

基于时空风险场的自主换道决策模型

冯洋, 杨轶

(同济大学道路与交通工程教育部重点实验室, 上海 201804)

摘要: 针对高速公路环境中自主换道决策复杂且影响行车安全与运行稳定性的问题, 以及现有模型难以捕捉周围车辆的动态风险交互、无法充分刻画驾驶人意图的时间演化特征, 导致预测精度和泛化能力受限的不足, 提出一种融合时空风险场的自主换道决策模型。将时间序列车辆运动学、驾驶行为与风险表征相结合, 采用基于注意力机制的 LSTM 网络构建时空风险场集成换道模型 (SRF-DLC)。利用 highD 数据集中的 5 631 条轨迹 (时长 1~4 s) 进行训练, 预测车道保持、左侧变道和右侧变道三种操作行为。通过消融实验验证时空风险场的关键作用, 并与多种现有方法进行对比分析。以 3 s 历史轨迹训练的模型表现最优, 峰值准确率达到 96.74 %, 该时长与人类自然决策时间线吻合。消融实验表明, 去除时空风险场组件后准确率最大降幅达 47 %。与其他方法相比, SRF-DLC 模型在预测性能上具有明显优势, 显式引入时空风险上下文并合理选择历史轨迹长度是实现高精度自主换道预测的关键因素。

关键词: 自主换道决策; Attention LSTM; 时空风险场; highD 数据集

中图分类号: U471.15

文献标志码: A

A discretionary lane-change decision-making model based on spatiotemporal risk field

Feng Yang, Yang Zhen

(Experimental Teaching Center of Transportation Engineering, Tongji University, Shanghai 201804, China)

Abstract: Discretionary lane-changing (DLC) is a complex and safety-critical maneuver in highway driving that presents substantial challenges to traffic safety and operational stability. Accurately modeling DLC decisions remains difficult. Many existing approaches have limitations. They often fail to capture dynamic risk interactions with surrounding vehicles. They also inadequately model the temporal evolution of driver intent. These limitations often lead to limited prediction accuracy and generalizability. To address these gaps, we propose a new model, the Spatiotemporal Risk Field-integrated DLC (SRF-DLC) model. This model integrates time-sequential vehicle kinematics, driving behavior, and risk representation using an Attention-based LSTM network. The model was trained on trajectories from the highD dataset. We used 5,631 trajectories, each lasting 1 to 4 seconds. The model forecasts three maneuvers: lane-keeping, overtaking, and fold-down. Results show that the model trained on 3-second trajectories performs best. It achieves a peak accuracy of 96.74 %. This optimal history length aligns with natural human decision-making timelines. Ablation studies were also conducted. By that we confirm the critical role of the Spatiotemporal Risk Field. Excluding this component caused a significant drop in accuracy. The highest accuracy decrease reached 47 %. In comparisons, the SRF-DLC model outperformed some existing methods. This demonstrates that explicit spatiotemporal risk contextualization and appropriate history length selection is crucial in accurate DLC prediction.

Key words: Discretionary Lane Change; Attention LSTM; Spatiotemporal Risk Field; highD

换道是一种必要但存在风险的驾驶行为, 它能使驾驶人高效地到达目的地。根据决策动因, 驾驶人的换道决策可分为两大类: 强制性换道和自主性换道。强制性换道发生在驾驶人因道路设计或交通规则必须变换车道时, 例如在匝道附近、交织区或施工区域; 而自主性换道则是指驾驶人出于左侧变道慢车或调整

路线等原因自愿变换车道,所受限制相对较少。然而,换道操作会降低道路通行能力并显著增加碰撞风险,其中自主性换道因其不可预测性而尤为危险。这一突出的安全问题,使得换道行为,特别是自主性换道,成为交通安全工程领域的关键研究课题。已有大量研究提供了重要发现^[1-3]。

当前关于自主性换道的研究主要分为两种范式:统计/博弈论模型和机器学习模型,两者在可解释性与性能之间存在着固有权衡^[4]。其中,统计模型(包括基于模糊逻辑或效用理论的模型)具有较高的可解释性,近年来博弈论被广泛用于模拟换道的交互特性,将决策表述为车辆间的策略互动以生成安全协同的操作^[5,6];而机器学习模型则擅长从海量数据中学习复杂模式,例如深度神经网络(如 CNN-LSTM 混合模型)融合多模态数据预测意图^[7],强化学习框架通过与环境的交互学习最优策略^[8]。然而,高级机器学习模型的黑箱特性掩盖了决策逻辑并增加了故障诊断难度,引发了安全隐患。

尽管已有上述大量研究提供了重要发现,但现有模型仍存在以下重要局限:其一,有限的交互分析。多数模型对周围车辆的交互处理过于简化^[9],通常将交互简化为基于固定安全距离的静态规则判断,并假设所有驾驶人完全理性,忽略了真实换道过程中主车与目标车道后车之间持续的、相互影响的博弈过程;其二,风险度量的缺失。尽管风险感知是影响换道决策的关键因素,但多数模型缺乏明确、定量且动态的风险评估指标,现有风险场理论虽涵盖了静态能量场、动态动能场及驾驶人行为场^[10],但这些模型主要假设静态条件,忽略了连续驾驶过程中风险暴露所产生的累积心理效应,而换道决策本质上依赖于历史风险交互而非瞬时评估;其三,时间窗口及相关时序因素的量化分析不足。尽管换道被普遍认为是一个连续过程,但准确捕捉该行为所需的时间窗口持续时间尚无定论,现有研究虽尝试定义了自主换道操作的时间跨度并测试了最佳校准窗口^[11],但对于分析窗口长度如何影响对换道动态及其他时序因素(如风险场演变)的理解,仍缺乏充分的定量讨论。

为弥补上述不足,开发了一种基于时间风险场分析的自主性换道新模型——时空风险场(Spatiotemporal Risk Field, SRF)换道模型。该模型应用王建强等^[12]提出的风险场框架,系统评估 1 至 4 s 时间段内的驾驶风险,并通过组合短期风险评估构建时空维度的风险场,从而在预测驾驶人自主行为方面实现了更高的准确性。与传统模型相比,本模型的主要改进包括:第一,本模型突破了静态风险分析的局限,通过使用时序数据动态追踪风险模式,有效改进了对右侧变道、左侧变道和车道保持等连续换道行为的预测能力;第二,本模型首次定量分析了不同长度时间窗口下 SRF 对换道行为预测精度的影响,并分别比较了不同时间窗口内运动学参数对预测精度的贡献差异,为最佳时间窗口的选取提供了量化依据;第三,SRF 模型通过深入分析历史运动数据,量化了周围车辆对驾驶人决策的动态影响权重,使模型能够更精确地解析多车交互作用,从而实现更准确、更贴合实际驾驶认知的换道预测。

1 方法

1.1 数据准备

本研究数据集来自highD数据集,这是一个包含德国高速公路车辆轨迹记录的大规模自然驾驶数据集。为保证数据一致性,独立研究自主性换道,排除了有合流与分流路段的视频,从总计 63 个视频中选取了 43 个用于提取换道行为。

在数据提取过程中,首先需要对换道行为做出定义。换道过程涉及三个关键位置:换道决策点、换道起始点和换道完成点。以往研究常将横向速度超过 0.2 m/s 的时刻定义为换道起点^[13],然而,该标准可能

受车辆轨迹振荡的影响，导致误判。为解决此问题，通过选取横向坐标持续变化直至完成点（记为 T_{cross} ）的轨迹来识别换道轨迹。将横向速度首次超过 0.2 m/s 的数据点标记为换道起始点 T_{start} 。此外，考虑到典型驾驶人反应时间，将换道决策点设置为换道起始点前 1 s，记为 $T_{willing}^{[14]}$ 。在图 1 中， E 为自车， P 为前车； PL 为左前车； PR 为右前车； FL 为左后车； FR 为右后车； F 为后车。 T_{cross} 为换道完成点， T_{start} 为换道起始点， $T_{willing}$ 为换道决策点。

在确定换道意图点、换道起始点和换道穿越点后，以换道穿越点为参考，选取 1~4 s 内的数据进行训练和评估，这与先前研究^[15]所确立的典型驾驶人反应时间一致。

训练数据集共含有 5,631 条轨迹，涵盖车道保持、左侧变道和右侧变道行为。后两种行为根据非强制区域内的车道索引变化进行识别。为减轻数据不平衡可能导致的模型偏差，通过欠采样将各类行为样本数平衡至最少类别样本数量。

在每 1 s 的数据中，包含两类数据：一类是换道影响因素，另一类是时空感知风险场。两类数据将在以下章节详述。




图 1 换道意图分析

Fig.1 Lane change intention analysis

1.2 换道影响因素

在换道过程中，行驶在 3 条车道上的车辆可选择左侧变道或右侧变道。在 highD 数据集中，这表现为车辆向左变道进入快车道或向右变道进入慢车道。这些自主性换道行为受三大因素影响：效益、安全性和容忍度，如图 2 所示， D_{PL} 、 D_{PR} 、 D_P 、 D_{FL} 、 D_{FR} 分别为各车至自车的距离； V_{PL} 、 V_{PR} 、 V_P 、 V_{Ex} 、 V_F 、 V_{FL} 、 V_{FR} 分别为各车 X 轴方向的速度。




图 2 换道意图分析

Fig.2 Lane change intention analysis.

1) 效益因素

$$f_{benefit} = f(V_{Ex} - V_P, V_{PL} - V_P, V_{PR} - V_P, D_{PR} - D_P, D_{PL} - D_P) \quad (1)$$

公式(1)给出了 $f_{benefit}$ 的表达式, 代表驾驶人对换道决策的效益判断。其中主要影响换道决策的因素包括: $V_{Ex} - V_P$ 为自车速度与前车速度之差, 其值反映了自车速度相对于前车速度的大小, 影响驾驶人换道倾向; $V_{PL} - V_P$ 与 $V_{PR} - V_P$ 分别表示左前车、右前车与前车的速度差, 驾驶人通过观察这三辆车的速度差来确定换道方向; $D_{PR} - V_P$ 与 $D_{PL} - V_P$ 分别表示左前车、右前车与前车之间的距离差, 距离差的增大将增强驾驶人向相应方向换道的意愿。

2) 安全因素

$$f_{safety} = f(V_{Ex} - V_{FL}, V_{Ex} - V_{FR}, D_{FL}, D_{FR}) \quad (2)$$

公式(2)给出了 f_{safety} 的表达式。其中 $V_{Ex} - V_{FL}$ 、 $V_{Ex} - V_{FR}$ 为影响换道安全性的速度因素, 分别表示左后车、右后车与前车的速度差, 其值越大, 换道过程中的冲突可能性越大, 风险也越高; D_{FL} 、 D_{FR} 分别表示左后车、右后车与前车之间的距离差, 距离差减小会缩短换道过程中的反应时间并增加风险。

3) 容忍度因素

$$f_{tolerance} = f(D_P - V_{Ex} \times t_h) \quad (3)$$

公式(3)给出了 $f_{tolerance}$ 的表达式, 其中 D_P 为自车到前车距离, t_h 为自车与同车道前车的车头时距。它解释了驾驶人如何评估当前车道的行驶状况, 这与后方车辆的安全距离以及与前车的距离密切相关。驾驶人在高速公路上可能选择保持比推荐安全距离更大的间距, 以使驾驶体验更加舒适。

4) 自车与周围车辆换道指标的最终选取

最后, 在纳入车辆运动学指标后, 选取了以下 19 个与换道因素相关的特征, 其中动力学要素包括速度、加速度、加加速度。它们分别是位移对时间的一阶、二阶、三阶导数, 速度描述自车的运动状态与行

驶节拍，是跟驰与换道决策的基础变量。加速度由牛顿第二定律直接正比于合力，反映驾驶人操纵输出的强弱，是纵横向受力状态的直观体现。加加速度是加速度对时间的导数，反映操纵输出本身的变化率，刻画加速度是以多快的速度建立或消退的。引入加加速度特征后，可基于前后时刻横向加速度的变化对轨迹误差进行补偿，提升路径跟踪性能^[16]。过往的研究中，加加速度亦被用于驾驶人意图的估计，驾驶人在操纵车辆时，其动作爆发与加加速度信号同步。此外，乘员舒适性实验证实，不适感同时取决于加速度幅值与加加速度，更高的加加速度会带来更明显的顿挫与不适。

具体使用指标如表 1 所示。

表 1 换道指标特征

Tab.1 Features of lane change indicators

特征	描述
x	自车 X 轴坐标
y	自车 Y 轴坐标
V_{Ex}	自车 X 轴速度
V_{Ey}	自车 Y 轴速度
自车特征	a_{Ex} 自车 X 轴加速度
	a_{Ey} 自车 Y 轴加速度
	$Jerk_{Ex}$ 自车 X 轴加加速度
	$Jerk_{Ey}$ 自车 Y 轴加加速度
	t_h 自车与同车道前车的车头时距
效益因素	$V_{Ex} - V_P$ 自车 X 轴速度减去前车速度
	$V_{PL} - V_P$ 左前车速度减去前车速度
	$V_{PR} - V_P$ 右前车速度减去前车速度
	$D_{PR} - D_P$ 自车到右后车的距离减去自车到前车的距离
	$D_{PL} - D_P$ 自车到左后车的距离减去自车到前车的距离
安全因素	$V_{Ex} - V_{FL}$ 自车 X 轴速度减去左后车速度
	$V_{Ex} - V_{FR}$ 自车 X 轴速度减去右后车速度
	D_{FR} 自车到右后车的距离
	D_{FL} 自车到左后车的距离
忍耐因素	$D_P - V_{Ex} \times t_h$ 自车到前车距离减去自车 X 轴坐标乘以自车与前车的时间间隙

3.3 时空风险场

按照 Wang 等^[10]和 Kolekar 等^[17]提出的方法，并结合 Li 等^[18]风险场理论的修改，计算了坐标系中每个坐标处的风险场强度。风险场计算公式见式(4)~式(9)，所有参数均参照所述文献中的方法进行标定。

$$M_i = m \cdot \left(1.566 \left(|v| \cdot 3.6 \right)^{6.687} \cdot 10^{-14} + 0.3345 \right) \quad (4)$$

式中： M_i 为等效质量，定义为车辆自身属性，由高速公路事故数据、速度数据和车辆分布数据得出，用于评估车辆对驾驶人构成的潜在风险。 m_i 为道路上车辆的平均质量，小型车为 1.5 t，大型车为 20 t^[19]。

$$E_{vehicle} = M_i \lambda \frac{e^{-\beta \alpha \cos \theta}}{|l'|} \quad (5)$$

$$|l'| = \sqrt{\left[(x-x_0)\frac{\tau}{e^{\alpha v}}\right]^2 + [(y-y_0)\tau]^2} \quad (6)$$

式中： $E_{vehicle}$ 为周围车辆对自车的影响强度， λ 、 β 和 α 为常数， l' 为修正距离，描述车辆从不同角度接近目标车辆时风险水平的变化； τ 为安全距离的临界阈值， v 表示车辆当前速度， e 为自然对数的底数。

$$E_{lane} = A_i \cdot e^{\frac{-(d_{Aj}^L)^2}{2\sigma^2}} \cdot \frac{d_{Aj}^L}{|d_{Aj}^L|} \quad (7)$$

式中： E_{lane} 为车道线产生的势场强度， A_i 为不同车道标线的势场强度系数， d_{Aj}^L 为自车指向车道线的距离向量， σ 决定车辆靠近或远离车道线时势场强度值增减的速率。

$$E_{border} = \frac{1}{2} \cdot \eta \frac{1}{|d_{Aj}^S|^2} \cdot \frac{d_{Aj}^S}{|d_{Aj}^S|} \quad (8)$$

式中： E_{border} 为道路边界场的风险场强度， d_{Aj}^S 为自车指向道路边界的距离向量， η 为道路边界场系数。

$$E_{field} = (E_{lane} + E_{border} + E_{vehicle}) \quad (9)$$

式中： E_{Field} 为最终计算得到的风险场强度。对轨迹内所有数据帧计算 E_{Field} ，得到风险场的时空分布，记为时空风险场（Spatiotemporal Risk Field, SRF）。

在 highD 数据集中，数据采集帧率为 25Hz，即每 1 s 包含 25 个数据帧。参考了 Kolekar 等^[20]的研究，对每一数据帧 t ，均以该帧自车质心为原点、车辆行驶方向为 X 轴正向建立自车坐标系，并在该坐标系下计算风险场。具体而言，对于一帧情况沿 X 轴取自车前方 30 m、后方 10 m 的范围，以 5 m 为步长离散化，得到 9 个纵向采样位置；横向取 7 个采样位置，从而构成 7×9 的风险场网格。

为构建时空训练样本，以行为事件的关键点为时间锚点，向前截取 1 至 4 s 的连续数据帧。在 highD 数据集内，这一历史时空数据序列长度覆盖的范围在 30m 到 120m 不等，实质上等价于提取驾驶人在不同前瞻距离做出决策的轨迹长度。跟驰轨迹在满足帧数充足的范围内随机取点作为关键点，变道轨迹则定位变道意图点，生成同一事件下 1 至 4 s 逐渐变长的历史轨迹片段，并附变道的左右方向类别与时长标签。

1.3 模型架构

基于上述结果，得到换道模型有如下方程所示

$$y = f_{LC}(\sum_0^N f_{benefit}, f_{safety}, f_{tolerance}, E_{Field}) \quad (10)$$

式中： N 为 1~4 s 轨迹内的所有数据点， f_{LC} 为多参数非线性变化函数，可通过神经网络方法确定。在此基础上，开发了 SRF-DLC 模型，将其视为一个利用时空数据进行预测的有监督分类学习问题。详细模型结构如图 3 所示。

该模型包含特征提取模块、双向长短期记忆（Bi-LSTM）网络，以及用于序列建模和分类的多头自注意力机制。输入序列在进入最终分类阶段之前，逐步转换为分类结果。

架构始于由两个全连接（FC）层组成的特征提取层。该模块通过使用 ReLU 激活函数和 dropout 正则化的非线性变换，将输入特征投影到 64 维空间，从而为输入特征提供基础编码。得到的表征随后传入堆叠的 Bi-LSTM 层，以捕获序列中的时间依赖关系。

在进一步处理之前，表征经过维度调整层，以确保在多头注意力层中，数据完全可整除。随后，序列由多头自注意力层处理，该层对 LSTM 输出的所有时间步计算动态的、上下文相关的权重，使模型能够强调与分类任务相关的信息片段。缩放点积注意力融入了稳定性增强措施，并对注意力权重应用 dropout 以防止过拟合。注意力层之后，自适应平均池化压缩序列维度，最终分类层将精炼后的表征映射到输出类别。




图 3 SRF-DLC 模型架构

Fig.3 SRF-DLC Model architecture

采用交叉熵函数作为损失函数，Adam 作为优化器，权重衰减设为 $5e-4$ ，并在训练过程中设置早停机制。不同轨迹长度下各模型的超参数使用微软神经网络智能（NNI）工具进行优化，搜索算法为 TPE，共进行 100 次试验。在 NNI 超参数优化中，各轨迹长度的最优模型训练超参数如表 2 所示。

表 2 1~4 s 轨迹各模型最优超参数

Tab. 1 Optimal hyperparameters for each model on 1-4s trajectory		
模型	超参数	取值
1s-SRF-DLC	堆叠 Bi-LSTM 层数	3 层 Bi-LSTM 堆叠
	维度调整层	Linear (256,256)
	多头注意力层数	1 个注意力头
	学习率	0.0022
	批大小	32
	Dropout 率	0.1021
2s-SRF-DLC	堆叠 Bi-LSTM 层数	4 层 Bi-LSTM 堆叠
	维度调整层	Linear (128,126)
	多头注意力层数	3 个注意力头
	学习率	0.0048
	批大小	128
	Dropout 率	0.2727
3s-SRF-DLC	堆叠 Bi-LSTM 层数	3 层 Bi-LSTM 堆叠
	维度调整层	Linear (256,252)
	多头注意力层数	6 个注意力头
	学习率	0.0014
	批大小	32
	Dropout 率	0.125
4s-SRF-DLC	堆叠 Bi-LSTM 层数	3 层 Bi-LSTM 堆叠
	维度调整层	Linear(256,256)
	多头注意力层数	4 个注意力头
	学习率	0.0033
	批大小	128
	Dropout 率	0.262

2 结果

2.1 轨迹长度影响分析

如表 3 所示，SRF-DLC 模型在 3 s 预测时域下对换道行为达到了峰值预测精度（总体准确率 96.74 %）。该性能优于较短（1、2 s）和较长（4 s）预测窗口。与 1 s 模型相比，3 s 模型在正确识别车道保持行为方面表现出尤为显著的提升（准确率 92.80 %），同时对于左侧变道等意图性行为保持了较高准确率（98.64 %）。而在 4 s 标记处性能的下降表明存在一个时间阈值，超过该阈值后预测确定性降低。

表 3 不同轨迹长度的 SRF-DLC 模型预测精度对比
Tab. 2 Prediction accuracy comparison for SRF-DLC models of different track lengths

		%			
模型	预测值	车道保持	左侧变道	右侧变道	总体准确率
	真实值				
1s-SRF-DLC	车道保持	82.35	1.38	16.26	93.69
	左侧变道	0.91	98.79	0.30	
	右侧变道	1.27	0.00	98.73	
2s-SRF-DLC	车道保持	88.10	0.74	11.15	95.72
	左侧变道	0.37	98.90	0.73	
	右侧变道	0.00	0.00	100.00	
3s-SRF-DLC	车道保持	92.80	0.80	6.40	96.74
	左侧变道	1.36	98.64	0.00	
	右侧变道	0.85	0.00	99.15	
4s-SRF-DLC	车道保持	89.04	1.37	9.59	94.32
	左侧变道	1.60	96.26	2.14	
	右侧变道	1.04	0.52	98.45	

2.2 SRF 对性能提升的影响

如表 4 所示，移除 SRF 会导致 DLC 模型在不同时间范围和类别上的预测准确率出现显著但不均匀的下降。最严重的性能退化出现在 2 s 预测时域，总体准确率骤降 47.01 %。这凸显了 SRF 的中期风险识别能力在确保模型稳定预测方面的关键作用。尤其值得注意的是，在 2 s 时域下，左侧变道行为的预测几乎完全失效，准确率下降 98.90 %，同时伴随大量误分类为车道保持（+74.72 %）和右侧变道（+24.18 %），这表明在缺少 SRF 提供的上下文风险线索时，模型辨别交互复杂性较高的左侧变道意图的能力严重受损。相比之下，3 s 时域波动相对较小（总体准确率仅下降 0.85 %），表明较长的时间窗口可能部分弥补风险信息缺失。尽管如此，SRF 的贡献效应仍然明显。

表 4 无 SRF 的不同轨迹长度 DLC 模型预测准确率变化
Tab.3 Prediction accuracy change for DLC models without SRF of different track lengths

					%
模型	预测值	车道保持	左侧变道	右侧变道	总体准确率
	真实值				
1s-DLC	车道保持	-2.42	0.00	+2.43	-0.53
	左侧变道	+0.60	-0.60	0.00	
	右侧变道	-1.27	0.00	+1.27	
2s-DLC	车道保持	-10.40	-0.74	+11.15	-47.01
	左侧变道	+74.72	-98.90	+24.18	
	右侧变道	31.27	0.00	-31.27	
3s-DLC	车道保持	-3.60	0.80	+2.80	-0.85
	左侧变道	-1.36	+0.91	+0.45	

模型	预测值 真实值	车道保持	左侧变道	右侧变道	总体准确率
4s-DLC	右侧变道	-0.42	0.00	+0.42	-1.50
	车道保持	+9.13	-0.46	-8.68	
	左侧变道	+3.75	-1.61	-2.14	
	右侧变道	+13.99	-0.52	-13.48	

2.3 模型性能对比

将最优的 3s-SRF-DLC 模型与多种现有换道模型进行了比较，包括 MOBIL^[21]、SVM^[22]、SVM-GMM-HMM^[23]、DSA-DLC^[24]、Attention Enhanced Residual-MBi-LSTM^[25]。每个模型均按照各自原始文献中的配置细节进行实现。为确保公平比较，所有模型均在同一数据集上评估。然而，由于部分研究中某些参数或训练细节报告不完整，此处呈现的性能结果可能与原始文献报道有所差异。对比结果汇总于表 5，表明 3s-SRF-DLC 的性能更优。总体而言，3s-SRF-DLC 表现最佳，总错误率为 3.26 %，准确率为 96.74 %。SRF-DLC 在除右侧变道预测外的所有类别上均优于 DSA-DLC，后者在右侧变道预测上差异为 4.06 %。

表 5 对比模型的换道预测精度
Tab. 4 Prediction accuracy of lane keeping, overtake and fold-down for the models in comparison

模型	预测值 真实值	车道保持	左侧变道	右侧变道	总体准确率
3s-SRF-DLC	Keep	92.80	0.80	6.40	96.74
	Overtake	1.36	98.64	0.00	
	Fold-down	0.85	0.00	99.15	
DSA-DLC	Keep	90.86	6.63	8.17	92.68
	Overtake	5.38	93.37	0.00	
	Fold-down	3.76	0.00	91.83	
SVM	Keep	73.63	17.92	10.53	81.03
	Overtake	10.95	81.50	1.05	
	Fold-down	15.42	0.58	88.42	
SVM-GMM-HMM	Keep	52.88	20.04	27.08	72.11
	Overtake	9.73	87.10	3.17	
	Fold-down	14.99	8.78	76.23	
Attention Enhanced Residual-MBi-LSTM	Keep	87.20	13.57	100	51.95
	Overtake	9.15	37.69	0.00	
	Fold-down	3.66	48.74	0.00	
MOBIL	Keep	31.03	39.46	46.15	36.70
	Overtake	15.52	44.06	38.46	
	Fold-down	53.45	16.48	15.38	

3 讨论

3.1 与人类决策时间线的一致性

SRF-DLC 模型在 3 s 时域下观察到的预测精度峰值，似乎与自然驾驶研究中关于人类驾驶人换道操作认知时间线的发现一致。现有文献表明，换道的准备阶段（包括情境评估、后视镜检查和初步驾驶规划）通常发生在执行前 2~3 s 内^[26]。3 s 模型的表现可能表明其能够捕捉到在 1 s 时域尚不明显、且由于不确定性增加而可能变得难以区分的细微行为前兆。

这种时间对应关系表明，3s-SRF-DLC 模型在一定程度上反映了人类驾驶人的认知过程，即意图在机动开始前约 3 s 趋于更清晰和更具可操作性。4 s 时域准确率的下降可能进一步表明存在一个时间阈值，超过此阈值后维持预测确定性更为困难。

3.2 误差模式反映行为约束

不同时间域上预测误差的分布可能揭示换道决策中固有的行为约束。在 1 s 时域观察到的车道保持与右侧变道之间的混淆，可能反映了意图形成的早期阶段，此时驾驶人可能正在考虑但尚未决定换道。这种模糊性在 3 s 模型中似乎有所降低，这与驾驶人意图通常变得更可辨别的时刻相吻合。

随着训练轨迹时长从 1 s 增加到 3 s，模糊的行为模式逐渐变得清晰，最清晰的意图度量在 3 s 内被捕获。然而，3 s 之后预测精度下降，表明超过 3 s 的轨迹包含更多无用信息。

3.3 时空风险场的作用

时空风险场（SRF）在概念上受时间序列图像识别技术的启发。它可被视为一个综合计算框架，将特定时间窗口内的运动学、几何学和行为学线索编码为统一的风险表示。这种表述自然反映了驾驶人的连续风险感知过程：通过持续观察驾驶环境、识别潜在风险因素，随后导航至风险较低的区域。

消融实验证实，移除 SRF 导致预测性能显著下降，特别是在 2 s 时域，总体准确率下降 47.01 %。在缺少 SRF 的情况下，左侧变道预测精度的严重退化（下降 98.90 %）凸显了其在交互复杂性较高场景中的关键作用。相比之下，在 3 s 时域移除 SRF 后观察到的性能变化相对较小（仅下降 0.85 %），这可能表明较长的观察窗口可以通过随时间累积足够的行为证据，部分弥补显式风险编码的缺失。

4 结论

提出了一种时空风险场增强的自主性换道（SRF-DLC）模型，以提高车辆换道行为的预测精度。基于从 highD 数据集中提取的 5,631 条 1~4 s 多样化轨迹（包括车道保持、左侧变道和右侧变道行为）的平衡数据集训练模型并评估，得出以下结论：

- 1) SRF-DLC 模型在 3 s 预测时域下表现最佳，总体准确率达 96.74 %。这表明 3 s 窗口可能与人类驾驶决策的自然时间线更为吻合，在此期间行为意图变得可辨别，但尚未被累积的不确定性所掩盖。
- 2) 时空风险场的引入对预测稳定性贡献显著，尤其是在左侧变道等交互场景中。消融研究表明，缺少 SRF 导致 2 s 时域准确率显著下降（下降 47.01 %），凸显了其在提供上下文风险线索方面的作用。
- 3) 与 DSA-DLC、SVM 和 MOBIL 等现有模型相比，3s-SRF-DLC 模型表现出具有竞争力的性能，尤其在左侧变道意图分类方面，尽管在右侧变道预测方面相对于 DSA-DLC 略有不足。

这些发现表明，时空风险表示的整合可以通过纳入类似于人类驾驶人使用的安全上下文信息来增强行

为预测模型。该模型对高级驾驶辅助系统和自动驾驶技术具有实际应用价值，在这些领域中，准确和早期的意图预测有助于在动态交通环境中实现更安全的交互。

未来研究应聚焦于将模型扩展到更广泛的道路环境和交通条件。纳入基于个体驾驶风格的个性化风险表示的适应机制，可提高实际应用性。此外，探索实时学习技术以动态更新风险场，可能进一步提升预测精度和鲁棒性。

5 局限性

- 1) 由于计算限制，本研究在使用更大规模数据集方面受到制约。未来研究将纳入 NGSIM 等数据集，通过扩展训练和验证数据来增强模型的泛化能力。
- 2) 当前换道模型对右侧变道和车道保持行为的预测精度不足。未来研究将更深入地探索这些行为，并提出新的指标以更好地表征它们。同时，考虑到 Attention Enhanced Residual MBI-LSTM 模型在右侧变道预测中的高表现，这可能与该模型中的梯度爆炸问题有关。
- 3) 模型主要在高速公路驾驶数据上进行训练
- 4) 和评估，其对其他高速公路场景的泛化能力
- 5) 仍有待验证。
- 6) 本研究未考虑驾驶人的出行意愿和个性特征对驾驶任务和风险感知的影响。然而，个性特征显著影响个体承担驾驶风险的倾向（Zinn, 2019）。未来研究应通过驾驶模拟或实车实验探索驾驶人个性和驾驶风格如何影响换道决策。

参考文献：

- [1] Zhaohan Wang, Mohsen Ramezani, David Levinson. How mandatory are ‘Mandatory’ lane changes? An analytical and experimental study on the costs of missing freeway exits [J]. *Transportation Research Part B: Methodological*, 2024, 186: 102994.
- [2] 范泽敏, 吴翊恺, 王晨菡. 基于深度强化学习的智能车辆风险评估决策模型 [J]. *华东交通大学学报*, 43(1): 82-92.
WuYikai Fan Zemin, Wang Chenhan. Intelligent Vehicle Risk Assessment Decision Model Based on Deep Reinforcement Learning [J]. *Journal of East China Jiaotong University*, 43(1): 82-92.
- [3] 关书睿, 李志强, 周俊宇, 等. 面向强制换道场景的智能网联汽车协同换道策略 [J]. *汽车工程*, 2024, 46(2): 201-210.
Guan Shurui, Li Keqiang, Zhou Junyu, Shi Jia, Kong Weiwei & Luo Yugong. A Cooperative Lane Change Strategy for Intelligent Connected Vehicles Oriented to Mandatory Lane Change Scenarios [J]. *Automotive Engineering*, 2024, 46(2): 201-210.
- [4] Ang Ji, David Levinson. A review of game theory models of lane changing [J]. *Transportmetrica A: transport science*, 2020, 16(3): 1628-1647.
- [5] Fan Guo, Xiao Han, Kang Song, et al. Game theory-based harmonious decision-making for autonomous bus lane change [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2025, 26(4): 4934-4947.
- [6] Victor G Lopez, Frank L Lewis, Mushuang Liu, et al. Game-theoretic lane-changing decision making and payoff learning for autonomous vehicles [J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(4): 3609-3620.

- [7] 贾寒冰, 刘鹏, 张雷, 等. 基于规则与机器学习融合的换道决策建模方法研究 [J]. 机械工程学报, 2022, 58(4): 212-221.
Liu Peng Jia Hanbing, Zhang Lei, Wang Zhenpo. Lane-changing Decision Model Development by Combining Rules Abstract and Machine Learning Technique [J]. Journal of Mechanical Engineering, 2022, 58(4): 212-221.
- [8] 姚福星, 李浩宇, 冷江昊, 等. 面向多场景高速公路的多专家学习自主换道决策方法 [J]. 机械工程学报, 2025, 61(22): 198-210.
Li Haoyu Yao Fuxing, Leng Jianghao, Yang Xiongji, Sun Chao. Multi-expert Learning Method for Autonomous Lane-changing Decision-making in Multi-scenario Highway Environments [J]. Journal of Mechanical Engineering, 2025, 61(22): 198-210.
- [9] Weiwei Qi, Wei Wang, Bin Shen, et al. A modified post encroachment time model of urban road merging area based on lane-change characteristics [J]. IEEE Access, 2020, 8: 72835-72846.
- [10] Jianqiang Wang, Jian Wu, Xunjia Zheng, et al. Driving safety field theory modeling and its application in pre-collision warning system [J]. Transportation research part C: emerging technologies, 2016, 72: 306-324.
- [11] Yasir Ali, Zuduo Zheng, Michiel CJ Bliemer. Calibrating lane-changing models: Two data-related issues and a general method to extract appropriate data [J]. Transportation research part C: emerging technologies, 2023, 152: 104182.
- [12] 王建强, 吴剑, 李洋. 基于人-车-路协同的行车风险场概念、原理及建模 [J]. 中国公路学报, 2016, 029(001): 105-114.
Wu Jian Wang Jian-qiang, Li Yang. Concept, Principle and Modeling of Driving Risk Field Based on Driver-vehicle-road Interaction [J]. China Journal of Highway and Transport, 2016, 029(001): 105-114.
- [13] Oliver Scheel, Loren Schwarz, Nassir Navab, et al. Situation assessment for planning lane changes: Combining recurrent models and prediction; proceedings of the 2018 IEEE International Conference on Robotics and Automation (ICRA), F, 2018 [C]. IEEE,
- [14] Marc Green. "How long does it take to stop?" Methodological analysis of driver perception-brake times [J]. Transportation human factors, 2000, 2(3): 195-216.
- [15] 孙剑, 王洁, 蒋溪彦, 等. 自动驾驶汽车驾驶人分阶段接管反应时间预测 [J]. 中国公路学报: 1-25.
Wang Jie Sun Jian, Jiang Xiyan, Shi Haotian, Li Zirui, Zhao Xiacong. Stage-Specific Prediction of Driver Takeover Reaction Time in Autonomous Vehicles [J]. China Journal of Highway and Transport: 1-25.
- [16] 黄晶, 刘祥臻, 邓潇阳, 等. 基于多模态轨迹预测的智能车轨迹规划研究 [J]. 汽车工程, 2024, 46(6): 965-974.
Xiangzhen Liu Jing Huang, Xiaoyang Deng, Ran Chen. Research on Intelligent Vehicle Trajectory Planning Based on Multimodal Trajectory Prediction [J]. Automotive Engineering, 2024, 46(6): 965-974.
- [17] Sarvesh Kolekar, Joost de Winter, David Abbink. Human-like driving behaviour emerges from a risk-based driver model [J]. Nature Communications, 2020, 11(1): 4850.
- [18] Linheng Li, Jing Gan, Ziwei Yi, et al. Risk perception and the warning strategy based on safety potential field theory [J]. Accident Analysis & Prevention, 2020, 148: 105805.
- [19] Andreas Humpe, Stefan Gössling, Sonja Haustein. Car careers: A socio-psychological evaluation of aspirational automobile ownership [J]. Transportation Research Part A: Policy and Practice, 2022, 164: 156-166.
- [20] Sarvesh Kolekar, Joost de Winter, David Abbink. Which parts of the road guide obstacle avoidance? Quantifying the driver's risk field [J]. Applied ergonomics, 2020, 89: 103196.

- [21] Arne Kesting, Martin Treiber, Dirk Helbing. General lane-changing model MOBIL for car-following models [J]. Transportation Research Record, 2007, 1999(1): 86-94.
- [22] Yonggang Liu, Xiao Wang, Liang Li, et al. A novel lane change decision-making model of autonomous vehicle based on support vector machine [J]. IEEE access, 2019, 7: 26543-26550.
- [23] Omveer Sharma, Nirod C Sahoo, Niladri B Puhan. Highway lane-changing prediction using a hierarchical software architecture based on support vector machine and continuous hidden markov model [J]. International Journal of Intelligent Transportation Systems Research, 2022, 20(2): 519-539.
- [24] Hanyi Yu, Shuning Huo, Mengran Zhu, et al. Machine learning-based vehicle intention trajectory recognition and prediction for autonomous driving [J]. arXiv preprint arXiv:240216036, 2024:
- [25] Zhanqian Wu, Kaichong Liang, Dengcheng Liu, et al. Driver lane change intention recognition based on Attention Enhanced Residual-MBi-LSTM network [J]. IEEE Access, 2022, 10: 58050-58061.
- [26] 党睿娜, 王建强, 李国强, 等. 高速公路行驶条件下的驾驶员换道特性 [J]. 清华大学学报(自然科学版), 2013, 53(10): 1481-1485.
- WANG Jianqiang DANG Ruina, LI Keqiang, ZHANG Qiang. Driver lane change characteristics for various highway driving conditions [J]. Journal of Tsinghua University (Science and Technology), 2013, 53(10): 1481-1485.



第一作者: 冯洋 (1997—), 男, 博士研究生, 研究方向为交通安全、交通行为。



通信作者: 杨轸 (1974—), 男, 副教授, 博士生导师, 美国弗吉尼亚理工大学访问学者, 道路交通安全与环境教育部工程研究中心副主任, 研究方向为道路安全、交通行为和交通 BIM。