

Hashing

Marcelo K. Albertini

19 de junho de 2018

Estrutura abstrata: dicionário

- ▶ Dicionário: operações
 - ▶ `put()`
 - ▶ `get()`
 - ▶ `contains()`
 - ▶ `delete()`
 - ▶ ...
- ▶ Implementações:
`Map<>()`, `Set<>()`
 - ▶ Usar `TreeMap`, `TreeSet` se ordem for importante
 - ▶ Usar `HashMap`, `HashSet` se ordem não for importante

Tabelas de espalhamento = Tabela hash

- ▶ Tabelas de espalhamento = Tabelas hash = Hashtable
- ▶ Hash significa “misturar, bagunçar”

Porquê “espalhar” ajudaria na busca?

Espalhamos elementos em um espaço limitado e montamos uma tabela para saber a posição.

A tabela é definida por uma **função pré-definida** que associa **chaves** com a posição na tabela.

Exemplo de tabela hash

Exemplo: método da divisão (“bubblesort do hashing”)

Usando: `hash(x) = x % 11`

pos	chave
0	11
1	23
2	
3	
4	
5	38
6	
7	29
8	19
9	
10	

Hashing

Valores são mantidos em uma tabela $T[\cdot]$ com m posições indexada de acordo com uma chave.

Função hash

Um método para computar a posição de uma chave em uma tabela: $h : \mathcal{U} \rightarrow \{0, 1, \dots, m - 1\}$.

Aspectos de projeto

- ▶ Como computar a função hash?
- ▶ Como solucionar uma **colisão**, quando $h(x) = h(y)$ e $x \neq y$?

Elementos de uma tabela hash

- ▶ M espaços de memória
- ▶ Função de pré-hashing
 - ▶ conversão do tipo composto em um inteiro (ou long)
- ▶ Hashing
 - ▶ cálculo da posição do inteiro do pré-hashing em uma das M posições da tabela hash
- ▶ Resolução de colisões
 - ▶ Verificação e posicionamento da chave na tabela de acordo com colisões
- ▶ Método de Rehashing
 - ▶ Expansão da tabela (aumento de M) e reposicionamento de chaves caso esteja muito cheia (fator de carga alto)

Análise de Tabelas hash

- ▶ Custos importantes: M , computação de hashings, verificação da igualdade de elementos em caso de colisão
- ▶ Objetivo da análise: como manter M pequeno e reduzir outros custos?

Pré-hashing

Meta

- ▶ computação da hash deve ser barata
- ▶ boa distribuição das chaves nas posições da tabela (cada posição da tabela tem igual chance de receber chaves)

Exemplo: números de telefones

- ▶ Ruim: três primeiros dígitos
- ▶ Melhor: três últimos dígitos

Necessário

- ▶ Um cálculo de Hash diferente para cada tipo de chave

Pré-hashing em Java: hashCode()

- ▶ Todas as classes herdam o método `int hashCode()`
- ▶ **Obrigatório:** Se `x.equals(y)` então `x.hashCode() == y.hashCode()`
- ▶ **Meta:** Se `!x.equals(y)` então `x.hashCode() != y.hashCode()`

Implementação padrão

Uso do endereço de memória do objeto

Implementações por tipo

`Integer`, `Double`, `String`, `File`, `Url`, `Date`,

Revisão: números e operadores do Java

- ▶ `Integer.MIN_VALUE ==`
`0b10000000000000000000000000000000`
- ▶ `-1 == 0b11111111111111111111111111111111`
- ▶ `-2 == 0b11111111111111111111111111111110`
- ▶ `0 == 0b00000000000000000000000000000000`
- ▶ `Byte.MIN_VALUE == 0b10000000 == -128`
- ▶ `Byte.MAX_VALUE == 0b01111111 == 127`
- ▶ Deslocamentos
 - ▶ `0b00010000 << 2 == 0b01000000` (à esquerda)
 - ▶ `0b00010000 >> 2 == 0b00000100` (à direita)
 - ▶ `0b10000000 >> 2 == 0b11100000` (com sinal)
 - ▶ `0b10000000 >>> 2 == 0b00100000` (sem sinal)
- ▶ Lógica bit a bit
 - ▶ `0b10101011 == (~0b01010100)` (negação)
 - ▶ `0b01001111 & 0b10101010 == 0b00001010` (AND)
 - ▶ `0b01001111 | 0b10101010 == 0b11101111` (OR)
 - ▶ `0b01001111 ^ 0b10101010 == 0b11100101` (XOR)

Pré-hashing: implementações do Java

Integer

```
1 int hashCode() {  
2     return value;  
3 }
```

Double

```
1 int hashCode() {  
2     // xor das metades do binario  
3     long bits = doubleToLongBits(this.  
4                                     doubleValue());  
5     return (int)(bits^(bits>>> 32));  
6 }
```

Boolean

```
1 int hashCode() {  
2     if (value)  
3         return 1231;  
4     else  
5         return 1237;  
6 }
```

String

```
1 //s[0]*31^(n-1)+s[1]*31^(n-2)+...+s  
2 [n-1]  
3 public int hashCode() {  
4     int h = 0;  
5     for (int i = 0; i < s.length; i++)  
6         h = s[i] + (31 * h);  
7     return h;  
8 }
```

Pré-hashing: exemplo para tipo composto

```
1 class Transacao {  
2     String quem;  
3     Date quando;  
4     double quanto;  
5  
6     int hashCode() {  
7         int hash = 17;  
8         hash = 31*hash + quem.hashCode();  
9         hash = 31*hash + quando.hashCode();  
10        hash = 31*hash + ((Double) quanto).hashCode();  
11        return hash;  
12    }  
13}
```

Pré-hashing: “receita” para tipo composto

Como fazer

- ▶ Se campo for primitivo, usar o `hashCode()` do wrapper
 - ▶ `Integer` para `int`
 - ▶ `Double` para `double`
- ▶ Se campo for tipo composto, usar `hashCode()`
- ▶ Se campo for `array`, usar hash para cada campo
- ▶ Se campo for `null`, usar 0
- ▶ Combinar cada campo `x` na hash com a operação
 $31 * \text{hash} + x.hashCode()$

Funções de hashing: tipos

- ▶ Funções simples para hashing (não recomendável usar)
 - ▶ Método da divisão: $h(x) = x \% m$ (ad hoc)
 - ▶ Método da multiplicação (ad hoc)
- ▶ Famílias de Funções de Hashing (modelos)
 - ▶ Família Uniforme
 - ▶ Família Universal
 - ▶ Família Quasi-universal
 - ▶ Família k -uniforme
 - ▶ ...

Funções hash: método da divisão

Sendo

- ▶ chave é um inteiro não-negativo k
- ▶ temos m posições na tabela
- ▶ a posição na tabela pela chave k é obtida pela função hash $h(k)$

Método da divisão

$$h(k) = k \bmod m$$

Funções hash: método da divisão

Método da divisão

$$h(k) = k \bmod m$$

- ▶ Se tabela tem $m = 1699$ posições e chave for $k = 25657$, a posição da tabela é $h(k) = 172$
- ▶ **Evitar** o uso de valores para m que sejam **potência de 2**
 - ▶ Se $m = 2^p$, h se torna somente p bits de baixa ordem de k
- ▶ Sugestão frequente: “Escolher para m um valor primo não próximo de uma potência de 2”
- ▶ **Na prática:** **NÃO USAR PARA CÓDIGOS REAIS** pois é fácil obter colisões

Implementação de hashing em Java: hash()

- ▶ Recebe pré-hashing de `hashcode()`: `int` entre -2^{31} e $2^{31} - 1$
- ▶ Função hash: índice da tabela de 0 a $M - 1$ para tabela com M posições

```
1 hash(Chave c) { // Código ERRADO
2     return c.hashCode() % M; // BUG
3 }
```

Código errado! Problema com negativos.

```
1 hash(Chave c) {
2     return Math.abs(key.hashCode()) % M; // BUG
3 }
```

Código errado! Problema com -2^{31} . `Math.abs(-231) < 0!`

```
1 int hash(Chave c) { // Código CERTO
2     return (c.hashCode() & 0x7fffffff) % M;
3 }
```

Funções hash: método da multiplicação

Método da multiplicação

Multiplicar a chave $k \geq 0$ por uma constante $0 < A < 1$, extrair a parte fracional, multiplicar esse valor pelo número m de posições na tabela e pegar a parte inteira arredondada para baixo com uma função *floor*.

$$h(k) = \text{floor}(m(kA \bmod 1)), \text{ onde } A \approx (\sqrt{5} - 1)/2 \approx 0.618$$

```
1 static double A = (Math.sqrt(5.0) - 1.0) / 2.0;
2 int hash2(Chave c) {
3     int k = c.hashCode() & 0xffffffff;
4     double fracional = (k*A) % 1;
5     return (int) Math.floor(M * fracional);
6 }
```

Exemplo

Se $m = 2000$ e chave for 6341, a posição obtida pela função hash $h(k)$ é 1476.

Funções hash: métodos da divisão e multiplicação

- ▶ Vantagens:
 - ▶ Simplicidade
- ▶ Desvantagens:
 - ▶ para todos inteiros a e x temos $h(x + a \times m) = h(x)$ de maneira predizível

Resolução de colisões

Uma boa função hash deve espalhar uniformemente valores no array.

Colisões

Valores distintos mapeados na mesma posição de um array são chamados de **colisões**

Exemplo: em uma tabela de tamanho M e método divisivo

$\text{hash}(2.1) == 1$

$\text{hash}(1.4) == 1$

$\text{hash}(7.1) == 1$

Colisões

Desafio

Tratar colisões eficientemente

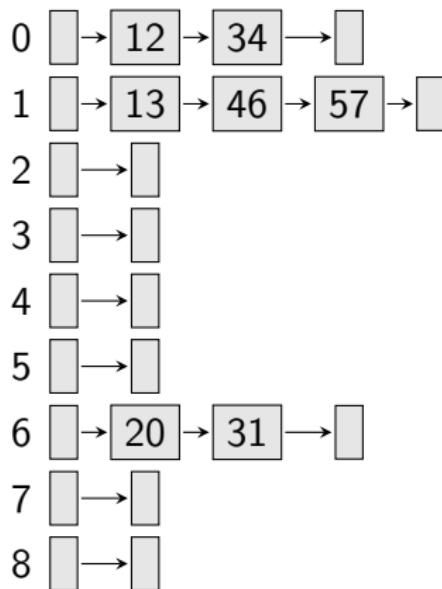
- ▶ é muito caro evitar colisões (memória $O(n^2)$)
- ▶ suposição comum: colisões são uniformemente distribuídas

Resolução de colisões

- ▶ Dois estilos principais de tratar de colisões
 - ▶ Encadeamento das colisões ou endereçamento fechado (Estilo HashMap do Java)
 - ▶ Sondagem ou endereçamento aberto (Estilo dict do Python)

Tabela Hash com encadeamento

- ▶ Tabela T tem M posições
- ▶ $T[1]$ tem lista de chaves colidindo: $h(13) = h(46) = h(57)$



Análise exata de custo de busca mal-sucedida

- ▶ Hash table com resolução por encadeamento em M listas
- ▶ Seja $|\mathbf{T}[i]|$ o número de chaves em $T[i]$ (colisões em i)
- ▶ Custos:
 - ▶ computação pré-hashing e hashing custa C_h
 - ▶ verificação de igualdade custa C_i
- ▶ Custo de busca mal-sucedida:

$$C_h + |\mathbf{T}[i]| \times C_i$$

Análises de custos

- ▶ Problema: balancear uso da memória com o número de colisões
- ▶ Qual é o número médio de colisões $E [|T[i]|]$?
- ▶ Como obter um limitante superior para o número de colisões $[\max |T[i]|]$?
- ▶ Como escolher tamanho da tabela M para reduzir chance de colisões?
- ▶ Como escolher o tamanho de redimensionamento da tabela para fazer rehashing?

Modelo de distribuição de entradas

- ▶ É difícil caracterizar a distribuição de entradas
- ▶ É mais fácil usar famílias de Hashing que garantem propriedades independentemente das entradas
 - ▶ Famílias de Hashing Uniforme
 - ▶ Famílias de Hashing Universal

Análise de Hashing: exemplo

- ▶ Também conhecido com “Paradoxo do aniversário”
- ▶ Temos M dias, grupo de N pessoas
- ▶ Seja i, j um par de pessoas, definir

$$X_{i,j} = \begin{cases} 1 & \text{niver}(i) = \text{niver}(j) \\ 0 & \text{caso contrário} \end{cases}$$

- ▶ **Suposição:** aniversários acontecem uniformemente ao longo do ano: $P[X_{i,j}] = 1/M$
- ▶ Em grupo de N pessoas, quantos aniversários acontecem no mesmo dia?

$$E \left[\sum_{\text{pares } i,j} X_{i,j} \right] = \sum_{\text{pares } i,j} E[X_{i,j}] = \binom{N}{2} \frac{1}{M}$$

- ▶ Tamanho de um grupo para 2 fazerem aniversário juntos?
 - ▶ Ou seja, qual é o N em $1 = \binom{N}{2} \frac{1}{M} = \frac{N(N-1)}{2M}$? $N \approx 27$

Premissa da Família de Hashing Uniforme

- ▶ Seja um conjunto de funções de hashing \mathcal{H}

$$P_{h \in \mathcal{H}}[h(x) = i] = \frac{1}{m}$$

para todo x e todo i

- ▶ Ideia: Todas as posições da tabela são igualmente prováveis para “espalhar chaves uniformemente”

Hashing uniforme NÃO É suficiente: exemplo de família

- ▶ Parece razoável mas não é suficiente para termos boas funções hash
- ▶ Seja $K = \{const_a | 0 \leq a \leq m - 1\}$ tal que $const_a(x) = a$
- ▶ Temos que $P_{h \in K}[h(x) = i] = \frac{1}{m}$ pois existem m opções para o valor a
e $P(h(x) = i) = P(a) \cdot P(h(x) = a) = \frac{1}{m} \cdot 1$

Família de Hashing Universal

- Ideia: “minimizar colisões”

$$P_{h \in H}[h(x) = h(y)] = \frac{1}{m}$$

para $x \neq y, \forall x, y$

- Quase-universal: $P[h(x) = h(y)] \leq \frac{c}{m}$ com c constante

Hashing universal

Se há m para serem selecionados aleatoriamente e colisões tem probabilidade de $1/m$ então essa função hash é universal.

$$P(h = i) = \frac{1}{m} \quad (1)$$

- ▶ Aplicações
 - ▶ Evitar ataques a uma função hash – exploração do pior caso
 - ▶ Reconstrução da hash quando fator de carga mostra risco de colisão

Família de Hashing Universal: exemplo 1

- ▶ Família de Hashing Multiplicativo Primal é
 $MP = \{multp_a | a \in [1 \dots p - 1]\}$
- ▶ Definir número primo $p > |U|$, onde U é o conjunto de todos os valores de hashing
- ▶ Definir inteiro $a \in [1 \dots p - 1]$ chamado **salt**
- ▶ A função de hashing é

$$multp_a(x) = (ax \mod p) \mod m$$

Família de Hashing Universal: exemplo 2

- ▶ Dietzfelbinger et al. (1997) “A Reliable Randomized Algorithm for the Closest-Pair Problem”
- ▶ Hashing binário multiplicativo
- ▶ Tabela tem $m = 2^l$ posições e pré-hashing produz inteiros com w bits
- ▶ Usar um valor aleatório de salt $a \in [0, 2^w[$
- ▶
$$multb_a(x) = \left\lfloor \frac{(a \cdot x) \bmod 2^w}{2^{w-l}} \right\rfloor$$
- ▶ `#define hash(a,x) ((a)*(x) >> (WORDSIZE - HASHBITS))`

Custo médio de busca mal-sucedida

- ▶ Tabela hash com encadeamento e família universal \mathcal{H}
 - ▶ Custo exato é $c_h + |T[i]|c_i$
 - ▶ Custo médio é $c_h + E [|T[i]|] c_i$
- ▶ Temos que o tamanho da lista de colisões em $h(x)$ é, para cada chave k na tabela T ,

$$|T[h(x)]| = \sum_{k \in T} \delta_{h(k), h(x)}$$

- ▶ Portanto queremos achar $E [|T[h(x)]|]$

Custo médio de busca mal-sucedida: continuação

- ▶ Como busca é mal-sucedida temos que $x \notin T$ e $x \neq k$, então

$$E [|T[h(x)]|] = E \left[\sum_{k \in T} \delta_{h(k), h(x)} \right] = \sum_{k \in T} E [\delta_{h(k), h(x)}]$$

- ▶ Sendo $h \in H$ uma Família Universal, temos

$$E[\delta_{h(k), h(x)}] = \begin{cases} 1 & \text{se } k = x \\ 1/M & \text{se } k \neq x \end{cases}$$

- ▶ Dessa forma, com $N = |T|$, o custo é

$$\sum_{k \in T} E [\delta_{h(k), h(x)}] = \left(\sum_{k \in T} \frac{1}{M} \right) = \frac{N}{M}$$

- ▶ Definimos a quantidade $\alpha = \frac{N}{M}$ como o **fator de carga**

Análise do maior número de colisões no caso médio

- ▶ Objetivo: obter limite superior com alta probabilidade para número de colisões
- ▶ Resultado da análise: se tabela tem carga $\alpha = 1$, para N chaves, o número de colisões é $O(\log N / \log \log N)$ com alta probabilidade
- ▶ Chance de uma lista X_j ter pelo menos K chaves é:

$$P[X_j \geq K] = \binom{N}{K} \left(\frac{1}{N}\right)^K$$

onde $\binom{N}{K}$ é o número de formas de distribuir K chaves em N posições, $\left(\frac{1}{N}\right)^K$ é chance de cada chave cair em j

- ▶ A partir de $P[X_j \geq K]$ queremos achar uma função $f(N) = K$ tal que a probabilidade $P[\max_j X_j \geq f(N)]$ seja pequena

Análise do maior número de colisões no caso médio (1)

$$\begin{aligned} P[X_j \geq K] &= \binom{N}{K} \left(\frac{1}{N}\right)^K \\ &= \frac{N!}{K!(N-K)!} \left(\frac{1}{N}\right)^K \\ &\leq \frac{N(N-1)(N-2)\cdots(N-(K-1))}{K!} \left(\frac{1}{N}\right)^K \\ &\leq \frac{N^K}{K!} \left(\frac{1}{N}\right)^K = \frac{1}{K!} \end{aligned}$$

Assim, $P[X_j \geq K] \leq \frac{1}{K!}$ e como

$$\begin{aligned} K! &= K(K-1)(K-2)(K-3)\dots \\ K(K-1)(K-2)\dots 3 \cdot 2 \cdot 1 &= (K \cdot 1)((K-1) \cdot 2)((K-2) \cdot 3)\dots \\ K! &\geq K^{K/2} \\ 1/K! &\leq 1/K^{K/2} \end{aligned}$$

Então

$$P[X_j \geq K] \leq \frac{1}{K!} \leq \frac{1}{K^{K/2}}$$

Análise do maior número de colisões no caso médio (2)

- Fazendo $K = 4c \lg N / \lg \lg N$ em $P[X_j \geq K] \leq \frac{1}{K^{K/2}}$

$$K^{K/2} = \left(\frac{4c \lg N}{\lg \lg N} \right)^{2c \lg N / \lg \lg N} \geq \left(\sqrt{\lg N} \right)^{2c \lg N / \lg \lg N}$$

Pois temos que $4c \frac{\lg N}{\lg \lg N} = w(\sqrt{\lg N})$ ao fazer $x = \lg N$ em

$$\lim_{N \rightarrow \infty} \frac{4c \frac{\lg N}{\lg \lg N}}{\sqrt{\lg N}} = \frac{\frac{4cx}{\lg x}}{x^{1/2}} = \frac{4c \sqrt{x}}{\lg x} = \infty$$

Por sua vez

$$(\sqrt{\lg N})^{\frac{2c \lg N}{\lg \lg N}} = \left[(\lg N)^{\frac{1}{\lg \lg N}} \right]^{c \lg N} = 2^{c \lg N} = N^c$$

- sendo que $(x)^{\frac{1}{\lg x}} = (x)^{\frac{1}{\log_x x / \log_x 2}} = (x)^{\frac{1}{1 / \log_x 2}} = x^{\log_x 2} = 2$
- Portanto $P[X_j \geq \frac{4c \lg N}{\lg \lg N}] \leq \frac{1}{N^c}$

Análise do maior número de colisões no caso médio (3)

- ▶ Até agora vimos que $P\left[X_j \geq \frac{4c \lg N}{\lg \lg N}\right] \leq \frac{1}{N^c}$
- ▶ Queremos achar $f(N)$ para quando $P[\max_j X_j \geq f(N)]$ tem baixa probabilidade.
- ▶ Usando o limitante da união: $P(A \cup B) \leq P(A) + P(B)$ e que $P[\max_j X_j \geq f(N)] = P\left[\bigcup_{j=0}^{N-1} (X_j \geq f(N))\right]$
- ▶ temos
$$P\left[\bigcup_{j=0}^{N-1} X_j \geq f(N)\right] \leq \sum_{j=0}^{N-1} P\left[X_j \geq \frac{4c \lg N}{\lg \lg N}\right] \leq N \frac{1}{N^c} = \frac{1}{N^{c-1}}$$
- ▶ Portanto, $\max_j X_j = O(\lg N / \lg \lg N)$ com alta probabilidade $1 - O(N^{-c})$

Controle do número de colisões usando M

- ▶ Usando a análise do Paradoxo do aniversário, o número médio de colisões é

$$E \left[\sum_{\text{pares } i,j} X_{i,j} \right] = \binom{N}{2} \frac{1}{M}$$

- ▶ Se usarmos bastante espaço, $M = N^2$, então o número esperado de colisões será

$$\frac{N(N-1)}{2} \frac{1}{N^2} \leq 1/2$$

- ▶ Então o custo médio de busca mal-sucedida será $c_h + c_i/2 = O(1)$ ao pagarmos um preço de $O(N^2)$ de espaço

Controle do número de colisões usando M e alta prob.

- ▶ Seja X_j o número de colisões na posição j
- ▶ Queremos achar uma fórmula que liga o número de colisões com M para $\alpha < 1$
- ▶ Ou seja, buscamos uma fórmula para fazer $P[\max_j X_j \leq 1]$ ter alta probabilidade

Controle do número de colisões usando M e alta prob. (1)

- ▶ Primeiro devemos achar

$$P[X_j > 1] = 1 - P[X_j = 0] - P[X_j = 1]$$

- ▶ Como a chance de uma chave não cair na posição j é
 $P[X_j = 0] = (1 - 1/M)$, então, para N chaves,

$$P[X_j = 0] = \left(1 - \frac{1}{M}\right)^N = \sum_{i=0}^{\infty} \binom{N}{i} \left(\frac{-1}{M}\right)^i = 1 - \frac{N}{M} + \Theta\left(\frac{N^2}{M^2}\right)$$

usando expansão binomial de Newton

$$\begin{aligned} P[X_j = 1] &= \frac{N}{M} \left(1 - \frac{1}{M}\right)^{N-1} \\ &= \sum_{i=0}^{\infty} \binom{N-1}{i} \left(\frac{-1}{M}\right)^i \\ &= \frac{N}{M} \left(1 - \frac{N-1}{M} + \Theta\left(\frac{N^2}{M^2}\right)\right) \end{aligned}$$

Controle do número de colisões usando M e alta prob. (2)

- Queremos achar $P[X_j > 1] = 1 - P[X_j = 0] - P[X_j = 1]$

$$P[X_j > 1] = 1 - \left[1 - \frac{N}{M} + \Theta\left(\frac{N^2}{M^2}\right) \right] - P[X_j = 1]$$

$$P[X_j > 1] = \frac{N}{M} + \Theta\left(\frac{N^2}{M^2}\right) - P[X_j = 1]$$

$$P[X_j > 1] = \frac{N}{M} + \Theta\left(\frac{N^2}{M^2}\right) - \frac{N}{M} \left(1 - \frac{N-1}{M} + \Theta\left(\frac{N^2}{M^2}\right)\right)$$

$$P[X_j > 1] = \Theta\left(\frac{N^2}{M^2}\right) + \frac{N}{M} \frac{N-1}{M} - \frac{N}{M} \Theta\left(\frac{N^2}{M^2}\right)$$

- Usando $N < M$, $P[X_j > 1] < \frac{N(N-1)}{M^2}$

Controle do número de colisões usando M e alta prob. (3)

- ▶ Usando o limitante da probabilidade da união

$$\begin{aligned} P \left[\max_j X_j > 1 \right] &= P [X_j > 1 \text{ para } \forall j] \\ &< \sum_{j=0}^{M-1} \frac{N(N-1)}{M^2} = N(N-1)/M \end{aligned}$$

- ▶ Portanto, se usarmos $M = N^{2+\epsilon}$ temos probabilidade menor que $1/N^\epsilon$ de não haver colisões
- ▶ Se usarmos $M = cN^2$, o número esperado de colisões é $E_{\forall \text{ pair } x,y \in T} [h(x) = h(y)] < 1/c$

Controle de colisões: método da matriz usando hashing universal

Método da matriz

Chave x tem u bits. Tamanho da tabela M é uma potência de 2.

Assim, um índice tem b bits tal que $M = 2^b$. É universal pois a probabilidade de colisão é igual ou menor que $1/M$.

Passos do algoritmo de hash

1. obter representação binária x da chave
2. definir aleatoriamente uma matriz h de tamanho $b \times u$ com valores 0 ou 1
3. obter o hash usando a multiplicação $h(x) = hx$ e fazendo soma resto 2.

Exemplo:

$$h = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 \end{pmatrix}, x = \begin{pmatrix} 1 \\ 0 \\ 1 \\ 0 \end{pmatrix}, h(x) = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} \quad (2)$$

Existe uma chance de $1/2^b$ de colisão.

Hashing perfeito

- ▶ No hashing perfeito queremos custo de busca seja $O(1)$
- ▶ Também queremos que o uso do espaço total seja $O(N)$
- ▶ Como fazer? Podemos usar no segundo nível da hash table outras hash tables encadeadas
 - ▶ Seja $N_j = |T[j]|$
 - ▶ Tamanho da tabela no primeiro nível é $M = N$
 - ▶ Tamanho M_j da tabela de segundo nível na posição j será $M_j = 2N_j^2$
 - ▶ Portanto, o número esperado de colisões nas tabelas secundárias será $< 1/2$
 - ▶ O custo médio de busca será $c_{\text{prehashing}} + 2c_{\text{hashing}} + \frac{1}{2}c_i$
- ▶ Qual é o espaço total médio usado? Calcular
$$E \left[\sum_{j=0}^{M-1} 2|T[j]|^2 \right]$$

Hashing perfeito com espaço $O(N)$

- Calcular $E \left[\sum_{j=0}^{M-1} 2N_j^2 \right] = 2 \sum_{j=0}^{M-1} E \left[N_j^2 \right]$

$$\begin{aligned}\sum_{j=0}^{M-1} N_j^2 &= \sum_{j=0}^{M-1} \left(\sum_{x \in T} \delta_{h(x),j} \right)^2 \\&= \sum_{j=0}^{M-1} \left(\sum_{x \in T} \delta_{h(x),j} \right) \left(\sum_{y \in T} \delta_{h(y),j} \right) \\&= \sum_{j=0}^{M-1} \sum_{x \in T} \sum_{y \in T} \delta_{h(x),j} \delta_{h(y),j} \\&= \sum_{j=0}^{M-1} \left(\sum_{x=y \in T} [\delta_{h(x),j}]^2 + \sum_{x \neq y \in T} \delta_{h(x),j} \delta_{h(y),j} \right) \\&= \sum_{x=y \in T} \sum_{j=0}^{M-1} [\delta_{h(x),j}]^2 + \sum_{x \neq y \in T} \sum_{j=0}^{M-1} \delta_{h(x),j} \delta_{h(y),j} \\&= \sum_{x \in T} \sum_{j=0}^{M-1} [\delta_{h(x),j}]^2 + \sum_{x \neq y \in T} \delta_{h(x),h(y)} \\&= N + \sum_{x \neq y \in T} \delta_{h(x),h(y)}\end{aligned}$$

- com $\sum_{x \in T} \sum_{j=0}^{M-1} [\delta_{h(x),j}]^2 = N$ pois é a contagem de 1² das chaves em suas posições na tabela T

Hashing perfeito com espaço $O(N)$ – continuação

- ▶ Calcular $E \left[\sum_{j=0}^{M-1} 2N_j^2 \right] = 2 \sum_{j=0}^{M-1} E \left[N_j^2 \right]$

$$\begin{aligned} E \left[\sum_{j=0}^{M-1} N_j^2 \right] &= E[N] + E \left[\sum_{x \neq y \in T} \delta_{h(x), h(y)} \right] \\ &= N + (N^2 - N) \frac{1}{M} \quad (\text{hashing universal}) \\ &= N + (N - 1) = 2N - 1 \quad (1^\circ \text{ nível } M = N) \end{aligned}$$

$$2E \left[\sum_{j=0}^{M-1} N_j^2 \right] = 4N - 2$$

- ▶ Portanto, o custo de espaço do Hashing Perfeito usando 2 níveis é $4N - 2 = O(N)$ com uma família universal de funções hash.

Uso de outras estruturas para tratar colisões

- ▶ Árvore de Busca Binária Balanceada
 - ▶ Custo de busca será $c_h + \lg |T[x]|c_i$
 - ▶ Usado como última linha de defesa contra degradação da hash
- ▶ Outras hash tables com M posições
 - ▶ Similar a árvore com bifurcação M
 - ▶ Custo de busca será $c_h + \log_M |T[x]|c_i$
 - ▶ Se $M = \sqrt{N}$, no pior caso, será $c_h + \log_{\sqrt{N}} N c_i = c_h + 2c_i$

Exemplo de Tabela com Encadeamento: HashMap Java

- ▶ java.util.HashMap (Java 9)
- ▶ Fator de carga máximo padrão: 0.75
- ▶ Endereçamento fechado – uso de buckets
 - ▶ Buckets são listas se número de colisões < 8
 - ▶ Lista vira árvore Rubro-Negra para ≥ 8 colisões
 - ▶ Usa pre-hashing ou função de comparação
- ▶ Mapeamento em posição é feito com
`hash(key) & (length - 1)`

```
1 static final int hash( Object key ) {  
2     int h;  
3     return (key == null) ?  
4             0 : (h = key.hashCode()) ^ (h >>> 16);  
5 }
```

Tabela de símbolos: sondagem linear

Endereçamento aberto

Usar apenas o array da tabela. Não usar listas ligadas.

Ideia: inserção

- ▶ Se houver uma colisão, buscar algum lugar vazio nas posições seguintes

Busca

- ▶ Verificar se o elemento na posição da hash da chave é o procurado
- ▶ Procurar nas posições seguintes até encontrar um vazio

Array tem que ser maior que o número de elementos a serem inseridos.

Tabela hash com sondagem linear

```
1 class TabelaHash<Chave, Valor> {
2     int M; // tamanho
3     Chave[] chaves;
4     Valor[] valores;
5
6     public TabelaHash(int M) {
7         chaves = (Chave[]) new Object[M];
8         valores = (Valor[]) new Object[M];
9         this.M = M;
10    }
11
12    void put(Chave c, Valor v) {
13        ...
14    }
15    void get(Chave c) {
16        ...
17    }
18 }
```

Hashing com sondagem linear

```
1 void put(Chave c, Valor v){  
2     int h = hash(c);  
3  
4     if (chaves[h] == null) {  
5         chaves[h] = c;  
6         valores[h] = v;  
7     } else { // colisão  
8         while(++h < M &&  
9             chaves[h] != null) {}  
10        if (h == M) {  
11            // tabela cheia  
12            // reestruturar tabela  
13        }  
14        chaves[h] = c;  
15        valores[pos] = v;  
16    }  
17}
```

M = 13

pos	chave
0	0
1	2.1
2	1.4
3	5.1
4	7.1
5	-1.1
6	6
7	
8	
9	
10	
11	1.3
12	1.3

Tabela Hash com resolução de colisões por sondagem

- ▶ Tabela de M posições de memória
- ▶ Cada posição contém só 1 chave
- ▶ Se ocorrer colisão, uma recorrência indicará próxima posição que será verificada para inserção
- ▶ Define uma sequência de funções hash:

$$\langle h_0, h_1, h_2, \dots, h_{M-1} \rangle$$

- ▶ Para uma chave x , temos uma sequência de sondagem

$$\langle h_0(x), h_1(x), h_2(x), \dots \rangle$$

- ▶ Idealmente, a sequência de sondagem deve ser uma permutação das posições da tabela $[0, M - 1]$

Tabela Hash com resolução de colisões por sondagem: operações

- ▶ Inserção
 - ▶ Inserir na primeira posição vazia indicada pela sequência de sondagem
- ▶ Busca
 - ▶ Verificar cada posição indicada pela sequência de sondagem até atingir posição vazia
- ▶ Remoção
 - ▶ Usar marcador de remoção
 - ▶ Alternativa: reposicionar cada colisão da mesma sequência de sondagem

Resolução de colisões por sondagem: tipos de recorrência

- ▶ Sondagem Linear

$$h_i(x) = (h(x) + i) \mod M$$

bom para caching, mas tem efeito de “clustering”

- ▶ Sondagem Binária

$$h_i(x) = h(x) \oplus i$$

Tabela Hash com resolução de colisões por sondagem: análise

- ▶ Premissa Forte de Hashing Uniforme (PFHU)
 - ▶ Para qualquer chave x , a sequência de sondagem é um sorteio de uma permutação das posições da tabela $[0, M - 1]$ com probabilidade uniforme do conjunto de todas as permutações
 - ▶ Independencia: a sequência de sondagem $\langle h_i(x), h_{i+1}(x), h_{i+2}(x), \dots \rangle$ continua sendo uma permutação uniforme após a sondagem de $\langle h_0(x), \dots, h_{i-1} \rangle$
- ▶ Sob a PFHU temos:
 - ▶ $P[\text{colisão em } h_0(x)] = \frac{N}{M}$ para tabela com N chaves e M posições
 - ▶ Premissa facilita análise, mas não existe (sequência) hash que comprovamente é PFHU

Tabela Hash com resolução de colisões por sondagem: análise

- ▶ Recorrência do número médio de sondagens necessárias, com mínimo de uma sondagem para tabela vazia $T(M, 0) = 1$,
- ▶ Usando indução provamos que $T(M, N) < \frac{M}{M-N}$

$$\begin{aligned} T(M, N) &= 1 + \frac{N}{M} T(M - 1, N - 1) \\ &< 1 + \frac{N}{M} \frac{M-1}{(M-1)-(N-1)} \quad (\text{aplicando } \frac{M}{M-N}) \\ &< 1 + \frac{N}{M} \frac{M-1}{M-N} \\ &< 1 + \frac{N}{M} \frac{M}{M-N} \quad (\text{troca } M-1 \text{ por } M) \\ &= 1 + \frac{N}{M-N} = \frac{M-N+N}{M-N} = \frac{M}{M-N} \\ &= \left(\frac{M-N}{M}\right)^{-1} = (1-\alpha)^{-1} \end{aligned}$$

- ▶ Com fator de carga $\alpha = M/N$
- ▶ Portanto temos que $T(M, N) < \frac{1}{1-\alpha}$ e $T(M, N) = O(1)$

Implementação Tabela Hash: Python

- ▶ Pre-hashing: link para pyhash.c
 - ▶ Tipos compostos: Função Hash Fowler Noll Vo (FNV) Modificada

```
1 hash = FNV offset basis // uma constante pré-definida
2 for each byte of data to be hashed
3     hash = hash * FNV prime (mod 2^N)
4     hash = hash XOR byte of data
5 return hash
```

- ▶ Dicionário (hash table): link para dictobject.c
- my_dict = {1: 'apple', 2: 'ball'}
- ▶ Endereçamento aberto, pseudo-random probing pela recorrência: $j = ((5 * j + 1) \bmod 2 * *i)$
- ▶ Fator de carga máximo: 0.66

Análise: sondagem linear

Knuth (1962): problema do estacionamento

Sob a premissa de espalhamento uniforme ($P[h(x) = j] = 1/M$), a média de sondagem de uma tabela hash de tamanho M que contém $N = \alpha M$ chaves, $0 < \alpha < 1$ é:

Para busca (encontrando)

$$\leq \frac{1}{2} \left(1 + \frac{1}{1-\alpha} \right)$$

Para inserção (ou busca sem encontrar)

$$\leq \frac{1}{2} \left(1 + \frac{1}{(1-\alpha)^2} \right)$$

Análise: sondagem linear

Avaliação de carga de uma hash table: risco de colisões

taxa de ocupação $\alpha = \frac{\text{número de elementos}}{\text{tamanho da tabela}}$

Quando taxa de ocupação $\alpha = N/M$

- ▶ Se M alto, muitas posições vazias no array
- ▶ Se M pequeno, tempo de busca aumenta devido a agrupamento
- ▶ Com $\alpha = 1/2$, sondagens para busca é cerca de $3/2$.
- ▶ Com $\alpha = 1/2$, sondagens para inserção é cerca de $5/2$

Endereçamento aberto: premissa do espalhamento uniforme

Temos espalhamento perfeitamente uniforme quando
Cada chave é igualmente provável a ser mapeada para um inteiro entre 0 e $M-1$.

Propriedades conhecidas

- ▶ Duas chaves terão a mesma posição na tabela (**colidirão**) após cerca de $\sqrt{\pi M}/2$ chaves aleatórias
- ▶ Cada inteiro terá sido utilizado para mapear pelo menos uma vez após $\approx M \ln M$ chaves
- ▶ Após M chaves, o inteiro mais mapeado foi usado $\Theta(\log M / \log \log M)$ vezes

Variações de hashing

- ▶ Hashing encadeado duplo
 - ▶ Obter 2 hashes para uma chave e inserir na cadeia menor
 - ▶ Reduz tamanho esperado da maior cadeia para $\log \log N$
- ▶ Hashing com sondagem variável
 - ▶ Usar sondagem linear com saltos variáveis maiores que 1
 - ▶ Reduz agrupamento
- ▶ Cuckoo hashing
 - ▶ Faz 2 hashes por chave; insere chave em uma das posições; se ocupado reinsere a chave deslocada na posição alternativa (com recorrência) (com recorrência)
 - ▶ **Pior caso garantido constante para busca**

Cuckoo hashing

Estratégia

- ▶ Usar **duas** funções **hashes**
 - ▶ Exemplo 1: método da divisão
 - ▶ Exemplo 2: método da multiplicação

Na busca `get(c)`

- ▶ c pode estar na posição da hash 1 ou da hash 2

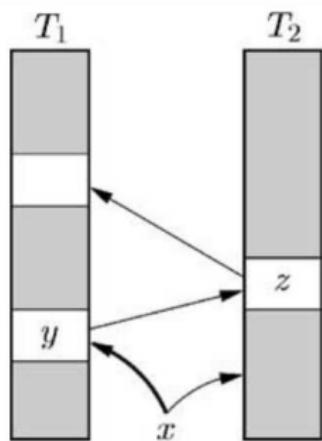
Na inserção `put(c, v)`

1. Tentar a hash 1, se estiver ocupado tentar hash 2
2. Se hash 2 ocupado, substituir o que estava ali e reposicioná-lo
3. Se houver até $6 \log n$ substituições, parar e reconstruir o hash com mais espaço

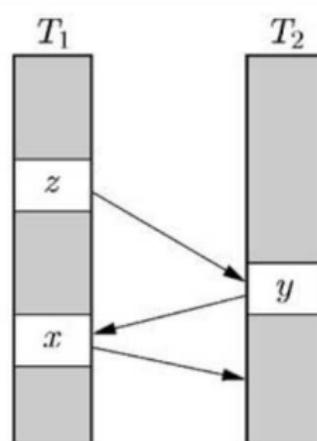
Video: <http://www.youtube.com/watch?v=dAU5MTXmAPY>

`put(x)`

Artigo: *Cuckoo hashing, Pagh & Rodler. 2004*



(a)



(b)

- (a) Operação bem sucedida
- (b) Operação mal sucedida: rearranjar

Hashing com encadeamento

- ▶ Tamanho da tabela:

Cuckoo hashing: análise

- ▶ Tempo de construção esperado: $O(n)$

Cuckoo hashing: tempo de construção

- ▶ Condições:
 - ▶ 2 tabelas de endereçamento aberto com $(1 + \epsilon)n$, ϵ chaves

Cuckoo hashing: operação put

```
1 // assume que chave não está na tabela
2 void put(Chave c, Valor v) {
3     int cuckoos = 0; int limite = (int)(log(++N)*6+1);
4     Integer h1 = hash1(c), h2 = hash2(c);
5     Chave ctmp = null; Valor vttmp = null;
6
7     while (cuckoos++ <= limite) { //garantia probabilística
8         if (h1 != null) { //insere com hash1
9             ctmp = chaves1[h1]; vttmp = valores1[h1];
10            chaves1[h1] = c; valores1[h1] = v;
11            h1 = null; h2 = hash2(ctmp); //prepara o cuckoo
12        } else if (h2 != null) { //insere com hash2
13            ctmp = chaves2[h2]; vttmp = valores2[h2];
14            chaves2[h2] = c; valores2[h2] = v;
15            h1 = hash1(ctmp); h2 = null; //prepara o cuckoo
16        }
17        if (ctmp == null) return; //sem chave deslocada.fim.
18        else { c = ctmp; v = vttmp;} //CUCKOO!
19    }
20    if (cuckoos > limite) rehashing(c, v); //obtém espaço
21 }
```

Inserindo (chave, valor) == (15.07, 1.0)

Hash 1

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (15.07, 1.0)

Hash 1

Hash 2

pos	chave	valor
0	null	null
1	15.07	1.0
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	null	null
1	15.07	1.0
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (0.08, 2.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	15.07	1.0
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (9.01, 3.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	15.07	1.0
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (9.01, 3.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	15.07	1.0
2	null	null
3	9.01	3.0
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (6.04, 4.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	15.07	1.0
2	null	null
3	9.01	3.0
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (6.04, 4.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	15.07	1.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Inserindo (chave, valor) == (27.06, 5.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	15.07	1.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Operação CUCKOO (chave, valor) = (15.07, 1.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

Número de operações CUCKOO = 1

Limite atual de operações CUCKOO = 10.0

Inserindo (chave, valor) == (27.06, 5.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (16.01, 6.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Operação CUCKOO (chave, valor) = (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	null	null
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 1

Limite atual de operações CUCKOO = 11.0

Inserindo (chave, valor) == (16.01, 6.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (28.02, 7.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	null	null
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (28.02, 7.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	null	null
9	null	null

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (24.04, 8.0)

Hash 1

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	null	null
9	null	null

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (24.04, 8.0)

Hash 1

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	null	null
9	24.04	8.0

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (13.08, 9.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	null	null
9	24.04	8.0

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (13.08, 9.0)

Hash 1

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

Hash 2

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (26.07, 10.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Operação CUCKOO (chave, valor) = (24.04, 8.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 1
Limite atual de operações CUCKOO = 14.0

Operação CUCKOO (chave, valor) = (0.08, 2.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 2

Limite atual de operações CUCKOO = 14.0

Operação CUCKOO (chave, valor) = (16.01, 6.0)
Hash 1 Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	null	null
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 3

Limite atual de operações CUCKOO = 14.0

Inserindo (chave, valor) == (26.07, 10.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	16.01	6.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (11.04, 11.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	null	null
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

Hash 2

pos	chave	valor
0	null	null
1	16.01	6.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (11.04, 11.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

Hash 2

pos	chave	valor
0	null	null
1	16.01	6.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (21.06, 12.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	16.01	6.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Operação CUCKOO (chave, valor) = (28.02, 7.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	16.01	6.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 1

Limite atual de operações CUCKOO = 15.0

Operação CUCKOO (chave, valor) = (16.01, 6.0)
Hash 1 Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	28.02	7.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 2

Limite atual de operações CUCKOO = 15.0

Operação CUCKOO (chave, valor) = (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	28.02	7.0
2	null	null
3	24.04	8.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 3

Limite atual de operações CUCKOO = 15.0

Operação CUCKOO (chave, valor) = (24.04, 8.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	26.07	10.0

pos	chave	valor
0	null	null
1	28.02	7.0
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 4

Limite atual de operações CUCKOO = 15.0

Operação CUCKOO (chave, valor) = (26.07, 10.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	null	null
1	28.02	7.0
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 5

Limite atual de operações CUCKOO = 15.0

Inserindo (chave, valor) == (21.06, 12.0)

Hash 1

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

Hash 2

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (23.08, 13.0)

Hash 1

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

Hash 2

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Operação CUCKOO (chave, valor) = (11.04, 11.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	0.08	2.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 1

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	11.04	11.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 2

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (16.01, 6.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	11.04	11.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 3

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (28.02, 7.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 4

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (21.06, 12.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	null	null
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 5

Limite atual de operações CUCKOO = 16.0

Inserindo (chave, valor) == (23.08, 13.0)

Hash 1

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

Hash 2

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Inserindo (chave, valor) == (25.08, 14.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Operação CUCKOO (chave, valor) = (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 1

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (11.04, 11.0)
Hash 1 Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	0.08	2.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 2

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (23.08, 13.0)
Hash 1 Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	0.08	2.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 3

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (21.06, 12.0)
Hash 1 Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	0.08	2.0
4	23.08	13.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 4

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (28.02, 7.0)

Hash 1

Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	0.08	2.0
4	23.08	13.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 5

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (16.01, 6.0)

Hash 1

Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	0.08	2.0
4	23.08	13.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 6

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (25.08, 14.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	28.02	7.0
2	null	null
3	0.08	2.0
4	23.08	13.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 7

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (28.02, 7.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	21.06	12.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	25.08	14.0
2	null	null
3	0.08	2.0
4	23.08	13.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 8

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (21.06, 12.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	25.08	14.0
2	null	null
3	0.08	2.0
4	23.08	13.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 9

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (23.08, 13.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	25.08	14.0
2	null	null
3	0.08	2.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 10

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (11.04, 11.0)
Hash 1 Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	25.08	14.0
2	null	null
3	0.08	2.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 11

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	16.01	6.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	25.08	14.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 12

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (16.01, 6.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	25.08	14.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 13

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (25.08, 14.0)

Hash 1

Hash 2

pos	chave	valor
0	0.08	2.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 14

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (0.08, 2.0)

Hash 1

Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	11.04	11.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 15

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (11.04, 11.0)
Hash 1 Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	23.08	13.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	0.08	2.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 16

Limite atual de operações CUCKOO = 16.0

Operação CUCKOO (chave, valor) = (23.08, 13.0)

Hash 1

Hash 2

pos	chave	valor
0	25.08	14.0
1	27.06	5.0
2	null	null
3	9.01	3.0
4	6.04	4.0
5	null	null
6	11.04	11.0
7	28.02	7.0
8	13.08	9.0
9	24.04	8.0

pos	chave	valor
0	26.07	10.0
1	16.01	6.0
2	null	null
3	0.08	2.0
4	21.06	12.0
5	null	null
6	null	null
7	15.07	1.0
8	null	null
9	null	null

Número de operações CUCKOO = 17

Limite atual de operações CUCKOO = 16.0

Complexidade computacional: Cuckoo Hashing

- ▶ Espaço: $\approx 2N$
- ▶ `get(c)`: no máximo 2 verificações por chave - determinístico

Para hash uniforme

- ▶ Reconstrução esperada para n^2 inserções
- ▶ Probabilidade de falha de inserção $O(\frac{1}{N})$
- ▶ Pior caso esperado amortizado: $O(1)$
 - ▶ O custo de reconstrução é amortizado no custo de n^2 inserções

Tabela hash vs. ABB balanceada

Tabela Hash

- ▶ Mais fácil para codificar
- ▶ Bom para chaves sem ordem
- ▶ Rápido para chaves simples

ABB balanceada

- ▶ Garantia de desempenho
- ▶ Permite operações ordenadas
- ▶ Mais fácil implementar `compareTo()` que `hashCode()`