

**Instituto de
Computação**

UNIVERSIDADE ESTADUAL DE CAMPINAS



BLAST

MO640 - Biologia Computacional / MC668 - Bioinformática

Zanoni Dias

2021

Instituto de Computação

Banco de Dados de Sequências

BLAST


BLAST 2.0


Banco de Dados de Sequências

- Maior banco público de sequências de nucleotídeos e de proteínas do mundo.
- Fundado por Walter Goad em 1982.
- Desenvolvido pelo National Center for Biotechnology Information (NCBI) e financiado pelo National Institutes of Health (NIH).
- Crescimento do GenBank:
 - *From 1982 to the present, the number of bases in GenBank has doubled approximately every 18 months.*


WGS (Whole Genome Shotgun)


- Com a simplificação, automatização e barateamento do processo de sequenciamento, o número de genomas completamente ou parcialmente sequenciados cresceu muito nas últimas duas décadas.
- Dois importantes marcos da genômica:
 - Nacional: em 2000, sequenciamento da bactéria *Xylella fastidiosa* (2.7Mbp, 3 mil genes), causadora da doença “amarelinho” que afeta laranjeiras.
 - Internacional: em 2001, sequenciamento do genoma humano (3Gbp, 30 mil genes).
- Desde 2002 o GenBank possui uma divisão (WGS - Whole Genome Shotgun) dedicado a montagens completas ou parciais de genomas.
- A proporção de bases e sequências do WGS em relação ao GenBank vem crescendo muito nos últimos anos.





Tamanho Médio das Sequências do GenBank





- UniProt: Universal Protein Resource.
- Consórcio criado em 2002 envolvendo:
 - Swiss-Prot: Swiss Institute of Bioinformatics (SIB) e European Bioinformatics Institute (EBI). Maior banco manualmente curado de proteínas do mundo.
 - TrEMBL: Swiss Institute of Bioinformatics (SIB) e European Molecular Biology Laboratory (EMBL-EBI). Banco de proteínas gerado computacionalmente pela tradução dos dados do EMBL Nucleotide Sequence Database.
 - PIR: Georgetown University Medical Center (GUMC). Conjunto de banco de dados de proteínas criados para auxiliar a análise genômica e proteômica.

Alinhamento de uma sequência contra todas do GenBank

- Exemplo: computador de 3GHz (1 instrução por ciclo)
 - $n = 10$:
 - Tempo: $(10 \times 10^{13}) / (3 \times 2^{30}) = 9$ minutos
 - $n = 100$:
 - Tempo: $(100 \times 10^{13}) / (3 \times 2^{30}) = 4$ dias
 - $n = 1000$:
 - Tempo: $(1000 \times 10^{13}) / (3 \times 2^{30}) = 36$ dias
 - $n = 10000$:
 - Tempo: $(10000 \times 10^{13}) / (3 \times 2^{30}) = 1$ ano
 - $n = 100000$:
 - Tempo: $(100000 \times 10^{13}) / (3 \times 2^{30}) = 1$ década
 - $n = 1000000$:
 - Tempo: $(1000000 \times 10^{13}) / (3 \times 2^{30}) = 1$ século
 - $n = 10000000$:
 - Tempo: $(10000000 \times 10^{13}) / (3 \times 2^{30}) = 1$ milênio

BLAST

- BLAST: Basic Local Alignment Search Tool.
- Ferramenta proposta por Stephen Altschul, Warren Gish, Webb Miller, Eugene Myers e David Lipman em 1990.
- Desenvolvido pelo National Center for Biotechnology Information (NCBI) e financiado pelo National Institutes of Health (NIH).
- Heurística para alinhamento local: não garante a obtenção do alinhamento local ótimo.
- Possui uma forte base estatística.
- Site oficial:
 - <https://blast.ncbi.nlm.nih.gov>
- O artigo original do BLAST foi o artigo mais citado da década de 1990 e hoje em dia possui mais de 95000 citações.

- Nomenclatura:
 - *query*: sequência que será comparada.
 - *database*: banco de sequências.
 - *HSP*: high-scoring sequence pair, par de subsequências com alta similariedade.
 - *seed*: sequência curta utilizada para iniciar um alinhamento.
 - *hit*: alinhamento com similariedade maior que a mínima.
- Passos básicos:
 - Obter uma lista de *seeds* da *query*.
 - Procurar *hits* de *seeds* com as sequências do banco de dados.
 - Estender os *hits* para obter os alinhamentos.

- Remover regiões de baixa complexidade da *query* (regiões com poucos tipos de elementos). Estas regiões são marcadas como subsequências de Xs (para sequências protéicas) e de Ns (para sequências de DNA).
- Construir uma lista de sementes (*seeds*) com todas as sequências de tamanho w que possuam pontuação pelo menos T quando alinhadas com a *query*.
- Geralmente os parâmetros w e T , sob algum esquema de pontuação específico, são ajustado para se obter uma lista de sementes (*seeds*) cerca de 50x maior que o tamanho da *query*.
- Em geral, $w \geq 3$ para proteínas e $w \geq 11$ para sequências de DNA.
- A escolha de uma matriz de pontuação adequada (PAM_{120} , $BLOSUM_{62}$, etc) é fundamental nesta fase.

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R

```
V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R  
V H R E
```

BLAST - Criação da Lista de *Seeds*

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R
V H R E
H R E M

BLAST - Criação da Lista de *Seeds*

```
V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R  
V H R E  
H R E M  
R E M A
```

BLAST - Criação da Lista de *Seeds*

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R

V H R E

H R E M

R E M A

E M A A

M A A R

A A R T

A R T S

R T S P

BLAST - Criação da Lista de *Seeds*

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R

V H R E T S P L
H R E M S P L R
R E M A P L R P
E M A A L R P L
M A A R R P L V
A A R T P L V A
A R T S L V A T
R T S P V A T A

BLAST - Criação da Lista de *Seeds*

```
V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R
V H R E           T S P L           A T A G
H R E M           S P L R           T A G P
R E M A           P L R R P         A G P A
E M A A           L R P L           G P A L
M A A R           R P L V           P A L S
A A R T           P L V A           A L S P
A R T S           L V A T           L S P V
R T S P           V A T A           S P V P
```

BLAST - Criação da Lista de *Seeds*

```
V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R
V H R E           T S P L           A T A G           P V P P
H R E M           S P L R           T A G P           V P P C
R E M A           P L R R P           A G P A           P P C V
E M A A           L R P L           G P A L           P C V H
M A A R           R P L V           P A L S           C V H L
A A R T           P L V A           A L S P           V H L T
A R T S           L V A T           L S P V           H L T L
R T S P           V A T A           S P V P           L T L R
```

BLAST - Criação da Lista de *Seeds*

```
V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R
V H R E           T S P L           A T A G           P V P P
H R E M           S P L R           T A G P           V P P C
R E M A           P L R R P           A G P A           P P C V
E M A A           L R R P L           G P A L           P C V H
M A A R           R P L V           P A L S           C V H L
A A R T           P L V A           A L S P           V H L T
A R T S           L V A T           L S P V           H L T L
R T S P           V A T A           S P V P           L T L R
```

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R
E M A A = 18

BLAST - Criação da Lista de *Seeds*

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R

E M A A = 18

A A A C = 6

BLAST - Criação da Lista de *Seeds*

V H R **E M A A** R T S P L R P L V A T A G P A L S P V P P C V H L T L R

E M A A = 18

A A A C = 6

A A A D = 3

BLAST - Criação da Lista de *Seeds*

V H R E M A A R T S P L R P L V A T A G P A L S P V P P C V H L T L R

E M A A = 18

A A A C = 6

A A A D = 3

• • •

E H A I = 14

E H A K = 9

• • •

Y Y Y Y = -15

BLAST - Criação da Lista de *Seeds*

V H R **E M A A** R T S P L R P L V A T A G P A L S P V P P C V H L T L R

E M A A = 18

A A A C = 6

A A A D = 3

• • •

E H A I = 14

E H A K = 9

• • •

Y Y Y Y = -15

Seeds:

($T \geq 11$)

BLAST - Criação da Lista de *Seeds*

V H R **E M A A** R T S P L R P L V A T A G P A L S P V P P C V H L T L R

E M A A = 18

A A A C = 6

A A A D = 3

• • •

E H A I = 14

E H A K = 9

• • •

Y Y Y Y = -15

Seeds:

($T \geq 11$)

• • •

E M A A

E H A I


• • •

BLAST - Busca por *Hits*


- Duas opções de busca:
 - Para cada *seed*, buscar *hits* em cada uma das sequências do banco de dados.
 - Para cada sequência do banco de dados, buscar *hits* com cada uma das *seeds*.
- Duas opções de estrutura de dados para auxiliar a busca:
 - Construção de um vetor, onde cada posição representa uma sequência protéica de tamanho w . A i -ésima posição do vetor armazena uma lista de todas ocorrências de *hits* da i -ésima sequência na *query*.
 - Poucas posições deste vetor armazenam informações úteis.
 - Alternativa: armazenar as informações num *hash*.
 - Construção de uma máquina de estados, usando autômatos finitos, onde cada estado representa a última palavra lida, e as transições de estados ocorrem a cada leitura de uma nova base da sequência do banco onde se está buscado por *hits*.
- Geralmente usa-se autômatos finitos para buscar todos as *seeds* em cada uma das sequência do banco (uma por uma).

BLAST - Obtenção dos HSPs


- Estende-se o *hit* em ambas as direções, apenas considerando alinhamento sem buracos.
- A extensão é interrompida após se distanciar muito do melhor alinhamento obtido até então.
- Por exemplo, para proteínas, o valor da distância máxima é 20. Este valor garante que a probabilidade deste método perder um alinhamento de maior pontuação é de cerca de 0,1%.
- Apenas HSPs com pontuação maior ou igual a um limiar S são apresentados como respostas.
- Estima-se que 90% do tempo de processamento é gasto nesta etapa.
- A performance do algoritmo nesta fase está intimamente relacionada a escolha dos parâmetros w e T .
 - Quanto maior for o valor de w , maior o número de *seeds* a se considerar.
 - Quanto maior for o valor de T , mais restrita será a busca por HSPs.




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs



BLAST - Obtenção dos HSPs



BLAST - Obtenção dos HSPs



BLAST - Obtenção dos HSPs

score = 12

Query

• • •

V H R E M A A R T S P L R P • • •


-2 -2 2

• • •


Seq DB

K W K E H A I Q A D P I A S • • •


BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs



BLAST - Obtenção dos HSPs




BLAST - Obtenção dos HSPs



BLAST - Obtenção dos HSPs

		score = 24																
Query	• • •	V	H	R	E	M	A	A	R	T	S	P	L	R	P	•	•	•
				2					1	0	0	7	2	-1	-1			
Seq DB	• • •	K	W	K	E	H	A	I	Q	A	D	P	I	A	S	•	•	•

BLAST - Obtenção dos HSPs




BLAST 2.0

- Extensão apresentada por Stephen Altschul, Thomas Madden, Alejandro Schaeffer, Jinghui Zhang, Zheng Zhang, Webb Miller e David Lipman em 1997.
- Duas principais inovações:
 - The Two-Hit Method
 - Gapped BLAST
- O artigo que introduziu a segunda versão do BLAST é um dos artigos mais citados do mundo, com mais de 80000 citações.


BLAST 2.0 - The Two-Hit Method

- Objetivo: acelerar o tempo de processamento do algoritmo original.
- Reduz o número de extensões.
- Observação: *HSPs* são muito maiores que w .
- Um *HSP* frequentemente contém dois ou mais *hits*.
- Apenas procurar um *HSP* se existirem dois *hits* na mesma diagonal.
- Como implementar:
 - Se os *hits* se sobrepõe, ignorar.
 - Se os *hits* estiverem a uma distância menor do que um certo valor A , estender.
- O valor de T deve ser reduzido para se manter a mesma sensibilidade.


BLAST 2.0 - The Two-Hit Method



BLAST 2.0 - The Two-Hit Method




BLAST 2.0 - The Two-Hit Method



- Métodos para extensão de hits (valores padrão para proteínas):
 - *One-Hit*: $w = 3$ e $T = 13$.
 - *Two-Hits*: $w = 3$ e $T = 11$.
- Comparação entre os métodos:
 - *Two-Hits* gera aproximadamente 3.2x mais *hits*.
 - *Two-Hits* faz aproximadamente 86% menos extensões.

- Extensões de *hits* não são mais limitados a diagonais da matriz de Programação Dinâmica, permitindo alinhamento com buracos.
- A extensão é interrompida quando o alinhamento cai abaixo de um limiar pré-estabelecido (X_G).
- Se a pontuação do *HSP* for maior que um parâmetro S , então o *HSP* é apresentado na lista de respostas.
- O BLAST 2.0 é cerca 3x mais rápido do que a versão original.

BLAST 2.0 - Gapped BLAST



Complexidade

- Seja w o tamanho dos *seeds*, \mathcal{A} o alfabeto ($|\mathcal{A}| = 4$ para DNA, $|\mathcal{A}| = 20$ para proteínas), M o tamanho do banco de dados (número total de bases), h o número de *hits* encontrados e n o tamanho da *query*.
- Fase 1: Obter uma lista de *seeds*:
 - $O(nw|\mathcal{A}|^w)$
- Fase 2: Procurar *hits* de *seeds* nas sequências do banco de dados:
 - $O(M)$
- Fase 3: Estender os *hits* para obter os alinhamentos (*HSPs*):
 - $O(hn^2)$
- Total:
 - $O(nw|\mathcal{A}|^w + M + hn^2)$

- Com base no valor do alinhamento (S), BLAST indica para cada HSP retornado um *bit score* e um *E-value*.
- O *bit score* (S') representa a pontuação normalizada do alinhamento, e é dada pela fórmula:

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

- O *E-value* representa o número esperado de HSPs com score maior ou igual a S , e é dado pela fórmula:

$$E = \frac{KMn}{e^{\lambda S}}$$

- As constantes λ e K são calculadas considerando a matriz de pontuação e a distribuição das bases no banco de dados.

- Não confundir E-value com P-value:
 - E-Value: número esperado de alinhamentos aleatórios com pontuação maior ou igual a S.
 - P-Value: probabilidade de se obter aleatoriamente um alinhamento com uma pontuação maior ou igual a S.
- E-value pode ser um número maior que 1, enquanto o P-value é sempre um valor entre 0 e 1.
- Dado um E-value é possível obter o P-value (e vice-versa) através da seguinte fórmula:

$$P = 1 - e^{-E}$$

- O BLAST é composto por uma família de programas, todos acessíveis através do executável *blastall*:
 - *blastn*: [*query*: DNA] x [*database*: DNA].
 - *blastp*: [*query*: proteína] x [*database*: proteína].
 - *blastx*: [*query*: DNA] x [*database*: proteína] (nos 6 frames da *query*).
 - *tblastx*: [*query*: DNA] x [*database*: DNA] (nos 6 frames da *query* e de cada sequência do banco de dados).
 - *tblastn*: [*query*: proteína] x [*database*: DNA] (nos 6 frames de cada sequência do banco de dados).
 - *megablast*: ideal para comparar várias sequências contra um banco de sequências. Concatena todas as sequências de entrada em uma única, e depois faz um pós-processamento para obter os alinhamentos corretos.