DECSAI
Departamento de Ciencias de la Computación e I.A.
Universidad de Granada

Patrones secuenciales

© Fernando Berzal, berzal@acm.org

Patrones secuenciales

- Análisis de secuencias & patrones secuenciales.
- GSP [Generalized Sequential Patterns].
- SPADE [Sequential PAttern Discovery using Equivalent Class]
- PrefixSpan
- CloSpan
- Patrones secuenciales con restricciones.
- SSMiner [Similar Sequence Miner]
- Apéndice: Episodios

Análisis de secuencias

Base de datos	Secuencia	Elemento (Transacción)	Evento (Item)
Clientes	Historial de compras de un cliente determinado	Conjunto de artículos comprados por un cliente en un instante concreto	Libros, productos…
Web	Navegación de un visitante del sitio web	Colección de ficheros vistos por el visitante tras un único click de ratón	Página inicial, información de contacto, fotografía…
Eventos	Eventos generados por un sensor	Eventos generador por un sensor en un instante t	Tipos de alarmas generadas
Genoma	Secuencia de ADN	Elemento de la secuencia de ADN	Bases A,T,G,C

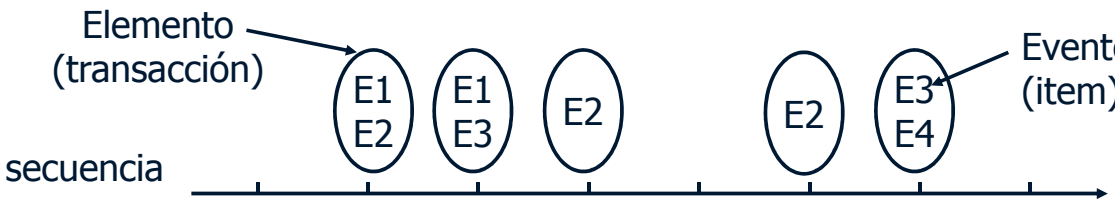

Análisis de secuencias

Una secuencia es una lista ordenada de elementos:

$$s = < e_1\ e_2\ e_3\ \ldots >$$

- Cada elemento contiene una colección de eventos:

$$e_i = \{i_1, i_2, \ldots, i_k\}$$

- Cada elemento tiene una localización temporal (o espacial) asociada.

- La longitud de la secuencia, |s|, es el número de elementos de la secuencia
- Una k-secuencia es una secuencia de k eventos.

Análisis de secuencias

Ejemplos

- Secuencia de visitas en una página web
  < {Homepage} {Electronics} {Tablets} {Kindle Fire HD} {Shopping Cart} {Order Confirmation} {Return to Shopping} >

- Secuencia de eventos que inició el accidente nuclear de 3-Mile Island http://en.wikipedia.org/wiki/Three_Mile_Island_accident
  < {clogged resin} {outlet valve closure} {loss of feedwater} {condenser polisher outlet valve shut} {booster pumps trip} {main waterpump trips} {main turbine trips} {reactor pressure increases}>

- Secuencia de préstamos de libros en una biblioteca
  <{Fellowship of the Ring} {The Two Towers} {Return of the King}>

Análisis de secuencias

Una secuencia $<a_1\ a_2 \ldots a_n>$
está contenida en otra secuencia $<b_1\ b_2 \ldots b_m>$ $(m \geq n)$
si existe un conjunto de enteros $i_1 < i_2 < \ldots < i_n$
tales que $a_1 \subseteq b_{i1}$, $a_2 \subseteq b_{i1}$, …, $a_n \subseteq b_{in}$

Secuencia	Subsecuencia	¿incluida?
< {2,4} {3,5,6} {8} >	< {2} {3,5} >	Sí
< {1,2} {3,4} >	< {1} {2} >	No
< {2,4} {2,4} {2,5} >	< {2} {4} >	Sí

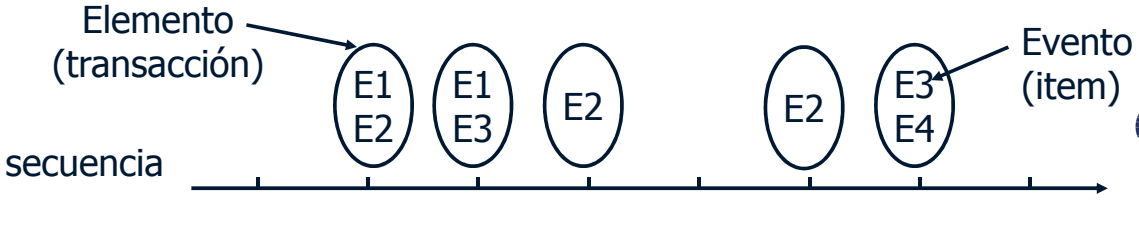

Análisis de secuencias

- El soporte de una subsecuencia S se define como la fracción de secuencias de la base de datos que incluyen la subsecuencia S.
- Un patrón secuencial es una subsecuencia frecuente (esto es, una subsecuencia con soporte ≥ MinSupp)

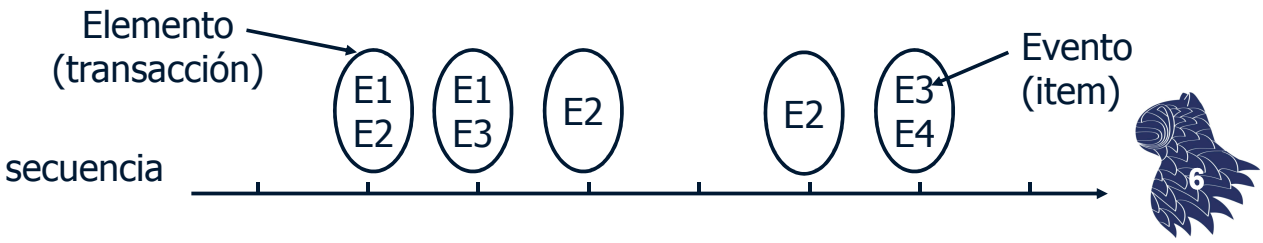

Análisis de secuencias

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, 7, 8

Base de datos
de secuencias

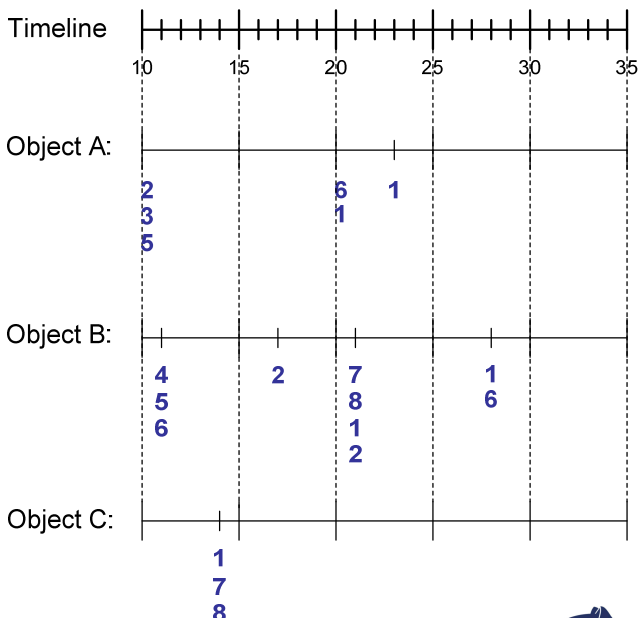

Patrones secuenciales

Problema

Extracción de patrones secuenciales

Dados

- una base de datos de secuencias y
- un umbral de soporte mínimo MinSupp,

encontrar todas las subsecuencias frecuentes (esto es, las subsecuencias con soporte ≥ MinSupp).

Patrones secuenciales

Object	Timestamp	Events
A	1	1,2,4
A	2	2,3
A	3	5
B	1	1,2
B	2	2,3,4
C	1	1, 2
C	2	2,3,4
C	3	2,4,5
D	1	2
D	2	3, 4
D	3	4, 5
E	1	1, 3
E	2	2, 4, 5

MinSupp = 50%

Ejemplos de subsecuencias frecuentes:

< {1,2} >	s=60%
< {2,3} >	s=60%
< {2,4}>	s=80%
< {3} {5}>	s=80%
< {1} {2} >	s=80%
< {2} {2} >	s=60%
< {1} {2,3} >	s=60%
< {2} {2,3} >	s=60%
< {1,2} {2,3} >	s=60%

Patrones secuenciales

¿Cuántas k-subsecuencias existen en una n-secuencia?

<{a b} {c d e} {f} {g h i}> n = 9

Y _ _ Y Y _ _ _ Y k = 4

<{a} {d e} {i}>

$$\binom{n}{k} = \binom{9}{4} = 126$$

Patrones secuenciales

Dados n eventos (items): $i_1, i_2, i_3, \ldots, i_n$

- **n** 1-subsecuencias candidatas
  <{i_1}>, <{i_2}>, <{i_3}>, …, <{i_n}>
- **n(n-1)/2 + n²** 2-subsecuencias candidatas:
  <{i_1, i_2}>, <{i_1, i_3}>, …, <{i_1} {i_1}>, <{i_1} {i_3}>, …, <{i_{n-1}} {i_n}>
- **¿?** 3-subsecuencias candidatas:
  <{i_1, i_2 , i_3}>, <{i_1, i_2 , i_4}>, …, <{i_1, i_2} {i_1}>, <{i_1, i_2} {i_2}>, …,
  <{i_1} {i_1 , i_2}>, <{i_1} {i_1 , i_3}>, …, <{i_1} {i_1} {i_1}>, <{i_1} {i_1} {i_2}>,
  …

GSP [Generalized Sequential Patterns]

Fase 1:

Recorrer la base de datos para obtener todas las secuencias frecuentes de 1 elemento.

Fase 2:

Mientras se encuentren nuevas secuencias frecuentes:

- **Generación:** Generar k-secuencias candidatas a partir de las (k-1)-secuencias frecuentes.
- **Poda:** Podar k-secuencias candidatas que contengan alguna (k-1)-secuencia no frecuente.
- **Conteo:** Recorrer nuevamente el conjunto de datos para obtener el soporte de las candidatas.
- **Eliminación:** Eliminar las k-secuencias candidatas cuyo soporte real esté por debajo de MinSupp.

GSP [Generalized Sequential Patterns]

Generación de candidatos

Caso base (k=2)

La combinación de dos 1-secuencias $<\{i_1\}>$ e $<\{i_2\}>$ produce dos 2-secuencias candidatas

$$<\{i_1\}\ \{i_2\}> \ \ \& \ \ <\{i_1\ i_2\}>$$

GSP [Generalized Sequential Patterns]

Generación de candidatos

Caso general (k>2)

Dos (k-1)-secuencias frecuentes, w_1 y w_2, se combinan para producir una k-secuencia candidata si la subsecuencia obtenida al eliminar el primer evento de w_1 es la misma que la subsecuencia obtenida al eliminar el último evento de w_2

La k-secuencia candidata vendrá dada por la extensión de w_1 con el último evento de w_2.

- Si los dos últimos eventos de w_2 corresponden al mismo elemento, el último evento de w_2 pasa a formar parte del último elemento de w_1

GSP [Generalized Sequential Patterns]

Generación de candidatos

Ejemplos

- w_1=<{1} {2 3} {4}> y w_2 =<{2 3} {4 5}> producen la secuencia candidata < {1} {2 3} {4 5}>
- w_1=<{1} {2 3} {4}> y w_2 =<{2 3} {4} {5}> producen la secuencia candidata < {1} {2 3} {4} {5}>
- w_1 =<{1} {2 6} {4}> y w_2 =<{1} {2} {4 5}> no es necesario combinarlas para producir la secuencia candidata < {1} {2 6} {4 5}>, ya que, si dicha secuencia es una posible candidata, se obtendrá combinando w_1 con < {1} {2 6} {5}>

GSP [Generalized Sequential Patterns]

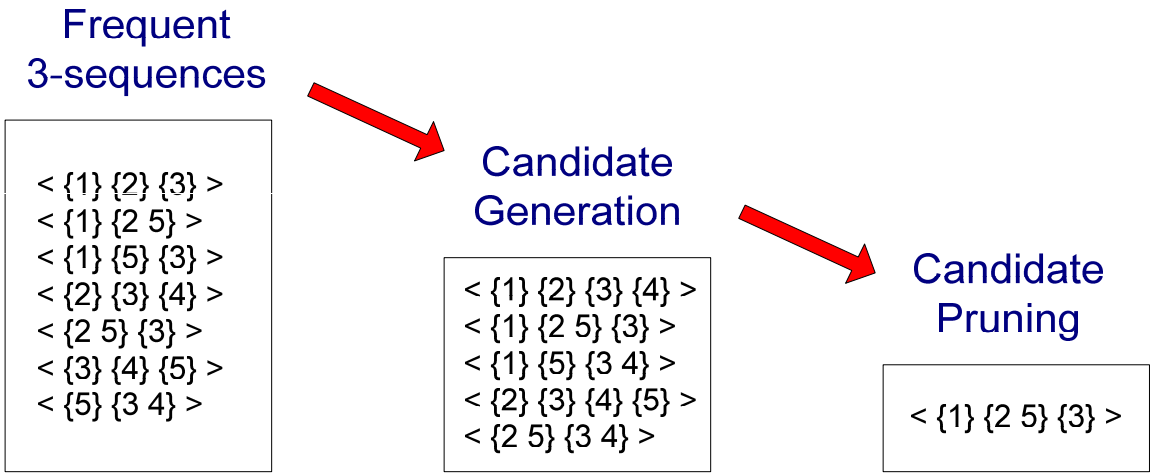

GSP [Generalized Sequential Patterns]

- Candidatos iniciales: "singleton sequences":
  <a>, <b>, <c>, <d>, <e>, <f>, <g>, <h>

- Recorrido inicial de la base de datos:
  Conteo del soporte de cada candidato

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

MinSupp =2

Cand	**Supp**
<a>	3
<b>	5
<c>	4
<d>	3
<e>	3
<f>	2
~~<g>~~	~~1~~
~~<h>~~	~~1~~

GSP [Generalized Sequential Patterns]

51 candidatos de tamaño 2 cumplen la propiedad Apriori

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

	<a>	<b>	<c>	<d>	<e>	<f>
<a>		<(ab)>	<(ac)>	<(ad)>	<(ae)>	<(af)>
<b>			<(bc)>	<(bd)>	<(be)>	<(bf)>
<c>				<(cd)>	<(ce)>	<(cf)>
<d>					<(de)>	<(df)>
<e>						<(ef)>
<f>						

Se poda el 44.57% de las 92 secuencias posibles (8*8+8*7/2)

GSP [Generalized Sequential Patterns]

5th scan:
1 cand. 1 length-5 seq. pat.

4th scan:
8 cand. 6 length-4 seq. pat.

3rd scan:
46 cand. 19 length-3 seq. pat.

2nd scan:
51 cand. 19 length-2 seq. pat.

1st scan:
8 cand. 6 length-1 seq. pat.

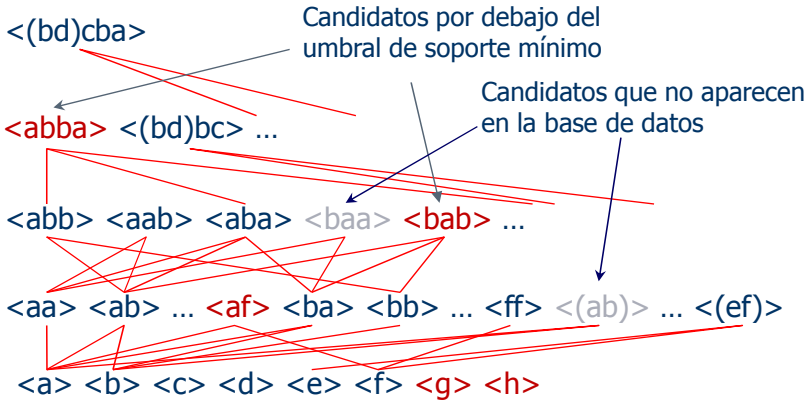

Seq. ID	Sequence
10	<(bd)cb(ac)>
20	<(bf)(ce)b(fg)>
30	<(ah)(bf)abf>
40	<(be)(ce)d>
50	<a(bd)bcb(ade)>

MinSupp =2

SPADE

Sequential PAttern Discovery using Equivalent Class [Zaki]

- Método de identificación de secuencias frecuentes basado en una representación vertical (tipo Eclat).
- La base de datos de secuencias se transforma en un conjunto enorme de items <SID, EID>.
- Las subsecuencias van creciendo usando el algoritmo de generación de candidatos de Apriori.

SPADE

SID	EID	Items
1	1	a
1	2	abc
1	3	ac
1	4	d
1	5	cf
2	1	ad
2	2	c
2	3	bc
2	4	ae
3	1	ef
3	2	ab
3	3	df
3	4	c
3	5	b
4	1	e
4	2	g
4	3	af
4	4	c
4	5	b
4	6	c

a		b		...
SID	EID	SID	EID	...
1	1	1	2	
1	2	2	3	
1	3	3	2	
2	1	3	5	
2	4	4	5	
3	2			
4	3			

ab			ba			...
SID	EID (a)	EID(b)	SID	EID (b)	EID(a)	...
1	1	2	1	2	3	
2	1	3	2	3	4	
3	2	5				
4	3	5				

aba				...
SID	EID (a)	EID(b)	EID(a)	...
1	1	2	3	
2	1	3	4	

GSP & SPADE

Limitaciones

- Se recorre la base de datos varias veces.
- Búsqueda en anchura [Breadth-first search].
  - Los patrones largos se construyen a partir de patrones más cortos, lo que obliga a considerar un número exponencial de candidatos.
  - Se genera un conjunto enorme de candidatos: 1000 patrones de tamaño 1 dan lugar a 1.5M patrones de tamaño 2.

$$1000 \times 1000 + \frac{1000 \times 999}{2} = 1{,}499{,}500$$

  - Descubrir una secuencia de tamaño 100 necesita considerar 10^{30} subsecuencias

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

PrefixSpan

Mining Sequential Patterns by Prefix Projections

Prefijos de una secuencia

Secuencia	<a(abc)(ac)d(cf)>
Prefijos	<a>, <aa>, <a(ab)>, <a(abc)>…

Prefix	Suffix (Prefix-Based Projection)
<a>	<(abc)(ac)d(cf)>
<aa>	<(_bc)(ac)d(cf)>
<ab>	<(_c)(ac)d(cf)>

PrefixSpan

Estrategia

Paso 1: Encontrar patrones secuenciales de longitud 1.

<a>, <b>, <c>, <d>, <e>, <f>

Paso 2: Dividir el espacio de búsqueda.

El conjunto completo de patrones secuenciales se puede dividir en 6 subconjuntos:

- Los patrones que tienen como prefijo <a>
- Los patrones que tienen como prefijo <b>
- …
- Los patrones que tienen como prefijo <f>

PrefixSpan

- Para encontrar los patrones con prefijo <a> sólo hay que considerar las proyecciones con respecto a <a>

Base de datos proyectada sobre <a>:
<(abc)(ac)d(cf)>
<(_d)c(bc)(ae)>
<(_b)(df)cb>
<(_f)cbc>

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

- A continuación, se identifican los patrones de longitud 2 que tienen <a> como prefijo:

<aa>, <ab>, <(ab)>, <ac>, <ad>, <af>

PrefixSpan

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

Patrones de secuenciales de longitud 1
<a>, <b>, <c>, <d>, <e>, <f>

Prefijo <a>

Prefijos <c>, …, <f>

Prefijo <b>

<a>-projected database
<(abc)(ac)d(cf)>
<(_d)c(bc)(ae)>
<(_b)(df)cb>
<(_f)cbc>

<b>-projected database

…

Patrones secuenciales
de longitud 2 con prefijos
<aa>, <ab>, <(ab)>,
<ac>, <ad>, <af>

… …

<aa>-proj. db … <af>-proj. db

Prefijo <aa> Prefijo <af>

PrefixSpan

Ventajas de PrefixSpan

- No se generan secuencias candidatas.
- Las proyecciones son cada vez más pequeñas.
- Pseudoproyecciones (punteros en memoria):

s=<a(abc)(ac)d(cf)>

↓ <a>

s|<a>: (, 2) <(abc)(ac)d(cf)>

↓ <ab>

s|<ab>: (, 4) <(_c)(ac)d(cf)>

PrefixSpan

Pseudoproyecciones

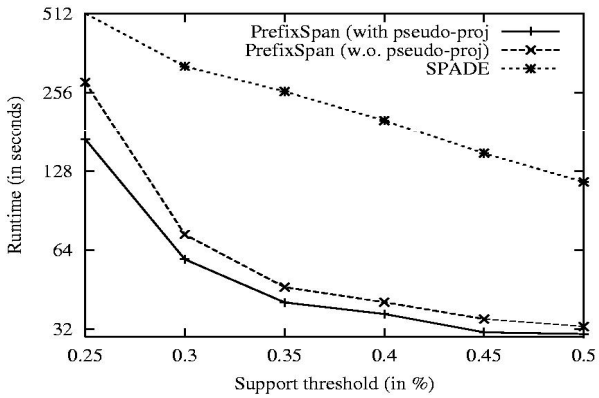

Performance comparison:
with pseudo-projection vs.
without pseudo-projection

PrefixSpan

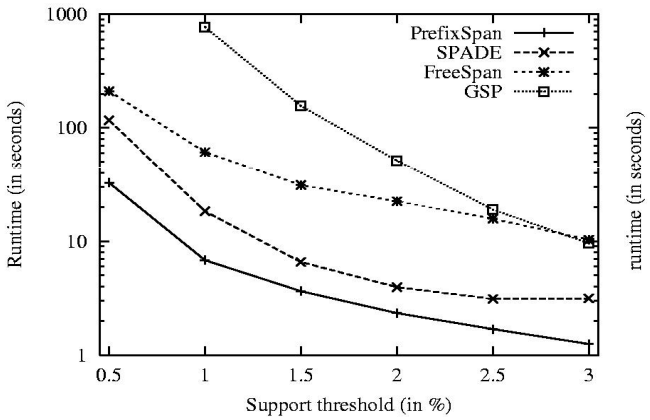

Performance comparison
on data set C10T8S8I8

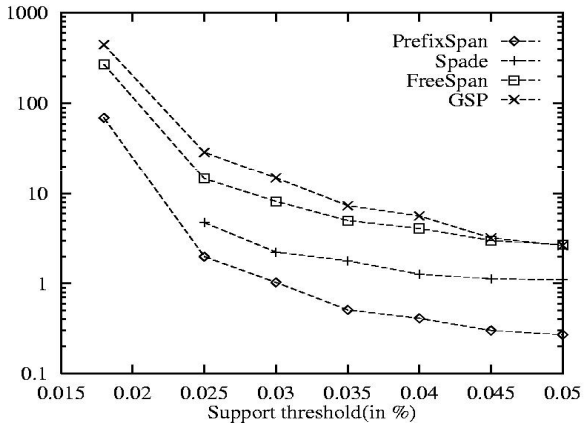

Performance comparison
on Gazelle data set

CloSpan

Mining Closed Sequential Patterns

- Un patrón secuencial s es cerrado si no existe otro patrón s' con el mismo soporte tal que $s \subset s'$.
- Identificar directamente patrones cerrados permite reducir el número de candidatos considerados.

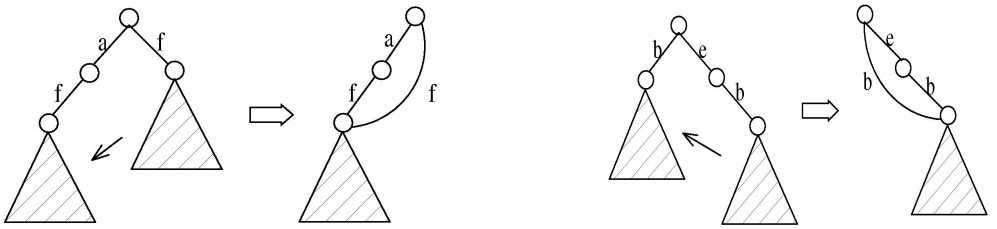

CloSpan

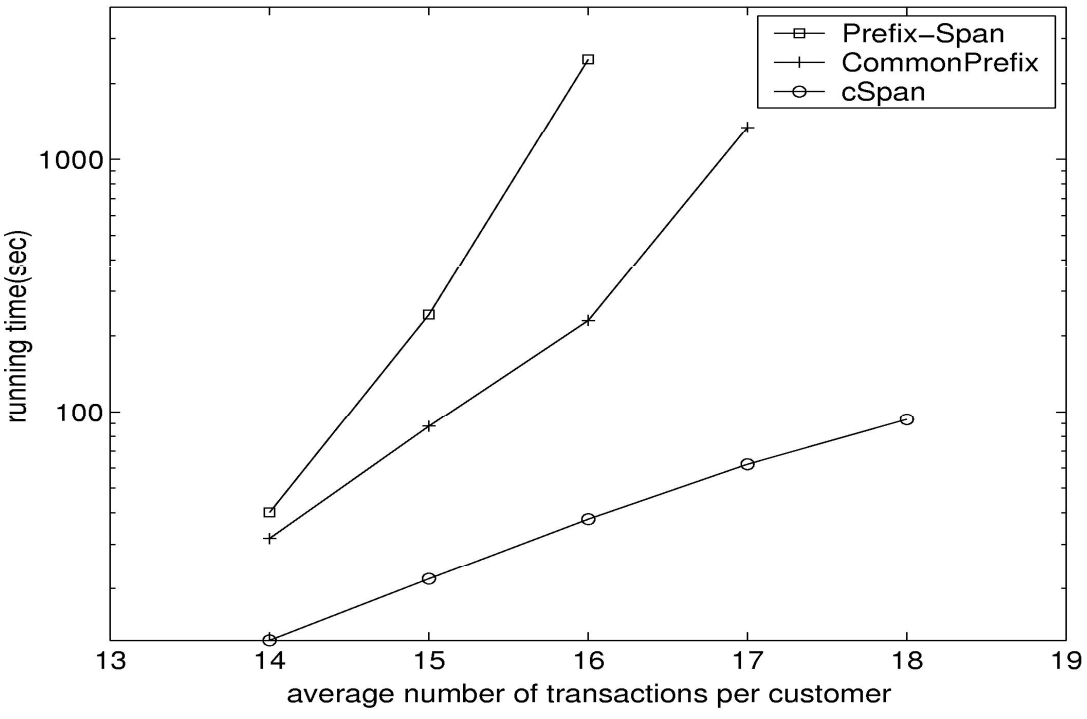

Restricciones

El uso de restricciones permite optimizar la exploración del espacio de patrones candidatos.

Clasificación de las restricciones

- **Anti-monótonas**: value_sum(S) < 150, min(S) > 10
- **Monótonas**: count (S) > 5, S $\supseteq$ {PC, digital_camera}
- **Sucintas:** length(S) $\geq$ 10, S $\in$ {Pentium, MS/Office}
- **Convertibles:** value_avg(S) < 25, profit_sum (S) > 160, max(S)/avg(S) < 2, median(S) – min(S) > 5
- **Inconvertibles:** avg(S) – median(S) = 0

Restricciones

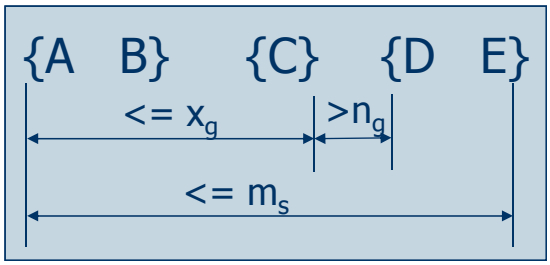

x_g: max-gap

n_g: min-gap

m_s: maximum span

$x_g = 2$, $n_g = 0$, $m_s = 4$

Secuencia de datos	Subsecuencia	¿Incluida?
< {2,4} {3,5,6} {4,7} {4,5} {8} >	< {6} {5} >	Sí
< {1} {2} {3} {4} {5}>	< {1} {4} >	No
< {1} {2,3} {3,4} {4,5}>	< {2} {3} {5} >	Sí
< {1,2} {3} {2,3} {3,4} {2,4} {4,5}>	< {1,2} {5} >	No

Restricciones

Identificación de patrones secuenciales con restricciones temporales

Estrategia 1

- Identificar patrones ignorando las restricciones.
- Postprocesar los patrones identificados.

Estrategia 2

- Modificar el algoritmo (p.ej. GSP) para podar los candidatos que no satisfacen las restricciones.

  ¡OJO! Hay que comprobar la propiedad Apriori…

Restricciones

Object	Timestamp	Events
A	1	1,2,4
A	2	2,3
A	3	5
B	1	1,2
B	2	2,3,4
C	1	1, 2
C	2	2,3,4
C	3	2,4,5
D	1	2
D	2	3, 4
D	3	4, 5
E	1	1, 3
E	2	2, 4, 5

x_g = 1 (max-gap)

n_g = 0 (min-gap)

m_s = 5 (maximum span)

MinSupp = 60%

<{2} {5}> support = 40%

<{2} {3} {5}> support = 60% !!!

La restricción max-gap
es la que causa el problema
(no posee la propiedad Apriori).

Restricciones

Modificación de la etapa de generación de candidatos

- **Sin** la restricción max-gap: Una k-secuencia candidata se elimina si al menos una de sus (k-1)-subsecuencias no es frecuente.
- **Con** la restricción max-gap: Una k-secuencia candidata se elimina si al menos una de sus (k-1)-subsecuencias contiguas no es frecuente.

Restricciones

Ejemplo: Subsecuencias contiguas

s = < {1} {2} >

- s es una subsecuencia contigua de
  < {1} {2 3}>
  < {1 2} {2} {3}>
  < {3 4} {1 2} {2 3} {4} >
- s no es una subsecuencia contigua de
  < {1} {3} {2}>
  < {2} {1} {3} {2}>

Restricciones

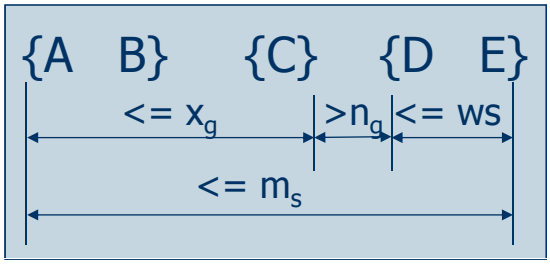

x_g: max-gap

n_g: min-gap

ws: window size

m_s: maximum span

x_g = 2, n_g = 0, ws = 1, m_s= 5

Secuencia de datos	Subsecuencia	¿Incluida?
< {2,4} {3,5,6} {4,7} {4,6} {8} >	< {3} {5} >	No
< {1} {2} {3} {4} {5}>	< {1,2} {3} >	Sí
< {1,2} {2,3} {3,4} {4,5}>	< {1,2} {3,4} >	Sí

Restricciones

Modificación de la fase de conteo del soporte

Dado un patrón candidato <{a, c}>, contribuirá al soporte del candidato cualquier secuencia que contenga

<… {a c} … >,

<… {a} … {c}…> con time({c}) – time({a}) ≤ ws

<… {c} … {a} …> con time({a}) – time({c}) ≤ ws

Restricciones

Distintas formas de calcular el soporte

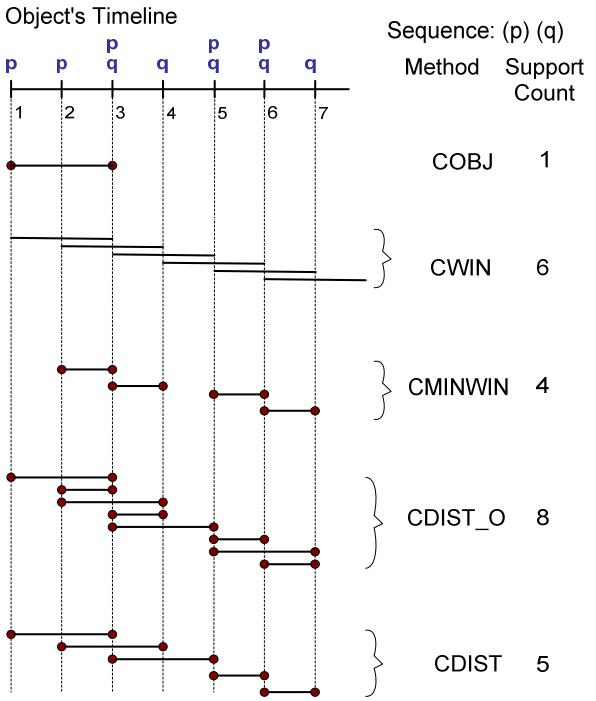

x_g = 2 (max-gap)

n_g = 0 (min-gap)

ws = 0 (window size)

m_s = 2 (maximum span)

SSMiner [Similar Sequence Miner]

Idea

- Generación de candidatos: Secuencias candidatas de k+1 elementos a partir de secuencias frecuentes de k elementos con k-1 elementos en común.

- Conteo del soporte: Listas de ocurrencias de cada secuencia frecuente en las que se preserva información acerca de la similitud entre patrones.

  NOTA: Sólo se lee el conjunto de datos **2 veces**.

SSMiner [Similar Sequence Miner]

Algoritmo

Obtain frequent elements (frequent patterns of size 1)
Build candidate classes C_1 from the frequent elements
for k=2 **to** MaxSize
  for each class $P \in C_{k-1}$
    for each element $p \in P$.
      Compute the frequency of p
      if p is frequent
      then
        Create a new class P' from p.
        Add P' **to** C_k

SSMiner [Similar Sequence Miner]

Listas de ocurrencias

Tuplas (t, m, p, d, Θ) asociadas a cada patrón

- t: Identificador de la secuencia.
- m: elementos de la secuencia que corresponden a los (k-1) elementos del prefijo del patrón.
- p: posición del último elemento en el patrón.
- d: parámetro utilizado para garantizar que los elementos del patrón son contiguos en la secuencia.
- Θ indica la similitud entre la ocurrencia y el patrón.

SSMiner [Similar Sequence Miner]

Listas de ocurrencias

Reunión de listas de ocurrencias

Let $(t_x, m_x, p_x, d_x, \Theta_x)$ and $(t_y, m_y, p_y, d_y, \Theta_y)$ be two tuples to be joined.

if

1. $t_x = t_y = t$ **and**
2. $m_x = m_y = m$ **and**
3. $d_x = 1$ (only if $k \neq 2$) **and**
4. $p_x < p_y$ **and**
5. $\Theta_x = \Theta_y$

then add $[t, m \bigcup \{p_x\}, p_y, d_y - d_x, \Theta_y]$ to the occurrence list

SSMiner [Similar Sequence Miner]

Eficiencia

$$O(L^K * n * (S - K + 1)^2)$$

L	Número de items frecuentes
K	Tamaño máximo de los patrones
n	Número de secuencias
S	Longitud de las secuencias

- Lineal con respecto al número de secuencias.
- Cuadrático con respecto a su longitud.
- Proporcional al número de patrones considerados.

SSMiner [Similar Sequence Miner]

Aplicación: Patrones musicales

- Una melodía puede verse como una secuencia de elementos musicales.
- "Motivo" [motif]:
  Elemento melódico más pequeño con significado.
- La identificación de "motivos" frecuentes puede servir…
  … para descubrir automáticamente el estribillo.
  … para crear miniaturas [audio-thumbnailing].
  … para indexar grandes bases de datos de canciones.

SSMiner [Similar Sequence Miner]

Ejemplo

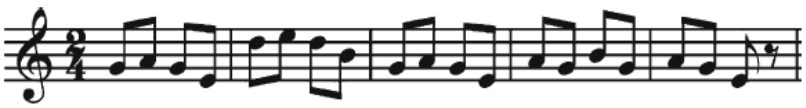

G4	A4	E4	D5	E5	B4
{1,_,1,1,=}	{1,_,2,2,=}	{1,_,4,4,=}	{1,_,5,5,=}	{1,_,6,6,=}	{1,_,8,8,=}
{1,_,3,3,=}	{1,_,10,10,=}	{1,_,12,12,=}	{1,_,7,7,=}		{1,_,15,15,=}
{1,_,9,9,=}	{1,_,13,13,=}	{1,_,19,19,=}			
{1,_,11,11,=}	{1,_,17,17,=}	{1,_,8,8,+5}			
{1,_,14,14,=}	{1,_,6,6,+5}	{1,_,15,15,+5}			
{1,_,16,16,=}					
{1,_,18,18,=}					
{1,_,5,5,+5}					
{1,_,7,7,+5}					

Secuencia

G4 A4 G4 E4 D5 E5 D5 B4 G4 A4 G4 E4 A4 G4 B4 G4 A4 G4 E4

SSMiner [Similar Sequence Miner]

Ejemplo

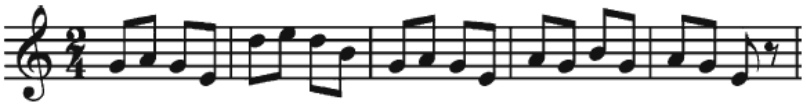

Prefix: G4

G4 G4

{1,1,3,2,=}
{1,1,11,10,=}
{1,1,16,15,=}
{1,3,9,6,=}
{1,3,14,11,=}
{1,3,18,15,=}
{1,9,14,5,=}
{1,9,18,9,=}
{1,11,16,5,=}
{1,14,16,2,=}
{1,16,18,2,=}
{1,1,9,8,=}
{1,1,14,13,=}
{1,1,18,17,=}
{1,3,11,8,=}
{1,3,16,13,=}
{1,9,11,2,=}
{1,9,16,7,=}
{1,11,14,3,=}
{1,11,18,7=}
{1,14,18,4,=}
{1,5,7,2,+5}

G4 A4

{1,1,2,1,=}
{1,1,13,12,=}
{1,3,10,7,=}
{1,3,17,14,=}
{1,9,13,4,=}
{1,11,13,2,=}
{1,14,17,3,=}
{1,5,6,1,+5}
{1,1,10,9,=}
{1,1,17,16,=}
{1,3,13,10,=}
{1,9,10,1,=}
{1,9,17,8,=}
{1,11,17,6,=}
{1,16,17,1,=}

G4 E4

{1,1,4,3,=}
{1,1,19,18,=}
{1,3,12,9,=}
{1,9,12,3,=}
{1,11,12,1,=}
{1,14,19,5,=}
{1,18,19,1,=}
{1,5,15,10,+5}
{1,7,15,8,+5}
{1,1,12,11,=}
{1,3,4,1,=}
{1,3,19,16,=}
{1,9,19,10,=}
{1,11,19,8,=}
{1,16,19,3,=}
{1,5,8,3,+5}
{1,7,8,1,+5}

Secuencia

G4 A4 G4 E4 D5 E5 D5 B4 G4 A4 G4 E4 A4 G4 B4 G4 A4 G4 E4

SSMiner [Similar Sequence Miner]

Aplicación: Patrones musicales

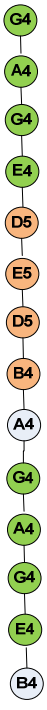

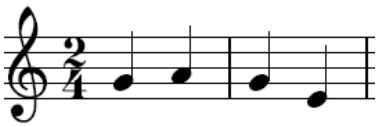

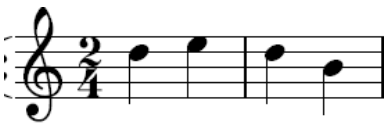

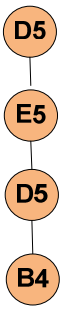

Exact Pattern

Similar Pattern

SSMiner [Similar Sequence Miner]

Aplicación: Patrones musicales

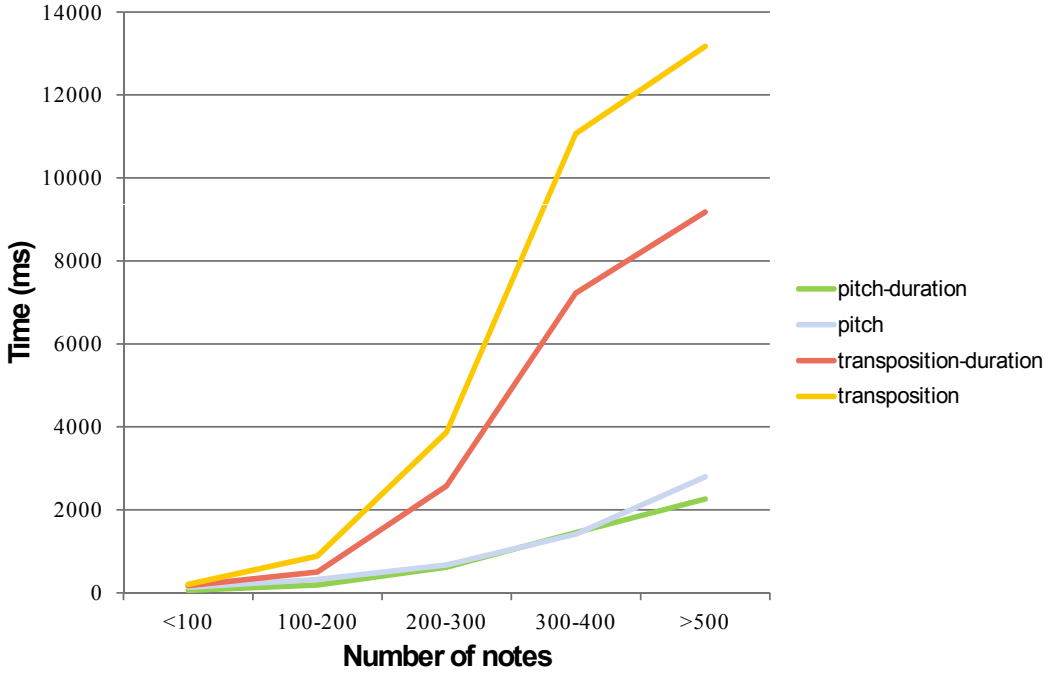

Algoritmos

Derivados de Apriori

Candidate Generation: Horizontal Database Format		
Apriori (All, Some, Dynamic Some)	[Agrawal and Srikant]	1995
Generalised Sequential Patterns (GSP)	[Srikant and Agrawal]	1996
PSP	[Masseglia et al.]	1998
Sequential Pattern mIning with Regular expressIon consTraints (SPIRIT)	[Garofalakis et al.]	1999
Maximal Frequent Sequences (MFS)	[Zhang et al.]	2001
Regular Expression-Highly Adaptive Constrained Local Extractor (RE-Hackle)	[Albert-Lorincz and Boulicaut]	2003
Maximal Sequential Patterns using Sampling (MSPS)	[Luo and Chung]	2004
Candidate Generation: Vertical Database Format		
Sequential PAttern Discovery using Equivalence classes (SPADE)	[Zaki]	2001
Sequential PAttern Mining (SPAM)	[Ayres et al.]	2002
LAst Position INduction (LAPIN)	[Yang and Kitsuregawa]	2004
Cache-based Constrained Sequence Miner (CCSM)	[Orlando et al.]	2004
Indexed Bit Map (IBM)	[Savary and Zeitouni]	2005
LAst Position INduction Sequential PAttern Mining (LAPIN-SPAM)	[Yang and Kitsuregawa]	2005

Derivados de FP-Growth

Algorithm Name	Author	Year
Pattern Growth		
FREquEnt pattern-projected Sequential PAtterN mining (FreeSpan)	[Han et al.]	2000a
PREFIX-projected Sequential PAtterN mining (PrefixSpan)	[Pei et al.]	2001b
Sequential pattern mining with Length-decreasing suPport (SLPMiner)	[Seno and Karypis]	2002

Algoritmos paralelos

ACME	Advanced Parallel Motif Extractor
DGSP	Distributed GSP
DPF	Data Parallel Formulation
EVE	Event Distribution
EVECAN	Event and Candidate Distribution
HPSPM	Hash Partitioned Sequential Pattern Mining
MG-FSM	Large-Scale Frequent Sequence Mining
NPSPM	Non-Partitioned Sequential Pattern Mining
Par-ASP	Parallel PrefixSpan with Sampling
Par-CSP	Parallel CloSpan with Sampling
PLUTE	Parallel Sequential Patterns Mining
pSPADE	Parallel SPADE

Bibliografía

- Charu C. Aggarwal & Jiawei Han(editors):
  Frequent Pattern Mining.
  Springer, 2014.
  ISBN 3319078208.

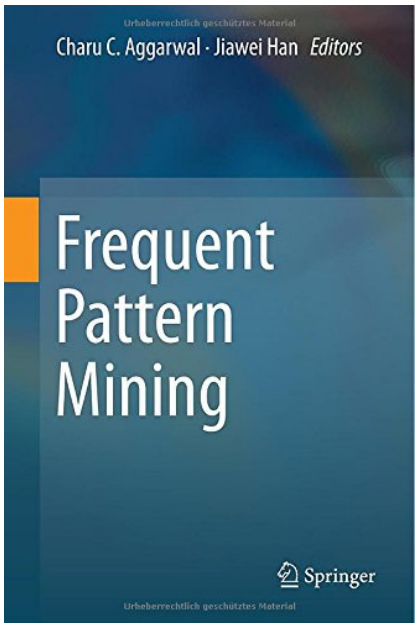

Bibliografía

- Pang-Ning Tan,
  Michael Steinbach
  & Vipin Kumar:
  Introduction to Data Mining
  Addison-Wesley, 2006.
  ISBN 0321321367 [capítulos 6&7]

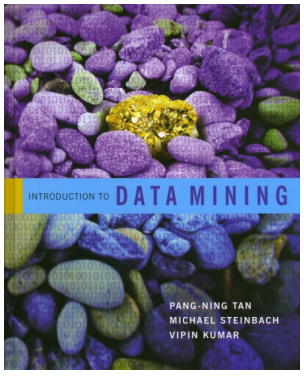

- Jiawei Han
  & Micheline Kamber:
  Data Mining:
  Concepts and Techniques
  Morgan Kaufmann, 2006.
  ISBN 1558609016 [capítulo 5]

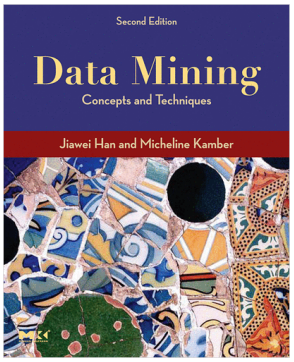

Bibliografía – Algoritmos

Algoritmo original (tipo Apriori)

- Rakesh Agrawal & Ramakrishnan Srikant: **Mining Sequential Patterns**. In Proceedings of the Eleventh International Conference on Data Engineering (ICDE '95), pp. 3-14. ISBN 0-8186-6910-1.

GSP [Generalized Sequential Patterns]

- Ramakrishnan Srikant & Rakesh Agrawal: **Mining Sequential Patterns: Generalizations and Performance Improvements**. In Proceedings of the 5th International Conference on Extending Database Technology: Advances in Database Technology (EDBT '96), pp. 3-17. ISBN 3-540-61057-X.

SPADE [Sequential PAttern Discovery using Equivalent Class]

- Mohammed J. Zaki: **SPADE: an efficient algorithm for mining frequent sequences**. Machine Learning 42(1/2):31-60, January 2001. DOI 10.1023/A:1007652502315

SSMiner [Similar Sequence Miner]

- Aída Jiménez, Miguel Molina-Solana, Fernando Berzal & Waldo Fajardo: **Mining transposed motifs in music**. Journal of Intelligent Information Systens 36(1):99-115, February 2011. DOI 10.1007/s10844-010-0122-7

Bibliografía – Algoritmos

FreeSpan

- Jiawei Han, Jian Pei, Behzad Mortazavi-Asl, Qiming Chen, Umeshwar Dayal & Mei-Chun Hsu: **FreeSpan: Frequent pattern-projected sequential pattern mining**. Proceedings of the 6th ACM SIGKDD International Conference on Knowledge discovery and Data Mining (KDD '00), pp. 355-359. DOI 10.1145/347090.347167.

PrefixSpan

- Jian Pei, Jiawei Han, Behzad Mortazavi-Asl, Helen Pinto, Qiming Chen, Umeshwar Dayal & Meichun Hsu: **PrefixSpan: Mining Sequential Patterns by Prefix-Projected Growth**. Proceedings of the 17th International Conference on Data Engineering (ICDE'2001), pp. 215-224. DOI 10.1109/ICDE.2001.914830
- Jian Pei, Jiawei Han, Behzad Mortazavi-Asl, Jianyong Wang, Helen Pinto, Qiming Chen, Umeshwar Dayal & Mei-Chun Hsu: **Mining Sequential Patterns by Pattern-Growth: The PrefixSpan Approach**. IEEE Transactions on Knowledge and Data Engineering 16(11): 1424-1440, November 2004. DOI 10.1109/TKDE.2004.77

IncSpan

- Hong Cheng, Xifeng Yan & Jiawei Han: **IncSpan: incremental mining of sequential patterns in large database**. Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '04), pp. 527-532. DOI 10.1145/1014052.1014114

Bibliografía – Algoritmos

CloSpan

- Xifeng Yan, Jiawei Han & Ramin Afshar: **CloSpan: Mining closed sequential patterns in large databases**. SIAM International Conference on Data Mining (SDM'2003)

BIDE [BI-Directional Extension]

- Jianyong Wang & Jiawei Han: **BIDE: Efficient Mining of Frequent Closed Sequences**. Proceedings of the 20th International Conference on Data Engineering (ICDE '04), pp. 79-90. DOI 10.1109/ICDE.2004.1319986

Par-CSP [Parallel CloSpan with samPling]

- Shengnan Cong, Jiawei Han & David Padua: **Parallel mining of closed sequential patterns**. Proceedings of the 11th ACM SIGKDD international conference on Knowledge Discovery in Data Mining (KDD '05), pp. 562-567. DOI 10.1145/1081870.1081937

MG-FSM [Mind the Gap – Frequent Sequence Mining]

- Iris Miliaraki, Klaus Berberich, Rainer Gemulla & Spyros Zoupanos: **Mind the gap: large-scale frequent sequence mining**. Proceedings of the 2013 ACM SIGMOD International Conference on Management of Data (SIGMOD '13), pp. 797-808. DOI 10.1145/2463676.2465285

Bibliografía

pSPADE [Parallel SPADE]

- Mohammed J. Zaki: **Parallel sequence mining on shared-memory machines**. Journal of Parallel and Distributed Computing 61(3):401-426, March 2001. DOI 10.1006/jpdc.2000.1695

Patrones secuenciales con restricciones

- Minos N. Garofalakis, Rajeev Rastogi & Kyuseok Shim: **SPIRIT: Sequential Pattern Mining with Regular Expression Constraints**. Proceedings of the 25th International Conference on Very Large Data Bases (VLDB '99), pp. 223-234. ISBN 1-55860-615-7
- Jian Pei, Jiawei Han & Wei Wang: **Mining sequential patterns with constraints in large databases**. Proceedings of the 11th International Conference on Information and Knowledge Management (CIKM '02), pp. 18-25. DOI 10.1145/584792.584799

Survey

- Carl H. Mooney and John F. Roddick. 2013. **Sequential pattern mining -- approaches and algorithms**. ACM Computing Surveys 45, 2, Article 19, March 2013, 39 pages. DOI 10.1145/2431211.2431218

Apéndice: Episodios

Patrones secuenciales alternativos

Episodios y expresiones regulares

- Episodios secuenciales: A → B
- Episodios paralelos: A & B
- Expresiones regulares: (A|B)C*(D → E)

Algoritmos para la identificación de patrones episódicos:

- Variaciones de Apriori/GSP
- Extensiones de FP-Growth:
  "Projection-based pattern growth"

Apéndice: Episodios

En dominios en los que se tiene una única secuencia,
p.ej. Monitorización del tráfico de una red

Objetivo

Encontrar secuencias frecuentes de eventos, también conocidas como episodios [episodes].

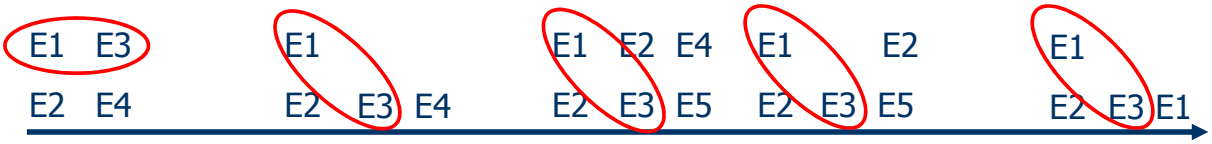

Patrón < {E1} {E3} >