



(12) 发明专利

(10) 授权公告号 CN 113724504 B

(45) 授权公告日 2023.04.07

(21) 申请号 202110905077.3

G06N 3/042 (2023.01)

(22) 申请日 2021.08.06

G06N 3/0464 (2023.01)

(65) 同一申请的已公布的文献号

G06N 3/0442 (2023.01)

申请公布号 CN 113724504 A

G06N 3/08 (2023.01)

G06F 18/25 (2023.01)

(43) 申请公布日 2021.11.30

(73) 专利权人 之江实验室

(56) 对比文件

CN 106935034 A, 2017.07.07

地址 310023 浙江省杭州市余杭区文一西路1818号人工智能小镇10号楼

CN 102819954 A, 2012.12.12

薛佳瑶等. 基于卷积循环神经网络的城市区域车流量预测模型.《信息工程大学学报》.2019, (第02期), 全文.

(72) 发明人 陈红阳 肖大鹏 肖竹

周明等. 基于时空信息的交通流预测.《工业控制计算机》.2020, (第04期), 全文.

(74) 专利代理机构 杭州求是专利事务所有限公司 33200

专利代理师 邱启旺

审查员 高毅娟

(51) Int. Cl.

G08G 1/065 (2006.01)

G08G 1/01 (2006.01)

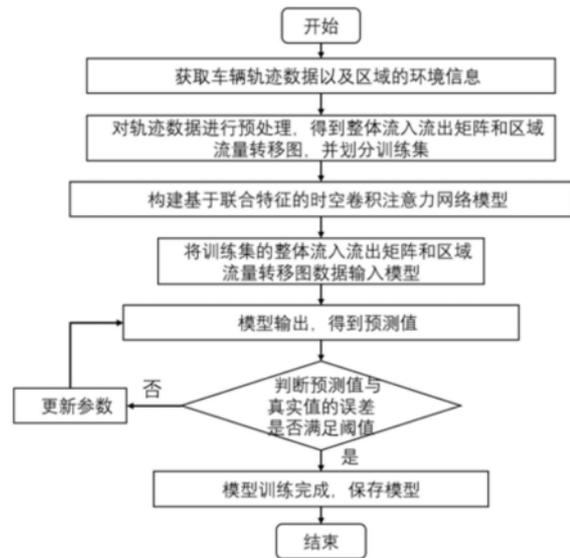
权利要求书4页 说明书11页 附图1页

(54) 发明名称

一种面向车辆轨迹大数据的城市区域流量预测系统及方法

(57) 摘要

本发明公开了一种面向车辆轨迹大数据的城市区域流量预测系统及方法。首先通过采集车辆的轨迹数据和环境信息数据构成历史信息数据集,构建得到整体历史流入流出矩阵和城市区域流量转移图,然后构建基于联合特征的时空卷积-注意力网络流量预测深度学习模型,其次基于该模型分别提取流量转移时空特征和区域间流量转移时空特征,并嵌入外部特征。最后,该模型通过流量全局时空特征和区域间流量转移特征,嵌入环境信息等外部特征,进行联合预测,得到下一时刻车流量的预测结果。



1. 一种面向车辆轨迹大数据的城市区域流量预测系统,其特征在于,所述城市区域流量预测系统包括数据采集模块和流量预测模块;

所述数据采集模块采集车辆的轨迹数据和环境信息数据构成历史信息数据集,具体为:通过具有GPS或北斗定位功能的终端采集不含隐私信息的车辆轨迹数据;通过天气查询服务的API接口获得区域天气数据;通过查询日历统计时间信息和节假日数据;通过网络爬虫技术获取事件数据;通过地图服务提供商提供的店铺信息进行聚类获取空间信息和区域POI信息;所述历史信息数据集构成整体历史流入流出矩阵和城市区域流量转移图;

所述流量预测模块提取车辆的轨迹数据的特征,并对车流量进行预测;包括全局时空特征提取模块、流量转移特征提取模块、流量变化特征融合模块、外部特征嵌入模块、联合特征预测模块;

所述全局时空特征提取模块使用 5×5 的二维卷积核对每个时刻的整体历史流入流出矩阵进行局部空间特征提取,得到多个时间片段的局部空间特征;接着将提取到的多个时间片段的局部空间特征堆叠输入多层时空卷积神经网络进行卷积操作,得到历史流量时空特征;

所述流量转移特征提取模块采用基于图卷积神经网络联合长短期记忆网络提取城市区域流量转移图的流量转移时空特征;其中,图卷积神经网络用于提取流量转移的空间特征,长短期记忆网络用于提取流量转移的时间特征;

所述流量变化特征融合模块:采用一个二维的卷积层和一个激活层对全局时空特征提取模块输出的历史流量时空特征和流量转移特征提取模块输出的流量转移时空特征进行融合,输出融合的流量变化特征;

所述外部特征嵌入模块:将时间信息、空间信息和环境信息分别进行编码,并通过一个两层的全连接网络进行嵌入,得到时间嵌入向量、空间嵌入向量和环境嵌入向量,再将上述3个嵌入向量进行融合,得到嵌入的外部特征;

所述联合特征预测模块:输入为外部特征嵌入模块输出的融合的外部特征和流量变化特征融合模块输出的流量变化特征,将外部特征与对应时间地点的流量变化特征相加,得到嵌入了外部特征的流量联合特征;采用基于卷积神经网络层和多头注意力网络的卷积注意力单元进行堆叠,学习之前时刻的联合特征中的注意力权重,并以此预测下一时刻的区域流入流出流量。

2. 一种应用权利要求1所述系统的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,具体包括以下步骤:

(1) 通过数据采集模块记录车辆的轨迹数据,并根据相应的轨迹数据收集相关区域、相关时间的环境信息数据构成历史信息数据集;所述车辆的轨迹数据具体为不含隐私信息的车辆轨迹数据,包括历史行程轨迹数据、车辆的停留时间;所述环境信息数据包括区域天气数据、时间信息、节假日数据、事件数据、空间信息、城市地图、路网信息和区域POI信息;各个区域的全部POI信息聚类得到功能区分信息;

(2) 根据步骤(1)采集的历史行程轨迹数据构建各时间片段的整体历史流入流出矩阵;

(3) 根据步骤(1)采集的城市地图、路网信息和功能区信息等环境信息,结合历史行程轨迹数据构建各个区域之间的区域流量转移图;

(4) 构建基于联合特征的时空卷积-注意力网络流量预测深度学习模型,包括以下步

骤:

(4.1) 将步骤(2)构建的各历史时间片段的整体流入流出矩阵输入全局时空特征提取模块中,输出历史流量时空特征;

(4.2) 将步骤(3)中得到的各个区域之间的区域流量转移图输入流量转移特征提取模块,采用基于图卷积神经网络和长短期记忆网络提取城市区域流量转移图的流量转移时空特征;所述步骤(4.2)包括以下子步骤:

(4.2.1) 利用流量转移特征提取模块,通过图卷积网络用于提取各子区域间的流量转移空间关联性,计算公式为:

$$X_{out} = ReLU(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} X_{in} W)$$

其中 $X_{in} = \{G_{t-s_{in}}, G_{t-s_{in}+1}, \dots, G_t\} \in \mathbb{R}^{n \times s_{in}}$ 作为图卷积网络的输入, $X_{out} \in \mathbb{R}^{n \times 1}$ 为网络的输出, $\tilde{A} = A + I_N$, I_N 为 N 维的单位矩阵, $\tilde{D} = \sum_j \tilde{A}_{ij}$ 为精细度矩阵, W 为图卷积网络要学习的参数, s_{in} 为输入图卷积网络的时间片段数;

(4.2.2) 利用长短期记忆网络提取各子区域间的流量转移的时间关联性和短期时间变化规律,通过一个全连接网络将流量转移空间关联性和流量转移的时间关联性融合成流量转移时空特征;历史区域流量转移图 $X_{in} = \{G_{t-s_{in}}, G_{t-s_{in}+1}, \dots, G_t\}$ 作为输入,通过流量转移特征提取模块进行特征提取,输出流量转移时空特征 $\hat{T}_k \in \mathbb{R}^{n \times n}, k \in [0, n]$;

(4.3) 利用流量变化特征融合模块将步骤(4.2)得到的流量转移时空特征与步骤(4.1)得到的历史流量时空特征相融合,得到融合的流量时空特征;

(4.4) 利用外部特征嵌入模块将时间信息、空间信息和环境信息分别进行编码,将步骤(1)采集的环境信息等外部特征的历史信息数据集通过一个两层的全连接网络,同时对步骤(4.3)输出的融合的流量时空特征的时间信息和空间信息做词嵌入操作,得到嵌入的外部特征;

(4.5) 将步骤(4.3)得到的融合的流量时空特征和步骤(4.4)得到的嵌入的外部特征输入联合特征预测模块,输出嵌入了外部特征的流量联合特征,下一时刻的区域流入流出流量,得到基于联合特征的时空卷积-注意力网络流量预测深度学习模型;

(5) 使用步骤(1)采集的历史行程轨迹数据训练步骤(4)输出的基于联合特征的时空卷积-注意力网络流量预测深度学习模型,将该模型训练后输出的预测与真实值进行比较,如误差函数在设定阈值之外,则采用adam优化算法更新模型的参数;如误差函数满足阈值,则保存参数,得到训练好的基于联合特征的时空卷积-注意力网络模型。

3. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(2)具体为:将整个研究区域划分为 $\binom{H}{h} \times \binom{L}{l}$ 个矩形子区域, L 和 H 为整个研究区域的长和宽, l 和 h 为矩形子区域的长和宽, $\frac{H}{h} = n, \frac{L}{l} = n$; 以 τ 为时间间隔,从步骤(1)采集的车辆的历史轨迹数据 $\{Y_1, \dots, Y_T\}$ 中,统计第 i 个子区域 G_i 中的车辆流入流出数量,则在第 a 个时间段,即得到在 $((a-1) \times \tau, a \times \tau)$ 时刻整个区域中的车辆流入量 $Vol_{i,in}^a$ 和车辆流出量 $Vol_{i,out}^a$, 则第 a 个时间段内整个区域的城市整体流入流出矩阵可以用两个通道 $n \times n$ 的二维矩阵表示为 $Vol^k = \{Vol_{i,in}^a, Vol_{i,out}^a\}$, 将 t 个时间片段的车流量按照时间先后顺序排列可得到城市历史的整体流入流出矩阵 $Vol = \{Vol^1, Vol^2, \dots, Vol^t\}$, 其中, $Vol \in \mathbb{R}^{t \times n \times n \times 2}$ 。

4. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(3)具体为:将城市区域的路网结构建成一个图结构 $G_k = (\mathcal{V}, \mathcal{E}_k, A_C)$,其中 \mathcal{V} 是以所有子区域 (G_1, G_2, \dots, G_n) 构成的集合, $|\mathcal{V}| = n \times n$; $A_C \in \mathbb{R}^{n \times n}$ 是连接性矩阵,其中元素 $A_C[i, j]$ 表示的是相应的第i个和第j个子区域之间空间的连接性;各节点之间的边 ε_k 表示第k时间段中为各个子区域之间具体的流量转移数量;然后以 τ 时间间隔划分得到 $((k-1) \times \tau, k \times \tau)$ 时间段的城市区域流量转移图 $G_k = (\mathcal{V}, \mathcal{E}_k, A_C)$, $G_k \in \mathbb{R}^{N \times d}$,其中 $N = n \times n$ 表示节点的数量, d 示历史观测特征的种类数目。

5. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(4.1)具体为:

先使用 5×5 的二维卷积核对每个时刻的城市的整体流入流出矩阵进行局部空间特征提取,得到多个时间片段的局部空间特征;接着将提取到的多个时间片段的局部空间特征堆叠输入多层时空卷积神经网络进行卷积操作得到历史流量时空特征;所述多层时空卷积神经网络由输入层、多个二维卷积层、三维卷积层、池化层、全连接层和输出层等基本的神经网络层构成;第i层时空卷积神经网络卷积第m个通道的卷积神经元矩阵中位于 (x, y, z) 的输出 e_{im}^{xyz} 如下:

$$e_{im}^{xyz} = \text{ReLU}(\sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{im}^{pqr} c_{(i-1)m}^{(x+p)(y+q)(z+r)} + b_{im})$$

其中, w_{im}^{pqr} 是第i层三维卷积核的m通道的卷积神经元矩阵中位于 (p, q, r) 上的参数, R_i 是Conv3D卷积核在时间轴上的维度, $c_{(i-1)m}^{(x+p)(y+q)(z+r)}$ 是m通道中位于 $(x+p, y+q, z+r)$ 的在第i-1层卷积中的输出值, b_{im} 是三维卷积核的偏差向量;ReLU为激励函数;

最终,全局时空特征提取模块输出整体历史流入流出矩阵的历史流量时空特征 $\hat{F}_k \in \mathbb{R}^{n \times n \times 2}, k \in [0, n]$ 。

6. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(4.3)具体为:

利用流量变化特征融合模块,通过融合车辆出行流量全局时空特征和区域间流量转移特征,得到流量时空特征 \widehat{Vol}_k :

$$\widehat{Vol}_k = \sigma(W \cdot \text{Concat}(\hat{F}_k; \hat{T}_k) + b)$$

其中, W 为融合网络层的学习参数, b 为偏差向量, $\text{Concat}(\blacksquare)$ 表示对括号内元素矩阵进行拼接操作。

7. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(4.4)具体为:

空间信息嵌入:将节点的向量作为输入,使用两层的全连接神经网络得到空间嵌入向量 $e_{G_i}^s \in \mathbb{R}^D$;

时间信息嵌入:将历史信息数据集中的每个时间片段进行嵌入,得到相应时间嵌入向量:将一天划分为 T 个时间段,使用独热编码将星期几和每天的第几个时间段编码成 \mathbb{R}^7 和 \mathbb{R}^T 的向量,将其拼接成 \mathbb{R}^{7+T} 的向量,使用两层的全连接神经网络得到时间嵌入向量

$e_k^t \in \mathbb{R}^D$, 其中k表示的是第k个时间片段;

环境信息嵌入:选择天气、温度、特殊事件、节假日四个环境信息进行特征嵌入,其中,天气包含:晴、雨、雪、风、云、雷,六种气象,采用独热编码生成向量,温度为原温度值;特殊事件和节假日分别使用一个1维向量表示;将上述向量进行拼接,得到 \mathbb{R}^{10} 的向量,使用两层的全连接神经网络得到第k时间段的环境嵌入向量 $e_{G_i,k}^e \in \mathbb{R}^D$;

然后,将以上3个特征嵌入向量进行融合,得到嵌入的外部特征 $e_{G_i,k}$:

$$e_{G_i,k} = e_{G_i}^s + e_k^t + e_{G_i,k}^e。$$

8. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(4.5)具体为:

采用注意力网络进行预测,各个节点的注意力Attention(Q,K,V)为:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}V\right)$$

其中 $Q, K \in \mathbb{R}^{T \times d_k}$, $V \in \mathbb{R}^{T \times d_v}$ 表示各个节点的查询、键和值, d_k 是每个节点的查询和键的维度, d_v 是每个节点的值的维度;

在将流量变化特征融合模块输出的流量时空特征 \widehat{Vol}_k 和外部特征 $e_{G_i,k}$ 进行合并 $h_j = \widehat{Vol}^j + e_{G_i,j}$, $j \in [1, k]$,得到 (h_1, \dots, h_k) 并将其堆叠为 $H^{v_i} \in \mathbb{R}^{T \times d}$,上标 v_i 表示其对应的节点;接着对矩阵 H^{v_i} 线性变换为各个节点的查询 Q^{v_i} 、键 K^{v_i} 和值 V :

$$Q^{v_i} = H^{v_i}W^Q, K^{v_i} = H^{v_i}W^K, V = H^{v_i}W^V$$

$W^Q \in \mathbb{R}^{d \times d_k}$, $W^K \in \mathbb{R}^{d \times d_k}$, $W^V \in \mathbb{R}^{d \times d_v}$ 是变换矩阵需要学习的参数,由全部节点共享;注意力结构为:

$$Attention(H^{v_i}) = softmax\left(\frac{(H^{v_i}W^Q)(H^{v_i}W^K)^T}{\sqrt{d_k}}H^{v_i}W^V\right)。$$

9. 根据权利要求2所述的面向车辆轨迹大数据的城市区域流量预测方法,其特征在于,所述步骤(5)具体为:

通过 $f()$ 表示整个区域流量预测的模型, (y_1, \dots, y_k) 为历史数据,第 $k+1$ 时刻到 $k+T'$ 的城市区域流量的预测值 $(\widehat{V}_{k+1}, \dots, \widehat{V}_{k+T'})$, T 为模型输入数据的滑动窗口长度, T' 为预测序列的时间长度:

$$\widehat{V}_{k+1}, \dots, \widehat{V}_{k+T'} = f(y_{k-T}, \dots, y_k)。$$

一种面向车辆轨迹大数据的城市区域流量预测系统及方法

技术领域

[0001] 本发明主要涉及智能交通系统领域,尤其涉及一种面向车辆轨迹大数据的城市区域流量预测系统及方法。

背景技术

[0002] 随着人民生活水平不断提高,以及城市化进程的推进。作为人们出行的主要交通工具之一的私家车,其保有量也急剧增加。以中国为例,据统计,截至2019年底,私家车保有量突破2亿辆,全国66个城市汽车保有量超过百万辆,30个城市超过200万辆。各种车辆保有量的迅猛增长与有限城市空间资源之间的矛盾日益加剧,城市道路交通带来了巨大压力,也造成了拥堵、事故和停车难等问题。

[0003] 城市区域交通流量预测作为智能交通领域的研究热点,旨在利用历史城市区域交通流量预测未来交通流量,具体可应用到交通资源合理配置、风险预警、城市规划和出行规划等方面。随着全球定位系统(GPS,global positioning system)等基于位置技术服务在各种设备平台上普及,为实时收集海量的车辆轨迹数据提供了便捷方法。车辆的轨迹特征在一定程度上反映了驾驶人的出行偏好,其轨迹数据记录了驾驶人的出行规律隐含着城市车流量转移的时空特征,展现了城市各区域对人们不同的吸引力。

[0004] ARIMA和Kalman滤波等统计的方法在交通流预测领域得到了广泛应用,但是这些方法只能研究一个单一区域的交通流量,且无法提取有效的时间空间相关性。目前,机器学习方法在该领域获得了不错的成绩,仍然存在一些缺陷:长短期记忆网络,将交通数据视为序列数据,仅能捕获时间相关性;但是仍然不能很好的捕捉整个城市区域之间复杂的时间空间关联性;卷积神经网络方法仅能处理欧几里得空间的张量结构;图结构被证明其在建模非欧几里得型空间数据时的有效性,之前研究通常将交通数据建模为时空图,并使用图神经网络提取地理位置的空间相关性,使用循环神经网络等提取序列时间相关性。但是现有的图卷积神经网络研究主要关注静态的无向图,对顶点之间的动态联系通常没有考虑,因此无法捕获各个时刻变化的全局空间关联,也忽视了各顶点区域功能区域不同而对流量产生的影响。同时现有的工作主要考虑各区域间的流入流出量,却没有对流入的来源地和流出的目的地进行研究,忽略了区域间交通流量变化相互影响,而在全局层面上来看,某个区域的流出流量终将成为其他区域的流入流量,同理该区域的流入流量是由其他区域的流出流量构成的;也忽略了天气、事件以及节假日等外部因素对交通流量的影响。

发明内容

[0005] 本发明的目的在于针对现有技术的不足,提供了一种面向车辆轨迹大数据的城市区域流量预测系统及方法。

[0006] 本发明的目的是通过以下技术方案来实现的:一种面向车辆轨迹大数据的城市区域流量预测系统,所述城市区域流量预测系统包括数据采集模块和流量预测模块;

[0007] 所述数据采集模块采集车辆的轨迹数据和环境信息数据构成历史信息数据集,具

体为:通过具有GPS或北斗定位功能的终端采集不含隐私信息的车辆轨迹数据;通过天气查询服务的API接口获得区域天气数据;通过查询日历统计时间信息和节假日数据;通过网络爬虫技术获取事件数据;通过地图服务提供商提供的店铺信息进行聚类获取空间信息和区域POI信息;所述历史信息数据集构成整体历史流入流出矩阵和城市区域流量转移图;

[0008] 流量预测模块提取车辆的轨迹数据的特征,并对车流量进行预测;包括全局时空特征提取模块、流量转移特征提取模块、流量变化特征融合模块、外部特征嵌入模块、联合特征预测模块;

[0009] 所述全局时空特征提取模块使用 5×5 的二维卷积核对每个时刻的整体历史流入流出矩阵进行局部空间特征提取,得到多个时间片段的局部空间特征;接着将提取到的多个时间片段的局部空间特征堆叠输入多层时空卷积神经网络进行卷积操作,得到历史流量时空特征;

[0010] 所述流量转移特征提取模块采用基于图卷积神经网络联合长短期记忆网络提取城市区域流量转移图的流量转移时空特征;其中,图卷积神经网络用于提取流量转移的空间特征,长短期记忆网络用于提取流量转移的时间特征;

[0011] 所述流量变化特征融合模块:采用一个二维的卷积层和一个激活层对全局时空特征提取模块输出的历史流量时空特征和流量转移特征提取模块输出的流量转移时空特征进行融合,输出融合的流量变化特征;

[0012] 所述外部特征嵌入模块:将时间信息、空间信息和环境信息分别进行编码,并通过一个两层的全连接网络进行嵌入,得到时间嵌入向量、空间嵌入向量和环境嵌入向量,再将上述3个嵌入向量进行融合,得到嵌入的外部特征;

[0013] 所述联合特征预测模块:输入为外部特征嵌入模块输出的融合的外部特征和流量变化特征融合模块输出的流量变化特征,将外部特征与对应时间地点的流量变化特征相加,得到嵌入了外部特征的流量联合特征;采用基于卷积神经网络层和多头注意力网络的卷积注意力单元进行堆叠,学习上一时刻的联合特征中的注意力权重,并以此预测下一时刻的区域流入流出流量。

[0014] 一种面向车辆轨迹大数据的城市区域流量预测方法,具体包括以下步骤:

[0015] (1) 通过数据采集模块记录车辆的轨迹数据,并根据相应的轨迹数据收集相关区域、相关时间的环境信息数据构成历史信息数据集;所述车辆的轨迹数据具体为不含隐私信息的车辆轨迹数据,包括历史行程轨迹数据、车辆的停留时间;所述环境信息数据包括区域天气数据、时间信息、节假日数据、事件数据、空间信息、城市地图、路网信息和区域POI信息;各个区域的全部POI信息聚类得到功能区分类信息;

[0016] (2) 根据步骤(1)采集的历史行程轨迹数据构建各时间片段的整体历史流入流出矩阵;

[0017] (3) 根据步骤(1)采集的城市地图、路网信息和功能区信息等环境信息,结合历史行程轨迹数据构建各个区域之间的区域流量转移图;

[0018] (4) 构建基于联合特征的时空卷积-注意力网络流量预测深度学习模型,包括以下步骤:

[0019] (4.1) 将步骤(2)构建的各历史时间片段的整体流入流出矩阵输入全局时空特征提取模块中,输出历史流量时空特征;

[0020] (4.2) 将步骤(3)中得到的各个区域之间的区域流量转移图输入流量转移特征提取模块,采用基于图卷积神经网络和长短期记忆网络提取城市区域流量转移图的流量转移时空特征;

[0021] (4.3) 利用流量变化特征融合模块将步骤(4.2)得到的流量转移时空特征与步骤(4.1)得到的历史流量时空特征相融合,得到融合的流量时空特征;

[0022] (4.4) 利用外部特征嵌入模块将时间信息、空间信息和环境信息分别进行编码,将步骤(1)采集的环境信息等外部特征的历史信息数据集通过一个两层的全连接网络,同时对步骤(6)输出的融合的流量时空特征的时间信息和空间信息做词嵌入操作,得到嵌入的外部特征;

[0023] (4.5) 将步骤(4.3)得到的融合的流量时空特征和步骤(4.4)得到的嵌入的外部特征输入联合特征预测模块,输出嵌入了外部特征的流量联合特征,下一时刻的区域流入流出流量,得到基于联合特征的时空卷积-注意力网络流量预测深度学习模型;

[0024] (5) 使用步骤(1)采集的历史行程轨迹数据训练步骤(4)输出的基于联合特征的时空卷积-注意力网络流量预测深度学习模型,将该模型训练后输出的预测与真实值进行比较,如误差函数在设定阈值之外,则采用adam优化算法更新模型的参数;如误差函数满足阈值,则保存参数,得到训练好的基于联合特征的时空卷积-注意力网络模型。

[0025] 进一步地,所述步骤(2)具体为:将整个研究区域划分为个 $(\frac{L}{l}) \times (\frac{h}{h})$ 矩形子区域, L 和 h 为整个研究区域的长和宽, l 和 h 为矩形子区域的长和宽。以 τ 为时间间隔,从步骤(1)采集的车辆的历史轨迹数据 (y_1, \dots, y_T) 中,统计第 i 个子区域 G_i 中的车辆流入流出数量,则在第 a 个时间段,即得到在 $((a-1) \times \tau, a \times \tau)$ 时刻整个区域中的车辆流入量 $Vol_{i,in}^a$ 和车辆流出量 $Vol_{i,out}^a$,则第 a 个时间段内整个区域的城市整体流入流出矩阵可以用两个通道 $n \times n$ 的二维矩阵表示为 $Vol^k = \{Vol_{i,in}^a, Vol_{i,out}^a\}$,将 t 个时间片段的车流量按照时间先后顺序排列可得到城市历史的整体流入流出矩阵 $Vol = \{Vol^1, Vol^2, \dots, Vol^t\}$,其中, $Vol \in \mathbb{R}^{t \times n \times n \times 2}$ 。

[0026] 进一步地,所述步骤(3)具体为:将城市区域的路网结构建成一个图结构 $\mathcal{G}_k = (\mathcal{V}, \mathcal{E}_k, A_C)$,其中 \mathcal{V} 是以所有子区域 (G_1, G_2, \dots, G_n) 构成的集合, $|\mathcal{V}| = n \times n$; $A_C \in \mathbb{R}^{n \times n}$ 是连接性矩阵,其中元素 $A_C[i, j]$ 表示的是相应的第 i 个和第 j 个子区域之间空间的连接性;各节点之间的边 ϵ_k 表示第 k 时间段中为各个子区域之间具体的流量转移数量;然后以 τ 时间间隔划分得到 $((k-1) \times \tau, k \times \tau)$ 时间段的城市区域流量转移图 $\mathcal{G}_k = (\mathcal{V}, \mathcal{E}_k, A_C)$, $\mathcal{G}_k \in \mathbb{R}^{N \times d}$,其中 $N = n \times n$ 表示节点的数量, d 示历史观测特征的种类数目。

[0027] 进一步地,所述步骤(4.1)具体为:

[0028] 先使用 5×5 的二维卷积核对每个时刻的城市的整体流入流出矩阵进行局部空间特征提取,得到多个时间片段的局部空间特征;接着将提取到的多个时间片段的局部空间特征堆叠输入多层时空卷积神经网络进行卷积操作得到历史流量时空特征;所述多层时空卷积神经网络由输入层、多个二维卷积层、三维卷积层、池化层、全连接层和输出层等基本的神经网络层构成;第 i 层时空卷积神经网络卷积第 m 个通道的卷积神经元矩阵中位于 (x, y, z) 的输出 e_{im}^{xyz} 如下:

$$[0029] \quad e_{im}^{xyz} = \text{ReLU}(\sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{im}^{pqr} c_{(i-1)m}^{(x+p)(y+q)(z+r)} + b_{im})$$

[0030] 其中, w_{im}^{pqr} 是第i层三维卷积核的m通道的卷积神经元矩阵中位于(p,q,r)上的参数, R_i 是Conv3D卷积核在时间轴上的维度, $c_{(i-1)m}^{(x+p)(y+q)(z+r)}$ 是m通道中位于(x+p,y+q,z+r)的在第i-1层卷积中的输出值, b_{im} 是三维卷积核的偏差向量; ReLU为激励函数;

[0031] 最终, 全局时空特征提取模块输出整体历史流入流出矩阵的历史流量时空特征 $\hat{F}_k \in \mathbb{R}^{n \times n \times 2}, k \in [0, n]$ 。

[0032] 进一步地, 所述步骤(4.2)包括以下子步骤:

[0033] (4.2.1) 利用流量转移特征提取模块, 通过图卷积网络用于提取各子区域间的流量转移空间关联性, 计算公式为:

$$[0034] \quad X_{out} = ReLU(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} X_{in} W)$$

[0035] 其中 $X_{in} = \{G_{t-s_{in}}, G_{t-s_{in}+1}, \dots, G_t\} \in \mathbb{R}^{n \times s_{in}}$ 作为图卷积网络的输入, $X_{out} \in \mathbb{R}^{N \times 1}$ 为网络的输出, $\tilde{A} = A + I_N$, I_N 为N维的单位矩阵, $\tilde{D} = \sum_j \tilde{A}_{ij}$ 为精细度矩阵, W为图卷积网络要学习的参数, s_{in} 为输入图卷积网络的时间片段数;

[0036] (4.2.2) 利用长短期记忆网络提取各子区域间的流量转移的时间关联性和短期时间变化规律, 通过一个全连接网络将流量转移空间关联性和流量转移的时间关联性融合成流量转移时空特征; 历史区域流量转移图 $X_{in} = \{G_{t-s_{in}}, G_{t-s_{in}+1}, \dots, G_t\}$ 作为输入, 通过流量转移特征提取模块进行特征提取, 输出流量转移时空特征 $\hat{T}_k \in \mathbb{R}^{n \times n}, k \in [0, n]$ 。

[0037] 进一步地, 所述步骤(4.3)具体为:

[0038] 利用流量变化特征融合模块, 通过融合车辆出行流量全局时空特征和区域间流量转移特征, 得到流量时空特征 \widehat{Vol}_k :

$$[0039] \quad \widehat{Vol}_k = \sigma(W \cdot Concat(\hat{F}_k; \hat{T}_k) + b)$$

[0040] 其中, W为融合网络层的学习参数, b为偏差向量, Concat(■)表示对括号内元素矩阵进行拼接操作。

[0041] 进一步地, 所述步骤(4.4)具体为:

[0042] 空间信息嵌入: 将节点的向量作为输入, 使用两层的全连接神经网络得到空间嵌入向量 $e_{G_i}^s \in \mathbb{R}^D$;

[0043] 时间信息嵌入: 将历史信息数据集中的每个时间片段进行嵌入, 得到相应的时间嵌入向量: 将一天划分为T个时间段, 使用独热编码将星期几和每天的第几个时间段编码成 \mathbb{R}^7 和 \mathbb{R}^T 的向量, 将其拼接成 \mathbb{R}^{7+T} 的向量, 使用两层的全连接神经网络得到时间嵌入向量 $e_k^t \in \mathbb{R}^D$, 其中k表示的是第k个时间片段;

[0044] 环境信息嵌入: 选择天气、温度、特殊事件、节假日四个环境信息进行特征嵌入, 其中, 天气包含: 晴、雨、雪、风、云、雷, 六种气象, 采用独热编码生成向量, 温度为原温度值; 特殊事件和节假日分别使用一个1维向量表示; 将上述向量进行拼接, 得到 \mathbb{R}^{10} 的向量, 使用两层的全连接神经网络得到第k时间段的环境嵌入向量 $e_{G_i,k}^e \in \mathbb{R}^D$;

[0045] 然后, 将以上3个特征嵌入向量进行融合, 得到嵌入的外部特征 $e_{G_i,k}$:

[0046] $e_{G_i,k} = e_{G_i}^s + e_k^t + e_{G_i,k}^e$ 。

[0047] 进一步地,所述步骤(4.5)具体为:

[0048] 采用注意力网络进行预测,各个节点的注意力Attention(Q,K,V)为:

[0049] $Attention(Q,K,V) = softmax(\frac{QK^T}{\sqrt{d_k}}V)$ 。

[0050] 其中 $Q, K \in \mathbb{R}^{T \times d_k}$, $V \in \mathbb{R}^{T \times d_v}$ 表示各个节点的查询、键和值, d_k 是每个节点的查询和键的维度, d_v 是每个节点的值的维度;

[0051] 在将流量变化特征融合模块输出的流量时空特征 \widehat{Vol}_k 和外部特征 $e_{G_i,k}$ 进行合并 $h_j = \widehat{Vol}^j + e_{G_i,j}$, $j \in [1, k]$,得到 (h_1, \dots, h_k) 并将其堆叠为 $H^{v_i} \in \mathbb{R}^{T \times d}$,上标 v_i 表示其对应的节点;接着对矩阵 H^{v_i} 线性变换为各个节点的查询、键和值:

[0052] $Q^{v_i} = H^{v_i}W^Q, K^{v_i} = H^{v_i}W^K, V = H^{v_i}W^V$

[0053] $W^Q \in \mathbb{R}^{d \times d_k}$, $W^K \in \mathbb{R}^{d \times d_k}$, $W^V \in \mathbb{R}^{d \times d_v}$ 是变换矩阵需要学习的参数,由全部节点共享。注意力结构为:

[0054] $Attention(H^{v_i}) = softmax(\frac{(H^{v_i}W^Q)(H^{v_i}W^K)^T}{\sqrt{d_k}}H^{v_i}W^V)$ 。

[0055] 进一步地,所述步骤(5)具体为:

[0056] 通过 $f()$ 表示整个区域流量预测的模型, (y_1, \dots, y_k) 为历史数据,第 $k+1$ 时刻到 $k+T'$ 的城市区域流量的预测值 $(\widehat{V}_{k+1}, \dots, \widehat{V}_{k+T'})$, T 为模型输入数据的滑动窗口长度, T' 为预测序列的时间长度:

[0057] $\widehat{V}_{k+1}, \dots, \widehat{V}_{k+T'} = f(y_{k-T}, \dots, y_k)$ 。

[0058] 本发明的有益效果是:本发明能够提供提取有效的时空相关性,能够长时间的进行城市区域流量预测。本发明不仅可以应用到城市车辆流量预测,同时可以应用到其他类型的流量预测,比如高速车流量、景区人流量等。甚至是其他领域的时空事件预测的场景,比如外卖订单量预测、网约车乘车需求等。本发明将区域间交通流量变化、天气等外部特征纳入考虑,使得城市区域流量预测结果更加准确。

附图说明

[0059] 图1为本发明一种面向车辆轨迹大数据的城市区域流量预测系统方法的流程图;

[0060] 图2为基于联合特征的时空卷积-注意力网络流量预测深度学习模型的基本结构。

具体实施方式

[0061] 以下结合说明书附图和具体优选的实施例对本发明作进一步描述,但并不因此而限制本发明的保护范围。

[0062] 城市车辆的交通流量由车驶入和驶离城市区域的数量组成。其流量的产生受到区域功能和区域间出行流量动态交互的影响,也与车辆在该段轨迹内停车时长有关。同一时间不同的功能区域有着不一样的交通流量特征:比如早晨时间段流量主要是由住宅区向工

作区转移,而傍晚时间段,则是由工作区向住宅区流入。且不同区域的同一种类型功能区域也有着不同的时间特征:同样是学校,小学初中和高中区域由于放学时间不同,它们有着截然不同的时间特征。如何提取各区域车辆出行的时空特征是准确预测交通流量的关键,同时也要将天气、节假日等其他外部特征对交通流量的影响纳入考虑。

[0063] 本发明公开了一种面向车辆轨迹大数据的城市区域流量预测系统,包括数据采集模块和流量预测模块。

[0064] 所述数据采集模块负责采集车辆的轨迹数据和环境信息数据,具体为:通过包含GPS或者北斗定位功能的终端采集不含隐私信息的车辆轨迹数据;通过天气查询服务的API接口获得区域天气数据;通过查询日历统计节假日数据;通过网络爬虫技术获取事件数据;通过地图服务提供商提供的店铺信息进行聚类获取区域POI信息。所述历史信息数据集构成整体历史流入流出矩阵

[0065] 流量预测模块负责提取历史轨迹数据的多种特征,并对车流量进行预测;包括全局时空特征提取模块、流量转移特征提取模块、流量变化特征融合模块、外部特征嵌入模块、联合特征预测模块。

[0066] 所述全局时空特征提取模块通过多层时空卷积神经网络提取整体历史流入流出矩阵的流量时空特征,所述多层时空卷积神经网络由输入层、二维卷积层、三维卷积层、池化层、全连接层和输出层等基本神经网络层构成。

[0067] 所述流量转移特征提取模块:采用基于图卷积神经网络和长短期记忆网络提取城市区域流量转移图的流量转移时空特征,其中,图卷积神经网络用于提取流量转移的空间关联性,长短期记忆网络用于提取流量转移的时间关联性,最通过全连接层综合以上两种关联性输出流量转移时空特征。

[0068] 所述流量变化特征融合模块:采用一个二维的卷积层和一个激活层对流量时空特征和流量全局时空转移特征进行融合,输出流量变化特征。

[0069] 所述外部特征嵌入模块:将时间特征、空间特征和环境特征分别进行编码,并通过一个两层的全连接网络进行嵌入,得到时间嵌入向量、空间嵌入向量和环境嵌入向量,再将上述3个嵌入向量进行融合,得到融合的外部特征。

[0070] 所述联合特征预测模块:输入为外部特征嵌入模块输出的融合的外部特征和流量变化特征融合模块输出的流量变化特征,将外部特征与对应时间地点的流量变化特征相加,得到嵌入了外部特征的流量联合特征。之后采用基于卷积神经网络层和多头注意力网络的卷积注意力单元进行堆叠,学习之前时刻的联合特征中的注意力权重,并以此预测下一时刻的区域流入流出流量。

[0071] 本发明提出了一种面向车辆轨迹大数据的城市区域流量预测方法,如图1流程图所示,具体包括以下步骤:

[0072] (1) 通过数据采集模块记录车辆的轨迹数据,并根据相应的轨迹数据收集相关区域相关时间的环境信息数据构成历史信息数据集;所述车辆的轨迹数据具体为不含隐私信息的车辆轨迹数据,包含时间、经纬度和车辆的停留时间;所述环境信息数据包括区域天气数据、节假日数据、事件数据、城市地图、路网信息和区域POI信息;各个区域的全部POI信息聚类得到功能区分类信息。

[0073] (2) 根据步骤(1)输出的历史信息数据集构建各时间片段的整体历史流入流出矩

阵,其具体步骤如下;

[0074] 本发明将整个研究区域划分为 $(\frac{L}{l}) \times (\frac{H}{h})$ 个矩形子区域, L 和 H 为整个研究区域的长和宽, l 和 h 为矩形子区域的长和宽, $\frac{H}{h} = n, \frac{L}{l} = n$ 。以 τ 为时间间隔,从步骤(1)采集的车辆的历史轨迹数据 (y_1, \dots, y_T) 中,统计第 i 个子区域 G_i 中的车辆流入流出数量,则在第 a 个时间段,即得到在 $((a-1) \times \tau, a \times \tau)$ 时刻整个区域中的车辆流入量 $Vol_{i,in}^a$ 和车辆流出量 $Vol_{i,out}^a$,则第 a 个时间段内整个区域的城市整体流入流出矩阵可以用两个通道 $n \times n$ 的二维矩阵表示为 $Vol^k = \{Vol_{i,in}^a, Vol_{i,out}^a\}$,将 t 个时间片段的车流量按照时间先后顺序排列可得到城市历史的整体流入流出矩阵 $Vol = \{Vol^1, Vol^2, \dots, Vol^t\}$,其中, $Vol \in \mathbb{R}^{t \times n \times n \times 2}$ 。

[0075] (3) 根据步骤(1)采集的城市地图、路网信息和功能区信息等环境信息,结合历史行程轨迹数据构建各个区域之间的区域流量转移图,其具体方法如下;

[0076] 先构建城市区域流量转移图,将城市区域的路网结构建成一个图结构 $G_k = (V, E_k, A_C)$,其中 V 是以所有子区域 (G_1, G_2, \dots, G_n) 构成的集合, $|V| = n \times n$; $A_C \in \mathbb{R}^{n \times n}$ 是连接性矩阵,其中元素 $A_C[i, j]$ 表示的是相应的第 i 个和第 j 个子区域之间空间的连接性,根据区域之间相连的道路数量和距离计算得到;各节点之间的边 e_k 表示第 k 时间段中为各个子区域之间具体的流量转移数量,并结合每段轨迹的停留时间以及功能区分类等作为边 e_k 的一个权值。若两个节点之间的边 e_k 不存在,则表示子区域之间没有流量转移关系。然后以 τ 时间间隔划分,可得到 $((k-1) \times \tau, k \times \tau)$ 时间段的城市区域流量转移图 $G_k = (V, E_k, A_C)$, $G_k \in \mathbb{R}^{N \times d}$,其中, $N = n \times n$ 表示节点的数量, d 表示历史观测特征的种类数目。

[0077] (4) 构建基于联合特征的时空卷积-注意力网络流量预测深度学习模型,所述基于联合特征的时空卷积-注意力网络流量预测深度学习模型的结构图如图2所示,包括以下步骤:

[0078] (4.1) 将步骤(2)构建的整体历史流入流出矩阵输入全局时空特征提取模块,输出历史流量时空特征,其具体方法如下;

[0079] 由于车辆流入流出轨迹的连续性,任何的流量转移都会经过该区域周围的几个区域,所以先使用 5×5 的二维卷积核为每个时刻的城市的整体流入流出矩阵进行局部空间特征提取,得到多个时间片段的局部空间特征;接着将提取到的多个时间片段的局部空间特征堆叠作为输入,使用多层时空卷积神经网络进行卷积操作,提取车辆流量的全局时空特征。所述多层时空卷积神经网络由输入层、多个二维卷积层、三维卷积层、池化层、全连接层和输出层等基本的神经网络层构成,其中卷积核可以选用大小为 $3 \times 3 \times 3$ 和 $3 \times 3 \times 12$ 的Conv3D三维卷积核。第 i 层时空卷积神经网络卷积第 m 个通道的卷积神经元矩阵中位于 (x, y, z) 的输出 e_{im}^{xyz} 由公式(1)得到。

$$[0080] \quad e_{im}^{xyz} = \text{ReLU}(\sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{im}^{pqr} c_{(i-1)m}^{(x+p)(y+q)(z+r)} + b_{im}) \quad (1)$$

[0081] 其中, w_{im}^{pqr} 是第 i 层三维卷积核的 m 通道的卷积神经元矩阵中位于 (p, q, r) 上的参数, R_i 是Conv3D卷积核在时间轴上的维度, $c_{(i-1)m}^{(x+p)(y+q)(z+r)}$ 是 m 通道中位于 $(x+p, y+q, z+r)$ 的在第 $i-1$ 层卷积中的输出值, b_{im} 是三维卷积核的偏差向量。激励函数ReLU具体表示如公式

(2) :

$$[0082] \quad \text{ReLU}(x) = \max(0, x) \quad (2)$$

[0083] 最终,全局时空特征提取模块输出整体历史流入流出矩阵的历史流量时空特征 $\hat{F}_k \in \mathbb{R}^{n \times n \times 2}, k \in [0, n]$ 。

[0084] (4.2) 将步骤(3)中得到的历史区域流量转移图输入流量转移特征提取模块,利用基于图卷积的长短期记忆网络结构提取区域间的流量转移时空特征,包括以下子步骤;

[0085] (4.2.1) 利用流量转移特征提取模块,通过图卷积网络(GCN)用于提取各子区域间的流量转移空间关联性,详细见公式(3):

$$[0086] \quad X_{out} = \text{ReLU}(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} X_{in} W) \quad (3)$$

[0087] 其中 $X_{in} = \{G_{t-s_{in}}, G_{t-s_{in}+1}, \dots, G_t\} \in \mathbb{R}^{n \times s_{in}}$ 作为图卷积网络的输入, $X_{out} \in \mathbb{R}^{N \times 1}$ 为网络的输出, $\tilde{A} = A + I_N$, I_N 为N维的单位矩阵, $\tilde{D} = \sum_j \tilde{A}_{ij}$ 为精细度矩阵, W 为图卷积网络要学习的参数, s_{in} 为输入图卷积网络的时间片段数。

[0088] (4.2.2) 长短期记忆网络(LSTM)负责提取各子区域间的流量转移的时间关联性和短期时间变化规律,详细见公式(4)、(5):

$$[0089] \quad f_t = \sigma(W_{xf} x_t + W_{hf} h_{t-1} + b_f)$$

$$[0090] \quad i_t = \sigma(W_{xi} x_t + W_{hi} h_{t-1} + b_i)$$

$$[0091] \quad o_t = \sigma(W_{xo} x_t + W_{ho} h_{t-1} + b_o)$$

$$[0092] \quad c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc} x_t + W_{hc} h_{t-1} + b_c)$$

$$[0093] \quad h_t = o_t \odot \tanh(c_t) \quad (4)$$

[0094] 其中 t 表示为第 t 个 LSTM 记忆单元, f_t , i_t 和 o_t 是第 t 个 LSTM 记忆单元的门向量,分别控制该 LSTM 记忆单元的遗忘、更新和输出, c_t 和 $h_t \in \mathbb{R}^{n \times 1}$ 为该记忆单元的状态向量和隐藏

状态, c_{t-1} 和 h_{t-1} 为上一个记忆单元的状态向量和隐藏状态, 激活函数为 $\sigma(x) = \frac{1}{1+e^{-x}}$,

\odot 表示矩阵对应元素相乘, x_t 为记忆单元的输入向量, $W_{xf}, W_{hf}, W_{xi}, W_{hi}, W_{xo}, W_{ho}, W_{xc}, W_{hc}$ 为线性变换矩阵中要学习的参数, b_f, b_i, b_o, b_c 是相应的偏差向量, X_{out} 为为该记忆单元的输入, 图卷积网络的输出。

[0095] LSTM层的表达式简化为公式(5):

$$[0096] \quad h_t, c_t = \text{LSTM}(x_t, h_{t-1}, c_{t-1}) \quad (5)$$

[0097] 流量转移特征提取模块由图卷积网络和长短期记忆力网络结合堆叠构成;最后,通过一个全连接网络将流量转移空间关联性和流量转移的时间关联性融合成流量转移时空特征;历史区域流量转移图 $X_{in} = \{G_{t-s_{in}}, G_{t-s_{in}+1}, \dots, G_t\}$ 作为输入,通过流量转移特征提取模块进行特征提取,输出流量转移时空特征 $\hat{T}_k \in \mathbb{R}^{n \times n}, k \in [0, n]$ 。

[0098] (4.3) 利用流量变化特征融合模块将步骤(4.2)得到的流量转移的时空特征与步骤(4.1)得到的历史流量时空特征相融合,得到融合的流量时空特征,其具体方法如下;

[0099] 从区域全局和划分的较长时间片段来看,某个区域的流入流量是由其他一些区域的流出流量构成的,同样的,它的流出流量将会转化为其他一些区域的流入流量。利用流量

变化特征融合模块,通过融合车辆出行流量全局时空特征和区域间流量转移特征,得到流量时空特征 \widehat{Vol}_k ,如公式(6):

$$[0100] \quad \widehat{Vol}_k = \sigma(W \cdot \text{Concat}(\widehat{F}_k; \widehat{T}_k) + b) \quad (6)$$

[0101] 其中,W为融合网络层的学习参数,b为偏差向量,Concat(■)表示对括号内元素矩阵进行拼接操作。

[0102] (4.4)利用外部特征嵌入模块将时间信息、空间信息和环境信息分别进行编码,将步骤(1)采集的环境信息等外部特征的历史信息数据集通过一个两层的全连接网络做词嵌入(embedding)操作,同时对步骤(4.3)输出的流量时空特征中的时间信息和空间信息做词嵌入(embedding)操作,得到嵌入的外部特征,其具体方法如下:

[0103] 空间信息嵌入:为了建模各个子区域之间的空间联系,并将路网结构信息传入联合预测模块,将节点的向量作为输入,使用两层的全连接神经网络得到空间嵌入向量 $e_{G_i}^s \in \mathbb{R}^D$ 。

[0104] 时间信息嵌入:同时将历史信息数据集中的每个时间片段进行嵌入,得到相应的时间嵌入向量:将一天划分为T个时间段,就可以使用独热编码(One-hot coding)将星期几和每天的第几个时间段编码成 \mathbb{R}^7 和 \mathbb{R}^T 的向量,将其拼接成 \mathbb{R}^{7+T} 的向量,使用两层的全连接神经网络得到时间嵌入向量 $e_k^t \in \mathbb{R}^D$,其中k表示的是第k个时间片段。

[0105] 环境信息嵌入:在此部分,选择天气、温度、特殊事件、节假日四个环境信息进行特征嵌入,其中,天气包含:晴、雨、雪、风、云、雷,六种气象,采用独热编码生成向量;温度为原温度值,为2维向量;特殊事件和节假日分别使用一个1维向量表示,0表示否,1表示是;将以上向量进行拼接,得到 \mathbb{R}^{10} 的向量,使用两层的全连接神经网络得到第k时间段的环境嵌入向量 $e_{G_i,k}^e \in \mathbb{R}^D$ 。

[0106] 然后,将以上3个特征嵌入向量进行融合,得到嵌入的外部特征 $e_{G_i,k}$,如公式(7)所示:

$$[0107] \quad e_{G_i,k} = e_{G_i}^s + e_k^t + e_{G_i,k}^e \quad (7)$$

[0108] (4.5)将步骤(4.3)得到的融合的流量时空特征和步骤(4.4)得到的嵌入的外部特征输入联合特征预测模块,输出嵌入了外部特征的流量联合特征,下一时刻的区域流入流出流量,得到基于联合特征的时空卷积-注意力网络流量预测深度学习模型,其具体方法如下:

[0109] 在联合特征预测模块中,采用注意力网络进行预测,各个节点的注意力Attention(Q,K,V)由以下公式进行计算,如公式(8)所示

$$[0110] \quad \text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (8)$$

[0111] 其中 $Q, K \in \mathbb{R}^{T \times d_k}$, $V \in \mathbb{R}^{T \times d_v}$ 表示各个节点的查询、键和值, d_k 是每个节点的查询和键的维度, d_v 是每个节点的值的维度。

[0112] 在将流量变化特征融合模块输出的流量时空特征 \widehat{Vol}_k 和外部特征 $e_{G_i,k}$ 进行合并

$h_j = \widehat{Vol}^j + e_{G_{i,j}}, j \in [1, k]$, 得到 (h_1, \dots, h_k) 并将其堆叠为 $H^{v_i} \in \mathbb{R}^{T \times d}$, 上标表示其对应的节点为 v_i 。接着对矩阵 H^{v_i} 线性变换为查询 Q^{v_i} 、键 K^{v_i} 和值 V , 如公式 (9) 所示:

$$[0113] \quad Q^{v_i} = H^{v_i}W^Q, K^{v_i} = H^{v_i}W^K, V = H^{v_i}W^V \quad (9)$$

[0114] $W^Q \in \mathbb{R}^{d \times d_k}, W^K \in \mathbb{R}^{d \times d_k}, W^V \in \mathbb{R}^{d \times d_v}$ 是变换矩阵需要学习的参数, 由全部节点共享。注意力结构 $Attention(H^{v_i})$ 能被写为以下形式如公式 (10) 所示:

$$[0115] \quad Attention(H^{v_i}) = softmax\left(\frac{(H^{v_i}W^Q)(H^{v_i}W^K)^T}{\sqrt{d_k}} H^{v_i}W^V\right) \quad (10)$$

[0116] (5) 使用历史数据对步骤 (4) 构建的基于联合特征的时空卷积-注意力网络 (MSTC-AN) 流量预测深度学习模型进行训练, 将模型训练后输出的预测与真实值进行比较, 如误差函数在设定阈值之外, 则采用adam优化算法更新模型的参数; 如误差函数满足阈值, 则保存参数, 得到训练好的基于联合特征的时空卷积-注意力网络模型。

[0117] 通过 $f(\cdot)$ 表示整个区域流量预测的模型如公式 (11), (y_1, \dots, y_k) 为历史数据, 第 $k+1$ 时刻到 $k+T'$ 的城市区域流量的预测值 $(\hat{V}_{k+1}, \dots, \hat{V}_{k+T'})$, T 为模型输入数据的滑动窗口长度, T' 为预测序列的时间长度:

$$[0118] \quad \hat{V}_{k+1}, \dots, \hat{V}_{k+T'} = f(y_{k-T}, \dots, y_k) \quad (11)$$

[0119] 本实施例中阈值设定为1, 可以根据预测精确度的要求调整阈值。模型通过训练使得输出的预测值与真实值的loss函数最小, 该模型中, loss函数采用以下方法计算, 如公式 (12):

$$[0120] \quad loss = \sum_{t=1}^{k+T} \sum_{i=1}^{T'} \|V_{t+T+i} - \hat{V}_{t+T+i}\| \quad (12)$$

[0121] 如表1所示为基于联合特征的时空卷积注意力网络的城市车流量预测框架方法在深圳数据集上进行多步预测 (即预测序列的长度 $T' = 3$ 时), 与ARIMA (差分自回归移动平均模型)、SVR (支持向量机线性回归模型)、StepDeep (基于3维卷积的流量预测模型)、FC-LSTM (全连接长短期记忆网络模型)、T-GCN (时间图卷积网络模型)、MDL的RMSE (均方根误差) 和MAPE (平均绝对百分比误差) 对比;

[0122] 表1

模型	30 分钟		60 分钟	
	RMSE	MAPE	RMSE	MAPE
ARIMA	16.543	14.447%	21.724	19.347%
SVR	10.492	9.384%	17.583	18.885%
StepDeep	9.565	9.280%	16.443	16.589%
FC-LSTM	9.483	8.948%	16.157	15.942%
T-GCN	9.528	8.473%	13.691	14.018%
MDL	9.717	8.546%	12.435	13.735%
MSTC-AN	8.518	7.973%	10.931	9.682%

[0125] 由表1可知,基于联合特征的时空卷积-注意力网络 (MSTC-AN) 流量预测深度学习模型,在时间间隔为30分钟和60分钟的实验中的RMSE和MAPE都最小,与其他预测模型相比有着更为精确的预测结果。

[0126] 上述只是本发明的较佳实施例,并非对本发明作任何形式上的限制。虽然本发明已以较佳实施例揭露如上,然而以限定本发明。任何熟悉并非用本领域的技术人员,在不脱离本发明技术方案范围的情况下,都可利用上述揭示的技术内容对本发明技术方案做出许多可能的变动和修饰,或修改为等同变化的等效实施例。因此,凡是未脱离本发明技术方案的内容,依据本发明技术实质对以上实施例所做的任何简单修改、等同变化及修饰,均应落在本发明技术方案保护的范围内。

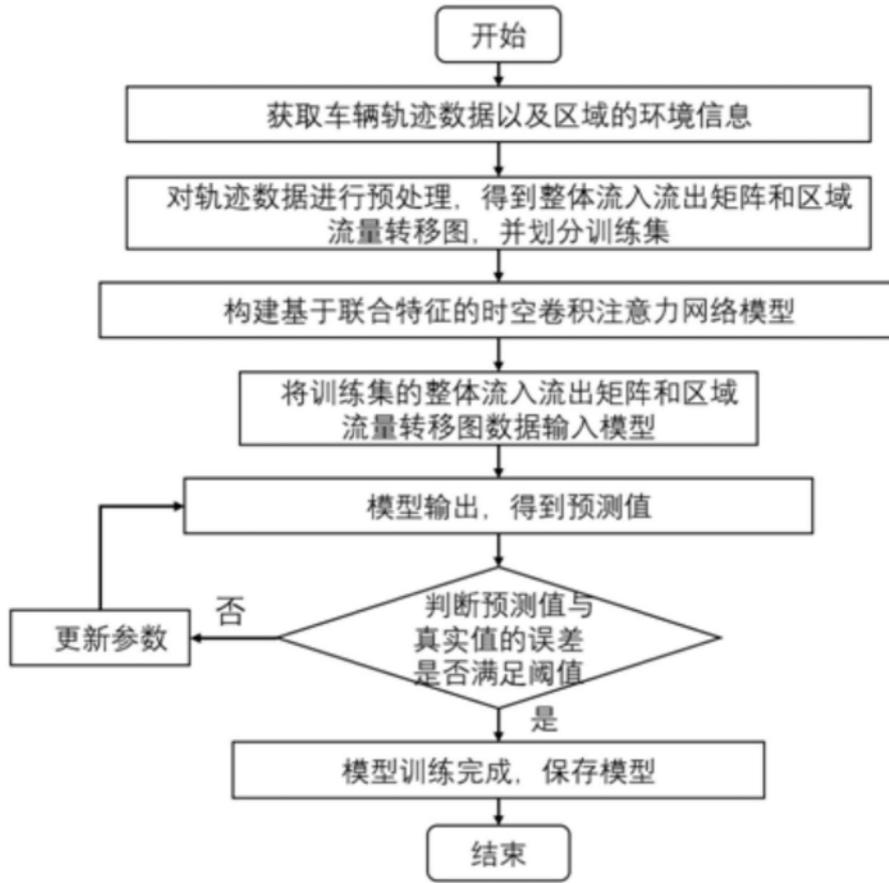


图1

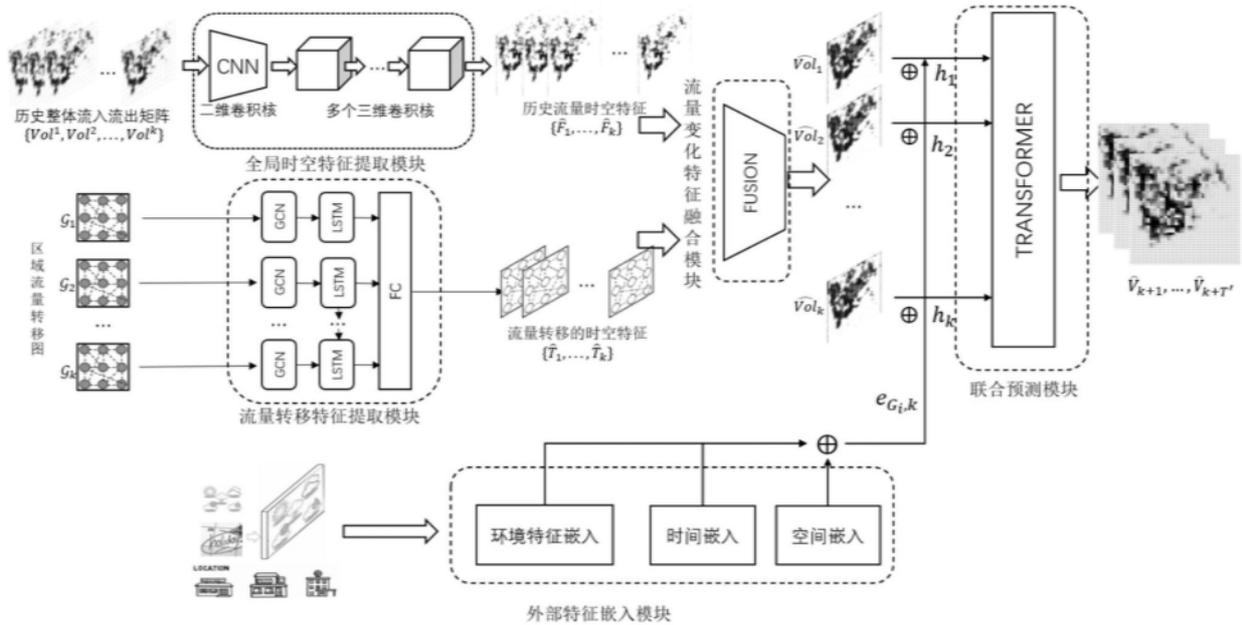


图2