

Estruturas de Dados

aula 28: O truque do passarinho

1 Introdução

Nós vimos que os mecanismos de resolução de colisão por encadeamento externo e endereçamento aberto permitem implementar as operações de acesso aos dados em tempo médio $O(1)$.

Mas para os dois mecanismos, o pior caso da busca ainda é $O(\log n)$ — (*assumindo que as funções de dispersão tem comportamento aleatório*)

Na aula passada, nós vimos uma técnica de dispersão perfeita que resolve esse problema para o mecanismo de encadeamento externo

Quer dizer, a ideia chave foi trocar memória por eficiência na operação de busca.


E hoje nós vamos fazer a mesma coisa, para obter outra técnica que reduz o pior caso da busca para $O(1)$, no mecanismo de endereçamento aberto.

2 O truque do passarinho

A técnica do cuco é baseada na seguinte ideia


→ *Nenhum elemento é o dono da sua posição na tabela*

Quer dizer, se um novo elemento y encontra a sua posição ocupada pelo elemento x , ele pode tirá-lo dali



E agora é o x quem tem o problema de encontrar um lugar para ele.

Daí, nós usamos uma outra função de dispersão $h_2(\cdot)$ para encontrar o lugar de x




E a coisa acaba aí.

Quer dizer, só existem dois lugares para o elemento x na tabela: $h_1(x)$ e $h_2(x)$.

— (*e é isso que vai garantir a busca em tempo $O(1)$, no pior caso*)


Daí, se o x encontra a sua segunda posição ocupada pelo elemento w , ele pode tirá-lo dali



E daí, pode acontecer uma coisa engraçada ...

Quer dizer, imagine que nesse ponto um novo elemento z quer ocupar o lugar onde o x está.

Daí, o x dá o lugar ao elemento z , e volta para a sua posição original tirando o y dali



E agora o y vai ter que procurar outra posição para ele, utilizando a função $h_2(\cdot)$...

Essa técnica é conhecida como *cuckoo hashing* — (ou o esquema de dispersão do cuco)

Mas, vejamos um exemplo concreto para entender melhor como a coisa funciona.

Exemplo: Suponha que nós queremos inserir os seguintes elementos em uma tabela de tamanho 11

20, 50, 53, 75, 89, 39, 3, 67

utilizando as funções de dispersão


$$h_1(x) = x \bmod 11$$

$$h_2(x) = \left\lfloor \frac{x}{11} \right\rfloor \bmod 11$$


Bom, o primeiro passo é pré-calcular as duas posições de cada elemento na tabela

	h_1	h_2		h_1	h_2
20	9	1	89	1	8
50	6	4	39	6	3
53	9	4	3	3	0
75	9	6	67	1	6


Daí, a primeira colisão ocorre quando o 53 toma o lugar do 20



Depois o 75 toma o lugar do 53



A seguir, a chegada do 89 provoca uma grande confusão



- o 89 tira o lugar do 20
- o 20 tira o lugar do 75
- o 75 tira o lugar do 50
- o 50 tira o lugar do 53
- o 53 tira o lugar do 20
- o 20 tira o lugar do 89
- e o 89 entra na posição 8

Daí, acontecem coisas semelhantes com a inserção do 39 e do 3, deixando a tabela assim

3
20
39
50
75
89
53

E finalmente chega o 67.

Quer dizer, quando ele chega acontece o seguinte

- o 67 tira o lugar do 20
- o 20 tira o lugar do 53
- o 53 tira o lugar do 50
- o 50 tira o lugar do 75
- o 75 tira o lugar do 20
- o 20 tira o lugar do 67
- o 67 tira o lugar do 50
- o 50 tira o lugar do 53
- o 53 tira o lugar do 75
- o 75 tira o lugar do 67
- o 67 tira ...

e a coisa entrou em ciclo ...

E agora?

Bom, agora não tem jeito.

Quer dizer, o que está acontecendo é que existem 5 elementos

20, 50, 53, 67, 75

que só podem ocupar 4 posições da tabela

1, 4, 6, 9

e daí a coisa não pode dar certo — (*sempre fica alguém de fora ...*)

3 Implementação

(. . .)

```
função busca-CH ( x, T )
{
    k1  <--  h1(x);    k2  <--  h2(x);

    Se ( T[k1] = x )   Retorna (k1)

    Se ( T[k2] = x )   Retorna (k2)

    Retorna (-1)
}
```

(. . .)

```
função remoção-CH ( x, T )
{
    k  <--  busca-CH (x,T)

    Se ( k = -1 )   Retorna

    T[k] = vazio
}
```

(. . .)

```
função inserção-CH ( x, T )
{
    elem <--  x;      pos <--  h1 (elem)

    Repita ( n vezes )
    {
        Se ( T[pos] == vazio )
        {
            T[pos] = elem;   Retorna
        }

        aux = T[pos]
        T[pos] = elem
        elem = aux

        Se ( pos == h1(elem) )      pos <--  h2 (elem)
        Senão                       pos <--  h1 (elem)
    }

    Rehash()
}
```

Nota: Rehash() é uma função que escolhe duas novas funções de dispersão $h1()$ e $h2()$, e reconstrói a tabela de dispersão.

(. . .)

```
função rehash-CH ( T )
{
    h1 <-- nova função de dispersão
    h2 <-- nova função de dispersão

    Para k <-- 1 Até n
    {
        Se ( T[k] não está vazio )
        {
            elem <-- T[k]

            Se ( h1(elem) != k E h2(elem) != k )
            {
                T[k] <-- vazio

                inserção-CH ( elem, T )
            }
        }
    }
}
```


(. . .)

4 Análise

Nós já vimos que as operações de busca e remoção executam em tempo $O(1)$, no pior caso.


Mas, qual é o tempo médio da operação de inserção?

Bom, para responder essa pergunta, é útil considerar o *grafo de vizinhanças* da tabela cuco



Quer dizer, nesse esquema as setas indicam para onde o elemento vai, quando ele é tirado da sua posição.

Daí, não é difícil ver que a busca percorre dois caminhos nesse grafo



E o tempo médio da inserção é proporcional ao tamanho dos caminhos que ela percorre.

Em outras palavras, a operação de inserção é eficiente se os caminhos que surgem no grafo de vizinhanças da tabela cuco são curtos.


A seguir, nós vamos ver que se a tabela contém muitas posições vazias, então os caminhos são curtos e a inserção executa em tempo médio $O(1)$.

Especificamente, considere uma tabela de tamanho n .

E suponha que ao menos $2n/3$ posições estão vazias.

Para determinar o tamanho médio dos caminhos que surgem nessa tabela, nós fazemos a seguinte pergunta

- Qual é a probabilidade de que o caminho que começa na posição i passe pela posição j ?



Bom, a situação mais simples possível é aquela onde existe uma seta de i para j .

Isso acontece quando existe algum elemento x na tabela tal que

$$h_1(x) = i \quad \text{e} \quad h_2(x) = j$$

Mas a probabilidade de que isso aconteça para um certo elemento x é igual a

$$\frac{1}{\binom{n}{2}} = \frac{2}{n(n-1)}$$

— (*assumindo que as funções h_1, h_2 tem comportamento aleatório*)

Por outro lado, existem até $n/3$ elementos na tabela.

Mas ainda assim, a probabilidade de que algum desses elementos coloque uma seta de i para j é no máximo

$$\frac{n}{3} \cdot \frac{2}{n(n-1)} \simeq \frac{2}{3n}$$

— (*o que é bem pequenininho, quando n é bem grande ...*)

A seguir, nós podemos considerar a possibilidade de que exista um caminho de tamanho 2 entre i e j

$$i \longrightarrow k \longrightarrow j$$

Como indicado no esquema, para que isso aconteça é preciso que exista uma posição k tal que

- existe uma seta entre i e k
- existe uma seta entre k e j

Mas, nós acabamos de ver que a probabilidade de uma seta qualquer é de $2/3n$.

Daí que, a probabilidade de que as duas setas acima existam, para uma certa posição k , é igual a

$$\frac{2}{3n} \cdot \frac{2}{3n} = \left(\frac{2}{3}\right)^2 \cdot \frac{1}{n^2}$$

Por outro lado, existem n posições na tabela que podem fazer o papel de k .

Mas ainda assim, a probabilidade de que exista um caminho de tamanho 2 entre i e j é no máximo

$$n \cdot \left(\frac{2}{3n}\right)^2 \cdot \frac{1}{n^2} = \left(\frac{2}{3}\right)^2 \cdot \frac{1}{n}$$

— (*o que é bem pequenininho, quando n é bem grande ...*)

Agora já deu para o ver o padrão, não é?

Quer dizer, a probabilidade de que exista um caminho de tamanho 3 entre i e j é

$$\left(\frac{2}{3}\right)^3 \cdot \frac{1}{n}$$

e a probabilidade de um caminho de tamanho 4 é de

$$\left(\frac{2}{3}\right)^4 \cdot \frac{1}{n}$$

Daí, a gente observa que

$$\begin{aligned}P(\text{existe um caminho entre } i \text{ e } j) &= P(\text{existe caminho de tamanho } 1) \\&+ P(\text{existe caminho de tamanho } 2) \\&+ P(\text{existe caminho de tamanho } 3) \\&+ P(\text{existe caminho de tamanho } 4) \\&+ \dots\end{aligned}$$

E agora nós podemos escrever

$$P(\text{existe um caminho entre } i \text{ e } j) = \left(\frac{2}{3}\right) \cdot \frac{1}{n} + \left(\frac{2^2}{3}\right) \cdot \frac{1}{n} + \left(\frac{2^3}{3}\right) \cdot \frac{1}{n} + \dots$$

o que a gente reescreve assim

$$P(\text{existe um caminho entre } i \text{ e } j) \leq \frac{1}{n} \cdot \sum_{k=1}^{\infty} \left(\frac{2}{3}\right)^k$$

e depois assim

$$P(\text{existe um caminho entre } i \text{ e } j) \leq \frac{1}{n} \cdot \frac{2/3}{1 - 2/3} = \frac{2}{n}$$

— (*o que é bem pequenininho, quando n é bem grande ...*)

Quer dizer, a probabilidade de que a posição j apareça no caminho que começa em i é bem pequena.

E isso vale para qualquer posição tabela.