

Задача поиска шаблонов в данных

*Мыслить по шаблону –
вернейший способ завалить дело.*

Дж.Ф. Энрайт

Челябинский
ОБЗОР

**В Челябинске мужчина стащил
из супермаркета пиво
и подгузники**

Происшествия 1 февраля 2020

Icons for social media: Facebook, VK, Odnoklassniki, Twitter.

<https://obzor174.ru/v-chelyabinske-muzhchina-stashchil-iz-supermarketa-pivo-i-podguzniki>

Содержание

- Постановка задачи
 - Частые наборы
 - Ассоциативные правила
- Основные алгоритмы поиска частых наборов
 - Apriori
 - Eclat
 - FP-Growth
- **Меры полезности шаблонов:**
 - **support**
 - **confidence**
 - **lift** и др.
- Поиск шаблонов в Больших данных
 - Компактное представление частых наборов
 - Иерархии наборов
 - Фрагментация и сэмплинг для поиска частых наборов

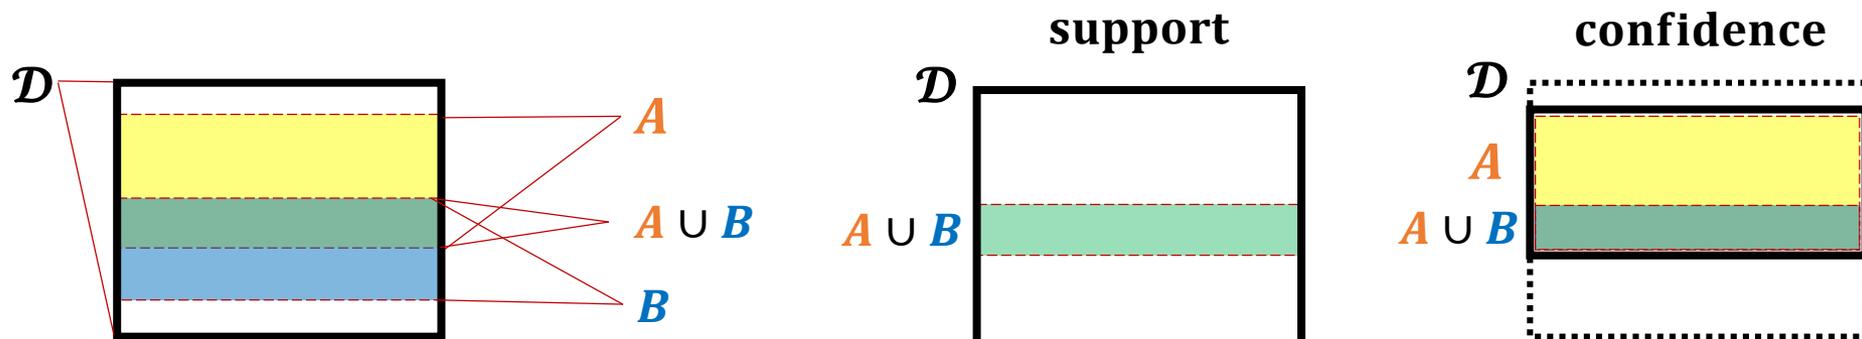
Шаблон, поддержка, достоверность

- Шаблон: $A \rightarrow B, A \neq \emptyset, B \neq \emptyset, A \cap B = \emptyset$
- Поддержка

$$\text{sup}(A \rightarrow B) = P(A \cup B) = \frac{|\{t \in \mathcal{D} \mid (A \cup B) \subseteq tI\}|}{|\mathcal{D}|}$$

- Достоверность

$$\text{conf}(A \rightarrow B) = P(B|A) = \frac{\text{sup}(A \cup B)}{\text{sup}(A)}$$



Полезность шаблонов

- Какие шаблоны полезны на практике?

№	Правило	sup	conf	Польза
1	хлеб → масло			?
2	хлеб → авокадо			?
3	молоко → тунец			?
4	масло → стир. порошок			?
5	водка → икра красная			?
6	водка → икра баклажанная			?

Полезность шаблонов

- Какие шаблоны полезны на практике?

№	Правило	sup	conf	Польза
1	хлеб → масло			
2	хлеб → авокадо			
3	молоко → тунец			
4	масло → стир. порошок			
5	водка → икра красная			
6	водка → икра баклажанная			

Пример: шаблон устойчив, но бесполезен

- Таблица сопряженности

	<i>coffee</i>	\overline{coffee}	Σ
<i>tea</i>	4000	3500	7500
\overline{tea}	2000	500	2500
Σ	6000	4000	10000

- $coffee \rightarrow tea$ [$sup = \frac{4000}{10000} = 0.4$, $conf = \frac{4000}{6000} = 0.66$]
- $P(tea) = \frac{7500}{10000} = 0.75 > P(tea|coffee) = conf$
- Проще угадать наличие *tea*, чем предсказать это с помощью шаблона $coffee \rightarrow tea$

Пример: шаблон неустойчив, но полезен

- Таблица сопряженности

	<i>honey</i>	\overline{honey}	Σ
<i>tea</i>	100	100	200
\overline{tea}	20	780	800
Σ	120	880	1000

- $tea \rightarrow honey$ [$sup = \frac{100}{1000} = 0.1$, $conf = \frac{100}{200} = 0.5$]
- $P(honey) = \frac{120}{1000} = 0.12 < P(honey|tea) = conf$
- $P(\overline{tea} \cup honey) = \frac{20}{1000} = 0.025$
- Отбрасывание шаблона не учитывает информацию о предпочтении *honey* при условии *tea*

Меры **support** и **confidence** не вполне адекватны

- Нужны дополнительные меры, которые учитывают корреляцию между объектами

Мера lift

- $\text{lift}(A, B) = \frac{P(A \cup B)}{P(A) \cdot P(B)}$
- Оценка
 - $\text{lift}(A, B) = 1$: A и B независимы
 - $\text{lift}(A, B) < 1$: A и B имеют отрицательную корреляцию (наличие A подразумевает отсутствие B)
 - $\text{lift}(A, B) > 1$: A и B имеют положительную корреляцию (наличие A подразумевает наличие B)
- $\text{lift}(A \rightarrow B) = \frac{P(B|A)}{P(B)} = \frac{\text{conf}(A \rightarrow B)}{\text{sup}(B)} = \frac{\text{sup}(A \rightarrow B)}{\text{sup}(A) \cdot \text{sup}(B)}$

Мера lift

- Пример:

- Таблица сопряженности

	A	\bar{A}	Σ
B	4000	3500	7500
\bar{B}	2000	500	2500
Σ	6000	4000	10000

- $A \rightarrow B$ [$sup = 0.4$, $conf = 0.66$]

- $lift(A, B) = \frac{P(A \cup B)}{P(A) \cdot P(B)} = \frac{0.4}{0.6 \cdot 0.75} = 0.89$

- A и B имеют отрицательную корреляцию

- $A \rightarrow B$ малополезно

Мера χ^2

- Выборки: $A = (a_1, \dots, a_c)$, $B = (b_1, \dots, b_r)$
- Таблица сопряженности $CT \in \mathbb{R}^{(r+1) \times (c+1)}$:
 - ячейки $(A = a_i, B = b_j)$, столбец и строка суммарных итогов

- $$\chi^2 = \sum \frac{(\text{observed} - \text{expected})^2}{\text{expected}} = \sum_{i=1}^c \sum_{j=1}^r \frac{(o_{ij} - e_{ij})^2}{e_{ij}}$$

- $$e_{ij} = \frac{\text{count}(A=a_i) \cdot \text{count}(B=b_j)}{n}$$

- $$n = CT(r + 1, c + 1)$$

- Таблица критических значений для отбрасывания гипотезы

- Кол-во степеней свободы:

$$k = (r - 1)(c - 1)$$

- Уровень значимости: $\alpha \in (0, 1)$

$k \setminus \alpha$	0.100	0.050	0.025	0.020	0.010	0.005	0.001
1	2.706	3.841	5.024	5.412	6.635	7.879	10.828
2	4.605	5.991	7.378	7.824	9.210	10.597	13.816
3	6.251	7.815	9.348	9.837	11.345	12.838	16.266
4	7.779	9.488	11.143	11.668	13.277	14.860	18.467
5	9.236	11.070	12.833	13.388	15.086	16.750	20.515
6	10.645	12.592	14.449	15.033	16.812	18.548	22.458
7	12.017	14.067	16.013	16.622	18.475	20.278	24.322
8	13.362	15.507	17.535	18.168	20.090	21.955	26.124

Мера χ^2

- Таблица сопряженности
(вычислены ожидаемые значения)

	A	\bar{A}	Σ
B	4000 (4500)	3500 (3000)	7500
\bar{B}	2000 (1500)	500 (1000)	2500
Σ	6000	4000	10000

- $A \rightarrow B$ [$sup = 0.4, conf = 0.66$]
- $\chi^2 = \frac{(4000-4500)^2}{4500} + \frac{(3000-3500)^2}{3000} + \frac{(2000-1500)^2}{1500} + \frac{(500-1000)^2}{1000} = 555.6;$
- $\chi^2 > 1, o(A, B) < e(A, B) \Rightarrow$ отрицательная корреляция A и B
- $A \rightarrow B$ малополезно

Другие меры

- $\text{allconf}(A, B) = \min(P(A|B), P(B|A)) = \frac{\text{sup}(A \cup B)}{\max(\text{sup}(A), \text{sup}(B))}$
- $\text{maxconf}(A, B) = \max(P(A|B), P(B|A)) = \max\left(\frac{\text{sup}(A \cup B)}{\text{sup}(B)}, \frac{\text{sup}(A \cup B)}{\text{sup}(A)}\right)$
- $\text{Kulc}(A, B) = \frac{1}{2}(P(A|B) + P(B|A)) = \frac{1}{2}\left(\frac{\text{sup}(A \cup B)}{\text{sup}(B)} + \frac{\text{sup}(A \cup B)}{\text{sup}(A)}\right)$
- $\text{cosine}(A, B) = \frac{P(A \cup B)}{\sqrt{P(A) \cdot P(B)}} = \sqrt{P(A|B) \cdot P(B|A)} = \frac{\text{sup}(A \cup B)}{\sqrt{\text{sup}(A) \cdot \text{sup}(B)}}$
- $\text{coherence}(A, B) = \frac{\text{sup}(A \cup B)}{\text{sup}(A) + \text{sup}(B) - \text{sup}(A \cup B)}$
- Общие свойства
 - зависимость от $\text{sup}(A)$, $\text{sup}(B)$, $\text{sup}(A \cup B)$ (т.е. от $P(A|B)$, $P(B|A)$)
 - отсутствие зависимости от $|\mathcal{D}|$
 - диапазон значений: $0..1$, большее означает большую связь A и B



**Станислав
Кульчинский**
(1895-1975)

Какая мера лучше?

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\bar{c}$	$\overline{m\bar{c}}$	\bar{c}
Σ_{col}	<i>m</i>	\bar{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\bar{c}$	$\overline{m\bar{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

Какая мера лучше?

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\overline{c}$	$\overline{m\overline{c}}$	\overline{c}
Σ_{col}	<i>m</i>	\overline{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\overline{c}$	$\overline{m\overline{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

m, *c*
связаны
положительно

m, *c*
связаны
отрицательно

m, *c*
нейтральны

Какая мера лучше?

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\bar{c}$	$\overline{m\bar{c}}$	\bar{c}
Σ_{col}	<i>m</i>	\bar{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\bar{c}$	$\overline{m\bar{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

m, *c*
связаны
положительно

m, *c*
связаны
отрицательно

m, *c*
нейтральны

Какая мера лучше?

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\overline{c}$	$\overline{m\overline{c}}$	\overline{c}
Σ_{col}	<i>m</i>	\overline{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\overline{c}$	$\overline{m\overline{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

m, *c*
связаны
положительно

m, *c*
связаны
отрицательно

m, *c*
нейтральны

Какая мера лучше?

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\overline{c}$	$\overline{m\overline{c}}$	\overline{c}
Σ_{col}	<i>m</i>	\overline{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\overline{c}$	$\overline{m\overline{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

m, *c*
связаны
положительно

m, *c*
связаны
отрицательно

m, *c*
нейтральны

Какая мера лучше?

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\bar{c}$	$\overline{m\bar{c}}$	\bar{c}
Σ_{col}	<i>m</i>	\bar{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\bar{c}$	$\overline{m\bar{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

m, *c*
связаны
положительно

m, *c*
связаны
отрицательно

m, *c*
нейтральны

- χ^2 и lift показывают неадекватные результаты ввиду чувствительности к $\overline{m\bar{c}}$
- как правило, $\overline{m\bar{c}}$ нестабильно и велико

Null-транзакции и pull-инвариантность мер

- Таблица сопряженности

	<i>milk</i>	\overline{milk}	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
\overline{coffee}	$m\overline{c}$	$\overline{m\overline{c}}$	\overline{c}
Σ_{col}	<i>m</i>	\overline{m}	Σ

- Сравнение мер для (*m*, *c*)

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\overline{c}$	$\overline{m\overline{c}}$	χ^2	<i>lift</i>	all conf	max conf	Kulc	cosine
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5

m, *c*
связаны
положительно

m, *c*
связаны
отрицательно

m, *c*
нейтральны

- χ^2 и *lift* не являются pull-инвариантами

Null-инвариантная мера Imbalance Ratio (IR)

$$\bullet \text{ IR}(A, B) = \frac{|\text{sup}(A) - \text{sup}(B)|}{\text{sup}(A) + \text{sup}(B) - \text{sup}(A \cup B)}$$

	<i>milk</i>	$\overline{\text{milk}}$	Σ_{row}
<i>coffee</i>	<i>mc</i>	\overline{mc}	<i>c</i>
$\overline{\text{coffee}}$	$m\overline{c}$	$\overline{m\overline{c}}$	\overline{c}
Σ_{col}	<i>m</i>	\overline{m}	Σ

\mathcal{D}	<i>mc</i>	\overline{mc}	$m\overline{c}$	$\overline{m\overline{c}}$	χ^2	lift	all conf	max conf	Kulc	cosine	IR
D_1	10000	1000	1000	100000	90557	9.26	0.91	0.91	0.91	0.91	0
D_2	10000	1000	1000	100	0	1	0.91	0.91	0.91	0.91	0
D_3	100	1000	1000	100000	670	8.44	0.09	0.09	0.09	0.09	0
D_4	1000	1000	1000	100000	24740	25.75	0.5	0.5	0.5	0.5	0
D_5	1000	10	10000	100000	8173	9.18	0.09	0.91	0.5	0.29	0.89
D_6	1000	10	100000	100000	965	1.97	0.01	0.99	0.5	0.1	0.99

Резюме о мерах полезности шаблонов

- Применение при поиске только мер sup и $conf$ приводит к большому количеству шаблонов, многие из которых неадекватны
- Рекомендуется дополнительно использовать меры, обладающие свойством $pull$ -инвариантности
- Среди мер с этим свойством рекомендуется совместное использование $Kulc$ и IR

Литература

- Han J., Kamber M., Pei J. Data Mining: Concepts and Techniques. 3rd Edition. Morgan Kaufmann, 2011. 740 p. ISBN 978-0123814791
 - Chapter 6. Mining Frequent Patterns, Associations, and Correlations: Basic Concepts and Methods, pp. 243-278
- Tan P.-N., Steinbach M., Karpatne A., Kumar V. Introduction to Data Mining. 2nd Edition. Pearson, 2019. 839 p. ISBN-13: 978-0-13-312890-1
 - 5. Association Analysis: Basic Concepts and Algorithms, pp. 357-450