

Árvore:

Seções 5.1 e 7.2 do livro "Estruturas de Dados Usando C" de Tenenbaum, Langsam e Augenstein
Seções 5.4 e 5.5 do livro do Sedgewick

Dado um conjunto de vértices e arestas, um caminho é uma lista de vértices distintos na qual cada vértice na lista é conectado ao próximo por uma aresta.

Árvore (livre): Um conjunto de vértices (nodos) e arestas que satisfaz a seguinte condição: existe exatamente um caminho conectando qualquer par de nodos.

Se houver algum par de nodos para o qual existe mais de um caminho ou nenhum caminho temos um grafo.

Floresta: Um conjunto de árvores disjuntas.

Em computação:

Em geral, árvores referem-se a estruturas que possuem um nodo designado como raiz. Nestas árvores, cada nodo é a raiz de uma subárvore.

Desenho da árvore:

Raiz no topo:

- existe a noção de um nodo estar acima (mais próximo da raiz) ou abaixo dele (mais longe da raiz)
 - PAI: todo nodo, exceto a raiz tem um único pai, que é o nodo logo acima dele
 - FILHOS: são os nodos logo abaixo de um determinado nodo
 - IRMAO / AVO / ASCESTRAL/ DESCENDENTE
 - FOLHAS ou nodos terminais: nodos que não possuem filhos
 - nodos INTERNOS ou não terminais: que possuem filhos
 - árvores ORDENADAS: árvores nas quais a ordem dos filhos é significativa
 - árvores n-aria: árvores nas quais todos os nodos internos obrigatoriamente tem "n" filhos.
- Ex: árvore binária.

Nestas árvores em geral é utilizado o conceito de "nodo externo" (que não possui filhos), referenciado por nodos internos que não tem o número especificado de filhos. Neste caso, FOLHA é um nodo interno cujos filhos são todos nodos externos.

Nível de um nó:

Nível da raiz = 0

Nível de outros nós = nível do pai + 1

Altura da árvore:

Nível máximo de um nodo (interno ou externo) da árvore.

Árvore Binária:

Um árvore binária é ou um nodo externo ou um nodo interno conectado a um par de árvores binárias, chamadas de subárvore esquerda e subárvore direita do nodo.

Representação:

```
typedef struct nodo *ApNodo;
struct nodo {
    Item item;
    ApNodo esq, dir;
}
```

Propriedades:

1) uma arv. binária com N nodos internos tem $N+1$ nodos externos.

Prova por indução:

$N = 0$ --> árvore vazia com apenas um nodo externo

$N > 0$ --> a raiz de uma árvore binária tem na
subarv. esq: k nodos internos, $0 \leq k \leq N-1$
subarv. dir: $N-k-1$ nodos internos

Por hip.ind. a subarv. esq tem $k+1$ nodos externos e a subarv. dir $N-k-1+1$ nodos externos.
Assim, a árvore tem $(k+1) + (N-k-1+1) = N+1$ nodos externos.

Árvore binária completa de altura d é uma árvore binária na qual todos os nodos externos estão no nível d .

2) a quantidade de nodos externos em uma arv.bin.compl de altura $d = 2^{\{d\}}$

3) quantidade de nodos em uma árvore binária completa de altura $d = 2^{\{d+1\}} - 1$

Prova por indução em d :

Base: $n = 0$ (árvore vazia)

$$\#nodos = 2^{\{0+1\}} - 1 = 1 \text{ (1 nodo externo)}$$

Hipótese da indução:

Uma árvore binária completa de altura d tem $2^{\{d+1\}} - 1$ nodos.

Passo da indução:

Uma arv.bin.compl de altura d tem 2^d nodos externos. Assim, aumentando 1 a altura da árvore, cada um destes nodos passa a ser pai de dois outros nos. Assim, # nodos em uma árvore de altura $d+1$

$$\begin{aligned} &= (2^{\{d+1\}} - 1) + (2^d * 2) \quad \text{os que já existiam + novos nodos} \\ &= 2^{\{d+1\}} - 1 + 2^{\{d+1\}} \\ &= 2 * 2^{\{d+1\}} - 1 \\ &= 2^{\{d+2\}} - 1 \end{aligned}$$

4) quantidade de nodos internos em uma árvore binária completa de altura $d = 2^{\{d\}} - 1$.

Consequência direta das propriedades 1 e 3.

Altura de uma arv.bin.completa com n "chaves" (nodos internos) = $\log_2 (n+1)$

Árvore Binária quase Completa de Altura d :

Uma arv. binária na qual:

1. todos os nodos externos estão no nível d ou $d-1$
2. se um nó nd na árvore tem algum descendente direito no nível d (o máximo da árvore), então todos os nodos externos que são descendentes esquerdos de nd estão também no nível d .

Numeração dos nodos:

$$\text{num}(\text{raiz}) = 1$$

$$\text{num}(n) = \begin{array}{l} 2 * \text{num}(np), \text{ se } n \text{ é filho esquerdo de } np \\ 2 * \text{num}(np) + 1, \text{ se } n \text{ é filho direito de } np \end{array}$$

Altura de uma arv.bin.quase completa com n nodos internos:

$$\text{teto}(\log_2(n+1))$$

Isso representa uma árvore que tem a quantidade de nodos internos entre uma árvore binária completa de altura $d-1$ ($2^{\{d-1\}} - 1$ nodos) e uma árvore binária completa de altura $d = (2^{\{d\}} - 1$ nos).

Árvore Binária - Implementação

Seções 5.6, 5.7, 12.2 (Sedgewick)

Representações de Árvore Binária:

- vetores
- apontadores

```
typedef struct no *Apontador;
typedef struct no{
    long chave;
    ...
    Apontador esq, dir;
} No;
```

Percurso:

Pre-ordem: visita o nodo, subarv. esq, subarv. direita
Em ordem: visita a subarv. esq., nodo, subarv. direita
Pós-ordem: visita a subarv. esq, subarv. direita, nodo

Função Recursiva:

```
void preOrdem( Apontador p )
{
    if( p == NULL ) return;
    printf("%ld\n", p->chave);
    preOrdem( p->esq );
    preOrdem( p->dir );
}
```

Função Não Recursiva:

```
void preOrdemPilha( Apontador p )
{
    pilha s;

    inicializaPilha( s );
    push( s, p );
    while( !vazio(s) ){
        p = pop( s );
        if( p != NULL ){
            printf("%ld\n", p->chave);
            push( p->dir, s );
            push( p->esq, s );
        }
    }
}
```

Observe que esta função não pode ser diretamente estendida para percursos em ordem e pós-ordem. Uma possibilidade para resolver o problema é fazer distinção entre empilhar "árvore" e empilhar "chave".

Percurso por nível (utilizando uma fila)

```
void percursoPorNível( Apontador p ){
    if( p == null )
        return;
    inicializaFila( f );
    putFila( f, p );
    while( !vazio( f )){
        p = getFila( f );
        printf( "%ld\n", p->chave );
        if( p->esq != null )
            putFila( f, p->esq );
        if( p->dir != null )
            putFila( f, p->dir );
    }
}
```

Contagem de Número de Nodos (internos) da Árvore:

```
int contaNodo( Apontador p ){
    if( p == NULL ) return 1;
    return contaNodo( p->esq ) + contaNodo( p->dir ) + 1;
}
```

Altura de uma árvore:

```
int altura( Apontador p ){
    int he, hd;

    if( p == NULL ) return 0;
    he = altura( p->esq ); hd = altura( p->dir );
    if( he > hd )
        return he+1;
    else
        return hd+1;
}
```

Nível do nodo que contém uma chave k:

- a função retorna -1 se k não existir na árvore
- chamada: nívelChave(raiz, k, 0)

```
int nívelChave( Apontador p, long k, int nível ){
    int result;

    if( p == null )
        return -1;
    else if( p->chave == k )
        return nível;
    else {
        result = nívelChave( p->esq, k, nível+1 );
        if( result >= 0 )
            return result;
        else
            return nívelChave( p->dir, k, nível+1 );
    }
}
```

Tipo abstrato de dados (TAD):

É um conjunto de operações associado a uma estrutura de dados, de tal forma que haja independência de implementação para as operações

Dicionário ou Tabela de Símbolos:

Um dicionário é um TAD que contém itens com chaves e que dá suporte a seguintes operações básicas: inicializa, insere um novo elemento, remove um elemento e pesquisa o item que contém uma determinada chave.

- analogia com dicionário da língua portuguesa: chave = palavra, registro = pronúncia, sinônimo, definição, etc.

Árvore Binária de Busca

Seção 12.5, 12.6, 12.8, 12.9 (Sedgewick)

É uma árvore binária na qual para todo no n , os elementos da subárvore a esquerda contem chaves com valores menores que a chave de n e a subárvore a direita contem chaves maiores que a chave de n .

Implementação:

A implementação abaixo usa um nodo (nodoNull) para a representação de nodos externos ao invés do valor NULL:

```
#include <stdio.h>

typedef struct nodo *Apontador;
typedef struct nodo {
    longInt chave;
    ...
    Apontador dir, esq;
    int contaNodo;
} Nodo;

static Apontador raiz, nodoNull;

Apontador criaNodo( longint chave, Apontador esq, Apontador dir, int N ){
    Apontador p;

    p = malloc( sizeof *p );
    p->chave = chave; p->esq = esq; p->dir = dir; p->contaNodo = N;
    return p;
}

void inicializaDic() {
    nodoNull = criaNodo( 0, 0, 0, 0 );
    raiz = nodoNull;
    return;
}

Apontador buscaArv( Apontador p, longInt chave ){
    if (p == nodoNull) return nodoNull;
    if (chave == p->chave) return p;
    if (chave < p->chave)
        return buscaArv( p->esq, chave )
    else return buscaArv( p->dir, chave );
}

Apontador insereArv( Apontador p, longint chave){
    if( p == nodoNull) return criaNodo( chave, nodoNull, nodoNull, 1 );
    if( chave < p->chave)
        p->esq = insereArv(p->esq, chave);
    else
        p->dir = insereArv(p->dir, chave);
    (p->contaNodo)++;
    return p;
}
```

Inserção - Função Iterativa:

```
Apontador insereArv( longint chave ){
    Apontador p, paiP;
```

```

if( raiz == nodoNull ){
    raiz = criaNodo( chave, nodoNull, nodoNull, 1 );
    return raiz;
}
p = raiz;
while( p != nodoNull ){
    paiP = p;
    if( chave < p->chave )
        p = p->esq;
    else
        p = p->dir;
}
p = criaNodo( chave, nodoNull, nodoNull, 1 );
if( chave < paiP->chave )
    paiP->esq = p;
else
    paiP->dir = p;
return p;
}

```

Ordenação por Árvore:

Composta por 2 passos:

1. pre-processamento: geração da árvore de binária de busca
2. percurso da árvore em-ordem

```

void ordena( longint v[], int tamV ){
    int i;

    inicializaDic();
    for( i=0; i < tamV; i++ )
        insereArv( raiz, v[i] );
    emOrdem( raiz );
    return;
}

```

Custo:

Pior caso:

n^2 , no caso dos elementos serem lidos em ordem ascendente ou descendente

Caso médio:

$n \log(n)$, a altura de uma árvore balanceada é $\text{chão}(\log_2(n))$. Assim, para inserir cada um dos n elementos na árvore são necessárias no máximo $\log(n)$ comparações.

Para obter uma árvore balanceada:

Após a entrada de uma chave k , metade dos elementos tem chave menor que k e metade tem chaves maiores que k .

Custo médio de busca:

(em uma árvore binária com n nos, considerando que todos os nos tem igual probabilidade de serem acessados)

$(s+n) / n$, onde s é o comprimento do caminho interno, ou seja, a soma do comprimentos dos caminhos entre a raiz e cada um dos nos da árvore. Isto se deve ao fato de para acessar um determinado no de nível l , são necessárias $l+1$ comparações.

- pode ser mostrado que o número esperado de comparações em uma arv. de pesquisa randômica é $1.39 \log(n)$, ou seja, somente 39% pior que a árvore completamente balanceada.

Inserção na raiz:

Exemplo:

```
      20
     /  \
    10   30
     /  \
    25  35
   /  \
  21  27
```

Inserção da chave 26:

```
      26
     /  \
    20   30
   /  \
  10  25  35
   /  \
  21  27
```

que viola a def. de Arv.Bin.Busca

Solução:

Série de rotações após a inserção do elemento na folha:

```
      20
     /  \
    10   30
     /  \
    25  35
   /  \
  21  27
     \
     26
```

1. rotação a direita de 27
2. rotação a esq. de 25
3. rotação a direita de 30
4. rotação a esquerda de 20

```
Apontador rotDir( Apontador p ){
    Apontador q;
```

```
    q = p->esq; p->esq = q->dir; q->dir = p;
    return q;
```

```
}
```

```
Apontador rotEsq( Apontador p ){
    Apontador q;
```

```
    q = p->dir; p->dir = q->esq; q->esq = p;
    return q;
```

```
}
```

```
Apontador insereArv( Apontador p, longint chave ){
```

```
    if( p == nodoNull ) return criaNodo( chave, nodoNull, nodoNull, 1 );
```

```
    if( chave < p->chave ){
```

```
        p->esq = insereArv( p->esq, chave );
```

```
        p = rotDir( p );
```

```
    } else {
```

```
        p->dir = insereArv( p->dir, chave );
```

```
        p = rotEsq( p );
```

```
    }
```

```
    return p;
```

```
}
```

```
void insereDic( longint chave ){
```

```
    raiz = insereArv( raiz, chave );
```

```
    return;
```

```
}
```

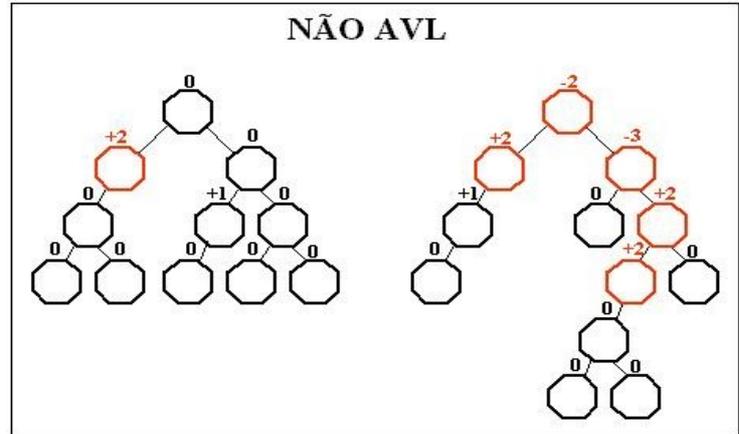
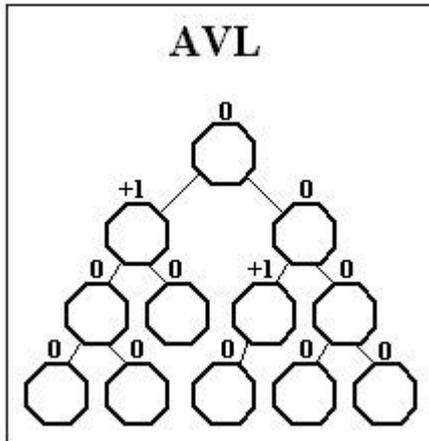
Árvore Balanceada AVL (Árvore de Adelson, Velskii e Landis)

<http://www.youtube.com/watch?v=mKMwi691rs8> (árv. Binárias, descrição, fator de balanceamento)

http://www.youtube.com/watch?v=s5w_Gny8B4A (inserção, rotação, remoção)

<http://www.lcad.icmc.usp.br/~nonato/ED/>

http://www.youtube.com/watch?v=1PGyt7_EAw (exemplo de inserção e rotação)



Motivação:

Garantir custo $O(\log n)$ para busca, inserção e remoção

Abordagem:

Manter a árvore balanceada após cada operação

Descrição:

Uma árvore binária de busca na qual, para todos os nós, as alturas de suas subárvores não diferem em mais de 1.

O balanceamento de um nó pode ser -1, 0, ou 1 dependendo de a altura da subárvore a esquerda ser menor, igual ou maior que a subárvore a direita, respectivamente. Ou seja, uma árvore está desbalanceada se contiver nodos com balanceamento menor que -1 ou maior que 1.

Balanceamento:

Rotação a direita e a esquerda:

Seja x o nodo com maior nível no qual ocorre um desbalanceamento. 4 casos a considerar. Inserção na:

- subárvore esquerda do filho esquerdo de x
- subárvore direita do filho direito de x
- subárvore direita do filho esquerdo de x
- subárvore esquerda do filho direito de x

Os casos a) e b) são resolvidos com UMA rotação para balancear a árvore.

Os casos c) e d) precisam de DUAS rotações.

Rotação, inserção e altura das subárvores:

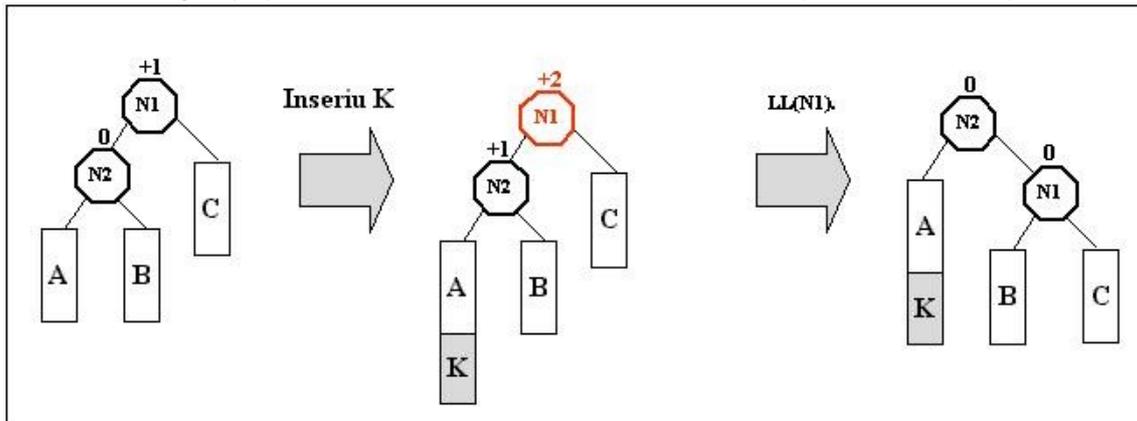
Rotação a direita do nó n :

-o balanceamento de n e de todos os seus ancestrais (depois da rotação) diminui de 1

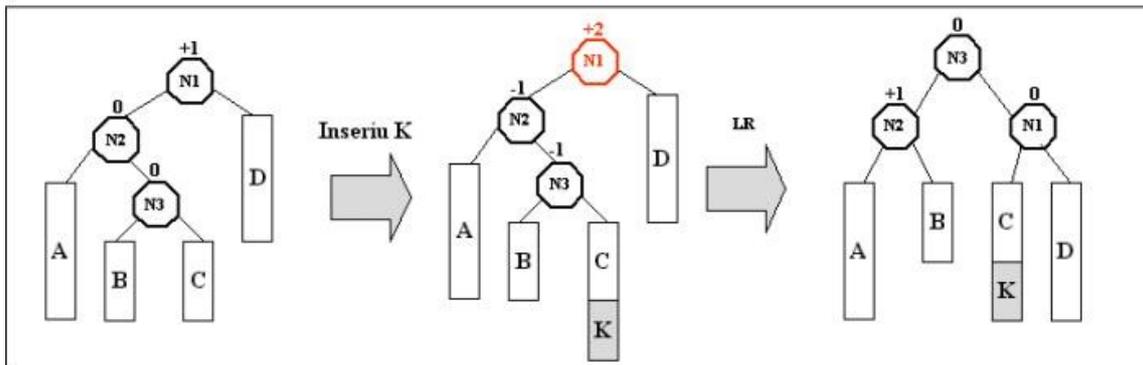
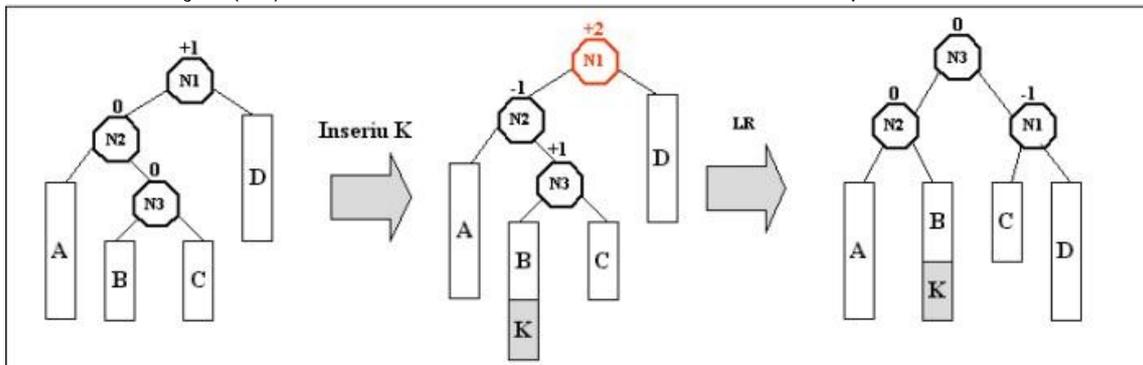
Rotação a esquerda do nó n:

-o balanceamento de n e de todos os seus ancestrais (depois da rotação) aumenta de 1

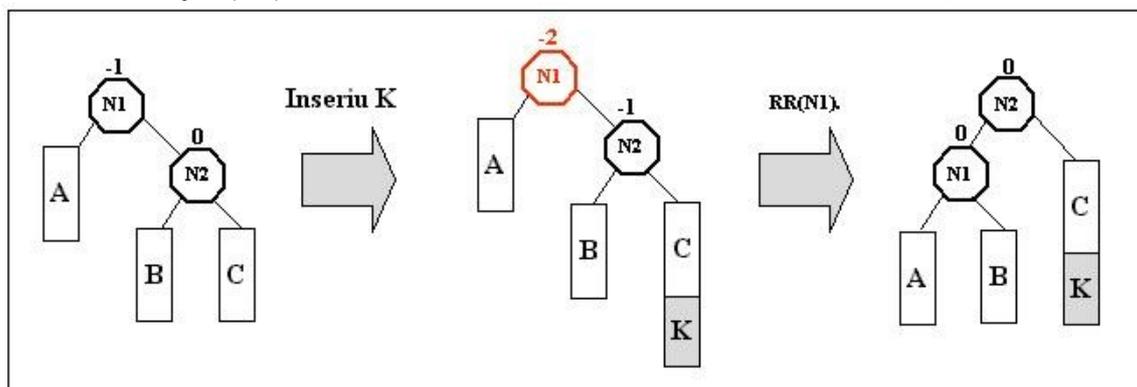
- Rotação (LL): O novo nó X é inserido na sub-árvore da esquerda do filho esquerdo de A;



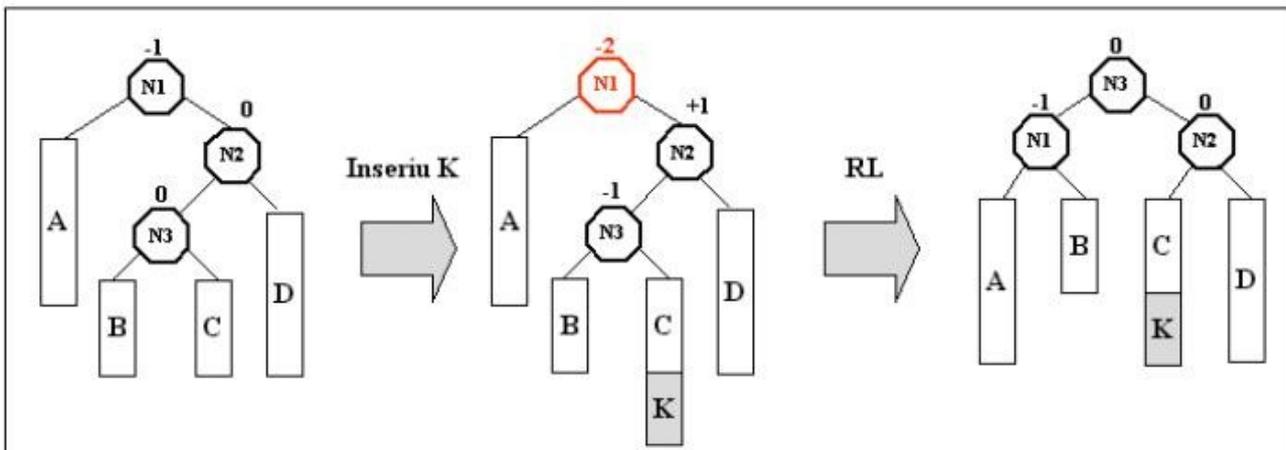
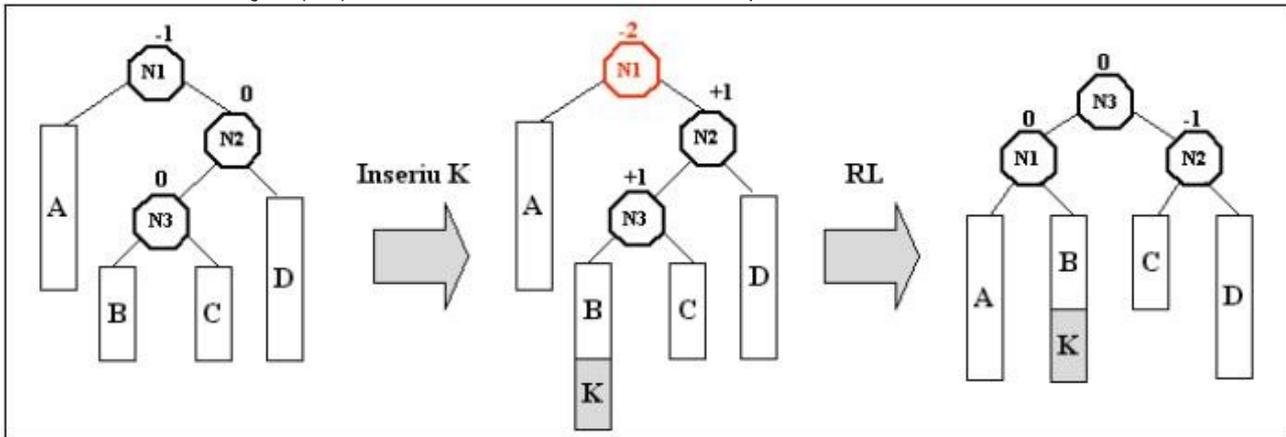
- Rotação (LR): X é inserido na sub-árvore da direita do filho esquerdo de A;



- Rotação (RR): X é inserido na sub-árvore da direita do filho direito de A;



- Rotação (RL): X é inserido na sub-árvore da esquerda do filho direito de A.



Inserção de um novo nodo n:

1. insere n na árvore binária, guardando o ancestral 'a' de nível mais alto que PODE ficar desbalanceado ('a' inicialmente é a raiz)
2. altera os balanceamentos de todos os nodos no caminho de 'a' até n

```
se chave(n) < chave(a)
    bal(a) = bal(a) + 1
senão
    bal(a) = bal(a) - 1
```

3. balanceia a árvore e acerta balanceamentos

```
se estiver desbalanceado para a direita -- bal(a) < -1
    f = direita(a)
    se bal(direita(a)) == -1
        rotaçãoEsquerda(a)
        bal(a) = bal(f) = 0
    senão
        neto = esquerda(f)
        rotaçãoDireita(direita(a))
        rotaçãoEsquerda(a)
        se bal(neto) == 0
            bal(a) = bal(f) = 0
        senão se bal(neto) > 0
            bal(a) = 0
            bal(f) = -1;
        senão
            bal(a) = 1;
            bal(f) = 0;
```

```

    bal(neto) = 0;

se estiver desbalanceado para a esquerda -- bal(a) > 1
    f = esquerda(a)
    se bal(f) == 1
        rotaçãoDireita(a)
        bal(a) = bal(f) = 0
    senão
        neto = direita(f)
        rotaçãoEsquerda(esquerda(a))
        rotaçãoDireita(a)

        se bal(n) == 0
            bal(a) = bal(f) = 0
        senão se bal(neto) > 0
            bal(a) = -1;
            bal(f) = 0;
        senão
            bal(a) = 0;
            bal(f) = 1;
        bal(neto) = 0

Apontador Insere(Registro r, Apontador p, int *mudouAltura){
    if( p == nodoNull ){
        *mudouAltura = TRUE;
        return criaNo( r, nodoNull, nodoNull );
    }
    if( r.Chave <= p->Reg.Chave ){
        p->Esq = Insere( r, p->Esq, mudouAltura );
        if( *mudouAltura ){
            p->bal++;
            if( p->bal == 0 )
                *mudouAltura = FALSE;
            else if( p->bal == 2){
                *mudouAltura = FALSE;
                balanceia( &p );
            }
        }
    } else {
        p->Dir = Insere( r, p->Dir, mudouAltura );
        if( *mudouAltura ){
            p->bal--;
            if( p->bal == 0 )
                *mudouAltura = FALSE;
            else if( p->bal == -2){
                *mudouAltura = FALSE;
                balanceia( &p );
            }
        }
    }
    return p;
}

```

Remoção de nodo:

Ideia:

1. fazer busca do nodo que contem a chave a ser removida (nodoK)
2. se nodoK for uma folha então remover nodoK, caso contrario:
 - encontrar o nodo com maior chave na subarv. esquerda ou
 - menor chave na subárvore direita (nodoRem)
 - remover nodoRem da árvore

- substituir a chave em nodoK pela chave em nodoRem

Cuidados na remoção do novo da árvore:

- caso o nodo ficar desbalanceado, balancear da mesma forma que na inserção
- a remoção de um nodo pode causar diversas operações de balanceamento a partir de nodoRem até a raiz
- a mesma estratégia utilizada pela inserção de manter um parâmetro (mudouAltura) pode ser usada na remoção: ele é verdadeiro caso a subárvore mudou de altura e falso caso contrario.
- a mudança de altura da subárvore com raiz em "n" pode ser verificada testando o balanceamento original de n: se o balanceamento for zero, uma remoção não vai alterar sua altura, uma vez que a remoção de um nodo na subárvore do filho esquerdo não altera a altura da subárvore do filho direito (e vice-versa). Portanto a altura da subárvore com raiz em n também não se altera.
- observe que uma operação de balanceamento em um nodo n também altera sua altura.

```
void Remove(TipoChave k, Apontador *raiz ){
    Apontador nodoK, nodoRem;
    Registro regRem;
    int mudouH;

    /* busca nodo que contem chave k */
    nodoK = busca( k, *raiz );
    if( nodoK == nodoNull )
        return;

    /* busca nodo com dados que vao substituir chave k que sera' removida */
    if( nodoK->Dir == nodoNull && nodoK->Esq == nodoNull )
        nodoRem = nodoK;
    else if( nodoK->bal > 0 )
        nodoRem = buscaMaior( nodoK->Esq );
    else
        nodoRem = buscaMenor( nodoK->Dir );
    regRem = nodoRem->Reg;

    /* remove nodoRem da árvore */
    /* nodoRem é folha ou tem um único filho */
    *raiz = removeR( nodoRem, *raiz, &mudouH );
    nodoK->Reg = regRem;
    return;
}

Apontador removeR( Apontador nodoRem, Apontador p, int *mudouH ){
    Apontador filho;

    /* remove nodoRem: se for folha retorna nodoNull;
    caso constrario retorna o endereço do seu único filho */
    if( p == nodoRem ){
        if( p->Dir != nodoNull )
            filho = p->Dir;
        else if( p->Esq != nodoNull )
            filho = p->Esq;
        else
            filho = nodoNull;
        free( p );
        *mudouH = TRUE;
        return filho;
    }
    else if( nodoRem->Reg.Chave < p->Reg.Chave ){
        p->Esq = removeR( nodoRem, p->Esq, mudouH );
        if( *mudouH ){
            if( p->bal == 0 )          /* se o balanceamento era originalmente = 0
*/
```

```

        *mudouH = FALSE;      /* a remoção não altera a altura da subarv.
*/
    p->bal--;
    if( p->bal == -2 )      /* mesmo balanceando a altura da subarv. muda
*/
        balanceia( &p );
    }
}
else {
    p->Dir = removeR( nodoRem, p->Dir, mudouH );
    if( *mudouH ){
        if( p->bal == 0 )
            *mudouH = FALSE;
        p->bal++;
        if( p->bal == 2 )
            balanceia( &p );
    }
}
return p;
}

```

Altura:

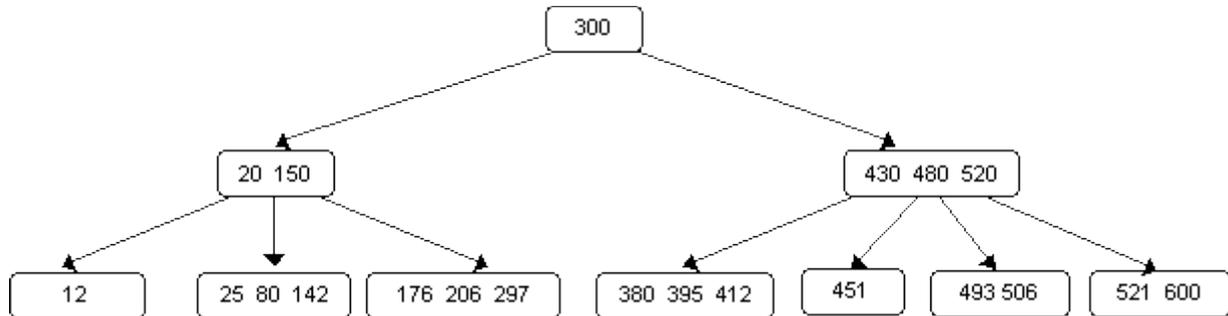
A altura de uma árvore AVL com n nodos é $\leq 1.44 \log(n)$

Árvores 2-3-4

Seção 13.3 (Sedgewick)

<http://www.youtube.com/watch?v=bhKixY-cZHE> (Inserção em uma árv. 2-3)

<http://www.lcad.icmc.usp.br/~nonato/ED/>



Definição:

Uma árvore 2-3-4 é uma árvore que está vazia ou que é composta por 3 tipos nodos:

-nodos-2: contem uma chave k_1 e dois apontadores, p_1 e p_2 . O apontador p_1 aponta para uma árvore com valores de chave menores que k_1 e o apontador p_2 aponta para uma árvore com valores de chave maiores que k_2 .

-nodos-3: contem duas chaves k_1 , k_2 e três apontadores, p_1 , p_2 e p_3 . p_1 aponta para uma árvore com valores de chave menores que k_1 , p_2 aponta para uma árvore com valores de chave $>k_1$ e $<k_2$, e p_3 aponta para uma árvore com valores de chave $>k_2$

-nodos-4: contem três chaves k_1 , k_2 , k_3 e quatro apontadores, p_1 , p_2 , p_3 e p_4 . p_1 aponta para uma árvore com valores de chave menores que k_1 , p_2 aponta para uma árvore com valores de chave $>k_1$ e $<k_2$, p_3 aponta para uma árvore com valores de chave $>k_2$ e $<k_3$, e p_4 aponta para uma árvore com valores de chave $>k_3$.

Definição:

Uma árvore 2-3-4 balanceada é uma árvore 2-3-4 na qual todos os nodos folha estão no mesmo nível.

Pesquisa:

- cada nodo possui no máximo 3 chaves ($k[0], k[1], k[2]$) e 4 apontadores ($p[0], p[1], p[2], p[3]$).

- cada nodo possui também o tamanho do nodo -- $tam(n)$, que corresponde a quantidade de chaves no nodo n .

```
q = raiz( A );
if( q != NULL ){
    for( i=0; i < tam(n); i++)
        if( q.k[i] == chave )
            return q;
        else if( q.k[i] > chave )
            return busca( q.p[i], chave );
    return busca( q.p[tam(n)], chave );
}
```

Propriedade:

A busca de uma arv. 2-3-4 com n nodos visita no máximo $\log(n)+1$ nodos .

Inserção:

A inserção de uma chave k pode ser feita da mesma forma que em uma árvore binária. Após uma busca sem sucesso, inserir a chave na folha.

Problema: a árvore pode ficar desbalanceada

Exemplo:

```
      R
     / \
    A   S  inserir C, H, I
```

Abordagem para balancear:

1. inserir sempre em um nodo folha. Caso o nodo contenha mais de 3 chaves, divide o nodo em dois e "sobe" com a chave do meio.

2. dividir os nodos com 3 chaves em todas as pesquisas realizadas na árvore.

Exemplo: inserir nodos A, S, E, R, C, H, I, N, G, X

```
typedef struct No *Apontador;
typedef struct No {
    Registro Reg[3];
    Apontador Ap[4];
    int NumReg;
} No;
```

- Inserir(registro r , no corrente p)

- Percorre a árvore, dividindo nos-3 e inserindo o novo registro na folha

1. se árvore vazia

```
criaNo( r );
```

2. se p é um no-3, divide, jogando o registro do meio "para cima"

```
cria no com Reg[0]
    p1 = criaNo( Reg[0] );
    p1->Ap[0] = p->Ap[0];
    p1->Ap[1] = p->Ap[1];

cria no com Reg[2]
    p2 = criaNo( p->Reg[2] );
    p2->Ap[0] = p->Ap[2];
    p2->Ap[1] = p->Ap[3];

se no dividido for a raiz
    novaRaiz = criaNo( Reg[1] )
    novaRaiz->Ap[0] = p1;
    novaRaiz->Ap[1] = p2;
}
senão insere Reg[1] no pai
    procura a posição pos de Reg[1] no pai
    desloca registros [pos, NumReg] em uma posição
    insere Reg[1] na posição pos
    pai->Ap[pos] = p1;
    pai->Ap[pos+1] = p2;
    pai->NumReg++;
```

3. continua percorrendo até achar uma folha da árvore

```
se p não for folha
    para cada registro r em p
```

```
se( r.Chave == p->Reg[i].Chave ) /* chave já existe */
    ERRO;
senão se( p->Reg[i].Chave > r.Chave ){
    Insere( r, p->Ap[i] );

Insere( r, p->Ap[q->NumReg])

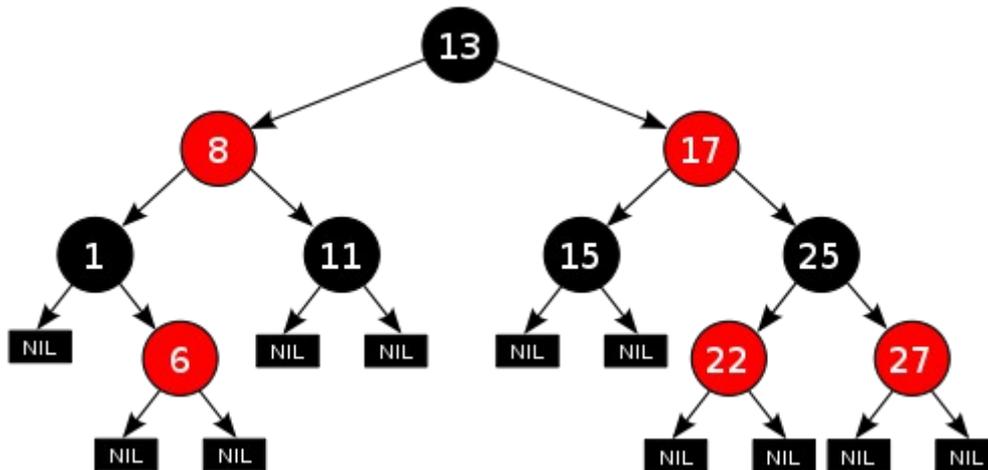
se p for folha
procura posição pos em p para inserir r
desloca registros nas posições [pos, NumReg]
insere registro r na posição r
q->NumReg++;
```

Árvore Rubro-Negra

Cap. 14 de Cormen&Leiserson&Rivest

<http://www.youtube.com/watch?v=DVpLMeGG-Qs> (INGLÊS, definição, inserção, prova da altura)

<http://www.ic.unicamp.br/~zanoni/mo637/aulas/arvoresRubroNegras.pdf>



Definição:

Em uma arv. Rubro-negra:

1. todo nodo ou é preto ou é vermelho
2. a raiz é preta.
3. todo nodo externo (NIL) é preto
4. se um nodo é vermelho seus dois filhos são pretos (não podem existir dois nodos vermelhos consecutivos em um caminho)
5. todo caminho de um nodo até um nodo externo contem o mesmo número de nodos pretos

Coloração:

A cada iteração as propriedades da arv. RN são violadas se:

1. a raiz for vermelha, neste caso é só pintar a raiz de preto (ultima linha do código); ou
2. porque há dois nodos vermelhos consecutivos (a altura preta não é alterada porque o novo nodo é sempre pintado de vermelho) neste caso, "jogar o problema para cima", mantendo como invariante a altura (de nodos pretos) nas subárvores.

- o "problema" continua enquanto o nodo corrente for vermelho

Caso 1: o tio é vermelho: neste caso, "descer" a cor preta para as duas sub-árvores: pintar o tio e o pai do nodo corrente de preto, e para manter a invariante, pintar o avô de vermelho.

Caso 3: (esq-esq): o tio é preto e o nodo corrente é filho esquerdo do pai, que é filho esquerdo do avô: pinta o avô de vermelho, o pai de preto e faz a rotação a direita

Caso 2: (esq-dir): o tio é preto e o nodo corrente é filho direito do pai, que é filho esquerdo do avô: transforma no Caso 2, fazendo uma rotação a esquerda do pai do nodo corrente.

- o algoritmo assume que a raiz é sempre preta, de forma que se pai(b) é vermelho, pai(pai(n)) sempre existe.

- observe que em todos os casos pai(pai(n)) é preto, já que pai(n) é vermelho

Inserção:

Considere a seguinte estrutura de dados para a estrutura do no da árvore, sendo que:

- a cor do NodoNulo é BLACK

- pai da raiz de uma árvore não vazia é o nodoNulo
- todos os nodos externos também são representados pelo mesmo nodoNulo.

```
enum tipoCor {RED, BLACK};
```

```
typedef struct no{
    Apontador esq, dir;
    Apontador pai;
    longInt chave;
    tipoCor cor;
} No;
```

```
RN-insere(raiz, k){
    novoNodo = criaNodo( k )
    x = raiz;
    paiX = nodoNulo;
    enquanto x <> nodoNulo
        paiX = x;
        se k < chave(x)
            x = esq(x)
        senao x = dir(x)

    pai(novoNodo) = paiX
    se paiX = nodoNulo
        raiz = novoNodo
    senao se k < chave(paiX)
        esq(paiX) = novoNodo
    senao
        dir(paiX) = novoNodo
    cor(novoNodo) = RED
    arrumaArvRN( raiz, novoNodo )
}
```

```
arrumaArvRN( raiz, p ){
    enquanto cor(pai(p)) = RED
        se pai(p) == esq(pai(pai(p))) { /* insercao na subarv.esq */
            tio = dir(pai(pai(p)))
            se cor(tio) == RED { /* cor a dir. do avo é vermelho */
                cor(pai(p)) = BLACK /* Caso 1 */
                cor(tio) = BLACK
                cor(pai(pai(p))) = RED
                p = pai(pai(p))
            }
            senao { /* cor a dir. do avo é preto */
                se p == dir(pai(p)) { /* desbal. na subarv.dir do filho esq
                */
                    p = pai(p) /* Caso 2: esq-dir */
                    rotEsq(p)
                }
                cor(pai(p)) = BLACK /* Caso 3 esq-esq*/
                cor(pai(pai(p))) = RED
                rotDir( pai(pai(p) )
            }
            senao {
                /* insercao na subarv. direita -- idem trocando dir <-> esq
                */
            }
            cor(raiz) = BLACK
        }
}
```

Custo e Altura:

insereArvBin - $O(\log n) \rightarrow$ while é executado no Caso 1 no máximo $\log(n)$ vezes, portanto, custo total $O(\log n)$
Altura $\rightarrow 2\lg(n + 1)$

Remoção em Arv. Rubro-Negra:

Lema:

A altura de uma arv. RN com n nodos tem altura de no máximo $2\log(n+1)$.

Prova:

Seja x um nodo. Representamos por $hp(x)$ a altura "preta" de x ; ou seja, a quantidade de nodos pretos a partir de x (sem incluir x) até um nodo externo.

Primeiro mostramos que a quantidade de nodos internos em uma subárvore de x é no mínimo $2^{\{hp(x)\}} - 1$ por indução na altura(h) de x .

Se $h=0$, x é um nodo externo e $bh(x)=0: 2^{\{0\}} - 1 = 0$.

Se $h>0$, x não é um nodo externo e tem 2 filhos com alturas menores que x .

As alturas pretas dos filhos de x podem ser $hp(x)-1$ ou $hp(x)$, dependendo do filho ser um nodo preto ou vermelho, respectivamente. Como a altura das subarv. é menor que a altura de x , pela hipótese da indução a quantidade de nodos internos da subarv. com raiz em x é pelo menos

$$(2^{\{hp(x)-1\}} - 1) + (2^{\{hp(x)-1\}} - 1) + 1$$

ou seja, pelo menos

$$2 \cdot 2^{\{hp(x)\}} - 2 + 1 = 2^{\{hp(x)\}} - 1.$$

Para terminar a prova, observe que em uma arv. RN de altura h pelo menos metade dos nodos em um caminho da raiz até um nodo externo são pretos. Assim

$$hp(x) \geq h/2 \text{ e } n \geq 2^{\{h/2\}} - 1.$$

Movendo 1 e aplicando \log_2 em ambos os lados temos $\log(n+1) \geq \log(2^{\{h/2\}})$ ou seja

$$h \leq 2\log(n+1).$$

Consequência:

busca, inserção, remoção em arv. RN é $O(\log(n))$

Remoção de nodos pretos causam desbalanceamento de todos os seus ancestrais \implies um dos nodos pretos vira um "duplo preto"

Correção:

Tentar "jogar" o desbalanceamento para cima até que:

-seja encontrado um nodo vermelho

-encontre a raiz

-possa executar rotações e mudanças de cor que restaurem o balanceamento

```
remove-RN( raiz, nodoK ){ /* nodoK é o nodo que tem a chave K a ser
removida */
  se esq(nodoK) == nodoNulo ou dir(nodoK) == nodoNulo
    nodoRem = nodoK /* se nodoK tem 0 ou 1 filho, remove
nodoK */
  senão /* senão remove o sucessor */
    nodoRem = sucessor( nodoK ) /* neste caso o nodoRem não tem filho
esq */
  se esq( nodoRem ) <> nodoNulo
    filho = esq(nodoRem)
  senão
    filho = dir(nodoRem)
  pai(filho) = pai(nodoRem)
  se pai(nodoRem) == nodoNulo
```

```

    raiz = filho
senão se nodoRem == esq(pai(nodoRem))
    esq(pai(nodoRem)) = filho
senão
    dir(pai(nodoRem)) = filho
se nodoK <> nodoRem
    /* copia chave e dados do nodoRem para nodoK */
se cor(nodoRem) == BLACK
    arrumaRem-RN( raiz, filho )
}

arrumaRem-RN( raiz, p ){
    enquanto p <> raiz e cor(p) == BLACK
        se n == esquerda(pai(p)){ /* extra BLACK a esquerda */
            d = direita(pai(p))

            se cor(d) == RED{ /* Caso 1 */
                cor(d) = BLACK
                cor(pai(p)) = RED
                rotaçãoEsq( pai(p) )
                d = direita(pai(p))
            }
            se cor(esquerda(d)) == BLACK e cor(direita(d)) == BLACK{
                cor(d) = RED /* Caso 2 */
                p = pai(p)
            }
        }
        se esquerda(d)->cor == RED /* direita(d)->cor == RED */
            cor(d) = RED /* Caso 3 */
            cor(esquerda(d)) = BLACK
            rotaçãoDir( d )
            d = direita( pai(p) )
        }
        cor(d) = cor(pai(p)) /* Caso 4 */
        pai(p)->cor = BLACK
        cor(direita(d)) = BLACK
        rotaçãoEsq ( pai(p) )
        p = raiz;
    }
    se não{ /* extra BLACK a direita -- similar */
    }
    cor(p) = BLACK
}

```

Caso 1:

Se o irmão de p for vermelho, seus dois filhos são pretos. O objetivo do Caso 1 é transformar o irmão de p em preto (Casos 2, 3 ou 4). Para isso, troca-se a cor do irmão para preto, o pai para vermelho e faz uma rotação. Como os filhos do irmão são pretos, o novo irmão de p será preto.

Na árvore 2-3-4, este caso equivale ao pai de p ser um nodo do tipo-3. O Caso 1 corresponde a transformar uma representação deste tipo de nodo, com a chave de maior valor como raiz da subárvore na representação deste tipo de nodo na RB em outra representação com a chave de menor valor como raiz da subárvore; e vice-versa.

Caso 2:

Se o irmão direito é preto e seus dois filhos são pretos troca a cor do irmão par vermelho, isso já compensa o preto extra da subarv. esquerda.

Na arv. 2-3-4 este caso corresponde ao "merge" de nodos do tipo-2; ou seja, seu irmão é um nodo do tipo-2 e não tem chaves para emprestar.

Caso 4:

Se o irmão direito d é preto. Se o filho direito de d é vermelho transforma ele em preto para compensar o preto extra. Troca cores. Faz rotação a esquerda em pai(n)

Na arv. 2-3-4 este caso corresponde ao empréstimo de uma chave do irmão.

Caso 3:

Se o irmão direito d é preto. Se o filho esquerdo de d é vermelho, faz uma rotação para transformar este caso no Caso 4:

Troca as cores de w e esquerdo(w)

Rotação a direita de w

$w = \text{direita}(\text{pai}(n))$

Na arv. 2-3-4 este caso corresponde ao empréstimo de uma chave do irmão.

porém, o irmão na RB não está na representação dir-dir ou esq-esq. Portanto, é necessário fazer uma rotação para transforma-la no Caso 4.

Árvores B

Cap. 6 (Nivio) - Cap. 18 (Cormen)

<http://www.youtube.com/watch?v=qXfPA6xqVIQ> (definição)

<http://www.youtube.com/watch?v=ANZBJw3a944> (inserção, remoção) (Atenção: a definição de grau é diferente da que apresentada pela Carmem)

http://www.lcad.icmc.usp.br/~nonato/ED/B_arvore/btree.htm (segue a definição de grau da Carmem)

Motivação:

- Indexação em memória secundária
- Generalização de uma árvore 2-3-4

Definição:

É uma árvore n-ária. Em uma árvore B com grau mínimo m temos que:

1. cada nodo contém no **mínimo $m-1$** chaves (e m filhos - grau $\geq m$) e no **máximo $2m-1$** chaves ($2m$ filhos - grau $\leq 2m$), **exceto o nodo raiz**, que pode conter entre 1 e $2m-1$ chaves
2. todas os nodos folha aparecem no mesmo nível.

Altura:

$$h \leq \log_t((n+1)/2).$$

Implementação:

- cada nodo x mantém:
 - num[x] : quantidade de chaves em x
 - chave_1[x],... chave_{num[x]}[x] chaves em ordem não decrescente
 - folha[x]: verdadeiro se x é folha e falso, caso contrário
 - p_1[x],...p_{num[x]+1}[x] apontadores para os filhos

```
const t = 2;
typedef struct no_arvoreB arvoreB;

struct no_arvoreB {
    int num_chaves;
    char chaves[2*t-1];
    arvoreB *filhos[2*t];
    bool folha;
};
```

Busca:

- parecido com uma árvore binária, porém com nodos contendo entre $t-1$ e $2t-1$ chaves
- resultado: um par (x,i) , onde x é o endereço do nodo que contém a chave procurada k e i é a posição da chave dentro do nodo

```
Busca (x, k)
    i = 0
    enquanto (i <= num[x] e k > chave_i[x])
        i = i+1
    se i <= num[x] e k = chave_i[x]
        retorna (x, i)
    se folha[x]
        retorna NIL
    else
        le_disco(p_i[x])
```

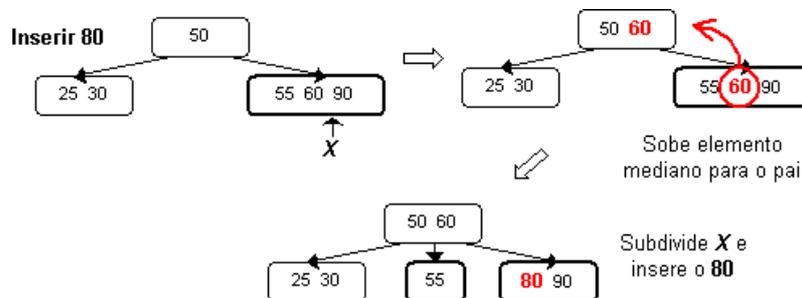
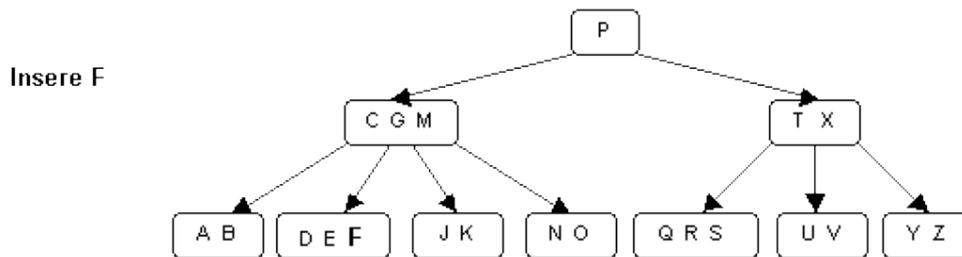
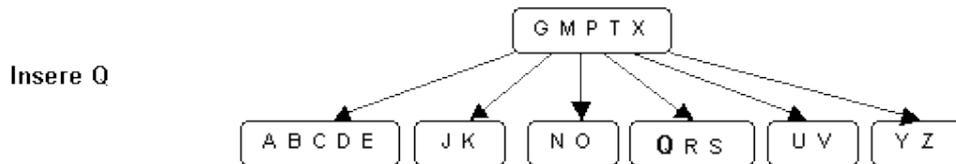
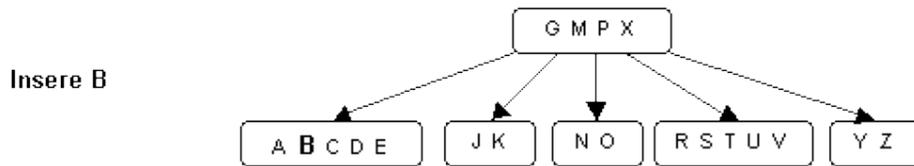
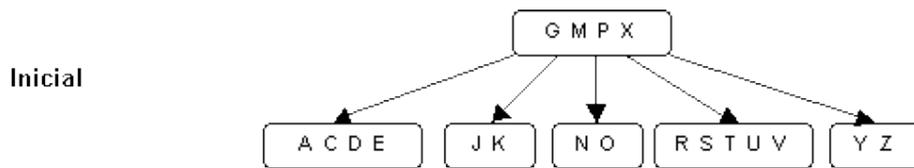
retorna Busca(p_i[x], k)

Número de acessos a disco: no pior caso $\log_t(n)$

Tempo de CPU: $O(t \log_t(n))$

Inserção:

- a ideia é a mesma da arv. 2-3-4: a medida que desce na árvore, nodos cheios são divididos para que seja sempre possível inserir novas chaves em seus filhos (com a possibilidade de uma chave "subir")



```

Inicializa( T )
  x = alocaNodo()
  folha[x] = TRUE
  num[x] = 0
  escreve_disco( x )
  raiz[T] = x
  
```

Acessos a disco e tempo CPU: $O(1)$

```

DivideNodo( pai, ind, f )
/* Divide nodo f que é filho de pai não cheio, sendo f o filho
"ind"
de pai */
  z = alocaNodo()
  folha[z] = folha[f]
  num[z] = t-1
  para j=1 a t-1
    chave_j[z]= chave_{j+t}[f]
  se f não é folha
    para j=1 a t
  
```

```

    p_j[z] = p_{j+t}[f]
num[f] = t-1
para j = num[pai]+1 downto ind+1
    p_{j+1}[pai] = p_{j}[pai]
p_{ind+1}[pai] = z
para j = num[pai] downto ind
    chave_{j+1}[pai] = chave_j[pai]
chave_ind[pai] = chave_t[f]
num[pai] = num[pai]+1
escreve_disco(f)
escreve_disco(p)
escreve_disco(z)

```

Acessos a Disco: $O(1)$

Tempo de CPU: $O(t)$

```

insereArvB( raiz, k )
    r = raiz
    se num[r] = 2t-1 /* raiz cheia */
        z = alocaNodo()
        raiz = z
        folha[z] = false
        num[z] = 0
        p_1[1] = raiz
        divideNodo( z, 1, r )
        insereNodoNaoCheio( z, k )
    senão
        insereNodoNaoCheio( r, k )

insereNodoNaoCheio( x, k ) /* insere chave k no nodo x */
    i = num[x]
    se folha[x]
        enquanto i >= 1 e k < chave_i[x]
            chave_{i+1}[x] = chave_i[x]
            i = i - 1
        chave_{i+1}[x] = k
        num[x] = num[x] + 1
        escreve_disco(x)
    senão
        enquanto i >= 1 e k < chave_i[x]
            i = i - 1
        i = i+1
        z = le_disco( p_i[x] )
        se num[z] = 2t-1
            divideNodo( x, i, z )
            se k > chave_i[x]
                i = i + 1
            inserenaoCheio( p_i[x], k )

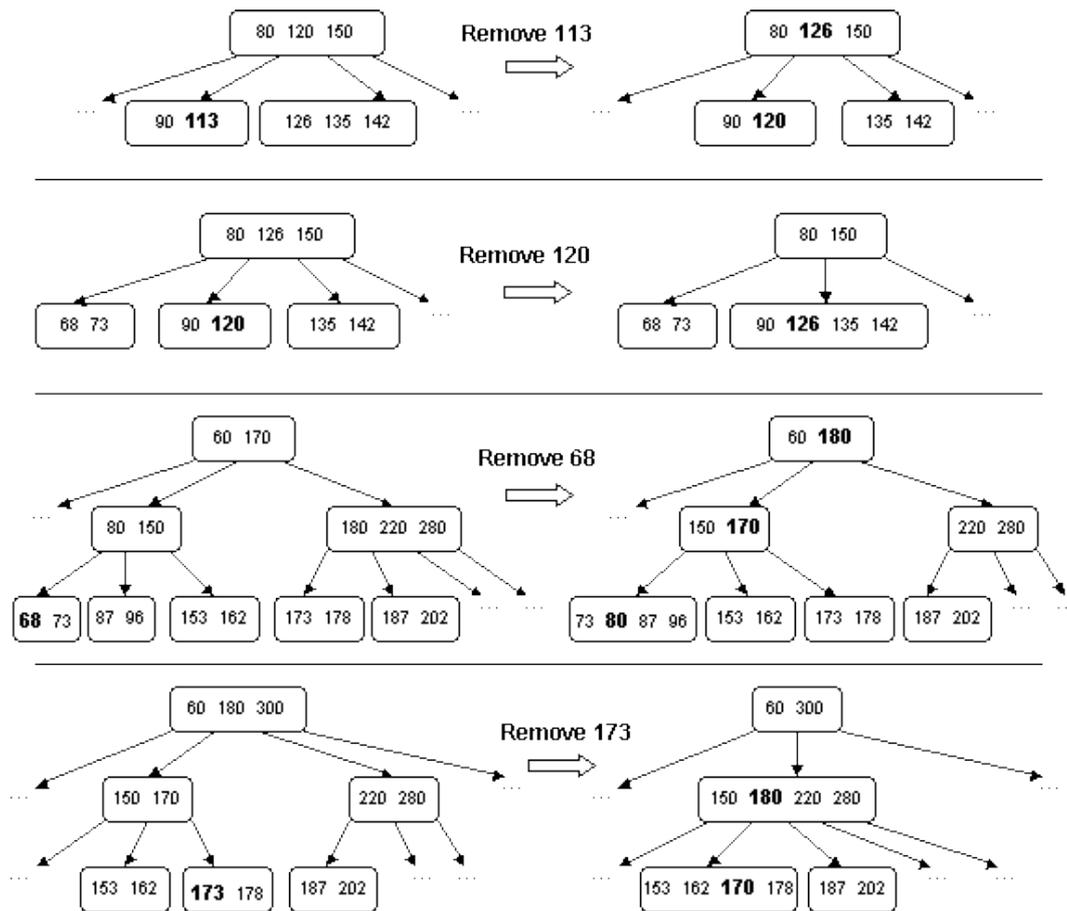
```

Acessos a Disco: $O(\log_t(n))$

Tempo de CPU: $O(t \log_t(n))$

Remoção em Árvores B:

- problema que pode acontecer: um nodo pode ficar com menos que $t-1$ chaves
- solução: a medida que faz a busca pelo nodo que contem a chave, garantir que todos os nodos no caminho tenham pelo menos t chaves (1 a mais que o minimo). Isso é garantido da seguinte forma: se o nodo a ser visitado tem $t-1$ chaves



```

buscaEmNodo( x, k )
    i = 1
    enquanto( i <= num(x) e k < chave[i](x) )
        i = i+1;
    retorna i

removeNoNodo( x, indK )
    para j = indK até num(x)-1
        chave[j](x) = chave[j+1](x)
    para j= indK+1 até num(x)
        p[j](x) = p[j+1](x)
    num(x) = num(x) - 1

remove( Apontador raiz, Apontador x, Chave k )
    indK = buscaEmNodo( x, k ) /* busca ind. de k ou de chave > k
    */
    esq = p[indK](x)
    se indK <= num(x)
        dir = p[indK+1](x)
    senão
        dir = NULL

    se indK <= num(x) e chave[indK](x) == k /* k é uma das chaves de
    x */
        se folha(x) /* remove k em nodo
        folha */
            removeNoNodo( x, indK )
        else /* remove k em nodo não folha */
            se (num(esq)) >= t /* filho esq. tem pelo menos t
            chaves*/
                predK = predecessor( x, k );

```

```

        remove( raiz, x, predK );
        chave[indK](x) = predK;

        senão se dir <> NULL and (num(dir) >= t
                                /* filho dir. tem pelo menos t
chaves*/
            succK = sucessor( x, k )
            remove( raiz, x, succK );
            chave[indK](x) = succK

        senão /* dois filhos tem t-1 chaves
*/
            p = merge( x, indK )
            se x == raiz
                free( raiz )
                raiz = p
            remove( raiz, p, k )

        senão /* k não está em x */
            se folha(x)
                retorna ERRO
            senão /* continua descendo na arv. */
                se num(esq) >= t
                    remove( raiz, esq, k )
                senão
                    se dir <> NULL and num(dir) >= t
                        /* empresta chave do irmao direito
*/
                        ...
                        remove( raiz, esq, k )
                    senão se indK > 1 e num(p[indK-1](x)) >= t
                        /* empresta do irmao esq */
                        ...
                        remove( raiz, esq, k )
                    senão
                        se dir == NULL
                            p = merge(x, indK-1)
                        senão
                            p = merge(x, indK)
                        se x == raiz
                            free( raiz )
                            raiz = p
                        remove( raiz, p, k )

merge( Apontador x, índice indK )
    esq = p[indK](x)
    dir = p[indK+1](x)
    num(esq) = num(esq) + 1 /* junta (esq + k + dir) em esq */
    chave[num(esq)](esq) = chave[indK](x);
    para i = 1 até num(dir)
        chave[num(esq)+i](esq) = chave[i](dir)
        p[num(esq)+i](esq) = p[i](dir)
    num(esq) = num(esq) + num(dir)
    p[num(esq)+1](esq) = p[num(dir)+1](dir)
    free( dir );

    para i = indK até num(x)-1 /* arruma chaves e apont. em x */
        chave[i](x) = chave[i+1](x)
    para i = indK+1 até num(x)
        p[i](x) = p[i+1](x)
    num(x) = num(x) - 1
    retorna esq;

```

Memória Secundária:

- conceito de prato, trilha, cilindro, cabeçote de leitura e gravação
- acesso é muito mais lento em mem. secundária que na mem. primária devido aos componentes mecânicos (rotação do disco e cabeçote)
- rotação: +- 7200 RPM --> 8.33 milissegundos para uma rotação
- acesso a memória em silício: +- 100 nanosegundos (5x mais rápido, dá para fazer 100.000 acessos à memória e durante a espera por 1 rotação do disco)
- este tempo não é constante porque da localização do dado na trilha e o posicionamento do cabeçote
- forma de amortização: transferência em páginas ao invés de itens individuais. Páginas em geral tem tamanho em múltiplo de 512 (2^9)
- capacidade de mem. secundária é em geral bem maior que a capacidade de mem. principal --> memória virtual
- memória virtual: baseada em uma função entre o espaço de endereçamento N (utilizado por um programa) e o espaço de memória M f: $N \rightarrow M$
- a memória principal é dividida em "Moldura de páginas", na qual cada moldura contém exatamente uma página
- mecanismo de paginação:
 1. determina qual a página que um programa está endereçando. O endereço é dividido da seguinte forma: se o espaço de endereçamento possui 24 bits, então a memória virtual tem tamanho 2^{24} . Se o tamanho da página é 512 (2^9) então nove bits são utilizados para endereçar o byte dentro de uma página e o restante para representar o número da página.
 2. carrega a página na moldura de páginas. Precisa de uma tabela de páginas (que mapeia o número da página à moldura na qual ela está carregada e também uma política para reposição de páginas (LRU-Least Recently Used, LFU-Least, Frequently Used, FIFO-First In First Out))
- o tamanho do nó coincide com o tamanho da página
- quantidade de chave tipicamente está entre 50 a 2000

Árvore B+

Cap. 6, 6.3 (Nivio)

Ideia:

Separar nodos de índice de nodos de dados

- nodos internos contem apenas índices
- todos os registros nas folhas (sem a necessidade de apontadores)
- os nodos folha são encadeados (para facilitar a busca ordenada de valores)
- pode ter um grau distinto para nodos índice e folha

Objetivo:

- acesso sequencial mais eficiente
- facilitar o acesso concorrente as dados

Exemplos:

- inserção
- remoção
- busca

Acesso Concorrente:

- podem ocorrer problemas se um processo estiver lendo a estrutura e outro inserindo uma nova chave que causa divisão de um nodo

- uma pagina é segura se não houver possibilidade de mudança na estrutura da árvore devido a inserção ou remoção na pagina

inserção: pagina é segura se $\#chaves < 2t-1$

remoção: pagina é segura de $\#chave > t-1$

Protocolo de bloqueio:

lock-R : bloqueio para leitura

lock-W: bloqueio exclusivo para escrita

Leitura:

1. lock-R(raiz)
2. read(raiz) e torne-a pagina corrente
3. enquanto pag. corrente não for folha
 - lock-R(descendente)
 - unlock(pag corrente)
 - read(descendente) e torne-a pagina corrente

Atualização:

1. lock-W(raiz)
2. read(raiz) e torne-a pagina corrente
3. enquanto pag. corrente não for folha
 - lock-W(descendente)
 - read(descendente) e torne-a paginal corrente
 - Se pag. corrente for segura
 - unlock(p) para todos os nodos p antecedentes que tenham sido bloqueados

Método de Acesso Sequencial Indexado (ISAM)

- parecido com o árvore B+, mas utiliza paginas de overflow
- há uma previsão inicial da quantidade de registros do arquivo, deixando cerca de 20% das paginas inicialmente livres
- vantagem: não ha' necessidade de bloqueio nas paginas de índice
- desvantagem: pode haver um "desequilíbrio" da quantidade de registros em cada intervalo

Heap

<http://www.youtube.com/watch?v=QdRL3XLYiVc> (definição, Heapsort, voz do Google)

<http://www.youtube.com/watch?v=9QXNFcrF4c> (INGLÊS, propriedades, árv. → array, parte 1)

<http://www.youtube.com/watch?v=DHhPg01rBGs> (INGLÊS, adição, remoção, parte 2)

<http://www.youtube.com/watch?v=8xJU2TZksWw> (INGLÊS, propriedades, construção, Heapfy)

É a representação *em forma de vetor* de uma árvore binária em ordem-heap.

- Lembrando: é uma árvore binária quase completa de altura d

Arv. binária na qual:

1. todas as folhas estão no nível d ou $d-1$
2. se um nó nd na árvore tem algum descendente direito no nível d (o máximo da árvore), então todos os descendentes esquerdos de nd que forem folhas estão também no nível d .

Numeração dos Nodos (Índice do Vetor):

$$\begin{aligned} \text{num}(\text{raiz}) &= 1 \\ \text{num}(n) &= \begin{array}{ll} 2 * \text{num}(np) & \text{se } n \text{ é filho esquerdo de } np \\ 2 * \text{num}(np) + 1 & \text{se } n \text{ é filho direito de } np \end{array} \end{aligned}$$

Assim, dado um heap A e um índice i :

$$\begin{aligned} \text{pai}(i) &= \text{chão}(i/2) \\ \text{esq}(i) &= i*2 \\ \text{dir}(i) &= i*2+1 \end{aligned}$$

$\text{tamHeap}(A)$: índice do maior elemento em A que está preenchido com elementos do heap
 $\text{tam}(A)$: tamanho do vetor

- arv. estritamente binária quase completa com n folhas tem $2n-1$ nós
- arv. binária quase completa (que não seja estritamente binária) tem $2n$ nós
- altura de uma arv.bin quase completa de n nos = $\text{floor}(\log_2(n))$

Propriedade da Heap:

max-heap: $A[\text{pai}(i)] \geq A[i] \implies$ o maior elemento é a raiz

min-heap: $A[\text{pai}(i)] \leq A[i] \implies$ o menor elemento é a raiz

Funções:

$\text{arrumaHeapDown}(A, i)$: supoe que as subarv. dir e esq do elemento i já satisfazem a propriedade max-heap, mas $A[i]$ pode ser menor que seus filhos (viola max-heap).

```
{
    e = esq(i); d = dir(i);
    se e < tamHeap(A) e e < d
        maior = d
    senão
        maior = e
    se A[maior] > A[i]
        troca(A[i], A[maior])
        arrumaHeap( maior )
}
```

Custo: $O(\log(n))$

```

arrumaHeapUp (A, i):
{
    enquanto i > 1 e A[i/2] < A[i]
        troca(A[i], A[i/2])
        i = i/2
    }
}

constróiMaxHeap( A ):
{ tamHeap( A ) = tam(A);
  para i = tamHeap(A) / 2 ate 1 em ordem decrescente
      arrumaHeapDown( A, i );
}

```

Observação: todos os elementos com índice maior que $\text{floor}(\text{tamHeap}(A))$ são folhas. Portanto a iteração só precisa tratar os elementos armazenados nos índices menores que este (nodos internos).

Custo: $n/2 * \log(n) = O(n \log(n))$

Heapsort:

```

heapSort (A)
{ constróiMaxHeap( A );
  para i = tam( A ) até 2 {
      troca( A[1], A[i];
      tamHeap( A ) = tamHeap( A ) - 1;
      arrumaHeapDown( A , 1 )
  }
}

```

Custo: $\text{constróiHeap}: O(n \log(n)) + n * \text{arrumaHeap} : n * O(\log(n))$

Total: $O(n \log(n))$

Embora o custo do heapsort seja o mesmo do quicksort, na prática o quicksort em geral é mais rápido. Mas uma das aplicações para o Heap é a implementação de uma lista de prioridades.

Lista de Propriedades :

(pode ser lista-max ou lista-min, aqui é considerado lista-max)

É uma estrutura para manter um conjunto de elementos S, cada um com um valor associado, chamado de chave. Deve prover as seguintes funções:

- $\text{insere}(S, x)$: insere o elemento x em S
- $\text{máximo}(S)$: retorna o maior elemento em S
- $\text{extraiMax}(S)$: remove e retorna o maior elemento de S

Exemplo de aplicação:

- Escalonamento de processos:
- Huffman (lista-min)

Implementação:

(representando o conjunto S em um Heap A)

```

máximo( A ){
    retorna A[1]
}

```

Custo: $O(1)$

```

extraiMax( A ){

```

```
    se tamHeap( A ) < 1 retorna erro;
    max = A[1]
    troca( A[1], A[tamHeap(A)]
    tamHeap(A) = tamHeap(A) - 1
    arrumaHeapDown( A, 1 );
    retorna max
}
```

Custo: $arrumaHeap = O(\log(n))$

```
insere( A, k ){
    tamHeap(A) = tamHeap(A) + 1;
    A[i] = k;
    arrumaHeapUp( A, tamHeap(A));
}
```

Custo: $O(\log(n))$

Árvores de Pesquisa Digitais

Cap. 15 (Sedgewick)

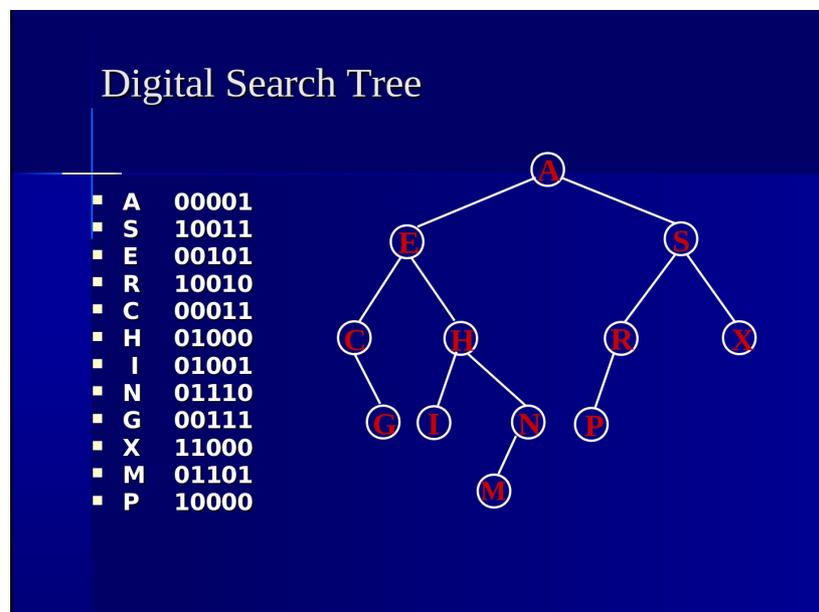
Para aplicações nas quais a busca é feita em apenas uma parte da chave. Ou seja, quando a chave pode ser decomposta em pedaços de tamanho fixo (bytes ou bits).

É necessário haver uma operação eficiente para obter a *i*-ésima parte da chave

Vantagens:

- custo do pior caso razoável, sem necessidade de balanceamento
- permite chaves de tamanho variável

Árvore de Pesquisa Digital Binária:



A arv. digital tem custo quase ótimo para aplicações com grande volume de chaves, com fácil implementação (+ fácil que avl, rubro-negra). O desempenho é muito bom desde que exista uma operação eficiente de acesso aos bits que compõe a chave.

- as chaves são representadas por sequência de bits
- cada nó pode ter dois filhos
- os bits são analisados do mais significativo para o menos significativo. Se for igual a zero, a chave é armazenada no filho esquerdo, caso contrário, no filho direito
- a árvore não mantém as chaves em ordem. A ordem somente é garantida para chaves no mesmo nível.
- a característica da árvore é que uma chave está armazenada em algum nodo no caminho determinado pela sua sequência de bits
- considerando chaves de tamanho fixo com w bits (e sem repetição de chaves), a quantidade de chaves N a ser inserida na árvore é $\leq 2^w$.
- a árvore digital é apropriada se a quantidade de chaves for significativamente menor que 2^w . Caso contrário, uma árvore de pesquisa AVL ou rubro-negra seria mais apropriada.
- para chaves de 32 bits, a arv. digital seria apropriada se o número de chaves for no máximo 100.000, e para chaves de 64 bits, a arv. digital pode ser apropriada para qualquer quantidade de chaves
- o tempo de busca é limitado pelo tamanho da chave
- o caminho mais longo tende a ser pequeno em diversas aplicações.

Implementação:

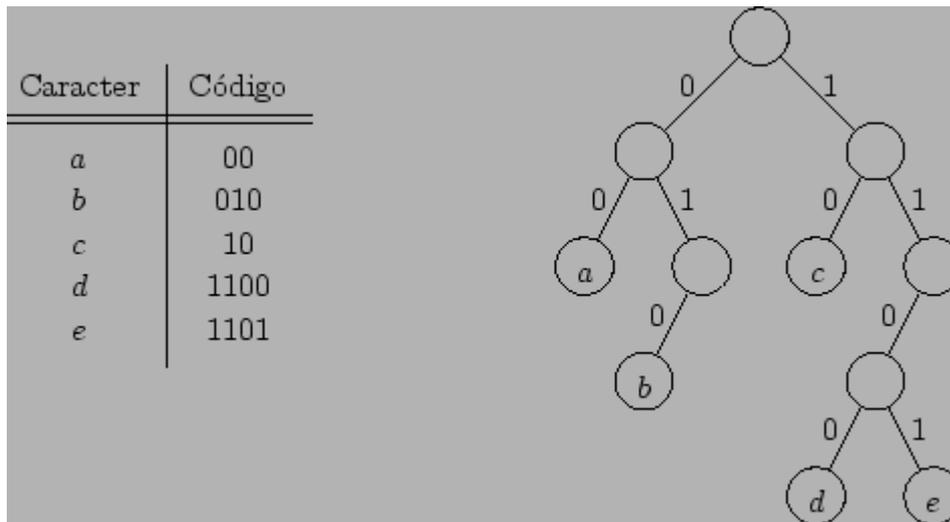
Estrutura de Dados: (Idêntica a árvore binária)

```
typedef long TipoChave;
typedef struct Registro {
    TipoChave Chave;
    /* outros componentes */
} Registro;
typedef struct No *Apontador;
typedef struct No {
    Registro Reg;
    Apontador Esq, Dir;
} No;

busca: busca(raiz, chave, 0) /* nodo, valor, ordem do bit */

busca( p, k, w )
    kNodo = p->reg.Chave;
    se( p == NULL) retorna NULL;
    se( kNodo == k ) retorna p->reg;
    se( digito(k, w) == 0 )
        retorna busca( esquerda(p), chave, w+1 )
    senão
        retorna busca( direita(p), chave, w+1 )
```

Trie



Similar as arv. de busca digitais, mas mantem as chaves em ordem e armazena chaves somente nas folhas.

Definição:

Uma trie é uma árvore binária que possui chaves associadas aos nodos folhas e definida recursivamente da seguinte forma:

- a) a trie para um conjunto vazio de chaves é apenas um apontador NULL;
- b) a trie para apenas uma chave é composta apenas por um nodo folha que contem esta chave
- c) a trie para um conjunto de chaves maior que um é composta por um nodo interno, sendo o filho esquerdo uma trie contendo chaves cujo bit inicial é 0 e o filho direito uma trie contendo chaves cujo bit inicial é 1. O primeiro bit é então removido para a construção das subárvores direita e esquerda.

Característica:

Existe uma única trie para um determinado conjunto de chaves. Ou seja, a estrutura da árvore independe da ordem de inserção.

Implementação:

A estrutura pode ser igual a arv. binária, mas pode ser melhorado para que os nodos internos contem somente apontadores, e as folhas apenas chaves.

```
busca(raiz, chave, 0)
-----
busca( p, k, w )
    se p == nodoNulo retorna nodoNulo;
    se p->esq == nodoNulo e p->dir == nodoNulo
        se p->reg.Chave == k
            retorna p->reg
        senão retorna nodoNulo;
    se digito(k, w) == 0
        retorna busca( p->esq), chave, w+1)
    senão
        retorna busca( p->dir, chave, w+1)

inicializa()
    return criaNodo( chaveNula )
```

chamada: insert(raiz, chave, 0)

insert(p, k, w)

```
kNodo = p->reg.Chave;
se p == nodoNulo retorna criaNodo( k );
se p é folha então retorna split( criaNodo(k), p, w );
se digito(k, w) == 0
    p->esq = insert( p->esq, chave, w+1 )
senão
    p->dir = insert( p->dir, chave, w+1 )
retorna p;
```

split(p1, p2, w)

```
n = criaNodo( itemNulo );
d1 = digito(p1, w);
d2 = digito(p2, w);
se d1 == d2
    se d1 == 0
        n->esq = split( p1, p2, w+1 )
    senão
        n->dir = split( p1, p2, w+1 )
senão
    se d1 == 0
        n->esq = p1; n->dir = p2;
    senão
        n->esq = p2; n->dir = p1;
retorna n;
```

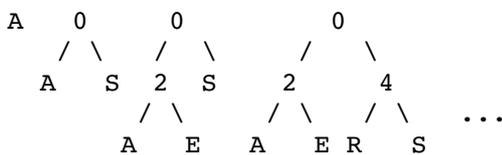
Árvore Patricia (Practical Algorithm to Retrieve Information coded in Alphanumeric)

Seção 15.3 (Sedgewick) – Seção 5.4.2 (Nivio)

Características:

- ao contrario das TRIES, não requer a criação de múltiplos nodos quando as chaves diferem apenas nos bits no final da chave.
- implementação com um único tipo de nodo (nas tries os nodos internos e folhas possuem estruturas distintas, já que as chaves estão armazenadas somente nas folhas)
- similarmente as árvores digitais, uma arv. Patricia para armazenar n chaves contem exatamente n nodos
- requer em media $\log(n)$ comparações de bits por busca e apenas uma busca da chave como um todo
- não depende do tamanho da chave como as tries e pode ser usada para chaves de tamanho variável

Exemplo da árvore Patricia "simplificada" (de acordo com a definição no livro do Ziviani):



Ideia:

- nodos armazenam qual o bit que o diferencia do pai
- nodos armazenam uma chave, da mesma forma que nas árvores digitais.

Os nodos externos, ao invés de serem somente NULL, podem apontar para o nodo na árvore que contem a chave com o prefixo determinado pelo caminho da raiz até o nodo externo.

Definição:

Uma árvore Patricia é uma árvore binária na qual cada nodo N possui uma chave e um índice de bit k , cujo valor é definido da seguinte forma:

- k é o primeiro bit no qual a chave difere da chave do seu pai. Seja k_p o índice bit do pai. Se o bit k_p da chave é igual a 0 então N é o filho esquerdo do pai; caso contrario, ele é o filho direito.

Um nodo externo pode corresponder a NULL ou ao endereço de um nodo A , que é igual a N ou um ancestral de N . Sejam n_1, \dots, n_q os nodos da raiz até A com índices bit b_1, \dots, b_q , respectivamente. A chave de A é a unica da árvore que satisfaz a seguinte condição: Para todo i em $[2, q]$:

- se n_i é filho esquerdo de n_{i-1} então o bit b_{i-1} da chave é igual a 0;
- se n_i é filho direito de n_{i-1} então o bit b_{i-1} da chave é igual a 1.

Exemplo:

```

bits de 0 a 4
A 00001
S 10011
E 00101
R 10010
C 00011
H 01000
I 01001
N 01110

```

G 00111
X 11000
M 01101
P 10000
L 01100

Implementação:

Estrutura de dados:

```
typedef long TipoChave;
typedef struct Registro {
    TipoChave chave;
    /* outros componentes */
} Registro;
typedef struct No *Apontador;
typedef struct No {
    Registro reg;
    Int bit;
    Apontador esq, dir;
} No;
```

Obs: para simplificar a implementação, a raiz da árvore é sempre um nodo R com "chave nula" (todos os bits iguais a 0, um valor não utilizado como valor de chave) e campo bit igual -1.
Caso a árvore contenha pelo menos uma chave, R->esq aponta para um nodo que contem uma chave.

Inicialização:

```
raiz = criaNodo( itemNulo, -1)
raiz->esq = raiz;
raiz->dir = raiz;
```

Busca:

Chamada: busca(raiz, chave)

Retorna endereço do registro com a chave ou nodoNulo

```
busca(raiz, k)
    p = buscaR( raiz->esq, k, -1 );
    se p->reg.Chave == k retorna p
    senão retorna nodoNulo

buscaR( p, k, bit )
    se p->bit <= bit retorna p;
    se digito( k, p->bit) == 0
        retorna buscaR( p->esq, k, p->bit )
    senão
        retorna buscaR( p->dir, k, p->bit )
```

Inserção:

Chamada: insere(raiz, reg)

```
insere( raiz, reg )
    k = reg.chave
    p = buscaR( raiz->esq, k, -1 )
    pk = p->chave
    se k == pk retorna; /* chave já está na árvore */
    i = 0; /* procura bit que diferencia k da chave de
p */
    enquanto digito(k, i)==digito(pk, i)
```

```

    i++;
    raiz->esq = insereR (raiz->esq, reg, i, raiz)

insereR( p, reg, bit, paiP )
se p->bit >= bit ou p->bit <= paiP->bit
    n = criaNodo( reg, bit )
    se digito(reg.chave, bit) == 0
        n->esq = n; n->dir = p;
    senão
        n->esq = p; n->dir = n;
    retorna n
se digito(reg.chave, bit) == 0
    p->esq = insereR( p->esq, reg, p->bit, p )
senão
    p->dir = insereR( p->dir, reg, p->bit, p )
retorna p

```

Obs: a inserção de um nodo com bit menor do que um já existente corresponde a inserção na trie no lugar de um filho "nulo" de um nodo interno que não foi criado na arv. Patricia. Se o bit for igual ao de um nodo existente, esta inserção corresponde na inserção na trie com "split" de uma folha.

Característica:

Todos os nodos externos abaixo de um determinado nodo n com bit de índice k tem como prefixo os mesmos k bits.

Assim, para obter as chaves ordenadas, basta imprimir as chaves dos nodos externos, percorrendo a árvore em-ordem.

Chamada: ordenado(raiz->esq, -1)

```

ordenado( p, bit )
se p == nodoNulo retorna;
se p->bit <= bit
    escreve p->reg.chave; retorna;
ordenado( p->esq, p->bit )
ordenado( p->dir, p->bit )

```

Custo:

Inserção: número médio de comparações = $\log(n)$
 número máximo de comparações = $2 * \log(n) \leq \text{sizeOf}(k)$

Arv. Patricia são especialmente indicadas para chaves grandes, pois evitam a comparação de todos os bits que a compõe.

Tries n-arias

Seção 15.4 (Sedgwick)

Generalização de tries, na qual chaves são codificadas em uma base qualquer, não necessariamente binária.

Uma trie n-aria possui chaves armazenadas nas folhas. Ela é def. rec. Da seguinte forma: uma trie para um conjunto vazio de chaves corresponde ao apontador nulo; uma trie com uma única chave corresponde a uma folha contendo esta chave; uma trie com cardinalidade maior que um é um nodo interno com apontadores referentes a trie com chaves começando com cada um dos dígitos possíveis, com este dígito desconsiderado na construção das subárvores.

- Ex1: números na base decimal com 5 dígitos

```
39646
39555      \   \   \ (2)      | | | | | | | |      44477   \ (5)   ....
21745                21745 23745   ..... \ (9)
23745                39646  39555
44477
```

Ex2: casa, bela, rua

Inserção: cara, número

Trie Existencial:

Não guarda informação sobre o registro, apenas se uma determinada chave esta presente ou não na trie (n-aria).

Uma trie existencial para um conjunto de chaves é def. rec. Da seguinte forma: uma trie para um conjunto vazio de chaves corresponde ao apontador nulo; uma trie para um conjunto não vazio de chaves corresponde a um nodo interno com apontadores para nodos filhos contendo valores para cada valor de digito possível. Nestas subárvores o primeiro digito é removido para sua construção, de forma recursiva.

Ex: casa, bela, rua

Inserção: cara, número

- assumimos que nenhuma chave é prefixo de outra. Isso pode ser garantido de duas formas distintas:

1. chaves de tamanho fixo
2. um "marcador" de final de chave: neste caso este marcador é um valor que não aparece em nenhuma chave e é considerado como um dos dígitos possíveis de serem encontrados na construção da trie.

Implementação:

```
typedef struct nodo *Apontador;
struct nodo {Apontador prox[R];}

static Apontador raiz;

void init() { raiz = null; }

Apontador criaNodo(){
    int i;
    Apontador x = malloc( sizeof *x );
    for( i = 0; i < R; i++) x->prox = null;
    return x;
}

Item buscaR( Apontador p, Chave v, int w ){
    int i = digito(v, w);
    if (p == null) return NULLItem;
    if (i == NULLdigit) return v;
    return buscaR( p->prox[i], v, w+1);
}

busca( Chave v ){ return buscaR( raiz, v, 0 ); }

Apontador insereR( Apontador p, Item item, int w ){
    Chave v = chave(item);
    int i = digito(v, w);
    if (p == null) h = criaNodo();
    if (i == NULLdigit) return p;
    p->prox[i] = insereR( p->prox[i], v, w+1);
    return p;
}

void insere(item){ raiz = insereR( raiz, item, 0); }
```

Características:

- árvore com altura baixa
- grande número de apontadores nulos

Consequências:

- baixo tempo de busca / inserção
- grande desperdício de espaço

Exemplo:

Éramos jovens e, como tal, sempre a buscar acelerar o tempo, indagando-nos sobre temas que os anos certamente se encarregariam de responder - mal sabíamos que, para entender certas coisas, bastava envelhecer.

Na forma de trie existencial, trie existencial abstrata e trie existencial ternaria

Trie Ternaria

- similar as arv. de busca binárias, mas que utiliza caracteres (dígitos) como chave do nodo
- cada nodo tem 3 apontadores: para chaves que começam com o digito menor que o corrente, iguais e maiores

Característica:

- tempo de busca: tamanho da chave
- número de links: no máximo 3 vezes o tamanho total do conjunto de chaves

Implementação:

```
typedef struct nodo *Apontador;
struct nodo {int d;
             Apontador dir, meio, esq;};
Apontador raiz;

void init() {raiz = NULL};

Apontador criaNodo( int d ){
    Apontador x = malloc( sizeof *x);
    x->d = d;
    x->dir = x->meio = x->esq = NULL;
    return x;
}

TipoChave buscaR( Apontador p, TipoChave k, int w ){
    int i = digito(k, w);
    se (p == NULL) return chaveNULLA;
    se (p == digitoNULO) return k;
    se (i < h->d) return buscaR( p->esq, k, w );
    senão se (i == h->d) return buscaR( p->meio, k, w+1 );
    senão buscaR( p->dir, k, w );
}

TipoChave busca( TipoChave k ){
    return buscaR( raiz, k, 0 );
}
```

Vantagens:

- adapta-se as irregularidades (desbalanceamento dos caracteres que aparecem) nas chaves de pesquisa
- não dependem da quantidade de dígitos (caracteres) possíveis
- quando a chave não está armazenada na árvore, a quantidade de dígitos comparados tende a ser pequena (mesmo quando a chave de busca é longa)
- ela é flexível:
 - . pode ser usada para obter chaves que casam com dígitos específicos da chave de pesquisa
 - . pode ser usada para obter chaves que diferem em no máximo uma posição da chave de pesquisa
- arv. Patricia oferece vantagens similares, mas comparando bits ao invés de bytes.

Exemplo:

Busca de todas as palavras que casam com "ca*", onde "*" pode ser qualquer carácter

```
char s[MAXTAM];
void casaR( Apontador p, char *k, int i ){
```

```

se p == NULL return;
se ((*k == '\0') && (p->d == '\0'))
{ s[i] = p->d; escreve s; }
se ((*k == '*' ) || (*k == p->d))
{ s[i] = p->d; casaR( p->meio, v+1, i+1 ); }
se ((*k == '*' ) || (*k < p->d))
  casaR( p->esq, k, i );
se ((*k == '*' ) || (*k > p->d))
  casaR( p->dir, k, i );
}

void casa( char *k )
{ casaR( raiz, k, 0 ); }

```

Melhoramentos possíveis na árvore:

1. como a maioria dos nodos próximos das folhas possuem apenas um único filho, utilizar a mesma ideia das arv. trie n-arias de manter a chave na folha no nível que a distingue das demais chaves. Isso torna a árvore *independente* do tamanho das chaves
2. utilizar a ideia das arv. Patricia de manter as chaves nos nodos internos, usando os apontadores "para cima".
3. usar um vetor com N elementos, um para cada dígito possível somente na raiz. -- busca similar a um catálogo telefônico. O objetivo é diminuir a altura da árvore e o número de comparações em uma busca.

Exemplo:

Se

- conjunto de chaves = 1 bilhão de chaves
 - conjunto de dígitos = 256
 - raiz com vetor de $256^2 = 65.536$
- #comparações de bytes é em torno de 10.

Compressão de Dados

Seção 17.3 (Cormem)

Motivação:

- Um texto contendo 100.000 caracteres em [a,f]:

	a	b	c	d	e	f
freq. (*1000)	45	13	12	16	9	5
cod. tam fixo	000	001	010	011	100	101
cod. tam var.	0	101	100	111	1101	1100

==> tamanho total com codificação fixa = $100.000 * 3 = 300.000$

==> tamanho total com codificação variável = $45000*1 + 13000*3 + 12000*3 + 16000*3 + 9000*4 + 5000*4 = 224.000$

Ganho de aprox. 25%.

Desafio:

- Geração da codificação de tamanho variável ótima.
--> codificação de Huffman

Exemplo:

cabaaed 100.0.101.0.0.1101.111
bebada

Custo de uma codificação:

somatório_{c no texto} (freq(c) * tam(c)), onde freq(c) é a frequência do carácter c no texto e tam(c) é o tamanho da codificação de c (em bits)

Codificação Ótima:

É dada pela representação na forma de uma árvore binária *completa*. Para um conjunto C de caracteres, a árvore tem |C| folhas, |C|-1 e nodos internos.

- para que o separador "." não seja necessário, a codificação deve ser uma codificação de prefixo. Ou seja, nenhum código pode ser prefixo de outro.

- Ideia de Huffman: códigos menores são gerados para caracteres que aparecem no texto com maior frequência.

--> geração de uma trie, na qual as chaves são os caracteres

Implementação:

Estrutura de dados:

```
typedef struct No *Apontador;
typedef struct No {
    Char k;          /* carácter */
    Int f;          /* frequência */
    Apontador Esq, Dir;
} No;

 Huffman( C ) /* C é um conjunto de nodos contendo as chaves e
                frequências preenchidas */
```

```

n = |C|    /* tamanho do conjunto C *
Q = C     /* Q é uma fila de prioridades */
para i= 1 a n-1
    z = criaNodo();
    p1 = extraiMinimo( Q )
    p2 = extraiMinimo( Q )
    esq(z) = p1;  dir(z) = p2;
    z->f = p1->f + p2->f
    insere(Q, z)
retorna extraiMinimo( Q )

```

Codificação:

(arquivo texto T, com código Huffman na trie com raiz)

```

codifica( T, raiz )
l = inicializaLista();
geraVetorCod( raiz, v, l );
enquanto não for fim de arquivo( Tc ){
    c = ler( Tc );
    escreve( v[c] );
}

geraVetorCod( p, v, lista ){ /* gera um vetor indexado pelo
carácter */
    se p é folha { /* contendo a codificao */
        v[p->k] = "conteudo da lista"
    }
    senão {
        insereFim( lista, 0 );
        geraVetorCod( esq(p), v, lista );
        removeFim( lista );

        insereFim( lista, 1 );
        geraVetorCod( dir(p), v, lista );
        removeFim( lista );
    }
}

```

Decodificação:

(arquivo codificado Tc, raiz da trie)

```

decodifica( Tc, raiz )
enquanto não for fim de arquivo( Tc ){
    p = raiz;
    enquanto p não for folha {
        b = ler(Tc);
        se b == 0
            p = esquerda(p)
        senão
            p = direita (p)
    }
    escreve p->k
}

```

Exemplo:

Processo de construção para a palavra ABRACADABRA.

O tempo de execução da construção da codificação de Huffman depende do tempo para obter os caracteres em ordem ascendente de frequência e inserir novos elementos no conjunto. Utilizando uma lista ordenada este tempo é $O(n)$, e a função Huffman teria gastaria então $n-1 * n$ tempo, ou seja, $O(n^2)$.

Uma alternativa seria a utilização de uma árvore binária balanceada (como AVL ou RN). porém, no problema

em questão também há uma limitação no valor de n , que é previamente conhecido. Ou seja, há uma quantidade previamente sabida de caracteres que um arquivo pode conter. Assim, introduzimos mais uma estrutura de dados, chamada de heap para a implementação da lista de prioridades.

Uma árvore está *em ordem-maxheap* se a chave em cada nodo é maior ou igual às chaves armazenadas em todos os seus filhos.

Hash

Cap. 12 (Cormen)

- suporte ao tipo dicionário (insert, busca e remove) -- note sem ordenação
- é uma generalização do tipo vetor, na qual o intervalo dos valores de chave é muito maior que a quantidade de valores que serão armazenados. Ex: chaves no intervalo [0,10.000], mas apenas 1000 elementos no vetor.

- endereçamento direto: para chave no intervalo [0,n], alocar um vetor de $n+1$ posições.

Problema: n pode ser muito grande

- abordagem:
 1. computar o valor de uma função de espalhamento (ou hash) no intervalo [0,m-1] -- $h(k)$
 2. armazenamento o elemento no elemento $h(k)$ do vetor

Problema: pode haver colisões, ou seja, mais de uma chave com o mesmo valor de $h(k)$. Paradoxo do aniversário: em um grupo de 23 ou + pessoas, existe uma chance de mais de 50% que duas pessoas façam aniversário no mesmo dia.

Exemplo: $M = m$
 $h = k \text{ mod } 7$

Chaves: {4, 7, 13, 8, 9, 2}
[4][0][6] [1][2][2]

Resolução de colisão por lista encadeada:
Constrói uma lista encadeada para cada endereço da tabela.

Custo de Busca:

Para n chaves:

- pior caso: $O(n)$ se a função h mapeia todas as chaves para o mesmo elemento do vetor
 - caso médio: $O(n/m)$ n/m é o fator de carga (número médio de elementos em cada posição do vetor)
- ==> para valores de m próximos de n: $O(1)$
- melhor caso: $O(1)$

Funções de Espalhamento:

Ideal:

- simples de ser computada
- para cada chave de entrada, qualquer uma das saídas possíveis é igualmente provável de ocorrer

Exemplo: para chaves uniformemente distribuídas no intervalo [0,1], $h(k) = \text{floor}(km)$

Para chaves não numéricas é preciso primeiro transformar a chave em inteiro:

Shift Folding: (deslocamento)

Somatório do código ASCII dos caracteres $K = \sum_{i=0}^{n-1} \text{Chave}[i]$

Limit Folding: (dobramento ou sanfona)

Inverte o código a cada carácter: $K = \sum_{i=0,2,4,6,..} \text{Chave}[i] + \sum_{i=1,3,5,7,..} \text{inverso}(\text{Chave}[i])$

Usando o código ASCII e a posição do carácter:

$$K = \sum_{i=0}^{n-1} \text{Chave}[i] * 128^{n-i-1}$$

Exemplo: pt = (112 * 128¹) + (116 * 128⁰) = 14452

Usando pesos:

$$K = \sum_{i=1}^n \text{Chave}[i] * \text{peso}[i], \text{ onde}$$

- Chave[i] é a representação ASCII do i-ésimo carácter da chave
- peso[i] é um inteiro randomicamente gerado.

Vantagem de usar pesos: conjuntos de pesos distintos geram funções de espalhamento distintos.

Exemplo: now: (110 * 128^{2*3}) + (111 * 128^{1*4}) + (119 * 128^{0*1})

Funções de Espalhamento:

Método da Divisão:

$$h(k) = k \text{ mod } m$$

- a escolha de m é importante. Em geral é escolhido um primo.
- motivo: no exemplo acima, se m for igual a 64 (2⁶), então o resultado da função h é simplesmente os 6 bits menos significativos de k, enquanto é melhor considerar a chave como um todo.
- bom valor para m: primos não muito próximos a potências de 2

Ex: n=2000, e queremos buscar uma chave examinando em media 3 elementos. Assim, 2000/3=666 e uma boa escolha pode ser 701, que é primo e não é prox. a uma potencia de 2.

Método da Multiplicação:

$$h(k) = \text{floor}(m * (kA \text{ mod } 1)),$$

onde A é uma constante entre 0 e 1 "mod 1" é a parte fracionaria de kA

- vantagem: o método não é muito dependente do valor de m
- pode ser implementado de forma eficiente quando m = 2^p, da seguinte forma: considere uma chave de w bits e um valor s no intervalo (0, 2^w), tal que A = s / 2^w. Assim, primeiro obtêm-se k*s, que é um valor de 2w bits (r1,r0). Como m=2^p, o valor de h(k) corresponde aos p bits mais significativos de r0.

Exemplo:

A = 0.6180339887 ("razao de ouro", (sqrt(5)-1)/2) sugerido por Knuth

p = 14

m = 2¹⁴ = 16384

w = 32

k = 123456

Procura-se um valor de A, ou seja, uma fração da forma s/2³² que seja próxima de (sqrt(5)-1/2) --> A=2.654.435.769 / 2³².

Assim, k*s = 123.456 * 2.654.435.769 = 327.706.022.297.664 = 76300 * 2³² + 17.612.864

Ou seja, r1 = 76300 e r0 = 17.612.864.

Os p (14) bits mais significativos de r0 resulta na valor de h(k) = 67.

Meio do Quadrado:

- Multiplica-se a chave por ela mesma e trunca-se as duas extremidades do resultado até o número de dígitos ser igual ao número de dígitos do endereço desejado (no intervalo da tabela hash).

Exemplo:

Endereçamento de 3 dígitos

Chave 134675 $\hat{+}$ quadrado = 18137355625

Trucando $\hat{+}$ 735

Chave 436987 $\hat{+}$ quadrado = 190957638169

Trucando $\hat{+}$ 763

Shift Folding: (deslocamento)

A mesma ideia da conversão de carácter para inteiro, mas dividindo o número de dígitos ou bits da chave para obter inteiros menores.

Ex: $k = 12345678$ para obter um índice de 3 dígitos da tabela hash:

```
 12 +
 345 +
 678
----
 925 <--- ind. da tabela
```

Limit Folding: (dobramento ou sanfona)

A mesma ideia da conversão, mas para obter índices de tamanho menor. Neste caso em geral não se leva em conta o "carry"

Ex: $k = 12345678$ para obter um índice de 3 dígitos

```
 21 +
 345 +
 876
---
 321 <--- ind. da tabela
```

Hashing universal:

- escolha de uma função hash randomicamente, que seja independente do valor da chave, em tempo de execução. Isso faz com que o sistema que está fornecendo as chaves não possa provocar o hash de chegar ao pior caso.

- o algoritmo pode ter comportamento distinto em cada execução

Exemplo (pesos para formação de chave numérica a partir de uma seq. de caracteres)

Ex: sabemos que o DDD e os 3 primeiros dígitos de um número telefônico não são distribuídos de forma uniforme: não servem para a função hash. Podemos supor que os 4 últimos dígitos de um número telefônico são distribuídos mais ou menos uniformemente, tornando-se uma boa opção. Assim, podemos dar peso 0 para os 3 primeiros dígitos.

$$-h_{\{a,b\}}(k) = ((ak+b) \bmod p) \bmod m, \text{ onde } p \text{ é primo, } a \text{ em } [0,p) \text{ e } b \text{ em } [1,p)$$

Tratamento de Colisão:

Lista encadeada:

Custo médio da busca sem sucesso:

$$\text{Custo} = 1/m \sum_{i=0}^{m-1} i \text{ (tamanho lista do elemento } i)$$

Endereçamento Aberto:

- usado quando a quantidade de registros a serem armazenados é previamente sabido \rightarrow escolhe-se $m > n$ e assim todas as chaves podem ser armazenadas na própria tabela

A função $h: U \times \{0, \dots, m-1\} \rightarrow \{0, \dots, m-1\}$

Assim, para achar a posição de armazenamento de uma chave é realizada uma busca nas posições $h(k,0)$, $h(k,1)$, $h(k,2)$ até achar uma que esteja vazia.

```
hash_insert(T, k) /* T é a tabela hash */
  i = 0
  repita
    j = h(k,i)
    se T[j] == nil então T[j] = k; retorna
    i = i+1
  até que i = m
  retorna "erro: tabela cheia"
```

Busca similar

Remoção: não pode colocar nil na posição, mas sim um outro valor "REMOVIDO" para que a posição possa ser usada novamente por uma inserção ou a busca continuar o processo até encontrar a chave procurada.

Hashing Linear:

$h(k,i) = (h'(k) + i) \bmod m$

Exemplo:

chaves = 12,21,14,5,19 $m=7$

Problema:

- agrupamento -- a medida que a tabela vai ficando cheia, uma nova chave tende a ocupar uma posição continua a uma já ocupada, piorando assim o tempo de pesquisa.
- consequência: o valor de $h(k,0)$ determina a sequência que será analisada

Custo da busca:

- pior caso $O(n)$
- melhor e caso médio $O(1)$

Hashing Duplo:

$h(k,i) = (h_1(k) + i \cdot h_2(k)) \bmod m$

Neste caso, a primeira posição investigada é $T[h_1(k)]$. As posições investigadas depois tem um deslocamento variável de $h_2(k)$ (modulo m). Assim, a sequência de posições investigadas depende duplamente da chave. Assim, para cada par de valores $(h_1(k), h_2(k))$, a sequência de posições do vetor investigada muda, gerando assim m^2 sequências distintas.

Ex: $m=13$

$h_1(k) = k \bmod 13$

$h_2(k) = 1 + (k \bmod 11)$

inserção de 14 na tabela:

[0]	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]
79		69	98	72						50		

- o método linear é mais simples e portanto melhor para tab. esparsas
- se n/m for próximo de 1: melhor o duplo para minimizar a quantidade de comparações em casos de colisão

Ordenação Externa

Seção 4,2 (Nivio)

Necessária quando a quantidade a ser ordenada não cabe na memória principal

Considerações:

- o custo para acessar um item é algumas ordens de grandeza maior que o os custos de processamento na memória interna. Assim, o custo de um algoritmo de ordenação externa considera apenas a quantidade de leituras e escritas em memória secundária, ignorando o custo de processamento em memória principal.

- podem existir restrições quanto ao acesso aos dados (sequencial / randômico)
- o desenvolvimento de algoritmos é muito dependente do estado atual da tecnologia

Estratégia Principal para Ordenação:

1. primeira passada sobre o arquivo quebrando em blocos do tamanho da memória interna disponível. Cada bloco é ordenado na memória interna.

2. os blocos ordenados são intercalados, fazendo varias passadas sobre o arquivo até que ele esteja completamente ordenado.

Objetivo:

Reduzir o número de passadas sobre o arquivo.

Entrada:

(considerando o arquivo armazenado em fita magnética)

- N registros para serem ordenados
- espaço em memória principal para armazenar M registros
- 2P dispositivos externos

Intercalação Balanceada de Vários Caminhos:

Exemplo: intercalação BALANCEADA (n=22)

Considerando M=3 e P=3 (intercalação de 3 caminhos)

Etapa 1: o arquivo é lido do dispositivo 0 de 3 em 3 (M) registros e armazenados em blocos de 3 nos dispositivos P a 2P-1

Resultado: N/M blocos de M registros ordenados

Etapa 2: intercalação dos blocos ordenados, escrevendo o resultado nos dispositivos 0 a P-1, repetindo até que todos os registros estejam ordenados.

Número de passos: $1 + \log_{\{P\}} (N/M)$

Exemplo: N=1.000.000.000 M=1.000.000 P=3 precisa de apenas 9 passos

Seleção por Substituição:

Objetivo:

Obtenção de sequencias maiores que M no primeiro passo utilizando uma lista de prioridades.

Ideia:

Retira-se o menor elemento dentre os M, e insere o próximo elemento x. Se x for menor que o ultimo elemento retirado, ele é marcado como maior que todos os demais para iniciar uma nova sequencia.

==> segundo Knuth, para números randômicos, o tamanho da sequencia gerada é em media igual a 2M.

Exemplo com heap size = 3

```
ent 1 2 3 ordenado
e i n t i
r n e* t n
c t e* c* t
a a* e* c* a*
l c* e* l* c*
a e* a l* e*
c l* a c l*
a a a c a
o a c c a
b b o c b
a c o a* c
l l o a* l
a o a* a* o
n a* n* a* a*
c a* n* c* a*
e c* n* e* c*
a e* n* a e*
d n* d a n*
a a d a a
  a d a
    d d
```

O heap pode também ser utilizado para fazer as intercalações, mas só é vantajoso quando a quantidade de blocos gerados na primeira fase for grande (p. ex. ≥ 8). Neste caso, é necessário $\log_2(8)$ comparações para obter o menor elemento.

Exemplo:

entradas: int cer aal

```
ent 1 2 3 sai
  a c i a
a  a c i a
l  c l i c
e  e l i e
r  i l r i
n  l n r l
  n r n
t  r t r
  t t
```