Hashing

Estruturas de Dados e Algoritmos – Ciência da Computação

Prof. Daniel Saad Nogueira Nunes

IFB – Instituto Federal de Brasília,
Campus Taguatinga

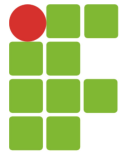

Sumário

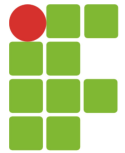

Sumário

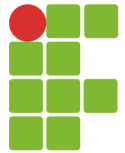

Introdução

- Em muitas aplicações, precisamos de um conjunto dinâmico, que suporte:
  - INSERT: inserção de um elemento pela sua chave.
  - DELETE: remoção de um elemento pela sua chave.
  - SEARCH: busca de um elemento pela sua chave.

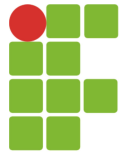

Estruturas de Dados

- Muitas estruturas suportam essas operações eficientemente, *e.g.*,
  - Árvores Binárias de Pesquisa.
  - Árvores Rubro-Negras.
  - ...
- Geralmente, o custo de cada operação é $\Theta(\log n)$.

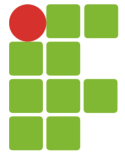

Estruturas de Dados

- Muitas estruturas suportam essas operações eficientemente, *e.g.*,
  - Árvores Binárias de Pesquisa.
  - Árvores Rubro-Negras.
  - ...
- Geralmente, o custo de cada operação é $\Theta(\log n)$.
- Será que podemos responder essas operações em $\Theta(1)$?

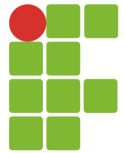

Estrutura de Dados

Hashing

- Possibilita a resposta dessas consultas em $O(1)$. No **caso médio**.
- No pior caso, as consultas levam $\Theta(n)$.
- Com hashing perfeito, conseguimos $O(1)$ até no **pior caso**!
- Alternativa eficiente na prática.
- Utilizado em Sistemas Operacionais para *lookup* rápido de tabelas.

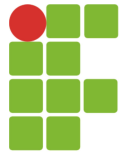

Motivação

- Antes de introduzir o conceito de hashing, vamos dar uma pequena motivação ao mostrar problemas existentes com outros métodos.
- Mostraremos como a técnica de Hashing soluciona estes problemas.

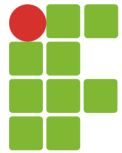

Motivação

Tabelas de Endereçamento Direto

- O uso de tabelas de endereçamento diretos proporciona consultas de inserção, remoção e busca em tempo $O(1)$ no pior caso.
- Seja $U = \{0, 1, 2, \ldots, m-1\}$ chaves do conjunto universo.
- **Premissa**: dois elementos distintos tem chaves distintas.
- Para cada chave, existe apenas uma entrada na tabela de endereçamento direto.
- Se o elemento não existe, então o conteúdo da tabela é preenchido com uma constante $\perp$.

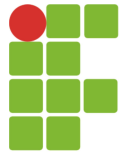

Tabelas de Endereçamento Direto

- As operações das operações usando tabelas de endereçamento direto são triviais de serem implementadas.

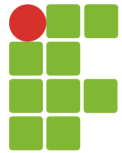

Operações em Tabelas de Endereçamento Direto

Algorithm 1: DAT-SEARCH(T, x)

Input: T, x
Output: x
1 **return** $T[x.key]$

Algorithm 2: DAT-INSERT(T, x)

Input: T, x
1 $T[x.key] \leftarrow x$

Algorithm 3: DAT-DELETE(T, x)

Input: T, x
1 $T[x.key] \leftarrow \perp$

Tabelas de Endereçamento Direto

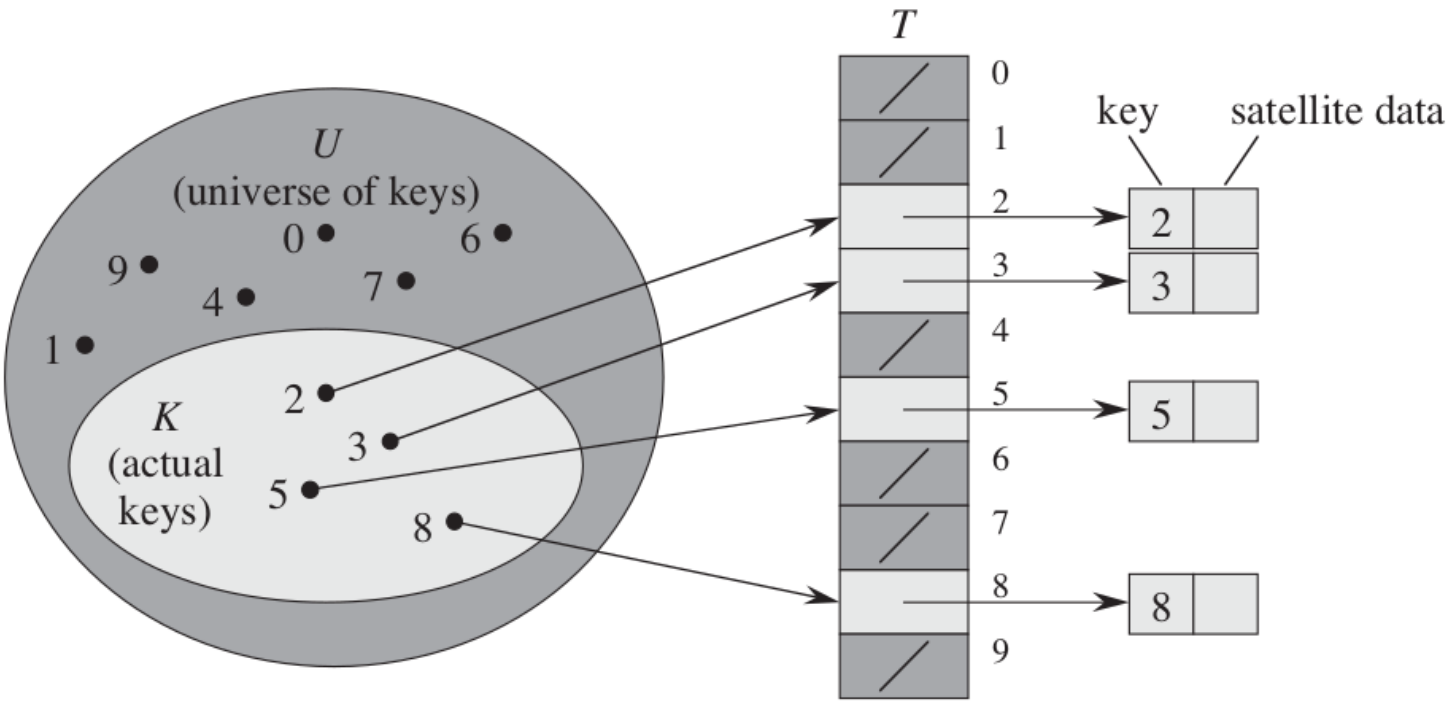

Figura: Tabelas de Endereçamento Direto.

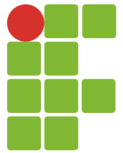

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?

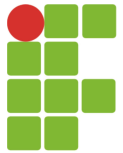

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?
- $|U|$, o tamanho do espaço de chaves.

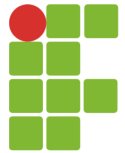

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?
- $|U|$, o tamanho do espaço de chaves.
- O que acontece se as chaves forem números de 64 bits?

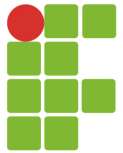

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?
- $|U|$, o tamanho do espaço de chaves.
- O que acontece se as chaves forem números de 64 bits?
- $|U| = 2^{64}$.

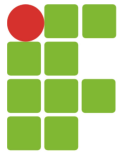

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?
- $|U|$, o tamanho do espaço de chaves.
- O que acontece se as chaves forem números de 64 bits?
- $|U| = 2^{64}$.
- Além disso, o número de elementos inseridos pode ser muito menor que o espaço de chaves.

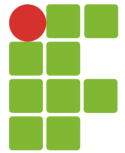

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?
- $|U|$, o tamanho do espaço de chaves.
- O que acontece se as chaves forem números de 64 bits?
- $|U| = 2^{64}$.
- Além disso, o número de elementos inseridos pode ser muito menor que o espaço de chaves.
- **Problema**: muito espaço utilizado.

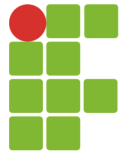

Tabelas de Endereçamento Direto

- Qual o problema de utiliza esta técnica?
- Quantas posições precisamos na nossa tabela?
- $|U|$, o tamanho do espaço de chaves.
- O que acontece se as chaves forem números de 64 bits?
- $|U| = 2^{64}$.
- Além disso, o número de elementos inseridos pode ser muito menor que o espaço de chaves.
- **Problema**: muito espaço utilizado.
- **Solução**: hashing!

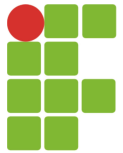

Sumário

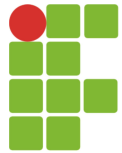

Hashing

Ideia do Hashing

- Nas tabelas de endereçamento direto, o elemento de chave k é armazenado no k-ésimo slot.
- Utilizando a técnica de **hashing**, aplicamos uma função $h : U \to \{0, 1, \ldots, m-1\}$, de modo que h mapeie um elemento x e uma entrada da tabela de **hash**.
- **Problema**: nem sempre h é injetora.

Hashing

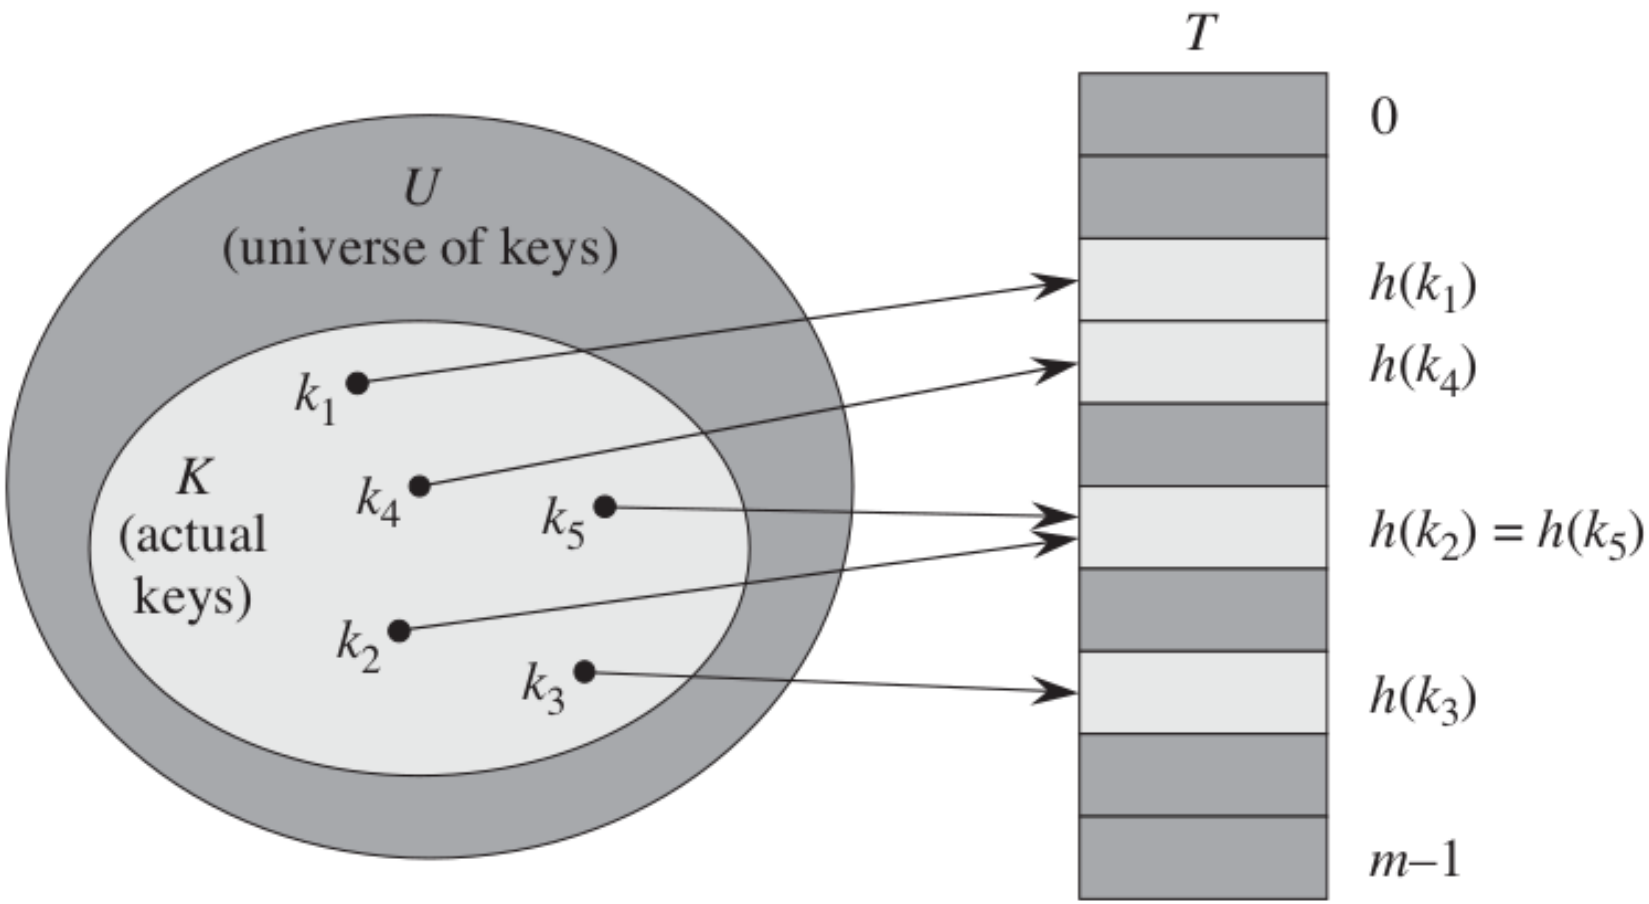

Figura: Técnica de hashing.

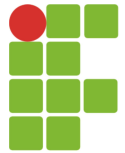

Hashing

Vantagens e Desvantagens

- Obviamente, a técnica de hashing tem uma vantagem enorme de espaço em relação à técnica de endereçamento direto.
- Em vez de utilizar $|U|$, utilizamos apenas m entradas da tabela hash.
- Problema: dois ou mais elementos podem ser mapeados na mesma posição da tabela.

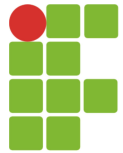

Hashing

Vantagens e Desvantagens

- Obviamente, a técnica de hashing tem uma vantagem enorme de espaço em relação à técnica de endereçamento direto.
- Em vez de utilizar $|U|$, utilizamos apenas m entradas da tabela hash.
- Problema: dois ou mais elementos podem ser mapeados na mesma posição da tabela.
- Princípio da casa dos pombos!

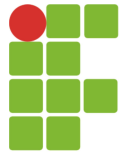

Hashing

Vantagens e Desvantagens

- Obviamente, a técnica de hashing tem uma vantagem enorme de espaço em relação à técnica de endereçamento direto.
- Em vez de utilizar $|U|$, utilizamos apenas m entradas da tabela hash.
- Problema: dois ou mais elementos podem ser mapeados na mesma posição da tabela.
- Princípio da casa dos pombos!
- Chamamos isso de **colisão**.

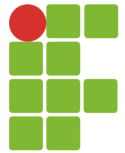

Hashing

Tratamento de Colisões

- Obviamente, haverão colisões, uma vez que $m < |U|$.
- Temos que escolher h de maneira apropriada, de maneira que espalhe os elementos de maneira uniforme!
- h tem que "parecer aleatória".
- Além disso, temos que conseguir distinguir um elemento do outro, temos que tratar a colisão.

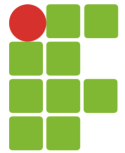

Hashing

Tratamento de Colisões

- Existem diversas maneiras de tratar colisão.
- Estudaremos o método de encadeamento.

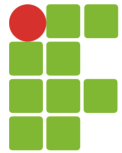

Encadeamento

Encadeamento

- No encadeamento, colocamos todos os elementos mapeados em uma mesma entrada em uma **lista encadeada**.
- Cada *slot* tem um ponteiro para a cabeça da lista.

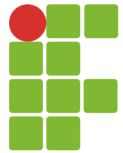

Operações em Hashing com Encadeamento

Algorithm 4: CHAINED-HASH-SEARCH

Input: T, x

Output: x

1 Procure o elemento x na lista apontada por $h(x)$

2 Retorne $\perp$ caso x não ocorra na lista, e x caso contrário.

Algorithm 5: CHAINED-HASH-INSERT

Input: T, x

1 Insira x no final da lista apontada por $h(x)$

Algorithm 6: CHAINED-HASH-DELETE

Input: T, x

1 Ache x na lista apontada por $h(x)$

2 Remova x da lista

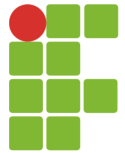

Operações em Hashing com Encadeaento

Análise

- Inserção: $O(1)$ de pior caso.
- Remoção: proporcional ao tamanho da lista.
- Busca: proporcional ao tamanho da lista.

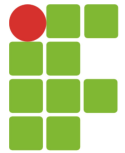

Operações em Hashing de Encadeamento

Análise

- O pior caso da técnica de hashing com encadeamento é muito ruim. $\Theta(n)$.
- Mas se escolhermos uma função de hashing adequada, o caso médio é bastante atraente na prática.

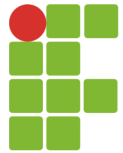

Operações em Hashing de Encadeamento

Definição (Fator de Carga)

- O fator de carga, definido como α, é dado por n/m. Sendo n o número de elementos e m o tamanho da tabela hashing.

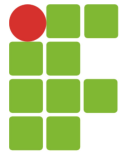

Operações em Hashing de Encadeamento

Análise

- Em uma função de hashing adequada, o tamanho de uma lista arbitrária é bem próxima de α.
- Pior caso de busca: $\Theta(1 + \alpha)$, desde que a função de hash espalhe de maneira uniforme.
- Quanto mais espaço, menos colisões.
- Quanto mais espaço, mais espaço!

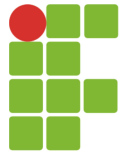

Sumário

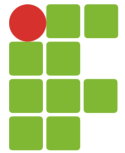

Funções de Hashing

- Vimos que o sucesso da técnica de hash se baseia na escolha da função de hash.
- A função tem que parecer uniforme.
- Caso contrário, haverão muitas colisões, e portanto, mais tempo será gasto procurando elementos.

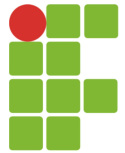

Funções de Hashing

Projetando funções de Hashing

- Para projetar uma função de hashing adequada, temos que analisar uma série de fatores.
  - A distribuição das chaves é conhecida?
  - Queremos que valores próximos ocupem *slots* próximos?

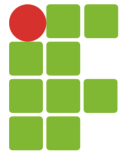

Funções de Hashing

Projetando funções de Hashing

- A função de hashing age de tal forma que transforma a chave em números naturais, correspondentes a um índice da tabela.
- Mesmo que estejamos falando de uma *string* ou um tipo definido pelo programador.

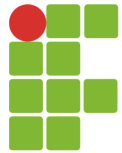

Funções de Hashing

Método da Divisão

- O método da divisão mapeia uma chave k, inteira, em um dos m *slots* ao pegar o resto da divisão de k por m.

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

- Exemplo, se $m = 12$ e $k = 100$, então $h(k) = 4$.
- Muito rápida na prática, precisamos apenas de uma instrução de divisão e um acesso à memória.

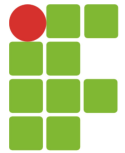

Funções de Hashing

Método da Divisão

- Temos que tentar evitar alguns valores de m.
- Por exemplo, se m for uma potência de 2, i.e, $m = 2^p$, então $h(k)$ são os p bits menos significativos.
- O padrão dos bits menos significativos pode ser altamente repetitivo dependendo da aplicação.

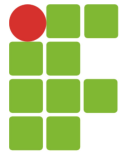

Funções de Hashing

Método da Divisão

- Geralmente, um primo não muito próximo de uma potência de 2 é uma boa escolha.
- Por exemplo, para $n = 2000$, $m = 701$ é uma boa escolha:

$$h(k) = k \mod 701$$

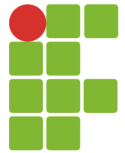

Funções de Hashing

Método da Multiplicação

- O método da multiplicação para criar funções de hash opera em dois passos.
  1. Primeiro multiplicamos a chave k por uma constante A, $0 < A < 1$ e extraímos a parte fracionária de k.
  2. Depois, multiplicamos este valor por m e pegamos o chão do resultado.

$$h(k) = \lfloor m(k \cdot A \mod 1) \rfloor$$

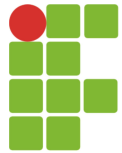

Funções de Hashing

Método da Multiplicação

- Uma vantagem deste método é que o valor de m não é crítico.
- Geralmente escolhemos $m = 2^p$ para algum p.
  - Mais fácil de implementar.
- Seja w o tamanho da palavra do computador e suponha que as chaves caibam em uma palavra. Podemos restringir A como um número da forma $s/2^w$, onde $0 < s < 2^w$.
- Apesar deste método funcionar para qualquer valor de A, alguns valores se comportam melhor que outros.
- Sugestão do D. Knuth: $A \approx (\sqrt{5} - 1)/2 = 0.6180339887\ldots$

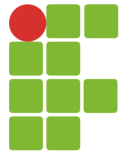

Sumário

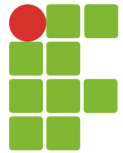

Considerações

- O método de hashing é extremamente útil para inserção, remoção ou busca de elementos em tempo eficiente.
- Contudo, a função de hashing deve ser adequada para manter os tempos competitivos.
- *Trade-off*: espaço *vs* tempo.