

Busca de palavras (string matching)

AULA 24

PF 13

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

A set of small, light-blue navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and table of contents.

A set of small, light-gray navigation icons typically found in presentation software like Beamer. From left to right, they include: a left arrow, a square, a right arrow, a double left arrow, a double square, a double right arrow, a double left arrow with a vertical bar, a double right arrow with a vertical bar, a double left arrow with a horizontal bar, a double right arrow with a horizontal bar, a double left arrow with a diagonal bar, a double right arrow with a diagonal bar, a double left arrow with a curved bar, a double right arrow with a curved bar, a magnifying glass, and a question mark.

Busca de palavras em um texto

Dizemos que um vetor $p[1..m]$ ocorre em um vetor $t[1..n]$ se

$$p[1..m] = t[s+1..s+m]$$

para algum s em $[0..n-m]$.

Exemplo:

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

	1	2	3	4
p	b	c	b	a

`p[1..4]` ocorre em `t[1..10]` com deslocamento 5.

Algoritmo trivial

$$p = a \ b \ a \ b \ b \ a \ b \ a \ b \ b \ a$$

A set of small, light-blue navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and table of contents.

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

	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.

Algoritmo trivial

$$p = a \ b \ a \ b \ b \ a \ b \ a \overset{\circ}{b} \ b \ a$$

A set of small, light-blue navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and table of contents.

Algoritmo trivial

$$p = a \ b \ a \ b \ b \ a \ b \ a \overset{\circ}{b} \ b \ a$$

Algoritmo trivial

$$p = a \ b \ a \ b \ b \ a \ b \ a \ b \ b \ a$$

Algoritmo trivial

$$p = a \ b \ a \ b \ b \ a \ b \ a \ b \ b \ a$$

Algoritmo trivial

Devolve o número de ocorrências de `p` em `t`.

```

int trivial (unsigned char p[], int m,
             unsigned char t[], int n) {
    int r, k, occurs = 0;
    for (k = 1; k <= n-m+1; k++) {
        r = 0;
        while (r < m && p[1+r] == t[k+r])
            r += 1;
        if (r == m) occurs += 1;
    }
    return occurs;
}

```

Algoritmo trivial

Relação invariante: no início da linha 3 vale que

(i0) $p[1..1+r-1] = t[k..k+r-1]$

Consumo de tempo

Consumo de tempo da função `trivial`, versão direita para a esquerda.

linha **todas** as execuções da linha

$$\begin{aligned}
 1 &= n - m + 2 \\
 2 &= n - m + 1 \\
 3 &\leq (n - m + 1)(m + 1) \\
 4 &\leq (n - m + 1)m \\
 5 &= n - m + 1 \\
 6 &= 1
 \end{aligned}$$

$$\begin{aligned} \text{total} &< 3(n - m + 2) + 2(n - m + 1)(m + 1) \\ &= O((n - m + 1)m) \end{aligned}$$

Pior caso

$p = aaaaaaaaaaaaaaaaaaaaaaaaaaaaaaaaat$

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 aaaaaaaaaaaaaaaaaaaaaaaa
2 aaaaaaaaaaaaaaaa
3 aaaaaaaaaaaaaaaa
4 aaaaaaaaaaaaaaaa
5 aaaaaaaaaaaaaaaa
6 aaaaaaaaaaaaaaaa
7 aaaaaaaaaaaaaaaa
8 aaaaaaaaaaaaaaaa
9 aaaaaaaaaaaaaaaa
10 aaaaaaaaaaaaaaaa
11 aaaaaaaaaaaaaaaa
12 aaaaaaaaaaaaaaaa
13 aaaaaaaaaaaaaaaa

◀ □ ▶ ⌂ ▶ ⌂ ▶ ⌂ 🔍 🔍

Melhor caso

$p = baaaaaaaaaaaaaaaaaaaaaaaat$

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 baaaaaaaaaaaaaaa
2 baaaaaaaaaaaa
3 baaaaaaaaaaa
4 baaaaaaaaaaa
5 baaaaaaaaaaa
6 baaaaaaaaaaa
7 baaaaaaaaaaa
8 baaaaaaaaaaa
9 baaaaaaaaaaa
10 baaaaaaaaaaa
11 baaaaaaaaaaa
12 baaaaaaaaaaa
13 baaaaaaaaaaa

◀ □ ▶ ⌂ ▶ ⌂ ▶ ⌂ 🔍 🔍

Conclusões

Algoritmo trivial: direita para esquerda
 $p = abababbababba$

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	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	t

1 abababbababba

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

O consumo de tempo da função **trivial** no **melhor caso** é $O(n - m + 1)$.

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

◀ □ ▶ ⌂ ▶ ⌂ ▶ ⌂ 🔍 🔍

Algoritmo trivial: direita para esquerda
 $p = abababbababba$

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	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	t

1 abababbababba
2 abababbababba

◀ □ ▶ ⌂ ▶ ⌂ ▶ ⌂ 🔍 🔍

Algoritmo trivial: direita para esquerda
 $p = abababbababba$

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	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	t

1 abababbababba
2 abababbababba
3 abababbababba

◀ □ ▶ ⌂ ▶ ⌂ ▶ ⌂ 🔍 🔍

◀ □ ▶ ⌂ ▶ ⌂ ▶ ⌂ 🔍 🔍

Algoritmo trivial: direita para esquerda

$p = a b a b b a b a b b a$

```

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

```

Algoritmo trivial: direita para esquerda

$p = a b a b b a b a b b a$

```

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

```

Algoritmo trivial: direita para esquerda

$p = a b a b b a b a b b a$

```

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
9 a b a b b a b a b b a
10 a b a b b a b a b b a
11 a b a b b a b a b b a
12 a b a b b a b a b b a
13 a b a b b a b a b b a

```

Algoritmo trivial: direita para esquerda

$p = a b a b b a b a b b a$

```

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

```

Algoritmo trivial: direita para esquerda

$p = a b a b b a b a b b a$

```

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

```

Algoritmo trivial: direita para esquerda

Devolve o número de ocorrências de p em t .

```

int trivial (unsigned char p[], int m,
             unsigned char t[], int n) {
    int r, k, ocorrs = 0;
    for (k = m; k <= n; k++) {
        r = 0;
        while (r < m && p[m-r] == t[k-r])
            r += 1;
        if (r == m) ocorrs += 1;
    }
    return ocorrs;
}

```

Algoritmo trivial: direita para esquerda

Relação invariante: no início da linha 3 vale que

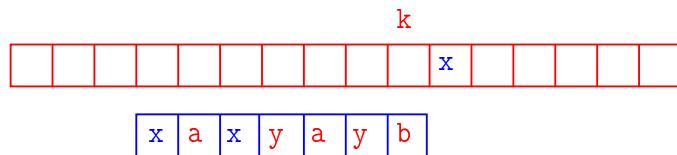
$$(i0) p[m-r+1..m] = t[k-r+1..k]$$

Algoritmo trivial: direita para esquerda

```
int trivial (unsigned char p[], int m,
             unsigned char t[], int n) {
    int r, k, ocorrs;
    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     k += 1;
    }
11 return ocorrs;
}
```

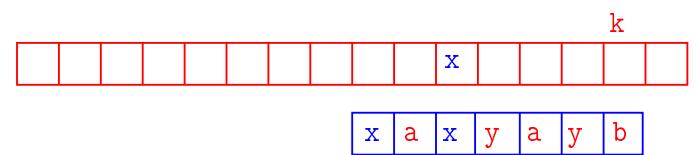
Primeiro algoritmo de Boyer-Moore

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



Boyer-Moore

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



Boyer-Moore

$p = \underline{a} \underline{n} \underline{d} \underline{a} \underline{n} \underline{d} \underline{o}$
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
as andorinhas andam andando alto t
1 andando

$p = \underline{a} \underline{n} \underline{d} \underline{a} \underline{n} \underline{d} \underline{o}$
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
as andorinhas andam andando alto t
1 andando
2 andando

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
2 andando
3 andando

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

2 andando
3 andando
4 andando

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
2 andando
3 andando
4 andando
5 andando

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

2 andando

3 andando

4 andando

5 andando

6 andando

Boyer-Moore

Boyer-Moore

Boyer-Moore

$$p = a \ b \ a \ b \ b \ a \ b \ a \ b \ b \ a$$

Boyer-Moore

$$p = a \ b \ a \ b \ b \ a \ b \ a \ b \ b \ a$$

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	
1	a	b	a	b	b	b	a	b	b	a													
2			a	b	a	b	b	a	b	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

$$p = a \ b \ a \ b \ b \ a \ b \ a \ b \ b \ a$$

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	b	a	b	a	b	a	b	b	a	b	a	b	a	b	b	a
1	a	b	a	b	a	b	a	b	b	a													t
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	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	a	b	a	b	a	b	b	a	b	a	b	b	a	
1	a	b	a	b	b	b	a	b	a	b	b	a											t
2		a	b	a	b	b	a	b	a	b	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	b	a								
5					a	b	a	b	b	a	b	a	b	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	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

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;
```

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 .

	1	2	3	4	5	6	7						
p	a	n	d	a	n	d	o						
ult	0	...	'a'	'b'	'c'	'd'	'n'	'o'	'p'	...	255

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 }
12 return ocorrs;
}
```

Melhor caso

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	c	?	?	a	t
1	a	a	a	a	b																		
2						a	a	a	a	b													
3							a	a	a	b										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	b												
4								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 e no melhor caso o algoritmo é **sublinear**.