

典型驾驶场景下接管绩效预测及特征分析^{*}

张杨杨^{1,2,5}, 张浩^{3,5}, 甘涛^{1,2,5}, 冷昶^{3,5}, 黄承超^{4,5}, 张立军^{1,2,5}



¹(基础软件与系统重点实验室(中国科学院软件研究所),北京100190)

²(计算机科学国家重点实验室(中国科学院软件研究所),北京100190)

³(中国科学院软件研究所人机交互技术与智能信息处理实验室,北京100190)

⁴(中科南京软件技术研究院 软件安全与可信实验室,江苏南京211135)

⁵(中国科学院大学,北京100049)

通信作者: 黄承超, E-mail: chengchao@njis.ac.cn; 张立军, E-mail: zhanglj@ios.ac.cn

摘要: 随着自动驾驶技术的快速发展,车辆控制权的接管问题成为研究的热点。装载辅助驾驶系统的汽车并不能完全处理所有的驾驶场景,当实际驾驶场景超出辅助系统的操作设计域时,仍需要人类驾驶员控制汽车以安全完成驾驶任务。接管绩效是衡量驾驶员接管表现的重要指标,包括接管反应时间和接管质量两个方面。接管反应时间是指系统发出接管请求后到驾驶员控制方向盘的时间开销,接管反应时间长短不仅一定程度上反映了当前驾驶员的状态,还对后续面对复杂场景进行操作也有一定影响。接管质量是指驾驶员获得车辆控制权后手动驾驶车辆的质量。基于CARLA驾驶模拟器,构建6个典型驾驶场景下,对车辆控制权接管过程进行仿真并通过多通道采集系统搜集了31名驾驶员的生理信号和眼动数据。根据驾驶员的接管表现,参考国际标准基于多个车辆数据提出包括驾驶员接管反应时间、最大横、纵向加速度、最小碰撞时间在内的更为客观的接管绩效评价标准。综合驾驶员数据、车辆数据和场景数据,研究利用深度神经网络(DNN)模型对接管绩效进行了预测,并运用SHAP模型分析各特征的影响,以提高模型的解释性和透明度。实验结果表明,所提出的DNN模型在接管绩效预测方面优于传统机器学习方法,预测准确率达到92.2%,且具备良好的泛化性。SHAP分析揭示了心率变异性、驾驶经验、最小安全距离等关键特征对预测结果的重要影响。为自动驾驶系统的安全性优化和人机交互设计提供了理论和实证基础,对提高自动驾驶技术中人车合作的效率和安全性具有重要意义。

关键词: 自动驾驶; 接管绩效; 深度神经网络; 可解释性; 人机交互

中图法分类号: TP311

中文引用格式: 张杨杨, 张浩, 甘涛, 冷昶, 黄承超, 张立军. 典型驾驶场景下接管绩效预测及特征分析. 软件学报. <http://www.jos.org.cn/1000-9825/7408.htm>

英文引用格式: Zhang YY, Zhang H, Gan T, Leng C, Huang CC, Zhang LJ. Takeover Performance Prediction and Characteristic Analysis Under Typical Driving Scenarios. Ruan Jian Xue Bao/Journal of Software (in Chinese). <http://www.jos.org.cn/1000-9825/7408.htm>

Takeover Performance Prediction and Characteristic Analysis Under Typical Driving Scenarios

ZHANG Yang-Yang^{1,2,5}, ZHANG Hao^{3,5}, GAN Tao^{1,2,5}, LENG Chang^{3,5}, HUANG Cheng-Chao^{4,5}, ZHANG Li-Jun^{1,2,5}

¹(Key Laboratory of System Software (Institute of Software, Chinese Academy of Sciences), Beijing 100190, China)

²(State Key Laboratory of Computer Science (Institute of Software, Chinese Academy of Sciences), Beijing 100190, China)

³(Laboratory of Human-computer Interaction Technology and Intelligent Information Processing, Institute of Software, Chinese Academy of Sciences, Beijing 100190, China)

* 基金项目: 中国科学院基础研究青年团队 (CASYSBR-040)

张杨杨和张浩为共同第一作者。

收稿时间: 2024-07-31; 修改时间: 2024-11-02, 2024-12-29; 采用时间: 2025-02-11; jos 在线出版时间: 2025-06-04

⁴(Software Security and Trustworthiness Laboratory, Nanjing Institute of Software Technology, Nanjing 211135, China)

⁵(University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: With the rapid development of autonomous driving technology, the issue of vehicle control takeover has become a prominent research topic. A car equipped with an assisted driving system cannot fully handle all driving scenarios. When the actual driving scenario exceeds the operational design domain of the assisted system, human intervention is still required to control the vehicle and ensure the safe completion of the driving task. Takeover performance is an extremely important metric for evaluating a driver's performance during the takeover process, which includes takeover reaction time and takeover quality. The takeover reaction time refers to the time from the system's takeover request to the driver's control of the steering wheel. The length of the takeover response time not only reflects the driver's current state but also affects the subsequent handling of complex scenarios. Takeover quality refers to the quality of manual vehicle operation by the driver after regaining control. This study, based on the CARLA driving simulator, constructs 6 typical driving scenarios, simulates the vehicle control takeover process, and collects physiological signals and eye movement data from 31 drivers using a multi-channel acquisition system. Based on the driver's takeover performance, and regarding International standards, an objective takeover performance evaluation metric is proposed, incorporating the driver's takeover reaction time, maximum horizontal and vertical accelerations, and minimum collision time, derived from multiple vehicle data. By combining driver data, vehicle data, and scenario data, a deep neural network (DNN) model predicts takeover performance, while the SHAP model analyzes the impact of each feature, improving the model's interpretability and transparency. The experimental results show that the proposed DNN model outperforms traditional machine learning methods in predicting takeover performance, achieving an accuracy of 92.2% and demonstrating good generalization. The SHAP analysis reveals the impact of key features such as heart rate variability, driving experience, and minimum safe distance on the prediction results. This research provides a theoretical and empirical foundation for the safety optimization and human-computer interaction design of autonomous driving systems and is of great significance for improving the efficiency and safety of human-vehicle cooperation in autonomous driving technology.

Key words: autonomous driving; takeover performance; deep neural network (DNN); interpretability; human machine interface

自动驾驶技术的迅猛发展使得人车合作变成了更加现实、紧迫的课题^[1]。根据 SAE 分级^[2], 可以将自动驾驶分为 6 个等级, 其中 L0 为手动驾驶, L5 为完全自动驾驶, 当前可应用在真实交通场景下的自动驾驶等级一般在 L3 以下。自动驾驶汽车联合摄像头、GPS、雷达和激光雷达等传感器感知环境数据, 通过规划模块规划行驶路线, 最后执行模块执行相应的驾驶动作。L3 为有条件自动驾驶, 其辅助驾驶系统 (advanced driving assistance system, ADS) 在驾驶过程中允许驾驶员暂时解放双手、减轻驾驶负荷, 执行一些阅读、饮食等与驾驶无关的任务 (non driving related task, NDRT)^[3,4]。受限于当前自动驾驶技术和法律规定, 在超出自动驾驶系统的操作设计域 (operation design domain, ODD) 时需要驾驶员对车辆进行接管并驾驶, 驾驶员仍旧是驾驶过程中重要的一环。在这种情况下, 自动驾驶系统需要发出接管请求 (take over request, TOR), 并通过视觉、听觉或触觉的方式提醒驾驶员, 以便驾驶员能及时接管车辆保障行车安全^[5]。在一些安全攸关的场景下 (如即将发生碰撞、礼让行人等), 驾驶员的接管行为的好坏对驾驶安全有着至关重要的影响^[6]。因此, 评估并预测驾驶员的接管行为, 确保驾驶员再次从事非驾驶任务时能够安全地接管车辆控制权具有重要意义。

评价接管行为的好坏主要通过接管绩效进行衡量, 通常来讲, 接管绩效主要包括接管反应时间和接管质量两方面。接管反应时间是指系统发出接管请求后到驾驶员控制方向盘的时间开销, 接管反应时间长短不仅一定程度上反映了当前驾驶员的状态, 还对后续面对复杂场景进行操作也有一定影响。接管质量是指驾驶员获得车辆控制权后手动驾驶车辆的质量。近年来, 面向有条件的自动驾驶情况下的接管研究大多专注于探究不同的接管提醒方式^[7]、接管提醒时间^[8]、接管场景^[9]对接管质量的影响, 对接管质量的绩效研究相对较少。部分学者对接管质量进行了预测但并未对影响接管质量的因素进行分析^[10]。同时, 接管质量的衡量目前还不具备统一的标准, 因而亟需对接管绩效进行判定, 并探究不同接管因素对接管绩效的影响。

在自动驾驶领域, 接管数据的获取面临着多重挑战, 不仅涉及复杂的多通道数据采集设备的需求, 还需实现这些设备与仿真平台之间的无缝对接, 以确保人-机-设备间的时间同步精度。此外, 鉴于该领域的特殊性, 当自动驾驶系统遇到难以自行解决的驾驶情境时, 会发出接管请求, 这对驾驶员快速且准确的接管能力提出了极高的要求。针对以上局限性, 本研究在 CARLA^[11]仿真平台上模拟驾驶场景并收集被试在 6 个具有代表性的驾驶场景下的接

管实验过程中产生的生理信号、车辆数据以及眼动数据,通过结合自动驾驶标准及现有的研究对接管绩效进行判定,并将这些数据特征使用 DNN 进行建模预测接管绩效,并使用 SHAP 模型对特征进行解释,探究不同的特征对接管绩效的影响程度.本研究的整体流程如图 1 所示.

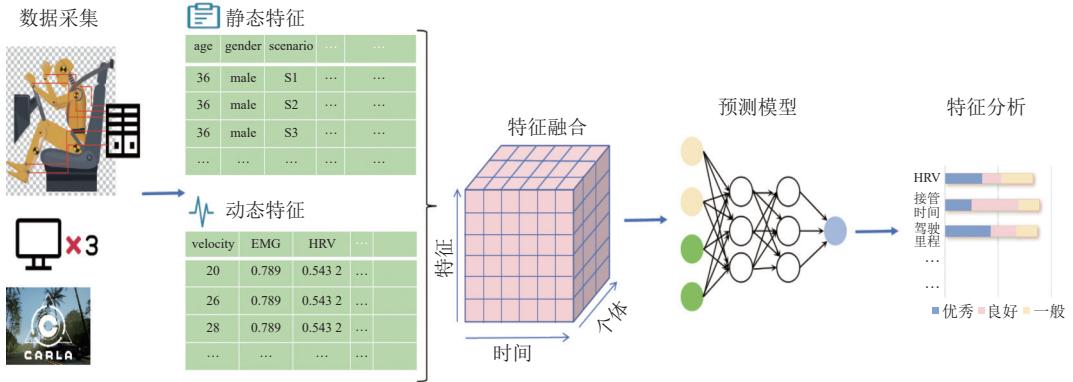


图 1 接管绩效预测及解释模型实验流程

本文的主要贡献如下.

(1) 典型事故场景仿真环境与驾驶接管表现研究. 本研究构建了 6 个覆盖高风险事故的仿真场景, 这些场景基于《智能网联汽车 自动驾驶功能场地试验方法及要求》国家标准和美国事故报告, 精心筛选出典型的事故多发场景, 并在仿真环境中进行了建模. 通过模拟不同驾驶场景, 不仅显著提升了研究的现实相关性, 还深入探究了驾驶员在紧急情况下的接管表现. 这一方法为自动驾驶技术的安全性能评估提供了全新的视角.

(2) 本研究在前人研究的基础上, 并参考国际评价标准, 提出了一套多维度的接管绩效评价体系. 该体系超越了传统的接管反应时间单一指标, 扩展到了包括最大横向和纵向加速度、最小碰撞时间等关键性能指标, 构建了一个更全面和客观的评估框架. 这一多维度评价方法为自动驾驶车辆的接管性能提供了更精细的量化分析, 有助于指导自动驾驶系统的实际设计和优化工作.

(3) 本研究提出了一种多模态绩效预测模型, 该模型融合了心跳变异率、肌电信号、眼动信号等多种生理信号以及车辆数据. 利用深度神经网络技术, 模型整合了机电、心电、车辆操作数据和眼动信息, 实现了对驾驶员接管绩效的高准确度预测, 准确率超过了 92%. 此外, 通过应用 SHAP (Shapley additive explanations) 模型对影响绩效的关键特征进行深入分析, 本研究不仅增强了模型的透明度和可解释性, 还揭示了心电特征、驾驶经验和最小碰撞距离等关键因素对接管绩效的显著影响, 为车辆安全性提供了科学的依据和改进建议.

本文第 1 节介绍不同场景下有条件自动驾驶接管实验及分析模型的相关工作. 第 2 节介绍不同场景下接管实验数据采集. 第 3 节介绍接管绩效预测及分析模型构建. 第 4 节汇报实验结果及分析. 最后总结全文.

1 典型场景下接管绩效预测及分析模型相关工作

从自动驾驶状态切换为手动驾驶状态, 意味着当前系统即将面临较为复杂的交通环境或者需要执行安全攸关的驾驶任务. 在这个过程中驾驶员自身状态、车辆数据以及自动驾驶系统与驾驶员之间的信息交互尤为关键, 而这种控制权的切换过程被定义为接管^[12]. 在安全攸关的场景下, 接管绩效的好坏会直接影响行车安全, 接管绩效不好可能会导致碰撞发生, 严重时甚至会危害驾驶员及车上乘客的生命安全. 当前对自动驾驶接管过程的研究大多数是基于有条件自动驾驶, 此时主驾驶座上的人在自动驾驶系统控制汽车时担任乘客角色, 但当自动驾驶系统发出接管提醒时, 人的角色由乘客转换成驾驶员, 需要完成汽车的接管并驾驶汽车.

一些研究者探究接管反应时间或接管质量的影响因素, McDonald 等人^[13]综合调研了在接管过程中时间预算、无声失败、手持次要任务、汽车的自动化程度、信任疲劳和酒精等外部条件因素及内部自身因素对接管反应时

间的影响. Gold 等人^[14]分别探究 5 s 和 7 s 的接管提醒时间对接管质量的影响, 实验发现在较短时间内接管会出现更快的反应时间但接管质量较差. Chen 等人^[15]探究使用注意力引导的方式发出接管提醒以提高驾驶员的接管绩效. Heo 等人^[16]探究不同天气条件及接管提醒方式对驾驶员接管的影响, 实验结果显示这些环境因素会对接管的接管反应时间、变道时间、接管后最大加速度及主观心理负荷等产生影响. Meteier 等人^[17]探究不同大小和不同运动状态障碍物对接管绩效的影响, 结果显示在接管过程中, 动态障碍物对驾驶员的驾驶能力提出了更高的要求. Hong 等人^[18]探究听觉、视觉和触觉的接管提醒方式对接管的影响, 实验结果表明混合提醒方式比单一提醒方式能更快让被试做出接管反应. Sanghavi 等人^[19]通过让不同的被试进行接管实验并分析实验结果得出性别、驾驶风格以及驾驶时驾驶员的精神状态和身体状态均会对接管反应时间和接管质量产生影响. Du 等人^[20]通过将驾驶场景归类成变道场景和跟车场景, 探究 40 名被试在这些场景下的接管绩效, 结果发现驾驶场景和道路环境均会对驾驶员的接管绩效和生理反应产生影响. 一些研究对接管的驾驶偏好进行了预测, Koochaki 等人^[21]使用神经网络对驾驶员的驾驶风格偏好进行了预测.

一些研究者对接管反应时间和接管质量进行了预测. Gold 等人^[22]使用定量方法对影响有条件自动驾驶情况下, 接管时间预算较为紧迫的接管绩效影响因素进行分析, 并构建回归模型对接管反应时间、最小碰撞时间 (time to collision, TTC)、制动应用和碰撞概率进行预测, 并使用 729 个接管片段对模型进行有效验证. Ma 等人^[23]使用眼动数据通过建立回归模型预测在特定驾驶场景下的接管反应时间. Ayoub 等人^[24]使用 XGBoost 建立回归模型对接管反应时间进行预测, 并使用 SHAP 模型探究特征对结果的影响程度. Pakdamanian 等人^[25]基于 DNN 使用生理信号、眼动数据、车辆数据和人口统计学等数据对在高速公路下的接管意图和接管质量分别进行预测. Sajedinia 等人^[26]使用线性模型对驾驶员的驾驶偏好和接管行为进行预测, 发现信任是确定驾驶员的驾驶偏好及接管行为的重要特征. Zhu 等人^[27]使用心电信号、眼动特征以及头部位置信息作为输入特征, 使用 XGBoost 对接管质量进行预测. Liu 等人^[10]使用最小碰撞时间作为对接管绩效的衡量标准, 将眼动特征、驾驶环境特征、驾驶员的人口统计信息以及时间预算作为神经网络 ACTNet 的输入对接管质量进行预测. Chen 等人^[28]利用个体特征、外部环境和态势感知等 15 个特征作为输入, 构建 BM+SA 模型对驾驶员的接管反应时间进行预测. Gu 等人^[29]使用驾驶员的多通道情绪和身体信息 (即面部表情、身体姿势、眼球运动和头部姿势), 以预测接管行为的准备程度、反应时间和车辆数据的质量. 这些研究或仅探究接管反应时间和质量的影响因素, 或仅对接管反应时间和接管质量进行预测, 并未能将二者结合起来, 且未考虑不同场景对接管结果的影响, 不能给自动驾驶系统提供有效的信息反馈以保障行车安全. 基于此, 本研究综合考虑不同场景下驾驶员在辅助驾驶系统发出接管提醒后的接管绩效表现, 综合考量接管反应时间与接管质量, 提出了新的接管绩效评价标准, 并通过构建数据采集实验采集包含生物电信号、车辆信息、场景信息等在内的多模态数据. 这些数据均作为模型训练及预测的数据集, 构建了接管绩效预测模型, 并对输入特征对预测结果的影响进行可解释性分析.

2 典型场景下接管实验数据采集

2.1 接管数据采集实验

- 驾驶场景. 驾驶场景是一个复杂的概念, 它涵盖了驾驶环境、交通参与者以及所有与驾驶行为相关的因素^[30]. 这些因素共同构成了一个影响驾驶质量的关键维度. 在不同的驾驶场景下, 驾驶员面临的挑战和要求各不相同. 例如, 在车辆密集且类型多样的城市道路上驾驶, 与在空旷的乡村马路上行驶, 对驾驶员的技能和认知负荷提出了不同的要求^[4]. 城市道路的驾驶场景通常要求驾驶员具备更高的警觉性和反应速度, 因为需要频繁地观察周围的交通状况, 包括行人、自行车和其他车辆. 同时, 城市交通中的信号灯、路口和复杂的路标也增加了驾驶的难度. 相比之下, 乡村道路上的驾驶可能相对简单, 但仍然需要驾驶员保持注意力集中, 尤其是在夜间或恶劣天气条件下. 此外, 即使是在同一类型的驾驶场景中, 障碍物的类型也会对驾驶员的反应产生影响. 例如, 遇到突然横穿道路的动物与遇到前方施工区域, 驾驶员所需的应对策略和反应时间可能会有很大差异. 在之前的研究中, 实验设计的驾驶场景往往局限于特定的情境, 如躲避障碍物和紧急制动, 而且大多数实验都是在高速公路上进行, 车辆行驶速度

固定。这样的研究设计虽然有助于控制变量, 但也可能限制了研究结果的普遍适用性。

与之前的驾驶场景不同, 本实验的驾驶场景基于 CARLA 自带的自动驾驶系统 (ADS) 在指定的城镇地图上行驶, 驾驶满足法律及路段限速要求, 具有较强的真实性。参考美国国家公路交通安全管理局 (National Highway Traffic Safety Administration, NHTSA) 发布的碰撞前情景分类驾驶场景^[31], 结合国家标准《智能网联汽车自动驾驶功能场地试验方法及要求》^[32]中对于自动驾驶测试场景的要求以及国际标准 ISO 34504^[33], 选取并构建了在乡村和城市道路中出现的 6 个的安全攸关的驾驶场景, 这些场景涵盖不同事故类型, 分别为车辆切入、右方来车、跟随前车行驶、行人过马路、十字路口红绿灯通行和自行车穿过人行道, 这些驾驶场景分布在乡村或城市公路上, 道路旁存在各种树木和房屋。在这些场景中, 驾驶道路均为双向六车道, 前车速度为 30 km/h、车辆切入的 NPC 场景车速为 35 km/h, 右侧来车的车辆速度为 25 km/h, 行人过马路的速度为 5 km/h, 自行车穿过人行道的速度为 12 km/h。仿真环境下的驾驶场景如图 2 所示, 实验采集过程所有的驾驶场景均以第 1 视角呈现。本研究中将驾驶场景抽象成 3 个重要的驾驶特征作为重要特征, 联合其他多模态数据作为模型的输入。

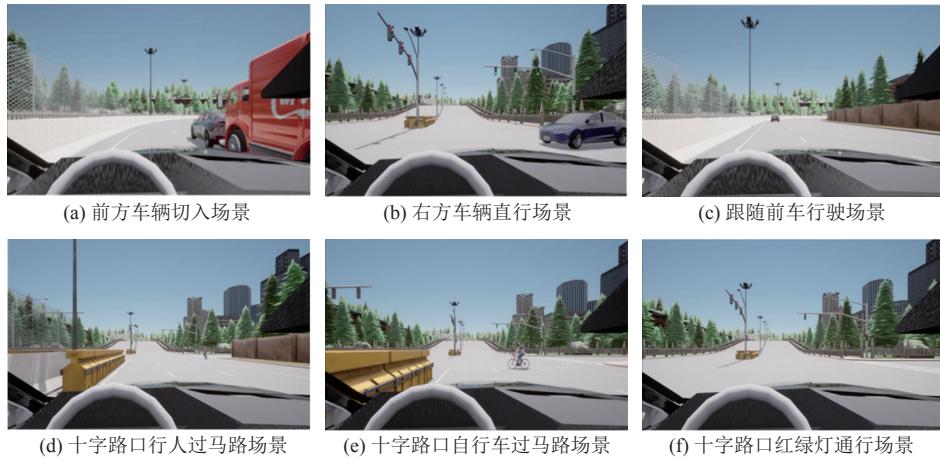


图 2 第一视角的仿真驾驶场景

- 采集特征。选择生理信号, 例如心电信号^[34]和肌电信号^[35], 能够揭示驾驶员当前的认知负荷和生理状况。认知负荷的增加可能会对驾驶员的反应时间和接管任务的质量产生不利影响。特别是, 基于心电信号的心跳变异率^[36] (heart rate variability, HRV), 它是一种衡量驾驶员实时状态的精确指标, 反映了心电信号中连续两个 R 峰之间的时间差。眼动信号^[37], 包括被试的注视点和注视持续时间, 能够揭示被试的注意力集中区域。基于这些信号, 本研究选择了心电信号、肌电信号和眼动信号来监测驾驶员的状态, 旨在更全面地收集和分析驾驶员的状态信息。

- 实验采集流程。之前的研究^[38-40]表明相较于年长人群, 年轻人对自动驾驶有着更高的接受程度和驾驶意愿。这意味着从实际应用的角度出发, 该年龄段的人群是本文所研究技术的主要潜在用户。本次实验招募 31 名被试者 (15 男 16 女), 年龄均值为 23.38 岁, 标准差 2.69, 主要采集被试的个人信息及他们在 6 个不同驾驶场景下执行接管任务过程中的生理信号、眼动数据以及车辆数据。所有被试均持有中华人民共和国机动车有效驾驶证且健康状况良好, 驾驶年龄均值为 2.59 年, 标准差为 2.06。实验正式开始前, 被试填写关于其人口特征及驾驶经验的问卷信息, 并进行 5 min 的模拟驾驶以熟悉驾驶环境。在不同的驾驶场景下, 被试要求在接管提醒发出后接管车辆并保持安全驾驶, 待经过下一个十字路口后视为一次子实验结束。子实验的实验流程如图 3 所示, 其中红色车为有条件自动驾驶车辆, 灰色车为其他交通参与车辆。接管提醒为一串铃声, 被试在铃声响起后按下切换按钮接管车辆, 一次完整的实验由两组构成, 一组为眼睛全程专注驾驶, 一组为使用手机模拟分心驾驶。整个实验耗时 75 min。实验中所使用的驾驶场景编号见表 1。

- 实验设备。本实验使用罗技 G27 方向盘, 并搭载模拟座舱和线性踏板作为模拟座舱环境, 生理信号采集设备为 16 通道的 biopac MP150, 实验过程使用 Ag-CI 电极片连接 biopac MP150 以采集被试生物电信号, 眼动仪型号

为 Tobii eye Tracker 5, 用以采集被试的眼动信号。模拟驾驶环境的仿真器为 CARLA, 支撑仿真模拟使用的显卡为 RTX 3070Ti, 模拟屏幕大小为 3 个分辨率为 2560×2000 的 27 寸三联屏。实验环境如图 4 所示。

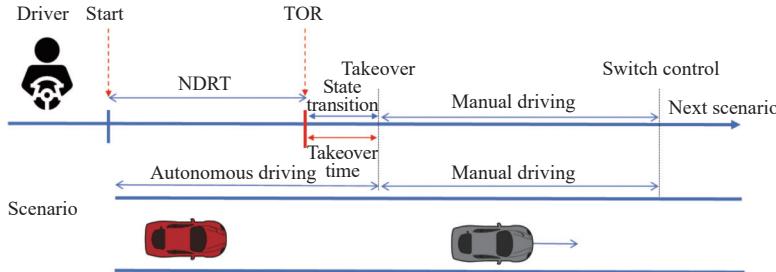


图 3 接管任务流程 (跟车场景), 红色车为有条件自动驾驶车辆, 灰色车为其他交通参与车辆

表 1 场景编号及其对应的场景设置

场景编号	场景设置
S1	前方车辆切入
S2	右方车辆直行
S3	跟随前车行驶
S4	十字路口行人过马路
S5	十字路口红绿灯通行
S6	十字路口自行车过马路



图 4 多模态数据采集实验环境

2.2 数据预处理

本次实验采集的数据有多种模态, 且采样频率不同, 需要对实验数据进行预处理并将不同模态的数据进行对齐。数据预处理包括数据筛选、剔除异常数据、标准化处理等步骤。除此之外, 还需要对每个接管片段的数据进行指标计算, 作为后续进行接管绩效研究的数据来源。数据筛选后的数据列表中根据每一条数据的时间戳以及是否在自动驾驶状态下定位出自动驾驶车辆发出接管提醒的时间节点, 最终在整个数据库中提取出共 432 个接管片段。

- 生理信号数据。实验采集的生理信号包括心电信号 (ECG) 和肌电信号 (EMG), 这两种生理信号的原始采样频率均为 2500 Hz。获得原始数据后, 将 ECG 和 EMG 信号进行 z-score 标准化处理以消除个体差异。随后, 对 ECG 依次使用宽度分别为 200 ms 和 600 ms 的中值滤波器以消除受试者在实验过程中因运动或呼吸引起的基线漂移。使用滑动窗口提取心跳变异率, 时间窗口宽度为 2 s, 滑动步长为 0.03 s。将处理好的 ECG 使用 Pan Tompkins QRS 检测器检测 R 峰, 并计算两个 R 峰之间的时间间隔。对 HRV 数据进行均值、标准差和一阶差分计算, 以获取 HRV 的重要时域特征。最后, 使用均值插值采样的方法将 EMG 和 ECG 采样频率降至 33 Hz。

- 其他数据。除生理信号之外, 本实验还采集了被试在接管过程中的车辆数据、眼动数据和场景数据, 这些数据使用时间戳对齐并将其与生理信号连接拓展成一个张量, 作为模型的输入。其中, 车辆数据包括车辆的速度、油门踏板幅度、制动踏板幅度、方向盘转角、最小碰撞距离、纵向加速度、横向加速度; 场景数据包括驾驶场景类型、车辆数量以及行人数量。然后分别提取并计算每个有效接管片段的接管反应时间、纵向加速度、横向加速度和与前车碰撞时间, 作为接管绩效评价的指标, 进行后续的对比分析。

3 接管绩效预测及分析模型构建

3.1 接管绩效

接管绩效是一项多维度的评估标准, 它整合了两个核心要素: 接管反应时间与接管驾驶质量。接管反应时间衡

量了驾驶员的即时反应能力^[41]. 接管驾驶质量直接体现了驾驶员驾控能力的高低, 高质量的接管质量体现为平滑、精确的车辆操控, 确保行程安全无虞^[42]. 重要的是, 接管响应时间的快慢并不直接等同于接管质量的好坏; 简言之, 迅速的反应时间不一定保证后续驾驶表现优良.

事实上, 过长的接管响应期可能蕴藏风险, 尤其在紧急情境下, 延长的反应时间可能导致驾驶员缺乏应对突发险情的宝贵时机, 从而加剧碰撞事故的风险^[43]. 因此, 在评判接管绩效时, 必须超越单一的响应时间指标, 兼顾响应速度与操作质量, 进行综合性评估. 实践中, 理想的接管情况是驾驶员既能迅速响应接管提示, 又能在接管后展现出卓越的驾驶技艺, 确保全程安全可控. 这不仅要求驾驶员拥有敏捷的反应力, 还必须具备精湛的驾驶技术和对车辆深入的了解及熟练度, 共同构成了确保自动驾驶与人工驾驶安全过渡的关键能力.

在之前关于自动驾驶接管的研究中, 文献 [22–25,28] 采用接管反应时间作为判定依据对驾驶员的接管表现进行评定, 而文献 [44,45] 则是将驾驶员接管后汽车的最大横、纵向加速度作为评价标准对驾驶员的接管质量进行判定. 在文献 [10,22] 中, 研究者将驾驶员在接管过程中的最小碰撞时间作为接管质量好坏的评价标准. 这些研究都涉及了接管绩效的接管反应时间或接管绩效部分, 但并未将接管反应时间与接管质量综合考虑起来对驾驶员的接管绩效做出较为全面的判定. 在当前关于接管绩效判定的基础上, 参考国际标准 ISO/TR 21959^[44], 该标准规范了自动驾驶接管绩效的定义, 包括接管反应时间的定义、接管质量等; 其中接管质量包括主观衡量标准和客观衡量标准, 而客观衡量标准主要参考驾驶员控制性能进行定义, 涵盖横向和纵向加速度值, 以及碰撞临界值, 如最小碰撞时间 (TTC) 等. 因此, 综合采集的实验数据, 本实验选取接管反应时间 t_r 、最大横向加速度 a_l 、最大纵向加速度 a_v 和最小碰撞时间 t_c 综合考虑作为评价指标对接管绩效进行判定, 通过计算每项指标的累积频率的方法确定绩效等级, 在对数据进行归一化之后, 统计得到不同指标对应的累积频率, 以累积频率为 30% 和 70% 时的指标值作为划分节点, 将数值区间内的驾驶员接管绩效划分为 3 类: 优秀、良好、不佳, 具体分类标准如表 2 所示.

表 2 接管绩效评价标准

绩效判定项	定义	绩效等级	范围	参考文献
接管反应时间 t_r (s)	接管请求发出后到驾驶员开始控制汽车的时间开销	优秀	$2.5 \leq t_r \leq 3.5$	
		良好	$t_r < 2.5$	[22–25,28]
		不佳	$t_r > 3.2$	
最大横向加速度 a_l (m/s^2)	驾驶员手动驾驶阶段汽车的横向加速度最大值	优秀	$2.5 \leq a_l \leq 3.72$	
		良好	$a_l < 2.53$	[44,45]
		不佳	$a_l > 3.72$	
最大纵向加速度 a_v (m/s^2)	驾驶员手动驾驶阶段汽车的纵向加速度最大值	优秀	$0.35 \leq a_v \leq 1.36$	
		良好	$a_v < 0.35$	[44,45]
		不佳	$a_v > 1.36$	
最小碰撞时间 t_c (s)	车辆保持当前运动状态条件下与目标车辆发生碰撞的时间	优秀	$1.21 \leq t_c \leq 2.16$	
		良好	$t_c < 1.21$	[10,22]
		不佳	$t_c > 2.16$	

3.2 接管绩效预测模型

基于预测事件的特殊性, 在模型选择时需要考虑模型的预测时间效率及准确性, 本研究使用带有反向传播机制的深度神经网络模型^[46], 优化算法采用小批量随机梯度下降方法. 预测模型的输入层将多模态特征与输入层进行匹配, 然后每一层接收到前一层传递的信息并将其计算得到的特征向量传递至下一层, 直到输出层接收到分类结果.

对于本预测模型, 定义其长度为 n 的输入特征向量为 $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$, 其中 x_i 表示第 i 个输入样本, 输入的特征向量为第 2 节采集并处理的多模态数据. 模型将输入向量与权重矩阵相乘后与偏置项相加得到的值传递给隐藏层 h_i , 隐藏层重复上述步骤直至将结果传递给输出层 o_i 得到模型预测的结果, 其计算方式如公式 (1).

$$h_{it} = \sigma(w_{it}^T x_i + b_{it}) \quad (1)$$

其中, h_{it} 表示第 i 个隐藏层的第 t 个神经元, w_{it} 是第 i 层第 t 个神经元对应的权重矩阵, b_{it} 是该神经元对应的偏置值, $\sigma(\cdot)$ 为激活函数. 本模型含有 3 个隐藏层, 分别包含 34、21、10 个 ReLU 神经元. 在模型优化方面, 本模型通过计算模型预测结果与真实结果之间的损失值, 使用梯度优化结合反向传播算法更新形成模型的个性化参数以强化模型分类预测能力, 其优化方法根据公式 (2) 和公式 (3) 计算得到.

$$loss = f(\hat{y}_i, y_i) \quad (2)$$

$$\theta = \theta - \eta \times \frac{\partial f(\theta, x_i, y_i)}{\partial \theta} \quad (3)$$

其中, \hat{y}_i 为模型预测结果, y_i 为真实结果, $f(\cdot)$ 为损失函数, θ 为模型参数. 输出层输出对于接管绩效等级的分类(优秀、良好、一般). 模型的学习过程如图 5 所示. 按照 8:2 的比例将多模态数据包集划分为训练集和测试集, 并采用十折交叉验证对模型进行评估, 其中 70% 的数据用以对模型进行训练, 10% 的数据用以对训练后的模型进行验证, 剩下 10% 的数据作为测试集在测试阶段对模型的分类能力进行测试. 模型训练使用随机梯度下降法作为优化方法, 初始学习率设定为 0.001, 选用交叉熵(cross-entropy)作为损失函数计算预测值与真实值之间的误差, 批大小设置为 32. 训练经过 250 次迭代后停止以防止模型过拟合. 实验结果在第 4.4 节中展示.

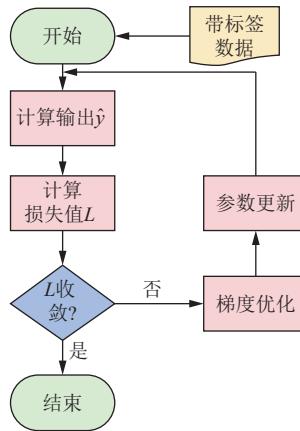


图 5 神经网络模型训练流程

3.3 特征分析模型

本研究基于 SHAP (Shapley additive explanations) 模型^[47]构建了特征分析模型, 基于博弈论原理中的 Shapley 值理论, 直观地展示有条件自动驾驶下接管绩效中特征的影响力增强用户对复杂模型内部机制的理解. SHAP 模型将机器学习模型中的特征视为合作博弈中的玩家, 每个特征的 Shapley 值即为其对模型预测结果的平均边际贡献, 其计算公式如公式 (4). 这一计算过程充分考虑了特征间的相互作用和每种可能的特征组合情况, 确保了特征重要性评估的公平性和全面性. 具体而言, Shapley 值通过遍历所有特征子集, 计算在加入特定特征前后预测结果的变化, 进而量化该特征的贡献度. 计算公式遵循 Shapley 值的经典定义, 体现了特征在所有可能的特征集合中的平均增量效益, 从而准确、公平地反映了各个特征的重要性.

$$f_{\text{Shapley}}(X_j) = \sum_{S \subseteq N \setminus j} \frac{k!(p-k-1)!}{p!} (f(S \cup j) - f(S)) \quad (4)$$

其中, S 为特征子集集合, p 为特征数量, $N \setminus j$ 代表除了 X_j 之外, 所有特征的排列组合, $f(\cdot)$ 表示模型的预测结果. 通过计算每个特征的 Shapley 值, SHAP 方法可以解释模型对于每个特征的预测结果是如何形成的. 较高的 Shapley 值表示该特征对于预测结果的贡献较大, 较低的 Shapley 值表示该特征对于预测结果的贡献较小. 通过将每个特征的 Shapley 值与其对应的特征值结合起来, 可以可视化地呈现出每个特征对于预测结果的正向或负向影响.

在探讨不同特征如何影响接管绩效这一实验目标时, 使用 SHAP 模型显得尤为合适。通过 SHAP 分析, 我们不仅能够识别出哪些特征对于提高接管反应速度和接管质量最为关键, 还能深入理解这些特征之间复杂的相互作用机制, 为优化自动驾驶系统的交接控制策略提供科学依据和实践指导。

4 实验结果分析

4.1 特征选择

除生理信号外, 车辆当前的行驶速度和方向、驾驶场景的复杂度以及驾驶员个人特征也会对驾驶员的接管绩效产生影响, 因此, 本实验选取车辆数据、场景数据、肌电数据、眼动数据、心电数据和驾驶员信息作为模型的输入特征。本实验所采集的多模态数据进行数据预处理后, 分别截取 1–15 s 时间窗口内的数据形成不同的数据集, 每个数据集为 432 个接管片段。然后将数据集按照 8:2 的比例分成训练数据和测试数据, 使用十折交叉验证对训练数据进行训练和验证, 构建接管绩效预测模型, 最后将测试数据作为测试集对模型有效性进行验证。模型训练的输入特征如表 3 所示。

表 3 输入特征变量名及其定义

数据类型	变量名	定义
车辆数据	steer_angle	车辆方向盘转向角度
	lateral_acc	横向加速度
	longitudinal_acc	纵向加速度
	Brake	刹车踏板踩踏幅度
	Throttle	油门踏板踩踏幅度
场景数据	Velocity	速度
	Scenario	接管场景
	person_num	行人数目
肌电数据	car_num	车辆数目
	peak_amplitude	肌电波形峰值幅度
眼动数据	peak_num	肌电波峰数目
	eye_pos	驾驶员凝视位置
	SDNN	心跳变异率RR间期标准差
心电数据	RMSSD	心跳变异率RR间期差值平方根均值
	SDSD	心跳变异率RR间期差值的平均值
	driving_year	被试驾驶证持有时长
驾驶员信息	is_ndrt	是否进行非驾驶相关任务
	Driving_Mileage	被试驾驶里程
	Sex	性别

4.2 模型评价指标及基准模型

与其他神经网络类似, 本研究采用准确率和 $F1$ 值作为衡量模型分类结果优劣的标准, 计算方法如公式(5)和公式(6)。

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$F1 = \frac{2 \times P \times R}{P + R} = \frac{2TP}{2TP + FP + FN} \quad (6)$$

其中, TP 表示正确识别正样本; FP 表示错误识别正样本; FN 表示错误识别负样本; TN 表示正确识别负样本; Acc 表示模型对所有判断正确的结果在所有结果中的比例; P 表示正确预测正样本的比例; $F1$ 表示模型输出能力的好坏, 取值范围为 $[0, 1]$, 其中, 1 代表模型的输出最好。较高的准确率表明模型在学习效果上表现更佳, 能够更准确

地判断接管绩效。本研究提出了一种基于场景研究绩效预测任务的新范式和构建预测模型的新框架，为了验证该框架的先进性，为了验证本方法的先进性，我们选取了几种经典的机器学习^[48]算法作为基准模型进行比较，包括随机森林(RF)、K-最近邻(KNN)、朴素贝叶斯(NB)和逻辑回归(LR)。在设置基准方法的超参数时，随机森林中设置决策树个数为100，深度为10，衡量指标为基尼系数；KNN聚类个数、LR分类类别数与绩效分类类别数据一致，均设置为3；NB中平滑强度设置为1。详细的实验结果见第4.4节。

SHAP模型作为一种解释性工具，其评价主要集中在解释一致性、解释有效性以及实用性和可视化方面。具体而言，Shapley值与特征重要程度正相关，可以保证特征重要性分数的一致性；通过计算每个特征对预测结果的贡献度，SHAP模型能够解释模型的输出，从而确保模型的有效性。

4.3 实验结果

4.3.1 基于多模态数据的深度神经网络接管绩效预测模型预测结果

为了验证这个问题的结果，我们使用从1–10 s的输入时间窗口对特征数据进行截取，截取开始的时刻为接管请求发出时刻前输入时间窗口数值的时刻，数据截取的结束时刻为接管请求发出时刻。然后使用深度神经网络模型与随机森林(RF)、K-最近邻(KNN)、朴素贝叶斯(NB)、逻辑回归(LR)在1–10 s时间窗下构建接管绩效预测模型，比较各个预测模型的准确率，比较不同时间窗口下和不同接管绩效预测模型。实验的结果见表4。

在时间窗口比较长，即能提供相较为丰富的背景信息的情况下，本实验选用的深度学习算法显著优于传统的机器学习方法，表明相对于现有的接管预测方法更具有实用价值。

为了分析不同时间窗长度的多通道数据输入神经网络预测模型对结果的影响，我们将时间窗口设为1–15 s，并分别对其进行训练，得到的正确率变化趋势如图6所示。可以看到当时间窗长度为10 s和15 s时，准确率分别为92.22%、88.68%。当时间窗长度大于10 s时，模型平均准确率均能达到89%，且变化不大，说明选择发出接管请求时间前10 s内的多通道数据作为输入已经足够。为了防止过拟合，当验证损失大于或等于先前的最小损失的次数为5次时，训练停止，训练轮次设置为250次。因此，认为选用的时间窗口为10 s是合理的。

表4 不同时间窗口下机器学习算法及本模型算法的准确率预测结果

时间窗口(s)	DNN	RF	KNN	NB	LR
1	0.643	0.743	0.421	0.322	0.345
2	0.684	0.784	0.483	0.364	0.367
3	0.715	0.789	0.577	0.382	0.397
4	0.708	0.812	0.682	0.396	0.405
5	0.732	0.809	0.740	0.402	0.417
6	0.817	0.812	0.802	0.425	0.421
7	0.834	0.832	0.856	0.440	0.427
8	0.851	0.844	0.865	0.463	0.432
9	0.897	0.854	0.871	0.456	0.438
10	0.922	0.863	0.896	0.452	0.448

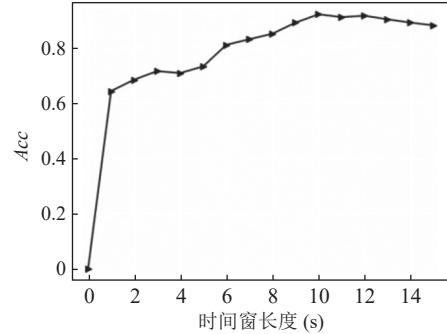


图6 不同时间窗口下模型预测准确率

对模型预测结果进行进一步分析，分析其预测结果与真实结果之间的差异，其结果如图7所示。统计结果显示，在所有评估案例中，模型将实际上表现不佳的接管行为错误分类为其他两类(良好或优秀)的情形占比为5.96%；相反，将实际表现优秀的接管误判为不佳类别的比例则较低，仅为0.63%。这意味着，模型在预测中出现了41例不安全接管行为被高估为安全的情况，以及相对较少的4例安全接管被误标为不安全接管的实例。尽管存在这些误差，模型的整体分类准确率依然维持在较高水平，彰显了其在评估接管绩效方面的稳健性和可靠性。

在车端部署时，受限于车载环境中的计算资源和响应时间，仅部署支持实时推理的离线训练模型。模型推理时间开销也是衡量模型好坏的重要指标之一。本模型的单次平均推理时间为1.02 ms，不同方法的推理时间如图8所示。在过往的研究中发现驾驶员在真实交通场景中的反应时间约为0.6833 s^[49]。从推理效率上看，本模型实现了与

其他模型中最优推理时间相近的表现,且判别准确率更高,能够在驾驶员尚未做出反应之前迅速而准确地评估接管性能,能为自动驾驶的安全驾驶提供重要参考.

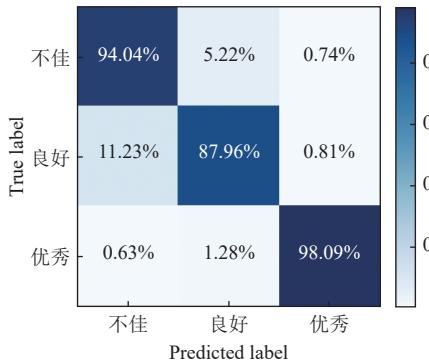


图 7 时间窗口为 10 s 时模型预测结果与真实值之间的混淆矩阵

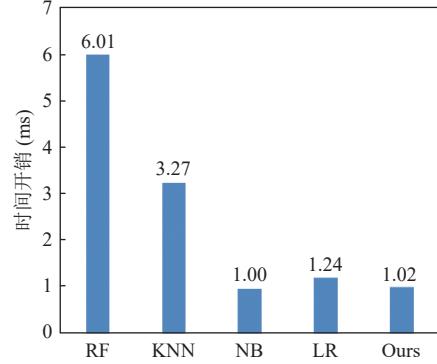


图 8 不同方法的推理时间对比

4.3.2 接管预测模型泛化性验证

为了验证模型的泛化能力,研究还将单一场景的多模态数据作为训练集,使用其他场景采集的数据作为测试集,对模型的泛化性进行了对比验证.采用单一特定场景的多模态数据集对接管绩效预测模型进行训练,并利用来自其他未包含于训练集场景的数据进行测试,实验结果见表 5.研究发现,当模型仅基于某一特定场景的训练数据进行预测时,其在相同场景下的接管绩效预测表现出较高准确性,然而,将其应用于预测其他场景下的接管绩效时,准确率显著下降,波动范围局限于 50%–70%,平均准确率为 55%–61%.这一表现与利用涵盖 6 种不同场景的综合数据集训练出的模型相比存在较大差距,后者在多场景测试中的准确率高达 92%,彰显了显著的泛化能力和优越性.

表 5 单一场景训练模型接管绩效预测准确率

数据来源场景编号	S1	S2	S3	S4	S5	S6	Average
S1	1.000	0.532	0.518	0.552	0.612	0.598	0.562
S2	0.546	1.000	0.572	0.562	0.608	0.584	0.574
S3	0.574	0.523	1.000	0.514	0.569	0.605	0.557
S4	0.602	0.537	0.626	1.000	0.592	0.671	0.606
S5	0.632	0.561	0.517	0.623	1.000	0.552	0.577
S6	0.613	0.547	0.608	0.658	0.637	1.000	0.613

尽管单一场景训练模型在跨场景预测时准确率有所下降,但仍保持了一定程度的鲁棒性,意味着模型在面临新环境的挑战时并未完全失效.相比之下,融合了 6 种场景数据训练而成的模型展现出了卓越的适应性和预测效能,能够有效跨越不同场景的界限,准确预测驾驶员在多样化环境下的接管表现,从而有力证明了多场景数据融合对于提升模型通用性和预测精度的重要性.

4.3.3 不同的特征对模型预测结果影响程度

为了深入分析不同特征对模型输出的影响,我们构建了一个以 DeepShap 为核心的 SHAP 模型解释器,利用该模型分析不同特征对神经网络预测结果的影响程度.该解释器能够处理多模态数据集,并评估每个特征在预测结果中的贡献.具体来说,我们使用预处理后的多模态数据集作为输入,通过计算每个特征的 Shapley 值,来量化其对模型预测结果的影响程度.这种方法不仅能提供模型决策过程的透明度,还能帮助我们理解哪些特征在模型中起到关键作用,从而为进一步优化模型提供指导.通过这种细致的分析,我们能够更好地解释和改进模型的性能.模型输出的影响程度结果如图 9 所示,其中 class 1、class 2、class 3 分别对应接管绩效不佳、良好、优秀.

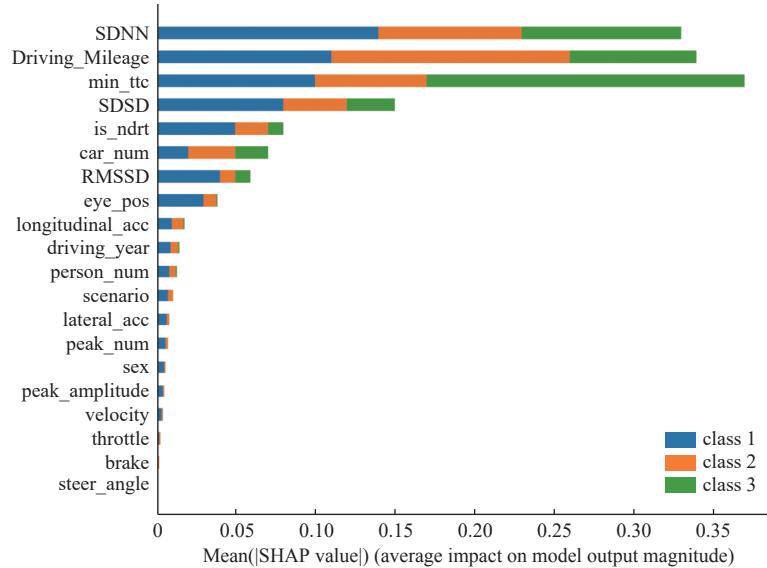


图 9 不同特征对输出的影响程度

SHAP 分析揭示, 对神经网络模型预测接管绩效影响最为显著的 8 大特征依次为: 心率变异性中 RR 间期的标准差、驾驶员累计驾驶经验(以里程计)、最近遭遇的最小安全距离、心率变异性中 RR 间期差的平方根平均值、执行非驾驶相关任务的频率、周围车辆数量、另一项反映心率变异性动态变化的指标——RR 间期差的平方根平均值以及驾驶员注视焦点的位置。具体而言, RR 间期标准差对判定接管绩效不佳情形的预测影响尤为突出, 而驾驶里程则显著影响对优异接管表现的正向预测, 最小碰撞距离成为判定接管操作卓越性的关键因素。由此可见, 确保模型对潜在不安全接管情况的精准预测尤为关键。

据此, 建议在自动驾驶交互系统设计及驾驶员在途监控中, 应重视对最近 10 s 窗口期内驾驶员心电活动特征的动态监测、车辆行进间最小安全间距的即时评估, 以及持续追踪驾驶员视线聚焦区域。当自动驾驶系统发出接管请求之际, 若模型预判驾驶员当前状态不利于安全接管, 可立即触发紧急靠边停车程序, 以此作为首要安全应对措施, 确保驾驶员及道路安全。

5 总 结

自动驾驶技术中的驾驶员接管研究是当前人机交互领域的一大研究热点, 尽管现有研究多集中于探究接管提示方式对驾驶员反应时间和接管表现的直接影响, 并有尝试运用机器学习技术来预测接管质量的相关研究, 但本研究在此基础上进行了更为深入的探索。针对有条件自动驾驶接管实验场景单一性的问题, 本研究依据事故分类和国家标准, 构建了 6 个典型的事故高发场景, 以丰富接管驾驶场景的多样性。针对 6 个典型驾驶场景, 系统地收集了驾驶员在接管过程中的多维度数据, 包括但不限于场景信息、生理信号、车辆动态数据及眼动追踪数据, 旨在全面分析并预测在有条件自动驾驶 (conditional autonomous driving) 模式下的接管绩效。结合国际标准和前人研究, 提出了一种涵盖车辆控制数据和接管反应时间的接管绩效评价标准。

在此基础上, 本研究提出了一种基于神经网络的预测模型, 该模型能够有效整合上述多模态数据, 利用深度学习的强大功能, 对驾驶员的接管绩效进行精准预测。尤为重要的是, 我们不仅限于模型的构建与预测性能的提升, 还进一步检验了模型的泛化能力。通过采用单一场景的训练数据来预测其他未见场景的接管质量, 我们严格验证了模型在面对新场景时的适应性和稳定性。

此外, 为了增强模型解释性和透明度, 本研究引入了 SHAP 模型进行特征重要性分析。SHAP 模型基于博弈论原理, 为各预测特征提供了定量化的贡献度评估, 清晰展现了哪些特征在预测接管绩效时发挥了关键作用。这一策

略不仅提升了模型的可信度, 还为理解自动驾驶接管过程中的关键影响因素提供了宝贵的洞见, 为未来的人机交互设计和自动驾驶系统的安全性优化奠定了坚实的理论与实证基础.

References:

- [1] Biondi F, Alvarez I, Jeong KA. Human–vehicle cooperation in automated driving: A multidisciplinary review and appraisal. *Int'l Journal of Human-computer Interaction*, 2019, 35(11): 932–946. [doi: [10.1080/10447318.2018.1561792](https://doi.org/10.1080/10447318.2018.1561792)]
- [2] SAE. J3016_201401 Taxonomy and definitions for terms related to on-road motor vehicle automated driving systems. SAE, 2014. 1.
- [3] Dogan E, Honnêt V, Masfrand S, Guillaume A. Effects of non-driving-related tasks on takeover performance in different takeover situations in conditionally automated driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2019, 62: 494–504. [doi: [10.1016/j.trf.2019.02.010](https://doi.org/10.1016/j.trf.2019.02.010)]
- [4] So JJ, Park S, Kim J, Park J, Yun I. Investigating the impacts of road traffic conditions and driver's characteristics on automated vehicle takeover time and quality using a driving simulator. *Journal of Advanced Transportation*, 2021, 2021(1): 8859553. [doi: [10.1155/2021/8859553](https://doi.org/10.1155/2021/8859553)]
- [5] Kim JW, Yang JH. Understanding metrics of vehicle control take-over requests in simulated automated vehicles. *Int'l Journal of Automotive Technology*, 2020, 21(3): 757–770. [doi: [10.1007/s12239-020-0074-z](https://doi.org/10.1007/s12239-020-0074-z)]
- [6] Soares S, Lobo A, Ferreira S, Cunha L, Couto A. Takeover performance evaluation using driving simulation: A systematic review and meta-analysis. *European Transport Research Review*, 2021, 13(1): 47. [doi: [10.1186/s12544-021-00505-2](https://doi.org/10.1186/s12544-021-00505-2)]
- [7] Yoon SH, Kim YW, Ji YG, Prevention. The effects of takeover request modalities on highly automated car control transitions. *Accident Analysis & Prevention*, 2019, 123: 150–158. [doi: [10.1016/j.aap.2018.11.018](https://doi.org/10.1016/j.aap.2018.11.018)]
- [8] DeGuzman CA, Kanaan D, Hopkins SA, Donmez B. Takeover request (TOR) effects during different automated vehicle failures. *Journal of Intelligent Transportation Systems*, 2021: 1–31. [doi: [10.1080/15472450.2021.1891536](https://doi.org/10.1080/15472450.2021.1891536)]
- [9] Deng HW, Xiang GL, Pan JD, Wu XH, Fan CJ, Wang K, Peng Y. How to design driver takeover request in real-world scenarios: A systematic review. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2024, 104: 411–432. [doi: [10.1016/j.trf.2024.06.012](https://doi.org/10.1016/j.trf.2024.06.012)]
- [10] Liu WM, Li QK, Wang WJ, Wang ZY, Zeng C, Cheng B. Deep learning based take-over performance prediction and its application on intelligent vehicles. *IEEE Trans. on Intelligent Vehicles*, 2024: 1–15. [doi: [10.1109/TIV.2024.3374528](https://doi.org/10.1109/TIV.2024.3374528)]
- [11] Dosovitskiy A, Ros G, Codevilla F, López AM, Koltun V. CARLA: An open urban driving simulator. In: Proc. of the 1st Annual Conf. on Robot Learning. Mountain View: CoRL, 2017. 1–16.
- [12] Cao YN, Zhou F, Pulver EM, Molnar LJ, Robert LP, Tilbury DM, Yang XJ. Towards standardized metrics for measuring takeover performance in conditionally automated driving: A systematic review. Proc. of the Human Factors and Ergonomics Society Annual Meeting, 2021, 65(1): 1065–1069. [doi: [10.1177/1071181321651213](https://doi.org/10.1177/1071181321651213)]
- [13] McDonald AD, Alambeigi H, Engström J, Markkula G, Vogelpohl T, Dunne J, Yuma N. Toward computational simulations of behavior during automated driving takeovers: A review of the empirical and modeling literatures. *Human Factors*, 2019, 61(4): 642–688. [doi: [10.1177/0018720819829572](https://doi.org/10.1177/0018720819829572)]
- [14] Gold C, Damböck D, Lorenz L, Bengler K. “Take over!” How long does it take to get the driver back into the loop? In: Proc. of the 57th Human Factors and Ergonomics Society Annual Meeting. 2013. 1938–1942.
- [15] Chen QX, Li JL, Tei KJ. Attention-guiding takeover requests for situation awareness in semi-autonomous driving. In: Proc. of the 2023 Companion of ACM/IEEE Int'l Conf. on Human-robot Interaction. Stockholm: ACM, 2023. 416–421. [doi: [10.1145/3568294.3580118](https://doi.org/10.1145/3568294.3580118)]
- [16] Heo J, Lee H, Yoon S, Kim K. Responses to take-over request in autonomous vehicles: Effects of environmental conditions and cues. *IEEE Trans. on Intelligent Transportation Systems*, 2022, 23(12): 23573–23582. [doi: [10.1109/TITS.2022.3201074](https://doi.org/10.1109/TITS.2022.3201074)]
- [17] Meteier Q, Capallera M, De Salis E, Angelini L, Carrino S, Abou Khaled O, Mugellini E, Sonderegger A. Effect of obstacle type and cognitive task on situation awareness and takeover performance in conditionally automated driving. In: Proc. of the 34th Conf. on l'Interaction Humain-machine. TROYES: ACM, 2023. 5. [doi: [10.1145/3583961.3583966](https://doi.org/10.1145/3583961.3583966)]
- [18] Hong S, Maeng J, Kim HJ, Yang JH. Development of warning methods for planned and unplanned takeover requests in a simulated automated driving vehicle. In: Proc. of the 14th Int'l Conf. on Automotive User Interfaces and Interactive Vehicular Applications. Seoul: ACM, 2022. 65–74. [doi: [10.1145/3543174.3545999](https://doi.org/10.1145/3543174.3545999)]
- [19] Sanghavi H, Zhang YQ, Jeon M. Exploring the influence of driver affective state and auditory display urgency on takeover performance in semi-automated vehicles: Experiment and modelling. *Int'l Journal of Human-computer Studies*, 2023, 171: 102979. [doi: [10.1016/j.ijhcs.2022.102979](https://doi.org/10.1016/j.ijhcs.2022.102979)]

- [20] Du N, Zhou F, Tilbury DM, Robert LP, Yang XJ. Behavioral and physiological responses to takeovers in different scenarios during conditionally automated driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2024, 101: 320–331. [doi: [10.1016/j.trf.2024.01.008](https://doi.org/10.1016/j.trf.2024.01.008)]
- [21] Koochaki F, Zheng ZK, Akash K, Misu T. Learn-able evolution convolutional Siamese neural network for adaptive driving style preference prediction. In: Proc. of the 2023 IEEE Intelligent Vehicles Symp. (IV). Anchorage: IEEE, 2023. 1–7. [doi: [10.1109/IV55152.2023.10186593](https://doi.org/10.1109/IV55152.2023.10186593)]
- [22] Gold C, Happee R, Bengler K. Modeling take-over performance in level 3 conditionally automated vehicles. *Accident Analysis & Prevention*, 2018, 116: 3–13. [doi: [10.1016/j.aap.2017.11.009](https://doi.org/10.1016/j.aap.2017.11.009)]
- [23] Ma S, Zhang W, Yang Z, Kang CY, Wu CX, Chai CL, Shi JL, Zeng YL, Li HT. Take over gradually in conditional automated driving: The effect of two-stage warning systems on situation awareness, driving stress, takeover performance, and acceptance. *Int'l Journal of Human-computer Interaction*, 2021, 37(4): 352–362. [doi: [10.1080/10447318.2020.1860514](https://doi.org/10.1080/10447318.2020.1860514)]
- [24] Ayoub J, Du N, Yang XJ, Zhou F. Predicting driver takeover time in conditionally automated driving. *IEEE Trans. on Intelligent Transportation Systems*, 2022, 23(7): 9580–9589. [doi: [10.1109/TITS.2022.3154329](https://doi.org/10.1109/TITS.2022.3154329)]
- [25] Pakdamanian E, Sheng SL, Baee S, Heo S, Kraus S, Feng L. DeepTake: Prediction of driver takeover behavior using multimodal data. In: Proc. of the 2021 CHI Conf. on Human Factors in Computing Systems. Yokohama: ACM, 2021. 103. [doi: [10.1145/3411764.3445563](https://doi.org/10.1145/3411764.3445563)]
- [26] Sajedinia Z, Akash K, Zheng ZB, Misu T, Dong MM, Krishnamoorthy V, Martinez K, Sureshbabu K, Huang GJ. Investigating users' preferences in adaptive driving styles for level 2 driving automation. In: Proc. of the 14th Int'l Conf. on Automotive User Interfaces and Interactive Vehicular Applications. Seoul: ACM, 2022. 162–170. [doi: [10.1145/3543174.35446088](https://doi.org/10.1145/3543174.35446088)]
- [27] Zhu JY, Ma YL, Zhang YR, Zhang YP, Lv C. Takeover quality prediction based on driver physiological state of different cognitive tasks in conditionally automated driving. *Advanced Engineering Informatics*, 2023, 57: 102100. [doi: [10.1016/j.aei.2023.102100](https://doi.org/10.1016/j.aei.2023.102100)]
- [28] Chen HL, Zhao XH, Li HJ, Gong JG, Fu Q. Predicting driver's takeover time based on individual characteristics, external environment, and situation awareness. *Accident Analysis & Prevention*, 2024, 203: 107601. [doi: [10.1016/j.aap.2024.107601](https://doi.org/10.1016/j.aap.2024.107601)]
- [29] Gu Y, Weng YB, Wang YT, Wang M, Zhuang GH, Huang JY, Peng XL, Luo L, Ren FJ. EmoTake: Exploring drivers' emotion for takeover behavior prediction. *IEEE Trans. on Affective Computing*, 2024, 15(4): 2112–2127. [doi: [10.1109/TAFFC.2024.3399328](https://doi.org/10.1109/TAFFC.2024.3399328)]
- [30] Li RJ, Qin TH, Widdershoven C. ISS-Scenario: Scenario-based testing in CARLA. In: Proc. of the 18th Int'l Symp. on Theoretical Aspects of Software Engineering. Guiyang: Springer, 2024. 279–286. [doi: [10.1007/978-3-031-64626-3_16](https://doi.org/10.1007/978-3-031-64626-3_16)]
- [31] Najm WG, Smith JD, Yanagisawa M. Pre-crash scenario typology for crash avoidance research. National Highway Traffic Safety Administration, 2007.
- [32] State Administration for Market Regulation, Standardization Administration of China. GB/T 41798-2022 Intelligent and connected vehicles—track testing methods and requirements for automated driving functions. Beijing: China Standard Press, 2022. 36. (in Chinese)
- [33] ISO. ISO 34504: 2024 Road vehicles—test scenarios for automated driving systems—scenario categorization. Geneva: ISO, 2024.
- [34] Alrefaei MT, Summerskill S, Jackson TW. In a heart beat: Using driver's physiological changes to determine the quality of a takeover in highly automated vehicles. *Accident Analysis & Prevention*, 2019, 131: 180–190. [doi: [10.1016/j.aap.2019.06.011](https://doi.org/10.1016/j.aap.2019.06.011)]
- [35] Radhakrishnan V, Merat N, Louw T, Gonçalves RC, Torrao G, Lyu W, Guillen PP, Lenné MG. Physiological indicators of driver workload during car-following scenarios and takeovers in highly automated driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2022, 87: 149–163. [doi: [10.1016/j.trf.2022.04.002](https://doi.org/10.1016/j.trf.2022.04.002)]
- [36] Massaro S, Pecchia L. Heart rate variability (HRV) analysis: A methodology for organizational neuroscience. *Organizational Research Methods*, 2019, 22(1): 354–393. [doi: [10.1177/1094428116681072](https://doi.org/10.1177/1094428116681072)]
- [37] Zhou F, Yang XJ, De Winter JCF. Using eye-tracking data to predict situation awareness in real time during takeover transitions in conditionally automated driving. *IEEE Trans. on Intelligent Transportation Systems*, 2022, 23(3): 2284–2295. [doi: [10.1109/TITS.2021.3069776](https://doi.org/10.1109/TITS.2021.3069776)]
- [38] Liu P, Zhang YW, He Z. The effect of population age on the acceptable safety of self-driving vehicles. *Reliability Engineering & System Safety*, 2019, 185: 341–347. [doi: [10.1016/j.ress.2019.01.003](https://doi.org/10.1016/j.ress.2019.01.003)]
- [39] Siegfried AL, Bayne A, Beck LF, Freund K. Older adult willingness to use fully autonomous vehicle (FAV) ride sharing. *Geriatrics*, 2021, 6(2): 47. [doi: [10.3390/geriatrics6020047](https://doi.org/10.3390/geriatrics6020047)]
- [40] Abraham H, Lee C, Brady S, Fitzgerald C, Mehler B, Reimer B, Coughlin JF. Autonomous vehicles and alternatives to driving: Trust, preferences, and effects of age. In: Proc. of the 96th Annual Meeting on Transportation Research Board. Washington: Transportation Research Board, 2017. 8–12.
- [41] Eriksson A, Stanton NA. Takeover time in highly automated vehicles: Noncritical transitions to and from manual control. *Human Factors*, 2017, 59(4): 689–705. [doi: [10.1177/0018720816685832](https://doi.org/10.1177/0018720816685832)]

- [42] Naujoks F, Purucker C, Wiedemann K, Marberger C. Noncritical state transitions during conditionally automated driving on German freeways: Effects of non-driving related tasks on takeover time and takeover quality. *Human Factors*, 2019, 61(4): 596–613. [doi: [10.1177/0018720818824002](https://doi.org/10.1177/0018720818824002)]
- [43] Wu HR, Wu CZ, Lyu NC, Li JN, prevention. Does a faster takeover necessarily mean it is better? A study on the influence of urgency and takeover-request lead time on takeover performance and safety. *Accident Analysis & Prevention*, 2022, 171: 106647. [doi: [10.1016/j.aap.2022.106647](https://doi.org/10.1016/j.aap.2022.106647)]
- [44] ISO. ISO/TR 21959-2: 2020 Road vehicles—human performance and state in the context of automated driving. Geneva: ISO, 2020.
- [45] Doubek F, Loosveld E, Happee R, De Winter J. Takeover quality: Assessing the effects of time budget and traffic density with the help of a trajectory-planning method. *Journal of Advanced Transportation*, 2020, 2020(1): 6173150. [doi: [10.1155/2020/6173150](https://doi.org/10.1155/2020/6173150)]
- [46] Liu WB, Wang ZD, Liu XH, Zeng NY, Liu YR, Alsaadi FE. A survey of deep neural network architectures and their applications. *Neurocomputing*, 2017, 234: 11–26. [doi: [10.1016/j.neucom.2016.12.038](https://doi.org/10.1016/j.neucom.2016.12.038)]
- [47] Lundberg SM, Lee SI. A unified approach to interpreting model predictions. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 4768–4777.
- [48] Mahesh B. Machine learning algorithms-a review. *Int'l Journal of Science and Research*, 2020, 9(1): 381–386. [doi: [10.21275/ART20203995](https://doi.org/10.21275/ART20203995)]
- [49] Droździel P, Tarkowski S, Rybicka I, Wrona R. Drivers' reaction time research in the conditions in the real traffic. *Open Engineering*, 2020, 10(1): 35–47. [doi: [10.1515/eng-2020-0004](https://doi.org/10.1515/eng-2020-0004)]

附中文参考文献:

- [32] 国家市场监督管理总局, 国家标准化管理委员会. GB/T 41798-2022 智能网联汽车 自动驾驶功能场地试验方法及要求. 北京: 中国标准出版社, 2022. 36.



张杨杨(2000—), 女, 硕士生, CCF 学生会员, 主要研究领域为自动驾驶仿真测试, 人机交互.



冷昶(1986—), 男, 博士, 副研究员, 主要研究领域为实时系统, 实时交互基础理论, 安全攸关系统.



张浩(1993—), 男, 博士, 助理研究员, 主要研究领域为人机交互, 用户行为建模.



黄承超(1992—), 男, 博士, 副研究员, 主要研究领域为符号与代数计算, 自动推理, 形式化方法.



甘涛(2000—), 男, 硕士, 主要研究领域为机器学习, 人机交互.



张立军(1979—), 男, 博士, 研究员, 博士生导师, 主要研究领域为概率模型检测, 协议验证, 学习算法, 自动驾驶系统验证.