



本课件仅用于教学使用。未经许可，任何单位、组织和个人不得将课件用于该课程教学之外的用途(包括但不限于盈利等)，也不得上传至可公开访问的网络环境

1

数据科学导论

Introduction to Data Science

第四章 数据挖掘基础

黄振亚，陈恩红

Email: huangzhy@ustc.edu.cn, cheneh@ustc.edu.cn

课程主页：

<http://staff.ustc.edu.cn/~huangzhy/Course/DS2023.html>




数据挖掘基础

2

□ 数据挖掘——四个任务有哪些常用方法？

分类与预测



数据


| | T | | H | | P | |
|---|-------|------|----|-----|------|------|
| | L | H | L | H | L | H |
| J | -6.0 | 8.8 | 60 | 100 | 986 | 1044 |
| F | -2.8 | 10.9 | 48 | 100 | 973 | 1025 |
| M | -5.6 | 17.7 | 34 | 100 | 976 | 1037 |
| A | -1.2 | 22.2 | 27 | 100 | 996 | 1036 |
| M | -0.8 | 27.8 | 25 | 100 | 1003 | 1034 |
| J | 5.2 | 29.1 | 26 | 100 | 998 | 1030 |
| J | 9.8 | 30.6 | 23 | 99 | 997 | 1027 |
| A | 5.6 | 26.1 | 31 | 100 | 992 | 1029 |
| S | 5.2 | 24.8 | 35 | 100 | 998 | 1028 |
| O | -0.4 | 21.3 | 42 | 100 | 990 | 1031 |
| N | -7.6 | 17.3 | 55 | 100 | 963 | 1023 |
| D | -10.4 | 9.2 | 53 | 100 | 987 | 1039 |

table 17a
2010 monthly weather variation, Cambridge (UK)

关联分析



聚类





关联分析

3

- 数据挖掘任务——关联分析(Association Analysis)
 - 例如：“啤酒与尿布”
 - 在一次圣诞节的顾客消费行为分析中，沃尔玛意外发现跟尿布一起购买最多的产品竟然是啤酒。经过深入分析后，卖场立即对两类商品的空间距离与价格都进行了调整，结果尿布与啤酒销量双双大增。



萨姆·沃尔顿
沃尔玛公司创始人



轰动一时的啤酒与尿布关联规则



关联规则挖掘

4

常用方法 —— 关联规则挖掘 (Association Rule Mining)

- 给出事务的集合, 能够发现一些规则: $A \Rightarrow B$
 - 当事务中某些子项出现时, 预测其他子项也出现
- 例如, 从下表中得到一个可能的规则

购买尿布(Diaper)的用户很大可能会购买啤酒(Beer)

→ 尿布和啤酒应陈列在一起销售

| <i>TID</i> | <i>Items</i> |
|------------|---------------------------|
| 1 | Bread, Milk |
| 2 | Bread, Diaper, Beer, Eggs |
| 3 | Milk, Diaper, Beer, Coke |
| 4 | Bread, Milk, Diaper, Beer |
| 5 | Bread, Milk, Diaper, Coke |

顾客购物交易数据



关联规则挖掘

5

□ 关联规则挖掘的基本概念

□ Itemset (项集)

- 一个或多个项目(items)的集合
- k-itemset: 大小为k的项集
- 例: {Milk, Bread, Diaper}是3项集

□ Support (支持度)

- 一个项集在数据中的出现频率
- 例: $support(\{\text{Milk, Bread, Diaper}\}) = \frac{2}{5}$

□ Frequent Itemset (频繁项集)

- 用户自行设定最小支持度阈值 min_sup , 支持度大于 min_sup 的项集称为频繁项集
- 例: 设 $\text{min_sup} = 0.3$, 则{Milk, Bread, Diaper}为频繁项集

| TID | Items |
|-----|---------------------------|
| 1 | Bread, Milk |
| 2 | Bread, Diaper, Beer, Eggs |
| 3 | Milk, Diaper, Beer, Coke |
| 4 | Bread, Milk, Diaper, Beer |
| 5 | Bread, Milk, Diaper, Coke |

$$support(\{\text{Milk, Bread, Diaper}\}) = \frac{2}{5}$$



关联规则挖掘

6

□ 关联规则挖掘的基本概念

□ Association Rule (关联规则)

- 形如 $X \rightarrow Y$ 的表达式， X, Y 均为项集
- 例： {Milk, Diaper} → {Beer}

□ Confidence (置信度)

- 度量包含 X 的事务中同时出现 Y 的频率

$$\text{Confidence}(A \rightarrow B) = \frac{\text{Support}(A \cup B)}{\text{Support}(A)}$$

- 例：对于关联规则 {Milk, Diaper} → {Beer}

$$\text{confidence}(\{\text{Milk, Diaper}\} \rightarrow \{\text{Beer}\}) = \frac{2}{3}$$

□ 强关联规则

- 用户自行设定最小置信度阈值 min_conf ，置信度大于 min_conf 的规则称为强关联规则
- 例：设 $\text{min_conf} = 0.5$ ，则 {Milk, Diaper} → {Beer} 为强关联规则

| TID | Items |
|-----|---------------------------|
| 1 | Bread, Milk |
| 2 | Bread, Diaper, Beer, Eggs |
| 3 | Milk, Diaper, Beer, Coke |
| 4 | Bread, Milk, Diaper, Beer |
| 5 | Bread, Milk, Diaper, Coke |



练习

7

- 请依据下表计算出关于早餐的关联规则 {面包} -> {豆浆} 的置信度

| | 买豆浆 | 不买豆浆 | |
|------|-----|------|-----|
| 买面包 | 90 | 30 | 120 |
| 不买面包 | 390 | 90 | 480 |
| | 480 | 120 | 600 |

买面包的次数 = 120,

买面包的同时买豆浆的次数 = 90

$$\text{置信度} = \frac{90}{120} = \frac{3}{4}$$



关联规则挖掘

8

□ 关联规则挖掘的一般步骤

- 根据支持度，**寻找所有的频繁项集**（频繁k项集）
- 根据频繁项集，生成频繁规则（长度大于2的频繁k项集）
- 根据置信度，过滤筛选规则

□ 关联规则挖掘的第一步：如何寻找所有的频繁项集？

- 暴力解法：
 - 穷举所有可能的项集，删除小于 min_sup 的项集

⇒ 计算效率低！

| <i>TID</i> | <i>Items</i> |
|------------|---------------------------|
| 1 | Bread, Milk |
| 2 | Bread, Diaper, Beer, Eggs |
| 3 | Milk, Diaper, Beer, Coke |
| 4 | Bread, Milk, Diaper, Beer |
| 5 | Bread, Milk, Diaper, Coke |



频繁项集挖掘

9

□ 频繁项集生成的经典算法

- APriori算法
- DHP算法(课后学习)
- FP-Growth算法(课后学习)



APriori算法

10



Rakesh Agrawal

Technical Fellow, Microsoft Research

在 microsoft.com 的电子邮件经过验证

Data Mining Web Search Education Privacy

□ 频繁项集挖掘——APriori算法

- 1994年，IBM研究员Agrawal提出，VLDB
- 核心思想：广度优先搜索，自底而上遍历，逐步生成候选集与频繁项集
- 反单调性原理：如果一个项集是频繁的，则它的所有子集一定也是频繁
 - 成立原因：

$$\forall X, Y : X \subseteq Y \rightarrow support(X) \geq support(Y)$$

- 依据该性质，对于某k+1项集，只要存在一个k项子集不是频繁项集，则可以
直接判定该项集不是频繁项集

- 算法步骤
 - 连接步：从**频繁K – 1项集**生成**候选K项集**
 - 剪枝步：从**候选K项集**筛选出**频繁K项集**

[Fast algorithms for mining association rules](#)

R Agrawal, R Srikant

Proc. 20th int. conf. very large data bases, VLDB 1215, 487-499

34008 * 1994

[Mining association rules between sets of items in large databases](#)

R Agrawal, T Imielinski, A Swami

Proceedings of the 1993 ACM SIGMOD international conference on Management of ...

23560 1993



APriori算法：连接步

11

□ A-Priori算法步骤1：连接步

- 输入：所有频繁 $K - 1$ 项集 L_{k-1}
- 输出：候选 K 项集 C_k
- 过程：执行自连接 $L_{k-1} \bowtie L_{k-1}$ ，其中 L_{k-1} 的两个项集是可连接的，当且仅当它们前 $(k - 2)$ 个项相同
 - 设 l_1 和 l_2 是 L_{k-1} 中的项集，且(记号 $l_i[j]$ 表示 l_i 的第 j 项)
$$l_1[1] = l_2[1] \wedge l_1[2] = l_2[2] \wedge \dots \wedge l_1[k - 2] = l_2[k - 2]$$
$$\wedge l_1[k - 1] < l_2[k - 1]$$

- 为方便计算，假定事务或项集中的项按字典次序排序，即条件 $l_1[k - 1] < l_2[k - 1]$ 可确保不产生重复的项集
- 生成 $\{l_1[1], l_1[2], \dots, l_1[k - 1], l_2[k - 1]\}$ 放入 C_k 中

$$L_3 = \{abc, abd, acd, ace, bcd\} \xrightarrow{L_3 \bowtie L_3} \begin{matrix} \{abc\} \{abd\} \\ \{acd\} \{ace\} \end{matrix} \longrightarrow C_4 = \{abcd, acde\}$$



APriori算法：剪枝步

12


□ A-Priori算法步骤2：剪枝步

- 输入：候选 k 项集 C_k $\forall X, Y: X \subseteq Y \rightarrow support(X) \geq support(Y)$
- 输出：所有频繁 k 项集 L_k
- 过程：计算 C_k 中每个候选项集的支持度，从而确定 L_k
 - 然而 C_k 可能很大，这样所涉及的计算量就很大
 - 为了提高效率，可利用反单调性：**任何非频繁的($k-1$)项集都不可能是频繁 k 项集的子集。**
 - 因此，若一个候选 k 项集的($k-1$)项子集不在 L_{k-1} 中，则该候选也不可能频繁的，从而可以从 C_k 中删除

$$L_3 = \{abc, abd, acd, ace, bcd\}$$

$$C_4 = \{abcd, a\textcolor{blue}{cde}\}$$

$$L_4 = \{abcd\}$$





APriori算法实例

13

□ A-Priori算法实例

【例】右图为某商店的用户购买记录，共有9个事务，A-Priori假定事务中的项按字典次序存放。

| ID | 事务 |
|------|----------------------|
| T100 | l_1, l_2, l_5 |
| T200 | l_2, l_4 |
| T300 | l_2, l_3 |
| T400 | l_1, l_2, l_4 |
| T500 | l_1, l_3 |
| T600 | l_2, l_3 |
| T700 | l_1, l_3 |
| T800 | l_1, l_2, l_3, l_5 |
| T900 | l_1, l_2, l_3 |



APriori算法实例

14

□ A-Priori算法实例

(1) 在算法的第一次迭代，每个项都是候选1项集的集合 C_1 的成员。算法简单地扫描所有的事务，对每个项的出现次数计数

| ID | 事务 |
|------|----------------------|
| T100 | l_1, l_2, l_5 |
| T200 | l_2, l_4 |
| T300 | l_2, l_3 |
| T400 | l_1, l_2, l_4 |
| T500 | l_1, l_3 |
| T600 | l_2, l_3 |
| T700 | l_1, l_3 |
| T800 | l_1, l_2, l_3, l_5 |
| T900 | l_1, l_2, l_3 |

扫描数据集,对每
个候选1项集计
算支持度



| C_1 | 支持度 |
|-----------|-----|
| $\{l_1\}$ | 6 |
| $\{l_2\}$ | 7 |
| $\{l_3\}$ | 6 |
| $\{l_4\}$ | 2 |
| $\{l_5\}$ | 2 |



APriori算法实例

15

□ A-Priori算法实例

(2) 设最小支持度计数=2，可以确定频繁1项集的集合 L_1

| C_1 | 支持度 |
|-----------|-----|
| $\{l_1\}$ | 6 |
| $\{l_2\}$ | 7 |
| $\{l_3\}$ | 6 |
| $\{l_4\}$ | 2 |
| $\{l_5\}$ | 2 |

比较候选项集
支持度与最小
支持度阈值



| L_1 | 支持度 |
|-----------|-----|
| $\{l_1\}$ | 6 |
| $\{l_2\}$ | 7 |
| $\{l_3\}$ | 6 |
| $\{l_4\}$ | 2 |
| $\{l_5\}$ | 2 |



APriori算法实例

16

□ A-Priori算法实例

(3) 使用 $L_1 \bowtie L_1$ 产生候选2项集的集合 C_2

| L_1 | 支持度 |
|-----------|-----|
| $\{l_1\}$ | 6 |
| $\{l_2\}$ | 7 |
| $\{l_3\}$ | 6 |
| $\{l_4\}$ | 2 |
| $\{l_5\}$ | 2 |

由 L_1 产生候选2项集



| C_2 |
|----------------|
| $\{l_1, l_2\}$ |
| $\{l_1, l_3\}$ |
| $\{l_1, l_4\}$ |
| $\{l_1, l_5\}$ |
| $\{l_2, l_3\}$ |
| $\{l_2, l_4\}$ |
| $\{l_2, l_5\}$ |
| $\{l_3, l_4\}$ |
| $\{l_3, l_5\}$ |
| $\{l_4, l_5\}$ |



APriori算法实例

17

□ A-Priori算法实例

(4) 扫描数据集，计算 C_2 中每个候选选项集的支持度

| ID | 事务 |
|------|----------------------|
| T100 | l_1, l_2, l_5 |
| T200 | l_2, l_4 |
| T300 | l_2, l_3 |
| T400 | l_1, l_2, l_4 |
| T500 | l_1, l_3 |
| T600 | l_2, l_3 |
| T700 | l_1, l_3 |
| T800 | l_1, l_2, l_3, l_5 |
| T900 | l_1, l_2, l_3 |

对每个候选2项集计算支持度



| C_2 | 支持度 |
|----------------|-----|
| $\{l_1, l_2\}$ | 4 |
| $\{l_1, l_3\}$ | 4 |
| $\{l_1, l_4\}$ | 1 |
| $\{l_1, l_5\}$ | 2 |
| $\{l_2, l_3\}$ | 4 |
| $\{l_2, l_4\}$ | 2 |
| $\{l_2, l_5\}$ | 2 |
| $\{l_3, l_4\}$ | 0 |
| $\{l_3, l_5\}$ | 1 |
| $\{l_4, l_5\}$ | 0 |



APriori算法实例

18

□ A-Priori算法实例

(5) 最小支持度计数=2, 确定频繁2项集的集合 L_2

比较候选选项集支持度
与最小支持度阈值



| L_2 | 支持度 |
|----------------|-----|
| $\{l_1, l_2\}$ | 4 |
| $\{l_1, l_3\}$ | 4 |
| $\{l_1, l_5\}$ | 2 |
| $\{l_2, l_3\}$ | 4 |
| $\{l_2, l_4\}$ | 2 |
| $\{l_2, l_5\}$ | 2 |



APriori算法实例

19

□ A-Priori算法实例

(6) 使用 $L_2 \bowtie L_2$ 产生候选3项集的集合 C_3

①连接步: $C_3 = L_2 \bowtie L_2$

$$= \{\{l_1, l_2\}, \{l_1, l_3\}, \{l_1, l_5\}, \{l_2, l_3\}, \{l_2, l_4\}, \{l_2, l_5\}\}$$

\bowtie

$$\{\{l_1, l_2\}, \{l_1, l_3\}, \{l_1, l_5\}, \{l_2, l_3\}, \{l_2, l_4\}, \{l_2, l_5\}\}$$

$$= \{\{l_1, l_2, l_3\}, \{l_1, l_2, l_5\}, \{l_1, l_3, l_5\}, \\ \{l_2, l_3, l_4\}, \{l_2, l_3, l_5\}, \{l_2, l_4, l_5\}\}$$

| L_2 | 支持度 |
|----------------|-----|
| $\{l_1, l_2\}$ | 4 |
| $\{l_1, l_3\}$ | 4 |
| $\{l_1, l_5\}$ | 2 |
| $\{l_2, l_3\}$ | 4 |
| $\{l_2, l_4\}$ | 2 |
| $\{l_2, l_5\}$ | 2 |



APriori算法实例

20

□ A-Priori算法实例

(6) 使用 $L_2 \bowtie L_2$ 产生候选3项集的集合 C_3

②剪枝步：反单调性：频繁项集的所有子集必须是频繁的

$\{\{l_1, l_2, l_3\}, \{l_1, l_2, l_5\}, \{l_1, l_3, l_5\}, \{l_2, l_3, l_4\}, \{l_2, l_3, l_5\}, \{l_2, l_4, l_5\}\}$

□ $\{l_1, l_2, l_3\}$ 的2项子集是 $\{l_1, l_2\}$, $\{l_1, l_3\}$ 和 $\{l_2, l_3\}$

它们都是 L_2 的元素。因此保留 $\{l_1, l_2, l_3\}$ 在 C_3 中

□ $\{l_1, l_3, l_5\}$ 的2项子集是 $\{l_1, l_3\}$, $\{l_1, l_5\}$ 和 $\{l_3, l_5\}$

$\{l_3, l_5\}$ 不是 L_2 的元素，因而不是频繁的，由 C_3 中删除 $\{l_1, l_3, l_5\}$

□ 以此类推筛选得到 C_3

| L_2 | 支持度 |
|----------------|-----|
| $\{l_1, l_2\}$ | 4 |
| $\{l_1, l_3\}$ | 4 |
| $\{l_1, l_5\}$ | 2 |
| $\{l_2, l_3\}$ | 4 |
| $\{l_2, l_4\}$ | 2 |
| $\{l_2, l_5\}$ | 2 |

| C_3 |
|---------------------|
| $\{l_1, l_2, l_3\}$ |
| $\{l_1, l_2, l_5\}$ |



APriori算法实例

21

□ A-Priori算法实例

(7) 扫描数据集，计算 C_3 中每个候选项集的支持度

| ID | 事务 |
|------|----------------------|
| T100 | l_1, l_2, l_5 |
| T200 | l_2, l_4 |
| T300 | l_2, l_3 |
| T400 | l_1, l_2, l_4 |
| T500 | l_1, l_3 |
| T600 | l_2, l_3 |
| T700 | l_1, l_3 |
| T800 | l_1, l_2, l_3, l_5 |
| T900 | l_1, l_2, l_3 |

对每个候选3项集
计算支持度



| C_3 | 支持度 |
|---------------------|-----|
| $\{l_1, l_2, l_3\}$ | 2 |
| $\{l_1, l_2, l_5\}$ | 2 |



APriori算法实例

22

□ A-Priori算法实例

(8) 最小支持度计数=2, 确定频繁3项集的集合 L_3

比较候选选项集支持度
与最小支持度阈值



| L_3 | 支持度 |
|---------------------|-----|
| $\{l_1, l_2, l_3\}$ | 2 |
| $\{l_1, l_2, l_5\}$ | 2 |



APriori 算法实例

23

□ A-Priori 算法实例

(9) 使用 $L_3 \bowtie L_3$ 产生候选4项集的集合 C_4 ，尽管这个项集被剪去，因为它的子集 $\{l_2, l_3, l_5\}$ 不是频繁项集，算法终止，找出了所有的频繁项集如下

| L_1 | 支持度 |
|-----------|-----|
| $\{l_1\}$ | 6 |
| $\{l_2\}$ | 7 |
| $\{l_3\}$ | 6 |
| $\{l_4\}$ | 2 |
| $\{l_5\}$ | 2 |

| L_2 | 支持度 |
|----------------|-----|
| $\{l_1, l_2\}$ | 4 |
| $\{l_1, l_3\}$ | 4 |
| $\{l_1, l_5\}$ | 2 |
| $\{l_2, l_3\}$ | 4 |
| $\{l_2, l_4\}$ | 2 |
| $\{l_2, l_5\}$ | 2 |

| ID | 事务 |
|------|----------------------|
| T100 | l_1, l_2, l_5 |
| T200 | l_2, l_4 |
| T300 | l_2, l_3 |
| T400 | l_1, l_2, l_4 |
| T500 | l_1, l_3 |
| T600 | l_2, l_3 |
| T700 | l_1, l_3 |
| T800 | l_1, l_2, l_3, l_5 |
| T900 | l_1, l_2, l_3 |

| L_3 | 支持度 |
|---------------------|-----|
| $\{l_1, l_2, l_3\}$ | 2 |
| $\{l_1, l_2, l_5\}$ | 2 |



APriori算法

24

□ APriori算法

- **总结：** APriori算法适合用在数据集稀疏，频繁模式较短，支持度较高的场景中
- **不足：** 难以适用于稠密数据和长频繁模式

- 可能产生大量的候选集
- 可能需要重复扫描数据集多次

□ 改进方法 (**课后学习**)

- DHP算法
- Partition算法
- Sample算法
- DIC算法



关联规则挖掘

25

□ 关联规则挖掘的第二步：如何从频繁项集中生成规则？

- 任务：给定一个频繁项集 L , 寻找所有非空子集 $f \subset L$ 使得 $f \rightarrow L - f$ 满足置信度要求
 - 若 $\{A, B, C, D\}$ 是频繁项集, 候选规则有14种:

$$\begin{array}{llll} ABC \rightarrow D, & ABD \rightarrow C, & ACD \rightarrow B, & BCD \rightarrow A, \\ A \rightarrow BCD, & B \rightarrow ACD, & C \rightarrow ABD, & D \rightarrow ABC \\ AB \rightarrow CD, & AC \rightarrow BD, & AD \rightarrow BC, & BC \rightarrow AD, \\ BD \rightarrow AC, & CD \rightarrow AB, & & \end{array}$$

- 若 $|L| = k$, 则有 $2^k - 2$ 种候选的关联规则(忽略 $L \rightarrow \emptyset$ 和 $\emptyset \rightarrow L$)




关联规则生成

26

□ 关联规则生成(Rule Generation)——计算复杂度

□ 对于 d 个项目:

- 候选项集数= 2^d
- 可能规则数 $R = 3^d - 2^{d+1} + 1$



$$R = \sum_{k=1}^{d-1} \binom{d}{k} \times \sum_{j=1}^{d-k} \binom{d-k}{j}$$
$$= 3^d - 2^{d+1} + 1$$

If $d=6$, $R = 602$ rules



关联规则生成

27

□ 关联规则生成(Rule Generation)

- 如何高效地从频繁项集中生成规则?
- 一般而言, 置信度不满足反单调性

$confidence(ABC \rightarrow D)$ 可能大于或小于 $confidence(AB \rightarrow D)$

- 但从同一项集生成的规则满足反单调性
 - 例: $L = \{A, B, C, D\}$

$confidence(ABC \rightarrow D) \geq confidence(AB \rightarrow CD) \geq confidence(A \rightarrow BCD)$

为什么? 课后验证一下




关联规则生成

28

□ 关联规则生成

- 对某个频繁项集，自顶向下生成候选规则
- 若某个父节点置信度较低，其所有子节点无需再判断





FP-Growth

29

□ 频繁项集挖掘——FP-Growth算法

- 关联规则挖掘的经典算法之一，于2000年由韩家炜等提出
- 核心思想：能够压缩原始数据的**频繁模式树**(Frequent Pattern Tree, FP-tree)

Mining frequent patterns without candidate generation

[J Han](#), [J Pei](#), [Y Yin](#) - ACM sigmod record, 2000 - dl.acm.org

Mining frequent patterns in transaction databases, time-series databases, and many other kinds of databases has been studied popularly in data mining research. Most of the previous studies adopt an Apriori-like candidate set generation-and-test approach. However, candidate set generation is still costly, especially when there exist prolific patterns and/or long patterns. In this study, we propose a novel frequent pattern tree (FP-tree) structure, which is an extended prefix-tree structure for storing compressed, crucial information about ...

☆ 保存 引用 被引用次数: 10079 相关文章 所有 64 个版本



<https://hanj.cs.illinois.edu/>



关联规则挖掘前沿：课后学习

34

□ 多维关联规则挖掘

- 多维的关联规则，如{购买: 电脑} \wedge {年龄 \in [20,30]} \rightarrow {购买:手机}

□ 多层关联规则挖掘

- {光明牛奶，全麦面包} 的支持度低，抽象化为{牛奶，面包}等高层概念

□ 稀有模式挖掘

- 金融安全领域：普通的交易行为，非正常交易（欺诈交易）

□ 负模式挖掘

- {可口可乐，百事可乐} 支持度高，但 $\{\text{可口可乐}\} \rightarrow \neg\{\text{百事可乐}\}$

□ 序列模式挖掘算法

- 加入事务发生的时间：用户购买顺序的关联分析



数据挖掘基础

42

□ 数据挖掘定义、四类任务及其应用场景

□ 聚类任务

□ 无监督：K-Means、DBSCAN、评估方法

□ 分类任务

□ 有监督：决策树、K近邻、感知机/SVM、集成分类器、评估方法

□ 关联分析

□ 支持度和置信度、Apriori算法

□ 异常检测

Tips: 结合实际场景，分析问题，设计模型，评估结果。