

Complementando a aula passada

AULA 24

Tabelas de dispersão (*hash tables*)

Uma **tabela de dispersão** (= *hash table*) é uma maneira de organizar uma tabela de símbolos.

Inventadas para funcionar bem **em média**.

universo de chaves = conjunto de **todas** as possíveis chaves

chaves realmente usadas são, em geral, uma **parte pequena** do universo.

A tabela terá a forma **tab[0..M-1]**, onde **M** é o **tamanho da tabela**.

Funções de dispersão

Uma **função de dispersão** (= *hash function*) é uma maneira de mapear o **universo de chaves** no conjunto de **índices** da tabela.

A função de dispersão recebe uma **chave** e retorna um número inteiro **h** no intervalo $0 \dots M-1$.

O número **h** é o **código de dispersão** (= *hash code*) da chave.

Exemplo de uma função de dispersão **modular**:

```
int hash(Chave chave, int M) {  
    return chave % M;  
}
```

Função de dispersão básica

Para evitar *overflow* usamos o método de Horne e tomamos o resto da divisão após cada multiplicação:

```
int hash(Chave chave, int M)
{
    int i, h = 0;
    int primo = 127;
    for (i = 0; chave[i] != '\0'; i++)
        h = (h * primo + chave[i]) % M;
    return h;
}
```

Colisões

Como o **número de chaves** é em geral **maior** que **M**, é inevitável que a função de dispersão leve várias **chaves diferentes** no **mesmo índice**.

Dizemos que há uma **colisão** quando duas **chaves diferentes** são levadas no **mesmo índice**.

Algumas maneiras de tratar colisões:

- ▶ lista encadeadas (*=separating chaining*);
- ▶ sondagem linear (*=linear probing (open addressing)*);
- ▶ *double hashing (open addressing)*;

Colisões por sondagem linear

Um outro método de resolução de colisões é conhecido como sondagem linear (*=linear probing*).

Todos os objetos são armazenados em um vetor $\text{tab}[0 \dots M-1]$.

Quando ocorre uma colisão, procuramos a próxima posição vaga do vetor.

Digamos que a tabela tem M posições e contém N chaves num dado instante.

O fator de carga $\alpha = N/M$ da tabela é menor do que 1. Quanto maior o fator de carga, mais tempo as funções de busca e inserção vão consumir.

Interface

```
typedef char *String;
typedef String Chave;
typedef int Valor;

void stInit(int);
void stInsert(Chave, Valor);
Valor stSearch(Chave);
void stFree();
void stDelete(Chave);
```

Implementação

```
#define LIVRE(h) (tab[h].chave == NULL)
#define INCR(h) (h = h == M-1? 0: h+1)

static int hash(Chave chave, int M);

typedef struct celTS CelTS;
struct celTS {
    Chave chave;
    Valor valor;
};

static CelTS *tab = NULL;
static int nChaves = 0;
static int M; /* tam. da tabela */
```

stInit

```
void stInit(int max)
{
    int h;
    M = max;
    nChaves = 0;
    tab = mallocSafe(M * sizeof(CelTS));
    for (h = 0; h < M; h++)
        tab[h].chave = NULL;
}
```

stInsert

```
void stInsert(Chave chave, Valor valor) {
    CelTS *p;    int h = hash(chave,M);
    while(!LIVRE(h)&&strcmp(tab[h].chave,chave))
        INCR(h);
    if (LIVRE(h)) {
        if (nChaves == M-1) {
            printf("Tabela cheia\");
            return;
        }
        tab[h].chave = copyString(chave);
        nChaves += 1;
    }
    tab[h].valor = valor;
}
```

stSearch

```
Valor stSearch(Chave chave) {
    CelTS *p = NULL;
    int h;

    /* procure chave na tabela */
    h = hash(chave,M); /* codigo de hash */
    while(!LIVRE(h)&&strcmp(tab[h].chave,chave))
        INCR(h);

    if (LIVRE(h)) return 0;
    return tab[h].valor;
}
```

stDelete

```
void stDelete(Chave chave) {
    int h;

    /* procure chave na tabela */
    h = hash(chave,M); /*codigo de hash*/
    while(!LIVRE(h)&&strcmp(tab[h].chave,chave))
        INCR(h);
    if (LIVRE(h)) return;

    /* remova chave da tabela */
    nChaves -= 1;
    free(tab[h].chave);
    tab[h].chave = NULL;
```

stDelete

```
/* faça rehash das chaves seguintes */
for (INCR(h); !LIVRE(h); INCR(h)) {
    Chave chave = tab[h].chave;
    Valor valor = tab[h].valor;
    tab[h].chave = NULL;
    stInsert(chave, valor); /* rehash */
    free(chave);
}
```

stFree

```
void stFree() {  
    int h;  
    for (h = 0; h < M; h++)  
        if (!LIVRE(h))  
            free(tab[h].chave);  
    free(tab);  
    tab = NULL  
    nChaves = 0;  
    M = 0;  
}
```

AULA 25

Busca de palavras (string matching)

PF 13

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

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**.

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

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

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	a	b	a	b	b	a											t

Algoritmo trivial

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

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

Algoritmo trivial

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

	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	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										

Algoritmo trivial

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

	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	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									

Algoritmo trivial

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

	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	a	b	a	b	a	b	b	a	b	a	b	a	b	b	a	b	a	b	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	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	a	b	a	b	b	a						
12											a	b	a	b	b	a	b	a	b	b	a				
13												a	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, ocorrs = 0;
1   for (k = 1; k <= n-m+1; k++) {
2       r = 0;
3       while (r < m && p[1+r] == t[k+r])
4           r += 1;
5       if (r == m) ocorrs += 1;
    }
6   return ocorrs;
}
```

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

$$1 = n - m + 2$$

$$2 = n - m + 1$$

$$3 \leq (n - m + 1)(m + 1)$$

$$4 \leq (n - m + 1)m$$

$$5 = n - m + 1$$

$$6 = 1$$

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

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	t
1	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
2	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
3	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
4	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
5	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
6	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
7	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
8	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
9	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
10	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
11	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
12	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
13	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	

Melhor caso

$p = b \text{ a a a a a a a a a a}$

	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	t
1	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
2	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
3	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
4	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
5	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
6	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
7	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
8	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
9	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
10	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
11	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
12	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
13	b	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	

Conclusões

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

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

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	a	b	b	a													t

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

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	
1	a	b	a	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									

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
1	a	b	a	b	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								

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
1	a	b	a	b	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							

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
1	a	b	a	b	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						

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		
1	a	b	a	b	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								
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

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;
1   for (k = m; k <= n; k++) {
2       r = 0;
3       while (r < m && p[m-r] == t[k-r])
4           r += 1;
5       if (r == m) ocorrs += 1;
    }
6   return ocorrs;
}
```

Algoritmo trivial: direita para esquerda

Relação invariante: no início da linha 3 vale que

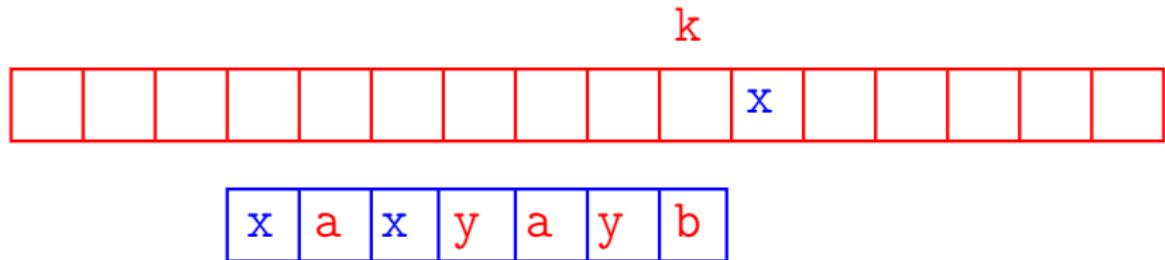
$$(i0) \ p[m-r+1..m] = t[k-r+1..k]$$

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;
}
```

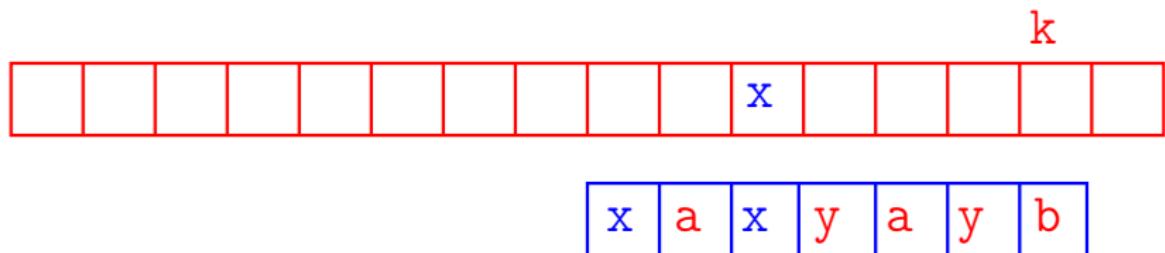
Primeiro algoritmo de Boyer-Moore

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



Primeiro algoritmo de Boyer-Moore

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



Boyer-Moore

$p = \text{a n d a n d o}$

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

as andorinha s andam andando alto t
1 andando

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

$p = \text{a n d a n d o}$

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

as andorinha s andam andando alto t
1 andando

2 andando

3 andando

Boyer-Moore

$p = \text{a n d a n d o}$

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

as andorinha s andam andando alto t
1 andando

2 andando

3 andando

4 andando

Boyer-Moore

$p = \text{a n d a n d o}$

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

as andorinha s andam andando alto t
1 andando

2 andando

3 andando

4 andando

5 andando

Boyer-Moore

$p = \text{a n d a n d o}$

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
1	a	b	a	b	b	a	b	a	b	b	a											t

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	a	b	b	b	a												t
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
1	a	b	a	b	b	a	b	a	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								

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	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								

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	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	a	b	b	a						
5					a	b	a	b	b	a	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	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						

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	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					

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	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					
8								a	b	a	b	b	a	b	a	b	b	a				

Primeiro algoritmo de Boyer-Moore

Ideia (“*bad-character heuristic*”): 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 }
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	t
1	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
2	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
3	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
4	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
5	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
6	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
7	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
8	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
9	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
10	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
11	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
12	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
13	a	a	a	a	a	a	a	a	a	a	a	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

a a a a b

a a a a b

Conclusões

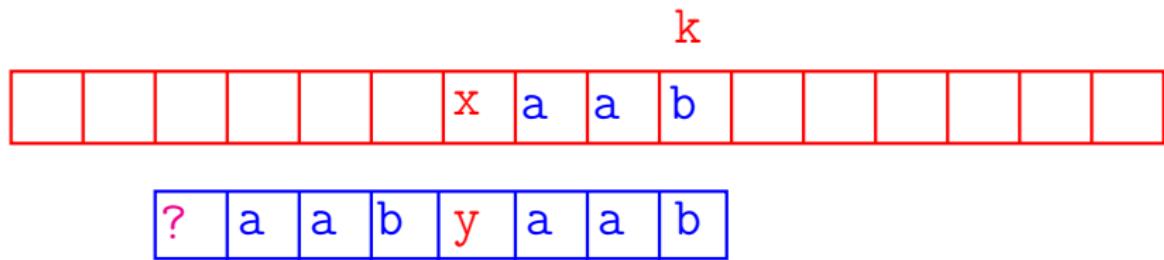
O consumo de tempo da função BoyerMoore no pior caso é $O((n - m + 1)m)$.

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 e no melhor caso o algoritmo é **sublinear**.

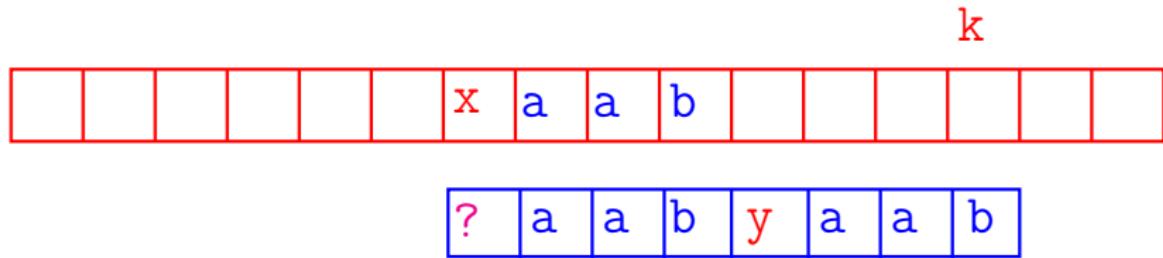
Segundo algoritmo de Boyer-Moore

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



Segundo algoritmo de Boyer-Moore

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



Boyer-Moore 2

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 2

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 2

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 2

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 2

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 2

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 n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

8 a n d a n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

8 a n d a n d o

9 a n d a n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

8 a n d a n d o

9 a n d a n d o

10 a n d a n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

8 a n d a n d o

9 a n d a n d o

10 a n d a n d o

11 a n d a n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

8 a n d a n d o

9 a n d a n d o

10 a n d a n d o

11 a n d a n d o

15 a n d a n d o

Boyer-Moore 2

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 n d o

7 a n d a n d o

8 a n d a n d o

9 a n d a n d o

10 a n d a n d o

11 a n d a n d o

15 a n d a n d o

16

 a n d a ...

Boyer-Moore 2

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

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
<hr/>																						
1	a	b	a	b	b	a	b	a	b	a	b	a	b	a	b	b	a	t				

Boyer-Moore 2

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

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 2

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

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	t	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					

Boyer-Moore 2

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

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 2

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

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	t	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	t	a	b	a	b	b	b	a					
5							a	b	a	b	b	a	b	a	b	b	a					

Boyer-Moore 2

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

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	t	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	t	a	b	a	b	b	b	a					
5											a	b	a	b	b	a	b	a	b	b	a	
6												a	b	a	b	b	a					...

Boyer-Moore 2

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

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	t	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	t	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

Segundo algoritmo de Boyer-Moore

Ideia (*good-suffix heuristic*): para cada índice i calcular o maior j em $1 \dots m-1$ tal que

- ▶ $p[1 \dots j]$ é um **sufixo** de $p[i \dots m]$ ou
- ▶ $p[i \dots m]$ é um **sufixo** de $p[1 \dots j]$.

Para implementar essa ideia basta fazermos um pré-processamento que **só depende** de p .

Segundo algoritmo de Boyer-Moore

Para implementar essa ideia, fazemos um pré-processamento de p , determinando para cada índice i o índice $\text{alcance}[i]$ de um “sufixo bom”.

	1	2	3	4	5	6	7	8	9	10	11
p	a	b	a	b	b	a	b	a	b	b	a

	1	2	3	4	5	6	7	8	9	10	11
alcance	6	6	6	6	6	6	6	6	6	8	8

Segundo algoritmo de Boyer-Moore

Para implementar essa ideia fazemos um pré-processamento de p , determinando para cada símbolo índice i o índice **alcance**[i] de um “sufixo bom”.

	1	2	3	4	5	6
p	c	a	a	b	a	a

	1	2	3	4	5	6
alcance	0	0	0	0	3	5

Segundo 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 BoyerMoore2 (unsigned char p[], int m,
                  unsigned char t[], int n) {
    int *alcance;
    int i, r, k, ocorrs;
    /* pre-processamento da palavra p */
1   alcance = preProcessamento(p, m);
2   /* em branco */
```

Segundo 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 (r == 0) k += 1;
10     else k += m - alcance[m-r+1];
11 }
11 free(alcance);
12 return ocorrs;
}
```

Pré-processamento

```
int *
preProcessamento(unsigned char p[], int m) {
    int i, r, j, *alcance;
    alcance = malloc((m+1)*sizeof(int));
1   for (i = m; i >= 1; i--) {
2       j = m-1; r = 0
3       while (m-r >= i && j-r >= 1)
4           if (p[m-r] == p[j-r]) r += 1;
5           else j -= 1, r = 0;
6       alcance[i] = j;
7   }
8   return alcance;
}
```

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	t
1	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
2	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
3	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
4	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
5	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
6	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
7	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
8	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
9	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
10	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
11	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
12	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	a	
13	a	a	a	a	a	a	a	a	a	a	a	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
?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	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
?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	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
?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	t

1 a a a a b

a a a a b

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
? ? ? c b ? ? ? c b ? ? ? c b ? ? ? c b ? ? ? 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

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
?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	?	c	b	?	?	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											
5								a	a	a	a											

Conclusões

O consumo de tempo da função BoyerMoore2 no pior caso é $O((n - m + 1)m)$.

O consumo de tempo da função BoyerMoore2 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.

Terceiro algoritmo de Boyer-Moore

O algoritmo de Boyer-Moore propriamente dito é uma fusão dos dois anteriores:

*a cada passo, o algoritmo escolhe o maior dos deslocamentos ditados pelas tabelas *ult* e *alcance*.*