

Comportamento Assintótico de Funções

É interessante comparar algoritmos para valores grandes de n .

Para valores pequenos de n , mesmo um algoritmo ineficiente não custa muito para ser executado

Fazendo estimativas e simplificações...

- O número de passos que um algoritmo dá para uma dada entrada pode depender de vários parâmetros:
 - Se for um grafo pode depender do número de nós, arestas, grau máximo do grafo, ou uma combinação destes.
- Mas, por simplicidade, computamos o tempo de execução em função da entrada
 - (que em grafos geralmente é o número de nós) e desconsideramos os outros parâmetros.
- Além disso, usamos uma estimativa – **a análise assintótica** – que somente considera o termo de ordem mais alta de uma expressão para o tempo de execução
 - Por exemplo, para $f(n) = 6n^3 + 2n^2 + 20n + 45$ consideramos $6n^3$ e descartamos o coeficiente 6 e dizemos que $f(n) = O(n^3)$.

Introdução

- Objetivos:

Apresentar as notações assintóticas usadas para descrever a taxa de crescimento de funções de custo de algoritmos

Tópicos:


- Notação O - big-oh
- Notação Ω - ômega
- Notação Θ - theta
- Classes de comportamento assintótico
- Algoritmo Exponencial versus Polinomial
- Como calcular a complexidade de limite superior (big - Oh) de algoritmos

Custo Assintótico de Funções

- O custo assintótico de uma função $f(n)$ representa o limite do comportamento de custo quando n cresce.
- Geralmente, um algoritmo que é assintoticamente mais eficiente será a melhor escolha para valores grandes de n .

Dominação Assintótica

- Definição: $f(n)$ domina assintoticamente $g(n)$ se existem duas constantes **positivas** c e m tais que, para $n \geq m$, temos $|g(n)| \leq c \cdot |f(n)|$



- Exemplo: Seja $g(n) = n$ e $f(n) = -n^2$
- Temos que $|n| \leq |-n^2|$ para todo n pertencente aos $\mathbb{N}$.
- Fazendo $c = 1$ e $m = 0$ a definição é satisfeita. Logo, $f(n)$ domina assintoticamente $g(n)$

Notação O

- Notação trazida da matemática por Knuth (1968):
$$g(n) = O(f(n))$$
- Lê-se:
 $g(n)$ é de ordem no máximo $f(n)$
 $f(n)$ domina assintoticamente $g(n)$
($f(n)$ é um limite assintótico superior para $g(n)$)
- $O(f(n))$ representa o conjunto de todas as funções que são assintoticamente dominadas por uma dada função $f(n)$.
- Se $g(n) \in O(f(n))$ então dizemos $g(n) = O(f(n))$

Formalmente: $g(n) = O(f(n))$, $\exists$ (existe) $c > 0$ e n_0 | $0 \leq g(n) \leq c \cdot f(n)$, $\forall$ (qualquer) $n \geq n_0$

Notação O

Se dizemos que $g(n) = O(n^2)$

Significa que existem constantes c e m | $g(n) \leq c \cdot n^2$ para $n \geq m$

Exemplo:

$$g(0) = 1$$

$$g(1) = 4$$

$$g(n) = (n+1)^2$$

$$(n+1)^2 \leq c \cdot n^2$$

$$n^2 + 2n + 1 \leq c \cdot n^2$$

$$2n + 1 \leq (c-1) \cdot n^2$$



n	$(n+1)^2$	$2 \cdot n^2$
0	1	0
1	4	2
2	9	8
3	16	18

Fazendo $c = 2$ e $m = 3$ a definição
é satisfeita

Notação Ω

- Ω define um limite inferior para a função, por um fator constante.
- Escreve-se $g(n) = \Omega(f(n))$, se existirem constantes **positivas** c e n_0 | para $n \geq n_0$, o valor de $g(n)$ é maior ou igual a $c \cdot f(n)$
- Neste caso, diz-se que $f(n)$ é um limite assintótico inferior para $g(n)$.

Formalmente: $g(n) = \Omega(f(n))$, $\exists$ (existe) $c > 0$ e n_0 | $0 \leq c \cdot f(n) \leq g(n)$, $\forall$ (qualquer) $n \geq n_0$

- A **notação Ω** é usada para expressar o limite inferior do tempo de execução de qualquer **algoritmo para resolver um problema específico**
- Exemplo: O limite inferior para qualquer algoritmo de ordenação que utiliza comparação de chaves é $\Omega(n \log n)$.

Comportamento Assintótico de Funções

- Assim, existem duas notações principais na análise assintótica de funções: O e Ω

$O(f(n))$ depende do **algoritmo** (limite superior)

$\Omega(f(n))$ depende do **problema** (limite inferior)

Notação Θ

- A notação Θ limita a função por fatores constantes.
- $g(n) = \Theta(f(n))$ se existirem constantes **positivas** c_1 e c_2 e n_0 tais que para $n \geq n_0$, o valor de $g(n)$ está sempre entre $c_1.f(n)$ e $c_2.f(n)$ inclusive.
- Neste caso, dizemos que $f(n)$ é um limite assintótico firme para $g(n)$.

Formalmente:

$g(n) = \Theta(f(n))$, $\exists$ (existe) $c_1 > 0$ e $c_2 > 0$ e n_0 | $0 \leq c_1.f(n) \leq g(n) \leq c_2.f(n)$, $\forall$ (qualquer) $n \geq n_0$

Exemplo de uso da Notação Θ

- Provem que $1/2n^2 - 3n = \Theta(n^2)$

Achem constantes $c_1 > 0$, $c_2 > 0$, $n_0 > 0$, tais que:

$$c_1.n^2 \leq 1/2n^2 - 3n \leq c_2.n^2$$

para todo $n \geq n_0$

OBS: as constantes c_1 e c_2 podem ser reais.

Classes de Comportamento Assintótico

- $f(n) = O(1)$ (complexidade constante)

O uso do algoritmo **independe** do tamanho de n . Neste caso, as instruções do programa são executadas um número fixo de vezes.

- $f(n) = O(\log n)$ (complexidade logaritmica)

Ocorre tipicamente em algoritmos que resolvem um problema transformando-o em problemas menores.

Nestes casos, o tempo de execução pode ser considerado como sendo menor que uma constante grande .

Exemplos: $n = 1000 \rightarrow \log_2 n \sim 10$; $n = 10^6 \rightarrow \log_2 n \sim 20$.

- $f(n) = O(n)$ (complexidade linear)

Em geral, um pequeno trabalho é realizado sobre cada elemento de entrada.

Esta é a melhor situação possível para um algoritmo que tem que processar n elementos de entrada ou produzir n elementos de saída. Cada vez que n dobra de tamanho o tempo de execução dobra.

Classes de Comportamento Assintótico

- $f(n) = O(n \log n)$

Este tempo de execução ocorre tipicamente em algoritmos resolvidos com o método **dividir&conquistar**.
Exemplos: $n = 1$ milhão - $n \log n \sim 20$ milhões;
 $n = 2$ milhões, $n \log n \sim 42$ milhões, pouco mais que o dobro.

- $f(n) = O(n^2)$ (complexidade quadrática)

Algoritmos desta ordem de complexidade ocorrem quando os **itens são processados aos pares**, em **um laço dentro de outro**. São úteis para resolver problemas de tamanho pequeno - métodos diretos de ordenação.

Dividir & Conquistar

- Muitos algoritmos possuem uma natureza recursiva:
 - para resolver um dado problema eles se chamam recursivamente uma ou mais vezes para tratar de subproblemas do mesmo tipo mas de tamanho menor e,
- Então combinam estas soluções para criar a solução original, seguindo a abordagem dividir e conquistar.
- Método Top-down

Os 3 Passos da Abordagem

- **Dividir** o problema em vários subproblemas
 - **Conquistar** os subproblemas resolvendo eles recursivamente. Quando os tamanhos são pequenos resolver diretamente
 - **Combinar** as soluções dos subproblemas na solução para o problema original
-
- Lembrem que o uso da recursão facilita a descrição do algoritmo e garante um mecanismo "limpo" para dividir o problema em 2 menores com a metade do tamanho do original.

MergeSort

(Dividir): divida a lista L de tamanho n em duas listas de tamanho $n/2$

(Conquistar): Ordene as duas listas recursivamente usando o mergesort. Se a lista L tem tamanho 1 ela está ordenada.

(Combinar): Intercale as duas produzindo uma lista ordenada

A complexidade de tempo de MergeSort é $O(n \log n)$

```
procedure mergesort(A,p,r);
```

```
Se  $p < r$  então
```

```
  início
```

```
     $q \leftarrow (p + r) \text{ div } 2$ 
```

```
    mergesort(A,p,q)
```

```
    mergesort(A,q+1,r)
```

```
    merge(A,p,q,r) {assume que os vetores  $A[p..q]$  e  
                      $A[q+1..r]$  estão ordenados e os intercala para  
                     formar um único array  $A[p..r]$ }
```

```
  fim
```

$A = \langle 5, 2, 4, 6, 1, 3, 2, 6 \rangle$

1 2 2 3 4 5 6 6

merge

2 4 5 6

1 2 3 6

merge

merge

2 5

4 6

1 3

2 6

merge

merge

merge

merge

5

2

4

6

1

3

2

6

Classes de Comportamento Assintótico (cont.)

- $f(n) = O(n^3)$ (complexidade cúbica)


Algoritmos desta ordem são úteis apenas para resolver pequenos problemas.

- $f(n) = O(2^n)$ (complexidade exponencial)

Algoritmos desta ordem geralmente não são úteis sob o ponto de vista prático.

Eles ocorrem na solução de problemas quando se usa a **força bruta** para resolvê-los.

Relação entre as ordens



Onde estão $n!$ e n^n ?

Algoritmo Exponencial Versus Polinomial

- Um algoritmo cuja função de complexidade é $O(c^n)$, $c > 1$, é chamado de **algoritmo exponencial** de tempo de execução.
- Um algoritmo cuja função de complexidade é $O(p(n))$, onde $p(n)$ é um polinômio, é chamado de **algoritmo polinomial** de tempo de execução.
- A **distinção** entre os dois torna-se **significativa** quando **n cresce**.
- Um problema é considerado **intratável** se ele é tão difícil que não existe um algoritmo polinomial para resolvê-lo
 - (torres de hanoi, damas e xadrez generalizados).
- Um problema é considerado **bem resolvido** quando existe um algoritmo polinomial para resolvê-lo.
 - São obtidos através de um entendimento mais profundo da estrutura do problema.

Princípios para a Análise de Algoritmos -- Prática

Tempo de execução para:

1. Atribuição, leitura e escrita: $O(1)$

Exceção linguagens que permitem atribuição direta em vetores de tamanho grande

2. Seqüência: comando de maior tempo

3. Decisão: avaliação da condição: $O(1)$; comandos dentro: regra 2.

4. Laço: avaliação do término: $O(1)$; comandos dentro: regra 2.

5. Programa com procedimentos não recursivos: o tempo de execução de cada procedimento deve ser calculado separadamente um a um.

Inicia-se com aqueles que não chamam outros. A seguir são avaliados aqueles que chamam os que não chamam outros, utilizando os tempos já calculados.

6. Programa com procedimentos recursivos: para cada procedimento é associada uma função de complexidade $f(n)$ desconhecida, onde n mede o tamanho dos argumentos para o procedimento.

Operações com a Notação O

- $f(n) = O(f(n))$
- c. $O(f(n)) = O(f(n))$ se $c = \text{constante}$
- $O(f(n)) + O(f(n)) = O(f(n))$
- $O(O(f(n))) = O(f(n))$
- $O(f(n)) + O(g(n)) = O(\max(f(n), g(n)))$
- $O(f(n))O(g(n)) = O(f(n)g(n))$
- $f(n)O(g(n)) = O(f(n)g(n))$

Regra da Soma

Suponha 3 trechos de programas cujos tempos de execução são $O(n)$, $O(n^2)$ e $O(n \log n)$. O tempo dos 2 primeiros é $O(\max(n, n^2))$ que é $O(n^2)$ e dos 3 é $O(\max(n^2, n \log n))$ que é $O(n^2)$.

Regra do Produto

Produto de $[\log n + k + O(1/n)]$ por $[n + O(\text{raiz}(n))]$ =
 $n \log n$

Fórmulas Úteis

$$\sum_{1 \leq i \leq n} 1 = n = O(n) \text{ (linearidade)}$$

$$\sum_{1 \leq i \leq n} i = n(n+1)/2 = O(n^2) \text{ (série aritmética)}$$

$$\sum_{1 \leq i \leq n} i^2 = [n(n+1)(2n+1)]/6 = O(n^3)$$

Exemplo

Procedure Ordena (var A: vetor);
{ ordena o vetor em ordem ascendente}

Var i, j, min, x: integer;

Begin

(1) For i:= 1 to n-1 do

Begin

(2) min := i;

(3) for j:= i + 1 to n do

(4) if $A[j] < A[\text{min}]$

(5) then min := j;

{troca $A[\text{min}]$ e $A[i]$ }

(6) X := $A[\text{min}]$;

(7) $A[\text{min}] := A[i]$;

(8) $A[i] := X$;

End;

End;

Análise do Programa

- O programa contém 2 laços, um dentro do outro.
 - Laço mais externo: (2) a (8)
 - Laço mais interno: (4) e (5)
 - Começamos pelo mais interno: comando de atribuição e avaliação da condição levam tempo constante.
 - Como não sabemos se o corpo da decisão vai ou não ser executado, considera-se o **pior caso**: assumir que a linha (5) sempre será executada.
 - O tempo para incrementar o índice do laço e avaliar sua condição de termo é também $O(1)$.
 - O tempo para executar **uma vez** o laço composto por (3), (4) e (5) é $O(\max(1,1,1)) = O(1)$.
- Seguindo regra da soma para a notação O .

- Como o número de iterações do laço é $n-i$ então o tempo gasto é $O(n-i \cdot 1) = O(n-i)$.

→ Seguindo a regra do produto para notação O .

- O corpo do laço mais externo contém, além do laço interno, os comandos de atribuição nas linhas (2), (6), (7), (8).
O tempo das linhas (2) a (8) é: $O(\max(1, (n-i), 1, 1, 1)) = O(n-i)$

A linha (1) é executada $n-1$ vezes, o tempo total do programa é:

$$\sum_{i=1}^{N-1} (n-i) = n \cdot \sum_{i=1}^{N-1} 1 - \sum_{i=1}^{N-1} i = n \cdot (n-1) - [(n-1) \cdot (n)]/2 = n^2 - n - n^2/2 - n/2$$

$$n^2/2 - n/2 = O(n^2)$$

Nro de comparações X nro de trocas

- Considerando o número de comparações como a mais relevante (4): $n^2/2 - n/2$ comparações
- Considerando o número de trocas (6), (7), (8) a mais relevante: $3(n-1)$ trocas.

Procedimento Recursivo para calcular $n!$

```
function fat(n: integer): integer;  
Begin  
(1)  If  $n \leq 1$   
(2)  then  $\text{fat} := 1$  { escape da recursão }  
(3)  Else  $\text{fat} := n * \text{fat}(n-1)$   
End;
```

Seja $T(n)$ o tempo de execução para $\text{fat}(n)$

(1) $\rightarrow O(1)$
(2) $\rightarrow O(1)$
(3) $\rightarrow O(1) + T(n-1)$

$T(n) = 1 + T(n-1)$
 $T(n-1) = 1 + T(n-2)$
...

$T(2) = 1 + T(1)$
 $T(n) = \underbrace{1 + 1 + 1 + \dots + 1}_{n-1 \text{ vezes}} + T(1)$

Método da Iteração: expande a recorrência e expressa ela como uma soma.

Relação de Recorrência:

Assumindo custos de multiplicações

$T(1) = 0$ pois não multiplica

$T(n) = 1 + T(n-1) \quad n \geq 2$

Procedimento não recursivo para fatorial

```
function fat (n : integer): integer;  
var f, i: integer;  
begin  
    f:= 1;  
    for i:= 2 to n do f:= f*i;  
    fat := f  
End;
```

$F(n) \rightarrow$ custo de multiplicações

$$F(1) = 0$$

$$F(n) = n - 1$$

Resolvendo Recorrências

- Quando um algoritmo contém uma chamada recursiva a ele mesmo, seu tempo de execução pode ser expresso como uma recorrência.
- Existem 3 métodos (Cormen et al, 1999):
- Método Mestre:
 - Fornece 3 casos para resolver $T(n) = aT(n/b) + f(n)$, $a \geq 1$; $b > 1$
- Método da Substituição:
 - O objetivo é encontrar uma função (chute) tal que $T(n) = O(f(n))$ e provar por indução em n .
- Método da Iteração:
 - Expande a recorrência e expressa ela como soma. Método mais utilizado.