

基于双路信息时空图卷积网络的交通预测模型

康雁 谢思宇 王飞 寇勇奇 徐玉龙 吴志伟 李浩

云南大学软件学院 昆明 650504

(562530855@qq.com)

摘要 随着深度学习的发展,神经网络在各个领域都有着大量的应用,智慧交通系统也不例外。交通流预测是智慧交通系统的基石,是整个交通预测的核心所在。近年来,图卷积神经网络的利用有效地提高了交通预测的性能,如何进一步提高对图的时空特征进行捕获的能力,将会成为热点。为了提升交通预测的精度,提出了一种基于双路信息时空图卷积网络的交通预测模型。首先,针对图卷积网络的交通预测模型在长距离依赖上建模有所不足,并且没有完全挖掘时空图信息之间的隐藏关系以及在时空图结构上还有信息缺失,提出了一种三重池化注意力机制来建模全局上下文信息。通过对图卷积层和时间卷积层各增加并行的三重池化注意力路径,构造了一个双路信息时空卷积层,提升了卷积层的泛化能力及模型捕获长距离依赖的能力,同时让时空卷积层能够很好地捕获时空图结构上的空间和时间特征,从而有效地提升了交通预测性能。在两个公共交通数据集(METR-LA和PEMS-BAY)上的实验结果表明,该模型具有较好的性能。

关键词: 交通预测;图卷积神经网络;全局上下文建模;长距离依赖

中图分类号 TP181

Traffic Prediction Model Based on Dual Path Information Spatial-Temporal Graph Convolutional Network

KANG Yan, XIE Si-yu, WANG Fei, KOU Yong-qi, XU Yu-long, WU Zhi-wei and LI Hao

School of Software, Yunnan University, Kunming 650504, China

Abstract With the development of deep learning, neural network has a large number of applications in various fields, and intelligent transportation system is no exception. Traffic flow forecast is the cornerstone of intelligent traffic system and the core of the whole traffic forecast. In recent years, the use of the graph convolutional neural network has effectively improved the performance of traffic prediction. How to further improve the ability to capture the spatial and temporal characteristics of the graph will become a hot topic. In order to improve the accuracy of traffic prediction, this paper proposes a traffic prediction model based on the convolution network of dual path information spatial-temporal map. First of all, the traffic prediction model based on the graph convolution network has some shortcomings in long-distance dependence modeling, and has not fully mined the hidden relationship between the spatial-temporal diagram information and the missing information in the spatial-temporal diagram structure, so we propose a triple pooling attention mechanism to model the global context information. Based on the figure of each increase in parallel convolution layer and the time convolution triple pooling attention path, we construct a dual path information spatial-temporal convolution layer, enhance the generalization ability of convolution layer, improve the model's ability to capture long distance dependence, and spatial-temporal convolution layer can capture figure characteristics of space and time structure of space-time, effectively improve the traffic prediction performance. Experimental results on two public transport data sets (METR-LA and PEMS-BAY) show that the proposed model has good performance.

Keywords Traffic forecast, Graph convolutional neural network, Global context modeling, Long distance dependence

随着国内近几年经济的飞速发展,城市化规模逐渐扩大,国内的汽车保有量可谓是年年攀升。相关资料显示,在我国国内汽车的数量已有2亿多辆,随之而来的是巨大的交通

压力,这不仅给出行者和交通管理部门带来诸多不便和困扰,也给环境带来了污染。智慧交通系统^[2]可以有效解决这些问题,帮助交通管理部门预测交通演化的趋势,提前制定交通管

基金项目:国家自然科学基金(61762092);云南省软件工程重点实验室开放基金项目(2017SE204);云南省重大科技专项(202002AB080001);云南大学服务云南行动计划《机场智慧管理平台关键技术研究及实现》(C176240501005);《材料基因工程—基于Metcloud的集成计算功能模块计算软件开发》(2019CLJY06)

This work was supported by the National Natural Science Foundation of China (61762092), Yunnan Key Laboratory of Software Engineering Open Fund Project (2017SE204), Yunnan Major Science and Technology Project (202002AB080001), Yunnan University Service Yunnan Action Plan "Key Technology Research and Implementation of Airport Smart Management Platform (C176240501005) and Material Genetic Engineering — Metcloud Based Integrated Computing Function Module Computing Software Development (2019CLJY06).

通信作者:李浩(lihao707@ynu.edu.cn)

制措施,有效缓解交通拥堵,还可以帮助出行者了解交通状况,为出行者制定出行路径规划。智慧交通系统的核心正是交通预测,所以合理地进行交通预测是缓解交通压力的重要手段。

图是一种特殊形式的数据,描述不同实体之间的关系。图神经网络^[1]在图数据处理方面取得了很大的成功,原因是置换不变性、局部连通性和组合性。交通路网图是一个天然的时空图结构,相连的交通道路构成了时空图的空间结构,路口在多个时间段的车速、车流量等构成了时空图的时间结构。交通预测是一个典型的时空图建模预测问题,因此图神经网络在交通预测中占据了重要的地位。随着图神经网络的发展,时空图建模越来越受到人们的关注,交通时空图如图1所示,它的目标是通过假设连接节点之间的相互依赖性来建模动态节点级输入。近年来,随着深度学习的发展,很多人将卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recursive Neural Network, RNN)等模型应用于时空大数据预测问题,如利用卷积神经网络可以有效提取网格数据的空间特征^[11]。对于图结构这种非欧数据的时空数据的建模和关联关系的挖掘,传统的卷积神经网络已无法满足要求。虽然图卷积神经网络(Graph Convolutional Network, GCN)能够很好地处理图结构数据,但如何进一步提升时空建模能力,目前仍然还在探索之中。




图1 交通时空图

Fig.1 Traffic spatial-temporal graph

本文提一种基于时空全局上下文建模的交通预测模型对交通时空图进行建模,实现交通预测。模型框架的骨干部分是堆叠的3个双路信息时空卷积层(Dual Path Information-spatial Temporal Convolutional Layer, D-STC Layer),双路信息时空卷积层是由三重池化注意力(Triple-Pool Attention, T-Pool Attention)、图卷积层(Graph Convolutional Layer, GC Layer)以及时间卷积层(Temporal Convolutional Layer, TC Layer)组成,其目的是建模时空依赖关系,同时捕获时空长距离依赖关系以及隐藏的时空特性。模型还通过图学习层(Graph Learning Layer)自适应地学习出图邻接矩阵,以捕获节点之间隐藏的关联关系。所有参数都是可学的,通过梯度下降法优化。本文所提模型通过提取交通图时空相关性和路网拓扑结构,实现了路网车速预测,同时考虑了交通图信息的长距离依赖的捕获,提高了交通预测精度。本文的主要贡献包括以下3个方面。

(1)提出了三重池化(Triple-Pool, T-Pool)机制,通过将通道的最大值、平均值,以及最小值拼接起来,将通道的丰富信息汇集到一起。

(2)提出了三重池化注意力,用于建模全局上下文信息,对模型长距离依赖信息的捕获,有效地提高了模型的性能。

(3)提出了一种双路信息时空卷积层,通过对时间卷积层和图卷积层分别增加并行的全局上下文建模路径,达到更有效地捕获时空特征的能力。

(4)在真实的交通数据集上进行实验,将车速的预测值与观测值之差转换成平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)等指标,实验部分验证了本文模型在交通预测方面的有效性。

1 相关工作

1.1 交通预测

近年来,对交通预测的研究取得了大量的成果。在深度学习兴起之前,传统模型应用于路网层面的预测都取得过不错的效果。Williams等^[7]利用自回归积分滑动平均法(ARIMA)实现了交通预测;Cheng等^[8]提出一种自适应K近邻(KNN)模型用于短期路网交通预测;Du等^[9]基于传统的交通波模型设计旅行时间预测算法;Shen等^[24]提出了一种基于梯度提升回归树的短时交通预测模型来预测交通速度。

随着深度学习在计算机视觉、自然语言处理等方面取得了大量的成果,许多学者借助深度学习强大的非线性数据挖掘能力,提出基于深度学习的路网交通流预测模型, Ma等^[11]提出基于卷积神经网络的方法预测路网交通流量。Yu等^[12]提出基于长短时记忆网络(Long-Short Term Memory, LSTM)的方法,用于预测高峰期路网交通流。根据以往的研究经验,多模型融合往往比单一模型具有更好的预测效果。Sun等^[13]应用 Graphical Lasso 和神经网络融合算法进行路网规模的流量预测;Yu等^[14]融合 CNN 和 LSTM 实现北京路网交通速度预测;Yang等^[5]提出一个新颖的框架 ST-ES-Net,有效考虑了交通流量的复杂性、非线性和不确定性。

传统深度学习模型虽然具有较高的精度,但无法有效地处理路网拓扑结构的关系。随着图神经网络的兴起,图卷积神经网络被应用于交通预测中并取得了大量成果。通过图神经网络和循环神经网络构建交通流预测模型,可以有效捕获交通拓扑图的空间和时间特征,并且可以很好地解决复杂路网的建模、交通流传播规律的学习以及动态交通状况的自适应问题。GCN在交通预测上的首次应用是Li等^[15]提出图卷积神经网络用于预测路网交通速度,并用于高速公路路网预测,主要贡献点是使用双向随机行走来对空间依赖进行建模,使用 encoder-decoder 架构来对时间依赖进行建模。Yu等^[16]提出的时空图卷积网络 STGCN,解决了交通领域的时间序列预测问题。Wu等^[3]专门为多元时间序列数据设计了通用图神经网络框架 MTGNN。Feng等^[10]提出一种新颖的基于深度学习的多组件时空图卷积网络用以解决交通流量预测问题。

交通大数据是典型的时空大数据,其特点是既包含时间属性,又包含空间属性。在交通系统中,交通路网数据是天然的时空大数据,其中交通路网构成了空间结构,交通路网当中的数据如路口车流量、路口车辆速度等构成了时间结构,所以合理对时空大数据建模成为了交通预测当中的关键任务。

1.2 注意力机制

注意力模型最初被用于机器翻译^[6],现在已成为神经网络领域的一个重要概念。在人工智能领域,注意力已成为神经网络结构的重要组成部分,并在自然语言处理、统计学习、

语音和计算机视觉等领域有着大量的应用。

为了建模全局上下文信息,从而捕获长距离依赖关系,产生了两类注意力机制:1)采用自注意力机制来建模 query 对的关系;2)建模独立于查询的全局上下文。NLNet^[17]采用自注意力机制来建模长距离依赖,但是存在着计算量太大的问题。CCNet^[18]通过叠加两个交叉块对 NLNet 进行加速,并应用于语义分割。然而,NLNet 实际上为每个查询位置学习了独立于查询的注意力图,这是对像素对关系建模的计算成本的浪费。为了对全局上下文特性进行建模,SENet^[19],GENet^[20]和 PSANet^[21]通过对不同通道的重调,重新优化通道依赖关系。CBAM^[25]通过重新标定来重新校准不同空间位置和通道的重要性。但这些方法都采用了调整尺度的特征融合方法,对全局上下文建模的效果不佳。GCNet^[4]通过添加融合的方式对全局上下文进行有效建模,GCNet 可以取得比 NLNet 和 SENet 更好的性能。GCNet 充分结合了 NLNet 全局上下文建模能力强和 SENet 省计算量的优点,在各个计算机视觉任务上得到了更好的结果。Triplet attention^[23]通过使用三分支结构捕获跨维度交互来计算注意力权重。对于输入张量, Triplet attention 通过旋转操作,然后使用残差变换建立维度间的依赖关系,并以可忽略的计算开销对通道间和空间信息进行编码。这些注意力模型在视觉任务上都取得了不错的效果,因此,通过合理利用注意力机制对全局上下文建模,可以进一步提高模型的泛化能力,提升模型性能。

2 关于交通预测的问题定义

交通路网可以由图 $G=(V,E,A)$ 表示,其中是 V 节点的集合,且 $|V|=N$, E 是边的集合, A 是图的邻接矩阵。其中由图导出的邻接矩阵表示为 $A \in \mathbb{R}^{N \times N}$ 。若 $v_i, v_j \in V$ 和 $(v_i, v_j) \in E$, 则 A_{ij} 为 1, 否则为 0。设在交通路网 G 中的每个节点在经过 P 个时间步长 t 后会由传感器采集到一系列时间序列数据,也就是长度为 P 的节点特征向量,因此图 G 会有一个动态特征矩阵 $X^{(t)} \in \mathbb{R}^{N \times D}$ 。在本文中,特征矩阵可以与图信号互换使用。给定一个图 G 和它历史的 S 个时间步长图信号,学习一个函数 f 能够预测它的下一个 T 阶的图信号。映射关系表示为:

$$[X^{(t-S:t)}, G] \xrightarrow{f} X^{(t+1),(t+T)} \quad (1)$$

其中, $X^{(t-S:t)} \in \mathbb{R}^{N \times D \times S}$ 并且 $X^{(t+1),(t+T)} \in \mathbb{R}^{N \times D \times T}$ 。

3 基于时空全局上下文建模的交通预测模型

本文提出的模型的总体框架如图 2(a) 所示,它主要由 3 层时空卷积层堆叠而成。输入层接收历史交通流数据并对通道数进行变换,然后数据被传递到后续堆叠的时空卷积层中。每一个时空卷积层通过一个参数化的跳跃连接输出,目的是将每个时空卷积层的输出特征连接传送到输出层,输出层经过两个通道变换后,最终得到预测结果。

如图 2(b) 所示,每个 D-STCLayer 由一个 TC Layer、一个 GC Layer 和两个 T-Pool Attention 组成。时间卷积层建模时间相关性,图卷积层建模空间相关性,T-Pool Attention 的主要目的是通过一条分支路径对时间卷积层和图卷积层的输入进行上下文建模,然后再与卷积层的输出融合,从而有效捕获长距离依赖信息。为了发现节点之间的隐藏关联关系,通过图学习层自适应学习出一个图邻接矩阵 A ,然后将其作

为图卷积层的输入。对于每一个 D-STC Layer,输入和输出之间增加了一条残差连接。每一个时空卷积层的时间卷积层与图卷积层之间通过一个参数化的跳跃连接输出,目的是将每个时空卷积层的输出特征传送到输出层,输出层经过两个通道变换后,最终得到预测结果。

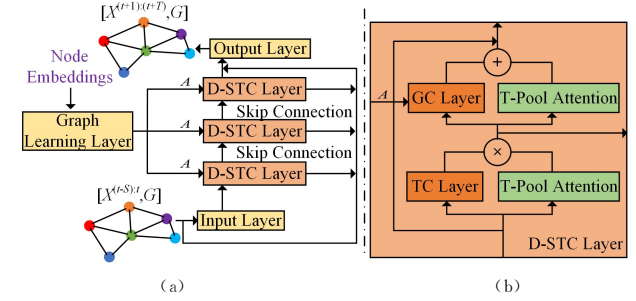


图 2 模型框架图

Fig. 2 Model frame diagram

3.1 图卷积层

图卷积神经网络能同时对节点特征信息与拓扑图结构信息进行端到端的学习。图卷积层的目的是将节点信息与其邻居信息融合,捕获图中的空间依赖关系。

本文模型的图卷积层由两个并行的混合跳跃传播层^[3]组成,这两个传播层分别处理通过的每个节点的流入和流出信息。将两个混合跳跃传播层的输出融合后作为图卷积层的输出。

混合跳跃传播层由信息传播和信息选择两个模块组成。

信息传播模块定义如下:

$$H^{(k)} = \beta H_{in} + (1-\beta) \tilde{D}^{-1} (A+I) H^{(k-1)} \quad (2)$$

其中, β 是一个超参数,它控制保持根节点原始状态的比率。

信息选择模块定义如下:

$$H_{out} = \sum_{i=0}^K H^{(i)} W^{(i)} \quad (3)$$

其中, K 为传播深度, H_{in} 表示上一层输出的输入隐藏状态, H_{out} 表示当前层输出的隐藏状态,并且 $H^{(0)} = H_{in}$, $\tilde{D}_{ii} = 1 + \sum_j A_{ij}$ 。

3.2 时间卷积层

时间卷积模块可以对时间序列上的特征进行建模。本文模型的时间卷积层由两个扩张起始层^[3]组成。一个扩张起始层之后通过一个 tanh 激活函数,作为一个过滤器。另一个扩张起始层后面通过一个 sigmoid 激活函数,控制信息的数量。然后将两个扩张起始层的输出融合后作为时间卷积层的输出。

每一个扩张起始层由 4 个并行的卷积神经网络组成,该层结合了两种常见的卷积神经网络策略,即通过多个不同大小的卷积核和应用扩张卷积。为了更好地抽取自然时间序列信号特征,使用了 4 个不同大小卷积核的卷积网络,其 4 个卷积核大小分别为 1×2 , 1×3 , 1×6 和 1×7 ,然后将 4 个卷积神经网络的输出拼接起来作为扩张起始层的输出。

3.3 三重池化注意力

通过对以往的注意力模型分析,发现通道上的特征捕获能力还不足,所以本文提出了一种加强捕获通道依赖的全局上下文建模机制——三重池化注意力(T-Pool Attention)。此模型可以很好地对全局上下文信息进行建模,从而更好地

捕获图信息的长距离依赖。模型结构如图3所示。

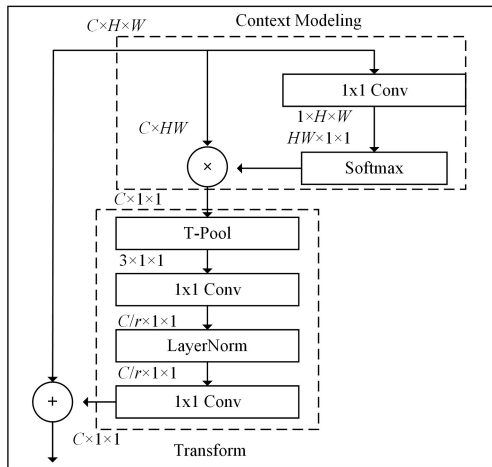


图3 T-Pool Attention 框架图

Fig. 3 T-pool Attention diagram

模型接收输入的特征后依次通过 Context Modeling 层和 Transform 层,其中 Context Modeling 层用于上下文建模; Transform 层用于捕获通道间的依赖。输入特征通过残差连接与 Context Modeling 层和 Transform 层的输出进行融合。Transform 层可以使模型变得更加轻量,能够显著降低参数量。通过增加 LayerNorm 层,减少了优化的问题,提升了模型的泛化能力。模型可表示为:

$$z_i = x_i + W_{v2} \text{ReLU}(\text{LN}(W_{v1} \text{T-Pool}(\sum_{j=1}^{N_k} \frac{e^{W_k x_j}}{\sum_{m=1}^{N_k} e^{W_k x_m}} x_j))) \quad (4)$$

T-Pool 主要将张量的通道数压缩到 3,目的是将通道维上的最大值特征、平均值特征和最小值特征汇集起来,因此可以让 Transform 层能够保留张量丰富的特征信息,同时缩小其深度,进一步减轻计算量,从而使模型变得更加轻量。T-Pool 可以定义为:

$$\text{T-Pool}(x) = \text{concat}[\text{MaxPool}(x), \text{AvgPool}(x), \text{MinPool}(x)] \quad (5)$$

总的来说,T-Pool Attention 通过将感受野覆盖到整个输入特征上,可以对全局的输入特征上下文建模,有效地对网络进行了语义信息的补充。通过 T-Pool 机制对通道依赖的捕获,增加了模型提取特征的多样性,从而提高了模型的泛化能力。

3.4 双路信息时空卷积层

为了同时捕获空间维度和时间维度的特征,本文构造了双路信息时空卷积层来建模时空特性。双路信息时空卷积层如图 2(b)所示,双路信息时空卷积层由一个时间卷积层、一个图卷积层和两个 T-Pool Attention 组成。时空卷积块中的时间卷积层主要捕获时间维度上的特征,图卷积层主要捕获空间维度上的特征。时间卷积层的输出结果与第一个 T-Pool Attention 的输出结果融合作为图卷积层与第二个 T-Pool Attention 的输入,这样经过图卷积层与 T-Pool Attention 时,数据同时也包含了时间卷积过后的信息,最后再将处理后的数据融合输出,所以时空卷积层能够很好地捕获时空图结构上的空间和时间特征。通过 T-Pool Attention 模块可以对时间卷积层和图卷积层的输入进行上下文建模,有效捕获了特征的长距离依赖。此外,在每个时空卷积层内加入残

差连接,以解决模型梯度消失问题。双路信息时空卷积层通过将图卷积层、时间卷积层和 T-Pool Attention 融合,能够更有效地同时捕获空间维度特征和时间维度特征。

双路径策略:如图 2(b)所示,双路信息时空卷积层中时间卷积层和图卷积层的输入构造了一条分支路径,并在这个分支路径中通过 T-Pool Attention 进行全局信息的捕获,其中一个与时间卷积层的输出作乘法融合,另一个与图卷积层的输出作加法融合,其目的是通过这样的路径,使卷积层的输出获得丰富的语义信息。

3.5 图学习层

图学习层^[3]能够自适应地学习出图的邻接矩阵,以此捕获数据之间的隐藏关联关系。通过将随机初始化的节点嵌入矩阵输入到图学习层中,可以输出一个被训练过的特征矩阵,这个特征矩阵可被当作图的邻接矩阵,作为图卷积层的输入。图学习层可定义为:

$$H_1 = \tanh(\alpha E_1 W_1) \quad (6)$$

$$H_2 = \tanh(\alpha E_2 W_2) \quad (7)$$

$$Adj = \text{ReLU}(\tanh(\alpha(H_1 H_2^T - H_2 H_1^T))) \quad (8)$$

$$idx = \text{topk}(Adj[i, :]), i \in N^* \quad (9)$$

$$Adj[j, -idx] = 0 \quad (10)$$

其中, E_1 和 E_2 表示随机初始化的节点嵌入, W_1 和 W_2 是模型参数, α 是一个用来控制激活函数饱和率的超参数, $\text{topk}(\cdot)$ 返回 top-k 的最大值向量的索引。由式(3)一式(5)得到不对称性图邻接矩阵。式(9)一式(10)是一种使邻接矩阵稀疏的策略,同时减少图卷积的计算损失。对于每个节点,选择其最接近的 top-k 个节点作为它的邻居,保留连通节点的权值,将非连通节点的权值设为零。

3.6 输入层和输出层

模型的输入层由一个卷积核大小为 1×1 的卷积网络组成,其目的是将输入的特征矩阵的通道变换到 32 后输入后续的建模模块当中。

模型的输出层接收来自跳跃连接融合后的数据。跳跃连接实际上是一个 $1 \times L_i$ 标准卷积,其中 L_i 是第 i 个跳跃连接输入的序列长度。它对跳跃到输出模块的信息进行标准化,使其具有相同的序列长度 1。输出模块由两个卷积核大小为 1×1 的卷积网络组成,将输入的通道数目变换为所需的输出数码。如果只想预测某个未来的步骤,那么期望的输出维度数是 1。想要预测 Q 个连续的步骤时,期望的输出维度数是 Q。

4 实验与结果分析

通过不断地改变模型的参数组合以发现最理想的参数值,并使用测试集进行模型性能的验证,将预测值与观测值之间的差转换成平均绝对误差 MAE、均方根误差 RMSE 及平均绝对百分比误差 MAPE 指标,对模型以及模型属性进行分析,并将本文提出的模型与 ARIMA 模型、Graph WaveNet 等模型进行预测精度的对比,以验证其在交通预测方面的有效性。

4.1 数据集

在两个公共交通网络数据集 METR-LA^[15] 和 PEMS-BAY^[15] 上,验证了本文模型的性能。

(1)METR-LA:洛杉矶大都会运输管理局的 METR-LA

包含来自洛杉矶高速公路段上部部署的环路检测器的交通信息。METR-LA 数据集选择了由 1515 条道路连接的 207 个传感器,包含 2012 年 3 月 1 日至 2012 年 6 月 30 日的 4 个月内的平均交通速度。包含的观测值总数为 34272。

(2)PEMS-BAY:加州交通运输机构的 PEMS-BAY 数据集包含加州湾区高速公路上收集的真实速度数据。PEMS-BAY 数据集选择了由 2369 条道路连接的 325 个传感器,包含 2017 年 1 月 1 日到 2017 年 5 月 31 日的平均交通速度。包含的观测值总数为 52116 个。

传感器的数据被汇总成 5 分钟的窗口,按照时间顺序将这两个数据集的 70% 作为训练集,10% 作为验证集,20% 作为测试集。输入序列长度为 12,目标序列长度为 12。对于所选择的对比方法,使用成对路网距离作为预定义的图结构。表 1 提供了详细的数据集的统计信息。

表 1 METR-LA 和 PEMS-BAY 数据集的统计信息

Table 1 Statistics for METR-LA and PEMS-BAY datasets

数据集	节点数	边数	时间步
METR-LA	207	1515	34272
PEMS-BAY	325	2369	52116

4.2 实验参数设置

模型通过 Adam 优化器进行训练,学习率为 0.001, batch_size 为 64。每个时间卷积层的输出,使用 0.3 的 Dropout。在每个图卷积模块之后应用 Layernorm。混合跳跃传

播层的深度设置为 2。混合跳跃传播层的保留率设置为 0.05。图学习层激活函数的饱和率设为 3。节点嵌入的维度为 40。实验在 Intel(R) Xeon(R) Gold 6130 CPU 和 NVIDIA 1080TI GPU 上进行。

4.3 对比方法

将本文方法与以下 6 种现有的先进时间序列预测方法进行比较。

(1)ARIMA^[15]:(ICLR2018)基于卡尔曼滤波的自回归积分移动平均模型;

(2)FC-LSTM^[15]:(ICLR2018) LSTM 隐藏单元全连接的循环神经网络;

(3)DCRNN^[15]:(ICLR2018)一种扩散卷积递归神经网络,它将扩散图卷积和递归神经网络相结合;

(4)STGCN^[22]:(IJCAI 2018)一种时空图卷积网络,它包含了图卷积和一维卷积;

(5)GraphWaveNet^[22]:(IJCAI 2019)一种时空图卷积网络,该网络集成了扩散图卷积和一维扩张卷积;

(6)MTGNN^[3]:(KDD2020)一种用图神经网络进行多变量时间序列预测的模型。

4.4 实验结果与分析

将本文提出的一种基于时空全局上下文建模的交通预测模型在数据集 METR-LA 和 PEMS-BAY 上与上述 6 种基准方法进行了比较,表 2 列出了实验结果。

表 2 不同方法在数据集 METR-LA 和 PEMS-BAY 上的性能比较

Table 2 Performance comparison of different approaches on the METR-LA and PEMS-BAY dataset

Data	Method	15 min			30 min			60 min		
		MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
METR-LA	ARIMA	3.99	8.21	9.60	5.15	10.45	12.70	6.90	13.23	17.40
	FC-LSTM	3.44	6.30	9.60	3.77	7.23	10.90	4.37	8.69	13.20
	DCRNN	2.77	5.38	7.30	3.15	6.45	8.80	3.60	7.60	10.50
	STGCN	2.88	5.74	7.62	3.47	7.24	9.57	4.59	9.40	12.70
	Graph WaveNet	2.69	5.15	6.90	3.07	6.22	8.37	3.53	7.37	10.01
	MTGNN	2.69	5.18	6.86	3.05	6.17	8.19	3.49	7.23	9.87
	Ours	2.66	5.12	6.87	3.02	6.13	8.14	3.45	7.15	9.65
PEMS-BAY	ARIMA	1.62	3.30	3.50	2.33	4.76	5.40	3.38	6.50	8.30
	FC-LSTM	2.05	4.19	4.80	2.20	4.55	5.20	2.37	4.96	5.70
	DCRNN	1.38	2.95	2.90	1.74	3.97	3.90	2.07	4.74	4.90
	STGCN	1.36	2.96	2.90	1.81	4.27	4.17	2.49	5.69	5.79
	Graph WaveNet	1.30	2.74	2.73	1.63	3.70	3.67	1.95	4.52	4.63
	MTGNN	1.32	2.79	2.77	1.65	3.74	3.69	1.94	4.49	4.53
	Ours	1.32	2.76	2.78	1.63	3.68	3.64	1.92	4.42	4.49

首先,进行性能比较分析,将对未来 15min,30min,60min 的速度的预测值与观测值之差转换成平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)评价指标。指标定义如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (11)$$

$$MAPE = 100\% \times \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (13)$$

本文引用了文献公开的 ARIMA,FC-LSTM,DCRNN 结果,以及文献公开的 STGCN,Graph WaveNet,MTGNN 的结果。表 2 列出了不同方法在 MTER-LA 和 PEMS-BAY 数据集上进行未来 15min,30min 和 60min 的预测性能比较。相

比之下,传统的时间序列分析方法 ARIMA 由于模型的局限性,无法处理复杂的交通流数据而预测误差最大。另外,我们可以观察到深度学习方法优于传统的时间序列方法。其中在深度学习方法中,STGCN,DCRNN,Graph WaveNet,MTGNN 因为同时对空间和时间维度进行建模,性能普遍优于 FC-LSTM。本文提出的模型由于对局部信息的捕获还有所不足,所以在对 PEMS-BAY 数据集未来 15min 预测的性能上还略微欠缺,但是在其他预测长度的表现均达最先进的预测性能。通过 T-Pool Attention 捕获了长距离依赖信息后,其中在长时间(未来 60min)的预测性能提升更为明显,这表明了 T-Pool Attention 有效地增强了模型性能。

本文选取了 METR 测试集中的 300 个真实值与预测值进行对比,如图 4 所示。可以明显看出模型对真实值的拟合程度还是可观的。




图 4 METR-LA 测试集中 300 个真实值与预测值的对比

Fig. 4 Comparison of 300 real and predicted values were selected in METR-LA test set

此外,实验还分析了 T-Pool 机制中对通道数进行不同方式的压缩对模型性能的影响,并且选取了在 METR-LA 数据集的实验结果对比。图 5 给出了实验结果的 MAE 以及 RMSE 值的对比。可以看出,使用最大值、平均值、最小值进行压缩对实验评价指标 MAE 以及 RMSE 值有了明显的提




图 5 不同通道压缩方式的实验结果对比

Fig. 5 Experimental results comparison of different channel methods are compared

表 3 不同注意力机制在数据集 METR-LA 上的性能比较

Table 3 Performance comparison of different attention mechanisms in data set METR-LA

Attention	15 min		30 min		60 min		Computation Time/ (s/epoch)
	MAE	RMSE	MAE	RMSE	MAE	RMSE	
GCNet	2.71	5.21	3.12	6.34	3.59	7.44	40
Triplet attention	2.68	5.16	3.03	6.09	3.46	7.12	56
T-Pool attention	2.66	5.12	3.02	6.13	3.45	7.15	40

结束语 本文提出一种基于双路信息时空图卷积网络的交通预测模型,该模型通过三重池化注意力对时空上下文信息建模,同时挖掘了时空图变量隐藏的关联关系,并将三重池化注意力、图卷积层和时间卷积层融合,形成的双路信息时空卷积层能更好地建模交通数据的复杂性,为交通流预测提供更准确的信息。在真实交通数据集上的实验对比表明,本文提出的模型的预测效果优于当前先进的交通数据预测方法,可以证明对于时空全局上下文信息的建模可以有效地捕获交通特征的长距离依赖信息。未来,随着图神经网络的发展,我们将进一步通过特征金字塔模型等策略来优化模型的网络结构,进一步提升模型的预测能力,实现更精准的交通预测。

参考文献

[1] ZHOU J, CUI G, ZHANG Z, et al. Graph neural networks: A review of methods and applications [J]. arXiv: 1812. 08434, 2018.

[2] ZHANG J, WANG F Y, WANG K, et al. Data-driven intelligent transportation systems: A survey [J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(4): 1624-1639.

[3] WU Z, PAN S, LONG G, et al. Connecting the Dots: Multivariate Time Series Forecasting with Graph Neural Networks [J]. arXiv: 2005. 11650, 2020.

升,说明 T-Pool 机制对模型性能的提升具有不可忽视的作用。

最后,为了比较不同注意力机制对双路信息时空卷积层的影响,本文选取了现有先进的模型 GCNet 和 Triple attention 与本文的 T-Pool attention 进行实验比较。表 3 列出了各个注意力机制在 METR-LA 数据集中预测未来 15 min, 30 min 和 60 min 的评价指标 MAE, RMSE 以及计算时间。GCNet 由于对通道依赖捕获还不够,实验效果最差。Triplet attention 效果优于 GCNet,但效果也不及 T-Pool attention,并且单次迭代的训练时间也增加了 16 s,大大消耗了计算开销。T-Pool Attention 机制将通道进行缩放可以让感受野放大,尽可能从全局区域捕获更多边缘的语义信息,所以在长距离依赖的建模上更为有效。从表 3 可以看出,本文模型在两个数据集上的实验结果相比于以往的先进模型更优。

[4] CAO Y, XU J, LIN S, et al. Gcnet: Non-local networks meet squeeze-excitation networks and beyond [C] // Proceedings of the IEEE International Conference on Computer Vision Workshops, 2019.

[5] YANG B, KANG Y, LI H, et al. Spatio-temporal expand-and-squeeze networks for crowd flow prediction in metropolis [J]. IET Intelligent Transport Systems, 2020, 14(5): 313-322.

[6] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate [J]. arXiv: 1409. 0473, 2014.

[7] WILLIAMS B M, HOEL L A. Modeling and forecasting vehicular traffic flow as a seasonal arima process: Theoretical basis and empirical results. Journal of Transportation Engineering, 2003, 129(6): 664-672.

[8] CHENG S, LU F, PENG P, et al. Short-term traffic forecasting: An adaptive ST-KNN model that considers spatial heterogeneity [J]. Computers Environment and Urban Systems, 2018, 71 (SEP.): 186-198.

[9] DU L, PEETA S, KIM Y H. An adaptive information fusion model to predict the short-term link travel time distribution in dynamic traffic networks [J]. Transportation Research Part B Methodological, 2012, 46(1): 235-252.

- [16] LIU H W, WANG G J, Continuity of triple I methods based on several implications[J]. *Comput. Math. Appl.*, 2008, 56: 2079-2087.
- [17] JENEI S. Continuity in Zadeh's compositional rule of inference [J]. *Fuzzy Sets and Systems*, 1999, 104(2): 333-339.
- [18] LUO M X, YAO N. Triple I algorithms based on Schweizer-Sklar operators in fuzzy reasoning[J] *Int. J. Approx. Reason.*, 2013, 54: 640-652.
- [19] DAI S S, PEI D W, WANG S M. Perturbation of fuzzy sets and fuzzy reasoning based on normalized Minkowski distance[J]. *Fuzzy Sets Systems*, 2012, 189: 63-73.
- [20] HU B Q. Fuzzy theoretical basis[M]. Wuhan: Wuhan University Press, 2008.
- [21] HONG D H, WANG S Y. A note on the value similarity of fuzzy systems variables[J]. *Fuzzy Sets and Systems*, 1994, 66(3): 383-386.

- [22] RUDIN W. Real and Complex Analysis[M]. Beijing: China Machine Press, 2006: 61-64.



KANG Bo, born in 1995, postgraduate. His main research interests include fuzzy reasoning and so on.



PAN Xiao-dong, born in 1979, associate professor. His main research interests include mathematical basic theory of fuzzy information processing and so on.

(上接第 51 页)

- [10] FENG N, GUO S N, SONG C, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting [J]. *Journal of Software*, 2019(3): 759-769.
- [11] MA X, YU H, WANG Y, et al. Large-scale transportation network congestion evolution prediction using deep learning theory [J]. *PLoS one*, 2015, 10(3): e0119044.
- [12] YU R, LI Y, SHAHABI C, et al. Deep learning: A generic approach for extreme condition traffic forecasting [C] // Proceedings of the 2017 SIAM international Conference on Data Mining. Society for Industrial and Applied Mathematics, 2017: 777-785.
- [13] SUN S, HUANG R, GAO Y. Network-Scale Traffic Modeling and Forecasting with Graphical Lasso and Neural Networks[J]. *Journal of Transportation Engineering*, 2012, 138(11): 1358-1367.
- [14] YU H, WU Z, WANG S, et al. Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks[J]. *Sensors*, 2017, 17(7): 1501.
- [15] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting[J]. *arXiv: 1707. 01926*, 2017.
- [16] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[J]. *arXiv: 1709. 04875*, 2017.
- [17] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7794-7803.
- [18] HUANG Z, WANG X, HUANG L, et al. Ccnet: Criss-cross attention for semantic segmentation[C] // Proceedings of the IEEE International Conference on Computer Vision. 2019: 603-612.
- [19] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7132-7141.

- [20] HU J, SHEN L, ALBANIE S, et al. Gather-excite: Exploiting feature context in convolutional neural networks[C] // Advances in Neural Information Processing Systems. 2018: 9401-9411.
- [21] ZHAO H, ZHANG Y, LIU S, et al. Psanet: Point-wise spatial attention network for scene parsing[C] // Proceedings of the European Conference on Computer Vision (ECCV). 2018: 267-283.
- [22] WU Z, PAN S, LONG G, et al. Graph WaveNet for Deep Spatial-Temporal Graph Modeling [C] // Twenty-Eighth International Joint Conference on Artificial Intelligence IJCAI-19. 2019.
- [23] MISRA D, NALAMADA T, ARASANIPALAI A U, et al. Rotate to Attend: Convolutional Triplet Attention Module[J]. *arXiv: 2010. 03045*, 2020.
- [24] SHEN X J, ZHANG J T, HANG D J. Short-term Traffic Flow Prediction Model Based on Gradient Boosting Regression Tree [J]. *Computer Science*, 2018, 45(6): 222-227, 264.
- [25] WOOS, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C] // Proceedings of the European Conference on Computer Vision (ECCV). 2018: 3-19.



KANG Yan, born in 1972, Ph.D, associate professor. Her main research interests include transfer learning, deep learning and integrated learning.



LI Hao, born in 1970, Ph.D, professor. His main research interests include distributed computing, grid and cloud computing.