

## Alinhamento Múltiplo de Sequências

# Alinhamento Múltiplo de Sequências

Zanoni Dias

Instituto de Computação – Unicamp

11 de maio de 2009

- Dadas  $k$  sequências  $\alpha_1, \alpha_2, \dots, \alpha_k$  sobre um alfabeto  $\mathcal{A}$  com, respectivamente,  $n_1, n_2, \dots, n_k$  caracteres, obter um alinhamento  $\alpha = \{\alpha'_1, \alpha'_2, \dots, \alpha'_k\}$ , sobre o alfabeto  $\mathcal{A}' = \mathcal{A} \cup \{-\}$ , tal que,  $|\alpha'_1| = |\alpha'_2| = \dots = |\alpha'_k| = n$ , e  $\alpha_i$  possa ser obtida através da remoção de todos os buracos (-) de  $\alpha'_i$  (para todo  $1 \leq i \leq k$ ).
- O alinhamento normalmente é representado por uma matriz de dimensões  $n$  e  $k$ , onde as linhas representam as sequências.
- Uma coluna, por definição, não pode conter apenas buracos.
- Dado um esquema de pontuação para alinhamentos múltiplos, desejamos encontrar o alinhamento de maior pontuação possível.
- O problema do Alinhamento Múltiplo de Sequências é também conhecido como MSA (*Multiple Sequence Alignment*).

## Alinhamento Múltiplo de Sequências

P	E	A	A	L	Y	G	R	F	T	I	K	S	D	V	W			
E	A	A	L	Y	G	R	F	T	I	E	S	D	V	W				
P	E	S	L	A	Y	N	K	F	S	I	K	S	D	V	W			
P	E	A	L	N	Y	G	R	Y	S	S	E	S	D	V	W			
P	E	A	L	N	Y	G	W	Y	S	S	E	S	D	V	W			
P	E	V	I	R	M	Q	D	D	N	P	F	S	F	Q	S	D	V	Y

## Alinhamento Múltiplo de Sequências

P	E	A	A	L	Y	G	R	F	T	-	-	-	I	K	S	D	V	W
-	E	A	A	L	Y	G	R	F	T	-	-	-	I	E	S	D	V	W
P	E	S	L	A	Y	N	K	F	-	-	-	S	I	K	S	D	V	W
P	E	A	L	N	Y	G	R	Y	-	-	-	S	S	E	S	D	V	W
P	E	A	L	N	Y	G	W	Y	-	-	-	S	S	E	S	D	V	W
P	E	V	I	R	M	Q	D	D	N	P	F	S	F	Q	S	D	V	Y

## Soma de Pares

- Considera a soma, par a par, das similariedades de todos os símbolos da coluna.
- Fórmula da Soma de Pares para uma coluna  $c$ :

$$\sum_{1 \leq i < j \leq k} \sigma(\alpha_i[c], \alpha_j[c])$$

- Soma de pares pode ser usada para avaliar o alinhamento como um todo, e com isso considerar esquemas de penalidade sub-aditivos para buracos.
- Neste caso teríamos:

$$\sum_{1 \leq i < j \leq k} sim(\alpha_i, \alpha_j)$$

- A Soma de Pares de uma coluna pode ser calculada em  $\Theta(k^2)$ .

## Como Pontuar um Alinhamento Múltiplo de Sequências

- Soma da pontuação de todas as colunas do alinhamento.
  - ▶ Necessita de uma função de pontuação de colunas.
- Exemplo de funções de pontuação de colunas:
  - ▶ Generalização da matriz de similariedade, com  $k$  dimensões.
  - ▶ Soma de Pares (SP-score: Sum-of-Pairs).
  - ▶ Entropia da coluna.

## Pontuação baseada em Entropia

- Quanto mais similar forem os símbolos de uma coluna, menor a entropia.
- A pontuação de uma alinhamento pode ser obtido pela soma das entropias das colunas.
- Neste caso, estamos interessados num alinhamento de entropia mínima.
- Fórmula da entropia de uma coluna:

$$-\sum_{x \in \mathcal{A}'} p_x \log_2 p_x$$

onde  $p_x$  é a frequência do símbolo  $x$  na coluna.

- Note que se  $p_x = 1$ , ou seja, a coluna contiver apenas o símbolo  $x$ , então a entropia da coluna será  $-1 \log_2 1 = 0$ .
- Caso, a coluna contiver mais de um símbolo, então a entropia será positiva. Exemplo,  $p_A = p_C = p_T = p_G = \frac{1}{4}$ , então a entropia será  $-4\left(\frac{1}{4} \log_2 \frac{1}{4}\right) = 2$ .
- A entropia de uma coluna pode ser calculada em  $\Theta(|\mathcal{A}| + k)$ .

## Sequência Consenso


- Em muitas aplicações, além do alinhamento das sequências, deseja obter uma sequência que represente o consenso do alinhamento.
- A sequência consenso ( $C$ ) pode ser obtida, coluna a coluna, escolhendo o símbolo que maximiza a soma das similariedades entre ele e todos os demais símbolos da coluna, ou seja:

$$\underset{i=1}{\text{maximize}} \sum_{i=1}^k \sigma(C[c], \alpha_i[c])$$


com  $C[c] \in \mathcal{A}'$ , para toda coluna  $c$  do alinhamento múltiplo.

- A sequência consenso pode ser obtida em  $\Theta(|\mathcal{A}|kn)$ .

## Alinhamento de Três Sequências



## Alinhamento de Três Sequências



## Alinhamento de Três Sequências

- Generalização do algoritmo de Needleman e Wunsch para alinhamento de duas sequências.
- Matriz de Programação Dinâmica deverá ser tridimensional (cada dimensão representará uma sequência a ser alinhada).


Fórmula de recorrência usada no preenchimento da matriz:

$$M[i,j,k] \leftarrow \max \left\{ \begin{array}{l} M[i-1, j, k] + \sigma(\alpha_1[i], -, -) \\ M[i, j-1, k] + \sigma(-, \alpha_2[j], -) \\ M[i, j, k-1] + \sigma(-, -, \alpha_3[k]) \\ M[i-1, j-1, k] + \sigma(\alpha_1[i], \alpha_2[j], -) \\ M[i-1, j, k-1] + \sigma(\alpha_1[i], -, \alpha_3[k]) \\ M[i, j-1, k-1] + \sigma(-, \alpha_2[j], \alpha_3[k]) \\ M[i-1, j-1, k-1] + \sigma(\alpha_1[i], \alpha_2[j], \alpha_3[k]) \end{array} \right\}$$

- Complexidade de tempo e espaço:

$$\Theta(n^3)$$

## Alinhamento de Três Sequências



## Alinhamento de $k$ Sequências

- Generalização do algoritmo de Needleman e Wunsch para alinhamento de duas sequências.
- Matriz de Programação Dinâmica deverá ser  $k$ -dimensional (cada dimensão representará uma sequência a ser alinhada).
- Cada célula da matriz dependerá de outras  $2^k - 1$  células.
- Quanto custa preencher cada célula?
  - Usando Soma de Pares:  $\Theta(k^2 2^k)$
  - Usando Entropia:  $\Theta(k 2^k)$
- Complexidade de tempo total:
  - $\Omega(k 2^k n^k)$
- Complexidade de espaço:
  - $\Theta(n^k)$
- Lusheng Wang e Tao Jiang provaram em 1994 que o problema do alinhamento múltiplo de sequências é  $\mathcal{NP}$ -Completo.

## Alinhamento de $k$ Sequências Redução do Espaço de Busca

- Método para redução de tempo de processamento quando usasse Soma de Pares para pontuar cada coluna.
- Antes de expandir uma célula (e atualizar a similariedade das células que são influenciadas por ela), verificar se ela é relevante, ou seja, se ela pode fazer parte do alinhamento múltiplo.
- O método usa as matrizes de pontuação total entre todos os pares de sequências as serem alinhadas.
- A Matriz de Pontuação Total ( $c$ ) entre as sequências  $\alpha$  e  $\beta$ , de tamanho  $m$  e  $n$ , é definida como:

$$c[i, j] = a[i, j] + b[i, j]$$

onde:

$$\begin{aligned} a[i, j] &= \text{sim}(\alpha[1..i], \beta[1..j]) \\ b[i, j] &= \text{sim}(\alpha[i+1..n], \beta[j+1..m]) \end{aligned}$$

## Alinhamento de $k$ Sequências Matriz de Pontuação de Prefixos

a	$\alpha$	A	C	T	G	A	G	T	C	
$\beta$	0	-5	-10	-15	-20	-25	-30	-35	-40	
A	-5	3	-2	-7	-12	-17	-22	-27	-32	
T	-10	-2	1	1	-4	-9	-14	-19	-24	
T	-15	-7	-4	4	-1	-6	-11	-11	-16	
G	-20	-12	-9	-1	7	2	-3	-8	-13	
A	-25	-17	-14	-6	2	10	5	0	-5	
G	-30	-22	-19	-11	-3	5	13	8	3	

## Alinhamento de $k$ Sequências Matriz de Pontuação de Sufixos

b		A	C	T	G	A	G	T	C	$\alpha$
	3	-5	-7	-10	-8	-16	-19	-27	-30	A
	-5	0	-3	-5	-8	-11	-14	-22	-25	T
	-8	-3	2	-6	-3	-6	-9	-17	-20	T
	-16	-11	-6	-1	-6	-1	-9	-12	-15	G
	-24	-19	-14	-9	-4	-9	-4	-7	-10	A
	-32	-27	-22	-17	-12	-7	-7	-2	-5	G
	-40	-35	-30	-25	-20	-15	-10	-5	0	$\beta$
	A	C	T	G	A	G	T	C		

## Alinhamento de $k$ Sequências Matriz de Pontuação Total

C	$\alpha$	A	C	T	G	A	G	T	C
$\beta$	3	-10	-17	-25	-28	-41	-49	-62	-70
A	-10	3	-5	-12	-20	-28	-36	-49	-57
T	-18	-5	3	-5	-7	-15	-23	-36	-44
T	-31	-18	-10	3	-7	-7	-20	-23	-31
G	-44	-31	-23	-10	3	-7	-7	-15	-23
A	-57	-44	-36	-23	-10	3	-2	-2	-10
G	-70	-57	-49	-36	-23	-10	3	3	3

## Alinhamento de $k$ Sequências Redução do Espaço de Busca

### Teorema

Seja  $\alpha$  um alinhamento ótimo entre as sequências  $\alpha_1, \alpha_2, \dots, \alpha_k$  e  $\alpha_{ij}$  a projeção do alinhamento entre  $\alpha_i$  e  $\alpha_j$ . Se  $SP\text{-score}(\alpha) \geq L$ , então:

$$sim(\alpha_{ij}) \geq L_{ij}$$

onde:

$$L_{ij} = L - \sum_{1 \leq x < y \leq k, (x,y) \neq (i,j)} sim(\alpha_x, \alpha_y)$$

Logo, se a célula  $M[i_1, i_2, \dots, i_k]$  é relevante, então:

$$c_{xy}[i_x, i_y] \geq L_{xy}$$

para todo par  $x$  e  $i$ , tal que,  $1 \leq x < y \leq k$ , onde  $c_{xy}$  é a matriz de pontuação total entre  $\alpha_x$  e  $\alpha_y$ .

## Alinhamento de $k$ Sequências Redução do Espaço de Busca

### Algoritmo 1: MSA

```

Input:  $k, n_1, n_2, \dots, n_k, \alpha_1, \alpha_2, \dots, \alpha_k, L$ 
for all  $x$  e  $y$ ,  $1 \leq x < y \leq k$  do Calcule  $c_{xy}$ 
for all  $x$  e  $y$ ,  $1 \leq x < y \leq k$  do  $L_{xy} \leftarrow L - \sum_{1 \leq p < q \leq k, (p,q) \neq (x,y)} sim(\alpha_p, \alpha_q)$ 
pool  $\leftarrow \{0\}$ 
while pool  $\neq \emptyset$  do
     $i \leftarrow$  the lexicographically smallest cell in the pool
    pool  $\leftarrow$  pool  $\setminus i$ 
    if  $c_{xy}[i_x, i_y] \geq L_{xy}$ , for all pair  $x$  e  $y$ , where  $1 \leq x < y \leq k$  then
        for each cell  $j$  dependent on  $i$  do
            if  $j \notin$  pool then
                pool  $\leftarrow$  pool  $\cup \{j\}$ 
                 $M[j] \leftarrow M[i] + SP\text{-score}(Column(\alpha, j - 1))$ 
            end
            else
                 $M[j] \leftarrow \max(M[j] + M[i] + SP\text{-score}(Column(\alpha, j - 1)))$ 
            end
        end
    end
end
return  $M[n_1, n_2, \dots, n_k]$ 

```

## Alinhamento de $k$ Sequências Redução do Espaço de Busca

- Complexidade de tempo:
  - $\Theta(k^2n^2 + k^4 + r2^k k^2)$   
onde  $r$  é o número de células relevantes.
  - Pior caso:  $r = \Theta(n^k)$
  - Logo, a complexidade de pior caso é  $\Theta(n^k 2^k k^2)$
- Método proposto por Humberto Carrillo e David Lipman em 1988.
- Implementado no programa MSA, de David Lipman, Stephen Altschul e John Kececioglu (1989).

## Compatibiliade de Alinhamentos de Pares de Sequências

### Similariedade x Distância

- Propriedades de distância de sequências:
  - $\delta(x, x) = 0$ , para todo  $x \in \mathcal{A}$ .
  - $\delta(x, y) > 0$ , com  $x \neq y$ , para todo para  $x, y \in \mathcal{A}$ .
  - $\delta(x, y) = \delta(y, x)$ , para todo par  $x, y \in \mathcal{A}$ .
  - $\delta(x, y) \leq \delta(x, z) + \delta(z, y)$ , para toda tripla  $x, y, z \in \mathcal{A}$ .
- Distância de sequência não é adequada para comparação local.
- Equivalência entre similariedade e distância de sequências:
  - $\delta(x, y) = M - \sigma(x, y)$ .
  - $g' = -g - \frac{M}{2}$ .
  - $\text{sim}(\alpha, \beta) + \text{dist}(\alpha, \beta) = \frac{M}{2}(m + n)$ .
- Equivalência descrita por Temple Smith, Michael Waterman e Walter Fitch, em 1981.

$\alpha_1 = \text{A A A A T T T T}$

$\alpha_2 = \text{T T T T G G G G}$

$\alpha_3 = \text{A A A A G G G G}$

$\alpha_1 = \text{A A A A T T T T - - - -}$

$\alpha_2 = - - - - \text{T T T T G G G G}$

$\alpha_2 = - - - - \text{T T T T G G G G}$

$\alpha_3 = \text{A A A A - - - - G G G G}$

$\alpha_1 = \text{A A A A T T T T - - - -}$

$\alpha_3 = \text{A A A A - - - - G G G G}$

### Compatibiliade de Alinhamentos de Pares de Sequências

$\alpha_1 = \text{A A A A T T T T}$

$\alpha_2 = \text{T T T T G G G G}$

$\alpha_3 = \text{A A A A G G G G}$

$\alpha_1 = \text{A A A A T T T T - - - -}$

$\alpha_2 = - - - - \text{T T T T G G G G}$

$\alpha_3 = \text{A A A A - - - - G G G G}$

$\alpha_1 = \text{A A A A T T T T}$

$\alpha_2 = \text{T T T T G G G G}$

$\alpha_3 = \text{G G G G A A A A}$

$\alpha_1 = \text{A A A A T T T T - - - -}$

$\alpha_2 = - - - - \text{T T T T G G G G}$

$\alpha_2 = \text{T T T T G G G G - - - -}$

$\alpha_3 = - - - - \text{G G G G A A A A}$

$\alpha_1 = - - - - \text{A A A A T T T T}$

$\alpha_3 = \text{G G G G A A A A - - - -}$

### Incompatibiliade de Alinhamentos de Pares de Sequências

## Alinhamento Estrela

- Construir um alinhamento múltiplo, usando uma sequência como âncora para as demais.
- Como escolher a âncora?
  - ▶ Use cada uma das sequências como âncora e retorne apenas o melhor alinhamento.
  - ▶ Use a sequência que maximiza a soma das similariedades em relação a todas as demais sequências.
- Passos:
  - ▶ Calcule os alinhamentos entre todos os pares de sequências.
  - ▶ Escolha a âncora.
  - ▶ Adicione, uma a uma, as demais sequências ao alinhamento.
    - ★ Usa a regra: "once a gap, always a gap".
- O valor do alinhamento ótimo obtido pode ser usado como limite inferior ( $L$ ) para o algoritmo de Carrillo e Lipman.
- Complexidade:
  - ▶  $\Theta(k^2n^2)$

## Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A T T}$   
 $\alpha_2 = \text{A T G G C C A T T}$   
 $\alpha_3 = \text{A T C C C A A T T T T}$   
 $\alpha_4 = \text{A T C T T C T T}$   
 $\alpha_5 = \text{A C T G A C C}$

## Alinhamento Estrela

sim	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	soma
$\alpha_1$		22	-1	4	-4	21
$\alpha_2$	22		-1	4	-7	18
$\alpha_3$	-1	-1		4	-14	-12
$\alpha_4$	4	4	4		-4	8
$\alpha_5$	-4	-7	-14	-4		-29
<b>soma</b>	21	18	-12	8	-29	

Match = 3

Mismatch = -2

Gap = -5

## Alinhamento Estrela

dist	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	soma
$\alpha_1$		5,0	29,5	21,5	28,0	84,0
$\alpha_2$	5,0		29,5	21,5	31,0	87,0
$\alpha_3$	29,5	29,5		23,0	39,5	121,5
$\alpha_4$	21,5	21,5	23,0		26,5	92,5
$\alpha_5$	28,0	31,0	39,5	26,5		125,0
<b>soma</b>	84,0	87,0	121,5	92,5	125,0	

Match = 0

Mismatch = -5

Gap = -6,5

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_2 = \text{A T G G C C A T T}$

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_4 = \text{A T C T T C - T T}$

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_5 = \text{A C T G A C C - -}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_2 = \text{A T G G C C A T T}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_2 = \text{A T G G C C A T T}$

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_2 = \text{A T G G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_2 = \text{A T G G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_4 = \text{A T C T T C - T T}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_2 = \text{A T G G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

$\alpha_4 = \text{A T C T T C - - - T T}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_2 = \text{A T G G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

$\alpha_4 = \text{A T C T T C - - - T T}$

$\alpha_1 = \text{A T T G C C A T T}$

$\alpha_5 = \text{A C T G A C C - -}$

### Alinhamento Estrela

$\alpha_1 = \text{A T T G C C A - - T T}$

$\alpha_2 = \text{A T G G C C A - - T T}$

$\alpha_3 = \text{A T C - C A A T T T T}$

$\alpha_4 = \text{A T C T T C - - - T T}$

$\alpha_5 = \text{A C T G A C C - - - -}$

## Alinhamento Estrela

- Seja:

- ▶  $\alpha_c$ : sequência usada como âncora do alinhamento estrela.
- ▶  $dist(\alpha_i, \alpha_j)$ : distância mínima entre  $\alpha_i$  e  $\alpha_j$ .
- ▶  $dist^*(\alpha_i, \alpha_j)$ : distância entre  $\alpha_i$  e  $\alpha_j$  no alinhamento estrela.
- ▶  $V(\alpha^*) = \sum_{1 \leq i, j \leq k} dist^*(\alpha_i, \alpha_j)$
- ▶  $V(\alpha) = \sum_{1 \leq i, j \leq k} dist(\alpha_i, \alpha_j)$

### Lema

Para quaisquer sequências  $\alpha_i$  e  $\alpha_j$ , com  $1 \leq i, j \leq k$ , temos que:  
 $dist^*(\alpha_i, \alpha_j) \leq dist^*(\alpha_i, \alpha_c) + dist^*(\alpha_c, \alpha_j) = dist(\alpha_i, \alpha_c) + dist(\alpha_c, \alpha_j)$ .

### Teorema

$$V(\alpha^*)/V(\alpha) \leq 2^{\frac{(k-1)}{k}} < 2$$

## Algoritmos de Aproximação para Alinhamento Múltiplo de Sequências

(usando Soma de Pares para pontuação de alinhamentos)

- Daniel Gusfield, 1993.
  - ▶ Aproximação:  $2 - 2/k$ .
  - ▶ Complexidade:  $O(k^2 n^2)$ .
- Pavel Pevzner, 1992.
  - ▶ Aproximação:  $2 - 3/k$ .
  - ▶ Complexidade:  $O(n^3 k^3 + k^4)$ .
- Vineet Bafna, Eugene Lawler e Pavel Pevzner, 1997.
  - ▶ Aproximação:  $2 - 1/k$ .
  - ▶ Complexidade:  $O(k^{l+1}(2^k + kl^2 2^l n^l))$
- Winfried Just, 2001.
  - ▶ MSA  $\in \mathcal{MAX-NP}$ -Difícil.
  - ▶ Não existe um esquema de aproximação polinomial (PTAS - *Polynomial Time Approximation Scheme*) para MSA, a menos que  $\mathcal{P} = \mathcal{NP}$ .

## Alinhamento Progressivo

- Consiste em construir um alinhamento múltiplo a partir de alinhamentos de pares de sequências e/ou de alinhamentos.
- Descrito inicialmente por Hogeweg e Hesper (1984) e depois reinventado por Feng e Doolittle (1987) e Taylor (1988).
- Características:
  - ▶ Simples e efetivo para MSA.
  - ▶ Requer pouco tempo e memória.
  - ▶ Bom desempenho para seqüências homólogas e relativamente bem conservadas.
  - ▶ Problema: natureza gulosa e muito sensível ao esquema de pontuação.

## Alinhamento Progressivo

- Etapas:
  1. Computar alinhamentos de todos os pares de sequências.
  2. Construir uma árvore guia.
  3. Construir o alinhamento múltiplo guiado pela árvore.
- Construção de árvore guia:
  - ▶ UPGMA (Sneath e Sokal, 1973)
  - ▶ Neighbor-Joining (Saitou e Nei, 1987)
- Construção do alinhamento múltiplo:
  - ▶ Seleção do par a incluir no alinhamento.
  - ▶ Alinhar duas seqüências/alinhamentos.
- Programas que implementam alinhamento progressivo:
  - ▶ Clustal W (Thompson et al, 1994)
  - ▶ MUSCLE (Edgar, 2004)
  - ▶ T-COFFEE (Notredame et al, 2000)
  - ▶ ProbCons (Do et al, 2005)

## **Alinhamento Iterativo**

- Consiste em refinar alinhamentos através de uma série de ciclos.
- Produz bons alinhamentos.
- Problema: requer muito tempo e depende de outros métodos auxiliares.
- Programas que implementam alinhamento múltiplo iterativo:
  - ▶ PRRP (Gotoh, 1996)
  - ▶ SAGA (Notredame e Higgins, 1996)