

第 5 章

基于ETC的超视距感知关键技术研究

随着智能驾驶技术的持续演进,纯车载环境感知逐渐成为制约车辆安全性能提升的瓶颈。由于传感器探测范围有限,单车智能系统难以获知视野盲区的交通状况,面临严重的安全隐患。为突破这一局限,业界日益重视车路协同感知技术。其本质是借助路侧基础设施的感知能力,弥补智能车的视野盲区,实现全方位、远距离的行车环境认知。本章拟聚焦 ETC 系统在车路协同超视距感知中的应用潜力,深度挖掘 ETC 海量数据在前向和后向异常车辆感知中的价值,并系统构建一套面向智能驾驶辅助决策的超视距感知技术框架。

5.1 超视距感知对智能驾驶安全的现实意义

5.1.1 智能驾驶面临的感知盲区挑战

尽管智能驾驶技术不断迭代,但车辆目前仍难以完全避免事故的发生。究其原因,有一大难题是车载传感器难以穿透视觉盲区,无法感知前后方的远距离目标。这使智能车辆在面对前方异常慢速或后方快速来车时常常措手不及,是引发追尾碰撞的重要诱因。以警惕性驾驶(defensive driving)理念为指导,若能提前感知到这些异常目标并及时预警,无疑将大大降低事故风险。

5.1.2 超视距感知的安全效益分析

超视距感知技术正是为解决上述痛点应运而生的。其本质是利用车外信息源获取超出本车视野范围的交通流信息,典型方案包括路侧雷达、路侧视频监控和车车通信(V2V)等。这些超视距信息与本车的感知视野形成互补,可为驾驶决策系统提供前瞻性的环境输入,做到“心中有数”,有效规避视野盲区导致的碰撞风险。

具体来看,超视距感知在如下场景中的安全效益尤为明显:高速公路前向低速目标感知。高速公路由于道路条件较好,车辆普遍时速较高。当偶遇前方异常低速行驶的车辆时,常常因视线受阻、反应时间不足而酿成追尾事故。而通过超视距感知,系统

可提前数百米发现前方的慢速目标,并结合两车位置、速度差等参数评估碰撞风险,进而向驾驶员发出减速或变道的主动提示。

总之,超视距感知通过提供更大跨度的环境感知,打破了传统智能驾驶的视野局限,在动态和复杂的行车环境下为主动避险决策提供了关键输入,对于提升智能网联汽车的安全性和鲁棒性具有不可替代的重要价值。

5.2 ETC 系统助力超视距感知的应用潜力分析

5.2.1 ETC 系统规模与数据价值

ETC 是目前全球规模最大的车路协同系统。以中国为例,高速公路 ETC 门架已超过 5 万个,日均记录上亿条通行数据,覆盖了超过 2 亿的汽车用户。这些海量的门架交易数据蕴藏了丰富的车辆时空轨迹信息,为超视距感知研究提供了理想的数据基础。

5.2.2 基于 ETC 的超视距感知优势

与传统 V2X 等感知方案相比,基于 ETC 的超视距感知思路具有显著优势。

(1) 感知设施建设成本低。依托现有的 ETC 门架系统,无须专门部署路侧感知设备,节约了大量的硬件建设和维护成本。

(2) 通信负载压力小。ETC 门架数据通过有线光纤网络传输,无须耗费无线通信资源,降低了 V2X 频谱资源紧张的问题。

(3) 具备车辆身份解析能力。ETC 交易数据包含车辆的唯一编码(OBU 号/车牌号)信息,可直接与车辆属性数据库关联,解析目标车辆的详细特征。

5.2.3 基于 ETC 超视距感知的应用场景

综合分析 ETC 系统在超视距感知领域的应用潜力,本章重点聚焦于利用 ETC 数据实现以下两类异常车辆的感知。

(1) 前向低速目标感知:通过分析本车前方路段的 ETC 门架数据,推算潜在低速目标的位置和速度,评估其与本车的碰撞风险,实现前向追尾预警。

(2) 后向超速目标感知:通过分析本车后方路段的 ETC 门架数据,识别潜在的超速追尾目标,评估其对本车的危险程度,实现防御性变道决策支持。

下面将针对这两类应用场景,系统阐述 ETC 数据驱动的多维感知建模、特征提

取、异常识别等关键技术。

5.3 ETC 数据驱动的在途车辆多维感知建模

5.3.1 车辆通行速度智能感知模型

为了获取高速公路 ETC 车辆的实时通行速度,需要预处理 ETC 原始交易数据并计算相应路段的通行时间。由于原始数据中只包含交易时间、车辆类型等信息,因此需要结合 ETC 门架经纬度信息进行预处理。首先,构造 ETC 门架 TOPO 结构的邻接矩阵,其中相邻门架间数值为 1,相同门架数值为 0,非相邻门架之间数值为 ∞ 。然后,通过遍历门架邻接矩阵,并根据门架经纬度调用高德地图 API 接口计算相邻门架间距矩阵。最后,通过求各路段的车辆通行时间和门架间距,得出相应区域内车辆平均行驶速度,形成车辆区段行驶速度特征集。

ETC 交易数据虽然未直接包含车速和坐标信息,但蕴藏着车辆位置和速度的深层特征。准确感知超视距目标的状态,需要充分挖掘和融合 ETC 数据中的多维语义信息。为此,本节提出一种基于信息融合理论的车辆速度-位置多维感知模型,其核心是通过时空数据关联与综合推理,实现对目标车辆状态的精准重构。

首先,定义车辆在时间 t_1 和 t_2 通过 ETC 门架 g_1 和 g_2 的数据记录为一个四元组:

$$r = (t_1, g_1, t_2, g_2) \quad (5-1)$$

其中, g_1 和 g_2 可以通过空间坐标或道路拓扑关系映射到实际路段 s_{12} 。将 r 与地图信息融合,就可粗略估计出车辆在该路段的平均速度 \bar{v} :

$$\bar{v} = \frac{\text{dist}(g_1, g_2)}{t_2 - t_1} \quad (5-2)$$

其中, $\text{dist}(\cdot)$ 函数表示门架间的路网距离。

然而,该平均速度估计较为粗糙,尤其是当路段跨度较大或存在服务区等特殊路段时,估计误差难以忽略。为进一步提升估计精度,提出一种改进的车辆速度-位置状态空间模型,模型框架如图 5-1 所示。

该融合估计机制的关键在于引入多层次的空间约束,并通过小波包变换、XGBoost 模型、DR(Dead Reckoning)算法和隐马尔可夫模型(Hidden Markov Model, HMM)实现车辆速度和位置的智能感知。其中:

- (1) 拓扑约束利用 ETC 门架网络的连通关系,限定了车辆运动的空间范围;
- (2) 路段约束进一步细化了车辆所在的具体路段及可能路径;

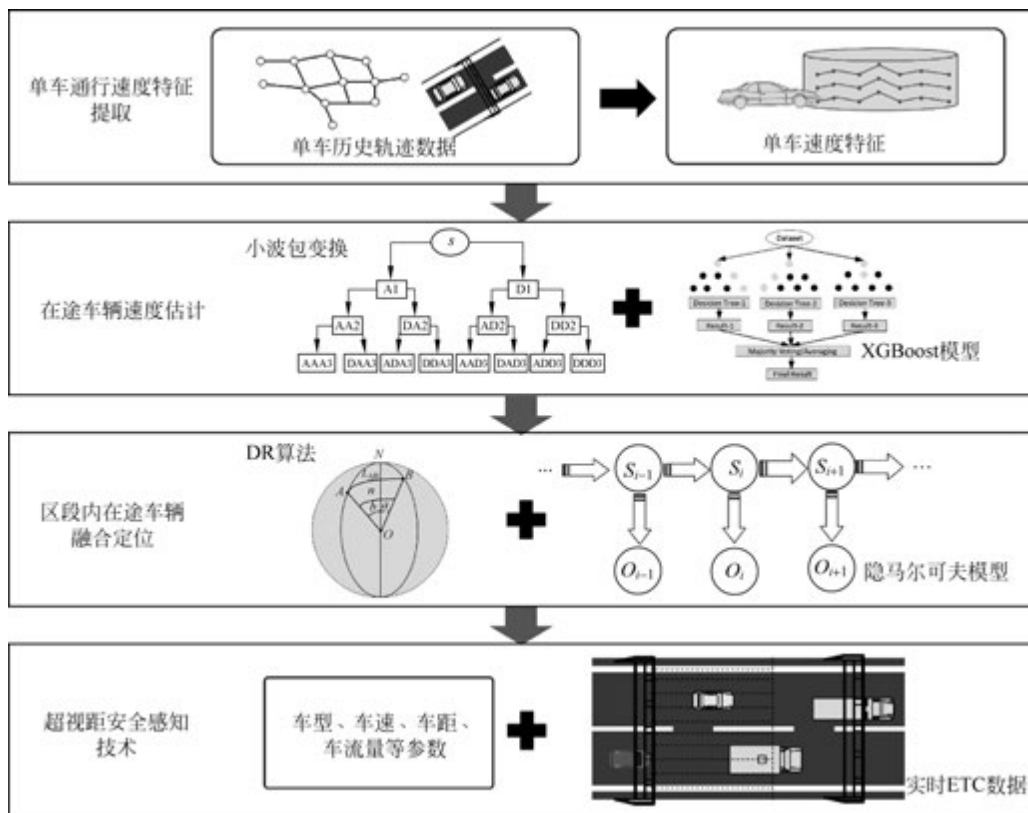


图 5-1 ETC 数据驱动的车辆速度-位置状态融合估计模型框架图

(3) 交通流约束根据车辆所在路段的历史交通流参数分布,初步判断其速度的合理区间。

首先,利用小波包变换对 ETC 原始交易数据进行预处理,提取车辆区段速度特征。然后,将提取的速度特征输入 XGBoost 模型中进行训练和预测,得到在途车辆的实时速度估计值。这些估计值与先验约束信息一起,作为 DR 算法和 HMM 的输入。

在速度估计的基础上,DR 算法根据车辆速度、航向角和行驶时间递推算车辆的位置,而 HMM 则通过建模车辆在不同路段的转移概率,对 DR 算法的估计结果进行修正。每当车辆驶过一个新的 ETC 门架,即产生一个新的观测值,触发模型更新车辆状态的估计。DR 算法和 HMM 的结合,可以有效权衡模型预测和观测校正,最终输出速度和位置的优化估计量。

相比于单纯依赖 ETC 数据的平均速度估计,上述融合机制充分利用了多源异构信息,通过机器学习和概率图模型的方法,减小了路况、驾驶行为等随机因素的影响,大幅提升了速度和位置估计的精确性,为后续超视距感知的异常识别奠定了良好的数据基础。

为验证所提模型的鲁棒性,本实验选取了两个路段,每段包含 3 个区段,进行车速预测实验。其中路段 1 的 3 个区段地势较为平坦,没有明显的上坡和下坡;路段 2 中的区段内存在一定的下坡段。在确定了实验路段后,采用 XGBoost 模型对测试集进行车速预测,通过对预测值与实际值之间的差值进行分析,得出预测模型的最大值、最小方差等性能指标。同时,对比了 LSTM 模型、BiLSTM 模型、Lasso 回归(Least Absolute Shrinkage and Selection Operator Regression)模型、前馈神经网络模型、CNN 模型、GRU 模型、TCNN(Transiently Chaotic Neural Network)模型、RF 模型与 XGBoost 模型的预测性能。路段 1 和路段 2 的预测性能评价结果分别见表 5-1 和表 5-2。

表 5-1 路段 1 车速预测性能评价

选用模型	MAE	RMSE	R2
LSTM	3.478	5.093	0.796
BiLSTM	3.378	4.918	0.809
Lasso 回归模型	3.399	4.555	0.885
前馈神经网络模型	3.338	4.445	0.884
CNN	3.175	4.607	0.833
GRU	3.120	4.815	0.817
TCNN	3.178	4.705	0.826
RF	3.073	4.571	0.835
小波包+XGBoost 模型	2.851	3.872	0.901

表 5-2 路段 2 车速预测性能评价

选用模型	MAE	RMSE	R2
Lasso 回归模型	11.533	18.279	0.563
前馈神经网络模型	10.363	16.264	0.598
GRU	8.814	11.569	0.465
LSTM	7.305	8.956	0.503
RF	7.030	8.069	0.628
BiLSTM	6.280	7.648	0.569
TCNN	6.025	7.373	0.630
CNN	5.495	7.336	0.718
小波包+XGBoost 模型	5.423	7.057	0.801

通过进行针对不同路段的车速预测实验,实验结果显示 XGBoost 模型在路段 1 的车速预测表现良好。在路段 1 中,9 种模型的预测值均相对较高且接近,具体数值分别为 2.851、3.872、3.156、2.976、2.990、3.006、3.027、2.998 以及 3.123。这可以归因于该路段的大多数车辆行驶路况良好且未受到服务区的影响,数据集噪声较小,

因此各模型能够较好地拟合数据。然而,相对于其他8种模型,XGBoost模型在速度发生急剧变化的位置附近的拟合程度更佳,能够更加准确地捕捉到车辆速度的变化。这种表现尤其在路段1中显著,它能够避免错过具有潜在安全威胁的车辆或错误地标识无潜在安全威胁的车辆。

经过对路段2的车速预测实验结果的深入分析,可以得出以下结论。在路段2中,存在下坡路段,这导致车辆速度出现波动。尽管大多数驾驶员会控制车速,但个别激进型驾驶风格的驾驶员可能会超速行驶,从而引入预测速度特征的噪声。因此,其他模型在路段2的预测效果并不理想,而XGBoost模型表现出色。具体来说,通过对比实验中各模型的性能指标,可以发现在路段2的车速预测中,Lasso回归模型、前馈神经网络模型、GRU、LSTM、RF、BiLSTM、TCNN和CNN等模型的表现较为一般。它们的MAE和RMSE值分别较高,表明相对较大的误差存在。例如,Lasso回归模型的MAE和RMSE分别为11.533和18.279。然而,XGBoost模型以及采用小波包变换和XGBoost模型的组合方法在路段2的预测中表现出色。该模型在MAE和RMSE指标上取得了较小的误差,分别为5.423和7.057,显示出更好的准确性。此外,通过 R^2 指标的评估,XGBoost模型也取得了较高的值,达到了0.801,说明该模型能够较好地拟合数据并解释目标变量的变异。

综合实验结果和分析,可以得出结论,采用小波包变换和XGBoost模型的组合方法在路段2的车速预测任务中表现出色。相较于其他模型具有更小的误差值,能够准确预测车辆速度,并且具有较好的拟合能力。这对于高速公路的实际运行环境非常重要,因为路段2可能会受到服务区休息或交通拥堵等因素的影响,导致车辆速度波动。因此,采用XGBoost模型进行车速预测可以通过较少的速度空间序列获得更精确的路段速度预测结果,具有较好的鲁棒性。

5.3.2 前向低速车辆感知算法设计

行驶中遭遇前方低速车辆是引发事故的常见诱因。然而,由于驾驶员视野和注意力的局限,往往难以及时发现远处的低速目标。为此,本节设计了一种基于ETC数据的前向多区间低速车辆感知算法,实现对前方不同纵向区间内的潜在低速目标的主动识别和预警。

算法的基本思路是:以本车当前位置为基准,依据预定的探测距离范围,将前向区域划分为近、中、远3个感知子区间。在每个子区间内,实时获取ETC门架数据,并借助5.3.1节所述的融合估计模型和自适应判决方法,甄别该区间内的异常低速车辆。若3个区间内任一识别为低速目标,即触发相应级别的减速或变道预警。直观

地,探测距离越远,预警的提前量就越充分。算法的主要步骤如表 5-3 所示。

表 5-3 前向低速车辆感知算法

<p>输入:</p> <p>本车状态($p_0(t), v_0(t)$),即 t 时刻的位置和速度</p> <p>ETC 门架网络拓扑关系 $G = \{g_i i = 1, 2, \dots\}$</p> <p>前向探测距离区间 $\{D_1, D_2, D_3\}$,其中 $D_1 < D_2 < D_3$</p> <p>输出:</p> <p>三个感知子区间内的低速目标集合 $\{S_1, S_2, S_3\}$</p> <p>每个低速目标的位置和速度估计值 $\{(p_i(t), v_i(t)) v_i < \eta\}$,其中 η 为低速阈值</p>
<ol style="list-style-type: none"> 1. 根据本车位置 p_0 和探测距离 D_k,确定第 k 个子区间覆盖的 ETC 门架集合 G_k 2. 获取当前时间片内流经 G_k 内门架的 ETC 交易数据 R_k 3. for r_i in R_k : <ol style="list-style-type: none"> (1) 提取 r_i 对应车辆的门架流量子序列 $\{(t_1, g_1), (t_2, g_2), \dots\}$ (2) 利用式(5-1)和式(5-2)估计该车辆在 G_k 内的平均速度 \bar{v}_i (3) 若 \bar{v}_i 小于依据车型和交通流密度自适应生成的低速阈值 η_k : (4) 将该车辆加入低速目标集合 S_k (5) 触发第 k 级别预警 4. 若 $S_1 \cup S_2 \cup S_3 \neq \emptyset$,则输出各低速目标的位置和速度估计值 5. 定期重复步骤 1~4,以滚动更新前向低速目标感知结果

以上算法巧妙利用了 ETC 门架布设的空间序贯特性,通过分区间的增量式计算,既控制了感知的时效性,又兼顾了探测范围的纵深性。尤其是将纵向区间的阈值生成和判决与车型、车流相融合,形成了自适应的分层预警机制,在提升预警精准性的同时,很大程度上降低了“狼来了”式的虚警风险。

5.3.3 车辆融合定位模型

经过估计实时在途车辆的行驶速度后,需要进一步计算所有车辆的位置,以判断车辆是否会威胁到目标服务对象车辆。为此,这里利用门架产生的交易时间 $T_{\text{tradedtime}}$ 、车辆通行时间 Δt_{drive} 、车辆在相应区段的行驶速度和航向角计算车辆的当前位置。然而,DR 算法更多地依赖车辆前后运动状态的变化,将车辆的实际运动状态视为一种匀速直线运动状态,而未考虑车辆的实际运动状态、路况的变化以及车辆定位系统自身的位置偏差。因此,可以采用隐马尔可夫模型来调整由 DR 算法估计的车辆位置,以获得更加精确的经纬度值,从而判断车辆是否会威胁到超视距目标车辆。

值得注意的是,高速公路路网拓扑异常分布也会影响车辆感知的准确性。研究表明,高速公路网络中存在部分日交易量为 0 的异常路段,这些路段主要集中在支线高

速公路上。这些无车辆通行的拓扑路段主要分布在交通量较小的支线上,导致 ETC 数据在这些区域存在“盲点”。例如,在某省份的路网分析中发现有 50 个路段无车辆通行记录,这些静默路段的存在不仅影响 ETC 数据的完整性,也会对基于 ETC 数据的交通分析和感知算法产生偏差。因此,在进行车辆融合定位时,需要特别考虑这些拓扑异常区域的影响,采取适当的数据补偿和算法调整策略。

在前文已知 DR 算法在面对车辆实际运动状态、路况的变化以及车辆定位系统自身的位置偏差等因素影响下存在一定的缺陷。因此,本节采用融合 DR 算法和 HMM 的方法,来调整由 DR 算法估计的车辆位置,从而获得更加精确的经纬度值,提高车辆定位的准确性和可靠性。其位置可表示为

$$\begin{cases} x_k = x_{k-1} + s_i \cos\theta_i \\ y_k = y_{k-1} + s_i \sin\theta_i \end{cases} \quad (5-3)$$

如图 5-2 所示,当前区段的门架位置为车辆初始位置 (x_0, y_0) ,计算当前区段前后门架的方向角作为车辆航向角 θ_i 。门架组成的方向角在同一区段内保持不变,因此任意时刻 θ_i 均相等;其次,根据车辆所在区段的通行时间和车速,计算出车辆行驶里程 s_i ;最后,结合车辆初始位置、航向角和行驶里程,计算出潜在位置 (x_k, y_k) 值。




图 5-2 高速公路车辆潜在位置估计示意图

DR 算法存在着一些缺点,其中之一是从原位置推导出新位置的准确性不高。此外,在计算过程中会对误差进行累加,随着时间的推移可能会导致错误率增加。为了进行车辆潜在位置估计,本节假定高速公路路段为较直的理想状态,并且认为车辆前、后车架构成的方向角即车辆的航向角。然而实际高速公路路段存在一定程度的弯曲和曲率,与理想状态存在一定差异。这种差异会导致 DR 算法计算的车辆潜在位置与实际车辆位置之间存在一定偏差。

为了实现车辆位置的精确定位,算法采用 HMM 对车辆位置数据 $Lng_{Vehicle}$ 和 $Lat_{Vehicle}$ 进行位置校正。首先对候选路段进行筛选,将候选路段视为隐藏在马尔可夫链中的状态,计算相应的观测代价,观察当前路径是否与候选路段相匹配,如果当前路

径距离候选路段较近,则选择合适的路段;然后计算隐藏状态边在马尔可夫链上的转移代价;再后给出了观测代价最小、转移代价最小的马尔可夫链路;最后利用 Viterbi 算法求解道路结构网,即采用动态规划法快速寻找最接近实际路径和最小总成本的路径。

Viterbi 算法被广泛应用于寻找最佳隐藏状态序列,以匹配观测序列。在对车辆位置数据进行校正时,Viterbi 算法可以考虑多种因素的影响,同时计算多条路径的成本,以找出车辆实际行驶路线总成本最小的路径,算法示意图如图 5-3 所示。这种方法可以提高路径计算的准确性和效率。




图 5-3 Viterbi 算法的路网匹配示意图

为了实现 Viterbi 算法,通常需要对局部状态进行计算,并给出其递推公式。在 HMM 中,首先给出了两个用于递推的局部状态。

对于第一个局部状态,所有可能隐藏状态之间转移路径 $\{i_1, i_2, \dots, i_t\}$ 中的概率最大概率 γ_t 和 γ_{t+1} 可由式(5-3)和式(5-4)分别计算得出:

$$\gamma_t(i) = \max_{i_1, i_2, \dots, i_{t-1}} P(i_1, i_2, \dots, i_t = i, O_1, O_2, \dots, O_t |), \quad i = 1, 2, \dots, N \quad (5-4)$$

$$\gamma_{t+1}(j) = \max_{1 \leq i \leq N} [\gamma_t(i) \cdot a_{ji}] b_j(O_{t+1}) \quad (5-5)$$

第二个局部状态可用递推公式计算,如当前时间 t 时刻,所有相互独立状态间转换路径 $\{i_1, i_2, \dots, i_t\}$ 中具有最大转换概率有 $t-1$ 时刻的隐藏状态 $\psi(i)$, 计算公式如下:

$$\psi_t(i) = \operatorname{argmax}_{1 \leq j \leq N} [\gamma_{t-1}(j) \cdot a_{ji}] \quad (5-6)$$

根据式(5-3)和式(5-5),可以根据出发时间找出隐藏状态,然后沿返回方向查找前序状态,直至可以解释为隐藏状态序列。

车辆融合定位算法的实现过程涉及多种技术和方法。首先,通过小波包变换和 XGBoost 算法对区段内车速进行估计,结合高速公路区段前后门架坐标和车辆构成


的航向角,确定车辆进入当前区段时与门架交易的时间和当前时间,从而计算出车辆通过该区段的时间。然后,利用DR算法根据车辆的航向角、车速、行驶时间等信息,推算出车辆在该区段内的潜在位置。接下来,利用HMM对DR算法估计的车辆位置进行校正,通过计算车辆从潜在位置到候选路段的概率和车辆上一时刻位置到当前位置之间的转移概率乘积,确定车辆的候选轨迹。最后,利用Viterbi算法求解车辆的最优轨迹,以获取最接近车辆实际行驶路线总成本最小的路径。车辆融合定位算法实现见表5-4。

表5-4 车辆融合定位算法


输入: 在途车辆速度 $[v_1, v_2, \dots, v_n]$,已通行时间 $[t_1, t_2, \dots, t_n]$,车辆前后门架位置 $P[\text{lat}, \text{lng}]$; 输出: 当前车辆位置 P_{now} ;
<pre> 1. 已知 car1……carn 的车辆位置 P[] 2. 已知 car1……carn 的通行速度 V[] 3. //已知两门架与车辆构成的方向角 4. FOR car IN Car[]: 5. car.position //获取车辆时间点位置 6. V = car.speed //获取车辆的行车速度 7. angle = courseAngle(lngA, latA, lngB, latB) //根据前后门架坐标推算车辆的航向角 8. P₁ = DR(angle, V, angle) //使用 DR 算法获取当前车辆潜在位置 P₁ 9. P.append(P₁) 10. END FOR 11. rspl = getRoadSegmentInfo() //构建路段信息 12. connected_graph = getNetworkGraph() //构建图 13. candidate_segments = searchCandidateRoadSegment() //搜索候选路段及先验概率 14. net_trans_prob, subpath, path_node = getNetworkTransProbability() //计算 prev_ //candidate_segments 到 segment_id 的最大转移概率 15. acquire.max_prob = candidate_segments[segment_id] * max_trans_prob //将各路段 //先验概率和最大转移概率之积的节点作为候选轨迹 16. FOR id IN path_node: 17. Viterbi(id) //使用 Viterbi 算法进行求解 18. optimal_path.append(id) 19. END FOR 20. Return optimal_path </pre>

为了评估DR算法和融合定位模型的定位精度,本节对两种方法进行了误差统计,并在图5-4中展示了统计结果。DR算法估计的车辆位置与实际位置之间的误差在10~100m。由于实验选取了一段具有小幅度弯道的路段,DR算法假设车辆处于匀速直线运动状态,因此在弯道路段进行试验时,实际车辆状态与算法假设存在一定偏差,导致计算结果与实际结果有较大偏差。在接近直线路段的定位试验中,车辆状

态与实际车辆状态基本一致,计算结果与实际情况基本一致,且误差较小。融合定位模型定位误差在 5~50m。基于 DR 算法的融合定位模型可以对车辆的潜在位置进行校正。虽然高速公路路网相对简单,能够较准确地将漂移出路网外的轨迹进行校正,但由于实际道路存在一定弯道,因此该模型得出的车辆位置与实际车辆位置之间可能存在误差。为了尽可能减小误差,该模型会计算由观测点至周边路段的观测代价和转移代价最小的点作为可能的真实轨迹。这种方法能够接近于在周边路段投影出路网外点,但误差仍然存在。



(a) DR算法定位误差图



(b) DR+HMM算法定位误差图

图 5-4 定位误差分析图

5.4 基于ETC的异常车辆感知技术

为了准确评估高速公路上车辆的行驶环境,本节分析了不同车速和车距条件下目标服务车辆与异常车辆的潜在交会时间,以及高速公路路段特征对超视距识别的影响。在获得车辆速度和位置信息后,结合实时交通状况来合理选择异常车辆的识别区域范围。根据研究结论,可以根据实际需求对异常车辆进行识别,并划定异常区域,以提高识别效率。

5.4.1 车辆潜在交会时间分析

根据车辆运动状态的特点,本节将目标服务对象车辆及其识别区域内的异常车辆视为追逐运动。针对不同的车速和车距条件,研究分析了后方车辆需要追上前方车辆所需的时间,并以此为基础划分了超视距识别区域。通过对东南某省高速公路某路段车速的研究,结果显示客车的最高速度可达154km/h,而该路段全天平均速度仅为100km/h,两者之间的速度差为54km/h。因此,将最大速度差设置为60km/h,并计算了不同速度和车距组合下的追逐时间。如表5-5所示,当速度差为60km/h时,在距离为4~6km时,后方车辆需要4~6min才能追上前面的车辆;而在距离为2~4km时,只需2~4min车程;当距离不到2km时,不到2min就能追上。当速度差为40km/h时,在距离为4~6km时,后方车辆需要6~9min才能赶上前面的车辆;在距离为2~4km时,只需3~6min;当距离不到2km时,不到3min就能追上。当速度差为20km/h时,在每个车距下的追逐时间分别为12~18min、6~12min和6min。当速度差为10km/h时,在每辆车之间的追逐时间为24~36min、12~24min和12min。这些结果可为确定超视距识别区域提供参考。

表 5-5 车辆潜在交会时间表

最大车速差(km/h)	车距(km)	追赶时间(min)
60	6	6
	4	4
	2	2
40	6	9
	4	6
	2	3
20	6	18
	4	12
	2	6

续表

最大车速差(km/h)	车距(km)	追赶时间(min)
10	6	36
	4	24
	2	12

为避免过早或过晚识别异常车辆所带来的不良后果,划定异常车辆识别区时需要考虑目标服务对象车辆与异常车辆可能相交的时间。如果异常车辆被过早预警,将影响驾驶员的正常驾驶;相反,过晚预警则会导致无法及时采取合理措施而增加事故发生的风险。综合考虑车辆运动状态、超视距识别条件等多种因素,以确定合适的识别时机和范围,可以提高驾驶安全性和交通效率,并划定出适当的异常车辆识别区。

5.4.2 车流量维度下的速度特征分析

车流量对车辆行驶环境具有重要影响,包括目标服务对象车辆遇到异常车辆时的操作空间以及高速公路整体车速的大小等方面。因此,本节中采用了车辆流量作为研究维度,并绘制了速度箱线图,如图 5-5 所示。同时,还分析了不同时间段各路段的通行速度。

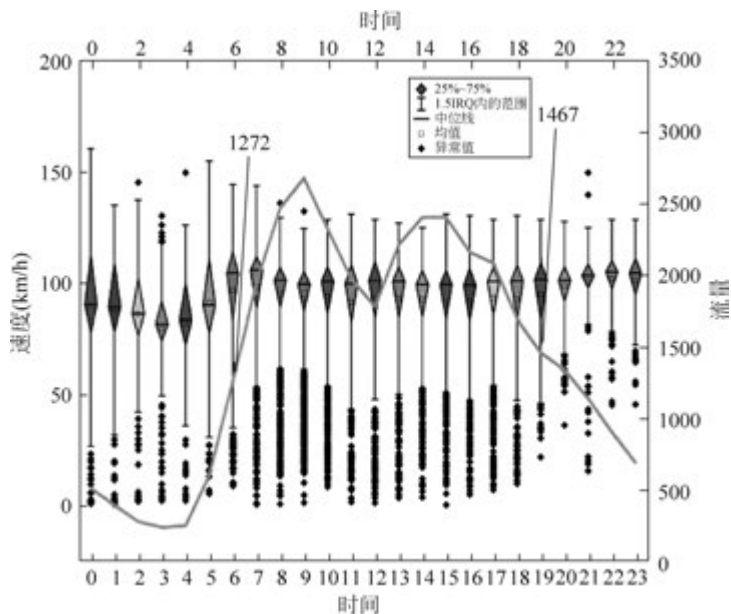


图 5-5 区段 1 车流量-速度特征图

根据图 5-5 可知,当车辆流量超过 1272 辆/h 时,该区段的非正常车辆数量显著增加,其主要原因是因为车速过慢。随着车流量从最大值 1467 辆/h 下降,异常车辆

逐渐减少。当车辆流量小于 90 辆/h 时,由于低速引起的异常车辆在区段内几乎可以忽略,但此时超速异常车辆较多;当车辆流量超过 900 辆/h 时,异常低速车辆出现增多,而异常超速车辆则减少至 0。综合考虑图 5-5 和图 5-6,发现在车辆流量小于 900 辆/h 的情况下,存在大量超速异常车辆;而在车辆流量高于 1325 辆/h 时,则出现了低速异常车辆。因此,车辆流量对车辆速度具有影响,通过观察异常车辆数量的变化可以推断不同路段的交通状况。同时,本实验采用车辆流量维度下的速度箱线图,分析了各路段分时段的通行速度。




图 5-6 区段 2 速度车流量-速度特征图

针对车辆流量对车速的影响,本算法将车辆流量分为 3 个不同状态:畅通状态、趋于饱和状态和过饱和状态,并相应调整了识别区域。具体而言,本文采用 1370 辆/h 作为过饱和状态的下限值,即当车辆流量超过 1370 辆/h 时,判定为过饱和状态;900 辆/h 作为趋于饱和状态的下限值,即当车辆流量在 $[900, 1370]$ 辆/h 时,判定为趋于饱和状态;当车辆流量小于 900 辆/h 时,路段处于畅通状态。

在超视距低速车辆识别区内,当车辆流量小于 900 辆/h 时,超视距车速受到的交通流量限制较小,与低速车辆之间的距离加速缩短。为提前感知由于交通空间分布的非规律性,导致当前路段流量正常,前方路段流量饱和,应在相同条件下将识别区上调一级。

当车辆流量超过 1370 辆/h 时,路段交通流量达到过饱和状态,超视距速度受到限制,与低速车辆之间的距离也会缩短。在此时,目标服务对象车辆的操作空间就越

小,因此应集中精力于较近的车辆,扩大识别区只会分散驾驶员的注意力。此时应适当地将识别区降低一个级别。

当车辆流量维持在 900 到 1370 辆/h 之间时,该段车流量处于趋于饱和的状态,兼顾了畅通与过饱和的行车特征。在这种情况下,识别区应取中间值。针对超视距超速车辆的识别,应根据不同的车流条件采取不同的识别区调整策略。当车辆流量小于 900 辆/h 时,由于车辆速度受交通流量的限制较小,会有更多的超速车辆出现,因此可以在相同条件下降低识别区的大小,以减少计算时延。当车辆流量超过 1370 辆/h 时,由于交通流量饱和,超速车辆大幅减少,此时也可以在相同条件下降低识别区的大小。在车辆流量介于 900 和 1370 辆/h 之间时,该路段处于趋于饱和状态,因此识别区的大小应取中间值。

5.4.3 车辆类型特征分析

在实际道路上,由于车辆的速度和性能存在差异,不同类型的车辆所造成的事故风险也不同。因此,在同一路段内,不同类型车辆所占比例对超视距行车环境有一定影响。然而,通过研究发现,无论各区段车流量是否饱和,不同类型车辆在各区段间的占比相近。因此,在识别超视距异常车辆时,可以忽略不同车辆类型分布比例的影响,并认为各区段间各类型车辆分布比例相似。

通过对东南某省高速公路某段一天内各类车辆的通行速度进行分析(见表 5-6)可知,一类车辆的 25%分位速度为 105km/h,85%分位速度为 118km/h;二类车辆的 30%分位速度为 91km/h,90%分位速度为 96km/h;三类车辆的 30%分位速度和 90%分位速度分别为 77km/h 和 94km/h。在一类车辆中,25%分位速度是 85%分位速度的 89%,速度差为 13km/h;而第二类和第三类车辆的 30%速度分别是 90%速度的 95%和 82%,速度差分别为 5km/h 和 17km/h。根据百分位限速规则,可以确定各类车辆的低速临界速度。一类车辆中,低于同类车正常速度上限 11%的车辆被定义为低速车辆;二类车辆中,低于同类车正常速度上限 5%的车辆被定义为低速车辆;三类车辆中,低于同类车正常速度上限 18%的车辆被定义为低速车辆。

表 5-6 各类车速度统计分析表

目标服务对象 车辆类型	25%/30%分位 车速(km/h)	85%/90%分位 车速(km/h)	速度差值 (km/h)	低速临界值与正常 车速上限值差幅
一类车	105	118	13	11%
二类车	91	96	5	5%
三类车	77	94	17	18%

根据图 5-7 所示,不同类型车辆的平均通行速度存在差异。其中一类车的平均通行速度大于二类车,两者之间的速度差异约为 18%。在超视距低速异常车辆的识别过程中,二类车识别出的异常车辆数相比一类车较少。由于二类车行驶速度较慢,与低速异常车辆的速度差距也较小,在 4~6km 的车距下,二类车可能需要超过 25min 才能追上前方低速异常车辆。因此,对于二类车来说,4km 以上的识别区域并不是很实用。相比之下,一类车速度更快,机械性能也更好,因此在 4-6km 的车距下,一类车可能只需要 5min 就能追上前方车辆。因此,相对于二类车,一类车的识别范围应更广一些。由于三类车的速度最慢,驾驶性能也不如一二类车,因此对于超过 4km 的识别区,对于三类车来说并没有意义。在 2km 左右的识别区,对于三类车来说较为合适。但是为了更好地感知路段流量的变化,可以适当将识别区扩大到 4km。




图 5-7 分类后各类车速度统计图

5.4.4 异常车辆识别区的划分

在超视距低速车辆识别过程中,不同类型车辆的速度差异会影响识别区的划分。一类车速度较快,与低速车辆速度差距较大,因此可在 2km、4km 和 6km 范围内进行选择。相比之下,二类车速度较慢,与低速车辆速度差距不大,因此若识别区太大,提前预警的效果会受限。对于速度最慢的三类车,扩大识别区可有助于感知路段的空间变化。因此,在 2~4km 的范围内进行选择较为合适。

在超视距超速车辆识别过程中,目标服务对象车辆位于超速车辆前方,在追尾运动过程中处于被动状态,后方超速车辆起着决定性作用。因此,在识别区划分时,应根据车辆流量、速度和异常车辆数量等因素选择合适的识别区,而不是考虑车辆类型的

影响。

综合考虑潜在交会时间、车流量、车速特征和车辆类型特征等因素,可以得出了不同行驶环境下车辆在遇到异常车辆时所面临的时空特征,并由此得出各类车辆的异常识别区划分范围,如表 5-7 和表 5-8 所示。

表 5-7 低速异常车辆识别区范围

目标服务对象 车辆类型	超视距车所在 路段车流量	操作空间	车距变化	低速识别区 范围(km)
一类车	$1370 \leq \text{flow}$	小	慢	2
	$900 < \text{flow} < 1370$	中	中	4
	$\text{flow} \leq 900$	大	快	6
二类车	$1370 \leq \text{flow}$	小	慢	2
	$900 < \text{flow} < 1370$	中	中	4
	$\text{flow} \leq 900$	中	中	4
三类车	$1370 \leq \text{flow}$	小	慢	2
	$900 < \text{flow} < 1370$	小	慢	2
	$\text{flow} \leq 900$	中	中	4

表 5-8 超速异常车辆识别区

目标服务对象车辆 所在路段车流量	操作空间	车距变化	异常车辆数	超速识别区 范围(km)
$1370 \leq \text{flow}$	小	慢	少	6
$900 < \text{flow} < 1370$	中	中	中	4
$\text{flow} \leq 900$	大	快	多	2

5.4.5 异常车辆判别方法

目标服务对象车辆包括前方相对低速和后方相对超速两种情况,对目标服务对象车辆的驾驶安全影响较大。由于车辆行驶状态具有不确定性和动态性,因此需要结合车辆历史驾驶行为安全性评价结果来判断是否为异常车辆。在本节中,利用车辆历史驾驶行为安全性评价结果作为影响因素,并通过对车速、车距、实时车流量等因素的分析进行修正。首先,在识别异常车辆的识别区基础上,获取该区域内车辆的速度、位置和类型,并结合实时路段的车流量,初步评估异常车辆的危险性。其次,采用驾驶行为安全性评价方法,根据异常车辆历史行驶特性,对其安全性进行评估,得出车辆安全性评价结果。最后,利用安全评价结果对基于车速、车距、车辆类型、实时交通流的判断结果进行修正,以确定是否为异常车辆,如式(5-7)所示。

$$\begin{cases} \gamma_1 \left(\frac{V_{OTH} - V_{LS}}{V_{OTH}} \right) + \lambda_1 f(s) + \kappa_1 f(V_{OTH}, V_{LS}, \eta) \\ \gamma_2 \left(\frac{V_{OTH} - V_{HS}}{V_{HS}} \right) + \lambda_2 f(x) + \kappa_2 f(V_{OTH}, V_{HS}, \tau) \end{cases} \quad (5-7)$$

式(5-7)中, $\lambda_i (i=1, 2, 3)$ 为加权因子, V_{OTH} 为目标服务对象车辆车速, V_{LS} 为低速异常车辆车速, V_{HS} 为超速异常车辆车速, s 为目标服务对象车辆与低速车的车距, f 为路段实时车流量, η 为驾驶行为隶属度, τ 为车辆驾驶行为安全性评价结果。

为了实现目标服务对象车辆的安全预警, 异常车辆识别算法首先获取异常车辆识别区域内所有车辆, 并根据车辆流量、车辆类型、车速差异等因素初步判断哪些车辆相对于目标服务对象车辆不正常。接着, 采用驾驶行为安全性评价方法对初步异常车辆进行安全性评价, 获取车辆的驾驶行为隶属度和安全性评价结果。然后, 根据异常车辆识别方法, 将初步判断结果与驾驶行为隶属度、驾驶行为安全性评价结果相结合, 进一步对异常判断结果进行修正。最后, 将目标服务对象车辆的速度、与目标服务对象车辆的距离等相关信息传递给目标服务对象车辆, 从而实现超视距安全预警。

异常车辆识别算法见表 5-9, 该算法在基于融合定位模型的基础上, 利用车辆当前车速、区段流量、区段总速度、区段目标服务对象车辆类型以及区段地形特征等因素, 划分出不同范围的潜在安全威胁车辆识别区。通过识别不同行驶环境下存在潜在安全威胁的车辆, 从而实现对视距范围外行驶车辆的安全预警。

表 5-9 异常车辆识别算法

输入: 在途的全部车辆 car[]; 输出: 异常车辆识别。
<ol style="list-style-type: none"> 1. 已知 car₁...car_n 的位置 P_{car} [] 2. 已知 BSD 的值 (如 2km) 3. 已知时延 T_{delay} 的值, 分别可求出各车的时延距离 D_{delay} [] 4. BSD_{car} [] = BSD - D_{delay} [] //更新后针对 car[] 的每一辆车的安全距离 5. AbnormalInfo [] = AbnormalIdentification(car[], BSD_{car} []) //进行异常车辆识别, 返回异常 //常预警信息 6. FOR EACH t_i IN AbnormalInfo [] 7. car = t_i.getCar //获取需要预警的车辆 8. alertInfo = t_i.getAlertInfo //获取预警的信息 9. SendAlertInfoToCar(car, alertInfo) //向车辆发送预警信息 10. END FOR 11. Def AbnormalIdentification(car[], BSD_{car} []) { //威胁车辆识别 12. AbnormalInfo //威胁车辆列表 13. FOR EACH car IN car [] 14. bsdCars [] = getEachCarBSD(car, BSD_{car} []) //获得目标服务对象车辆安全距离内的所有车辆

```
15. T1 = validSpeed(bsdCars[]) //验证速度是否异常
16. T2 = validVehicleType(bsdCars[]) //验证车辆类型威胁
17. IF exist(T1) OR exist(T2) THEN
18. AbnormalInfo.add(car,makeAlertInfo(T1,T2))
19. END IF
20. END FOR
21. RETURN AbnormalInfo
```

5.5 基于 ETC 的异常车辆感知实验分析

为了验证估计的结果,实验通过 ETC 仿真平台对泉厦路段的实时交易数据进行模拟。原始交易数据包括车辆编号、交易时间、门架经纬度等多项信息。实验路段为泉州至厦门段。

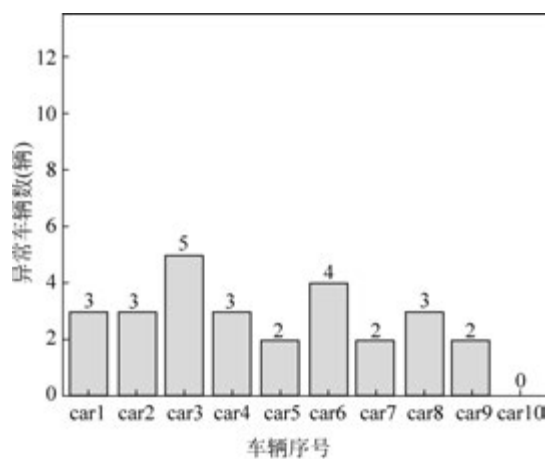
门架节点距离数据来源于高德地图,Distance 为各个门架节点之间的距离。

5.5.1 异常车辆判别方法实验分析


为了更好地评估识别效果,根据高速公路上不同类型车辆所占比例,本节将车辆分为 3 个类别。具体而言,car₁、car₂、car₃ 被归为一类车辆,代表小汽车; car₄ 和 car₅ 被归为二类车辆,代表客车; car₈、car₉、car₁₀ 被归为三类车辆,代表货车。这些车辆类型的配比为 5 : 2 : 3。在仿真平台中,将这些车辆类型比例作为输入,并结合交通流的多线程调度算法,对所有车辆进行了在途独立线程的运行模拟,以更好地检测和评估识别效果。

为了验证算法的识别效果,本节对仿真结果进行了静态和动态分析。随着异常车辆识别区域的扩大,识别出的异常车辆数也会相应增加或保持不变。

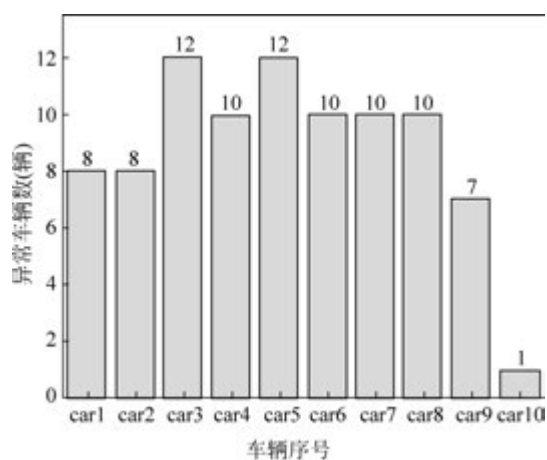
通过分析图 5-8,发现在不同识别区范围内,各类车的平均异常车辆数存在差异。当识别区为 2km 时,各类车异常车辆识别区内的异常车辆数平均值,分别为一类车 3.2 辆,二类车 3 辆,三类车 1.67 辆;当识别区为 4km 时,分别为 7 辆、6.5 辆、4.33 辆;当识别区为 6km 时,分别为 10 辆、10 辆、6 辆。其中,三类车平均识别数最小,一类车平均识别数最大,二类车平均识别数处于中间位置。



(a) 2km静态实验图



(b) 4km静态实验图



(c) 6km静态实验图


图 5-8 静态异常车辆识别

可见,超视距异常车辆识别过程中,不仅路段车流量对识别结果产生影响,车辆类型也是至关重要的因素。因此,合理考虑车流量和车辆类型作为识别区划分的因素具有实际意义。此外,车辆速度也会受到区段交通流的影响,因此也应将其作为一个影响因素加以考虑。


为了验证目标服务对象车辆异常车辆识别区内的异常车辆会不断被超越或超过目标服务对象车辆的假设,并探究随时间推移异常车辆数量的变化,进行了异常车辆识别动态实验。从图 5-9 中可知,当车辆进入当前路段时,识别区范围设为 2km,此时并未检测到异常车辆。但随着时间推移,识别区内不断有新车辆进入,异常车辆数量并不会随时间减少,反而会增加。当将识别区范围扩大至 4km 和 6km 时,异常车辆数量分别为 8 和 10,显著增加。需要注意的是,车流量的分布不均可能会导致识别区内的异常车辆数量激增。例如,在该实验中,当 car_{10} 在 7:50 进入当前路段,车流量逐渐接近饱和区域,导致识别区内异常车辆数量急剧增加。因此,建议将识别区范围调大一级,以感知路段交通态势的变化,并为驾驶员合理规划车速提供参考。无论出现拥堵或事故,提前感知路况变化对驾驶员的行车安全都具有重要影响。

另外,从 car_7 的实验结果可以得出,在此路段行驶了 40min 后进入了较为拥堵的区域,此时识别区内的异常车辆数量急剧增加。当识别区范围为 6km 时,识别区内车辆数量为 17 辆;4km 时为 10 辆,2km 时为 8 辆。考虑到实际情况,当车辆自身处于拥堵区域时,导致交通事故的主要原因是前方车辆突然刹车或紧急变道引起的追尾与刮擦,而非因为感知不到视距范围外的车辆导致的追尾。因此,在这种情况下,更应关注近距离的交通状况,过大范围的识别区域是没有意义的,而且可能干扰驾驶员对当前环境的判断。因此,将识别区范围设为 2km 是比较合理的选择。


综上所述,当目标服务对象车辆所在区域的交通流未达到饱和状态时,可以将识别区在相同情况下调大一级,以提前感知道路交通态势的变化。而当目标服务对象车辆进入交通拥堵区域时,应将识别区在相同情况下调小一级,更加关注近距离的交通状况。考虑到车辆在实验路段的不同时段进入,其行车环境存在显著差异,因此简单地比较同一时刻识别区内的异常车辆数无实际意义。相反,应以平均值为基础进行分析。从不同类别车辆在 7 个时间节点上,平均每个时间节点识别区内的异常车辆数量的角度来看,图 5-9 结果表明当识别区分别为 2km、4km、6km 时,异常车辆数的最大值分别为 2.86、4.38、10.86,均出现在一类车中;中位数为 2.71、5.86、8.71,均出现在二类车中。这也符合实际高速公路的行车情况,其中一类车速度最快,二类车速度次之,三类车速度最慢,这导致异常车辆数量存在相应规律。因此,本研究的识别结果符合实际行车规律,验证了本方法的有效性。



(a) 2km识别区实验图



(b) 4km识别区实验图



(c) 6km识别区实验图



彩图

图 5-9 超视距识别异常车辆图

为了在安全距离维度上精准捕获高速公路异常车辆的变化特性以实现车辆速度规律的精确拟合,本实验特别针对二类车(客车)和三类车(货车)的仿真数据进行了统计分析,以不同的安全距离为基准。分析结果如图 5-10 所示,客车和货车周围异常车辆的安全距离总体呈增长曲线。随着安全距离的增加,异常车辆的数量也不同程度地增加,这符合高速公路车辆行驶的客观规律。




图 5-10 不同安全距离的异常车辆分布

通过对基于超视距异常车辆识别实验结果及 ETC 仿真平台生成的仿真实验数据的验证,本节对识别出的低速异常车辆进行了评估。在静态实验中,以 car_1 为例,当识别区为 2km 时,通过对低速异常车辆与目标服务对象车辆的车距、车速百分比进行验证,结果如表 5-10 所示。可以发现,识别出的 3 辆低速异常车辆与目标服务对象车辆的估计车距分别为 1.32km、0.98km、0.65km;估计车速与目标服务对象车速的百分比分别为 85%、70%、72%。通过对比车距及车速百分比的数据,可以发现低速异常车辆的位置在 car_1 的潜在安全威胁识别区内,且车速百分比符合超视距一类车对低速异常车速的要求。因此,在该实验中, car_1 识别出的低速异常车辆均被正确识别。

表 5-10 识别区为 2km 的静态实验识别结果

异常车辆	估计车距/(km)	实际车距/(km)	估计车速与超视距车速百分比(%)	实际车速与超视距车速百分比(%)
异常车辆 1	1.32	1.29	85	86
异常车辆 2	0.98	0.94	70	72
异常车辆 3	0.65	0.60	72	74

经过 car_9 的 4km 识别区静态实验的验证,结果如表 5-11 所示。在识别出的异常车辆均在识别区范围内,从车距维度上看不存在误识别。但是,从车速维度上看,异常

车辆5的估计车速与目标服务对象车速的百分比为82%，而实际车速与目标服务对象车速百分比为88%，未满足超视距三类车对异常车速的要求。

表 5-11 识别区为 4km 的静态实验识别结果

异常车辆	估计车距(km)	实际车距(km)	估计车速与超视距车速百分比(%)	实际车速与超视距车速百分比(%)
异常车辆 1	2.56	2.55	78	80
异常车辆 2	3.53	3.50	70	72
异常车辆 3	3.41	3.40	75	74
异常车辆 4	1.38	1.38	80	81
异常车辆 5	0.95	0.94	82	88
异常车辆 6	3.82	3.78	69	73
异常车辆 7	3.05	3.03	68	69

综合考虑 XGBoost 速度估计模型和车辆融合定位模型的实验结果,可以得出以下主要原因:①XGBoost 速度估计模型能够较为准确地估计车辆速度,并且估计出的车速与实际车速存在负偏差,即估计车速稍小于实际车速。这也使得本方法在对异常车速判别时,能够减少漏判。②车辆融合定位模型能够较为准确地估算车辆位置。虽然估算出的车辆位置与实际位置存在一定的偏差,但其平均偏差只占 2km 识别区范围的 1%左右。当识别扩大时,甚至能降低到 0.5%以内。因此,这也减少了本方法在车距维度上的误判,保证了本方法在不同类型车辆与识别区组合下的鲁棒性。

然而,由于单车的识别结果分析存在一定的偶然性,需要分别统计静态实验和动态实验的整体识别正确率,并使用识别准确率和召回率来进一步验证本方法的有效性。计算公式如式(5-8)和式(5-9)所示。

$$A = \frac{T_{r_ac}}{T_R} \quad (5-8)$$

$$R = \frac{T_{r_ac}}{T_{ac}} \quad (5-9)$$

式中, T_{r_ac} 为本方法识别出的异常车辆中实际的异常车辆数, T_R 为本方法识别出的异常车辆总数, T_{ac} 为实际驾驶环境中存在的异常车辆总数。

如表 5-12 所示,在不同的识别区和车辆类型组合环境下,静态实验中存在 180 辆异常车辆。本方法识别出了 176 辆异常车辆,其中有 171 辆车实际存在异常,识别准确率为 97.1%,召回率为 95%。在动态实验中,各种识别区与车辆类型组合的不同环境下,实际存在异常车辆总数为 1006 辆,本方法识别出的异常总数为 980 辆,其中实际存在异常的车辆数为 963 辆,识别准确率达 98.3%,召回率为 95.7%。

表 5-12 识别结果正确率统计表

实验类别	实际总数	本方法识别总数	本方法识别实际数	准确率	召回率
静态实验	180	176	171	97.1%	95%
动态实验	1006	980	963	98.3%	95.7%

5.5.2 响应时延性能分析

综上所述,本章提出了一种能够较为准确地识别存在异常车辆的高速公路超视距异常车辆识别方法,并进行了验证实验。实验使用了基于 ETC 仿真平台生成的实时仿真交易数据。ETC 数据仅记录车辆节点的通行时间、车辆唯一标识符和车辆类型等信息。因此,需要对 ETC 数据进行深入挖掘,以获取车辆的通行速度和位置信息。在实际情况中,获取在途车辆的通行速度和位置信息需要一定的计算时间,即使用本方法进行超视距感知检测的响应时延。当响应时延过大时,会导致车辆出现较大的定位偏差,从而影响超视距感知检测的效果。因此,在实际应用中,需要对系统响应时延进行优化,以保证车辆的定位精度和识别准确率。

为了进一步验证本方法的可行性,本实验从前方超低速检测和后方超高速检测响应时间数据中随机抽取了 200 辆在途行驶车辆,并统计了本方法在超视距感知检测时的响应时延。根据前方超低速感知检测结果(见图 5-11)的分析,本节发现响应时延大于 250ms 的车辆,其检测到的前方超低速车辆数量明显多于其他车辆。通过分析其行驶轨迹和驾驶行为安全性评价模型的结果,本研究认为导致响应时延超过 250ms 的首要原因是车辆在高速公路通行高峰期出行。然而,由于高速公路车流空间分布不均衡,该车所处位置未在拥堵核心区,因此该车可以保持正常车速。但是,其超视距识别区域覆盖到拥堵核心区,而拥堵核心区内车速受限,导致该车前方相对于其车速的超低速行驶车辆较多,因此计算时间也相对较长。其次,少部分车辆由于驾驶行为习惯开快车,导致其车速偏快,从而超视距识别区内的相对超低速车辆增多,计算时间也变长。

在后方超高速感知检测仿真实验中,本节发现与前方超低速感知检测类似的特征。大多数情况下,本方法的响应时延在 250ms 以内,但也存在部分车辆的响应时延超过 250ms。然而,在超高速感知检测实验中,导致相对超高速车辆增多、响应时延变长的主要原因是车辆类型的影响。由于三类车的速度相对其他类型的车辆较慢,因此其超视距识别区内的超高速车辆数量也相对较多。其次,部分驾驶员习惯开慢车,这也导致超视距识别区内的相对超高速车辆增多,进而延长了计算时间。最后,车流量分布的空间不均匀性也是一个因素,目标服务对象车辆位于拥堵核心区,车速受限,导




图 5-11 超视距感知检测单样本响应时延统计图

致其后方相对超高速车辆增多,从而计算时间变长。

为了避免单个样本时延分析结果的偶然性,本研究对响应时间数据进行了多样本随机抽样分析。实验从后方超高速检测和前方超低速检测的响应延迟数据中随机抽样,每个样本容量为 100,样本数为 1000 到 50 000 不等,并进行 100 次重复取平均值,以得出 ETC 仿真平台的超视距异常车辆识别时延统计值。如图 5-12 所示,在样本容量小于 14 000 的情况下,无论是对后方超速检测响应时间还是前方低速检测响应时间进行统计,平均响应时间都会有一定的波动,但波动幅度很小,均在 1ms 以内。当样本容量大于 14 000 时,平均响应时间趋于稳定,后方超速检测平均响应延迟为 175.88ms,前方低速检测平均响应延迟为 175.77ms,基本不随样本容量变化而变化。

为了保证样本的覆盖性,本实验随机抽取了 1000 到 50 000 个样本,每个样本均重复 100 次。这样可以充分保证样本覆盖了高速公路通行的各种特征,包括不同时间段、不同车辆类型、不同驾驶行为以及不同车流量下道路通行情况等。实验结果表明,在全高速公路环境下,本算法的响应时延低且稳定,表现出良好的鲁棒性,可以满足高速公路超视距感知检测的全环境要求。

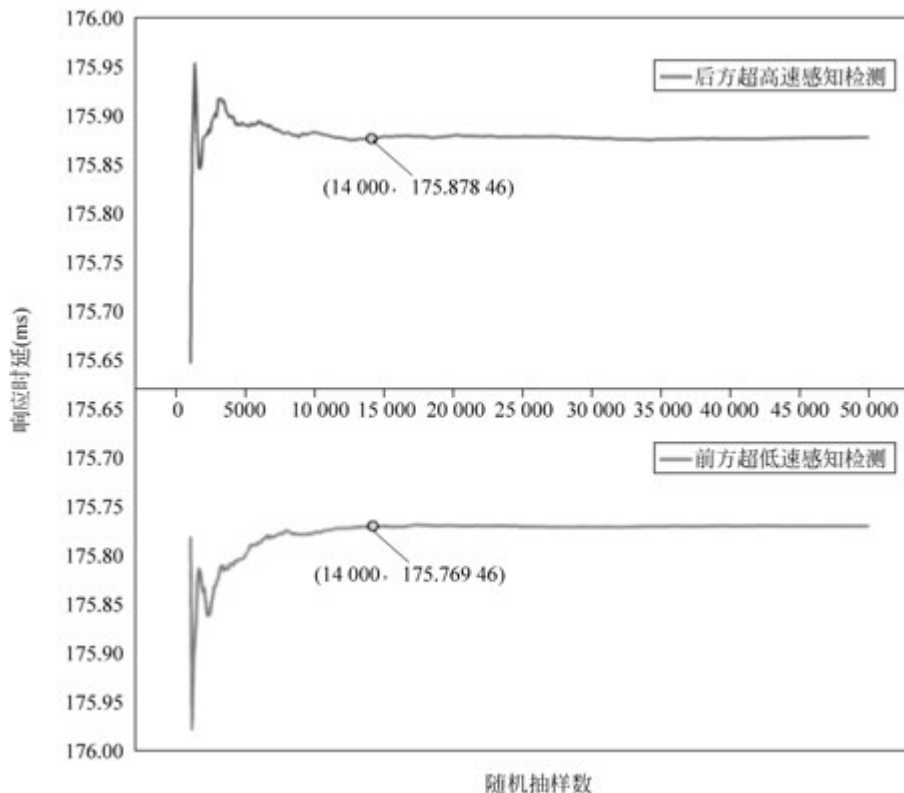


图 5-12 超视距潜在安全威胁车辆识别实验时延性能分析结果

5.6 本章小结

本章研究了一种基于 ETC 系统的高速公路超视距安全感知技术,旨在提高车辆在视距范围外的安全感知能力。该算法采用小波包变换分解和重构车辆区段速度集,并使用降噪处理过的数据进行训练,以提高模型精确性。接着,利用 XGBoost 模型解决空间序列回归问题,实现了对视距范围外车辆的识别。通过 DR 算法计算出车辆潜在位置,并使用 HMM 对车辆潜在位置进行纠偏,从而准确定位车辆位置。最后,根据目标服务对象车辆类型、车流量、车速等因素,确定出超视距的异常车辆识别区域,并利用第 4 章提出的车辆超高速/超低速驾驶行为识别方法对在途车辆进行安全评估。

经过仿真验证,本方法感知异常车辆的准确率达到 98.3%,召回率达到 95.7%,响应延迟趋近于 175ms。本方法具备响应时延低、稳定性高且鲁棒性好的特点,能够满足高速公路超视距感知检测的全环境要求。因此,本章成果可作为智能驾驶车路协同安全辅助驾驶的重要手段,具有广阔的应用前景。