

全局和局部感知的交通速度预测模型

申岩松¹, 李琳^{1*}, 黄传明^{1,2}

(1. 武汉理工大学计算机与人工智能学院, 湖北武汉 430070; 2. 武汉市交管局, 湖北武汉 430030)

摘要: 面对日益严峻的交通堵塞问题, 智能交通系统获得飞速发展和广泛应用, 作为基石工作的交通速度预测因此备受关注. 近些年来, 深度学习被广泛用于交通速度预测的研究工作, 并且研究方向也从单一的建模时间相关性迁移到复杂的时空相关性, 图神经网络由于契合交通路网的图结构数据这一本质属性, 成为建模空间相关性的主流方法. 目前, 大多数的研究工作已经注意到动态的空间相关性对交通速度预测任务的重要性. 然而, 基于这一发现所提出的建模思路主要预定义矩阵或自适应矩阵, 属于静态矩阵, 并不足以应对空间相关性的复杂和动态的特性. 同时通过对真实交通速度数据集的分析, 本文发现交通节点间依赖的局部波动相比交通路网的全局影响具有更强的动态性, 这表明空间相关性可以从全局和局部的角度分开建模, 因此本文提出了一个端到端全局和局部融合的动态图神经网络模型来进行交通速度预测. 首先, 交通速度流被自分解层分解为静态分量和动态分量, 随后动态图生成模块为动态分量构造实时的动态图以匹配其动态性. 基于构造的动态图和输入的预定义图, 本文借助图卷积操作来学习这两类空间相关性的高阶表达. 除此之外, 本文在时间模块使用空洞因果卷积捕获交通数据中时间相关性. 最后, 残差连接被用来聚合时空相关性并输送给输出层完成最终的速度预测. 在两个高速公路数据集和一个城市路数据集上的实验结果表明本文提出的模型相比主流模型在平均绝对误差和均方根误差两个预测指标上均优于主流模型.

关键词: 交通速度预测; 时空相关性; 动态图神经网络; 图生成

基金项目: 国家自然科学基金(No.62276196); 湖北省重点研发计划项目(No.2021BAA030)

中图分类号: TP391.1

文献标识码: A

文章编号: 0372-2112(2024)09-3195-11

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

DOI: 10.12263/DZXB.20221274

Global and Local Information Aware Traffic Speed Prediction

SHEN Yan-song¹, LI Lin^{1*}, HUANG Chuan-ming^{1,2}

(1. School of Computer Science and Artificial Intelligence, Wuhan University of Technology, Wuhan, Hubei 430070, China;

2. Wuhan Traffic Management Bureau, Wuhan, Hubei 430030, China)

Abstract: Facing the increasingly severe traffic congestion problem, the intelligent transportation system has been rapidly developed and widely used, and the traffic speed prediction, a cornerstone task, has attracted much attention. In recent years, deep learning has been widely used in the research of traffic speed prediction, and the research direction has also shifted from modeling time correlation to considering complex spatiotemporal correlation. The graph neural network fits the graph structure data of the traffic network and has become the mainstream method for modeling spatial correlation. To date, most research works have noted the importance of modeling dynamic spatial correlations in the task of traffic speed prediction. However, predefined or adaptive matrices for spatial feature learning are essentially static, and are not sufficient to match the complex and dynamic characteristics of spatial correlations. Moreover, through the analysis of multiple real traffic speed datasets, we find that the local fluctuations of inter-node dependencies are more dynamic than the global influence of the traffic network, which indicates that the spatial correlation can be derived from the global and local angles. Therefore, we propose an end-to-end global and local aware dynamic graph neural network model for traffic speed prediction. The traffic speed flow is first decomposed into static components and dynamic components by the self-decomposition layer, and then the dynamic graph generation module constructs a real-time dynamic graph for the dynamic components to match their dynamics. With the constructed dynamic graph and the input predefined graph, we model higher-order representations of these two classes of spatial correlations through graph convolution operations. Besides, we use causal convolution in the temporal module to capture temporal correlations in traffic data. Finally, residual connections are used to aggregate spatio-

temporal correlations and feed to the output layer for final speed prediction. Experimental results on two highway datasets and one urban road dataset show that our proposed model outperforms state-of-the-art models in terms of MAE and RMSE.

Key words: traffic speed prediction; spatial-temporal correlations; dynamic graph neural network; graph generation

Foundation Item(s): National Natural Science Foundation of China (No.62276196); Key Research and Development Project of Hubei Province (No.2021BAA030)

1 引言

准确的交通速度预测为智能交通系统(Intelligent Transportation System, ITS)提供了有力支持,并在近些年通过应用深度学习方法取得显著成果. 相较传统方法^[1-3],卷积神经网络(Convolution Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)拥有更强的非线性捕获能力,因此被广泛应用于建模时间相关性^[4-6]. 考虑到交通模式下单个节点的未来速度会受到其他节点的影响^[7],许多研究工作越发重视建模空间相关性.

近年来,图神经网络(Graph Neural Network, GNN)对非欧数据的处理能力愈发瞩目,应用其建模节点依赖也逐渐成为了主流方法,而关键问题便是构建一个合适的邻接矩阵以反映路网信息. 早期基于图神经网络的模型使用预定义矩阵作为节点间依赖的描述,这些矩阵大都通过计算节点间的相似度(如:连接关系^[8,9]、距离^[10,11]或兴趣点相似度^[12,13])来构造. 考虑交通速度预测任务蕴含的空间相关性的复杂性,部分研究工作如:Graph WaveNet, SDGCN(Semantics-aware Dynamic Graph Convolutional Network)等,在模型中补充了一个自适应矩阵,在训练中学习隐藏的空间相关性^[14,15]. 然而,这两类矩阵本质上属于静态矩阵,无法随着时间动态调整自身,因此面对动态变化的空间相关性均显不足. 目前,部分研究如:MTGNN(Multivari-

ate Time Series Forecasting with Graph Neural Networks)、DMSTGCN(Dynamic Multi-scale Spatial-Temporal Graph Convolutional Network)、STDGAT(Spatial-Temporal Dynamic Graph Attention Network)等,提出构造实时的动态图以适应空间相关性的动态特性^[16-18],他们试图靠构造单个动态图来建模空间相关性,却没有区分节点依赖的不同特性.

图1(a)为METR-LA(Metro Traffic Los Angeles)数据集中部分节点在某段时间步上速度的变化情况. 图中展现了某些节点的速度跳跃现象,这表明该影响具有局部性和短期性. 图1(b)为METR-LA交通数据集节点的平均速度变化情况. 平均速度随着时间有规律的起伏,表明了这种影响具有全局性和长期性. 具体来说,图1(a)展示了发生在节点15处的交通堵塞影响到节点3、17以及19处,这引发了交通速度的下降随后快速回升. 这表明这类影响具有局部性和强烈的动态性,因此本文称其为空间相关性的局部波动(可能由特定地点发生的交通事故导致). 另一方面,交通路网和节假日的固有影响可以借助平均速度反应. 如图1(b)所示,观测数据集的平均速度存在明显的周期性,这表明这类影响是作用于全局的交通网络,并且持续了很长时间. 因此,本文称这种稳态的大范围影响为空间相关性的全局影响. 考虑到节点间的影响会随着交通环境改变而发生变化,因此建模空间相关性的动态特性对降低速度预测误差至关重要. 然而,主流方法大都采用




图1 空间相关性的局部波动和全局影响

静态矩阵作为路网结构^[8-15],缺乏对动态变化的建模,也没有区分空间相关性中全局影响和局部波动的显著区别。

基于以上分析,本文认为交通速度流可以被分解为静态分量和动态分量。其中,静态分量包括了路网结构和外部环境对空间相关性的全局影响;动态分量代表空间相关性的局部波动。这种对复杂且动态的空间相关性的细粒度建模,可以进一步释放动态图神经网络能力,进而提高交通速度预测任务的准确度。因此本文提出了一种端到端全局和局部融合的动态图神经网络模型,被称为 GL-STGCN (Global and Local aware Spatial-Temporal Dynamic Graph Convolutional Neural Network)。本文工作的主要贡献概括如下:

(1)本文提出了一个新颖的全局和局部融合的动态图神经网络框架,其由多个堆叠的时空层组成。每个时空层包含一个时间模块以及一个空间融合模块,其中空间融合模块由一个自分解模块、一个静态图卷积层 S-GCN (Static Graph Convolution Network) 以及一个动态图卷积模块 D-GCN (Dynamic Graph Convolution Network) 组成。D-GCN 模块包括动态图生成和一个图卷积层。

(2)本文的 D-GCN 模块利用动态图生成模块为动态分量在每个时间步构造动态图,图卷积 (Graph Convolution Network, GCN) 可以构建在动态图上建模空间相关性的局部波动。

(3)本文在两个高速公路数据集和一个城市道路数据集进行实验检验,结果表明模型在平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 两个指标上均优于主流模型。

2 相关工作

2.1 交通速度预测

自上世纪七十年代起,交通预测的研究工作几经技术迭代,作为其中分支的交通速度预测,预测的准确度也不断提升。早期的研究工作依托数据驱动的统计方法进行预测,例如:历史平均 (History Average, HA)、移动自回归均值模型 (Autoregressive Integrated Moving Average, ARIMA)^[2,3,19]。然而这些方法受到自身参数数量和对数据的平稳性假设的限制而不能处理复杂且动态的交通流数据,因此难以适用于如今数据量不断膨胀的交通数据集。

随着深度学习的提出与发展,其应用于交通速度预测任务便产生了令人惊叹的效果。Gehring 等人首次引入全卷积模型用于序列到序列学习^[20],自此以后,基于深度学习的交通速度预测模型便不断被提出^[4-6,8-14,21]。为了更好的进行长期预测,Wu 等人采用

空洞因果卷积来建模时间相关性^[15],相比标准 1D 卷积可以以更低的消耗取得更高的预测效果。另一方面,考虑到交通速度预测不再是单个节点的时间序列预测任务,因此如何挖掘交通速度数据中隐藏的空间相关性也成为研究工作的另一个方向。为了契合 CNN 对欧式数据的优秀处理能力,早期的研究将路网结构视为网格图,并借助 CNN 学习空间相关性^[6,21,22]。Yu 等人便是应用 CNN 处理网格图的时间序列的数据^[21]。然而,路网结构本质上属于非欧空间的数据,相较于 CNN,图神经网络 GNN 更擅长处理非欧数据,因此更适合学习空间相关性。

2.2 图神经网络

从 GNN 首次应用到交通速度预测,如何构造一个合适的图以代表节点依赖就一直是一个关键问题。Bruna 等人基于无向图首次实现了用 GCN 捕获空间依赖^[23]。然而,在现实的交通环境下,对向车流往往互不影响,这在高速公路中尤其明显。因此,无向图并不适合有向的节点依赖。考虑到交通数据的有向性,Li 等人采用在有向图上的双向随机游走操作来学习节点依赖^[10]。自此,预定义矩阵被广泛用于建模空间相关性^[11,21]。然而,这种预定义的矩阵所提供的信息还不足以描述动态的空间相关性。

为了克服预定义矩阵的缺陷,自适应矩阵被提出用来发掘隐藏的节点依赖^[14,15]。然而,它本质上还是属于静态矩阵,缺乏随交通环境的变化而动态调整自身的能力。针对此问题,许多研究工作从构造动态图入手,进一步提高了预测精度。Wu 等人提出了一个图学习模块,通过计算可学习的节点嵌入之间的相似度来生成一个动态图^[16]。受张量分解中 Trucker 分解的启发,Han 等人设计了一个动态图生成层为一天中特定时刻的节点依赖构造动态图^[17]。本文认为空间相关性的全局影响和局部波动具有不同的特点,动态图神经网络可以对这两种空间相关性分别建模,从而细粒度地构造动态图获得空间相关性的高阶表达,提高交通速度预测的精度。

3 问题定义

交通速度预测通常被视为带有先验知识的多元时间序列预测任务。先验知识即交通网络,通常是由带权的有向图表示为 $g=(V,\varepsilon,A)$ 。V 代表着交通节点的集合 $|V|=N$; ε 代表着边的集合; $A \in \mathbf{R}^{N \times N}$ 代表着邻接矩阵。

在时间 t 时,交通节点的速度可由 $\mathbf{X}_t \in \mathbf{R}^{N \times D}$ 表示,其中 D 是每个节点的特征长度。给定路网结构 g 和 T 步的历史交通速度 $\mathbf{X}_{(t-T+1):t}$,需要学习一个函数 $f(\cdot)$ 能够将 g 和 $\mathbf{X}_{(t-T+1):t}$ 转换到未来 Q 步的交通速度 $\mathbf{X}_{(t+1):(t+Q)}$,其可以由下述公式表示:

$$[\mathbf{X}_{(t-T+1):t}, \mathbf{g}] \xrightarrow{f(\cdot)} \mathbf{X}_{(t+1):(t+Q)} \quad (1)$$

4 方法

4.1 模型结构

本文提出的 GL-STGCN 的整体框架如图 2 所示, 其由 k 个堆叠的时空层和一个输出层组成. 在每个时空

层中, 时间模块(4.2 节)和空间融合模块(4.3 节)分别被设计用来捕获交通数据中时间相关性和空间相关性. 同时为了避免梯度消失的问题, 残差连接被添加在时间模块的输入和空间融合模块的输出之间. 每一时空层的输出将传递给下一时空层作为输入. 最后, 在每一层的时间模块后面添加跳跃连接来聚合时空特征用于预测未来交通速度.

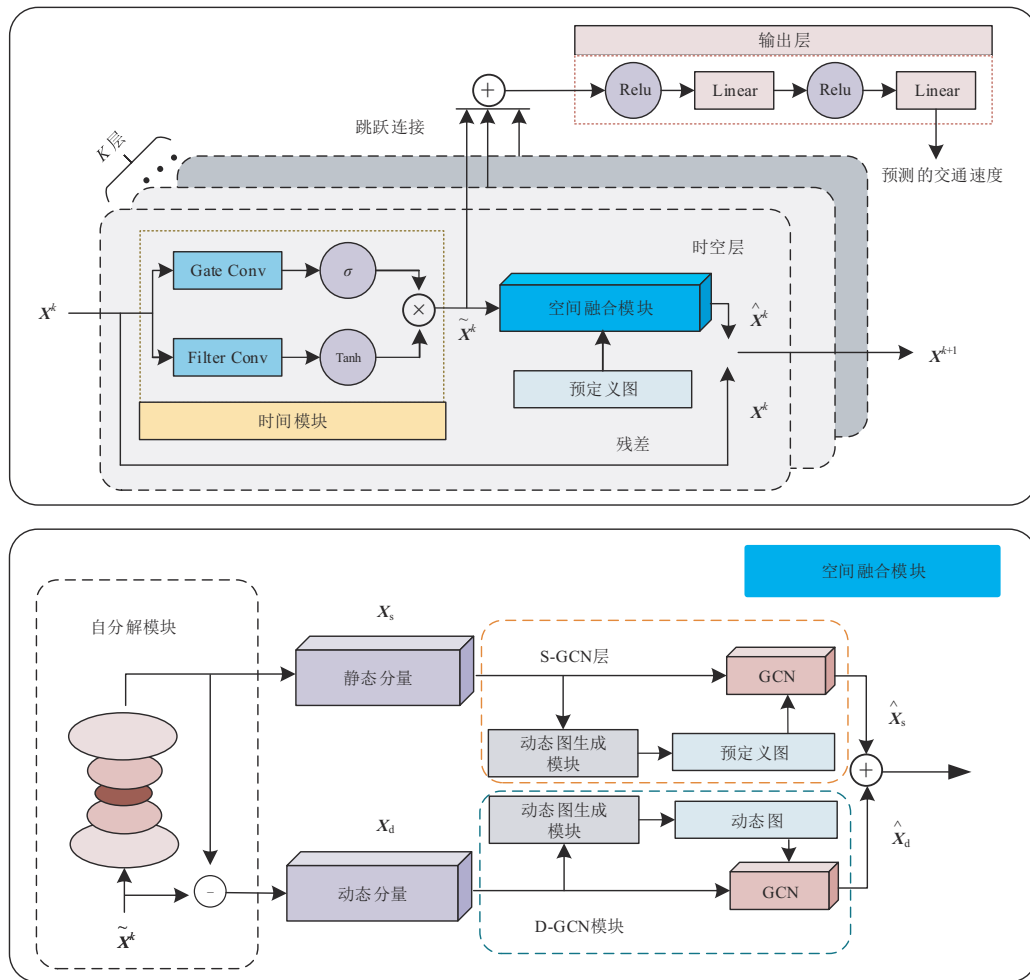


图2 模型整体框架

正如图 2 下半部分所展示, 本文提出的空间融合模块包含一个自分解模块、一个 S-GCN 层以及一个由动态图生成模块和一个 GCN 层组成的 D-GCN 模块. 自分解层采用提取数据中主体关键特征的方式将输入分解为一个静态分量 \mathbf{X}_s 和一个动态分量 \mathbf{X}_d . S-GCN 层和 D-GCN 模块分别被用来建模空间相关性的全局影响和局部波动.

4.2 时间模块

本文选取了门控空洞因果卷积来学习交通速度数据中的时间相关性^[15]. 门控机制可以避免信息在每个时间步的转换中消失的问题, 使经过时间模块的交通

流包含历史的交通流信息. 空洞因果卷积通过设定跳跃步长的大小来挖掘较远历史的交通数据对当前时刻的交通速度的影响, 这允许模型可用以较小的层处理更长的时间序列, 该过程可以通过图 3 展示.

时间模块展示在图 2 黄色部分, 对于给定输入 $\mathbf{X}^k \in \mathbf{R}^{T \times N \times D}$, 其可定义如下式:

$$\tilde{\mathbf{X}}^k = \tanh(\mathbf{f}_k * \mathbf{X}_k) \odot \sigma(\mathbf{g}_k * \mathbf{X}_k) \quad (2)$$

其中, $*$ 代表空洞因果卷积操作, $\tanh(\cdot)$ 是激活函数, $\sigma(\cdot)$ 为 sigmoid 函数 (主要用于控制流向下一层的交通信息的比率). \mathbf{f}_k 和 \mathbf{g}_k 分别是第 k 时空层中可学习的矩阵. 时间模块首先使用两个空洞因果卷积处理输入, 借助




图3 空洞因果卷积示意图

跳跃步长来跳过相邻时刻的交通信息,提高处理长期交通流数据的能力. 经过卷积操作后,历史信息已被包含在当前时刻的交通流中. 随后的门控结构使用两个函数处理卷积结果,两者Hadamard的乘积将作为时间模块的输出流入空间融合模块.

4.3 空间融合模块

正如前面论述,空间相关性不仅包含路网结构的固有影响还有因交通特性所引起的动态变化,因此较为复杂. 为了捕获空间相关性的动态变化,需要考虑以下两点:(1)节点间的影响存在着高频的波动现象;(2)这种波动通常是局部的,要与路网结构的全局影响区分开.

因此,本文提出了一个空间融合模块,如图2底部所示. 首先设计了一个自分解模块将输入的交通流分解为两个分量;随后将其分别馈入到S-GCN层和D-GCN模块来捕获空间相关性的两种动态变化.

4.3.1 自分解模块

如图4所示,自分解模块将输入数据分解为一个静态分量以及一个动态分量. 输入的交通速度数据 $\tilde{X}^k \in \mathbf{R}^{T \times N \times D}$ 依次通过由多层 CNN 组成的解码器模块和编码器模块,结果将作为静态分量 $X_s \in \mathbf{R}^{T \times N \times D}$. 整个过程伴随着维度的收缩和回升,从而提取交通速度流中的主体分量. 除此之外,每个编码卷积操作后面添加的批量归一化操作被用来加快收敛^[24]. 最后,输入与静态分量的差作为动态分量 $X_d \in \mathbf{R}^{T \times N \times D}$. 在图4中, X_s 为空间相关性的全局影响,而 X_d 代表节点间依赖的局部波动. 通过分离两类空间相关性,本文可以分别建模空间相关性的不同变化.

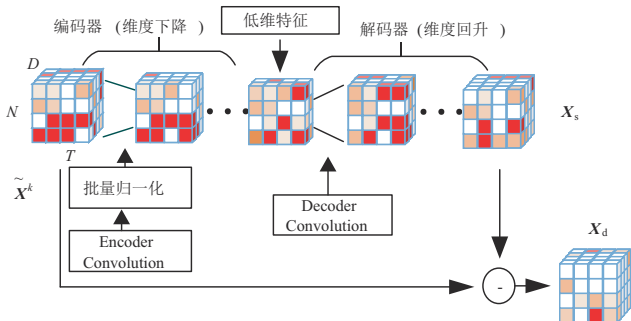


图4 自分解模块的处理过程

4.3.2 D-GCN模块

考虑到空间相关性的局部波动的动态特性,本文设计了D-GCN模块处理动态分量,并为其构造动态图. 每一个D-GCN模块包括一个动态图生成以及一个GCN层. 动态图生成基于当前时间步的交通信息为其构造合适的动态图,随后馈入到GCN来捕获空间相关性的动态变化,整个过程如图5所示.

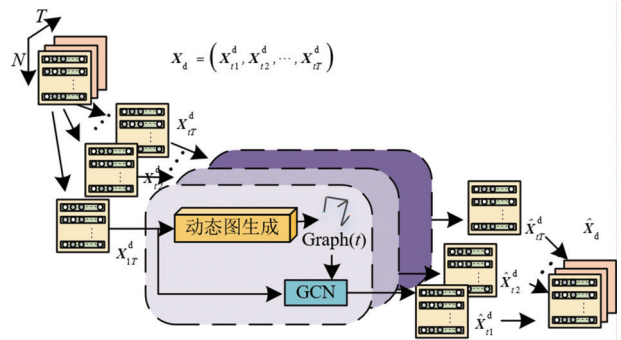


图5 D-GCN模块对 X_d 的处理过程

(1) 动态图生成

动态图生成的过程如图6所示,其可以分为以下3步.

第1步,使用图卷积操作处理交通流数据和预定义

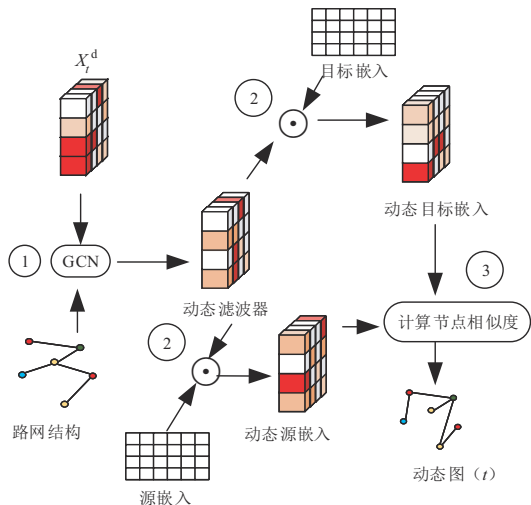


图6 动态图生成成为 X_d^t 构造 t 时间步下的动态图的过程

的路网结构信息,这使得每个节点可以感知邻居节点的信息,帮助我们生成更准确的实时图,其结果将作为动态滤波器供后续使用. 该过程可以由式(3)表示:

$$F_t = g * f_{\theta} X_t^d \quad (3)$$

其中, X_t^d 为在 t 时间步的动态分量, F_t 代表动态滤波器, 而 $*f_{\theta}$ 是图卷积操作, 其定义公式在下一小节给出.

第2步, 设置两个节点嵌入向量 $E_{in}, E_{out} \in \mathbf{R}^{N \times D}$ 分别代表源节点嵌入和目标节点嵌入. 这两个嵌入向量被随机初始化, 其参数随训练学习. 本文采用元素 Hadamard 乘积分别将源嵌入和目标嵌入与动态滤波器相结合, 得到动态源嵌入 S_t^{in} 和动态目标嵌入 S_t^{out} . 整个过程可以由式(4)表示:

$$\begin{aligned} S_t^{in} &= \tanh(\lambda(F_t \odot E_{in})) \\ S_t^{out} &= \tanh(\lambda(F_t \odot E_{out})) \end{aligned} \quad (4)$$

第3步, 通过计算节点相似度的方法来构造动态图 $G_t \in \mathbf{R}^{N \times N}$, 该过程可定义为式(5):

$$\begin{aligned} \Delta &= \lambda(S_t^{in} S_t^{out T} - S_t^{out} S_t^{in T}) \\ G_t &= \text{softmax}(\text{ReLU}(\tanh(\Delta))) \end{aligned} \quad (5)$$

其中, λ 为控制控制激活函数饱和度的超参数, ReLU 和 $\tanh(\cdot)$ 均是激活函数, softmax 被用来实现矩阵的归一化.

(2) 图卷积层

我们采用扩散卷积的方式实现图卷积操作. 扩散卷积使用向前转移和向后转移矩阵在有向图上进行双向 K 层随机游走, 达到聚合邻居节点信息的目的, 并获得中心节点的高阶表达^[9], 扩散卷积的定义如式(6)所示:

$$\widehat{X} = g * f_{\theta} X = \sum_{k=0}^K (\theta_{k,1} D_f^k + \theta_{k,2} D_b^k) X \quad (6)$$

其中, g 为输入的图, $\theta \in \mathbf{R}^{2 \times k}$ 为双向随机游走中的过滤器, k 为扩散步数, D_f^k 和 D_b^k 分别代表扩散卷积中的向前转移和向后转移矩阵.

因此, 整个 D-GCN 模块对动态分量的处理过程可定义为:

$$X_d^{k,\dots} = G_t * f_{\theta} X_t^d \quad (7)$$

其中, G_t 为动态图生成成为动态分量构造的 t 时间步下的动态图, $t \in \{1, \dots, T\}$, $*f_{\theta}$ 代表图卷积操作.

4.3.3 S-GCN 层

通过建立在在预定义图上的图卷积捕获空间相关性的全局变化, 该过程可定义为:

$$\widehat{X}_s = g * f_{\theta} X_s \quad (8)$$

其中, g 为输入的路网预定义图, X_s 为静态分量, S-GCN 和 D-GCN 的输出结果将一同传输作为下一时空层的输入.

4.4 损失函数

在时间模块和空间融合模块分别学习时间相关性

和空间相关性后, 跳跃连接被添加到时间模块后面用于聚合时空相关性, 随后输送给输出层, 用于最终的速度预测.

GL-STGCN 的输出层包含两组 ReLU 和线性层, 以确保输出结果为我们想要的预测长度. 残差链接用于加速收敛^[15]. 整个过程如图2上半部所示. 真实值 X 与预测值 \widehat{X} 之间的平均绝对误差被选取作为模型的损失函数, 可定义为式(9),

$$\text{Loss} = \frac{1}{TND} \sum_{t=1}^T \sum_{i=1}^N \sum_{j=1}^D |X_{ij}^t - \widehat{X}_{ij}^t| \quad (9)$$

5 实验

5.1 数据集与度量标准

为了检验本文所提出模型的有效性, 本文在两个高速公路数据集 (<https://github.com/liyaguang/DCRNN>) 和一个城市道路数据集 (<https://github.com/lehaifeng/T-GCN>) 上分别进行了一系列的相关实验^[10,15-17,25]. 数据集情况的描述如下:

(1) METR-LA (Metro Traffic Los Angeles): 收集自洛杉矶高速公路上部署的环路检测器的交通信息. 整个路网包括 1 515 条道路, 共 207 个传感器, 自 2012 年 3 月 1 日至 2012 年 6 月 30 日每两分钟记录一次交通流的平均速度, 观测值总计 34 272 个.

(2) PEMS-BAY (caltrans Performance Measurement System Bay Area Dataset): 该数据集为加州交通评估系统 (caltrans Performance Measurement System, PeMS) 发布的加州湾区高速公路的真实交通数据. 路网由 2 369 个道路组成, 共 325 个传感器, 自 2017 年 1 月 1 日至 2017 年 5 月 3 日每 30 秒记录一次交通流的平均速度, 观测值总计 52 116 个.

(3) SZ-taxi: 该数据集来自深圳市 2015 年 1 月 1 日至 31 日的出租车轨迹信息, 选取了罗湖区 156 个主要道路, 数据集也包含道路之间的连接信息. 交通速度每 15 分钟记录一次, 观测值共计 2 976 个.

所有输入数据均进行了零-均值标准化 (z-score standardization). 数据集的划分按照时间顺序进行分割, 其中 70% 用于训练、10% 用于验证、20% 用于测试^[10]. 所有实验均使用过去一小时的交通信息预测未来 15 min、30 min 以及 60 min 的交通速度. 代表高速公路数据集的交通路网信息通过计算传感器之间的距离构造, 随后使用带阈值的高斯核函数处理结算结果来提高距离差异^[9]. 构造的过程可定义为下述公式:

$$A_{ij} = \begin{cases} \exp(-\frac{d_{v_i, v_j}^2}{\sigma^2}), & d_{v_i, v_j} \leq k \\ 0, & d_{v_i, v_j} > k \end{cases} \quad (10)$$

其中, \mathbf{A}_j 代表构造的邻接矩阵, d_{v_i, v_j} 为传感器 v_i 和传感器 v_j 之间的距离, σ 为全部传感器之间距离的标准差, k 为设定的阈值. MAE (Mean Absolute Error) 和 RMSE (Root Mean Square Error) 被选取为模型的评价指标^[10, 15, 16].

5.2 基线模型和实验设置

从传统模型、基于静态矩阵的模型和基于动态图的模型三类交通速度预测模型中, 本文选取了五个模型作为基线模型. 按照这些模型论文中的参数设置, DMSTGCN 在高速公路数据集上进行复现, 其他模型的结果直接来自各自的论文. 除此之外, 复现的基线模型均在数据集上进行多次实验以选取最好的结果.

(1) ARIMA^[2]: 该模型使用传统的时间序列预测方法进行交通速度预测.

(2) DCRNN^[10]: 该模型不仅使用 RNN 来捕获交通速度数据的时间相关性并在预定义图上借助 GCN 建路网结构的固有空间相关性.

(3) Graph WaveNet^[15]: 该模型结合了 GCN 以及门控一维空洞因果卷积来捕获时空相关性, 并且在预定义图的基础上添加了一个自适应矩阵来挖掘隐藏的节点依赖.

(4) MTGNN^[16]: 该模型设计了一个图学习层通过使用外部特征生成一个动态图, 并且应用了空洞扩张卷积以及混合跳跃传播.

(5) DMSTGCN^[17]: 该模型将一天划分为多个时间段, 并提出一个动态图构造模块学习特定时间的空间依赖.

根据实验结果, 本文模式的空间融合模块的参数设置如下: 自分解模块包括 4 层, 输入通道为 32, 输出通道为 16、8、16、32. 在 GCN 层, 扩散步数 K 设置为 2, 随机失活率被设置为 0.5. 在动态图生成层中, 超参数 λ 设置为 3, 源节点嵌入 \mathbf{E}_{in} 的维度和目标节点嵌入 \mathbf{E}_{out} 的维度均设置为 32, 空间模型的最终输出通道为 32. 至于时间模块的参数设置, 参照文献[15], 时空层的层数为 8, 空洞因果卷积的扩散参数分别为 1、2、1、2、1、2、1、2, 每一层时间卷积核长度为 2, 时间模块的输出通道与空间模块的输入通道保持一致, 为 32.

整个模型的训练优化器采用 Adam 优化算法, 初始学习率设置为 0.001, 在 70 轮后使用 0.1 的衰减率进行衰减. 模型使用 python 语言在 1.7.1 版本的 Pytorch 框架下编译, 整个实验在 GPU 为 NVIDIA Titan XP 的计算机环境下运行.

5.3 实验结果

表 1 表明本文的 GLSTGCN 在三个数据集上的预测准确度均高于基线模型. 以在高速公路数据集上预测未来一个小时的交通速度的准确度来衡量,

DMSTGCN 的效果要优于其他基线模型, 而本文的模型获得了更低的 MAE 和 RMSE 误差, 在 METR-LA 上分别降低了 6.0% 和 6.2%, 在 PEMS-BAY 上分别降低了 6.9% 和 6.2%. 而 MTGNN 在城市道路数据集上优于其他基线模型, 本文的模型可以降低 15.2% 的 MAE 和 4.5% 的 RMSE.

接下来, 将依照基线模型的类别划分分别讨论实验结果:

(1) 传统模型. 代表传统模型的 ARIMA 由于自身方法的限制, 因此无法处理复杂非线性的时间相关性, 同时缺乏对空间相关性的建模. 因此, 传统模型的预测误差最大.

(2) 使用静态邻接矩阵的深度学习模型. 深度学习方法因对非线性的捕获能力而被应用在时间模块, 因此深度学习模型相比 ARIMA 均有更高的预测精度. 相较于仅使用预定义矩阵的 DCRNN, Graph WaveNet 补充了一个自适应矩阵, 进一步提高了自身对空间相关性的建模能力从而获得了更好的预测效果.

(3) 构造动态图的深度学习模型. 相较于 Graph WaveNet, MTGNN 和 DMSTGCN 使用构造动态图的方法更好地捕获了空间相关性. 而本文的 GL-STGCN 继承了生成动态图的方法, 并进一步提出了细粒度地建模空间相关性的动态变化, 分别学习节点依赖的全局影响和局部波动, 因此获得了最低的预测误差.

同时为了更好地分析 GL-STGCN 的预测效果, 本文从 SZ-taxi 数据集上选取某个特定交通节点, 为其预测未来 60 min 的交通速度, 用于比较 GL-STGCN 和 MTGNN 的预测结果.

如图 7 所示, GL-STGCN 和 MTGNN 对于交通速度的周期性都具有良好的建模效果(红圈所示), 这表明预定义图可以描述空间相关性的全局影响; 同时, 本文注意到对于异常值的交通速度预测(黑圈所示), 由于 GL-STGCN 使用了自分解层将动态分量从交通信息中分离出来, 其构造的动态图更能适应交通环境的动态变化, 因此达到了更低的误差和更好地预测效果.


5.4 参数分析

为了更好地探究参数对模型能力的影响, 本文在提升最大的 SZ-taxi 数据集上进行了多次参数分析实验. 被选取的参数包括: 随机失活率从 0.1、0.3、0.5、0.7 四个值中选取; 自分解层中本质特征(图 4 中的低维特征)的维度从 4、6、8、10、12 五个值选取. 实验结果的汇总可视化如图 8 所示.


图 8(a) 显示, 模型在随机失活率为 0.3 和 0.5 的效果优于其他情况, 前者的 RMSE 误差低于后者, 而后的 MAE 误差低于前者, 但都要低于其他基线模型. 本文以降低 MAE 误差为预测的首要目的, 因此将随机失

表 1 GL-STGCN 与基线模型在三个数据集上的实验结果对比 (误差越小, 预测的准确度越高)

	T	Metrics	ARIMA	DCRNN	Graph WaveNet	MTGNN	DMSTGCN	GL-STGCN	提升率
METR-LA	15 min	MAE	3.99	2.77	2.69	2.69	<u>2.65</u>	2.51	5.2%
		RMSE	8.21	5.38	5.15	5.18	<u>4.94</u>	4.63	7.4%
	30 min	MAE	5.15	3.15	3.07	3.05	<u>2.94</u>	2.77	5.7%
		RMSE	10.45	6.45	6.22	6.17	<u>5.66</u>	5.30	6.3%
	60 min	MAE	6.90	3.60	3.53	3.49	<u>3.32</u>	3.12	6.0%
		RMSE	13.23	7.60	7.37	7.23	<u>6.52</u>	6.11	6.2%
PEMS-BAY	15 min	MAE	1.62	1.38	1.30	1.32	<u>1.15</u>	1.09	5.2%
		RMSE	3.30	2.95	2.74	2.79	<u>2.31</u>	2.18	5.6%
	30 min	MAE	2.33	1.74	1.63	1.62	<u>1.40</u>	1.31	6.4%
		RMSE	4.76	3.97	3.70	3.74	<u>2.99</u>	2.81	6.0%
	60 min	MAE	3.38	2.07	1.95	1.94	<u>1.72</u>	1.60	6.9%
		RMSE	6.50	4.74	4.52	4.49	<u>3.78</u>	3.58	5.2%
SZ-taxi	15 min	MAE	4.98	3.92	3.32	<u>3.04</u>	3.17	2.55	16.1%
		RMSE	7.24	5.39	4.70	<u>4.31</u>	4.49	4.07	5.5%
	30 min	MAE	4.67	4.03	3.36	<u>3.05</u>	3.20	2.57	15.7%
		RMSE	6.78	5.50	4.47	<u>4.32</u>	4.53	4.1	5.0%
	60 min	MAE	4.66	4.29	3.42	<u>3.08</u>	3.24	2.61	15.2%
		RMSE	6.77	5.77	4.83	<u>4.35</u>	4.57	4.15	4.5%



(a) MTGNN 的预测结果可视化




(b) GL-STGCN 的预测结果可视化

图 7 MTGNN 和 GL-STGCN 在 SZ-taxi 某节点的预测结果对比图


活率选取为 0.5.

GL-STGCN 使用自分解层分离静态分量与动态分量, 因此其中本质特征的维度对模型效果至关重要. 维度过高会使得动态分量更多地参杂于静态分量中, 无

法实现分离地效果导致模型能力降低. 同时, 维度过低也会导致不能较好地将静态分量从交通流信息中提取出来. 图 8(b) 展示了维度大小对预测精度的影响, 模型在维度为 8 时速度预测的 MAE 和 RMSE 最低.



(a) Dropout 对预测精度的影响



(b) 自分解层的特征维度对预测精度的影响

图 8 dropout 和自分解层的特征维度对预测精度的影响

5.5 对比试验

相较于高速公路数据集,本文的 GL-STGCN 在城市道路数据集上的提升效果更明显,其中 MAE 误差降低了 16.1%。其结果可能是由于城市道路会受到更多外部因素的影响,导致路况更加复杂多变,空间相关性更加难以建模。因此,本文通过对比实验,进一步探索哪一模块对建模空间相关性的影响最大。为此,设计了以下模型的变种:

(1) Variant I :使用 S-GCN 层取代 D-GCN 模块,以检验动态图和预定义图建模局部波动的效果。

(2) Variant II :取消掉了自分解层,仅使用 D-GCN 模块来建模节点依赖,借此检验我们动态图生成的效果。

所有变种在三个数据集上的实验结果如表 2 所示。同时,为了更加直观地查看变体与完整模型之间的预测差距,我们对三个数据集上 60 min 的预测结果进行整理和计算,如图 9 所示。

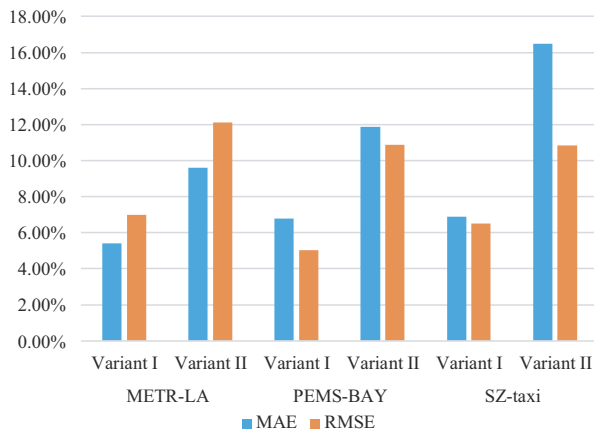


图9 变体相比完整GL-STGCN的预测误差增加比

从 MAE 和 RMSE 两个度量标准上,相较于 GL-STGCN 的六十分钟预测效果, Variant I 的误差在 METR-LA 数据集上上升了 5.40% 和 7.00%, 在 PEMS-BAY 数据集上上升了 6.80% 和 5.02%, 在城市道路数据集上上升了 6.89%、6.50%; Variant II 的误差在 METR-LA 数据集上上升了 9.60% 和 12.11%, 在 PEMS-BAY 数据集上上升了 11.87% 和 10.89%, 在城市道路数据集上上升了 16.47%、10.84%。

对于 Variant I, 在三个数据集上均下降的预测效果表明局部节点依赖的波动具有动态性, 构造动态图可以比仅使用预定义图获得更好地建模效果。同时对于 Variant II, 其预测的误差要远大于 Variant I, 这说明仅使用动态图还不足以释放动态图神经网络的能力, 而采用自分解层分离静态分量和动态分量, 并根据其

表2 GL-STGCN 及其变体在数据集上的对比实验结果

	T	Metrics	GL-STGCN	Variant I	Variant II
META-LA	15 min	MAE	2.51	2.64	2.70
		RMSE	4.63	4.98	4.93
	30 min	MAE	2.77	3.01	3.05
		RMSE	5.30	5.68	6.11
	60 min	MAE	3.12	3.29	3.42
		RMSE	6.11	6.54	6.85
PEMS-BAY	15 min	MAE	1.09	1.10	1.29
		RMSE	2.18	2.16	2.60
	30 min	MAE	1.31	1.37	1.62
		RMSE	2.81	2.80	3.44
	60 min	MAE	1.60	1.71	1.79
		RMSE	3.58	3.76	3.97
SZ-taxi	15 min	MAE	2.55	2.70	2.91
		RMSE	4.07	4.31	4.37
	30 min	MAE	2.57	2.74	2.96
		RMSE	4.1	4.35	4.46
	60 min	MAE	2.61	2.79	3.04
		RMSE	4.15	4.42	4.60

特点分开建模可以进一步提高预测精度。

从以上对比实验结果可以看出, 城市道路数据集的提升效果大体高于高速公路数据集, 因此城市道路的节点依赖具有更高的动态性。

6 总结与展望

本文提出了一个基于动态图生成的 GL-STGCN 模型用于交通速度预测。首先, 本文提出交通数据中的空间相关性包含有不同特性的全局影响和局部波动, 可以从交通流中分离后分开建模提高模型能力。据此, 自分解层被设计用于分解交通数据。随后, 代表局部波动的动态分量被输送到 D-GCN 模块来构造动态图。最后, 模型使用图卷积在预定义图和动态图上分别学习空间相关性的全局影响和局部波动。在两个高速公路数据集和一个城市道路数据集的实验结果表明: 本文提出的 GL-STGCN 在 MAE 和 RMSE 上均优于主流模型。今后的研究工作将考虑外部因素的影响(例如: 天气、交通事故以及路段属性等)、历史信息对当前影响的权重, 进一步提升交通速度预测的准确度。

参考文献

- [1] 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 Intel-

- ligent Transportation Systems, 2013, 14(4): 1700-1707.
- [2] KUMAR S V, VANAJAKSHI L. Short-term traffic flow prediction using seasonal ARIMA model with limited input data[J]. European Transport Research Review, 2015, 7(3): 21.
- [3] LEE S, FAMBRO D B. Application of subset autoregressive integrated moving average model for short-term freeway traffic volume forecasting[J]. Transportation Research Record: Journal of the Transportation Research Board, 1999, 1678(1): 179-188.
- [4] ALIREZA E, DAVID L. Spatiotemporal traffic forecasting: review and proposed directions[J]. Transport Reviews, 2018, 38(6): 786-814.
- [5] YAO H X, WU F, KE J T, et al. Deep multi-view spatial-temporal network for taxi demand prediction[C]//Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans: AAAI Press, 2018: 2588-2595.
- [6] ZHANG J B, ZHENG Y, QI D K. Deep spatio-temporal residual networks for citywide crowd flows prediction[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco: AAAI Press, 2017: 1655-1661.
- [7] 金苍宏, 董腾然, 陈天翼, 等. 融合序列分解与时空卷积的时序预测算法[J]. 电子学报, 2021, 49(2): 233-238.
- JIN C H, DONG T R, CHEN T Y, et al. Spatio-temporal convolutional forecasting based on time-series decomposition strategy[J]. Acta Electronica Sinica, 2021, 49(2): 233-238. (in Chinese)
- [8] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI Press, 2019: 922-929.
- [9] SONG C, LIN Y, GUO S, et al. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting[C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York: AAAI Press, 2020: 914-921.
- [10] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[EB/OL]. (2018-02-16)[2022-08-02]. <https://openreview.net/pdf?id=SJIHXGWAZ>.
- [11] PAN Z Y, LIANG Y X, WANG W F, et al. Urban traffic prediction from spatio-temporal data using deep meta learning[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 1720-1730.
- [12] GENG X, LI Y G, WANG L Y, et al. Spatiotemporal multi-graph convolution network for ride-hailing demand forecasting[C]//Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI Press, 2019: 3656-3663.
- [13] ZHENG C P, FAN X L, WANG C, et al. GMAN: A graph multi-attention network for traffic prediction[C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York: AAAI Press, 2020: 1234-1241.
- [14] LI Z Y, LI L, PENG Y Q, et al. A two-stream graph convolutional neural network for dynamic traffic flow forecasting[C]//2020 IEEE 32nd International Conference on Tools with Artificial Intelligence (ICTAI). Piscataway: IEEE, 2020: 355-362.
- [15] WU Z H, PAN S R, LONG G D, et al. Graph wavenet for deep spatial-temporal graph modeling[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. New York: ACM, 2019: 1907-1913.
- [16] WU Z H, PAN S R, LONG G D, et al. Connecting the dots: Multivariate time series forecasting with graph neural networks[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2020: 753-763.
- [17] HAN L Z, DU B W, SUN L L, et al. Dynamic and multifaceted spatio-temporal deep learning for traffic speed forecasting[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: ACM, 2021: 547-555.
- [18] 骈纬国, 吴映波, 陈蒙, 等. 一种基于时空动态图注意力网络的共享出行需求预测方法[J]. 电子学报, 2022, 50(2): 432-439.
- PIAN W G, WU Y B, CHEN M, et al. A spatial-temporal dynamic graph attention network based method for sharing travel demand prediction[J]. Acta Electronica Sinica, 2022, 50(2): 432-439. (in Chinese)
- [19] AHMED M S, COOK A R. Analysis of freeway traffic time-series data by using Box-Jenkins techniques[J]. Transportation Research Record, 1979, 773(722):1-9.
- [20] GEHRING J, AULI M, GRANGIER D, et al. Convolutional sequence to sequence learning[C]//Proceedings of the 34th International Conference on Machine Learning - Volume 70. New York: ACM, 2017: 1243-1252.
- [21] 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. California: International Joint Conferences on Artificial Intelligence Organization, 2018: 3634-3640.

- [22] ZHANG J B, ZHENG Y, QI D K, et al. Predicting city-wide crowd flows using deep spatio-temporal residual networks[J]. Artificial Intelligence, 2018, 259: 147-166.
- [23] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs[EB/OL]. (2013-12-21) [2022-08-22]. <http://arxiv.org/abs/1312.6203>.
- [24] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37. New York: ACM, 2015: 448-456.
- [25] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: A temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.

作者简介



申岩松 男, 1998年11月出生于山西省运城市. 2023年获得武汉理工大学硕士学位, 研究领域为机器学习、数据挖掘.
E-mail: yaso9527@whut.edu.cn



李琳 女, 1977年10月出生于湖南省衡阳市. 2009年于东京大学获得博士学位, 现为武汉理工大学教授, 主要研究领域为信息检索与推荐系统、数据挖掘与机器学习. 中国电子学会会员编号: E190008559M.
E-mail: cathylin@whut.edu.cn



黄传明 男, 1976年10月出生于黑龙江牡丹江市, 武汉理工大学交通运输工程在读博士生. 主要研究方向为交通信号控制以及智能交通.
E-mail: 10083823@qq.com