

VERİ MADENCİLİĞİ İlişkilendirme Kuralları

Prof. Dr. Şule Gündüz Öğüdücü
http://www3.itu.edu.tr/~sgunduz/courses/verimaden/


1

İlişkilendirme Kuralları Madenciliği

- İlişkilendirme kuralı madenciliği
 - Veri kümesi içindeki yaygın örüntülerin, nesneleri oluşturan nitelikler arasındaki ilişkilerin bulunması
- İlişkilendirme kurallarını kullanma: veri içindeki kuralları belirleme
 - Hangi ürünler çoğunlukla birlikte satılıyor?
 - Kişisel bilgisayar satın alan bir kişinin bir sonraki satın alacağı ürün ne olabilir?
 - Yeni bir ilaca duyarlı olan DNA tipleri hangileridir?
 - Web dökümanları otomatik olarak sınıflandırılabilir mi?

2

İlişkilendirme Kuralları Bulma

- Bir niteliğin (veya nitelikler kümesinin) varlığını harekette bulunan başka niteliklerin varlıklarına dayanarak öngörme
 
- Kural şekli: "Gövde → Baş [destek, güven]"
 - satın alma(x, "ekmek") → satın alma (x, "süt") [%0.6, %65]
 - öğrenci(x, "BLG"), kayıt(x, "VTYS") → not(x, "A") [%1, %75]

3

İlişkilendirme Kuralları Bulma

- Bütün niteliklerden oluşan küme $I = \{I_1, I_2, \dots, I_d\}$
 - $I = \{\text{ekmek, süt, bira, kola, yumurta, bez}\}$
- Hareket $T_i \in I, T_j = \{I_{j1}, I_{j2}, \dots, I_{jd}\}$
 - $T_1 = \{\text{ekmek, süt}\}$
- Hareketlerden oluşan veri kümesi $D = \{T_1, T_2, \dots, T_N\}$



Market Alışveriş verisi

Hareket	Nitelikler
T1	Ekmek, Süt
T2	Ekmek, Bez, Bira, Yumurta
T3	Süt, Bez, Bira, Kola
T4	Ekmek, Süt, Bez, Bira
T5	Ekmek, Süt, Bez, Kola

Yaygın nitelikler:

Bez, bira
Süt, ekmek, yumurta, kola
Bira, ekmek, süt

Bulunan İlişkilendirme Kuralları

{Bez} → {Bira},
{Süt, Ekmek} → {Yumurta, Kola},
{Bira, Ekmek} → {Süt}

4

Yaygın Nitelikler

- nitelikler kümesi (Itemset)
 - Bir veya daha çok nitelikten oluşan küme
 - k-nitelikler kümesi (k-itemset): k nitelikten oluşan küme
 - 3-nitelikler kümesi: {Bez, Bira, Ekmek}
- Destek sayısı σ (Support count)
 - Bir nitelikler kümesinin veri kümesinde görülme sıklığı
 - $\sigma(\{\text{Süt, Ekmek, Bez}\}) = 2$
- Destek s (Support)
 - Bir nitelikler kümesinin içinde bulunduğu hareketlerin toplam hareketlere oranı
 - $s(\{\text{Süt, Ekmek, Bez}\}) = 2/5$
- Yaygın nitelikler (Frequent itemset)
 - Destek değeri *minsup* eşik değerinden daha büyük ya da eşit olan nitelikler kümesi

5

İlişkilendirme Kuralları

- Veri kümesi $D = \{T_1, T_2, \dots, T_N\}$
- en az, en küçük destek ve güven değerine sahip $X \rightarrow Y$ şeklinde kuralların bulunması
 - $X \subset I, Y \subset I, X \cap Y = \emptyset$
- Kuralları değerlendirme ölçütleri
 - destek (support) s: $X \cup Y$ nitelikler kümesinin bulunduğu hareket sayısının toplam hareket sayısına oranı

$$\text{support}(X \rightarrow Y) = \frac{\#(X \cup Y)}{N}$$
 - güven (confidence) c: $X \cup Y$ nitelikler kümesinin bulunduğu hareket sayısının X nitelikler kümesi bulunan hareket sayısına oranı

$$\text{confidence}(X \rightarrow Y) = \frac{\#(X \cup Y)}{\#X}$$

TID	Öğeler
T1	Ekmek, Süt
T2	Ekmek, Bez, Bira, Yumurta
T3	Süt, Bez, Bira, Kola
T4	Ekmek, Süt, Bez, Bira
T5	Ekmek, Süt, Bez, Kola

Örnek:
{Süt, Bez} → {Bira}

$$\text{support} = \frac{\sigma(\text{süt, bira, bez})}{|T|} = \frac{2}{5} = 0,4$$

$$\text{confidence} = \frac{\sigma(\text{süt, bira, bez})}{\sigma(\text{süt, bez})} = \frac{2}{3} = 0,67$$

6

İlişkilendirme Kuralları Oluşturma

- İlişkilendirme kuralları madenciliğinde temel amaç: D hareket kümesinden kurallar oluşturmak
 - kuralların destek değeri, belirlenen en küçük destek ($minsup$) değerinden büyük ya da eşit olmalı
 - kuralların güven değeri, belirlenen en küçük güven ($minconf$) değerinden büyük ya da eşit olmalı
- Brute-force yaklaşım
 - Olası bütün kuralları listele
 - Her kural için destek ve güven değeri hesapla
 - $minsup$ ve $minconf$ eşik değerlerinden küçük destek ve güven değerlerine sahip kuralları sil
 - hesaplama maliyeti yüksek

$$R = 3^d - 2^{d+1} + 1$$

7

İlişkilendirme Kuralları Özellikleri

TID	Öğeler
1	Ekmek, Süt
2	Ekmek, Bez, Bira, Yumurta
3	Süt, Bez, Bira, Kola
4	Ekmek, Süt, Bez, Bira
5	Ekmek, Süt, Bez, Kola

Örnek Kurallar:


$\{Süt, Bez\} \rightarrow \{Bira\}$ ($s=0.4, c=0.67$)
 $\{Süt, Bira\} \rightarrow \{Bez\}$ ($s=0.4, c=1.0$)
 $\{Bez, Bira\} \rightarrow \{Süt\}$ ($s=0.4, c=0.67$)
 $\{Bira\} \rightarrow \{Süt, Bez\}$ ($s=0.4, c=0.67$)
 $\{Bez\} \rightarrow \{Süt, Bira\}$ ($s=0.4, c=0.5$)
 $\{Süt\} \rightarrow \{Bez, Bira\}$ ($s=0.4, c=0.5$)

- Aynı nitelikler kümesinin ikili bölünmesine (binary partition) ait kurallar
 - $\{Süt, Bez, Bira\}$
- Aynı nitelikler kümesinden oluşan kuralların destek değerleri aynı, güven değerleri farklı
- Kurallar için destek ve güven şartları ayrı değerlendirilebilir

8


İlişkilendirme Kuralları Oluşturma

- İki adımda gerçekleşir
 - Yaygın nitelikleri belirleme:**
 - destek değeri $minsup$ değerinden büyük ya da eşit olan nitelikler kümelerini bulma
 - Kural Oluşturma:**
 - Güven değeri $minconf$ değerinden büyük ya da eşit olan ve yaygın niteliklerin ikili bölünmeleri olan kuralları oluşturma
 - Güçlü kurallar



9

Yaygın nitelik Adayları Oluşturma




- Yaygın nitelikleri bulmak maliyetli
 - d nitelik için $2^d - 1$ yaygın nitelik oluşabilir
 - $2^d - 1$ yaygın nitelik adayı

10

Yaygın Nitelik Oluşturma

- Brute-Force Yaklaşım
 - Her yaygın nitelik adayı için veri kümesini taranarak hareketlerde yaygın nitelik adayı bulunup bulunmadığı kontrol edilir

TID	Öğeler
1	Ekmek, Süt
2	Ekmek, Bez, Bira, Yumurta
3	Süt, Bez, Bira, Kola
4	Ekmek, Süt, Bez, Bira
5	Ekmek, Süt, Bez, Kola



- yaygın nitelik adayları için destek değeri bulunur
- Destek değeri $minsup$ değerine eşit yada büyük olanlar yaygın nitelikler
- karmaşıklığı: $O(NMw)$, $M=2^d - 1 \Rightarrow$ hesaplaması maliyetli

11

Yaygın nitelik Oluşturma Yöntemleri

- Yaygın nitelik aday sayısını (M) azaltma
 - Örnek: Apriori algoritması
- Hareket sayısını (N) azaltma
- Veri kümesi tarama sayısını (MN) azaltma

12

Apriori Algoritması

- Apriori yöntemi
 - Rakesh Agrawal, Ramakrishnan Srikant, *Fast Algorithms for Mining Association Rules*, Proc. 20th Int. Conf. Very Large Data Bases, VLDB'94
 - Heikki Mannila, Hannu Toivonen, Inkeri Verkamo, *Efficient Algorithms for Discovering Association Rules*. AAAI Workshop on Knowledge Discovery in Databases (KDD-94).
- Temel yaklaşım:

$$\forall X, Y : (X \subseteq Y) \Rightarrow s(X) \geq s(Y)$$
 - Bir nitelikler kümesinin destek değeri altkümesinin destek değerinden büyük olamaz
 - anti-monotone özellik


13

Apriori Algoritması

- Bir yaygın nitelikler kümesinin herhangi bir altkümesi de yaygın nitelikler kümesidir
 - {Süt, Bez, Bira} kümesi yaygın nitelikler kümesi ise {Süt, Bez} kümesi de yaygın nitelikler kümesidir
 - {Süt, Bez, Bira} nitelikler kümesi olan her harekette {Süt, Bez} kümesi de vardır
- Yaygın nitelik aday sayısını azaltma yöntemi: Yaygın nitelikler kümesi olmayan bir kümenin üst kümeleri yaygın nitelik adayı olarak oluşturulmaz (destek değeri hesaplanmaz)
- Yöntem:
 - k-yaygın nitelikler kümesinden (k+1) yaygın nitelik adayları oluştur
 - yaygın nitelik adayları için destek değeri hesapla

14

Apriori Yaygın Nitelik Azaltma Yöntemi



15

Apriori Algoritması: Örnek

Nitelik	Sayı
Ekmek	4
Kola	2
Süt	4
Bira	4
Yumurta	1

1-nitelikler kümesi

Nitelikler kümesi	Sayı
{Ekmek, Süt}	3
{Ekmek, Bira}	2
{Ekmek, Bez}	3
{Süt, Bira}	2
{Süt, Bez}	3
{Bira, Bez}	3

2-nitelikler kümesi
(içinde kola ya da yumurta olan nitelikler kümesini yaygın nitelik adayı olarak oluşturmaya gerek yok)

minsüp = 3

Her nitelikler kümesi için destek hesaplınsaydı,
 $C_1 + C_2 + C_3 = 6 + 15 + 20 = 41$
 Yaygın nitelik sayısı azaltılınca,
 $6 + 6 + 1 = 13$

Nitelikler Kümesi	Sayı
{Ekmek, Süt, Bez}	3

3-nitelikler kümesi

16

Apriori Algoritması

- Pseudo-code:
 - C_k : Candidate itemset of size k
 - L_k : frequent itemset of size k
 - $L_I = \{\text{frequent items}\}$
 - for ($k = 1; L_k \neq \emptyset; k++$) **do begin**
 - C_{k+1} = candidates generated from L_k
 - for each** transaction t in database **do**
 - increment the count of all candidates in C_{k+1} that are contained in t
 - L_{k+1} = candidates in C_{k+1} with min_support
 - end**
 - return** $\cup_k L_k$

17

Yaygın Nitelikler Adayı Oluşturma

- L_{k-1} kümesinde nitelikler alfabetik sıralanmış olsun
- 1. adım: L_{k-1} kendisiyle birleştirme
 - insert into C_k
 - select $p.item_y, p.item_z, \dots, p.item_{k-1}, q.item_{k-1}$
 - from $L_{k-1} p, L_{k-1} q$
 - where $p.item_1 = q.item_y, \dots, p.item_{k-2} = q.item_{k-2}, p.item_{k-1} < q.item_{k-1}$
- 2. adım: Eleme
 - forall **itemsets** c in C_k **do**
 - forall ($k-1$)-subsets s of c **do**
 - if** (s is not in L_{k-1}) **then delete** c **from** C_k

18

Örnek: Yaygın nitelikler Adayı Oluşturma

- Yaygın nitelik adayları oluşturma:
 - L_k kendisiyle birleştirilir (self join)
 - eleme
- Örnek:
 - $L_3 = \{abc, abd, acd, ace, bcd\}$
 - Kendisiyle birleştirme: $L_3 * L_3$
 - abc ve abd nitelikler kümesinden $abcd$
 - acd ve ace nitelikler kümesinden $acde$
 - Eleme
 - ade L_3 kümesinin bir elemanı olmadığından $acde$ yaygın niteliklere dahil edilmez
 - $C_4 = \{abcd\}$

19

Yaygın niteliklerden İlişkilendirme Kuralları Oluşturma

- Sadece güçlü ilişkilendirme kuralları oluşuyor
- Yaygın nitelikler *minsup* değerini sağlıyor
- Güçlü ilişkilendirme kuralları *minconf* değerini sağlıyor.
- Güven $(A \rightarrow B) = \frac{\text{Prob}(B|A) \cdot \text{Destek}(A \cup B)}{\text{Destek}(A)}$
- Yöntem:
 - Her yaygın nitelikler kümesi f 'in altkümelerini oluşturun
 - Her altküme s için, $s \rightarrow (f-s)$ ilişkilendirme kuralı oluşturun eğer: $\frac{\text{destek}(f)}{\text{destek}(s)} \geq \text{minconf}$ ise

20

İlişkilendirme Kuralları Oluşturma

- L yaygın niteliklerden $f \subseteq L$ altkümelerinin bulunması
 - $f \rightarrow L-f$ kurallarının en küçük güven değeri koşulunu sağlaması gerekir
- Eğer $\{A, B, C, D\}$ yaygın nitelikler ise olası ilişkilendirme kuralları

$ABC \rightarrow D$,	$ABD \rightarrow C$,	$ACD \rightarrow B$,	$BCD \rightarrow A$,
$A \rightarrow BCD$,	$B \rightarrow ACD$,	$C \rightarrow ABD$,	$D \rightarrow ABC$
$AB \rightarrow CD$,	$AC \rightarrow BD$,	$AD \rightarrow BC$,	$BC \rightarrow AD$,
$BD \rightarrow AC$,	$CD \rightarrow AB$		
- $|L| = k$ için $2^k - 2$ ilişkilendirme kuralı adayı vardır
 - $L \rightarrow \emptyset$ ve $\emptyset \rightarrow L$ kuralları geçerli kurallar değildir


21

İlişkilendirme Kuralları Oluşturma

- İlişkilendirme kurallarının güven değerlerinin anti-monotone özelliği yok
 - $c(ABC \rightarrow D)$ değeri $c(AB \rightarrow D)$ değerinden küçük ya da büyük olabilir
- Aynı yaygın nitelikler kümesinden $L = \{A, B, C, D\}$ oluşan ilişkilendirme kurallarının güven değerleri için anti-monotone özelliği var
 - $c(ABC \rightarrow D) \geq c(AB \rightarrow CD) \geq c(A \rightarrow BCD)$
 - İlişkilendirme kuralının solunda bulunan nitelik sayısı büyük olan kuralların güven değerleri de büyüktür.

22


Apriori Algoritması için Kural Oluşturma



23

Apriori Algoritması için Kural Oluşturma

- Sağ taraflarındaki niteliklerin örnekleri aynı olan iki kural birleştirilir
- $(CD \Rightarrow AB, BD \Rightarrow AC)$ kuralları birleştirilerek $D \Rightarrow ABC$ kuralı oluşturulur.
- $AD \Rightarrow BC$ kuralının güven değeri büyük değilse $D \Rightarrow ABC$ kuralı elenir



24

Destek Değerinin Etkisi

- minsup değeri büyük belirlenirse veri kümesinden bazı örüntüler elde edilmeyebilir:
 - veri kümesinde daha az bulunan
 - önemli bilgi taşıyan
- minsup değeri küçük belirlenirse
 - yöntem karmaşılaşır
 - çok fazla sayıda yaygın nitelikler kümesi elde edilir
- Tek bir destek değeri her zaman yeterli olmayabilir.

25


Bulunan Kuralların Önemi

- Tarafsız Ölçüt:
 - Örüntüler veri kümesinden elde edilen istatistiklere göre sıralanır
 - güven, destek, Jaccard, Gini, ...
- Tarafli Ölçüt
 - Örüntüler kullanıcının değerlendirmesine göre sıralanır
 - Bulunan örüntü kullanıcının beklentisi dışındaysa ilginçtir (Silberschatz & Tuzhilin)

26

Bulunan Kuralların Önemi

- Tarafli değerlendirme için kullanıcının beklentisinin modellenmesi gerekir



- + Yaygın olduğu düşünülen örüntü
- - Yaygın olmadığı düşünülen örüntü
- □ Yaygın olduğu bulunan örüntü
- ○ Yaygın olmadığı bulunan örüntü
- ⊕ ⊖ Beklenen örüntüler
- ⊖ ⊕ Beklenmeyen örüntüler

27

Apriori Algoritmasını Geliştirme

- Veritabanı tarama sayısını azaltma
 - k-yaygın nitelikler kümesi için veritabanı k kez taranıyor
- Hash yöntemi ile veritabanı tarama sayısını azaltma
- Veritabanındaki hareket sayısını ve hareketlerdeki nitelik sayısını azaltma
 - yaygın olmayan niteliklerin veritabanında yer almasına gerek yok
- Arama uzayını parçalama

28



Eniyilime: Hash Ağacı

- Her yaygın nitelik adayının destek değerinin belirlenmesi için veri kümesi taranır
 - Yaygın nitelik adayı sayısı çok büyük olabilir
- Karşılaştırma sayısını azaltmak için yaygın nitelik adayları hash ağacında saklanır
 - Her hareket bütün yaygın niteliklerle karşılaştırılmak yerine hash ağacının ilgili bölümündeki yaygın nitelikler adayları ile karşılaştırılır

29

Hash Ağacı Oluşturma


- 15 adet 3-nitelikler kümesi
 $\{1\ 4\ 5\}, \{1\ 2\ 4\}, \{4\ 5\ 7\}, \{1\ 2\ 5\}, \{4\ 5\ 8\}, \{1\ 5\ 9\}, \{1\ 3\ 6\}, \{2\ 3\ 4\}, \{5\ 6\ 7\}, \{3\ 4\ 5\}, \{3\ 5\ 6\}, \{3\ 5\ 7\}, \{6\ 8\ 9\}, \{3\ 6\ 7\}, \{3\ 6\ 8\}$
- Hash fonksiyonu kullanılarak bir hash ağacında saklanıyor
 - $h(p) = p \bmod 3$
- max yaprak boyutu: bir yaprakta bulunabilecek nitelik kümesi sayısı



30


Bir Harekette Bulunabilecek Yaygın nitelikleri Belirleme

- t hareketinin 3-nitelikler kümesi




31

Bir Harekette Bulunabilecek Yaygın nitelikleri Hash Ağacı ile Belirleme



32

Bir Harekette Bulunabilecek Yaygın nitelikleri Hash Ağacı ile Belirleme



15 yaygın nitelik adayının 9'u ile karşılaştırıldı

33

Karmaşıklığı Etkileyen Etmenler

- Veri kümesindeki boyut sayısı (nitelik sayısı)
 - her niteliğin destek değerini saklamak için daha fazla saklama alanına ihtiyaç var
- Veri kümesinin büyüklüğü
 - Veri kümesi tarandığı için veri kümesindeki hareket sayısının fazla olması algoritmanın çalışma süresini uzatır
- Hareketlerin ortalama büyüklüğü (nitelik sayısı)
 - Yoğun veri kümelerinde hareketlerdeki nitelik sayısı fazla olur
 - Yaygın nitelik kümelerindeki nitelik sayısı daha fazladır
- En küçük destek değerini belirleme
 - En küçük destek değerini küçültme daha fazla sayıda yaygın nitelik oluşmasına neden olur
 - Yaygın nitelik adayları sayısının ve yaygın nitelik kümesindeki niteliklerin sayısının artmasına neden olur

34

Yaygın Nitelikleri Belirlemede Sorunlar

- Sorunlar
 - Veri kümesinin birçok kez taranması
 - Yaygın nitelikler aday sayısının fazlalığı
 - Yaygın nitelikleri bulmak için $I_{f_2} \dots I_{f_{100}}$
 - veri kümesini tarama sayısı: 100
 - Aday sayısı: $(100^1) + (100^2) + \dots + (100^{100}) = 2^{100} - 1 = 1.27 \times 10^{30}$
 - Yaygın nitelikler adayları için destek değerinin hesaplanması
- Çözümler
 - Veri kümesi tarama sayısını azaltma (S. Brin R. Motwani, J. Ullman, and S. Tsur. *Dynamic itemset counting and implication rules for market basket data*. In SIGMOD'97)
 - Yaygın nitelik aday sayısını azaltma (J. Park, M. Chen, and P. Yu. *An effective hash-based algorithm for mining association rules*. In SIGMOD'95)
 - Destek değerinin hesaplanmasını kolaylaştırma (M. Zaki et al. *New algorithms for fast discovery of association rules*. In KDD'97)
 - Yaygın nitelikler adayları oluşturmadan yaygın nitelikler bulunabilir. (J. Han, J. Pei, and Y. Yin. *Mining Frequent Patterns without Candidate Generation*. In SIGMOD'00.)

35

FP-Tree Algoritması

- Hareketlerden oluşan bir veri kümesinden destek değeri (ξ), kullanıcının belirlediği destek değerine eşit ya da daha büyük olan tüm yaygın örüntülerin bulunması

Giriş:	DB:	TID	Items bought
		100	{f, a, c, d, g, i, m, p}
		200	{a, b, c, f, l, m, o}
		300	{b, f, h, j, o}
		400	{b, c, k, s, p}
		500	{a, f, c, e, l, p, m, n}

Minimum support: $\xi = 3$

Çıkış: bütün yaygın örüntüler, f, a, ..., fa, fac, fam, ...

36

Apriori Özelliği

- Apriori algoritmasının temeli:
 - $(k-1)$ uzunluğundaki yaygın örüntülerden (L_{k-1}) k uzunluğunda yaygın örüntü adayları oluşturma (C_k)
 - veritabanı taranarak C_k içinde destek koşuluna sağlayan k uzunluklu yaygın örüntülerin bulunması L_k

TID	nitelikler	Apriori iteration
100	{f, a, c, d, g, i, m, p}	C1 f,a,c,d,g,i,m,p,l,o,h,j,k,s,b,e,n
200	{a, b, c, f, l, m, o}	L1 f, a, c, m, b, p
300	{b, f, h, j, o}	C2 fa,fc,fm,fp,ac,am,...bp
400	{b, c, k, s, p}	L2 fa,fc,fm,...
500	{a, f, c, e, l, p, m, n}	...


37

FP-Tree Algoritması

TID	nitelikler	(sıralı) yaygın
100	{f, a, c, d, g, i, m, p}	{f, c, a, m, p}
200	{a, b, c, f, l, m, o}	{f, c, a, b, m}
300	{b, f, h, j, o, w}	{f, b}
400	{b, c, k, s, p}	{c, b, p}
500	{a, f, c, e, l, p, m, n}	{f, c, a, m, p}

minsup = 3

- DB bir kez taranarak 1-yaygın nitelik bulunuyor
- Yaygın nitelikler destek sayısına göre büyükten küçüğe sıralanıyor, f-list
- DB bir kez daha taranarak FP-ağacı oluşturuluyor.



F-list=f-c-a-b-m-p

38

FP-Tree Oluşturma

TID	nitelikler	(sıralı) yaygın
100	{f, a, c, d, g, i, m, p}	{f, c, a, m, p}
200	{a, b, c, f, l, m, o}	{f, c, a, b, m}
300	{b, f, h, j, o, w}	{f, b}
400	{b, c, k, s, p}	{c, b, p}
500	{a, f, c, e, l, p, m, n}	{f, c, a, m, p}

minsup = 3

- 2 Adım:
 - DB bir kez taranarak 1-yaygın nitelik bulunuyor
L={f:4, c:4, a:3, b:3, m:3, p:3}
 - Yaygın nitelikler destek sayısına göre büyükten küçüğe sıralanıyor: f-list. DB bir kez daha taranarak FP-ağacı oluşturuluyor.
F-list=f-c-a-b-m-p

39

FP-Tree Oluşturma: Adım 1

- Veritabanını bir kez tarayarak L_1 oluşturma

TID	nitelik
100	{f, a, c, d, g, i, m, p}
200	{a, b, c, f, l, m, o}
300	{b, f, h, j, o}
400	{b, c, k, s, p}
500	{a, f, c, e, l, p, m, n}



Item	destek
f	4
c	4
a	3
b	3
m	3
p	3

40

FP-Tree Oluşturma: Adım 2


- Veritabanını bir kez daha tarayarak her hareketteki niteliği f-list'e göre sırala

TID	nitelikler	(sıralı) yaygın
100	{f, a, c, d, g, i, m, p}	{f, c, a, m, p}
200	{a, b, c, f, l, m, o}	{f, c, a, b, m}
300	{b, f, h, j, o, w}	{f, b}
400	{b, c, k, s, p}	{c, b, p}
500	{a, f, c, e, l, p, m, n}	{f, c, a, m, p}

41

FP-Tree Oluşturma: Adım 2


- FP-Tree oluştur



42


FP-Tree Oluşturma: Adım 2

■ FP-Tree oluştur



43

Örnek: FP-Tree Oluşturma



44

FP-Ağacının Özelliği


- En büyük avantajı veritabanını sadece 2 kez taraması
- Bütünlük
 - Yaygın nitelikleri bulmak için gerekli tüm bilgiyi barındırır
- Sıkıştırılmış
 - Yaygın olmayan nitelikler FP-ağacında bulunmaz
 - Destek sayısı daha büyük olan nitelikler köke daha yakın
 - Asıl veri kümesinden daha büyük değil

45

Özellikleri

- Hareketlerdeki niteliklerin f-list'e göre sıralanmadığı durum

TID	sıralanmamış
100	{f, a, c, m, p}
500	{a, f, c, p, m}




46

Özellikleri

- f-list'teki niteliklerin destek değerinin artan sırada sıralandığı durum

TID	(ascended) frequent items
100	{p, m, a, c, f}
200	{m, b, a, c, f}
300	{b, f}
400	{p, b, c}
500	{p, m, a, c, f}



47

FP-Tree ile Yaygın Örüntülerin Bulunması

- Kısa yaygın niteliklere yeni nitelikler eklenerek daha uzun yaygın nitelikler elde etme
- 3 Adım
 1. Başlık tablosundaki her nitelik için nitelik koşullu örüntüleri oluştur
 2. Koşullu FP-Tree oluştur
 3. Yinelemeli olarak işlemi devam ettir. Koşullu FP-Tree yapısında tek dal kaldığında olası bütün örüntüleri listele
- Örnek:
 - "abc" bir yaygın nitelik
 - Veri kümesinde içinde "abc" nitelikleri bulunan hareketler (DB|abc)
 - DB|abc içinde d yaygın nitelik olarak bulunursa: "abcd" yaygın nitelik olarak belirlenir

48


Örüntüleri ve Veri Kümesini Bölme

- Yaygın nitelikler f-listesine göre altkümelere bölünür
 - F-list=f-c-a-b-m-p
 - p niteliği bulunan örüntüler
 - m niteliği bulunan ancak p niteliği bulunmayan örüntüler
 - ...
 - c niteliği bulunan ancak a, b, m, p niteliği bulunmayan örüntüler
 - f niteliği bulunan örüntüler

49

Adım 1: Nitelik Koşullu Örüntü Oluşturma


- Başlık tablosundan her niteliğin bulunduğu ilk düğüm bulunur.
- Bu düğümden başlayarak ağaçta niteliğin bulunduğu tüm düğümlere ulaşılır
- Kökten niteliğe kadar olan yollar bulunur (*transformed prefix paths*)



50


Adım 2: Nitelik Koşullu Örüntülerden Koşullu FP-Ağaçları Oluşturma

- Her koşullu örüntü için niteliklerin destek sayısı bulunur
- Yaygın nitelikler için koşullu FP-ağacı oluşturulur



51

Koşullu FP-Ağaçları



52

FP-Ağaçları ile Yaygın nitelikleri Bulma

- Yaygın niteliklere yinelemeli olarak yeni nitelikler ekleme
- Yöntem:
 - Her yaygın niteliğin koşullu örüntülerini ve koşullu FP-ağacını oluştur
 - İşlemi, yeni oluşturulan her koşullu FP-ağacı için tekrarla
 - Oluşturulan FP-ağaçlarında hiç nitelik bulunmayana kadar veya ağaçta tek bir dal kalana kadar işleme devam et
 - Ağaçta tek bir dal kaldığında yaygın nitelikler dalı oluşturan niteliklerin kombinasyonu

53

Çok Katmanlı İlişkilendirme Kurallarını Çıkarma

- Ürünler hiyerarşik yapıda olabilir
- Değişebilen destek değerleri
 - daha alt seviyelerdeki ürünlerin destek değeri daha düşük olabilir



54

Gereksiz Kuralları Eleme

- Ürünler arasındaki ilişki nedeniyle bazı kurallar gereksiz olabilir
- Örnek
 - `satin_alma (X, "Taşınabilir bilg.") => satin_alma(X, "HP yazıcı") [%8, %70]`
 - `satin_alma (X, "IBM Taşınabilir bilg.") => satin_alma(X, "HP yazıcı") [%2, %70]`
- İlk kural ikinci kuralın üst kuralı
- Eğer bir kuralın destek değeri üst kuralının destek değerinden tahmin edilebiliyorsa gereksizdir

55