

基于改进 STGCN 深度学习框架的交通速度预测

孙大盟, 欧阳安杰, 何立明
(长安大学 信息工程学院, 陕西 西安 710064)

摘要: 实时准确的交通速度预测对于加快智慧交通建设和推动智能交通系统发展至关重要。然而交通网络具有复杂的空间结构和动态随机的时变特征, 致使现有预测方法无法准确捕捉其隐藏的时空相关性。为了充分挖掘数据中隐藏的动态时空特性, 并提高预测准确性, 本文提出了一种基于 STGCN 框架的交通速度预测改进算法, 即时空注意力图神经网络 (STA-GNN)。该算法采用可学习的位置注意力机制, 有效聚合邻近节点信息, 从而获取道路网络中的空间相关性。同时, 引入带有门控机制的一维因果卷积网络为内核的时序卷积网络, 来捕获时间序列中的时间相关性, 并通过残差块连接来提高模型的泛化能力。所提方法在 PeMSD7 数据集上进行了 15 分钟、30 分钟和 45 分钟的交通速度预测实验。实验结果显示, 该模型在 45 分钟预测任务中, 均方根误差相较于 STGCN 模型降低了约 10.2%。表明 STA-GNN 模型在中长期交通速度预测任务中表现更为出色。

关键词: 智慧交通系统; 交通速度预测; 图卷积网络; 位置注意力机制; 时空相关性

中图分类号: TP31; U491.2

文献标识码: A

文章编号: 1673-629X(2024)11-0133-07

doi: 10.20165/j.cnki.ISSN1673-629X.2024.0225

Traffic Speed Prediction Based on Improved STGCN Deep Learning Framework

SUN Da-meng, OUYANG An-jie, HE Li-ming
(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: Real-time and accurate traffic speed prediction is crucial for accelerating smart transportation development and advancing intelligent traffic systems. However, the complex spatial structure and dynamic stochastic temporal characteristics of traffic networks make it challenging for existing prediction methods to accurately capture their hidden spatiotemporal correlations. To fully exploit the dynamic spatiotemporal features hidden in data and enhance prediction accuracy, we propose an improved traffic speed prediction algorithm based on the STGCN framework, namely the Spatiotemporal Attention Graph Neural Network (STA-GNN). This algorithm employs a learnable position attention mechanism to effectively aggregate information from neighboring nodes, thereby capturing spatial correlations within road networks. Simultaneously, it introduces a one-dimensional causal convolutional network with gate mechanisms as the kernel of the temporal convolutional network to capture time correlations in time series data. This is further enhanced through residual block connections to improve model generalization capability. The proposed approach was evaluated on the PeMSD7 dataset for traffic speed prediction experiments at 15-minute, 30-minute, and 45-minute intervals. Experimental results demonstrate that the proposed model achieves approximately 10.2% reduction in root mean square error compared to the STGCN model in the 45-minute prediction task, indicating superior performance of the STA-GNN model in mid- to long-term traffic speed prediction tasks.

Key words: smart transportation system; traffic speed prediction; graph convolutional network; position attention mechanism; spatial-temporal correlation

0 引言

随着智慧交通系统^[1]的快速发展和人们生活水平的提高, 机动车数量不断增加, 这导致城市道路出现严重的交通拥堵现象。缓解这一问题已成为当今社会

的迫切需求。交通速度预测在城市交通控制和管理方面发挥着重要作用。实时、准确的交通速度预测一方面为交通管理者提供有力的交通规划依据, 另一方面为交通出行者提前规划出行路线提供帮助, 从而缓解

收稿日期: 2024-03-12

修回日期: 2024-07-16

基金项目: 国家自然科学基金项目(51308058)

作者简介: 孙大盟(1999-), 男, 硕士研究生, 通信作者, 研究方向为交通流预测; 何立明(1978-), 男, 副教授, 研究方向为智能交通系统信息采集及融合。

或避免交通拥堵问题。

现有的交通预测模型主要分为 3 大类:基于统计理论的方法、基于传统机器学习的方法和基于深度学习的方法。近年来,随着对深度学习算法的深入研究,诸如长短期记忆网络(LSTM)^[2]等神经网络模型被广泛应用于交通速度预测任务中。相较于指数平滑模型^[3]和线性回归模型^[4]等统计理论模型,这些方法在非线性关系捕捉能力和预测精度方面具有显著优势。此外,使用支持向量回归(Support Vector Regression, SVR)^[5]和贝叶斯网络^[6]构造的机器学习模型逐渐被基于深度学习模型所替代,因为它们不能准确捕捉交通数据的动态特征。相反,基于深度学习的交通速度预测模型能充分捕捉交通时序数据中复杂的动态时空特征,成为了研究的热点。近年来,由于图卷积网络(Graph Convolution Network, GCN)^[7]在处理具有拓扑结构的图数据上表现良好,并进一步降低了图上卷积操作的复杂度,被广泛应用于交通速度预测模型中。赵嘉雨等^[8]在结合 GCN 和门控循环神经网络(Gated Recurrent Unit, GRU)的基础上,又通过加入对比学习中的 R-Drop 方法来捕捉交通网络中的时空相关性。陈华伟等^[9]利用 GCN 提取空间特征,利用 LSTM 提取时间特征,建立了面向在线地图的 GCN-LSTM 神经网络模型。冯思芸等^[10]采用全局图卷积的方法加深对空间特征的捕捉,采用门控循环单元提取时间特征,准确挖掘了城市路网中的时空特性。

上述神经网络模型在捕捉时间相关性方面采用的大多是基于循环神经网络(RNN)的方法。然而,采用这种方法会使网络存在迭代时间长和门控机制复杂等问题。此外,在处理较长的时间序列时,避免梯度弥散和梯度爆炸等问题仍然是一个具有挑战性的任务。相反,卷积神经网络(Convolutional Neural Network, CNN)结构简单,能并行计算输入的时间序列数据,降低了训练时间和难度。此外, CNN 网络具有梯度稳定等优点,有助于提高模型稳定性。Bai 等人^[11]提出了时间卷积网络(Temporal Convolutional Networks, TCN),通过在多种预测任务中采用 CNN,明确展示了 TCN 网络在处理序列建模任务方面的有效性,取得了比 RNNs 更好的性能。张安勤等人^[12]在 TCN 的基础上加入时间注意力机制来捕捉不同时间片段序列信息,充分提交通网络中的时间依赖性。另外,黄伟坚等人^[13]提出使用扩张因果卷积代替 TCN 中的因果卷积,在没有增加卷积层和增大卷积核的情况下扩大了感受野,实现了对长时间序列数据时间依赖关系的提取。Yu 等人^[14]提出了时空图卷积网络(Spatial - Temporal Graph Convolutional Networks, STGCN),通过在时间轴上采用完全卷积结构来捕捉

时间特征,有效避免了使用循环网络可能导致的缺陷。然而,该模型在捕捉空间相关性方面采用的是 GCN 网络,GCN 将相邻节点的信息均匀地聚合到给定的中心节点,无法根据节点的特征属性来调整邻居权重,这一限制影响了模型对空间相关性的捕捉能力。目前已经涌出许多基于注意力机制的交通速度预测模型^[15-16],但这些模型的注意力评分仅依赖于速度信息,忽略了其他重要因素,如车道数、车流量、停车设施等对交通流的影响。Wang 等人^[17]提出一种新的具有位置注意力机制的图神经网络层,能够更好地聚合邻近道路的交通流信息,以全面捕捉交通网络中的空间依赖关系。

为此,提出了基于 STGCN 框架的交通速度预测改进算法,即时空注意力图神经网络(STA-GNN)。使用带有位置注意力机制的图神经网络捕捉空间相关性;使用一维因果时序卷积网络来获取时间相关性,并通过残差连接提高模型的准确度。

1 问题陈述与模型构建

1.1 交通速度预测问题的定义

交通速度预测旨在通过分析历史交通数据和其他相关信息,预测未来某个时刻或时间段内特定地点或道路段的交通速度。具体而言,历史交通数据可以被视为交通网络上的时间序列。该交通网络被定义为一个拓扑图 $G = \{V, E, A\}$, 其中 V 为所有节点的集合, $|V| = N$ 表示交通网络中包含的节点数为 N ; E 为连接这些节点的边的集合; $A \in \mathbf{R}^{N \times N}$ 为交通网络节点的邻接矩阵,通常为基于距离加权的邻接矩阵。 $X_t \in \mathbf{R}^{N \times F}$, 表示 t 时刻 N 个节点的输入属性特征矩阵,其中 F 是每个节点的特征数量。因此,交通速度预测问题可以描述为:在给定交通网络 G 和特征矩阵 X 的前提下,找到一个合适的映射函数 f , 以便预测未来时刻的交通速度。这个映射关系可以通过公式 1 表示:

$$Y = f[X, G] \quad (1)$$

1.2 空间图神经网络

交通预测任务面临的主要挑战之一是如何准确获取交通网络中复杂的空间依赖关系。为了应对这一挑战,该文采用一种具有位置注意力机制的空间图神经网络层。具体来说,首先应用位置编码来获取整个输入序列中各个节点的相对位置,位置编码 e_t 可以定义为:

$$e_t = \begin{cases} \sin(t/10000^{2i/d_{\text{model}}}), & \text{if } t = 0, 2, 4, 6, \dots \\ \cos(t/10000^{2i/d_{\text{model}}}), & \text{otherwise} \end{cases} \quad (2)$$

接下来对加上位置信息后的输入 $H'_i[i, :] = H_i[i, :] + e_t$ 做线性映射得到 Q, K, V 。

$$Q^v = H^v W^Q$$

$$K^v = H^v W^K$$

$$V^{v_i} = H^i v_i W^V \quad (3)$$

其中, $W^Q \in R^{d \times d_i}$, $W^K \in R^{d \times d_i}$, $W^V \in R^{d \times d_i}$ 。

然后对 Q, K, V 做自注意力机制操作, 得到每个节点的注意力分数 e_{ij} 如式 4 所示。

$$e_{ij} = \text{softmax}\left(\frac{Q^v K^{v_j T}}{\sqrt{d_k}}\right) V^{v_i} \quad (4)$$

最后将得到的注意力系数 e_{ij} 转化为新的含有更多图信息的关系矩阵 $R[i, j]$ 。

$$R[i, j] = \frac{\exp(e_{ij})}{\sum_{k=1}^N \exp(e_{ik})} \quad (5)$$

此时得到的关系矩阵含有丰富的全局信息, 但是它考虑了图中任意两个节点之间的关系, 损失了图结构信息, 同时为了进一步降低计算复杂度, 使用掩码操作来稀疏关系矩阵 $R[i, j]$, 如式 6 所示。

$$\text{mask}(R) = \begin{cases} R_{ij}, & \text{if } \tilde{A}_{ij} > 0 \\ 0, & \text{otherwise} \end{cases} \quad (6)$$

式中, \tilde{A}_{ij} 为原始附加自连接的邻接矩阵中的元素。

将经过掩码操作的关系矩阵应用到切比雪夫多项式一阶近似的 GCN 上:

$$x_{\text{out}} = \sigma(\tilde{D}_R^{-\frac{1}{2}} \tilde{R} \tilde{D}_R^{-\frac{1}{2}} x_{\text{in}} W^l) \quad (7)$$

式中, $R = \text{mask}(R) + I_N$, I_N 为单位矩阵。 \tilde{D}_R 为关系矩阵 \tilde{R} 的度矩阵, σ 为网络所用的激活函数, W^l 是第 l 层所要学习的参数。

上述自注意力机制在计算注意力分数时, 考虑了更多的道路信息, 包括车道数、道路信号和标志、人口密度以及其他可能影响道路交通流量的紧急事件, 而不仅仅是依赖速度信息。更全面地捕捉了交通网络中的空间依赖关系, 提高交通预测模型的准确性。

1.3 门控因果卷积网络

交通数据是一种典型的时间序列数据, 如何提取丰富的时间相关性是交通速度预测任务面临地另一个重要性挑战。该文采用一种门控因果卷积网络来捕获交通数据中的时间相关性特征, 如图 1 所示。




图 1 门控因果卷积模型

该模型主要由因果卷积层和门控单元两部分组成, 可以定义为:

$$\Gamma * \tau X = P \Theta \sigma(Q) \in R^{(M-K_i+1) \times C_o} \quad (8)$$

式中, Γ 为卷积核, K_i 为卷积核的大小; $X \in R^{M \times C_i}$ 为输入的时间序列; P, Q 分别表示门控单元的输入; Θ 表示逐元素的哈达玛积; σ 是一个 sigmoid 函数, 用于过滤无用信息, 保留有用信息。 $1 * 1$ 表示全连接层, 用来调整输入的通道数, 以使其与指定的输出通道数相匹配。此外, 残差连接被用在堆叠的时间因果卷积层中以确保时间卷积的稳定性, 提高模型的泛化能力和准确性。

因果卷积层使用一维因果卷积 (1-D causal convolution) 来捕捉交通数据在时间方面的变化趋势, 以及聚合相邻节点的时间信息, 有助于增强相邻时间特征的影响, 并且充分捕捉时间维度的非线性关系。一维因果卷积操作如图 2 所示。




图 2 一维因果卷积

经过门控卷积捕捉到时间特征后, 将时间特征通过 ReLU 激活函数, 之后再通过一个全连接输出层, 通过线性变化得到最终的输出结果, 如式 9 所示。

$$\text{Output} = \text{Linear}(\text{ReLU}(h_{\text{out}})) \quad (9)$$

1.4 文中模型结构

STA-GNN 网络模型如图 3 所示。框架由两个串行的时空块 (ST blocks) 和一个全连接输出层组成。每个时空块包含两个时序门控卷积 (Temporal Gated-conv) 和一个由自注意力机制和图卷积网络组成位置注意力的空间图神经网络 (S-GNN)。自注意力机制用来提取全局信息, 图卷积网络中的邻接矩阵由得到的相关系数矩阵重新构建, 这样就能够考虑到更多道路信息。空间图神经网络层桥接两个时间层, 实现从时间卷积到图卷积的快速空间状态传播, 充分融合来自空间域和时间域的特征。此外, 在每个时空块内应用残差连接和归一化操作。最后, 将捕捉到的时空特征经过全连接输出层得到最终的预测结果。

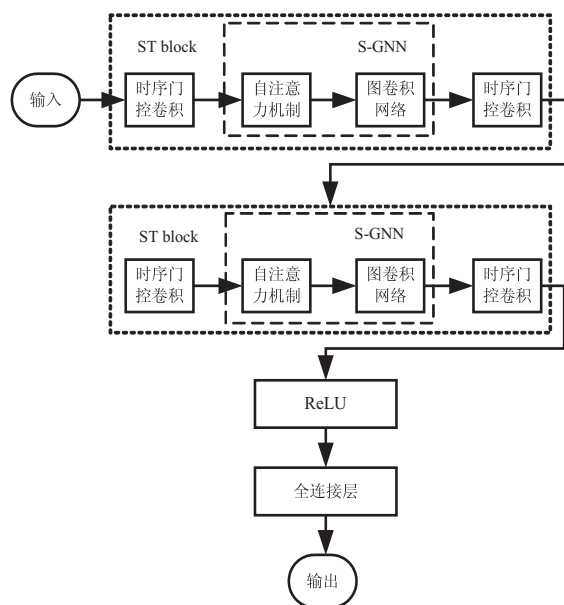


图 3 STA-GNN 模型框架

1.5 损失函数

在训练过程中,训练的目的在于降低道路上实际交通速度与预测值之间的误差。STA-GNN 的损失函数如式 10 所示。

$$\text{loss} = \|Y_t - \hat{Y}_t\| + \lambda L_{\text{reg}} \quad (10)$$

式中: Y_t 是实际的交通速度; \hat{Y}_t 是预测值。第一项用于最小化实际交通速度与预测值之间的误差。第二项 L_{reg} 是 L_2 正则化项,用于避免过拟合问题, λ 是超参数。

2 实验结果及分析

2.1 数据集及预处理

选取现实世界的 PeMSD7 数据集来评估 STA-GNN 模型的预测性能。PeMSD7 数据集简要描述如下:

该数据集是由美国加州交通运输部提供的公开交通数据集,用于交通流量分析和预测。数据集中采集数据的传感器数量超过 390 000 个,涵盖了加州多个地区的高速公路系统,详细记录了加州第七区自 2012 年 5 月 1 日至 6 月 30 日期间的车辆速度。数据集将 30 s 的数据样本每 5 min 聚合一次。该数据集含有 2 个数据矩阵,一个是特征矩阵 X , 另外一个大小为 $228 * 228$ 的邻接矩阵 A , 它表示交通图上 228 条道路之间的连接情况。

为了避免某些特征对模型的影响过大,采用 Z-Score 标准化方法对原始数据进行标准化,如式 11 所示。

$$z = \frac{x - \mu}{\sigma} \quad (11)$$

式中: z 是标准化后的值; x 是原始数据; μ 是原始数据的均值; σ 是原始数据的标准差。该文将数据集进行划分,70% 用作训练数据,15% 用作测试数据,15% 用作验证数据。

2.2 实验环境及参数设置

实验运行环境为 Ubuntu 22.04.3 操作系统, GPU 型号为: NVIDIA GeForce GTX 1080TI (11G 显存), 基于 Pytorch 3.7 深度学习框架。所有测试都使用 60 min 作为历史时间窗口,也就是用 12 个历史观测数据来预测下一个 15 min, 30 min 和 45 min 的交通状况。输入批量大小设置为 35。空间图神经网络中的隐藏单元数量为 16,注意力头个数设置为 4。时序因果卷积中的隐藏单元数量为 64,卷积核大小设置为 3。选择 Adam 优化算法作为优化器,初始学习率 $\gamma = 0.001$, 正则化超参数 $\lambda = 0.0005$ 。最大训练轮次为 1 000。此外,使用提前停止训练的方法来调整学习率、权重衰减和训练周期。

2.3 评价指标

为了评估不同方法的预测性能,实验中使用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)作为评价指标。

平均绝对误差是预测值与实际值之间误差的平均绝对值,该值越小,表示模型的预测性能越好,计算公式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

平均绝对百分比误差用于评估预测值与实际值之间的平均绝对百分比误差。该值越低,表示预测模型的准确性越高。计算公式如下:


$$\text{MAPE} = \frac{1}{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (13)$$

均方根误差是均方误差的平方根,该值越小,表示模型的预测性能越好,计算公式如下:

$$\text{RMSE} = \left[\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \right]^{\frac{1}{2}} \quad (14)$$

2.4 对比分析


为了直观地看出 STA-GNN 模型的预测效果,在 PeMSD7 数据集上随机选择一条道路,并将提前 15 min, 30 min 和 45 min 的预测结果进行可视化,如图 4~6 所示,图中(a)表示工作日的交通速度预测结果,(b)表示单日的交通速度预测结果。从图中可以看出,短时间(5~30 min)的交通速度预测轨迹与实际交通速度轨迹基本吻合,中期(45 min)的预测结果较短期效果较差。



(a) 预测范围为 15 min 工作日的交通速度

(b) 预测范围为 15 min 单日的交通速度


图 4 预测范围为 15 min 的可视化结果



(a) 预测范围为 30 min 工作日的交通速度

(b) 预测范围为 30 min 单日的交通速度

图 5 预测范围为 30 min 的可视化结果



(a) 预测范围为 45 min 工作日的交通速度

(b) 预测范围为 45 min 单日的交通速度

图 6 预测范围为 45 min 的可视化结果

为了进一步验证 STA-GNN 模型的预测性能,选择与以下 6 种基线模型进行比较:

(1)HA:历史平均模型^[18]。该模型假设未来的值与过去的值相似,将过去一段时间内的观测值的平均值作为未来的预测值。

(2)ARIMA:自回归差移动平均模型^[19]。该模型在观测到的时间序列上拟合参数模型来预测未来时刻的交通速度。

(3)SVR:支持向量回归模型^[20]。通过使用线性支持向量机来获取输入与输出之间的关系,然后应用得到关系式来预测未来的交通数据。

(4)STGCN:时空图卷积网络模型。该模型结合了图卷积和门控因果卷积,使用完全卷积结构来提取交通数据中的时空信息。

(5)GRU-GCN-Drop:该模型在结合 GCN 和 GRU 的基础上,又通过加入对比学习中的 R-Drop 方法来捕捉交通网络中的时空相关性。

(6)RSATCN:RSATCN 模型利用遮罩矩阵和图

卷积网络相结合的方法来捕捉空间特征,在提取时间序列的动态相关性方面采用带有时间注意力机制的时序卷积网络。

表 1 记录了 STA-GNN 模型和其他 5 个基准模型在 PeMSD7 数据集上 15 min、30 min 和 45 min 预测任务的性能。从表中可以看出,所提出的模型在这 3 个评价指标下都是最佳表现。

(1)预测性能的比较:STA-GNN 模型与所选的基准模型相比,预测性能最好。从表 1 实验数据中可以看出,在 15 min、30 min 和 45 min 的交通速度预测任务中,STA-GNN 模型展现出最小的均方根误差和平均绝对误差。例如,在 PeMSD7 数据集的 15 min 交通速度预测任务中,STA-GNN 模型的均方根误差值分别比 HA 模型和 SVR 模型低了约 44.8% 和 47.2%。此外,在 30 min 交通速度预测任务中,STA-GNN 模型的均方根误差值分别比 GRU-GCN-RDrop 模型和 RSATCN 模型低了约 2.6% 和 15.4%。误差越小,预测精度越高。图 7 展示了各个模型在不同预

测范围的均方根误差值。从图中可知,无论预测范围如何,STA-GNN 模型的预测性能优于其他 6 个基准模型。

(2)传统模型比较分析:STA-GNN、GRU-GCN-RDrop 以及 RSATCN 作为基于深度学习方法的预测模型在交通速度预测任务中要比 HA、ARIMA 等时间序列模型和传统机器学习模型 SVR 预测性能更好,均方根误差更低。例如:在 PeMSD7 数据集的 30 min 交通速度预测任务中,GRU-GCN-RDrop 模型的均方根

误差比 HA 模型降低了约 26.5%,比 ARIMA 模型降低了约 48.5%,比 SVR 模型降低了约 31.7%;STA-GNN 模型的均方根误差比 HA 模型降低了约 28.4%,比 ARIMA 模型降低了约 49.8%,比 SVR 模型降低了约 38.9%。这主要是因为 HA、ARIMA 和 SVR 等方法难以有效处理复杂的非平稳时间序列数据,而交通速度数据具有非线性、非平稳的特征。因此,这些传统方法的预测效果要低于深度学习方法的预测模型。

表 1 STA-GNN 模型及其他基准模型在 PeMSD7 数据集上的预测结果

时间/min	评价指标	HA	ARIMA	SVR	GRU-GCN-RDrop	RSATCN	STA-GNN
15	MAE	4.288 0	5.622 7	3.886 1	2.961 5	3.081 5	2.399 6
	MAPE/%	11.555 9	14.138 2	13.080 0	9.103 7	9.834 4	4.132 0
	RMSE	7.689 7	9.875 0	8.042 9	4.480 3	5.322 9	4.243 7
30	MAE	4.288 0	6.031 7	4.112 7	3.174 2	3.253 0	3.071 2
	MAPE/%	11.555 9	15.365 8	13.548 0	10.517 3	10.927 5	5.288 4
	RMSE	7.689 7	10.977 0	8.272 5	5.651 9	6.507 3	5.507 6
45	MAE	4.288 0	6.532 5	4.306 2	3.801 4	3.977 9	3.535 6
	MAPE/%	11.555 9	16.976 5	13.965 3	11.190 8	12.012 2	6.088 0
	RMSE	7.689 7	12.276 0	8.502 9	6.230 9	7.251 8	5.921 6




图 7 各个模型在 PeMSD7 数据集上的 RMSE

(3)中长期预测任务的评估:STA-GNN 模型在中长期的交通速度预测任务中预测性能要优于其他基准模型。由表 1 中的实验数据可知,在 45 min 的交通速度预测任务中,STA-GNN 模型的均方根误差和平均绝对误差是最小的。例如:STA-GNN 模型的均方根误差分别比 GRU-GCN-RDrop 模型以及 RSATCN 低了约 5% 和 18.3%;平均绝对误差分别比 GRU-GCN-RDrop 模型以及 RSATCN 低了约 7% 和 11.1%。

2.5 消融实验

对 STGCN 模型和采用位置注意力机制的 STA-GNN 模型进行实验,实验结果如表 2 所示。

从表 2 中可以看到,在 PeMSD7 数据集的 15 min 和 30 min 预测任务中,两种模型误差相差不大,STA-GNN 模型的均方根误差相比 STGCN 模型降低了不超

表 2 STA-GNN 模型的消融实验在 PeMSD7 数据集上的预测结果

时间/min	评价指标	STGCN	STA-GNN
15	MAE	2.499 2	2.399 6
	MAPE/%	4.303 5	4.132 0
	RMSE	4.302 5	4.243 7
30	MAE	3.122 8	3.071 2
	MAPE/%	5.377 2	5.288 4
	RMSE	5.565 5	5.507 6
45	MAE	3.725 5	3.535 6
	MAPE/%	6.415 1	6.088 0
	RMSE	6.591 2	5.921 6

过 1.5%。然而,当预测范围延长至 45 分钟时,STA-

GNN 模型的均方根误差相较于 STGCN 模型降低了约 10.2%。这表明 STA-GNN 模型在长期交通速度预测方面比 STGCN 模型表现更出色。这是因为在提取交通数据中的空间相关性方面,STA-GNN 采用一种具有位置注意力机制的空间图神经网络,通过提取全局信息,考虑了更多的道路信息,而不仅仅是依赖速度信息。在时间维度上,二者都是使用普通的一维 CNN 处理,并通过时序门控卷积方法捕获交通信息中的时间相关性。

3 结束语

道路上的交通速度受到多种因素的影响,具有强烈的时变性、随机性、非线性和时空相关性。针对这些问题,基于 STGCN 深度学习模型,该文提出了一种改进模型 STA-GNN。该模型通过使用具有位置注意力机制的图神经网络和带有门控的一维卷积神经网络来捕捉交通速度中的时空相关性。通过与 6 种基准模型进行对比实验表明,STA-GNN 预测模型在 RMSE、MAE、WPAE 三个指标上均表现为最佳。同时通过消融实验表明改进的模型比原模型长期预测能力更强。该预测模型为交通管理部门提供了科学依据,有助于有效管理城市交通。未来将进一步优化网络结构和参数设置,并尝试将所提出的框架应用于其他时空结构化序列预测场景,如社交网络、偏好预测等。

参考文献:

- [1] ZHU L, YU F R, WANG Y, et al. Big data analytics in intelligent transportation systems: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(1): 383-398.
- [2] BI J, ZHANG X, YUAN H, et al. A hybrid prediction method for realistic network traffic with temporal convolutional network and LSTM[J]. IEEE Transactions on Automation Science and Engineering, 2021, 19(3): 1869-1879.
- [3] 高洪波, 张登银. 基于分形与三次指数平滑的交通流量预测模型[J]. 南京邮电大学学报: 自然科学版, 2018, 38(6): 63-67.
- [4] TANG L, ZHAO Y, CABRERA J, et al. Forecasting short-term passenger flow: an empirical study on shenzhen metro[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(10): 3613-3622.
- [5] LIU L. A short-term traffic flow prediction method based on SVR[C]//2021 2nd international conference on urban engineering and management science (ICUEMS). Sanya: IEEE, 2021: 1-4.
- [6] 孙云飞. 城市道路短时交通流预测方法研究与应用[D]. 成都: 电子科技大学, 2021.
- [7] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. arXiv: 1609. 02907, 2016.
- [8] 赵嘉雨, 段亚茹, 何立明. 基于 GRU-GCN-RDrop 模型的交通速度预测[J]. 计算机技术与发展, 2023, 33(4): 120-125.
- [9] 陈华伟, 邵毅明, 敖谷昌, 等. 面向在线地图的 GCN-LSTM 神经网络速度预测[J]. 交通运输工程学报, 2021, 21(4): 183-196.
- [10] 冯思芸, 施振佳, 曹阳. 基于全局时空特性的城市路网交通速度预测模型[J]. 计算机工程, 2022, 48(5): 112-117.
- [11] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv: 1803. 01271, 2018.
- [12] 张安勤, 胡梓明. 基于残差时序图卷积网络的交通速度预测[J]. 计算机仿真, 2023, 40(11): 116-121.
- [13] 黄伟坚, 李春贵. 基于时空注意力图卷积神经网络的交通速度预测[J]. 广西科技大学学报, 2022, 33(1): 54-62.
- [14] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]//Proceedings of the 27th international joint conference on artificial intelligence (IJCAI '18). Stockholm: AAAI Press, 2018: 3634-3640.
- [15] SUN H X. Traffic flow prediction model based on attention spatiotemporal graph convolutional network[C]//2023 3rd international symposium on computer technology and information science (ISCTIS). Chengdu: IEEE, 2023: 148-153.
- [16] ZHANG J, SHI X, XIE J, et al. Gaan: gated attention networks for learning on large and spatiotemporal graphs[J]. arXiv: 1803. 07294, 2018.
- [17] WANG X, MA Y, WANG Y, et al. Traffic flow prediction via spatial temporal graph neural network[C]//Proceedings of the web conference 2020. Taipei, China: Association for Computing Machinery, 2020: 1082-1092.
- [18] LIU J, GUAN W. A summary of traffic flow forecasting methods[J]. Journal of Highway and Transportation Research and Development, 2004, 21(3): 82-85.
- [19] WILLIAMS B M, HOEL L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: theoretical basis and empirical results[J]. Journal of Transportation Engineering, 2003, 129(6): 664-672.
- [20] SMOLA A J, SCHÖLKOPF B. A tutorial on support vector regression[J]. Statistics and Computing, 2004, 14: 199-222.