

深度时空混合图卷积的城市交通预测模型

郭海锋¹,许宏伟²,周子盛²

¹(浙江工业大学网络空间安全研究院,杭州310000)

²(浙江工业大学信息工程学院,杭州310000)

E-mail: guohf@zjut.edu.cn

摘要: 由于交通网络复杂的时空相关性和交通数据的非线性,给交通预测带来了很大的挑战. 现有的方法主要关注路网的时空特征,分别对时间相关性和空间相关性进行建模来模拟时空依赖关系. 随着城市道路网络的进一步扩大,导致模型对路网空间特征的挖掘能力不足. 此外,交通运行状态受到外部环境因素的干扰,交通流在路段传递效应的影响下会出现较大波动. 为解决上述问题,提出深度时空混合图卷积模型,利用图卷积网络和图注意力网络的残差连接分别汇聚路网全局和局部信息,扩展图卷积的感受野范围,从而增强路网空间特征的提取能力. 受 Transformer 在长序列预测上的启发,同时为减少计算复杂度,通过引入 Informer 模型来处理路网数据潜在的时间依赖性,实现对交通流参数的长期预测能力,并对城市天气和 POI(医院,学校,商场)等外部因素进行编码来增强路网信息的属性. 为验证所提出模型的性能,在真实数据集上开展实验,对模型进行准确性和可行性分析. 实验结果表明,深度时空混合图卷积模型预测精度最高达到 75.1%,较 Transformer 和 Informer 分别提升了 2.5% 和 2.3%,在不同预测范围下都超过了其他基线模型,具有长期的交通预测能力.

关键词: 交通预测;时空依赖;道路网络;图神经网络;长期预测

中图分类号: TP301

文献标识码: A

文章编号: 1000-1220(2025)01-0097-07

Urban Traffic Prediction Based on Deep Spatio-temporal Hybrid Graph Convolution

GUO Haifeng¹, XU Hongwei², ZHOU Zisheng²

¹(Institute of Cybersecurity, Zhejiang University of Technology, Hangzhou 310000, China)

²(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310000, China)

Abstract: Due to the complex spatio-temporal correlations and nonlinear patterns in the traffic network, traffic prediction presents substantial challenges. Existing methods primarily focus on the spatio-temporal features of road networks, separately modeling temporal and spatial correlations to simulate spatio-temporal dependencies. As urban road networks continue to expand, existing models may lack the ability to fully exploit the spatial characteristics of road networks. Furthermore, the traffic operational state is influenced by external environmental factors, leading to significant fluctuations in traffic flow due to segment transmission effects. To address these issues, a deep spatio-temporal hybrid graph convolution model is proposed. The residual connected graph neural network and graph attention network are used to aggregate the global and local information of the road network, respectively, thereby extending the receptive field of graph convolutions to enhance the extraction capability of spatial features. Inspired by the Transformer's success in long sequence prediction and to reduce computational complexity, the Informer model is introduced to handle the potential temporal dependencies in road network data. This achieves long-term prediction capabilities for traffic flow parameters and encodes external factors such as city weather and points of interest to enhance road network information attributes. To validate the performance of the proposed model, accuracy and feasibility analyses are conducted on real-world datasets. Experimental results demonstrate that the deep spatio-temporal hybrid graph convolution model achieves a peak accuracy of up to 75.1%, outperforming Transformer and Informer models by 2.5% and 2.3% respectively. It surpasses other baseline models across different prediction ranges, showcasing its long-term traffic prediction capabilities.

Keywords: traffic prediction; spatio-temporal dependency; road network; graph neural network; long-term forecastin

0 引言

交通预测是智能交通系统中备受关注的研究领域,长期有效的交通预测对道路状况和车辆调度^[1]至关重要,在交通

管理和控制中起着关键作用. 交通预测是指通过部署大量的传感器来收集历史交通信息和其他相关数据,对未来的交通流量、车辆行驶时间、路段速度以及车辆分布类型^[2]等参数进行预测,由于城市路网愈加复杂的时空相关性,交通预测变

得十分困难。一方面,驾驶行为的差异性导致交通数据在时间维度上存在未知性,从交通参数的长期变化趋势来看具有一定周期性规律。另一方面,上游路段发生的交通事故和突发事件^[3]通过递归效应转移到下游路段,使得系统很难快速响应这些变化,从而无法单纯的依靠时间依赖性^[4]进行特征提取。

随着大数据技术的快速发展和智能交通系统的不断推进,交通预测领域取得了显著的进展。传统的交通预测方法主要基于统计学模型,如线性回归、ARIMA、卡尔曼滤波以及HAM模型等。这些方法能够反映交通数据的一般规律,但对交通数据的非线性关系和时空依赖性建模能力有限。随着深度学习技术的兴起,利用数据驱动的方法在交通预测任务中取得了显著突破,如卷积神经网络^[5]、长短期记忆网络^[6](Long Short-Term Memory Network, LSTM)和门控循环单元^[7](Gated Recurrent Unit, GRU)等,可以对大规模交通数据进行学习和建模,能够捕捉到潜在的非线性关系和时空依赖性,提高了预测精度,但忽略了交通数据的空间相关性。近年来,基于图神经网络^[8](Graph Neural Networks, GNNs)的模型被提出用于交通预测,该方法能模拟更加复杂的路网结构,但面对路网复杂的时空相关性,目前的图数据模型仍存在着不足。城市交通网络是个庞大的拓扑结构数据群,除了考虑全局信息外,局部区域发生的突发事件会对周围交通状况产生影响,图神经网络很难捕捉该边缘特征。此外,图神经网络本质上是低通滤波器,经过多层融合后会出现过度平滑的现象,导致节点特征相似性增加,表达能力下降,因此实现深层图神经网络对提取路网空间特征至关重要。在时间依赖性方面,现有方法无法进行针对性的路段研究,LSTM和GRU等时间序列预测模型将所有路段看成单一个体,把交通流的空间维度预处理为数据特征来对模型参数进行优化,忽略了个体间的差异性,导致模型泛化能力不足。

综上,本文提出了深度时空混合图卷积模型,旨在进一步加强路网的时空信息提取,并利用Informer模型对单个路段进行交通时序的预测。同时考虑外部环境因素对路网参数的影响,对其独热编码后嵌入到时间序列预测模型中,增强路网的特征属性,从时空依赖层面来完成交通预测任务。

1 相关工作

交通预测涵盖了对车辆数量、通行时间、路段速度以及车辆类型分布等参数的预测,主要分为模型驱动方法和数据驱动方法^[9]。模型驱动方法通过先验知识对路网进行数学建模,代表性模型包括排队论模型^[10]、交通速度模型^[11]和微观基本图模型^[12]等。这些方法过于依赖大量的先验知识,无法处理路段突发事件和交通事故等外部因素,难以准确描述交通数据中潜在的非线性关系。相比之下,数据驱动方法基于真实的交通数据建模,可分为数学统计模型、机器学习模型和神经网络模型,相对于模型驱动方法更具合理性。数学统计模型的经典方法包括ARIMA^[13]、线性回归^[14]和卡尔曼滤波等,但在处理交通长序列预测问题上存在较大局限。基于机器学习的交通预测模型应运而生,例如K-最邻近算法^[15]和支持向量机^[16],它们能够模拟复杂的交通运行状况,但对于捕获路网中的非线性特征能力有限。

随着神经网络的发展,时间序列预测性能有了显著提升。黄等人^[17]首次利用深度通信网络来处理交通流信息进行参数预测,但该方法无法建立数据在时间上的依赖关系。为了捕捉路网的时间依赖性,RNN及其变种LSTM^[18]和GRU^[19]被发现更适合交通时间序列数据的预测,具有较强学习数据动态变化的能力。GRU模型不仅解决了RNN在反向传播时梯度消失或梯度爆炸的问题,相对于LSTM模型参数更少,在细节丰富的路网中具有更好的预测效果^[20]。但这些模型仍未解决交通路网中存在的空间依赖关系问题,并且对于远距离时序传输时容易造成信息损失。卷积神经网络^[21]在捕获空间特征方面对欧几里得空间较为适用,但面对路网复杂的拓扑结构时存在较大局限,将路网一定范围内的流量矩阵转换成卷积应用的图像取得效果较低。直到图神经网络的广泛应用,在图数据上取得了显著的效果,例如图分类^[22]、节点分类^[23]和链路检测等^[24]。在交通预测领域,GNN^[25,26]将道路网络直接处理为带有边和节点的图以提取空间依赖关系,如利用图卷积网络^[27](Graph Convolution Network, GNN)和图注意力网络^[28,29](Graph Attention Network, GAT)等方法汇聚相邻节点的信息,通过考虑时间和空间领域处理更复杂的数据^[30],从而建立路网时空特征依赖关系。GAT对空间局部特征具有更好的解释性,通过分配边权重区分出邻接节点对目标节点的不同影响力。此外,交通运行状态还会受到天气和环境因素的影响。Liao等人^[31]通过在LSTM中集成编码器来处理外部信息,将多模态数据建模为序列,以实现交通预测任务。利用外部因素的多源数据可以增强路网信息属性,从而提高模型预测的泛化能力。

近年来,Transformer^[32]在自然语言处理领域展现出卓越性能,其内部的自注意力机制对每个输入和输出位置对之间进行分数评估,能够准确捕捉两者的长期依赖关系,避免信息损失。特定的自注意力机制导致Transformer的计算复杂度较高,并且解码器的输出速度较慢。为了解决这些问题,在Transformer概念的基础上提出了Informer^[33]长序列预测模型,通过使用ProbSparse自注意力机制降低时间复杂度,并添加卷积层以提高局部上下文的性能,在不同的数据集上证明了Informer在长期预测任务中的有效性^[34,35]。以往方法在使用Informer模型进行交通预测时仅考虑到序列时间维度上的特征,忽略了路段之间的空间相关性,时间戳部分只针对长序列的时间周期进行编码。对此,为了探究天气、POI(其中包括学校、医院、商场等影响交通流量的标志建筑)因素对交通流的影响,在Informer模型中嵌入时间戳编码,可用于处理时间序列数据,有助于模型更好的理解和捕捉时间信息的模式和依赖关系。通过对天气、POI进行独热编码,与速度序列的位置编码组成Informer时间特征提取层的输入,不增加过多训练参数的情况下增强数据特征维度,提高模型线性回归精度,在实验环节加入消融实验来验证方案的可行性。在空间层面,本文利用GCN和GAT网络构建混合图卷积模型,来获取数据在传递过程中的空间特征。由于GCN和GAT网络本质上属于低通滤波器,经过多次堆叠会出现过平滑现象,导致节点表达能力下降,节点之间呈相似性。为了解决该问题,通过引入残差网络以提高模型的表达能力和抑制过平滑现象。在每个GCN和GAT模块的输出特征上,将原始节点特征与网络

输出特征进行相加形成残差连接,用于保留原始特征的细节和区分度,抑制特征的过度平滑化,并增强模型对节点的细粒度建模能力。

本文旨在探讨和研究交通预测领域的最新进展,针对现有方法的不足提出新算法,主要贡献如下:

1)解决了图神经网络由于过平滑现象导致对空间特征提取能力不足的问题,提高了对全局和局部的依赖关系,加强了路网空间信息的传递。

2)针对上游混合图卷积输出的节点数据均使用单个 Informer 模型进行特征提取,节点之间参数相互独立,实现全图路段时序的并发预测。

3)通过对外部环境因素进行编码,引入到 Informer 模型的时间戳中,提高模型预测精度,增强模型的泛化能力。

4)实验结果表明本文所提出模型在不同范围预测下的效果均优于基线模型,并可以实现长期的交通预测任务。

2 深度时空混合图卷积的交通预测

2.1 数据分析

本文将城市各路段的瞬时速度作为实验研究对象,选取的数据集来自深圳出租车车辆,采集了共 156 条路段的数据,时间窗口为 5 分钟,主要包括关于速度的时间序列 $X_T = (X_1, X_2, \dots, X_T)$, $X_T \in R^{T \times N}$,其中 $X_t = (x_{1,t}, x_{2,t}, \dots, x_{N,t})$ 表示 t 时刻 N 条路段对应的速度时序;描述各路段相邻关系的邻接矩阵 $A, A \in R^{N \times N}$;对应时间的天气情况以及周围环境的 POI(学校、医院、商场)数据。基于以上信息,路网结构可以表示为 $G = \{O, R, A\}$,其中 O 是节点集, R 是连接节点的边集,邻接矩阵 A 代表了节点对的连通性。通过对收集的数据分析发现,交通流在长期范围下呈周期性变化,在时间维度上具有依赖关系,即未来流量变化会受历史时刻的交通流影响,因此提取路网参数在时间链路上的非线性关系是交通预测任务的关键。

另外交通流在空间维度上也具有强相关性,由于传递效应上游路段的交通状况会影响下游路段,相邻路段的交通流在短期内变化趋势相似,且下游路段存在一定的滞后性,道路网络的拓扑结构会进一步扩大该特征,对路网空间建模也是提高预测精度的重要途径。除了上述的时空依赖性,外部因素也会对交通运行状态造成影响,例如交通流在雨天以及人流量密集地区变化缓慢且波动幅度较小。

通过以上分析,将对路网时空层面建模,捕捉其空间相关性和周期性,并对天气和 POI 进行独热编码,嵌入到模型中以增强交通预测的鲁棒性和可靠性。

2.2 空间相关性建模

本文利用图卷积网络处理路网的图结构,如图 1 所示,将路段目标视作节点对其进行特征聚合,通过一个可学习的权重矩阵进行线性变换,生成新的节点特征表示。GCN 在解释模型的输出和分析节点影响力时具有较好的可解释性,有助于深入理解图数据中的节点关系和特征重要性,如公式(1)所示:

$$H^{(l+1)} = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}) \quad (1)$$

其中 \hat{A} 是自相关的邻接矩阵,描述了各路段之间的相邻关

系, $H^{(l)}$ 是第 l 层的特征表示, $W^{(l)}$ 是第 l 层的权重矩阵。该汇聚方式消除了数据稀疏性,每个节点的表示由其邻居节点的特征加权平均得到,可以更好捕获图的全局特征。




图 1 图卷积网络框架

Fig. 1 Graph convolutional network framework

除了关注路网全局信息外,目标节点的局部信息汇聚也至关重要。图注意力网络加入注意力机制来动态学习和判断节点在信息传递过程中的重要性,如图 2 所示,节点特征被表示为特征向量,通过权重学习允许网络在信息聚合时对周围节点赋予不同的权重,注重于局部邻接节点的特征汇聚,汇聚方式如公式(2)所示:

$$e_{ij} = \text{att}[W\hat{x}_i, W\hat{x}_j] \quad (2)$$

其中 x_i 表示目标节点特征, x_j 表示邻接节点特征, $W \in R^{F' \times F}$ 为线性变化的加权矩阵, F' 输出特征维度。




图 2 多头图注意力网络框架

Fig. 2 Multi-head GAT layer illustration

在真实的交通网络中,不是所有链路之间都是连通的,需要邻接矩阵来选择图中的邻域进行注意权重计算,并对所有的注意权重系数归一化操作,如公式(3)所示:

$$\alpha_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(\text{LeakyReLU}(\overrightarrow{\text{att}}^T[W\hat{x}_i \| W\hat{x}_j]))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(\overrightarrow{\text{att}}^T[W\hat{x}_i \| W\hat{x}_k]))} \quad (3)$$

其中 N_i 表示目标节点 i 在图结构中的邻接节点, $\|$ 为连接操作。此外, GAT 网络可引入多头注意力机制来捕捉到不同的节点信息,提高模型的表达能力,来减少模型的过拟合风险,增强模型的泛化能力。具体操作如公式(4)所示:

$$\overrightarrow{h}_i = \sigma\left(\frac{1}{k} \sum_{k=1}^k \alpha_{ij}^k W^k \overrightarrow{h}_j\right) \quad (4)$$

将 k 组相互独立的注意力机制的结果进行平均操作,其中 α_{ij}^k 表示第 k 个注意力机制的归一化权重系数。

2.3 时间相关性建模

基于路网的全局时间依赖性建模是交通流预测的关键步

骤. Transformer 模型采用 Encoder-Decoder 框架,通过引入自注意力机制对输入序列中不同位置之间的关系进行建模,因此能够更好地处理远距离的时间依赖关系.自注意力机制的特点是对所有节点的 Q 、 K 和 V 执行缩放的点积,并对聚合数据使用 softmax 函数计算每个位置的注意力分数.注意力的计算方法如公式(5)所示:

$$A(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d}}\right) \quad (5)$$

其中 d 为 K 的向量维度, $Q \in R^{l_Q \times d_{in}}$, $K \in R^{l_K \times d_{in}}$, $V \in R^{l_V \times d_{in}}$, d_{in} 表示输入序列的维度.第 i 个 Q 的注意力系数的概率公式如公式(6)所示:

$$A(q_i, K, V) = \sum_j \frac{k(q_i, k_j)}{\sum_i k(q_i, k_i)} v_j = E_{p(k_j|q_i)}[v_j] \quad (6)$$

其中 $p(k_j|q_i) = \frac{k(q_i, k_j)}{\sum_i k(q_i, k_i)}$, $k(q_i, k_j)$ 是 Attention 中的不对称指数核 $\exp\left(\frac{q_i k_j^T}{\sqrt{d}}\right)$.

面对真实的交通场景,并非所有 Q 、 K 点积对都占据主导地位,全部进行相关性运算会提高计算复杂度和增加内存消耗.如图3所示,Informer通过使用ProbSparse自注意力机制

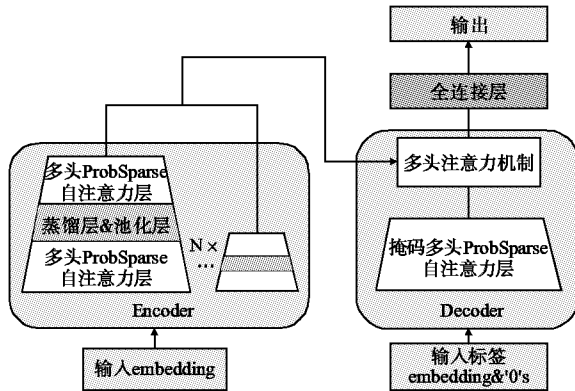


图3 Informer长序列预测模型

Fig. 3 Informer long sequence prediction model

替代 Self-attention,引入稀疏化概率来控制每个位置与其他位置的连接概率,从而减少了注意力权重的计算和存储成本.ProbSparse 自注意力机制首先对采样得到样本 \bar{K} ,再利用 KL 散度来衡量均匀分布和 Attention 分布的相似性,对于每个 $q_i \in Q$ 关于 \bar{K} 求其稀疏性度量 M ,如公式(7)所示:

$$M(q_i, K) = \ln \sum_{j=1}^{l_K} e^{\frac{q_i k_j^T}{d_{in}}} - \frac{1}{l_K} \sum_{j=1}^{l_K} \frac{q_i k_j^T}{d_{in}} \quad (7)$$

其中前半部分是 q_i 关于所有 K 的 LSE(Log-Sum-Exp),后半部分是算术平均值.但在计算 M 时需要进行 O 次计算 ($L_Q L_K$),会导致 LSE 数值上下波动,通过近似计算方法来替代 M ,如公式(8)所示:

$$\bar{M}(q_i, K) = \max_j \frac{q_i k_j^T}{\sqrt{d_{in}}} - \frac{1}{l_K} \sum_{j=1}^{l_K} \frac{q_i k_j^T}{\sqrt{d_{in}}} \quad (8)$$

其中 $\bar{M}(q_i, K)$ 值越大表示其对 Attention 越重要,找到 \bar{M} 值最大的 u 个 q_i ,关于 K 的自注意力分数如公式(9)所示:

$$A(Q, K, V) = \text{Softmax}\left(\frac{\bar{Q}K^T}{\sqrt{d}}\right) \quad (9)$$

式中 Q 和 \bar{Q} 具有相同的维度, \bar{Q} 是由 M 值最大的 u 个 q_i 组成,其余部位用 0 填充.Informer 在 ProbSparse 自注意力层之间加入了蒸馏操作,利用一维卷积和最大池化层将 x_t 长度减半来剔除关于冗余的自注意力分数所对应的 V 值,以提取主导注意力和聚焦序列特征,从第 m 层到第 $m+1$ 层的蒸馏操作如公式(10)所示:

$$X'_{m+1} = \text{MaxPool}(\text{ELU}(\text{Conc1d}([\text{X}'_m]_{MH}))) \quad (10)$$

其中 Conc1d 代表一维卷积操作, $[\]_{MH}$ 表示多头概率稀疏自注意力操作.

2.4 深度时空混合图卷积的交通网络建模

基于以上研究,搭建深度时空混合图卷积模型(Deep Hybrid Spatiotemporal Graph Convolution, DSTHGC),如图4所示,该模型分为2个部分:

1)深度混合图卷积层,捕捉网络的空间关系.模型输入为 L 个历史时刻的速度序列 $X_L = (X_1, X_2, \dots, X_L)$,将长序列按照时间维度分割成 $X_t = (x_{1,t}, x_{2,t}, \dots, x_{N,t})$ 后依次输入到空间提取层,空间提取层的输出为包含 N 个节点的切片信息 $H_t^N = (h_t^1, h_t^2, \dots, h_t^N)$, $H_t^N \in R^{N \times d}$, d 为隐藏层数量.

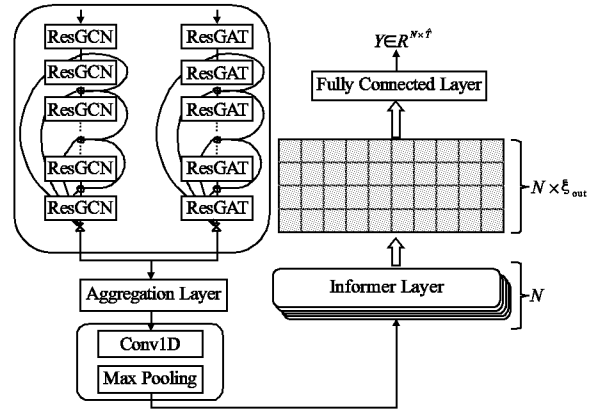


图4 深度时空混合图卷积模型

Fig. 4 Deep spatio-temporal hybrid graph convolution model

2)Informer 时间信息提取层,捕捉长序列的时间依赖性.用 N 个 Informer 单元来处理对应数量的节点特征,Informer 单元之间参数相互独立,时间信息传递层将空间层切片信息 H_t^N 提取时间特征后进行输出,输出结果为 \hat{Y} , $\hat{Y} \in R^{N \times \hat{E}_{out}}$,最后通过全连接层得到预测结果 Y , $Y \in R^{N \times T}$, T 为预测时间步数.

此外在空间和时间层之间引入了一维卷积,对每个节点的特征进行局部上下文的建模.一维卷积通过一个窗口在特征序列上进行滑动,并在每个位置上应用卷积操作,其输入是混合图卷积层的输出结果,即节点的切片信息 $H_t^N = (h_t^1, h_t^2, \dots, h_t^N)$, $H_t^N \in R^{N \times d}$,这样可以有效地捕捉到序列中的局部模式和依赖关系.

3 案例应用与结果分析

3.1 实验数据

实验选取了真实的交通数据集,该数据集来自于深圳罗湖区的出租车车辆.选择了156条主要道路,并记录了相同时间间隔的速度值,这些记录每5分钟汇总一次.除了特征矩阵

外,该数据集还包含邻接矩阵,显示了 156 条道路之间的空间依赖性.此外,还收集了该地区对应时间窗口的天气情况和 POI,并对其进行独热编码作为本次实验的数据.对于深度时空混合图卷积模型(DSTHGC),使用 80% 的数据作为训练集,其余的数据作为测试集.序列样本的滑动窗口为 $T + T'$,其中 T 为输入序列长度, T' 为真实数值的标签长度,实验预测范围为 4 个时间步长,分别为 15 分钟,30 分钟,45 分钟和 60 分钟.模型涉及的超参数手动进行调整以达到最佳效果,注意力头数设为 4,隐藏层数量设为 32,训练迭代次数设为 300 次.选用的损失函数如公式(11)所示:

$$loss = \| Y_t - \hat{Y}_t \| + \tau L_{reg} \quad (11)$$

其中 L_{reg} 是 $L2$ 正则化,用于避免模型出现过拟合, τ 为超参数.

3.2 评估指标

为了验证 DSTHGC 的预测性能,使用了 5 个评估指标来描述交通数据真实值 Y_t 和模型预测值 \hat{Y}_t 之间的差异,包括:均方根误差 RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_t - \hat{Y}_t)^2} \quad (12)$$

表 1 DSTHGC 模型和基线模型对未来 15 分钟交通状况的预测结果

时间	性能指标	ARIMA	GRU	T-GCN	Transformer	Informer	DSTHGC
15min	RMSE	8.691	5.621	5.138	3.128	2.817	2.763
	MAE	7.623	4.313	4.123	2.362	1.965	2.215
	Accuracy	0.462	0.712	0.724	0.732	0.736	0.751
	R^2	0.081	0.823	0.841	0.856	0.853	0.858
	Var	*	0.823	0.841	0.854	0.853	0.856

不计.选用不同的基线模型与 DSTHGC 进行对比,分别选用 15 分钟、30 分钟、45 分钟和 60 分钟 4 个不同范围来表示各模

平均绝对误差 MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_t - \hat{Y}_t| \quad (13)$$

精确度 Accuracy:

$$Accuracy = 1 - \frac{\| Y - \hat{Y} \|_F}{\| Y \|_F} \quad (14)$$

可决系数 R^2 :

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{i=1}^n (Y_t - \bar{Y}_t)^2} \quad (15)$$

解释方差分数 Var:

$$Var = 1 - \frac{Var\{Y - \hat{Y}\}}{Var\{Y\}} \quad (16)$$

其中, RMSE 和 MAE 用来描述预测误差大小,数值越小则预测效果越好, Accuracy 用来表示模型预测精确性,数值越大代表预测精准度越高, R^2 和 Var 则表示预测值代表真实值的能力,数值越大说明模型预测能力越高.

3.3 实验结果与分析

实验结果如表 1 ~ 表 4 所示,其中 * 表示数值太小,忽略

型预测性能. DSTHGC 模型在大多数指标下获得了最好的性能,从结果分析可以得出以下结论:

表 2 DSTHGC 模型和基线模型对未来 30 分钟交通状况的预测结果

时间	性能指标	ARIMA	GRU	T-GCN	Transformer	Informer	DSTHGC
30min	RMSE	10.627	6.584	5.467	3.096	3.123	2.728
	MAE	8.454	4.695	4.638	2.312	2.387	2.345
	Accuracy	0.453	0.701	0.713	0.728	0.730	0.745
	R^2	0.009	0.813	0.831	0.849	0.845	0.853
	Var	*	0.816	0.829	0.846	0.842	0.856

表 3 DSTHGC 模型和基线模型对未来 45 分钟交通状况的预测结果

时间	性能指标	ARIMA	GRU	T-GCN	Transformer	Informer	DSTHGC
45min	RMSE	11.443	6.873	5.823	3.258	3.385	2.954
	MAE	9.567	4.917	4.755	2.460	2.453	2.367
	Accuracy	0.439	0.698	0.710	0.723	0.725	0.742
	R^2	*	0.810	0.814	0.841	0.839	0.843
	Var	*	0.812	0.817	0.841	0.842	0.841

1) 在基线模型中,从 GRU 到 DSTHGC 的神经网络方法比传统 ARIMA 回归模型具有更好的预测性能,验证了对路网时间依赖关系提取的必要性.在 4 个预测范围中, DSTHGC 模型预测性能均高于基线模型.对于 15 分钟的预测任务, DSTHGC 的预测精度比 ARIMA 模型提高了 37.7%, RMSE 误差降低了 68.2%,较 GRU 和 Transformer 模型预测

精度分别提高了 4% 和 2.5%, RMSE 误差分别降低了 50.8% 和 11.7%,说明该模型在时间非线性特征提取上具有明显的优越性.

2) 为了验证路网空间特征提取的重要性,在基线模型中加入了仅对时间特征建模的 Informer 网络,并与具有捕获空间特征能力的 DSTHGC 模型进行对比.所有时间步的预测任

务中,DSTHGC均明显优于Informer模型,其中对于15分钟的预测结果,DSTHGC预测精度较Informer提高了2.3%,RMSE误差降低了2%,表明图卷积层可以帮助模型从序列

数据中捕获空间依赖和更好的理解隐藏特征,同时也验证了DSTHGC模型可以提取路网潜在的空间特征信息,加强路段之间的信息传递,提高交通预测的精度.

表4 DSTHGC模型和基线模型对未来60分钟交通状况的预测结果

时间	性能指标	ARIMA	GRU	T-GCN	Transformer	Informer	DSTHGC
60min	RMSE	12.647	7.127	6.027	3.356	3.415	3.158
	MAE	9.945	5.247	4.954	2.645	2.612	2.691
	Accuracy	0.424	0.687	0.707	0.718	0.721	0.739
	R ²	*	0.801	0.811	0.839	0.834	0.840
	Var	*	0.800	0.810	0.837	0.822	0.836

3)对于外部环境因素的引入,进行了消融实验,结果如图5所示,其中DSTHGC+F表示加入外部环境因素,对外部因素进行编码后DSTHGC模型预测精度相对提高了2.4%,RMSE误差降低了2.3%,实验证明增加路段节点的特征表达多样性可以提高交通预测的准确性.

DSTHGC模型在交通流量预测方面表现出色,仍需进一步研究和探索,以提高在实际应用中的准确性和实用性.例如,可以考虑引入交通事件、道路施工等更多的外部因素,以进一步提升模型对于复杂交通环境的适应能力.

4 结论

1)通过对图卷积模型和图注意力网络的残差连接,实现了交通路网空间信息的深度挖掘,避免模型多层连接后对路段节点造成的过平滑和特征多样性降低的问题,进一步把控路网全局和局部信息的融合,实验结果证明残差连接的混合图卷积模型在挖掘交通路网空间信息时表现出更好的鲁棒性和表达能力.

2)通过引入Informer模型解决了时间序列模型在长期预测问题上的不足,实现了更准确的长期交通流量预测.在传统时间序列模型中,由于缺乏对长期时序依赖关系的建模能力,对于未来较长时间范围内的交通流量预测表现较为有限.Informer模型作为一种基于注意力机制的深度学习模型,具备了处理长期时序依赖的优势,使得其在长期预测问题上表现出色.

3)针对Informer模型的时间戳引入外部因素编码,生成更加丰富的特征表示,实验结果证明引入外部因素编码的Informer模型在交通流量预测任务中表现出更高的预测准确性和稳定性.在未来研究中,将会进一步探究外部因素的重要性和对模型的影响,并优化了外部因素的编码方式,使其适应不同的交通场景,并结合更多的领域知识和技术手段,不断提升交通预测的精度和实用性.




图5 外部因素的消融实验

Fig. 5 Dilution experiment of external factors

此外,对某路段未来15分钟的交通流预测结果进行可视化.如图6所示,DSTHGC模型预测结果在整体上具有较好的拟合度,对于下潜数据能够精准的进行捕捉,不会出现预测数值过平滑现象.对于不同时间步的预测,DSTHGC模型预测结果相差较小,不会因为长期预测导致预测曲线偏离真实




图6 路段未来15分钟交通预测结果

Fig. 6 Traffic prediction results for segment in the next 15 minutes

结果,说明模型能够进行长期的交通预测任务.除实验中的外部因素外,路网运行状态还会受交通事件等其他因素干扰,DSTHGC模型在进行长期预测过程中未发生严重震荡而脱离预测目标,证明其具有一定的抗干扰能力,对外界敏感度较低,进一步验证了DSTHGC模型的可靠性和稳定性.尽管

References:

[1] Huang L,Zhao S,Luo R, et al. An incremental map matching approach with speed estimation constraints for high sampling rate vehicle trajectories[C]//IEEE 17th International Conference on Control & Automation (ICCA),2022:758-765.

[2] Luo R,Song Y,Zhao H, et al. Dense-tnt:efficient vehicle type classification neural network using satellite imagery[J]. arXiv preprint arXiv:2209.13500,2022.

[3] Siami-Namini S,Tavakoli N,Namin A S. A comparison of ARIMA and LSTM in forecasting time series[C]//17th IEEE International Conference on Machine Learning and Applications (ICMLA), 2018:1394-1401.

[4] Li Y,Yu R,Shahabi C, et al. Diffusion convolutional recurrent neu-

- ral network; data-driven traffic forecasting [J]. arXiv preprint arXiv:1707.01926, 2017.
- [5] Zhang J, Zheng Y, Qi D. Deep spatio-temporal residual networks for citywide crowd flows prediction [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2017:1655-1661.
- [6] Schmidhuber J, Hochreiter S. Long short-term memory [J]. Neural Comput, 1997, 9(8):1735-1780.
- [7] Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [J]. arXiv preprint arXiv:1406.1078, 2014.
- [8] Shi X, Qi H, Shen Y, et al. A spatial-temporal attention approach for traffic prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22(8):4909-4918.
- [9] Zhao H, Yang H, Wang Y, et al. Attention based graph bi-lstm networks for traffic forecasting [C]//IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), 2020:1-6.
- [10] Xu X, Liu J, Li H, et al. Analysis of subway station capacity with the use of queueing theory [J]. Transportation Research Part C: Emerging Technologies, 2014, 38:28-43, doi:10.1016/j.trc.2013.10.010.
- [11] Wang Q, Li L I, Hu J, et al. Traffic velocity distributions for different spacings [J]. Journal of Tsinghua University Science and Technology, 2011, 51(3):309-312.
- [12] XU F F, HE Z C, SHA Z R. Impacts of traffic management measures on urban network microscopic fundamental diagram [J]. Journal of Transportation Systems Engineering and Information Technology, 2013, 13(2):185-190.
- [13] Luo X, Li D, Zhang S. Traffic flow prediction during the holidays based on DFT and SVR [J]. Journal of Sensors, 2019, 2019(10):1-10, doi:10.1155/2019/6461450.
- [14] Sun H, Zhang C, Ran B. Interval prediction for traffic time series using local linear predictor [C]//Proceedings the 7th International IEEE Conference on Intelligent Transportation Systems (IEEE Cat. No. 04TH8749), 2004:410-415.
- [15] Van Lint J W C, Van Hinsbergen C. Short-term traffic and travel time prediction models [J]. Artificial Intelligence Applications to Critical Transportation Issues, 2012, 22(1):22-41.
- [16] Jeong Y S, Byon Y J, Castro-Neto M M, et al. Supervised weighting-online learning algorithm for short-term traffic flow prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(4):1700-1707.
- [17] Huang W, Song G, Hong H, et al. Deep architecture for traffic flow prediction: deep belief networks with multitask learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5):2191-2201.
- [18] Tian Y, Pan L. Predicting short-term traffic flow by long short-term memory recurrent neural network [C]//IEEE International Conference, 2015:153-158.
- [19] Zhang D, Kabuka M R. Combining weather condition data to predict traffic flow: a GRU-based deep learning approach [J]. IET Intelligent Transport Systems, 2018, 12(7):578-585.
- [20] Fu R, Zhang Z, Li L. Using LSTM and GRU neural network methods for traffic flow prediction [C]//31st Youth Academic Annual Conference of Chinese Association of Automation (YAC), 2016:324-328.
- [21] Liu Y, Zheng H, Feng X, et al. Short-term traffic flow prediction with Conv-LSTM [C]//9th International Conference on Wireless Communications and Signal Processing (WCSP), 2017:1-6.
- [22] Ying Z, You J, Morris C, et al. Hierarchical graph representation learning with differentiable pooling [J]. Advances in Neural Information Processing Systems, 2018, 31:4805-4815, doi:10.48550/arXiv.1806.08804.
- [23] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks [J]. arXiv preprint arXiv:1609.02907, 2016.
- [24] Zhang M, Chen Y. Link prediction based on graph neural networks [J]. Advances in Neural Information Processing Systems, 2018, 31:5171-5181, doi:10.48550/arXiv.1802.09691.
- [25] Wu Z, Pan S, Chen F, et al. A comprehensive survey on graph neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1):4-24.
- [26] Jiang W, Luo J. Graph neural network for traffic forecasting: a survey [J]. Expert Systems with Applications, 2022, 207:117921, doi:10.1016/j.eswa.2022.117921.
- [27] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [J]. arXiv preprint arXiv:1709.04875, 2017.
- [28] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks [J]. arXiv preprint arXiv:1710.10903, 2017.
- [29] Lin C Y, Su H T, Tung S L, et al. Multivariate and propagation graph attention network for spatial-temporal prediction with outdoor cellular traffic [C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management, 2021:3248-3252.
- [30] Zhao L, Song Y, Zhang C, et al. T-gcn: a temporal graph convolutional network for traffic prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(9):3848-3858.
- [31] Liao B, Zhang J, Wu C, et al. Deep sequence learning with auxiliary information for traffic prediction [C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018:537-546.
- [32] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30:6000-6010, doi:10.48550/arXiv.1706.03762.
- [33] Zhou H, Zhang S, Peng J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2021:11106-11115.
- [34] Wang X, Ma Y, Wang Y, et al. Traffic flow prediction via spatial temporal graph neural network [C]//Proceedings of the Web Conference, 2020:1082-1092.
- [35] Cai L, Janowicz K, Mai G, et al. Traffic transformer: capturing the continuity and periodicity of time series for traffic forecasting [J]. Transactions in GIS, 2020, 24(3):736-755.

附中文参考文献:

- [12] 许菲菲, 何兆成, 沙志仁. 交通管理措施对路网宏观基本图的影响分析 [J]. 交通运输系统工程与信息, 2013, 13(2):185-190.