

基于时空图注意力卷积神经网络的车辆轨迹预测

袁静, 夏英

引用本文

袁静, 夏英. 基于时空图注意力卷积神经网络的车辆轨迹预测[J]. 计算机科学, 2024, 51(12): 157-165.

YUAN Jing, XIA Ying. [Vehicle Trajectory Prediction Based on Spatial-Temporal Graph Attention Convolutional Network](#) [J]. Computer Science, 2024, 51(12): 157-165.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于分层注意力网络和积分梯度的细粒度漏洞检测方法](#)

Fine-grained Vulnerability Detection Based on Hierarchical Attention Networks and Integral Gradients
计算机科学, 2024, 51(12): 326-333. <https://doi.org/10.11896/jsjcx.231000174>

[DE-AA:基于词对距离嵌入和轴向注意力机制的实体关系联合抽取模型](#)

Joint Extraction of Entities and Relations Based on Word-Pair Distance Embedding and Axial Attention Mechanism
计算机科学, 2024, 51(12): 234-241. <https://doi.org/10.11896/jsjcx.231100023>

[基于特征融合的毫米波雷达行为识别算法](#)

Millimeter Wave Radar Human Activity Recognition Algorithm Based on Feature Fusion
计算机科学, 2024, 51(12): 181-189. <https://doi.org/10.11896/jsjcx.231200170>

[MB-ATMK:融合属性权重和时序元知识的多行为序列推荐模型](#)

MB-ATMK:Multi-behavior Sequential Recommendation Integrating Attribute Weights and Temporal Meta-knowledge
计算机科学, 2024, 51(11A): 231100047-9. <https://doi.org/10.11896/jsjcx.231100047>

[FCTNet:基于双域深度学习的公交车到站时间预测方法](#)

FCTNet:Bus Arrival Time Prediction Method Based on Dual Domain Deep Learning
计算机科学, 2024, 51(11A): 231000180-7. <https://doi.org/10.11896/jsjcx.231000180>

基于时空图注意力卷积神经网络的车辆轨迹预测

袁 静 夏 英

重庆邮电大学计算机科学与技术学院 重庆 400065

(S210201129@stu.cqupt.edu.cn)

摘要 车辆轨迹预测是交通管理、智能汽车和自动驾驶等领域的一项关键技术。准确预测车辆轨迹,有利于汽车安全行驶。城市交通场景中,车辆轨迹数据的时空特征复杂多变。为充分获取数据中的动态时空相关性,提高轨迹预测精度,同时降低模型复杂度,提出了时空图注意力卷积神经网络模型(Spatial-Temporal Graph Attention Convolutional Network,STGACN)。该模型首先通过轨迹信息嵌入模块对车辆历史轨迹数据进行时空图转换,然后通过时空卷积块及其堆叠完成轨迹数据的时序特征和空间特征的提取与融合,最终由门控递归单元完成编码与解码工作,得到预测轨迹。模型采用由膨胀因果卷积和门控单元组成的门控卷积网络提取时序特征,避免了循环神经网络带来的冗余迭代,使得模型参数更少,轨迹预测推理速度更快;时空卷积块组的时空特征融合工作使模型关注到更丰富的场景特征,提高了预测精度。在真实轨迹数据集 Argoverse 和 NGSIM 上进行实验,结果表明 STGACN 模型与基线模型相比,具有更高的预测精度和效率。

关键词: 车辆轨迹预测;时空相关性;时空图;图卷积网络;注意力机制

中图分类号 TP391

Vehicle Trajectory Prediction Based on Spatial-Temporal Graph Attention Convolutional Network

YUAN Jing and XIA Ying

College of Computer Science and Technology,Chongqing University of Posts and Telecommunications,Chongqing 400065,China

Abstract Vehicle trajectory prediction is a crucial technology in fields such as traffic management, intelligent-car, and autonomous driving. Accurately predicting vehicle trajectories contributes to safe driving. In urban traffic scenarios, the spatial-temporal features of vehicle trajectory data are complex and variable. To fully capture the dynamic spatial-temporal correlations in the data, enhance trajectory prediction accuracy, and simultaneously reduce model complexity, this paper proposes a spatial-temporal graph attention convolutional network(STGACN). It utilizes a trajectory information embedding module to transform historical vehicle trajectory data into spatial-temporal graphs. Subsequently, it extracts and combines temporal and spatial features of trajectory data through stacked spatial-temporal convolution blocks. Finally, encoding and decoding are performed by gated recurrent units to obtain the predicted trajectory. The model employs a gated convolutional network composed of dilated causal convolutions and gating units to extract temporal features, avoiding the redundant iterations introduced by recurrent neural network. The fusion of spatial-temporal features in the spatial-temporal convolution blocks group enables the model to focus on richer scene features. This results in a model with fewer parameters, faster trajectory prediction inference speed, and improved prediction accuracy. Experiments are conducted on real trajectory datasets, including Argoverse and NGSIM, and the results demonstrate that the proposed STGACN model exhibits higher prediction accuracy and efficiency than the compared baseline models.

Keywords Vehicle trajectory prediction, Spatial-temporal correlation, Spatial-temporal graph, Graph convolutional network, Attention mechanism

1 引言

从而调整自身驾驶动作,安全高效地通过复杂的交通场景。随着交通基础设施以及车载传感器、网络通信等技术的快速发展,智能汽车能够通过目标分类等算法捕获周围环境的

人们在驾驶过程中需要不断观察附近车辆的运动行为,

到稿日期:2023-11-22 返修日期:2024-02-06

基金项目:国家自然科学基金(41971365);重庆市教委重点合作项目(HZ2021008)

This work was supported by the National Natural Science Foundation of China(41971365) and Chongqing Municipal Education Commission Cooperation Projects(HZ2021008).

通信作者:夏英(xiaying@cqupt.edu.cn)

信息^[1],并通过车辆轨迹预测等技术辅助运动规划,提高驾驶效率和安全性能^[2]。

现有的车辆轨迹预测方法可以分为基于运动学的方法、基于机器学习的方法和基于深度学习的方法^[3]。基于运动学的方法主要包括运动学和动力学模型^[4]、卡尔曼滤波^[5]等。这类方法计算效率高,但由于忽略了车辆间的时空相关性,不适合时间范围较长的预测任务^[6]。基于机器学习的轨迹预测方法主要以目标车辆历史轨迹为依据,识别驾驶员的行为意图,以此预测车辆轨迹。人类意图识别领域研究成果丰富,如 Gao 等^[7]提出结构约束矩阵分解框架对人类行为序列数据的不同行为进行分割,其算法简单,所需硬件资源较少,能有效识别人类行为意图。研究人员尝试使用这类方法进行驾驶员意图识别。Deo 等^[8]基于隐马尔可夫模型估计目标车辆驾驶员的驾驶意图。Tran 等^[9]提出高斯过程回归模型识别目标车辆的行为意图,采用蒙特卡罗方法预测轨迹。但基于机器学习的方法依赖于手工特征提取,泛化能力不足,在复杂多变的交通场景中,预测性能受到较大影响。将运动学方法和机器学习模型相结合,提取车辆之间的时空相关性,能够缓解这一问题,如 Gao 等^[10]结合车辆物理模型和意图识别模型提出交互式多模型,针对不同场景和需求进行轨迹预测。该模型以运动学和动力学模型为基础提高短期预测的准确性,同时采用隐马尔可夫模型实现意图识别,保证了更长时间预测的准确性。

基于深度学习的方法具有学习和泛化能力强的优势,可以从丰富的数据中自动提取特征,增强模型的迁移能力。车辆轨迹预测虽然属于时序预测任务,但轨迹数据同时包含空间和时间信息,且城市交通场景中动态多变的道路情况使得空间信息同样重要。早期研究常仅采用循环神经网络(Recurrent Neural Network, RNN)及其变体网络提取轨迹数据的时序特征。其中,长短期记忆网络(Long Short-Term Memory, LSTM)能够有效捕获复杂的时序特性,被广泛应用于轨迹预测。Gao 等^[11]将其与动态贝叶斯网络结合,对骑车人进行意图识别,有效预测了十字路口场景下自行车的转向。该方法为智能汽车的主动防撞以及轨迹预测提供了重要参考。在此之前的车辆轨迹预测研究中,已有不少学者尝试将该类方法与深度学习结合,如 Zyner 等^[12]基于 LSTM 模型进行驾驶员意图估计,并预测其在十字路口的转向。这类方法主要依赖目标车辆历史轨迹,但仍然忽略了车辆间的空间信息。为解决这一问题,Deo 等^[13]提出结合卷积社交池化的长短期记忆网络模型(LSTM with convolutional social pooling, CS-LSTM),设计社交张量和卷积社交池化机制对车辆间的空间相互作用进行建模和捕获。但该模型只保留轨迹数据中最后一个时间节点的空间关系,仅能捕捉到车辆间的静态交互,对车辆间动态时空信息交互的关注仍然不足。

近年来,研究人员尝试引入图卷积网络和注意力机制等深度学习方法融合时空特征,以解决上述问题。Zhao 等^[14]利用图卷积网络增强车辆信息的共享能力,通过结合注意力机制使目标车辆学习邻近车辆的潜在意图。该方法沿用网格图

建模方式捕获空间特征,但网格图划分受车辆尺寸影响较大,泛化性有待提升。Li 等^[15]提出基于边缘增强图卷积神经网络的分布式机器学习框架。该框架将用户数据存储在本地设备,并由各边缘设备实现对数据的实时并发处理,提高模型的数据处理效率,增强泛化能力。Zhang 等^[16]提出基于图的双尺度上下文融合网络,该网络以分层方式对静态和动态驾驶上下文进行编码,实现局部与全局的特征融合,但从高清地图中提取几何拓扑信息,计算开销较大。Schmidt 等^[17]引入材料科学领域的晶体图卷积方法,提出了基于多模态和非光栅化的轨迹预测模型。该模型在不依赖地图信息的情况下,能够对车辆之间的相互作用进行建模和特征提取,但模型参数较多,在实际应用场景中对硬件资源需求较高。Li 等^[18]提出结合 GAN 网络与时空注意力机制的轨迹预测算法,将轨迹数据中的时空交互信息建模为交互影响力场,并通过该力场学习时空注意力权重,捕获复杂环境下车辆间的时空交互信息。Gao 等^[19]结合双向 Transformer 和多头注意力机制考虑目标车辆及其周围车辆的时空信息,捕获各车辆的变道意图并进行轨迹预测。为便于图卷积网络进行特征提取与融合,降低模型复杂度,研究人员尝试依据空间拓朴理论将轨迹数据构建为图结构,该结构同时保留了时间和空间信息。Li 等^[20]提出基于图卷积的轨迹预测模型(Graph-based Interaction-aware Trajectory Prediction, GRIP),采用拓扑图表示车辆间的相关性,用图卷积模块提取空间特征,并使用基于 LSTM 的编码解码模块完成时空特征融合并进行轨迹预测。Sheng 等^[21]提出基于图的时空卷积网络模型(Graph-Based Spatial-Temporal Convolutional Network, GSTCN),构建时空图表示车辆相关性,并由图卷积网络学习空间特征,由卷积神经网络处理时序信息,但该方法仍然分别处理时间和空间特征。STAG 网络^[22]通过构建有向时空图对车辆时空相关性进行建模,设计掩码块学习不对称掩码来增强车辆关联程度,并采用图卷积网络和时间卷积网络进行时空特征提取与融合,以生成预测轨迹。

上述方法通过结合图卷积、注意力机制等深度学习方法不断改进历史轨迹数据的构图方式,关注车辆间的相互影响,提取更有效的时空特征,并促进特征融合,从而提高轨迹预测性能,但仍然存在以下两个方面的挑战。

1) 车辆轨迹之间的空间相关性随时间的变化而动态改变。现有研究通常采用图卷积网络提取轨迹的空间特征,采用循环神经网络提取时序特征,待空间特征与时序特征分别提取完成后,进行时空特征融合。虽然特征提取步骤连续,但特征提取模块间相对独立,这削弱了时空特征之间的相关性。如何提取更丰富的时空特征并实现更全面的特征融合,是一个值得关注的方向。

2) 采用 LSTM 等循环神经网络虽然可以捕获到更丰富的时序特征,但迭代过程中容易发生梯度爆炸,且多数模型一次只能预测一台目标车辆的未来轨迹。若计算所有邻近车辆的轨迹,模型复杂度和计算成本将大大增加。

针对城市道路交通复杂多变的特点,本文提出了时空图

注意力卷积神经网络模型(STGACN)。该方法充分利用图卷积网络、注意力机制等方法在时空特征提取工作中的优势,有效融合时空特征,提高预测精度,同时避免循环神经网络带来的冗余,降低模型时间复杂度。主要贡献如下:

1)为了充分捕获车辆轨迹之间的动态时空相关性,引入并改进时空卷积模块,通过时空块及其堆叠处理图结构的轨迹数据,增强模型时空特征提取与融合的能力,提高了轨迹预测精度,同时有效获取数据中的时空相关性,增强了模型应对复杂场景的能力。

2)采用由膨胀因果卷积和门控单元组成的门控卷积网络进行时序特征提取,避免循环神经网络迭代耗时、梯度爆炸等问题。与对比方法相比,所提方法有效降低了模型参数及其时间复杂度,提高了模型推理速度,缩短了预测时间。

3)在两个公开数据集 Argoverse 和 NGSIM 上进行论证实验,结果表明 STGACN 模型与基线模型相比,具有更好的预测性能,在城市道路复杂场景下表现出了更好的稳定性,同时优化了模型参数,降低了预测耗时。

2 问题定义

依据空间拓扑理论将轨迹数据构建为图结构,其同时包含时间和空间信息,便于图卷积网络进行特征提取与融合。因此本文依照文献[21]的假设,以智能汽车可以观察到的纵向±100m 范围内和横向 2 条相邻车道内的车辆轨迹数据为基础,将轨迹数据建模为时空图。时空图表示为一个时序图集合,集合中每个子图对应一个时刻,图中节点特征表示空间特征,时间序列则通过多个子图构成。时空图的具体构建过程将在第 3 章中详细阐述。

车辆轨迹预测任务,即给定所有车辆在过去时间范围 T 内的轨迹 T_h ,预测它们在未来时间范围 H 内的轨迹 T_f 。在有 N 台汽车的场景中,模型输入的车辆轨迹信息为:

$$T_h = \{P_1, P_2, P_3, \dots, P_t, \dots, P_T\} \quad (1)$$

其中, P_t 是 N 台汽车在时刻 t 的位置,记为:

$$P_t = \{(x_t^1, y_t^1), \dots, (x_t^n, y_t^n), \dots, (x_t^N, y_t^N)\} \quad (2)$$

模型输出的未来时间范围 H 内的预测轨迹记为:

$$T_f = \{\hat{P}_{T+1}, \hat{P}_{T+2}, \dots, \hat{P}_{T+t}, \dots, \hat{P}_{T+H}\} \quad (3)$$

其中, \hat{P}_{T+t} 是 N 台汽车在时刻 $T+t$ 的预测位置,记为:

$$\hat{P}_{T+t} = \{(\hat{x}_{T+t}^1, \hat{y}_{T+t}^1), \dots, (\hat{x}_{T+t}^n, \hat{y}_{T+t}^n), \dots, (\hat{x}_{T+t}^N, \hat{y}_{T+t}^N)\} \quad (4)$$

3 模型设计

3.1 STGACN 模型框架

STGACN 模型的整体结构如图 1 所示,由轨迹信息嵌入模块、时空卷积块组和轨迹预测模块组成。首先,由轨迹信息嵌入模块获取车辆历史轨迹数据,依据不同时刻车辆间的空间拓扑结构生成对应的时空图,并按序输入时空卷积块组中。时空卷积块组通过堆叠若干时空卷积块联合处理图结构的时序数据,并在完成时空特征的提取与融合后,将数据送入轨迹预测模块。轨迹预测模块对特征数据进行编码和解码,通过循环更新增强数据的时空相关性后,生成预测轨迹。

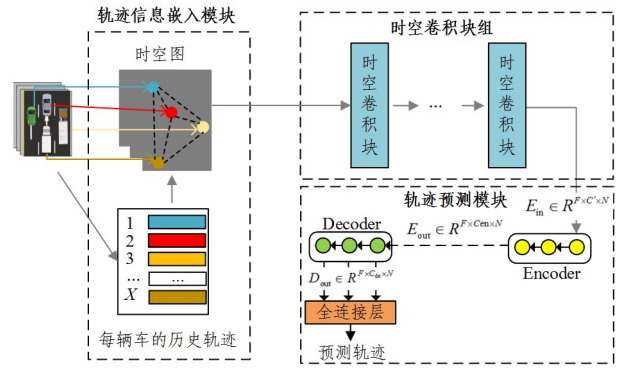


图 1 STGACN 模型框架

Fig. 1 STGACN model framework

3.2 轨迹信息嵌入模块

在交通场景中,目标车辆下一时刻的运动行为变化至少会受到两个方面的影响:一是当前时刻目标车辆的轨迹特征,包括位置、速度、加速度、航向角等;二是目标车辆与周围车辆间的时空相关信息,这些信息随时间改变而动态变化,如相对速度、相对距离等。

在轨迹信息嵌入模块中,充分考虑这两个方面的影响,从轨迹数据中分离出各车辆的历史轨迹,同时根据空间拓扑结构生成时空图,以便通过图卷积模块进行空间特征的提取。在时间范围 T 内的时空图定义为 $G = \{G_t | \forall t \in \{1, \dots, T\}\}$,其中 G_t 表示 t 时刻车辆间的空间关系图,一个空间关系图对应一个时刻的建模方式,使模型能够同时考虑时序和空间信息。假设场景中有 N 台汽车, $G_t = \{V_t, E_t\}$,其中 $V_t = \{v_n^t | \forall n \in \{1, \dots, N\}\}$ 是所有顶点的集合。每个顶点 v_n^t 代表场景中的一台汽车, v_n^t 的属性为坐标 (x_n^t, y_n^t) 。 E_t 为所有边的集合,边表示车辆之间的相关性权值。通常将两车之间的相关性权值设为 1,默认相互影响是相同的^[14]。但实际驾驶场景下,每台汽车对其他车辆具有不同的影响。例如,车辆突然减速变道会导致近车减速或变道,但对远车影响较小。为了区分两台车辆之间相关性的强度,引入了加权邻接矩阵^[21],并为 E_t 中的每条边赋予不同的权值。距离越近的两台车对彼此的影响越强,矩阵采用两车之间距离的倒数来衡量它们之间的权重,这样距离越近的车权重越大。邻接矩阵 A_t 如下:

$$A_t = \begin{pmatrix} 0 & \frac{1}{d_{1,2}} & \dots & \frac{1}{d_{1,N}} \\ \frac{1}{d_{2,1}} & 0 & \dots & \frac{1}{d_{2,N}} \\ \dots & \dots & \dots & \dots \\ \frac{1}{d_{N,1}} & \frac{1}{d_{N,2}} & \dots & 0 \end{pmatrix} \quad (5)$$

其中, $d_{i,j}$ 表示车辆 i 和 j 在 t 时刻的欧氏距离。

轨迹信息嵌入模块根据对应时刻的历史轨迹数据生成时空图和邻接矩阵。图 2 给出了邻接矩阵示例,图中每个顶点对应一台车辆,车辆间的距离由近似取整后的欧氏距离衡量。欧氏距离的计算如式(6)所示:

$$d(2,1) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (6)$$

其中, (x_2, y_2) 和 (x_1, y_1) 表示车辆 2 和车辆 1 的坐标。最终

以距离的倒数表示加权邻接矩阵 A_0 中的权重。




图2 邻接矩阵示意图

Fig. 2 Adjacency matrix diagram

为便于后续模块能够直接对时空图进行运算,轨迹信息嵌入模块采用邻接矩阵表示 N 台车的时空图,其时间复杂度为 $O(N^2)$ 。

3.3 时空卷积块组

为了融合轨迹数据的时序和空间特征,本文模型构建了时空卷积块组处理图结构的时间序列。时空卷积块(ST Conv Block)可以根据预测性能要求进行堆叠,卷积块堆叠数量越多,特征提取越丰富,但模型参数量和复杂度也会上升。

如图3所示,时空卷积块包含两个门控时间卷积层和图注意力网络层。门控时间卷积层采用卷积结构捕获轨迹数据的时序变化,同时采用时空卷积操作关注各节点与其他节点在不同时间步下的时空特征,实现时空特征融合。图注意力网络层通过捕捉同一时间步下不同节点之间的空间依赖关系,进一步增强模型学习节点之间时空关联性的能力。卷积块通过分层设计,由图注意力网络层桥接两个门控时间卷积层,实现快速的空间状态传播。同时,此“三明治”结构还有助于网络充分应用瓶颈策略^[23]。图注意力网络层作为瓶颈层,将特征维度先缩小,实现数据尺度压缩和特征压缩,同时保留数据的重要特征,完成特征提取后再将维度扩展还原。每个时空卷积块内均采用残差连接和层归一化来防止过拟合。




图3 时空卷积块

Fig. 3 Spatial-temporal convolutional network block

3.3.1 门控时间卷积层

在时间维度上,车辆下一时刻的运动高度依赖于历史轨迹。例如,需要变道的车辆最有可能在接下来的几秒钟之内继续进行变道的行动。现有研究方法中,LSTM网络常用于提取轨迹数据的时序特征。然而,LSTM迭代耗时且容易发生梯度爆炸,降低了模型训练效率和预测精度。

为解决这一问题,门控时间卷积层采用基于CNN的门控时间卷积^[24]网络提取时序特征。该网络由一个长度为 K_t 的一维膨胀因果卷积和非线性的门控线性单元(Gated Linear Unit, GLU)组成。膨胀因果卷积是门控卷积网络的核心

操作,对于长度为 n 的输入序列,其时间复杂度为 $O(n * K_t)$ 。GLU是网络中的非线性激活函数。通常,GLU的计算可以认为是常数时间复杂度。综合上述两个部分,该网络的总体时间复杂度为 $O(n * K_t)$,而LSTM中的主要操作包括门操作,如输入门、遗忘门、输出门等。若输入序列的长度为 n ,LSTM隐藏状态的维度为 h ,LSTM的参数数量(权重和偏置)为 p ,则其时间复杂度为 $O(n * h * p)$ 。从算法理论上比较,门控时间卷积网络具有更小的时间复杂度。

在数据处理过程中,门控时间卷积层对于时空图 G 中每个节点的时间卷积输入表示为 $Y \in R^{M \times C_t}$,其中 M 为时间序列长度, C_t 为通道数。时间门控卷积公式如下:

$$\Gamma * Y = P \odot \sigma(Q) \in R^{(M-K_t+1) \times C_t} \quad (7)$$

其中,卷积核 $\Gamma \in R^{K_t \times C_t \times C_t}$, \odot 表示哈达玛积。卷积核以均分通道数的设计将输入序列 Y 分别映射到单个元素 P 和 Q ,它们作为GLU的两个门输入。非线性门控机制采用 \tanh 和 sigmoid 激活函数,使得网络拥有对时序数据的非线性建模能力,并通过堆叠多个时序处理层关注到所有时间域的信息。

通过对每个节点使用相同的卷积核 Γ ,将时序卷积推广到三维,进行时空卷积操作。针对三维输入 $X \in R^{N \times M \times C_t}$,其中 N 为节点数,时空卷积操作可表示为:

$$Y_{n,t} = \sum_{k=1}^C \sum_{\tau=1}^M \sum_{i=1}^N \sum_{j=1}^N X_{i,k,\tau} \cdot K_{n,i,j,t} \quad (8)$$

其中, $Y_{n,t}$ 是输出的节点 n 在时间步 t 的特征; $X_{i,k,\tau}$ 是输入节点 i 在时间步 τ 的特征; $K_{n,i,j,t}$ 是时空卷积核中的权重,用于学习节点 i 和 j 之间在时间步 t 的时空关系。

时空卷积操作不仅考虑了每个节点在每个时间步的特征,还考虑了每个节点与其他节点在不同时间步的时空关系。时空卷积核的参数 K 为可学习参数,它能够有效捕捉图结构中的时空依赖关系,允许模型同时学习时序和空间维度上的权重,实现时空特征的融合。

3.3.2 图注意力网络层

在空间维度上,车辆的未来轨迹高度依赖于其附近车辆的运动。为了捕捉空间相关性,常将同一时刻所有车辆所处路面划分成网格^[13],使用网格中的空格数量来表示车辆之间的距离。这些方法能够捕捉到空间特征,但是网格划分受车辆尺寸影响较大,且大量的空网格数计算导致模型的效率降低。轨迹信息嵌入模块构建的时空图包含车辆之间的空间相关性,且图卷积神经网络能够直接对图进行运算^[23],因此本文采用图卷积神经网络提取轨迹间的空间特征。

图卷积运算表示为:

$$\mathbf{Z}^{(l+1)} = f(\mathbf{A}_l^{-\frac{1}{2}} \hat{\mathbf{A}}_l \mathbf{A}_l^{-\frac{1}{2}} \mathbf{Z}^{(l)} \mathbf{W}^l) \quad (9)$$

其中, $\mathbf{Z}^{(l+1)}$ 为 l 层顶点的特征矩阵; $f(\cdot)$ 是激活函数; $\hat{\mathbf{A}}_l = \mathbf{A}_l + \mathbf{I}$, $\mathbf{I} \in R^{N \times N}$ 是单位矩阵; $\mathbf{A}_l \in R^{N \times N}$ 是 $\hat{\mathbf{A}}_l$ 的对角节点度矩阵; \mathbf{W}^l 是 l 层的注意力矩阵。 $\mathbf{A}_l^{-\frac{1}{2}} \hat{\mathbf{A}}_l \mathbf{A}_l^{-\frac{1}{2}}$ 将邻接矩阵归一化,加快图卷积神经网络的学习速度。

考虑到时空图中不连通的两个节点之间也可能存在较强的关联性,如前车制动会影响到后面所有车辆,本文将空间注意力机制与图卷积结合。空间注意力能够根据输入数据自适应地关注最相关的特征,可以自适应捕获任意节点之间的空间相关性^[25]。注意力矩阵 \mathbf{W} 参与计算的方式如式(10)所示:

$$\mathbf{W} = \mathbf{O}\sigma(\mathbf{Y}_{l-1}\mathbf{Z}_1\mathbf{Z}_2(\mathbf{Z}_3\mathbf{Y}_{l-1})^T + \mathbf{b}) \quad (10)$$

其中, \mathbf{Y}_{l-1} 为第 $l-1$ 个时空块的输出,也是第 l 个时空块的输入; $\mathbf{Z}_1, \mathbf{Z}_2, \mathbf{Z}_3$ 均为可学习的参数矩阵。

针对图注意力网络层的时间复杂度分析,同样集中在图卷积网络和注意力机制。图卷积网络的时间复杂度通常受到图的规模和结构的影响,而注意力机制也要考虑序列长度和特征维度。假定输入序列数为 n ,图卷积参数量为 d ,特征维度为 f ,一个简单的图卷积层的时间复杂度记为 $O(n * d * f)$,一次自注意力机制记为 $O(n^2 * f)$ 。在图注意力网络层中,将图卷积网络和注意力机制结合,综合考虑二者因素,总体时间复杂度表示为 $O(n * d * f + n^2 * f)$ 。

3.4 轨迹预测模块

提取到轨迹数据的时空特征后,预测车辆轨迹就是一个典型的序列生成任务。门控递归单元(Gated Recurrent Unit, GRU)网络在序列任务上具有成本低廉且性能优异的特点,因此本文采用基于 GRU 的编码-解码网络从特征数据中提取关键信息进行轨迹预测。

GRU 网络结构如图 4 所示,该网络通过文献[26]提出的方程计算当前隐藏状态 \mathbf{h}_t 和当前输出状态 \mathbf{y}_t ,如式(11)所示:

$$\begin{cases} \mathbf{r}_t = \sigma(\mathbf{W}_{rx} \cdot \mathbf{x}_t + \mathbf{W}_{rh} \cdot \mathbf{h}_{t-1}) \\ \mathbf{z}_t = \sigma(\mathbf{W}_{zx} \cdot \mathbf{x}_t + \mathbf{W}_{zh} \cdot \mathbf{h}_{t-1}) \\ \mathbf{h}'_t = \tanh(\mathbf{W}'_{hx} \cdot \mathbf{x}_t + \mathbf{W}'_{hh} \cdot (\mathbf{r}_t \odot \mathbf{h}_{t-1})) \\ \mathbf{h}_t = \mathbf{z}_t \mathbf{h}_{t-1} + (1 - \mathbf{z}_t) \odot \mathbf{h}'_t \\ \mathbf{y}_t = \sigma(\mathbf{W}_o \cdot \mathbf{h}_t) \end{cases} \quad (11)$$

其中, \mathbf{x}_t 是当前输入状态; \mathbf{h}_{t-1} 表示前一刻的隐藏状态; $\sigma(\cdot)$ 为 sigmoid 函数; $\mathbf{W}_{rx}, \mathbf{W}_{rh}, \mathbf{W}_{zx}, \mathbf{W}_{zh}, \mathbf{W}'_{hx}, \mathbf{W}'_{hh}$ 是参数矩阵; \odot 表示哈达玛积。本文采用式(11)循环更新获得隐藏状态和输出状态。循环中,GRU 通过门控机制决定更新、重置和保留特征记忆,再次增强时空特征相关性。

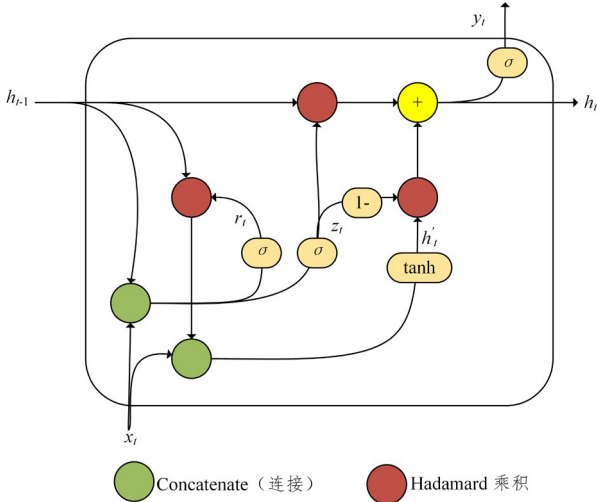


图 4 门控递归单元结构

Fig. 4 Architecture of GRU

轨迹预测模块的输入表示为 $E_{in} \in R^{F \times C \times N}$,其中向量 $e_{in} \in R^C$ 为编码器 GRU 的输入, F 为批处理大小。通过对式(10)进行 N 次迭代循环更新后,编码器 GRU 的隐藏状态由初始状态(等于零)更新到最终状态 \mathbf{h}_N 。编码器每一次迭代的输出为 $e_{out} \in R^{C_{en}}$,其中 C_{en} 是编码器的隐藏层大小。最终

将编码器的所有输出级联为张量 $E_{out} \in R^{F \times C_{en} \times N}$ 。 \mathbf{h}_N 和 E_{out} 分别作为初始隐藏状态和输入张量传递到解码器 GRU 中。

在解码迭代中,解码器 GRU 的输入状态为向量 $e_{out} \in R^{C_{de}}$,每次迭代输出 $d_{out} \in R^{C_{de}}$ 。其中, C_{de} 是解码器的隐藏层大小。经过 N 次迭代后,将所有输出 d_{out} 级联为张量 $D_{out} \in R^{F \times C_{de} \times N}$ 。最后,将张量 D_{out} 送入到全连接层,由该层生成预测轨迹。

最后,对轨迹预测模块的时间复杂度进行讨论。该模块的核心为基于门控循环单元的编码解码网络。其时间复杂度分析涉及到前向传播和反向传播的计算。假设输入序列长度为 n ,隐藏状态维度为 h ,参数量为 p 。前向传播中,单个时间步 GRU 的时间复杂度为 $O(h^2)$,计算序列长度为 n ,其总体时间复杂度为 $O(n * h^2)$ 。反向传播的时间复杂度通常与前向传播相同,为 $O(n * h^2)$ 。编码解码阶段均采用单层 GRU,因此基于 GRU 的编码解码网络的总体前向传播和反向传播的时间复杂度为 $O(n * h^2)$ 。而基于 LSTM 的编码解码网络整体的时间复杂度取决于序列长度、LSTM 层的大小和层数。同样假设输入序列长度为 n ,编码解码器中每个时间步的计算复杂度大致为 $O(h * d)$,其中 h 是隐藏状态的维度, d 是输入维度。对于 l 层的编码解码网络,整体的时间复杂度大致为 $O(l * n * h * d)$ 。单层 GRU 网络结构在理论上的时间复杂度同样优于基于 LSTM 网络的编码解码网络。

4 实验分析

4.1 数据集

为了分析 STGACN 模型在城市道路场景中的预测性能和计算效率,使用了 Argoverse 和 NGSIM 两个公共数据集对模型进行评估。两个数据集记录的场景均为城市道路,且在大量研究中进行了实验验证,具有较强的代表性。

Argoverse 数据集[27]由 Argo AI 公司团队收集,数据涵盖匹兹堡和迈阿密两座城市,包含 30 万条车辆轨迹和相应的语义地图。每条轨迹包含 5 s 数据,都是以 10 Hz 采样的帧序列。实验过程中,前 2 s 输入为模型的学习数据;后续 3 s 为真实数据,与预测数据对比,验证模型的预测结果。

NGSIM 数据集包含研究人员收集的加利福尼亚州洛杉矶的 US101[28]、Lankershim Boulevard 南行、加利福尼亚州 Emeryville 的 I-80[28] 东行以及佐治亚州亚特兰大的 Peachtree 街道 4 个场景的详细车辆轨迹数据。初始数据以 10 Hz 的频率记录城市交通中的轨迹信息,其中包含了畅通、较拥堵和重度拥堵交通场景下 45 min 的车辆轨迹。

4.2 实验设置

由于部分对比方法的代码未开源或算法复杂难以复现,为便于进行对比,本文采用多种实验环境适应实验需求。不同方法在 Argoverse 上的性能对比实验、不同方法在 NGSIM 上的 RMSE 比较及时空卷积块堆叠数量测试实验均在 Ubuntu 18.04 服务器(GPU: NVIDIA RTX 3090 24 GB, CUDA 11, Pytorch 1.11.0, Python 3.8)进行。参数量大小和预测耗时对比实验选择在 NVIDIA GTX1080Ti GPU 环境下进行。实验选取数据集的 60% 作为训练集,30% 作为测试集,

剩余 10% 作为验证集。模型使用 Adam 优化器优化训练, MSE 为损失函数, batch_size 为 128, 初始学习率设置为 0.01。解码器和编码器都是单层 GRU, 由全连接层输出最终预测结果。

4.3 评价指标

为了便于与基线模型进行对比, 实验沿用对应数据集常用的评价指标。Argoverse 数据集对比实验常用 3 个评价指标, 即最小平均位移误差 (ADE)、最小终点位移误差 (FDE) 和未命中率 (MR)。

1) 最小平均位移误差 (MinADE): 最佳预测轨迹的每个预测位置和每个真实位置之间的平均欧氏距离差值。

$$\text{MinADE} = \frac{1}{n} \sum_{i=1}^n \sqrt{(\hat{x}_i - x_i)^2 + (\hat{y}_i - y_i)^2} \quad (12)$$

其中, n 表示轨迹点总数, (\hat{x}_i, \hat{y}_i) 为预测轨迹坐标, (x_i, y_i) 为真实轨迹坐标。

2) 最小终点位移误差 (MinFDE): 最佳预测轨迹终点预测位置和终点真值位置之间的平均欧氏距离差值。

$$\text{MinFDE} = \sqrt{(\hat{x}_i - x_i)^2 + (\hat{y}_i - y_i)^2} \quad (13)$$

其中, (\hat{x}_i, \hat{y}_i) 为预测轨迹坐标, (x_i, y_i) 为真实轨迹坐标。

3) 未命中率 (MR): 最终位置距离真实位置超过 2.0 m 的预测的比率。

$$\text{MR} = \frac{\text{FN}}{\text{TP} + \text{FN}} \quad (14)$$

其中, FN 表示模型未能正确预测的轨迹点, TP 表示模型正确预测的轨迹点。

NGSIM 数据集对比实验中, 采用均方根误差 (RMSE) 来评估性能。

$$\text{RMSE}_t = \sqrt{\frac{1}{n} \sum_{i=1}^n [(\hat{x}_i - x_i)^2 + (\hat{y}_i - y_i)^2]} \quad (15)$$

其中, (\hat{x}_i, \hat{y}_i) 为 t 时刻预测轨迹的坐标, (x_i, y_i) 为 t 时刻真实轨迹的坐标, n 表示轨迹点总数。

4.4 实验比较与分析

采用 Argoverse 数据集进行对比实验, 验证模型的预测性能。对比的基线模型包括:

1) LSTM^[29]: 使用长短期记忆网络捕获历史轨迹的时序特征, 在网格图上生成未来轨迹。

2) LaneGCN^[30]: 采用矢量地图构造车道图, 增强模型构建车道拓扑结构和捕捉长时依赖的能力。

3) DSP^[16]: 应用图神经网络提取车辆交互信息中不同层次的空间特征, 并将特征与基于注意力的层间网络进行聚合, 实现局部-全局特征融合, 然后由编码解码模块输出预测轨迹。

4) CratGCN^[17]: 引入材料科学领域的晶体图卷积方法并与多头自注意力相结合, 有效利用边缘特征, 在不依赖地图信息的情况下捕获车辆之间的空间相关性, 采用长短期记忆网络捕获时序特征。

运动预测中, 通常会考虑多种可能的运动路径, 即存在多个可能的轨迹预测结果。Argoverse 使用前 K 个预测的最小 ADE (MinADE) 和最小 FDE (MinFDE) 作为度量标准, 其基准测试最多允许 6 个预测。本文选用 $K=1$ 和 $K=6$ 的

MinADE, MinFDE 和 MR 数据作为度量标准。

如表 1 所列, 本文提出的 STGACN 模型在全部评估指标中性能表现均最佳。模型采用时空卷积块组, 以块为整体同时处理时间和空间信息, 块内图注意力网络层桥接两个门控时间卷积层的设计进一步增强了时空特征融合效果, 捕获到数据中的动态时空特征, 在特征提取上优于其他对比模型。与基线模型中性能最优的 DSP 模型相比, STGACN 模型 MinADE_{@K=1} 和 MinFDE_{@K=1} 的性能均提高了 2.5%, MinADE_{@K=6} 和 MinFDE_{@K=6} 的性能分别提高了 12% 和 9%。

表 1 不同方法在 Argoverse 上的性能对比实验

Table 1 Performance comparison experiment of different methods on Argoverse

模型	K=1			K=6		
	MinADE	MinFDE	MR	MinADE	MinFDE	MR
LSTM	2.15	4.97	0.75	1.44	2.78	0.31
LaneGCN	1.71	3.78	0.59	0.87	1.36	0.16
CratGCN	1.67	3.64	0.60	0.96	1.44	0.22
DSP	1.59	3.60	0.55	0.82	1.22	0.15
STGACN	1.55	3.51	0.53	0.72	1.11	0.14

为了验证 STGACN 模型能否在更为复杂的交通环境下仍保持较好的预测精度, 在场景更丰富的 NGSIM 数据集上将其与 3 个能够在更长预测范围内保持较好预测性能的基线模型进行对比实验。

1) CS-LSTM^[13]: 模型基于长短期记忆网络提出卷积社交池化层处理空间交互信息, 并基于意图预测目标车辆的轨迹分布。

2) GRIP^[20]: 使用图卷积网络对车辆之间的交互进行建模, 并使用 LSTM 网络预测场景中所有车辆的未来轨迹。

3) GSTCN^[21]: 以图卷积网络和卷积神经网络为主干网络, 可以同时预测所有邻近车辆的未来轨迹分布。

表 2 列出了不同模型预测未来 5s 轨迹的 RMSE 值。可以看到, 对于 1s 范围内的预测, GRIP 的性能表现更好, 这源于它通道数的增加。但在更长时序预测范围中, STGACN 模型均优于 GRIP, 其平均 RMSE 值比 GRIP 低约 11%, 比另一基于图卷积的模型 GSTCN 低约 3%, 比 CS-LSTM 模型低约 23%, 比不考虑空间相关性的 LSTM 网络模型低约 56%。该实验数据表明, 与其他对比方法相比, STGACN 模型在复杂交通场景下能够更好地保持预测性能, 尤其在更长的预测范围中, 其误差值更低。如第 4s 的预测结果表明, STGACN 模型误差比 GRIP 低 14%, 比 GSTCN 低约 3.5%, 这再次证明面对更丰富的时空信息时, STGACN 模型较其他模型具有更优秀的特征提取与融合能力。

表 2 不同方法在 NGSIM 上的 RMSE 比较

Table 2 Comparison of RMSE of different methods on NGSIM

预测时段	LSTM	CS-LSTM	GRIP	GSTCN	STGACN
1s	0.66	1.03	0.37	0.42	0.40
2s	1.62	1.13	0.86	0.81	0.80
3s	2.94	1.61	1.45	1.29	1.25
4s	4.63	2.31	2.21	1.97	1.90
5s	6.63	3.21	3.16	2.95	2.86
平均	3.30	1.86	1.61	1.49	1.44

时空卷积块组通过联合多个卷积块共同处理图结构的

时间序列,融合空间和时序特征,提高模型预测精度。但卷积块的堆叠数量需要依据性能需求和资源开销的综合考量。为验证时空卷积块最合适的堆叠数量,本文进行了一组消融实验。

图 5 展示了在 NGSIM 数据集上采用不同时空卷积块堆叠预测未来 5s 车辆轨迹得到的 RMSE 值。可见,仅采用一个时空卷积块时,其每个时间节点的 RMSE 值都明显高于其他 4 种堆叠情况。当堆叠两个时空卷积块时,与使用一个时空卷积块相比,每个时间节点的 RMSE 值都有明显下降,预测精度提升较大。继续增添时空卷积块,预测精度提升微弱,同时增加了模型参数量;第 3 章模型设计中对各模块的时间复杂度分析也说明,添加时空卷积块会带来额外的时间开销。因此,为在提升模型预测精度的同时尽可能减少参数量,缩短预测时间,本文将时空卷积块的堆叠数 2 作为模型的最优选择。




图 5 时空卷积块堆叠数量的测试
Fig. 5 ST Conv Block num test

轨迹预测模型的参数量大小和轨迹预测速度是模型能否在车辆终端上进行部署的两个关键因素,前者决定该方法能否在有限的硬件资源情况下出色地完成工作,后者反映车辆是否有足够的时间根据预测结果做出决策并安全执行。本文选择同样基于图卷积的 CratGCN^[17], GRIP^[20] 和 GSTCN^[21] 进行模型参数量大小和预测耗时的对比,实验结果如表 3 所列。

表 3 不同模型参数量大小和预测耗时的对比

Table 3 Comparison of parameter size and prediction time of different models

模型	参数量	预测耗时/s
CratGCN	6.11×10^7 (1 166.0 \times)	1.290(29.3 \times)
GRIP	4.963×10^5 (9.4 \times)	0.322(6.2 \times)
GSTCN	4.89×10 (0.93 \times)	0.044(0.85 \times)
STGACN	5.24×10	0.052

从表 3 可以看出,CratGCN 模型的参数量大小是 STGACN 模型的 1166 倍,GRIP 模型的参数量大小是 STGACN 的 9.4 倍。STGACN 与此前性能表现优秀的图卷积方法 GSTCN 相比,模型参数量大小仅相差约 4K。对于预测速度,在相同的预测环境下,比较每个模型预测一台目标车辆未来轨迹所需的平均时间。STGACN 模型平均预测开销为 0.052 s,约为 CratGCN 的 1/29,约为 GRIP 的 1/6,与表现优异的 GSTCN 模型相比,仅相差约 0.008 s。上述结果表明,STGACN 采用 CNN 和 GCN 为主干网络,减少递归结构带来的限制,有效地降低了模型参数量,提高了模型的推理速度。STGACN 虽然与 GSTCN 模型存在较小差距,但从表 2 的对比实验中看出其在预测精度上有所提升。

最后,利用 NGSIM 数据集对城市道路中畅通、较拥堵和重度拥堵交通场景的预测轨迹进行可视化,定性分析 STG-

ACN 的预测性能以及其在实际场景中的应用前景。

图 6 中,长间距虚线表示被观测车辆的 3s 历史轨迹,实线表示被观测车辆的未来 5s 预测轨迹,短间距虚线表示被观测车辆的未来 5s 真实轨迹。被观测车辆 5s 内的横向和纵向位移的长短体现其速度的快慢。如图 6(a)所示,当交通条件较好时,车辆间基本不存在相互影响,且 5s 内横向位移较长,车辆倾向于高速行驶。预测轨迹与真实轨迹的高度相同,展示出 STGACN 模型学习到了这一特征。在较拥堵的环境(见图 6(b))中,车辆间的交互增多,如 2 车道前车行驶较慢,后车准备借 3 车道超车以提高行驶速度,致使 3 车道前车速度降低,轨迹变短。可视化中预测轨迹和真实轨迹长度和位置仍然比较契合,证明模型学习到了这些交互行为,并成功预测了未来轨迹。而在重度拥堵交通环境下,车辆运动更为复杂。如图 6(c)中,3 车道车辆拥堵,行驶缓慢,而 2 车道后车尝试借 1 车道超车,导致 1 车道车辆减速转向。可以看到,重度交通拥堵环境下的车辆行驶过程中,车辆间的交互更为频繁,但 STGACN 仍然预测到了所有车辆的未来轨迹分布,这表明该模型在重度交通环境中依旧有效地学习到了车辆间的动态时空特征。STGACN 模型在畅通、较拥堵和重度拥堵城市交通场景中均准确地预测到了未来轨迹的分布,表明模型能够捕获不同交通条件下车辆间的动态时空特征,能够在实际交通场景中适应畅通的交通状况,面对拥堵和重度拥堵情况时,同样能够保持较好的预测性能。这也证明了该模型对于复杂动态的轨迹变化的学习和预测具有很高的鲁棒性和泛化能力。

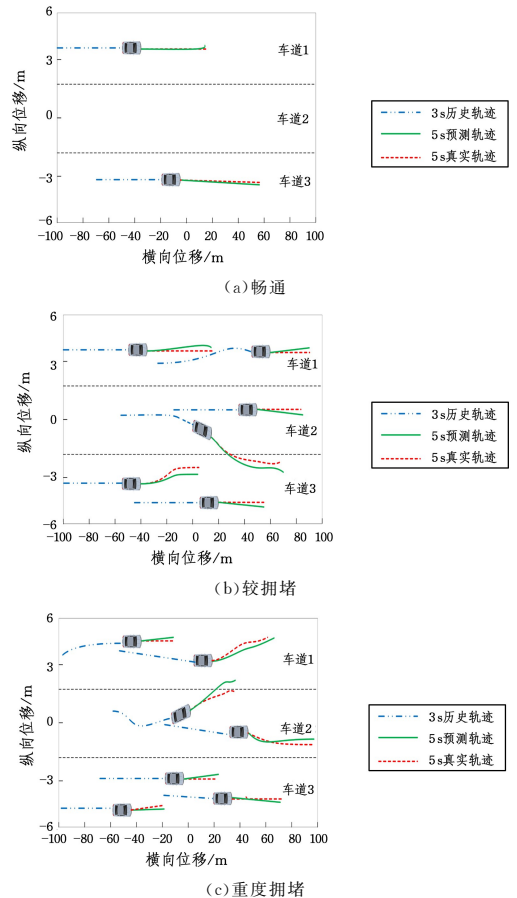


图 6 畅通、较拥堵和重度拥堵交通场景下预测轨迹的可视化
Fig. 6 Visualization of predicted trajectories in smooth, congested and heavily congested traffic scenarios

结束语 本文提出了时空图注意力神经网络模型进行车辆轨迹预测,充分获取城市道路交通场景中车辆间复杂多变的时空相关性,提取更丰富的时空特征,提高轨迹预测精度,同时降低模型复杂度,提高预测效率。一方面,该模型根据拓扑图结构将车辆历史轨迹数据转换为时空图,然后通过时空卷积块组完成轨迹数据的时序特征和空间特征的提取与融合。时空卷积块采用图注意力网络层桥接两个门控时间卷积层的结构设计,增强模型时空特征融合的效果,提高预测精度。另一方面,模型采用由膨胀因果卷积和门控单元组成的门控卷积网络进行时序特征提取工作,避免了长短期记忆网络等循环神经网络带来的冗余迭代,模型参数更少,模型预测效率更高。模型在 Argoverse 和 NGSIM 数据集上进行了验证。考虑到车辆轨迹预测依赖的数据不仅仅是位置轨迹数据,还可以包括图像数据、雷达数据和通信数据等,未来的工作将继续拓展网络模型,探索优化模型处理大规模数据的能力,增加多种交通场景进行实验,考虑不同道路环境对模型的影响,进一步增强和验证模型的泛化能力。

参 考 文 献

- [1] GAO H B, CHENG B, WANG J Q, et al. Object classification using CNN-based fusion of vision and LIDAR in autonomous vehicle environment[J]. IEEE Transactions on Industrial Informatics, 2018, 14(9): 4224-4231.
- [2] ZHANG M H, DU D H, ZHANG M Z, et al. Spatio-temporal trajectory data-driven autonomous driving scenario meta-modeling approach[J]. Journal of Software, 2021, 32(4): 973-987.
- [3] HUANG Y J, DU J T, YANG Z Y, et al. A Survey on Trajectory-Prediction Methods for Autonomous Driving [J]. IEEE Transactions on Intelligent Vehicles, 2022, 7(3): 652-674.
- [4] BRANNSTROM M, ERIK C, JONAS S. Model-based threat assessment for avoiding arbitrary vehicle collisions [J]. IEEE Transactions on Intelligent Transportation Systems, 2010, 11(3): 658-669.
- [5] CARVALHO A, GAO Y, LEFEVRE S, et al. Stochastic predictive control of autonomous vehicles in uncertain environments [C] // Proceedings of 12th International Symposium on Advanced Vehicle Control. 2014: 712-719.
- [6] LEFEVRE S, VASQUEZ D, LAUGIER C. A survey on motion prediction and risk assessment for intelligent vehicles[J]. Robomech J, 2014, 1(1): 1-14.
- [7] GAO H B, CHEN L, ZHANG T, et al. A structure constraint matrix factorization framework for human behavior segmentation[J]. IEEE Transactions on Cybernetics, 2021, 52(12): 12978-12988.
- [8] DEO N, RANGESH A, TRIVEDI M M. How would surround vehicles move? a unified framework for maneuver classification and motion prediction[J]. IEEE Transactions on Intelligent Vehicles, 2018, 3(2): 129-140.
- [9] TRAN Q, FIRL J. Online maneuver recognition and multimodal trajectory prediction for intersection assistance using non-parametric regression[C] // 2014 IEEE Intelligent Vehicles Symposium Proceedings. IEEE, 2014: 918-923.
- [10] GAO H B, QIN Y H, HU C, et al. An interacting multiple model for trajectory prediction of intelligent vehicles in typical road traffic scenario[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 34(9): 6468-6479.
- [11] GAO H B, SU H, CAI Y F, et al. Trajectory prediction of cyclist based on dynamic Bayesian network and long short-term memory model at unsignalized intersections[J]. Science China Information Sciences, 2021, 64(7): 172207.
- [12] ZYNER A, WORRALL S, NEBOT E. A recurrent neural network solution for predicting driver intention at unsignalized intersections[J]. IEEE Robotics and Automation Letters, 2018, 3(3): 1759-1764.
- [13] DEO N, TRIVEDI M M. Convolutional social pooling for vehicle trajectory prediction[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). IEEE, 2018: 1468-1476.
- [14] ZHAO Z Y, FANG H W, JIN Z, et al. GISNet: Graph-Based Information Sharing Network For Vehicle Trajectory Prediction [C] // Proceedings of 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020: 1-7.
- [15] LI K, YANG L, ZHAO Y, et al. EGCN-CeDML: A Distributed Machine Learning Framework for Vehicle Driving Behavior Prediction[J]. Computer Science, 2023, 50(9): 318-330.
- [16] ZHANG L, LI P, CHEN J, et al. Trajectory prediction with graph-based dual-scale context fusion. [C] // RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2022: 11374-11381.
- [17] SCHMIDT J, JORDAN J, GRITSCHNEDER F, et al. CRAT-Pred: Vehicle Trajectory Prediction with Crystal Graph Convolutional Neural Networks and Multi-Head Self-Attention[C] // 2022 International Conference on Robotics and Automation (ICRA). IEEE, 2022: 7799-7805.
- [18] LI W L, HAN D, SHI X H, et al. Vehicle Trajectory Prediction Based on Spatial-temporal Attention Mechanism[J]. China Journal of Highway and Transport, 2023, 36(1): 226-239.
- [19] GAO K, LI X, CHEN B, et al. Dual Transformer Based Prediction for Lane Change Intentions and Trajectories in Mixed Traffic Environment[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 23(6): 6203-6216.
- [20] LI X, YING X W, CHUAH M C. GRIP: Graph-based interaction-aware trajectory prediction[C] // Proceedings of 2019 IEEE Intelligent Transportation Systems Conference (ITSC). IEEE, 2019: 3960-3966.
- [21] SHENG Z H, XU Y W, XUE S B, et al. Graph-Based Spatial-Temporal Convolutional Network for Vehicle Trajectory Prediction in Autonomous Driving[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 17654-17665.
- [22] AZADANI M N, BOUKERCHE A. STAG: A novel interaction-aware path prediction method based on Spatio-Temporal Attention Graphs for connected automated vehicles[J]. Ad Hoc Networks, 2023, 138: 103021.
- [23] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional

networks: a deep learning framework for traffic forecasting [C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. IJCAI, 2018;3634-3640.

[24] GEHRING J, AULI M, GRANGIER D, et al. Convolutional sequence to sequence learning[C]//Proceedings of International Conference on Machine Learning. IMLS, 2017;1243-1252.

[25] FENG X C, GUO J, QIN B, et al. Effective deep memory networks for distant supervised relation extraction [C]// Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence(IJCAI). 2017;4002-4008.

[26] CHO K, VAN M B, GULCEHRE C et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//the 2014 Conference on Empirical Methods in Natural Language Processing. ACL, 2014;1724-1734.


[27] CHANG M F, LAMBERT J, SANGKLOY P, et al. Argoverse: 3d tracking and forecasting with rich maps[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2019;8748-8757.

[28] COLYAR J, HALKIAS J. Us highway 101 dataset[J]. Federal Highway Administration(FHWA), 2007,1:27-69.

[29] PARK S H, KIM B D, KANG C M, et al. Sequence-to-sequence

prediction of vehicle trajectory via LSTM encoder-decoder architecture[C]//2018 IEEE Intelligent Vehicles Symposium(IV). IEEE, 2018;1672-1678.

[30] LIANG M, YANG B, HU R, et al. Learning lane graph representations for motion forecasting[C]//European Conference on Computer Vision. Springer, 2020;541-556.



YUAN Jing, born in 1997, postgraduate. His main research interests include deep learning and trajectory prediction.



XIA Ying, born in 1972, Ph.D, professor, Ph.D supervisor, is a senior member of CCF(No. 10248S). Her main research interests include spatio-temporal big data and cross-media retrieval.

(责任编辑:柯颖)

申报提醒 | CCF 产学合作基金

2024 年度 CCF 产学合作基金目前有 5 支基金同步申报中,部分基金已进入申报倒计时,欢迎 CCF 会员关注并积极申报。

CCF 产学合作基金启动于 2013 年,截止 2023 年底已有超千个项目获得基金资助,通过 CCF 搭建的产学合作平台正在以良好的产学应用效果服务于计算机行业。

1)2024 年 CCF-蚂蚁科研基金隐私计算专项 & 绿色计算算效专项

10 月 24 日, CNCC 2024 期间,2024 年度 CCF-蚂蚁科研基金隐私计算专项 & 绿色计算算效专项于蚂蚁集团主办的“产学研融合助力科研探索暨 CCF-蚂蚁科研基金发布论坛”上正式对外发布,隐私计算专项计划投入约 300 万元,共推出 16 个课题,绿色计算算效专项计划投入 500 万,共推出 21 项研究课题。申报截止时间为北京时间 2024 年 11 月 24 日 24:00(北京时间)。

2)2024 年 CCF-华为胡杨林基金软件工程专项(鸿蒙专题)

为促进鸿蒙生态和相关产业在中国的健康发展,CCF 联合华为为设立 CCF-华为胡杨林基金软件工程专项鸿蒙专题,助力前瞻性地构建鸿蒙相关关键技术竞争力。专题资助激励高校学者与产业界专家合作进行鸿蒙相关前沿技术的研发,推动产业创新发展。本期鸿蒙专题拟资助 10 个课题,资助金额 30 万元/项,优秀项目额外资助 10 万元/项(不超过 2 个),课题申报截止时间为 2024 年 11 月 30 日 24:00(北京时间)。

3)2024 CCF-深信服“远望”科研基金(第二期)

CCF-深信服“远望”科研基金重点面向国内高校、科研机构的研究人员和团队,旨在以小微课题的方式支持科研人员的研究与创新,推动科研成果转化,促进外部科研机构优秀研发能力与公司内部产品价值深度融合,构建互动合作与创新发展的生态圈,为深信服的产品与解决方案创新赋能。2024 年计划资助不少于 20 项课题,项目实施期为 1 年,单项资助额度最高 20 万元,申报截止时间:2024 年 11 月 30 日 24:00(北京时间)。

4)2024 CCF-玻色量子计算应用创新基金

2024 年 11 月 6 日,CCF 和北京玻色量子科技有限公司联合发起“CCF-玻色量子计算应用创新基金”,此次基金项目共发布两项研究主题,主题一是以量子计算技术与 AI 人工智能相结合为研究方向;主题二是以量子计算与金融、物流与供应链、社会与城市治理、能源与电力、医疗与生命科学等领域的应用场景发掘作为主要研究方向。玻色量子作为该基金项目的独家资金赞助商,将公开资助上述主题范围内的研究项目,资助金额为人民币 10—20 万元/项。申报截止时间:2024 年 12 月 6 日 24:00(北京时间)。