

ACH2024

Aula 20

HASHING

Hashing estático – endereçamento fechado (interno)

Profa. Ariane Machado Lima

Aulas anteriores

Algoritmos e
estruturas de dados
para lida com
memória secundária

- Organização interna de arquivos
- Acesso à memória secundária (por blocos - seeks)
- Tipos de alocação de arquivos na memória secundária:
 - Sequencial (ordenado e não ordenado)
 - Ligada
 - Indexada
 - Árvores-B
 - Hashing (veremos também hashing em memória principal)
- Algoritmos de processamento cossequencial e ordenação em disco

Aula de hoje e próximas

- Organização interna de arquivos
- Acesso à memória secundária (por blocos - seeks)
- Tipos de alocação de arquivos na memória secundária:
 - Sequencial (ordenado e não ordenado)
 - Ligada
 - Indexada
 - Árvores-B
 - Hashing (veremos também hashing em memória principal)
- Algoritmos de processamento cossequencial e ordenação em disco

Motivação e Conceitos Básicos

Formas de organizar os registros/elementos/objetos em uma estrutura (baseado em seu campo chave):

- Pelo valor relativo das chaves
 - Ex: vetor ordenado, árvore de busca, árvore B/B+, etc...
- Pelo valor absoluto:
 - Hashing: o endereço base depende apenas do valor absoluto da chave

Obs: *hash* em inglês: cortar em pequenos pedaços

OBSERVAÇÕES INICIAIS

VAMOS PENSAR A PRINCÍPIO EM MEMÓRIA PRINCIPAL
(HASHING INTERNO)

Vamos falar em armazenar chave como sinônimo de armazenar um registro/objeto/elemento

Motivação e Conceitos Básicos

Você quer armazenar 6 chaves contendo valores de 0 a 5

- Que estrutura de dados usaria? Onde armazenaria cada chave?

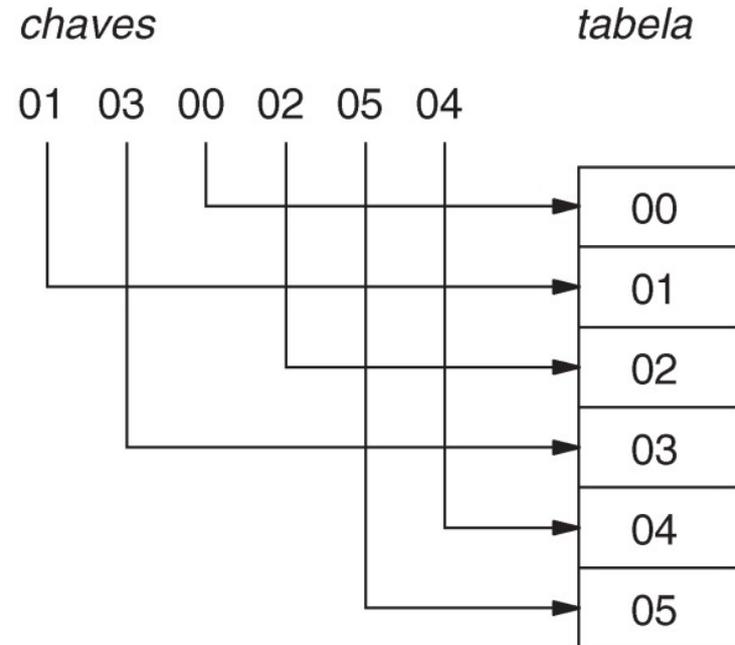
Motivação e Conceitos Básicos

Você quer armazenar 6 chaves contendo valores de 0 a 5

- Que estrutura de dados usaria? Onde armazenaria cada chave? Vetor em que chave = posição

Vantagens:

- **ACESSO DIRETO!!!** →
Inserção/remoção/busca
em tempo constante ($O(1)$)



Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 1, 3, 4, 5, 7}

- Que estrutura de dados usaria? Onde armazenaria cada chave?

Motivação e Conceitos Básicos

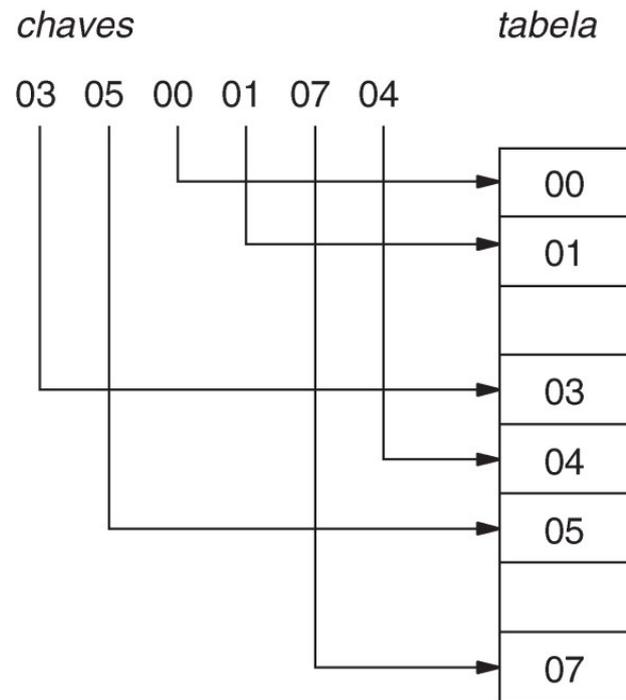
Agora você quer armazenar 6 chaves contendo valores {0, 1, 3, 4, 5, 7}

- Que estrutura de dados usaria? Onde armazenaria cada chave? Vetor em que chave = posição

Vantagens:

- **ACESSO DIRETO!!!** →
Inserção/remoção/busca
em tempo constante ($O(1)$)

Desvantagem:



Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 1, 3, 4, 5, 7}

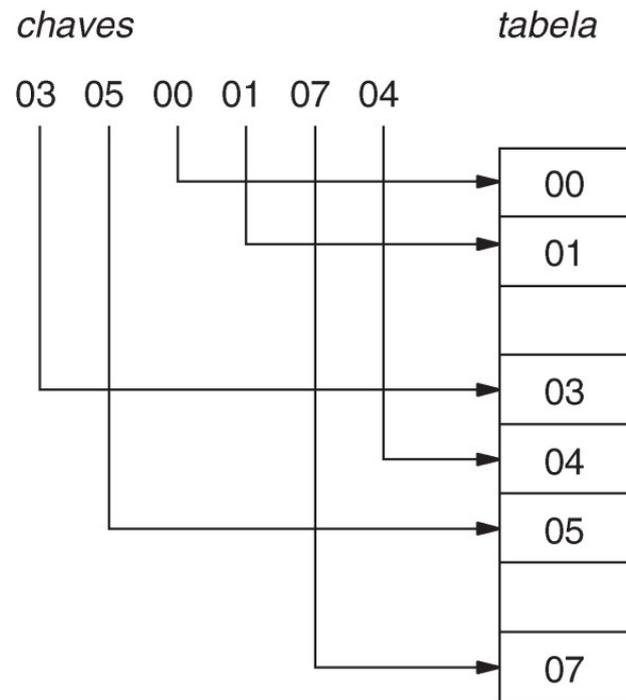
- Que estrutura de dados usaria? Onde armazenaria cada chave? Vetor em que chave = posição

Vantagens:

- **ACESSO DIRETO!!!** →
Inserção/remoção/busca
em tempo constante ($O(1)$)

Desvantagem:

- Pequeno desperdício de espaço (parece valer a pena)



Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 7, 15, 367, 4067, 50876}

- Que estrutura de dados usaria? Onde armazenaria cada chave?

Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 7, 15, 367, 4067, 50876}

- Que estrutura de dados usaria? Onde armazenaria cada chave?

tabela

Vantagens:

- **ACESSO DIRETO!!!** →
Inserção/remoção/busca
em tempo constante ($O(1)$)

Desvantagem:

- Desperdício de espaço já começa a não valer a pena quando
chave máxima \gg número de chaves

00
...
07
...

Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 7, 15, 367, 4067, 50876}

- Que estrutura de dados usaria? Onde armazenaria cada chave?

IDEIA:

- 1) utilizar um vetor (tabela) de tamanho m
- 2) aplicar uma função que mapeie cada chave a um número de 0 a $m-1$ (Ex?)

Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 7, 15, 367, 4067, 50876}

- Que estrutura de dados usaria? Onde armazenaria cada chave

IDEIA:

- 1) utilizar um vetor (tabela) de tamanho m
- 2) aplicar uma função que mapeie cada chave a um número de 0 a $m-1$

Ex: $m = 10$ e pegar o primeiro dígito (ou letra)

Hashing: picar/dividir o conjunto em **slots**

Tabela de armazenamento: **tabela de hash**

Função de mapeamento: **função de hash**

Endereço calculado: **endereço-base**



Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 7, 15, 367, 4067, 50876}

- Que estrutura de dados usaria? Onde armazenaria cada chave

IDEIA:

- 1) utilizar um vetor (tabela) de tamanho m
- 2) aplicar uma função que mapeie cada chave a um número de 0 a $m-1$

Ex: $m = 10$ e pegar o primeiro dígito (ou letra)

Hashing: picar/dividir o conjunto em **slots**

Tabela de armazenamento: **tabela de dispersão**

Função de mapeamento: **função de dispersão**

Endereço calculado: **endereço-base**



Motivação e Conceitos Básicos

Agora você quer armazenar 6 chaves contendo valores {0, 7, 15, 367, 4067, 50876}

- Que estrutura de dados usaria? Onde armazenaria cada chave

IDEIA:

- 1) utilizar um vetor (tabela) de tamanho m
- 2) aplicar uma função que mapeie cada chave a um número de 0 a $m-1$

Ex: $m = 10$ e pegar o primeiro dígito (ou letra)

Hashing: picar/dividir o conjunto em **slots**

Tabela de armazenamento: **tabela de espalhamento**

Função de mapeamento: **função de espalhamento**

Endereço calculado: **endereço-base**



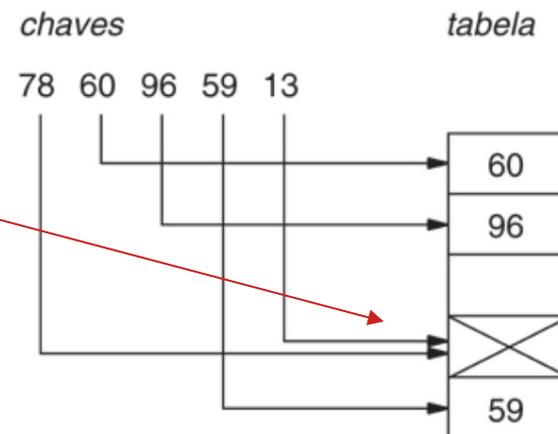
Motivação e Conceitos Básicos

Questões que podem surgir?

Motivação e Conceitos Básicos

Questões que podem surgir:

- O que fazer quando duas chaves caem na mesma posição? (**colisão**)
- **Tratamento de colisões**
- Qual **função de hash** utilizar? Como ela impacta na ocorrência de colisões?



Vamos estudar essas questões

Funções de hash

Definição: considerando:

uma tabela de tamanho m (m slots)

Um domínio C de valores de chaves (strings, \mathbb{N} , \mathbb{Z} , \mathbb{R} , ...)

um função de hash é uma função $h: C \rightarrow \{0, 1, \dots, m-1\}$

Ou seja, se $x \in C$ é uma chave, $h(x)$ retorna o **endereço-base** de x (ou seja, seu índice na tabela de hash)

Ex: $h(x) = x$ (primeiro exemplo)

$h(x) =$ dígito mais significativo (segundo exemplo)

Funções de hash

Propriedades desejáveis:

Funções de hash

Propriedades desejáveis:

- 1) Poucas colisões
- 2) Ser rapidamente calculada ($O(1)$, senão estraga vantagem do hashing)
- 3) Distribuição uniforme:
 - idealmente se há m slots, $P(h(x)) = 1/m \forall x$
(a probabilidade de qualquer endereço-base deve ser $1/m$)
 - importante para minimizar colisões (de pior caso)
 - difícil de ser testada, mas bom senso pode ajudar. Ex: dígito mais significativo seria uma boa?

Funções de hash

Propriedades desejáveis:

- 1) Poucas colisões
- 2) Ser rapidamente calculada ($O(1)$, senão estraga vantagem do hashing)
- 3) Distribuição uniforme:
 - idealmente se há m slots, $P(h(x)) = 1/m \forall x$
(a probabilidade de qualquer endereço-base deve ser $1/m$)
 - importante para minimizar colisões (de pior caso)
 - difícil de ser testada, mas bom senso pode ajudar. Ex: dígito mais significativo seria uma boa? – péssima ideia na maioria dos casos

Funções de hash

Principais métodos de funções de hash:

- 1) Método da divisão
- 2) Método da dobra
 - baseado em soma
 - baseado em ou-exclusivo
- 3) Método da multiplicação
- 4) Método da análise de dígitos

Funções de hash

Método da divisão

Considerando uma tabela de m slots:

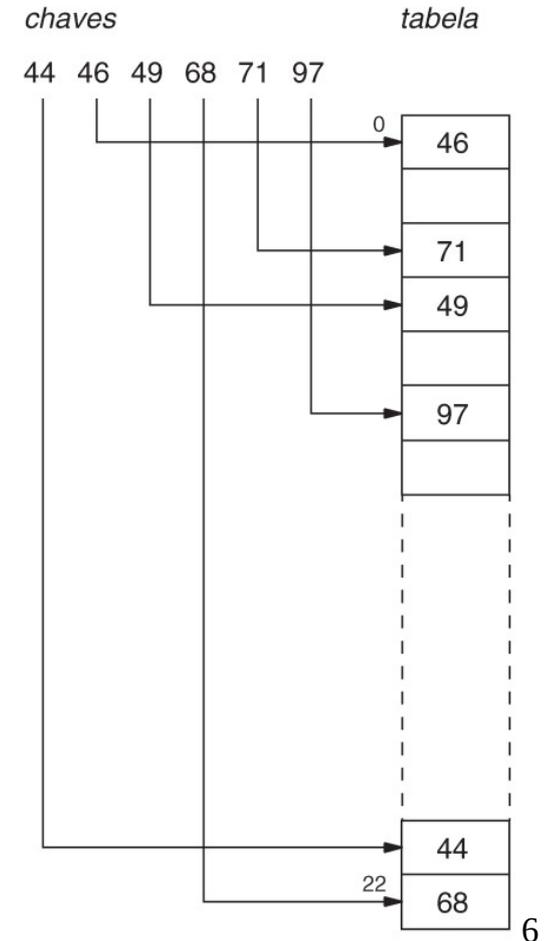
$$h(x) = x \bmod m \quad (\text{mod: resto da divisão inteira})$$

$$\text{Ex: } h(x) = x \bmod 23$$

Alguns valores de m são melhores que outros...

Ex de m **bons**:

- Números **primos** (de preferência não próximo de potência de 2)



Funções de hash

Método da dobra

Método da dobra: sucessivas dobras de trechos do número e efetuar uma operação.

Ex:

- Soma: manipulando a chave como um número decimal
- Ou-exclusivo: manipulando a chave como um número binário

Funções de hash

Método da dobra baseado em soma

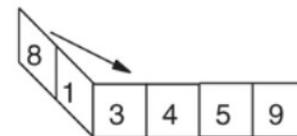
Método da dobra baseado em soma: (obtem $h(x)$ com j dígitos)

x = número descrito com k dígitos decimais : d_1, d_2, \dots, d_k (ex: $k = 6$)

Dobras de tamanho j (ex: $j = 2$) \Rightarrow

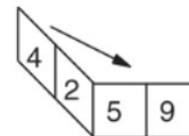
$d_1, \dots, d_k \rightarrow d'_j, \dots, d'_1, d_{2j+1}, \dots, d_k$

Sendo cada d'_i o dígito menos significativo da soma $d_i + d_{2j-i+1}$



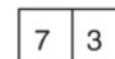
$$8+4=12$$

$$1+3=4$$



$$4+9=13$$

$$2+5=7$$



Funções de hash

Método da Multiplicação

Muitas variações, a mais conhecida:

Método do “meio do quadrado”: (obtem $h(x)$ com b bits – Ex: $b = 8$)

x = número binário descrito com **K BITS** : d_1, d_2, \dots, d_k (ex: $K = 32$)

=> pegar o b bits centrais do número binário x^2

Ex: $x = 157 = 0000\ 0000\ 0000\ 0000\ 0000\ 0000\ 1001\ 0101$

$x^2 = 24649 = 0000\ 0000\ 0000\ 0000\ 0110\ 0000\ 0100\ 1001$

$h(x) = 0000\ 0110 = 6$

Funções de hash

Método da Análise de Dígitos

Diferentemente dos demais, precisa analisar ANTES o conjunto de **n chaves** a serem armazenadas

Ideia básica: utilizar as d posições de dígitos (decimais) que mais se aproximam da distribuição uniforme (isto é, com menor desvio):

- $n(j)_i$ = número de chaves contendo o dígito i na posição j
- Se a posição j apresenta-se perfeitamente uniforme, cada valor i apareceria $n/10$ vezes nessa posição (potencialmente com algum desvio)

Procedimento: para números de até k dígitos (posições), calcule o desvio (da dist. uniforme) para a posição $j = 1 \dots k$

$$\text{desvio}(j) = \sum_{i=0..9} |n(j)_i - n/10| \quad \text{ou} \quad \sum_{i=0..9} (n(j)_i - n/10)^2$$

E escolha os d dígitos com menor desvio

Ex: chaves = {44, 46, 49, 68, 71, 97}, $k = 2$, $d = 1$

$\text{desvio}(1) = 7.2$; $\text{desvio}(2) = 4.1 \Rightarrow h(x)$ deve pegar o dígito 2

$h(44) = 4$; $h(46) = 6$; $h(49) = 9$; ...

Tratamento de colisões

Tratamento de colisões

Colisão: quando $x \neq y$ mas $h(x) = h(y)$

Fator de carga: $\alpha = n/m$ ($m =$ nr de slots da tabela de hash, $n =$ nr de chaves a serem inseridas)

Qual a relação de α com o nr de colisões ?

Tratamento de colisões

Colisão: quando $x \neq y$ mas $h(x) = h(y)$

Fator de carga: $\alpha = n/m$ ($m = \text{nr de slots da tabela de hash}$, $n = \text{nr de chaves a serem inseridas}$)

Maior $\alpha \rightarrow$ maior o nr de colisões

Mas $\alpha < 1$ não garante ausência de colisões... \rightarrow tem que tratar

Tratamento de colisões

Estratégias:

A) Hashing estático (tamanho da tabela é constante)

1) Encadeamento ou endereçamento fechado – colisões vão para uma lista ligada

1.1) Encadeamento exterior (fora da tabela)

1.2) Encadeamento interior (dentro da tabela)

2) Endereçamento aberto (chaves dentro da tabela, sem ponteiros)

2.1) Tentativa/Sondagem linear

2.2) Tentativa/Sondagem quadrática

2.3) Dispersão dupla / Hash duplo

B) Hashing dinâmico (tabela pode expandir/encolher)

3) Hashing extensível (estrutura de dados adicional)

4) Hashing linear

Tratamento de colisões

Estratégias:

A) Hashing estático (tamanho da tabela é constante)

1) Encadeamento ou endereçamento fechado – colisões vão para uma lista ligada

1.1) Encadeamento exterior (fora da tabela)

1.2) Encadeamento interior (dentro da tabela)

2) Endereçamento aberto (chaves dentro da tabela, sem ponteiros)

2.1) Tentativa/Sondagem linear

2.2) Tentativa/Sondagem quadrática

2.3) Dispersão dupla / Hash duplo

B) Hashing dinâmico (tabela pode expandir/encolher)

3) Hashing extensível (estrutura de dados adicional)

4) Hashing linear

Tudo isso para hashing interno (em memória) quanto para externo (em disco).

Primeiro assumiremos hashing interno e depois discutiremos mudanças para hashing externo.

A) Hashing estático (tamanho constante da tabela)

A) Hashing estático (tamanho constante da tabela)

- 1) Encadeamento ou **endereçamento fechado**
(colisões vão para uma lista ligada, ie,
 $h(x)$ não muda)

Tratamento de colisões - 1) Endereçamento fechado

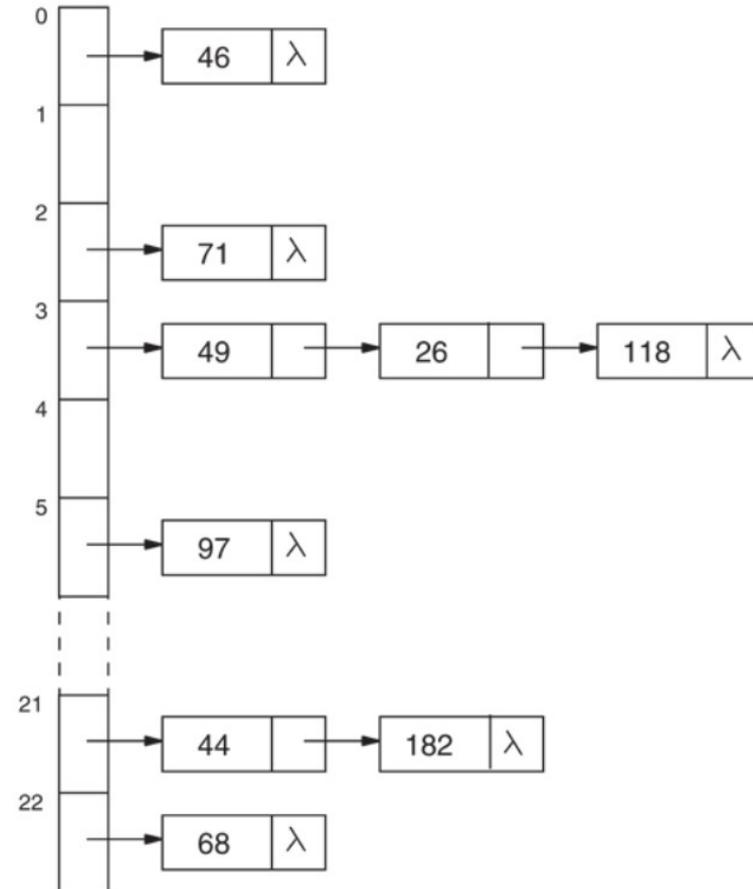
1.1) Encadeamento exterior (fora da tabela de hash)

A tabela de hash é um vetor de m listas ligadas (não necessariamente ordenadas), uma para cada endereço base

- chaves ficam fora do espaço da tabela
- $T[i]$ guarda o ponteiro para o início da lista de chaves com endereço-base = i

Busca/inserção/remoção: em listas ligadas

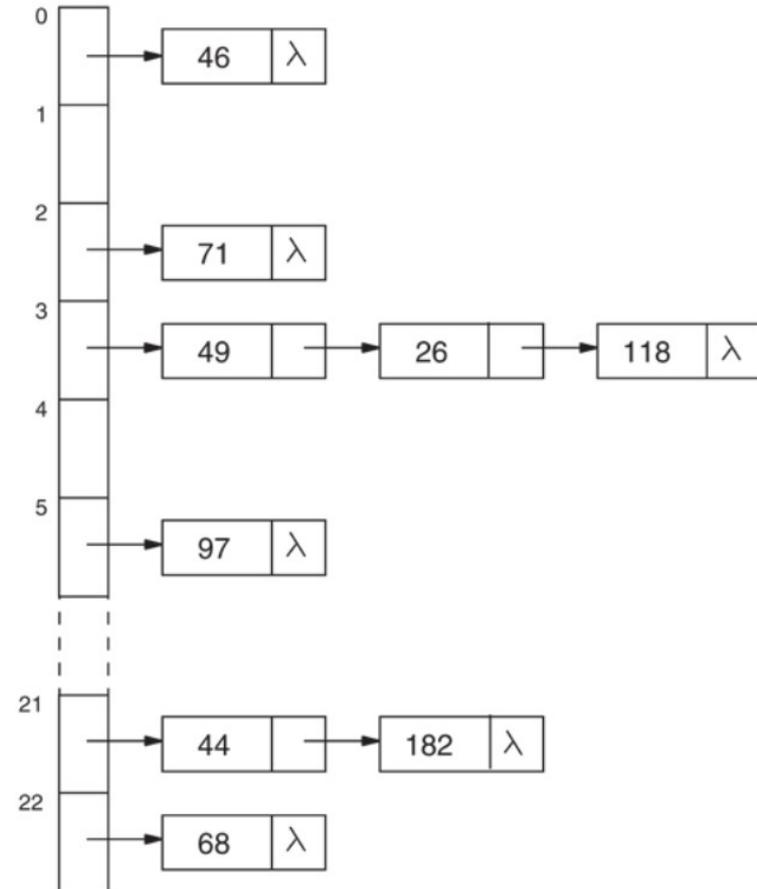
Se tiver que impedir duplicação de chaves, pode inserir no final



Tratamento de colisões - 1) Endereçamento fechado

1.1) Encadeamento exterior (fora da tabela de hash)

Complexidade de busca/inserção/remoção:



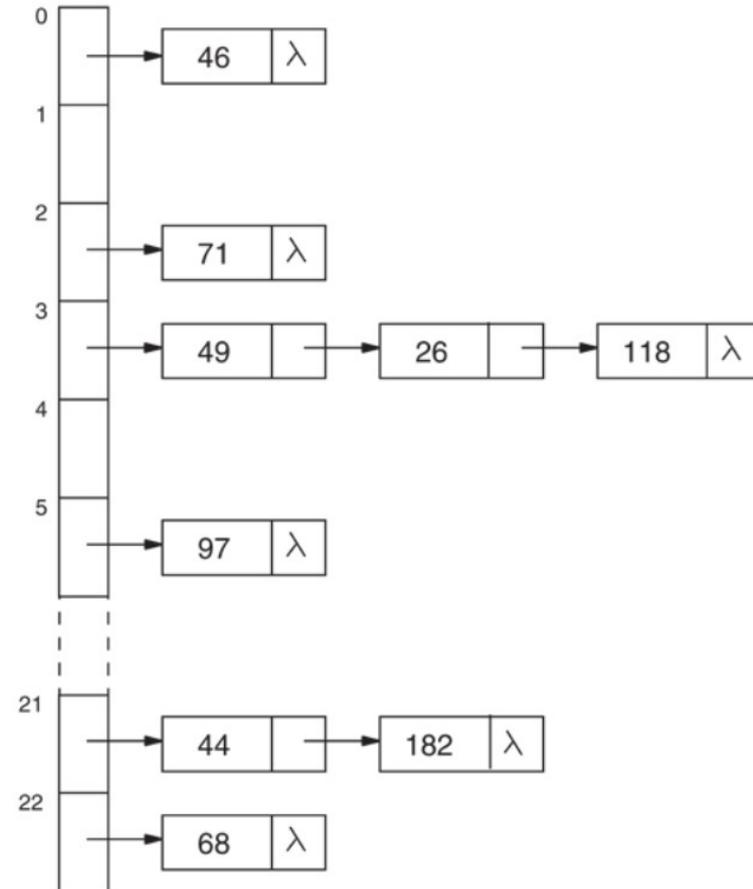
Tratamento de colisões - 1) Endereçamento fechado

1.1) Encadeamento exterior (fora da tabela de hash)

Complexidade de busca/inserção/remoção:

- pior caso: $O(n)$
- caso médio (assumindo hash uniforme):
 - sem sucesso (chave não existe): tamanho médio da lista = α

= média ponderada (pela prob. de i) do
nr de elementos em cada lista L_i
 $= 1/m \sum_{i=1..m} |L_i| = n/m = \alpha$



Tratamento de colisões - 1) Endereçamento fechado

1.1) Encadeamento exterior (fora da tabela de hash)

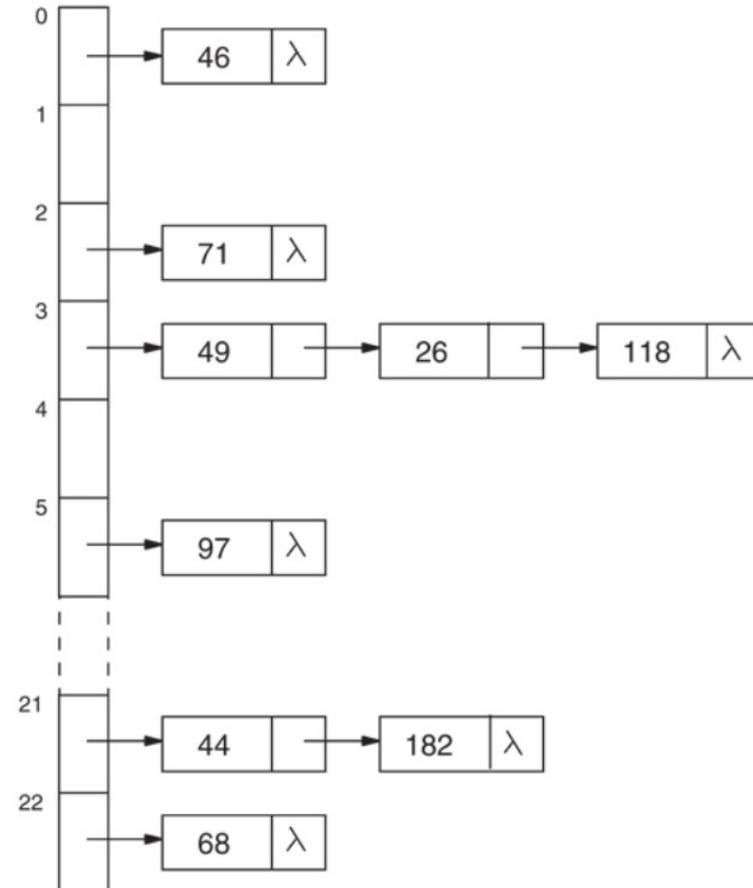
Complexidade de busca/inserção/remoção:

- pior caso: $O(n)$
- caso médio (assumindo hash uniforme):
 - sem sucesso: α
 - com sucesso: $1 + \alpha/2 - 1/2m$

= nr médio de comparações assumindo que x é $(j+1)$ -ésima chave a ser inserida, no final, sem remoções (posição fixa), $|L_i|_{\text{médio}} = j/m$

$$= \frac{1}{n} \sum_{j=0..n-1} (1 + j/m) = 1 + \frac{n(n-1)}{2nm}$$

$$= 1 + \frac{(n^2-n)}{2nm} = 1 + \alpha/2 - 1/2m$$



Tratamento de colisões - 1) Endereçamento fechado

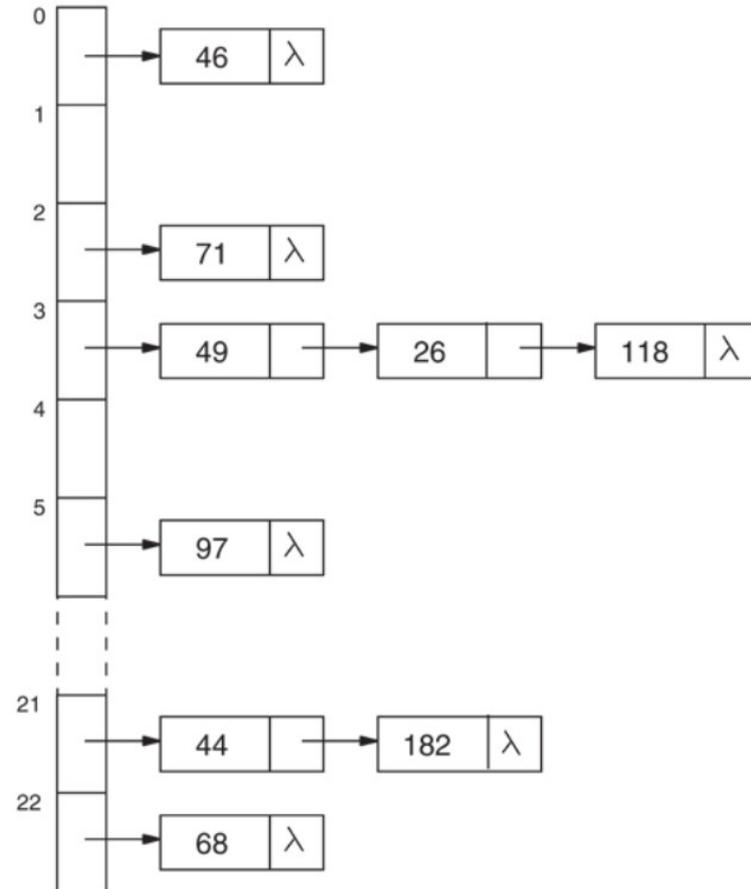
1.1) Encadeamento exterior (fora da tabela de hash)

Complexidade de busca/inserção/remoção:

- pior caso: $O(n)$
- caso médio (assumindo hash uniforme):
 - sem sucesso: α
 - com sucesso: $1 + \alpha/2 - 1/2m$

Isto é, mais rápido conforme:

- α menor e m maior - linearmente



Referências

Conceitos gerais de Hashing:

SZWARCFITER, J. L.; MARKENZON, L. Estruturas de Dados e Seus Algoritmos. Ed. LTC, 3^a ed, 2013. Capítulo 10 (figuras do livro)

Slides dos Profs. M. Chaim, Delano Beder e L. Digiampietri