



# 基于群体行为分析的人群异常聚集预测方法

黄贺贺, 曾园园, 张毅, 奈何

(武汉大学 电子信息学院, 武汉 430072)

**摘要:** 随着智能通信设备的普及和通信基站定位精度的提升, 利用通信基站记录的用户行为数据监测和预测人群密度成为可能。由于人群异常聚集事件具有突发性, 利用时间序列分析方法和概率模型进行预测的效果较差。针对该问题, 提出一种基于群体行为分析的预测方法。通过分析聚集人群的上网行为和基站间的人群移动行为特征, 得到两者之间的相关性, 结合基站的人群密度时间序列信息, 利用扩张因果卷积神经网络和逻辑回归模型得出预测结果。运营商提供的手机用户上网记录数据集上的实验结果表明, 该预测方法的精确率为 0.93, 召回率为 0.97, 显著优于 ARIMA 算法、LSTM 算法和 XGBoost 算法, 证明了引入用户群体的上网行为和移动特征能够有效提升人群异常聚集预测的准确性。

**关键词:** 人群异常聚集; 移动互联网; 群体行为分析; 聚集预测; 卷积神经网络

开放科学(资源服务)标志码(OSID):



**中文引用格式:** 黄贺贺, 曾园园, 张毅, 等. 基于群体行为分析的人群异常聚集预测方法[J]. 计算机工程, 2020, 46(3): 292-298, 308.

**英文引用格式:** HUANG Hehe, ZENG Yuanyuan, ZHANG Yi, et al. Prediction method of abnormal crowd aggregation based on group behavior analysis[J]. Computer Engineering, 2020, 46(3): 292-298, 308.

## Prediction Method of Abnormal Crowd Aggregation Based on Group Behavior Analysis

HUANG Hehe, ZENG Yuanyuan, ZHANG Yi, NAI He  
(Electronic Information School, Wuhan University, Wuhan 430072, China)

**[Abstract]** With the popularization of intelligent communication devices and the improvement of positioning accuracy of communication base stations, it becomes feasible to monitor and predict crowd density using the behavior data of users recorded by communication base stations. However, the prediction performance of the frequently methods using time series and probability models is reduced by the suddenness of crowd gathering events. To address the problem, this paper proposes a prediction method based on group behavior analysis. By analyzing the online behavior of crowds and the behavior features of crowds moving between base stations, their correlation is obtained. On this basis, in combination with the time series information of the crowd density of stations, the prediction result is obtained by using the expanded causal convolutional neural network and logistic regression model. Experimental results on the online behavior record dataset of mobile phone users provided by operators show that the accuracy of this prediction method is 0.93 and the recall rate is 0.97, which is significantly better than the ARIMA algorithm, LSTM algorithm and XGBoost algorithm, proving the introduction of online behavior and movement features of users can effectively improve the accuracy of abnormal crowd aggregation prediction.

**[Key words]** abnormal crowd aggregation; mobile Internet; group behavior analysis; crowd prediction; Convolutional Neural Network(CNN)

**DOI:** 10.19678/j.issn.1000-3428.0055439

### 0 概述

近年来,随着社会经济的发展,城市的人口密度

急速增大,给城市建设和管理的各个方面带来巨大挑战。在公共安全方面,由于人群异常聚集而导致的各类安全问题时有发生,因此对人群异常聚集现

**基金项目:** 国家自然科学基金(61371126)。

**作者简介:** 黄贺贺(1995—),男,硕士研究生,主研方向为机器学习、数据挖掘;曾园园,副教授、博士;张毅,硕士;奈何,博士。

**收稿日期:** 2019-07-10 **修回日期:** 2019-08-28 **E-mail:** hhhuang@whu.edu.cn

象进行预测具有重要的现实意义。

目前,国内外学者对人群异常聚集的预测方法进行了深入的研究,大多数基于图像处理的监控系统已投入运行并已取得了一定的效果<sup>[1-2]</sup>。然而,基于图像处理的方法具有局限性,例如,摄像机无法捕捉视野外的元素且易被其他障碍遮挡,难以融合来自多个摄像机的信息以获得全局态势感知。另外,基于图像处理的方法需要良好的照明条件,因此,对于发生在夜间的事件而言,该方法难以发挥作用。

许多研究者根据各区域的人群密度历史数据和用户的历史移动轨迹数据,利用时间序列分析方法或概率模型预测未来的人群密度分布。文献[3]提出一种利用长短时记忆网络预测行人轨迹,从而估计各区域人群密度的方法。文献[4]根据用户的历史移动轨迹数据构建基于马尔科夫模型的路径预测系统,用于预测每个用户的未来位置和停留时间。上述方法对于日常的人群密度预测问题较为有效,然而人群异常聚集事件具有突发性,此类方法可能无法取得很好的效果。

针对人群异常聚集现象,许多学者尝试从分析人群的移动行为模式出发,预测各区域的人群密度分布情况,从而提早发现人群异常聚集现象。文献[5]指出,一起人群聚集导致的踩踏事件的形成过程可以分为4个阶段,即自由移动-停留-拥堵-踩踏。文献[6]建立了一个社会力模型来分析人群移动机制,综合考虑了行人意图、期望速度和个体之间的相互作用。文献[7]提出一种密度泛函理论,综合考虑环境因素和行人在不同环境下的移动行为,用以预测人群密度的分布情况。上述方法均基于人群的移动行为特征进行分析,然而对于人群异常聚集事件而言,群体情绪、公共舆论等因素对于群体行为也有重要的影响<sup>[8-9]</sup>。因此,对于人群异常聚集现象的预测问题,需要从多个维度全面具体地分析和描述群体行为,以提高预测性能。

本文提出一种基于用户群体行为分析的人群异常聚集预测方法。通过对比分析异常聚集场景和正常场景下用户群体的上网行为和空间移动行为,发现不同场景下用户行为的差异性。根据群体上网行为和移动行为对未来时刻是否会发生异常聚集事件进行预测,得到最终的预测结果。

## 1 人群异常聚集现象分析

### 1.1 人群异常聚集阈值计算模型

随着智能移动终端的普及和移动互联网的发展,通信基站会记录大量用户产生的会话数据,这些数据准确详细地记录了用户的移动行为和上网访问内容,为群体行为的分析研究提供了数据支撑<sup>[10-11]</sup>。

大量的研究证明,人类行为在宏观上服从一定的模式<sup>[12-13]</sup>,各个基站覆盖范围内的人群密度分布

具有一定的稳定性<sup>[14-15]</sup>,因此,可以通过设定阈值的方式来判定当前区域是否发生了人群异常聚集事件。

由于特定区域上的人群密度分布在一天内会随着时间变化,且同一区域上的人群密度在工作日和节假日时也会有所不同,因此对于某特定基站所在的区域,定义其人群密度期望值如下:

$$E_{BS}^D(T) = \frac{\sum_{n=1}^N H_n^D V_{BS}^n(T)}{\sum_{n=1}^N H_n^D} \quad (1)$$

其中, $D \in \{0, 1\}$ 分别表示工作日和节假日, $E_{BS}^D(T)$ 表示基站BS在工作日或节假日中T时段的人群密度期望, $n$ 表示数据记录的天数, $H_n^D$ 表示第n天是否与待计算的 $E_{BS}^D(T)$ 同为工作日或节假日,相同则为1,否则为0, $V_{BS}^n(T)$ 表示第n天基站BS在T时段的人群密度。

在此基础上,定义人群聚集的异常判定阈值如下:

$$Z_{BS}^D(T) = \left(1 + \alpha + \frac{1}{E_{BS}^D(T)}\right) E_{BS}^D(T) \quad (2)$$

其中, $Z_{BS}^D(T)$ 表示基站BS在工作日或节假日的T时段的人群密度异常阈值, $\alpha$ 为尺度调节因子。

### 1.2 聚集体行为分析

将用户群体访问过的内容按照业务类型分为19类,如表1所示。

表1 用户访问内容分类

Table	Classification of content accessed by users	
类别	标识	典型 URL
社交	social	weibo.com
购物	shopping	taobao.com
应用市场	application	myapp.com
视频	video	youku.com
音乐	music	music.163.com
新闻	news	news.baidu.com
娱乐	entertainment	game.qq.com
搜索	search	baidu.com
出行	travel	ditu.amap.com
小说	fiction	www.qidian.com
教育	education	mooc.org
天气	weather	weather.com.cn
云盘	cloud	pan.baidu.com
广告	ad	www.cnad.com
门户	portal	sina.com
论坛	forum	bbs.hupu.com
健康	health	gotokeep.com
工作	work	www.51job.com
邮件	mail	mail.163.com

对正常场景和异常聚集场景下的用户群体访问内容分布进行统计,结果如图1所示。可以看出,两类场景下的用户上网流量分布具有一定的相似性,都主要集中在社交、购物、音乐、视频、新闻等类型上,说明用户群体的内容偏好在不同场景下具有一定的稳定性。




图1 不同场景下的用户访问流量分布

Fig.1 Distribution of user access traffic in different scenarios

需要注意的是,在异常场景下,社交类应用的流量占比有明显提升,说明异常聚集场景下的用户群体更多地访问社交网站,更频繁地在社交网络上分享内容或获取内容。此外,正常场景下的出行类内容(主要包括打车出行类和地图类内容)的占比明显高于异常场景下,说明在异常场景下的人群移动行为具有明确的目的地,并且移动范围较为有限。

通过以上对比分析,可以将一起人群异常聚集事件的发生过程分为3个阶段。首先,在某区域上发生一起突发性事件,然后,此事件引起区域附近人群的关注并移动至该区域,最后,该区域的聚集人数远超正常值,如图2所示。其中,在第2个阶段,当

前区域内群体对于突发事件的反应是在社交网络上分享信息,即访问的内容集中在少数热点内容上,从而可以推断异常聚集用户群体的访问内容分布会表现出较高的相似性。




图2 异常聚集事件发生过程

Fig.2 Occurrence procedure of abnormal aggregation event

对于异常聚集事件的预测问题,除了传统方法使用到的人群密度的时间序列信息之外,群体的上网行为信息以及相邻区域上的群体行为信息均可提高预测的准确性。

根据以上分析,异常聚集的用户在上网内容上可能会表现出较高的相似性,使用Jaccard相似系数衡量用户间的相似度,定义如下:

$$J_{\text{Jaccrd}}(u, v) = \frac{N(u) \cap N(v)}{N(u) \cup N(v)} \quad (3)$$

其中,  $N(u)$  表示用户  $u$  的访问内容集合。然而在实际场景中,网络中会存在一些流行内容被大部分用户都访问过,显然这类内容用于衡量相似度会导致偏差,因此需要降低这些流行内容的权重,将式(3)的分子修改为如下形式:

$$\sum_{i \in N(u) \cap N(v)} \frac{1}{\text{lb}(1 + C(i))} \quad (4)$$

其中,  $i$  为被用户  $u$  和用户  $v$  共同访问的内容,  $C(i)$  为内容  $i$  在同时段被所有用户访问的次数。

在得到用户之间的访问内容相似度后,对观测区域在指定时段内的用户群体构建有权相似网络  $G = \langle U, S \rangle$ 。其中,  $U$  为用户集合,每个用户对应相似网络中的一个节点,  $E$  为连边集合,每条边的权重为对应的一对用户之间的Jaccrd相似系数。在此基础上,定义群体行为平均相似度为相似网络中所有连边的平均权重,具体如下:

$$S_{\text{sim}} = \frac{\sum E}{n_{\text{num}}(E)} \quad (5)$$

其中,  $\sum E$  表示所有连边权重的加和,  $n_{\text{num}}(E)$  表示网络中连边的条数。

对2种场景(正常现象和异常聚集现象)下的用户群体行为进行比较分析。统计2种场景下的用户间的Jaccrd相似系数,大致分布如图3所示。可以看出,人群异常聚集场景下的用户相似度大多在0.7以上,显著高于正常场景下的0.3,即异常聚集场景下的大部分用户上网行为的相似度较高,说明用户

群体的异常聚集现象是由现实中的特定事件引起的,用户对此类事件的反应为社交网络中的使用流量增加,用户间的上网访问内容分布非常相似。




图 3 不同场景下的用户行为相似度分布  
Fig. 3 Distribution of user behavior similarity in different scenarios

下面验证用户群体行为特征信息对于人群异常聚集现象的预测是否有效。由于人群异常聚集现象的直接特征为人群密度,因此需要计算所有基站上的人群密度分布的香农熵和已知群体行为特征信息条件下的条件熵。香农熵和条件熵的定义分别如式(6)和式(7)所示:

$$H_{BS}^{in} = - \sum_{j \in N_{BS}} P(j) \cdot \lg P(j) \quad (6)$$

其中,  $N_{BS}$  表示基站 BS 的人群密度的可能取值的集合,  $P(j)$  表示人群密度为  $j$  的概率。  $H_{BS}^{in}$  表征了基站 BS 的人群密度的可预测性。

$$H_{BS}^{con} = - \sum_{l \in M_{BS}} P(l) \sum_{j \in N_{BS}} P(j|l) \cdot \lg P(j|l) \quad (7)$$

其中,  $M_{BS}$  表示基站 BS 的条件状态集合, 此处特指群体行为平均相似度。  $H_{BS}^{con}$  表征了在群体行为平均相似度已知的条件下, 基站 BS 的人群密度的可预测性。

分别对正常和异常聚集场景下的人群密度的香农熵和条件熵进行统计计算, 绘制累积分布函数图 (Cumulative Distribution Function, CDF), 如图 4 所

示。可以看出, 在两种场景下, 人群密度分布的条件熵均低于香农熵, 说明群体行为平均相似度信息能够有效降低人数的不确定性。

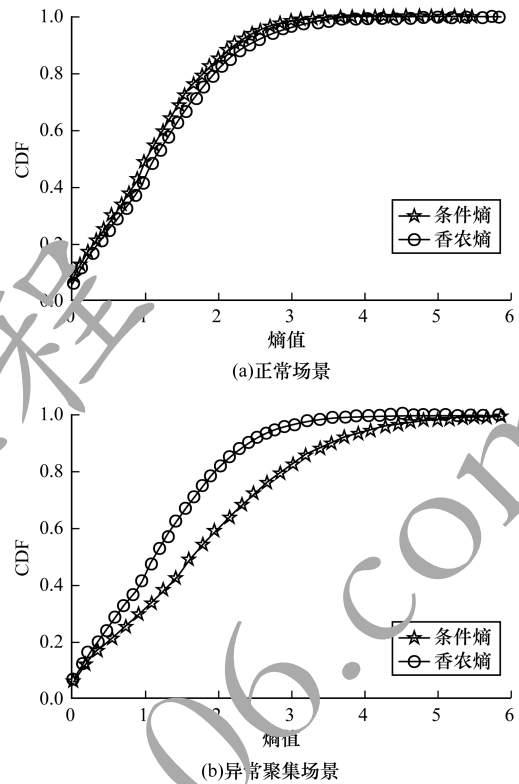


图 4 不同场景下人群密度分布的香农熵和条件熵  
Fig. 4 Shannon entropy and conditional entropy of crowd density distribution in different scenarios

值得注意的是, 异常场景下人群密度分布的条件熵显著低于香农熵, 即群体行为特征消除人群密度分布的不确定性的作用更为明显, 因此, 群体行为相似度是预测异常聚集的一个有效特征。

### 1.3 空间网络分析

在图 2 中, 引起用户关注到聚集大量用户的过程中, 由于人的移动行为具有时空连续性, 即区域最终聚集的人群是从相邻区域移动而来的, 因此一起异常聚集事件的影响范围不局限于该特定区域, 其相邻区域也会受到一定的影响, 需要考虑相邻区域上的群体行为特征对于人群异常聚集现象是否会产生影响。

基站的空间网络拓扑结构 (如图 5 所示) 可以根据基站的经纬度信息, 选取距离最近的几个基站作为该基站的邻接基站。然而在实际场景中, 由于建筑布局、道路设施等因素的影响, 空间上直接相邻的基站之间可能无法进行用户交互, 因此根据用户的

移动轨迹,采用两基站间的交互用户数量作为连接权重,取权重排名前 6 的基站作为该基站的相邻基站。

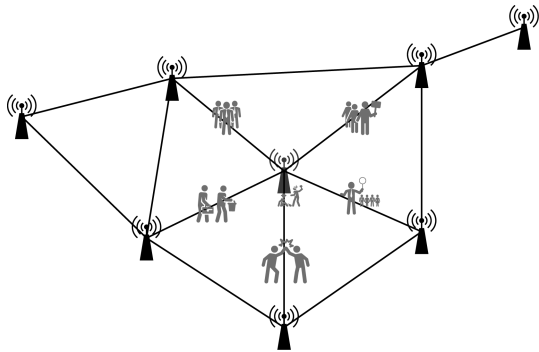


图 5 基站空间拓扑结构

Fig. 5 Spatial topology of base station

莫兰指数是一种用于衡量空间特征相关性的指标,被广泛应用于各领域的空间结构问题分析中<sup>[16-17]</sup>。本文采用局部莫兰指数量化分析当前区域的聚集属性,定义如下:

$$I_i = \frac{n^2}{\sum_i \sum_j \omega_{ij}} \times \frac{(x_i - \bar{x}) \times \sum_j \omega_{ij} (x_j - \bar{x})}{\sum_j (x_j - \bar{x})^2} \quad (8)$$

其中,  $n$  为空间网络中的节点数量,本文中特指基站数量,  $x$  为待观测的指标,本文中特指群体行为平均相似度,  $\omega_{ij}$  为节点连边权重,本文中特指两个基站间的用户交互数量。

对于人群异常聚集场景,局部莫兰指数为正值表示当前区域与相邻区域具有相近的特征表现,说明当前区域具有聚集的潜在可能,为负值则说明当前区域暂无聚集的可能。

计算数据集中发生异常聚集现象的基站人数分布的信息熵,以及已知局部莫兰指数信息后人数分布的条件熵,绘制累积分布函数图,如图 6 所示。可以看出,局部莫兰指数能够降低人数分布的不确定性,即空间网络中的信息有助于提高基站人数分布的可预测性。

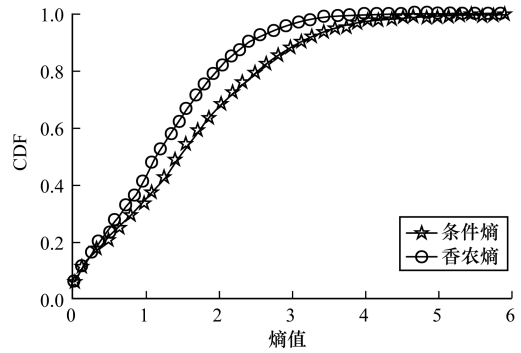


图 6 局部莫兰指数条件熵的累积分布函数

Fig. 6 Cumulative distribution function of conditional entropy of local Moran's I

## 2 人群异常聚集现象预测模型

异常聚集场景具有以下典型特征:

- 1) 突发性:事件的发生在较短时间内吸引了大量用户聚集。
- 2) 持续时间短:事件的发生过程持续时间通常不超过 2 h,即人群聚集一段时间后又迅速疏散。
- 3) 非周期性:当前区域的历史数据中可能从未发生过类似事件。
- 4) 影响范围广:事件的空间影响范围不局限于指定观测区域,邻近区域也会受到影响。

由于人群异常聚集现象的突发性和非周期性,常用的时间序列分析方法(LSTM、ARIMA等)不适用于此问题。此外,已知空间网络中邻近区域的特征信息有助于提高目标区域人数的可预测性,因此,最终的问题模型应当是多元输入的非线性模型。

基于以上分析,模型选择需要考虑时间序列的因果性以及多维特征的信息融合问题。CNN 网络模型的卷积层-池化层结构能够满足多维特征信息融合的基本要求。在此基础上,本文采用扩张因果卷积<sup>[18]</sup>模型(Dilated Convolutional Neural Network, D-CNN)作为整体模型的基础部分,其基本结构如图 7 所示。在隐层间的信息传输过程中,当前网络节点的输出只能与之前时刻的输入有关,以保证信息传输过程中的因果性。




图 7 扩张因果卷积神经网络结构

Fig. 7 Structure of expansion of causal convolutional neural network

在单个样本中,对于待预测的区域,需要考虑人群密度、群体行为相似度和局部莫兰指数 3 个特征,对于 6 个相邻基站,需要考虑人群密度和群体行为相似度 2 个特征,因此,模型输入包含 15 个时间序列信息。对于每个特征,从待预测的时刻回溯 4 h,每 15 min 进行切片,构造长度为 16 的时间序列。将所有特征拼接成一个二维矩阵,因此,单个样本的大小为  $15 \times 16$  的二维矩阵。样本标签为下一时刻是否会发生异常聚集现象,1 表示会发生,0 表示不会发生。

本文模型结构如图 8 所示,单个样本中的每一个时间序列对应一个 D-CNN 层,共 15 层。将每一个卷积层的输出拼接成一维向量,通过逻辑回归模型(Logistics Regression, LR)<sup>[19]</sup>得到最终的输出。

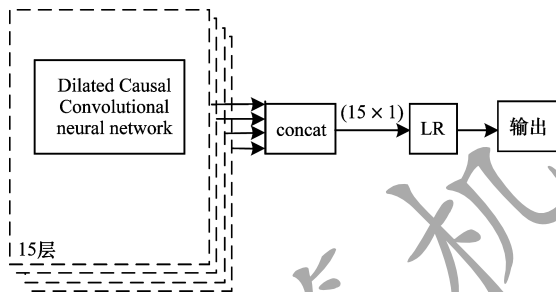


图 8 预测模型整体结构

Fig. 8 Overall structure of the prediction model

本文预测方法的核心思想为考虑异常聚集发生时用户的上网行为变化以及用户行为特征的空间自相关性,利用扩张因果卷积神经网络和逻辑回归模型的组合模型进行预测,预测方法流程如图 9 所示。




图 9 本文方法预测流程

Fig. 9 Prediction procedure of the proposed method

### 3 实验结果与分析

#### 3.1 数据集介绍

本文实验采用广东省江门市的中国联通记录的

用户上网详单数据,包括 2018 年 4 月和 5 月的完整数据,数据集的关键字段和示例如表 2 所示。用户 ID 为脱敏处理后的用户手机号码,时间为该条上网记录的产生时间,基站标识为用户连接的基站的唯一标识,URL 为用户访问的网址信息。本文所有数据处理及算法设计均在 Spark 大数据平台环境下运行。

表 2 数据基本字段与示例数据  
Table 2 Basic data fields and sample data

字段	数据
用户 ID	4115121649965110
时间	2018-05-16 13:17:59
基站标识	579D_79E3
URL	weibo.com

#### 3.2 对比算法

本文选取时间序列分析方法 LSTM 和 ARIMA 作为对比算法。首先使用模型预测人群密度,然后通过一个线性判别器来判断未来是否会发生异常聚集现象。同时,为了验证扩张因果卷积神经网络的有效性,选用机器学习中被广泛使用的 XGBoost 模型<sup>[20]</sup>作为对比模型。

#### 3.3 结果与分析

分类问题的模型评价指标通常选用精确率(Precision)、召回率(Recall)和 F1 值(F1-Measure)。对于面向公共安全的人群异常聚集预测问题而言,通常认为召回率(查全率)是更为重要的评价指标,即可以接受一定的误报率,但要尽可能地检测出所有异常聚集现象。具体的实验结果和模型训练过程如表 3、图 10 和图 11 所示。

表 3 4 种模型的实验结果对比  
Table 3 Comparison of experimental results of the four models

模型	精确率	召回率	F1 值
ARIMA	0.84	0.83	0.83
LSTM	0.81	0.84	0.82
XGBoost	0.91	0.91	0.91
D-CNN	0.93	0.97	0.95




图 10 D-CNN 模型训练过程

Fig. 10 Training procedure of D-CNN model

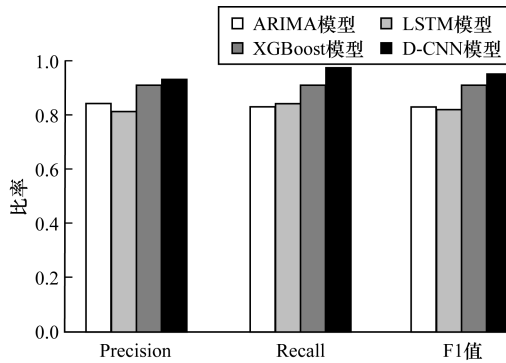


图 11 4种模型的预测结果对比

Fig. 11 Comparison of prediction results of the four models

从实验结果可以看出,本文预测方法在3项评价指标上均取得了最好的效果,验证了群体行为特征信息和空间相关性信息对于人群异常聚集现象预测的有效性。需要注意的是,在相同的特征信息上,D-CNN模型的表现优于XGBoost模型,说明D-CNN模型对于多维时间序列分析问题的有效性。

此外,基于时间序列分析的模型ARIMA和LSTM在各项评价指标上的表现并不理想,其可能的原因是时间序列分析模型会累积预测误差,预测结果与真实序列的差异呈现出一定的滞后性,如图12所示。时间序列分析模型在人数快速增加时会产生较大的误差,因此,人群异常聚集事件的突发性会使得该类模型的误差较大,导致异常现象的误判和漏判,从而影响预测性能。




图 12 LSTM模型误差

Fig. 12 Error of LSTM model

#### 4 结束语

针对现实生活中时常发生的人群异常聚集现象,本文提出一种考虑用户群体上网行为特征和空间自相关性的预测方法。通过引入用户群体行为特征和群体特征的空间自相关性,全面地描述和分析异常聚集现象下的群体活动特征,从而提升预测性能。真实的中国联通数据集上的实验结果表明,与ARIMA、LSTM和XGBoost模型相比,该方法对于人群异常聚集预测的准确性更高。下一步将引入社交网络中的内容信息,更加全面细致地刻画群体行为,以进一步改善预测性能。

#### 参考文献

- [1] YUAN Yajun, LI Feifei, CHEN Qiu. Crowd behavior recognition algorithm based on combined features and deep learning[J]. Computer Science, 2019, 46(6): 305-310. (in Chinese)  
袁亚军,李菲菲,陈虬. 基于复合特征及深度学习的人群行为识别算法[J]. 计算机科学, 2019, 46(6): 305-310.
- [2] KONG Weihang, LI He, XING Guanglong, et al. An automatic scale-adaptive approach with attention mechanism-based crowd spatial information for crowd counting[J]. IEEE Access, 2019(7): 66215-66225.
- [3] SUN Yunmiao, LIN Feng, ZHOU Jiliu. Research progress of long short-term memory applications in mobile scenarios[J]. Modern Computer, 2017(35): 10-15. (in Chinese)  
孙运淼,林锋,周激流. 长短时记忆网络在移动场景中的应用研究进展[J]. 现代计算机, 2017(35): 10-15.
- [4] ZHENG Hong, DENG Xiao, DENG Wenxuan. Crowd pre-warning system based on mobile locators and behavior prediction[C]//Proceedings of International Conference on Digital Home. Washington D. C., USA: IEEE Computer Society, 2016: 122-127.
- [5] LIU Zimei, CHEN Yun, XIE Kefar. Research on the impact of crowd flow on crowd risk in large gathering spots[C]//Proceedings of International Conference on Industrial Informatics-Computing Technology. Washington D. C., USA: IEEE Press, 2017: 368-371.
- [6] DEDOMENICO M, LAMA F, MUSOLESI M. Interdependence and predictability of human mobility and social interactions[J]. Pervasive and Mobile Computing, 2013, 9(6): 798-807.
- [7] MENDEZ VILELA, KINKHABWALA Y, SILVER J, et al. Density-functional fluctuation theory of crowds[J]. Nature Communications, 2018, 9(1): 1-10.
- [8] CHRISTAEDT J C, SMITH R J, MERCHANT R M, et al. Facebook language predicts depression in medical records[J]. Proceedings of the National Academy of Sciences, 2018, 115(44): 11203-11208.
- [9] ZHONG X, DUCKHAM M, CHONG D, et al. Real-time estimation of wildfire perimeters from curated crowd sourcing[J]. Scientific Reports, 2016, 6(1): 1-10.
- [10] JIAO Enwei, WU Yue. Pedestrian-crowd monitoring and prediction based on LTE[J]. Communications Technology, 2017, 50(3): 492-495. (in Chinese)  
焦恩伟,吴越. 基于的人群密度监控及预测[J]. 通信技术, 2017, 50(3): 492-495.
- [11] ZHANG Shixue, LI Shijun, YU Wei, et al. Prediction on hot region of crowd abnormal gathering on unexpected event[J]. China Safety Science Journal, 2015, 25(9): 159-164. (in Chinese)  
张仕学,李石君,余伟,等. 突发事件人群异常聚集热点区域预测[J]. 中国安全科学学报, 2015, 25(9): 159-164.
- [12] GONZALEZ M C, HIDALGO C A, BARABASI A L. Understanding individual human mobility patterns[J]. Nature, 2008, 453(7196): 779-782.
- [13] PAPPALARDO L, SIMINI F, RINZIVILLO S, et al. Returners and explorers dichotomy in human mobility[J]. Nature Communications, 2015, 6(1): 1-8.

(上接第 298 页)

- [14] CHEN Yanyan, CHEN Ning, WANG Yong, et al. Modeling pedestrian behaviors under attracting incidents using cellular automata [J]. *Physica A: Statistical Mechanics and Its Applications*, 2015, 432:287-300.
- [15] YONG Nuo, NI Shunjiang, SHEN Shifei, et al. Uncovering stable and occasional human mobility patterns: a case study of the Beijing subway [J]. *Physica A: Statistical Mechanics and Its Applications*, 2017, 492: 28-38.
- [16] DAS M, GHOSH S K. Measuring Moran's I in a cost-efficient manner to describe a land-cover change pattern in large-scale remote sensing imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(6):2631-2639.
- [17] WANG Shengjin, WANG Zhichu. Studies on spatial consistency between population agglomeration and economic agglomeration in China [J]. *Population Journal*, 2017, 39(6):43-50. (in Chinese)
- 王胜今, 王智初. 中国人口集聚与经济集聚的空间一致性研究 [J]. *人口学刊*, 2017, 39(6):43-50.
- [18] BOROVYKH A, BOHTE S M, OOSTERLEE C W, et al. Conditional time series forecasting with convolutional neural networks [EB/OL]. [2019-06-27]. <https://arxiv.org/pdf/1703.04691.pdf>.
- [19] FRIEDMAN J H, HASTIE T, TIBSHIRANI R, et al. Additive logistic regression: a statistical view of boosting [J]. *Annals of Statistics*, 2000, 28(2):337-407.
- [20] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system [EB/OL]. [2019-06-27]. <https://arxiv.org/pdf/1603.02754.pdf>.