

# Stupeň podobnosti dvou sekvencí

SEKVENCE A: MASAQSFYLL

SEKVENCE B: MASGQWLLAS

Které oblasti A a B jsou si nejvíce podobné ?

Jsou si A a B víc podobné než A a C ?

Která ze sekvencí  $x_1, \dots, x_n$  je nejpodobnější A ?

Jaká je pravděpodobnost výskytu dané podobnosti v náhodné sekvenci ?

Existují už publikované homology sekvence A ?

Jaká je funkce A ?

# Stupeň podobnosti dvou sekvencí

## IDENTITA

MASAQSFYLL

||||||| | | |

MASAQSFYLL

## SUBSTITUCE

MASAQSFYLL

||||| : | | |

MASAQS-WYLL

MASAQSFYLL

||||| | | |

MASAQS-TYLL

## INZERCE/DELECE

MASAQSFYLL

||||| | | |

MASAQS-YLL

## TRANSPOZICE

MASAQSFYLL

||||| | | |

MASAQFSYLL

# Stupeň podobnosti dvou sekvencí

Netriviální hodnocení substitucí  
u proteinů  
(matrice PAM250)

<b>A</b>	2																								
<b>R</b>	-2	6																							
<b>N</b>	0	0	2																						
<b>D</b>	0	-1	2	4																					
<b>C</b>	-2	-4	-4	-5	12																				
<b>Q</b>	0	1	1	2	-5	4																			
<b>E</b>	0	-1	1	3	-5	2	4																		
<b>G</b>	1	-3	0	1	-3	-1	0	5																	
<b>H</b>	-1	2	2	1	-3	3	1	-2	6																
<b>I</b>	-1	-2	-2	-2	-2	-2	-2	-3	-2	5															
<b>L</b>	-2	-3	-3	-4	-6	-2	-3	-4	-2	-2	6														
<b>K</b>	-1	3	1	0	-5	1	0	-2	0	-2	-3	5													
<b>M</b>	-1	0	-2	-3	-5	-1	-2	-3	-2	2	4	0	6												
<b>F</b>	-3	-4	-3	-6	-4	-5	-5	-5	-2	1	2	-5	0	9											
<b>P</b>	1	0	0	-1	-3	0	-1	0	0	-2	-3	-1	-2	-5	6										
<b>S</b>	1	0	1	0	0	-1	0	1	-1	-1	-3	0	-2	-3	1	2									
<b>T</b>	1	-1	0	0	-2	-1	0	0	-1	0	-2	0	-1	-3	0	1	3								
<b>W</b>	-6	2	-4	-7	-8	-5	-7	-7	-3	-5	-2	-3	-4	0	-6	-2	-5	17							
<b>Y</b>	-3	-4	-2	-4	0	-4	-4	-5	0	-1	-1	-4	-2	7	-5	-3	-3	0	10						
<b>V</b>	0	-2	-2	-2	-2	-2	-2	-1	-2	4	2	-2	2	-1	-1	-1	0	-6	-2	4					
	<b>A</b>	<b>R</b>	<b>N</b>	<b>D</b>	<b>C</b>	<b>Q</b>	<b>E</b>	<b>G</b>	<b>H</b>	<b>I</b>	<b>L</b>	<b>K</b>	<b>M</b>	<b>F</b>	<b>P</b>	<b>S</b>	<b>T</b>	<b>W</b>	<b>Y</b>	<b>V</b>					

# Stupeň podobnosti dvou sekvencí

	A	G	A	T	A	
0	-2	-4	-6	-8	-10	
A	-2	2	0	-2	-3	-5
G	-4	-1	?			
T	-6					
C	-8					
A	-10					

INDEL=-2 IDENT=2 SUBST=-1

AGATA  
|| | S=4  
AGTCA

# **BLAST (basic local alignment search tool)**

Co když jsou sekvence dlouhé a máme jich několik milionů ?

DP nestačí, výpočty trvají příliš dlouho. Alternativou výpočtu by byl předpočítaný soubor výskytu různých slov v databázi (index). Problémem indexu je, že je pro dlouhá slova nezvladatelný objemově. Existuje např.

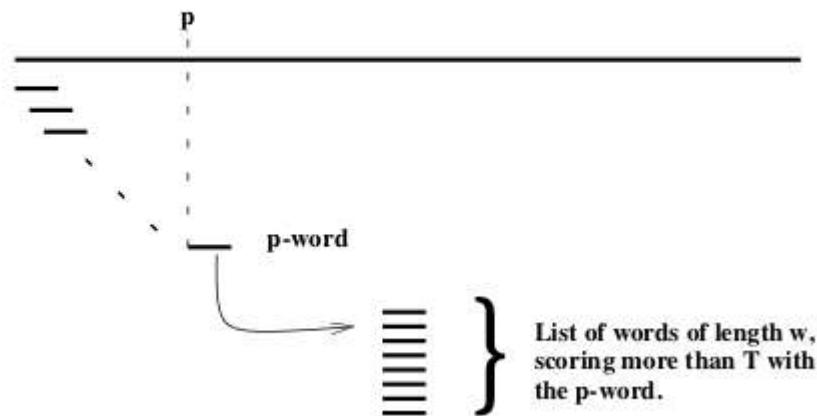
$$20^8 = 25\ 600\ 000\ 000$$

různých uspořádání osmi aminokyselin v řetězci, několik způsobů hodnocení podobnosti atd.

Kompromisem je heuristické řešení. Nalezení tzv. “seeds”, výskytu krátkých řetězců a hledání podobnosti DP algoritmem jenom v jejich blízkosti.

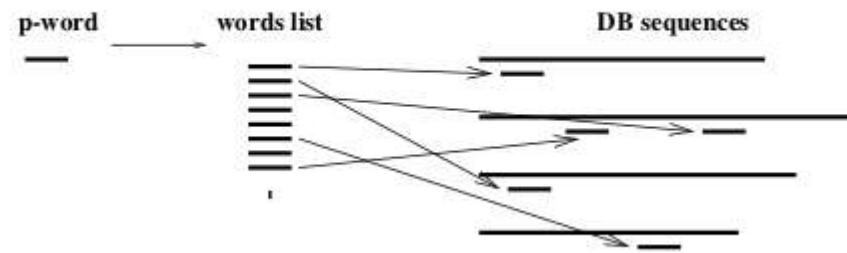
# BLAST (basic local alignment search tool)

A: For each position  $p$  of the query, find the list of words of length  $w$  scoring more than  $T$  when paired with the word starting at  $p$ :



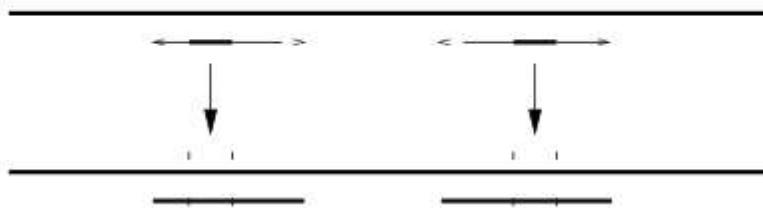
# BLAST (basic local alignment search tool)

**B: For each words list, identify all exact matches with DB sequences:**

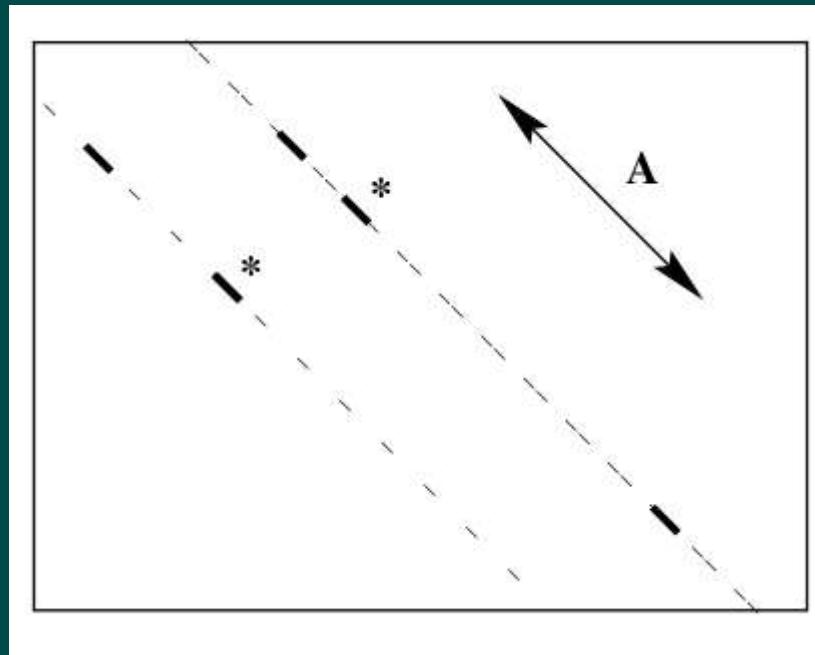


# BLAST (basic local alignment search tool)

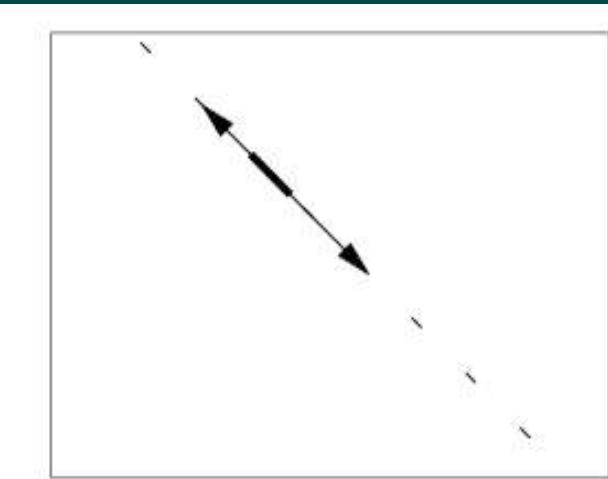
C: For each word match («hit»), extend ungapped alignment in both directions. Stop when S decreases by more than X from the highest value reached by S.



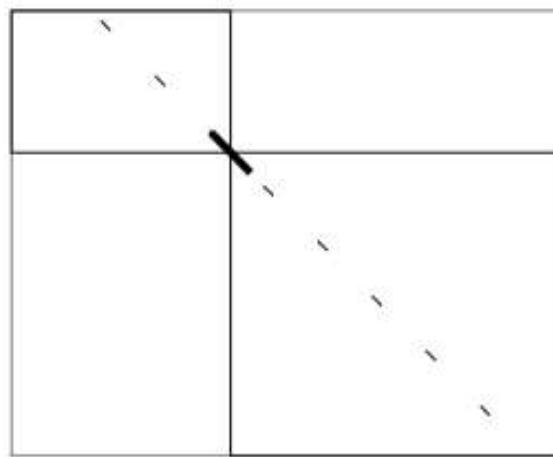
# BLAST (basic local alignment search tool)



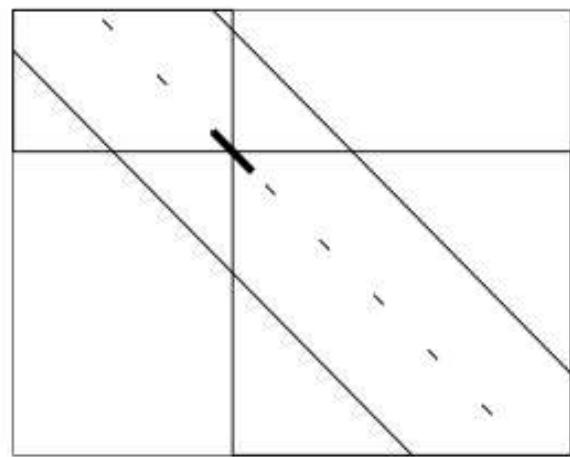
# BLAST (basic local alignment search tool)



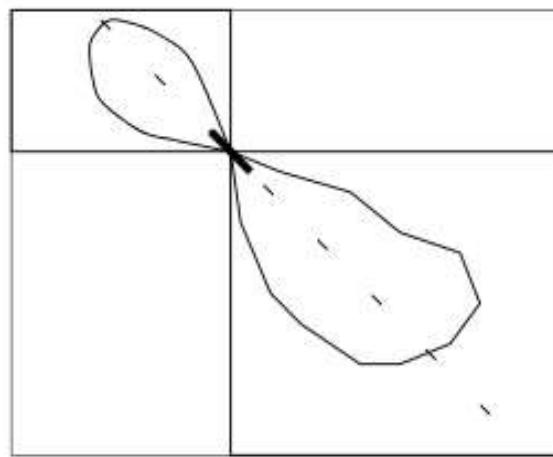
Ungapped extension



Gapped extension by full DP

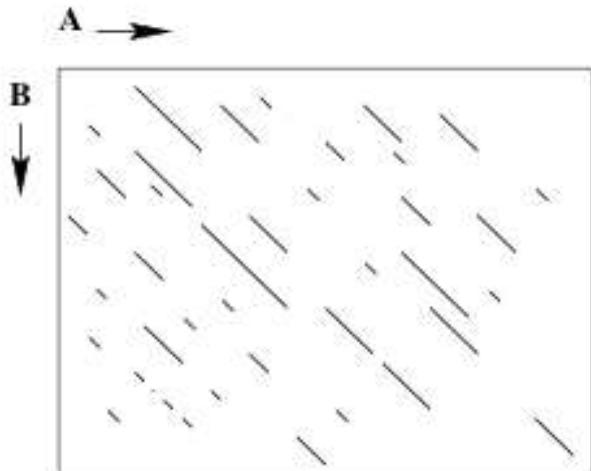


Gapped extension by «banded DP»

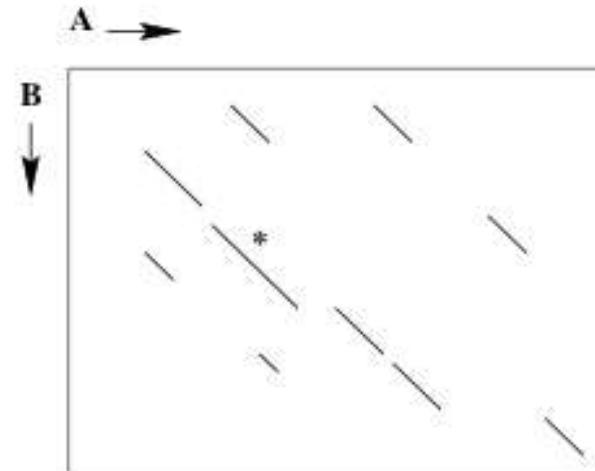


Gapped extension by «score-limited DP»

# FASTA

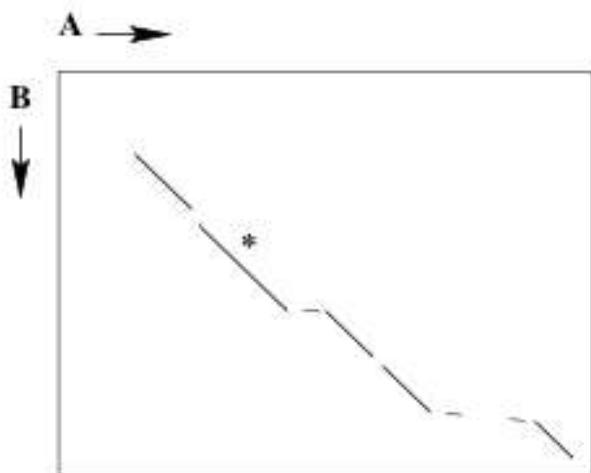


Identify all k-tuple matches



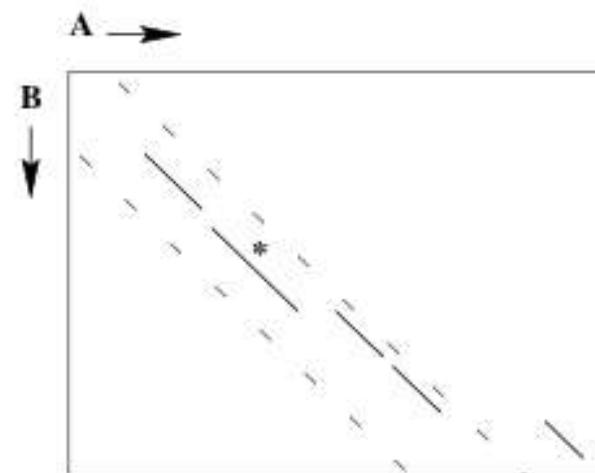
Re-score the 10 best scoring regions  
using a scoring matrix

→ Init1 score



Apply joining procedure

→ Initn score



Apply limited DP

→ Opt score

# BLAST (basic local alignment search tool)

P-VALUE . . .  $P(score > S)$

PRAVDĚPODOBNOST VÝSKYTU PODOBNOSTI VĚTŠÍ  
NEŽ  $S$  V NÁHODNÝCH SEKVENCÍCH URČITÉ DÉLKY

$$P(MSP(M, N) > S) = 1 - \exp(-K_{mn} \cdot \exp(-\lambda \cdot S))$$

E-VALUE

OČEKÁVANÝ POČET PODOBNOSTÍ KDE  $score > S$

$$K_{mn} \cdot \exp(-\lambda \cdot S)$$

# **BLAST (basic local alignment search tool)**

## **PAM150**

Percent Accepted Mutations

Substituční matice odvozena z předpokladu 150 mutací na 100 pozic sekvence

## **BLOSUM65**

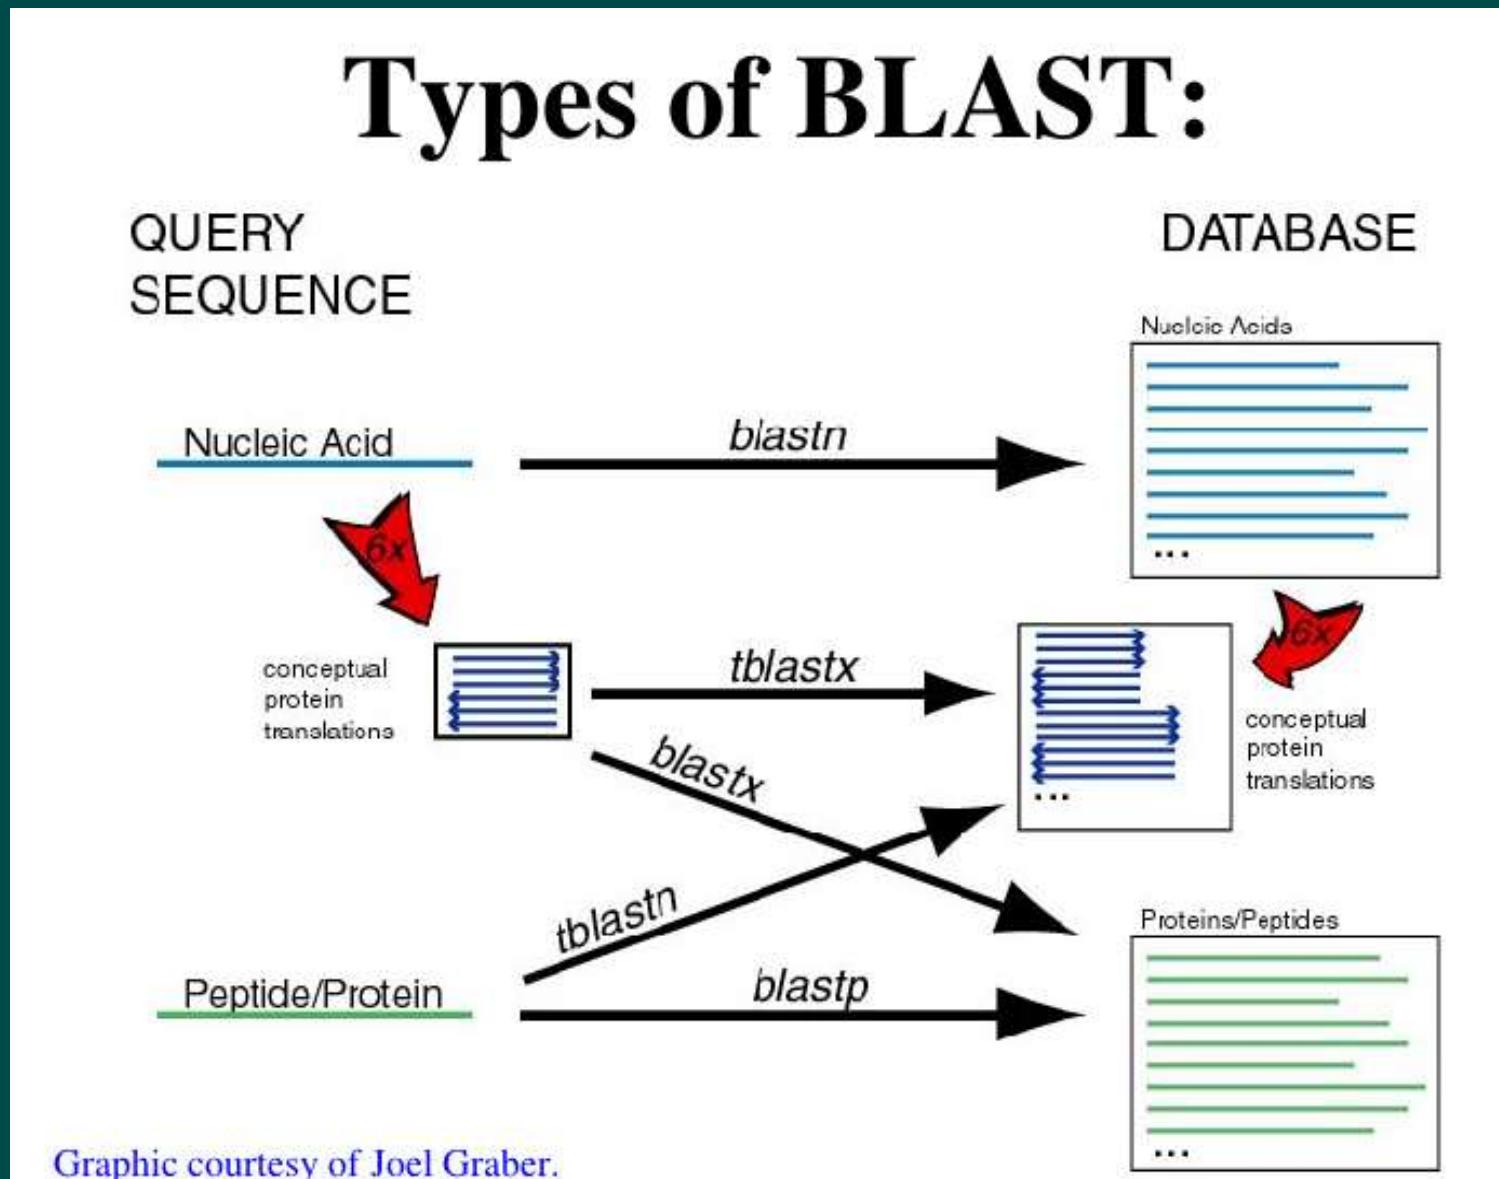
BLOCK SUbstitution Matrix

Substituční matice odvozena ze sekvencí se 65% identitou

PAM120 <=> BLOSUM80

PAM250 <=> BLOSUM45

# BLAST (basic local alignment search tool)



# BLAST (basic local alignment search tool)

```
>gi|50757596|ref|XP_425354.1|similar to protein kinase  
Length = 613
```

```
Score = 50.4 bits (119), Expect(2) = 2e-17  
Identities = 26/54 (48%), Positives = 36/54 (66%), Gaps = 1/54 (1%)
```

```
Query: 740 YVMVLEYANEGNLREYLEK-KFDTLQWENKIQMALDITRGLLCLHSRNIIHRDL 582  
Y +V EY +EG+LR YL K + +L + I ALDI RG+ +HS+ +IHRDL
```

```
Sbjct: 250 YCVVTEYLSEGSLRAYLHKLERKSLPLQKLIAFALDIARGMEYIHSQGVIHRDL 303
```

# **BLAST (basic local alignment search tool)**

BLAST (NCBI-BLAST WU-BLAST)

BLASTN BLASTP BLASTX TBLASTN TBLASTX

MEGABLAST

PSI-BLAST

PHI-BLAST

SNPBLAST

BLASTZ

# **BLAST (basic local alignment search tool)**

BLAT

SESAM

PATTERN\_HUNTER

PSST

PRIMEX

