

引用格式:张丽英,孟斌,尹芹.基于符号集合近似的城市轨道交通站点分类研究[J].地球信息科学学报,2016,18(12):1597-1607. [Zhang L Y, Meng B, Yin Q. 2016. Classification of urban rail transit stations based on SAX. Journal of Geo-information Science, 18(12):1597-1607.] DOI: 10.3724/SP.J.1047.2016.01597

基于符号集合近似的城市轨道交通站点分类研究

张丽英^{1,2}, 孟斌^{3*}, 尹芹⁴

1. 中国矿业大学(北京)地球科学与测绘工程学院,北京 100083; 2. 中国石油大学(北京)地球物理与信息学院,北京 102249;
3. 北京联合大学应用文理学院,北京 100191; 4. 首都师范大学资源环境与旅游学院,北京 100048

Classification of Urban Rail Transit Stations based on SAX

ZHANG Liying^{1,2}, MENG Bin^{3*} and YIN Qin⁴

1. College of Geoscience and Surveying Engineering, China University of Mining & Technology, Beijing 100083; 2. College of Geophysics and Information Engineering, China University of Petroleum, Beijing 102249; 3. College of Applied Arts & Sciences of Beijing Union University, Beijing 100191; 4. College of Resource Environment and Tourism, Capital Normal University, Beijing 100048

Abstract: Urban rail transit stations are the key nodes of the basic urban rail transit network system. The scientific classification of the rail transit stations is significant to understand the urban functional zoning and evaluate the construction of the rail transit infrastructure. The time series data of urban rail transit stations objectively records the important information of observed stations at all-time points. The time series data contains different patterns, which reflect different sequence genesis. Therefore, studying cluster of the time series data is an important means to recognize and understand the essence of time series data formation. It is also a major method to mine higher value of principle and knowledge that implied in time series data. In this paper, we use smart card data of urban rail transit stations in Beijing, and divide the big data into four data sets: weekdays boarding data set (WB), weekdays alighting data set (WA), weekends (rest day) boarding data set (RB) and weekends alighting data set (RA) to describe characteristics of each station's daily passenger volume. Symbolic Aggregate approxImation (SAX) is firstly introduced to analyze four data sets, which effectively reduces the dimensionality of high-dimensional data and realizes similarity measure between stations. Finally, it is more reasonable to classify the 195 rail transit stations into 8 types according to the DB index by hierarchical clustering method. They are residential stations, work stations, partial residential-based residential and work mixed stations, dislocation stations, tourist attractions and commercial stations, partial work-based residential and work mixed stations, integrated stations and other stations. The performance of SAX is compared with Euclidean distance similarity measure. The results indicate that SAX outperforms Euclidean distance in terms of accuracy and efficiency. The paper analyzes characteristics of daily passenger boarding and alighting volume on four data sets and spatial distribution of each type. It is found that residence and dislocation stations are mostly located in the far end of the subway, while the types of work stations, tourist attractions and commercial stations, partial work-based residential and work mixed stations, and integrated stations are concentrated in the urban areas. Partial residential-based residential and work mixed stations scatter around the city center. The results can help to interpret the different functional zoning of the city and the characteristics of residents' travel behavior, which provides a basis for understanding the urban spatial pattern and its evolution process, and also provides some objective reference for planning, design and management services of rail transit stations.

Key words: rail transit stations; time series; Symbolic Aggregate approxImation(SAX); Hierarchical clustering; spatio-temporal characteristics

*Corresponding author: MENG Bin, E-mail: mengbin@bnu.edu.cn

收稿日期:2016-08-04;修回日期:2016-10-18.

基金资助:北京市哲学社会科学基金项目(14CSA002);国家自然科学基金项目(41171136)。

作者简介:张丽英(1980-),女,河南社旗人,博士生,研究方向为时空数据挖掘。E-mail: lyzhang1980@cup.edu.cn

*通讯作者:孟斌(1971-),男,安徽肥东人,博士,教授,硕士生导师,研究方向为城市地理、地理信息科学。

E-mail: mengbin@bnu.edu.cn

摘要:轨道站点是城市轨道交通基本线网系统中的关键节点,科学的轨道站点分类,对了解城市功能分区及评价轨道交通基础设施建设情况具有重要意义。轨道交通站点时间序列客观记录了所观测的站点在各个时刻点的重要信息,研究其时间序列聚类,是认识和理解轨道交通站点时间序列形成本质的的重要手段,也是挖掘轨道交通站点时间序列中隐含的有较高价值规律知识的重要方法。本文以北京IC卡轨道站点刷卡数据为研究对象,提出了描述轨道站点的4个数据集,即工作日进站数据集(WB)、工作日出站数据集(WA)、休息日进站数据集(RB)和休息日出站数据集(RA);并首次引入时间序列分析方法(符号集合近似(SAX)方法)对4个数据集进行聚类分析,实现了高维数据的有效降维和轨道站点之间的相似性度量。采用层次聚类方法并根据聚类有效性DB指数确定将195个站点分为8类更为合理。通过分析每类站点的日客流特征和空间位置分布情况,为轨道交通站点规划设计和管理服务提供一定的客观参考依据。

关键词:轨道交通站点;时间序列;符号集合近似(SAX);层次聚类;时空特征

1 引言

轨道站点是城市轨道交通基本线网系统中的关键节点,随着国内城市轨道交通建设的全面展开,轨道在城市交通中发挥着越来越重要的作用。2013年北京市交通发展年度报告指出北京轨道交通占公共交通出行的比重由2000年13.6%增至2012年38.2%^[1],对改善北京市交通结构、优化城市空间布局、提高生活环境质量发挥了重要作用。不同类型的站点在城市中的区域特征、交通功能、用地功能等方面均存在差异^[2],科学的地铁站点分类,对了解城市功能分区、解读居民出行特征、理解城市格局和演化以及评价轨道交通基础设施建设情况具有重要意义。

国内外学者针对轨道交通站点开展了大量的研究。国外对轨道交通站点的分类研究一般以城市地铁站点为研究对象,把郊区地铁站点作为其中的子类^[3],根据站点交通节点的特性,或者开放空间的场所特性进行分类指标选取,如站点客流量大小、站点服务地区的主要功能、站点衔接方式种类、或者与某个指定参照系统的相关关系等^[4]。日本东京、大阪等城市根据地铁站点所处区位,首先将地铁站点划分为市区和郊区站点,再通过站点衔接方式种类、换乘比例等指标将其各划分为3个不同的等级^[5]。国内学者对轨道站点分类研究主要采用2种分类标准:①国内部分城市轨道交通建设采用的分类标准,一般采用站点衔接的交通方式、轨道线路数以及站点周围的土地利用类型等作为分级指标,将地铁站点划分为3-4个等级^[6]。吴娇蓉等^[7-8]按照站点区位特征、站点周边土地利用性质、开发规模和强度等数据,将上海市郊区轨道交通站点划分为7大类。段德罡等^[9]综合考虑站点的区域特征和交通功能,对西安地铁2号线的站点进行分类研究。余丽洁等^[9]使用西安地铁2号线现状及规划特征年的

数据,采用几种不同的谱聚类算法对站点分类效果进行了评述。②通过轨道交通的运营资料数据进行分类。马小毅^[10]根据不同类型站点的客流特征差异,将站点分为居住型、办公型、商业型和枢纽型。王静等^[11]通过分析站点进站客流的波动性对站点进行聚类,归纳出周边不同用地类型的车站客流时空分布差异性特征规律。谭啸^[12]按轨道站点的职能进行了站点分类的研究。从国内外研究现状看,大多学者是通过实地调研数据、站点交通职能或站点周边土地利用情况对某些线路的站点分类进行了研究。采用大规模的数据对城市的轨道站点分类的研究相对比较少。

公交IC卡的使用为研究轨道交通站点的交通职能积累了具有地理标识和时间标签的大数据,其数据具有连续性好、覆盖面广、信息全面且动态更新等优点^[13]。国内外学者利用公交IC卡数据也展开了很多研究:Ali等^[14]利用公交智能卡数据作为大型活动的输入数据,基于公共交通仿真分析有关公交出行的用户行为;Gitanjali等^[15]对公交智能卡数据使用数据挖掘的聚类方法,实现更好地理解旅行模式和评价旅客的旅行行为属性;Long等^[16]使用IC卡数据研究北京通勤的模式;Joh和Hwang^[17]利用IC卡数据分析了公交卡持有者的出行轨迹与都市区的土地利用特征;Jang^[18]利用IC卡数据对公交出行时间和换乘信息进行估计;Bagchi等^[19]使用IC卡数据对公共交通市场进行分析;Roth等^[20]基于伦敦实时的Oyster卡数据库,获得地铁乘客移动特征;Ma等^[21]使用IC卡数据对公共交通乘客的出行模式进行了研究;尹芹等^[22]使用IC卡地铁刷卡客流量数据,引入客流特征的时间序列聚类方法,对地铁站点进行聚类研究;戴霄等^[23]研究了数据挖掘技术在公交卡信息处理方面的运用;杨智伟等^[24]基于大连的IC卡数据进行客流预测。总体上,这些研究侧重于研究用户的出行行为、通勤模式、公共交

通市场分析以及客流预测。使用IC卡数据对轨道站点进行分类研究,尤其是从工作日和休闲日进出站形成的多元时间序列的角度对轨道站点进行分类的研究相对较少。

轨道交通站点时间序列中蕴藏着不同的模式,不同的模式反映了不同的时间序列成因。对轨道交通站点的时间序列进行聚类分析,是认识和理解轨道站点时间序列形成本质的重要手段,也是挖掘轨道交通站点时间序列中隐含的有较高价值规律知识的重要方法^[25-26]。由于时间序列具有海量、高维的特性,研究者提出了近似表示的思路,实现对时间序列作降维处理^[27]。其基本思想是保留时间序列的主要形态,对时间序列进行压缩表示,用新的表示近似替代原始的时间序列。代表性的时间序列近似表示有离散傅立叶变换(the Discrete Fourier, DWT)^[28]、分段累积近似(Piecewise Aggregate Approximation, PAA)^[29]、符号集合近似(Symbolic Aggregate approximation, SAX)^[30-32]、可索引符号聚集近似(indexable SAX, iSAX)、分段线性近似(Piecewise Linear Approximation, PLA)、分段线性聚集近似(piecewise linear aggregate approximation, PLAA)^[33]等方法。其中,符号集合近似(SAX)是由Keogh E在分段累积近似(PAA)的基础上提出的一种有效的时间序列离散化降维方法,因其计算简单且高效、支持下界函数、算法不依赖于具体试验数据等特点而得到越来越多的关注,一经提出,便成为一种非常受欢迎的时间序列降维表示法^[30-31,34-36]。IC卡记录刷卡时间精确到秒,轨道交通站点进站或出站的刷卡数据形成的一日时间序列维数达到上万,引入SAX方法可以有效地对IC卡刷卡时间序列实现降维,且能保留时间序列的主要形态,有助于挖掘轨道站点的时间序列中蕴藏的不同模式。

随着大数据挖掘及可视化技术日渐成熟,大数据逐渐应用到城市空间、城市等级体系及居民时空

行为等研究领域^[37],本文拟基于2013年北京市连续三周的IC卡轨道站点刷卡日客流量数据,对具有完整数据源的195个轨道站点,探讨利用IC卡进出站刷卡数据形成的时间序列,引入时间序列分析方法——SAX方法,对时间序列进行降维和相似性度量,研究轨道站点的分类问题。

2 数据与方法

2.1 数据描述

本文使用的轨道交通站点数据为2013年3月北京市1-20日无重大节假日的完整的出行(包含完整进出站刷卡记录)记录数共74 516 278条,轨道站点共208个。为了保证数据的质量,对采集到的数据进行清洗,去掉进出站刷卡记录不完整的站点,包括机场轨道站点T2航站楼、T3航站楼、三元桥j、东直门j、北京西、白碓子、丰台东大街、丰台科技园、丰台南路、科怡路、六里桥、六里桥东、七里庄。最终选择具有完整的进出站刷卡记录的轨道站点共195个作为研究对象,研究日常情况下轨道站点的分类问题。记录包含的基本信息如表1所示。

2.2 数据处理

每个轨道站点从每日的早4时到晚24时内进出站客流量数据按时间顺序形成了时间序列,由于IC卡记录刷卡时间精确到秒,因此一日的轨道交通站点进站或出站的刷卡数据形成的时间序列长度为72 000,通常又被称为时间序列的维数^[38],大数据带来大样本的同时,也带来了维数灾难,维数膨胀给高维数据中模式识别和规则发现带来极大挑战^[38],如果直接对其进行分析将会带来巨大的计算资源耗费,且不利于发现数据间的内部关系^[39]。本文通过PAA^[29]方法实现对轨道站点时间序列降维,窗口间隔为3600,把原始时间序列的维数由72000降维到 $72\ 000 \div 3600 = 20$ 。

表1 北京市部分地铁站点2013年3月1日刷卡数据

Tab. 1 Smart card data of some subway stations in Beijing on March 1st, 2013

| ID | 进站名称 | 进站刷卡时间 | 出站名称 | 出站刷卡时间 |
|------------------|------|----------|-------|----------|
| 10007510****6142 | 长椿街 | 8:03:00 | 复兴门 | 8:10:26 |
| 10007510****5723 | 苹果园 | 8:12:00 | 玉泉路 | 8:29:08 |
| 10007510****2821 | 通州北苑 | 8:28:00 | 军事博物馆 | 9:25:23 |
| 10007510****6032 | 和平门 | 9:36:00 | 五棵松 | 10:07:08 |
| 10007510****5779 | 古城路 | 11:10:00 | 王府井 | 11:58:26 |

图1是安定门工作日及休息日进站客流量分布图。从图1可以看出,周一到周五的日客流量分布特征基本相似,具有相同的双高峰时段和平峰时段,而周六到周日的日客流量分布特征也基本相似,从早8:00到晚8:00客流量比较平稳。因此,把进站数据集分为工作日进站和休息日进站2类数据集来描述轨道站点进站的客流量分布特征。根据各站点的日出站客流量分布也可以得出相同结论,出站数据集可以分为工作日出站和休息日出站2类数据集来描述出站的客流量分布特征。图2是天通苑的工作日休息日进站和出站的日客流量分布图,可以看出其工作日进出站高峰时段完全不同,工作日进站高峰发生在早上上班时段,工作日出站高峰发生在下午下班时段,休息日高峰时段也是有差异的,这说明各个站点工作日休息日的进出站日客流量分布是有区别的,因此轨道站点的日客流量分布




图1 安定门工作日休息日进站日客流量分布

Fig. 1 Distribution of daily passenger boarding volume at AN DING MEN on weekdays and weekends




图2 天通苑工作日休息日进出站日客流量分布

Fig. 2 Distribution of daily passenger boarding and alighting volume at TIAN TONG YUAN on weekdays and weekends

特征可以使用工作日进站数据集(WB)、工作日出站数据集(WA)、休息日进站数据集(RB)和休息日出站数据集(RA)共4个数据集来描述。

2.3 SAX方法

SAX^[31,40]是由 Keogh E 在分段累积近似(PAA)的基础上提出的一种有效的时序数据降维方法,在时序相似性度量的研究中作为变换函数有着非常多的优点^[30-31,34-36],如具有较高的压缩率,保留了数据的局部信息,有效地实现了数据降维,解决了维数过高引起的问题;对噪声数据有较高的承受能力。分段过程既实现了消除噪声又实现了数据平滑处理,视觉直观简洁,具有多分辨率特性等优点,因此成为一种非常受欢迎的时间序列降维表示法,在时序挖掘的诸多领域都有广泛的应用。

2.3.1 符号化表示

SAX把一条任意长度为 m 的时间序列转换成一个长度为 n 的 ($n \ll m$) 符号串, n 是分段后子序列的数目。已知时间序列 $X = \{x_1, x_2, \dots, x_m\}$, SAX 的实现过程可分为以下3步:

(1) 正规化。把原始时间序列 X 按式(1)标准化为均值为0方差为1的序列 $X' = \{x'_1, x'_2, \dots, x'_m\}$ 。此标准化不会改变原始序列 X 的形状和尺度^[41]。

$$x'_i = \frac{x_i - u_x}{\sigma_x} \quad (1)$$

式中: x_i 是序列 X 中的某一时刻的观测值; u_x 是序列 X 中所有观测值的平均值; σ_x 是序列 X 所有观测值的标准差。

(2) PAA降维。利用PAA方法,按子序列长度为 w 把长度为 m 的时间序列划分为长度为 n 的序列 $\bar{X} = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n\}$, 并根据式(2)计算出每一段子序列的均值。

$$\bar{x}_j = \frac{n}{m} \sum_{i=\frac{m}{n}(j-1)+1}^{\frac{m}{n}j} x'_i \quad (2)$$

(3) 符号化表示。由于序列 \bar{X} 近似服从高斯分布,可以将其划分为 α 个等概率的区间,划分区间系列分裂点 β_i 是按照表2来取值,位于同一区间的序列值用相同的符号表示,最终得到其符号化表示 $\tilde{X} = \{\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n\}$ 。图3是安定门工作日进站客流量时间序列的SAX表示,原始时间序列长度为72000,窗口间隔为3600,使用PAA方法降维后的时间序列长度为20,将其划分为 $\alpha = 6$ 个等概率区间,划

表2 2种方法聚类的DB指数表^[40]
Tab. 2 DB index of two clustering methods

| 方法 | 分类个数 | | | | |
|------|------|------|------|------|------|
| | 6 | 7 | 8 | 9 | 10 |
| SAX | 1.27 | 1.30 | 1.26 | 1.26 | 1.29 |
| 欧式距离 | 1.39 | 1.50 | 1.38 | 1.37 | 1.36 |

分区间系列分裂点 β_i 的值分别为-0.97、-0.43、0、0.43、0.97, 最终得其符号化序列表示为AABEFDC-CBCCDFDBBBA。

2.3.2 相似性度量方法

时间序列长度为 m 的任意2个时间序列 $Q = \{q_1, q_2, \dots, q_m\}$ 和 $C = \{c_1, c_2, \dots, c_m\}$, 使用SAX方法得




图3 安定门工作日进站客流量时间序列的SAX表示

Fig. 3 SAX representation of distribution of passenger boarding volume at AN DING MEN on weekdays

到长度为 n 的符号化序列表示分别为 $\tilde{Q} = \{\tilde{q}_1, \tilde{q}_2, \dots, \tilde{q}_n\}$ 和 $\tilde{C} = \{\tilde{c}_1, \tilde{c}_2, \dots, \tilde{c}_n\}$ 。为了对符号化序列进行聚类, 首先需要计算各符号化序列之间的相似性, SAX方法里采用式(3)^[40]来计算序列 \tilde{Q} 和 \tilde{C} 之间的距离值, 以此表示它们之间的相似度。其中, $dist(\tilde{q}_i - \tilde{c}_i)$ 表示2个符号之间的距离值, 其计算方法按照文献[40]和表3来计算。

$$MINDIST(\tilde{Q}, \tilde{C}) = \sqrt{\frac{m}{n} \sum_{i=1}^n (dist(\tilde{q}_i - \tilde{c}_i))^2} \quad (3)$$

2.4 层次聚类方法^[41]

层次聚类(Hierarchical Clustering)通过计算不同类别数据点间的相似度来创建一棵有层次的嵌套聚类树。在聚类树中, 不同类别的原始数据点是树的最低层, 树的顶层是一个聚类的根节点。创建聚类树有自下而上凝聚和自上而下分裂2种方法。凝聚型层次聚类的算法是通过计算每一个类别的数据点与所有数据点之间的距离来确定它们之间的相似性, 距离越小, 相似度越高, 并将距离最近的2个数据点或类别进行组合, 生成聚类树。本文采用的是凝聚型层次聚类, 数据点之间的相似性采用式(3)实现, 最终的聚类个数根据DB指标^[42]确定。

3 结果分析

3.1 聚类结果

针对北京195个轨道站点, 每个站点的日客流特征使用4个数据集描述, 采用Matlab编程实现SAX方法和相似性度量, 采用层次聚类对轨道交通站点分类, 并根据DB指标^[42]从聚类个数为6-10类中选择DB指数最小的值对应的8类, 作为最优的聚类个数。8类结果如表4所示, 8个类别的站点工作日休息日进出站分时段客流量分布特征曲线如图4(a)-(h)所示。

3.2 聚类有效性指标

DB指标^[42]是基于样本的类内散度与各聚类中心间距的测度, 进行类数估计时其最小值对应的类数作为最优的聚类个数。表2是采用SAX方法和欧式距离2种方法对时间序列的相似性进行度量, 使用层次聚类聚6-10类, 计算其各自的聚类有效性DB指标。从表2可以得出, SAX方法的DB值更小, 说明使用SAX方法进行相似性度量, 其聚类质量更好。结合图4(a)-(h)的曲线特征, 也进一步证明了SAX方法的合理性。

表3 8类轨道站点的曲线特征

Tab. 3 The time distribution features of eight types of subway stations

| 类别 | 工作日曲线特征 | | | | 休息日曲线特征 | | | |
|----|-------------|------|-------------|------|------------|------|------------|------|
| | 进站 | | 出站 | | 进站 | | 出站 | |
| | 峰值及时间 | 峰值个数 | 峰值及时间 | 峰值个数 | 峰值及时间 | 峰值个数 | 峰值及时间 | 峰值个数 |
| 1 | 4.53 7:00 | 1 | 3.33 18:00 | 1 | 0.74 8:00 | 1 | 0.82 18:00 | 1 |
| 2 | 3.04 18:00 | 1 | 5.45 8:00 | 1 | 0.26 17:00 | 1 | 0.31 8:00 | 1 |
| 3 | 4.27 7:00 | 2 | 1.26 8:00 | 2 | 0.58 8:00 | 2 | -0.12 8:00 | 2 |
| 4 | 0.96 17:00 | 2 | 3.20 18:00 | 2 | 0.13 17:00 | 2 | 0.68 18:00 | 2 |
| | 3.82 8:00 | | 0.58 8:00 | | 0.74 9:00 | | 0.47 11:00 | |
| 5 | 0.68 18:00 | 2 | 2.90 18:00 | 3 | 0.65 16:00 | 1 | 1.15 17:00 | 2 |
| | 1.49 17:00 | | 1.93 8:00 | | 2.34 16:00 | | 2.05 10:00 | |
| 6 | -0.11 21:00 | 2 | 0.07 13:00 | 2 | 0.14 9:00 | 2 | 1.66 14:00 | 2 |
| | 2.27 8:00 | | 4.43 8:00 | | | | 0.22 8:00 | |
| 7 | 2.56 17:00 | 2 | 2.07 18:00 | 2 | 0.30 15:00 | 2 | 0.34 17:00 | 3 |
| | 1.42 8:00 | | 3.60 8:00 | | 0.08 10:00 | | 0.80 8:00 | |
| 8 | 2.47 17:00 | 4 | 1.65 18:00 | 5 | 0.95 16:00 | 3 | 0.37 13:00 | 2 |
| | 0.10 7:00 | | 0.88 8:00 | | 1.20 9:00 | | 0.68 11:00 | |
| | -0.33 10:00 | | -0.15 11:00 | | 0.78 12:00 | | 2.66 17:00 | |
| | 0.31 12:00 | | -0.22 13:00 | | 1.11 17:00 | | | |
| | 0.50 15:00 | | -0.16 15:00 | | | | | |
| | | | 0.41 18:00 | | | | | |

3.3 类别特征分析和空间分布分析

首先按照工作日进站、出站和休息日进站、出站对8类聚类结果求平均值,得到每类站点工作日进站、出站和休息日进站、出站对应的4条时间序列;然后分别对每类时间序列求其峰值、对应的时间以及峰值个数。判断峰值的方法为每类聚类结

果的平均值序列中某一元素的值比相邻2个元素的值都大且峰值的最小高度大于此类序列的平均值。8类轨道站点的曲线特征描述见表3。结合图4(a)-(h)和表3,每类站点的类别特征分析描述如下:

第1类站点工作日进出站日客流时间分布呈单

表4 层次聚类8类结果类

Tab. 4 Eight clusters of hierarchical clustering

| 类别 | 站点数量 | 站点名称 |
|----|------|--|
| 1 | 41 | 八里桥 北宫门 草房 常营 传媒大学 次渠 次渠南 褡裢坡 稻田 俸伯 巩华城 管庄 广阳城 果园 黄村火车站 黄渠 回龙观 回龙观东大街 霍营 旧宫 梨园 良乡大学城西 临河里 龙泽 苹果园 沙河 沙河高教园 生命科学园 石门 天通苑 天通苑北 天通苑南 通州北苑 土桥 西红门 西苑 小红门 新宫 育新 枣园 朱辛庄 |
| 2 | 39 | 白石桥南 朝阳门 车公庄 车公庄西 磁器口 大望路 大钟寺 灯市口 东大桥 东单 东四十条 阜成门 复兴门 高碑店 国贸 海淀黄庄 呼家楼 惠新西街北口 建国门 金台夕照 亮马桥 灵镜胡同 柳芳 木樨地 南礼士路 荣京东街 三元桥 苏州街 团结湖 万源街 五道口 西二旗 西土城 宣武门 雍和宫 永安里 张自忠路 知春里 中关村 |
| 3 | 34 | 安和桥北 八宝山 八角游乐园 北苑 慈寿寺 崔各庄 高米店北 公益西桥 古城路 海淀五路居 后沙峪 花梨坎 角门西 劲松 九棵树 立水桥 立水桥南 林萃桥 刘家窑 马家堡 南法信 蒲黄榆 青年路 十里堡 双桥 四惠东 宋家庄 孙河 陶然亭 同济南路 亦庄桥 亦庄文化园 永泰庄 玉泉路 |
| 4 | 14 | 高米店南 黄村西大街 篱笆房 良乡南关 马泉营 南邵 清源路 顺义 苏庄 天宫院 肖村 义和庄 圆明园 长阳 |
| 5 | 10 | 奥林匹克公园 奥体中心 北海北 动物园 南锣鼓巷 森林公园南门 天安门东 天安门西 王府井 西单 |
| 6 | 33 | 安定门 安华桥 安贞门 北土城 北苑路北 菜市口 大葆台 大屯路东 鼓楼大街 光熙门 和平里北街 和平门 和平西桥 花园桥 惠新西街南口 健德门 金台路 经海路 牡丹园 荣昌东街 上地 芍药居 生物医药基地 双井 四惠 太阳宫 万寿路 望京 望京西 五棵松 西小口 长椿街 知春路 |
| 7 | 22 | 巴沟 北京大学东门 北京南站 北京站 北新桥 崇文门 东四 东直门 郭公庄 国家图书馆 国展 积水潭 军事博物馆 农业展览馆 平安里 前门 中国人民大学 天坛东门 魏公村 西四 西直门 新街口 |
| 8 | 2 | 良乡大学城 良乡大学城北 |




图4 8类典型站点工作日休息日进出站分时段客流量分布

Fig. 4 Time distribution of passenger boarding and alighting volume of eight types of stations on weekdays and weekends

峰型,进出站客流高峰时间较为集中,在时间上具有明显的潮汐性,早高峰以进站客流为主且发生在上班时,晚高峰以出站客流为主且发生在下班时,早晚峰值平均值比较大。休息日和工作日类似,但高峰客流量远低于工作日。命名为居住型站点。例如,天通苑、回龙观就是典型的居住型站点,站点的主要功能是为上班人群提供交通职能。

第2类站点工作日进出站客流时间分布呈单峰型,进出站客流高峰时间较为集中,在时间上具有明显的潮汐性,但和1类相反,早高峰以出站客流为主且发生在上班时,晚高峰以进站客流为主且发生在下班时,早晚峰值平均值比较大。休息日和工作日类似,但高峰客流量远低于工作日。命名为办公型站点。例如,复兴门、中关村和西二旗等是典型的办公型站点。

第3类站点工作日进出站客流时间分布呈双峰型,进出站客流高峰时间较为集中,发生在上、下班时,但进站客流早高峰大于晚高峰、出站客流早高峰低于晚高峰,且进站客流早高峰大于出站客流早高峰、进站客流晚高峰低于出站客流晚高峰,进出站早晚峰值低于第1类和第2类。休息日和工作日类似,但高峰客流量远低于工作日且整体客流量相对平缓。命名为居住与办公混合型但偏居住型站点。典型的站点有陶然亭、立水桥和四惠东等,此类站点周围既有居民区又有办公区,但居民区的功能比重大于办公区。

第4类工作日进站客流时间分布呈双峰型,和第3类类似,但休息日高峰客流量整体比第3类大且相对平缓,休息日进站早高峰比第3类延迟1 h、晚高峰提前1 h,休息日出站早高峰推迟3 h,晚高峰提前1 h。此类站点周边既有居住地又有办公地,在此居住的居民,工作地可能在其它地点,也有部分人居住在别处,但在此类站点附近工作,表现出职住错位。命名为错位型站点。

第5类站点工作日客流时间分布进站呈双峰型,时间分别为下午17:00和晚上21:00,出站呈三峰型,时间分别为上午8:00、中午13:00和下午18:00。相比于第3、4类,进站晚高峰时间段长,出站高峰多了中午时段。休息日进站客流时间分布呈单峰,和第2类相比,差异比较大,中午12:00后以进站客流为主,且在下午15:00-16:00达到最大值,之后下降;休息日出站客流时间分布呈双峰型,和第3、4类相比从上午8:00之后以出站客流为主一直持续

到晚上19:00,且峰值出现在10:00和14:00。命名为景区及商业型站点。例如,王府井、天安门东、奥林匹克公园等站点。

第6类站点工作日进出站客流时间分布呈双峰型,进出站客流高峰时间较为集中,发生在上、下班时,但进站客流早高峰略低于晚高峰、出站客流早高峰高于晚高峰,且进站客流早高峰低于出站客流早高峰、进站客流晚高峰高于出站客流晚高峰,与第3类相反,进出站早晚峰值低于第1类和第2类。休息日和工作日类似,但高峰客流量远低于工作日且整体客流量相对平缓。命名为居住与办公混合但偏办公型站点。典型的站点有知春路、上地和生物医药基地等,此类站点周围既有居民区又有办公区,但居民区的功能比重小于办公区。

第7类站点工作日进出站客流时间分布呈双峰型,与第6类相似,但出站早高峰时段一直到12:00,推迟了2 h,进站晚高峰时段从中午12:00开始,提前了3 h。休息日进站日客流量呈双峰,但峰值出现在上午10:00和下午16:00,比第5类峰值出现早且高峰开始时段提前了4 h,出站日客流量呈三峰,与第5类工作日出站相似。命名为综合型站点。典型站点如前门、北京站、西直门站点,此类站点周围用地类型具有多样性特点。

第8类站点工作日进出站客流时间分布分别呈四峰和五峰,工作日进站呈三峰,出站呈双峰型,波动性比较大,命名为其它类型。

各类轨道站点在空间分布的位置如图5所示。从图5可以看出,第1类居住型站点和第4类错位型站点多数分布在地铁最远端,如昌平区、顺义区、大兴区、通州区和朝阳区与通州区交界处,这些区是人口居住密集的地区。不同的是,居住型站点更多集中在昌平区、顺义区、通州区和朝阳区,而错位型站点更多集中在大兴区和房山区,这和大兴区为北京经济技术开发区有一定的关系,一方面有居住其它地方的居民到这里工作,另一方面居住此地的居民工作地点在别处。第2类办公类类型站点、第5类景区及商业类站点、第6类居住型与办公型混合但偏办公型站点和第7类综合型站点大部分集中在市区。第3类居住型与办公型混合但偏居住型站点围绕市中心分散在周围;第8类站点其它类型的站点波动性大,休息日客流量远远大于工作日,这和周围是大学城有一定的关系,学生工作日在学校上课,周末外出频繁。



图5 轨道站点类型空间分布图

Fig. 5 Space distribution of subway stations types

4 结论与讨论

本文使用北京IC卡轨道站点刷卡数据形成的日客流量时间序列对轨道站点分类进行了研究。

首先,根据北京IC卡每个站点工作日及休息日进出站客流量分布图的特征不同,提出了描述轨道站点的4个数据集,即工作日进站数据集(WB)、工作日出站数据集(WA)、休息日进站数据集(RB)和休息日出站数据集(RA)。在此基础上,得到的聚类结果表明从这4个角度刻画站点日客流量特征的有效性。

其次,使用时间序列分析方法对轨道站点分类进行研究,首次引入符号集合近似(SAX)方法,对轨道站点日客流量形成的高维时间序列实现了高效的降维和相似性度量,通过在实际数据集上和欧式距离相似性度量方法的实验对比,证明了SAX方法的有效性,为轨道站点的分类研究提供了新思路。

再次,采用层次聚类方法并根据聚类有效性DB指数确定将195个站点分为8类更为合理,分别为居住类型、办公类型、居住与办公混合型但偏居住型、错位型、景区及商业型、居住与办公混合但偏办公型、综合型和其它型。

最后,结合8类站点的空间分布,发现居住型和错位型站点多数分布在地铁最远端,而办公型、景区及商业型、居住与办公混合型但偏办公型和综合

型站点大部分集中在市区,居住与办公混合型但偏居住型站点围绕市中心分散在周围,其结果有助于解读城市的不同功能分区及其所体现的居民出行行为特征,对理解城市空间格局及其演化过程提供了一定的依据。

今后将从以下2个方面开展后续研究:①随着轨道交通线路的建设,轨道交通出行比例较前几年有了很大的上升,因此将通过进一步获得北京轨道站点交通信息,得到更完善的北京各个轨道站点的出行信息;②由于城市的重大交通设施与空间结构之间存在互为基础、循环反馈的作用机制^[43-44],将结合每个站点的空间维度信息和其它相关辅助信息,如站点周边土地利用情况及兴趣点等信息,实现对轨道站点进行更加准确地分类,为研究城市功能和轨道站点规划设计和管理服务提供更准确的科学依据。

参考文献 (References):

- [1] 北京交通发展研究中心. 2013年北京市交通发展年度报告[R]. 北京:北京交通发展研究中心,2013. [Beijing Transportation Research Center. Beijing transportation annual report 2013[R]. Beijing: Beijing Transportation Research Center, 2013.]
- [2] 段德盟,张凡. 土地利用优化视角下的城市轨道交通站点分类研究——以西安地铁2号线为例[J]. 城市规划, 2013, 37(9):39-45. [Duan D G, Zhang F. Study on classification of urban rail transit stations from the perspective of land use optimization: A case study on Xi'an subway line 2[J]. City Planning Review, 2013, 37(9):39-45.]
- [3] Korf J L, Demetsky M J. Analysis of rapid transit access mode choice. Transportation research record. 1981, 817:29-35.
- [4] Bates Jr E G. A study of passenger transfer facilities (abridgment)[J]. Transportation research record, 1978, 662:23-25.
- [5] 谢岫. 城市轨道交通站点周边空间形态整合浅析:以南京为例[D]. 南京:南京大学, 2011. [Xie S. Study on morphological integration of space surrounding urban rail transit stations: A case study of Nanjing[D]. Nanjing: Nanjing University, 2011.]
- [6] 龚晓芳. 现代城市轨道交通站点地区规划研究[D]. 西安:长安大学, 2009. [Gong X F. The planning research of metro rail transit station in modern city[D]. Xi'an: Chang'an University, 2009.]
- [7] 吴娇蓉, 毕艳祥, 傅博峰. 基于郊区轨道交通站点分类的客流特征和换乘系统优先级分析[J]. 城市轨道交通研究, 2007, 10(11): 23-28. [Wu J R, Bi Y X, Fu B F. Characteristics of in passenger different suburban rail stations

- and the priority of transfer system[J]. *Urban Mass Transit*, 2007,10(11):23-28.]
- [8] 傅搏峰,吴娇蓉,陈小鸿.郊区轨道站点分类方法研究[J]. *铁道学报*,2008,30(6):19-23. [Fu B F, Wu J R, Chen X H. Method of classification of suburban rail transit station sites[J]. *Journal of the China Railway Society*, 2008,30(6): 19-23.]
- [9] 余丽洁,李岩,陈宽民.基于谱聚类的城市轨道站点分类方法[J]. *交通信息与安全*,2014,32(1):122-125,129. [Yu L J, Li Y, Chen K M. Using spectral clustering for urban rail station classification[J]. *Journal of Transport Information and Safety*, 2014,32(1):122-125,129.]
- [10] 马小毅,金安,刘明敏,等.广州市轨道交通客流特征分析[J]. *城市交通*,2013,11(6):35-42. [Ma X Y, Jin A, Liu M M, *et al.* Rail transit passenger flow characteristics in guangzhou[J]. *Urban Transport of China*, 2013,11(6):35-42.]
- [11] 王静,刘剑锋,马毅林,等.北京市轨道交通车站客流时空分布特征. *城市交通*,2013,11(6):18-27. [Wang J, Liu J F, Ma Y L, *et al.* Temporal and spatial passenger flow distribution characteristics at rail transit stations in beijing[J]. *Urban Transport of China*, 2013,11(6):18-27.]
- [12] 谭啸.天津城市轨道交通站点周边土地利用优化研究[D].天津:天津大学,2012. [Tan X. Study on optimization of land-use surrounding the urban rail station in Tianjin [D]. Tianjin: Tianjin University, 2012.]
- [13] 龙瀛,张宇,崔承印.利用公交刷卡数据分析北京职住关系和通勤出行[J]. *地理学报*,2012,67(10):1339-1352. [Long Y, Zhang Y, Cui C Y. Identifying commuting pattern of beijing using bus smart card data[J]. *Acta Geographica Sinica*, 2012,67(10):1339-1352.]
- [14] Ali A, Kim J, Lee S. Travel behavior analysis using smart card data[J]. *KSCE Journal of Civil Engineering*, 2016,20(4):1532-1539.
- [15] Gitanjali J. Data mining from smart card data using data clustering[J]. *International Journal of Applied Engineering Research*, 2016,11(1):347-352.
- [16] Long Y, Thill J C. Combining smart card data and household travel survey to analyze jobs-housing relationships in Beijing[J]. *Computers, Environment and Urban Systems*, 2015,53:19-35.
- [17] Joh C, Hwang C. Time-geographic analysis of trip trajectories and land use characteristics in Seoul metropolitan area by using multidimensional sequence alignment and spatial analysis[C]. 2010 AAG Annual Meeting, Washington, DC, 2010.
- [18] Jang W. Travel time and transfer analysis using transit smart card data[J]. *Transportation Research Record: Journal of the Transportation Research Board*, 2010,2144(1): 142-149.
- [19] Bagchi M, White P R. Use of public transports smart card data for understanding travel behavior[C]. *Proceedings of the European Transport Conference*, Strasbourg, 2003.
- [20] Roth C, Kang S M, Batty M, *et al.* Structure of urban movements: polycentric activity and entangled hierarchical flows[J]. *PloS one*,2011,6(1):e15923.
- [21] Ma X, Wu Y J, Wang Y, *et al.* Mining smart card data for transit riders' travel patterns[J]. *Transportation Research Part C: Emerging Technologies*, 2013,36:1-12.
- [22] 尹芹,孟斌,张丽英.基于客流特征的北京地铁站点类型识别[J]. *地理科学进展*,2016,35(1):126-134. [Yin Q, Meng B, Zhang L Y. 2016. Classification of subway stations in Beijing based on passenger flow characteristics [J]. *Progress In Geography*,2016,35(1):126-134.]
- [23] 戴霄,陈学武,李文勇.公交IC卡信息处理的数据挖掘技术研究[J]. *交通与计算机*,2006,24(1):40-42. [Dai X, Chen X W, Li W Y. Study of data mining technique for bus intelligent card data processing[J]. *Computer and Communications*, 2006,24(1):40-42.]
- [24] 杨智伟,赵骞,赵胜川,等.基于公交IC卡数据信息的客流预测方法研究[J]. *交通标准化*,2009(9):115-119. [Yang Z W, Zhao Q, Zhao S C, *et al.* Passenger flow volume forecasting method based on public transit intelligent card (IC) survey data. *Transport Standardization*, 2009,9:115-119.]
- [25] 何晓旭.时间序列数据挖掘若干关键问题研究[D].中国科学技术大学,2014. [He X X. Study on several key issues of time series data mining[D]. University of Science and Technology of China, 2014.]
- [26] 宋辞,裴韬.基于特征的时间序列聚类方法研究进展[J]. *地理科学进展*,2012,31(10):1307-1317. [Song C, Pei T. Research progress in time series clustering methods based on characteristics. *Progress in Geography*, 2012,31(10):1307-1317.]
- [27] Faloutsos C, Ranganathan M, Manolopoulos Y. Fast subsequence matching in time-series databases[C]. *Proceedings of the 1994 ACM SIGMOD International Conference on Management of Data*, 1994.
- [28] Chan K P, Fu A C. Efficient time series matching by wavelets[C]. *Proceedings - International Conference on Data Engineering*, 1999:126-133.
- [29] Keogh E, Chakrabarti K, Pazzani M, *et al.* Locally adaptive dimensionality reduction for indexing large time series databases[J]. *ACM SIGMOD Record*, 2001,30(2): 151-162.
- [30] Keogh E, Lin J, Fu A. Hot sax: Efficiently finding the

- most unusual time series subsequence[C]. Data mining, IEEE fifth international conference on, 2005:226-233.
- [31] Lin J, Keogh E, Wei L, *et al.* Experiencing SAX: a novel symbolic representation of time series[J]. Data Mining and knowledge discovery, 2007,15(2):107-144.
- [32] Keogh E, Chakrabarti K, Pazzani M, *et al.* Dimensionality reduction for fast similarity search in large time series databases[J]. Knowledge and information Systems, 2001, 3(3):263-286.
- [33] Hung N, Anh D. An improvement of PAA for dimensionality reduction in large time series databases[J]. PRICAI 2008: Trends in Artificial Intelligence, 2008,5351:698-707.
- [34] Camerra A, Palpanas T, Shieh J, *et al.* iSAX 2.0: Indexing and mining one billion time series[C]. Data Mining (ICDM), 2010 IEEE 10th International Conference on, IEEE, 2010.
- [35] 李桂玲,王元珍,杨林权,等.基于SAX的时间序列相似性度量方法[J].计算机应用研究,2012,29(3):893-896. [Li G L,Wang Y Z,Yang L Q, *et al.* Research on similarity measure for time series based on SAX[J]. Application Research of Computers, 2012,29(3):893-896.]
- [36] 刘威,邵良杉,曾繁慧,等.基于SAX方法的股票时间序列数据相似性度量方法研究[J].计算机工程与科学,2009, 31(9):115-118. [Liu W, Shao L S, Zeng F H, *et al.* Research on the stock time series data similarity based on sax[J].Computer Engineering&Science, 2009,31(9):115-118.]
- [37] 秦萧,甄峰,熊丽芳,等.大数据时代城市时空行为研究方法[J].地理科学进展,2013,32(9):1352-1361. [Qin X, Zhen F, Xiong L F, *et al.* Methods in urban temporal and spatial behavior research in the big data era[J].Progress in Geography, 2013,32(9):1352-1361.]
- [38] 谭璐.高维数据的降维理论及应用[D].长沙:国防科学技术大学,2005. [Tan L. The theory and application of the dimension reduction on the high-dimensional data set[D]. Changsha: National University of Defense Technology, 2005.]
- [39] 郝晓军,闫京海,樊友谊.大数据分析过程中的降维方法[J].航天电子对抗,2014,30(4):58-60. [Hao X J, Yan J H, Fan Y Y. Dimensionality reduction of large volumes of data analysis[J]. Aerospace Electronic Warfare, 2014,30(4):58-60.]
- [40] Lin J, Keogh E, Lonardi S, *et al.* A symbolic representation of time series, with implications for streaming algorithms. Proceedings of the 8th ACM SIGMOD workshop on Research issues in data mining and knowledge discovery, 2003:2-11.
- [41] Kaufman L, Rousseeuw P J. Finding groups in data: an introduction to cluster analysis[M]. John Wiley & Sons, 2009:157-159.
- [42] 王开军,李健,张军英,等.聚类分析中类数估计方法的实验比较[J].计算机工程,2008,34(9):198-199. [Wang K J, Li J, Zhang J Y, *et al.* Experimental comparison of clusters number estimation for cluster analysis[J]. Computer Engineering, 2008,34(9):198-199.]
- [43] 林琳,卢道典.广州重大交通设施建设与空间结构演化研究[J].地理科学,2011,31(9):1050-1055. [Lin L, Lu D D. Major transportation facility and spatial structure evolution in guangzhou[J]. Scientia Geographica Sinica, 2011, 31(9):1050-1055.]
- [44] 曹小曙,薛德升,阎小培.城市交通运输地理发展趋势[J].地理科学,2006,26(1):111-117. [Cao X S, Xue D S, Yan X P. Development tendency of urban transport geography [J]. Scientia Geographica Sinica, 2006,26(1):111-117.]