

基于时空依赖性和注意力机制的交通速度预测^①



陈 钰, 张安勤, 许春晖

(上海电力大学 计算机科学与技术学院, 上海 201306)

通讯作者: 张安勤, E-mail: aqzhang@fudan.edu.cn

摘 要: 交通流精准预测对保障公共安全和解决交通拥堵具有重要的意义, 在城市交通规划、交通管理、交通控制等起着重要的作用. 交通预测由于其受限制于城市路网并且随着时间动态变化, 其中存在着空间依赖与时间依赖, 是近些年来具有挑战性的课题之一. 为了同时捕获到空间和时间上的依赖, 提出了一个新的神经网络: 基于注意力机制的时空图卷积网络 (A-TGCN). TGCN 网络模型用于捕获交通数据中的动态时空特性与相关性, 采用注意力机制来增强每个 A-TGCN 层中关键节点的信息. 通过在两组数据上的实验结果表明, A-TGCN 在精度以及可解释性方面都有很好的表现.

关键词: 交通速度预测; 图卷积神经网络; 长短期记忆模型; 注意力机制; 时空依赖性

引用格式: 陈钰, 张安勤, 许春晖. 基于时空依赖性和注意力机制的交通速度预测. 计算机系统应用, 2021, 30(1): 200-206. <http://www.c-s-a.org.cn/1003-3254/7757.html>

Traffic Speed Prediction Based on Spatial-Temporal Dependency and Attention Mechanism

CHEN Yu, ZHANG An-Qin, XU Chun-Hui

(School of Computer Science and Technology, Shanghai University of Electric Power, Shanghai 201306, China)

Abstract: Accurate prediction of traffic flow is of great significance for safeguarding public safety and solving traffic congestion, and plays an important role in urban traffic planning, traffic management, and traffic control. Traffic forecasting is one of the challenging topics in recent years because it is restricted to urban road networks and changes with time, and there are spatial dependence and time dependence. In order to capture both spatial and temporal dependencies, a new neural network is proposed: A space-time map convolutional network based on the attention mechanism (A-TGCN). The TGCN network model is used to capture the dynamic spatiotemporal characteristics and correlations in traffic data, and an attention mechanism is used to enhance the information of key nodes in each A-TGCN layers. The experimental results on two sets of data show that A-TGCN has a good performance in terms of accuracy and interpretability.

Key words: traffic speed prediction; GCN; LSTM; attention; spatial-temporal dependency

随着智能交通系统的发展, 交通预测越来越受到重视, 它是先进交通控制的重要组成部分. 准确地对交通进行预测对城市交通规划、交通管理和交通控制等方面起到了重要的作用. 交通预测是分析城市路网上的交通状况、包括流量、车速和密度等, 挖掘交通模

式, 对路网上的交通进行预测的一个过程. 交通预测不仅能给管理者提供科学依据来预测交通拥挤并提前限制车辆出行提供科学依据, 而且还可以给城市出行者提供适当的出行路线, 提高出行效率提供保障. 然而, 交通预测由于其复杂的时空依赖性, 一直是一项具有

① 基金项目: 国家自然科学基金 (61772327)

Foundation item: National Natural Science Foundation of China (61772327)

收稿时间: 2020-06-06; 修改时间: 2020-07-07; 采用时间: 2020-07-10; csa 在线出版时间: 2020-12-31

挑战性的任务。

1 相关工作

目前有很多交通预测的方法,早期,有一些是基于时间依赖性来进行分析的,例如 ARIMA 模型^[1]、卡尔曼滤波模型^[2]和 SVR^[3]模型等。但在实际应用中,这些方法对于不稳定、非线性的数据处理是比较困难的。

近年以来,随着深度学习的快速发展,深度神经网络能够捕获交通数据的动态特征并取得很好的效果,例如,胡鑫泽等^[4]构建了基于 BP 神经网络的模型来预测城市交通拥堵情况。

根据是否考虑空间依赖,神经网络模型可以划分为两类。一些方法只考虑时间依赖,例如,李校林等^[5]构建了 PF-LSTM 来预测交通流量;满春涛等^[6]使用考虑上下游的 LSTM 网络来进行短时交通流量的预测,这些模型考虑时间特征但忽略了空间依赖性,所以交通数据的变化不受城市路网的限制,因此不能精确的预测路上的交通状态。

解决交通预测问题的关键在于充分利用空间和时间依赖性,为了更好地表现空间特征,很多研究已经在这个基础上进行了改进。例如,LYU 等^[7]提出了一个 SAE 模型从交通数据中捕获空间特征;朱凯利等^[8]使用图卷积神经网络来捕捉城市道路网络的空间特征,实现短期交通流的预测;Yu 等^[9]使用深度卷积神经网络捕获空间依赖,用 LSTM 捕获时间动态性,在北京交通网络数据上展示出了 SRCN 模型优越性。

尽管上述方法引入了 CNN 来捕获空间依赖,在交通预测任务上有很大的进步,但 CNN 本质上只适用于欧氏空间,在有着复杂拓扑结构的交通网络上具有局限性,因此,这类方法有缺陷。近年以来,随着图卷积神经网络的发展,图卷积神经网络(GCN)能够被有效提取网格数据的空间特征,为上述问题提供更好的解决方案。

在这一背景下,本文提出了一种新的深度学习模型:基于注意力机制的时空图卷积网络,可以从交通数据中捕获复杂的时空特征,将其用于基于城市路网的交通预测任务上。与其他模型相比,A-TGCN 不仅可以捕捉空间形态和时间动力学的判别特征,而且可以探索时空域之间的共生关系。

2 问题描述与建模

2.1 问题描述和定义

在本文中,交通预测的目标是基于道路上的历史

交通信息来预测未来某段时间内的交通信息。本文将交通速度作为实验中的一个预测对象。

定义 1. 路网 G . 用图 $G = (V, E)$ 来描述路网的拓扑结构,将每条道路视为一个节点, V 就是道路节点的集合, $V = \{v_1, v_2, \dots, v_N\}$, N 为顶点数, E 为边集。邻接矩阵 $A = R^{N \times N}$ 用来表示道路之间的关系。邻接矩阵只包含 0 和 1。如果道路之间直接连接就设为 1,如果没有直接连接就设为 0^[9]。

定义 2. 特征矩阵 $X^{N \times P}$. 将道路网络中的每条道路上的速度视为道路网络中节点的属性特征,表示为 $X \in R^{N \times P}$. 其中 P 表示各个节点特征的数量(历史时间序列的长度), $X_t \in R^{N \times i}$ 用来表示在时刻 i 时每条道路的速度。

可以将时空交通预测的问题视为在确定了道路网络拓扑结构 G 和特征矩阵 X 的前提下学习一个映射函数,然后计算下一个 T 时刻的交通信息,模型表示为:

$$[X_{t+1}, \dots, X_{t+T}] = f(G; (X_{t-n}, \dots, X_{t-1}, X_t)) \quad (1)$$

其中, n 表示历史时间序列的长度, T 表示需要预测的时间序列的长度。

2.2 基于图卷积神经网络的空间依赖模型

获取复杂的空间依赖在交通预测中是一个关键性问题。传统的 CNN 只能应用于欧氏空间,比如说图片,常规网格等。但是城市路网并不是网格, CNN 不能反映其中复杂的拓扑结构。近年来被提出的 GCN 可以处理图结构, GCN 的原理是在傅里叶域中构建滤波器,作用在顶点及其一阶邻居上,捕获顶点间的空间特征,可以通过堆叠多个卷积层来构建 GCN 模型。GCN 模型可以获取中心道路及其周围道路的拓扑关系,以获取空间依赖。总之,本文使用 GCN 模型^[10]从交通数据中提取空间特征。对于本文, GCN 模型可以表示为:

$$f(X) = \sigma(\widehat{A}XW_0) \quad (2)$$

式中, X 表示特征矩阵, A 表示邻接矩阵, $\widehat{A} = A + I_N$ 是一个具有自连接结构的矩阵, $\widehat{A} = \widehat{D}^{-\frac{1}{2}} \widehat{A} \widehat{D}^{-\frac{1}{2}}$ 表示一个预处理的步骤, \widehat{D} 是一个度矩阵, $\widehat{D} = \sum_j \widehat{A}_{ij}$. W_0 表示 GCN 的权重矩阵, $\sigma(\cdot)$ 是激活函数。

2.3 时间依赖模型

获取时间依赖是交通预测中的另一个关键问题。目前,用于处理序列数据被最广泛使用的是递归神经网络(RNN)。但是,由于梯度消失和梯度爆炸等缺陷,传统的递归神经网络对长期预测具有局限性。

LSTM 模型是 RNN 模型的变体, 并且已被证明可以解决上述问题. LSTM 的基本原理是使用门控机制来记忆尽可能多的长期信息, 因此选用 LSTM 模型为基础进行改进, 从交通数据中获取时间依赖.

基本 LSTM 模型如图 1 所示.




图 1 LSTM 模型

图 1 中 h_{t-1} 表示 $t-1$ 时刻的输出同时也是 t 时刻的输入. c_{t-1} 表示 $t-1$ 时刻的细胞状态, 会各个时刻一直向前传递. X_t 表示 t 时刻从外界接受的输入, f_t 为遗忘门, i_t 和 j_t 为输入门, o_t 为输出门. LSTM 模型就是通过 f_t , i_t 等 4 个门控逻辑单元实现对时间序列的记忆和预测.

经过改进后的 LSTM 模型如图 2 所示.




图 2 改进的 LSTM 模型

将 c 细胞状态隐藏在每一个改进的 LSTM 细胞中, 使其包含于每个时间序列输出的 h_t 中, 将 LSTM 中的 f_t , i_t 和 j_t 合并为重置门 r_t 和更新门 u_t , 并且更换了激活函数. 具体的计算过程如下:

$$r_t = \text{relu}(W_r [h_{t-1} + X_t]) \quad (3)$$

$$u_t = \sigma(W_u [h_{t-1} + X_t]) \quad (4)$$

$$c_t = \text{tanh}(W_c [r_t * h_{t-1} + x_t]) \quad (5)$$

$$h_t = (1 - u_t) * h_{t-1} + u_t * c_t \quad (6)$$

式中, $\sigma(\cdot)$, $\text{relu}(\cdot)$ 和 $\text{tanh}(\cdot)$ 为激活函数, W 和 b 为训练过程中的权重和偏置.

r_t 用来将上一个细胞的状态和当前细胞的状态融合; u_t 用来控制遗忘哪些信息并把新的信息传入当前细胞; c_t 用来将 r_t 和 u_t 融合, 形成当前细胞的输出.

改进后的 LSTM 模型拥有更少的输入和输出以及门控逻辑单元, 能够拥有更好的时间复杂度. 并且调整了激活函数, 实验结果表明其能够更好地挖掘图拓扑结构的数据.

2.4 A-TGCN 模型

为了从交通数据中同时捕获时间和空间依赖性, 我们提出了一种基于图卷积神经网络和改进的 LSTM 模型的基于注意力机制的时间图卷积模型 (A-TGCN).

A-TGCN 模型有 3 个部分: 图卷积网络, 改进的 LSTM 以及注意力机制. 一方面利用图卷积网络来捕捉城市道路网的拓扑结构, 从而得到空间相关性. 另一方面, 利用门控逻辑单元捕捉道路上交通信息的动态变化, 获取时间相关性. 本文的模型使用图卷积网络算子来替换循环神经网络中的门控逻辑单元, 与 Ling 等人^[11] 所提出的 T-GCN 相比, 该模型在捕捉空间特征的同时将其融合进入时间特征中, 使得空间特征在随着时间序列的推进过程中产生关联性. 相比于先进行空间特征捕捉, 再进行时间特征捕捉的模型, 该模型减弱了由于传递过程中所造成的信息丢失所产生的误差逐渐放大的现象, 并且在每个 A-TGCN 模块中加入了注意力机制, 使得该模型在每个时间段能够对路网上节点的信息进行动态的聚焦, 从而提升了模型的泛化能力, 也让该模型在进行长时间交通信息预测是拥有更好的性能.

模型的结构如图 3 所示, 其中 X_{t-1} 表示 $t-1$ 时刻的一个输入, Y_{t-1} 表示 $t-1$ 时刻的预测结果, h_{t-1} 和表示 $t-1$ 时刻的输出同时也是 t 时刻的一个输入.




图 3 A-TGCN 模型的结构

图 3 中的 LS-GCN 细胞就是通过结合 GCN, 改进的 LSTM 以及注意力机制相融合, 提出的新的网络模型. A-TGCN 和改进的 LSTM 一样包含 3 个门: 重置门 r_t , 更新门 u_t 和输出门 o_t . 但是, 这些门控循环逻辑单元都是由式 (2) 的图卷积算子得到的, A-TGCN 细胞的具体结构如图 4 所示.

图 4 中 h_{t-1} 和 X_t 为 t 时刻的输入. gc 表示图卷积过

程, u_t 和 r_t 为更新门和重置门, c_t 为隐含的细胞状态更新. 具体的计算公式如下所示:

$$r_t = \text{relu}(W_r[f(X_t) + f(H_{t-1})] + b_r) \quad (7)$$

$$u_t = \sigma(W_u[f(X_t) + f(H_{t-1})] + b_u) \quad (8)$$

$$u_t = \sigma(W_u[f(X_t) + f(H_{t-1})] + b_u) \quad (9)$$

$$c_t = \tanh(W_c[r_t * f(H_{t-1}) + f(X_t)] + b_c) \quad (10)$$

$$h_t = (1 - u_t) * H_{t-1} + u_t * c_t \quad (11)$$

$$H_t = f_{\text{att}}(h_t) + h_t \quad (12)$$

式中, $\sigma(\cdot)$, $\text{relu}(\cdot)$ 和 $\tanh(\cdot)$ 为激活函数, $f(\cdot)$ 为式 (2) 中定义的图卷积过程, W 和 b 是各个门控单元中的权重和偏置, 为可训练参数.

$f_{\text{att}}(\cdot)$ 是一种能够选择关键节点信息的注意力机制网络. $f_{\text{att}}(h_t)$ 和 h_t 的总和作为输出的目的是在不削弱非聚焦节点信息的前提下, 增强关键节点的信息, 保持空间信息的完整性.

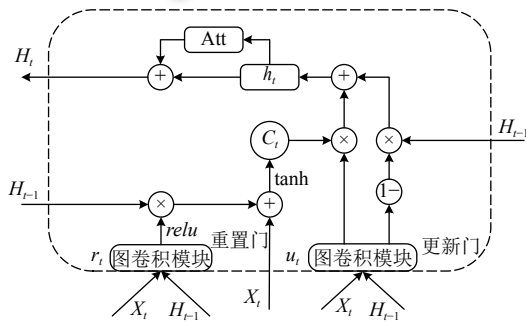


图4 A-TGCN 细胞的具体结构

2.5 注意力网络

通过 GCN 和门控逻辑单元模块所获取到的为包含空间特征的时间序列信息. 这就意味着, 在时间序列中, 路网中的信息一直在动态的变化, 所以在不同的时间点对于路网中各个节点的关注权重是不同的. 但是, 在每个时刻, 应该全局性的关注路网上的每个节点, 而不是单独的几个节点, 因此, 本文通过使用 Soft-attention^[12] 机制, 它能够对于输入的序列提取的特征信息, 寻找其内部联系, 从不同时间点的路网信息中自适应的衡量各个节点的重要程度.

本文使用的注意力网络的结构如图 5 所示. 首先, 将 t 时刻所以节点的信息聚合为一个向量. 这里的信息包含 t 时刻路网的空特征和节点信息.

图 5 中 q_t 即为 t 时刻所有节点信息的聚合.

$$q_t = \text{relu}\left(\sum_{i=1}^N W h_{ti}\right) \quad (13)$$

式中, W 为可训练参数, h_{ti} 表示 t 时刻路网上第 i 个节点的第一个隐含状态.

那么所有节点的注意力分数的计算方法如式 (13) 所示:

$$\alpha_t = \text{Sigmoid}\left(U_s \tanh\left(W_h h_t + W_q q_t + b_s\right) + b_u\right) \quad (14)$$

其中, $\alpha_t = (\alpha_{t1}, \alpha_{t2}, \dots, \alpha_{tN})$, 其中 α_{ti} 表示 t 时刻第 i 个节点相对于的注意力分数. U_s , W_h 和 W_q 为可训练参数, b_s 和 b_u 为偏置.

该注意力机制将 t 时刻所有节点聚合后的信息与 t 时刻所有节点的信息进行拼接, 再通过全连接层, 从而得到各个节点相对于全部节点的注意力权重. 因为解决的是非线性关系, 所以本文采用了两层全连接层的结构. 可能存在多个关键节点, 本文使用 Sigmoid 作为最后一层的激活函数.

因此 t 时刻第 i 个节点的第 2 个隐含状态 H_{ti} 可以表示为 $(1 + \alpha_{ti}) \cdot h_{ti}$. 第 2 隐含状态包含时间信息, 以及在空间特征下被注意力机制增强的节点信息, H_{ti} 将被送入下一个 A-TGCN 层.




图5 注意力机制结构图

2.6 损失函数

在训练过程中, 目标是使道路上的实际交通速度与预测值之前的误差最小. 本文使用 Y_t 和 \hat{Y}_t 分别来表示实际的交通速度和预测速度, A-TGCN 的损失函数如式 (15) 所示:

$$\text{loss} = \|Y_t - \hat{Y}_t\| + \lambda L_{\text{reg}} \quad (15)$$

式中, 第一项用来最小化实际车速和预测值之间的误差, 第二项 L_{reg} 表示 L2 正则化项, 有助于避免过拟合问题, λ 为一个超参数.

3 实验数据与参数设定

为了检验 A-TGCN 模型的性能, 构建交通流预测系统并选取城市道路历史平均速度进行测试, 将 A-TGCN 模型和其他经典模型的预测结果进行比较, 来分析模型的优劣.

3.1 实验数据的选取

实验选取了两个真实世界数据集 SZ-taxi 数据集和 Los-loop 数据集来评估 A-TGCN 模型的预测性能.

SZ-taxi: 该数据集为深圳市 2015 年 1 月 1 日至 2015 年 1 月 31 日的出租车轨迹. 选择罗湖区 156 个主要道路为研究区. 实验数据包括两部分: 一个是 156×156 邻接矩阵, 描述了道路之间的空间关系. 每行代表一条道路, 矩阵中的值代表道路之间的连通性. 另一个是特征矩阵, 它描述了每条道路上的速度随时间的变化. 每行代表一条道路; 每列是不同时段道路上的交通速度. 每 15 分钟汇总一条道路的交通速度. 从中选取一条道路上的速度如图 6 所示.




图 6 深圳数据中一条道路的速度随时间变化图

(2) Los-loop: 该数据集是在洛杉矶市的高速公路上实时收集的数据. 从 2012 年 3 月 1 日到 2012 年 3 月 7 日, 每 5 分钟汇总一次交通流量. 和 SZ-taxi 数据集类似, 数据分为邻接矩阵和特征矩阵两部分. 从中选取一条道路上的速度如图 7 所示.




图 7 Los-loop 数据中一条道路的速度随时间变化图

在实验中, 将数据预处理, 输入数据被标准化在 $[0, 1]$ 之间. 其中, 80% 的数据用作训练集, 20% 的数据用作测试集. 将预测接下来的 15 分钟、30 分钟、

45 分钟和 60 分钟的交通速度.

3.2 性能评估指标

为了评估 A-TGCN 的预测性能, 使用 2 个指标来评估实际交通情况 Y_t 和预测值 \hat{Y}_t 之间的误差, 包括:

(1) RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (Y_t - \hat{Y}_t)^2} \quad (16)$$

(2) Accuracy:

$$Accuracy = 1 - \frac{\|Y - \hat{Y}\|_F}{\|Y\|_F} \quad (17)$$

其中, RMSE 用于衡量预测误差, 它的值越小, 表示此模型的预测效果就越好. Accuracy 用于衡量模型预测精度, 它的值越大, 预测效果越好.

3.3 模型参数设定

A-TGCN 模型的参数主要包括: 学习率, 训练次数以及隐藏层数. 在实验中, 将学习率设置为 0.001, 将训练次数设定为 1000 次.

隐藏单元的数量对于 A-TGCN 模型是非常重要的参数, 不同的隐藏单元会影响预测精度. 为了选择最佳值, 尝试使用不同的隐藏单位, 通过模型 RMSE 和 Accuracy 来选择最佳值.

在实验中, 对于 SZ-taxi 数据集, 使用二分法来寻找最优的隐藏单元的数量, 并分析预测精度的变化. 如图 8 所示, 横轴表示隐藏单元的数量, 纵轴表示 RMSE 和 Accuracy 的变化. 可以看出, 当隐藏单元数量为 64 时, RMSE 最小, Accuracy 最大. 因此, 我们在实验中将 SZ-taxi 数据隐藏单元数量设置为 64.




图 8 SZ-taxi 数据不同隐含单元数量对应的模型效果比较

对于 Los-loop 的数据也使用相同的方法. 经过实验发现, 当隐藏单元数为 16 时, 预测精度最高, 而预测误差最低. 所以最终将 Los-loop 数据隐藏单元数量设置为 16.

4 实验结果与分析

本文将 A-TGCN 模型的性能与以下模型进行比较:

(1) SVR: 该模型通过使用历史数据来训练模型, 并获得输入和输出之间的关系, 来对未来交通数据进行预测。

(2) ARIMA: 将时间序列拟合到参数模型中来预测未来的交通数据。

(3) LSTM+GCN: 单纯使用长短期网络和图卷积神

经网络, 捕获时间和空间特征进行预测。

(4) T-GCN: 使用 GCN 和 GRU, 先使用 GCN 捕捉空间信息, 再送入使用 GRU 捕捉空间信息。

表 1 和表 2 显示了在 SZ-taxi 和 Los-loop 数据集上分别进行 15 分钟, 30 分钟, 45 分钟和 60 分钟预测的 A-TGCN 模型和其他模型上的结果。可以看出, A-TGCN 模型在评估范围内均获得了良好的预测性能, 证明了 A-TGCN 模型在时空交通量预测中的有效性。

表 1 A-TGCN 模型和其他方法在 SZ-taxi 数据集上的预测结果

预测时间(分)	对比方法	SVR	ARIMA	GCN	LSTM+GCN	T-GCN	A-TGCN
15	RMSE	7.5368	8.2151	9.2717	4.3028	3.9162	3.868
	Accuracy	0.6961	0.4278	0.6433	0.7292	0.7306	0.7582
30	RMSE	7.4747	8.2123	9.345	4.1987	3.9617	3.872
	Accuracy	0.6987	0.4281	0.6405	0.7075	0.7275	0.7467
45	RMSE	7.4755	8.2132	9.4023	4.2028	3.995	3.898
	Accuracy	0.6986	0.428	0.6383	0.6871	0.7252	0.7425
60	RMSE	7.4883	8.2063	9.4504	4.2475	4.0141	3.628
	Accuracy	0.6981	0.4282	0.6365	0.6638	0.7238	0.7368

表 2 A-TGCN 模型和其他方法在 Los-loop 数据集上的预测结果

预测时间(分)	对比方法	SVR	ARIMA	GCN	LSTM+GCN	T-GCN	A-TGCN
15	RMSE	6.0084	10.0439	7.7922	6.2021	5.2182	5.1699
	Accuracy	0.6961	0.4278	0.8673	0.9021	0.9127	0.9185
30	RMSE	6.9588	9.345	8.3353	7.1816	6.0598	6.0016
	Accuracy	0.8815	0.8275	0.8581	0.8706	0.8968	0.9049
45	RMSE	7.7504	10.0508	8.8036	8.3986	6.7065	6.6328
	Accuracy	0.868	0.8273	0.85	0.8632	0.8857	0.9014
60	RMSE	8.4388	10.0538	9.2657	8.3927	7.2677	7.1256
	Accuracy	0.8562	0.8273	0.8421	0.8476	0.8592	0.8842

从表 1 和表 2 中能够发现:

(1) 预测精度: 基于神经网络的模型, 包括 T-GCN 模型, A-TGCN 模型等方法, 一般都比 SVR, ARIMA 等传统机器学习算法具有更好的预测精度。例如, 对于深圳数据 15 min 的交通量预测任务, A-TGCN 模型的 RMSE 误差比 SVR 模型降低了约 10%, 准确率比 SVR 模型提高了约 24%。这主要是由于 SVR 模型和 ARIMA 模型难以处理复杂, 非平稳的时间序列数据, 因为 ARIMA 是通过计算各节点误差并求平均值来计算的, 如果时间的波动较大, 也将增加最终预测的总误差。GCN 模型预测效果差的原因是因为 GCN 只考虑了空间特征, 忽略了交通数据的时间特征。

(2) 在 Los-loop 数据上的实验结果比在 SZ-taxi 数据上的要好。经过推测, 主要原因是 GCN 模型在傅立叶域中定义了一个平滑的滤波器, 并通过不断移动滤

波器来捕获空间特征, 所以在处理更加平滑的数据时, 会具有更好的效果。从图 6 和图 7, 以及 GCN 模型分别在两个数据上的预测结果, 可以看出, Los-loop 数据更加的平滑, 总体的预测结果也越好。

(3) LSTM-GCN 模型相比于 T-GCN 模型和 A-TGCN 模型在进行长时间的预测时的能力下降的更快。本文分析, 主要是因为 LSTM-GCN 模型没有对时间和空间特征进行联合的特征挖掘, 而是分步进行, 这就导致了在较长的时间序列的数据的传递过程中不可避免地出现信息的丢失, 时间越长, 丢失的信息就越多, 最终的预测结果造成较大的误差。

(4) T-GCN 相比于 A-TGCN 模型在长时间序列的预测方面的能力也有所下降, 特别是对未来 60 分钟的交通流进行预测时, TGCN 模型的准确率衰减的较为厉害。本文认为, 首先, 相比于 T-GCN 只是将 GCN 模

型挖掘出的空间特征在 GRU 中联合计算, A-TGCN 模型是将 GCN 模型集成于循环神经网络中, 使得空间特征随着时间序列的推移实现了不同时刻的空间特征的动态关联性, 增强了信息传递的时空依赖性, 其次, A-TGCN 模型在每个 A-TGCN 细胞中加入了注意力机制, 使得神经网络能够具备专注于输出信息中的重要特征的能力, 从而使得重要的特征能够一直传递下去。

5 结论与展望

本文提出了一种新的基于神经网络以及注意力机制相结合的交通预测方法, 称为 A-TGCN。一方面, GCN 用于捕获路网的拓扑结构以获取空间依赖性; 另一方面, 改进的 LSTM 模型用于捕获节点属性的时间动态变化以获得时间依赖性。最终, 使用 Soft-attention 机制来自适应聚焦于关键节点, 增强预测效果。

在两个真实的交通数据集上进行评估, 在与 ARIMA 模型、SVR 模型、GCN 模型、LSTM+GCN 以及 T-GCN 模型进行比较后, A-TGCN 模型无论在长期还是短期的交通速度预测能力都优于这几种算法, 也更加接近真实的数据。总之, A-TGCN 模型可以成功地从交通数据中捕获时空特征, 并且不仅局限于交通速度预测, 还可以应用于其他的时空序列预测的任务。

参考文献

- 1 刘学刚, 张腾飞, 韩印. 基于 ARIMA 模型的短时交通流预测研究. 物流科技, 2019, (12): 91-94, 102. [doi: 10.13714/j.cnki.1002-3100.2019.12.024]
- 2 范光鹏, 孙仁诚, 邵峰晶. 基于 LSTM 和 Kalman 滤波的公交车到站时间预测. 计算机应用与软件, 2018, 35(4): 91-96. [doi: 10.3969/j.issn.1000-386x.2018.04.017]
- 3 潘伟靖, 陈德旺. 基于 GRU-SVR 的短时交通流量预测研究. 计算机技术与发展, 2019, 29(10): 11-14. [doi: 10.3969/j.issn.1673-629X.2019.10.003]
- 4 胡鑫泽, 张琪虹, 孙涵莆, 等. 基于 BP 神经网络的城市交通拥堵情况预测. 电子技术与软件工程, 2020, (1): 186-187.
- 5 李校林, 吴腾. 基于 PF-LSTM 网络的高效网络流量预测方法. 计算机应用研究, 2019, 36(12): 3833-3836. [doi: 10.19734/j.issn.1001-3695.2018.06.0394]
- 6 满春涛, 康丹青. 考虑上下游的 LSTM 短时交通流量预测. 哈尔滨理工大学学报, 2019, 24(5): 101-107. [doi: 10.15938/j.jhust.2019.05.017]
- 7 Lv YS, Duan YJ, Kang WW, *et al.* Traffic flow prediction with big data: A deep learning approach. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 865-873.
- 8 朱凯利, 朱海龙, 刘靖宇, 等. 基于图卷积神经网络的交通流量预测. 智能计算机与应用, 2019, 9(6): 168-170, 177. [doi: 10.3969/j.issn.2095-2163.2019.06.035]
- 9 Yu HY, Wu ZH, Wang SQ, *et al.* Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks. Sensors, 2017, 17(7): 1501. [doi: 10.3390/s17071501]
- 10 Bruna J, Zaremba W, Szlam A, *et al.* Spectral networks and locally connected networks on graphs. Proceedings of the 2nd International Conference on Learning Representations. Banff, AB, Canada. 2014.
- 11 Zhao L, Song YJ, Zhang C, *et al.* T-GCN: A temporal graph convolutional network for traffic prediction. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858. [doi: 10.1109/TITS.2019.2935152]
- 12 Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need. arXiv: 1706.03762, 2017.