

车辆轨迹预测的分布外泛化： 一种社会交互因果模型框架

何 鹏^{1,2,3}, 万志飞^{1,2,3}, 崔亚平^{1,2,3*}, 吴大鹏^{1,2,3}, 王汝言^{1,2,3}, 潘孟铨^{1,2,3}

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 先进网络与智能互联技术重庆市高校重点实验室, 重庆 400065;
3. 泛在感知与智能互联重庆市重点实验室, 重庆 400065)

摘 要: 自动驾驶车辆在真实开放道路的可靠部署, 高度依赖其在未知交通场景中的轨迹预测泛化能力, 精准的车辆轨迹预测更是连接自动驾驶环境感知与决策规划模块的关键纽带, 直接决定了自动驾驶系统的运行安全性与环境适应性。现有基于深度学习的预测方法主要依赖历史与未来轨迹间的统计相关性, 其性能严重受限于训练与测试数据独立同分布 (Independent and Identically Distributed, IID) 的基本假设。然而, 实际复杂交通环境中地图几何、道路拓扑结构等的显著差异导致数据分布偏移, IID 假设难以成立, 造成各类预测模型在分布外 (Out-Of-Distribution, OOD) 场景下性能显著下降, 这成为自动驾驶系统开放道路部署的核心技术瓶颈。为应对上述挑战, 本文提出一种即插即用的基于社会交互因果模型的车辆轨迹预测 (Vehicle Trajectory Prediction based on Causal Model, CMVTP) 框架。该框架可灵活嵌入现有主流轨迹预测模型, 无需对原模型进行复杂修改或重训练, 具备高度的通用性与适配性。CMVTP 通过构建面向交通场景的结构因果模型 (Structural Causal Model, SCM), 显式刻画域不变因果特征与域可变因果特征间的内在关联, 精准揭示轨迹数据中的潜在因果关系, 有效提取驾驶风格、社会交互等跨环境稳定的域不变特征; 同时设计因果特征学习模块实现域不变与域可变特征的显式分离, 并提出双路径的不变特征转移模块, 通过隐藏层特征对齐与输出分布对齐强化模型对域不变特征的提取能力, 降低模型对地图特征等域可变特征的依赖。实验结果表明, CMVTP 能有效提升多种主流预测模型的分布外泛化性能, 在各类未见场景中, 模型预测精度获得显著提升, 最高可达 12.75%。本文提出的 CMVTP 框架突破了传统基于统计相关性的轨迹预测方法在分布外场景的性能局限, 为提升自动驾驶系统在开放动态环境中的适应性和安全性提供了重要技术支撑, 也为车辆轨迹预测的泛化建模研究提供了新的思路与方法。

关键词: 自动驾驶; 车辆轨迹预测; 因果模型; 社会交互; 分布外泛化; 域不变特征

基金项目: 国家自然科学基金 (No. U24A20211, No. 62271096); 重庆市教委科学技术研究项目 (No. KJQN202500603, No. KJQN202300621); 重庆市自然科学基金 (No. CSTB2025NSCQ-LZX0144, No. CSTB2024NSCQ-LZX0124, No. CSTB2023NSCQ-LZX0134); 重庆市高校创新研究群体项目 (No. CXQT20017); 重邮信通青创团队支持计划 (No. SCIE-QN-2022-04); 四川省重点研发计划 (No. 2024YFHZ0093)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2026)04-1885-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250827

OOD Generalization of Vehicle Trajectory Prediction Based on Causal Model of Social Interaction

HE Peng^{1,2,3}, WAN Zhifei^{1,2,3}, CUI Yaping^{1,2,3*}, WU Dapeng^{1,2,3},
WANG Ruyan^{1,2,3}, PAN Mengquan^{1,2,3}

(1. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China; 2. Advanced Network and Intelligent Connection Technology Key Laboratory of Chongqing Education Commission of China, Chongqing 400065, China; 3. Chongqing Key Laboratory of Ubiquitous Sensing and Networking, Chongqing 400065, China)

Abstract: The reliable deployment of autonomous vehicles on real-world open roads is highly dependent on their trajectory prediction generalization ability in unknown traffic scenarios. Accurate vehicle trajectory prediction serves as a key bridge between the autonomous driving environment perception and decision-making and planning modules, which directly determines the operational safety and environmental adaptability of autonomous driving system. The existing prediction methods based on deep learning mainly rely on the statistical correlation between historical and future trajectories, and their performance is severely limited by the basic assumption that training and test data are independent and identically distribut-

ed (IID). However, in complex real-world traffic environments, significant variations in map geometry and road topology lead to distribution shifts, making the IID assumption difficult to hold. Consequently, various prediction models suffer from substantial performance degradation in out-of-distribution (OOD) scenarios, which has become a critical technical bottleneck for the deployment of autonomous driving systems on open roads. To address these challenges, this paper proposes a plug-and-play vehicle trajectory prediction framework based on a causal model (CMVTP). The framework can be flexibly integrated into existing mainstream trajectory prediction models without requiring complex modifications or retraining, demonstrating strong generality and adaptability. By constructing a traffic scene-oriented structural causal model (SCM), CMVTP explicitly characterizes the intrinsic relationships between domain-invariant and domain-variant causal features, accurately reveals the underlying causal relationships in trajectory data, and effectively extracts domain-invariant features such as driving style and social interactions. Meanwhile, a causal feature learning module is designed to explicitly disentangle domain-invariant and domain-variant features, and a dual-path invariant feature transfer module is proposed. The hidden layer feature alignment and output distribution alignment enhance the model's ability to extract domain-invariant features and reduce its reliance on domain-variant features such as map characteristics. The experimental results show that CMVTP can effectively improve the out-of-distribution generalization performance of various mainstream prediction models. In various unseen scenarios, prediction accuracy is significantly improved, with gains of up to 12.75%. The CMVTP framework proposed in this paper breaks through the performance limitations of traditional trajectory prediction methods based on statistical correlations in out-of-distribution scenarios, provides important technical support for improving the adaptability and safety of autonomous driving systems in open dynamic environments, and offering new insights and methodologies for generalization modeling in vehicle trajectory prediction.

Keywords: autonomous driving; vehicle trajectory prediction; causal model; social interaction; out-of-distribution generalization; domain-invariant features

Foundation Item(s): National Natural Science Foundation of China (No.U24A20211, No.62271096); Science and Technology Research Program of Chongqing Municipal Education Commission (No.KJQN202500603, No.KJQN202300621); Natural Science Foundation of Chongqing (No.CSTB2025NSCQ-LZX0144, No.CSTB2024NSCQ-LZX0124, No.CSTB2023NSCQ-LZX0134); University Innovation Research Group of Chongqing (No.CxQT20017); Youth Innovation Group Support Program of ICE Discipline of CQUPT (No.SCIE-QN-2022-04); Sichuan Science and Technology Program (No.2024YFHZ0093)

0 引言

自动驾驶汽车依靠智能计算系统执行驾驶任务,其技术进步显著提高了驾驶的便捷性和城市交通效率^[1]。凭借其独特的技术优势,自动驾驶汽车正推动汽车产业向智能化方向演进^[2]。自动驾驶系统集成环境感知、决策规划与计算控制等功能。在智能感知层面,自动驾驶汽车依托高精度地图,利用激光雷达、毫米波雷达及摄像头等新一代传感技术,这些技术凭借探测范围广、响应速度快、感知精度高的优势实现对周围环境的精准探测与动态追踪,为自动驾驶系统提供关键数据支撑^[3]。在决策规划层面,自动驾驶汽车能够基于多模态数据和智能算法配合或替代驾驶员制定安全、稳定、高效的驾驶策略。其中,车辆轨迹预测作为感知模块和决策规划模块之间的关键纽带,是实现精准决策与合理规划的基础。同时,计算控制模块负责将决策结果转化为精确的驾驶指令,通过精密控制系统实现车辆的平稳行驶和安全操作^[4]。然而,交通参与者运动模式的多样性、交互关系的复杂性、交通环境的高度动态性以及自动驾驶汽车的计算时间约束,使得精准预测交通参

与者的未来轨迹成为自动驾驶领域的核心挑战之一。

当前车辆轨迹预测模型主要利用深度神经网络学习历史轨迹和未来轨迹之间的相关性,然而这种方法严重依赖于训练数据与测试数据满足独立同分布 (Independent Identically Distributed, IID) 的假设。实际应用中,交通状况、道路结构等因素常导致车辆面临各种未知场景^[5],使得 IID 假设难以成立。分布外 (Out-Of-Distribution, OOD) 数据定义为与训练数据统计特性存在显著差异的测试样本,本质上是模型训练过程中未覆盖的数据分布。其典型表现为场景几何形态、拓扑结构等关键特征的分布偏移。当模型面对此类未训练过的道路类型时,预测性能会因分布不匹配而急剧下降。在实际场景中,车辆轨迹预测模型对 OOD 数据的高度敏感性,导致其性能显著下降。针对此问题,本研究提出一种基于因果模型的车辆轨迹预测 OOD 泛化方法,旨在揭示车辆轨迹数据间的因果关系,重点学习跨环境不变特征而非依赖于可变特征,从而增强模型的 OOD 泛化能力。

基于深度学习的车辆轨迹预测方法凭借其强大的学习能力,能够高效整合并分析复杂交通数据,在预测精度方面展现出显著优势,已成为车辆轨迹预测

公共基准测试中的主流方法^[6]。然而,这些方法在 OOD 场景中泛化能力有限,其性能甚至可能低于基于物理模型的方法。例如,在高速公路直线路段数据集上训练的车辆轨迹预测模型,在该特定场景下表现良好,但应用于环形交叉路口等未见场景时,几何形状和拓扑结构的显著差异会导致数据分布偏移,模型性能出现急剧下降。若模型无法在未见场景下做出可靠预测,在实际道路环境中可能引发严重事故。由于缺乏未知环境的先验知识,分布偏移会使轨迹预测性能严重下降。具体而言,当测试集的数据不属于训练域集合中时,车辆轨迹预测方法的准确度可能会严重下降。为此,本文提出了一种即插即用的基于因果模型的车辆轨迹预测(Vehicle Trajectory Prediction based on Causal Model, CMVTP)框架,该框架能灵活适应不同应用场景和任务需求,无需对现有模型进行复杂修改或重训练,具有高度通用性和适应性。CMVTP 引导车辆轨迹预测模型聚焦于域不变特征,例如车辆的驾驶风格和交通参与者间社会交互,而非记忆特定域的地图特征等可变特征,从而有效提高车辆轨迹预测方法的分布外泛化能力。

综上所述,本文的贡献如下:

(1) 提出面向轨迹预测任务的结构因果模型(Structural Causal Model, SCM),在交通场景中显式刻画域不变因果特征(驾驶风格、社会交互)与域可变因果特征(道路几何、交通布局)之间的因果关系,为模型的因果学习提供结构基础。

(2) 在因果特征学习基础上,设计了基于互信息优化的因果特征学习(Causal Feature Learning, CFL)模块,实现对域不变因果特征的显式分离,并结合变分推断方法实现可插拔式集成。

(3) 基于已有不变特征迁移理念,提出了双路径的不变特征转移(Invariant Feature Transfer, IFT)策略,包括隐藏层特征对齐与输出分布对齐两类损失函数,并构建通用插拔接口,可在不同轨迹预测模型上复用。在不破坏原模型结构的前提下,强化跨环境不变特征的提取,降低对可变特征的依赖,增强模型泛化能力和鲁棒性。

(4) 在 NGSIM 和 INTERACTION 数据集上的实验研究表明,该策略可以显著提升车辆轨迹预测模型的 OOD 泛化性能,在可见域与未见域均表现出良好性能。

1 相关工作

1.1 车辆轨迹预测方法

车辆轨迹预测任务旨在融合车辆历史运动状态、交互行为等多维度特征,对未来行驶轨迹进行预

测^[7]。现有方法主要分为基于物理模型和基于深度学习的两类预测方法。

由于硬件资源和计算能力的限制,早期的车辆轨迹预测算法研究主要采用物理学和动力学模型。此类模型通过车辆速度、加速度、转弯率等运动参数构建车辆的运动学或动力学模型,典型代表包括恒定速度模型、恒定加速度模型以及恒定转弯率和速度模型等,这些模型基于运动状态和固定运动参数推演轨迹^[8],但通常假设运动参数已知且无噪声干扰。然而实际场景中噪声是不可避免的,文献[9]提出了基于噪声标签重加权的车辆轨迹异常检测方法,通过自监督权重估计模块评估标签可信度,结合图卷积网络时空建模与混合高斯特征空间,有效提升了噪声数据下的模型鲁棒性。基于卡尔曼滤波(Kalman Filtering, KF)的方法则根据车辆运动原理建立状态转移方程,描述状态随时间的变化,同时建立观测方程关联车辆状态与传感器观测值,更新当前时刻最优估计状态与状态协方差矩阵,从而计算具有相关不确定性的车辆轨迹^[10]。在车辆轨迹预测任务中,不确定性是一个不可忽视的因素,蒙特卡罗方法(Monte Carlo Methods, MCM)通过生成大量随机样本模拟车辆可能的运动状态,从而更准确地估计车辆未来轨迹及其不确定性^[11]。上述方法实现简单,计算资源消耗较低,但特征提取能力有限,难以建模复杂交互关系,故多适用于短期预测场景。

得益于人工智能、传感器与通信技术的迅速发展,车辆轨迹预测研究取得了显著进展。现有的车辆轨迹预测模型突破了简单场景的限制,在交互性较强的复杂场景中也能表现良好。深度学习技术凭借其强大的复杂特征提取、多模态数据处理及长期依赖关系建模能力,推动预测方法从物理模型转向数据驱动模型,典型代表包括长短时记忆(Long Short-Term Memory, LSTM)网络、图神经网络(Graph Neural Network, GNN)和 Transformer^[12]。

基于 LSTM 的车辆轨迹预测方法凭借其强大的时间序列建模能力,能够深度挖掘车辆运动模式,准确捕捉历史运动轨迹并预测未来行驶轨迹。文献[13]提出 CS-LSTM 模型,该模型将社交池化层融入 LSTM 中,通过社会张量编码相邻车辆空间交互关系。文献[14]使用 LSTM 网络从车辆历史轨迹序列中提取隐藏依赖关系,显著提升预测精度。然而 LSTM 在捕捉长期交互关系时存在局限性,面临过拟合和泛化性能下降的风险,且对序列局部结构建模不足,可能导致模型偏向于捕捉全局模式而忽略局部信息。

图神经网络^[15]具有处理非结构化数据、保留拓扑信息及动态适应力强等优势,在提取图结构时空特

征方面性能良好,适用于各种图数据处理任务。交通场景中车辆间的交互关系天然契合图结构特性。GNN通过聚合节点邻域特征深入挖掘交互模式。文献[16]将交通场景表示为一个有向时空图,用于预测未来轨迹。文献[17]使用分层GNN框架处理异构交通参与者的交互,并结合LSTM进行车辆轨迹预测。文献[18]使用图卷积神经网络(Graph Convolutional Network, GCN)处理空间交互,卷积神经网络(Convolutional Neural Network, CNN)提取时间特征,通过门控循环单元对时空特征进行编码和解码。然而,在平衡局部和全局信息关注度方面,GNN存在信息传递效率低、处理大规模图数据能力不足的问题。

注意力机制能够有效地关注并学习历史轨迹中的重要信息,使模型能够更好地适应不同的交通环境,同时还能够灵活处理不同长度的历史轨迹序列,使模型能够更好地应对长期依赖关系和动态环境变化,从而提升车辆轨迹预测任务的效果和性能。文献[19]首次基于注意力机制提出Transformer模型,该模型使用大量注意力机制完成序列任务。相比于LSTM架构,Transformer模型能够对车辆轨迹序列进行并行计算。鉴于Transformer在机器翻译任务中表现良好,文献[20]将其引入车辆轨迹预测任务,结果表明Transformer模型在长期预测方面性能更优。文献[21]使用多头注意力(Multi-Head Attention, MHA)机制提取车道和车辆特征,以预测车辆的未来轨迹分布。此外,Transformer在交通领域应用中展现出强大的交互建模能力,利用注意力机制计算不同交通参与者之间的注意力权重,从而有效地对交通参与者和环境之间的复杂交互进行建模。文献[22]提出了一种mmTransformer模型,通过堆叠多层Transformer,将环境特征信息和交互特征信息融入模型中,从而深入地学习和分析交通环境中的复杂因素。文献[23]基于注意力机制提出了一种针对驾驶意图的特征融合机制,该机制能够将时间特征与空间特征融合起来,从而更全面地理解驾驶意图和行为。

1.2 分布外泛化

在车辆轨迹预测任务中,分布外泛化特指模型对训练数据分布外的测试数据的适应能力,旨在评估预测模型在面对未知环境时的适应能力^[24]。增强OOD泛化能力有助于提升车辆在未知环境中的轨迹预测准确性。目前深度学习方法中使用的数据集基于独立同分布的假设,即训练数据和测试数据在统计特性上相同且互不依赖。然而实际交通系统中的动态道路结构、环境变化及复杂场景导致车辆常面临未见情况,使得IID假设难以成立,从而造成自动驾驶系统在部署时模型性能显著下降^[25]。由于训练域和测试

域之间的数据分布可能存在显著差异,这种分布不匹配现象往往会让车辆轨迹预测模型在遇到与训练集相似的情况时展现出良好的性能,但是当测试数据中包含未知环境或新场景时却表现不佳^[26]。

目前车辆轨迹预测方法普遍采用序列到序列(Sequence-to-sequence, Seq2seq)框架,在车辆历史轨迹的基础上预测其未来轨迹,学习历史轨迹和未来轨迹之间的相关性^[27]。这种相关性基于IID的假设,导致在IID样本上训练的模型难以推广到OOD样本中。在车辆轨迹预测任务中,OOD数据可能导致车辆在未知场景下的轨迹预测偏差,进而产生不安全的驾驶决策^[28]。由于真实世界中存在多种复杂因素,车辆在实际应用中常面临各种未见情境。当数据分布不匹配时,模型的性能急剧下降,甚至可能导致交通事故,对自动驾驶系统安全构成实质威胁^[29]。因此,解决OOD泛化问题仍是当前车辆轨迹预测的核心挑战。

在现有解决OOD泛化问题的方法中,主要包含以下三类技术路径:域适应(Domain Adaptation, DA)、域泛化(Domain Generalization, DG)和基于不变风险最小理论(Invariant Risk Minimization, IRM)的不变学习方法。DA同时利用源域和目标域中的数据进行学习,使预测模型在目标域表现良好。该方法允许模型在训练过程中访问小部分未标记的目标域数据,从而降低OOD泛化难度。其核心机制在于最小化域间散度或通过域对抗学习构建源域与目标域样本的共享嵌入空间。DG禁止模型在训练期间访问任何形式的目标域数据。旨在学习可直接迁移至未知目标域的特征表示。相关文献提出了一系列解决方案,包括对比学习、因果推理等。文献[30]提出了无监督域泛化(Unsupervised Domain Generalization, UDG)的概念,该方法旨在利用无标签数据学习OOD泛化模型,同时分析预训练对OOD泛化的影响。文献[31]使用因果表示学习解决OOD泛化问题,通过融入因果先验知识,使得模型能够辨别数据的潜在因果结构。因果学习方法旨在挖掘数据潜在的因果结构,基于识别出的因果变量预测结果变量。其核心假设是数据背后的潜在因果结构在不同环境中保持不变。通过正确识别并利用这些因果关系,预测模型能够在数据分布发生变化时保持良好性能。越来越多的研究利用因果关系启发的方法解决OOD泛化问题,例如对因果推理公式进行前门调整和后门调整,然后对损失函数进行推导^[32]。不变风险最小理论在训练数据中区分出具有不同分布的子集,并将这些子集定义为特定的“环境”,在每个独立“环境”中施加特定的约束条件,以此来增强模型在面对未见分布数据时的泛化性

能^[33]。这种方法通过提取和利用跨域不变特征,提升模型对于多样变化数据分布的泛化性。OOD泛化的核心目标是在仅依赖单一训练集且不接触目标分布数据的情况下进行有效的泛化研究^[34]。

2 方法

2.1 问题描述

在交通场景中,车辆的历史轨迹和运动状态信息可以由自动驾驶车辆或路侧单元收集并表示为 $\mathbf{S}_t = [s_t^1, s_t^2, \dots, s_t^N]$,其中, $s_t^i = (x_t^i, y_t^i)$ ($i \in \{1, 2, \dots, N\}$)表示 t 时刻第 i 辆车的横纵坐标信息, N 表示车辆的数量。预测模型将历史轨迹序列 $\mathbf{X} = [\mathbf{S}_1, \mathbf{S}_2, \dots, \mathbf{S}_{T_{\text{obs}}}]$ 作为输入,输出车辆的未来轨迹序列 $\mathbf{Y} = [\mathbf{S}_{T_{\text{obs}}+1}, \mathbf{S}_{T_{\text{obs}}+2}, \dots, \mathbf{S}_{T_{\text{obs}}+T_{\text{fut}}}]$ 。将给定的数据集 $\mathcal{U}$ 中的数据划分为 m 个独立的域,即 $\mathcal{U} = \{u_1, u_2, \dots, u_m\}$,其中 $u_i = \{(X_j^i, Y_j^i)\} (j = 1, 2, \dots, n_i)$ 表示第 i 个域。假设各域之间的数据分布不同,可以将数据集拆分为可见域 $\mathcal{U}_{\text{seen}}$ 和不可见域 $\mathcal{U}_{\text{unseen}}$,前 k 个域作为模型在训练过程中可以访问的可见域 $\mathcal{U}_{\text{seen}} = \{u_1, u_2, \dots, u_k\}$,其余 $m-k$ 个域作为不可见域 $\mathcal{U}_{\text{unseen}} = \{u_{k+1}, u_{k+2}, \dots, u_m\}$,用于模拟交通道路上出现的新场景。训练集 $\mathcal{U}_{\text{train}}$ 是从可见域中采样的,即 $\mathcal{U}_{\text{train}} \subseteq \mathcal{U}_{\text{seen}}$,训练期间使用的验证集 $\mathcal{U}_{\text{val}}$ 也来自 $\mathcal{U}_{\text{seen}}$ 并且不与训练集重叠,即 $\mathcal{U}_{\text{val}} \subseteq \{\mathcal{U}_{\text{seen}} \setminus \mathcal{U}_{\text{train}}\}$,测试集是从不可见区域中抽样得到的,即 $\mathcal{U}_{\text{test}} \subseteq \mathcal{U}_{\text{unseen}}$ 。

车辆轨迹预测任务中的分布外泛化目标是从可见域中学习可泛化的预测函数 $O: \mathbf{X} \rightarrow \mathbf{Y}$,在不可见的测试域上实现最小预测误差:

$$\min_{\theta_i} \mathbb{E}_{(\mathbf{X}, \mathbf{Y}) \in \mathcal{U}_{\text{test}}} [\mathcal{L}(O(\mathbf{X}), \mathbf{Y})] \quad (1)$$

其中, $\mathbb{E}$ 表示期望, $\mathcal{L}$ 是损失函数, θ_i 是模型参数。

2.2 车辆轨迹泛化模型概述

为使车辆轨迹预测模型能泛化至训练数据未覆盖的新环境中,本文提出了一种即插即用的基于因果模型的车辆轨迹预测结构,该模型架构结构主要由编码器模块、社会交互模块、解码器模块、CFL模块和不变特征转移组成,其中,编码器、社会交互与解码器模块沿用现有主流预测结构,用于保持模型的通用性与可比性。本文的创新主要体现在SCM的因果变量设计、CFL模块的互信息驱动结构化实现,以及IFT模块的双路径转移机制与可插拔式集成方式,可灵活嵌入不同类型的轨迹预测模型中,从而提升模型在分布外场景下的泛化与稳健性能。

模型的总体概述如图1所示。模型以车辆历史轨迹和运动状态信息作为输入,通过轨迹编码器提取时序特征,经社会交互模块捕获交通参与者间的相互关系,编码后的历史轨迹用于建模潜在变量的近似后

验分布,并从这些后验分布中进行采样,以重构历史轨迹并预测未来轨迹。在此过程中,因果特征学习模块(CFL)区分后门特征中的域不变因果特征 f_i 和域可变因果特征 f_v ,并通过不变特征转移模块(IFT)将 f_i 注入原解码器的特征空间,实现域不变因果特征与原模型特征的合理融合。若要将本框架应用于其他轨迹预测模型(如CS-LSTM、STDAN、DS-STT等),只需将其编码器与解码器替代本框架中相应的基础预测模块即可,无需改变原预测模型的主体结构。CMVTP作为独立的增强模块可直接嵌入现有方法,实现即插即用的分布外泛化增强。

2.3 结构因果图

SCM用于描述因果特征及特征之间相互作用的方式,这些特征和交互方式使用有向无环图表示。当该图中存在从 $\mathbf{X}$ 到 $\mathbf{Y}$ 的有向边时,可以认为 $\mathbf{X}$ 是 $\mathbf{Y}$ 的直接原因。因果关系 $\mathbf{X} \rightarrow \mathbf{Y}$ 表明,当改变 $\mathbf{X}$ 的值的时候,会导致 $\mathbf{Y}$ 的值发生改变,反之不成立。SCM的输入包括三个部分:一组定性的因果假设,这些假设描述了变量间的因果关系;一组关于变量之间的因果关系的查询;一组实验数据,这数据和定性因果假设一致。SCM根据定性因果假设可以推导出的结论,可以通过统计测试来验证。

在车辆轨迹预测任务中,深度学习方法旨在捕捉历史输入轨迹 $\mathbf{X}$ 与预测轨迹 $\mathbf{Y}$ 之间的统计相关性,但这些相关性不足以解决OOD问题。基于共同因果原则,可将此类相关性分解为一系列后门特征,包括域不变因果特征 f_i (Domain-Invariant Causal Feature, DICF)和域可变因果特征 f_v (Domain-Variant Causal Feature, DVCF)。本节构建的结构因果模型如图2所示,其中,实心圆圈表示观察到的变量,空心圆圈表示未观察到的变量, $\mathbf{X}$ 表示历史轨迹, $\mathbf{Y}$ 表示预测的未来轨迹。 $\mathbf{Z}$ 表示跨域的不变特征,DICF在域之间不发生变化,但会影响车辆的行驶轨迹,例如社会规范,车辆的驾驶风格和交通参与者之间的社交交互等。 $\mathbf{D}$ 表示每个域中的可变特征,例如驾驶场景中的地图信息等。此外,还引入了一个域标识 $\mathbf{U}$,以表示每个域中的变化因素。在训练模型的时候,使用的训练数据都是从一组 $\mathbf{U}$ 环境中进行收集, $\mathbf{U}$ 可以在不同的环境中进行切换,由于在测试期间无法获得域标签,本章将 $\mathbf{U}$ 视为一个不可观测的潜在变量,带箭头的实线表示后门特征之间的关系。

在交通场景的结构因果图中,各因果变量之间的连接关系通过因果边确定。以下是对SCM中各边的解释。

(1)从 $\mathbf{D}$ 到 $\mathbf{X}$ 和 $\mathbf{Y}$ 的边:驾驶风格可以影响车辆的行驶速度,从而影响车辆行驶轨迹 $\mathbf{X}$,因此存在从




图1 车辆轨迹预测泛化模型

Figure 1 Generalization model of vehicle trajectory prediction




图2 结构因果模型

Figure 2 Structural causal model

D 到 X 。此外,驾驶风格也会影响未来轨迹 Y ,因为车辆驾驶员可能会根据自己的习惯或偏好来驾驶。

(2)从 Z 到 X 和 Y 的边:社会交互可以影响车辆之间的相对距离,即车辆行驶时的紧密程度。这会影响到历史轨迹 X ,因为车辆在遵守社会规范的同时会形成特定的驾驶方式。同样,社会交互也会影响未来轨迹 Y ,因为车辆会继续根据这些规范来驾驶。

(3)从 X 和 Y 的边:历史轨迹 X 决定了车辆起始位置,因为车辆的行驶是连续的,过去的位置和速度等信息可以用来预测未来的位置 Y 。

(4)从 U 到 D 的边:域选择变量 U 代表不同的场景域,而域可变特征 D 在每个环境中可能会有所不同。因此,存在从 U 到 D 的边,以解释每个环境中可变特征的变化。

2.4 因果特征学习

结构因果图中的因果特征包括域不变因果特征和域变因果特征。域不变因果特征是在不同环境下均能保持稳定的特征集合,跨域时具有高度的相似性和因果性,因此在多域中具备通用性和鲁棒性,反映域间共有结构和规律,而非特定域的独有特性。域可变因果特征不包含这种因果性,而是表现特定环境下的独有特性,其中可能包含大量与任务无关的非因果信息,例如交通场景中的可观测的地图信息和周围车辆的历史轨迹等,这些信息与特定环境高度相关。

上述的SCM没有考虑混淆偏差, D 和 Z 混淆了 X 对 Y 的因果效应,且存在后门路径和 $Y \leftarrow Z \rightarrow X$ 。车辆轨迹预测任务可以表示为 $p(Y|X)$,但是当存在混淆变量的时候, $p(Y|X)$ 不能捕获到 X 对 Y 真正的因果效应,会导致最终的预测结果出现错误。因此,需要使用后门准则消除混淆效应,使 X 对 Y 的因果效应变为 $p(Y|\text{do}(X))$ 。S可容许性准则表明如果变量集合 T 在给定的因果中满足条件 $(Y \perp\!\!\!\perp S|T, X)$,则称 T 为S可容许的。这个条件表示在给定变量集合 T 和 X 的条件下, Y 与 S 是独立的, T 能够阻断 S 对 Y 的所有潜在影响路径,从而可以确定哪些变量可以作为条件来控制因果效应中的混淆。

在SCM中对 X 进行干预,控制 X 的值,或者假设 X 的值是由外部实验设定的,而不是由模型中的其他变量决定的。根据后门准则,因果效应可以表示为

$$\begin{aligned}
& p(Y|\text{do}(X), U=u_1) \\
&= \int p(Y|X, D, Z, U) p(D|U) p(Z|U) \text{d} s \text{d} z \\
&= \int p(Y|X, D, Z) p(D|U) p(Z) \text{d} s \text{d} z \\
&= E_{p(D|U), p(Z)}[p(Y|X, D, Z)]
\end{aligned} \quad (2)$$

其中, $p(Y|\text{do}(X), U=u_1)$ 是在环境 u_1 中 X 对 Y 的因果效应, $\text{do}(\cdot)$ 表示干预操作。为了计算每个环境中 X 对 Y 的因果效应,需要在 D 和 Z 上进行分层。

本研究使用均值场变分推断来对潜在变量的真实后验分布进行近似,标准的对数似然用于训练模型,其定义为

$$\min_p E_{p^*(x,y)}[\log p(x,y)] \quad (3)$$

其中, $p^*(x,y)$ 是车辆轨迹数据中的样本分布。直接计算 $p(x,y)$ 是不可行的,因为 $p(x,y) = \sum_{u \in U} \int p(x,y,d,z,u) \text{d} d \text{d} z$, u 是环境集合变量。

为了近似潜在变量的真实后验分布,本研究使用均值场变分并根据变分下界(Evidence Lower Bound, ELBO)函数来训练模型:

$$\min_{p,q} E_{p^*(x,y)} \left[E_{q(d,z,u|x,y)} \left[\log \frac{p(x,y,d,z,u)}{q(d,z,u|x,y)} \right] \right] \quad (4)$$

其中, ELBO 函数使用 $q(d,z,u|x,y)$ 逼近目标分布 $p(d,z,u|x,y)$,使得式(4)中的目标函数转换为式(3)。

由于无法获取测试域中的未来轨迹数据,近似模型是不可行的。因此,要用 $q(s,z,u,x|y)$ 进行替代,损失函数变成:

$$\begin{aligned}
& \min_{p,q} E_{p^*(x)} E_{p^*(y|x)} [\log q(y|x)] \\
& + E_{p^*(x)} \left[E_{q(d,z,u,y|x)} \left[\frac{p^*(y|x)}{q(y|x)} \log \frac{p(x,y,d,z,u)}{q(d,z,u,y|x)} \right] \right]
\end{aligned} \quad (5)$$

其中,假设 $q(y|x)$ 是高斯分布,式(5)的损失函数的第一项是均方误差,使用 $q(y|x)$ 逼近 $p^*(y|x)$,而第二项会变成 $\log p(x)$ 的下界。使用 $p(x,y,d,z,u)$ 表示潜在变量和观测变量的联合分布, $q(d,z,u|x,y)$ 为模型中给定历史轨迹的潜在变量和未来轨迹的近似后验分布,则历史轨迹的对数似然的下界为

$$E_{q(d,z,u,y|x)} \left[\log \frac{p(x,y,d,z,u)}{q(d,z,u,y|x)} \right] \leq \log p(x) \quad (6)$$

通过因式分解可以将 $q(d,z,u,y|x)$ 分解为 $q(y|x,d,z)q(z|x)q(d|u)q(u|x)$, $p(d,z,u,y,x)$ 分解为 $p(y|x,d,z)p(x|d,z)p(d|u)p(z)p(u)$ 。第一项中的可以使 $q(y|x,s,z)$ 用已知的 $p(y|x,s,z)$ 替换。由于 $q(s|x,u)$ 是其真实后验的近似,可以将其变为 $q(s|x)$:

$$\begin{aligned}
& E_{q(d,z,u,y|x)} \left[\log \frac{p(x,y,d,z,u)}{q(d,z,u,y|x)} \right] \\
&= E_{q(d,z,u,y|x)} \left[\log \frac{p(x|d,z)p(d|u)p(z)p(u)}{q(z|x)q(d|x)q(u|x)} \right] \\
&= E_{q(d|x), q(z|x)} [\log p(x|d,z)] - \text{KL}(q(z|x)||p(z)) \\
&\quad - \text{KL}(q(d|x)||p(d)) - \text{KL}(q(u|x)||p(u|d)) \leq \log p(x)
\end{aligned} \quad (7)$$

其中, $q(u|x)$ 近似为 $p(u|x)$ 。

通过因果马尔可夫条件将 $q(u|x)$ 替换为 $p(u|x)$ 可以得到一个更加简化的推断模型,式(5)中的损失函数将变为

$$\begin{aligned}
& \min_{p,q} E_{p^*(x,y)} \log q(y|x) \\
& + \frac{1}{q(y|x)} E_{q(d|x), q(z|x)} \left[p(y|x,d,z) \log \frac{p(x|d,z)p(d)p(z)}{q(z|x)q(d|x)} \right]
\end{aligned} \quad (8)$$

其中, $p(d) = \sum_{u \in U} p(d|u)p(u)$ 表明 D 具有高斯混合先验分布,且 $q(y|x) = E_{q(s|x), q(z|x)} [p(y|x,s,z)] = p(y|\text{do}(x))$ 可以通过采样计算。

2.5 不变特征转移

在训练阶段考虑多个不同的环境,这些环境代表了数据分布的可能变化。每个环境都有自己的数据,这些数据在统计特性上可能会有所不同。本研究提出了一种不变特征转移策略,用于自适应生成相应的混合不变特征表示,引导模型学习如何有效处理这些特征表示,鼓励模型学习具有泛化性的不变特征表示,从而提高模型处理数据分布偏移的能力,缓解模型受到来自数据偏差信息的影响。

在该策略中,模型预测的车辆轨迹分布与环境 U 相关,如果直接学习 X 和 Y 之间的关系,很难将预测模型泛化到新的域。当编码器同时提取了 f_i 和 f_v 时,模型预测的车辆轨迹分布仍然会受 U 的影响,因为 X 直接受 Z 和 D 的影响,而导致车辆轨迹预测方法无法泛化到新的域。如果预测的轨迹分布仅与 f_i 相关,那么车辆轨迹预测模型就能更好地泛化到新的环境中。因此,IFT 希望学习到的特征主要包含 f_i 而不是 f_v ,上述问题可以定义为

$$\min_{\theta_e} \text{dist}(f_i, \varepsilon(X)) \quad (9)$$

$$\min_{\theta_e} \text{dist}(f_v, \varepsilon(X)) \quad (10)$$

其中, $\varepsilon(\cdot)$ 表示编码器, $\text{dist}(\cdot)$ 表示两个分布之间的距离, θ_e 表示编码器的参数集合。

IFT 将不变解码器 f_i 中的不变特征 D 输入到原始解码器 f_o 中,包含两种特征转移路径:隐藏转移和输出转移。隐藏转移的损失函数 $\mathcal{L}_h$ 为

$$\mathcal{L}_h = \mathcal{L}_2(h_o, h_i) \quad (11)$$

其中, $\mathcal{L}_2$ 为 L2 损失函数, $\mathbf{h}_o$ 为原始解码器的隐藏特征, $\mathbf{h}_i$ 为不变解码器的隐藏特征。输出转移的损失函数 $\mathcal{L}_o$ 为

$$\mathcal{L}_o = (1 - \varpi) \mathcal{L}_2(\mathbf{Y}_o, \mathbf{Y}) + \varpi \mathcal{L}_2(\mathbf{Y}_o, \mathbf{Y}_i) \quad (12)$$

其中, $\mathbf{Y}_o$ 表示原始解码器的输出, $\mathbf{Y}_i$ 表示不变解码器的输出, ϖ 为超参数。最终的损失函数 $\mathcal{L}_{all}$ 可以表示为

$$\mathcal{L}_{all} = \mathcal{L}_o + \varsigma \mathcal{L}_h \quad (13)$$

其中, ς 为超参数。

3 实验

为了评估 CMVTP 在车辆轨迹预测分布外泛化方面的性能, 本节在 NGSIM 和 INTERACTION 两个大型公开数据集中进行了大量实验。通过在两个数据集上进行大量实验, 全面评估 CMVTP 方案对于模型预测精度和泛化能力的提升效果。需要说明的是, 本文实验所采用的 NGSIM 与 INTERACTION 数据集虽然源于人工驾驶车辆, 但它们真实反映了人类驾驶者在复杂道路环境中的时空交互规律, 能够为自动驾驶系统的行为建模与轨迹预测提供可靠的代理样本。目前国际主流的自动驾驶研究工作^[13, 35-36]均使用上述数据集进行模型验证与性能评估, 因此本文的实验设置与研究对象保持一致性与可比性。

3.1 数据集

(1) NGSIM 数据集

NGSIM 数据集^[37-38]由美国联邦公路管理局的下一代模拟 (Next Generation SIMulation, NGSIM) 研究项目发布的车辆轨迹数据集。NGSIM 数据集包含两个子数据集: US-101 和 I-80 数据集。这两个数据集分别记录了美国 US-101 高速公路与 I-80 高速公路上特定研究区域内的车辆行驶状况, 记录了约 45 min 内轻度、中度和重度拥挤交通场景下的车辆轨迹, 采样频率为 10 Hz, 大约有 8 288 392 条车辆行驶轨迹记录。US-101 数据集涵盖了 5 条主车道及 1 条辅助车道, 摄像机监控的路段长度约为 640 m。而 I-80 数据集则包含了 6 条主车道和 1 条入口匝道, 摄像机监控区域长度约为 500 m。NGSIM 数据集中包含了丰富的属性信息, 如车辆 ID、帧 ID、总帧数、采样时间、车辆在局部坐标系中的 x 和 y 坐标、车辆类型、实时速度、加速度以及所属车道等。在车辆轨迹预测任务中, 模型以前 3 s 作为输入, 并预测接下来 5 s 的轨迹。

为保证数据质量与模型训练的可靠性, 本文在使用 NGSIM 数据集前对原始轨迹进行了系统的预处理。参考文献[39]中提出的多步轨迹重构方法, 我们首先检测并剔除了在摄像机拼接边界处存在空间跳变、速度不连续或加速度突变的异常数据。随后,

基于物理可行性约束, 对轨迹中出现的瞬时异常速度与加速度进行局部重构, 使得位置、速度与加速度三者在时间序列上保持动态一致性。接着采用低通滤波和平滑技术抑制由摄像机量化误差引起的高频噪声, 保证轨迹在空间和时间维度上的连续性。通过这种方式, 可有效消除由于遮挡、镜头切换和检测误差带来的定位偏移, 使得车辆的运动状态更加符合真实交通流特性。经该流程处理后的轨迹在速度、加速度及空间一致性方面均得到显著改善, 为后续分布外泛化实验提供了高质量的数据基础。

(2) INTERACTION 数据集

INTERACTION 数据集^[36]由美国加州伯克利大学在全球范围内使用无人机或固定摄像头记录的多种高度交互的驾驶场景组成, 包括高速公路匝道、环岛和交叉路口等。INTERACTION 数据集在每个时刻都提供了车辆的行驶状态信息, 包括车辆的位置、速度、偏航角和形状。该数据集包含不同国家的交通场景, 涵盖了中国的北京、上海、广州、深圳, 美国的加州、纽约, 德国的柏林、慕尼黑, 以及保加利亚的索菲亚等地, 总共有 500 000 多条轨迹数据。轨迹数据的采样频率为 10 Hz。

如表 1 所示, INTERACTION 数据集可以划分为 11 个子集, 分为三类场景: 环岛、并道和十字路口。INTERACTION 数据集的不同子集之间的数据量存在显著差异, 特别是子集 0、1 和 7 的数据量明显高于其他子集。

表 1 INTERACTION 中每个子集的数据比例

Table 1 The data proportion of each subset in INTERACTION

子集 ID	采样地点	场景	数据比例/%
sub-0	美国	环岛	17.9
sub-1	中国	并道	35.2
sub-2	美国	十字路口	7.9
sub-3	美国	十字路口	2.6
sub-4	德国	环岛	1.8
sub-5	美国	环岛	5.3
sub-6	德国	并道	1.2
sub-7	美国	十字路口	21.6
sub-8	美国	环岛	3.2
sub-9	美国	十字路口	2.6
sub-10	中国	环岛	0.6

3.2 评估指标

鉴于轨迹预测是一项回归任务, 车辆轨迹预测的预测精度评估使用平均位移误差 (Average Displacement Error, ADE), 最终位移误差 (Final Displacement Error, FDE), 根均方误差 (Root Mean Squared Error, RMSE)。这几个评估指标常用于车辆轨迹预测任务。

ADE 衡量车辆在每个时间步上预测与真实值之间的欧氏距离误差,体现了车辆预测轨迹中总误差的平均值。FDE 衡量最后一个时间步上预测值与真实值之间的欧氏距离误差,体现了预测与实际值目的地的误差。RMSE 用于衡量预测值和真实值之间的误差,体现预测值与真实值整体误差的平均水平。在本文的实验设置中,不同评价指标用于不同类型的实验分析。具体而言,在泛化实验中主要采用 ADE 和 FDE,以评估模型在整体轨迹形状与最终位置预测方面的泛化性能;在消融实验中, RMSE 被用于衡量不同模块组合对连续时间预测误差的影响。

$$ADE = \frac{\sum_{i=1}^N \sum_{t=T_{obs}+1}^{T_{obs}+T_{pred}} \|\hat{y}_t^i - y_t^i\|_2}{N \times T_{pred}} \quad (14)$$

$$FDE = \frac{\sum_{i=1}^N \|\hat{y}_t^i - y_t^i\|_2}{N}, t = T_{obs} + T_{pred} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_t^i - y_t^i)^2} \quad (16)$$

3.3 实施细节

在模型训练过程中,编码器和解码器的维度大小都设置为 32,批处理样本大小设置为 128,实验中使用 Adam 优化器优化所有模型,初始的学习率设置为 0.000 5,同时将 dropout 设置为 0.3 防止过拟合,超参数 ω 设置为 0.3,超参数 ζ 设置为 0.02。此外,为了使模型在训练过程中更加容易收敛到最优解,本文对输入的运动状态信息进行了归一化处理,具体如式(17)所示。实验是在一台采用 NVIDIA GeForce RTX3090GPU 机器上进行的,平台基于 Python3.8 和 Pytorch1.12.1。

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (17)$$

为全面评估 CMVTP 在提升 OOD 泛化能力方面的有效性,并验证其在不同轨迹预测框架中的适用性,本文选取六种具有代表性的车辆轨迹预测模型进行对比实验。

MMnTP^[22]:该方法提出了一种新的机动行为预测建模框架,通过估计不同机动行为模式实现多模式预测。模型采用基于 Transformer 的结构,以捕捉复杂的时间依赖关系和空间动态特征,从而同时预测多种机动模式及其对应的精确轨迹。

GRIP++^[40]:该方法提出了一种基于 GRU 的编码器-解码器结构,并通过构建固定图与动态图来刻画不同交通参与者之间的交互关系,从而实现多主体轨迹预测。

Social GAN(S-GAN)^[41]:该方法将循环序列到序列模型与生成对抗网络相结合,通过对抗训练机制聚

合不同交通参与者之间的社会交互信息,从而生成多种符合社会约束的未来轨迹预测结果。

CS-LSTM^[13]:该方法是一种基于 LSTM 的编码器-解码器架构模型,该框架中引入了卷积社交池化层,用以提取车辆之间的交互关系,并将这些关系转化为特征向量用于预测车辆的未来轨迹。

STDAN^[23]:该方法使用分层的时空动态注意力网络获取时间和空间维度的轨迹特征,并使用一种新颖的特定意图特征融合方法,用于联合意图识别和轨迹预测。

DS-STT^[42]:一种融合驾驶风格的时空 Transformer 模型,以实现准确的车辆个性化轨迹预测。

为模拟 OOD 泛化场景,本文在实验部分对数据进行结构化划分,将原始数据集划分为多个具有显著分布差异的子域,并通过控制源域与目标域之间的数据来源差异构建 OOD 测试环境。其中,INTERACTION 数据集根据采样地点与交通场景被划分为多个子集(sub-0 至 sub-10),不同子集在道路结构(如环岛、十字路口、并道)及交通流特性方面存在明显差异,从而形成具有分布偏移的多个子域。

在此基础上,本文设计了三类 OOD 泛化实验设置。

(1)单场景域泛化:源域与目标域来自同一交通场景,但选取不同子集进行划分,将数据量最大的子集作为目标域,其余子集作为源域,用于评估模型在相同语义场景下的分布偏移适应能力。

(2)跨场景域泛化:源域与目标域来自不同交通场景,将数据量最大的三个子集(sub-0、sub-1 和 sub-7)作为源域,其余子集作为目标域,以模拟不同道路结构之间的分布迁移。

(3)跨数据集域泛化:选取 INTERACTION 数据集作为源域,NGSIM 数据集作为目标域,通过跨数据采集环境的差异,构建更具挑战性的 OOD 测试条件。

在上述设置中,模型训练仅使用源域数据,目标域数据在训练阶段完全不可见,仅用于测试,从而严格满足 OOD 泛化中训练与测试分布不一致的基本假设。该划分方式能够系统性地模拟从同场景的轻度分布偏移到跨数据集的强分布偏移的不同泛化难度,为评估模型的泛化能力提供统一且可复现的实验基础。

3.4 定量分析

在单场景域泛化实验中,表 2 和表 3 对比了不同模型使用 CMVTP 方案前后的 OOD 泛化性能。整体来看,所有模型在两个场景中均表现出不同程度的误差下降,验证了 CMVTP 策略在单场景域迁移条件下的有效性与稳定性。

在十字路口场景中,sub-7 作为目标域,其他子集作为源域。如表 2 所示,在源域中,各模型在 ADE 与

FDE 指标上均呈现一致下降趋势。DS-STT 在源域中的平均 ADE 和 FDE 分别降低了 7.40% 和 4.99%, 其中 FDE 改善幅度在所有模型中最高, 表明其在长时预测误差控制方面具有更强优势。MMnTP 与 S-GAN 的平均 ADE 下降幅度分别为 7.3% 与 7.43%, 与 DS-STT 处于相近水平, 但在 FDE 指标上略低于 DS-STT。GRIP++ 的平均 ADE 与 FDE 下降分别为 7.38% 与 4.53%。相比之下, CS-LSTM 与 STDAN 的改进幅度最小, 其平均 ADE 下降分别为 5.86% 与 5.94%, FDE 平均下降为 4.00% 与 4.84%。在目标域中, 各模型的提升幅度相对源域略有收敛, 表明目标分布与训练分布差异带来的泛化难度增加, 但仍保持一致的改善趋势。其中, DS-STT 在目标域中 ADE 与 FDE 分别下降 1.27% 与 4.94%, 其中 FDE 改善幅度依然处于较优水平。GRIP++ 与 STDAN 在 ADE 上的改进表现最优, 分别降低了 3.23% 与 4.07%, 而 S-GAN 和 MMnTP 在 FDE 上的改进效果更好, 分别降低了 5.05% 和 4.78%, 进一步验证了 CMVTP 策略在不同基础结构上的普适有效性。

表 2 十字路口场景下的 OOD 泛化实验中 ADE 和 FDE 结果
单位: m
Table 2 ADE and FDE results in the OOD generalization experiment in the intersection scenario unit: m

		sub-2	sub-3	sub-9	sub-7
MMnTP ^[22]	ADE	1.55/1.66	1.20/1.30	1.22/1.32	2.38/2.45
	FDE	3.52/3.68	3.42/3.60	3.38/3.55	4.78/5.02
GRIP++ ^[40]	ADE	1.57/1.69	1.22/1.32	1.24/1.34	2.40/2.48
	FDE	3.60/3.75	3.50/3.68	3.45/3.62	4.90/5.10
S-GAN ^[41]	ADE	1.56/1.68	1.21/1.31	1.23/1.33	2.36/2.43
	FDE	3.55/3.70	3.45/3.62	3.40/3.58	4.70/4.95
CS-LSTM ^[13]	ADE	1.52/1.59	1.21/1.29	1.20/1.29	2.22/2.25
	FDE	4.65/4.85	3.48/3.60	3.37/3.53	6.20/6.32
STDAN ^[23]	ADE	1.62/1.72	1.25/1.32	1.25/1.34	2.12/2.21
	FDE	5.05/5.29	3.67/3.83	3.57/3.79	6.02/6.04
DS-STT ^[42]	ADE	1.53/1.64	1.18/1.28	1.20/1.30	2.34/2.37
	FDE	3.43/3.59	3.36/3.56	3.30/3.47	4.62/4.86

在环岛场景中, sub-0 作为目标域, 其他子集作为源域, 如表 3 所示。与十字路口场景相比, 源域中的性能提升幅度更加显著。在源域中, DS-STT 模型获得了最大的改进, ADE 和 FDE 降低幅度分别为 13.42% 和 12.24%, 均为所有模型中最高水平, 显示出其在曲线运动与复杂轨迹模式下的显著优势。S-GAN、MMnTP 与 GRIP++ 在源域中的平均 ADE 下降分别为 13.36%、13.18% 和 13.20%, 整体表现与 DS-STT 接近, 但在 FDE 指标上略低于 DS-STT。CS-LSTM 模型的改进幅度最小, ADE 和 FDE 平均降低幅度分别为 6.78% 和 6.80%。在目标域中, 各模型均获得不同

程度的误差降低, 其中 S-GAN 和 MMnTP 在 ADE 指标上表现出较为明显的改进效果, ADE 分别下降了 3.90% 与 3.01%; 而 CS-LSTM 在 FDE 指标下降上表现更突出, 降低了 3.62%。DS-STT 的 ADE 和 FDE 分别降低 3.08% 和 0.34%, 在 ADE 指标上保持稳定改善, 但 FDE 提升相对有限。与十字路口场景相比, 采用 CMVTP 策略的车辆轨迹预测模型在环岛场景中表现出更大的精度提升。

表 3 环岛场景下的 OOD 泛化实验中 ADE 和 FDE 结果 单位: m
Table 3 ADE and FDE results in the OOD generalization experiment in the roundabout scenario unit: m

		sub-4	sub-10	sub-0
MMnTP ^[22]	ADE	1.62/1.76	1.33/1.63	3.22/3.32
	FDE	3.00/3.25	3.55/4.20	8.95/9.05
GRIP++ ^[40]	ADE	1.65/1.80	1.36/1.66	3.28/3.38
	FDE	3.15/3.40	3.65/4.30	9.11/9.20
S-GAN ^[41]	ADE	1.63/1.78	1.34/1.64	3.20/3.33
	FDE	3.05/3.30	3.58/4.25	8.90/9.04
CS-LSTM ^[13]	ADE	1.68/1.75	1.42/1.57	3.31/3.34
	FDE	4.41/4.64	3.60/3.94	9.04/9.38
STDAN ^[23]	ADE	1.62/1.83	1.38/1.51	3.24/3.35
	FDE	4.41/4.81	3.50/3.94	9.01/9.09
DS-STT ^[42]	ADE	1.59/1.73	1.30/1.60	3.15/3.25
	FDE	2.86/3.14	3.42/4.05	8.80/8.83

在跨场景域泛化能力的比较中, 表 4 对比了不同模型使用 CMVTP 方案前后的 OOD 泛化性能, 实验包含十字路口、环岛和并道三种场景, sub-0、sub-1 和 sub-7 作为源域, 而 INTERATION 中的其他子集作为目标域。从整体趋势来看, CMVTP 在源域与目标域中均实现了所有模型 ADE 与 FDE 的一致下降, 说明该方案不仅能够增强已见场景的拟合能力, 同时也能有效缓解跨场景分布偏移带来的性能退化问题。在源域, STDAN 在 CMVTP 下提升最大, ADE 和 FDE 分别降低了约 7.54% 和 5.95%, 表明其对跨模态协同机制较为敏感, 在源域特征增强后能获得明显收益。相比之下, DS-STT 提升幅度相对较小, ADE 与 FDE 平均分别下降 3.58% 和 2.95%, 这与其原始模型已具备较强时空建模能力有关, 因此可提升空间相对有限。其他模型在源域的 ADE 平均下降幅度约为 4.6%~4.8%, FDE 下降约 3.4%~3.9%, 表现出较为稳定的性能增益。在目标域, CMVTP 同样带来了持续且稳定的性能改善, 各模型的改善幅度相对接近。ADE 下降幅度平均约 4.3%, FDE 下降幅度平均约 3.5%, 其中 DS-STT 的精度提升最小, ADE 和 FDE 平均降低了约 3.73% 和 2.83%, 说明 CMVTP 对于原本泛化能力较强的模型仍具有正向补偿作用。

表 4 跨场景域的 OOD 泛化实验中 ADE 和 FDE 结果

单位:m

Table 4 ADE and FDE results in cross-domain OOD generalization experiments

unit: m

		sub-0	sub-1	sub-7	sub-2	sub-3	sub-4	sub-5	sub-6	sub-8	sub-9
MMnTP ^[22]	ADE	1.47/1.55	0.88/0.92	1.22/1.28	2.48/2.55	1.70/1.76	3.65/3.85	1.74/1.85	1.10/1.18	2.12/2.18	1.66/1.70
	FDE	4.55/4.70	2.55/2.62	3.78/3.95	7.75/7.95	5.10/5.30	10.90/11.40	5.05/5.32	3.42/3.55	6.25/6.40	4.90/5.05
GRIP++ ^[40]	ADE	1.49/1.57	0.90/0.94	1.24/1.30	2.50/2.58	1.72/1.78	3.68/3.90	1.76/1.88	1.12/1.20	2.15/2.20	1.68/1.73
	FDE	4.60/4.75	2.60/2.70	3.85/4.05	7.85/8.05	5.20/5.40	11.00/11.60	5.15/5.45	3.48/3.60	6.35/6.55	4.98/5.15
S-GAN ^[41]	ADE	1.46/1.54	0.87/0.91	1.21/1.27	2.46/2.53	1.68/1.74	3.62/3.82	1.73/1.84	1.09/1.16	2.10/2.16	1.64/1.68
	FDE	4.52/4.68	2.52/2.60	3.75/3.92	7.70/7.88	5.08/5.25	10.85/11.35	5.00/5.28	3.38/3.50	6.22/6.35	4.88/4.98
CS-LSTM ^[13]	ADE	1.40/1.51	0.83/0.85	1.18/1.26	2.42/2.52	1.63/1.73	3.32/3.67	1.75/1.83	1.19/1.21	2.07/2.14	1.65/1.70
	FDE	4.33/4.58	2.28/2.33	3.60/3.78	7.59/7.82	4.92/5.23	10.13/11.01	5.16/5.38	3.59/3.63	6.21/6.34	4.90/5.04
STDAN ^[23]	ADE	1.36/1.46	0.80/0.86	1.14/1.25	2.45/2.55	1.68/1.77	3.42/3.65	1.72/1.84	1.15/1.24	2.07/2.22	1.66/1.75
	FDE	4.24/4.46	2.24/2.36	3.53/3.83	7.72/7.90	5.13/5.42	10.60/10.76	5.20/5.36	3.54/3.69	6.21/6.48	4.99/5.19
DS-STT ^[42]	ADE	1.45/1.50	0.86/0.89	1.19/1.24	2.42/2.48	1.66/1.71	3.59/3.78	1.71/1.82	1.07/1.14	2.08/2.13	1.62/1.64
	FDE	4.47/4.56	2.48/2.55	3.70/3.86	7.60/7.72	5.02/5.18	10.71/11.26	4.97/5.25	3.34/3.43	6.17/6.28	4.83/4.86

针对跨数据域泛化能力的比较,表 5 对比了 CS-LSTM、STDAN 和 DS-STT 使用 CMVTP 方案前后的 OOD 泛化性能。其中 sub-0、sub-1 与 sub-7 作为源域,而 NGSIM 数据集作为目标域,用于检验模型在跨数据分布条件下的迁移能力。CMVTP 实现了不同车辆轨迹预测模型在源域和目标域中 ADE 和 FDE 的降低,说明该策略不仅能够提升已见数据分布上的拟合精度,同时对跨数据集的分布偏移同样具有缓解作用。在源域中,CS-LSTM 在 CMVTP 策略下实现了最大的改进,ADE 和 FDE 分别降低 7.54% 和 5.95%,STDAN 在源域的平均 ADE 与 FDE 分别下降 3.58% 和 2.96%,提升幅度相对有限。在目标域中,DS-STT 在 CMVTP 下实现了最大的改进,ADE 和 FDE 平均降低 4.39% 和 3.53%,表明 CMVTP 能进一步增强其在复杂车流数据分布下的泛化能力。MMnTP、GRIP++ 与 S-GAN 的 ADE 下降幅度也维持在 4.35%~4.79% 区间,但 FDE 改善略低于 3.4%。综合来看,CMVTP 在跨数据集迁移场景中仍能保持稳定的误差下降趋势,但整体提升幅度略低于跨场景实验结果,体现出数据集分布差异带来的更大泛化挑战。

3.5 消融实验

本节旨在验证 CMVTP 中每个组成部分对于提高车辆轨迹预测 OOD 泛化能力的有效性。为了深入研究策略中每个部分的有效性,在两种不同场景下进行 CMVTP 的消融实验,即源域和目标域中的数据不同,其中源域选择 NGSIM 数据集中的 US101,目标域选择 NGSIM 数据集中的 I80。通过将 DS-STT 在完整 CMVTP 方法上移除不同的部分后观察预测性能的变化,从而反映 OOD 泛化性的差异。CMVTP 主要由以下两个部分组成。

(1) CFL:形式化车辆轨迹的结构因果模型,利用

表 5 跨数据集域的 OOD 泛化实验中 ADE 和 FDE 结果 单位:m

Table 5 ADE and FDE results in cross-dataset domain

OOD generalization experiments

unit: m

		sub-0	sub-1	sub-7	NGSIM
MMnTP ^[22]	ADE	1.44/1.54	0.85/0.88	1.21/1.29	3.32/3.48
	FDE	4.40/4.65	2.35/2.42	3.70/3.95	8.65/8.95
GRIP++ ^[40]	ADE	1.46/1.57	0.87/0.90	1.23/1.30	3.38/3.55
	FDE	4.50/4.75	2.45/2.55	3.80/4.05	8.85/9.10
S-GAN ^[41]	ADE	1.42/1.53	0.84/0.87	1.20/1.28	3.30/3.45
	FDE	4.38/4.60	2.32/2.40	3.68/3.90	8.60/8.85
CS-LSTM ^[13]	ADE	1.36/1.46	0.80/0.86	1.14/1.25	3.50/3.60
	FDE	4.24/4.46	2.24/2.36	3.53/3.83	9.17/9.47
STDAN ^[23]	ADE	1.45/1.50	0.86/0.89	1.19/1.24	3.54/3.58
	FDE	4.47/4.56	2.48/2.55	3.70/3.86	9.28/9.38
DS-STT ^[42]	ADE	1.40/1.51	0.83/0.85	1.18/1.26	3.27/3.42
	FDE	4.33/4.58	2.28/2.33	3.60/3.78	8.47/8.78

互信息原理学习结构因果模型的不变表示,消除混淆偏差。

(2) IFT:自适应生成混合不变特征表示,引导模型学习处理泛化特征,从而提高模型处理数据分布偏移的能力,缓解模型受到来自数据偏差信息的影响。

表 6 表明了在不同的 CMVTP 条件下 DS-STT 在 NGSIM 数据集中跨场景域泛化方面的比较。在完整的 CMVTP 条件训练下,DS-STT 预测精度显著提升。未使用 CMVTP 时,DS-STT 模型在 I80 中预测性能最差,表明模型依旧依赖于训练数据集和测试数据集 IID 的假设,未学习到 I80 场景中的不变特征,导致预测误差较大,ODD 泛化能力较低。当 CFL 模块添加到原方法中,DS-STT+CFL 预测结果在第 5 s 时 RMSE 从 3.87 m 降低到 3.51 m。同时将 CFL 模块和 IFT 模块

加入原方法中,DS-STT+CFL+IFT的预测结果在第5 s时RMSE降低到3.42 m。消融实验结果表明CFL模块和IFT模块可以有效地提高现有车辆轨迹预测方法的OOD泛化能力。

表6 消融实验中不同CMVTP配置下DS-STT模型的RMSE结果

单位:m

源域/ 目标域	方法	1 s	2 s	3 s	4 s	5 s
US101 / 180	DS-STT	0.50	1.15	1.95	2.84	3.87
	DS-STT+ CFL	0.51	1.13	1.94	2.75	3.51
	DS-STT+ CFL+ IFT	0.49	1.11	1.89	2.64	3.42

3.6 定性分析

本节展示了在跨场景域泛化实验中DS-STT生成的预测轨迹的比较。图3~图6展示了DS-STT使用CMVTP方案下INTERACTION数据集中不同场景下的预测轨迹对比,包括十字路口、并道和环岛场景。图中,黑色实线表示交通道路,红色圆圈代表目标车辆,蓝色圆圈表示目标车辆的周围车辆,黄色虚线表示当前车辆的历史轨迹,而蓝色虚线表示真实轨迹。红色虚线表示使用CMVTP方案预测的未来轨迹。紫色虚线表示未使用CMVTP方案预测的未来轨迹。在复杂的交通环境中,车辆的运动情况变得更加多样。短期内车辆预测轨迹能够接近车辆真实的行驶轨迹,长期预测的准确性会出现一定程度的衰减。在十字路口、并道和环岛驾驶场景中,采用CMVTP方案的DS-STT模型能够更加精准捕捉车辆运动的长期趋势,进而实现了面向未知数据分布时的有效泛化,使得车辆轨迹预测模型在各种交通场景下均能展现出更好的性能。




图3 小型环岛场景下轨迹可视化

Figure 3 Trajectory visualization in small roundabout scene




图4 大型环岛场景下轨迹可视化

Figure 4 Trajectory visualization in large island scene




图5 十字路口场景下轨迹可视化

Figure 5 Trajectory visualization in crossroads scene




图6 并道场景下轨迹可视化

Figure 6 Trajectory visualization in parallel scene

4 结束语

本文围绕自动驾驶系统中车辆轨迹预测在分布外场景下的泛化能力问题,提出了一种即插即用的社会交互因果模型框架CMVTP,系统性地构建了结构因果模型以刻画交通行为中的潜在因果机制,并引入IFT模块以增强模型对域不变特征的捕捉能力,从而有效提升了现有轨迹预测模型在多种未知场景中的

泛化性能。本文在NGSIM和INTERACTION两个具有代表性的开放式数据集上进行了大量实证研究,结果表明,所提出的方法在不增加模型结构复杂度的前提下,显著提高了主流预测模型在目标域中的预测精度,最高提升可达12.75%,充分验证了因果建模和特征不变性学习在应对复杂交通场景分布偏移方面的有效性。相比现有主要依赖统计相关性的深度学习方法,本文在理论建模和泛化能力提升方面均实现了突破性进展,丰富了车辆轨迹预测在泛化建模层面的研究体系,为自动驾驶系统在多变环境下的安全部署提供了坚实支撑。尽管CMVTP在提升OOD泛化能力方面取得了显著成果,但仍存在可拓展空间。未来研究可探索在更动态、多模态交通环境中的应用,以进一步验证模型的鲁棒性;同时,可结合强化学习或在线学习机制,实现模型在实时部署中的自适应优化,以应对持续演变的交通分布偏移。


参考文献

- [1] Hakak S, Gadekallu T R, Maddikunta P K R, et al. Autonomous vehicles in 5G and beyond: A survey[J]. *Vehicular Communications*, 2023, 39: 100551.
- [2] 陈建, 苏思教, 黄立勤, 等. 自动驾驶中的3D目标检测研究进展[J]. *电子学报*, 2025, 53(6): 2131-2156.
Chen Jian, Su Sijiao, Huang Liqin, et al. Research advances on 3D object detection in autonomous driving[J]. *Acta Electronica Sinica*, 2025, 53(6): 2131-2156. (in Chinese)
- [3] Mozaffari S, Al-Jarrah O Y, Dianati M, et al. Deep learning-based vehicle behavior prediction for autonomous driving applications: A review[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(1): 33-47.
- [4] Zhang Yuxiao, Carballo A, Yang Hanting, et al. Perception and sensing for autonomous vehicles under adverse weather conditions: A survey[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 196: 146-177.
- [5] Crosato L, Tian Kai, Shum H P H, et al. Social interaction-aware dynamical models and decision-making for autonomous vehicles[J]. *Advanced Intelligent Systems*, 2024, 6(3): 2300575.
- [6] Meng Qingyu, Guo Hongyan, Li Jialin, et al. Vehicle trajectory prediction method driven by raw sensing data for intelligent vehicles[J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(7): 3799-3812.
- [7] Giannaros A, Karras A, Theodorakopoulos L, et al. Autonomous vehicles: Sophisticated attacks, safety issues, challenges, open topics, blockchain, and future directions[J]. *Journal of Cybersecurity and Privacy*, 2023, 3(3): 493-543.
- [8] Zhao Junwu, Qu Ting, Gong Xun, et al. Interaction-aware personalized trajectory prediction for traffic participant based on interactive multiple model[J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(3): 2184-2196.
- [9] 苏越阳, 姚迪, 毕经平. 基于噪声标签重加权的车辆轨迹异常检测方法[J]. *电子学报*, 2025, 53(1): 182-192.
Su Yueyang, Yao Di, Bi Jingping. A vehicle trajectory anomaly detection method based on noise label re-weighting[J]. *Acta Electronica Sinica*, 2025, 53(1): 182-192. (in Chinese)
- [10] Chen Yuxiao, Veer S, Karkus P, et al. Interactive joint planning for autonomous vehicles[J]. *IEEE Robotics and Automation Letters*, 2024, 9(2): 987-994.
- [11] Wang Yijing, Liu Zhengxuan, Zuo Zhiqiang, et al. Trajectory planning and safety assessment of autonomous vehicles based on motion prediction and model predictive control[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(9): 8546-8556.
- [12] 裴焰, 邱文涛, 王森, 等. 基于Transformer动态场景信息生成对抗网络的行人轨迹预测方法[J]. *电子学报*, 2022, 50(7): 1537-1547.
Pei Zhao, Qiu Wentao, Wang Miao, et al. Pedestrian trajectory prediction method using dynamic scene information based transformer generative adversarial network[J]. *Acta Electronica Sinica*, 2022, 50(7): 1537-1547. (in Chinese)
- [13] Deo N, Trivedi M M. Convolutional social pooling for vehicle trajectory prediction[C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. Piscataway: IEEE, 2018: 1549-15498.
- [14] Ip A, Irio L, Oliveira R. Vehicle trajectory prediction based on LSTM recurrent neural networks[C]//*Proceedings of 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring)*. Piscataway: IEEE, 2021: 1-5.
- [15] 李鑫, 陆伟, 马召祎, 等. 基于图注意力和改进Transformer的节点分类方法[J]. *电子学报*, 2024, 52(8): 2799-2810.
Li Xin, Lu Wei, Ma Zhaoyi, et al. A node classification method based on graph attention and improved transformer[J]. *Acta Electronica Sinica*, 2024, 52(8): 2799-2810. (in Chinese)
- [16] Zhuolei Chaochen, Zhang Qichao, Li Ding, et al. Vehicle trajectory prediction based on graph attention network[C]//*Proceedings of the 6th International Conference on Cognitive Systems and Information Processing*. Heidelberg:

- Springer, 2021: 427-438.
- [17] Li Zirui, Lu Chao, Yi Yangtian, et al. A hierarchical framework for interactive behaviour prediction of heterogeneous traffic participants based on graph neural network[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 9102-9114.
- [18] Zhao Ziyi, Fang Haowen, Jin Zhao, et al. GISNet: Graph-based information sharing network for vehicle trajectory prediction[C]//*Proceedings of 2020 International Joint Conference on Neural Networks (IJCNN)*. Piscataway: IEEE, 2020: 1-7.
- [19] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. New York: Curran Associates Inc., 2017: 6000-6010.
- [20] Hong J, Sapp B, Philbin J. Rules of the road: Predicting driving behavior with a convolutional model of semantic interactions[C]//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2019: 8446-8454.
- [21] Casas S, Gulino C, Suo S, et al. The importance of prior knowledge in precise multimodal prediction[C]//*Proceedings of 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Piscataway: IEEE, 2020: 2295-2302.
- [22] Liu Yicheng, Zhang Jinghuai, Fang Liangji, et al. Multimodal motion prediction with stacked transformers[C]//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2021: 7573-7582.
- [23] Chen Xiaobo, Zhang Huanjia, Zhao Feng, et al. Intention-aware vehicle trajectory prediction based on spatial-temporal dynamic attention network for internet of vehicles[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10): 19471-19483.
- [24] Wang Jindong, Lan Cuiling, Liu Chang, et al. Generalizing to unseen domains: A survey on domain generalization[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(8): 8052-8072.
- [25] Mahajan D, Tople S, Sharma A. Domain generalization using causal matching[C]//*Proceedings of the 38th International Conference on Machine Learning*. PMLR, 2021: 7313-7324.
- [26] Sui Yongduo, Wang Xiang, Wu Jiancan, et al. Causal attention for interpretable and generalizable graph classification[C]//*Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2022: 1696-1705.
- [27] Chen Yongqiang, Zhang Yonggang, Bian Yatao, et al. Learning causally invariant representations for out-of-distribution generalization on graphs[C]//*Proceedings of the 36th International Conference on Neural Information Processing Systems*. New York: Curran Associates Inc., 2022: 1608.
- [28] Zhou Kaiyang, Liu Ziwei, Qiao Yu, et al. Domain generalization: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(4): 4396-4415.
- [29] Dendorfer P, Elflein S, Leal-Taixé L. MG-GAN: A multi-generator model preventing out-of-distribution samples in pedestrian trajectory prediction[C]//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision (ICCV)*. Piscataway: IEEE, 2021: 13138-13147.
- [30] Liu Yuejiang, Cadei R, Schweizer J, et al. Towards robust and adaptive motion forecasting: A causal representation perspective[C]//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2022: 17081-17092.
- [31] Feng Lan, Bahari M, Amor K M B, et al. UniTraj: A unified framework for scalable vehicle trajectory prediction[C]//*Proceedings of the 18th European Conference on Computer Vision*. Heidelberg: Springer, 2024: 106-123.
- [32] Zhang Linfeng, Bao Chenglong, Ma Kaisheng. Self-distillation: Towards efficient and compact neural networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(8): 4388-4403.
- [33] Lin Yong, Dong Hanze, Wang Hao, et al. Bayesian invariant risk minimization[C]//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2022: 16000-16009.
- [34] Mao Chaojin, Zhao Liang, Min Geyong, et al. Informative causality-based vehicle trajectory prediction architecture for domain generalization[C]//*Proceedings of GLOBECOM 2023 - 2023 IEEE Global Communications Conference*. Piscataway: IEEE, 2023: 1-6.
- [35] Tang Xiaolong, Kan Meina, Shan Shiguang, et al. HPNet: Dynamic trajectory forecasting with historical prediction attention[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2024: 15261-15270.
- [36] Zhan Wei, Sun Liting, Wang Di, et al. INTERACTION dataset: An INTERNATIONAL, adversarial and cooperative moTION dataset in interactive driving scenarios with se-

- mantic maps[PP/OL]. V1. arXiv (2019-09-30)[2025-09-21]. <https://arxiv.org/abs/1910.03088>.
- [37] Halkias J, Colyar J. Interstate 80 freeway dataset[DS/OL]. (2006-12) [2025-09-21]. <https://www.fhwa.dot.gov/publications/research/operations/06137/>.
- [38] Colyar J, Halkias J. US highway 101 dataset[DS/OL]. (2007-01) [2025-09-21]. <https://www.fhwa.dot.gov/publications/research/operations/07030/>.
- [39] Montanino M, Punzo V. Making NGSIM data usable for studies on traffic flow theory: Multistep method for vehicle trajectory reconstruction[J]. Transportation Research Record: Journal of the Transportation Research Board, 2013, 2390(1): 99-111.
- [40] Li Xin, Ying Xiaowen, Chuah M C. GRIP: Graph-based interaction-aware trajectory prediction[C]//Proceedings of 2019 IEEE Intelligent Transportation Systems Conference (ITSC). Piscataway: IEEE, 2019: 3960-3966.
- [41] Gupta A, Johnson J, Fei-Fei L, et al. Social GAN: Socially acceptable trajectories with generative adversarial networks[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 2255-2264.
- [42] Cui Yaping, Wan Zhifei, Pan Mengquan, et al. Incorporating driving style in spatial-temporal transformer for vehicle trajectory prediction[J]. Engineering Applications of Artificial Intelligence, 2026, 171: 114133.

作者简介



何 鹏 男,1990年5月出生于重庆市江津区。2018年获得电子科技大学博士学位。现为重庆邮电大学副教授。主要研究方向为新一代通信网络技术、跨学科通信交叉领域。在国内外发表学术论文40余篇。

E-mail: hepeng@cqupt.edu.cn



吴大鹏 男,1979年8月出生于黑龙江省大庆市。2009年获得北京邮电大学博士学位。现为重庆邮电大学通信与信息工程学院教授。主要研究方向为泛在无线网络、无线网络服务质量管理等。

E-mail: wudp@cqupt.edu.cn



万志飞 男,2000年11月出生于湖北省监利市。2024年获得重庆邮电大学学士学位。现为重庆邮电大学通信与信息工程学院硕士研究生。主要研究方向为车联网。

E-mail: s240131143@stu.cqupt.edu.cn



王汝言 男,1968年12月出生于湖北省浠水县。2007年获得中国电子科技大学博士学位。现为重庆邮电大学通信与信息工程学院教授。主要研究方向为网络性能分析和多媒体信息处理。中国电子学会会员编号:E190005780S。

E-mail: wangry@cqupt.edu.cn



崔亚平 男,1986年11月出生于河南省新乡市。2017年获得西南交通大学交通信息工程与控制博士学位。现为重庆邮电大学通信与信息工程学院副教授。主要研究方向为机器学习和车辆网络的智能通信。

E-mail: cuiyp@cqupt.edu.cn



潘孟铨 男,2000年2月出生于江西省万安县。现为北京滴滴无线科技发展有限公司员工。2025年获得重庆邮电大学硕士学位。主要研究方向为车联网与机器学习。

E-mail: s220101114@stu.cqupt.edu.cn