

Matrizes de score

- As matrizes de *score*, ou matrizes de substituição, permitem obter um score para a comparação de cada um dos possíveis pares de aminoácidos
 - Os valores destas matrizes expressam as diferentes tendências de conservação dos aminoácidos em posições **homólogas** de duas sequências
 - Existem diferentes tipos de matrizes de *score*, baseados em diferentes análises e diferentes pressupostos sobre os mecanismos de substituição
 - O processo de inserção (criação de *gaps*) é geralmente tratado separadamente (não há scores nas matrizes para alinhamento com *gaps*)
 - Os dois tipos de matrizes mais usados são:
Matrizes PAM: baseadas na comparação, por alinhamento global, de famílias de sequências muito próximas
Matrizes BLOSUM: baseadas no alinhamento de regiões de elevada similaridade (blocos) em diferentes grupos de proteínas.

Matrices PAM

Matriz PAM 256

- As matrizes PAM são geradas a partir das frequências de substituição para sequências muito próximas (%id > 85%) e depois extrapoladas para sequências mais distantes
 - Assume-se que a probabilidade de substituição numa posição é independentes das substituições anteriores e dos resíduos circundantes
 - As matrizes PAM deverão ser escolhidas de acordo com o grau de proximidade esperado entre as sequências.

Exemplo:

PAM400 - sequências distantes

PAM10 - sequências próximas

1 PAM = 1 Point Accepted Mutation per 100 aminoacids
PAM250 ≈ 20% de identidade entre as sequências

Alinhamento de sequências de citocromo b de primatas (fragmento)

P00156 CYB_HUMAN	1 MTPMRKTNPMLKLINHSFIDLPTPSNISAWWNFGSLLGACLILQITTGLFLAMHYSPDAS
Q9G0S9 CYB_MICMU	1 MTNIRKTHPLMKIMNNSFIDLPPAPSNISSWWNFGSLLGACLVIQITGLFLAMHYTADTT
Q2Y067 CYB_AOTAI	1 MTPRKTHPLAKIINESFIDLPTPSNISSWWNFGSLLGICLIIQITTGFLFLAMHYTPDTS
Q34876 CYB_LEMCA	1 MTPNIRKNHPLMKIMNSSFIDLPTPSNISSWWNFGSLLGACLAIQIITGLFLAMHYTADTT
Q3YLC2 CYB_MIRZA	1 MTPNIRKMHPLMKIMNSSFIDLPTPSNISSWWNFGSLLGACLAIQIITGLFLAMHYTADTA
047488 CYB_CEPBA	1 MTPNLRKTHPLMKIINHSFIDLPTPSNISSAWWNFGSLLGVCLGLQIVTGLFLAMHYTPDTM
Q9G946 CYB_PROCO	1 MTPNIRKNHPLIKIMNSSFIDLPTPSNISSWWNFGSLLGACLAIQIITGLFLAMHYTADTT
047892 CYB_NOMLE	1 MTPPLRKTNPMLKLINHSLVDLPPAPSNISSWWNLGSLLGTCVLQIVTGLFLAMHYTPDAS
Q50DL8 CYB_CHLAE	1 MTPPMRKSNPIMKMINHSLIDLPTPSNISSWWNFGSLLAFCLILQIITGLFLAMHYSPDTS
Q35930 CYB_SAISC	1 MTPSPRKTHPLKKMINNSFIDLPTPSNISSFWWNNGSLLGACLIIQITTGFLFLAMHYTPDTQ
Q35677 CYB_PROTA	1 MTPNIRKNHPLIKIMNSSFIDLPTPSNISSWWNFGSLLGACLAIQIITGLFLAMHYTADTT
Q34341 CYB_DAUMA	1 MTPNIRKTPLIKIINNSFIDLPTPSNISSWWNFGSLLGTCVLQILTGLFLAMHYTSDDT
Q35131 CYB_NYCCO	1 MTPNIRKNHPLMKIINHSFIDLPTPSNISSWWNFGSLLGCLTIQIVTGLFLAMHYTSDDT *** :*: *::* :***:***** ***:***. ** :** *****: *: 61 TAFSSIAHITRDVNYGWIIRYLHANGASMFFICLFLHIGRGLYYGSFLYSETWNIGIILL 61 TAFSSVTHICRDVNQGWIIRYLHANGASMFFLCLFLHVGGRGMYYGSFTLTETWNIGIILL 61 TAFSSVAHITRDVNYGWIIRYLHANGASMFFLCLFIHIGRGLYYGSFLFLKTWNIGIILL 61 TAFSSVTHICRDVNQGWIIRYIHANGASMFFVCLFLHIGRGLYYGSFTLSETWNIGIILL 61 TAFSSVTHICRDVNQGWIIRYIHANGASMFFMCLFIHVGGRGMYYGSFTLSETWNIGIILL 61 TAFSSVTHICRDVNQGWIIRYIHANGASMFFMCLFMHVGGRGLYYGSFTLSETWNIGIILL 61 TAFSSVTHICRDVNQGWIIRYIHANGASMFFLCLFIHVGGRGLYYGSFTLSETWNIGIILL 61 MAFSSVAHITRDVNYGWIIRYIHANGASMFFICLFLHIGRGLYYGSFLYLETWNIGIILL 61 SAFSSIAHITRDVNHGWIIRYIHANGASMFFICLFLHVGRSLYYGSFLLLKTWNTGIMLL 61 TAFSSVAHITRDVNHGWTIRYMHANGASMFFTCLFLHIGRGLYYGSFLSRETWNIGTILL 61 TAFSSVTHICRDVNQGWIIRYIHANGASMFFLCLFIHVGGRGLYYGSFTLSETWNIGIILL 61 SAFSSISHICRDVNQGWIIRYIHANGASMFFLCLFIHTGRGLYYGSFTYLETNIGIILL 61 TAFSSVAHICRDVNQGWIIRYIHANGASMFFCFLFIHIGRGLYYGSFTLLEDTWNIGIMLL 61 ****:*** ***:***:***** ***:***:***: .*** * :** 121 LATMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTDLVQWIWGGYSVDSTLTRFFT 121 FTVMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTDLVWEWIWGGFSVDKATLTRFFA 121 LTTMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGSDLVQWXWGGFSVDKATLTRFFT 121 FTVMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTNTLVEWIWGGFSVDKATLTRFFA 121 FTVMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTSLVEWIWGGFSVDKATLTRFFA 121 FTVMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGINLVEWIWGGFSVDKATLTRFFA 121 LATMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTNTLVEWIWGGFSVDKATLTRFFT 121 FTMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTNTLVEWIWGGFSVDKATLTRFFA 121 LTTMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTSNLVEWIWGGFSVDKATLTRFFT 121 FTVMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTDLVQWVWGGYSVDNATLTRFFT 121 LTVMATAFMGYVLPWGQMSFWGATVITNLLSATPYIGTSLVEWIWGGFSVDKATLTRFFA 121 IAVMATAFMGYVLPWGQMSFWGATVITNLLSAIPYIGTNTLVEWIWGGFSVDKATLTRFFA 121 : .*****:*****:*****:***:***:***:***: .***:***:

A similaride destas sequências é muito elevada pelo que podemos alinhá-las “manualmente”

As frequências de ocorrência das substituição de pares de amino ácidos podem ser obtidas por contagem directa no alinhamento

Estas frequências de ocorrência podem ser convertidas numa matriz de probablidades de transição (mutação)

As frequências são extrapoladas para distâncias evolutivas maiores

Estes cálculos têm que ser feitos com milhares de sequências para serem estaticamente fiáveis!

Percentagens de identidade para o alinhamento do cit b de primatas

Percent Identity Matrix

□  Q34341 CYB_DAUMA	100.00%	86.02%	83.38%	85.49%	83.91%	82.59%	83.11%	82.85%	81.27%	79.16%	76.78%	80.74%	78.89%
□  Q34876 CYB_LEMCA	86.02%	100.00%	91.03%	92.88%	90.24%	89.71%	84.17%	84.17%	78.10%	77.57%	74.93%	80.21%	78.89%
□  Q9G946 CYB_PROC	83.38%	91.03%	100.00%	97.89%	87.86%	87.60%	82.32%	81.79%	76.52%	75.46%	73.09%	77.84%	78.10%
□  Q35677 CYB_PROTA	85.49%	92.88%	97.89%	100.00%	89.71%	89.71%	84.43%	83.91%	78.36%	77.31%	75.20%	79.68%	79.68%
□  Q9G0S9 CYB_MICMU	83.91%	90.24%	87.86%	89.71%	100.00%	90.77%	82.59%	83.91%	77.84%	77.04%	74.14%	79.16%	78.89%
□  Q3YLC2 CYB_MIRZA	82.59%	89.71%	87.60%	89.71%	90.77%	100.00%	82.59%	83.64%	77.84%	77.57%	74.14%	78.89%	76.52%
□  O47488 CYB_CEPBA	83.11%	84.17%	82.32%	84.43%	82.59%	82.59%	100.00%	84.70%	78.63%	77.31%	75.20%	77.84%	78.36%
□  Q35131 CYB_NYCCO	82.85%	84.17%	81.79%	83.91%	83.91%	83.64%	84.70%	100.00%	79.95%	77.31%	76.52%	78.63%	79.42%
□  Q2Y067 CYB_AOTAI	81.27%	78.10%	76.52%	78.36%	77.84%	77.84%	78.63%	79.95%	100.00%	87.60%	76.78%	81.53%	79.16%
□  Q35930 CYB_SAISC	79.16%	77.57%	75.46%	77.31%	77.04%	77.57%	77.31%	77.31%	87.60%	100.00%	75.20%	79.42%	78.10%
□  Q50DL8 CYB_CHLAE	76.78%	74.93%	73.09%	75.20%	74.14%	74.14%	75.20%	76.52%	76.78%	75.20%	100.00%	82.11%	80.00%
□  P00156 CYB_HUMAN	80.74%	80.21%	77.84%	79.68%	79.16%	78.89%	77.84%	78.63%	81.53%	79.42%	82.11%	100.00%	86.32%
□  O47892 CYB_NOMLE	78.89%	78.89%	78.10%	79.68%	78.89%	76.52%	78.36%	79.42%	79.16%	78.10%	80.00%	86.32%	100.00%

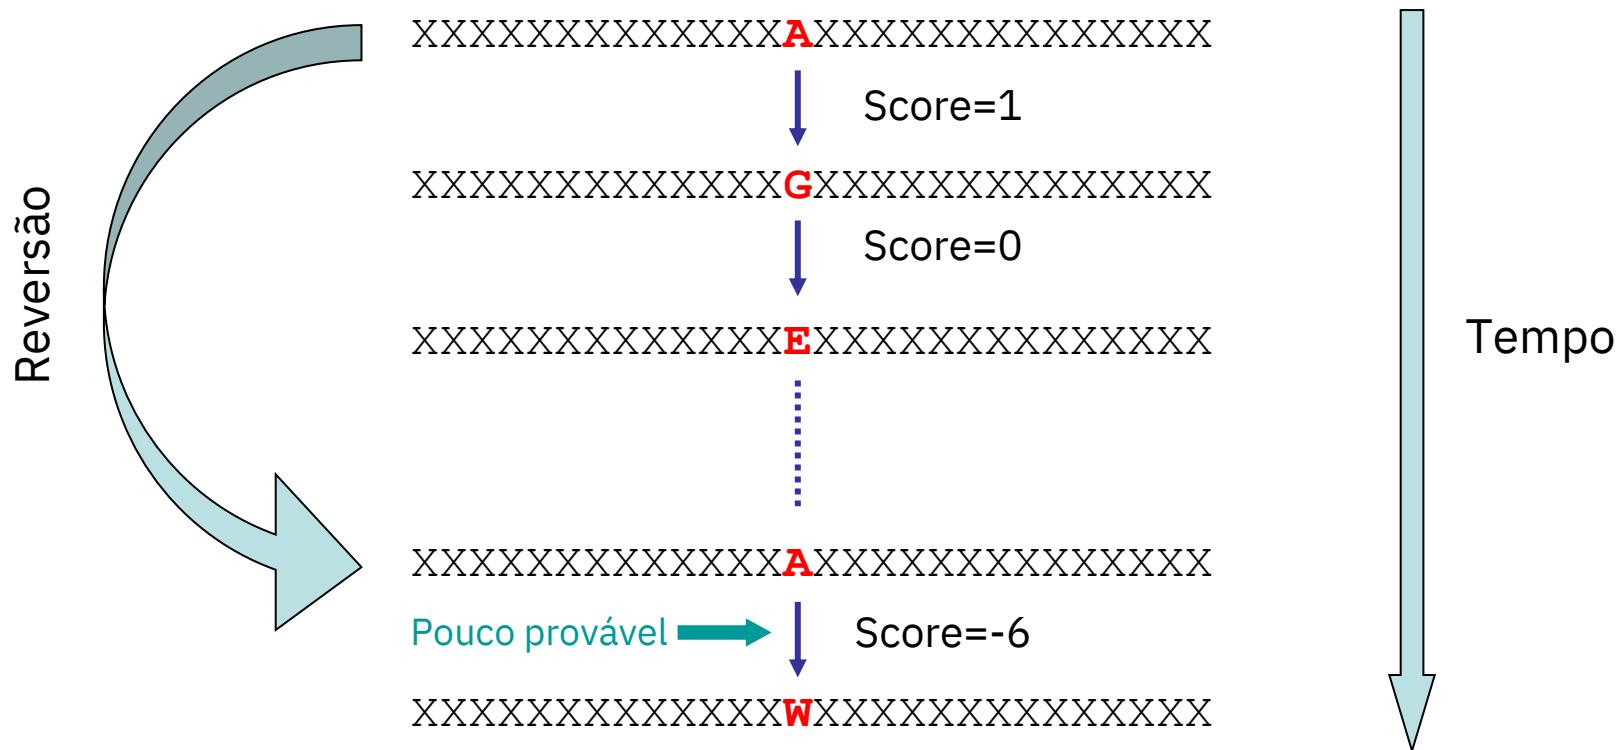
Align results

[Overview](#) [Trees](#) [Percent Identity Matrix](#) [Text Output](#) [Input Parameters](#) [API Request](#)

BLAST Align Map IDs [Download](#) [Add](#) [Resubmit](#)

Highlight properties • Select annotation • View: Overview Wrapped

Evolução por mutações sucessivas



Reversão: o aminoácido numa determinada posição pode mutar sucessivas vezes e voltar a dar origem ao aminoácido inicial.

Distância PAM versus % de identidade

PAM \geq 100 - %id

% de identidade
mínima para
conseguir produzir
um alinhamento



% identidade	Unidades PAM
99	1
95	5
90	11
85	17
80	23
75	30
70	38
66	47
60	56
55	67
50	80
45	94
40	112
35	133
30	159
25	195
20	246
15	328

- A percentagem de identidade não reflete exatamente o número de substituições que ocorreram numa determinada posição, pois há mutações “ocultas” mascaradas pela reversão
- O número de idades PAM de distância entre duas sequências é quase sempre superior ao número de substituições visíveis no alinhamento ($100\text{-}\%id$).

Probabilidade para a mutação de um aminoácido a PAM1 e a PAM250

- A uma distância de PAM1, a probabilidade da fenilalanina não mutar é 99%, e a probabilidade de mutar num dos outros 19 aminoácidos é ~1%
- A uma distância de PAM250, a probabilidade de a fenilalanina ser conservada é de 32%, e de mutar em um qualquer dos outros aminoácidos é 68%
- As probabilidades individuais de mutação em cada um dos outros 19 aminoácidos são diferentes

Amino acid change	PAM1	PAM250
Phe to Ala	0.0002	0.04
Phe to Arg	0.0001	0.01
Phe to Asn	0.0001	0.02
Phe to Asp	0.0000	0.01
Phe to Cys	0.0000	0.01
Phe to Gln	0.0000	0.01
Phe to Glu	0.0000	0.01
Phe to Gly	0.0001	0.03
Phe to His	0.0002	0.02
Phe to Ile	0.0007	0.05
Phe to Leu	0.0013	0.13
Phe to Lys	0.0000	0.02
Phe to Met	0.0001	0.02
Phe to Phe	0.9946	0.32
Phe to Pro	0.0001	0.02
Phe to Ser	0.0003	0.03
Phe to Thr	0.0001	0.03
Phe to Trp	0.0001	0.01
Phe to Tyr	0.0021	0.15
Phe to Val	0.0001	0.05
SUM ^a	1.0000	1.00

Probabilidade da Fenilalanina não mutar:
99% (1 PAM)
32% (250 PAM)

^aApproximate since scores are rounded off.

Matriz PAM 1 – probabilidades de transição

	Ala	Arg	Asn	Asp	Cys	Gln	Glu	Gly	His	Ile	Leu	Lys	Met	Phe	Pro	Ser	Thr	Trp	Tyr	Val
	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
Ala A	9867	2	9	10	3	8	17	21	2	6	4	2	6	2	22	35	32	0	2	18
Arg R	1	9913	1	0	1	10	0	0	10	3	1	19	4	1	4	6	1	8	0	1
Asn N	4	1	9822	36	0	4	6	6	21	3	1	13	0	1	2	20	9	1	4	1
Asp D	6	0	42	9859	0	6	53	6	4	1	0	3	0	0	1	5	3	0	0	1
Cys C	1	1	0	0	9973	0	0	0	1	1	0	0	0	0	1	5	1	0	3	2
Gln Q	3	9	4	5	0	9876	27	1	23	1	3	6	4	0	6	2	2	0	0	1
Glu E	10	0	7	56	0	35	9865	4	2	3	1	4	1	0	3	4	2	0	1	2
Gly G	21	1	12	11	1	3	7	9935	1	0	1	2	1	1	3	21	3	0	0	5
His H	1	8	18	3	1	20	1	0	9912	0	1	1	0	2	3	1	1	1	4	1
Ile I	2	2	3	1	2	1	2	0	0	9872	9	2	12	7	0	1	7	0	1	33
Leu L	3	1	3	0	0	6	1	1	4	22	9947	2	45	13	3	1	3	4	2	15
Lys K	2	37	25	6	0	12	7	2	2	4	1	9926	20	0	3	8	11	0	1	1
Met M	1	1	0	0	0	2	0	0	0	5	8	4	9874	1	0	1	2	0	0	4
Phe F	1	1	1	0	0	0	0	1	2	8	6	0	4	9946	0	2	1	3	28	0
Pro P	13	5	2	1	1	8	3	2	5	1	2	2	1	1	9926	12	4	0	0	2
Ser S	28	11	34	7	11	4	6	16	2	2	1	7	4	3	17	9840	38	5	2	2
Thr T	22	2	13	4	1	3	2	2	1	11	2	8	6	1	5	32	9871	0	2	9
Trp W	0	2	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	9976	1	0
Tyr Y	1	0	3	0	3	0	1	0	4	1	1	0	0	21	0	1	1	2	9945	1
Val V	13	2	1	1	3	2	2	3	3	57	11	1	17	1	3	2	10	0	2	9901

(as probabilidades estão multiplicadas por 10000 para maior legibilidade)

Matriz PAM 1 – log odds scores

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V	
A	11	-26	-20	-19	-24	-20	-17	-16	-26	-22	-24	-26	-21	-27	-16	-14	-14	###	-26	-17	
R	-26	14	-25	-25	###	-26	-16	###	-30	-16	-22	-28	-13	-20	-29	-20	-18	-26	-17	-31	-26
N	-20	-25	14	-10	###	-20	-18	-19	-13	-21	-25	-15	###	-28	-24	-13	-16	-26	-20	-28	
D	-19	###	-10	13	###	-19	-9	-19	-21	-26	###	-21	###	###	-29	-20	-22	###	###	-27	
C	-24	-26	###	###	15	###	###	-30	-25	-24	###	###	###	###	-27	-18	-28	###	-20	-23	
Q	-20	-16	-20	-19	###	14	-11	-25	-12	-27	-21	-18	-19	###	-18	-22	-23	###	###	-25	
E	-17	###	-18	-9	###	-11	13	-21	-23	-22	-29	-21	-25	###	-23	-21	-25	###	-27	-24	
G	-16	-30	-19	-19	-30	-25	-21	10	-30	###	-31	-26	-28	-28	-25	-16	-25	###	###	-23	
H	-26	-16	-13	-21	-25	-12	-23	-30	15	-31	-23	-26	###	-23	-20	-24	-26	-26	-19	-23	
I	-22	-22	-21	-26	-24	-27	-22	###	-31	14	-16	-23	-15	-17	-29	-26	-17	###	-24	-11	
L	-24	-28	-25	###	###	-21	-29	-31	-23	-16	11	-27	-13	-18	-25	-28	-25	-23	-25	-18	
K	-26	-13	-15	-21	###	-18	-21	-26	-26	-23	-27	11	-16	###	-25	-20	-19	###	-29	-30	
M	-21	-20	###	###	###	-19	-25	-28	###	-15	-13	-16	18	-20	-28	-22	-20	###	###	-16	
F	-27	-29	-28	###	###	###	###	-28	-23	-17	-18	###	-20	14	-29	-23	-29	-21	-12	-29	
P	-16	-20	-24	-29	-27	-18	-23	-25	-20	-29	-25	-25	-28	-29	13	-16	-21	###	###	-23	
S	-14	-18	-13	-20	-18	-22	-21	-16	-24	-26	-28	-20	-22	-23	-16	11	-13	-21	-25	-25	
T	-14	-26	-16	-22	-28	-23	-25	-25	-26	-17	-25	-19	-20	-29	-21	-13	12	###	-24	-18	
W	###	-17	-26	###	###	###	###	###	-26	###	-23	###	###	-21	###	-21	###	20	-22	###	
Y	-26	-31	-20	###	-20	###	-27	###	-19	-24	-25	-29	###	-12	###	-25	-24	-22	15	-25	
V	-17	-26	-28	-27	-23	-25	-24	-23	-23	-11	-18	-30	-16	-29	-23	-25	-18	###	-25	12	

Os valores de score são logaritmos

$$S_{ij} = \log_b (p_i M_{ij} / p_i p_j)$$

S_{ij} = score (“log odds” ratio)

M_{ij} = score da matriz de transição (probabilidade observada de substituição do resíduo p_i por p_j)

p_i, p_j = probabilidades de ocorrência dos aminoácidos

b = base do logaritmo (arbitrária)

Odds ratio ($p_i M_{ij}/p_i p_j$) – razão entre a probabilidade de ocorrência de uma transição, e a probabilidade de ocorrência dessa mesma transição num modelo aleatório

G A L H I V H
| | | | | | |
G G V N L V H

$p_1 * p_2 * p_3 * p_4 * p_5 * p_6 * p_7 = Pa$ (probabilidade de ocorrência do alinhamento)

dado que **log(a*b) = log(a) + log(b)** temos:

$$\begin{aligned}\log(Pa) &= \log(p_1 * p_2 * p_3 * p_4 * p_5 * p_6 * p_7) = \\ &= \log(p_1) + \log(p_2) + \log(p_3) + \log(p_4) + \log(p_5) + \log(p_6) + \log(p_7)\end{aligned}$$

Assim, se usarmos $\log(p_i)$ como valor de score para cada resíduo, a soma destes valores produz o logaritmo do score total $\log(Pa)$!

Família de Matrizes PAM

Família de matrizes de substituição – PAM 1, PAM 2, etc. – onde
PAM n é adequada à comparação de sequências que distam entre si
de n PAM

$$\text{PAM } n = (\text{PAM } 1)^n$$

$$\text{PAM2} = \text{PAM1} \times \text{PAM1}$$

$$\text{PAM4} = \text{PAM2} \times \text{PAM2}$$

$$\text{PAM8} = \text{PAM4} \times \text{PAM4}$$

$$\text{PAM16} = \text{PAM8} \times \text{PAM8}$$

$$\text{PAM32} = \text{PAM16} \times \text{PAM16}$$

$$\text{PAM64} = \text{PAM32} \times \text{PAM32}$$

$$\text{PAM128} = \text{PAM64} \times \text{PAM64}$$

$$\text{PAM256} = \text{PAM128} \times \text{PAM128}$$

Não confundir com as matrizes PAM de substituição com as matrizes PAM de score.

Matrizes PAM de score são obtidas a partir das matrizes PAM de substituição calculando os logaritmos da razão das frequências observadas e esperadas (“log odds score”)..

PAM2

A	10	-23	-17	-16	-21	-17	-14	-13	-23	-19	-21	-23	-18	-24	-13	-11	-11	-46	-23	-14
R	-23	14	-22	-41	-23	-13	-39	-27	-13	-19	-25	-10	-17	-26	-17	-15	-23	-14	-28	-23
N	-17	-22	14	-8	-41	-17	-15	-16	-10	-18	-22	-12	-38	-25	-21	-10	-13	-23	-17	-25
D	-16	-41	-8	13	-47	-16	-6	-16	-18	-23	-44	-18	-42	-48	-26	-17	-19	-48	-42	-24
C	-21	-23	-41	-47	15	-47	-47	-27	-22	-21	-48	-47	-46	-45	-24	-15	-25	-49	-17	-20
Q	-17	-13	-17	-16	-47	14	-9	-22	-9	-24	-18	-15	-16	-45	-15	-19	-20	-45	-43	-22
E	-14	-39	-15	-6	-47	-9	13	-18	-20	-19	-26	-18	-22	-47	-20	-18	-22	-52	-24	-21
G	-13	-27	-16	-16	-27	-22	-18	10	-27	-42	-28	-23	-25	-25	-21	-13	-22	-48	-46	-20
H	-23	-13	-10	-18	-22	-9	-20	-27	15	-28	-20	-22	-41	-20	-17	-21	-23	-23	-16	-21
I	-19	-19	-18	-23	-21	-24	-19	-42	-28	14	-13	-20	-12	-14	-26	-23	-14	-46	-21	-8
L	-21	-25	-22	-44	-48	-18	-26	-28	-20	-13	11	-24	-10	-15	-22	-25	-22	-20	-22	-15
K	-23	-10	-12	-18	-47	-15	-18	-23	-22	-20	-24	11	-13	-46	-22	-17	-16	-43	-26	-27
M	-18	-17	-38	-42	-46	-16	-22	-25	-41	-12	-10	-13	18	-17	-25	-19	-17	-45	-42	-13
F	-24	-26	-25	-48	-45	-45	-47	-25	-20	-14	-15	-46	-17	14	-26	-20	-25	-18	-9	-26
P	-13	-17	-21	-26	-24	-15	-20	-21	-17	-26	-22	-22	-25	-26	13	-13	-18	-46	-46	-20
S	-11	-15	-10	-17	-15	-19	-18	-13	-21	-23	-25	-17	-19	-20	-13	11	-10	-18	-22	-22
T	-11	-23	-13	-19	-25	-20	-22	-22	-23	-14	-22	-16	-17	-25	-18	-10	12	-44	-21	-15
W	-46	-14	-23	-48	-49	-45	-52	-48	-23	-46	-20	-43	-45	-18	-46	-18	-44	20	-19	-49
Y	-23	-28	-17	-42	-17	-43	-24	-46	-16	-21	-22	-26	-42	-9	-46	-22	-21	-19	15	-22
V	-14	-23	-25	-24	-20	-22	-21	-20	-21	-8	-15	-27	-13	-26	-20	-22	-15	-49	-22	12
	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V

PAM50

A	8	-8	-3	-3	-7	-4	-2	-1	-8	-5	-7	-8	-5	-10	-1	1	1	-16	-9	-2
R	-8	12	-6	-11	-10	-1	-10	-11	-1	-6	-10	2	-4	-11	-4	-3	-7	-1	-12	-9
N	-3	-6	10	3	-12	-3	-1	-3	2	-6	-9	0	-10	-10	-6	1	-1	-10	-5	-9
D	-3	-11	3	10	-17	-2	5	-3	-4	-9	-14	-4	-12	-17	-9	-3	-5	-18	-13	-9
C	-7	-10	-12	-17	14	-17	-17	-11	-9	-7	-18	-17	-16	-15	-10	-3	-9	-19	-4	-7
Q	-4	-1	-3	-2	-17	12	3	-8	3	-9	-6	-2	-4	-15	-3	-6	-6	-15	-14	-8
E	-2	-10	-1	5	-17	3	10	-4	-5	-6	-11	-4	-8	-17	-6	-4	-6	-20	-10	-7
G	-1	-11	-3	-3	-11	-8	-4	9	-10	-12	-13	-8	-10	-11	-7	-1	-6	-18	-16	-6
H	-8	-1	2	-4	-9	3	-5	-10	13	-10	-7	-6	-12	-7	-4	-6	-8	-9	-3	-7
I	-5	-6	-6	-9	-7	-9	-6	-12	-10	12	0	-7	1	-2	-10	-8	-2	-16	-7	4
L	-7	-10	-9	-14	-18	-6	-11	-13	-7	0	10	-10	2	-2	-8	-10	-8	-7	-8	-1
K	-8	2	0	-4	-17	-2	-4	-8	-6	-7	-10	9	-1	-16	-7	-4	-3	-13	-11	-10
M	-5	-4	-10	-12	-16	-4	-8	-10	12	1	2	-1	16	-4	-9	-6	-4	-15	-13	0
F	-10	-11	-10	-17	-15	-15	-17	-11	-7	-2	-2	-16	-4	13	-12	-8	-10	-5	4	-9
P	-1	-4	-6	-9	-10	-3	-6	-7	-4	-10	-8	-7	-9	-12	11	-1	-4	-16	-16	-6
S	1	-3	1	-3	-3	-3	-6	-4	-1	-6	-8	-10	-4	-6	-8	-1	8	2	-6	-8
T	1	-7	-1	-5	-9	-6	-6	-6	-8	-2	-8	-3	-4	-10	-4	2	10	-15	-8	-2
W	-16	-1	-10	-18	-19	-15	-20	-18	-9	-16	-7	-13	-15	-5	-16	-6	-15	19	-6	-19
Y	-9	-12	-5	-13	-4	-14	-10	-16	-3	-7	-8	-11	-13	4	-16	-8	-8	-6	14	-9
V	-2	-9	-9	-7	-8	-7	-6	-7	4	-1	-10	0	-9	-6	-7	-2	-19	-9	10	
	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V

PAM150

A	4	-3	0	0	-3	-1	0	1	-3	-1	-3	-3	-2	-5	1	2	2	-9	-5	0
R	-3	9	-1	-4	-5	1	-3	-5	2	-3	-5	4	-1	-7	-1	-1	-2	2	-7	-4
N	0	-1	5	3	-6	0	1	0	2	-3	-5	1	-3	-5	-2	1	0	-6	-3	-3
D	0	-4	3	6	-8	1	5	0	0	-4	-7	-1	-5	-9	-3	0	-1	-10	-7	-4
C	-3	-5	-6	-8	13	-8	-8	-6	-5	-4	-9	-9	-8	-7	-5	0	-4	-11	-1	-3
Q	-1	1	0	1	-8	7	3	-3	4	-4	-3	0	-2	-8	0	-2	-2	-7	-6	-3
E	0	-3	1	5	-8	3	6	-1	0	-3	-5	-1	-4	-9	-2	-1	-2	-11	-6	-3
G	1	-5	0	0	-6	-3	-1	7	-4	-5	-7	-3	-5	-7	-2	1	-1	-10	-8	-3
H	-3	2	2	0	-5	4	0	-4	9	-5	-3	-1	-4	-3	-1	-2	-3	-4	-1	-4
I	-1	-3	-3	-4	-4	-3	-5	-5	7	2	-3	2	1	-4	-3	0	-8	-3	5	
L	-3	-5	-5	-7	-9	-3	-7	2	8	-5	-4	1	-4	-5	-3	-3	-3	-3	-1	
K	-3	4	1	-1	-9	0	-1	-3	-1	3	-5	7	1	8	-3	-1	-1	-6	-7	-5
M	-2	-1	-3	-5	-8	-2	-4	-5	-4	2	4	1	11	-1	-4	-3	-1	-7	-5	2
F	-5	-7	-5	-9	-7	-8	-7	-3	1	1	-8	-1	11	-7	-5	-1	7	-3	-2	-10
P	1	-1	-2	-3	-5	0	-2	-2	-1	-4	-4	-3	-4	-7	8	1	0	-9	-8	-2
S	2	-1	1	0	0	-2	-1	1	-2	-3	-5	-1	4	2	-3	-4	-2	-2	-1	-2
T	2	-2	0	-1	-4	-2	-2	-1	-3	0	-3	-1	-5	0	2	5	-8	-4	0	-8
W	-9	2	-6	-10	-11	-7	-11	-10	-4	-8	-3	-6	-7	-1	-9	-3	8	-2	-10	-10
Y	-5	-7	-3	-7	-1	-6	-6	-8	-1	-3	-3	-7	-5	7	-8	-4	-2	7	-5	-3
V	0	-4	-3	-4	-3	-3	-4	5	1	-5	2	-3	-2	-2	0	-10	-4	7	-2	4
	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V

PAM256

A	2	-1	0	0	-2	0	0	1	-1	0	-2	-1	-1	-3	1	1	1	-6	-3	0
R	-1	6	0	-1	-4	1	-1	-2	2	-2	-3	3	0	-4	0	0	-1	2	-4	-2
N	0	0	2	2	-4	1	1	0	2	-2	-3	1	-2	-3	0	1	0	-4	-2	-2
D	0	-1	2	4	-5	2	3	1	1	-2	-4	0	-3	-5	-1	0	0	-7	-4	-2
C	-2	-4	-4	-5	12	-5	-5	-3	-2	-6	-5	-5	-4	-3	0	-2	-8	0	-2	-2
Q	0	1	1	2	-5	4	2	-1	3	-2	-2	1	-1	-5	0	0	-1	-5	-4	-2
E	0	-1	1	3	-5	2	4	0	1	-2	-3	0	-2	-5	-1	0	0	-7	-4	-2

PAM500

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	0	0	0	0	-1	0	0	1	0	0	-1	0	0	-1	0	0	0	-3	-1	0
R	0	2	0	0	-2	1	0	-1	1	-1	-1	2	0	-2	0	0	0	2	-2	-1
N	0	0	0	1	-2	1	1	0	1	-1	-1	0	-1	-2	0	0	0	-2	-1	0
D	0	0	1	1	-2	1	1	1	1	-1	-1	0	-1	-2	0	0	0	-3	-2	-1
C	-1	-2	-2	-2	9	-2	-2	-1	-2	-1	-3	-2	-2	-1	-1	0	-1	-4	1	-1
Q	0	1	1	1	-2	1	1	0	1	-1	-1	1	0	-2	0	0	0	-2	-2	-1
E	0	0	1	1	-2	1	1	0	1	-1	-1	0	-1	-2	0	0	0	-3	-2	-1
G	1	-1	0	1	-1	0	0	2	0	-1	-1	0	-1	-2	0	1	0	-3	-2	0
H	0	1	1	1	-2	1	1	0	2	-1	-1	0	-1	-1	0	0	0	-1	0	-1
I	0	-1	-1	-1	-1	-1	-1	-1	-1	1	2	-1	1	1	-1	0	0	-2	0	1
L	-1	-1	-1	-1	-3	-1	-1	-1	-1	2	3	-1	2	2	-1	-1	0	-1	1	1
K	0	2	0	0	-2	1	0	0	0	-1	-1	2	0	-2	0	0	0	-1	-2	-1
M	0	0	-1	-1	-2	0	-1	-1	-1	1	2	0	2	1	-1	-1	0	-2	0	1
F	-1	-2	-2	-2	-1	-2	-2	-2	-1	1	2	-2	1	6	-2	-1	-1	1	5	0
P	0	0	0	0	-1	0	0	0	0	-1	-1	0	-1	-2	2	0	0	-3	-2	0
S	0	0	0	0	0	0	0	1	0	0	-1	0	-1	-1	0	0	0	-1	-1	0
T	0	0	0	0	-1	0	0	0	0	0	0	0	-1	0	0	0	-2	-1	0	
W	-3	2	-2	-3	-4	-2	-3	-3	-1	-2	-1	-1	-2	1	-3	-1	-2	15	1	-3
Y	-1	-2	-1	-2	1	-2	-2	-2	0	0	1	-2	0	5	-2	-1	-1	1	6	-1
V	0	-1	0	-1	-1	-1	-1	0	-1	1	1	-1	1	0	0	0	0	-3	-1	1

A	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0		
R	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0		
N	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0		
D	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	-1	-1	0	
C	0	0	0	0	5	0	0	0	0	-1	-1	-1	0	0	0	0	-1	0	0	
Q	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	
E	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	
G	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	0	-1	-1	0	
H	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
I	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
L	0	0	0	0	-1	0	0	0	0	1	0	0	1	0	0	0	0	0	0	
K	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
M	0	0	0	0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
F	0	0	0	-1	0	0	0	-1	0	0	1	0	0	2	0	0	0	1	2	0
P	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	
S	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
T	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	
W	-1	1	-1	-1	-1	-1	-1	-1	0	0	0	0	1	-1	0	-1	10	1	-1	
Y	0	0	0	-1	0	0	0	-1	0	0	0	0	2	0	0	0	1	2	0	
V	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0	0	
	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V

Matrizes BLOSUM

Matriz BLOSUM62

- As matrizes BLOSUM são construídas a partir da alinhamentos **locais** sem gaps de **regiões** de elevada similaridade
 - Estes alinhamentos (blocos) estão organizados numa base de dados chamada BLOCKS
 - O número da matriz BLOSUM indica a percentagem de identidade usada para agrupar as sequências
 - Quanto mais baixo o valor, maior a diversidade incorporada na criação da matriz

Exemplo:

BLOSUM90 - para sequências próximas

BLOSUM20 - para sequências afastadas

BLOSUM n – são comparadas sequências com uma percentagem de identidade não superior $n\%$.

BLOSUM N – construída a partir de blocos com similaridade não superior a N%

Exemplo de entrada na base de dados BLOCKS

Block PR00808A

```
ID  AMLASEINHBTR; BLOCK
AC  PR00808A; distance from previous block=(6,42)
DE  Cereal trypsin/alpha-amylase inhibitor family signature
BL  adapted; width=15; seqs=34; 99.5%=>771; strength=1203
O49864      ( 29) CAPGDALPHNPLRAC 28
O49865      ( 29) CAPGDALPHNPLRAC 28
IAAE HORVU|P01086 ( 29) CAPGDALPHNPLRAC 28
O49861      ( 29) CAPGDELPHNPLRAC 50
O49863      ( 29) CAPGDALPANPLRAC 30
O23982      ( 32) CSPGVAAFFTNLLGHC 43
IAAD HORVU|P11643 ( 32) CSPGVAAFFTNLLGHC 43
O49862      ( 29) CAPGDALPANPLRAC 30
ITRF MAIZE|P01088 ( 34) CVPGWAIIPHNPPLPSC 50
O24000      ( 32) CSPGVAAFFTNLHGHC 100
IA03 WHEAT|P17314 ( 29) CVPGVAAFRTNLLPHC 63
O49867      ( 29) CAPGDALPANPLRAC 30
IAAB HORVU|P32936 ( 30) CTPWTATPITPLPSC 54
IA16 WHEAT|P16159 ( 30) CTPWMSTLITPLPSC 69
IA02 WHEAT|P16851 ( 30) CYPGMGLPSNPLEGC 39
IAAA HORVU|P28041 ( 30) CYAGMGLPSNPLEGC 57
Q41540      ( 30) CTPWTSTLITPLPSC 71
IAAT ELECO|P01087 (  6) CIPGMAIPHNPPLDSC 58
RA14 ORYSA|Q01882 ( 41) CQPGMGYPMYSLPRC 35
Q40652      ( 41) CQPGMGYPMYSLPRC 35
RAG2 ORYSA|Q01885 ( 41) CQPGMGYPMYSLPRC 35
IA01 WHEAT|P16850 ( 30) CYAGMGLPINPLEGC 53
P93602      ( 32) CQPGVAFPHNALATC 43
Q40655      ( 42) CQPGMGYPMYPLPRC 30
Q40654      ( 41) CQPGIGYPTYPLPRC 36
RA05 ORYSA|Q01881 ( 41) CQPGMGYPMYSLPRC 35
RA17 ORYSA|Q01883 ( 39) CRPGISYPTYSLPQC 71
IAA HORVU|P16969 ( 33) CQLGVDFPHNPLATC 98
IAA4 SORBI|P81367 (  7) CAPGLAIPAPPLPTC 56
IAA1 WHEAT|P01085 (  6) CYPGQAFQVPALPAC 56
O49956      ( 37) CDPATGYKVSALTGC 71
IAA2 WHEAT|P01083 (  7) CNPATGYKVSALTGC 77
IAA5 WHEAT|P01084 (  6) CYPGQAFQVPALPGC 57
IAA2 HORVU|P13691 ( 37) CDPEMGHKVSPLTRC 96
//
```

Matriz	Utilização	% identidade
PAM40	Alinhamentos curtos, elevada similaridade	70-90
PAM160	Detecção de membros de uma família	50-60
PAM250	Alinhamentos de sequências distantes	~20-30
BLOSUM90	Alinhamentos curtos, elevada similaridade	70-90
BLOSUM80	Detecção de membros de uma família	50-60
BLOSUM62	Eficaz na detecção de possíveis similaridades	30-40
BLOSUM30	Alinhamentos longos, sequências distantes	<30

Matrizes de probabilidades de transição para nucleótidos

Transições: $A \leftrightarrow G$, $C \leftrightarrow T$

Transversões: $A \leftrightarrow T$, $G \leftrightarrow T$

$A \leftrightarrow C$, $G \leftrightarrow C$

Frequências de mutação uniformes (**1 PAM**)

	A	T	G	C
A	0.99			
T	0.0033	0.99		
G	0.0033	0.0033	0.99	
C	0.0033	0.0033	0.0033	0.99

Transições mais frequentes (3x) que transversões

	A	T	G	C
A	0.99			
T	0.0020	0.99		
G	0.0060	0.0020	0.99	
C	0.0020	0.0060	0.0020	0.99

Matrizes de score para nucleótidos (log odds)

$$S_{ij} = \log_b (p_i M_{ij} / p_i p_j)$$

S_{ij} = “log odds” score

M_{ij} = score da matriz de transição

p_i , p_j = probabilidades de ocorrência dos nucleótidos
 b = base do logaritmo (arbitrária)

Frequências de mutação uniformes (**1 PAM**)

	A	T	G	C
A	2			
T	-6	2		
G	-6	-6	2	
C	-6	-6	-6	2

Transições mais frequentes (**3x**) que transversões

	A	T	G	C
A	2			
T	-5	2		
G	-7	-7	2	
C	-5	-7	-5	2

$$S_{A,A} = \log_2(0.25 * 0.99 / 0.25 * 0.25) \approx 2$$

$$S_{T,A} = \log_2(0.25 * 0.0020 / 0.25 * 0.25) \approx -5$$

$$S_{T,A} = \log_2(0.25 * 0.0033 / 0.25 * 0.25) \approx -6$$

$$S_{G,A} = \log_2(0.25 * 0.0060 / 0.25 * 0.25) \approx -7$$

Interpretação física dos valores das matrizes de score

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

Chemical structures and labels for the amino acids:

- Glutamine: NC(C(=O)O)C(=O)N
- Aspartate: NC(CC(=O)O)C(=O)O
- Asparagine: NC(CC(=O)O)N
- Glutamine: NC(CC(=O)O)N
- Methionine: CSCC(=O)N
- Leucine: CC(C)CC(=O)N
- Valine: CC(C)C(=O)N
- Isoleucine: CC(C)CC(C)C(=O)N
- Phenylalanine: CC1=CC=C1Cc2ccccc2C(=O)N
- Tyrosine: Oc1ccc(cc1)Cc2ccccc2C(=O)N
- Tryptophan: CC1=CC=C1Cc2ccccc2C(=O)N
- Arginine: NC(CCN)C(=O)N
- Lysine: CC(C)CC(=O)N
- Histidine: CN1C=CC=C1C(=O)N

Red arrows and circles highlight specific interactions or patterns in the matrix.

Gap penalties

A inserção ou deleção de porções de uma sequência são eventos raros que conduzem a divergências de comprimento entre sequências homólogas.

Estas diferenças de comprimento implicam a necessidade inserir espaços (“gaps”) num alinhamento, mas esta inserção tem que ser pesadamente penalizada para estar de acordo com a raridade destes eventos.

Existem diferentes esquemas de penalização dos gaps (“gap penalties”), mas todos passam pela atribuição de um score negativo que está geralmente relacionado com o comprimento do gap.

Esquemas mais comuns:

- Constante: o tipo mais simples, consistem a atribuir uma penalização constante cada vez que é criado um gap num alinhamento
- Linear: a penalização é proporcional ao comprimento total dos gaps criados no alinhamento, não dependendo do seu número
- Afim (affine gap penalties): as penalizações possuem um termo constante para cada gap criado, e um termo proporcional ao comprimento do gap criado.

Penalidades afins (Affine gap penalties)

Uma representação mais realista do processo de evolução das proteínas deveria penalizar de modo diferente a *criação* e a *extensão* de um *gap*. Para entender este facto, devemos considerar que os alinhamentos entre sequências tem tendência a conter poucos gaps, mas quase sempre com vários resíduos de comprimento.

Se atribuirmos uma penalidade **c** para a criação de um gap e uma penalidade **e** para a sua extensão, temos:

$$gp = c + n \times e,$$

em que **n** é o comprimento do gap.

Não existe uma teoria rigorosa para a escolha de valores para este parâmetros!

Valores usuais:

$$c = -10, e = -2 \text{ (FASTA)}$$

$$c = -5 \dots -10, e = -1, -2 \text{ (BLAST)}$$

$$c = -12, -2 \text{ (Smith-Waterman)}$$

O valor óptimo das *gap penalties* depende da matriz de score usada!

Reese, JT & Pearson, WR (2002) *Bioinformatics*, **18**:1500-1507

Alinhamentos sub-óptimos: o programa LALIGN

Comparison of:
(A) f9-human.aa >F9 gi|119772|sp|P00740|FA9_HUMAN COAGULATION FA -
(B) f12-hum.aa >F12 gi|119763|sp|P00748|FA12_HUMAN COAGULATION -
using protein matrix

① 35.4% identity in 254 aa overlap; score: 358

F9	220	230	240	250	260	270
	QSFNDFTRVVGGEDAKPGQFPWQVVLNGKVDAFCGGSIVNEKWIWTAACVVE---TGVKI					

F12	370	380	390	400	410	420
	KSLSSMTRVVGGGLVALRGAHPYIAALY-WGHHSFCAGSLIAPCWVLTAAHCLQDRPAPEDL					

F9	280	290	300	310	320	330
	TVVAGEHNIEETEHTEQKRNVIIRIIPHYNNAINKYHNHDIALLELDPL----VLNSY					

F12	430	440	450	460	470	480
	TVVLGQERRNRHSCCEPCQTLAVRSYRLHEAFSPV--SYQHDLALLRLQEDADGSCALLSPY					

F9	340	350	360	370	380	
	VTPICIAIDKEYTNIFLKFGSGYVSGWGRVFHKGRS-ALVLQYLRVPLVDRATCLRSTKF-					

F12	490	500	510	520	530	
	VQPVCLPSGAARPSETTLHQ--VAGWGHQFEGAEYYASFLQEAQVPFLSLERC SAPDVHG					

F9	390	400	410	420	430	440
	-TIYNNMFCAGFHEGGRDSCQGDSSGGPHVTEVEGTS---FLTGIISWGEECAMKGKYGIY					

F12	540	550	560	570	580	590
	SSILPGMLCAGFLEGGTDACQGDSSGPLVCEDQAAERRLTQGIISWGSGCGDRNKPVGVY					

F9	450					
	TKVSRYVNWIKEKT					

F12	600	610				
	TDVAYYLAWIREHT					

② 34.7% identity in 49 aa overlap; score: 120

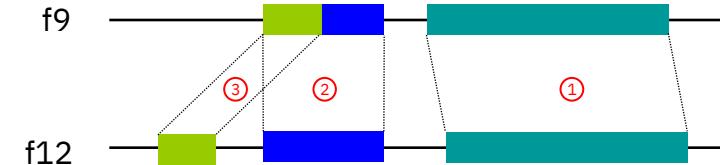
F9	100	110	120	130	140
	VDGDQCESNPCLNGGSCKDDINSYECWCPCFGFEGKNCELDVTCNIKNGR				

F12	180	190	200	210	220
	LASQACRTNPCLHGGRCLEVEGHRLCHCPVGYTGPFCDVDTKASCYDGR				

③ 33.3% identity in 36 aa overlap; score: 87

F9	100	110	120		
	DQCESN-PCLNGGSCKDDINSYECWCPCFGFEGKNCE				

F12	100	110	120	130	
	DHCSKHSPCQKGGTCVNMPSPGHCLCPQHLTGNHCQ				



- Neste caso o alinhamento 1 é o alinhamento local óptimo, e os alinhamentos 2 e 3 são alinhamentos sub-óptimos identificados pelo programa LALIGN
- Muitas vezes a análise de alinhamentos sub-óptimos permite a identificação de regiões de similaridade entre duas sequências, não imediatamente reconhecíveis num alinhamento óptimo