

# **CG020 Genomika**

## **Bi7201 Základy genomiky**

### **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](mailto:hejatko@sci.muni.cz), [www.ceitec.muni.cz](http://www.ceitec.muni.cz)



MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



### **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 earlylate 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



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



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



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

### Revoluce v chápání pojmu genu

## Přístupy „klasické“ genetiky





3 : 1




## „Reverzně geneticky“ přístup

5'TTATATATATATTAAAAAATAAAATAAAA  
GAACAAAAAAGAAAATAAAATA...3'



...sat tca agt cgt gga gag tac act



# 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



EVROPSKÁ UNIE  
esf



MŠMT



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

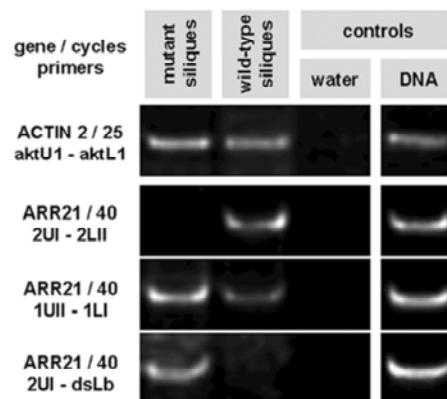
Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# 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  
BRNO

## 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  
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 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  
PROGRAM RODU A VZDELÁVÁNIA  
Operatívny program pre konkurenčnosť a vývoj

Operatívny program pre konkurenčnosť a vývoj



ZVÖJE VZDĚLÁVÁNÍ

zrealizované je s podporou celku

europejským sociálnim 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




## 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



## 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](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

# 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:

```
GAAGGAGGCACAAATGACGAATATAACAAATGACTTAAACAGCTAACTATATTGGACATTTTCGATCTCAGATATA  
AAAGATTTCATTCAATATAACTCTGGATAAATACTCTTATTTCTTAGTTTAAACCTCTAATAAAAT  
ACGAGTTAACGTCACAAAATCGCTTAGACTAAAAATACCCATATAATTCAAACGATAAAGTTACAAAAGTAATATCC  
AAGTATCTCATAGTCACACATATAATAGTAAATAATTAGTTGACGTATAAGAAATAAAAATAATAATTAGTATCTTAT  
TTTGCGTGGTCTGACTGGTGACTGGTGACTGCAGAGATCTCGGCCAAATGGAACCATATCCCAGACATGGGTTTGGAT
```

... 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\\_sp1.html](http://www.tigr.org/tdb/GeneSplicer/gene_sp1.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

# Predikce míst sestřihu

CENTER FOR BIOLOGICAL SEQUENCES  
CALSEQUE  
ENCEANOLOGY  
LYSIS CBS

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

```
GAGGAGGCACAAAATGACGAATATAAAAATGATCTAAACAGCTAAACTATATTGGACATTTTCGATC  
TCAGATATA  
AAAGATTTCATTCAATAATACTTGATAAAATCTCTTATTATTTCTTACTTTTATTAAAAAAAACCT  
CTAATAAAAT  
ACGAGTTTAAGGCCACAAAATGCTTAGACTAAAAAACCCATATAATTCAACCGATAAAAGTTTACAAA  
 
```

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

---

**DO ROZVOJE VZDĚLÁVÁNÍ**

Tato aplikace je součástí programu  
Evropských sociálních fondů  
a smluvního sporadického České republiky

  
EVROPSKÁ UNIE esf

# Predikce míst sestřihu

Prediction done

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

The 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	TTCGAAACAGC	GT	ATTAATTT	
1904	0	+	0.99	CCTGAGCCG	GT	AGAGACAT	
1954	1	+	0.99	TTTGATGCG	GT	ATTTT	
2152	1	+	0.99	TTCGAGCG	GT	ATTTT	
3162	1	+	0.99	TTCGAGCG	GT	ATTTT	
4134	0	+	0.74	TCAAACACAG	GT	TTTAAAAA	
4619	1	+	0.74	ACCAAGAGAG	GT	TTTGTTC	
4915	0	+	0.94	CCCTCCCTCT	GT	ATTTACTC	
5326	0	+	0.97	TCTGATGAAAT	GT	ATTTT	
5384	1	+	1.00	GATTGGTGTG	GT	AGACTCT	
5809	1	+	1.00	TATCTAAAGG	GT	TTCTCAA	
6057	0	+	1.00	GCAGCTCTG	GT	AGCTCTAC	
6094	1	+	0.74	CTCTTCACAA	GT	AACTCTAG	
7349	0	+	1.00	GGGGGGGGGG	GT	GGGGGGGG	
7884	0	+	0.74	GAACAAATGG	GT	AGATGAA	
9323	0	+	0.74	GANGATTAGG	GT	TTTCTCT	

Donor splice sites, complement strand

pos 3'=>5' pos 5'=>3' phase strand confidence 5' exon intron 3'

Acceptor splice sites, direct strand

pos 5'=>3'	phase	strand	confidence	5'	intron	exon	3'
1221	0	+	0.59	TATTTTTT	AT	GGAGAC	
1221	2	+	0.77	AGTTAACAA	AT	GGAGAC	
1373	2	+	0.71	TCTTACAC	AT	GGACAGAT	
1487	1	+	0.81	ATATTGATAC	AT	GGGACATTA	
1284	0	+	0.81	GTAACTAAA	AT	GGTTCAC	
4254	0	+	1.00	TGTCCTCACG	AT	CGACCAT	
4832	2	+	0.54	AAAATTCGAG	TT	CCAGTGCG	
5004	0	+	0.94	TTTTTGCG	AG	TACACCGC	
5472	1	+	0.66	AAAATCACGG	AT	GGGGGGGG	
6135	0	+	1.00	ATTATTATACG	AT	GGAGATAA	
6490	1	+	0.90	AAAGCTTACAG	TG	TTGGGGAGAA	
6744	0	+	0.59	TGTCAAACAG	TT	TCGTAGAG	
7447	0	+	0.96	TTCTGGACAG	AT	GGCAGAAA	
7780	2	+	0.76	TCCATTTCAG	AT	CAAGACAA	
7786	2	+	0.92	TCAGATACAG	AAC	ACATCA	



INVESTICE DO ROZVOJE Vzdělávání

Tato příručka je spouštěna v rámci

Evropským sociálním fondem

a státním rozpočtem České republiky




MINISTERSTVO REGIONALOVÝV  
RÁDILSTVÍ A TĚLOVÝDĚLAVÍ  
pro konkurenčního hospodářství



# 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

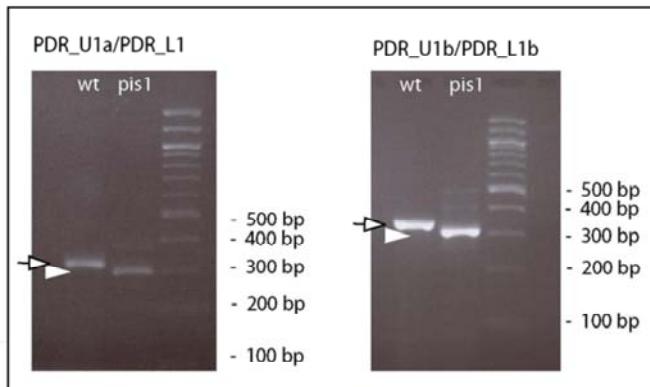
OP Vaškárov  
pro konkurenčnost

JANNA BRU

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



MINISTERSTVO ZDRAVOTNICTVÍ  
Ministerstvo zdravotnictví  
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

českatekouzlo.cz

projekt financuje

a státním rozpočtem České republiky




EVROPSKÁ UNIE

MINISTERSTVO ZDRAVOTNICTVÍ ČR  
Ministerstvo zdravotnictví České republiky  
pro komunikační podporu



# 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 organizmů (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



UNIVERSITATE  
JANAE  
BRUNNEAE

## 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*

GENSCANW output for sequence CKII

```
GENSCAN 1.0      Date run: 10-Nov-105      Timer: 02:24:26
Sequence CKII : 9490 bp : 36.53% C+G : Isochore 1 ( 0 = 43 C+G)
Parameter matrix: Arabidopsis.smst
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 Init + 3769 3917 2 0 63 51 37 0.499 -0.03
1.02 Intr + 4123 246 2 0 -3 -7 327 0.713 12.59
1.03 Intr + 4255 4914 560 0 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 7915 6 -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
Exnum Type S .Begin ...End .Len Fr Ph B/Ac Do/T CodRg P.... Tscr...
----- -----
S.001 Init + 1867 1905 39 0 0 64 40 57 0.298 3.74
S.002 Init + 2374 2442 69 0 0 55 95 -11 0.132 2.40
S.003 Intr + 3894 4110 213 2 1 -3 -34 307 0.177 11.55
S.004 Intr + 4352 4914 563 0 2 75 59 338 0.187 26.20
S.005 Intr + 5005 5379 375 0 0 70 9 335 0.212 22.99
S.006 Intr + 5442 6056 615 2 0 95 99 589 0.208 57.32
```



EVROPSKÝ SOJUZ / JEDNOSTKA PRO VzděLÁVANÍ

Tato akce je podpořena Evropským sociálním fondem  
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 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 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

OZVOJE VZDĚLÁVÁNÍ


Vzdělávací je nástroj pro rozvoj

Evropských sociálních fondů

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



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

# 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

## Identifikace genů *ab initio*

# Identifikace genů *ab initio*

LÁVÁNÍ

...nancována

financována

# Identifikace genů *ab initio*

Result of last submission:

[View PDF Graphical Output](#)

[GeneMark hmmer Listing](#)


[Go to: GeneMark hmmer Protein Translations](#)

[Go to: Job Submission](#)

Dukaritovc: 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\_hmm0.0.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 - -	196	1 0 - -
1	2	+	Internal	1155 1374	219	1 0 - -
1	3	+	Internal	1516 2175	660	1 0 - -
1	4	+	Internal	2266 2649	379	1 1 - -
1	5	+	Internal	2794 3217	584	2 0 - -
1	6	+	Internal	3397 4629	1232	1 0 - -
1	7	+	Terminal	4709 4921	212	1 0 - -



/ZDĚLÁVÁNÍ

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



MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



# 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](#)

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/gmark/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	3297	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



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 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



UNIVERSITAS  
SANT'ANNA  
BRNO

## 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,  
VÝzkUMOVÉ A VEDLICKÝ  
UR 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 kniha je součástí soubíku  
Evropských vzdělávacích knih  
a může být použita v 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 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, Capl-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



## 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