

基于改进 K 均值聚类分析的汽车驾驶风格 自动识别算法研究

陈 振, 梁丰收, 陆高林, 张露婵, 陈 鹏

(比亚迪汽车工业有限公司, 广东 深圳 518118)

摘要: 驾驶风格作为影响汽车性能表现的关键因素之一, 不仅直接关系到车辆的能耗水平、续航里程, 还深刻影响道路安全及交通流畅度。本文提出了一种基于改进 K 均值聚类的驾驶风格自动识别算法。在利用因子分析对实车上传的周期数据降维后, 使用该算法能够有效识别驾驶风格, 并对结果进行有效解读与分析。结果表明, 驾驶风格可分为平静型、保守型与激进型三类。

关键词: 改进 K 均值聚类; 因子分析; 驾驶风格识别

中图分类号: U461.91; TP301.6 文献标志码: A DOI: 10.15917/j.cnki.1006-3331.2025.04.001

Research on Automatic Recognition Algorithm of Automobile Driving Style Based on Improved K-Means Clustering Analysis

CHEN Zhen, LIANG Fengshou, LU Gaolin, ZHANG Luchan, CHEN Peng

(BYD Auto Industry Co., Ltd., Shenzhen 518118, China)

Abstract: As a key factor affecting commercial vehicle performance, driving style significantly impacts not only vehicle energy consumption and range but also road safety and traffic fluency. This paper proposes a driving style recognition algorithm based on an improved K-means clustering approach. After reducing the dimension of periodic real vehicle operational data using factor analysis, the algorithm effectively identifies driving styles and interprets and analyzes the results. The results show that driving styles can be divided into three distinct types: calm, conservative, and aggressive.

Key words: improved K-means clustering; factor analysis; driving style recognition

作为影响车辆性能表现的关键因素之一, 驾驶风格不仅直接关系到车辆的能耗水平和续航里程, 还会对道路安全和交通流畅度产生影响。因此, 对汽车驾驶风格进行分类并展开深入分析, 对于优化车辆控制策略、提升能源利用效率以及保障道路交通安全而言, 均具有重要意义。

1 汽车驾驶风格识别方法现状

当前, 根据驾驶风格识别算法是否预先对数据实施标签化处理, 可将其划分为有监督、半监督与无监

督三大类。三者的区别在于, 有监督学习全部使用带有标签的数据进行训练, 半监督学习使用少量带标签的数据和大量无标签的数据进行训练, 而无监督学习使用的训练数据全部为无标签状态。有许多研究者对有监督的驾驶风格识别进行了研究, 还有少部分学者对无监督和半监督进行了研究, 本文主要采用无监督学习框架。

文献[1]提出了一种依托支持向量机(Support Vector Machine, SVM)的有监督学习方案, 该方案有效缩短了驾驶风格识别的耗时。文献[2]提出了一

收稿日期: 2025-01-24。

第一作者: 陈 振(1987—), 男, 硕士, 工程师, 主要从事新能源商用车产品技术研究工作。E-mail: chen.zhen2@byd.com。

通信作者: 陆高林(1998—), 男, 硕士, 助理工程师, 主要从事新能源商用车大数据研究工作。E-mail: 1275062530@qq.com。

种基于卷积神经网络的电动城市客车进站驾驶风格识别算法,通过全连接网络识别客车进站驾驶风格,取得了较好的效果。文献[3]提出了一种基于机器学习的驾驶员行为分析方法。该方法专注于变道和加速场景的行为指标量化,通过SVM算法对激进型和稳健型驾驶风格进行分类。研究表明,在包含距离参数的情况下,该分类方法的准确率约为78%。

为深入探究驾驶人驾驶倾向性的动态变化,文献[4]和文献[5]开发了一种基于深度学习的识别方法。该方法首先提取车辆运动状态参数,然后运用K均值聚类初步分类,最终构建了融合注意力机制的BiLSTM模型,实现了对周围车辆驾驶倾向性的高精度(89.74%)识别。相较于SVM与人工神经网络模型,其识别性能显著提升。文献[6]探讨了基于深度学习构建激进驾驶行为识别模型的方法。当面对复杂场景(如异常天气)时,引入迁移学习技术可实现模型从正常天气到异常天气场景的知识迁移,为解决数据匮乏的特殊场景中驾驶行为识别问题提供了新思路。

文献[7]针对自动驾驶车辆换道行为的安全保障,提出了一种结合多元特征参数与优化SVM的驾驶风格识别模型,通过改进粒子群算法优化SVM参数,并利用真实交通流数据验证其高效性与准确性,实现了对驾驶风格的高精度识别。文献[8]针对智能网联汽车与人工驾驶车辆共存的异质混杂交通环境,聚焦驾驶行为识别,提出了基于深度学习的异常驾驶行为识别方法,有效提升了异常驾驶行为的识别精度,为智能网联汽车的行驶安全提供了关键支撑。

文献[9]针对驾驶风格识别研究中存在的数据不真实、考虑因素片面及整体把握不足等问题,通过采集真实驾驶数据,并以工况为识别基础构建了基于半监督学习的多工况驾驶风格识别模型,实现了对驾驶风格全面准确的评估。文献[10]为满足驾驶员对车辆性能的个性化需求,采用驾驶模拟器采集多工况数据,通过主成分分析法提取特征参数,并运用自组织映射(Self-Organizing Map, SOM)神经网络进行聚类分析,成功构建了可基于驾驶历史数据识别不同驾驶风格的SOM神经网络系统,并以温和型驾驶风格为例,验证了其合理性。文献[11]针对传统驾驶风

格分类忽略多样性的问题,提出了融合驾驶事件提取、谱聚类分析和随机森林算法的识别方法,通过事件特征聚类与多算法对比,验证了该融合模型的高识别准确率(92.73%),较单一的随机森林算法有显著提升(77.89%)。

虽然有监督学习在模型准确率方面有优势,但其依赖于大量人工对数据进行事先标注。特别是在驾驶风格识别中,需要预先对驾驶行为进行主观标签定义。这种方法不仅耗时费力,而且主观性较强,可能影响分类结果的客观性和准确性。此外,标注完成后还需进行模型训练,进一步增加了时间成本。相比之下,半监督学习作为一种折中方案,仅需少量标注样本与大量未标注数据,便可在保证一定识别精度的同时显著减少标注工作量。然而,半监督学习模型在结构设计和算法实现上通常比有监督学习更为复杂,常常涉及伪标签生成、一致性正则化机制技术。这些技术不仅增加了模型构建的难度,还可能导致训练过程不稳定和调参困难,从而限制了其在实际工程中的应用。鉴于此,一些研究者转向基于无监督学习的驾驶风格识别,该方法无需提前标注,可在时间成本较低的情况下识别驾驶风格。其中文献[12]采用基于K-Means聚类的驾驶风格识别方法,通过采集商用车实车运行数据,将驾驶风格划分为激进、普通、平静三种类型,该方法在动力总成换挡线自适应修正方面展现出良好的识别效果。然而无监督方法(如K-means聚类)需提前规定聚类中心,仍存在一定的主观性。

本文将聚类分析作为一种无监督学习技术,其在数据处理与模式识别领域优势明显,特别适合探索性数据分析。该技术能从大量复杂的驾驶行为数据中发现潜在的驾驶风格特征。通过聚类算法,可将具有相似驾驶习惯和行为模式的驾驶员划分为同一类别,从而有效区分不同类型的驾驶员,为后续的驾驶风格量化评估、个性化驾驶辅助系统开发以及智能车队管理策略的制定提供理论基础和科学依据。

为探索一种更客观且无需提前训练即可自动化识别的分类方法,本文提出了一种基于聚类分析的驾驶风格自动识别算法,主要聚焦于无监督学习框架下的驾驶风格识别。即在无需提前对数据进行标签化处理的前提下,通过聚类算法对数据进行训练,自动

识别驾驶风格, 输出识别结果与输入指标的关系, 并对识别结果进行有效解读与分析。

2 驾驶风格识别算法

本文提出的驾驶风格自动识别算法流程如下。

2.1 数据采集及预处理

1) 数据采集与分段处理。首先对目标车辆进行连续数据采集, 采集时间不少于一周。采集的主要数据包括油门踏板深度、刹车踏板深度、车速及百公里能耗等关键驾驶指标。采集数据的频率为 10 s 一次。每采集一次, 就形成一条数据记录。为确保后续分析的有效性, 将采集到的连续数据按每 10 min 为一个时间窗口进行分段处理, 从而形成若干个独立的驾驶片段。每个驾驶片段包含 60 条数据记录, 作为后续驾驶风格分析的基础数据单元。

2) 数据预处理与指标计算。对每个驾驶片段中的 60 条数据进行预处理, 以消除数据异常值与无效值对分析结果的干扰。预处理过程主要包括: ①剔除数据中的异常值(如超出合理范围的数值)与无效值(如缺失值或无效记录), 以确保数据的有效性; ②基于过滤后的有效数据, 应用公式(1)~(8)计算与驾驶风格相关的每个驾驶片段的指标。具体指标包括: 油门踏板深度均值 μ_p 、油门踏板深度标准差 σ_p 、刹车踏板深度均值 μ_q 、刹车踏板深度标准差 σ_q 、车速均值 \bar{v} 、车速标准差 σ_s 、百公里能耗 C 、刹车踏板使能占比 β 。

$$\mu_p = \sum_i^n p_i/n \quad (1)$$

$$\sigma_p = \sqrt{\sum_i^n (p_i - p_{\text{avg}})^2/(n-1)} \quad (2)$$

$$\mu_q = \sum_i^n q_i/n \quad (3)$$

$$\sigma_q = \sqrt{\sum_i^n (q_i - q_{\text{avg}})^2/(n-1)} \quad (4)$$

$$\bar{v} = \sum_i^n s_i/n \quad (5)$$

$$\sigma_s = \sqrt{\sum_i^n (s_i - s_{\text{avg}})^2/(n-1)} \quad (6)$$

$$C = (e_2 - e_1)/(m_2 - m_1) \times 100 \quad (7)$$

$$\beta = \sum_i^n \text{sign}(q_i)/n \quad (8)$$

式中: n 为过滤掉无效值与异常值后的有效数据数量, 假设一个驾驶片段里, 包含无效值和异常值的数据总共有 k 条, 则 $n = 60 - k$; p_i 为第 i 次采集的油门踏板深度; q_i 为第 i 次采集的刹车踏板深度; s_i 为第 i 次采集的车速; m_1 和 m_2 分别为采集开始和采集结束时的里程; e_1 和 e_2 分别为采集开始时和采集结束时的总能耗。

3) 数据标准化。完成指标计算后, 为消除不同指标间的量纲差异, 通过 Z-Score 标准化技术对数据进行规范化处理, 以确保数据在统计分析中的可比性与一致性。Z-Score 标准化公式如式(9)所示。

$$z = (x - u)/\sigma \quad (9)$$

式中: x 为式(1)~式(8)中 8 个原始指标的值; u 为该原始指标的均值; σ 为该原始指标的标准差; z 为原始数据 x 对应的 Z-Score 标准化后的数据。各指标的均值和标准差则可由式(10)和式(11)计算得出。

$$u = \sum_i^N x_i/N \quad (10)$$

$$\sigma = \sqrt{\sum_i^N (x_i - u)^2/(N-1)} \quad (11)$$

式中: N 为驾驶片段的数量; x_i 为第 i 个驾驶片段中每个原始指标在整个驾驶片段对应时间范围内的值, 这些值是在至少一周的数据采集时间内记录的。

2.2 驾驶风格核心指标提取

本部分工作是对 2.1 节中第 3) 步得到的 N 个驾驶片段的 8 个指标数据进行降维处理, 即从这 8 个指标中提取更能反映驾驶风格的少数核心指标。

因子分析是一种常用的数据降维方法, 其可从一组关联性指标中提取出公因子, 这些公因子能够反映原始数据的某些潜在特质或结构。具体步骤如下:

1) 适合性检验。在进行因子分析之前, 需要对数据进行适合性检验, 以判断数据是否适合进行因子分析。常用的适合性检验方法为凯泽-迈耶-奥尔金检验(Kaiser-Meyer-Olkin, 简称 KMO 检验)。

KMO 值越接近 1, 说明数据越适合进行因子分析。一般来说, KMO 值大于等于 0.6 时, 数据比较适合进行因子分析; KMO 值小于 0.6 时, 则不适合进行

因子分析。具体计算公式如式(12)所示。

$$K = \sum r_{ij}^2 / (\sum r_{ij+}^2 + \sum p_{ij}^2) \quad (12)$$

式中: K 为整体抽样适配度检验量; p_{ij} 为第*i*个变量和第*j*个变量的偏相关系数,即偏相关系数矩阵的第*i*行第*j*列元素; r_{ij} 为第*i*个变量和第*j*个变量的相关系数,其公式如式(13)所示。

$$r_{ij} = \frac{\sum_{k=1}^n (x_{ik} - u_i)(x_{jk} - u_j)}{(n \cdot \sigma_i \cdot \sigma_j)} \quad (13)$$

式中: x_{ik} 为第*i*个变量的第*k*个值; u_i 为第*i*个变量的均值,可由式(10)计算; x_{jk} 为第*j*个变量的第*k*个值; u_j 为第*j*个变量的均值,可由式(10)计算; σ_i 和 σ_j 分别为变量*i*和变量*j*的标准差,均可由式(11)计算。

第*i*个变量和第*j*个变量的协方差值 $\text{cov}(x_i, x_j)$, 可由式(14)计算。

$$\text{cov}(x_i, x_j) = \frac{\sum_{k=1}^n (x_{ik} - u_i)(x_{jk} - u_j)}{n} \quad (14)$$

偏相关系数矩阵 P 中的元素 p_{ij} 可通过矩阵 P 直接计算得出,其公式如式(15)所示。

$$P = -D^{-\frac{1}{2}} R^{-1} D^{-\frac{1}{2}} \quad (15)$$

式中: R 为变量的协方差矩阵,其中第*i*行第*j*列的元素可由式(14)计算得到, R^{-1} 为矩阵 R 的逆。 D 为 R^{-1} 的对角矩阵,即 R^{-1} 的对角元素构成的对角矩阵, $D^{-\frac{1}{2}}$ 为矩阵 D 的每个对角元素取平方根后的逆矩阵。

本文进行KMO检验,得到KMO值为0.96,可进行因子分析。

2) 公因子提取与旋转。在该环节中,先计算原数据集的相关矩阵。相关矩阵中的每个元素可由式(13)计算得到,即相关矩阵的第*i*行第*j*列元素为 r_{ij} 。同时得到该矩阵的特征值。这里将自动选择特征值下降最快的因子数作为最后的因子数,并输出碎石图,如图1所示。碎石图通过展示每个因子所解释的特征值百分比下降趋势,为确定应保留的因子数量提供依据。

由图1可知,当本文算例中的因子编号大于3时,特征值下降速度明显减缓,因此选择因子数为3。其他情况则需根据碎石图具体分析。

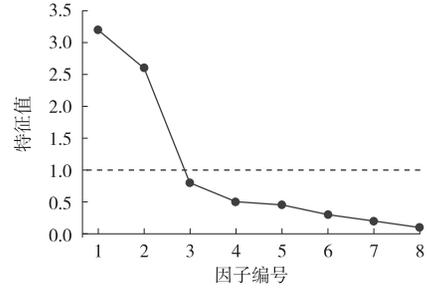


图1 因子提取碎石图

为使因子分析中求得的因子载荷矩阵结构更简化,便于从专业角度对主因子进行合理解释,通常需要对因子载荷矩阵进行变换,此过程又称为因子旋转。本文使用能够让方差最大的正交旋转法,即将旋转后的因子载荷阵中的每一列元素尽可能地拉开距离,即向-1或1两极分化,使每一个主因子只对应少数几个变量具有高载荷,其余载荷则都很小。将旋转后的因子载荷矩阵利用热力表(表1)进行表示。

表1 因子载荷热力表

特征	因子1载荷	因子2载荷	因子3载荷
百公里能耗	0.09	0.73	0.3
平均加速踏板深度	-0.16	0.32	0.8
加速踏板深度标准差	0.27	0.31	0.86
平均刹车踏板深度	1	-0.02	0.03
刹车踏板深度标准差	0.83	0.09	0.13
平均车速	-0.56	0.75	0.19
车速标准差	-0.01	0.69	0.22
刹车踏板使能比例	0.87	-0.17	-0.05

因子载荷热力表中,数值越接近1,正相关程度越大;数值越接近-1,负相关程度越大。由表1可知,共有3个新因子,新因子1主要与刹车踏板的平均深度、刹车踏板深度的标准差以及刹车踏板使能比例呈正相关关系。该因子数值越高,表明刹车踏板的踩踏深度越大且频率越高,可作为车辆减速行为的有效量化指标。新因子2主要与百公里能耗、平均车速以及车速标准差呈正相关关系。该因子数值越高,表明车辆行驶的车速越快且能耗越高,可作为车辆动力性能的量化指标。新因子3主要与加速踏板的平均深度及加速踏板深度的标准差呈正相关。该因子数值越高,表明车辆加速踏板的踩踏深度越大,可作为车辆

加速性能的量化指标。

2.3 基于改进K均值算法的聚类分析

本部分工作为:采用改进的K均值聚类算法对上文提取的3个核心指标进行聚类分析,得到不同车辆驾驶片段对应的驾驶风格。

K均值聚类是一种常用的无监督学习算法,常用于将数据集中的样本划分为若干组相似的数据点,使得同一组内的样本具有较高的相似性,每组相似的数据点称为一簇。每个簇的中心点,称为聚类中心,通常用该簇样本点的平均值表示。K均值聚类算法在开始时随机选择若干个数据点作为每个簇的中心点。K均值聚类算法的收敛速度与随机选取的初始中心密切相关。因为K均值聚类的收敛速度和最终结果依赖于初始中心的选择,随机选取的初始中心可能导致算法陷入局部最优,从而影响稳定性和收敛速度。因此,本文采用改进的K均值聚类方法,旨在优化初始中心的选择,从而提高聚类结果的稳定性和质量。

聚类分析主要包含随机中心选取、剩余质心计算、分配簇、更新质心以及迭代等内容。使用基于上述改进的K均值聚类分析,可将不同的驾驶风格从降维后的数据中高质量地识别出来。具体步骤如下:

1) 从数据集中随机选择一个数据点作为第一个簇中心。

2) 对于每个数据点,计算其到已选择的所有中心的最短距离 $D(x_i)$,其中第 i 个点 x_i 到第 j 个中心 μ_j 的距离可由式(16)计算, K 为数据点的维度。 x_{ik} 为第 i 个点第 k 个维度的数据值, μ_{jk} 为第 j 个点第 k 个维度的数据值。

$$D(x_i, \mu_j) = \sqrt{\sum_{k=1}^K (x_{ik} - \mu_{jk})^2} \quad (16)$$

3) 选择一个新的数据点作为下一个中心,选择的概率 P 与 $D(x_i)^2$ 成正比,概率可由式(17)计算。

$$P(x_i) = D(x_i)^2 / \sum_j D(x_i, \mu_j) \quad (17)$$

4) 重复上述两个步骤,直到选出 k 个中心为止。

5) 将数据集中的每个数据点分配到最近的中心所对应的簇。

6) 根据当前的簇分配,重新计算每个簇内所有点的均值作为新的簇中心。

7) 不断重复分配和更新步骤,直到簇中心不再发生变化(变化的百分比小于0.1%)或达到指定的最大迭代次数(通常为300次)。

改进的K均值算法的伪代码见表2。

表2 改进K均值算法的伪代码

算法	改进K均值聚类算法
1:	开始 改进K均值聚类(X, k)
2:	输入:数据集 $X = \{x_1, x_2, \dots, x_n\}$, 聚类数 k
3:	输出:聚类中心 y_1, y_2, \dots, y_k
4:	初始化:
5:	从数据集 X 中随机选择一个第一个中心点 y_1
6:	初始化中心点集合 $C, C = \{y_1\}$
7:	for $i = 2$ to k do
8:	根据式(16)计算每个数据点到最近中心点的距离
9:	根据式(17),计算每个中心点被选为下一个中心点的概率,并以此选择下一个中心点 y_i
10:	将 y_i 加入集合 C
11:	end for
12:	repeat:
13:	对每个数据点 x , 分配到最近的中心点 y_i 所在的簇
14:	更新每个簇的中心点 y_i 为簇内所有点的均值
15:	until 变化的百分比小于0.1%或达到最大迭代次数
16:	return 聚类中心 y_1, y_2, \dots, y_k
17:	结束算法

将2.2节所述的降维数据输入该改进算法进行聚类分析,聚类中心见表3,聚类结果如图2所示。为对比收敛速度,采用K均值聚类的方法对同样的数据进行处理,两个算法的收敛速度对比如图3所示。

表3 聚类中心

因子序号	簇1	簇2	簇3
因子1	-0.166 325 14	1.781 853 67	-0.782 646 5
因子2	-0.671 055 02	0.403 598 76	0.742 287 24
因子3	-0.304 203 36	0.220 454 96	0.314 944 06

由表1可知,所有驾驶片段被分为3个簇。第一个簇中,车辆减速指标与加速指标数值都较小,且均

为负数,而车辆动力指标负相关性很大,可看作平静型的驾驶风格,即驾驶车速较慢,且刹车与加速踏板深度较浅;第二个簇中,车辆的减速指标非常高,加速指标与动力指标较低,可看作保守型的驾驶风格,即在驾驶过程中会频繁急刹和重刹;第三个簇中,减速指标非常低,动力指标很高,可看作激进型的驾驶风格,即驾驶过程中的平均车速较高,且很少踩刹车。

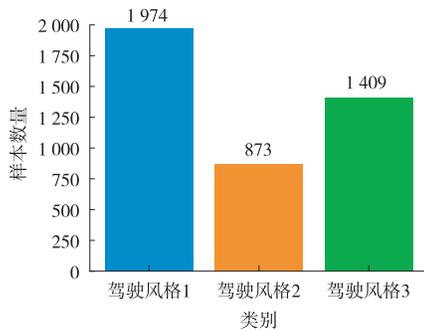


图2 聚类结果

从图2可以看出,所有驾驶片段被分为3类:驾驶风格1为平静型,驾驶风格2为保守型,驾驶风格3为激进型。其中平静型驾驶风格的数量最多,保守型驾驶风格的数量最少。

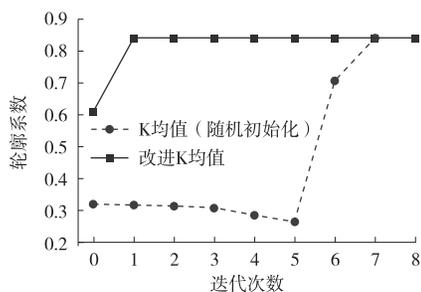


图3 K均值与改进K均值收敛速度对比图

两个算法的收敛速度对比图(图3)均使用了轮廓系数来对比算法的收敛程度。轮廓系数是一种用于评估聚类效果的指标,其取值范围为 $(-1, 1)$,越接近1,表示样本与其所在簇的相似度远高于其他簇,聚类效果越好。对于某一个点*i*,其对应的轮廓系数 $S(i)$ 可以由式(18)计算。

$$S(i) = [b(i) - a(i)] / \max \{a(i), b(i)\} \quad (18)$$

式中: $a(i)$ 为点*i*与其所在簇内其他点的平均距离; $b(i)$ 为点*i*与最近的其他簇中所有样本的平均距离。

由图3可知,改进K均值仅一次迭代就完成了算法的收敛,而随机初始化的K均值算法需要7次迭代

才能收敛,并达到与改进K均值算法一样的效果。

3 应用验证

第2章采集了纯电和混动轻卡的数据,包括市内低速、市间高速与跨省长途等多种工况。将这些数据输入本文提出的基于改进K均值聚类的驾驶风格识别算法后,该算法迅速完成了计算,并得出了识别结果。将识别结果与驾驶员的实际情况进行对比,算法所分类的驾驶风格与驾驶员的驾驶风格相似性很高,验证了本文所提出算法的有效性。

4 结论

本文提出的基于改进K均值聚类的驾驶风格识别算法,不仅能有效分辨不同驾驶员的驾驶风格,还能直观地解读与分析分类结果,为后续更加精细化的运营管理提供依据。

参考文献:

- [1] 覃文文, 鄢祺阳, 谷金晶, 等. 重载货车驾驶人驾驶风格识别与量化研究[J]. 交通运输系统工程与信息, 2022, 22(4): 137-148.
- [2] 赵登峰, 钟玉东, 刘朝辉, 等. 基于CNN电动城市客车进站驾驶风格识别研究[J]. 重庆交通大学学报(自然科学版), 2023, 42(12): 121-128.
- [3] 张金晶. 基于机器学习的驾驶员行为分析研究[D]. 上海: 上海电机学院, 2023.
- [4] 杨玉凤, 曲大义, 兰添贺, 等. 基于深度学习的驾驶倾向性分类及辨识方法[J]. 广西大学学报(自然科学版), 2024, 49(2): 324-335.
- [5] 梁科, 陈华晟, 潘明章, 等. 采用双向LSTM自编码器的驾驶风格谱聚类识别研究[J]. 重庆理工大学学报(自然科学), 2023, 37(10): 28-37.
- [6] 姚宏. 基于深度神经网络和迁移学习的激进驾驶行为识别[D]. 南京: 东南大学, 2023.
- [7] 黄江, 李雨涵, 吴盛斌, 等. 基于多元特征参数与改进SVM算法的驾驶风格识别研究[J]. 重庆理工大学学报(自然科学), 2022, 36(11): 8-19.
- [8] 贾硕. 面向智能网联的驾驶行为识别与预测预警方法研究[D]. 西安: 长安大学, 2022.

上能引导企业提升载货汽车安全性能,同时也引导消费者、货运企业选择更安全的车型,提升欧洲交通安全。Euro-NCAP 还发布了载货汽车技术路线图和 2030 远景规划,预计在 2030 年将碰撞保护正式纳入评价规程,届时规程将从安全驾驶、碰撞避免、碰撞保护、碰撞后安全四个维度评价载货汽车整体安全性能,并将借鉴乘用车已有的规程完善评价体系。在安全驾驶维度会更多关注驾驶员状态,更加细化驾驶员疲劳监测的评价维度,并增加驾驶员分心监测。碰撞避免维度会考虑增加低速前进、倒车场景,并完善载货汽车转向侵入其他道路使用者路线的场景。同时,增加碰撞保护维度,将从保护车外的弱势道路使用者和车内的驾乘人员两方面保护人员安全。因此,计划出口欧洲的载货汽车企业需要重点关注 Euro-NCAP 规程的实施规则(车辆选择、测试规程、评分方法)、测评结果和后续的技术路线图,从安全驾驶、碰撞避免、碰撞保护、碰撞后安全等维度提升整车安全性能。

参考文献:

- [1] Euro NCAP Timeline[EB/OL]. (2023-04-12)[2025-03-17]. <https://www.euroncap.com/en/about-euro-ncap/timeline/>.
- [2] 胡林,谷子逸,王丹琦,等.汽车安全性测评规程现状及趋势展望[J].汽车工程,2024,46(2):187-200.
- [3] C-NCAP 管理中心. C-NCAP 管理规则(2021版)[S].天津:中国汽车技术研究中心,2020.
- [4] Euro NCAP Safe Trucks[EB/OL]. (2024-05-01)[2025-03-17]. <https://www.euroncap.com/en/truck-van-safety/safer-trucks/>.
- [5] the Economic Commission for Europe of the United Nations. Uniform provisions concerning the approval of: I. Safety-belts, restraint systems, child restraint systems and ISOFIX child restraint systems for occupants of power-driven vehicles II. Vehicles equipped with safety-belts, safety-belt reminder, restraint systems, child restraint systems, ISOFIX child restraint systems and i-Size child restraint systems; UN Regulation No 16 [S/OL]. (2024-07-29)[2024-10-25]. <https://unece.org/sites/default/files/2024-10/R016r10am6e.pdf/>.
- [6] The specific test procedures and technical requirements for the type-approval of motor vehicles with regard to their driver drowsiness and attention warning systems; EU 2021/1341 [S/OL]. [2025-03-17]. https://eur-lex.europa.eu/eli/reg_del/2021/1341/oj/eng.
- [7] 陈泾渭.基于盲区实验的重型商用车驾驶室内饰优化设计[D].长春:吉林大学,2019.
- [8] Uniform provisions concerning the approval of motor vehicles with regard to their direct vision; UN Regulation No 167 [S/OL]. [2024-05-17]. https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=OJ:L_202401065.
- [9] Euro NCAP Safe Trucks for engineers[EB/OL]. (2024-11-01)[2025-03-17]. <https://www.euroncap.com/en/truck-van-safety/for-engineers/protocols/>.
- [10] the International Organization for Standardization. Road vehicles — Information for first and second responders [S]. 2nd ed. Geneva; ISO, 2022: 1-15.
- [11] Euro NCAP Safe Trucks commercial-truck-ratings [EB/OL]. (2024-11-20)[2025-03-17]. <https://www.euroncap.com/en/truck-van-safety/safer-trucks/commercial-truck-ratings/>.
- [9] 张维轩.基于半监督学习的多工况驾驶风格识别方法[D].长春:吉林大学,2021.
- [10] 吕明,张滢,冯先泽.基于SOM神经网络的多工况驾驶风格识别[J].汽车实用技术,2021,46(2):108-112.
- [11] 秦大同,陈沫机,曹宇航,等.基于驾驶事件的驾驶风格分类与识别方法研究[J].中国机械工程,2024,35(9):1534-1541.
- [12] 孙晓鹏,赵朕,李冬瑞,等.基于K-Means算法的驾驶风格辨识方法研究[J].机械工程与自动化,2023(2):35-37.

(上接第6页)