

# 自动驾驶车辆换道意图识别研究现状

方华珍<sup>1)</sup>, 刘立<sup>1)</sup>, 顾青<sup>1)✉</sup>, 肖小凤<sup>1)</sup>, 孟宇<sup>1)</sup>

1) 北京科技大学机械工程学院, 北京 100083

✉ 通信作者, E-mail: qinggu@ustb.edu.cn

**摘要** 近年来基于数据驱动的自动驾驶车辆换道意图识别研究取得了显著进展, 学者们发布了大量的研究成果。针对该领域面临的一些共性的技术挑战, 如换道过程的认定、换道标签的缺失以及数据类别不均衡等问题, 从不同的数据驱动方法进行分类, 主要包括基于传统机器学习、基于深度学习和基于集成学习的换道意图识别方法, 对近年来这些方法的研究成果进行了回顾和总结。关于换道行为的认定, 存在两种主流方案, 即车辆是否穿越车道线。对于未穿越车道线的车辆, 主要应用于驾驶者换道意图的早期识别方法; 而当车辆穿越过车道线时, 则通常被用于完整的换道过程的识别。在换道意图标注的研究中, 研究者们针对固定时间窗口和航向角阈值对标注精度的影响进行了深入探讨。为了找到最优参数, 如最佳的固定时间窗口和航向角阈值, 研究者们采用了网格搜索进行寻优。虽然这种方法在固定的驾驶场景中表现良好, 但在不同的驾驶场景中, 如何实现参数的自适应调节仍然是一个挑战。针对换道数据类别不均衡的问题, 研究者采用两种策略: 一是调整数据采样方法, 利用欠采样和过采样技术平衡各类别样本数量; 二是采用对不均衡数据适应性强的分类模型, 如集成学习算法或代价敏感学习, 以维持较好的分类性能。

**关键词** 交通工程; 自动驾驶; 车辆; 数据驱动; 换道意图识别;

**分类号** U495

## Current status of lane change intention recognition of autonomous vehicles

FANG Huazhen<sup>1)</sup>, LIU Li<sup>1)</sup>, GU Qing<sup>1)✉</sup>, XIAO Xiaofeng<sup>1)</sup>, MENG Yu<sup>1)</sup>

1) School of Mechanical Engineering, University of Science and Technology Beijing, Beijing 100083, China

✉ Corresponding author, E-mail: qinggu@ustb.edu.cn

**ABSTRACT** In recent years, with the rapid development of big data and artificial intelligence technology, the research on data-driven automatic driving vehicle lane change intention recognition has become a hot topic in the transportation field. Numerous scholars have devoted themselves to this field and released a large number of innovative and practical research results. However, this field still presents common technical challenges, such as accurately identifying the lane change process, handling missing lane change labels, and addressing imbalanced data categories. These issues remain the focal point of current research. This paper aims to classify and organize current research from different data-driven methods, mainly including lane change intention recognition methods based on traditional machine learning, deep learning, and ensemble learning. There are two mainstream approaches in the academic community regarding the identification of lane change behavior. The first approach mainly focuses on the vehicle not crossing the lane line, which is mainly suitable for early recognition of the driver's intention to change lanes. The second approach focuses on the actual crossing of lane markings by vehicles, which is often seen as the identification of the complete lane change process. In academic research on lane change intention annotation, the selection of fixed time windows and heading angle thresholds plays a crucial role in the accuracy of annotation. These parameters not only affect the accurate recognition of lane change behavior but also directly relate to the

stability and reliability of autonomous driving and intelligent transportation system performance. Therefore, researchers have conducted in-depth discussions on the impact of these two parameters on annotation accuracy. To find the optimal fixed time window and heading angle threshold, researchers used the grid search optimization algorithm for optimization. This method performs well in fixed driving scenarios by traversing all possible parameter combinations and selecting the optimal parameters based on preset evaluation criteria. However, in practical applications, driving scenarios often have diversity and complexity, and different driving environments, road conditions, and driving styles of drivers may all have an impact on the recognition of lane change intentions. Therefore, how to achieve adaptive parameter adjustment so that the annotation algorithm can maintain high annotation accuracy in different driving scenarios remains a challenging problem. To address the issue of imbalanced data categories in lane changing, researchers adopt two strategies: one is to adjust the data sampling method and use under-sampling and oversampling techniques to balance the number of samples in each category; The second is to use classification models with strong adaptability to imbalanced data, such as ensemble learning algorithms or cost-sensitive learning, to maintain good classification performance.

**KEY WORDS** traffic engineering; autonomous driving; vehicle; data driven; lane change intention recognition;

随着汽车工业、信息技术和人工智能技术的迅猛发展，自动驾驶技术也取得了显著进步<sup>[1, 2]</sup>。其中，车辆换道意图识别<sup>[3-10]</sup>作为高级驾驶辅助系统（Advanced driving assistance system, ADAS）中的关键技术，为车辆风险预测、轨迹预测和行为决策等提供了重要参考，对提高行驶安全性和舒适性具有重要意义<sup>[11-13]</sup>。近年来，车辆换道意图识别领域发展迅速，积累了大量的研究成果。然而，这些研究工作仍存在一些共性的技术挑战与解决思路，需要进一步探讨和解决。

换道意图识别问题本质上是一个分类问题，其解决思路与分类问题相似。近年来，基于数据驱动的方法已成为换道意图识别研究的主流。传统的基于模型的方法，如采用车辆运动学模型、车道线信息融合和证据推理等，虽然在早期取得了一定成果，但由于其场景适应性较弱、识别精度较低等局限性，逐渐被基于数据驱动方法所替代<sup>[14-18]</sup>。因此，本文将重点介绍基于数据驱动的方法及其所面临的挑战。针对换道过程认定、换道标签缺失和数据类别不均衡等问题，根据所采用的方法，将换道意图识别分为基于传统机器学习、基于深度学习和基于集成学习的方法。通过梳理不同研究者的方法，以期梳理出近年来车辆换道意图识别的发展趋势，为该领域的发展提供一定的参考。

## 1 换道意图识别研究现状

### 1.1 基于传统机器学习的换道意图识别

基于传统机器学习的驾驶意图识别方法，其特点在于所需数据量相对较小。通常，这类方法需要依赖特征工程对数据进行预处理，以提升分类效果。其中，支持向量机<sup>[19]</sup>（Support vector machine, SVM）作为一种经典分类算法，在车辆换道意图识别研究中，获得了广泛关注<sup>[20-24]</sup>。SVM 通过寻找一个超平面，以最大化两个不同类别样本的间隔。

Wang 等<sup>[20]</sup>结合驾驶员情绪特征，利用 SVM 提出了针对二车道换道意图识别的模型。这项研究的目的在于深入探究不同情绪状态下驾驶员的换道意图。通过实车实验和模拟器驾驶实验，研究结果表明，在蔑视（contempt）情绪下，换道识别的准确率达到最高，分别为 91.52% 和 91.35%。祝俪菱和陈亮<sup>[21, 22]</sup>提出了一个基于 SVM 的高速公路换道意图识别方法。该方法的分类域涵盖了换道准备、换道跟驰和换道执行三个阶段。祝俪菱采用了数据归一化和主成分分析的特征处理方法，并在 NGSIM US101 数据集上进行实验验证。最终，祝俪菱和陈亮分别实现了 96.49% 和 97.68% 的换道识别率。然而，仅凭单一驾驶场景的验证数据尚不足以全面评估模型的鲁棒性。Benterki 等<sup>[23]</sup>在研究中利用 SVM 对高速公路换道意图进行了识别，分类领域包括左换道、车道保持和右换道。在 NGSIM 高速公路数据集上，该方法的识别准确率达到了 97.10%。Li 等<sup>[24]</sup>在研究中采用了 ABC-SVM 方法进行换道意图识别。利用人工蜂群算法（Artificial bee colony, ABC）优化 SVM 参数，从而在 NGSIM US101 数据集上实现了 96.19% 的识别率。

鉴于隐马尔可夫算法 (Hidden markov model, HMM) 在处理连续数据方面的优越性, 它在车辆换道意图识别领域亦获得较大关注<sup>[25-30]</sup>。该算法的核心思想是将观测序列视为由隐藏状态序列生成的产物, 并利用学习到的观测与隐藏状态之间的概率转移关系来进行推断和预测。Berndt 等<sup>[25]</sup>提出了一种基于 HMM 的早期换道意图识别方法, 仅采用了目标车辆方向盘转角和转角速度作为特征, 识别准确率达到了 74.00%。李克强等<sup>[26]</sup>进一步优化了这一方法, 他们融合了贝叶斯滤波

(Bayesian filtering, BF) 与 HMM 来进行换道意图识别。首先利用 HMM 进行初步识别, 随后通过 BF 输出最终的换道意图结果。经过实车实验验证, 该方法的准确率达到了 93.50%。Liu 等<sup>[27]</sup>则基于非线性多项式回归 (Nonlinear polynomial regression, NPR) 与 HMM, 提出了一种递归隐半马尔可夫 (Recurrent hidden semi-markov model, R-HSMM) 模型用于换道意图识别。在硬件在环仿真器上的实验结果表明, 该方法的换道识别准确率高达 97.85%。徐婷等<sup>[29]</sup>结合高斯混合模型 (Gaussian mixed model, GMM) 与连续型隐马尔可夫模型 (Continuous hidden markov model, CHMM), 提出了一种城市道路换道意图识别模型。经过实车实验验证, 该模型的换道行为识别率达到了 93.60%。田彦涛等<sup>[30]</sup>则提出了基于多维高斯混合隐马尔可夫模型 (Multi-dimension gauss hidden markov model, MGHMM) 的换道意图识别方法。他们结合 Carmaker 车辆动力学仿真软件搭建了模拟驾驶平台, 并实现了 88.00% 的识别准确率。刘志强等<sup>[28]</sup>融合了 HMM 与 SVM 的优点, 提出了 HMM-SVM 模型进行意图识别。经过实车实验验证, 该模型的换道准确率达到了 95.83%。

Liu 等<sup>[31]</sup>还基于动态贝叶斯网络 (Dynamic bayesian network, DBN) 进行了换道意图识别, 在公开数据集 HighD<sup>[32]</sup>上实现了 96.05% 的识别准确率。David 等<sup>[33]</sup>则开发了一种基于人工神经网络 (Artificial neural network, ANN) 的状态机驾驶行为识别模型。该模型通过定义状态机拓扑来确定状态之间的关系, 并根据 ANN 的估计定义的具体条件, 使状态机在各状态之间进行转移或保持当前状态。在仿真器上的实验结果表明, 该模型的识别准确率达到了 92.82%。

为了对各类基于传统机器学习的自动驾驶车辆换道意图研究进行更为直观的比较, 表 1 对上述论文进行了方法类别、具体算法、换道过程、数据集以及识别准确率的汇总, 其中换道 (Lane change) 认定法 (a) 表示车辆未跨过车道边界线, 法 (b) 为车辆跨过车道边界线, 下文表 2、3 同义。

**表 1 基于传统机器学习的自动驾驶车辆换道意图识别方法综述**

**Table 1** A summary of traditional machine learning on the lane change intention recognition of autonomous vehicles

Works	Algorithm	Year	Lane change	Datasets	Accuracy / %
Wang et al. [20]	SVM	2020	-	Real/Simulator	91.52/91.35
Zhu et al. [21]	SVM	2017	(b)	NGSIM	96.49
Chen et al. [22]	SVM	2020	(b)	NGSIM	97.68
Bentkerki et al. [23]	SVM	2019	(b)	NGSIM	97.10
Li et al. [24]	ABC-SVM	2021	(b)	NGSIM	96.20
Berndt et al. [25]	HMM	2008	(a)	Real	74.00
Li et al. [26]	BF-HMM	2015	-	Real	93.50
Liu et al. [27]	R-HSMM	2020	(b)	Simulator	97.85
Liu et al. [28]	HMM-SVM	2018	(a)	Real	95.84
Xu et al. [29]	GMM-CHMM	2020	(b)	Real	93.60
Tian et al. [30]	MGHMM	2020	(b)	Real	88.00
Liu et al. [31]	DCIE	2019	(b)	HighD	96.05
David et al. [33]	ANN	2021	(a)	Simulator	92.82

## 1.2 基于深度学习的换道意图识别

相较于传统的机器学习方法, 基于深度学习的方法在特征提取方面展现出更强的能力。Fang 等<sup>[34]</sup>提出了一个基于深度神经网络 (Deep neural network, DNN) 的高速公路换道意图识别方案。该方法利用目标车辆及其周围六辆车的历史轨迹信息作为特征输入, 并设定了左换道、车道保持和右换道三个分类域。在 NGSIM US101 和 I-80 数据集上的实验结果显示, 该方法的识别准确率达到了 88.88%。

循环神经网络 (Recurrent neural network, RNN) 因其对连续序列数据的处理能力, 在换道意

图识别方面得到了广泛应用。其变种长短时记忆网络（Long short-term memory, LSTM）和门控循环单元（Gated recurrent unit, GRU）也在该领域有所应用。Li 等<sup>[51]</sup>采用基于 RNN 的换道意图识别方法，利用自车与周围六辆车的历史轨迹作为特征输入，对比了 LSTM 和 GRU 两种方法。在 NGSIM I-80 数据集上，两种方法的识别准确率分别为 96.00% 和 95.60%。Ding 等<sup>[52]</sup>则提出了一种基于交互的车辆行为识别网络，采用 GRU 对目标车辆及其周围车辆进行编码，再通过全连接层输出换道意图。在 NGSIM US 101 和 I-80 数据集上，该方法的识别准确率达到了 94.40%。

季学武等<sup>[36]</sup>提出了基于 LSTM 的换道意图识别方法，结合了目标车辆和周围六辆车的历史轨迹数据作为特征。该方法利用 LSTM 对时序数据进行编码，并采用 Softmax 函数输出换道概率。在 NGSIM US101 和 I-80 数据集上进行了实验，识别准确率为 87.43%。Wang 等<sup>[37]</sup>也基于 LSTM 单元，利用目标车辆和周围六辆车的特征，在 NGSIM 数据集上实现了 92.59% 的识别准确率。赵健等<sup>[38]</sup>则采用数据机理混合驱动的方法，结合马尔可夫决策过程、动态安全场的换道可行性分析和双向长短时记忆网络（Bi-directional long short-term memory, Bi-LSTM），实现了 95.06% 的识别准确率。宋晓琳等<sup>[39]</sup>提出了融合条件随机场（Conditional random field, CFR）和 LSTM 的换道意图识别方法，在 NGSIM I-80 数据集上的换道识别率达到了 91.64%。张海伦等<sup>[40]</sup>进一步优化了 Bi-LSTM 模型，在 NGSIM I-80 数据集上取得了 99.31% 的准确率。高镇海等<sup>[41]</sup>基于 LSTM 构建的换道意图识别模型，融合了目标车辆及周围 8 辆车的历史轨迹特征，分类域涵盖了左换道、左加速换道等多种情况，在 HighD 数据集上达到了 98.34% 的识别准确率。Dang 等<sup>[42]</sup>将换道意图识别问题建模为基于 LSTM 网络的回归问题，并在双车道驾驶仿真器上进行了实验，换道识别准确率到了 92.50%。高凯等<sup>[43]</sup>结合多头注意力、卷积神经网络（Convolution neural network, CNN）和 LSTM 的优势，提出了高速公路换道意图识别方法，在 NGSIM US101 和 I-80 数据集上的识别准确率到了 95.50%。蔡英凤等<sup>[44]</sup>则提出了 SLSTMAT（Social-LSTM-Attention）算法，引入了目标车辆社交特征，通过卷积神经网络提取并结合注意力机制，在 HighD 数据集上实现了精度为 94.01% 的识别。Zhao 等<sup>[45]</sup>提出了 DCLSTM（Direction convolution LSTM）换道意图识别方法，在 NGSIM US 101 和 I-80 数据集上的识别率到了 94.10%。Su 等<sup>[46]</sup>提出了周围感知的 LSTM 算法，利用车辆历史轨迹和周围六辆车的当前状态进行换道意图识别，在 NGSIM US101 和 I-80 数据集上的识别率到了 87.40%。Scheel 等<sup>[47, 48, 55]</sup>在 LSTM 基础上融合了注意力机制进行换道意图识别，在 NGSIM 和 HighD 数据集上的识别率分别为 96.10% 和 99.20%。Armin 等<sup>[49]</sup>基于 LSTM 建立了换道意图识别模型，对比了不同特征参数与周围车辆数量对模型的影响，在 HighD 数据集上换道识别率到了 92.43%。Liao 等<sup>[50]</sup>基于 LSTM 设计了换道意图识别模型，融入了驾驶员偏好和车辆交互因素。Yan 等<sup>[53]</sup>则提出了基于 GRU 的换道意图识别模型，将其建模为回归模型，在实车实验中识别率到了 94.76%。赵建东等<sup>[54]</sup>采用了基于 CNN 与 GRU 并融合注意力机制的换道识别模型，融合了自车与周围六辆车的历史轨迹特征，在 NGSIM US101 数据集上识别准确率到了 97.37%。

倪捷等<sup>[56]</sup>提出一种基于模糊神经网络（Fuzzy neural network）的驾驶人换道意图识别模型，在实车数据进行实验上，换道识别率达 89.93%。Wei 等<sup>[57]</sup>提出一种基于深度学习计算机视觉网络的换道识别系统，利用摄像头和惯导数据，通过分析高速公路驾驶图像来检测车道变化行为，在真实数据集上实验识别率达 86.95%。Griesbach 等<sup>[58]</sup>提出一种回声状态网络（Echo State Network, ESN）的驾驶意图识别方法，融入驾驶员特征（例如注视）、环境特征（例如与其他车辆的距离）和车辆状态特征（例如速度），在自然数据集上识别准确率达 95.00%。Guo 等<sup>[59]</sup>提出一种基于 Transformer 的高速公路换道意图识别模型，在实际道路数据集上识别率达 95.70%。同样的，Gao 等<sup>[60]</sup>也采用 Transformer 模型来识别换道意图，在 NGSIM 和 HighD 数据集上进行验证，识别率分别为 97.46% 和 99.39%。Mozaffari 等<sup>[61]</sup>提出一种基于注意力的卷积神经网络来识别换道，通过卷积神经网络提取周围环境中相关的特征，在 High D 数据集上识别准确率达 83.00%。Izquierdo 等<sup>[62]</sup>提出了一种基于卷积神经网络车辆换道意图识别的方法，将下文、车辆交互、车辆轨迹和场景外观有效地组合成一个单一的 RGB 图像，作为分类模型的输入，在 PREVENTION 数据集上识别准确率达

83.40%。David 等<sup>[63]</sup>将车辆换道意图识别问题建模为视频摄像机堆叠视觉线索的动作分类问题，基于卷积神经网络建立识别模型，在实际道路识别率达 90.30%。Guo 等<sup>[64]</sup>提出一种基于注意力机制的双向长短时记忆网络（AT-BiLSTM）的换道意图识别模型，通过分析驾驶员的眼球运动、头部转动、车辆移动以及操作参数，在仿真器识别准确率达 93.33%。

表 2 对上述基于深度学习的论文进行了汇总。

**表 2 基于深度学习的自动驾驶汽车换道意图识别方法综述**

**Table 2** A summary of deep learning on the lane change intention recognition of autonomous vehicles

Works	Algorithm	Year	Lane change	Datasets	Accuracy / %
Fang et al. [34]	DNN	2022	(b)	NGSIM	88.88
Ji et al. [36]	LSTM	2019	(b)	NGSIM	87.43
Wang et al. [37]	LSTM	2022	(b)	NGSIM	92.59
Zhao et al. [38]	Bi-LSTM	2022	(b)	NGSIM	95.06
Song et al. [39]	CRF-LSTM	2021	(a)	NGSIM	91.64
Zhang et al. [40]	Bi-LSTM	2020	(a)	NGSIM	99.31
Gao et al. [41]	FC-LSTM	2023	(b)	HighD	98.34
Dang et al. [42]	LSTM	2017	(a)	Simulator	92.50
Gao et al. [43]	CNN-LSTM	2022	(a)	NGSIM	95.50
Cai et al. [44]	SLSTMAT	2020	(b)	HighD	94.01
Zhao et al. [45]	DCLSTM	2022	(a)	NGSIM	94.10
Su et al. [46]	LSTM	2018	(b)	NGSIM	87.40
Scheel et al. [47, 48, 55]	A-LSTM	2022	(a)	NGSIM/HighD	96.10/99.20
Armin et al. [49]	LSTM	2023	(a)	HighD	92.43
Liao et al. [50]	LSTM	2022	(b)	-	-
Li et al. [51]	RNN-based	2021	(b)	NGSIM	96.00
Ding et al. [52]	RNN-VBIN	2019	(a)	NGSIM	94.40
Yan et al. [53]	GRU	2019	(b)	Real	94.76
Zhao et al. [54]	CNN-GRU	2022	(a)	NGSIM	97.37
Ni et al. [56]	FNN	2016	(a)	Real	89.93
Wei et al. [57]	DRNN	2019	(b)	Real	86.95
Griesbach et al. [58]	ESN	2020	(b)	Real	95.00
Guo et al. [59]	Transformer	2022	(b)	NGSIM/HighD	97.46/99.39
Mozaffari et al. [61]	A-CNN	2022	(b)	HighD	83.00
Izquierdo et al. [62]	CNN	2021	(b)	PREVENTION	83.40
Cao et al. [60]	Transformer	2023	(a)	NGSIM/HighD	97.46/99.39
David et al. [63]	CNN	2020	(a)	Real	90.30
Guo et al. [64]	AT-BiLSTM	2021	(a)	Simulator	93.33

### 1.3 基于集成学习的换道意图识别

蒋司杨等<sup>[65]</sup>提出一种基于改进的极端梯度提升（Extreme gradient boosting, XGBoost）的换道决策识别模型，运用交叉检验和网格搜索（Grid search, GS）算法进一步提升了模型性能，在实际道路数据识别准确率为 86.20%。黑凯先等<sup>[66]</sup>提出一种基于随机森林决策树（Random forest, RF）的换道意图识别模型，融合车道偏离量、车辆加速度、方向盘转角、方向盘转角速度和方向盘力矩等特征参数，在仿真平台上进行实验，换道识别准确率达 93.92%。Zhang 等<sup>[67]</sup>提出一种融合特征工程的极端梯度提升（FE-XGBoost）算法的换道意图识别模型，在 NGSIM US101 和 I-80 数据集上换道识别率达 95.30%。方华珍等<sup>[68]</sup>提出一种融合混合示教长短时记忆网络（Mixed teacher force long short-term memory, MTF-LSTM）和极端梯度提升算法（LSTM-XGBoost）的换道意图识别模型，通过 MTF-LSTM 网络提取未来轨迹特征，并与历史轨迹进行结合，通过 XGBoost 进行分类，在 NGSIM US101 和 I-80 数据集上识别准确率达 97.70%。Zhao 等<sup>[69]</sup>融合深度神经网络（DNN）和极端梯度提升算法来识别换道意图，在实车数据识别率达 92.46%。Syama 等<sup>[70]</sup>提出一种集成学习的换道意图识别模型，融合 SVM 和 RF 模型，在 NGSIM 数据集上换道识别准确率达 96.00%。Abraham 等<sup>[71]</sup>提出一种基于 RF 换道意图识别模型，在 NGSIM US101 数据集上识别率达 98.60%。Zhao 等<sup>[72]</sup>提出一种融合 XGBoost 和 LightGBM 的集成学习换道意图识别模型，融合目标车辆及周围八辆车历史轨迹特征信息，在实际道路数据集上识别准确率达 96.32%。张洪加等<sup>[73]</sup>对比了网联与非网联状态下的换道意图识别，在网联基础上采用集成学习方法，融合 RF、SVM、LSTM 和 Bi-LSTM 模型，在换道点 0.5s 前实现 96.35%的准确率。Xing 等<sup>[74]</sup>提出一种融合 Bi-RNN 和 LSTM 的集成学习模型来识别车辆换道意图，通过摄像头和 VBOX 所采集的数据

来进行实车实验，识别准确率达 96.10%。Deng 等<sup>[75]</sup>基于 RF 提出一种融合眼动数据的换道意图识别模型，在驾驶模拟器上识别准确率达 99.00%。

表 3 对上述基于集成学习论文进行了汇总。

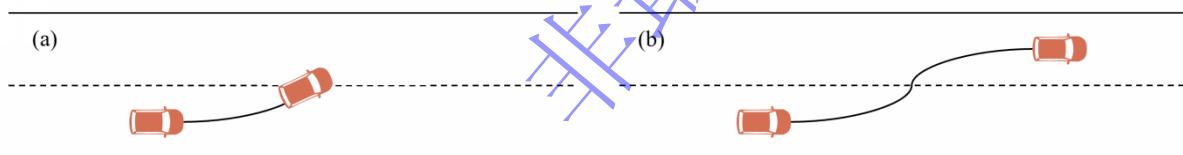
**表 3 基于集成学习的自动驾驶汽车换道意图识别方法综述**

**Table 3** A summary of ensemble learning on the lane change intention recognition of autonomous vehicles

Works	Algorithm	Year	Lane change	Datasets	Accuracy / %
Jiang et al. [65]	GS-XGBoost	2022	(b)	Real	86.20
Hei et al. [66]	RF	2020	(a)	Simulator	93.92
Zhang et al. [67]	FE-XGBoost	2022	(a)	NGSIM	95.30
Fang et al. [68]	LSTM-XGBoost	2023	(b)	NGSIM	97.70
Zhao et al. [69]	XGBoost-DNN	2022	-	Real	92.46
Syama et al. [70]	SVM-RF	2022	(b)	NGSIM	96.00
Abraham et al. [71]	RF	2021	(a)	NGSIM	98.60
Zhao et al. [72]	SFM	2022	(b)	Real	96.32
Zhang et al. [73]	EL	2023	(a)	Simulator	96.35
Xing et al. [74]	EL	2020	(b)	Real	96.10
Deng et al. [75]	RF	2020	(a)	Simulator	99.00

## 2 换道意图识别研究现状分析

在数据驱动的换道意图识别领域，重点关注换道过程认定、换道意图标注以及换道数据不均衡等问题。首先，关于自动驾驶车辆换道意图识别的核心问题，即换道过程的认定，存在两种主流方法<sup>[76]</sup>。第一种方法（法 a）将车辆跨过车道边界线临界点之前的一段视为换道过程，如文献[25, 28, 33, 39, 40, 42, 43, 45, 47-49, 52, 54-56, 60, 63, 64, 66, 67, 71, 75]所述；另一种方法（法 b）则将跨过临界点前后的部分都视为换道过程，如文献[21-24, 27, 29-31, 34, 36-38, 41, 44, 46, 50, 51, 53, 57-59, 61, 62, 65, 68, 70, 72, 74]所述。对于换道过程认定（a），它主要用于识别车辆在早期阶段跨过车道线前的换道意图；而对于换道过程认定（b），它则涵盖了车辆跨过车道线前后的时间段。



**图 1 两种主流的换道过程。(a) 未跨过车道边界线; (b) 跨过车道边界线**

**Fig.1** Two mainstream lane-changing process: (a) Vehicle does not cross lane boundary; (b) Vehicle crosses lane boundary

换道意图标注是指将车辆换道的信息标记在车辆的历史轨迹上。关于如何进行车辆换道意图标注，目前尚未有一种广为接受的方法。针对不同的换道认定方法，当前研究中常见的有两种标注方法。一种是固定时间窗口法（Fixed time window）：对于换道过程认定（a），在换道临界点（轨迹与车道边界线的交点）前的固定时间 T 被确定为换道标签<sup>[28, 38, 40, 42, 47, 48, 52, 55, 67]</sup>；对于换道过程认定（b），则在换道临界点前后各设定了固定时间 T/2 作为换道标签<sup>[21-23, 29, 59]</sup>。另一种换道标注方法是航向角阈值法（Heading threshold），这种方法主要基于车辆的航向角变化来标注换道意图。具体来说，对于换道过程认定（a），以换道临界点作为换道终止点，然后沿着这一临界点一侧回溯航向角，通过设定的阈值来搜索换道意图标注起始点；对于换道过程认定（b），沿着换道临界点两侧回溯航向角，并使用阈值来确定换道起始点与终止点<sup>[34, 36, 41, 68, 77]</sup>。在航向角阈值法中，换道起始点与终止点之间的数据被视为换道标签。宋晓琳等<sup>[39]</sup>融合两种方法的优点，提出一种以侧向速度阈值与固定时间窗口的换道意图标注法（Mixed），以换道临界点作为换道终止点，通过侧向速度阈值确定换道中间点，在此基础上延伸固定窗口 T 找到换道起始点。

**表 4 换道标注方法**

**Table 4** Methods of lane changing labeling

Lane change process	Date labeling	Precision	Robustness	Process cost
a	Fixed time window	-	-	+
a	Heading threshold	+	+	-
a	Mixed	-	+	-
b	Fixed time window	-	-	+
b	Heading threshold	+	+	-

固定时间窗口法对于不同类别、速度和加速度的车辆，存在较大的误差，对于后续基于学习的方法留下了天生的数据缺陷，并且如何确定时间窗口 T 也是一个问题。航向角阈值法换道意图标注更为精准，但是对于不同场景，如何确定航向角阈值是一个重要难点。表 4 给出上述不同换道意图标注法的特点，表中+表示较好，-表示较差。

在换道意图识别的研究中，研究者们广泛采用公开数据集来验证算法的有效性。应用较多的数据集有美国联邦公路局 2005 年推出的 NGSIM 数据集<sup>[78]</sup>、德国亚琛工业大学 2018 年推出的 High D 数据集<sup>[32]</sup>、2022 年中佛罗里达大学推出的 CitySim 数据集<sup>[79]</sup>。其中，NGSIM 数据集由于早年技术限制，误差相对较大。High D 和 CitySim 数据集数据集采用较为先进的图像处理技术，有效地降低了数据集误差。换道数据不均衡是指在驾驶过程中，不同换道意图类别的数据量存在显著差异。以 NGSIM US101 和 I-80 为例，换道意图类别包括左换道、车道保持和右换道。其中，车道保持类别 ( $10^6$ ) 的数据量远大于左换道 ( $10^5$ ) 与右换道 ( $10^4$ ) 的数据。为了解决车辆换道意图类别数据不均衡的问题，通常采用两种方法。第一种方法是在数据层面改变数据采样方法<sup>[34, 36]</sup>，主要包括欠采样和过采样。欠采样是指在对大类样本进行采样时减少该类数据样本的个数，使其与小类样本数目接近时再进行学习。过采样则与欠采样相反，通过对少量数据进行增加采样以提升样本的个数。第二种方法是在模型层面采用对不均衡数据不敏感的方法<sup>[80]</sup>，例如支持向量机（SVM）、决策树（DT）和随机森林<sup>[81]</sup>等。这些方法在处理不均衡数据时具有一定的鲁棒性，能够有效地分类不同换道意图的类别。

基于集成学习的车辆换道意图识别框架如图 2 所示，目标车辆（Target vehicle）根据其自身及周围车辆（Surrounding vehicle）的历史轨迹信息，通过融合 n 个子模型，来识别车辆换道意图（左换道 LLC，车道保持 LK，右换道 RLC），基于传统机器学习与深度学习的方法仅采用单一模型。基于集成学习的换道识别模型通过融合传统机器学习与深度学习的优势，实现了多模型的协同集成。这一方法不仅提升了换道行为识别的准确率，同时也显著增强了模型的泛化能力。

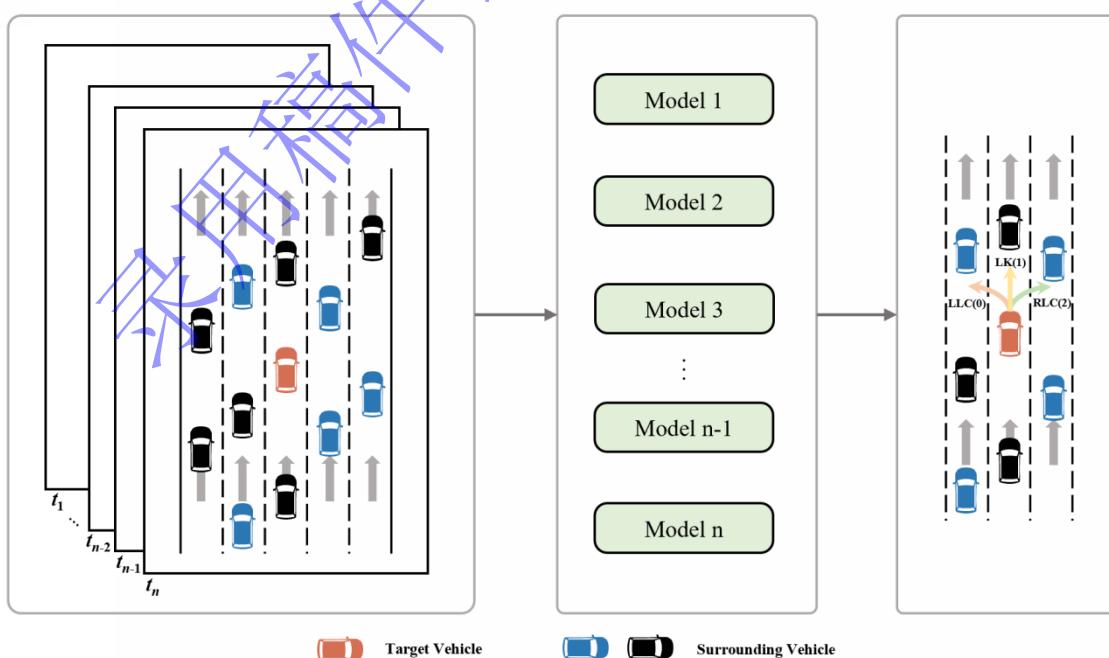


图 2 基于集成学习的换道意图识别框架。

**Fig.2** Lane change recognition framework based on ensemble learning.

### 3 总结与展望

(1) 在换道过程的认定研究中，当前主要存在两种方案。其中，未穿越车道线的认定主要用于对驾驶者换道意图的早期识别，这有助于判断驾驶者是否产生了换道的意愿。而当车辆穿越了车道线，这一行为则被认定为完整的换道过程，这一方案的应用更为广泛。

(2) 在换道意图标注的研究中，研究者们深入探讨了固定时间窗口和航向角阈值对标注精度的影响。为了找到最优参数，如最佳的固定时间窗口和航向角阈值，研究者们采用了网格搜索的方法，这种方法在固定的驾驶场景中表现出良好的效果。然而，面对不同的驾驶场景，如何实现参数的自适应调节成为了一个重要的研究方向。因为不同的驾驶场景可能具有不同的特性和挑战，固定参数可能无法满足所有场景的需求。因此，研究如何根据不同驾驶场景的特点和需求，动态调整参数，以提高标注的准确性和适应性，是当前研究的热点和难点。

(3) 对于换道数据类别不均衡的问题，研究者们采用了两种常用的方法来处理。第一种方法是改变数据采样方法，通过欠采样和过采样等技术来调整各类别的样本数量，使其更为均衡。第二种方法则是采用对不均衡数据不敏感的分类模型，例如一些集成学习算法或者代价敏感学习等，这些模型能够在类别不均衡的情况下依然保持较好的分类性能。

### 参 考 文 献

- [1] Li K Q, Dai Y F, Li S B, et al. State-of-the-art and technical trends of intelligent and connected vehicles. *J Automotive Safety and Energy*, 2017, 8(01):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. 汽车安全与节能学报, 2017, 8(01): 1)
- [2] Bian M Y, Li K Q. Strategic analysis on establishing an automobile power in China based on intelligent & connected vehicles. *Engineering science*, 2018, 20(01): 52  
(边明远, 李克强. 以智能网联汽车为载体的汽车强国战略顶层设计. 中国工程科学, 2018, 20(01): 52)
- [3] Pan Y, Zhang Q, Zhang Y, et al. Lane-change intention prediction using eye-tracking technology: A systematic review. *Applied ergonomics*, 2022, 103:103775
- [4] Mozaffari S, Al-jarra O Y, Dianati M, et al. Deep learning-based vehicle behavior prediction for autonomous driving applications: A review. *IEEE Trans Intell Transp Syst*, 2020, 23(1): 33
- [5] Doshi A, Trivedi M M. Tactical driver behavior prediction and intent inference: A review // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Washington, 2011: 1892
- [6] Xing Y, Lv C, Wang H J, et al. Driver lane change intention inference for intelligent vehicles: framework, Survey, and Challenges. *IEEE Trans Veh Technol*, 2019, 68(5): 4377
- [7] Deng Q, Söffker D. A Review of the current HMM-based Approaches of Driving Behaviors Recognition and Prediction. *IEEE Trans Veh Technol*, 2021, 7(1): 21
- [8] Fu R, Zhang H L, Liu W X, et al. Review on driver intention recognition. *Journal of Chang an University(Natural Science Edition)* , 2022, 42(01): 33  
(付锐, 张海伦, 刘文晓, 等. 驾驶人意图识别综述. 长安大学学报(自然科学版), 2022, 42(01): 33)
- [9] Song R, Li B. Surrounding vehicles' lane change maneuver prediction and detection for intelligent vehicles: A comprehensive review. *IEEE Trans Intell Transp Syst*, 2021, 23(7): 6046
- [10] Xing Y, Lv C, Wang H, et al. Driver lane change intention inference for intelligent vehicles: Framework, survey, and challenges. *IEEE Trans Veh Technol*, 2019, 68(5): 4377
- [11] Yildirim M, Mozaffari S, Mccutcheon L, et al. Prediction based decision making for autonomous highway driving // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Macau, 2022:138
- [12] Chandra R, Guan T, Panuganti S, et al. Forecasting trajectory and behavior of road-agents using spectral clustering in

- graph-lstms. *IEEE Robot Autom Lett*, 2020, 5(3): 4882
- [13] Woo H, Ji Y, Kono H, et al. Lane-change detection based on vehicle-trajectory prediction. *IEEE Robot Autom Lett*, 2017, 2(2): 1109
- [14] Houenou A, Bonnifait P, Cherfaoui V, et al. Vehicle trajectory prediction based on motion model and maneuver recognition // *Proceedings of the IEEE/RSJ conference on intelligent robots and systems*, Tokyo, 2013: 4363
- [15] Xie F, Lou J T, Zhao K, et al. A research on vehicle trajectory prediction method based on behavior recognition and curvature constraints. *Autom Eng*, 2019, 41(09): 1036  
(谢枫, 娄静涛, 赵凯, 等. 基于行为识别和曲率约束的车辆轨迹预测方法研究. 汽车工程, 2019, 41(09): 1036)
- [16] Tsogas M, Polychronopoulos A, Floudas N, et al. Situation refinement for vehicle maneuver identification and driver's intention prediction // *Proceedings of the international conference on information fusion*, Quebec, 2007: 1
- [17] Khelfa B, Tordeux A. Lane-changing prediction in highway: Comparing empirically rule-based model MOBIL and a naïve Bayes algorithm // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Indianapolis, 2021: 1598
- [18] Do J, Han K, Choi S B. Lane change–intention inference and trajectory prediction of surrounding vehicles on highways. *IEEE Trans Veh Technol*, 10.1109/TIV.2023.3266102
- [19] Cortes C, Vapnik V. Support-vector networks. *Machine learning*, 1995, 20(3): 273
- [20] Wang X, Guo Y, Bai C, et al. Driver's intention identification with the involvement of emotional factors in two-lane roads. *IEEE Trans Intell Transp Syst*, 2020, 22(11): 6866
- [21] Zhu L L, Liu L, Zhao X P, et al. Driver behavior recognition based on support vector machine. *Journal of Transportation Systems Engineering and Information Technology*, 2017, 17(01): 91  
(祝俪菱, 刘澜, 赵新朋, et al. 基于支持向量机的车辆驾驶行为识别研究. 交通运输系统工程与信息, 2017, 17(01): 91)
- [22] Chen L, Ma Y C, Li Q R. Probe into the Multi-class SVM-based recognition model for the vehicle lane-altering behavior. *Journal of Safety and Environment*, 2020, 20(01): 193  
(陈亮, 冯延超, 李巧茹. 基于 Multi-class SVM 的车辆换道行为识别模型研究. 安全与环境学报, 2020, 20(01): 193)
- [23] Benterki A, Boukhnifer M, Judaelet V, et al. Prediction of surrounding vehicles lane change intention using machine learning // *Proceedings of the IEEE Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, Metz, 2019: 839
- [24] Li X, Xie N. Research on vehicle lane change recognition based on ABC-SVM algorithm // *Proceedings of the International Conference on Computer Science & Education (ICCSE)*, Lancaster, 2021: 133
- [25] Berndt H, Emmert J, Dietmayer K. Continuous driver intention recognition with hidden markov models // *Proceedings of the IEEE Conference on Intelligent Transportation Systems (ITSC)*, Beijing, 2008: 1189
- [26] Li K, Wang X, Xu Y, et al. Lane changing intention recognition based on speech recognition models. *Transport Res Part C: Emerg Technol*, 2016, 69: 497
- [27] Liu Q, Xu S, Lu C, et al. Early recognition of driving intention for lane change based on recurrent hidden semi-Markov model. *IEEE Trans Veh Technol*, 2020, 69(10): 10545
- [28] Liu Z Q, Wu X G, Ni J, et al. Driving intention recognition based on hmm and SVM cascade algorithm. *Autom Eng*, 2018, 40(07): 858  
(刘志强, 吴雪刚, 倪捷, 等. 基于 HMM 和 SVM 级联算法的驾驶意图识别. 汽车工程, 2018, 40(07): 858)
- [29] Xu T, Wen C L, Zhang X, et al. Lane changing behavior identification of urban road based on GMM-CHMM. *Journal of Transportation Systems Engineering and Information Technology*, 2020, 20(01): 61  
(徐婷, 温常磊, 张香, 等. 基于 GMM-CHMM 的城市道路换道行为识别. 交通运输系统工程与信息, 2020, 20(01): 61)
- [30] Tian Y T, Zhao F K, Nie G M. Driver's lane change intention recognition considering driving habits. *Journal of Jilin University (Engineering and Technology Edition)*, 2020, 50(06): 2266

- (田彦涛, 赵凤凯, 聂光明. 考虑驾驶习惯的驾驶员换道意图识别. 吉林大学学报(工学版), 2020, 50(06): 2266)
- [31] Liu J, Luo Y, Xiong H, et al. An integrated approach to probabilistic vehicle trajectory prediction via driver characteristic and intention estimation // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Auckland, 2019: 3526
- [32] Krajewski R, Bock J, Kloeker L, et al. The highd dataset: A drone dataset of naturalistic vehicle trajectories on german highways for validation of highly automated driving systems // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Maui, 2018: 2118
- [33] David R, Rothe S, Soffker D. Lane changing behavior recognition based on Artificial Neural Network-based State Machine approach // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Indianapolis, 2021: 3444
- [34] Fang H, Liu L, Gu Q, et al. Driving intention recognition of human drivers in mixed traffic flow // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Macau, 2022: 153
- [35] Lipton Z C, Berkowitz J, Elkan C. A critical review of recurrent neural networks for sequence learning. *arXiv preprint*, arXiv:150600019
- [36] Ji X W, Fei C, He X K, et al. Intention recognition and trajectory prediction for vehicles using LSTM network. *China J Highway Transp*, 2019, 32(06): 34  
(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. 中国公路学报, 2019, 32(06): 34)
- [37] Wang W, Qie T, Yang C, et al. An intelligent lane-changing behavior prediction and decision-making strategy for an autonomous vehicle. *IEEE Trans Ind Electron*, 2021, 69(3): 2927
- [38] Zhao J, Song D J, Zhu B, et al. Traffic vehicles intention recognition method driven by data and mechanism hybrid. *Autom Eng*, 2022, 44(07): 997  
(赵健, 宋东鉴, 朱冰, 等. 数据机理混合驱动的交通车意图识别方法. 汽车工程, 2022, 44(07): 997)
- [39] Song X L, Zeng Y B, Cao H T, et al. Lane change intention recognition method based on an lstm network. *China J Highway Transp*, 2021, 34(11): 236  
(宋晓琳, 曾艳兵, 曹昊天, 等. 基于长短期记忆网络的换道意图识别方法. 中国公路学报, 2021, 34(11): 236)
- [40] Zhang H L, Fu R, Driving behavior recognition and intention prediction of adjacent preceding vehicle in highway scene. *Journal of Transportation Systems Engineering and Information Technology*, 2020, 20(01): 40  
(张海伦, 付锐. 高速场景相邻前车驾驶行为识别及意图预测. 交通运输系统工程与信息, 2020, 20(01): 40)
- [41] Gao Z H, Bao M X, Gao F, et al. The method of probabilistic multi-modal expected trajectory prediction based on LSTM. *Autom Eng*, 2023, 45(07): 1145  
(高镇海, 鲍明喜, 高菲, 等. 基于 LSTM 概率多模态预期轨迹预测方法. 汽车工程, 2023, 45(07): 1145)
- [42] Dang H Q, Fürnkranz J, Biedermann A, et al. Time-to-lane-change prediction with deep learning // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Yokohama, 2017: 1
- [43] Gao K, Li X H, Hu L, et al. Lane change intention prediction of CNN-LSTM based on multi-head attention. *J Mech Eng*, 2022, 58(22): 369  
(高凯, 李勋豪, 胡林, 等. 基于多头注意力的 CNN-LSTM 的换道意图预测. 机械工程学报, 2022, 58(22): 369)
- [44] Cai Y F, Tai K S, Wang H, et al. Research on behavior recognition algorithm of surrounding vehicles for driverless car. *Autom Eng*, 2020, 42(11): 1464  
(蔡英凤, 郁康盛, 王海, 等. 无人驾驶汽车周边车辆行为识别算法研究. 汽车工程, 2020, 42(11): 1464)
- [45] Zhao N, Wang B, Lu Y, et al. Direction convolutional LSTM network: Prediction network for drivers' lane-changing behaviours // *Proceedings of the IEEE Conference on Control & Automation (ICCA)*, Naples, 2022: 752
- [46] Su S, Muelling K, Dolan J, et al. Learning vehicle surrounding-aware lane-changing behavior from observed trajectories // *Proceedings of the IEEE Intelligent Vehicles Symposium (IV)*, Changshu, 2018: 1412
- [47] Scheel O, Nagaraja N S, Schwarz L, et al. Recurrent models for lane change prediction and situation assessment. *IEEE Trans Intell Transp Syst*, 2022, 23(10): 17284
- [48] Scheel O, Nagaraja N S, Schwarz L, et al. Attention-based lane change prediction // *Proceedings of the Conference on*

- Robotics and Automation (ICRA)*, Montreal, 2019: 8655
- [49] Qasemabadi A N, Mozaffari S, Rezaei M, et al. A novel model for driver lane change prediction in cooperative adaptive cruise control systems. *arXiv preprint*, arXiv:230501096
- [50] Liao X, Wang Z, Zhao X, et al. Online prediction of lane change with a hierarchical learning-based approach // *Proceedings of the International Conference on Robotics and Automation (ICRA)*, Philadelphia, 2022: 948
- [51] Li L, Zhao W, Xu C, et al. Lane-change intention inference based on RNN for autonomous driving on highways. *IEEE Trans Veh Technol*, 2021, 70(6): 5499
- [52] Ding W, Chen J, Shen S. Predicting vehicle behaviors over an extended horizon using behavior interaction network // *Proceedings of the Conference on Robotics and Automation (ICRA)*, Montreal, 2019: 8634
- [53] Yan Z, Yang K, Wang Z, et al. Time to lane change and completion prediction based on gated recurrent unit network // *Proceedings of the IEEE Intelligent Vehicles Symposium (IV)*, Paris, 2019: 102
- [54] Zhao J D, Zhao Z M, Qu Y C, et al. Vehicle lane change intention recognition driven by trajectory data. *Journal of Transportation Systems Engineering and Information Technology*, 2022, 22(04): 63  
(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. 交通运输系统工程与信息, 2022, 22(04): 63)
- [55] Scheel O, Schwarz L, Navab N, et al. Situation assessment for planning lane changes: Combining recurrent models and prediction // *Proceedings of the IEEE Conference on Robotics and Automation (ICRA)*, Brisbane, 2018: 2082
- [56] Ni J, Liu Z Q. A recognition model of lane change intention based on driver's decision mechanism. *Journal of Transportation Systems Engineering and Information Technology*, 2016, 16(01): 58  
(倪捷, 刘志强. 基于驾驶人决策机制的换道意图识别模型. 交通运输系统工程与信息, 2016, 16(01): 58)
- [57] Wei Z, Wang C, Hao P, et al. Vision-based lane-changing behavior detection using deep residual neural network // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Auckland, 2019: 3108
- [58] Griesbach K, Hoffmann K, Beggiato M. Prediction of lane change by echo state networks. *Transport Res Part C: Emerg Technol*, 2020, 121: 102841
- [59] Guo H, Keyvan-ekbatani M, Xie K. Lane change detection and prediction using real-world connected vehicle data. *Transport Res Part C: Emerg Technol*, 2022, 142: 103785
- [60] Gao K, Li X, Chen B, et al. Dual transformer based prediction for lane change intentions and trajectories in mixed traffic environment. *IEEE Trans Intell Transp Syst*, 10.1109/TITS.2023.3248842
- [61] Mozaffari S, Arnold E, Dianati M, et al. Early lane change prediction for automated driving systems using multi-task attention-based convolutional neural networks. *IEEE Trans. Intell Veh*, 2022, 7(3): 758
- [62] Izquierdo R, Quintanar Á, Lorenzo J, et al. Vehicle lane change prediction on highways using efficient environment representation and deep learning. *IEEE Access*, 2021, 9: 119454
- [63] Fernández-llorca D, Biparva M, Izquierdo-gonzalo R, et al. Two-stream networks for lane-change prediction of surrounding vehicles // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Greece, 2020: 1
- [64] Guo Y, Zhang H, Wang C, et al. Driver lane change intention recognition in the connected environment. *Physica A: Statistical Mechanics and its Applications*, 2021, 575: 126057
- [65] Jiang S Y, Li C, Lei Y, et al. Research on the Drivers' lane-changing decision recognition based on the naturalistic driving data. *Automobile Technology*, 2022, 01: 27  
(蒋司杨, 李朝, 雷毅, 等. 基于自然驾驶数据的驾驶人换道决策识别研究. 汽车技术, 2022, 01: 27)
- [66] Hei K X, Qu D Y, Zhou Q C, et al. Lane-changing behavior recognition of running vehicles based on random forest. *Journal of Qingdao University of Technology*, 2020, 41(01): 115  
(黑凯先, 曲大义, 周警春, 等. 基于随机森林决策树的行驶车辆换道行为识别. 青岛理工大学学报, 2020, 41(01): 115)
- [67] Zhang Y, Shi X, Zhang S, et al. A XGBoost-Based Lane Change Prediction on Time Series Data Using Feature Engineering for Autopilot Vehicles. *IEEE Trans Intell Transp Syst*, 2022, 23(10): 19187
- [68] Fang H Z, Liu L, Gu Q, et al. Driving intention recognition based on trajectory prediction and extreme gradient

- boosting. *Journal of Jilin University (Engineering and Technology Edition)*, 10.13229/j.cnki.jdxbgxb.20230479  
(方华珍, 刘立, 顾青. 基于轨迹预测和极限梯度提升的驾驶意图识别. 吉林大学学报(工学版), 10.13229/j.cnki.jdxbgxb.20230479)
- [69] Zhao C, Zhao X, Li Z, et al. XGBoost-DNN Mixed Model for Predicting Driver's Estimation on the Relative Motion States during Lane-Changing Decisions: A Real Driving Study on the Highway. *Sustainability*, 2022, 14(11): 6829
- [70] Syama R, Mala C. An ensemble model for lane change intention inference for autonomous driving // *Proceedings of the International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS)*, India, 2022: 1
- [71] Abraham A, Zhang Y, Prasad S. Real-time prediction of multi-class lane-changing intentions based on highway vehicle trajectories // *Proceedings of IEEE Conference on Intelligent Transportation Systems (ITSC)*, Indianapolis, 2021: 1457
- [72] Zhao L, Xu T, Zhang Z, et al. Lane-changing recognition of urban expressway exit using natural driving data. *Applied Sciences*, 2022, 12(19): 9762
- [73] Zhang H J, Guo Y S, Gao S, et al. Driver lane changing intention recognition in connected and non-connected environments. *China J Highway Transp*, 2023, 36(09): 257  
(张洪加, 郭应时, 高松, 等. 网联与非网联环境下驾驶人换道意图识别研究. 中国公路学报, 2023, 36(09): 257)
- [74] Xing Y, Lv C, Wang H, et al. An ensemble deep learning approach for driver lane change intention inference. *Transport Res Part C: Emerg Technol*, 2020, 115: 102615
- [75] Deng Q, Wang J, Hillebrand K, et al. Prediction performance of lane changing behaviors: a study of combining environmental and eye-tracking data in a driving simulator. *IEEE Trans Intell Transp Syst*, 2019, 21(8): 3561
- [76] Li L, Li P. Analysis of driver's steering behavior for lane change prediction // *Proceedings of the Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, Hangzhou, 2019: 71
- [77] Fang H Z, Liu L, Xiao X F, et al. Vehicle trajectory prediction based on mixed teaching force long short-term memory. *Journal of Transportation Systems Engineering and Information Technology*, 2023, 23(04): 80  
(方华珍, 刘立, 肖小凤, 等. 混合示教长短时记忆网络的车辆轨迹预测研究. 交通运输系统工程与信息, 2023, 23(04): 80)
- [78] Alexiadis V, Colyar J, Halkias J, et al. The next-generation simulation program. *Institute of Transportation Engineers ITE Journal*, 2004, 74(8): 22
- [79] Zheng O, Abdel-Aty M, Yue L, et al. CitySim: A Drone-Based Vehicle Trajectory Dataset for Safety Oriented Research and Digital Twins. *arXiv preprint*, arXiv:220811036
- [80] Johnson J M, Khoshgoftaar T M. Survey on deep learning with class imbalance. *Journal of Big Data*, 2019, 6(1): 1
- [81] Breiman L. Random forest. *Machine Learning*, 2001, 45:5