

# 基于前车换道意图识别与车车通信的汽车切入防撞预警模型

曹城铭, 杨炜, 张志威

(长安大学 汽车学院, 西安 710064)

**摘要:** 针对前车切入的突发性和现有的驾驶辅助系统在前车切入场景中存在预警准确率低和预警不及时的问题, 设计了一种基于前方车辆换道意图识别的汽车切入防撞预警模型。利用车车通信将相邻前车换道意图发送给后方车辆, 后方车辆预测并基于前车换道轨迹进行碰撞检测。提出碰撞时间 TTC-S, 又对避险时间 TTA 进行重新分析和计算, 设计了分级预警策略。为验证防撞预警系统的有效性, 搭建基于 Simulink 和 PreScan 的联合仿真平台进行测试。结果表明, 防撞预警模型在预警测试中的平均正警率为 90.32%, 与 Mazda 模型和传统 TTC 模型相比, 平均正警成功率分别高出 8.44% 和 11.66%, 同时平均预警提前时间分别为 1.42 s 和 1.9 s, 安全系数更高。

**关键词:** 换道意图; 轨迹预测; 车车通信; 防撞预警

中图分类号: U461.91

文献标志码: A

DOI: 10.3969/j.issn.2095-1469.2025.04.05

## A Cut-in Collision Avoidance Warning Model Based on Front-Vehicle Lane-Change Intention Recognition and Vehicle-to-Vehicle Communication

CAO Chengming, YANG Wei, ZHANG Zhiwei

(School of Automobile, Chang'an University, Xi'an 710064, China)

**Abstract:** Existing driver-assistance systems often deliver late or inaccurate alerts when a vehicle cuts in suddenly from an adjacent lane. To address this issue, the paper develops a collision-warning model that detects the lane-change intention of the lead vehicle. The vehicle-vehicle communication is utilized to send that intention to the following vehicle, which then predicts the cut-in path and performs collision detection. The collision time TTC-S is proposed, the avoidance time TTA is re-examined, and a tiered warning strategy is designed. In order to verify the effectiveness of the collision warning system, a joint simulation platform is built based on Simulink and PreScan. The results show that the collision-warning model achieves an average true-positive rate of 90.32%, outperforming the Mazda model by 8.44% and the traditional TTC model by 11.66%. The system also provides earlier alerts, extending the average warning lead time by 1.42 s and 1.9 s, respectively, which provides a larger safety margin.

**Keywords:** lane change intention; trajectory prediction; vehicle-vehicle communication; collision warning

收稿日期: 2024-05-15 改稿日期: 2024-08-15 网络首发日期: 2024-09-02

基金项目: 国家重点研发计划项目(2021YFB2601000); 秦创原队伍建设项目(2022KXJ-021); 陕西省秦创原“科学家+工程师”队伍建设

参考文献引用格式:

曹城铭, 杨炜, 张志威. 基于前车换道意图识别与车车通信的汽车切入防撞预警模型[J]. 汽车工程学报, 2025, 15(4): 477-488.

CAO Chengming, YANG Wei, ZHANG Zhiwei. A Cut-in Collision Avoidance Warning Model Based on Front-Vehicle Lane-Change Intention Recognition and Vehicle-to-Vehicle Communication[J]. Chinese Journal of Automotive Engineering, 2025, 15(4): 477-488. (in Chinese)



随着汽车保有量的快速增长,交通安全问题备受人们关注。城市道路环境中,车辆密集、车流复杂且交叉路口频繁出现,导致车辆换道、并道行为普遍发生。美国高速公路安全管理局的统计数据表明,在近年发生的交通事故中,大约27%的事故是由车辆换道导致的<sup>[1]</sup>,这些事故中大部分可以通过主动防撞系统来避免。主动防撞系统在检测到潜在的危险情况时,能向驾驶员发出警告或自主激活制动系统以避免碰撞或减少碰撞损失,所以研究主动防撞系统具有重要意义。

现有预警模型大致可以分为两大类,一类是基于安全距离的预警模型,另一类是基于安全时间的预警模型。ZHANG Ruifeng等<sup>[2]</sup>通过预测周围车辆的轨迹来计算碰撞时间TTC,当TTC在指定阈值之内时,向车辆驾驶人提供报警信息,该防撞预警模型在直线、拐角和弯道处均能适用,可以防止潜在的碰撞。YANG Wei等<sup>[3]</sup>提出了一种基于前车驾驶意图识别与车车通信的前向碰撞预警系统,利用双层隐马尔可夫模型对前车驾驶意图进行识别,并通过V2V通信将预测到的前车驾驶意图传递给后车,后车根据前向防撞预警模型对潜在碰撞进行预警。这些研究大多针对的是纵向方向上的车辆,较少考虑相邻前车突然切入本车车道的工况。张凯等<sup>[4]</sup>结合正弦函数换道轨迹模型估计换道压线时间TLC,然后根据危险安全时间阈值TTC建立换道安全预警距离模型和换道预警规则。XU Guoyan等<sup>[5]</sup>针对不同车道前方车辆,提出了一种实时碰撞预警系统。首先使用多传感器检测前方车辆的距离与速度信息,然后设计神经网络预测前方车辆是否换道至本车车道,最后提出针对不同换道动作的碰撞预警模型,对驾驶员进行有效预警。黄慧玲等<sup>[6]</sup>提出了一种基于前车行为识别的防撞预警算法,利用单目视觉检测,实时跟踪目标,结合驾驶意图构建了一种变道防撞预警模型。这些研究利用传感器获取车辆外部环境信息或者其他车辆已表现出的状态信息作为危险评估的先决条件,对驾驶人

的换道驾驶意图在系统中的作用考虑较少。

鉴于此,面向城市道路场景,本文提出了一种基于前车换道意图识别与车车通信的切入防撞预警模型,该模型利用车车通信将前方车辆换道意图引入后车预警防撞模型中,以便能对相邻前车换道切入时的潜在碰撞风险进行有效预警,提高主动防撞预警系统的安全性。

## 1 总体框架

本文提出的基于前车换道意图识别与车车通信的汽车切入防撞预警模型总体框架如图1所示。

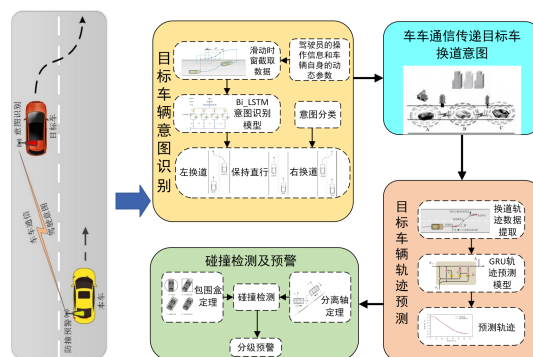


图1 防撞预警模型

首先,基于公开数据集NGSIM提取的典型数据,采用滑动时窗法截取连续数据,并利用截取的数据实现对目标车辆左换道、保持直行和右换道的换道意图识别。其次,本车通过车车通信获取相邻前方车辆的换道意图后,对换道车辆进行轨迹预测。最后,本车结合相邻前车换道轨迹进行碰撞危险检测并及时发出预警信号,实现主动防撞预警。

## 2 基于Bi-LSTM的换道意图识别模型

### 2.1 意图识别模型构建

在换道意图识别问题中,车辆当前时刻的状态输出不仅与历史时刻的信息相关,而且也受未来时刻的状态影响。本文所用的Bi-LSTM换道意图识别模型<sup>[7]</sup>网络框架如图2所示。

基于Bi-LSTM构建的换道意图识别模型输入参数为:

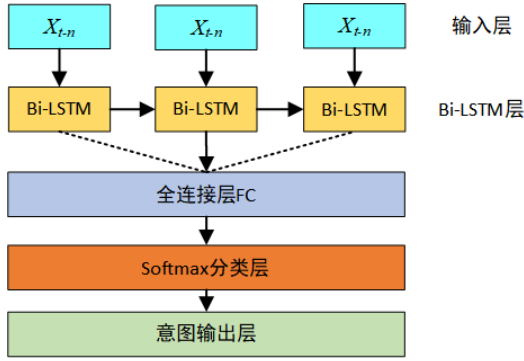


图2 换道意图识别模型网络框架

$$X = (X_{t-n}, X_{t-n+1}, \dots, X_{t-1}, X_t)。(1)$$

式中：\$X\_t\$ 为在 \$t\$ 时刻输入的历史长度特征数据，可表示为：

$$X_{t-i} = [d_{t-i}, vx_{t-i}, vy_{t-i}, ax_{t-i}, ay_{t-i}]。(2)$$

式中：\$d\_{t-i}\$ 为 \$t-i\$ 时刻目标车辆的横向车道偏移量；\$vx\_{t-i}\$、\$vy\_{t-i}\$、\$ax\_{t-i}\$、\$ay\_{t-i}\$ 分别为 \$t-i\$ 时刻目标车辆的纵向速度、横向速度、纵向加速度、横向加速度。

输入序列 \$X\$ 经过 Bi-LSTM 网络输出后，再经过 Softmax 层，最终的输出结果为 3 种换道意图，左换道、直行、右换道 3 种意图概率可表示为：

$$[w_1, w_2, w_3] = P([c_1, c_2, c_3]|X)。(3)$$

式中：\$c\_1\$、\$c\_2\$、\$c\_3\$ 分别代表左换道、右换道和保持直行；\$w\_1\$、\$w\_2\$、\$w\_3\$ 分别代表 3 种换道意图的概率<sup>[8]</sup>。

本文在 Matlab 环境下搭建 Bi-LSTM 模型。所使用的硬件配置为 Inter Core i9-13900HX 2.20 GHz CPU，操作系统为 Windows 11 系统。网络的输入节点设置为 5，输出节点设置为 3。隐藏层是由 2 个双向的 LSTM 层构成，其对应的节点个数分别为 30 和 35。设定 batch\_size 为 30，epoch 为 200，学习率为 0.001。

## 2.2 试验与分析

### 2.2.1 数据预处理

本文选用 NGSIM 公开数据集中的 US-101 路段数据进行模型训练与测试，如图 3 所示，检测路段长度为 640 m，包括 5 条普通车道和 1 条汇流匝道。该数据集源于美国联邦公路管理局发起的 NGSIM

计划，采样频率为 10 Hz，采集了一段时间内通过车辆的位置信息、速度信息、加速度信息和车辆类型、编号等。




图3 US-101路段示意图

首先需要将数据集中车辆轨迹分为左换道、右换道和保持直行 3 类，然后对提取的车辆轨迹进行标注。

具体的分类依据为：首先找出车道号发生变化的时刻，该时刻对应的即为换道点，然后，运用式 (4) 和式 (5) 找出换道起点和换道终点<sup>[9]</sup>，即：

$$t_{start} = \begin{cases} \max \{t|t - t_1 < 0, x_{t-1} \leq x_t\}, & \text{向左换道} \\ \max \{t|t - t_1 < 0, x_{t-1} \geq x_t\}, & \text{向右换道} \end{cases}。(4)$$

$$t_{end} = \begin{cases} \min \{t|t - t_1 > 0, x_t \leq x_{t+1}\}, & \text{向左换道} \\ \min \{t|t - t_1 > 0, x_t \geq x_{t+1}\}, & \text{向右换道} \end{cases}。(5)$$

式中：\$t\_{start}\$ 和 \$t\_{end}\$ 分别为换道起点和换道终点；\$t\_1\$ 为换道点对应时刻；\$x\_i\$ 为车辆在 \$i\$ 时刻的横向坐标。

意图分类后，需对轨迹进行标注。如图 4 所示，以左换道为例，C 点为换道点，B 点为换道起点，为了尽早识别到换道意图，从换道起点 B 往前延长 1 s 得到 A 点，也标注为换道意图数据，通过滑动时窗法将 A 和 C 之间的序列标记为 0，代表左换道。右换道车辆标注方法与左换道车辆相同，标记为 1。直行车辆轨迹数据标记为 2。

通过该方法，得到左换道、右换道和保持直行 3 类数据集，由于直线行驶数据量远大于换道数据量，为保证模型良好的分类效果，从 3 类数据集中各随机选取 1 500 条数据作为模型数据集，将其中 80% 作为训练集，20% 作为测试集。最后对输入的数据进行归一化处理，便于模型训练。




图 4 左换道车辆标注示意图

2.2.2 试验结果与分析

在使用训练集数据对模型进行构建后，需要通过测试集数据对模型进行分类结果进行评估，本文选用准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1-score) 作为模型评价指标<sup>[9]</sup>。在多分类问题中，混淆矩阵各参数的定义，见表 1。

表 1 多分类混淆矩

实际意图	识别结果	
	当前意图	其他意图
当前意图	TP (真阳性)	FN (假阴性)
其他意图	FP (假阳性)	TN (真阴性)

在混淆矩阵中，TP 表示预测为正样本，真实为正样本；FP 表示预测为正样本，真实为负样本；FN 表示预测为负样本，真实为正样本；TN 表示预测为负样本，真实为负样本。

模型的准确率 (Accuracy)，表示在测试集中预测正确的样本占总数的比例，用于评估模型整体的预测准确率，其计算式为：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

模型的精确率 (Precision)，表示正确预测为正的样本占全部预测为正的样本比例，其计算式为：

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

模型的召回率 (Recall)，表示正确预测为正的样本占全部实际为正的样本比例，其计算式为：

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

模型的 F1 分数 (F1-score)，表示精确率和召回率的权衡指标，其取值范围为 0~1，越接近 1 就表明模型识别效果越好，其计算式为：

$$F1 = \frac{2P \times R}{P + R} = \frac{2TP}{2TP + FP + FN} \quad (9)$$

利用测试集中的数据对各模型进行测试，表 2 为测试结果的混淆矩阵，表 3 为模型在测试集上的 Precision、Recall、F1 和 Accuracy 值。由表 2 和表 3 可知，Bi-LSTM 模型对每种换道意图的平均识别准确率为 93.89%。精确率、召回率、F1 分数和整体准确率均在 91% 以上，具有较好的换道意图识别能力。

表 2 前车换道意图识别准确率混淆矩阵

实际换道意图	预测意图			准确率/%
	左换道	保持直行	右换道	
左换道	281	12	7	93.89
保持直行	6	286	8	
右换道	7	15	278	

表 3 前车换道意图识别评价指标

评价指标	召回率/%	精确率/%	F1 分数
左换道	93.67	95.58	94.61
保持直行	95.33	91.37	93.31
右换道	92.67	94.88	93.76

3 基于 GRU 神经网络的换道轨迹预测模型

在能识别前方车辆左换道、右换道和直行意图的前提下，进一步对其换道轨迹进行预测，以此通过碰撞检测判断本车未来时刻是否与前方车辆发生碰撞，对行车安全进行量化的评估，从而调整行车策略，防止事故发生。考虑到车辆轨迹的时序性，以及在处理长序列时能更好地解决梯度消失的问题的特点，本文基于 GRU 神经网络对换道估计进行预测，轨迹预测模型结构如图 5 所示，并采用均方误差 MSE 和平均绝对误差 MAE 对预测轨迹的准确性进行评估<sup>[11]</sup>。

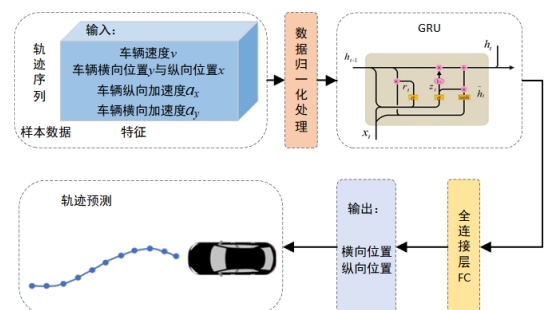


图 5 轨迹预测模型结构

### 3.1 轨迹预测模型的构建

#### 3.1.1 模型的输入与输出

轨迹预测模型的输入参数为驾驶员的操作信息和车辆自身的动态参数。车辆轨迹呈现时间序列的特征，历史轨迹会对未来行驶状况产生影响。因此，模型的输入特征为一段历史时长的序列数据，表示为：

$$O = [O^{t-n}, O^{t-n+1}, \dots, O^{t-1}, O^t]。 \quad (10)$$

式中： $O$ 为模型的输入数据； $O^t$ 为当前时刻的数据特征； $n$ 为输入数据的历史长度。

当前时刻的数据特征 $O^t$ 可表示为：

$$O^t = [v^t, x^t, y^t, a_x^t, a_y^t]。 \quad (11)$$

式中： $v^t$ 为车辆速度； $x^t$ 为纵向位置； $y^t$ 为横向位置； $a_x^t$ 为纵向加速度； $a_y^t$ 为横向加速度；

模型的输出为 $t+1$ 时刻目标车辆的横向位置和纵向位置，即：

$$Y = [x^{t+1}, y^{t+1}]。 \quad (12)$$

#### 3.1.2 模型评价指标

在根据训练集数据构建模型后，需要通过测试集数据对模型的轨迹预测结果进行评估分析。本文选用均方误差MSE和平均绝对误差MAE两个指标，对预测轨迹和实际轨迹之间的误差进行评估。

均方误差(MSE)，表示了预测轨迹和实际轨迹之间的差异性，该值越小说明模型预测效果越好，可表示为：

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2。 \quad (13)$$

式中： $n$ 为样本数； $y_i$ 为实际值； $\hat{y}_i$ 为预测值。

平均绝对误差(MAE)，表示了预测轨迹和实际轨迹之间的距离差异，该值越小说明模型预测效果越好，可表示为：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|。 \quad (14)$$

式中： $n$ 为样本数； $y_i$ 为实际值； $\hat{y}_i$ 为预测值。

#### 3.1.3 训练数据和测试数据

该模型使用的数据为处理后的NGSIM数据集中左换道和右换道轨迹数据，随机抽取500组左换

道轨迹数据和500组右换道轨迹数据，将这些轨迹数据分割为训练集和测试集，分割比例为8:2。在模型训练和测试之前，需要对数据中的各个特征维度进行归一化处理，以标准化输入数据，此外，在预测完成后，还需对模型的输出值执行反归一化操作，以恢复其原始的尺度和意义。归一化公式为：

$$e' = \frac{e - e_{\min}}{e_{\max} - e_{\min}}。 \quad (15)$$

式中： $e$ 为原始数值； $e'$ 为归一化后的数值； $e_{\max}$ 和 $e_{\min}$ 分别为数据样本中的最大值与最小值。

#### 3.1.4 参数设置

基于Matlab搭建环境进行模型训练，参数设定如下：输入层的神经元数量为5；输出层的神经元数量为2；训练批次大小batch\_size为30；学习率为0.001；训练次数epoch为200。

模型参数确定后，还需确定隐藏层层数以及各层神经网络数量。设置预测时域1s，设置神经元个数以10个为间隔，且依次从10个至50个递增，对不同神经元数量的模型，分别进行10次测试，计算每次测试的误差，并取其平均值，误差测试结果见表4。

表4 第1个隐藏层不同神经元数量对应误差

神经元数量/个	MSE	MAE
10	0.663 5	1.132 0
20	0.453 7	1.094 7
30	0.153 1	0.293 4
40	0.332 9	0.934 6
50	0.492 6	0.842 8

由表4可知，当第1个神经元数量为30时，MSE和MAE达到最小值，因此，第1个隐藏层的神经元数量为30。

在确定第1个隐藏层的神经元个数之后，为了使模型架构更优，采用控制变量法，设置第1个隐藏层的神经元数量固定为30，并设置第2个隐藏层的神经元数量同样以10个为间隔，且依次从10个至50个递增，误差测试结果见表5。

由表5可知，当第2个隐藏层的神经元数量为40时，模型的MSE和MAE达到最小值。虽然当第

表 5 第 2 个隐藏层不同神经元数量对应误差

神经元数量/个	MSE	MAE
10	0.701 5	1.217 0
20	0.652 3	0.920 4
30	0.421 7	0.775 2
40	0.231 2	0.421 3
50	0.367 4	0.583 6

2 个隐藏层的神经元数量为 40 时，模型训练效果不错，但是误差与单隐藏层相比变大。因此，本文选择隐藏层数为 1，设置隐藏层神经元数量为 30，最后确定模型为 5-30-2 的神经网络结构。

### 3.2 GRU 模型预测结果

随机从测试集中选取一条换道轨迹进行试验，以此来评估换道轨迹预测模型的性能。试验结果显示，均方误差 (MSE) 和平均绝对误差 (MAE) 均较低，见表 6，说明模型预测的轨迹与实际轨迹之间的偏差较小，基于 GRU 神经网络换道轨迹预测模型具有良好的预测效果。

表 6 试验测试误差

MSE	MAE
0.163 1	0.310 4

## 4 考虑前车换道意图与车车通信的切入防撞预警模型

在已知前车换道意图与换道轨迹的前提下，首先采用包围盒理论 (OBB) 和分离轴定理进行碰撞检测<sup>[12]</sup>，并根据前车轨迹与碰撞检测结果实时计算碰撞时间 (Time to Collision of Side, TTC-S)，然后对避险时间 (Time to Avoidance, TTA) 进行重新计算和分析，最后将碰撞时间 TTC-S、避险时间 TTA 和驾驶员反应时间结合，制定分级预警策略。

### 4.1 基于轨迹的碰撞预测模型

在目标车换道切入本车车道的过程中<sup>[13]</sup>，本车与目标车碰撞检测过程如图 6 所示。本车检测轴线有 2 条，分别平行、垂直于车道中心线；检测轴线 3 为目标车航向角，可由目标车横纵向速度求得，检测轴线 4 与检测轴线 3 相互垂直。具体的基

于 OBB 和分离轴定理的碰撞检测步骤<sup>[14]</sup>如图 7 所示，步骤如下：

- 1) 构建车辆空间坐标系，并获取车辆矩形框顶点坐标；
- 2) 从本车与目标车辆轴线任取一条作为投影轴，将矩形框顶点坐标投影到该轴线上，并判断投影是否存在重叠；
- 3) 对两辆车共 4 条轴线全部进行步骤 2 投影检测；
- 4) 若 4 条轴线投影检测结果均重叠，则表示两车发生碰撞；若其中某一条轴线未重叠，则表示两车未发生碰撞。



图 6 碰撞检测过程

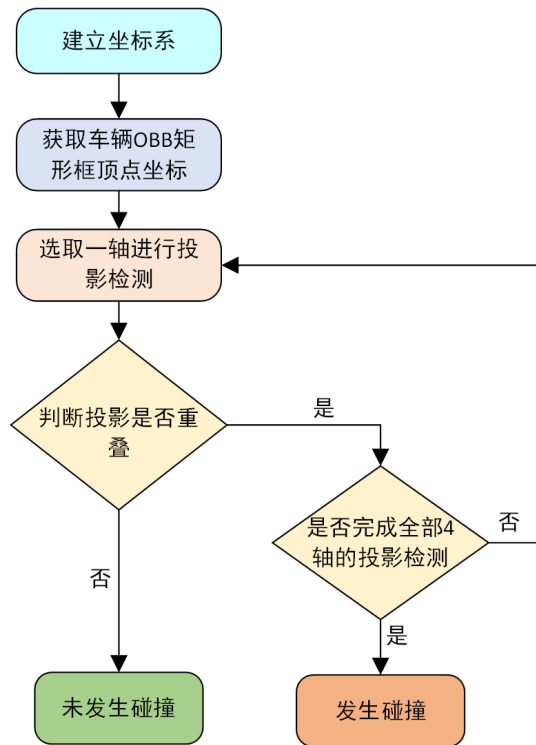


图 7 碰撞检测流程

利用车车通信技术 (V2V)<sup>[15]</sup>，车辆可以获取其周边车辆的相关动态信息。当周围车流密集时，本车仅需关注可能对其行驶造成影响的车辆，并只

考虑本车一定范围内的车辆是否有变道行为。一般情况下，如果两车的车头时距 THW 超过 5 s，认为两车不会相互影响正常行驶。因此，与本车车头时距低于 5 s 的前方相邻车辆均被视为目标车辆。预警范围如图 8 所示，棕色区域内的车辆即为目标车辆。




图 8 预警范围

当棕色区域内出现车辆时，会借助车车通信技术实时获取区域内车辆的动态数据。并通过换道意图识别模型识别其换道意图。一旦识别到预警范围内车辆即将采取换道行为，立即利用车车通信将其驾驶意图传递至本车，本车随即采用轨迹预测模型预测其轨迹。

已知目标车辆及其换道轨迹的前提下，轨迹冲突检测如图 9 所示。本文提出碰撞时间 TTC-S 用于表示当前时刻根据目标车轨迹计算出即将发生碰撞的剩余时间。如图中  $t_1$  时刻，其碰撞时间 TTC-S 的值即为  $t_5 - t_1$ ，TTC-S 值越小，表示当前危险程度越高，若两车不会发生碰撞，TTC-S 值将为无穷大。




图 9 轨迹冲突检测示意图

基于轨迹进行两车碰撞检测时，需将目标车轨迹转换到本车坐标系下，以便碰撞检测计算。两车坐标转换如图 10 所示。本车坐标系为  $y_k - x_k$ ，目标车坐标系为  $y_c - x_c$ ，在  $t$  时刻，目标车中心点坐标  $(x_c(t), y_c(t))$  在本车坐标系下可表示为  $(x_i(t), y_i(t))$ ，其变换公式为：

$$x_i(t) = x_c(t) + d + 2 \times 0.5L_v \quad (16)$$

$$y_i(t) = y_c(t) \quad (17)$$

式中： $d$  为本车识别到目标车换道意图时两车纵向相对距离； $L_v$  为车长；本车中心点坐标在本车坐标系中可表示为  $(x_h(t), y_h(t))$ ，由于本车在未来几秒时间内维持直线行驶，所以可利用当前时刻本车速度  $v_h$  和加速度  $a_h$  来预测未来几秒的纵向位移，如式 (18) 所示。

$$x_h(t) = v_h t + \frac{1}{2} a_h t^2 \quad (18)$$




图 10 两车坐标转换示意图

基于本车坐标系与本车中心点坐标，即可求得  $t$  时刻本车包围盒 4 个顶点坐标，分别可表示为：

$$\begin{cases} H_1(x_h(t) - 0.5L_v, y_h(t) + 1) \\ H_2(x_h(t) + 0.5L_v, y_h(t) + 1) \\ H_3(x_h(t) + 0.5L_v, y_h(t) - 1) \\ H_4(x_h(t) - 0.5L_v, y_h(t) - 1) \end{cases} \quad (19)$$

目标车换道过程中其包围盒 4 个顶点坐标跟随航向角变化而变化，航向角可由目标车横纵向速度求出，由于模型的预测时间步长为 0.1 s，所以目标车  $t$  时刻横纵向速度相应公式为：

$$\begin{cases} v_x(t) = \frac{x(t) - x(t-1)}{0.1} \\ v_y(t) = \frac{y(t) - y(t-1)}{0.1} \end{cases} \quad (20)$$

在计算得到目标车横纵向速度后，即可计算出目标车航向角：

$$\theta(t) = \tan^{-1} \frac{v_y(t)}{v_x(t)} \quad (21)$$

在  $\theta = 0$  时目标车包围盒 4 个顶点坐标，分别为  $T_1'(x_1', y_1'), T_2'(x_2', y_2'), T_3'(x_3', y_3'), T_4'(x_4', y_4')$ ，则航向角为  $\theta$  时目标车包围盒顶点坐标为：

$$\begin{cases} x = \cos \theta (x' - x_i) + \sin \theta (y' - y_i) + x_i \\ y = \cos \theta (y' - y_i) - \sin \theta (x' - x_i) + y_i \end{cases} \quad (22)$$

式中： $x$  和  $y$  为待求顶点坐标； $x'$  和  $y'$  为  $\theta = 0$  时的坐标； $x_i$  和  $y_i$  为目标车中心点坐标； $\theta$  为目标车航向角。

在求得同一坐标系下本车和目标车包围盒的 4 个顶点坐标之后,对两车进行碰撞检测,若检测到目标车切入换道过程中会与本车发生碰撞,计算此时碰撞时间 TTC-S。

### 4.2 分级预警策略关键参数确定

#### 4.2.1 驾驶人制动避险时间确定

传统的避险时间 TTA 公式如下<sup>[16]</sup>:

$$TTA = t_r + \frac{\delta v}{\mu g} \quad (23)$$

式中:  $t_r$  为驾驶员反应时间;  $\delta$  为减速因子;  $\mu$  为路面附着系数。

本文所提出的预警系统在碰撞危险即将发生时先对驾驶员进行预警,以警示驾驶员采取制动行为避免与前方换道切入车辆发生碰撞,若驾驶员收到预警信号后未采取相应措施,车辆驾驶辅助系统会立即接管车辆进行辅助制动,其预警信息传递过程如图 11 所示。本文在驾驶员制动和驾驶辅助系统制动两方面对避险时间 TTA 进行重新计算和评估。




图 11 预警信息传递过程

图中,  $t_0$  为驾驶员反应时间;  $t_1$  为制动空行程时间;  $t_2$  为制动力从 0 持续增长到最大制动力所需要的时间;  $t_3$  为制动持续时间;  $t_t$  为预警信息产生和传递的时间。  $t_r$  为驾驶辅助系统反应时间。参考相关文献,选取  $t_0 = 0.5 \text{ s}$ ,  $t_1 = 0.1 \text{ s}$ ,  $t_2 = 0.24 \text{ s}$ , 由于预警信息传输数量少,所以选取  $t_t = 0.001 \text{ s}$ , 驾驶辅助系统反应时间通常小于 1 ms, 所以选取  $t_r = 0.001 \text{ s}$ 。车辆在  $t_2$  时间结束时的速度  $v_{t_2}$  为:

$$v_{t_2} = v_0 + \int_0^{t_2} a dt = v_0 + \frac{1}{2} (a_{\max} - a_0) t_2 \quad (24)$$

式中:  $v_0$  为初速度;  $a_0$  为初始加速度; 最大制动减速度  $a_{\max} = -\mu g$ ,  $\mu$  为路面附着系数,取 0.8,  $g$  为重力加速度,取  $9.8 \text{ m/s}^2$ 。  $t_3$  时间段内保持最大制动减速度  $a_{\max}$ , 所以  $t_3$  可表示为:

$$t_3 = \frac{v_{t_2}}{a_{\max}} = \frac{v_0 + 0.12(a_{\max} - a_0)}{-\mu g} \quad (25)$$

所以驾驶员从产生反应到制动完成最小时间间隔为:

$$T_{\text{reaction}} = t_0 + t_1 + t_2 + t_3 + t_t = 0.841 + \frac{v_0 + 0.12(a_{\max} - a_0)}{-\mu g} \quad (26)$$

当  $TTC-S \geq T_{\text{reaction}}$  时,可通过预警的方式提示驾驶员采取制动措施避免发生碰撞,碰撞时间 TTC-S 越接近  $T_{\text{reaction}}$ , 发生碰撞的可能性越大。

#### 4.2.2 驾驶辅助系统制动避险时间确定

若驾驶员收到预警信息但未采取任何避险措施,此时 TTC-S 会逐渐降低,当  $TTC-S < T_{\text{reaction}}$  时,再依靠驾驶员采取制动行为已经无法避免碰撞的发生,因此,需要驾驶辅助系统的介入,接管车辆控制权进行制动,确保行车安全。相比于驾驶员接收到危险信息到采取制动措施所需时间,驾驶辅助系统所需时间较少。驾驶辅助系统从产生反应到制动完成最小时间间隔为:

$$T_{\text{assis}} = t_t + t_r + t_2 + t_3 = 0.242 + \frac{v_0 + 0.12(a_{\max} - a_0)}{-\mu g} \quad (27)$$

### 4.3 分级预警策略设计

ZHANG Yizhen 等<sup>[17]</sup>研究了驾驶员对意外的反应时间,通过数据分析把驾驶员反应时间近似拟合成了参数  $\mu$  和  $\sigma^2$  的对数正态概率分布,研究结果见表 7。

表 7 意外中驾驶人反应时间

预警类型	平均值	标准差	$\mu$	$\sigma^2$	75%	85%	90%
图像预警	1.13	0.52	1.03	0.44	1.38	1.62	1.80
声音预警	0.99	0.44	0.90	0.43	1.20	1.40	1.55
图像+声音	0.90	0.34	0.84	0.37	1.08	1.23	1.35

由表可知,驾驶员对图像预警的反应时间平均值为 1.13 s,对图像和声音联合预警的反应时间平均值为 0.9 s。因此,本文设计的分级预警策略的预警形式和阈值为:

1) 一级预警(图像预警), 阈值  $T_1 = T_{\text{reaction}} + 1.13 \text{ s}$ ;

2) 二级预警(声音+图像预警), 阈值  $T_2 = T_{\text{reaction}} + 0.9 \text{ s}$ ;

3) 三级预警 (驾驶辅助系统介入), 阈值  $T_3 =$

$T_{assist}$ 。

确定分级预警形式及阈值后, 通过对比基于预测轨迹碰撞检测得出的碰撞时间 TTC-S 和分级预警阈值  $T_1$ 、 $T_2$ 、 $T_3$  来确定分级预警形式。本文设计的分级预警策略如图 12 所示。

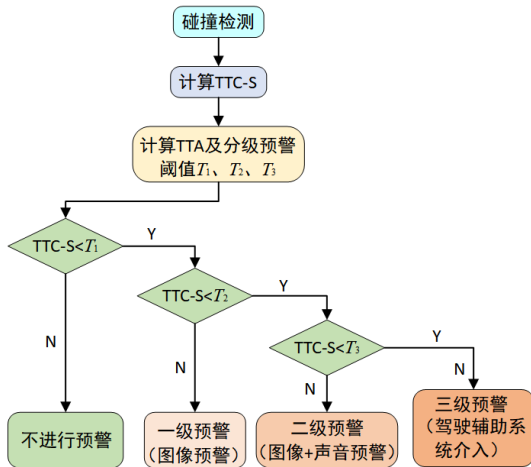


图 12 分级预警策略

1) 当  $TTC-S < T_1$  时, 采用图像预警方式对驾驶员进行一级预警。

2) 当  $TTC-S < T_2$  时, 预警级别由一级升为二级, 采用图像与声音联合预警方式对驾驶员进行预警。

3) 当  $TTC-S < T_3$  时, 预警级别升至三级, 此时驾驶辅助系统介入接管车辆执行制动操作。

## 5 试验及结果分析

### 5.1 前车换道切入工况下的防撞预警试验

本文基于 Simulink、PreScan 搭建驾驶人在环的联合仿真平台, 并对所提出的切入防撞预警模型性能进行了测试。如图 13 所示, 利用 Simulink 建立包括换道意图模型、轨迹预测模型 V2X 通信收发模型和 Collision Detection 模型; 利用 PreScan 中 V2X 无线通信设备实现 V2V, 并建立基于 G29 驾驶模拟器的双驾驶员仿真场景; 本车和目标车均采用软件自带的汽车动力学模型; 最后将不同模型在 Simulink 中进行整合。

本文设计的人机预警界面如图 14 所示, 当车辆处于危险工况时, 界面会显示当前车速、碰撞时

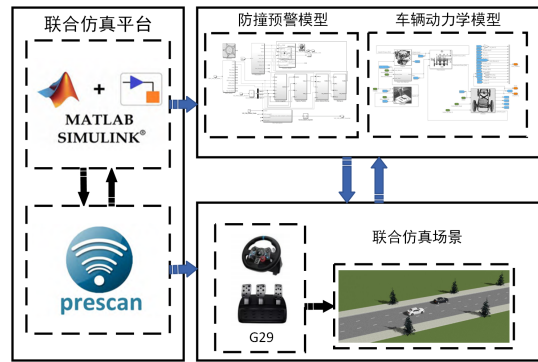


图 13 联合仿真平台

间 TTC-S 以及危险等级, 实现对驾驶员的预警。试验中, 本车和目标车驾驶员分别通过两台接入 PreScan 的 G29 模拟器操控相应车辆, 实现双驾驶员仿真, 操作平台如图 15 所示。




图 14 人机预警界面



图 15 双驾驶模拟器操作平台

本研究在模拟城市道路环境中进行数据采集和试验。试验场景包括多条车道、交通信号灯等典型城市道路特征。本文测试工况为前车换道切入本车车道, 仿真场景道路长度 3 000 m, 车道数为 3, 车道宽度为 3.5 m; 试验人员为 10 名拥有 C1 驾驶证的驾驶员, 2 人一组, 共 5 组试验人员。驾驶员生理和心理均无疾病, 精神状态良好, 且试验前一天告

知驾驶员避免熬夜、饮酒等, 保证充足的睡眠参加此次试验。试验中, 驾驶员控制车辆在仿真场景中进行换道操作。如图 16 所示, 车道 1 为目标车, 车道 2 为本车, 目标车与本车在初始起点相距 200 m。两车同时从起点出发, 本车加速至  $v_h$  保持匀速直线行驶, 目标车加速至  $v_t$  保持匀速直线行驶, 设置速度  $v_h = v_t + 10 \text{ km/h}$ ; 本车与目标车相对纵向距离逐渐缩小, 当目标车驾驶员通过后视镜发现本车后, 选择合适的时间点换道并入车道 2, 制造近距离危险换道情况。在目标车换道过程中, 本车不采取制动操作, 通过驾驶辅助系统进行制动。




图 16 前车换道切入工况试验

试验分为 5 组不同车速进行, 设置第 1 组本车速度  $v_h = 40 \text{ km/h}$ , 其余 4 组本车速度依次增加  $10 \text{ km/h}$ , 每组车速采集 60 次换道切入事件样本数据, 5 组试验人员共计采集 1 500 组样本数据, 每组速度所得试验数据按照比例 8:2 分为训练集与测试集。试验过程中, 通过 Collision Detection 模块观察换道切入过程两车是否发生碰撞。统计碰撞次数, 并记录碰撞时本车速度  $v_{\text{end}}$ 。同时, 以  $50 \text{ Hz}$  的频率提取目标车越过车道线前后各  $15 \text{ s}$  的连续数据作为数据样本。

为验证所提出的防撞预警模型的有效性, 选取了两种模型进行对比, 分别是基于安全距离的 Mazda 模型<sup>[18]</sup>和基于碰撞时间固定阈值的传统 TTC 模型。

## 5.2 试验结果

由于本文仿真试验工况测试下每种模型均会发生预警的情况, 所以不统计预警漏报情况, 则预警成功率计算如下:

$$R_T = \frac{\eta_T}{N} \times 100\% \quad (28)$$

式中:  $\eta_T$  为预警情况下未发生碰撞的次数;  $N$  为触发预警的总次数。

本文对所提出的切入预警模型和两种对比模型

仿真测试结果进行了统计, 图 17 为各防撞预警模型的仿真试验预警成功率。由图可知, 本文提出的预警模型预警成功率在各组试验中都高于其他两种模型。经统计, 所提出的预警模型平均预警成功率为  $90.32\%$ , 较 Mazda 模型和传统 TTC 模型平均预警成功率分别提高了  $8.44\%$  和  $11.66\%$ 。接着, 本文对两种预警模型的预警提前时间进行了对比。如图 18 所示, 本文模型较 Mazda 模型和传统 TTC 模型平均预警时间分别提前  $1.42 \text{ s}$  和  $1.9 \text{ s}$ 。






图 17 预警成功率对比



(a) Mazda 模型



(b) 传统 TTC 模型

图 18 预警提前时间

两种预警模型仿真碰撞次数的对比, 如图 19 所示, 图中, 同一试验车速下, 本文模型较其他两种对比模型的碰撞次数明显减少。对于没有成功预警防撞的试验, 统计碰撞时的本车速度  $v_{\text{end}}$ , 如图 20 所示。本文模型较其他两种模型, 每组试验的平均碰撞速度更低, 一定程度上减轻了两车碰撞产生的危害。

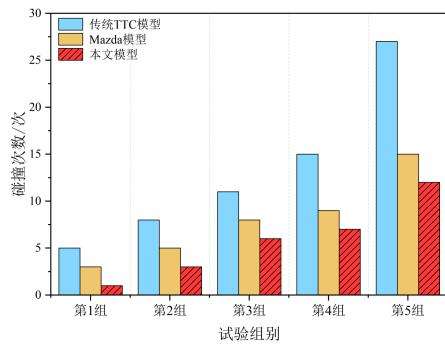





图19 仿真碰撞次数对比图



(a) 本文模型



(b) Mazda模型



(c) 传统TTC模型

图20 碰撞时本车速度对比

## 6 结论

本文提出了一种基于前车换道意图的切入防撞预警模型，利用车车通信技术将前方相邻车道目标车换道意图以及换道轨迹引入本车防撞预警模型中，并将其作为预警防撞判断和执行逻辑的重要依据。本文从预警成功率、预警提前时间等方面对模型性能进行评价。仿真结果表明，基于前车换道意图的切入防撞预警模型平均预警成功率为90.32%。较Mazda模型和传统TTC模型，本文模型平均预警成功率分别提高8.44%和11.66%，平均预警时间分别提前1.42 s和1.9 s，在应对前车突然换道切入工况时，具有更好的安全性。

## 参考文献 (References)

- [1] LI Guofa, LI S E, CHENG Bo, et al. Estimating of Driving Styles in Natural Highway Traffic Using Maneuver Transition Probabilities [J]. Transportation Research Part C: Emerging Technologies, 2017, 74: 113–125.
- [2] ZHANG Ruifeng, CAO Libo, BAO Shan, et al. A Method for Connected Vehicle Trajectory Prediction and Collision Warning Algorithm Based on V2V Communication [J]. International Journal of Crashworthiness, 2017, 22(1): 15–25.
- [3] YANG Wei, WAN Bo, QU Xiaolei. A Forward Collision Warning System Using Driving Intent Recognition of the Front Vehicle and V2V Communication [J]. IEEE Access, 2020, 8: 11268–11278.
- [4] 张凯, 刘军, 后士浩, 等. 基于Simulink的换道防撞预警建模与仿真分析 [J]. 重庆理工大学学报(自然科学), 2018, 32(2): 46–53.
- [5] ZHANG Kai, LIU Jun, HOU Shihao, et al. Modeling and Simulation Analysis of Lane Changing Anti-Collision Warning Based on Simulink [J]. Journal of Chongqing University of Technology (Natural Science), 2018, 32(2): 46–53. (in Chinese)
- [6] XU Guoyan, XIONG Yu, NIU Huan, et al. Collision-Warning System Integrated with Merging Behaviour Prediction Model Based on Multi-Sensor Fusion [J]. International Journal of Vehicle Design, 2021, 86(1–4): 143–161.
- [7] 黄慧玲, 杨明, 王春香, 等. 基于前方车辆行为识别的碰撞预警系统 [J]. 华中科技大学学报(自然科学版), 2015, 43(增刊1): 117–121.
- [8] HUANG Huiling, YANG Ming, WANG Chunxiang. Collision Warning System Based on Forward Vehicle Behavior Recognition [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2015, 43(Sup.1): 117–121. (in Chinese)
- [9] 刘飞龙, 郝文宁, 陈刚, 等. 基于双线性函数注意力Bi-LSTM模型的机器阅读理解 [J]. 计算机科学, 2017, 44

- (增刊1):92-96,122.
- LIU Feilong, HAO Wenning, CHEN Gang, et al. Attention of Bilinear Functional Based on Bi-LSTM Model for Machine Reading Comprehension[J]. Computer Science, 2017, 44(Sup.1):92-96, 122.(in Chinese)
- [8] 季学武, 费聪, 何祥坤, 等. 基于 LSTM 网络的驾驶意图识别及车辆轨迹预测[J]. 中国公路学报, 2019, 32(6): 34-42.
- JI Xuewu, FEI Cong, HE Xiangkun, et al. Intention Recognition and Trajectory Prediction for Vehicles Using LSTM Network [J]. Chinese Journal of Highway and Transport, 2019, 32(6):34-42.(in Chinese)
- [9] 赵建东, 赵志敏, 屈云超, 等. 轨迹数据驱动的车辆换道意图识别研究[J]. 交通运输系统工程与信息, 2022, 22(4):63-71.
- ZHAO Jiandong, ZHAO Zhimin, QU Yunchao, et al. Research on Trajectory Data-Driven Vehicle Lane Change Intention Recognition [J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(4):63-71.(in Chinese)
- [10] 张新锋, 王万宝, 柳欢, 等. 高速动态交通场景下自动驾驶车辆换道意图识别模型研究[J]. 汽车技术, 2023(4):8-15.
- ZHANG Xinfeng, WANG Wanbao, LIU Huan, et al. Research on Lane Change Intention Recognition Model of Automated Vehicle in High-Speed Dynamic Traffic Scenario[J]. Automobile Technology, 2023(4):8-15.(in Chinese)
- [11] FU Rui, ZHANG Zuo, LI Li. Using LSTM and GRU Neural Network Methods for Traffic Flow Prediction [C]//2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC), Nov. 11-13, 2016, Wuhan, China. Piscataway NJ: IEEE, c2016: 324-328.
- [12] 宋涛, 舒涛, 梅朝, 等. 基于空间分解与混合包围盒的碰撞检测算法[J]. 火力与指挥控制, 2016, 41(11):94-97.
- SONG Tao, SHU Tao, MEI Chao, et al. A Collision Detection Algorithm Based on Spatial Partitioning and Hybrid Bounding Box [J]. Fire Control & Command Control, 2016, 41(11):94-97.(in Chinese)
- [13] 史旭升, 乔立红, 朱作为. 基于改进 OBB 包围盒的碰撞检测算法[J]. 湖南大学学报(自然科学版), 2014, 41(5):26-31.
- SHI Xusheng, QIAO Lihong, ZHU Zuowei. Algorithm of Collision Detection Based on Improved Oriented Bounding Box [J]. Journal of Hunan University (Natural Science Edition), 2014, 41(5):26-31.(in Chinese)
- [14] LYU Nengchao, WEN Jiaqiang, DUAN Zhicheng, et al. Vehicle Trajectory Prediction and Cut-in Collision Warning Model in Connected Vehicle Environment [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 23(2):966-981.
- [15] 杨炜, 刘佳俊, 刘晶郁. 车联网环境下考虑前方车辆驾驶人意图的汽车主动预警防撞模型[J]. 机械工程学报, 2021, 57(22):284-295.
- YANG Wei, LIU Jiajun, LIU Jingyu. Active Anti-Collision Warning Model Considering the Driver's Intention of the Vehicle Ahead Under Internet of Vehicles [J]. Journal of Mechanical Engineering, 2021, 57(22):284-295.(in Chinese)
- [16] 胡艳, 樊亚云, 曹钻. 城市道路交叉口防碰撞预警的研究[J]. 无线互联科技, 2020, 17(8):137-138.
- HU Yan, FAN Yayun, CAO Zuan. A Study on Collision Prevention Warning for Urban Road Intersections [J]. Wireless Connectivity Technology, 2020, 17(8):137-138.(in Chinese)
- [17] ZHANG Yizhen, ANTONSSON E K, GROTE K. A New Threat Assessment Measure for Collision Avoidance Systems [C]//2006 IEEE Intelligent Transportation Systems Conference, Sept. 17-20, Toronto, Canada. Piscataway NJ: IEEE, c2006:968-975.
- [18] DOI A, BUTSUEN T, NIIBE T, et al. Development of a Rear-End Collision Avoidance System with Automatic Brake Control [J]. JSAE Review, 1994, 15(4):335-340.

## 作者简介



曹城铭 (1999-), 男, 黑龙江鸡西人, 硕士研究生, 主要研究方向为智能网联技术。

E-mail: 544254627@qq.com

## 通信作者



杨炜 (1985-), 男, 陕西渭南人, 博士, 讲师, 主要研究方向为智能网联技术和汽车主动安全技术。

E-mail: yw@chd.edu.cn