

# Structures de données avancées :

## *MLH (Multidimensional linear hashing)*

Pr ZEGOUR DJAMEL EDDINE  
Ecole Supérieure d'Informatique (ESI)  
[www.zegour.univ.dz](http://www.zegour.univ.dz)  
email: [d\\_zegour@esi.dz](mailto:d_zegour@esi.dz)

## Hachage linéaire multidimensionnel

### ***Considérations***

- Soit  $K = D_0 \times D_1 \times \dots \times D_{d-1}$  l'espace des clés  
 $D_i$  est le domaine correspondant à l'attribut  $A_i$ .
- Une clé  $k = (k_0, k_1, \dots, k_{d-1})$  peut être vue comme un vecteur dans un espace D-dimensionnel, où chaque axe correspond à un attribut différent.

## Hachage linéaire multidimensionnel

### *Principe de la méthode*

- Appliquer LH consécutivement sur chaque axe
- Chaque division dépend seulement de l'axe courant.
- Les N premières collisions sont résolues selon uniquement l'axe 0 (comme si les clés ne sont composées que d'une seule composante  $k_0$ )
- En général,  $N=1$  au départ
- En fin de cette séquence de division, le nombre de cases double.

## Hachage linéaire multidimensionnel

### *Principe de la méthode*

- Par la suite, si des collisions apparaissent, elles sont résolues le long de l'axe 1, jusqu'à ce que le fichier double de nouveau.
- Etc.
- Pour chaque séquence, on éclate à partir de la case 0.  
Pour chaque séquence, le niveau est incrémenté
- La case rajoutée est donnée par  $P + 2^l$  (Si  $N=1$ , Sinon  $P + 2^l \cdot N$ )

P : pointeur de la case à éclater  
l : niveau de la fonction

## Hachage linéaire multidimensionnel

### *Remarques importantes*

- En général, le prochain axe sur lequel les éclatements sont réalisés est déterminé de manière cyclique :  $(i+1) \text{ Mod } d$   
( $i$  est l'axe courant,  $d$  : nombre de dimensions)
- Dans la formule  $P + 2^l$ ,  $2^l$  représente la taille du fichier avant les éclatements le long d'un axe donné.
- A la fin d'un cycle ( $d$  séquences d'éclatements), l'espace des adresses est incrémenté par un facteur de  $2^d$ .  
(au départ c'est  $1.N$ , après axe 1 :  $2^1N$ , après axe 2 :  $2^2N$ , ...).

## Hachage linéaire multidimensionnel

### *Propriété*

- Si  $l$  désigne le nombre total de séquences de divisions réalisées sur tous les axes, alors
 
$$l = Ld + r$$
 $L$  : nombre de cycles
- L'ensemble des cases a été éclaté  $(L+1)$  fois le long des axes  $\{0, 1, \dots, r-1\}$  et  $L$  fois le long des axes  $\{r, \dots, d-1\}$

## Hachage linéaire multidimensionnel

### *Fonction de hachage*

- Supposons  $N = 1$  ( au départ ) et  $I_i = \{0, 1, \dots, 2^i - 1\}$
- $H_l$ , pour le niveau  $l$  (avec  $l = Ld+r$ ) , sera définie comme une fonction de  $D_0 \times D_1 \times \dots \times D_{d-1} \rightarrow R_0 \times R_1 \times \dots \times R_{d-1}$  avec

$$R_i = I_{L+1} \text{ pour } i < r \text{ et}$$

$$R_i = I_L \text{ pour } i \geq r$$

## Hachage linéaire multidimensionnel

### *Fonction de hachage*

- Pour une clé  $k$ ,

$$H_l(k) = (h_{L+1}(k_0), h_{L+1}(k_1), \dots, h_{L+1}(k_{r-1}), h_L(k_r), \dots, h_L(k_{d-1}))$$

- La prochaine séquence de division s'effectuera le long de l'axe  $r$ , on utilisera alors :

$$H_{l+1}(k) = (h_{L+1}(k_0), h_{L+1}(k_1), \dots, h_{L+1}(k_{r-1}), h_{L+1}(k_r), h_L(k_{r+1}), \dots, h_L(k_{d-1}))$$

## Hachage linéaire multidimensionnel

### *Fonctions de division*

$H_1, H_2, \dots$  sont des fonctions de division pour MLH si elles satisfont la condition de rang suivante

$$H_l : K \rightarrow \{0, 1, \dots, 2^l - 1\} \text{ (par projection)}$$

## Hachage linéaire multidimensionnel

### *Fonctions de division*

$H_1, H_2, \dots$  sont des fonctions de division pour MLH si elles satisfont la condition de division suivante:

Pour chaque niveau  $l$  du fichier avec  $l = L d + r$  et pour chaque clé  $k$  de  $K$  :

$$H_{l+1}(k) = H_l(k) \text{ ou bien}$$

$$\begin{aligned} H_{l+1}(k) &= (h_{L+1}(k_0), \dots, h_{L+1}(k_{r-1}), h_L(k_r) + 2^L, h_L(k_{r+1}), \dots, h_L(k_{d-1})) \\ &= H_l(k) + (0, 0, \dots, 2^L, 0, 0, \dots) \end{aligned}$$

Noter que :  $h_{L+1}(k_r) = h_L(k_r) + 2^L$

## Hachage linéaire multidimensionnel

### Exemple ( Dimension $d = 2$ )

- Les divisions sont contrôlées par le facteur de chargement  $\alpha$

$$\alpha = n / (s \cdot b + s' \cdot b')$$

$n$  : nombre d'articles insérés

$s$  : nombre de cases primaires

$s'$  : nombre de cases en débordement

$b$  : capacité case primaire

$b'$  : capacité case de débordement

- On prend  $b = 3$  et  $b' = 2$ . seuil  $s = 0.6$
- On prendra le modulo pour les fonctions de division

## Hachage linéaire multidimensionnel

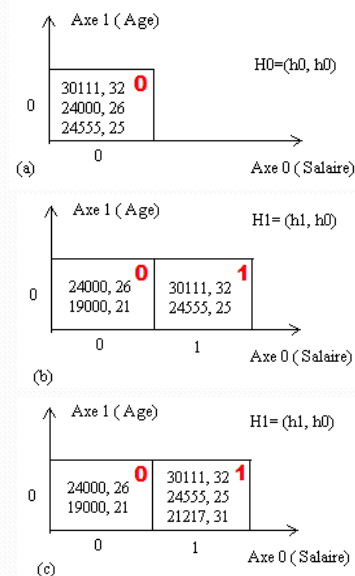
### Première séquence de division

(a) Au départ, une seule case est allouée pour le fichier. Les 3 premiers articles sont insérés avec la fonction  $H_0 = (h_0, h_0)$  où  $h_0(k) = k \text{ Mod } 1$


(b) insertion de l'article (19000, 21):  
Collision sur la case 0.

Résolue par l'éclatement de la case 0 le long de l'axe 0, utilisant la fonction  $H_1 = (h_1, h_0)$  avec  $h_1(k) = k \text{ Mod } 2$

(c) La clé (21217, 31) est insérée dans la case 1.



## Hachage linéaire multidimensionnel





### Deuxième séquence de division

(a) L'insertion de (15241, 26) cause une collision sur la case 1 le long de l'axe 1, puisque  $a=6/6 = 1$ . L'article est mis en débordement et c'est la case 0 qui s'éclate. L'éclatement est accompli par  $H_2=(h_1, h_1)$ .

Noter que

$$H_2(k) = H_1(k) \text{ ou } H_2(k) = H_1(k) + (0, 1)$$

(b) Insertion de (59219, 35) :  $H_2$  donne (1, 1) : en dehors. Donc  $H_1$  qui donne (1, 0) : case 1. → Éclatement.



## Hachage linéaire multidimensionnel

### Adresses logiques des cases

durant les 4 premières séquences de division.

Problème :

Association entre les coordonnées et les adresses de cases ?

| Axe 1 |       |    |    |    |    |
|-------|-------|----|----|----|----|
|       |       | 10 | 11 | 14 | 15 |
| 3     |       |    |    |    |    |
| 2     |       | 8  | 9  | 12 | 13 |
| 1     |       | 2  | 3  | 6  | 7  |
| 0     |       | 0  | 1  | 4  | 5  |
|       | Axe 0 | 0  | 1  | 2  | 3  |

## Hachage linéaire multidimensionnel

### Tableau linéaire dynamique

- Un tableau d-dimensionnel est dit *tableau linéaire dynamique* s'il peut être généré récursivement comme suit:

$$A_0 = \{ A(o, o, \dots, o) \}$$

$$A_{l+1} = A_l \cup A_{l'}$$

- $A_0$  = tableau d-dim contenant le seul élément  $A(o, o, \dots, o)$
- $A_l$  et  $A_{l'}$  sont des ensembles ordonnés tel que  
(1)  $A_l \cap A_{l'} = \emptyset$

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Tableau linéaire dynamique

- (2) Pour chaque élément  $A(i_0, i_1, \dots, i_{d-1})$  de  $A_l$  dans un ordre linéaire ajouter  $A(i'_0, i'_1, \dots, i'_{d-1})$  où

$$i'_j = i_j \text{ pour tout } j, j \neq r$$

$$i'_r = i_r + 2^L$$

avec  $l = L.d + r$  ( $d$  : dimension ;  $L$  : nombre de cycles;  $l$  : nombre de séquences de divisions)



$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Exemple pour $d = 2$

1.  $A_0 = \{A(0, 0)\}$

2.  $A_1 = A_0 \cup A'_0$   
 $l=0 \rightarrow L=0$  et  $r=0$  donc  $2^L = 1$   
 $A_1 = \{A(0, 0), A(1, 0)\}$   
 (Ajouter  $2^L = 1$  à la composante  $r=0$ )

3.  $A_2 = A_1 \cup A'_1$   
 $l=1 \Rightarrow L=0$  et  $r=1$  donc  $2^L = 1$   
 $A_2 = \{A(0, 0), A(1, 0), A(0, 1), A(1, 1)\}$   
 (Ajouter  $2^L = 1$  à la composante  $r=1$  des éléments de  $A_1$ )

4.  $A_3 = A_2 \cup A'_2$

$l=2 \Rightarrow L=1$  et  $r=0$  donc  $2^L = 2$


$A_3 = \{A(0, 0), A(1, 0), A(0, 1), A(1, 1), A(2, 0), A(3, 0), A(2, 1), A(3, 1)\}$

Ajouter  $2^L = 2$  à la composante  $r=0$  des éléments de  $A_2$

Ect...

## Hachage linéaire multidimensionnel

### Évolution du fichier (vue par niveau)



## Hachage linéaire multidimensionnel

*Adresses logiques des cases pour  $l = 5$ :*

|       |    |    |    |    |    |    |    |    |       |
|-------|----|----|----|----|----|----|----|----|-------|
| Axe 1 |    |    |    |    |    |    |    |    |       |
| 3     | 10 | 11 | 14 | 15 | 26 | 27 | 30 | 31 |       |
| 2     | 8  | 9  | 12 | 13 | 24 | 25 | 28 | 29 |       |
| 1     | 2  | 3  | 6  | 7  | 18 | 19 | 22 | 23 |       |
| 0     | 0  | 1  | 4  | 5  | 16 | 17 | 20 | 21 |       |
|       | 0  | 1  | 2  | 3  |    |    |    |    | Axe 0 |

## Hachage linéaire multidimensionnel

### *Projection*

- $\mu$  un point dans  $I^d$ ,  $I$  étant un intervalle quelconque  
(  $I = [o..v]$  par exemple )
- $\mu_i$ :  $i$ -ème coordonnée de  $\mu$ ,  $0 \leq i \leq d-1$
- Projection  $\Pi_i: I^d \rightarrow I^d$

Détermine pour  $\mu$  donné, les coordonnées de la projection de  $\mu$  le long de l'axe  $i$ ,

$$\Pi_i(\mu) := (o, o, \dots, \mu_i, o, \dots o)$$

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### *Fonction de mapping*

Une fonction  $M$  de  $I^d$  (Espace à  $d$  dim) dans  $J$  (espace à 1 dim) est une fonction de stockage si elle satisfait la contrainte suivante :

$$\begin{aligned} M(H_{l+1}(k)) &= M(H_l(k)) + z^l \\ M(H_l(k) + (0, 0, \dots, z^l, 0, 0, \dots)) &= M(H_l(k)) + z^l \end{aligned}$$

ou bien

$$M(i_0, i_1, \dots, i_{l-1}, i_l + z^l, i_{l+1}, \dots, i_{d-1}) = M(i_0, i_1, \dots, i_l, \dots, i_{d-1}) + z^l$$

où  $l = L.d + r$

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### *Fonction de Mapping*

- **Théorème 1**:  $M(\mu) = \sum_{i=0, d-1} M(\Pi_i(\mu))$ ,

$M$  est une fonction bijective

Exemple :  $M(3, 2) = M(3, 0) + M(0, 2)$

La démo se fait par récurrence

- **Théorème 2**: Si  $M(0, 0, \dots, 0) = 0$ , alors  $M$  est une fonction sur la droite  $I_l$  ( $I_l = \{0, 1, 2, \dots, z^{l-1}\}$ ) avec  $l = L.d + r$

## Hachage linéaire multidimensionnel

### Fonction de Mapping

#### Théorème 3:

M est complètement caractérisée par :

$$M(\mu) = \sum_{j=0, d-1} (\sum_{i=0, x_j} (2^{d \cdot i + j} \cdot b_{ij}))$$

où

$$x_j = \text{Ent}(\log \mu_j)$$

et  $b_{x_j j} b_{x_{j-1} j} \dots b_{0j}$  est la représentation binaire de  $\mu_j$

### Exemple (d=2)

#### ♦ Calcul de M(6, 3)

$$(6)_2 = 110 \quad 0 \cdot 2^0 + 1 \cdot 2^2 + 1 \cdot 2^4$$

$$(3)_2 = 11 \quad 1 \cdot 2^1 + 1 \cdot 2^3$$

$$M(6, 3) = 30$$

#### ♦ Calcul de M(4, 2)

$$(4)_2 = 100 \quad 0 \cdot 2^0 + 0 \cdot 2^2 + 1 \cdot 2^4$$


$$(2)_2 = 10 \quad 0 \cdot 2^1 + 1 \cdot 2^3$$

$$M(4, 2) = 24$$


## Hachage linéaire multidimensionnel

### Exemple


**M(6, 3)**



**M(4, 2)**



**M(7, 1)**



$$l = L.d + r$$

## Hachage linéaire multidimensionnel

*Connaissant le niveau  $l$  du fichier on peut déterminer  $M(x, y, z, \dots)$*

• Algorithme :

1. Dédurre  $L$  et  $r$
2. Calcul de  $M$
3.  $l := l - 1$
4. Reprendre à partir de 1

• Pour la dimension 2 on a les formules :

$$\begin{aligned} M(a, b) &= M(a, b-2^l) + 2^l & \text{si } r = 1 \\ &= M(a-2^l, b) + 2^l & \text{si } r = 0 \end{aligned}$$

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

*Connaissant le niveau  $l$  du fichier on peut déterminer  $M(x, y, z, \dots)$*

Exemple : Calcul  $M(3, 3)$  sachant que  $l = 3$

Si  $l = 3 \implies L = 1$  et  $r = 1$   
 $M(3, 3) = M(3, 1) + 2^3$

Pour  $l = 2 \implies L = 1$  et  $r = 0$   
 $M(3, 1) = M(1, 1) + 2^2$

Pour  $l = 1 \implies L = 0$  et  $r = 1$   
 $M(1, 1) = M(1, 0) + 2^1$

Pour  $l = 0 \implies L = 0$  et  $r = 0$   
 $M(1, 0) = M(0, 0) + 2^0$

$\rightarrow M(3, 3) = 2^3 + 2^2 + 2^1 + 2^0 = 15$

## Hachage linéaire multidimensionnel

### *Fonction inverse*

Étant donné une adresse  $m$  obtenue par la fonction  $M$ , et  $b_x m$ ,  $b_{x-1} m, \dots, b_0 m$  sa représentation binaire alors la fonction inverse  $R$  peut être exprimée comme :

$$R = (m_0, m_1, \dots, m_{d-1})$$

avec

$$m_j = \sum (2^{k \text{ div } d} \cdot b_k m) , k \text{ dans } E_m(j)$$

$E_m(j) = \{ k \text{ tel que } k = d \cdot i + j \text{ et } b_k m \text{ est dans la représentation binaire de } m \}$

Pour déterminer  $m_j$ , on ne considère que les bits de rang  $k = d \cdot i + j$

$j = 0, 1, \dots, d-1$

$i = 0, 1, \dots$

## Hachage linéaire multidimensionnel

### *Exemples*

- Pour  $d = 2$

$$E_m(0) = \{ 0, 2, 4, \dots \}$$

$$E_m(1) = \{ 1, 3, 5, \dots \}$$

- Pour  $d = 3$

$$E_m(0) = \{ 0, 3, 6, \dots \}$$


$$E_m(1) = \{ 1, 4, 7, \dots \}$$

$$E_m(2) = \{ 2, 5, 8, \dots \}$$

## Hachage linéaire multidimensionnel

### Exemples

Pour  $d=2$  ;  $m = 27$ , puis  $m=12$



$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Requête exacte

Soit  $k = (k_0, k_1, \dots, k_{d-1})$  et  $l = L.d + r$  le nombre de séquences de divisions accomplies, l'algorithme qui suit rend l'adresse logique où l'article est rangé

1. Appliquer  $H_l(k) \leftarrow (h_{L+1}(k_0), \dots, h_{L+1}(k_{r-1}), h_L(k_r), \dots, h_L(k_{d-1}))$

2.  $m \leftarrow M(H_l(k)) = \sum_{i=0, d-1} (M(\Pi_i(H_l(k)))$

3. Si  $m < P$  alors  $m := M(H_{L+1}(k))$

(P : prochaine case à éclater)

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Requête exacte : Exemple

Trouver l'adresse de (30121, 35) en supposant que  $l = 3$  et  $P = 4$

$$1. H_3(k) = (h_2(30121), h_1(35)) = (1, 1)$$

$$2. M(1, 1) = M(1, 0) + M(0, 1)$$

$$M(1, 0) = 1; M(0, 1) = 2$$

$$m \leftarrow 3$$

$$3. m < P \text{ donc } H_4(k) = (h_2, h_2)(k) = (1, 3)$$

$$M(1, 0) = 1; M(0, 3) = 10$$

$$m \leftarrow 11$$

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Requête partielle

- Rechercher des clés de la forme  $(k_0, k_1, \dots, k_{d-1})$

$k_i$  est

- soit une valeur du domaine  $D_i$
- soit une valeur non spécifiée (\*).

- Soit  $k$  une requête partielle, on désigne par  $b^l(k)$  l'ensemble des cases à rechercher ( $l = L.d + r$ )

$$b^l(k) = \{b^0(k_0), \dots, b^r(k_r), \dots, b^{d-1}(k_{d-1})\}$$

où  $b^i(k_i)$  est défini comme suit :

$$k_i \text{ est spécifié et } i < r : b^i(k_i) = h_{L+1}(k_i)$$

$$k_i \text{ est spécifié et } i \geq r : b^i(k_i) = h_L(k_i)$$



$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Requête partielle

$k_i = *$  et  $i \neq r$  :  $0 \leq b^i(k_i) \leq 2^m - 1$   
avec  $m = L+1$  si  $i < r$  et  $m = L$  si  $i > r$

$k_i = *$  et  $i=r$  :  $0 \leq b^i(k_i) \leq 2^{L+1} - 1 + Last_i$   
 $Last = P - 1$  : dernière case éclatée

$Last_i$  dénote la  $i$ -ième ( $i = r$ ) coordonnée obtenue par l'application de la fonction inverse  $R$

$$l = L.d + r$$

## Hachage linéaire multidimensionnel

### Requête partielle

Soit la requête  $k=(k_0, k_1, \dots, k_{d-1})$  et  $l = Ld + r$ , l'algorithme retourne les adresses des cases où les articles avec les attributs spécifiés sont rangés.

*Pour Chaque  $b$  dans  $b^l(k)$*   
      $m \leftarrow M(b_0, b_1, \dots, b_{d-1})$   
     *Si  $k_r$  est spécifié et  $m < P$*   
          $b_r \leftarrow h_{L+1}(k_r)$   
          $m \leftarrow M(b_0, b_1, \dots, b_{d-1})$   
     *Fsi*  
     *Écrire( $m$ )*  
*Finpour*

## Hachage linéaire multidimensionnel

### *Conclusion*

- Très bonnes performances
- Pour des divisions non contrôlées avec  $b=5$  et  $b'=1$ , le coût d'accès est de 1.09 indépendamment de la dimension et le facteur de chargement est de 67%.
- Pour des division contrôlées, même avec un seuil de 90%, pour  $b=10$  et  $b'=2$ , le temps d'accès est de 1.74.