Projeto e Análise de Algoritmos

Aula 06 – Busca de Padrões em Texto

Edirlei Soares de Lima
<edirlei@iprj.uerj.br>

Processamento de Texto

- **Cadeia de caracteres:** sequência de elementos denominados caracteres.
- Os **caracteres** são escolhidos de um conjunto denominado alfabeto.
- **Casamento de cadeias de caracteres** (string matching) ou **casamento de padrão** (pattern matching): encontrar todas as ocorrências de um padrão em um texto.
- **Exemplos de aplicação:** edição de texto, recuperação de informação, estudo de sequências de DNA em biologia computacional, ...

Processamento de Texto

- **Texto:** arranjo T[1..*n*] de tamanho *n*.
- **Padrão:** arranjo P[1..*m*] de tamanho $m \leq n$.
- Os elementos de P e T são escolhidos de um alfabeto finito α de tamanho c.
  - Exemplo: α = {0, 1} ou α = {a, b, ..., z}
- **Casamento de cadeias ou casamento de padrão:** dados duas cadeias P (padrão) de comprimento *m* e T (texto) de comprimento *n*, onde $n \leq m$, deseja-se saber as ocorrências de P em T.

Cadeias de Caracteres

- “CGTAAACTGCTTTAATCAAACGC”
  - Cadeias de moléculas chamadas bases: adenina (A), guanina (G), citosina (C) e timina (T)
- “Projeto e Análise de Algoritmos”
- “http://www.iprj.uerj.br”
- “if ((x==0) && (y!=3))”

Encontrando Padrões em Textos

- Exemplo:
  - T = “kvjlixapejrbxeenpphkhthbkwyrwamnugzhppfxiyjyanhapfwbghxm shrlyujfjhrsovkvveylnbxnawavgizyvmfohigeabgksfnbkmffxjffqbualeytqr phyrbjqdjqavctgxjifqgfgydhoiwhrvwqbxgrixydzbpajnhopvlamhhfavoctd fytvvggikngkwzixgjtlxkozjlefilbrboignbzsudssvqymnapbpqvlubdoyxkkw hcoudvtkmikansgsutdjythzl”
  - P = “avoctdfytvv”

Encontrando Padrões em Textos (Força Bruta)

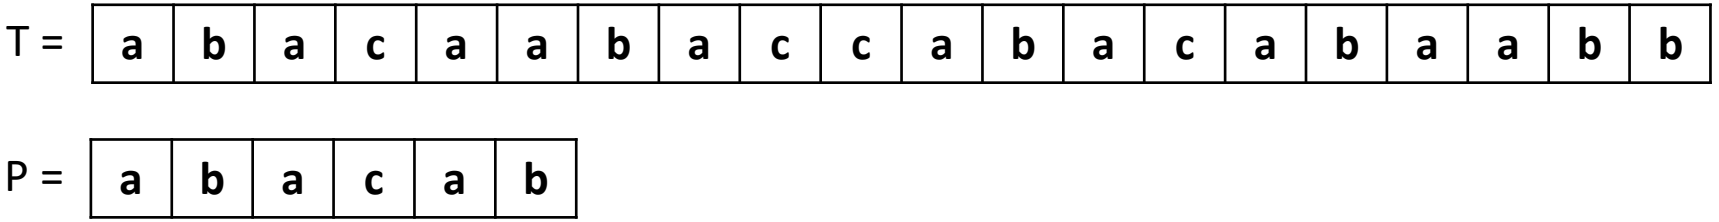

- **Objetivo:** descobrir se a string P (padrão) está em T
- **Força bruta:** caminha elemento a elemento da esquerda para a direita

Encontrando Padrões em Textos (Força Bruta)

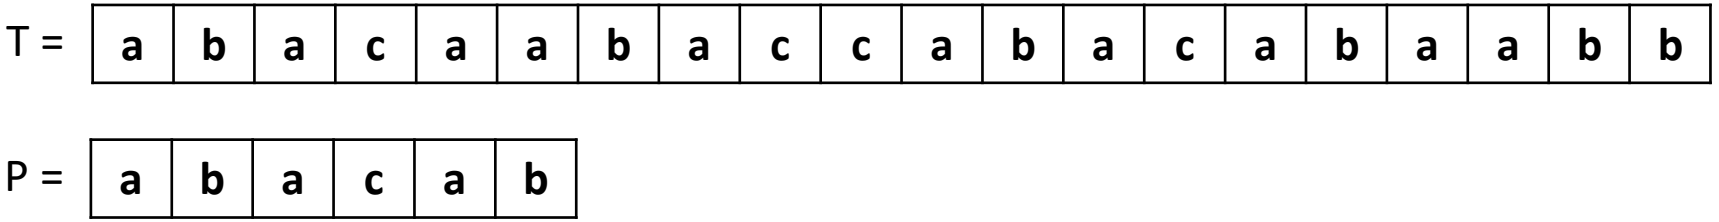


```
1. busca_padrao(t, n, p, m)
2.   para i ← 0 até n - m faça
3.     j ← 0
4.     enquanto (j < m) e t[i + j] == p[j] faça
5.       j ← j + 1
6.     se j == m então
7.       retorne i
8.   retorne "padrão p não encontrado em t"
```

O(nm)

Encontrando Padrões em Textos

- É possível melhorar o algoritmo de força bruta?

- **Algoritmo de Boyer-Moore (1976)**
  - Baseia-se na alta probabilidade de encontrar diferenças em alfabetos grandes.
  - Por isso, P é comparado com T de trás para frente.
  - Quando se encontra uma diferença em T[i], o padrão P dará um salto à frente, considerando-se as comparações já realizadas.

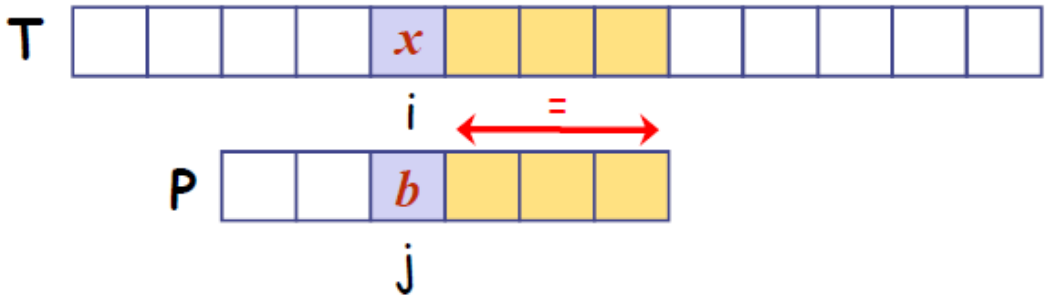

$T[i] \neq P[j]$

Algoritmo de Boyer-Moore

- No algoritmo é necessário considerar 3 casos:
  - **Caso 1:** P não contém x
    - Deslocar P para a direita, alinhando P[0] com T[i+1]

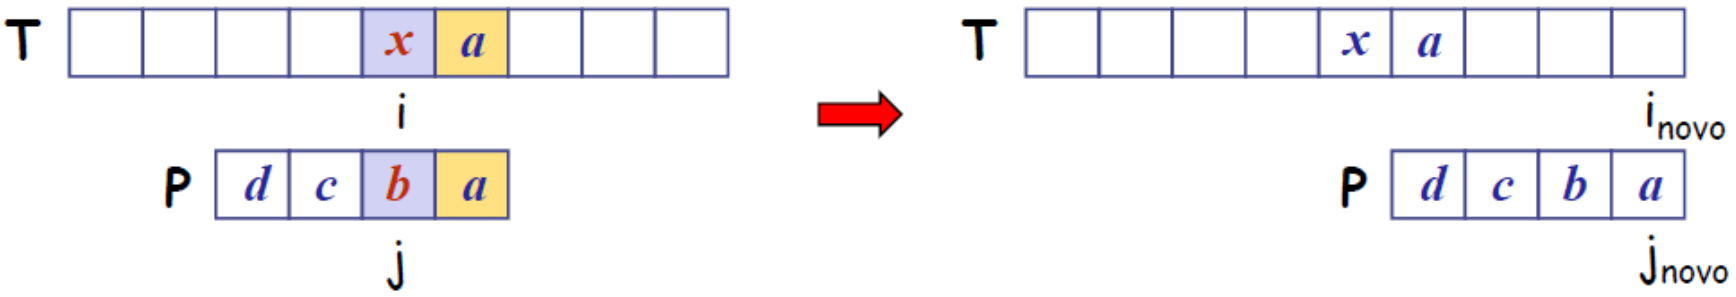

Algoritmo de Boyer-Moore

- No algoritmo é necessário considerar 3 casos:
  - **Caso 2:** A última ocorrência de x em P está algum índice menor do que j.
    - Deslocar P para a direita, até que a última ocorrência de x fique alinhada com T[i].

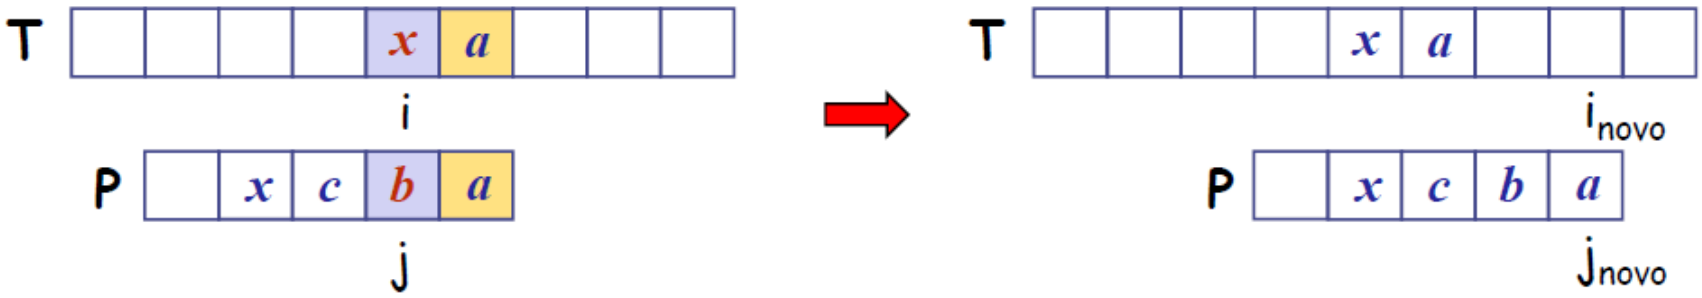

Algoritmo de Boyer-Moore

- No algoritmo é necessário considerar 3 casos:
  - **Caso 3:** A última ocorrência de x em P está em algum índice maior do que j.
    - Deslocar P apenas uma posição para a direita.

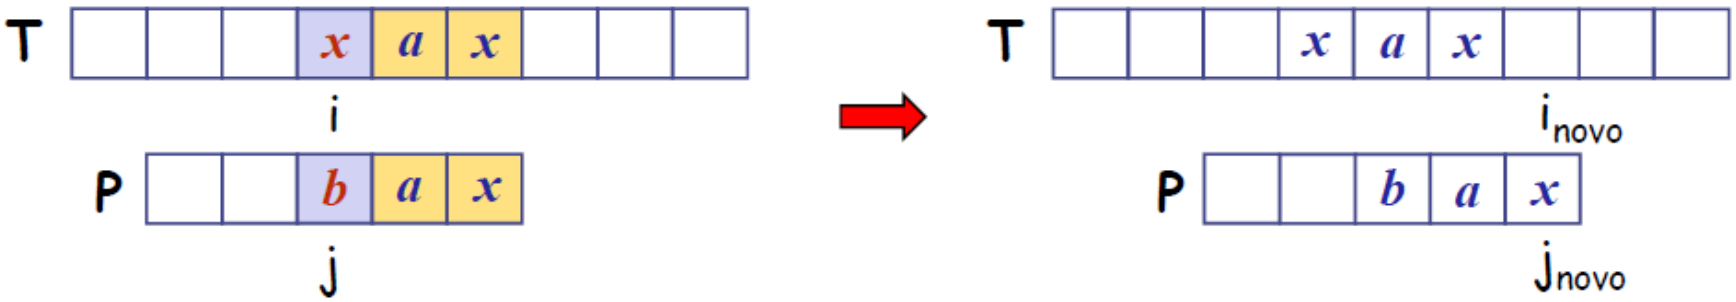

Algoritmo de Boyer-Moore – Exemplo

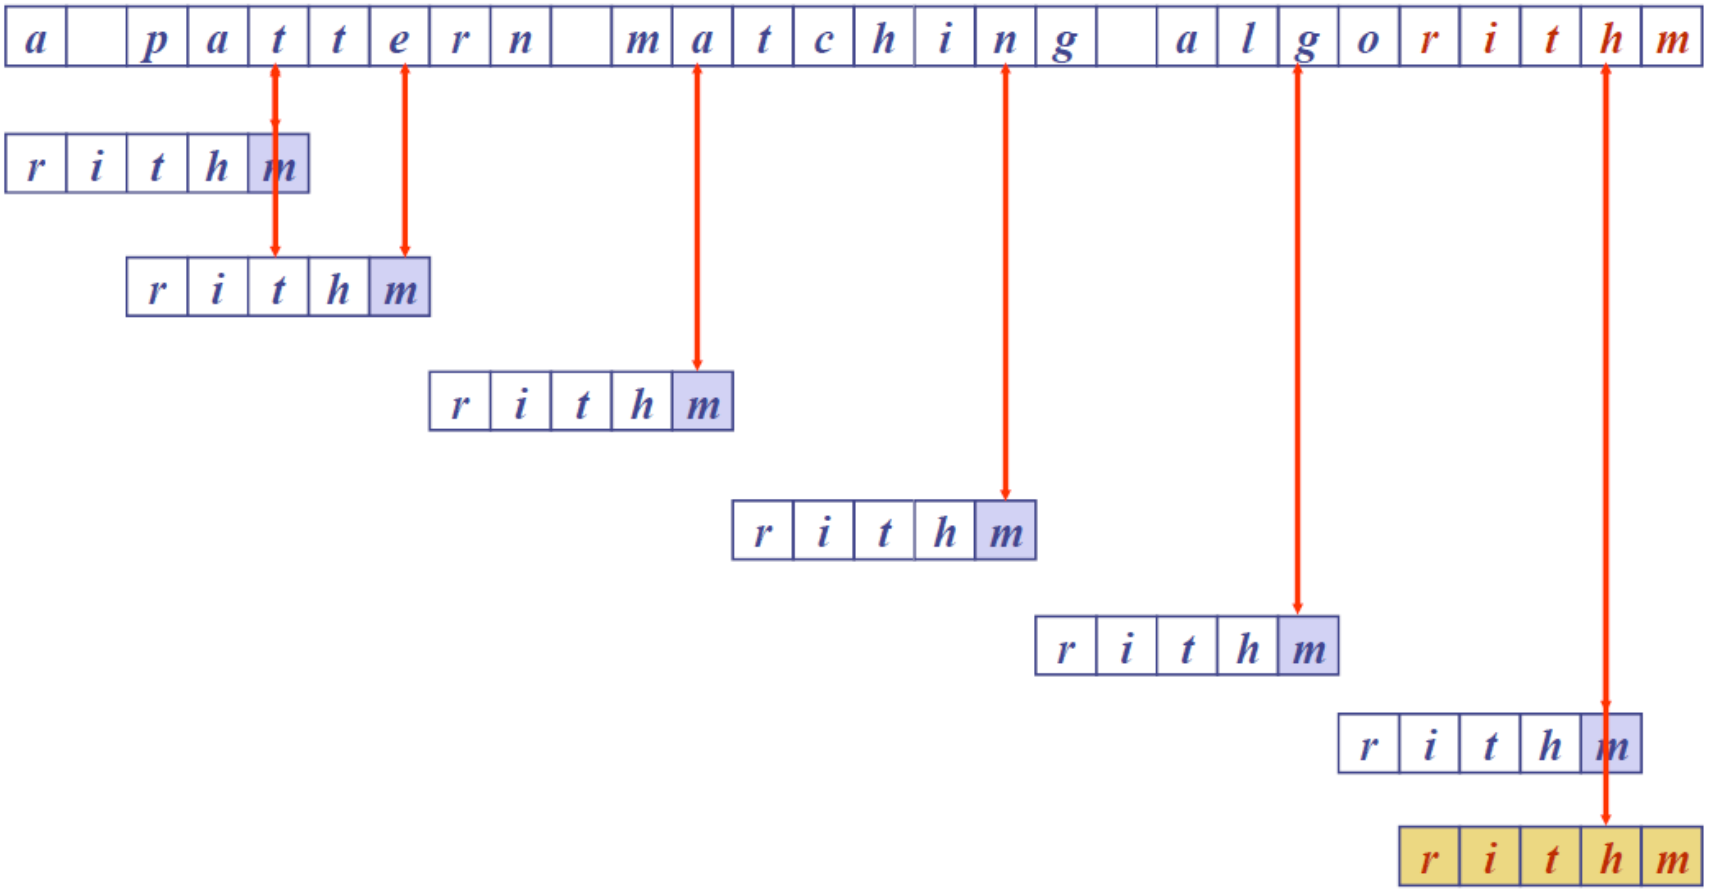

Algoritmo de Boyer-Moore – Exemplo

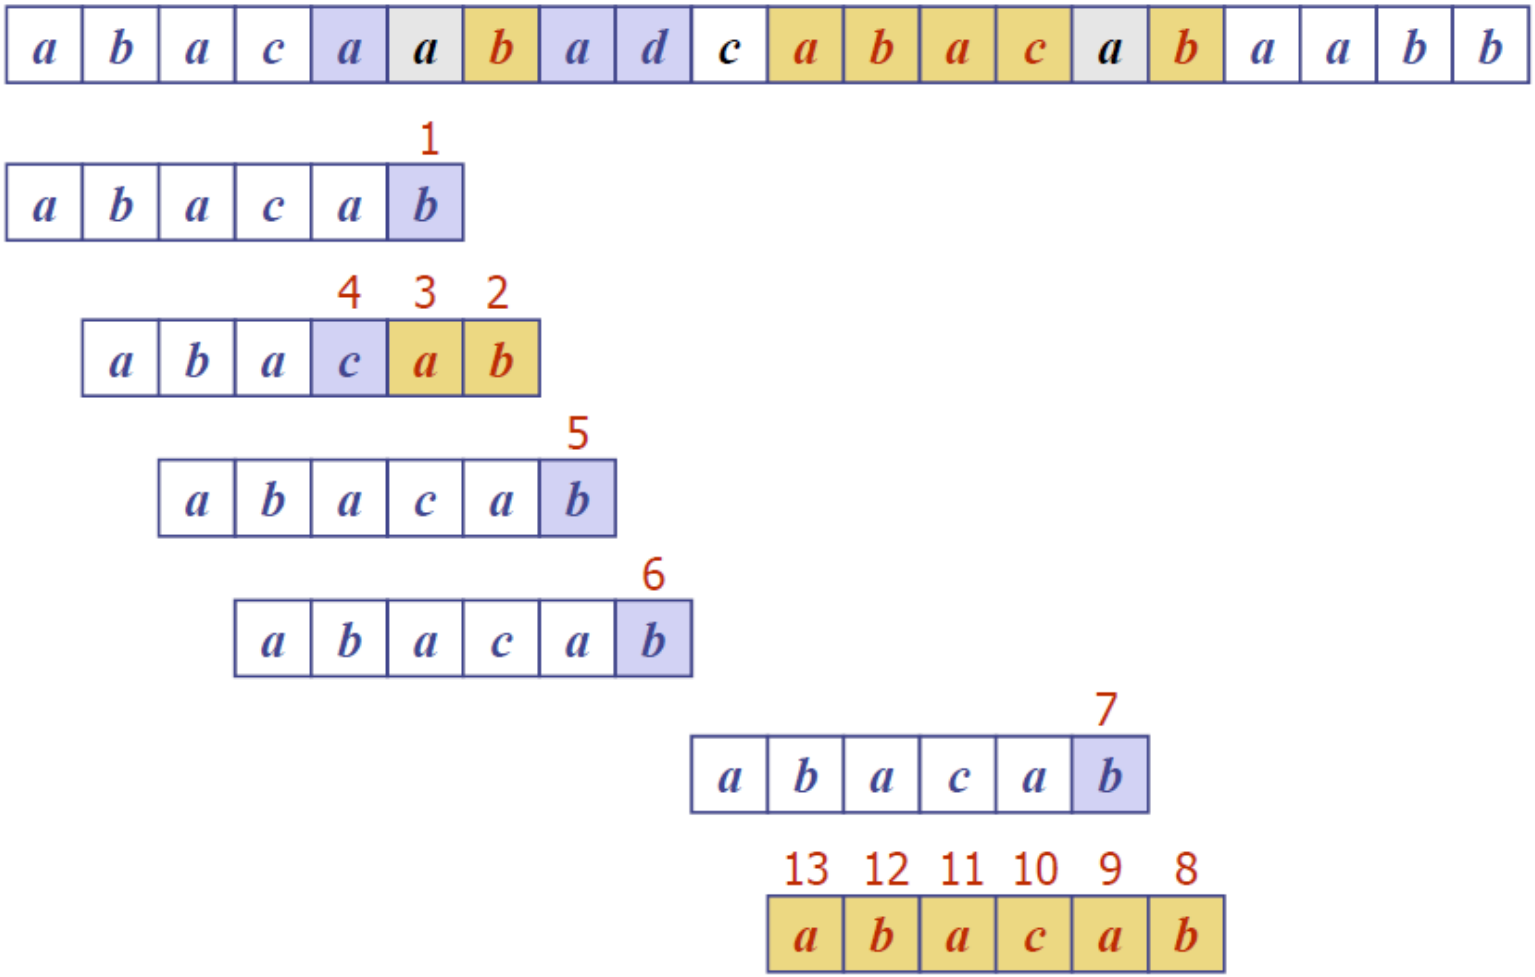

Algoritmo de Boyer-Moore

- Através de um pré-processamento, o algoritmo de Boyer-Moore calcula uma função L, onde L(x) é definida como:
  - o maior índice i tal que P[i] = x;
  - -1, caso este índice não exista;

- Exemplo: $\alpha = \{a, b, c, d\}$

P =

a	**b**	**a**	**c**	**a**	**b**
0	1	2	3	4	5

x	**a**	**b**	**c**	**d**
L(x)	4	5	3	-1

```
1. Boyer_Moore(T, n, P, m, α, w)
2.   para k ← 0 até w faça
3.     L[k] ← -1
4.   para k ← 0 até m faça
5.     L[P[k]] ← k
6.   i ← m - 1
7.   j ← m - 1
8.   repita
9.     se T[i] == P[j] então
10.      se j == 0 então
11.        retorne i
12.      senão
13.        i ← i - 1
14.        j ← j - 1
15.    senão
16.      i ← i + m - min{j, 1 + L[T[i]]}
17.      j ← m - 1
18.  enquanto i > n - 1
19.  retorne -1
```

O(nm)

Exercício

1) Considerando a seguinte cadeia de DNA:

- T = “CTAATCGCTTAATCAAACGC”

Realize o passo a passo do algoritmo Boyer-Moore para verificar se o padrão P = “ATCA” ocorre em T.

- Construa o vetor L e ilustre todos os alinhamentos e comparações dos caracteres do padrão P em T.

Exercícios

Lista de Exercícios 06 – Busca de Padrões em Texto

http://www.inf.puc-rio.br/~elima/paa/

Leitura Complementar

- Halim e Halim. **Competitive Programming**, 3rd Edition, 2003.

- **Capítulo 6: String Processing**