

# IV107 Bioinformatika I

## Přednáška 4

Katedra informačních technologií  
Masarykova Univerzita Brno

Jaro 2011

Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

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

Anotace sekvence a genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



## Anotace sekvence a genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Bioinformatické databázy

Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

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

## Anotace sekvence a genů

[Anotace genomu](#)

[Identifikace genů](#)

[Homologie a podobnost](#)

## Příště

[Bioinformatické databázy](#)

>P12345 Gen1 - protein  
alkoholdehydrogenáza

TATA	TATAAA
	CGATTGACGATGACGAT
start	ATG
exon1	TACAGATTACAGATTACAGATTAAGATGT
intron1	CAGATTACAGATTACAGATTACACAGATTCA
exon2	AGATTACAGATTACAGATTACAGA
stop	TAA

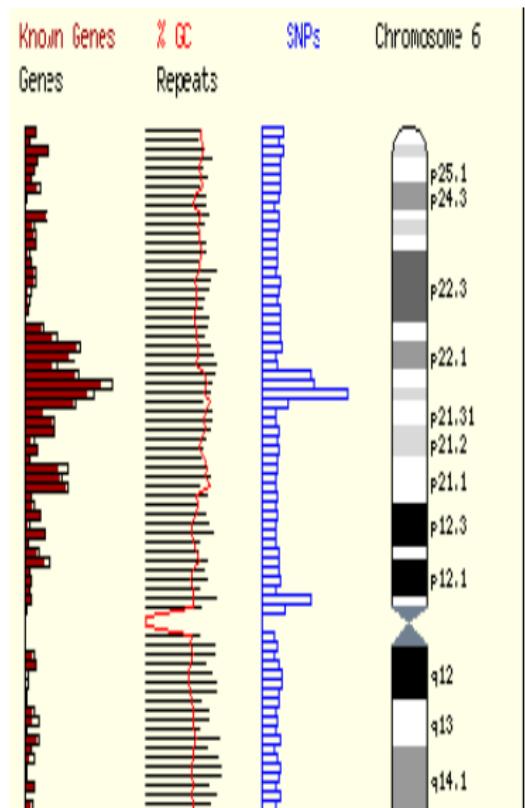
>P12346 Protein1  
MASAQSFYLLDHQNQNFDDHLAVDIVMILSHERFMN

## Anotace sekvence a genů

[Anotace genomu](#)  
[Identifikace genů](#)  
[Homologie a podobnost](#)

## Příště

[Bioinformatické databázy](#)



Anotace sekvence a  
genů

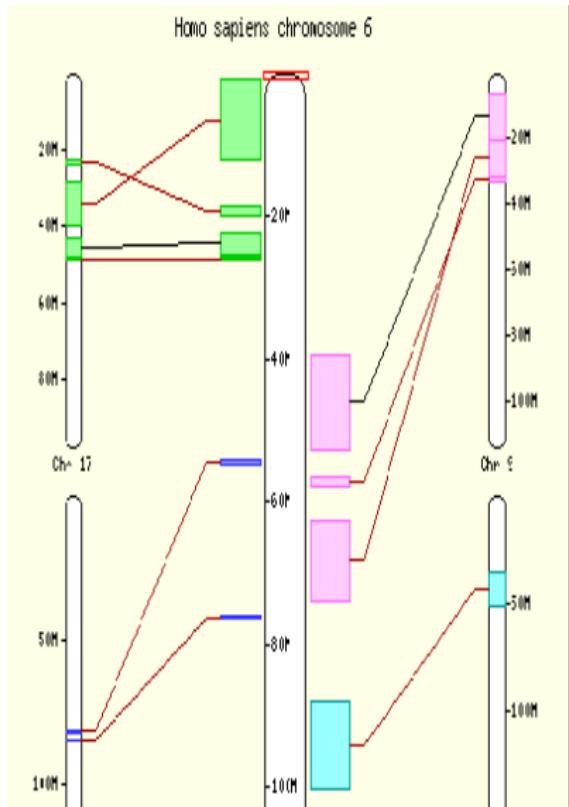
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

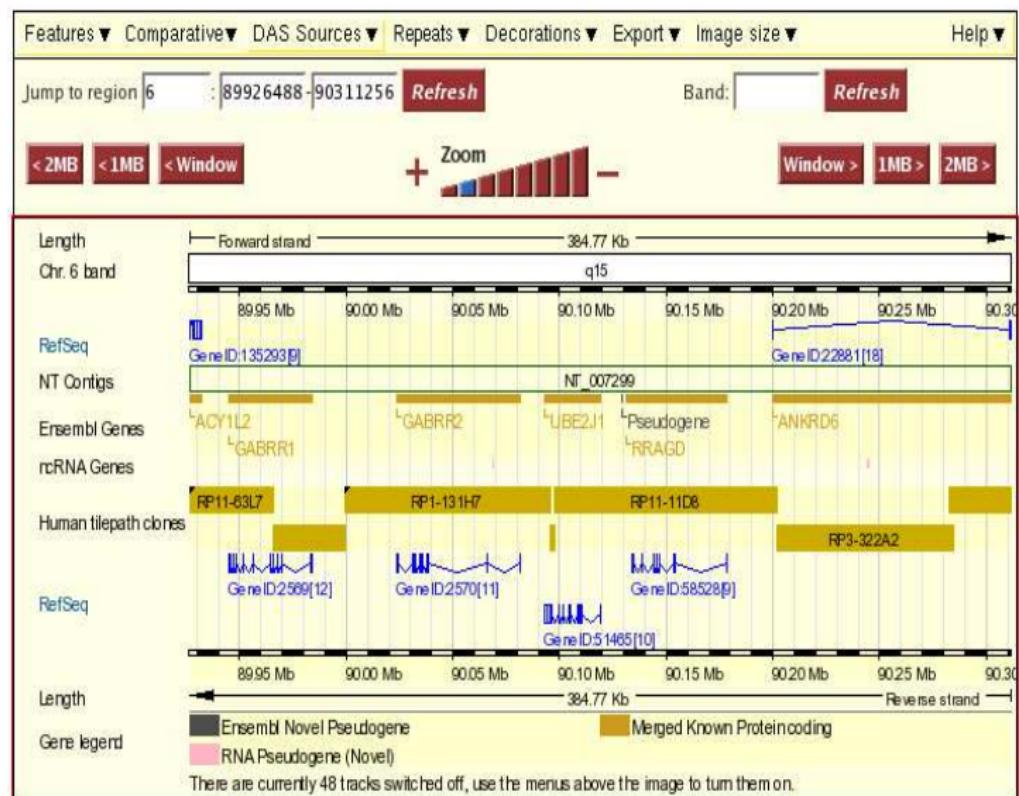
Homologie a podobnost

Příště

Bioinformatické databázy

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

IV107 Bioinformatika I -  
Přednáška 4



Anotace sekvence a genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

- ▶ Experimentální metody (cDNA, EST)
- ▶ Komparativní metody
  - ▶ Selekcí tlak
  - ▶ Druh zachovaných mutací
- ▶ Strukturní metody (GeneMark, GeneScan, GenID)
- ▶ Detekce charakteristických signálů

## Identifikace genů podle charakteru mutací

## Anotace sekvence a genů

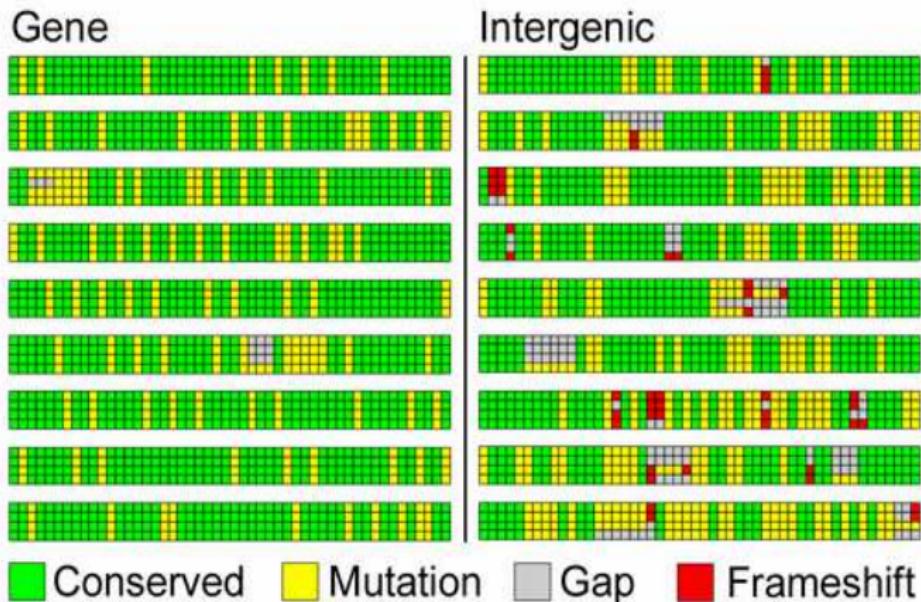
### Anotace genomu

### Identifikace genů

### Homologie a podobnost

Příště

Bioinformatické databázy



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

Anotace sekvence a  
genů

[Anotace genomu](#)

[Identifikace genů](#)

[Homologie a podobnost](#)

Příště

[Bioinformatické databázy](#)

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 sekveních
- ▶ občasný překryv genů

Anotace sekvence a genů

[Anotace genomu](#)

[Identifikace genů](#)

[Homologie a podobnost](#)

Příště

[Bioinformatické databázy](#)

## Struktura genu (prokaryotická)

## Anotace sekvence a genů

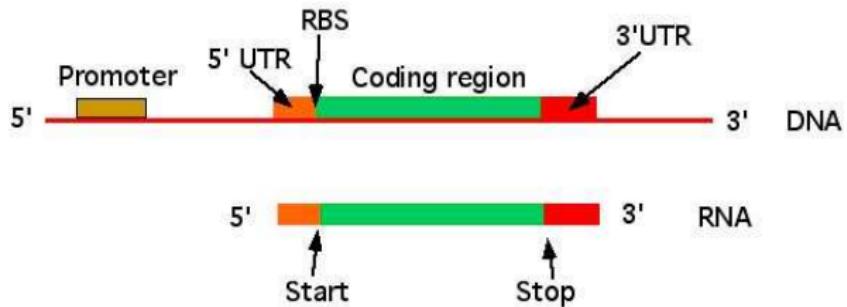
### Anotace genomu

## Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



## Anotace sekvence a genů

Anotace genomu

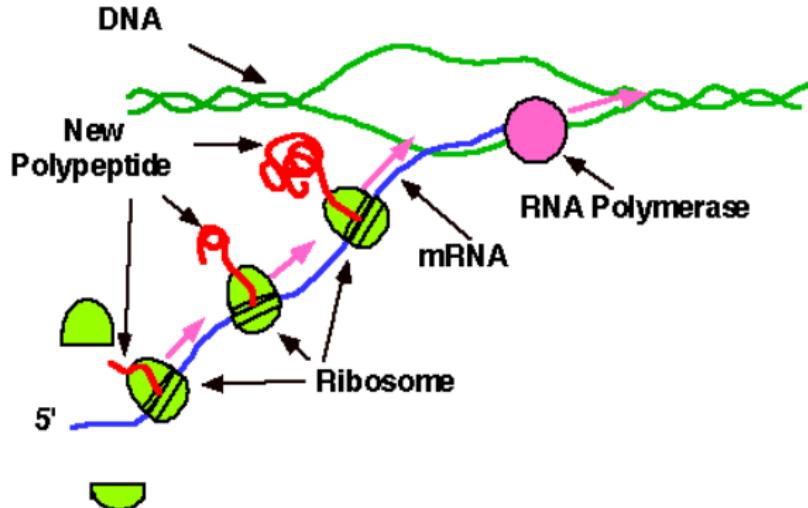
### Identifikace genů

## Homologie a podobnost

## Příště

Bioinformatické databázy

## Coupled Transcription and Translation



## Struktura genu (eukaryotická)

## Anotace sekvence a genů

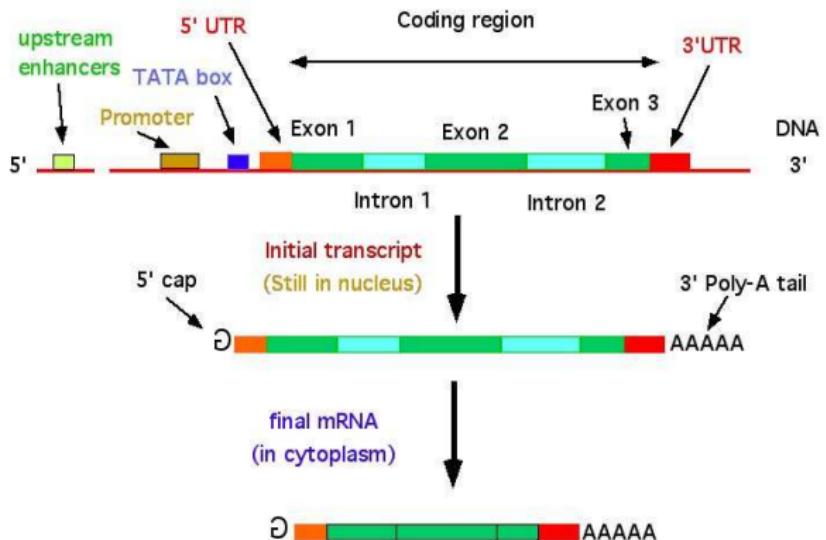
## Anotace genomu

### Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy



# 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/GTaagt)
    - ▶ akceptor (cAG/gt)
    - ▶ lariat (CU[AG]A[CU])
  - ▶ terminátor translace (stop kodon = UAG—UAA—UGA)
- ▶ 3'-UTR
  - ▶ polyadenylační signál (AATAAA)
  - ▶ terminátor transkripce

Anotace sekvence a genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

Anotace sekvence a  
genů

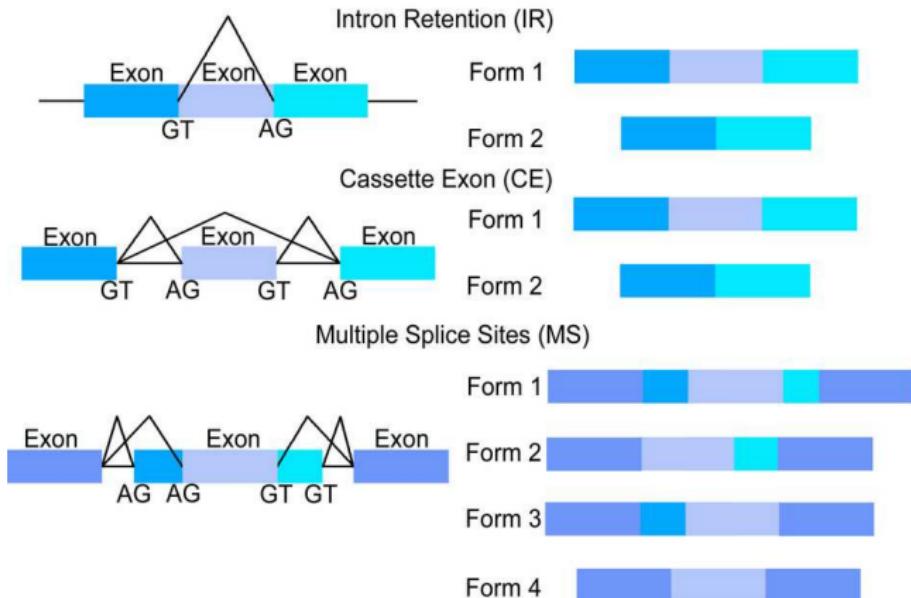
Anotace genomu

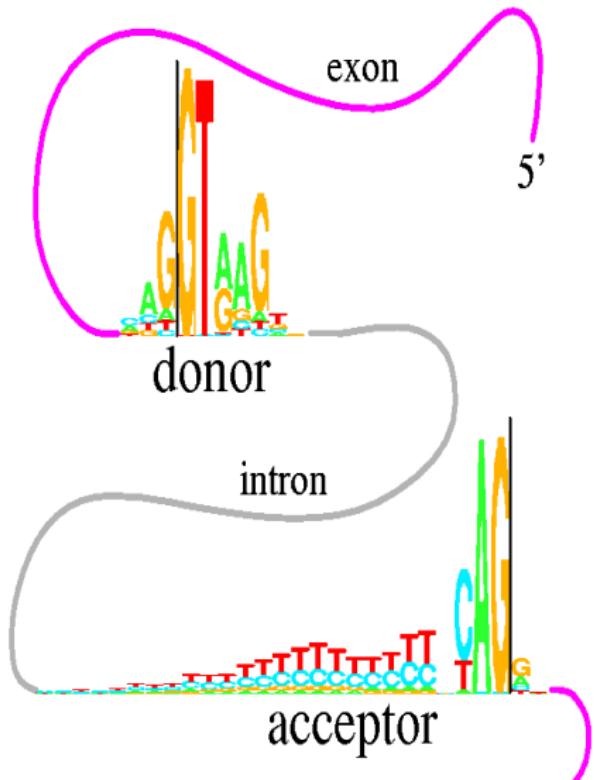
Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy





Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

## detailedy sestřihu

## Anotace sekvence a genů

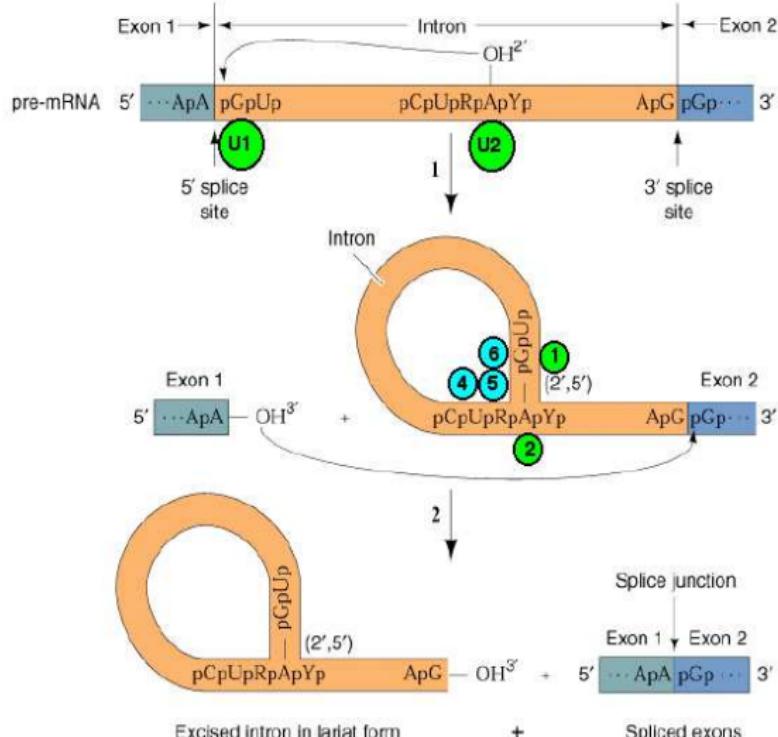
### Anotace genomu

## Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy



# Identifikace genů podle struktury

Anotace sekvence a  
genů

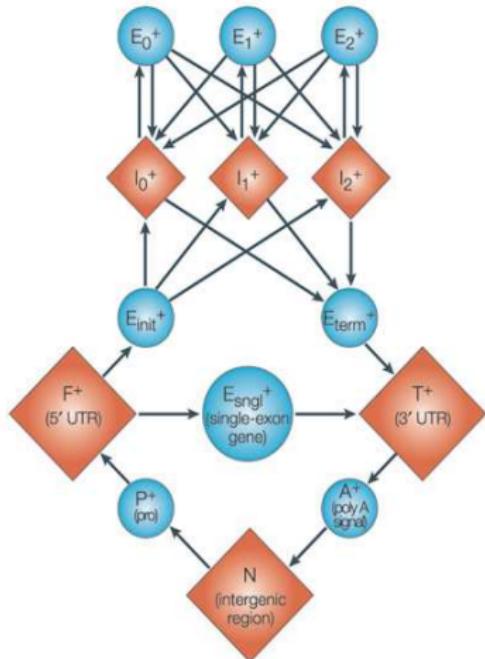
Anotace genomu

Identifikace genů

Homologie a podobnost

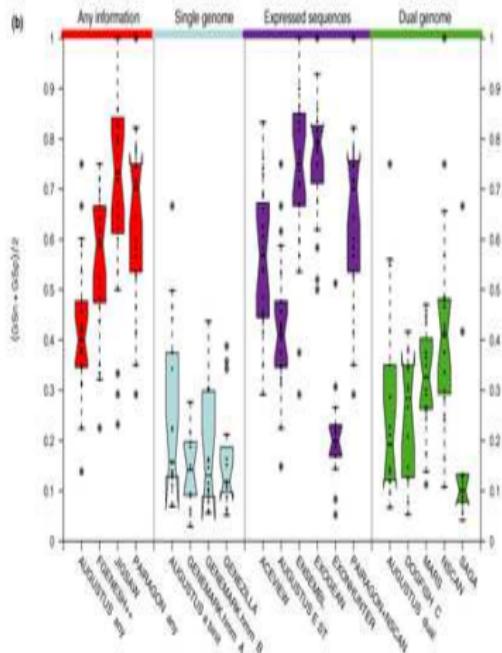
Příště

Bioinformatické databázy



Reverse strand: mirror reflection of above

# Úspěšnost identifikace genů



Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

# Příbuzné geny mají podobnou funkci i sekvenci

Anotace sekvence a genů

Anotace genomu

Identifikace genů

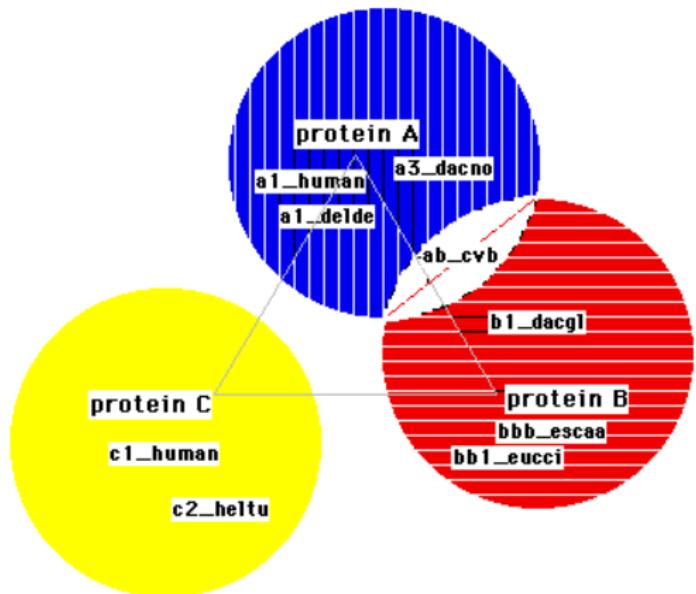
Homologie a podobnost

Příště

Bioinformatické databázy

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

## Rost - prostor podobnosti



## Anotace sekvence a genů

### Anotace genomu

## Identifikace genů

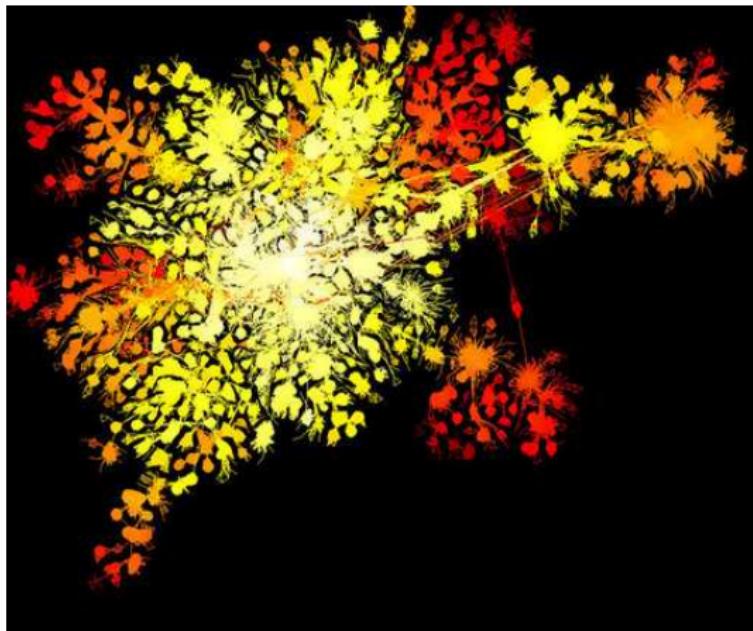
## Homologie a podobnost

Příště

Bioinformatické databázy

# Síť proteinů podle sekvenční podobnosti

IV107 Bioinformatika I -  
Přednáška 4



Proteiny přepojené podle sekvenční podobnosti.  
Každý z 30727 vrcholů reprezentuje protein, každá z  
1,206,654 hran podobnost. Seed Maqazine, Červenec 2013

Anotace sekvence a  
genů

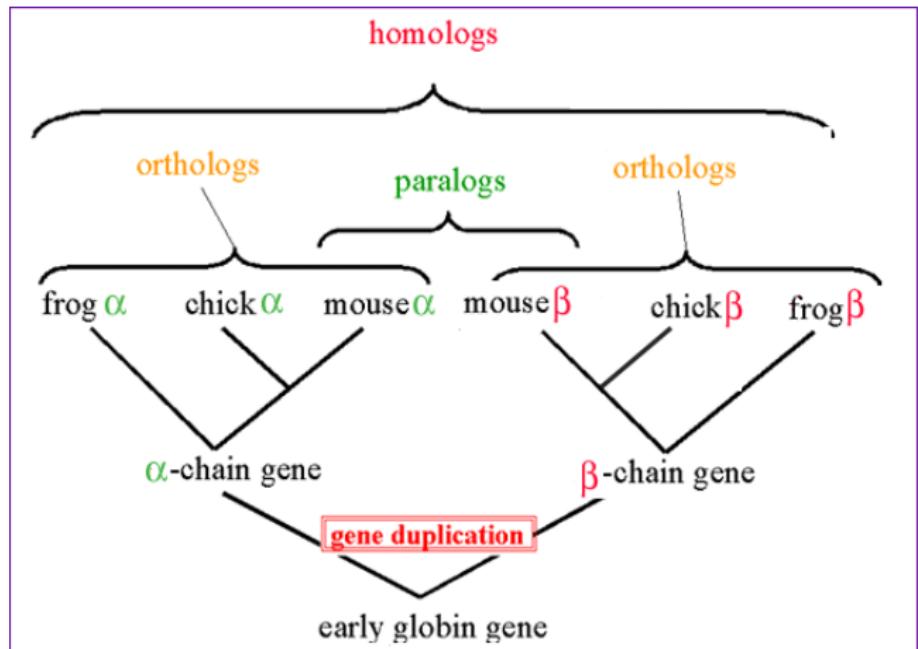
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



## Anotace sekvence a genů

## Anotace genomu

## Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy

Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

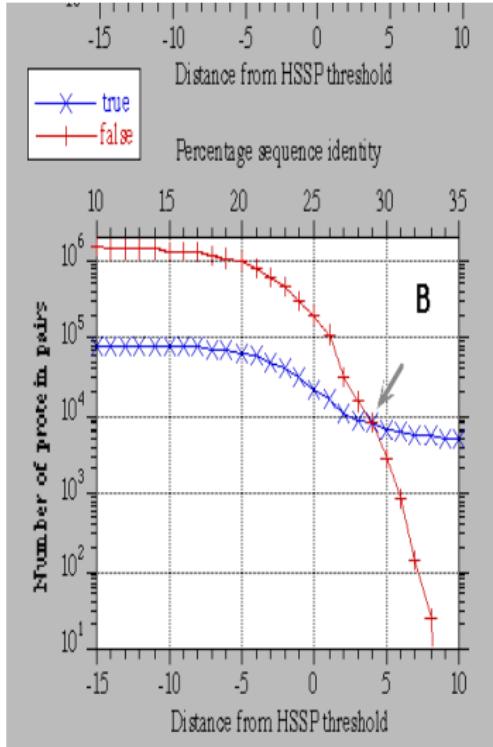
Příště

Bioinformatické databázy

- ▶ 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.

## Rost - "twilight zone"



## Anotace sekvence a genů

### Anotace genomu

## Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy

Anotace sekvence a  
genů

[Anotace genomu](#)

[Identifikace genů](#)

[Homologie a podobnost](#)

Příště

[Bioinformatické databázy](#)

- ▶ 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

Anotace sekvence a  
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

(A) local

PI3-kinase DRHNSNIMVKDDGQLFHI DFG  
cAMP PK DLKPENLIDQQGYIQVT DFG

(B) global

10 20 30 40 50  
PI3-kinase HQLGNLRL--LEECRI---MSSAKRPLWLWNWENPDIMSELLFQNNEIIFKNGDDLRLQDMLT  
cAMP PK GNAAAAKKGXEQESVKEFLAKAKEDFLKKWENPAQNTAHLDQFERIKTLGTGSFGRVML-

60 70 80 90 100 110  
PI3-kinase LQIIRIME--NIWQNQGLDLRMLPYGCLSIGDCVGILIEVVRNSHTIMQ-IQCKGGLKAL  
cAMP PK ---VKHMETGNHYAMKILDQKVVK-----LKQIETHLNEKRILQAVNFPFLVKLEF

120 130 140 150 160  
PI3-kinase QFNSHT-LHQWLKDKNKGEIYDAA--IDLFTRSAGYCVATFILGIGDRHNSNIMVKD-D  
cAMP PK SFKDNSNLYMVMVEYVPGGEMFSHLRRIGRFSEPHARFYAAQIVLTFEYLHSLDLIYRDLK

# Matice pro hodnocení podobnosti proteinových sekvencí

## Anotace sekvence a genů

## Anotace genomy

### Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy

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

# Tabulka pro algoritmus dynamického programování

## Anotace sekvence a genů

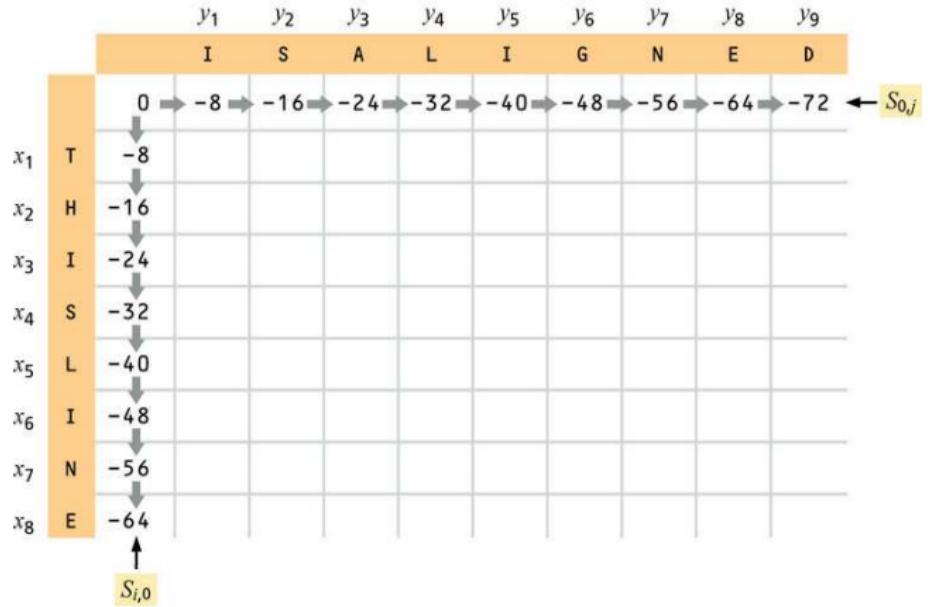
## Anotace genomu

## Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy



# Tabulka pro algoritmus dynamického programování

Anotace sekvence a  
genů

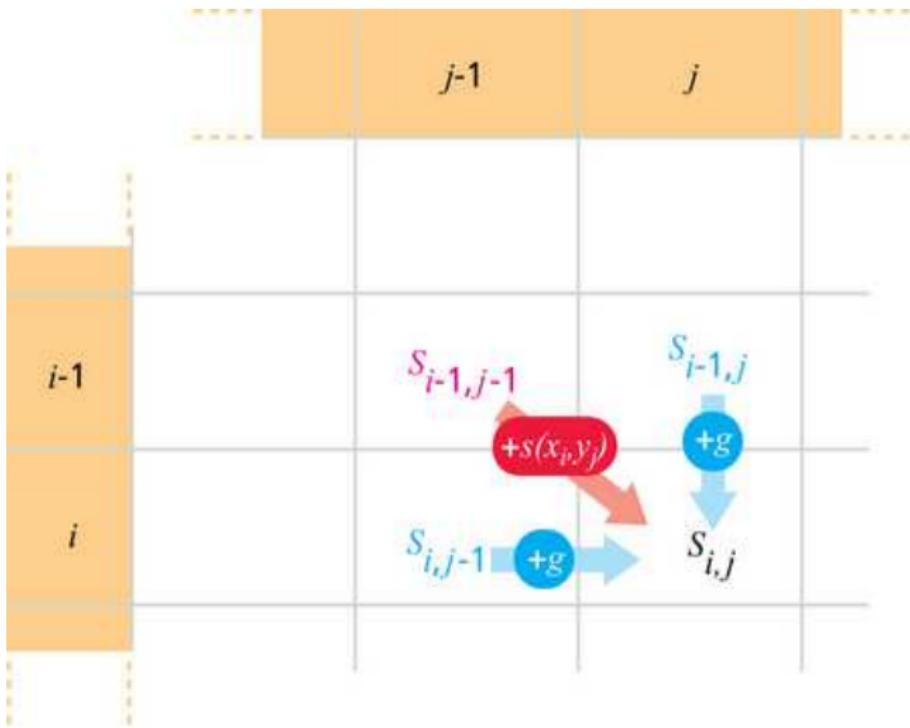
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



# Tabulka pro algoritmus dynamického programování

## Anotace sekvence a genů

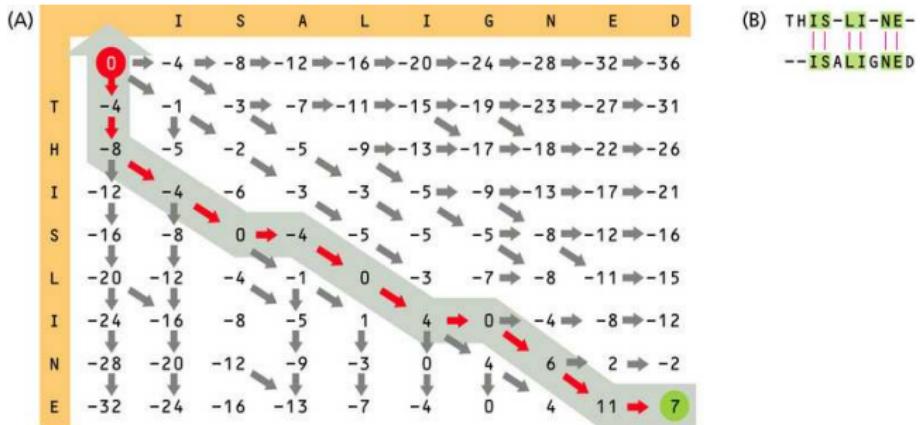
Anotace genomu

### Identifikace genů

## Homologie a podobnost

Příště

Bioinformatické databázy



# Tabulka pro algoritmus dynamického programování

Anotace sekvence a  
genů

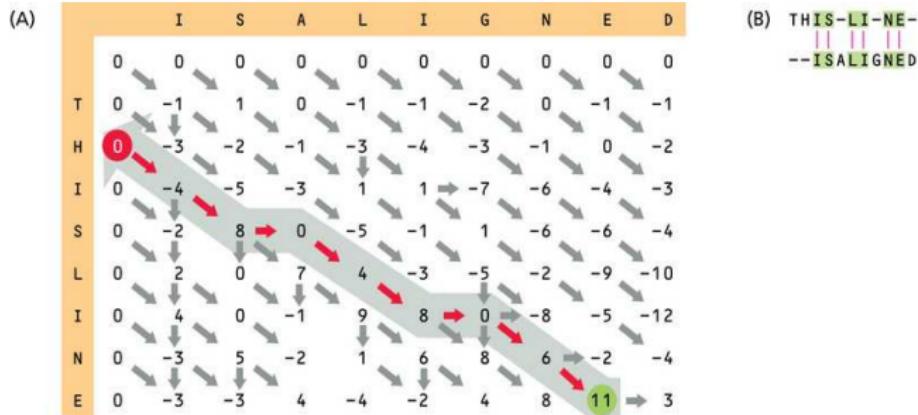
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



# Tabulka pro algoritmus dynamického programování

Anotace sekvence a  
genů

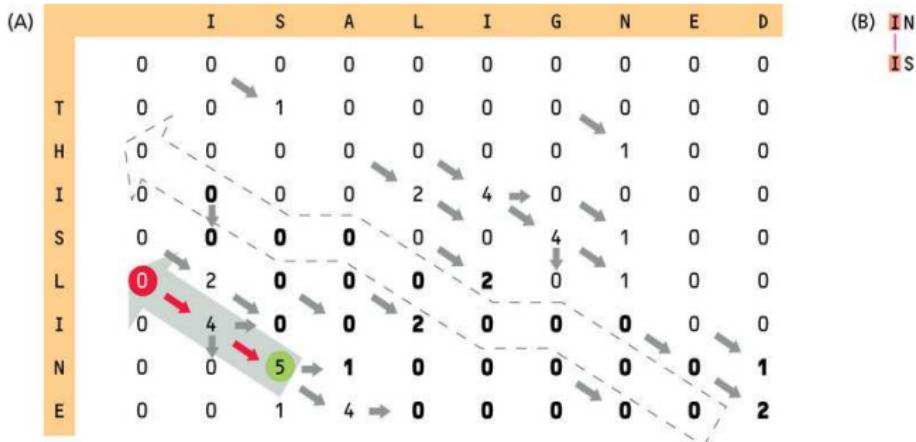
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



Biomimetic

## Wyszukiwanie w bazie danych

A set of small, light-blue navigation icons typically found in Beamer presentations, including symbols for back, forward, search, and table of contents.

## Dodatek

For Further Reading

## Dodatek

Dodatek

For Further Reading

X