



HASHING 1

Marcus Ritt

INF 5016/CMP 588 – Algoritmos avançados — Sep 2021 1

1. Introdução
2. Listas encadeadas
3. Seleção de funções hash
4. Endereçamento aberto

strings, números, datas } 264

- Universe de chaves $|U|$, tabela hash H .
- Operações:
 - Inserção de uma chave $c \in U$: insert(c, H)
 - Deleção de uma chave $c \in U$: delete(c, H)
 - Teste da pertinência: Chave $c \in H$? lookup(c, H)





$$[m] = \{1, 2, \dots, m\}$$

- Tabela de tamanho $m \ll |U|$
- Função hash: $h : U \rightarrow [m]$ para posições.
- Problema: *colisão* $h(u_1) = h(u_2)$

- Lista l_i na posição i com $n_i := |l_i|$ elementos

$insert(c, H) :=$


$insert(c, l_{h(c)})$ $O(1)$

$lookup(c, H) :=$

$lookup(c, l_{h(c)})$ $O(n_i)$

$delete(c, H) :=$

$delete(c, l_{h(c)})$ $O(n_i)$



chaves $1, 2, \dots, n$

- Para função hash simples e uniforme:

$$\Pr(h(c) = i) = 1/m.$$



(1)

- Seja c_{ji} a variável aleatória que indica se chave j pertence a lista i

- Temos $\Pr(c_{ji} = 1) = \Pr(h(j) = i)$ e $n_i = \sum_{1 \leq j \leq n} c_{ji}$

- Logo

$$E[n_i] = E\left[\sum_{1 \leq j \leq n} c_{ji}\right] = \sum_{1 \leq j \leq n} E[c_{ji}] = \sum_{1 \leq j \leq n} \Pr(h(c_j) = i) = n/m.$$

1/m

- Onde $\alpha := n/m$ é o fator de ocupação.

Teorema 2.1

Uma busca sem sucesso precisa tempo esperado $\Theta(1 + \alpha)$.

Teorema 2.2

Uma busca com sucesso precisa tempo esperado $\Theta(1 + \alpha)$.

Demonstração Th. 2.1

- (have a fun prob. at the value level i.)
 - Tempo esperado de sucesso: $\Theta(L)$
 - Tempo total: $\Theta(1+L)$
- $\uparrow$ height

Th. 2.2 Tip. chave c é uma das chaves na tabela e prob. uniforme.
 $\Rightarrow$ Prob. pertencer a lista L_i : n_i/n .
 $\Rightarrow$ Custo: $\Theta(1 + E[p])$

Seja: $L_1, L_2, \dots, L_n$ a ordem de $\nearrow$ posição na lista
 marcação: assume: marcação é no início da lista.

$X_{ij} = \begin{cases} 1, & \text{chaves } c_i, c_j \text{ tem o mesmo valor hash} \\ 0, & \text{c.c.} \end{cases}$ $E[X_{ij}] = 1/m$

p_i a posição da chave c_i na sua lista.

$$E[p_i] = E\left[1 + \sum_{j:j > i} X_{ij}\right] = 1 + \sum_{j:j > i} E[X_{ij}] = 1 + (n-i)/m.$$

$$E[p] = \sum_{i \in [n]} 1/n E[p_i] = \sum_{i \in [n]} 1/n \left(1 + \frac{(n-i)}{m}\right) = 1 + \frac{1}{2m} + \frac{(n+1)}{2m}$$

$$\Theta(1 + E[p]) = \Theta(2 + \frac{1}{2} + \frac{1}{2n}) = \Theta(1 + \frac{1}{n})$$

2

LISTAS ENCADEADAS

Demonstração

HASHING 1

Método de

- Divisão

- $h(i) = (i \bmod m)$ é simples e uniforme.
 - Prática: número primo "suficientemente" distante de uma potência de 2.

$$m = 2^l$$



- Multiplicação

$$h(c) = \lfloor m \{A c\} \rfloor$$

$$\{x\} = x - \lfloor x \rfloor$$

- Funciona para qualquer m , mas depende de um $A \in \mathbb{R}$ adequado.
 - Knuth: $A \approx (\sqrt{5} - 1)/2$.

- *Problema*: para função hash h fixa, sempre existe um conjunto de chaves com muitas colisões
- Idéia: $\rightarrow$ escolhe uma *função hash aleatória* de uma família $\mathcal{H}$ de funções.
- Uma família é *universal* se

$$|\{h \in \mathcal{H} \mid h(c_1) = h(c_2)\}| = |\mathcal{H}|/m$$

ou equivalente

$$\Pr(h(c_1) = h(c_2)) = 1/m$$

para todos $h \in \mathcal{H}$

para qualquer par de chaves c_1, c_2 .

Teorema 3.1

Se escolhemos uma função hash $h \in \mathcal{H}$ uniformemente, para uma chave arbitrária c o tamanho esperado de $l_{h(c)}$ é

- α , caso $c \notin H$, e
- $1 + \alpha$, caso $c \in H$

Dem. Fixa c_1, c_2 ; $x_{ij} = [h(c_1) = h(c_2)]$

$$E[x_{ij}] = \Pr[x_{ij} = 1] = \Pr[h(c_1) = h(c_2)] = 1/m.$$

Núm. de colônias de uma colmeia fixa c , y_c .

$$E[y_c] = E\left[\sum_{\substack{c' \in H \\ c' \neq c}} x_{cc'}\right] = \sum_{\substack{c' \in H \\ c' \neq c}} E[x_{cc'}] \leq \sum_{\substack{c' \in H \\ c' \neq c}} 1/m. \}}}$$

$c \notin H$: tamanho y_c : tam. esp. $E[y_c] \leq n/m = \alpha$

$c \in H$: tam. lista y_{c+1} : $E[y_c] = (n-1)/m$

$$E[y_{c+1}] = 1 + (n-1)/m = 1 + \alpha - 1/m < 1 + \alpha$$

Exemplo: Chave $C = (c_0, c_1, \dots, c_r)_m$ $c_i \in [0, m-1]$

$\leftarrow$ no base m

Escolhe $q = (a_0, a_1, \dots, a_r)_m$ aleatoriamente

$$h_a(C) = \left(\sum_{i \in [0, r]} a_i c_i \right) \bmod m.$$

$\hookrightarrow$ universal.

- *Idealmente*: sem colisões. $\rightarrow$ hashing ~~é~~ perfeito.
- **Garantia**: somente com conhecimento das chaves.
- Função aleatória em $\mathcal{H}$: número esperado de colisões

$$E\left[\sum_{i \neq j} X_{ij}\right] = \sum_{i \neq j} E[X_{ij}] \leq n^2/m. < 1.$$


- Logo: número esperado de colisões para tabela de tamanho $m > n^2$ é ≤ 1 .
- Ainda: para $m > cn^2$ com $c > 1$ a probabilidade de uma colisão é

$$\Pr\left(\sum_{i \neq j} X_{ij} \geq 1\right) \leq E\left[\sum_{i \neq j} X_{ij}\right] \leq n^2/m < 1/c.$$

$\Pr[X \geq a] \leq E[X]/a.$
 (Des. Markov)

Open addressing.

- **Colisão**: → selecciona outra posição, visitando os elementos em alguma ordem (π)
- Concretamente: $h(c, \textcircled{1}), \dots, h(c, \textcircled{m})$ é uma **permutação** de $[m]$.
- Função $h(c, i)$ **uniforme**: probabilidade de uma chave aleatória gera dada permutação é $1/m!$.



```

insert(c,H) :=
  for i in [m]
    if H[h(c,i)] = free
      H[h(c,i)] = c
  return
  
```

```

lookup(c,H) :=
  for i in [m]
    if H[h(c,i)] = free
      return false
    if H[h(c,i)] = c
      return true
  return false
  
```


Teorema 4.1

As funções **lookup** e **insert** precisam no máximo $1/(1-\alpha)$ testes caso a chave não está na tabela.

Dem. X : núm. de testes até encontrar uma pos. livre.


$$E[X] = \sum_{i \geq 1} i \cdot \Pr(X=i) = \sum_{i \geq 1} \sum_{j \geq i} \Pr(X=j) \\ = \sum_{i \geq 1} \Pr(X \geq i) \quad ||$$

T_i : evento teste i ocorre e a pos. i ocupada.

$$\Pr(X \geq i) = \Pr(T_1 \cap T_2 \cap \dots \cap T_{i-1}) = \Pr(T_1) \Pr(T_2 | T_1) \Pr(T_3 | T_1, T_2) \\ \dots \Pr(T_{i-1} | T_1, \dots, T_{i-2})$$

$$\Pr(T_1) = n/m = \alpha; \quad \Pr(T_2 | T_1) = (n-1)/(m-1);$$

$$\Pr(T_k | T_1, \dots, T_{k-1}) = (n-k+1)/(m-k+1) \leq n/m = \alpha$$



$$\Pr(X \geq i) \leq \alpha^{i-1}$$


$$\begin{aligned} E[X] &= \sum_{i \geq 1} \Pr(X \geq i) \leq \sum_{i \geq 1} \alpha^{i-1} = \sum_{i \geq 0} \alpha^i \\ &= 1/(1-\alpha). \end{aligned}$$

Lema 4.1

Para $i < j$, temos $H_i - H_j \leq \ln(i) - \ln(j)$.

$$H_i = 1 + 1/2 + 1/3 + \dots + 1/i.$$

$$\begin{aligned} i < j : H_i - H_j &\leq \int_{j+1}^{i+1} \frac{1}{x-1} dx \\ &= \ln(i) - \ln(j). \end{aligned}$$



Teorema 4.2

Caso $\alpha < 1$ a função lookup precisa esperadamente $1/\alpha \ln 1/(1 - \alpha)$ testes caso a chave esteja na tabela, e cada chave tem a mesma probabilidade de ser procurada.

Denn. Chave c ; c foi $\boxed{\frac{1}{\alpha} \ln \frac{1}{1-\alpha}}$
a i -ésima chave encontrada.

Na inserção: $i-1$ chaves; $\alpha = (i-1)/m. \Rightarrow \frac{\# \text{ testes exp. até sucesso}}{\text{profundidade}}.$

$$\rightarrow 1/(1 - (i-1)/m) = m/(m - (i-1)).$$

$$E[T] = \frac{1}{n} \sum_{i \in [n]} \frac{m}{(m - (i-1))} = \frac{1}{\alpha} \sum_{i \in [n]} \frac{1}{m-i} = \frac{1}{\alpha} (\underbrace{H_m - H_{m-n}})$$


$$< \frac{1}{\alpha} (\ln(m) - \ln(m-n)) = \frac{1}{\alpha} \ln \frac{1}{1-\alpha}.$$

4

ENDEREÇAMENTO ABERTO

Demonstração

HASHING 1



- **Linear:** $h(c, i) = h(c) + i \bmod m$
 - **Quadrática:** $h(c, i) = h(c) + c_1 i + c_2 i^2 \bmod m$
 - **Hashing duplo:** $h(c, i) = h_1(c) + i h_2(c) \bmod m$
- (Nenhuma das funções é **uniforme**, mas o hashing duplo mostra um bom desempenho na prática.)