13 – Hashing Interno (parte 1)

SCC501 - Introdução à Ciência de Computação II

Paulo H. R. Gabriel

phrg@icmc.usp.br

Prof. Moacir Ponti Jr.

www.icmc.usp.br/~moacir

Instituto de Ciências Matemáticas e de Computação – USP

2010/2

Sumário

Busca, inserção e remoção em vetores

- Métodos de busca estudados até agora: Comparação de chaves
- Valor relativo de cada chave
- Tiramos proveito da ordenação

Custo

Ordenação: $\mathcal{O}(n \cdot \log(n))$ ou $\mathcal{O}(n)$
Busca: $\mathcal{O}(\log(n))$
Inserção?
Remoção?

Tabela *Hash* ou de Espalhamento ou de Dispersão

- Valor absoluto das chaves
- Não compara, define valor (função)
- Atingir diretamente a posição

Em outras palavras. . .

$\mathcal{O}(1)$

Intuitivo

Fazemos com frequência. . .

Acesso direto (1/2)

- Indexar elementos em vetores

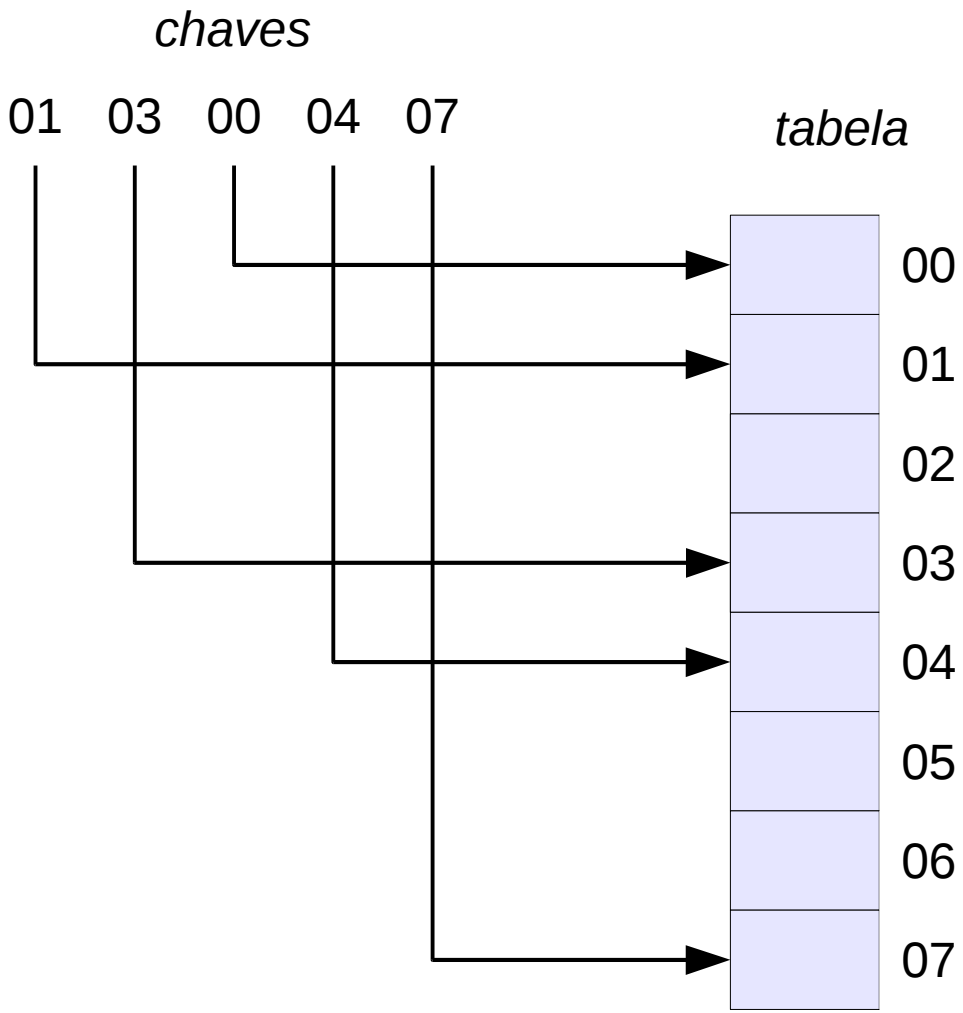

Acesso direto (2/2)

Limitações

- Elementos não numéricos
- Quantidade de espaço vazio
- Frequência de atualizações

Exemplo: Dicionários

- Conjunto de palavras e significados
- Diversas aplicações práticas (*e.g.*, pré-processamento)
- Necessidade de acesso direto (eficiência)
- "Volátil"

Conceitos (1/4)

Ideia Central

Utilizar uma função, aplicada a [parte] da informação (*i.e.*, à chave), para devolver o índice onde a informação deve [deveria] ser armazenada.

- A função é chamada **função de espalhamento** (ou função *hash*)
- A estrutura de dados é a **tabela de espalhamento** (ou tabela *hash*)
- O índice também é chamado de **endereço base**
- A posição onde a chave é alocada recebe o nome de **compartimento** (ou *bucket*)

Conceitos (2/4)

Função de Espalhamento

Uma função de espalhamento $h()$ transforma uma chave x em um endereço-base $h(x)$ da tabela hash.

- Função hash: Função injetora
- Na prática:
  - E se $h(x)$ estiver ocupado?
  - Não há garantias de injetividade: pode existir $y \neq x$ tal que $h(y) = h(x)$

Conceitos (3/4)

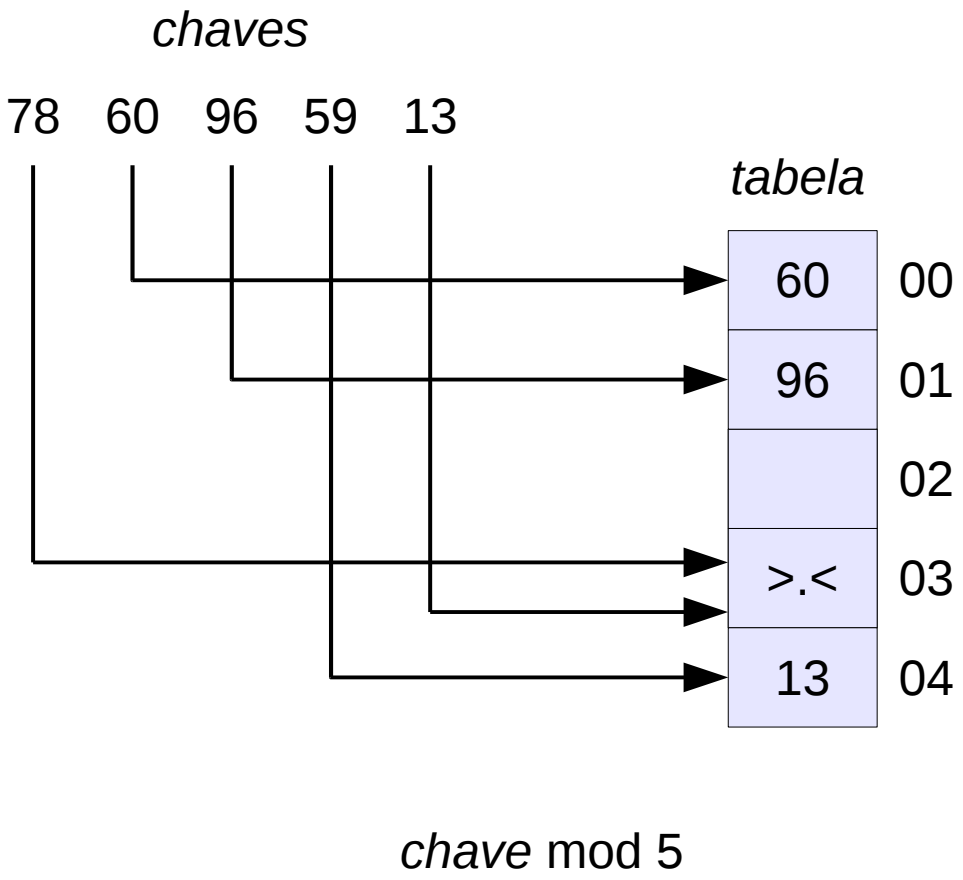

Conceitos (4/4)

- Idealmente:
  - Número baixo de colisões
  - Facilmente computável
  - Uniforme

Tratamento de Colisões

- Fator de carga (número esperado de espaços ocupados):

$$\alpha = \frac{n}{m}$$

- Menor fator de carga $\rightarrow$ Menor número de colisões
- Sempre pode haver uma colisão
- Previsão de tratamento de colisões
  - Endereçamento aberto
  - Encadeamento

Tratamento de Colisões por Endereçamento Aberto (1/3)

Ideia básica

Calcular novo endereço para chaves sinônimas

- Em caso de colisão, calcula-se o novo índice (novo endereço base)
- Processo iterativo, enquanto a chave não for armazenada
- Pode-se utilizar vetor circular

Tratamento de Colisões por Endereçamento Aberto (2/3)

- *Overflow* progressivo
  - Sondagem linear
  - Sondagem quadrática
- *Rehash* – Aplicar segunda função *hash*

Tratamento de Colisões por Endereçamento Aberto (3/3)

- Sondagem linear
  - Todas posições da tabela são checadas
  - $rh(h(x)) = (h(x) + k) \mod m$
    $0 \leq k \leq m - 1$
  - Longos trechos consecutivos podem ser ocupados
- Sondagem quadrática
  - Diversifica sequência de endereços
  - $rh(h(x)) = (h(x) + c_1 \cdot k + c_2 \cdot k^2) \mod m$
    $0 \leq k \leq m - 1$
    c_1 e c_2 são constantes, $c_2 \neq 0$
  - Agrupamento ocorre com menos frequência

Tratamento de Colisões por Encadeamento

Mais natural

Armazena chaves sinônimas em listas encadeadas

Duas implementações

- "Externo" à tabela
- "Interno" à tabela

Encadeamento Externo (1/2)

- m listas encadeadas
- Endereço base: cabeça da lista
- Busca, inserção e remoção em listas encadeadas

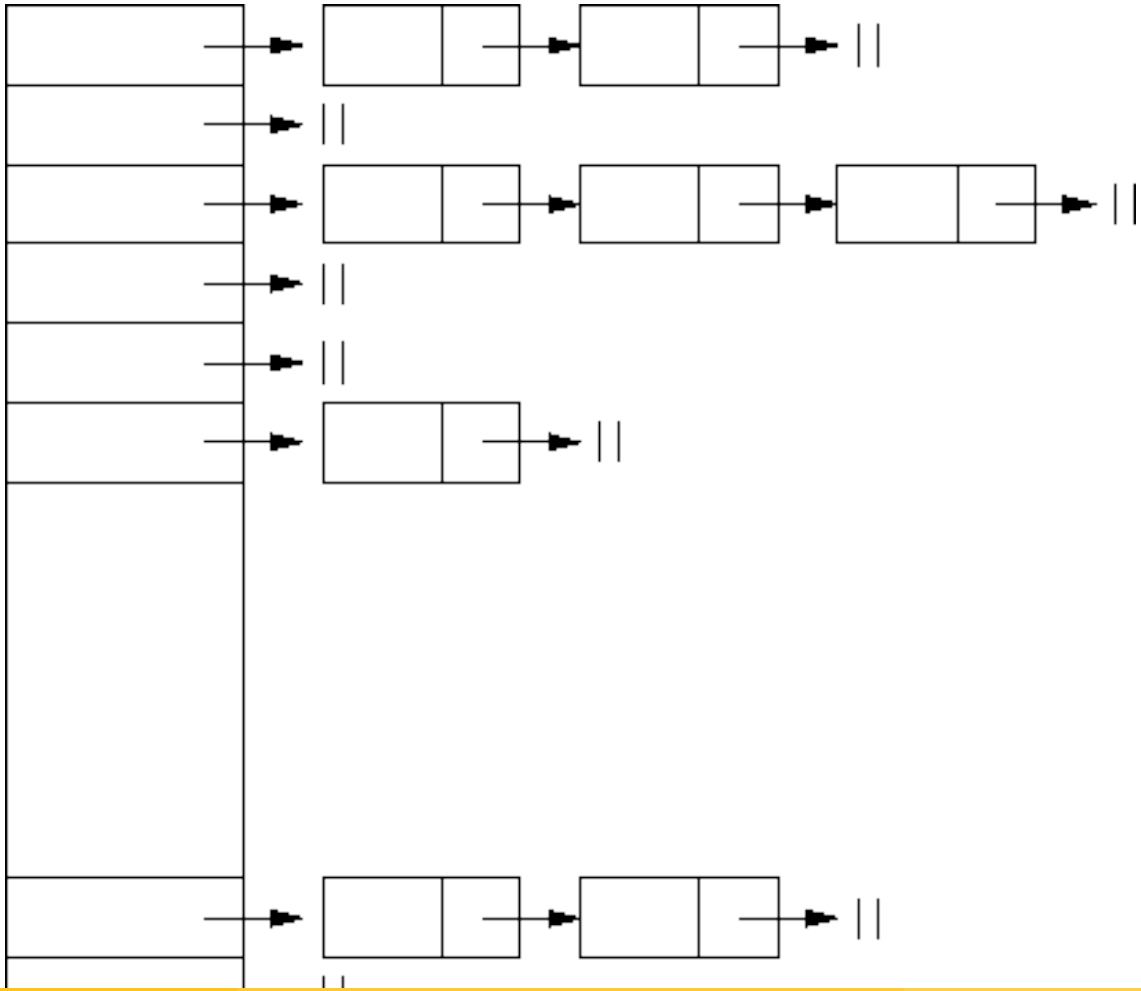

Encadeamento Externo (2/2)

- Melhor caso (inserir): $\mathcal{O}(1)$
- Pior caso (buscar): $\mathcal{O}(n)$
- Pode-se inserir ordenado para reduzir a busca
- **Deve-se questionar:** Qual operação será realizada mais vezes?

Encadeamento Interno (1/3)

- Divisão da tabela: $p + s = m$
- Função de espalhamento busca endereços em $[0, p - 1]$
- Cada posição tem dois campos
  - Armazenamento da chave
  - Ponteiro para próximo sinônimo

Encadeamento Interno (2/3)

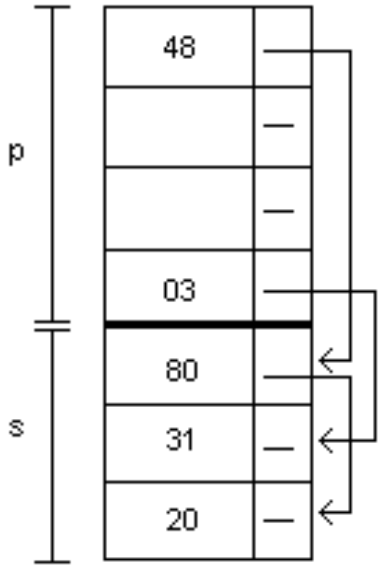

$h(x) = x \% 4$

Entrada: 48, 80, 03, 31, 20

- Pode degenerar em uma lista encadeada

Encadeamento Interno (3/3)

- Pode-se, alternativamente, não diferenciar as duas regiões

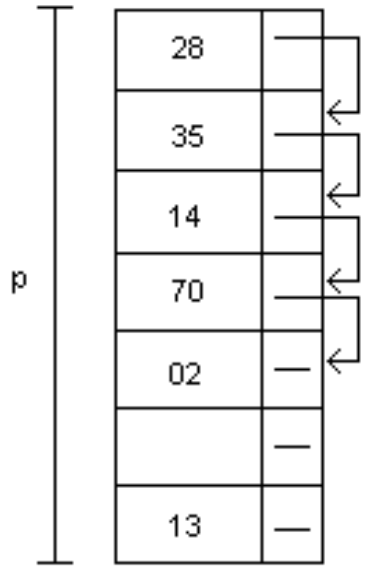

h(x) = x % 7

Entrada: 28, 35, 13, 14, 70, 02

- Problema: colisões secundárias

Leituras Recomendadas I


ROSA, J. L. G.
Métodos de Busca.
Slides de aula SCC-201, ICMC-USP.


SHEWCHUK, J.
Hash Table – Data Structures University of California, Berkeley..
Disponível em: `http://www.youtube.com/watch?v=UPo-M8bzRrc`


ZIVIANI, N.
Projeto de Algoritmos (Capítulo 5). 3.ed..
Cengage Learning


CORMEN, T. H., LEISERSON, C. E., RIVEST, R. L., STEIN, C.
Introduction to Algorithms.
MIT Press, 2001

Leituras Recomendadas II

LEVITIN, A. V.
Introduction to the Design and Analysis of Algorithms (Capítulo 7), 1.ed..
Addison-Wesley Longman Publishing Co., Inc., 2002.

Szwarcfiter, J. L., Markenzon, L.
Estruturas de Dados e seus Algoritmos (Capítulo 8), 2.ed.
LTC Editora, 1994.

NONATO, L. G.
Material da disciplina SCE5763 – Tipos e Estrutura de Dados.
`www.lcad.usp.br/~nonato/ED/EDpos.html`, 2000.