

Algoritmos e Estruturas de Dados I

TABELAS HASH

Prof. Tiago Eugenio de Melo
tmelo@uea.edu.br

www.tiagodemelo.info

Introdução

Problema

Problema

- Princípio de funcionamento dos métodos de busca

Problema

- Princípio de funcionamento dos métodos de busca
 - Procurar a informação desejada com base na comparação de suas chaves, isto é, com base em algum valor que a compõe.

Problema

Problema

- Algoritmos eficientes necessitam que os elementos estejam armazenados de forma ordenada

Problema

- Algoritmos eficientes necessitam que os elementos estejam armazenados de forma ordenada
- Custo ordenação melhor caso é $O(N \log N)$

Problema

- Algoritmos eficientes necessitam que os elementos estejam armazenados de forma ordenada
- Custo ordenação melhor caso é $O(N \log N)$
- Custo da busca melhor caso é $O(\log N)$

Problema

Problema

- Custo da comparação de chaves é alto

Problema

- Custo da comparação de chaves é alto
- O que seria uma operação de busca ideal?

Problema

- Custo da comparação de chaves é alto
- O que seria uma operação de busca ideal?
 - Seria aquela que permitisse o acesso direto ao elemento procurado, sem nenhuma etapa de comparação de chaves.

Problema

- Custo da comparação de chaves é alto
- O que seria uma operação de busca ideal?
 - Seria aquela que permitisse o acesso direto ao elemento procurado, sem nenhuma etapa de comparação de chaves.
 - Nesse caso, teríamos um custo $O(1)$.

Problema

- Custo da comparação de chaves é alto
- O que seria uma operação de busca ideal?
 - Seria aquela que permitisse o acesso direto ao elemento procurado, sem nenhuma etapa de comparação de chaves.
 - Nesse caso, teríamos um custo $O(1)$.
 - Tempo sempre constante de acesso

Problema

Problema

- Uma saída é usar arrays

Problema

- Uma saída é usar arrays
 - São estruturas que utilizam índices para armazenar informações.

Problema

- Uma saída é usar arrays
 - São estruturas que utilizam índices para armazenar informações.
 - Permite acessar um determinada posição com custo $O(1)$.

Problema

- Uma saída é usar arrays
 - São estruturas que utilizam índices para armazenar informações.
 - Permite acessar um determinada posição com custo $O(1)$.
- Problema

Problema

- Uma saída é usar arrays
 - São estruturas que utilizam índices para armazenar informações.
 - Permite acessar um determinada posição com custo $O(1)$.
- Problema
 - Arrays não possuem nenhum mecanismo que permita calcular a posição onde uma informação está armazenada.

Problema

- Uma saída é usar arrays
 - São estruturas que utilizam índices para armazenar informações.
 - Permite acessar um determinada posição com custo $O(1)$.
- Problema
 - Arrays não possuem nenhum mecanismo que permita calcular a posição onde uma informação está armazenada.
 - A operação de busca não é $O(1)$.

Problema

Problema

- Precisamos do tempo de acesso do array juntamente com a capacidade de busca um elemento em tempo constante.

Problema

- Precisamos do tempo de acesso do array juntamente com a capacidade de busca um elemento em tempo constante.
- Solução: usar uma **tabela hash**.

Tabela Hash

Tabela Hash

Tabela Hash

- Também conhecidas como tabelas de indexação ou de espalhamento

Tabela Hash

- Também conhecidas como tabelas de indexação ou de espalhamento
 - É uma generalização da ideia de array.

Tabela Hash

- Também conhecidas como tabelas de indexação ou de espalhamento
 - É uma generalização da ideia de array.
- Ideia central

Tabela Hash

- Também conhecidas como tabelas de indexação ou de espalhamento
 - É uma generalização da ideia de array.
- Ideia central
 - Utilizar uma função, chamada de **função de hashing**, para espalhar os elementos que queremos armazenar na tabela.

Tabela Hash

- Também conhecidas como tabelas de indexação ou de espalhamento
 - É uma generalização da ideia de array.
- Ideia central
 - Utilizar uma função, chamada de **função de hashing**, para espalhar os elementos que queremos armazenar na tabela.
 - Esse espalhamento faz com que os elementos fiquem dispersos de forma não ordenada dentro do array que define a tabela.

Tabela Hash

- Exemplo:




Tabela Hash

Tabela Hash

- Por que espalhar os elementos melhora a busca?

Tabela Hash

- Por que espalhar os elementos melhora a busca?
 - A tabela permite a associar valores a chaves

Tabela Hash

- Por que espalhar os elementos melhora a busca?
 - A tabela permite a associar valores a chaves
 - **chave**: parte da informação que compõe o elemento a ser inserido ou buscado na tabela.

Tabela Hash

- Por que espalhar os elementos melhora a busca?
 - A tabela permite a associar valores a chaves
 - **chave**: parte da informação que compõe o elemento a ser inserido ou buscado na tabela.
 - **valor**: é a posição (índice) onde o elemento se encontra no array que define a tabela.

Tabela Hash

- Por que espalhar os elementos melhora a busca?
 - A tabela permite a associar valores a chaves
 - **chave**: parte da informação que compõe o elemento a ser inserido ou buscado na tabela.
 - **valor**: é a posição (índice) onde o elemento se encontra no array que define a tabela.
 - Assim, a partir de uma chave podemos acessar de forma rápida uma determinada posição do array.

Tabela Hash

- Por que espalhar os elementos melhora a busca?
 - A tabela permite a associar valores a chaves
 - **chave**: parte da informação que compõe o elemento a ser inserido ou buscado na tabela.
 - **valor**: é a posição (índice) onde o elemento se encontra no array que define a tabela.
 - Assim, a partir de uma chave podemos acessar de forma rápida uma determinada posição do array.
 - Na média, essa operação tem custo **$O(1)$** .

Tabela Hash

Tabela Hash

- Vantagens

Tabela Hash

- Vantagens
 - Alta eficiência na operação de busca

Tabela Hash

- Vantagens
 - Alta eficiência na operação de busca
 - Caso médio é **$O(1)$** enquanto o da busca linear é **$O(N)$** e a da busca binária é **$O(\log N)$** .

Tabela Hash

- Vantagens
 - Alta eficiência na operação de busca
 - Caso médio é **$O(1)$** enquanto o da busca linear é **$O(N)$** e a da busca binária é **$O(\log N)$** .
 - Tempo de busca é praticamente independente do número de chaves armazenadas na tabela.

Tabela Hash

- Vantagens
 - Alta eficiência na operação de busca
 - Caso médio é **$O(1)$** enquanto o da busca linear é **$O(N)$** e a da busca binária é **$O(\log N)$** .
 - Tempo de busca é praticamente independente do número de chaves armazenadas na tabela.
 - Implementação *relativamente* simples.

Tabela Hash

Tabela Hash

- Infelizmente, esse tipo de implementação também tem suas desvantagens:

Tabela Hash

- Infelizmente, esse tipo de implementação também tem suas desvantagens:
 - Alto custo para recuperar os elementos da tabela ordenados pela chave.

Tabela Hash

- Infelizmente, esse tipo de implementação também tem suas desvantagens:
 - Alto custo para recuperar os elementos da tabela ordenados pela chave.
 - Nesse caso, é preciso ordenar a tabela.

Tabela Hash

- Infelizmente, esse tipo de implementação também tem suas desvantagens:
 - Alto custo para recuperar os elementos da tabela ordenados pela chave.
 - Nesse caso, é preciso ordenar a tabela.
 - O pior caso é $O(N)$, sendo N o tamanho da tabela.

Tabela Hash

- Infelizmente, esse tipo de implementação também tem suas desvantagens:
 - Alto custo para recuperar os elementos da tabela ordenados pela chave.
 - Nesse caso, é preciso ordenar a tabela.
 - O pior caso é $O(N)$, sendo N o tamanho da tabela.
 - Alto número de colisões.

Tabela Hash

Tabela Hash

- O que é uma colisão?

Tabela Hash


- O que é uma colisão?
 - Uma colisão ocorre quando duas (ou mais) chaves diferentes tentam ocupar a mesma posição na tabela hash.

Tabela Hash

- O que é uma colisão?
 - Uma colisão ocorre quando duas (ou mais) chaves diferentes tentam ocupar a mesma posição na tabela hash.
 - A colisão de chaves não é algo exatamente ruim, é apenas algo indesejável pois diminui o desempenho do sistema.

Tabela Hash

- Exemplo de colisão:



Aplicações

Aplicações

Aplicações

- A tabela hash pode ser utilizada para:

Aplicações

- A tabela hash pode ser utilizada para:
 - Busca de elementos em base de dados

Aplicações

- A tabela hash pode ser utilizada para:
 - Busca de elementos em base de dados
 - Estruturas de dados em memória, bancos de dados e mecanismos de busca na Internet;

Aplicações

- A tabela hash pode ser utilizada para:
 - Busca de elementos em base de dados
 - Estruturas de dados em memória, bancos de dados e mecanismos de busca na Internet;
 - Verificação de integridade de dados e autenticação de mensagens

Aplicações

- A tabela hash pode ser utilizada para:
 - Busca de elementos em base de dados
 - Estruturas de dados em memória, bancos de dados e mecanismos de busca na Internet;
 - Verificação de integridade de dados e autenticação de mensagens
 - Os dados são enviados juntamente com o resultado da função de hashing.

Aplicações

- A tabela hash pode ser utilizada para:
 - Busca de elementos em base de dados
 - Estruturas de dados em memória, bancos de dados e mecanismos de busca na Internet;
 - Verificação de integridade de dados e autenticação de mensagens
 - Os dados são enviados juntamente com o resultado da função de hashing.
 - Quem receber os dados recalcula a função de hashing usando os dados recebidos e compara o resultado obtido com o que ele recebeu.

Aplicações

- A tabela hash pode ser utilizada para:
 - Busca de elementos em base de dados
 - Estruturas de dados em memória, bancos de dados e mecanismos de busca na Internet;
 - Verificação de integridade de dados e autenticação de mensagens
 - Os dados são enviados juntamente com o resultado da função de hashing.
 - Quem receber os dados recalcula a função de hashing usando os dados recebidos e compara o resultado obtido com o que ele recebeu.
 - Resultados diferentes: erro de transmissão

Aplicações

Aplicações

- A tabela hash pode ser utilizada para:

Aplicações

- A tabela hash pode ser utilizada para:
 - Armazenamento de senhas com segurança.

Aplicações

- A tabela hash pode ser utilizada para:
 - Armazenamento de senhas com segurança.
 - A senha não é armazenada no servidor, mas sim o resultado da função de hashing.

Aplicações

- A tabela hash pode ser utilizada para:
 - Armazenamento de senhas com segurança.
 - A senha não é armazenada no servidor, mas sim o resultado da função de hashing.
 - Implementação da tabela de símbolos dos compiladores.

Aplicações

- A tabela hash pode ser utilizada para:
 - Armazenamento de senhas com segurança.
 - A senha não é armazenada no servidor, mas sim o resultado da função de hashing.
 - Implementação da tabela de símbolos dos compiladores.
 - Criptografia:

Aplicações

- A tabela hash pode ser utilizada para:
 - Armazenamento de senhas com segurança.
 - A senha não é armazenada no servidor, mas sim o resultado da função de hashing.
 - Implementação da tabela de símbolos dos compiladores.
 - Criptografia:
 - MD5 e família SHA (*Secure Hash Algorithm*).

Tabela Hash

Tamanho da Tabela Hash

Tamanho da Tabela Hash

- O ideal é escolher um número primo e evitar valores que sejam uma potência de dois:

Tamanho da Tabela Hash

- O ideal é escolher um número primo e evitar valores que sejam uma potência de dois:
 - Número primo reduz a probabilidade de colisões, mesmo que a função de hashing utilizada não seja muito eficaz.

Tamanho da Tabela Hash

- O ideal é escolher um número primo e evitar valores que sejam uma potência de dois:
 - Número primo reduz a probabilidade de colisões, mesmo que a função de hashing utilizada não seja muito eficaz.
 - Potência de dois melhora a velocidade, mas pode aumentar os problemas de colisão se estivermos utilizando uma função de hashing mais simples.

Função de Hashing

Função de Hashing

Função de Hashing

- Inserção e busca: é necessário calcular a posição dos dados dentro da tabela.

Função de Hashing


- Inserção e busca: é necessário calcular a posição dos dados dentro da tabela.
- Função de Hashing.

Função de Hashing

- Inserção e busca: é necessário calcular a posição dos dados dentro da tabela.
- Função de Hashing.
 - Calcula a posição de uma chave escolhida a partir dos dados manipulados.

Função de Hashing

- Inserção e busca: é necessário calcular a posição dos dados dentro da tabela.
- Função de Hashing.
 - Calcula a posição de uma chave escolhida a partir dos dados manipulados.



Função de Hashing

Função de Hashing

- Função de Hashing

Função de Hashing

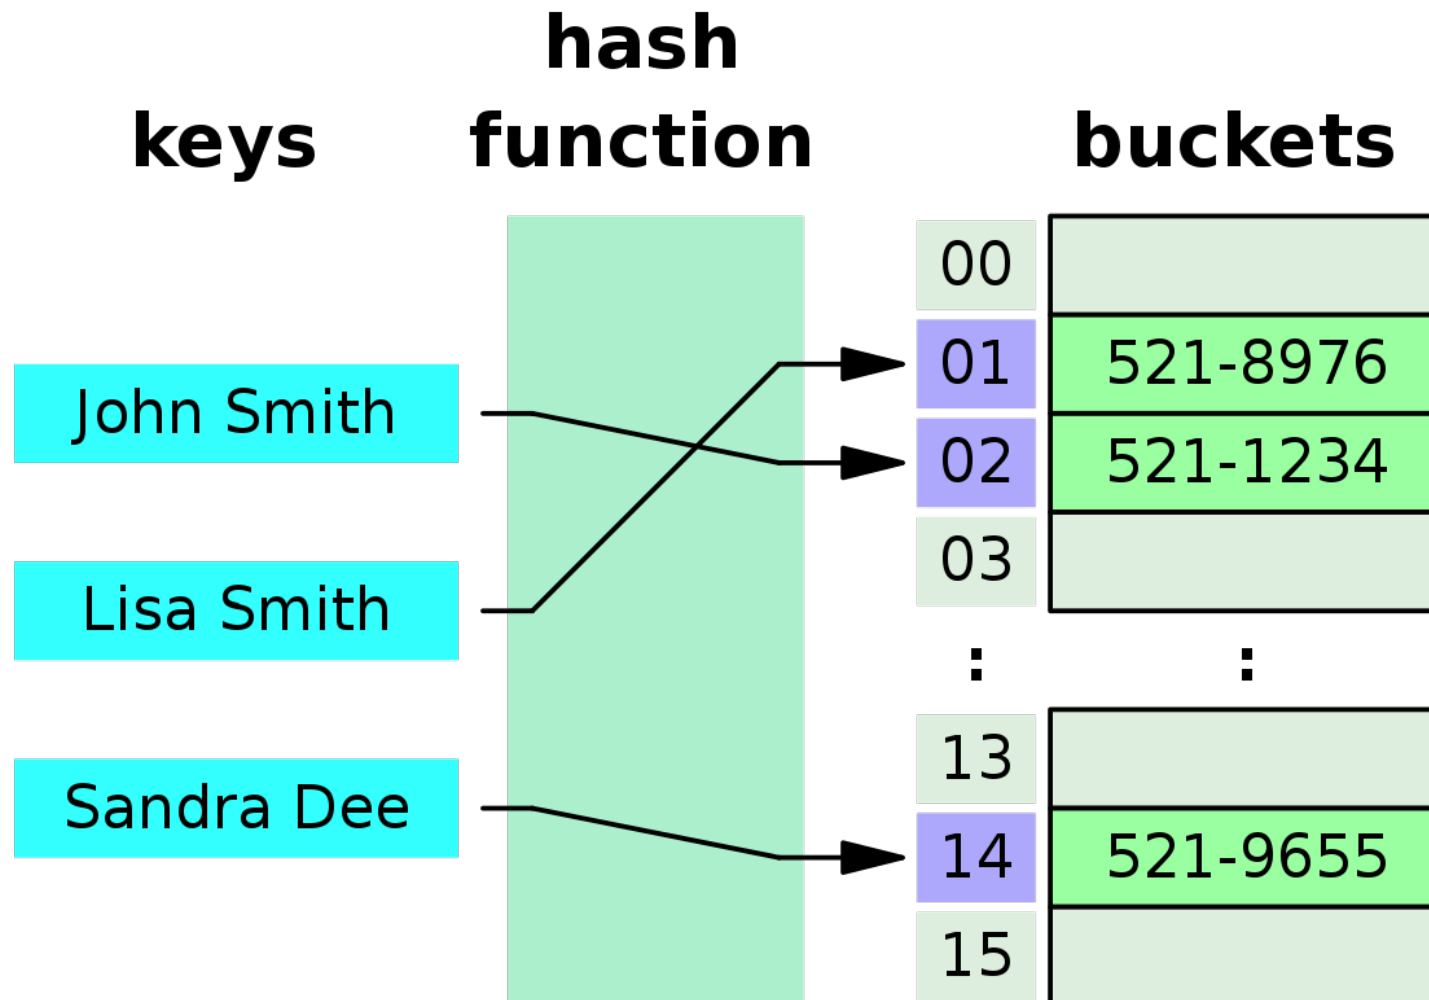
- Função de Hashing
 - É extremamente importante para o bom desempenho da tabela.

Função de Hashing

- Função de Hashing
 - É extremamente importante para o bom desempenho da tabela.
 - Ela é responsável por distribuir as informações de forma equilibrada pela tabela hash.

Função de Hashing

- Exemplo:



Função de Hashing

Função de Hashing

- Para um bom funcionamento, deve satisfazer as seguintes condições:

Função de Hashing

- Para um bom funcionamento, deve satisfazer as seguintes condições:
 - Ser simples e barata de se calcular.

Função de Hashing

- Para um bom funcionamento, deve satisfazer as seguintes condições:
 - Ser simples e barata de se calcular.
 - Garantir que valores diferentes produzam posições diferentes.

Função de Hashing

- Para um bom funcionamento, deve satisfazer as seguintes condições:
 - Ser simples e barata de se calcular.
 - Garantir que valores diferentes produzam posições diferentes.
 - Gerar uma distribuição equilibrada dos dados na tabela.

Função de Hashing

- Para um bom funcionamento, deve satisfazer as seguintes condições:
 - Ser simples e barata de se calcular.
 - Garantir que valores diferentes produzam posições diferentes.
 - Gerar uma distribuição equilibrada dos dados na tabela.
 - Cada posição da tabela tem a mesma chance de receber uma chave (máximo espalhamento).

Função de Hashing

Função de Hashing

- Sua implementação depende do conhecimento prévio da natureza e domínio da chave a ser utilizada.

Função de Hashing

- Sua implementação depende do conhecimento prévio da natureza e domínio da chave a ser utilizada.
- Exemplo: utilizar apenas os quatro dígitos do número de celular de uma pessoa para armazená-lo na tabela.

Função de Hashing

- Sua implementação depende do conhecimento prévio da natureza e domínio da chave a ser utilizada.
- Exemplo: utilizar apenas os quatro dígitos do número de celular de uma pessoa para armazená-lo na tabela.
 - Neste caso, seria melhor usar os quatro últimos dígitos do que os quatro primeiros, pois os primeiros costumam se repetir com maior frequência e iriam gerar posições iguais na tabela.

Função de Hashing

- Sua implementação depende do conhecimento prévio da natureza e domínio da chave a ser utilizada.
- Exemplo: utilizar apenas os quatro dígitos do número de celular de uma pessoa para armazená-lo na tabela.
 - Neste caso, seria melhor usar os quatro últimos dígitos do que os quatro primeiros, pois os primeiros costumam se repetir com maior frequência e iriam gerar posições iguais na tabela.
 - Assim, o ideal é usar um cálculo diferente de hash para cada tipo de chave.

Função de Hashing

Função de Hashing

- Alguns exemplos de função de hashing comumente utilizadas:

Função de Hashing

- Alguns exemplos de função de hashing comumente utilizadas:
 - Método da Divisão.

Função de Hashing

- Alguns exemplos de função de hashing comumente utilizadas:
 - Método da Divisão.
 - Método da Multiplicação.

Método da Divisão

Método da Divisão

- Uma função de hash precisa garantir que o valor retornado seja um índice válido para uma das células da tabela.

Método da Divisão

- Uma função de hash precisa garantir que o valor retornado seja um índice válido para uma das células da tabela.
- A maneira mais simples é usar o módulo da divisão como $h(k) = k \% S$, sendo K um número e S o tamanho da tabela.

Método da Divisão

- Uma função de hash precisa garantir que o valor retornado seja um índice válido para uma das células da tabela.
- A maneira mais simples é usar o módulo da divisão como $h(k) = k \% S$, sendo K um número e S o tamanho da tabela.
- O método da divisão é bastante adequado quando se conhece pouco sobre as chaves.

Método da Divisão

Método da Divisão

- Apesar de simples, apresenta alguns problemas.

Método da Divisão

- Apesar de simples, apresenta alguns problemas.
- Resto da divisão: valores diferentes podem resultar na mesma posição.

Método da Divisão

- Apesar de simples, apresenta alguns problemas.
- Resto da divisão: valores diferentes podem resultar na mesma posição.
- Exemplo:

Método da Divisão

- Apesar de simples, apresenta alguns problemas.
- Resto da divisão: valores diferentes podem resultar na mesma posição.
- Exemplo:
 - O resto da divisão de 11 por 10 e de 21 por 10 são o mesmo valor de posição: 1.

Método da Divisão

- Apesar de simples, apresenta alguns problemas.
- Resto da divisão: valores diferentes podem resultar na mesma posição.
- Exemplo:
 - O resto da divisão de 11 por 10 e de 21 por 10 são o mesmo valor de posição: 1.
 - Uma maneira de reduzir esse tipo de problema é utilizar como tamanho da tabela, `TABLE_SIZE`, um número primo.

Método da Multiplicação

Método da Multiplicação

- Também chamado de método da congruência linear multiplicativo.

Método da Multiplicação

- Também chamado de método da congruência linear multiplicativo.
- Usa uma constante fracionária A , $0 < A < 1$, para multiplicar o valor da chave que representa o elemento.

Método da Multiplicação

- Também chamado de método da congruência linear multiplicativo.
- Usa uma constante fracionária A , $0 < A < 1$, para multiplicar o valor da chave que representa o elemento.
- Em seguida, a parte fracionária resultante é multiplicada pelo tamanho da tabela para calcular a posição do elemento.

Método da Multiplicação

Método da Multiplicação

- Procedimento do método da multiplicação:

Método da Multiplicação

- Procedimento do método da multiplicação:
 1. Escolha uma constante de valor A tal que $0 < A < 1$.

Método da Multiplicação

- Procedimento do método da multiplicação:
 1. Escolha uma constante de valor A tal que $0 < A < 1$.
 2. Multiplique o valor da chave por A .

Método da Multiplicação

- Procedimento do método da multiplicação:
 1. Escolha uma constante de valor A tal que $0 < A < 1$.
 2. Multiplique o valor da chave por A .
 3. Extraia a parte fracionária de kA .

Método da Multiplicação

- Procedimento do método da multiplicação:
 1. Escolha uma constante de valor A tal que $0 < A < 1$.
 2. Multiplique o valor da chave por A .
 3. Extraia a parte fracionária de kA .
 4. Multiplique o resultado do passo anterior pelo tamanho M da tabela hash.

Método da Multiplicação

- Procedimento do método da multiplicação:
 1. Escolha uma constante de valor A tal que $0 < A < 1$.
 2. Multiplique o valor da chave por A .
 3. Extraia a parte fracionária de kA .
 4. Multiplique o resultado do passo anterior pelo tamanho M da tabela hash.
 5. O resultado do valor do hash é obtido por pegar o piso do resultado obtido no passo anterior (Passo 4).

Método da Multiplicação

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \bmod 1))$

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \bmod 1))$
 - M é o tamanho da tabela hash.

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \text{ mod } 1))$
 - M é o tamanho da tabela hash.
 - K é o valor da chave.

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \text{ mod } 1))$
 - M é o tamanho da tabela hash.
 - K é o valor da chave.
 - A é um valor constante.

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \bmod 1))$
 - M é o tamanho da tabela hash.
 - K é o valor da chave.
 - A é um valor constante.
 - Knuth sugere o valor da constante áurea:

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \text{ mod } 1))$
 - M é o tamanho da tabela hash.
 - K é o valor da chave.
 - A é um valor constante.
 - Knuth sugere o valor da constante áurea: $A = (\sqrt{5} - 1)/2$

Método da Multiplicação

- $h(K) = \text{floor}(M (kA \text{ mod } 1))$
 - M é o tamanho da tabela hash.
 - K é o valor da chave.
 - A é um valor constante.
 - Knuth sugere o valor da constante áurea: $A = (\sqrt{5} - 1)/2$

k = 12345

A = 0.357840

M = 100

*h(12345) = floor[100 (12345*0.357840 mod 1)]*

= floor[100 (4417.5348 mod 1)]

= floor[100 (0.5348)]

= floor[53.48]

= 53

Hashing Perfeito

Hashing Perfeito

- Se conhecermos todas as chaves antes de criar a função de hashing, é possível encontrar uma função de hashing injetora:

Hashing Perfeito

- Se conhecermos todas as chaves antes de criar a função de hashing, é possível encontrar uma função de hashing injetora:
 - isto é, não temos colisões.

Hashing Perfeito


- Se conhecermos todas as chaves antes de criar a função de hashing, é possível encontrar uma função de hashing injetora:
 - isto é, não temos colisões.
 - tais funções podem ser difíceis de encontrar.

Hashing Perfeito

- Se conhecermos todas as chaves antes de criar a função de hashing, é possível encontrar uma função de hashing injetora:
 - isto é, não temos colisões.
 - tais funções podem ser difíceis de encontrar.
- Exemplo:

Hashing Perfeito

- Se conhecermos todas as chaves antes de criar a função de hashing, é possível encontrar uma função de hashing injetora:
 - isto é, não temos colisões.
 - tais funções podem ser difíceis de encontrar.
- Exemplo:



Hashing Universal

Hashing Universal

- Função de hashing está sujeita ao problema de gerar posições iguais para chaves diferentes.

Hashing Universal

- Função de hashing está sujeita ao problema de gerar posições iguais para chaves diferentes.
 - Por se tratar de uma função determinística, ela pode ser manipulada de forma indesejada.

Hashing Universal

- Função de hashing está sujeita ao problema de gerar posições iguais para chaves diferentes.
 - Por se tratar de uma função determinística, ela pode ser manipulada de forma indesejada.
 - Conhecendo a função de hashing, pode-se escolher as chaves de entrada de modo que todas colidam, diminuindo o desempenho da tabela na busca para $O(N)$.

Hashing Universal

Hashing Universal

- Hashing universal é uma estratégia que busca minimizar esse problema de colisões:

Hashing Universal

- Hashing universal é uma estratégia que busca minimizar esse problema de colisões:
 - Basicamente, devemos escolher aleatoriamente (em tempo de execução) a função de hashing que será utilizada.

Hashing Universal

- Hashing universal é uma estratégia que busca minimizar esse problema de colisões:
 - Basicamente, devemos escolher aleatoriamente (em tempo de execução) a função de hashing que será utilizada.
 - Para tanto, construímos um conjunto (ou família) de funções de hashing.

Chaves Não Numéricas

Chaves Não Numéricas

- Pressupomos que as chaves são números inteiros

Chaves Não Numéricas

- Pressupomos que as chaves são números inteiros
 - E se não for?

Chaves Não Numéricas


- Pressupomos que as chaves são números inteiros
 - E se não for?
- Reinterpretamos a chave como uma sequência de bits

Chaves Não Numéricas

- Pressupomos que as chaves são números inteiros
 - E se não for?
- Reinterpretamos a chave como uma sequência de bits
- Exemplo:

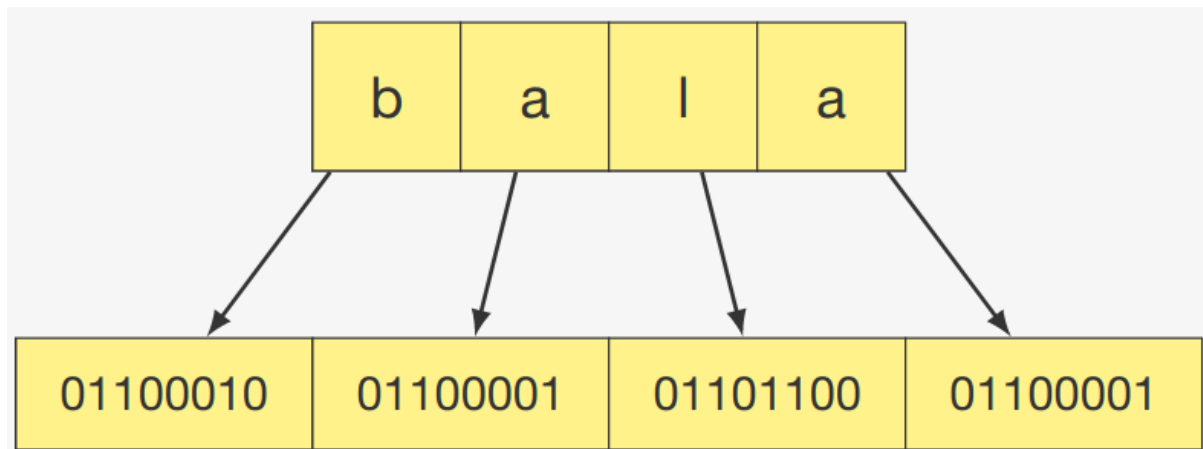
Chaves Não Numéricas

- Pressupomos que as chaves são números inteiros
 - E se não for?
- Reinterpretamos a chave como uma sequência de bits
- Exemplo:



Chaves Não Numéricas

- Pressupomos que as chaves são números inteiros
 - E se não for?
- Reinterpretamos a chave como uma sequência de bits
- Exemplo:



- Assim, “bala” se torna o número 1.650.551.905

Tratamento de Colisões

Fator de Carga

Fator de Carga

- O fator de carga de uma tabela hash é $F = n/m$, onde n é o número de elementos armazenados na tabela de tamanho m .

Fator de Carga

- O fator de carga de uma tabela hash é $F = n/m$, onde n é o número de elementos armazenados na tabela de tamanho m .
 - O número de colisões cresce rapidamente quando o fator de carga aumenta.

Fator de Carga

- O fator de carga de uma tabela hash é $F = n/m$, onde n é o número de elementos armazenados na tabela de tamanho m .
 - O número de colisões cresce rapidamente quando o fator de carga aumenta.
 - Uma forma de diminuir as colisões é diminuir o fator de carga.

Fator de Carga

- O fator de carga de uma tabela hash é $F = n/m$, onde n é o número de elementos armazenados na tabela de tamanho m .
 - 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.

Fator de Carga

- O fator de carga de uma tabela hash é $F = n/m$, onde n é o número de elementos armazenados na tabela de tamanho m .
 - 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?

Colisões

Colisões

- Tratamento de colisões:

Colisões

- Tratamento de colisões:
 - Por Encadeamento

Colisões

- Tratamento de colisões:
 - Por Encadeamento
 - Por Endereçamento Aberto

Encadeamento

Encadeamento

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

Encadeamento

- Manter m listas encadeadas, uma para cada possível endereço base.
- A tabela base não possui nenhum elemento, apenas os ponteiros para as listas encadeadas.

Encadeamento

- Manter m listas encadeadas, uma para cada possível endereço base.
- A tabela base não possui nenhum elemento, apenas os ponteiros para as listas encadeadas.
- A tabela base não armazena nenhum registro.

Encadeamento

Encadeamento

- Cada nó da lista encadeada contém:

Encadeamento

- Cada nó da lista encadeada contém:
 - um elemento;

Encadeamento


- Cada nó da lista encadeada contém:
 - um elemento;
 - um ponteiro para o próximo nó (elemento);

Encadeamento

- Cada nó da lista encadeada contém:
 - um elemento;
 - um ponteiro para o próximo nó (elemento);
- Exemplo:

Encadeamento

- Cada nó da lista encadeada contém:
 - um elemento;
 - um ponteiro para o próximo nó (elemento);
- Exemplo:



Encadeamento

Encadeamento

- Procedimento de busca:

Encadeamento

- Procedimento de busca:
 - Calcular o endereço aplicando a função de hash $h(x)$;

Encadeamento

- Procedimento de busca:
 - Calcular o endereço aplicando a função de hash $h(x)$;
 - Percorrer a lista encadeada associada ao endereço;

Encadeamento

- Procedimento de busca:
 - Calcular o endereço aplicando a função de hash $h(x)$;
 - Percorrer a lista encadeada associada ao endereço;
 - Comparar a chave de cada nó da lista encadeada com a chave x , até encontrar o nó (item) desejado;

Encadeamento

- Procedimento de busca:
 - Calcular o endereço aplicando a função de hash $h(x)$;
 - Percorrer a lista encadeada associada ao endereço;
 - Comparar a chave de cada nó da lista encadeada com a chave x , até encontrar o nó (item) desejado;
 - Se o final da lista for atingido, o elemento não está na tabela;

Encadeamento

Encadeamento

- Procedimento de inserção:

Encadeamento

- Procedimento de inserção:
 - Calcular o endereço aplicando a função de hash $h(x)$;

Encadeamento

- Procedimento de inserção:
 - Calcular o endereço aplicando a função de hash $h(x)$;
 - Buscar o elemento na lista associada ao endereço $h(x)$;

Encadeamento

- Procedimento de inserção:
 - Calcular o endereço aplicando a função de hash $h(x)$;
 - Buscar o elemento na lista associada ao endereço $h(x)$;
 - Se registro for encontrado, sinalizar erro;

Encadeamento

- Procedimento de inserção:
 - Calcular o endereço aplicando a função de hash $h(x)$;
 - Buscar o elemento na lista associada ao endereço $h(x)$;
 - Se registro for encontrado, sinalizar erro;
 - Se o registro não for encontrado, inserir no final da lista;

Análise de Complexidade

Análise de Complexidade

- Encadeamento (pior caso):

Análise de Complexidade

- Encadeamento (pior caso):
 - É necessário percorrer uma lista encadeada até o final para concluir que a chave não está na tabela.

Análise de Complexidade

- Encadeamento (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 $O(n)$.

Análise de Complexidade

- Encadeamento (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: $O(n)$.

Análise de Complexidade

Análise de Complexidade

- Encadeamento (caso médio):

Análise de Complexidade

- Encadeamento (caso médio):
 - Assume-se que a função hash é uniforme.

Análise de Complexidade

- Encadeamento (caso médio):
 - Assume-se que a função hash é uniforme.
 - Número médio de comparações feitas na busca sem sucesso é igual ao fator de carga da tabela $F = n/m$.

Análise de Complexidade

- Encadeamento (caso médio):
 - Assume-se que a função hash é uniforme.
 - Número médio de comparações feitas na busca sem sucesso é igual ao fator de carga da tabela $F = n/m$.
 - Número médio de comparações feitas na busca com sucesso também é igual a $F = n/m$.

Análise de Complexidade

- Encadeamento (caso médio):
 - Assume-se que a função hash é uniforme.
 - Número médio de comparações feitas na busca sem sucesso é igual ao fator de carga da tabela $F = n/m$.
 - Número médio de comparações feitas na busca com sucesso também é igual a $F = n/m$.
 - Se assumirmos que o número de chaves n é proporcional ao tamanho da tabela m , então:

Análise de Complexidade

- Encadeamento (caso médio):
 - Assume-se que a função hash é uniforme.
 - Número médio de comparações feitas na busca sem sucesso é igual ao fator de carga da tabela $F = n/m$.
 - Número médio de comparações feitas na busca com sucesso também é igual a $F = n/m$.
 - Se assumirmos que o número de chaves n é proporcional ao tamanho da tabela m , então:
 - $F = n/m = O(1)$

Análise de Complexidade

- Encadeamento (caso médio):
 - Assume-se que a função hash é uniforme.
 - Número médio de comparações feitas na busca sem sucesso é igual ao fator de carga da tabela $F = n/m$.
 - Número médio de comparações feitas na busca com sucesso também é igual a $F = n/m$.
 - Se assumirmos que o número de chaves n é proporcional ao tamanho da tabela m , então:
 - $F = n/m = O(1)$
 - Complexidade constante!

Encadeamento

Encadeamento

- Procedimento de remoção:

Encadeamento

- Procedimento de remoção:
 - Calcular o endereço aplicando a função $h(x)$;

Encadeamento

- Procedimento de remoção:
 - Calcular o endereço aplicando a função $h(x)$;
 - Buscar o elemento na lista associada ao endereço $h(x)$;

Encadeamento

- Procedimento de remoção:
 - Calcular o endereço aplicando a função $h(x)$;
 - Buscar o elemento na lista associada ao endereço $h(x)$;
 - Se o elemento for encontrado, excluir o elemento;

Encadeamento

- Procedimento de remoção:
 - Calcular o endereço aplicando a função $h(x)$;
 - Buscar o elemento na lista associada ao endereço $h(x)$;
 - Se o elemento for encontrado, excluir o elemento;
 - Se o elemento não for encontrado, sinalizar erro;

Endereçamento Aberto

Endereçamento Aberto

- Motivação: a abordagem anterior utiliza ponteiros nas listas encadeadas.

Endereçamento Aberto

- Motivação: a abordagem anterior utiliza ponteiros nas listas encadeadas.
 - Aumento no consumo de espaço

Endereçamento Aberto

- Motivação: a abordagem anterior utiliza ponteiros nas listas encadeadas.
 - Aumento no consumo de espaço
- Alternativa: armazenar apenas os elementos, sem os ponteiros.

Endereçamento Aberto

- Motivação: a abordagem anterior utiliza ponteiros nas listas encadeadas.
 - Aumento no consumo de espaço
- Alternativa: armazenar apenas os elementos, sem os ponteiros.
- Quando houver colisão, determina-se, por cálculo de novo endereço, o próximo compartimento a ser examinado.

Funcionamento

Funcionamento

- Para cada chave x , é necessário que todas as posições da tabela possam ser examinadas.

Funcionamento

- Para cada chave x , é necessário que todas as posições da tabela possam ser examinadas.
- A função $h(x)$ deve fornecer, ao invés de um único endereço, um conjunto de m endereços base.

Funcionamento

- Para cada chave x , é necessário que todas as posições da tabela possam ser examinadas.
- 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 $k = 0, \dots, m-1$.

Funcionamento

- Para cada chave x , é necessário que todas as posições da tabela possam ser examinadas.
- 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 $k = 0, \dots, m-1$.
- Para se encontrar a chave x deve-se tentar o endereço base $h(x,0)$.

Funcionamento

- Para cada chave x , é necessário que todas as posições da tabela possam ser examinadas.
- 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 $k = 0, \dots, m-1$.
- Para se 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.

Tratamento de Colisões

Tratamento de Colisões

- A sequência $h(x,0), h(x,1), \dots, h(x, m-1)$ é denominada sequência de tentativas.

Tratamento de Colisões

- A sequência $h(x,0), h(x,1), \dots, h(x, m-1)$ é denominada sequência de tentativas.
- A sequência de tentativas é uma permutação do conjunto $\{0, m-1\}$.

Tratamento de Colisões

- A sequência $h(x,0), h(x,1), \dots, h(x, m-1)$ é denominada sequência de tentativas.
- A sequência 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.

Função de Hash

Função de Hash

- Exemplos de funções hash para gerar sequência de tentativas:

Função de Hash

- Exemplos de funções hash para gerar sequência de tentativas:
 - Sondagem Linear

Função de Hash

- Exemplos de funções hash para gerar sequência de tentativas:
 - Sondagem Linear
 - Sondagem Quadrática

Função de Hash

- Exemplos de funções hash para gerar sequência de tentativas:
 - Sondagem Linear
 - Sondagem Quadrática
 - Dispersão Dupla

Sondagem Linear

Sondagem Linear

- Suponha que o endereço base de uma chave x é $h'(x)$.

Sondagem Linear

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

Sondagem Linear

- Suponha que o endereço base de uma chave x é $h'(x)$.
- Suponha que já existe uma chave y ocupando o endereço $h'(x)$.
- Ideia: tentar armazenar x no endereço consecutivo a $h'(x)$. Se já estiver ocupado, tenta-se o próximo e assim sucessivamente.

Sondagem Linear

- Suponha que o endereço base de uma chave x é $h'(x)$.
- Suponha que já existe uma chave y ocupando o endereço $h'(x)$.
- Ideia: 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:

Sondagem Linear

- Suponha que o endereço base de uma chave x é $h'(x)$.
- Suponha que já existe uma chave y ocupando o endereço $h'(x)$.
- Ideia: 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:
 - $h(x, k) = (h'(x) + k) \bmod m, 0 \leq k \leq m-1$

Sondagem Linear


Sondagem Linear

- Exemplo:

Sondagem Linear

- Exemplo:

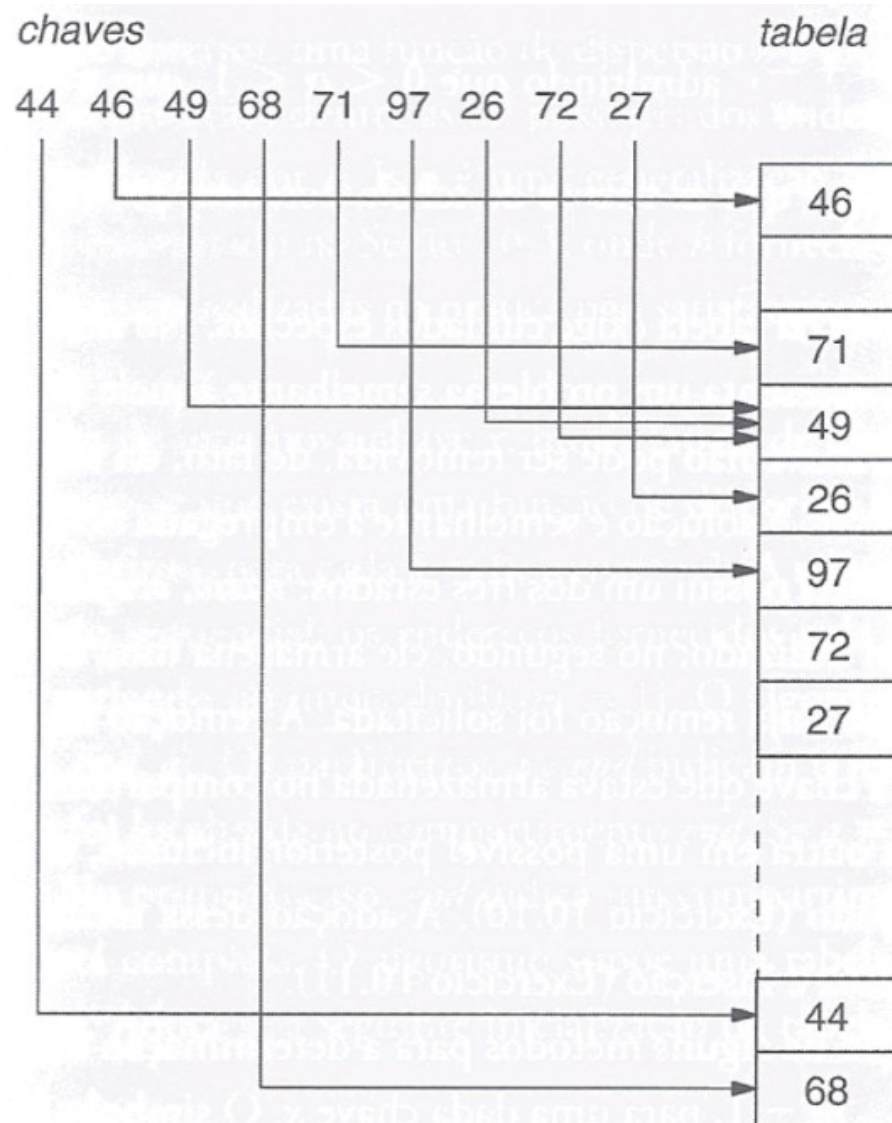
Deve-se observar a ocorrência de



Sondagem Linear

- Exemplo:


Deve-se observar a ocorrência de colisões a partir da inserção do



Sondagem Linear

- Exemplo:

Deve-se observar a ocorrência de colisões a partir da inserção do elemento 26.



Sondagem Linear

Sondagem Linear

- Na presença de remoções, a inserção precisa que a busca percorra toda a tabela até ter certeza de que o elemento procurado não existe.

Sondagem Linear

- Na presença de remoções, a inserção precisa que a busca percorra toda a tabela até ter certeza de que o elemento procurado não existe.
- Em situações onde não há remoção, a busca pode parar assim que encontrar uma posição livre (se a chave existisse, ela estaria ali).

Sondagem Linear

Sondagem Linear

- Ponto Fraco

Sondagem Linear

- Ponto Fraco
 - Suponha um trecho de j posições consecutivas ocupadas (chama-se agrupamento primário) e uma posição l vazia imediatamente seguinte a essas posições.

Sondagem Linear

- Ponto Fraco
 - Suponha um trecho de j posições consecutivas ocupadas (chama-se agrupamento primário) e uma posição l vazia imediatamente seguinte a essas posições.
 - Suponha que uma chave x precisa ser inserida em uma das j posições:

Sondagem Linear

- Ponto Fraco
 - Suponha um trecho de j posições consecutivas ocupadas (chama-se agrupamento primário) e uma posição l vazia imediatamente seguinte a essas posições.
 - Suponha que uma chave x precisa ser inserida em uma das j posições:
 - x será armazenada em l

Sondagem Linear

- Ponto Fraco
 - Suponha um trecho de j posições consecutivas ocupadas (chama-se agrupamento primário) e uma posição l vazia imediatamente seguinte a essas posições.
 - Suponha que uma chave x precisa ser inserida em uma das j posições:
 - x será armazenada em l
 - isso aumenta o tamanho do agrupamento primário para $j + 1$

Sondagem Linear

- Ponto Fraco
 - Suponha um trecho de j posições consecutivas ocupadas (chama-se agrupamento primário) e uma posição l vazia imediatamente seguinte a essas posições.
 - Suponha que uma chave x precisa ser inserida em uma das j posições:
 - x será armazenada em l
 - isso aumenta o tamanho do agrupamento primário para $j + 1$
 - Quanto maior for o tamanho de um agrupamento primário, maior a probabilidade de aumentá-lo ainda mais mediante a inserção de uma nova chave

Sondagem Quadrática

Sondagem Quadrática

- Para mitigar a formação de agrupamentos primários, que aumentam muito o tempo de busca:

Sondagem 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.

Sondagem 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

Sondagem 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
 - $h(x,k) = (h'(x) + c1.k + c2.k^2) \bmod m$, onde $c1$ e $c2$ são constantes, $c2 \neq 0$ e $k = 0, \dots, m-1$

Sondagem Quadrática

Sondagem Quadrática

- Método evita agrupamentos primários

Sondagem Quadrática

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

Sondagem Quadrática

Sondagem Quadrática

- Valores de m , $c1$ e $c2$ precisam ser escolhidos de forma a garantir que todos os endereços-base serão percorridos:

Sondagem Quadrática

- Valores de m , $c1$ e $c2$ precisam ser escolhidos de forma a garantir que todos os endereços-base serão percorridos:
- Exemplo:

Sondagem Quadrática

- Valores de m , $c1$ e $c2$ precisam ser escolhidos de forma a garantir que todos os endereços-base serão percorridos:
- Exemplo:
 - $h(x,0) = h'(x)$

Sondagem Quadrática

- Valores de m , c_1 e c_2 precisam ser escolhidos de forma a garantir que todos os endereços-base serão percorridos:
- Exemplo:
 - $h(x,0) = h'(x)$
 - $h(x,k) = (h(x,k-1) + k) \bmod m$, para $0 < k < m$

Sondagem Quadrática

- Valores de m , $c1$ e $c2$ precisam ser escolhidos de forma a garantir que todos os endereços-base serão percorridos:
- Exemplo:
 - $h(x,0) = h'(x)$
 - $h(x,k) = (h(x,k-1) + k) \bmod m$, para $0 < k < m$
 - Essa função varre toda a tabela se m for potência de 2

Linear x Quadrática

Linear x Quadrática

tentativa linear:

endereço-base 0



endereço-base 1




tentativa quadrática:

endereço-base 0



endereço-base 1



Dispersão Dupla

Dispersão Dupla

- Utiliza duas funções de hash, $h'(x)$ e $h''(x)$

Dispersão Dupla

- Utiliza duas funções de hash, $h'(x)$ e $h''(x)$
- $h(x,k) = (h'(x) + k \cdot h''(x)) \bmod m$, para $0 \leq k < m$

Dispersão Dupla

- Utiliza duas funções de hash, $h'(x)$ e $h''(x)$
- $h(x,k) = (h'(x) + k \cdot h''(x)) \bmod m$, para $0 \leq k < m$
- Método distribui melhor as chaves do que os dois métodos anteriores

Dispersão Dupla

- Utiliza duas funções de hash, $h'(x)$ e $h''(x)$
- $h(x,k) = (h'(x) + k \cdot h''(x)) \bmod m$, para $0 \leq k < m$
- 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

Dispersão Dupla

- Utiliza duas funções de hash, $h'(x)$ e $h''(x)$
- $h(x,k) = (h'(x) + k \cdot h''(x)) \bmod m$, para $0 \leq k < m$
- 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 $h''(x) = h''(y)$

Exercícios

Exercícios

- Qual é a diferença entre *hash* perfeito e *hash* universal? Dê um exemplo de cada.
- Qual é a ordem de complexidade de encontrar o maior elemento (maior chave) em uma estrutura de dados do tipo *hash*? Justifique a sua resposta.
- Dado o conjunto de elementos $S = \{42, 39, 57, 3, 18, 5, 67, 13, 70, 26\}$ e uma tabela hash T de tamanho 13 e com uma função de hash $H = X \bmod 13$. Mostre a inserção dos elementos de S em T usando o tratamento de colisões por encadeamento e por endereçamento aberto.