

IV107 Bioinformatika I

Přednáška 4

Katedra informačních technologií
Masarykova Univerzita Brno

Jaro 2010

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

Outline

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

MASAQSFYLLDHNQNQNFDDHLAVDIVMILSHERFMN

Anotace sekvence a
genů

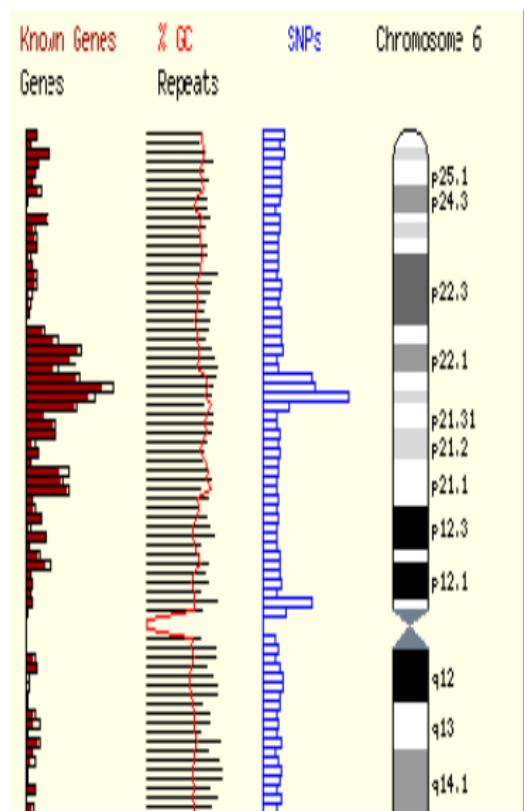
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



Anotace sekvence a
genů

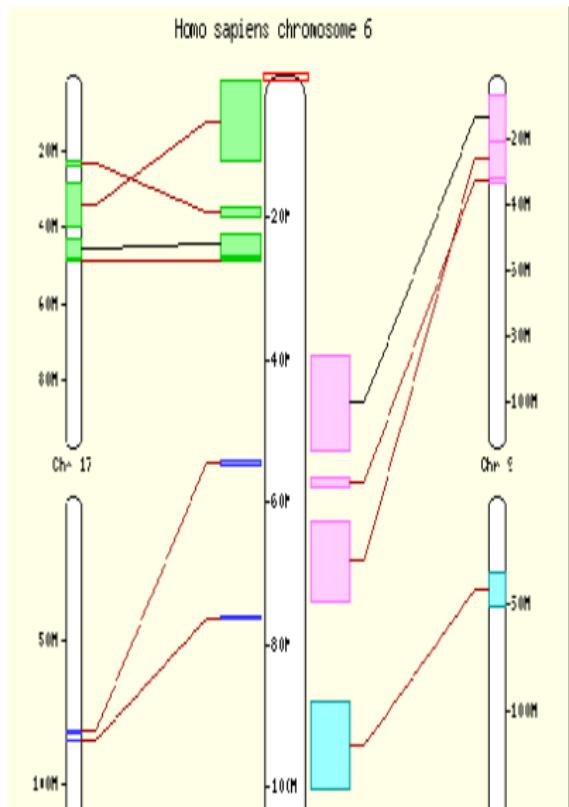
Anotace genomu

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

Features ▾ Comparative ▾ DAS Sources ▾ Repeats ▾ Decorations ▾ Export ▾ Image size ▾ Help ▾

Jump to region 6 : 89926488 - 90311256 Refresh Band: Refresh

< 2MB < 1MB < Window + Zoom - Window > 1MB > 2MB >

Length Chr. 6 band Forward strand 384.77 Kb q15

Chr. 6 band RefSeq NT Contigs Ensembl Genes ncRNA Genes Human tilepath clones RefSeq Length Gene legend

89.95 Mb 90.00 Mb 90.05 Mb 90.10 Mb 90.15 Mb 90.20 Mb 90.25 Mb 90.30

Gene ID:135293[9] Gene ID:22881[18]

NT_007299

ACY1L2 GABRR2 UBE2J1 Pseudogene RRAGD ANKRD6

GABRR1

RP11-63L7 RP1-131H7 RP11-11D8 RP3-322A2

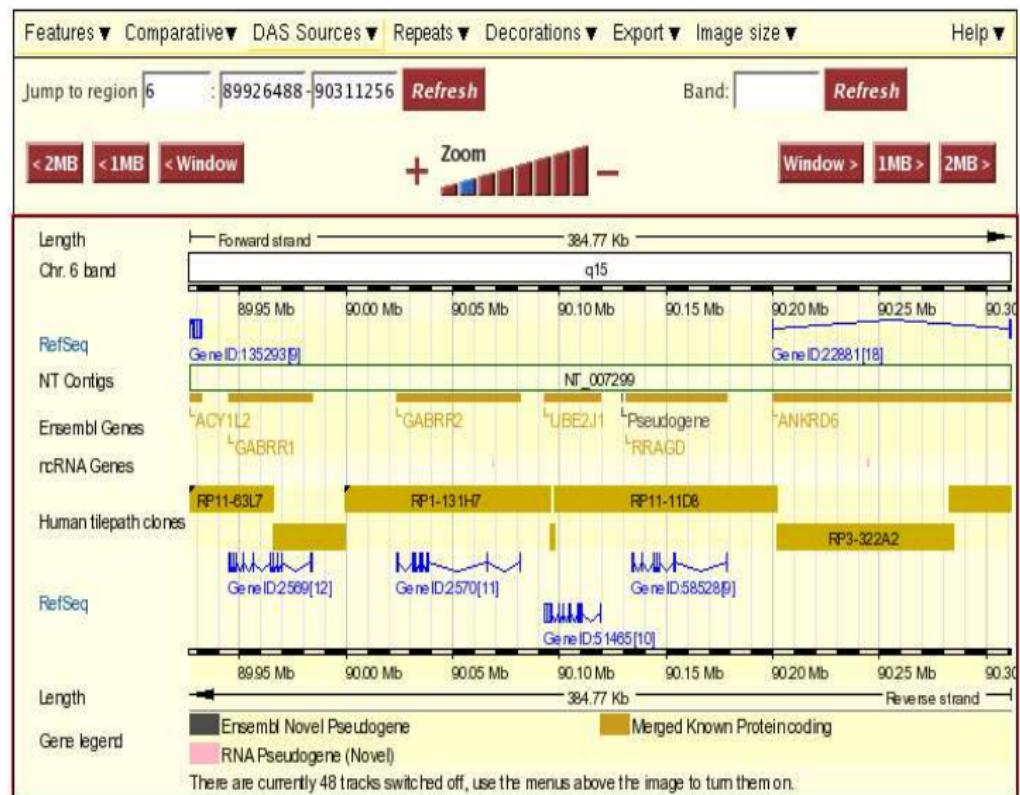
Gene ID:2569[12] Gene ID:2570[11] Gene ID:58528[9] Gene ID:51465[10]

89.95 Mb 90.00 Mb 90.05 Mb 90.10 Mb 90.15 Mb 90.20 Mb 90.25 Mb 90.30

384.77 Kb Reverse strand

Ensembl Novel Pseudogene Merged Known Protein coding RNA Pseudogene (Novel)

There are currently 48 tracks switched off, use the menus above the image to turn them on.



Anotace sekvence a genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

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

Anotace sekvence a
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

Identifikace genů podle charakteru mutací

Anotace sekvence a genů

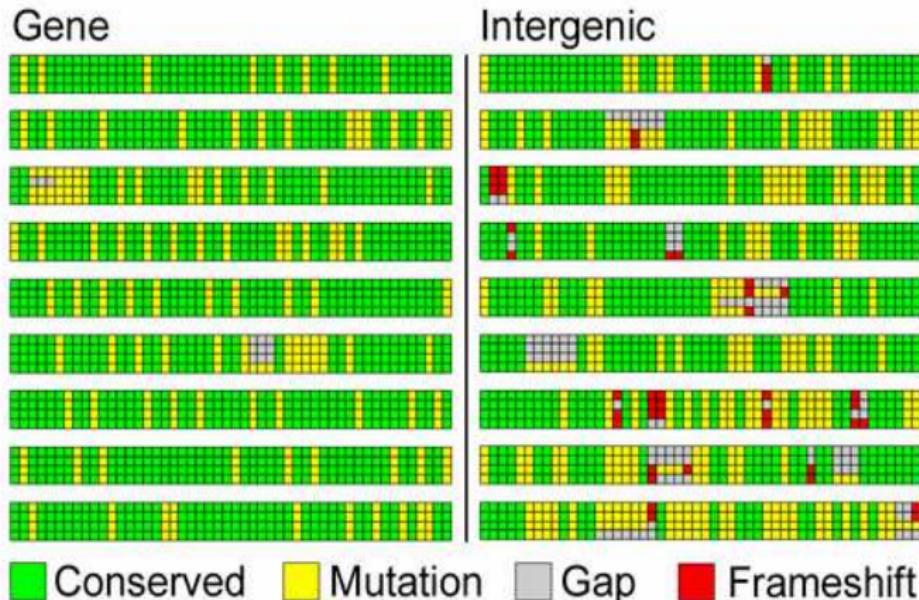
Anotace genomu

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

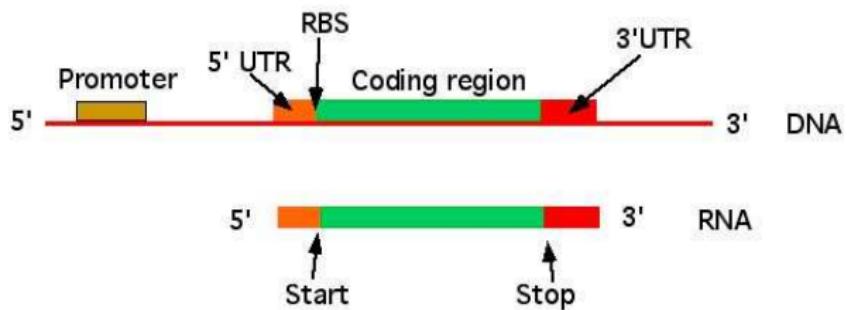
Anotace genomu

Identifikace genů

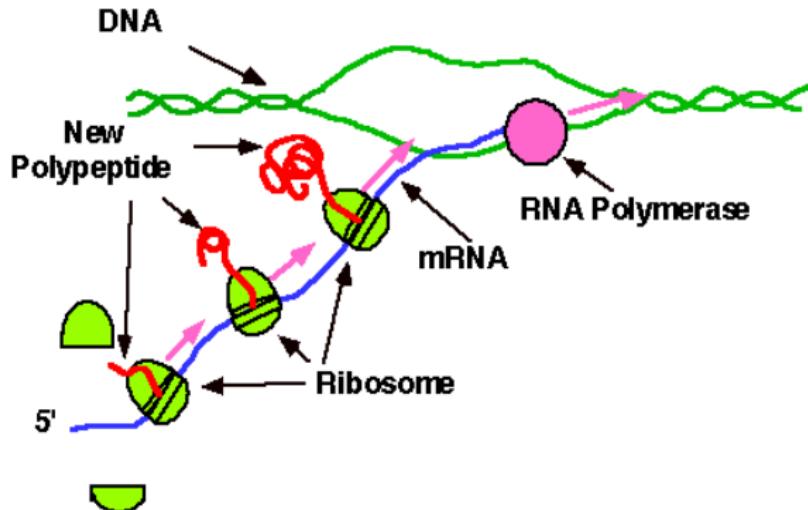
Homologie a podobnost

Příště

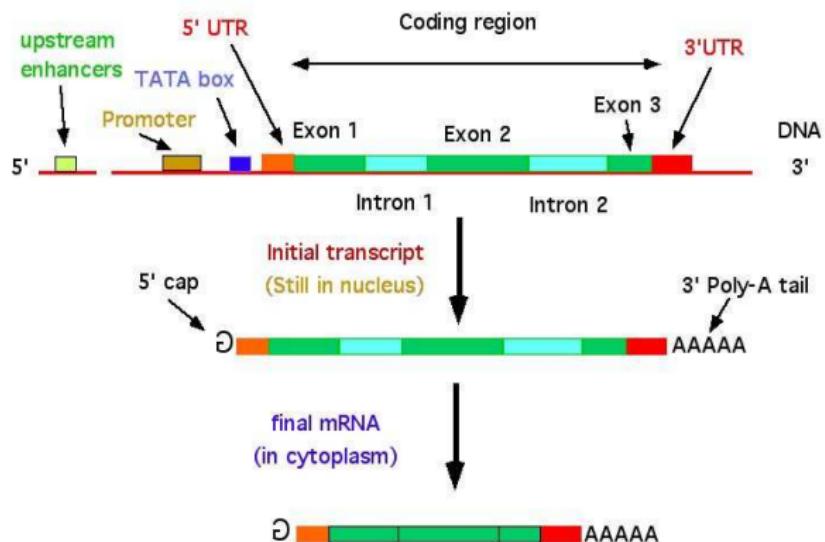
Bioinformatické databázy



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

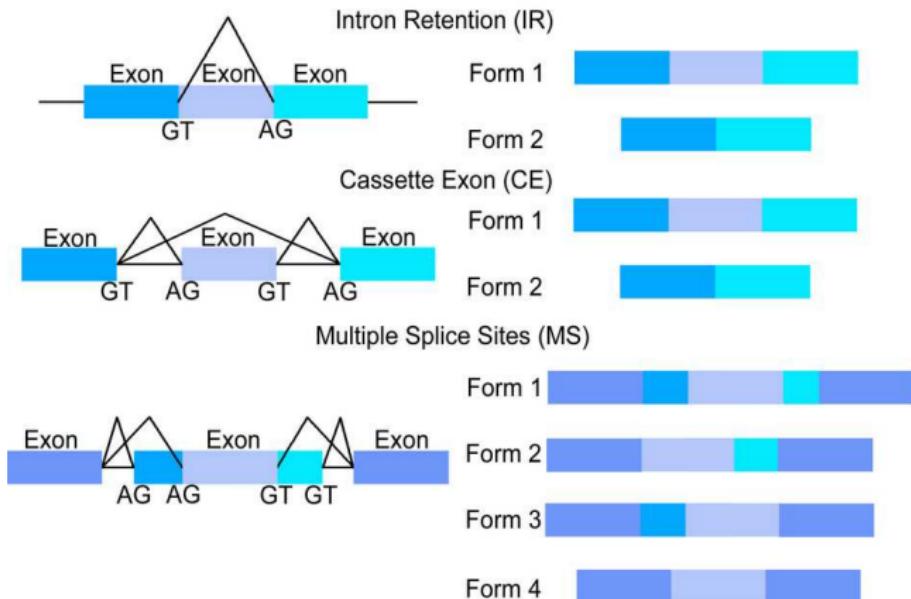
Anotace genomu

Identifikace genů

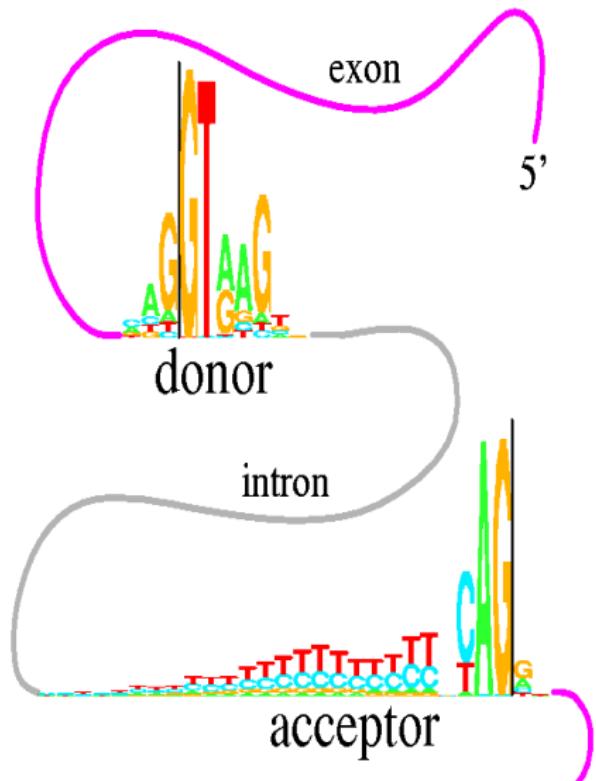
Homologie a podobnost

Příště

Bioinformatické databázy



Sekvenční logo intronu



Anotace sekvence a
genů

Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy

detailedy sestřihu

Anotace sekvence a genů

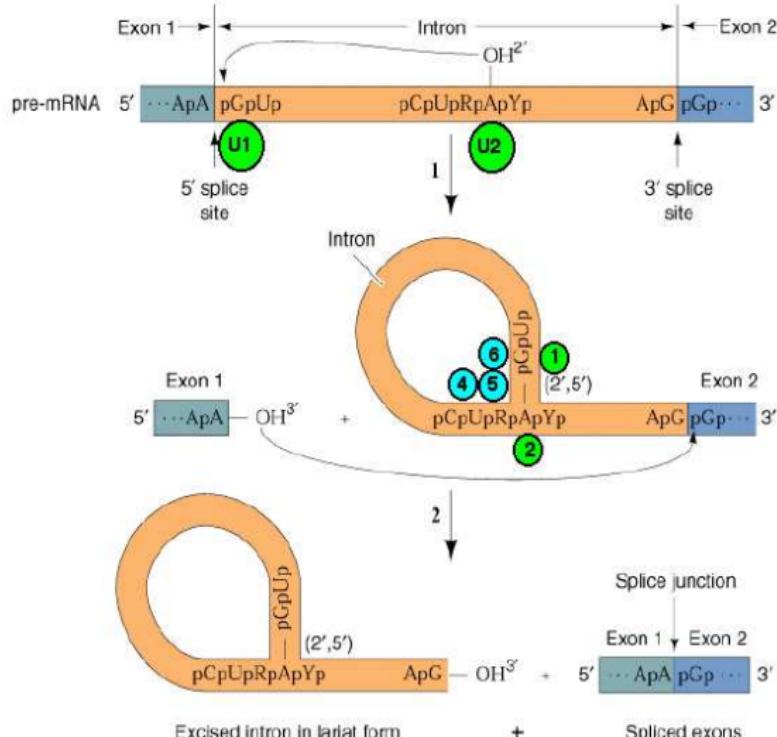
Anotace genomu

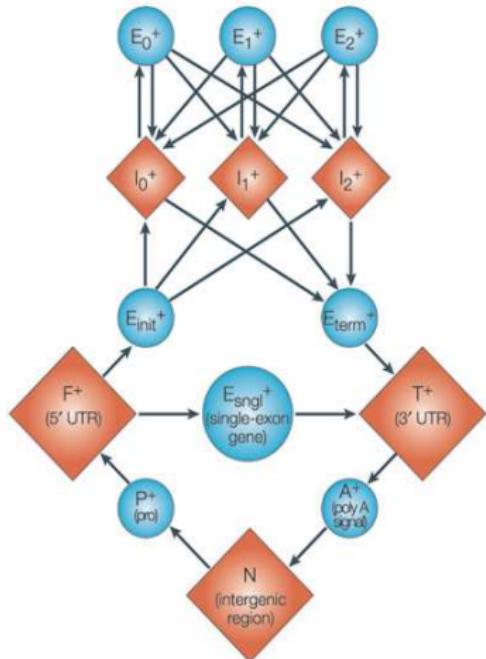
Identifikace genů

Homologie a podobnost

Příště

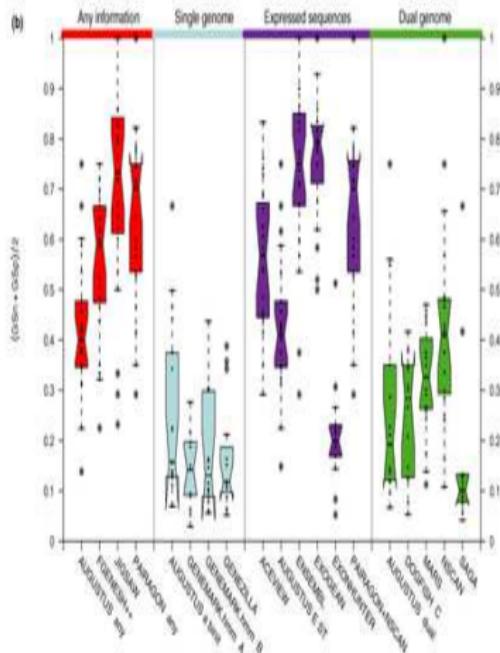
Bioinformatické databázy





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.

Anotace sekvence a
genů

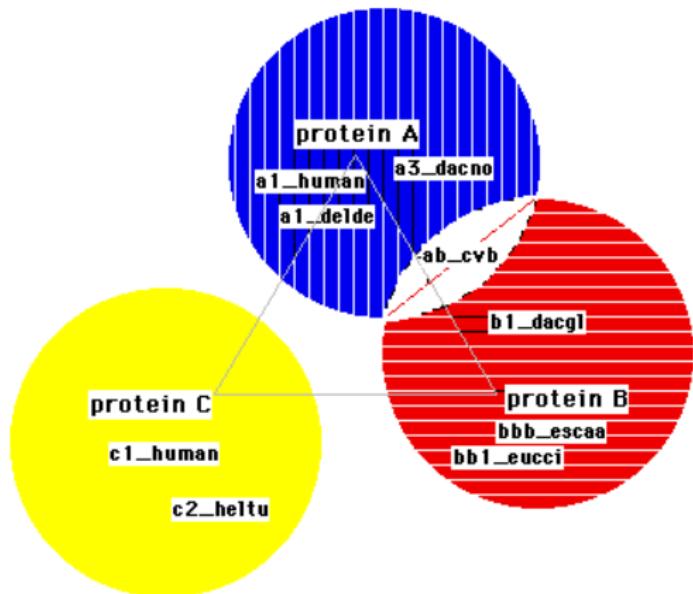
Anotace genomu

Identifikace genů

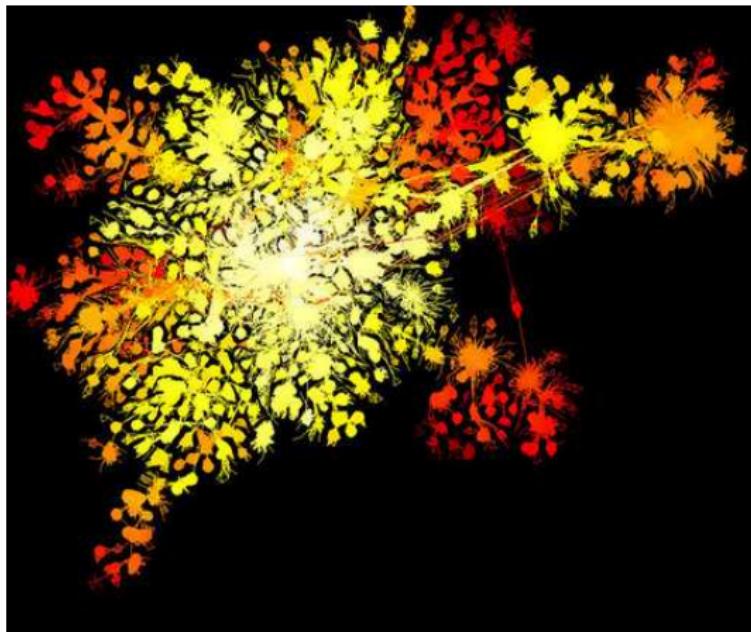
Homologie a podobnost

Příště

Bioinformatické databázy



Síť proteinů podle sekvenční podobnosti



Proteiny přepojené podle sekvenční podobnosti.
Každý z 30727 vrcholů reprezentuje protein, kada z
1.206.654 hran podobnost. Seed Magazine. Červenec 2008

Anotace sekvence a
genů

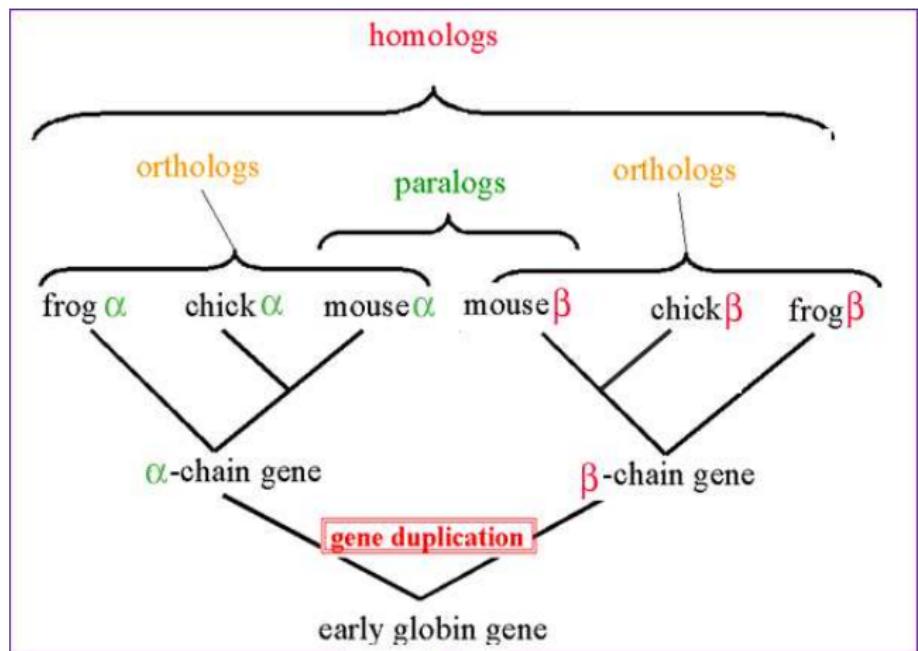
Anotace genomu

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

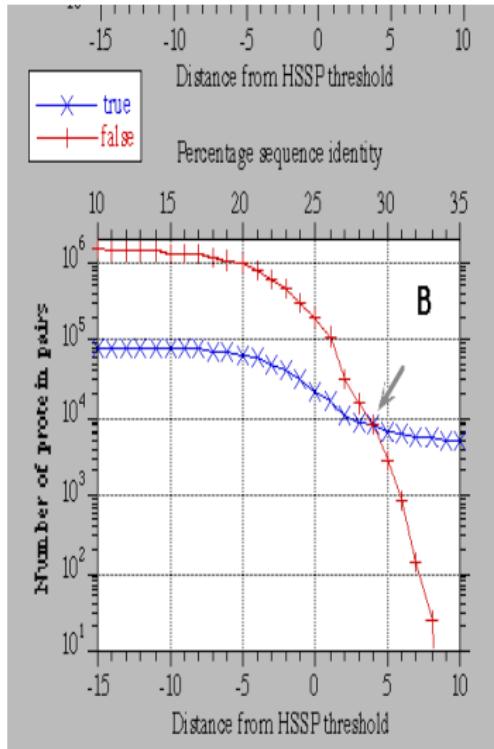
Příště

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 DLKPENLLIDQQGYIQVT DFG

(B) global

PI3-kinase HQLGNLRL--LEECRI---MSSAKRPLWLWNWENPDIMSELLFQNNEIIFKNGDDLRLQDMLT
cAMP PK GNAAAAKKGXEQESVKEFLAKAKEDFLKKWENPAQNTAHLDQFERIKTLGTGSFGRVML-

PI3-kinase LQIIRIME--NIWQNQGGLDLRMLPYGCLSIGDCVGLIEVVRNSHTIMQ-IQCKGGLKAL
cAMP PK ---VKHMETGNHYAMKILDQKVVK-----LKQIETHLNEKRILQAVNFPFLVKLEF

PI3-kinase QFNSHT-LHQWLKDKNKGEIYDAA--IDLFTRSAGYCVATFILGIGDRHNSNIMVKD-D
cAMP PK SFKDNSNLYMVMVEYVPGGEMFSHLRRIGRFSEPHARFYAAQIVLTFEYLHSLDLIYRDLK

Matice pro hodnocení podobnosti proteinových sekvencí

Anotace sekvence a genů

Anotace genomu

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

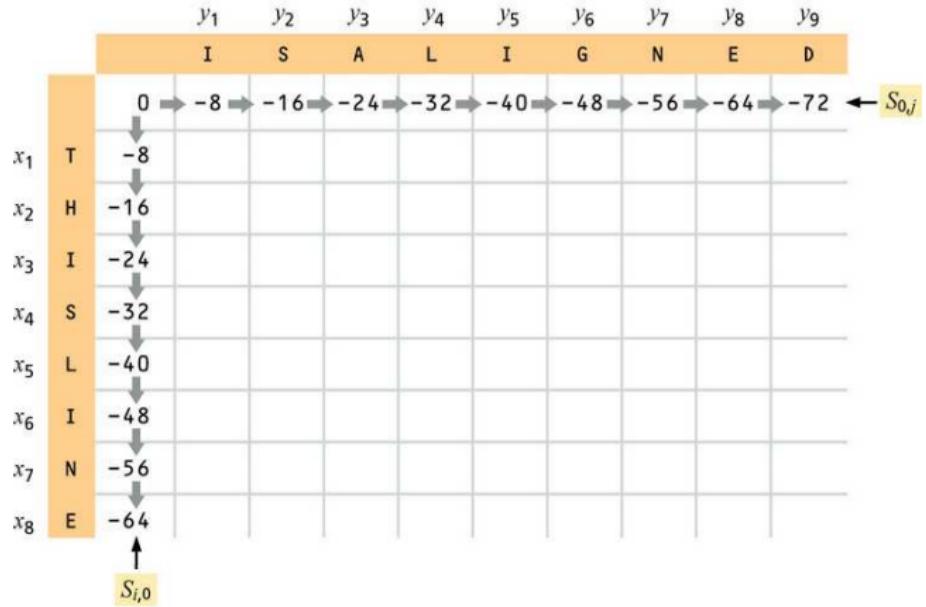
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



Tabulka pro algoritmus dynamického programování

Anotace sekvence a genů

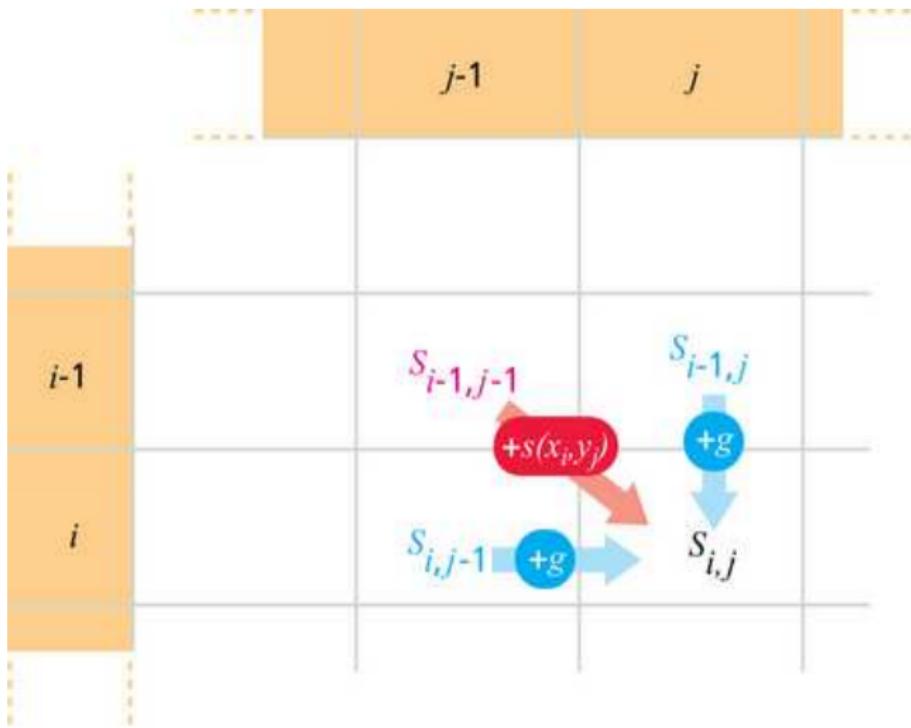
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



Tabulka pro algoritmus dynamického programování

Anotace sekvence a
genů

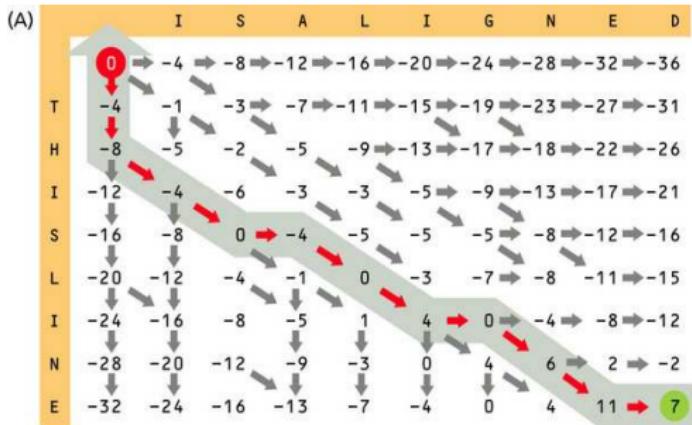
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



(B) THIS-LI-NE-
--IS ALIGNED

Tabulka pro algoritmus dynamického programování

Anotace sekvence a
genů

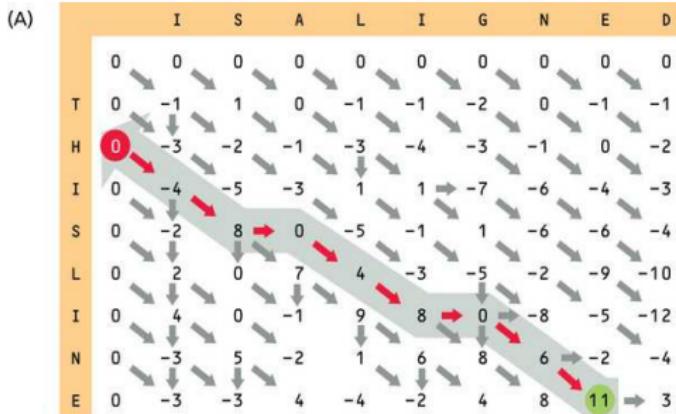
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



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

Tabulka pro algoritmus dynamického programování

Anotace sekvence a genů

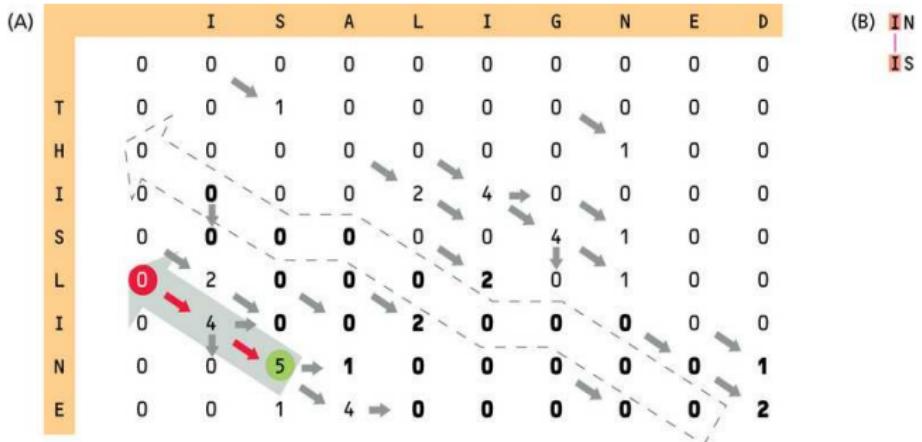
Anotace genomu

Identifikace genů

Homologie a podobnost

Příště

Bioinformatické databázy



Dodatek

For Further Reading

Dodatek

For Further Reading

Dodatek

For Further Reading

X