

Análise de Algoritmos

Nem todos os problemas algorítmicos que podem ser resolvidos em princípio podem ser resolvidos na prática: os recursos computacionais requeridos (tempo ou espaço) podem ser proibitivos.

- Suponha que duas soluções corretas diferentes sejam apresentadas para um mesmo problema matemático.
- Qual delas é a melhor?
 - Esta pergunta é praticamente impossível de ser respondida dada a dificuldade de encontrar critérios que as diferenciem de forma convincente.
- Considere agora dois algoritmos para a mesma tarefa.
- Qual deles é o melhor?

- Em geral, dizemos
 - que o mais rápido é o que consome menos memória.
- Tempo de execução é uma medida natural,
 - embora o processador, memória e compilador possam influenciar nos resultados da medição...
 - por exemplo, quando grandes quantidades de memória são usadas, as medidas de tempo são influenciadas por esse aspecto,

Introdução

- **Objetivos:**

Mostrar como medir o tempo de execução de um algoritmo através de ferramentas matemáticas que são independentes da máquina, da linguagem de implementação e do compilador.

- **Tópicos:**

- Medindo tempo em computador real **versus** modelo genérico de processador
- Custo de execução de um algoritmo
- Análise de um algoritmo **versus** análise da classe de problemas
- Análise de pior caso, melhor caso e caso médio
- Limite inferior para uma classe de problemas

Por que analisar um algoritmo?

- Descobrir suas **características** para avaliar sua adequação para várias aplicações
 - **Tempo de execução** - 2 formas
 - Custo real e custo não aparente como alocação de memória, carga, etc.
 - Número de vezes que uma operação relevante é executada
 - **Espaço ocupado** - memória necessária
- Compará-lo com outros algoritmos para a mesma aplicação

Formas de medir o custo de execução

- Execução em computador real (Empírica)
 - Importante quando existem vários algoritmos de uma mesma classe de complexidade
- Uso de um modelo genérico de processador, com execução seqüencial das operações (Teórica)

Independência da Análise com a Implementação

- Os resultados da análise **dependem** do compilador, da arquitetura de hardware e do ambiente operacional
 - Porém, na prática, ao invés de avaliar um algoritmo em um computador real usa-se um modelo **genérico** de um processador em que as instruções são executadas umas após as outras sem nenhuma concorrência, como uma MT.
 - Ainda, **ignoramos o custo** de algumas operações e **consideramos apenas as mais significativas** (ex: na ordenação consideramos o número de comparações de chaves)
 - Todo **comando** de atribuição, leitura, escrita, avaliação de comando condicional e avaliação em laço tem **tempo constante**.
 - Tempo não é tempo!! na realidade a complexidade de tempo representa o **número de vezes** que determinada **operação relevante** é executada

As abordagens são complementares

- As duas são necessárias no projeto e análise de algoritmos eficientes
 - Quando projetando um novo algoritmo utilizamos estudos de **complexidade computacional** em um modelo genérico para ter uma rápida idéia de como ele vai se comportar.
 - Este é o primeiro passo.
 - Uma **análise** de tempo real mais refinada é necessária para predizer o desempenho numa implementação real ou para compará-lo com outros algoritmos para a mesma tarefa.
 - Nesse segundo passo consideramos custos reais de operações e custos não aparentes como alocação de memória, indexação, carga, etc.

Como medir o custo de execução de um algoritmo

- Função de Custo ou Função de Complexidade
 $f(n)$ = medida de custo necessário para executar um algoritmo para um problema de **tamanho de entrada n**
 - Se $f(n)$ é uma medida da quantidade de tempo necessária para executar o algoritmo então f é chamada de função de **função de complexidade de tempo**
 - Se $f(n)$ é uma medida da quantidade de memória necessária para executar o algoritmo então f é chamada **função de complexidade de espaço**

Dois Tipos de Análises Predominam

- **Análise de um particular algoritmo**
 - Análise do número de vezes que cada parte do algoritmo deve ser executada
 - Estudo da quantidade de memória necessária
- **Análise de uma classe de algoritmos**
 - Estabelece limites para a complexidade computacional dos algoritmos pertencente à classe
 - Quanto determinamos o menor custo possível (limite inferior) para resolver problemas de uma classe, temos uma medida da dificuldade inerente da classe
 - Investiga-se toda uma classe para identificar um que seja o melhor possível
 - Algoritmo ótimo - custo é igual ao limite inferior
 - Veremos 3 exemplos.

Exemplo 1: Problema da Ordenação

Teorema 1 (Complexidade da Ordenação) - Qualquer algoritmo de ordenação baseado na abordagem de comparação deve usar pelo menos $\log N! \geq (n/2) \log n - n/2$ comparações para uma entrada. Requer $n \log n$ no pior caso.

Prova inteira em Aho, Hopcroft e Ullman - Data Structures and Algorithms

Intuitivamente o resultado segue da observação que:

cada comparação pode reduzir o número de possíveis permutações de elementos a serem considerados, no máximo por um fator de 2.

Desde que existem $N!$ possíveis permutações antes da ordenação e o objetivo é ter somente uma no final, o número de comparações deve ser pelo menos o número de vezes que $N!$ pode ser dividido por 2 antes de alcançar um número menor que 1.

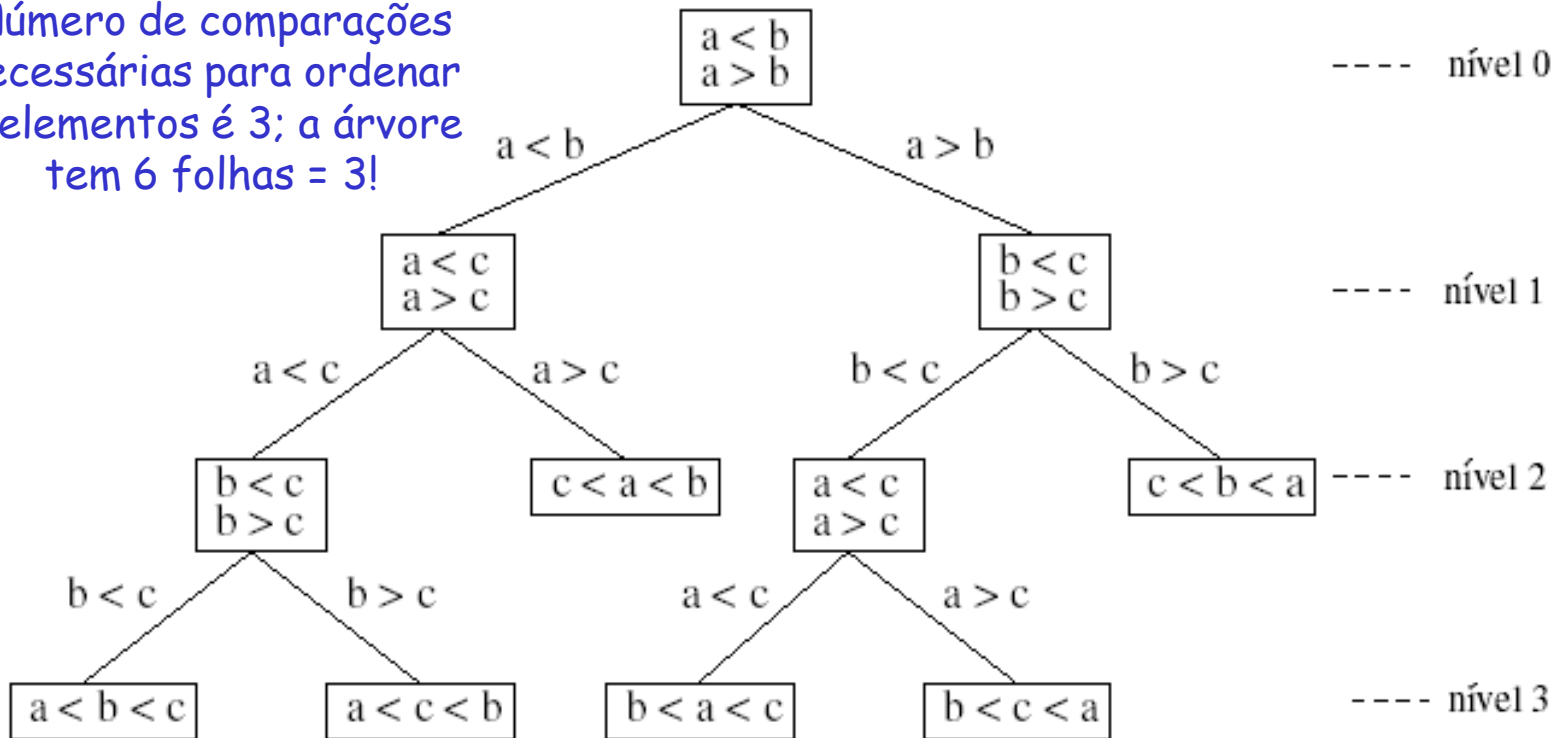
Aproximação de Stirling

- Qualquer algoritmo de ordenação de n itens por comparação deve ter uma **árvore de decisão com $n!$ folhas, de altura pelo menos igual a $\log(n!)$.**
- $n \log(n)$ é um limite inferior para $\log(n!)$,
 - assim nenhum algoritmo de ordenação por comparação pode ser mais rápido do que $O(n \log(n))$.

Árvore de decisão mostrando comparações na ordenação de 3 elementos

abc
acb
bac
bca
cba
cab

Número de comparações necessárias para ordenar 3 elementos é 3; a árvore tem 6 folhas = 3!



$N! \sim (n/e)^n e$, sendo $\log (n/e)^n = n \log n - n \log e$, ele é da ordem de $n \log n$.

Mais precisamente: $N!$ é o produto da metade de fatores que são cada um pelo menos $n/2$.

$$\text{Assim, } n! \geq (n/2)^{n/2}$$

$$\log(n!) \geq (n/2) \log (n/2) = (n/2) \log n - n/2$$

Do ponto de vista da Complexidade, o resultado do teorema demonstra que $N \log N$ é um **limite inferior** para a dificuldade do problema de ordenação por comparação de chaves.

Ordenação por Distribuição

- Existem métodos de ordenação que utilizam o princípio da distribuição.
- E utilizam informação a respeito da chave
 - Por exemplo, o fato dela poder ser quebrada em partes A e B e que A seja mais significativo que B
 - Exemplos de tipos de dados que permitem a aplicação:
 - inteiros (começa do dígito menos significativo - unidade) e
 - strings ($O(n \cdot L)$ com n strings e L o tamanho da maior string = $O(n)$)
- Exemplo de ordenação por distribuição:
 - considere o problema de ordenar um baralho com 52 cartas
 - Cada carta é representada como $U = U1 \times U2$ e usando ordem lexicográfica:

A < 2 < 3 < ... < 10 < J < Q < K (U2)

♣ < ♦ < ♥ < ♠ (U1)

Algoritmo

1. Distribuir as cartas abertas em treze montes: ases, dois, três, : : :, reis.
2. Colete os montes na ordem especificada.
3. Distribua novamente as cartas abertas em quatro montes: paus, ouros, copas e espadas.
4. Colete os montes na ordem especificada.

OBS1: ordenamos primeiro U2 depois U1

Radixsort, bucketsort (ou binsort)

- Métodos como o ilustrado são também conhecidos como **ordenação digital**, **radixsort (least-significant-digit-first radix sorting)** ou **bucketsort/binsort**.
- Binsort que trabalha **somente** com a permutação de valores entre $0..n-1$


```
for (i=0; i<n; i++)  
    B[A[i]] = A[i];
```

- O radix usa o binsort em cada parte da chave
- Os métodos não utilizam comparação entre chaves.
- Uma das dificuldades de implementar estes métodos está relacionada com o problema de lidar com cada monte.
- Se para cada monte nós reservarmos uma área, então a demanda por memória extra pode tornar-se proibitiva.
- O custo para ordenar um arquivo com n elementos é da ordem de $O(n)$, isto é, linear.

RadixSort


Initial List: 27 91 1 97 17 23 84 28 72 5 67 25

First pass
(on right digit)



Result of first pass: 91 1 72 23 84 5 25 27 97 17 67 28

Second pass
(on left digit)



Result of second pass: 1 5 17 23 25 27 28 67 72 84 91 97

Exemplo 2: Máximo de um conjunto

$A[1..n], n \geq 1$

```
Function Max (var A: vetor): integer;  
Var i, temp: integer;  
Begin  
    temp:=A[1];  
    for i:= 2 to n do  
        if A[i] > temp then temp:= A[i];  
    Max:= temp  
End.
```

Seja f a função de complexidade tal que $f(n)$ é o número de comparações entre os elementos de A se A tiver n elementos:

$$f(1) = 0$$

MAX é ótimo?

$$f(n) = n-1, n > 1$$

Teorema 2: Qualquer algoritmo para encontrar o maior elemento de um conjunto com n elementos $n \geq 1$, faz pelo menos $n-1$ comparações

Prova: Cada um dos $n-1$ elementos tem que ser mostrado, através de comparações, que é menor do que algum outro elemento. Logo $n-1$ comparações são necessárias.

Algoritmos Ótimos

- Se dispusermos de um algoritmo cujo custo é igual ao **limite inferior da classe**, então teremos um algoritmo ótimo para a tarefa,
 - no sentido de que a quantidade de recursos utilizada por qualquer outro algoritmo para a tarefa será maior, ou no melhor caso igual à do algoritmo que temos.
- Vejam que o limite inferior da classe é **provado teoricamente**, assim, em alguns casos MUITO trabalho ainda precisa ser feito antes que se consiga tal algoritmo.
 - Exemplo: **multiplicação de matrizes**. Método convencional $O(n^3)$; existe o método de Strassen com $O(n^{2.81})$, um ainda mais rápido com $O(n^{2.5})$ e teoricamente o limite inferior é $\Omega(n^{2+\xi})$.
- Muitas vezes, na prática, algoritmos não-ótimos são mais rápidos, mais claros e até consomem menos memória!

Exemplo 3: Pesquisa Seqüencial

Definição do Problema: Cada registro contém uma chave única que é utilizada para recuperar registros do arquivo. Dada uma chave qualquer o problema consiste em localizar o registro que contenha a chave.

Solução do problema: O algoritmo de pesquisa mais simples que existe é o que faz uma pesquisa seqüencial.

Seja f uma função de complexidade tal que $f(n)$ é o número de vezes que a chave de consulta é comparada com a chave de cada registro.

Melhor Caso:

o registro procurado é o primeiro consultado.

$$f(n) = 1$$

Pior Caso:

o registro procurado é o último consultado, ou então não está presente no arquivo.

$$f(n) = n$$

Caso Médio: considerando que toda pesquisa recupera um registro e sendo p_i a probabilidade de que o i -ésimo registro seja procurado e para recuperá-lo são necessárias i comparações: $f(n) = 1.p_1 + 2.p_2 + \dots + n.p_n$

Se cada registro tiver a mesma probabilidade de ser acessado, então $p_i = 1/n$, $1 \leq i \leq n$. $f(n) = 1/n(1 + 2 + 3 + \dots + n) = 1/n (1/2 n.(n+1)) = (n+1)/2$

$$\sum_{i=1}^n i \text{ (série aritmética)}$$

Melhor Caso, Pior Caso, Caso Médio

- Melhor Caso

Corresponde ao menor tempo de execução sobre todas as possíveis entradas de tamanho n .

(Se $n = 3$, 123, 132, ..., 321)

- Pior Caso:

Corresponde ao maior tempo de execução sobre todas as entradas de tamanho n .

- Caso Médio (ou caso esperado):

Corresponde à média dos tempos de execução de todas as entradas de tamanho n .

- Nesta análise, uma distribuição de probabilidades sobre o conjunto de entradas de tamanho n é suposta, e o custo médio é obtido com base nesta distribuição.
- É mais difícil de se obter do que as outras duas análises.

Diferenças entre Cálculo do Máximo e a Pesquisa Seqüencial

- O Algoritmo para encontrar o maior elemento de um conjunto possui **custo uniforme** sobre todos os tamanhos de entrada n .
- O Algoritmo da pesquisa seqüencial **depende da ordem** em que os registros aparecem.
 - Assim, fazemos o estudo do pior caso (**custo máximo**) e o do caso médio (**custo médio**), assumindo uma distribuição da entrada.

Link importante- Curso do Prof. Nivio Ziviani da UFMG

- <http://www.dcc.ufmg.br/~nivio/cursos/pa02/pa02apr.html>
- **Projeto de Algoritmos
com Implementações em Pascal e C**
Nivio Ziviani:
<http://www2.dcc.ufmg.br/livros/algoritmos/>