大数据与商务智能

第7讲 时空数据挖掘

肖升生 博士
xiao.shengsheng@shufe.edu.cn

课程导入：时空数据不断累积

- 人类活动产生的时空数据
  - Active recording
    - Travel logs
    - Sport analysis
    - Check-ins
    - …

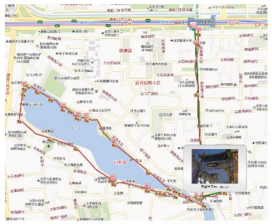

  - Passive recording
    - Credit card transactions
    - Public transit records
    - Mobile phone signal, Wi-Fi…
    - ….

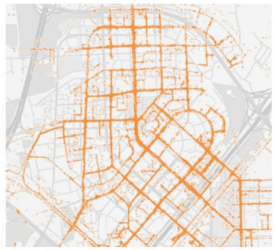
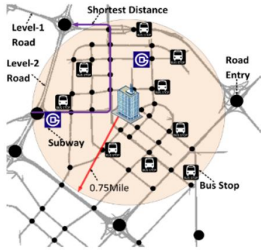

Yu Zheng. Trajectory Data Mining: An Overview. ACM Transactions on Intelligent Systems and Technology. 2015, vol. 6, issue 3

课程导入：时空数据不断累积

- 非人类活动产生的时空数据
  - Mobility of transportation vehicles
    - Taxis, buses, trucks,…
    - Air planes, ferries, cruise,…
  - Mobility of Animals
    - Migration: Birds, zebra, tiger
  - Mobility of natural phenomena
    - Hurricane, tornado,…

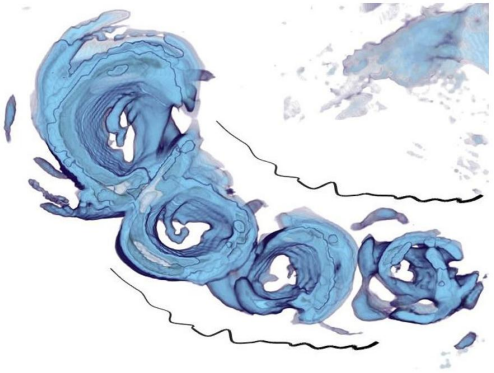

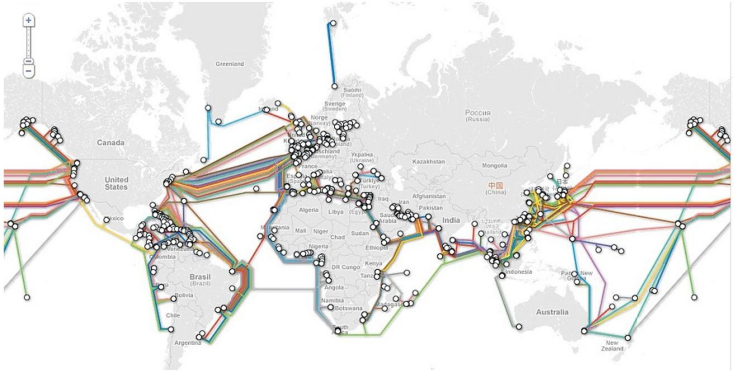

Yu Zheng. Trajectory Data Mining: An Overview. ACM Transactions on Intelligent Systems and Technology. 2015, vol. 6, issue 3

讲授提纲

01 应用场景及挑战

02 时空数据管理

03 时空数据可视化

04 时空数据挖掘算法

05 商业案例分析

讲授提纲

01 应用场景及挑战

02 时空数据管理

03 时空数据可视化

04 时空数据挖掘算法

05 商务案例-餐饮业时空数据挖掘

应用场景：基于位置的服务

- 地图和导航
  - 智能交通
    - 拼车、路径选择
    - 公共交通需求预测（共享单车等）

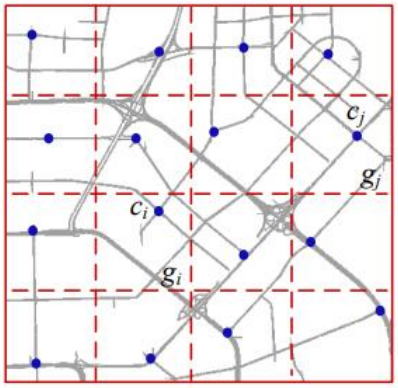

- 基于位置的社交网络 (LBSN)
  - POI推荐、社区推荐、朋友推荐、旅行线路推荐等
- 基于位置的广告 (LBA)

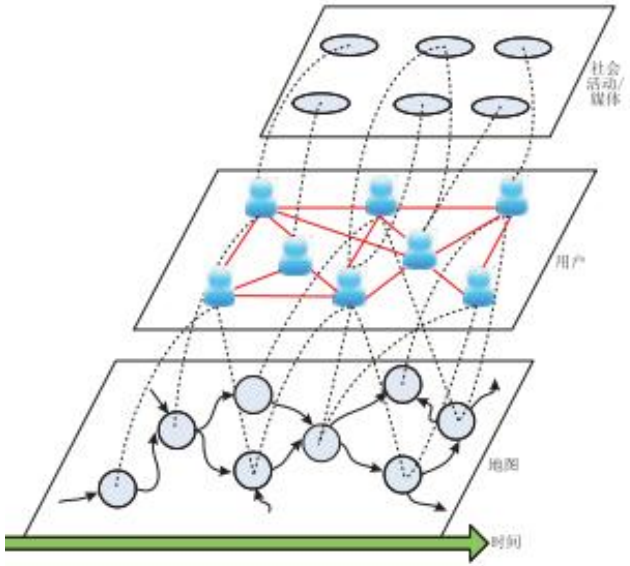

[1] S. Ma, Y. Zheng and O. Wolfson, "T-share: A large-scale dynamic taxi ridesharing service," ICDE, 2013
[2] 刘树栋、孟祥武，基于位置的社会化网络推荐系统[J], 计算机学报，2015：38（2）

应用场景：地理信息系统

- 地理信息系统
  - 捕获、存储、操作、管理地理数据
  - 空间统计等
  - 制图学、地理投影
- 商业地理： Business Geography

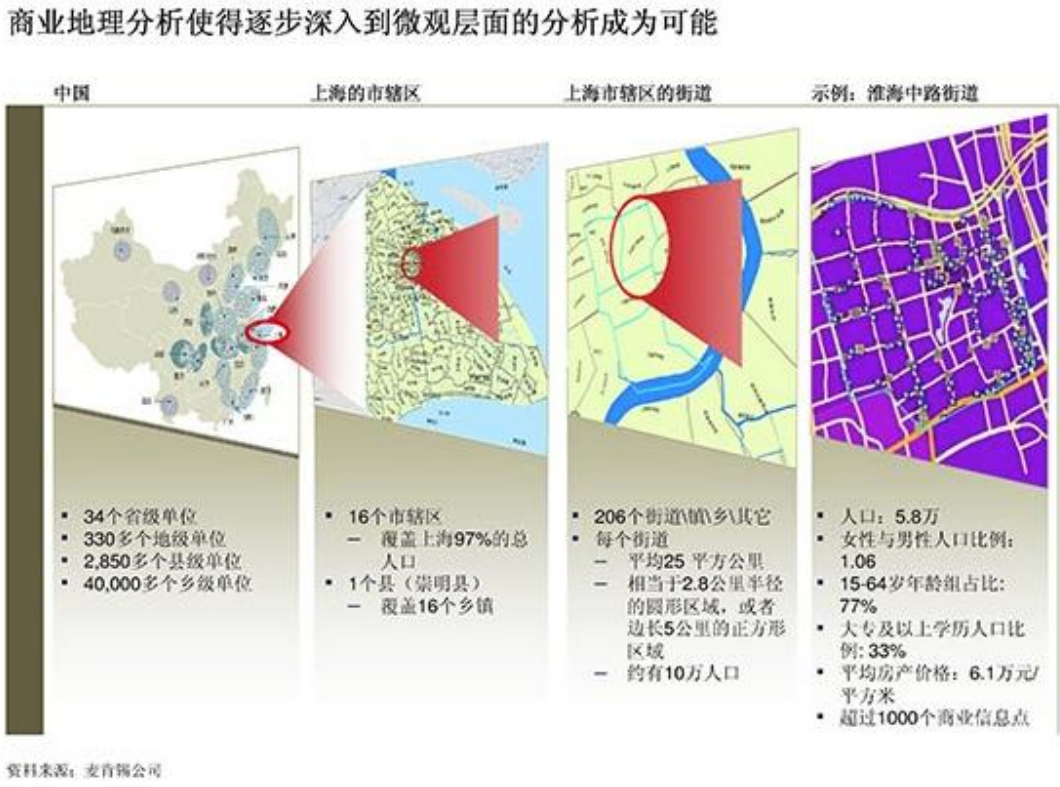

上海市网格化管理综合平台GIS系统，http://www.china-gis.com/StaticPage/Engineer/content/EngineerConCSGL-1.aspx，2020-0

应用场景：商业选址

- 店铺选址

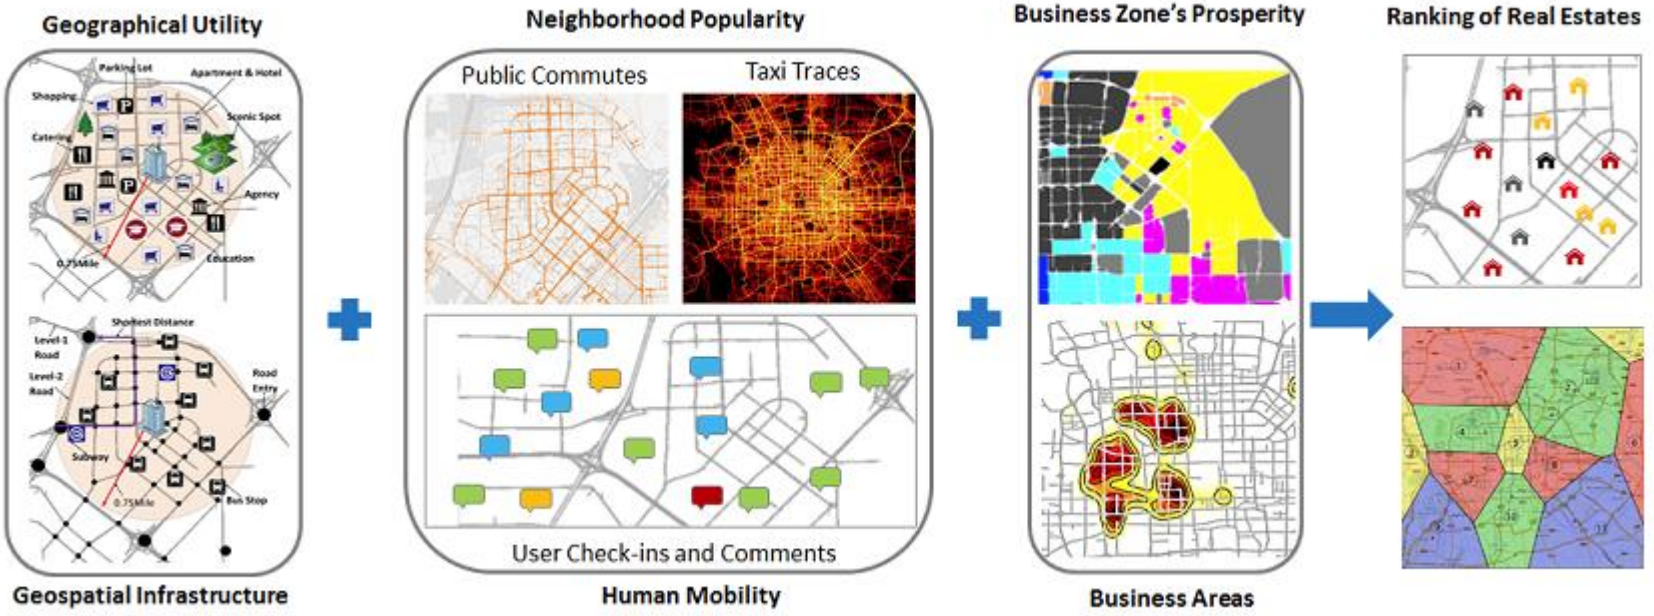

https://www.msra.cn/zh-cn/research/urban-computing-economy, 2020-8-20

应用场景：营销分析

- Huff模型
  - 商店吸引力：满足顾客需求的能力
  - 顾客到商店的时间或距离

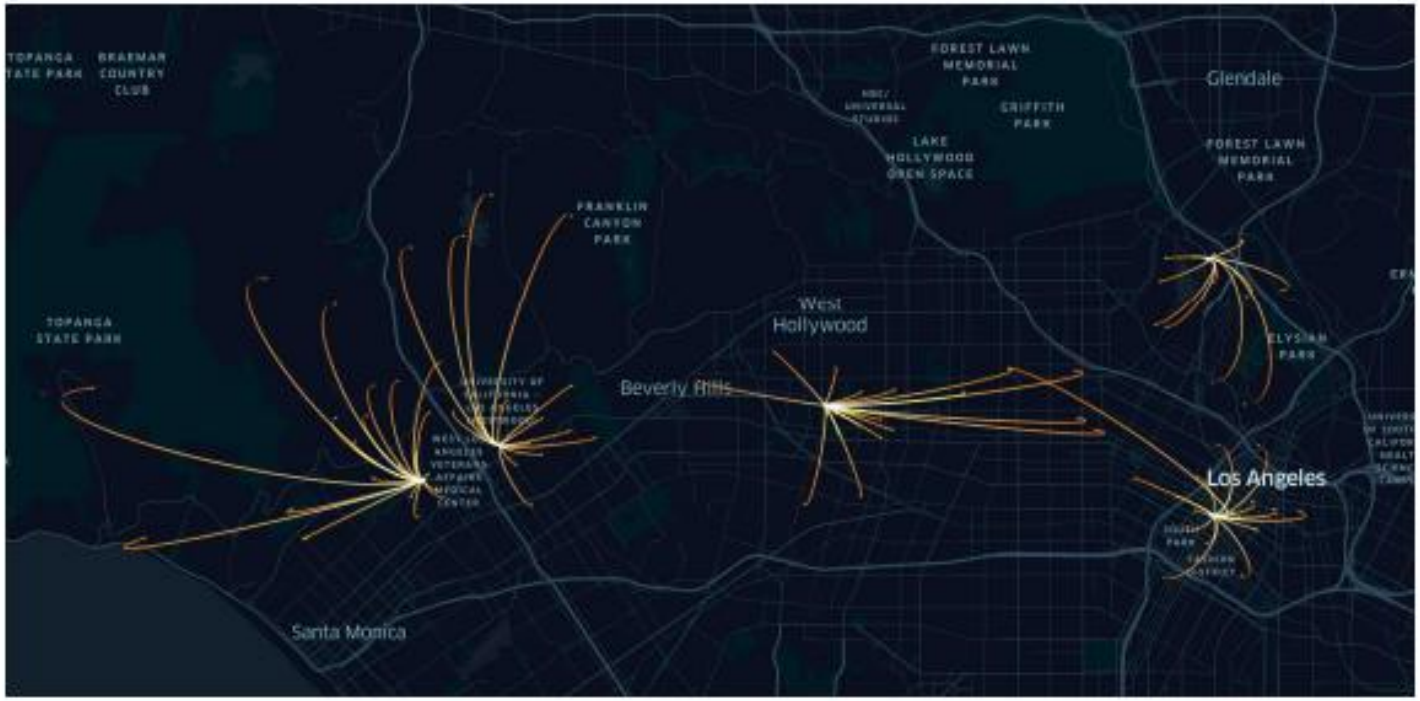

Liang, Y., Gao, S., Cai, Y., Foutz, N. Z., & Wu, L. (2020). Calibrating the dynamic Huff model for business analysis using location big data. Transact GIS.

应用场景：城市交通管理


107,700
15,600
2,300
330
50
10
GPS trajectories of 33,000 taxis from 2009 to 2013

时空数据挖掘的重要性

- 在各行各业有显著社会重要性
  - 地理气象局
  - 生态与环境管理
  - 公共安全
  - 智能交通
  - 流行病管理
  - 其他：如地球科学、气候学、物联网等

时空数据挖掘的挑战

- 复杂的时空数据类型和关系
- 空间依赖性，独立同分布假设失效
- 嵌入在连续的时间和空间中，非离散
- 空间的异质性和时间的非平稳性
- 多尺度效应

时空数据挖掘的工作流程

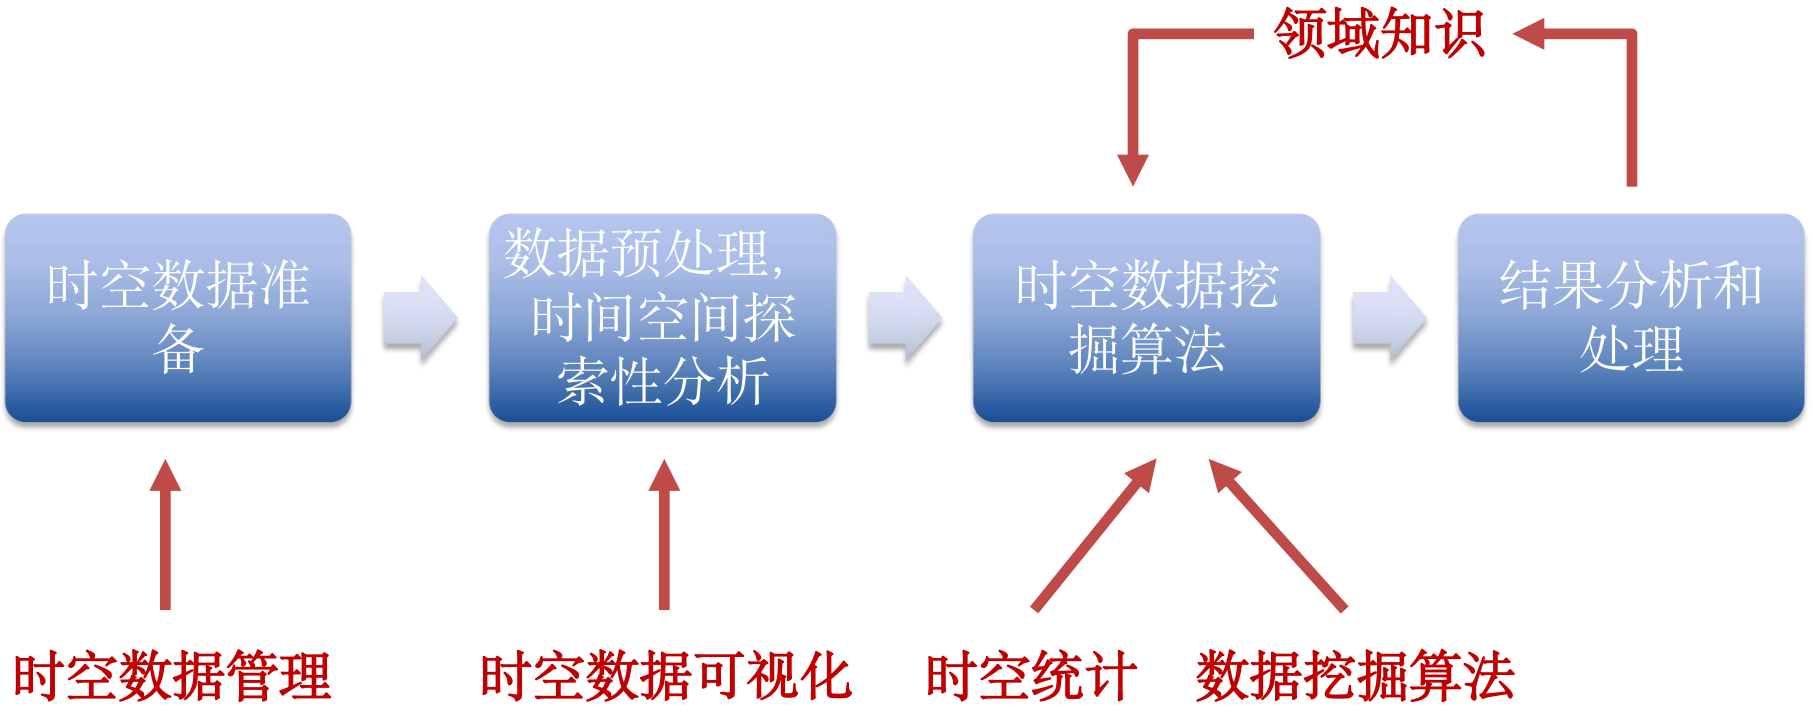

时空数据挖掘的框架图

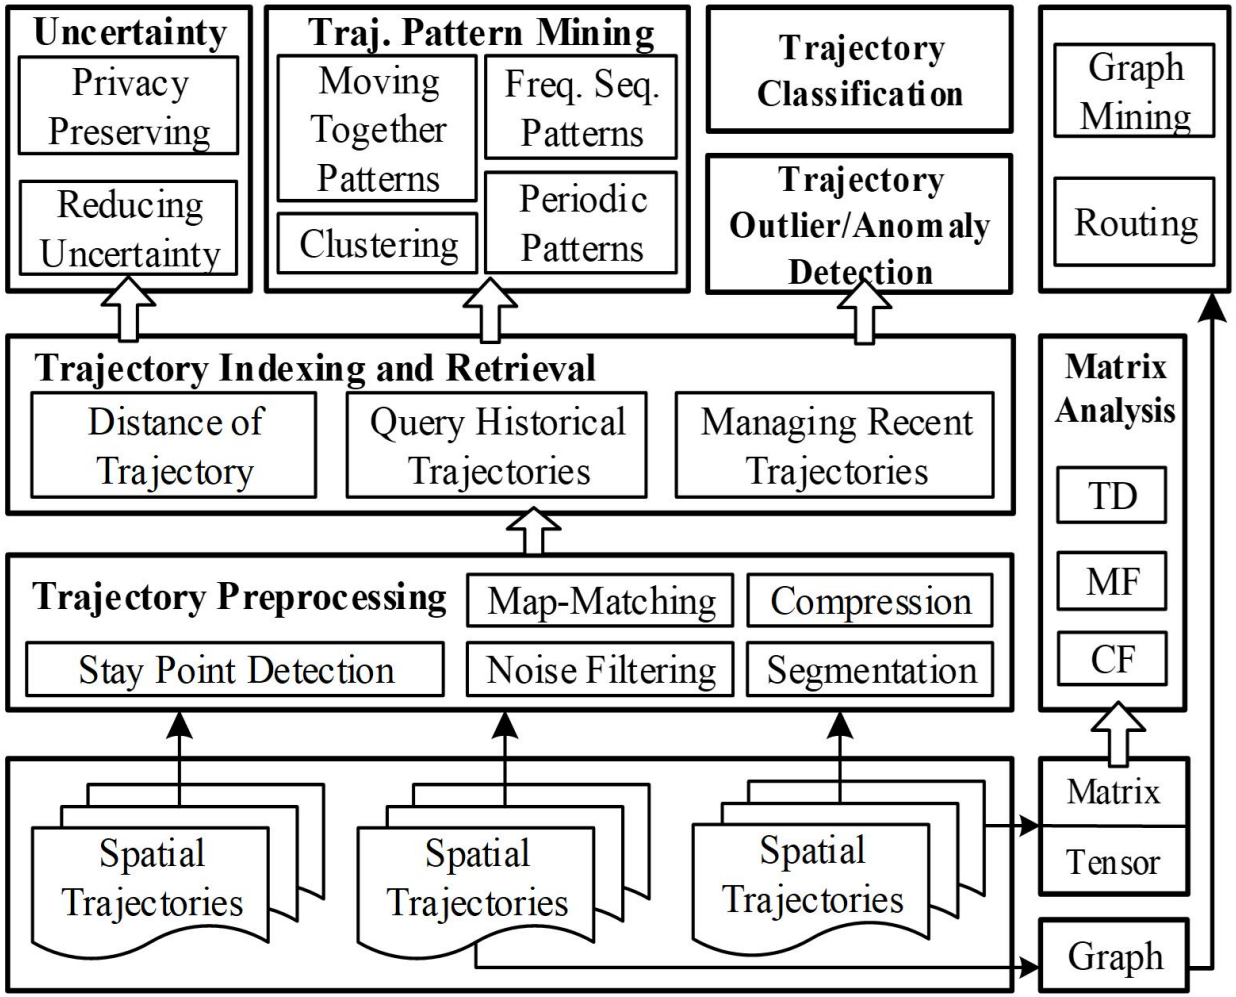

Yu Zheng. Trajectory Data Mining: An Overview. ACM Transactions on Intelligent Systems and Technology. 2015, vol. 6, issue 3

讲授提纲

01 应用场景及挑战

02 时空数据管理

03 时空数据可视化

04 时空数据挖掘算法

05 商务案例-餐饮业时空数据挖掘

时空数据库

- 时空数据库：管理空间、时态以及移动对象数据
  - 多维度、多类型、动态变化、更新快等特点
  - 传统关系型数据库不适应时空数据的处理

- 时空数据库主要类型
  - 空间数据库
    - 处理点、线、区域等二维数据
  - 时态数据库
    - 管理数据的时间属性
  - 移动对象数据库
    - 管理位置随时间连续变化的空间对象
    - 选择查询（range querying）和最近邻查询（KNN querying）

崔斌, 高军, 童咏昕, 许建秋, 张东祥, & 邹磊. (2019). 新型数据管理系统研究进展与趋势. 软件学报, 30(1), 164-193.

时空数据管理技术

- 时空索引技术
- 轨迹数据管理技术
- 图数据管理技术
- 流数据管理技术

关键技术：时空索引技术

- 有效支持对对象时空范围的查询索引
  - **检索过去**
  - **检索当前和未来位置**
- 基于空间划分的索引技术
  - **Grid-based**
  - **Quad-tree**
  - **K-D tree**
- 基于数据划分的索引技术
  - **R-Tree**

Mokbel M F, Ghanem T M, Aref W G. Spatio-temporal access methods[J]. IEEE Data Eng. Bull., 2003, 26(2): 40-49.
Mahmood, A.R., Punni, S. & Aref, W.G. Spatio-temporal access methods: a survey (2010 - 2017). *Geoinformatica* **23,** 1–36 (2019).

时空索引技术：Grid-based

- Grid-based 技术

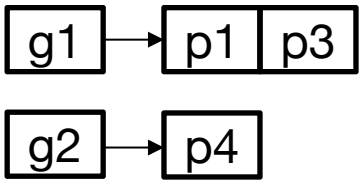

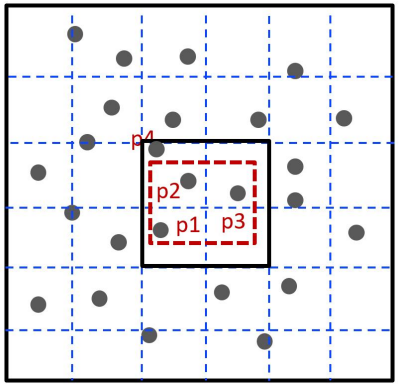

区域查询

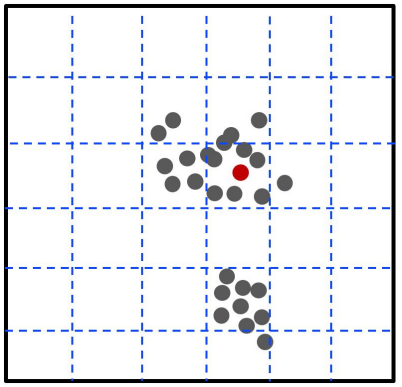

Unbalanced data

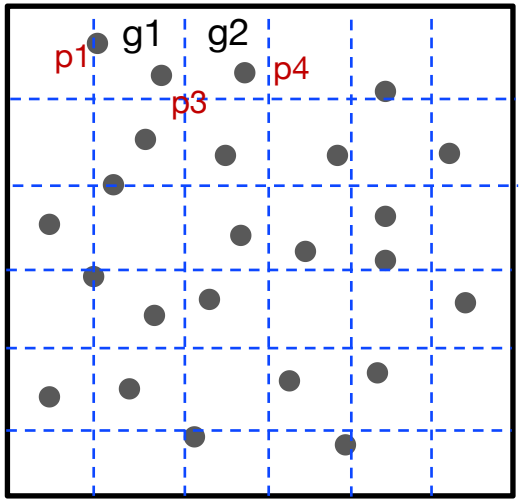

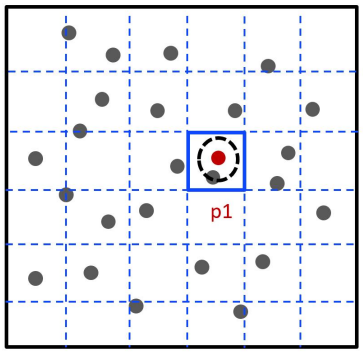

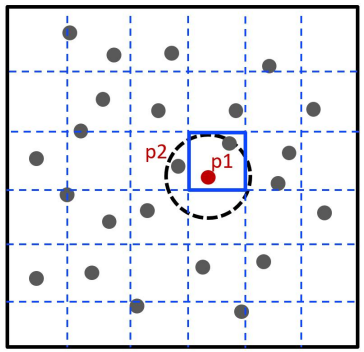

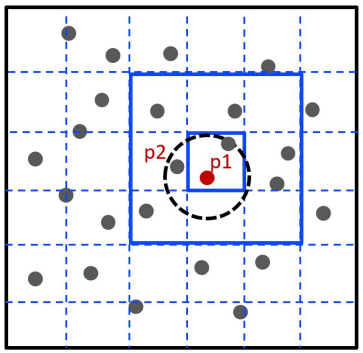

最近邻查询

时空索引技术：Quad-Tree

- Quad-Tree 技术

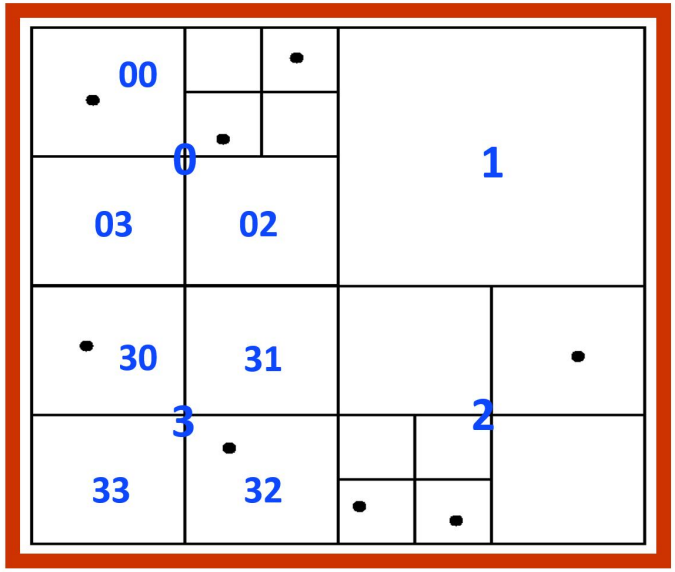

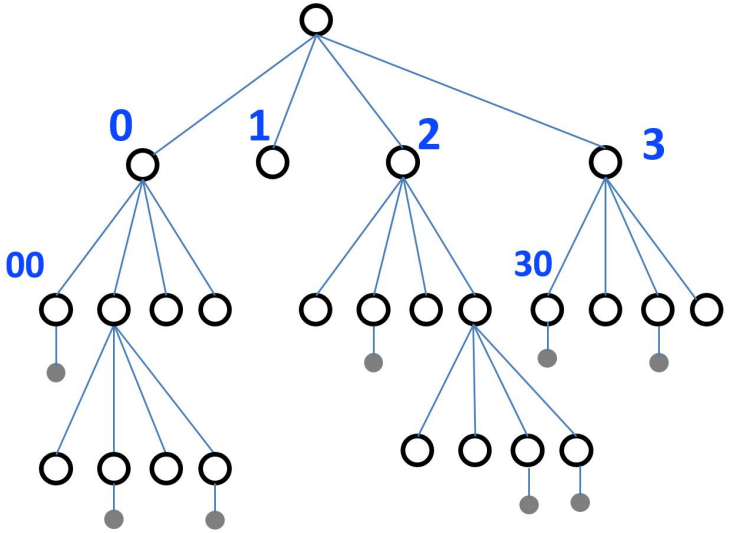

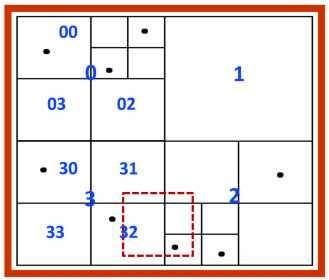

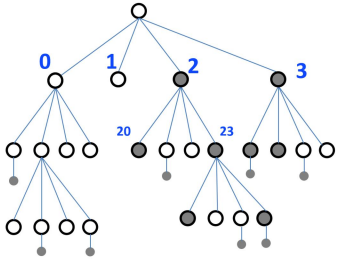

区域查询

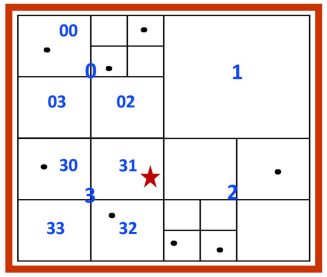

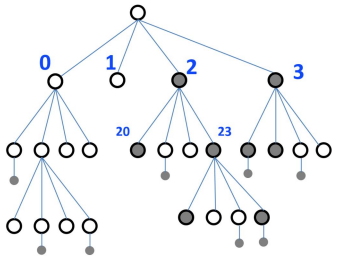

最近邻查询

时空索引技术：R-tree

- R-tree
  - 构建 Minimum Bounding Rectangle (MBR)

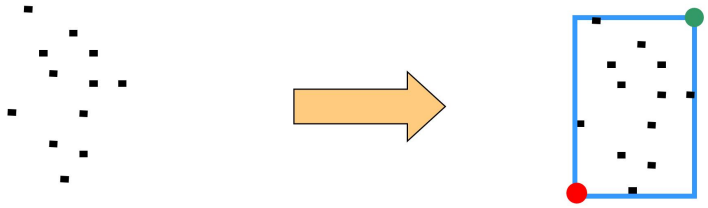

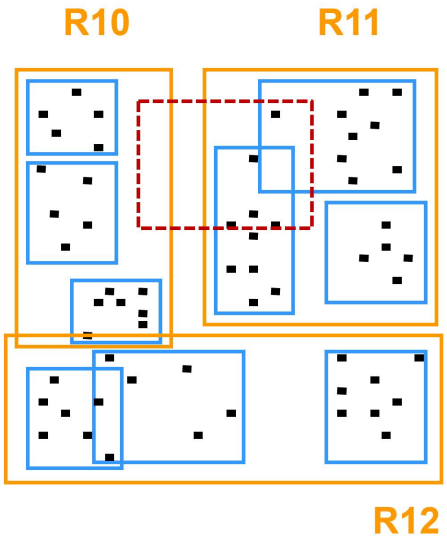

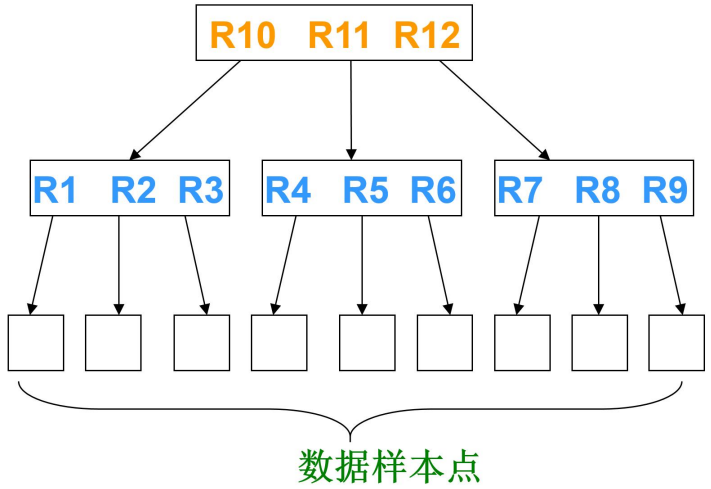

参考资料：csci5715: Spatial computing, University of Minnesota, http://www.spatial.cs.umn.edu/Courses/Fall19/5715/index.php?page=lectureNotes

时空索引技术：R-tree

- R-tree
  1. 从根节点开始确定子节点
  2. 递归查询相应的子节点

  如： 查询区域对象5
  - 从根节点确定子节点X
  - 根据X确定子节点b和c
  - 从b没有找到区域对象5
  - 从c找到区域对象5

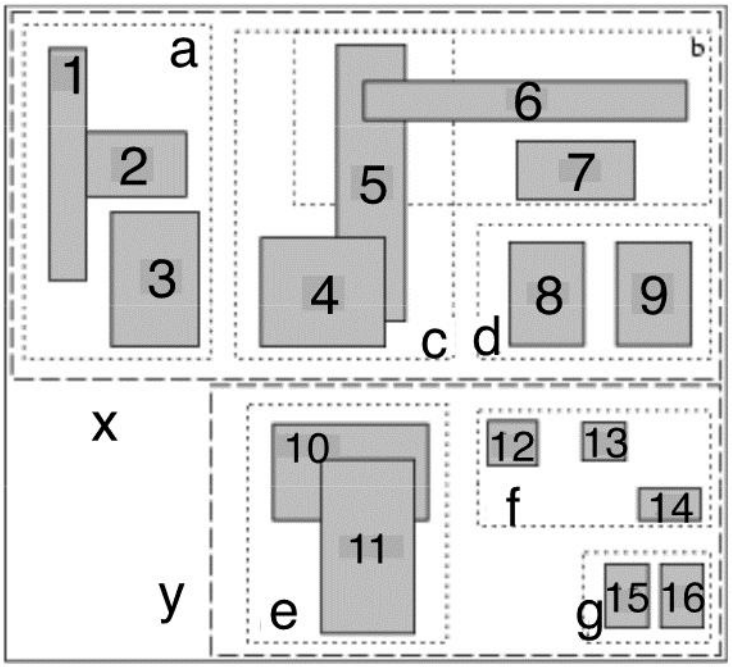

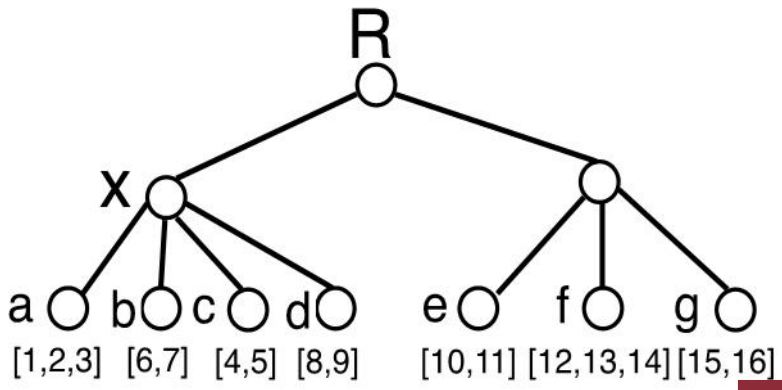

参考资料： csci5715: Spatial computing, University of Minnesota, http://www.spatial.cs.umn.edu/Courses/Fall19/5715/index.php?page=lectureNotes

关键技术：轨迹数据管理技术

- 移动对象数据库
- 距离公式
  - 点q与轨迹A之间的距离
    - $\mathrm{D}(q,A)=\min_{p\in A} D(q,p)$
    - $\mathrm{Sim}(Q,A)=\sum_{q\in Q} e^{-D(q,A)}$：多个点与轨迹A之间的相似度，指数函数将更大的权重给与轨迹A距离更相近的点
  - 两个轨迹之间的距离
  - 两个轨迹段之间的距离

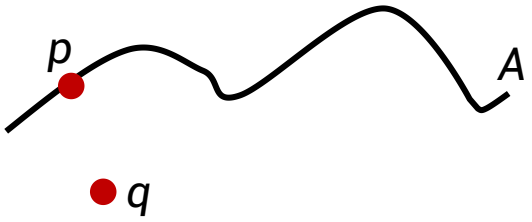

Zaiben Chen, et al. Searching Trajectories by Locations: An Efficiency Study, SIGMOD 2010

Yu Zheng. 2015. Trajectory data mining: An overview. ACM Trans. Intell. Syst. Technol. 6, 3, Article 29 (May 2015), 41 pages.

轨迹数据管理：两个轨迹之间的距离

- 轨迹A与轨迹B之间的距离，多种衡量方式
  - Closest-Pair距离
    - $CPD(A,B) = min_{p \in A, p' \in B} D(p, p')$
  - Sum-of-Pairs距离
    - $SPD(A,B) = \sum_{i=1}^{n} D(p_i, p_i')$
    - 两段轨迹长度相等
  - Dynamic Time wrapping (DTW)距离
    - 允许多次“重复”一些点，以获得最好的对齐，解决轨迹长度相等的限制
    - 假设A、B的长度分别为n, m；$Head(*)$为序列的第一个点，$Rest(*)$为其余点

$$DTW(A,B) = \begin{cases} 0, & n = 0 \text{ and } m = 0 \\ \infty, & n = 0 \text{ or } m = 0 \\ D(Head(A), Head(B)) + min\{ \begin{matrix} DTW(A, Rest(B)) \\ DTW(Rest(A), B) \\ DTW(Rest(A), Rest(B)) \end{matrix} \end{cases}$$

    - 缺点：容易受噪音的影响；不满足三角不等式定理
  - 其他距离公式：LCSS（允许跳过一些噪音点）、EDR（考虑具有相似公共子序列）、ERP（结合DTW和EDR）等

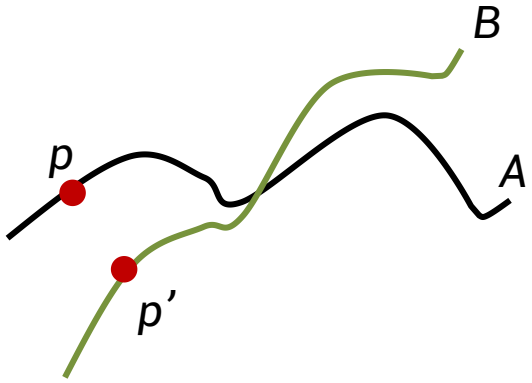

轨迹数据管理：两个轨迹段之间的距离

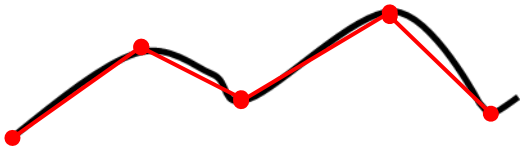

- 两个轨迹段L_1和L_2之间的距离公式
  - 基于最小矩阵边框（minimum bounding rectangle, MBR-based）
    - 如图所示，轨迹段L_1和L_2的MBR分别是$B_1\{(x_l, y_l), (x_u, y_u)\}$和$B_2\{(x'_l, y'_l), (x'_u, y'_u)\}$

$$D_{min}(B_1, B_2) = \sqrt{(\Delta([x_l, x_u], [x'_l, x'_u]))^2 + (\Delta([y_l, y_u], [y'_l, y'_u]))^2}$$

$$\text{Where } \Delta([x_l, x_u], [x'_l, x'_u]) = \begin{cases} 0 & [x_l, x_u] \cap [x'_l, x'_u] \neq \emptyset \\ x'_l - x_u & x'_l > x_u \\ x_l - x'_u & x_l > x'_u \end{cases}$$

  - Trajectory-Hausdorff 距离
    - 三个带权重距离的和
      - 两个轨迹段间的垂直距离
      - 平行距离
      - 夹角距离

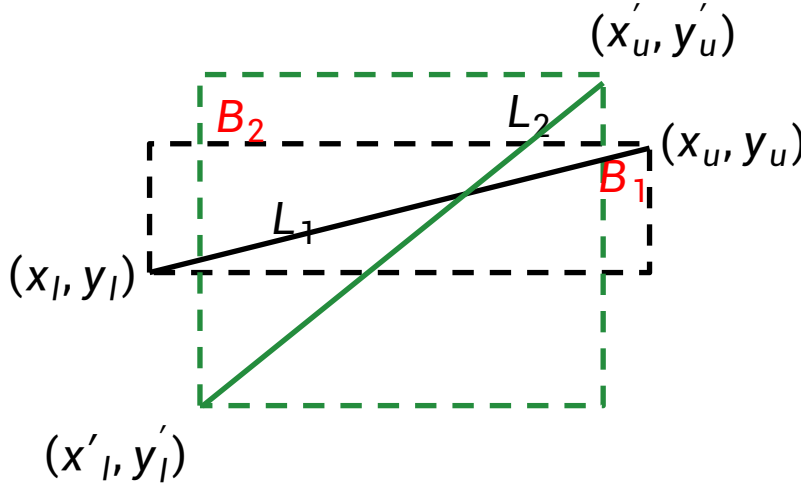

关键技术：图数据管理技术

- 各种各样的网络
  - 不同地区间的人口流动
  - 道路上的交通网络
  - POI网络等
- 可使用带有时空属性的图对时空数据进行建模
  - 采用基于图的数据挖掘算法，包括目前流行的图神经网络模型等

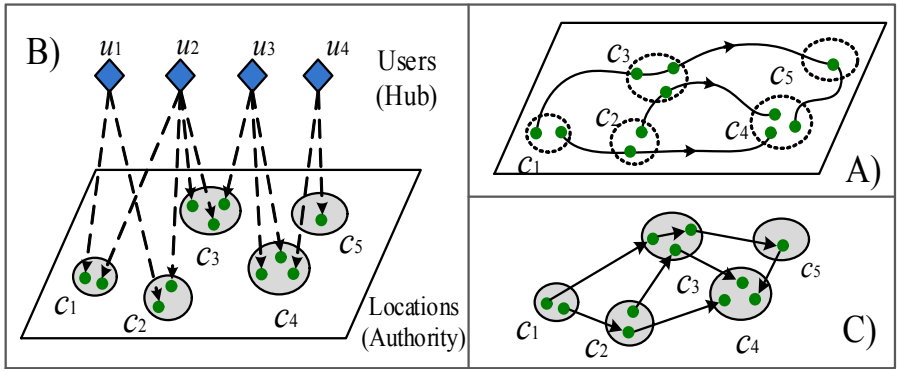

关键技术：流数据管理技术

- 传感器感知的数据
  - 由于大量的传感器数据都以流的形式输入，高效的流数据库技术是时空数据管理层的基石
- 三个主要研究问题
  - 流数据采样
  - 持续性数据查询
  - 流数据并行计算

讲授提纲

01 应用场景及挑战

02 时空数据管理

03 时空数据可视化

04 时空数据挖掘算法

05 商务案例-餐饮业时空数据挖掘

时序数据可视化

- 时序数据
  - 随时间变化
  - 带有时间性质
- 例子
  - 气温变化
  - 股市
  - 系统登录
  - 历史版本
  - ……

时序数据可视化：基本工具

- 简单图（matplotlib）
  - 折线图 .pyplot.plot
  - 柱状图 .pyplot.bar
  - 面积图
- 复杂图
  - 多折线图
  - 星形图
  - 热图
  - ……
- 更多资源
  - http://survey.timeviz.net/

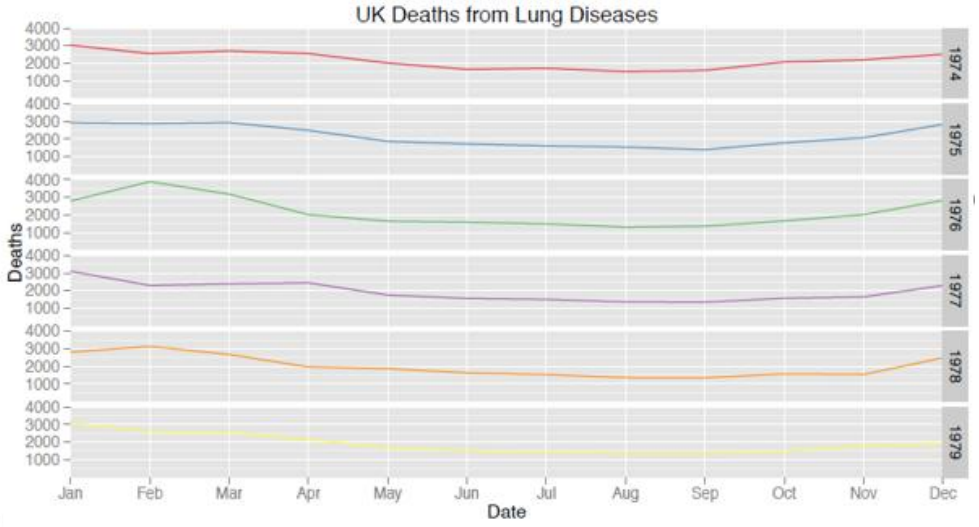

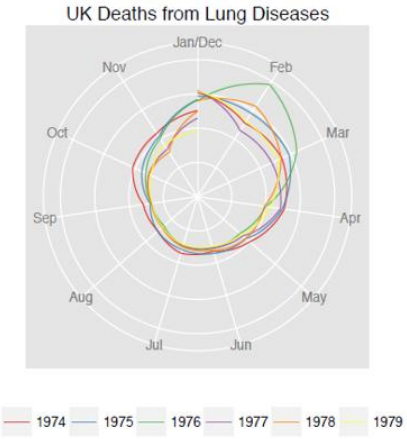

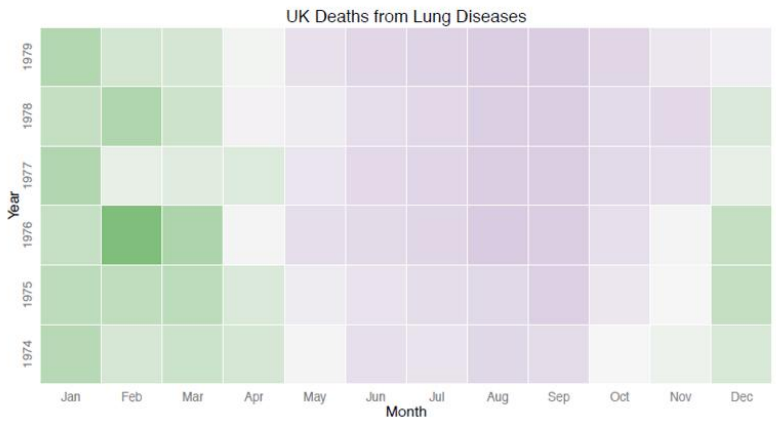

空间数据可视化

- 空间数据是指带有物理空间坐标的数据
- 地理空间数据
  - 真实的人类生活的空间
  - 经纬度

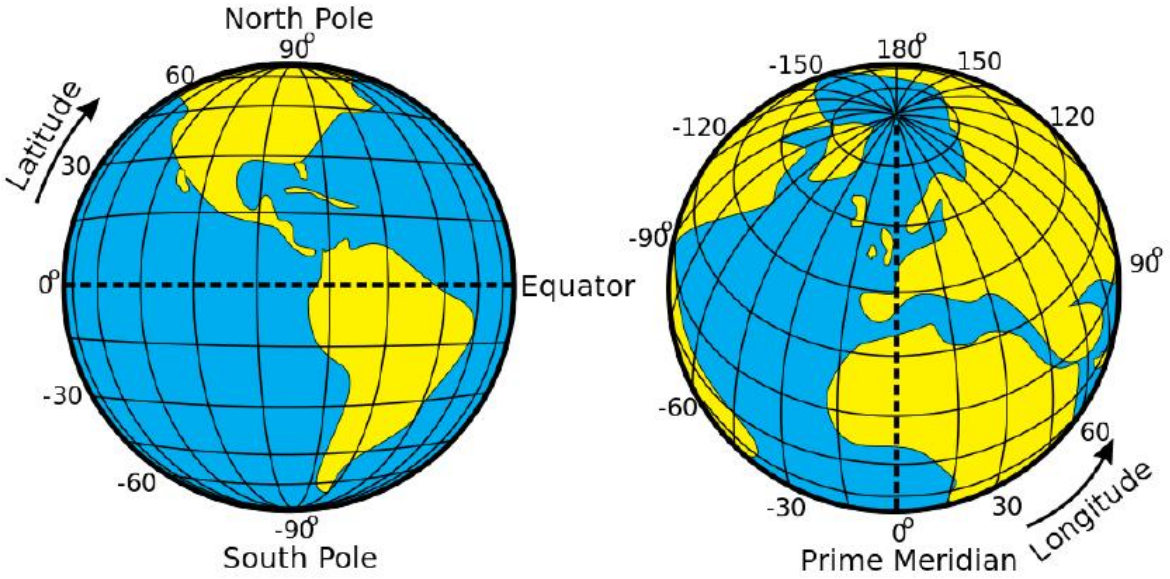

空间数据可视化：地理信息格式

- Shapefiles
  - 1990S早期GIS软件常使用
  - *.shp 包含几何信息
  - *.shx 包含索引信息
  - *.dbf 包含特征信息
- GeoJSON
  - JSON标准的针对web的地理信息编码方式
  - 可以代表一个几何图形、特征以及特征集
  - 几何图形包括点、线、多边形、多个点、多条线等
  - 可以往JSON格式添加其他数据

空间数据可视化：地理信息格式

- GeoJSON例子

```
{ "type": "FeatureCollection",
  "features": [
    { "type": "Feature",
      "geometry": {"type": "Point", "coordinates": [102.0, 0.5]},
      "properties": {"prop0": "value0"}
      },
    { "type": "Feature",
      "geometry": {
        "type": "LineString",
        "coordinates": [
          [102.0, 0.0], [103.0, 1.0], [104.0, 0.0], [105.0, 1.0]
          ]
        },
      "properties": {
        "prop0": "value0",
        "prop1": 0.0
        }
      },
    { "type": "Feature",
      "geometry": {
        "type": "Polygon",
        "coordinates": [
          [ [100.0, 0.0], [101.0, 0.0], [101.0, 1.0],
            [100.0, 1.0], [100.0, 0.0] ]
          ]
      },
      "properties": {
        "prop0": "value0",
        "prop1": {"this": "that"}
        }
      }
    ]
  }
```

http://geojson.org/geojson-spec.html

空间数据可视化：地图类型

- 点数据的可视化：符号地图
- 区域数据的可视化
  - Choropleth
  - Cartogram
- 线数据的可视化
  - 流型图
  - 道路图

空间数据可视化：符号地图

- 点数据的可视化
- 将对象根据它的坐标以一定的符号大小及颜色标识到地图上
  - 符号必须直观且符合常识
  - 不同符号数量不宜太多

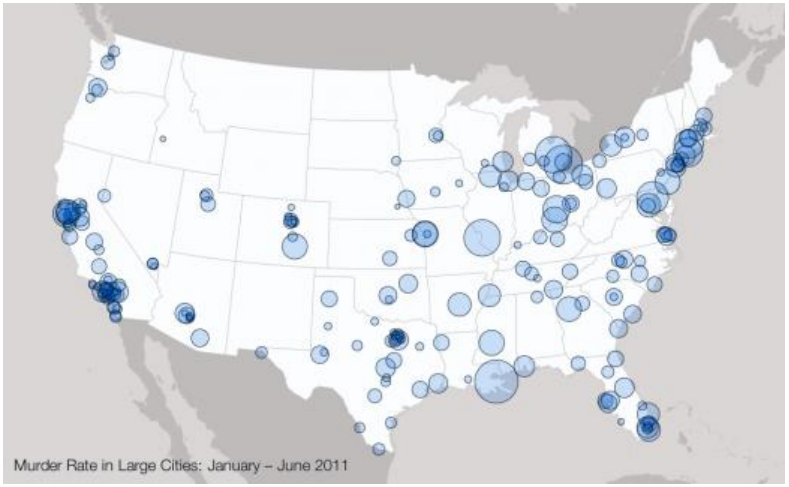

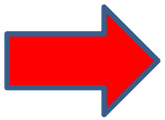

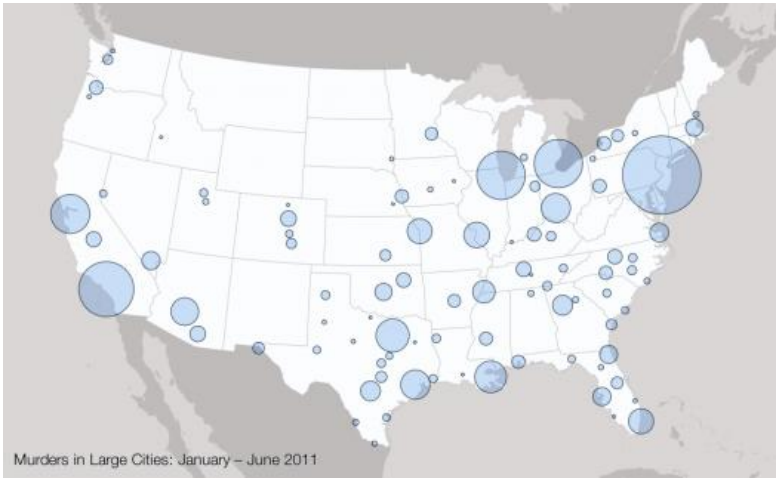

空间数据可视化

- 时间+地图

空间数据可视化：线数据可视化

- 线数据通常指连接两个或更多地点的线段或者路径
  - 长度属性
  - 连接关系

Facebook全球用户之间的好友关系

空间数据可视化：区域数据的可视化

- Choropleth 地图
  - 假设数据的属性在一个区域内部平均分布
  - 一个区域用同一种颜色来表示其属性
  - 数据最好标准化（百分比、比例等）
  - 用颜色及其强度来显示数据的内在模式
  - 必须合理地使用颜色
    - 多种颜色，无强度
    - 多种颜色，有强度
    - 单个颜色，有强度

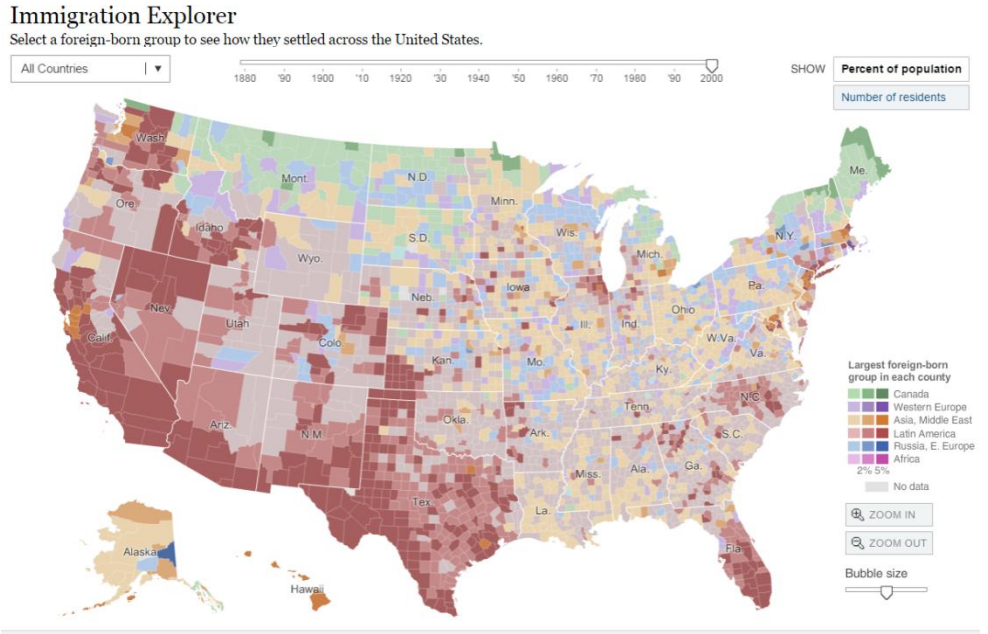

https://archive.nytimes.com/screenshots/www.nytimes.com/interactive/2009/03/10/us/20090310-immigration-explorer.jpg，2020-8-20

空间数据可视化：区域数据的可视化

- Choropleth 地图的误导
- 数据分布和地理区域大小的不对称
  - 大量数据集中于人口密集的区域，而人口稀疏的地区却占有了大多数的屏幕空间，用大量屏幕空间来表示小部分数据的做法对空间的利用非常不经济
  - 这种不对称还常常会造成用户对数据理解的错误

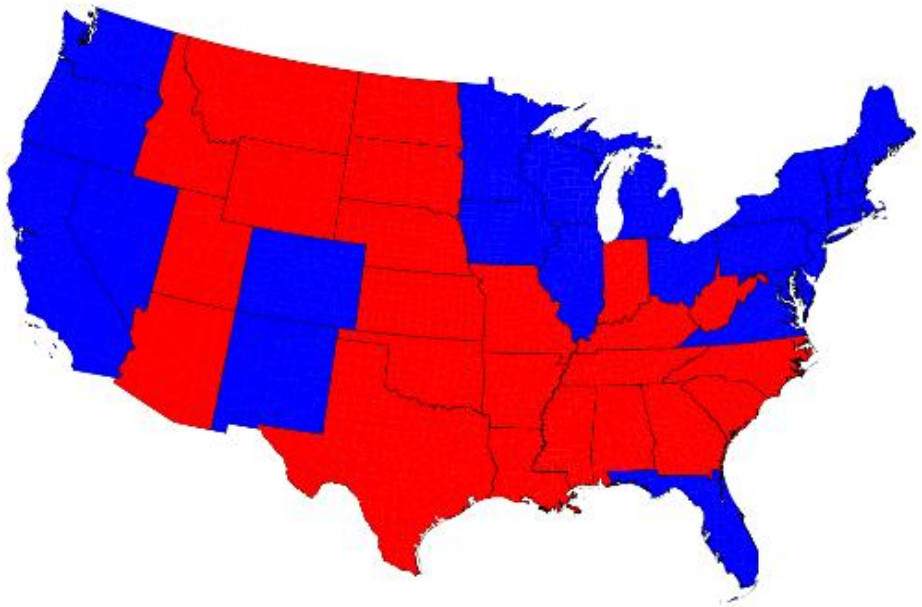

08年美国总统选举

空间数据可视化：区域数据的可视化

- 保证用户的思维连贯性
- 相似的形状，被描绘面积的邻接关系
- Cartogram地图：按照地理区域的属性值对各区域进行适当变形，克服Choropleth地图对空间展示的不合理性
  - Area Cartogram
    - 按照区域大小对地图处理
    - 保证区域之间的连接和相对位置不变
    - 区域仍保持连续
  - 非连续性Cartogram
    - 按照区域大小对地图进行处理
    - 保持区域的原始形状
  - Dorling Cartogram
    - 不再保持区域的形状和连接关系
    - 用其他相比例的形状替代

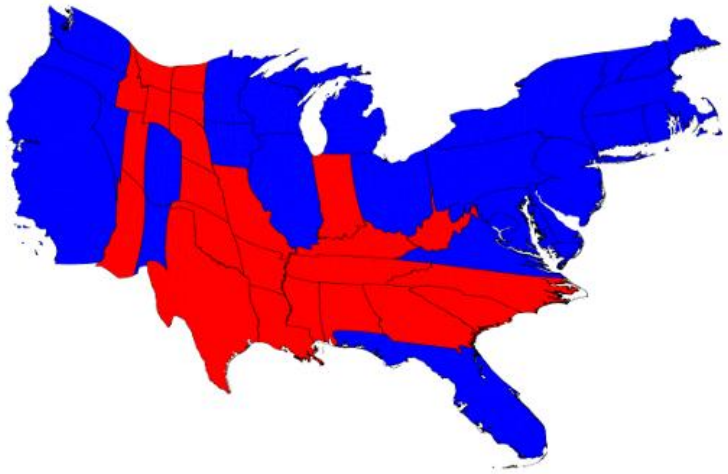

地图上的每个州根据人口做缩放

http://www-personal.umich.edu/~mejn/election/2012/，2020-8-20

空间数据可视化：工具

- Python packages
  - Matplotlib, Seaborn， 各种统计图
  - 空间数据： folium
    - https://python-visualization.github.io/folium/quickstart.html
  - 其他： pyecharts, plotly, bokeh, geopandas等

讲授提纲

01 应用场景及挑战

02 时空数据管理

03 时空数据可视化

04 **时空数据挖掘算法**

05 商务案例-餐饮业时空数据挖掘

时空数据统计

- 时空数据具有空间自相关性、异质性、时间自相关性等特性，时空统计有别于经典统计
- 不满足独立同分布的假设
  - Tobler's first law of geography: 地理学第一定理
    - 所有事物都与其他事物相关，此联系随着距离增加而递减

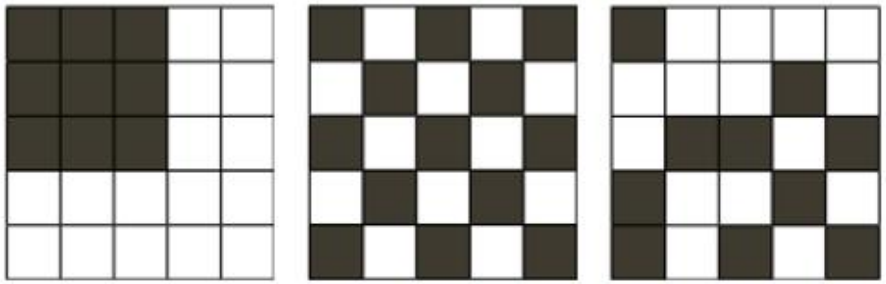

(a) 空间正相关　(b) 空间负相关　(c) 空间无相关性

  - 空间异质性：属性值的空间差异性（地理学第二定理，Michael Goodchild）
    - 全局模型与局部模型不一致
    - 某些时候可考虑对数据从空间上进行切片（分组），再进行DM

Tobler W., (1970) "A computer movie simulating urban growth in the Detroit region". Economic Geography, 46 (Supplement): 234–240.
Goodchild, M.F. (2004) GIScience, geography, form, and process. Annals of the Association of American Geographers 94(4): 709–714

传统DM算法在时空数据中的应用

- 将时间和空间属性当作常规的数据特征，使用经典的数据挖掘技术，将导致信息的丢失
  - 空间连续性（空间划分方式会影响结果）
  - 自相关、异质性，etc.
  - 噪音的问题
- 时空数据挖掘算法
  - 空间自回归
  - 地理加权算法
  - 空间聚类
  - 空间决策树
  - 空间关联规则分析

空间自回归

- 经典的回归模型无法将空间的相关性考虑进去
- Spatial Autoregression (SAR)
  - $y = \rho W y + X\beta + \epsilon$
  - $y \in R^n$, $X \in R^{n*k}$, $\beta \in R^k$, ϵ是观测误差，服从正态分布
  - $\rho W y$: 空间自相关项，用于对因变量y的元素之间的空间依赖强度进行建模，$\rho \in [0,1)$空间自相关参数，$W \in R^{n*n}$矩阵解释空间数据之间的空间关系
  - $$W = \begin{pmatrix} 0 & w_{12} & \dots & w_{1n} \\ w_{21} & 0 & \dots & w_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ w_{n1} & w_{n2} & \dots & 0 \end{pmatrix}$$
  - w_{ij}是指i和j的空间相关性，即相似性
    - 基于距离的（K-function)
    - Moran's I measure (MI)$\in [-1,1]$（基于邻居的）
    - …
- 考虑被附近的自变量影响的情况
  - $y = \alpha + \beta x + \delta W X$

空间自回归

- 空间溢出效应

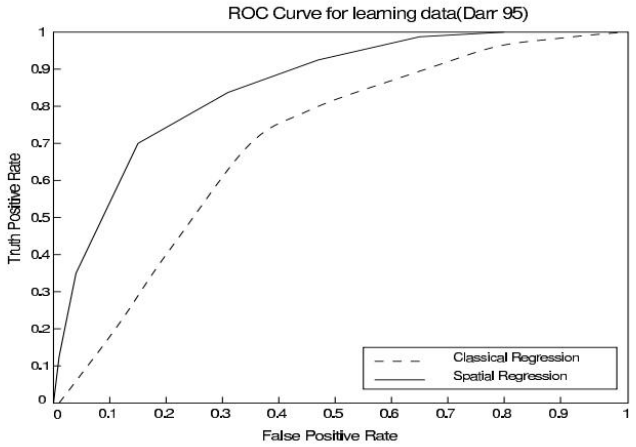

(a) ROC curves for learning

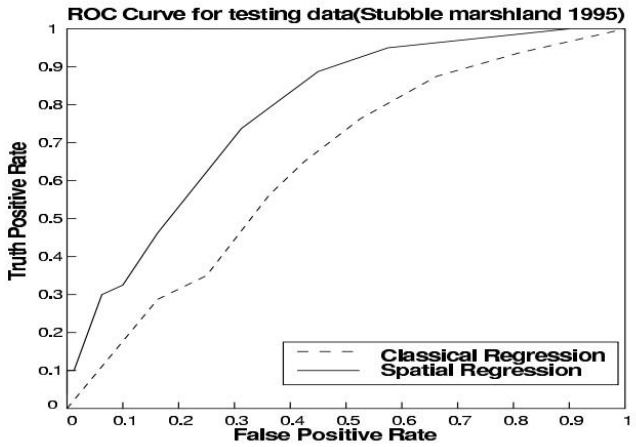

(b) ROC curves for testing

- 时间自回归
  - 时序数据的自相关性
  - 各种不同模型：AR，ARIMA，etc.

Spatial contextual classification and prediction models for mining geospatial data, IEEE Trans. On Multimedia, 4(2):174-188, 2002.

地理加权回归

- 考虑空间异质性
- Geographically Weighted Regression (GWR)
  - 局部回归模型
  - $y = X\beta' + \epsilon'$
  - β'与ϵ'地理位置相关

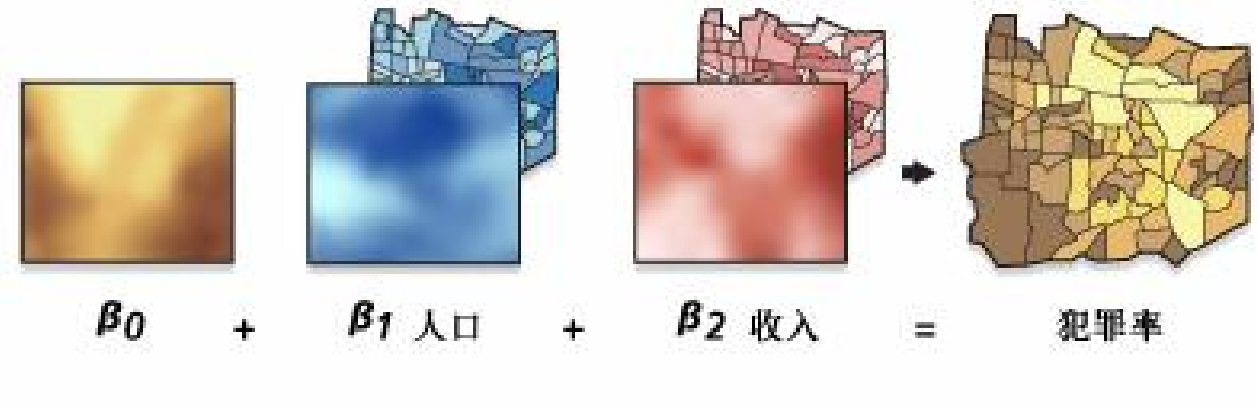

https://desktop.arcgis.com/zh-cn/arcmap/latest/tools/spatial-statistics-toolbox/geographically-weighted-regression.htm, 2020-08-20

空间聚类

- CLARANS (Ng and Han, 1994)
- DBSCAN
  - Density-Based **Spatial** Clustering of Applications with Noise
  - 算法的思想是寻找具有足够的高密度的连通区域，而低密度区域的点则作为孤立点
  - 一个点的密度可以看作所有样本点与此点的相似度之和
  - 参数：密度水平和近邻参数（$\epsilon, MinPts$）-难以选择
  - 优点：可以发现任意形状类

OPTICS算法

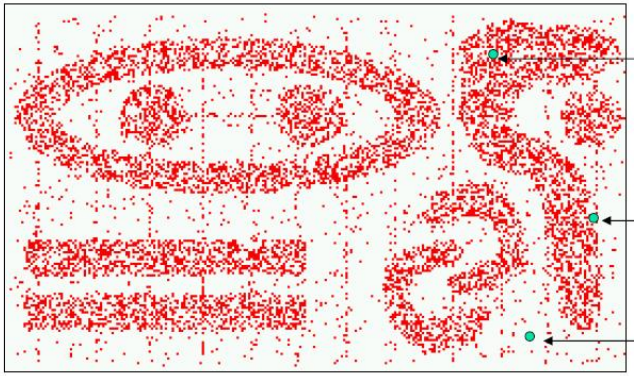

(DBSCAN) M. Ester, H.-P. Kriegel, J. Sander, and X. Xu. 1996. A density-based algorithm for discovering clusters in large spatial databases. KDD
Ng, R., & Han, J. (1994, September). Efficient and effective clustering method for spatial data mining. In VLDB 1994, pages144-155, Santiago, Cl
Ankerst et al., (1999). OPTICS: ordering points to identify the clustering structure. ACM Sigmod record, 28(2), 49-60.

空间关联规则分析

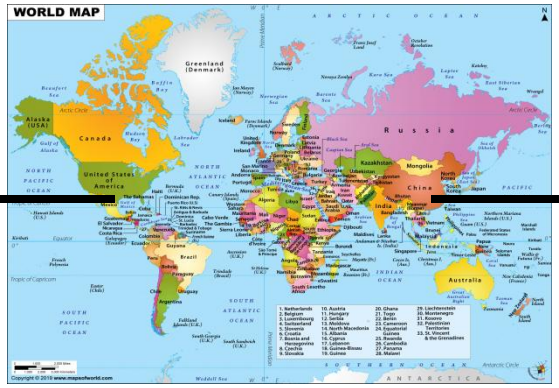

- 空间关联规则分析：事件在时间和空间上同时发生 (Spatial Colocation)

	关联规则	Co-location 规则
潜在空间 （underlying spaces）	离散集	连续空间
物品类型	物品	事件 /布尔空间特征集
集合	交易 (T)	邻居 (N)
衡量标准	support	participation index
条件概率指标	Pr.[A in T | B in T]	Pr.[A in N(L) | B at location L]

讲授提纲

01 应用场景及挑战

02 时空数据管理

03 时空数据可视化

04 时空数据挖掘算法

05 商务案例-餐饮业时空数据挖掘

在线用户评论分析

- 整理自Yelp官方公开的商户、点评和用户数据
  - https://www.yelp.com/dataset
- 整理好的Yelp数据集包含位于多伦多的所有餐馆信息(biz_res.txt)、所有餐馆截至2017年7月的评论数据(review_res.txt)及所有相关用户个人信息(user_res.txt)。
- 各文件的数据字段名称详见ReadMe.txt，数据字段含义详见Yelp Dataset JSON.pdf