

基于动态时空神经网络的城市交通流量预测方法

孟祥福, 许睿航

引用本文

孟祥福, 许睿航. 基于动态时空神经网络的城市交通流量预测方法[J]. 计算机科学, 2023, 50(6A): 220600266-7.

MENG Xiangfu, XU Ruihang. City Traffic Flow Prediction Method Based on Dynamic Spatio-Temporal Neural Network [J]. Computer Science, 2023, 50(6A): 220600266-7.

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)

[面向交通流量预测的时空Graph-CoordAttention网络](#)

Spatial-Temporal Graph-CoordAttention Network for Traffic Forecasting

计算机科学, 2023, 50(6A): 220200042-7. <https://doi.org/10.11896/jsjcx.220200042>

[基于多模态特征融合的时间序列异常检测](#)

Anomaly Detection of Time-series Based on Multi-modal Feature Fusion

计算机科学, 2023, 50(6A): 220700094-7. <https://doi.org/10.11896/jsjcx.220700094>

[联合人体姿态估计和多目标跟踪的跨数据集学习](#)

Cross-dataset Learning Combining Multi-object Tracking and Human Pose Estimation

计算机科学, 2023, 50(6A): 220400199-7. <https://doi.org/10.11896/jsjcx.220400199>

[基于改进Yolov4-tiny的轻量级目标检测算法](#)

Lightweight Target Detection Algorithm Based on Improved Yolov4-tiny

计算机科学, 2023, 50(6A): 220700006-7. <https://doi.org/10.11896/jsjcx.220700006>

[注意力特征融合的孪生网络目标跟踪方法](#)

Attentional Feature Fusion Approach for Siamese Network Based Object Tracking

计算机科学, 2023, 50(6A): 220300237-9. <https://doi.org/10.11896/jsjcx.220300237>

基于动态时空神经网络的城市交通流量预测方法

孟祥福 许睿航

辽宁工程技术大学电子与信息工程学院 辽宁 葫芦岛 125105

摘要 交通流量预测对城市道路规划、交通安全问题和建设智慧城市等具有重要意义。然而,现有大部分交通预测模型无法很好地捕捉交通数据的动态时空相关性。针对该问题,提出了一种基于动态时空神经网络的城市交通流量预测方法。首先,通过对交通数据的最近周期依赖、日周期依赖和周周期依赖进行建模,在每个分量上使用三维卷积神经网络提取城市交通高维特征;然后,使用改进的残差结构捕捉远距离区域对与预测区域的相关度,融合空间注意力和时间注意力机制捕捉不同区域不同时间段上的交通流量之间的动态相关性;最后,使用基于参数矩阵的方法对3个分量的输出进行加权融合,得到预测结果。在TaxiBJ和BikeNYC两个公开数据集上开展实验,结果表明所提模型的预测性能优于主流交通预测模型。

关键词: 时空相关性;交通预测;交通流动性;注意力机制;融合机制

中图分类号 TP183

City Traffic Flow Prediction Method Based on Dynamic Spatio-Temporal Neural Network

MENG Xiangfu and XU Ruihang

School of Electronic and Information Engineering, Liaoning Technical University, Huludao, Liaoning 125105, China

Abstract Traffic flow forecasting is of great importance to urban road planning, traffic safety issues and building smart cities. However, most existing traffic prediction models cannot capture the dynamic spatio-temporal correlation of traffic data well enough to obtain satisfactory prediction results. To address this problem, a dynamic spatio-temporal neural network-based city traffic flow prediction method is proposed to solve the traffic flow prediction problem. First, by modelling the nearest cycle dependence, daily cycle dependence and weekly cycle dependence of the traffic data, a 3D convolutional neural network is used on each component to extract the high-dimensional features of urban traffic. Then, an improved residual structure is used to capture the correlation between remote area pairs and the prediction area, and a fusion of spatial attention and temporal attention mechanisms is used to capture the dynamic correlation between traffic flows in different time periods in different areas. Finally, the outputs of the three components are weighted and fused using a parameter matrix-based approach to obtain the prediction results. Experiments on two publicly available datasets, TaxiBJ and BikeNYC, show that the proposed model outperforms the mainstream traffic forecasting models.

Keywords Temporal correlation, Traffic forecast, Traffic fluidity, Attention mechanism, Fusion mechanism

1 引言

近年来,发展智能交通系统已经成为智慧城市建设不可或缺的一部分。其中,交通流量预测尤为重要,它可以帮助管理部门更好地规划交通路线,同时减少堵车和交通事故的发生。因此,如果能提前准确预测城市交通流量,就可以合理地规划路网,提高城市路网的运行效率。

交通数据记录某一时间段内人们在城市中的行驶轨迹。交通流量预测是根据过去一段时间内的交通数据预测未来一段时间内的交通流量。早期研究人员尝试使用时间序列分析模型来解决交通流量预测问题,但在实际应用中,这类方法很难建模非线性数据,而交通数据往往是非线性变化的,不同区域的车流量在不同时间段的变化是动态的。后来,基于机器学习的模型被提出用于对较为复杂的非线性数据建模,但

难以提取高维度交通数据的时空相关性。近年来,研究人员基于深度学习的方法对高维度的交通时序数据建模,提取交通数据的空间特征。但交通流量预测仍面临以下挑战:

(1)交通数据是一种典型的时空数据,不同区域在不同时间段内的交通流量数据具有流动性以及动态变化的特点。因此,从多维度提取交通数据的高层特征,对时空数据的流动性建模是预测的关键。

(2)观测的区域与时间段不是相互独立的,而是动态相关的。在空间维度上,不同区域的交通数据对预测区域的影响是不同的,甚至同一区域不同时间段内的交通数据对于其本身的影响程度也是不同的。在时间维度上,不同时间段的历史观测数据对预测区域具有不同程度的影响。因此,有效提取交通流量数据的动态相关性对于准确预测交通流量是一个挑战。

基金项目:国家自然科学基金(61772249);辽宁省教育厅项目(LJKZ0355)

This work was supported by the National Natural Science Foundation of China(61772249) and Research Project of Liaoning Education Department(LJKZ0355).

通信作者:孟祥福(marxi@126.com)

(3)交通数据在周期上具有相似性。例如,某一区域在星期一和星期二的早高峰内具有相似的交通流量;某一区域第一周的星期一和第二周的星期一早高峰内的流量同样具有相似性。因此,需要对交通数据的周期性进行建模。

基于上述问题,本文提出了一种融合注意力机制的动态时空神经网络交通流量预测模型 AST-3DGN (Attention based Spatio-Temporal 3D Convolution Global Network),采用三维卷积和融合注意力机制的残差模块对交通流量数据进行建模,从而预测城市未来的流量变化。

本文的主要工作有以下4个方面:

(1)提出了融合注意力机制的动态相关性预测模型。从全局的角度出发,考虑了远距离区域对预测区域的相关度。使用空间注意力动态捕捉区域之间的空间相关性,使用时间注意力来动态捕捉不同时间段之间的时间相关性。

(2)在局部动态预测模块中使用三维卷积,从多维度上提取交通数据的高层时空特征,获取城市交通的流动规律。

(3)将历史数据依据最近周期依赖、日周期依赖、周周期依赖进行建模,捕获不同的历史时间周期对未来交通流量的影响。进而,通过学习参数对最近周期依赖、日周期依赖和周周期依赖的预测结果进行融合,提高预测结果的准确度。

(4)使用两个真实的公开数据集进行了大量实验,实验结果表明本文模型的预测效果优于对比模型。

2 相关工作

近年来统计学方法、机器学习方法和深度学习方法在交通预测上均取得了突破性进展^[1]。使用传统统计学方法的交通预测模型有 HA, ARIMA^[2], VAR^[3]等。这些方法需要数据满足某些特定的假设,在实际应用中,这些统计学方法通常由于交通数据的复杂性而表现不佳。为了解决模型不能适应非线性数据问题, Yang 等^[4]提出了一种融合统计学方法和反向传播神经网络的模型,通过模拟退火算法优化 ARIMA 模型,充分挖掘了统计学方法处理非线性数据的能力。KNN^[5]和 SVM^[6]等机器学习方法可以对更复杂的数据进行建模,但它们需要仔细选取数据特征进行预测,且无法考虑交通数据的时空相关性。

由于深度学习在医学影像处理^[7]、兴趣点推荐^[8]等任务上取得了突破性进展,越来越多的研究人员开始基于深度学习对数据建模进行交通预测。Zhang 等^[9]提出了一种基于残差卷积的 ST-ResNet 模型来对城市人流量进行预测,通过对残差模块的改进,可以利用更深层的神经网络来捕捉交通数据的时空特性。Yao 等^[10]通过融合卷积神经网络与长短时记忆网络的模型提取交通数据的时间特征。Dai 等^[11]设计了基于简化残差结构的深度神经网络预测交通流量,通过改进深层残差结构减少了训练时间。

传统的深度学习模型由于对时间关联因素过于依赖而忽略了复杂的空间关联因素。Zhang 等^[12]针对这一问题提出了考虑空间关联特性的深度学习模型,通过道路之间的距离、车速和车流量构建了空间相关性函数,同时使用长短时记忆网络捕捉数据的时间相关性,对短时交通流量进行了有效预测。Li 等^[13]设计了一种多任务循环神经网络,通过将预测目标相关路段的流量作为额外任务实现协同预测,克服了传统预测方法对单点区域交通信息的依赖,使预测范围扩展至

其他区域网络。Abduljabbar 等^[14]采用长短时记忆递归神经网络进行预测,并考虑了传感器数据的实时性,并将预测范围扩大进行实验,在澳洲高速公路数据集上取得了优异的性能表现。

由于历史数据具有噪声,导致交通预测结果不理想, Zhang 等^[15]针对此问题设计了一种去噪声的深度神经网络预测模型,使用 EMD 算法将时序数据进行去噪声处理,然后使用 LSTM 提取时间特征,进而对路网交通进行预测。Tsai 等^[16]考虑了城市交通的多特征性,提出了基于多元长短时深度学习模型 LS-LSTM,通过融合特征矩阵和长短期历史矩阵,解决了在交通条件波动的情况下,历史交通数据的相关性减小的问题。这些模型虽然能够通过深度神经网络提取数据的高层特征,但是缺乏对交通流量的周期性或动态相关性的建模。

注意力机制近年来被广泛用于文本情感分析^[17]、医学影像识别^[18]等领域。注意力机制的目标是从输入中选择对任务相对重要的信息,提升模型性能。Xu 等^[19]在图像识别任务中提取了两种注意力,并使用可视化的方法展示了注意力机制的效果。Velickovic 等^[20]提出了基于自注意力层的神经网络处理来节点分类任务。近几年,注意力机制被越来越多的研究人员应用在交通预测模型中^[21]。Wang 等^[22]考虑了交通数据的周期性,对数据的日和周的周期性进行建模,设计了一种时空注意力网络进行预测,但是没有考虑远距离区域对预测目标的依赖性。Ren 等^[23]通过融合空间注意力机制对残差结构进行改进和对不同距离的区域地理相关度进行建模,捕获了交通数据的空间依赖性,但是仍然没有考虑交通数据的动态时间相关性。

现有预测方法对交通数据的最近周期和日周期依赖进行建模,但没有考虑周周期依赖的重要性,且缺乏对不同区域不同时间段对预测区域的动态时空相关性的建模。本文将针对此问题开展研究,综合考虑不同区域不同时间段对预测区域的动态时空相关性进行交通流预测。

3 相关定义

定义 1(区域) 将城市划分为 $m \times n$ 个网格,其中 $m \in M, n \in N, M$ 表示网格的行数, N 表示网格的列数,所有区域的集合可表示为:

$$R = \{r_{1,1}, \dots, r_{1,n}, \dots, r_{m,1}, \dots, r_{m,n} \mid m \in M, n \in N\}$$

定义 2(轨迹) 使用三元组 (x, y, τ) 表示记录区域个体的移动数据。对于个体 u , (x, y) 表示其在时刻 τ 的位置, u 的运动轨迹可表示为 $T_u = \{p_1, p_2, \dots, p_k, \dots, p_l\}$,其中 $p_k \in R^{M \times N}$ 表示轨迹 T_u 中的第 k 个轨迹点, l 表示轨迹 T_u 的长度,其在时间间隔 t 内经过的区域表示为 S_t^u 。

定义 3(交通流量) 对于区域 (m, n) , $\{x_t^{m,n}\}$ 表示一条区域流量记录,其中 $t \in \{\tau_i\}$ 为一段固定的时间间隔, c 表示通道数。设连续时间间隔 $\{t-1, t, t+1\}$ 内所有轨迹的数量为 Q ,则对于 t 时刻,区域 (m, n) 的流入量和流出量为:

$$x_t^{\text{in},m,n} = \{T_u \mid T_u \in Q \wedge (m, n) \notin S_{t-1}^u \wedge (m, n) \in S_t^u\} \quad (1)$$

$$x_t^{\text{out},m,n} = \{T_u \mid T_u \in Q \wedge (m, n) \in S_{t-1}^u \wedge (m, n) \notin S_t^u\} \quad (2)$$

定义 4(周期依赖) 城市区域车流在某一时刻的流入和流出可以看作是图片的两个通道,分别从中提取最近周期依赖、日周期依赖和周周期依赖序列。设预测时间段序列长度为 l_p ,则有:

最近周期依赖序列表示为

$$(x_{t-l_h}, x_{t-l_h+2}, \dots, x_{t-1}) \in R^{c \times m \times n \times l_h};$$

日周期依赖序列表示为

$$(x_{t-(l_d/l_p) * q}, x_{t-(l_d/l_p-1) * q}, \dots, x_{t-q}) \in R^{c \times m \times n \times l_d};$$

周周期依赖序列表示为

$$(x_{t-(l_w/l_p) * 7q}, x_{t-(l_w/l_p-1) * 7q}, \dots, x_{t-7q}) \in R^{c \times m \times n \times l_w}.$$

其中, l_h, l_d, l_w 分别为最近周期依赖、日周期依赖、周周期依赖的序列长度, q 为固定的一段时间, c 表示流入或流出通道。

问题定义: 给定交通网络上所有区域的历史测量数据, 预测城市所有区域下一个时间间隔上的交通流量序列 $Y \in R^{c \times m \times n \times l_p}$, 其中 $Y = (y_{\tau+1}, y_{\tau+2}, \dots, y_{\tau+l_p})$ 表示从 $\tau+1$ 开始的交通流量。

4 基于动态时空神经网络的城市交通流量预测模型

本文提出的 AST-3DGN 模型总体框架如图 1 所示。它由 3 个周期组件构成, 分别为最近周期依赖、日周期依赖、周周期依赖的相关性建模, 每个组件包含局部动态预测模块和全局相关性预测模块。其中, 局部动态预测模块使用多层三维卷积来提取交通数据的高层特征, 以捕获时空数据的流动规律; 全局相关性模块通过空间注意力和时间注意力来动态捕捉交通流量数据的空间相关性和时间相关性, 然后通过改进的残差单元获取远距离之间交通流量的影响。最后, 通过基于参数矩阵的融合方法得出最终预测结果。

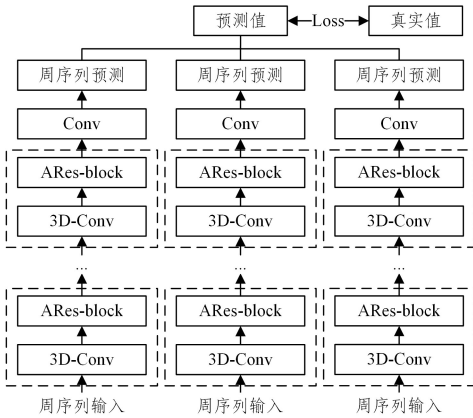


图 1 AST-3DGN 总体框架图

Fig. 1 Overall framework of AST-3DGN

4.1 流输入输出与周期组件

流输入输出: 将城市按照经纬度划分成若干大小完全相同的网格, 每个网格代表一个区域。每隔一段固定时间对各个区域的流入和流出进行统计。根据定义 1 与定义 3, 将城市所有的流入与流出轨迹交通图转化为二通道(In 和 Out)的图像矩阵。

周期组件: 设预测时间段的序列长度为 l_p , 最近周期、日周期和周周期分量的输入序列长度分别为 l_h, l_d 和 l_w 。如图 2 所示, 最近周期序列是与预测周期直接相邻的一段历史时间序列, 最近时间段内的交通流量必然会对要预测的交通流量产生影响。例如某一区域过去一小时内的交通流量产生影响, 日周期序列由过去的几天与预测时间段相同的时间序列组成, 在相同的时间段内交通流具有相似性, 例如某一区域周一至周五早高峰的流量具有相似性。周周期由过去的几周与预测时间段相同的时间序列组成, 在每周相同时间段内交通流

可能具有相似性, 例如某一区域每周周一早高峰的交通流量会呈现明显的相似性。



图 2 周期组件示例图

Fig. 2 Example of periodic component

4.2 局部动态预测模块

局部动态预测模块通过三维卷积神经网络捕捉时空数据的流动性规律, 从时间和空间维度上对近邻区域的动态相关性进行建模。

城市交通预测属于时空数据预测问题。时空数据包含时间和空间两个维度, 相邻的时间间隔和城市区域的交通流量通常具有较强的关联性。传统的二维卷积神经网络不能有效捕捉时间维度上的特征信息, 而三维卷积神经网络可以更有效地提取交通数据的时空特征, 二维卷积与三维卷积的对比如图 3 所示。城市在某一时刻的交通网络可以看作是视频中的一帧, 对于二维卷积, 视频的帧数是卷积的通道数, 在经过二维卷积操作后, 视频的帧数被压缩为一个特征图, 特征图只捕捉到了一个特征维度, 而忽略了时间维度上的信息。对于三维卷积, 其滤波器有 3 个维度, 将滤波器与视频中的连续帧组成的立方体进行卷积操作, 由于一个特征图可以连接到前一层的一个或多个帧, 所以三维卷积可以有效地捕捉时间信息, 因此局部动态预测模块使用三维卷积来捕捉交通数据的时间和空间维度信息。

以最近周期组件为例, 对时空数据的三维建模可以表示为:

$$x_h^{(k)} = f(W_h^{(k)} * x_h^{(k)} + b_h^{(k)}), k=1, \dots, K_h \quad (3)$$

其中, $*$ 代表三维卷积操作, $x_h^{(k)}$ 为三维卷积第 k 层的输入, W 与 b 为三维卷积的学习参数。

4.3 全局相关性预测模块

全局相关性模块通过空间注意力机制和时间注意力机制获取交通数据的空间相关性和时间相关性, 并融合了 ResPlus 单元进一步挖掘远距离区域对预测区域的依赖关系。

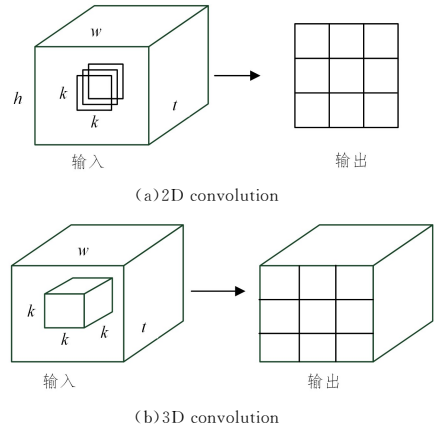


图 3 二维卷积与三维卷积对比图

Fig. 3 Comparison of 2D convolution and 3D convolution

城市区域之间的轨迹可能因为人们乘坐高速交通工具(地铁、高铁等)而变得很长, 因此, 预测区域对于远距离区域的空间依赖性越来越重要。普通卷积网络要通过堆叠许多层

来捕捉这种关系,但是随着参数的增加,整个网络的预测效率会大大降低。针对这个问题, Lin 等^[24]设计了一种新的残差单元 ResPlus 单元来捕捉不同距离区域之间的空间依赖性。图 4 为 ResPlus 单元结构图,包含 ConvPlus 模块和一个卷积层。其中, ConvPlus 模块对交通流量图进行了分离通道的操作,分离后的一个通道进行局部普通卷积操作,另一个通道进行全局卷积操作,全局卷积核大小与网格尺寸大小相同,以此来捕捉预测区域对每一个区域的空间依赖程度。将两个通道进行合并操作,若合并后的输出向量的维度与卷积神经网络相同,则可继续进行下一层的卷积操作。需要指出的是,使用残差结构可使神经网络具有回退能力,避免出现梯度消失或梯度爆炸现象。残差操作可以定义为:

$$x_c^{(l+1)} = x_c^{(l)} + F(x_c^{(l)}; \theta_c^{(l)}), l = 1, \dots, L \quad (4)$$

其中, F 为残差函数, $x_c^{(l)}$ 为第 l 层的输入向量。

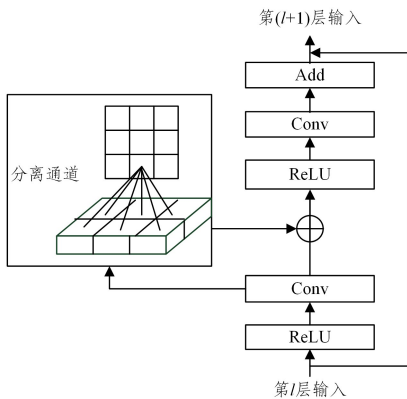


图 4 ResPlus 单元结构图

Fig. 4 ResPlus unit structure diagram

在实际生活中,不同区域相互影响的程度不同,这在很大程度上影响了对区域的交通流量预测,例如,学校和住宅所在的区域在周一至周五具有强联系。不同时间段对预测区域的交通流量影响也不同,例如,放学或下班时间段对学校或公司所在的区域影响较大。ConvPlus 结构捕捉了城市区域之间两两的关系,但是缺乏对不同区域之间交通流量影响强弱的考虑,且没有考虑时间信息对于预测结果的影响。本文使用空间注意力机制获取不同区域之间交通流量的影响程度,使用时间注意力机制获取不同时间段之间交通流量的影响程度。具体如下:

(1)空间注意力机制

不同区域的交通流量在空间维度上相互影响,且这种影响具有动态性。例如,在节假日期间景点区域和住宅区域会保持动态性的联系。所以我们通过使用空间注意力机制来自适应地捕捉空间维度上不同区域之间的动态相关性。以日周期组件为例,空间注意力可以表示为:

$$S'_{x,y} = \frac{\exp(S_{x,y})}{\sum_{y=1} \exp(S_{x,y})} \quad (5)$$

其中, $S_{x,y}$ 表示区域 x 和区域 y 在空间上的相关程度。

(2)时间注意力机制

在时间维度上,不同时间切片上的交通流量之间存在相关性,且在不同情况下其相关性也不同。使用时间注意力机制来动态地挖掘交通数据时间属性的重要性,计算方法为:

$$E'_{a,b} = \frac{\exp(E_{a,b})}{\sum_{b=1} \exp(E_{a,b})} \quad (6)$$

其中, $E_{a,b}$ 表示时间 a 和时间 b 在时间上的相关程度。

受到 Woo 等^[25]在注意力机制研究上的启发,本文提出了一种融合时空注意力机制的 ResPlus 结构,如图 5 所示。

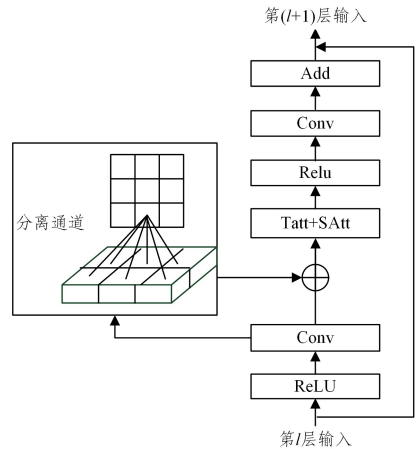


图 5 融合时空注意力的 ResPlus 结构图

Fig. 5 ResPlus structure fused with temporal and spatial attention

其中, SAtt 表示空间注意力, TAtt 表示时间注意力, ReLU 表示激活函数, Conv 表示卷积层。该方法在获取区域之间距离依赖关系的同时,动态捕捉区域之间的空间相关性和时间相关性。

4.4 融合预测模块

融合预测模块将使用基于参数矩阵的融合方法集成 3 个组件的输出。在融合输出时,每个组件的影响权值是不同的。例如,部分区域在早高峰期间交通流量有明显的高峰时段,因此日周期组件和周周期组件的输出更为关键。然而,一些区域的交通流量没有明显的周期性,所以日周期和周周期对结果的影响极小。因此,在融合 3 个组件的输出时,需要考虑不同组件的影响权值。融合预测模块的最终预测结果可以表示为:

$$Y = W_h \times Y_h + W_d \times Y_d + W_w \times Y_w \quad (7)$$

其中, \times 为哈达玛积, W_h , W_d 和 W_w 为权重参数,反映了 3 个组件对预测目标的影响程度。

4.5 损失函数

AST-3DGN 模型的整体损失值为预测交通流量值与真实交通流量值之间的均方误差,并通过反向传播使其最小化,损失函数表示为:

$$L_\theta = \| y_t - Y_t \|^2_\theta \quad (8)$$

其中, y_t 为真实交通流量值, Y_t 为预测交通流量值, θ 为学习参数。

5 实验

5.1 数据集

实验采用 TaxiBJ 和 BikeNYC 两个公开数据集进行模型性能的验证,表 1 列出了两个数据集的统计信息。

TaxiBJ:北京出租车数据集,通过 GPS 信息收集的 2013 年 7 月 1 日至 2016 年 4 月 10 日北京市内所有出租车在连续时间段内生成的轨迹集。数据集使用 (32, 32) 表示北京市交通图网格化后的尺寸,流输入的通道数为 2,分别为 In(流入)和 Out(流出);取最后 10 天为测试集,其余为训练集。

BikeNYC:纽约市共享单车数据集,收集了从 2014 年

4月1日到9月30日纽约市所有共享单车产生的轨迹集,包括行程时间段、起止站和起止时间。该数据集使用(16,8)表示纽约市交通图网格化后的尺寸,流输入的通道数为2,分别为In(流入)和Out(流出);取最后10天为测试集,其余为训练集。

表1 TaxiBJ和BikeNYC数据集的统计信息

Table 1 Information of datasets TaxiBJ and BikeNYC

数据集	TaxiBJ	BikeNYC
时间间隔/min	30	60
网格尺寸	(32,32)	(16,8)
车辆统计数目	34000+	6800+
时间间隔数	22459	4392

5.2 实验设置

采用TensorFlow框架实现了AST-3DGN模型的搭建。考虑到计算效率和预测效果,设置最近周期依赖序列长度为6,日周期依赖序列长度为4,周周期依赖序列长度为6,即 $l_h=6, l_d=4, l_w=6$;设置预测交通流量序列长度为4,即 $l_p=4$ 。三维卷积核大小设置为(3,3,3),改进的ResPlus单元中卷积核大小设置为(3,3),卷积核数量为64。时间注意力与空间注意力的卷积核大小设置均为(3,3)。学习率设置为 2×10^{-5} ,批处理(batch_size)大小设置为32。

为了验证空间注意力与时间注意力对于模型性能的提升,本文还搭建了一个简化版的模型AST-3DGN-m,该模型不使用空间注意力与时间注意力,其他设置与AST-3DGN相同。

本文使用均方根误差RMSE和平均绝对误差MAE作为评价指标来验证预测模型的效果。两个评估指标的计算方法如下:

$$RMSE = \sqrt{\frac{1}{z} \sum_i (y_i - Y_i)^2} \quad (9)$$

$$MAE = \frac{1}{z} \sum_i |y_i - Y_i| \quad (10)$$

其中, Y_i 为预测值, y_i 为真实值。

5.3 对比模型

本文将AST-3DGN模型与以下7种基线方法进行比较:

(1)HA:历史均值法,利用平均值进行预测。

(2)ARIMA^[2]:差分自回归移动平均模型,通过对时间序列的分析进行预测。

(3)LSTM^[26]:长短时记忆网络,通过输入门、输出门和遗忘门来处理较长的序列信号数据。

(4)ST-ResNet^[9]:一种融合残差结构的时空神经网络模型,能够捕捉交通数据的时空特性,同时改善深层神经网络梯度消失或梯度爆炸的问题。

(5)ST-MetaNet^[27]:一种基于编码器学习历史数据的时空神经网络模型。该模型将历史数据送入编码器进行学习,然后使用解码器解析数据进行预测,可以有效地提取交通数据的时空相关性。

(6)ST-3DGN^[23]:一种动态时空神经网络模型。该模型使用三维卷积捕获交通数据的流动性,并通过早期融合机制提高模型的预测性能。

(7)AST-3DGN-m:AST-3DGN的简化模型。为了验证时空注意力对模型的提升,设置了没有融合时空注意力机制的模型。

5.4 实验结果与分析

将本文的模型与TaxiBJ和BikeNYC数据集上的7种基线方法进行比较。表2列出了不同模型的交通预测性能。

表2 不同方法在TaxiBJ和BikeNYC数据集上的性能比较

Table 2 Performance comparison of different methods on TaxiBJ and BikeNYC datasets

Model	TaxiBJ		BikeNYC	
	RMSE	MAE	RMSE	MAE
HA	46.41	23.70	10.73	5.84
ARIMA	22.80	16.31	9.98	6.02
LSTM	20.77	11.96	9.66	5.94
ST-ResNet	17.21	10.06	6.73	3.92
ST-MetaNet	16.88	9.83	6.26	3.66
ST-3DGN	15.42	9.25	5.54	3.32
AST-3DGN-m	15.36	9.21	5.50	3.30
AST-3DGN	15.01	9.02	5.32	3.26

通过对比发现,传统时间序列分析方法(HA和ARIMA)的预测结果相对不理想,这说明该类方法对复杂的、非线性的交通数据的建模能力有限。历史平均模型只捕捉了交通数据的周期性,由于城市交通流量与近期城市区域间的交通流量相关性高,因此ARIMA模型的预测效果优于HA模型。

基于传统深度学习的方法(LSTM)比时间序列分析方法的预测性能更好,这是因为循环神经网络更有利于处理时间序列问题,LSTM模型对循环神经网络进行改进,通过控制输入门、输出门和遗忘门解决了短时记忆的问题,从而使循环神经网络可以有效利用较大范围内的训练数据来提升性能。

基于深度学习的时空神经网络(ST-ResNet,ST-MetaNet,ST-3DGN)的预测效果优于LSTM模型,这是因为尽管传统深度学习方法能够建模非线性的交通数据,但是没有考虑交通网络的流动性,无法有效提取时空数据的高层特征。ST-ResNet通过残差结构和深层卷积神经网络考虑了长期依赖与短期依赖,可以捕捉交通数据的时间和空间特征,但是缺乏对远距离区域依赖关系的建模。ST-MetaNet通过编码器与解码器对交通特征图进行建模,有效捕捉了交通流量的时空特征,但是没有考虑交通数据的动态性。每个区域和时间段的交通流量对于预测时间段的影响是动态变化的,所以需要动态捕捉时空相关性。ST-3DGN使用三维卷积代替二维卷积对城市交通图进行建模,并使用了早期融合机制来稳定模型预测性能,但是没有对日周期依赖性进行建模,城市每日的交通流量具有时间相似性。ST-3DGN针对远距离区域相关性进行了建模,但是没有考虑区域之间的时间相关性是动态变化的,且没有对日周期依赖进行建模。实验结果表明,加入时间注意力机制明显改善了模型的预测性能。

AST-3DGN使用三维卷积神经网络来提取交通数据的空间特征和时间特征;通过对最近周期、日周期和周周期依赖的建模来捕获交通数据的周期依赖性;改进了ResPlus模块,考虑了地理位置对交通流量的影响,并融合了空间注意力和时间注意力机制,动态地捕捉交通流量数据的空间相关性和时间相关性;使用了基于参数矩阵的融合方法,考虑了不同周期依赖对于预测结果的影响程度。实验结果表明,AST-3DGN模型在不加入空间注意力和时间注意力机制的情况下,预测性能优于已有的先进模型,这表明了该模型在描述交通数据时空特征的优越性。结合时空注意力机制的AST-3DGN在两个数据集上的预测性能均优于对比模型。

超参数的设置往往依赖于研究人员的经验,且对模型性能的影响很大,为了使本文模型的预测性能更加理想、训练过程更加稳定,本文设置了不同学习率对模型进行实验。实验采用训练集的十分之一作为验证集,使用早停法控制训练的轮数,参数“patients”设置为 50,即如果 50 轮训练内验证集的性能都没有提升,那么终止训练,使用 MSE 作为验证集的损失函数,MSE 定义如式(11)所示,其中 Y_i 为预测值, y_i 为真实值。图 6 为不同学习率在 BikeNYC 数据集上对模型性能的影响。

$$MSE = \frac{1}{n} \sum_i (y_i - Y_i)^2 \quad (11)$$




图 6 不同学习率对模型性能的影响

Fig. 6 Influence of different learning rates on model performance

通过图 6 可以发现,当学习率设置为 2×10^{-3} , 2×10^{-4} 和 2×10^{-6} 时,模型训练轮数较小,这是因为过大或过小的学习率使模型在某 50 轮内验证集的性能没有得到提升,导致训练过早停止。当学习率设置为 1×10^{-5} , 2×10^{-5} 和 3×10^{-5} 时,训练较为稳定,其中学习率为 2×10^{-5} 时验证集的性能最好,所以采用 2×10^{-5} 作为模型的学习率超参数。

实验还对 AST-3DGN 模型的鲁棒性进行了测试。将数据集按时间划分为 3 个子数据集,如表 3 所列。并与 ST-ResNet 和 ST-3DGN 模型进行了对比,对比结果如表 4 所列。实验结果表明,AST-3DGN 模型在 4 个子数据集上的表现均优于两个模型,这说明本文模型具有较高的鲁棒性。

表 3 鲁棒性测试子数据集划分

Table 3 Subdataset division for Robustness test

Dataset	Time
01	2013/7/1—2013/10/30
02	2014/3/1—2014/6/30
03	2015/3/1—2015/6/30

表 4 不同模型在 3 个子数据集上的预测性能(RMSE)

Table 4 Predictive performance(RMSE)of different models on three subdatasets

Model	01	02	03
ST-ResNet	23.11	21.58	22.75
ST-3DGN	18.70	16.63	17.18
AST-3DGN(ours)	18.16	16.41	16.82

结束语 本文提出了一种基于动态时空神经网络的城市交通流量预测模型。以时空数据为输入,分别对最近周期依赖、日周期依赖、周周期依赖进行建模;使用三维卷积提取交通数据的时空特征,通过改进的残差结构对非相邻区域的地理相关性进行建模,并融合了时空注意力机制,能够很好地捕获交通数据的流动性和动态时空相关性;通过基于参数矩阵的融合方法动态地调整 3 个组件对预测目标的影响程度。最后,在两个真实的公开数据集上进行实验,结果表明,本文提出的 AST-3DGN 在城市区域交通流量预测方面优于对比模型。

未来的工作是探索模型在非网格数据的交通流量预测。

参考文献

- [1] BENABDALLAH B R, BEGHADAD B K. A Comparative Study of Road Traffic Forecasting Models[C]// International Conference on Artificial Intelligence and Its Applications. Cham: Springer, 2022: 272-280.
- [2] WU T F, XU H Z, LU J. Short term passenger flow forecast based on arrival interval[J]. Journal of Wuhan University of Technology (Traffic Science and Engineering), 2020, 44(6): 1098-1102.
- [3] ZIVOT E, WANG J. Vector autoregressive models for multivariate time series[J/OL]http://www.databaser.net/moniwiki/pds/TimeSeries/varModels.pdf.
- [4] YANG H, LI X, QIANG W, et al. A network traffic forecasting method based on SA optimized ARIMA-BP neural network[J]. Computer Networks, 2021, 193: 108102.
- [5] VAN L J W C, VAN H C. Short-term traffic and travel time prediction models[J]. Artificial Intelligence Applications to Critical Transportation Issues, 2012, 22(1): 22-41.
- [6] 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.
- [7] LIU X, SONG L, LIU S, et al. A review of deep-learning-based medical image segmentation methods[J]. Sustainability, 2021, 13(3): 1224.
- [8] TANG J X, CHEN Y, ZHOU M Y, et al. A survey of studies on deep learning applications in POI recommendation[J]. Computer Engineering, 2022, 48(1): 12-23, 42.
- [9] ZHANG J, ZHENG Y, QI D, et al. Predicting citywide crowd flows using deep spatio-temporal residual networks[J]. Artificial Intelligence, 2018, 259: 147-166.
- [10] YAO H, WU F, KE J, et al. Deep multi-view spatial-temporal network for taxi demand prediction[C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2018.
- [11] DAI G, HU X Y, GE Y M, et al. Attention based simplified deep residual network for citywide crowd flows prediction[J]. Frontiers of Computer Science, 2021, 15(2): 1-12.
- [12] ZHANG Y, HU Y, XIN D R. A deep learning short-term traffic flow prediction method considering spatial-temporal association [J]. Chinese Journal of Intelligent Science and Technology, 2021, 3(2): 172-178.
- [13] LI S J, ZHU S S, WANG P. Traffic prediction based on spatio-temporal correlation multitask neural network [J]. Computer Applications and Software, 2021, 38(9): 286-292.
- [14] ABDULJABBAR R L, DIA H, TSAI P W, et al. Short-term traffic forecasting: an LSTM network for spatial-temporal speed prediction[J]. Future Transportation, 2021, 1(1): 21-37.
- [15] ZHANG X H, FENG A M. Short-term traffic flow prediction based on empirical mode decomposition and long short-term memory neural network[J]. Journal of Computer Applications, 2021, 41(1): 225-230.
- [16] TSAI M J, CHEN H Y, CUI Z, et al. Multivariate Long And Short Term LSTM-Based Network for Traffic Forecasting Under Interference: Experiments During COVID-19 [C]// 2021

- IEEE International Intelligent Transportation Systems Conference(ITSC). IEEE,2021:2169-2174.
- [17] NAQVI U, MAJID A, ABBAS S A. UTSA: Urdu text sentiment analysis using deep learning methods[J]. IEEE Access,2021,9: 114085-114094.
- [18] CAI W, ZHAI B, LIU Y, et al. Quadratic polynomial guided fuzzy C-means and dual attention mechanism for medical image segmentation[J]. Displays,2021,70:102106.
- [19] XU K, BA J, KIROS R, et al. Show, attend and tell: Neural image caption generation with visual attention[C]// International Conference on Machine Learning. PMLR,2015:2048-2057.
- [20] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. arXiv:1710.10903,2017.
- [21] LIU Q, LIU T, CAI Y, et al. Explanatory prediction of traffic congestion propagation mode: A self-attention based approach [J]. Physica A: Statistical Mechanics and its Applications,2021, 573:125940.
- [22] WANG J J, CHEN Q K. Traffic Prediction Model Based on Spatiotemporal Attention Network[J]. Journal of Chinese Computer Systems,2021,42(2):303-307.
- [23] REN J H, ZHU Y, et al. Predicting Citywide Traffic Flow Using Dynamic Spatial-temporal Neural Networks[J]. Journal of Chinese Computer Systems,2023,44(3):529-535.
- [24] LIN Z, FENG J, LU Z, et al. Deepstn+: Context-aware spatial-temporal neural network for crowd flow prediction in metropolis [C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2019:1020-1027.
- [25] WOO S Y, PARK J C, LEE J Y. CBAM: convolutional block attention module[C]// European Conference on Computer Vision (ECCV). 2018:3-19.
- [26] YANG D, CHEN K, YANG M, et al. Urban rail transit passenger flow forecast based on LSTM with enhanced long-term features[J]. IET Intelligent Transport Systems, 2019, 13 (10): 1475-1482.
- [27] PAN Z, LIANG Y, WANG W, et al. Urban traffic prediction from spatio-temporal data using deep meta learning[C]// 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining,2019:1720-1730.



MENG Xiangfu, born in 1981, Ph. D, professor, is a senior member of China Computer Federation. His main research interests include big data analysis and query, spatio-temporal data mining, and machine learning algorithms.