响身份特征指标的辨识能力。
- 2) 提出 PCA 与 1DCNN 组合的驾驶人辨识模型框架, 建立了忽视疲劳与考虑疲劳演化的两种驾驶人辨识模型。两种模型在训练阶段均能较好地挖掘驾驶人身份特征, 但模型 B 的整体辨识效果显著优于模型 A, 其平均准确率、精确率和召回率较模型 A 分别提高 23.34%、22.53%和 23.24%。

3) 发现在疲劳样本中, 模型 A 的准确率下降超 38%, 仅为 55.19%。而模型 B 在不同驾驶状态下的辨识效果较为平衡, 准确率均超过 92%, 可有效应对疲劳演化引起的驾驶数据偏移, 显著提升全周期特别是疲劳阶段的辨识精度。

在模拟驾驶环境中采集的数据与真实道路场景中的数据存在差异, 未来将采集真实道路数据验证模型, 构建适应复杂场景的驾驶人辨识系统。本文为长时间连续驾驶场景下的驾驶人辨识提供了新思路, 可结合驾驶状态监测等辅助驾驶系统实时采集多模态驾驶数据, 实现不同驾驶状态下的高精度驾驶人辨识, 为车辆个性化配置、安全管理等应用场景提供可靠的驾驶人身份信息。

参考文献:

- [1] 梁钰, 杨艳群, 张燕, 等. 基于驾驶模拟器的高速公路工作区预警策略优化[J]. 华东交通大学学报, 2026, 43(3): 74-82.
LIANG Y, YANG Y Q, ZHANG Y, et al. Optimization of warning strategies for highway work zone based on driving simulator[J]. Journal of East China Jiaotong University, 2026, 43(3): 74-82.
- [2] XU J, PAN S, SUN P Z H, et al. Human-factors-in-driving-loop: Driver identification and verification via a deep learning approach using psychological behavioral data[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(3): 3383-3394.
- [3] COMPANY MCKINSEY. The future of autonomous vehicles: from technology to commercialization[R]. New York, NY: McKinsey & Company, 2024.
- [4] RAVI C, TIGGA A, REDDY G T, et al. Driver identification using optimized deep learning model in smart transportation[J]. ACM Transactions on Internet Technology, 2022, 22(4): 1-17.
- [5] SUN Y, WU C, ZHANG H, et al. Understanding influences of driving fatigue on driver fingerprinting identification through deep learning[J]. IEEE Transactions on Vehicular Technology, 2024, 73(2): 1829-1844.
- [6] AZADANI M N, BOUKERCHE A. Driverrep: Driver identification through driving behavior embeddings[J]. Journal of Parallel Distributed Computing, 2022, 162: 105-117.
- [7] WANG X, XU C. Driver drowsiness detection based on non-intrusive metrics considering individual specifics[J]. Accident Analysis & Prevention, 2016, 95: 350-357.
- [8] MARTINELLI F, MERCALDO F, NARDONE V, et al. Driver Identification Through Formal Methods[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(6): 5625-5637.
- [9] XUN Y, LIU J, KATO N, et al. Automobile Driver Fingerprinting: A New Machine Learning Based Authentication Scheme[J]. IEEE Transactions on Industrial Informatics, 2020, 16(2): 1417-1426.
- [10] EZZINI S, BERRADA I, GHOGHO M. Who is behind the wheel? Driver identification and fingerprinting[J]. Journal of Big Data, 2018, 5(1): 9.
- [11] LU L, XIONG S. Few-shot driver identification via meta-learning[J]. Expert Systems with Applications, 2022, 203: 117299.
- [12] ANSARI S, NAGHDY F, DU H, et al. Driver mental fatigue detection based on head posture using new modified reLU-BiLSTM deep neural network[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8): 10957-10969.
- [13] FADHEL M A, GHARGHAN S K, MAHMOOD A I. Artificial Intelligence-Based Non-intrusive Driver Drowsiness Detection: A Multimodal Review of Behavioral and Physiological Solutions[J]. International Journal of Intelligent Transportation Systems Research, 2026: 1-48.
- [14] TSELENTIS D I, PAPADIMITRIOU E. Driver profile and driving pattern recognition for road safety assessment: Main challenges and future directions[J]. IEEE Open Journal of Intelligent Transportation Systems, 2023, 4: 83-100.
- [15] 孙一帆, 王榕, 张晖, 等. 基于 PCA-1DCNN 的快速个性化疲劳驾驶辨识研究[J]. 中国公路学报, 2025, 38(12): 289-305.
SUN Y F, WANG R, ZHANG H, et al. Research on fast and personalized fatigue driving recognition based on PCA-1DCNN[J]. China Journal of Highway and Transport, 2025, 38(12): 289-305.

- [16] ZHANG J, WU Z, LI F, et al. A deep learning framework for driving behavior identification on in-vehicle CAN-BUS sensor data[J]. Sensors, 2019, 19(6): 1356.



第一作者: 陈青云（1982—），男，正高级工程师，博士研究生，硕士生导师，研究方向为交通安全、智能交通系统。



通信作者: 郭军华（1976—），男，教授，博士，博士生导师，江西飞行学院副校长，江西省政府研究室特约研究员，中国物流学会常务理事，研究方向为智能交通、交通安全、低空交通。