

Mais busca de palavras

Busca de palavras em um texto

Problema: Dados $P[1..m]$ e $T[1..n]$, encontrar o número de ocorrências de P em T .

Exemplo: Para $n = 10$, $m = 4$, e

PF 13

<http://www.ime.usp.br/~pf/algoritmos/aulas/strma.html>

	1	2	3	4	5	6	7	8	9	10
T	b	b	a	b	a	b	a	c	b	a

	1	2	3	4
P	b	a	b	a

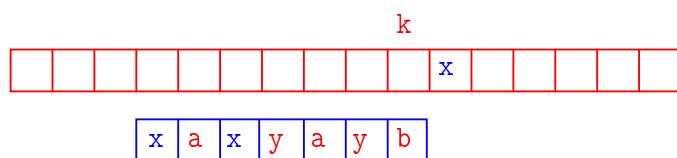
P ocorre 2 vezes em T.

Primeiro algoritmo de Boyer-Moore

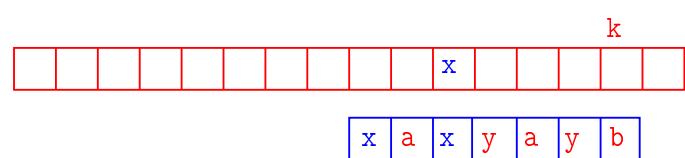
Primeiro algoritmo de Boyer-Moore

O primeiro algoritmo de R.S. Boyer e J.S. Moore (1977) é baseado na seguinte heurística.

O primeiro algoritmo de R.S. Boyer e J.S. Moore (1977) é baseado na seguinte heurística.



Boyer-Moore



Boyer-Moore

P = andando
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32
as andorinhas andam andando alto T
1 andando

P = andando
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32
as andorinhas andam andando alto T
1 andando
2 andando

Boyer-Moore

Boyer-Moore

Boyer-Moore

Boyer-Moore

Boyer-Moore

$P =$	a	b	a	b	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	T	
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23		
a	b	a	a	b	a	b	a	b	b	a	b	a	b	a	b	a	b	a	b	a	b	b	A	
1	a	b	a	b	b	b	a	b	b	a														
2		a	b	a	b	b	a	b	a	b	b	a												
3			a	b	a	b	b	a	b	a	b	b	a											
4				a	b	a	b	b	a	b	a	b	b	a										
5					a	b	a	b	b	a	b	a	b	b	a									
6						a	b	a	b	b	a	b	a	b	b	a								
7							a	b	a	b	b	a	b	a	b	a	b	a	b	b	a			

Boyer-Moore

P = a	b	a	b	b	a	b	a	b	a															T
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23		
a	b	a	a	b	a	b	a	b	b	a	b	a	b	a	b	b	a	b	a	b	b	a	T	
1	a	b	a	b	b	a	b	a	b	a														
2		a	b	a	b	b	a	b	a	b	b	a												
3			a	b	a	b	b	a	b	a	b	b	a											
4				a	b	a	b	b	a	b	a	b	b	a										
5					a	b	a	b	b	a	b	a	b	b	a									
6						a	b	a	b	b	a	b	a	b	b	a								
7							a	b	a	b	b	a	b	a	b	b	a							
8								a	b	a	b	b	a	b	a	b	a	b	a	b	a	b	a	T

Primeiro algoritmo de Boyer-Moore

Ideia: calcular um deslocamento de modo que $T[k+1]$ fique emparelhado com a última ocorrência do caractere $T[k+1]$ em P .

Suponha que o conjunto a que pertencem todos os elementos de P e de T é conhecido de antemão. Este conjunto é o **alfabeto** do problema.

Suponha que o alfabeto é o conjunto de todos os 256 caracteres.

Primeiro algoritmo de Boyer-Moore

Recebe vetores $P[1 \dots m]$ e $T[1 \dots n]$ de caracteres, com $m \geq 1$ e $n \geq 0$, e devolve o número de ocorrências de P em T .

```
int BoyerMoore (unsigned char P[], int m,
                 unsigned char T[], int n) {
    int ult[256];
    int i, r, k, ocorrs;

    /* pre-processamento da palavra P */
    1 for (i=0; i < 256; i++) ult[i] = 0;
    2 for (i=1; i <= m; i++) ult[P[i]] = i;
```

Pior caso

Primeiro algoritmo de Boyer-Moore

Para implementar essa ideia fazemos um pré-processamento de P , determinando para cada símbolo x do alfabeto a posição de sua última ocorrência em P .

P	1	2	3	4	5	6	7
	a	n	d	a	n	d	o

ult	0	...	'a'	'b'	'c'	'd'	'n'	'o'	'p'	...	255
	0	...	4	0	0	6	5	7	0

Primeiro algoritmo de Boyer-Moore

```
/* busca da palavra P no texto T */
3  ocorrs = 0; k = m;
4  while (k <= n) {
5      r = 0;
6      while (r < m && P[m-r] == T[k-r])
7          r += 1;
8      if (r == m) ocorrs += 1;
9      if (k == n) k += 1;
10     else k += m - ult[T[k+1]] + 1;
11 }
11 return ocorrs;
}
```

Melhor caso

$$\begin{array}{ccccccccc}
 P & = & a & a & a & a & b \\
 \hline
 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & 10 & 11 & 12 & 13 & 14 & 15 & 16 & 17 & 18 & 19 & 20 & 21 & 22 & 23 \\
 ? & ? & ? & a & c & ? & ? & ? & a & c & ? & ? & ? & ? & a & c & ? & ? & ? & ? & a & T \\
 \hline
 1 & a & a & a & a & b
 \end{array}$$

Melhor caso

$P = a \ a \ a \ a \ b$
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23
? ? ? ? a c ? ? ? ? a c ? ? ? ? a c ? ? ? ? a T
1 a a a a b
2 a a a a b

$P = a \ a \ a \ a \ b$
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23
? ? ? ? a c ? ? ? ? a c ? ? ? ? a c ? ? ? ? a T
1 a a a a b
2 a a a a b
3 a a a a b

Melhor caso

$P = a \ a \ a \ a \ b$
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23
? ? ? ? a c ? ? ? ? a c ? ? ? ? a c ? ? ? ? a T
1 a a a a b
2 a a a a b
3 a a a a b
4 a a a a b

Conclusões

O consumo de tempo da função BoyerMoore no pior caso é $O((n - m + 1)m)$.

O consumo de tempo da função BoyerMoore no melhor caso é $O(n/m)$.

Isto significa que no pior caso o consumo de tempo é essencialmente proporcional a mn .

Comentários finais

MACO122 Princípios de Desenvolvimento de Algoritmos

Edição 2012

Livros

Nossa referência básica **foi** o livro *PF = Paulo Feofiloff, Algoritmos em linguagem C,*



Este livro é baseado no material do sítio *Projeto de Algoritmos em C.*

Outros livros **foram**

S = Robert Sedgewick, Algorithms in C, vol. 1

CLRS = Cormen-Leiserson-Rivest-Stein, Introductions to Algorithms

MAC0122

MAC0122 Princípios de Desenvolvimento de Algoritmos **foi** uma disciplina introdutória em:

- ▶ **projeto de algoritmos**: recursão, algoritmos de enumeração, divisão-e-conquista, pré-processamento, heurísticas.
- ▶ **correção de algoritmos**: relações invariantes.
- ▶ **eficiência de algoritmos**: consumo de tempo, notação assintótica O, análise experimental.
- ▶ **estruturas de dados**: listas lineares encadeadas, listas encadeadas círculares, listas com e sem cabeça, filhas, pilhas, heaps.



Principais tópicos

Alguns dos tópicos de MAC0122 **foram**:

- ▶ recursão;
- ▶ busca em um vetor;
- ▶ busca (binária) em vetor ordenado;
- ▶ listas encadeadas;
- ▶ listas lineares: filas e pilhas;
- ▶ algoritmos de enumeração;
- ▶ busca de palavras em um texto;
- ▶ algoritmos de ordenação: bubblesort, heapsort, mergesort,...; e

Tudo isso regado a muita **análise de eficiência de algoritmos invariantes**.



Pausa para nossos comerciais

- ▶ **EP5**: segunda-feira, 3/DEZ
- ▶ **Prova 3**: terça-feira, 4/DEZ
- ▶ **Aula do Will**: quinta-feira, 6/DEZ (**cancelar?**)
- ▶ **Linux**: vocês devem usar
- ▶ **Página do BCC**: <http://bcc.ime.usp.br/>



MAC0122

MAC0122 **combinou** conceitos e recursos de programação:

- ▶ **recursão**
- ▶ **strings**
- ▶ **endereços e ponteiros**
- ▶ **registros e structs**
- ▶ **alocação dinâmica de memória**
- ▶ **interfaces**

que nasceram de aplicações cotidianas em ciência da computação.



C

*... There is an important pedagogical issue in choosing a language for our examples. Just as **no language** solves all problems equally well, no single language is best for presenting all topics. Higher-level languages preempt some design decisions. If we use a lower-level language, we get to consider alternative answers to the questions; by exposing more of the details, we can talk about them better. Experience shows that even when we use the facilities of high-level languages, it's invaluable to know how they relate to lower-level issues; without that insight, it's easy to run into performance problems and mysterious behavior. So we will often use C for our examples, even though in practice we might choose something else..."*

The Practice of Programming
Brian W. Kernighan e Rob Pike



Próximos anos

MAC0122 **foi** um primeiro passo para

- ▶ **MAC0323 Estruturas de Dados**
- ▶ **MAC0328 Algoritmos de Grafos**
- ▶ **MAC0338 Análise de Algoritmos**

Entretanto, várias outras disciplinas apoiam em **MAC0122**.

