

# Melhorando Alinhamentos Locais

Katia Guimarães

# Alinhamentos locais têm aplicações em comparação de proteínas

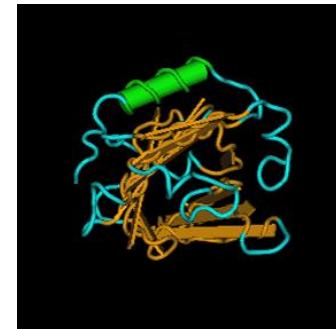
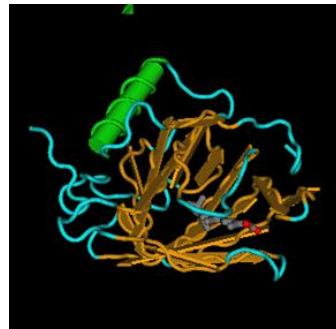
Ex: Alinhamento entre retinol-binding e  $\beta$ -lactoglobulin

```
1 MKWVWALLLAAWAAAERDCRVSSFRVKENFDKARFSGT WYAMAKKDPEG 50 RBP
      . ||| | | . . | : . ||| . | : .
1 ...MKCLLLALALTCGAQALIVT..QTMKG LDI QKVAGTWYSLAMAASD. 44 lactoglobulin

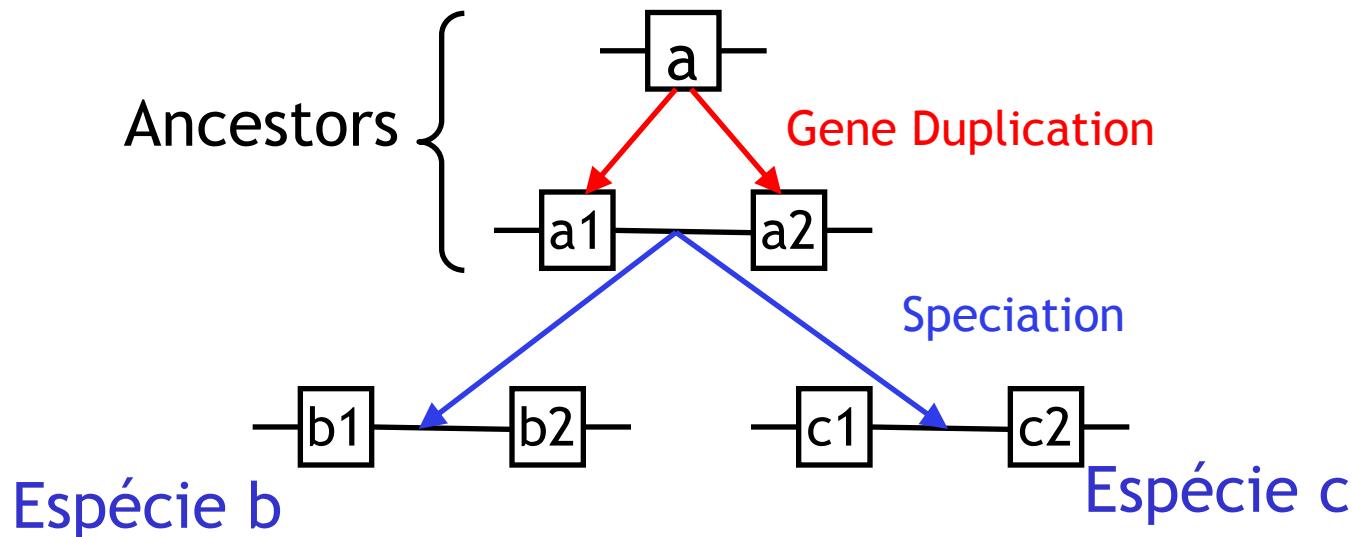
51 LFLQDNIVAEFSVDET GQMSATAKGRVR.LLNNWD..VCADMVGTF TDTE 97 RBP
    : | | | | | : | . | . || | : | | | .
45 ISLLDAQSAPLRV.YVEELKPTPEGDLEILLQKWENGECAQKKIIAEKTK 93 lactoglobulin

98 DPAFKKMKYWGVASFLQKG NDDHWIVDTDYDTYAV.....QYSC 136 RBP
    || | |. | | : | | | | . | .
94 I PAVFKIDALNENKVL.....VLDTDYKKYLLFCMENSAEPEQSLAC 135 lactoglobulin

137 RLLNLDGTCADSYSFVFSRDPNGLPPEAQKIVRQRQ.EELCLARQYRLIV 185 RBP
    . | | | | : | | . | | | |
136 QCLVRTPEVDEALEKFDKALKALPMHIRLSFNPTQLEEQCHI..... 178 lactoglobulin
```



# Homólogos, Ortólogos, Parálogos



- **Homologia:** Similaridade atribuída a descendentes de um ancestral comum.
- **Ortólogos:** Seqüências homólogas em espécies diferentes, originárias de um ancestral comum, devido a *speciation*; pode ter função similar ou não.
- **Parálogos:** Seqüências homólogas dentro de uma mesma espécie, gerada por *duplicação de genes*.

# Alinhamento e evolução

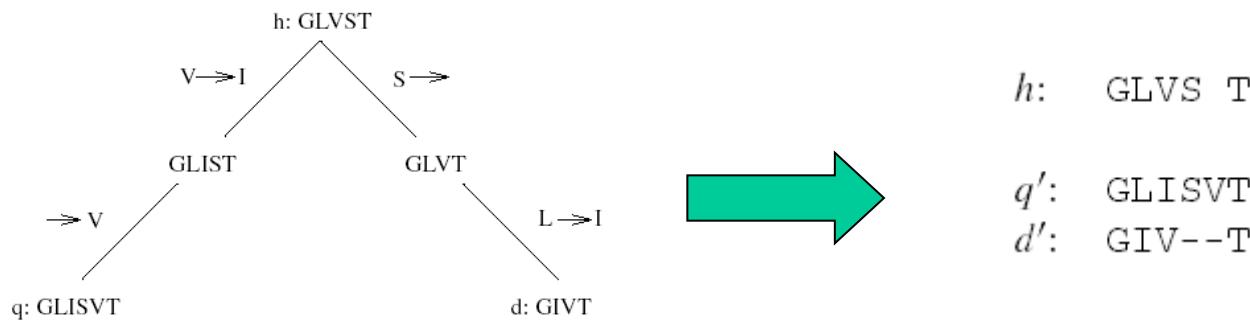
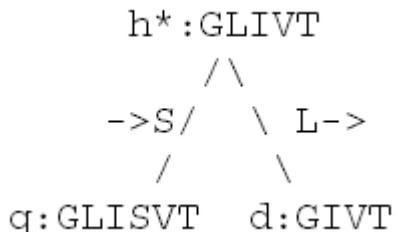


Figure 1.1 An evolution from  $h$  to  $q$  and  $d$ .

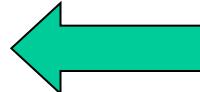
Evolutionary history



Incorrect evolutionary model

Correct alignment

$q': GLISVT$   
 $d': G-I-VT$



Probable alignment model

To build the correct alignment, we need to know evolutionary history. Without knowing the evolution, it's impossible to build the correct alignment.

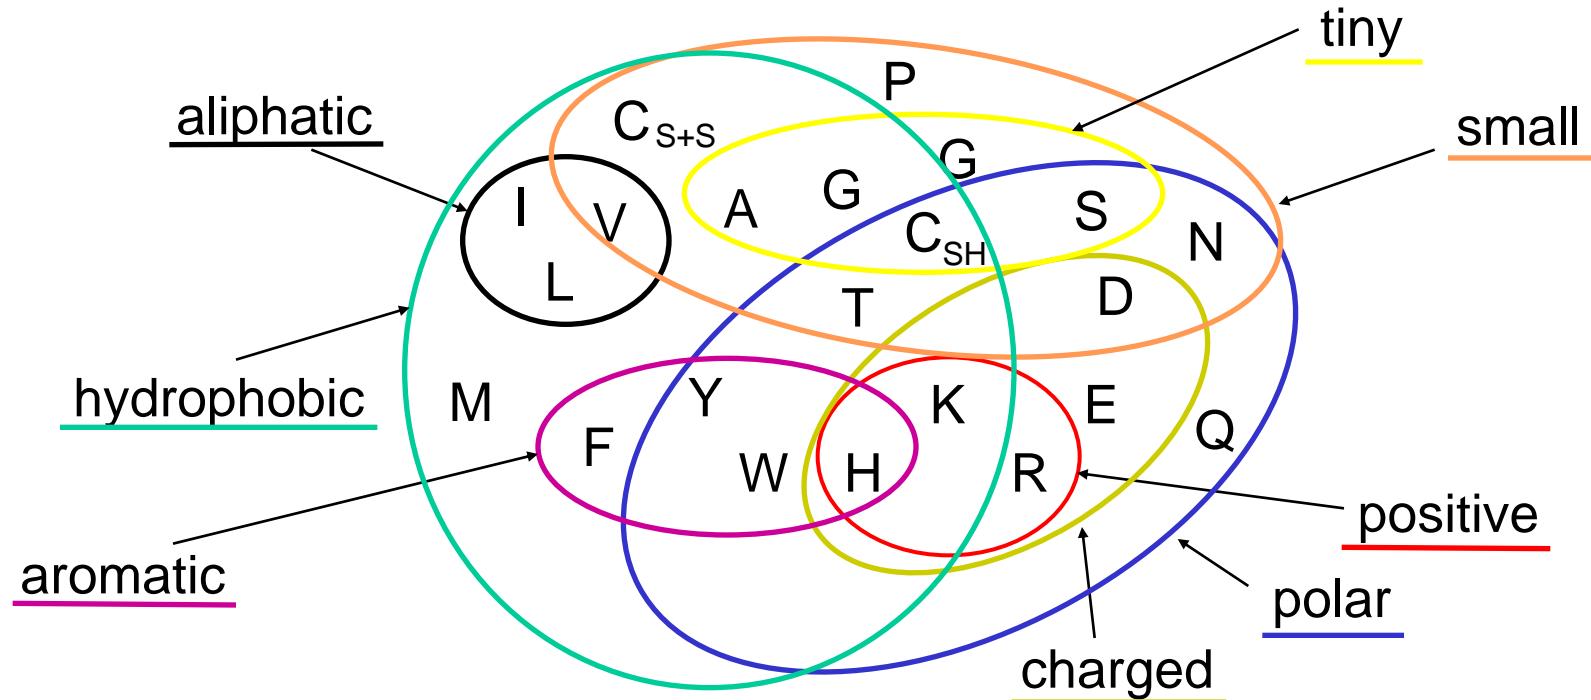
Only meaningful for homologous sequences.

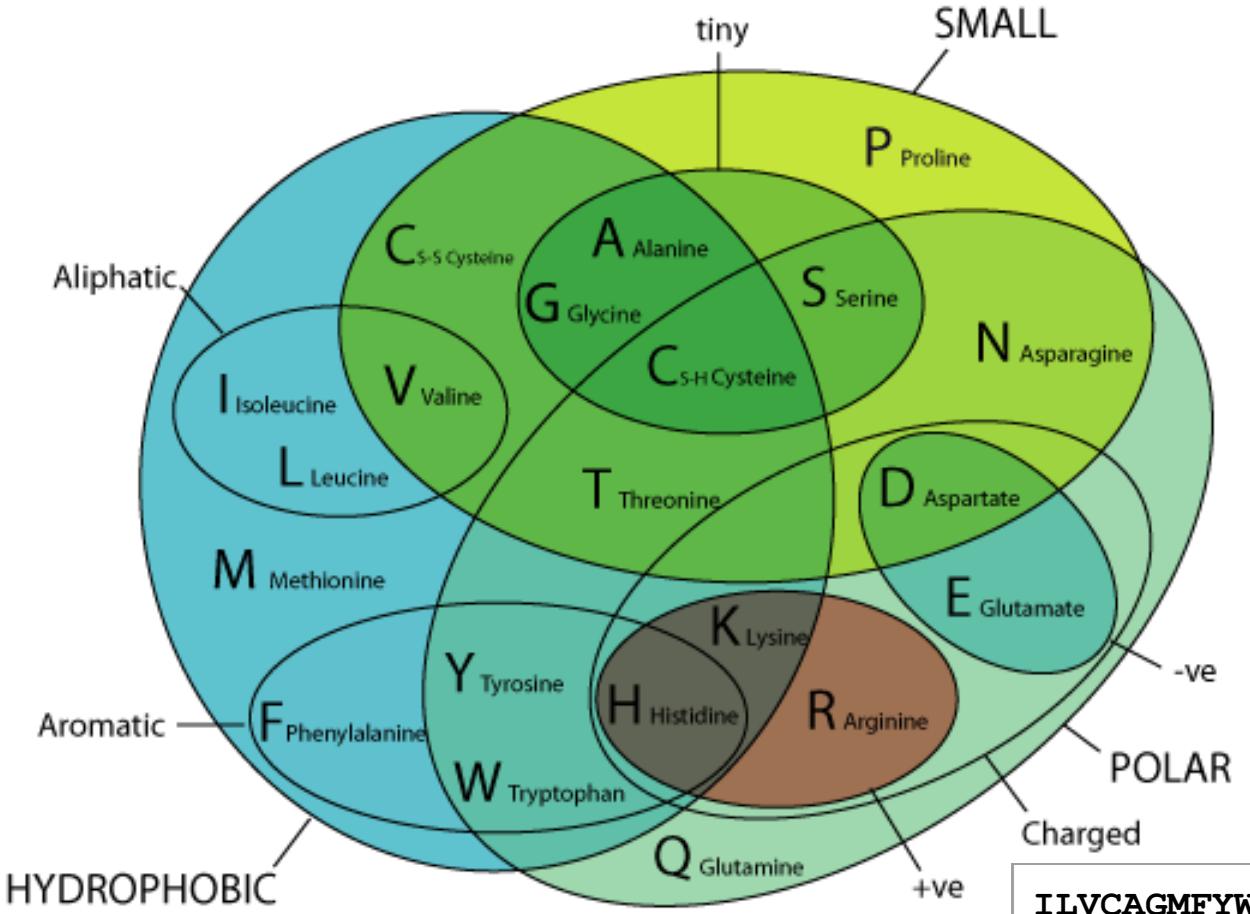
A “good” alignment can indicate homology.

# Scoring System para Alinhamentos de Proteínas

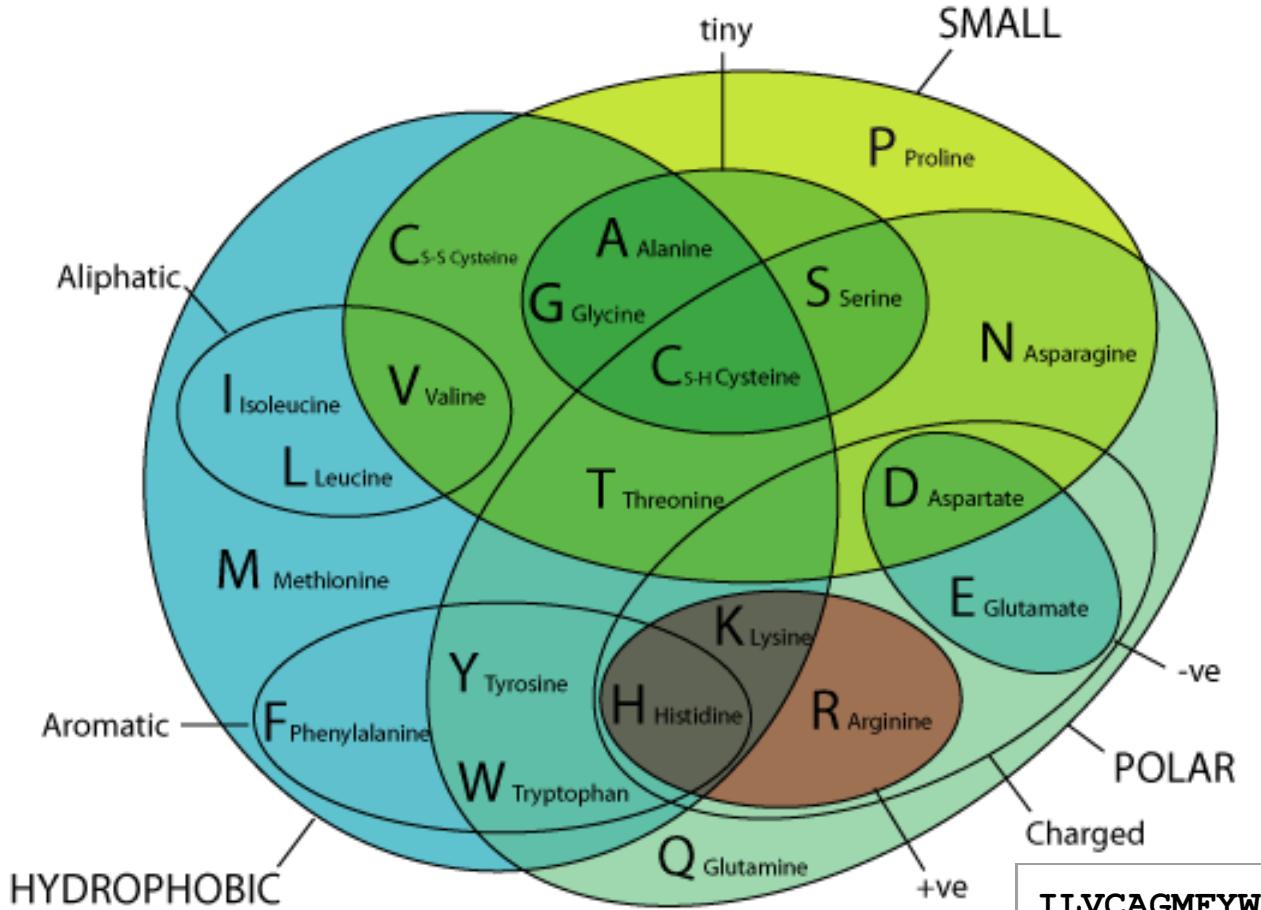
- Matrizes de Substituição
  - Dois resíduos diferentes têm diferentes medidas de similaridade.
  - PAM, BLOSUM
- Gap model
  - Linear
  - General

Aminoácidos diferentes possuem diferentes propriedades bio-químicas e bio-físicas que influenciam a sua mutabilidade e evolução





I L V C A G M F Y W H K R E Q D N S T P B Z X -



**ILVCAGMFYWHKREQDNSTPBZX-**

XXXXXXXXXXXX	.....	X .. XX	Hydrophobic
.....	..... XXXXXXXXXX	XXXXXX	Polar
.. XXXX	.....	XXXXX .. XX	Small
.....	.....	X .. XX	Proline
... XX	.....	X .. XX	Tiny
XXX	.....	XX	Aliphatic
.....	..... XXXX	XX	Aromatic
.....	..... XXX	XX	Positive
.....	..... X .. X	XX	Negative
.....	..... XXXX .. X	XX	Charged

# Substituições de aminoácidos

## Synonymous

Thr	<b>Tyr</b>	Leu	Leu
ACC	<b>TAT</b>	TTG	CTG
	↓		
ACC	<b>TAC</b>	TTG	CTG
Thr	<b>Tyr</b>	Leu	Leu

## Conservative

Thr	<b>Tyr</b>	Leu	Leu
ACC	<b>TAT</b>	TTG	CTG
	↓		
ACC	<b>TCT</b>	TTG	CTG
Thr	<b>Ser</b>	Leu	Leu

## Non-Conservative

Thr	<b>Tyr</b>	Leu	Leu
ACC	<b>TAT</b>	TTG	CTG
	↓		
ACC	<b>GAT</b>	TTG	CTG
Thr	<b>Asp</b>	Leu	Leu

Substituições **sinônimas** preservam a **identidade** do aminoácido.

Substituições **conservativas** preservam o **tipo** de aminoácido.

# Matriz de Substituição BLOSUM 62

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	
C	9																			C	
S	-1	4																		S	
T	-1	1	5																	T	
P	-3	-1	-1	7																P	
A	0	1	0	-1	4															A	
G	-3	0	-2	-2	0	6														G	
N	-3	1	0	-2	-2	0	6													N	
D	-3	0	-1	-1	-2	-1	1	6												D	
E	-4	0	-1	-1	-1	-2	0	2	5											E	
Q	-3	0	-1	-1	-1	-2	0	0	2	5										Q	
H	-3	-1	-2	-2	-2	-2	1	-1	0	0	8									H	
R	-3	-1	-1	-2	-1	-2	0	-2	0	1	0	5								R	
K	-3	0	-1	-1	-1	-2	0	-1	1	1	-1	2	5							K	
M	-1	-1	-1	-2	-1	-3	-2	-3	-2	0	-2	-1	-1	5						M	
I	-1	-2	-1	-3	-1	-4	-3	-3	-3	-3	-3	-3	-3	1	4					I	
L	-1	-2	-1	-3	-1	-4	-3	-4	-3	-2	-3	-2	-2	2	2	4				L	
V	-1	-2	0	-2	0	-3	-3	-3	-2	-2	-3	-3	-2	1	3	1	4			V	
F	-2	-2	-2	-4	-2	-3	-3	-3	-3	-3	-1	-3	-3	0	0	0	-1	6		F	
Y	-2	-2	-2	-3	-2	-3	-2	-3	-2	-1	2	-2	-2	-1	-1	-1	-1	3	7	Y	
W	-2	-3	-2	-4	-3	-2	-4	-4	-3	-2	-2	-3	-3	-1	-3	-2	-3	1	2	11	W

# BLOSUM62 Amino Acid Substitution Matrix

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	
C	9																				C sulfhydryl
S	-1	4																			S
T	-1	1	5																		T
P	-3	-1	-1	7																	P small
A	0	1	0	-1	4																A hydrophilic
G	-3	0	-2	-2	0	6															G
N	-3	1	0	-2	-2	0	6														N
D	-3	0	-1	-1	-2	-1	1	6													D acid, acid-amide
E	-4	0	-1	-1	-1	-2	0	2	5												E and hydrophilic
Q	-3	0	-1	-1	-1	-2	0	0	2	5											Q
H	-3	-1	-2	-2	-2	-2	1	-1	0	0	0	8									H
R	-3	-1	-1	-2	-1	-2	0	-2	0	1	0	5									R basic
K	-3	0	-1	-1	-1	-2	0	-1	1	1	-1	2	5								K
M	-1	-1	-1	-2	-1	-3	-2	-3	-2	0	-2	-1	-1	5							M
I	-1	-2	-1	-3	-1	-4	-3	-3	-3	-3	-3	-3	-3	1	4						I small
L	-1	-2	-1	-3	-1	-4	-3	-4	-3	-2	-3	-2	-2	2	2	4					L hydrophobic
V	-1	-2	0	-2	0	-3	-3	-3	-2	-2	-3	-3	-2	1	3	1	4				V
F	-2	-2	-2	-4	-2	-3	-3	-3	-3	-1	-3	-3	0	0	0	-1	6			F	
Y	-2	-2	-2	-3	-2	-3	-2	-3	-2	-1	2	-2	-2	-1	-1	-1	-1	3	7	Y aromatic	
W	-2	-3	-2	-4	-3	-2	-4	-4	(-3)	-2	-2	-3	-3	-1	-3	-2	-3	1	2	11	W
	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	

# MATRIZES BLOSUM

## The BLOSUM (*BLOck SUbstitution Matrix*) Family

- BLOSUM matrices are based on local alignments.
- BLOSUM 62 is a matrix calculated from comparisons of sequences with no less than 62% divergence.
- All BLOSUM matrices are based on observed alignments; they are not extrapolated from comparisons of closely rel. prots.
- BLOSUM 62 is the default matrix in BLAST 2.0. Though it is tailored for comparisons of moderately distant proteins, it performs well in detecting closer relationships. A search for distant relatives may be more sensitive with a different matrix.

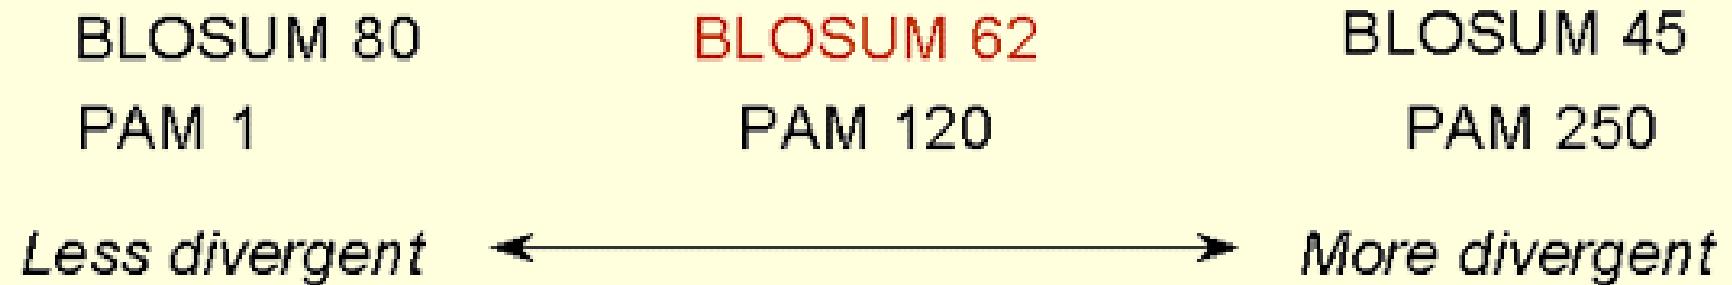
# Matrices PAM

## The PAM (*Point Accepted Mutation*) Family

The PAM matrices are based on **global alignments** of closely related proteins.

- The PAM<sup>1</sup> is the matrix calculated from comparisons of sequences with **no more than 1%** divergence.
- Other PAM matrices are extrapolated from PAM1.

# Relação entre matrizes Blosum e PAM



- *BLOSUM50* ( $L=50\%$ ):  
mainly used for alignment with gaps
- *BLOSUM62* ( $L=62\%$ ):  
mainly used for ungapped alignment

# Gap Penalty Functions

O custo de  $k$  “spaces” não tem um custo linear.

Inserções e remoções tendem a ocorrer em blocos, de forma que gaps tendem a ocorrer juntos.

Desta forma, um gap de comprimento  $k$  tem um custo menor do que  $k$  gaps de compr. um.

Ou seja, o esquema de score não é aditivo.

O nosso alinhamento será sobre **BLOCOS**.

# Tipos de Blocos

1. Dois caracteres de  $\Sigma$  alinhados
2. Uma série maximal de caracteres consecutivos de  $t$  alinhados com espaços em  $s$
3. Uma série maximal de caracteres consecutivos de  $s$  alinhados com espaços em  $t$ .

$s$ : AAC---AATTCCGACTAC

$t$ : ACTACCT-----CGC--

$s$ : A|A|C|---|A|ATTCCG|A|C|T|AC

$t$ : A|C|T|ACC|T|-----|C|G|C|--

# Scoring a Nível de Bloco

No algoritmo de Programação Dinâmica, ao invés de pensarmos na **coluna** anterior, temos que pensar no **bloco** anterior.

Note que blocos do tipo 2 e 3 (que envolvem gaps) não podem seguir blocos do mesmo tipo.

Por quê?

$s$ : A|A|C|--|-|A|ATT|CCG|A|C|T|AC

$t$ : A|C|T|AC|C|T|---|---|C|G

# Scoring a Nível de Bloco

Ao invés de lembrarmos para cada par  $(i, j)$  apenas o melhor score entre  $s[1..i]$  e  $t[1..j]$ , precisaremos lembrar o melhor score destes prefixos **terminando com um tipo de bloco** em particular → Três matrizes.

## Inicialização:

$$a[0, 0] = 0$$

$$b[0, j] = -w(j)$$

$$c[i, 0] = -w(i)$$

Todos os demais valores devem ter  $-\infty$

# Scoring a Nível de Bloco

**Passo:**

$$a[i, j] = p(i, j) + \max \begin{cases} a[i-1, j-1] \\ b[i-1, j-1] \\ c[i-1, j-1] \end{cases}$$

$$b[0, j] = \max \begin{cases} a[i, j-k] - w(k), \text{ para } 1 \leq k \leq j \\ c[i, j-k] - w(k), \text{ para } 1 \leq k \leq j \end{cases}$$

$$c[0, j] = \max \begin{cases} a[i-k, j] - w(k), \text{ para } 1 \leq k \leq j \\ b[i-k, j] - w(k), \text{ para } 1 \leq k \leq j \end{cases}$$

Note que cada entrada do array  $b$  ou  $c$  depende de vários valores anteriores, porque o último bloco pode ter tamanho variável.

## Ao final...

O custo do melhor alinhamento entre as duas seqüências será dado pelo máximo entre  $a[n, m]$ ,  $b[n, m]$  e  $c[n, m]$ .

A complexidade desta nova versão do algoritmo é  $O(m n^2 + m^2 n)$ .

Para conseguir um alinhamento ótimo, basta proceder da mesma forma que antes, apenas tendo o cuidado de usar o array (bloco) correto.

# Complementando o projeto anterior

Adicionar uma terceira opção de tipo de alinhamento:  
Alinhamento local.

Neste alinhamento,

- Serão usados blocos, como indicado na aula de hoje.
- Os custos das substituições serão dados pela matriz BLOSUM 62.
- Os custos dos gaps serão lidos como entrada.