

Hashage parfait [Commen p 258-262]

Pour le des = fois que le mot

On considère 1 univers U de lequel les clés prennent leurs valeurs et 1 ensemble fini
 $K \subset U$ de clés, de taille m . Par codage, ops $U \subset \mathbb{N}$
taille de U arbitraire

On dit qu'1 hashage est parfait qd le nb d'accès mémoire au pui cas pour 1 recherche est en $O(1)$
 + des classe de fonctions de hashage universelle

Pour créer 1 hashage parfait, on utilise 2 niveaux de hashage :

On commence par hasher les m clés de m alvéoles avec 1 certaine jet^e h

Puis pour chaque alvéole j , on la remplit avec 1 table de hashage secondaire S_j
 avec 1 fonction de hashage h_j . On montre qu'en fixant la taille de S_j égale à
 $m_j = m_j^2$ où $m_j = \text{nb de clés hashées de l'alvéole } j \text{ par } h$ on n'aura pas de collision au 2^e niv

Soit $p \in \mathbb{P}$ tq $p > |U|$. Pour tout $a \in \mathbb{Z}/p\mathbb{Z}^*$ et tout $b \in \mathbb{Z}/p\mathbb{Z}$

on note $R_{a,b} : \mathbb{Z}/p\mathbb{Z} \rightarrow \llbracket 0, m-1 \rrbracket$

$$k \mapsto (ak + b \pmod p) \pmod m$$

et on note $\mathcal{H}_{p,m} = \{R_{a,b} \mid a \in \mathbb{Z}/p\mathbb{Z}^*, b \in \mathbb{Z}/p\mathbb{Z}\}$

[ADMIS] au moins de la des

$\mathcal{H}_{p,m}$ est 1 classe de fonctions de hashage universelle car si k est tiré aléatoirement
 de $\mathcal{H}_{p,m}$ et k, l sont 2 clés \neq de $\mathbb{Z}/p\mathbb{Z}$, $\mathbb{P}(R(k) = R(l)) \leq \frac{1}{m}$ (chances de collision $\leq \frac{1}{m}$)

Si on stocke m clés de 1 table de taille $m = m^2$ à l'aide d'1 fonction R choisie
 aléatoirement de 1 classe de fonctions de hashage universelle alors la proba d'avoir
 des collisions est $\leq \frac{1}{2}$

Soit X la va qui compte le nb de collisions. Il y a $\binom{m}{2}$ paires de clés
 susceptibles d'entrer en collision et chaque paire a 1 proba $\leq \frac{1}{m}$ d'entrer en collision

(des classe universelle) $\mathbb{E}[X] \leq \sum_{\substack{k, l \text{ paires} \\ \text{de clés } \neq}} \mathbb{P}(R(k) = R(l)) \leq \frac{1}{m} \times \binom{m}{2}$

Donc $\mathbb{E}[X] \leq \frac{1}{m} \binom{m}{2} = \frac{1}{m^2} \times \frac{m(m-1)}{2} = \frac{m-1}{m} \times \frac{1}{2} < \frac{1}{2}$

On applique ensuite l' \leq de Markov : $\mathbb{P}(X \geq 1) \leq \frac{\mathbb{E}[X]}{1} < \frac{1}{2}$ ce qui conclut

Pour trouver 1 table sans collisions, il suffit d'essayer plusieurs h jusqu'à ce que ça marche :

La proba d'avoir 1 collision après k choix de h est $\leq \frac{1}{2^k}$ donc on va y arriver !

Pb : en mémoire, la table est de taille m^2 = quadratique en le nb de clés = trop gros si beaucoup de clés.

On choisit alors les m clés de 1 table de taille $m = m$ via h puis pour chaque arête j on construit 1 table secondaire S_j de taille $m_j = m_j^2$ où $m_j =$ nb de clés qui arrivent de l'arête j via h . On garantit là encore qu'en peu d'essais (linéaire en m) on a 1 table à 2 niveaux sans collision. Montrons qu'on a gagné en mémoire $\frac{1}{2}$ à la 1^{ère} situation :

(Th) Si on stocke m clés de 1 table de taille $m = m$ via h choisie uniformément de 1 classe

de fonctions de hachage universelle alors $E \left[\sum_{j=0}^{m-1} m_j^2 \right] < 2m$

où m_j est la va correspondant au nb de clés hachées de l'arête j par h

démo On a $\forall p \in \mathbb{N}^*$, $p^2 = p + 2 \binom{p}{2}$

$$\text{donc } E \left[\sum_{j=0}^{m-1} m_j^2 \right] = E \left[\sum_{j=0}^{m-1} \left(m_j + 2 \binom{m_j}{2} \right) \right]$$

$$= E \left[\underbrace{\sum_{j=0}^{m-1} m_j}_{=m} \right] + 2 E \left[\sum_{j=0}^{m-1} \binom{m_j}{2} \right] \text{ par linéarité}$$

= nb de paires d'élé qui entrent en collision dans la grande table principale (donnée par h) = 2x du nb d'avant

Donc comme par le Th d'avant, $E \left[\sum_{j=0}^{m-1} \binom{m_j}{2} \right] \leq \frac{1}{m} \binom{m}{2} = \frac{1}{m} \frac{m(m-1)}{2} = \frac{m-1}{2}$

Donc $E \left[\sum_{j=0}^{m-1} m_j^2 \right] \leq m + m - 1 < 2m$.

On en déduit que, si on prend la table S_j de taille $m_j = m_j^2$, la quantité moyenne de mémoire requise pour toutes les tables secondaires est $< 2m$. Et \hat{m} :

(Th) Avec la stratégie décrite précédemment, la proba que l'espace total occupé par 2 tables secondaires)

dépasse $4m$ est $< \frac{1}{2}$

démo / inégalité Markov : $P \left(\sum_{j=0}^{m-1} m_j^2 \geq 4m \right) \leq \frac{E \left[\sum_{j=0}^{m-1} m_j^2 \right]}{4m} < \frac{1}{2}$

Rappel : l'atta vient du choix des fonctions de hachage, par des clés qui elles sont fixées. Pour éviter 1 collision et en $O(m)$ en espace = tant que $\sum m_j^2 \geq 4m$, choisir une nouvelle h (on va trouver 1 h qui va par \dots). La garantie d'espace linéaire. Puis $\forall j \in \{0, m-1\}$, tant que y a 1 collision de S_j , choisir 1 nouvelle h_j (on va en trouver 1