

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



UNIVERSITAS
MASARYKIANA BRUNNENSIS

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, Economy, and Unveil: three ab initio eukaryotic genefinders. *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)
- Fribius, 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



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
- Experimentální identifikace genů
 - příprava genově obohacených knihoven pomocí technologie metylačního filtrování
 - EST knihovny
 - přímá a reverzní genetika



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
SAPientIAE
JANAE
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



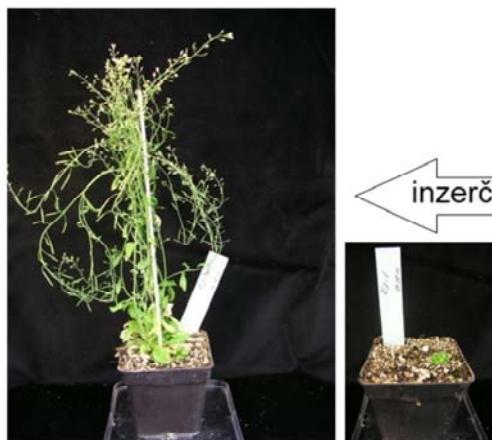
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Přímá vs. reverzní genetika

Revolute v chápání pojmu genu

Přístupy „klasické“ genetiky

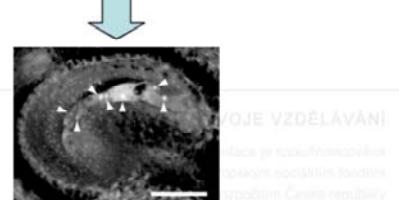
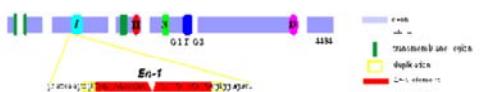
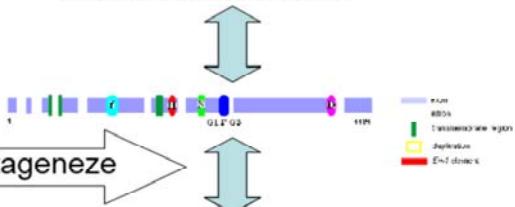


3 : 1



„Reverzně geneticky“ přístup

5' TTATATATATATATTAAAAAATAAAATAAAA
GAACAAAAAGAAAATAAAATA...3'



Identifikace role genu *ARR21*

- Předpokládaný přenašeč signálu u dvoukomponentního signálního systému *Arabidopsis*



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

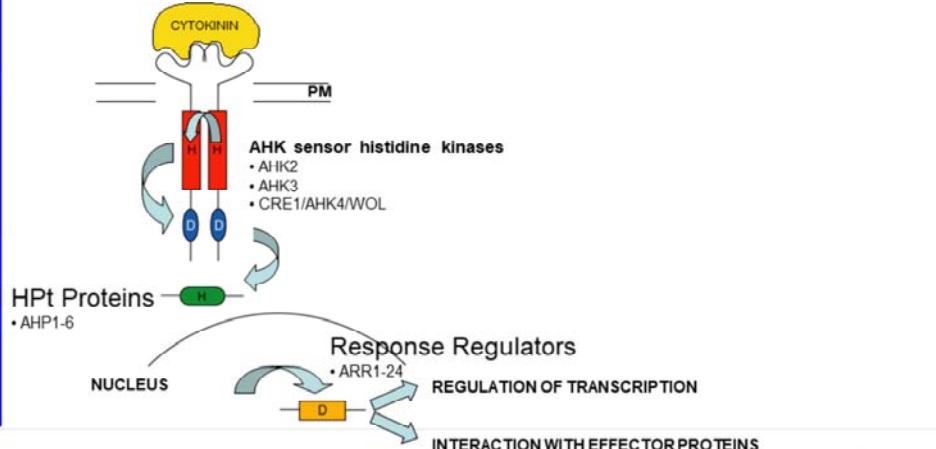


INVESTICE DO ROZVOJE Vzdělávání

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

Identifikace role genu *ARR21*

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



INVESTICE DO ROZVOJE Vzdělávání

Tato akce je podpořena v rámci
Evropských sociálních fondů
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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

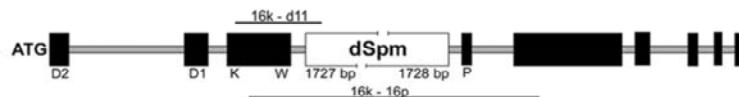
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – izolace inz. mutanta

- vyhledávání v databázi inzerčních mutantů (SINS)

```
Insert_SINS: 01_09_64
Query: 80 tcctagcggtcatgagcgtaccatacttgacaanagagaacgtggccatgg 139
Sbjct: 58319 tcctagcggtcatgagcgtaccatacttgacaagagagaacgtggccatgg 58378
Arr21: 1830
```

- 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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



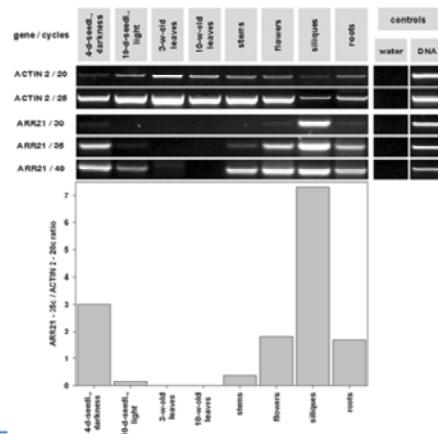
UNIVERSITAS
SANT'ANNA
BRNO

INVESTICE DO ROZVOJE Vzdělávání

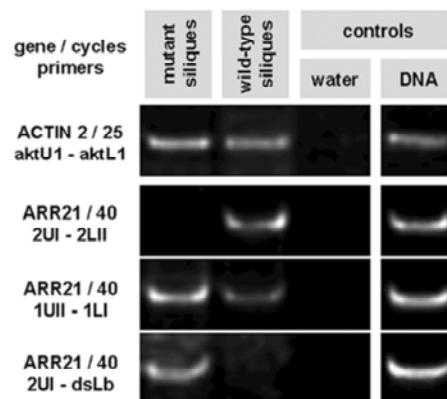
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Identifikace role genu *ARR21* – analýza exprese

Standardní typ



Inzerční mutant



EVROPSKÁ UNIE



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*

- 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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



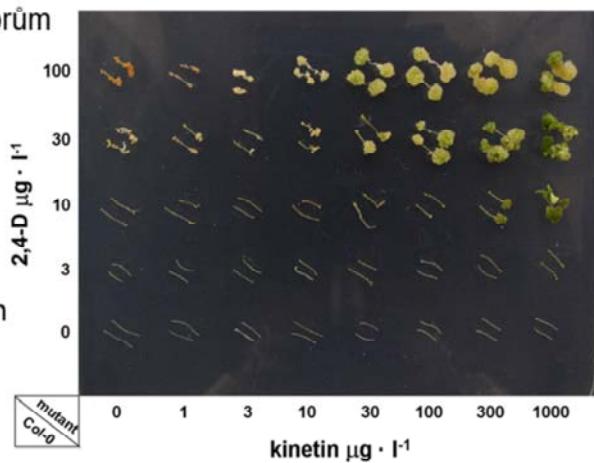
UNIVERSITAS SANT'ANNA BRUNELLA

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
SANT'ANNA
BRUNELLA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Identifikace role genu *ARR21* – příčiny absence fenotypu

- Funkční redundance 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

Identifikace role genu *ARR21* – příbuznost ARR genů

Legenda:

□ ARR-A

■ ARR-B

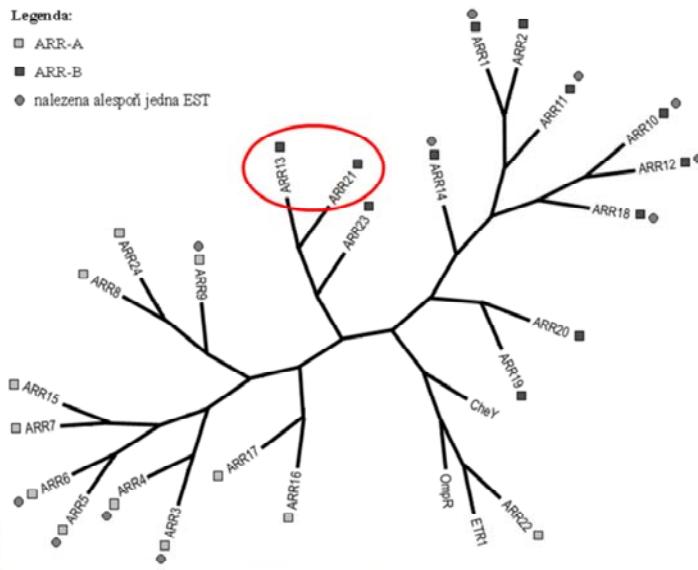
● nalezena alespoň jedna EST



MINISTERSTVO REGIONALNÉHO VÝROVNU
URZENIE A INOVÁCIÍ

OPERATÍVNA PROGRAMA
PRE SPOLEČNOSŤNÚ KONKURENCIALNOST

OPERATÍVNA PROGRAMA
PRE VEDOMOSTNÝ ROK



ZVÖJE VZDĚLÁVÁNÍ

zrealizované je s podporou celku

europejským sociálním fondom

a státním rozpočtem České republiky

Identifikace role genu *ARR21* – příčiny absence fenotypu

- Funkční redundance 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 redundance v rámci genové rodiny



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
SANT'ANNA
BRUNELLA

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 přistupech k identifikaci genů a jejich funkcí
- Identifikace genů *ab initio*
 - struktura genů a jejich vyhledávání



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
SANT'ANNA
BRNO

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

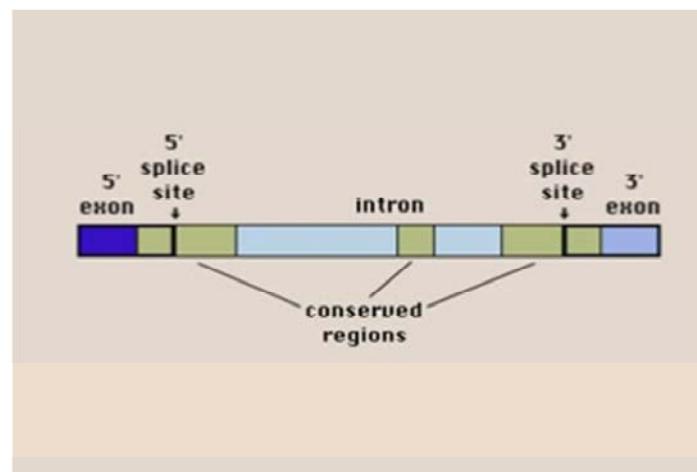
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Struktura genů

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



Sestřih RNA



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



UNIVERSITAS
SANT'ANNA
BRUNELLA

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_sp1.html)
 - SplicePredictor (<http://depc2.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

SplicePredictor

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:

```
GAAGGAGGCACAAATGACGAATATAACAAATGACTCTAACACTATATTGGACATTTTCGATCTCAGATATA  
AAAGATTCATTCAATATAACTCTGGATAAATACTCTTATTATTTCTTAGTTTAAACCTCTAATAAAAT  
ACGAGTTAACGTCACAAAATCGCTTGACTAAACATACCCATATAATTCAACGATAAAGTTACAAAAGTAATATCC  
AAGTATCTCATAGTCACACATATAATTAGTAAATAATTAGTTGACGTATAAGAAAATAAAAATAAAATTAGTATCTTAT  
TTTGGGTGTTGACTGGTGACTGGTGACTGCAAGATGCTCGGCCAAATGGAACCATATCCCAGACATGGGTTTGGAT
```

... or upload your sequence file (specify file name):

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



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://depc2.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

NetGene 2



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

```
GAGGAGGCACAAAATGACGAATATAAAATGATCTTAAACAGCTAAACTATATTGGACATTTTCGATC  
TCAGATATA  
AAAGATTTCATTCAATAATACTTGATAAAATCTCTTATTATTTCTTACTTTTATTAAAAAAAACCT  
CTAATAAAAT  
ACGAGTTTAAGTCCACAAAATGCTTAGACTAAAAAACCCATATAATTCAACGATAAAAGTTTACAAA
```

DO ROZVOJE VZDĚLÁVÁNÍ

Tato aplikace je podpořena v rámci
Evropských sociálních fondů
a smluvním sporadickým České republiky



NOTE: The submitted sequences are kept confidential and will be erased immediately after processing.

NetGene 2

Prediction done

***** NetGene v. 2.4 *****

The sequence: Sequence has the following composition:

Length: 9490 nucleotides, 31,8% A, 17,0% C, 31,7% T, 0,9% G, 36,5% G+C

Donor splice sites, direct strand

pos 5'=>3'	phase	strand	confidence	5'	exon	intron	3'
1704	0	+	0.87	TTCGAAACG**GTATAGATT			
1704	0	+	0.99	CCTGAGACCG**CTAGAACAT			
1705	1	+	0.99	TTTGATGGTCTGATGATGATG			
3762	1	+	0.99	TTTGATGGTCTGATGATGATG			
4134	0	+	0.74	TCAAACACAG**GTTTAAAAAA			
4619	1	+	0.74	ACCAAGAAGG**GCTTGTTC			
4915	0	+	0.94	CCCTTCTCTCTGCTTACTCTC			
5326	0	+	0.97	TCTGATGATGATGATGATGATG			
5384	1	+	1.00	GATTGTTGTCG**GTAGACTCT			
5809	1	+	1.00	TATCTTAAGG**GTGTCCAA			
6057	0	+	1.00	GCAGCTCTG**GTAGCTCT			
6094	1	+	0.74	CTCTTCACAA**GTAACCTG			
7349	0	+	1.00	GGGGGGGGGGGGGGGGGGGG			
7884	0	+	0.74	GACAAATTGATGAGATGAA			
9323	0	+	0.74	GANGATTAGG**GTGTTTCCT			



Donor splice sites, complement strand

pos 3'=>5'	phase	strand	confidence	5'	exon	intron	3'
1221	0	+	0.59	TATTTTTTTTTGTATGGACAC			
1221	2	+	0.77	AGTATGAAAGAGAAGACG			
1373	2	+	0.71	TCTTCACACG**GCAACAGAT			
1487	1	+	0.81	ATATTGATAC**TGGGACATTA			
1284	0	+	0.81	GTAACTAAA**GTTTGAATC			
4254	0	+	1.00	TGTCCTCTACG**ATCGACCAT			
4832	2	+	0.54	AAAATTCGAG**TCCAGTGCG			
5004	0	+	0.94	TTTTTGACG**AGATACACCG			
5472	1	+	0.66	AAAATTCGAG**TCCAGTGCG			
6135	0	+	1.00	ATTATTATACG**GTAGATCAA			
6490	1	+	0.90	AAAGCTTACACG**TGGGGAGAA			
6744	0	+	0.59	TGTCAAACAG**TTTCGTAGAG			
7447	0	+	0.96	TTCTGGACAG**ATGCCAGAGA			
7780	2	+	0.76	TCCATTTCACG**ATCACAGACA			
7786	2	+	0.92	TCAGATACACG**AACACATCA			

INVESTICE DO ROZVOJE Vzdělávání

Tato příručka je spouštěna v rámci
Evropským sociálním fondem
a státním rozpočtem České republiky

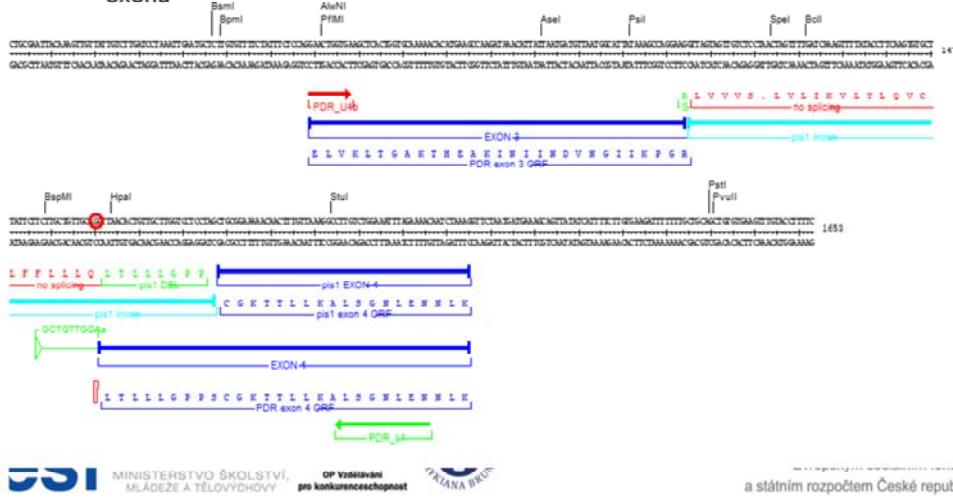


MINISTERSTVO REGIONALOVÝV
OP KOMUNIKACIÍ
MINISTERSTVO
PRO KOMUNIKACE A VZDĚLÁVÁNÍ



Sestřih RNA a adaptace

- odchyly 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



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

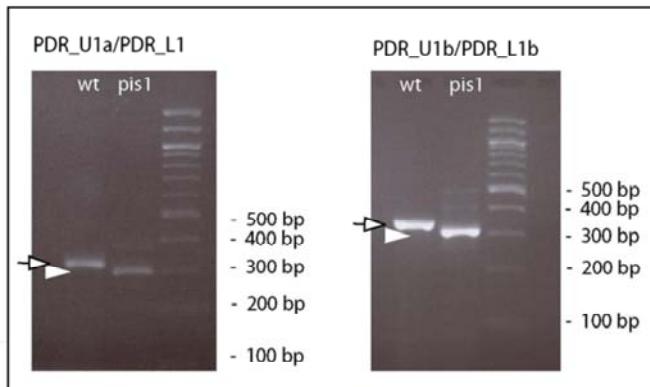
OP Vaškůvka
pro konkurenčnost

MATANA BROT

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

toto omezení je možno odstranit
Evropským sociálním fondem
a státním rozpočtem České republiky



MU
MINISTERSTVO Vzdělávání
mládeže a tělovýchovy
pro komunitní rozvoj

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



DĚLÁVÁNÍ

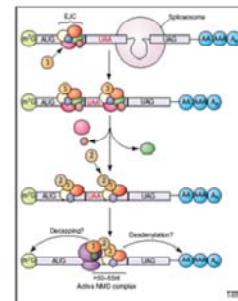
článkovacího

účinku řečenky

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



OP VK
pro konkurenčnost
UNIVERSITAS
SANT'ANNA
BRUNELLO

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

GENESCAN

GENSCAN

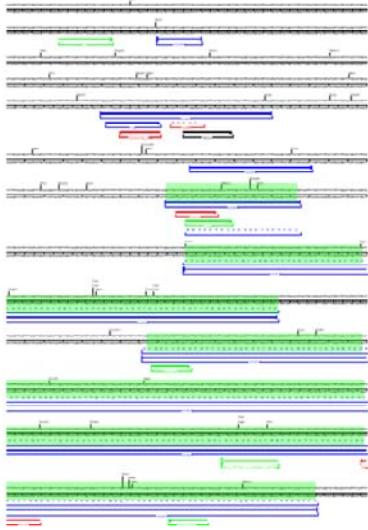
GENSCAN output for sequence CKII

GENSCAN 1.0 Date run: 10-Nov-105 Timer: 02:24:26
Sequence CKII : 9490 bp z 36.53% C+G : Isochore 1 (0 = 43 C+G)
Parameter matrix: Arabidopsis.smat
Predicted genes/exons:

Gn.Ex	Type	S	.Begin	...End	.Len	Fr	Ph	I/Ac	Do/T	CodRg	P....	Tscr...
1.00	Prom +	1497	1536	40								-3.85
1.01	Intr +	3709	3917	2	0	63	51	37	0.499	0.003		
1.02	Init +	4123	2416	2	0	33	7	327	0.713	1.259		
1.03	Intr +	4255	4914	560	0	86	59	286	0.771	22.52		
1.04	Intr +	5005	5383	379	0	1	70	91	343	0.772	31.41	
1.05	Intr +	5473	6056	584	2	2	38	99	582	0.722	50.76	
1.06	Intr +	6136	7368	1233	0	0	68	108	655	0.977	56.86	
1.07	Term +	7448	7660	213	1	0	43	35	212	0.999	12.65	
1.08	PlyA +	7910	7919	5								-0.45
2.03	PlyA -	7976	7971	6								-4.83
2.02	Term -	8783	8050	744	0	0	107	37	542	0.997	48.46	
2.01	Init -	9253	8936	318	1	0	105	73	386	0.999	41.18	

Suboptimal exons with probability > 0.100

Gn.Ex	Type	S	.Begin	...End	.Len	Fr	Ph	B/Ac	Do/T	CodRg	P....	Tscr...
2.001	Init +	1867	1905	39	0	0	64	40	57	0.298	3.74	
2.002	Init +	2374	2442	69	0	0	55	95	-11	0.132	2.40	
2.003	Intr +	3894	4110	213	2	1	-3	-34	307	0.177	11.55	
2.004	Intr +	4352	4914	563	0	2	75	59	338	0.187	26.20	
2.005	Intr +	5005	5379	375	0	0	70	9	335	0.212	22.99	
2.006	Intr +	5442	6056	615	2	0	95	99	589	0.208	57.32	



EVROPSKÁ UNIE | ESF | MŠMT | Česká republika | AVANI

Tato výzkumná činnost je podpořena v rámci
Evropských sociálních fondů
a státním rozpočtem České republiky

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: AATAAA) \$: 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 points 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.

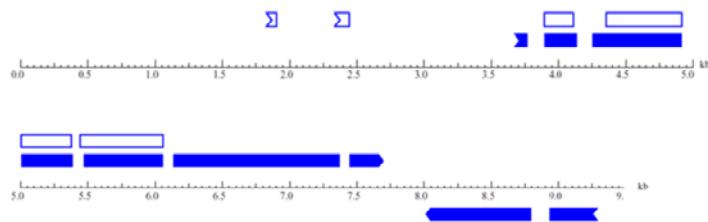
What are the suboptimal exons?

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 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.

GENSCAN

GENSCAN predicted genes in sequence 02:56:23



Key:

- Initial exon
- Internal exon
- Terminal exon
- Single-exon gene

- Optimal exon
- Suboptimal exon

OZVOJE Vzdělávání

Vzdělávací je možné finanční podporou

Evropským sociálním fondem

a státním rozpočtem České republiky

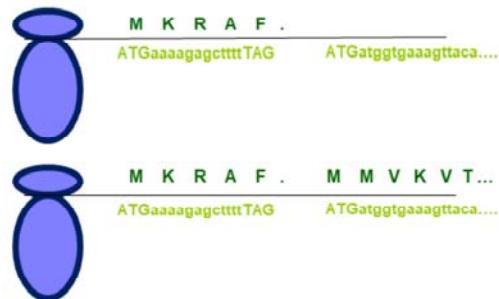


MINISTERSTVO ŽDROJOV VZDĚLÁVÁNÍ
PRO INNOVACI
Vzdělávací program pro konkurenčnost

AVANA

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 linii nesoucích *uidA* pod kontrolou dvou verzí promotoru, zatím nepotvrzeno



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



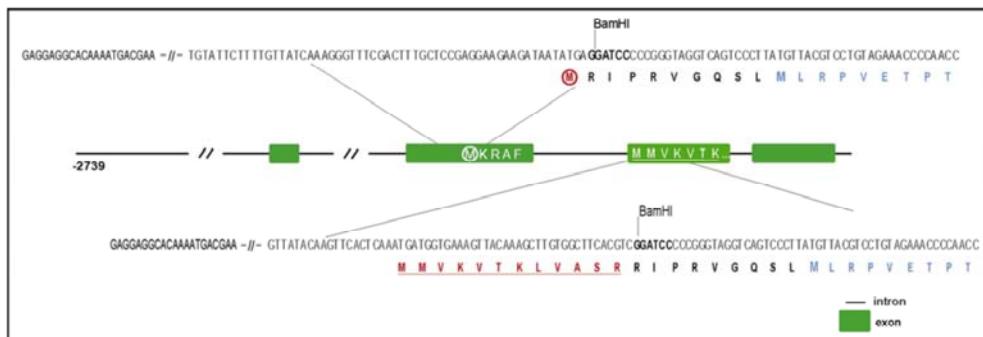
UNIVERSITAS
SANT'ANNA
BRUNELLA

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 CK11 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

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 kódujích oblastech
(testováno na genu *PDR9*, identifikoval všech 23 (!) exonů)
 - GeneMark.hmm (<http://opal.biology.gatech.edu/GeneMark/>)
 - GlimmerHMM (<http://ccb.jhu.edu/software/glimmerhmm/>)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
SANT'ANNA
BRNO

INVESTICE DO ROZVOJE Vzdělávání

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

GeneMark

Result of last submission:

[View PDF Graphical Output](#)

[GeneMark.htm Listing](#)

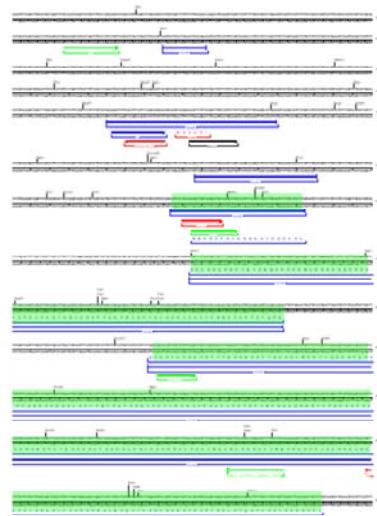
[Go to: GeneMark.htm Protein Translations](#)

[Go to: Job Submission](#)

Dukaritovc GeneMark.htm version bp 0.9 April 25, 2008
Sequence name: CK11
Sequence length: 5043 bp
G+C content: 38.79%
Matrices file: /home/gemmark/euk_ghm.matrices/athaliana_hmmer3.0.mod
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 - -	156	1 0 - -
1	2	+	Internal	1155 1374 220	219	1 0 - -
1	3	+	Internal	1516 2175 660	660	1 0 - -
1	4	+	Internal	2266 2649 379	379	1 1 - -
1	5	+	Internal	2724 3217 584	584	2 0 - -
1	6	+	Internal	3297 4629 1232	1232	1 0 - -
1	7	+	Terminal	4709 4921 213	213	1 0 - -



/ZDĚLÁVÁNÍ

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



GeneMark

Result of last submission:

[View PDF Graphical Output](#)

[GeneMark.hmm Listing](#)

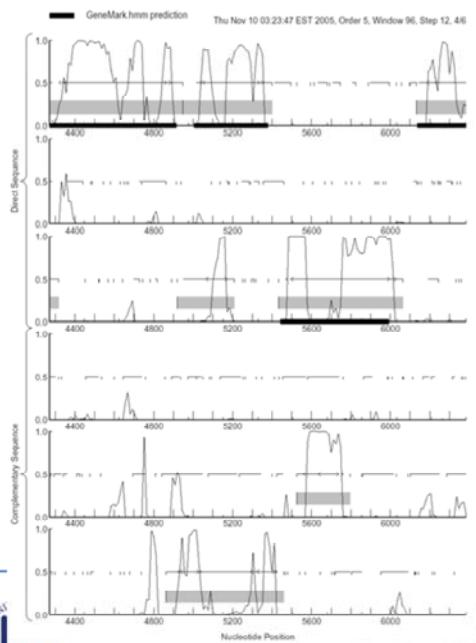
[Go to: GeneMark.hmm Protein Translations](#)

[Go to: Job Submission](#)

Dukarsoft's GeneMark.hmm version bp 0.9 April 25, 2008
Sequence name: CK11
Sequence length: 5040 bp
G+C content: 38.79%
Matrices file: /home/gemmark/euk_ghm.matrices/athaliana_hmm2.0.mod
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	969	1025	57 1 0 - -
1	2	+	Internal	1155	1294	240
1	3	+	Internal	1516	2175	660
1	4	+	Internal	2266	2649	379
1	5	+	Internal	2794	3217	584
1	6	+	Internal	3397	4629	1232
1	7	+	Terminal	4709	4921	213



LÁVÁNÍ

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



OP Vzdělávání
pro konkurenční schopnost
UNIVERSITAS SANTO TOMÁSA JUAN JUANES

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 genomové 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)

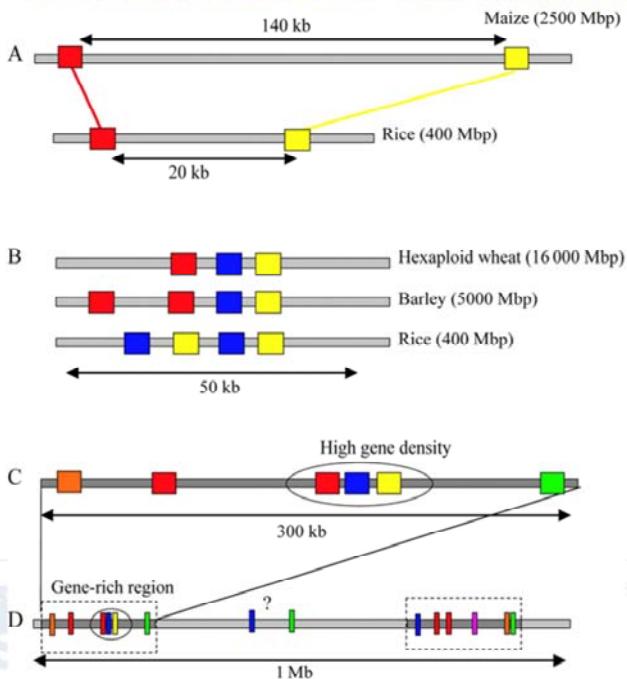


MU
MINISTERSTVO VZDĚLÁVÁNÍ,
VÝzkUMU A TECNICKÉHO VYROBENÍ
a vzdělávání
pro konkurenčnost



Tato vnitřní akce je spouštěna v rámci
Evropských sociálních fondů
a státním rozpočtem České republiky

Genomová kolinearita



Feuillet and Keller, 2002

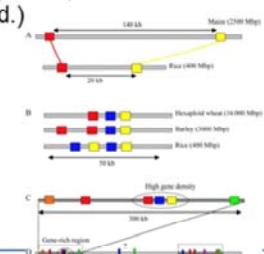
STÍČICE DO ROZVOJE Vzdělávání

Tato vnitřní stránka je součástí nového výukového materiálu
Evropských vzdělávacích fondů
a náleží do programu České regulace



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.)



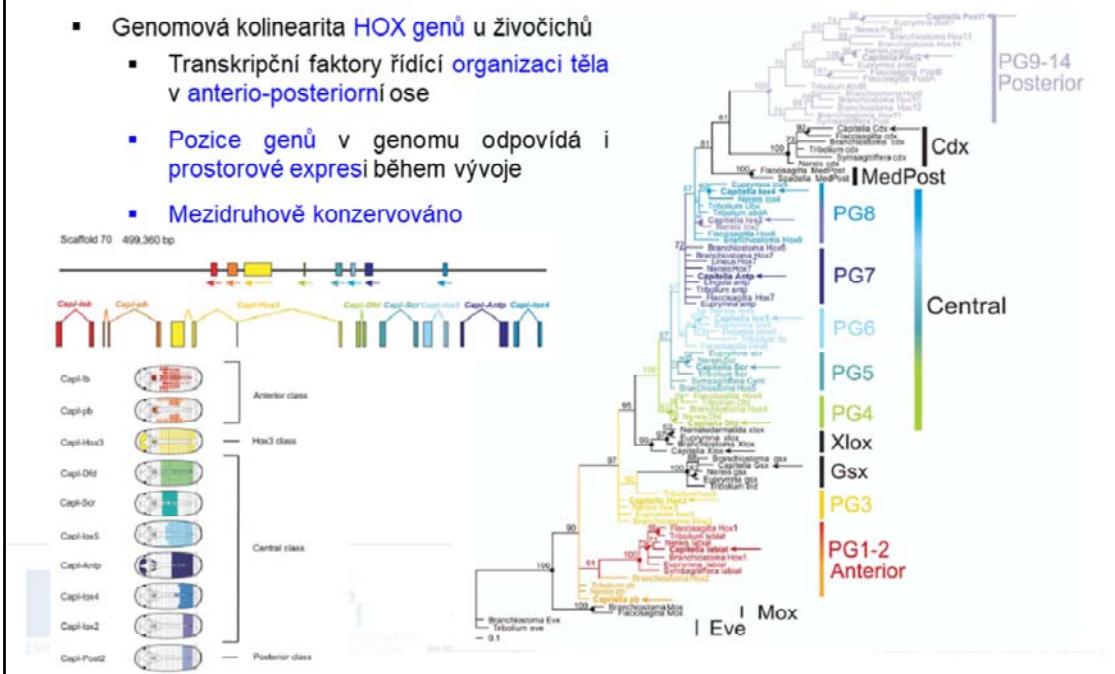
INVESTICE DO ROZVOJE VzděLAVÁNÍ

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 antero-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 chromosome is retained in several species (genome colinearity).

Osnova

- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přistupech 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



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
- 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 adaptorů
 - příprava BAC knihovny v *mcrBC+* kmeni *E. coli*
 - selekce pozitivních klonů
- omezené využití: obohacení o kódující DNA o pouze cca 5-10 %



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
SANT'ANNA
BRNO

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 přistupech 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



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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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