

面向城市人群时空热点预测的混合神经网络

游 兰¹, 张涵钰¹, 韩凡宇¹, 金 红¹, 崔海波¹,
何 渡², 汪坤钰¹, 郑巧仙¹

(1. 湖北大学 计算机与信息工程学院, 湖北 武汉 430062;
2. 湖北省科技信息研究院, 湖北 武汉 430071)

摘要:城市人群时空热点预测对公共安全应急决策有重要的意义。城市人群热点区域往往伴随时间空间的推移而快速演化,如何发掘利用热区的时空相关性是精准预测城市人群热点变化趋势的关键。该文提出了一种基于深度学习的混合神经网络模型,即 CNN-Seq2Seq-Attention(CSA),用来预测连续一周城市人群热点的时空变化分布。为了较好捕捉热点区域的空间信息,CSA 模型采用卷积神经网络提取城市热点区域的特征向量,同时,考虑到长时有序数据的周期性,CSA 结合 Seq2Seq 与 Attention 注意力机制建模人群热点在连续特征日下相同时间片段的时间周期规律。其中,针对人群热点随时间变化的不均匀特性,CSA 采用了一种改进的时间片段划分方法,即,基于生活作息的不等长时间段作为数据划分依据。实验使用了连续3个月的城市出租车轨迹数据集,将每周7天标识成7个特征日,每个特征日被划分为7个时间片段,采用预测结果的均方根误差(RMSE)为评估指标。实验结果表明,较传统的 PreHA、HA 和 ARIMA 方法,CSA 模型效果更好,同时,相较 Seq2Seq 和 CNN-Seq2Seq 模型,CSA 模型预测误差最大分别降低 6.4% 和 3.8%。

关键词:社会计算;时空数据;混合神经网络;城市人群热点;时空相关性

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2023)06-0194-08

doi:10.3969/j.issn.1673-629X.2023.06.029

A Deep Hybrid Neural Network Model Oriented to Urban Crowd Spatio-temporal Hotspot Prediction

YOU Lan¹, ZHANG Han-yu¹, HAN Fan-yu¹, JIN Hong¹, CUI Hai-bo¹,
HE Du², WANG Kun-yu¹, ZHENG Qiao-xian¹

(1. School of Computer Science and Information Engineering, Hubei University, Wuhan 430062, China;
2. Hubei Academy of Scientific and Technical Information, Wuhan 430071, China)

Abstract: The prediction of the urban crowd hotspots is of great significance to the public security emergency decision. The urban crowd hotspots always evolve rapidly with the changes of time and space. The key to accurately predict the trends of the urban crowd hotspots is how to explore and utilize the spatio-temporal correlations of the hotspots. We propose a hybrid neural network model based on deep learning, namely CNN-seq2seq-attention (CSA) model, for the urban crowd hotspots predictions. Considering the spatial correlations among hotspots areas, the eigenvectors of urban hotspots are extracted through the CNNs model. Also, CSA is combined the Seq2Seq and Attention mechanism to model the time cycle rules of crowd hotspots for the certain time segment in continuous days. Meanwhile, in view of the uneven characteristics of urban crowd hotspots changing with time, an improved time divisions method is designed in CSA, which is an unequal time periods division method based on urban daily schedules. In this paper, the urban taxi track dataset of 3 consecutive months is used in the experiment. 7 days per week are identified as seven featured-days, each of which is divided into 7 time segments. The mean square error (RMSE) is the evaluation index. The experimental results show that the traditional methods including PreHA, HA and ARIMA are not as good as neural networks, and CSA can get better accuracy. Moreover, compared with Seq2Seq and CNN-Seq2Seq, CSA can reduce the prediction errors by 6.4% and 3.8% respectively.

Key words: social computing; spatio-temporal data; hybrid neural network; urban crowd hotspots; spatio-temporal correlation

收稿日期:2022-06-30

修回日期:2022-10-30

基金项目:国家自然科学基金资助项目(61803149);湖北省重点专项(2022BAA044);湖北省教育厅科学技术研究计划重点项目(D20201006)

作者简介:游 兰(1978-),女,博士,教授,CCF 会员(H8967M),研究方向为时空大数据、自然语言处理(NLP)及社会计算等;通讯作者:崔海波(1984-),男,硕士,副教授,研究方向为软件工程、系统集成、大数据与人工智能。

0 引言

城市人群热点指的是一个相较其他区域具有更多的人类活动、居民出行次数以及交通流量较大的地理区域^[1],相关预测研究对于城市感知和公共安全应急决策具有重要的实际意义^[2]。

近年来,许多国内外学者围绕基于出租车轨迹的城市热点区域展开研究。这些方法大多使用空间聚类方法进行城市热点区域的空间规律分析,主要预测较短时间范围内的热点趋势^[3-4]。城市人群热点区域往往伴随时空环境变化而快速演化,存在典型的时空相关性和时间相关性特点^[5]。如何发掘利用热点区域的时空相关性是精准预测城市人群热点变化趋势的关键。

传统时空数据预测研究常常采用单一卷积神经网络(convolution neural networks, CNNs)或循环神经网络(recurrent neural networks, RNNs)进行建模,忽略了时空同时相关性。同时,也未考虑生活作息、天气和环境等因素对城市人群活动可能造成的影响^[6]。通过结合卷积网络和循环网络模型,可用于捕捉时空演变规律^[7]。

近年来,混合神经网络已经被广泛应用在各个研究领域,如游戏策略、语音识别等^[8-10]。如何将城市人群的作息规律用于时空热点预测是研究的难点。因此,该文提出了一种面向城市人群时空热点预测的深度混合神经网络模型(CNN-Seq2Seq-Attention, CSA)结合生活作息规律的时空相关性对人群热点分布进行预测。

贡献包括3个方面:

(1)提出一种基于城市人群生活作息的不等长时间片段划分方法。通过在数据中区分不同作息时间段中人群热点的空间分布差异,帮助预测模型更准确地捕获不同作息片段间的人群流动规律,从而提高城市热点预测的准确性。

(2)针对城市人群活动中存在的高度时空相关性现象,提出了一种深度混合神经网络模型(CSA)用于城市人群热点预测。该模型通过CNN提取不同区域网格间的空间相关性特征,并结合Seq2Seq和Attention注意力机制,对人群热点在连续特征日中同等时间片段的时间相关性进行建模。通过对人群热点的时空属性进行多维建模,从而有效避免神经网络模型在预测时考虑因素不全的问题。

(3)采用了大规模真实的出租车轨迹数据进行实验,与传统模型及其他预测神经网络模型进行了对比实验,验证了CSA模型的有效性和优越性,并对城市人群热点变化规律进行相关分析。

1 相关工作

对于未来时空人群热点预测,大多数学者常使用时序模型来处理时空数据。常见的时序预测模型包括移动平均自回归模型(ARMA)及其变种,如差分整合移动平均自回归模型(ARIMA)等^[11-12]。上述模型难以发掘时空数据中的空间相关性规律。

在城市热点预测研究中,越来越多的学者通过多种神经网络的结合来得到更为高效、准确率更高的模型。Ma等人^[13]通过二维时空矩阵将时空交通动力学转化为能够描述交通流时空关系的图像,并将CNN应用到该图像上提取出交通特征。Zhang等人^[14]提出了基于CNN的深度时空模型(Deep-ST),该模型将时空数据网格化,并将模型分为最近、近期和远期三个模块进行卷积操作,后通过通道进行数据连接,还加入了天气、节假日特征进行特征融合来进行城市交通量的预测。Zhang等人^[15]在原有模型基础上,提出了时空残差网络(ST-ResNet)。ResNet残差模块的加入使模型还能对远空间相关特征进行卷积挖掘。Deep-ST和ST-ResNet模型若要对未来多个时间片段的热点情况进行预测,需要通过迭代的方式完成。

基于CNN和RNN的各自特点,越来越多的研究者将两种神经网络结合使用。Srivastava等人^[16]提出使用RNN来对时空数据进行预测。由于LSTM节点内部的门结构较为复杂,数据中相当一部分信息在压缩过程中被丢弃。Rodrigues等人^[17]提出了一种结合字嵌入、一维CNN、RNN和注意力机制的模型来预测出租车需求量。Du等人^[18]提出一种基于卷积LSTM和注意力机制的深度神经网络模型(STATF)来处理城市交通流预测任务,考虑了交通流数据中的时空相关性,能更好地预测城市交通流。Lai等人^[19]提出一种基于卷积LSTM和Stack-LSTM的模型(STPM),能够同时捕捉事务时间依赖性、空间相关性与外部影响因素,对公交车到站时间的预测较准确。这些研究已经开始关注交通预测中的时间或空间相关性。

Wang等人^[20]借助百度热力图,并结合Arc GIS,分析了武汉主城区人口在工作日和休息日流动的时空特征。Wang等人^[21]对传统基于DBSCAN算法进行了改进,更好地实现了出行热点的聚类分析,为缓解交通压力、改善居民出行体验提供一定参考。Liu等人^[22]使用图卷积算子来探索区域之间的相关性以建立多模态,并将带有注意力机制的基于图卷积神经网络应用于模型,以更好地建立相关区域关联。

该文提出的CSA模型结合了RNN中的Seq2Seq神经网络,动态地呈现出轨迹数据的长期时间特征。通过Seq2Seq提取的长期时间特征,再将Attention融

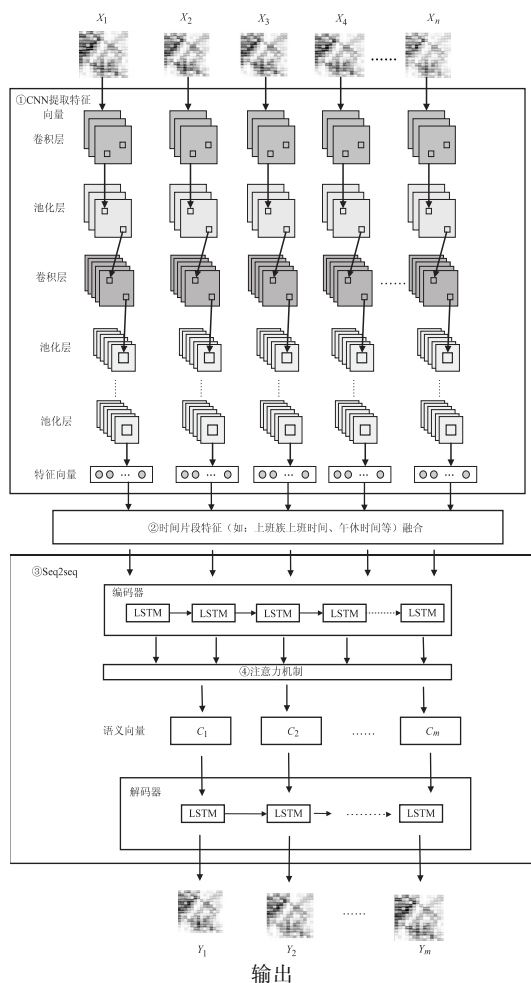
入模型中来学习连续多天之间的城市热点变化关系。采用基于城市人群生活作息的时间片段划分方法,将一天内的 24 小时划分成不等长的时间片段。并通过特征融合,提高模型的准确性。

2 CSA 城市热点预测模型

该文提出的 CSA 模型采用城市人群分布的历史时空特征对未来一段时间的城市人群分布进行预测,充分考虑了城市人群的空间相关性、时间相关性、生活作息规律等特征。

CSA 模型包括四个部分,模型结构框架如图 1 所示。模型利用城市热点分布的近期历史数据预测后续连续多天的城市热点变化趋势。

输入
(连续 n 天相同时间段下的人群密集分布矩阵,如 $X_n =$

$$\begin{pmatrix} x_{11} & \cdots & x_{1j} \\ \vdots & \ddots & \vdots \\ x_{i1} & \cdots & x_{ij} \end{pmatrix}$$


输出
(连续 m 天相同时间段下的人群密集分布矩阵,如 $Y_m =$

$$\begin{pmatrix} y_{11} & \cdots & y_{1j} \\ \vdots & \ddots & \vdots \\ y_{i1} & \cdots & y_{ij} \end{pmatrix}$$

图 1 CSA 模型框架

在图 1 中,①显示了 CSA 模型的 CNN 部分。CSA 模型利用 CNN 中的滤波器提取热点区域的局部区域信息,并通过迭代卷积和池运算提取较远区域的空间相关特征。

②是时间划分的语义特征部分。该文将时间段特征分开划分,在 CNN 提取特征向量后,将时间段特征作为特征向量的一个维度,对每个特征向量所处的时间段进行缝合和标记。

在③中,Seq2Seq 编码器通过对卷积网络提取的城市空间特征进行时间序列特征提取,通过 LSTM 的可记忆性提取该时间段的最近趋势特征。解码器使用 LSTM 对下一时期的城市热点区域进行明确的时间序列预测。

④为注意力机制部分。该文将一周 7 天标识为不同的特征日,并在模型中引入注意机制,以自适应地获取特征日之间的关系。

2.1 问题定义

对城市人口流量预测问题进行了形式化描述,根据经纬度将一个城市均匀划分为 $V \times W$ 的网格,网格中的某个单元 (j, k) 表示一个区域。将一天 24 小时划分为 $t \in (1, 2, \dots, d)$ 个不等长的时间片段, T_n^t 表示在时间片段 t 下连续 n 天人群流量数据。

$$T_n^t = [X_1^t, X_2^t, \dots, X_n^t] \quad (1)$$

X_i^t 表示在时间片段 t 下第 i 天的人群流量。

$$X_i^t = \begin{pmatrix} x_i^{11} & x_i^{12} & \cdots & x_i^{1W} \\ x_i^{21} & x_i^{22} & \cdots & x_i^{2W} \\ \vdots & \vdots & \ddots & \vdots \\ x_i^{V1} & x_i^{V2} & \cdots & x_i^{VW} \end{pmatrix} \quad (2)$$

x_i^{jk} 表示在第 i 天、第 j 行、第 k 列个区域的人群流量。

未来 m 天的人群流量为该文的预测目标。设学习函数为 $h(\cdot)$, 该函数使用历史 n 天的流量预测未来 m 天的流量,如公式(3)。

$$T_n^t \xrightarrow{h(\cdot)} T_{n+m}^t \quad (3)$$

2.2 城市人群热点空间相关性建模

城市不同区域人群热点之间可能存在某种空间模式下的联系,这种模式可能是并发关系,也可能是前后关系。比如,某个繁华的商圈附近的区域会由于紧邻该商圈而出现人流量、交通量较多的情况,因此不同的热点区域之间可能存在空间模式下的并发关系。上下班高峰期时,由于人们是从工作区域回到生活区域,因此在高峰期前半段时间,工作区域及其附近的区域人流量大、交通密度高,后半段时间则是生活区域以及附近的区域人流量大、交通密度高,因此热点区域之间可能存在空间模式下的先后关系。所以城市热点区域的

分布具有空间相关性。

当 CNN 在图像处理上应用时,能够通过滤波器最大程度地利用图片的局部信息对事物进行特征提取,然后根据提取出来的特征对该事物进行分类或者预测^[23]。

CNN 通常由 N 层组成,假设在 CNN 第 l 层的输入为 $M * N * K$ 的矩阵,那么第 l 层用来提取空间特征的滤波器可以被描述为 $M * N * K$ 的矩阵,故第 l 层的输入可以由以下子式表示:

$$U_{i,j,m} = \sum_{k=0}^{K-1} \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} \{ W_{i+p}^{l-1} * X_{p,q,k,m} + B_{i,j,m} \} \quad (4)$$

其中, $l \in \{1, 2, \dots, N\}$, W 为 $l-1$ 层滤波器中的权重值。

图 1 中①为文中模型的 CNN 部分,利用 CNN 中的滤波器提取热点区域的局部区域信息,并通过反复的卷积和池化操作,提取出较远地区的空间相关特征。

2.3 基于居民生活作息的时间片段划分

该模型将时间分为不同的特征日,同时根据人们的作息特点将一天划分为不同的时间片段。在 CNN 提取特征向量后,将时间片段特征作为特征向量的一个维度,对每个特征向量所处的时间片段进行拼接标记,以此来提高模型的预测准确率。

基于城市人群的时空活动规律分析,考虑一天中不同时间片段下城市热点区域分布不同的情况,根据人们的作息特点将一天的 24 小时进行了时间片段划分,共分为表 1 中的 8 个时间片段。若将 24 小时视作集合 D , D 可表示为:

$$D = \{t_i \mid 0 \leq i \leq 7\}$$

时间分段见表 1。

表 1 时间分段

符号表示	时间段	该时间段作息特点
t_0	23:00—03:59	上半夜
t_1	04:00—06:59	下半夜
t_2	07:00—08:59	早晨上学上班高峰期
t_3	09:00—11:59	早上上学、上班族上班时间
t_4	12:00—13:59	午休时间
t_5	14:00—17:59	下午上学、上班时间
t_6	18:00—20:59	下班放学时间段,回家或外出逛街
t_7	21:00—22:59	晚间活动结束时间

表 1 展示了一天 24 小时划分成的 8 个时间片段以及各时间段的作息特点。其中,由于 t_0 时段人们的出行流量较低,故未对该时间段的热点区域进行分析。

对于一周 7 天而言,人们的出行规律也有差异,城市的热点区域分布在一周 7 天内也会存在差异。为了

进一步提高对未来一周的热点区域分布的预测准确性,将一周划分为 7 个特征日。一周 7 天用集合 W 表示为:

$$W = \{ \text{Mon, Tue, Wed, Thu, Fri, Sat, Sun} \}$$

因此, W 可被描述为:

$$W = \{ D_i \mid 1 \leq i \leq 7 \}$$

2.4 城市人群热点时间相关性建模

为了捕获人群热点的时间相关性以及预测未来一段时间的热点区域分布,使用 Seq2Seq^[24] 作为热点预测模型。其中, LSTM^[25] 和 GRU^[26] 常用作 Seq2Seq 模型的编码器和解码器。

Seq2Seq 模型利用两个 RNN,其中一个 RNN 作为 encoder,即编码器,负责将输入序列压缩成中间状态向量 C ,生成的状态向量 C 称作是这个输入序列的语义。另一个 RNN 作为 decoder,即解码器,负责将中间状态向量 C 进行解码。

通常情况下,Seq2Seq 只会产生一个语义向量。该文使用的 Seq2Seq 模型中的 RNN 单元为 LSTM。

CSA 模型通过在 Seq2Seq 模型的编码器与解码器之间加入 Attention 机制考虑特征日对人群热点预测的影响,使得捕获的时间相关性符合人群每周的出行规律,提高了预测准确度。

公式如下:

$$P(y_i \mid \{y_1, y_2, \dots, y_{i-1}\}, X) = g(y_{i-1}, s_i, c_i) \quad (5)$$

$$s_i = f(s_{i-1}, y_{i-1}, c_i) \quad (6)$$

$$c_i = \sum_{j=1}^{T_x} a_{ij} h_j \quad (7)$$

式中, g 函数代表的是非线性激活函数, s_i 表示解码器 i 时刻的隐藏状态,这里的条件概率与每个目标输出 y_i 相对应的内容向量 c_i 有关。在 Seq2Seq 模型中,只有一个语义向量 $c \cdot s$ 为隐藏层输出。式 7 中 c_i 是由编码时的隐藏向量序列 (h_1, \dots, h_{T_x}) 按权重相加得到的。

将隐藏向量序列按权重相加,表示在生成第 j 个输出时的注意力分配是不同的。 a_{ij} 的值越高,表示第 i 个输出在第 j 个输入上分配的注意力越多,在生成第 i 个输出的时候受第 j 个输入的影响也就越大。

a_{ij} 的权重值由第 $i-1$ 个输出隐藏状态 s_{i-1} 和输入中各个隐藏状态共同决定,即:

$$e_{ij} = b(s_{i-1}, h_j) \quad (8)$$

$$a_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^{T_x} \exp(e_{ik})} \quad (9)$$

s_{i-1} 先与每个 h 分别计算得到一个数值 e_{ij} ,然后使用 softmax 函数得到 i 时刻的输出在 T_x 个输入隐藏状态中的注意力分配向量。这个分配向量也就是计算式(7)中 c_i 的权重。

3 实验及分析

3.1 实验数据集

城市出租车不受线路和时间的约束,是最灵活、覆盖范围最广的轨迹数据,且精度较高、较少涉及隐私问题,常被作为轨迹数据研究和应用的主要数据集。

轨迹点 g 具有 T_TargetID(车牌号)、T_UTCTime(时间戳)、T_Longtitude(经度)、T_Latitude(纬度)、T_Speed(行驶速度)、T_Heading(行驶方向)、T_Status(搭客状态)等属性。由于建立的模型只需要考虑轨迹点所在的时间和所处位置,因此只保留了 T_UTCTime、T_Longtitude 和 T_Latitude 这三个属性特征值。

该文使用了中国武汉某区域内三个月的出租车数据进行实验,数据集的统计信息如表 2 所示。

表 2 数据集概况

数据集	Taxi	备注
数据类型	Taxi GPS	
城市	武汉	
维度范围	[30.515 224, 30.630 852]	
经度范围	[114.254 328, 114.379 643]	
时间跨度	30/12/2013 至 7/4/2014	
时间区间总数	504	
时间片划分	一天划分为 7 个 时间片段	根据出行 规律划分
区域网格数量	(14, 15)	
区域轨迹点数 取值范围	(0, 5 486)	
外部数据	时间特征	范围[1, 7]

3.2 数据预处理

将武汉市纬度在 30.515 224 至 30.630 852,经度在 114.254 328 至 114.379 643 的区域划分成为 14×15 的网格,每个网格的长和宽大约为 1.0 km。

此外,由于 RNN 算法对数字较为敏感,直接将轨迹点数带入训练会导致误差较大。在代入训练前,采用 Min-Max 方法将区域轨迹点数归一化到 $[-1, 1]$ 范围内,最终在比较预测值和真实值时,再将预测值重新还原到原来的数字。归一化算法如下:

$$p' = 2 \times \frac{p_{\max} - p}{p_{\max} - p_{\min}} - 1 \quad (10)$$

其中, p 为归一化前的任一时间区域网格轨迹数目, p_{\max} 为所有时间区域网格轨迹数目的最大值, p_{\min} 为所有时间区域网格轨迹数目的最小值, p' 为归一化后的网格点轨迹数目。

3.3 实验对比模型

文中模型对比方法如下:

(1) PreHA: 将上一周某个时间片段该区域的轨迹点个数,作为下一周该时间段该区域下的轨迹点个数。

(2) HA: 将前几周该时间段下该区域的轨迹点个数平均值,作为下一周该时间段该区域下的轨迹点个数。

(3) ARIMA 模型: 是一种广泛应用的时间序列预测方法。

(4) Seq2Seq: 不考虑空间相关性,训练 Seq2Seq 模型利用前两周数据对下一周的区域轨迹点个数进行预测。

(5) CNN_Seq2Seq: 考虑空间相关性和时间相关性,使用 CNN 和 Seq2Seq 联合预测。

该文使用均方根误差 RMSE (Root Mean Square Error) 作为模型预测效果的评价指标:

$$RMSE = \sqrt{\frac{1}{M * N * T} \sum_i (x_i - \hat{x}_i)^2} \quad (11)$$

其中, $M * N$ 为区域的网格数量, T 为预测的时间片段总数, x_i 是真实值, \hat{x}_i 是预测值。

3.4 实验参数设置

在训练集上验证模型的准确性,对比实验中使用的滤波器数目分别为 16、32 和 64,每个滤波器都为 $3 * 3$ 的大小。其中 Seq2Seq 模型编码器和解码器的步长分别为 14 和 7。模型训练时的学习速率大小为 0.001。卷积操作后的激活函数和输出层的激活函数分别为 ReLU 和 Tanh。

模型的超参数设置如表 3 所示。

表 3 超参数设置

参数	值	备注
滤波器数目	(16, 32, 64, 128)	卷积层中的滤波器数目
滤波器大小	$3 * 3$	每个滤波器数目的大小
Dropout 大小	0.001	Dropout
时间依赖长度	(14, 7)	输入为 14, 输出为 7
学习速率	0.001	学习速率
激活函数	ReLU	卷积操作后的激活函数
激活函数	Tanh	输出层的激活函数
优化器	Adam	训练时用的优化器


3.5 实验结果分析

3.5.1 不同参数影响对比


针对 CSA 模型中各种参数设置对时间预测的影响进行一系列实验,选取实现平均误差最低的模型参数,具体包括 CSA 中 LSTM_num、卷积层数等对特征日、时间片段的影响。将实验结果绘制成图 2 和图 3。其中,图像的横轴代表特征日 ($W_{1..7}$ 定义见 2.3 节) 和特征时间片段 ($t_{1..7}$ 定义见 2.3 节)。图像的纵轴代表均方根误差 (RMSE)。图像绘制的曲线代表各模型参

数对特征日、特征时间片段的均方根误差影响。

图 2 展示了 CSA 模型中 LSTM 个数对特征日、特征时间片段的均方根误差影响效果。比较 3 种 LSTM 个数参数,当参数值为 250 时,平均 RMSE 最小。




(a) LSTM_num 对特征日的作用效果




(b) LSTM_num 对特征时间的作用效果

图 2 CSA 模型 LSTM_num 对特征日和特征时间的作用效果



(a) 卷积层数对特征日的作用效果



(b) 卷积层数对特征时间片段的作用效果

图 3 CSA 模型卷积层数对特征日和特征时间片段的作用效果

图 3 展示了 CSA 模型中卷积层数对特征日、特征时间片段的均方根误差影响效果。比较 4 种卷积层数参数,当参数值为 2 时,平均 RMSE 最小。

综上所述,在 CSA 模型中时间特征维度为 20,滤波器数目为 32, LSTM_num 为 250 和卷积层数为 2 时,模型训练出的效果达到最佳状态, RMSE = 73.265 542 5。

3.5.2 与不同模型对比

将 CSA 模型与 3.3 节提到的 5 种基准模型进行对比。如图 4 所示,较为传统的 PreHA、HA 和 ARIMA 时序模型没有神经网络算法 (CNN、CNN-Seq2seq) 的实验效果好。在对比实验的 3 个神经网络模型中, CSA 模型较 Seq2Seq 而言,不仅能够利用 CNN 提取空间特征,还能够在 Attention 机制的作用下,较 CNN-Seq2Seq 模型而言,又提高了准确率。因此,在 6 个模型中, CSA 模型效果最好。

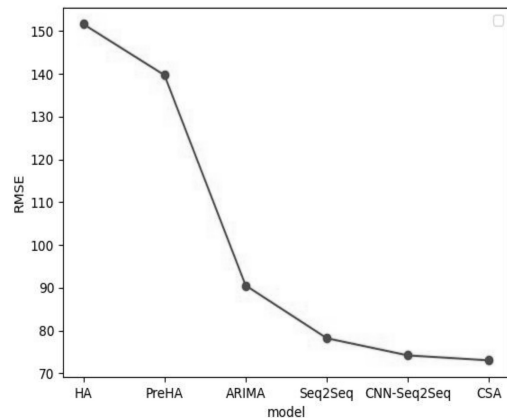



图 4 模型实验结果


3.6 城市人群热点时空分析

为了验证人们每周的出行规律以及每日的生活作息规律能够被 CSA 模型学习并产生作用,随机采用了一组城市人群流量热点的预测结果进行了城市热点的时空热力分析及可视化对比。


图 5 中(a)~(d)是 2014 年 3 月 4 日周二 7:00—8:59、18:00—20:59 以及前一周周二 2 月 25 日相应时间段的时空热力分布。其中,序号①对应的是汉口火车站及周辺区域。序号②对应的是武汉市洪山区光谷广场及周围住宅区。从四张图可以看出,序号①区域即汉口火车站附近在大多数时间片段下人流量远远高于其它区域。对比图(a)(b)与图(c)(d)可以看出,相同特征日的人流量热点分布具有很大相似性。由此证明,CSA 模型通过划分每周的特征日以及每日的不等长时间片段考虑了出行规律和作息规律对人群流量的影响。并且这些规律能被 CSA 模型学习并产生作用。这是 CSA 模型预测准确度高于其余模型的重要原因。




(a) 2014 年 3 月 4 日 7:00-8:59



(b) 2014 年 3 月 4 日 18:00-20:59



(c) 2014 年 2 月 25 日 7:00-8:59



(d) 2014 年 2 月 25 日 18:00-20:59

图 5 分时段城市人群热点的时空热力分析

4 结束语

挖掘和利用热区的时空相关性是精准预测城市人群热点变化的关键难点。基于城市热点区域的时间相关性、空间相关性特点以及城市居民生活作息规律,提出了一种面向城市人群时空热点预测的深度混合神经网络模型 CSA。CSA 模型结合了 Seq2Seq 神经网络以动态呈现轨迹数据的长时时间特征,通过 Seq2Seq 提取的长期时间特征反映热点区域的近段时间的趋势变化。根据 Attention 机制能够有效得到 Seq2Seq 中编码器序列各时间点对解码器序列各时间点的不同重要程度,将其融入模型。

实验采用中国武汉某区域内三个月的真实出租车轨迹数据进行实验,展开了大量对比实验和分析,验证了 CSA 模型的效果和优势。但 CSA 模型仍有不足,例如天气、节假日对居民出行有一定影响,城市热点区域会有不同的变化。在后续研究中,会继续将天气、休假等因素加入考虑。

参考文献:

- [1] YUE Y, WANG H, HU B, et al. Exploratory calibration of a spatial interaction model using taxi GPS trajectories [J]. Computers, Environment and Urban Systems, 2012, 36 (2): 140-153.
- [2] 滕巧爽,孙尚宇,秘金钟. 众源地理空间数据的城市热点区域探测 [J]. 测绘科学, 2018, 43 (5): 74-80.
- [3] 邹海翔,乐 阳,李清泉. 城市交通状态的空间依赖性和异质性分析 [J]. 城市交通, 2015, 13 (3): 9-16.
- [4] HOANG M X, ZHENG Y, SINGH A K. FCCF: forecasting citywide crowd flows based on big data [C] // Proceedings of the 24th ACM SIGSPATIAL international conference on advances in geographic information systems. Burlingame; Association for Computing Machinery, 2016: 1-10.
- [5] 王 举,陈晓江,常偏琼,等. 基于压缩感知的被动式移动目标轨迹测绘 [J]. 计算机学报, 2015, 38 (12): 2361-2374.
- [6] 涂 伟,曹劲舟,高琦丽,等. 融合多源时空大数据感知城市动态 [J]. 武汉大学学报:信息科学版, 2020, 45 (12): 1875-1883.
- [7] 庄镇泉,王东生,王熙法. 神经网络与神经计算机 第三讲神经网络的学习算法 [J]. 电子技术应用, 1990 (5): 38-41.
- [8] 李永刚,王朝晖,万晓依,等. 基于深度残差双向 LSTM 的时空一致视频事件识别 [J]. 计算机学报, 2018, 41 (12): 2852-2866.
- [9] 刘 全,翟建伟,钟 珊,等. 一种基于视觉注意力机制的深度循环 Q 网络模型 [J]. 计算机学报, 2017, 40 (6): 1353-1366.
- [10] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting [C] // Proceedings of the 28th international conference on

- neural information processing systems—volume 1. Montreal: MIT Press, 2015:802–810.
- [11] 徐冰冰,岑科廷,黄俊杰,等. 图卷积神经网络综述[J]. 计算机学报,2020,43(5):755–780.
- [12] 张建晋,王搢博,龙明盛,等. 面向季节性时空数据的预测式循环网络及其在城市计算中的应用[J]. 计算机学报,2020,43(2):286–302.
- [13] MA X, DAI Z, HE Z, et al. Learning traffic as images: a deep convolutional neural network for large-scale transportation network speed prediction[J]. Sensors, 2017, 17(4):818.
- [14] ZHANG J, ZHENG Y, QI D, et al. DNN-based prediction model for spatio-temporal data [C]//Proceedings of the 24th ACM SIGSPATIAL international conference on advances in geographic information systems. Burlingame: Association for Computing Machinery, 2016:1–4.
- [15] ZHANG J, ZHENG Y, QI D. Deep spatio-temporal residual networks for citywide crowd flows prediction [C]//Thirty-first AAAI conference on artificial intelligence. San Francisco: AAAI, 2017.
- [16] SRIVASTAVA N, MANSIMOV E, SALAKHUDINOV R. Unsupervised learning of video representations using LSTMs [C]//International conference on machine learning. Lille: International Machine Learning Society (IMLS), 2015:843–852.
- [17] RODRIGUES F, MARKOU I, PEREIRA F C. Combining time-series and textual data for taxi demand prediction in event areas: a deep learning approach [J]. Information Fusion, 2019, 49:120–129.
- [18] 杜圣东,李天瑞,杨 燕,等. 一种基于序列到序列时空注意力学习的交通流预测模型[J]. 计算机研究与发展, 2020, 57(8):1715–1728.
- [19] 谢 昭,周 义,吴克伟,等. 基于时空关注度 LSTM 的行为识别[J]. 计算机学报, 2021, 44(2):261–274.
- [20] 王录仓. 基于百度热力图的武汉市主城区城市人群聚集时空特征[J]. 西部人居环境学刊, 2018, 33(2):52–56.
- [21] 王 震. 基于时空场的城市人群流动热点提取方法研究 [C]//面向高质量发展的空间治理——2021 中国城市规划年会论文集(05 城市规划新技术应用). 成都:中国城市规划学会, 2021:410–423.
- [22] 刘玉强,顾晶晶,孙 明,等. 基于城市区域多模态融合的人群流量预测[J]. 郑州大学学报:理学版, 2022, 54(1):25–31.
- [23] 周飞燕,金林鹏,董 军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6):1229–1251.
- [24] 杨 丽,吴雨茜,王俊丽,等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(S2):1–6.
- [25] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. NeuralComputation, 1997, 9(8):1735–1780.
- [26] CHO K, VAN MERRIËNBOER B, BAHDANAU D, et al. On the properties of neural machine translation: Encoder-decoder approaches[J]. arXiv:1409.1259, 2014.
- (上接第 193 页)
- 法及应用研究[J]. 计算机工程与应用, 2021, 57(1):92–98.
- [15] DZVONYAR D, ALPEROWITZ L, HENZE D, et al. Team composition in software engineering project courses [C]//Proceedings of 2nd international workshop on software engineering education for millennials. Gothenburg: IEEE, 2018:16–23.
- [16] ERGIN H. Instructor-formed capstone teams based on interest and technical experience: the road to success[J]. Journal of Computing Sciences in Colleges, 2019, 35(5):37–49.
- [17] LIKAS A, VLASSIS N, VERBEEK J. The global k-means clustering algorithm [J]. Pattern Recognition, 2003, 36(2):451–461.
- [18] MÜLLNER D. Modern hierarchical, agglomerative clustering algorithms [J]. arXiv:1109.2378, 2011.
- [19] ZHANG T, RAMAKRISHNAN R, LIVNY M. BIRCH: an efficient data clustering method for very large databases [C]//Proceedings of 1996 ACM SIGMOD international conference on management of data. Montreal: Association for Computing Machinery, 1996:103–114.
- [20] WANG K, ZHANG J, LI D, et al. Adaptive affinity propagation clustering [J]. Acta Automatica Sinica, 2007, 33(12):1242–1246.