

Paradigmas de Projeto de Algoritmos*

Última alteração: 2 de Setembro de 2010

*Transparências elaboradas por Charles Ornelas Almeida, Israel Guerra e Nivio Ziviani

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 . Provando que T é válido para todos os valores de n , provamos 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 (podemos usar a asserção de que T é válido para $n - 1$).
- Esta afirmativa é a **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.

Conteúdo do Capítulo

- 2.1 Indução
- 2.2 Recursividade
 - 2.2.1 Como Implementar Recursividade
 - 2.2.2 Quando Não Usar Recursividade
- 2.3 Algoritmos Tentativa e Erro
- 2.4 Divisão e Conquista
- 2.5 Balanceamento
- 2.6 Programação Dinâmica
- 2.7 Algoritmos Gulosos
- 2.8 Algoritmos Aproximados

Exemplo de Indução Matemática

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

- 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.
- Nestes casos, pode ser mais fácil tentar adivinhar a solução ou obter 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 certo 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

$T(2n) \leq 2T(n) + 2n - 1$, $T(2) = 1$ quando n é potência de 2.

- Procuramos $f(n)$ tal que $T(n) \leq O(f(n))$, 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 $T(n) = O(f(n))$ por 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:

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

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



```

type TipoRegistro = record
    Chave: integer;
end;
TipoApontador = ^TipoNo;
TipoNo = record Reg: TipoRegistro;
               Esq, Dir: TipoApontador;
end;
  
```

Implementação de Recursividade

- Usa 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 prosseguir, os dados da pilha são recuperados.
- No caso do caminhamento central:
 - para cada chamada recursiva, o valor de p e o endereço de retorno da chamada recursiva são armazenados na pilha.
 - Quando encontra $p=nil$ o procedimento retorna para quem chamou utilizando o endereço de retorno que está no topo da pilha.

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.
- Os nós são visitados em ordem lexicográfica das chaves.

```

procedure Central (p: TipoApontador);
begin
    if p <> nil
    then begin
        Central (p^.Esq);
        writeln (p^.Reg.Chave);
        Central (p^.Dir);
    end;
end;
  
```

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 : $P \equiv \text{if } B \text{ then } C[S_i, P]$
- 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.
 $P \equiv \text{if } n > 0 \text{ then } \mathcal{P}[S_i, P(n-1)]$
- 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 $P \equiv \text{if } B \text{ then } (S, P)$
- Tais programas são facilmente transformáveis em uma versão não recursiva $P \equiv (x := x_0; \text{while } B \text{ do } S)$

Exemplo de Quando Não Usar Recursividade (1)

- Cálculo dos **números de Fibonacci**
 $f_0 = 0, f_1 = 1,$
 $f_n = f_{n-1} + f_{n-2}$ 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:

```
function FibRec (n: integer): integer;
begin
  if n < 2
  then FibRec := n
  else FibRec := FibRec(n-1) + FibRec(n-2);
end;
```

Exemplo de Quando Não Usar Recursividade (2)

- É extremamente ineficiente porque recalcula o mesmo valor várias vezes.
- Considerando que a medida de complexidade de tempo $f(n)$ é o número de adições, então $f(n) = O(\Phi^n)$.
- A complexidade de espaço para calcular f_n é $O(n)$, pois apesar do número de chamadas ser $O(\Phi^n)$, o tamanho da pilha equivale a um caminho na árvore de recursividade, que é equivalente a altura da árvore, isto é, $O(\log \Phi^n) = O(n)$.

Versão iterativa do Cálculo de Fibonacci


```
function FibIter(n: integer): integer;
var i, k, F: integer;
begin
  i := 1; F := 0;
  for k := 1 to n do
    begin
      F := i + F;
      i := F - i;
    end;
  FibIter := F;
end;
```

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

n	20	30	50	100
Recursiva	1 seg	2 min	21 dias	10^9 anos
Iterativa	1/3 mseg	1/2 mseg	3/4 mseg	1,5 mseg

Algoritmos Tentativa e Erro (Backtracking) (1)

- **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 (Backtracking) (2)

- 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 rápidas.


Backtracking: Passeio do Cavalo

```
procedure Tenta;
begin
  inicializa selecao de movimentos;
  repeat
    seleciona proximo candidato ao movimento;
    if aceitavel
    then begin
      registra movimento;
      if tabuleiro nao esta cheio
      then begin
        tenta novo movimento; { Chamada recursiva para Tenta }
        if nao sucedido then apaga registro anterior;
      end;
    end;
  until (movimento bem sucedido) ou (acabaram candidatos a movimento);
end;
```

- Tabuleiro com $n \times n$ posições: cavalo se movimenta segundo 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.

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

```

procedure Tenta (i: integer; x,y: TipoIndice; var q: boolean);
var u, v, k: integer; q1: boolean;
begin k := 0; { inicializa selecao de movimentos }
repeat k := k + 1; q1 := false; u := x + a[k]; v := y + b[k];
  if (u in s) and (v in s)
  then if t[u,v] = 0
    then begin
      t[u,v] := i;
      if i < N * N { tabuleiro nao esta cheio }
      then begin
        Tenta (i+1, u, v, q1); { tenta novo movimento }
        if not q1 then t[u,v] := 0 { apaga reg. anterior }
      end
    else q1 := true;
    end;
until q1 or (k = 8); { nao ha mais casas a visitar a partir de x,y }
q := q1;
end;

```

Implementação do Passeio do Cavalo

```

program PasseioCavalo;
const N = 8; { Tamanho do lado do tabuleiro }
type TipoIndice = 1..N;
var i, j: integer; t: array[TipoIndice, TipoIndice] of integer;
    q: boolean; s: set of TipoIndice; a, b: array[TipoIndice] of integer;
  {— Entra aqui o procedimento Tenta mostrado a seguir —}
begin { programa principal }
  s := [1,2,3,4,5,6,7,8];
  a[1] := 2; a[2] := 1; a[3] := -1; a[4] := -2;
  b[1] := 1; b[2] := 2; b[3] := 2; b[4] := 1;
  a[5] := -2; a[6] := -1; a[7] := 1; a[8] := 2;
  b[5] := -1; b[6] := -2; b[7] := -2; b[8] := -1;
  for i:= 1 to N do for j:= 1 to N do t[i, j] := 0;
  t[1,1] := 1; { escolhemos uma casa do tabuleiro }
  Tenta (2, 1, 1, q);
  if q then for i:=1 to N do begin for j:=1 to N do write (t[i, j]:4); writeln; end
  else writeln('Sem solucao');
end.

```

Divisão e Conquista (1)

- 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, $A[1..n]$, $n \geq 1$.
- Cada chamada de MaxMin4 atribui à Max e Min o maior e o menor elemento em $A[\text{Lin}f]$, $A[\text{Lin}f + 1], \dots, A[\text{Lsup}]$, respectivamente.

Divisão e Conquista (2)

```

procedure MaxMin4 (Linf, Lsup: integer; var Max, Min: integer);
var Max1, Max2, Min1, Min2, Meio: integer;
begin
  if Lsup – Linf <= 1
  then if A[Linf] < A[Lsup]
    then begin Max := A[Lsup]; Min := A[Linf]; end
    else begin Max := A[Linf]; Min := A[Lsup]; end
  else begin
    Meio := (Linf + Lsup) div 2;
    MaxMin4 (Linf, Meio, Max1, Min1);
    MaxMin4 (Meio+1, Lsup, Max2, Min2);
    if Max1 > Max2 then Max := Max1 else Max := Max2;
    if Min1 < Min2 then Min := Min1 else Min := Min2;
  end;
end;

```

Divisão e Conquista - Análise do Exemplo

- Conforme mostrado no Capítulo 1, o algoritmo dado neste exemplo é **ótimo**.
- Entretanto, ele pode ser pior do que os apresentados no Capítulo 1, pois, a cada chamada recursiva, salva Linf, Lsup, Max e Min, além do endereço de retorno da chamada para o procedimento.
- Além disso, uma comparação adicional é necessária a cada chamada recursiva para verificar se $Lsup - Linf \leq 1$.
- $n + 1$ 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 - Análise do Exemplo

- Seja $f(n)$ o número de comparações entre os elementos de A .

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

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

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

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

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

$$\vdots$$

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

- Adicionando lado a lado, obtemos:

$$f(n) = 2^{i-1}f(n/2^{i-1}) + \sum_{k=1}^{i-1} 2^k$$

$$= 2^{i-1}f(2) + 2^i - 2$$

$$= 2^{i-1} + 2^i - 2$$

$$= \frac{3n}{2} - 2.$$

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

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.

Teorema Mestre: O Que Diz o Teorema

- 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 das 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 $af(n/b) \leq cf(n)$.

Teorema Mestre

- A prova para o caso em que $f(n) = cn^k$, onde $c > 0$ e $k \geq 0$ são duas constantes inteiras, é tratada no Exercício 2.13.
- A prova desse teorema não precisa ser entendida para ser aplicado, conforme veremos em exemplos a seguir.

Teorema Mestre: Outros Aspectos

- No caso 1, $f(n)$ tem de ser polinomialmente menor do que $n^{\log_b a}$, isto é, $f(n)$ tem de ser assintoticamente menor do que $n^{\log_b a}$ por um fator de n^ϵ , para alguma constante $\epsilon > 0$.
- No caso 3, $f(n)$ tem de ser polinomialmente maior do que $n^{\log_b a}$ e, além disso, satisfazer a condição de que $af(n/b) \leq cf(n)$.
- Logo, os três casos não cobrem todas as funções $f(n)$ que poderemos encontrar. Existem algumas poucas aplicações práticas que ficam entre os casos 1 e 2 (quando $f(n)$ é menor do que $n^{\log_b a}$, mas não polinomialmente menor) e entre os casos 2 e 3 (quando $f(n)$ é maior do que $n^{\log_b a}$, mas não polinomialmente maior). Assim, se a função $f(n)$ cai em um desses intervalos ou se a condição $af(n/b) \leq cf(n)$ não é satisfeita, então o Teorema Mestre não pode ser aplicado.

Teorema Mestre: Exemplos do Uso

- 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 $T(n) = \Theta(n^2)$.
- Considere a equação de recorrência: $T(n) = 2T(n/2) + n - 1$, onde $a = 2$, $b = 2$, $f(n) = n - 1$ e $n^{\log_b a} = n^{\log_2 2} = \Theta(n)$.
O caso 2 se aplica porque $f(n) = \Theta(n^{\log_b a}) = \Theta(n)$, e a solução é $T(n) = \Theta(n \log n)$.
- Considere a equação de recorrência: $T(n) = T(2n/3) + n$, onde $a = 1$, $b = 3/2$, $f(n) = n$ e $n^{\log_b a} = n^{\log_{3/2} 1} = n^0 = 1$.
O caso 3 se aplica porque $f(n) = \Omega(n^{\log_{3/2} 1 + \epsilon})$, onde $\epsilon = 1$ e $af(n/b) = 2n/3 \leq cf(n) = 2n/3$, para $c = 2/3$ e $n \geq 0$. Logo, a solução é $T(n) = \Theta(f(n)) = \Theta(n)$.

Teorema Mestre: Exemplos do Uso

- Considere a equação de recorrência: $T(n) = 3T(n/4) + n \log n$, onde $a = 3$, $b = 4$, $f(n) = n \log n$ e $n^{\log_b a} = n^{\log_3 4} = n^{0.793}$.
O caso 3 se aplica porque $f(n) = \Omega(n^{\log_3 4 + \epsilon})$, onde $\epsilon \approx 0.207$ e $af(n/b) = 3(n/4) \log(n/4) \leq cf(n) = (3/4)n \log n$, para $c = 3/4$ e n suficientemente grande.

- O Teorema Mestre não se aplica à equação de recorrência:

$$T(n) = 3T(n/3) + n \log n,$$

$$\text{onde } a = 3, b = 3, f(n) = n \log n \text{ e } n^{\log_b a} = n^{\log_3 3} = n.$$

O caso 3 não se aplica porque, embora $f(n) = n \log n$ seja assintoticamente maior do que $n^{\log_b a} = n$, a função $f(n)$ não é polinomialmente maior: a razão $f(n)/n^{\log_b a} = (n \log n)/n = \log n$ é assintoticamente menor do que n^ϵ para qualquer constante ϵ positiva. Logo, a solução é $T(n) = \Theta(f(n)) = \Theta(n \log n)$.

Balanceamento - Análise do Exemplo

- Equação de recorrência para comparações entre elementos:

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

- 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:

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

- 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 $n-1$.

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 de $A[1..n]$ e troca-o com o primeiro elemento $A[1]$.
- Repete o processo com os $n-1$ elementos, resultando no segundo maior elemento, o qual é trocado com o segundo elemento $A[2]$.
- Repetindo para $n-2, n-3, \dots, 2$ ordena a seqüência.

Exemplo de Balanceamento - Mergesort

- **Intercalação**: unir dois arquivos ordenados gerando um terceiro arquivo 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 - Mergesort

```
procedure Mergesort (var A: array[1..n] of integer; i, j: integer);
```

```
begin
```

```
  if i < j
```

```
  then begin
```

```
    m := (i + j)/2;
```

```
    Mergesort (A, i, m);
```

```
    Mergesort (A, m+1, j);
```

```
    Merge (A, i, m, j);
```

```
  end;
```

```
end;
```

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

Análise do Mergesort (1)

- Na contagem de comparações, o comportamento do Mergesort pode ser representado por: $T(n) = 2T(n/2) + n - 1$, $T(1) = 0$
- 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:

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

- 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

- $M = M_1 \times M_2 \times \dots \times M_n$, 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 $1 \leq i \leq j \leq n$.

- Nesse 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 - Implementação

```

program AvaliaMultMatrizes;
const MAXN = 10;
var i, j, k, h, n, temp: integer; d: array[0..MAXN] of integer;
    m: array[1..MAXN, 1..MAXN] of integer;
begin
  write('Numero de matrizes n:'); readln(n); write('Dimensoes das matrizes:');
  for i := 0 to n do read(d[i]); for i := 1 to n do m[i, i] := 0;
  for h := 1 to n - 1 do
    begin for i := 1 to n - h do
      begin for j := i + h; m[i, j] := MaxInt;
        for k := i to j - 1 do
          begin temp := m[i, k] + m[k+1, j] + d[i-1] * d[k] * d[j];
            if temp < m[i, j] then m[i, j] := temp; end;
          write(' m[', i:1, ', ', j:1, ']=', m[i, j]);
        end;
      end;
    end;
  writeln;
end;
end.

```

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

- 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.

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.

Aplicação do Princípio da Otimalidade

- Por exemplo, quando o problema utiliza recursos limitados, quando o total de recursos usados nas substâncias 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.

Algoritmos Gulosos

- Resolve problemas de otimização.
- Ex: encontrar o menor caminho entre dois vértices de um grafo.
 - Escolhe a aresta que parece mais promissora em qualquer instante;
 - Independente do que possa acontecer, 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 α .
- O **algoritmo guloso** 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).

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.

Pseudo Código de Algoritmo Guloso

```
function Guloso (C: conjunto): Conjunto;
{ C: conjunto de candidatos }
```

```
begin
```

```
  S :=  $\emptyset$ ; { S contém conjunto solução }
```

```
  while (C  $\neq \emptyset$ ) and not solucao(S) do
```

```
    begin
```

```
      x := seleciona (C);
```

```
      C := C – x;
```

```
      if viavel (S + x) then S := S + x;
```

```
    end;
```

```
  if solucao (S) then return (S) else return ('Não existe solução');
```

```
end;
```

- Se o conjunto aumentado de candidatos se torna inviável, o candidato é rejeitado. Senão, o candidato é adicionado ao conjunto S de escolhidos.
- A cada aumento de S verificamos se S constitui uma 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.

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).