


Análise de algoritmos

Parte I

SCC-201 Introdução à Ciência da Computação II
Rosane Minghim

Material preparado por : Prof. Thiago A. S. Pardo
e modificado por R. Minghim e Nathalie Vargas

SCC - ICMC



Algoritmo



- Noção geral: conjunto de instruções que devem ser seguidas para solucionar um determinado problema.
- Cormen et al. (2002)
 - Qualquer procedimento computacional bem definido que toma algum valor ou conjunto de valores de **entrada** e produz algum valor ou conjunto de valores de **saída**.
 - Ferramenta para resolver um problema computacional bem especificado.
 - Assim como o hardware de um computador, constitui uma tecnologia, pois o desempenho total do sistema depende da escolha de um algoritmo eficiente tanto quanto da escolha de um hardware rápido.

Algoritmo



- Comen et al. (2002)
 - Deseja-se que um algoritmo termine e seja correto
- Perguntas
 - Mas um algoritmo **correto** vai **terminar**, não vai?
 - A afirmação está redundante?



Recursos de um algoritmo

- Uma vez que um algoritmo está pronto/disponível, é importante determinar os **recursos necessários** para sua execução.
 - Tempo
 - Memória
- Qual o principal quesito? Por que?



Análise de algoritmos

- Um algoritmo que soluciona um determinado problema, mas requer o processamento de **um ano**, não deve ser usado.
- O que dizer de uma afirmação como a abaixo?
 - “Desenvolvi um novo algoritmo chamado TripleX que leva 14,2 segundos para processar 1.000 números, enquanto o método SimpleX leva 42,1 segundos”.
- Você trocaria o SimpleX que roda em sua empresa pelo TripleX?

Análise de algoritmos




- A afirmação tem que ser examinada, pois há diversos fatores envolvidos
 - Características da máquina em que o algoritmo foi testado
 - Quantidade de memória
 - Linguagem de programação
 - Compilada vs. interpretada
 - Alto vs. baixo nível
 - Implementação pouco cuidadosa do algoritmo SimpleX vs. “super” implementação do algoritmo TripleX
 - Quantidade de dados processados
 - Se o TripleX é mais rápido para processar 1.000 números, ele também é mais rápido para processar quantidades maiores de números, certo?



Análise de algoritmos

- A comunidade de computação começou a pesquisar formas de comparar algoritmos de forma independente de:
 - Hardware
 - Linguagem de programação
 - Habilidade do programador
- Portanto, quer-se comparar **algoritmos** e não **programas**.
 - Área conhecida como “análise/complexidade de algoritmos”.



Eficiência de algoritmos

- Sabe-se que:
 - Processar 10.000 números leva mais tempo do que 1000 números.
 - Cadastrar 10 pessoas em um sistema leva mais tempo do que cadastrar 5.
 - Etc.
- Então, pode ser uma boa idéia estimar a eficiência de um algoritmo em função do tamanho do problema.
 - Em geral, assume-se que “n” é o tamanho do problema, ou número de elementos que serão processados.
 - E calcula-se o número de operações que serão realizadas sobre os n elementos.

Eficiência de algoritmos



- O melhor algoritmo é aquele que requer menos operações sobre a entrada, pois é o mais rápido.
 - O tempo de execução do algoritmo pode variar em diferentes máquinas, mas o número de operações é uma boa medida de desempenho de um algoritmo.
- De que **operações** estamos falando?
- Toda operação leva o **mesmo tempo**?

Exemplo: TripleX vs. SimpleX



- TripleX: para uma entrada de tamanho n , o algoritmo realiza n^2+n operações
 - Pensando em termos de função: $f(n)=n^2+n$
- SimpleX: para uma entrada de tamanho n , o algoritmo realiza $1.000n$ operações
 - $g(n)=1.000n$

Exemplo: TripleX vs. SimpleX



- Faça os cálculos do desempenho de cada algoritmo para cada tamanho de entrada.

Tamanho da entrada (n)	1	10	100	1.000	10.000
$f(n)=n^2+n$					
$g(n)=1.000n$					



Exemplo: TripleX vs. SimpleX

- Faça os cálculos do desempenho de cada algoritmo para cada tamanho de entrada.

Tamanho da entrada (n)	1	10	100	1.000	10.000
$f(n)=n^2+n$	2	110	10.100	1.001.000	100.010.000
$g(n)=1.000n$	1.000	10.000	100.000	1.000.000	10.000.000

- A partir de $n=1.000$, $f(n)$ mantém-se maior e cada vez mais distante de $g(n)$.
 - Diz-se que $f(n)$ cresce mais rápido do que $g(n)$.



Análise assintótica

- Deve-se preocupar com a eficiência de algoritmos quando o tamanho de n for **grande**.
- Definição: a eficiência assintótica de um algoritmo descreve a eficiência relativa dele quando n torna-se grande.
- Portanto, para **comparar** 2 algoritmos, determinam-se as **taxas de crescimento** de cada um: o algoritmo com menor taxa de crescimento rodará mais rápido quando o tamanho do problema for grande.

Análise assintótica




- Atenção
 - Algumas funções podem não crescer com o valor de n .
 - Quais?
 - Também se pode aplicar os conceitos de análise assintótica para a quantidade de memória usada por um algoritmo.
 - Mas não é tão útil, pois é difícil estimar os detalhes exatos do uso de memória e o impacto disso.



Análise de algoritmos

- Existem basicamente 2 formas de estimar o tempo de execução de programas e decidir quais são os melhores.
 - **Empírica** ou **teoricamente**.
- É desejável e possível estimar qual o melhor algoritmo sem ter que executá-los.
 - Função da análise de algoritmos

Calculando o tempo de execução



- Supondo que as operações simples demoram uma unidade de tempo para executar, considere o programa abaixo para calcular o resultado de $\sum_{i=1}^n i^3$

Início

declare soma_parcial numérico;

soma_parcial \leftarrow 0;

para $i \leftarrow 1$ até n faça

 soma_parcial \leftarrow soma_parcial + $i * i * i$;

escreva(soma_parcial);

Fim

Calculando o tempo de execução



- Supondo que as operações simples demoram uma unidade de tempo para executar, considere o programa abaixo para calcular o resultado de $\sum_{i=1}^n i^3$

Início

declare soma_parcial numérico;

soma_parcial \leftarrow 0;

para $i \leftarrow 1$ até n faça

 soma_parcial \leftarrow soma_parcial + $i * i * i$;

 escreva(soma_parcial);

Fim

1 unidade de tempo

1 unidade para inicialização de i ,
 $n+1$ unidades para testar se $i \leq n$ e n
unidades para incrementar $i = 2n+2$

4 unidades (1 da soma, 2
das multiplicações e 1 da
atribuição) executada n
vezes (pelo comando
“para”) = $4n$ unidades

1 unidade para escrita

Calculando o tempo de execução



- Supondo que as operações simples demoram uma unidade de tempo para executar, considere o programa abaixo para calcular o resultado de $\sum_{i=1}^n i^3$

Início

declare soma_parcial numérico;

soma_parcial \leftarrow 0;

para $i \leftarrow 1$ até n faça

soma_parcial \leftarrow soma_parcial + $i * i * i$;

1 unidade de tempo

1 unidade para inicialização de i ,
 $n+1$ unidades para testar se $i \leq n$ e n
unidades para incrementar $i = 2n+2$

4 unidades (1 da soma, 2 das multiplicações e 1 da atribuição) executada n vezes (pelo comando "para") = $4n$ unidades


1 unidade para escrita

Custo total: somando tudo, tem-se $6n+4$ unidades de tempo, ou seja, a função é **$O(n)$**

Calculando o tempo de execução



- Ter que realizar todos esses passos para cada algoritmo (principalmente algoritmos grandes) pode se tornar uma tarefa **cansativa**.
- Em geral, como se dá a resposta em termos do *big-oh*, **costuma-se desconsiderar as constantes e elementos menores dos cálculos**
 - No exemplo anterior
 - A linha $\text{soma_parcial} \leftarrow 0$ é insignificante em termos de tempo
 - É desnecessário ficar contando 2, 3 ou 4 unidades de tempo na linha $\text{soma_parcial} \leftarrow \text{soma_parcial} + i * i$
 - O que realmente dá a grandeza de tempo desejada é a repetição na linha para $i \leftarrow 1$ até n faça



Regras para o cálculo

- Repetições
 - O tempo de execução de uma repetição é pelo menos o tempo dos comandos dentro da repetição (incluindo testes) vezes o número de vezes que é executada



Regras para o cálculo

- Repetições aninhadas

- A análise é feita de dentro para fora
- O tempo total de comandos dentro de um grupo de repetições aninhadas é o tempo de execução dos comandos multiplicado pelo produto do tamanho de todas as repetições
- O exemplo abaixo é $O(n^2)$

para $i \leftarrow 0$ até n faça
 para $j \leftarrow 0$ até n faça
 faça $k \leftarrow k+1$;

Regras para o cálculo



- Comandos consecutivos
 - É a soma dos tempos de cada um, o que pode significar o máximo entre eles
 - O exemplo abaixo é $O(n^2)$, apesar da primeira repetição ser $O(n)$


```
para i ← 0 até n faça
  k ← 0;
para i ← 0 até n faça
  para j ← 0 até n faça
    faça k ← k + 1;
```



Regras para o cálculo

- Se... então... senão
 - Para uma cláusula condicional, o tempo de execução nunca é maior do que o tempo do teste mais o tempo do maior entre os comandos relativos ao então e os comandos relativos ao senão
 - O exemplo abaixo é $O(n)$

se $i < j$
então $i \leftarrow i+1$
senão para $k \leftarrow 1$ até n faça
 $i \leftarrow i*k;$



Regras para o cálculo


- Chamadas a sub-rotinas
 - Uma sub-rotina deve ser analisada primeiro e depois ter suas unidades de tempo incorporadas ao programa/sub-rotina que a chamou.

Operações Elementares

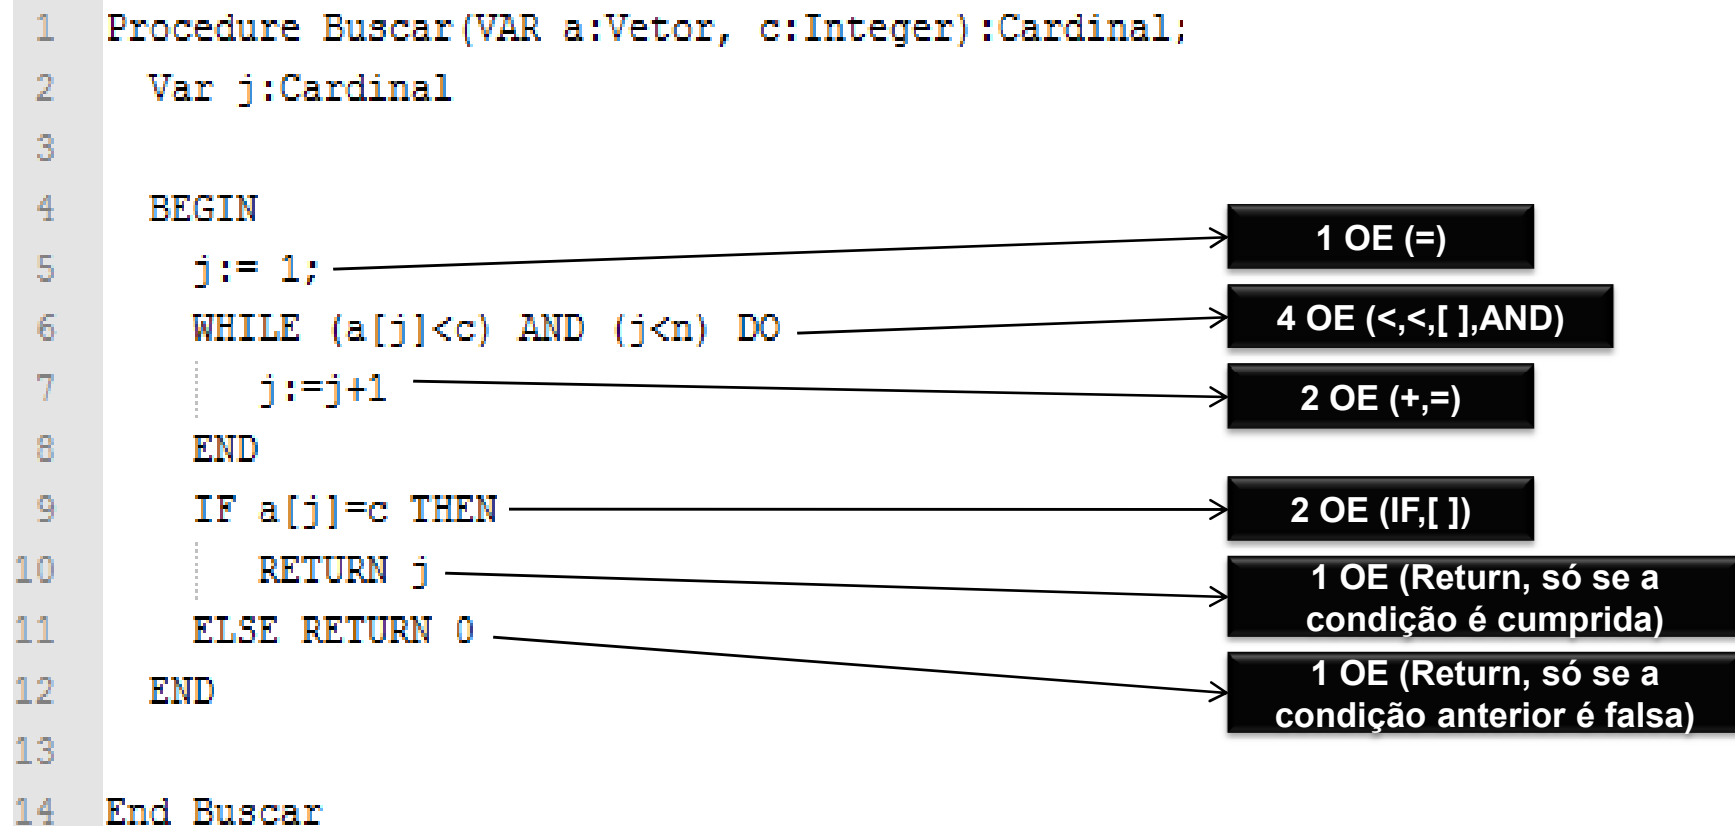


- As operações elementares (OE), são as medidas básicas de complexidade de algoritmos.
- Exemplos:
 - `a++` → 2 OE (=,+).
 - `b=a*5-Vetor[2*2]` → 5 OE (=,*,-,[],*).
 - `b+=soma(a,b<2)` → 4 OE (+,=,soma,<).
 - `C++ == E[1] AND B>3` → 6 OE (=,+==,[],AND,>).

Exemplos



- Para o seguinte problema primeiro temos que identificar as operações elementares (OE) que são realizadas:





Exemplos

- **Melhor Caso**

- Na linha 6, só é executada a primeira metade da condição, isto é, a comparação $a[j] < c$ vai ser falsa.
 - $T1(n) = 1OE(\text{linha 5}) + 2OE(\text{linha 6}) = 3OE$
- Nas linhas 9 a 11, serão executados pelo menos uma comparação e um Return.
 - $T2(n) = 2OE(\text{linha 9}) + 1OE(\text{Return}) = 3OE$

```
5      j:= 1;
6      WHILE (a[j]<c) AND (j<n) DO
7          j:=j+1
8      END
9      IF a[j]=c THEN
10         RETURN j
11     ELSE RETURN 0
12 END
```

$$T(n) = T1(n) + T2(n)$$

$$T(n) = 6OE$$



Exemplos

- **Pior Caso:**

- Linha 5 = **1OE**.
- A linha 6 é repetida **n-1** vezes até que a segunda condição seja cumprida.
- Linhas 9 até 11 = **3OE**.
- Cada iteração do ciclo while composta pelas linhas 6 e 7 mais uma execução adicional do while (que avalia de novo se as condições do ciclo foram cumpridas).

```
5      j:= 1;  
6      WHILE (a[j]<c) AND (j<n) DO  
7          j:=j+1  
8      END  
9      IF a[j]=c THEN  
10         RETURN j  
11     ELSE RETURN 0  
12     END
```

$$T(n)=1+ ((\sum_{i=1}^{n-1}(4 + 2))+4)+3$$

$$T(n)=1+ ((6(n-1)+4)+3$$

$$T(n)=1+6n-6+4+3$$

$$T(n)=6n+2$$



Exemplos

- **Pior Caso:**

- $T(n) = 1 +$ → Corresponde à **linha 5**, onde o custo é **1OE**.
- **((Somatória de $j+1$ até $n-1$))** → Corresponde à **linha 6**, já que se percorre $n-1$ vezes o ciclo até que a segunda condição seja TRUE.
 - **(4+2)** → As 4OE representam as condições dentro do while, e 2OE representam as condições dentro do ciclo while na **linha 7**.
 - **+4** → Representa as condições do while, já que cada laço ele volta a perguntar se a condição foi cumprida para terminar o ciclo.
- Depois da somatória no **+3** → Representa as **linhas 9 até 11**, com 3OE.

```
5      j:= 1;
6      WHILE (a[j]<c) AND (j<n) DO
7          j:=j+1
8      END
9      IF a[j]=c THEN
10         RETURN j
11     ELSE RETURN 0
12     END
```

$$T(n) = 1 + ((\sum_{i=1}^{n-1} (4 + 2)) + 4) + 3$$

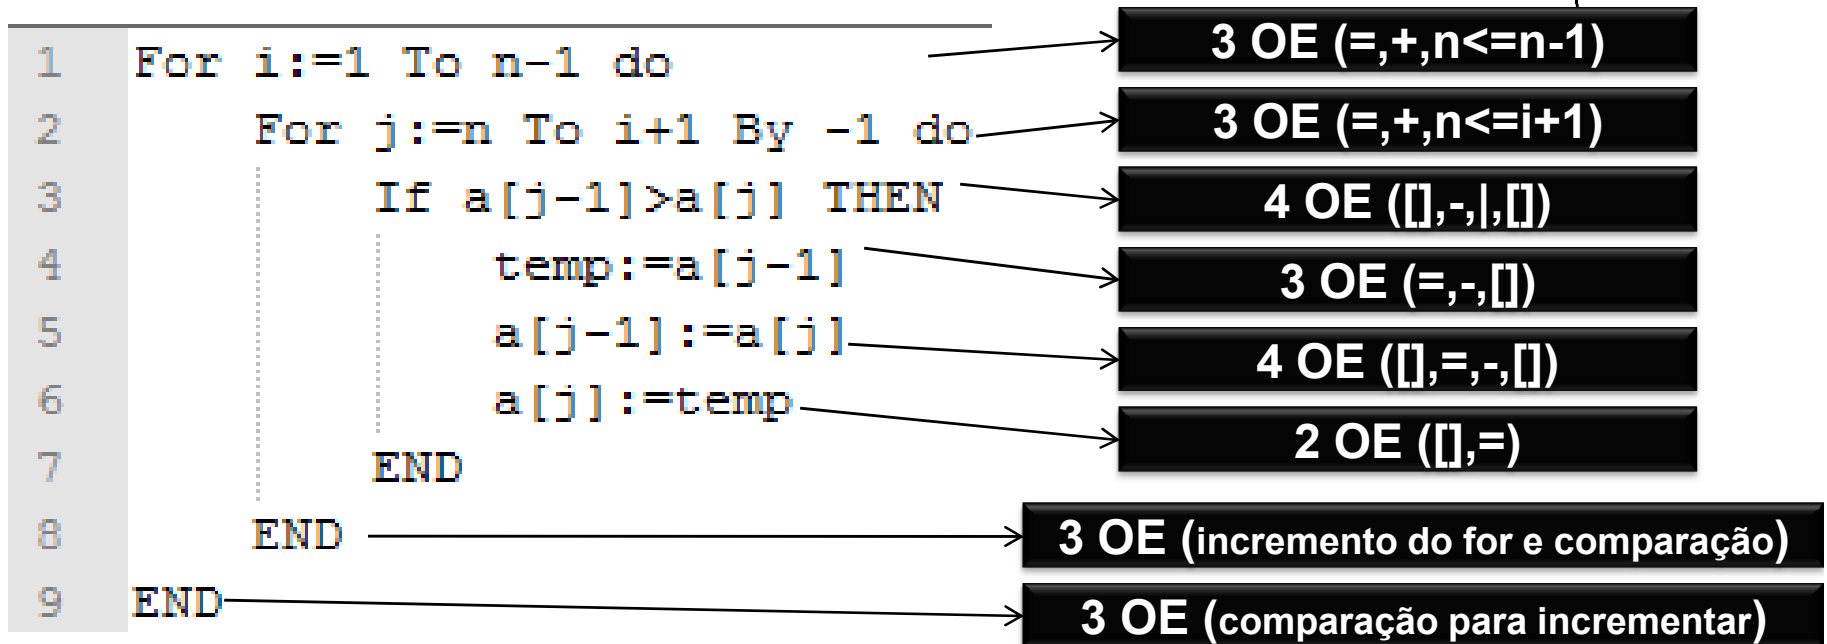
$$T(n) = 1 + ((6(n-1) + 4) + 3)$$

$$T(n) = 1 + 6n - 6 + 4 + 3$$

$$T(n) = 6n + 2$$



Exemplo



- **Melhor Caso** → A condição na linha 3 será falsa, e as linhas 4 até 6 não serão executadas.
- **Pior Caso** → A condição na linha 3 seja verdadeira, e as linhas 4 até 6 serão executadas.



Exercício

- Estime quantas unidades de tempo são necessárias para rodar o algoritmo abaixo

Início

declare i e j numéricos;

declare A vetor numérico de n posições;

$i \leftarrow 1$;

enquanto $i \leq n$ faça

$A[i] \leftarrow 0$;

$i \leftarrow i + 1$;


para $i \leftarrow 1$ até n faça

 para $j \leftarrow 1$ até n faça

$A[i] \leftarrow A[i] + i + j$;

Fim

Relembrando um pouco de matemática...



- Expoentes

- $x^a x^b = x^{a+b}$
- $x^a / x^b = x^{a-b}$
- $(x^a)^b = x^{ab}$
- $x^n + x^n = 2x^n$ (diferente de x^{2n})
- $2^n + 2^n = 2^{n+1}$

Relembrando um pouco de matemática...



- **Logaritmos** (usaremos a base 2, a menos que seja dito o contrário)
 - $x^a=b \rightarrow \log_x b=a$
 - $\log_a b = \log_c b / \log_c a$, se $c>0$
 - $\log ab = \log a + \log b$
 - $\log a/b = \log a - \log b$
 - $\log(a^b) = b \log a$

Relembrando um pouco de matemática...




- **Logaritmos** (usaremos a base 2, a menos que seja dito o contrário)

- E o mais importante
 - $\log x < x$ para todo $x > 0$

- **Alguns valores**

- $\log 1=0$, $\log 2=1$,
 $\log 1.024=10$,
 $\log 1.048.576=20$



Exemplo para várias bases

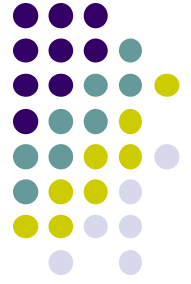
Função exponencial vs. logarítmica



- Na palma da mão direita



Relembrando um pouco de matemática...



- Séries

$$\sum_{i=0}^n 2^i = 2^{n+1} - 1$$

$$\sum_{i=0}^n a^i = \frac{a^{n+1} - 1}{a - 1}$$

$$\sum_{i=1}^n i = \frac{n(n+1)}{2} \approx \frac{n^2}{2}$$

Algumas notações




- Notações que usaremos na análise de algoritmos
 - $T(n) = O(f(n))$ (lê-se *big-oh*, *big-o* ou “da ordem de”) se existirem constantes c e n_0 tal que $T(n) \leq c * f(n)$ quando $n \geq n_0$
 - A taxa de crescimento de $T(n)$ é menor ou igual à taxa de $f(n)$
 - $T(n) = \Omega(f(n))$ (lê-se “ômega”) se existirem constantes c e n_0 tal que $T(n) \geq c * f(n)$ quando $n \geq n_0$
 - A taxa de crescimento de $T(n)$ é maior ou igual à taxa de $f(n)$

Algumas notações




- Notações que usaremos na análise de algoritmos
 - $T(n) = \Theta(f(n))$ (lê-se “theta”) se e somente se $T(n) = O(f(n))$ e $T(n) = \Omega(f(n))$
 - A taxa de crescimento de $T(n)$ é igual à taxa de $f(n)$
 - $T(n) = o(f(n))$ (lê-se *little-oh* ou *little-o*) se e somente se $T(n) = O(f(n))$ e $T(n) \neq \Theta(f(n))$
 - A taxa de crescimento de $T(n)$ é menor do que a taxa de $f(n)$


Algumas notações



Algumas notações



Algumas notações





Algumas notações

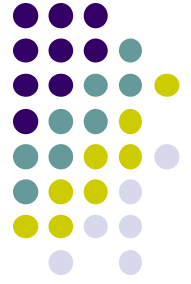
- O uso das notações permite **comparar a taxa de crescimento** das funções correspondentes aos algoritmos.
 - **Não faz sentido comparar pontos isolados** das funções, já que podem não corresponder ao comportamento assintótico.



Exemplo

- Para 2 algoritmos quaisquer, considere as funções de eficiência correspondentes $1.000n$ e n^2
 - A primeira é maior do que a segunda para valores pequenos de n
 - A segunda cresce mais rapidamente e eventualmente será uma função maior, sendo que o ponto de mudança é $n=1.000$
 - Segunda as notações anteriores, se existe um ponto n_0 a partir do qual $c \cdot f(n)$ é sempre pelo menos tão grande quanto $T(n)$, então, se os fatores constantes forem ignorados, $f(n)$ é pelo menos tão grande quanto $T(n)$
 - No nosso caso, $T(n)=1.000n$, $f(n)=n^2$, $n_0=1.000$ e $c=1$ (ou, ainda, $n_0=10$ e $c=100$)
 - Dizemos que $1.000n=O(n^2)$

Mais algumas considerações



- Ao dizer que $T(n) = O(f(n))$, garante-se que $T(n)$ cresce numa taxa não maior do que $f(n)$, ou seja, $f(n)$ é seu limite superior.
- Ao dizer que $f(n) = \Omega(T(n))$, tem-se que $T(n)$ é o limite inferior de $f(n)$.



Outros exemplos

- A função n^3 cresce mais rapidamente que n^2
 - $n^2 = O(n^3)$
 - $n^3 = \Omega(n^2)$
- Se $f(n)=n^2$ e $g(n)=2n^2$, então essas duas funções têm taxas de crescimento iguais
 - Portanto, $f(n) = O(g(n))$ e $f(n) = \Omega(g(n))$



Taxas de crescimento

- Algumas regras
 - Se $T_1(n) = O(f(n))$ e $T_2(n) = O(g(n))$, então
 - $T_1(n) + T_2(n) = \max(O(f(n)), O(g(n)))$
 - $T_1(n) * T_2(n) = O(f(n) * g(n))$
 - Para que precisamos desse tipo de cálculo?



Taxas de crescimento

- Algumas regras

- Se $T(x)$ é um polinômio de grau n , então
 - $T(x) = \Theta(x^n)$


- Relembrando: um polinômio de grau n é uma função que possui a forma abaixo

$$f(x) = a_n x^n + a_{n-1} x^{n-1} + \dots a_1 x + a_0$$

segundo a seguinte classificação em função do grau

- Grau 0: polinômio constante
- Grau 1: função afim (polinômio linear, caso $a_0 = 0$)
- Grau 2: polinômio quadrático
- Grau 3: polinômio cúbico

Se $f(x)=0$, tem-se o polinômio nulo



Taxas de crescimento

- Algumas regras
 - $\log^k n = O(n)$ para qualquer constante k , pois logaritmos crescem muito vagarosamente


Funções e taxas de crescimento



- As mais comuns

Função	Nome
c	constante
$\log n$	logarítmica
$\log^2 n$	log quadrado
n	linear
$n \log n$ n^2	quadrática
n^3	cúbica
2^n a^n	exponencial

Funções e taxas de crescimento





Taxas de crescimento

- Apesar de às vezes ser importante, **não se costuma incluir constantes ou termos de menor ordem em taxas de crescimento**
 - Queremos medir a taxa de crescimento da função, o que torna os “termos menores” irrelevantes
 - As constantes também dependem do tempo exato de cada operação; como ignoramos os custos reais das operações, ignoramos também as constantes
- Não se diz que $T(n) = O(2n^2)$ ou que $T(n) = O(n^2+n)$
 - Diz-se apenas $T(n) = O(n^2)$



Exercício em duplas

- Um algoritmo tradicional e muito utilizado é da ordem de $n^{1,5}$, enquanto um algoritmo novo proposto recentemente é da ordem de $n \log n$.
 - $f(n)=n^{1,5}$
 - $g(n)=n \log n$
- Qual algoritmo você adotaria na empresa que está fundando?
 - Lembre-se que a eficiência desse algoritmo pode determinar o sucesso ou o fracasso de sua empresa



Exercício em duplas

- Uma possível solução

- $f(n) = n^{1,5} \quad \rightarrow \quad n^{1,5}/n = n^{0,5} \quad \rightarrow \quad (n^{0,5})^2 = n$

- $g(n) = n \log n \quad \rightarrow \quad (n \log n)/n = \log n \quad \rightarrow \quad (\log n)^2 = \log^2 n$


- Como n cresce mais rapidamente do que qualquer potência de \log , temos que o algoritmo novo é mais eficiente e, portanto, deve ser o adotado pela empresa no momento.




Análise de algoritmos

- Para proceder a uma análise de algoritmos e determinar as taxas de crescimento, necessitamos de um **modelo de computador** e das **operações** que executa.
- Assume-se o uso de um **computador tradicional**, em que as **instruções de um programa são executadas sequencialmente**.
 - Com **memória infinita**, por simplicidade.

Análise de algoritmos



- Repertório de **instruções simples**: soma, multiplicação, comparação, atribuição, etc.
- Por simplicidade e viabilidade da análise, assume-se que **cada instrução demora exatamente uma unidade de tempo** para ser executada.
 - Obviamente, em situações reais, isso pode não ser verdade: a leitura de um dado em disco pode demorar mais do que uma soma.
- Operações complexas, como inversão de matrizes e ordenação de valores, não são realizadas em uma única unidade de tempo, obviamente: devem ser analisadas em partes.



Análise de algoritmos

- Considera-se somente o algoritmo e suas entradas (de tamanho n).
- Para uma entrada de tamanho n , pode-se calcular $T_{\text{melhor}}(n)$, $T_{\text{média}}(n)$ e $T_{\text{pior}}(n)$, ou seja, o melhor tempo de execução, o tempo médio e o pior, respectivamente.
 - Obviamente, $T_{\text{melhor}}(n) \leq T_{\text{média}}(n) \leq T_{\text{pior}}(n)$
- Atenção: para mais de uma entrada, essas funções teriam mais de um argumento.

Análise de algoritmos




- Geralmente, utiliza-se somente a análise do pior caso $T_{\text{pior}}(n)$, pois ela fornece os limites para todas as entradas, incluindo particularmente as entradas ruins.
- Logicamente, muitas vezes, o **tempo médio pode ser útil**, principalmente em sistemas executados rotineiramente.
 - Por exemplo: em um sistema de cadastro de alunos como usuários de uma biblioteca, o trabalho difícil de cadastrar uma quantidade enorme de pessoas é feito somente uma vez; depois, cadastros são feitos de vez em quando apenas.
- Dá mais trabalho calcular o tempo médio.
- O melhor tempo não tem muita utilidade.



Pergunta

- Idealmente, para um algoritmo qualquer de ordenação de vetores com n elementos.
 - Qual a configuração do vetor que você imagina que provavelmente geraria o melhor tempo de execução?
 - E qual geraria o pior tempo?



Exemplo

- Soma da subsequência máxima
 - Dada uma seqüência de inteiros (possivelmente negativos) a_1, a_2, \dots, a_n , encontre o valor da máxima soma de quaisquer números de elementos consecutivos; se todos os inteiros forem negativos, o algoritmo deve retornar 0 como resultado da maior soma
 - Por exemplo, para a entrada -2, 11, -4, 13, -5 e -2, a resposta é 20 (soma de a_2 a a_4)



Soma da subsequência máxima

- Há muitos algoritmos propostos para resolver esse problema.
- Alguns são mostrados abaixo juntamente com seus tempos de execução.

Algoritmo	1	2	3	4
Tempo	$O(n^3)$	$O(n^2)$	$O(n \log n)$	$O(n)$
Tamanho da entrada				
n = 10	0.00103	0.00045	0.00066	0.00034
n = 100	0.47015	0.01112	0.00486	0.00063
n = 1.000	448.77	1.1233	0.05843	0.00333
n = 10.000	ND*	111.13	0.68631	0.03042
n = 100.000	ND	ND	8.0113	0.29832

*ND = Não Disponível

Soma da subsequência máxima



- Deve-se notar que:
 - Para entradas pequenas, todas as implementações rodam num piscar de olhos.
 - Portanto, se somente entradas pequenas são esperadas, não devemos gastar nosso tempo para projetar melhores algoritmos
 - Para entradas grandes, o melhor algoritmo é o 4.
 - Os tempos não incluem o tempo requerido para leitura dos dados de entrada.
 - Para o algoritmo 4, o tempo de leitura é provavelmente maior do que o tempo para resolver o problema: característica típica de algoritmos eficientes.

Taxas de crescimento




Gráfico (n x milisegundos) das taxas de crescimento dos 4 algoritmos com entradas entre 10 e 100.

Taxas de crescimento




Gráfico (n x segundos) dos 4 algoritmos para entradas maiores



Exercício 1

- Com um algoritmo de função de custo temporal $f(n) = n^3$ se podem resolver problemas de tamanho k em 1 hora.
 - Até que tamanho poderemos resolver no mesmo tempo com um computador 1000 vezes mais rápido.
 - E se a função de custo fosse $f(n) = 2^n$?



Solução 1

- $f(n)$ representa o número de operações elementares feitas para o algoritmo de tamanho n .
- Cada operação precisa de um tempo t para ser feita, então temos que $f(k)t$ é uma hora.
- Um computador 1000 vezes mais rápido vai demorar $t/1000$ para realizar cada operação Elementar.
 - A equação $\rightarrow f(k)t = f(x)t / 1000$.
 - Quando $f(n) = n^3 \rightarrow x = 10 \cdot \sqrt[3]{k}$.
 - Quando $f(n) = 2^n \rightarrow x = k + \log_2 1000$.



Exercício 2


- Usando a definição de notação assintótica, demonstre que $1024n^2 + 5n \in O(n^2)$.
 - Primeiro é preciso encontrar um número n_0 e uma constante $c > 0$ que cumpra que $1024n^2 + 5n \leq cn^2$ para todo $n \leq n_0$.
 - Para simplificar a equação divide-se por n^2 para obter $1024 + (5/n) \leq c$.
 - $n_0 = 5$ e $c = 1025$.
- A mesma função é $\Theta(n^2)$? Prove.



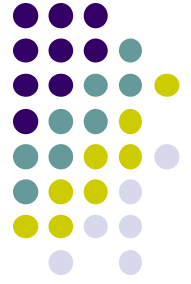
Exercício 3

- Determine qual é a complexidade do algoritmo a seguir.

```
1 procedure prod_mat (n:integer)
2   var
3     i,j,k:integer
4   begin
5     for i:=1 to n do
6       for j:=1 to n do begin
7         C[i,j]:=0
8         for k:=1 to n do
9           C[i,j]:=C[i,j]+A[i,k]*B[k,j]
10        end
11      end
12    end
13  end
14 end procedure
```



Exercício 4



- Muito tempo atrás, o visir Sissa bem Dahir inventou o jogo de xadrez para o Rei Shirham da Índia.
- O Rei deu a possibilidade de selecionar sua recompensa, e Sissa lhe deu algumas opções:
 - Poderia ser recompensado com uma quantidade de trigo equivalente à plantação de trigo de seu reino por 2 anos, ou,
 - Poderia ser recompensado com uma quantidade de trigo que seria calculado da seguinte forma:
 - Um grão de trigo na primeira seção do tabuleiro de xadrez.
 - Mais dois grãos de trigo na segunda seção .
 - Mais quatro grãos na terceira seção , e assim por diante, até chegar na última seção.
 - O Rei selecionou a segunda opção. Quantos grão de trigo deu o Rei para Sissa?