

# 基于因子长短期记忆的驾驶人接管行为及意图识别

姚荣涵<sup>1</sup>, 徐文韬<sup>1</sup>, 郭伟伟<sup>2</sup>

(1. 大连理工大学 交通运输学院, 辽宁 大连 116024; 2. 北方工业大学 城市道路交通智能控制技术北京市重点实验室, 北京 100144)

**摘要:**为识别自动驾驶环境下驾驶人的接管行为及意图,面向18.95 km双向六车道高速公路场景,借助驾驶模拟器和眼动仪,实施驾驶人10次面对5种紧急情境之一接管自动驾驶车辆的模拟试验。利用所得车辆运行和视觉注意力数据,根据因子分析提取得到3个公因子,采用K-means聚类分析定性识别驾驶人接管行为及意图。将因子分析分别与支持向量机和长短期记忆神经网络进行结合,获得两个定量识别驾驶人接管行为及意图的模型。研究表明,驾驶人接管行为受其纵向反应、横向反应和视觉注意力影响;聚类分析可定性描述不同类型驾驶人的接管行为及意图,并揭示潜在的驾驶安全隐患;相比支持向量机、长短期记忆神经网络和因子支持向量机模型,因子长短期记忆模型能更有效地识别驾驶人接管意图,其精确率、召回率、 $F_1$ 分数和准确率4项性能指标均最优;利用因子分析进行数据降维和有效信息浓缩所得公因子有助于提高驾驶接管意图识别模型的分类型性能。本研究有助于识别出接管风险较高的驾驶人,进而设计有针对性的驾驶辅助策略。

**关键词:**交通运输系统工程;驾驶人接管行为及意图;因子分析;K-means聚类分析;长短期记忆神经网络

**中图分类号:**U491.2 **文献标志码:**A **文章编号:**1671-5497(2023)03-0758-14

**DOI:**10.13229/j.cnki.jdxbgxb20210919

## Drivers' takeover behavior and intention recognition based on factor and long short-term memory

YAO Rong-han<sup>1</sup>, XU Wen-tao<sup>1</sup>, GUO Wei-wei<sup>2</sup>

(1. School of Transportation and Logistics, Dalian University of Technology, Dalian 116024, China; 2. Beijing Key Laboratory of Urban Intelligent Traffic Control Technology, North China University of Technology, Beijing 100144, China)

**Abstract:** To identify drivers' takeover behavior and intention in an autonomous driving environment, with the help of a driving simulator and an eye-tracking device, the simulation tests were conducted to let drivers takeover an autonomous vehicle ten times in five emergency situations on a two-way six-lane

**收稿日期:**2021-09-14.

**基金项目:**国家自然科学基金项目(52172314);教育部2020年第一批产学合作协同育人项目(202002035013);中央高校基本科研业务费专项资金项目(DUT20JC40).

**作者简介:**姚荣涵(1979-),女,副教授,博士生导师.研究方向:间断交通流理论. E-mail:cyanyrh@dlut.edu.cn

freeway of 18.95 km. Using the vehicle operation and visual attention data, the three common factors were extracted by the factor analysis, and the  $K$ -means clustering analysis was used to qualitatively identify the drivers' takeover behavior and intention. The factor analysis was respectively combined with the support vector machine and the long short-term memory neural network, then the two models were obtained to quantitatively identify drivers' takeover behavior and intention. Research results show that: drivers' takeover behavior is influenced by their longitudinal response, lateral response and visual attention; the clustering analysis can qualitatively describe the takeover behavior and intention of different types of drivers and reveal the potential driving safety risks; compared with the support vector machine, the long short-term memory neural network and the factor and support vector machine model, the factor and long short-term memory model is more effective in identifying drivers' takeover intention, with the best four performance indices of accuracy rate, recall rate,  $F_1$ -score and precision rate; and the common factors which are obtained using the factor analysis for data downscaling and effective information enrichment are helpful to improve the classification performance of the driving takeover intention recognition model. This study is helpful to identify drivers who are at a higher risk of takeover and to design some targeted driving assistance strategies.

**Key words:** engineering of communications and transportation system; drivers' takeover behavior and intention; factor analysis;  $K$ -means clustering analysis; long short-term memory neural network

## 0 引言

作为交通领域近年来的研究热点之一,自动驾驶车辆在提高驾驶安全性、促进车辆节能减排和提升交通网络性能方面远胜于手动驾驶车辆<sup>[1]</sup>。美国汽车工程师学会<sup>[2]</sup>将自动驾驶车辆分为6个等级。有条件自动驾驶是指自动驾驶系统可在特定的驾驶操作设计域(Operational design domain, ODD)执行全部动态驾驶任务,驾驶人无需始终监控前方道路情况。ODD包括但不限于路况、区域、时间、时速和车道等,其限制条件越多,自动驾驶功能的普适性越差<sup>[3]</sup>。当车辆所处情况超出ODD时,驾驶人必须及时地人为控制车辆,此时人机交互称为驾驶人接管。

对于有条件自动驾驶,驾驶人接管过程是否顺利关乎自动驾驶车辆能否安全行驶。2016年,美国佛罗里达州发生一起以自动驾驶运行的特斯拉Model S引发的致命事故,其原因被认定为驾驶人失误(Driver error)<sup>[4]</sup>。Lu等<sup>[5]</sup>通过试验模拟驾驶人接管L3级自动驾驶车辆的过程,发现驾驶人注意力转换和情境意识重构对其顺利接管自动驾驶车辆极为重要。当自动驾驶车辆处于ODD所设驾驶情境时,驾驶人会将注意力集中于非驾驶任务,直到预警系统发出接管请求。当接收到接管请求后,驾驶人必须立刻将注意力转移至手动驾驶任务。Endsley<sup>[6]</sup>定义情境意识为操作员

感知、理解其周围环境以及预测周围环境的近期状态。情境意识丧失意味着驾驶人脱离周围环境和驾驶任务,这将导致危险事件发生。如遇紧急情况,驾驶人需要采取避险措施,由于情境意识丧失和恢复,自动驾驶车辆驾驶人明显比手动车辆驾驶人反应慢。

有学者探讨了L3级自动驾驶恢复到手动驾驶之前,驾驶人为完全显现潜在危险而重构情境意识所需时间,即接管请求提前量。Samuel等<sup>[7]</sup>发现,接管请求提前量至少为8 s时,新手驾驶人的视线才能聚焦于潜在危险的方位,即驾驶人完成注意力转换。Wright等<sup>[8]</sup>将新手驾驶人替换为有经验的驾驶人后重复了Samuel等的研究,结果发现,有经验的驾驶人至少需要6 s才能完全重构情境意识。Vlakveld等<sup>[9]</sup>研究发现,在接管请求提前量小于6 s的情况下,驾驶人发现的道路危险较少,这意味着驾驶人需要至少6 s的接管请求提前量,以便使车祸风险降至最低。

影响自动驾驶接管的因素众多,结合驾驶人注意力转换和情境意识重构,将自动驾驶接管的影响因素分为接管请求方式、非驾驶任务、驾驶情境和驾驶人的社会经济属性4类:①对于L3级自动驾驶,Petermeijer等<sup>[10]</sup>通过模拟试验发现,当预警系统发出接管请求,以此唤醒驾驶人的情境意识,由于视觉资源被非驾驶任务占用,预警系统向

驾驶人发出的视觉刺激难以发挥作用。Forster 等<sup>[11]</sup>认为,相比视觉刺激,听觉刺激能更好地向驾驶人传达预警信息,且在通用警告音的基础上加入人的声音会更有利于接管。②L3级自动驾驶因非驾驶任务使得驾驶人处于分心状态而缺乏情境意识,进而可能导致接管失败。Radlmayr 等<sup>[12]</sup>应用标准化的如  $n$ -back 的非驾驶任务,对驾驶人施加认知或视觉干扰。Yoon 等<sup>[13]</sup>发现视觉注意力是影响接管质量的最重要因素之一,非驾驶任务所需的高水平视觉注意力影响参与者及时将视觉注意力转移到手动驾驶。③驾驶情境涉及自动驾驶所处道路、环境等影响驾驶人重构情境意识的因素。Gold 等<sup>[14]</sup>发现高交通密度会使接管质量降低,主要表现为碰撞时间短、碰撞次数多。Roche 等<sup>[15]</sup>发现随着接管难度增加(如车头时距减小),驾驶人为避免碰撞而产生换道行为,从而使安全隐患增加。④驾驶人的社会经济属性包括年龄、信任等。Clark 等<sup>[16]</sup>的研究表明,就更长的接管响应时间而言,年老驾驶人比年轻驾驶人更受益。Epple 等<sup>[17]</sup>发现,当驾驶人遭遇一次自动驾驶故障后,在下次自动驾驶过程中主动发起接管的频率高达 85%。驾驶人的其他社会经济属性(如酒精<sup>[18]</sup>和疲劳<sup>[19]</sup>)也会影响其接管行为。

针对手动驾驶车辆,王海星等<sup>[20]</sup>从货运数据中提取 8 个驾驶行为指标,使用因子分析确定了 3 个潜在变量,并利用模糊 C 均值聚类分析描述了危险货运驾驶行为特征。Zhou 等<sup>[21]</sup>使用主成分分析和具有噪声的基于密度的聚类方法(Density-based spatial clustering of applications with noise, DBSCAN)密度聚类识别不同类型的卡车驾驶人,得到其驾驶行为倾向。孙剑等<sup>[22]</sup>利用长短期记忆(Long short-term memory, LSTM)神经网络分类识别分心驾驶意图,与支持向量机(Support vector machine, SVM)和 Adaboost 模型相比,LSTM 神经网络更有利于准确地识别驾驶意图。Jia 等<sup>[23]</sup>提出了一种基于 LSTM 神经网络和卷积神经网络(Conventional neural network, CNN)的异常驾驶行为识别模型。张姝玮等<sup>[24]</sup>借助驾驶模拟器模拟驾驶疲劳环境,进而分析了驾驶行为多重分形特征对 SVM 驾驶疲劳检测模型的提升作用。这些研究并未涉及自动驾驶车辆和驾驶人接管行为,但所用方法可为驾驶人接管行为研究提供借鉴。

综上,已有文献针对驾驶人接管自动驾驶车辆探究了注意力转换和情境意识重构及其影响因素,针对手动驾驶车辆识别了分心、异常和危险货运等驾驶行为及意图,但较少研究接管过程中驾驶人的驾驶意图,且忽视了不同类型的接管行为导致的驾驶行为差异。为全面解析驾驶人接管自动驾驶车辆时与车、路、环境、信息之间的交互作用,有必要识别驾驶人接管行为及意图。考虑不同接管情境和不同集中程度的视觉注意力,本文解析了驾驶人接管自动驾驶车辆时的情境意识重构,构建了驾驶人接管行为及意图识别模型。

## 1 自动驾驶接管试验

### 1.1 试验设备及参与者

使用 Up-Coming 公司的驾驶模拟器(含驾驶人座椅、方向盘和脚踏板)及配套的 UC-win/Road 10.1 模拟软件(见图 1(a)),通过 3 块液晶显示屏获取 140° 视野及左、右、后视镜所见驾驶情境,同时记录车辆速度、加速度、方向盘转角、车灯状态等车辆运行数据。另外,使用 Tobii Pro



(a) 驾驶模拟器



(b) 眼动仪

图 1 接管试验所采用的设备

Fig. 1 Equipment used for takeover tests

Glasser 2 眼动仪(见图 1(b)),记录了试验参与者的眼部观测位置、左右瞳孔直径、凝视行为等视觉注意力数据,凝视行为是指驾驶人视线落在道路上的时间百分比。

此项试验的参与者有 10 名男性和 1 名女性,其年龄为 22~26 岁,年龄均值为 23.55 岁、标准差为 1.08 岁。所有试验参与者均持有有效驾驶证,其驾龄均值为 3.14 年、标准差为 0.91 年,并且其视力正常或矫正至正常。

### 1.2 试验描述

试验场景设为一条总长为 18.95 km 的双向 6 车道高速公路,每条车道的宽度均为 3.75 m,最外侧车道为自动驾驶车道,设定稳定状态下自动驾驶车辆的平均速度为 60 km/h。该值既符合中国高速公路规定的同方向 3 条车道时,最右侧车道最低限速为 60 km/h,又考虑到自动驾驶技术尚未完全成熟时,平均速度为 60 km/h 可使驾驶人在高速公路上遇到紧急情况能及时接管自动驾驶车辆。

在试验过程中,车辆处于自动驾驶模式时以 60 km/h 的速度行驶;当车辆遇到紧急接管情境时,预警系统发出警告音,同时显示屏左上角显示“请求接管!”的红底黄字字样,并且根据 Wright 等<sup>[8]</sup>和 Vlakveld 等<sup>[9]</sup>的研究将接管请求提前量设

为 6 s;当参与者通过手动驾驶完成接管操作后回到自动驾驶车道,并按下自动驾驶按钮时,显示屏上出现“自动驾驶”的红底黄字字样,此时车辆恢复到自动驾驶模式。

在自动驾驶过程中,所有试验参与者均可自由选择非驾驶任务(如使用手机、与他人交谈等),也可抬头观察道路情况,手可以自然地放在身体两侧或双腿上。

### 1.3 接管事件

本试验在双向 6 车道高速公路上设计如下 5 类紧急接管情境:①情境 1,前方车辆遇停车标志紧急制动,自动驾驶车辆需要超车;②情境 2,前方道路正在施工,自动驾驶车辆需要绕行;③情境 3,显示屏上显示计算题(如“35+28”),而前方车辆发生故障,自动驾驶车辆需要超车;④情境 4,前方有低速车辆换道至自动驾驶车道,自动驾驶车辆需避让并超车;⑤情境 5,系统提示前方限速 40 km/h,自动驾驶车辆需要制动。其中,情境 2、3 和 5 为静态障碍接管情境,情境 1 和 4 为动态障碍接管情境。每位试验参与者经历 10 次接管事件,每次接管事件出现的位置及对应的紧急情境如图 2 所示。其中,2 个动态障碍接管情境共出现 6 次。因此,本试验的主要接管情境为动态障碍接管情境。

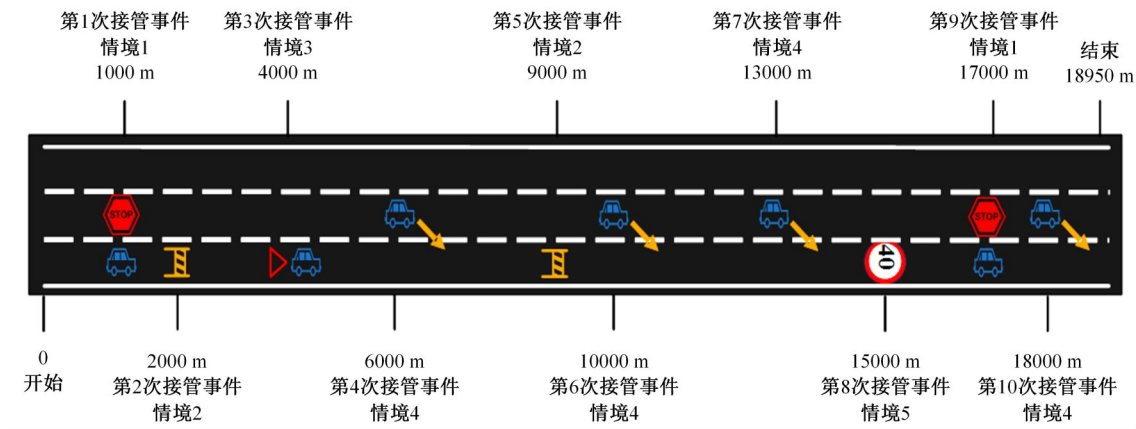


图 2 接管事件出现的位置及对应的紧急情境

Fig. 2 Emergent locations and corresponding emergency situations for takeover incidents

在预警系统请求接管车辆之前,自动驾驶车辆行驶在最右侧车道上,同时该车道上没有其他车辆。试验参与者在接收到接管请求后通过变换车道躲避最右侧车道上出现的障碍,避让操作完成后换道至最右侧车道。

### 1.4 试验步骤

首先,工作人员向参与者简要介绍本试验,参与者签署知情同意书,并填写性别、年龄、驾龄等个人信息。随后,工作人员向参与者介绍试验流程和设备操作方法,并让参与者进行模拟驾驶练

习,以便熟悉驾驶模拟器。

当参与者熟悉试验流程和设备操作后,参与者进行正式试验。在试验开始时,模拟车辆处于自动驾驶模式,同时参与者进行非驾驶任务直至系统发出接管命令,而后参与者接管车辆并手动驾驶直到车辆再次稳定地行驶在自动驾驶车道上,自动驾驶模式重新被激活。

1.5 试验结果

由于个别参与者在部分试验中未能正常佩戴眼动仪而导致视觉注意力数据丢失,因此剔除存在缺失的相关数据,包括第 5 位参与者的 10 次接管事件和第 8 位参与者的第 7 次接管事件的相关数据。最后,得到 10 位参与者共 99 次接管事件的试验数据。表 1 列出 11 位参与者接管自动驾驶车辆的试验结果,本次试验共发生 17 次不良接管行为,占总接管次数的 17.17%。这里不良接管行为(即接管质量差),具体指的是出现与前方/故障车辆发生碰撞、刹停、遇限速标志而没减速和转角过大导致车体倾斜等明显交通事故。如果不是接管质量差,则认为接管质量好,即接管成功。

模拟试验中接管过程从接管警告音发出开始,经历参与者按下自动驾驶按钮,直到自动驾驶

表 1 参与者接管自动驾驶车辆的试验结果

Table 1 Experimental results of participants taking over an autonomous vehicle

参与者	模拟试验	正式试验
1	接管质量好	出现事件 6 和 10 时,自动驾驶车辆与前方车辆碰撞
2	没及时接管	出现事件 6 和 10 时,自动驾驶车辆转角过大
3	接管质量好	接管质量好
4	接管质量好	出现事件 3 和 6 时,自动驾驶车辆分别与故障车辆和前方车辆发生碰撞
6	接管质量好	出现事件 3 时,自动驾驶车辆转角过大
7	接管质量好	接管质量好
8	车辆转角过小	接管质量好
9	接管质量好	出现事件 1 和 3 时,自动驾驶车辆转角过大
10	接管质量好	出现事件 3 时,自动驾驶车辆转角过大;出现事件 8 时,自动驾驶车辆遇限速标志而没减速
11	接管质量差	出现事件 2 时,自动驾驶车辆转角过大;出现事件 3 时,自动驾驶车辆与故障车辆发生碰撞;出现事件 4、5 和 6 时,自动驾驶车辆刹停;出现事件 8 时,自动驾驶车辆遇限速标志而没减速

车辆转速保持 2 s 不变结束。图 3 为第 7 位参与者面对第 1 次接管事件时接管行为参数随行驶距离的变化。由图 3(a)~(c)可见,在 1000~1200 m 内发生接管行为,此时车辆紧急制动,加速度急剧




图 3 第 7 位参与者面对第 1 次接管事件时接管行为参数随行驶距离的变化

Fig. 3 Variations of takeover behavior parameters with driving distance when participant 7 dealing with first takeover event

降低,其速度随之降至10 km/h;由图3(d)(e)可见,发生接管行为时,车辆横摆角随转向盘转动而发生变化;由图3(f)(g)可见,当发生接管行为时,在1100~1200 m内,驾驶人左右眼瞳孔直径显著增大且频繁眼跳。因此,视觉注意力数据选用左眼瞳孔直径标准差、右眼瞳孔直径标准差和凝视行为;车辆运行数据选用速度标准差、最大速度差、平均速度、最大纵向加速度、最大横摆角和横摆角标准差。表2为自动驾驶接管行为分析选用的所有因变量,视觉注意力数据和车辆运行数据均为描述整个接管过程的统计量。

表2 接管行为分析所选因变量

Table 2 Dependent variables selected for takeover behavior analysis

	因变量	定义
视觉注意	左眼瞳孔直径标准差/mm	左眼瞳孔直径的离散程度
	右眼瞳孔直径标准差/mm	右眼瞳孔直径的离散程度
力数据	凝视行为/%	视线落在道路上的时间百分比
	速度标准差/(km·h <sup>-1</sup> )	车辆速度的离散程度
车辆运行数据	最大速度差/(km·h <sup>-1</sup> )	车辆速度的变化幅度
	平均速度/(km·h <sup>-1</sup> )	车辆速度的平均快慢程度
	最大纵向加速度/(m·s <sup>-2</sup> )	接管过程中车辆最大制动加速度
	最大横摆角/rad	车辆横摆角的变化幅度
	横摆角标准差/rad	车辆横摆角的离散程度

## 2 因子分析

因子分析(Factor analysis, FA)可从许多变量中提取隐藏的具有代表性的因子,被认为是获得潜在变量的经典分析方法<sup>[25]</sup>。这里使用探索性因子分析,提取因子时采用主成分分析法。

### 2.1 可行性验证

使用因子分析寻找变量间内在的关联结构并提取因子之前,利用巴特利特球形检验和KMO(Kaiser-Meyer-Olkin)检验进行可行性验证<sup>[26]</sup>。巴特利特球形检验考察相关矩阵是否为单位矩阵,若为单位矩阵,则不能使用因子分析。KMO检验考察各变量是否偏相关,是一种更好的关联性考察依据。所选样本数据的检验结果如表3所示,巴特利特球形检验结果的显著性水平为0.000,拒绝各变量独立的假设,即各变量具有较强的相关性;KMO值为0.672(>0.6),说明各变量之间的偏相关性较强,原始数据存在一定程度的信息重叠,有可能得到结果较好的因子分析模型。

表3 巴特利特球形检验和KMO检验

Table 3 Bartlett's spherical test and KMO test

检验指标	结果	
近似卡方	875.790	
巴特利特球形检验	自由度	36
	显著性	0.000
KMO取样适切性量数	0.672	

### 2.2 公因子提取

原始数据涉及很多变量,有必要进行降维处理。表4展示了因子分析所得的总方差解释,包含方差百分比和累积百分比。前3个公因子的特征值均大于1,且累积方差百分比为82.206%,可见因子分析效果较为理想,所提取的前3个成分为公因子。

表4 因子分析所得总方差解释

Table 4 Total variance explained by factor analysis

成分	特征值	方差百分比/%	累积方差百分比/%
1	3.698	41.086	41.086
2	2.395	26.608	67.694
3	1.306	14.512	82.206
4	0.657	7.296	89.502
5	0.442	4.913	94.415
6	0.304	3.377	97.792
7	0.102	1.133	98.925
8	0.087	0.962	99.887
9	0.010	0.113	100.000

表5为因子载荷矩阵,显示了3个公因子在各原始变量上的载荷,由此可得下述关于公因子含义的结论:①公因子1与速度标准差、最大加速度和最大纵向加速度的正相关性较强,与平均速度的负相关性较强,但与横摆角标准差的负相关性弱。②公因子2与左眼瞳孔直径标准差、右眼瞳孔直径标准差和最大横摆角的正相关性较强,但与横摆角标准差和凝视行为存在一定的相关性。③公因子3与最大横摆角、横摆角标准差和凝视行为的正相关性较强。

### 2.3 因子旋转

表5所示因子载荷矩阵显示的公因子的意义并不是很清晰,由于因子载荷矩阵不是唯一的,因此采用凯撒正态化最大方差法进行因子旋转<sup>[27]</sup>。经过旋转后的因子载荷的绝对值向0和1进行两级分化,即和每个因子相关的载荷值的方差最大化,从而使因子载荷值更显著。

表6为旋转后的因子载荷矩阵。由此可知,

表 5 因子分析所得因子载荷矩阵

Table 5 Component matrix obtained by factor analysis

原始指标	因子载荷值		
	公因子 1	公因子 2	公因子 3
速度标准差/(km·h <sup>-1</sup> )	0.967	0.043	0.155
最大速度差/(km·h <sup>-1</sup> )	0.955	0.097	0.200
平均速度/(km·h <sup>-1</sup> )	-0.890	0.048	-0.082
最大纵向加速度/(m·s <sup>-2</sup> )	0.792	0.008	0.277
左眼瞳孔直径标准差/mm	0.225	0.793	-0.288
最大横摆角/rad	-0.321	0.747	0.520
右眼瞳孔直径标准差/mm	0.287	0.719	-0.363
横摆角标准差/rad	-0.436	0.647	0.576
凝视行为/%	-0.077	-0.508	0.584

公因子 1 与车辆纵向运动具有强相关性,将其定义为驾驶人接管行为的纵向反应指标;公因子 2 与眼部运动行为具有强相关性,将其定义为驾驶人接管行为的视觉注意力指标;公因子 3 与车辆横向运动具有强相关性,将其定义为驾驶人接管行为的横向反应指标。

表 6 旋转后的因子载荷矩阵

Table 6 Rotated component matrix

原始指标	因子载荷值		
	公因子 1	公因子 2	公因子 3
最大速度差/(km·h <sup>-1</sup> )	0.971	0.122	-0.059
速度标准差/(km·h <sup>-1</sup> )	0.965	0.112	-0.128
平均速度/(km·h <sup>-1</sup> )	-0.864	-0.076	0.218
最大纵向加速度/(m·s <sup>-2</sup> )	0.838	-0.023	-0.018
右眼瞳孔直径标准差/mm	0.184	0.823	0.138
左眼瞳孔直径标准差/mm	0.154	0.821	0.257
凝视行为/%	0.096	-0.766	0.098
横摆角标准差/rad	-0.194	0.043	0.950
最大横摆角/rad	-0.100	0.175	0.944

利用旋转后的因子矩阵,建立公因子和原始指标之间的线性回归方程,即:

$$F_j = b_{j_0} + b_{j_1}x_1 + b_{j_2}x_2 + b_{j_3}x_3 + \dots + b_{j_p}x_p + \dots + b_{j_P}x_P, \quad (1)$$

$$j = 1, 2, \dots, J$$

式中: $F_j$ 为第  $j$  个公因子; $b_{j_0}$ 为第  $j$  个公因子涉及的常数项; $b_{j_p}$ 为第  $p$  个原始指标对第  $j$  个公因子的得分系数; $x_p$ 为第  $p$  个原始指标; $P$ 为原始指标数; $J$ 为公因子数。

利用 SPSS 26.0 软件,选用最小二乘法估计式(1)中的常数项和因子得分系数,所得因子得分系数矩阵如表 7 所示,以此为基础进行后续研究。

表 7 因子得分系数矩阵

Table 7 Factor score coefficient matrix

原始指标	因子得分系数		
	公因子 1	公因子 2	公因子 3
左眼瞳孔直径标准差/mm	0.000	0.400	0.046
右眼瞳孔直径标准差/mm	-0.004	0.416	-0.019
凝视行为/%	0.117	-0.446	0.181
平均速度/(km·h <sup>-1</sup> )	-0.247	0.010	0.035
速度标准差/(km·h <sup>-1</sup> )	0.286	-0.013	0.024
最大速度差/(km·h <sup>-1</sup> )	0.296	-0.019	0.063
最大纵向加速度/(m·s <sup>-2</sup> )	0.272	-0.092	0.092
横摆角标准差/rad	0.045	-0.097	0.520
最大横摆角/rad	0.062	-0.033	0.509

### 3 接管时驾驶行为分析

#### 3.1 K-means 聚类算法

K-means 算法是一种鲁棒性强、快速简单、被广泛利用的无监督、迭代型聚类算法,通过启发式迭代逐一更新每个聚类中心的值,直到获得最佳聚类结果,即前后两轮的聚类中心相同<sup>[28,29]</sup>。

K-means 算法更新聚类簇均值时,针对簇  $C = \{C_1, C_2, C_3, \dots, C_k\}$  得到的最小化平方误差  $E$  为:

$$\begin{cases} E = \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|_2^2 \\ \mu_i = \frac{1}{|C_i|} \sum_{x \in C_i} x \end{cases} \quad (2)$$

式中: $x$ 为给定的样本集  $x = \{x_1, x_2, \dots, x_m\}$ ;  $m$  为样本数; $\mu_i$ 为簇  $C_i$  的均值; $C_i$ 为第  $i$  个簇的聚类中心; $k$ 为聚类簇数。

鉴于 K-means 算法具有优秀的聚类效果<sup>[28,29]</sup>,具体分析驾驶接管行为时,本文选用 K-means 聚类。

#### 3.2 聚类结果分析

使用 K-means 算法对驾驶人接管自动驾驶车辆时的驾驶行为进行聚类分析,设置  $K$  为 3、最大迭代次数为 50,当收敛判别标准小于 0.01 时完成聚类。利用 SPSS 26.0 软件的聚类轮廓插件优化聚类结果,轮廓取值范围为  $[-1, 1]$ ,若轮廓值大于 0,则表明聚类效果较好,该值越接近 1,说明聚类效果越好。根据因子分析得到的 3 个公因子,将自动驾驶接管时以接管强度衡量的驾驶行为评为强、一般和弱 3 类。图 4 为分别以 3 个公因子为聚类指标得到的聚类结果。

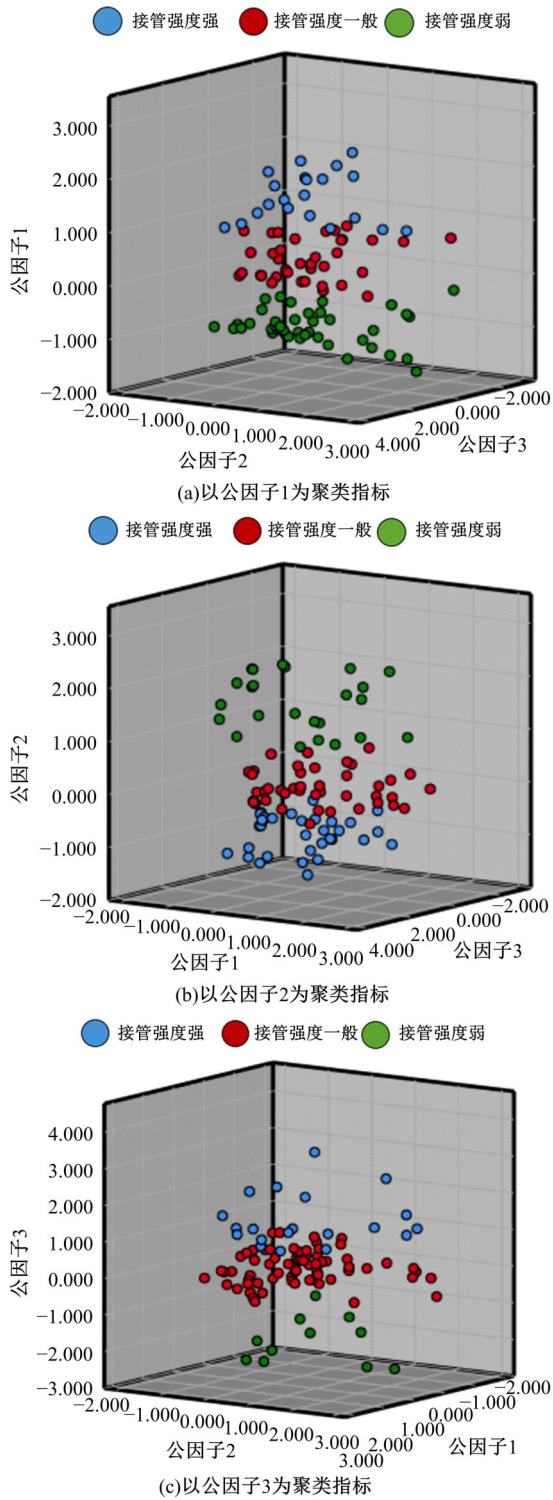


图 4 K-means 聚类结果

Fig. 4 K-means clustering results

表 8 给出了以驾驶人接管纵向反应为指标的聚类结果,各类别的轮廓平均值都大于 0,且最小值也大于 0,因此该聚类效果较好。根据接管试验的真实情况,试验编号为 6、33、36 和 92 时参与者在接管过程中撞上前方车辆或障碍车辆,其接管强度为弱;试验编号为 10 时参与者在接管过程

中撞上前方车辆,其接管强度为一般;试验编号为 93、94 和 95 时参与者在接管过程中刹停,其接管强度为强。结合聚类分析和试验情况,发现驾驶人的接管纵向反应影响其在接管过程中采取的措施,一定程度上可揭示驾驶风险。通过该项指标的聚类分析能解释面对不同接管情境时,不同接管纵向反应类型的驾驶人在接管过程中是否存在刹停或发生碰撞的可能性。

表 9 给出了以驾驶人接管横向反应为指标的聚类结果。结合接管试验的真实情况,试验编号为 16、20、43、72、82 和 70、91 时参与者在接管过程中使车辆转角过大,其接管强度分别为强和一般。由此可知,接管横向反应也能揭示驾驶风险,通过该项指标的聚类分析可识别面对不同接管情境时,不同接管横向反应类型的驾驶人在接管过程中是否存在使车辆转角过大的驾驶风险。

结合表 8 和表 9,综合考虑驾驶人的接管纵向和横向反应。试验编号为 93、94 和 95 时,参与者采取刹停措施,其接管纵向反应为强、接管横向反应为一般;试验编号为 6、33 和 36、92 时参与者在接管过程中发生碰撞,其接管纵向反应为弱、接管横向反应分别为强和一般;试验编号为 43、82 和 70、91 时参与者使车辆转角过大,其接管横向反应分别为强和一般、接管纵向反应为弱。由此可见,同一接管情境下,驾驶人的接管能力在横向和纵向两个维度上有所侧重,往往难以兼顾两者,这与实际驾驶经验相一致。

表 10 列出了以驾驶人接管视觉注意力为指标的聚类结果。根据接管试验的真实情况,试验编号为 87 和 97 时参与者在接管过程中经过限速标志路段时没有降速,其接管强度分别为弱和一般。

综合表 8~表 10 可知,实际试验中发生的不良接管行为有与前方或故障车辆发生碰撞、车辆刹停、车辆转角过大和遇限速标志时没有降速,试验编号为 6、10、33、36、43、82、87、92、94 和 95 时参与者在接管视觉注意力方面的接管强度为弱,占有该项聚类结果为弱的 41.67%,同时也占有不良接管行为的 58.82%。这表明,接管过程中视觉注意力影响驾驶人接管质量,这与驾驶情境意识重构密不可分,若视觉注意力无法长时间保持在道路上,将更容易导致事故发生,这与现实认知相符。

表 8 以驾驶人接管纵向反应为聚类指标的聚类结果及其轮廓值

Table 8 Clustering results and profile values when using drivers' takeover longitudinal response as a clustering indicator

类别	样本量	试验编号	接管强度	轮廓值		
				平均值	最小值	最大值
1	21	7,8,16,46,51,53,56,57,58,59,60,75,81,85,86,88,93,94,95,96,98	强	0.580	0.123	0.723
2	37	1,4,9,10,17,20,26,27,28,29,31,34,38,45,47,49,50,52,54,55,61,64,67,69,71,72,73,74,76,77,78,79,83,84,89,97,99	一般	0.507	0.065	0.735
3	41	2,3,5,6,11,12,13,14,15,18,19,21,22,23,24,25,30,32,33,35,36,37,39,40,41,42,43,44,48,62,63,65,66,68,70,80,82,87,90,91,92	弱	0.711	0.062	0.829

表 9 以驾驶人接管横向反应为聚类指标的聚类结果及其轮廓值

Table 9 Clustering results and profile values when using drivers' takeover lateral response as a clustering indicator

类别	样本量	试验编号	接管强度	轮廓值		
				平均值	最小值	最大值
1	20	2,3,5,6,16,17,20,33,42,43,47,52,53,55,72,75,81,82,88,99	强	0.482	0.082	0.620
2	68	1,4,7,8,9,10,11,12,13,14,15,19,21,22,23,24,25,26,27,29,30,31,32,34,35,36,37,40,41,44,45,46,49,51,54,56,57,59,60,61,62,63,64,65,66,68,69,70,71,73,74,76,78,79,80,83,84,85,86,89,90,91,92,93,94,95,96,98	一般	0.596	0.025	0.773
3	11	18,28,38,39,48,50,58,67,77,87,97	弱	0.621	0.045	0.789

表 10 以驾驶人接管视觉注意力为聚类指标的聚类结果及其轮廓值

Table 10 Clustering results and profile values when using drivers' takeover visual attention as a clustering indicator

类别	样本量	试验编号	接管强度	轮廓值		
				平均值	最小值	最大值
1	33	3,5,8,9,13,14,15,19,25,29,30,31,34,42,48,60,61,62,63,64,65,66,67,68,69,72,73,74,75,76,81,93,99	强	0.588	0.207	0.705
2	42	1,11,12,16,17,20,21,22,23,24,26,27,28,32,35,39,40,41,45,46,47,49,51,53,56,57,58,59,70,71,77,78,79,83,84,85,86,88,89,91,97,98	一般	0.499	0.026	0.687
3	24	2,4,6,7,10,18,33,36,37,38,43,44,50,52,54,55,80,82,87,90,92,94,95,96	弱	0.631	0.265	0.768

## 4 接管时驾驶意图识别

### 4.1 LSTM 模型原理

LSTM 模型是一种循环神经网络结构,在时间序列数据的识别和预测方面表现出良好的性能,由输入层、输出层和隐藏层组成,其中隐藏层由一个或多个记忆单元和 3 个乘法门单元(输入门、输出门和遗忘门)组成<sup>[30]</sup>。t 时刻,LSTM 模型读取上一时刻的信息  $h_{t-1}$  和当前时刻的输入  $x_t$ ,以此获得当前时刻的记忆信息  $h_t$ ,此时输入门、输出门和遗忘门的输出分别为  $i_t$ 、 $o_t$  和  $f_t$ ,即:

$$i_t = \sigma_i [W_i \cdot (h_{t-1}, x_t) + b_i] \quad (3)$$

$$o_t = \sigma_o [W_o \cdot (h_{t-1}, x_t) + b_o] \quad (4)$$

$$f_t = \sigma_f [W_f \cdot (h_{t-1}, x_t) + b_f] \quad (5)$$

式中: $\sigma_i$ 、 $\sigma_o$  和  $\sigma_f$  分别为输入门、输出门和遗忘门所选的激活函数; $W_i$ 、 $W_o$  和  $W_f$  分别为输入门、输出

门和遗忘门所选的权重; $b_i$ 、 $b_o$  和  $b_f$  分别为输入门、输出门和遗忘门所选的偏差。

t 时刻,隐藏层单元的状态  $C_t$  可表示为:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (6)$$

$$\tilde{C}_t = \tanh [W_c \cdot (h_{t-1}, x_t) + b_c] \quad (7)$$

式中: $\odot$  为哈达玛积; $C_{t-1}$  为 t-1 时刻隐藏层单元的状态; $\tilde{C}_t$  为  $C_t$  的备选取值; $W_c$  和  $b_c$  分别为计算  $\tilde{C}_t$  时所选用的权重和偏差; $\tanh$  为双曲正切函数。

LSTM 模型通过输入门、输出门和遗忘门学习时间序列数据的规律,经过 Softmax 层后可得输入数据所对应的分类结果。

### 4.2 LSTM 模型应用

以 20 s (即 200 个时间戳)为间隔,处理有效的接管试验数据,获得驾驶人接管行为的时间序

列数据。选取满足以下两个条件的接管试验数据作为 LSTM 模型的输入数据:①当发生换道行为或制动行为时,车辆的车灯状态会有相应的变化;②每次接管过程的持续时间大于 20 s。







可视化车辆的车灯状态,图 5 为各个参与者面对第 1 次接管事件时,车灯状态随行驶距离的变化。由图 5 可知,第 6 位参与者的车灯状态数据错误,没有准确地反映其接管避让过程,因此需剔除对应的片段。对其余片段进行相同处理,结合条件②,可获得满足要求的 39 个接管片段,共计 7800 条数据。根据经验法则,深度监督学习算法在给定约 5000 个标注样本时一般能达到可接受的性能<sup>[31]</sup>,而 LSTM 模型属于深度监督学习算法。因此,将前 5400 条数据用于训练模型,后 2400 条数据用于测试模型。选用 LSTM 层的神经元数为 128、激活函数为 ReLU 函数、损失函数为分类交叉熵,采用 Adam 优化器,设学习率为 0.01、衰减率为 0.01、控制梯度均值和未中心化方差的指数衰减率分别为 0.9 和 0.999,将 Softmax 激活函数作为输出层的激活函数。

#### 4.3 FA-LST 模型构建及应用

一方面,运用 LSTM 模型可识别驾驶人接管自动驾驶车辆时的驾驶意图,其中每个时间戳包含 5 个视觉注意力指标和 20 个车辆运行指标。另一方面,前述由因子分析提取的 3 个公因子能表征多个复杂但相关的变量及其内在关联结构,可涵盖驾驶人接管自动驾驶车辆过程中车辆的横向运动和纵向运动及驾驶人的眼部运动。因此,组合 FA 和 LSTM,形成新模型形成因子长短期记忆 (Factor and long short-term memory, FA-LST) 模型,该模型先使用因子分析预处理样本数据,再使用 LSTM 识别驾驶人接管自动驾驶车辆时的驾驶意图,其中每个时间戳包含 3 个视觉注意力指标 (含 1 个公因子) 和 15 个车辆运行指标 (含 2 个公因子)。图 6 为 FA-LST 模型识别驾驶人接管自动驾驶车辆时的驾驶意图的结构图。

#### 4.4 FA-LST 模型性能评价

为了验证 FA-LST 模型识别驾驶意图的性能,使用支持向量机 (SVM) 作为基准模型。对于 SVM 模型,其 Kernel 选取高斯核,  $C$  取 1000,  $\gamma$  取 0.0002。同 FA-LST 模型类似,构建 FA-SVM 模型。选用精确率 (分类结果正确的正样本数占分类结果为正样本数的比例)、召回率






图 5 参与者面对第 1 次接管事件时车灯状态随行驶距离的变化

Fig. 5 Variations of turn-light status with driving distance when participants dealing with first takeover event

(分类结果正确的正样本数占实际结果为正样本数的比例)、 $F_1$  分数(精确率和召回率的调和平均值)和准确率(分类结果正确的样本数占全部样本数的比例)作为评价分类结果的指标,对 LSTM、FA-LST、SVM 和 FA-SVM 模型进行性能评价。表 11 和 12 分别为 LSTM、FA-LST 模型和 SVM、FA-SVM 模型使用测试集数据识别驾驶意图所得的混淆矩阵,直观地反映了各模型所得的分类结果,其中,加粗数字代表模型所得正确分类数,其数值越高,说明分类效果越好。

表 13 给出了各模型所得驾驶意图识别的 4 项性能指标,其中,加粗数字表示同组数据中的最大值。从分类算法的性能指标来看,FA-LST 模型和 LSTM 模型分别明显优于 FA-SVM 模型和 SVM 模型,FA-SVM 模型优于 SVM 模型,FA-LST 模型优于 LSTM 模型,可见 FA-LST 模型最优。

具体而言,FA-LST 模型识别制动左转、左转和直行的驾驶意图有最佳的效果;LSTM 模型仅对右转所得精确率、召回率和  $F_1$  分数优于 FA-LST 模型,但两者差距很小(依次分别为 1.5%、0.3% 和 1.0%);FA-SVM 模型对制动右转所得精确率、召回率和  $F_1$  分数、对右转所得精确率以及对制动所得召回率和  $F_1$  分数优于 FA-LST 模型。整体来看,FA-SVM 模型对识别制动右转有明显优势,而 FA-LST 模型对识别右转以外的其余 5 类驾驶意图均有明显优势,显然 FA-LST 模型的综合性能最佳,该模型的准确率达到




图 6 FA-LST 模型识别驾驶意图的结构

Fig. 6 Structure of FA-LST model for recognizing driving intention

表 11 LSTM、FA-LST 模型所得驾驶意图识别混淆矩阵

Table 11 Confusion matrices of driving intention recognition obtained by LSTM and FA-LST models

真实意图	制动左转		左转		直行		制动		右转		制动右转	
	FA-LST	LSTM	FA-LST	LSTM	FA-LST	LSTM	FA-LST	LSTM	FA-LST	LSTM	FA-LST	LSTM
制动左转	85	34	22	71	0	1	0	1	0	0	0	0
预 测 意 图	1	1	372	315	10	67	0	0	0	0	0	0
左 转	0	0	0	2	1233	1226	1	2	1	5	0	0
直 行	0	0	0	0	12	25	133	133	59	46	0	0
制 动	0	0	0	0	3	2	0	0	458	459	0	0
右 转	0	0	0	0	0	0	0	0	9	9	0	0
制 动 右 转	0	0	0	0	0	0	0	0	9	9	0	0

表 12 SVM、FA-SVM 模型所得驾驶意图识别混淆矩阵

Table 12 Confusion matrices of driving intention recognition obtained by SVM and FA-SVM models

真实意图	制动左转		左转		直行		制动		右转		制动右转		
	FA-SVM	SVM	FA-SVM	SVM	FA-SVM	SVM	FA-SVM	SVM	FA-SVM	SVM	FA-SVM	SVM	
制动左转	70	69	11	9	5	4	4	8	0	0	1	1	
预 测 意 图	左 转	9	9	311	296	42	54	2	4	4	5	0	0
直 行	3	0	51	61	1248	1241	13	10	37	40	0	0	
制 动	8	6	4	8	18	18	108	106	0	0	1	1	
右 转	0	0	7	10	40	56	2	1	396	378	1	1	
制 动 右 转	0	0	0	0	0	0	0	0	0	0	3	3	

表 13 驾驶意图识别的性能指标

Table 13 Performance indices of driving intention recognition

性能指标	模型	驾驶意图					
		制动 左转	左 转	直 行	制 动	右 转	制 动 右 转
精确率	FA-LST	0.988	0.944	0.980	0.992	0.869	0.000
	LSTM	0.971	0.812	0.928	0.978	0.884	0.000
	FA-SVM	0.778	0.810	0.922	0.837	0.906	0.500
	SVM	0.821	0.771	0.904	0.822	0.894	0.500
召回率	FA-LST	0.794	0.971	0.998	0.652	0.993	0.000
	LSTM	0.318	0.822	0.993	0.652	0.996	0.000
	FA-SVM	0.769	0.845	0.923	0.777	0.888	1.000
	SVM	0.758	0.804	0.918	0.763	0.848	1.000
$F_1$ -分数	FA-LST	0.880	0.957	0.989	0.787	0.927	0.000
	LSTM	0.479	0.817	0.959	0.782	0.937	0.000
	FA-SVM	0.773	0.827	0.922	0.806	0.897	0.667
	SVM	0.788	0.787	0.911	0.791	0.870	0.667
准确率	FA-LST	0.951					
	LSTM	0.903					
	FA-SVM	0.890					
	SVM	0.872					

95.10%，优于其他 3 个模型。

对比 LSTM 模型和 SVM 模型，SVM 模型对制动左转的识别在整体上优于 LSTM 模型( $F_1$  分数分别为 78.80% 和 47.90%)，但 LSTM 模型的精确率更优(SVM 精确率为 82.10%，LSTM 精确率为 97.10%)；LSTM 模型对左转、直行、制动和右转的识别明显优于 SVM 模型。值得注意的是，LSTM 模型对制动右转的识别十分失败，分析原始数据后发现，仅有 11 条数据对应制动右转这一驾驶意图，而 LSTM 模型善于识别连续的时间序列数据，且测试集中仅有 2 条数据对应制动右转，由于右转与制动右转相似，在对训练集进行制动右转识别时，其余 9 条数据对应的驾驶意图被误认为是右转，这一分类结果可从表 11 所示的混淆矩阵看出。对比 FA-SVM 模型和 SVM 模

型，SVM 模型仅对制动左转进行识别时所得精确率和  $F_1$  分数优于 FA-SVM 模型。

综合上述分析，对于识别驾驶人接管自动驾驶车辆时的驾驶意图，适用于时间序列数据的 LSTM 模型的性能较为出色，且通过因子分析提炼有效信息后有助于提高 LSTM 模型的性能。

## 5 结 论

(1)考虑驾驶人的视觉注意力，设计了考虑不同接管情境的模拟试验，深入剖析了驾驶人接管自动驾驶车辆的过程。

(2)以因子分析提取的公因子为聚类指标，采用 K-means 聚类分析定性描述了特定接管类型的驾驶人的接管行为，并根据试验结果显示的不良接管行为，揭示了具有相同接管类型的驾驶人可能存在的驾驶风险。

(3)基于 LSTM 模型，输入层采用因子分析所得结果，以此构建了 FA-LST 模型，进一步分类识别驾驶意图。结果表明，就分类性能而言，FA-LST 模型优于 LSTM 模型，FA-SVM 模型优于 SVM 模型，LSTM 模型优于 SVM 模型，FA-LST 模型最优。

(4)招募的试验参与者局限于以男性为主的硕士研究生，且有效试验人数只有 11 人，所得结论具有一定的局限性。另外，制动右转的数据量过少，导致所建模型对制动右转的识别很差；同时，直行数据有 4475 条，占有所有数据的 57.37%，所建模型对直行的识别最为容易且效果最好，提高了该模型的总体性能。

### 参考文献：

[ 1 ] de LaTorre G, Rad P, Choo K R. Driverless vehicle security: challenges and future research opportunities

- [J]. Future Generation Computer Systems, 2020, 108: 1092-1111.
- [2] SAE J3016—2016. Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles[S].
- [3] SAE J3016—2018. Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles[S].
- [4] National Highway Traffic Safety Administration. ODI resume[R]. Washington, DC: National Highway Traffic Safety Administration, 2017.
- [5] Lu Z J, Coster X, de Winter J C F. How much time do drivers need to obtain situation awareness? a laboratory-based study of automated driving[J]. Applied Ergonomics, 2017, 60: 293-304.
- [6] Endsley M R. Situation awareness global assessment technique (SAGAT)[C]//Proceedings of the IEEE 1988 National Aerospace and Electronics Conference, Dayton, OH, USA, 1988: 789-795.
- [7] Samuel S, Borowsky A, Zilberstein S, et al. Minimum time to situation awareness in scenarios involving transfer of control from an automated driving suite[J]. Transportation Research Record, 2016, 2602(1): 115-120.
- [8] Wright T J, Samuel S, Borowsky A, et al. Experienced drivers are quicker to achieve situation awareness than inexperienced drivers in situations of transfer of control within a level 3 autonomous environment [C]//Proceedings of the Human Factors and Ergonomics Society Annual Meeting, Los Angeles, CA, USA, 2016: 270-273.
- [9] Vlakveld W, van Nes N, de Bruin J, et al. Situation awareness increases when drivers have more time to take over the wheel in a level 3 automated car: a simulator study[J]. Transportation Research Part F: Psychology and Behaviour, 2018, 58: 917-929.
- [10] Petermeijer S M, Bazilinskyy P, Bengler K, et al. Take-over again: investigating multimodal and directional tors to get the driver back into the loop[J]. Applied Ergonomics, 2017, 62: 204-215.
- [11] Forster Y, Naujoks F, Neukum A, et al. Driver compliance to take-over requests with different auditory outputs in conditional automation[J]. Accident Analysis and Prevention, 2017, 109: 18-28.
- [12] Radlmayr J, Fischer F M, Bengler K. The influence of non-driving related tasks on driver availability in the context of conditionally automated driving[J]. Proceedings of the 20th Congress of the International Ergonomics Association, 2018, 823: 295-304.
- [13] Yoon S H, Ji Y G. Non-driving-related tasks, workload, and takeover performance in highly automated driving contexts[J]. Transportation Research Part F: Psychology and Behaviour, 2019, 60: 620-631.
- [14] Gold C, Körber M, Lechner D, et al. Taking over control from highly automated vehicles in complex traffic situations: the role of traffic density[J]. Human Factors, 2016, 58(4): 642-652.
- [15] Roche F, Thüning M, Trukenbrod A K. What happens when drivers of automated vehicles take over control in critical brake situations?[J]. Accident Analysis and Prevention, 2020, 144: No. 105588.
- [16] Clark H, Feng J. Age differences in the takeover of vehicle control and engagement in non-driving-related activities in simulated driving with conditional automation[J]. Accident Analysis and Prevention, 2017, 106: 468-479.
- [17] Epple S, Roche F, Brandenburg S. The sooner the better: drivers' reactions to two-step take-over requests in highly automated driving[C]//Proceedings of the Human Factors and Ergonomics Society Annual Meeting, Los Angeles, CA, USA, 2018, 62(1): 1883-1887.
- [18] Wiedemann K, Naujoks F, Wörle J, et al. Effect of different alcohol levels on take-over performance in conditionally automated driving[J]. Accident Analysis and Prevention, 2018, 115: 89-97.
- [19] Vogelpohl T, Kühn M, Hummel T, et al. Asleep at the automated wheel: sleepiness and fatigue during highly automated driving[J]. Accident Analysis and Prevention, 2019, 126: 70-84.
- [20] 王海星, 王翔宇, 王招贤, 等. 基于数据挖掘的危险货物运输风险驾驶行为聚类分析[J]. 交通运输系统工程与信息, 2020, 20(1): 183-189.  
Wang Hai-xing, Wang Xiang-yu, Wang Zhao-xian, et al. Dangerous driving behavior clustering analysis for hazardous materials transportation based on data mining[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(1): 183-189.
- [21] Zhou T, Zhang J. Analysis of commercial truck drivers' potentially dangerous driving behaviors based on 11-month digital tachograph data and multilevel modeling approach[J]. Accident Analysis and Prevention, 2019, 132: No. 105256.
- [22] 孙剑, 张一豪, 王俊骅. 基于自然驾驶数据的分心驾驶行为识别方法[J]. 中国公路学报, 2020, 33(9):

- 225-235.
- Sun Jian, Zhang Yi-hao, Wang Jun-hua. Detecting distraction behavior of drivers using naturalistic driving data[J]. *China Journal of Highway and Transport*, 2020, 33(9): 225-235.
- [23] Jia S, Hui F, Li S N, et al. Long short-term memory and convolutional neural network for abnormal driving behaviour recognition[J]. *IET Intelligent Transport Systems*, 2020, 14(5): 306-312.
- [24] 张姝玮, 郭忠印, 杨轸, 等. 驾驶行为多重分形特征在驾驶疲劳检测中的应用[J]. *吉林大学学报: 工学版*, 2021, 51(2): 557-564.
- Zhang Shu-wei, Guo Zhong-yin, Yang Zhen, et al. Application of multi-fractal features of driving performance in driver fatigue detection[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2021, 51(2): 557-564.
- [25] 庄明科, 白海峰, 谢晓非. 驾驶人员风险驾驶行为分析及相关因素研究[J]. *北京大学学报: 自然科学版*, 2007, 4: 75-82.
- Zhuang Ming-ke, Bai Hai-feng, Xie Xiao-fei. A study on risky driving behavior and related factors[J]. *Acta Scientiarum Naturalium Universitatis Pekinensis (Natural Science Edition)*, 2007, 4: 75-82.
- [26] Child D. *The Essentials of Factor Analysis*[M]. London: Cassell Educational, 1990.
- [27] Kaiser H F. The varimax criterion for analytic rotation in factor analysis[J]. *Psychometrika*, 1958, 23(3): 187-200.
- [28] Macqueen J. Some methods for classification and analysis of multivariate observations[C]//*Proceedings of Berkeley Symposium on Mathematical Statistics and Probability*, Berkeley, CA, USA, 1967: 281-297.
- [29] Sun H D, Chen Y Y, Lai J H, et al. Identifying tourists and locals by K-means clustering method from mobile phone signaling data[J]. *Journal of Transportation Engineering, Part A: Systems*, 2021, 147(10): No. 04021070.
- [30] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [31] 赵申剑, 黎彧君, 符天凡, 等译. *深度学习*[M]. 北京: 人民邮电出版社, 2017.