

- [BBCP 147] -

À partir d'un ensemble de données de même type, on va chercher des structures de données adaptées pour effectuer les opérations :

- insérer.
- supprimer.
- rechercher.

I Méthodes simples.

A) Recherche dans une liste non triée.

Pour rechercher un élément dans la liste : on le compare avec le premier élément, si c'est négatif, on passe au suivant... Par exemple, la suppression infinie est en $O(n)$.

B) Recherche dans une liste triée.

On a une relation d'ordre sur les éléments. L'insertion d'un élément en fin de liste se fait en $O(n)$ comparaisons. Performance moyenne : $\Theta(n)$.

C) Recherche dichotomique.

Recherche d'une occurrence d'un élément quelconque se fait $O(\log n)$ comparaisons. On utilise du récursif.

En bref : un algorithme fonctionnant par comparaisons ne peut faire mieux que $O(\log n)$ (arbre de décision).

II Structure d'arbre.

A) Arbres de recherche.

Def 1: Un univers U est un ensemble totalement ordonné. Pour éviter de déplacer les données $x = \{x, y, z\}$ à l'ici, on associera à chaque donnée une clé, qui est un élément de l'univers. Réciproquement, une clé nous permet d'accéder à une unique donnée : de $c(x)$ on trouve x .

Def 2: Un arbre binaire de recherche est un arbre munis d'une fonction clé : $\forall x$ sommet, $\forall y \in A_g(x)$ (sous-arbre gauche du noeud x)
 $\forall y \in A_d(x)$ (sous-arbre droit du noeud x),
 $c(y) < c(x) < c(y)$.

Def 3: Une arborescence ordonnée de recherche est un arbre tel que en chaque noeud x , à $d(x)$ fils et muni de $d(x)-1$ clés $c_1(x), \dots, c_{d(x)-1}(x)$, enforçant $A_1(x), \dots, A_{d(x)}(x)$ les sous-arbres de x , pour tout y sommet de $A_i(x)$, on a : $c(y) < c_1(x) < c(y_2) < \dots < c_{d(x)-1}(x) < c(y_{d(x)})$.

Def 4: Un arbre de recherche est un ABR ou un AOR.

Rem 5: Ces structures sont dynamiques, elles sont amenées à changer au cours du temps (exemple : dictionnaire).

Def 6: On effectue les opérations suivantes sur les arbres binaires :

rotations gauche, droite, (gaud) $g-d$ ou $d-g$. (voir annexes 1 - 2).

Sug 7: Si A est un ABR, alors les rotations sur A préservent cette structure. De plus, elles se réalisent en temps constant.

B) Arbres AVL

Def 8: On note s la fonction "différence de hauteurs" définie sur l'ensemble des ABR : $s(A) = \text{hauteur}(A_g) - \text{hauteur}(A_d)$.

Les AVL sont des ABR respectant la condition : $s(A) \in \{-1; 0; 1\}$.

Sug 9: Soit A un AVL ayant n sommets et de hauteur h . Alors :

$$\log_2(1+n) \leq 1+h \leq 1,44 \log_2(2+n).$$

La borne minimale est essentiellement atteinte par les arbres de Fibonacci.

$$\Phi_0 = 0, \quad \Phi_1 = 1, \quad \Phi_{n+2} = \frac{\Phi_{n+1}}{\Phi_n}$$

Sug 10: Les opérations insertion, suppression et recherche se font en temps $O(\log n)$. (DEV1)

C) Arbres a-b.

Def 11: Soient a et b deux entiers avec $a \geq 2$ et $b \geq 2a-1$. Un arbre a-b est un arbre A vérifiant :

- (i) toutes les feuilles ont la même profondeur.
- (ii) la racine a au moins 2 et au plus b fils.
- (iii) les autres noeuds ont au moins a et au plus b fils.

Soit $d(x)$ le nombre de fils de x , et $A_i(x)$ le $i^{\text{ème}}$ sous-arbre de x .

Def 12: Soit S un ensemble de clés. A est un arbre a-b pour S si les éléments de S sont rangés aux feuilles de A en ordre croissant de la gauche vers la droite, et si pour chaque noeud x à $d(x)-1$ fils $h_1 < \dots < h_{d(x)-1}$ (les tailles de x) vérifient :

pour toute clé c_i de $A_i(x)$, on a :

$$c_1 < h_1 < c_2 < h_2 < \dots < h_{d(x)-1} < c_{d(x)}$$

Ex 13 : voir annexe 3.

Sigo 14 : La recherche dans un arbre a-b se fait en temps $O(\log n)$.

Principe 15 de l'insertion : (1) On descend dans l'arbre à partir de la racine, et on ajoute au père une balise (cf annexe 4).

(2) On vérifie que le père a entre a et b fils. Si ce n'est pas le cas, on réalise un éclatement (cf annexe 5), et si nécessaire, on continue jusqu'à la racine.

Sigo 16 : L'insertion dans un arbre a-b se fait en temps $O(\log n)$.

Principe 17 de la suppression : on recherche la clé, on la supprime, on supprime une balise (si nécessaire, réaliser une fusion).

Sigo 18 : La suppression dans un arbre a-b se fait en temps $O(\log n)$.

D) Arbres bicolores (rouge-noir)

Def 13 : Un arbre bicolore (a,c) où A est un arbre complet binaire et c une coloration des sommets dans {rouge-noir} est un arbre vérifiant :

- a) toutes les feuilles sont noires;
- b) la racine est noire;
- c) le père d'un sommet rouge est noir;
- d) les chemins d'un même sommet à une feuille ont le même nombre de sommets noirs.

Un arbre bicolore pour un ensemble ordonné S est un arbre bicolore qui est un ABR pour S, où les éléments de S ne sont que sur les feuilles.

Ex 20 : voir annexe 6.

Def 21 : Une fonction rang_A définie sur un ABR complet A est une application de S (sommets de A) dans N vérifiant :

- i) \forall feuille x, $\text{rang}(x)=0$ et si x a un père, $\text{rang}(p(x))=1$.
- ii) \forall sommet x, $\text{rang}(x) \leq \text{rang}(p(x)) \leq \text{rang}(x)+1$.
- iii) \forall sommet x, $\text{rang}(x) \leq \text{rang}(p(p(x)))$.

Sigo 22 : si (A,c) est un arbre bicolore, alors il existe une fonction rang_A . Reciproquement, l'existence d'une fonction rang_A indique que il existe

une coloration pour A tel qu'il soit bicolore.

Sigo 23 : les opérations d'insertion et de suppression se font en temps $O(\log n)$.

E) Arbres binaires de recherche optimisés.

Def 24 : Soient h_1, \dots, h_n des trèves par ordre croissant. La probabilité qu'une clé h_i soit demandée est p_i . On ajoute $n+1$ des factices, d_0, \dots, d_n , où d_i représente les mots recherchés entre h_i et h_{i+1} . Soit q_i la probabilité qu'on recherche d_i. Un ABBQ est un arbre binnaire minimisant :

$$\text{IE [coût de recherche dans A]} = t + \sum_{i=1}^n \text{prof}_A(h_i)p_i + \sum_{i=0}^n \text{prof}_A(d_i) \cdot q_i.$$

Rem 25 : Cette structure est statique, l'insertion et la suppression d'un élément entraînent une reconstruction totale de l'arbre.

Ex 26 : cf annexe 7.

IV Application à l'algorithme de texte.

A) Plus longue sous-séquence commune.

Exemple : Comparaison de deux trênes d'ADN.

Def 27 : Z = (z₁, ..., z_l) est une sous-séquence de X = (x₁, ..., x_m), si il existe $\ell : [1; l] \rightarrow [1; m]$ strictement croissante telle que $\forall i \in [1; l], z_i = x_{\ell(i)}$.

On recherche la plus longue sous-séquence commune (PLSC) à X = (x₁, ..., x_m) et à Y = (y₁, ..., y_n).

Sigo 28 : Soit Z une plus longue sous-séquence commune à X et à Y.

$\exists i : z_l = x_m = y_n$, alors Z_{l-1} est une PLSC à X_{m-1} et Y_{n-1}.

$\exists i : z_l \neq x_m$ alors Z_l est une PLSC à X_{m-1} et Y_n.

$\exists i : z_l \neq y_n$ alors Z_l est une PLSC à X_m et Y_{n-1}.

Résolution par programmation dynamique ; récurrence sur la taille de X et sur la taille de Y.

B) Distance d'édition.

Ex : Comparer les mots REMUER et RUNEUR.

[CROJ]

- On veut minimiser la distance d'édition avec trois possibilités d'action,
- aligner une lettre de X et une de Y .
 - sauter une lettre de X .
 - sauter une lettre de Y .
- $O(nm)$

ex: REMU - EUR
 $\begin{array}{ccccccc} R & - & E & M & U & - & E & - & R \\ & & \pi & \pi & \pi & & & & \\ & & \text{distance est de 4.} & & & & & \end{array}$

c) Tri des suffixes.

Pour rechercher un mot dans un texte : création de la table des suffixes.
 Un mot w sera défini par une liste de lettres $y[0], \dots, y[n-1]$, et on veut trier les suffixes $y[0], \dots, y[n-1], \dots, y[n-i]$.

On va chercher une permutation p telle que $y[p(0)], \dots, y[p(n-1)] \leq \dots$

Déf 29: Soit $h > 0$. Pour $n \in \mathbb{A}^*$, le début d'ordre h du mot w :

$$\text{premp}(w) = \left\{ i \in \{0, \dots, n-1\} \mid h_i \leq h \right\} \text{ sinon.}$$

On note $R_h[i]$ le rang de $\text{premp}(y[i, \dots, n-1])$ dans l'ordre croissant des $(R_h[i])_{i \in \{0, \dots, n-1\}}$. Pour tout h , on a la relation d'équivalence:

$$i \equiv_h j \iff R_h[i] = R_h[j].$$

Si $i \geq n$, on pose $R_h[i] = -1$.

Lemma 30 (de dédoublement): $R_h[i]$ est le rang du couple $(R_h[i], R_h[i+1])$ dans la liste croissante de ces couples.

Th 31: L'algorithme TRI-SUFFIXES appliquée à y de longueur n crée la table des suffixes en temps $O(n \log n)$

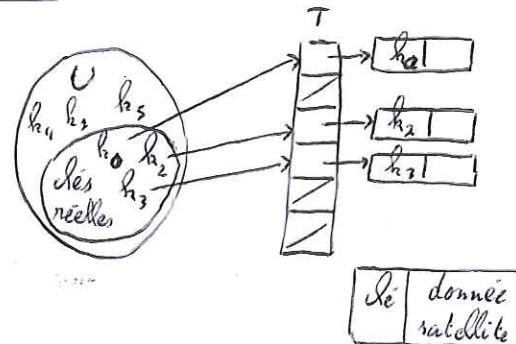
| DVPI

IV) Tables de hachage.

A) Tables à adressage direct.

Déf 32: Une table à adressage direct est un tableau $T[0, \dots, m-1]$ dans lequel chaque position (ou cellule) correspond à une clé de l'univers U .

Prop 33: Chacune des opérations : recherche, insertion et suppression se fait en temps $O(1)$.



+ recherche de clé minimal (TAIS - 11AV)

B) Tables de hachage.

Problème: Si $|U|$ grand, on ne peut pas toujours gérer T aussi grand.

Déf 34: Une fonction de hachage est une fonction $h: U \rightarrow \{0, \dots, m-1\}$, où $m \leq |U|$; le tableau $T[0, \dots, m-1]$ est la table de hachage. On dit qu'un élément de U est haché dans l'adresse $h(u)$.

Inconvénient: La non injectivité de h peut envoyer deux clés dans la même adresse: on a un phénomène de collision! Pour le résoudre, on utilise le chaînage (cf annexes 8).

Déf 35: On définit $\alpha = \frac{n}{m}$ le facteur de remplissage, c'est-à-dire pour n éléments stockés dans un tableau de taille m .

Th 36: Dans une table de hachage dont la résolution se fait par chaînage, le coût d'une recherche réussie ou d'une recherche infructueuse est $\Theta(1 + \alpha)$, dans le cas d'un hachage uniforme simple (chaque élément a la même chance d'être haché vers l'une quelconque des adresses).

c) Des exemples de fonctions de hachage.

Déf 37: Méthode de la division (les clés sont des entiers).

$$h: u \mapsto h \pmod m.$$

Si les données sont stockées en lit, on évite que m soit $m = 2^k$.

Déf 38: Méthode de la multiplication. Soit $0 \leq A \leq 1$.

$$h: u \mapsto m(hA - \lfloor hA \rfloor) \pmod 1.$$

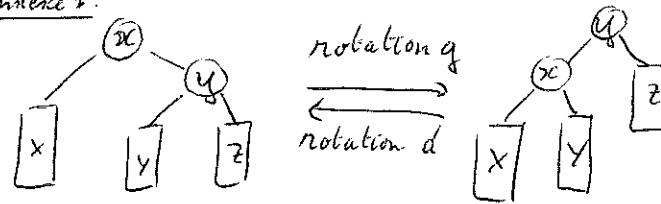
Déf 39: Si la fonction de hachage est donnée, un ennemi peut choisir les clés telles qui elles soient stockées dans la même cellule. On sélectionne donc aléatoirement une fonction de hachage, c'est le hachage universel.

Déf 40: Une collection de fonctions de hachage est universelle si:

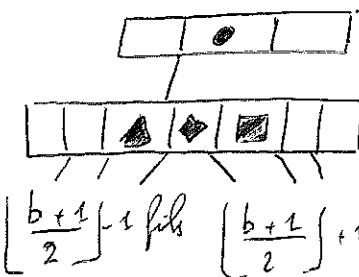
$$\#\{h \in \mathcal{H}; h(h) = h(\delta)\} \leq \frac{1}{m}, \forall h, \delta \in U.$$

Th: Soit n : la longueur de la liste $T[i]$. Pour une fonction de hachage choisie aléatoirement dans une collection universelle, et si la clé recherchée : si h est dans la table:
 $|E[\#h(h)]| \leq \frac{n}{m}$ sinon:
 $|E[\#h(h)]| \leq x+1$.

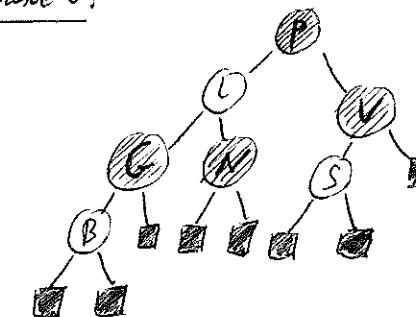
Annexe 1:



Annexe 5:

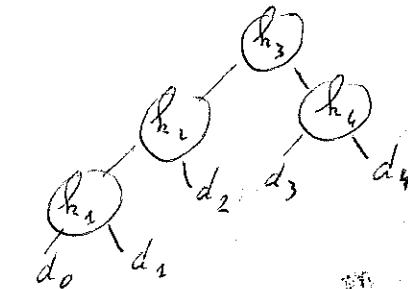


Annexe 6:

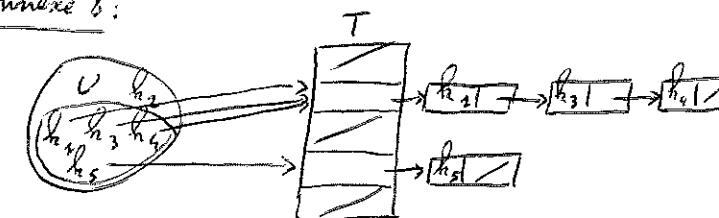


Annexe 7:

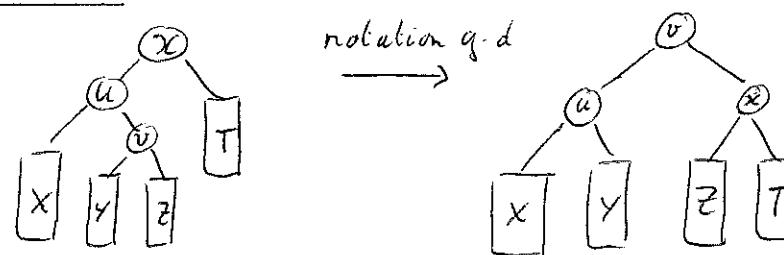
i	0	1	2	3	4
p_i			0,05	0,015	0,05
q_i	0,05	0,05	0,05	0,05	0,15



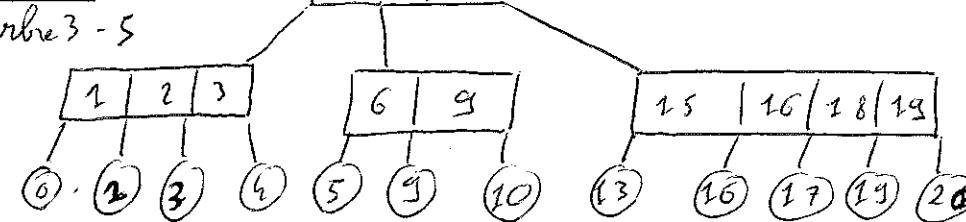
Annexe 8:



Annexe 2:



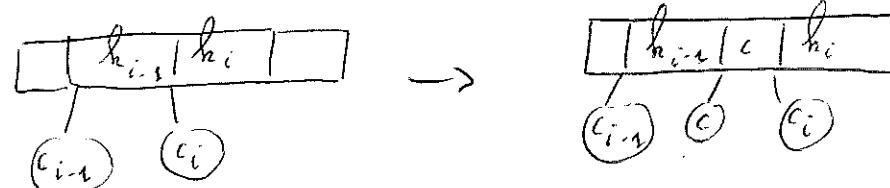
Annexe 3:



$$S = \{10; 4; 3, 16; 19; 5; 20; 13, 0; 17; 2; 9\}$$

Annexe 4:

$$c_{i-1} < h_{i-1} < c < c_i & s h_i :$$



$$c_{i-1} < h_{i-1} < c_i < c < h_i :$$

