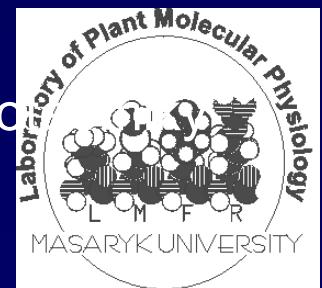


Základy genomiky



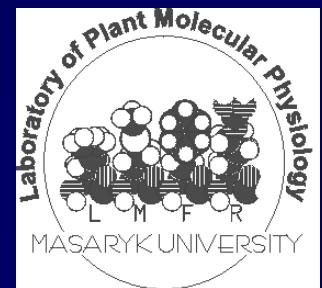
Masarykova univerzita, Laboratoř funkční genomiky a pro
Laboratoř molekulární fyziologie rostlin



Základy genomiky II.

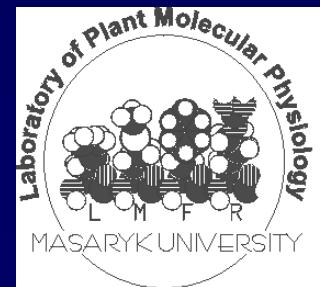
- Zdrojová literatura ke kapitole II:

- 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 nonsensemediated 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)



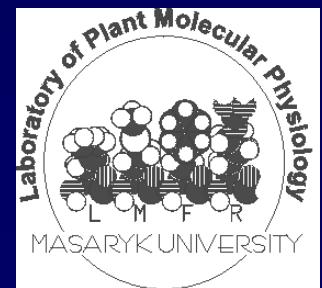
Základy genomiky II.

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



Základy genomiky II.

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



Přímá vs. reverzní genetika

Revoluce v chápání pojmu genu

Přístupy „klasické“ genetiky



3

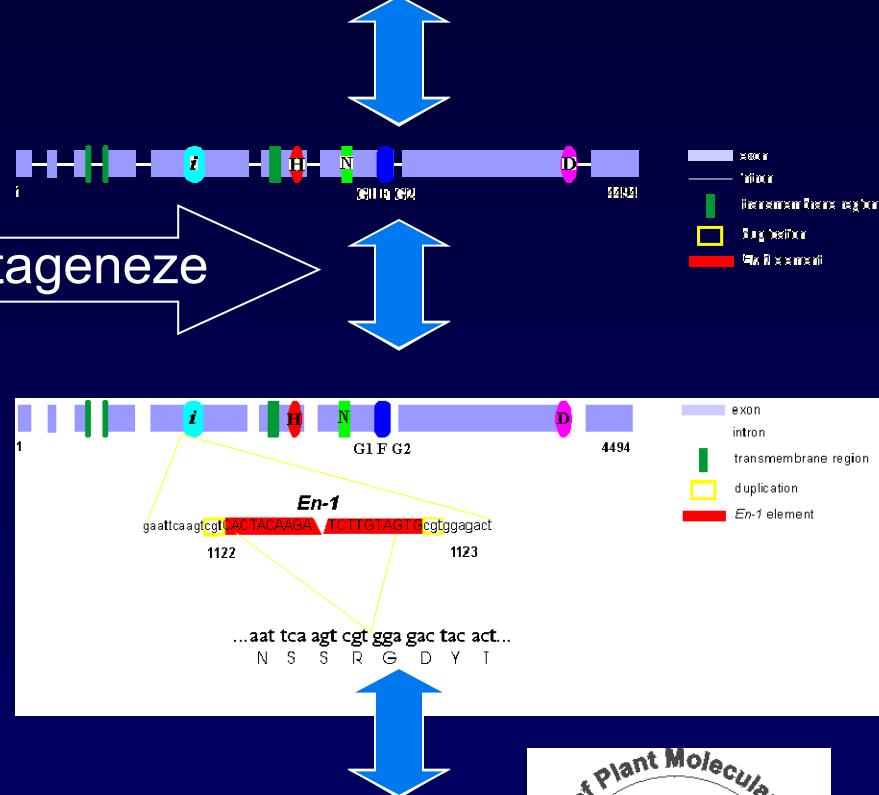
:

1

?

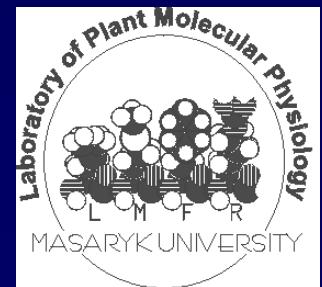
„Reverzně geneticky“ přístup

5' TTATATATATATTAAAAAATAAAATAAA
AGAACAAAAAAGAAAATAAAATA...3'

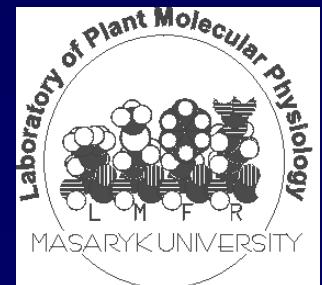
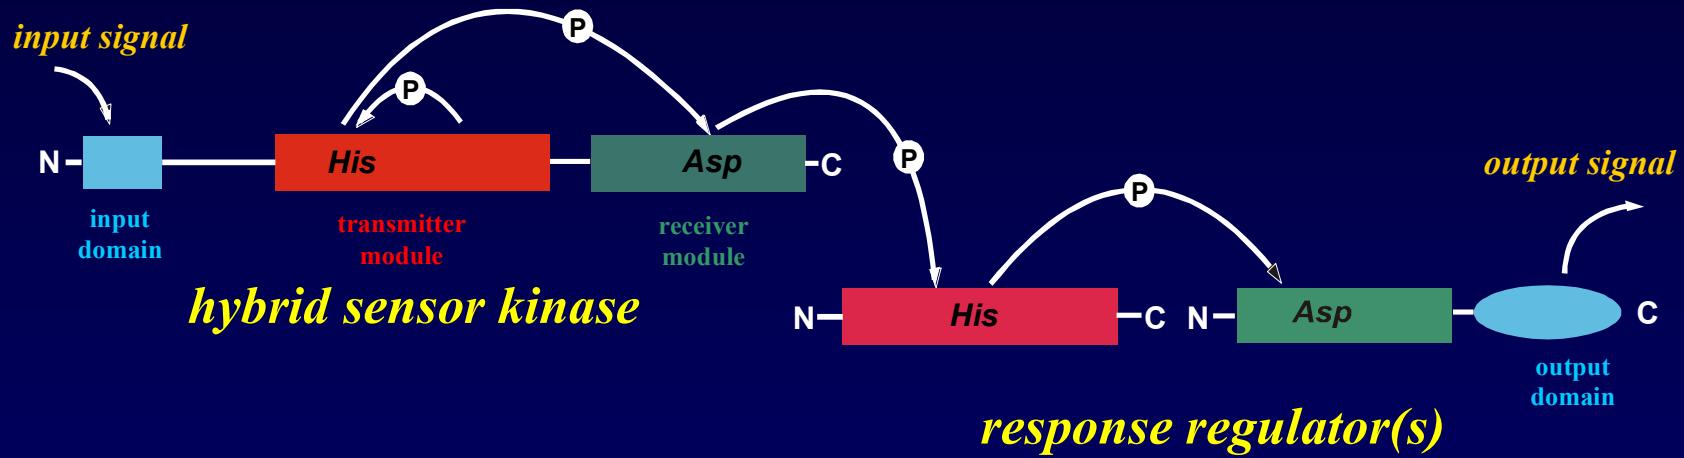


Identifikace role genu *ARR21*

- Předpokládaný přenášeč signálu u dvoukomponentního signálního systému *Arabidopsis*

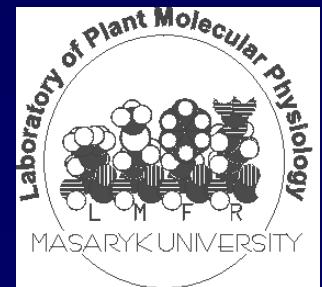


Identifikace role genu *ARR21* regulátor odezvy v dvoukomponentním signálním systému



Identifikace role genu *ARR21*

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



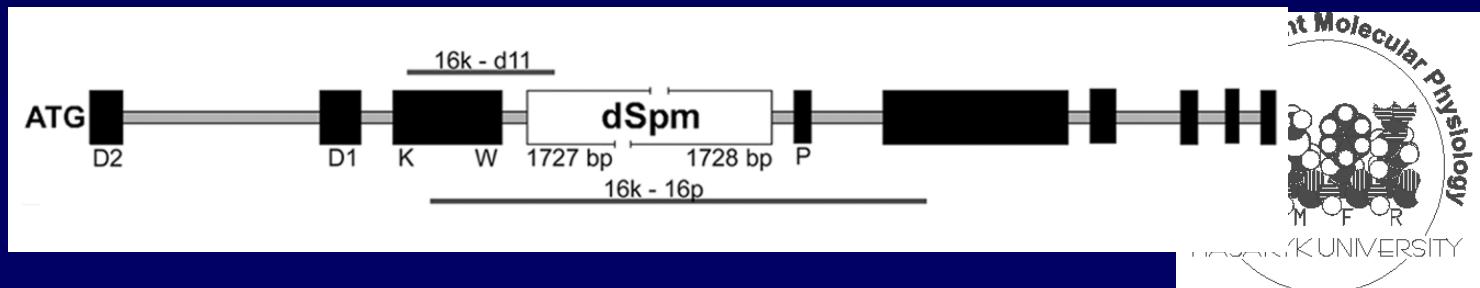
Identifikace role genu *ARR21* identifikace inzerčního mutanta

- vyhledávání v databázi inzerčních mutantů (SINS)

```
Insert_SINS: 01_09_64
Query: 80  tcctagcggtcatgagcgtaccataacttgacaanaagagaacgttagccagccatttacagg 139
          ||||||| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
Sbjct: 58319 tcctagcggtcatgagcgtaccataacttgacaagaagagaacgttagccagccatttacagg 58378
Arr21: 1830

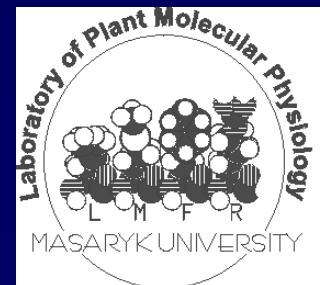
Insert_SINS: 01_09_64
Query: 140  tttgatatctttgtcaaaaatgtttttggattttactgt 179
          ||||||| | | | | | | | | | | | | | | | | | | | |
Sbjct: 58379 tttgatatctttgtcaaaaatgtttttggattttactgt 58418
Arr21: 1890
```

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



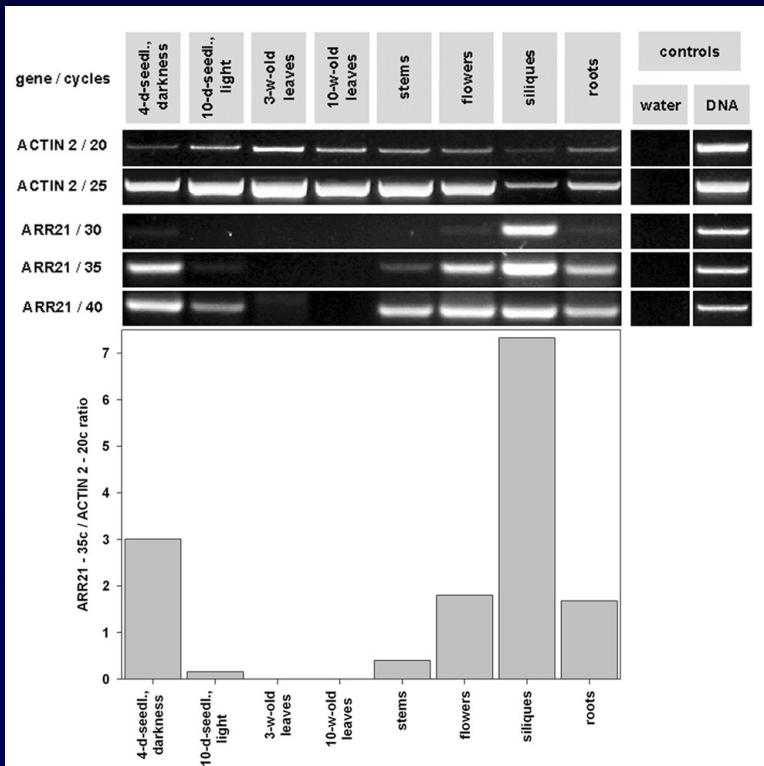
Identifikace role genu *ARR21*

- 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

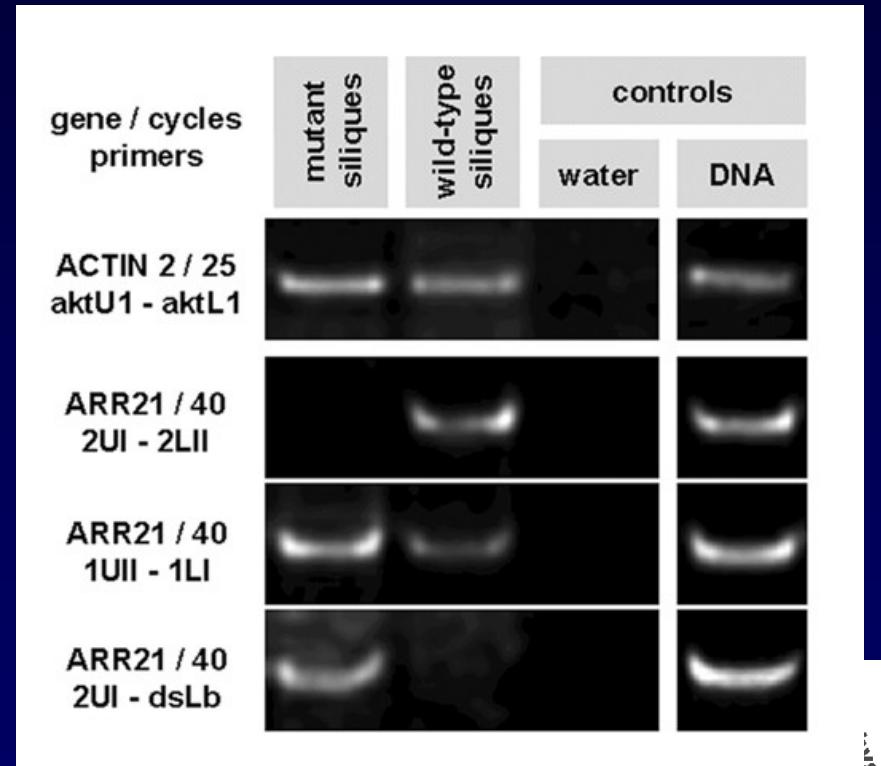


Identifikace role genu *ARR21* analýza expresního profilu

Standardní typ

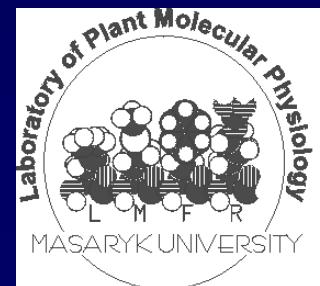


Inzerční mutant



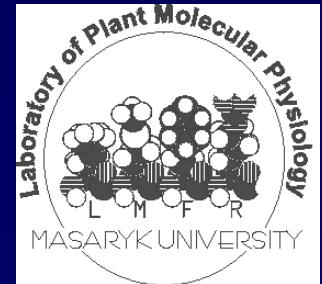
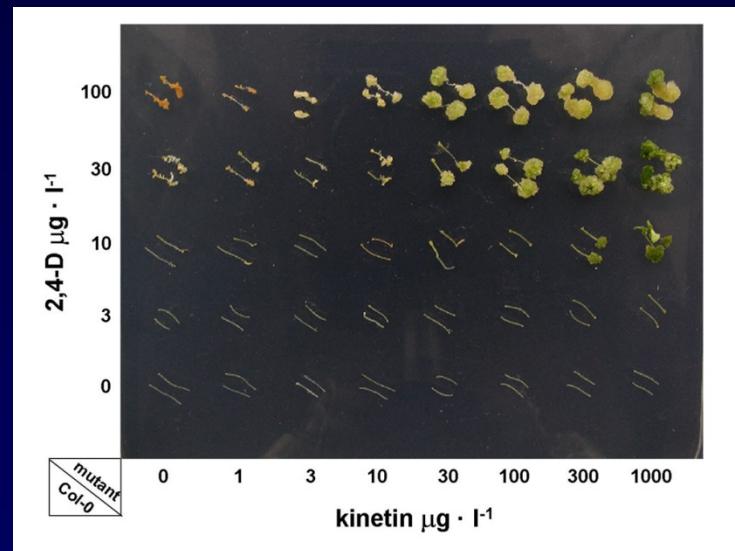
Identifikace role genu *ARR21*

- 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



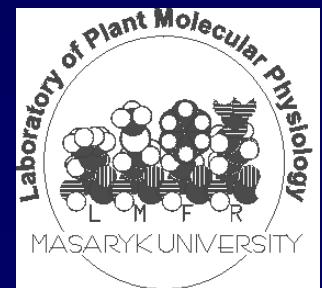
Identifikace role genu *ARR21* analýza fenotypu inzerčního mutanta

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

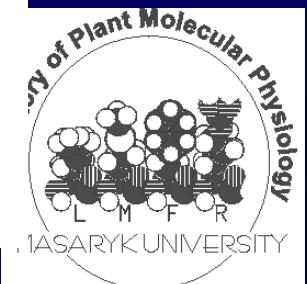
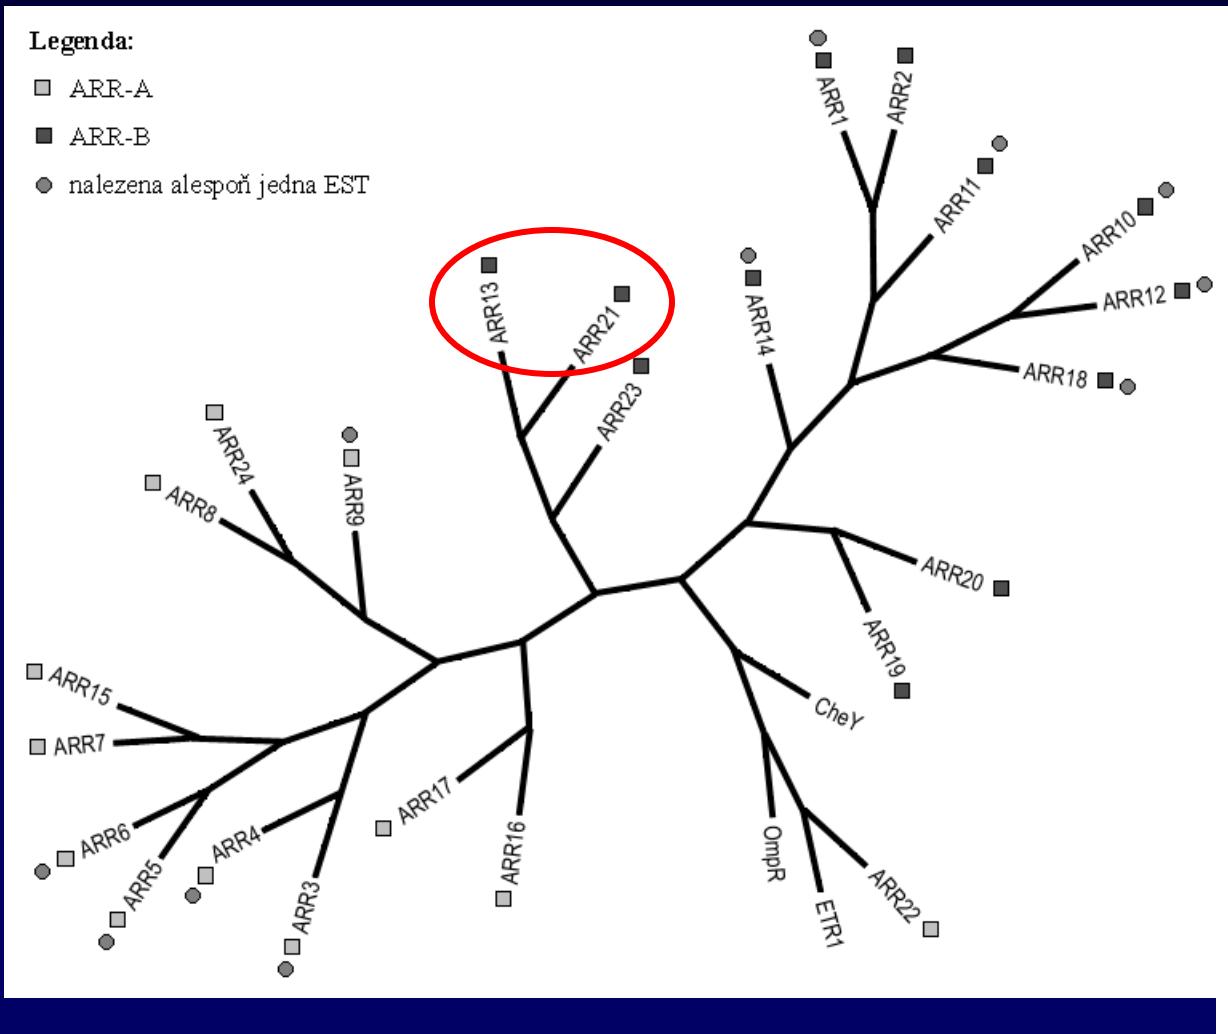


Identifikace role genu *ARR21* možné příčiny absence odchylek fenotypu u inzerčního mutanta

- Funkční redundance v rámci genové rodiny?

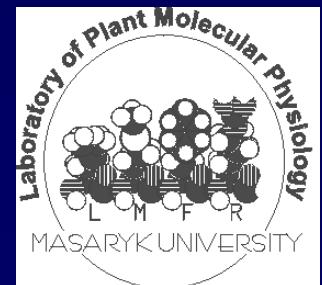


Identifikace role genu *ARR21* příbuznost jednotlivých ARR genů u *Arabisopsis*



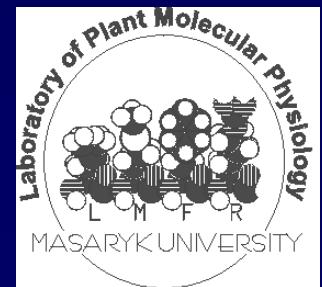
Identifikace role genu *ARR21* možné příčiny absence odchylek fenotypu u inzerčního mutanta

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



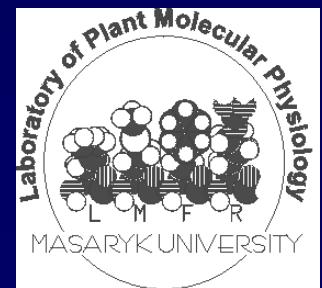
Inzerční mutageneze ve funkční genomice *Arabidopsis thaliana*

- 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
- Inzerční mutageneze v případě identifikace funkce genu *ARR21* ve vývoji *Arabidopsis* byla neúspěšná, pravděpodobně v důsledku funkční redundance v rámci genové rodiny



Základy genomiky II.

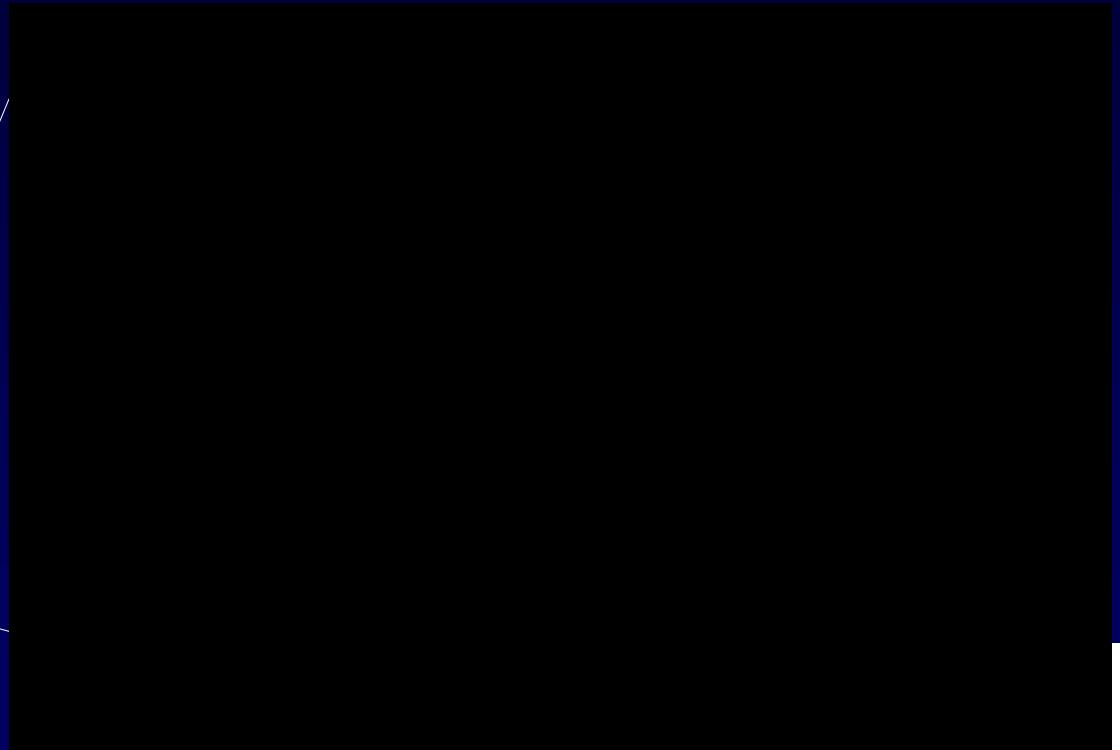
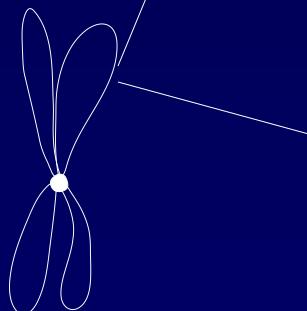
- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Predikce funkce genů *in silico*
 - struktura genů a jejich vyhledávání



Predikce funkce genů *in silico*

struktura genů

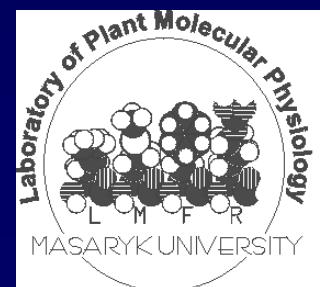
- struktura genů
 - promotor
 - počátek transkripce
 - 5 UTR
 - počátek translace
 - místa sestřihu
 - stop kodon
 - 3 UTR
 - polyadenylační signál



Predikce funkce genů *in silico*

vyhledávání genů

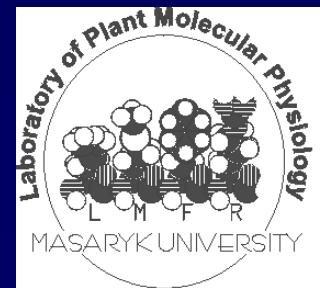
- vyhledávání genů *ab inicio*
 - zanedbání 5' a 3' UTR
 - identifikace počátku translace (ATG) a stop kodonu (TAG, TAA, TGA)
 - nalezení donorových (většinou GT) a akceptorových (AG) míst sestřihu
 - většina ORF není skutečně kódujícími sekvencemi – u *Arabidopsis* je asi 350 mil. ORF na každých 900 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



Predikce funkce genů *in silico*

vyhledávání genů

- vyhledávání 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>)



Predikce funkce genů *in silico*

vyhledávání genů

What do the output columns mean?

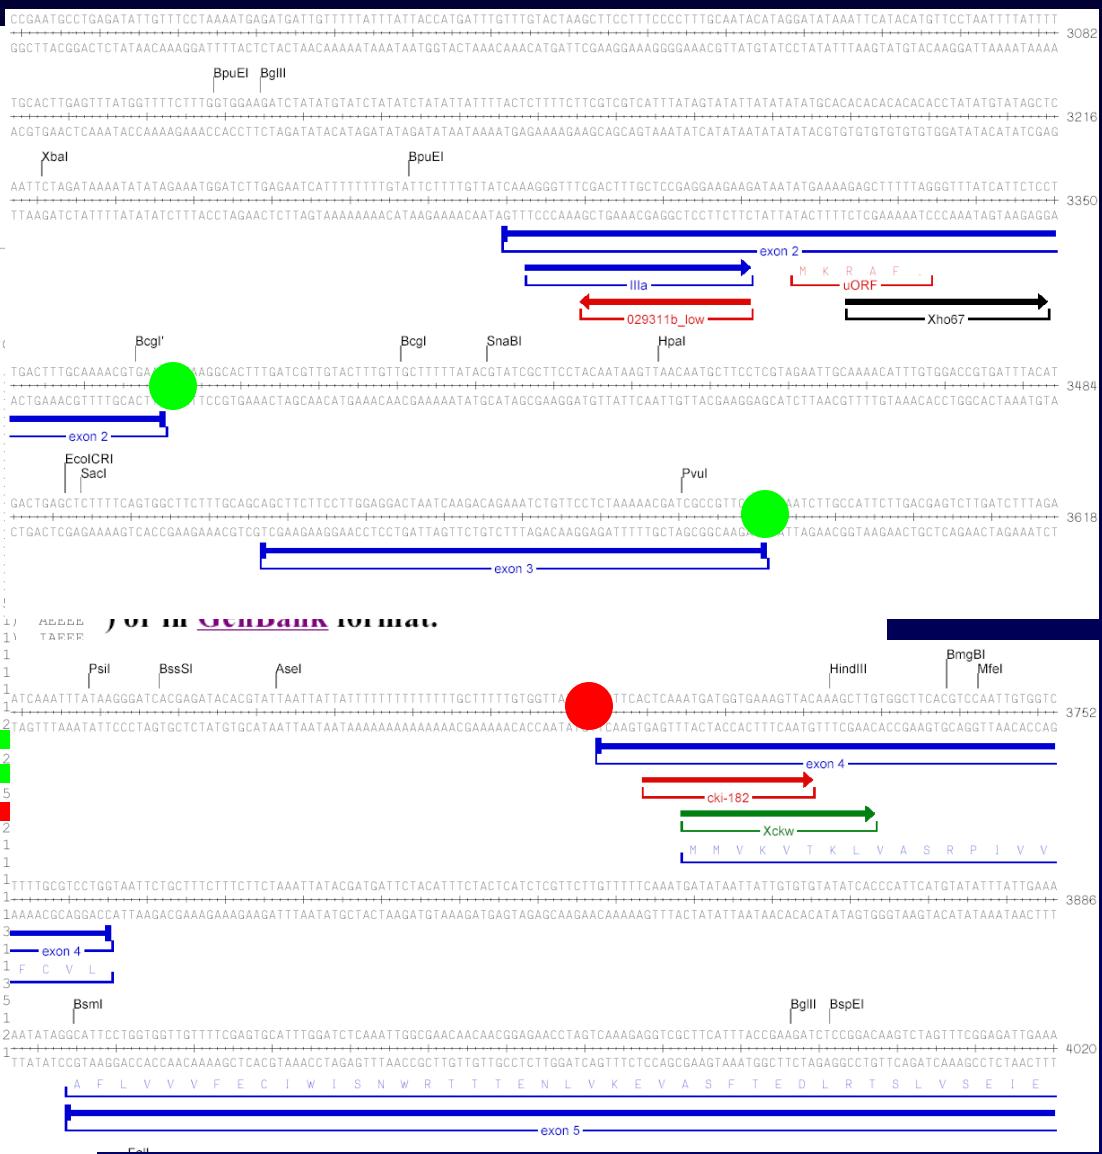
SplicePredictor. Version of February 13, 2005
Date run: Wed Nov 9 11:30:14 2005

Species: Homo sapiens
Model: 2-class Bayesian
Prediction cutoff (2 ln[BF]): 3.00
Local pruning: on
Non-canonical sites: not scored

Sequence 1: your-sequence, from 1 to 9490

Potential splice sites

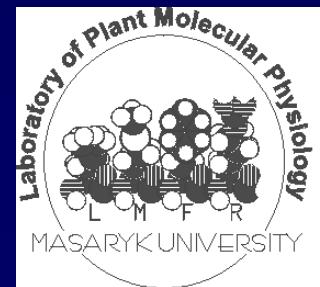
	q	loc	sequence	P	c	rho	gamma	*	P*R*
A	<--	75	tttttcgatctcAGat	0.973	7.16	0.000	0.000	7	(5 1)
A	<--	134	atttttttttttAGtt	0.999	14.86	0.000	0.000	7	(5 1)
A	<--	500	gattttgtgttAGtc	0.977	7.48	0.000	0.000	7	(5 1)
A	<--	780	tctgttatttatAGct	0.986	8.56	0.000	0.000	7	(5 1)
A	<--	848	tattttttgaatAGat	0.968	6.80	0.000	0.000	7	(5 1)
A	<--	1051	caatttttttttaGaa	0.930	5.19	0.000	0.000	7	(5 1)
A	<--	1213	tttttttttttAGtt	0.998	12.14	0.000	0.000	7	(5 1)
A	<--	1373	tttccctctcacAGga	0.999	13.17	0.000	0.000	7	(5 1)
A	<--	1487	tttataatgtatAGtg	0.883	4.04	0.000	0.000	7	(5 1)
A	<--	1581	atgtgtgttgttAGga	0.982	8.03	0.000	0.000	7	(5 1)
A	<--	1781	ggtgtgcggaaatAGgg	0.886	4.10	0.000	0.000	7	(5 1)
A	<--	2440	taaaaaaaaatttAGat	0.939	5.46	0.000	0.000	7	(5 1)
A	<--	2479	cattcaaaaaatttAGat	0.942	5.59	0.000	0.000	7	(5 1)
D	----->	2546	aagTgtata	0.909	4.61	0.885	1.903	15	(5 5)
A	<--	2572	tttttttttttggcAGca	0.930	5.16	0.000	0.000	7	(5 1)
A	<---	2763	ctcaaaatccacaaaAGgt	0.873	3.86	0.185	0.000	11	(5 5)
A	<---	2782	tttcgttttttatttACgc	0.952	5.98	0.220	0.000	11	(5 5)
A	<---	3022	ttttgtgtactaaAGct	0.956	6.16	0.221	0.000	11	(5 5)
A	<---	3048	cttgcatacatACgg	0.973	7.15	0.229	0.000	11	(5 5)
A	<--	3171	cgtcgtcatttatAGta	0.988	8.74	0.000	0.000	7	(5 1)
A	<--	3284	cttttgttatcaaAGgg	0.993	10.03	0.000	0.006	8	(5 1)
A	<---	3451	aatcttccttcgtAGaa	0.916	4.77	0.293	0.065	12	(5 1)
D	----->	3649	cacGTatta	0.933	5.25	0.000	1.848	11	(5 1)
A	<--	4254	atttttttttcAGat	0.998	12.82	0.000	0.002	8	(5 1)
A	<--	4351	tttcttaacatttcAGaa	0.991	9.42	0.000	0.000	7	(5 1)
A	<--	4633	gtctgttttttttAGgg	0.879	3.97	0.000	0.000	7	(5 1)
A	<--	4976	ctttgtgttttttcAGct	0.952	5.98	0.000	0.000	7	(5 1)
A	<--	5004	ttttttttttccAGag	0.996	11.17	0.000	0.000	7	(5 1)
D	----->	5356	caaGTgtat	0.821	3.04	0.387	0.000	11	(5 5)
D	----->	5384	tttGTAaga	0.941	5.54	0.478	0.090	13	(5 5)
A	<--	5403	actctgttttttAGct	0.894	4.26	0.000	0.000	7	(5 1)
A	<--	5441	ctttcttcacaaGaa	0.995	10.43	0.387	0.000	11	(5 5)
A	<--	5472	tgtttaaaatttACgt	0.965	6.62	0.478	0.090	13	(5 5)
D	----->	5745	gcgTGAaga	0.991	9.48	0.990	1.956	15	(5 5)
A	<--	5808	catatccatcaaAGgt	0.948	5.83	0.458	0.000	11	(5 5)
A	<--	6135	gggttttacccatAGgt	0.999	13.59	0.508	0.050	12	(5 5)
A	<--	6652	gggttttacccatAGag	0.938	5.42	0.000	0.000	7	(5 1)



Predikce funkce genů *in silico*

vyhledávání genů

- vyhledávání 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/>)



Predikce funkce genů *in silico*

vyhledávání genů

Prediction done

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

The sequence: Sequence has the following <

Length: 9490 nucleotides.
31.8% A, 17.0% C, 19.6% G, 31.7% T, 0.0% U

Donor splice sites, direct strand

pos 5'->3'	phase	strand	con
1704	0	+	
1906	0	+	
4134	0	+	
4619	1	+	
4915	0	+	
5356	0	+	
5384	1	+	
5809	1	+	
6057	0	+	
6096	1	+	
7369	0	+	
7886	0	+	
9323	0	+	

Donor splice sites, complement strand

pos 3'->5' pos 5'->3' phase strand con

Acceptor splice sites, direct strand

pos 5'->3'	phase	strand	con
1213	0	+	
1221	2	+	
1373	0	+	
1487	1	+	
4254	0	+	
4832	2	+	
5004	0	+	
5472	1	+	
6135	0	+	
6490	1	+	
6744	0	+	
7447	0	+	
7780	2	+	
7786	2	+	0.92



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

```
GAGGAGGCACAAAACTCGAATATAACAAATGATCTAACAGCTAAACTATATTGGACATTTCGATCTCAGATATA  
TCAGATATA  
AAAGATTTCATTCA  
CTAATAAAT  
ACGAGTTAACGTCCTAACATGCTTAGACTAAAATACACCATATAATTCAAACGATAAAAGTTACAAAAA
```

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

TCAGATACCTAACACATGCA

CCGAATGCCGTGAGATAATGTTCTCTAAACATGAGTGTGTTATTCTACTAAGCTTCTCTCCCTTCCCCTGCAATACAGATAAAATCATACATGTTCTTAATTATTT
GCCTTAACGAACTCTATAACAAAGGTTTACTCTACTAACAAAAATAATGQTAACAAACATGATTCCGAAGGAAGGGGAAACDTTATGTTATCTATTAATTAACTGATGTCAG
BpuEI BglII

TGCACCTTGAGTTATGGTTCTCTGGGAAAGATCTATGATGCTATCTATATTATTTACTCTTTCTGCTGCTGATTATAGTATATTATATGACACACACACACCTTATGTTAGCTC
VCGAGTAATCATATAATACGTGTTGTTGGATACATCGAG

3350
3216
3082

CTTGGCTGGGAAAGAGATAATGAAAGAGCTTTAGGGTTATCATTCCT
AAACGAGGCTCTCTCTCTATAACTCTCTCTGCAAAACCTGGAAATGAGAAG
exon 2
Hsp90
ORF
029311b_low
XbaI

3350
3216
3082

XAAAGTTACAATGCTCTCGTAGAATTGCAAAACATTGTCGACCTGATTACAT
TATTCATTGTTACGAAAGGACATCTTAACGTTGTAACACCTGGCACTAAATGTA

3484
3364
3244

PvuI
CTTGGCCTTCTTGACGCTCTGTTGATTCTTGA
TTTTTCTAGCGGCAAAGAAACGCTGCTCAGACTAGAAATCT
3618

3618
3502
3382

HindIII
BmgBI
MfeI
exon 4
cki-182
Xckw
H M V K T L V A S R P I V

3618
3502
3386

TTTCAATGATAATTATTGTTGTTATACCCATTCTGATATTGAA
AAAAGTTACTATTAAACACACATAGTGGTAAGTACATATAAAACTT

4020
3900
3780

BglII BpuEI
AAGAGGTCCCTTCTTACCGAAATCTCCGGACAAAGCTAGTTGGAGATTGAA
TTCTCAGCGAAAGTAATGGCTTCTAGAGGCCGTCGATCAAAGCTCTAACCTT
K E V A S F T E D L R T S L V S E I E

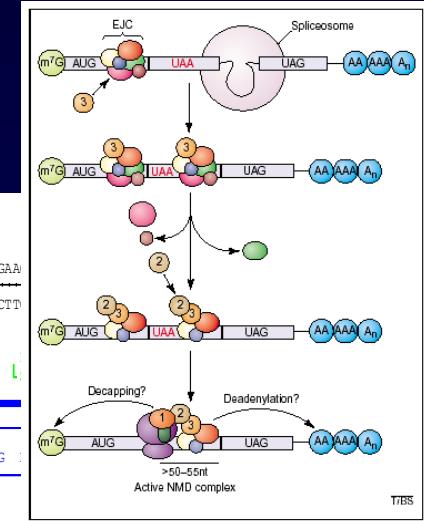
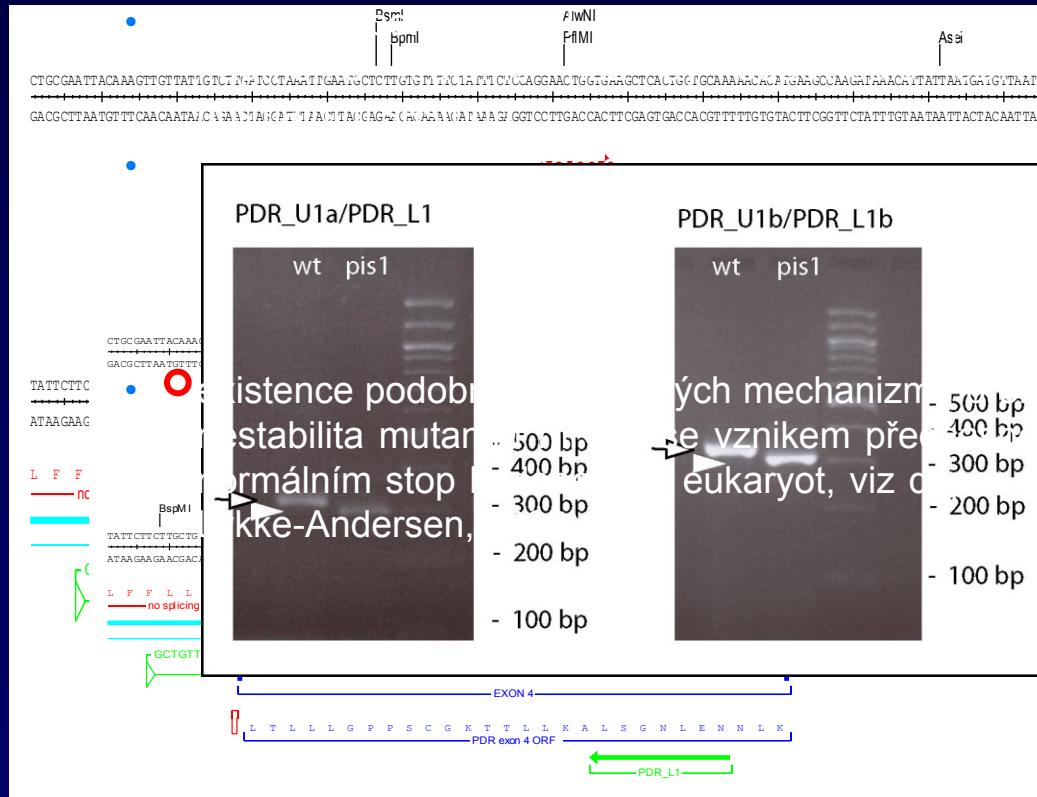
4020
3900
3780



Predikce funkce genů *in silico*

vyhledávání genů

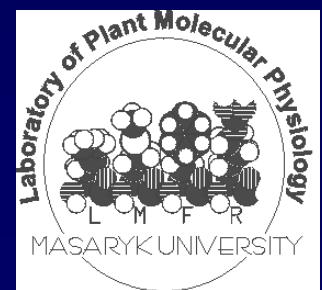
- odchylky rozpoznávání míst sestřihu u rostlin v praxi - příklad vývojové plasticity (nejen) rostlin
 - identifikace mutanta s bodovou mutací (tranzice G→A) přesně v místě sestřihu na 5' konci 4. exonu



Predikce funkce genů *in silico*

vyhledávání genů

- vyhledávání 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/>)
 - programy pro predikci exonů
 - 4 typy exonů (podle polohy):
 - iniciační
 - vnitřní
 - terminální a
 - 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/>)



Predikce funkce genů *in silico*

vyhledávání genů

The New GENSCAN Web Server at MIT

GENSCANW output for sequence CKII

GENSCAN 1.0 Date run: 10-Nov-105 Time: 02:24:26

Sequence CKII : 9490 bp : 36.53% C+G : Isochore 1 (0 - 43 C+G%)

Parameter matrix: *Arabidopsis.smat*

Predicted genes/exons:

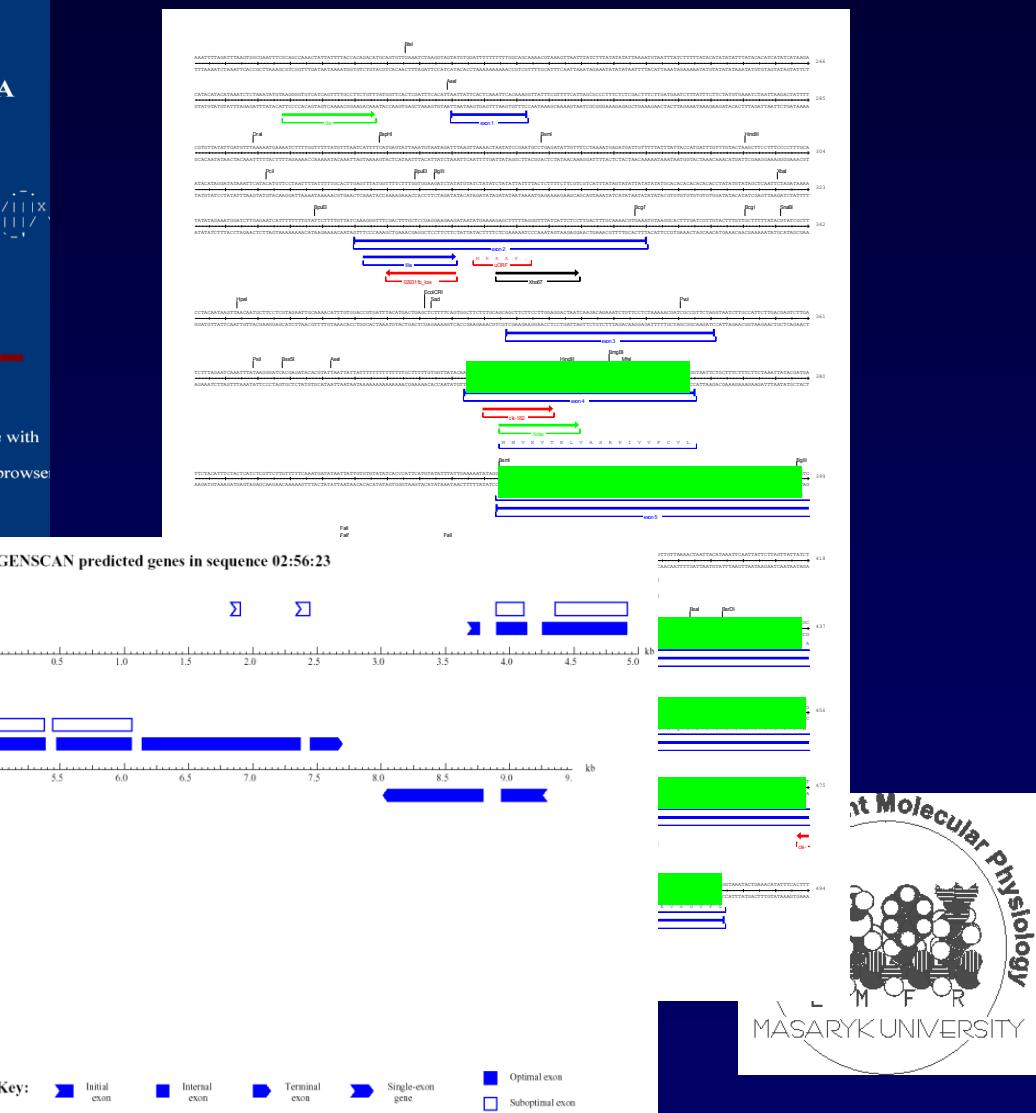
Gn.	Ex.	Type	S.	.Begin	..End	.Len	Fr	Ph	I/Ac	Do/T	CodRg	P....	Tscr..
1.00	Prom	+	1497	1536	40							-3.85	
1.04	Intr	+	5005	5383	379	0	1	70	91	343	0.772	31.41	
1.05	Intr	+	5473	6056	584	2	2	38	99	582	0.722	50.76	
1.06	Intr	+	6136	7368	1233	0	0	68	108	655	0.977	56.86	
1.07	Term	+	7448	7660	213	1	0	43	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	-	8793	8050	744	0	0	107	37	542	0.997	48.46	
2.01	Term	-	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	217	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	Init	+	5005	5379	375	0	0	70	8	335	0.212	22.99	
S.006	Intr	+	5442	6056	615	2	0	95	99	589	0.208	57.32	

To have the results mailed to you, enter your email address here (optional):

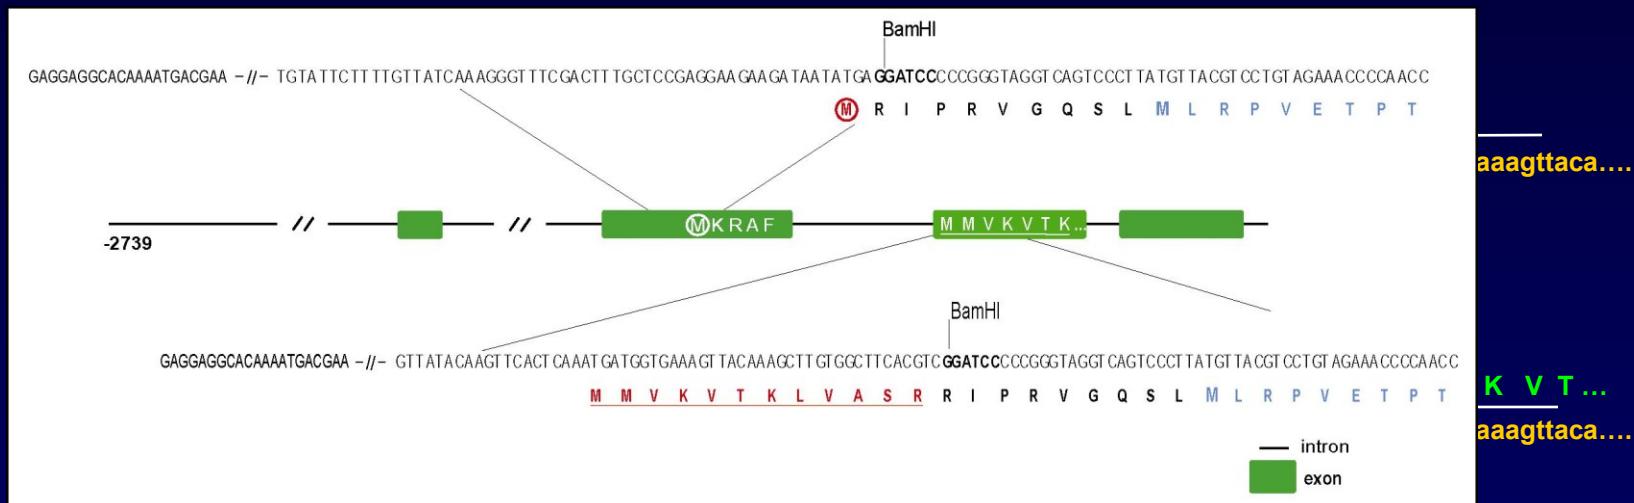
[Back to the top](#)



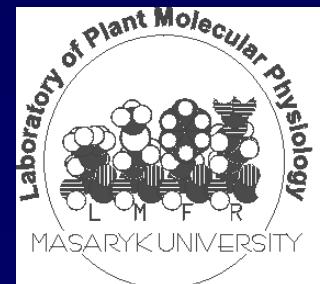
Predikce funkce genů *in silico*

vyhledávání genů

- Funkční význam sestřihu v nepřekládaných oblastech - důležitá regulační součást genů



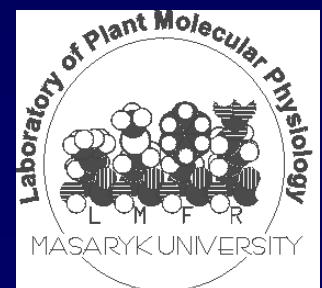
- V případě CKI1 pokus prokázat tento způsob regulace genové exprese pomocí transgenních linií nesoucích *uidA* pod kontrolou dvou verzí promotoru, zatím nepotvrzeno



Predikce funkce genů *in silico*

vyhledávání genů

- vyhledávání genů *ab inicio*
 - 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/>)



Predikce funkce genů *in silico* vyhledávání genů

Eukaryotic GeneMark.hmm^(1,2) ([Reload this page](#))

Result of last submission:

[View PDF Graphical Output](#)

[GeneMark.hmm Listing](#)

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

Go to: [Job Submission](#)

Eukaryotic GeneMark.hmm version bp 3.9 April 25, 2008

Sequence name: CK1L

Sequence length: 5043 bp

G+C content: 38.79%

Matrices file: /home/genemark/euk_ghm.matrices/athaliana

Thu Oct 1 11:09:24 2009

[Predicted genes/exons](#)

Gene #	Exon #	Strand	Exon Type	Exon Range	Exon Length
1	1	+	External	2266 - 2644	388
1	4	+	Internal	2266 - 2644	388
1	5	+	Internal	2734 - 3317	583
1	6	+	Internal	3397 - 4629	1232
1	7	+	Terminal	4709 - 4921	212

[Procházet...](#)

Species: **A**thaliana ES-3.0 [Model description](#)

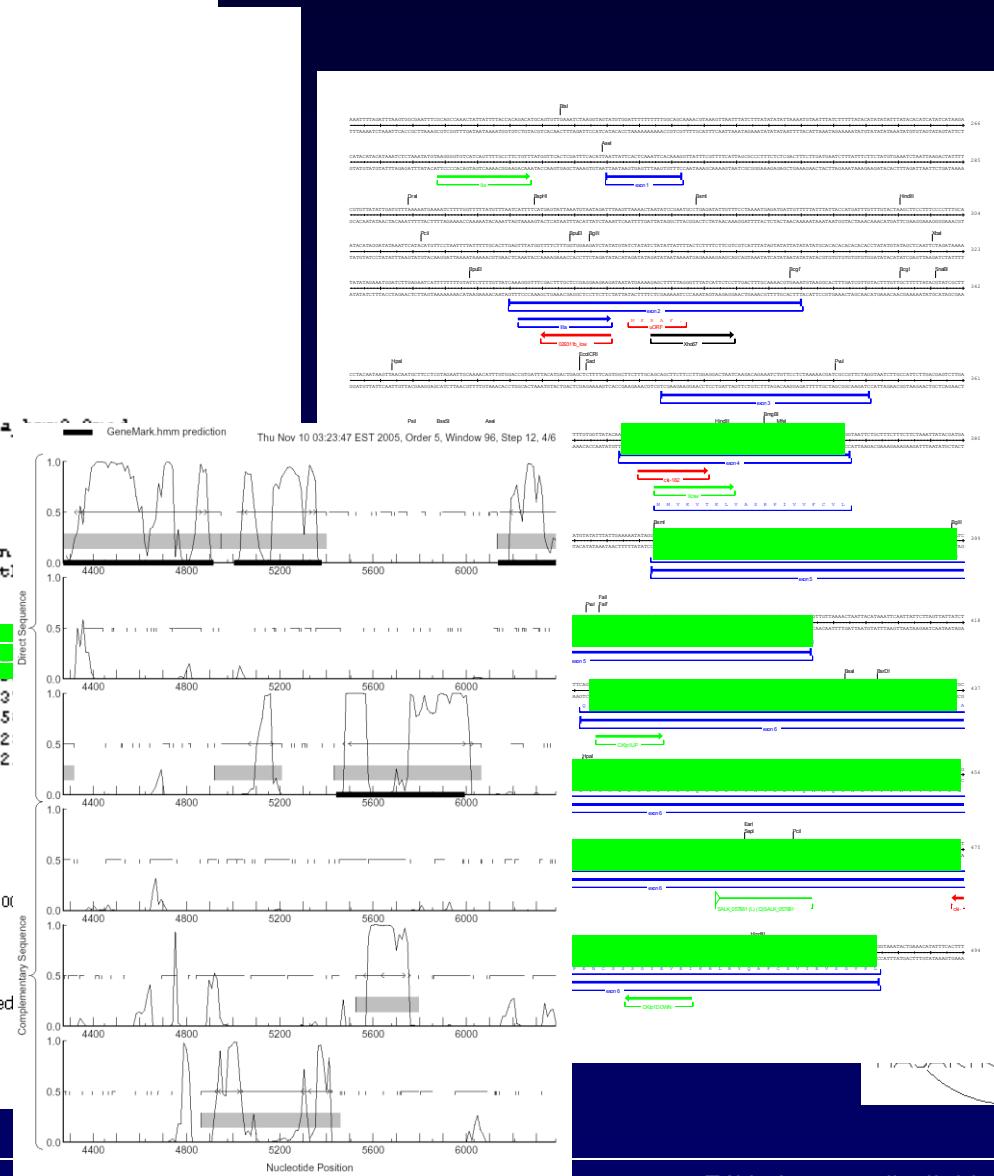
Output Options

Email Address: (required for graphical output or sequences longer than 4000)

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

Run

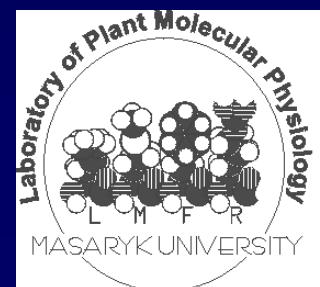
[Default](#)
[Start GeneMark.hmm](#)



Predikce funkce genů *in silico*

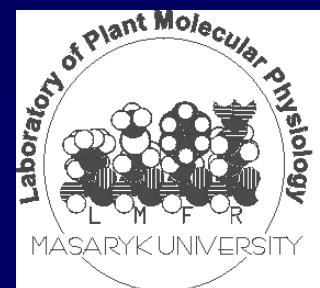
vyhledávání genů

- vyhledávání genů podle homologií
 - 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/lbl1690.html>)



Základy genomiky II.

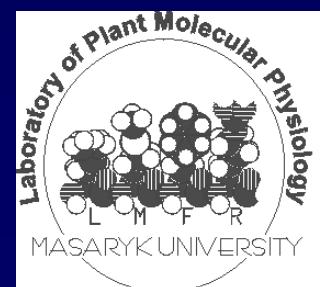
- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Predikce funkce genů *in silico*
 - struktura genů a jejich vyhledávání
 - genomová kolinearita a genová homologie



Predikce funkce genů *in silico*

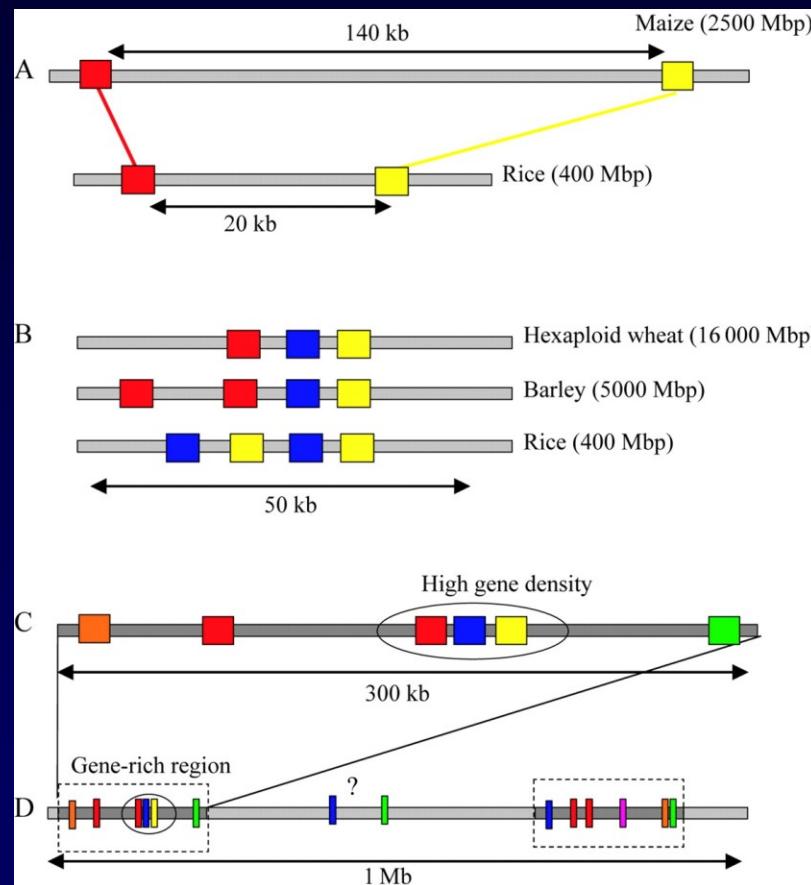
vyhledávání genů

- genomová kolinearita a genová homologie
 - 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, 46-55 tis. genů) 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)

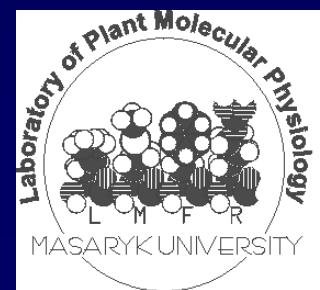


Predikce funkce genů *in silico*

vyhledávání genů-genomová kolinearita



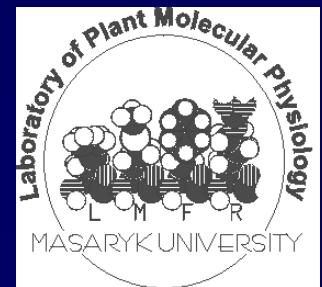
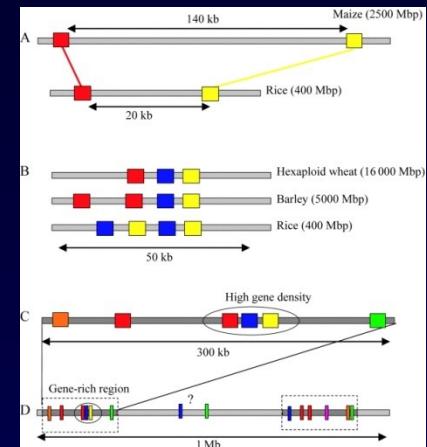
Feuillet and Keller, 2002



Predikce funkce genů *in silico*

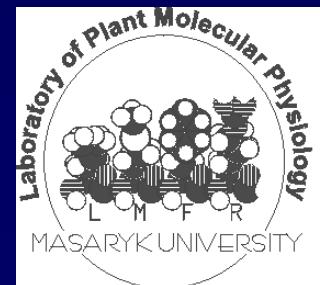
vyhledávání genů

- genomová kolinearita a genová homologie
 - 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, 46-55 tis. genů) 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)
 - zejména využitelné u trav (např. využití příbuznosti u ječmene, pšenice, rýže a kukuřice)
 - malé geonomové 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.)



Základy genomiky II.

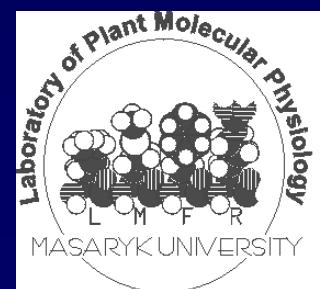
- Postupy „přímé“ a reverzní genetiky
 - rozdíly v myšlenkových přístupech k identifikaci genů a jejich funkcí
- Predikce funkce genů *in silico*
 - struktura genů a jejich vyhledávání
 - genomová kolinearita a genová homologie
- Experimentální identifikace genů
 - příprava genově obohacených knihoven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



Predikce funkce genů *in silico*

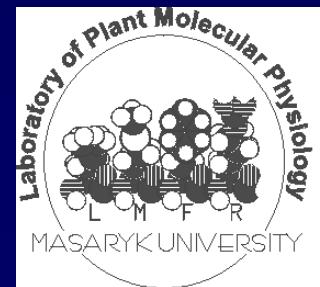
vyhledávání genů

- 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
- schéma postupu při přípravě BAC genomových knihoven pomocí metylačního filtrování:
 - příprava genomové DNA bez příměsí 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 %



Základy genomiky II.

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



Predikce funkce genů *in silico* vyhledávání genů-EST knihovny

- příprava EST knihoven
 - izolace mRNA
 - RT PCR
 - 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

NCBI Nucleotide

Search [Nucleotide] for [] Preview/Index History Features

Display [Default] Units [Show 20] Send to [Get Subsequence Features]

□ NC_002377, Agrobacterium tumefaciens (Bhizobium radiobacter)

LOCUS NC_002377 2490 bp RNA linear NCBI 29-DEC-2003

DEFINITION Agrobacterium tumefaciens (Bhizobium radiobacter) plasmid Tn1 complete sequence.

ACCESSION NC_002377 EMBL:144544, 144543

VERSION NC_002377.1 GI:10955016

FEATURES

SOURCE Agrobacterium tumefaciens (Bhizobium radiobacter)

ORGANISM Bacteria; Proteobacteria; Alphaproteobacteria; Rhizobiales;

REFERENCE 1. (bases 1 to 2490)
AUTHORS Winnie,L.C., Zhai,J., Opre,P.N., Schrammeijer,B., Hooykaas,P.J. and

TITLE Octopine-type Tn1 plasmid sequence

REFERENCE 2. (bases 1 to 2490)
AUTHORS Winnie,L.C., Opre,P.N., Schrammeijer,B., Hooykaas,P.J., Farrand,S.K. and

TITLE Direct sequencing of Tn1

JOURNAL J Bact 182(17):4930-2000 Microbiology, Cornell University, Ithaca, NY, USA

HALL, Ithaca, NY 14853, USA

COMMENT This sequence record has not yet been subject to final NCBI review. The reference sequence was derived from AF214381.

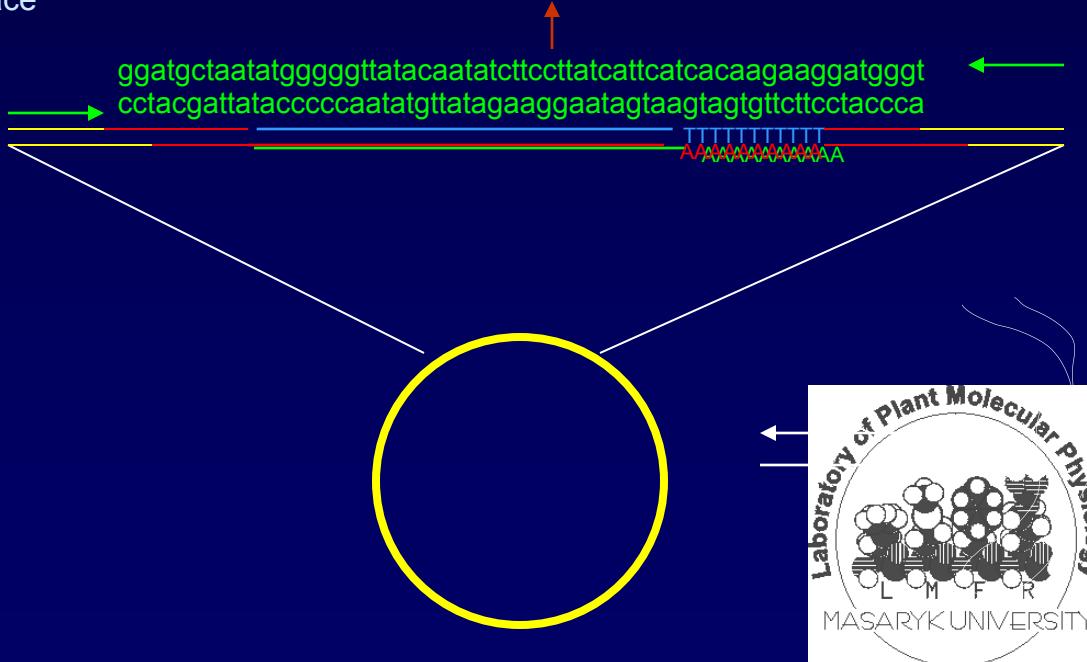
FEATURES

source 1..2490
/organism="Agrobacterium tumefaciens"
/genomic="genomic DNA"
/db_xref="taxon:158"
/db_xref="NC_002377"
/note="extrachromosomal

gene 1..2490
/name="virA"
/db_xref="NC_002377ID:1224345"
/note="two-component regulator of vir repulsion; VirA is a

CDS 1..2490
/name="virR"
/note="two-component regulator of vir repulsion; VirR is a

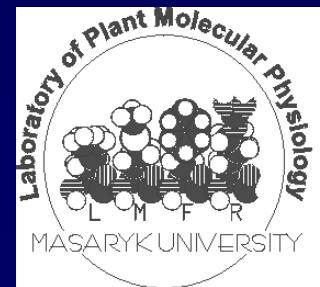
ggatgctaataatggggttatacaataatcttccttatacattcatcacaagaaggatgggt
cctacgattataccccaatatgttatagaaggaaatagtaagttagtgtttccctaccca



Základy genomiky II.

shrnutí

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



Základy genomiky II.

diskuse

