

# IV107 Bioinformatika I

## Přednáška 4

Katedra informačních technologií  
Masarykova Univerzita Brno

Jaro 2023



# Před týdnem

Existují techniky pro manipulaci, modifikaci, kopírování a detekci DNA, RNA a proteinů.

- ▶ rekombinace a klonování DNA
- ▶ PCR
- ▶ hybridizace DNA a RNA
- ▶ měření aktivity proteinů
- ▶ DNA čipy, microarray, proteinové čipy
- ▶ zjišťování sekvence



# Outline

## Anotace sekvence a genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Bioinformatické databázy



# Sekvence DNA

```
>P12345 Yeast chromosome1  
GATTACAGATTACAGATTACAGATTACAGATTACAG  
ATTACAGATTACAGATTACAGATTACAGATTACAGA  
TTACAGATTACAGATTACAGATTACAGATTACAGAT  
TACAGATTAGAGATTACAGATTACAGATTACAGATT  
ACAGATTACAGATTACAGATTACAGATTACAGATTA  
CAGATTACAGATTACAGATTACAGATTACAGATTAC  
AGATTACAGATTACAGATTACAGATTACAGATTACA  
GATTACAGATTACAGATTACAGATTACAGATTACAG  
ATTACAGATTACAGATTACAGATTACAGATTACAGA  
TTACAGATTACAGATTACAGATTACAGATTACAGAT
```



# Anotovaná sekvence DNA

>P12345 Gen1 - protein alkoholdehydrogenáza

TATA TATAAA  
CGATTGACGATGACGAT

start ATG

exon1 TACAGATTACAGATTACAGATTAAGATGT

intron1 CAGATTACAGATTACAGATTACACAGATTCA

exon2 AGATTACAGATTACAGATTACAGA

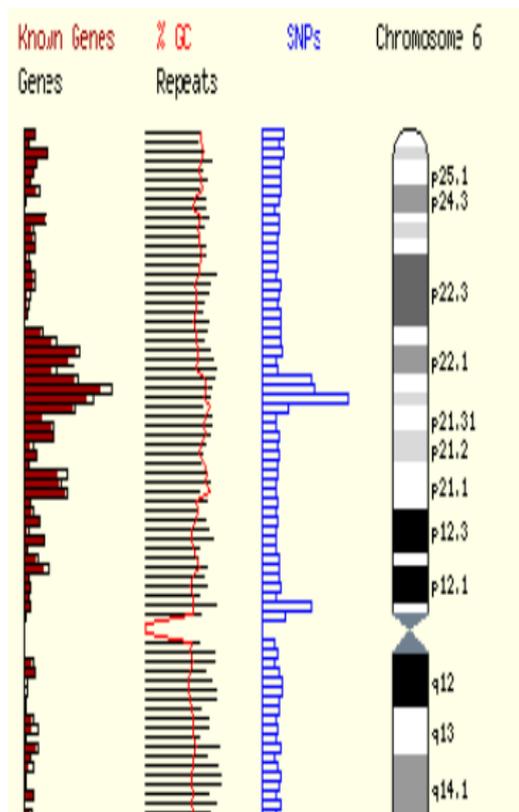
stop TAA

>P12346 Protein1

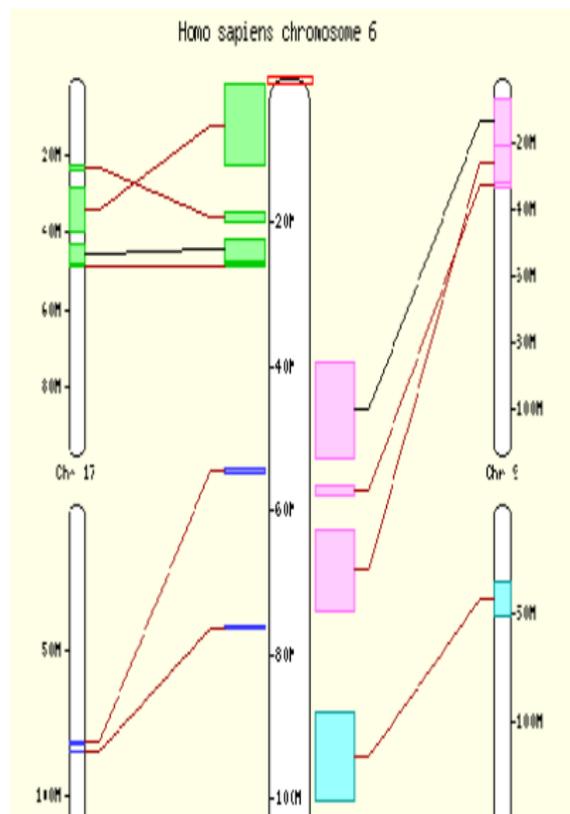
MASAQSFYLLDHNQNQNFDDHLAVDIVMILSHERFMN



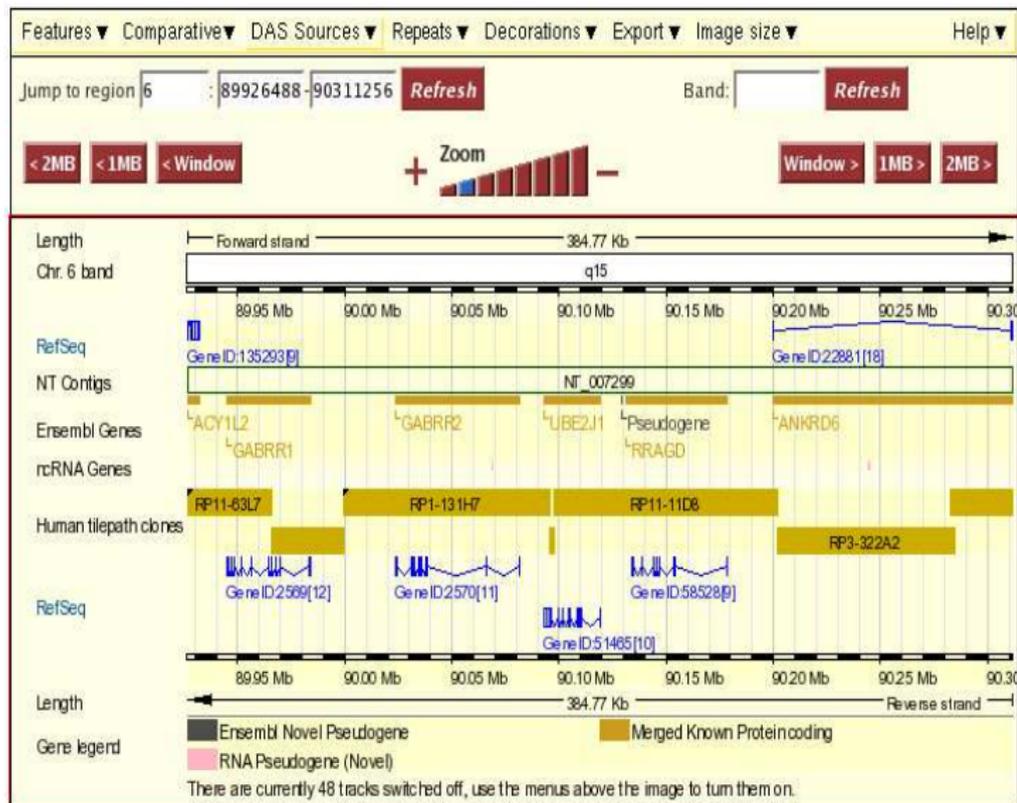
# Anotace genomu



# Anotace genomu



# Anotace genomu <http://www.ensembl.org/>



# Způsoby identifikace genů in silico

- ▶ Experimentální metody (RNA-seq, dřív sekvenace cDNA/EST)
- ▶ Komparativní metody
  - ▶ Selekční tlak
  - ▶ Druh zachovaných mutací
- ▶ Strukturní metody (GeneMark, GeneScan, GeneID)
- ▶ Detekce charakteristických signálů

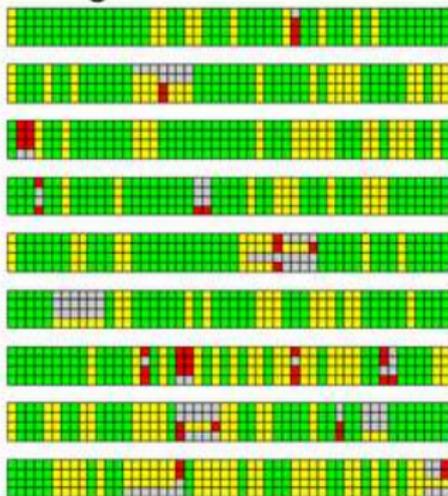


# Identifikace genů podle charakteru mutací

Gene



Intergenic



 Conserved  Mutation  Gap  Frameshift

# Využití známé struktury genů

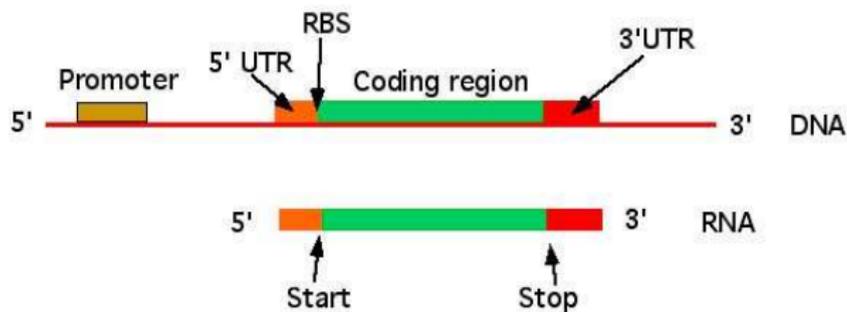
- ▶ intergenová DNA
- ▶ geny
  - ▶ kódující protein
    - ▶ statistika sekvence
    - ▶ ORF
    - ▶ exon/intron (u eukaryotů)
    - ▶ promotor
  - ▶ RNA geny (rRNA, tRNA, jiné)



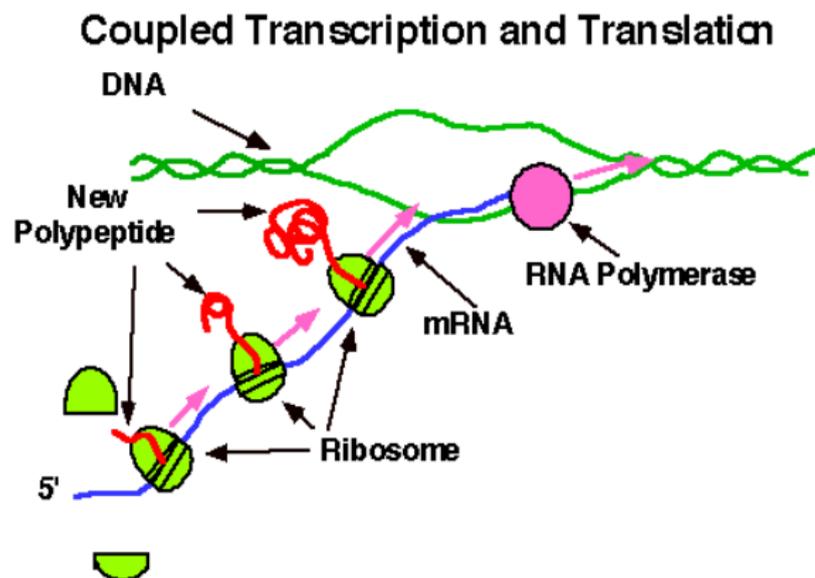
U prokaryotů 95-100% spolehlivost, u složitějších eukaryotů 90% na úrovni bazí, 70% na úrovni exonů/intronů

- ▶ existence intronů
- ▶ větší genomy
- ▶ nízká hustota genů (<30%; 3% u Homo sapiens)
- ▶ alternativní splicing (zhruba u poloviny genů)
- ▶ velké množství repetitivních sekvenčí
- ▶ občasný překryv genů

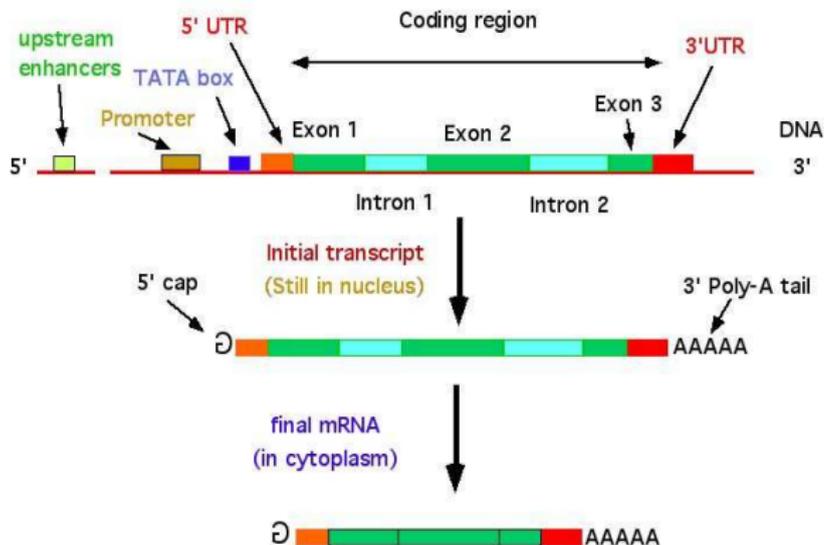
# Struktura genu (prokaryotická)



# Vztah transkripce a translace u prokaryotů



# Struktura genu (eukaryotická)

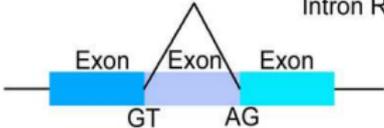


# Typické sekvence v eukaryotických genech

- ▶ Enhancer
- ▶ Promotor
  - ▶ vazební místo transkripčního faktoru (aktivátor, represor)
  - ▶ TATA-box
- ▶ 5'-UTR
  - ▶ Začátek transkripce
- ▶ Kódující oblast
  - ▶ Začátek translace (často ATG)
  - ▶ exony
  - ▶ introny
    - ▶ donor (ag/GTaatg)
    - ▶ akceptor (cAG/gt)
    - ▶ lariat (CU[AG]A[CU])
  - ▶ terminátor translace (stop kodon = UAG—UAA—UGA)
- ▶ 3'-UTR
  - ▶ polyadenylační signál (AATAAA)
  - ▶ terminátor transkripce

# Sestřih mRNA

## Intron Retention (IR)



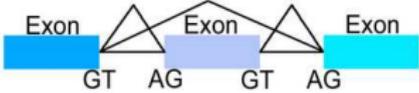
Form 1



Form 2



## Cassette Exon (CE)



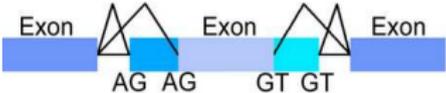
Form 1



Form 2



## Multiple Splice Sites (MS)



Form 1



Form 2



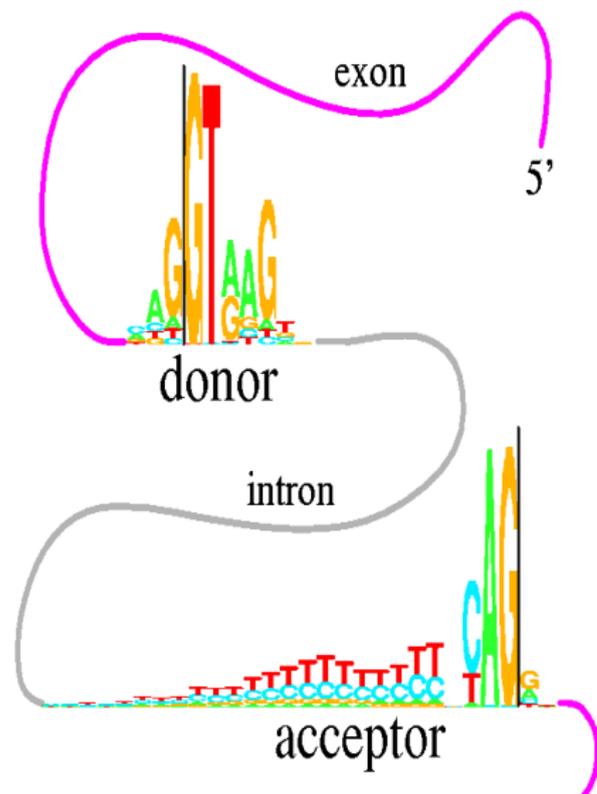
Form 3



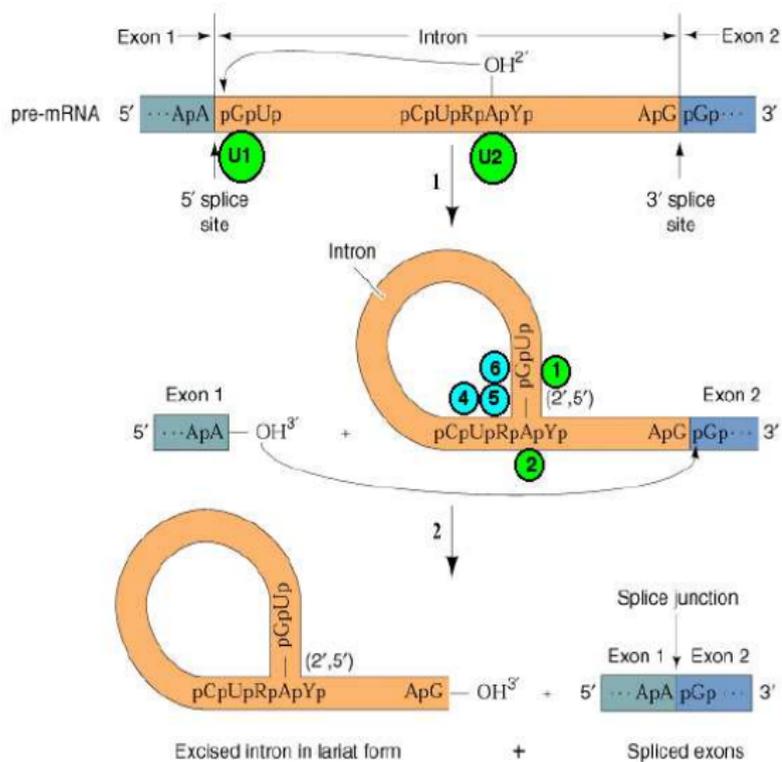
Form 4



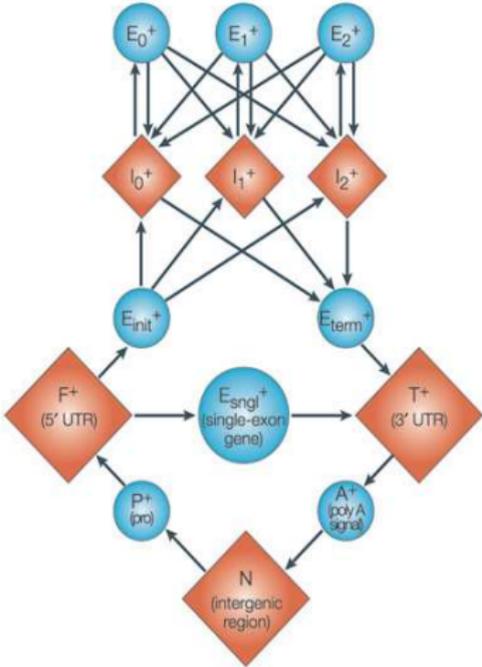
# Sekvenční logo intronu



# detaily sestřihu



# Identifikace genů podle struktury



Reverse strand: mirror reflection of above

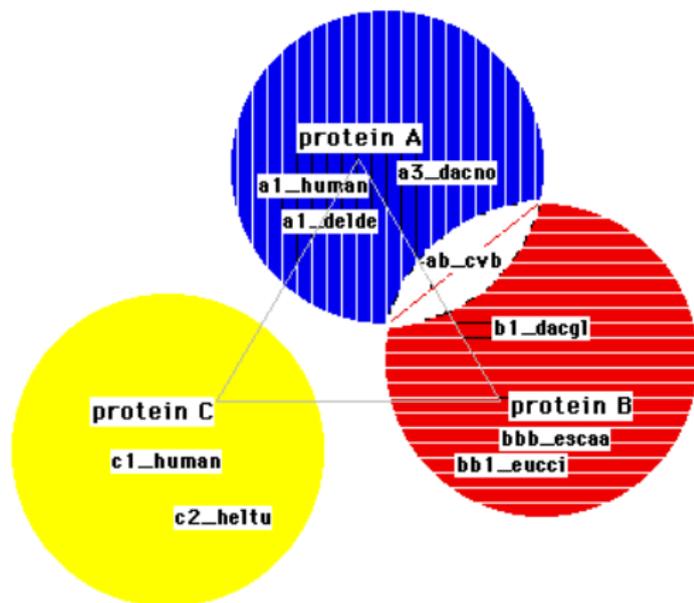


# Příbuzné geny mají podobnou funkci i sekvenci

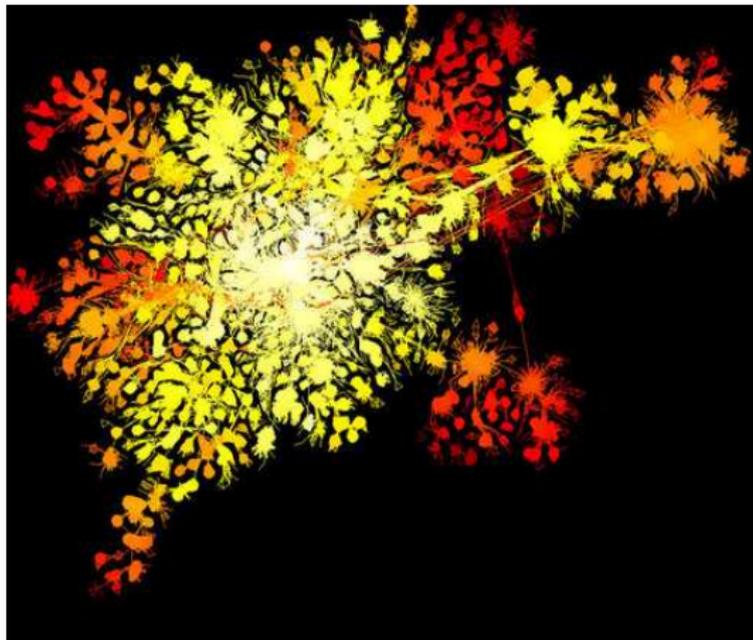
Burkhardt Rost studoval proteiny s různou sekvenční podobností. Zjistil, že když je víc než 30% aminokyselin identických, proteiny mají často velmi podobnou strukturu.



# Příbuzné geny mají podobnou funkci i sekvenci

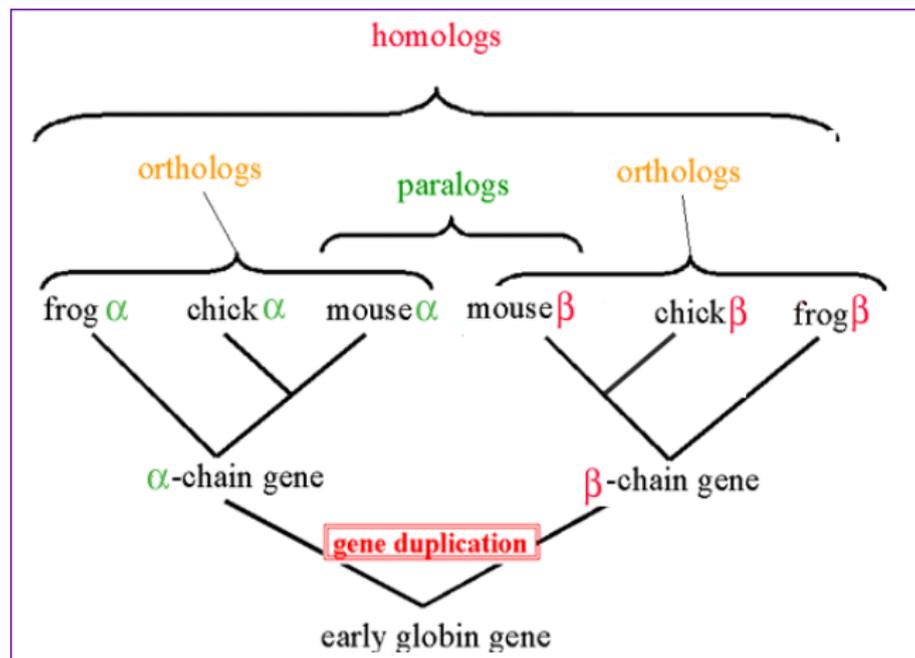


## Příbuzné geny mají podobnou funkci i sekvenci



Proteiny přepojené podle sekvencní podobnosti. Každý z 30727 vrcholů reprezentuje protein, každá z 1,206,654 hran podobnost. Seed Magazine, Červenec 2006

# homologie



# Příbuznost a podobnost sekvencí

- ▶ Homologie  
buď je nebo není
- ▶ Podobnost  
lze kvantifikovat a stupňovat

Od určitého stupně podobnosti je homologii velmi pravděpodobná. U proteinových sekvencí od cca. 30% identity.



# Podobnost sekvencí

- ▶ bez zarovnání (přiložení)
  - ▶ např obsah n-gramů
- ▶ se zarovnáním (přiložením)
  - ▶ stejná délka, pozice si odpovídají
  - ▶ libovolná délka, pozice přiřazujeme



# Rozdíl mezi lokálním a globálním porovnáváním

## (A) local

PI3-kinase DRHNSNIMVKDDGQLFHI DFG

cAMP PK DLKPENLLIDQQGYIQVT DFG

## (B) global

```
PI3-kinase 10 20 30 40 50
           HQLGNLR--LEECRI---MSSAKRPLWLNWENPDIMSELFQNNEIFKNGDDLRRQDMLT
cAMP PK    GNAAAAKKGXEQESVKEFLAKAKEDFLKKWENPAQNTAHLDQFERIKTLGTGSFGRVML-
```

```
PI3-kinase 60 70 80 90 100 110
           LQIIRIME--NIWQNGLDLRMLPYGCLSIGDCVGLIEVVRNSHTIMQ-IQCKGGLK GAL
cAMP PK    ---VKHMETGNHYAMKILDKQKVVK-----LKQIEHTLNEKRILQAVNFPFLVKLEF
```

```
PI3-kinase 120 130 140 150 160
           QFNSHT-LHQWLKDKNGEIIDAA--IDLFRSCAGYCVATFILGIGDRHNSNIMVKD-D
cAMP PK    SFKDNSNLYVMMEYVPGGEMFSLRRITGRFSEPHARFYAAQIVLTFEYLHSLDLIYRDLK
```

```
PI3-kinase 170 180 190 200 210 220
           GQLFHI DFGHFLDHKKKFGYKRERVP----FVLTQDFL---IVISKAQECTKTREFE
cAMP PK    PENLLIDQQGYI--QVTD FGF AFAK-RVKGRTWXLCGTPEYLAPEIILSKGYNKAVDWVALG
```

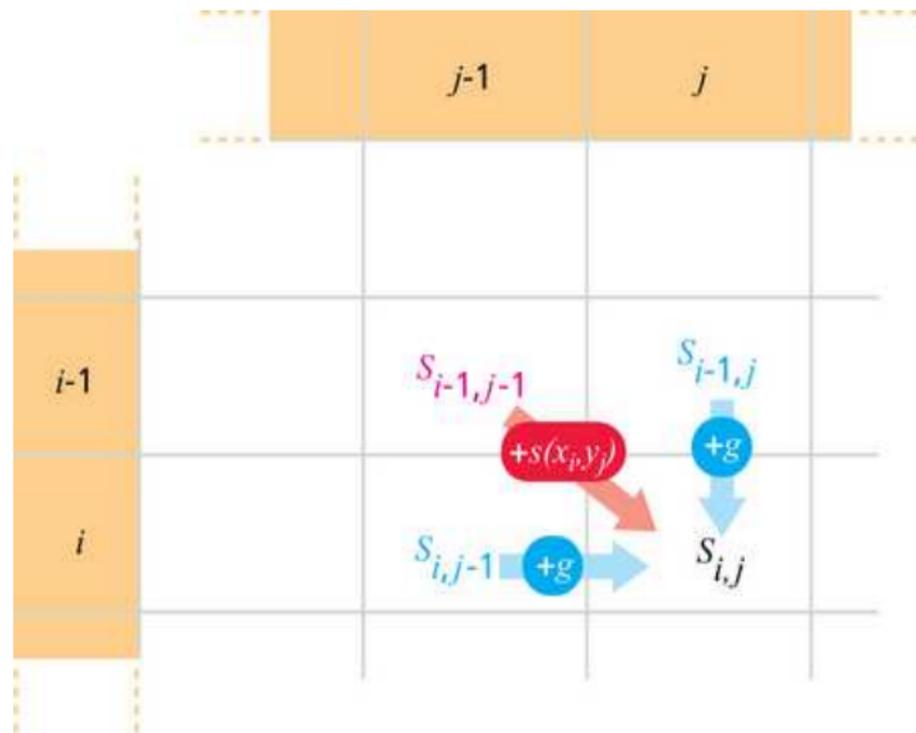


# Tabulka pro algoritmus dynamického programování

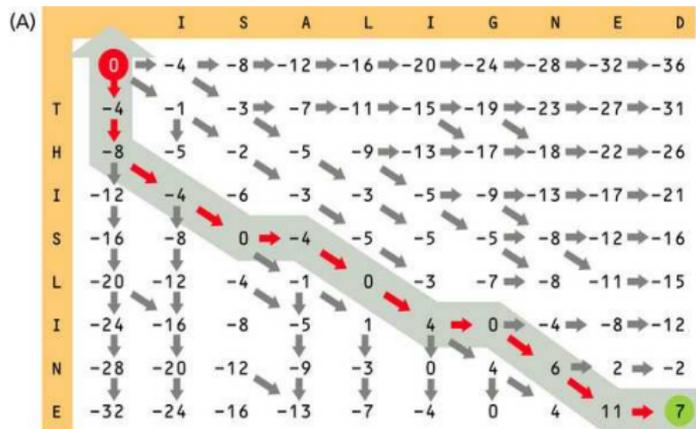
|       |   | $y_1$ | $y_2$ | $y_3$ | $y_4$ | $y_5$ | $y_6$ | $y_7$ | $y_8$ | $y_9$ |     |           |
|-------|---|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|-----------|
|       |   | I     | S     | A     | L     | I     | G     | N     | E     | D     |     |           |
|       |   | 0     | -8    | -16   | -24   | -32   | -40   | -48   | -56   | -64   | -72 | $S_{0,j}$ |
| $x_1$ | T | -8    |       |       |       |       |       |       |       |       |     |           |
| $x_2$ | H | -16   |       |       |       |       |       |       |       |       |     |           |
| $x_3$ | I | -24   |       |       |       |       |       |       |       |       |     |           |
| $x_4$ | S | -32   |       |       |       |       |       |       |       |       |     |           |
| $x_5$ | L | -40   |       |       |       |       |       |       |       |       |     |           |
| $x_6$ | I | -48   |       |       |       |       |       |       |       |       |     |           |
| $x_7$ | N | -56   |       |       |       |       |       |       |       |       |     |           |
| $x_8$ | E | -64   |       |       |       |       |       |       |       |       |     |           |

$S_{i,0}$

# Tabulka pro algoritmus dynamického programování

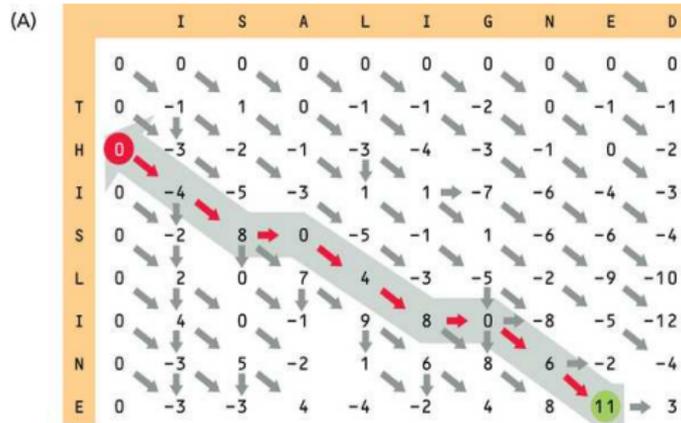


# Tabulka pro algoritmus dynamického programování



(B) THIS-LI-NE-  
--ISALIGNED

# Tabulka pro algoritmus dynamického programování



(B) THIS-LI-NE-  
--ISALIGNED

# Tabulka pro algoritmus dynamického programování

(A)

|   | I | S | A | L | I | G | N | E | D |
|---|---|---|---|---|---|---|---|---|---|
| T | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| H | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| I | 0 | 0 | 0 | 0 | 2 | 4 | 0 | 0 | 0 |
| S | 0 | 0 | 0 | 0 | 0 | 0 | 4 | 1 | 0 |
| L | 0 | 2 | 0 | 0 | 0 | 2 | 0 | 1 | 0 |
| I | 0 | 4 | 0 | 0 | 2 | 0 | 0 | 0 | 0 |
| N | 0 | 0 | 5 | 1 | 0 | 0 | 0 | 0 | 1 |
| E | 0 | 0 | 1 | 4 | 0 | 0 | 0 | 0 | 2 |

(B) IN  
IS

## Bioinformatické databázy



# Outline

Příloha



# For Further Reading

X

