

# Algumas Noções de Complexidade

Luís Lopes

DCC-FCUP

Estruturas de Dados

# Algoritmo

- ▶ um método para resolver um problema
- ▶ especifica, passo a passo, as operações a realizar
- ▶ as funções que manipulam as estruturas de dados que definimos são também algoritmos
- ▶ e.g., inserir elemento no fim de uma lista, encontrar o índice de um elemento na lista, remover um elemento no início da lista
- ▶ outros algoritmos operam sobre estruturas de dados completas
- ▶ e.g., ordenar um array, multiplicar matrizes, inverter uma lista

# Eficiência de um Algoritmo

- ▶ normalmente mede-se com base em 2 critérios em função do tamanho do input  $n$
- ▶ taxa de crescimento do *tempo de execução* (complexidade temporal)
- ▶ taxa de crescimento do *espaço usado na memória* (complexidade espacial)
- ▶ vamos centrar a nossa atenção na primeira métrica

# Análise da Eficiência

- ▶ descrição matemática do algoritmo em vez de implementação
- ▶ caracteriza o tempo de execução como uma função do tamanho do input
- ▶ tem em conta todos os possíveis inputs
- ▶ permite avaliar eficiência de forma independente do ambiente de hardware/software

# Exemplo

Estimativa do tempo de execução em função de  $n$

```
int findMax(int a[], int n) {
    int max = a[0];           // 2 operações
    int i   = 1;             // 1 operação
    while (i <= n - 1) {    // n operações
        // n-1 vezes ciclo
        if (a[i] > max)     // 2 operações
            max = a[i];     // 2 operações
        i = i + 1;         // 2 operações
    }
    return max;             // 1 operação
}
```

## Pressupostos

- ▶ contabilizar número de instruções primitivas
- ▶ memória de acesso aleatório e ilimitada
- ▶ e.g.,  $\text{max} = \text{a}[0]$  é composta por 2 operações primitivas
  - ▶ 1 leitura de  $\text{a}[0]$  + 1 atribuição a  $\text{max}$

## Exemplo (cont.)


- ▶ caso mais favorável ( $a[0]$  é o maior elemento):  
 $T(n) = 2 + 1 + n + 4(n - 1) + 1 = 5n$  operações primitivas
- ▶ pior caso:  
 $T(n) = 2 + 1 + n + 6(n - 1) + 1 = 7n - 2$
- ▶ caso médio depende da distribuição do input
- ▶ o pior caso dá-nos um limite superior do tempo de execução
- ▶ neste caso  $T(n) \propto n$

## Taxa de Crescimento de $T(n)$

- ▶ o tempo de execução,  $T(n)$ , pode ser afectado pela alteração do ambiente hardware/software
- ▶ tal não acontece se considerarmos a taxa de crescimento de  $T(n)$ : a variação de  $T(n)$  quando se aumenta o valor de  $n$ .
- ▶ para a função `findMax()`,  $T(n)$  é limitado por 2 funções lineares em  $n$
- ▶ diz-se que o crescimento de  $T(n)$  é linear

# Taxas de crescimento

logarítmica	$\log n$
linear	$n$
n-logarítmica	$n \log n$
quadrática	$n^2$
cúbica	$n^3$
exponencial	$a^n (a > 1)$



Crescimento de algumas funções:

$n$	$\log_2 n$	$\sqrt{n}$	$n$	$n \log_2 n$	$n^2$	$n^3$	$2^n$
2	1	1.4	2	2	4	8	4
8	3	2.8	8	24	64	512	256
16	4	4.0	16	64	256	4096	65536
...	...	...	...	...	...	...	...
1024	10	32	1024	10240	$> 10^6$	$> 10^9$	$> 10^{308}$



## Taxas de crescimento

Se assumirmos que cada operação pode ser executada em  $1\mu s$  (micro-sec), qual será o maior problema (função de  $n$ ) para um programa que execute em 1 seg., 1 min., 1 hora?

$T(n)$	Tamanho máximo problema ( $n$ )		
	<i>1 seg.</i>	<i>1 min.</i>	<i>1 hora</i>
$400n$	2500	150,000	9,000,000
$20n\lceil\log n\rceil$	4096	166,666	7,826,087
$2n^2$	707	5,477	42,426
$n^4$	31	88	244
$2^n$	19	25	31

No caso de crescimento exponencial, apenas conseguimos tratar problemas para dimensões muito pequenas de  $n$ .


# Ordem de Complexidade Assimptótica: $\mathcal{O}()$

Sejam  $f(n)$  e  $g(n)$  funções de  $\mathbb{N}_0 \mapsto \mathbb{R}$ .

$f(n)$  é  $\mathcal{O}(g(n))$  (ou seja,  $f(n)$  é da ordem de  $g(n)$ )

se  $\exists c > 0, \exists n_0 \geq 1 : f(n) \leq cg(n), \forall n \geq n_0$

Interpretação gráfica:



- ▶  $\mathcal{O}(g(n))$  corresponde ao limite superior da taxa de crescimento de  $f(n)$ .
- ▶ dizer que  $f(n)$  é  $\mathcal{O}(g(n))$ , significa dizer que  $f(n)$  não cresce mais do que  $g(n)$ .

## Exemplo

- ▶  $2n + 10$  é  $\mathcal{O}(n)$  porque:

$$2n+10 \leq cn \quad \Leftrightarrow \quad (c-2)n \geq 10 \quad \Leftrightarrow \quad n \geq \frac{10}{(c-2)}$$

para  $c = 3$  e  $n_0 = 10$  verifica-se sempre que  $2n + 10 \leq cn$

- ▶ outras funções:

$$\begin{aligned} 20n^3 + 10n \log n + 5 & \text{ — } \mathcal{O}(n^3) \\ a_k n^k + a_{k-1} n^{k-1} + \dots + a_0 & \text{ — } \mathcal{O}(n^k) \\ 3 \log n + \log \log n & \text{ — } \mathcal{O}(\log n) \\ 2^{100} & \text{ — } \mathcal{O}(1) \\ \frac{5}{n} & \text{ — } \mathcal{O}\left(\frac{1}{n}\right) \end{aligned}$$

# Algumas Propriedades Úteis

- ▶ Se  $h(n) \sim \mathcal{O}(f(n))$ , então  $\alpha h(n)$  (com  $\alpha > 0$ )  $\sim \mathcal{O}(f(n))$
- ▶ Se  $h_1(n) \sim \mathcal{O}(f(n))$  e  $h_2(n) \sim \mathcal{O}(g(n))$ , então  $h_1(n) + h_2(n) \sim \mathcal{O}(f(n) + g(n))$
- ▶ Se  $h_1(n) \sim \mathcal{O}(f(n))$  e  $h_2(n) \sim \mathcal{O}(g(n))$ , então  $h_1(n)h_2(n) \sim \mathcal{O}(f(n)g(n))$
- ▶ Se  $h(n) \sim \mathcal{O}(f(n))$  e  $f(n) \sim \mathcal{O}(g(n))$ , então  $h(n) \sim \mathcal{O}(g(n))$

## Exemplo: Método da Bolha (Bubble-Sort)

```
void bubbleSort(int a[], int n) {  
    int i, j, tmp;  
    for(int i = 0; i < n; i++)           // n iterações  
        for(int j = 0; j < n-1-i; j++) // n-i iterações  
                tmp      = a[j+1];  
                a[j+1] = a[j];  
                a[j]   = tmp;  
            }  
}
```

Efectivamente, o número de iterações total é a soma das iterações que o ciclo  $j$  faz para cada valor de  $i$ , i.e.

$$\begin{aligned} T(n) &\sim \sum_{i=1}^{n-1} (n-i) = (n-1) + (n-2) + \dots + 2 + 1 = \\ &= \frac{n(n-1)}{2} = \frac{n^2}{2} - \frac{n}{2} \\ &\Rightarrow T(n) \text{ é } \mathcal{O}(n^2) \end{aligned}$$

## Exemplo: Factorial

```
int factorial(int n) {  
    if (n == 0 || n == 1)           // 0(1)  
        return 1;                  // 0(1)  
    else  
        return n * factorial(n-1); // 0(1) + T(n-1)  
}
```

$$\therefore T(n) = \begin{cases} \alpha + T(n-1), & \text{se } n > 1 \\ \beta, & \text{se } n \leq 1 \end{cases}$$

assumindo  $n \geq 2$ :

$$T(n-1) = \alpha + T(n-2) \Rightarrow T(n) = 2\alpha + T(n-2)$$

em geral:  $T(n) = i\alpha + T(n-i), n > i$

se  $i = n - 1$ , então  $T(n) = \alpha(n-1) + T(1) = \alpha(n-1) + \beta$

donde podemos concluir que  $T(n)$  é  $\mathcal{O}(n)$

## Exemplo: Pesquisa Binária

```
int binarySearch(int[] values, int val, int low, int high) {
    if( high < low )
        return -1;
    else {
        int half = low + ( high - low ) / 2;
        if ( val == values[half] ) )
            return half;
        else if ( val < values[half] ) )
            return binarySearch(values, val, low, half - 1);
        else
            return binarySearch(values, val, half + 1, high);
    }
}
```

- ▶ em cada passo do ciclo, o intervalo reduz-se a metade.
- ▶ para um  $n$  dado, o algoritmo pára quando atingir um intervalo de tamanho  $\leq 1$

## Exemplo: Pesquisa Binária

- ▶ qual dos valores  $n/2, n/4, n/8, \dots, n/2^k \dots$  será o primeiro a ser  $\leq 1$ ?
- ▶ temos de resolver  $n/2^k \leq 1$ , o que dá um número de passos  $k \geq \log_2 n$
- ▶ tomando o mais pequeno inteiro  $k$  que satisfaz  $k \geq \log_2 n$  ( $k = \lceil \log_2 n \rceil$ ) sabemos que ao fim de um máximo de  $k$  iterações encontramos o valor no array ou podemos concluir que o valor que procuramos não existe
- ▶ deduzimos assim que  $T(n) = \lceil \log_2 n \rceil$  ou seja  $T(n)$  é  $\mathcal{O}(\log n)$