


VERİ MADENCİLİĞİ İlişkilendirme Kuralları: Farklı Yöntemler

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

1

Çok Katmanlı İlişkilendirme Kuralları

- Nitelikler bir hiyerarşi oluşturabilir.
 - kavram hiyerarşisi
 - Daha alt katmanlarda yer alan ürünlerin destek değeri daha düşük
 - Alt seviyelerde oluşan kurallar özel durumları tanımlıyor
 - Beyaz ekmek => normal süt
 - Kepekli ekmek => normal süt
 - Kepekli ekmek => diyet süt
- kuralları ekmek => süt kuralının bir göstergesi



2

Çok Katmanlı İlişkilendirme Kuralları

- Destek ve güven değerlerinin katmanlar arasında değişimi
 - X_1 ve X_2 niteliklerinin üst düğümünde yer alan nitelik X
 $\sigma(X) \geq \sigma(X_1) + \sigma(X_2)$
 - $\sigma(X_1 \cup Y_1) \geq \text{minsup}$, X_1 niteliğinin üst düğümünde yer alan nitelik X , Y_1 niteliğinin üst düğümünde yer alan nitelik Y
 $\sigma(X \cup Y_1) \geq \text{minsup}$, $\sigma(X_1 \cup Y) \geq \text{minsup}$
 $\sigma(X \cup Y) \geq \text{minsup}$
- $\text{conf}(X_1 \Rightarrow Y_1) \geq \text{minconf}$ ise $\text{conf}(X_1 \Rightarrow Y) \geq \text{minconf}$

3

Çok Katmanlı İlişkilendirme Kuralları

- 1. Yaklaşım:
 - Her hareket t , üst katmanlardaki nitelikler cinsinden yazılarak genişletilmiş harekete t' dönüştürülür
 $t = \{\text{beyaz ekmek, normal süt}\}$
 $t' = \{\text{beyaz ekmek, normal süt, ekmek, süt, yiyecek}\}$
 t' hareketleri için ilişkilendirme kuralları bulunur
- Problemler:
 - Üst düğümlerde yer alan niteliklerin destek değerleri daha büyük
 - Farklı seviyelerde farklı destek değerleri
 - Veri kümesinin boyutu artıyor

4

Çok Katmanlı İlişkilendirme Kuralları

- Alt katmanlarda destek değerini küçültme
 - Her katmanda bağımsız hesaplama (Level-by-level independent)
 - İlk olarak en üst katman için yaygın nitelikler bulunur. Her aşamada bir alt katmandaki nitelikler arasındaki ilişkiler bulunur
 - Problemler:
 - Kullanışlı değil: her katman için veri kümesi araştırılıyor
 - Farklı katmanlar arasındaki ilişkiler bulunamıyor

5

Çok Katmanlı İlişkilendirme Kuralları

- Alt katmanlarda destek değerini küçültme
 - Her katmanda bağımsız hesaplama (Level-by-level independent)
 - Üst düğümleri yaygın nitelik olan niteliklerin destek değerini hesaplama
 - Tek niteliğe göre budama (Level-cross filtering by single item)
 - nitelikler kümesine göre budama (Level-cross filtering by k-itemset)

6

Çok Katmanlı İlişkilendirme Kuralları

- 2. Yaklaşım
İlk olarak en üst katman için yaygın nitelikler bulunur
Her aşamada bir alt katmandaki nitelikler arasındaki ilişkiler bulunur
- Problemler:
 - Kullanışlı değil: her katman için veri kümesi araştırılıyor
 - Farklı katmanlar arasındaki ilişkiler bulunamıyor

7

Gereksiz Kuralları Eleme

- Ürünler arasındaki ilişki nedeniyle bazı kurallar gereksiz olabilir
- Örnek
 - $\text{satın_alma}(X, \text{"Ekmek"}) \Rightarrow \text{satın_alma}(X, \text{"Süt"})$ [%8, %70]
 - $\text{satın_alma}(X, \text{"Beyaz Ekmek"}) \Rightarrow \text{satın_alma}(X, \text{"Süt"})$ [%2, %70]
- İlk kural ikinci kuralın üst kuralı
- Eğer bir kuralın destek değeri üst kuralının destek değerinden tahmin edilebiliyorsa gereksizdir

8

Nicel İlişkilendirme Kuralları

Kayıt No	Yaş	Medeni Durum	Araba Sayısı
1	23	Bekar	1
2	25	Evli	1
3	29	Bekar	0
4	34	Evli	2
5	38	Evli	2
...	...	...	...

- Örnek ilişkilendirme kuralları:
yaş:30-39, medeni durum: evli $\Rightarrow$ araba sayısı:2
(destek: %40, güven: %100)
araba sayısı: 0-1 $\Rightarrow$ medeni durum: bekar
(destek: %40, güven: %66,70)

9

Nicel İlişkilendirme Kuralları

- İkili değişkenlerden oluşan ilişkilendirme kurallarına dönüştürülüyor:
 - Kategorik olmayan nitelik değerleri için bölmeleme
 - yaş: 20-29, 30-39
 - ikili değişken oluşturma
 - kategorik niteliklerin her değeri için bir ikili değişken
 - kategorik olmayan niteliklerin her bölümü için bir ikili değişken

Kayıt No	Yaş	Medeni Durum	Araba Sayısı
1	23	Bekar	1
5	38	Evli	2

Kayıt No	Yaş 20-29	Yaş 30-39	M.Durum Evli	M.Durum Bekar	Araba 0	Araba 1	Araba 2
1	1	0	0	1	0	1	0
5	0	1	1	0	0	0	1

10

Nicel İlişkilendirme Kuralları

- Dönüştürmeden kaynaklanan problemler
 - bölme sayısı az: Bilgi kaybolması
 - Destek değeri küçük: fazla sayıda kural

11

Koşullu Veri Madenciliği

- Veri madenciliği algoritmasının olası bütün örüntüleri çıkarması
 - gerçekçi değil
 - çok fazla sayıda amaca hizmet etemeyen örüntü çıkabilir
- Veri madenciliği yöntemleri kullanıcı ile etkileşimli çalışabilir
- Koşullu veri madenciliği
 - kullanıcıya esneklik sağlar
 - sistemin daha verimli çalışmasını sağlar

12


Veri Madenciliği için Koşullar

- Bilgi koşulu
 - ilişkilendirme, sınıflandırma..
- Veri koşulu
 - SQL benzer sorgulamalar
 - İstanbul'da aralık 2007'de en çok satılan ürün çiftlerini bul
- Boyut koşulu (katman koşulu)
 - veri madenciliğinde kullanılacak boyutları veya katmanları belirler
- İlginçlik koşulu
 - min_sup>%3 ve min_conf>%70 olan kuralların bulunması
- Kural (örüntü) koşulu
 - kuralların yapısını belirler

13


Yaygın Altçizge Madenciliği

- Frequent Subgraph Mining
 - İlişkilendirme kuralları madenciliği yöntemleri uygulanarak yaygın altçizgeler bulunur
- Uygulama alanları
 - Web madenciliği
 - Biyoinformatik



14

Çizge Tanımları




- $V=\{x_i\}$ düğümler kümesi
- $E=\{w_{ij}\}$ x_i ve x_j düğümleri arasındaki ağırlık
- Altçizge: $G_i(V_i, E_i)$

$$\bigcup_{i=1}^k V_i = V$$

$$E_i = \{ \{u, v\} \in E \wedge u, v \in V_i \}$$

15

Çizge-Hareket Dönüşümü



	(a,b,p)	(a,b,q)	(a,b,r)	(b,c,p)	(b,c,q)	(b,c,r)	...	(d,e,r)
G1	1	0	0	0	0	1	...	0
G2	1	0	0	0	0	0	...	0
G3	0	0	1	1	0	0	...	0
G3	...	...	...	...	...	...	...	...


16

Apriori Temelli Yaklaşım

- Bir altçizgenin destek değeri:
 - Altçizgenin bulunduğu çizgelerin toplam çizgelere oranı
- Apriori temelli yaklaşım
 - yaygın (k+1)-altçizgeleri bulmak için k-altçizgelerin kullanılması
 - düğüm ekleme: k düğüm sayısı
 - ayırt ekleme: k ayırt sayısı

17


Düğüm Ekleme



$$M_{G1} = \begin{pmatrix} 0 & p & p & q \\ p & 0 & r & 0 \\ p & r & 0 & 0 \\ q & 0 & 0 & 0 \end{pmatrix} \quad M_{G2} = \begin{pmatrix} 0 & p & p & 0 \\ p & 0 & r & 0 \\ p & r & 0 & r \\ 0 & 0 & r & 0 \end{pmatrix} \quad M_{G3} = \begin{pmatrix} 0 & p & p & 0 & q \\ p & 0 & r & 0 & 0 \\ p & r & 0 & r & 0 \\ 0 & 0 & r & 0 & 0 \\ q & 0 & 0 & 0 & 0 \end{pmatrix}$$

18

Ayrit Ekleme



19

Apriori Temelli Algoritma

- Yaygın 1-altçizgelerin belirlenmesi
- Yeni yaygın altçizge oluşmayana kadar tekrarla
 - Aday oluşturma: Yaygın (k-1) altçizgeleri kullanarak k-altçizgeler oluşturma
 - Aday azaltma: (k-1)-altçizgesi yaygın olmayan adayların silinmesi
 - Destek hesaplaması: Kalan adaylar için destek değerinin hesaplanması
 - Aday eleme: min_sup değerini sağlamayan adayların silinmesi


20

Aday Oluşturma

- Apriori yöntemi:
 - İki (k-1)-yaygın niteliklerin birleştirilmesi sonucu sadece bir k-yaygın nitelikler oluşur.
- Altçizge madenciliği
 - İki (k-1)-yaygın altçizgenin birleştirilmesi sonucu birden fazla k-yaygın altçizge oluşur
 - iki (k-1)-yaygın altçizgenin birleştirilmesi için (k-2)-altçizgelerinin aynı olması gerekir (çekirdek)

21


Düğüm Ekleme: Farklı Aday Oluşması



22

Ayrit Ekleme: Farklı Aday Oluşması


- 1. durum: düğüm etiketleri aynı



23

Ayrit Ekleme: Farklı Aday Oluşması

- 2. durum: çekirdekteki düğüm etiketleri aynı



24

Çizge Madenciliği

- Jun Huan, Wei Wang, Jan Prins, and Jiong Yang, *SPIN: Mining maximal frequent subgraphs from graph databases*. Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (SIGKDD), 2004.
- X. Yan, X. J. Zhou, and J. Han, *Mining Closed Relational Graphs with Connectivity Constraints*, Proc. 2005 Int. Conf. on Knowledge Discovery and Data Mining (KDD'05), Chicago, IL, Aug. 2005.

25

Sıralı Diziler

- İlişkilendirme kuralları hareketlerde yer alan nitelikler arasındaki ilişkiyi bulmayı hedefler. Zaman bilgisini kullanmaz.




- Sıralı dizi analizi zaman bilgisini kullanarak hareketlerin sırasına göre nitelikler arasındaki ilişkiyi bulur.



26

Sıralı Dizi Verisi

Object	Timestamp	Events
A	10	2, 3, 5
A	20	6, 1
A	23	1
B	11	4, 5, 6
B	17	2
B	21	7, 8, 1, 2
B	28	1, 6
C	14	1, 8, 7



- Örnek sıralı dizi verisi:
 - müşteri hareketleri
 - tıbbi veriler
 - web verileri
 - telefon görüşme kayıtları
 - DNA dizileri

27

Sıralı Dizi Tanımı

Sıralı dizi veritabanı

SID	sıralı dizi
10	<a(abc)(ac)d(cf)>
20	<(ad)c(bc)(ae)>
30	<(ef)(ab)(df)cb>
40	<eg(af)cb>

Elemanlar içinde niteliklerin sırası yok (liste)

$$\langle a(abc)(ac)d(cf) \rangle = \langle a(cba)(ac)d(cf) \rangle$$

$$\langle a(abc)(ac)d(cf) \rangle \neq \langle a(ac)(abc)d(cf) \rangle$$

Elemanlar sıralı 9-sıralı dizi

- Elemanlar nitelikler kümesi, nitelikler sıralı değildir, genelde alfabetik sırada sıralanırlar (abc)
- Elemanların sıralı listesi (<a(abc)(ac)d(cf)>)
- Elemanlar zaman veya yer ile nitelendirilir
- Sıralı dizinin uzunluğu |s|: Sıralı diziyi oluşturan nitelikler sayısı
- k-sıralı dizi: k niteliği olan sıralı dizi

28

Sıralı Dizi Örnekleri

- Web verileri:
 - < (Homepage) (Electronics) (Digital Cameras) (Canon Digital Camera) (Shopping Cart) (Order Confirmation) (Return to Shopping) >
- Kütüphaneden alınan kitaplar:
 - <(Fellowship of the Ring) (The Two Towers) (Return of the King)>
- DNA dizileri
 - ACAAGATGCCATTGTCCCCGGCCTCTGCTGCTGCTCTCCGGGGCCACGGCC

29

Alt Dizi Tanımı

- $\beta = \langle b_1 b_2 \dots b_m \rangle$ sıralı dizisi içinde $\alpha = \langle a_1 a_2 \dots a_n \rangle$ sıralı dizinin bulunabilmesi için ($m \geq n$):
 - $i_1 < i_2 < \dots < i_n$ koşulunda $a_1 \subseteq b_{i_1}, a_2 \subseteq b_{i_2}, \dots, a_n \subseteq b_{i_n}$
 - $\langle a(abc)(ac)d(cf) \rangle$ sıralı dizinin bir alt dizisi: $\langle a(bc)dc \rangle$
 - $\langle ad \rangle, \langle (ad)c(bc)(ae) \rangle$ sıralı dizinin alt dizisi değil
- α dizisi için β "super sequence" olarak tanımlanır.
- s dizisi hiç bir dizinin alt dizisi değilse "maximal" olarak tanımlanır.
- Bir alt dizinin destek değeri: Alt dizinin bulunduğu sıralı dizilerin toplam sıralı dizi sayısına oranı
- Sıralı dizi örüntüsü: Destek değeri en küçük destek değerine (minsup) eşit ya da büyük olan alt diziler

30

Sıralı Dizi Analizi

- Sıralı dizi veritabanında en az *minsup* destek değerine sahip alt dizilerin bulunması (sıralı dizi örüntülerinin bulunması)

sıralı dizi veritabanı

SID	sıralı dizi
10	<a(abc)(ac)d(cf)>
20	<(ad)c(bc)(ae)>
30	<(ef)(ab)(df)cb>
40	<eg(af)cbc>

$\alpha.1 = \langle (ab)c \rangle$ $\text{minsup}(\alpha.1) = 2$

31

Zorluklar

- Veri kümesi içinde çok fazla sayıda sıralı dizi örüntüsü bulunabilir. Sıralı dizi bulmak için kullanılan algoritmanın:
 - bütün sıralı dizi örüntülerini bulması gerekir
 - Veri kümesini az sayıda tarayarak sonuç üretmesi gerekir
 - ölçeklenebilir
 - Değişik veri tipleri üzerinde çalışabilmesi gerekir

32

Sıralı Dizi Örüntülerinin Temel Özelliği

- Apriori:
 - Sıralı dizi *s*, *minsup* değerini sağlamıyorsa, *s*'in hiçbir üst kümesi de *minsup* değerini sağlamaz.
 - Örnek: <hb> *minsup* değerini sağlamıyor → <hab> ve <(ah)b> sıralı dizileri de *minsup* değerini sağlamaz.

SID	Sıralı dizi
10	<(bd)cb(ac)>
20	<(bf)(ce)b(fg)>
30	<(ah)(bf)abf>
40	<(be)(ce)d>
50	<a(bd)bcb(ade)>

minsup = 2

33

Apriori All

- Rakesh Agrawal and Ramakrishnan Srikant, *Mining Sequential Patterns*, In Proc. of 11th Int. Conf. on Data Engineering, Taipei, Taiwan, 1995.
- Apriori algoritmasının yaklaşımını kullanır
- Aday sıralı dizileri bulmak için Apriori algoritmasının Apriori-generate fonksiyonunu kullanır. Aday sıralı dizilerin *minsup* değerlerini bulmak için sıralı dizi verisini tarar.

34

Apriori All Algoritması

- 5 aşamadan oluşur
 - Sıralama aşaması (sort phase)
Hareketlerden oluşan veri kümesinden sıralı dizileri oluşturma
 - Yaygın nitelikler kümesi aşaması (large itemset phase)
Apriori ile yaygın nitelikler kümeleri bulunur
 - Dönüştürme aşaması (Transformation phase)
Her yaygın nitelikler kümesi bir tamsayı ile eşleştirilir
 - Sıralı dizi aşaması (sequence phase)
Apriori kullanılarak bütün sıralı dizi örüntüleri çıkarılır
 - Maximal aşaması (maximal phase)
Maximal olmayan sıralı diziler elenir

35

Apriori All Algoritması (1)


- C_k : k uzunluğunda yaygın sıralı dizi adayları
- L_k : k uzunluğunda yaygın sıralı diziler
- $L_1 = \{1\text{-frequent sequences}\};$ //2. aşama sonucu
for ($k = 1; L_k \neq \emptyset; k++$) **do begin**
 $C_{k+1} =$ candidates generated from L_k
for each sequence *c* in database **do**
 increment the count of all candidates in C_{k+1} that are contained in *c*
 $L_{k+1} =$ candidates in C_{k+1} with *min_support*
end
return $\cup_k L_k$
- Aday oluşturma: L_{k-1} kendisiyle birleştirme
 insert into C_k
 select $p.item_y, p.item_z, \dots, p.item_{k-y}, q.item_{k-1}$
 from $L_{k-1} p, L_{k-1} q$
 where $p.item_1 = q.item_y, \dots$
 $p.item_{k-2} = q.item_{k-2}$
 Tanım : Dizinin uzunluğu, dizi içindeki nitelikler kümesi sayısıdır.

Örnek:
 $\{1,2,3\} \times \{1,2,4\} =$
 $\{1,2,3,4\}$ ve
 $\{1,2,4,3\}$

36

Örnek: Sıralı Dizi Veritabanı

ID	Zaman	Ürün
1	1	30
1	2	90
2	1	10,20
2	2	30
2	3	40,60,70
3	1	30,50,70
4	1	30
4	2	40,70
4	3	90
5	1	90




minsüp=%40 => en az iki farklı ID

Sonuç: <(30)(90)> (ID=1,4) <(30)(40 70)> (ID=2,4)
<30><40><70><90>, <(30)(40)> <(30)(70)> <(40 70)> sıralı dizi
örüntüsü **değil**

37

Sıralama Aşaması

ID	Zaman	Ürün
1	1	30
1	2	90
2	1	10,20
2	2	30
2	3	40,60,70
3	1	30,50,70
4	1	30
4	2	40,70
4	3	90
5	1	90



- ID
- Zaman

38

Yaygın Nitelikler Kümesi Aşaması

- Apriori algoritması kullanılarak yaygın nitelikler belirlenir.
 - Sıralı dizi örüntülerinde geçen nitelikler yaygın nitelikler olması gerekiyor
- Destek değerinin farklı hesaplanması gerekiyor
 - Bir niteliğin kaç farklı "ID" için bulunduğu

ID	Zaman	Ürün
1	1	30
1	2	90
2	1	10,20
2	2	30
2	3	40,60,70
3	1	30,50,70
4	1	30
4	2	40,70
4	3	90
5	1	90

minsüp=%40 => en az iki farklı ID

Yaygın nitelikler kümeleri:
{30},{40} {70}{40 70} {90}

39


Dönüştürme Aşaması (1)

- Her yaygın nitelikler kümesi bir tamsayı ile eşleştirilir
 - İki farklı nitelikler kümesinin veritabanı içinde eşit zamanda taranması için
- Hareketler tamsayılar ile temsil edilir

Nitelikler	Tamsayı
{30}	1
{40}	2
{70}	3
{40 70}	4
{90}	5

40

Dönüştürme Aşaması (2)



ID	Sıralı Diziler
1	<(30) (90)>
2	<(10 20)30(40 60 70)>
3	<(30 50 70)>
4	<30 (40 70) 90>
5	<(90)>

Nitelikler	Tamsayı
{30}	1
{40}	2
{70}	3
{40 70}	4
{90}	5

ID	Tamsayı Eşleneği
1	<{1} {5}>
2	<{1}{2 3 4}>
3	<{1 3}>
4	<{1} {2 3 4} {5}>
5	<{5}>

41

Sıralı Dizi Aşaması

- Nitelikler kümesi kullanarak istenen destek değerini sağlayan sıralı diziler bulunuyor
- Apriori algoritması ile aynı yaklaşım

Nitelikler	Tamsayı
{30}	1
{40}	2
{70}	3
{40 70}	4
{90}	5

minsüp=%40

ID	Tamsayı Eşleneği
1	<{1} {5}>
2	<{1}{2 3 4}>
3	<{1 3}>
4	<{1} {2 3 4} {5}>
5	<{5}>

Nitelikler	Destek
{1}	4
{2}	2
{3}	3
{4}	2
{5}	3
{{1} {2}}	2
{{1} {3}}	3
{{1} {4}}	2
{{1} {5}}	2

<30>
<40>
<70>
<40 70>
<90>
<30><40>
<30><70>
<30 (40 70)>
<30><90>

42

Maximal Aşaması

- Maximal olmayan sıralı dizileri sil
 - Başka bir sıralı dizinin alt dizisi olan dizileri sil

for $k=n$; $k=1$; $k--$
for each k -sequence s_k do
delete all subsequences of s_k

<30>
<40>
<70>
<40-70>
<90>
<30><40>
<30><70>
<30 (40 70)>
<30><90>

43

GSP (A Generalized Sequential Pattern Mining Algorithm)

- Ramakrishnan Srikant, Rakesh Agrawal, *Mining Sequential Patterns: Generalizations And Performance Improvements*, Proc. 5th Int. Conf. Extending Database Technology, EDBT'96

- Aşama:
 - Veritabanını bir kez tarayarak 1 nitelikten oluşan sıralı dizi örüntülerini bulunur
- Aşama: Yeni bir sıralı dizi örüntüsü bulunmayınca kadar tekrarla
 - Aday oluşturma: $(k-1)$. adımda bulunan sıralı dizi örüntüleri birleştirilerek k uzunluklu sıralı dizi örüntü adayları bulunur
 - Aday azaltma: $(k-1)$ alt dizileri minsup değerini sağlamayan adaylar elenir
 - Destek değeri hesaplama: Kalan sıralı dizi örüntü adayları için veritabanı taranarak destek değeri hesaplanır
 - Aday eleme: minsup değeri sağlamayan sıralı dizi örüntü adayları elenir.

44

GSP: Aday Oluşturma

- İlk durum ($k=2$): Bir uzunluklu sıralı dizilerden iki uzunluklu sıralı diziler oluşturma
 - $s_{11} = \langle i_1 \rangle$ ve $s_{12} = \langle i_2 \rangle$ sıralı dizilerin birleştirilmesi sonucunda $s_{21} = \langle i_1 i_1 \rangle$, $s_{22} = \langle i_1 i_2 \rangle$, $s_{23} = \langle i_2 i_2 \rangle$, $s_{24} = \langle i_2 i_1 \rangle$ ve $s_{25} = \langle i_1 i_2 \rangle$ sıralı dizileri oluşur
- Genel durum ($k>2$):
 - k uzunluklu s_{ki} ve s_{kj} sıralı dizileri şu şartlar altında birleştir:
 - s_{ki} sıralı dizinin ilk niteliği ve s_{kj} sıralı dizinin son niteliği silindiğinde oluşan alt dizinin aynı olması
 - $(k+1)$ uzunluklu sıralı dizi örüntü adayı, s_{ki} sıralı diziye s_{kj} sıralı dizinin son niteliğinin eklenmesi ile bulunur
 - s_{ki} sıralı dizinin son iki niteliği aynı elemana ait: s_{kj} sıralı dizinin son niteliği s_{ki} sıralı dizisinin son elemanının parçası olur
 - diğer durumda s_{ki} sıralı dizisinin son niteliği s_{kj} sıralı dizisinin ayrı bir elemanı olur.

45

Örnek

- $s_1 = \langle (a) (b) (c) (d) \rangle$ ve $s_2 = \langle (b) (c) (d) (e) \rangle$ sıralı dizileri birleştirilirse
 - aday sıralı dizi $\langle (a) (b) (c) (de) \rangle$
 - s_2 sıralı dizideki son iki nitelik (d) ve (e) aynı elemana ait
- $s_1 = \langle (a) (b) (c) (d) \rangle$ ve $s_2 = \langle (b) (c) (d)(e) \rangle$ sıralı dizileri birleştirilirse
 - aday sıralı dizi $\langle (a) (b) (c) (d)(e) \rangle$
 - s_2 sıralı dizideki son iki nitelik (d) ve (e) aynı elemana ait değil
- $s_1 = \langle (a)(b) (f)(d) \rangle$ ve $s_2 = \langle (a) (b) (d) (e) \rangle$ sıralı dizileri $\langle (a) (b) (f) (de) \rangle$ sıralı dizi örüntü adayı oluşturmak üzere birleştirilemez
 - $s_2 = \langle (b) (f) (d) (x) \rangle$ veya $s_2 = \langle (b) (f) (d) (x) \rangle$ şeklinde olmadığı için

46

Örnek

- Bir nitelikten oluşan dizilerin bulunması
- Adaylar
 - $\langle a \rangle$, $\langle b \rangle$, $\langle c \rangle$, $\langle d \rangle$, $\langle e \rangle$, $\langle f \rangle$, $\langle g \rangle$, $\langle h \rangle$
- Veritabanı taranarak destek sayıları hesaplanır

$min_sup = 2$

SID	Sıralı Dizi
10	$\langle (bd)cb(ac) \rangle$
20	$\langle (bf)(ce)b(fg) \rangle$
30	$\langle (ah)(bf)abf \rangle$
40	$\langle (be)(ce)d \rangle$
50	$\langle a(bd)bc(b)(ade) \rangle$

Aday	Des
$\langle a \rangle$	3
$\langle b \rangle$	5
$\langle c \rangle$	4
$\langle d \rangle$	3
$\langle e \rangle$	3
$\langle f \rangle$	2
$\langle g \rangle$	1
$\langle h \rangle$	1

47

Örnek

- iki uzunluklu sıralı dizilerin bulunması
 - 51 aday

	$\langle a \rangle$	$\langle b \rangle$	$\langle c \rangle$	$\langle d \rangle$	$\langle e \rangle$	$\langle f \rangle$
$\langle a \rangle$	$\langle aa \rangle$	$\langle ab \rangle$	$\langle ac \rangle$	$\langle ad \rangle$	$\langle ae \rangle$	$\langle af \rangle$
$\langle b \rangle$	$\langle ba \rangle$	$\langle bb \rangle$	$\langle bc \rangle$	$\langle bd \rangle$	$\langle be \rangle$	$\langle bf \rangle$
$\langle c \rangle$	$\langle ca \rangle$	$\langle cb \rangle$	$\langle cc \rangle$	$\langle cd \rangle$	$\langle ce \rangle$	$\langle cf \rangle$
$\langle d \rangle$	$\langle da \rangle$	$\langle db \rangle$	$\langle dc \rangle$	$\langle dd \rangle$	$\langle de \rangle$	$\langle df \rangle$
$\langle e \rangle$	$\langle ea \rangle$	$\langle eb \rangle$	$\langle ec \rangle$	$\langle ed \rangle$	$\langle ee \rangle$	$\langle ef \rangle$
$\langle f \rangle$	$\langle fa \rangle$	$\langle fb \rangle$	$\langle fc \rangle$	$\langle fd \rangle$	$\langle fe \rangle$	$\langle ff \rangle$

	$\langle a \rangle$	$\langle b \rangle$	$\langle c \rangle$	$\langle d \rangle$	$\langle e \rangle$	$\langle f \rangle$
$\langle a \rangle$		$\langle (ab) \rangle$	$\langle (ac) \rangle$	$\langle (ad) \rangle$	$\langle (ae) \rangle$	$\langle (af) \rangle$
$\langle b \rangle$			$\langle (bc) \rangle$	$\langle (bd) \rangle$	$\langle (be) \rangle$	$\langle (bf) \rangle$
$\langle c \rangle$				$\langle (cd) \rangle$	$\langle (ce) \rangle$	$\langle (cf) \rangle$
$\langle d \rangle$					$\langle (de) \rangle$	$\langle (df) \rangle$
$\langle e \rangle$						$\langle (ef) \rangle$
$\langle f \rangle$						

Apriori özelliği kullanılmadan aday sayısı
 $8*8+8*7/2=92$

Apriori aday sayısını
 %44.57 azaltıyor

48

Örnek

- 3 uzunluklu adayların bulunması
 - 2 uzunluklu sıralı dizilerden 3 uzunluklu adaylar oluşturma
 - Apriori özelliği kullanılıyor
 - <ab>, <aa> ve <ba> : 2 uzunluklu sıralı diziler
→ <aba> : 3 uzunluklu sıralı dizi
 - <(bd)>, <bb> ve <db> : 2 uzunluklu sıralı diziler
→ <(bd)b> : 3 uzunluklu sıralı dizi
 - 46 aday oluşuyor
- 3 uzunluklu sıralı dizilerin bulunması
 - Veritabanı taranarak adayların destek sayıları hesaplanır
 - 46 adaydan 19 adet 3 uzunluklu sıralı dizi örüntüsü bulunur

49

GSP Örnek

5. adım: 1 aday, 1 adet 5-sıralı dizi örüntüsü
4. adım: 8 aday, 6 adet 4-sıralı dizi örüntüsü
3. adım: 46 aday, 19 adet 3-sıralı dizi örüntüsü. 20 aday DB'de değil
2. adım: 51 aday, 19 adet 2-sıralı dizi örüntüsü. 10 aday DB'de değil
1. adım: 8 aday, 6 adet 1-sıralı dizi örüntüsü.
- $minsup = 2$

ID	Sıralı dizi
10	<(bd)cb(ac)>
20	<(bf)(ce)b(fg)>
30	<(ah)(bf)abf>
40	<(be)(ce)d>
50	<a(bd)bcb(ade)>

50

GSP Örnek

3-sıralı dizi örüntüleri

< {1} {2} {3} >
< {1} {2} {5} >
< {1} {5} {3} >
< {2} {3} {4} >
< {2} {5} {3} >
< {3} {4} {5} >
< {5} {3} {4} >



Aday Oluşturma

< {1} {2} {3} {4} >
< {1} {2} {5} {3} >
< {1} {5} {3} {4} >
< {2} {3} {4} {5} >
< {2} {5} {3} {4} >



Aday Eleme

< {1} {2} {5} {3} >

51

GSP Algoritmasında Problemler

- Çok sayıda sıralı dizi örüntü adayı oluşturulabilir
 - 1000 adet 1-sıralı dizi örüntülerinden $1000 \times 1000 + \frac{1000 \times 999}{2} = 1,499,500$ adet sıralı dizi örüntü adayı oluşur.
- Veritabanı birçok kez taranır
- Uzun sıralı dizileri belirlemek çok zor
 - sıralı diziler art arda eklenerek daha uzun sıralı diziler oluşuyor
 - 100-sıralı dizi oluşturmak için 10^{30} sıralı dizi gerekiyor.

$$\sum_{i=1}^{100} \binom{100}{i} = 2^{100} - 1 \approx 10^{30}$$

52

Sıralı Dizi Örüntü Adayı Oluşturma

- Parçala ve çöz yaklaşımı
 - veritabanı yinelenmeli küçültülür
 - oluşan her veritabanında sıralı dizi örüntüleri bulunur
- Algoritmalar:
 - J. Han J. Pei, B. Mortazavi-Asi, Q. Chen, U. Dayal and M.C. Hsu. *FreeSpan: Frequent pattern-projected sequential pattern mining*. KDD'00
 - J. Pei, J. Han, B. Mortazavi-Asi, H. Pinto, Q. Chen, U. Dayal, and M.C. Hsu. *Prefixspan: Mining sequential patterns efficiently by prefix-projected pattern growth*. In Proceedings of the 17th International Conference on Data Engineering, 2001.

53

FreeSpan Algoritması

- Örnek: Sıralı dizi veritabanı ve min_sup=2

Sıralı dizi Veritabanı

< (bd) c b (ac) >
< (bf) (ce) b (fg) >
< (ah) (bf) a b f >
< (be) (ce) d >
< a (bd) b c b (ade) >

- 1. Adım: 1-sıralı dizi örüntülerinin bulunması ve destek değeri küçülen sırada sıralanmaları (f-list)

f_list: b:5, c:4, a:3, d:3, e:3, f:2

54

FreeSpan Algoritması

- 2. Adım: Arama uzayının bölünmesi. Sıralı dizi veritabanı altkümelere bölünür
 - f niteliği bulunan alt diziler
 - e niteliği bulunan f niteliği bulunmayan
 - d niteliği bulunan e ve f nitelikleri bulunmayan
 - a niteliği bulunan d , e ve f nitelikleri bulunmayan
 - c niteliği bulunan a , d , e ve f nitelikleri bulunmayan
 - b niteliği bulunan
- Her alt dizi (α) için bu alt dizilerin bulunduğu sıralı dizilerden oluşan veritabanları, α -yansımali veritabanları (α -projected database), oluşturulur.

55

FreeSpan Algoritması

- c niteliği bulunan a , d , e ve f nitelikleri bulunmayan sıralı diziler
 - $\langle c \rangle$ -yansımali veritabanı: $\langle b c b c \rangle$, $\langle b c b \rangle$, $\langle b c \rangle$, $\langle b b c b \rangle$
 - c niteliği bulunan a , d , e ve f nitelikleri bulunmayan bütün alt dizilerin bulunması: $\langle bc \rangle$: 4, $\langle cb \rangle$: 3
 - Veritabanı yansıtılarak sıralı diziler bulunmaya devam edilir.

Sıralı dizi Veritabanı

```
< (bd) c b (ac) >  
< (bf) (ce) b (fg) >  
< (ah) (bf) a b f >  
< (be) (ce) d >  
< a (bd) b c b (ade) >
```

56