

# Tópicos Especiais em Inteligência Artificial

## COS746

Vítor Santos Costa  
COPPE/Sistemas

Universidade Federal do Rio de Janeiro



# Agradecimento

- Copiado dos slides de Mark Craven/C. David Page para BMI/CS 576, UW-Madison

# Funções de Penalização de buracos

- linear

$$w(k) = gk$$

- afim

$$w(k) = \begin{cases} h + gk, & k \geq 1 \\ 0, & k = 0 \end{cases}$$

- Côncava:

$$w(k + m + l) - w(k + m) \leq w(k + m) - w(k)$$

★ Ex:  $w(k) = h + g \times \log(k)$

# Programação Dinâmica para o caso afim

- Para conseguir em tempo  $O(n^2)$  precisamos de 3 matrizes em vez de 1:
  - ★  $M(i, j)$  melhor valor se  $x[i]$  estiver alinhado com  $y[j]$
  - ★  $I_x(i, j)$  melhor valor se  $x[i]$  estiver alinhado com um buraco
  - ★  $I_y(i, j)$  melhor valor se  $y[i]$  estiver alinhado com um buraco

# DP para o caso afim, global

- $M(i, j) = \max \begin{cases} M(i - 1, j - 1) + s(x_i, y_j) \\ I_x(i - 1, j - 1) + s(x_i, y_j) \\ I_y(i - 1, j - 1) + s(x_i, y_j) \end{cases}$
- $I_x(i, j) = \max \begin{cases} M(i - 1, j) + h + g \\ I_x(i - 1, j) + g \end{cases}$
- $I_y(i, j) = \max \begin{cases} M(i, j - 1) + h + g \\ I_y(i, j - 1) + g \end{cases}$
- Assumimos que é sempre melhor um match do que 2 buracos

# DP para o caso afim global

- Inicialização
  - ★  $M(0, 0) = 0$
  - ★  $I_x(i, 0) = h + g \times i$
  - ★  $I_y(0, j) = h + g \times j$
  - ★ outras células no topo e coluna da esquerda =  $-\infty$
- Voltar para trás:
  - ★ começar no maior de  $M(m, n), I_x(m, n), I_y(m, n)$
  - ★ parar num de  $M(0, 0), I_x(0, 0), I_y(0, 0)$

# DP para o caso afim local

- $M(i, j) = \max \begin{cases} M(i - 1, j - 1) + s(x_i, y_j) \\ I_x(i - 1, j - 1) + s(x_i, y_j) \\ I_y(i - 1, j - 1) + s(x_i, y_j) \\ 0 \end{cases}$
- $I_x(i, j) = \max \begin{cases} M(i - 1, j) + h + g \\ I_x(i - 1, j) + g \end{cases}$
- $I_y(i, j) = \max \begin{cases} M(i, j - 1) + h + g \\ I_y(i, j - 1) + g \end{cases}$

# DP para o caso afim local

- Inicialização
  - ★  $M(0, 0) = 0$
  - ★  $I_x(i, 0) = 0$
  - ★  $I_y(0, j) = 0$
  - ★ outras células no topo e coluna da esquerda =  $-\infty$
- Voltar para trás:
  - ★ começar no maior de  $M(i, j)$
  - ★ parar num  $M(i, j) = 0$

# DP Para o Caso Geral

Alinhamento Global:

$$\bullet F(i, j) = \max \begin{cases} F(i - 1, j - 1) + s(x_i, y_j) \\ F(k, j) + \gamma(i - k) \\ F(i, k) + \gamma(j - k) \end{cases}$$

- Considerar todos os elementos anteriores na linha!
- Considerar todos os elementos anteriores na coluna!

# Complexidade Computacional

Dependendo da penalização de buracos:

- linear:

$$O(n^2)$$

- afim:

$$O(n^2)$$

- geral:

$$O(n^3)$$

# Motivação para Uso de Heurísticas

- $O(mn)$  demasiado lento para grandes bancos de dados com muitas interrogações
- métodos heurísticos permitem aproximação rápida à programação dinâmica:
  - ★ FASTA, de Pearson & Lipman, 1988
  - ★ BLAST, de Altschul et al., 1990

# Motivação para Alinhamento Por Heurísticas

- Imaginem procurar SWISS-PROT contra uma sequência de interrogação:
  - ★ imaginem que a nossa pergunta tem 362 amino-ácidos
  - ★ SWISS-PROT versão 38 contém 29.085.265 amino-ácidos
  - ★ procurar alinhamentos locais através da programação dinâmica obrigaria a  $O(10^{10})$  operações em matrizes
- muitos servidores têm que resolver milhares de tais perguntas por dia
  - ★ NCBI > 100.000

# BLAST

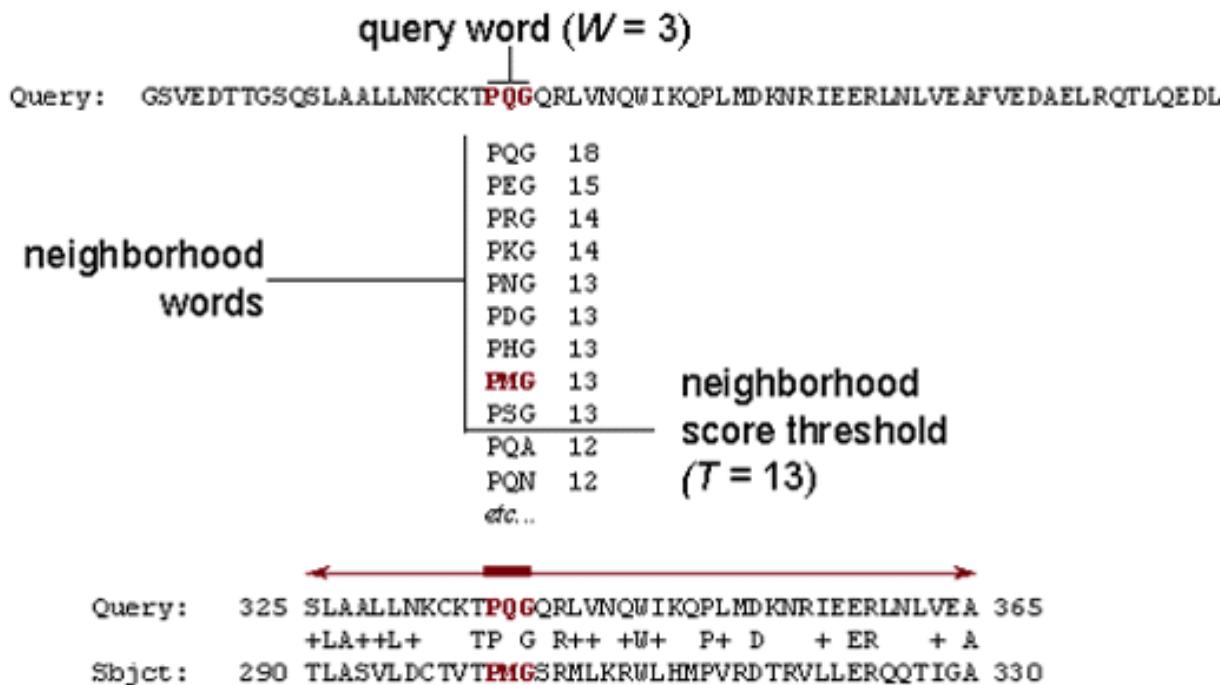
- Basic Local Alignment Search Tool
- BLAST usa heurísticas para encontrar *pares com pontuação alta* (HSPs):
  - ★ Segmentos do mesmo tamanho de 2 sequências com pontuação de alinhamento estatisticamente significantes
  - ★ ie, alinhamentos locais sem buracos
- Escolha entre precisão e velocidade

$$precisao = \frac{\#Emparelhamentos\ Significantes}{\#EmparelhamentosnaDB}$$

# Ideia do BLAST

- Dada uma sequência de interrogação  $q$  tamanho de palavra  $w$ , um limite de pontuação  $T$ , e um limite de segmento  $S$ :
  - ★ compilar uma lista de palavras que têm resultado  $\geq T$  quando comparadas com palavras de  $q$
  - ★ percorre a BD por alinhamentos com palavras na lista
  - ★ extender todos alinhamentos para procurar os pares de sequência com pontuação mais alta.
- resultado: pares de segmentos com resultado  $\geq S$

## The BLAST Search Algorithm



High-scoring Segment Pair (HSP)

# Determinação de Palavras da Interrogação

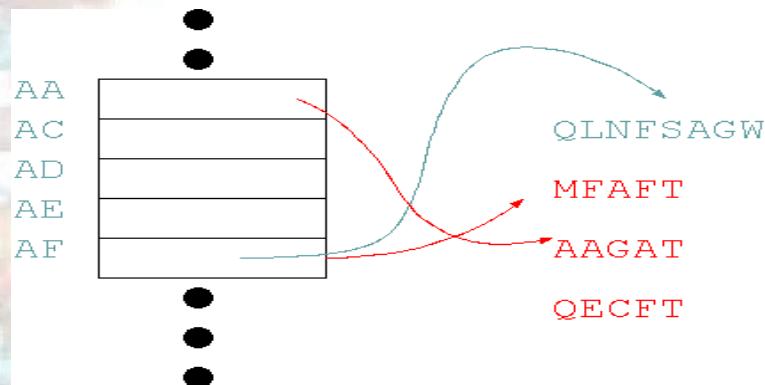
- Dada:
  - ★ sequência de interrogação: QLNFSAGW
  - ★ tamanho de palavra  $w = 2$  (para proteína usualmente  $w = 3$ )
  - ★ limite para pontuação de palavra;  $T = 8$
- Passo 1: determinar todas as palavras de tamanho  $w$  na sequência de interrogação:
  - ★ QL LN NF FS SA AG GW

# Palavras Similares Query

- Passo 2
  - ★ Procurar todas as palavras com resultado acima de limiar  $T$
  - ★ Usando  $T = 9$ 
    - \* QL  $\Rightarrow$  QL (10)
    - \* LN  $\Rightarrow$  LN (11), LS (9)
    - \* FS  $\Rightarrow$  FS (12)

# Procurando na BD

- Procurar na BD por todas as instâncias das palavras na sequência de interrogação:
- método:
  - ★ indexar sequências na BD com *tabela de palavras*
  - ★ procurar palavras da interrogação na tabela



# Ampliar Sucessos

- Ampliar sucessos em ambas as direcções (sem permitir buracos)
- terminar a ampliação numa direcção quando a pontuação cair abaixo de certa distância abaixo pontuação óptima para pequenas extensões

Inicial



Melhor Extensao b



Extensao Corrente c



$$score(c) \geq score(b) - \epsilon ?$$

- resultado: pares de segmentos com resultado pelo menos  $S$

# Pontuação

- Se na BD  $\mathcal{D}$  a sequência  $X$  tem o pontuação  $S(\mathcal{D}, X) = s$ , então:
  - ★ *p-value*:  $P(S(\mathcal{D}, Y) \leq s)$ , onde  $Y$  é uma sequência aleatória
  - ★ Quanto menor, melhor, eg:
    - ★ 0.1: 1 em 10 têm pontuação  $\geq$
    - ★  $10^{-6}$ : 1 em 1000000
- Como fazer isso para BLAST?
- Simplificação:
  - ★ Se pontuação 1 para acerto
  - ★  $-\inf$
  - ★ pontuação óptima: maior alinhamento

# Pontuação: Explicação

- Se matriz de alinhamento tem tamanho  $n \times m$ ,
- Alinhamento pode começar  $\approx n \times m$  posições
- Além disso:

★  $p$  probabilidade de 2 letras à sorte serem iguais.

- Probabilidade de alinhamento de tamanho  $t$

$$p^t(1 - p)$$

- Média será:

$$nmp^t(1 - p)$$

- É conhecido que binomial pode ser aproximado por Poisson se  $tp$  e  $p$  pequenos

$$P(seq_t) = 1 - P(\neg seq_t) = 1 - \frac{\lambda^0 e^{-\lambda}}{0!} = 1 - e^{-nmp^t(1-p)}$$

- BLAST:

$$p-value \approx 1 - e^{-nm\gamma\xi^t}$$

# Pontuação: Explicação

- Valor-E:

$$e-value = \gamma nm\xi^t = Knme^{-\lambda S}$$

- Mais intuitivo para matches fracos
  - E-value de 5, P-value de 0.993
  - E-value de 10, P-value de 0.99995
  - Convergem para matches fortes

- Unidades?
- Bit-Score não depende dos parâmetros  $K$  e  $\lambda$

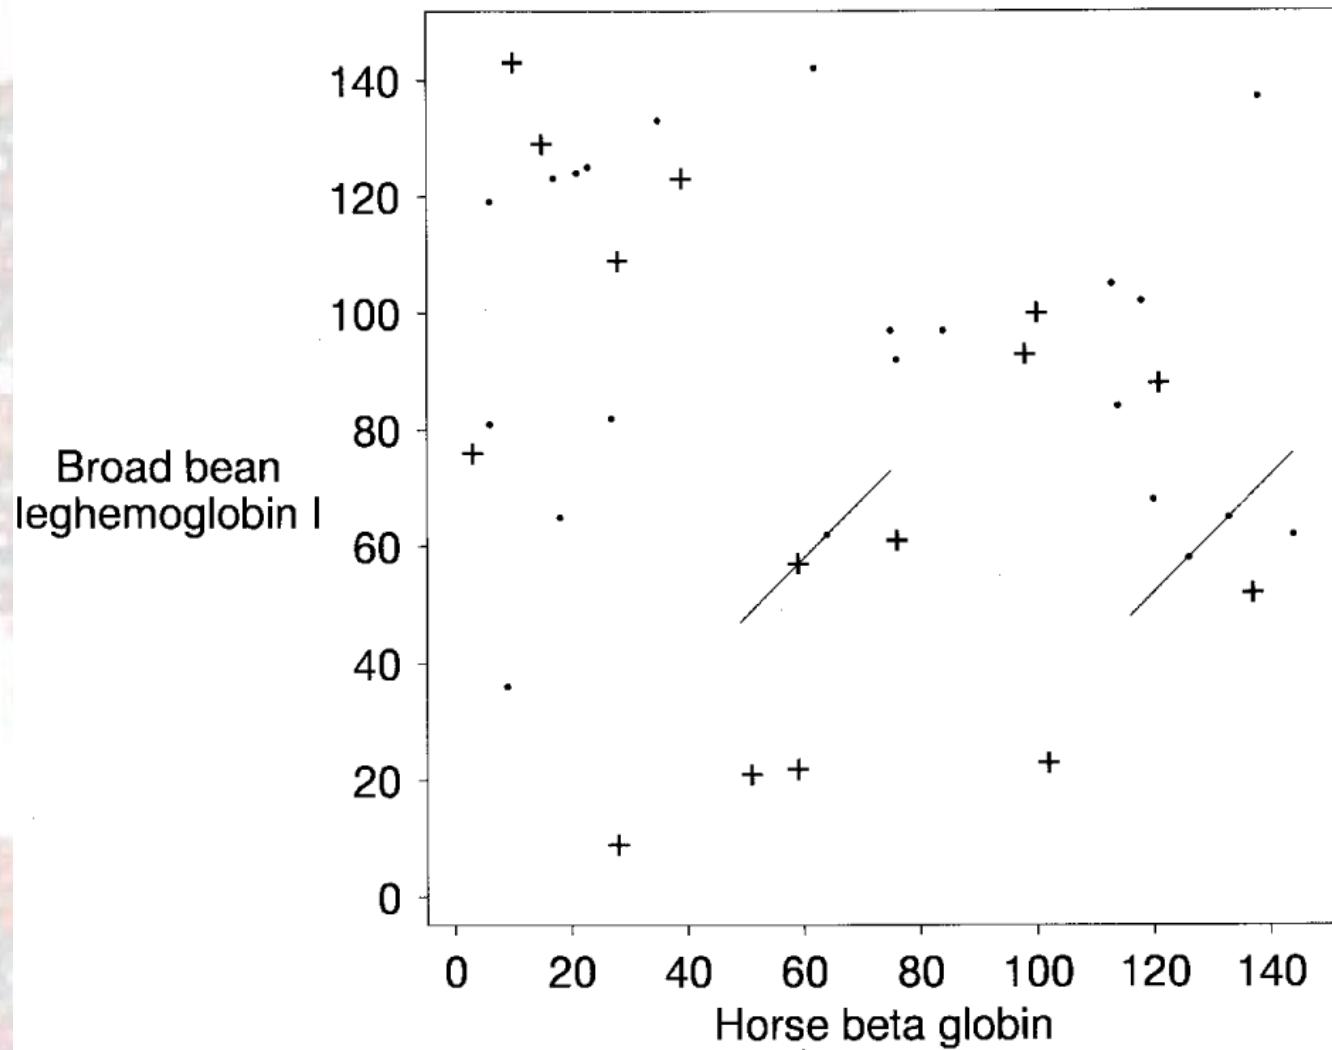
$$S' = \frac{\lambda S - \ln K}{\ln 2}$$

- Para entender significância precisa apenas de  $mn$

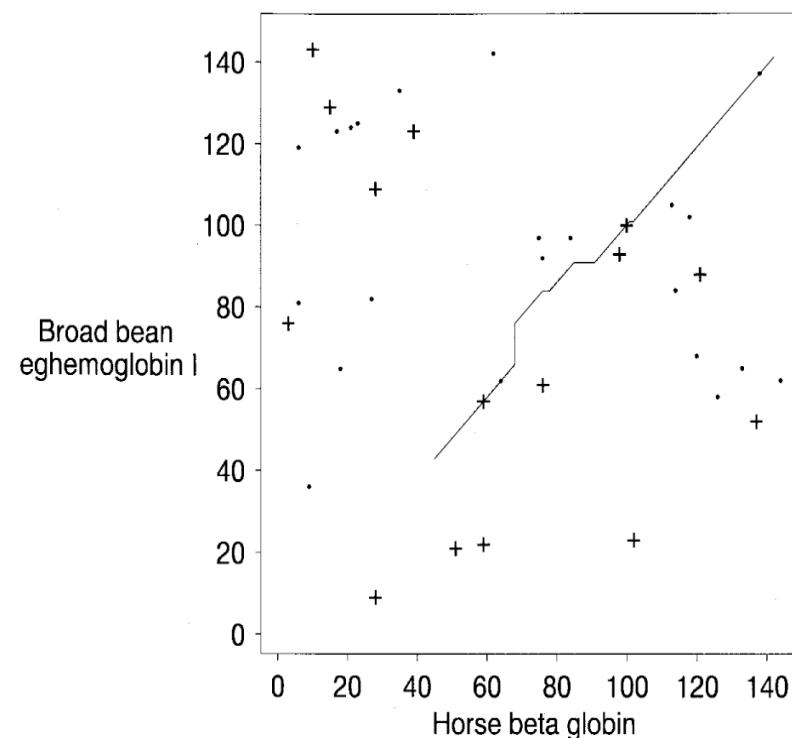
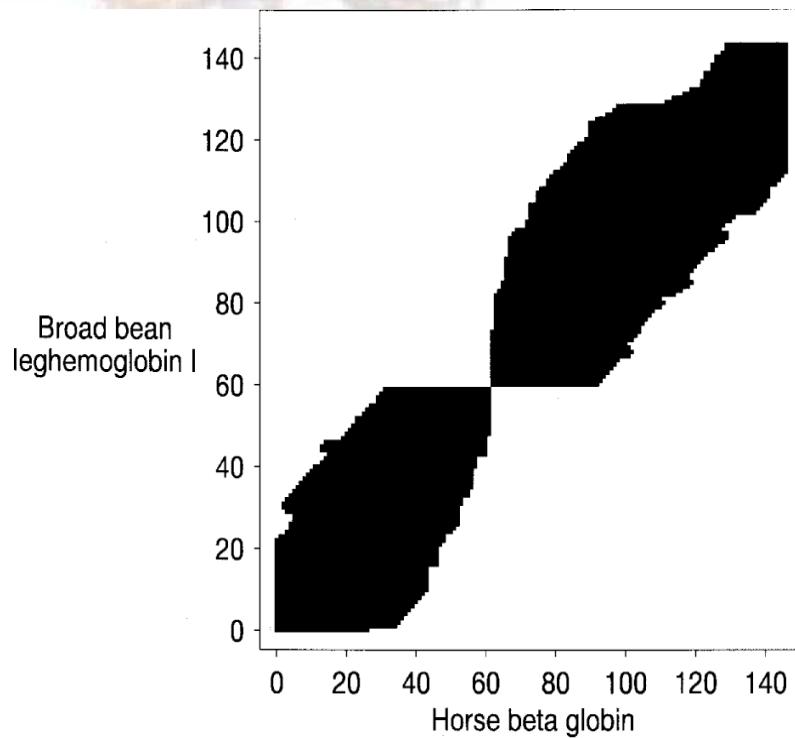
# Extensões de BLAST

- O método *two-hit*: ampliar apenas quando há dois acertos perto e na mesma diagonal
  - ★ permite abaixar  $T$
- BLAST com buracos:
  - ★ usar DP a partir de alinhamento com pontuação melhor
- PSI-BLAST: generalizar iterativamente a questão (fazê-la parecer mais como acertos) e voltar a procurar
- Todas tentam aumentar precisão enquanto limitam o tempo de execução

# Método Two-Hits



# Gapped Blast



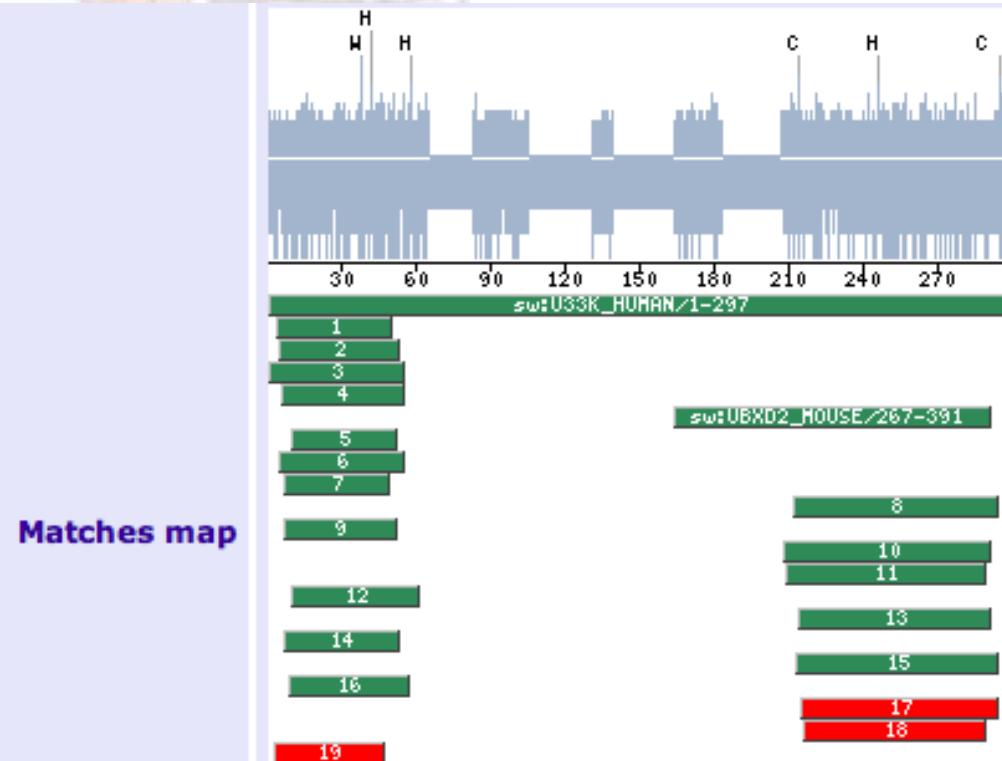
Leghemoglobin 43 FSFLKDSAGVVVDSPKLGAHAEKVFGMVRD SAVQLRATGEVV --LDGKDGS----- 90  
F L + V+ +PK+ AH +KV L + GE V LD G+

Beta globin 45 FGDL SNP GAVMGNPKVKAHGKKV-----LHSFGEGVHLDNLKGTF AALSE 90

Leghemoglobin 91 IHIQKGVLDP-HFVVVK E ALLKTIKEASGDKWSEELSAAWEVAYDGLATAI 140  
+H K +DP F ++ L+ + G ++ EL A+++ G+A A+

Beta globin 91 LHCDKLHVDPENFRLLGNVLVVIARHFGKDFTPELQASYQKV VAGVANAL 141

# Gapped BLAST



**Legends:** 1, sw:UAS3\_DROME/22-68; 2, sw:UBP14\_SCHPO/580-628; 3, sw:UBP5\_MOUSE/654-708; 4, sw:UBP14\_YEAST/612-661; 5, sw:UBP14\_ARATH/622-664; 6, sw:UBP13\_HUMAN/656-706; 7, sw:UBPA\_DICDI/634-676; 8, sw:Y0J8\_CAEEL/281-359; 9, sw:UAS3\_HUMAN/25-70; 10, sw:UBX7\_YEAST/211-290; 11, sw:UBXD1\_HUMAN/332-406; 12, sw:UPL2\_ARATH/1280-1332; 13, sw:UBX6\_YEAST/191-264; 14, sw:UBP14\_SCHPO/645-690; 15, sw:UBXD7\_HUMAN/412-488; 16, sw:UBP5\_MOUSE/730-777; 17, sw:FAF1\_MOUSE/574-648; 18, sw:UBAX1\_ARATH/350-418; 19, sw:UBP13\_HUMAN/731-775.

# Papers sobre extensões do BLAST

- Altschul, S.F., Madden, T.L., et al. (1997) Gapped BLAST and PSI-BLAST: a new generation of protein database search programs. *Nucleic Acids Research*, 25 (17), 3389-3402. <http://www.ncbi.nlm.nih.gov/CBBresearch/Altschul/>
- Zhang, Z., Schwartz, S., Wagner, L. Miller, W. "A greedy algorithm for aligning DNA sequences." *J. Computational Biology* (2000) 7:203-214. <http://bio.cse.psu.edu/~jzhang/>
- Schaffer, A.A., Aravind, L., Madden, T.L., Shavirin, S., Spouge, J.L., Wolf, Y.I., Koonin, E.V., Altschul, S.F. (2001) Nucleic Acids Research, July 15;29(14):2994-3005 Improving the accuracy of  
PSI-BLAST protein database searches with composition-based statistics and other refinements. <http://www.ncbi.nlm.nih.gov/CBBresearch/Altschul/>

# Comentários sobre BLAST

- é uma heurística: pode não encontrar alguns bons resultados
- rápido: empiricamente é de 10 a 50 vezes mais rápido do que Smith-Waterman
- Tem grande impacto:
  - ★ o servidor do NCBI recebe mais de 100.000 interrogações por dia
  - ★ é o programa mais usado em bioinformática

# Parâmetros Default do BLAST

- $M$ : ganho por match de nucleotídeos (5)
- $N$ : perca por mismatch de DNA (-4)
- Buracos: usa afim com 11/1
- Matriz BLOSUM62
- Tamanho de palavra:
  - ★ 11 para nucleotídeos
  - ★ 3 para AAs

# Conclusões

- apresentamos alinhamentos: *locais* e *globais*
- o algoritmo exacto com DP depende de ser local/global e da função da penalização de buracos
- ao permitir buracos permitimos um número exponencial de alinhamentos
- com programação dinâmica a complexidade é  $O(mn)$
- algoritmos funcionam tanto para proteínas como DNA
- heurísticas como BLAST são mais rápidas mas não tão precisas.