

# 智能网联车辆 个性化运动控制与测试评价方法

李浩然 郑四发 孙川 许述财 著

Personalized  
Motion  
Control  
and  
Test  
Evaluation  
Method  
for  
Connected  
Vehicles

清华大学出版社  
北京

## 内 容 简 介

本书针对自动驾驶车辆的个性化决策、规划、控制及测评方法展开研究,建立自动驾驶车辆的决策框架,利用自然驾驶实验分析的结果标定模型参数,提出体现人类驾驶行为的自动驾驶方法,在此基础上研究考虑环境车行为特征的自动驾驶系统,使车辆的自动驾驶能够体现人类驾驶员的个性特征,最后构建测试评价体系,实现算法的量化测试。

本书的研究不仅能改善驾驶员/乘员对自动驾驶的接受度,还能够提高道路交通安全水平,促进自动驾驶车辆的应用与推广。本书可作为智能汽车、智能交通领域的科研人员和工程技术人员的参考书。

版权所有,侵权必究。举报:010-62782989, beiqinquan@tup.tsinghua.edu.cn。

### 图书在版编目(CIP)数据

智能网联车辆个性化运动控制与测试评价方法/李浩然等著. —北京:清华大学出版社,2023.2  
ISBN 978-7-302-62738-8

I. ①智… II. ①李… III. ①汽车—智能通信网—运动控制—测试 ②汽车—智能通信网—运动控制—评价 IV. ①U463.67

中国国家版本馆 CIP 数据核字(2023)第 027748 号

责任编辑:许 龙  
封面设计:傅瑞学  
责任校对:赵丽敏  
责任印制:丛怀宇

出版发行:清华大学出版社

网 址: <http://www.tup.com.cn>, <http://www.wqbook.com>

地 址:北京清华大学学研大厦 A 座 邮 编:100084

社 总 机:010-83470000

邮 购:010-62786544

投稿与读者服务:010-62776969, c-service@tup.tsinghua.edu.cn

质量反馈:010-62772015, zhiliang@tup.tsinghua.edu.cn

印 装 者:大厂回族自治县彩虹印刷有限公司

经 销:全国新华书店

开 本:185mm×230mm 印 张:8.5

字 数:181千字

版 次:2023年2月第1版

印 次:2023年2月第1次印刷

定 价:59.00元

---

产品编号:100157-01

# 前 言

车辆自动驾驶系统始终要为人提供服务,因此需考虑人类的个性化驾驶需求。在实际的道路交通环境中,不同驾驶员的驾驶行为特性具有显著差异性,单一行为模式的自动驾驶决策与控制方式无法适应不同驾驶员的驾乘需求。特别地,对于高级别自动驾驶而言,若自动驾驶行为与人类预期不相符,会降低人类对自动驾驶系统的接受度,并在紧急情况下引发人类驾驶员的恐慌,进而造成安全事故。然而,当前的自动驾驶车辆决策、规划与控制,未考虑不同人类驾驶员之间的行为差异性。

本书针对自动驾驶车辆的个性化决策、规划、控制及测评方法展开研究,建立自动驾驶车辆的决策框架,利用自然驾驶实验分析的结果标定模型参数,提出体现人类驾驶行为的自动驾驶方法,在此基础上研究考虑环境车行为特征的自动驾驶系统,使车辆的自动驾驶能够体现人类驾驶员的个性特征,最后构建测试评价体系,实现算法的量化测试。具体地,本书开展的研究工作如下:

(1) 利用高速公路自然驾驶数据,提取典型驾驶场景下的个性化驾驶操作特征。通过开展自然驾驶实验,基于时序模糊 C 均值聚类算法,将换道、跟驰数据划分为不同的阶段,分析不同驾驶员在跟驰、换道场景下的车头时距、车道偏移、速度、航向角、加速度、横摆角速度及横摆角加速度的差异。根据所需标定的参数数量以及不同驾驶员自然驾驶特征变量差异的显著程度,选取车头时距、加速度以及横摆角加速度变量作为体现驾驶员差异性的指标。

(2) 基于混成自动机方法,提出个性化自动驾驶行为决策框架。针对体现人类驾驶行为的自动驾驶和考虑环境车行为特征的自动驾驶,分别设计混成自动机决策框架。基于改进的人工势场方法,提出自动驾驶车辆的个性化轨迹规划方法。建立障碍物势场(如路面散落物)、道路势场、环境车势场等,结合自然驾驶状态下典型驾驶场景的个性化操作特征,对人工势场模型的主要参数进行标定,生成个性化轨迹。

(3) 基于改进的模型预测控制(Model Predictive Control, MPC)方法,设计能适应多种典型驾驶场景的个性化轨迹跟踪控制器。为了消除传统 MPC 控制器内部模型失真造成的

稳态误差,在传统 MPC 算法中加入一个 PID 反向通道。同时,为解决 MPC 控制器消耗过多计算资源的问题,对其进行显式化,将优化求解的过程离线处理,实现 MPC 的实时控制。然后,基于混成自动机,实现在不同驾驶场景下多控制器的模式切换。最后,基于机会约束模型将不同驾驶员的操作特性引入 MPC 控制算法中。

(4) 研究考虑环境车行为特征的决策、规划与控制方法。提出驾驶行为相容性的评价指标,针对不同的驾驶行为相容性程度,自动驾驶车辆与环境车之间采取不同的协同策略,并设计基于分布式 MPC 算法结构的自动驾驶控制器,避免出现未考虑环境车行为特征的“误判”的情况,使控制结果更加符合驾驶员的个性化需求。

(5) 研究个性化算法的测试评价体系。通过层次分析法和德尔菲法搭建了自动驾驶车辆的评价指标体系,并将其分为多个层级。通过综合考虑主、客观权重的方法融合得到的综合权重确认方法来确认自动驾驶车辆智能水平定量综合评价体系每个层级中所有评价指标权重。最终通过模糊综合评价法对自动驾驶车辆进行综合定量评价,并计算得出该自动驾驶车辆综合智能水平分数的最终结果。

本书针对自动驾驶车辆的个性化决策、规划、控制与测评问题展开研究。一方面,建立自动驾驶车辆的决策、规划与控制系统架构,在自然驾驶实验分析基础上标定模型参数,使其能够体现人类驾驶员的个性特征;另一方面,通过软件在环仿真、硬件在环仿真和实车实验三种实验方式,对决策、规划与控制方法进行了验证。本书提出的个性化决策、规划与控制算法,能够控制车辆较为平稳地完成跟驰、换道等典型的驾驶场景,并体现出一定的驾驶行为个性。该研究不仅能改善驾驶员/乘员对自动驾驶的接受度,还能够提高道路交通安全水平,促进自动驾驶车辆的应用与推广。

本书是作者在近年来研究工作的基础上写作而成的,衷心感谢清华大学车辆与运载学院郑四发教授、王建强教授,以及武汉理工大学智能交通系统研究中心吴超仲教授、褚端峰研究员。本书的研究成果为作者在武汉理工大学智能交通系统研究中心攻读博士学位期间,在日本京都大学博士联合培养期间,在清华大学苏州汽车研究院/车辆与运载学院博士后工作期间以及武汉科技大学工作期间所得,向所有帮助过作者的领导、教授与同事们一并表示感谢。同时也感谢有关领导对作者工作以及书稿出版的支持。该专著出版受国家重点研发计划(2018YFE0204302)、国家自然科学基金(52002215)、江苏省青年基金项目(BK20220243)、苏州市工业和信息化局产业链核心技术攻关项目(20210210SB0053)的资助。限于作者的水平,书中难免有缺点与不完善之处,恳请批评指正。

作 者

2023 年 1 月

# 目录

第 1 章 绪论 .....	1
1.1 研究背景及意义 .....	1
1.2 国内外研究现状与分析 .....	2
1.2.1 个性化驾驶研究现状 .....	2
1.2.2 驾驶员行为建模研究现状 .....	3
1.2.3 自动驾驶决策规划与控制研究现状 .....	6
1.3 研究内容 .....	7
第 2 章 面向个性化自动驾驶的自然驾驶数据分析 .....	9
2.1 自然驾驶实验 .....	9
2.2 自然驾驶数据分析 .....	11
2.3 个性化驾驶行为特征提取 .....	15
2.3.1 跟驰场景下的驾驶行为特征提取 .....	16
2.3.2 换道场景下的驾驶行为特征提取 .....	22
2.4 个性化驾驶行为特征验证 .....	27
2.5 本章小结 .....	29
第 3 章 个性化自动驾驶决策框架 .....	31
3.1 体现人类驾驶行为的自动驾驶决策框架 .....	34
3.2 考虑环境车行为特征的自动驾驶决策框架 .....	35
3.3 本章小结 .....	37
第 4 章 基于人工势场法的自动驾驶轨迹规划 .....	38
4.1 障碍物势场建模 .....	38
4.2 道路势场建模 .....	39

4.3	环境车势场建模 .....	40
4.4	本章小结 .....	43
<b>第5章</b>	<b>面向个性化车辆轨迹跟踪的 MPC 算法 .....</b>	<b>44</b>
5.1	车辆横向反馈控制算法 .....	45
5.2	车辆纵向控制算法 .....	52
5.3	反馈 MPC 的软件在环仿真测试 .....	55
5.4	本章小结 .....	60
<b>第6章</b>	<b>考虑环境车行为特征的分布式 MPC 算法 .....</b>	<b>61</b>
6.1	基于驾驶行为相容性分析的自动驾驶行为决策 .....	62
6.2	分布式 MPC 控制设计 .....	67
6.3	分布式 MPC 的软件在环仿真测试 .....	71
6.4	本章小结 .....	72
<b>第7章</b>	<b>个性化自动驾驶实验测试平台 .....</b>	<b>73</b>
7.1	硬件在环 .....	74
7.1.1	硬件在环仿真测试平台 .....	74
7.1.2	仿真实验结果及分析 .....	80
7.2	实车测试 .....	88
7.2.1	实车测试平台 .....	88
7.2.2	实车实验结果及分析 .....	91
7.3	本章小结 .....	93
<b>第8章</b>	<b>个性化自动驾驶车辆综合能力的定量评价 .....</b>	<b>94</b>
8.1	自动驾驶智能水平等级划分 .....	94
8.2	自动驾驶车辆评价指标体系 .....	95
8.2.1	评价指标体系建立 .....	95
8.2.2	评价指标的选取 .....	96
8.3	自动驾驶车辆评价指标权重的确定 .....	98
8.3.1	熵值法 .....	98
8.3.2	序关系分析法 .....	99
8.3.3	综合权重 .....	100
8.4	自动驾驶车辆智能水平的综合定量评价 .....	100
8.4.1	模糊综合评价法 .....	100
8.4.2	测试条件评价模型建立 .....	101

---

8.5 本章小结 .....	102
参考文献 .....	103
附录 A .....	107
附录 B .....	122

清华大学出版社

清华大学出版社

# 第1章

## 绪论

### 1.1 研究背景及意义

随着汽车产业的不断发展和汽车保有量的迅速攀升,汽车在带来出行方便的同时也造成了交通事故、交通拥堵等问题。自动驾驶车辆的发展为这些问题提供了新的解决方案。自动驾驶车辆的发展将升级我国传统交通体系,改变人-车-路之间的关系。

自动驾驶车辆的控制系统通常由“感知融合—决策规划—运动控制”三个部分构成。自动驾驶车辆系统由感知层接收信息,并对这些信息进行融合处理,随后展开决策及轨迹规划,再由车辆控制器控制自动驾驶车辆,引导车辆进行预定的操作(如跟踪期望轨迹),从而完成车辆行驶任务。

在现有研究中,自动驾驶车辆的决策和规划较少考虑不同驾驶员之间的差异性。在实际的道路交通中,不同驾驶员的车辆操作特点是不同的。以跟驰和换道场景为例:在跟驰场景中,个性激进的驾驶员倾向于保持较近的跟车距离,而个性保守的驾驶员则偏向于保持较大的跟车距离;在换道场景中,个性激进的驾驶员换道迅速,而个性保守的驾驶员会尽可能使车辆平缓地完成换道过程。传统的固定模式的决策、规划与控制方式已经难以适应不同驾驶员/乘员对车辆行驶的个性化需求。因此,有必要分析驾驶员的实际操作数据,研究驾驶员的个性化特征,根据个性化特征设计、开发个性化的自动驾驶车辆决策、规划和控制系统。自动驾驶车辆的个性化行驶的优点为:①能够提高驾驶员/乘员对自动驾驶技术的接受度,促进自动驾驶的推广;②在自动-非自动混合行驶的交通环境中,能够使自动驾驶车辆更好地融入到非自动驾驶的交通流中,保证交通系统的稳定和安全。

本书在车路协同环境下对智能网联车辆提出基于混成自动机的自动驾驶车辆决策框架,基于该架构,设计个性化的自动驾驶车辆决策、规划与控制系统,并且通过搭建实验测试平台等一系列方法对车辆个性化运动控制与测试提出可靠的评价方法。具体包括以下研究内容:①开展自然驾驶实验,采集、分析驾驶员在高速公路场景中的自然驾驶数据,研究典型驾驶场景中驾驶员的个性化特征;②建立基于改进人工势场算法的轨迹规划模型,利用

自然驾驶数据分析的驾驶员个性化特征,对人工势场模型进行标定,标定后的模型能够产生个性化的期望轨迹;③设计基于改进模型预测控制方法的跟踪控制器,以实现期望轨迹进行稳定、准确地跟踪;④搭建硬件在环测试平台以及实车测试平台对车辆决策、规划与控制的功能及可靠性进行进一步的测试,并对车辆的综合能力进行评价。

## 1.2 国内外研究现状与分析

本节从个性化驾驶,驾驶员行为建模,自动驾驶决策、规划与控制三个方面对与本书相关的国内外研究现状进行整理和分析。

### 1.2.1 个性化驾驶研究现状

驾驶风格(Driving Style)是当前驾驶行为研究的一个热点,它的研究对象是由驾驶员的习惯、心理、性格等形成的外在操作特点,具体体现在驾驶员驾驶期间的车速、加速度、车头时距等变量。目前,驾驶风格的分类是驾驶行为研究的一个重要方面,是对驾驶员驾驶行为评价的主要依据之一。近年来,从驾驶风格的角度探究交通安全问题逐渐成为一个研究热点。

驾驶风格的成因很复杂,是一个涉及心理学和社会学的研究问题。国内外学者对其进行了大量的分析,一般情况下,影响驾驶员驾驶风格的因素主要包括年龄、性格、性别、家庭等<sup>[1]</sup>。

国内外学者进行驾驶风格研究主要是通过问卷调查、测量量表等传统手段,如驾驶员行为测量量表(Driver Behavior Inventory, DBI)<sup>[2]</sup>。近年来,随着智能交通的快速发展,先进的车载数据采集技术为利用实车实验和模拟实验数据进行驾驶风格研究提供了便利的条件。Zoran 等利用车载设备采集的实际道路车辆行驶数据,分析了驾驶员的行为特点(包括驾驶员的平均车速、超速率、正向加速度均值等),建立了驾驶风格评价模型,在此基础上基于主成分分析、聚类分析等方法进行驾驶风格的识别<sup>[3]</sup>。Murphey 等根据实际行车状态下驾驶员加减速的强度进行驾驶风格的辨识,区分出平稳型、正常型和侵略型的驾驶员。之后进行了驾驶模拟实验,实验结果表明:侵略型的驾驶操作燃油消耗量最大<sup>[4]</sup>。Joeri 等探究了驾驶风格与燃油消耗以及污染物排放之间的相关性关系。结合实际道路实验和驾驶模拟实验的方法,研究了不同驾驶风格驾驶员的燃油消耗及污染物排放水平。国内学者也进行了大量相关的研究<sup>[5]</sup>。罗强等根据驾驶员历史行车数据中车辆横向状态变化规律,建立了驾驶风格分类决策系统<sup>[6]</sup>。王畅等开展了实车实验,分析了 20 名被试的实验数据,基于模糊综合评价方法,以车头时距、换道时长、超速率等特征参数,将被试驾驶员进行驾驶风格的分类<sup>[7]</sup>。Bellem 等利用模拟实验数据研究不同驾驶员对不同驾驶风格自动驾驶车辆的适应程度<sup>[8]</sup>。Qi 等利用实际驾驶员操作数据建立了驾驶风格的辨识模型,该模型能够快速准确地对驾驶员的驾驶风格进行识别<sup>[9]</sup>。

由上可知,当前个性化驾驶的研究还主要停留在研究驾驶风格的层面。传统的基于评价量表及调查问卷的驾驶风格研究方法有很强的主观性,研究结果不可避免地存在偏差。国内外研究者转而利用更为客观的实际行车数据来提取驾驶员的操作特性,据此进行驾驶风格研究。当前,智能交通系统正在向更为精细的个性化方向发展,寻求为驾驶员/乘员提供个性化的服务。因此,仅仅局限于三种或五种驾驶风格的分类不能满足该发展趋势的需求,故需要提取单个驾驶员的操作特征,研究单个驾驶员的个性化特征。大数据和自动驾驶技术的进步也为这一需求的实现提供了有力的支持。

### 1.2.2 驾驶员行为建模研究现状

驾驶员模型是指能够反映驾驶员操作特点的数学模型。驾驶员操纵车辆的一般过程为:感知环境信息,基于获得的信息进行决策规划,最后对车辆进行横向和纵向的控制。

1967年McRuer等开启了车辆驾驶员模型的研究,他们将飞行员驾驶员模型的研究方法引入到车辆领域<sup>[10]</sup>。此后的驾驶员模型的研究主要分为基于传递函数的驾驶员行为建模、基于最优控制的驾驶员行为建模、基于数据的驾驶员行为建模等三类。

#### 1. 基于传递函数的驾驶员行为建模

直观上,可以从控制理论的角度来解释驾驶员操纵车辆的行为,即驾驶行为就是驾驶员采用一定的控制律来消除实际轨迹与期望轨迹的误差的过程。基于古典控制理论方法的驾驶员模型最常见的为预瞄跟随模型,该模型能以较高的精度跟踪期望路径。控制过程如图1-1所示,图中 $G(s)$ 代表本车模型,驾驶员模型的感知模块 $P(s)$ 获取环境信息,根据该信息控制模块 $H(s)$ 输出对应的控制量,期望输出和实际输出之间有误差,则反馈模块 $B(s)$ 对该误差进行矫正。国内外学者基于实际情况,采用不同的数学模型(传递函数)对以上各个模块进行建模。驾驶员预瞄感知模块 $P(s)$ 可用迟滞环节<sup>[11]</sup>,反馈模块 $B(s)$ 可用微分环节或迟滞环节<sup>[12]</sup>,驾驶员控制模块 $H(s)$ 可用比例环节或神经肌肉模型<sup>[13]</sup>。我国汽车领域的著名专家郭孔辉院士,在该框架的基础上建立了驾驶员模型,该模型不仅考虑了驾驶员预瞄、延迟、跟踪等因素,还能够体现出驾驶员对本车动力学的认知情况与反应能力<sup>[14]</sup>。但是,该类建模方法没有考虑复杂的道路环境和驾驶场景对驾驶员及车辆运行的影响,并且基于线性控制方法的建模方式太简单,因此不适用于面向主动安全系统开发的驾驶员模型的建立。




图 1-1 基于传递函数的预瞄驾驶员模型基本结构<sup>[15]</sup>

## 2. 基于最优控制的驾驶员行为建模

最优控制理论是指设计目标系统的数学模型,并设定对应的约束条件,将控制问题转化为优化问题进行求解。驾驶员的驾驶操作可以看作一个控制任务,则驾驶员在一定环境下的行车操作可以简化为一个优化问题,因此可以基于最优控制理论进行驾驶员模型的研究。

1980年 MacAdam 等结合预瞄控制模型,第一次将最优控制理论运用于驾驶员模型研究领域,目标函数为预测路径和参考路径的误差值,约束条件为车辆的运动学/动力学约束<sup>[16]</sup>。此后,Peng 等提出了精度更高的转向驾驶员模型,该模型设计了一个二次目标函数,该函数能够体现侧向加速度误差、侧向轨迹跟踪误差和姿态角误差<sup>[17]</sup>。Sharp 等依据线性二次型控制(Linear Quadratic Regulator, LQR)框架提出了多点预瞄线性控制驾驶员模型。区别于 MacAdam 的连续控制模型,该模型采用离散的车辆动力学模型,求解的二次代价函数包含了离散的路径误差和航向角误差<sup>[18]</sup>。在 Sharp 等的研究基础上,Odhams 等开展了多种工况下的模拟驾驶实验,利用模拟驾驶实验数据对 Sharp 等的线性转向驾驶员模型进行参数标定,并引入了神经肌肉模型来建立驾驶员模型<sup>[19]</sup>。

基于模型预测控制(Model Predictive Control, MPC)的驾驶员行为模型是该方向的一个重要分支。MPC 是一种利用滚动优化思想运行的控制策略,在每一个控制步长,基于系统当前的状态预测未来一定时间窗口内系统的状态,然后对控制量进行优化,以获取最优的控制输出,控制量作用于系统后,系统的状态获得更新,然后循环上面的过程。这个工作原理与人类驾驶员操纵车辆的方式很相近,人类驾驶员首先感知到当前时刻的车辆和交通的信息,大脑根据常识和驾驶经验,通过当前的车辆和交通状态预测未来一段时间内车辆和交通系统的状态,然后选择最理想的车辆控制方式,通过车辆控制系统对车辆进行横纵向控制,使本车获得新的状态,然后不停地循环上面的步骤。此外,驾驶员的驾驶行为会受到车辆动力学、交通流量、气候、路面状况等因素的限制,从这个角度来看,又与 MPC 在多约束条件下优化求解的思想是一致的,可见 MPC 算法与驾驶员的操作行为高度契合。因此,近年来 MPC 方法在汽车控制上得到了广泛的发展和應用。Ungoren 等改进了 MacAdam 等的驾驶员模型,将路径偏差与路径偏差变化率引入到目标函数中<sup>[20]</sup>。Cole 等对比了基于 LQR 和 MPC 两种方法的驾驶员转向控制模型,发现当 MPC 算法的控制时域与预测时域足够长时,基于 MPC 与 LQR 的驾驶员模型的控制性能很接近<sup>[21]</sup>。Falcone 等深入研究了基于 LTV 的模型预测控制器,计算出了使 LTV-MPC 控制器渐近稳定的充分条件,并在湿滑路面上对该充分条件进行了验证,结果表明:该条件下路径跟踪的过程中本车具有稳定的横向状态特性<sup>[22]</sup>。

内部模型是 MPC 控制方法的核心,换句话说,其内部模型的精度越高, MPC 的控制效果也就越好。因此,如何提高 MPC 内部模型的精确性,成为一个研究的热点。通常情况下,应用于传统 MPC 内部模型的数学模型为线性的车辆运动学模型,并未考虑系统机构的非线性特征,这其中对车辆运动状态影响最大的是轮胎的非线性特征。基于线性车辆动力学模型 MPC 算法的驾驶员模型作用于真实车辆时,由于实际车辆是一个复杂的非线性系

统,因此必然会导致输出的控制量和实际需要的控制量之间有一定的误差。当前,国内外学者解决这一问题的主要思路是设计拥有复杂非线性车辆动力学内模的 MPC 驾驶员模型。Keen 等基于模型预测控制方法设计了一个非线性驾驶员转向模型,该驾驶员模型利用考虑轮胎非线性侧偏特性的车辆动力学模型作为内模来设计 MPC 控制器<sup>[23]</sup>。采用分段线性化的方式拟合轮胎的非线性特性,得到考虑轮胎非线性特性的分段非线性车辆动力学模型,使 MPC 的内模和实际的车辆状态特性更加相符。仿真实验结果表明:这种分段非线性内模框架与 MPC 相结合的方法能够稳定、准确、快速地控制具有大量非线性特征的汽车。此外,Keen 等开展了实车实验,根据采集的实验数据对 MPC 转向控制器的主要参数进行标定。参数标定的方法是以最小化转向角预测误差为目标的间接标定方法,该方法能够在一定程度上消除系统噪声干扰<sup>[24]</sup>。

上述讨论的基于 MPC 方法的驾驶员建模方法虽然能够模仿驾驶员的决策、规划与控制过程及相关的约束条件,但车辆与交通系统受到了多种不确定性及随机因素的影响,而传统的 MPC 算法很难处理包含大量随机与不确定性的问题。国内外学者开始针对这一问题展开研究,有研究利用鲁棒控制的思想改进 MPC 算法,可以在一定程度上处理噪声扰动及其不确定性,但是该模型的保守性太强,不符合人类决策控制的习惯<sup>[25]</sup>。针对以上问题,有学者在理论上从不同角度将概率思想引入到 MPC 方法中,形成了基于随机模型预测控制(Stochastic Model Predictive Control, SMPC)的驾驶员行为模型。比如,郭孔辉院士基于 SMPC 方法将天气、道路环境及驾驶员的身心特征的不确定性引入到驾驶员模型中,取得了很好的决策控制效果<sup>[26]</sup>,该方法可以在降低系统保守性与应对随机性问题方面取得平衡,获得了良好的控制效果。

MPC 方法能够较好地描述驾驶员的感知-决策-控制过程,并能够体现出驾驶场景中的各类约束条件,该方法十分适合于建立驾驶员模型。该方法的最大问题是其内模的精确性直接影响到控制效果的好坏。因此,国内外学者进行了大量的研究以期提高 MPC 方法的控制精度,主要做法有两种:一是利用非线性的车辆动力学模型建立 MPC 的内模,以此体现车辆系统的非线性特征;二是引入概率论的方法建立基于 SMPC 的驾驶员模型以体现人-车-路系统的不确定性干扰。这两种方法都取得了较好的效果,但是基于这两种思路设计的驾驶员模型结构十分复杂,参数标定难度较高,很难应用于实际工程之中。随着当前自动驾驶技术的迅速发展,自动驾驶车辆产业化的趋势日趋显著,因此急需一个不依赖于内模精确的 MPC 方法。

### 3. 基于数据的驾驶员行为建模

融合通信、感知、定位和计算机等技术为一体的智能交通系统在运行的过程中会产生海量的、多维度的道路、车辆、行人、交通等运行情况的数据。基于数据挖掘和人工智能技术,利用智能交通大数据建立道路、车辆、驾驶员等交通元素的精确模型已逐渐成为研究的热点。

驾驶员的驾驶行为会受到天气、行人、路面状况等多种外界因素以及视觉、感知、情绪、

疲劳等内部因素的影响,这些因素都具有随机性和不确定性,因此在进行高精度的驾驶员模型研究时,一般都会考虑利用随机变量或随机过程方法。Peng 等利用不确定性的思想,建模驾驶员的跟车行为。并利用实验数据标定模型的各种参数,获得了可以较为准确地模拟驾驶员特征的跟车行为模型<sup>[27]</sup>。Zou 等基于隐马尔可夫模型(Hidden Markov Model, HMM)方法对驾驶员在交叉路口场景中的驾驶行为进行分析和建模,该驾驶员 HMM 模型可以对交叉口的驾驶员行为进行模拟和预测<sup>[28]</sup>。Yuan 等基于 HMM 算法建立了城市巴士驾驶员的行驶模型,并用实际的数据进行模型标定,该模型可以模拟和预测巴士车辆的能耗和污染排放<sup>[29]</sup>。Chen 等利用车辆运动轨迹提出稀疏表示方法描述驾驶行为决策特性<sup>[30]</sup>。Ramyar 等提出使用支持向量机方法学习车辆换道时驾驶行为决策特性<sup>[31]</sup>。基于数据驱动的驾驶员模型能够体现交通环境、驾驶行为特征与驾驶员物理特性的相关性关系,但该驾驶员模型结构过于复杂(大部分都是黑箱模型),模型扩展性较差,不利于我们开展驾驶员驾驶行为产生机理方面的研究。

国内外学者利用传递函数、最优控制、数据对驾驶员行为进行建模。但是,理想的自动驾驶车辆系统需要考虑驾驶员/乘员和车辆之间的友好交互,使驾驶员/乘员获得良好的使用体验,目前针对这方面的研究较少。德国科学家 Heide 等提出了“更加舒适”的自动驾驶的理念<sup>[32]</sup>。Abdul 等基于小脑模型建立了个性化的拟人车辆控制器<sup>[33]</sup>。Wang 等基于 HMM 利用实际的驾驶数据建立了个性化车道偏移预警模型,可以根据不同的驾驶员特性制订不同的预测方案<sup>[34]</sup>。吉林大学的严伟等利用实际驾驶员行车数据,开发了智能化的 ACC 系统,该系统可以模拟人类驾驶员的驾驶特性<sup>[35]</sup>。清华大学的张磊等建立了有自学习功能的个性化线性跟车控制模型<sup>[36]</sup>。Lan 等利用实际驾驶数据标定转向回正时刻、转向回正过程和转向回正结束点,设计了车道保持系统<sup>[37]</sup>。以上的这些研究还仅仅停留在单车安全辅助驾驶系统的个性化改造阶段,高级别的自动驾驶车辆,特别是考虑人类驾驶个性与环境车行为特征的自动驾驶决策控制的研究依然任重而道远。

### 1.2.3 自动驾驶决策规划与控制研究现状

无人驾驶系统主要包括决策、规划与控制三部分的内容。决策算法一般可分为基于规则的、基于概率的和基于学习的。基于规则的决策算法指依照预设的规则输出相应的驾驶决策,预设规则的来源一般为经验和常识。基于概率的决策算法为根据不同的交通场景,通过概率模型输出最恰当的自动驾驶决策策略,如隐马尔可夫链、概率图等。基于学习的决策算法为利用训练好的机器学习模型输出与交通环境情况相符合的决策策略,如 SVM、神经网络等方法,也包括最近兴起的强化学习等方法。目前,自动驾驶轨迹规划算法主要包括基于图搜索、基于插值、基于采样和基于数值优化四种。基于图搜索的规划方法,一般是对道路环境进行栅格化处理,并采用一些搜索算法寻找当前位置到目标位置的最优路径,如 Dijkstra、A\*、D\* 等搜索算法。基于插值的轨迹规划算法,是利用数学曲线拟合起点到终点来获取轨迹,常用的曲线模型为 Spline 曲线、Bezier 曲线、多项式曲线等。基于采样的轨迹

规划方法,是从起点开始向目标点位置进行随机采样,连接采样点与最近节点,去掉其中有障碍物阻挡的部分,最后得到规划的轨迹,如 RRT 算法(Rapidly Exploring Random Tree)。国内外学者进行了大量改进 RRT 算法的研究。基于数值优化的轨迹规划方法是设定车辆动力学和交通环境约束,建立目标函数,进行轨迹规划,如群优化算法等。自动驾驶的控制是指操纵车辆对规划的目标轨迹进行跟踪,包括横向控制和纵向控制两个方面。横向控制为操控车辆的转向系,使车辆横向位置接近目标轨迹。纵向控制是指对车辆速度的操控。跟踪控制包括 PID、滑模控制、MPC 等传统控制方法和当前流行的基于学习的控制方法。但是,目前自动驾驶的决策、规划与控制算法主要考虑车辆当前的行驶状态和交通环境情况,少有将驾驶员的个性化操作特征引入到自动驾驶技术的研究中。

综上所述,当前上述三方面的研究仍存在以下问题:①现有的个性化驾驶研究主要关注不同群体的驾驶风格分类,驾驶员的个性化特征较少体现在自动驾驶车辆的决策、规划与控制中;②现有的非线性模型预测控制方法虽在驾驶员模型构建中取得了较好效果,但该类驾驶员模型结构复杂,参数标定难度高,很难应用于工程实际中;③现有的个性化驾驶主要面向单个车辆的辅助驾驶系统,较少研究考虑环境车行为特征的自动驾驶决策与控制。因此,本书开展智能汽车个性化驾驶行为决策与运动控制方法的研究。

### 1.3 研究内容

本书利用自然驾驶实验数据提取不同驾驶员的个性化特征,并基于这些特征标定人工势场的关键参数,在自动驾驶路径规划中体现驾驶员的个性;提出改进的 MPC 算法,降低它对高精度车辆内模的依赖性,提高它控制的实时性和对不同驾驶场景的适应性,并在控制约束中体现驾驶员的个性化特征;研究考虑环境车行为特征的自动驾驶决策与控制方法,体现不同车辆之间的交互影响。

以基于混成自动机的自动驾驶车辆决策框架为基础,建立个性化的人工势场轨迹规划器,设计面向典型驾驶场景的个性化模型预测控制器,实现体现人类驾驶行为和考虑环境车行为特征的自动驾驶决策与控制。具体来说,研究内容主要包括以下几点:

(1) 进行个性化自动驾驶的研究,首先要提取驾驶员个性化的行为特征。开展自然驾驶实验,利用自然驾驶数据研究驾驶员的个性化行为特征,提取能够表征驾驶员行为特征的个性化变量指标,为个性化自动驾驶算法的研究奠定基础。

(2) 为了简化自动驾驶系统的算法结构,设计自动驾驶的决策框架。车辆控制系统为一个离散与连续结合的混成系统,因此基于混成自动机算法,采用分层结构构建体现人类驾驶行为和考虑环境车行为特征的自动驾驶决策框架。

(3) 研究考虑驾驶员个性的轨迹规划算法,使其在保证车辆安全的前提下能够根据驾驶员的行为特征生成符合驾驶员个性的目标轨迹。

(4) MPC 算法的控制性能极大地取决于其内模的精确性,此外 MPC 滚动优化的机制使其运算效率较低。对 MPC 算法进行改进,一方面提高控制的精度和实时性,另一方增强

它对不同驾驶环境的适应性,并能够体现出一定的驾驶员操作个性。

(5) 通过层次分析法和德尔菲法搭建了自动驾驶车辆的评价指标体系,并且通过模糊综合评价法对自动驾驶车辆决策、控制进行综合定量评价。

本书共分为 8 章。

第 1 章重点介绍了本书选题意义、研究现状及存在问题。

第 2 章针对个性化的自动驾驶算法研究的需要,分析典型驾驶场景中人类驾驶员的操作特点。首先,设计并进行自然驾驶实验,采集实验数据。然后,利用时序卡尔曼滤波等算法对自然驾驶数据进行除杂、平滑等预处理。基于 C 均值模糊聚类算法将人类驾驶员在典型驾驶场景中(跟驰和换道)的操作特征划分为不同的阶段,便于进行驾驶行为个性化特征的分析。最后,利用 T 检验法分析不同驾驶员在典型驾驶场景中不同驾驶阶段下驾驶行为的差异性。

第 3 章研究个性化自动驾驶的决策框架。车辆的决策控制是一个典型的混成系统,基于混成自动机建立自动驾驶车辆决策框架。对体现人类驾驶行为的自动驾驶而言,建立三层的混成自动机决策框架,分别为驾驶员模式离散状态位的切换层、行车模式离散状态位的切换层、连续的车辆动力学控制层。对考虑环境车行为特征的自动驾驶决策而言,构建四层决策框架,分别为驾驶员模式离散状态位的切换层、协同策略离散状态位的切换层、行车模式离散状态位的切换层、连续的车辆动力学控制层。

第 4 章基于人工势场法的个性化自动驾驶轨迹规划,研究自动驾驶车辆个性化轨迹规划的建模方法。首先,基于改进的人工势场算法对道路环境、障碍物、环境车以及目标点进行数学建模。然后,根据第 2 章获取的人类驾驶员个性化的驾驶行为特点,对人工势场模型的重要参数进行标定,产生典型驾驶场景中个性化的人工势场模型。最后,根据典型驾驶场景中个性化的人工势场模型生成个性化的自动驾驶车辆的规划轨迹。

第 5 章设计基于改进模型预测控制方法的个性化轨迹跟踪控制器。传统 MPC 控制方法由于内模失真会造成控制稳态误差。为了解决这一问题,在传统的 MPC 算法中加入一个 PID 反馈通路。为了提高 MPC 控制器的运算效率,基于 MPC 的显式化方法,优化控制器,实现 MPC 的实时控制。

第 6 章在建立的体现人类驾驶行为的自动驾驶系统基础上,研究考虑环境车行为特征的自动驾驶决策与控制方法。首先,为了在控制中体现环境车行为特征,提出了驾驶行为相容性的指标,该指标表示驾驶员驾驶行为个性化特征的相似程度。针对不同的相容性程度,采取换道、跟驰、超车等不同的协同策略,即相容性较高的驾驶员的协同策略趋向于跟驰,而相容性较低的驾驶员之间的协同策略更趋向于换道和超车。然后,设计基于分布式模型预测控制的决策控制方法,实现考虑环境车行为特征的决策控制。

第 7 章进行个性化自动驾驶实验测试与验证。设计多种测试场景,在硬件在环仿真测试平台和实车测试平台上对本书研究的个性化自动驾驶算法进行测试与验证。

第 8 章通过搭建合理的自动驾驶车辆的评价指标体系对自动驾驶车辆进行综合定量评价。

## 第 2 章

# 面向个性化自动驾驶的 自然驾驶数据分析

由于年龄、性别、性格、驾驶经验等多方面因素的影响,不同的驾驶员会体现出不同的驾驶个性化特征,自然驾驶实验是研究驾驶员个性化特征的主要方法之一。本章利用自然驾驶实验数据,分析典型驾驶场景(跟驰和换道)中驾驶员的个性化特征,提出对应场景中能够体现驾驶员个性化特征的变量指标,为车路协同环境下智能网联车辆个性化运动控制与测试评价方法的研究奠定基础。

获取驾驶员个性化特征的关键变量需要大量驾驶操作和车辆运动数据,当前获取驾驶员操作和车辆运动数据的方式主要有模拟驾驶实验和自然驾驶实验两种方式。目前,基于驾驶模拟器进行的模拟实验存在驾驶场景和驾驶环境失真的问题,很难获得接近真实道路驾驶行为的数据,因此,我们开展了实际道路环境下的自然驾驶实验。

自然驾驶研究是指自然状态下利用高精度数据采集系统,观测、记录驾驶员真实驾驶过程的研究。在自然驾驶道路实验中,驾驶员只需按照各自习惯的方式进行驾驶。在实验车辆上装有监测、记录驾驶员行为和车辆运动数据的仪器设备、相关的数据采集系统和数据存储系统,在驾驶员驾驶的过程中实验车会自动记录下驾驶员的操作行为和车辆状态。自2004年起,美国就率先开展了自然驾驶实验,最有代表性的研究为密歇根大学开展的IVBSS和Safety Pilot项目。2012年同济大学启动了我国首个自然驾驶实验。基于这些自然驾驶实验的数据,国内外学者进行了很多研究。

## 2.1 自然驾驶实验

### 1. 自然驾驶实验车

武汉理工大学智能交通系统研究中心自行开发了自然驾驶实验车(基于长安悦翔1.5AT改造而来),如图2-1所示。该实验车有两方面的功能:一是能够实时采集车辆的速度、加速度等状态信息;二是能够监测驾驶员的驾驶情况。传感器设备:RT2500导航设备

(监测实验车的实时位置、速度、航向角等)、摄像头(监测车内驾驶员的驾驶状态和操作行为)、Mobileye(监测实验车与车道线的横向距离、实验车与前方障碍的车头时距)、方向盘传感器(监测方向盘转角、转角速度)、CAN 信息采集系统(通过 CAN 通信获取油门踏板行程、发动机转矩等数据),还包括两台工控机,用于处理传感器设备监测到的数据。



图 2-1 自然驾驶实验车

## 2. 自然驾驶实验被试

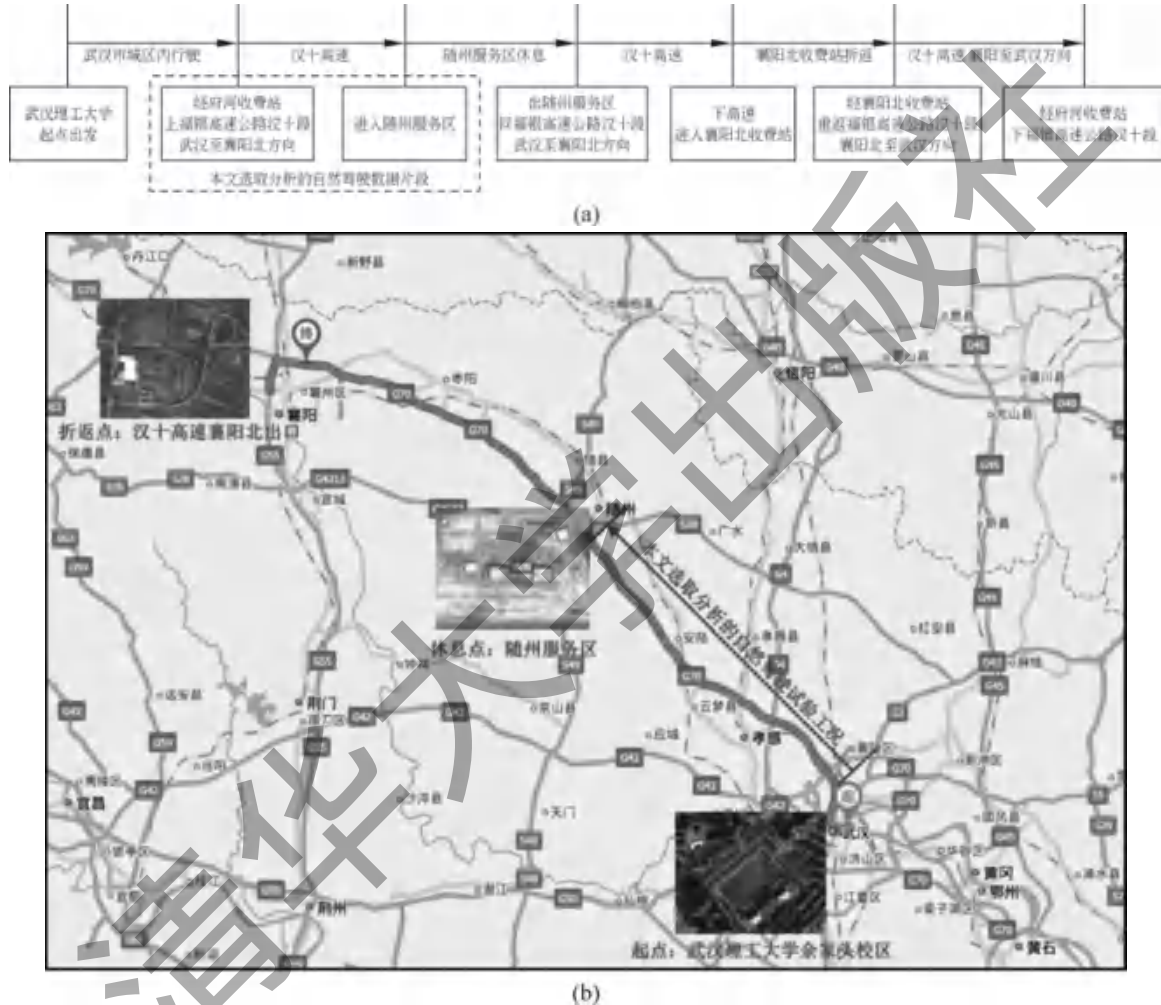
本研究中自然驾驶实车实验共招募被试驾驶员 50 名,被试条件如下:①为了确保被试的驾驶经验和驾驶水平相当,招募的被试均为职业驾驶员(如出租车司机、通勤车司机等);②均为身体健康的中年驾驶员;③实验期间禁止饮酒和服用精神类药物。限于篇幅,选取其中 10 个被试的数据(男性 8 名和女性 2 名)作为代表进行分析,具体信息如表 2-1 所示。

表 2-1 自然驾驶实验被试基本信息统计

编号	性别	年龄	驾龄	职业	编号	性别	年龄	驾龄	职业
01	男	51	21	出租车	06	男	41	11	出租车
02	男	52	12	通勤车	07	男	42	23	出租车
03	男	35	5	出租车	08	男	41	11	出租车
04	男	51	11	出租车	09	女	52	22	出租车
05	男	32	12	通勤车	10	女	35	5	出租车

### 3. 自然驾驶实验过程及线路

本自然驾驶实验全部在高速公路路段上开展,选取的高速公路为 G70 福银高速公路汉十段,分 50 组进行,每组实验采集一个驾驶员一天的行车数据(早 9 点至晚 5 点)。为了排除天气因素和路面状态的影响,实验均选择能见度良好的晴天进行。具体的实验线路安排如图 2-2 所示,通过高速收费站后车载设备开始采集数据,下高速后实验结束,关闭设备。



彩图 2-2

图 2-2 实验安排及线路

(a) 实验过程; (b) 实验线路

## 2.2 自然驾驶数据分析

2.1 节的自然驾驶实验获取了大量的数据,图 2-3 所示为本书采用的自然驾驶数据处理流程,原始数据经过同步和预处理后,基于一些统计学的方法可获取驾驶员的个性化特征

规律。本节大体介绍自然驾驶数据分析的流程和方法,2.3节将具体利用该流程分析高速公路跟驰和换道场景下驾驶员的个性化特征,并根据实际情况对相应的参数进行选取和标定。

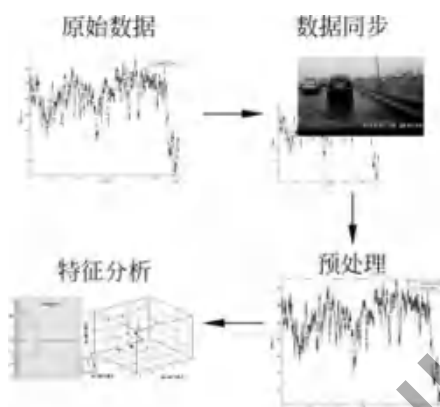


图 2-3 自然驾驶数据处理流程

### 1. 数据同步

由上文可知,本实验要求监测和采集车辆、驾驶员多个维度的数据,这就要求实验平台有多个传感器同时进行数据的采集工作。目前使用的自然驾驶实验平台并不具备统一数据采集的功能。也就是说,传感器会基于自己的时钟存储数据,这就要求在数据分析前进行时间的同步。

为了便于同步,在设备开机和关机时,随车人员会拍摄同步视频,记录传感器设备开关机的精确时间。随后,利用同步视频在 Observer XT 行为分析软件中进行多传感器的数据同步。

### 2. 预处理

在自然驾驶实验过程中,传感器获取的数据不可避免地要受到白噪声的影响,且由于一些客观原因会产生采集数据异常。为了提高数据分析的精度需要在进行分析前消除白噪声和异常数据的影响,这就要求我们进行数据的预处理。此外,为了便于分析、减小工作量,预处理时还将具有相似特征的数据进行分组聚类。

本研究利用卡尔曼滤波算法进行数据的预处理。针对自然驾驶数据中白噪声和奇异数据干扰的问题,卡尔曼滤波可以用于此类数据的预处理。

卡尔曼滤波是基于系统的状态特点对数据进行预测和平滑的,因此首先要确定系统的状态空间方程,如式(2-1)所示。

$$\begin{aligned} \mathbf{X}(t+1) &= \mathbf{F}_t \cdot \mathbf{X}(t) + \mathbf{V}(t) \\ \mathbf{Y}(t) &= \mathbf{H}_t \cdot \mathbf{X}(t) + \mathbf{W}(t) \end{aligned} \quad (2-1)$$

式中, $\mathbf{X}(t)$ 为系统的状态变量; $\mathbf{Y}(t)$ 为观测量,即可以用传感器测得的变量; $\mathbf{F}_t$ 为状态转

移矩阵； $\mathbf{W}(t)$ 和 $\mathbf{V}(t)$ 为白噪声。

基于以上的状态空间方程设计卡尔曼滤波器，算法模型如式(2-2)和式(2-3)所示<sup>[38]</sup>。

$$\hat{\mathbf{X}}_{(t|t-1)} = \mathbf{F}_{t-1} \cdot \hat{\mathbf{X}}_{(t-1|t-1)} \quad (2-2)$$

$$\hat{\mathbf{X}}_{(t|t)} = \hat{\mathbf{X}}_{(t|t-1)} + \Gamma_t (\mathbf{Y}_t - \mathbf{H}_t \hat{\mathbf{X}}_{(t|t-1)}) \quad (2-3)$$

式中， $\hat{\mathbf{X}}_{(t|t-1)}$ 为利用状态转移矩阵获取的状态变量； $\Gamma_t$ 为卡尔曼增益。

卡尔曼滤波的核心问题就是卡尔曼增益 $\Gamma_t$ 的获取，一般情况下卡尔曼增益由式(2-4)~式(2-6)所示的向前迭代的方式获取。

$$\Omega_{(t|t-1)} = \mathbf{F}_{t-1} \Omega_{(t-1|t-1)} \mathbf{F}_{t-1}^T + \mathbf{R}_{t-1}^V \quad (2-4)$$

$$\Gamma_t = \Omega_{(t|t-1)} \mathbf{H}_t^T [\mathbf{H}_t^T \Omega_{(t|t-1)} \mathbf{H}_t^T + \mathbf{R}_t^W]^{-1} \quad (2-5)$$

$$\Omega(t|t) = (\mathbf{I} - \Gamma_t \mathbf{H}_t) \Omega_{(t|t-1)} \quad (2-6)$$

式中， $\Omega_{(t|t-1)} = E[(\mathbf{X}_t - \hat{\mathbf{X}}_{(t|t-1)})(\mathbf{X}_t - \hat{\mathbf{X}}_{(t|t-1)})^T]$ 为先验协方差； $\Omega_{(t|t)} = E[(\mathbf{X}_t - \hat{\mathbf{X}}_{(t|t)})(\mathbf{X}_t - \hat{\mathbf{X}}_{(t|t)})^T]$ 为后验协方差； $\mathbf{R}^V$ 和 $\mathbf{R}^W$ 为白噪声的协方差矩阵。

滤波除杂之后，还需要对数据进行聚类分组，常用的聚类分析法能够将数据划分为有不同意义的组，其基本原理如式(2-7)所示，通过数据分组使式中的 $J$ 值最小。

$$J = \sum_{i=1}^C \sum_{k \in C_i} D(x_k, c_i) \quad (2-7)$$

式中， $D(x_k, c_i)$ 表示变量 $x_k$ 到对应聚类中心 $c_i$ 的距离。

本章中聚类分析的目的是为了划分跟驰、换道场景的各个阶段。具体地说，是将跟驰场景划分为靠近前车阶段、跟驰行驶阶段和与前车分离阶段<sup>[39]</sup>。将换道场景分为准备换道阶段、执行换道阶段和结束并线阶段<sup>[40]</sup>。这种数据的划分需求并不要求精确地将驾驶数据划分到某个组，组与组之间的界限不一定很清晰，因此模糊聚类能够很好地满足这一需求。本书所分析的数据都是按照时间序列排列的，而且在驾驶场景的阶段划分时必须要考虑时间先后顺序。比如，通常情况下跟驰场景一定是按靠近前车阶段→跟驰行驶阶段→与前车分离阶段这一顺序进行的。因此，本章采用时序模糊聚类算法对跟驰和换道驾驶场景进行阶段的划分。

传统的模糊C均值聚类算法如式(2-8)所示。

$$J = \sum_{i=1}^C \sum_{k=1}^N u_{ik}^m d_{ik}^2 \quad (2-8)$$

式中， $u_{ik}$ 为数据 $\vec{x}_k$ 属于类 $i$ 的隶属度； $d_{ik}$ 为数据 $\vec{x}_k$ 与类 $i$ 聚类中心的距离； $m$ 为加权指数。

模糊C均值聚类的优化迭代过程如图2-4所示。图中聚类中心 $c_i$ 和隶属度 $u_{ik}$ 的计算方法如式(2-9)和式(2-10)所示。

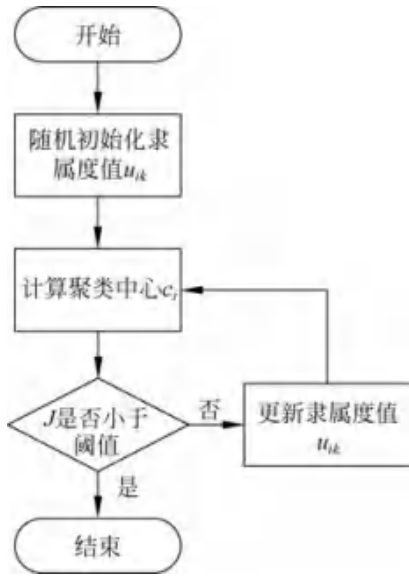


图 2-4 模糊 C 均值聚类流程

$$c_i = \frac{\sum_{k=1}^N u_{ik}^m x_k}{\sum_{k=1}^N u_{ik}^m} \quad (2-9)$$

$$u_{ik} = \frac{d_{ik}^{-\frac{2}{m-1}}}{\sum_{j=1}^C (d_{jk})^{-\frac{2}{m-1}}} \quad (2-10)$$

本章对跟驰驾驶场景和换道驾驶场景进行聚类分析,分别将其分为有时间先后顺序的三个阶段,这就要求聚类结果有时序特点。因此,在传统模糊 C 均值聚类的基础上要加入时序的约束,具体做法如式(2-11)所示。

$$J = \sum_{i=1}^C \sum_{t=1}^N u_{it}^m d_{it}^2 + \alpha \sum_{i=1}^C \sum_{t=1}^N u_{it}^m \sum_{\delta t=-r}^r d_{it, \delta t}^2 \quad (2-11)$$

式中,第一项代表所有数据变量  $\vec{x}_t$  到全部聚类中心的惩罚值;第二项代表  $[t-r, t+r]$  的时间领域内的数据到所有聚类中心的惩罚值;  $\alpha$  为权重值,其值恒为正;  $d_{it, \delta t}$  为数据  $\vec{x}_{t+\delta t}$  到类  $i$  聚类中心的距离。

### 3. 特征分析

同步和预处理之后的数据,可以进行分析建模,本研究主要采用时域法进行个性化特征的分析。时域分析法顾名思义,就是研究数据在数据序列上的变化规律,常用的时域分析法有概率分析法、统计分析法、随机过程分析法等。

概率分析法利用的概率模型如式(2-12)所示,该模型能够体现驾驶行为特征变量  $x$  的概率分布情况。

$$F(x) = P(x \leq X) = \int_{-\infty}^X p(x) dx \quad (2-12)$$

式中,  $p(x)$  为驾驶行为变量的概率密度函数。

统计分析法有期望(均值)、方差等多种分析指标。驾驶行为变量  $x$  的期望值  $E(x)$  能够体现变量的平均程度,如式(2-13)所示。

$$E[x(t)] = \frac{1}{T} \int_0^T x(t) dt \quad (2-13)$$

式中,  $T$  为时间范围。

对于离散型驾驶行为信号,其期望如式(2-14)所示。

$$E[x(n)] = \frac{1}{n} \sum_{i=1}^n x(t_i) \quad (2-14)$$

式中,  $n$  为总采样数。

驾驶行为变量  $x$  的中位数  $M$  也能够体现其平均程度,如式(2-15)所示。

$$M(x(t)) = \frac{\max(x(t)) - \min(x(t))}{2} \quad (2-15)$$

式中,  $\max(x(t))$  和  $\min(x(t))$  为连续变量  $x(t)$  的最大和最小值。

对于离散的驾驶行为变量, 其中位数如式(2-16)所示。

$$M(x(i)) = \begin{cases} x(r+1), & n = 2r + 1 \\ \frac{x(r) + x(r+1)}{2}, & n = 2r \end{cases} \quad (2-16)$$

式中,  $n$  为总采样数。

驾驶行为变量  $x$  的方差  $S^2(x)$  能够体现其值在一定范围内的变化情况, 计算方法如式(2-17)<sup>[40]</sup>所示。

$$S^2(x(t)) = \frac{1}{T} \int_0^T [x(t) - E(x(t))]^2 dt \quad (2-17)$$

式中,  $E(x(t))$  为连续变量的期望值。

对于离散型驾驶行为变量, 其方差如式(2-18)所示。

$$S^2(x(n)) = \frac{1}{n} \sum_{i=1}^n [x(t_i) - E(x(i))]^2 \quad (2-18)$$

式中,  $E(x(i))$  为离散变量的期望值。

频域分析也是一种主要的数据分析手段, 利用频域分析法能够得到一些在时间序列上无法获取的特征规律<sup>[41]</sup>。傅里叶变换可将数据的时域特征与频域特征联系起来。连续信号  $f(t)$  傅里叶变换的方法如式(2-19)<sup>[41]</sup>所示。

$$F(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (2-19)$$

离散信号  $x(j)$  的计算如式(2-20)<sup>[41]</sup>所示。

$$X(k) = \sum_{j=1}^N x(j) \omega_N^{(j-1)(k-1)} \quad (2-20)$$

式中,  $\omega_N = e^{-\frac{2\pi j}{N}}$ ,  $N$  为离散信号的样本点数。

以傅里叶变换为基础, 在频域范围内进行数据分析的常用特征有自功率谱密度函数、倒谱峰值、均方频率等。

本研究基于自然驾驶实验数据的驾驶员个性化分析主要采用时域分析的方法, 获取驾驶员操作行为的均值、方差及其分布规律, 总结出能够体现驾驶员个性的特征指标变量。

### 2.3 个性化驾驶行为特征提取

本节根据上文的数据分析流程, 对典型驾驶场景(跟车和换道)中的自然驾驶个性化特征进行提取。以 01、02 两个被试的实验数据为例, 介绍驾驶个性化特征的分析提取, 分别编号 A、B。

### 2.3.1 跟驰场景下的驾驶行为特征提取

利用 2.1 节获取的自然驾驶数据,从中截取跟驰场景的数据,按照数据同步→预处理→特征分析的步骤提取跟驰场景下不同驾驶员的个性化特征。

#### 1. 跟驰行为数据同步

跟驰场景下,驾驶员的特征主要体现在车辆的纵向操作上,因此,对跟驰场景的研究选取的变量如下所示:

$$[T_h(t), u(t), a(t)]^T$$

式中,  $T_h(t)$  为车头时距;  $u(t)$  为纵向车速;  $a(t)$  为纵向加速度。

图 2-5 所示为选取的一段跟驰的自然驾驶数据。首先,观看视频数据,确定跟驰操作的




图 2-5 跟驰数据的选取和时间同步

开始和结束时刻。根据视频信息,该段跟驰数据开始的时间为第 24805s,结束的时间为第 24965s。然后,根据开始和结束的时刻,选取出对应的车头时距  $T_h(t)$ 、纵向车速  $u(t)$ 、纵向加速度  $a(t)$ 。车头时距数据中,只有在第 24900s 附近时有有效的数据。因为本自然驾驶实验中采集车头时距的 Mobileye 系统的有效范围为 2.5s,因此当前车与本车的车头时距大于 2.5s 时记录的数据为 0。依据该方法,每个驾驶员选取 10 段跟驰数据并进行同步处理。

## 2. 跟驰行为数据预处理

根据 2.2 节的数据分析流程,基于卡尔曼滤波和时序模糊 C 均值聚类的方法对同步后的高速公路跟驰数据进行除杂平滑和聚类分组。

截取同步之后的跟驰车头时距  $T_h(t)$ 、纵向车速  $u(t)$ 、纵向加速度  $a(t)$  数据,基于卡尔曼滤波进行除杂、平滑预处理。

采用状态变量如式(2-21)所示。

$$\mathbf{X}(t) = [s_n(t), v_n(t), a_n(t)]^T \quad (2-21)$$

式中,  $s_n(t)$  为本车与前车的距离;  $v_n(t)$  为本车车速;  $a_n(t)$  为本车的加速度。

观测量如式(2-22)所示。

$$\mathbf{Y}(t) = [T_n(t), v_n(t), a_n(t)]^T \quad (2-22)$$

式中,  $T_n(t)$  为车头时距。

由物理特性可得对应的差分方程如式(2-23)所示。

$$\begin{aligned} s_n(t+1) &= s_n(t) + v_n(t)T_g + \frac{1}{2}a_n(t)T_g^2 \\ v_n(t+1) &= v_n(t) + a_n(t)T_g \\ a_n(t+1) &= \beta a_n(t) + \theta(t) \end{aligned} \quad (2-23)$$

式中,  $\beta$  为加速度转移系数;  $\theta(t)$  为白噪声。

则建立状态空间方程如式(2-24)所示。

$$\begin{aligned} \mathbf{X}(t+1) &= \mathbf{F}_t \cdot \mathbf{X}(t) + \mathbf{V}(t) \\ \mathbf{Y}(t) &= \mathbf{H}_t \cdot \mathbf{X}(t) + \mathbf{W}(t) \end{aligned} \quad (2-24)$$

式中,  $\mathbf{F}_t = \begin{pmatrix} 1 & T_g & \frac{T_g^2}{2} \\ 0 & 1 & T_g \\ 0 & 0 & \beta \end{pmatrix}$ ;  $\mathbf{H}_t = \begin{pmatrix} \frac{1}{v_t} & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$ ;  $\mathbf{V}(t)$  和  $\mathbf{W}(t)$  为白噪声。

状态方程确定之后,设计对应的卡尔曼滤波器,如式(2-25)<sup>[38]</sup>所示。此处预处理的数据为离线数据,即已经获取了所有的观测值,因此在原有卡尔曼滤波的基础上加入如式(2-25)所示的向后迭代的方式对样本数为  $N$  的数据进行除杂和平滑。

$$\hat{\mathbf{X}}_{(t|N)} = \hat{\mathbf{X}}_{(t|t)} + \mathbf{A}_t (\hat{\mathbf{X}}_{(t+1|N)} - \hat{\mathbf{X}}_{(t+1|t)})$$

$$\begin{aligned}\Omega_{(t|N)} &= \Omega_{(t|t)} + \Lambda_t (\Omega_{(t+1|N)} - \Omega_{(t+1|t)}) \Lambda_t^T \\ \Lambda_t &= \Omega_{(N|t)} F_t^T \Omega_{(t+1|t)}^{-1}\end{aligned}\quad (2-25)$$

式中,  $\hat{\mathbf{X}}_{(t|N)}$  为基于全部的观测值  $Y_0, \dots, Y_N$  估测的  $\mathbf{X}_t$  的值;  $\Omega_{(t|N)} = E[(\mathbf{X}_t - \hat{\mathbf{X}}_{(t|N)})(\mathbf{X}_t - \hat{\mathbf{X}}_{(t|N)})^T]$  为估测状态的协方差。

依据该方法,对上文每个驾驶员选取的 10 段跟驰数据进行卡尔曼滤波处理。图 2-5 所示的一段跟驰数据的预处理结果如图 2-6 所示。




图 2-6 基于卡尔曼滤波的数据预处理

图 2-6 中,速度和加速度原始数据在经过卡尔曼滤波的预处理之后,获得了比较平滑的特征曲线。由于 Mobileye 设备的限制,它只能探测到 2.5s 以内的车头时距数据,因此车头时距中存在大量的数据 0。为了后续的研究,需要对缺失数据 0 进行补充,具体方法为基于系统的状态方程式(2-24),根据滤波后的速度、加速度和已知的车头时距数据计算出缺失的数据,如图 2-6 所示。

基于上文提出的考虑时序的模糊 C 均值聚类算法,对经过同步和预处理的数据进行分类,将每一段跟驰数据分为靠近前车阶段、跟驰行驶阶段和与前车分离阶段。

首先确定每个数据与每一个阶段的隶属度值  $\hat{u}_{ik}$ 。然后,根据式(2-26)<sup>[38]</sup>计算聚类中

心  $\hat{c}_i$ 。

$$\hat{c}_i = \frac{\sum_{k=1}^N \hat{u}_{ik}^m \hat{x}_k}{\sum_{k=1}^N \hat{u}_{ik}^m} \quad (2-26)$$

式中,  $\hat{x}_k$  为经过卡尔曼滤波后的数据, 本研究中取  $m=2$ 。

再根据式(2-27)<sup>[38]</sup>计算新的隶属度值。

$$u_{ik} = \frac{\hat{d}_{ik}^{-\frac{2}{m-1}}}{\sum_{c=1}^C (\hat{d}_{ck})^{-\frac{2}{m-1}}} \quad (2-27)$$

式中,  $\hat{d}_{ik}$  为数据  $\hat{x}_k$  到类  $i$  聚类中心的距离。

根据式(2-28)判断是否迭代结束。当  $\hat{J}$  小于阈值时停止迭代, 否则返回继续迭代。

$$\hat{J} = \sum_{i=1}^C \sum_{t=1}^N \hat{u}_{it}^m \hat{d}_{it}^2 + \alpha \sum_{i=1}^C \sum_{t=1}^N \hat{u}_{it}^m \sum_{\delta t=-r}^r \hat{d}_{it, \delta t}^2 \quad (2-28)$$

式中,  $\hat{d}_{it, \delta t}$  代表  $\hat{x}_{it-\delta t}$  到类  $i$  聚类中心的距离, 权重值取  $\alpha=3$ 。

对预处理之后的图 2-6 的数据进行时序聚类, 其结果如图 2-7 所示。类 C1 为靠近前车阶段、类 C2 为跟驰行驶阶段、类 C3 与前车分离阶段。基于该算法, 通过对变量车头时距、加速度、速度的聚类, 可以自动地将跟驰的过程分为三个阶段, 便于后面对跟驰场景进行驾驶特征的分析。

### 3. 跟驰行为个性化特征分析

选择驾驶员 A 和 B 的自然驾驶数据, 利用上文提到的数据同步、预处理和聚类分析, 将这两个驾驶员的跟驰过程分为三个阶段(C1 靠近前车阶段、C2 跟驰行驶阶段、C3 与前车分离阶段), 统计驾驶员 A 和 B 在三个阶段的驾驶特征(车头时距、速度、加速度), 描述性统计结果分别如附录图 B-1 和附录图 B-2 所示。

附录图 B-1 为驾驶员 A 10 段跟驰数据的车头时距、速度、加速度的描述统计结果。由图中可知, 在 C1 阶段车头时距在  $[3, 3.6]$  的范围内, 在 C2 阶段车头时距在  $[2.6, 3]$  的范围内, 而在 C3 阶段车头时距在  $[3.4, 3.5]$  的范围内。可见 C1 阶段是车辆逐渐靠近前车的过程, C2 阶段是和前车保持较近距离稳定跟驰的阶段, C3 阶段是逐渐和前车分离的阶段。从速度来看, C1 阶段车速在  $[86, 92]$  的范围内, C2 阶段车速在  $[84, 86]$  的范围内, C3 阶段车速在  $[0, 84]$  的范围内。可知 C1 阶段车速较快, 在追赶前车; C2 阶段保持和前车基本一致的车速; C3 阶段速度变慢, 减速停止跟驰前车。从加速度来看, C1 阶段加速度范围在  $[-0.02, 0.04]$ , C2 阶段加速度范围在  $[-0.02, 0.02]$ , 而 C3 阶段加速度范围在  $[-0.06, 0]$ 。

附录图 B-2 为驾驶员 B 10 段跟驰数据的车头时距、速度、加速度的描述统计结果。与




图 2-7 跟驰工况时序聚类结果

驾驶员 A 相似, C1 阶段车头时距逐渐减小, C2 阶段保持较小的车头时距并以稳定的车速跟驰前车, C3 阶段减速停止跟驰。与驾驶员 A 相比, 驾驶员 B 有其独特的驾驶特征。驾驶员 B C2 阶段的车头时距更小, 保持在 $[1.8, 2.2]$ 的范围内(驾驶员 A C2 阶段车头时距集中在范围 $[2.6, 3]$ ), C1 阶段驾驶员 B 的车速在 $[92, 94]$ 范围占比较大(驾驶员 A 的车速主要在范围 $[86, 92]$ ), C1 阶段驾驶员 B 的加速度较大, 主要在范围 $[0.02, 0.04]$ , 而且有较大的减速度, 范围 $[-0.08, -0.06]$ (驾驶员 A 主要集中在 $[-0.02, 0.04]$ )。

综上所述, 跟驰场景下驾驶员 A 和 B 被聚类算法分成了三个阶段, 由描述性统计结果可知 C1 阶段驾驶员加速靠近前车, 与前车的车头时距逐渐减小; C2 阶段驾驶员与前车保持较小的车头时距, 以较为稳定的车速行驶; C3 阶段开始减速, 与前车的车头时距增大, 逐渐停止跟驰。描述性统计结果可以进一步验证聚类分析结果比较合理。横向比较驾驶员 A、B, 相对于驾驶员 B, 在靠近前车阶段驾驶员 A 的加/减速度更小, 而且在稳定跟驰阶段有更大的车头时距。

上文基于描述性统计结果可以看出驾驶员 A 和 B 在跟驰三阶段的加/减速及车头时距变量有一定的差异。为了研究这些差异是否具有统计学意义, 下面利用独立样本 T 检验的方法研究变量的差异性。

首先,对驾驶员 A 的 10 组跟驰数据两两独立 T 检验,附录表 A-1 为车头时距的 T 检验的结果,每个单元格内的三个值表示跟驰三个阶段的 T 值。可见第 3 组数据与其他组有显著的差异,其他组的数据并没有显著的差异。

附录表 A-2 为驾驶员 A 跟驰场景下车速的 T 检验的结果,在每个单元格中列出跟驰场景三个阶段的 T 值。表中 10 组数据两两对比,并没有显著的差异。

附录表 A-3 为跟驰过程中加速度的 T 检验结果,在每个单元格中列出跟驰三个阶段的 T 值。表内数据显示出的规律与附录表 A-1 类似,第 3 组数据与其他数据有明显的差异,其他的 9 组数据之间的差异并不明显。

附录表 A-4 为驾驶员 A 和驾驶员 B 的车头时距 T 检验的结果,同样,在每个单元格中列出跟驰三个阶段的 T 值。由表中数据可知驾驶员 A 和 B 在跟驰的三个阶段的车头时距都有显著的差异,且相对于 C1 和 C3 阶段,C2 阶段的差异性更为明显(不显著的 T 值占比: C1 阶段 19%,C2 阶段 6%,C3 阶段 32%)。

附录表 A-5 所示为驾驶员 A 和驾驶员 B 的速度 T 检验的结果,在每个单元格中列出跟驰场景三个阶段的 T 值。由表中数据可知驾驶员 A 和 B 在跟驰场景的三个阶段,大部分车速都没有显著的差异,有一小部分的车速在 C1 和 C3 阶段差异显著,但是 C2 阶段差异显著的车速很少(不显著的 T 值占比: C1 阶段 87%,C2 阶段 95%,C3 阶段 86%)。

附录表 A-6 所示为驾驶员 A 和驾驶员 B 的加速度 T 检验的结果,在每个单元格中列出跟驰三个阶段的 T 值。由表中数据可知驾驶员 A 和 B 在跟驰的三个阶段,大部分车辆加速度都有显著的差异(不显著的 T 值占比: C1 阶段 26%,C2 阶段 25%,C3 阶段 25%)。

综上所述,驾驶员 A 和驾驶员 B 在跟驰场景下能够体现出特有的特征:①在 C1、C2 和 C3 阶段驾驶员 A 的车头时距比驾驶员 B 大,有统计学上的显著性差异,且在 C2 阶段的差异最为显著;②三个阶段中,驾驶员 A 和驾驶员 B 速度特征的统计学差异不显著,特别是 C2 阶段统计学差异最不显著;③三个阶段中,驾驶员 A 的加速度比驾驶员 B 小,且有一定的统计学差异。

驾驶员的跟驰行为体现了相应驾驶员的纵向驾驶特征。由后文采用的轨迹规划算法的建模方式可知,纵向轨迹规划模型需要对两个参数进行标定,因此需选取两个特征变量标定相应的特性参数。如图 2-8 所示,由不同驾驶员跟驰场景下变量差异的显著程度可知(依据为不显著的 T 值占比的大小),选取车头时距变量和加速度变量最能体现驾驶员之间纵向操作行为的差异。




图 2-8 跟驰变量不显著的 T 值占比

### 2.3.2 换道场景下的驾驶行为特征提取

本节从 2.1 节获取的自然驾驶数据中截取换道场景的数据,按照数据同步→预处理→特征分析的步骤提取换道场景下不同驾驶员的个性化特征。

#### 1. 换道行为数据同步

换道场景下,驾驶员的特征体现在车辆的横向和纵向联合操作上,但是以横向操作为主,因此对换道场景的研究选取的变量如下所示:

$$[L_h(t), u(t), \phi(t), \omega(t), r(t)]^T$$

式中,  $L_h(t)$  为车道偏移;  $u(t)$  为纵向车速;  $\phi(t)$  为航向角;  $\omega(t)$  为横摆角速度;  $r(t)$  为横摆角加速度。

如图 2-9 所示,选取了一段换道场景下的自然驾驶数据。首先,观看视频数据,确定换

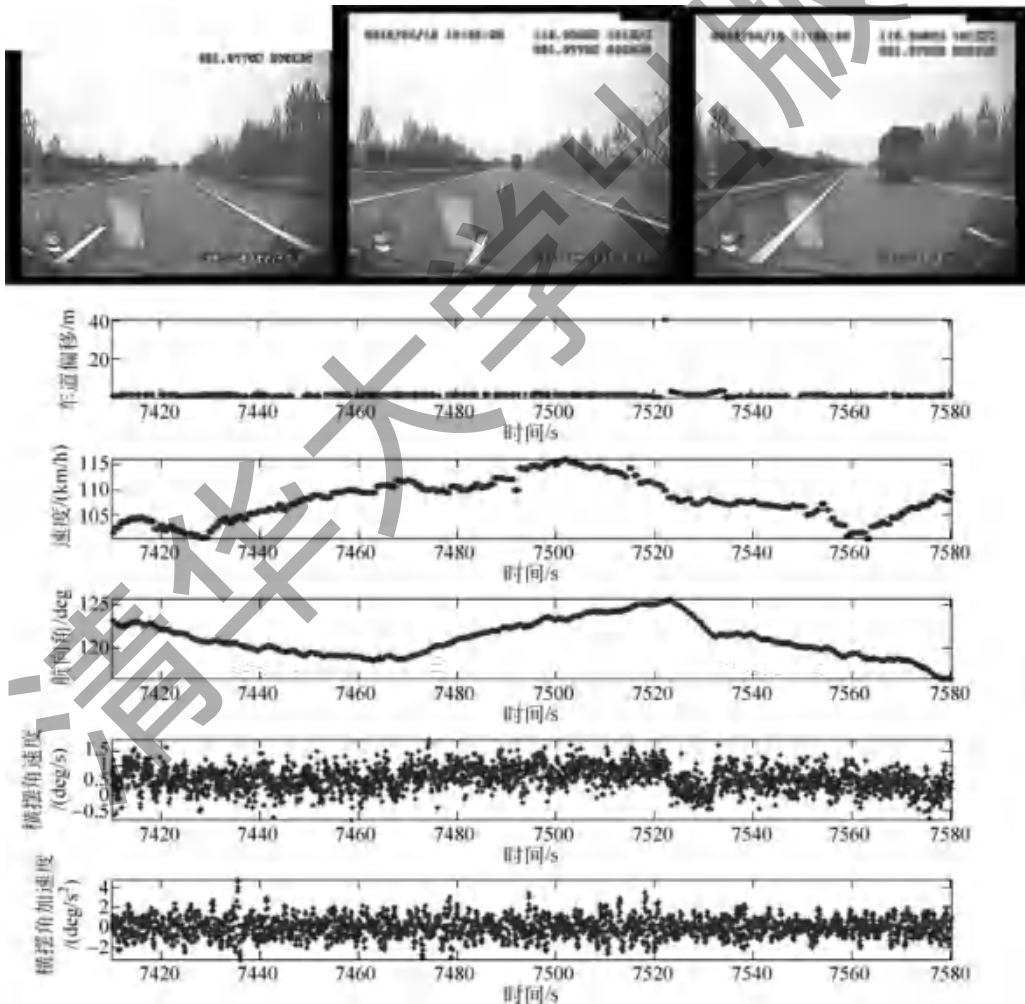


图 2-9 换道数据的选取和时间同步