

بسمه تعالیٰ

داده کاوی

Data mining

مدرس
فاطمه دارائی

f_daraei@semnan.ac.ir
<https://fdaraei.profile.semnan.ac.ir>



دانشگاه سمنان
Semnan University
بردهی فرازنگان





1


فصل سوم: الگوهای مکرر و قوانین انجمنی

الگوی مکرر: الگویی (مجموعه‌ای از آیتم‌ها، زیرتریپ‌ها، زیرساختارها و غیره) که به طور مکرر در یک مجموعه داده اتفاق می‌افتد.



- چه محصولاتی اغلب با هم خریداری شده‌اند؟
- پس از خرید یک کامپیوتر، خریدهای بعدی چه چیزهایی هستند؟
- چه نوع DNA به این داروی جدید حساس است؟

Input Graph G



Subgraph S



(b)

- اولین بار در سال ۱۹۹۳ توسط Agrawal در زمینه کاوش مجموعه آیتم‌های مکرر پیشنهاد شد.

2



کاربردها



- تحلیل سبد خرید (Market Basket Analysis)
- بازاریابی متقاطع (Cross-marketing)
- مدیریت قفسه (Shelf management)
- تحلیل وب لاغ (تحلیل جریان کلیک)
- تحلیل توالی (DNA (DNA sequence analysis))
- استخراج ارتباطات کلمات
- همکاران و کلمات کلیدی در مقالات علمی

3



مفاهیم پایه

مجموعه آیتم: **Itemset** یک مجموعه از آیتم‌ها

مجموعه k آیتم: **k -itemset** یک مجموعه آیتم با k آیتم.

تعداد پشتیبانی: **Support count** تعداد تراکنش‌هایی که شامل یک مجموعه آیتم هستند.

نسبت پشتیبانی: **Support ratio** کسری از تراکنش‌هایی که شامل یک مجموعه آیتم هستند.

مجموعه آیتم مکرر: **Frequent itemset** یک مجموعه آیتم که پشتیبانی آن بزرگتر یا مساوی یک آستانه حداقل پشتیبانی (**minsup threshold**) است.

جدول ۱-۴: نمونه‌ای از یک پایگاه داده تراکنشی فروشگاه

TID	Items
1	{Bread, Milk}
2	{Bread, Egg, Butter, Cheese}
3	{Milk, Butter, Cheese, Chicken}
4	{Bread, Cheese, Chicken}
5	{Bread, Milk, Butter, Cheese}

4



دانشگاه سمنان
Semnan University
بررسی فرآیندان

TID	Transaction
T ₁₀	A, C, D
T ₂₀	B, C, E
T ₃₀	A, B, C, E
T ₄₀	B, E

1-itemset

Support count ($\{C\}$) = 3
Support ratio ($\{C\}$) = 3/4

2-itemset

Support count ($\{B, C\}$) = 2
Support ratio ($\{B, C\}$) = 2/4

3-itemset

Support count ($\{B, C, E\}$) = 2
Support ratio ($\{B, C, E\}$) = 2/4

If minsup = 0.7


$\{C\}$ is a Frequent itemset

5



دانشگاه سمنان
Semnan University
بررسی فرآیندان

مجموعه آیتم مکرر: Frequent itemset



6




Brute-force رویکرد

هر مجموعه اقلام در شبکه یک مجموعه اقلام مکرر کاندید است.

با اسکن و جستجوی پایگاه داده تعداد پشیبانی هر نامزد و کاندید را بشمارید.

هر تراکنش را با هر کاندید مطابقت دهید - پیچیدگی $\sim O(NMw)$ گران از مرتبه $M = 2^d$



7



الگوریتم Apriori

الگوریتم دو ورودی دیتابیس و minsub را دارد.


اگر یک مجموعه اقلام مکرر نباشد، subset های آن حتماً مکرر نمی باشد.

- در ابتدا، یک بار دیتابیس را اسکن کنید تا مجموعه 1 موردی مکرر frequent 1-itemset را دریافت کنید.


• 1 = k را تنظیم کنید. (شروع الگوریتم)

- مجموعه آیتم های کاندید با طول (k+1) را از مجموعه آیتم های k مکرر ایجاد کنید.
- کاندیدها را در دیتابیس آزمایش کنید تا مجموعه های مکرر (k+1)-اقلام را بدست آورید.
- به k یکی اضافه کنید. (بدنه تکرار)
- زمانی خاتمه دهید که هیچ مجموعه ای مکرر یا کاندید ایجاد نشود. (شرط توقف)



8



9



۱۰



ادامه مثال ۲

TID	Items
T1	I1, I2, I5
T2	I2, I4
T3	I2, I3
T4	I1, I2, I4
T5	I1, I3
T6	I2, I3
T7	I1, I3
T8	I1, I2, I3, I5
T9	I1, I2, I3

minsup = 2

Scan D for count of each candidate →

C ₁	Itemset	Sup.count
	I1	6
	I2	7
	I3	6
	I4	2
	I5	2

Compare Candidate support with minsup count →

L ₁	Itemset	Sup.count
	I1	6
	I2	7
	I3	6
	I4	2
	I5	2

13

ادامه مثال ۲

C ₂	Itemset
	I1, I2
	I1, I3
Generate C ₂ candidates from L ₁ →	I1, I4
	I1, I5
	I2, I3
	I2, I4
	I2, I5
	I3, I4
	I3, I5
	I4, I5


Scan D for count of each candidate →

C ₂	Itemset	Sup. count
	I1, I2	4
	I1, I3	4
	I1, I4	1
	I1, I5	2
	I2, I3	4
	I2, I4	2
	I2, I5	2
	I3, I4	0
	I3, I5	1
	I4, I5	0

Compare Candidate support with minsup count →

L ₂	Itemset	Sup.count
	I1, I2	4
	I1, I3	4
	I1, I5	2
	I2, I3	4
	I2, I4	2
	I2, I5	2

14





Apriori افزایش بهره وری الگوریتم

1. استفاده از توابع درهم سازی (Hash based)
2. کاهش تراکنش (Transaction Reduction)
3. پارتیشن بندی (Partitioning)
4. نمونه برداری (Sampling)
5. شمارش پویای Itemset ها (Dynamic itemset counting)

17



فرمت داده افقی Horizontal Data Format

تبديل فرمت در دیتابیس باعث می شود محاسبات کمتر و ساده تر شود.
 گاهی اوقات می توان قالب داده ها را عوض کرد و یا در فرمت ها مختلفی نمایش داد.
 در حالت عادی برای هر تراکنش، مجموع کالاها را به صورت سطحی مقابل آن داریم.
 به این چینش اطلاعات، **فرمت داده افقی** می گوییم.

TID	Transaction
T ₁	A, B, C
T ₂	B
T ₃	B, C, D
T ₄	A, D

Horizontal Format 1

TID	Item
T ₁	A
T ₁	B
T ₁	C
T ₂	B
T ₃	B
T ₃	C
...	...

Horizontal Format 2

TID	Transaction			
	A	B	C	D
T ₁	1	1	1	0
T ₂	0	1	0	0
T ₃	0	1	1	1
T ₄	1	0	0	1

Horizontal Format 3

18



فرمت داده عمودی Vertical Data Format

این فرمت به طور گسترده‌ای در موتورهای جستجو مورد استفاده قرار می‌گیرد.

Horizontal: document → words
Vertical: words → document

TID	Transaction
T ₁	A, B, C
T ₂	B
T ₃	B, C, D
T ₄	A, D
Horizontal Format 1	

item	Transaction				
		T ₁	T ₂	T ₃	T ₄
A	T ₁ , T ₄	1	0	0	1
B	T ₁ , T ₂ , T ₃	1	1	1	0
C	T ₁ , T ₃	1	0	1	0
D	T ₃ , T ₄	0	0	1	1
Vertical Format					

19




الگوریتم Eclat

(تبديل کلاس هم‌ارز) (Equivalence Class Transformation) ECLAT مشابه الگوریتم Apriori است،

- اما از فرمت داده‌های عمودی استفاده می‌کند.
- ابتدا، با یکبار پیمایش پایگاه داده، فرمت افقی را به فرمت عمودی تبدیل می‌کنیم.
- تعداد support یک مجموعه آیتم به سادگی برابر با طول مجموعه است = دستیابی به مجموعه آیتم‌های مکرر آیتمی.
- مرحله تولید کاندیدها مشابه الگوریتم Apriori است.

TID	Items
T1	I1, I2, I5
T2	I2, I4
T3	I2, I3
T4	I1, I2, I4
T5	I1, I3
T6	I2, I3
T7	I1, I3
T8	I1, I2, I3, I5
T9	I1, I2, I3



Item	TID
I1	T1, T4, T5, T7, T8, T9
I2	T1, T2, T3, T4, T6, T8, T9
I3	T3, T5, T6, T7, T8, T9
I4	T2, T4
I5	T1, T8

20



دانشگاه سمنان
Semnan University
بردهیس فرداگان

لیستهای مربوط به مجموعه آیتم‌های مکرر k آیتم را با هم اشتراک می‌گیریم تا لیستهای مربوط به مجموعه آیتم‌های $(k+1)$ - آیتم را به دست آوریم.

Item	TID
I1	T1, T4, T5, T7, T8, T9
I2	T1, T2, T3, T4, T6, T8, T9
I3	T3, T5, T6, T7, T8, T9
I4	T2, T4
I5	T1, T8

$$L_1 = \{I1, I2, I3, I4, I5\}$$

TID	Items
I1, I2	T1, T4, T8, T9
I1, I3	T5, T7, T8, T9
I1, I4	T4
I1, I5	T1, T8
I2, I3	T3, T6, T8, T9
I2, I4	T2, T4
I2, I5	T1, T8
I3, I4	\emptyset
I3, I5	T8
I4, I5	\emptyset

$$L_2 = \{I_1 I_2, I_1 I_3, I_1 I_5, I_2 I_3, I_2 I_4, I_2 I_5\}$$

$$C_3 = \{I_1 I_2 I_3, I_1 I_2 I_5\}$$

TID	Items
I1, I2, I3	T8, T9
I1, I2, I5	T1, T8

$$C_4 = \emptyset$$

21



دانشگاه سمنان
Semnan University
بردهیس فرداگان

قوانين انجماني

با توجه به مجموعه ای از تراکنش های T ، هدف از استخراج قوانین انجمانی این است که همه قوانین قوی پیدا شود.

$$\begin{aligned} \text{support} &\geq \text{minsup threshold} \\ \text{confidence} &\geq \text{minconf threshold} \end{aligned}$$

.Drصدی از تراکنش ها که حاوی A و B است. Support

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

:Drصدی از تراکنش هایی است که اگر حاوی A باشند، B نیز در آنها وجود داشته باشد. Confidence

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

پوشش قانون را نشان می دهد و Confidence اطمینان، دقت و درستی قانون را.

22



دانشگاه سمنان
Semnan University
بررسی فرآیندان

مثال

TID	Items		
1	A, B	$\{B, C\} \rightarrow \{D\}$	(sup = 0.4, conf = 0.67)
2	A, C, D, E	$\{B, D\} \rightarrow \{C\}$	(sup = 0.4, conf = 1.0)
3	B, C, D, F	$\{C\} \rightarrow \{B, D\}$	(sup = 0.4, conf = 0.5)
4	A, B, C, D	$\{B\} \rightarrow \{C\}$	(sup = 0.6, conf = 0.75)
5	A, B, C, F		

23



دانشگاه سمنان
Semnan University
بررسی فرآیندان

Confidence و Support مقایسه

- I. Support and confidence are both high. II. Support and confidence are both low.

I
A, B
A, B, C
A, B, D
A, B
A, B, C, D



$A \rightarrow B$
sup = 1
conf = 1

II
A
B
A, C
B, C
C, D



$A \rightarrow B$
sup = 0
conf = 0

24



مقایسه Confidence و Support

III. Confidence is high and support is low. IV. Confidence is low and support is high.

III		It is impossible because: $\text{Sup} \leq \text{Conf}$
A, B, D A, C, D A, D, E B, E, F B, C, D, E, F G, A	$G \rightarrow A$ $\text{sup} = \frac{1}{6}$ $\text{conf} = 1$	\downarrow $\text{Conf}(A \rightarrow B) = \frac{P(A,B)}{P(A)} = \frac{\text{Sup}(A \rightarrow B)}{P(A)}$ $P(A) \leq 1$

25



استخراج قوانین انجمنی

:Brute-force رویکرد

- تمام قوانین ارتباط ممکن را فهرست کنید.
- پشتیبانی و اطمینان برای هر قانون را محاسبه کنید.
- قوانینی را که در آستانه minconf و minsup ناموفق هستند، هرس کنید.

غیر عملی است، زیرا ما می توانیم قوانین متفاوتی را برای هر کدام ایجاد کنیم و مجموعه آیتم ها، و تعداد نمایی از مجموعه آیتم ها وجود دارد!

26



استخراج قوانین انجمنی

داده کاو در هنگام استخراج قوانین دو آستانه زیر را تعیین می نماید:

min-sub

min-conf

قوانينی که درجه پشتیبانی و اطمینان آنها بیش از این دو مقدار باشند، به عنوان **قوی strong** شناخته می شوند.

استفاده از مجموعه الگوهای مکرر

- همه مجموعه موارد را با $\text{minsup} \leq \text{support}$ ایجاد کنید.
- تولید قوانین با اطمینان بالا از هر مجموعه آیتم های مکرر، که در آن هر قانون یک پارتبیشن بندی باینری از مجموعه آیتم های مکرر است.

27



مثال

L₁

Itemset	Sup.count
I1	6
I2	7
I3	6
I4	2
I5	2

TID Items

TID	Items
T1	I1, I2, I5
T2	I2, I4
T3	I2, I3
T4	I1, I2, I4
T5	I1, I3
T6	I2, I3
T7	I1, I3
T8	I1, I2, I3, I5
T9	I1, I2, I3

L₂

Itemset	Sup.count
I1, I2	4
I1, I3	4
I1, I5	2
I2, I3	4
I2, I4	2
I2, I5	2

L₃

Itemset	Sup. count
I1, I2, I3	2
I1, I2, I5	2

Minsup = 2, minconf = %70

20

ادامه مثال

I1, I2	I1 → I2	conf = $\frac{4}{6}$ ✗
	I2 → I1	conf = $\frac{4}{7}$ ✗
I1, I3	I1 → I3	conf = $\frac{4}{6}$ ✗
	I3 → I1	conf = $\frac{4}{6}$ ✗
I2, I5	I2 → I5	conf = $\frac{2}{7}$ ✗
	I5 → I2	conf = 1 ✓

L ₁		L ₂	
Itemset	Sup.count	Itemset	Sup.count
I1	6	I1, I2	4
I2	7	I1, I3	4
I3	6	I1, I5	2
I4	2	I2, I3	4
I5	2	I2, I4	2
		I2, I5	2

/

29

ادامه مثال

I1, I2, I3	I1 → I2 I3	conf = $\frac{2}{6}$ ✗
	I2 → I1 I3	conf = $\frac{2}{7}$ ✗
	I3 → I1 I2	conf = $\frac{2}{6}$ ✗
	I1 I2 → I3	conf = $\frac{2}{4}$ ✗
	I1 I3 → I2	conf = $\frac{2}{4}$ ✗
	I2 I3 → I1	conf = $\frac{2}{4}$ ✗
I1, I2, I5	I5 → I1 I2	conf = 1 ✓
	I1 I5 → I2	conf = 1 ✓
	I2 I5 → I1	conf = 1 ✓

L ₁		L ₂	
Itemset	Sup.count	Itemset	Sup.count
I1	6	I1, I2	4
I2	7	I1, I3	4
I3	6	I1, I5	2
I4	2	I2, I3	4
I5	2	I2, I4	2
		I2, I5	2

/