

基于深度学习与交互特征的智能车辆换道风险预测模型

孟令一

山东科技大学交通学院 山东青岛 266590

摘要: 随着自动驾驶技术的发展, 车辆换道风险预测已成为提高智能车辆安全性和性能的关键任务之一。传统的换道风险预测方法往往忽略了换道车辆与周围环境之间的复杂交互特征, 导致预测准确度不足。本文提出了一种基于交互特征的智能车辆换道风险预测方法。首先基于 highD 数据集提取周围交互车辆轨迹数据, 利用停车距离指数建立风险评价指标, 并通过聚类算法划分风险等级。最后, 采用 LSTM 模型进行风险预测, 实验结果表明, 加入交互特征的 LSTM 模型预测效果更好。

关键词: 交互特征; 智能车辆; 换道风险预测; LSTM 模型

引言

随着机动车数量的不断增加, 交通系统日益复杂, 交通拥堵问题加剧。为提升安全并缓解交通压力, 我国积极推动汽车智能化与网联化。然而, 自动驾驶与人工驾驶车辆在混合交通环境中的共存, 增加了交通复杂性, 并对自动驾驶车辆的安全行驶带来挑战。换道行为涉及纵向、横向运动及与周围车辆的交互, 增加了驾驶复杂性。提前识别潜在风险换道情形, 对评估交通风险和预防事故至关重要。

陈吉清等^[1]通过分析换道过程中车辆与周围车辆的冲突形式, 并结合微观和宏观的换道风险特征, 提出了一种新的换道风险综合量化方法。郝志国等^[2]基于 NGSIM 数据, 通过 Logistic 回归和事故树分析, 评估换道车辆与周围车辆的交通冲突, 分析碰撞和避险时间以划分风险等级。刘巧斌等^[3]根据 TTC 和 THW 指数提出了风险规律, 并基于该规律设计了认知风险动态平衡跟车模型, 从而提高自动跟车的安全性。马艳丽等^[4]通过车辆控制数据与驾驶员指标, 构建贝叶斯网络模型评估风险并进行等级划分, 但其阈值设定较为主观, 模型鲁棒性不足。温惠英等^[5]通过分析大型车在换道过程中的 TTC 和 MTC, 揭示了时间风险与空间风险的相互关系, 为提高换道过程中的风险预测提供了新的思路。Ali 等^[6]应用极值理论分析强制换道的碰撞风险, 并基于模拟器数据验证其精度。Chen 等^[7]通过关键空间序列特征与随机森林分类器, 提出换道风险预测方法, 提前评估碰撞风险。程士强^[8]提出基于最大可行加速度与安全距离的风险评估模型, 分析空间距离对换道风险的影响。宋佳^[9]结合

合流区交通环境与 CAV 车辆动力学特征, 提出早期换道模型与强制换道控制策略, 研究安全场变化, 评估换道风险。

传统的方法大多依赖于车辆动力学模型和基于规则的算法, 通过分析车辆的位置、速度、加速度等特征来估算换道风险。例如, 某些研究通过设定安全距离阈值, 来判断车辆是否存在碰撞风险。然而, 这些方法忽略了换道过程中车辆间的交互影响, 且难以应对复杂的交通环境。

1. 周围交互车辆特征分析

1.1 周围交互车辆影响

(1) 原车道前车影响: 在自由换道的偏离阶段, 换道车逐渐离开原车道。如果未能准确评估与原车道前车的纵向距离, 或在调整车速时操作不当, 可能会导致追尾碰撞。当换道车加速过快或未能及时减速时, 与原车道前车的距离缩短, 发生碰撞的风险增加。此类碰撞通常发生在车辆动态变化较大的情况下, 反映出偏离阶段对纵向距离与速度控制的要求。

(2) 目标车道前车影响: 在跨道阶段, 换道车进入目标车道后需与目标车道前车保持安全距离。当换道车未能准确判断前车的车速或动态变化, 或者未能及时调整自身速度, 就可能发生追尾碰撞。如果目标车道前车突然减速, 而换道车反应不足, 碰撞风险将显著增加。换道车与目标车道前车的距离与速度匹配是避免此类碰撞的重要因素。

(3) 目标车道后车影响: 自由换道的跨道阶段和回正阶段, 换道车需与目标车道后车协调完成并道。如果换道车未能精确评估目标车道后车的速度和距离, 在切入车道时与

后车产生干扰,可能导致后车无法及时避让,发生尾部或侧面碰撞。这种碰撞通常源于换道时对目标车道后车的动态变化感知不足,以及车辆切入路径规划的偏差。

1.2 数据提取

本文采用德国高速公路大型自然驾驶轨迹数据集 highD 进行研究,highD 数据集中有充足的车辆交互数据。提取数据具体步骤如下:

- (1) 剔除 highD 数据集中非汽车类型的车辆轨迹;
- (2) 通过 laneID 列相邻帧的车道 ID 变化确定换道时间戳;
- (3) 以换道时间戳为起点,向前向后搜索连续四帧横向位移均小于 0.03m 的时间戳,确定换道开始结束时间;
- (4) 提取换道车辆周围车辆的轨迹数据。




图 1 换道场景提取

2. 考虑交互特征的换道风险预测

2.1 基于聚类分析的换道风险等级划分

本文基于停车距离指数 (SDI) 建立换道过程中的交互冲突评价指标。首先计算换道车辆与周围交互车辆的停车距离指数,然后采用模糊 c-均值聚类算法,实现无监督的风险等级标记。风险等级划分聚类中心结果:

(1) 安全等级,其聚类中心为 (97.84,123.85,119.68),说明该风险等级下,三组 SDI 值均处于较高的范围,表明换道车辆与周围车辆之间的安全距离较大,速度差异较小,加速度变化平稳。因此,换道过程的风险较低,车辆间的相对位置和动态行为相对稳定,换道车的安全性较高,碰撞风险较低。

(2) 低风险等级,其聚类中心为 (93.02,48.76,41.11),该等级的 SDI 值明显低于安全等级,表明换道过程中,虽然安全距离相对较大,但车辆之间的速度差和加速度差有所增大,可能出现短暂的紧张状态。此时,虽然仍可维持一定的

安全性,但周围车辆的行为和换道车辆的相对位置可能导致一定程度的风险,需保持警觉。

(3) 中风险等级,其聚类中心为 (39.58,32.07,38.00),SDI 值较低,意味着换道车辆与周围车辆的距离变得较小,速度差距增大,加速度波动较大。这种情况下,换道车辆可能面临较为复杂的交通状况,换道过程中存在一定的碰撞风险,车辆间的动态交互较为剧烈,安全性较低。

(4) 高风险等级,其聚类中心为 (24.45,22.42,32.07),三组 SDI 值均处于较低的范围,表明换道车辆与周围车辆的距离极小,速度差异和加速度差异较大,车辆间的交互非常紧张。这种情况下,换道车辆极有可能面临碰撞或其他重大风险,换道操作应十分谨慎,且需要迅速采取紧急避让措施。

2.2 网络模型结构确定及参数设置

模型选取了三层神经网络结构模型,包括数据输入层、LSTM 隐藏层和数据输出层。参数设置:

- (1) 学习率: 0.01;
- (2) Batch_size: 32;
- (3) Dropout: 0.5;
- (4) LSTM 神经元个数: 64;
- (5) LSTM input_dim : 24;
- (6) LSTM hidden_dim: 64;
- (7) LSTM output_dim: 4;
- (8) 损失函数: categorical_crossentropy;
- (9) Epoch: 200。

2.3 特征选取

在使用 LSTM 神经网络进行换道决策预测时,需考虑本车及周围车辆的状态,因此将交互特征纳入风险预测模型的特征。模型特征参数如下:

(1) 自车特征:

横向位置、纵向位置、横向速度、纵向速度、横向加速度、纵向加速度。

(2) 交互特征:

原车道前车: 横向位置、纵向位置、横向速度、纵向速度、横向加速度、纵向加速度;

目标车道前车: 横向位置、纵向位置、横向速度、纵向速度、横向加速度、纵向加速度;

目标车道后车: 横向位置、纵向位置、横向速度、纵向速度、横向加速度、纵向加速度。

3. 结果与分析

本文以自然驾驶轨迹数据为训练原始数据，将数据划分为80%的训练集和20%的验证集。选取准确率(Accuracy)、精确率(Precision)、召回率(Recall)以及F1分数作为模型评价指标。

表 1 模型评价指标

输入特征	Accuracy	Precision	Recall	F1 分数
自行车特征	79.47	82.10	79.47	78.60
自行车特征 + 交互特征	82.65	83.03	82.65	82.52

为了验证本文建立的基于 LSTM 的换道风险预测模型的性能，分别输入自行车特征加交互特征的特征值以及未加入交互特征的特征值。由表 9 中的换道风险预测结果可知，当输入的特征中加入交互特征时，LSTM 模型的准确率为 82.65%，而未加入交互特征的模型准确率为 79.47%，这说明了本文所提出的考虑交互特征的 LSTM 模型在换道风险预测方面具有更好的性能。




图 2 未加入交互特征混淆矩阵

图 2 中标签 0 代表高风险，标签 1 代表中风险，标签 2 代表低风险，标签 3 代表安全。从图中可以看出加入交互特征后模型能够更好地利用时间序列特征和交互特征，显著提升了分类准确率，尤其是在高风险类别上表现最优，正确识别了 241 个样本，显著高于未加入交互特征的 LSTM 模型。说明 LSTM 模型能够更好地结合时间序列特征与交互特征，有效提升高风险样本的识别能力。

4. 结论

本文研究智能车辆换道风险预测问题。首先，分析了周围交互车辆的影响，筛选换道车辆及周围车辆轨迹数据；然后，基于 SDI 构建交互风险评价指标，并通过模糊 c 均值聚类划分风险等级；最后，利用 LSTM 模型进行风险预测，并将交互特征作为特征值输入，实验结果表明，加入交互特征的模型预测准确率高于未加入交互特征的模型。

参考文献:

- [1] 陈吉清, 翁楚滨, 兰凤崇. 智能车辆换道潜在冲突分析与风险量化方法 [J]. 汽车工程, 2021, 43(11): 1565-1576+1586.
- [2] 郝志国. 高速公路换道冲突预测与安全评价研究 [D]. 吉林大学, 2019.
- [3] 刘巧斌, 杨路, 高博麟等. 基于认知风险动态平衡的智能汽车跟车模型 [J]. 汽车工程, 2022, 44(11): 1627-1635.
- [4] 马艳丽, 范璐洋, 吕天玲, 等. 车辆运行风险贝叶斯网络量化分级方法 [J]. 哈尔滨工业大学学报, 2020, 52(03): 33-37.
- [5] 温惠英, 李秋灵, 赵胜. 快速路合流区大型车换道时空特征及风险研究 [J]. 华南理工大学学报 (自然科学版), 2022, 50(05): 11-21.
- [6] Ali Y, Haque M M, Zheng Z, et al. A hazard-based duration model to quantify the impact of connected driving environment on safety during mandatory lane-changing [J]. Transportation Research Part C, 2019, 106(C):113-131.
- [7] Chen T, Shi X, Wong Y D, et al. Predicting lane-changing risk level based on vehicles' space-series features: A pre-emptive learning approach [J]. Transportation Research Part C-Emerging Technologies, 2020, 116:102646.
- [8] 程士强. 混驶环境下基于风险评估的自动驾驶车辆换道轨迹规划 [D]. 合肥工业大学, 2020.
- [9] 宋佳. 异质交通流环境下高速公路合流区车辆换道行为研究 [D]. 吉林大学, 2023.