

## 基于表征学习的时空态势可视分析方法

李杰, 马欣莹, 赵丹宁, 谭淮联

(天津大学智能与计算学部 天津 300350)  
(jie.li@tju.edu.cn)

**摘要:** 时空态势描述了大量运动对象在一段时间内的空间位置变化过程, 分析和寻找时空态势对大量实际应用都具有重要意义. 针对海量的数据和无法避免的数据缺失为分析时空态势带来的问题, 提出一种从大规模时空数据中寻找代表性时空态势的表征学习的方法. 首先, 基于 Denoising Autoencoder 框架实现一个时空态势表征模型, 将每个时空态势编码为一个紧凑的表征向量, 向量之间的距离体现了时空态势之间的特征差异, 通过向编码器添加噪声并让解码器还原未带噪声的原始态势, 提高表征模型在数据缺失条件下的鲁棒性; 然后提出一种可视摘要算法, 以一个精简的小图标直观地显示连续时空态势的整体运动特征, 进一步构造了一个时空态势投影, 供用户快速地找到数据集中代表性的时空态势. 基于纽约出租车数据集和芝加哥犯罪数据集, 采用自相似和交叉相似的指标与既有相似性方法对比, 实验结果表明, 所提出的表征模型在大数据量、高缺失率条件下的准确性和鲁棒性, 并具有较高的执行效率; 用户实验包括选择和排序任务, 结果表明, 所提方法找到的代表性的时空态势与用户的主观认知更加一致.

**关键词:** 时空态势; 表征学习; 可视化摘要; 自编码器; 可视分析

**中图法分类号:** TP391.41 **DOI:** 10.3724/SP.J.1089.2024.20012

## Visual Analysis of Spatiotemporal Situation via Representation Learning

Li Jie, Ma Xinying, Zhao Danning, and Tan Huailian

(College of Intelligence and Computing, Tianjin University, Tianjin 300350)

**Abstract:** Spatiotemporal situations involve the process of change in the continuous spatial distribution of a large number of moving objects over a long period of motion. Aiming at the problems caused by the huge amount of data and unavoidable data loss and distortion for analyzing spatiotemporal situations, a representation learning-based approach is proposed for exploring representative spatiotemporal situations from large datasets. Firstly, we implement a spatiotemporal situation representation model based on the denoising autoencoder framework, which can encode each spatiotemporal situation as a compact representation vector. The distance between the representation vectors reflects the overall difference between different spatiotemporal situations. By introducing noise to the input data of the model encoder and allowing the decoder to restore the original data without noise, our model can effectively improve the characterization accuracy and robustness under the conditions of missing and distorted data. Second, we propose a summary algorithm that can visualize the overall characteristics of continuous spatiotemporal situations with a streamlined glyph. Furthermore, we construct a spatiotemporal situation projection for users to quickly find representative spatiotemporal situations from large datasets. Based on the New York taxi dataset and Chicago crime dataset, we use self-similarity and cross-similarity indicators to compare with the existing methods. The quantitative experiments show the representation model's accuracy, robustness, and high execution efficiency under the conditions of large data volume and a high missing rate. User experi-

收稿日期: 2022-10-19; 修回日期: 2023-05-06. 基金项目: 国家自然科学基金(61972278). 李杰(1984—), 男, 博士, 副教授, 硕士生导师, CCF 会员, 主要研究方向为机器学习、大数据可视分析; 马欣莹(2001—), 女, 在校学生; 赵丹宁(1996—), 女, 硕士研究生, 主要研究方向为数据可视化; 谭淮联(1998—), 男, 硕士研究生, 主要研究方向为数据可视化.

ments include selection and ranking tasks, and the results illustrate that the representative spatiotemporal situations found by our method are more consistent with users' subjective perceptions.

**Key words:** spatiotemporal situations; representation learning; visualization summary; autoencoder; visual analytics

时空态势描述了大量运动对象在连续时间内的位置变化过程. 分析时空态势在很多实际场景中具有重要意义. 例如, 城市管理者可以在城市车辆轨迹数据中挖掘典型的时空态势, 并据此优化城市的路网规划和流量控制策略; 安全人员可以根据犯罪活动位置分布的变化, 分析犯罪活动的演变趋势及产生原因, 并优化警力部署.

时空数据复杂和多变的特性使得从一个数据集中寻找并分析时空态势是一个具有挑战性的任务. 首先, 一个时空态势涉及大量运动对象在长时间内的海量数据, 这使得抽取和量化时空态势的特征具有较高的计算复杂度. 其次, 长时间的运动数据采集无法避免地存在数据缺失和失真, 这会降低分析结果的准确性. 最后, 采用逐帧计算快照<sup>[1]</sup>以及 2 个时空过程整体分布<sup>[2-3]</sup>之间的距离计算时空相似度, 为了解决采样率以及采样准确性的问题, 提出了基于表征学习的方法来计算时空数据表征的距离<sup>[4-5]</sup>. 但这些工作都缺乏对连续时空变化的整体特征的抽取和概括, 无法保证结果符合人的认知<sup>[6]</sup>.

在一个包含大量运动对象的、覆盖很大时空范围的、存在大比例数据缺失和失真的数据集中, 为了支持用户准确、高效、鲁棒地寻找代表性的时空态势, 本文提出了一种时空态势的可视分析方法, 它集成了一个表征模型和一个态势概览. 本文方法主要包括: (1) 使用自然语言的思想, 将每一个时空过程建模为一个句子, 每个时间帧的运动对象的分布则看成句子中的一个字; 并使用去噪自编码器(denoising autoencoder, DA)框架来实现表征模型, 简称 STS2vec(spatiotemporal situation). 通过向模型的原始输入序列中加入噪声, 以提高模型在数据缺失和失真情况下的准确性和鲁棒性. (2) 设计了一种摘要算法, 可以以一个简洁的图标表达连续时空态势的整体特征, 将表征后的特征向量与态势图标相结合生成态势投影, 可以帮助用户从大量的时空过程中识别典型的时空态势. (3) 在一个开放的真实世界数据集上开展了一系列实验. 首先通过定量地衡量模型的准确性和鲁棒性, 并在数据集中找到有意义的时空态势, 其中隐含了一

些与城市人群出行相关的独特时空模式; 然后通过用户实验证明时空态势表征之间的差异与用户的主观认知更加一致.

## 1 相关工作

### 1.1 时空表征

表征学习可以将复杂的高维的数据投影到低维潜空间, 被广泛应用于处理各类时空数据. 现有的时空数据表征主要聚焦在位置表征和轨迹表征 2 个方向.

在位置表征方面, 有很多基于 word2vec 或循环神经网络(recurrent neural networks, RNN)的模型. Yan 等<sup>[7]</sup>提出一个以 word2vec 为基础的代表模型 Place2Vec 用于捕捉空间位置的语义信息; POI2Vec<sup>[8]</sup>将地理影响和 word2vec 进行结合, 表征兴趣点(point of interest, POI)数据中的空间位置; Yabe 等<sup>[9]</sup>和 Shimizu 等<sup>[10-11]</sup>均利用 RNN 对空间位置进行表征; 还有双向 Transformer<sup>[12]</sup>和前馈神经网络<sup>[13]</sup>. 已有的工作旨在对位置进行表征, 并利用表征向量进行位置分类和预测等. 位置表征将单个位置作为表征对象, 其中不包含运动趋势或运动态势的变化.

在轨迹表征方面, 有很多基于 Autoencoder<sup>[14]</sup>的模型. Habit2vec<sup>[15]</sup>利用 word2vec 构建轨迹表征模型, 进而识别用户的居住模式和生活习惯; Yu 等<sup>[16]</sup>提出一个基于 Skip-Gram 的上下文和偏好感知模型(context-and preference-aware model, CPAM), 用于捕捉环境对轨迹特征的影响; t2vec<sup>[4]</sup>首次利用 Autoencoder 框架实现高效的轨迹相似性计算; Zhang 等<sup>[5]</sup>和 Yao 等<sup>[17-18]</sup>分别采用向表征模型中增加轨迹特征, 以提高表征质量. 对轨迹进行表征的结果包含了一条轨迹或一个运动对象的运动趋势信息, 因此, 在研究无固定对象的大规模运动趋势(如流行病传播、犯罪案件分布)时, 表征轨迹的思想并不适用.

与现有的位置表征相比, 本文重点关注时空态势的变化, 不仅是空间位置的变化, 还有时空中大量运动对象的整体变化趋势; 与轨迹表征相比,

本文能够在时空范围很大、运动对象很多的情况下, 寻找代表性的运动趋势, 这是现有的工作尚未涉及的。

## 1.2 时空可视化

时空数据具有维度多、体量大、应用场景广泛的特点, 在城市交通<sup>[19]</sup>、人口流动<sup>[20]</sup>、体育运动<sup>[21]</sup>、环境保护<sup>[22]</sup>中广泛应用. Kalamaras 等<sup>[19]</sup>提出一个基于道路行为聚类 and 异常检测的可视分析平台, 帮助用户发现道路行为中相似或者异常的情况; TelCoVis<sup>[20]</sup>帮助分析从电信数据中挖掘城市人口流动模式; Ye 等<sup>[23]</sup>开发了一个名为 ShuttleSpace 的沉浸式分析系统, 帮助教练员制定羽毛球比赛战术。

部分工作采用字形编码的方式对时空数据进行可视化展示. PassVizor<sup>[21]</sup>采用了基于字形的设计, 以揭示体育比赛中的运动员身份、空间位置、团队阵型等信息; Wu 等<sup>[24]</sup>将击球位置、击球方式和球速等属性进行编码, 便于分析击球时的战术模式. 这些方法仅对指定的特征进行分析, 并没有聚焦整体时空状态。

构建可视化概览是另一个经典的研究问题. MotionRugs<sup>[25]</sup>将每一帧的运动对象的位置进行排序, 并通过组合不同时间帧的排序结果以生成概览; Wulms 等<sup>[26]</sup>在此基础上优化了颜色平滑和排序算法, 但其并不适用于非轨迹数据; Maciejewski 等<sup>[27]</sup>采用了核密度估计来计算城市中离散数据的密度分布, 但其仅能对某一时间内的空间信息进行可视化, 用户无法捕捉连续时间内的时空数据变化。

可视化大空间范围在连续时间范围内的态势是一个尚未解决的研究课题, 本文将基于提出的表征模型开展时空态势概览研究, 以支持用户快速地发现给定数据集内的代表性的时空态势。

## 2 问题描述

### 2.1 时空态势定义

本文定义时空态势为在一个固定空间范围内所有运动对象在一段时间内空间位置的变化过程 (以下简称为时空过程). 令  $p$  是一个时空过程, 由多个快照组成的,  $p = (S_1, S_2, \dots, S_N)$ , 其中,  $S_i$  表示一个快照, 记录全部运动对象在  $t_i$  时刻空间位置的分布,  $i \in [0, N]$ , 如图 1 所示. 令  $O_j$  是第  $j$  个运动对象,  $L_i(O_j)$  表示对象  $O_j$  在  $t_i$  时刻的空间位置, 则  $S_i = L_i(O_1, O_2, \dots, O_M)$ .




图 1 时空过程  $p$  的结构

### 2.2 主要任务

本文的任务是: 给定一组时空过程, 然后训练一个表征模型  $f$ , 它可以将每一个时空过程  $p$  编码为向量  $h$ , 即  $h = f(p)$ ;  $h$  体现了  $p$  的时空特征. 时空特征运动对象在全部快照中的数量和位置变化。

图 2 所示为 6 种常见的时空特征. 可以看出, 图 2a 中, 随着运动对象的数量增加, 位置不变; 图 2b 中, 运动对象的位置向右移动, 数量不变; 图 2c 中, 随着运动对象的数量增加, 位置向右下方移动; 图 2d 中, 运动对象的数量和空间范围呈扩散式增长; 图 2e 中, 运动对象的数量和空间范围逐渐收缩; 图 2f 中, 运动对象的数量和空间范围先缩小而后增长。




图 2 6 种常见的时空特征

训练这个表征模型的关键是: (1) 提高其准确性, 以正确捕捉带有不规则运动特征的大量运动对象的时空过程; (2) 增强其鲁棒性, 以应对海量数据中无法避免的信息丢失和失真情况。

### 3 本文方法

#### 3.1 方法概述

本文设计了时空态势表征模型, 将时空过程编码为一个表征向量; 进一步提出一种时空摘要算法, 用来生成时空态势的精简图标。

#### 3.2 时空态势表征模型

本文使用序列到序列(sequence-to-sequence)的方法来构造时空态势表征模型。具体地, 将每一个时空过程看作一句话, 将每一个快照看作这句话中的一个字。使用了一个基于 DA 的框架来实现这个模型。其中编码器和解码器部分都采用长短期记忆(long short-term memory, LSTM)网络模型, 它常用来处理序列。

该表征方法包括了数据预处理、快照编码和时空过程表征 3 个阶段:

(1) 数据预处理。将每个时空过程离散为若干快照, 去除近似的快照; 所有时空过程去重后的快照将形成一个快照集合。

(2) 快照编码。为快照集合中的每一个快照生成一个长度固定的全局唯一编码。

(3) 时空过程表征。训练表征模型, 它可以将快照编码转化为时空过程的表征向量。

##### 3.2.1 数据预处理

首先将每个时空过程离散化为多个快照, 每个快照可以被可视化为一个热图, 则运动对象频繁出现的地区应具有更高的热度, 如图 3a 所示。其次, 将对时空过程对应的空间范围网格化, 并为每一个时空快照构造一个特征矩阵, 其中的每个坐标记录了对应网格内的运动对象出现次数, 如图 3b 所示。最后, 将该特征矩阵二值化, 将矩阵中所有大于等于设定阈值的元素置为 1, 否则为 0, 如图 3c 所示。在 play2vec<sup>[28]</sup>工作中也采取了矩阵二值化的处理, 其研究对象为足球运动员, 由于对象数量少, 所以该阈值的设定为 1。但在本文中, 研究对象数目较多, 研究人员根据多次实验的结果得出该阈值大小, 保证了矩阵中 0 和 1 的比例。

二值化的目的是抽取矩阵中的关键特征, 因为很多细小的数值事实上对于时空过程整体的时空态势分析无较大贡献; 同时要避免随机的数值

波动对表征结果的影响。令时空过程的数量为  $m$ , 每个时空过程包括  $n$  个快照, 则这个步骤会产生  $m \times n$  个二值化特征矩阵。




图 3 时空快照预处理

本文使用 Jaccard 相似系数来判断 2 个矩阵的相似程度, 公式为

$$J(\mathbf{M}, \mathbf{M}') = \frac{|\mathbf{M} \cap \mathbf{M}'|}{|\mathbf{M} \cup \mathbf{M}'|} \quad (1)$$

其中,  $\mathbf{M}$  和  $\mathbf{M}'$  表示 2 个快照的二值化特征矩阵,  $|\mathbf{M} \cap \mathbf{M}'|$  表示在  $\mathbf{M}$  和  $\mathbf{M}'$  中值都为 1 的元素总数,  $|\mathbf{M} \cup \mathbf{M}'|$  表示  $\mathbf{M}$  为 0 且  $\mathbf{M}'$  为 1, 或者  $\mathbf{M}$  为 1 且  $\mathbf{M}'$  为 0 的元素总数。

通过设定一个相似度阈值, 将特征矩阵间相似度大于该阈值的时空快照合并。该阈值的大小可以影响每个时空过程中时空快照的数量, 阈值越大, 因为近似而被去除的快照就越少; 反之, 去除的快照就越多。实验过程中通过调整这个相似度阈值, 使得去重后时空快照的大小占全部时空过程的快照总量的 15%~18%(第 5 节证明这个比例能够产生最高的查询准确性)。

对时空快照进行去重时, 首先逐个扫描二值化特征矩阵, 当它与已扫描过的矩阵被判定为不相似时, 其对应的快照存入时空快照集合中; 反之, 若矩阵与已扫描过的某个矩阵被判定为相似时, 则不会将其保存到快照集合中。

##### 3.2.2 快照编码

本文采用隐式矩阵分解模型(skip-gram with negative sampling, SGNS)<sup>[29]</sup>来获得每一个快照的编码。在数据预处理部分将较短时间差导致的相似快照合并之后, 使得不同的时空过程中拥有更多相同的快照, 产生自然语言分析中必需的不同句子中出现相同字的情况, 因此可以依据快照在时空过程中的共现情况, 实现准确的快照编码。时空过程中频繁出现的快照将具有相似的编码, 例如, 在早高峰这个时空过程中, 对象  $a$  和对象  $b$  存在的时空快照总是出现, 那么在这些时空过程中, 它们出现的对应快照的编码就会相似, 这样在态势表征中更有利于发现代表性时空态势。

训练集中包含多个训练样本, 每一个训练样本都由一个给定的目标快照  $s$ 、一个正样本和  $k$  个负样本构成. 本文称一个快照为  $s$  的正样本, 如果它位于  $s$  的上下文中(前后  $w$  个快照,  $w$  为窗口大小), 定义为  $o$ ; 反之, 如果一个快照位于  $s$  的窗口以外, 则称之为负样本, 定义为  $q$ .  $O$  和  $Q$  分别表示  $s$  的全部正样本和负样本集合. 每次迭代训练  $s$  的编码时, 将随机从  $O$  中选择正样本, 并以一元模型分布从集合  $Q$  选择负样本, 即

$$P(q) = \frac{f(q)^\alpha}{\sum_{q' \in Q} f(q')^\alpha} \quad (2)$$

其中,  $P(q)$  为负样本  $q$  被选中的概率,  $f(q)$  是  $q$  在快照集中出现的频率,  $\alpha$  是超参数. 通过一元模型, 出现频率更高的快照将会有更大的概率成为负样本.

本文为每一个快照  $s$  随机初始化一个编码, 令  $\mathbf{v}_s \in \mathbb{R}^d$  代表快照  $s$  的编码,  $\mathbf{v}_o \in \mathbb{R}^d$  代表  $s$  的正样本的编码,  $\mathbf{v}_q \in \mathbb{R}^d$  代表负样本的编码, 通过噪声对比估计损失(noise-contrastive estimation loss)<sup>[30]</sup>来计算每次更新  $\mathbf{v}_s$  时的损失值. 本文希望  $\mathbf{v}_s$  与  $\mathbf{v}_o$  尽可能相似, 而  $\mathbf{v}_s$  与  $\mathbf{v}_q$  尽可能不相似.

在模型训练中, 本文采用 Adam 随机梯度下降算法对快照的编码进行更新, 随着训练的进行, 该算法可以对模型中的参数进行动态调整, 同时引入动量. 这样做的目的是避免损失优化时模型进入局部最优的陷阱中, 以达到全局最优. 通过多次迭代可为每一个时空快照  $s$  获得一个体现其上下文共现情况的编码.

### 3.2.3 时空态势表征

本文采用 DA 框架来构造时空态势表征模型, 并选择 LSTM 来实现编码器和解码器. 完整框架如图 4 所示. 采用 2 个步骤向时空快照  $s$  中加入噪声, 得到带噪声的时空快照  $s'$ . 首先, 以一个固定的缺失率随机删除  $s$  中的部分运动对象; 然后, 以一个固定的噪声率移动部分剩余运动对象的位置, 并让位置的偏差值符合正态分布. 编码器的输入是带有噪声的全部时空快照的编码序列  $\{\mathbf{v}_{s'_1}, \mathbf{v}_{s'_2}, \dots, \mathbf{v}_{s'_i}\}$  ( $\mathbf{v}_{s'}$  表示  $s'$  的编码), 其输出是一个更加紧凑的表征向量  $\mathbf{h}_t^{\text{enc}}$ . 解码器以  $\mathbf{h}_t^{\text{enc}}$  为输入, 并预测原始的、没有噪声的快照编码序列  $\{\mathbf{v}_{s_1}^{\text{pred}}, \mathbf{v}_{s_2}^{\text{pred}}, \dots, \mathbf{v}_{s_i}^{\text{pred}}\}$ . 这里使用平均交叉熵作为损失函数.




图 4 表征模型结构

本文通过去除噪声来提升模型的鲁棒性. 由于长时间的运动数据采集, 不可避免地会产生大数据量、高缺失率的问题. 因此, 在模型训练时, 人为地生成带有噪声的数据, 将其作为模型的输入训练解码器, 以获得干净的无噪声的数据. 这些模型在带有噪声的训练集上进行训练, 会进一步加强在数据缺失和失真场景下的表征能力, 因此具有更强的鲁棒性. 但是需要注意的是, 添加噪声

确实是会提高模型的鲁棒性, 但也有负面影响, 受噪声影响, 模型的复杂度可能会提高.

## 3.3 态势概览

### 3.3.1 时空态势摘要算法

本文提出了时空摘要算法, 用来生成时空态势的精简图标. 首先, 该算法使用核密度估计计算每个快照的运动对象分布密度函数, 该空间范围内  $(x, y)$  处的概率密度估计为

$$\hat{f}_h(x, y) = \frac{1}{N} \sum_{i=1}^N \frac{1}{h^2} K\left(\frac{x-x_i}{h}, \frac{y-y_i}{h}\right) \quad (3)$$

其中,  $N$  为样本总数;  $K(\cdot)$  为核函数;  $h$  为核带宽. 本文使用高斯核函数, 并采用 Scott 等<sup>[31]</sup>提出的方法计算核带宽. 之后, 使用引力模型计算不同样本点之间的相互作用力

$$F(i, j) = \sum_{i=1}^N \sum_{j=1}^M (x_i - x)(y_j - y) \frac{\hat{f}_h(x_i, y_i) \cdot \hat{f}_h(x_j, y_j)}{d_{ij}^2} \quad (4)$$

其中,  $i$  和  $j$  分别为 2 个不同的样本点;  $d_{ij}$  为它们之间的距离. 相互作用力方向由 2 个点的坐标确定.

将不同快照中不同样本点之间的相互作用力进行矢量叠加, 计算出  $(x, y)$  处的流量大小及方向可以得到该时空态势的流量图.


最后, 使用箭头表示每一处的流量, 箭头指向与流量方向一致, 箭头长度由流量大小决定. 图 5b 列举了 5 个不同的时空态势图标以及对应的时空数据可视化结果.

### 3.3.2 态势投影


本文进一步构建态势投影作为多个时空态势的概览, 如图 5a 所示. 本文使用  $t$  分布随机邻居嵌入算法( $t$ -distributed stochastic neighbor embedding,  $t$ -SNE)根据每个时空态势的表征进行降维, 获取每个时空态势的投影坐标. 为了降低杂乱度, 该方法采用网格的形式对投影坐标进行布局, 每个网格所覆盖的空间大小相同, 且全部的时空态势图标必须按照网格对齐, 时空态势的投影坐标分布在不同的网格中. 如果某个网格中仅存在一个时空态势的坐标, 则在该网格中展示对应的时空态势图标; 如果某个网格中没有坐标, 则不展示任何内容. 多个态势图标可能落入一个网格, 由于这些态势的特征向量具有较高相似度, 将随机从中选择一个进行绘制.

这个设计将时空态势图标和投影分布结合起来, 用户因此可以根据投影位置直观地观察时空态势之间的相似度, 并快速地了解不同时空态势的主要特征.

在态势投影中, 投影坐标的远近代表了对应的时空态势特征向量的相似程度, 因此, 对应的时空态势整体特征也具有较高的相似度. 从图 5a 中发现, 相似的时空态势在投影中距离相近, 呈现出聚簇状; 其中, ①~⑤分别是投影中找到的 5 个具有相似时空态势的聚簇.



a. 时空过程表征投影



b. 5种典型的时空态势可视化

图 5 曼哈顿出租车数据时空态势可视化结果

## 4 案例研究

本文给出在纽约出租车数据集上找到的代表性时空态势. 该数据集来源于 2011 年 7 月纽约市曼哈顿区内 1 293 万条的载客记录, 每条记录包含了上下车位置(经度和纬度)和时间戳.

该案例将出租车在 2h 内的上下车位置分布的连续变化看作一个时空过程, 总共得到 372 个时空过程(12 个过程/d, 共 31 d). 之后对这些时空过程进行表征, 并构建如图 5a 所示的态势投影; 图 5b 展示了从投影中找到的部分代表性时空态势.

**态势 1.** 出租车数量增加, 且呈现出向右扩散的特征, 如图 5a 中①所示. 该类时空态势普遍发生在工作日早高峰时间段(06:00—08:00), 它在运动对象数量增长的同时, 运动范围呈现扩散的趋势; 从起初只有 2 个街区打车较为活跃, 逐渐蔓延到曼哈顿大部分的街区.

**态势 2.** 出租车数量增加, 但无明显的扩散方向, 如图 5a 中②所示. 该类时空态势普遍发生在休息日的上午(10:00—12:00), 它只包含较少的运

动对象, 且在无明显的活跃区域.

**态势 3.** 出租车数量减少, 且活动中心向左下方移动, 如图 5a 中③所示. 该类时空态势普遍发生在夜晚(22:00—00:00), 它与现实世界的情况相吻合, 曼哈顿中城区中的大部分地区是传统商业区, 夜晚时这部分地区打车状态较为活跃; 午夜时, 中城区的热度渐渐下降, 与此同时热度上升的地区为下城区, 这是因为下城区中涵盖了大量的公寓和住宅楼.

**态势 4.** 出租车数量整体较少, 且向活动中心向右上部移动, 如图 5a 中④所示. 该态势与态势 1 的运动趋势相近, 但运动对象数量更少, 表明了表征模型捕捉数量差异的能力.

**态势 5.** 出租车数量较多, 且活动向左下方移动. 该态势与态势 3 的运动趋势较相似, 但运动对象数量不同, 再次证明了表征模型的有效性.

## 5 实验

本文定量地评价了模型的准确性、鲁棒性、效率以及一个重要超参对模型的影响, 通过 2 个用户实验(选择任务和排序任务)来验证该方法的查询结果与用户认知的一致性.

### 5.1 定量实验

#### 5.1.1 实验设置

本文基于 2 个数据集开展了定量实验. 除了案例研究中使用的纽约出租车数据, 还使用了芝加哥犯罪数据集. 该数据总共包含 210 个时空过程, 每个过程记录了某类犯罪在一天中长度为 4h 的时段内(一天共 6 个时段, 即 00:00—03:59, 04:00—07:59, 08:00—11:59, 12:00—15:59, 16:00—19:59, 20:00—23:59; 35 个犯罪类型; 共 6 个过程), 在 17 年间的犯罪事件发生地点分布的变化情况.

该实验一共选择了 3 种参照方法:

(1) BD(bitness difference)<sup>[32]</sup>. 因为快照的二值化矩阵是同型矩阵, 并且每一位的数值 1 和 0 是根据该位置对象的数目得来, 所以本文使用 BD 方法, 它通过比较简单的矩阵减法运算, 将 2 个时空快照对应的矩阵进行按位相减, 并计算全部位置的差异的绝对值之和作为 2 个快照的相似度; 同时计算 2 个时空态势中对应位置的时空快照之间的相似度之和作为 2 个时空态势的整体相似度.

(2) ED(Euclidean distance). 该方法计算 2 个时空快照之间的欧几里得距离, 并累加全部快照对的距离作为 2 个时空态势的距离.

(3) JD(Jeffery divergence)<sup>[4]</sup>. 该方法计算 2 个快照之间的 JD 作为快照相似度, 并将全部快照的该分数累加作为态势间的相似度.

把曼哈顿和芝加哥分别划分为 960(30×32)和 1 050(30×35)个网格, 每个网格分别覆盖 0.003°×0.003°和 0.001°×0.001°的空间范围. 在所有的实验中, 调整字与字的相似度阈值来使得语料库中字的数量占全部时空快照数量的 15%~18%, 表征向量的维度为 20.

本文实验均在 GPU(XEON E5-2680, 196GB, 2080 Ti×4)服务器上进行. 本文方法在 Python3.6 和 TensorFlow1.8.0 上实现.

#### 5.1.2 准确性

本文采用经典的自相似指标<sup>[4]</sup>来评价查询相似时空过程的准确性. 首先从数据集中随机选择 200 个时空过程作为测试集  $T$ ; 之后对  $T$  中的每个时空过程  $p$  随机选择部分快照来创建 2 个子过程,  $T$  中所有的时空过程的子过程形成 2 个集合, 即  $T_a$  和  $T_b$ . 从  $T_a$  中随机选择 10 个子过程, 对于每一个选出的子过程  $p_a$ , 在  $T_b$  中查询它的相似时空过程. 理论上, 和  $p_a$  产生自相同时空过程的子过程, 即  $p_b$ , 应该与  $p_a$  最相似. 通过

$$S_{\text{score}} = \frac{1}{10} \sum_{p_a} \text{rank}(p_b) \quad (5)$$

计算 10 个查询中  $p_b$  的平均排名作为自相似指标分数(更小的指标分数代表更高的查询准确性). 准确性评价实验引入了 2 个控制变量, 即采样率和快照数量. 采样率指的是构建子过程时选择保留原过程中全部快照数量的比例; 快照数量等于每一个时空过程中划分的时间间隔数量(更小的时间间隔会产生更多的快照).

2 个数据集上的自相似指标结果分别如表 1 和表 2 所示. 可以看出, 本文方法的准确性在整体上优于其他 3 种对比方法, 其在低采样率的条件下的准确性优势明显, 进而证明了本文方法更加适用于数据缺失条件下的情况.

#### 5.1.3 鲁棒性

本文采用交叉相似指标<sup>[4]</sup>来评估模型在数据缺失和数据误差条件下的鲁棒性.

首先, 将测试集  $T$  中的 200 个时空过程进行两两配对, 组成 100 个时空过程组, 即  $(p_1, p_2)$ ; 然后, 随机删除  $p_1$  和  $p_2$  中的部分运动对象坐标信息或对  $p_1$  和  $p_2$  中的部分运动对象坐标信息添加随机的噪声(噪声偏移量符合正态分布)来创建一个新

表 1 曼哈顿出租车数据的自相似指标分数结果

| 方法                 | 快照数量 | 采样率          |              |              |              |              |             |             |             |
|--------------------|------|--------------|--------------|--------------|--------------|--------------|-------------|-------------|-------------|
|                    |      | 0.2          | 0.3          | 0.4          | 0.5          | 0.6          | 0.7         | 0.8         | 0.9         |
| BD <sup>[32]</sup> | 36   | 336.02       | 255.29       | 191.34       | 152.92       | 92.03        | 58.62       | 45.83       | 15.08       |
|                    | 24   | 284.08       | 210.70       | 118.93       | 70.34        | 39.32        | 17.70       | 10.58       | 2.92        |
|                    | 12   | 223.80       | 143.16       | 86.33        | 29.06        | 20.44        | 5.53        | 1.57        | 1.01        |
| ED                 | 36   | 329.62       | 236.80       | 175.01       | 147.52       | 66.73        | 40.76       | 22.14       | 12.83       |
|                    | 24   | 258.28       | 189.08       | 110.02       | 41.31        | 20.33        | 10.16       | 3.10        | 1.00        |
|                    | 12   | 222.40       | 101.14       | 71.56        | 17.21        | 8.34         | 2.74        | 1.00        | 1.00        |
| JD <sup>[4]</sup>  | 36   | 122.46       | 59.92        | 29.26        | 21.62        | <b>12.09</b> | <b>5.86</b> | <b>4.65</b> | <b>1.04</b> |
|                    | 24   | 114.95       | 48.80        | 18.52        | 6.26         | 4.23         | <b>1.52</b> | <b>1.00</b> | <b>1.00</b> |
|                    | 12   | 97.02        | 39.37        | 14.74        | 3.62         | 2.48         | <b>1.15</b> | <b>1.00</b> | <b>1.00</b> |
| STS2vec            | 36   | <b>40.93</b> | <b>36.96</b> | <b>20.76</b> | <b>15.60</b> | 12.94        | 10.64       | 8.31        | 4.20        |
|                    | 24   | <b>21.03</b> | <b>18.80</b> | <b>11.71</b> | <b>5.80</b>  | <b>4.19</b>  | 3.76        | 3.16        | 2.40        |
|                    | 12   | <b>12.92</b> | <b>10.60</b> | <b>5.08</b>  | <b>2.00</b>  | <b>1.72</b>  | 1.50        | 1.38        | 1.20        |

注. 粗体表示最优值.

表 2 芝加哥犯罪数据的自相似指标分数结果

| 方法                 | 快照数量 | 采样率          |              |              |              |              |              |              |              |
|--------------------|------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                    |      | 0.2          | 0.3          | 0.4          | 0.5          | 0.6          | 0.7          | 0.8          | 0.9          |
| BD <sup>[32]</sup> | 51   | 169.14       | 157.90       | 143.53       | 128.50       | 114.78       | 82.75        | 60.92        | 39.92        |
|                    | 34   | 86.12        | 73.11        | 66.13        | 61.94        | 52.74        | 52.11        | 45.97        | 30.41        |
|                    | 17   | 60.69        | 52.26        | 36.41        | 38.07        | 34.11        | 26.08        | 16.69        | 5.97         |
| ED                 | 51   | 192.43       | 177.21       | 174.68       | 166.77       | 146.25       | 133.18       | 89.34        | 53.41        |
|                    | 34   | 104.14       | 90.69        | 85.21        | 82.77        | 71.09        | 69.18        | 54.07        | 29.45        |
|                    | 17   | 65.61        | 61.82        | 58.41        | 56.46        | 47.22        | 38.84        | 30.27        | 25.16        |
| JD <sup>[4]</sup>  | 51   | 123.27       | 103.40       | 99.75        | 87.58        | 70.65        | 50.84        | 44.70        | 18.31        |
|                    | 34   | 50.75        | 37.46        | 37.36        | 36.42        | 26.39        | 24.28        | 20.58        | 9.79         |
|                    | 17   | 26.09        | 22.37        | 22.57        | 18.28        | 16.43        | 14.89        | 13.20        | 10.46        |
| STS2vec            | 51   | <b>61.71</b> | <b>29.89</b> | <b>21.71</b> | <b>21.98</b> | <b>18.91</b> | <b>17.73</b> | <b>18.19</b> | <b>16.36</b> |
|                    | 34   | <b>19.07</b> | <b>17.58</b> | <b>16.98</b> | <b>15.79</b> | <b>14.51</b> | <b>12.67</b> | <b>11.03</b> | <b>7.74</b>  |
|                    | 17   | <b>13.15</b> | <b>8.72</b>  | <b>8.51</b>  | <b>5.82</b>  | <b>4.88</b>  | <b>4.25</b>  | <b>3.78</b>  | <b>2.16</b>  |

注. 粗体表示最优值.

的时空过程组  $(p'_1, p'_2)$ ; 交叉计算 2 个时空过程对之间的相似度差异. 理论上, 由于  $p'_1$  和  $p'_2$  是从  $p_1$  和  $p_2$  中得到的,  $p_1$  和  $p_2$  的相似度应该与  $p'_1$  和  $p'_2$  的相似度高度一致, 所以对应的交叉相似指标应该比较低. 计算 100 个时空过程组的交叉相似指标总分数, 即

$$S_{\text{cross}} = \frac{1}{100} \sum \frac{|S_{\text{sim}}(p'_1, p'_2) - S_{\text{sim}}(p_1, p_2)|}{S_{\text{sim}}(p_1, p_2)} \quad (6)$$

其中,  $S_{\text{sim}}(p_1, p_2)$  是  $p_1$  和  $p_2$  的相似度计算结果, 可以采用本文方法或者其他对比方法进行计算,  $S_{\text{sim}}(p'_1, p'_2)$  代表  $p'_1$  和  $p'_2$  的相似度计算结果.

2 个数据集上的交叉相似指标结果分别如表 3 和表 4 所示, 可以看出, 本文方法在数据不同缺失

率和噪声率下的交叉相似指标分数更小, 表明其具有更高的鲁棒性.

#### 5.1.4 效率

本文定义了一个查询任务, 即从  $T_a$  中随机选择不同数量的时空过程, 并在  $T_b$  中查询它的相似时空过程, 然后对比 4 种方法在执行上述任务时的时间开销. 2 个数据集上的实验结果分别如表 5 和表 6 所示, 可以看出, 本文方法在整体上具有更高的执行效率.

#### 5.1.5 超参数影响

最后, 本文分析了时空快照集合  $V$  的大小占全部时空过程的快照总量的比例(字比例)对表征准确性的影响. 由于字比例过低会导致时空过程中出现重复快照的概率增加, 使得本文时空过程

表 3 曼哈顿出租车数据的交叉相似指标分数结果

| 方法                 | 缺失率          |              |              |              |              | 噪声率          |              |              |              |              |
|--------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                    | 0.1          | 0.2          | 0.3          | 0.4          | 0.5          | 0.1          | 0.2          | 0.3          | 0.4          | 0.5          |
| BD <sup>[32]</sup> | 0.161        | 0.189        | 0.271        | 0.386        | 0.403        | 0.087        | 0.184        | 0.217        | 0.288        | 0.301        |
| ED                 | 0.572        | 0.628        | 0.680        | 0.747        | 0.807        | 0.129        | 0.186        | 0.263        | 0.324        | 0.511        |
| JD <sup>[4]</sup>  | 0.273        | 0.292        | 0.374        | 0.398        | 0.428        | 0.104        | 0.176        | 0.273        | 0.386        | 0.467        |
| STS2vec            | <b>0.061</b> | <b>0.092</b> | <b>0.163</b> | <b>0.193</b> | <b>0.220</b> | <b>0.023</b> | <b>0.054</b> | <b>0.072</b> | <b>0.093</b> | <b>0.128</b> |

注. 粗体表示最优值.

表 4 芝加哥犯罪数据的交叉相似指标分数结果

| 方法                 | 缺失率          |              |              |              |              | 噪声率          |              |              |              |              |
|--------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                    | 0.1          | 0.2          | 0.3          | 0.4          | 0.5          | 0.1          | 0.2          | 0.3          | 0.4          | 0.5          |
| BD <sup>[32]</sup> | 0.025        | 0.029        | 0.038        | 0.044        | 0.059        | 0.011        | 0.026        | 0.042        | 0.081        | 0.179        |
| ED                 | 0.224        | 0.274        | 0.308        | 0.381        | 0.418        | 0.183        | 0.277        | 0.304        | 0.339        | 0.416        |
| JD <sup>[4]</sup>  | 0.172        | 0.209        | 0.270        | 0.392        | 0.404        | 0.136        | 0.182        | 0.281        | 0.305        | 0.394        |
| STS2vec            | <b>0.006</b> | <b>0.012</b> | <b>0.018</b> | <b>0.023</b> | <b>0.031</b> | <b>0.004</b> | <b>0.007</b> | <b>0.009</b> | <b>0.014</b> | <b>0.029</b> |

注. 粗体表示最优值.

表 5 曼哈顿出租车数据模型效率评估结果 s

| 方法                 | 查询次数           |                |                |                |
|--------------------|----------------|----------------|----------------|----------------|
|                    | 50             | 100            | 150            | 200            |
| BD <sup>[32]</sup> | 0.008 4        | 0.016 8        | 0.026 0        | 0.033 4        |
| ED                 | 1.725 1        | 3.460 5        | 5.205 9        | 7.018 0        |
| JD <sup>[4]</sup>  | 3.751 3        | 7.641 2        | 11.571 0       | 15.250 4       |
| STS2vec            | <b>0.000 4</b> | <b>0.000 6</b> | <b>0.000 8</b> | <b>0.001 2</b> |

注. 粗体表示最优值.

表 6 芝加哥犯罪数据模型效率评估结果 s


| 方法                 | 查询次数           |                |                |                |
|--------------------|----------------|----------------|----------------|----------------|
|                    | 50             | 100            | 150            | 200            |
| BD <sup>[32]</sup> | 0.014 2        | 0.028 2        | 0.042 2        | 0.055 7        |
| ED                 | 4.657 3        | 9.408 0        | 14.095 5       | 19.027 0       |
| JD <sup>[4]</sup>  | 9.437 7        | 18.785 6       | 28.427 5       | 37.982 0       |
| STS2vec            | <b>0.000 4</b> | <b>0.000 6</b> | <b>0.000 8</b> | <b>0.001 0</b> |

注. 粗体表示最优值.

的部分特征缺失, 进而对模型的训练效果产生影响; 反之, 字比例过高, 意味着本文对于删除时空快照的标准更严格, 使得时空快照集合  $V$  过大, 导致更高的训练复杂度, 降低模型效率.


实验观察不同比值对于自相似指标分数的影响, 并且固定了采样率为 0.5, 同时设置 2 组不同的网格大小, 以避免其他参数对结果的影响. 出租车数据实验结果如图 6a 所示, 选择的网格大小为  $0.002^\circ$  和  $0.003^\circ$ , 芝加哥犯罪数据实验结果如图 6b 所示, 选择的网格大小为  $0.001^\circ$  和  $0.002^\circ$ . 发现在 2 个数据集中, 随着字比例的升高, 自相似分数呈现出先下降后上升的趋势. 当比值在 15%~18%时,

自相似分数最低(可达到 10%以下), 说明字比例在这个范围内时, 自相似的准确性最高, 模型的表征效果最佳.



a. 曼哈顿出租车数据

—●— 网格大小=0.002°; —■— 网格大小=0.003°



b. 芝加哥犯罪数据

—●— 网格大小=0.001°; —■— 网格大小=0.002°

图 6 2 个数据集上字比例对模型结果的影响

## 5.2 用户实验

本文通过 2 个用户实验(选择任务和排序任务)来验证该方法的查询结果与用户认知的一致性. 2 个实验任务的详细设计如下:

**选择任务.** 给定一个时空过程, 使用本文方法和 3 种对比方法查询出与它最相似的 4 个时空过程, 用户从其中选出他们认为最相似的时空过程. 通过统计 4 种方法的得票情况分析哪个方法的查询结果与用户的主观认知更一致.

**排序任务.** 给定一个时空过程, 使用本文方法和 3 种对比方法查询出与它 Top-5 相似的时空过程, 被试根据主观认知对这 20 个时空过程进行排序. 最后, 统计 4 种方法对应的时空过程的排序得分, 排序越靠前得分越低, 和给定的时空过程越相似.

实验从 2 个数据集的  $T_a$  中各随机选择 5 个时空过程(总共 10 个)作为测试集, 并在  $T_b$  中查询最相似的时空过程. 在实验开始前, 有一个培训环节, 首先花 10min 的时间向被试介绍实验的整体设计, 然后额外生成 2 个时空过程供被试进行练习. 由于任务比较简单, 被试都能很快地理解实验内容. 每位被试依次完成 2 个实验任务, 同时安排一个实验员负责回答被试在实验中遇到的问题, 以保证实验的顺利进行.

本实验招募了 36 名具有计算机专业背景的研究生和本科生作为被试(19 名男性和 17 名女性, 年龄为 20~29 岁).

图 7 展示了选择任务的实验结果. 实验结果证明本文方法在 2 个数据集上的表现整体上比对比方法好得多, 表明本文方法的查询结果更加符合人类的视觉认知.




图 7 选择任务实验结果

图 8 展示了排序任务的实验结果, 可以看出本文方法依然具有更好的实验结果.




图 8 排序任务实验结果

## 6 结 语

本文提出一种基于表征学习的相似时空态势查询方法, 用于辅助用户快速发现数据集中的典型时空态势. 表征模型由 SGNS 模型和去噪自编码器框架组成, 可以将每一个时空态势表征为固定长度的向量. 态势图标由时空摘要算法生成, 用一个简练的图标展示时空态势的整体变化. 通过在 2 个不同的数据集上对本文方法进行评估, 实验数据表明, 与已有的方法相比, 该方法不仅在时间上花费最少, 而且准确性和鲁棒性效果更好. 最后, 在对 36 位被试进行的用户研究中, 发现该方法找到的时空态势更符合人类的视觉认知.

表征学习会带来训练开销, 但较高的准确性、查询速度, 以及和人类的视觉认知更加一致的结果, 证明了本项目认为这个开始是有价值的. 在数据预处理阶段, 涉及 2 个超参数: (1) 数据二值化时将聚合矩阵转化为 0-1 矩阵的阈值; (2) 语料库创建时判断 2 个 0-1 矩阵是否相似的阈值. 超参数会在一定程度上影响方法的可用性, 但本文的实验已经证明将这 2 个超参数的比值控制在 15%~18% 可以得到较好的表征结果, 这为实际使用本文方法提供了依据.

在未来, 计划从 3 个维度扩展这项工作. 首先, 通过在更多的时空数据集上进行实验, 进一步探究该方法的可扩展性; 其次, 进一步研究本文所涉及的超参数的复用性; 最后, 计划在多个真实数据的分析任务中应用本文的表征模型, 基于其构建交互系统, 并分析其在真实的数据分析任务中的可用性和有效性.

## 参考文献(References):

- [1] Ranu S, Deepak P, Telang A D, *et al.* Indexing and matching trajectories under inconsistent sampling rates[C] //Proceedings of the 31st International Conference on Data Engineering. Los Alamitos: IEEE Computer Society Press, 2015: 999-1010
- [2] Puzicha J, Hofmann T, Buhmann J M. Non-parametric similarity measures for unsupervised texture segmentation and image retrieval[C] //Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 1997: 267-272
- [3] Rubner Y, Tomasi C, Guibas L J. The earth mover's distance as a metric for image retrieval[J]. International Journal of Computer Vision, 2000, 40(2): 99-121
- [4] Li X C, Zhao K Q, Cong G, *et al.* Deep representation learning for trajectory similarity computation[C] //Proceedings of the 34th International Conference on Data Engineering. Los

- Alamitos: IEEE Computer Society Press, 2018: 617-628
- [5] Zhang Y F, Liu A, Liu G F, *et al.* Deep representation learning of activity trajectory similarity computation[C] //Proceedings of the IEEE International Conference on Web Services. Los Alamitos: IEEE Computer Society Press, 2019: 312-319
  - [6] Vlachos M, Kollios G, Gunopulos D. Discovering similar multidimensional trajectories[C] //Proceedings of the 18th International Conference on Data Engineering. Los Alamitos: IEEE Computer Society Press, 2002: 673-684
  - [7] Yan B, Janowicz K, Mai G C, *et al.* From ITDL to Place2Vec: reasoning about place type similarity and relatedness by learning embeddings from augmented spatial contexts[C] //Proceedings of the 25th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM Press, 2017: Article No.35
  - [8] Feng S S, Cong G, An B, *et al.* POI2Vec: geographical latent representation for predicting future visitors[C] //Proceedings of the 31st AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 102-108
  - [9] Yabe T, Tsubouchi K, Shimizu T, *et al.* City2City: translating place representations across cities[C] //Proceedings of the 27th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM Press, 2019: 412-415
  - [10] Shimizu T, Yabe T, Tsubouchi K. Improving land use classification using human mobility-based hierarchical place embeddings[C] //Proceedings of the IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events. Los Alamitos: IEEE Computer Society Press, 2021: 305-311
  - [11] Shimizu T, Yabe T, Tsubouchi K. Enabling finer grained place embeddings using spatial hierarchy from human mobility trajectories[C] //Proceedings of the 28th International Conference on Advances in Geographic Information Systems. New York: ACM Press, 2020: 187-190
  - [12] Lin Y, Wan H Y, Guo S N, *et al.* Pre-training context and time aware location embeddings from spatial-temporal trajectories for user next location prediction[C] //Proceedings of the 35th AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2021: 4241-4248
  - [13] Yang J, Eickhoff C. Unsupervised learning of parsimonious general-purpose embeddings for user and location modeling[J]. ACM Transactions on Information Systems, 2018, 36(3): Article No.32
  - [14] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507
  - [15] Cao H C, Xu F L, Sankaranarayanan J, *et al.* Habit2vec: trajectory semantic embedding for living pattern recognition in population[J]. IEEE Transactions on Mobile Computing, 2020, 19(5): 1096-1108
  - [16] Yu D J, Wanyan W B, Wang D J. Leveraging contextual influence and user preferences for point-of-interest recommendation[J]. Multimedia Tools and Applications, 2021, 80(1): 1487-1501
  - [17] Yao D, Zhang C, Zhu Z H, *et al.* Learning deep representation for trajectory clustering[J]. Expert Systems, 2018, 35(2): Article No.e12252
  - [18] Yao D, Zhang C, Zhu Z H, *et al.* Trajectory clustering via deep representation learning[C] //Proceedings of the International Joint Conference on Neural Networks. Los Alamitos: IEEE Computer Society Press, 2017: 3880-3887
  - [19] Kalamaras I, Zamichos A, Salamanis A, *et al.* An interactive visual analytics platform for smart intelligent transportation systems management[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(2): 487-496
  - [20] Wu W C, Xu J Y, Zeng H P, *et al.* TelCoVis: visual exploration of co-occurrence in urban human mobility based on Telco data[J]. IEEE Transactions on Visualization and Computer Graphics, 2016, 22(1): 935-944
  - [21] Xie X, Wang J C, Liang H Y, *et al.* PassVizor: toward better understanding of the dynamics of soccer passes[J]. IEEE Transactions on Visualization and Computer Graphics, 2021, 27(2): 1322-1331
  - [22] Deng Z K, Weng D, Liang Y X, *et al.* Visual cascade analytics of large-scale spatiotemporal data[J]. IEEE Transactions on Visualization and Computer Graphics, 2022, 28(6): 2486-2499
  - [23] Ye S N, Chen Z T, Chu X T, *et al.* ShuttleSpace: exploring and analyzing movement trajectory in immersive visualization[J]. IEEE Transactions on Visualization and Computer Graphics, 2021, 27(2): 860-869
  - [24] Wu J, Guo Z Y, Wang Z B, *et al.* Visual analytics of multivariate event sequence data in racquet sports[C] //Proceedings of the IEEE Conference on Visual Analytics Science and Technology. Los Alamitos: IEEE Computer Society Press, 2020: 36-47
  - [25] Buchmuller J, Jäckle D, Cakmak E, *et al.* MotionRugs: visualizing collective trends in space and time[J]. IEEE Transactions on Visualization and Computer Graphics, 2019, 25(1): 76-86
  - [26] Wulms J, Buchmüller J, Meulemans W, *et al.* Stable visual summaries for trajectory collections[C] //Proceedings of the 14th IEEE Pacific Visualization Symposium. Los Alamitos: IEEE Computer Society Press, 2021: 61-70
  - [27] Maciejewski R, Rudolph S, Hafen R, *et al.* A visual analytics approach to understanding spatiotemporal hotspots[J]. IEEE Transactions on Visualization and Computer Graphics, 2010, 16(2): 205-220
  - [28] Wang Z, Long C, Cong G, *et al.* Effective and efficient sports play retrieval with deep representation learning[C] //Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2019: 499-509
  - [29] Mikolov T, Sutskever I, Chen K, *et al.* Distributed representations of words and phrases and their compositionality[C] //Proceedings of the 26th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2013: 3111-3119
  - [30] Gutmann M, Hyvärinen A. Noise-contrastive estimation: a new estimation principle for unnormalized statistical models[C] //Proceedings of the 13th International Conference on Artificial Intelligence and Statistics. Lille: JMLR.org, 2010: 297-304
  - [31] Scott D W. On optimal and data-based histograms[J]. Biometrika, 1979, 66(3): 605-610
  - [32] Sanderson A C, Wong A K C. Pattern trajectory analysis of nonstationary multivariate data[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2007, 10(7): 384-392