


# Vertikális felosztás

**Definíció:** Adott egy  $r$  reláció. Annak  $F_r = \{r_1, r_2, \dots, r_n\}$  a felosztása, ahol minden  $r_i = \prod_{x_i \cup K} r$  ( $x_i$  azon attribútumok halmaza, amiket  $r_i$ -ben látni szeretnénk,  $K$   $r$  elsődleges kulcsa)

s:

<u>ID</u>	név	cím	telszám



$$X_1 \quad X_2 \quad \Rightarrow \quad S_1 = \prod_{x_1 \cup K} S = \prod_{ID, név} S$$

$$S_2 = \prod_{x_2 \cup K} S = \prod_{cím, telszám, ID} S$$

A felosztás célja, hogy olyan attribútumok kerüljenek egy töredékbe, melyeket gyakran kérdezzük le egyszerre. A kulcsok minden töredékbe bele kell tenni, hiszen az alapján tudjuk majd újra összeilleszteni a teljes relációt.

## Particionáló algoritmus

Bemenetek:

$Q = \{q_1, \dots, q_q\}$  lekérdezések halmaza

$R = (A_1, \dots, A_n)$  felosztandó  $r$  reláció sémája

$use(q_j, A_j) = \begin{cases} 1, & \text{ha } q_j \text{ lekérdezés használja } A_j \text{ attribútumot} \\ 0 & \text{egyébként} \end{cases}$

(használati indikátor)

$acc(q_k) = q_k$  futási gyakorisága (olyan attribútumokat akarunk egy halmazba rakni, amiket gyakran használunk együtt)

$aff(A_i, A_j) = \text{affinitás} = \sum_{k: use(q_k, A_i)=1 \wedge use(q_k, A_j)=1} acc(q_k)$

(összefüggőségi mérték)

milyen gyakran hivatkozzák lekérdezések a 2 attribútumot együttesen ( $A_i$  és  $A_j$  konstans időintervallumon belül hányszor vagy milyen gyakran hivatkozik együtt)

$[aff(A_i, A_j)] \rightarrow$  összefüggőségi mátrix

$$\begin{array}{c}
 \begin{array}{ccc}
 & A_1 & \dots & A_n \\
 A_1 & [aff(A_1, A_1) & \dots & aff(A_1, A_n)] \\
 & \vdots & \ddots & \vdots \\
 A_n & [aff(A_n, A_1) & \dots & aff(A_n, A_n)]
 \end{array}
 =
 \begin{array}{ccc}
 & A_1 & \dots & A_n \\
 [a(1,1) & \dots & a(1,n)] \\
 \vdots & \ddots & \vdots \\
 [a(n,1) & \dots & a(n,n)]
 \end{array}
 \end{array}$$

## Algoritmus

- I. **Mátrix létrehozása (affinitás mátrix)**
- II. **Mátrix oszlopainak permutálása**
- III. **Sorok átrendezése oszlopnak megfelelően**
- IV. **Felosztási pont meghatározása**

II. lépésnél a cél a globális összefüggőségi mérték (AM = affinity measure) maximalizálása

$bond(i,j) =$  i. és j. oszlop szorzatösszege

$$AM^* = \sum_{i=1}^n \sum_{j=1}^n a(i,j)[a(i,j-1) + a(i,j+1) + a(i-1,j) + a(i+1,j)]$$

$$a(0,j) = a(i,0) = a(n+1,j) = a(i,n+1) = 0$$

A globális összefüggőségi mátrix ortogonálisan szimmetrikus, ezt kihasználva szépen le lehet vezetni, hogy:

$$AM = \sum_{j=1}^n [bond(j,j-1) + bond(j,j+1)]$$

90	80	1	2
80	70	3	4
1	3	60	50
2	4	50	40

„Szuboptimális” oszlopsorrendet határozunk meg, ami lehet, hogy nem a legjobb, de legalább emberi időben számítható.

## Algoritmus (oszloppermutáció)

1. **Rögzítjük a mátrix 1. oszlopát**

2.  $i$  oszlop beszúrása után a maradékból az  $i+1$ . oszlop kiválasztása, bepróbáljuk a lehetséges  $i+1$  db pozícióba úgy, hogy beszúrással a legnagyobb javítást érjük el AM metrika mértékében
3. A 2. lépés ismétlése, míg kész nem vagyunk.

### Javítás

Tegyük fel, hogy a jelenlegi állapot:

$$A_1, \dots, A_{i-1}, A_i, A_j, A_{j+1}, \dots, A_n$$

$AM'$                        $AM''$                       a globális összefüggőség mértéke

$A_k$ -t szeretnénk beszúrni  $A_i$  és  $A_j$  közé.


$$AM \text{ régi} = AM' + AM'' + \overbrace{\text{bond}(i-1,i) + \text{bond}(i,j)}^{A_i \text{ miatt}} + \underbrace{\text{bond}(i,j) + \text{bond}(j,j+1)}_{A_j \text{ miatt}}$$

$$AM \text{ új} = AM' + AM'' + \underbrace{\text{bond}(i-1,i) + \text{bond}(i,k)} + \underbrace{\text{bond}(i,k) + \text{bond}(k,j)} + \underbrace{\text{bond}(k,j) + \text{bond}(j,j+1)}$$

$$\text{Javítás}^* = AM \text{ új} - AM \text{ régi} = 2 * \text{bond}(i,k) + 2 * \text{bond}(k,j) - 2 * \text{bond}(i,j)$$

$$\text{Javítás} = \text{Javítás}^* / 2 = \text{bond}(i,k) + \text{bond}(k,j) - \text{bond}(i,j)$$

### Osztópontkeresés



Cél: a főátló mentén találjunk egy pontot az  $i$ . és az  $i+1$ . sor/oszlop között, amelyre a metrika maximális. (olyan osztópontot találjunk, hogy a két töredéklerációra lekérdezések diszjunkt halmazai hivatkozzanak)

$$TA = \{A_1, \dots, A_i\}$$

$$BA = \{A_{i+1}, \dots, A_n\}$$

Cél: egy töredékhez való (lekérdezések általi) hozzáférések száma -> maximális  
 több töredékhez való (lekérdezések általi) hozzáférések száma -> minimális

### Definíciók

Adott  $Q$  lekérdezhalmaz,  $Q = \{q_1, q_2, \dots, q_q\}$

$AQ(q_i) = \{A_j \mid use(q_i, A_j) = 1\}$  (azon attribútumok halmaza, amiket használ)

$TQ = \{q_i \mid AQ(q_i) \subseteq TA\}$  (azon lekérdezések, amelyek attribútumai TA-ban vannak)

$BQ = \{q_i \mid AQ(q_i) \subseteq BA\}$  (azon lekérdezések, amelyek attribútumai BA-ban vannak)

$OQ = Q \setminus (TQ \cup BQ)$

#### Költségfüggvények

$CTQ = \sum_{q \in TQ} acc(q)$  } az a jó, ha ezek minél nagyobbak  
 $CBQ = \sum_{q \in BQ} acc(q)$  }  
 $COQ = \sum_{q \in OQ} acc(q)$  } cél, hogy minél kisebb legyen

**Célfüggvény:  $\max[CTQ * CBQ - COQ^2]$**

# Példa

## (Vertikális felosztás)

Adott:

- $R(A, B, C, D)$  séma,  $r(R)$  reláció
- $Q = \{q_1, q_2, q_3, q_4\}$ 
  - $q_1 = \sigma_{C>A}r$        $\text{acc}(q_1) = 20$
  - $q_2 = \pi_B \sigma_{C>3}r$        $\text{acc}(q_2) = 10$
  - $q_3 = \pi_{B,D}r$        $\text{acc}(q_3) = 5$
  - $q_4 = \pi_{C,D}r$        $\text{acc}(q_4) = 15$

### I. Mátrix létrehozása (affinitás mátrix)

	A	B	C	D
A	20	0	20	0
B	0	15	10	5
C	20	10	45	15
D	0	5	15	20

$\text{aff}(A,B) = 0$ , mivel egyik lekérdezés sem használja A-t és B-t együtt

$\text{aff}(A,A) = \text{acc}(q_1)$ , mivel csak  $q_1$  használja A-t

$\text{aff}(B,B) = \text{acc}(q_2) + \text{acc}(q_3) = 10+5=15$ ,  
mivel  $q_2$  és  $q_3$  használja B-t

...

### II. Mátrix oszlopainak permutálása

Rögzítjük az első sort, A-t. Utána beszúrjuk mellé B-t (mindegy, hogy melyik oldalra, legfeljebb tükörképe lesz egyik megoldás a másikkak).

Ezután majd próbáljuk beszúrni C-t, ami a következő oszlop. Ezt 3 helyre tehetjük meg ( a szélső oszlopoknál mindig 0-val számolunk):

	A	B		
0	20	0	0	
0	0	15	0	
0	20	10	0	
0	0	5	0	
	I	II	III	

I	II	III
C A	A C B	B C
0 20 20	20 20 0	0 20 0
0 10 0	0 10 15	15 10 0
0 45 20	20 45 10	10 45 0
0 15 0	0 15 5	5 15 0

$$\text{Javítás}_I = \text{bond}(0,C) + \text{bond}(C,A) - \text{bond}(0,A) = 0 + 1300 + 0 = 1300$$

$$\text{Javítás}_{II} = \text{bond}(A,C) + \text{bond}(C,B) - \text{bond}(A,B) = 1300 + 675 - 200 = \underline{\underline{1775}}$$

$$\text{Javítás}_{III} = \text{bond}(B,C) + \text{bond}(C,0) - \text{bond}(B,0) = 675 + 0 - 0 = 675$$

A legnagyobb javítás a II-es, 1775-tel, így C-t A és B közé szúrjuk be. Ezután jön a D oszlop.

	A	C	B	
0	20	20	0	0
0	0	10	15	0
0	20	45	10	0
0	0	15	5	0
	↙	↙	↙	↙
	I	II	III	IV

I	II	III	IV
D A	A D C	C D B	B D
0 0 20	20 0 20	20 0 0	0 0 0
0 5 0	0 5 10	10 5 15	15 5 0
0 15 20	20 15 45	45 15 10	10 15 0
0 20 0	0 20 15	15 20 5	5 20 0

$$\text{Javítás}_I = \text{bond}(0,D) + \text{bond}(D,A) - \text{bond}(0,A) = 0 + 300 - 0 = 300$$

$$\text{Javítás}_{II} = \text{bond}(A,D) + \text{bond}(D,C) - \text{bond}(A,C) = 300 + 1025 - 1300 = 25$$

$$\text{Javítás}_{III} = \text{bond}(C,D) + \text{bond}(D,B) - \text{bond}(C,B) = 1025 + 325 - 675 = \underline{\underline{675}}$$

$$\text{Javítás}_{IV} = \text{bond}(B,D) + \text{bond}(D,0) - \text{bond}(B,0) = 325 + 0 - 0 = 325$$

A legnagyobb javítás a III-as, 675-tel, így D-t C és B közé szúrjuk be.

Így a végleges oszlopsorrend: A, C, D, B. Ennek megfelelően rendezzük a sorokat is.

### III. Sorok átrendezése oszlopnak megfelelően

	A	C	D	B
A	20	20	0	0
C	20	45	15	10
D	0	15	20	5
B	0	10	5	15

### IV. Felosztási pont meghatározása

A végleges, átrendezett mátrixban 3 ponton lehet az osztópont:

	A	C	D	B
A	20	20	0	0
C	20	45	15	10
D	0	15	20	5
B	0	10	5	15

I.

$$\begin{array}{lll}
 TA = \{A\} & TQ = \{ \} & CTQ * CBQ - COQ^2 = -400 \\
 BA = \{C, D, B\} & BQ = \{q_2, q_3, q_4\} & (0 * 30 - 20^2) \\
 & OQ = \{q_1\} &
 \end{array}$$

II.

$$\begin{array}{lll}
 TA = \{A, C\} & TQ = \{q_1\} & CTQ * CBQ - COQ^2 = -525 \\
 BA = \{D, B\} & BQ = \{q_3\} & (20 * 5 - 25^2) \\
 & OQ = \{q_2, q_4\} &
 \end{array}$$

III.

$$\begin{array}{lll}
 TA = \{A, C, D\} & TQ = \{q_1, q_4\} & CTQ * CBQ - COQ^2 = \underline{\underline{-225}} \\
 BA = \{B\} & BQ = \{ \} & (35 * 0 - 15^2) \\
 & OQ = \{q_2, q_3\} &
 \end{array}$$

A maximális összeget, vagyis a -225-öt úgy kapjuk meg, ha a harmadik helyre hozunk létre osztópontot.

Így végül a kapott két részséma:  $R_1(\underline{A}, C, D)$  és  $R_2(\underline{A}, B)$ .