

INSERTION DANS UN B-ARBRE.

Leçons 901, 921, 932

Référence Cormen chap. 18

Théorème

L'insertion dans un B-arbre de hauteur h se fait en $O(h)$ accès disque.

(La suppression aussi)

+ la hauteur h d'un B-arbre avec $t-1 \geq t-1$ clés, par nœud

est $h = O(\log_t(m))$ où m est le nombre total de clés.

Résumé

I - Petit mot sur B-arbre vs. arbre binaire de recherche et sur le coût des accès disques et de la recherche dans un B-arbre.

I - Etude de l'insertion dans un B-arbre.

II - Bonne sur la hauteur h .

BONUS - Un mot sur la suppression.

I • Un B-arbre c'est une arborescence T telle que :

1) Chaque nœud x contient les champs

* $n(x)$: le nombre de clés

* $clé_1(x) \leq \dots \leq clé_{n(x)}(x)$: les valeurs stockées dans le nœud.

* $feuille(x)$: booléen qui dit si l'arbre est une feuille.

2) Chaque nœud x contient $c_1(x), \dots, c_{n+1}(x)$ pointeurs vers ses enfants

3) Les clés déterminent les valeurs stockées dans les nœuds enfants.

4) Toutes les feuilles ont pour profondeur h .

5) Chaque nœud a minimum $t-1$ clés (sauf la racine) et maximum $2t-1$.

- L'idée d'un B-arbre est de généraliser les ABR de façon à minimiser le nombre d'accès disque, qui sont de loin les opérations les plus coûteuses en temps, mais qui sont nécessaires pour stocker de gros volumes de données.

- Pour un B-arbre, la recherche se fait en $O(t \log_t(n))$ contre $O(\log_2(n))$ dans un ABR.

t est effectivement une constante mais en pratique on prend $t \approx 1000$ ce qui permet de stocker beaucoup de clés dans une petite hauteur.

{ Remarque : accéder à 1000 clés stockées consécutivement sur un disque dur n'est pas si long car le bras du disque bouge peu.

- III] • On va avoir besoin d'une procédure qui permet de découper un noeud plein en deux noeuds.

Définissons aussi

PARTAGER

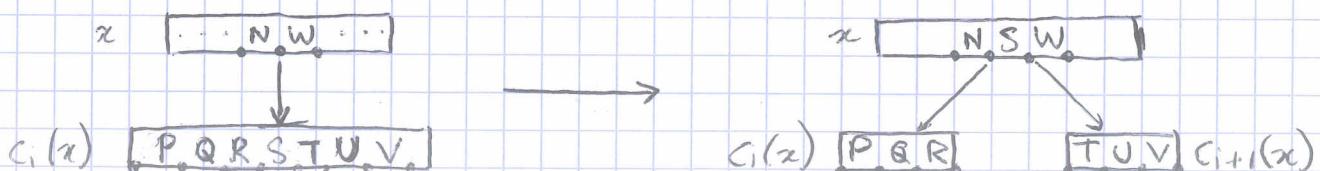
Entrées : x un noeud non plein
 i un indice tel que $c_i(x)$ est plein.

- 1) Découper $c_i(x)$ autour de la médiane et rajouter la médiane au noeud x .

- 2) Écrire sur le disque pour les mises à jour du noeud parent et des deux noeuds enfants

3 ECRITURES

Exemple avec $t = 4$



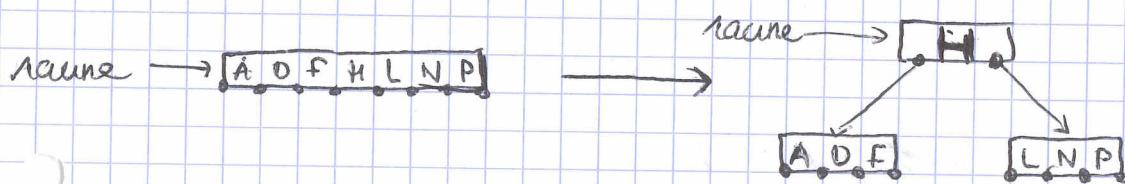
- On est maintenant armé pour insérer une nouvelle clé dans un arbre : on effectue l'insertion par le haut !

On a vu qu'on peut toujours s'en sortir si on vient d'un noeud qui n'est pas plein pour vider celui d'en dessous qui nous intéresse.

Avant de décrire notre algorithme d'insertion, on va s'assurer que la racine de T n'est pas pleine. **LECTURE**

→ si elle est pleine, on rajoute une racine vide au dessus, notée s , puis on appelle **PARTAGER**($s, 1$)

Exemple avec $t=4$



- Maintenant on peut définir la procédure d'insertion.

INSERER

Entrée : x un noeud supposé non plein
k la clé à insérer.

1) Si x est une feuille, on insère simplement la clé k . **ÉCRITURE**

2) Sinon

- Parcourir les clés jusqu'à trouver l'enfant de x dans lequel on est susceptibles de pouvoir rajouter la clé k .

- Si ce noeud enfant est plein **LECTURE**

- le couper en deux en appelant **PARTAGER** **ÉCRITURE**

- choisir l'enfant du côté qui correspond à k .

- INSERER récursivement sur le noeud non plein choisi.

- Notons (ÉCRITURE / LECTURE) à chaque endroit où l'on a accédé au disque dur. Il y en a $O(1)$ par chaque appel de INSERER.
→ on en effectue donc en tout $O(h)$.

II] • Tout l'intérêt des B-arbres c'est qu'on va pouvoir avoir une complexité agréable sur l'insertion : estimons h !

- Comptons le nombre minimal de nœuds dans un B-arbre de hauteur h :

Profondeur	0	1	2	...	h
Nb min de nœuds	1	2	$2t$		$2t^{h-1}$

D'où la relation sur le nombre de clés :

$$m \geq 1 + \underbrace{(2 + 2t + \dots + 2t^{h-1})}_{\text{nombre minimum de nœuds}} (t-1) = 1 + 2(t-1) \frac{t^h - 1}{t-1} = 2t^h - 1$$

racine nombre minimum de nœuds nombre minimum de clés par nœud.

On en déduit donc $h \leq \log_t \left(\frac{m+1}{2} \right)$.

À titre d'exemple, avec $t=1000$ et $m=10^9$, on a $h \leq 3$.

ce qui explique que SQL s'en serve pour faire des index :

- on accède très peu de fois au disque dur
- on peut regrouper facilement des clés.