

---

# Paradigmas de Projeto de Algoritmos\*

---

Última alteração: 10 de Outubro de 2006

---

\*Transparências elaboradas por Charles Ornelas, Leonardo Rocha, Leonardo Mata e Nivio Ziviani

---

# Paradigmas de Projeto de Algoritmos

---

- indução,
- recursividade,
- algoritmos tentativa e erro,
- divisão e conquista,
- balanceamento,
- programação dinâmica,
- algoritmos gulosos,
- algoritmos aproximados.

---

## Indução Matemática

---

- É útil para provar asserções sobre a correção e a eficiência de algoritmos.
- Consiste em inferir uma lei geral a partir de instâncias particulares.
- Seja  $T$  um teorema que tenha como parâmetro um número natural  $n$ . Para provar que  $T$  é válido para todos os valores de  $n$ , basta provarmos que:
  1.  $T$  é válido para  $n = 1$ ;
  2. Para todo  $n > 1$ , se  $T$  é válido para  $n - 1$ , então  $T$  é válido para  $n$ .
- A condição 1 é chamada de **passo base**.
- Provar a condição 2 é geralmente mais fácil que provar o teorema diretamente, uma vez que podemos usar a asserção de que  $T$  é válido para  $n - 1$ .
- Esta afirmativa é chamada de **hipótese de indução** ou **passo indutivo**
- As condições 1 e 2 implicam  $T$  válido para  $n = 2$ , o que junto com a condição 2 implica  $T$  também válido para  $n = 3$ , e assim por diante.

---

## Exemplo de Indução Matemática

---

$$S(n) = 1 + 2 + \cdots + n = n(n + 1)/2$$

- Para  $n = 1$  a asserção é verdadeira, pois  $S(1) = 1 = 1 \times (1 + 1)/2$  (passo base).
- Assumimos que a soma dos primeiros  $n$  números naturais  $S(n)$  é  $n(n + 1)/2$  (hipótese de indução).
- Pela definição de  $S(n)$  sabemos que  $S(n + 1) = S(n) + n + 1$ .
- Usando a hipótese de indução,  $S(n + 1) = n(n + 1)/2 + n + 1 = (n + 1)(n + 2)/2$ , que é exatamente o que queremos provar.

---

## Limite Superior de Equações de Recorrência

---

- A solução de uma equação de recorrência pode ser difícil de ser obtida.
- Nesses casos, pode ser mais fácil tentar adivinhar a solução ou chegar a um limite superior para a ordem de complexidade.
- Adivinhar a solução funciona bem quando estamos interessados apenas em um limite superior, ao invés da solução exata.
- Mostrar que um limite existe é mais fácil do que obter o limite.
- Ex.:  $T(2n) \leq 2T(n) + 2n - 1$ ,  $T(2) = 1$ , definida para valores de  $n$  que são potências de 2.
  - O objetivo é encontrar um limite superior na notação  $O$ , onde o lado direito da desigualdade representa o pior caso.

---

## Indução Matemática para Resolver Equação de Recorrência

---

$T(2n) \leq 2T(n) + 2n - 1$ ,  $T(2) = 1$ , definida para valores de  $n$  que são potências de 2.

- Procuramos  $f(n)$  tal que  $T(n) = O(f(n))$ , mas fazendo com que  $f(n)$  seja o mais próximo possível da solução real para  $T(n)$ .
- Vamos considerar o palpite  $f(n) = n^2$ .
- Queremos provar que  $T(n) = O(f(n))$  utilizando indução matemática em  $n$ .
- Passo base:  $T(2) = 1 \leq f(2) = 4$ .
- Passo de indução: provar que  $T(n) \leq f(n)$  implica  $T(2n) \leq f(2n)$ .

$$\begin{aligned} T(2n) &\leq 2T(n) + 2n - 1, \quad (\text{def. da recorrência}) \\ &\leq 2n^2 + 2n - 1, \quad (\text{hipótese de indução}) \\ &< (2n)^2, \end{aligned}$$

que é exatamente o que queremos provar.

Logo,  $T(n) = O(n^2)$ .

---

## Indução Matemática para Resolver Equação de Recorrência

---

- Vamos tentar um palpite menor,  $f(n) = cn$ , para alguma constante  $c$ .
- Queremos provar que  $T(n) \leq cn$  implica em  $T(2n) \leq c2n$ . Assim:

$$\begin{aligned} T(2n) &\leq 2T(n) + 2n - 1, \quad (\text{def. da recorrência}) \\ &\leq 2cn + 2n - 1, \quad (\text{hipótese de indução}) \\ &> c2n. \end{aligned}$$

- $cn$  cresce mais lentamente que  $T(n)$ , pois  $c2n = 2cn$  e não existe espaço para o valor  $2n - 1$ .
- Logo,  $T(n)$  está entre  $cn$  e  $n^2$ .

---

## Indução Matemática para Resolver Equação de Recorrência

---

- Vamos então tentar  $f(n) = n \log n$ .
- Passo base:  $T(2) < 2 \log 2$ .
- Passo de indução: vamos assumir que  $T(n) \leq n \log n$ .
- Queremos mostrar que  $T(2n) \leq 2n \log 2n$ .

Assim:

$$\begin{aligned} T(2n) &\leq 2T(n) + 2n - 1, && \text{(def. da recorrência)} \\ &\leq 2n \log n + 2n - 1, && \text{(hipótese de indução)} \\ &< 2n \log 2n, \end{aligned}$$

- A diferença entre as fórmulas agora é de apenas 1.
- De fato,  $T(n) = n \log n - n + 1$  é a solução exata de  $T(n) = 2T(n/2) + n - 1$ ,  $T(1) = 0$ , que descreve o comportamento do algoritmo de ordenação *Mergesort*.




---

## Recursividade

---

- Um método que chama a si mesmo, direta ou indiretamente, é dito **recursivo**.
- Recursividade permite descrever algoritmos de forma mais clara e concisa, especialmente problemas recursivos por natureza ou que utilizam estruturas recursivas.
- Ex.: árvore binária de pesquisa:
  - Todos os registros com chaves menores estão na subárvore esquerda;
  - Todos os registros com chaves maiores estão na subárvore direita.



```
package cap2;  
public class ArvoreBinaria {  
    private static class No {  
        Object reg;  
        No esq, dir;  
    }  
    private No raiz;  
}
```

---

## Recursividade

---

- Algoritmo para percorrer todos os registros em ordem de **caminhamento central**:
  1. caminha na subárvore esquerda na ordem central;
  2. visita a raiz;
  3. caminha na subárvore direita na ordem central.
- No caminhamento central, os nós são visitados em ordem lexicográfica das chaves.

```
private void central (No p) {  
    if (p != null) {  
        central (p.esq);  
        System.out.println (p.reg.toString());  
        central (p.dir);  
    }  
}
```

---

## Implementação de Recursividade

---

- Usa-se uma **pilha** para armazenar os dados usados em cada chamada de um procedimento que ainda não terminou.
- Todos os dados não globais vão para a pilha, registrando o estado corrente da computação.
- Quando uma ativação anterior prossegue, os dados da pilha são recuperados.
- No caso do caminharmento central:
  - para cada chamada recursiva, o valor de  $p$  e o endereço de retorno da chamada recursiva são armazenados na pilha.
  - Quando encontra  $p=\text{null}$  o procedimento retorna para quem chamou utilizando o endereço de retorno que está no topo da pilha.

---

## Problema de Terminação em Procedimentos Recursivos

---

- Procedimentos recursivos introduzem a possibilidade de iterações que podem não terminar: existe a necessidade de considerar o problema de **terminação**.
- É fundamental que a chamada recursiva a um procedimento  $P$  esteja sujeita a uma condição  $B$ , a qual se torna não-satisfeita em algum momento da computação.
- Esquema para procedimentos recursivos: composição  $C$  de comandos  $S_i$  e  $P$ .  
$$P \equiv \mathbf{if } B \mathbf{ then } C[S_i, P]$$
- Para demonstrar que uma repetição termina, define-se uma função  $f(x)$ , sendo  $x$  o conjunto de variáveis do programa, tal que:
  1.  $f(x) \leq 0$  implica na condição de terminação;
  2.  $f(x)$  é decrementada a cada iteração.

---

## Problema de Terminação em Procedimentos Recursivos

---

- Uma forma simples de garantir terminação é associar um parâmetro  $n$  para  $P$  (no caso **por valor**) e chamar  $P$  recursivamente com  $n - 1$ .
- A substituição da condição  $B$  por  $n > 0$  garante terminação.

$P \equiv \mathbf{if } n > 0 \mathbf{ then } \mathcal{P}[S_i, P(n - 1)]$

- É necessário mostrar que o nível mais profundo de recursão é finito, e também possa ser mantido pequeno, pois cada ativação recursiva usa uma parcela de memória para acomodar as variáveis.

---

## Quando Não Usar Recursividade

---

- Nem todo problema de natureza recursiva deve ser resolvido com um algoritmo recursivo.
- Estes podem ser caracterizados pelo esquema  $P \equiv \mathbf{if } B \mathbf{ then } (S, P)$
- Tais programas são facilmente transformáveis em uma versão não recursiva  
 $P \equiv (x := x_0; \mathbf{while } B \mathbf{ do } S)$

---

## Exemplo de Quando Não Usar Recursividade

---

- Cálculo dos números de Fibonacci

$$f_0 = 0, f_1 = 1,$$

$$f_n = f_{n-1} + f_{n-2} \text{ para } n \geq 2$$

- Solução:  $f_n = \frac{1}{\sqrt{5}}[\Phi^n - (-\Phi)^{-n}]$ , onde  $\Phi = (1 + \sqrt{5})/2 \approx 1,618$  é a **razão de ouro**.
- O procedimento recursivo obtido diretamente da equação é o seguinte:

```
package cap2;
public class Fibonacci {
    public static int fibRec (int n) {
        if (n < 2) return n;
        else return (fibRec (n-1) + fibRec (n-2));
    }
}
```

- O programa é extremamente ineficiente porque recalcula o mesmo valor várias vezes.
- Neste caso, a complexidade de espaço para calcular  $f_n$  é  $O(\Phi^n)$ .
- Considerando que a complexidade de tempo  $f(n)$  é o número de adições,  $f(n) = O(\Phi^n)$ .

---

## Versão iterativa do Cálculo de Fibonacci

---

```

package cap2;
public class Fibonacci {
    public static int fibIter (int n) {
        int i = 1, f = 0;
        for (int k = 1; k <= n; k++) {
            f = i + f;
            i = f - i;
        }
        return f;
    }
}

```

- O programa tem complexidade de tempo  $O(n)$  e complexidade de espaço  $O(1)$ .
- Devemos evitar uso de recursividade quando existe uma solução óbvia por iteração.
- Comparação versões recursiva e iterativa:

$n$	10	20	30	50	100
<i>fibRec</i>	8 ms	1 s	2 min	21 dias	$10^9$ anos
<i>fibIter</i>	1/6 ms	1/3 ms	1/2 ms	3/4 ms	1,5 ms




---

## Algoritmos Tentativa e Erro (*Backtracking*)

---

- **Tentativa e erro:** decompor o processo em um número finito de subtarefas parciais que devem ser exploradas exaustivamente.
- O processo de tentativa gradualmente constrói e percorre uma árvore de subtarefas.



- Algoritmos tentativa e erro não seguem regra fixa de computação:
  - Passos em direção à solução final são tentados e registrados;
  - Caso esses passos tomados não levem à solução final, eles podem ser retirados e apagados do registro.
- Quando a pesquisa na árvore de soluções cresce rapidamente é necessário usar **algoritmos aproximados** ou **heurísticas** que não garantem a solução ótima mas são rápidos.

---

## Backtracking: Passeio do Cavalo

---

- Tabuleiro com  $n \times n$  posições: cavalo movimenta-se segundo as regras do xadrez.
- Problema: a partir de  $(x_0, y_0)$ , encontrar, se existir, um passeio do cavalo que visita todos os pontos do tabuleiro uma única vez.
- Tenta um próximo movimento:


```
void tenta () {  
    inicializa seleção de movimentos;  
    do {  
        seleciona próximo candidato ao movimento;  
        if (aceitável) {  
            registra movimento;  
            if (tabuleiro não está cheio) {  
                tenta novo movimento; // Chamada recursiva  
para tenta  
                if (não sucedido) apaga registro anterior;  
            }  
        }  
    } while (movimento não sucedido e não acabaram can-  
didatos a movimento);  
}
```

---

## Exemplo de Backtracking - Passeio do Cavalo

---

- O tabuleiro pode ser representado por uma matriz  $n \times n$ .
- A situação de cada posição pode ser representada por um inteiro para recordar o histórico das ocupações:
  - $t[x,y] = 0$ , campo  $\langle x, y \rangle$  não visitado,
  - $t[x,y] = i$ , campo  $\langle x, y \rangle$  visitado no  $i$ -ésimo movimento,  $1 \leq i \leq n^2$ .
- Regras do xadrez para os movimentos do cavalo:



---

## Implementação do Passeio do Cavalo

---

```
package cap2;
public class PasseioCavalo {
    private int n; // Tamanho do lado do tabuleiro
    private int a[], b[], t[][];

    public PasseioCavalo (int n) {
        this.n = n;
        this.t = new int[n][n];  this.a = new int[n];
        this.b = new int[n];
        a[0] = 2; a[1] = 1; a[2] = -1; a[3] = -2;
        b[0] = 1; b[1] = 2; b[2] = 2; b[3] = 1;
        a[4] = -2; a[5] = -1; a[6] = 1; a[7] = 2;
        b[4] = -1; b[5] = -2; b[6] = -2; b[7] = -1;
        for (int i = 0; i < n; i++)
            for (int j = 0; j < n; j++) t[i][j] = 0;
        t[0][0] = 1; // escolhemos uma casa do tabuleiro
    }
    // {-- Entra aqui os métodos tenta, imprimePasseio e main mos-
    trados a seguir --}
}
```

---

## Implementação do Passeio do Cavalo

---

```

public boolean tenta (int i, int x, int y) {
    int u, v, k; boolean q;
    k = -1; // inicializa seleção de movimentos
    do {
        k = k + 1; q = false;
        u = x + a[k]; v = y + b[k];
        /* Teste para verificar se os limites do tabuleiro
           serão respeitados. */
        if ((u >= 0) && (u <= 7) && (v >= 0) && (v <= 7))
            if (t[u][v] == 0) {
                t[u][v] = i;
                if (i < n * n) { // tabuleiro não está cheio
                    q = tenta (i+1, u, v); // tenta novo movimento
                    if (!q) t[u][v] = 0; // não sucedido apaga reg.
                    anterior
                }
                else q = true;
            }
    } while (!q && (k != 7)); // não há casas a visitar a par-
    tir de x,y
    return q;
}

```

---

## Implementação do Passeio do Cavalo

---

```
public void imprimePasseio () {  
    for (int i = 0; i < n; i++) {  
        for (int j = 0; j < n; j++)  
            System.out.print ("\t" +this.t[i][j]);  
        System.out.println ();  
    }  
}  
  
public static void main (String[] args) {  
    PasseioCavalo passeioCavalo = new PasseioCavalo (8);  
    boolean q = passeioCavalo.tenta (2, 0, 0);  
    if (q) passeioCavalo.imprimePasseio();  
    else System.out.println ("Sem solucao");  
}
```

---

## Divisão e Conquista

---

- Consiste em dividir o problema em partes menores, encontrar soluções para as partes, e combiná-las em uma solução global.
- Exemplo: encontrar o maior e o menor elemento de um vetor de inteiros,  $v[0..n - 1]$ ,  $n \geq 1$ ,. *Algoritmo na próxima página.*
- Cada chamada de  $maxMin_4$  atribui à  $maxMin[0]$  e  $maxMin[1]$  o maior e o menor elemento em  $v[linf]$ ,  $v[linf + 1], \dots, v[lsup]$ , respectivamente.

---

## Divisão e Conquista

---

```
package cap2;

public class MaxMin4 {
    public static int [] maxMin4(int v[], int linf , int lsup){
        int maxMin[] = new int[2];
        if (lsup – linf <= 1) {
            if (v[linf] < v[lsup]) {
                maxMin[0] = v[lsup]; maxMin[1] = v[linf];
            }
            else {
                maxMin[0] = v[linf]; maxMin[1] = v[lsup];
            }
        }
        else {
            int meio = (linf + lsup)/2;
            maxMin = maxMin4 (v, linf , meio);
            int max1 = maxMin[0], min1 = maxMin[1];
            maxMin = maxMin4 (v, meio + 1 , lsup);
            int max2 = maxMin[0], min2 = maxMin[1];
            if (max1 > max2) maxMin[0] = max1;
            else maxMin[0] = max2;
            if (min1 < min2) maxMin[1] = min1;
            else maxMin[1] = min2;
        }
        return maxMin;
    }
}
```



---

## Divisão e Conquista - Análise do Exemplo

---

- Seja  $T(n)$  uma função de complexidade tal que  $T(n)$  é o número de comparações entre os elementos de  $v$ , se  $v$  contiver  $n$  elementos.

$$T(n) = 1, \quad \text{para } n \leq 2,$$

$$T(n) = T(\lfloor n/2 \rfloor) + T(\lceil n/2 \rceil) + 2, \quad \text{para } n > 2.$$

- Quando  $n = 2^i$  para algum inteiro positivo  $i$ :

$$T(n) = 2T(n/2) + 2$$

$$2T(n/2) = 4T(n/4) + 2 \times 2$$

$$4T(n/4) = 8T(n/8) + 2 \times 2 \times 2$$

$$\vdots \quad \vdots$$

$$2^{i-2}T(n/2^{i-2}) = 2^{i-1}T(n/2^{i-1}) + 2^{i-1}$$

- Adicionando lado a lado, obtemos:

$$\begin{aligned} T(n) &= 2^{i-1}T(n/2^{i-1}) + \sum_{k=1}^{i-1} 2^k = \\ &= 2^{i-1}T(2) + 2^i - 2 = 2^{i-1} + 2^i - 2 = \frac{3n}{2} - 2. \end{aligned}$$

- Logo,  $T(n) = 3n/2 - 2$  para o melhor caso, o pior caso e o caso médio.

---

## Divisão e Conquista - Análise do Exemplo

---

- Conforme o Teorema da página 10 do livro, o algoritmo anterior é **ótimo**.
- Entretanto, ele pode ser pior do que os apresentados no Capítulo 1, pois, a cada chamada do método salva os valores de  $linf$ ,  $lsup$ ,  $maxMin[0]$  e  $maxMin[1]$ , além do endereço de retorno dessa chamada.
- Além disso, uma comparação adicional é necessária a cada chamada recursiva para verificar se  $lsup - linf \leq 1$ .
- $n$  deve ser menor do que a metade do maior inteiro que pode ser representado pelo compilador, para não provocar *overflow* na operação  $linf + lsup$ .

---

## Divisão e Conquista - Teorema Mestre

---

- Teorema Mestre: Sejam  $a \geq 1$  e  $b > 1$  constantes,  $f(n)$  uma função assintoticamente positiva e  $T(n)$  uma medida de complexidade definida sobre os inteiros. A solução da equação de recorrência:

$$T(n) = aT(n/b) + f(n),$$

para  $b$  uma potência de  $n$  é:

1.  $T(n) = \Theta(n^{\log_b a})$ , se  $f(n) = O(n^{\log_b a - \epsilon})$  para alguma constante  $\epsilon > 0$ ,
  2.  $T(n) = \Theta(n^{\log_b a} \log n)$ , se  $f(n) = \Theta(n^{\log_b a})$ ,
  3.  $T(n) = \Theta(f(n))$ , se  $f(n) = \Omega(n^{\log_b a + \epsilon})$  para alguma constante  $\epsilon > 0$ , e se  $af(n/b) \leq cf(n)$  para alguma constante  $c < 1$  e todo  $n$  a partir de um valor suficientemente grande.
- O problema é dividido em  $a$  subproblemas de tamanho  $n/b$  cada um sendo resolvidos recursivamente em tempo  $T(n/b)$  cada.
  - A função  $f(n)$  descreve o custo de dividir o problema em subproblemas e de combinar os resultados de cada subproblema.

---

## Divisão e Conquista - Teorema Mestre

---

- A prova desse teorema não precisa ser entendida para ele ser aplicado.
- Em cada um dos três casos a função  $f(n)$  é comparada com a função  $n^{\log_b a}$  e a solução de  $T(n)$  é determinada pela maior dessas duas funções.
  - No caso 1,  $f(n)$  tem de ser polinomialmente menor do que  $n^{\log_b a}$ .
  - No caso 2, se as duas funções são iguais, então
$$T(n) = \Theta(n^{\log_b a} \log n) = \Theta(f(n) \log n).$$
  - No caso 3,  $f(n)$  tem de ser polinomialmente maior do que  $n^{\log_b a}$  e, além disso, satisfazer a condição de que
$$af(n/b) \leq cf(n).$$
- Ele não pode ser aplicado nas aplicações que ficam entre os casos 1 e 2 (quando  $f(n)$  é menor do que  $n^{\log_b a}$ , mas não polinomialmente menor), entre os casos 2 e 3 (quando  $f(n)$  é maior do que  $n^{\log_b a}$ , mas não polinomialmente maior) ou quando a condição  $af(n/b) \leq cf(n)$  não é satisfeita.

---

## Divisão e Conquista - Exemplo do Uso do Teorema Mestre

---

- Considere a equação de recorrência:

$$T(n) = 4T(n/2) + n,$$

onde  $a = 4$ ,  $b = 2$ ,  $f(n) = n$  e  
 $n^{\log_b a} = n^{\log_2 4} = \Theta(n^2)$ .

- O caso 1 se aplica porque  
 $f(n) = O(n^{\log_b a - \epsilon}) = O(n)$ , onde  $\epsilon = 1$ , e a  
solução é  $T(n) = \Theta(n^2)$ .

---

## Balanceamento

---

- No projeto de algoritmos, é importante procurar sempre manter o **balanceamento** na subdivisão de um problema em partes menores.
- Divisão e conquista não é a única técnica em que balanceamento é útil.

Vamos considerar um exemplo de ordenação

- Seleciona o menor elemento do conjunto  $v[0..n - 1]$  e então troca este elemento com o primeiro elemento  $v[0]$ .
- Repete o processo com os  $n - 1$  elementos, resultando no segundo maior elemento, o qual é trocado com o segundo elemento  $v[1]$ .
- Repetindo para  $n - 2, n - 3, \dots, 2$  ordena a seqüência.

## **Balanceamento - Análise do Exemplo**

- O algoritmo leva à equação de recorrência:  
 $T(n) = T(n - 1) + n - 1$ ,  $T(1) = 0$ , para o número de comparações entre elementos.

- Substituindo:

$$\begin{aligned} T(n) &= T(n - 1) + n - 1 \\ T(n - 1) &= T(n - 2) + n - 2 \\ &\vdots \\ T(2) &= T(1) + 1 \end{aligned}$$

- Adicionando lado a lado, obtemos:

$$T(n) = T(1) + 1 + 2 + \dots + n - 1 = \frac{n(n-1)}{2}.$$

- Logo, o algoritmo é  $O(n^2)$ .
- Embora o algoritmo possa ser visto como uma aplicação recursiva de divisão e conquista, ele não é eficiente para valores grandes de  $n$ .
- Para obter eficiência assintótica é necessário **balanceamento**: dividir em dois subproblemas de tamanhos aproximadamente iguais, ao invés de um de tamanho 1 e o outro de tamanho  $n - 1$ .

---

## Exemplo de Balanceamento - Mergesort

---

- **Intercalação:** unir dois arquivos ordenados gerando um terceiro ordenado (*merge*).
- Colocar no terceiro arquivo o menor elemento entre os menores dos dois arquivos iniciais, desconsiderando este mesmo elemento nos passos posteriores.
- Este processo deve ser repetido até que todos os elementos dos arquivos de entrada sejam escolhidos.
- Algoritmo de ordenação (**Mergesort**):
  - dividir recursivamente o vetor a ser ordenado em dois, até obter  $n$  vetores de 1 único elemento.
  - Aplicar a intercalação tendo como entrada 2 vetores de um elemento, formando um vetor ordenado de dois elementos.
  - Repetir este processo formando vetores ordenados cada vez maiores até que todo o vetor esteja ordenado.



---

## Exemplo de Balanceamento - Implementação do Mergesort

---

```

package cap2;
public class Ordenacao {
    public static void mergeSort (int v[], int i, int j) {
        if (i < j) {
            int m = (i + j)/2;
            mergeSort (v, i, m); mergeSort (v, m + 1, j);
            merge (v, i, m, j); // Intercala v[i..m] e v[m+1..j] em
v[i..j]
        }
    }
}

```

- Considere  $n$  como sendo uma potência de 2.
- $merge(v, i, m, j)$ , recebe duas seqüências ordenadas  $v[i..m]$  e  $v[m + 1..j]$  e produz uma outra seqüência ordenada dos elementos de  $v[i..m]$  e  $v[m + 1..j]$ .
- Como  $v[i..m]$  e  $v[m + 1..j]$  estão ordenados,  $merge$  requer no máximo  $n - 1$  comparações.
- $merge$  seleciona repetidamente o menor dentre os menores elementos restantes em  $v[i..m]$  e  $v[m + 1..j]$ . Caso empate, retira de qualquer uma delas.

---

## Análise do Mergesort

---

- Na contagem de comparações, o comportamento do Mergesort pode ser representado por:

$$T(n) = 2T(n/2) + n - 1, \quad T(1) = 0$$

- No caso da equação acima temos:

$$\begin{aligned} T(n) &= 2T(n/2) + n - 1 \\ 2T(n/2) &= 2^2T(n/2^2) + 2\frac{n}{2} - 2 \times 1 \\ &\vdots \\ 2^{i-1}T(n/2^{i-1}) &= 2^iT(n/2^i) + 2^{i-1}\frac{n}{2^{i-1}} - 2^{i-1} \end{aligned}$$

- Adicionando lado a lado:

$$\begin{aligned} T(n) &= 2^iT(n/2^i) + \sum_{k=0}^{i-1} n - \sum_{k=0}^{i-1} 2^k \\ &= in - \frac{2^{i-1+1} - 1}{2 - 1} \\ &= n \log n - n + 1. \end{aligned}$$

- Logo, o algoritmo é  $O(n \log n)$ .
- Para valores grandes de  $n$ , o balanceamento levou a um resultado muito superior, saímos de  $O(n^2)$  para  $O(n \log n)$ .

---

## Programação Dinâmica

---

- Quando a soma dos tamanhos dos subproblemas é  $O(n)$  então é provável que o algoritmo recursivo tenha **complexidade polinomial**.
- Quando a divisão de um problema de tamanho  $n$  resulta em  $n$  subproblemas de tamanho  $n - 1$  então é provável que o algoritmo recursivo tenha **complexidade exponencial**.
- Nesse caso, a técnica de programação dinâmica pode levar a um algoritmo mais eficiente.
- A programação dinâmica calcula a solução para todos os subproblemas, partindo dos subproblemas menores para os maiores, armazenando os resultados em uma tabela.
- A vantagem é que uma vez que um subproblema é resolvido, a resposta é armazenada em uma tabela e nunca mais é recalculado.

---

## Programação Dinâmica - Exemplo

---

### Produto de $n$ matrizes

- $M = M_1 \times M_2 \times \cdots \times M_n$ , onde cada  $M_i$  é uma matriz com  $d_{i-1}$  linhas e  $d_i$  colunas.
- A ordem da multiplicação pode ter um efeito enorme no número total de operações de adição e multiplicação necessárias para obter  $M$ .
- Considere o produto de uma matriz  $p \times q$  por outra matriz  $q \times r$  cujo algoritmo requer  $O(pqr)$  operações.
- Considere o produto  $M = M_1[10, 20] \times M_2[20, 50] \times M_3[50, 1] \times M_4[1, 100]$ , onde as dimensões de cada matriz está mostrada entre colchetes.
- A avaliação de  $M$  na ordem  $M = M_1 \times (M_2 \times (M_3 \times M_4))$  requer 125.000 operações, enquanto na ordem  $M = (M_1 \times (M_2 \times M_3)) \times M_4$  requer apenas 2.200.

## Programação Dinâmica - Exemplo

- Tentar todas as ordens possíveis para minimizar o número de operações  $f(n)$  é exponencial em  $n$ , onde  $f(n) \geq 2^{n-2}$ .
- Usando programação dinâmica é possível obter um algoritmo  $O(n^3)$ .
- Seja  $m_{ij}$  menor custo para computar  $M_i \times M_{i+1} \times \dots \times M_j$ , para  $1 \leq i \leq j \leq n$ .
- Neste caso,

$$m_{ij} = \begin{cases} 0, & \text{se } i = j, \\ \text{Min}_{i \leq k < j} (m_{ik} + m_{k+1,j} + d_{i-1}d_kd_j), & \text{se } j > i. \end{cases}$$

- $m_{ik}$  representa o custo mínimo para calcular  $M' = M_i \times M_{i+1} \times \dots \times M_k$
- $m_{k+1,j}$  representa o custo mínimo para calcular  $M'' = M_{k+1} \times M_{k+2} \times \dots \times M_j$ .
- $d_{i-1}d_kd_j$  representa o custo de multiplicar  $M'[d_{i-1}, d_k]$  por  $M''[d_k, d_j]$ .
- $m_{ij}$ ,  $j > i$  representa o custo mínimo de todos os valores possíveis de  $k$  entre  $i$  e  $j - 1$ , da soma dos três termos.

---

## Programação Dinâmica - Exemplo

---

- O enfoque programação dinâmica calcula os valores de  $m_{ij}$  na ordem crescente das diferenças nos subscritos.
- O calculo inicia com  $m_{ii}$  para todo  $i$ , depois  $m_{i,i+1}$  para todo  $i$ , depois  $m_{i,i+2}$ , e assim sucessivamente.
- Desta forma, os valores  $m_{ik}$  e  $m_{k+1,j}$  estarão disponíveis no momento de calcular  $m_{ij}$ .
- Isto acontece porque  $j - i$  tem que ser estritamente maior do que ambos os valores de  $k - i$  e  $j - (k + 1)$  se  $k$  estiver no intervalo  $i \leq k < j$ .
- Programa para computar a ordem de multiplicação de  $n$  matrizes,  $M_1 \times M_2 \times \dots \times M_n$ , de forma a obter o menor número possível de operações.

---

## Programação Dinâmica - Implementação

---

```
package cap2;
import java.io.*;
public class AvaliaMultMatrizes {
    public static void main(String[] args) throws IOException {
        int n, maxn = Integer.parseInt (args[0]);
        int d[] = new int[maxn + 1];
        int m[][] = new int[maxn][maxn];
        BufferedReader in = new BufferedReader (
            new InputStreamReader (System.in));
        System.out.print ("Numero de matrizes n:");
        n = Integer.parseInt (in.readLine());
        System.out.println ("Dimensoes das matrizes:");
        for (int i = 0; i <= n; i++) {
            System.out.print (" d["+i+"] = ");
            d[i] = Integer.parseInt (in.readLine());
        }
        // Continua na próxima transparência...
```

---

## Programação Dinâmica - Continuação da Implementação

---

```
for (int i = 0; i < n; i++) m[i][i] = 0;
for (int h = 1; h < n; h++) {
    for (int i = 1; i <= n - h; i++) {
        int j = i + h;
        m[i-1][j-1] = Integer.MAX_VALUE;
        for (int k = i; k < j; k++) {
            int temp = m[i-1][k-1] + m[k][j-1] +
                + d[i-1] * d[k] * d[j];
            if (temp < m[i-1][j-1]) m[i-1][j-1] = temp;
        }
        System.out.print(" m[" + i + "][" + j + "] = " + m[i-1][j-1]);
    }
    System.out.println();
}
}
```



---

## Programação Dinâmica - Implementação

---

- A execução do programa obtém o custo mínimo para multiplicar as  $n$  matrizes, assumindo que são necessárias  $pqr$  operações para multiplicar uma matriz  $p \times q$  por outra matriz  $q \times r$ .
- A execução do programa para as quatro matrizes onde  $d_0, d_1, d_2, d_3, d_4$  são 10, 20, 50, 1, 100, resulta:

$m_{11} = 0$	$m_{22} = 0$	$m_{33} = 0$	$m_{44} = 0$
$m_{12} = 10.000$	$m_{23} = 1.000$	$m_{34} = 5.000$	
$m_{13} = 1.200$	$m_{24} = 3.000$		
$m_{14} = 2.200$			

---

## Programação Dinâmica - Princípio da Otimalidade

---

- A ordem de multiplicação pode ser obtida registrando o valor de  $k$  para cada entrada da tabela que resultou no mínimo.
- Essa solução eficiente está baseada no **princípio da otimalidade**:
  - em uma seqüência ótima de escolhas ou de decisões cada subseqüência deve também ser ótima.
- Cada subseqüência representa o custo mínimo, assim como  $m_{ij}$ ,  $j > i$ .
- Assim, todos os valores da tabela representam escolhas ótimas.
- O princípio da otimalidade não pode ser aplicado indiscriminadamente.
- Quando o princípio não se aplica é provável que não se possa resolver o problema com sucesso por meio de programação dinâmica.

---

## **Aplicação do Princípio da Otimalidade**

---

- Por exemplo, quando o problema utiliza recursos limitados, quando o total de recursos usados nas subinstâncias é maior do que os recursos disponíveis.
- Se o caminho mais curto entre Belo Horizonte e Curitiba passa por Campinas:
  - o caminho entre Belo Horizonte e Campinas também é o mais curto possível
  - assim como o caminho entre Campinas e Curitiba.
  - Logo, o princípio da otimalidade se aplica.

---

## Não Aplicação do Princípio da Otimalidade

---

- No problema de encontrar o caminho mais longo entre duas cidades:
  - Um caminho simples nunca visita uma mesma cidade duas vezes.
  - Se o caminho mais longo entre Belo Horizonte e Curitiba passa por Campinas, isso não significa que o caminho possa ser obtido tomando o caminho simples mais longo entre Belo Horizonte e Campinas e depois o caminho simples mais longo entre Campinas e Curitiba.
  - Quando os dois caminhos simples são ajuntados é pouco provável que o caminho resultante também seja simples.
  - Logo, o princípio da otimalidade não se aplica.

---

## Algoritmos Gulosos

---

- Resolve problemas de otimização.
- Exemplo: algoritmo para encontrar o caminho mais curto entre dois vértices de um grafo.
  - Escolhe a aresta que parece mais promissora em qualquer instante;
  - Independente do que possa acontecer mais tarde, nunca reconsidera a decisão.
- Não necessita avaliar alternativas, ou usar procedimentos sofisticados para desfazer decisões tomadas previamente.
- Problema geral: dado um conjunto  $C$ , determine um subconjunto  $S \subseteq C$  tal que:
  - $S$  satisfaz uma dada propriedade  $P$ , e
  - $S$  é mínimo (ou máximo) em relação a algum critério  $\alpha$ .
- O **algoritmo guloso** para resolver o problema geral consiste em um processo iterativo em que  $S$  é construído adicionando-se ao mesmo elementos de  $C$  um a um.

---

## Características dos Algoritmos Gulosos

---

- Para construir a solução ótima existe um conjunto ou lista de candidatos.
- São acumulados um conjunto de candidatos considerados e escolhidos, e o outro de candidatos considerados e rejeitados.
- Existe função que verifica se um conjunto particular de candidatos produz uma *solução* (sem considerar otimalidade no momento).
- Outra função verifica se um conjunto de candidatos é *viável* (também sem preocupar com a otimalidade).
- Uma *função de seleção* indica a qualquer momento quais dos candidatos restantes é o mais promissor.
- Uma *função objetivo* fornece o valor da solução encontrada, como o comprimento do caminho construído (não aparece de forma explícita no algoritmo guloso).

## Pseudo Código de Algoritmo Guloso

```

Conjunto guloso (Conjunto C) { /* C: conjunto de candidatos */
  S = ∅; /* S contém conjunto solução */
  while ((C ≠ ∅) && not solução(S)) {
    x = seleciona (C);
    C = C – x;
    if (viável (S + x)) S = S + x;
  }
  if (solução (S))
    return S else return ("Não existe solução");
}

```

- Inicialmente, o conjunto  $S$  de candidatos escolhidos está vazio.
- A cada passo, o melhor candidato restante ainda não tentado é considerado. O critério de escolha é ditado pela função de seleção.
- Se o conjunto aumentado de candidatos se torna inviável, o candidato é rejeitado. Senão, o candidato é adicionado ao conjunto  $S$  de candidatos escolhidos.
- A cada aumento de  $S$  verificamos se  $S$  constitui uma solução ótima.

---

## Características da Implementação de Algoritmos Gulosos

---

- Quando funciona corretamente, a primeira solução encontrada é sempre ótima.
- A função de seleção é geralmente relacionada com a função objetivo.
- Se o objetivo é:
  - maximizar  $\Rightarrow$  provavelmente escolherá o candidato restante que proporcione o maior ganho individual.
  - minimizar  $\Rightarrow$  então será escolhido o candidato restante de menor custo.
- O algoritmo nunca muda de idéia:
  - Uma vez que um candidato é escolhido e adicionado à solução ele lá permanece para sempre.
  - Uma vez que um candidato é excluído do conjunto solução, ele nunca mais é reconsiderado.



---

## Algoritmos Aproximados

---

- Problemas que somente possuem algoritmos exponenciais para resolvê-los são considerados “difíceis”.
- Problemas considerados intratáveis ou difíceis são muito comuns.
- Exemplo: **problema do caixeiro viajante** cuja complexidade de tempo é  $O(n!)$ .
- Diante de um problema difícil é comum remover a exigência de que o algoritmo tenha sempre que obter a solução ótima.
- Neste caso procuramos por algoritmos eficientes que não garantem obter a solução ótima, mas uma que seja a mais próxima possível da solução ótima.

---

## Tipos de Algoritmos Aproximados

---

- **Heurística:** é um algoritmo que pode produzir um bom resultado, ou até mesmo obter a solução ótima, mas pode também não produzir solução alguma ou uma solução que está distante da solução ótima.
- **Algoritmo aproximado:** é um algoritmo que gera **soluções aproximadas** dentro de um limite para a razão entre a solução ótima e a produzida pelo algoritmo aproximado (comportamento monitorado sob o ponto de vista da qualidade dos resultados).