

Tabela Hash (Hashing)

- É uma extensão à busca indexada por chave
 - adequa melhor à aplicações de busca mais típicas quando não temos chaves que casem exatamente com os índices.
- Algoritmos de busca baseados em Hashing são divididos de duas partes:
 - 1) Computar a função hash que transforma a chave de busca em um endereço da tabela
 - Idealmente chaves diferentes resolverão para endereços diferentes
 - Mas é frequente que uma ou mais chaves resolvem para o mesmo endereço
 - 2) Tratar colisão: processo que processa a questão das chaves que resolvem para o mesmo endereço.
 - Um dos métodos de colisão é o uso de lista encadeada
 - Útil em situações que não se prevê o número de chaves de busca
 - Os outros dois métodos de tratamento de colisão obtém melhor resultado com os itens armazenados em um vetor fixo.
- Hashing é um bom exemplo de "time-space tradeoff"
 - Se não tivesse limite de memória, então faríamos a busca com apenas um acesso à memória usando a chave como um endereço de memória, como uma busca indexada pela chave
 - Se não tivesse limite de tempo, usaríamos a menor quantidade de memória e faríamos busca sequencial.

- Hashing provê um balanço entre os dois extremos apenas ajustando o tamanho o tamanho da tabela, sem precisar reescrever código ou escolhendo outros algoritmos
- Hashing é um problema clássico de computação: Os algoritmos são bem estudados, em profundidade e diversidade.
 - busca e inserção ficam em tempo constante
- Nem tudo são flores:
 - O tempo de execução depende do tamanho da chave, podendo ser impraticável para chaves muito compridas
 - Não há implementação eficiente para "sort" e "select"

⇒ Funções HASH

- Se temos uma tabela que armazena M itens, precisamos de uma função que transforme chaves em inteiros $[0, M-1]$
- Uma função hash ideal é fácil de computar e se aproxima de uma função aleatória
- A função^{hash} é dependente do tipo de chave
 - precisamos de funções diferentes para tipos diferentes
- Ideia simples para números em ponto flutuante
 - Chaves são números reais que 0 e menores que 1 basta multiplicar por M e arredondar para o inteiro mais próximo para obter um endereço entre 0 e $M-1$.
 - Generalizando: As chaves são números em ponto flutuante maiores que " s " e menores que " t " para qualquer " s " e " t " que sejam fixos.
 - re-escalamos a chave subtraindo por " s " e dividindo por " $t-s$ ", colocando entre 0 e 1 , então multiplicamos por M .

- Se as chaves são números inteiros de " u " bits, podemos converter para números em ponto flutuante dividindo por 2^u para obter números em ponto flutuante entre 0 e 1, depois multiplicamos por M .

- Se operações em números em ponto flutuante são caras e os números não são muito grandes (a ponto de não causar overflow), fazemos:

- Multiplicar a chave por M

- fazer "right shift" em u -bits e dividir por 2^u

- Problema:

- Só funciona para hash se as chaves forem distribuídas uniformemente no intervalo, pois o valor hash é definido pelos primeiros dígitos de chave

- O algoritmo mais comum e mais simples para chaves inteiros de " u " bits

- Escolher um tamanho M para a tabela que seja um número primo

- Para qualquer chave " k ", computar o resto dividindo k por M , ou:

$$h(k) = k \bmod M \quad k < M$$

- Também podemos usar hashing modular para chaves em ponto-flutuante.

Se as chaves estão em um intervalo pequeno, rescalamos para um número entre 0 e 1, multiplicamos por 2^u e, então, fazemos a hash modular.

- É quando a chave é menor que uma palavra? Ou se ela possui parte dos bits fixos?

exemplo: Chaves de 3 caracteres, representado em

3 chars, cada char possui 8 bits, no entanto cada letra é codificada em 7 bits, logo podemos tratar como inteiros de base 128, então a chave

"abc" é codificado como

$$97 \cdot 128^2 + 98 \cdot 128^1 + 99 \cdot 128^0 \\ = 1589577$$

Escolher M como 64 é ruim para esta função pois $(x \bmod 64)$ não é afetado com a soma de múltiplos de 64 (ou 128) a x — a função hash de qualquer chave é o valor dos últimos 6 bits

Há um efeito similar quando a chave é múltiplo de 2

Para evitar isso, devemos usar um número primo

⇒ Função hash para strings

```
int hash(char *v, int M)
```

{


```
    int h=0, a=127;
```

```
    for (; *v != '\0'; v++)
```

```
        h = (a * h + *v) % M;
```

```
    return h;
```

}



← $M=96, a=127$

← $M=97, a=128$

← $M=96, a=127$

→ As primeiras 1000 palavras de Moby Dick

Função Hash Universal (para strings)

```
int hashU(char *v, int M)
```

```
{
```

```
    int h, a = 31415, b = 27183;
```

```
    for (h = 0; *v != '\0'; v++, a = a * b % (M - 1))
```

```
        h = (a * h + *v) % M;
```

```
    return h;
```

```
}
```

- Valores "aleatórios" para os coeficientes, e um número "aleatório" diferente para cada dígito de chave

→ Sumário

```
#define hash(v, M) (((v - 1) / (t - 1)) * M)
```

```
#define hash(v, M) (v % M)
```

Se M não for primo :

```
#define hash(v, M) ((int) (-616161 * (float) v) % M)
```

```
#define hash(v, M) (16161 * (unsigned) v) % M)
```


→ Hash Universal pode ser muito mais lento que os métodos mais simples

→ Estratégia de Colisão

⇒ Encadeamento Separado

```
link *heads, z;  
int M;  
void STinit(int M)  
{  
    heads = malloc(M * sizeof(link));  
    z = NEW(NULLitem, NULL);  
    for(int i=0; i<M; i++)  
        heads[i] = NEW(NULLitem, z);  
    M = M;  
}
```

```
Item STsearch(Key k)  
{  
    int h = hash(k, M);  
    return SearchLE(heads[h], k);  
}
```



```
void STinsert(Item ite)  
{  
    int h = hash(Key(ite), M);  
    insertLE(heads[h], ite);  
}
```

⇒ Encadenamiento Aberto



```
#define hash(v, M) (v % M)
Item *ht; int M;
void STinit(int Max)
{
```

```
    ht = malloc(Max * sizeof(Item));
    M = Max;
    for(int i = 0; i < Max; i++)
        ht[i] = NULLItem;
}
```

```
int HTinsert(Item ni)
{
```

```
    • int h = hash(Key(ni), M);
      int c = MaxCol;
      while(c && !eq(Key(ht[h]), Key(NULLItem)))
      • c--, h = (h+1) % M;
      if(!c)
          return false;
      ht[h] = ni;
      return true;
}
```

```
Item HTsearch(Key k)
{
```

```
    int h = hash(k, M);
    int c = MaxCol;
    while(c && !eq(k, ht[h]))
        h = (h+1) % M, c--;

    if(!c)
        return NULLItem;
    return ht[h];
}
```

```
#define MaxCols 10
```




```
void STinsert(Item ni)
{
    if(!HTinsert(ni))
        bluescreen();
}
```

```
void ATRemove(Key k)
{
    int h = hash(k, M);
    int c = MaxCol;
    while(c && !eq(k, ht[h]))
        h = (h+1) % M, c--;

    if(!c) return;
    ht[h] = NULLItem;
}
```

⇒ Double Hash



```
#define hash(v, M) (v % M)
```

```
Item *ht; int M;
void STinit(int Max)
```

```
{
```

```
    ht = malloc (Max * sizeof(Item));
```

```
    M = Max;
```

```
    for(int i = 0; i < Max; i++)
```

```
        ht[i] = NULLItem;
```

```
}
```

```
int HTinsert(Item ni)
```

```
{
```

```
    int h = hash(Key(ni), M); int h2 = hashtable(Key(ni))
    int c; int hn = -1;
```

```
    for(c = MaxCol; c > 0; c--, h = (h + h2) % M)
```

```
        if (eq(Key(ht[h]), Key(NULLItem)))
```

```
            hn = h;
```

```
        else if (eq(Key(ht[h]), Key(ni)))
```

```
            hn = h; break;
```

```
}
```

```
if (hn == -1)
```

```
    return false;
```

```
ht[hn] = ni;
```

```
return true;
```

```
}
```

```
Item HTsearch(Key k)
```

```
{ int h2 = hashtable(k);
```

```
int h = hash(k, M);
```

```
int c = MaxCol;
```

```
while (c && !eq(k, ht[h]))
```

```
    h = (h + h2) % M, c--;
```

```
if (!c)
```


```
    return NULLItem;
```

```
return ht[h];
```

```
}
```

```
#define MaxCol 10
```

```
#define hashtable(v) (v % 97 + 1)
```



```
void STinsert(Item ni)
```

```
{ if (!HTinsert(ni))
```

```
    bluescreen();
```

```
}
```

```
void ATRemove(Key k)
```

```
{ int h2 = hashtable(k)
```

```
int h = hash(k, M);
```

```
int c = MaxCol;
```

```
while (c && !eq(k, ht[h]))
```

```
    h = (h + h2) % M, c--;
```

```
if (!c) return;
```

```
ht[h] = NULLItem;
```

```
}
```



```
void STgrow(int Max)
```

```
{
```

```
    Item *ht2 = malloc(Max * sizeof(Item))
```

```
    Item *htv[ho] = ht; ht = ht2;
```

```
    for(int i=0; i<Max; i++)
```

```
        ht2[i] = NULL Item;
```

```
    int Mv[ho] = M; M = Max;
```

```
    for(int i=0; i<Mv[i]; i++)
```

```
    {
```

```
        if(!eq(Key(NULL Item), Key(htv[ho][i])))  
            continue;
```

```
        HIinsert(htv[ho][i]);
```

```
    }
```

```
    free(htv[ho])
```

```
{
```