

# **Algoritmos e heurísticas para comparações exata e aproximada de seqüências**

Guilherme P. Telles<sup>1</sup>, Nalvo F. de Almeida Jr.<sup>2</sup> e Fábio H. Viduani Martinez<sup>2</sup>

gpt@icmc.usp.br, nalvo@dct.ufms.br, fhvm@dct.ufms.br

<sup>1</sup>ICMC–USP e <sup>2</sup>DCT–CCET–UFMS

# Roteiro

- Definições básicas e notação

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata
  - Algoritmos para comparação exata baseados em árvores digitais

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata
  - Algoritmos para comparação exata baseados em árvores digitais
  - Algoritmos para comparação exata e aproximada baseados em programação dinâmica

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata
  - Algoritmos para comparação exata baseados em árvores digitais
  - Algoritmos para comparação exata e aproximada baseados em programação dinâmica
  - Heurísticas para comparação aproximada

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata
  - Algoritmos para comparação exata baseados em árvores digitais
  - Algoritmos para comparação exata e aproximada baseados em programação dinâmica
  - Heurísticas para comparação aproximada
  - Outros métodos de comparação

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata
  - Algoritmos para comparação exata baseados em árvores digitais
  - Algoritmos para comparação exata e aproximada baseados em programação dinâmica
  - Heurísticas para comparação aproximada
  - Outros métodos de comparação
- Métodos para comparação de textos

# Roteiro

- Definições básicas e notação
- Algoritmos, complexidades e aplicações
  - Algoritmos para comparação exata
  - Algoritmos para comparação exata baseados em árvores digitais
  - Algoritmos para comparação exata e aproximada baseados em programação dinâmica
  - Heurísticas para comparação aproximada
  - Outros métodos de comparação
- Métodos para comparação de textos
- Considerações finais

# Comparação de Duas Seqüências

- Sejam  $s$  uma seqüência de  $n$  símbolos chamada **texto** e  $p$  uma seqüência de  $m$  símbolos chamada **padrão**.

# Comparação de Duas Seqüências

- Sejam  $s$  uma seqüência de  $n$  símbolos chamada **texto** e  $p$  uma seqüência de  $m$  símbolos chamada **padrão**.
- $p$  **ocorre em**  $s$  **na posição**  $d + 1$  se

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

para algum  $d$ , com  $0 \leq d \leq n - m$ , e  $d$  é chamado um **deslocamento** de  $p$  sobre  $s$ .

# Comparação de Duas Seqüências

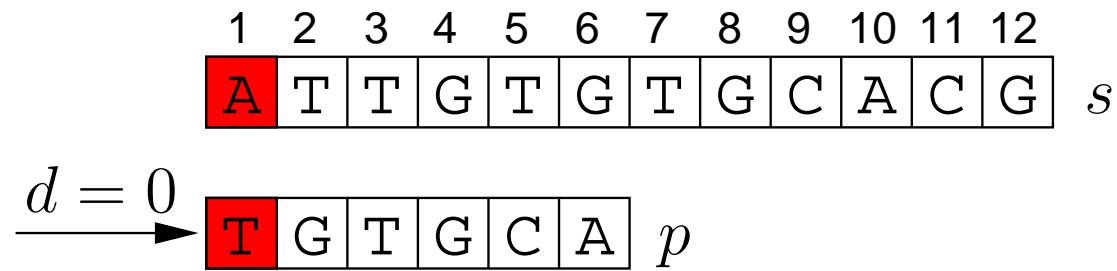
- Sejam  $s$  uma seqüência de  $n$  símbolos chamada **texto** e  $p$  uma seqüência de  $m$  símbolos chamada **padrão**.
- $p$  **ocorre em**  $s$  **na posição**  $d + 1$  se

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

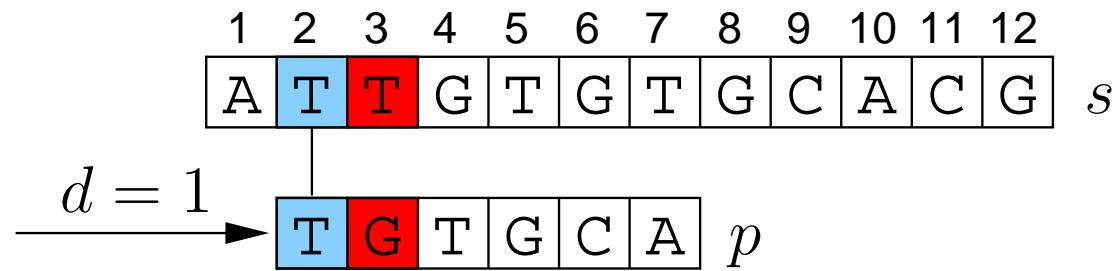
para algum  $d$ , com  $0 \leq d \leq n - m$ , e  $d$  é chamado um **deslocamento** de  $p$  sobre  $s$ .

- Problema SM( $s, p$ ): dada uma seqüência  $s$  de  $n$  símbolos e uma seqüência  $p$  de  $m$  símbolos, com  $m \leq n$ , encontrar todas as ocorrências de  $p$  em  $s$ .

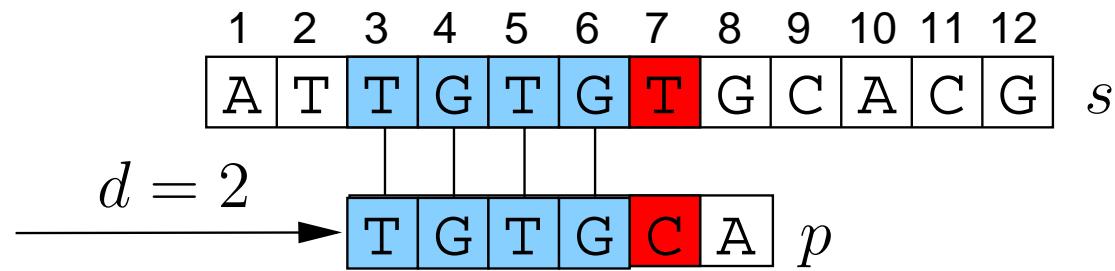
# Força Bruta ou Ingênuo



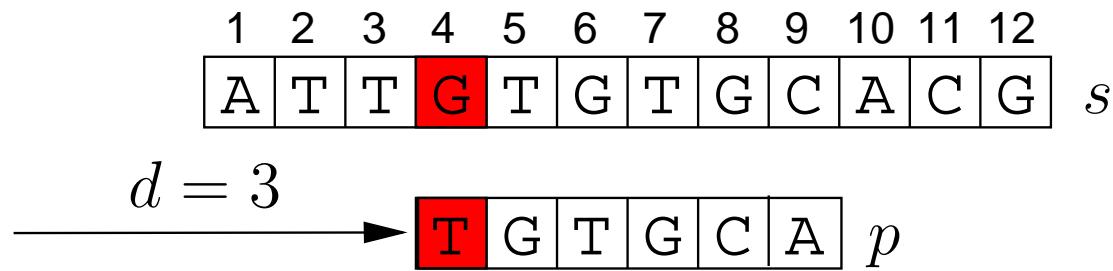
# Força Bruta ou Ingênuo



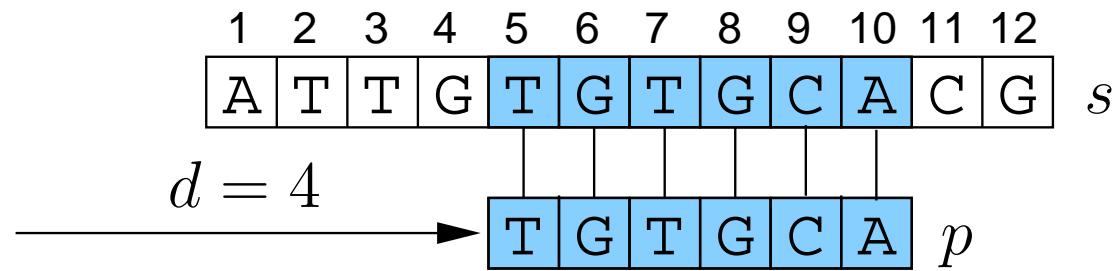
# Força Bruta ou Ingênuo



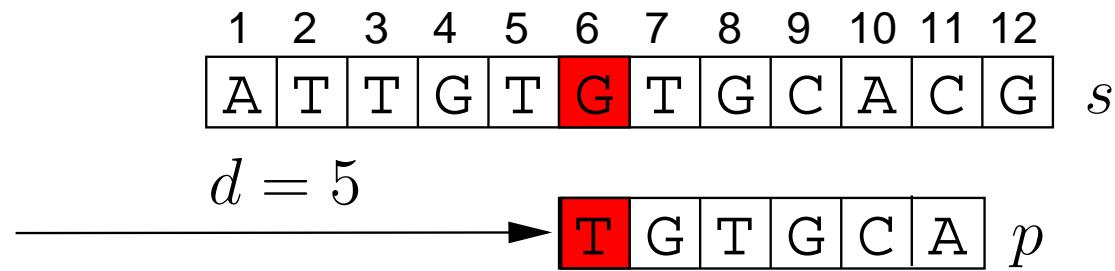
# Força Bruta ou Ingênuo



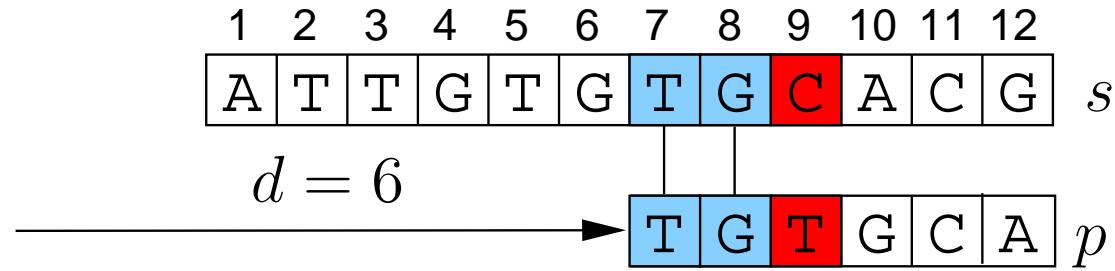
# Força Bruta ou Ingênuo



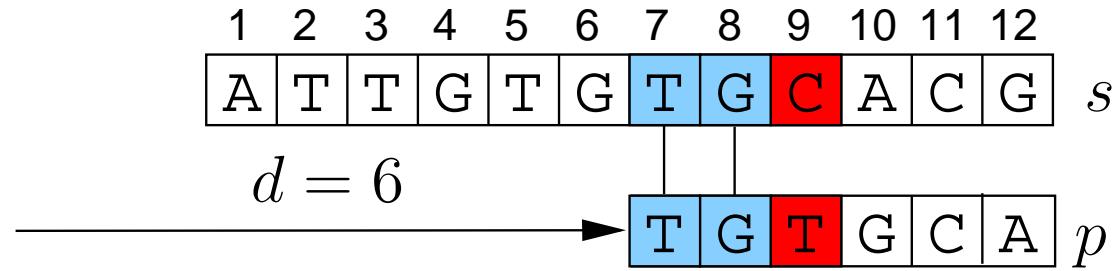
# Força Bruta ou Ingênuo



# Força Bruta ou Ingênuo

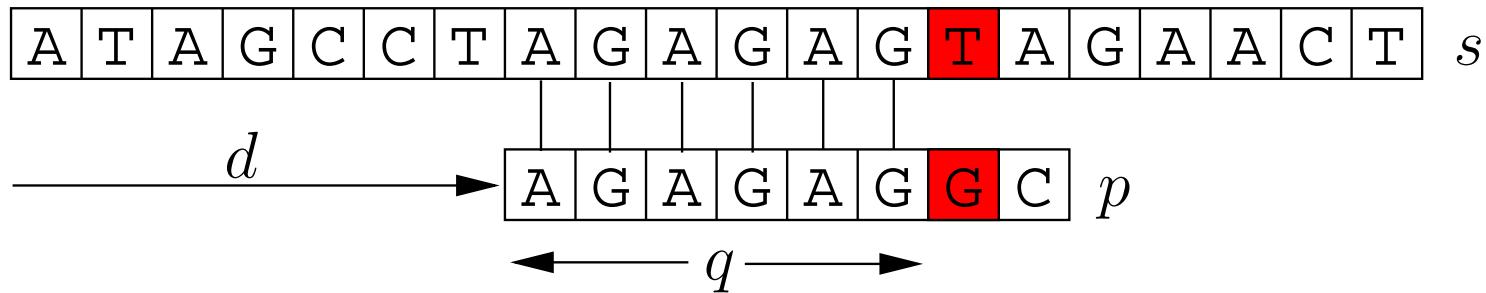


# Força Bruta ou Ingênuo

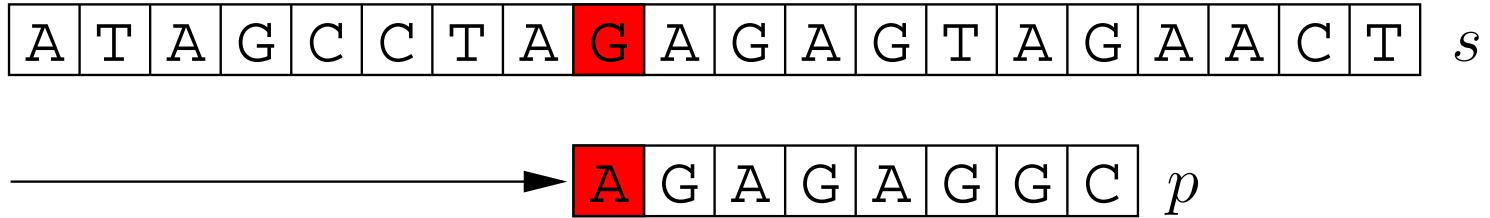


$$O(mn)$$

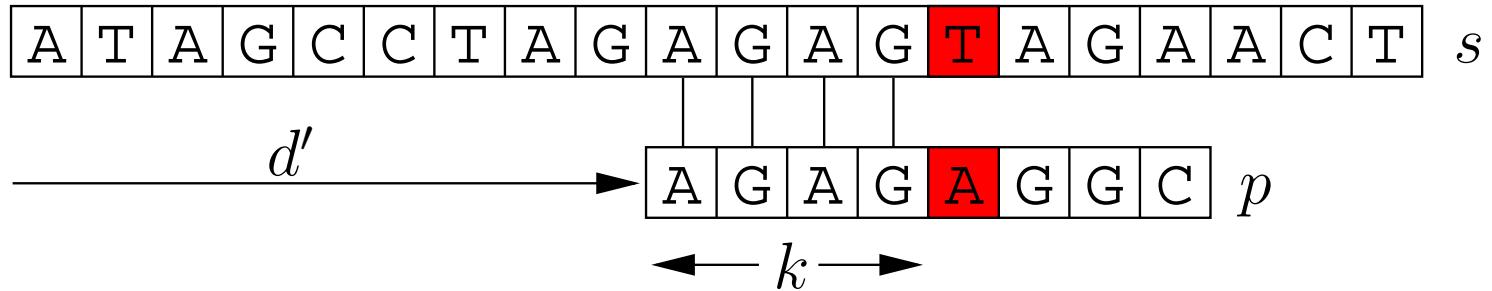
# Knuth, Morris e Pratt



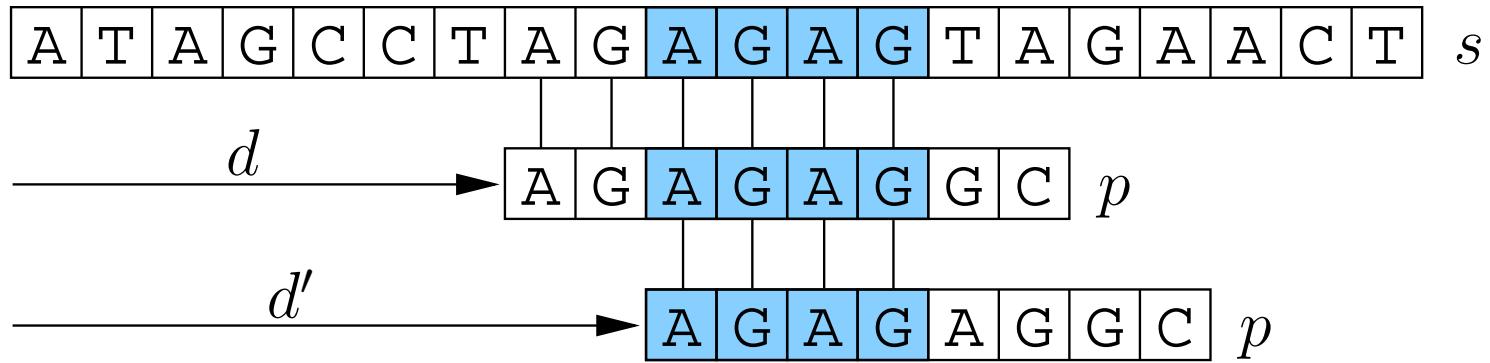
# Knuth, Morris e Pratt



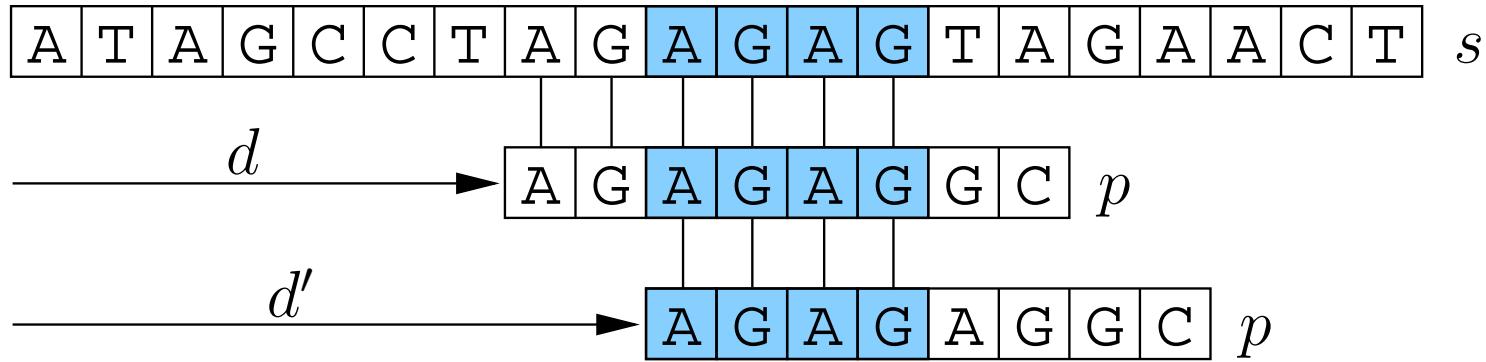
# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt

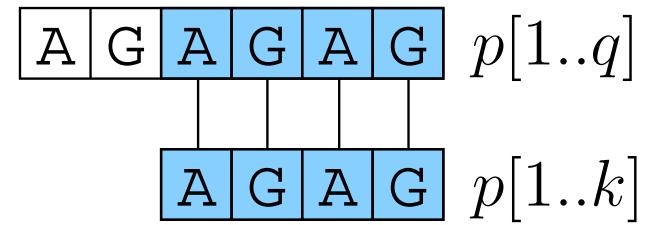


Dado que os símbolos  $p[1..q]$  do padrão coincidem com os símbolos  $s[d + 1..d + q]$  do texto, qual o menor deslocamento  $d' > d$  tal que

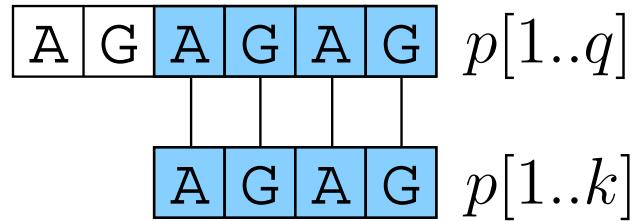
$$p[1..k] = s[d' + 1..d' + k],$$

onde  $d' + k = d + q$ ?

# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



Queremos encontrar o maior  $k < q$  tal que  $p[1..k]$  é um sufixo de  $p[1..q]$ . Assim, o próximo deslocamento a ser verificado é  $d' = d + (q - k)$ .

# Knuth, Morris e Pratt

Dado um padrão  $p$  de comprimento  $m$ , a **função prefixo**  $\pi$  é tal que:

$$\pi: \{1, \dots, m\} \rightarrow \{0, \dots, m - 1\} \text{ e}$$

# Knuth, Morris e Pratt

Dado um padrão  $p$  de comprimento  $m$ , a **função prefixo**  $\pi$  é tal que:

$$\pi: \{1, \dots, m\} \rightarrow \{0, \dots, m-1\} \text{ e}$$

$$\pi(q) = \max\{k: k < q \text{ e } p[1..k] \text{ é sufixo de } p[1..q]\}.$$

# Knuth, Morris e Pratt

**FUNÇÃO-PREFIXO( $p$ ):** recebe uma seqüência  $p$  de  $m$  símbolos e devolve a função prefixo  $\pi$  para  $p$ .

- 1:  $\pi[1] \leftarrow 0$
- 2:  $k \leftarrow 0$
- 3: **para**  $q \leftarrow 2$  **até**  $m$  **faça**
- 4:   **enquanto**  $k > 0$  **e**  $p[k + 1] \neq p[q]$  **faça**
- 5:      $k \leftarrow \pi[k]$
- 6:     **se**  $p[k + 1] = p[q]$  **então**
- 7:        $k \leftarrow k + 1$
- 8:      $\pi[q] \leftarrow k$
- 9: **devolva**  $\pi$

# Knuth, Morris e Pratt

1 2 3 4 5 6 7 8  

A	G	A	G	A	G	G	C
---	---	---	---	---	---	---	---

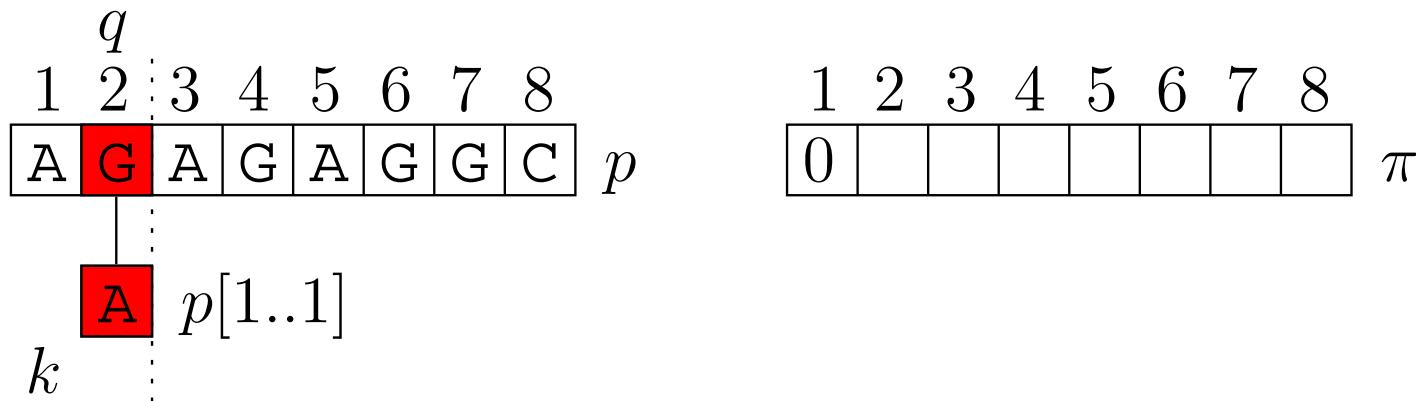
 $p$

1 2 3 4 5 6 7 8  

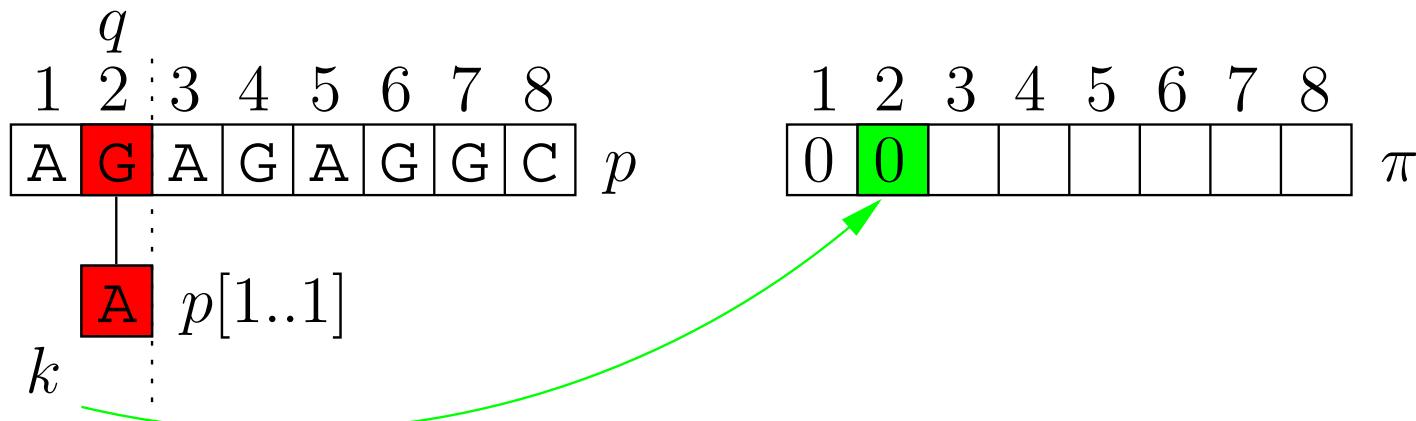
0							
---	--	--	--	--	--	--	--

 $\pi$

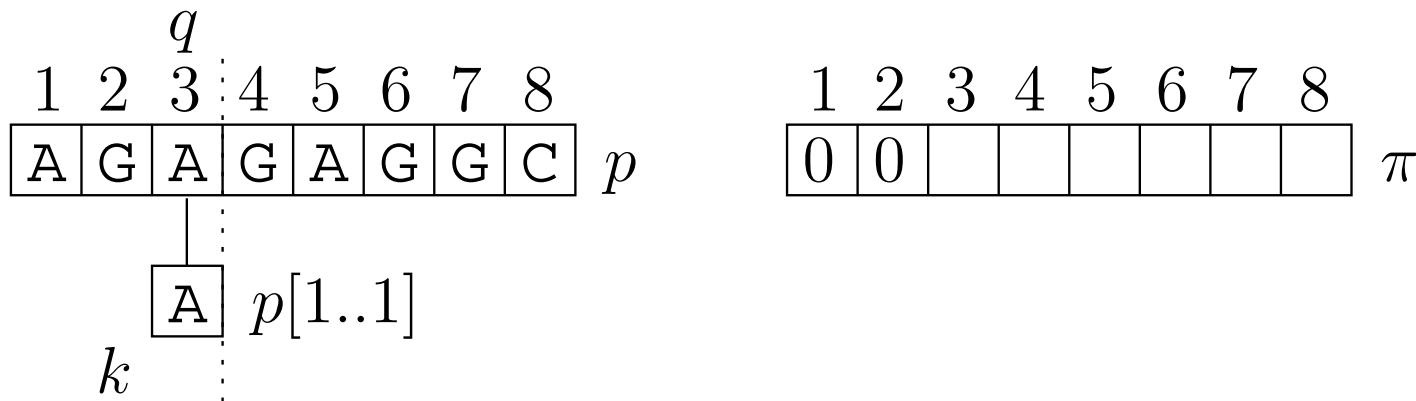
# Knuth, Morris e Pratt



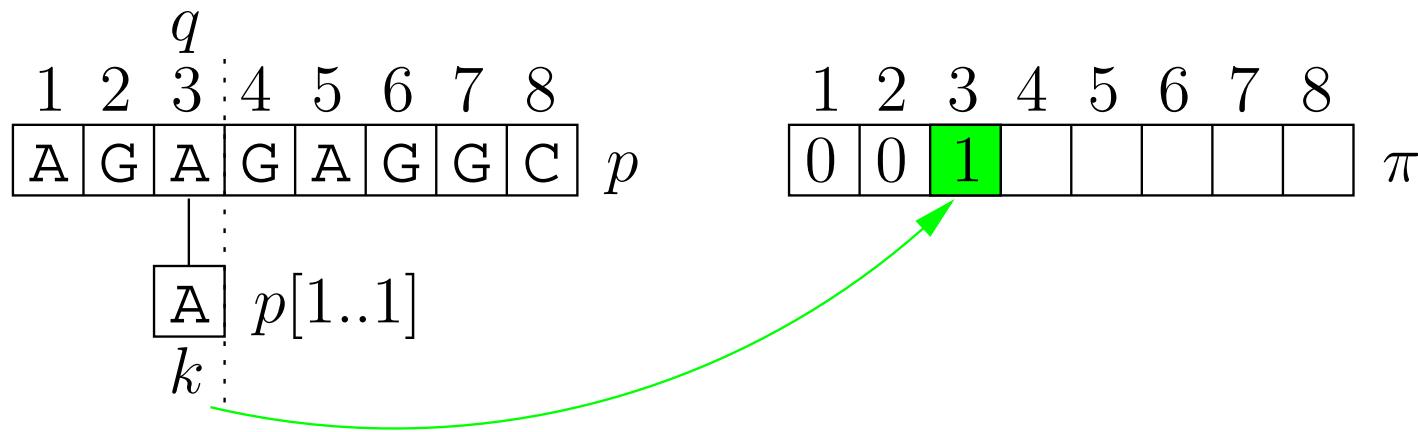
# Knuth, Morris e Pratt



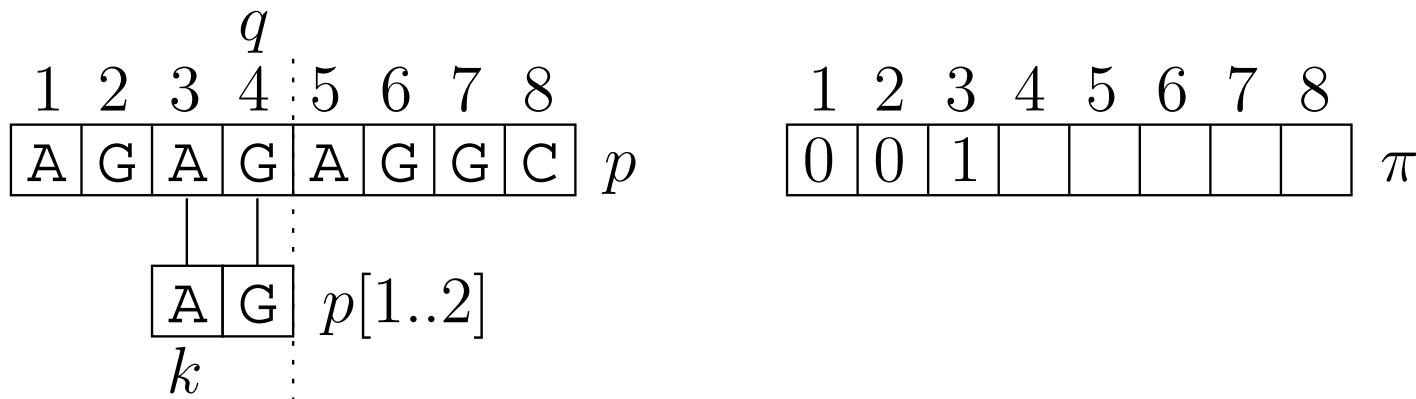
# Knuth, Morris e Pratt



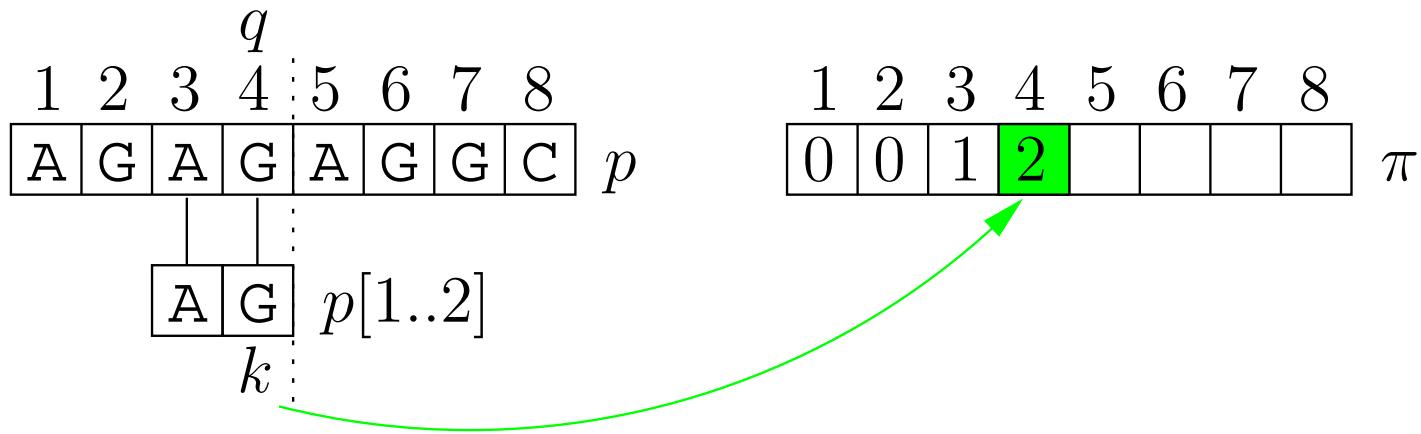
# Knuth, Morris e Pratt



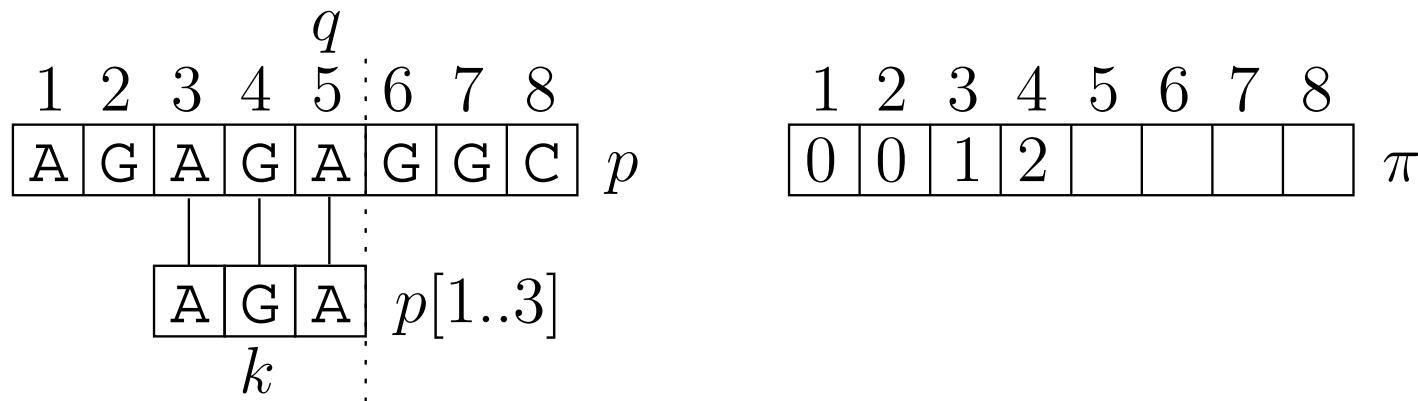
# Knuth, Morris e Pratt



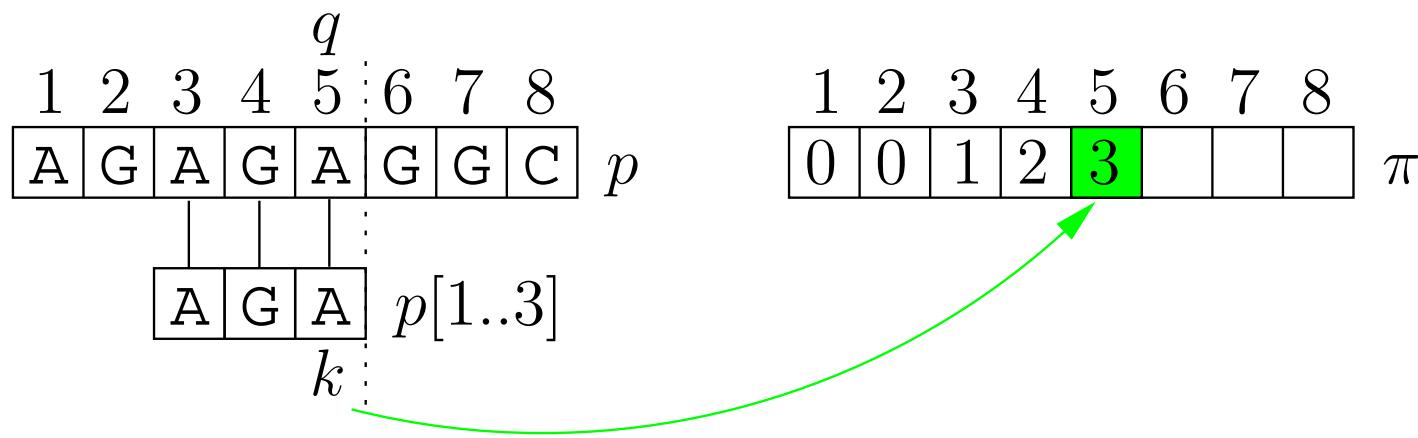
# Knuth, Morris e Pratt



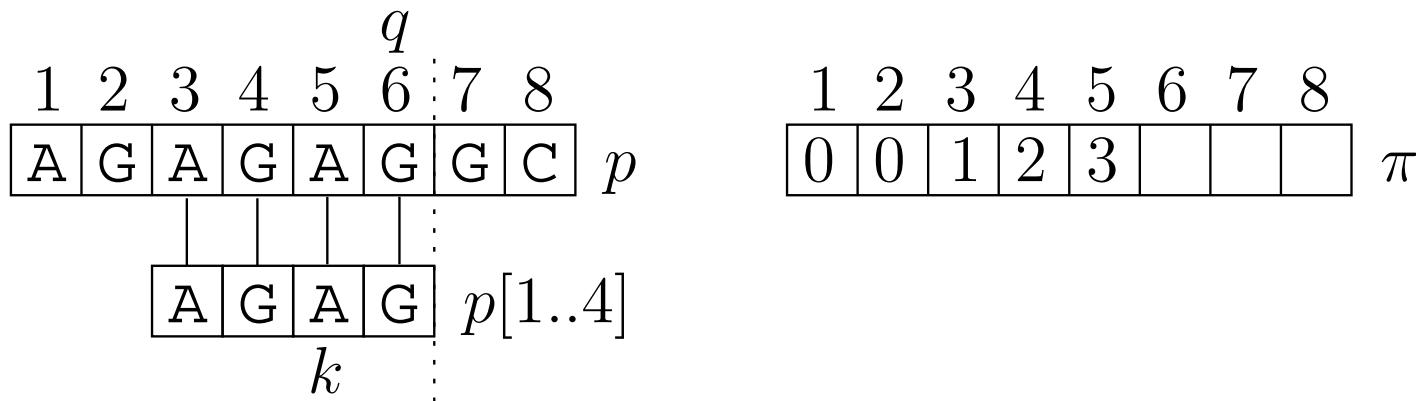
# Knuth, Morris e Pratt



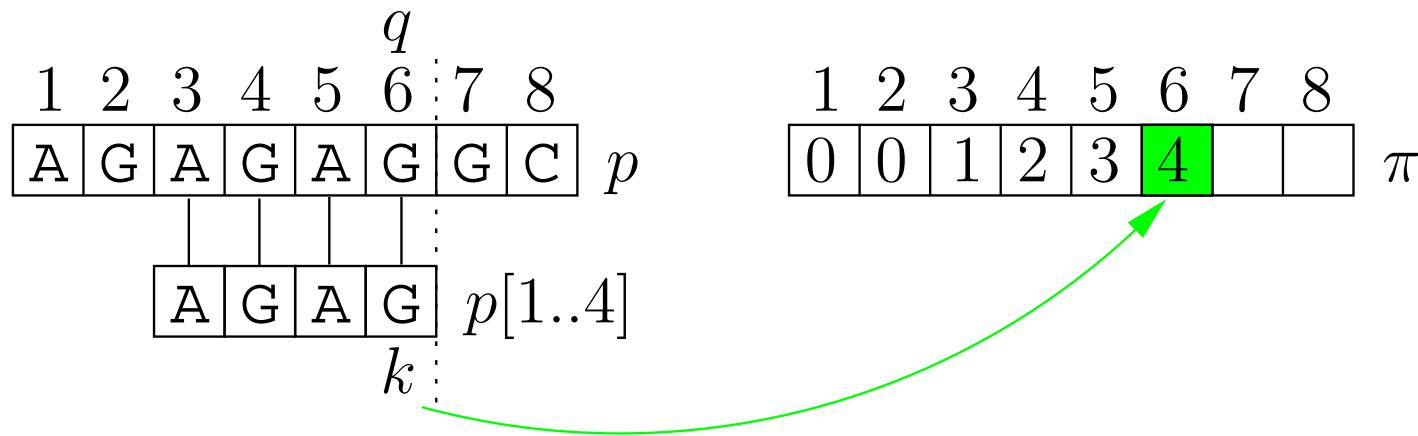
# Knuth, Morris e Pratt



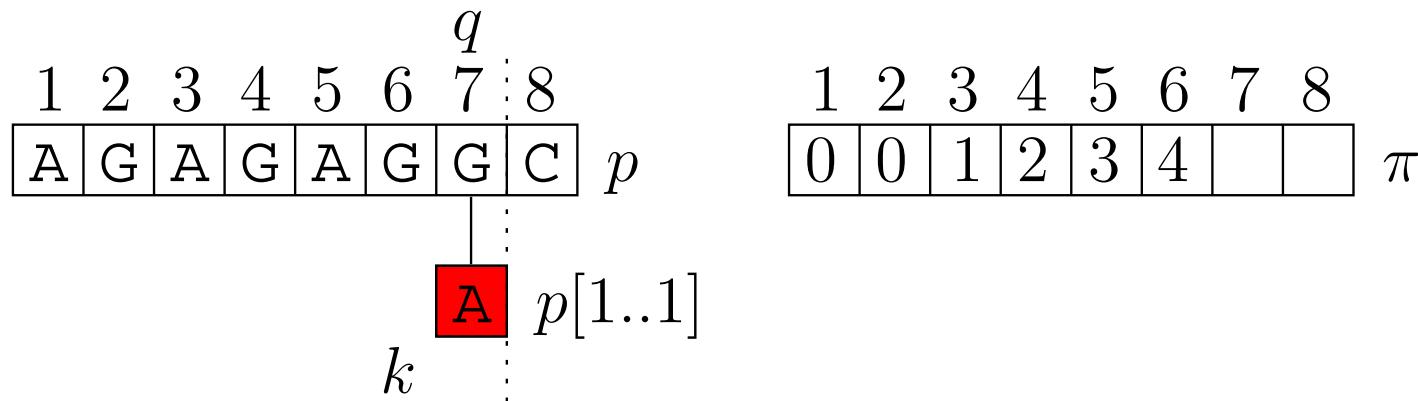
# Knuth, Morris e Pratt



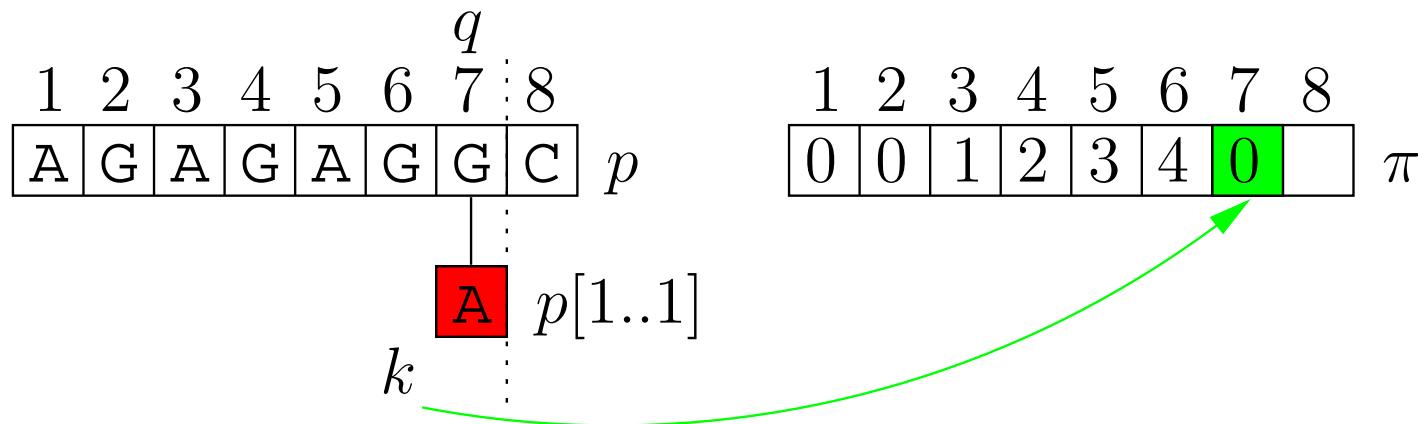
# Knuth, Morris e Pratt



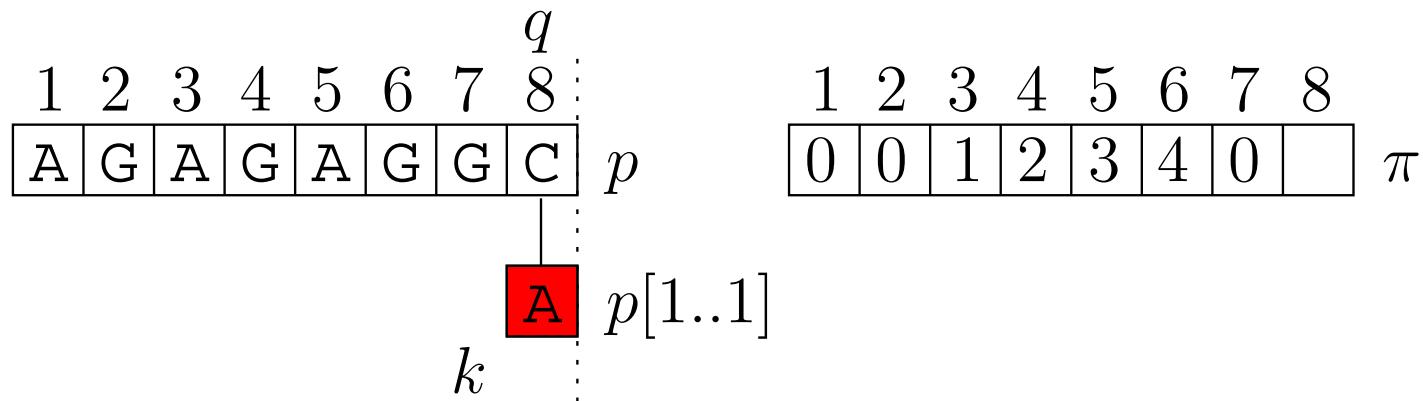
# Knuth, Morris e Pratt



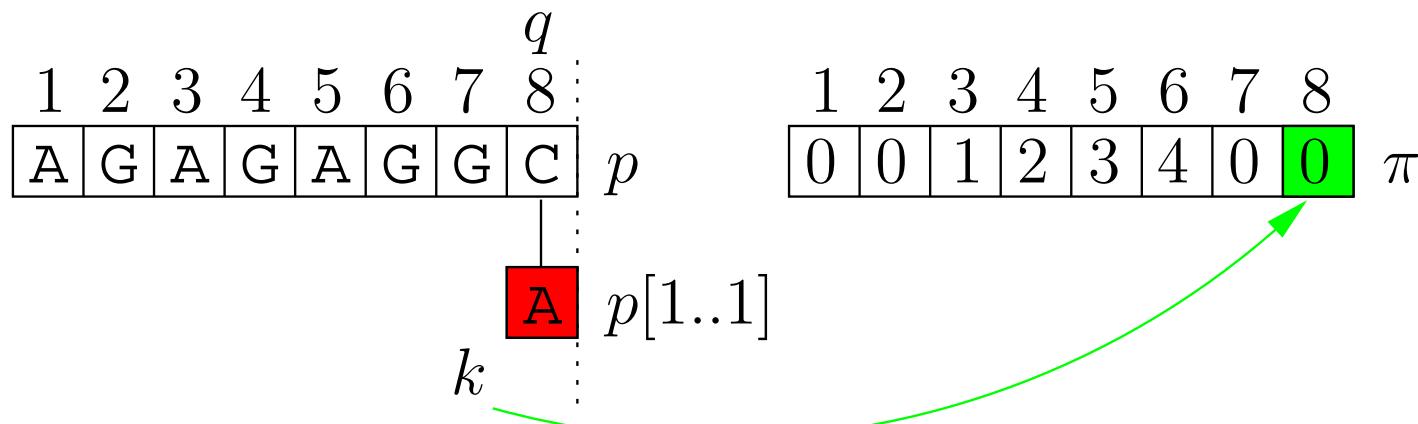
# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt

1	2	3	4	5	6	7	8	
A	G	A	G	A	G	G	C	$p$

1	2	3	4	5	6	7	8	
0	0	1	2	3	4	0	0	$\pi$

Tempo de execução:  $O(m)$

# Knuth, Morris e Pratt

KMP( $s, p$ ): recebe um texto  $s$  de  $n$  símbolos e um padrão  $p$  de  $m$  símbolos e realiza a comparação de  $s$  e  $p$ , devolvendo os índices em  $s$  onde  $p$  ocorre.

- 1:  $\pi \leftarrow \text{FUNÇÃO-PREFIXO}(p)$
- 2:  $q \leftarrow 0$
- 3: **para**  $i \leftarrow 1$  **até**  $n$  **faça**
- 4:   **enquanto**  $q > 0$  **e**  $p[q + 1] \neq s[i]$  **faça**
- 5:      $q \leftarrow \pi[q]$
- 6:   **se**  $p[q + 1] = s[i]$  **então**
- 7:      $q \leftarrow q + 1$
- 8:   **se**  $q = m$  **então**
- 9:     **escreva** “Padrão ocorre no texto com deslocamento”  $i - m$
- 10:     $q \leftarrow \pi[q]$

# Knuth, Morris e Pratt

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17  
A G C A G A G C A G A G A G G C C

*s*

1 2 3 4 5 6 7 8  
A G A G A G G C

*p*

# Knuth, Morris e Pratt

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
A	G	C	A	G	A	G	C	A	G	A	G	A	G	G	C	C

*s*

1	2	3	4	5	6	7	8
0	0	1	2	3	4	0	0

*π*

A	G	A	G	A	G	G	C
1	2	3	4	5	6	7	8

*p*

# Knuth, Morris e Pratt

$i$

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
A	G	C	A	G	A	G	C	A	G	A	G	A	G	G	C	C

$s$

1	2	3	4	5	6	7	8
0	0	1	2	3	4	0	0

A	G	A	G	A	G	G	C
---	---	---	---	---	---	---	---

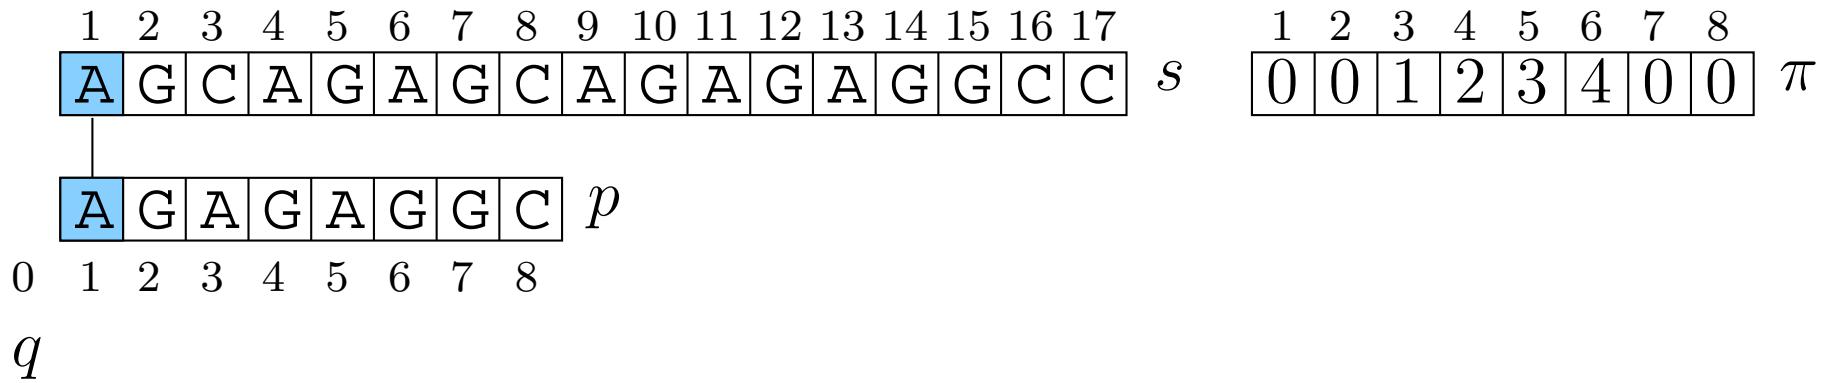
$p$

0    1    2    3    4    5    6    7    8

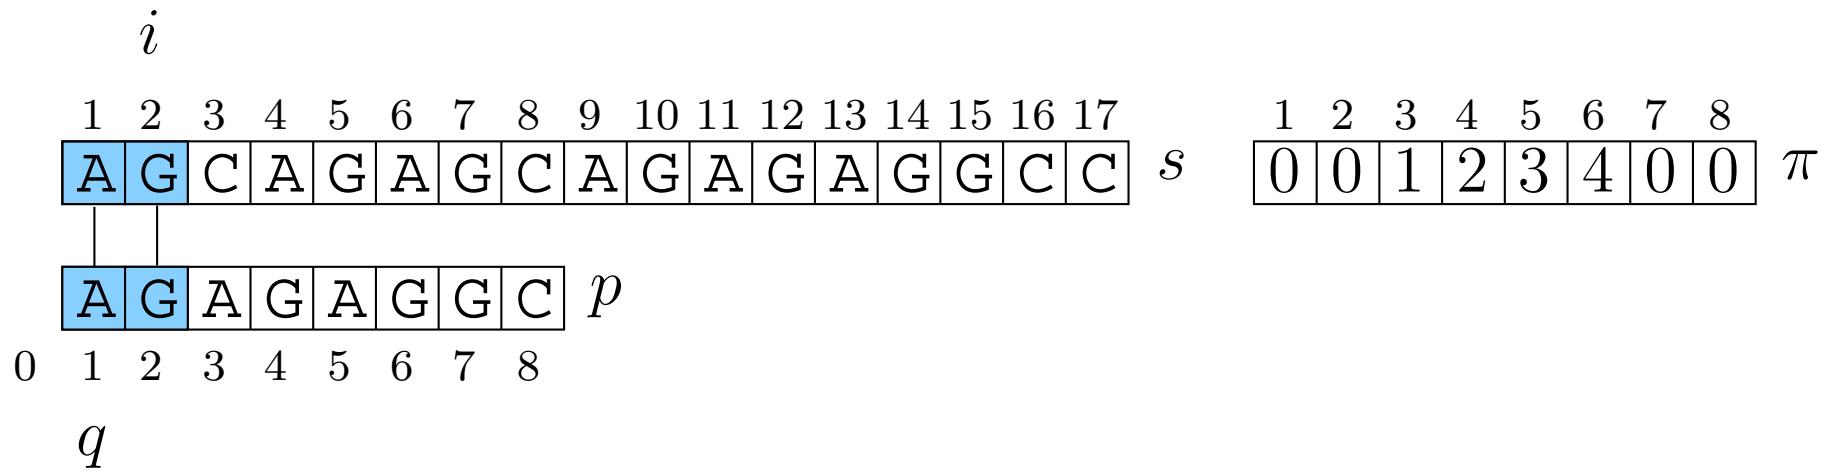
$q$

# Knuth, Morris e Pratt

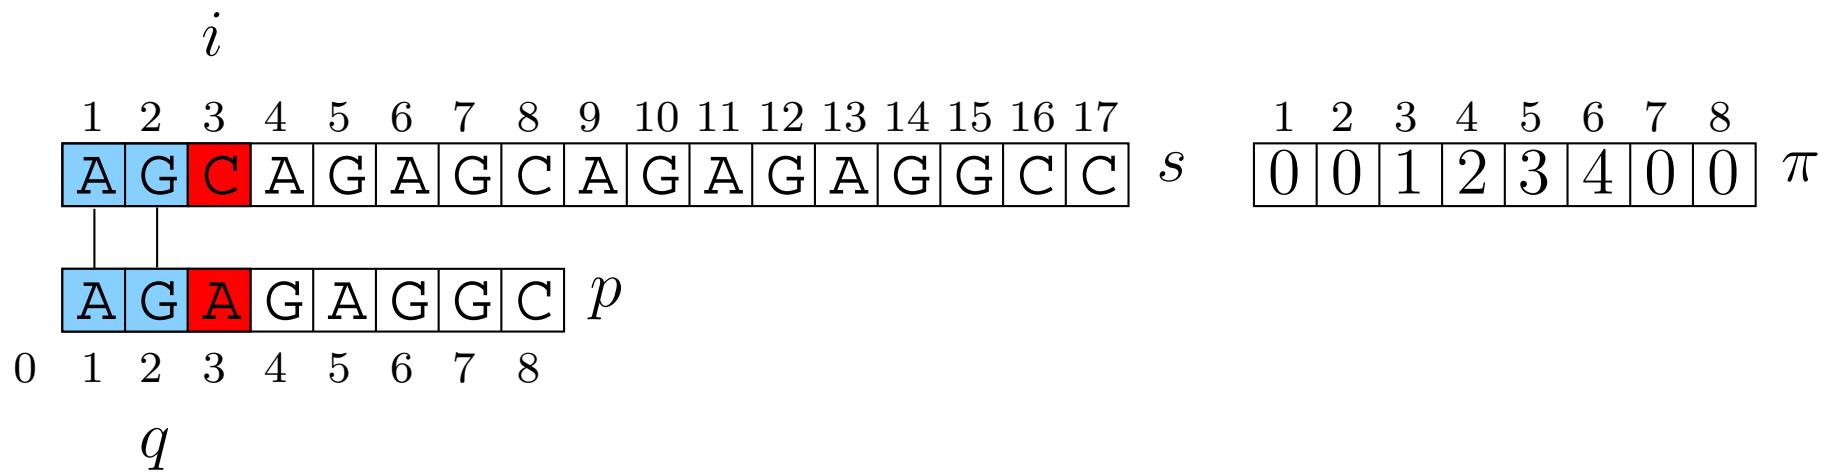
$i$



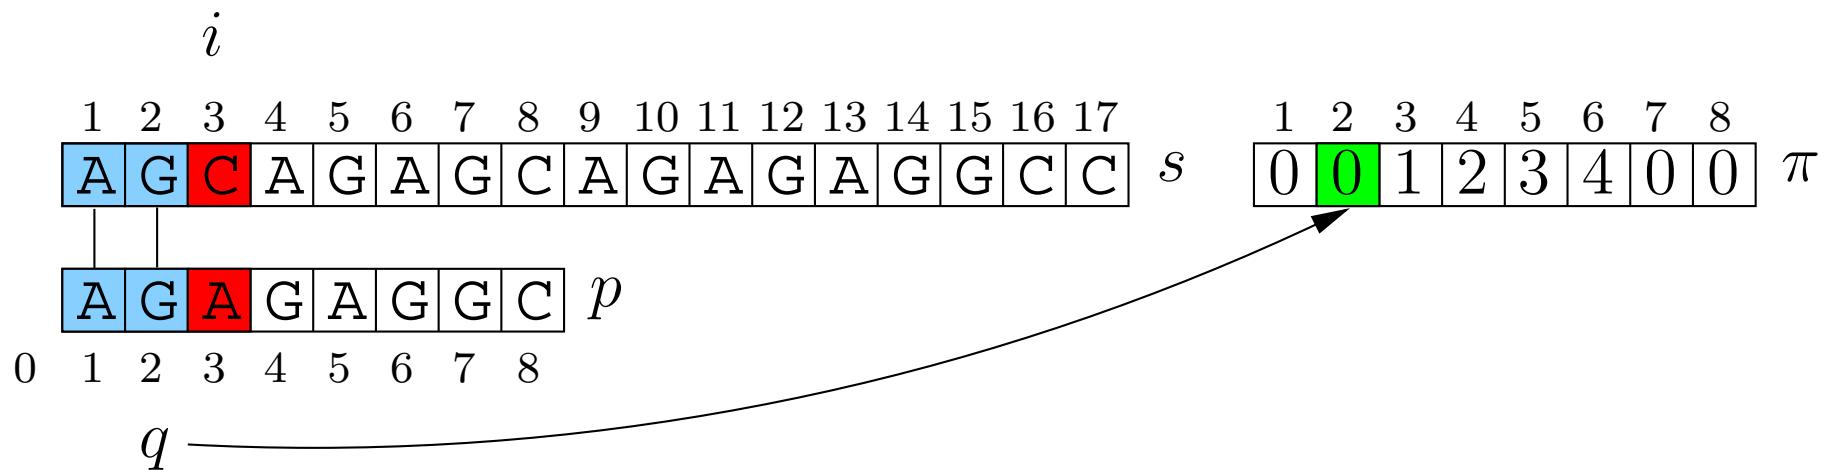
# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt

$i$

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
A	G	C	A	G	A	G	C	A	G	A	G	A	G	G	C	C

$s$

1	2	3	4	5	6	7	8
0	0	1	2	3	4	0	0

$\pi$

$A$   $G$   $A$   $G$   $A$   $G$   $G$   $C$   $p$

0    1    2    3    4    5    6    7    8

$q$

# Knuth, Morris e Pratt

$i$

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
A	G	C	A	G	A	G	C	A	G	A	G	A	G	G	C	C

$s$

1	2	3	4	5	6	7	8
0	0	1	2	3	4	0	0

$\pi$

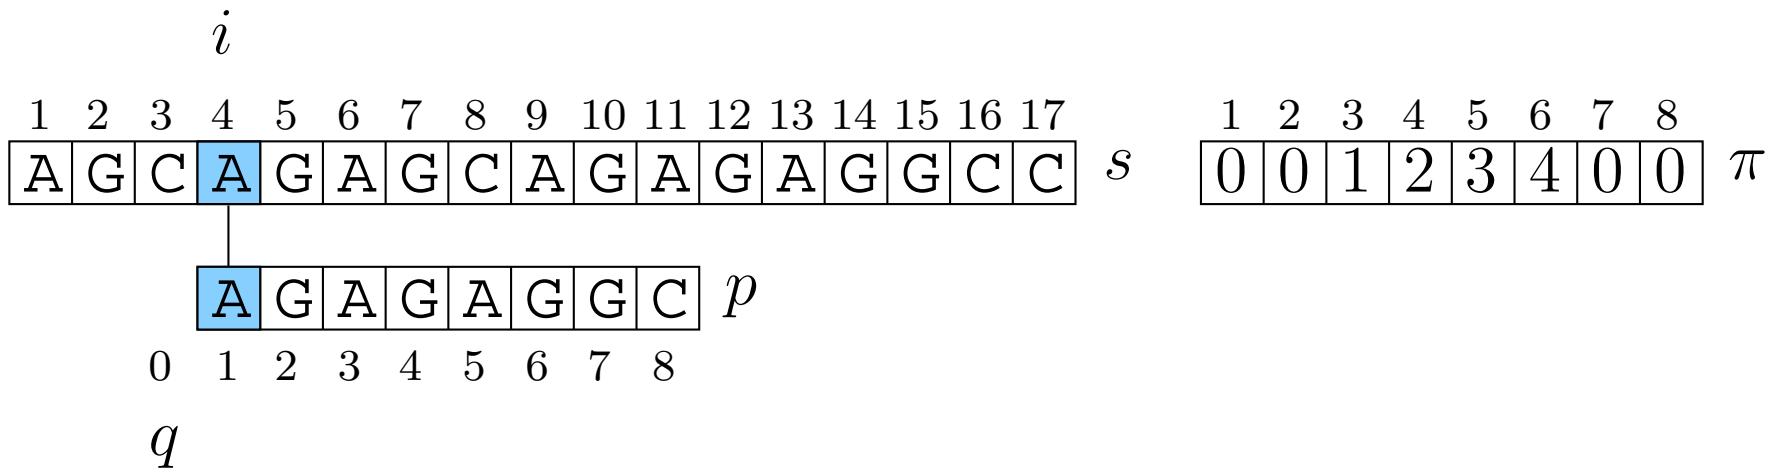
A	G	A	G	A	G	G	C
0	1	2	3	4	5	6	7

$p$

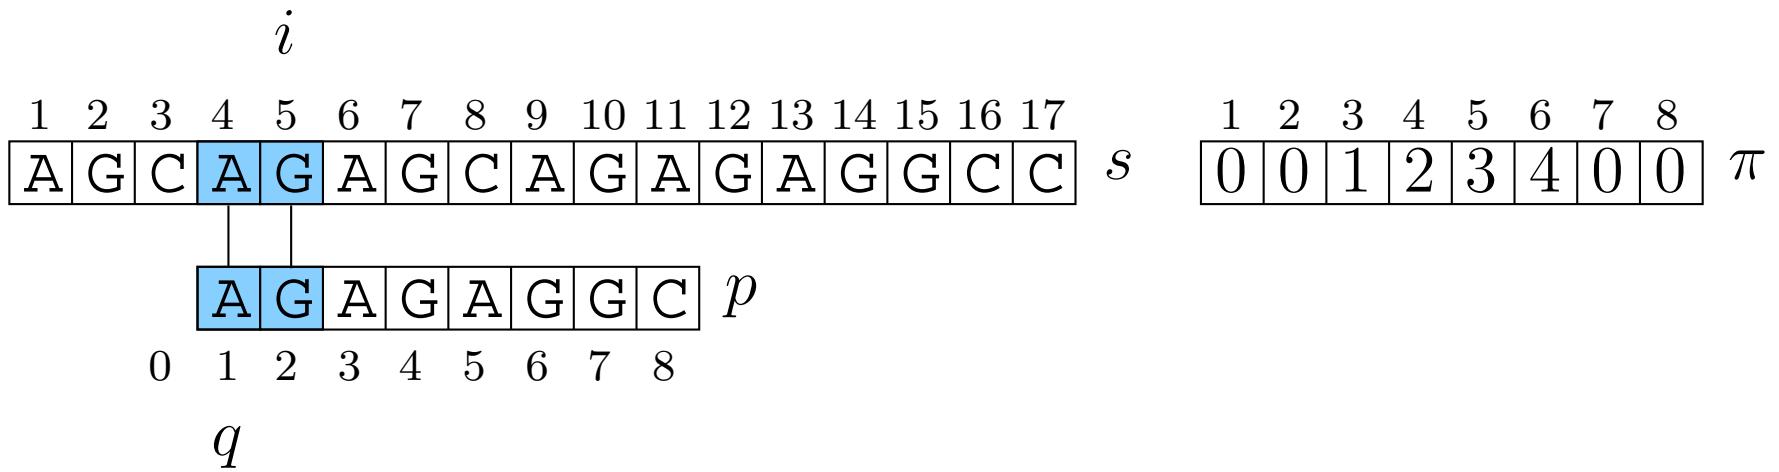
0 1 2 3 4 5 6 7 8

$q$

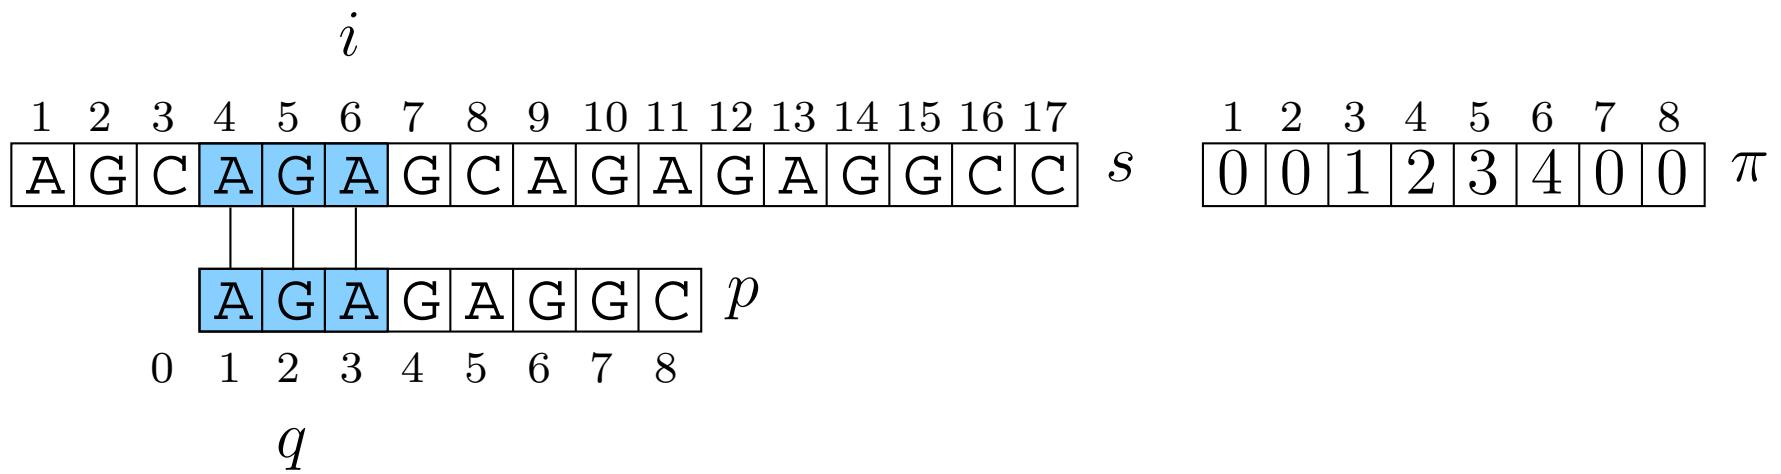
# Knuth, Morris e Pratt



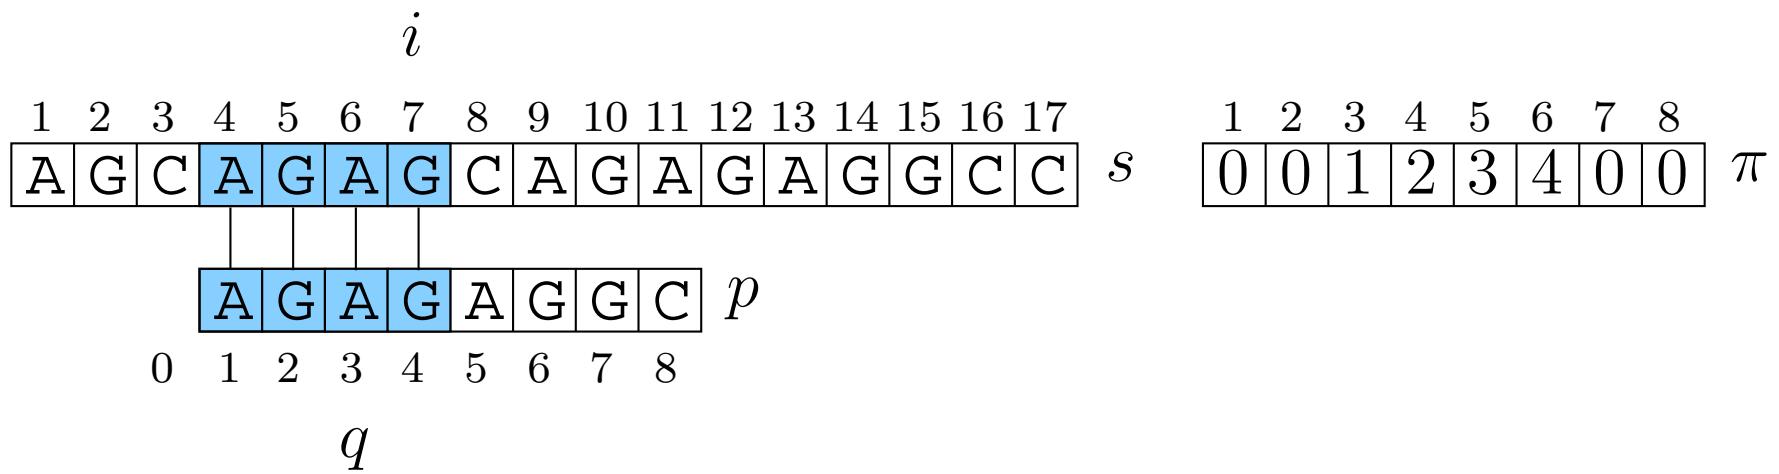
# Knuth, Morris e Pratt



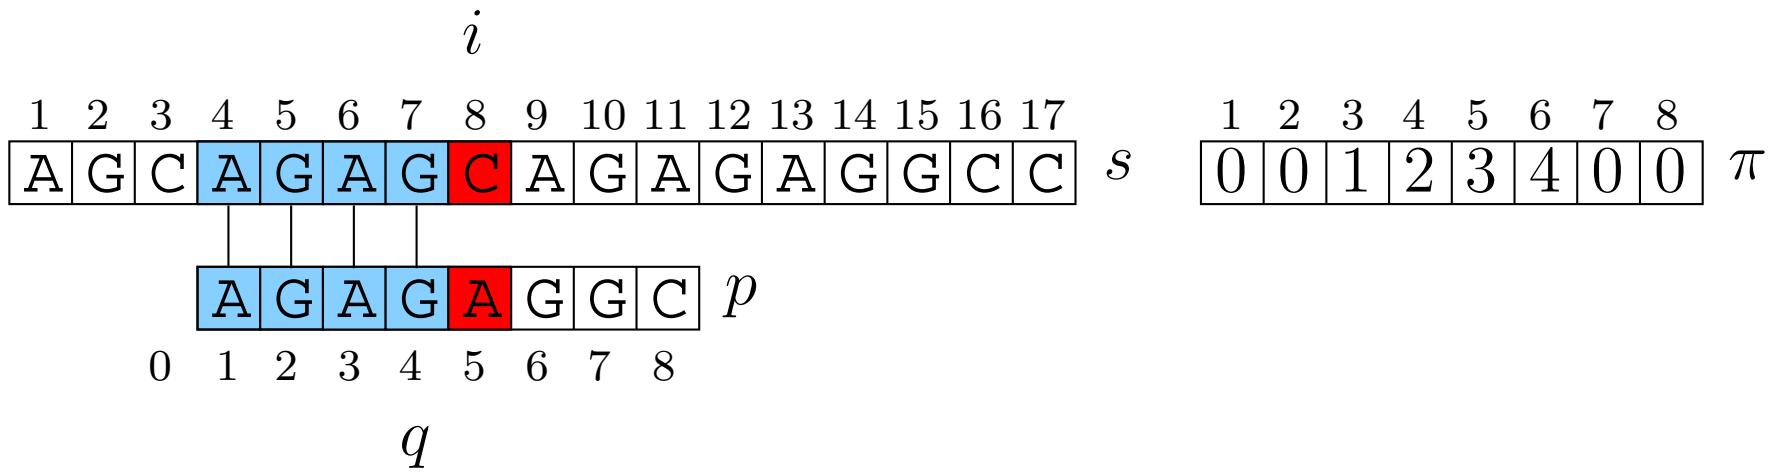
# Knuth, Morris e Pratt



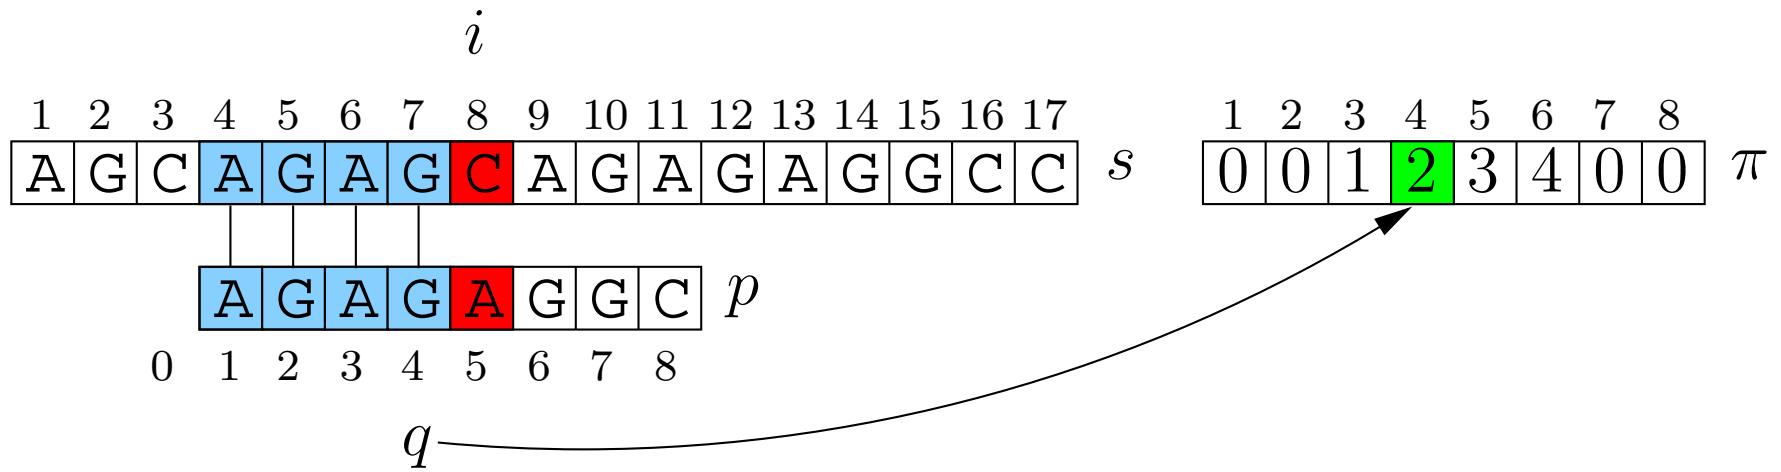
# Knuth, Morris e Pratt



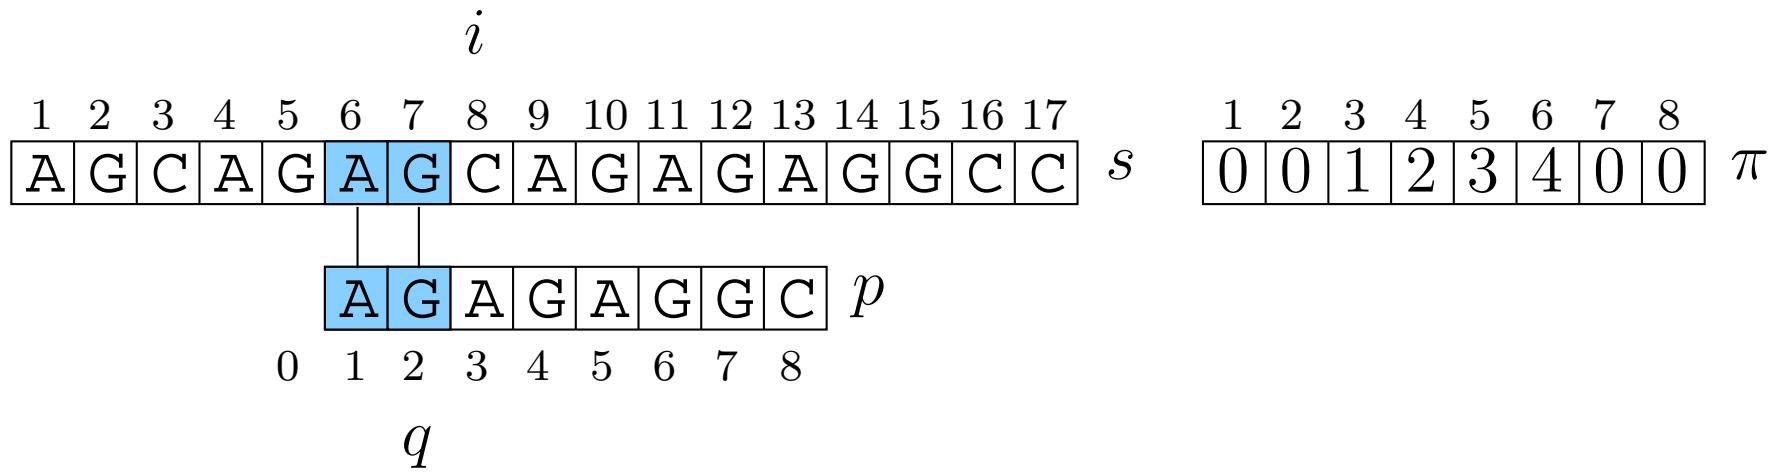
# Knuth, Morris e Pratt



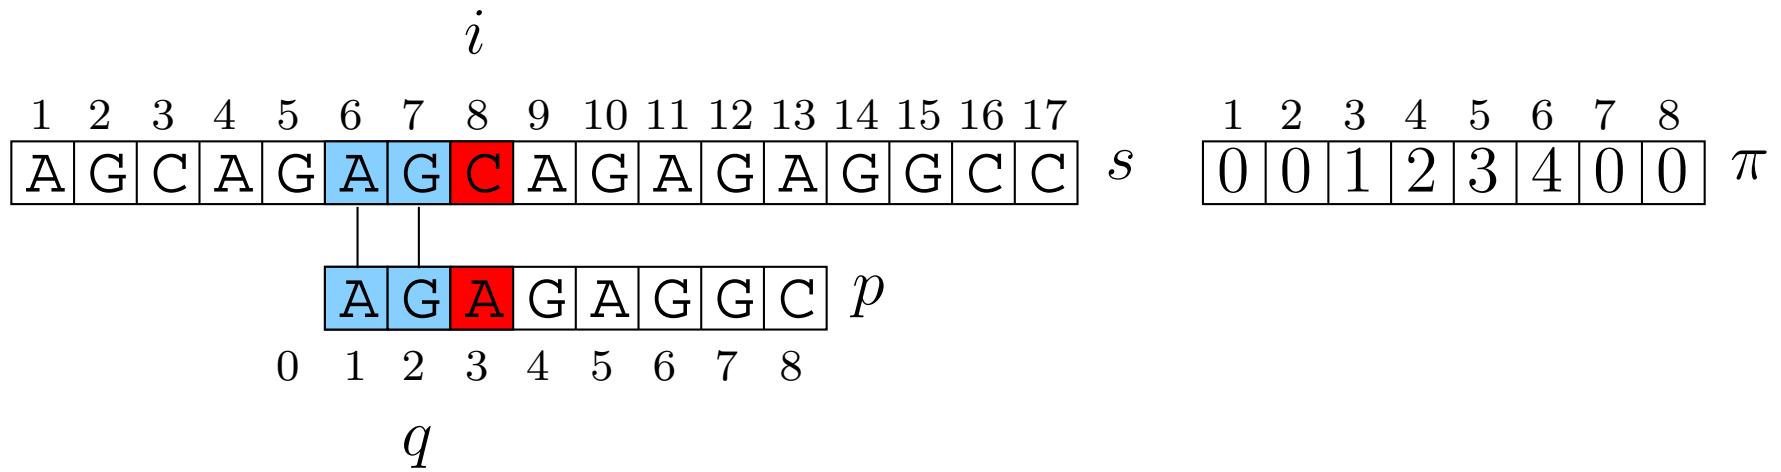
# Knuth, Morris e Pratt



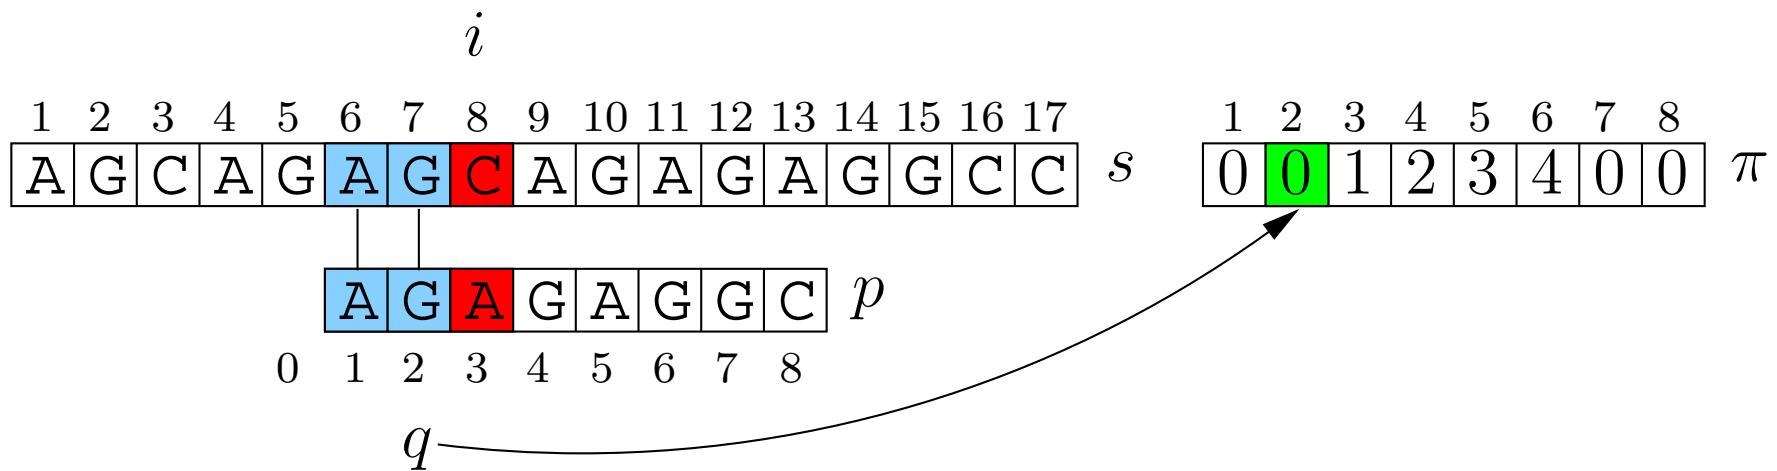
# Knuth, Morris e Pratt



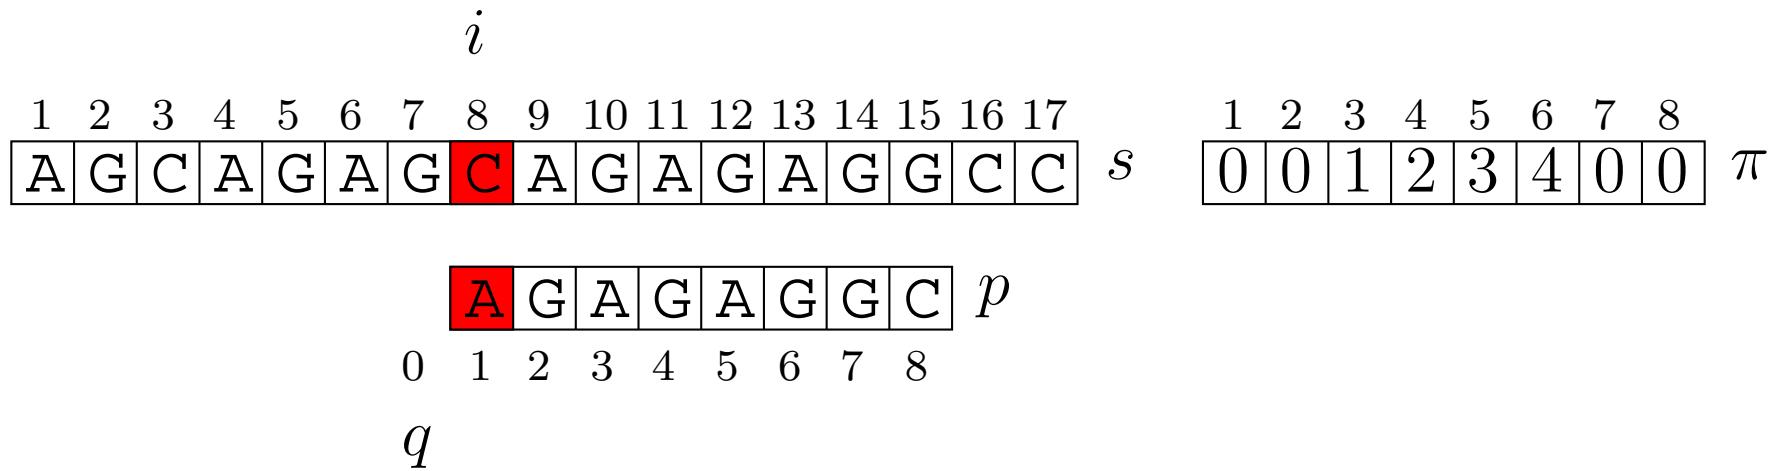
# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt

$i$

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
A	G	C	A	G	A	G	C	A	G	A	G	A	G	G	C	C

$s$

1	2	3	4	5	6	7	8
0	0	1	2	3	4	0	0

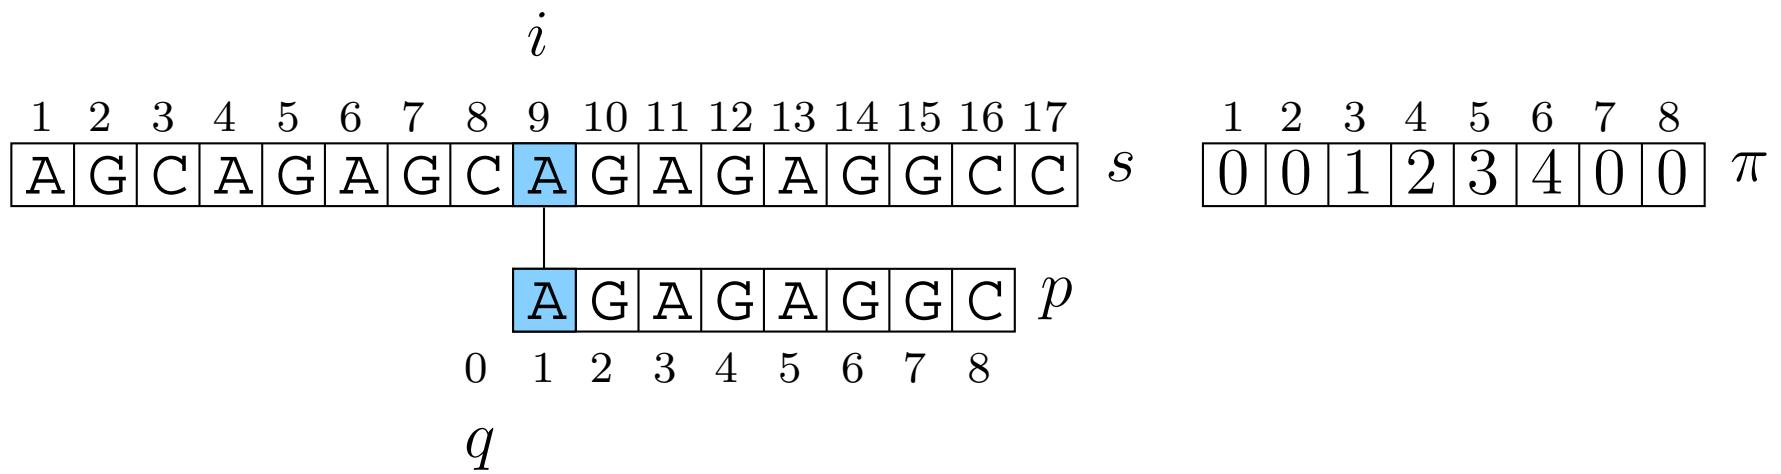
$\pi$

A	G	A	G	A	G	G	C
---	---	---	---	---	---	---	---

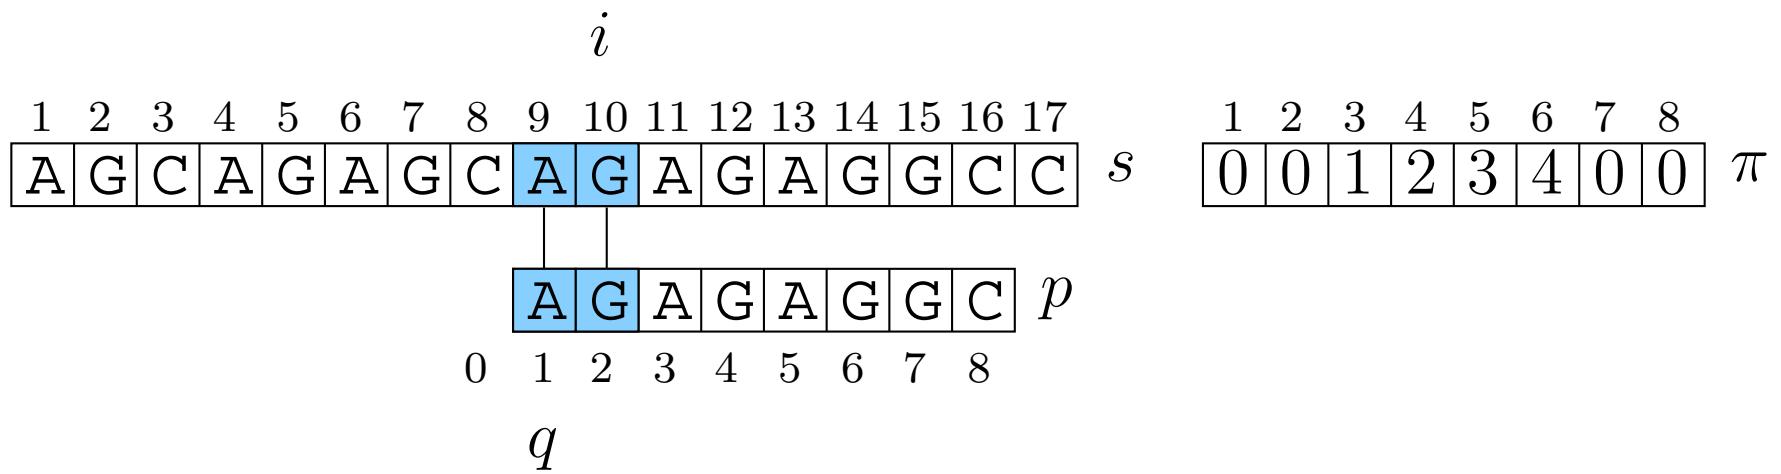
0    1    2    3    4    5    6    7    8

$q$

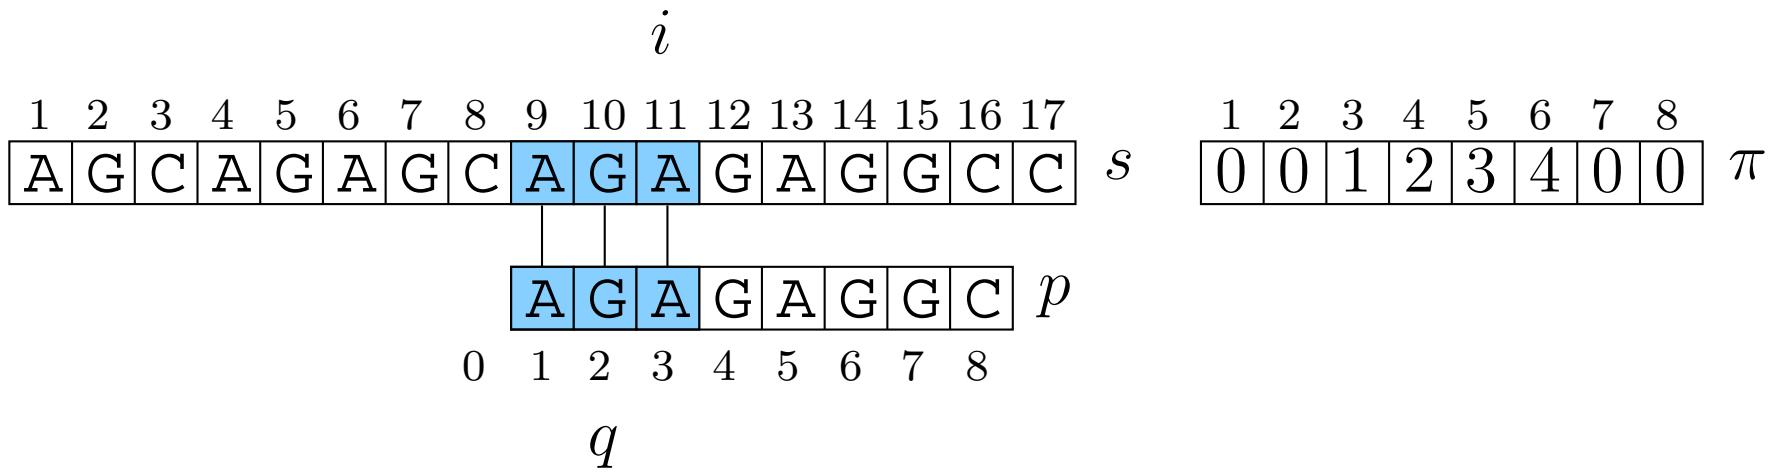
# Knuth, Morris e Pratt



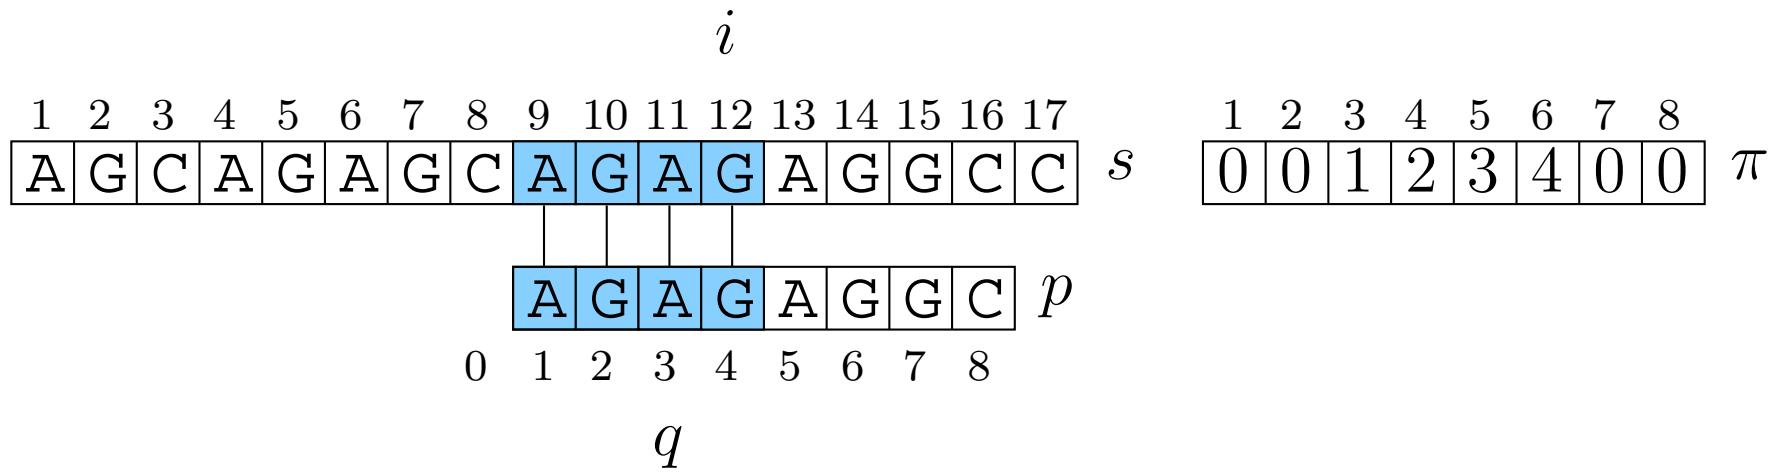
# Knuth, Morris e Pratt



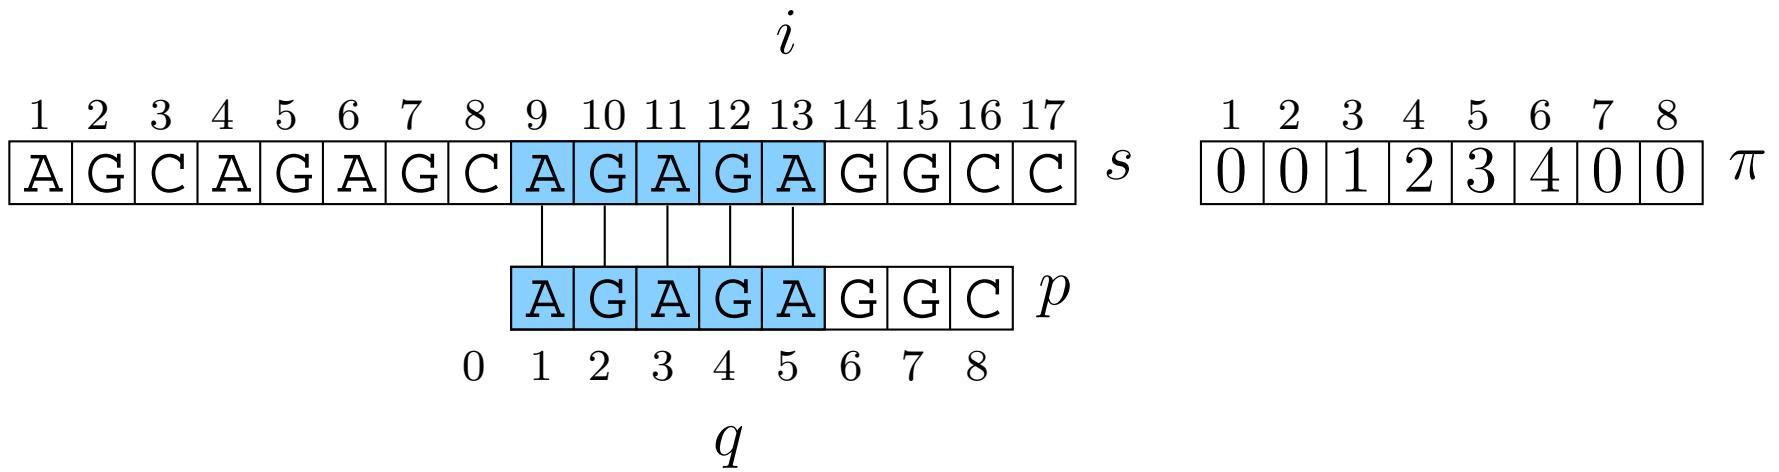
# Knuth, Morris e Pratt



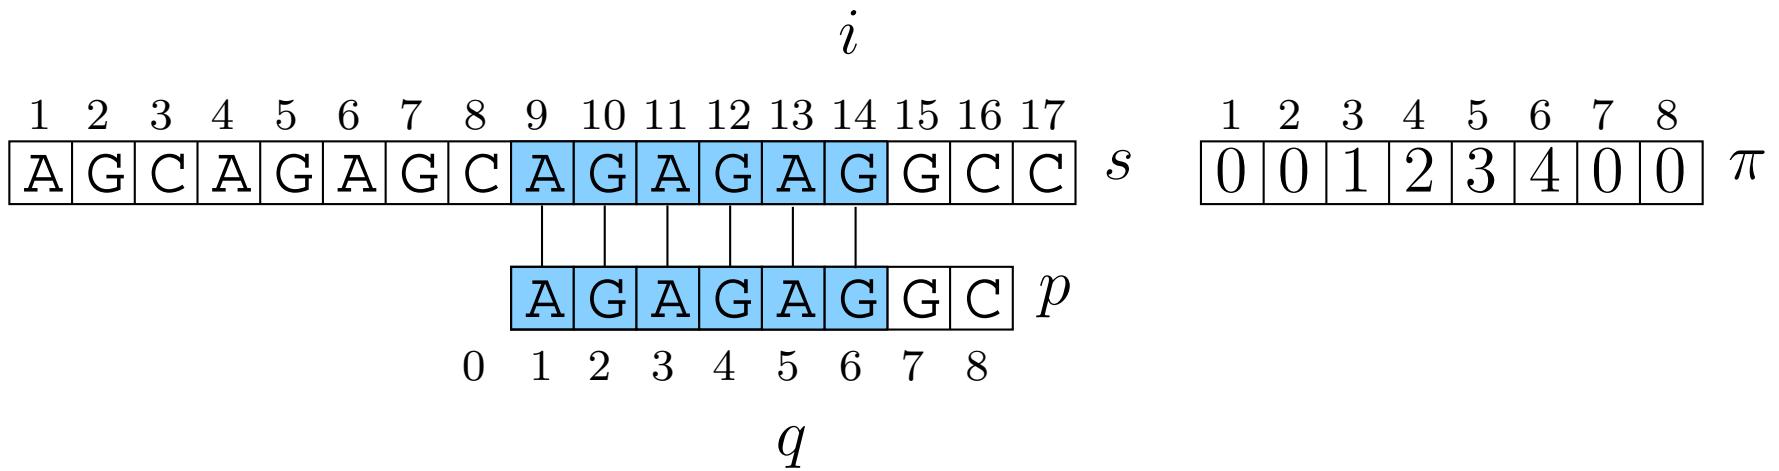
# Knuth, Morris e Pratt



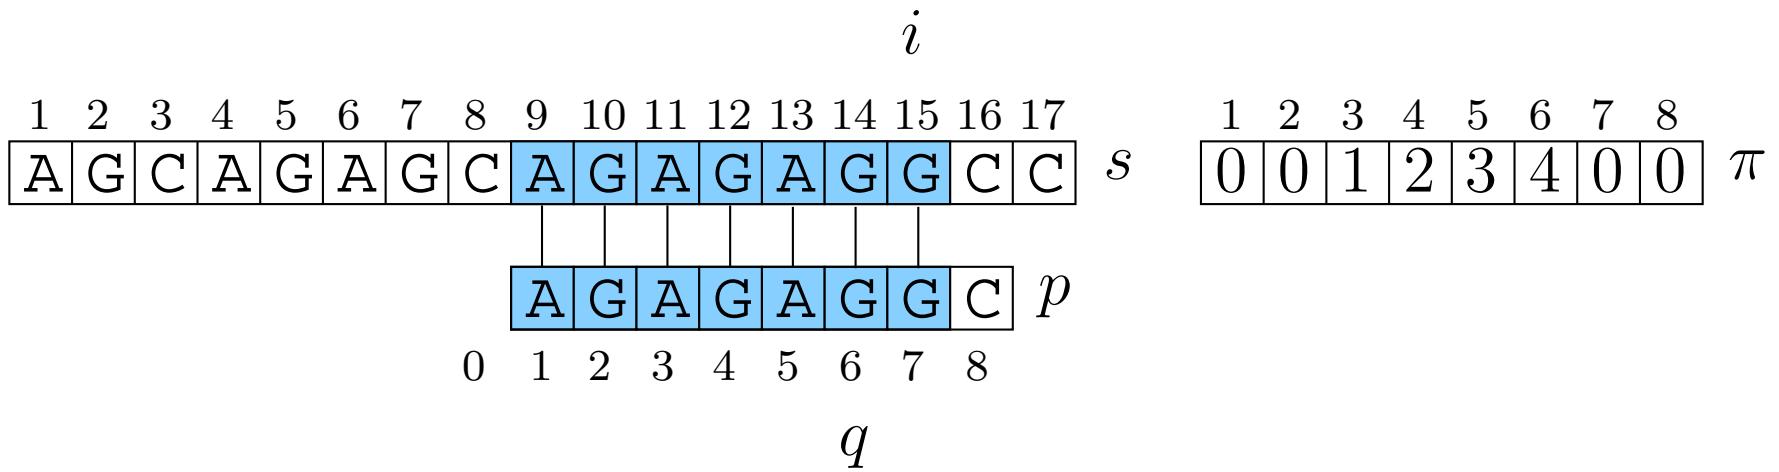
# Knuth, Morris e Pratt



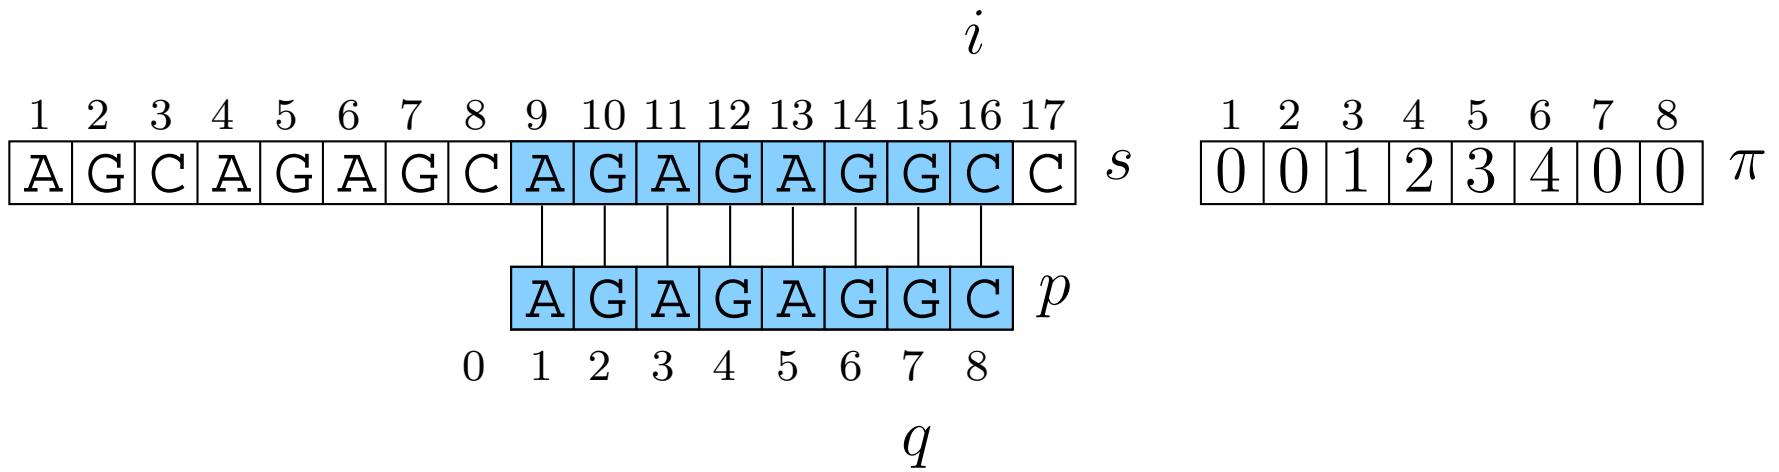
# Knuth, Morris e Pratt



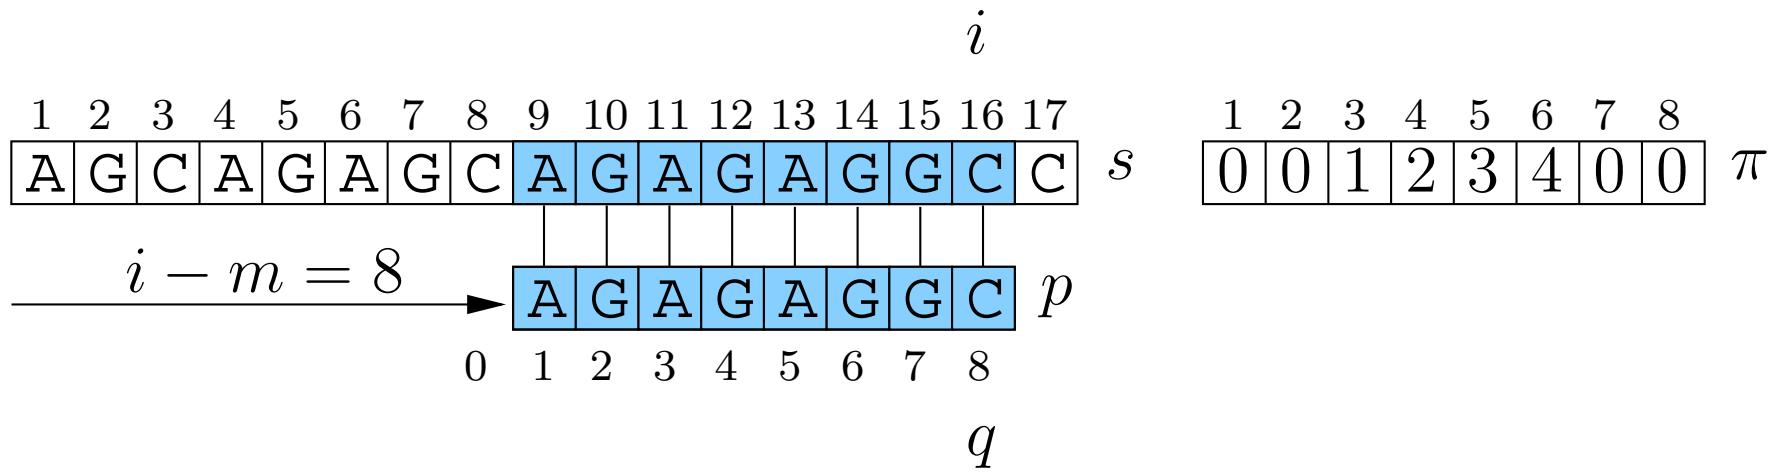
# Knuth, Morris e Pratt



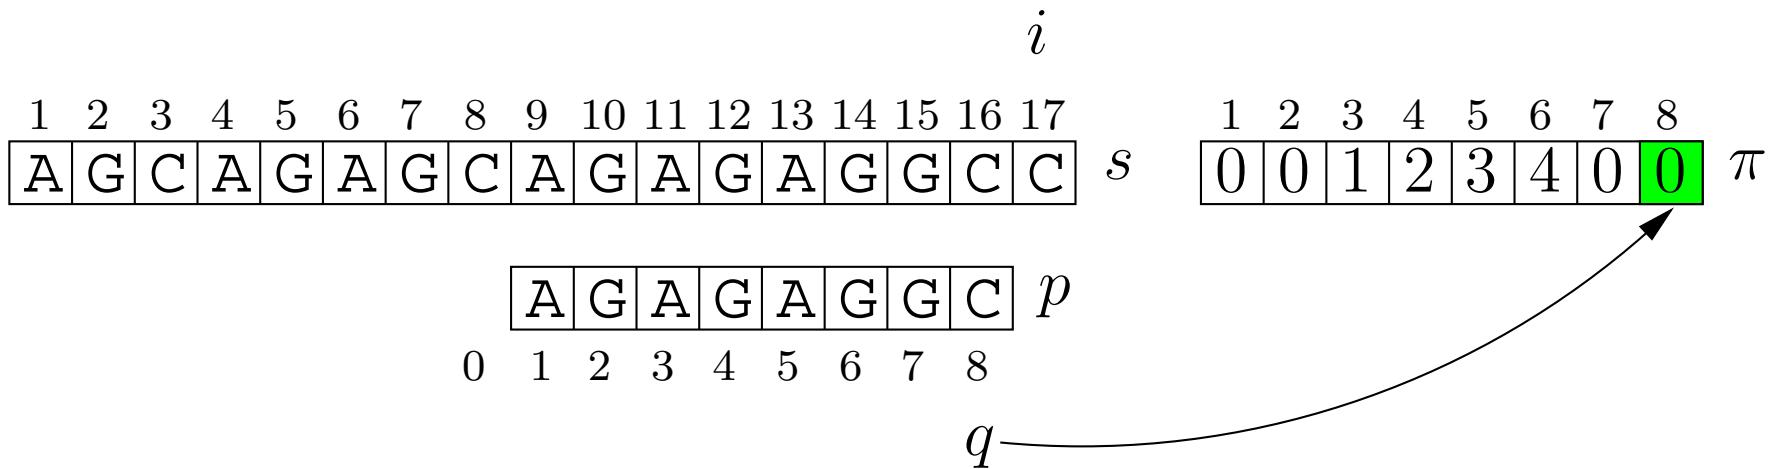
# Knuth, Morris e Pratt



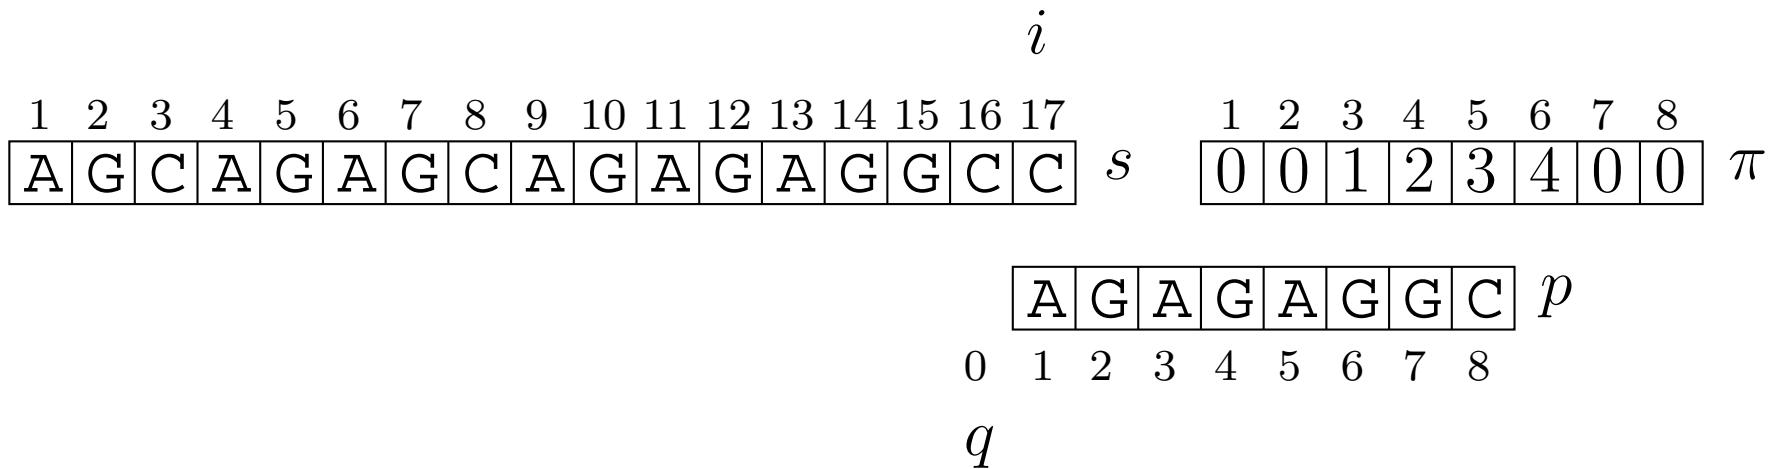
# Knuth, Morris e Pratt



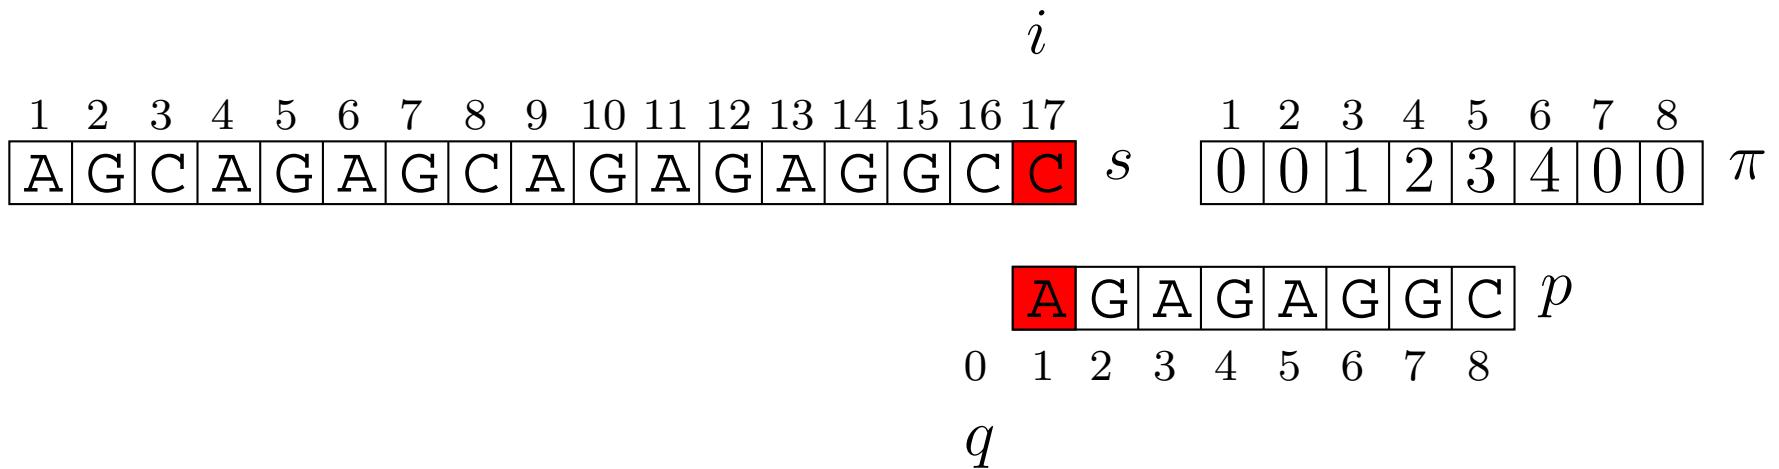
# Knuth, Morris e Pratt



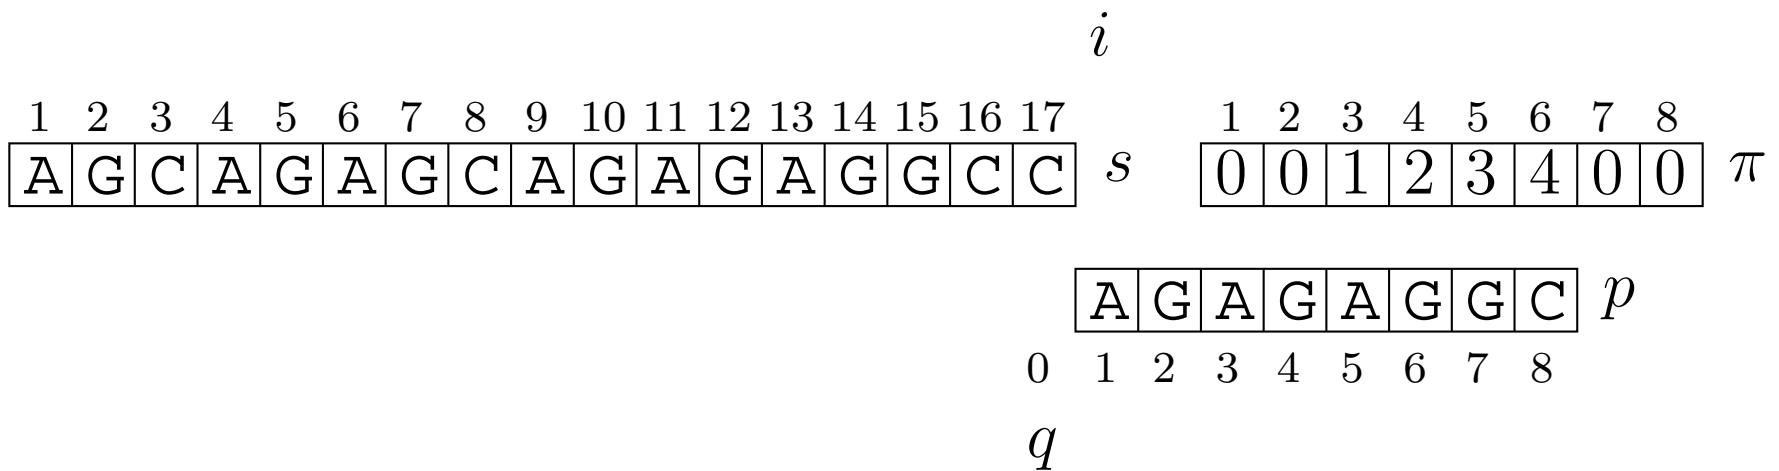
# Knuth, Morris e Pratt



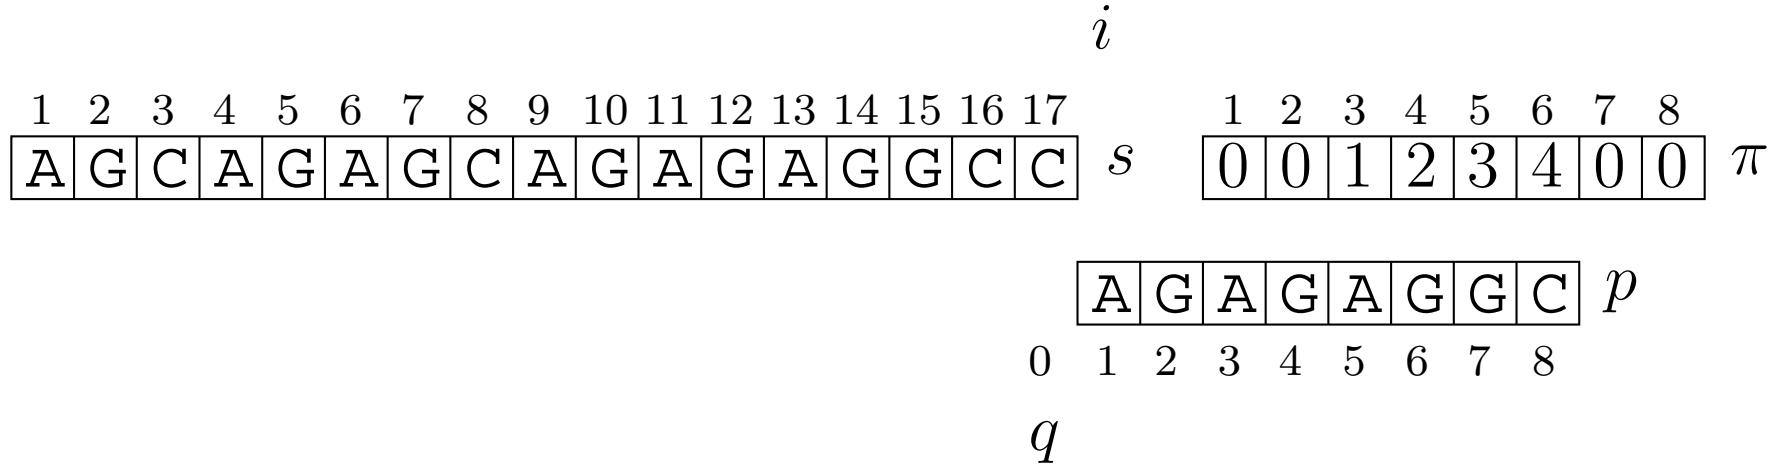
# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



# Knuth, Morris e Pratt



Tempo de execução:  $O(m + n)$ .

# Boyer e Moore

- O algoritmo de Boyer e Moore tem a estrutura do algoritmo ingênuo com a adição de duas heurísticas:

# Boyer e Moore

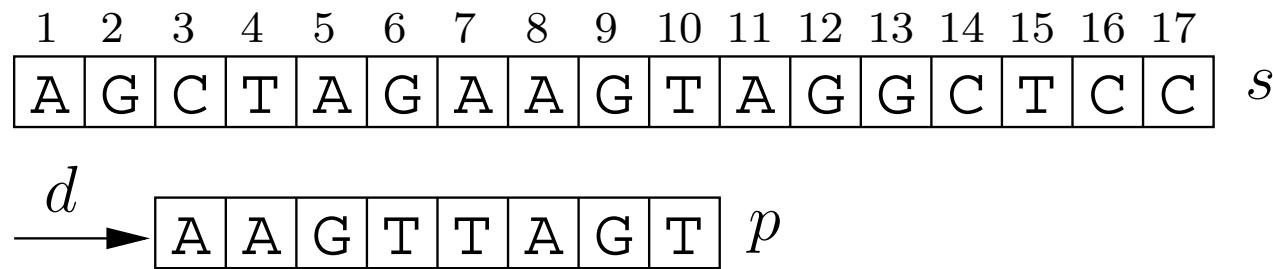
- O algoritmo de Boyer e Moore tem a estrutura do algoritmo ingênuo com a adição de duas heurísticas:
  - **heurística do símbolo ruim;**

# Boyer e Moore

- O algoritmo de Boyer e Moore tem a estrutura do algoritmo ingênuo com a adição de duas heurísticas:
  - **heurística do símbolo ruim;**
  - **heurística do sufixo bom.**

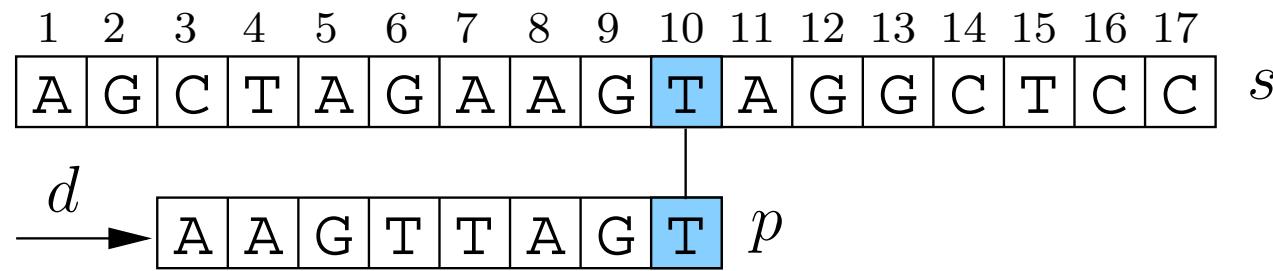
# Boyer e Moore

## Heurística do símbolo ruim



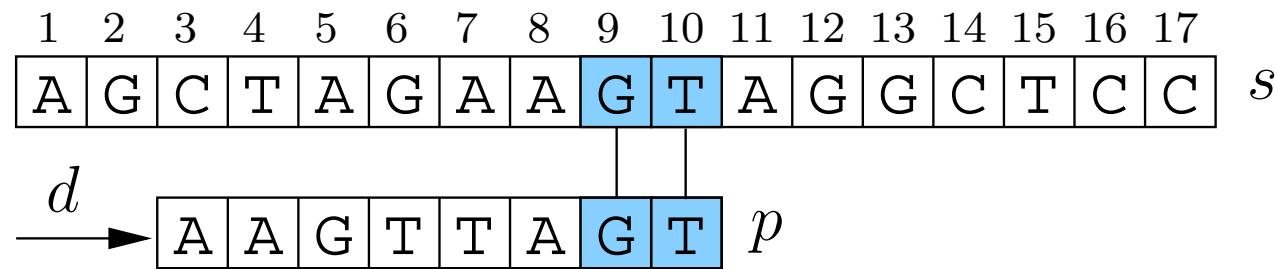
# Boyer e Moore

## Heurística do símbolo ruim



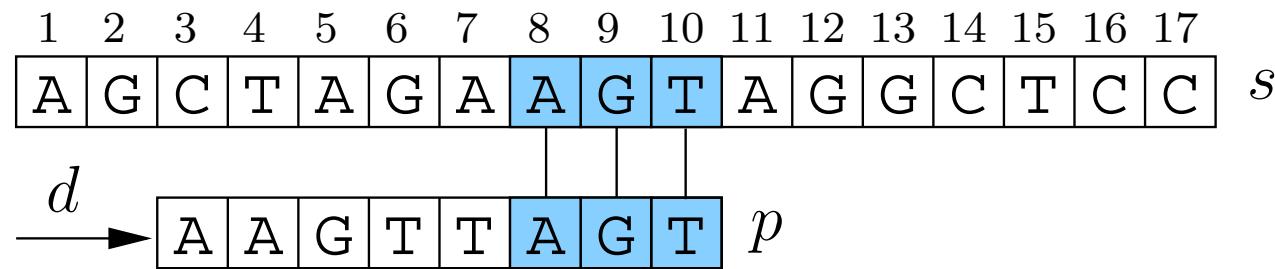
# Boyer e Moore

## Heurística do símbolo ruim



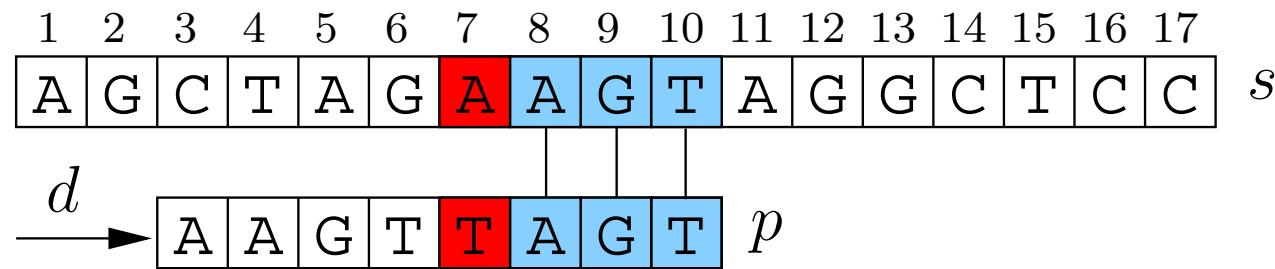
# Boyer e Moore

## Heurística do símbolo ruim



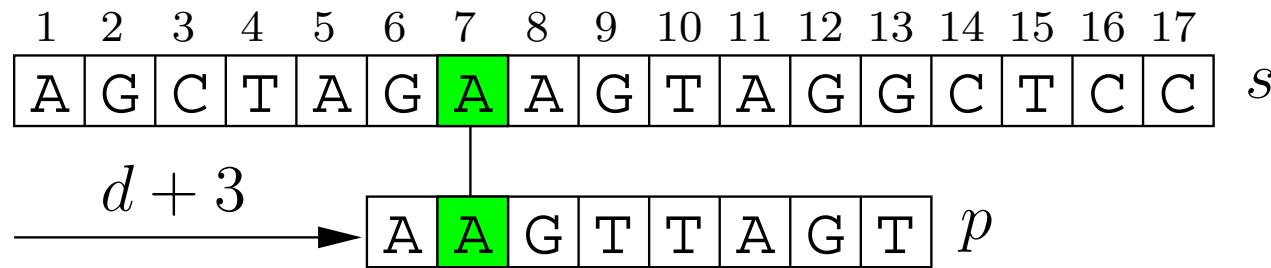
# Boyer e Moore

## Heurística do símbolo ruim



# Boyer e Moore

## Heurística do símbolo ruim



Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$  para algum  $j$ , com  $1 \leq j \leq m$ , então a heurística do símbolo ruim encontra o maior índice  $k$ , com  $1 \leq k \leq m$ , tal que  $s[d + j] = p[k]$  se um tal  $k$  existe. Caso contrário,  $k = 0$ .

Então, o algoritmo toma o próximo deslocamento como sendo  $d + j - k$ .

# Boyer e Moore

A **função última ocorrência**  $\lambda$  implementa a idéia de deslocamentos baseados em um símbolo ruim e é definida da seguinte forma:  $\lambda[a]$  é o índice da posição mais à direita no padrão  $p$  em que o símbolo  $a$  ocorre, para cada símbolo  $a \in \Sigma$ .

# Boyer e Moore

**FUNÇÃO-ÚLTIMA-OCORRÊNCIA**( $p, \Sigma$ ): recebe um padrão  $p$  de  $m$  símbolos e um alfabeto  $\Sigma$  e devolve a função última ocorrência  $\lambda$  para todo símbolo em  $\Sigma$ .

- 1: **para** cada símbolo  $a \in \Sigma$  **faça**
- 2:     $\lambda[a] \leftarrow 0$
- 3: **para**  $j \leftarrow 1$  **até**  $m$  **faça**
- 4:     $\lambda[p[j]] \leftarrow j$
- 5: **devolva**  $\lambda$

# Boyer e Moore

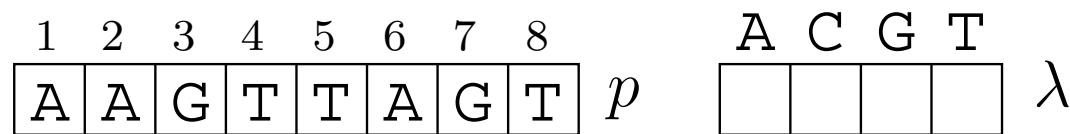
**FUNÇÃO-ÚLTIMA-OCORRÊNCIA**( $p, \Sigma$ ): recebe um padrão  $p$  de  $m$  símbolos e um alfabeto  $\Sigma$  e devolve a função última ocorrência  $\lambda$  para todo símbolo em  $\Sigma$ .

- 1: **para** cada símbolo  $a \in \Sigma$  **faça**
- 2:     $\lambda[a] \leftarrow 0$
- 3: **para**  $j \leftarrow 1$  **até**  $m$  **faça**
- 4:     $\lambda[p[j]] \leftarrow j$
- 5: **devolva**  $\lambda$

Tempo de execução:  $O(\Sigma + m)$

# Boyer e Moore

## Heurística do símbolo ruim – Função última ocorrência



# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		0				

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		0	0			

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		0	0	0		

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		0	0	0	0	

# Boyer e Moore

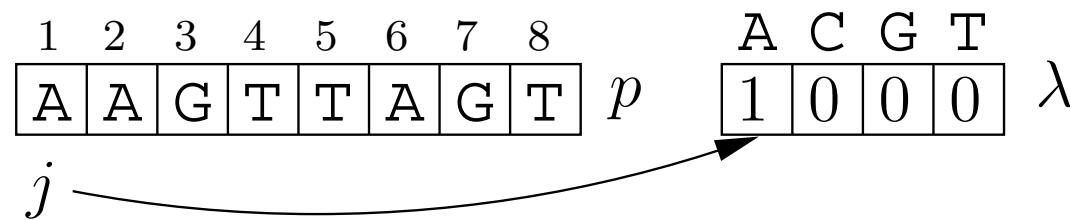
Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		0	0	0	0	

$j$

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



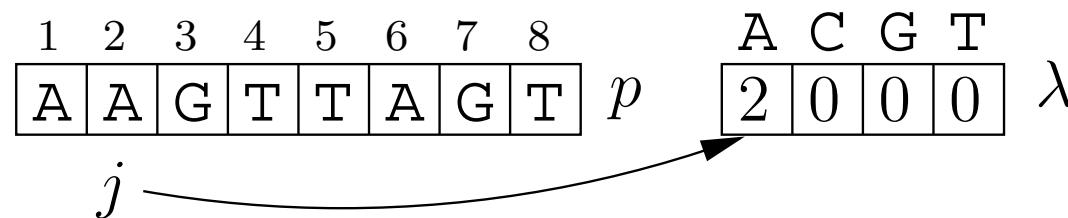
# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8		A	C	G	T	
A	A	G	T	T	A	G	T	$p$	1	0	0	0	$\lambda$
		$j$											

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



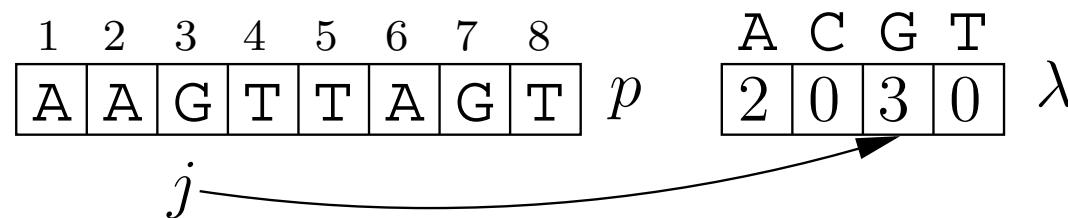
# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8		A	C	G	T	
A	A	G	T	T	A	G	T	$p$	2	0	0	0	$\lambda$
		$j$											

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

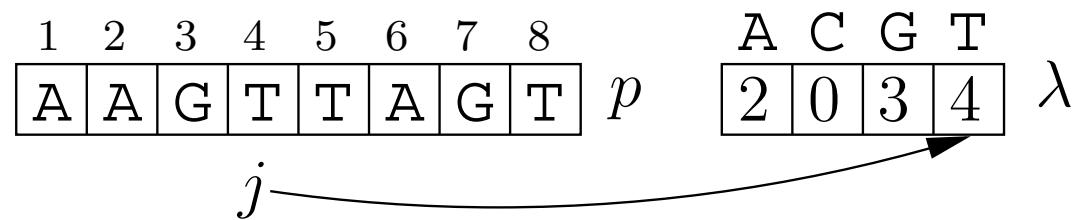
1	2	3	4	5	6	7	8				
A	A	G	T	T	A	G	T	$p$	A	C	G
									2	0	3

$j$

$\lambda$

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



# Boyer e Moore

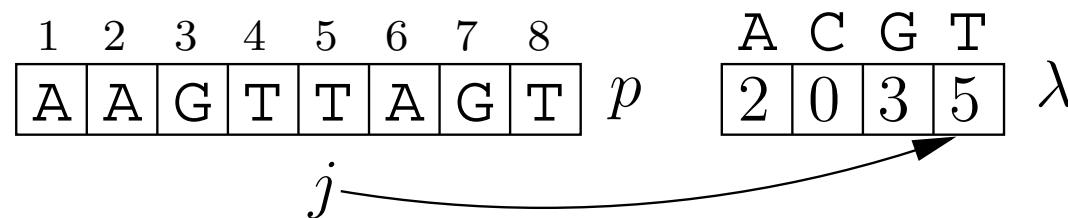
Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		2	0	3	4	

$j$

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



# Boyer e Moore

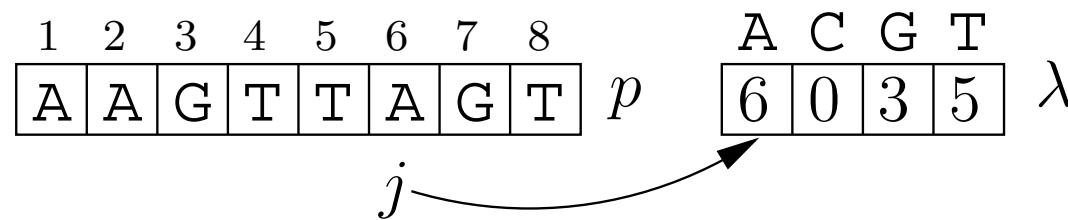
Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		2	0	3	5	

$j$

# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



# Boyer e Moore

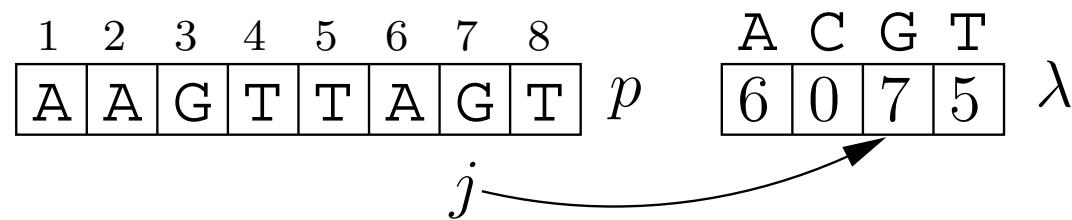
Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		6	0	3	5	

$j$

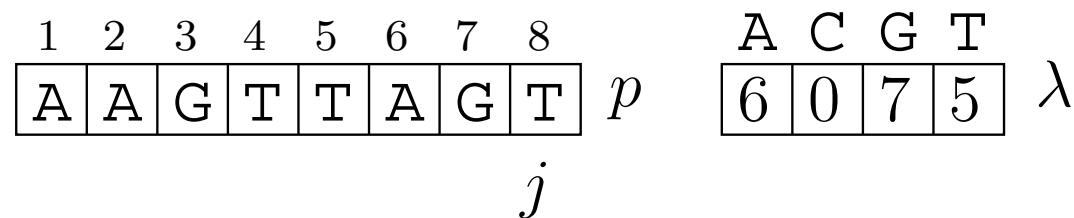
# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



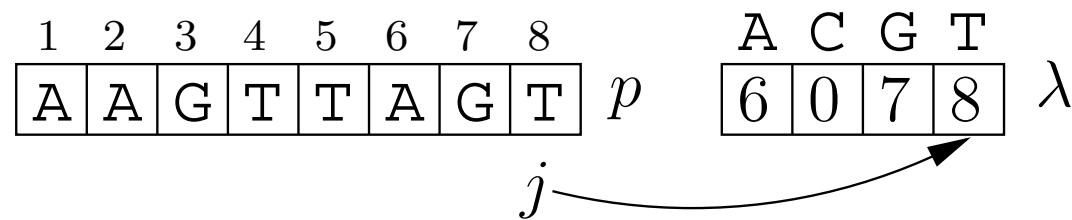
# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência



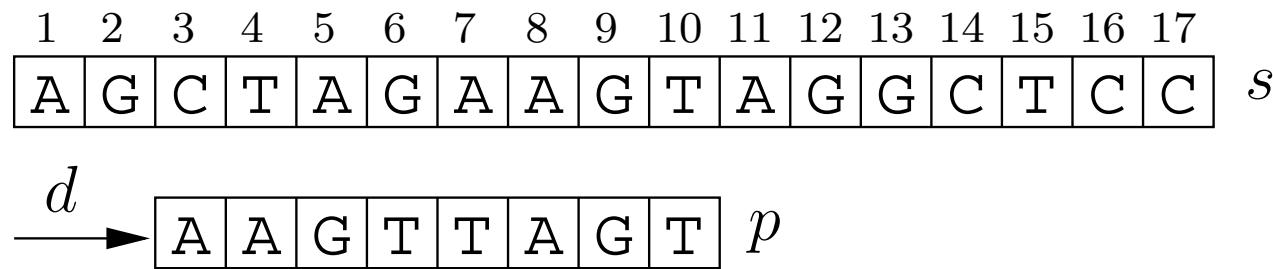
# Boyer e Moore

Heurística do símbolo ruim – Função última ocorrência

1	2	3	4	5	6	7	8	$p$	A	C	G	T	$\lambda$
A	A	G	T	T	A	G	T		6	0	7	8	

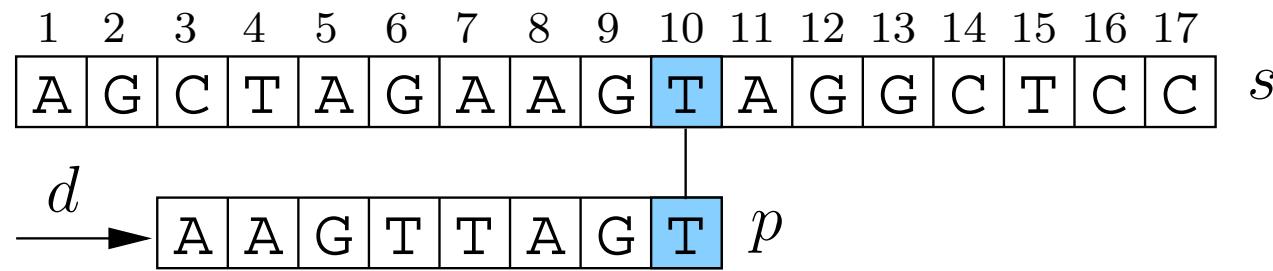
# Boyer e Moore

## Heurística do sufixo bom



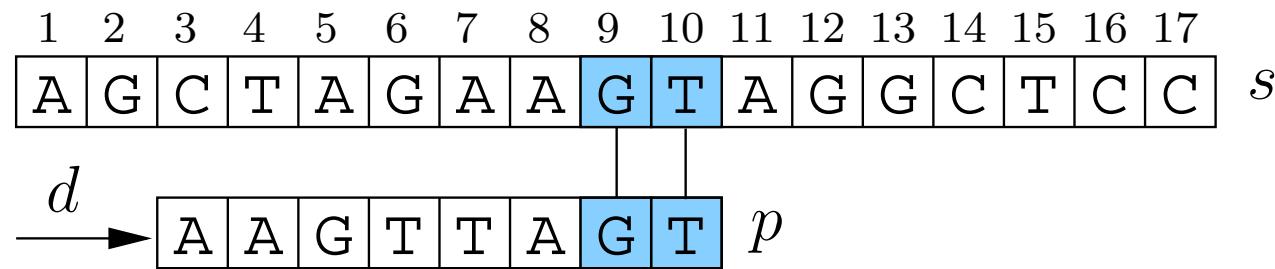
# Boyer e Moore

## Heurística do sufixo bom



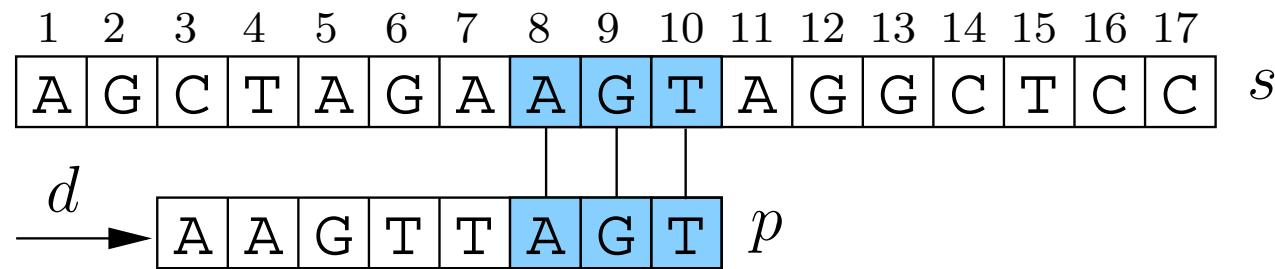
# Boyer e Moore

## Heurística do sufixo bom



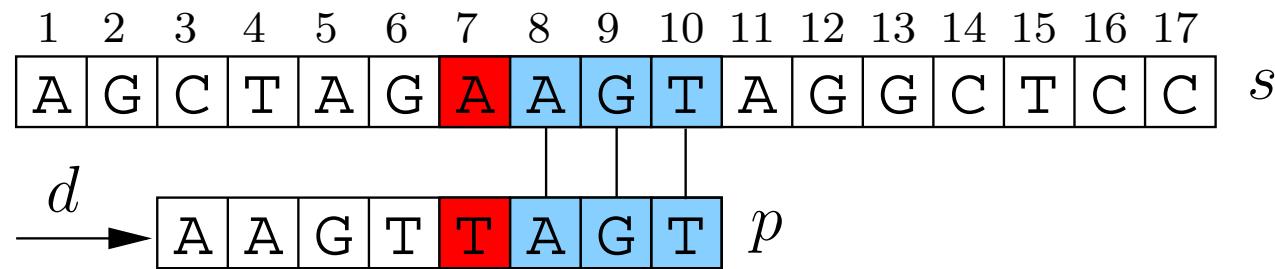
# Boyer e Moore

## Heurística do sufixo bom



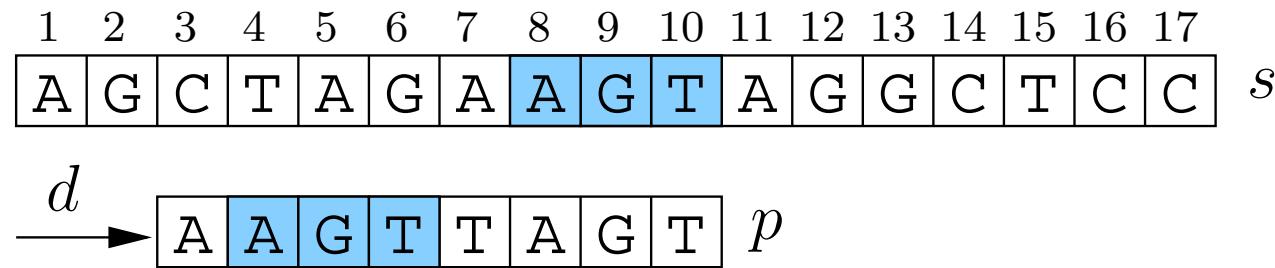
# Boyer e Moore

## Heurística do sufixo bom



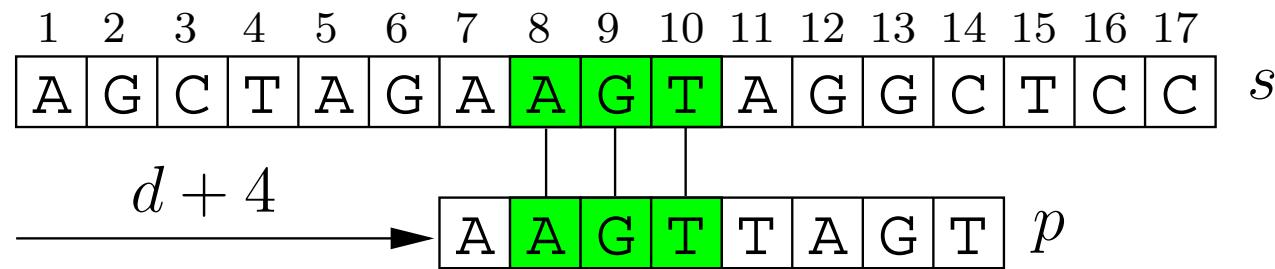
# Boyer e Moore

## Heurística do sufixo bom



# Boyer e Moore

## Heurística do sufixo bom



# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;

# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;
- A função  $\gamma$  é chamada **função sufixo bom** para o padrão  $p$ . O valor  $\gamma[j]$  é o menor avanço possível para o deslocamento  $d$  para o qual os símbolos no sufixo bom  $s[d + j + 1..d + m]$  do texto se casam com alguma subsequência do padrão;

# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;
- A função  $\gamma$  é chamada **função sufixo bom** para o padrão  $p$ . O valor  $\gamma[j]$  é o menor avanço possível para o deslocamento  $d$  para o qual os símbolos no sufixo bom  $s[d + j + 1..d + m]$  do texto se casam com alguma subsequência do padrão;
- A função sufixo bom é dada por

$$\gamma[j] = m - \max\{k : 0 \leq k < m \text{ e } p[j + 1..m] \sim p[1..k]\}.$$

Ou seja,  $\gamma[j]$  é o menor valor que podemos adicionar ao deslocamento  $d$  e para fazer com que os símbolos do sufixo bom  $s[d + j + 1..d + m]$  de  $s$  se casem com o novo posicionamento de  $p$ .

# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;
- A função  $\gamma$  é chamada **função sufixo bom** para o padrão  $p$ . O valor  $\gamma[j]$  é o menor avanço possível para o deslocamento  $d$  para o qual os símbolos no sufixo bom  $s[d + j + 1..d + m]$  do texto se casam com alguma subsequência do padrão;
- A função sufixo bom é dada por

$$\gamma[j] = m - \max\{k : \pi[m] \leq k < m \text{ e } p[j + 1..m] \sim p[1..k]\},$$

onde  $\pi$  é a função prefixo para o padrão  $p$ .

# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;
- A função  $\gamma$  é chamada **função sufixo bom** para o padrão  $p$ . O valor  $\gamma[j]$  é o menor avanço possível para o deslocamento  $d$  para o qual os símbolos no sufixo bom  $s[d + j + 1..d + m]$  do texto se casam com alguma subsequência do padrão;
- A função sufixo bom é dada por

$$\gamma[j] = m - \max \left( \{\pi[m]\} \cup \{k : \pi[m] \leq k < m \text{ e } p[j + 1..m] \text{ é sufixo de } p[1..k]\} \right),$$

onde  $\pi$  é a função prefixo para o padrão  $p$ .

# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;
- A função  $\gamma$  é chamada **função sufixo bom** para o padrão  $p$ . O valor  $\gamma[j]$  é o menor avanço possível para o deslocamento  $d$  para o qual os símbolos no sufixo bom  $s[d + j + 1..d + m]$  do texto se casam com alguma subsequência do padrão;
- A função sufixo bom é dada por

$$\gamma[j] = m - \max \left( \{\pi[m]\} \cup \{m - l + \pi'[l]: 1 \leq l \leq m \text{ e } j = m - \pi'[l]\} \right),$$

onde  $\pi$  é a função prefixo para o padrão  $p$  e  $\pi'$  é a função prefixo para o reverso  $p'$  do padrão  $p$ .

# Boyer e Moore

## Heurística do sufixo bom

- Dado um deslocamento  $d \geq 0$ , se  $p[j] \neq s[d + j]$ , para  $j < m$ , então  $d$  pode ser seguramente avançado de  $\gamma[j]$  posições;
- A função  $\gamma$  é chamada **função sufixo bom** para o padrão  $p$ . O valor  $\gamma[j]$  é o menor avanço possível para o deslocamento  $d$  para o qual os símbolos no sufixo bom  $s[d + j + 1..d + m]$  do texto se casam com alguma subsequência do padrão;
- A função sufixo bom é dada por

$$\gamma[j] = \min \left( \{m - \pi[m]\} \cup \{l - \pi'[l]: 1 \leq l \leq m \text{ e } j = m - \pi'[l]\} \right),$$

onde  $\pi$  é a função prefixo para o padrão  $p$  e  $\pi'$  é a função prefixo para o reverso  $p'$  do padrão  $p$ .

# Boyer e Moore

**FUNÇÃO-SUFIXO-BOM( $p$ ):** recebe o padrão  $p$  de  $m$  símbolos e devolve a função sufixo bom  $\gamma$  para  $p$ .

- 1:  $\pi \leftarrow \text{FUNÇÃO-PREFIXO}(p)$
- 2:  $p' \leftarrow \text{REVERSO}(p)$
- 3:  $\pi' \leftarrow \text{FUNÇÃO-PREFIXO}(p')$
- 4: **para**  $j \leftarrow 0$  **até**  $m$  **faça**
- 5:    $\gamma[j] \leftarrow m - \pi[m]$
- 6: **para**  $l \leftarrow 1$  **até**  $m$  **faça**
- 7:    $j \leftarrow m - \pi'[l]$
- 8:   **se**  $\gamma[j] > l - \pi'[l]$  **então**
- 9:      $\gamma[j] \leftarrow l - \pi'[l]$
- 10: **devolva**  $\gamma$

# Boyer e Moore

**FUNÇÃO-SUFIXO-BOM( $p$ ):** recebe o padrão  $p$  de  $m$  símbolos e devolve a função sufixo bom  $\gamma$  para  $p$ .

- 1:  $\pi \leftarrow \text{FUNÇÃO-PREFIXO}(p)$
- 2:  $p' \leftarrow \text{REVERSO}(p)$
- 3:  $\pi' \leftarrow \text{FUNÇÃO-PREFIXO}(p')$
- 4: **para**  $j \leftarrow 0$  **até**  $m$  **faça**
- 5:    $\gamma[j] \leftarrow m - \pi[m]$
- 6: **para**  $l \leftarrow 1$  **até**  $m$  **faça**
- 7:    $j \leftarrow m - \pi'[l]$
- 8:   **se**  $\gamma[j] > l - \pi'[l]$  **então**
- 9:      $\gamma[j] \leftarrow l - \pi'[l]$
- 10: **devolva**  $\gamma$

Tempo de execução:  $O(m)$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

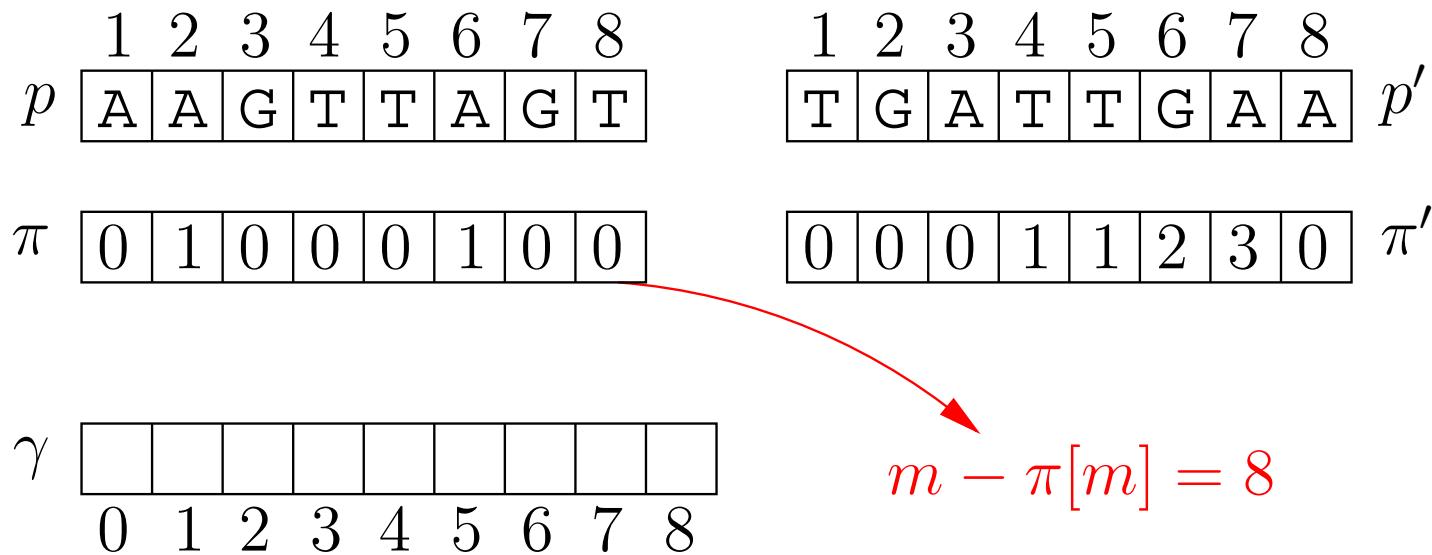
	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$								
	0	1	2	3	4	5	6	7

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom



# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	8
	0	1	2	3	4	5	6	7	8

$$m - \pi[m] = 8$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	8
	0	1	2	3	4	5	6	7	8

$$l \quad j = m - \pi'[l]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	8
	0	1	2	3	4	5	6	7	8

1	2	3	4	5	6	7	8
T	G	A	T	T	G	A	A

$\pi'$	0	0	0	1	1	2	3	0
--------	---	---	---	---	---	---	---	---

$$l = 1 \quad j = m - \pi'[1]$$



# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	8
	0	1	2	3	4	5	6	7	8

1	2	3	4	5	6	7	8
T	G	A	T	T	G	A	A

$\pi'$	0	0	0	1	1	2	3	0
--------	---	---	---	---	---	---	---	---

$$l = 1 \quad j = m - \pi'[1]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	8
	0	1	2	3	4	5	6	7	8

$$l = 1 \quad j = 8$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	8
	0	1	2	3	4	5	6	7	8

$$l = 1 \quad j = 8$$
$$\gamma[8] > 1 - \pi'[1]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	1
	0	1	2	3	4	5	6	7	8

$$l = 1 \quad j = 8$$
$$\gamma[8] > 1 - \pi'[1]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	1
	0	1	2	3	4	5	6	7	8

$$l = 2 \quad j = 8$$

$$\gamma[8] \not> 2 - \pi'[2]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	1
	0	1	2	3	4	5	6	7	8

$$l = 3 \quad j = 8$$

$$\gamma[8] \not> 3 - \pi'[3]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	8	1
	0	1	2	3	4	5	6	7	8

$$l = 4 \quad j = 7$$
$$\gamma[7] > 4 - \pi'[4]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	3	1
	0	1	2	3	4	5	6	7	8

$$l = 4 \quad j = 7$$
$$\gamma[7] > 4 - \pi'[4]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	3	1
	0	1	2	3	4	5	6	7	8

$$l = 5 \quad j = 7$$

$$\gamma[7] \not> 5 - \pi'[5]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	8	3	1
	0	1	2	3	4	5	6	7	8

$$l = 6 \quad j = 6$$
$$\gamma[6] > 6 - \pi'[6]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	4	3	1
	0	1	2	3	4	5	6	7	8

$$l = 6 \quad j = 6$$
$$\gamma[6] > 6 - \pi'[6]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	8	4	3	1
	0	1	2	3	4	5	6	7	8

$$l = 7 \quad j = 5$$
$$\gamma[5] > 7 - \pi'[7]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	4	4	3	1
	0	1	2	3	4	5	6	7	8

$$l = 7 \quad j = 5$$
$$\gamma[5] > 7 - \pi'[7]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

$\gamma$	8	8	8	8	8	4	4	3	1
	0	1	2	3	4	5	6	7	8

$$l = 8 \quad j = 8$$
$$\gamma[8] \not> 9 - \pi'[8]$$

# Boyer e Moore

## Heurística do sufixo bom – Função sufixo bom

	1	2	3	4	5	6	7	8
$p$	A	A	G	T	T	A	G	T

$\pi$	0	1	0	0	0	1	0	0
-------	---	---	---	---	---	---	---	---

	1	2	3	4	5	6	7	8
	T	G	A	T	T	G	A	A

	0	0	0	1	1	2	3	0
--	---	---	---	---	---	---	---	---

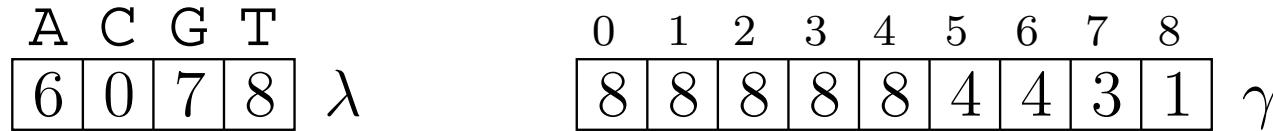
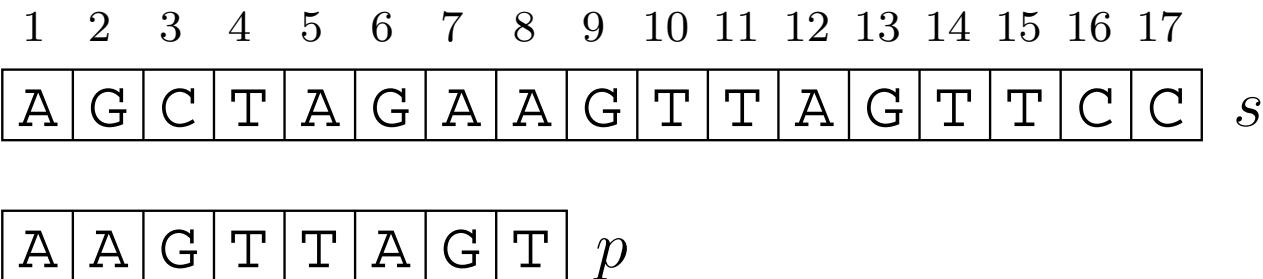
$\gamma$	8	8	8	8	8	4	4	3	1
	0	1	2	3	4	5	6	7	8

# Boyer e Moore

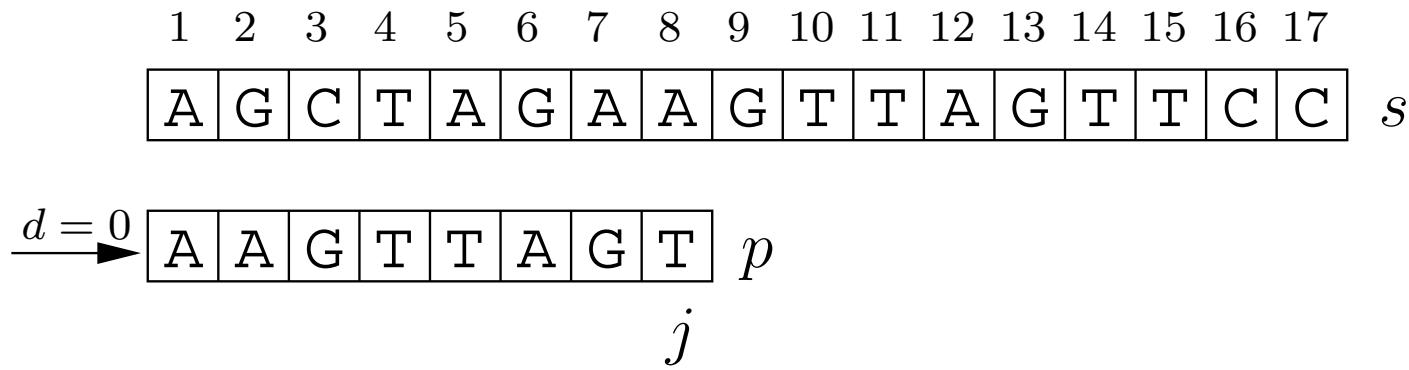
$\text{BM}(s, p, \Sigma)$ : recebe um texto  $s$  de  $n$  símbolos, um padrão  $p$  de  $m$  símbolos de um alfabeto  $\Sigma$  e devolve os índices em  $s$  onde  $p$  ocorre.

- 1:  $\lambda \leftarrow \text{FUNÇÃO-ÚLTIMA-OCORRÊNCIA}(p, \Sigma)$
- 2:  $\gamma \leftarrow \text{FUNÇÃO-SUFIXO-BOM}(p)$
- 3:  $d \leftarrow 0$
- 4: **enquanto**  $d \leq n - m$  **faça**
- 5:    $j \leftarrow m$
- 6:   **enquanto**  $j > 0$  e  $p[j] = s[d + j]$  **faça**
- 7:      $j \leftarrow j - 1$
- 8:   **se**  $j = 0$  **então**
- 9:     **escreva** “Padrão ocorre no texto com deslocamento”  $d$
- 10:     $d \leftarrow d + \gamma[0]$
- 11:   **senão**
- 12:      $d \leftarrow d + \max(\gamma[j], j - \lambda[s[d + j]])$

# Boyer e Moore



# Boyer e Moore



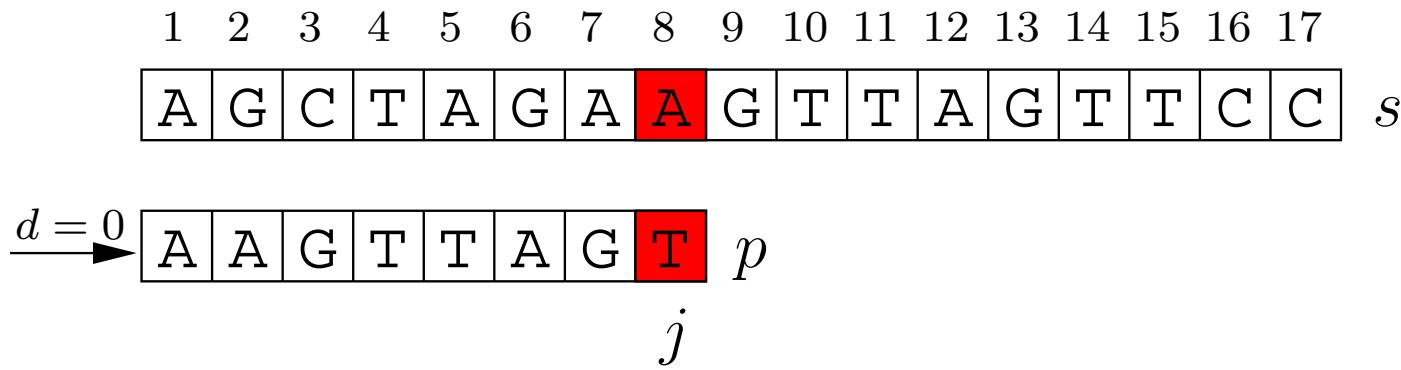
A	C	G	T
6	0	7	8

$\lambda$

0	1	2	3	4	5	6	7	8
8	8	8	8	8	4	4	3	1

$\gamma$

# Boyer e Moore



A C G T

6	0	7	8
---	---	---	---

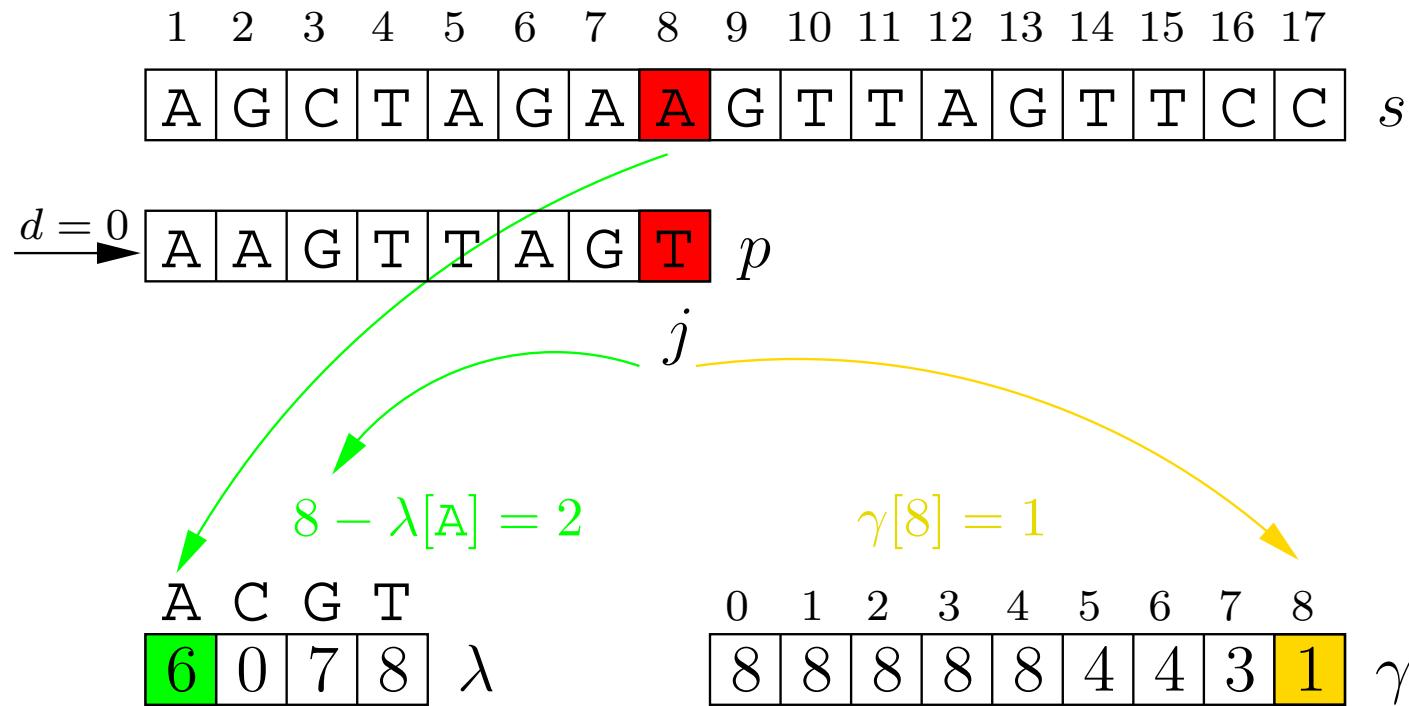
$\lambda$

0 1 2 3 4 5 6 7 8

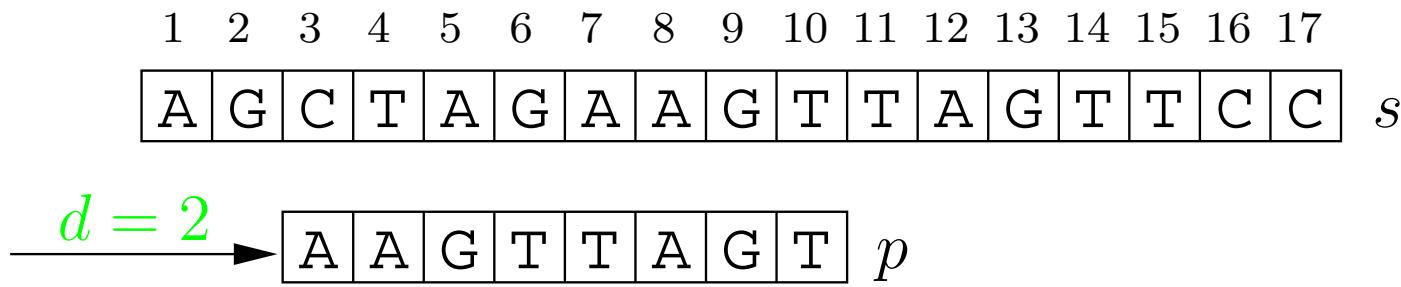
8	8	8	8	8	4	4	3	1
---	---	---	---	---	---	---	---	---

$\gamma$

# Boyer e Moore



# Boyer e Moore



A C G T  

6	0	7	8
---	---	---	---

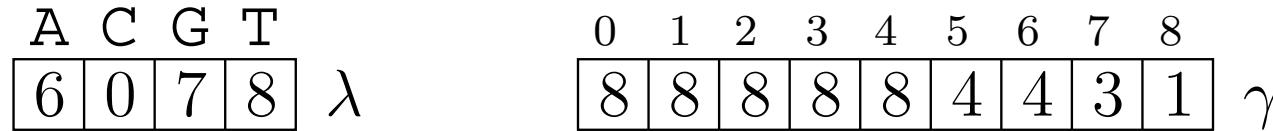
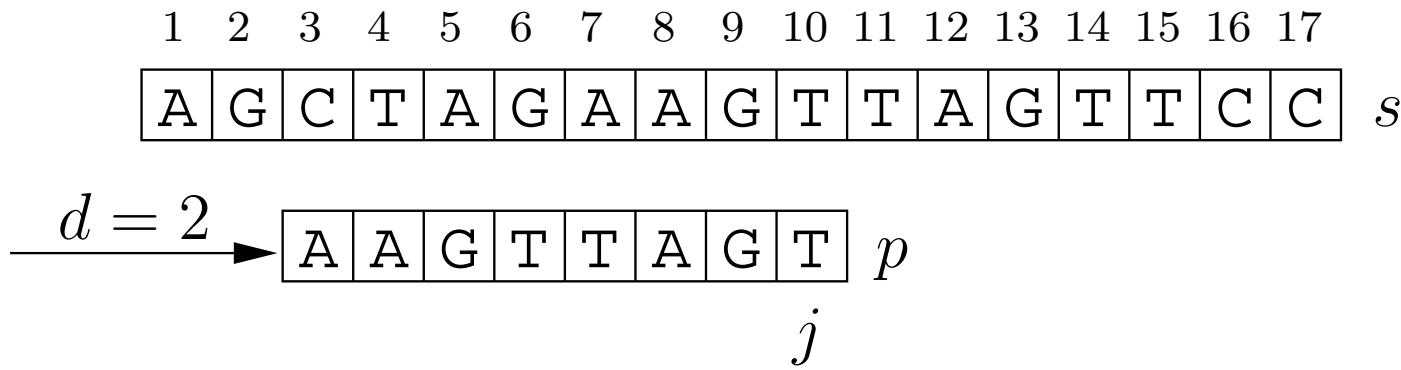
 $\lambda$

0 1 2 3 4 5 6 7 8  

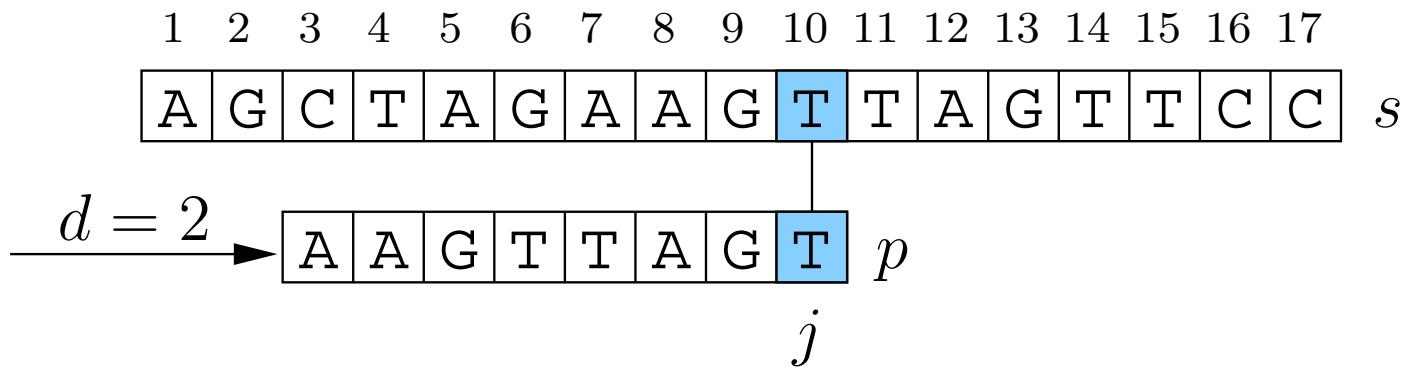
8	8	8	8	8	4	4	3	1
---	---	---	---	---	---	---	---	---

 $\gamma$

# Boyer e Moore



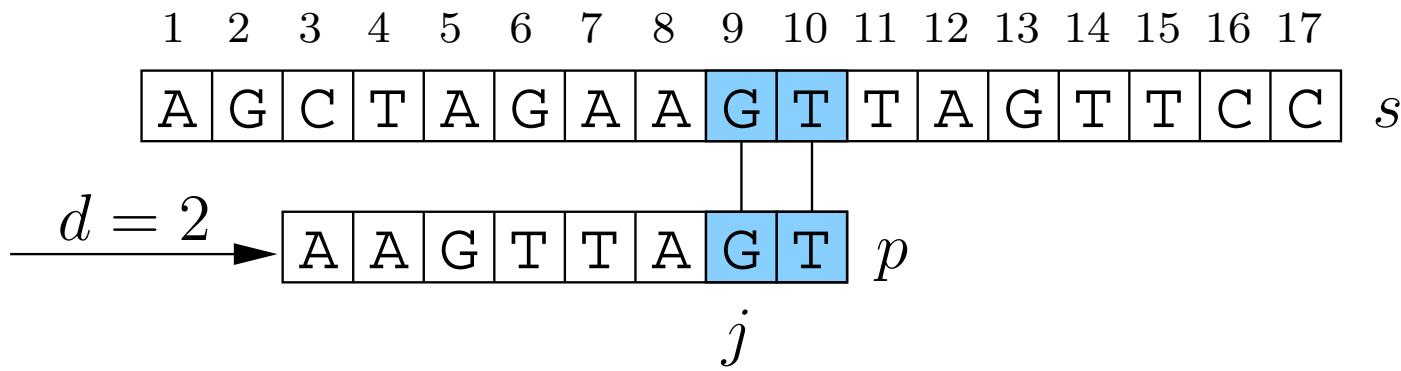
# Boyer e Moore



A C G T  
6 0 7 8  $\lambda$

0 1 2 3 4 5 6 7 8  
8 8 8 8 8 4 4 3 1  $\gamma$

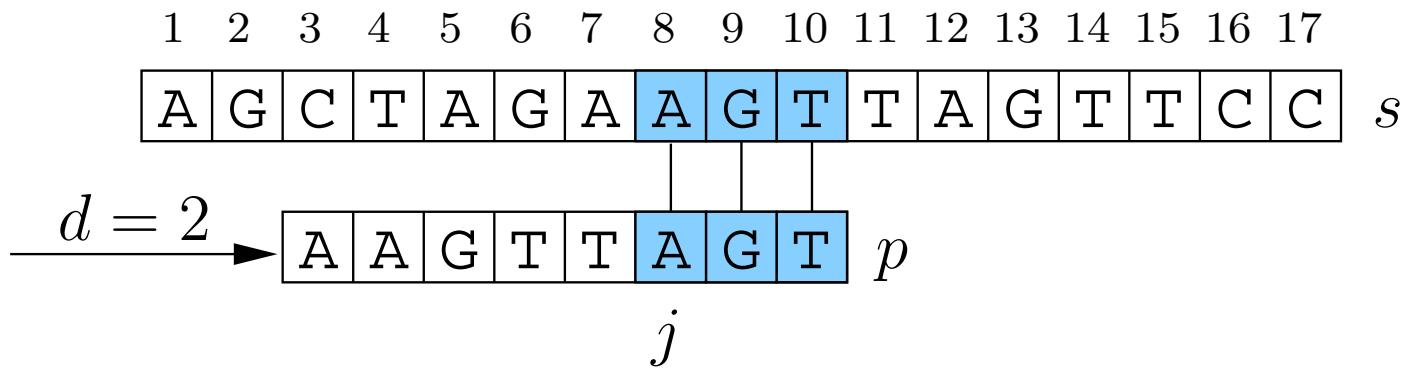
# Boyer e Moore



A C G T  
6 0 7 8  $\lambda$

0 1 2 3 4 5 6 7 8  
8 8 8 8 8 4 4 3 1  $\gamma$

# Boyer e Moore



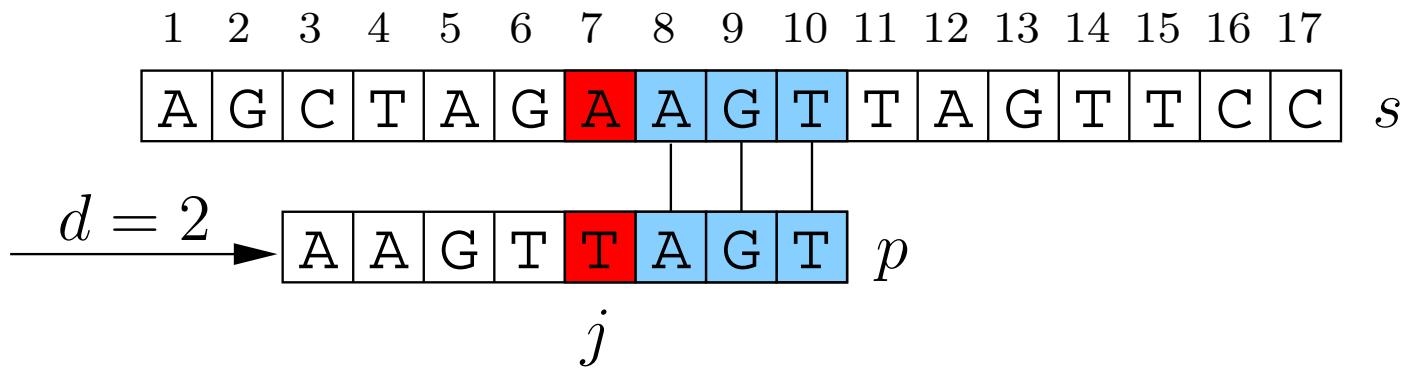
A	C	G	T
6	0	7	8

$\lambda$

0	1	2	3	4	5	6	7	8
8	8	8	8	8	4	4	3	1

$\gamma$

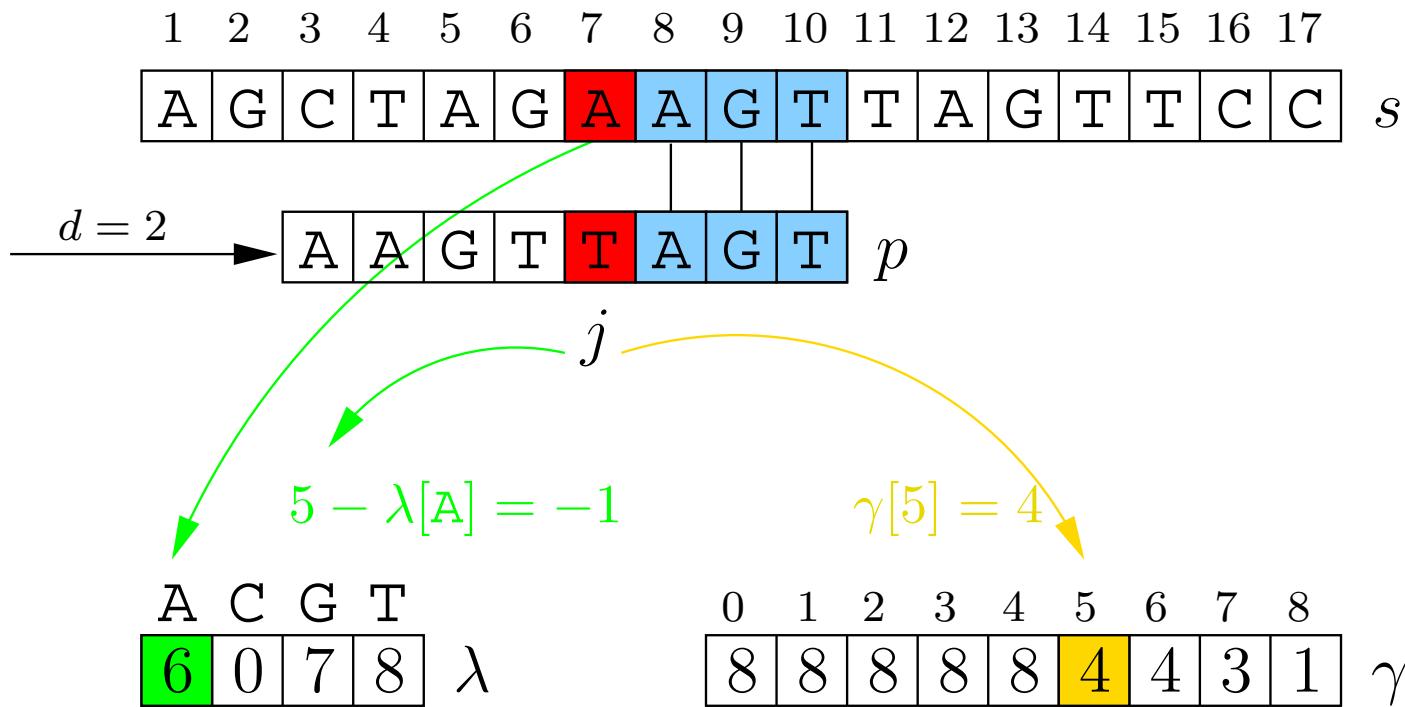
# Boyer e Moore



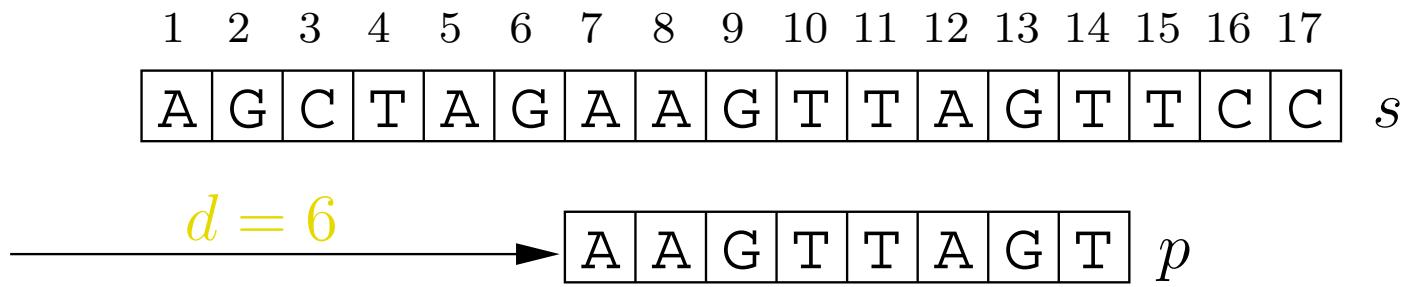
A C G T  
6 0 7 8  $\lambda$

0 1 2 3 4 5 6 7 8  
8 8 8 8 8 4 4 3 1  $\gamma$

# Boyer e Moore



# Boyer e Moore



A C G T  

6	0	7	8
---	---	---	---

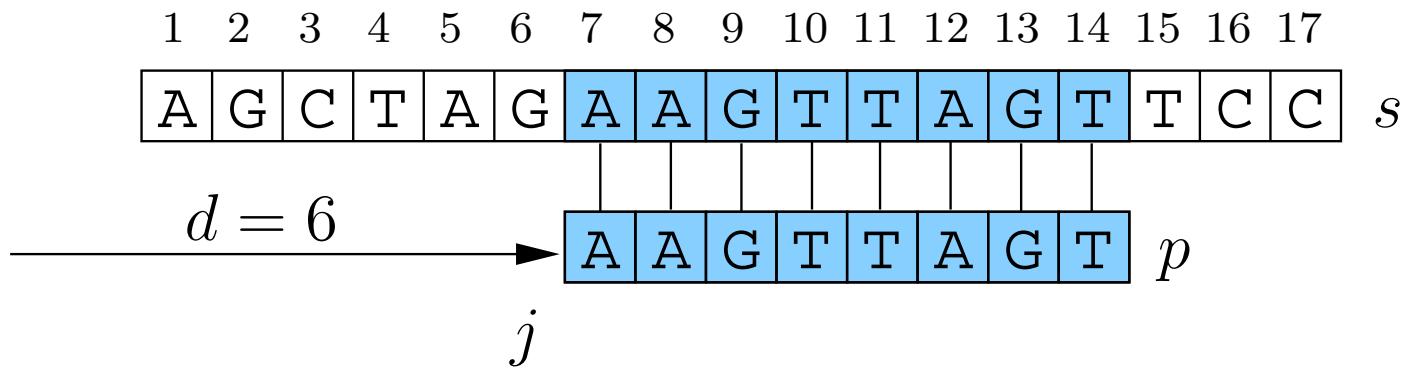
 $\lambda$

0 1 2 3 4 5 6 7 8  

8	8	8	8	8	4	4	3	1
---	---	---	---	---	---	---	---	---

 $\gamma$

# Boyer e Moore



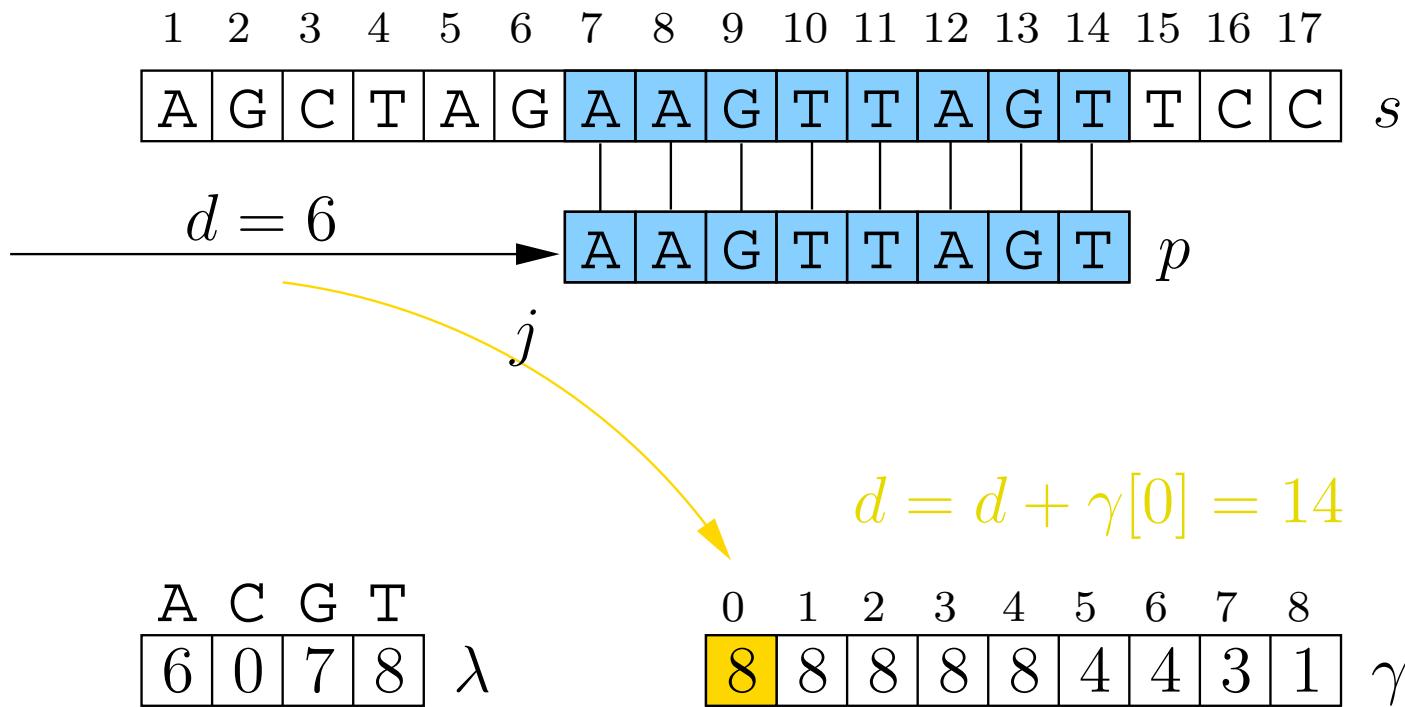
A	C	G	T
6	0	7	8

$\lambda$

0	1	2	3	4	5	6	7	8
8	8	8	8	8	4	4	3	1

$\gamma$

# Boyer e Moore



# Boyer e Moore

- O algoritmo BM tem tempo de execução

$$O((n - m + 1)m + |\Sigma|)$$

que supera o tempo de execução do algoritmo KMP e é equivalente ao tempo de execução do algoritmo ingênuo.

# Boyer e Moore

- O algoritmo BM tem tempo de execução

$$O((n - m + 1)m + |\Sigma|)$$

que supera o tempo de execução do algoritmo KMP e é equivalente ao tempo de execução do algoritmo ingênuo.

- Muito eficiente na prática.