

Soit E un ensemble d'éléments ayant chacun une clé. On note U l'ensemble des clés possibles. Quelles structures de données utiliser pour rechercher efficacement dans E ?

I Tableaux et listes

1) Vecteurs de bits ($U \subset \mathbb{N}$)

On représente E par un tableau T de taille $|U|$ tel que $T[i] = \begin{cases} 1 & \text{si } \exists x \in E, \text{cl}(x)=i \\ 0 & \text{sinon} \end{cases}$. Lorsque $x \in E$ revient à savoir si $T[\text{cl}(x)] = 1$. On a donc une recherche en $\mathcal{O}(1)$ mais cette idée est inutilisable si $|U|$ est grand.

2) Recherche naïve

On représente E par la liste L des clés de ses éléments. Rechercher x dans E revient à parcourir L jusqu'à trouver de (x) . D'où une complexité au pire en $\mathcal{O}(|E|)$.

3) Recherche dichotomique (ordonné)

On représente E par le tableau trié de ses clés. On effectue alors une recherche dichotomique en $\mathcal{O}(\log |E|)$.

II Hachage [Cor]

1) Principe général

Si $|U|$ est grand, I.1 est inutilisable. On cherche ici une structure de taille $\mathcal{O}(|E|)$ telle que la recherche soit $\mathcal{O}(1)$.

On choisit un tableau T de taille $m < |U|$ et $h: U \rightarrow [0, m-1]$. On stocke alors $x \in E$ à la place $T[h(\text{cl}(x))]$. Comme $m < |U|$, h n'est pas injective. Si deux clés ont même image par h , on parle de collision (Figure 1).

2) Résolution par chaînage

On considère T comme un tableau de listes. Ainsi $T[i]$ contient tous les éléments $x \in E$ tel que $h(\text{cl}(x)) = i$. Notons alors $n_i = |T[i]|$ et $\alpha = |E|/m$ le coefficient de remplissage.

Si h est mal choisie, toutes les clés peuvent être envoyées sur la même case. Dans ce cas la recherche se fait en $\mathcal{O}(|E|)$. On va voir comment choisir h pour éviter ça.

Hypothèse : On suppose que h vérifie l'hypothèse de hachage uniforme simple (HHS) :

$$P(h(x) = r) = 1/m \quad \forall x \in U \quad \forall r \in [0, m-1].$$

Thm: Sous HHS, toute recherche infructueuse est au pire en $\mathcal{O}(1+\alpha)$ et toute recherche réussie est en moyenne en $\mathcal{O}(1+\alpha)$.

3) Hachage universel et hachage parfait

Def: Soit \mathcal{H} une classe de fonctions de hachage. \mathcal{H} est dite universelle ssi

$$\forall k \neq l \in U, |\{R \in \mathcal{H}, R(k) = R(l)\}| \leq |\mathcal{H}|/m.$$

Ex: Si $p \nmid |U|$ est premier, la classe $\{k \mapsto (ak+b) \bmod p\} \bmod m$, $a \in (\mathbb{Z}/p\mathbb{Z})^*$, $b \in \mathbb{Z}/p\mathbb{Z}\}$ est universelle

Thm: Si \mathcal{H} est universelle et $R \in \mathcal{H}$, $E(n_{R(k)}) \leq 1 + \alpha \quad \forall k \in U$.

App: Soit E un ensemble fixé, i.e. on ne fait plus d'insertion ni de suppression, seulement des recherches. On peut construire une structure de taille $\mathcal{O}(|E|)$ où la recherche est $\mathcal{O}(1)$ au pire

App: Implementation des dictionnaires

• utilisation de CD-Rom

• tables des symboles / mots réservés dans les compilateurs

III Structures arborescentes [Cor] [Bear]

1) Arbres de recherche

def: Un arbre de recherche est un arbre étiqueté tel que tout noeud ayant $k+1$ sous-arbres A_0, \dots, A_k contient un k -uplet $x_1 < \dots < x_k$ tel que pour toute composante x d'une étiquette d'un noeud de A_i , $x_i < x_k < x_{k+1}$.

ex: Figure 2.

def: Un arbre binaire de recherche (ABR) est un arbre de recherche où tout noeud non terminal a deux fils.

On a un algorithme de recherche linéaire en la hauteur de l'arbre, donc entre $\log |E|$ et $|E|$.

Si pour chaque clé, on connaît la probabilité qu'on la recherche, on peut s'intéresser à des ABR optimaux, i.e. qui minimisent l'espérance du temps de recherche d'une clé (DEV2).

2) Équilibrage et AVL

def: Un AVL est un arbre binaire de recherche tel que pour tout noeud $x \in T$ de sous-arbres G et D , $|h(G) - h(D)| \leq 1$.

Thm: Soit T un AVL à n noeuds, de hauteur h . Alors

$$\log_2(n+1) \leq h+1 \leq 1.44 \log_2(n+1)$$

cor: Les opérations de recherche dans un AVL sont en $\Theta(\log(n))$.

remq: Les opérations d'insertion et suppression sont plus complexes à cause des rééquilibrages mais restent $\Theta(\log n)$.

3) Arbres 2-3-4

def: Un arbre 2-3-4 est un arbre de recherche où tous les noeuds internes ont 2, 3 ou 4 fils, et dont toutes les feuilles sont à la même hauteur.

Thm: La hauteur h d'un arbre 2-3-4 contenant n clés vérifie $\log_4(n+1) \leq h+1 \leq \log_2(n+1)$.

cor: La recherche est encore en $\Theta(\log n)$.

4) Arbres rouge-noir

def: Un arbre rouge/noir est un ABR vérifiant:

- * tout noeud est rouge ou noir
- * la racine est noire
- * les feuilles sont noires
- * les fils d'un noeud rouge sont noirs
- * $\forall x$, les chemins issus de x et allant jusqu'aux feuilles ont même nombre de noeuds noirs.

Thm: Un arbre rouge/noir à n noeuds a une hauteur plus petite que $2 \log_2(n+1)$.

cor: La recherche est en $\Theta(\log n)$.

remq: On peut passer d'un arbre rouge/noir à un arbre 2-3-4 et réciproquement via la figure 3.

5) Arbres persistants et duplication de chemins

On veut gérer une base de données qui évolue dans le temps. On veut savoir si x appartient à la structure au temps t . (i.e. après t opérations insérer/supprimer)

1^{ere} idée: recopie intégral à chaque opération (Figure 4)

2^{eme} idée: on utilise des arbres et on duplique chaque noeud dont un descendant est modifié (Figure 5).

La recherche de x à l'instant t revient à chercher x dans l'arbre dont la racine est pointée par $T[t]$. L'insertion, la suppression et la recherche sont en $O(\ln n)$ où n est le plus grand nombre de clés présentes dans la structure à l'instant t .

6) Tas et file de priorité

def: Un tas est un arbre binaire dont tous les niveaux sont complets sauf éventuellement le dernier, où tous les noeuds sont tassés à gauche.

- Un tas max est un tas où chaque noeud est plus grand que ses fils.

remq: • On représente un tas par un tableau (Figure 6)
• Le maximum d'un tas max est sa racine.

Si A est un tas, $x \in A$ dont les sous-arbres G et D sont des tas max. Alors on peut obtenir un tas max contenant x , G et D en faisant descendre x tant qu'il n'a pas la propriété de tas max. On parle d'entassement.

app: • Construction d'un tas max à partir d'un tas en temps linéaire
• On utilise l'entassement pour récupérer un tas max quand on extrait la racine d'un tas max.

On peut implementer une file de priorité grâce avec tas max:

- défilage par extraction du maximum : on extrait la racine puis on entasse pour obtenir un tas max $\rightsquigarrow \mathcal{O}(n)$
- enfilage : on ajoute un noeud (correspondant à une case à la fin du tableau) qui contient la nouvelle priorité et on fait remonter le noeud jusqu'à obtenir un tas max $\rightsquigarrow \mathcal{O}(\log n)$.

app: • algorithme de Dijkstra
• ordonnancement de tâches/processus.
• codage de Huffman.

[Cor] [Bac] [Pop] [Bac]

IV Union Find, Union par rang et compression de chemins

On peut pouvoir gérer des classes d'équivalences de $\{0, \dots, n-1\}$ avec deux opérations:

- déterminer la classe d'un élément
- fusionner deux classes.

On représente chaque classe par un arbre et la partition par une forêt. On prend un tableau T tel que $T[i]$ est le père de i . Si i est racine, on pose par convention $T[i] = i$.
On a alors les deux algorithmes

Trouver(x)

 si $x \neq T[x]$, Trouver($T[x]$)

 sinon renvoyer x

Union(x, y)

$[T[Trouver(x)] \leftarrow Trouver(y)]$

problème: On peut se retrouver avec des arbres peigne
Trouver est alors en $\mathcal{O}(n)$

Union par rang :

 → On calcule un tableau Rang tel que Rang[x] majore la hauteur du sous-arbre issu de x .

 → lors d'une union, on fait pointer le noeud de plus petit rang pour Trouver(x) et Trouver(y) vers l'autre

 → On actualise Rang

Compression de chemins:

 → quand on appelle Trouver(x), on fait pointer tous les noeuds parcourus vers Trouver(x)
(Figure 7)

thm: Si on fait m opérations, leur complexité est $\mathcal{O}(m \alpha(n))$ donc la complexité amortie est $\mathcal{O}(\alpha(n))$ où α est une fonction à croissance très lente ($\alpha(n) \leq 5$ pour tous les n utilisés en pratique).

app: • algorithme de Kruskal

- * composants connexes d'un graphe
- * unification
- * fermétoire congruent.

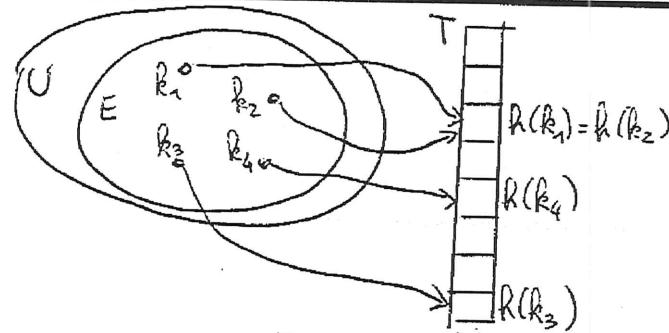


Figure 1.

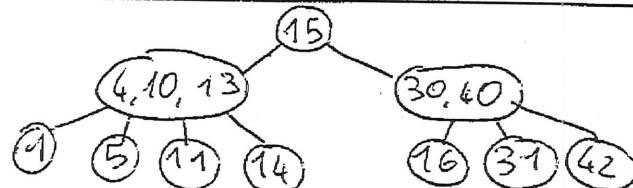


Figure 2

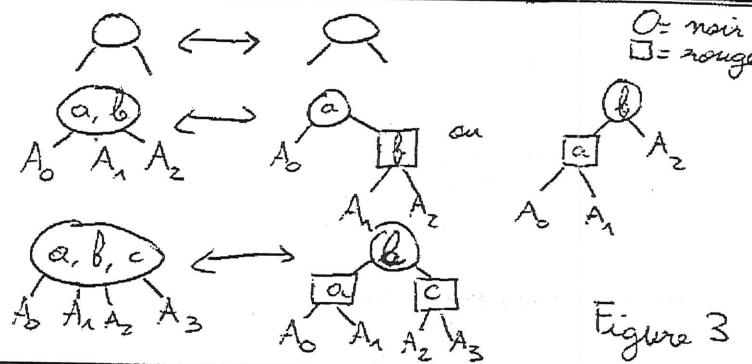


Figure 3

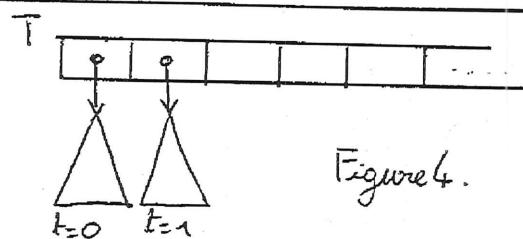


Figure 4.

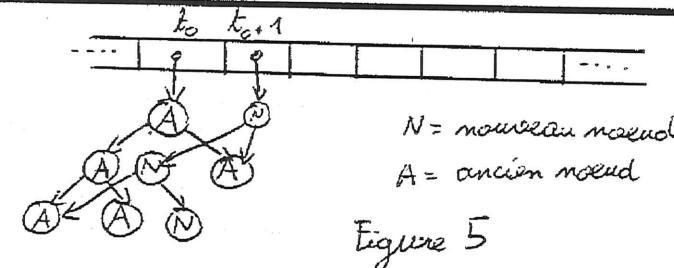


Figure 5

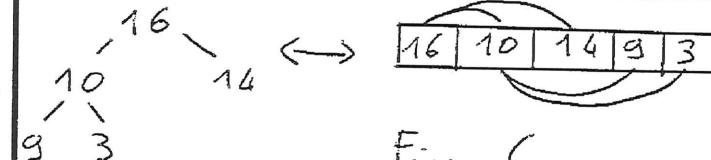


Figure 6

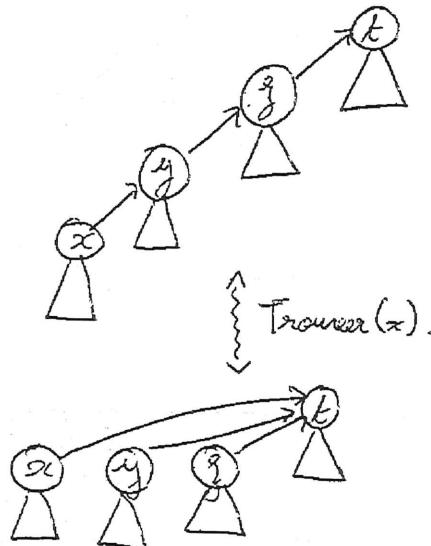


Figure 7.

[Cor] Carmen

[Beno] Beaquier

[Pop] Parallelization, Algorithms

[Box] Bachelor Network, Term rewriting systems and all that