Mais busca de palavras

PF 13

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

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

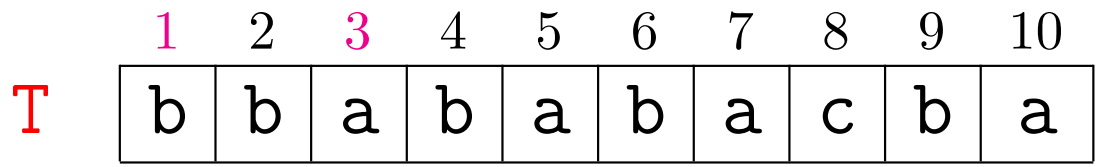

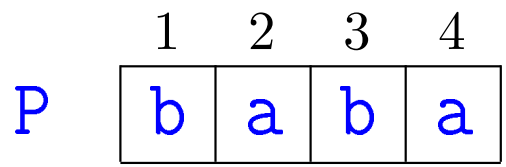

P ocorre 2 vezes em T.

Primeiro algoritmo de Boyer-Moore

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

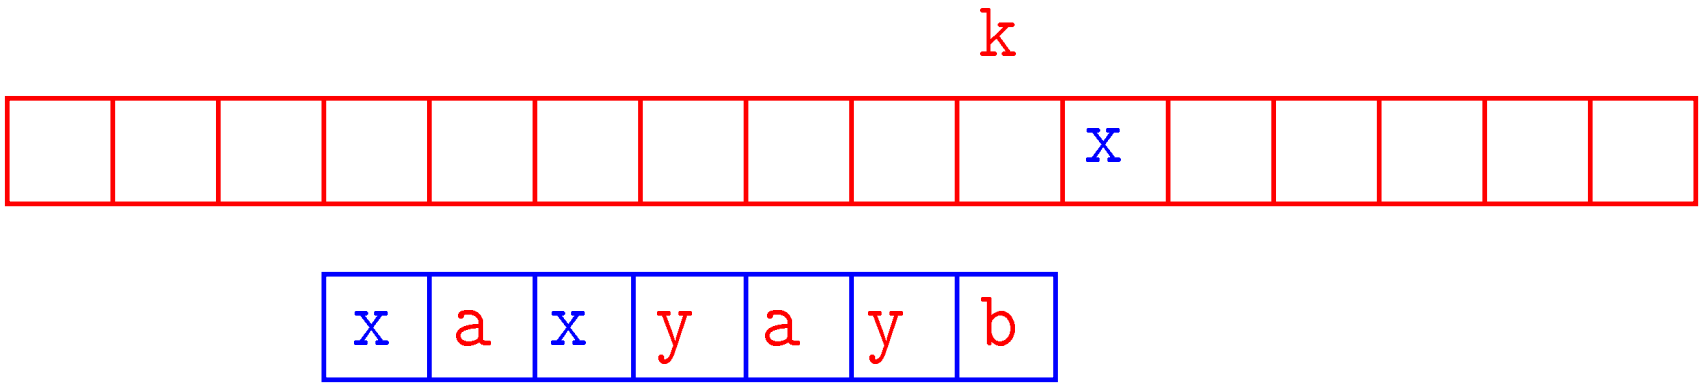

Primeiro algoritmo de Boyer-Moore

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

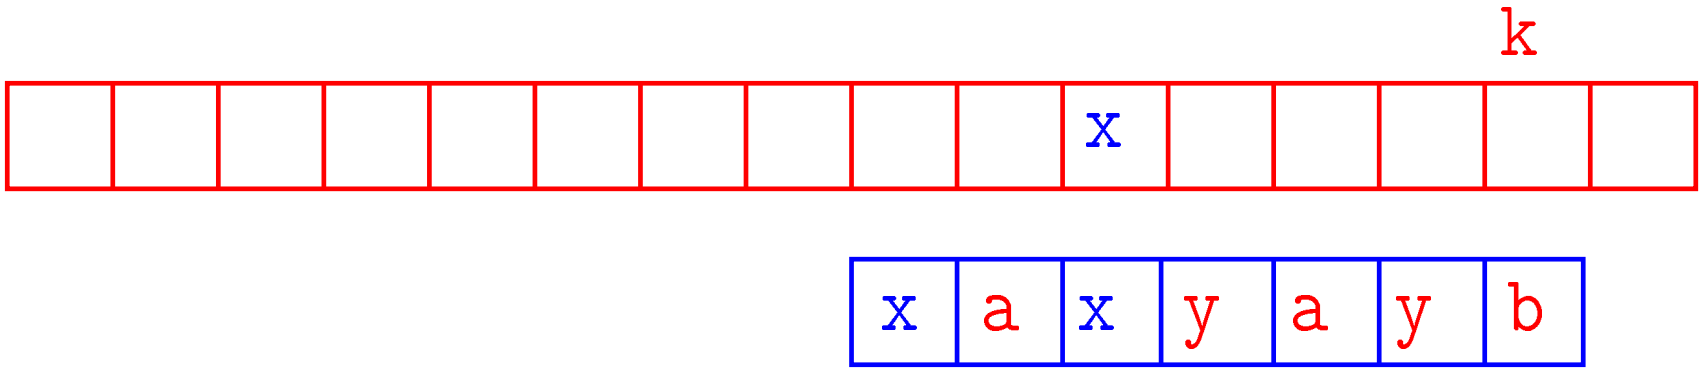

Boyer-Moore

P = a n d a n d o

```
  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
  a s   a n d o r i n h a s   a n d a m   a n d a n d o   a l t o T
  ---------------------------------------------------------------
1 a n d a n d o
```

Boyer-Moore

P = a n d a n d o

```
  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
  a s   a n d o r i n h a s   a n d a m   a n d a n d o   a l t o  T
  ---------------------------------------------------------------
1 a n d a n d o
2             a n d a n d o
```

Boyer-Moore

P = a n d a n d o

```
  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
  a s   a n d o r i n h a s   a n d a m   a n d a n d o   a l t o  T
  ---------------------------------------------------------------
1 a n d a n d o
2             a n d a n d o
3                 a n d a n d o
```

Boyer-Moore

P = a n d a n d o

```
  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
  a s   a n d o r i n h a s   a n d a m   a n d a n d o   a l t o  T
1 a n d a n d o
2           a n d a n d o
3               a n d a n d o
4                           a n d a n d o
```

Boyer-Moore

P = a n d a n d o

```
  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
  a s   a n d o r i n h a s   a n d a m   a n d a n d o   a l t o  T
  ---------------------------------------------------------------
1 a n d a n d o
2             a n d a n d o
3                 a n d a n d o
4                             a n d a n d o
5                               a n d a n d o
```

Boyer-Moore

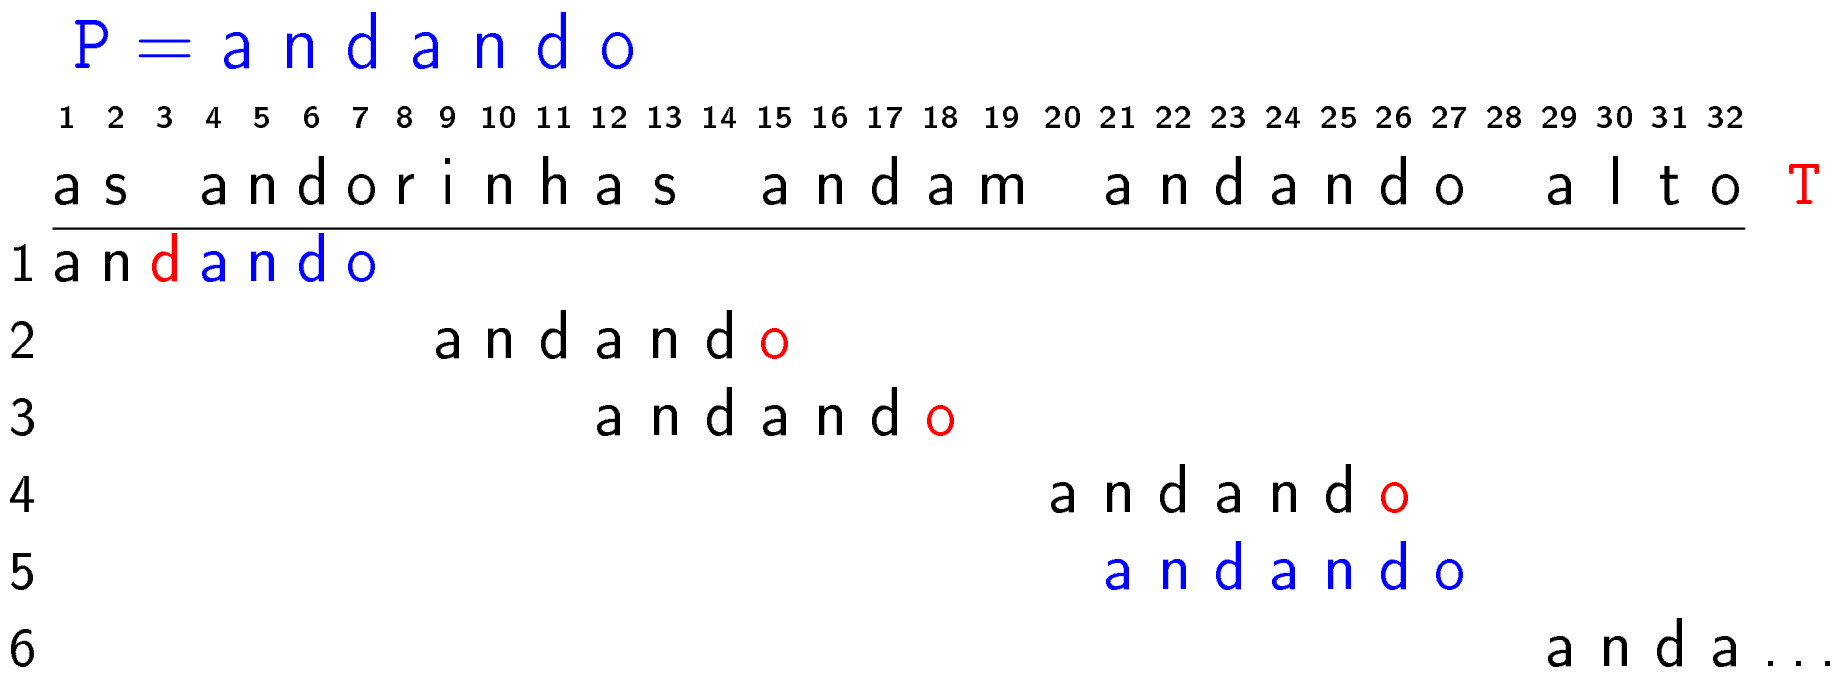
P = a n d a n d o
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32
a s a n d o r i n h a s a n d a m a n d a n d o a l t o T
1 a n d a n d o
2 a n d a n d o
3 a n d a n d o
4 a n d a n d o
5 a n d a n d o
6 a n d a . . .

Boyer-Moore

P = a b a b b a b a b b a

	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	b	a													

Boyer-Moore

P = a b a b b a b a b b a

	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	b	a													
2			a	b	a	b	b	a	b	a	b	b	a											

Boyer-Moore

P = a b a b b a b a b b a

	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	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									

Boyer-Moore

P = a b a b b a b a b b a

	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	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							

Boyer-Moore

P = a b a b b a b a b b a

	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	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						

Boyer-Moore

P = a b a b b a b a b b a

	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	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				

Boyer-Moore

P = a b a b b a b a b b a

	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	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		

Boyer-Moore

P = a b a b b a b a b b a

	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	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	b	a	

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

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.

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

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

Primeiro algoritmo de Boyer-Moore

Recebe vetores P[1 . . m] e T[1 . . 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;
```

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   return ocorrs;
  }
```

Pior caso

P = a a a a a a a a a a a

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

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

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													

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							

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

MAC0122 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 ciculares, listas com e sem cabeça, filas, pilhas, heaps.

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.

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 e invariantes.

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. Kernigham e Rob Pike

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/

Próximos anos

MAC0122 **foi** um primeiro passo para

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

Entretanto, várias outras disciplina se apoiam em MAC0122.