Tabelas de Dispersão (hash tabels)

Motivação

- Busca (acesso) com vetor é muito eficiente…

```
Info* v[N];
...
v[i]->...
```

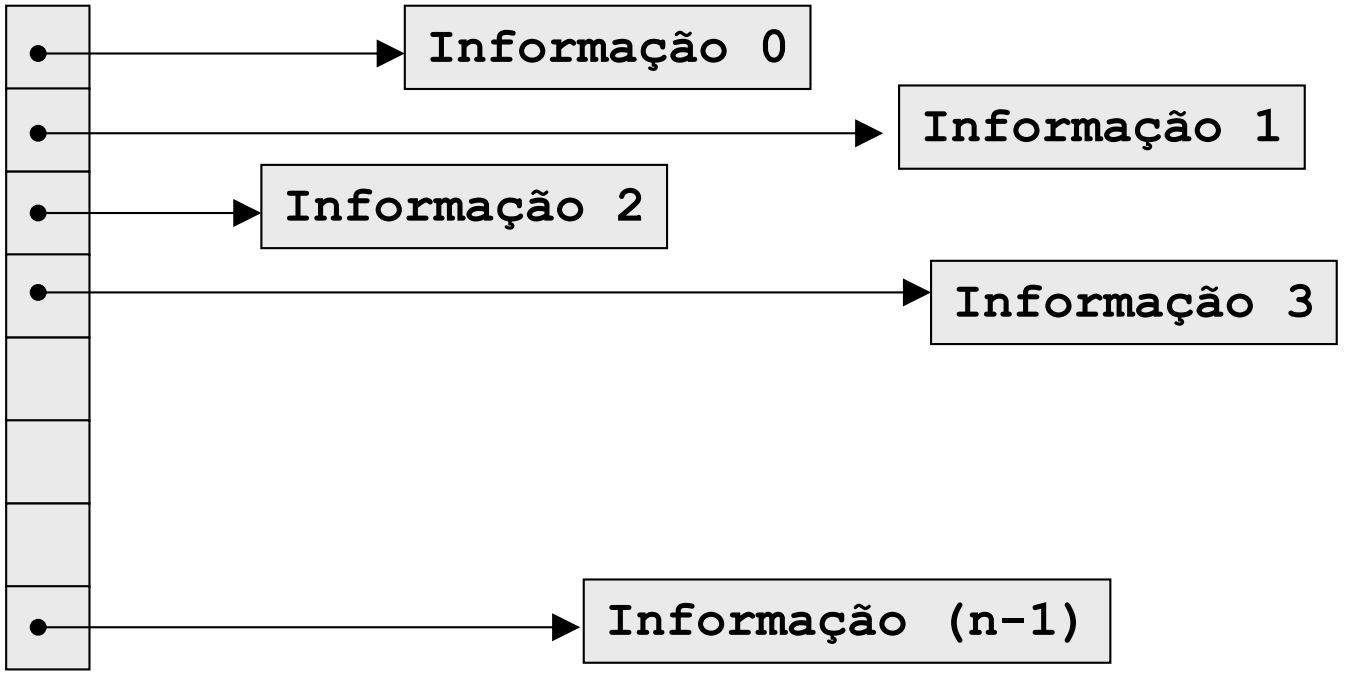

Nem sempre temos chaves numéricas pequenas…

```
struct Aluno {
   int mat;
   char nome[81];
   char email[41];
   char turma;
};
```

Como fazer para buscar pelo nome ou pela matrícula?

Idéia dos escaninhos

A primeira letra do nome define a caixa onde a informação é depositada…

$$Hash : Info \rightarrow [0, N]$$

$$x \rightarrow h(x)$$

Tabelas de Dispersão (Hash Tables)

- utilizadas para buscar um elemento em ordem constante O(1)
- necessitam de mais memória, proporcional ao número de elementos armazenado
- ex.: {14,16,58,39,44,10,72,22}, chave k $\in$ [0,99]
- 8 elementos $\Rightarrow$ N=13

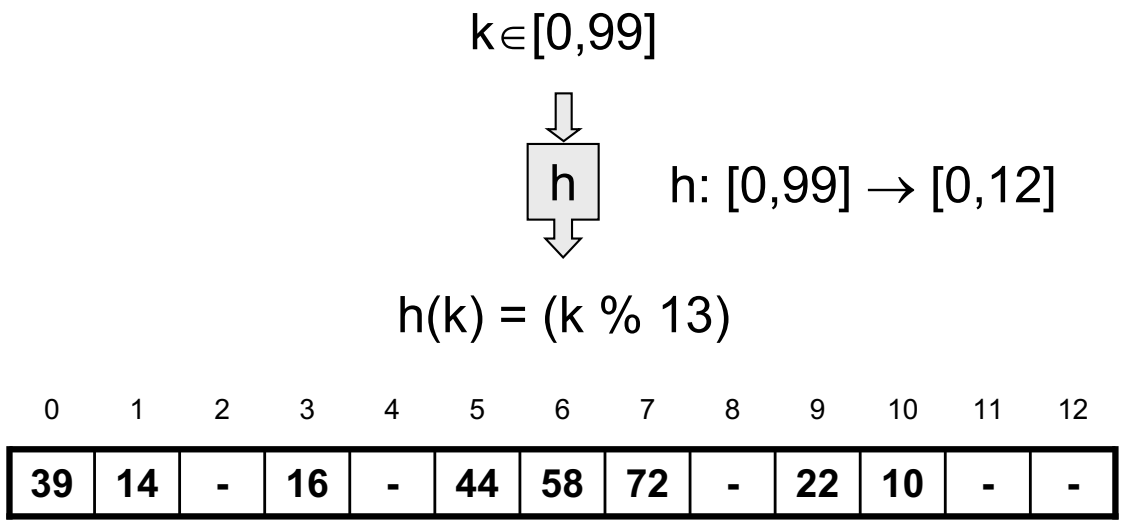

Tabelas de Dispersão (Hash Tables)

- utilizadas para buscar um elemento em ordem constante O(1)
- necessitam de mais memória, proporcional ao número de elementos armazenado
- ex.: {14,16,58,39,44,10,72,22}, chave k $\in$ [0,99]
- 8 elementos $\Rightarrow$ N=20

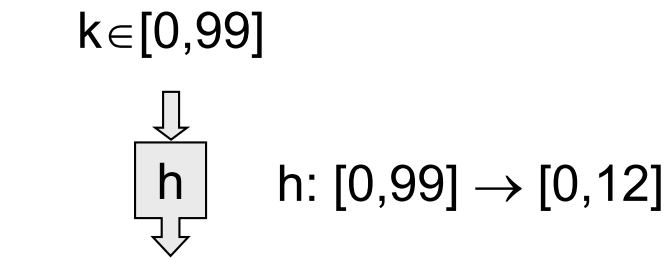

0	
1	
2	**22**
3	
4	
5	
6	
7	
8	
9	
10	
11	
12	
13	
14	**14,44**
15	
16	**16**
17	
18	**58**
19	**39**

Função de dispersão (função de *hash*)

- mapeia uma chave de busca em um índice da tabela
- deve apresentar as seguintes propriedades:
  - ser eficientemente avaliada (para acesso rápido)
  - espalhar bem as chaves de busca (para minimizarmos colisões)
- colisão = duas ou mais chaves de busca são mapeadas para um mesmo índice da tabela de *hash*

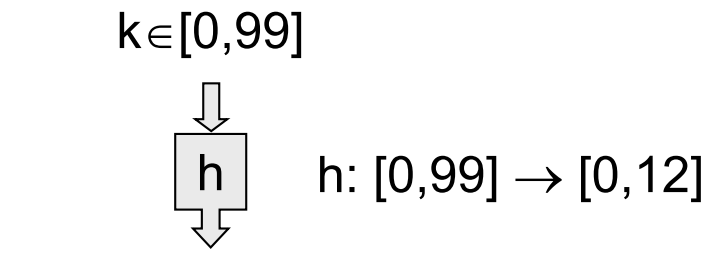

Dimensão da tabela

- deve ser escolhida para diminuir o número de colisões
- costuma ser um valor primo
- a *taxa de ocupação* não deve ser muito alta:
  - a taxa de ocupação não deve ser superior a 75%
  - uma taxa de 50% em geral traz bons resultados
  - uma taxa menor que 25% pode representar um gasto excessivo de memória

Fator de carga = (#entradas/tamanho)

Exemplo de Tabelas de Dispersão

- tipo Aluno: define o tipo da estrutura de dados de interesse
- tipo Hash: define o tipo dos vetores de ponteiros para Aluno

```
struct Aluno {
   int mat;
   char nome[81];
   char email[41];
   char turma;
};

#define N 127
typedef Aluno* Hash[N];
```

```
int hash (int mat)
{
   return (mat%N);
}
```

Estratégias para tratamento de colisão

- uso da primeira posição consecutiva livre(encadeamento interior):
  - simples de implementar
  - tende a concentrar os lugares ocupados na tabela
- uso de uma segunda função de dispersão (encadeamento aberto):
  - evita a concentração de posições ocupadas na tabela
  - usa uma segunda função de dispersão para re-posicionar o elemento
- uso de listas encadeadas(encadeamento exterior):
  - simples de implementar
  - cada elemento da tabela hash representa um ponteiro para uma lista encadeada

Tratamento de Colisão

- Uso da posição consecutiva livre:
  - estratégia geral:
    - armazene os elementos que colidem em outros índices, ainda não ocupados, da própria tabela
  - estratégias particulares:
    - diferem na escolha da posição ainda não ocupada para armazenar um elemento que colide

Uso da posição consecutiva livre

- Estratégia 1:
  - se a função de dispersão mapeia a chave de busca para um índice já ocupado, procure o próximo índice livre da tabela (usando incremento circular) para armazenar o novo elemento

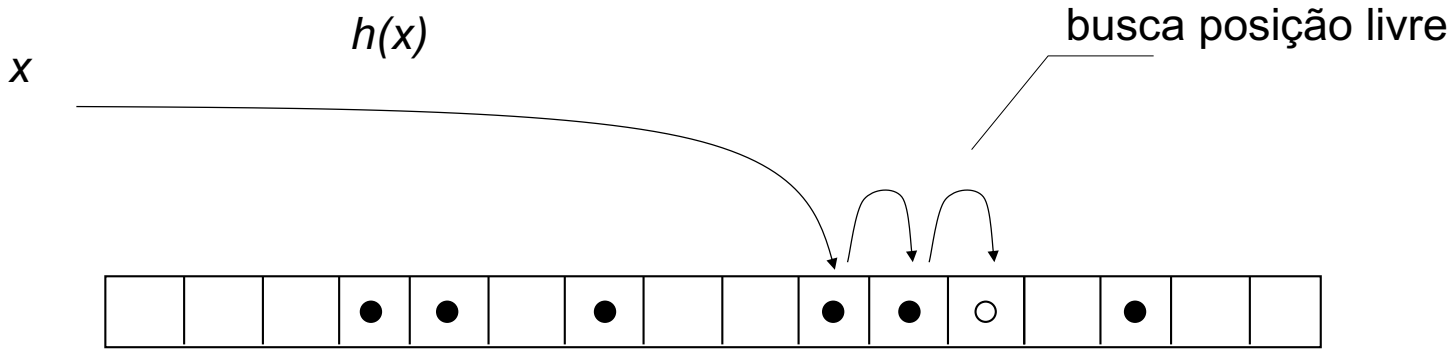

Operação de busca

- suponha que uma chave x for mapeada pela função de hash h para um determinado índice h(x)
- procure a ocorrência do elemento a partir de h(x),
  até que o elemento seja encontrado ou
  que uma posição vazia seja encontrada

Operação de busca

- entrada: a tabela e a chave de busca
- saída: o ponteiro do elemento, se encontrado
  NULL, se o elemento não for encontrado

```
Aluno* hsh_busca (Hash tab, int mat)
{
   int h = hash(mat);
   while (tab[h] != NULL) {
      if (tab[h]->mat == mat)
         return tab[h];
      h = (h+1) % N;
   }
   return NULL;
}
```

Operação de inserção e modificação

- suponha que uma chave x for mapeada pela função de hash h para um determinado índice h(x)
- procure a ocorrência do elemento a partir de h(x), até que o elemento seja encontrado ou que uma posição vazia seja encontrada
- se o elemento existir, modifique o seu conteúdo
- se não existir, insira um novo na primeira posição livre que encontrar na tabela, a partir do índice mapeado

Inserção/modificação

```
Aluno* hsh_insere(Hash tab,int mat, char* n, char* e, char t)
{
   int h = hash(mat);
   while (tab[h] != NULL) {
      if (tab[h]->mat == mat)
         break;
      h = (h+1) % N;
   }
   if (tab[h]==NULL) {  /* não encontrou o elemento */
      tab[h] = (Aluno*) malloc(sizeof(Aluno));
      tab[h]->mat = mat;
   }
   /* atribui/modifica informação */
   strcpy(tab[h]->nome,n);
   strcpy(tab[h]->email,e);
   tab[h]->turma = t;
   return tab[h];
}
```

Tratamento de Colisão

- Uso de uma segunda função de dispersão:
  - exemplo:
    - primeira função de hash: $h(x) = x\%N$
    - segunda função de hash: $h'(x) = N - 2 - x\%(N-2)$

    onde *x* representa a chave de busca e *N* a dimensão da tabela

  - se houver colisão, procure uma posição livre na tabela com incrementos dados por *h'(x)*
    - em lugar de tentar **`(h(x)+1)%N`**, tente **`(h(x)+h'(x))%N`**

Uso de uma segunda função de dispersão (cont)

- cuidados na escolha da segunda função de dispersão:
  - nunca pode retornar zero
    - pois isso não faria com que o índice fosse incrementado
  - não deve retornar um número divisor da dimensão da tabela
    - pois isso limitaria a procura de uma posição livre a um sub-conjunto restrito dos índices da tabela
    - se a dimensão da tabela for um número primo, garante-se automaticamente que o resultado da função não será um divisor

Busca com segunda função de colisão

```
static int hash2 (int mat)
{
   return N - 2 - mat%(N-2);
}
Aluno* hsh_busca (Hash tab, int mat)
{
   int h = hash(mat);
   int h2 = hash2(mat);
   while (tab[h] != NULL) {
      if (tab[h]->mat == mat)
         return tab[h];
      h = (h+h2) % N;
   }
   return NULL;
}
```

Tratamento de Colisão

- Uso de listas encadeadas
  - cada elemento da tabela hash representa um ponteiro para uma lista encadeada
    - todos os elementos mapeados para um mesmo índice são armazenados na lista encadeada
    - os índices da tabela que não têm elementos associados representam listas vazias

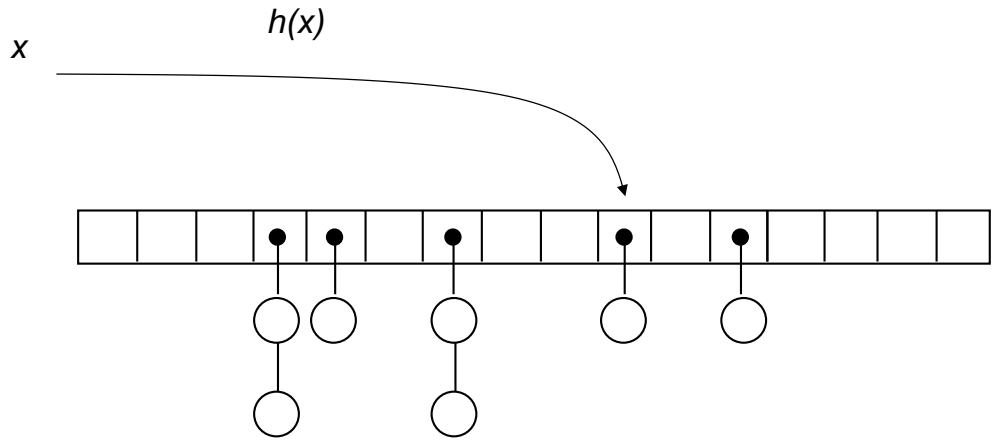

Tratamento de Colisão

- Exemplo:
  - cada elemento armazenado na tabela será um elemento de uma lista encadeada
  - a estrutura da informação deve prever um ponteiro adicional para o próximo elemento da lista

```
struct aluno {
   int mat;
   char nome[81];
   char turma;
   char email[41];
   struct aluno* prox; /* encadeamento na lista de colisão */
};
typedef struct aluno Aluno;
```

```
/*  função para inserir ou modificar um determinado elemento */
Aluno* hsh_insere (Hash tab, int mat, char* n, char* e, char t)
{
   int h = hash(mat);
   Aluno* a = tab[h];
   while (a != NULL) {
      if (a->mat == mat)
         break;
      a = a->prox;
   }
   if (a==NULL) {          /* não encontrou o elemento */
      /* insere novo elemento no início da lista */
      a = (Aluno*) malloc(sizeof(Aluno));
      a->mat = mat;
      a->prox = tab[h];
      tab[h] = a;
   }
   /* atribui ou modifica informação */
   strcpy(a->nome,n);
   strcpy(a->email,e);
   a->turma = t;
   return a;
}
```

Exemplo: número de ocorrências de palavras

- Especificação:
  - programa para exibir quantas vezes cada palavra ocorre em um dado texto
    - entrada: um texto T
    - saída: uma lista de palavras, em ordem decrescente do número de vezes que cada palavra ocorre em T
  - observações:
    - uma palavra é uma seqüência de uma ou mais letras (maiúsculas ou minúsculas)
    - por simplicidade, caracteres acentuados não são considerados

Exemplo: número de ocorrências de palavras

- Armazenamento das palavras lidas e da sua freqüência:
  - tabela de dispersão
  - usa a própria palavra como chave de busca
- Função para obter a freqüência das palavras:
  - dada uma palavra, tente encontrá-la na tabela
  - se não existir, armazene a palavra na tabela
  - se existir, incremente o número de ocorrências da palavra
- Função para exibir as ocorrências em ordem decrescente:
  - crie um vetor armazenando as palavras da tabela de dispersão
  - ordene o vetor
  - exiba o conteúdo do vetor

Exemplo: número de ocorrências de palavras

- Tabela de dispersão:
  - usa a lista encadeada para o tratamento de colisões

```
#define NPAL  64   /* dimensão máxima de cada palavra */
#define NTAB 127  /* dimensão da tabela de dispersão */

/* tipo que representa cada palavra */
struct palavra {
   char pal[NPAL];
   int  n;                  /* contador de ocorrências */
   struct palavra* prox;  /* colisão com listas */
};

typedef struct palavra Palavra;
/* tipo que representa a tabela de dispersão */

typedef Palavra* Hash[NTAB];
```

Exemplo: número de ocorrências de palavras

- Leitura de palavras:
  - captura a próxima seqüência de letras do arquivo texto
  - entrada: ponteiro para o arquivo de entrada
    cadeia de caracteres armazenando a palavra capturada
  - saída: inteiro, indicando leitura bem sucedida (1) ou não (0)
  - processamento:
    - capture uma palavra, pulando os caracteres que não são letras e armazenando a seqüência de letras a partir da posição do cursor do arquivo
    - para identificar se um caractere é letra ou não,
      use a função isalpha disponibilizada pela interface ctype.h

```
static int le_palavra (FILE* fp, char* s)
{
   int i = 0;
   int c;
   /* pula caracteres que não são letras */
   while ((c = fgetc(fp)) != EOF) {
      if (isalpha(c))
         break;
   }
   if (c == EOF)
      return 0;
   else
      s[i++] = c /* primeira letra já foi capturada */
   /* lê os próximos caracteres que são letras */
   while ( i<NPAL-1 && (c = fgetc(fp)) != EOF && isalpha(c))
      s[i++] = c;
   s[i] = '\0';
   return 1;
}
```

Exemplo: número de ocorrências de palavras

- Função para inicializar a tabela:
  - atribui NULL a cada elemento

```
static void inicializa (Hash tab)
{
   int i;
   for (i=0; i<NTAB; i++)
      tab[i] = NULL;
}
```

Exemplo: número de ocorrências de palavras

- Função de dispersão:
  - mapeia a chave de busca (uma cadeia de caracteres) em um índice da tabela
  - soma os códigos dos caracteres que compõem a cadeia e tira o módulo dessa soma para se obter o índice da tabela

```
static int hash (char* s)
{
   int i;
   int total = 0;
   for (i=0; s[i]!='\0'; i++)
      total += s[i];
   return total % NTAB;
}
```

Exemplo: número de ocorrências de palavras

- Função para acessar os elementos na tabela:
  - entrada: uma palavra (chave de busca)
  - saída: o ponteiro da estrutura Palavra associada
  - processamento:
    - se a palavra ainda não existir na tabela,
      crie uma nova palavra e
      forneça como retorno essa nova palavra criada

```
static Palavra *acessa (Hash tab, char* s)
{
   Palavra* p;
   int h = hash(s);
   for (p=tab[h]; p!=NULL; p=p->prox) {
      if (strcmp(p->pal,s) == 0)
         return p;
   }
   /* insere nova palavra no inicio da lista */
   p = (Palavra*) malloc(sizeof(Palavra));
   strcpy(p->pal,s);
   p->n = 0;
   p->prox = tab[h];
   tab[h] = p;
   return p;
}
```

Exemplo: número de ocorrências de palavras

- Trecho da função principal:
  - acessa cada palavra
  - incrementa o seu número de ocorrências

```
...
inicializa(tab);
while (le_palavra(fp,s)) {
   Palavra* p = acessa(tab,s);
   p->n++;
}
...
```

Exemplo: número de ocorrências de palavras

- Exibição do resultado ordenado:
  - crie dinamicamente um vetor para armazenar as palavras
    - vetor de ponteiros para a estrutura Palavra
    - tamanho do vetor = número de palavras armazenadas na tabela
  - coloque o vetor em ordem decrescente do número de ocorrências de cada palavra
    - se duas palavras tiverem o mesmo número de ocorrências, use a ordem alfabética como critério de desempate

```
/*
    função para percorrer a tabela e contar o
    número de palavras
    entrada: tabela de dispersão
*/
static int conta_elems (Hash tab)
{
   int i;
    Palavra* p;
   int total = 0;
   for (i=0; i<NTAB; i++) {
      for (p=tab[i]; p!=NULL; p=p->prox)
         total++;
   }
   return total;
}
```

```
/*
    função para criar dinamicamente o vetor de ponteiros
    entrada: número de elementos
             tabela de dispersão
*/
static Palavra** cria_vetor (int n, Hash tab)
{
   int i, j=0;
   Palavra* p;
   Palavra** vet = (Palavra**) malloc(n*sizeof(Palavra*));
   /* percorre tabela preenchendo vetor */
   for (i=0; i<NTAB; i++) {
      for (p=tab[i]; p!=NULL; p=p->prox)
         vet[j++] = p;
   }
   return vet;
}
```

Exemplo: número de ocorrências de palavras

- Ordenação do vetor (de ponteiros para Palavra):
  - utilize a função *qsort* da biblioteca padrão
  - defina a função de comparação apropriadamente

```
static int compara (const void* v1, const void* v2)
{
   Palavra** p1 = (Palavra**)v1;
   Palavra** p2 = (Palavra**)v2;
   if ((*p1)->n > (*p2)->n) return -1;
   else if ((*p1)->n < (*p2)->n) return 1;
   else return strcmp((*p1)->pal,(*p2)->pal);
}
```

Exemplo: número de ocorrências de palavras

- Impressão da tabela:

```
static void imprime (Hash tab)
{
   int i;
   int n;
   Palavra** vet;
   /* cria e ordena vetor */
   n = conta_elems(tab);
   vet = cria_vetor(n,tab);
   qsort(vet,n,sizeof(Palavra*),compara);
   /* imprime ocorrências */
   for (i=0; i<n; i++)
      printf("%s = %d\n",vet[i]->pal,vet[i]->n);
   /* libera vetor */
   free(vet);
}
```

Exemplo: número de ocorrências de palavras

- Função Principal:

```
#include <stdio.h>
#include <string.h>
#include <ctype.h>
#include <stdlib.h>
...  /* funções auxiliares mostradas acima */
```

```
int main (int argc, char** argv)
{
   FILE* fp;
   Hash tab;
   char s[NPAL];
   if (argc != 2) {
      printf("Arquivo de entrada nao fornecido.\n");
      return 0; }
   /* abre arquivo para leitura */
   fp = fopen(argv[1],"rt");
   if (fp == NULL) {
      printf("Erro na abertura do arquivo.\n");
      return 0; }
   /* conta ocorrência das palavras */
   inicializa(tab);
   while (le_palavra(fp,s)) {
      Palavra* p = acessa(tab,s);
      p->n++; }
   /* imprime ordenado */
   imprime (tab);
   return 0;
}
```

Resumo

- Tabelas de dispersão (hash tables):
  - utilizadas para buscar um elemento em ordem constante O(1)
- Função de dispersão (função de hash):
  - mapeia uma chave de busca em um índice da tabela
- Estratégias para tratamento de colisão:
  - uso da primeira posição consecutiva livre
  - uso de uma segunda função de dispersão
  - uso de listas encadeadas

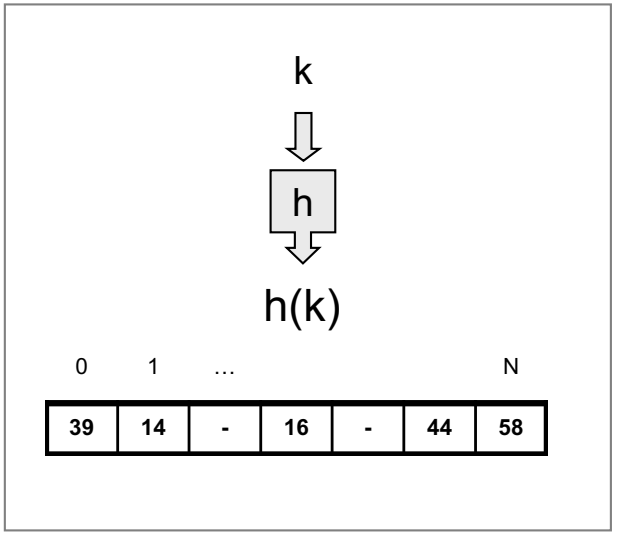

Referências

Waldemar Celes, Renato Cerqueira, José Lucas Rangel, *Introdução a Estruturas de Dados*, Editora Campus (2004)

Capítulo 18 – Tabelas de dispersão