

控制与决策

Control and Decision

基于时空图卷积循环神经网络的交通流预测

谷振宇, 陈聪, 郑家佳, 孙棣华

引用本文:

谷振宇, 陈聪, 郑家佳, 等. 基于时空图卷积循环神经网络的交通流预测[J]. *控制与决策*, 2022, 37(3): 645–653.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1445>

您可能感兴趣的其他文章

Articles you may be interested in

基于生成对抗网络的大规模路网交通流预测算法

Traffic flow forecasting algorithm for large-scale road network based on GAN

控制与决策. 2021, 36(12): 2937–2945 <https://doi.org/10.13195/j.kzyjc.2020.0333>

基于卷积长短时记忆神经网络的城市轨道交通短时客流预测

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925–932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

区分交通模式的混合服务路口信号控制策略

Signal control strategies of mixed service intersections to discriminate traffic flow patterns

控制与决策. 2021, 36(6): 1509–1515 <https://doi.org/10.13195/j.kzyjc.2019.1520>

基于时空图卷积循环神经网络的交通流预测

谷振宇^{1†}, 陈 聪¹, 郑家佳², 孙隽华¹

(1. 重庆大学 自动化学院, 重庆 400044; 2. 重庆城市管理职业学院 商学院, 重庆 401331)

摘要: 针对交通流预测模型中路网空间结构刻画和交通流时空特性挖掘不充分的问题, 构建一种新型的有向时空图, 通过定义节点相对临近度来表征路网结构关系, 通过学习邻域节点对预测节点的影响权重来表征节点间时空维度的作用关系, 从而能更好表达交通流的时空特性. 将时空图作为预测模型的输入, 采用图卷积获取交通流数据空间依赖关系, 采用门控循环神经网络获取交通流数据的时空依赖关系, 建立一种基于时空图卷积循环神经网络的交通流预测模型 (STG-CRNN). 在美国公路交通数据集上对模型预测效果进行验证, 其结果表明: STG-CRNN 模型的预测结果在平均绝对误差、均方根误差和平均绝对百分误差方面, 均优于自回归移动平均模型、门控循环单元模型, 以及扩散卷积循环神经网络模型.

关键词: 交通流预测; 有向时空图; 相对临近度; 时空依赖性; 图卷积网络; 循环神经网络

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1445

开放科学(资源服务)标识码(OSID):



引用格式: 谷振宇, 陈聪, 郑家佳, 等. 基于时空图卷积循环神经网络的交通流预测[J]. 控制与决策, 2022, 37(3): 645-653.

Traffic flow prediction based on STG-CRNN

GU Zhen-yu^{1†}, CHEN Cong¹, ZHENG Jia-jia², SUN Di-hua¹

(1. School of Automation, Chongqing University, Chongqing 400044, China; 2. School of Business Administration, Chongqing City Management College, Chongqing 401331, China)

Abstract: Aiming at the problem of insufficient characterization of road network spatial structure and inadequate mining of traffic flow spatiotemporal characteristics in the traffic flow prediction model, a new type of directed spatiotemporal graph is constructed. In which the spatial relationship between nodes are characterized by defining the relative proximity, and the spatiotemporal relationship between nodes are characterized by learning the influence weights of neighborhood nodes on the prediction node, so as to better express the temporal and spatial characteristics of traffic flow. Taking spatiotemporal graphs as the input of the prediction model, graph convolution is used to obtain the spatial dependence of traffic flow data, and the gated recurrent neural network is used to obtain the spatiotemporal dependence of traffic flow data, and a traffic flow based on the spatiotemporal graph convolution recurrent neural network (STG-CRNN) is established. The model prediction effect is verified on the U.S. highway traffic data set, and the results show that the STG-CRNN model is better than the autoregressive moving average model, the gated recurrent unit model, and the diffusion convolutional recurrent neural network model in terms of the mean absolute error, root mean square error, and mean absolute percentage error.

Keywords: traffic flow prediction; directed spatiotemporal graph; relative proximity; temporal and spatial dependencies; graph convolutional network; recurrent neural network

0 引言

随着城市机动车保有量的迅速增加, 有限的道路资源与快速增长的交通需求之间不平衡的问题日益凸显. 这一问题不仅使交通拥堵和交通事故的发生日益严重, 而且极大地制约了交通运输业和物流行业的发展. 通过交通流预测, 实现交通动态诱导, 对于缓

解此类交通问题, 提升交通系统运行效率和主动防控能力具有重要作用.

交通流预测, 即基于历史和当前的交通流数据对未来一段时间内的交通能力进行预测. 早期的预测方法主要是将历史交通量的平均值作为预测值对交通流进行预测. 交通流是随时间动态变化的, 而

收稿日期: 2020-10-20; 录用日期: 2021-01-11.

基金项目: 国家自然科学基金项目(62073049); 重庆市教委科学技术研究项目(KJQN202003303).

责任编辑: 郭戈.

[†]通讯作者. E-mail: gzy@cqu.edu.cn.

历史平均模型不能很好地适用于时间序列的动态变化,因此学者们进一步提出了卡尔曼滤波模型^[1]、指数平滑模型^[2]和自回归移动平均模型 (autoregressive integrated moving average model, ARIMA)^[3]等统计学预测模型. 其中,因为 ARIMA 模型对规律性较强的平稳序列的预测能力比较好,所以 ARIMA 模型是统计学预测模型应用较为广泛的一种方法^[4-5]. 然而,这类统计学方法大多是基于一定的线性假设,对交通流的非线性特征表征能力不足,因此其预测精度较差. 支持向量机回归 (support vector regression, SVR)^[6]、 K 邻近^[7]和贝叶斯网络^[8]等机器学习方法能够对交通数据进行特征工程建模,挖掘数据中的非线性关系,从而使预测精度获得较大的提升. 但是,机器学习的方法需要构建特征工程,而构建合理的特征工程是一项困难而复杂的工作,因此在提升预测精度方面仍存在一定问题. 深度学习方法为交通流预测领域的研究带来了新的机遇,与基于统计学习和机器学习方法的预测模型相比,深度学习可以对多维特征进行建模,通过学习深层的非线性网络结构来实现复杂函数的逼近,可以更好地学习交通流内在丰富的变化规律,模拟其复杂非线性关系,极大提高交通流预测精度^[9-10]. 文献[11]提出了长短期记忆网络 (long short-term memory networks, LSTM) 应用于交通流预测,该模型利用 LSTM 捕获交通流数据中的长期时间依赖性的特征,能够更好地表征交通流的非线性,使之达到更好的预测结果. 文献[12]构建了基于 LSTM-RNN 的快速路短时交通流预测模型,通过重构时间序列,并根据预测精度自适应更新训练模型. 文献[13]将基于门控循环单元 (gated recurrent unit, GRU) 的递归神经网络应用于交通流预测,由于内部结构少一个门控单元,比 LSTM 更简单. 文献[14]研究选取 GRU 中最佳门控循环单元的个数来进行交通流预测并获得了良好的预测性能,由于交通流数据不仅在时间上具有依赖性,在空间上也具有较强的依赖性,仅从时间维度进行分析在提高预测精度上具有一定局限性. 为了更加充分地挖掘数据的时间和空间依赖性,文献[15]提出的将卷积和循环神经网络相融合的 Conv-LSTM 预测模型,取得了很好的预测效果. 文献[16]提出一种扩散卷积循环神经网络 (DCRNN) 模型,分别使用扩散卷积和循环神经网络在有向图上分别捕获交通流的空间和时间依赖性,通过实验结果表明该模型比经典方法具有更好的预测精度. 文献[17]提出了一种基于图卷积网络 (graph convolutional network, GCN) 和门控递归单

元 (GRU) 的组合预测方法,利用 GCN 学习复杂的拓扑结构来学习空间依赖关系,利用 GRU 学习交通数据的动态变化来捕获时间依赖性. 文献[18]提出基于信息熵的灰色关联分析提取交通流空间依赖性,并采用双层循环神经网络实现快速车道级速度预测.

车辆在城市道路网络上汇聚形成交通流,交通流的形成、扩散过程和交通状态演化过程与路网结构密切相关,因此路网结构关系的刻画以及表征结构关系权重的确定是影响交通流预测精度的重要因素. 现有研究在权重的设计方面,主要是以简单的逻辑关系 (0 或 1) 或由以距离为计算标准的高斯核来表征,连通关系则是认为无向连接的,这种权重和连通关系的设计对路网的空间结构刻画能力不足. 同时,受天气、车辆事故、临时交通措施等复杂的实际情况制约使得交通系统具有时空强耦合的特性. 这种特性,在时空维度上由交通事件演化时间的作用,使得某一节点的交通流量会受到历史时刻相互连通节点交通流量的影响. 例如,某一节点受交通事故影响,会经过一定时间后才能传导并作用于其他节点. 现有研究在时空依赖性的挖掘上采用的是分别提取交通数据的时间和空间依赖性之后,再进行融合计算,而没有考虑时空维度上空间交通事件对其他节点的影响存在时间滞后的现象,使得对交通数据中的时空特性挖掘不充分.

针对上述问题,本文构建一种新型的有向时空图,用节点的有向连通来刻画路网结构的有向性,通过定义节点相对临近度表征路网结构关系的权重,通过学习历史时刻邻居节点对当前时刻预测节点的影响权重来表征邻居节点与预测节点间时空维度的作用关系,从而能更好表达交通流数据在时空维度上的依赖关系. 将时空图作为预测模型的输入,采用图卷积神经网络获取交通流数据空间依赖关系,采用门控循环神经网络获取交通流数据的时空依赖关系,最终得到交通流预测模型 (spatiotemporal graph-convolutional recurrent neural network STG-CRNN). 该模型在公开的美国公路交通数据集上进行了实验,结果表明 STG-CRNN 模型的预测结果在平均绝对误差、均方根误差和平均绝对百分误差方面均优于基线模型.

1 基于 STG-CRNN 的交通流时空预测方法

1.1 交通路网时空图构建

充分考虑交通流时空特性和交通状态的时空演化过程,是提高预测精度的关键. 交通流的形成、扩散

过程和交通状态演化过程与路网结构密切相关。

图1是一段城市道路结构的示意图,图2是这段道路通行速度的可视化表示. 结合图1和图2可以看到,虽然A点到B点距离较近,但它们的通行速度和变化趋势差异很大;C点和D点到A点的距离相近,但从它们各自的通行速度和变化趋势中可以得出C点和D点对A点的交通流状态的影响是不同的. 这些示例说明,道路的有向性、路网节点间的结构及其相互作用关系对挖掘路网空间相关性和时空依赖性具有重要作用。




图1 路网中检测节点的结构




图2 道路(图1中所示)通行速度的可视化表达

鉴于此,本文根据节点相对临近度来确定节点间的权重,并以此刻画节点间相互影响程度. 在此基础上,结合路网的有向性,构建表征路网结构关系的空间图. 在空间图上引入时间维度,从而构成时空图。

t_1 时刻空间图 G_{t_1} 可以表述为 $G_{t_1} = (\nu, \varepsilon, A)$,其中: $\nu = \{\nu_i | i = 1, 2, \dots, n\}$ 是图 G_{t_1} 中检测节点 ν_i 的集合, $\varepsilon = \{(\nu_i, \nu_j) | \nu_i, \nu_j \in \nu\}$ 表示图 G_{t_1} 中有向边集合, (ν_i, ν_j) 表示从节点 ν_i 到节点 ν_j 的交通流向,且 $(\nu_i, \nu_j) \neq (\nu_j, \nu_i)$;A为权重连接矩阵, A_{ij} 表示节点 ν_i 到节点 ν_j 的权重信息。

$$\begin{cases} G_{t_1} = (\nu, \varepsilon, A), \\ \nu = \{\nu_i | i = 1, 2, \dots, n\}, \\ \varepsilon = \{(\nu_i, \nu_j) | \nu_i, \nu_j \in \nu\}, \\ A = \{A_{ij} | (\nu_i, \nu_j) \in \varepsilon\}. \end{cases} \quad (1)$$

采用带有阈值的高斯核来计算两点的权重值,即

$$w_{ij} = \begin{cases} \exp\left(-\frac{\text{dist}(\nu_i, \nu_j)^2}{\delta^2}\right), & j \in k(i); \\ 0, & \text{otherwise.} \end{cases} \quad (2)$$

其中: $\delta^2 = \frac{1}{nk} \sum_{i=1}^n \sum_{j \in k(i)} \text{dist}(\nu_i, \nu_j)^2$, $k(i)$ 表示当

$\text{dist}(\nu_i, \nu_j) \leq \gamma$ 时,节点 ν_i 的 k 个邻域节点的集合, $\text{dist}(\nu_i, \nu_j)$ 为节点 $\nu_i \rightarrow \nu_j$ 的欧氏距离, γ 为设置的阈值,当两个节点的距离超出阈值 γ 的大小,则代表两节点的权重系数为0,无依赖性。

由式(2)可知,欧氏距离相等的两节点的权重相同,该权重体现的是两节点在整个路网图的临近程度. 而在实际交通网络中,在两个节点(假设为 M, N)与某个节点(假设为 O)欧氏距离相等的情况下,由于 M 和 N 的邻域节点的数目不同,使得它们与 O 的临近度有差异. 式(2)仅从全局信息的角度定义两点的临近度,未考虑到这种差异. 为此,两节点的相对临近度定义如下:

$$A_{ij} = \frac{1}{k+1} \sum_{\nu \in [k(i), i]} \omega_{\nu j}, \quad i \neq j. \quad (3)$$

其中 A_{ij} 表示节点 ν_i 到节点 ν_j 的权重值. 通过分析式(2)和(3)可知,两节点的临近度与如下因素相关:1)两节点的欧氏距离;2)整个路网图的节点集合;3)两节点的局部邻域节点。

在空间图上引入时间维度获得交通路网时空图,在时间区间 t ,路网时空图 G 上观测到的路网交通流量表示为 X^t ,且 $X^t \in \mathbf{R}^{n \times r}$. 其中: N 为图 G 的节点数, r 为采集到的每个节点交通流的特征维数. 交通路网时空图如图3所示。




图3 交通路网时空图

在空间维度上,节点 ν_i 的交通流量直接受到邻域节点的影响(如图3中标号1);在时间维度上,节点 ν_i 的交通流量受到历史时刻交通流量的影响(如图2中标号2);在时空维度上,由于交通状态演变的原因,节点 ν_i 的交通流量受到历史时刻周围邻域节点的影响(如图3中标号3)。

交通流预测问题可以表述为:通过学习映射函数 $f(\cdot)$,作用于 T' 周期内图 G 的历史交通流数据,输出未来 T 周期在时空图 G 上的交通流量预测,即

$$\begin{aligned} [\hat{X}^{t+1}, \dots, \hat{X}^{t+T}] = \\ f([\hat{X}^{t-T'+1}, \dots, \hat{X}^t]; G; \theta). \end{aligned} \quad (4)$$

其中: $\hat{X}^{t+1}, \hat{X}^{t+T}$ 为在时间区间 $t+1, t+T$ 的预测值; θ 为函数 $f(\cdot)$ 的参数;时间区间 t 为在数据预处理

理阶段,对时间进行分段划分的时间区间,假设时间区间的长度为5 min,时间区间 $t = 1$ 代表时间间断[00:00, 00:05].

基于时空图的交通流预测框架由3个模块组成:时空图结构,Encoder层和Decoder层.如图4所示,交通流预测过程可以描述为:

step 1: 根据路网结构关系特征构建交通路网时空图;

step 2: 将时空图结构及交通流数据输入到Encoder层自动提取交通流时空依赖性;

step 3: 将Encoder层得到的编码状态输入Decoder层解码,获得该时间序列下一周期的预测值.




图4 基于时空图的交通流预测框架

1.2 STG-CRNN模型

1.2.1 空间依赖性建模

交通流的空间依赖性表现在某时刻检测节点的交通流受到上下游及相邻检测节点交通流的影响.在学习路网交通流发散过程基础上,通过在空间图上进行带权重的双向随机游走来实现对交通流扩散过程的模拟并构建卷积层用于交通流数据空间依赖性的捕获.

在空间图 G_{t_1} 上,构造重启概率 α ($\alpha \in [0, 1]$)和进行随机漫步^[19]的状态转移矩阵 $(\text{diag}(AI))^{-1}A$,其中 I 是单位矩阵, $I \in \mathbf{R}^{n \times n}$.在经过多次的状态转移后,根据马尔科夫特性,可以收敛于一个稳定的分布 $\chi \in \mathbf{R}^{n \times n}$.其中 $\chi_{i,:}$ 为矩阵 χ 第 i 行, $\chi_{i,:} \in \mathbf{R}^n$,其数值代表路径中设置的第 i 个区间划分节点,且 ν_i 向其他节点发散的概率值,其分布计算公式如下:

$$\chi = \sum_{k=0}^{\infty} ((\text{diag}(AI))^{-1}A)^k \alpha (1-\alpha)^k. \quad (5)$$

其中: k 是状态转移步数,本文使用 k 步作为扩散过程上限并为每一步分配一个可训练的权重.实现扩散过程后,在空间图 G_{t_1} 上对交通状态 $X_{:,r}^t \in \mathbf{R}^{n \times R}$, $r \in \{1, 2, \dots, R\}$ 进行双向随机游走来构成卷积运算.令状态转移方程为 $D_p = (\text{diag}(AI))^{-1}A$,其反向的状态转移方程为

$$D_r = (\text{diag}(AI))^{-1}A^T, \quad (6)$$

则交通状态 $X_{:,r}^t \in \mathbf{R}^{n \times R}$ 和滤波器 $f(\theta)$ 的双向卷积计算为

$$X_{:,r}^t * f(\theta) = \sum_{k=0}^{K-1} (\theta_{k,1} D_p + \theta_{k,2} D_r) X_{:,r}^t. \quad (7)$$

其中: $\theta \in \mathbf{R}^{K \times 2}$ 为滤波器 $f(\theta)$ 的参数;卷积层的输入为交通状态 $X_{:,r}^t \in \mathbf{R}^{n \times R}$,其输出为预测结果 $Y \in \mathbf{R}^{N \times O}$, O 为其输出数据的特征维度.输入到输出的卷积层计算为

$$Y_{:,o} = \sigma \left(\sum_{r=1}^R X_{:,r}^t * f(\theta) \right). \quad (8)$$

其中: $o \in \{1, 2, \dots, O\}$ 代表输出层的特征维度,与 R 相对应; $f(\theta)$ 为滤波器; $\sigma(\cdot)$ 为激活函数.此卷积层用于学习交通流数据的空间依赖性.本文选取 $k=2$,即在预测节点进行2步的随机游走来获取预测节点周围的空间关联关系,当 k 再进行增大时导致整个模型参数的爆炸和游走过程中很可能多次游走过同一节点带来的信息冗余.

1.2.2 时空依赖性建模

从时间维度上看,交通流数据本质上是一个时间序列数据.道路交通状况在时间尺度上呈周期性、相关性和时变性的特点.交通流的时间依赖性表现在某时刻某节点的交通流数据受历史时刻交通流数据的影响;从时空的角度看,某时刻某节点的交通流数据也受到历史其邻域节点交通数据的影响.因此,选择循环神经网络(RNN)中结构简单、易于计算且能够处理传统RNN梯度消失等问题的门控循环单元(GRU)对时间序列进行建模.通过改进GRU的输入结构来对交通时延现象进行刻画,改进GRU的具体结构如图5所示.

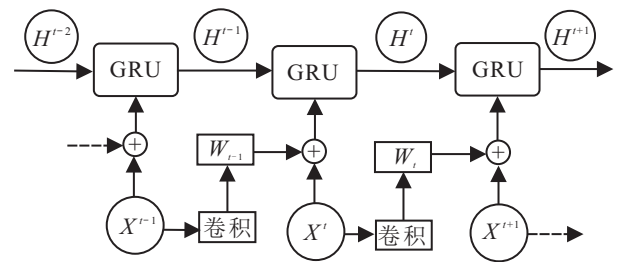


图5 GRU的结构

图5中 ω_t, ω_{t-1} 为 t 和 $t-1$ 时刻的权重矩阵, $\omega_t, \omega_{t-1} \in \mathbf{R}^{n \times n}$,其中直接与预测节点有连通关系的节点值设置为可学习的参数,其余节点权重为0.将上一时刻的数据进行卷积运算,然后与权重矩阵相乘,用以筛选出对当前时刻预测节点有影响的历史节点数据,并将结果与当前时刻的数据一同输入GRU单元.这样在时空维度将与预测节点关联程度更紧密的节点信息保留下来,增强对交通流数据时空关系的学习能力.

GRU通过引入更新门和重置门对交通状态信息传递进行控制. 更新门用于控制前一时间段的交通状态信息被带入到当前状态中的程度, 而重置门决定了如何将当前的状态信息与前面的信息相结合. 本文利用GRU模型来获取交通流的时空特性, 将重置门和更新门原来的矩阵乘积改为矩阵之间的卷积, 将GRU单元的输入改为由上一时刻预测节点的直接连通节点, 做带权重的卷积并同当前时刻的输入相加, 其中一个GRU单位具体计算如下.

输入

$$\hat{X}^t = A \odot X^t + \omega_{t-1} \odot A \odot X^{t-1}. \quad (9)$$

重置门

$$r^t = \sigma(W_r * \mathcal{G}[\hat{X}^t, H^{t-1}] + b_r). \quad (10)$$

更新门

$$u^t = \sigma(W_u * \mathcal{G}[\hat{X}^t, H^{t-1}] + b_u). \quad (11)$$

候选状态

$$\tilde{H}^t = \tanh(W_{\tilde{h}} * [r^t \odot H^{t-1}, \hat{X}^t] + b_{\tilde{h}}). \quad (12)$$

隐藏状态

$$H^t = (1 - u^t) \odot H^{t-1} + u^t \odot \tilde{H}^t. \quad (13)$$

输出

$$Y^t = \sigma(W_o \odot H^t). \quad (14)$$

其中: * 是对应空间建模中的卷积操作; \odot 是对应矩阵的乘积; $[]$ 表示将两个向量相连; $W_r, W_u, W_{\tilde{h}}, W_o$ 是对应滤波器的矩阵参数; $b_r, b_u, b_{\tilde{h}}$ 是对应滤波器的偏置; $\sigma(\cdot)$ 为 sigmoid 激活函数, \tanh 为激活函数; X^t 表示该时刻的输入, X^{t-1} 表示上一时刻的输入, \hat{X}^t 表示该时刻汇聚了历史信息的状态; H^{t-1} 表示上一时刻的隐藏状态; \tilde{H}^t 表示该时刻的候选状态, H^t 表示该时刻的隐藏状态; Y^t 表示该时刻的输出.

对于未来长时间的多步预测, 采用 Encoder-Decoder 的机制进行对序列-序列数据的处理. 构建一个编码器和一个解码器. 在对模型的训练过程中, 利用周期数据训练编码器, 其输出是解码器的初始状态, 经过解码器输出最终的预测值. 其中 SG-CRNN 模块是模型的关键结构, 如图6所示, SG-CRNN 集成




图6 SG-CRNN模块

上文中所提出的空间依赖性建模方法和时空依赖性建模方法, 通过对这一时刻输入和上一时刻隐藏状态进行卷积之后得到新的状态 X'_t , 经过更新门 u^t 和重置门 r^t 输出这一时刻的隐藏状态和输出.

2 实验设计与验证

2.1 数据集描述

为了验证模型的有效性, 需要在较大规模的数据集上进行验证, 选取美国公路交通数据集 METR-LA^[20] 和 PEMS-BAY^[21] 进行实验验证. 其中: METR-LA 包含 6 519 002 条交通速度数据以及采集这些信息的 207 个检测节点的地理位置信息; PEMS-BAY 包含 16 937 179 条交通速度数据以及采集这些信息的 325 个检测节点的地理位置信息.

2.2 对比基线模型

为了对比分析预测模型的预测效果, 选择在交通流预测中应用较为广泛、比较有代表性的预测模型, 包括 HA、ARIMA、SVR、GRU 和 DCRNN 作为对比基线模型. 这些基线模型是参考对应文献进行构建, 其模型参数是在本文选取数据集上进行训练优化后得到. 这些基线模型如下:

1) HA, 又称历史均值法, 通过历史交通流量的平均值预测下一时间段的交通量.

2) ARIMA, 自回归移动平均模型, 是一种经典时间序列预测方法, 参考文献[3]进行构建.

3) SVR, 支持向量回归模型, 参考文献[6]进行构建, 其主要模型参数包括: 径向函数是高斯核函数, 惩罚系数是 $1e3$, 宽度系数是 0.01 .

4) GRU, 门控循环单元网络, 参考文献[13]进行构建, 其主要模型参数包括: 隐藏单元数目是 64, 梯度下降算法 Adam (adaptive moment estimation), 输入时间步长是 12.

5) DCRNN, 扩散卷积循环神经网络, 参考文献[16]进行构建, 其主要模型参数包括: 隐藏单元数目 64, 梯度下降算法 Adam (adaptive moment estimation), 输入时间步长是 12.

6) STG-CRNN (Unitmatrix), 表示将邻接矩阵连接点权重设置为 0 或 1, 并运用本文时空建模方法进行预测.

2.3 评价指标设计

为了验证模型的有效性并对预测结果进行对比分析, 参考文献[3, 6, 13, 16]中采用的评价指标, 选取平均绝对误差 (MAE)、均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 作为实验验证评价指标. 其中: 平均绝对误差 (MAE) 的作用是评价多次实验的

预测结果与观测值的平均误差情况,它能解决预测结果分析中偏差相互抵消的问题,可以直观地反映预测结果误差的实际情况和模型总体预测效果;均方根误差(RMSE)的作用是评价多次实验的预测结果偏离观测值的变化程度,它能较好地反映预测模型的精确度;平均绝对百分比误差(MAPE)作用是评价多次实验预测结果与观测值的符合程度,它能较好地反映预测模型的准确度.这些评价指标的计算公式如下:

1) 平均绝对误差

$$MAE(y_i, \hat{y}_i) = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)|; \quad (15)$$

2) 均方根误差

$$RMSE(y_i, \hat{y}_i) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (16)$$

3) 平均绝对百分比误差

$$MAPE = \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) \cdot \frac{100}{n}. \quad (17)$$

其中: y_i 为观测值, \hat{y}_i 为预测值.

2.4 模型参数

为了便于进行模型训练和验证,以8:2的比例将数据集划分为训练集和测试集.模型的超参数包括学习率(learning rate),批量大小(batch),训练迭代次数(epoch)和GRU单元中的隐藏神经元个数.其中:学习率决定了权值更新的速度,批量大小为训练过程中一次处理的训练样本个数,根据经验和重复实验中的调整,学习率设置为0.001,批量大小设置为64;训练迭代次数表示在一个训练数据集上反复实验的次数,在实验中发现,基于本文搭建的训练平台,当在METR-LA训练集上迭代80次时3类指标趋于稳定,在PEMS-BAY训练集上迭代至150次时3类指标趋于稳定,因此,在METR-LA数据集进行实验时,迭代次数设置为100,在PEMS-BAY数据集进行实验时,迭代次数设置为170.

由于GRU单元中的隐藏神经元个数表征过去时刻信息汇聚维度的大小,它对整个模型的预测精度影响较大,可通过对比实验分析来确定GRU中的隐藏神经元个数.在数据集上设置GRU单元中隐藏神经元个数为[8, 16, 32, 64, 100, 128]来对比分析不同数目的神经元对指标的影响.

图7显示神经元数在64附近时, RMSE、MAPE、MAE的值最小.当神经元数小于64时,性能指标随着隐藏单元数的增加而减小;当神经元数大于64时,性能指标随着隐藏单元数的增加而增加.这是由于当隐藏单元增加到一定数目时,整个模型的参数爆炸

增长,模型复杂度变大的同时预测精度变低.因此,将GRU中的隐藏神经元数设置为64.




图7 隐藏神经元数对指标影响

2.5 实验结果与分析

基于谷歌的TensorFlow深度学习框架,在PyCharm开发环境中完成交通流预测模型的训练环境的搭建,用NVIDIA GeForce RTX 2080Ti进行训练和预测.在METR-LA和PEMS-BAY数据集上,运用STG-CRNN模型和前述的5种基线模型分别对未来15 min、30 min和1 h的交通流进行预测,表1展示了不同模型在两种数据集上的预测结果.由表1可以得出,STG-CRNN模型在两个数据集上的实验结果在三项评价指标的表现方面均优于基线模型.为了进一步分析STG-CRNN模型相较于基线模型的优越性,选取15 min的预测结果进行对比,各指标的性能提升如表2所示.

由表2可知,STG-CRNN比HA、ARIMA、SVR、GRU在两个数据集上预测未来15 min交通数据表现优越,尤其是在MAE指标大幅降低的同时,其他两类RMSE和MAPE同时也降低.这是因为HA、ARIMA、SVR、GRU这些传统的时间序列预测方法由于建模能力有限只能捕获交通数据时间上的相关性,而无法获取交通数据空间的相关性,在预测指标上表现得较差.这说明采用的空间建模方法和时间建模方法共同作用下,对交通数据进行训练学习能够捕获交通数据中隐藏的信息,从而进行预测运算能够达到更好的预测效果.

由表1和表2可知,STG-CRNN相较于DCRNN模型在不同数据集上不同预测步长都有着更好的预测结果.DCRNN和本文提出的STG-CRNN都考虑了时空依赖性,比仅用时间序列预测的方法表现出更好的预测能力.此外DCRNN模型是将卷积和循环以分步的方式进行特征提取,导致最后得到的交通流时空特征并不能充分融合.所以STG-CRNN的预测结果优于DCRNN.这说明同样基于图卷积神经网络,由于考虑了空间节点间作用关系的时间滞后效应,STG-CRNN能更充分挖掘路网结构的时空特性.

表1 STG-CRNN模型和基线模型的预测结果

| 数据集 | 时间区间 | 指标 | HA | ARIMA | SVR | GRU | DCRNN | STG-CRNN(unitmatrix) | 本文方法STG-CRNN |
|----------|--------|--------|-------|-------|-------|-------|-------|----------------------|--------------|
| METR-LA | 15 min | MAE | 4.15 | 4.02 | 4.37 | 3.08 | 2.77 | 2.79 | 2.66 |
| | | RMSE | 7.77 | 8.69 | 7.78 | 6.10 | 5.38 | 5.43 | 5.13 |
| | | MAPE/% | 12.9 | 9.39 | 10.08 | 8.19 | 7.30 | 7.36 | 6.77 |
| | 30 min | MAE | 4.15 | 5.09 | 5.40 | 3.78 | 3.15 | 3.11 | 3.06 |
| | | RMSE | 7.77 | 11.13 | 9.37 | 7.70 | 6.45 | 6.40 | 6.24 |
| | | MAPE/% | 12.9 | 12.21 | 12.75 | 10.49 | 8.80 | 8.75 | 8.29 |
| | 1 h | MAE | 4.15 | 6.79 | 6.50 | 4.90 | 3.6 | 3.63 | 3.53 |
| | | RMSE | 7.77 | 14.21 | 10.68 | 9.97 | 7.59 | 7.69 | 7.44 |
| | | MAPE/% | 12.90 | 16.71 | 15.84 | 14.20 | 10.50 | 10.55 | 10.03 |
| PEMS-BAY | 15 min | MAE | 2.88 | 1.6 | 1.74 | 1.4 | 1.38 | 1.39 | 1.31 |
| | | RMSE | 5.59 | 3.43 | 3.09 | 3.01 | 2.95 | 2.86 | 2.78 |
| | | MAPE/% | 6.76 | 3.24 | 3.59 | 2.94 | 2.90 | 2.93 | 2.74 |
| | 30 min | MAE | 2.88 | 2.18 | 2.33 | 1.88 | 1.74 | 1.74 | 1.65 |
| | | RMSE | 5.59 | 4.98 | 4.15 | 4.31 | 3.97 | 3.84 | 3.76 |
| | | MAPE/% | 6.76 | 4.65 | 5.02 | 4.33 | 3.90 | 3.91 | 3.72 |
| | 1 h | MAE | 2.88 | 3.05 | 2.92 | 2.48 | 2.07 | 2.12 | 1.97 |
| | | RMSE | 5.59 | 7.02 | 5.11 | 5.77 | 4.74 | 4.76 | 4.6 |
| | | MAPE/% | 6.76 | 6.84 | 6.46 | 6.34 | 4.90 | 4.98 | 4.69 |

表2 5种诊断方法的分类准确度

| 数据集 | 评价指标 | STG-CRNN与基线模型预测结果在不同指标下的对比 | | | | | |
|----------|------|----------------------------|-------------|-----------|-----------|-------------|----------------------------|
| | | 与HA相比提升了 | 与ARIMA相比提升了 | 与SVR相比提升了 | 与GRU相比提升了 | 与DCRNN相比提升了 | 与STG-CRNN(unitmatrix)相比提升了 |
| METR-LA | MAE | 35.90 | 33.83 | 39.13 | 13.63 | 3.97 | 4.66 |
| | RMSE | 33.98 | 40.97 | 34.06 | 15.90 | 4.65 | 5.52 |
| | MAPE | 47.52 | 27.90 | 32.83 | 17.33 | 7.26 | 8.01 |
| PEMS-BAY | MAE | 54.51 | 18.13 | 24.71 | 6.43 | 5.07 | 5.76 |
| | RMSE | 50.26 | 18.95 | 10.03 | 7.64 | 5.76 | 2.79 |
| | MAPE | 59.47 | 15.43 | 23.67 | 6.80 | 5.52 | 6.48 |




图8 各模型在METR-LA数据集上不同步长的预测结果对比




图9 各模型在PEMS-BAY数据集上不同步长的预测结果对比

由表2可知,STG-CRNN相较于STG-CRNN (unitmatrix)模型表现出更好的预测性能.这说明同样采用本文提出的时空图卷积循环神经网络方法,通过挖掘路网结构关系构建权重邻接矩阵,比以简单的逻辑关系设计权重能够更好地表征路网结构,预测精度更高,预测结果更接近真实值.

为了分析不同预测步长下各预测模型的表现,以5 min为一个预测时间间隔,累计增加预测步长,实验分析结果如图8和图9所示.

由图8和图9可以看出,从整体来看随着预测时长的增加,预测的误差呈现上升趋势,而STG-CRNN在不同的预测时长和3种评价指标MAE、RMSE、MAPE中都表现出较优的预测结果.

3 结论

本文针对现有研究对路网结构刻画不充分,交通流数据时空依赖性捕获能力不足的问题,提出了一种基于时空图融合卷积和循环神经网络的交通流预测模型(STG-CRNN).在美国公路交通数据集上进行实验验证,结果表明STG-CRNN模型的预测结果在平均绝对误差、均方根误差和平均绝对百分误差方面均优于基线模型.

通过对STG-CRNN交通流预测模型的研究和实验验证及效果的对比分析,可得出以下结论:

1) 通过定义检测节点相对临近度能够更加充分表征路网结构关系;

2) 在有向时空图中学习历史时刻邻居节点对当前时刻预测节点的影响权重,能够更加充分地挖掘路网结构中时空依赖性;

3) 通过构建有向时空图,分别进行空间依赖性和时空依赖性建模有助于挖掘交通流时空特性,从而得到更好的预测结果.

由于测试数据集只包含速度数据,实验中仅从交通状态中速度这个单一维度对预测模型进行测试和验证,模型对交通流多维度预测的能力尚需在后续研究中结合多维数据集进行实验验证.同时,由于缺乏国内城市交通流的数据集,模型仅在美国公开数据集上进行了实验验证,下一步需要收集国内城市交通流数据,进行算例分析与实验验证,进而完善预测模型,并检验模型对中国城市的适应性.

参考文献(References)

[1] 马云龙,王坚,任子晖.基于微观仿真的快速路短时交通流预测研究[J].系统仿真学报,2009,21(14): 4501-4503.

(Ma Y L, Wang J, Ren Z H. Research on short-term traffic flow prediction based on microcosmic simulation[J]. Journal of System Simulation, 2009, 21(14): 4501-4503.)

[2] 贾学力,焦帅,李建军.二次指数平滑在交通信息短期预测中的应用[J].公路交通科技,2011,28(S1): 101-104.
(Jia X L, Jiao S, Li J J. Application of quadric exponential smoothing model in short-term prediction of traffic information[J]. Journal of Highway and Transportation Research and Development, 2011, 28(S1): 101-104.)

[3] 邱敦国,杨红雨.一种基于双周期时间序列的短时交通流预测算法[J].四川大学学报:工程科学版,2013,5(5): 64-68.
(Qiu D G, Yang H Y. A short-term traffic flow forecast algorithm based on double seasonal time series[J]. Journal of Sichuan University: Engineering Science Edition, 2013, 5(5): 64-68.)

[4] 蔡昌俊,姚恩建,王梅英,等.基于乘积ARIMA模型的城市轨道交通进出站客流量预测[J].北京交通大学学报,2014,38(2): 135-140.
(Cai C J, Yao E J, Wang M Y, et al. Prediction of urban railway station's entrance and exit passenger flow based on multiply ARIMA model[J]. Journal of Beijing Jiaotong University, 2014, 38(2): 135-140.)

[5] 王振雷,唐苦,王昕.一种基于D-S和ARIMA的多模型软测量方法[J].控制与决策,2014,29(7): 1160-1166.
(Wang Z L, Tang K, Wang X. A multi-model soft sensing method based on D-S and ARIMA model[J]. Control and Decision, 2014, 29(7): 1160-1166.)

[6] 傅贵,韩国强,逯峰,等.基于支持向量机回归的短时交通流预测模型[J].华南理工大学学报:自然科学版,2013,41(9): 71-76.
(Fu G, Han G Q, Lu F, et al. Short-term traffic flow forecasting model based on support vector machine regression[J]. Journal of South China University of Technology: Natural Science Edition, 2013, 41(9): 71-76.)

[7] Van Lint H, Van Hinsbergen C. Short-term traffic and travel time prediction models[J]. Transportation Research Encircular, 2012, 22(1): 22-41.

[8] Zhu S L, Cheng L, Chu Z M. Bayesian network model for traffic flow estimation using prior link flows[J]. Journal of Southeast University: English Edition, 2013, 29(3): 322-327.

[9] Lv Y, Duan Y J, Kang W W, et al. Traffic flow prediction with big data: A deep learning approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 865-873.

[10] 郭戈,许阳光,徐涛,等.网联共享车路协同智能交通

- 系统综述[J]. 控制与决策, 2019, 34(11): 2375-2389.
(Guo G, Xu Y G, Xu T, et al. A survey of connected shared vehicle-road cooperative intelligent transportation systems[J]. Control and Decision, 2019, 34(11): 2375-2389.)
- [11] Shao H X, Soong B H. Traffic flow prediction with long short-term memory networks (LSTMs)[C]. 2016 IEEE Region 10 Conference (TENCON). Singapore, 2016: 2986-2989.
- [12] 王祥雪, 许伦辉. 基于深度学习的短时交通流预测研究[J]. 交通运输系统工程与信息, 2018, 18(1): 81-88.
(Wang X X, Xu L H. Short-term traffic flow prediction based on deep learning[J]. Journal of Transportation Systems Engineering and Information Technology, 2018, 18(1): 81-88.)
- [13] 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.
- [14] 刘明宇, 吴建平, 王钰博, 等. 基于深度学习的交通流量预测[J]. 系统仿真学报, 2018, 30(11): 4100-4105.
(Liu M Y, Wu J P, Wang Y B, et al. Traffic flow prediction based on deep learning[J]. Journal of System Simulation, 2018, 30(11): 4100-4105.)
- [15] Shi X, Chen Z, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[J]. Advances in Neural Information Processing Systems, 2015, 28: 802-810.
- [16] Li Y, Yu R, Shahabi C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting[C]. International Conference on Learning Representations. Vancouver, 2018: 1-16.
- [17] 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.
- [18] 谷远利, 陆文琦, 李萌, 等. 基于组合深度学习的快速路车道级速度预测研究[J]. 交通运输系统工程与信息, 2019, 19(4): 79-86.
(Gu Y L, Lu W Q, Li M, et al. Lane-level traffic speed prediction for expressways based on A combined deep learning model[J]. Journal of Transportation Systems Engineering and Information Technology, 2019, 19(4): 79-86.)
- [19] Teng Shang-Hua. Scalable algorithms for data and network analysis[J]. Foundations and Trends in Theoretical Computer Science, 2016, 12(1/2): 1-274.
- [20] Jagadish H V, Gehrke J, Labrinidis A, et al. Big data and its technical challenges[J]. Communications of the Acm, 2014, 57(7): 86-94.
- [21] Chen C, Petty K, Skabardonis A, et al. Freeway performance measurement system: Mining loop detector data[J]. Journal of the Transportation Research Board, 2001, 1748: 96-102.

作者简介

谷振宇(1975—), 男, 副教授, 博士, 从事交通态势智能分析与预测等研究, E-mail: gzy@cqu.edu.cn;

陈聪(1996—), 男, 硕士生, 从事交通态势智能分析与预测的研究, E-mail: 812478119@qq.com;

郑家佳(1980—), 女, 讲师, 从事物流系统工程的研究, E-mail: jjajiaz@cqu.edu.cn;

孙棣华(1962—), 男, 教授, 博士生导师, 从事交通信息物理系统、智能交通系统规划、智能网联汽车等研究, E-mail: dsun@cqu.edu.cn.

(责任编辑: 孙艺红)