

CG020 Genomika

Přednáška 2

Identifikace genů

Jan Hejátko

Funkční genomika a proteomika rostlin,

Mendelovo centrum genomiky a proteomiky rostlin,

Středoevropský technologický institut (CEITEC), Masarykova univerzita, Brno

hejatko@sci.muni.cz, www.ceitec.muni.cz



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



MASARYKIANA
UNIVERSITAS
BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Literatura

▪ Zdrojová literatura ke kapitole 2

- Plant Functional Genomics, ed. Erich Grotewold, 2003, Humana Press, Totowa, New Jersey
- Majoros, W.H., Pertea, M., Antonescu, C. and Salzberg, S.L. (2003) GlimmerM, ExonM, and Unveil: three ab initio eukaryotic gene finders. *Nucleic Acids Research*, **31**(13).
- Singh, G. and Lykke-Andersen, J. (2003) New insights into the formation of active nonsense-mediated decay complexes. *TRENDS in Biochemical Sciences*, **28** (464).
- Wang, L. and Wessler, S.R. (1998) Inefficient reinitiation is responsible for upstream open reading frame-mediated translational repression of the maize R gene. *Plant Cell*, **10**, (1733)
- de Souza et al. (1998) Toward a resolution of the introns earlylylate debate: Only phase zero introns are correlated with the structure of ancient proteins *PNAS*, **95**, (5094)
- Feuillet and Keller (2002) Comparative genomics in the grass family: molecular characterization of grass genome structure and evolution *Ann Bot*, **89** (3-10)
- Fribus, A.C., Matus, D.Q., and Seaver, E.C. (2008). Genomic organization and expression demonstrate spatial and temporal Hox gene colinearity in the lophotrochozoan *Capitella* sp. I. *PLoS One* **3**, e4004



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání
 - genomová kolinearita a genová homologie
- Experimentální identifikace genů
 - příprava genově obohacených knihoven pomocí technologie metylačního filtrování
 - EST knihovny
 - přímá a reverzní genetika



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



MASARYKIANA
UNIVERSITAS
BRUNNENS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Přímá vs. reverzní genetika

Revoluce v chápání pojmu genu

Přístupy „klasické“ genetiky



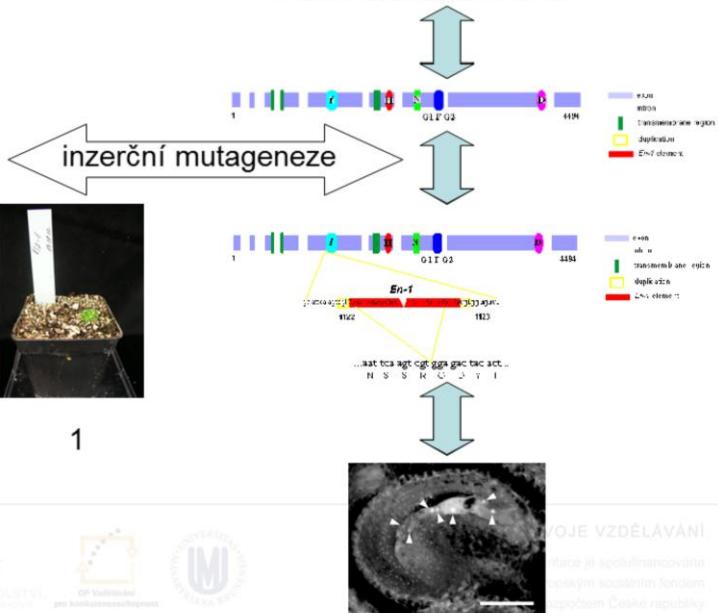
3

:

1

„Reverzně geneticky“ přístup

5' TTATATATATATAAAGAAAATAAAA... 3'



OJE Vzdělávání
stále se spolupracovává
s mezinárodním fondem
zdrojem České republiky



Identifikace role genu ARR21

- Předpokládaný přenašeč signálu u dvoukomponentního signálního systému *Arabidopsis*



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



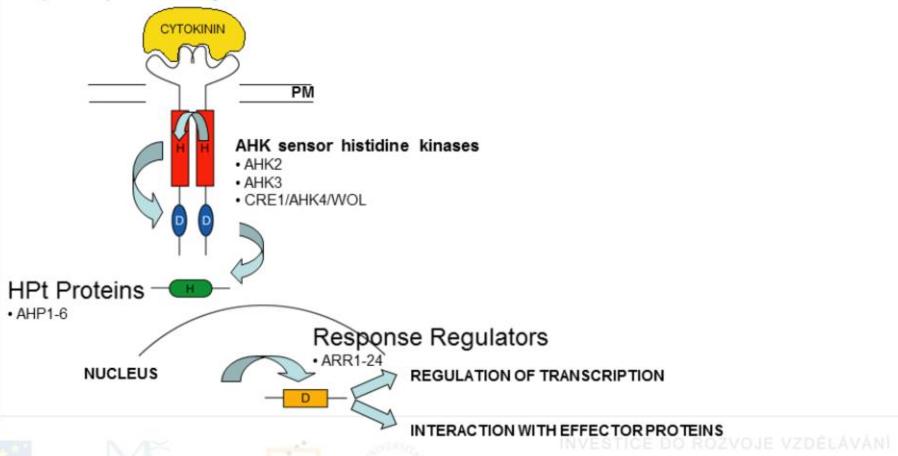
MASARYKIANA BRUNNEN

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu ARR21

Recent Model of the CK Signaling via Multistep Phosphorelay (MSP) Pathway



EVROPSKÁ UNIJA



MINISTERSTVO Školství, mládeže a tělovýchovy



OP VaVN



INVESTICE DO ROZVOJE Vzdělávání

Tato prezentace je spolufinancována

Evropským sociálním fondem

a státním rozpočtem České republiky

Identifikace role genu ARR21

- Předpokládaný přenašeč signálu u dvoukomponentního signálního systému *Arabidopsis*
- Mutant identifikován vyhledáváním v databázi inzerčních mutantů (SINS-sequenced insertion site) pomocí programu BLAST



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – izolace inz. mutanta

- vyhledávání v databázi inzerčních mutantů (SINS)

```
Insert_SINS: 01_09_64
Query: 80 tccatgcgttcatgagcgtaaccatacttgacaanagagaacgttagccagcattacagg 139
|||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||||
Sbjct: 58319 tccatgcgttcatgagcgtaaccatacttgacaagagagaacgttagccagcattacagg 58378
Arx21: 1830
```

```
Insert_SINS: 01_09_64
Query: 140 tttgatatcttgtcaaaaatgttttgatttactgt 179
|||||||||||||||||||||||||||||||||||||||||||||||
Sbjct: 58379 tttgatatcttgtcaaaaatgttttgatttactgt 58418
Arr21: 1890
```

- lokalizace inzerce *dSpm* v genomové sekvenci *ARR21* pomocí sekvenace PCR produktů



Identifikace role genu ARR21

- Předpokládaný přenašeč signálu u dvoukomponentního signálního systému *Arabidopsis*
- Mutant identifikován vyhledáváním v databázi inzerčních mutantů (SINS-sequenced insertion site) pomocí programu BLAST
- Exprese *ARR21* u standardního typu a Inhibice exprese u inzerčního mutanta potvrzena na úrovni RNA

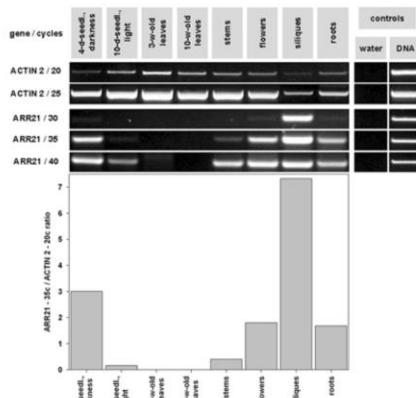


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

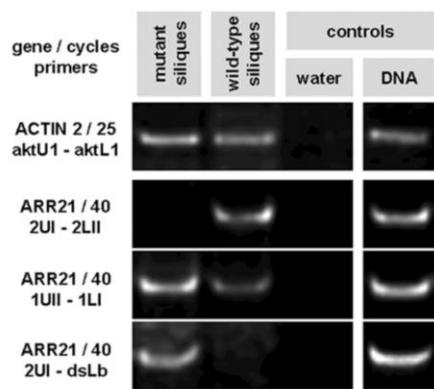
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – analýza exprese

Standardní typ



Inzerční mutant



 MINISTERSTVO ŠKOLSTVÍ
MLÁDEŽE A TĚLOVÝCHOVY



The logo of Masaryk University, featuring a stylized 'M' inside a circle with the text 'UNIVERSITAS MARYKIANA BRUNENSIS' around it.

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu ARR21

- Předpokládaný přenašeč signálu u dvoukomponentního signálního systému *Arabidopsis*
- Mutant identifikován vyhledáváním v databázi inzerčních mutantů (SINS-sequenced insertion site) pomocí programu BLAST
- Exprese *ARR21* u standardního typu a Inhibice exprese u inzerčního mutanta potvrzena na úrovni RNA
- Analýza fenotypu inzečního mutanta

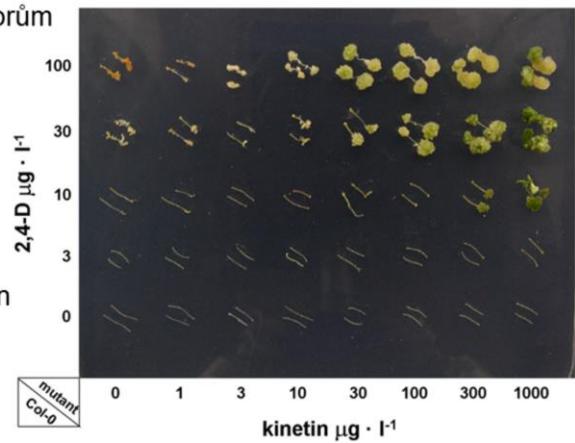


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – analýza fenotypu mutanta

- Analýza citlivosti k regulátorům růstu rostlin
 - 2,4-D a kinetin
 - etylén
 - světlo různých vlnových délek
- Doba kvetení i počet semen nezměněn



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
MASARYKIANA BRNO

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu

ARR21 – příčiny absence fenotypu

- Funkční redundancy v rámci genové rodiny?



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



UNIVERSITAS
MASARYKIANA BRNO

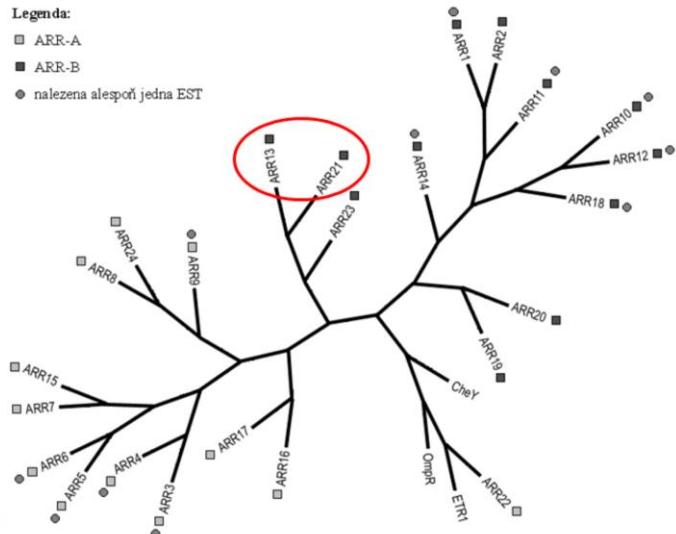
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – příbuznost ARR genů

Legenda:

- ARR-A
- ARR-B
- nalezena alespoň jedna EST



ZVĚŘE VZDĚLÁVÁNÍ

zentrace je spolufinancována
evropským sociálním fondem
a státním rozpočtem České republiky



MINISTERSTVO PRAVOSUDÍ, KULTURY A TĚLOVÝCHOVY

OP Vařenice pro konkurenční prostor



Identifikace role genu

ARR21 – příčiny absence fenotypu

- Funkční redundancy v rámci genové rodiny?
- Fenotypový projev pouze za velmi specifických podmínek (?)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – shrnutí

- Gen *ARR21* identifikován pomocí srovnávací analýzy genomu *Arabidopsis*
- Na základě analýzy sekvence byla předpovězena jeho funkce
- Byla prokázána místně specifická exprese genu *ARR21* na úrovni RNA
- Identifikace funkce genu pomocí inzerční mutageneze v případě *ARR21* ve vývoji *Arabidopsis* byla neúspěšná, pravděpodobně v důsledku funkční redundancy v rámci genové rodiny



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



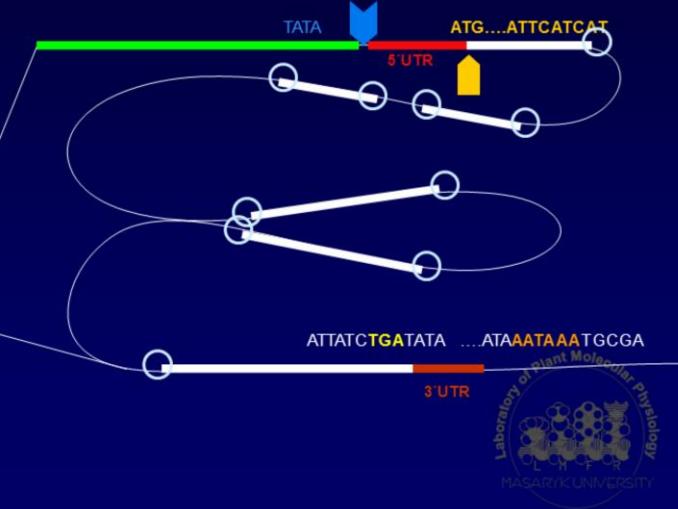
MASARYKIANA BRUNNEN

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

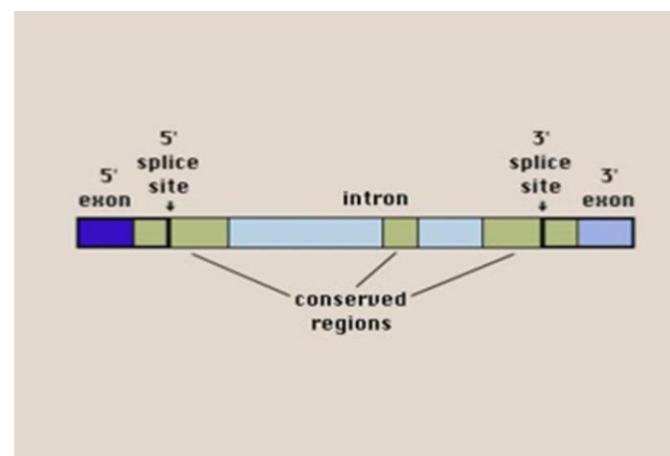
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Struktura genů

- promotor
- počátek transkripce
- 5'UTR
- počátek translace
- místa sestřihu
- stop kodon
- 3'UTR
- polyadenylační signál



Sestřih RNA



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace genů *ab initio*

- zanedbání 5' a 3' UTR
- identifikace počátku translace (ATG) a stop kodonu (TAG, TAA, TGA)
- nalezení donorových (většinou GT) a akceptorových (AG) míst sestřihu
- většina ORF není skutečně kódujícími sekvencemi – u *Arabidopsis* je asi 350 mil. ORF na každých 900 bp (!)
- využití různých statistických modelů (např. Hidden Markov Model, HMM, viz doporučená studijní literatura, Majoros et al., 2003) k posouzení a ohodnocení váhy identifikovaných donorových a akceptorových míst



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Predikce míst sestřihu

- programy pro predikci míst sestřihu
(specifita přibližně 35%)
 - GeneSplicer (http://www.tigr.org/tdb/GeneSplicer/gene_spl.html)
 - SplicePredictor (<http://deepc2.psi.iastate.edu/cgi-bin/sp.cgi>)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Predikce míst sestřihu

BCB @ ISU Bioinformatics 2 Go Download Help Tutorial References Contact

SplicePredictor

- a method to identify potential splice sites in (plant) pre-mRNA by sequence inspection using Bayesian statistical models
(click [here](#) to access the older method using logitlinear models)

Sequences should be in the one-letter-code ({a,b,c,g,h,k,m,n,r,s,t,u,w,y}), upper or lower case; all other characters are ignored during input. Multiple sequence input is accepted in [FASTA](#) format (sequences separated by identifier lines of the form ">SQ:name_of_sequence comments") or in [GenBank](#) format.

Paste your genomic DNA sequence here:

```
GAGGAGGCCACAAATGACGGAATATAACAAATGATCTTAAACAGCTAAACTATATTGGACATTTTTGATCTCAGATATA  
AAAGAATTTCATCAATAATAACTTGGATAAAACTCTTATTTTTCTTAGTTTATTAAAAAAAACCTCTAAATAAT  
ACGAGTTTAAGTCACAAATCGCTTAGACTAAATAACCCATATAATTCAACCGATAAGTTACAAAAGTAATAATCC  
AAGTATCTCATAGTCACACATATATATAGTAATAATTAGTTGACGTTAGAAAAATAAAAATAATAATTAGTATCTTAT  
TTGGGTGGTGTCTGACTGTTGACTGAGATGCTCGGCAAAATGGACCCATATCCCAGAACATGGGTTTGTAGAT
```

[Browse...](#)

... or type in the GenBank accession number of your sequence:



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
MASARYKIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace genů *ab initio*

- programy pro predikci míst sestřihu
(specifita přibližně 35%)
 - GeneSplicer (http://www.tigr.org/tdb/GeneSplicer/gene_spl.html)
 - SplicePredictor (<http://deepc2.psi.iastate.edu/cgi-bin/sp.cgi>)
 - NetGene2 (<http://www.cbs.dtu.dk/services/NetGene2/>)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Predikce míst sestřihu

CENTERFO	0.24%	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%
RBIOLGI	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%
CALSEOU	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%
ENCEANU	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%
LYSIS CBS	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%	0.02%

CBS >> Prediction Servers >> NetGene2

NetGene2 Server

The NetGene2 server is a service producing neural network predictions of splice sites in human, *C. elegans* and *A. thaliana*.

Instructions

Output format

Abstract

Performance

SUBMISSION

Submission of a local file with a single sequence:

File in **FASTA** format

Human

C. elegans

A. thaliana

Submission by pasting a single sequence:

Sequence name

Human

C. elegans

A. thaliana

Sequence

```
GAGGGAGGCACAAAATGACGAATATAACAAATGATCTTAAACAGCTAAACTATATTGGACATTTCGATC  
TCAGATATA  
AAAGATTTCATCAATAATAACTTGGATAAAACTCTCTTATTTTTTCTTAGTTATTAACAAAAACCT  
CTATAAAT  
ACGAGTTAACGTCACAAATCGCTTAGACTAAAATCACCATATAATTCAAACGATAAAAGTTACAAAA
```

DO ROZVOJE Vzdělávání

Tato prezentace je spolufinancována

Evropským sociálním fondem

a státním rozpočtem České republiky



EVROPSKÁ UNIE

esf

Predikce míst sestřihu

Prediction done

***** NetGene2 v. 2.4 *****

The sequence: Sequence has the following composition:

Length: 9490 nucleotides.

31.8% A, 17.0% C, 19.4% G, 31.7% T, 0.0% K, 36.5% G+C

Donor splice sites, direct strand

pos 5'=>3'	phase	strand	confidence	5'	exon	intron	3'
1	0	+	0.87	TTCACAAACAGTATTTT			
1906	0	+	0.99	CCTGTGACGCGTTCACACAT			
3582	1	+	1.00	GCGGTTCTAGGTTAATTTT			
2765	1	+	1.00	GGCTTGTGTTGTTAATTTT			
411	0	+	0.74	TCAACACAGCCTTGTTTAAA			
4619	1	+	0.74	AGCAAGAAAGTGTGTTTAA			
4915	0	+	0.94	CGTTCCTCTGTTAAATCTG			
5356	0	+	0.87	TCTCAACCAAATGTAATTTT			
5384	1	+	1.00	GATTGGTGTGTTAAAGACTT			
3899	1	+	1.00	TCTTGTGTTGTTAAATTTT			
6057	0	+	1.00	GCAGCTTGTGTTAACTACT			
6096	1	+	0.74	CTCTTCACAAATGAACTAG			
7369	0	+	1.00	GGACTCCCAAATGAACTAA			
7886	0	+	0.74	GAACAAATGTTAGATGAA			
7933	0	+	0.74	GAAGAATGTTAGTTCCTC			

Donor splice sites, complement strand

pos 3'=>5'	phase	strand	confidence	5'	exon	intron	3'
1	0	+	0.59	TATTTTTTATTTTATGAGAC			
1221	2	+	0.77	ACTTGTGTTGTCACACATG			
1373	0	+	0.71	TCTCTCACACGTCACAGAT			
1487	1	+	0.81	ATATTGATGTTGGACATTA			
3284	0	+	0.87	GTCATCACATGTTGTTTCACT			
4254	0	+	1.00	TGTTCCTCCATGTCGACCAT			
4812	2	+	0.54	AAAATTCACGTTGTTGTTG			
5004	0	+	0.74	TTCATTCACGTTGATACAC			
5472	1	+	0.96	AAAATTCACGTTCTGCTCAA			
6135	0	+	1.00	ATTATATGTTGTAGATTTA			
6490	1	+	0.90	AAAGTTACAGTTGGGAGAA			
6744	0	+	0.59	TOTCAACACGTTTCCTAGAO			
7447	0	+	0.76	TTCATTTCCATACAGACAA			
7780	2	+	0.76	TCAGATACACGTTACACATCA			
7786	2	+	0.92	TCAGATACACGTTACACATCA			

Acceptor splice sites, direct strand

pos 5'=>3'	phase	strand	confidence	5'	introm	exon	3'
1	0	+	0.59	TATTTTTTATTTTATGAGAC			
1221	2	+	0.77	ACTTGTGTTGTCACACATG			
1373	0	+	0.71	TCTCTCACACGTCACAGAT			
1487	1	+	0.81	ATATTGATGTTGGACATTA			
3284	0	+	0.87	GTCATCACATGTTGTTTCACT			
4254	0	+	1.00	TGTTCCTCCATGTCGACCAT			
4812	2	+	0.54	AAAATTCACGTTGTTGTTG			
5004	0	+	0.74	TTCATTCACGTTGATACAC			
5472	1	+	0.96	AAAATTCACGTTCTGCTCAA			
6135	0	+	1.00	ATTATATGTTGTAGATTTA			
6490	1	+	0.90	AAAGTTACAGTTGGGAGAA			
6744	0	+	0.59	TOTCAACACGTTTCCTAGAO			
7447	0	+	0.76	TTCATTTCCATACAGACAA			
7780	2	+	0.76	TCAGATACACGTTACACATCA			
7786	2	+	0.92	TCAGATACACGTTACACATCA			



MINISTERSTVO VZDĚLÁVÁNÍ
MLÁDEŽE A TĚLOVÝCHOVY

OP Vašeho dne
pro konkurenčního prostředí



INVESTICE DO ROZVOJE Vzdělávání

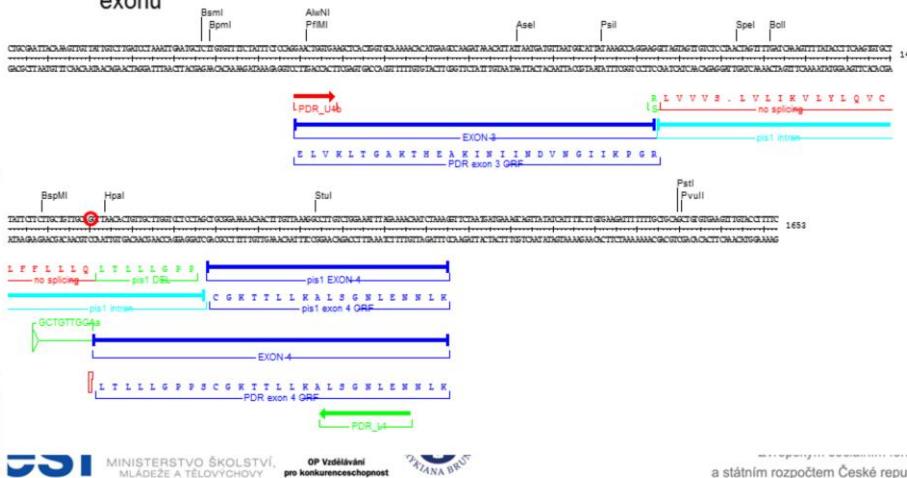
Tato prezentace je spolufinancována

Evropským sociálním fondem

a státním rozpočtem České republiky

Sestřih RNA a adaptace

- odchylky rozpoznávání míst sestřihu u rostlin v praxi - příklad vývojové plasticity (nejen) rostlin
 - identifikace mutanta s bodovou mutací (tranzice G→A) přesně v místě sestřihu na 5' konci 4. exonu



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

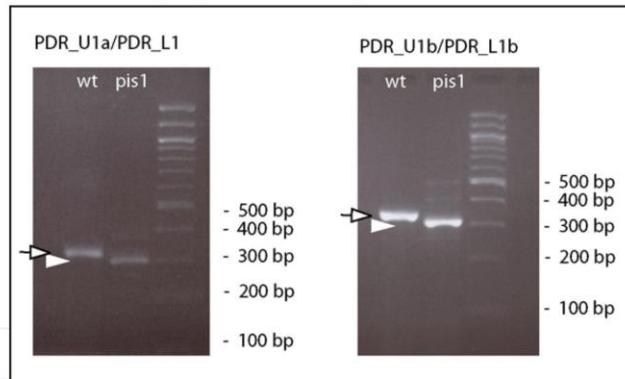
OP Vzdělávání
pro konkurenčnost



a státním rozpočtem České republiky

Sestřih RNA a adaptace

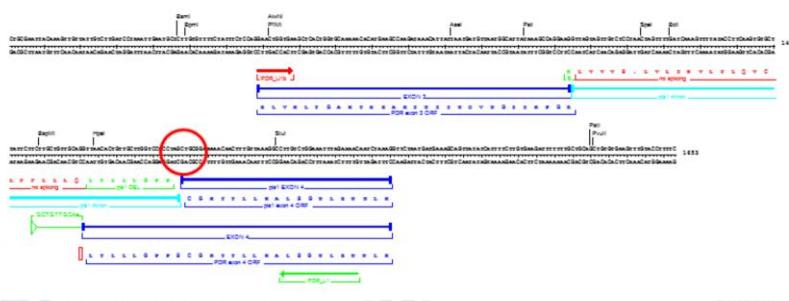
- identifikace mutanta s bodovou mutací (tranzice G→A) přesně v místě sestřihu na 5' konci 4. exonu
- analýza pomocí RT PCR prokázala přítomnost fragmentu kratšího než by odpovídalo cDNA po normálním sestřihu



ROZVOJE Vzdělávání
do prezentace a spolufinancováno
Evropským sociálním fondem
a státním rozpočtem České republiky

Sestřih RNA a adaptace

- odchylky rozpoznávání míst sestřihu u rostlin v praxi - příklad vývojové plasticity (nejen) rostlin
 - identifikace mutanta s bodovou mutací (tranzice G→A) přesně v místě sestřihu na 5' konci 4. exonu
 - analýza pomocí RT PCR prokázala přítomnost fragmentu kratšího než by odpovídalo cDNA po normálním sestřihu
 - sekvenace tohoto fragmentu pak ukázala na alternativní sestřih s využitím nejbližšího možného místa sestřihu v exonu 4



EUROPSKÁ UNIE
ESF

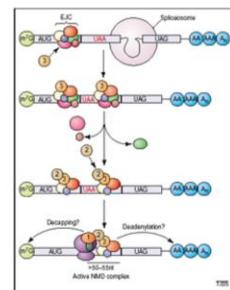
MUZIKANT PRO ROSTLINY
MILÍČENÍ A VÝUČBA

GP Vzdělávání
pro konkurenčního

DĚLÁVÁNÍ
finančováno
zřízením fondem
a státním rozpočtem České republiky

Sestřih RNA a adaptace

- odchylky rozpoznávání míst sestřihu u rostlin v praxi - příklad vývojové plasticity (nejen) rostlin
 - identifikace mutanta s bodovou mutací (tranzice G→A) přesně v místě sestřihu na 5' konci 4. exonu
 - analýza pomocí RT PCR prokázala přítomnost fragmentu kratšího než by odpovídalo cDNA po normálním sestřihu
 - sekvenace tohoto fragmentu pak ukázala na alternativní sesříh s využitím nejbližšího možného místa sestřihu v exonu 4
 - existence podobných obranných mechanizmů prokázána i u jiných organismů (např. nestabilita mutantní mRNA se vznikem předčasného stopkodonu (> 50-55 bp před normálním stop kodonem) u eukaryot, viz doporučená studijní literatura, Singh and Lykke-Andersen, 2003)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



MASARYKIANA
UNIVERSITAS
BRUNNEN

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace genů *ab initio*

- programy pro predikci exonů
 - 4 typy exonů (podle polohy):
 - iniciační
 - vnitřní
 - terminální
 - jednoduché
 - programy kromě rozpoznávání míst sestřihu zohledňují i strukturu jednotlivých typů exonů
- iniciační:
 - Genescan (<http://genes.mit.edu/GENSCAN.html>)
 - GeneMark.hmm (<http://opal.biology.gatech.edu/GeneMark/>)
- interní:
 - MZEF (<http://rulai.cshl.org/tools/genefinder/>)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

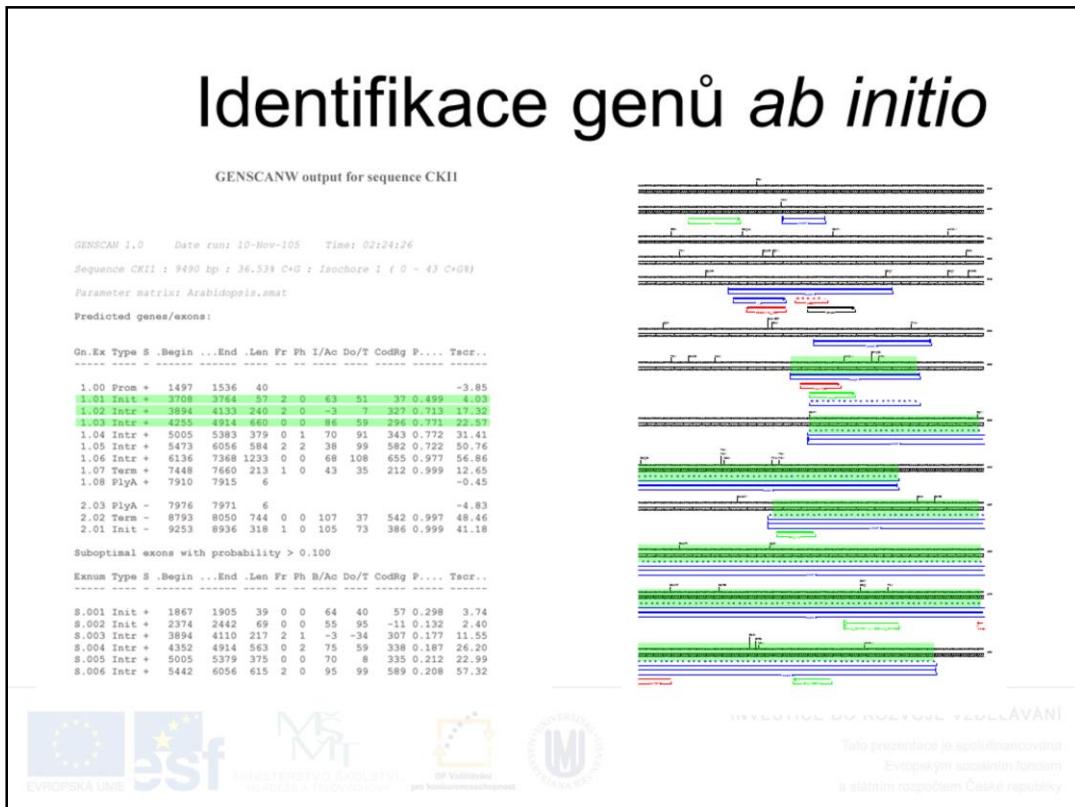


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace genů *ab initio*

Identifikace genů *ab initio*



Explanation Gn.Ex : gene number, exon number (for reference) **Type :** Init = Initial exon (ATG to 5' splice site) Intr = Internal exon (3' splice site to 5' splice site) Term = Terminal exon (3' splice site to stop codon) Sngl = Single-exon gene (ATG to stop) Prom = Promoter (TATA box / initiation site) PlyA = poly-A signal (consensus: AAAAA) S : DNA strand (+ = input strand; - = opposite strand) **Begin :** beginning of exon or signal (numbered on input strand) **End :** end point of exon or signal (numbered on input strand) **Len :** length of exon or signal (bp) Fr : reading frame (a forward strand codon ending at x has frame x mod 3). For example, if nucleotides 1,2,3 of the sequence are read as a codon, that's called reading frame 0. If 2,3,4 are read as a codon, that's reading frame 1. If 3,4,5 are read as a codon, that's reading frame 2, and so on. This information, together with the starting and ending positions of the exon, is sufficient to give the amino acid sequence encoded by the exon. Another use of the reading frame is that if you see two adjacent predicted exons separated by a relatively short intron which share the same reading frame, it may be worth looking at the possibility that the intervening intron is not correct, i.e. that the two exons plus the intervening intron might form one long exon (assuming there are no inframe stops in the intron, of course). Ph : net phase of exon (exon length modulo 3). For example, an exon of length 15 bp has net phase 0 since 15 is divisible by 3, an exon of length 16 bp has net phase 1 because 16 divided by 3 leaves a remainder of 1, an exon of length 17 bp has net phase 2, and an exon of length 18 bp has net phase 0 again. The point of this is that exons whose net phase is 0 can be omitted from the gene without disrupting the reading frame: such exons are candidates for being either 1) incorrect, or 2) alternatively spliced. I/Ac : initiation signal or 3' splice site score (tenth bit units; x 10). If below zero, probably not a real acceptor site. Do/T : 5' splice site or termination signal score (tenth bit units; x 10) If below zero, probably not a real donor site. CodRg : coding region score (tenth bit units) P : probability of exon (sum over all parses containing exon). This quantity is close to the actual probability that the predicted exon is correct. Tscr : exon score (depends on length, I/Ac, Do/T and CodRg scores).

Comments The SCORE of a predicted feature (e.g., exon or splice site) is a log-odds measure of the quality of the feature based on local sequence properties. For example, a predicted 5' splice site with score > 100 is strong; 50-100 is moderate; 0-50 is weak; and below 0 is poor (more than likely not a real donor site). The PROBABILITY of a predicted exon is the estimated probability under GENSCAN's model of genomic sequence structure that the exon is correct. This probability depends in general on global as well as local sequence properties, e.g., it depends on how well the exon fits with neighboring exons. It has been shown that predicted exons with higher probabilities are more likely to be correct than those with lower probabilities.

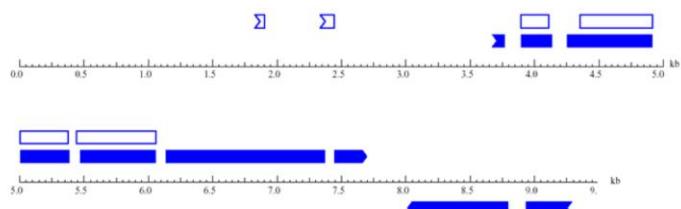
What are the suboptimal exons?

Under the probabilistic model of gene structural and compositional properties used by GENSCAN, each possible "parse" (gene structure description) which is compatible with the sequence is assigned a probability. The default output of the program is simply the "optimal" (highest probability) parse of the sequence. The exons in this optimal parse are referred to as "optimal exons" and the translation products of the corresponding "optimal genes" are printed as GENSCAN predicted peptides. (All the data in our J Mol Biol paper and on the other GENSCAN web pages refer exclusively to the optimal parse/optimal exons.) Of course, the optimal parse does not always correspond to the actual (biological) parse of the sequence, that is, the actual set of exons/genes present. In addition, there may be more than one parse which can be considered "correct", for example, in the case of a gene which is alternatively transcribed, translated or spliced. For both of these reasons, it may be of interest to consider "suboptimal" ("near-optimal") exons as well, i.e. exons which have reasonably high probability but are not present in the optimal parse. Specifically, for every potential exon E in the sequence, the probability P(E) is defined as the sum of the probabilities under the model of all possible "parses" (gene structures) which contain the exact exon E in the correct reading frame. (This quantity is calculated as described on the [GENSCAN exon probability page](#).) Given a probability cutoff C, suboptimal exons are those potential exons with P(E) > C which are not present in the optimal parse.

Suboptimal exons have a variety of potential uses. First, suboptimal exons sometimes correspond to real exons which were missed for whatever reason by the optimal parse of the sequence. Second, regions of a prediction which contain multiple overlapping and/or incompatible optimal and suboptimal exons may in some cases indicate alternatively spliced regions of a gene (Burge & Karlin, in preparation). The probability cutoff C used to determine which potential exons qualify as suboptimal exons can be set to any of a range of values between 0.01 and 1.00. The default value on the web page is 1.00, meaning that no suboptimal exons are printed. For most applications, a cutoff value of about 0.10 is recommended. Setting the value much lower than 0.10 will often lead to an explosion in the number of suboptimal exons, most of which will probably not be useful. On the other hand, if the value is set much higher than 0.10, then potentially interesting suboptimal exons may be missed.

Identifikace genů *ab initio*

GENSCAN predicted genes in sequence 02:56:23



Key:

Initial exon Internal exon Terminal exon Single-exon gene

Optimal exon Suboptimal exon



MINISTERSTVO REGIONÁLNÍHO VLASTNICTVÍ
OPERATIVNÍ PROGRAM PRO REGIONÁLNU
ROZVITOK A TERRITORIALE VLASTNOSTI

OP Vlastnictví
pro konkurenčního vývoje



OZVOJE Vzdělávání

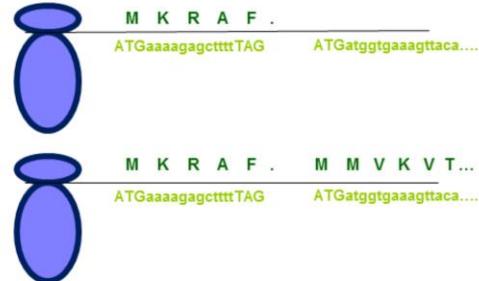
inzenářce a spoluřízenec vzdělání

Evropským sociálním fondem

a státním rozpočtem České republiky

Regulace translace

- Funkční význam sestřihu v nepřekládaných oblastech - důležitá regulační součást genů
 - Translační represe prostřednictvím krátkých ORF v 5'UTR
 - Identifikováno např. u kukuřice (Wang and Wessler, 1998, viz doporučená lit.)
 - V případě CKI1 pokus prokázat tento způsob regulace genové exprese pomocí transgenních linií nesoucích *uidA* pod kontrolou dvou verzí promotoru, zatím nepotvrzeno



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

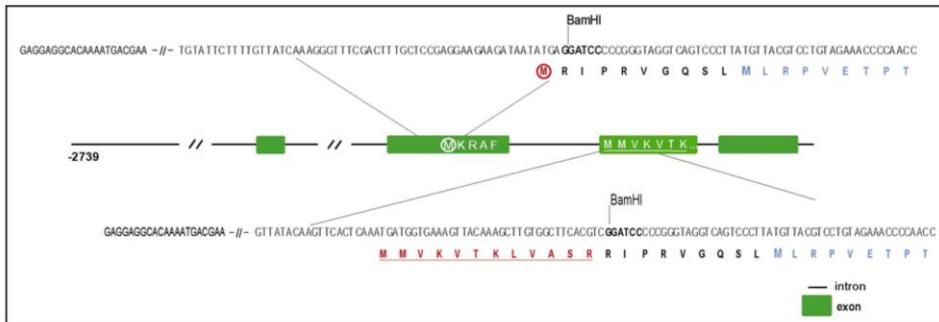


INVESTICE DO ROZVOJE Vzdělávání

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Regulace translace

- Funkční význam sestřihu v nepřekládaných oblastech - důležitá regulační součást genů
- V případě CKI1 pokus prokázat tento způsob regulace genové exprese pomocí transgenních linií nesoucích *uidA* pod kontrolou dvou verzí promotoru, zatím nepotvrzeno



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Genové modelování

- programy pro genové modelování
 - zohledňují také další parametry, např. návaznost ORF
 - Genescan (<http://genes.mit.edu/GENSCAN.html>)
velice dobrý pro predikci exonů v kódujících oblastech
(testováno na genu *PDR9*, identifikoval všech 23 (!) exonů)
 - GeneMark.hmm (<http://opal.biology.gatech.edu/GeneMark/>)
 - GlimmerHMM (<http://ccb.jhu.edu/software/glimmerhmm/>)



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace genů *ab initio*

GeneMark™
A family of gene prediction programs provided by Mark Borodovsky's Bioinformatics Group at the Georgia Institute of Technology, Atlanta, Georgia.

Gene Prediction in Bacteria and Archaea
For bacterial and archaeal gene prediction, you can use the parallel combination of the GeneMark and GeneMark.hmm programs [here](#).

If the DNA sequence of interest belongs to a species whose name is not in the list of available models, you should use either the [Heuristic models](#) option, or, if the sequence is longer than 1 Mb, generate a self-training program [GeneMarkS](#). Both options will allow you to generate models and then to use GeneMark.hmm and GeneMark in parallel.

Gene Prediction in Eukaryotes
For eukaryotic gene prediction, you can use the parallel combination of the GeneMark and GeneMark.hmm programs [here](#).

Gene Prediction in EST and cDNA
To analyze ESTs and cDNAs, please follow [this link](#).

Gene Prediction in Viruses
For viral gene prediction, or to access our virus database [VIOLIN](#), please follow [this link](#).

What the programs do:

EVROPSKÁ UNIE
 esf
 MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY
OP Vzdělávání
pro konkurenčeschopnost

LIAZ
UNIVERSITY
MASARYKIANA BRNO

What's New - November, 2005
Predictors: predicted gene database
Prokaryotes: models for GeneMark and GeneMark.hmm

Supported by NIH

Eukaryotic GeneMark.hmm^(1,2) ([Release this week](#))

References:
1Borodovsky M. and Lukashin A. (unpublished)
2Lomadze A., Ter-Hovhannisyan V., Chernoff Y. and Borodovsky M., "Gene prediction in novel eukaryotic genomes by self-training algorithm", *Nucleic Acids Research*, 2003, Vol. 31, No. 20, 6494-6506

Accuracy comparison

UPDATE October 2005. Added pre-built models of eukaryotic GeneMark.hmm ES-3.0 (E - eukaryotic; S - self-training; 3.0 - the version)

Links of previous updates

Input Sequence
Title (optional):

Sequence:

Species: [Archaea ES-3.0](#) [Model description](#)

Output Options
Email Address: (required for graphical output or sequences longer than 400000 bp)

Generate PDF graphics (screen)
 Generate PostScript graphics (email)
 Print GeneMark 2.4 predictions in addition to GeneMark.hmm predictions
 Translate predicted genes into protein

Run

LÁVÁNÍ

nancována

Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace genů *ab initio*

Result of last submission:

[View PDF Graphical Output](#)

[GeneMark.hmm Listing](#)

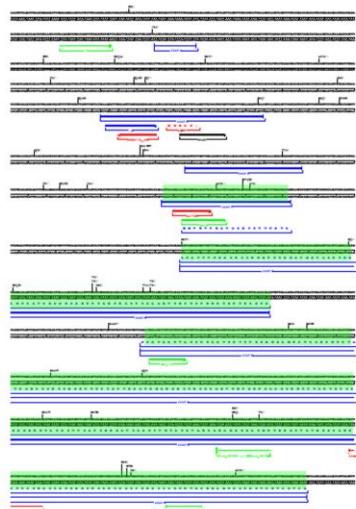
[Go to: GeneMark.hmm Protein Translations](#)

[Go to: Job Submission](#)

Dukazitoyc GeneMark.hmm version bp 0.9 April 25, 2008
Sequence name: CK11
Sequence length: 1040 bp
G+C content: 38.79%
Matrices file: /home/gennmark/euk_ghm.matrices/ambaliana_hmm0.0mod
Thu Oct 1 11:09:24 2009

Predicted genes/exons

Gene	Exon	Strand	Exon Type	Exon Range	Exon Length	Start/End Frame
1	1	+	Initial	869 1025	57	1 2 - -
1	2	+	Internal	1155 1294	240	1 3 - -
1	3	+	Internal	1516 2175	660	1 3 - -
1	4	+	Internal	2266 2644	379	1 1 - -
1	5	+	Internal	2704 3017	313	2 2 - -
1	6	+	Internal	3297 4629	1232	1 3 - -
1	7	+	Terminal	4709 4921	212	1 3 - -



/ZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky



Identifikace genů *ab initio*

Result of last submission:

[View PDF Graphical Output](#)

[GeneMark.hmm Listing](#)

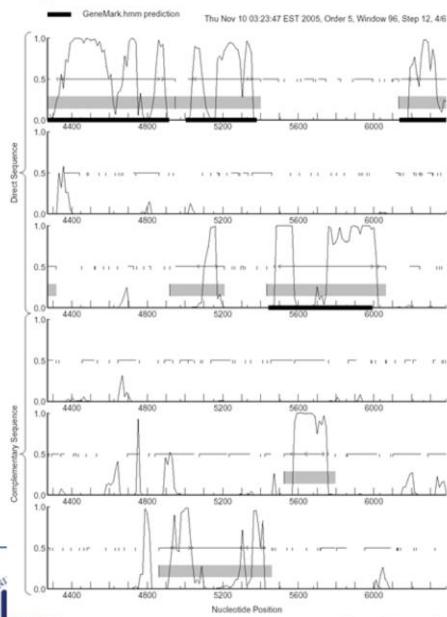
[Go to: GeneMark.hmm Protein Translations](#)

[Go to: Job Submission](#)

Dukariotyc GeneMark.hmm version bp 0.9 April 25, 2008
Sequence name: CK11
Sequence length: 6040 bp
G+C content: 38.79%
Matrices file: /home/gennmark/euk_ghm.matrices/ambaliana_hmm0.0mod
Thu Oct 1 11:09:24 2009

Predicted genes/exons

Gene	Exon #	Strand	Exon Type	Exon Range	Exon Length	Start/End Frame
1	1	+	Initial	869	1025	57 1 2 - -
1	2	+	Internal	1155	1094	240
1	3	+	Internal	1516	2175	660
1	4	+	Internal	2266	2644	379
1	5	+	Internal	2794	3017	584
1	6	+	Internal	3297	4629	1232
1	7	+	Terminal	4709	4921	212



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



ÁVÁNÍ

ancována

Evropským sociálním fondem
a státním rozpočtem České republiky

Genové homologie

- vyhledávání genů podle homologí
- porovnávání s EST databázemi
 - BLASTN (<http://www.ncbi.nlm.nih.gov/BLAST/>, <http://workbench.sdsc.edu/>)
- porovnávání s proteinovými databázemi
 - BLASTX (<http://www.ncbi.nlm.nih.gov/BLAST/>, <http://workbench.sdsc.edu/>)
 - Genewise (<http://www.ebi.ac.uk/Wise2/>)
porovnávají proteinovou sekvenci s genomovou DNA (po zpětném překladu), je nutná znalost aminokyselinové sekvence
- porovnávání s homologními genomovými sekvencemi z příbuzných druhů
 - VISTA/AVID (<http://www.lbl.gov/Tech-Transfer/techs/lbnl1690.html>)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání
 - genomová kolinearity a genová homologie



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Genomová kolinearita

- genomy **příbuzných druhů** se přes značné odlišnosti vyznačují **podobnostmi v uspořádání i sekvencích**, možnost využití při **identifikaci genů u příbuzných organizmů** pomocí vyhledávání v databázích
- obecné schéma postupu při využívání geonomové kolinearity (také „komparativní genomika“) při experimentální identifikaci genů příbuzných organizmů:
 - **mapování malých genomů** s využitím nízkokopiových DNA markerů (např. RFLP)
 - **využití těchto markerů k identifikaci orthologních genů** (genů se stejnou nebo podobnou funkcí) příbuzného organizmu
 - **malý genom** (např. rýže, 466 Mbp) může sloužit jako **vodítko**, kdy jsou identifikovány **molekulární nízkokopiové markery** (např. RFLP) ve **vazbě s genem zájmu** a tyto oblasti jsou pak **použity jako sonda** při vyhledávání v **BAC knihovnách** při identifikaci **orthologních oblastí velkých genomů** (např. ječmene nebo pšenice, 5000, resp. 16000 Mbp)

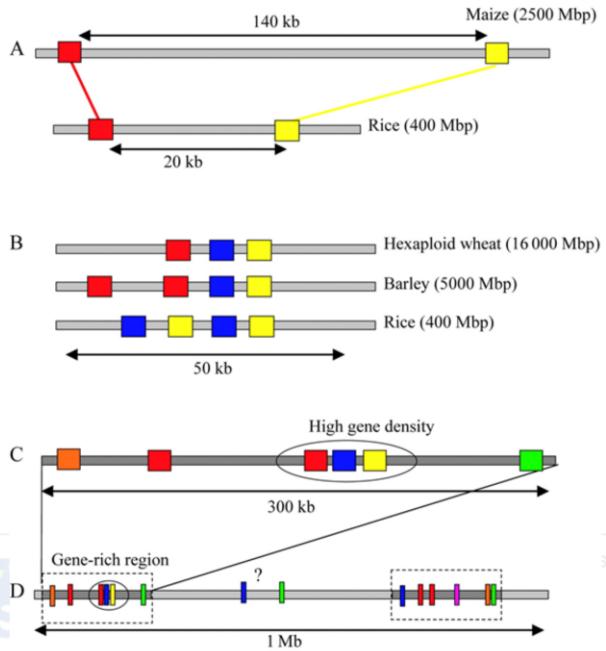


MÍSTNÍ VÝROBEC
PROJEKT
MÍSTNÍ VÝROBEC
PROJEKT



INVESTICE DO ROZVOJE Vzdělávání
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Genomová kolinearita



Feuillet and Keller, 2002

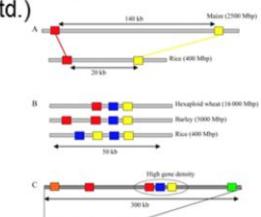
STÍČCE DO ROZVOJE Vzdělávání

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky



Genomová kolinearita

- zejména využitelné u trav (např. využití příbuznosti u ječmene, pšenice, rýže a kukuřice)
- malé genomové přestavby (dalece, duplikace, inverze a translokace menší než několik CM) jsou pak detekovány podrobnou sekvenční komparativní analýzou
- během evoluce dochází u příbuzných druhů k odchylkám především v nekódujících oblastech (invaze retrotranspozonů atd.)



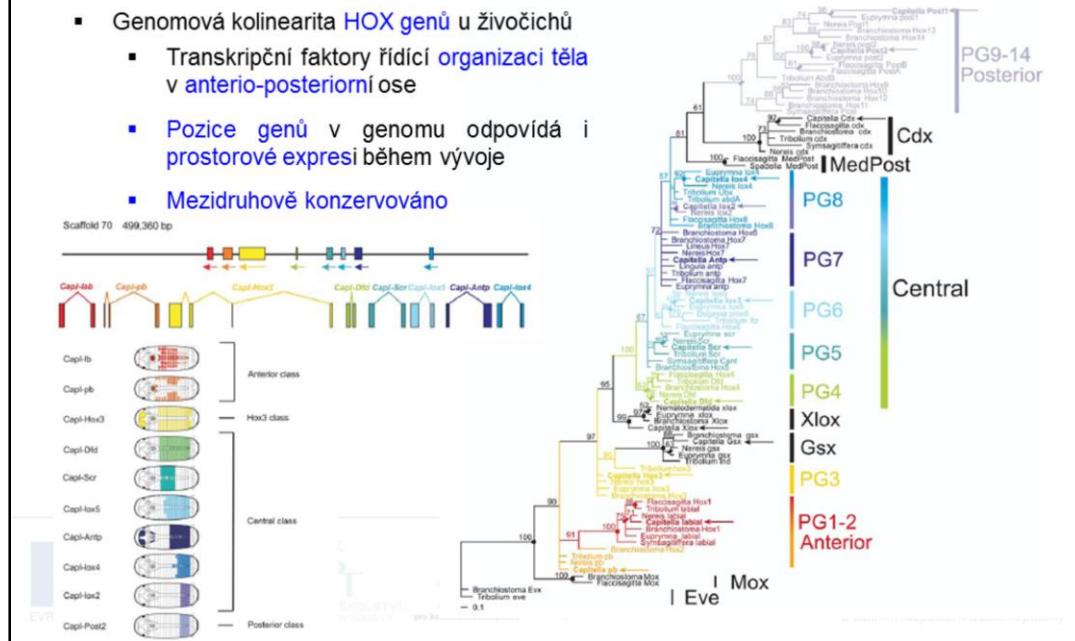
INVESTICE DO KUZOVUJE VZDELAVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky



Genomová kolinearita

- Genomová kolinearita **HOX genů** u živočichů
 - Transkripční faktory řídící **organizaci těla** v **anterio-posteriorní ose**
 - Pozice genů v genomu odpovídá i **prostorové exprese** během vývoje
 - Mezidruhově konzervováno



Genomic organization of the *Capitella* sp. I Hox cluster. A total of 11 *Capitella* sp. I Hox genes are distributed among three scaffolds. Black lines depict two scaffolds, which contain 10 of the *Capitella* sp. I Hox genes. The eleventh gene, *CapI-Post1*, is located on a separate scaffold surrounded by ORFs of non-Hox genes (unpublished data). No predicted ORFs were identified between adjacent linked Hox genes. Transcription units are shown as boxes denoting exons, connected by lines that denote introns. Transcription orientation is denoted by arrows beneath each box. Color coding is the same as that used in on the right-hand side for each ortholog.

The phylogenetic tree on the right-hand side shows that the order of the genes on the chromozome is retained in several species (genome colinearity).

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání
 - genomová kolinearita a genová homologie
- Experimentální identifikace genů
 - příprava genově obohacených knihoven pomocí technologie metylačního filtrování



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Metylační filtrování

- příprava genově obohacených knihoven pomocí technologie metylačního filtrování
- geny jsou (většinou!) **hypometylované**, kdežto nekódující oblasti jsou **metylované**
- využití bakteriálního RM systému, který rozpoznává metylovanou DNA pomocí rest. enzymů McrA a McrBC
 - McrBC rozpoznává v DNA metylovaný cytozin, který předchází purin (G nebo A)
 - pro štěpení je nutná vzdálenost těchto míst z 40-2000 bp



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Metylační filtrování

- příprava genově obohacených knihoven pomocí technologie metylačního filtrování
- schéma postupu při přípravě BAC genomových knihoven pomocí metylačního filtrování:
 - příprava genomové DNA bez příměsi organelární DNA (chloroplasty a mitochondrie)
 - fragmentace DNA (1-4 kbp) a ligace adaptérů
 - příprava BAC knihovny v mcrBC+ kmeni *E. coli*
 - selekce pozitivních klonů
- omezené využití: obohacení o kódující DNA o pouze cca 5-10 %



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání
 - genomová kolinearita a genová homologie
- Experimentální identifikace genů
 - příprava genově obohacených knihoven pomocí technologie metylačního filtrování
 - EST knihovny



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



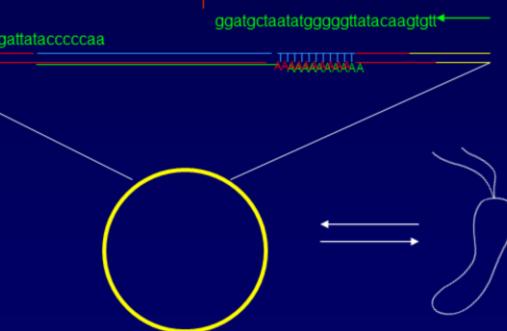
MASARYKIANA BRUNNEN

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

EST knihovny

- příprava EST knihoven
 - izolace mRNA
 - RT
 - ligace linkerů a syntéza druhého řetězce cDNA
 - klonování do vhodného bakteriálního vektoru
 - transformace do bakterií a izolace DNA (amplifikace DNA)
 - sekvenace s použitím primerů specifických pro použitý plasmid
 - uložení výsledků sekvenace do veřejné databáze



Základy genomiky II, Identifikace genů

Shrnutí

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání
 - genomová kolinearity a genová homologie
- Experimentální identifikace genů
 - příprava genově obohacených knihoven pomocí technologie metylačního filtrování
 - EST knihovny
 - přímá a reverzní genetika (přednáška 03)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Diskuse



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost



UNIVERSITAS
MASARYKIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky