

Hashing Universal y Perfecto

Note Title

11/3/2009

$$h: [0, M-1] \rightarrow [0, N-1]$$

$$M \gg N$$

h "bien equilibrada" para $S \subset [0, M-1]$

$\hookrightarrow$ si $|S| \leq N$, no hay conflictos

si $|S| > N$, conflictos estan repartidos

Problema $\forall h \exists S$ con muchas colisiones

Soluciones ① Elegir h al azar $\rightarrow$ Universal hash

② Elegir h en funcion de $S \Rightarrow$ Perfect hashing

I Hashing Universal

a) Definición

Una familia H de funciones: $[0, M-1] \rightarrow [0, N-1]$

es 2-universal si

$$\forall x \neq y \in [0, M-1] \quad \Pr_{h \in H} [h(x) = h(y)] \leq \frac{1}{N}$$

→ idea es de elegir h al azar en H

Notaciones

$$C_{x,y} = \begin{cases} 1 & \text{si } h(x) = h(y) \\ 0 & \text{sino} \end{cases} \Rightarrow E(C_{x,y}) = P(C_{x,y} = 1) \quad (*)$$
$$\leq \begin{cases} \frac{1}{n} & \text{si } x \neq y \\ 1 & \text{sino} \end{cases}$$

$$\forall x \quad C_{x,S} = |\{y \in S, C_{x,y} = 1\}| = \sum_{y \in S} C_{xy}$$

Resultado $\forall S \subset [0, n-1] \forall h$ el azar en H

Si H es ℓ -universal y $x \in S$

$$E(C_{x,S}) = \sum_{y \in S} E(C_{xy}) \stackrel{*}{\leq} 1 + \frac{|S|-1}{N}$$

$\xrightarrow{\text{linealidad de } E}$

$$< 1 + \frac{|S|}{N}$$

Corolario Si elijo $|S| = \Theta(N)$ y un h el azar en H universal
el costo esperado de todas las operaciones es $\Theta(1)$

Nota No hay garantía sobre el costo en peor caso.

③ Ejemplo de Familia Universal

$$H_{p,N} = \left\{ h_{a,b} / \begin{array}{l} 1 \leq a < p \\ 0 \leq b < p \end{array} \right\}$$

$$\text{donde } h_{a,b} = \left((ax + b) \bmod p \right) \bmod N$$

$$- p \text{ primo } > N$$


(Nota : en practica p primo "con alta probabilidad")

Lemma H_{pN} es Universal

Intuition de la prueba

Queremos mostrar $\forall x \neq y \Pr_{a,b} [h_{a,b}(x) = h_{a,b}(y)] \leq \frac{1}{N}$

$$\Pr[a, b \text{ elegidos}] = \frac{1}{p(p-1)}$$



Prueba completa en apuntes

② Hashing Perfecto Dado S , como elegir h ?

Una función de hashing $h: [0, n-1] \rightarrow [0, N-1]$ es perfecta para $S \subseteq [0, n-1]$ si:

no genera ninguna colisiones para $x \neq y \in S$

Objetivo Construir tal h ($|S| \leq N$)
(para tener peor caso $\in O(1)$)
* en tiempo polinomial determinística (e.g. N^2)
* al azar (algoritmo de Las Vegas)

ⓐ Caso fácil

Espacio $|S|^2$

* estamos dispuestos a pagar $|S|^2$ de espacio
* elegimos $h \in H$ universal al azar

* $\Pr[h \text{ perfecta para } S] ?$

$\forall x, y \quad \Pr[h(x) = h(y)] \leq 1/N^2$ porque $h \in H$ universal

$$\Pr[\exists x \neq y \in S \quad h(x) = h(y)] \leq \frac{N(N-1)}{2} \cdot \frac{1}{N^2} < \frac{1}{2}$$

$\Rightarrow$ Algoritmo de tipo Las Vegas,
 $O(1)$ iteraciones en promedio, costo $O(|S|)$ (para verificar)

⑥ Caso Real $O(N) = O(|S|)$

① Eligo $h \in H$ universal $[0, n-1] \rightarrow [0, N-1]$

② $B_i \triangleq \# \text{ elementos } x \text{ q. } h(x) = i \quad \forall i \in [0, N-1]$

③ Si $\sum B_i^2 > 4n$, vuelvo al paso ①

* Para cada Celda $i \in [0, N-1]$:

- tenemos un conjunto de tamaño B_i

- podemos "gastar" B_i^2 espacio

- aplicamos el "caso fácil" para cada celda

$\Rightarrow h_0, \dots, h_{N-1}$ funciones de hash "perfectas"
en tiempo lineal en promedio, espacio SN

$$* \Pr \left[\sum B_i^2 \leq 4n \right] ?$$

$$\sum_i B_i^2 = \sum_{x,y} C_{xy}$$

$$B_i^2 = \left((i,j), i,j \in B_i \right) \\ = \{ (i,j), C_{ij} = 1 \}$$

$$E\left(\sum B_i^2\right) = E\left(\sum C_{xy}\right)$$

$$= E\left(\sum_{x=y} C_{xy}\right) + E\left(\sum_{x \neq y} C_{xy}\right)$$

$$\underbrace{\sum_{x=y} C_{xy}}_N + \sum_{x \neq y} E(C_{xy}) \quad \left. \begin{array}{l} \text{Pr}[C_{xy}=1] \leq \frac{1}{N} \\ \text{Si el promedio es } \leq 2N, \text{ al menos la mitad tiene valor } \leq 4N \end{array} \right\}$$

Si el promedio es $\leq 2N$, al menos la mitad tiene valor $\leq 4N$

$\Rightarrow$ con probabilidad $\frac{1}{2}$ $E(T = \sum B_i^2) \in O(n)$

$\Rightarrow$ Algo de Las Vegas para encontrar hash perfecto para S dado.