

CG920 Genomics

Lesson 1

Introduction into Bioinformatics

Jan Hejátko

Functional Genomics and Proteomics of Plants,

Mendel Centre for Plant Genomics and Proteomics,

Central European Institute of Technology (CEITEC), Masaryk University, Brno

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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

OP Vzdělávání
pro konkurenčníchopnost

MASARYKOVÁ
UNIVERSITA
JANA BRUNNENSE

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus Of The Course
- Definition Of Genomics
- Role Of Bioinformatics In Functional Genomics
- Databases
 - Spectre Of „On-line“ Resources
 - PRIMARY, SECONDARY and STRUCTURAL Databases
 - GENOME Resources
- Analytical Tools
 - Homologies Searching
 - Searching Of Sequence Motifs, Open Reading Frames, Restriction Sites...
 - Other On-line Genome Tools



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Course Syllabus

- **Chapter 01**
 - Introduction into Bioinformatics
- **Chapter 02**
 - Identification of Genes
- **Chapter 03**
 - Reverse Genetics Approaches
- **Chapter 04**
 - Forward Genetics Approaches



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Course Syllabus

- **Chapter 05**
 - Functional Genomics Approaches
- **Chapter 06**
 - Protein-Protein Interactions And Their Analysis
- **Chapter 07**
 - Current Methods of DNA Sequencing
- **Chapter 08**
 - Structure of genomes



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Course Syllabus

- **Chapter 09**
 - Genome evolution
- **Chapter 10**
 - Genomics and Systems Biology
- **Chapter 11**
 - Practical Aspects Of Functional Genomics
 - Model Organisms,
 - PCR and Primer Design



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Literature

- Literature resources for **Chapter 01**:
 - **Bioinformatics and Functional Genomics**, 3rd Edition, Jonathan Pevsner, Wiley-Blackwell, 2015
<http://www.bioinfbok.org/php/?q=book3>
 - **Úvod do praktické bioinformatiky**, Fatima Cvrčková, 2006, Academia, Praha
 - **Plant Functional Genomics**, ed. Erich Grotewold, 2003, Humana Press, Totowa, New Jersey



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CARINIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus of thecourse
- Definition of Genomics



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

GENOMICS – What is it?

- *Sensu lato* (in the broad sense) – it is interested in **STRUCTURE** and **FUNCTION** of genomes
 - Necessary prerequisite: knowledge of the genome (sequence) – work with databases
- *Sensu stricto* (in the narrow sense) – it is interested in **FUNCTION** of **INDIVIDUAL GENES** – **FUNCTIONAL GENOMICS**
 - It uses mainly the reverse genetics approaches



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
SARAFJANA BRUNNENS
UNIVERSITY

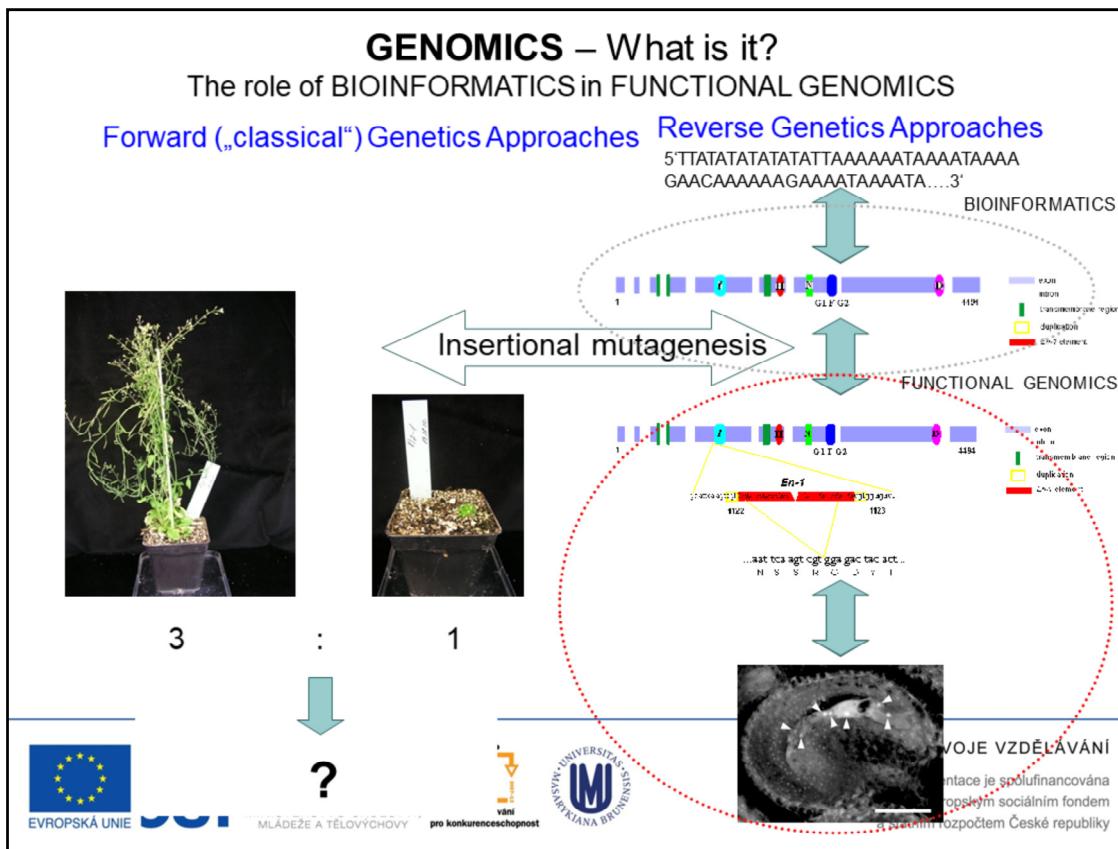
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomics is a science discipline that is interested in the analysis of genomes. Genome of each organism is a complex of all genes of the respective organism. The genes could be located in cytoplasm (prokaryotes), nucleus (in most eukaryotic organisms), mitochondria or chloroplasts (in plants).

The critical prerequisite of genomics is the knowledge of gene sequences.

Functional genomics is interested in function of individual genes.



With the knowledge of gene sequences (or the knowledge of the gene files in the individual organisms, i.e. the knowledge of genomes), **Reverse Genetics** appears that allows study their function.

In comparison to "classical" or **Forward Genetics**, starting with the phenotype, the reverse genetics starts with the sequence identified as a gene in the sequenced genome. The gene identification using approaches of **Bioinformatics** will be described later (see Lesson 02).

Reverse genetics uses a spectrum of approaches that will be described in the Lesson 03 that allow isolation of sequence-specific mutants and thus their phenotype analysis.

The necessity of having phenotype alterations in the forward genomics approach introduces important difference between those two approaches. Thus, the gene is no longer understood as a factor (*trait*) determining *phenotype*, but rather as a piece of DNA characterized by the unique *string of nucleotides*. i.e. **physical DNA molecule**.

Outline

- Syllabus of this course
- Definition of genomics
- Role of BIOINFORMATICS in FUNCTIONAL GENOMICS



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



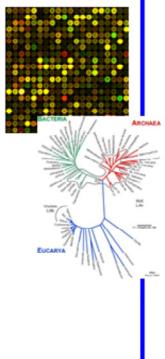
UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Bioinformatics

- **Definition of Bioinformatics** (according to NIH Biomedical Information Science and Technology Initiative Consortium)



Research, development, or application of computational tools and approaches for expanding the **use of biological, medical, behavioral or health data**, including those to **acquire, store, organize, archive, analyze, or visualize such data**.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

NIH WORKING DEFINITION OF BIOINFORMATICS AND COMPUTATIONAL BIOLOGY

July 17, 2000

The following working definition of bioinformatics and computational biology were developed by the BISTIC Definition Committee and released on July 17, 2000. The committee was chaired by Dr. Michael Huerta of the National Institute of Mental Health and consisted of the following members:

Bioinformatics Definition Committee BISTIC Members Expert Members

Michael Huerta (Chair) Gregory Downing

Florence Haseltine Belinda Seto

Yuan Liu

Preamble

Bioinformatics and computational biology are rooted in life sciences as well as computer and information sciences and technologies. Both of these interdisciplinary approaches draw from specific disciplines such as mathematics, physics, computer science and engineering, biology, and behavioral science. Bioinformatics and computational biology each maintain close interactions with life sciences to realize their full potential. Bioinformatics applies principles of information sciences and technologies to make the vast, diverse, and complex life sciences data more understandable and useful. Computational biology uses mathematical and computational approaches to address theoretical and experimental questions in biology. Although bioinformatics and computational biology are distinct, there is also significant overlap and activity at their interface.

Definition

The NIH Biomedical Information Science and Technology Initiative Consortium agreed on the following definitions of bioinformatics and computational biology recognizing that no definition could completely eliminate overlap with other activities or preclude variations in interpretation by different individuals and organizations.

Bioinformatics: Research, development, or application of computational tools and approaches for expanding the use of biological, medical, behavioral or health data, including those to acquire, store, organize, archive, analyze, or visualize such data.

Computational Biology: The development and application of data-analytical and theoretical methods, mathematical modeling and computational simulation techniques to the study of biological, behavioral, and social systems.

What is bioinformatics?

- Interface between the **biology** and **computers**
- **Analysis** of **proteins**, **genes** and **genomes** using **computer algorithms** and **databases**
- **Genomics** is the **analysis** of **genomes**.

The **tools of bioinformatics** are used to make **sense** of the **billions** of **base pairs** of **DNA** that are sequenced by genomics projects.

J. Pevsner,
<http://www.bioinfbook.org/index.php>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



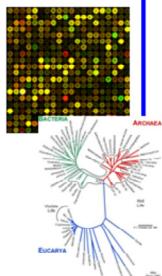
UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Bioinformatics

- **Bioinformatics in functional genomics**



- **Processing and analysis of sequencing data**

- Identification of reference sequences
- Identification of genes
- Identification of homologues, orthologues and paralogues
- Correlative analysis of genomes and phenotypes (incl. human)

- **Processing and analysis of transcriptional data**

- Transcriptional profiling using DNA chips or next-gen sequencing

- **Evaluation of experimental data and prediction of new regulations in systems biology approaches**

- Mathematical modelling of gene regulatory networks



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus of this course
- Definition of genomics
- Role of BIOINFORMATICS in FUNCTIONAL GENOMICS
- Databases
 - Spectre of „on-line“ resources



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Spectre of on-line Resources

EMNet National Nodes	
Vienna Biocenter	Austria
	Belgium
BioBase	Denmark
CSE	Finland
INRA/IRD	France
GENO/Sent	Germany
DMBB	Greece
HEN	Hungary
NCBI	Iceland
INRA	Ireland
ITB-ADR	Italy
CAOS/CANIK	Netherlands
	Norway
IRB	Poland
IGC	Portugal
GenoBee	Russia
CGPS/CSC	Spain
BMC	Sweden
SIB	Switzerland
SEONET	UK
EMNet Specialist Nodes	
MOPS	Germany
ICGEB	Italy
Pharmacia Upjohn	Sweden
Merck-Monsant-La Roche	Austria
ERI	UK
HCMP-RC	UK
Sanger	UK
UNIBER	UK
EMNet Associate Nodes	
	Argentina
ANGS	Australia
CRI	China
CGIB	Cuba
CGP	India
SANBI	South Africa
USA Information Providers	
NBII	USA
NLM	USA
NIH	USA



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



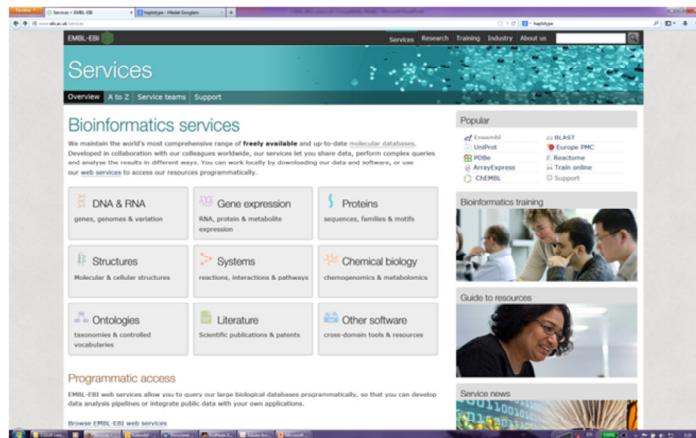
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

There are many of on-line resources that could be used.

Spectre of on-line Resources

- EBI <http://www.ebi.ac.uk/services>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



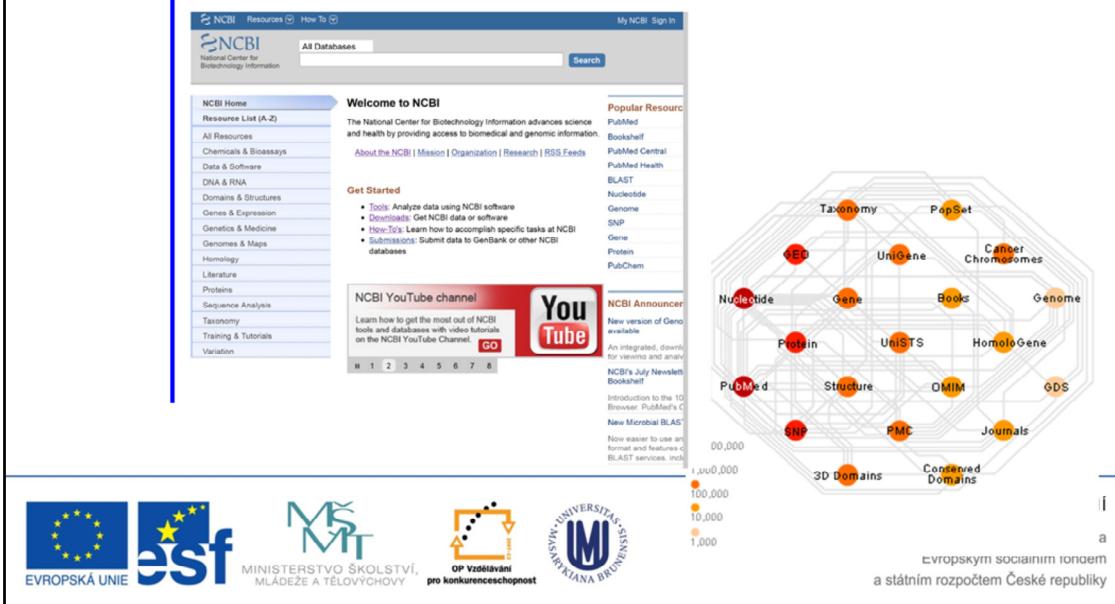
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Nowadays, the resources are interconnected and could be accessed via dedicated web pages. Among the best and mostluy used www resources integrating plenty of database resources belong www portal of European Bioinformatics Institute (EBI) in Europe (Germany) and National Center of Biotechnology Information (NCBI) in the USA (

Spectre of on-line Resources

- NCBI <http://www.ncbi.nlm.nih.gov/>



Nowadays, the resources are interconnected and could be accessed via dedicated web pages.

Outline

- Syllabus of this course
- Definition of genomics
- Role of BIOINFORMATICS in FUNCTIONAL GENOMICS
- Databases
 - Spectre of „on-line“ resources
 - PRIMARY, SECONDARY and STRUCTURAL databases



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primary Databases

- Include primary datasets – DNA and Protein sequences
 - Sequences in databases of „The Big Three“:
 - EMBL
 - <http://www.ebi.ac.uk/embl/>
 - GenBank,
 - <http://www.ncbi.nih.gov/Genbank/GenbankSearch.html>
 - DDBJ,
 - <http://www.ddbj.nig.ac.jp>
 - Daily mutual exchange and backup of data
 - Works with large amount of data (capacity and software requirements)
 - September 2003 $27,2 \times 10^6$ entries (approx. 33×10^9 bp)
 - August 2005 100×10^9 bp from 165.000 organisms



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

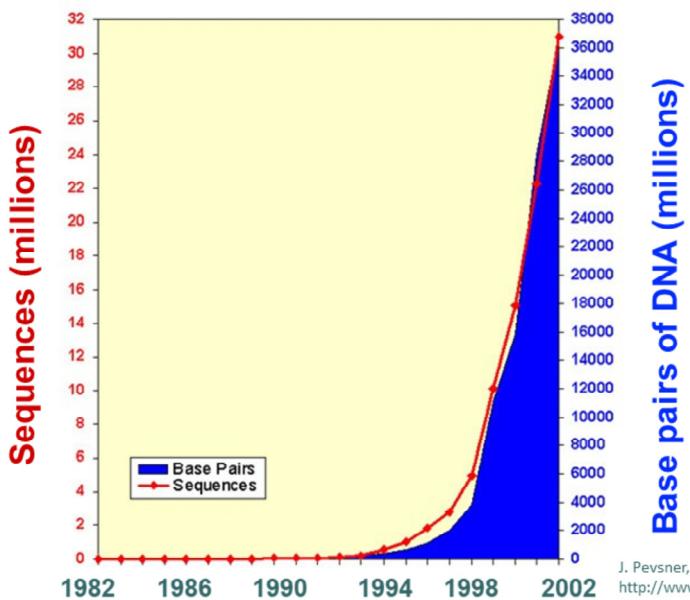


UNIVERSITAS
SANT'ANNA
BRUNELLO

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Growth of GenBank



J. Pevsner,
<http://www.bioinfbook.org/index.php>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



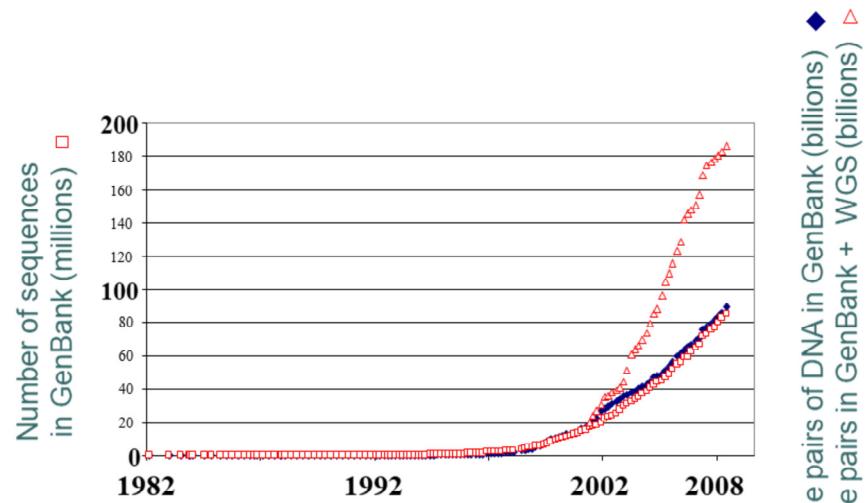
Year

UNIVERSITAS
CAROLINA BRUNNENS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Growth of GenBank + Whole Genome Shotgun (1982-November 2008): we reached 0.2 terabases



J. Pevsner,
<http://www.bioinfbook.org/index.php>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

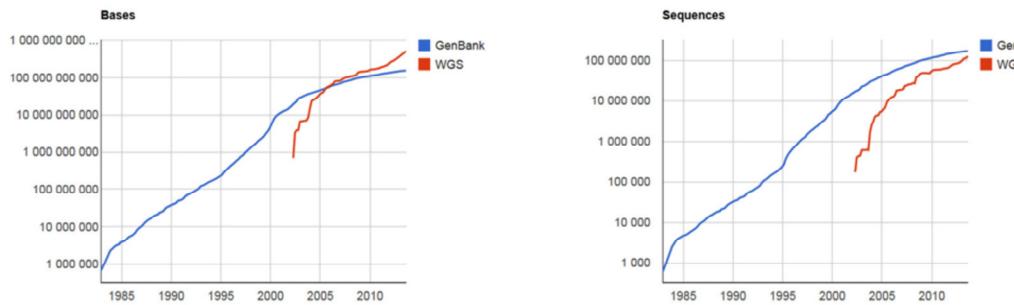


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Growth of GenBank

Feb 15 2013



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

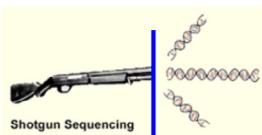


UNIVERSITAS
SANT'JAKO
BRUNNENS
pro konkurenčních

INVESTICE DO ROZVOJE Vzdělávání

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

WGS



Shotgun Sequencing

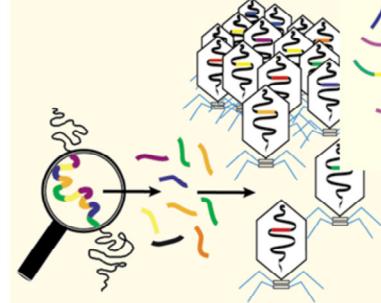


Fig 1: Genomic DNA is fragmented, ligated into viral DNA and packaged into viral particles to create a library

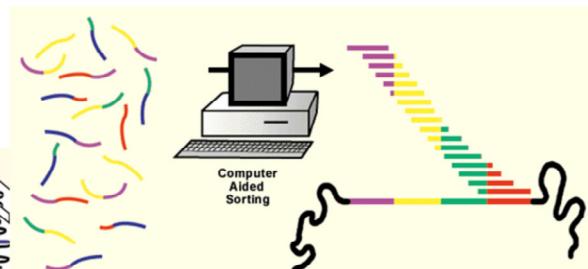


Fig 2: Short fragments of DNA sequence are ordered by overlapping data to recreate the whole genome sequence

Interactive concepts in biochemistry, Rodney Boyer, Wiley, 2002, <http://www.wiley.com//college/boyer/0470003790/>



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

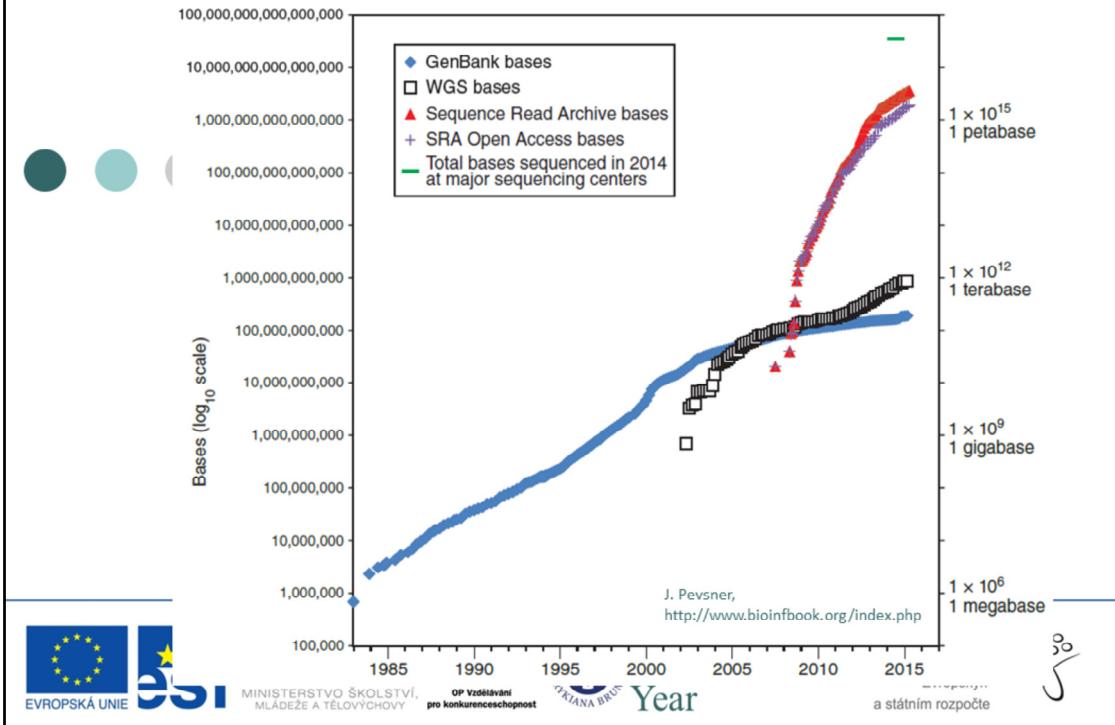
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Shotgun sequencing allows a scientist to rapidly determine the sequence of very long stretches of DNA. The key to this process is fragmenting of the genome into smaller pieces that are then sequenced side by side, rather than trying to read the entire genome in order from beginning to end. The genomic DNA is usually first divided into its individual chromosomes. Each chromosome is then randomly broken into small strands of hundreds to several thousand base pairs, usually accomplished by mechanical shearing of the purified genetic material. Each of the short DNA pieces is then inserted into a DNA vector (a viral genome), resulting in a viral particle containing "cloned" genomic DNA (Fig. 1).

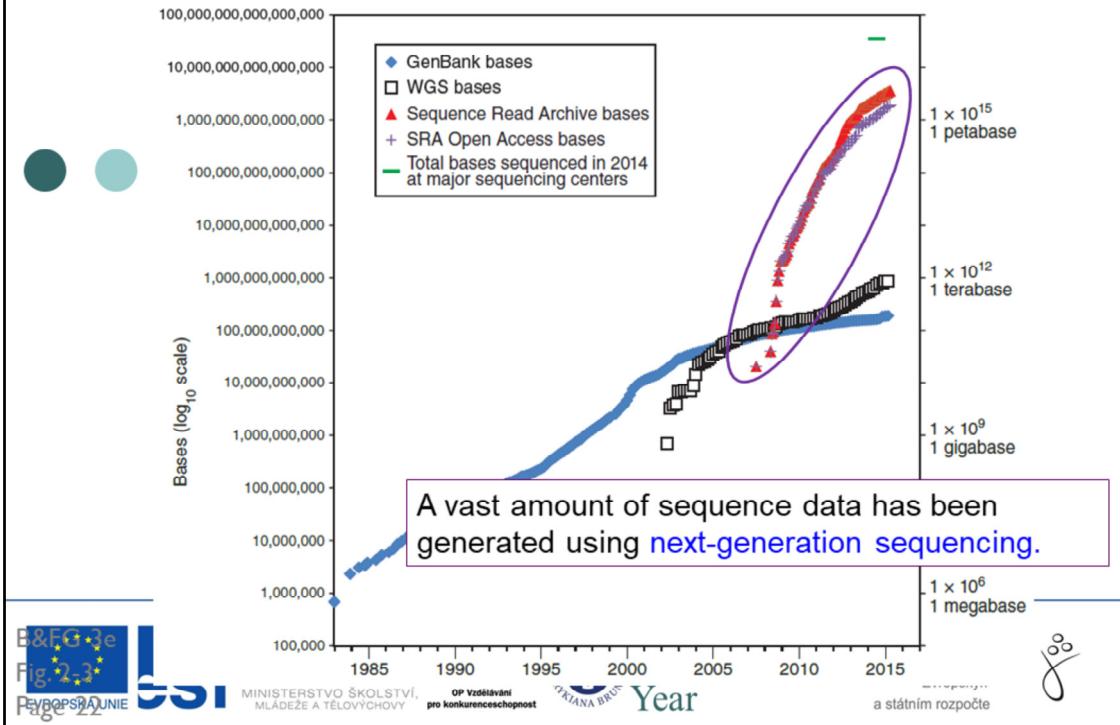
The collection of all the viral particles with all the different genomic DNA pieces is referred to as a library. Just as a library consists of a set of books that together make up all of human knowledge, a genomic library consists of a set of DNA pieces that together make up the entire genome sequence. Placing the genomic DNA within the viral genome allows bacteria infected with the virus to faithfully replicate the genomic DNA pieces. Additionally, since a little bit of known sequence is needed to start the sequencing reaction, the reaction can be primed off the known flanking viral DNA.

In order to read all the nucleotides of one organism, millions of individual clones are sequenced. The data is sorted by computer, which compares the sequences of all the small DNA pieces at once (in a "shotgun" approach) and places them in order by virtue of their overlapping sequences to generate the full-length sequence of the genome (Fig. 2). To statistically ensure that the whole genome sequence is acquired by this method, an amount of DNA equal to five to ten times the length of the genome must be sequenced. (Interactive concepts in biochemistry, Rodney Boyer, Wiley, 2002, <http://www.wiley.com//college/boyer/0470003790/>)

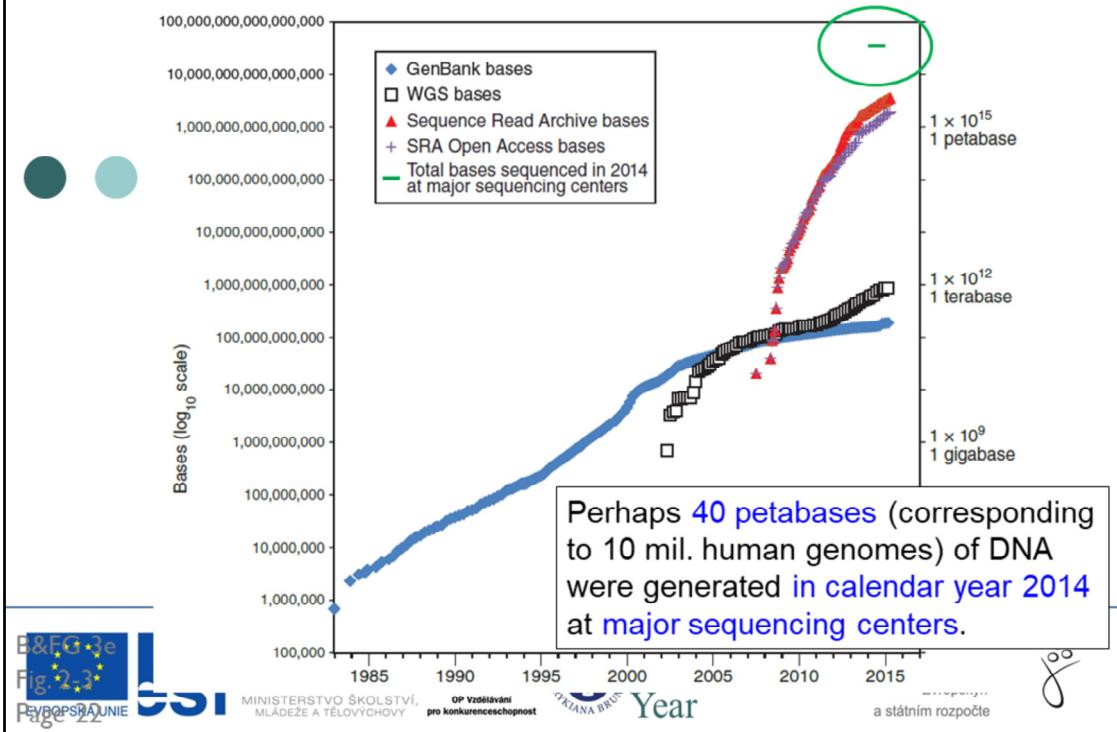
Growth of DNA Sequence in Repositories



Growth of DNA Sequence in Repositories



Growth of DNA Sequence in Repositories



Primary Databases

- They include sets of primary data – [DNA](#) and [Protein](#) sequences
 - Protein sequences:
 - PIR, <http://pir.georgetown.edu/>
 - MIPS, <http://www.mips.biochem.mpg.de>
 - SWISS-PROT, <http://www.expasy.org/sprot/>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primary Databases

- Types of sequences in primary databases
 - Standard nucleotide sequences acquired by high quality sequencing
 - **ESTs (Expressed Sequence Tags)**
 - **HGTS (High Throughput Genome Sequencing)**
 - Results of sequencing projects without annotation
 - **Reference Sequences** of annotated genomes
 - **TPAs (Third Party Annotation)**
 - sequences annotated by third party (by someone else, not the original authors)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primary Databases

GenBank (NCBI) <http://www.ncbi.nlm.nih.gov/>

The screenshot shows the NCBI homepage with a search bar at the top. Below the search bar, there's a "Welcome to NCBI" section with a brief introduction and links to "About the NCBI", "Mission", "Organization", "Research", and "RSS Feeds". To the left is a sidebar with a "Resource List (A-Z)" menu containing links to "All Resources", "Chemicals & Bioassays", "Data & Software", "DNA & RNA", "Domains & Structures", "Genes & Expression", "Genetics & Medicine", "Genomes & Maps", "Homology", "Literature", "Proteins", "Sequence Analysis", "Taxonomy", "Training & Tutorials", and "Variation". To the right is a "Popular Resources" sidebar listing "PubMed", "Books", "PubMed Central", "PubMed Health", "BLAST", "Nucleotide", "Genome", "SNP", "Gene", "Protein", and "PubChem". At the bottom, there's a "NCBI YouTube channel" section with a link to the channel and a "GO" button, followed by a "YouTube" logo. Logos for the European Union, ESF, Ministry of Education, Youth and Sports of the Czech Republic, OP Vzdělávání pro konkurenčníchopnost, and Masaryk University are also present.

EVROPSKÁ UNIE esf MINISTERSTVO ŠKOLSTVÍ, MLADEŽE A TĚLOVÝCHOVY NCBI ANNOUNCER
New version of Geno available
An integrated, downlo
for viewing and analys
NCBI's July Newsletter

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

Primary Databases

The screenshot shows a web-based bioinformatics tool interface. At the top, the URL is www.ncbi.nlm.nih.gov/genomes/NCBR/. The main content area displays a genomic sequence for a two-component Vck-like kinase gene. Key details include:

- Gene symbol:** vck
- Gene description:** two-component Vck-like sensor kinase
- Gene type:** protein coding
- RefSeq status:** PROVISIONAL
- Organism:** Agrobacterium tumefaciens (old name: Agrobacterium tumefaciens, ab initio), Rhizobium radiobacter
- Lineage:** Bacteria; Proteobacteria; Alpha-proteobacteria; Rhizobiales; Rhizobiaceae; Rhizobium/Agrobacterium group; Agrobacterium; Agrobacterium tumefaciens complex

The interface includes a navigation bar with links like "Biology", "General protein info", "Recent sequences", and "Links" (BioProjects, Full-text in PMC, Genome, Nucleotide, Project, Protein Clusters, PubMed, RefSeq Proteins, Taxonomy). A sidebar on the right provides "General information" about the gene, including links to "About Gene", "FAQ", "FTP site", "Help", "My NCBI help", and "NCBI Handbook". Other sections include "Related sites" (BLAST, Genome, BioProject, General Biology, GEO), "Feedback" (Contact Help Desk, Submit Correction, Submit GenBank), and logos for the European Union, ESF, Czech Ministry of Education, Youth and Sports, and the Operational Program for Vocational Training.

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primary Databases

The screenshot shows a genomic sequence viewer for NC_002377.1. A red box highlights the protein NP_059797.1. A blue arrow points from this box to a detailed information panel. The panel contains the following text:

NP_059797.1
NP_059797.1: two-component VirA-like sensor kinase
total range: NC_002377.1 (145,694..148,183)
strand: plus
protein product length: 829
Links & Tools
GenBank View: [NC_002377.1 \(145,694..148,183\)](#), [NP_059797.1](#)
FASTA View: [NC_002377.1 \(145,694..148,183\)](#), [NP_059797.1](#)
BLAST Genomic: [NC_002377.1 \(145,694..148,183\)](#)
Graphical View: [NP_059797.1](#)
BLAST Protein: [NP_059797.1](#)
BLINK Results: [NP_059797.1](#)

Below this panel, there are links for "Bibliography" and "Related articles in PubMed".

At the bottom of the interface, there are logos for the European Union, ESF, Ministry of Education, Youth and Sports, Operational Program for Vocational Education, and Masaryk University.

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

Primary Databases

NCBI Nucleotide

Search [Nucleotide] for [Nucleotide]

Accession number: NC_002377.1

Preview Index Get Subsequence History Features

Details

GeneBank Identifier: NC_002377.1

DEFINITION: 2490 bp DNA linear RCT 29-DEC-2003.

ACCESSION: NC_002377.1

VERSION: NC_002377.1

KEYWORDS: Azospirillum, gene, (Rhizobium radiobacter)

SOURCE: Agrobacterium, gene (Rhizobium radiobacter)

TITLE: VirA gene of Agrobacterium tumefaciens

JOURNAL: *Appl Environ Microbiol* 69(17):10955-10961 (2003)

REFERENCE: 2. (bases 1 to 2490)

AUTHORS: Parrand, S.E., Schrammeijer, B., Hooykaas, P.J. and Vinane, S.C.

COMMENT: This sequence has not yet been subject to formal NCBI review. The reference sequence was derived from [AP214184](#).

FEATURES

source

/organism="Agrobacterium tumefaciens"
/mol_type="genomic DNA"
/db_xref="GenBank:AP214184"
/plasmid="Ti"
/chromosome="chromosomal"
/octopine-type="1..2490"
/virA
/db_xref="GeneID:1224316"
/CDS
/virA
/note="two-component regulator of vir regulon; VirA is a two-component system that activates VirB and VirD4 genes"
/codon_start=1
/transl_table=11
/protein_id="NP_003797.1"
/db_xref="UniProtKB:NP_003797.1"

EVROPSKÁ UNIE esf

MINISTERSTVO ŠKOLSTVÍ, MLADEŽE A TĚLOVÝCHOVY

OP Vzdělávání pro konkurenční schopnost

UNIVERSITAS Svatopluka Čecha a Jana Evangelisty Purkyně

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primary Databases

```
/translation-*#WBSHUEPFCUFTTCAFWHILALITWAMIFPMAVULWCHNT  
TQRLQZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
IYERBNMAGQLZLQZLUVYLZLNMADAAVAFQZGQZVSLQZLACZPTHLZLSLZEMADTGT  
TQRLQZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
PQEDELMNQZTSDTAJAMMGRCLTYLNTTEGJASZPLOZAVSLZLJTTL  
VTFLSZKTWLZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
GLLLALALHESTED,IAVCLZLZHTEPZPFZCZHLELAHZCHZLHDTBZCTED  
ZLSCZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
KZSWMALZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
KTFIISQZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
KZTFCZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
KZTFCZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
KZTFCZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ  
LZBZLSDCZBZDCAZL4CZVLAUTYTXAVXYS:1:16RQZLSKWLZCQZLGQZFGQZ
```

ORIGIN

1 atyaapaa gataatcaoo paapogpaag pattaataaa cappapaga postpigt
61 atattpgco ttaatppgtgk tqaaqasat tqapogpata tqapogpata tqapogpata
121 gataatcaoo ttaatppgtgk tqaaqasat tqaaqasat tqaaqasat tqaaqasat
181 taaatppgtgk tqaaqasat tqaaqasat tqaaqasat tqaaqasat tqaaqasat
241 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
301 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
361 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
421 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
481 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
541 gataatcaoo tqapogpata tqapogpata tqapogpata assasaaacg oppapigt
601 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
661 tppaaqapj tppjaqasat gatcogpaaq tppjaqasat tppjaqasat tppjaqasat
721 capogpaaq gttipgpgk tataapgtt assasaaatg apapapggp apapapgt
781 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
841 opaasaaaas opaaktpjt tppjaqasat tppjaqasat tppjaqasat
901 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata atenccapn
961 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata tppjaqasat
1021 tppprtpgtgk ssassatqg typpaaqee ssassactg typpapaa qapogptgk
1081 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata tqapogpata
1141 tppaaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
1201 assatccapn assatccapn assatccapn assatccapn assatccapn assatccapn
1261 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata tqapogpata
1321 gatctgpgk tgasqapaaq tgasqapaaq tgasqapaaq gasqatggk pratqpgpaa
1381 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
1441 gptneatoqk tppjaqasat tqapogpata assasactg tytctogaaq atenccapn
1501 opaqatataqk tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
1561 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata tqapogpata
1621 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
1681 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata tqapogpata
1741 atenccapgk tappapataqk tqapogpata tqapogpata tqapogpata tqapogpata
1801 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
1861 gptneatoqk tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
1921 canatctttt assocetttt taaatgpaaoq tppjaqasat tppjaqasat tppjaqasat
1981 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
2041 opapatappk tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
2101 gataatcaoo tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
2161 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
2221 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
2281 gataatcaoo tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat
2341 tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat tppjaqasat



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenčnost
UNIVERSITATSKA JANA BRUNNERA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

What is an Accession Number?

An accession number is label that used to identify a sequence. It is a string of letters and/or numbers that corresponds to a molecular sequence.

Examples (all for retinol-binding protein, RBP4):

X02775	GenBank genomic DNA sequence	DNA
NT_030059	Genomic contig	
Rs7079946	dbSNP (single nucleotide polymorphism)	
N91759.1	An expressed sequence tag (1 of 170)	RNA
NM_006744	RefSeq DNA sequence (from a transcript)	
NP_007635	RefSeq protein	Protein
AAC02945	GenBank protein	
Q28369	SwissProt protein	
1KT7	Protein Data Bank structure record	

J. Pevsner,
<http://www.bioinfbook.org/index.php>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

NCBI's important RefSeq project: best representative sequences

RefSeq (accessible via the main page of NCBI) provides an expertly curated accession number that corresponds to the most stable, agreed-upon “reference” version of a sequence.

RefSeq identifiers include the following formats:

Complete genome	NC_#####
Complete chromosome	NC_#####
Genomic contig	NT_#####
mRNA (DNA format)	NM_##### e.g. NM_006744
Protein	NP_##### e.g. NP_006735

J. Pevsner,
<http://www.bioinfbook.org/index.php>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

RefSeq

The following sections contain reference sequences that belong to a specific genome build. [Explain](#)

Reference assembly

Genomic

1. NC_003065.3
Range 180831..183332
Download GenBank, FASTA, Sequence Viewer (Graphics)

mRNA and Protein(s)

1. NP_396486.1 two component sensor kinase [Agrobacterium tumefaciens str. C58]
UniProt/BiSwiss-Prot P18640
Conserved Domains (1) Summary

0000075 HATPase_c; Histidine kinase-like ATPases: This family includes several ATP-binding proteins for example: Histidine kinase, DNA gyrase B, topoisomerase, heat shock protein HSP90, cytochrome-b-like ATPases and DNA mismatch repair

Location: 590 – 694
Blast Score: 202

0000082 HisKA; Histidine Kinase A (dimerization/phosphoacceptor) domain; Histidine Kinase
Location: 480 – 530
Blast Score: 144
VBL
PRK13837 PRK13837; two-component VirA-like sensor kinase. Provisional
Location: 14 – 833
Blast Score: 2944

Related Sequences

EVROPSKÁ UNIE esf MINISTERSTVO ŠKOLSTVÍ, MЛАДЕЖЕ А ТЕЛОВЪЧОВЫ OP Vzdělávání pro konkurenčnost INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ
Tato prezentace je spolufinancována Evropským sociálním fondem a státním rozpočtem České republiky

NCBI's RefSeq project: many accession number formats for genomic, mRNA, protein sequences

<u>Accession</u>	<u>Molecule</u>	<u>Method</u>	<u>Note</u>
AC_123456	Genomic	Mixed	Alternate complete genomic
AP_123456	Protein	Mixed	Protein products; alternate
NC_123456	Genomic	Mixed	Complete genomic molecules
NG_123456	Genomic	Mixed	Incomplete genomic regions
NM_123456	mRNA	Mixed	Transcript products; mRNA
NM_123456789	mRNA	Mixed	Transcript products; 9-digit
NP_123456	Protein	Mixed	Protein products;
NP_123456789	Protein	Curation	Protein products; 9-digit
NR_123456	RNA	Mixed	Non-coding transcripts
NT_123456	Genomic	Automated	Genomic assemblies
NW_123456	Genomic	Automated	Genomic assemblies
NZ_ABCD12345678	Genomic	Automated	Whole genome shotgun data
XM_123456	mRNA	Automated	Transcript products
XP_123456	Protein	Automated	Protein products
XR_123456	RNA	Automated	Transcript products
YP_123456	Protein	Auto. & Curated	Protein products
ZP_12345678	Protein	Automated	Protein products

J. Pevsner,
<http://www.bioinfbook.org/index.php>



INVESTICE DO ROZVOJE Vzdělávání

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

Primary Databases

The screenshot shows a genomic sequence viewer for the gene NC_002377.1. A specific protein product, NP_059797.1, is highlighted in red. A tooltip provides detailed information about this protein:

- NP_059797.1: two-component VirA-like sensor kinase
- total range: NC_002377.1 (145,694..148,183)
- strand: plus
- protein product length: 829

Links & Tools:

- GenBank View: [NC_002377.1 \(145,694..148,183\)](#), [NP_059797.1](#)
- FASTA View: [NC_002377.1 \(145,694..148,183\)](#), [NP_059797.1](#)
- BLAST Genomic: [NC_002377.1 \(145,694..148,183\)](#)
- Graphical View: [NP_059797.1](#)
- BLAST Protein: [NP_059797.1](#)
- BLINK Results: [NP_059797.1](#)

Below the main viewer, there are links for "Bibliography" and "Related articles in PubMed".

At the bottom of the slide, there are logos for the European Union, ESF, Ministry of Education, Youth and Sports of the Czech Republic, Operational Program for Vocational Education and Training, and Masaryk University.

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

Primary Databases

The screenshot shows a computer screen displaying the NCBI BioProject interface. The main window title is "Agrobacterium tumefaciens plasmid Ti, complete sequence". The sequence itself is a long string of DNA bases (A, T, C, G) starting with "ATGAACTGGAAAATTCACCGAACGGGAAACGATTTAAACACGGGCGAAACGATGAGCTACGGGAGC". Above the sequence, there are several toolbars and dropdown menus. A prominent feature is a "Change region shown" dialog box in the upper right corner, which allows users to select a specific region of the sequence for analysis. Other visible options include "Display Settings" (set to FASTA), "Send", "Analyze this sequence", "Highlight Sequence Features", and "Recent activity". The bottom of the screen shows the Windows taskbar with various open application icons.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenčních schopností

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Secondary Databases

- Databases of **functional** or **structural motifs**, acquired by **primary data (sequences) comparison**
- o PROSITE, <http://www.expasy.org/prosite/>

[ExPASy Home page](#) [Site Map](#) [Search ExPASy](#) [Contact us](#) [Swiss-Prot](#) [PROSITE](#) [Proteomics tools](#)

Search PROSITE

prosite ScanProsite

This program allows to scan a protein sequence (either from Swiss-Prot or TrEMBL, or provided by the user) for the occurrence of patterns and profiles stored in the [PROSITE](#) database, or to search protein databases with a user-entered pattern ([Reference](#) / [Download ps_scan, the standalone version](#)). The program [PRATT](#) can be used to generate your own patterns. You may either:
• enter a PROSITE accession number or pattern to search the Swiss-Prot/TrEMBL and/or PDB databases with a pattern, OR
• enter a sequence or a Swiss-Prot/TrEMBL accession number to scan the sequence with all patterns, profiles and rules in PROSITE, OR
• fill in both fields to find all occurrences of a pattern or profile in a sequence.

Scan a protein for PROSITE matches
Enter a Swiss-Prot/TrEMBL accession number, for example PS00001, or a PROSITE identifier, or put your own protein sequence in the box below:

and specify which motif to use:
Scan patterns profiles rules ([User Manual](#)) (You may also specify a PROSITE entry in the box to the right)
Exclude patterns with a high probability of occurrence
Your e-mail (optional): (will be used by e-mail)
 plain text output
START THE SCAN **RESET**

Search Swiss-Prot with a PROSITE entry
Enter a PROSITE accession number (for example PS01234), or type your pattern in [PROSITE](#). Leave this box blank to scan a sequence with the entire PROSITE database.

and specify your search limits:
• For the "Scan-Prot" ("TrEMBL", "TrEMBLnew", "PDB" databases)
(You may also specify a protein in the box to the left)
• including splice variants
• The following limits apply:
• **NEW**: repeat multiple text with a connector, e.g. Homo sapiens: Drosophila Not available for PDB
• At most kilo
• At most matches
Advanced options: FASTA output retrieve complete sequences
allow at most X sequence characters to match a conserved position in the pattern
match mode: greedy, contiguous, no matches no pattern, see help
restriction database: no restriction, see help



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Secondary Databases

- Databases of **functional** or **structural motifs**, acquired by **primary data (sequences) comparison**
- PROSITE, <http://www.expasy.org/prosite/>

```
>PDOC00002 PS00002 SULFATION Tyrosine sulfation site [rule] [Warning: rule with a high probability of occurrence].  
571 - 588 nkeearTetelaas  
>PDOC00004 PS00004 CAMP_PHOSPHO_SITE cAMP- and cGMP-dependent protein kinase phosphorylation site [pattern] [Warning: pattern with a high probability of occurrence].  
744 - 747 SERT  
811 - 817 ERK5  
>PDOC00005 PS00005 PKC_PHOSPHO_SITE Protein kinase C phosphorylation site [pattern] [Warning: pattern with a high probability of occurrence].  
148 - 150 S#R  
144 - 164 T#R  
171 - 173 S#R  
213 - 215 S#R  
363 - 371 T#R  
440 - 442 S#R  
121 - 123 S#R  
581 - 587 S#R  
602 - 604 T#R  
652 - 654 S#R  
715 - 718 S#R  
721 - 723 S#R  
747 - 749 S#R  
794 - 796 S#R  
841 - 843 S#R  
844 - 864 S#R  
844 - 870 S#R  
921 - 923 S#R  
957 - 959 S#R  
940 - 942 T#R  
971 - 973 S#R  
997 - 999 S#R  
1002 - 1004 T#R  
1030 - 1032 S#R  
1031 - 1033 T#R  
1119 - 1121 S#R
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
SANT'ANNA
BRUNELLO

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Secondary Databases

- Databases of **functional** or **structural motifs**, acquired by **primary data (sequences) comparison**
- PROSITE, <http://www.expasy.org/prosite/>

>PDOC50100 PS50100 HKK_KIN Histidine kinase domain [profile]

402 - 671 MASHCICRLLALGAGGEGIDIDCIGGIVFPGPFQPFVTTIIVMAMVYAFCSVLLAEEFLLDIDLIESS
DPSVLLVAVLDPVVAEVVPAFVAVVTVVPAFVAVVTVVPAFVAVVTVVPAFVAVVTVVPAFVAVVTVV
HLLVTAIAVEPTYC - GHIAATRAAQGpppseavvliaspkprahfvlamfckhdkasayte
VKLAAASAKTAAACWCPVPPVTCVCTGDIIMMHEZCVPSPNQVYKEKAQHQJQULGLSITVQ
SLVLTMLQHEEAEKTCRGEAGGGGKQCPVPLTLLT

>PDOC50100 PS50100 RESPONSE_REGULATORY Response regulatory domain [profile].

987 - 1088 PVVLYTYCNPFLSEAVAVCQDLSKQYGVVWQQTDSRQEALALATEHSVgvv+gvvvv+G1PFV
1PDOC501000C65C66C67C68C69C70C71C72C73C74C75C76C77C78C79C7A

Graphical summary of hits (java applet)

Click on items to see a description. Drag the two red markers to reflect a zoom region.



About Help

Zoom View Options 9123 primary 100 residues

98 hits with 12 PROSITE entries

[ExPASy Home page](#) [Site Map](#) [Search ExPASy](#) [Contact us](#) [Swiss-Prot](#) [PROSITE](#) [Proteomics tools](#)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Secondary Databases

- Databases of **functional** or **structural motifs**, acquired by **primary data (sequences) comparison**

- PRINTS, <http://www.bioinf.man.ac.uk/dbbrowser/PRINTS/>



PRINTS is a compilation of protein fingerprints. A fingerprint is a group of conserved motifs used to characterize a protein family; its diagnostic power is refined by iterative scanning of a SWISS-PROT/TrEMBL database. Unlike the motifs do not overlap, but are separated along a sequence, though they may be continuous in 3D space. Fingerprints can encode protein folds and functionalities more flexibly and powerfully than can single motifs, full diagnostic potency deriving from the mutual context provided by motif neighbours. [References](#)

New:

[PRINTS - Search & PRINTS-S \(enhanced PRINTS\)](#)
[esPRINTS - Search & PRINTS automatic segmenter](#)
[InterPro - Search & the integrated InterProFamily database](#)

Direct PRINTS access:

[By accession number](#)
[By PRINTS code](#)
[By domain code](#)
[By text](#)
[By sequence](#)
[By motif](#)
[By number of motifs](#)
[By motif length](#)
[By every language](#)

PRINTS search:

[Search PRINTS with NEW FingerPRINTScan](#)
[FingerPRINTScan](#)
[GEAPIScan](#)
[MUTIScan](#)
[FingerPRINTScan binaries and source are available: \[contact@scordis.biocent.man.ac.uk\]\(mailto:contact@scordis.biocent.man.ac.uk\)](#)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
JAKOVA BRUNNESA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Secondary Databases

- TRANSFAC <http://www.gene-regulation.com/>

The screenshot shows the TRANSFAC website interface. On the left, there's a sidebar with links to 'The GBF', 'Research', 'Service & Technology Transfer', and 'News & Public Relations'. Below that is a 'Molecular Biotechnology' section with links to 'Bioinformatics', 'The team', 'Publications', 'Projects', 'Databases', 'Tools', and 'Links'. The main content area has a 'Database' header. It lists several databases:

- TSM**: TRANSFAC Saccharomyces Module 0.1
- S/MARt DB**: Scaffold/Matrix Attached Region transaction Database
- TRANSFAC**: The TRANSFAC Database (Release 5.0)
- TRANSPATH**: This database is no longer available on this server. You can access it on <http://www.generegulation.de>
- CYTOMER**: The database of physiological systems, organs and cell types



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
JANAE BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

S/MARt DB (scaffold/matrix attached region transaction database). This database collects information about S/MARs and the nuclear matrix proteins that are supposed be involved in the interaction of these elements with the nuclear matrix. <http://transfac.gbf.de/SMARTDB/index.html>)

Structural Databases

- PDB <http://www.rcsb.org/pdb/>

The screenshot shows the PDB homepage with a large "PROTEIN DATA BANK" logo at the top. Below it, a banner states: "Welcome to the PDB, the single worldwide repository for the processing and distribution of 3-D biological macromolecular structure data." To the left, there's a sidebar with links like "DEPOSIT data", "DOWNLOAD files", "browse LINKS", "BETA TEST new features", and "BETA mmCIF files". It also displays "Current Holdings: 19623 Structures" and "Last Update: 30-Dec-2002". A "PDB Statistics" section shows a 3D molecular model of Cytochrome c. The main search area has a form to "Enter a PDB ID or Keyword" with options for "query by PDB id only", "match exactword", and "remove sequence homologues". Below the search form, there's a "SearchLite keyword search form with examples" and a "SearchLite customizable search form". A "Status Search" link is also present. On the right, a "PDB Mirrors" section lists various mirrors including "San Diego Supercomputer Center", "Rutgers University", "National Institute of Standards and Technology", "Cambridge Crystallographic Data Centre", "National University of Singapore", "Osaka University", "Japan University", "Universidade Federal de Minas Gerais", "Brazil", and "Max Delbrück Center for Molecular Medicine", "Germany". Other links include "OTHER SITES" and "OTHER SITES". At the bottom, there's a news section with a link to "Comics News Newsletter" and a "pdbl Archive Subscribe" button.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Structural Databases

- PDB <http://www.rcsb.org/pdb/>

Structure Explorer - 1PSY

PDB
PROTEIN DATA BANK

Date: 1997-01-01
Classification: Viral Protein
Compound: Med. ID: 1; Molecule: Coat Protein Vp2; Chain: A; Fragment: Sequence Database Residues 190-737; Engineered: Yes; Mutant: Yes
Exp. Method: X-ray Diffraction

Structure Explorer - 1PSY

The Structure Of Heat Range Controlling Regions Of The Capsids Of Canine And Feline Parvoviruses And Mutants.

[View Structure](#)

[Summary Information](#)

[View Structure](#)

[Download/Display File](#)

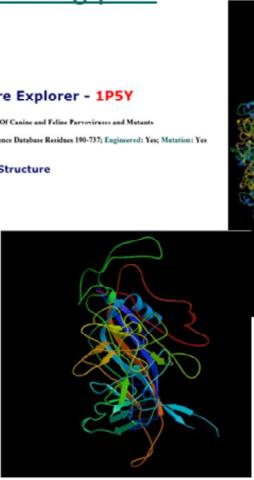
[Structural Neighbors](#)

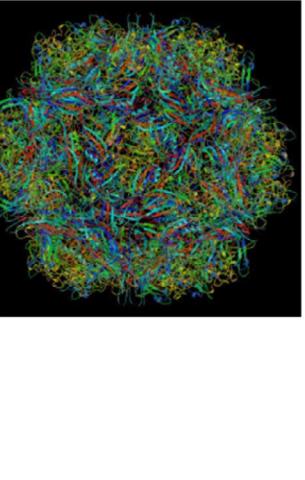
[Geometry](#)

[Other Sources](#)

[Sequence Details](#)

[Explore](#)





http://www.rcsb.org/pdb/cgi/explore.cgi?job_graphicspBDD-1PSY.page-&pid=173561064189344&bio=1&opt-show&size=500 12/20/2003

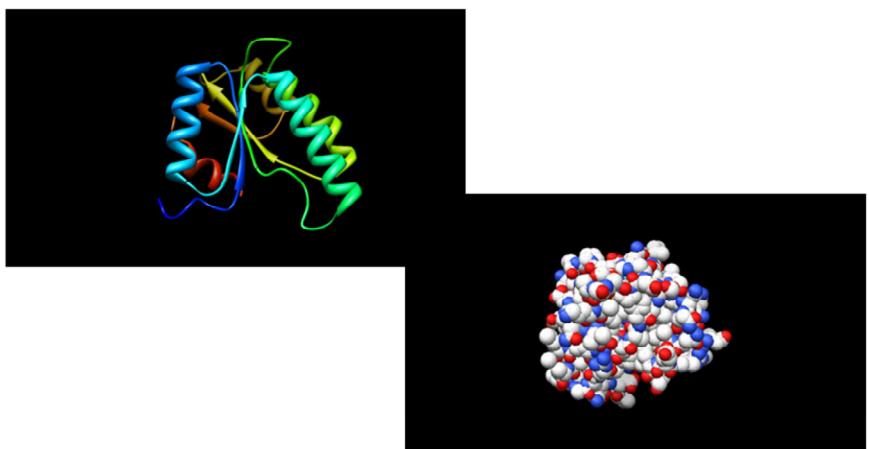
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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



Structural Databases

- PDB <http://www.rcsb.org/pdb/>



Pekárová et al., *Plant Journal* (2011)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus Of The Course
- Definition Of Genomics
- Role Of Bioinformatics In Functional Genomics
- Databases
 - Spectre of „on-line“ Resources
 - PRIMARY, SECONDARY And STRUCTURAL Databases
 - GENOME Resources



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

□ Human Genome Browser <http://genome.ucsc.edu/cgi-bin/hgGateway>

The screenshot shows the UCSC Genome Browser interface. At the top, there's a navigation bar with links like 'Home', 'Genome Browser', 'Tools', 'Mirrors', 'Diseases', 'My Data', 'About Us', and 'Help'. Below the navigation is a search bar with fields for 'clade' (set to 'Mammal'), 'genome' (set to 'Human'), 'assembly' (set to 'hg19'), 'position' (set to 'chr21 33,031,587-33,041,579'), and 'search term'. A 'Submit' button is next to the search bar. Below the search bar is a link 'Click here to reset the browser user interface settings to their defaults'. Underneath are buttons for 'back search', 'add custom tracks', 'track help', 'configure tracks and display', and 'submit'.

The main content area is titled 'Human Genome Browser - hg19 assembly (sequences)'. It contains a brief description of the genome assembly and a sample position query. A list of valid position queries is provided, such as 'chr7', 'chr3_1000000', and 'RHS10015 RHS0175'. On the right side, there's a small image of the human genome map with chromosomes labeled 'U C S C'.

At the bottom of the browser window, there's a status bar with icons for zoom, orientation, and other browser functions.

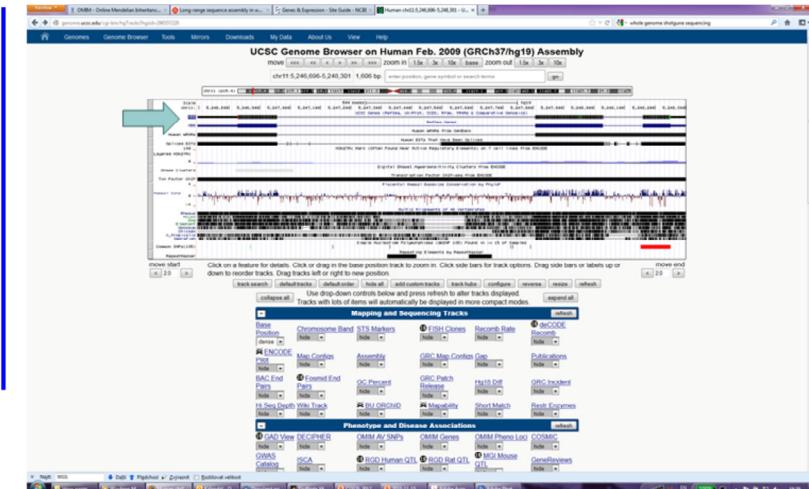


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

□ Human Genome Browser <http://genome.ucsc.edu/cgi-bin/hgGateway>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

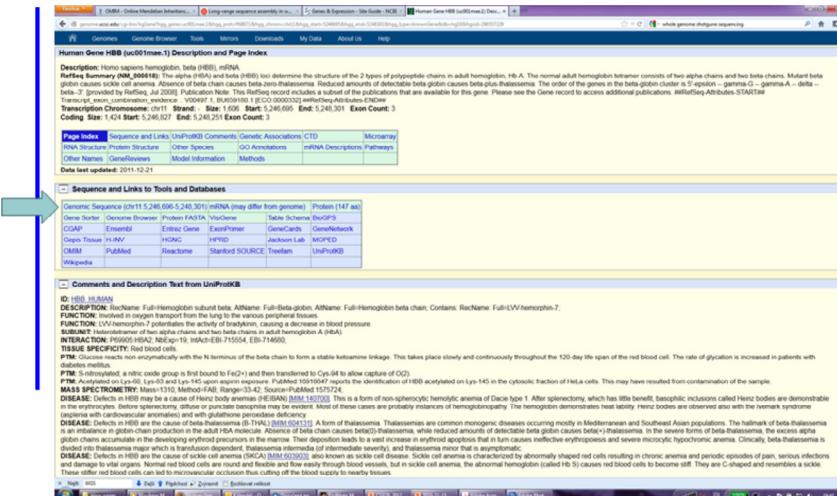


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

□ Human Genome Browser <http://genome.ucsc.edu/cgi-bin/hgGateway>



The screenshot shows the Human Genome Browser interface for the HBB gene. At the top, there's a navigation bar with links like 'Home', 'Online Medianion', 'Long-range sequence assembly', 'Gene & Expression', 'Site Guide', 'NCBI', and 'Human Gene HBB (UCSC|Ensembl)'. Below the title 'Human Gene HBB (uc001mn.1)' is a detailed description of the gene, mentioning its function in oxygen transport and its structure. A table provides links to UniProtKB, GenBank, and other databases. A large section titled 'Sequence and Links to Tools and Databases' contains links to various tools like BLAST, BLAT, and Ensembl. At the bottom, there's a 'Comments and Description Text from UniProtKB' section with detailed biological information.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



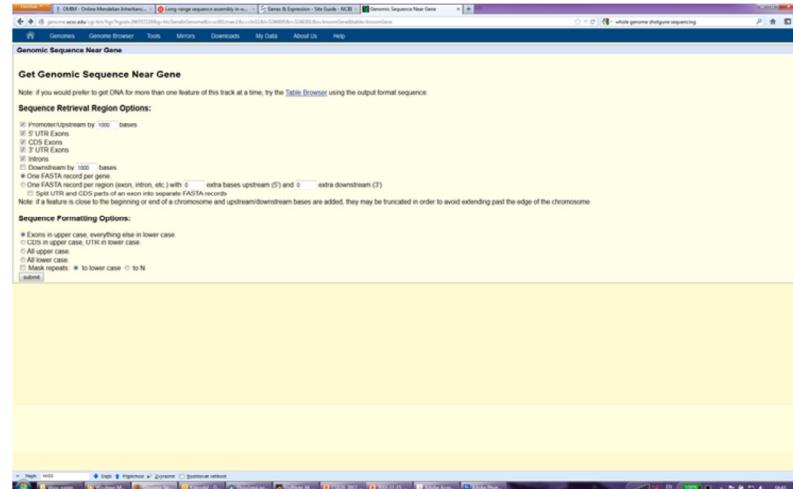
OP Vzdělávání
pro konkurenční schopnost
UNIVERSITATSKRJANA BRNOVENSKEJ

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

□ Human Genome Browser <http://genome.ucsc.edu/cgi-bin/hgGateway>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



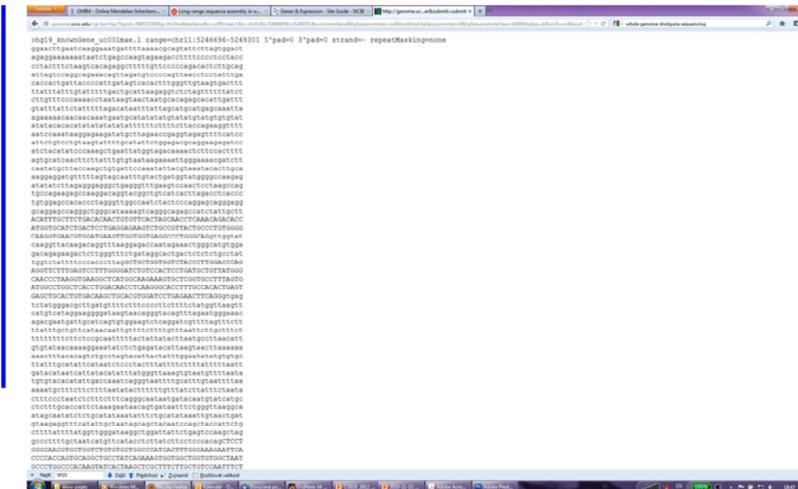
OP Vzdělávání
pro konkurenčních schopností
UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

□ Human Genome Browser <http://genome.ucsc.edu/cgi-bin/hgGateway>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

□ The Arabidopsis Information Resource (TAIR) <http://www.arabidopsis.org>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genome Resources

- TAIR, The Arabidopsis Information Resource, <http://www.arabidopsis.org>



The Arabidopsis Information Resource

The Arabidopsis Information Resource (TAIR) maintains a database of genetic and molecular biology data for the model higher plant *Arabidopsis thaliana*. Data available from TAIR includes the complete genome sequence of *A. thaliana*, gene product information, metabolism, gene expression, DNA and seed stocks, genome maps, genetic and physical markers, publications, and information about the Arabidopsis research community. Gene product function data is updated every two weeks from the latest published research literature and community data sources. Gene product entries are updated approximately 1-2 times per year via computational and manual methods as well as community submissions of new and updated genes. TAIR also provides extensive linkouts from our data pages to other Arabidopsis resources.

The Arabidopsis Biological Resource Center at The Ohio State University collects, preserves, and distributes seed and DNA resources of *Arabidopsis thaliana* and related species. Stock information and ordering for the ABRC are fully integrated into TAIR.

The NEW arabidopsis.org

We've added new dropdown headers and left navigation bars and reorganized our web pages to make it easier to locate information and resources in TAIR. Please contact us if you experience any problems with our new site.



Breaking News

Data Updates Suspended
[October 15, 2006]
Some TAIR data updates, including loading of new ABRC stocks, will be suspended from Oct 20-Nov 17 while we move our servers.

New Phenotype Search Option
[October 15, 2006]
Search for genes, germplasms, and polymorphisms using associated phenotype, and see improved phenotype data display in results and detail pages.

ASPB Presentations
[August 15, 2006]
Following high demand, the TAIR workshop presentations given at the ASPB meeting in Boston have been made available from the TAIR website for download.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus Of The Course
- Definition Of Genomics
- Role Of Bioinformatics In Functional Genomics
- Databases
 - Spectre Of „On-line“ Resources
 - PRIMARY, SECONDARY And STRUCTURAL Databases
 - GENOME Resources
- Analytical Tools
 - Homology Searching



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

□ Global versus Local alignment

```
Globální přiřazení
SLAV-----APATNIK-----PIQNYR-I-----AKSETQRYMWIE
SLAVYTYIEFVRANAPATNIKSECVRAAPIQNYRRVEHVRATAKSETQRYMWIE

Lokální přiřazení
SLAVYTYIEFVRANAPATNIKSECVRAAPIQNYRRVEHVRATAKSETQRYMWIE
-----NAPATNIKSECVRA-PIQNYRRVEHVRA-----
```

Cvrčková, Úvod do praktické bioinformatiky

- **Global Alignment:** only for sequences, which are **similar** and of a **similar length** (BUT can insert spaces into one or both sequences)
- **Global Alignment** is used mainly in case of **multiple alignment** (CLUSTALW, further in the presentation)
- **Local Alignment** provides identification and comparison even in case of alignment of **regions of sequences with high similarity**, e.g. even in case of **change of order of protein domains** during evolution



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



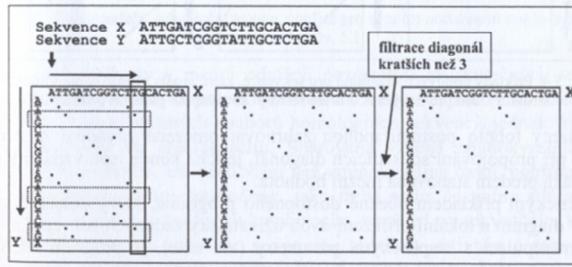
UNIVERSITAS
JARNA BRUNNEN

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- Choosing the right type of alignment using [dotplot](#)



Cvrčková, Úvod do praktické bioinformatiky

- Plotting the sequences against each other (x and y axis)
- Identification of identity in „dot“ of specific size (e.g. 2 bp)
- Filtering the diagonals of lengths lower than a threshold



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



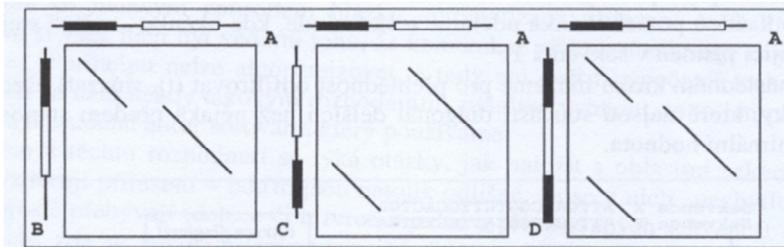
OP Vzdělávání
pro konkurenční schopnost

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

Examples of sequence alignment using dotplot



Cvrčková, Úvod do praktické bioinformatiky

- **Global Alignment:** possible only for sequences A and B
- The rest of the sequences underwent change of order of protein domains and therefore it is necessary to do a local alignment
- Dotplot can be obtained using **BLAST2** (see further in the presentation)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
JANAE BRUNENSIS
SARTIJANA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- o BLAST <http://ncbi.nlm.nih.gov/BLAST/>

The screenshot shows the NCBI BLAST interface for nucleotide searching. At the top, there are tabs for Nucleotide, Protein, Translations, and 'Retrieve results for an RID'. Below the tabs, a sequence of DNA is entered into a search field:

```
aaaaaaatggt  
acaccatcat cattatcata atcgttttgg ggcgtatgtt tgggttcca  
gggtttttat  
atataattttt tattccacat gagatatgtt atgtatatttt  
ttttttttttt  
tttatgttaa acctttata taacaagaac tacaaaaaat gaaaa
```

Below the sequence, there are buttons for 'Set subsequence', 'Choose database' (set to 'nr'), and 'Now: BLAST!' (which is highlighted with an orange rectangle). There are also 'Reset query' and 'Reset all' buttons.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



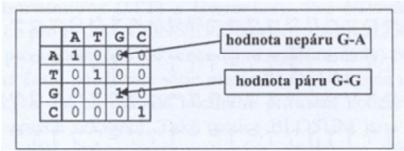
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Basic Local Alignment Search Tool

- Word size: 10-11 bp or 2-3 aa
 - Primary similarities (seed matches)
 - Expanding the homology regions to the left and to the right
- Scoring the homology with matrices PAM (Point Accepted Mutation) or BLOSUM (BLOcks Substitution Matrix)
- Showing the results



Ovrčková, Úvod do praktické bioinformatiky

Matici PAM 250	
S	0 2
T	-2 1 3
P	-3 1 0 6
A	-2 1 1 1 2
G	-3 1 0 -1 1 5
N	-4 0 0 -1 0 3 2
C	-5 0 0 0 1 2 4
E	-5 0 0 -1 0 0 1 3 4
K	-5 -1 1 0 0 -1 1 2 2 4
H	-3 -1 -1 0 -1 -2 2 1 1 3] 6
R	-4 0 -1 0 -2 -3 0 -1 -1 1 2 6
K	-5 0 0 -1 -3 -2 1 0 0 1 0 3 5
M	-5 -2 -1 -2 -3 -3 -3 -1 -1 -2 0 0 6
I	-2 1 2 -4 -2 -2 -2 -2 -2 -2 2 4 5
L	-3 -2 1 2 -4 -3 -4 -3 -2 -3 -3 4 2 6
V	-2 -1 0 -1 0 -1 -2 -2 -2 -2 -2 2 4 2 4
F	-4 -3 -3 -5 -4 -5 -4 -6 -5 -5 -2 -4 -5 0 1 2 -3] 9
Y	0 -3 -3 -5 -3 -5 -2 -4 -4 -4 0 -4 -4 -2 -3 -1 -2] 7 10
W	-8 -2 -5 -6 -6 -7 -2 -7 -5 -3 2 -3 -4 -5 -2 -6 0 0 17
C S T P A G N D E Q H R K M I L V F Y W	AVÁNI

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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



BLAST

Basic Local Alignment Search Tool



„expectancy value“ provides the number of expected sequence number with the same or higher similarity when searching in the database consisting of randomly assembled sequences

- the results shows fraction of identical and in case of proteins also similar sequence positions and/or inserted spaces



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primary Databases

The screenshot shows a computer screen displaying a genomic sequence from NC_002377.1. A specific gene, NP_059797.1, is highlighted with a red box. A blue arrow points from the text "BLINK is a link to the pre-computed BLAST search results for the respective sequence (see the next slide)." to a tooltip that appears over the gene highlight. The tooltip contains the following information:

NP_059797.1
NP_059797.1: two-component VirA-like sensor kinase
total range: NC_002377.1 (145,694..148,183)
total length: 2,490
strand: plus
protein product length: 829
Links & Tools
GenBank View: [NC_002377.1 \(145,694..148,183\)](#), [NP_059797.1](#)
FASTA View: [NC_002377.1 \(145,694..148,183\)](#), [NP_059797.1](#)
BLAST Genomic: [NC_002377.1 \(145,694..148,183\)](#)
Graphical View: [NP_059797.1](#)
BLAST Protein: [NP_059797.1](#)
BLINK Results: [NP_059797.1](#)

Below the tooltip, there is a "Bibliography" section and a "Related articles in PubMed" section.

At the bottom of the slide, there are logos for the European Union (EU), ESF (European Social Fund), MŠMT (Ministry of Education, Youth and Sports of the Czech Republic), OP Vzdělávání pro konkurenční schopnost (Operational Program for Education and Research for Competitive Capacity), and the University of Brno. To the right, the text reads:

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

BLINK is a link to the pre-computed BLAST search results for the respective sequence (see the next slide).

BLAST

Basic Local Alignment Search Tool

Pre-computed BLAST results for: gi|16119781|ref|NP_396496.1 two component sensor kinase [Agrobacterium tumefaciens str. C58]
Matching gis: 15163423;20141871;1019660;
Total (score > 100): 147086 hits in 146754 proteins in 6309 species
Selected: 147086 hits in 146754 proteins in 6309 species Filter: Min Scores: 100 |
Other views (Reports): Taxonomy report | Multiple Alignment | Blast |
Reset all filters

Choose Display Options

1203 Archaea 138295 Bacteria 13 Metazo 1349 Fungi 554 Plants 6 Viruses 5676 The Others reset selection

Results: 1 - 100 Next Page Last

Score	Accession	Length	Protein Description
833	gi 16119781 ref NP_396496.1	833	two component sensor kinase [Agrobacterium tumefaciens str. C58]
	P18540	833	RecName: Full=Wide host range virA protein; Short=WRP virA
	AAA79282	833	virA [Plasmid pTC58]
	NP_053380	833	hypothetical protein pti-SANDRA_p142 [Agrobacterium tumefaciens]
	BAAB7765	833	virf140 [Agrobacterium tumefaciens]
	AAA91939	833	virA [Plasmid T1]
	gi 1737127	833	virA protein
	AAA91937	833	virA protein [Agrobacterium tumefaciens]
	CAA16780	829	virA [Agrobacterium rhizogenes]
	gi 1227240	869	virA gene
	AAA88643	829	virA [Plasmid T1]



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
JAKOVA BRUNNESA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specialized Versions

- Currently there exists a lot of specialized versions of BLAST
 - Searching according to source (organism) of sequences, e.g. known genomes of microorganisms
 - **BLASTP**
 - Given the [protein query](#), it returns the most similar protein sequences from the [protein database](#).
 - **BLASTN**
 - Given the [DNA query](#), it returns the most similar DNA sequences from the [DNA database](#).
 - Other variants, e.g. [MEGABLAST](#), for identification of identical or [very similar sequences](#) (searches [long similar regions](#) of nucleotide sequences)
 - **BLASTX**
 - Compares the all possible [six-frame translation products](#) of a [nucleotide query sequence](#) (both strands) against a [protein sequence database](#).



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je podporována
Evropským sociálním fondem
a celkovým rozpočtem České republiky



BLAST

Specialized Versions

- Currently there exists a lot of specialized versions of BLAST

- **TBLASTN**

- Compares a protein query against the all six reading frames of a nucleotide sequence database.

- **TBLASTX**

- Translates the query nucleotide sequence in all six possible frames and compares it against the six-frame translations of a nucleotide sequence database.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
JANAE BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specialized Versions

- Currently there exist a lot of specialized versions of BLAST

- **PSI-BLAST** (Position-Specific Iterated Blast)
 - First step: standard BLAST, during which PSI-BLAST identifies a list of similar sequences with E value better than minimal value (standard = 0,005)
 - For every alignment, PSI-BLAST creates so-called PSSM (Position Specific Substitution Matrix)
 - PSSM takes into account relative frequency of specific aminoacid residue in a specific position within sequences identified as similar in first step, which can mean functional conservation.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATE
JANAE BRUNNENS
ARTIKANA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specialized Versions

- Currently there exists a lot of specialized versions of BLAST

- **PHI-BLAST** (Pattern-Hit Initiated BLAST)
 - For identification of **specific sequence**, e.g. motif (pattern) in sequence of similar protein sequences
 - Sequence of motif must be inserted using **special syntax**:
 - [LVIMF] means either Leu, Val, Ile, Met or Phe
 - - is spacer (means nothing)
 - x(5) means 5 positions in which any residue is allowed
 - x(3, 5) means 3 to 5 positions where any residue is allowed



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITATIS
CAROLINA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specialized Versions

□ Example of search by PHI-BLAST

```
>gi|4758958|ref|NP_004148.1| Human cAMP-dependent protein kinase  
MSHIQIPPGTLELLQGYTVEVLRQQPPDLDVEFAVEYFTRLREARAPASVLPAAATPRQSLGHPPPEPGPDR  
VADAKGDSESEEDEDLEVPVPSRFNRVSVCAETYNPDEEEEDTDPRVIHPKTDEQRCLQEACKDILLF  
KNLDQEQLSQVLDAMFERIVKADEHVIDQGDGDNFYVIERGTYDILVTKDNQTRSVGQYDNRGSFGELA  
LMYNTPRAATIVATSEGSLWGLDRVTFRRIIVKNNAKKRKMFESFIESVPLLSLEVSRMKIVDVIGEK  
IYKDGERIITQGEKADSYYIESGEVSILIRSRTKSNKDGNNQEVIEARCHKGQYFTELALVTNKPRAAS  
AYAVGDVKCLVMQAFERLLGPCMDIMKRNISHYEEQLVKMFGSSVDLGNLQ  
[LIVMF] -G-E-x- [GAS] - [LIVM] -x(5,11) -R- [STAQ] -A-x- [LIVMA] -x- [STACV] .
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITA
JANAJA BRUNN
S

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus Of The Course
- Definition Of Genomics
- Role Of Bioinformatics In Functional Genomics
- Databases
 - Spectre Of „On-line“ Resources
 - PRIMARY, SECONDARY And STRUCTURAL Databases
 - GENOME Resources
- Analytical Tools
 - Homologies Searching
 - Searching Of Sequence Motifs, Open Reading Frames, Restriction Sites...



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



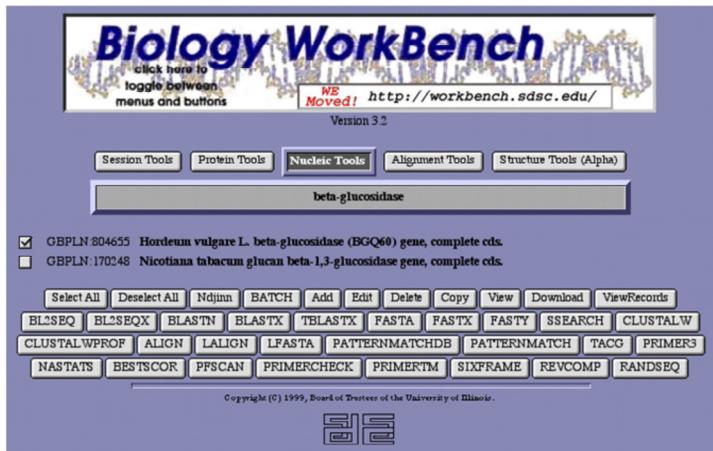
UNIVERSITATIS
SARAFJANA BRUNNENS
UNIVERSITY

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- <http://workbench.sdsc.edu/>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- <http://workbench.sdsc.edu/>

The screenshot shows a web-based sequence viewer. At the top, there's a button labeled "View" with the sub-instruction "View Nucleic Sequence(s)". Below it are dropdown menus for "Format" (set to "Fasta") and "Case" (set to "Upper"). There's also a "Change Format" button. A link "Download/view all sequences in text format" is present. The main content area displays the sequence of the Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds. The sequence starts with a header: "Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds. GBPLN:170248, 4699 bp". The sequence itself is a long string of nucleotide bases (A, T, C, G) starting with >170248.

```
>170248
GAGCTCCCCTGGGGGCAAGGGCAAACCTTTTGTAAATGGAAAAATAATTATACCAAGGTTTTTAATA
GTACTCAATTGTAAATTAAACAAGGGGCAAATTGGACTATTGGCCCTTATATCCTTTGGGTCAACAAAAAC
ATAAAATATCCCATCGAAAATTCCAATGGTCATTATCGGCAGTAGCTTTCCTTTAATTATAGTTAGTT
GACAAAACACTTACAGATAATTATTTATTAATAACTTAAAGTCATCATTTAGCTGCCCTCCCTA
GTAGAGCCGCCAGTAANATAAGACCGATAATAAACGCCCATTAATAATAGATAATTAGACCTTC
GATTTTCACAGCCATTTACAAACATTTTACGAACTTAAACATTTTACGAACTTAAACATTTTACGAA
CAAAATTCATAAAATTTTCCCTTAAGAAAGACATTAACCTTGCGGTAACTGAACTTACGAACTTACGAA
CGGGAAATTCATAAAATTTTCCCTTAAGAAAGACATTAACCTTGCGGTAACTGAACTTACGAACTTACGAA
CTGGCATATGCCATTTACACTTAAAGGGTTCCTTAAAGTAACTTAAATAATAATTTGGGGATAGAATTG
GAGATGAGTTAACTTACATTTACACTTAAAGGGTTCCTTAAAGTAACTTAAATAATAATTTGGGGATAGAATTG
GAGATGAGTTAACTTACATTTACACTTAAAGGGTTCCTTAAAGTAACTTAAATAATAATTTGGGGATAGAATTG
TAAAAATCAACTTACATTTACACTTAAAGGGTTCCTTAAAGTAACTTAAATCCCATAGCCACTCACATAGAAATATCC
TTAATTTAAACACTTACATTTACACTTAAAGGGTTCCTTAAAGTAACTTAAATCCCATAGCCACTCACATAGAAATATCC
TTAATTTAAACACTTACATTTACACTTAAAGGGTTCCTTAAAGTAACTTAAATCCCATAGCCACTCACATAGAAATATCC
GTAAAGAGTTAGAAAATTTTCATTAATCAATTAAATTTAAAATAATTAGATATGAGGACTTTAAG
ATACAATAAAAGATGTACCGTTAAATAATAAAAGATAAGTAGAGTTTTAAATAGGAAAAAAAACCGTT
CGAGACACTTACATTTGAGGGCGTTGTCCTCAAGAGTAACTTCATTCATTTGCTCTGGTCGAATAGCAAA
TGACACCTTACATTTAAGATACAGCGAGCCACTCTACAACTTCTCATTTGATATCTCAAAATGAAACTTTA
GAGACACTTCAAACTCTCAACTACTTTAAGGGAAATCTCAAAATACGACCAATATTATCTACTCTAC
TTATAGTTAAATGATATGAAATTATTTAATTTGAAATTGAAAATTTAAATTACTGATTTAATATA
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenční schopnost

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- o <http://workbench.sdsc.edu/>

Regex pattern:

ctt. {1,32}ctt

0 sequences were searched

1 match was found

Matches are indicated in blue

```
> 170248
GAGCTCCCTTGGGGGCAAGGGCAAAACCTTCTTGCTTAATGGAAAATTATTTTACGANGTGTTTGTATA
GTTACCTAATTGGAAATTACAAAGGGGAAATTGGACTATTTCCTCCCTTACGCTTGTGTCACAAAAAC
ATAAAATATCCTCCATCGAAATTCCAAATGTCCTAATTCGGCAAGTGAATTCCTTAAATTATGAGTGTGTT
GACAAAACACTATCAAGATATTCATTTAATAATAAACTTCAAAGTTCATTCATCTTACGCTGCCCTCTCA
GTAGAGCCGCAGTAAATTAAGACCGATCAAAATAAGGCCGCATTTAAATAATGAAATTAGGACTCTC
GATTGGCACGCTAAGTGAAACACTCTTGGTCCACCTTGGGGTTGCTAGGTTCTGAGCCTTC
CAGATATGGATAATTCTCAAATTCTCTAAATTTCCTCAAACTAACTAATTTAGAAATTAAACAGGTTC
CAGCAAAATCTAAATTAATTCCTAAATGGAAAGACATGGAACTCGGTTACGAAATTGGGCTTTTCAGAG
TGGAAATGAACTGGGAAAGGAACTGGAAAGGAACTGGAAAGGAACTGGAAAGGAACTGGAAAGGAACTGG
GAGAACTGGAAATTGGTGTGGTGTGGTGTGGTGTGGTGTGGTGTGGTGTGGTGTGGTGTGGTGTGG
TAAATTCACACTATTCACACTTGAGGAAACTGGAAAGGAACTGGAAAGGAACTGGAAAGGAACTGGAAAGG
TTAATTCTCACTATTCTAACCTGGAAAGGAACTGGAAAGGAACTGGAAAGGAACTGGAAAGGAACTGG
GTAAAGAAGTTAGAAAATTTCATTAATTAATTTAAATTAATTTAAATTTAAATTTAAATTTAAATTTAA
ATACAAATAAAAGATGZACCGGTAAATAAAAGATAAGATAGAGTTTTAAATAGGAAAAAACGGTT
CGAGACACTCTTATGAAAGGCCTTGTGCTTCAAAAGTAGATTCATTCATTCATTCATTCATTCATTC
TGACATCTTACCTCTTAAAGATACAGCGAGGCCACCTCTACATCTTCTTATTCATTCATTCATTCATTC
GAGACTTCAAACTCTCACAATCTCACAATCTTAAAGGAATTCAAATACGACCAATATTTATTTAATTA
TTATGTTAAATGATGATGATGATGATGATGATGATGATGATGATGATGATGATGATGATGATGATGAT
ACAATAGATATCGCTAAAGTATTTTACCAAAACATGAGATACATCAGAAGATTTTATTTATGTTAAAGAT
GTTAAAGCCTTACCTCTGTTGCTGGATGAANGAAGTACTAGCTATAATTCTTGTGATGATGATGATGAT
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenčníchopnost
UNIVERSITATIS
JANAE BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- <http://workbench.sdsc.edu/>

Frame 1, 1 stop codon

Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds. Tran
>170248 Translated - Frame 1
ELPWGARAKLFAKWKNIIFPSVCNSYSI*INKGANLTILPL

E L P W G A R A K L F A K W K N I I P S S
1 gagttccctggggcaaggccaaaattttgttaatggaaaaatataccaagt 60
V C N S Y S I * I N K G A N L T I L P L
61 gtttgtaaatagttactcaatttgaattaacaaggccaaatttgactattttgcctta 120

Frame 2, 1 stop codon

Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds. Tran
>170248 Translated - Frame 2
SSLGGQQNFLNGKILYQVFVIVIQFELTKQI*LFCP

S S L G G Q G Q N F L L N G K I L Y Q V
2 agotccctggggcaaggccaaaactttgttaatggaaaaatataccaagt 61
F V I V T Q F E L T K G Q I * L F C P
62 ttttgtaaatagttactcaatttgaattaacaaggccaaatttgactattttgcctta 120



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- <http://workbench.sdsc.edu/>

— Linear Map of Sequence:

```
      SstI
      BsaJI
      CviJI
      AluI
      SacI
      EcoICRI
      Bsp1286I
      BsiHKAI
      BanII
      BslI
      SspI
      \ \ \ \
      1  gagctcccttggggggcaagggcaaaacttttgcataatggaaaaattttatccaagt 60
          ctcgaggggacccccccgttcggttttaaaaacgattttatccctttataatatgttca
          * * * * * * * * * * * * * * * * * * * * * * * * * * * * * * *
      1  E L P W G A R A K L F A K W K N I I P S *
      2  S A P L G G Q G O N F L L N G K I L Y Q V
      3  A P F L G G K G K T F C * M E K Y Y T K C
      4  L E R P P C P C F K K S F P F I N Y W T
      5  S S G Q P A L A F S K A L H F F I I G L
      6  L A G K P P L P L V E Q * I S F Y * V L
      Tsp509I           Tsp509I
      MaeIII Tsp509I MseI           ApoI
      \ \ \ \
      61 gtttgtaatagttactcaatttgaatcaaacaaggccaaatttgactatttgcctta 120
          caaacattataatagttatggtaaactttatgtttcccgctttaactgtataaaacggat
          * * * * * * * * * * * * * * * * * * * * * * * * * * * * * * *
      1  V C N S Y S L * I N K G A N L T I L P L
      2  F V I V T Q F E L T K G G Q I * L F C P *
      3  L * * L L N L N * Q R G K F D Y F A L R
      4  N T I T V * N S N V F F P C I Q S N Q G *
      5  T Q L L * E I Q I L L P A F K V I K G K
      6  H K Y Y N S L K F * C L P L N S * K A R
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY
pro konkurenčnost
OP Vzdělávání



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- o <http://workbench.sdsc.edu/>

Selected Sequences:

- Lycopersicon esculentum beta-1,3-glucanase mRNA, complete cds.
- Ornithidium vulgare L. GC170 beta-1,3-glucanase-like protein gene.
- Nicotiana tabacum glucan beta-1,3-glucanase gene, complete cds.
- Musotama plumbeoglandula beta-(1,3)-glucanase gene for a vacuole.
- Morinda volgare L. beta-glucuronidase (BQ-Q60) gene, complete cds.

Download a PostScript version of the output

MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



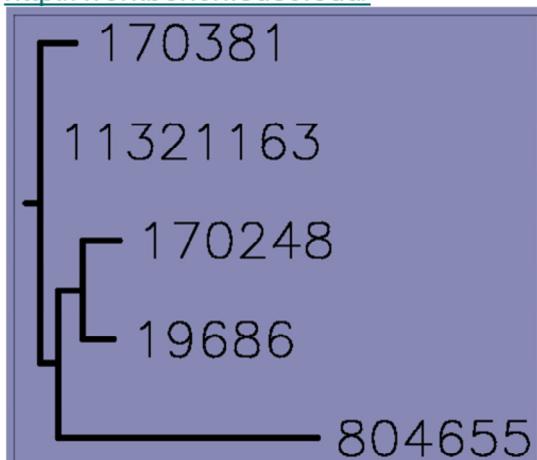
UNIVERSITATE JK JAKOVA BRUNNÉHO

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- <http://workbench.sdsc.edu/>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- VPCR <http://grup.cribi.unipd.it/cgi-bin/mateo/vpcr2.cgi>

The screenshot shows the vPCR 2.0 web interface. At the top, there are tabs for SEARCH, ABOUT, DOWNLOAD, and LINKS. Below the tabs, a note states: "VPCR 2.0 (WWW interface) - Please, enter nucleotide primer sequences (UR codes allowed for degenerate primers). VPCR 2.0 searches the specified database for matches to the primers. If matches are found within 10000 bases, a PCR simulation model predicts amplification. Calculated PCR products are displayed within a minute." A note below says: "NOTE: Abilities of VPCR 2.0 are still limited by BLAST capabilities and settings, as well as inability of our server resources to deal with more than a couple thousand matches per primer. That's why we have shown a limit of 11-mer length in order to have more matches. Primers with overrepresented sequences cause problems as well. We are now busy solving most of these problems, please, be patient. If you have a mistake, please, let us know what kind of expectations you have for VPCR 2.0 etc. Currently, this address is for testing VPCR 2.0, stable features will be installed on [VPCR 2.0 Homepage](#)". The main form area has fields for "Search using" (set to BLAST), "in the database for" (set to M.musculus), and eight input fields for "Primer 1" through "Primer 8". Below these is a "Annealing temperature" field set to 50, and a "Do PCR!" button. The vPCR logo is at the bottom right.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



UNIVERSITAS
JAKOVA BRUNNESA

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytical Tools

- VPCR <http://grup.cribi.unipd.it/cgi-bin/mateo/vpcr2.cgi>



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Outline

- Syllabus Of The Course
- Definition Of Genomics
- Role Of Bioinformatics In Functional Genomics
- Databases
 - Spectre Of „On-line“ Resources
 - PRIMARY, SECONDARY And STRUCTURAL Databases
 - GENOME Resources
- Analytical Tools
 - Homologies Searching
 - Searching Of Sequence Motifs, Open Reading Frames, Restriction Sites...
 - Other On-line Genome Tools



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Other On-Line Genome Resources

- **TIGR (The Institute for Genomic Research, <http://www.tigr.org/software/>)**
 - Recently part of the [J. Craig Venter Institute](#)

The screenshot shows the TIGR Human Genome Browser interface for the PHACTR4 gene. The main content area displays the gene's official symbol (PHACTR4), official full name (phosphatase and actin regulator 4), and various genomic details like locus tag (RP11-442N2_L_A1) and review status (REVIEWED). A summary notes that this gene encodes a member of the phosphatase and actin-regulating (PAP) family. Below this is a genomic context diagram showing the gene's location on Chromosome 1 (NC_000001.10) between markers D4Z4 and D4Z5. The diagram includes a zoom feature and a link to the MapView. To the right is a table of contents and a links section. At the bottom, there are navigation links for nucleotide, statistics, FASTA, and genomic data.

EVROPSKÁ UNIE
esf
MINISTERSTVO MLÁDEŽE

JE VZDĚLÁVÁNÍ
Tato akce je spolufinancována
- kým sociálním fondem
- a zdrojem financí České republiky

Other On-Line Genome Resources

■ Online Mendelian Inheritance in Man (OMIM)



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Summary

- Syllabus Of The Course
- Definition Of Genomics
- Role Of Bioinformatics In Functional Genomics
- Databases
 - Spectre Of „On-line“ Resources
 - PRIMARY, SECONDARY and STRUCTURAL Databases
 - GENOME Resources
- Analytical Tools
 - Homologies Searching
 - Searching Of Sequence Motifs, Open Reading Frames, Restriction Sites...
 - Other On-line Genome Tools



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Discussion



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenčníchopnost



UNIVERSITAS
JYVÄSKYLÄ
UNIVERSITY OF
JYVÄSKYLÄ

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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