


# Základy genomiky

## II. Identifikace genů



Jan Hejátko


Masarykova univerzita, Laboratoř funkční genomiky a proteomiky  
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, Exonomy, 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
- 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

„Reverzně genetický“ přístup

5'TTATATATATATATTTAAAAATAAAATA  
AAAGAACAAAAAGAAAATAAAAATA...3'





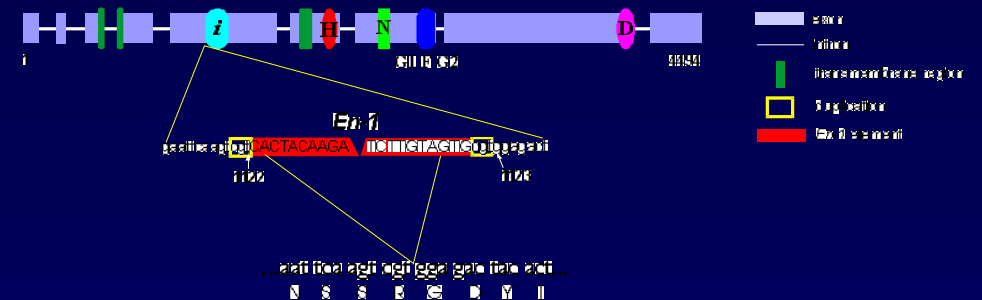
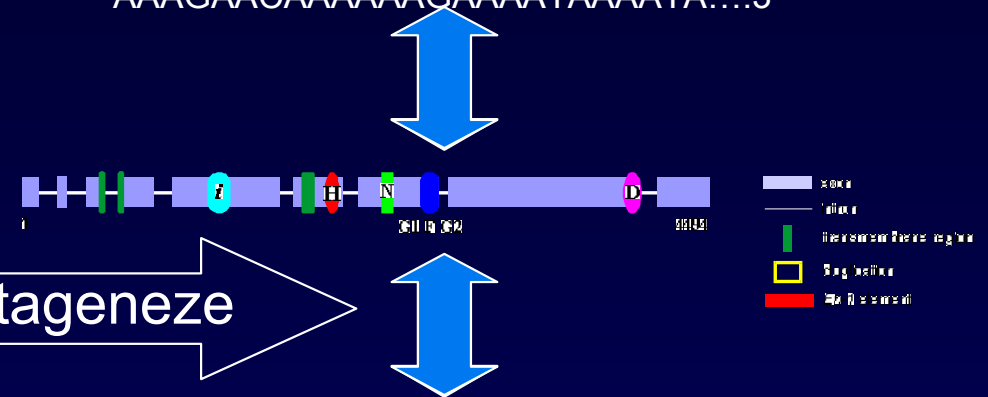
3

:

1



?


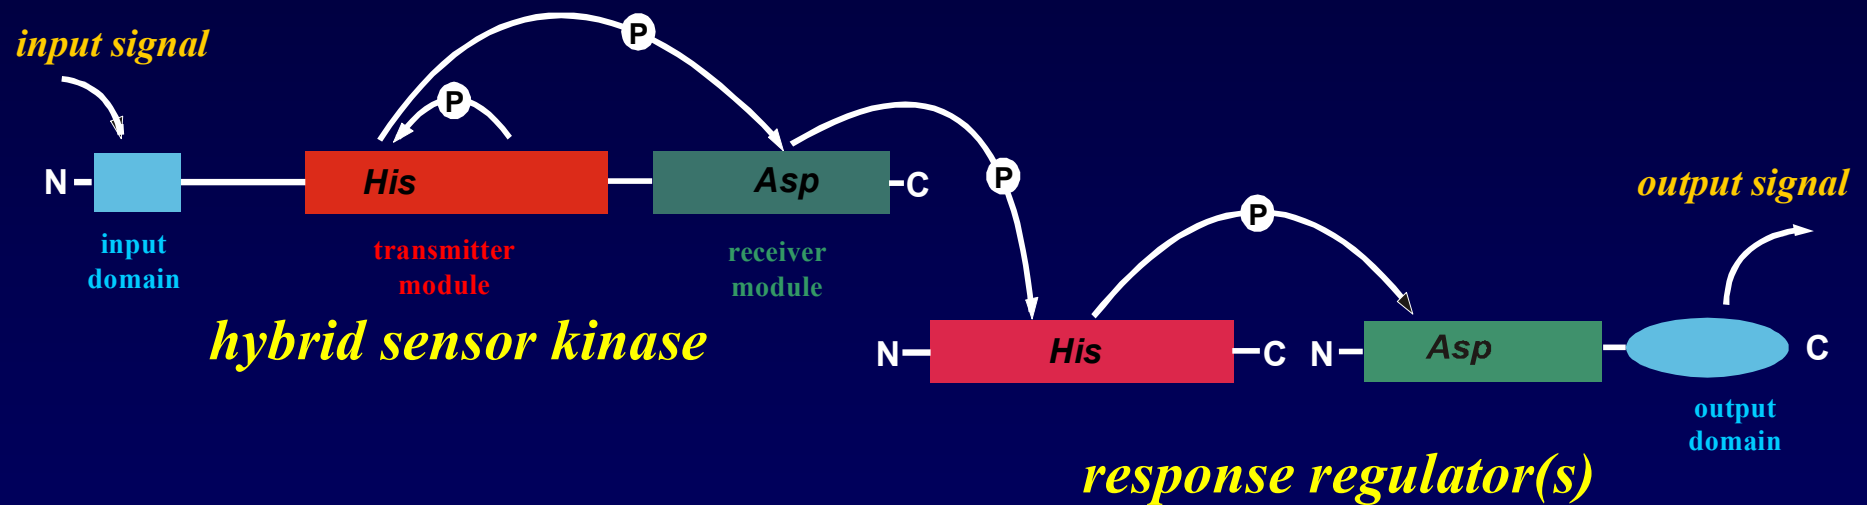


# Identifikace role genu *ARR21*

- Předpokládaný přenašeč signálu u dvoukomponentního signálního systému *Arabidopsis*




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





# 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




# Identifikace role genu *ARR21* identifikace inzerčního mutanta

- vyhledávání v databázi inzerčních mutantů (SINS)

```
Insert_SINS: 01_09_64
Query: 80      tcctagcgttcacatgagcgtaccataacttgacaanagagaacgtagccagccatttacagg 139
              |||
Sbjct: 58319   tcctagcgttcacatgagcgtaccataacttgacaagagagaacgtagccagccatttacagg 58378
Arr21: 1830


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

- lokalizace inserce *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




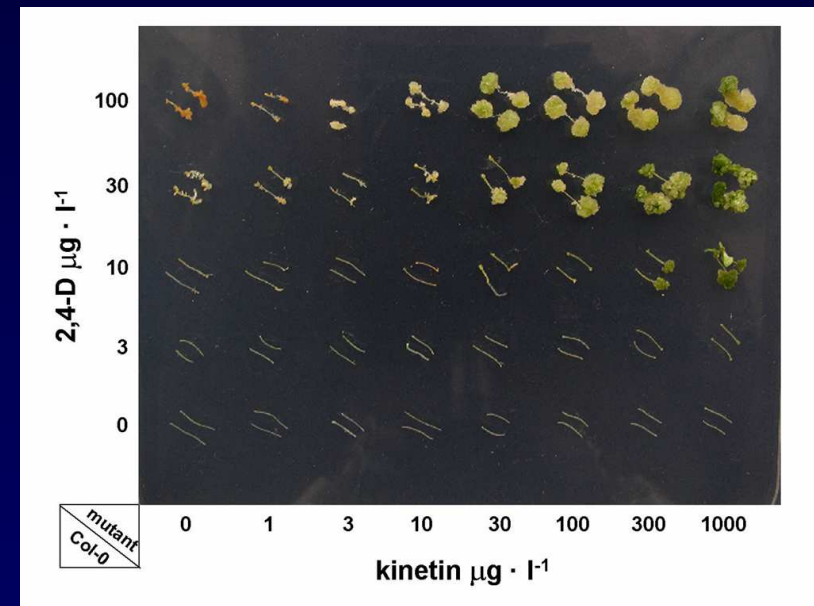
# Identifikace role genu *ARR21*

- 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 inzerčního 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 mutantu

- 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

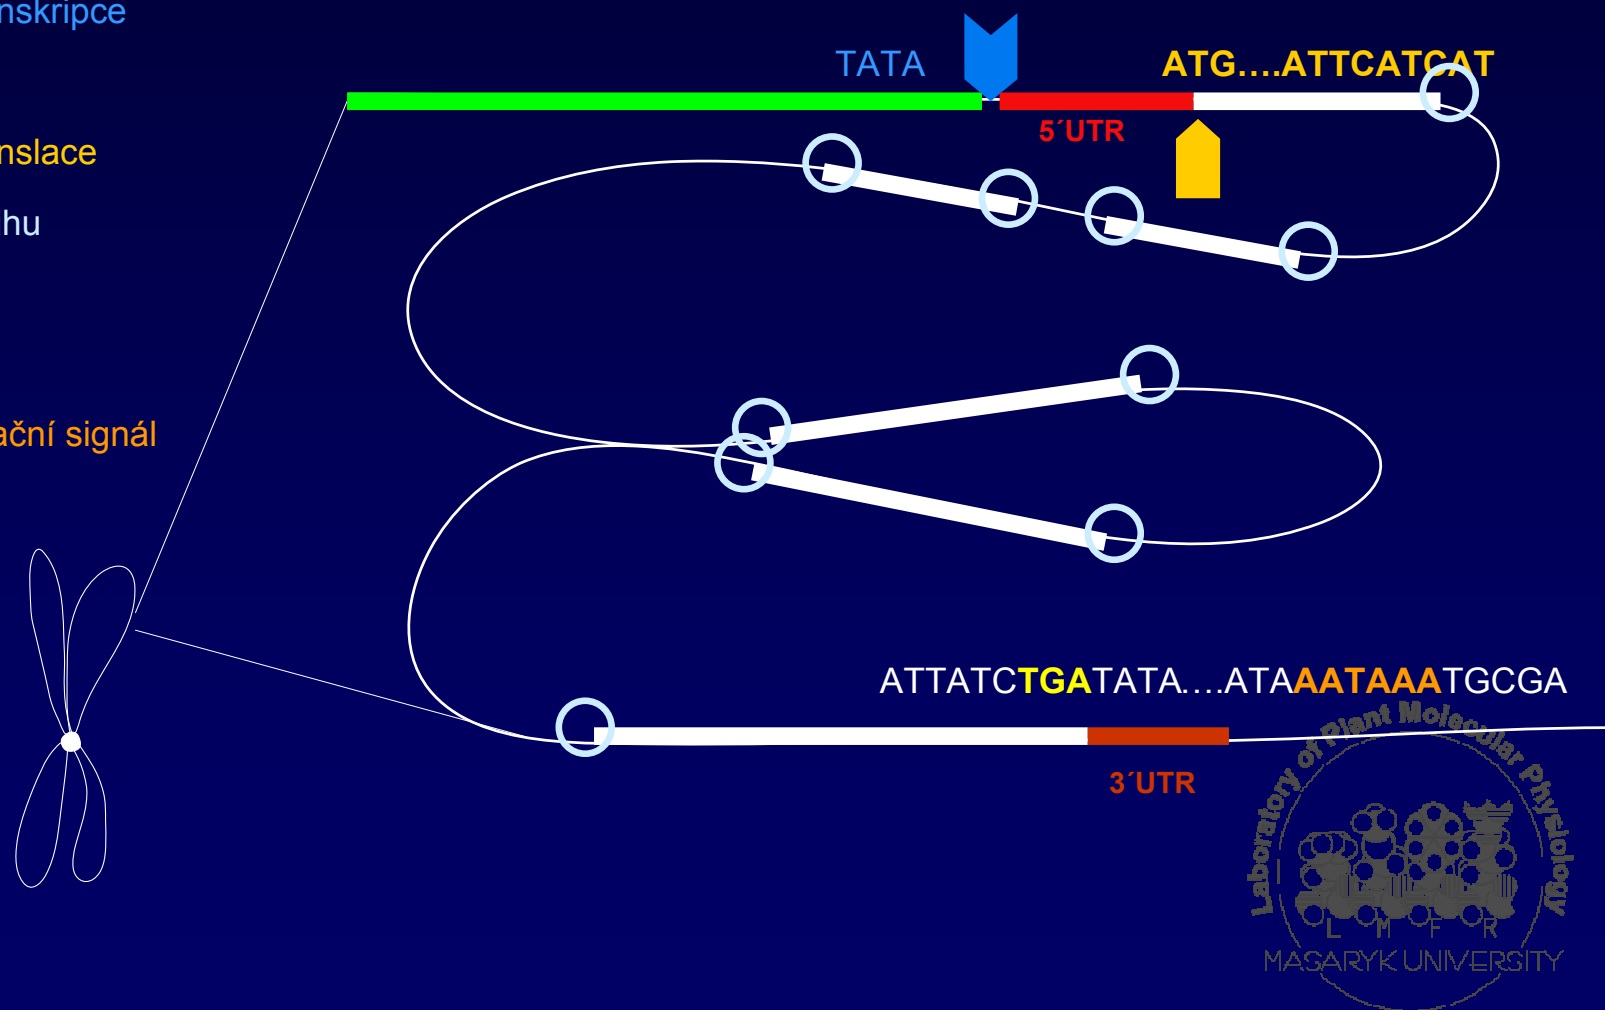


# Predikce funkce genů *in silico*

## 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 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



# Predikce funkce genů *in silico*

## vyhledávání genů

- vyhledávání genů *ab initio*
  - programy pro predikci míst sestřihu (specifická přibližně 35%)
    - GeneSplicer ([http://www.tigr.org/tdb/GeneSplicer/gene\\_spl.html](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


| t | q     | loc  | sequence             | P     | c     | rho   | gamma | *          | P*R* |
|---|-------|------|----------------------|-------|-------|-------|-------|------------|------|
| A | <--   | 75   | ttttttcgcactcAGat    | 0.973 | 7.16  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 134  | attattttttttAGtt     | 0.999 | 14.86 | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 500  | gattttgtgtttAGtc     | 0.977 | 7.48  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 780  | tctgttattgtatAGct    | 0.986 | 8.56  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 848  | taatttttgaatAGat     | 0.968 | 6.80  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 1051 | caatttttttttaAGaa    | 0.930 | 5.19  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 1213 | ttattttttttttAGtt    | 0.998 | 12.14 | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 1373 | tttccctctctcaacAGga  | 0.999 | 13.17 | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 1487 | tttatatttggatAGtg    | 0.883 | 4.04  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 1581 | atgtgttctgtAGga      | 0.982 | 8.03  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 1781 | ggttggtgcgaatAGgg    | 0.886 | 4.10  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 2440 | taattaaaaatttAGat    | 0.939 | 5.46  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 2479 | catctaaaaatttAGat    | 0.942 | 5.59  | 0.000 | 0.000 | 7 (5 1     |      |
| D | ----> | 2546 | aagGTagta            | 0.909 | 4.61  | 0.885 | 1.903 | 15 (5 5    |      |
| A | <--   | 2572 | ttttttttttggcAGca    | 0.930 | 5.16  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <---- | 2763 | ctcaaattcacaatAGgt   | 0.873 | 3.86  | 0.185 | 0.000 | 11 (5 5 1) |      |
| A | <---- | 2782 | tttctgtttcattAGcg    | 0.952 | 5.98  | 0.220 | 0.000 | 11 (5 5 1) |      |
| A | <---- | 3022 | tttgtttgtactaAGct    | 0.956 | 6.16  | 0.221 | 0.000 | 11 (5 5 1) |      |
| A | <---- | 3048 | ctttgcaatcatAGga     | 0.973 | 7.15  | 0.229 | 0.000 | 11 (5 5 1) |      |
| A | <--   | 3171 | cgctgtcatttatAGta    | 0.988 | 8.74  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <---- | 3284 | cttttggatcaaaAGgg    | 0.993 | 10.03 | 0.000 | 0.006 | 8 (5 1     |      |
| A | <---- | 3332 | tttttttttttgaagAGg   | 0.933 | 5.25  | 0.000 | 0.000 | 11 (5 1    |      |
| A | <---- | 3451 | aatgcttctctgtAGaa    | 0.916 | 4.77  | 0.293 | 0.065 | 12 (5 5 2) |      |
| A | <---- | 3551 | gatttgcctctctAGgg    | 0.850 | 4.47  | 0.000 | 0.000 | 7 (5 1     |      |
| D | ----> | 3649 | cacGTatta            | 0.933 | 5.25  | 0.000 | 1.848 | 11 (5 1    |      |
| A | <--   | 3686 | ttttttttttttgcccAGat | 0.990 | 4.86  | 0.000 | 0.000 | 7 (5 1     |      |
| A | <--   | 4254 | attattgtttttcAGat    | 0.998 | 12.82 | 0.000 | 0.002 | 8 (5 1 2)  |      |
| A | <--   | 4351 | tttcttaccattgcAGaa   | 0.991 | 9.42  | 0.000 | 0.000 | 7 (5 1 1)  |      |
| A | <--   | 4633 | gtctgttttttttAGgg    | 0.879 | 3.97  | 0.000 | 0.000 | 7 (5 1 1)  |      |
| A | <--   | 4976 | cttgttgtttttcAGct    | 0.952 | 5.98  | 0.000 | 0.000 | 7 (5 1 1)  |      |
| A | <--   | 5004 | ttttttttttttgcccAGag | 0.996 | 11.17 | 0.000 | 0.000 | 7 (5 1 1)  |      |
| D | ----> | 5356 | caaGTgaat            | 0.821 | 3.04  | 0.387 | 0.000 | 11 (5 5    |      |
| D | ----> | 5384 | ttgGtaaga            | 0.941 | 5.54  | 0.478 | 0.090 | 13 (5 5 3) |      |
| A | <--   | 5403 | actctgttttttAGct     | 0.894 | 4.26  | 0.000 | 0.000 | 7 (5 1 1)  |      |
| A | <---- | 5441 | ctttctctctaacAGaa    | 0.995 | 10.43 | 0.387 | 0.000 | 11 (5 5 1) |      |
| A | <--   | 5472 | ttgttaaaattacAGct    | 0.965 | 6.62  | 0.478 | 0.090 | 13 (5 5 3) |      |
| D | ----> | 5745 | gcgGtaaga            | 0.991 | 9.48  | 0.990 | 1.956 | 15 (5 5 5) |      |
| A | <---- | 5808 | catcatatcctaaAGgt    | 0.948 | 5.83  | 0.458 | 0.000 | 11 (5 5 1) |      |
| A | <---- | 6135 | ggtctattattatAGgt    | 0.999 | 13.59 | 0.508 | 0.050 | 12 (5 5    |      |
| A | <--   | 6552 | ggattttcacctcAGag    | 0.938 | 5.42  | 0.000 | 0.000 | 7 (5 1     |      |



# Predikce funkce genů *in silico*

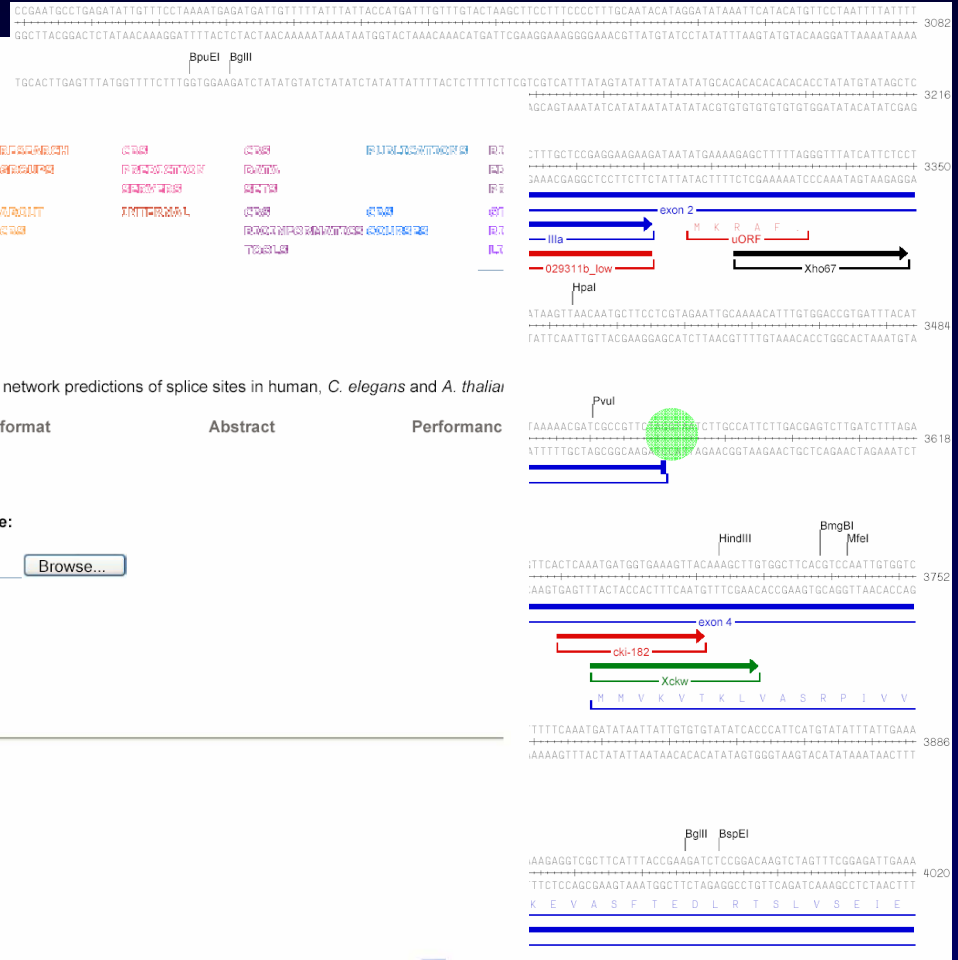
## vyhledávání genů

- vyhledávání genů *ab initio*
  - programy pro predikci míst sestřihu (specificita přibližně 35%)
    - GeneSplicer ([http://www.tigr.org/tdb/GeneSplicer/gene\\_spl.html](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%

Donor splice sites, direct strand

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

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

TCGATACAG^AACACATGCA



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

GAGGAGGCACAAAATCACGAATATACAAAATGATCTTAAACAGCTAAACTATATGGACATTTTTTCGATC  
TCAGATATA  
AAAGATTTCATTCAATATAAATACTTGGATAAATACTCTTATTATTTTTCTTTAGTTTATTAACAAAAACCT  
CTAATAAAT  
ACGAGTTTAAAGTCCACAAAATCGCTTAGACTAAAATACACCATATAATTTCAAACGATAAAGTTTACAAAA

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

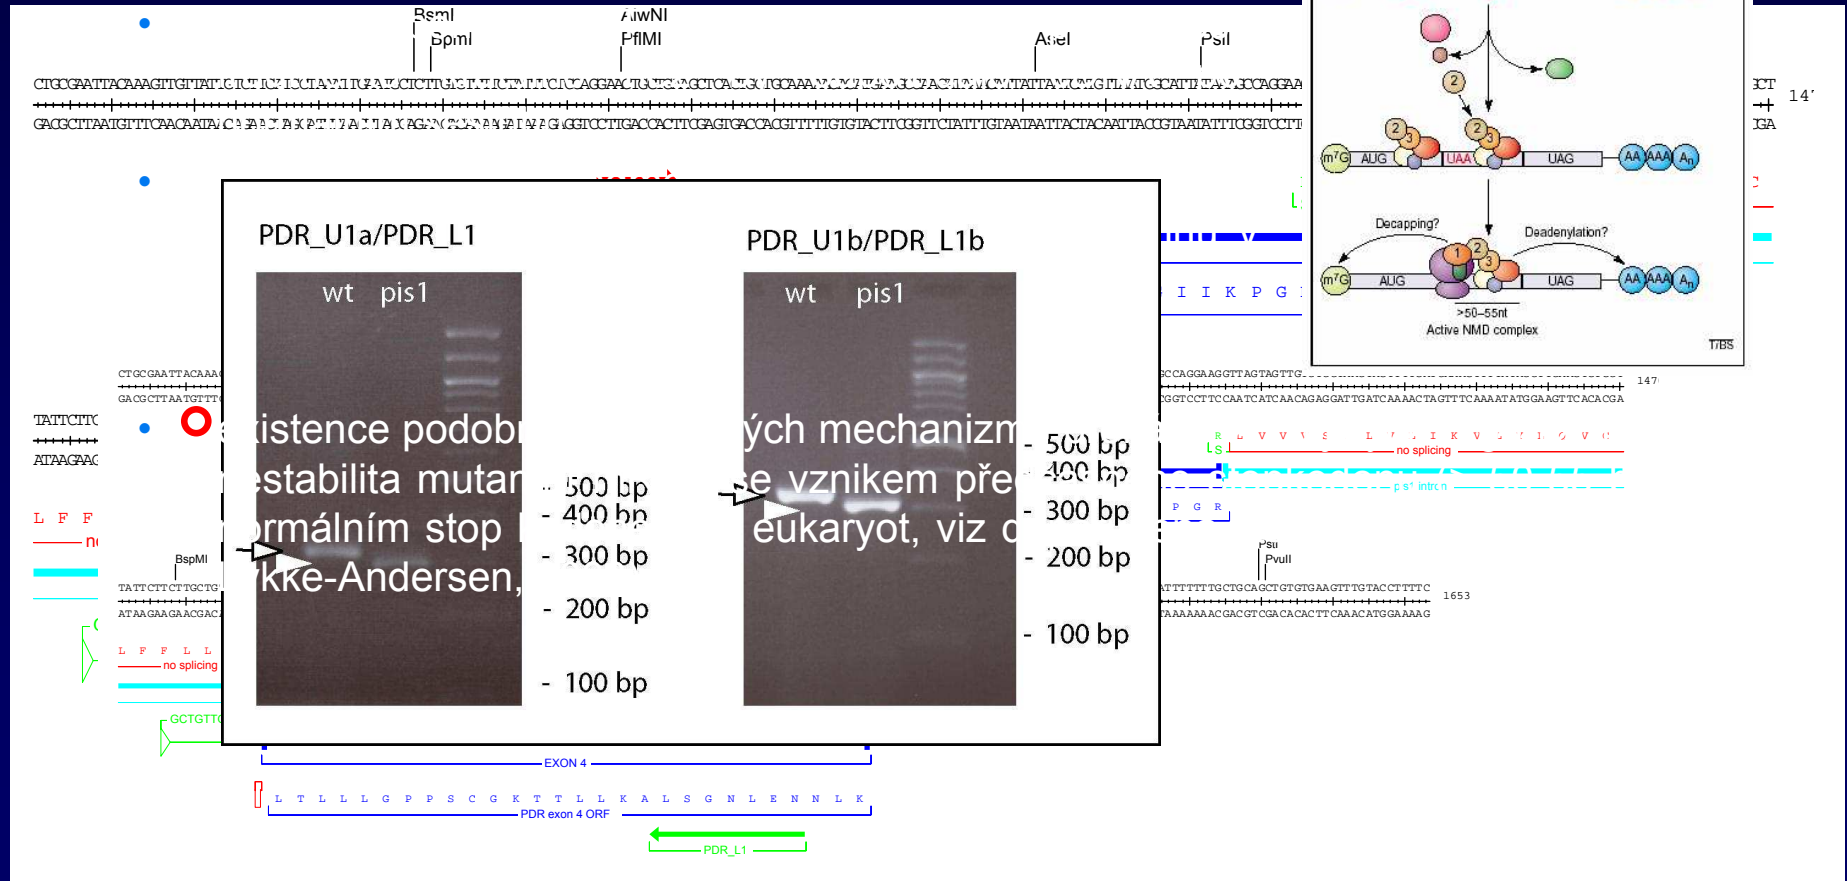


# Predikce funkce genů *in silico*

## vyhledávání genů

- 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



# Predikce funkce genů *in silico*

## vyhledávání genů


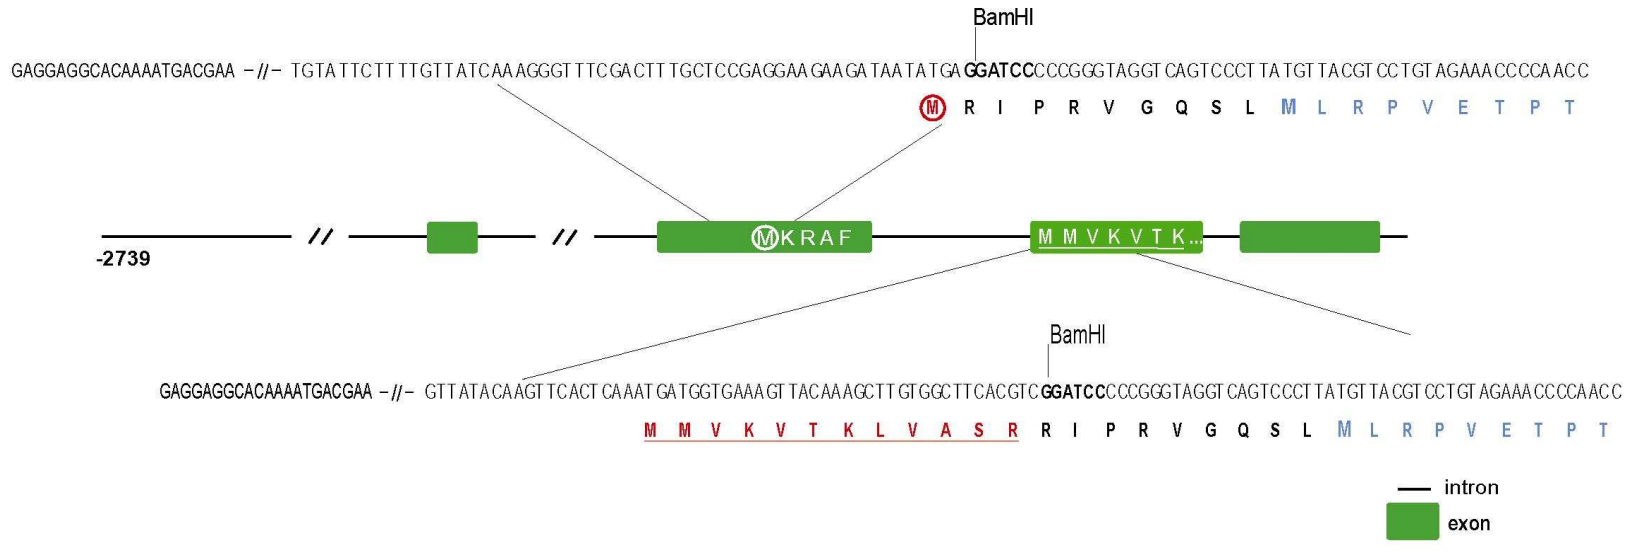
- vyhledávání genů *ab initio*
  - programy pro predikci míst sestřihu (specifická přibližně 35%)
    - **GeneSplicer** ([http://www.tigr.org/tdb/GeneSplicer/gene\\_spl.html](http://www.tigr.org/tdb/GeneSplicer/gene_spl.html))
    - **SplicePredictor** (<http://deepc2.psi.iastate.edu/cgi-bin/sp.cgi>)
    - **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 CK11





```
GAG
TCA
AAA
CTA
ACG
GTAATATCC
AAGTATCTCATAGTCAACATATATATA
GTATCTTAT
TTTGGGTGGTCTGACTGGTGACTGGT
GTTTTAGAT
AGAACAAAATAAGTGTCCGAAGGAATG
AATAAAAAC
```

To have the results mailed to you,

Run GENSCAN Clear Input

[Back to the top](#)

Key: ■ Initial exon ■ Internal exon ■ Terminal exon ■ Single-exon gene ■ Optimal exon □ Suboptimal exon

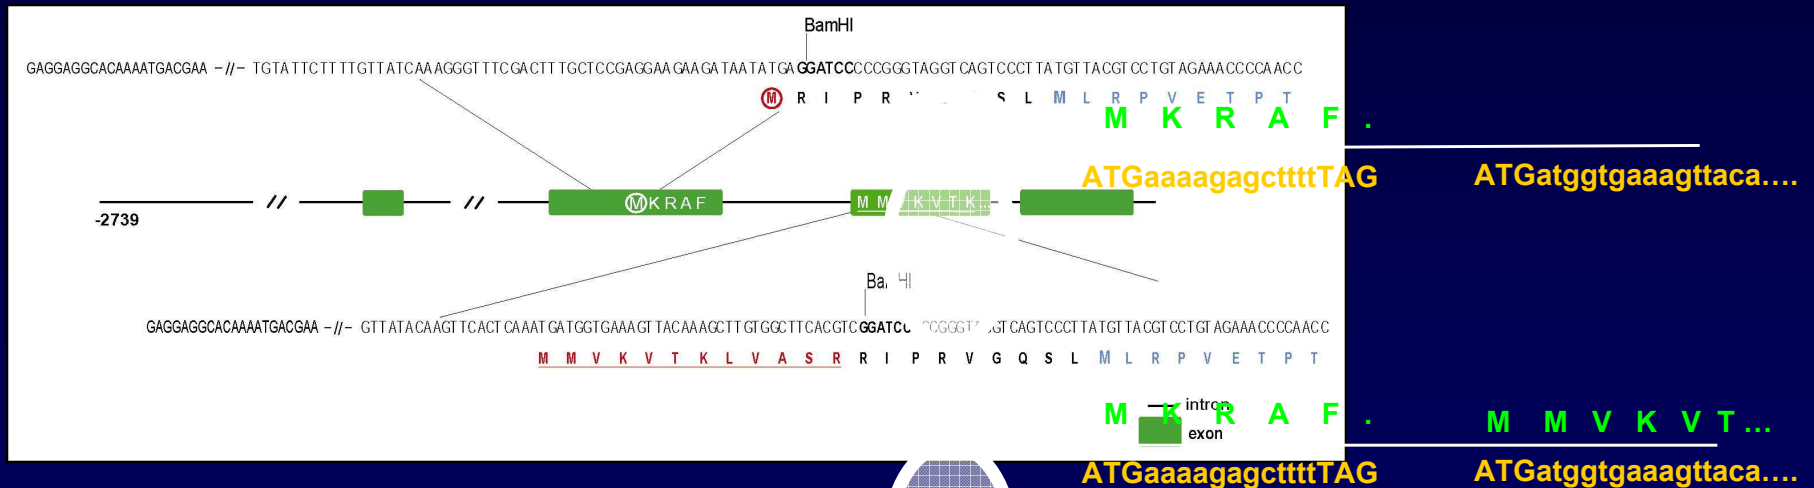


..\\..sequences\\CK11\\cki\_genomic.mpd

# Predikce funkce genů *in silico*

## vyhledávání genů

- 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



# Predikce funkce genů *in silico*

## vyhledávání genů

- vyhledávání genů *ab initio*

- programy pro genové modelování


- zohledňují také další parametry, např. návaznost ORF



- **Genescan** (<http://genes.mit.edu/GENSCAN.html>)

- velice dobrý pro predikci exonů v kódujících oblastech (testováno na genu *PDR9*, identifikoval všech 23 (!) exonů)

- **GeneMark.hmm** (<http://opal.biology.gatech.edu/GeneMark/>)



# Predikce funkce genů *in silico*

## vyhledávání genů

### Result of last submittal:

[View PDF Graphical Output](#)

GeneMark.hmm Listing

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

Go to: [Job Submittal](#)


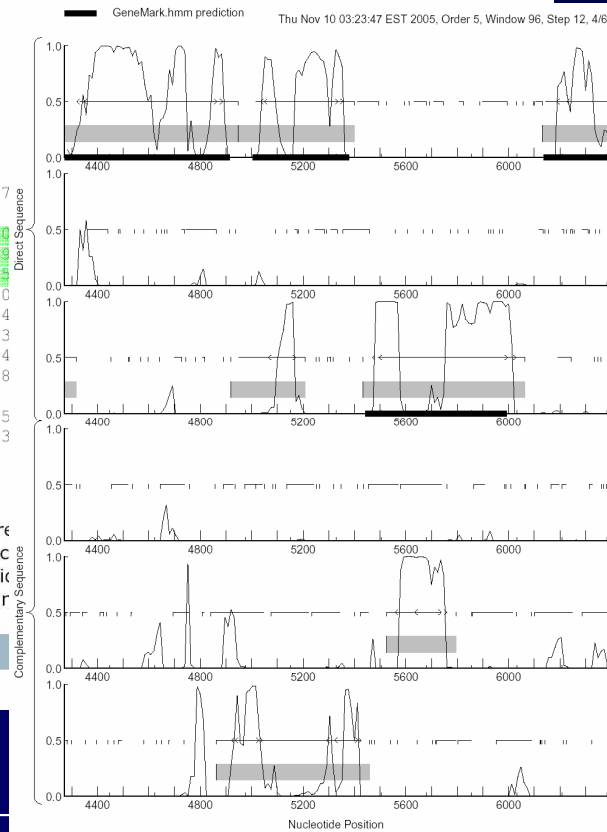
GeneMark.hmm (Version 2.2a)  
 Sequence name: Thu Nov 10 03:24:47 EST 2005  
 Sequence length: 9490 bp  
 G+C content: 36.53%  
 Matrix: Homo sapiens  
 Thu Nov 10 03:24:48 2005

Predicted genes/exons

| Gene # | Exon # | Strand | Exon Type | Length |
|--------|--------|--------|-----------|--------|
| 1      | 1      | +      | Terminal  | 137    |
| 2      | 4      | +      | Internal  | 500    |
| 2      | 5      | +      | Internal  | 544    |
| 2      | 6      | +      | Internal  | 613    |
| 2      | 7      | +      | Internal  | 744    |
| 2      | 8      | +      | Terminal  | 778    |
| 3      | 2      | -      | Terminal  | 805    |
| 3      | 1      | -      | Initial   | 893    |

- Generate PDF graphics (screen)
- Generate PostScript graphic
- Print GeneMark 2.4 prediction
- Translate predicted genes in


Run



# 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/lbnl1690.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



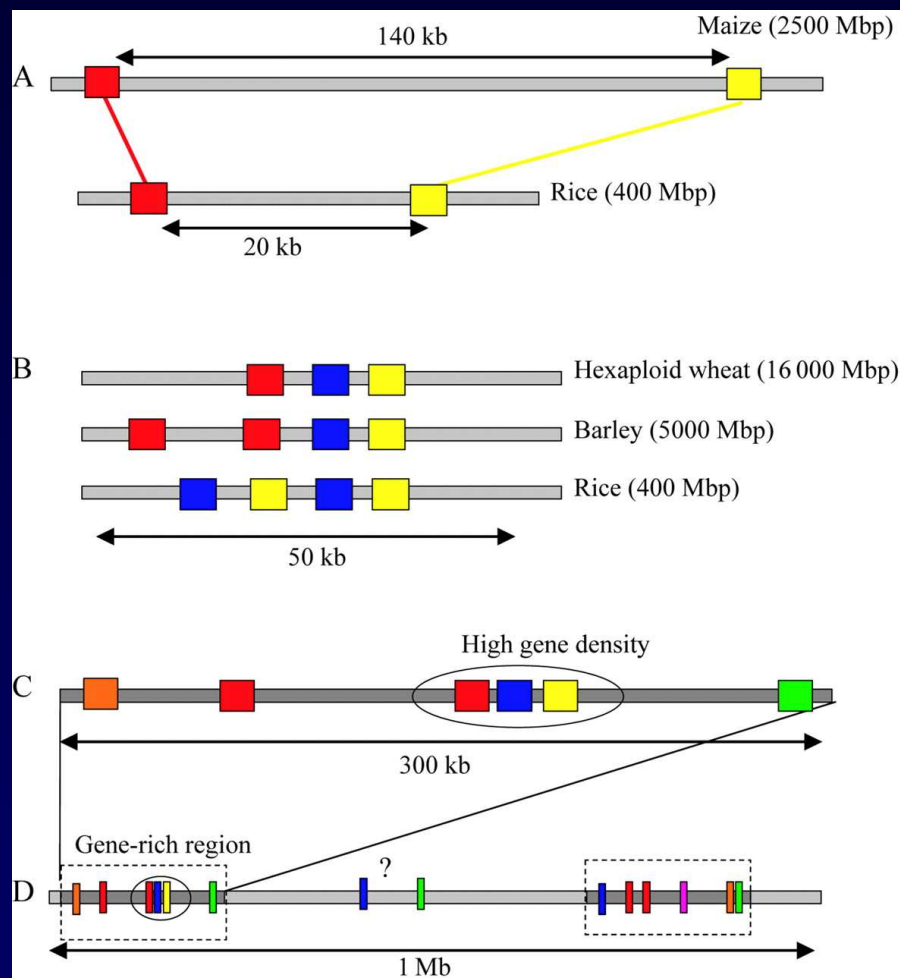
# Predikce funkce genů *in silico*

## 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 organismů pomocí vyhledávání v databázích
  - obecné schéma postupu při využívání genomové kolinearity (také „komparativní genomika“) při experimentální identifikaci genů příbuzných organismů:
    - mapování malých genomů s využitím nízkokopiových DNA markerů (např. RFLP)
    - využití těchto markerů k identifikaci orthologních genů (genů se stejnou nebo podobnou funkcí) příbuzného organismu
    - 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 organismů pomocí vyhledávání v databázích
  - obecné schéma postupu při využívání genomové kolinearity (také „komparativní genomika“) při experimentální identifikaci genů příbuzných organismů:
    - mapování malých genomů s využitím nízkokopiových DNA markerů (např. RFLP)
    - využití těchto markerů k identifikaci orthologních genů (genů se stejnou nebo podobnou funkcí) příbuzného organismu
    - 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 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.)



# 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 database entry for Agrobacterium tumefaciens plasmid Ti. The entry includes details such as LOCUS, DEFINITION, ACCESSION, VERSION, FEATURES, and COMMENT. The features section lists 'gene' and 'CDS' for the 'virA' gene, with a protein ID of NP\_059793.1.






# 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

