

硕士学位论文

**跟车场景下自动驾驶车辆安全性与通行
效率评价方法研究**

**Research on the Evaluation Method of the Safety and
Traffic Efficiency of Automated Vehicles in
Car-following Scenarios**

学科专业： 控制科学与工程

学科方向： 模式识别与智能系统

作者姓名： 秦觅

指导教师： 谢斌 副教授

中南大学

2020年4月

中图分类号 TP301.6

学校代码 10533

UDC 471.15

学位类别 学术学位

硕士学位论文

跟车场景下自动驾驶车辆安全性与通行效率评价方法研究

Research on the Evaluation Method of the Safety and Traffic Efficiency of Automated Vehicles in Car-following Scenarios

作者姓名： 秦觅

学科专业： 控制科学与工程

学科方向： 模式识别与智能系统

研究方向： 智能网联汽车

二级培养单位： 自动化学院

指导教师： 谢斌 副教授

论文答辩日期_____

答辩委员会主席_____

中南大学

2020年4月

学位论文原创性声明

本人郑重声明，所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了论文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得中南大学或其他教育机构的学位或证书而使用过的材料。与我共同工作的同志对本研究所作的贡献均已在论文中作了明确的说明。

申请学位论文与资料若有不实之处，本人承担一切相关责任。

作者签名：_____ 日期：_____年___月___日

学位论文版权使用授权书

本学位论文作者和指导教师完全了解中南大学有关保留、使用学位论文的规定：即学校有权保留并向国家有关部门或机构送交学位论文的复印件和电子版；本人允许本学位论文被查阅和借阅；学校可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用复印、缩印或其它手段保存和汇编本学位论文。

保密论文待解密后适应本声明。

作者签名：_____

导师签名_____

日期：_____年___月___日

日期：_____年___月___日

跟车场景下自动驾驶车辆安全性与通行效率评价方法研究

摘要：跟车场景是自动驾驶中常见的一种交通场景，跟车距离太近会导致车辆的安全性较低，而跟车距离太远又会影响车辆的通行效率，如何有效地评价跟车场景下自动驾驶车辆行驶时的安全性以及车辆的通行效率是现有研究的一大难点，本文针对这一课题展开了深入的研究，主要内容如下：

(1) 针对目前跟车场景下自动驾驶车辆安全性评价的方法难以体现车辆跟车行驶时的动态过程并且没有考虑车辆通行效率的问题，本文首先对跟车场景进行了定义和划分，将其定义为一个动态过程，然后基于现有的威胁度量指标 TTC(Time-to-Collision)，提出了一种新的评价指标 STCI(Safety and Traffic Capacity Index)，用于评价自动驾驶车辆在跟车场景下行驶时的安全性和车辆通行效率。该指标将整个跟车场景下的最小 TTC 指标值以及最优 TTC 阈值作为参数，其评价结果可以较好的反映出自动驾驶车辆在跟车行驶时的动态过程。通过对 STCI 指标计算值及其参数值的分析，能够得到自动驾驶车辆在其所处的动态跟车场景下的最优制动时刻，实现对自动驾驶车辆实际制动时刻及其制动减速度的评价，从而为自动驾驶车辆控制决策算法的评价提供参考。

(2) 对 STCI 指标两个参数的计算方法进行了深入研究。通过理论推导得到了不同场景状态参数组合下计算 STCI 指标最小 TTC 参数的解析式，确定了跟车场景的范围，结合实例证明了使用最小 TTC 作为 STCI 参数的合理性和有效性。由于 STCI 指标的最优 TTC 阈值参数需要综合考虑车辆行驶时的安全性和通行效率而得到，而场景状态参数是动态变化的，因此本文通过建立跟车场景的数学模型来求解 STCI 指标最优 TTC 阈值参数。

(3) 针对最优 TTC 阈值参数难以得到解析式，需要通过数值解法多次遍历计算耗时较长，导致 STCI 指标计算效率较低的问题，本文提出了一种基于机器学习快速计算最优 TTC 阈值参数的方法以加速 STCI 指标的计算，从而加速对于自动驾驶车辆在跟车场景下行驶时的安全性与通行效率的评价，并通过实验验证了该方法能在保证计算精度的前提下有效提高 STCI 指标的计算速度。

(4) 结合 PreScan 与 Simulink 的联合仿真建立大量的跟车场景，

通过加入动力学模型的仿真实验进一步验证了不同场景下 TTC 指标的变化曲线以及最小 TTC 解析式的正确性。通过对车辆的制动时刻和制动减速度进行消融实验，分析跟车场景中不同车辆制动行为对 STCI 指标评价的影响，证明了采用 STCI 指标对跟车场景下自动驾驶车辆的安全性和通行效率进行评价的合理性与有效性。

图 50 幅，表 12 个，参考文献 63 篇

关键词：自动驾驶；安全性评价；通行效率；机器学习；PreScan 仿真

分类号：TP301.6

Research on the Evaluation Method of the Safety and Traffic Efficiency of Automated Vehicles in Car-following Scenarios

Abstract: The car-following scenario is common in automated driving. A close distance will lower vehicle safety while a far distance will affect traffic efficiency. The balance between vehicle safety and traffic efficiency of car-following is a major difficulty in current research. This thesis has conducted in-depth research on this issue and the main contents are as follows:

(1) The current methods of evaluating the automated vehicle safety in the car-following scenario hardly reflect the dynamic car-following process and ignore traffic efficiency. Accordingly, this paper first defines and classifies car-following scenario, and then proposes a new evaluation index STCI (Safety and Traffic Capacity Index) based on the existing threat measurement index TTC (Time-to-Collision) in order to evaluate both vehicle safety and traffic efficiency in the car-following scenario. STCI takes the minimum TTC index value and the optimal TTC threshold value in the entire car-following as parameters. Therefore, its evaluation can reflect the dynamic process of car-following by automated vehicles. Through the analysis of the calculated value of the STCI index and its parameter values, the optimal braking time of the automated vehicles in the dynamic car-following could be obtained, which makes evaluating actual braking time and deceleration speed of braking at certain time possible. This provides a reference for the control decision algorithm of automated vehicles.

(2) The paper studies the calculation method of the two parameters of the STCI, and obtains the analytical formula for calculating the minimum TTC parameter of the STCI indicator under different scene parameter combinations through theoretical derivation. Since the optimal TTC threshold parameter of the STCI index needs to be obtained by taking vehicles safety and traffic efficiency into consideration and the scene parameters keep changing, this paper aims to figure out the TTC threshold parameter via establishing a mathematical model of car-following.

(3) Facing the problem of low calculation efficiency of the STCI

indicator caused by the difficulty to obtain the analytical formula for the optimal TTC threshold parameter, the paper proposes a new method based on rapid machine learning to accelerate the calculation of the optimal TTC threshold parameter of the STCI index, thereby speeding up the evaluation of the safety and traffic efficiency of automated vehicles in car-following scenario. Such a method which has been verified through adequate experiments can effectively improve the calculation speed and accuracy of STCI index.

(4) Numerous car-following scenarios are established by combining PreScan and Simulink, and the ablation experiment proves the rationality of using STCI to evaluate the braking of automated vehicles. In addition, the testing results of calculation method of the STCI index in various different car-following scenarios verify the feasibility of STCI evaluation index proposed in this paper.

Key words: Automatic driving; Safety evaluation; Traffic efficiency; Machine learning; PreScan Simulation

Classification: TP301.6

目 录

摘要.....	I
Abstract.....	III
目 录.....	V
1 绪论.....	1
1.1 课题研究背景及意义.....	1
1.2 国内外研究现状.....	2
1.2.1 碰撞风险评价指标研究现状.....	2
1.2.2 安全性评价方法研究现状.....	3
1.3 论文主要研究内容及组织结构.....	5
1.3.1 主要研究内容.....	5
1.3.2 组织结构.....	6
2 安全性与通行效率评价模型设计.....	7
2.1 跟车场景的定义及划分.....	7
2.2 安全性与通行效率评价函数曲线构造.....	10
2.3 STCI 评价指标设计.....	13
2.4 小结.....	16
3 STCI 指标最小 TTC 参数分析及计算方法研究.....	17
3.1 跟车场景下 TTC 指标变化趋势分析.....	17
3.1.1 后车逼近阶段.....	18
3.1.2 后车制动阶段.....	21
3.1.3 TTC 指标完整变化趋势.....	22
3.2 最小 TTC 指标参数解析式.....	25
3.3 实验结果分析.....	27
3.4 小结.....	30
4 STCI 指标最优 TTC 阈值参数分析及计算方法研究.....	31
4.1 基于物理模型的最优 TTC 阈值参数计算方法.....	31
4.1.1 跟车场景建模.....	31
4.1.2 最优 TTC 阈值参数计算.....	33
4.2 基于机器学习的最优 TTC 阈值参数快速计算方法研究.....	34
4.2.1 数据预处理与特征工程构建.....	35
4.2.2 模型介绍.....	36

4.2.3 模型训练及验证.....	38
4.3 两种计算最优 TTC 阈值参数的方法实验对比分析.....	42
4.4 小结.....	43
5 基于 PreScan 与 Simulink 的跟车场景联合仿真实验设计.....	44
5.1 PreScan 与 Simulink 联合仿真工作流程.....	44
5.2 基于 PreScan 的虚拟跟车场景构建.....	45
5.3 基于 Simulink 的车辆控制算法设计.....	46
5.3.1 前车控制算法设计.....	47
5.3.2 后车控制算法设计.....	47
5.4 基于联合仿真的 TTC 指标变化趋势分析.....	50
5.5 STCI 指标实例评价分析.....	53
5.6 STCI 指标有效性与可行性分析.....	58
5.6.1 STCI 分析实验.....	58
5.6.2 STCI 与制动时刻消融实验.....	59
5.6.3 STCI 与后车制动减速度消融实验.....	63
5.7 小结.....	66
6 总结与展望.....	67
6.1 论文总结.....	67
6.2 研究展望.....	68
参考文献.....	70
攻读学位期间主要研究成果.....	75
致 谢.....	76

1 绪论

1.1 课题研究背景及意义

近年来,自动驾驶技术得到了飞速发展,从最初的单车智能到现在的车路协同,从自动驾驶辅助到 L3 级别及以上的高级自动驾驶,自动驾驶的商业化时机似乎已经到来。但实际上,自动驾驶车辆在全面推广前还有很多方面的问题需要解决,其中最重要的就是如何验证自动驾驶车辆的驾驶安全性^[1]。

研究表明^[2],通过实地测试的方式来证明自动驾驶车辆的安全性能超过人类,至少需要行驶 4.4 亿公里。而一旦更改车辆的规划和控制算法,就需要重新进行测试,这无疑是不可实现的。因此,目前行业的普遍共识是依照 V 模型^[3],结合虚拟仿真技术来加速自动驾驶汽车的性能测试,虚拟测试关键场景的生成技术成为当前研究的热点^{[4][5]},而对于车辆安全性评价的研究却较少受到关注。实际上,自动驾驶车辆的安全性评价与场景是相辅相成的,应当是每一个场景都有对应的安全性评价标准,而每一项安全性评价也对应着场景应该包含的考察任务^[6]。

在众多交通场景中,跟车场景是自动驾驶技术应用最广泛的场景之一,包括紧急制动功能、主动车距控制巡航系统、编队驾驶^[7]等,它指的是车辆的速度和纵向位置受到前方车辆影响的场景^[8]。车辆在跟车行驶时由于车速过快、跟车距离太近、前车紧急制动时自车采取的制动决策行为不合理等原因都可能会导致追尾碰撞事故。而在中国交通事故的分布中,由跟车行驶导致的追尾碰撞事故的比例仅次于侧面碰撞^[9]。

从安全方面考虑,自动驾驶车辆在跟车场景下与前车的距离越远时,发生追尾碰撞事故的概率就越低,但是如果为了驾驶安全,自动驾驶车辆过早地降低车速,使得跟车距离过远,将会影响到自车甚至整个交通场景的通行效率^[10]。如何有效地评价跟车场景下自动驾驶车辆行驶时的安全性以及车辆的通行效率是现有研究的一大难点,也是亟待解决的一个问题。

目前已经有很多威胁度量指标可用于进行安全评估,例如碰撞时间(TTC)和车间时间(IVT)等^[11]。这些指标主要用在高级驾驶辅助系统 ADAS 中的自动紧急制动系统 AEB 和前方碰撞预警系统 FCW 上^[12],通过实时计算指标当前值并与设定的安全阈值比较,一旦低于设定阈值,则触发安全系统。

现有的研究通常将这些威胁度量指标在同类场景下的安全阈值设为固定值,例如 TTC 指标在跟车场景下的安全阈值是 4 秒^[13],如果 ADAS 系统通过实时计算得到当前场景下的 TTC 值小于 4 秒,则认为车辆此刻的安全性较低,ADAS 系统便会控制车辆紧急制动或避开前方障碍物以降低发生碰撞的风险。但实际上,

将同一场景的安全阈值设置为固定值是存在问题的。同样是还有 4 秒就要与前车发生碰撞,车辆在高速和低速运行时由于需要降低的速度不同,安全威胁程度也不同^[14]。此外,这些威胁度量指标主要针对的是较为危险的场景下车辆需要紧急制动以避免碰撞的时刻,而对于自动驾驶车辆的安全性评价,不仅要在极端危险的场景,也需要在一些相对安全的场景中进行,评价其控制决策行为是否能够使得整个场景变得更加安全,以及是否能够提高车辆的通行效率。因此现有的威胁度量指标并不适用于对自动驾驶车辆的安全性进行评价。

目前,对于 L3 级以上的自动驾驶车辆仍缺乏一套成熟而完善的安全性评价方法,世界范围内也还没有一个统一的评价标准^[15],对于跟车场景下自动驾驶车辆安全性评价方法的研究,目前主要以静态的跟车距离作为评价依据,只能用于评价某一时刻的安全性,难以体现车辆跟车行驶时的动态过程,并且没有考虑车辆的通行效率。

针对上述问题,本文提出了一种新的评价指标 STCI(Safety and Traffic Capacity Index),通过对 STCI 指标计算值及其参数值的分析,不仅可以得到对于自动驾驶车辆安全性和通行效率的评价,也可以得到自动驾驶车辆在其所处的动态跟车场景下的最优制动时刻,实现对自动驾驶车辆实际制动时刻以及在某个时刻下制动减速度的评价,从而为自动驾驶车辆控制决策算法提供参考,并且能够用于扩展 ADAS 的功能。

1.2 国内外研究现状

关于自动驾驶车辆的安全评估技术一直是学术界研究的热点,国内外学者进行了很多扎实的研究工作,本节将进行详细的介绍。

1.2.1 碰撞风险评价指标研究现状

目前已经有很多学者针对不同交通场景提出了各种碰撞风险评价指标^[16],可以计算得到车辆发生碰撞的可能性以及发生碰撞后的严重程度,从而实现安全评估^[17],目前主要应用在主动安全系统上。这些指标可以分为两大类,即时间类评估指标和非时间类评估指标,其中非时间类评估指标又可以根据距离、加速度等属性进行划分^[18]。

现阶段广泛使用的基于时间的评价指标是碰撞时间 TTC (Time-to-Collision),表示两辆车以当前速度在同一轨迹上行驶,直到发生碰撞为止所需要的时间^[19],计算方式为车辆的相对距离与相对速度的比值,其计算值通常作为 ADAS 系统决策过程中启用预警或自动干预的阈值^[20],文献^[21]研究了在交通事故频发的各种场景下 TTC 指标的最优预警阈值。

Michiel^[22]等人利用 TTC 指标提出了两种新的评价指标,第一种被称为 TET

指标，它代表主车在一定时间内与前车低于 TTC 指标安全阈值的时长总和，为求取该指标，假定 TTC 在很短的时间段内是不变的。另一种被称为 TIT，该指标计算主车在一定时间内 TTC 指标安全阈值与 TTC 计算值之差的积分。TET 指标对于区分不同场景之间碰撞风险的差异很有用，常用于比较研究，而 TIT 指标尽管在理论上更具吸引力，但在更复杂的交通场景下很难解释其含义。

Kaan^[23]等人根据车辆的相对距离、相对速度和相对加速度等信息对场景进行了划分，提出了一个新的碰撞风险评价指标 CI。该指标结合多种因素来综合反映可能发生的碰撞的严重性，借鉴了车辆动力学的思想，以描述速度对碰撞所涉及的动能的影响，并且考虑了碰撞发生之前所经过的时间，通过该时间可以解释发生碰撞风险的可能性，该指标涉及到多种条件判断计算复杂度较大。

Chan^[24]等人基于车辆在碰撞前的速度越高后果越严重以及后车制动的时间越长越有可能避免碰撞的假设，提出了 CIF 评价指标，该指标可以通过评估交通状况所涉及的安全等级来评估碰撞的可能性和严重性。

以上这些碰撞风险评价指标可以表征车辆驾驶过程中发生碰撞的可能性，但是这些指标大都基于固定的指标安全阈值进行计算，同时也很难对车辆运行的控制行为进行评价。

1.2.2 安全性评价方法研究现状

目前对于自动驾驶车辆进行安全性评价的方法主要包括两类，一类是基于物理模型的方法，另一类是基于数据驱动的方法。现有的研究大多数都是针对 L2 级自动驾驶车辆的安全性评价，而已公开发表的关于 L3 级以上自动驾驶车辆安全性评价方法的相关文献较少。接下来将进行详细的介绍。

(1) 基于物理模型的方法

Inoue Y^[25]等人针对跟车场景中单纯将 TTC 指标作为碰撞风险的衡量标准时在两车相对速度比较接近的情况下出现的问题，提出了一种基于前方车辆假想制动过程的计算模型，以评估车辆的安全性。Chen Y L^[26]等人提出了同时考虑 TTC 和安全制动距离的方法来解决高速公路下车辆的安全性评估问题。Eidehall^[27]等人使用递归搜索树的方法实现了在多车辆环境中对于车辆安全性的评估。以上这些方法在 L2 级自动驾驶预警系统中表现良好，可以对碰撞风险做出判断，但是这种方法舍弃了车辆行驶过程中的一些状态信息，可能会导致安全性评估结果不准确，并且这类方法由于是以车辆发生碰撞的概率来评估安全性，对于一些相对安全的场景下车辆的安全性评估性能将会下降。

Borrelli^[28]等人提出了一种基于模型预测控制 MPC 的方法来评估自动驾驶车辆在行驶过程中的安全性，它由一个约束优化问题构成，依据系统当前和过去

的状态滚动优化以降低目标函数值,从而预测车辆在未来一段时间内的最优行驶轨迹,通过对未来运动的预测,可以获得最危险的位置,然后通过风险指标对风险进行量化,进而实现对车辆安全性的评估。该方法需要获取车辆的动力学模型,并且模型构建过程也较为复杂,可用于车辆轨迹规划,而不适合用于车辆驾驶行为评价。

也有研究基于概率的方法来计算车辆的安全性水平,其基本思想是利用系统的不确定性信息为不同的事件分配概率。Houénou^[29]等人采用蒙特卡洛法得到了主车与前车在未来几秒内的碰撞概率,提出了一种考虑车辆预测轨迹误差的安全性评估方法。Katrakazas^[30]等人使用 DBN 将网络级碰撞预测与车辆级碰撞预测相结合来计算车辆的安全性。在网络层面,安全评估基于交通信息,如路段的平均速度和交通流量,而在车辆层面,安全评估基于周围车辆的运动预测。

针对自动驾驶车辆安全性测试评价需要大量的车辆,较长的测试时间以及大量资金预算的问题,Zhao^[31]等人基于真实的自然驾驶场景数据,使用分段混合模型对场景进行建模并提取出关键场景,提高了车辆遇到危险场景的概率,并将车辆动态模型输入到虚拟仿真系统中进行验证,从而用于加速对于自动驾驶车辆行驶安全性的测试评价。

常宇^[32]等人综合考虑了 20 项道路特征提出基于 AHP 的干线公路行车安全性评估方法,卞光宇^[33]等人在传统道路特征的基础上加入了车辆的异常驾驶行为特征,最终得到车辆行驶时的安全性综合评分。以上两种行车安全性评价方法没有考虑速度、加速度等车辆运行过程中的状态。

刘瑞^[34]等人提出了一种跟车场景下的潜在危险估计模型,采用核密度估计描述了驾驶员的纵向加速行为,可以描述两车相对速度较小时的危险等级。王笑笑^[35]等人基于高速公路上的交通流运行特性,选取宏观风险和跟车碰撞风险度量指标,基于实测的交通流数据采用定量与定性相结合的方法研究了高速公路上车辆行驶的安全性。

有很多学者通过对跟车行为的研究,开发了多种汽车跟车模型^{[36][37][38]},例如 GHR 模型、线性跟驰模型等。王晓安^[39]等人依据车辆的行驶状态构建了九种临界安全车距、基本安全车距和充分安全车距模型,并在此基础上建立了车辆跟车行驶时的安全度评价模型,将两车距离为临界安全车距时的安全度设为 60,并假定随着实际间距与临界安全车距的比值的增大,车辆安全度将无限趋近于 100。该评价模型仅考虑了车辆行驶的安全性,而没有考虑车辆的通行效率。

(2) 基于数据驱动的方法

基于数据驱动的方法主要是采用机器学习^[40],其中输入是系统的当前状态,输出是对未来状态的预测。例如采用人工神经网络(ANN)、递归神经网络(RNN)、

支持向量机 (SVM)、决策树等模型来预测车辆发生碰撞的概率。使用机器学习的方法建立安全性评估模型的优势是它们能够方便地捕获输入与输出间复杂的非线性关系^[41]。而在监督学习的情况下,用作训练算法的数据首先需要进行标签的标注,要想得到较好的模型训练效果需要大量的环境数据,然后经过复杂的预处理工作才能用于实际训练。

(3) 其他方法

中国汽车工程研究院发布的 2020 版 i-VISTA 智能行车辅助评价规程中,从安全、舒适和能耗等方面对智能网联汽车的驾驶性能进行了评价^[42],并将评价结果分为了优秀、良好、一般、较差四个等级。以安全性评价为例,该规程的评价方法是通过设置一些固定的场景来进行评价,比如设置前车静止时主车分别以 50km/h、60km/h 和 70km/h 的速度向前靠近的场景,并对每一个场景设置一个固定的分数,若主车能够刹停并避免碰撞那么就能获得这个分数,通过多项测试后车辆的总分数所处的评分等级即为车辆的安全性评价等级,对于舒适度和能耗的评价同理。该规程中的评价方法比较简单,并且是针对固定的场景进行评价,局限性较大,对于自动驾驶车辆安全性的评价应该在大规模随机生成的场景下反复进行测试才能得到较为精确的结果。

1.3 论文主要研究内容及组织结构

1.3.1 主要研究内容

本研究依托长沙市湘江智能科技创新中心,就跟车场景下自动驾驶车辆的安全性与通行效率评价方法进行了深入研究。基于现有的威胁度量指标 TTC,以自动驾驶车辆在动态跟车场景下行驶时的最小 TTC 值和最优 TTC 阈值作为参数,设计了一个新的评价指标 STCI,用于评价自动驾驶车辆的安全性和通行效率。通过对 STCI 指标计算值及其参数的分析,能够得到自动驾驶车辆在其所处的动态跟车场景下的最优制动时刻,实现对自动驾驶车辆制动决策行为的评价。

本文对 STCI 指标最小 TTC 参数以及最优 TTC 阈值参数的计算方法进行了深入研究,通过理论推导了跟车场景下 TTC 指标可能出现的变化趋势,并根据变化趋势研究了不同场景状态参数组合下计算 STCI 指标最小 TTC 参数的解析式。由理论分析结合具体实例证明了使用最小 TTC 值作为 STCI 参数的合理性与有效性。通过建立跟车场景的物理模型来求解 STCI 指标的最优 TTC 阈值参数,并提出了一种基于机器学习快速计算最优 TTC 阈值的方法。最后通过 PreScan 与 Simulink 的联合仿真对本文提出的 STCI 指标的有效性和可行性进行了验证。

1.3.2 组织结构

本文围绕跟车场景下自动驾驶车辆的安全性及通行效率的评价方法进行研究，共分为六章。各章节的主要内容如下：

第一章，绪论。首先对课题的背景及研究意义进行了说明，然后分析了近年来国内外对于自动驾驶车辆安全性评价的研究现状，最后对本文的主要研究内容和组织结构进行了简要概述。

第二章，安全性与通行效率评价模型设计。本章首先对跟车场景进行了定义和划分，然后针对跟车场景提出了一种新的评价指标 STCI，用于评价自动驾驶车辆在跟车场景下行驶时的安全性和通行效率，并详细分析了指标构建的过程及车辆分级标准。

第三章，STCI 指标最小 TTC 参数分析及计算方法研究。本章对 STCI 指标的最小 TTC 参数进行了深入研究，将整个跟车场景分为后车逼近和后车制动两个阶段，通过理论推导详细分析了 TTC 指标在每个阶段下大于 0 时的变化趋势，综合后得到完整的变化趋势。此后研究了最小 TTC 与车辆制动行为之间的关系，根据不同的变化趋势确定计算最小 TTC 参数的解析式，最后通过实验对 TTC 指标变化趋势以及最小 TTC 参数解析式的理论推导结果进行了验证。

第四章，STCI 指标最优 TTC 阈值参数分析及计算方法研究。本章首先根据场景的状态参数建立了跟车物理模型，并通过数值解法对 STCI 指标最优 TTC 阈值参数进行了求解。针对数值解法求解效率较低的问题，提出了一种基于机器学习快速计算最优 TTC 阈值参数的方法，并对两种确定最优 TTC 阈值的方法进行了实验对比，证明了快速计算最优 TTC 阈值参数方法的有效性。

第五章，基于 PreScan 与 Simulink 的跟车场景联合仿真实验设计。本章首先通过 PreScan 构建虚拟跟车场景，并在 Simulink 中分别设计前车与后车的控制算法，然后通过仿真平台验证了 TTC 指标变化趋势的正确性，通过设计消融实验在不同跟车场景下对 STCI 指标的有效性和可行性进行了验证。

第六章，总结与展望。本章对本文的研究工作进行了总结，归纳论文的主要创新点与成果，对文章存在的不足进行了分析，并对研究工作提出了展望。

2 安全性与通行效率评价模型设计

自动驾驶汽车主要包含环境感知、规划、通信与控制模块。环境感知模块所感知的周围环境信息与通信得到的 V2X 信息相结合传递给规划模块^[43]。规划模块规划全局路径以及局部轨迹,生成目标轨迹作为控制模块的输入。最后控制模块控制车辆进行自动化的轨迹运行。车辆在进入自动驾驶状态后,其一切驾驶决策行为都是由系统控制的,而车辆的运行轨迹则是车辆自动驾驶系统功能的集中体现。在同样的场景下,车辆在不同时刻不同的决策行为会对自车和其他车辆的安全性和通行效率带来不同的影响。

目前对于跟车场景下自动驾驶车辆安全性评价的方法计算得到的是车辆在某一个具体时刻下的安全性评分,并不能很好的反映出车辆行驶的动态过程,并且没有考虑车辆的通行效率。因此,本章首先对跟车场景进行了定义和划分,将其定义为一个动态的过程,根据场景状态参数的不同组合对实际交通环境下可能出现的跟车场景进行了细分,确定了本文研究的范围。然后设计了一个新的评价指标 STCI,该评价指标并不是以两车是否会发生碰撞为依据来评价安全性,而是以车辆行驶时的状态信息为依据来进行评价,将自动驾驶车辆在跟车行驶过程中最小的 TTC 值和该场景下的最优 TTC 阈值作为指标的参数,其计算结果可直接作为对自动驾驶车辆在动态跟车过程下安全性和通行效率的评分,并且能够实现对于自动驾驶车辆在动态跟车过程下制动决策行为的评价。

2.1 跟车场景的定义及划分

在定义本文研究的跟车场景之前,首先介绍一下自动驾驶中“场景”的概念。“场景”(Scenario)一词原指在生活中特定的时间和地点下的情景,随着科技的发展,场景的概念在各领域逐渐得到拓展,例如气候变化场景^[44]、能源工业场景^[45]等,不同领域对于场景一词有着不同的解释和定义。在自动驾驶领域,有很多研究者提出了各自对于“汽车驾驶场景”的理解,Elrofai^[46]等人提出“场景指的是在特定的时间内,主车周围动态环境的连续变化,包括主车在该环境下产生的行为”。西安交通大学的郑南宁院士^[47]则指出“场景应该定义为某个交通场合在特定的时间和空间中的具体情景,在这个情景下我们可以得到当前环境中丰富的感知数据描述”。

综合以上观点,我们可以将自动驾驶车辆驾驶场景的内涵理解为:自动驾驶车辆与其所在周围环境的各组成要素在一段时间内的总体动态描述,不同的车辆间距、速度、加速度和朝向信息会构成不同的场景。

实际交通道路上行驶的车辆其运行状态是非常复杂的,车辆的加速和减速过

程会反复交替,但是这些复杂的运行过程与时间片段可以由一系列的场景进行描述。通常,跟车场景会包含四个阶段,如下图 2-1 所示。

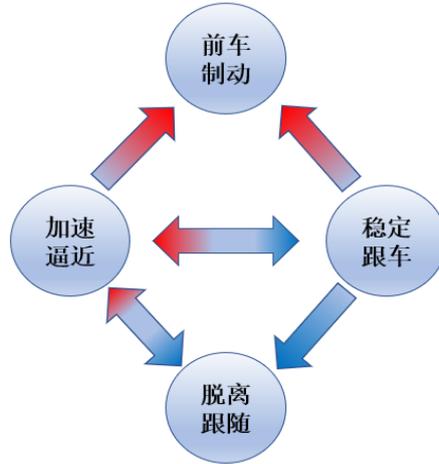


图 2-1 跟车场景的四个阶段

(1) 加速逼近阶段

该阶段通常是跟车场景的开始,主车以大于前车的速度逐渐逼近。若逼近过程中主车刹车减速至与前车速度相等,则转换为稳定跟车阶段;若该阶段中前车紧急制动,则场景进入前车制动阶段;若主车刹车减速至速度低于前车,则会脱离跟车场景。

(2) 前车制动阶段

当前车发起制动时进入该阶段,此时主车需要通过制动来避免碰撞。

(3) 稳定跟车阶段

该阶段是跟车场景中最稳定的阶段,主车将与前车保持相等的车速跟车行驶。若前车加速度增大,则后车同样增大加速度保持跟车,并进入加速逼近阶段;若前车减速,则进入前车制动阶段;若前车加速度增大,后车速度不变则脱离跟车场景。

(4) 脱离跟随阶段

该阶段前车速度增大,主车与前车距离逐渐增大,安全性增加,并逐渐退出跟车场景。若主车增大加速度以跟随前车,则重新开始新的跟车场景,进入加速逼近阶段。

由以上四个阶段的分析可知,跟车场景中主车与前车通常在几个状态间来回转换,其中加速逼近阶段和前车制动阶段为非静态的跟车场景。本文主要对非静态跟车场景下自动驾驶车辆的安全性和通行效率进行评价。在这两个阶段中,主车需要在适当的时间减小车辆速度以达到平稳的跟车状态。

本研究将同车道上行驶的两辆车从初始时刻开始,到前车加速度发生变化之

前的整个过程视为一个待评价的跟车场景，其中前车在行驶时的加速度可能存在多种变化，包括数值变大、数值变小、变为零或者符号发生改变等。在对实际交通环境进行场景划分时可以假定一个变化量阈值，当前车加速度的变化超过阈值后便开始一个新的场景，因此两车在同车道上行驶时的整个时间片段即可由多个待评价的场景进行表征，如下图 2-2 所示。

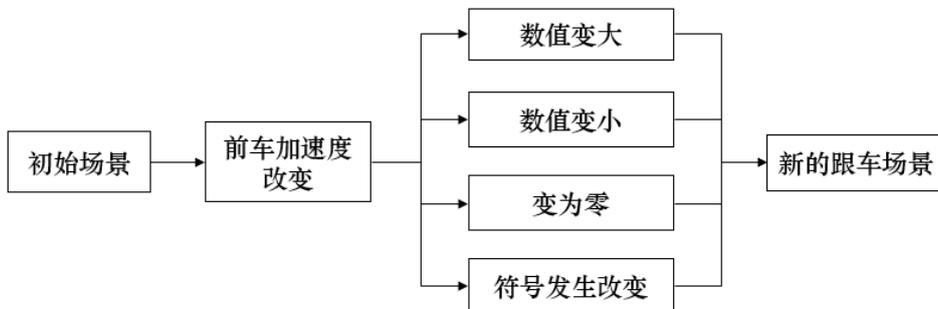


图 2-2 跟车场景划分

对于同车道上行驶的两辆车，其可能出现的运行状态就是加速、减速和匀速行驶三种状态的组合，而当车辆在纵向运行速度受到前方车辆影响时就会产生跟车场景。依据前车加速度的变化，整个跟车时间片段可以切分为一系列的跟车场景。具体来说，本研究中的后车是自动驾驶车辆，而其前方车辆可以是自动驾驶车辆也可以是传统的由驾驶员驾驶的车辆，对于一个跟车场景，在初始时刻两车间存在一定的初始间距，各自以其初始速度和加速度向前行驶，在初始速度上存在三种可能：1) 前车初始速度比后车快；2) 前车初始速度与后车相同；3) 前车初始速度比后车慢。并且初始时刻前车的加速度可以是任意值，即前车可以处于匀加速、匀速或者匀减速三种状态，而后车在初始时刻的加速度大于或者等于 0，即后车处于匀加速或者匀速行驶状态。

本研究将一个场景中后车刚开始加速或者匀速行驶的时刻作为跟车场景的初始时刻，假设初始时刻前车与后车的初始速度分别为 v_f 和 v_e ，初始加速度分别为 a_f 和 a_e 。在不同场景状态参数的组合下，会构成多种不同的跟车场景，如图 2-3 所示。

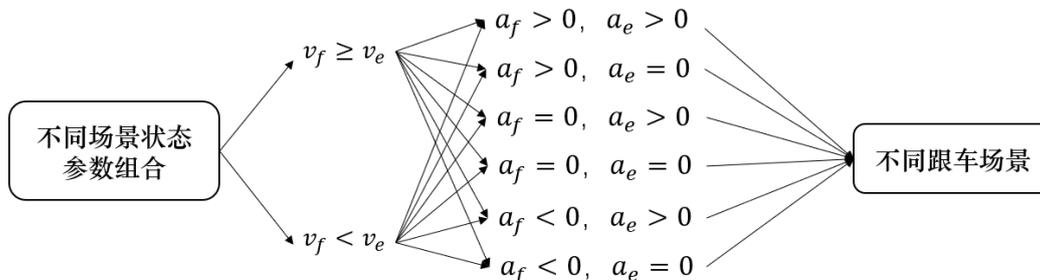


图 2-3 不同场景状态参数组合下可能出现的跟车场景

对于跟车场景的结束时刻，在前车加速度状态发生改变前，若后车制动过程

结束了,且后车车速仍然大于前车车速,那么该跟车场景的结束时刻为后车结束制动的时刻;若后车经过制动后车速与前车相等了,由于后车继续制动会使得车速小于前车,之后的过程将不构成跟车场景,因此该跟车场景的结束时刻为两车车速相等的时刻。若后车制动过程结束前,后车车速仍然大于前车车速,且此时前车的加速度状态发生改变,那么该跟车场景的结束时刻为前车加速度状态发生改变的时刻。以此类推,车辆在道路上行驶的一个时间段内包含多个不同的跟车场景。

本文将针对上述定义的跟车场景下自动驾驶车辆行驶的安全性和车辆通行效率进行评价,通过 STCI 指标得到的是整个动态跟车过程下对自动驾驶车辆安全性和通行效率的评分,而不是针对某一个具体时刻的评分。

2.2 安全性与通行效率评价函数曲线构造

对于同车道上行驶的前后两辆车,当后车与前车之间的距离越大时,安全性就越高,但是若自动驾驶车辆的驾驶决策使其跟车距离过大,将会影响自车甚至整个交通场景的车辆通行效率;反之,若前后两车间的车距过小,当前车出现紧急制动的情况时,后车就没有足够的时间和距离采取制动措施,很容易会导致追尾事故的发生。由以上剖析,同车道上行驶的前后两辆车之间应该存在一个最佳的车距值,在该车距下稳态行驶时既能保证车辆行驶的安全性,又能保证较好的车辆通行效率。

最佳车距的取值没有绝对的标准,只有动态标准,其中对于最佳车距最直接、最重要的影响因素是车速。不同的车速下所需的刹车距离是不一样的,根据《中华人民共和国道路交通安全法》中的规定^[48]:机动车在高速公路上行驶时,车速若超过 100km/h,安全车距应为 100 米以上。目前最常用的经验法则是车辆间的最佳安全车距在数值上等于后车车速^[49]。例如,后车车速为 90km/h,则它与前车的最佳安全车距是 90 米。

在跟车场景下,当两辆车在当前车速下的最佳安全车距内相距越近时是越危险的,越容易发生追尾事故,而相距越远时则越安全,此时主要评价的是车辆的安全性。假设两车速度相等时的车间距离为 ΔS ,在最佳安全车距内随着 ΔS 的增大,整个场景的安全性评价函数值是逐渐变大的,但是评价函数值变化的趋势并不是简单的随着 ΔS 的增大而线性增长^[50]。

当两车速度相等时的距离很近时,若前车紧急制动,后车在该场景下与前车发生追尾碰撞的概率较大,此时随着车间距离的增大,安全性评价函数值的增长速率会逐渐变快,因此这部分评价函数的曲线斜率是逐渐增大的。当两车距离接近最佳安全车距时,若前车紧急制动,后车在该场景下与前车发生追尾碰撞的概

率已经较低,此时随着车间距离的增大,以安全性为主的评价函数值的增长速率会逐渐变缓,因此这部分评价函数的曲线斜率是逐渐减小的。

假设一个场景中后车与前车速度相等时的车速为 60km/h,根据经验法则此时后车与前车的最佳安全车距是 60 米,在这个场景下安全性评价函数值随 ΔS 变化的曲线如图 2-4 所示。

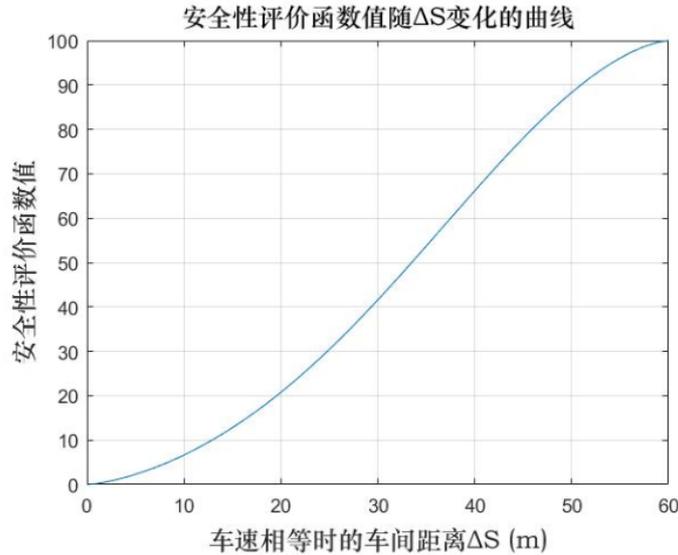


图 2-4 安全性评价函数值随 ΔS 变化的曲线

当 ΔS 大于当前车速下的最佳安全车距时,此时两车之间处于一个非常安全的状态,该车距下后车有足够的距离和时间避免与前车发生碰撞,因此在该场景下主要评价的是车辆的通行效率。 ΔS 越大时评价函数值越小,表示车辆通行效率越低,并且这部分评价函数的曲线斜率会经历以下三种状态:

(1) 在 ΔS 超过最佳安全车距不多的情况下,比如两车在某一场景下的最佳安全车距是 60 米,此时车辆间的实际距离不管是 62 米,还是 65 米,对于后车以及整个交通场景下的通行效率的影响都不会很大,所以评价函数值是处于缓慢下降的状态,此时的评价函数曲线斜率较小;

(2) 随着 ΔS 的增大,车间距离对于车辆通行效率的影响逐渐显现出来,评价函数值下降的速率逐渐变快,此时的评价函数曲线斜率会逐渐变大;

(3) 当 ΔS 远超过最佳安全车距时,评价函数值已经较低,随着 ΔS 的增大,评价函数值减小的速率会逐渐变缓,并且评价函数值无限趋近于 0,此时的评价函数曲线斜率会逐渐减小。

仍然以后车与前车速度相等时的车速是 60km/h 的场景为例,在这个场景下车辆通行效率评价函数值随 ΔS 变化的曲线如图 2-5 所示。

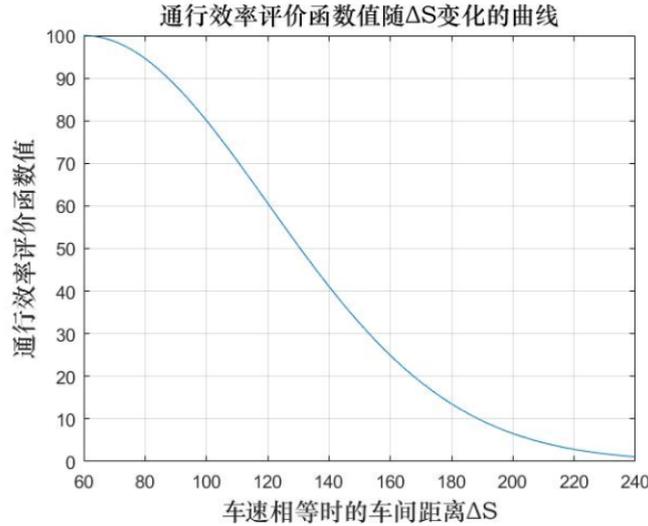


图 2-5 通行效率评价函数值随ΔS变化的曲线

将以上两段曲线合并后即可得到整个跟车场景下对于自动驾驶车辆安全性和通行效率的综合评价函数曲线，其最高值为 100，表示后车在某一时刻以某一减速度制动时可以使得该跟车场景得到最好的行驶安全性和车辆通行效率；评价函数曲线的最小值为 0，表示后车与前车在相对距离为 0 时后车的速度仍然比前车快，此时两车不可避免地会发生追尾碰撞。

通过上述对于评价函数曲线的分析，本研究构造了一个分段函数来表征这条曲线，如式(2-1)所示。

$$F(x) = \begin{cases} \frac{100 \cdot x^{1.4}}{x^{1.4} + (r-x)^{1.5}} & x \leq r \\ 100 \cdot e^{-\frac{(x-r)^2}{2r^2}} & x > r \end{cases} \quad (2-1)$$

其中， r 表示两车速度相等时的车速， x 表示两车速度相等时的车间距离。

本研究取 r 等于 30, 60 和 90 得到三个分段函数式，并将它们绘制在同一张图上如图 2-6 所示。

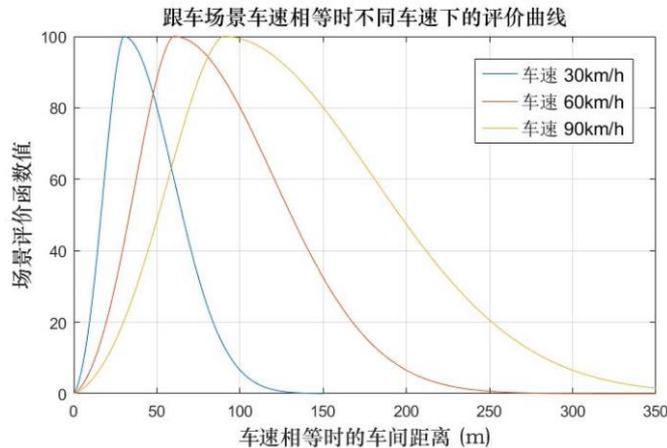


图 2-6 跟车场景车速相等时不同车速下的评价曲线

2.3 STCI 评价指标设计

在一个跟车场景中，尽管两车最终并不一定会达到车速相等这一状态，但是由于跟车场景的初始时刻以及初始状态参数已经确定，包括前后车的初始速度、加速度和初始间距等，当后车在某个时刻开始以某一减速度制动后，该跟车场景的状态参数将完全确定。为了得到该场景下自动驾驶车辆的安全性和通行效率的评分，同时评价自动驾驶车辆在该场景下制动行为(包括制动减速度以及制动时刻)的好坏，可以假设自动驾驶车辆继续保持当前减速度运行，并统一以其与前车速度相等时的车间距离为依据来进行评价。

通过计算两车速度相等时的车速 r ，以及此时的车间距离 x ，并将这两个参数代入式(2-1)，可以将计算得到的结果直接作为该跟车场景下自动驾驶车辆安全性和通行效率的评分，并且可以用于对自动驾驶车辆的制动决策行为进行评价。

跟车场景中，当车辆的状态参数完全确定后，两车速度相等时的车速以及车间距离就是两个确定的值，可以理解为这两个确定的值是由该场景的状态参数所决定的结果，那么以这两个确定的值作为参数去计算整个跟车场景下自动驾驶车辆安全性和通行效率的评分其实是以结果为导向来得到的，这会导致不同的刹车时刻与减速度的配合出现相同的评价结果，例如自动驾驶车辆在偏晚的时刻以较大的减速度刹车，与在合适的时刻以较小的减速度刹车可能会得到相同的评分。但是这两种行为反映出的系统性能和给乘客带来的感受是完全不同的。在进行自动驾驶车辆的安全性评价时，应该尽可能的区分车辆性能。

在实际的跟车场景中，两车速度相等时的车间距离 x 可能并不存在，也就是后车在某时刻以某一减速度制动会导致两车在相对距离为 0 时，后车的车速仍然比前车快，此时两车将发生追尾碰撞，如果依然去计算两车速度相等时的车间距离，那结果必然为负数，将负的车间距离代入式(2-1)去计算这一类场景下自动驾驶车辆安全性和通行效率的评分显然是不合理的，并且也不能很好的用于对自动驾驶车辆在当前场景下的制动决策行为进行评价。因此，式(2-1)不能满足这一类场景下对自动驾驶车辆安全性和通行效率评价的要求。

本文在碰撞风险评价指标研究现状中介绍了目前常用的 TTC 指标，其计算公式定义为：

$$TTC(t) = \frac{|D(t)|}{V_{ego}(t) - V_{forward}(t)} \quad (2-2)$$

其中， $D(t)$ 是 t 时刻主车与前车的相对距离， $V_{ego}(t)$ 是 t 时刻主车的速度， $V_{forward}(t)$ 是 t 时刻前车的速度。

由 TTC 指标的计算公式可知，当后车速度小于前车时，TTC 指标计算值为

负数，若保持该状态行驶两车距离将越来越远，不会发生追尾碰撞，而当后车速度比前车大时，TTC 指标计算值为正数，两车有可能会发生碰撞，若两车此时的间距较小并且两车的相对速度较大时的场景是很危险的。在 TTC 计算值大于 0 的情况下值越小代表场景越危险^[19]，TTC 最小值出现的时刻则表示整个场景中最危险的时刻。

由于后车是自动驾驶车辆，其在何时以何种减速度发起制动是不确定的，不同的驾驶决策行为会导致整个场景 TTC 的最小值出现的时刻及大小发生变化，其数值是与后车制动时间以及制动减速度有关的。

而对于场景中的最优 TTC 阈值，当后车在某一时刻开始制动后，其制动减速度 a_s 就确定了，此时整个跟车场景下一定存在一个时刻 t^* ，使得后车在该时刻以其制动减速度制动是最佳的，这里的最佳指的是当后车以 a_s 的减速度制动时，相比于其他的制动时刻，在 t^* 时刻制动能够使得车辆达到最好的安全性和通行效率，该时刻制动后场景下的最小 TTC 指标的计算值即为整个跟车场景下的最优 TTC 阈值。换句话说，在当前跟车场景下使场景最小 TTC 达到最优 TTC 阈值的制动行为是最佳的决策行为。

由以上分析可知，最小 TTC 值和最优 TTC 阈值可以很好的反映出整个跟车场景的动态过程，以这两个值作为参数去计算跟车场景下自动驾驶车辆安全性和通行效率的评分是以车辆行驶的过程为向来得到的，相比于以结果为导向的评价会更加精确。

因此，本研究对式(2-1)进行了调整，将该式中两车速度相等时的车间距离 x 替换为自动驾驶车辆在跟车场景下行驶时的最小 TTC 值 m_{\min} ，两车速度相等时的车速 r 替换为最优 TTC 阈值 m^* ，并将调整后的计算式称为 STCI 评价指标 (Safety and Traffic Capacity Index)，如式(2-3)所示。

$$STCI = \begin{cases} \frac{100 \cdot m_{\min}^{1.4}}{m_{\min}^{1.4} + (m^* - m_{\min})^{1.5}} & m_{\min} \leq m^* \\ 100 \cdot e^{-\frac{(m_{\min} - m^*)^2}{2m^{*2}}} & m_{\min} > m^* \end{cases} \quad (2-3)$$

以自动驾驶车辆在跟车场景中行驶时的最小 TTC 值和最优 TTC 阈值作为参数，可以计算得到对自动驾驶车辆安全性和通行效率的评分，并且该评分能够反映出车辆在行驶时的动态过程，评价结果也具有较好的可解释性，同时也能够得到自动驾驶车辆在其所处的动态跟车场景下的最优制动时刻，实现对自动驾驶车辆实际制动时刻以及其在某个时刻下制动减速度的评价，从而为自动驾驶车辆控制决策算法的评价提供参考。由于自动驾驶车辆在跟车场景下一定存在最小 TTC 值和最优 TTC 阈值，因此通过这两个参数构建的 STCI 指标可以实现在前后两

车无法达到速度相等的这一类场景下对于自动驾驶车辆安全性以及车辆制动决策行为的评价。

假设随机初始化了一个跟车场景，通过计算得到该跟车场景下的最优 TTC 阈值 m^* 为 7.2，此时的 STCI 评价函数曲线如图 2-7 所示。

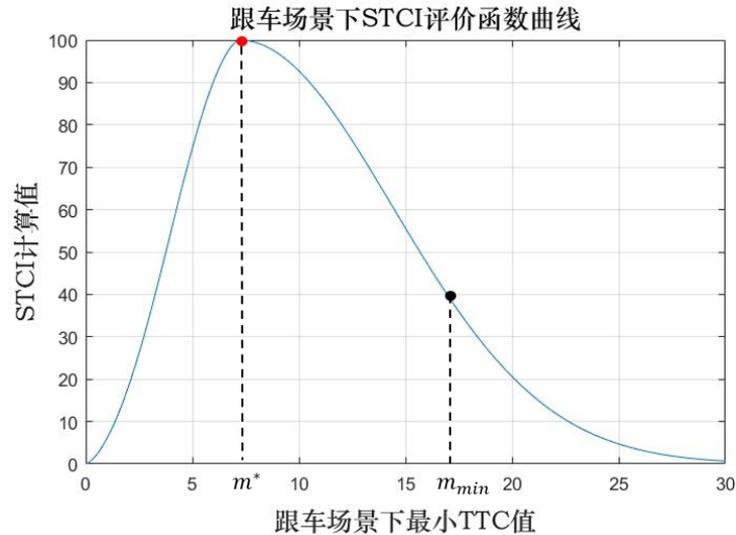


图 2-7 跟车场景下 STCI 评价函数曲线图

图 2-7 中，横坐标表示整个跟车场景下的最小 TTC 值，纵坐标表示 STCI 指标计算值。若该场景下的 m_{min} 比 m^* 小，表示自动驾驶车辆在该时刻以其制动减速度制动的这一个决策行为较晚，会使得车辆的安全性不够高。若该场景下的 m_{min} 比 m^* 大，表示自动驾驶车辆在该时刻以其制动减速度制动的这一个决策行为太早了，车辆行驶的安全性虽然很高，但是也降低了车辆的通行效率。而当 m_{min} 与 m^* 相等时 STCI 评价指标的计算值为 100，表示自动驾驶车辆在该时刻以其制动减速度制动的这一个决策行为既可以保证行车安全，又不会影响车辆通行效率，可以使得自动驾驶车辆在该跟车场景下达到最佳的行驶状态。

本文将 STCI 指标的计算值分为了四个等级用于评价自动驾驶车辆的安全性和通行效率，当计算得到当前场景下的最小 TTC 值比最优 TTC 阈值小时，主要评价车辆的安全性，反之则主要评价车辆的通行效率。以 60 分为界限，STCI 指标评价等级划分如表 2-1 所示。

表 2-1 STCI 指标评价等级划分

0~60	60~75	75~90	90~100
差	及格	良好	优秀

图 2-8 中简要描述了利用 STCI 指标对跟车场景下自动驾驶车辆的安全性和

通行效率进行评价的流程。

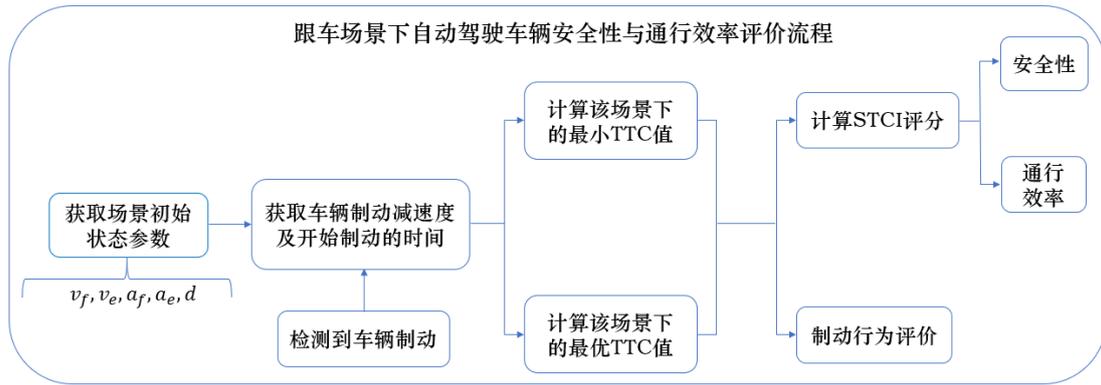


图 2-8 跟车场景下自动驾驶车辆安全性与通行效率评价流程

自动驾驶车辆在进行测试时会实时获取当前场景中的一些状态参数，包括前车与自车的速度、加速度以及两车的间距等，首先确定一个跟车场景的初始时刻，并记录当前时刻下的状态参数，当检测到自车制动时，记录此时制动的减速度以及开始制动的的时间，通过这些参数计算出该场景下的最小 TTC 值以及最优 TTC 阈值，计算完成后将这两个参数代入到 STCI 评价指标中即可得到当前场景下自动驾驶车辆安全性和通行效率的评分，并且能够对自动驾驶车辆的制动决策行为进行评价。通过在多个不同的跟车场景下对自动驾驶车辆的安全性和通行效率进行测试评价，可以得到对于自动驾驶车辆整体驾驶决策能力的评价。

2.4 小结

本章首先对跟车场景进行了定义和划分，根据场景状态参数的不同组合对实际交通环境下可能出现的跟车场景进行了细分，确定了本研究需要评价的对象。分别构建了对自动驾驶车辆的安全性和通行效率进行评价的函数曲线，并定义了曲线的函数式。将自动驾驶车辆在跟车场景下行驶时的最小 TTC 值和最优 TTC 阈值作为参数构建了一个新的评价指标 STCI，用于评价自动驾驶车辆行驶的安全性和通行效率，并实现对于车辆制动决策行为的评价。本章对 STCI 指标的优势进行了分析，并介绍了利用 STCI 指标对跟车场景下自动驾驶车辆的安全性和通行效率进行评价的流程。

3 STCI 指标最小 TTC 参数分析及计算方法研究

本章旨在从理论推导方面论证使用最小 TTC 作为 STCI 参数进行车辆驾驶决策系统评价的合理性，并求得最小 TTC 的计算解析式。通过分析跟车场景模型，获得了不同场景下 TTC 指标的变化曲线，基于此研究了最小 TTC 受到车辆制动行为影响的情况，进一步明确了本文所研究的跟车场景的类型与范围，最后通过实例验证了本章理论推导的正确性。

由于 TTC 指标在达到最小值时所在的时刻反映的是整个跟车场景下最危险的时刻，而只有当后车速度比前车快时才会有追尾碰撞的可能，此时 TTC 指标大于 0，并且值越小代表场景越危险，因此本文研究的最小 TTC 参数针对的是其在大于 0 时的最小值。

为了求解最小 TTC 参数，本文首先将整个跟车场景分为后车逼近和后车制动两个阶段，通过理论推导详细分析了 TTC 指标在每个阶段下大于 0 时的变化趋势，综合后得到完整的变化趋势，然后根据不同的变化趋势确定计算最小 TTC 参数的解析式。通过研究跟车场景下 TTC 指标的变化趋势以及最小值出现的情况，不仅可以用于计算 STCI 指标，也可以为自动驾驶车辆行驶的轨迹规划提供参考和依据。

3.1 跟车场景下 TTC 指标变化趋势分析

一个完整的跟车场景根据后车驾驶行为可以分为逼近和制动两个阶段，直到两车速度相等。本节将对完整的跟车场景下 TTC 指标可能出现的变化趋势进行分析，便于后续计算 STCI 指标最小 TTC 参数的解析式。首先设计了一个跟车场景，如图 3-1 所示。

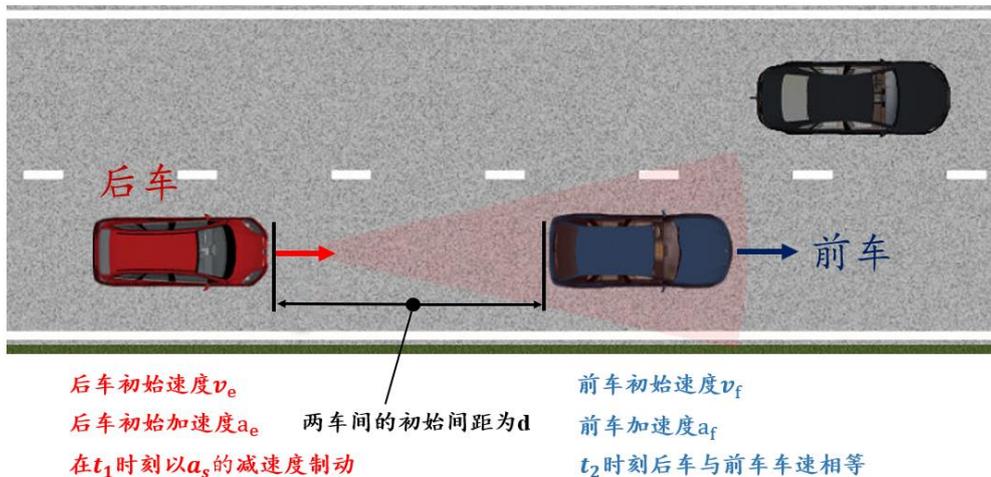


图 3-1 跟车场景示意图

假设初始时刻后车与前车间的距离为 d ，前车的初始速度为 v_f ，加速度为 a_f ，后车的初始速度为 v_e ，加速度为 a_e ，在 t_1 时刻，前车的速度变为 v_f' ，后车的速度变为 v_e' ，并且此时后车以 a_s 的减速度开始制动，至 t_2 时刻两车速度相等。

由于实际交通场景下的状态参数有多种组合，比如前车初始时刻可能处于加速、减速或者匀速行驶状态，前车的初始速度或者初始加速度可能比后车大，本文选取了其中一种可能出现的场景绘制了前车与后车在跟车场景下行驶时速度随时间变化的曲线，如图 3-2 所示。

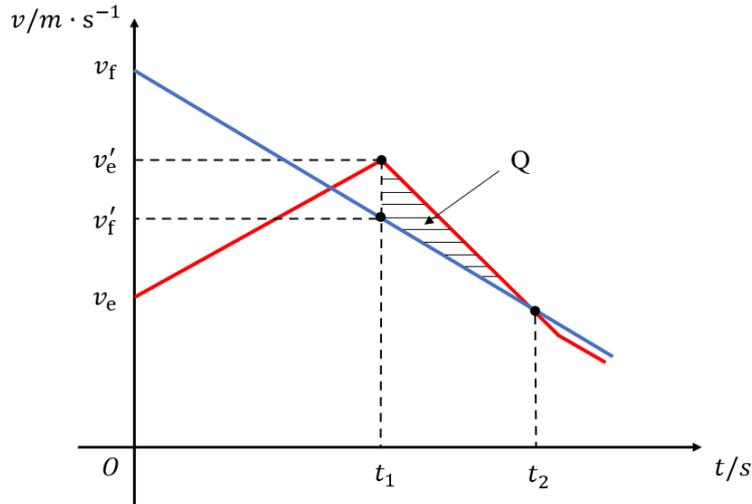


图 3-2 跟车场景下前车与后车的速度随时间变化的曲线

其中蓝色的线代表前车的行驶速度随时间变化的曲线，该场景下前车处于减速状态，红色的折线代表后车的行驶速度随时间变化的曲线，阴影部分 Q 的面积表示后车在制动阶段与前车之间的相对位移量。在跟车场景中后车的驾驶状态一共包括两个阶段：

(1) 后车逼近阶段 ($0 \sim t_1$)

在该阶段中，初始时刻前车与后车之间存在着间距 d ，前车可以是加速、减速或者匀速向前行驶，而后车则以恒定的加速度或者恒定的速度不断接近前车；

(2) 后车制动阶段 ($t_1 \sim t_2$)

前车继续保持原有状态向前行驶，而后车从 t_1 时刻开始以恒定减速度减速直到速度与前车相同。

接下来将分阶段对 TTC 指标在跟车场景下的变化趋势进行分析，并进行综合以得到完整的变化趋势，研究在不同跟车场景下制动行为对最小 TTC 的影响。

3.1.1 后车逼近阶段

首先分析在后车逼近阶段 TTC 指标的变化趋势。假设从初始时刻至 t 时刻前车行驶的距离为 S_1 ，后车行驶的距离为 S_2 ，两车在 t 时刻的间距为 ΔD ，由匀

加速运动的位移计算公式可知：

$$S_1 = v_f t + \frac{1}{2} a_f t^2 \quad (3-1)$$

$$S_2 = v_e t + \frac{1}{2} a_e t^2 \quad (3-2)$$

$$\Delta D = d + S_1 - S_2 \quad (3-3)$$

假设 t 时刻前车的速度为 v_{ft} ，后车的速度为 v_{et} ，两车的速度差为 ΔV 。根据匀加速运动的速度计算公式可知：

$$v_{ft} = v_f + a_f t \quad (3-4)$$

$$v_{et} = v_e + a_e t \quad (3-5)$$

$$\Delta V = v_{et} - v_{ft} \quad (3-6)$$

由 TTC 指标的计算式可知， t 时刻的 TTC 指标值为：

$$TTC(t) = \frac{\Delta D}{\Delta V} = \frac{d + S_1 - S_2}{v_{et} - v_{ft}} \quad (3-7)$$

将式(3-1)、(3-2)、(3-4)以及(3-5)代入式(3-7)化简后得到：

$$TTC_1(t) = \frac{d + (v_f - v_e)t + \frac{1}{2}(a_f - a_e)t^2}{(v_e - v_f) + (a_e - a_f)t} \quad (3-8)$$

当 $t \leq t_1$ 时，TTC 指标的计算值可由式(3-8)求得。对式(3-8)求导后得到 TTC 指标在后车逼近阶段下的导数为：

$$TTC_1'(t) = \frac{-\frac{1}{2}[(a_f - a_e)t - (v_e - v_f)]^2 - \frac{1}{2}(v_f - v_e)^2 - d(a_e - a_f)}{(v_e - v_f + a_e t - a_f t)^2} \quad (3-9)$$

由数学知识可知，函数在其一阶导数小于 0 的范围内是单调递减的，而在一阶导数大于 0 的范围内是单调递增的，所以可以通过分析式(3-9)的正负来判别 TTC 指标的变化趋势，由于式(3-9)中的分母部分恒大于 0，因此只需要分析其分子部分的正负情况。可以将式(3-9)的分子部分拆分为三个子变量的加和：

$$\begin{aligned} \text{numerator}_1 &= -\frac{1}{2}[(a_f - a_e)t - (v_e - v_f)]^2 - \frac{1}{2}(v_f - v_e)^2 - d(a_e - a_f) \\ &= \text{PartA}_1 + \text{PartB}_1 + \text{PartC}_1 \end{aligned} \quad (3-10)$$

其中，

$$PartA_1 = -\frac{1}{2}[(a_f - a_e)t - (v_e - v_f)]^2 \quad (3-11)$$

$$PartB_1 = -\frac{1}{2}(v_f - v_e)^2 \quad (3-12)$$

$$PartC_1 = -d(a_e - a_f) \quad (3-13)$$

对式(3-10)进行分析可知, $TTC_1(t)'$ 的正负与前车和后车初始时刻的加速度有关, 可以分为以下两种情况进行讨论:

(1) $a_e \geq a_f$ 的情况

由于 d 是两车间距恒大于 0, $PartA_1, PartB_1$ 和 $PartC_1$ 均小于 0, 故而 TTC 导数的分子部分 $numerator_1$ 恒小于 0, $TTC_1(t)'$ 恒为负, 表示在该阶段 TTC 指标是单调递减的, 随着时间 t 的不断增大, TTC 指标的变化趋势是逐渐减小的。

(2) $a_e < a_f$ 的情况

此时 $PartC_1$ 恒大于 0, $numerator_1$ 的正负情况会受到 v_f, v_e, a_f, a_e, d 和 t 等场景状态参数值的影响。由于在后车逼近阶段后车的速度始终是大于前车车速的, 因此可以得到以下关系:

$$v_e + a_e t > v_f + a_f t \quad (3-14)$$

转换后得到:

$$f_1(t) = (a_f - a_e)t - (v_e - v_f) < 0 \quad (3-15)$$

又由于 $a_f - a_e > 0$, 故而当 $t=0$ 时, $f_1^2(t)$ 最大, 随着 t 从 0 不断增大到 t_1 , $f_1^2(t)$ 逐渐减小, 所以在 $a_e < a_f$ 时可能会出现以下两种情况:

① $t = 0$ 时

$$-d(a_e - a_f) > \frac{1}{2}[-(v_e - v_f)]^2 + \frac{1}{2}(v_f - v_e)^2 \quad (3-16)$$

那么在跟车场景的后车逼近阶段, $numerator_1$ 将恒大于 0, 因此 $TTC_1(t)'$ 恒为正, 表示在该阶段下 TTC 指标是单调递增的, 随着时间 t 的不断增大, TTC 指标的变化趋势是逐渐增大的。

② $t \in [0, t_1]$

若后车逼近阶段的 t_m 时刻下满足以下关系式:

$$\begin{cases} -d(a_e - a_f) < \frac{1}{2}[(a_f - a_e)t - (v_e - v_f)]^2 + \frac{1}{2}(v_f - v_e)^2 & t \in [0, t_m] \\ -d(a_e - a_f) \geq \frac{1}{2}[(a_f - a_e)t - (v_e - v_f)]^2 + \frac{1}{2}(v_f - v_e)^2 & t \in (t_m, t_1] \end{cases} \quad (3-17)$$

那么在跟车场景的后车逼近阶段, $numerator_1$ 将首先小于 0, 之后再大于 0, 所以 $TTC_1(t)'$ 的状态是先负后正, 表示在该阶段随着时间 t 的不断增大, TTC 指标

的变化趋势将是先减后增的。

根据场景状态参数的不同，后车逼近阶段 TTC 指标可能出现的变化趋势如图 3-3 所示。

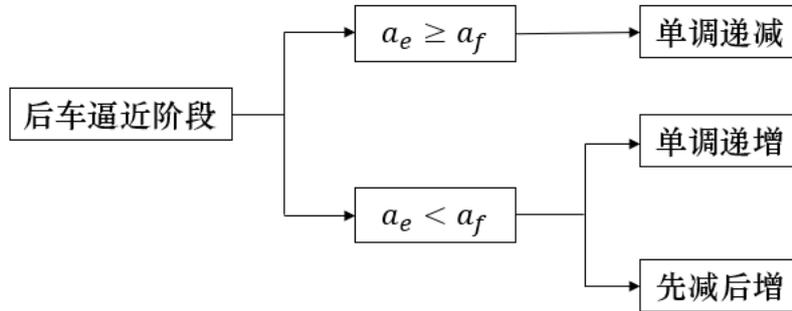


图 3-3 后车逼近阶段 TTC 指标可能出现的变化趋势

3.1.2 后车制动阶段

接着分析整个跟车场景下后车制动阶段 TTC 指标值随时间的变化情况。假设后车在 t_1 时刻制动时前车的速度为 v_f' ，后车的速度为 v_e' ，该阶段下行驶的时间设为 t 。可以得到后车制动阶段 TTC 指标的计算式为：

$$TTC_2(t) = \frac{D + (v_f' - v_e')t + \frac{1}{2}(a_f - a_s)t^2}{(v_e' - v_f') + (a_s - a_f)t} \quad (3-18)$$

其中，

$$D = d + (v_f t_1 + \frac{1}{2} a_f t_1^2) - (v_e t_1 + \frac{1}{2} a_e t_1^2) \quad (3-19)$$

对式(3-18)求一阶导并化简后得到后车制动阶段 TTC 指标的导数为：

$$TTC_2(t)' = \frac{-\frac{1}{2}[(a_f - a_s)t - (v_e' - v_f')]^2 - \frac{1}{2}(v_f' - v_e')^2 - D(a_s - a_f)}{(v_e' - v_f' + a_s t - a_f t)^2} \quad (3-20)$$

式(3-20)中的分母部分恒大于 0，因此只对其分子部分进行讨论。分子部分可以拆分为三个子变量的加和：

$$\begin{aligned} numerator_2 &= -\frac{1}{2}[(a_f - a_s)t - (v_e' - v_f')]^2 - \frac{1}{2}(v_f' - v_e')^2 - D(a_s - a_f) \\ &= PartA_2 + PartB_2 + PartC_2 \end{aligned} \quad (3-21)$$

其中，

$$PartA_2 = -\frac{1}{2}[(a_f - a_s)t - (v_e' - v_f')]^2 \quad (3-22)$$

$$PartB_2 = -\frac{1}{2}(v_f' - v_e')^2 \quad (3-23)$$

$$PartC_2 = -D(a_s - a_f) \quad (3-24)$$

对式(3-21)进行分析可知, $TTC_2(t)'$ 的正负与前车和后车初始时刻的加速度有关, 可以分为以下三种情况进行讨论:

(1) $a_f \geq 0$ 的情况

由于 a_s 为制动减速度, 始终为负, 因此 $(a_s - a_f)$ 恒小于 0, 此时 $PartC_2$ 恒大于 0。通过观察可以发现, 式(3-21)与后车逼近阶段中的式(3-10)形式上是一样的, 只不过其中的常量不一样, 因此对于该情况下 TTC 指标值的变化趋势与后车逼近阶段类似, 可能会出现单调递增和先减后增这两种情况。

(2) $a_f < 0$ 且 $a_f > a_s$ 的情况

此时 $(a_s - a_f)$ 恒小于 0, $PartC_2$ 恒大于 0, 因此该情况下 TTC 指标可能出现的变化趋势也是单调递增和先减后增这两种情况。

(3) $a_f < 0$ 且 $a_f \leq a_s$ 的情况

$PartA_1, PartB_1$ 和 $PartC_1$ 均小于 0, 故而后车制动阶段 TTC 指标导数的分子部分 $numerator_2$ 恒小于 0, 由此 $TTC_2(t)'$ 恒小于 0, 表示在该阶段中 TTC 指标是单调递减的, 随着时间 t 的不断增大, TTC 指标的变化趋势是逐渐减小的。

根据场景状态参数的不同, 后车制动阶段 TTC 指标可能出现的变化趋势如图 3-4 所示。

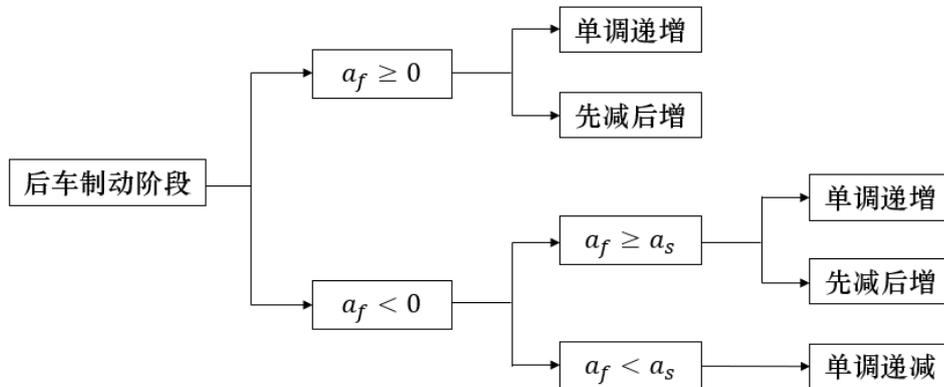


图 3-4 后车制动阶段 TTC 指标可能出现的变化趋势

3.1.3 TTC 指标完整变化趋势

后车制动阶段 TTC 指标的变化趋势是受后车逼近阶段下 TTC 指标变化趋势的制约的, 因此整个跟车场景下 TTC 指标的完整变化趋势不能直接简单地将两个阶段可能出现的情况进行两两组合, 需要进行详细的分析。

当 $a_e \geq a_f$ 时, 后车逼近阶段的 TTC 指标变化趋势是单调递减的, 通过 3.1.2 节的分析可知, 后车制动阶段 TTC 指标的变化趋势可以出现递增或者递减的状态, 不会受到影响。而当 $a_e < a_f$ 时情况则不一样, 因此本节重点对 $a_e < a_f$ 的场

景进行分析。

首先对后车制动阶段 $numerator_2$ 中的 $PartB_2$ 部分进行分析。在后车刚开始制动的 t_1 时刻，将式(3-4)和(3-5)代入式(3-23)可得：

$$PartB_2 = -\frac{1}{2}[(v_f - v_e) + (a_f - a_e)t_1]^2 \quad (3-25)$$

展开后得到：

$$PartB_2 = -\frac{1}{2}(v_f - v_e)^2 - (v_f - v_e)(a_f - a_e)t_1 - \frac{1}{2}(a_f - a_e)t_1^2 \quad (3-26)$$

将式(3-19)代入 $PartC_2$ 化简后可以得到：

$$PartC_2 = -d(a_s - a_f) + (v_f - v_e)(a_f - a_s)t_1 + \frac{1}{2}(a_f - a_e)(a_f - a_s)t_1^2 \quad (3-27)$$

由于 a_s 为制动减速度恒小于 0，而 a_e 为后车初始加速度为非负，所以 $a_e > a_s$ ，并且

$$a_f - a_s > a_f - a_e \quad (3-28)$$

当 $a_e < a_f$ 时，可以得到以下两个不等式：

$$(v_f - v_e)(a_f - a_s)t_1 > (v_f - v_e)(a_f - a_e)t_1 \quad (3-29)$$

$$\frac{1}{2}(a_f - a_e)(a_f - a_s)t_1^2 > \frac{1}{2}(a_f - a_e)t_1^2 \quad (3-30)$$

根据式(3-29)和式(3-30)可以得到：

$$PartB_2 + PartC_2 > -\frac{1}{2}(v_f - v_e)^2 - d(a_e - a_f) \quad (3-31)$$

也即

$$PartB_2 + PartC_2 > PartB_1 + PartC_1 \quad (3-32)$$

接着，对式(3-22)中的 $PartA_2$ 进行分析。由于两车速度相等前后车的速度始终比前车快，因此可以得到：

$$v_e' + a_s t > v_f' + a_f t \quad (3-33)$$

转换后得到：

$$f_2(t) = (a_f - a_s)t - (v_e' - v_f') < 0 \quad (3-34)$$

当 $a_e < a_f$ 时，

$$v_e' - v_f' = (v_e - v_f) + (a_e - a_f)t_1 < v_e - v_f \quad (3-35)$$

由此可知，后车制动阶段 $f_2(t)$ 的曲线比第一阶段 $f_1(t)$ 的曲线斜率更大，截距更接近 0。因此可以得到：

$$-\frac{1}{2}f_2^2(t) > -\frac{1}{2}f_1^2(t) \quad (3-36)$$

也即

$$PartA_2 > PartA_1 \tag{3-37}$$

综合式(3-32)和(3-37)可知，当 $a_e < a_f$ 时，

$$PartA_2 + PartB_2 + PartC_2 > PartA_1 + PartB_1 + PartC_1 \tag{3-38}$$

由式(3-38)可知，后车制动阶段 TTC 指标导数的分子部分 $numerator_2$ 肯定比后车逼近阶段的 $numerator_1$ 大。而对于 TTC 指标导数的分母部分，在后车逼近阶段为：

$$denominator_1 = (v_e - v_f) + (a_e - a_f)t \tag{3-39}$$

在后车制动阶段，当 $a_e < a_f$ 时，

$$\begin{aligned} denominator_2 &= (v_e' - v_f') + (a_s - a_f)t \\ &= (v_e - v_f) + (a_e - a_f)t_1 + (a_s - a_f)t \\ &< denominator_1 \end{aligned} \tag{3-40}$$

由上述推论可知，后车制动阶段 TTC 指标的导数肯定比后车逼近阶段 TTC 指标的导数大，即

$$TTC_2(t)' > TTC_1(t)' \tag{3-41}$$

由式(3-41)可知，若后车逼近阶段 TTC 指标的导数 $TTC_1(t)'$ 大于 0，那么后车制动阶段 TTC 指标的导数 $TTC_2(t)'$ 必然大于 0，也即在后车逼近阶段 TTC 指标值在处于递增状态后，后车制动阶段 TTC 指标的变化趋势只可能继续递增，而不会出现递减的情况。

通过以上的分析，根据场景状态参数的不同，可以得到跟车场景下 TTC 指标所有可能出现的完整变化趋势，如图 3-5 所示。

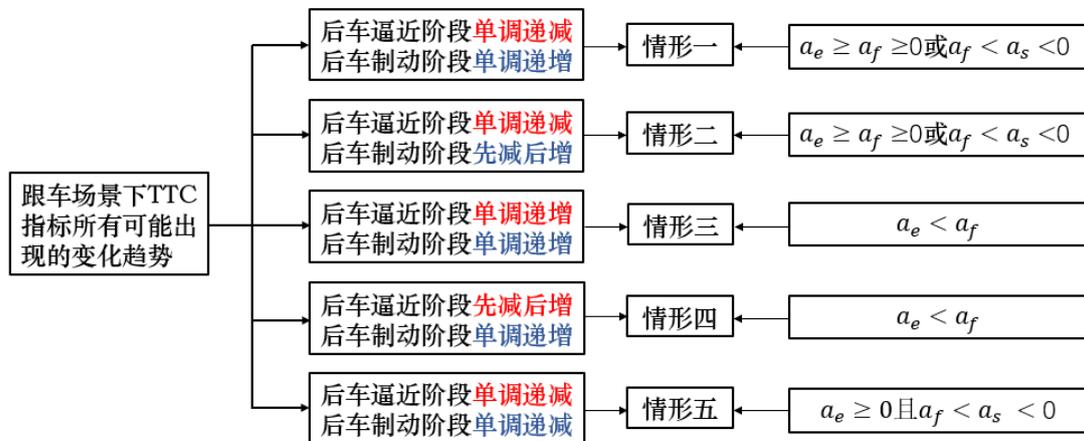


图 3-5 跟车场景下 TTC 指标可能出现的完整变化趋势

3.2 最小 TTC 指标参数解析式

通过分析 TTC 指标的完整变化趋势，可以确定整个跟车场景下 TTC 最小值出现的时刻，进而可以求解出当前场景下 TTC 指标最小值的解析式。首先需要判断当前场景属于图 3-5 中的哪一种情形，具体做法如图 3-6 所示。

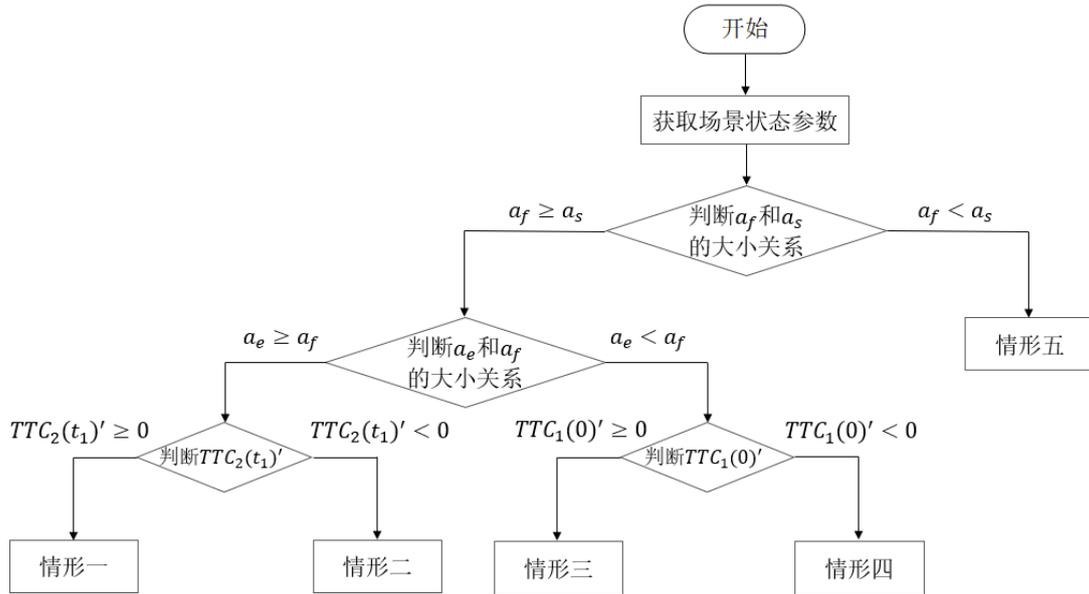


图 3-6 判断 TTC 完整变化趋势属于何种情形的流程图

首先判断场景中 a_f 和 a_s 的大小关系，当 $a_f \geq a_s$ 时，继续判断场景中 a_e 和 a_f 的大小关系。若 $a_e \geq a_f$ ，则继续计算后车制动阶段的导数 $TTC_2(t)$ 在 t_1 时的数值， $TTC_2(t_1)' \geq 0$ 时的场景中 TTC 指标的完整变化趋势属于情形一， $TTC_2(t_1)' < 0$ 时的场景中 TTC 指标的完整变化趋势属于情形二。若 $a_e < a_f$ ，则继续计算后车逼近阶段的导数 $TTC_1(t)$ 在 $t = 0$ 时刻的数值， $TTC_1(0)' > 0$ 时的场景中 TTC 指标的完整变化趋势属于情形三； $TTC_1(0)' < 0$ 时的场景中 TTC 指标的完整变化趋势属于情形四。当 $a_f < a_s$ 时，场景中 TTC 指标的完整变化趋势属于情形五。

在判断得到当前场景属于何种情形后即可获取每一种情形下计算最小 TTC 参数的解析式。

(1) TTC 指标的完整变化趋势属于情形一

整个跟车场景下 TTC 指标的最小值将出现在后车刚开始制动的时刻，假设该时刻为 t_1 ，那么由式(3-8)可知，该情形下计算最小 TTC 参数的解析式为：

$$TTC_{\min}(t) = \frac{d + (v_f - v_e)t_1 + \frac{1}{2}(a_f - a_e)t_1^2}{(v_e - v_f) + (a_e - a_f)t_1} \quad (3-42)$$

(2) TTC 指标的完整变化趋势属于情形二

整个跟车场景下 TTC 指标的最小值将出现在后车制动后的某一个时刻 t_s ，该时刻 TTC 的导数值为 0，也即

$$TTC_2(t)' = \frac{-\frac{1}{2}[(a_f - a_s)t_s - (v_e' - v_f')]^2 - \frac{1}{2}(v_f' - v_e')^2 - D(a_s - a_f)}{(v_e' - v_f' + a_s t_s - a_f t_s)^2} = 0 \quad (3-43)$$

通过求解可得：

$$t_s = \frac{-B \pm \sqrt{B^2 - 4AC}}{2A} \quad (3-44)$$

其中，

$$A = a_s - a_f \quad (3-45)$$

$$B = 2[(v_e - v_f) + (a_e - a_f)t_1] \quad (3-46)$$

$$C = 2D - \frac{2B}{a_f - a_s} \quad (3-47)$$

$$D = d + (v_f t_1 + \frac{1}{2} a_f t_1^2) - (v_e t_1 + \frac{1}{2} a_e t_1^2) \quad (3-48)$$

v_f 、 v_e 、 a_f 、 a_e 、 a_s 、 t_1 和 d 分别表示前后车的速度、加速度、后车制动减速度、后车制动时刻以及两车的初始间距，在场景确定后都是已知的，取 $t_s > 0$ 的时刻即为该情形中 TTC 最小值出现的时刻，代入式(3-18)得到该情形下计算最小 TTC 参数的解析式为：

$$TTC_{\min}(t) = \frac{D + (v_f + a_f t_1 - v_e - a_e t_1)t_s + \frac{1}{2}(a_f - a_s)t_s^2}{(v_e + a_e t_1 - v_f - a_f t_1) + (a_s - a_f)t_s} \quad (3-49)$$

(3) TTC 指标的完整变化趋势属于情形三

整个跟车场景下 TTC 指标的最小值将出现在初始时刻，该情形下计算最小 TTC 参数的解析式为：

$$TTC_{\min}(t) = \frac{d}{v_e - v_f} \quad (3-50)$$

(4) TTC 指标的完整变化趋势属于情形四

整个跟车场景下 TTC 指标的最小值将出现在后车逼近阶段的某一个时刻 t_n ，该时刻 TTC 的导数值为 0，也即

$$TTC_1(t)' = \frac{-\frac{1}{2}[(a_f - a_e)t_n - (v_e - v_f)]^2 - \frac{1}{2}(v_f - v_e)^2 - d(a_e - a_f)}{(v_e - v_f + a_e t_n - a_f t_n)^2} = 0 \quad (3-51)$$

与第二种情形类似，通过式(3-51)求出 t_n 并代入式(3-8)中，可以得到该情形下计算最小 TTC 参数的解析式为：

$$TTC_{\min}(t) = \frac{d + (v_f - v_e)t_n + \frac{1}{2}(a_f - a_e)t_n^2}{(v_e - v_f) + (a_e - a_f)t_n} \quad (3-52)$$

(5) TTC 指标的完整变化趋势属于情形五

整个跟车场景下 TTC 指标的计算值是不断减小的。该情形下前车的制动减速度比后车的制动减速度大，由于后车在制动时的速度比前车快，因此在该场景下两车若继续保持该状态行驶将发生追尾碰撞，这一类情形下 TTC 指标的最小值即为 0。

3.3 实验结果分析

本章在 3.1 节中通过理论推导分析了整个跟车场景下 TTC 指标所有可能出现的完整变化趋势，在不同场景状态参数的组合下一共会出现五种不同的情形，在 3.2 节中得到了五种不同情形下计算最小 TTC 参数的解析式。本节通过 Matlab 在各场景状态参数的取值范围内随机生成数值来构建不同的跟车场景，然后绘制了整个跟车场景下 TTC 指标随时间变化的曲线图，通过大量实验测试证明了 TTC 指标的完整变化趋势只包含前述理论推导下的五种情形。本文选取五组状态参数进行实验分别对上述五种情形进行展示，状态参数的具体值如表 3-1 所示。

表 3-1 不同情形下状态参数具体值

类型	v_f	v_e	a_f	a_e	a_s	d	t_1
情形一	22.7	27.4	1.4	1.9	-2.0	35.6	4.0
情形二	26.3	48.5	1.5	2.4	-2.5	33.6	3.0
情形三	19.0	47.0	1.4	0	-1.8	75.1	3.0
情形四	64.4	105.0	3.7	0.8	-1.9	58.1	2.9
情形五	45.4	54.0	-3.0	0	-2.0	53.5	1.5

表 3-1 中， v_f 和 v_e 分别代表前车和后车的初始速度，单位是 km/h； a_f 和 a_e 分别代表前车和后车的初始加速度，单位是 m/s^2 ； d 为两车初始间距， t_1 后车制动的时刻，对于表 3-1 中的各情形分别绘制 TTC 指标随时间的变化曲线如图 3-7 至图 3-11 所示。

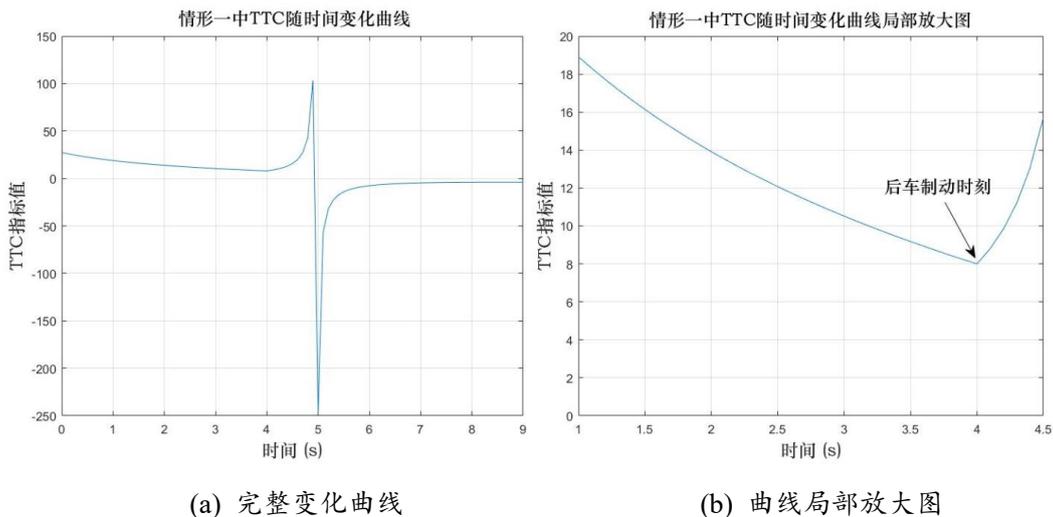


图 3-7 情形一 TTC 指标变化曲线

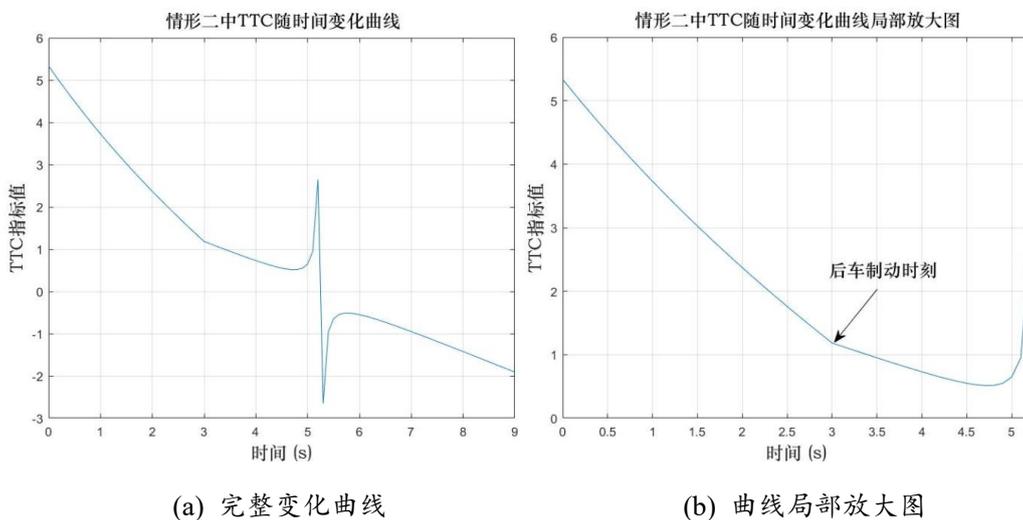


图 3-8 情形二 TTC 指标变化曲线

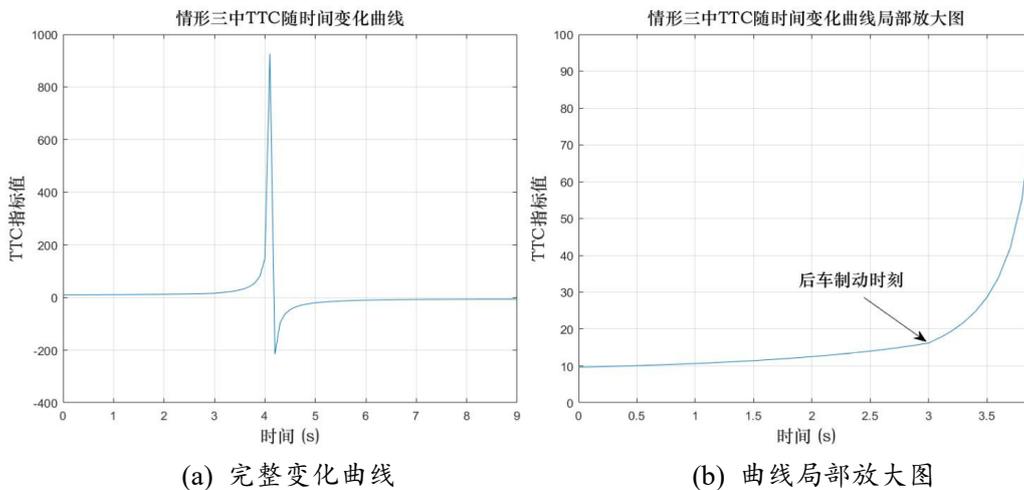


图 3-9 情形三 TTC 指标变化曲线

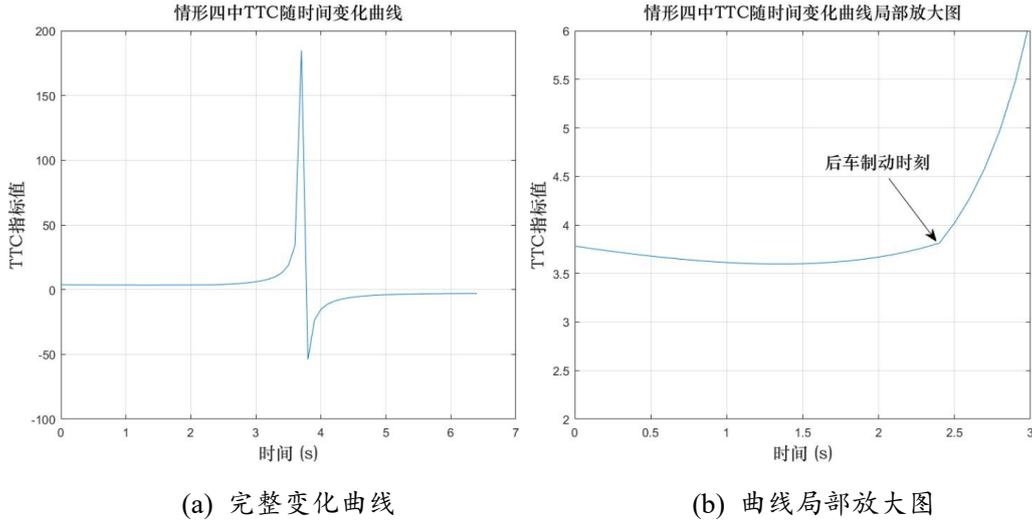


图 3-10 情形四 TTC 指标变化曲线

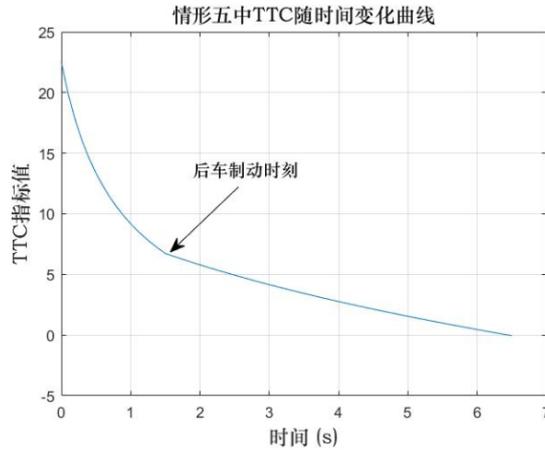


图 3-11 情形五 TTC 指标变化曲线

从以上实验结果图中可以看到，TTC 指标的变化曲线中存在负数的情况，代表的是此时后车的速度已经比前车慢了。在一些情形下 TTC 指标值在某一个时刻会出现极大或者极小的情况，出现这种现象的原因是由于 TTC 指标的分母部分是两车的相对车速，当相对车速很小时，TTC 指标的计算值将出现极大或者极小的情况，而极值处所在的时刻代表的是两车相对速度最小的时刻。

图 3-7 中 TTC 指标的变化趋势代表的是理论推导结果中的情形一，即后车逼近阶段单调递减，后车制动阶段单调递增；图 3-8 中 TTC 指标的变化趋势代表的是理论推导结果中的情形二，即后车逼近阶段单调递减，后车制动阶段先减后增；图 3-9 中 TTC 指标的变化趋势代表的是理论推导结果中的情形三，即后车逼近阶段单调递增，后车制动阶段也是单调递增；图 3-10 中 TTC 指标的变化趋势代表的是理论推导结果中的情形四，即后车逼近阶段先减后增，后车制动阶段单调递增。图 3-11 中 TTC 指标的变化趋势代表的是理论推导结果中的情形五，

即后车逼近阶段单调递减，后车制动阶段单调递减，从图中可以看到，在 6.5 秒的时候 TTC 指标计算值降为 0，表示车辆在此时发生了追尾碰撞。

分别将各场景的状态参数代入到对应的计算最小 TTC 值的解析式中，并与实验结果图进行比较结果是完全一致的，由此证明了本章对于 TTC 指标可能出现的变化趋势的理论推导结果以及计算不同情形下 STCI 指标最小 TTC 参数的解析式是正确的。

通过理论推导及实验结果可知，在不同的场景参数下最小 TTC 值受到车辆决策行为的影响不同。在情形一中，车辆在制动时刻的 TTC 值便是整个跟车场景下的最小 TTC 值，此时的最小 TTC 便是系统决策行为的直接体现。在情形二和情形五中，在后车进行制动以后，TTC 的变化曲线斜率发生了突变，即在车辆制动行为影响下，最小 TTC 数值发生了改变。而对于情形三和情形四，其最小 TTC 取值在制动行为之前，这意味着其最小 TTC 值不受制动行为的影响。从图 3-6 可以看出情形三和情形四都是前车加速度大于后车加速度的场景，这通常意味着后车与前车距离逐渐增加，即将脱离跟车场景。因此本文主要讨论情形一、情形二和情形五下的自动驾驶车辆跟车场景。在这几类场景下由于场景的初始状态参数以及自动驾驶车辆制动决策行为的不同，最小 TTC 值出现的时刻以及大小都会发生改变，其计算结果可以很好的反映出车辆在跟车行驶时的动态过程。通过将整个跟车场景下的最小 TTC 值作为参数去计算 STCI 指标，可以使得计算结果更加真实的反映出自动驾驶车辆在当前场景下的安全性和通行效率。

3.4 小结

本章主要从理论分析方面研究了在不同跟车场景下 TTC 指标的变化趋势以及最小 TTC 值受驾驶行为影响的情况，得到了不同场景下最小 TTC 参数的计算解析式，进一步明确了本文的研究范围，证明了使用最小 TTC 作为车辆安全性与通行效率评价指标参数的合理性。首先分别对跟车场景的后车逼近阶段和后车制动阶段下 TTC 指标的变化趋势分别进行了分析，此后根据场景下不同的状态参数将两个阶段进行拼合得到了完整的跟车过程 TTC 变化曲线。在不同场景参数下，TTC 曲线有五种不同的变化情况，其中情形一、情形二和情形五中的最小 TTC 都受到场景下车辆驾驶行为的制约，即最小 TTC 数值可以很好的反应车辆的制动驾驶行为。而情形三和情形四为后车逐渐脱离跟车驾驶的过程，不在本文的考虑之内。最后，本章通过 Matlab 随机构建了大量不同的跟车场景，并对 TTC 指标出现的变化趋势进行了分析，经过实验测试证明了本章对于 TTC 指标可能出现的变化趋势的理论推导结果以及计算不同情形下 STCI 指标最小 TTC 参数解析式的正确性。

4 STCI 指标最优 TTC 阈值参数分析及计算方法研究

STCI 指标中存在两个可变参数,分别是场景下的最小 TTC 值以及最优 TTC 阈值,本文在第三章中深入分析了 TTC 指标在跟车场景下的变化趋势以及最小 TTC 值的计算解析式,论证了采用最小 TTC 值作为评价函数参数的合理性。本章将对 STCI 指标的最优 TTC 阈值参数进行分析并研究其计算方法。首先研究了基于跟车场景物理模型的最优 TTC 阈值计算方法,该方法计算精度高但是耗时较长,为此本章提出了基于机器学习快速计算最优 TTC 阈值的方法,并论证了其有效性。

4.1 基于物理模型的最优 TTC 阈值参数计算方法

场景中的最优 TTC 阈值代表的是在某一特定场景下车辆最佳的驾驶行为。在跟车场景下,后车速度与前车速度不同时将处于不稳定状态,若后车速度较快则需要通过制动来达到稳定跟车状态,这种情形也包括前车减速所导致的后车制动,若后车速度较慢则容易脱离跟随状态。因此本文以自动驾驶车辆与前车速度相同时的车间距离作为评价标准,以两车速度相等时的车速值作为最佳的跟车距离。然而正如第二章所论述的,两车相对静止时的相对距离有时并不存在,并且基于距离进行安全性评价是以结果为导向的,难以精准评价车辆的动态行为。因此,需要将最佳的跟车距离转换为对应的最优 TTC 阈值。

当后车在某一时刻开始制动后,其制动减速度 a_s 就确定了,此时整个跟车场景下一定存在一个时刻 t^* ,使得后车在该时刻以其制动减速度制动是最佳的,这里的最佳指的是当后车以 a_s 的减速度制动时,相比于其他的制动时刻,在 t^* 时刻制动能够得到车辆达到最好的安全性和通行效率。该时刻制动后场景下的最小 TTC 指标的计算值即为整个跟车场景下的最优 TTC 阈值。

本节首先根据跟车场景的状态参数建立物理模型,通过该模型可以计算出跟车场景下两车速度相等时的车速以及车间距离,借助于该模型能够计算得到跟车场景下的最优 TTC 阈值参数。

4.1.1 跟车场景建模

为了研究场景的最优 TTC 阈值,本章沿用 3.1 节中构建的跟车场景及其状态参数的定义,如图 3-1 所示。假设在当前跟车场景下 TTC 的计算值达到 m 的时刻为 t_m ,并且将该时刻作为后车开始制动的时刻,在该时刻下前车的速度为 v_{fm} ,后车的速度为 v_{em} ,两车此时的间距为 ΔS_m ,由 TTC 计算公式可以得到:

$$m = \frac{\Delta S_m}{v_{em} - v_{fm}} \quad (4-1)$$

从 t_m 时刻开始, 后车以 a_s 的减速度匀减速向前行驶, 若保持该减速度制动两车会在 t_2 时刻达到速度相等的状态, 此时两车相距为 ΔS 。假设后车在逼近阶段也即制动之前与前车之间的相对位移量为 ΔS_m , 在制动阶段与前车之间的相对位移量为 ΔS_Q 。由数学知识可知, ΔS_Q 可由图 3-2 中从 t_m 时刻开始到 t_2 时刻前后两车速度曲线与横轴的面积差求得。在经历了后车逼近和后车制动两个阶段, 当前车与后车的速度相等时, 两车之间的距离为:

$$\Delta S = \Delta S_m - \Delta S_Q \quad (4-2)$$

其中,

$$\Delta S_m = m \cdot (v_{em} - v_{fm}) \quad (4-3)$$

$$\Delta S_Q = \frac{v_{em} - v_{fm}}{2} (t_2 - t_m) \quad (4-4)$$

由此可以得到

$$\Delta S = m \cdot (v_{em} - v_{fm}) - \frac{v_{em} - v_{fm}}{2} (t_2 - t_m) \quad (4-5)$$

由匀加速运动的位移计算公式可以得到

$$\Delta S_m = d + v_f t_m + \frac{1}{2} a_f t_m^2 - (v_e t_m + \frac{1}{2} a_e t_m^2) \quad (4-6)$$

将式(4-6)代入式(4-1), 得到

$$\frac{d + v_f t_m + \frac{1}{2} a_f t_m^2 - (v_e t_m + \frac{1}{2} a_e t_m^2)}{v_{em} - v_{fm}} = m \quad (4-7)$$

根据匀加速运动的速度公式可知

$$v_{fm} = v_f + a_f t_m \quad (4-8)$$

$$v_{em} = v_e + a_e t_m \quad (4-9)$$

将式(4-8)和式(4-9)代入式(4-7), 可以求解出 t_m , 求解结果如式(4-10)所示。该值表示的是在当前跟车场景下 TTC 的计算值达到阈值 m 的时刻, 从该时刻起后车开始制动。

$$t_m = \frac{-G \pm \sqrt{G^2 - 4RF}}{2R} \quad (4-10)$$

其中,

$$R = \frac{1}{2}(a_f - a_e) \quad (4-11)$$

$$G = v_f - v_e + m \cdot (a_f - a_e) \quad (4-12)$$

$$F = d - m \cdot (v_e - v_f) \quad (4-13)$$

求解出的 t_m 包含两个值，本研究取 t_m 大于 0 的那个值。

后车从 t_m 时刻开始以 a_s 的减速度减速向前行驶，而前车则继续保持原有状态向前行驶，在 t_2 时刻两车速度相等，由此可以列出如下等式：

$$v_{em} + a_s(t_2 - t_m) = v_{fm} + a_f(t_2 - t_m) \quad (4-14)$$

化简后得到

$$t_2 - t_m = \frac{v_{em} - v_{fm}}{a_f - a_s} \quad (4-15)$$

将式(4-8)、(4-9)以及(4-15)代入式(4-5)，即可求得前后两车的速度相等时两车之间的距离 ΔS

$$\Delta S = m \cdot [(v_e - v_f) + (a_e - a_f)t_m] - \frac{[(v_e - v_f) + (a_e - a_f)t_m]^2}{2(a_f - a_s)} \quad (4-16)$$

两车速度相等时的车速可由下式计算得到：

$$v_{equal} = v_e + a_e t_m + \frac{a_s \cdot [(v_e - v_f) + (a_e - a_f)t_m]}{a_f - a_s} \quad (4-17)$$

4.1.2 最优 TTC 阈值参数计算

在一个跟车场景中，初始时刻 v_f 、 v_e 、 a_f 、 a_e 和 d 的具体数值是确定的，而后车由于是自动驾驶车辆，其在何时以多大的减速度制动是不确定的，当检测到自动驾驶车辆在某时刻开始制动后，其制动减速度 a_s 就确定了，此时整个跟车场景下一定存在一个时刻 t^* ，使得后车在该时刻以 a_s 的减速度制动相比于其他的制动时刻能够达到更高的安全性和车辆通行效率，该时刻 TTC 指标的计算值即为整个跟车场景下的最优 TTC 阈值。根据场景的不同，需要分三种情况进行计算。

(1) 后车无法达到与前车速度相等的状态

若自动驾驶车辆保持某一减速度 a_s 制动无法达到与前车速度相等的状态，说明两车的初始间距过小，或者自动驾驶车辆的制动减速度 a_s 过小，那么车辆以 a_s 的减速度制动的这一个决策行为应该在场景的初始时刻就执行是最好的，该跟车场景下的最优 TTC 阈值为初始时刻便制动的场景下最小 TTC 数值。

(2) 能够达到与前车速度相等的状态，但速度相等时车速小于 3km/h

这一类场景反映的是前车减速至极低速以及静止的场景，由于车辆在正常行驶时与前车都会至少保持一定的距离，除非发生碰撞，因此本文设定速度相等时车速小于 3km/h 的场景中最佳安全车距为 3 米，最优 TTC 阈值的计算方式是令式(4-16)为 3，通过联立式(4-10)和 3.2 小节中对应场景下的最小 TTC 解析式即可求解。

(3) 能够达到与前车速度相等的状态，且速度相等时车速大于 3km/h

该场景为正常的跟车场景，最后后车与前车以相等速度跟车行驶。此时最优 TTC 阈值的计算方式为联立式(4-7)、式(4-10)、式(4-16)和式(4-17)按照两车在稳定跟车状态驾驶速度与两车间距一致这一原则进行求解。

由于联立的计算公式复杂并且阶数较高，难以直接求得解析解，因此本文采用数值解法求取最优 TTC 阈值，即遍历不同的 TTC 指标值带入到公式(4-10)中，结合式(4-16)和式(4-17)分别计算出稳态跟车距离和速度，然后根据式(2-1)的计算结果评判自动驾驶车辆制动决策行为的好坏，现重写如下：

$$F(x) = \begin{cases} \frac{100 \cdot x^{1.4}}{x^{1.4} + (r-x)^{1.5}} & x \leq r \\ 100 \cdot e^{-\frac{(x-r)^2}{2r^2}} & x > r \end{cases} \quad (4-18)$$

其中， x 代表两车速度相等时的车间距离， r 代表两车速度相等时的车速， $F(x)$ 代表对自动驾驶车辆制动决策行为的评分，计算值越大表示车辆在当前场景下的制动决策行为越好。

将计算出来的两车速度相等时车速和车距带入到公式(4-18)，找到使式(4-18)最大的 TTC 指标值即为最优 TTC 阈值。

4.2 基于机器学习的最优 TTC 阈值参数快速计算方法研究

本文在 4.1 节中是利用数值解法通过遍历的方式确定每个场景下的最优 TTC 阈值参数，计算效率较低，进而会影响到 STCI 指标的计算速度，在更为复杂的场景下由于状态参数更多，场景物理模型将更为复杂，此时若采用数值解法计算效率将更低。为了加速虚拟仿真的测试，快速得到自动驾驶车辆在不同跟车场景下安全性和通行效率的测试评价结果，需要研究一种快速求解 STCI 指标最优 TTC 阈值参数的方法。

由于最优 TTC 阈值与场景的状态参数之间是有关系的，因此可以将场景的状态参数作为自变量，该场景下对应的最优 TTC 阈值作为因变量，构建拟合函数。采用机器学习的方法可以较好的拟合特征与标签之间复杂的关系，因此本节研究了一种基于机器学习快速计算 STCI 指标最优 TTC 阈值参数的方法。

4.2.1 数据预处理与特征工程构建

为了研究场景状态参数与最优 TTC 阈值之间的关系, 本文首先对不同状态参数进行随机组合生成了 30 万个场景样本, 每个状态参数都设定了一个取值范围, 其中前车速度 v_f 的取值范围是 $[20,100]$ km/h, 前车加速度 a_f 的取值范围是 $[-5,4]$ m/s², 后车加速度 a_e 的取值范围是 $[0,4]$ m/s²。对于后车的车速, 由于在不同路段的城市道路对于车速都有一定限制, 因此在真实情况下交通道路上运行的车辆间行驶速度不会差距太大, 因此本文限定后车的车速范围在前车速度 ± 30 km/h 的区间内, 即 v_e 的取值范围是 $[v_f - 30, v_f + 30]$ km/h, 而对于两车间的初始距离 d , 由于实际交通场景下车辆间距一般是与车速成正比的, 比如车辆在行驶速度为 30km/h 时, 那么其与前方车辆的初始间距一般不会低于 5 米, 并且也不会间隔太远, 因此本文限定车间距离 d 的范围是 $[v_f - 30, v_f + 50]$ 米。

本文根据跟车场景的定义剔除掉后车制动时速度小于前车的样本, 最终剩余 248736 个样本。每个样本中包括六维基础特征, 即前车初始速度 v_f 、前车加速度 a_f 、后车初始速度 v_e 、后车加速度 a_e 、后车制动时的减速度 a_s 以及两车初始间距 d 。本文通过物理模型的方法对每一个样本下的最优 TTC 阈值进行了计算, 并作为该样本的标签。在训练机器学习模型之前首先需要对样本进行数据预处理和特征工程的处理, 为此本节将对自动驾驶场景下的数据样本进行分析, 以此作为模型构建的基础。

(1) 数据预处理

由于样本特征的量纲不同, 如果直接采用机器学习模型进行训练, 数值较大的特征对回归模型的影响较大^[51], 而数值小的特征对模型的影响会变得不明显, 从而会降低拟合的效果, 因此本文首先对自动驾驶场景的样本特征进行归一化, 计算公式如式(4-19)所示。

$$X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \cdot (max - min) + min \quad (4-19)$$

其中, x 表示特征值, x_{min} 表示特征列的最小值, x_{max} 表示特征列的最大值, min 和 max 表示要归一化的区间边界。本研究将样本特征归一化到 $[0, 1]$ 之间, 故取 $min = 0$, $max = 1$ 。

(2) 特征工程构建

① 特征交叉

考虑到本文所采用的数据样本基础特征只有 6 维, 特征维数较少, 而场景的状态参数和最优 TTC 阈值之间并不是简单的线性关系, 而是复杂的非线性关系, 若直接采用基础特征进行训练会出现对非线性关系拟合程度不够的问题, 因此本

文采用特征交叉的方法来增加特征的维数，从而使模型具备更好的效果。

本文在样本原有特征的基础上采用多项式的方式构建了非线性的交叉项特征。举例说明，假设前车的初始速度为 a 特征、前车的初始加速度为 b 特征，那么对这两维特征构建二阶多项式交叉项特征是对它们进行两两交叉，扩展到以下六维特征，即 $[1, a, b, ab, a^2, b^2]$ 。对于 n 阶多项式交叉特征也按照上述步骤进行，交叉特征的最高次项为 n 次方。

由于机器学习模型对于不同阶数交叉项特征的拟合效果不同，因此本文采用网格搜索算法^[51]获取最佳的交叉项特征阶数，通过将交叉项特征的阶数作为参数，对不同阶数下的交叉项特征采用同一个模型进行反复训练和拟合效果验证，使得模型拟合效果最好的交叉项特征对应的阶数即为最佳交叉项特征阶数。

② 特征选择

通过上述步骤获取交叉项特征后，为了提高模型预测的速度，还需要对交叉项特征进行选取，剔除对模型预测影响较小的冗余特征和不相关特征。

本文采用GBDT算法计算每个特征的重要性以实现特征选择^[52]。GBDT算法主要基于CART树作为基学习器进行训练，由于决策树模型的训练涉及到分裂节点的特征选择，其目标通常是选择能使损失函数降低最多的特征作为分裂节点来构建决策树模型。GBDT算法在训练的过程中，会记录以每个特征作为分裂节点时对于损失函数的降低程度，由此可以计算得到每个特征的重要性。

在GBDT算法中，特征 j 的重要性是通过该特征在单个基学习器中重要性的平均值计算的，计算公式为：

$$J_j = \frac{1}{M} \sum_{m=1}^M J_j^2(T_m) \quad (4-20)$$

其中， M 是决策树的数量。特征 j 在每一棵树中的重要性计算式为：

$$J_j^2(T) = \sum_{t=1}^{L-1} \bar{i}_t^{-2} (v_t = j) \quad (4-21)$$

其中， L 为树的叶子节点数， v_t 是与节点 t 相关联的特征， \bar{i}_t^{-2} 是节点 t 在分裂后平方误差的减少量。

由于GBDT算法能够发现特征间的高阶关系^[53]，得到每个特征的重要性，并且计算速度较快，因此本文基于GBDT算法来实现特征选择。

4.2.2 模型介绍

由于不同的模型对于非线性关系的拟合效果不同，因此本文选取了当前主流的三种不同的机器学习算法模型分别对场景样本进行训练，包括多元线性回归模型^[54]、随机森林模型^[55]和 LightGBM 模型^[56]，以选出对于当前任务具有最佳拟

合效果的模型。首先对这些模型分别进行简要的介绍。

(1) 多元线性回归模型

多元线性回归模型是通过多个输入变量进行线性组合以最大程度的拟合目标值,在只有一个变量的时候,模型是平面中的一条直线;有两个变量的时候,模型是空间中的一个平面;有更多变量时,模型将是更高维的。该模型的可解释性较强,可以从权重中直接看出每个特征对结果的影响程度,并且形式较为简单、易于建模,其目标函数为:

$$f(x) = \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n + b \quad (4-22)$$

其中的 ω_i 为各个特征的权重,需要通过梯度下降法不断更新来得到,而 b 代表的是一个偏置量。

(2) 随机森林模型

随机森林 RF 是 Bagging 算法的一种,可以用于分类或者回归问题,其核心思想是采用 BootStrap 的抽样方法,对原始训练集进行有放回的重复采样,并构建多个训练子集,对每一个训练子集都生成一棵决策树作为弱学习器,通过组合多个弱学习器进而得到一个性能优越的强学习器。对于回归问题,是将多棵决策树预测结果的平均值作为最终结果。

随机森林在构建决策树时对传统的方法进行了改进,首先从样本特征集中随机选出 n 个特征作为候选特征集,再从这 n 个特征集中选出最优特征作为决策树的划分节点。通过对样本特征引入随机性,增强了模型的泛化和抗噪能力,可以使得模型不易产生过拟合。其算法流程图如图 4-1 所示。

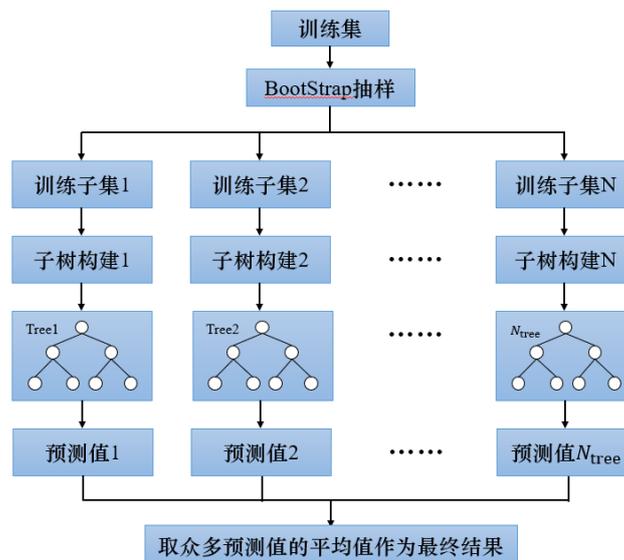


图 4-1 随机森林算法流程图

(3) LightGBM 模型

LightGBM 模型是由微软团队的 Guolin 等人于 2017 年提出的一种基于

Boosting 的集成学习方法，其基本思想是通过拟合损失函数的负梯度串联地构建多个基学习器，每一个基学习器都是在上一个基学习器训练后的数据基础上再次进行学习，最终将这些基学习器进行线性组合以提高模型预测的性能。该模型通过 GOSS (Gradient-based One-Side Sampling, 基于梯度的单边采样) 和 EFB (Exclusive Feature Bundling, 互斥特征捆绑) 来减少特征量和数据量，从而减少模型训练的复杂度，通过直方图优化算法和基于 Leaf-wise 的叶子增长策略来改进决策树的训练方式，从而提升算法的精度。

直方图算法的使用可以有效降低模型对内存的消耗，同时也可以降低模型在计算上的代价。传统的 Boosting 方法在决策树增长时采取的是 Level-wise 的生长策略，每一次增长都会同时分裂同一层的所有叶子，增大了计算的开销，实际上很多叶子的分裂对模型带来的增益较小，没有必要进行分裂。LightGBM 模型进行了改进，对决策树采用 Leaf-wise 的增长策略，如图 4-2 所示。每次从同一层的所有叶子中找出分裂后增益最大的叶子进行分裂，其他叶子不分裂。同 Level-wise 的策略相比在分裂次数相同的情况下可以降低更多的误差，因此可以得到更好的预测精度。

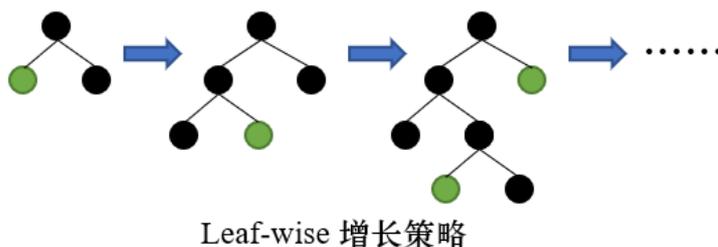


图 4-2 LightGBM 模型中决策树的生长方式

4.2.3 模型训练及验证

本文对场景样本进行随机抽样并划分为训练集和测试集，其中训练集占总样本的 75%，包含 186552 个样本，测试集占 25%，包含 62184 个样本。由于需要对模型的拟合效果进行验证，因此本节首先对本文所采用的模型拟合性能评价指标进行介绍，然后分别构建上述介绍的三种机器学习模型对样本进行训练，采用性能评价指标进行评估，并对实验结果进行分析。

(1) 模型拟合性能评价指标

目前常用的对于回归模型性能进行评价的指标包括均方误差 MSE、平均绝对误差 MAE 和决定系数 R^2 ，本文将采用这三种指标对模型的拟合效果进行评价。其中 MSE 指标定义为真实值 y_{true} 与预测值 $y_{predict}$ 之间差值平方的平均值，计算值越接近 0 表示模型拟合效果越好，其计算式为：

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{true}(i) - y_{predict}(i))^2 \quad (4-23)$$

MAE 指标定义为预测值与真实值之间误差绝对值的平均值，计算值越接近 0 表示模型拟合效果越好，当 MAE 计算值为 0 时，表示模型预测值与真实值完全一致，其计算式为：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{true}(i) - y_{predict}(i)| \quad (4-24)$$

R^2 指标的计算式为：

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{true}(i) - y_{predict}(i))^2}{\sum_{i=1}^n (y_{true}(i) - y_{mean}(i))^2} \quad (4-25)$$

其中， y_{mean} 表示真实值的平均值，当 R^2 为 1 时，此时分子为 0，样本中预测值和真实值完全相等，表示构建的模型完美拟合了所有真实数据。当 R^2 为 0 时，分子等于分母，样本的每项预测值都等于均值。当 R^2 小于 0 时，分子大于分母，表示训练出来的模型产生的误差比使用均值产生的还要大，训练模型还不如直接取均值效果好。因此 R^2 计算值越接近 1，表示模型拟合效果越好。

(2) 模型训练

本文首先采用样本的原始六维特征分别训练三种机器学习模型以拟合标签，具体方式如下：

① 多元线性回归模型训练

原始样本特征对应的线性回归拟合函数为：

$$g(x) = \omega_1 v_e + \omega_2 v_f + \omega_3 a_e + \omega_4 a_f + \omega_5 a_s + \omega_6 d + b \quad (4-26)$$

通过将特征归一化后的训练样本输入到多元线性回归模型进行训练，得到了每个特征对应的权重，对应得到多元线性回归拟合函数如式(4-27)所示。通过将场景的特征输入到拟合函数式中即可计算得到该场景对应的最优 TTC 阈值参数。

$$g(x) = 89.8v_e - 116.7v_f + 13.6a_e - 5.7a_f + 1.9a_s - 2.85d + 43.2 \quad (4-27)$$

② 随机森林模型训练

随机森林模型中包含较多的参数，不同参数组合下训练的模型在预测结果的准确度上会不同，其中对模型影响较大的主要有以下四个参数，即模型迭代次数、树的最大深度、叶子节点最小样本数和节点划分最小样本数。为了得到最佳参数，本文采用网格搜索算法对这些参数进行了寻优，将这些参数分别设置一个区间值，在设置的区间范围内对参数进行交叉组合，然后对不同参数组合分别训练模型并

对拟合效果进行验证,通过不断的训练可以找到一组使得模型拟合效果最佳的参数组合。通过网格搜索算法得到随机森林模型对于场景样本拟合效果最好的参数如表 4-1 所示。

表 4-1 随机森林模型最佳拟合参数

参数	参数说明	最佳参数
n_estimators	模型迭代次数	500
max_depth	树的最大深度	6
min_samples_leaf	叶子节点最小样本数	5
min_samples_split	节点划分最小样本数	8

③ LightGBM 模型训练

对于 LightGBM 模型的训练与随机森林类似,不同参数组合下训练的模型在预测结果的准确度上会不同,其中对模型影响较大的主要有以下七个参数,即模型迭代次数、树的最大深度、学习率、特征采用比率、样本采用比率、叶子节点最小样本数和迭代时用的数据比例。为了得到最佳参数,本文采用网格搜索算法对这些参数进行了寻优,方法与随机森林模型类似。通过不断的训练可以找到一组使得模型拟合效果最佳的参数组合。通过网格搜索算法得到 LightGBM 模型对于场景样本拟合效果最好的参数如表 4-2 所示。

表 4-2 LightGBM 模型最佳拟合参数

参数	参数说明	最佳参数
n_estimators	模型迭代次数	800
max_depth	树的最大深度	7
learning_rate	学习率	0.05
colsample_bytree	特征采用比率	0.9
subsample	样本采用比率	0.8
min_child_samples	叶子节点最小样本数	12
bagging_fraction	迭代时用的数据比例	0.8

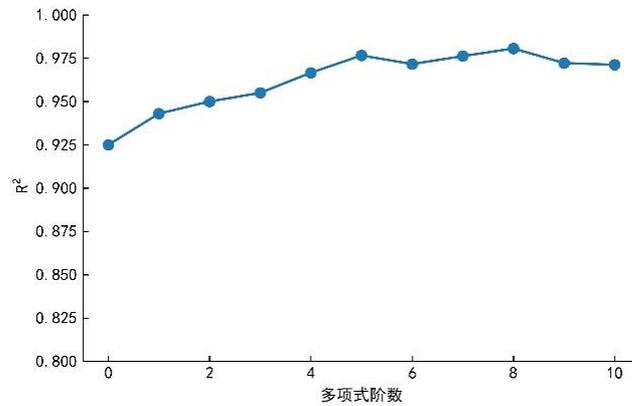
(3) 模型拟合效果验证

在各模型训练完成后,对 62184 个测试集样本进行预测,并对各模型的预测结果进行评估,如表 4-3 所示。

表 4-3 原始特征下各模型的预测情况

模型	MSE	MAE	R^2	运行时间/s
多元线性回归	17.93	9.60	0.61	1.72
随机森林	6.91	3.53	0.86	6.46
LightGBM	3.64	1.89	0.92	2.09

从表 4-3 中可以看出, LightGBM 模型在原始特征上的预测结果表现最好, 因此本文选用 LightGBM 作为后续使用的模型。为了提高 LightGBM 模型预测的精度, 本文采用多项式的方式来构建多维非线性交叉项特征, 交叉项特征的阶数通过网格搜索算法来确定, 采用不同阶数下的交叉项特征进行训练时 R^2 的变化情况如图 4-3 所示。

图 4-3 采用不同阶数下的交叉项特征进行训练时 R^2 的变化情况

从图 4-3 中可以看到, 随着多项式阶数的增大, R^2 也在不断增大, 在多项式阶数达到 8 时 R^2 最大, 此后继续增大多项式阶数时 R^2 出现减小的趋势。由此可知, 采用 LightGBM 模型对阶数为 8 的交叉项特征进行训练能够使得预测的精度最高, 该阶数下样本共包含 2002 维特征。

虽然通过构建交叉项特征使得模型预测的效果有了较大提升, 但是特征量也变得过于庞大, 为了提高计算效率, 本文采用 GBDT 算法计算每个特征的重要性, 分别选择特征重要性排名前 30、前 50、前 70 和前 100 的特征, 通过 LightGBM 模型进行训练, 并在 62184 个测试集样本中进行预测, 与未经过特征筛选时的预测情况进行对比, 如表 4-4 所示。

表 4-4 采用筛选前的特征与筛选后的特征进行训练时预测情况比较

特征	MSE	MAE	R^2	运行时间/s
筛选前	0.72	0.251	0.985	55.72
重要性前 30	1.21	0.394	0.971	10.36
重要性前 50	1.04	0.323	0.979	11.09
重要性前 70	0.99	0.315	0.980	13.11
重要性前 100	0.97	0.311	0.980	16.03

从表 4-4 中可以看出,在进行特征筛选前,通过 LightGBM 模型对 62184 个样本的最优 TTC 阈值进行预测时 R^2 达到 0.985,从 MAE 评估指标中可以看出,模型预测值与真实值之间误差绝对值的平均值仅为 0.251,但由于特征维数较多,对测试集进行预测前需要花费大量的时间在构建特征上,因此运行时间较长。而进行特征筛选后,虽然对同样的样本进行预测时特征筛选后的 R^2 相比特征筛选前低了,但是相差较少,而运行时间却比特征筛选前减小很多。通过对筛选后的特征进行训练能够较好保留模型的预测精度,并且在预测效率上有了较大的提升。

通过对比发现,采用重要性前 30 的特征训练得到的模型相比重要性前 50 的特征训练得到的模型在运行效率上提升不大,但是 R^2 却降低了不少,而采用重要性前 70 和前 100 的特征训练得到的模型相比重要性前 50 的特征训练得到的模型虽然 R^2 提高了,但是运行效率也降低了。综合分析后本文选择重要性排名前 50 的特征训练的模型来计算最优 TTC 阈值参数。

4.3 两种计算最优 TTC 阈值参数的方法实验对比分析

基于物理模型的方法采用的是数值解法通过不断遍历 TTC 计算值的方式来确定场景的最优 TTC 阈值,遍历间隔越小计算精度越高,但是耗时也越高。而基于机器学习的方法通过将场景的状态特征输入到已经训练好的模型中,即可快速得到该场景的最优 TTC 阈值。为了对比两种方法在计算最优 TTC 阈值参数的耗时和在 STCI 指标计算结果上的差异,本文进行了大量实验,对基于物理模型的方法取遍历间隔为 0.1,统一在 Python 环境进行测试,实验结果如表 4-5 所示。

表 4-5 两种计算最优 TTC 阈值的方法实验对比

计算方法	2 万场景	8 万场景	14 万场景	20 万场景
物理模型数值解法	25.1s	96.7s	171.2s	241.5s
基于机器学习预测	4.2s	16.1s	28.3s	40.7s
最优 TTC 阈值平均差异	0.327	0.314	0.329	0.322
STCI 指标平均差异	2.0	1.9	2.4	2.1

从表 4-5 中可以看出, 虽然采用 LightGBM 模型预测得到的场景最优 TTC 阈值与基于物理模型的方法求得的最优 TTC 阈值之间存在一定的误差, 但是该误差较小, 在计算 STCI 指标上的差异也较小, 并且采用 LightGBM 模型预测最优 TTC 阈值的计算效率相比基于物理模型的方法提升了约 6 倍, 在更为复杂的场景下由于状态参数更多, 场景物理模型更为复杂, 此时采用机器学习模型预测最优 TTC 阈值对于计算效率的提升将更为明显。由此证明了采用机器学习模型预测最优 TTC 阈值以提升计算效率是可行的。

4.4 小结

本章首先研究了基于物理模型计算跟车场景下最优 TTC 阈值参数的方法, 通过对跟车场景建模, 得到了跟车场景下两车速度相等时的车速以及车间距离的表达式, 借助于该模型能够计算得到跟车场景下的最优 TTC 阈值参数。但由于求解最优 TTC 阈值需要联立的方程组较为复杂, 联立后阶数较高, 难以直接得到求解最优 TTC 阈值的解析式, 因此本章研究了一种基于机器学习快速计算最优 TTC 阈值参数的方法。

首先构建了大量的跟车场景样本, 并对样本进行了一系列的数据预处理和特征工程构建, 采用了目前主流的三种机器学习模型对样本进行训练, 并利用网格搜索算法对模型参数进行调优, 通过对各模型的拟合效果进行验证, 最终得出 LightGBM 模型是对场景样本拟合效果最好的。本章通过 GBDT 算法对多维特征进行选择, 通过对比实验得出采用特征重要性排名前 50 的特征作为训练特征来训练 LightGBM 模型能在保证模型预测精度的前提下, 有效提升模型预测效率。

为了验证采用机器学习模型预测最优 TTC 阈值的有效性, 本章分别采用两种计算最优 TTC 阈值的方法在大量场景中进行测试, 统计了两种方法的计算耗时以及在计算 STCI 指标上的差异, 实验结果表明, 采用机器学习模型预测最优 TTC 阈值的计算效率相比基于物理模型的方法提升了约 6 倍, 并且采用机器学习模型预测与基于物理模型的方法确定最优 TTC 阈值在计算 STCI 指标上的差异较小, 平均差异 2.0, 由此证明了采用机器学习模型预测最优 TTC 阈值以提升计算效率是可行的。

5 基于 PreScan 与 Simulink 的跟车场景联合仿真实验设计

本章首先对 PreScan 与 Simulink 的联合仿真工作流程进行了介绍, 构建了虚拟跟车场景及车辆控制算法, 设计 PreScan 实验对第三章中理论推导得到的整个跟车场景下 TTC 指标可能出现的变化趋势进行了进一步验证。此后设计了三个场景实例来演示 STCI 指标的计算流程及其有效性, 最后对车辆制动行为进行消融实验, 通过对虚拟仿真场景中状态参数变化的分析, 更进一步的证明了 STCI 评价指标的有效性与可行性。

5.1 PreScan 与 Simulink 联合仿真工作流程

PreScan 是西门子公司旗下的一款用于 ADAS 及自动驾驶系统的仿真测试软件, 支持 V2V/V2I 等多种应用功能的开发应用^[58]。该软件由多个模块组成, 在使用时主要包括以下四个步骤: 搭建交通场景、添加车载传感器、车辆控制系统建模和运行仿真。在 PreScan 中提供了强大的图形编辑器用于快速可靠地构建较为真实的虚拟交通场景^[59], 包括机动车、障碍物、天气、路标、行人等, 并且可以实现 3D 可视化, 以方便用户分析实验结果。支持种类丰富的传感器, 包括各种雷达、GPS、摄像机、V2X 传感器等, 这些传感器能够保证与真实传感器功能一致, 用户可以根据需求自行添加^[60]。

PreScan 需要与 Matlab 中的 Simulink 进行联合仿真才能实现在构建的交通场景中对于车辆的运动控制^[61], 首先需要在 PreScan 中通过一些参数设置来搭建车辆的动力学模型, 然后在 Simulink 中设计车辆的控制算法, 并与车辆动力学模型连成一个整体。车载传感器会实时检测虚拟仿真环境下车辆行驶的信息, 并将信息传输给控制系统, 控制系统会通过各模块对信号进行一系列的处理, 并输出控制信号, 从而控制车辆进行加速、制动、转向等操作。PreScan 与 Simulink 联合仿真的工作流程如下:

(1) 在 PreScan 中搭建虚拟交通场景, 绘制车辆行驶路径, 设置各车辆行驶时的状态参数, 包括车辆在场景中的初始速度、加速度以及初始位置等, 并设置车辆的动力学参数。

(2) 在 PreScan 中为虚拟仿真场景下的车辆添加雷达等传感器, 并调节传感器的感知范围。

(3) 从 PreScan 环境下打开 Simulink, 并在 Simulink 中构建车辆的控制算法, 该算法依据传感器实时检测到的数据对车辆进行相应的控制。

(4) 在 PreScan 和 Simulink 中查看仿真结果。

5.2 基于 PreScan 的虚拟跟车场景构建

本节对于 PreScan 中虚拟跟车场景构建的介绍主要包括道路设置、车辆设置以及传感器设置这三个方面的内容。

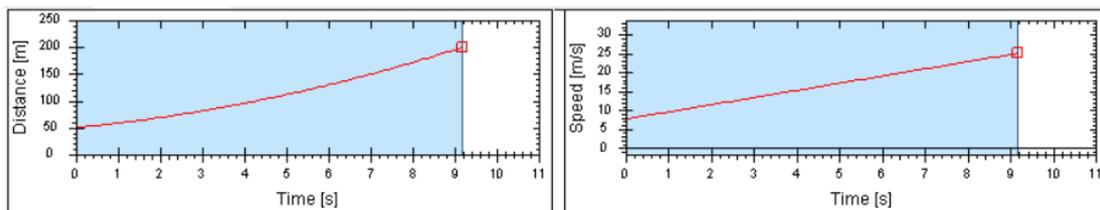
① 道路设置

首先在 PreScan 中搭建一条直道，设置直道为双车道，长度为 600 米，宽度为 3.5 米，在道路旁铺设树木以及房屋建筑。

② 车辆设置

需要设置的状态参数包括车辆的初始速度、加速度以及车辆的初始位置等。在设置好状态参数后还需要在 PreScan 中开启车辆的动力学模型以及碰撞检测的功能。

假设后车初始时刻是在道路第 50 米的地方，初始速度为 7.6m/s，加速度为 $1.9m/s^2$ ，并且限定车辆在加速到 110km/h 后停止加速，通过 PreScan 可以画出该车辆在道路上行驶时的距离、速度随时间的变化曲线如图 5-1 所示。



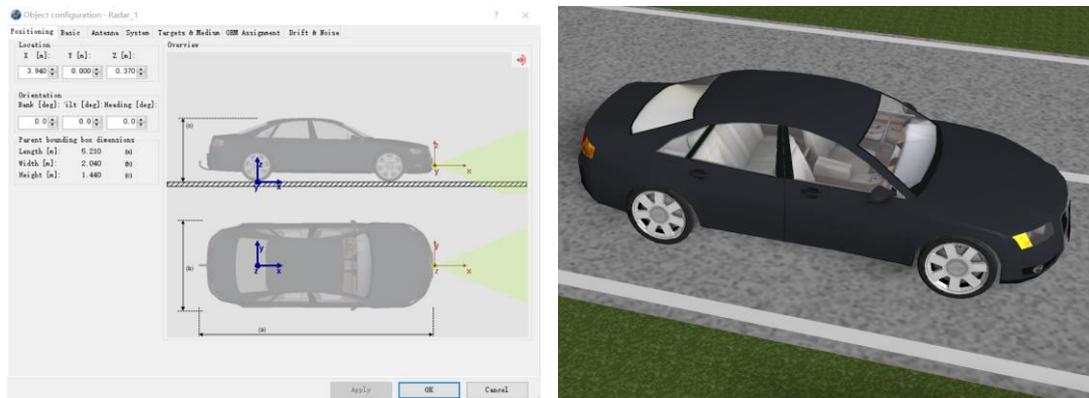
(a) 距离随时间变化曲线

(b) 速度随时间变化曲线

图 5-1 仿真车辆行驶距离与速度随时间的变化曲线

③ 传感器设置

本研究在后车的车头安装了雷达，用于检测后车与前方车辆的车距。雷达水平扫描范围为中心线±20度，测量范围为 200 米。在车辆后方添加了 Human View，以便于观察车辆运动。车辆的仿真模型如图 5-2 所示。



(a) 车辆雷达安装示意图

(b) 仿真模型效果图

图 5-2 车辆仿真模型

根据以上步骤搭建完成后的跟车场景如图 5-3 所示，该图分别展示了整个场景的二维和三维视角图。

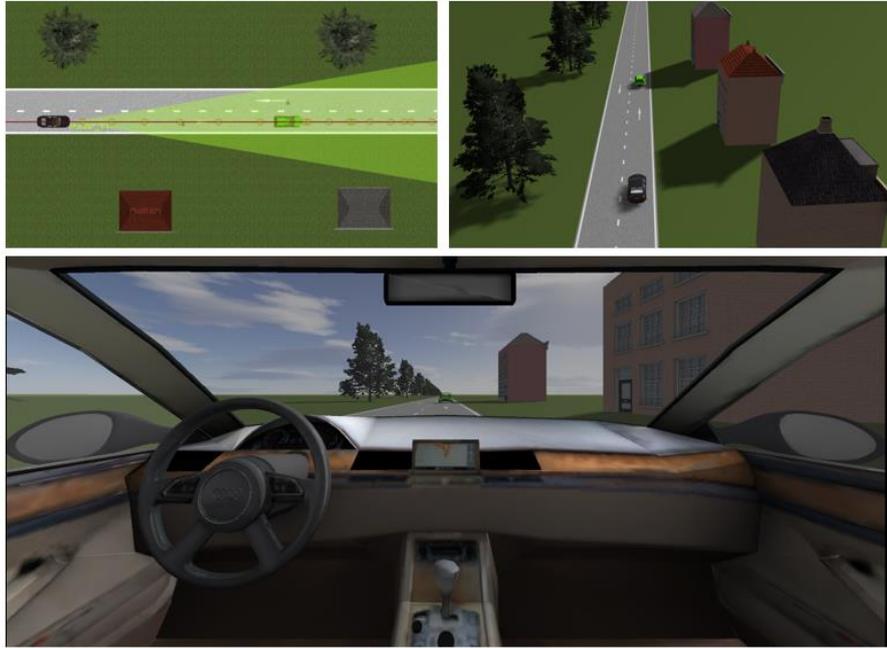


图 5-3 虚拟跟车场景二维及三维视角图

5.3 基于 Simulink 的车辆控制算法设计

跟车场景搭建完成后会得到一个后缀为 slx 的模型文件，从 Simulink 中打开会得到图 5-4 所示的车辆模型，该模型包含了 PreScan 中设置的所有车辆以及传感器^[61]，其中两车相撞的这部分图代表的是在 PreScan 中设置的碰撞检测模块，下面的两辆车分别代表场景中的后车和前车，双击后即可开始构建各车辆在 Simulink 下的控制算法。

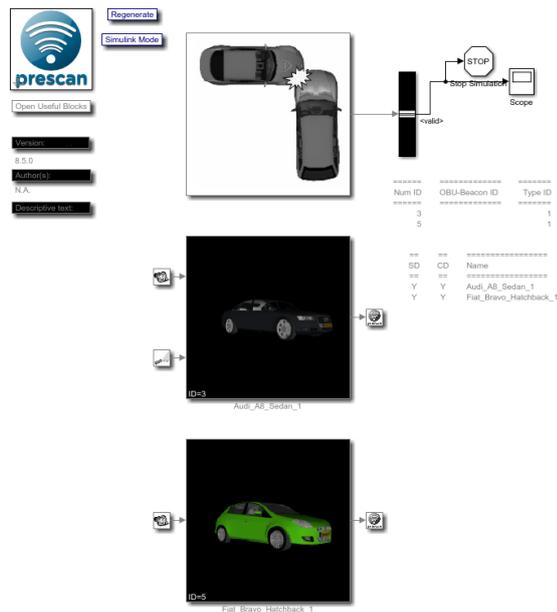


图 5-4 Simulink 下的车辆模型图

5.3.1 前车控制算法设计

本文假定前车可以处于加速、匀速或者减速三种状态，若车辆处于加速状态时，限定其最大速度为 110km/h，达到最大速度后车辆将停止加速，并以当前速度匀速向行驶。若车辆处于匀减速状态时可以速度至速度为 0。本文设计得到前车在 Simulink 下的控制算法逻辑图如图 5-5 所示。

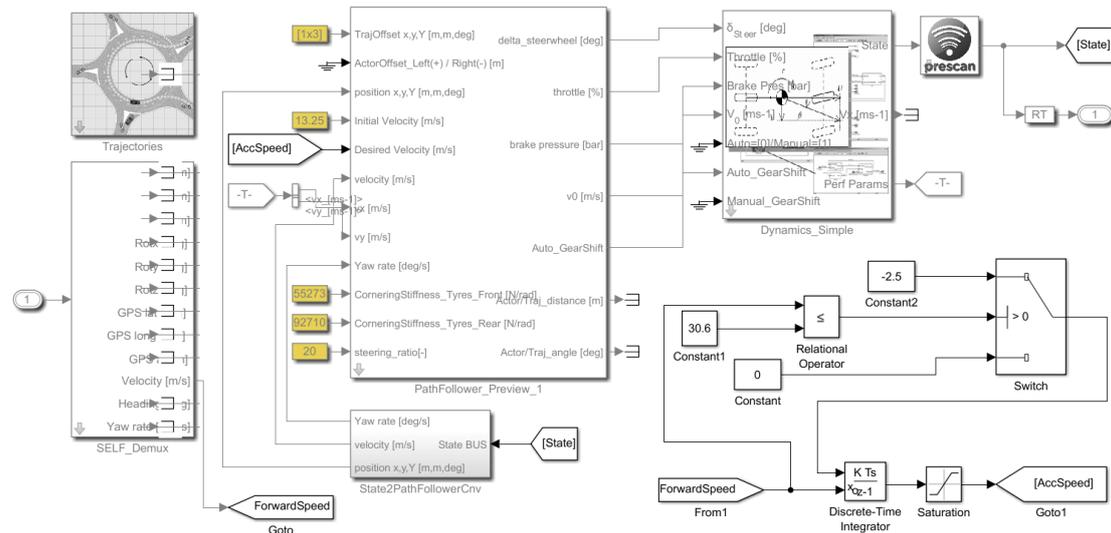


图 5-5 前车控制算法逻辑图

图 5-5 的逻辑图中左边的 SELF_Demux 模块用于提供车辆在行驶过程中实时检测到的信号，包括车辆的坐标、车辆速度、GPS 和朝向角等，对于前车只需要获取其车速，本研究将其保存到 ForwardSpeed 变量中。中间的 PathFollower 模块用于控制车辆的状态参数信息，包括车辆的初始速度、期望速度等，其与逻辑图中右上角的车辆动力学模块相连，使得控制模型能够访问车身的一些底盘动力学变量^[62]，如方向盘转角、节气门开度等。逻辑图右下角的部分是用于计算车辆的期望速度，当速度达到 110km/h 时使其停止加速。

5.3.2 后车控制算法设计

后车在初始时刻可以是匀速或者匀加速状态向行驶，其在整个跟车场景中会经历三个阶段，即加速逼近前车的阶段、制动阶段以及速度与前车相等时的跟随行驶阶段。由于前车设定了其在加速到 110km/h 后停止加速，因此后车也需要加上这一限制，即设定后车最大的跟随速度是 110km/h。后车在车头处安装了雷达，可以实时获取后车的行驶速度、与前车之间的相对距离以及相对速度等信号，这些信号将输入到控制算法模块中，通过各模块对于信号的一系列处理，实现对后车行驶状态的控制。本研究设计得到的后车在 Simulink 下的控制算法逻辑图如图 5-6 所示。

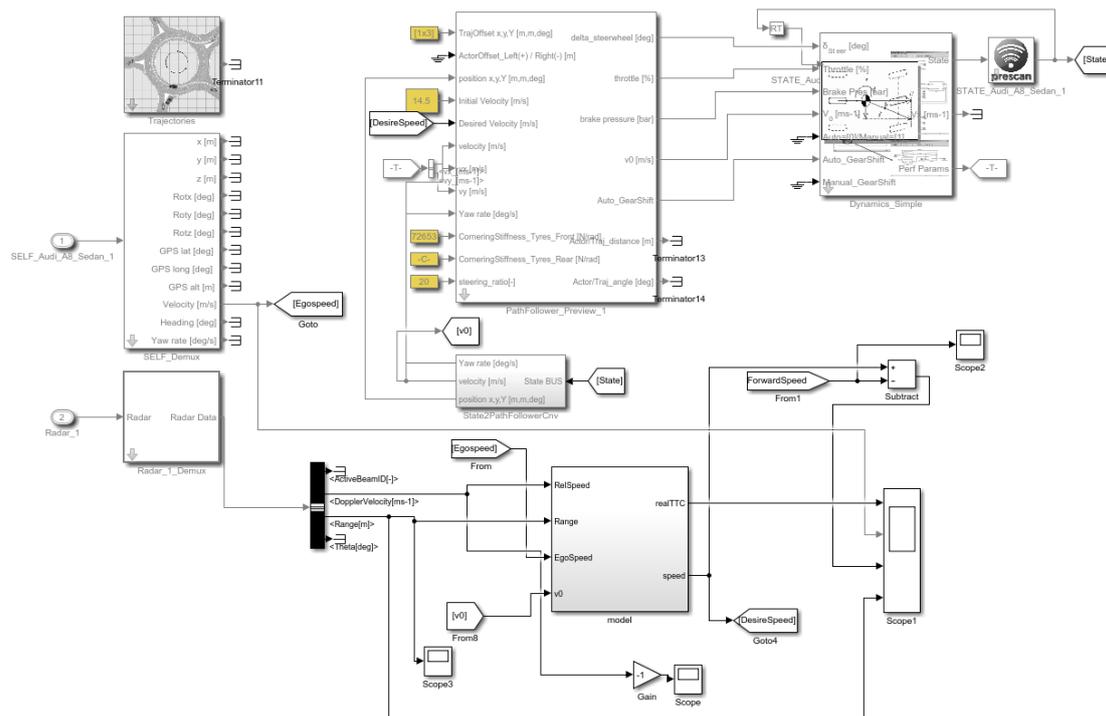


图 5-6 后车控制算法逻辑图

图 5-6 的逻辑图中左边的 SELF_Demux 模块用于提供车辆在行驶过程中实时检测到的信号，本研究需要实时获取后车的行驶速度，将其保存到 EgoSpeed 变量中。PathFollower 模块和 Dynamics_Simple 模块与前车类似，主要用途是通过车辆动力学模块控制车辆的一些状态参数信息。对于后车的主要控制算法逻辑集成在 model 模块中，如图 5-7 所示。

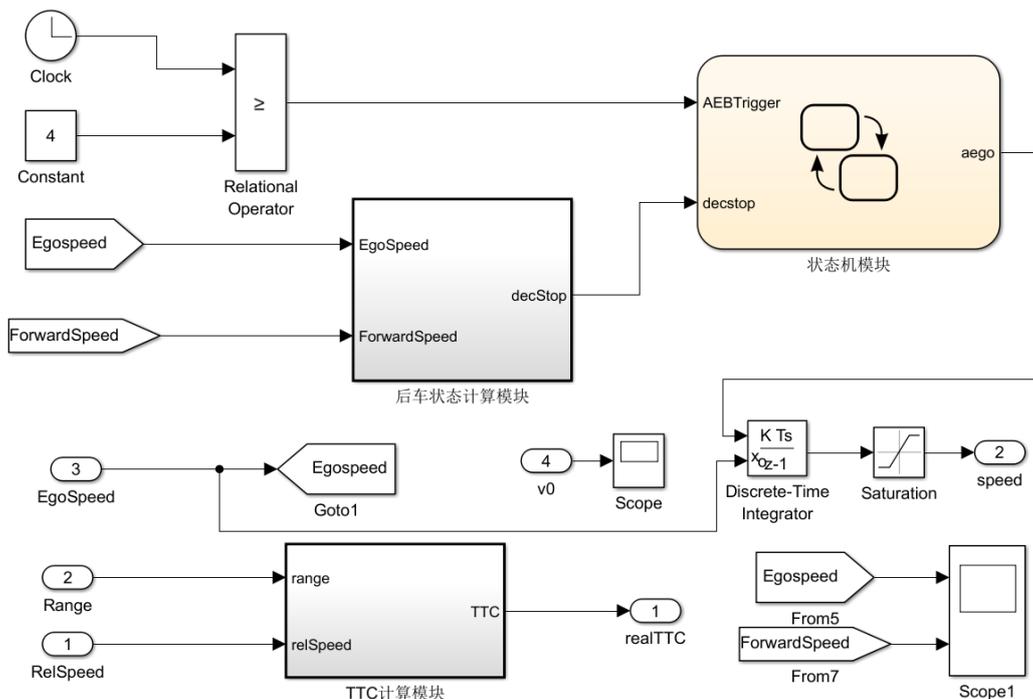


图 5-7 model 模块控制算法逻辑图

图 5-7 的逻辑图中的 TTC 计算模块用于实时计算 TTC 值，后车状态计算模块用于确定后车在何时停止制动以及在何时停止加速，状态机模块需要获取两个输入信号作为状态转移的判断条件，即 AEBTrigger 和 decstop。其中 AEBTrigger 信号用于控制车辆的制动行为，decstop 信号用于控制车辆制动阶段结束后的加速度，整个状态机的输出是后车在道路上行驶时的加速度。接下来将详细分析各模块的具体实现逻辑。

① 后车状态计算模块

该模块的控制算法逻辑如图 5-8 所示，输入是前车与后车的速度，输出是 decStop 信号，信号取值为 0 或者 1。当两车速度差小于等于 0m/s 并且后车的速度小于 30.6m/s 即 110km/h 时，令输出信号 decStop 为 1，当上述条件其中一项不满足时令输出信号 decStop 为 0。

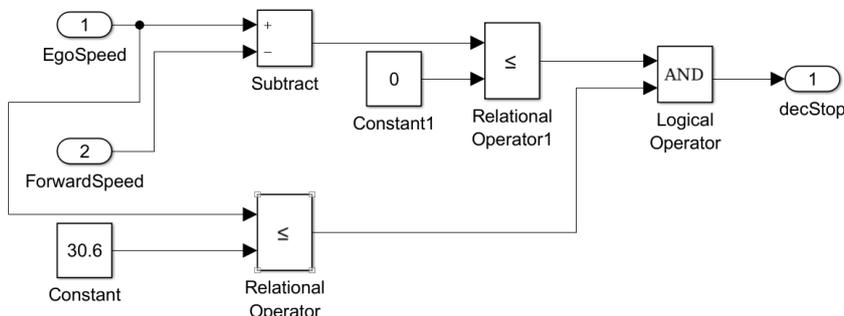


图 5-8 后车状态计算模块控制算法逻辑图

② 状态机模块

该模块的控制算法逻辑如图 5-9 所示。本文假定后车在整个场景到达某一时刻时开始制动，在到达某一时刻之前状态机的输入信号 AEBTrigger 为 0，此时设置后车按其初始状态下的加速度向前行驶，当到达设定的时刻后状态机的输入信号 AEBTrigger 变为 1，此时更改后车的状态变为减速，使其加速度变为负的制动减速度。当后车与前车的速度差小于等于 0m/s 并且后车的速度小于 110km/h 时，状态机的输入信号 decStop 变为 1，此时更改后车的状态由上阶段的制动变为与前车保持相同的加速度向前行驶，使整个跟车场景进入车辆跟随阶段。若初始时刻前车是匀速向前行驶的，那么当后车与前车速度相等后两车将保持相等的速度匀速向前行驶，此时后车的制动减速度将变为 0。若初始时刻前车是匀加速向前行驶的，那么当后车与前车速度相等后后车的制动减速度将改为与前车加速度相等，并以此状态跟随前车向前加速行驶，直至速度达到 110km/h 后停止加速。

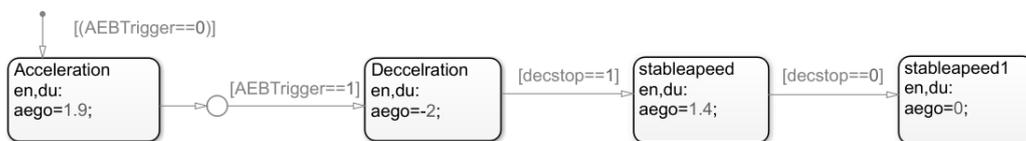


图 5-9 状态机控制算法逻辑图

状态机的输出为后车的加速度，将其与后车的初始速度输入到积分模块便可计算出后车实时的速度，计算逻辑如图 5-10 所示。

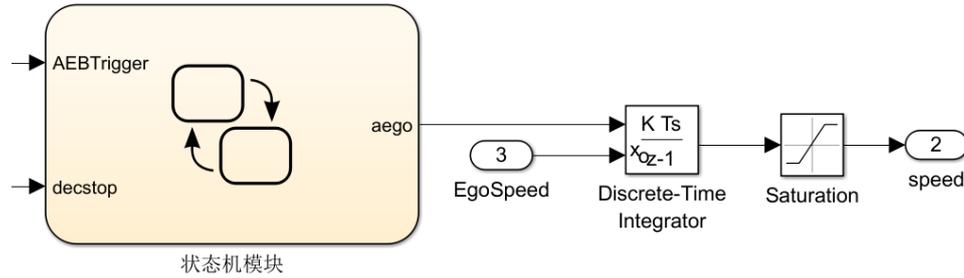


图 5-10 后车实时速度计算逻辑

③ TTC 计算模块

该模块的算法逻辑如图 5-11 所示，其中 *range* 代表两车的相对距离，*relSpeed* 为两车的相对速度，这两个信号均从车载雷达处获取^[63]。由 TTC 指标的计算公式可知，其为两车间的相对距离除以相对速度，通过雷达实时获取到的两车相对距离和相对速度信号，即可实时计算出场景的 TTC 指标值。

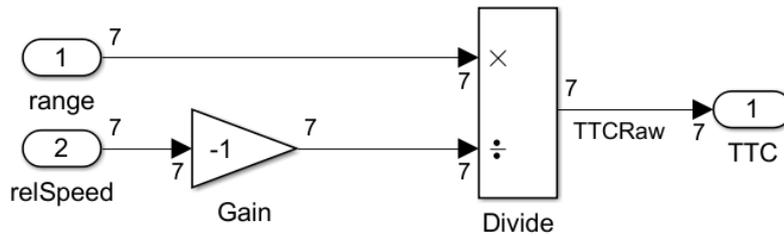


图 5-11 TTC 计算模块逻辑图

5.4 基于联合仿真的 TTC 指标变化趋势分析

本文在第三章中通过理论推导的方法获取了不同跟车场景下 TTC 曲线的变化情况并通过 Matlab 进行了验证。为了进一步证明第三章五种情形的 TTC 变化趋势以及使用 TTC 最小值作为 STCI 指标参数的合理性，本文基于 PreScan 与 Simulink 的联合仿真构建了五个不同的跟车场景进行测试，各场景的状态参数如表 5-1 所示。

表 5-1 TTC 指标变化趋势实验场景状态参数表

场景	$v_f(\text{km/h})$	$v_e(\text{km/h})$	$a_f(\text{m/s}^2)$	$a_e(\text{m/s}^2)$	$a_s(\text{m/s}^2)$	$d(\text{m})$	$t_{zd}(\text{s})$
1	23.0	45.0	1.0	1.5	-2.0	56.5	2.3
2	12.6	34.6	0	1.5	-3.2	36.5	2.4
3	27.4	44.2	1.4	0	-1.5	40.3	2.0
4	38.5	65.1	1.2	0	-2.82	76.1	4.0
5	60.1	49.7	-3.0	0	-2.0	56.5	1.5

表 5-1 中 t_{zd} 表示后车制动的时刻，其他参数的含义同前文所述。本文在前面设计车辆控制算法时构建了 TTC 计算单元，可以实时计算场景中的 TTC 指标值，采用 Simulink 中的示波器即可显示 TTC 指标在不同跟车场景下的变化趋势，如图 5-12 至图 5-16 所示。

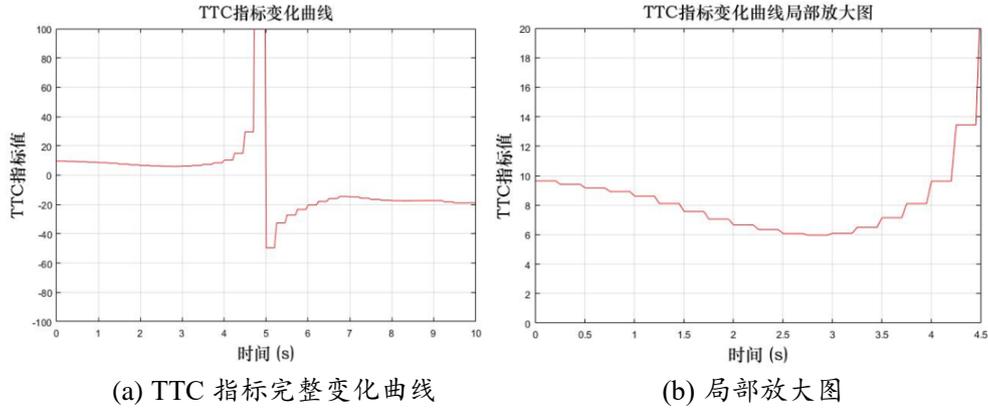


图 5-12 场景 1 中 TTC 指标实时检测曲线

图 5-12 验证的 TTC 指标的变化趋势是情形一，即后车逼近阶段 TTC 指标单调递减，而后车制动阶段 TTC 指标单调递增。本文在实验中设定场景 1 中的后车在 2.3 秒的时候开始制动，但是由于在车辆上加入了动力学模型，车辆的实际运行情况是非理想的，包括开始制动、停止制动等这些对于车辆的控制行为不会在发起后立即实现，而是会有一些延迟，这也是与真实情况相符的。因此从图 5-12-b 中可以看到，在时间到达 2.3 秒后，TTC 指标值并没有直接从后车逼近阶段的单调递减状态转为后车制动阶段的单调递增状态，而是延后了 0.4 秒，从 2.7 秒开始变为单调递增，实验结果图与第三章情形一中 TTC 变化趋势的理论推导结果一致。

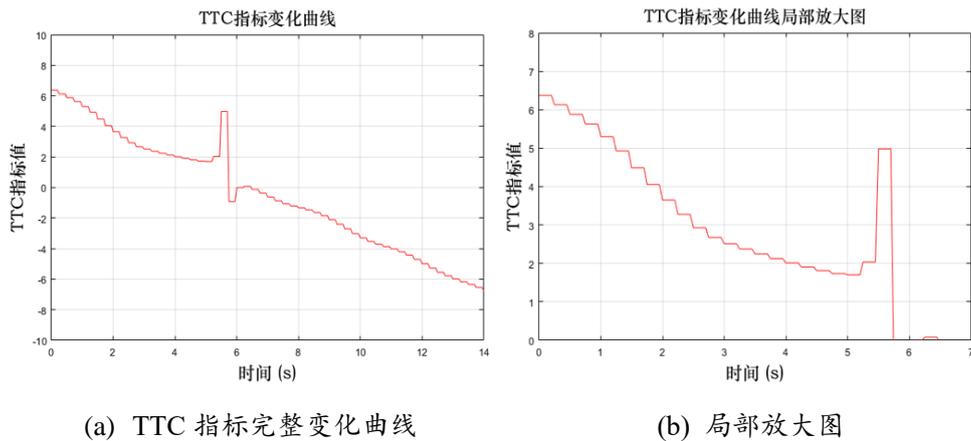
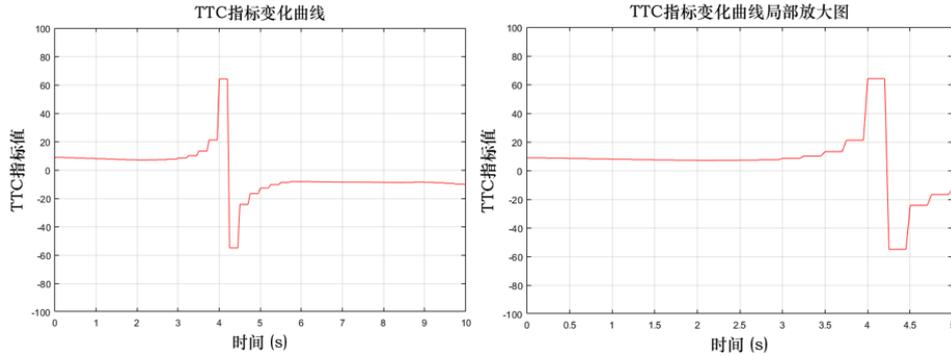


图 5-13 场景 2 中 TTC 指标实时检测曲线

图 5-13 验证的 TTC 指标的变化趋势是情形二，即后车逼近阶段 TTC 指标单调递减，而后车制动阶段 TTC 指标先减后增。在场景 2 中本文设定后车在 2.4

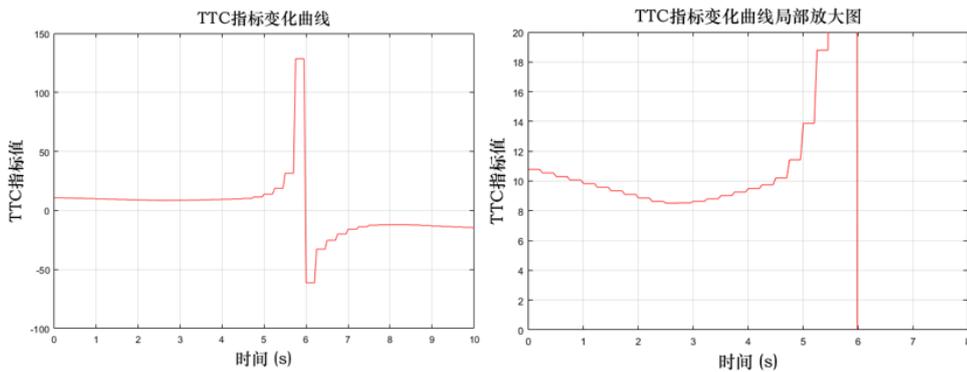
秒的时候开始制动，在 2.4 秒前该场景处于加速逼近阶段，从图 5-13-b 中可以看到，此阶段 TTC 指标是单调递减的，在第 2.7 秒，TTC 指标的变化斜率受制动影响发生突变，此后在 2.7 秒到 5 秒期间 TTC 指标依然在单调递减，直到 5 秒的时候才开始变为单调递增。同样与情形二的 TTC 变化趋势一致。



(a) 场景三 TTC 指标变化曲线 (b) 场景三 TTC 指标变化曲线局部放大图

图 5-14 场景 3 中 TTC 指标实时检测曲线

图 5-14 验证的 TTC 指标的变化趋势是情形三，即后车逼近阶段 TTC 指标单调递增，而后车制动阶段 TTC 指标也是单调递增。在场景 3 中设定后车在 2.0 秒的时候开始制动，从图 5-14-b 中可以看到，忽略掉由于车辆动力学影响导致的 TTC 指标初始时刻略微下降的部分，该场景下 TTC 指标一直是处于单调递增的状态。此外，从图中也可以看出制动行为对于场景的 TTC 影响有限，这是因为此时前车的加速度大于后车，初始时刻为场景的最危险时刻，后车正在逐渐退出跟车场景。



(a) 场景四 TTC 指标变化曲线 (b) 场景四 TTC 指标变化曲线局部放大图

图 5-15 场景 4 中 TTC 指标实时检测曲线

图 5-15 验证的 TTC 指标的变化趋势是情形四，即后车逼近阶段 TTC 指标先减后增，而后车制动阶段 TTC 指标单调递增。在场景 4 中本文设定后车在 4.0 秒的时候开始制动，从图 5-15-b 中可以看到，在 4.0 秒之前 TTC 指标出现了先递减然后递增的趋势，而在 4.0 秒后单调递增。实验结果与理论推导的 TTC 变化趋势一致，在该场景下前车加速度大于后车，虽然后车初始速度较大导致场景

安全性的下降，但随着前车的速度上升，场景的安全性逐渐增加。

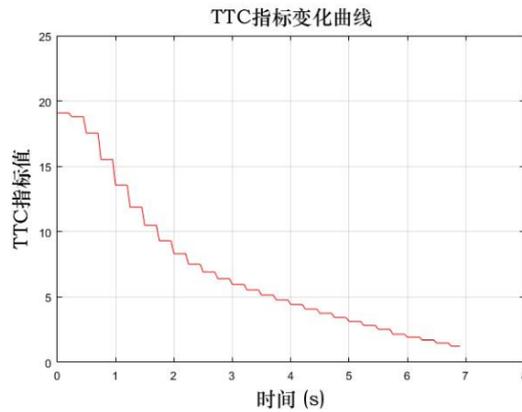


图 5-16 场景 5 中 TTC 指标实时检测曲线

图 5-16 验证的 TTC 指标的变化趋势是情形五，即后车逼近阶段和后车制动阶段 TTC 指标都是递减的情况。在该场景中本文设定后车在 1.5 秒的时候开始制动，从图 5-16 中可以看到，在 1.5 秒之前 TTC 指标是单调递减的，而在 1.5 秒后 TTC 指标值的下降斜率降低，此后继续递减至接近 0。这与第三章中对于情形五的 TTC 变化趋势一致，在前车制动情况下，后车再采取制动行为后会影响 TTC 曲线的变化斜率，增加场景安全性。

通过以上的实验分析验证了第三章中对于 TTC 变化趋势理论推导结果的正确性，同时，也进一步证明了在情形一、情形二和情形五中，制动行为对于最小 TTC 数值的影响，从而证明了使用最小 TTC 值作为 STCI 指标参数的合理性。

5.5 STCI 指标实例评价分析

为了能够较为直观的验证本文提出的 STCI 评价指标的有效性与可行性，本文首先构建了三类场景进行实验，分别代表安全性较好、安全性较差和通行效率较差的场景并计算出其 STCI 数值，各场景的状态参数如表 5-2 所示。通过 PreScan 搭建虚拟场景，并与 Simulink 进行联合仿真，绘制了这三类场景下前车速度、后车速度、相对速度以及相对距离的实时变化曲线，并对各场景下的状态参数进行了详细的分析。

表 5-2 不同场景状态参数及评价结果

场景	v_f	v_e	a_f	a_e	a_s	d	t_{zd}	STCI	评价
1	23.5	46.4	1.0	1.5	-2.0	51.5	1.5	96.4	优秀
2	45.0	63.4	0	1.3	-3.0	62.0	4.5	5.1	差
3	37.0	42.5	0	0.8	-2.5	51.5	2.0	67.9	及格

(1) 安全性较优的场景

表 5-2 中的场景 1 对应的是安全性较优的场景。该场景中两车初始间距为 51.5 米，前车初始速度为 23.5km/h，以 1.0m/s^2 的加速度向行驶，而后车的初始速度为 46.4km/h，以 1.5m/s^2 的加速度向前逼近前车，在经过 1.5 秒后以 -2m/s^2 的减速度制动。

为了得到该场景下的 STCI 指标值，首先需要计算该场景下的最小 TTC 值以及最优 TTC 阈值。对于最小 TTC 值的计算，首先需要判断当前场景对应的 TTC 指标变化趋势属于哪一种情形，由于该场景中 $a_e > a_f$ ，因此根据图 3-6 的判别流程，还需要继续判断 $TTC_2(t_1)|_{t=1.5}$ 的正负，将该场景的状态参数代入到式 (3-20) 中，计算得到 $TTC_2(t_1)|_{t=1.5}$ 为 14.0 是大于 0 的，因此该场景中 TTC 指标的变化趋势属于情形一，TTC 指标的最小值将出现在后车刚开始制动的时刻，通过式(3-42)即可得到该场景下 TTC 指标的最小值 $TTC_{\min}(t)|_{t=4}$ 为 5.91。

接着，通过将该场景的状态特征输入到已经训练好的机器学习模型中，计算得到该场景的最优 TTC 阈值为 6.4，该阈值出现的时间是初始时刻后第 1.1 秒。由此可以得出，在该跟车场景中若后车是以 -2m/s^2 的减速度制动，那么其应该在初始时刻后第 1.1 秒开始制动能够使得车辆达到最佳的安全性和通行效率。

由于该场景中最小 TTC 值比最优 TTC 阈值小，因此主要评价的是车辆的安全性。通过将计算得到的最小 TTC 值和最优 TTC 阈值代入 STCI 指标的计算公式，得到 STCI 为 96.4，根据评分分级可以将该场景划分为优秀等级，由此即可对自动驾驶车辆的安全性和通行效率进行评价，结论是该场景是较为安全的，通行效率也较好。

为了验证上述结论的正确性，本文通过 PreScan 和 Simulink 的联合仿真绘制该场景下 TTC 指标、相对速度、后车速度以及相对距离的实时变化曲线进行分析，如图 5-17 所示。

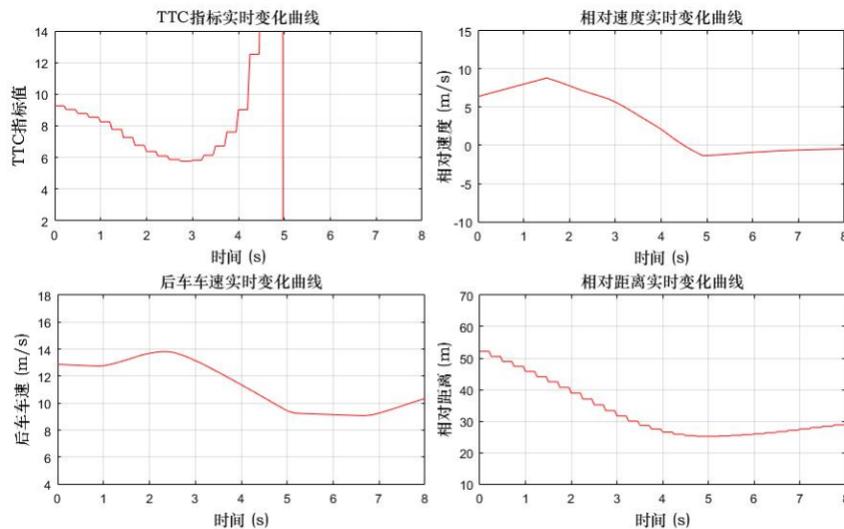


图 5-17 安全性较优的场景中各状态参数实时变化曲线

该场景中后车的速度变化曲线经历了三个阶段，首先是逼近阶段，此时后车速度逐渐增大；之后是制动阶段，此时后车速度逐渐减小；当其与前车速度相等时停止减速，并与前车保持相同的速度和加速度跟随行驶。从图 5-17 中可以看到，实际的状态参数变化曲线并没有严格与设置的参数对应，这是由于在车辆中加入了动力学模型，车辆的实际运行情况是非理想的，两车在实际行驶时的控制行为不会在发起后立即实现，而是会有一些滞后。

通过分析图 5-17 中后车车速、相对车速以及相对距离的实时变化曲线可知，该场景中后车在初始时刻经过 4.8 秒后速度变为 9.1m/s，即 32.7km/h，此时其与前车的相对速度近似为 0，而与前车的间距为 25 米。图 5-18 展示的是后车在车速为 32.7km/h 时驾驶员视角图，在该跟车场景下若前车紧急制动也能给后车留有足够的反应时间来刹车或者转向避开，由此可以看出 STCI 指标对于该场景的评价结论是合理的。



图 5-18 场景 1 中驾驶员视角图

(2) 安全性较差的场景

表 5-2 中的场景 2 对应的是安全性较差的场景。该场景中两车初始间距为 62.0 米，前车初始速度以 45.0km/h 的速度匀速向前行驶，而后车的初始速度为 63.4km/h，以 1.3m/s^2 的加速度向前逼近前车，在经过 4.5 秒后以 -3m/s^2 的减速度制动。

通过计算得到该场景的最小 TTC 值为 2.7，最优 TTC 阈值为 11.9，由于该场景中最小 TTC 值比最优 TTC 阈值小，因此主要评价的依然是车辆的安全性。通过将计算得到的最小 TTC 值和最优 TTC 阈值代入 STCI 指标的计算公式，得到 STCI 为 5.1，根据分级该场景被划分为差，由此即可对自动驾驶车辆的安全性和通行效率进行评价，结论是自动驾驶车辆在该场景下的控制决策行为是非常不合理的，该场景十分危险，车辆很容易发生追尾碰撞事故。该场景下各状态参数的实时变化曲线如图 5-19 所示。

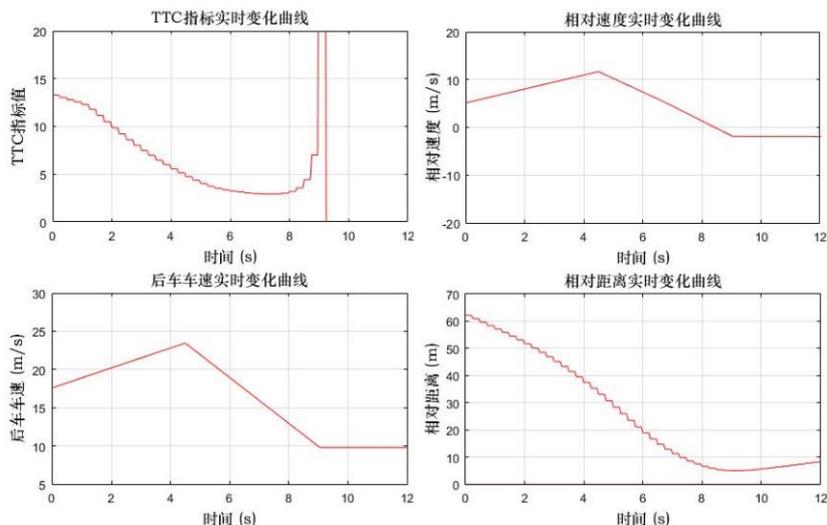


图 5-19 安全性较差的场景中各状态参数实时变化曲线

通过图 5-19 中各参数的实时变化曲线可以看到，该场景中后车在初始时刻经过 4.5 秒后的速度为 85km/h，前车速度为 45km/h，此时两车间距为 36 米，自动驾驶车辆选择在此时才开始以 $-3m/s^2$ 的减速度制动显然是不合理的，不仅会使得车辆处于非常危险的行驶状态，而且以该减速度制动会影响到车上乘客的舒适度体验。在 9.15 秒的时候后车的速度变为 34.9km/h，此时其与前车的相对速度近似为 0，且两车间距为 3.7 米，对于这一个跟车场景，从驾驶员视角来看确实是很危险的，若前车紧急制动那么两车将很容易发生追尾碰撞事故，由此可以看出 STCI 指标对于该场景的评价结论是合理的。通过 PreScan 从驾驶员视角来观察该场景的整个过程，如图 5-20 所示。

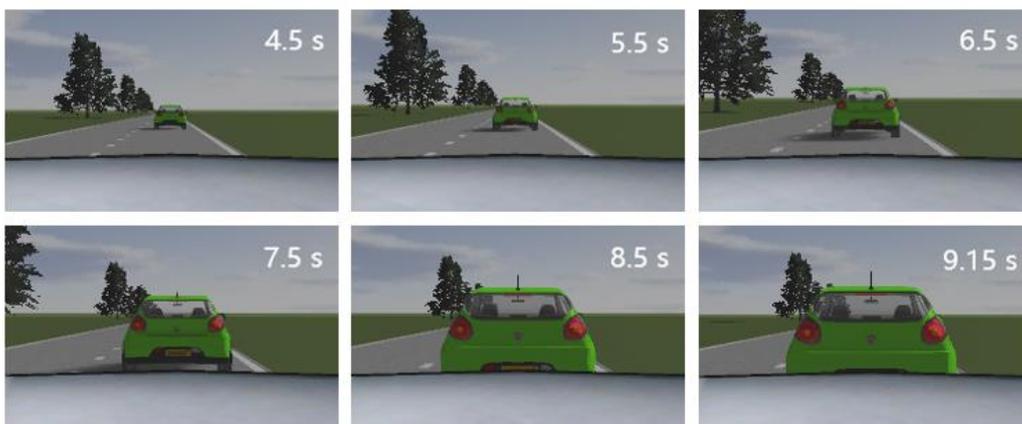


图 5-20 场景 2 中驾驶员视角图

(3) 通行效率较差的场景

表 5-2 中的场景 3 对应的是通行效率较差的场景。该场景中两车初始间距为 51.5 米，前车以 37.0km/h 的车速匀速向前行驶，而后车的初始速度为 42.5km/h，以 $0.8m/s^2$ 的加速度向前逼近前车，在经过 2 秒后以 $-2.5m/s^2$ 的减速度制动。

通过计算得到该场景的最小 TTC 值为 19.5，最优 TTC 阈值为 8.6，由于该场景中最小 TTC 值比最优 TTC 阈值大，因此主要评价的是车辆的通行效率。通过将计算得到的最小 TTC 值和最优 TTC 阈值代入 STCI 指标的计算公式，得到 STCI 为 67.9，根据评分分级可以将该场景划分为及格等级，由此即可对自动驾驶车辆的安全性和通行效率进行评价，结论是该场景虽然很安全，但是车辆通行效率较差。该场景下各状态参数的实时变化曲线如图 5-21 所示。

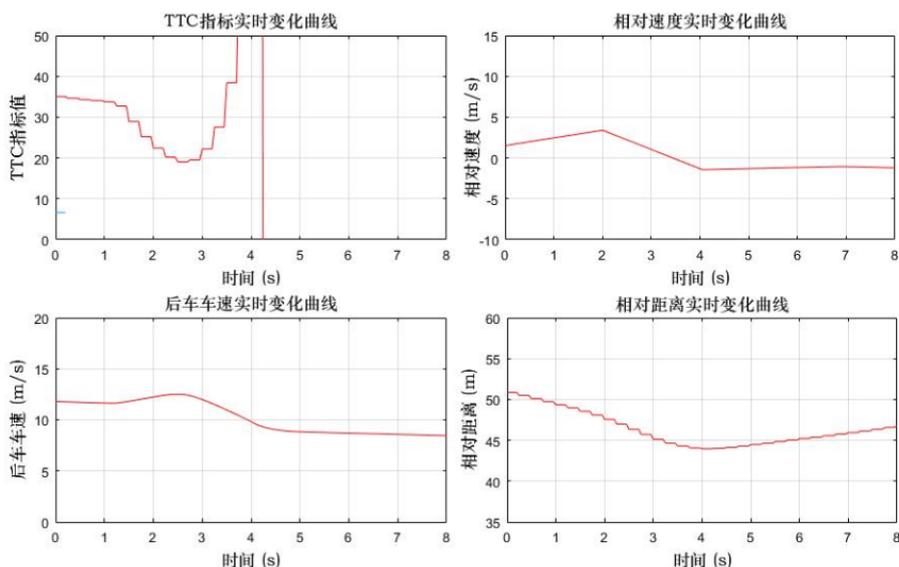


图 5-21 通行效率较差的场景中各状态参数实时变化曲线

通过图 5-21 中各参数的实时变化曲线可以看到，该场景中后车在初始时刻经过 4.1 秒后速度变为 8.15m/s，即 25.6km/h，此时其与前车的相对速度近似为 0，并且与前车的间距为 44 米。图 5-22 展示的是后车在车速为 25.6km/h 时驾驶员视角图，在该场景下两车相距较远，虽然车辆处于很安全的状态行驶，但实际上在当前速度下并不需要相距这么远，车辆在当前场景下过早的刹车行为使得车辆的通行效率较低。由此可以看出 STCI 指标对于该场景的评价结论是合理的。

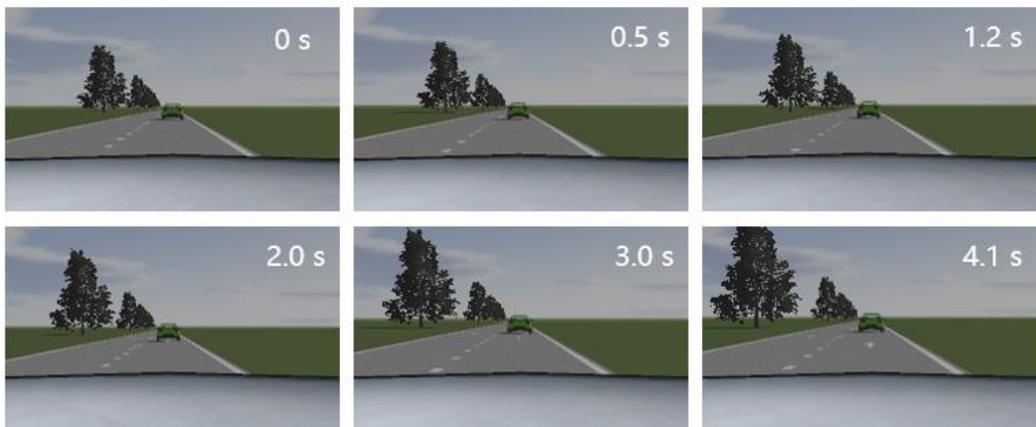


图 5-22 通行效率较差的场景下驾驶员视角图

5.6 STCI 指标有效性与可行性分析

上一小节中结合 PreScan 对三类不同场景通过 STCI 指标进行了评价，从主观上证明了 STCI 评价指标的合理性。本节首先随机生成了大量场景，然后根据前后车速和前车加速度状态进行分类实验分析，选取了 9 类不同的典型场景进行指标分析并结合消融实验展示分析结论，进一步证明 STCI 综合评价指标的有效性与可行性。

5.6.1 STCI 分析实验

本文通过随机生成场景的状态参数构建了多种不同类型的跟车场景，获取场景的最小 TTC 参数 m_{min} ，然后用前面训练好的 LightGBM 模型分别计算各场景的最优 TTC 阈值参数 m^* ，并计算各场景的 STCI 指标值，得到对场景的综合评分，以及对各场景下自动驾驶车辆制动决策行为的评价，如表 5-3 所示。

表 5-3 不同跟车场景的状态参数及评价结果

场景编号	v_f	v_e	a_f	a_e	a_s	d	t_{zd}	t^*	m_{min}	m^*	STCI	评价	
第一组	1	23.5	46.4	1.0	1.5	-2.0	51.5	1.5	1.1	5.9	6.4	96.4	优秀
	2	62.0	64.4	1.2	2.0	-2.2	71.8	2.5	1.3	25.6	40.8	61.3	及格
	3	76.9	84.3	2.2	2.6	-4.8	67.8	2.3	0	19.7	32.6	58.3	差
第二组	4	37.0	42.5	0	0.8	-2.5	51.2	2.0	3.8	16.2	8.6	67.9	及格
	5	97.8	108	0	0.5	-4.9	101	1.7	0.8	25.8	30.5	90.2	优秀
	6	53.5	50.0	0	3.3	-3.4	62.4	2.3	1.6	5.6	7.9	77.1	良好
第三组	7	51.0	54.0	-4.0	0	-3.0	61.0	3.0	0	1.7	50.3	0	差
	8	24.5	25.8	-2.0	0.7	-4.0	42.8	2.4	2.9	3.8	2.6	90.5	优秀
	9	69.0	75.0	-2.0	0	-2.3	70.0	0.8	1.6	12.1	3.9	60.5	及格

表 5-3 中的跟车场景根据前车的加速度状态进行了划分，编号 1~3 的跟车场景中前车加速度大于 0，即前车初始时刻处于加速行驶的状态，而此时后车以更大的加速度逼近前车。这种场景在高速上经常出现，即较为激进的驾驶方法，以较大速度接近前车，在靠近一定距离后才进行减速。场景 1 中的后车驾驶行为较为合理，评分较高，很好的保证了车辆的安全性与通行效率，而场景 2 中后车制动时间较晚，导致两车之间的间距过低，安全性较差因此 STCI 指标较低。场景 3 中后车制动减速度较大，这通常代表着一类舒适度较差的车辆，其制动时间同样较晚，导致驾驶安全性过低。

编号 4~6 的跟车场景中前车匀速，而后车以一定加速度靠近前车，场景 4 中

后车制动时刻较早，即较为谨慎的驾驶行为，导致跟车距离较远，因此 STCI 评分较低，而编号 5 和编号 6 的跟车场景中制动时刻偏晚，分别较最佳制动时刻晚了 0.9 和 0.7s，但是二者的 STCI 评分却差距很大，这是由于二者的后车制动减速度不同，场景 5 的后车制动减速度较大，此时时间推迟导致的危险性增加较低。此外，场景 6 相比较场景 5 更加危险，因为后车初始加速度较大。这进一步论证了 STCI 进行安全性行为评价的合理性。

编号 7-9 的跟车场景为前车制动场景。场景 7 中后车匀速跟车，但是在第 3s 中才进行制动，导致碰撞发生，表明后车的感知系统可能存在问题。而在场景 8 中，后车的制动减速度较大，并且在合适的时间点进行减速，保证了驾驶的安全性并且较少的影响通行效率。相比之下，场景 9 中后车制动减速度较大且两车之间的距离较远，制动时刻较早，影响通行效率。

5.6.2 STCI 与制动时刻消融实验

为了论证 STCI 指标的合理性，本文固定场景下其他参数，仅改变车辆驾驶行为相关参数即后车制动时间以及后车减速度进行实验。上表 5-3 中的 9 个跟车场景首先按照前车加速度分了三组，此后根据前车速度又分了三个场景，具有较好的跟车场景覆盖效果。本节将通过对比表 5-3 中的跟车场景进行实验，分析车辆制动时刻与 STCI 指标之间的关系。为了更好的区分在不同的前车驾驶行为下本文所提出的 STCI 的合理性与有效性，本文分三组场景分别进行实验。

(1) 前车加速的场景

表 5-3 的第一组场景中前车加速，后车以更快的速度逼近前车，这种跟车场景在高速路上经常发生，后车驾驶员较为激进以更高速度从远处向前车靠近，在距离前车很近时才降低速度。通过设置后车制动时刻为 0 至 10 秒，并计算不同制动时刻下对应的 STCI 指标值，可以得到 STCI 与制动时刻的关系曲线，如图 5-23 所示。

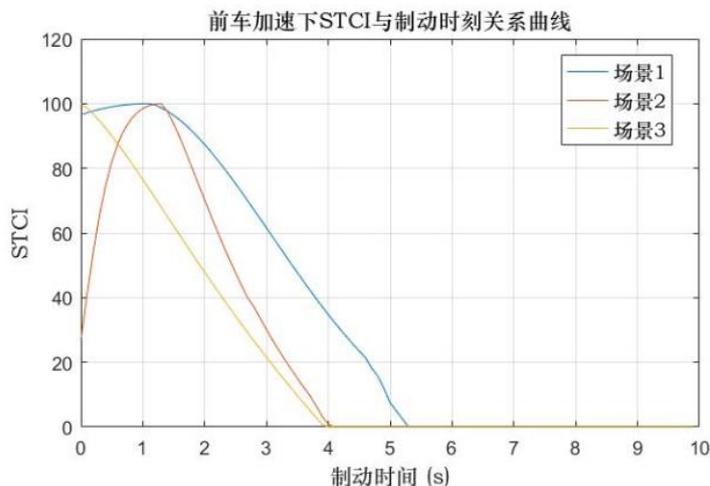


图 5-23 前车加速下 STCI 与制动时刻关系曲线

图 5-23 中蓝线代表场景 1, 该场景中后车速度远高于前车, 并且加速度也大于前车, 在这个场景下的最佳制动时刻为 1.1s。从图 5-23 可以看出, 场景 1 的曲线在 1.1s 取得最大值, 而在此之前其变化速率较为缓慢, 这是因为该场景下前后车的速度较低, 并且初始距离适中, 在这种情形下后车稍微减速就可以保持很好的跟车距离。此后, 随着后车制动时刻的推迟, 场景安全性程度开始降低, 直到 5.2s 发生碰撞。由于该场景中前后车速度较低, 因此在最佳制动时间后的曲线斜率较小, 表示 STCI 指标评分下降较慢。

红线代表场景 2, 该场景中前后两车的速度都较大, 同时两车间的初始距离也较大, 因此当后车制动较早时, 会导致较大的跟车距离, 从而会降低车辆的通行效率, 因此红色曲线在最佳制动时刻之前的增长速率较快。场景 2 中最佳制动时刻之后的曲线下降速率相比于场景 1 的下降速率更快, 这同样是由于场景 2 中的车速较快导致的, 在这种情况下, 制动时间的推迟会更大的影响安全性和通行效率。

黄线代表场景 3, 该场景中前后车速都很快, 同时后车以更高的加速度行驶, 在初始距离较小的情况下, 场景是非常危险的, 后车应当立刻制动保持良好的跟车距离。但是可以看出, 场景 3 中最佳制动时刻之后的曲线下降速率低于场景 2, 与场景 1 接近, 这是因为场景 3 中的后车制动减速度和前车加速度较大。在这种情况下, 后车可以更加从容的面对追尾碰撞, 因此其下降速率较低。

对图 5-23 进行横向分析可知, 在某一具体场景下, 随着后车制动时刻的推迟, STCI 指标会经历先变大然后变小的过程, 即场景下存在着一个最佳的制动时刻, 在该时刻之前制动会影响通行效率, 在该时刻之后制动才会影响安全性。由此证明 STCI 指标可以很好的用于评价跟车场景下车辆的制动时刻, 并给出合理的建议。

对图 5-23 进行纵向分析可知, 前后车速越大, STCI 随着制动时刻的变化斜率越大, 这与高速环境下车辆行驶更加危险的人类认知是一致的, 在这种场景下对于制动时刻的把控需要更加的细致。此外, 后车的制动减速度同样影响 STCI 随着制动时刻的变化, 制动减速度越大时, 车辆会有更短的制动距离, 因此 STCI 评分会降低的较慢。

(2) 前车匀速的场景

图 5-24 展示的是前车匀速行驶时后车制动时刻与 STCI 的关系曲线图, 对应于表 5-3 中的第二组场景。由图 5-24 可以看出, 在前车匀速行驶的情况下随着后车制动时刻的推迟, STCI 指标会经历了先增大后减小的过程。当后车提前制动时会导致两车稳定跟车阶段的间距过大, 影响车辆通行效率。当后车制动较晚时则会导致两车稳定跟车阶段的间距过小, 从而影响车辆安全性。

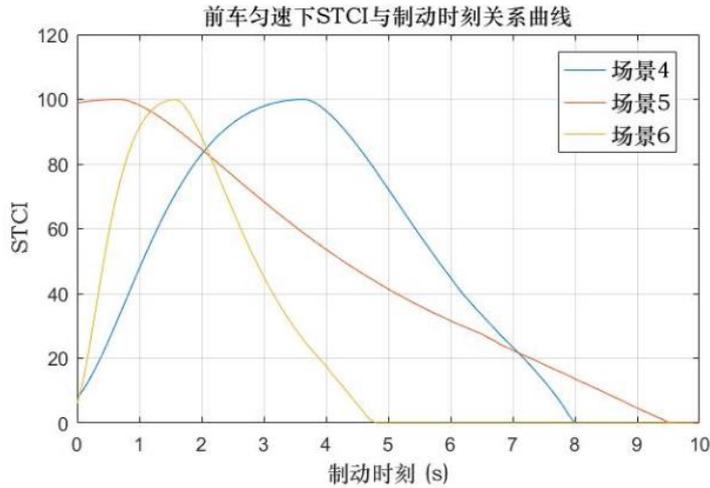


图 5-24 前车匀速下 STCI 与制动时刻关系曲线

场景 4 中前后两车的速度较低，对应于图 5-24 中的蓝线。该场景中两车的初始间距较大同时减速度较高，因此在 STCI 达到峰值之前 STCI 上升的速度较慢，即该场景较为安全。场景 5 则较为危险，前后车的速度较快，两车的初始相对距离相较于速度偏小，同时后车具备一定的加速度，因此需要尽快减速避免碰撞。由于其制动减速度较大，因此曲线的增长与下降的速率都不快。场景 6 中前后车速适中，初始车距较大，曲线同样经历了先增大后减小的过程。由于后车的初始加速度较大，因此整个曲线斜率较大。

对图 5-24 的分析可以看出，在前车匀速时随着制动时刻的推迟，STCI 指标同样需要经历从增大到减小的过程，这证明了 STCI 指标用于制动行为评价的合理性。此外，后车的初始加速度越大，会使得 STCI 指标的变化斜率越大，这意味着场景更危险。

(3) 前车制动的场景

图 5-25 展示的是前车制动下的 STCI 与后车制动时刻的关系曲线图，对应于表 5-3 中的第三组场景。

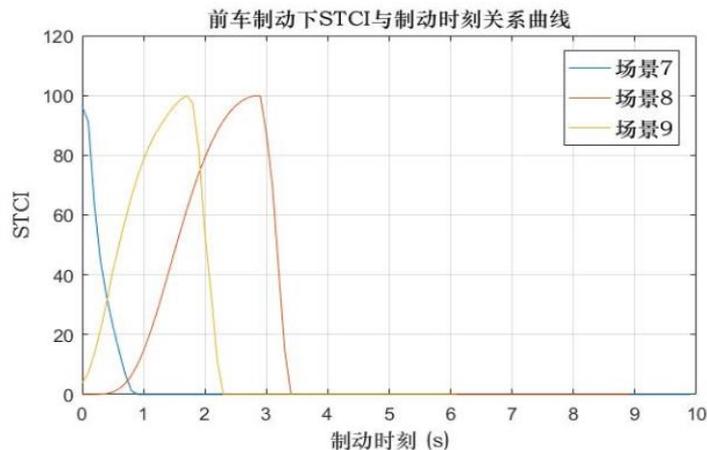


图 5-25 前车制动下 STCI 与制动时刻关系曲线

从图 5-25 中可以看出,在前车制动的情况下,STCI 指标仍然是经历了先增大后减小的过程。前车制动是跟车场景下最危险的情况,最容易导致追尾事故的发生,在这种情况下的及时制动十分重要。由表 5-3 可以看出,场景 7 的前车制动减速度较大,后车在 0 时刻减速能够使得 STCI 分值最高。此时,制动的不及时将极大影响车辆运行的安全性,因此在前车制动情况下的三个曲线的斜率都非常大。场景 8 和场景 9 中前车制动减速度较低,同时两个场景下的两车初始间距较大,因此可以分别在 2.9 秒和 1.6 秒以后进行制动,从而保持较好的跟车距离。

总的来说,图 5-23、图 5-24 和图 5-25 分别代表了在前车加速、匀速和制动情况下的 STCI 随着车辆制动时刻的变化情况,其总体趋势是先增后减,而场景下的两车速度变小、前车加速度变大、后车制动减速度变大和初始间距变大都会导致曲线的斜率减小,反之则会使曲线斜率增大。此外,前车若处于制动状态,则曲线的斜率较大,曲线斜率越大代表着场景越危险,车辆需要有更加精准的车辆控制能力。

上述内容从总体上描述了 STCI 指标随着制动时间的变化趋势,固定了 9 个场景下的其他参数进行消融实验,从宏观上分析了曲线的变化趋势,本文选取场景 9 的部分消融实验场景进行具体分析,如表 5-4 所示。

表 5-4 场景 9 中 STCI 与后车制动时刻关系表

编号	v_f	v_e	a_f	a_e	d	a_s	t_{zd}	S_{eq}	m_{\min}	m^*	STCI	评价
1	69	75	-2	0	70	-2.3	1.0	42.5	16.7	10.2	83.3	良好
2	69	75	-2	0	70	-2.3	1.1	40.4	15.5	10.2	87.4	良好
3	69	75	-2	0	70	-2.3	1.2	38.3	14.7	10.2	90.7	优秀
4	69	75	-2	0	70	-2.3	1.3	36.2	13.9	10.2	93.7	优秀
5	69	75	-2	0	70	-2.3	1.4	34.2	12.9	10.2	96.3	优秀
6	69	75	-2	0	70	-2.3	1.5	32.1	11.9	10.2	98.5	优秀
7	69	75	-2	0	70	-2.3	1.6	29.9	10.8	10.2	99.8	优秀
8	69	75	-2	0	70	-2.3	1.7	27.9	9.4	10.2	97.3	优秀
9	69	75	-2	0	70	-2.3	1.8	25.8	7.8	10.2	82.8	良好
10	69	75	-2	0	70	-2.3	1.9	23.7	5.6	10.2	63.3	及格

该场景为典型的前车制动情景,在该具体场景下最佳的制动时刻为 1.6s,当车辆提前制动时会导致后车与前车的距离过远,影响通行效率。其中 v_f 和 v_e 分别代表前车与后车的初始速度;单位为 km/h, a_f 和 a_e 分别代表前车与后车的初始加速度, a_s 代表后车制动时的减速度,单位为 m/s^2 ; d 代表两车的初始间距,单位是米; t_{zd} 代表后车实际制动的时刻, S_{eq} 代表两车速度相等时车间距离。在上表中最优 TTC 阈值始终是 10.2s,是因为场景的参数没有更改,仅仅是车辆的制动时刻发生了改变,即场景下的最优制动行为与车辆的制动时间无关。而最小 TTC 数值则是逐渐减小,表明刹车时间越晚,场景越不安全。表 5-4 具体描述了

在最佳制动时刻附近随着制动时刻的变化最小 TTC 值和 STCI 指标的变化情况，与图 5-25 一致，当后车在最佳制动时刻之前刹车时，STCI 指标的变化速率较慢，而一旦制动时刻大于最佳制动时刻 STCI 数值便会急剧降低，意味着场景的安全性急剧下降。

至此，本文从曲线分析和具体案例分析两个方面分析了后车制动时刻与 STCI 指标之间的关联变化关系，证明了 STCI 可以在任意场景下反映后车制动时刻对周围交通的影响，证明使用 STCI 对车辆制动时刻进行评价的合理性与有效性。

5.6.3 STCI 与后车制动减速度消融实验

车辆的制动行为包括制动时刻和制动减速度，上一小节从曲线分析和具体案例分析两个方面论证了 STCI 对制动时刻进行评价的合理性。本小节主要证明 STCI 对车辆制动减速度的评价的合理性与有效性。

本节同样使用表 5-3 中的 9 个场景，将制动时间固定为最佳制动时间，遍历场景下的制动减速度，从而获取制动减速度与 STCI 指标之间的曲线关系。同样分为三个曲线图来进行分析，分别是前车加速、前车匀速以及前车制动场景。

(1) 前车加速的场景

图 5-26 展示的是前车加速行驶时 STCI 与后车制动减速度的关系曲线图，对应于表 5-3 中的第一组场景。

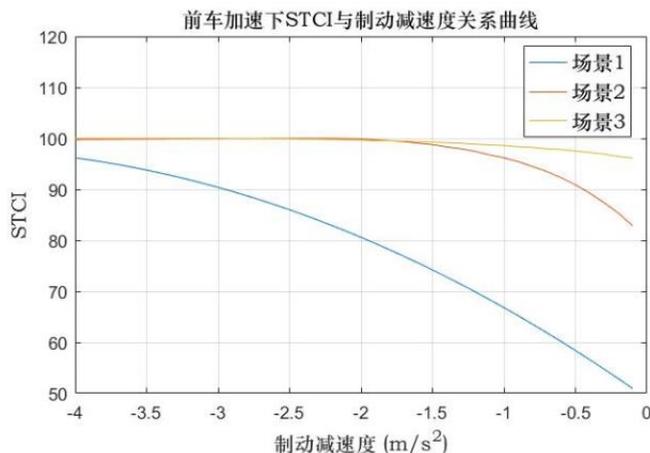


图 5-26 前车加速下 STCI 与制动减速度关系曲线

由图 5-26 可以看出，在前车加速场景下随着后车制动减速度的上升，STCI 数值逐渐上升。这是因为在前车加速的场景下，通常是后车以更快的速度和加速度逼近前车，而对于 STCI 与制动减速度的消融实验中设置制动时刻为表格 5-3 中的最优制动时刻，因此只要保证减速度足够大，后车便可以在很短的时间内减速至与后车一致的速度，因此随着制动减速度的增大，STCI 逐渐增加。从另一

方面进行理解，在后车制动减速度特别小时，速度缓慢下降，因此安全性较低，此后随着制动减速度的增加，场景逐渐安全。又因为前车有加速度，因此很快后车便可以获得与前车一致的跟车速度，保持稳定的跟车距离，由于 3 个场景的初始距离都在初始速度附近稳定跟车状态下的跟车距离都不会影响通行效率。

(2) 前车匀速的场景

图 5-27 展示的是前车匀速行驶时 STCI 与后车制动减速度的关系曲线图，对应于表 5-3 中的第二组场景。

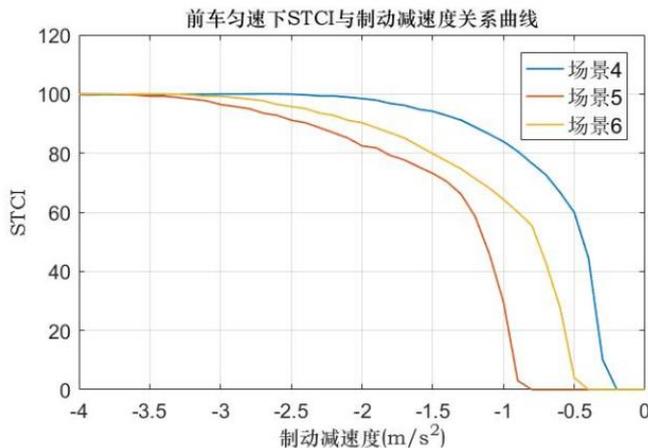


图 5-27 前车匀速下 STCI 与制动减速度关系曲线

将图 5-27 与图 5-24 对比发现，在前车匀速的情况下，如果后车的制动减速度较低，则 STCI 分值为 0。因为在这种情况下前车匀速行驶，后车制动减速度过小接近匀速，而后车初始速度大于前车，则必然会发生碰撞。随着后车制动减速度的增加，后车驾驶安全性程度逐渐上升。此后随着制动减速度过大，后车都可以很快降低至与前车一致的速度，保持安全车距，因此 STCI 分值都较高。

(3) 前车制动的场景

图 5-28 展示的是前车制动时 STCI 与后车制动减速度的关系曲线图，对应于表 5-3 中的第三组场景。

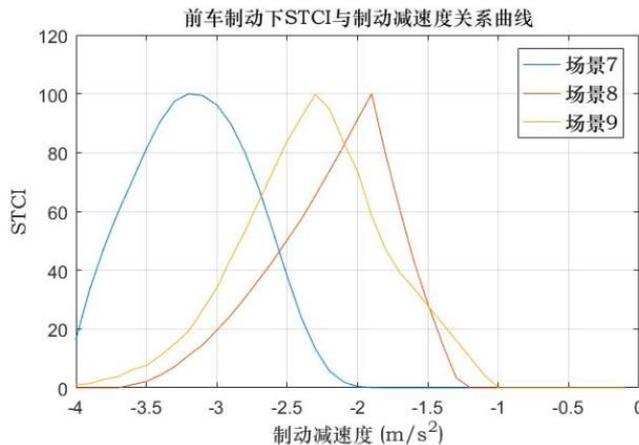


图 5-28 前车制动下 STCI 与制动减速度关系曲线

对比于前车匀速和前车加速的情况可以发现,在该场景下,随着制动减速度的增加,STCI 经历了先增加后减小的过程。在后车制动减速度较小时,由于后车初始速度大于前车,前车制动减速度较大,因此两车将发生碰撞,安全性极低,此后随着制动减速度的增大,安全性迅速增大直至该场景下的最佳制动减速度。随着制动减速度的继续增大,STCI 指标逐渐下降,因为此时制动减速度过大,导致两车之间的稳态距离过大,影响车辆的通行效率。

由上文对前车加速、前车匀速与前车制动这三种情况下 STCI 指标随着制动减速度的变化曲线的分析结果可知,在前车加速和前车匀速的情况下曲线类似,都是随着制动减速度的增大 STCI 将逐渐增大,此后以极慢的速度减小。而在前车制动的情况下,对于后车的制动减速度要求较高,过大影响车辆通行效率,过小则导致安全性不足。综合以上三个场景可知,STCI 指标可以很好的反映出后车的制动减速度对于交通的影响并且能够给出最佳制动减速度数值,证明了 STCI 对于制动减速度评价的合理性和有效性。

上文从总体上论证了 STCI 指标的合理性和有效性,本文取表 5-3 中场景 9 对于制动减速度的消融实验,列出其详细参数如表 5-5 所示。

表 5-5 STCI 与后车制动减速度

编号	v_f	v_e	a_f	a_e	d	a_s	t_{zd}	S_{eq}	m_{\min}	m^*	STCI	评价
1	69	75	-2	0	70	-1.6	1.6	4.4	12.1	28.1	33.8	差
2	69	75	-2	0	70	-1.7	1.6	5.3	12.1	25.9	39.1	差
3	69	75	-2	0	70	-1.8	1.6	7.3	12.1	23.2	47.0	差
4	69	75	-2	0	70	-1.9	1.6	10.2	12.1	20.3	58.5	差
5	69	75	-2	0	70	-2.0	1.6	14.3	12.1	17.3	73.6	及格
6	69	75	-2	0	70	-2.1	1.6	20.4	12.1	15.6	83.6	良好
7	69	75	-2	0	70	-2.2	1.6	25.6	12.1	13.8	94.9	优秀
8	69	75	-2	0	70	-2.3	1.6	30.0	12.1	10.2	99.8	优秀
9	69	75	-2	0	70	-2.4	1.6	34.0	12.1	8.6	92.0	优秀
10	69	75	-2	0	70	-2.5	1.6	37.5	12.1	7.6	83.9	良好

表 5-5 中最小 TTC 是不变的,因为场景下的制动时刻已经确定为 1.6s,在该场景下制动时刻便是场景最危险的时刻,制动时间不变最小 TTC 也不会发生改变。而最优 TTC 阈值是随着后车制动减速度的增加而逐渐减小的,因为在后车制动减速度较小时,后车需要尽可能早的减速,从而避免碰撞,当后车制动减速度较大时就可以较晚制动,减少对于车辆通行效率的影响。由表 5-5 和图 5-28 可以看出,STCI 指标可以给出车辆在跟车场景下的最佳制动减速度并对车辆的安全性和通行效率进行合理的评价。

至此，本文从曲线分析和具体案例两个方面论述了 STCI 指标与后车制动时刻以及后车制动减速度之间的关系，证明了使用 STCI 指标对跟车场景下自动驾驶车辆安全性和通行效率进行评价的可行性和有效性。

5.7 小结

本章首先介绍了利用 PreScan 和 Simulink 进行联合仿真的工作流程，然后基于 PreScan 构建了虚拟跟车场景，在 Simulink 中分别设计了前车与后车的控制算法，通过联合仿真对跟车场景下 TTC 指标变化趋势的理论推导结果进行了验证，从而证明了 STCI 指标最小 TTC 参数计算方法的正确性以及使用最小 TTC 作为 STCI 指标参数的合理性。此后，基于 PreScan 对三类不同场景进行评价，从主观上验证了 STCI 指标的合理性与有效性。最后，本文按照前后车速和前车加速度的状态建立了九种不同的跟车场景，分别采用 STCI 指标进行评价分析，通过对跟车场景下后车的制动时刻以及制动减速度进行消融实验，分析制动时刻以及制动减速度与 STCI 指标之间的曲线关系，证明了使用 STCI 指标对跟车场景下自动驾驶车辆行驶安全性和通行效率进行评价的可行性和有效性。

6 总结与展望

6.1 论文总结

自动驾驶车辆在全面推广前需要经过大量严格的测试和验证,其中最重要的就是对于车辆行驶安全性的测试。目前针对自动驾驶车辆安全性测试评价指标的研究较少,传统的安全性评价指标主要用于 ADAS 系统上实现对于危险场景的判定,进而辅助车辆实现紧急避撞的功能,而对于自动驾驶车辆的安全性测试评价,仅仅从是否会与其他车辆发生碰撞来评价是不够的,不仅要在极端危险的场景中对自动驾驶车辆的控制决策行为进行测试评价,也需要在一些相对安全的场景下进行测试,评价其在该场景下的控制决策行为对于整个场景安全性和车辆通行效率的影响。由于跟车场景在实际交通环境下较为常见,因此本文选取跟车场景对自动驾驶车辆的安全性测试评价指标进行了深入研究,主要工作总结如下:

(1) 提出了一种综合考虑车辆行驶安全性和通行效率的评价指标 STCI

传统的安全性评价指标主要针对的是危险场景,不能反映出车辆的通行效率,并且也不能直接用于评价自动驾驶车辆的控制决策行为。本文在第 2 章中提出一种综合考虑了自动驾驶车辆行驶安全性和通行效率的评价指标 STCI,并详细分析了指标构建的过程及合理性。该评价指标以车辆行驶时的状态信息为依据来进行评价,将自动驾驶车辆在跟车行驶过程中最小的 TTC 值和该场景下的最优 TTC 阈值作为指标的参数,可以很好的反映出整个跟车场景的动态过程,适用于各类跟车场景。其计算结果可直接作为对跟车场景的综合评分,不仅可以得到自动驾驶车辆在整个跟车场景下的最优制动决策时刻,对其实际的制动时间点进行评价,也可以对自动驾驶车辆在某个时间点下的制动减速度进行评价。

(2) 对 STCI 评价指标最小 TTC 参数和最优 TTC 阈值参数进行了深入研究

STCI 评价指标中的最小 TTC 参数所在的时刻反映的是整个跟车场景下最危险的时刻,不同场景状态参数的组合会使得最小 TTC 值出现的时刻以及大小不同,本文在第 3 章中对不同状态参数组合下 TTC 指标可能出现的变化趋势进行了深入研究,证明了车辆制动行为对最小 TTC 的影响以及使用最小 TTC 作为 STCI 指标参数的合理性,并且得到了不同情形下计算最小 TTC 参数的解析式。之后建立了跟车场景的数学模型,研究了确定跟车场景中最优 TTC 阈值参数的方法。该阈值综合考虑了自动驾驶车辆行驶的安全性和车辆通行效率,不仅可以用于扩展 ADAS 系统的功能,也可以为自动驾驶车辆行驶的轨迹规划提供参考。

(3) 提出了一种基于机器学习快速确定跟车场景最优 TTC 阈值的方法

场景的最优 TTC 阈值与场景的状态参数之间是有关系的,但是这种关系是

非常复杂的非线性关系，本文针对最优 TTC 阈值参数难以得到解析式，需要通过数值解法多次遍历计算耗时较长，导致 STCI 指标计算效率较低的问题，提出了一种基于机器学习快速计算最优 TTC 阈值参数的方法以加速 STCI 指标的计算，从而加速对于自动驾驶车辆在跟车场景下行驶时安全性与通行效率的评价。本文在第 4 章中进行了深入的研究，包括样本生成、特征工程、模型训练和验证等工作，最终得到对场景的状态参数与对应的最优 TTC 阈值之间关系拟合效果最好的模型为 LightGBM 模型。通过在大量场景下的测试，证明基于 LightGBM 模型预测确定跟车场景的最优 TTC 阈值的方法相比基于模型确定最优 TTC 阈值的方法速度提升了 6 倍，并且由于误差对最终评价结果的影响较小，因此可以直接采用模型预测的方式快速确定场景的最优 TTC 阈值，从而可以加速虚拟仿真的测试。

(4) 基于 PreScan 与 Simulink 设计了跟车场景联合仿真实验

本文在第 5 章中通过 PreScan 构建虚拟跟车场景，在 Simulink 中设计了车辆控制算法，基于两者的联合仿真实验，进一步证明了 STCI 指标最小 TTC 参数计算方法的正确性以及最小 TTC 作为 STCI 参数的合理性。此外，本文基于联合仿真实验环境，分别从主观和客观方面验证了本研究提出的 STCI 评价指标对于安全性和通行效率的综合评分以及对自动驾驶车辆制动决策行为进行综合评价的可行性和有效性。主观上，建立了三类不同场景计算 STCI 指标，通过分析场景状态参数的实时变化曲线，结合驾驶员视角证明了 STCI 指标的有效性。客观上，本文基于 PreScan 随机生成了大量实验场景，按照前车加速度和前后车速进行分类分析，选取九类典型场景进行消融实验与分析，证明了采用 STCI 指标对跟车场景下自动驾驶车辆行驶安全性和通行效率进行评价的可行性和有效性。

6.2 研究展望

本文对跟车场景下自动驾驶车辆的安全性测试评价指标进行了深入的研究，取得了一定的成果，但是仍然存在改进的空间，未来工作可以从以下 3 个方面进行改进和深入研究：

(1) 由于目前尚未获得自动驾驶车辆的实车采集数据，因此本文是通过 PreScan 与 Simulink 的联合仿真对 STCI 评价指标的有效性进行验证，在后续获取了实车采集数据后，可以基于真实数据进一步验证 STCI 评价指标的有效性，并根据真实数据下的评价结果对 STCI 评价指标进行调整，使得评价结果更加准确。

(2) 本文在构建跟车场景的数学模型时未考虑车辆的动力学模型，对于自动驾驶车辆的制动行为本研究假定在瞬间就能达到设定的减速度，而实际上由于车

辆控制的稳定性，加速度不可能瞬间就能达到设定值，因此在后续的研究中构建跟车场景的数学模型时可加入车辆动力学模型，使得构建的数学模型更加符合真实情况。

(3) 对于跟车场景中的最佳安全车距本文采用的是目前最常用的经验法则确定的，后期可以考虑引入跟车距离模型使得最佳安全车距来增加评价的准确度。

参考文献

- [1] 李克强, 戴一凡, 李升波, 等. 智能网联汽车(ICV)技术的发展现状及趋势[J]. 汽车安全与节能学报, 2017, 8(01):1-14.
- [2] Kalra N, Paddock S M. Driving to safety: How many miles of driving would it take to demonstrate autonomous vehicle reliability[J]. Transportation Research Part A Policy and Practice, 2016, 94:182-193.
- [3] 自动驾驶之家. 自动驾驶仿真蓝皮书《中国自动驾驶仿真技术研究报告》.[EB/OL]. [2019-06-04]. <http://www.heredrive.com/news/20190604/5913.html>.
- [4] Klischat M, Althoff M. Generating Critical Test Scenarios for Automated Vehicles with Evolutionary Algorithms[C]// 2019 IEEE Intelligent Vehicles Symposium(IV), Paris, France, 2019, pp. 2352-2358.
- [5] Menzel T, Bagschik G, Isensee L, et al. From Functional to Logical Scenarios: Detailing a Keyword-Based Scenario Description for Execution in a Simulation Environment[C]// 2019 IEEE Intelligent Vehicles Symposium (IV), Paris, France, 2019, pp. 2383-2390.
- [6] Li L, Lin Y, Zheng N, et al. Artificial intelligence test: a case study of intelligent vehicles[J]. Artificial Intelligence Review, 2018, 50: 441-465.
- [7] Tan J, Yang T, Zhang Y, et al. Evaluation of Vehicles' Platooning on Expressways Based on V2X[C]// 2019 5th International Conference on Transportation Information and Safety (ICTIS), Liverpool, United Kingdom, 2019, pp. 369-375.
- [8] 王雪松, 朱美新, 邢祎伦. 基于自然驾驶数据的避撞预警对跟车行为影响[J]. 同济大学学报(自然科学版), 2016, 44(7):1045-1051.
- [9] 汽车技术研究中心. 汽车安全蓝皮书[M]. 北京: 社会科学文献出版社, 2017: 5-13.
- [10] 吴海飞, 宋雪松, 曹寅. 自动驾驶汽车测试评价方法体系研究[J]. 质量与标准化, 2018(5):50-52.
- [11] Dahl J, Gabriel R D, Olsson C, et al. Collision avoidance: a literature review on threat-assessment techniques[J]. IEEE Transactions on Intelligent Vehicles, 2018, 4(1): 101-113.
- [12] Zhu M, Wang X, Hu J. Impact on car following behavior of a forward collision warning system with headway monitoring[J]. Transportation Research Part C Emerging Technologies, 2020, 111:226-244.
- [13] Meng Q, Qu X. Estimation of Rear-end Vehicle Crash Frequencies in Urban Road Tunnels[J]. Accident, Analysis and Prevention, 2012, 48(1):254-263.

- [14] 何仁, 冯海鹏. 自动紧急制动(AEB)技术的研究与进展[J]. 汽车安全与节能学报, 2019, 10(01):1-15.
- [15] 冯钊. 自动驾驶汽车运行安全性测试评价体系研究[J]. 时代汽车, 2019(08): 19-20.
- [16] Houénou A, Bonnifait P, Cherfaoui V. Risk assessment for Collision Avoidance Systems[C]// 17th International IEEE Conference on Intelligent Transportation Systems (ITSC), Qingdao, 2014, 386-391.
- [17] 赵福全, 吴成明, 潘之杰, 刘卫国, 刘巍. 中国汽车安全技术的现状与展望[J]. 汽车安全与节能学报, 2011, 2(02):111-121.
- [18] Mahmud S M S , Ferreira L, Hoque M S , et al. Application of proximal surrogate indicators for safety evaluation: A review of recent developments and research needs[J]. Iatss Research, 2017, 41:153-163.
- [19] Horst R, Hogema J. Time-to-collision and collision avoidance systems[J]. ICTCT Workshop Salzburg, 1994: 109–121.
- [20] Sayed T, Brown G. Simulation of traffic conflicts at unsignalized intersections with TSC-Sim[J]. Accident Analysis & Prevention, 1994, 26(5):593-607.
- [21] Vogel K. A comparison of headway and time to collision as safety indicators[J]. Accident Analysis & Prevention, 2003, 35(3):427-433.
- [22] Minderhoud M, Bovy P H. Extended time-to-collision measures for road traffic safety assessment[J]. Accident Analysis & Prevention, 2001, 33(1):89-97.
- [23] Kaan O, Hong Y, Bekir B, et al. Derivation and validation of new simulation-based surrogate safety measure[J]. Road Transp Res, 2008, 2083(1):105–113.
- [24] Chan C Y . Defining Safety Performance Measures of Driver-Assistance Systems for Intersection Left-Turn Conflicts[C]// IEEE Intelligent Vehicles Symposium. IEEE, 2006.
- [25] Inoue Y, Ikeda K, Mima H, et al. A collision risk criterion based on imaginary brakes[C]// 2010 IEEE SICE Annual Conference, 2010:1358-1361.
- [26] Chen Y L, Shen K Y, Wang S C, et al. Forward collision warning system considering both time-to-collision and safety braking distance[C]//2013 IEEE Industrial Electronics and Applications, 2013:972-977.
- [27] Eidehall A. Multi-target threat assessment for automotive applications[C]// 2011 IEEE International Conference on Intelligent Transportation Systems, 2011: 433–438.
- [28] Borrelli F, Bemporad A, Morari M. Predictive Control for Linear and Hybrid

- Systems. Cambridge[M]. U.K., Cambridge University Press, 2017.
- [29] Houénou, Adam, Bonnifait, et al. Risk assessment for Collision Avoidance Systems[C]//2014 IEEE Intelligent Transportation Systems (ITSC), 2014:386-391.
- [30] Katrakazas C. Developing an advanced collision risk model for autonomous vehicles[D]. Loughborough University, Loughborough, U.K., 2017.
- [31] Zhao D, Huang X, Peng H, et.al. Accelerated Evaluation of Automated Vehicles in Car-Following Maneuvers[J]. IEEE Transactions on Intelligent Transportation Systems, 2018,19(3):733-744.
- [32] 常宇, 代磊磊. 基于 AHP 的干线公路行车安全评估方法研究[J]. 道路交通科学技术, 2014(2):25-29.
- [33] 卞光宇, 卞佳丽. 车联网环境下道路行车安全性评价系统[EB/OL]. 北京: 中国科技论文在线[2017-12-12]. <http://www.paper.edu.cn/releasepaper/content>.
- [34] 刘瑞, 贺经纬, 朱西产. 基于自然驾驶数据的跟车场景潜在危险估计模型[J]. 东南大学学报(自然科学版), 2019, 49(4):788-795.
- [35] 王笑笑. 基于交通流参数的高速公路安全性风险因素研究[D].扬州: 扬州大学, 2019.
- [36] He X, Xu D, Zhao H, et al. A Human-like Trajectory Planning Method by Learning from Naturalistic Driving Data[C]//2018 IEEE Intelligent Vehicles Symposium (IV), 2018:339-346.
- [37] 张锋, 陈欣星. 自动驾驶车辆的一种改进跟车算法[J]. 长江大学学报(自然科学版), 2019,16(11):126~130.
- [38] 裴晓飞,刘昭度,马国成.汽车主动避撞系统的安全距离模型和目标检测算法[J],汽车安全与节能学报,2012, 3(1):26-33.
- [39] 王晓安,熊坚,李志中.汽车跟车预警仿真及评价研究[J]. 公路,2012(12):98-104.
- [40] Hussein A, Gaber M M, Elyan E, et al. Imitation Learning: A Survey of Learning Methods[J]. ACM Computing Surveys, 2017, 50(2): 1-35.
- [41] Rösener C, Sauerbier J, Zlocki A, et al. A Comprehensive Evaluation Approach for Highly Automated Driving[C]// 25th International Technical Conference on the Enhanced Safety of Vehicles (ESV) Detroit, Michigan USA, 2017.
- [42] 中国汽车工程研究院股份有限公司. 智能行车辅助评价规程[R/OL]. [2019-07-18], <https://www.i-vista.org/upload/智能行车辅助评价规程.pdf>.
- [43] 陈君毅,李如冰,邢星宇,等. 自动驾驶车辆智能性评价研究综述[J].同济大学学报(自然科学版),2019,47(12):1785-1790.
- [44] Olander L P , Gibbs H K , Steininger M, et al. Reference scenarios for deforestation

- and forest degradation in support of REDD: a review of data and methods [J]. *Environmental Research Letters*, 2008,3(2):169-198.
- [45] Dan C, Tyree M, Pierce D, et al. Climate and sea level rise scenarios for California vulnerability and adaptation assessment. a white paper from the California Energy Commission's California Climate Change Center[M]. Sacramento: California Energy Commission, 2012:17.
- [46] Elrofai H, Worm D. Scenario Identification for Validation of Automated Driving Functions[M]. *Advanced Microsystems for Automotive Applications*, 2016:12.
- [47] 新智驾. 实现完全自主无人驾驶仍面临艰难挑战[EB/OL]. [2019-03-17]. <https://www.leiphone.com/news/201712/>.
- [48] 中华人民共和国道路交通安全法实施条例[J]. *新法规月刊*, 2004(6):3-14.
- [49] 刘威, 李建涛. 无人驾驶车辆编队纵向控制器中安全车距与车速分析[J]. *科技风*, 2019(11):211.
- [50] Luo Q. Simulation analysis and study on car-following safety distance model based on braking process of leading vehicle[C]// 2011 9th World Congress on Intelligent Control and Automation, Taipei, 2011:740-743.
- [51] Sebastian R. Python 机器学习[M]. 北京:机械工业出版社, 2017.104-121.
- [52] Friedman J H. Greedy Function Approximation: A Gradient Boosting Machine[J]. *Annals of Statistics*, 2001, 29(5):1189-1232.
- [53] Chen T, Guestrin C. A Scalable Tree Boosting System[C]. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*. Association for Computing Machinery, New York, NY, USA, 785-794.
- [54] David A F. *Statistical Models: Theory and Practice*[M]. Cambridge: U.K.: Cambridge University Press, 2009:26.
- [55] Ho T K. Random decision forests[C]// 1995 IEEE International Conference on Document Analysis and Recognition, 1995:278-282.
- [56] Ke G, Meng Q, Finley T, et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree[C]// 2017 Annual Conference on Neural Information Processing Systems (NIPS), 2017.
- [57] Witten, Ian H, Frank E. *Data mining : practical machine learning tools and techniques*[J]. *acm sigmod record*, 2011, 31(1):76-77.
- [58] 梁军, 陈龙, 蔡英凤, 等. 基于 PreScan 的车辆主动安全技术[M]. 北京:人民交通出版社股份有限公司, 2018:46.

- [59] 赵伊齐, 张引, 申成刚. 基于 Prescan 的智能驾驶辅助系统在环研究[J].汽车实用技术, 2019(09):47-59.
- [60] 胡远志, 吕章洁, 刘西. 基于 PreScan 的 AEB 系统纵向避撞算法及仿真验证[J].汽车安全与节能,2017,8(2):136-142.
- [61] 赵垚森, 朱勇, 徐小东. 基于 Simulink 的汽车 ABS 仿真分析[J].机电工程, 2018,35(12):1357-1360.
- [62] Elrofai H, Daniel W, CAMP O D. Scenario Identification for Validation of Automated Driving Functions[C]// Advanced Microsystems for Automotive Applications 2016. Berlin: Springer, 2016: 153-163.
- [63] 吕章杰. 汽车 AEB 仿真控制算法优化及验证[D].重庆: 重庆理工大学, 2017.

攻读学位期间主要研究成果

一、发表的学术论文

[1] 本人第一作者，导师通讯作者. 八自由度全自动隧道喷浆机器人系统设计, 第十四届中国智能机器人大会优秀论文, 大会论文集收录.

[2] 本人第二作者，导师第一作者. 八自由度全自动隧道喷浆机器人系统设计[J]. 华中科技大学学报(自然科学版), 2020, 48(01): 115-120.

[3] 本人第三作者，导师通讯作者. An Automatic Tunnel Shotcrete Robot[C]. 2019 Chinese Automation Congress (CAC), Hangzhou, China, 2019, pp. 3858-3863.

[4] 本人第三作者，导师通讯作者. Interval Search Genetic Algorithm Based on Trajectory to Solve Inverse Kinematics of Redundant Manipulators and Its Application, 2020 IEEE International Conference on Robotics and Automation (ICRA 2020), 计算机 B 类, 已录用.

二、主持和参与的科研项目

[1] 智能网联汽车安全性测试评价体系研究，2018.3-至今，项目核心成员。

[2] 长沙科达智能装备股份有限公司，校企合作研究项目，隧道全自动喷浆机器人系统设计，2017.8-2018.10，项目主要成员。

[3] 脑肿瘤智能医疗辅助诊断系统设计，2018.5-2018.10，项目组成员。

三、个人获奖情况

[1] 第四届中国“互联网+”大学生创新创业大赛全国总决赛银奖

[2] 2019 年 11 月获得格林美创新实践团队奖

致谢

时光荏苒，三年的研究生涯已经接近尾声。在这个夏天，我将为我的学生时代画上句号，以毕业生的身份走向社会，开启我的人生新篇章。在这里，我想真诚的感谢每一位陪伴我成长的师长和同学们，感谢中南大学。

首先，我要特别感谢我的研究生导师谢斌老师！三年前的一个机缘巧合找到了谢老师，有幸加入了中南大学人工智能与机器人实验室，在刚进实验室的第一天谢老师就跟我详细介绍了整个实验室目前正在做的项目，然后问我对于未来的规划。谢老师非常尊重我们的想法，会考虑我们每个人的规划给我们安排适合的项目，从来没有把自己的想法强加在我们的身上，而是经常鼓励我们独立思考，培养我们的创新思维，全方位的锻炼我们的能力。从研一时做的机器人智能化改造的项目，到现在的智能网联汽车项目，谢老师带给我们的都是行业里面最前沿的方向，并且给我们提供了很好的平台来做这些事情。在我攻读硕士研究生的三年期间，深深受益于谢老师的关心、爱护和谆谆教诲，在此我要对谢老师表示深深的感谢，希望谢老师未来的路越走越好，AIRL团队的影响力越来越大。

同时我还要特别感谢我的师弟吴迪，从我研二的时候带他做本科毕设，到一起解八自由度隧道喷浆机的逆解，再到后来一起做智能网联汽车的项目，我们两一直都捆绑在一起，相互督促、相互鼓励、相互帮助，他的到来深深影响到了我未来的发展，在此祝吴师弟科研顺利，未来发出更多高质量的论文！

感谢实验室的师兄师弟们，我们一起奋战了两年科达的喷浆机项目，一起努力攻克项目难关，感谢我的同门张文婷和林学斌，感谢我的师弟文杰、徐勇、新宇、程清、彭哲、铭蔚、思远，还有我的师兄宋迪、小宇，三年来我们一起做项目、一起参加各种比赛、一起写项目申报书，感谢你们的付出和对我的帮助，祝福你们拥有一个美好的未来！

感谢我的室友王畅、保江和杨焕，三年来我们一起搞比赛、吃瓜、唱跳 Rap 篮球、健身、火锅、聊算法，我们相处的美好时光不会忘记！

感谢同届的同学们，我们一起撕过名牌、玩过狼人杀、去过别墅趴、一起爬过无数次的岳麓山、一起奋战的实习和秋招，感谢你们三年来对我的帮助和鼓励，祝福你们前程似锦，未来一帆风顺！

最后，感谢智能所的各位老师们在研究生期间给我的指导和帮助，谢谢各位老师，衷心的祝愿各位老师工作顺利，身体健康！

2020年4月25日星期六

于广西桂林家中