# Arquivos de Acesso Direto

Vanessa Braganholo

# Arquivo de Acesso Direto

- Definição: arquivo em que o acesso a um registro pode ser feito diretamente, sem ter que ler todos os registros que vêm antes dele

- Implicação prática: não é mais necessário que o arquivo esteja ordenado

- Basta que saibamos o endereço do registro que queremos acessar

# Endereço?

- Como saber o endereço de um determinado registro?
- Definido sempre como um deslocamento em relação ao primeiro registro

  - EndereçoReg(i) = (i – 1) * tamanhoReg

  onde tamanhoReg é o tamanho dos registros do arquivo, em bytes

# Exemplo

| CodCli | Nome | DataNascimento |
|---|---|---|
| 10 | Joao | 02/12/1990 |
| 02 | Maria | 04/10/1976 |
| 15 | Carlos | 30/06/1979 |
| 04 | Carolina | 14/05/2000 |
| 01 | Murilo | 23/10/1988 |

- Tamanho Registro:
  - CodCli = 4 bytes
  - Nome = 10 bytes
  - DataNascimento = 12 bytes

- **Total**: 26 bytes por registro

# Exemplo

| | CodCli | Nome | DataNascimento |
|---|---|---|---|
| 0 | 10 | Joao | 02/12/1990 |
| 26 | 02 | Maria | 04/10/1976 |
| 52 | 15 | Carlos | 30/06/1979 |
| 78 | 04 | Carolina | 14/05/2000 |
| 104 | 01 | Murilo | 23/10/1988 |

- Tamanho Registro:
  - CodCli = 4 bytes
  - Nome = 10 bytes
  - DataNascimento = 12 bytes
  - **Total**: 26 bytes por registro

- Endereço do Registro 3 = (3-1) * 26 = 52

# Para ler o registro 3

1. Abrir o arquivo
2. Calcular o endereço do registro 3
3. Avançar o cursor (*seek*) para o endereço calculado
4. Ler o registro

- Ao terminar de ler o registro, o cursor estará posicionado no registro 4

# Tutorial sobre Manipulação de Arquivos de Acesso Direto em Java

# RandomAcessFile

- Arquivos de acesso direto são manipulados através da classe RamdonAccessFile

- Esta classe tem todos os métodos de leitura e escrita que já vimos
- Tem também um método **seek** que avança o cursor para uma posição específica do arquivo
- A nova posição é dada em bytes, a partir do início do arquivo

# Posição do Cursor

- Para usar o método **seek**, é necessário saber quantos bytes queremos avançar
- Para isso, precisamos saber quantos bytes cada registro do nosso arquivo ocupa

- writeInt: grava um int de 4 bytes
- writeLong: grava um inteiro longo de 8 bytes
- writeDouble: grava um double de 8 bytes
- writeChar: grava um char de 2 bytes
- …

# Tabela de Tamanhos

| Tipo | Tamanho em Bytes |
|---|---|
| Boolean | 1 |
| Char | 2 |
| Short | 2 |
| Int | 4 |
| LongInt | 8 |
| Float | 4 |
| Double | 8 |
| UTF (String) | 2 bytes p/ o tamanho da String +<br>1 ou 2 ou 3 bytes por caracter |

# Como saber o tamanho das Strings que gravamos?

1. Usar apenas caracteres sem acentuação, pois eles ocupam sempre 1 byte cada
2. Usar tamanhos fixos de Strings ao gravar no arquivo
   - Fixar o tamanho da string e completar com espaços em branco antes gravar

```
String s = "Maria";
int tam = 10;
for (int i=s.length();i<tam;i++) {
        s = s + " ";
        }
out.writeUTF(s); //tamanho em bytes gravado:10+2
```

# Exemplo de código

- Ver classe **Main.java** no projeto Java do tutorial, disponibilizado no site da disciplina

# Mas...

- A operação de leitura normalmente é guiada pelo valor da chave do registro que estamos procurando, e não pela posição do registro
- Ao invés de ler registro 3, ler o registro de chave 55
- Como fazer para saber em que endereço está um registro que possui uma determinada chave?

# Técnicas para localizar registros

- Como fazer para saber em que endereço está um registro que possui uma determinada chave?
  - Cálculos computacionais: uso de funções de cálculo de endereço a partir do valor da chave (hashing)
  - Indexação: uso de uma estrutura de dados auxiliar (ex. Árvore B, …)

# Hashing
# (Tabelas de Dispersão)

Fonte de consulta: Szwarcfiter, J.; Markezon, L. Estruturas de Dados e seus Algoritmos, 3a. ed. LTC. Cap. 10

# Exemplo Motivador

- Distribuição de correspondências de funcionários numa empresa
  - Um escaninho para cada inicial de sobrenome
  - Todos os funcionários com a mesma inicial de sobrenome procuram sua correspondênia dentro do mesmo escanhinho
    - Pode haver mais de uma correspondência dentro do mesmo escanhinho

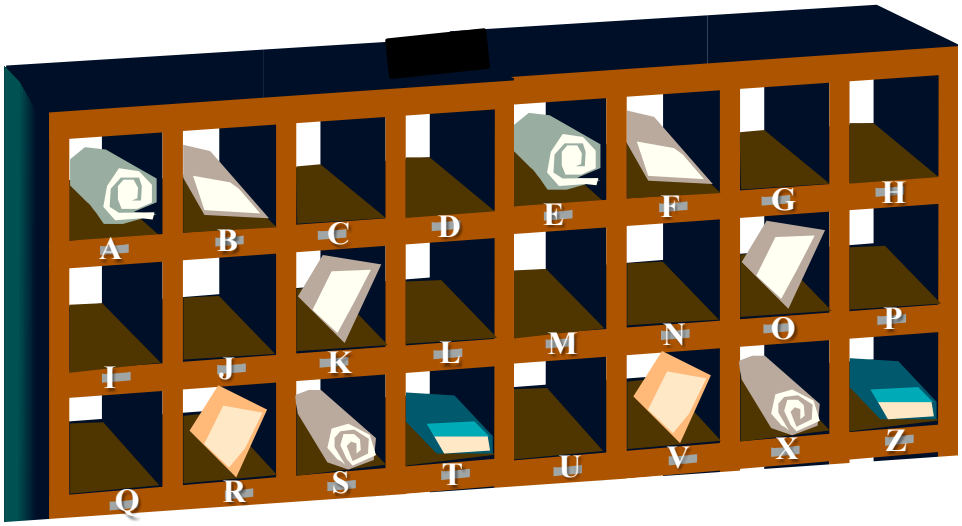

# *Hashing*: Princípio de Funcionamento

- Suponha que existem **n** chaves a serem armazenadas numa tabela de comprimento **m**
  - Em outras palavras, a tabela tem **m** compartimentos
  - Endereços possíveis: [**0, m-1**]
  - Situações possíveis: cada compartimento da tabela pode armazenar **x** registros
  - Para simplificar, assumimos que **x = 1** (cada compartimento armazena apenas **1** registro)

# Como determinar *m*?

- Uma opção é determinar **m** em função do número de valores possíves das chaves a serem armazenadas

# *Hashing*: Princípio de Funcionamento

- Se os valores das chaves variam de [**0, m-1**], então podemos usar o valor da chave para definir o endereço do compartimento onde o registro será armazenado

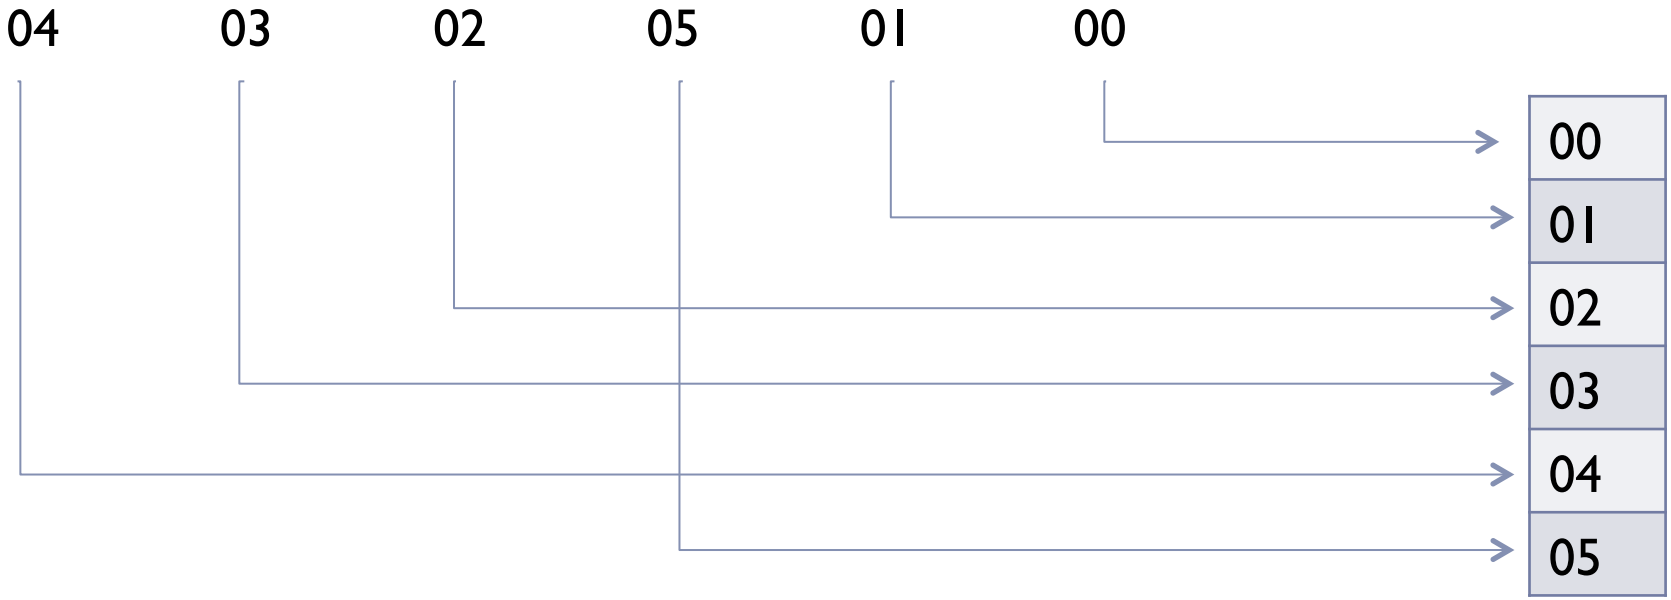

# Tabela pode ter espaços vazios

- Se o número **n** de chaves a armazenar é menor que o número de compartimentos **m** da tabela

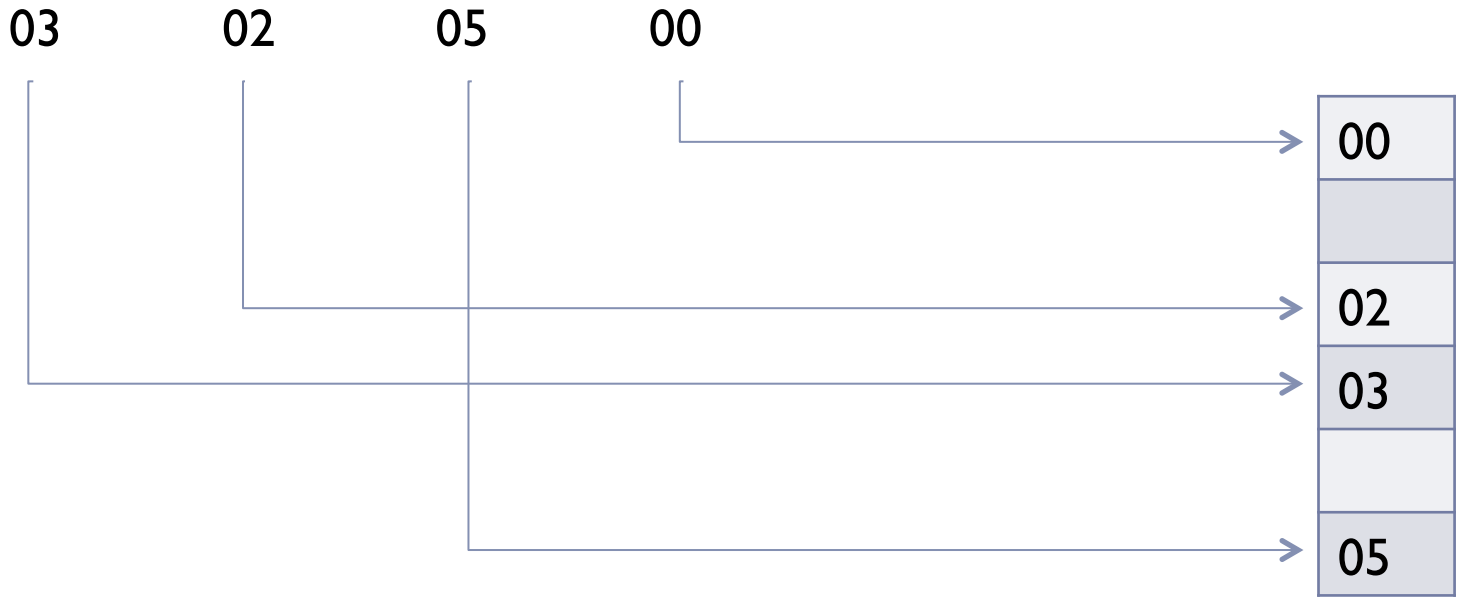

# Mas...

- Se o intervalo de valores de chave é muito grande, **m** é muito grande
- Pode haver um número proibitivo de espaços vazios na tabela se houverem poucos registros

- Exemplo: armazenar 2 registros com chaves 0 e 999.999 respectivamente
  - **m** = 1.000.000
  - tabela teria 999.998 compartimentos vazios

# Solução

- Definir um valor de **m** menor que os valores de chaves possíveis

- Usar uma função hash **h** que mapeia um valor de chave **x** para um endereço da tabela
- Se o endereço **h(x)** estiver livre, o registro é armazenado no compartimento apontado por **h(x)**

- Diz-se que **h(x)** produz um **endereço-base** para **x**

# Exemplo

- **h(x) = x mod 7**

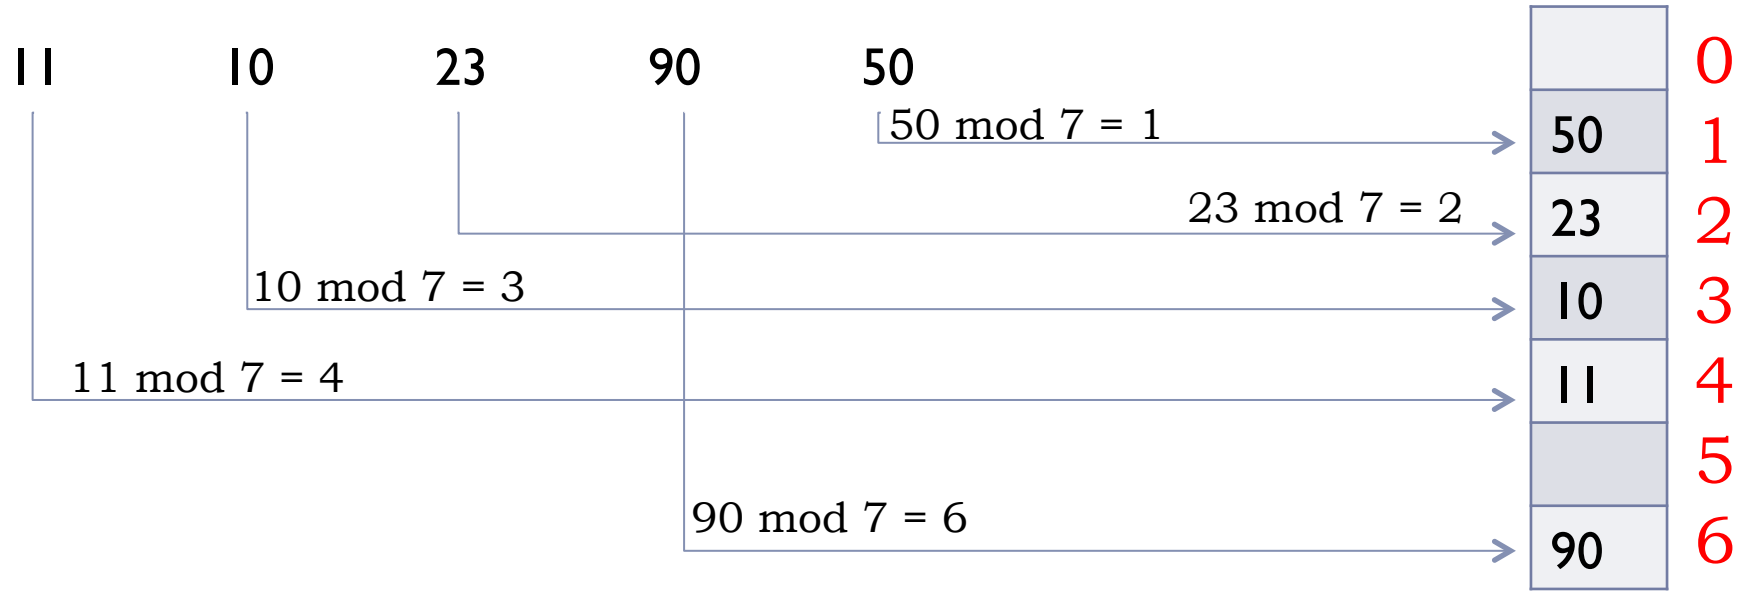

# Função hash h

- Infelizmente, a função pode não garantir injetividade, ou seja, é possível que **$x \neq y$** e **$h(x) = h(y)$**

- Se ao tentar inserir o registro de chave **x** o compartimento de endereço **h(x)** já estiver ocupado por **y**, ocorre uma **colisão**
  - Diz-se que **x** e **y** são sinônimos em relação a **h**

# Exemplo: Colisão

- **h(x) = x mod 7**

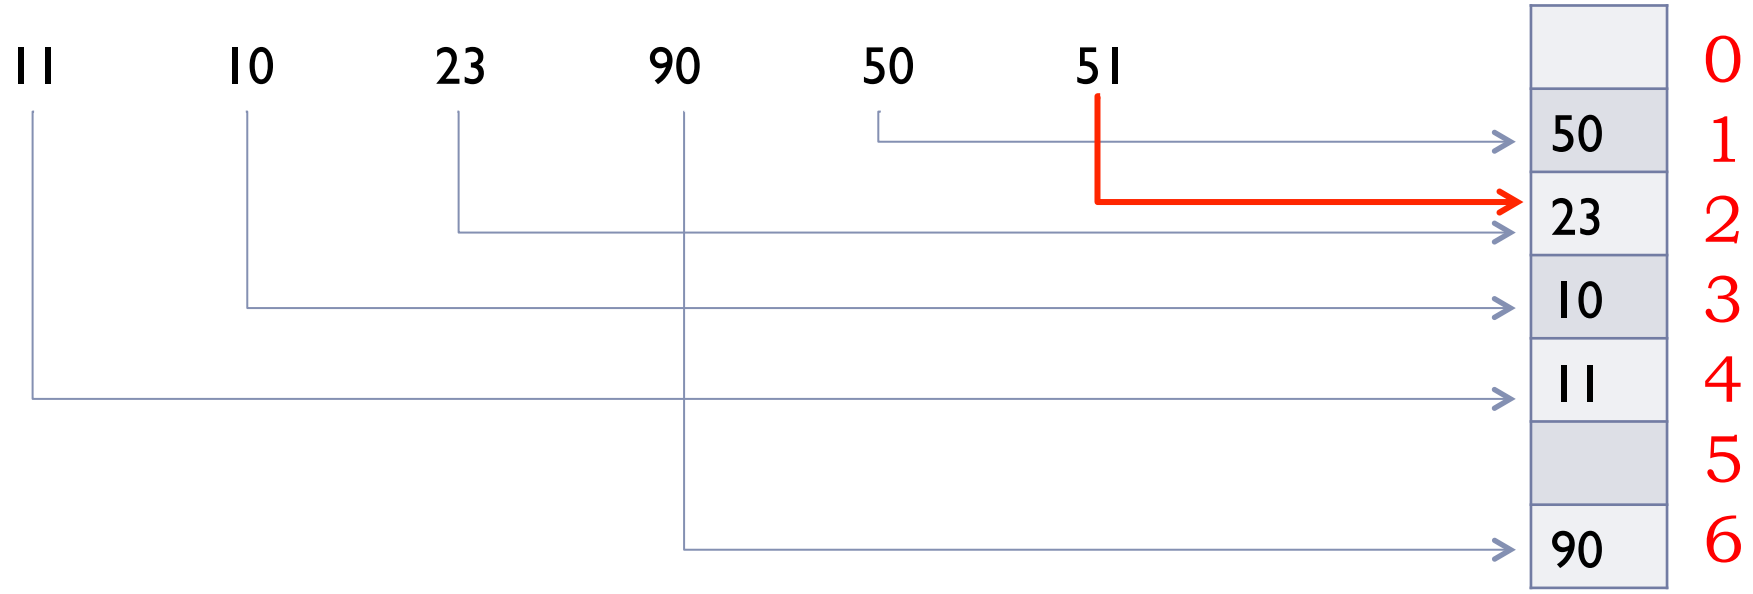


**A chave 51 colide com a chave 23 e não pode ser inserida no endereço 2!**

Solução: uso de um procedimento especial para armazenar a chave 51 (tratamento de colisões)

# Características desejáveis das funções de hash

- Produzir um número baixo de colisões
- Ser facilmente computável
- Ser uniforme

# Características desejáveis das funções de hash

- Produzir um número baixo de colisões
  - Difícil, pois depende da distribuição dos valores de chave.
  - Exemplo: Pedidos que usam como parte da chave o ano e mês do pedido.
    - Se a função **h** realçar estes dados, haverá muita concentração de valores nas mesmas faixas.

# Características desejáveis das funções de hash

- Ser facilmente computável
  - Se a tabela estiver armazenada em disco (nosso caso), isso não é tão crítico, pois a operação de I/O é muito custosa, e dilui este tempo
  - Das 3 condições, é a mais fácil de ser garantida
- Ser uniforme
  - Idealmente, a função **h** deve ser tal que todos os compartimentos possuam a mesma probabilidade de serem escolhidos
  - Difícil de testar na prática

# Exemplos de Funções de Hash

- Algumas funções de hash são bastante empregadas na prática por possuírem algumas das características anteriores:
  - Método da Divisão
  - Método da Dobra
  - Método da Multiplicação

# Exemplos de Funções de Hash

- **Método da Divisão**
- Método da Dobra
- Método da Multiplicação

# Método da Divisão

- Uso da função mod:

  **h(x) = x mod m**

  onde **m** é a dimensão da tabela

- Alguns valores de m são melhores do que outros
  - Exemplo: se **m** for par, entao **h(x)** será par quando **x** for par, e ímpar quando **x** for ímpar → indesejável



Atenção: na pag. 235 do livro, a fórmula contém um pequeno erro

# Método da divisão

- Estudos apontam bons valores de **m**:
  - Escolher **m** de modo que seja um número primo não próximo a uma potência de 2; ou
  - Escolher **m** tal que não possua divisores primos menores do que 20

# Exemplos de Funções de Hash

- Método da Divisão
- **Método da Dobra**
- Método da Multiplicação

# Método da Dobra

- Suponha a chave como uma sequencia de dígitos escritos em um pedaço de papel
- O método da dobra consiste em "dobrar" este papel, de maneira que os dígitos se superponham
- Os dígitos então devem ser somados, sem levar em consideração o "vai-um"

# Exemplo: Método da Dobra

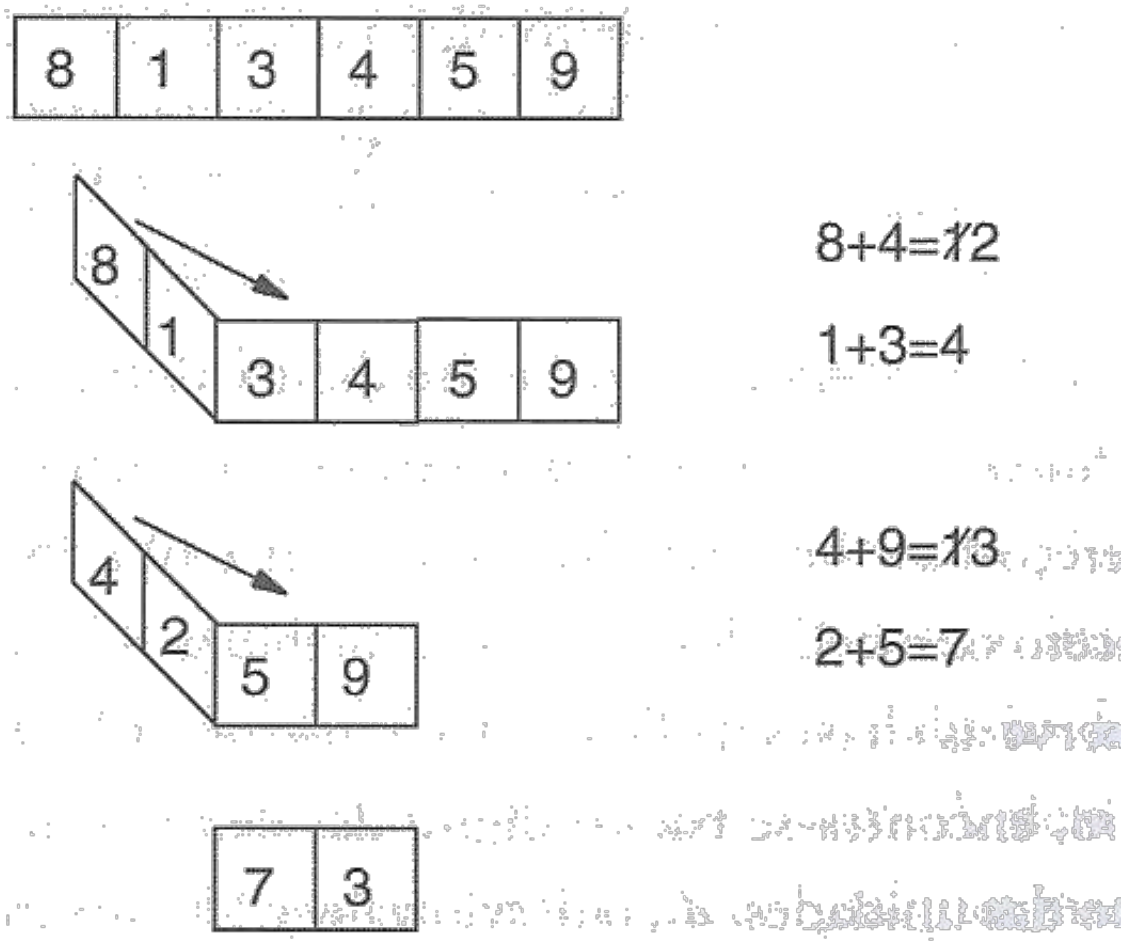




Fonte: Fig. 10.4, pag 237

# Método da Dobra

- A posição onde a dobra será realizada, e quantas dobras serão realizadas, depende de quantos dígitos são necessários para formar o endereço base
- O tamanho da dobra normalmente é do tamanho do endereço que se deseja obter

# Exercício

- Escreva um algoritmo para implementar o método da dobra, de forma a obter endereços de 2 dígitos
- Assuma que as chaves possuem 6 dígitos

# Exemplos de Funções de Hash

- Método da Divisão
- Método da Dobra
- **Método da Multiplicação**

# Método da Multiplicação

- Multiplicar a chave por ela mesma
- Armazenar o resultado numa palavra de **b** bits
- Descartar os bits das extremidadades direita e esquerda, um a um, até que o resultado tenha o tamanho de endereço desejado

# Método da Multiplicação

- Exemplo: chave 12
  - 12 x 12 = 144
  - 144 representado em binário: 10010000
  - Armazenar em 10 bits: 0010010000
  - Obter endereço de 6 bits (endereços entre 0 e 63)

# Método da Multiplicação

- Exemplo: chave 12
  - 12 x 12 = 144
  - 144 representado em binário: 10010000
  - Armazenar em 10 bits: 0010010000
  - Obter endereço de 6 bits (endereços entre 0 e 63)

# Método da Multiplicação

- Exemplo: chave 12
  - 12 x 12 = 144
  - 144 representado em binário: 10010000
  - Armazenar em 10 bits: 0010010000
  - Obter endereço de 6 bits (endereços entre 0 e 63)

# Método da Multiplicação

- Exemplo: chave 12
  - 12 x 12 = 144
  - 144 representado em binário: 10010000
  - Armazenar em 10 bits: 0010010000
  - Obter endereço de 6 bits (endereços entre 0 e 63)

# Método da Multiplicação

- Exemplo: chave 12
  - 12 x 12 = 144
  - 144 representado em binário: 10010000
  - Armazenar em 10 bits: 0010010000
  - Obter endereço de 6 bits (endereços entre 0 e 63)

# Método da Multiplicação

- Exemplo: chave 12
  - 12 x 12 = 144
  - 144 representado em binário: 10010000
  - Armazenar em 10 bits: 0010010000
  - Obter endereço de 6 bits (endereços entre 0 e 63)

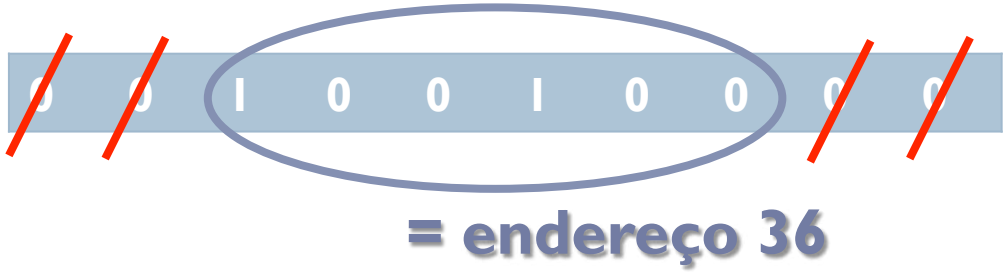

# Uso da função de hash

- A mesma função de hash usada para inserir os registros é usada para buscar os registros

# Exemplo: busca de registro por chave

- **h(x) = x mod 7**
- Encontrar o registro de chave 90
  - 90 mod 7 = 6
- Encontrar o registro de chave 7
  - 7 mod 7 = 0
  - Compartimento 0 está vazio: registro não está armazenado na tabela
- Encontrar o registro de chave 8
  - 8 mod 7 = 1
  - Compartimento 1 tem um registro com chave diferente da chave buscada, e não exitem registros adicionais: registro não está armazenado na tabela

# Tratamento de Colisões

# Fator de Carga

- O fator de carga de uma tabela hash é $\alpha = n/m$, onde **n** é o número de registros armazenados na tabela
  - O número de colisões cresce rapidamente quando o fator de carga aumenta
  - Uma forma de diminuir as colisões é diminuir o fator de carga
  - Mas **isso não resolve o problema**: colisões sempre podem ocorrer
- Como tratar as colisões?

# Tratamento de Colisões

- Por Encadeamento
- Por Endereçamento Aberto

# Tratamento de Colisões

- **Por Encadeamento**
- Por Endereçamento Aberto

# Tratamento de Colisões por Encadeamento

- **Encadeamento Exterior**
- Encadeamento Interior

# Encadeamento Exterior

- Manter **m** listas encadeadas, uma para cada possível endereço base

- A tabela base não possui nenhum registro, apenas os ponteiros para as listas encadeadas
- Por isso chamamos de encadeamento **exterior**: a tabela base não armazena nenhum registro

# Nós da lista Encadeada

- Cada nó da lista encadeada contém:
  - um registro
  - um ponteiro para o próximo nó

# Exemplo: Encadeamento Exterior

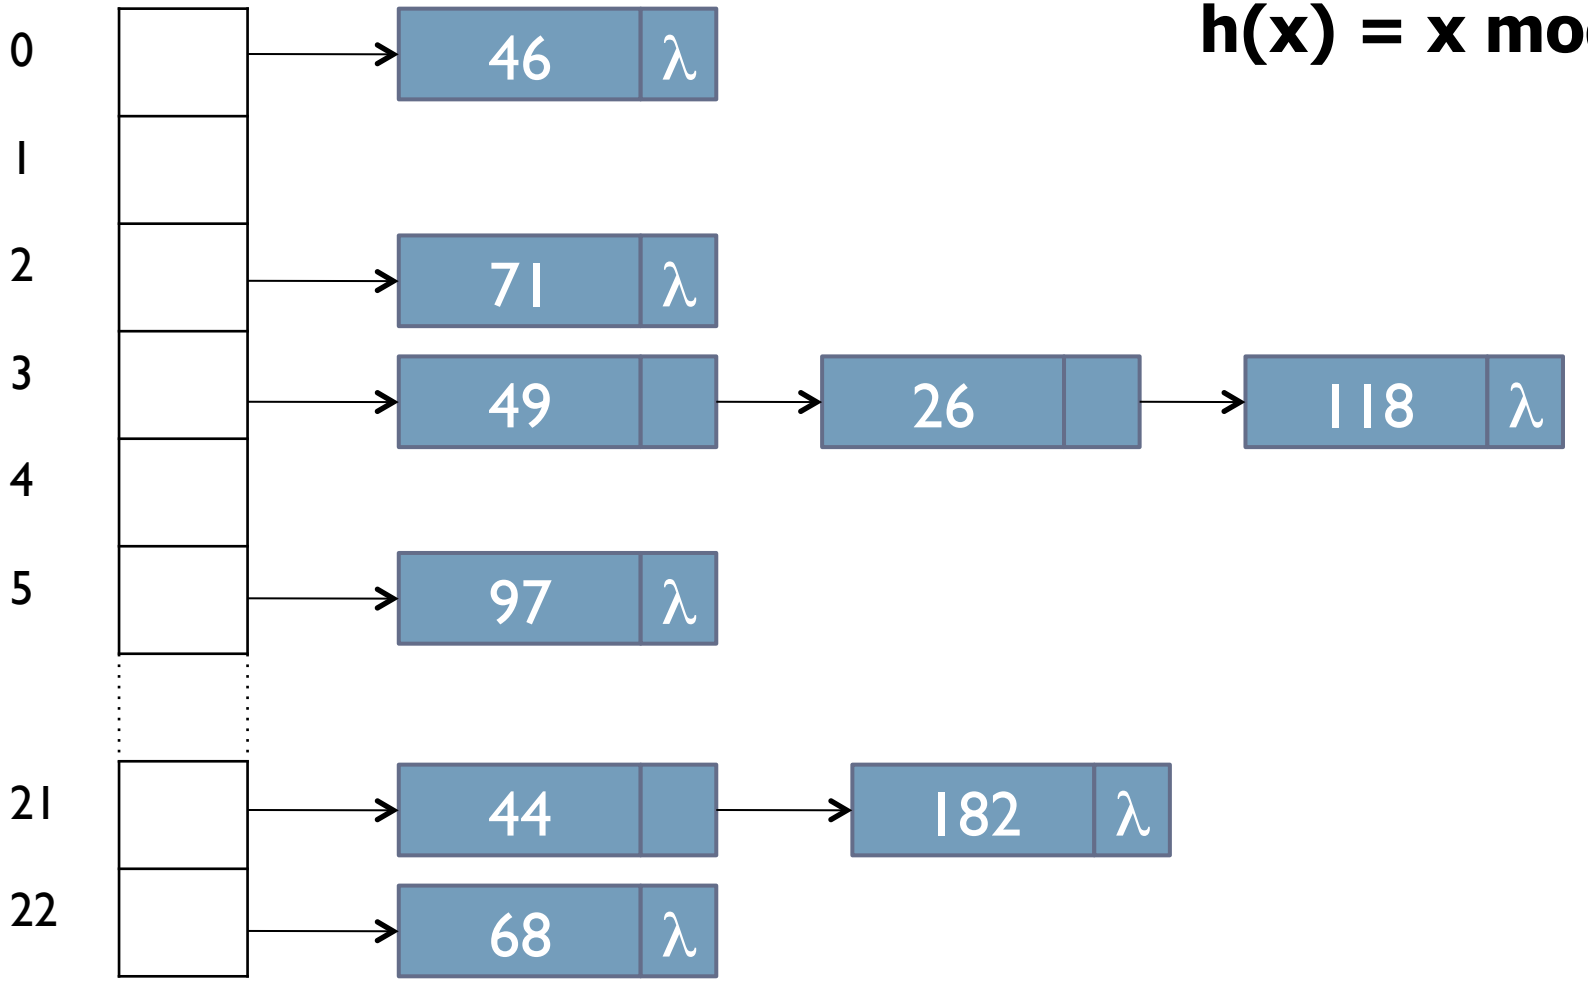




Fonte: Fig. 10.5, pag 240

# Encadeamento Exterior

- Busca por um registro de chave x:
  1. Calcular o endereço aplicando a função h(x)
  2. Percorrer a lista encadeada associada ao endereço
  3. Comparar a chave de cada nó da lista encadeada com a chave x, até encontrar o nó desejado
  4. Se final da lista for atingido, registro não está lá

# Encadeamento Exterior

- Inserção de um registro de chave x
  1. Calcular o endereço aplicando a função h(x)
  2. Buscar registro na lista associada ao endereço h(x)
  3. Se registro for encontrado, sinalizar erro
  4. Se o registro não for encontrado, inserir no final da lista

# Encadeamento Exterior

- Exclusão de um registro de chave x
  1. Calcular o endereço aplicando a função h(x)
  2. Buscar registro na lista associada ao endereço h(x)
  3. Se registro for encontrado, excluir registro
  4. Se o registro não for encontrado, sinalizar erro

# Complexidade no Pior Caso

- É necessário percorrer uma lista encadeada até o final para concluir que a chave não está na tabela
- Comprimento de uma lista encadeada pode ser O(n)
- Complexidade no pior caso: O(n)

# Complexidade no Caso Médio

- Assume que função hash é uniforme
- Número médio de comparações feitas na **busca sem sucesso** é igual ao fator de carga da tabela **$\alpha = n/m$**
- Número médio de comparações feitas na **busca com sucesso** também é igual a **$\alpha = n/m$**

- Se assumirmos que o número de chaves **n** é proporcional ao tamanho da tabela **m**
  - **$\alpha = n/m = O(1)$**
  - **Complexidade constante!**

# Implementação

- Registros podem ser gravados no mesmo arquivo físico

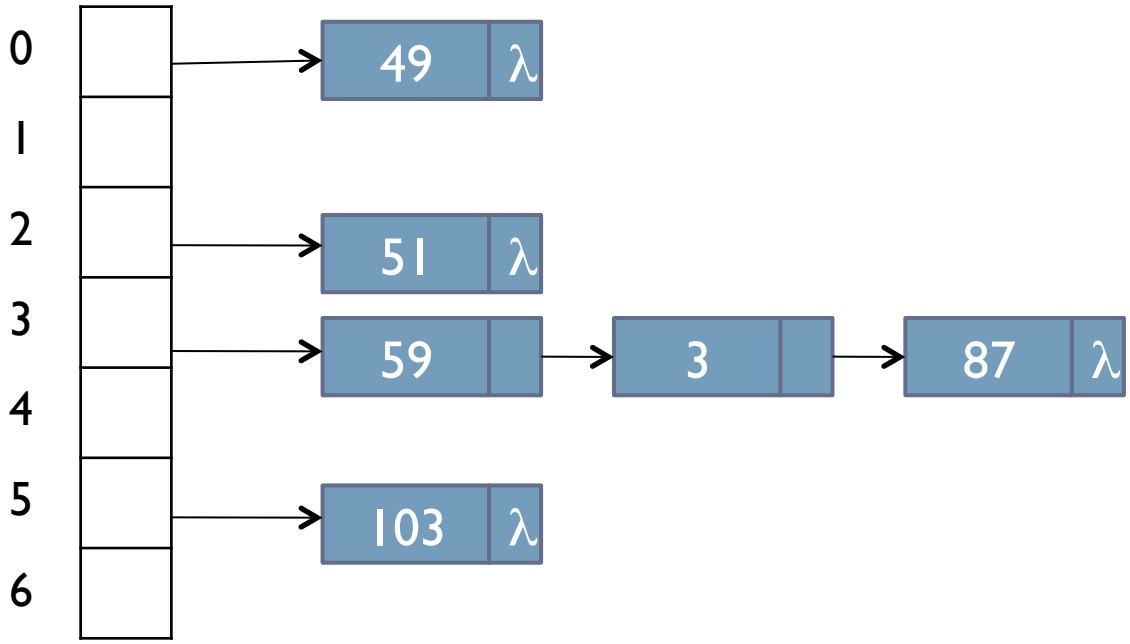


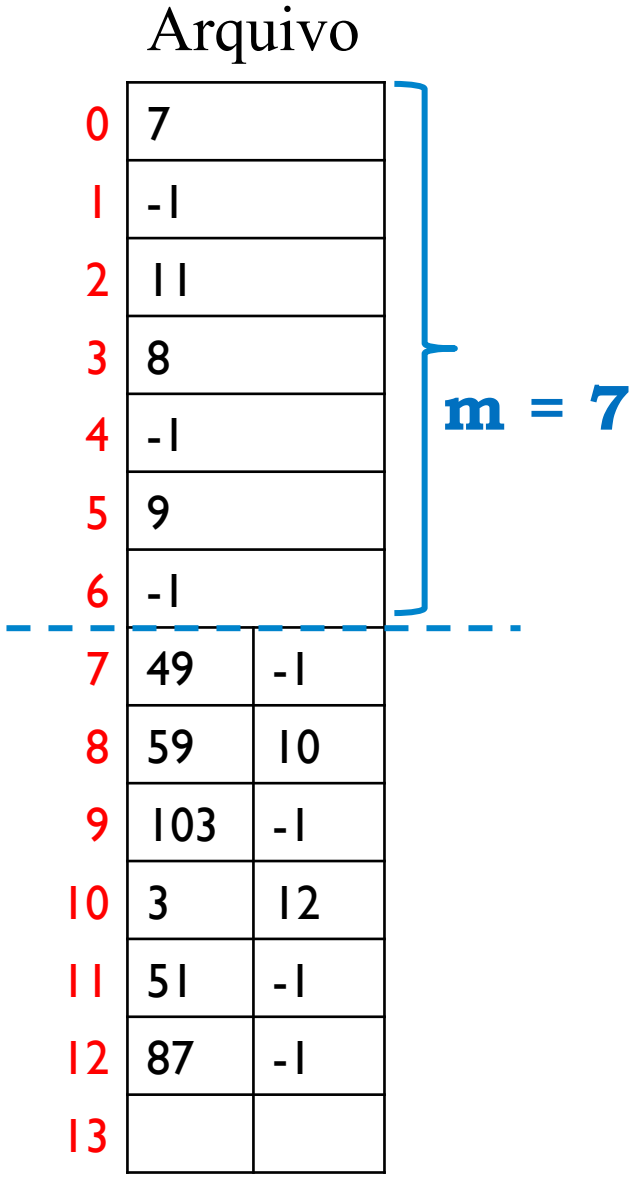

# Uso de Flag STATUS

- Para facilitar, pode-se adicionar um flag **status** a cada registro
- O flag pode ter os seguintes valores:
  - OCUPADO: quando o compartimento tem um registro
  - LIBERADO: quando o registro que estava no compartimento foi excluído

# Reflexão:

- Como seriam os procedimentos para inclusão e exclusão?

# Implementação de Exclusão

- Ao excluir um registro, marca-se o flag "status" como LIBERADO

# Implementação de Inserção (Opção 1)

- Para inserir novo registro
  - Inserir o registro no final da lista encadeada, se ele já não estiver na lista
  - De tempos em tempos, rearrumar o arquivo para ocupar as posições onde o flag status é LIBERADO

# Implementação de Inserção (Opção 2)

- Para inserir novo registro
  - Ao passar pelos registros procurando pela chave, guardar o endereço **p** do primeiro nó marcado como LIBERADO
  - Se ao chegar ao final da lista encadeada, a chave não for encontrada, gravar o registro na posição p
  - Atualizar ponteiros
    - Nó anterior deve apontar para o registro inserido
    - Nó inserido deve apontar para nó que era apontado pelo nó anterior

# Exercício em Grupo

- Reúnam-se em grupos
- Implementar o Encadeamento Exterior (sem expansão)
  - Tamanho da tabela: m = 7
  - Função de hash: h(x) = x mod 7
  - Registros a inserir: Clientes (codCliente (inteiro) e nome (String de 10 caracteres))

# Estrutura da Implementação

- Uso de dois arquivos:
  - tabHash.dat (modelado pela classe CompartimentoHash)
  - clientes.dat (modelado pela classe Cliente)

# Exemplo

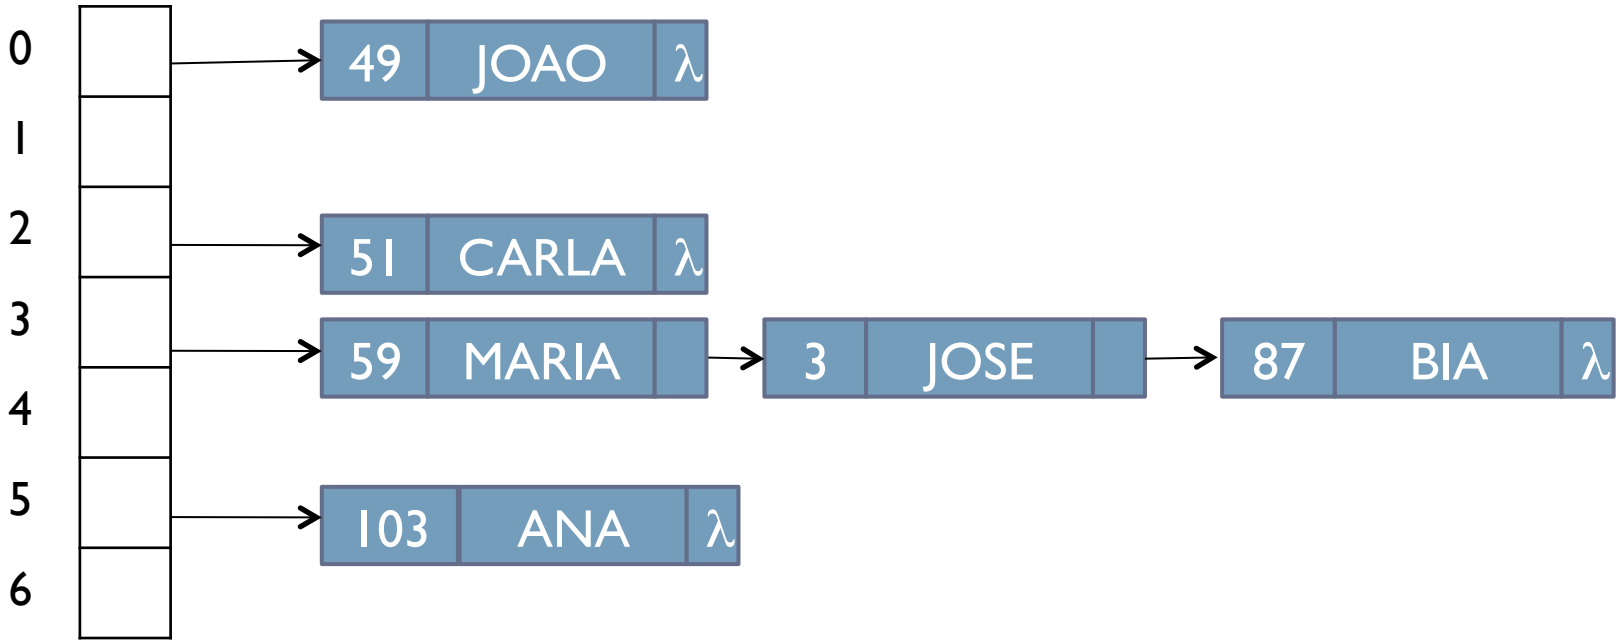

# Estrutura dos arquivos

Arquivo tabHash.dat
(CompartimentoHash)

| | |
|---|---|
| 0 | 0 |
| 1 | -1 |
| 2 | 4 |
| 3 | 1 |
| 4 | -1 |
| 5 | 2 |
| 6 | -1 |

m = 7

Arquivo clientes.dat (Cliente)

| | CodCliente | Nome | Prox | Flag |
|---|---|---|---|---|
| 0 | 49 | JOAO | -1 | FALSE |
| 1 | 59 | MARIA | 3 | FALSE |
| 2 | 103 | ANA | -1 | FALSE |
| 3 | 3 | JOSE | 5 | FALSE |
| 4 | 51 | CARLA | -1 | FALSE |
| 5 | 87 | BIA | -1 | FALSE |
| 6 | | | | |
| 7 | | | | |
| 8 | | | | |
| ... | | | | |

**FALSE = OCUPADO**
**TRUE = LIBERADO**

# Tratamento de Colisões por Encadeamento

- Encadeamento Exterior
- **Encadeamento Interior**

# Encadeamento Interior

- Em algumas aplicações não é desejável manter uma estrutura externa à tabela hash, ou seja, não se pode permitir que o espaço de registros cresça indefinidamente
- Nesse caso, ainda assim pode-se fazer tratamento de colisões

# Encadeamento Interior com Zona de Colisões

- Dividir a tabela em duas zonas
  - Uma de endereços-base, de tamanho **p**
  - Uma de colisão, de tamanho **s**
  - **p + s = m**
  - Função de hash deve gerar endereços no intervalo **[0, p-1]**
  - Cada nó tem a mesma estrutura utilizada no Encadeamento Exterior

# Exemplo: Encadeamento Interior com Zona de Colisões

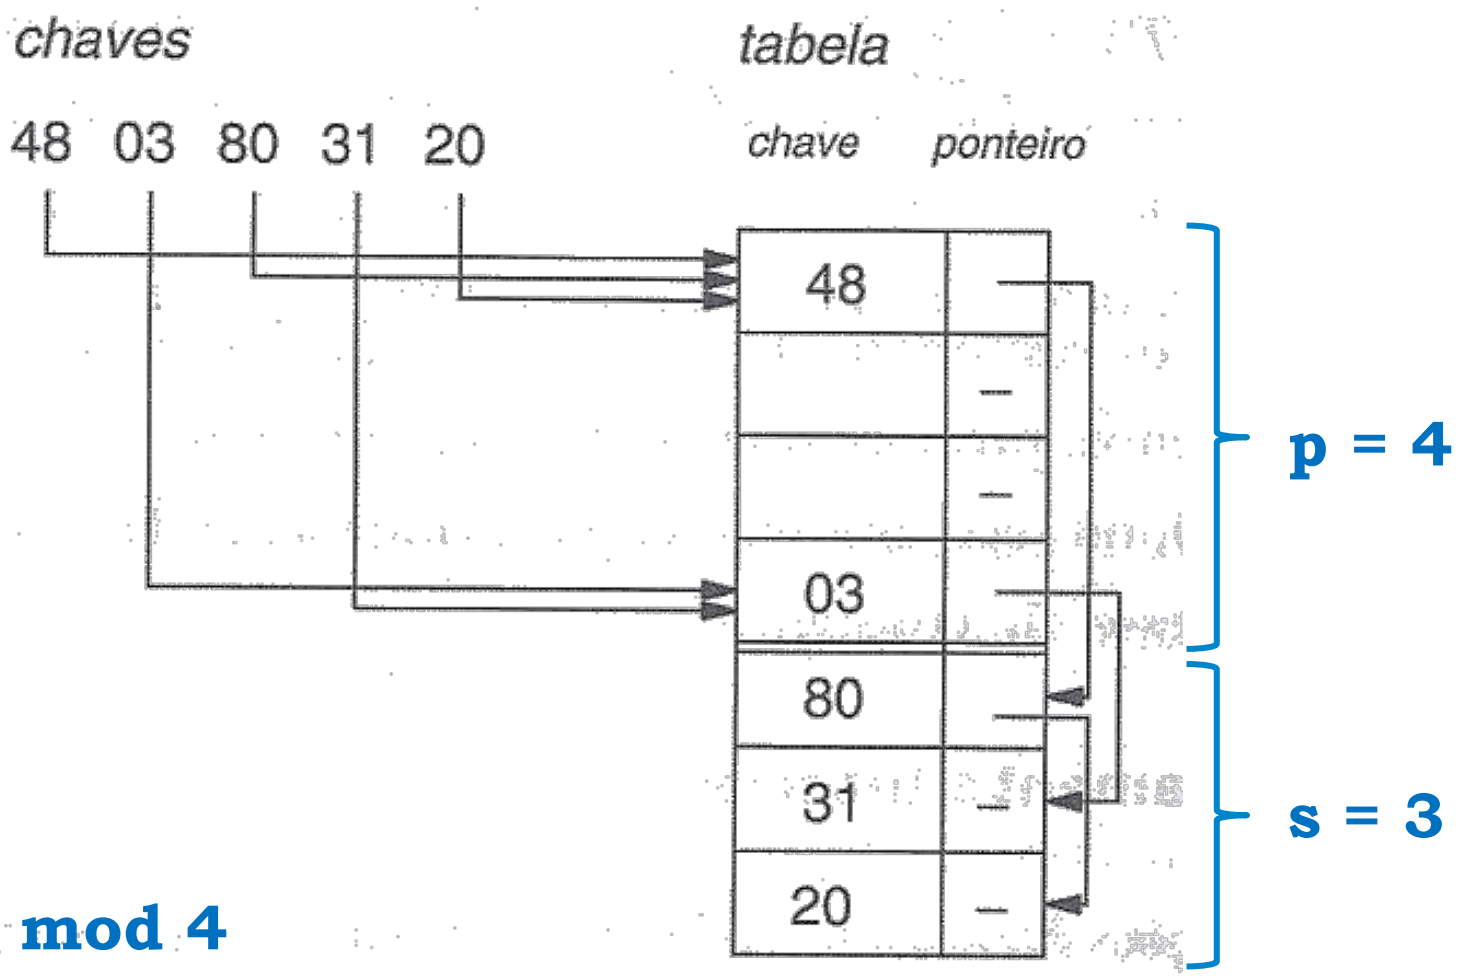




Fonte: Fig. 10.6, pag 242

# Overflow

- Em um dado momento, pode acontecer de não haver mais espaço para inserir um novo registro

# Reflexões

- Qual deve ser a relação entre o tamanho de **p** e **s**?
  - O que acontece quando **p** é muito grande, e **s** muito pequeno?
  - O que acontece quando **p** é muito pequeno, e **s** muito grande?

  - Pensem nos casos extremos:
    - p = 1; s = m – 1
    - p = m-1; s = 1

# Encadeamento Interior **sem** Zona de Colisões

- Outra opção de solução é não separar uma zona específica para colisões
  - Qualquer endereço da tabela pode ser de base ou de colisão
  - Quando ocorre colisão a chave é inserida no **primeiro compartimento vazio** a partir do compartimento em que ocorreu a colisão
  - Efeito indesejado: **colisões secundárias**
    - Colisões secundárias são provenientes da coincidência de endereços para chaves que não são sinônimas

# Exemplo: Encadeamento Interior **sem** Zona de Colisões

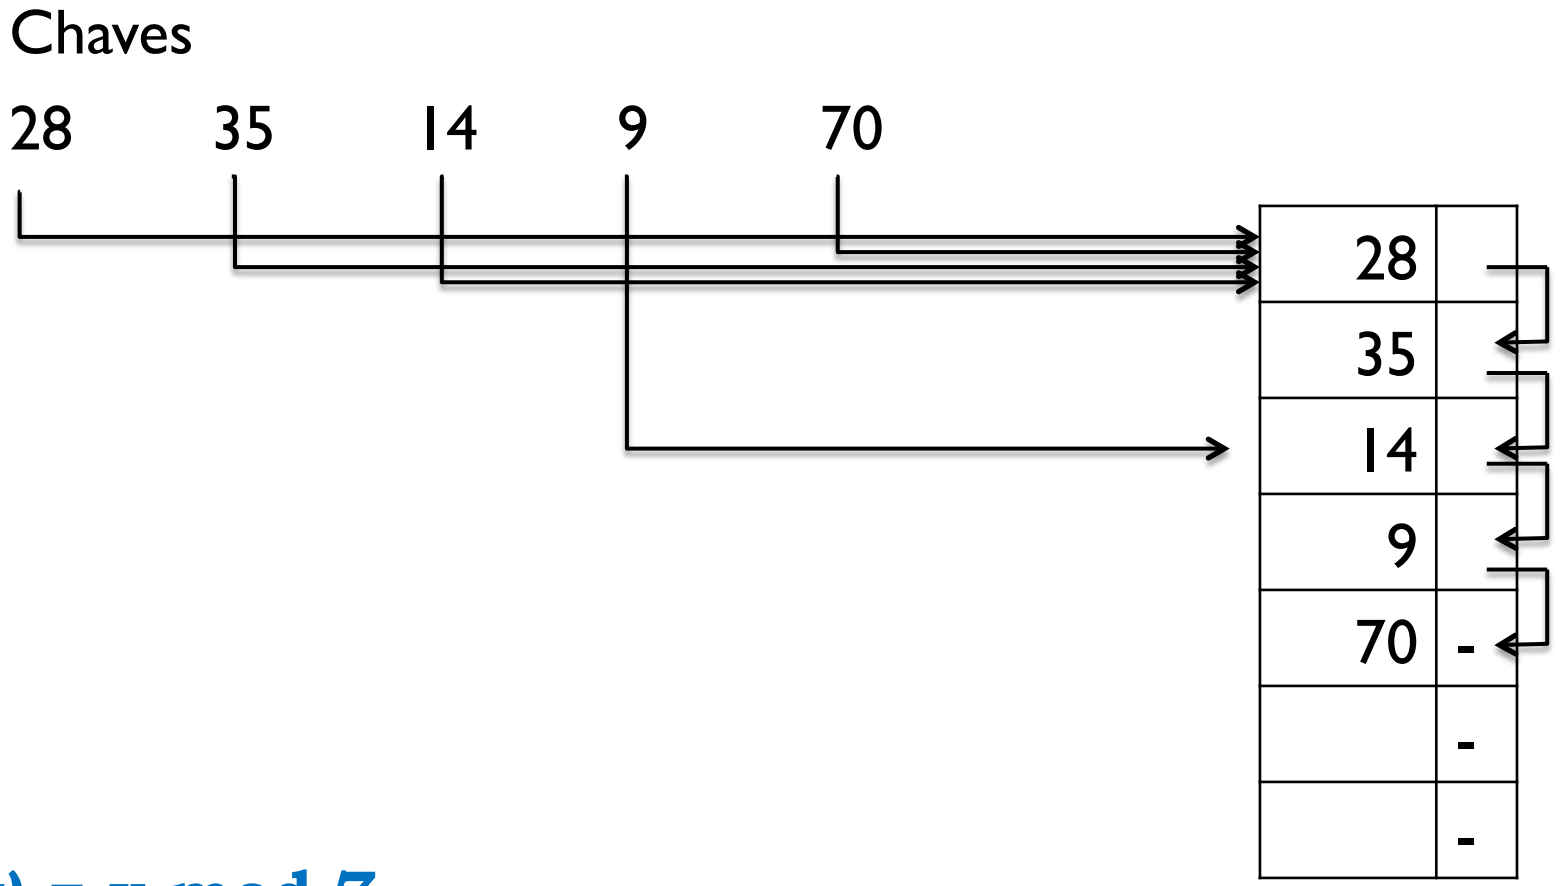


**h(x) = x mod 7**



Note que a Fig. 10.7, pag 243 do livro busca compartimentos livres de baixo para cima

# Procedimento:
# Busca por Encadeamento Interior

```
/* Procedimento assume que a tabela tenha sido inicializada da
   seguinte maneira: T[i].estado = liberado,
   e T[i].pont = i, para 0 < i < m-1

RETORNO:
     Se chave x for encontrada, a = 1,
     end = endereço onde x foi encontrada

     Se chave x não for encontrada, a = 2, e há duas
     possibilidades para o valor de end:
        end = endereço de algum compartimento livre, encontrado
                  na lista encadeada associada a h(x)
        end = λ se não for encontrado endereço livre
*/
```

 Fonte: Algoritmo 10.1, pag 244 (algoritmo no livro contém pequeno erro)

# Procedimento:
# Busca por Encadeamento Interior

```
procedimento busca(x, end, a)
    a:= 0; end:= h(x); j:= λ;
    enquanto a = 0 faça
        se T[end].estado = liberado então j : = end
        se T[end].chave = x e T[end].estado = ocupado então
                    a := 1   % chave encontrada
        senão
              se end = T[end].pont então
                  a := 2; end := j   % chave não encontrada
              senão end := T[end].pont
     fim enquanto
```

# Exercício: Simular a execução do algoritmo de busca

- Procurar chave 9

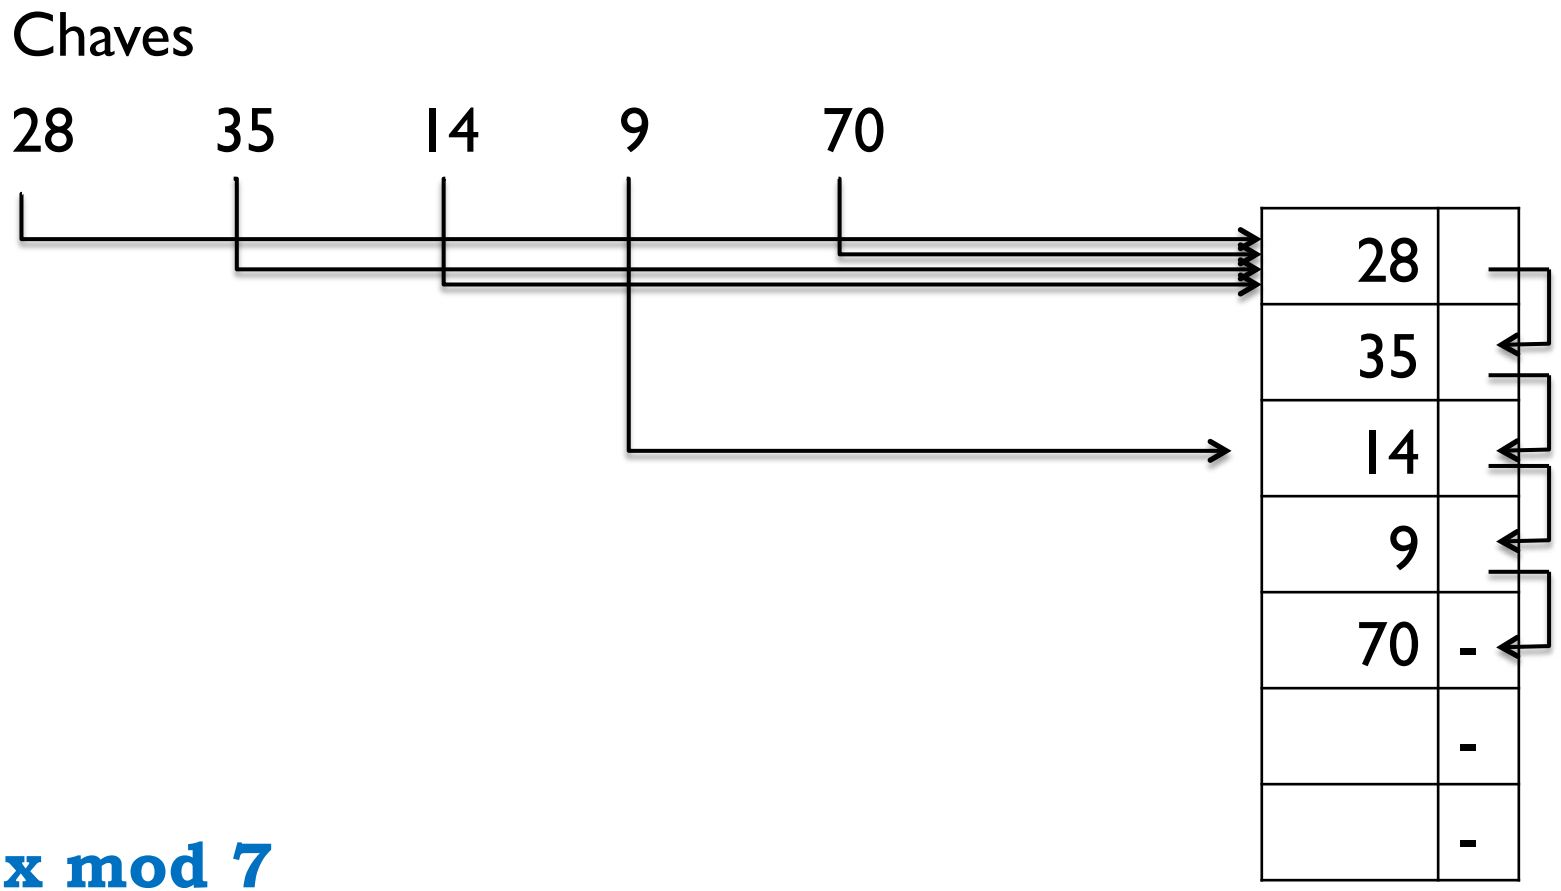


**h(x) = x mod 7**

# Procedimento: Inserção por Encadeamento Interior

```
/* Procedimento assume que j é o endereço
    onde será efetuada a inserção. Para
    efeitos de escolha de j, a tabela foi
    considerada como circular, isto é, o
    compartimento 0 é o seguinte ao m-1
*/
```



Fonte: Algoritmo 10.2, pag 244

# Procedimento: Inserção por Encadeamento Interior

```
procedimento insere(x)
   busca(x, end, a)
   se a ≠ 1 então
         se end ≠ λ então j:= end
         senão i:= 1; j:= h(x)
                  enquanto i ≤ m faça
                           se T[j].estado = ocupado então
                                    j : = (j + 1) mod m
                                    i := i + 1
                           senão i : = m + 2 % comp. não ocupado
                  se i = m + 1 então "inserção inválida: overflow "; pare
                  temp : = T[h(x)].pont   % fusão de listas
                  T[h(x)].pont := j
                  T[j].pont := temp
         T[j].chave: = x % inserção de x
         T[j].estado: = ocupado
   senão "inserção inválida: chave já existente"
```

[83] Fonte: Algoritmo 10.2, pag 244 (algoritmo no livro contém pequeno erro)

# Exercício: Simular a execução do algoritmo de inserção

- Inserir chave 21

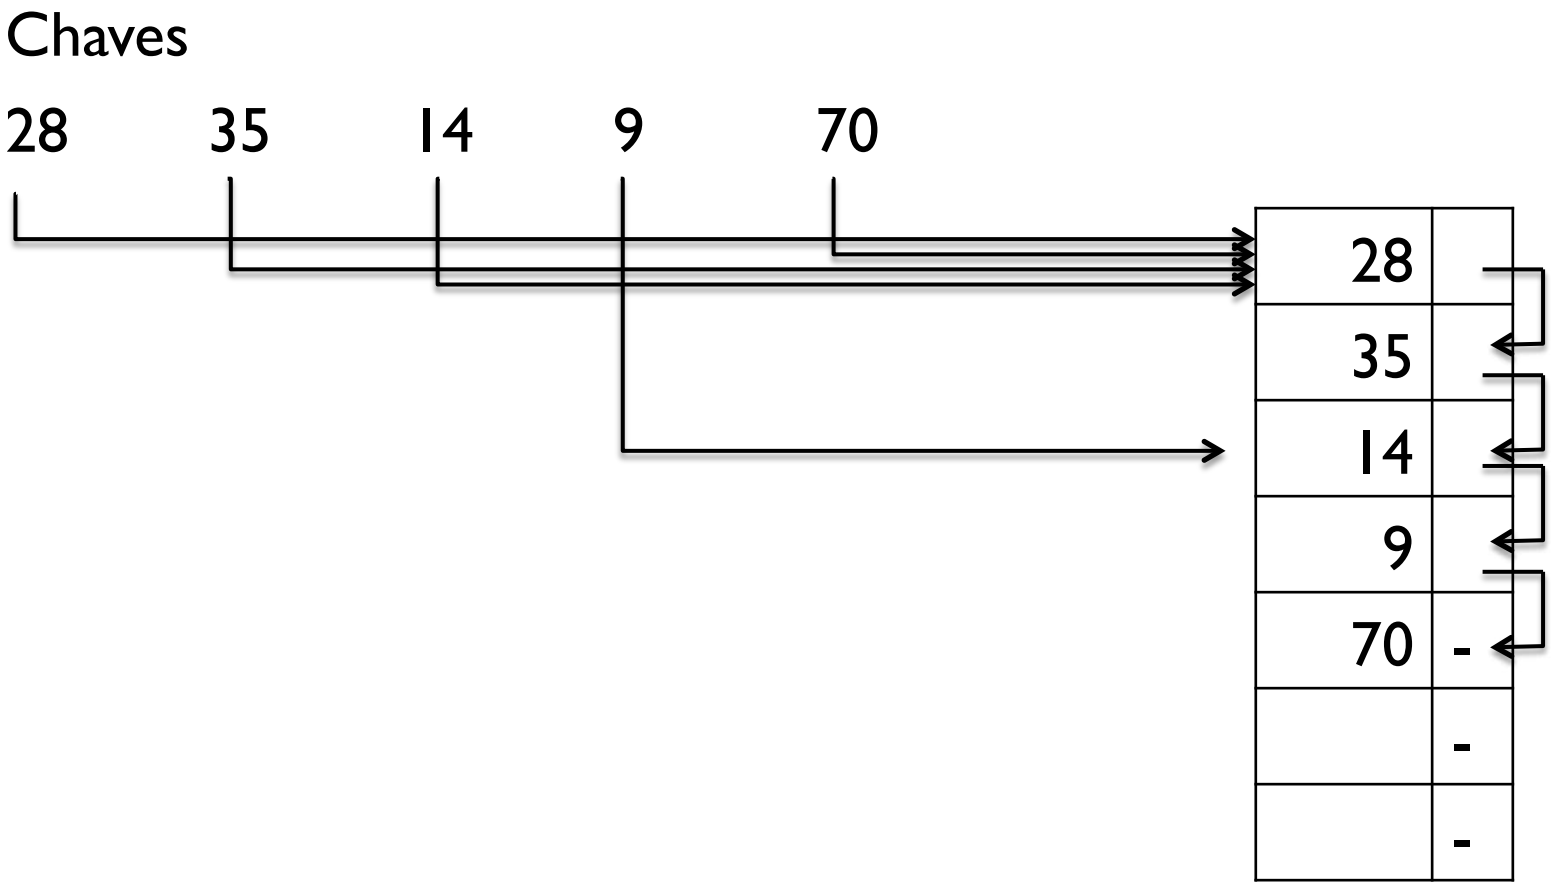

# Procedimento: Remoção por Encadeamento Interior

```
procedimento remove(x)
    busca(x, end, a)
    se a = 1 então T [end].estado: = liberado
    senão "exclusão inválida: chave não existente"
```



Fonte: Algoritmo 10.3, pag 245

# Tratamento de Colisões

- Por Encadeamento
- **Por Endereçamento Aberto**

# Tratamento de Colisões por Endereçamento Aberto

- Motivação: as abordagens anteriores utilizam ponteiros nas listas encadeadas
  - Aumento no consumo de espaço
- Alternativa: armazenar apenas os registros, sem os ponteiros
- Quando houver colisão, determina-se, por cálculo de novo endereço, o próximo compartimento a ser examinado

# Funcionamento

- Para cada chave **x**, é necessário que todos os compartimentos possam ser examinados
- A função **h(x)** deve fornecer, ao invés de um único endereço, um conjunto de **m** endereços base

- Nova forma da função: **h(x,k)**, onde **k = 0, …, m-1**

- Para encontrar a chave **x** deve-se tentar o endereço base **h(x,0)**
- Se estiver ocupado com outra chave, tentar **h(x,1)**, e assim sucessivamente

# Sequência de Tentativas

- A sequência **h(x,0), h(x,1), …, h(x, m-1)** é denominada **sequencia de tentativas**
- A sequencia de tentativas é uma **permutação** do conjunto {0, m-1}

- Portanto: para cada chave **x** a função **h** deve ser capaz de fornecer uma permutação de endereços base

# Procedimento: Busca por Endereçamento Aberto

```
/* Tabela deve ser inicializada com T[i].chave =
    λ .Se a = 1, chave foi encontrada. Se a = 2
    ou 3, a chave não foi encontrada pq
    encontrou uma posição livre (a=2) ou pq a
    tabela foi percorrida até o final (a=3)
*/
procedimento busca-aberto(x, end, a)
        a:=3; k:=0
        enquanto k < m faça
                end:= h(x, k)
                se T[end].chave = x então
                        a:= 1   % chave encontrada
                        k:= m
                senão se T[end].chave = λ então
                                a:= 2  % posição livre
                                k:= m
                        senão k:= k+ 1
```



Fonte: Algoritmo 10.4, pag 247

# Função hash

- Exemplos de funções hash p/ gerar sequência de tentativas
  - Tentativa Linear
  - Tentativa Quadrática
  - Dispersão Dupla

# Função hash

- Exemplos de funções hash p/ gerar sequência de tentativas
  - **Tentativa Linear**
  - Tentativa Quadrática
  - Dispersão Dupla

# Tentativa Linear

- Suponha que o endereço base de uma chave **x** é **h'(x)**
- Suponha que já existe uma chave **y** ocupando o endereço **h'(x)**

- Idéia: tentar armazenar **x** no endereço consecutivo a **h'(x)**. Se já estiver ocupado, tenta-se o próximo e assim sucessivamente
- Considera-se uma tabela circular

- **h(x, k) = (h'(x) + k) mod m**, 0 ≤ k ≤ m-1

# Exemplo Tentativa Linear

- Observem a tentativa de

inserir chave 26

- Endereço já está ocupado: inserir no próximo endereço livre

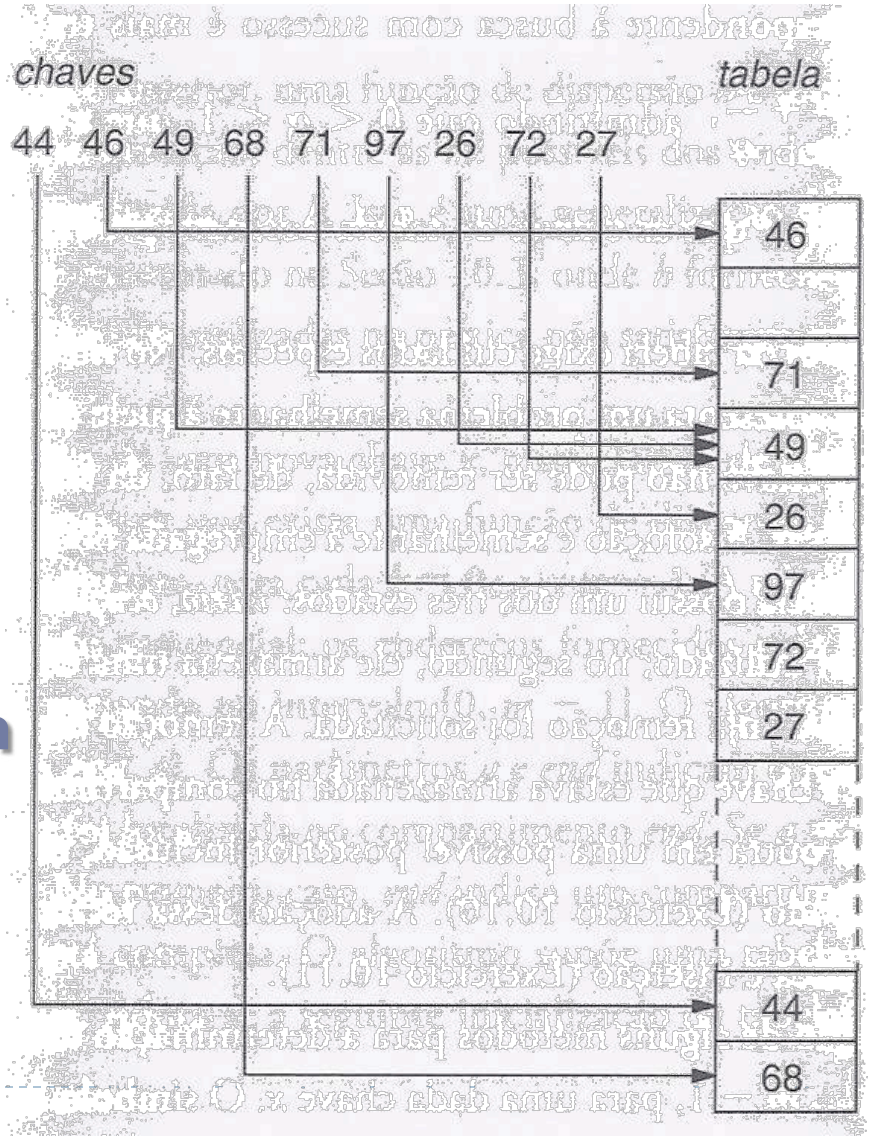


- **h(x, k) = (h'(x) + k) mod m**
- **h'(x) = x mod 23**

# Quais são as desvantagens?

# Quais são as desvantagens?

- Suponha um trecho de **j** compartimentos consecutivos ocupados (chama-se **agrupamento primário**) e um compartimento **l** vazio imediatamente seguinte a esses
- Suponha que uma chave **x** precisa ser inserida em um dos **j** compartimentos
  - **x** será armazenada em **l**
  - isso aumenta o tamanho do compartimento primário para **j + l**
  - Quanto maior for o tamanho de um agrupamento primário, maior a probabilidade de aumentá-lo ainda mais mediante a inserção de uma nova chave

# Função hash

- Exemplos de funções hash p/ gerar sequência de tentativas
  - Tentativa Linear
  - **Tentativa Quadrática**
  - Dispersão Dupla

# Tentativa Quadrática

- Para mitigar a formação de agrupamentos primários, que aumentam muito o tempo de busca:
  - Obter sequências de endereços para endereços-base próximos, porém diferentes
  - Utilizar como incremento uma função quadrática de k

  - **$h(x,k) = (h'(x) + c_1\ k + c_2\ k^2)\ \mathbf{mod}\ m$**,

onde **$c_1$** e **$c_2$** são constantes, **$c_2 \neq 0$** e **$k = 0, \ldots, m-1$**

# Tentativa Quadrática

- Método evita agrupamentos primários
- Mas…
  - Se duas chaves tiverem a mesma tentativa inicial, vão produzir sequências de tentativas idênticas: **agrupamento secundário**

# Tentativa Quadrática

- Valores de **m**, $\mathbf{c_1}$ e $\mathbf{c_2}$ precisam ser escolhidos de forma a garantir que todos os endereços-base serão percorridos

- Exemplo:
  - **h(x,0) = h'(x)**
  - **h(x,k) = (h(x,k-1) + k) mod m**, para **0 < k < m**

  - Essa função varre toda a tabela se **m** for potência de 2

# Comparação: Tentativa Linear x Tentativa Quadrática

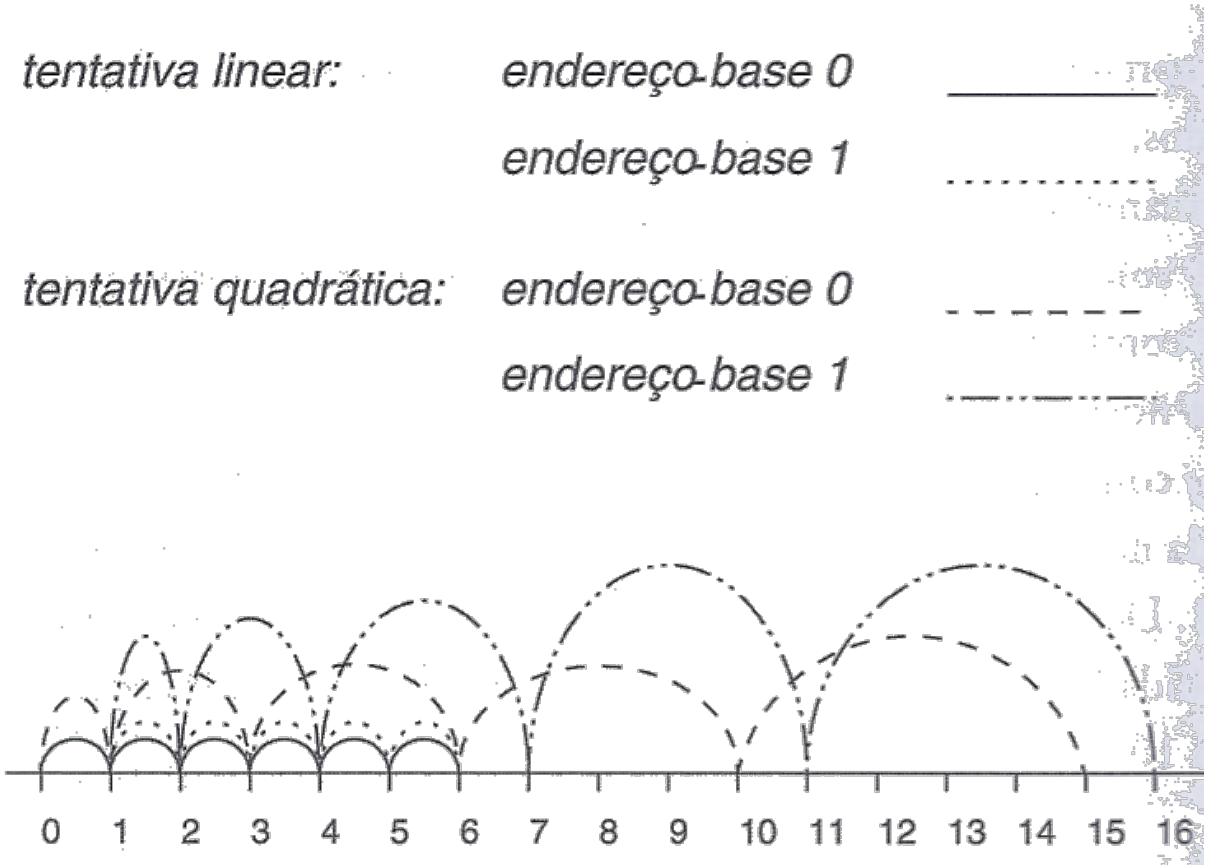

# Função hash

- Exemplos de funções hash p/ gerar sequência de tentativas
  - Tentativa Linear
  - Tentativa Quadrática
  - **Dispersão Dupla**

# Dispersão Dupla

- Utiliza duas funções de hash, **h'(x)** e **h"(x)**
- **h(x,k) = (h'(x) + k.h"(x)) mod m**, para **0 ≤ k < m**
- Método distribui melhor as chaves do que os dois métodos anteriores
  - Se duas chaves distintas **x** e **y** são sinônimas (**h'(x) = h'(y)**), os métodos anteriores produzem exatamente a mesma sequência de tentativas para **x** e **y**, ocasionando concentração de chaves em algumas áreas da tabela
  - No método da dispersão dupla, isso só acontece se **h'(x) = h'(y)** e **h"(x) = h"(y)**

# Tabelas de Dimensão Dinâmica (Tabelas Extensíveis)

Seção 10.6 do livro “Estruturas de Dados e Seus Algoritmos”

# Tabelas Extensíveis

- O que fazer quando o fator de carga da tabela aumenta muito?
  - Deveria ser possível aumentar o tamanho **m** da tabela, de forma a equilibrar o fator de carga
  - Quais são os impactos de se aumentar o tamanho **m** da tabela?

# Impactos

- Impactos de se aumentar o tamanho **m** da tabela:
  1. A função hash tem que mudar
  2. Com isso, todos os endereços dos registros armazenados precisam ser recalculados, e os registros movidos

# Solução

- Alterar apenas parte dos endereços já alocados
- Metódo: Dispersão linear

# Dispersão Linear

- Situação inicial: Tabela com **m** compartimentos **0,..., m-1**
- Expandir inicialmente o compartimento 0
- Depois o compartimento 1, e assim sucessivamente

- Expandir um compartimento **p** significa criar um novo compartimento **q** no final da tabela, denominado expansão de **p**
- O conjunto de chaves sinôminas, originalmente com endereço-base **p** é distribuído entre os compartimentos **p** e **q** de forma conveniente

# Dispersão Linear

- Quando todos os compartimentos tiverem sido expandidos, o tamanho da tabela terá sido dobrado
- Nesse ponto o processo poderá ser recomeçado, se necessário

# Exemplo (m = 5)

- **p** indica o próximo compartimento a ser expandido

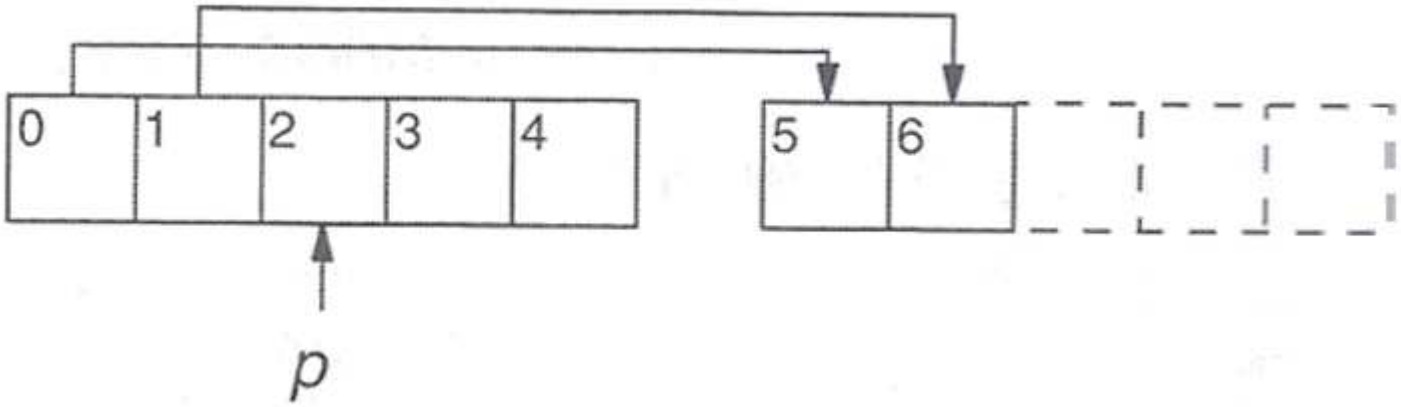

# Manutenção dos endereços ao longo do processo

- Quando a tabela possui tamanho **m = 5**, os endereços-base podem ser encontrados com a função **$h_0(x) = x \bmod 5$**, por exemplo
- Quando a tabela tiver dobrado de tamanho, as chaves serão endereçadas com **$h_1(x) = x \bmod 10$**
- Mas e antes do processo terminar? Como calcular os endereços?

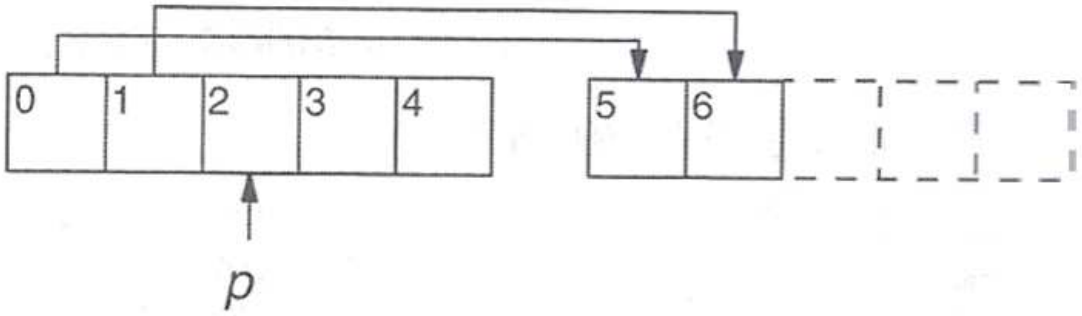

# Manutenção dos endereços ao longo do processo

- Segundo a função **$h_0(x) = x \bmod 5$**:
  - para pertencer ao compartimento 0, último dígito da chave deve ser 0 ou 5
- Segundo a função **$h_1(x) = x \bmod 10$**:
  - chaves com último dígito 0 continuam a pertencer ao compartimento 0
  - chaves com último dígito 5 serão alocadas ao novo compartimento
  - Nenhum dos registros que iriam para os compartimentos 1, 2, 3 ou 4 sofre alterações

# Cálculo dos Endereços

- Dada uma chave **x**, computa-se **$h_0(x)$**
- Seja **p** o menor compartimento ainda não expandido
- Se **$h_0(x) < p$**, o compartimento correspondente já foi expandido
  - Usar **$h_1(x)$** para recalcular o endereço correto

# Cálculo dos Endereços: Caso Geral

- É preciso conhecer **l**: número de vezes que a tabela já foi expandida
- Função de hash: $h_l = x \bmod (m * 2^l)$

# Procedimento mapear

```
/* l indica o número de vezes que a tabela foi expandida a partir
   de seu tamanho mínimo m
   p indica o próximo compartimento a ser expandido
   inicialmente p e l são iguais a zero
*/
procedimento mapear (x, ender, p, l)
    ender := h_l(x)
    se ender < p então
            ender := h_{l+1}(x)
```



Fonte: Algoritmo 10.5, pag 252

# Tratamento de colisões

- Feito por Encadeamento Exteriror
  - Ao expandir um compartimento, é necessário apenas ajustar os ponteiros da lista de nós
  - Não é necessário mover registros fisicamente

# Quando iniciar um processo de expansão?

- Quando o fator de carga atingir um determinado limite máximo
- Da mesma forma, pode-se "encolher" a tabela quando o fator de carga atingir um valor muito baixo

# Discussão

- A técnica de hashing é mais utilizada nos casos em que existem muito mais buscas do que inserções de registros