

CG020 Genomika Bi7201 Základy genomiky

Přednáška 1 Úvod do bioinformatiky

Jan Hejátko

Funkční genomika a proteomika rostlin,
Mendelovo centrum genomiky a proteomiky rostlin,
Středoevropský technologický institut (CEITEC), Masarykova univerzita, Brno
hejatko@sci.muni.cz, www.ceitec.muni.cz



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Osnova

- Schéma předmětu
- Definice
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze
 - GENOMOVÉ zdroje
- Analytické nástroje
 - Vyhledávání homologií
 - Vyhledávání sekvenčních motivů, otevřených čtecích rámců, restrikčních míst....
 - Další www genomové nástroje



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Schéma předmětu

- **Kapitola 01** (CG020 , Bi7201)
 - Úvod do bioinformatiky
- **Kapitola 02** (CG020 , Bi7201)
 - Identifikace genů
- **Kapitola 03** (CG020 , Bi7201)
 - Přístupy reverzní genetiky
- **Kapitola 04** (CG020 , Bi7201)
 - Přístupy genetiky přímé



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Schéma předmětu

- **Kapitola 05** (CG020 , Bi7201)
 - Přístupy funkční genomiky
- **Kapitola 06** (CG020 , Bi7201)
 - Protein-protein interakce a jejich analýza
- **Kapitola 07** (CG020)
 - Moderní postupy funkční genomiky
- **Kapitola 08** (CG020)
 - Strukturní genomika



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Schéma předmětu

- **Kapitola 09 (CG020)**
 - Lokalizace genů a genových produktů v buňce
- **Kapitola 10 (CG020)**
 - Genomika a systémová biologie
- **Kapitola 11 (CG020)**
 - Praktické aspekty funkční genomiky
- **Kapitola 12 (CG020)**
 - Lokalizace genů a genových produktů v buňce



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Literatura

- Zdrojová literatura ke kapitole I:
 - **Bioinformatics and Functional Genomics**, 2009, Jonathan Pevsner, Willey-Blackwell, Hoboken, New Jersey
<http://www.bioinfbook.org/index.php>
 - **Úvod do praktické bioinformatiky**, Fatima Cvrčková, 2006, Academia, Praha
 - **Plant Functional Genomics**, ed. Erich Grotewold, 2003, Humana Press, Totowa, New Jersey



INVESTICE DO ROZVOJE Vzdělávání

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

Osnova

- Schéma předmětu
- Definice



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

GENOMIKA-co to je?

- V širším pojetí zkoumá **STRUKTURU** a **FUNKCI** genomů
 - Předpokladem je znalost genomu (sekvencí)-práce s databázemi
- V užším pojetí zkoumá **FUNKCI** jednotlivých genů - **FUNKČNÍ GENOMIKA**
 - používá zejména přístupy REVERZNÍ GENETIKY



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



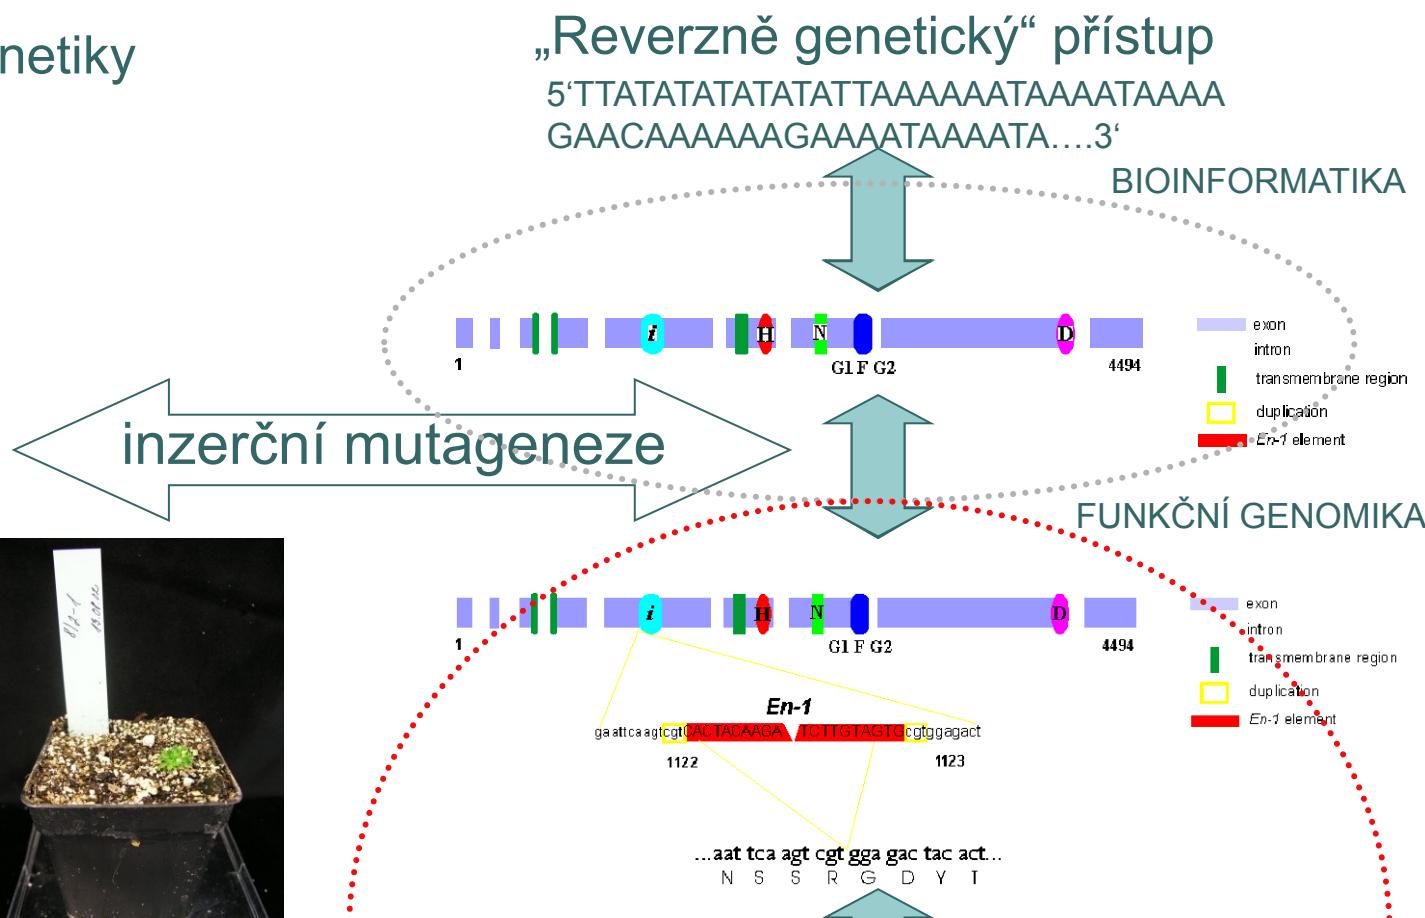
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

GENOMIKA-co to je?

role BIOINFORMATIKY ve FUNKČNÍ GENOMICE

Přístupy „klasické“ genetiky



3

:

1

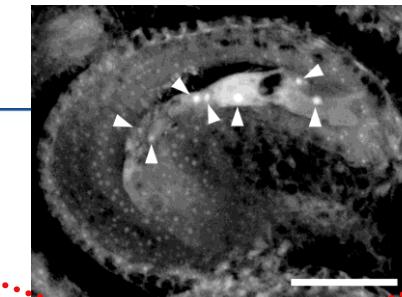


?



MLÁDEŽE A TĚLOVÝCHOVY

pro konkurenčnost



VOJE VZDĚLÁVÁNÍ

Projekt je spolufinancován Evropským sociálním fondem
a vlastním rozpočtem České republiky

Osnova

- Schéma předmětu
- Definice
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY

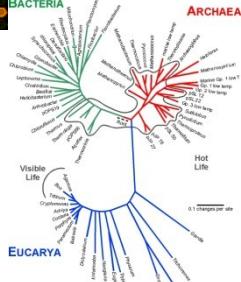
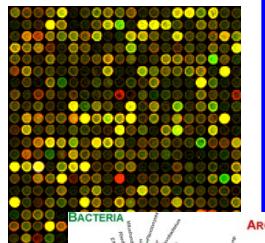


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Bioinformatika

- **Definice bioinformatiky** (podle NIH vědeckého a technologického konsorcia pro biomedicínské informace)



Výzkum, vývoj nebo aplikace výpočetních nástrojů a přístupů za účelem zvyšování rozvoje využití biologických, lékařských, dat o chování nebo zdraví, včetně těch, které umožňují taková data získávat, ukládat, organizovat, archivovat, analyzovat nebo vizualizovat.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

What is bioinformatics?

- Interface of biology and computers
- Analysis of proteins, genes and genomes using computer algorithms and computer 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>

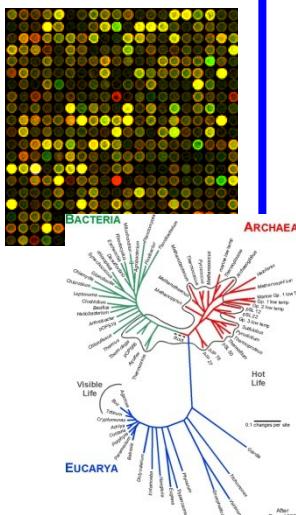


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Bioinformatika

- Bioinformatika ve funkční genomice
 - Zpracování a analýza sekvenačních dat
 - Identifikace referenčních sekvencí
 - Identifikace genů
 - Identifikace homologů, ortologů a paralogů
 - Korelační analýzy mezi sekvencemi a fenotypy (včetně člověka)
 - Zpracování a analýza transkripčních dat
 - Transkripční profilování pomocí DNA čipů nebo next-gen sekvenování
 - Vyhodnocování experimentálních dat a predikce nových regulací v přístupech systémové biologie
 - Matematické modelování genových regulačních sítí



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Osnova

- Schéma předmětu
- Definice
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Spektrum on-line zdrojů

EMBnet National Nodes

Vienna Biocenter	Austria	http://www.at.embnet.org/
BEN	Belgium	http://www.be.embnet.org/
BioBase	Denmark	http://biobase.dk/
CSC	Finland	http://www.fi.embnet.org/
INFOBIOGEN	France	http://www.infobiogen.fr/
GENIUSnet	Germany	http://genome.dkfz-heidelberg.de/biounit/
IMBB	Greece	http://www.imbb.forth.gr/
HEN	Hungary	http://www.hu.embnet.org/
INCBI	Ireland	http://acer.gen.tcd.ie/
INN	Israel	http://dapsas.weizmann.ac.il/bcd/inn.html
IEN-ADR	Italy	http://bio-www.ba.cnr.it:8000/BioWWW/Bio-WWW.htm
CAOS/CAMM	Netherlands	http://www.caos.kun.nl/
Bio	Norway	http://www.no.embnet.org/
IBB	Poland	http://www.ibb.waw.pl/
IGC	Portugal	http://www.igc.gulbenkian.pt/
GeneBee	Russia	http://www.genabee.msu.su/
CNB-CSIC	Spain	http://www.es.embnet.org/
BMC	Sweden	http://www.embnet.se/
SIB	Switzerland	http://www.ch.embnet.org/
SEQNET	UK	http://www.seqnet.dl.ac.uk/

EMBnet Specialist Nodes

MIPS	Germany	http://www.mips.biochem.mpg.de/
ICGEB	Italy	http://www.icgeb.trieste.it/
Pharmacia Upjohn	Sweden	http://www.pnu.com/
F.Hoffmann-La Roche	Switzerland	http://www.roche.com/
EBI	UK	http://www.ebi.ac.uk/
HGMP-RC	UK	http://www.hgmp.mrc.ac.uk/
Sanger	UK	http://www.sanger.ac.uk/
UMBER	UK	http://www.bioinf.man.ac.uk/dbrowser

EMBnet Associate Nodes

IBBM	Argentina	http://sol.biol.unlp.edu.ar/embnet
ANGIS	Australia	http://www.angis.su.oz.au/
CBI	China	http://www.cbi.pku.edu.cn/
CIGB	Cuba	http://bio.cigb.edu.cu/
CDFD	India	http://salarjung.embnet.org.in/
SANBI	South Africa	http://www.sanbi.ac.za

USA Information Providers

NCBI	USA	http://www.ncbi.nlm.nih.gov/
NLM	USA	http://www.nlm.nih.gov/
NIH	USA	http://www.nih.gov/



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

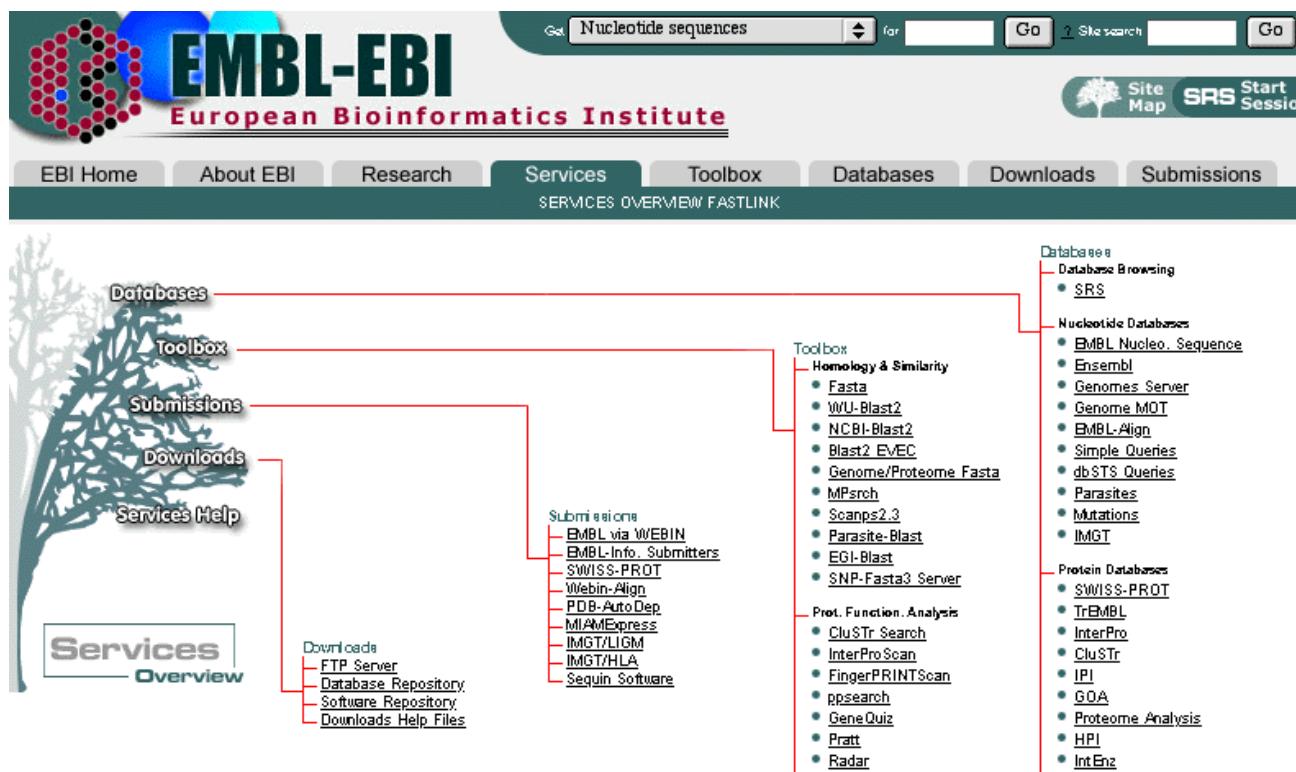


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Spektrum on-line zdrojů

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



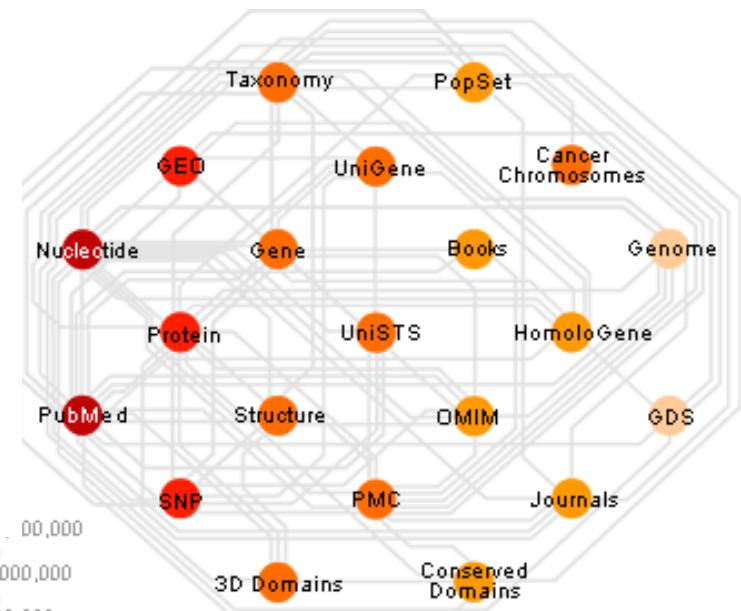
INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Spektrum on-line zdrojů

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

The screenshot shows the NCBI homepage with a blue header bar containing the NCBI logo, a search bar, and links for Resources, How To, My NCBI, and Sign In. Below the header is a navigation menu with links to NCBI Home, Resource List (A-Z), 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. The main content area features a "Welcome to NCBI" section with a brief introduction and links to About the NCBI, Mission, Organization, Research, and RSS Feeds. It also includes a "Get Started" section with links to Tools, Downloads, How-To's, and Submissions. A "NCBI YouTube channel" section with a video player and a "GO" button is present. On the right side, there is a "Popular Resources" sidebar listing PubMed, Bookshelf, PubMed Central, PubMed Health, BLAST, Nucleotide, Genome, SNP, Gene, Protein, and PubChem. At the bottom right is a logarithmic scale from 1,000 to 10,000,000.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



Evropským sociálním fondem
a státním rozpočtem České republiky

Osnova

- Schéma předmětu
- Definice
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - **PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze**



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

- zahrnují soubory primárních dat – sekvencí DNA a proteinů
 - Sekvence v databázích tzv. „Velké trojky“:
 - EMBL, <http://www.ebi.ac.uk/embl/>
 - GenBank, http://www.ncbi.nih.gov/Genbank/Genbank_Search.html
 - DDBJ, <http://www.ddbj.nig.ac.jp>
 - denně vzájemná výměna a zálohování dat
 - velká datová náročnost (kapacita i software)
 - září 2003 $27,2 \times 10^6$ záznamů o zhruba 33×10^9 bp
 - srpen 2005 100×10^9 bp ze 165.000 organizmů



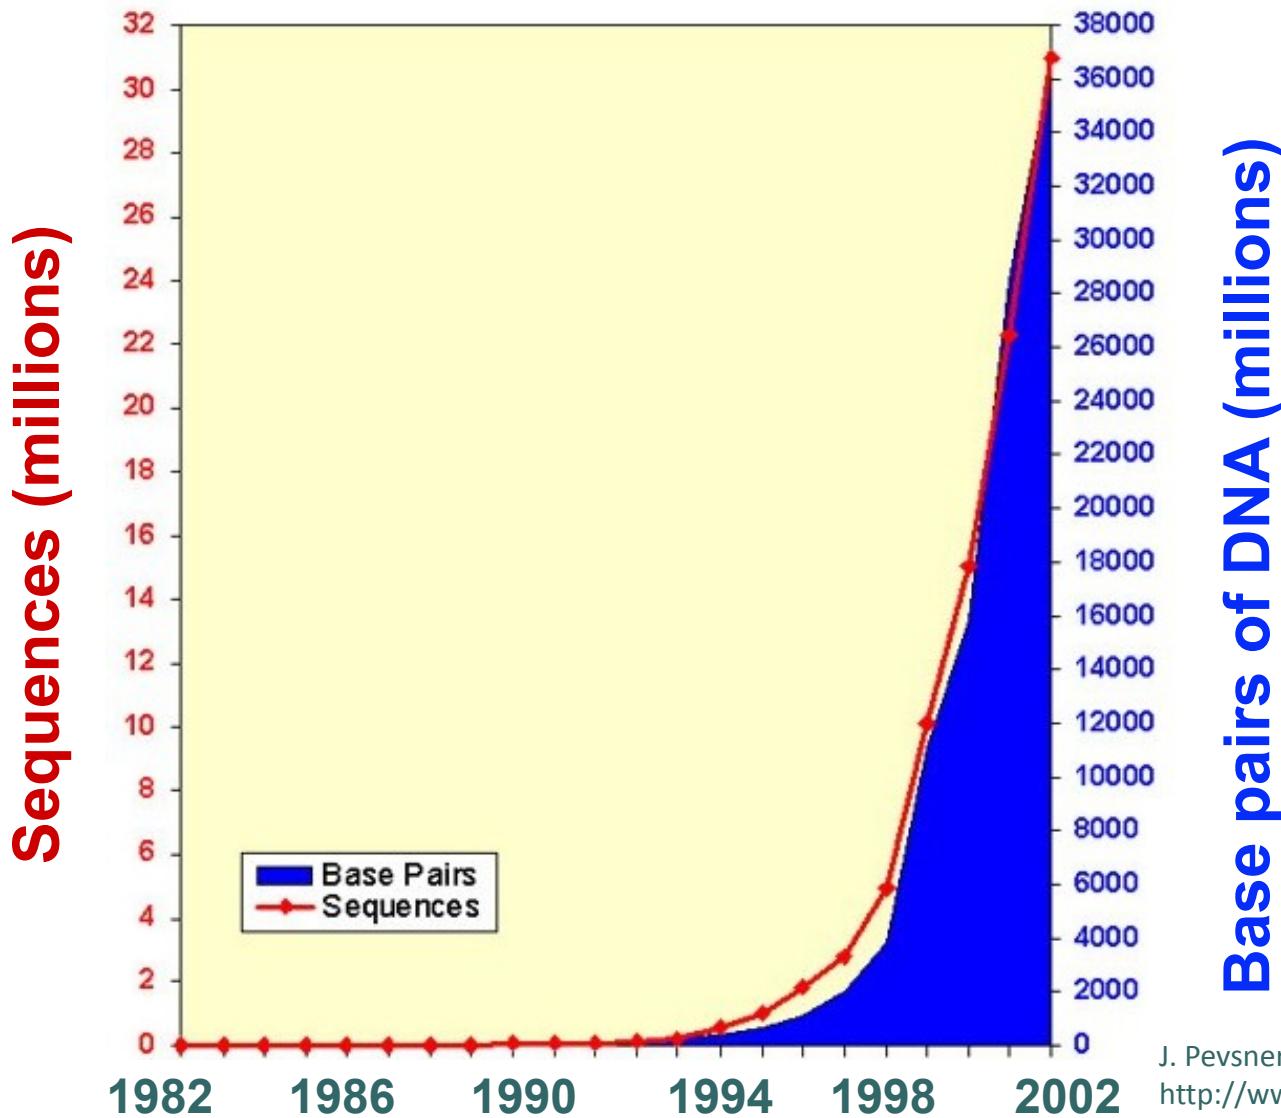
MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Growth of GenBank



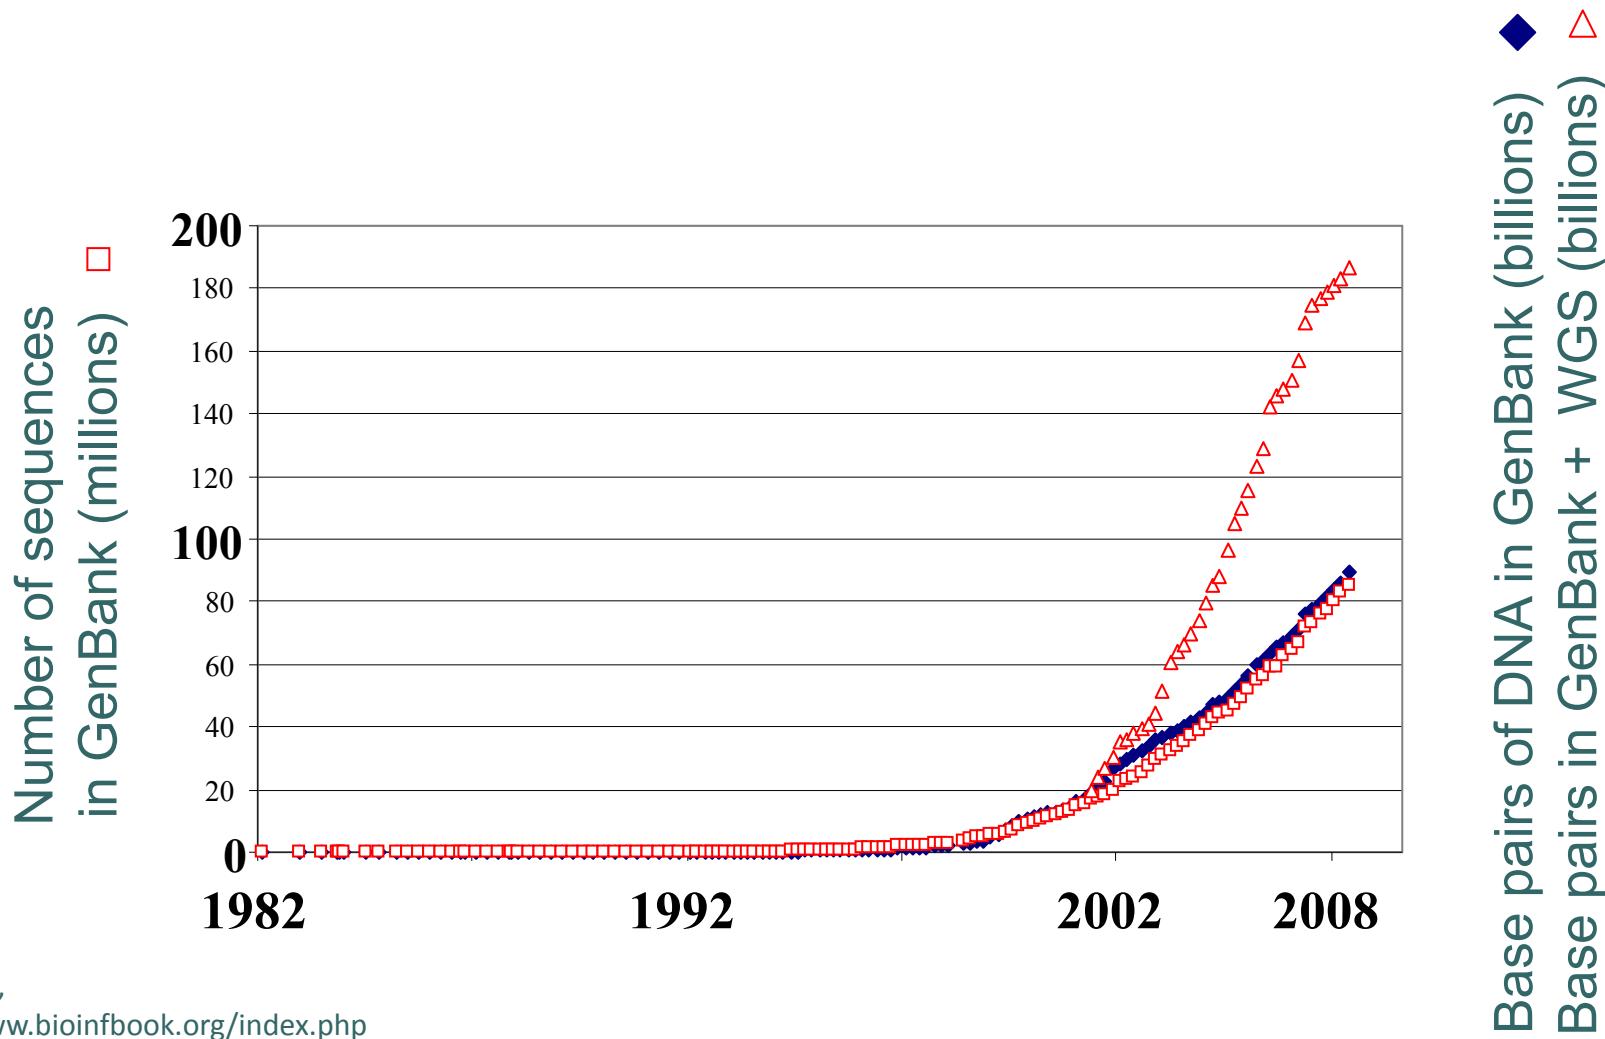
MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



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



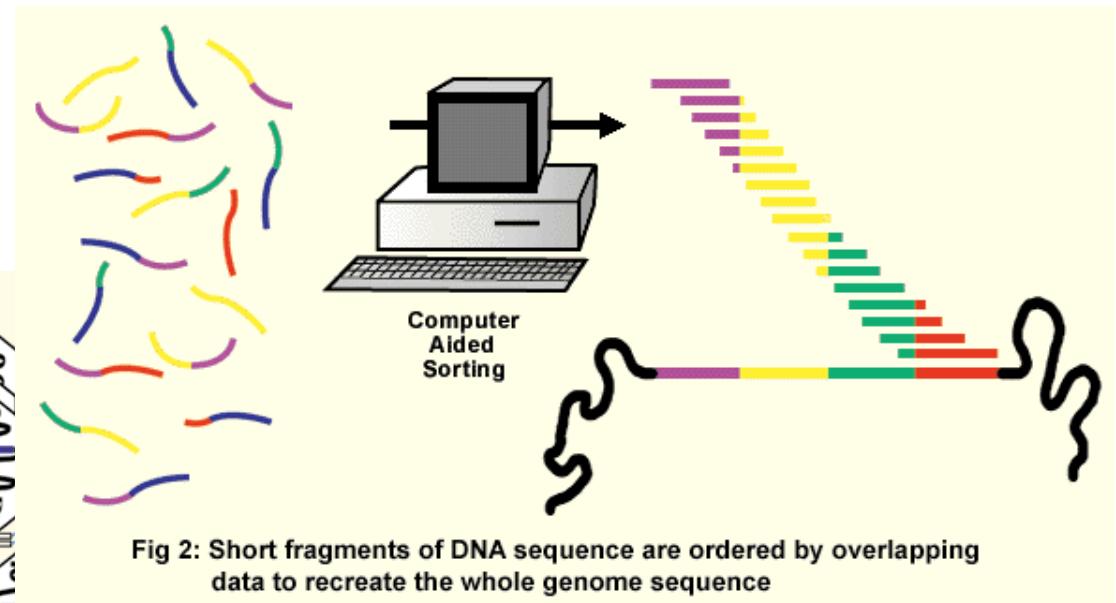
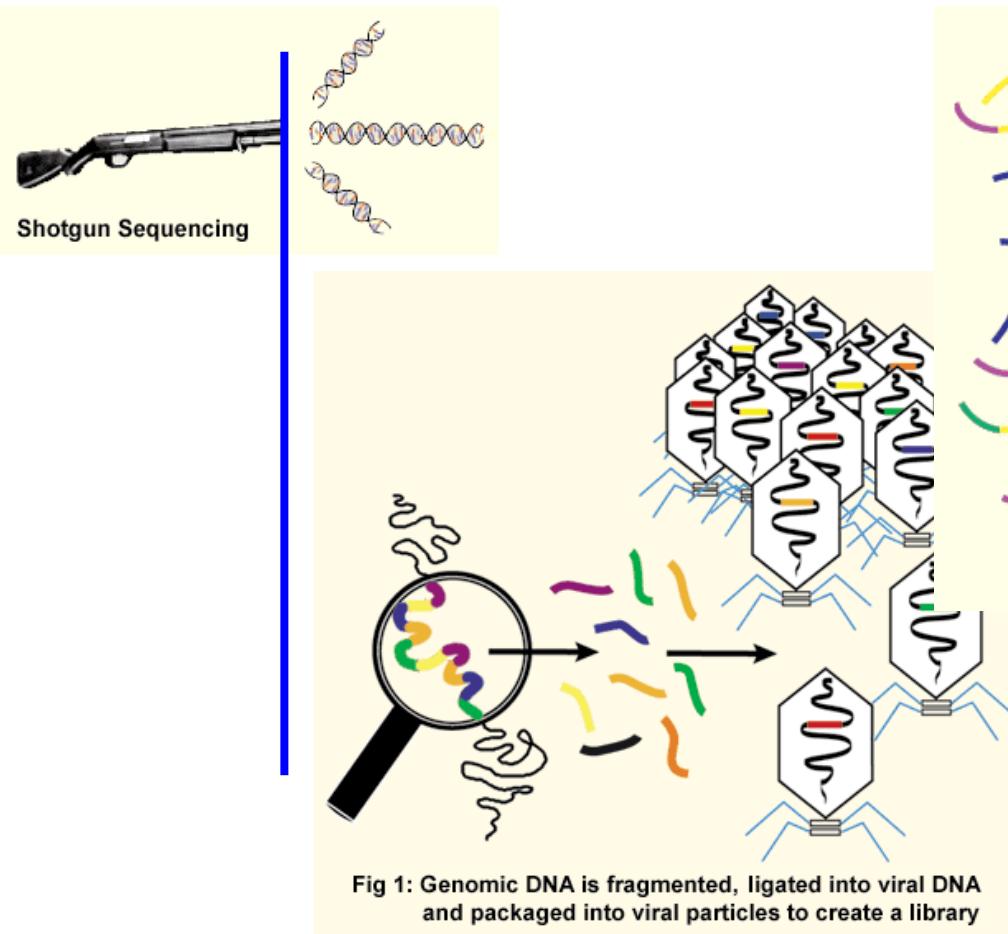
J. Pevsner,
<http://www.bioinfbbook.org/index.php>



INVESTICE DO ROZVOJE Vzdělávání

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

WGS



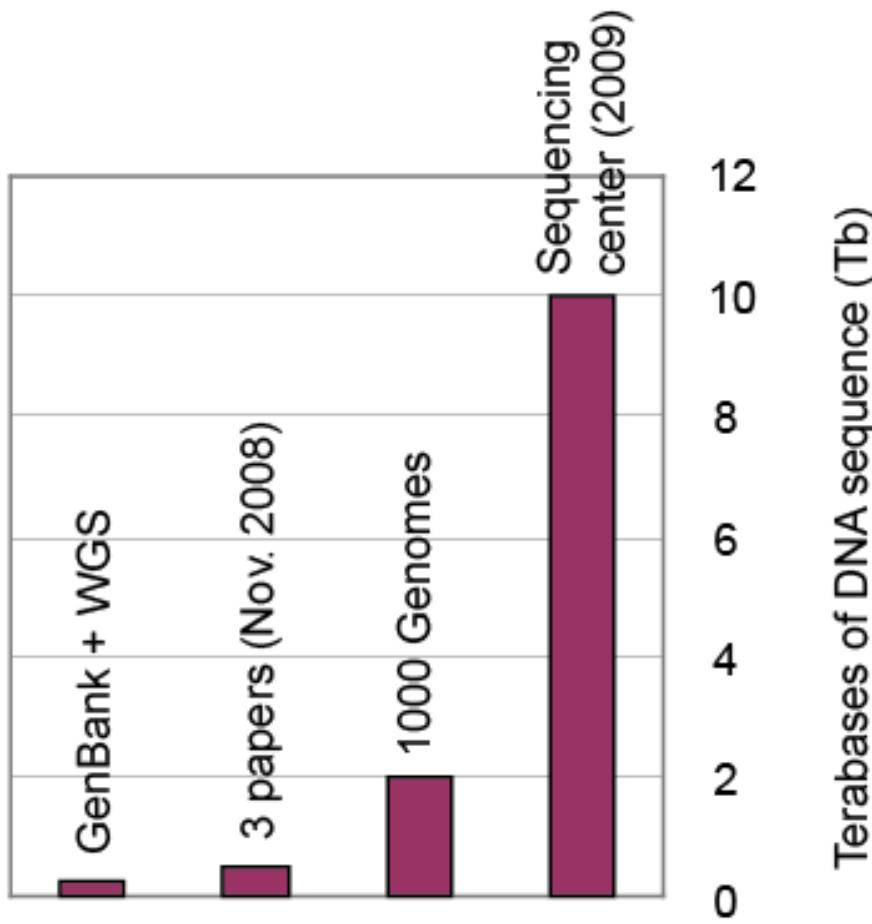
Interactive concepts in biochemistry, Rodney Boyer, Wiley, 2002, <http://www.wiley.com//college/boyer/0470003790/>



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Arrival of next-generation sequencing: In two years we have gone from 0.2 terabases to 71 terabases (71,000 gigabases) (November 2010)



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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

- zahrnují soubory primárních dat – sekvencí DNA a proteinů
 - Proteinové sekvence:
 - PIR, <http://pir.georgetown.edu/>
 - MIPS, <http://www.mips.biochem.mpg.de>
 - SWISS-PROT, <http://www.expasy.org/sprot/>



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

- Typy sekvencí v primárních databázích
 - standardní nukleotidové sekvence získané kvalitním sekvencováním
 - **ESTs (Expressed Sequence Tags)**
 - **HGTS (High Throughput Genome Sequencing)**
 - neanotované „surové“ výsledky sekvenačních projektů
 - referenční sekvence anotovaných genomů
 - **TPAs (Third Party Annotation)**
 - sekvence anotované jinými než původními autory



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

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

The screenshot shows the NCBI homepage. At the top, there's a blue header bar with the NCBI logo, a "Resources" dropdown, a "How To" dropdown, and links for "My NCBI" and "Sign In". Below the header is the NCBI logo and the text "National Center for Biotechnology Information". A search bar with the placeholder "All Databases" and a "Search" button is positioned above the main content area. On the left, a sidebar menu lists categories like "NCBI Home", "Resource List (A-Z)", "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". The main content area features a "Welcome to NCBI" section with a brief description of the center's mission and links to "About the NCBI", "Mission", "Organization", "Research", and "RSS Feeds". Below this is a "Get Started" section with a bulleted list of links: "Tools", "Downloads", "How-To's", and "Submissions". To the right, there's a "Popular Resources" sidebar listing "PubMed", "Bookshelf", "PubMed Central", "PubMed Health", "BLAST", "Nucleotide", "Genome", "SNP", "Gene", "Protein", and "PubChem". At the bottom, there's a "NCBI Announcer" section with news items and a "NCBI YouTube channel" section featuring a thumbnail for a video tutorial.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

The screenshot shows a Firefox browser window displaying the NCBI BioProject page for the gene *virA*. The page includes the following sections:

- Summary:** Gene symbol *virA*, Gene description two-component VirA-like sensor kinase, Locus tag *pTi_125*, Gene type protein coding, RefSeq status PROVISIONAL, Organism *Agrobacterium tumefaciens* (old-name: *Agrobacterium tumefaciens*; gb-synonym: *Rhizobium radiobacter*), Lineage Bacteria; Proteobacteria; Alphaproteobacteria; Rhizobiales; Rhizobiaceae; Rhizobium/Agrobacterium group; Agrobacterium; Agrobacterium tumefaciens complex.
- Genomic context:** Location: plasmid: Ti, Sequence: NC_002377.1 (145694..148183). A diagram shows the genomic context of the *virA* gene, which is part of a larger operon spanning from approximately 142447 to 151951. The gene is preceded by *virR* and followed by *virB1*.
- Genomic regions, transcripts, and products:** Genomic Sequence NC_002377.1. A detailed genomic track viewer shows the sequence from 145,400 to 148,400, highlighting the *virA* gene. A yellow circle is drawn over the *virA* gene track.
- Bibliography:** Related articles:

 - Sequence analysis of the *virA* locus of *Agrobacterium tumefaciens* octopine Ti plasmid *pTi15956*. Schrammeijer B, et al. J Exp Bot, 2000 Jun. PMID 10948245.
 - The *virA* promoter is a host-range determinant in *Agrobacterium tumefaciens*. Turk SC, et al. Mol Microbiol, 1993 Mar. PMID 8469115.
 - Characterization of the *virA* locus of *Agrobacterium tumefaciens*: a transcriptional regulator and host range determinant. Leroux B, et al. EMBO J, 1987 Apr. PMID 3595559.
 - Analysis of the complete nucleotide sequence of the *Agrobacterium tumefaciens* *virB* operon. Thompson DV, et al. Nucleic Acids Res, 1988 May 25. PMID 2837739.

- GeneRIFs:** Gene References Into Functions. Submit: New GeneRIF Correction.
- Links:** Bibliography, General protein info, Reference sequences, Related sequences, BioProjects, Conserved Domains, Full text in PMC, Genome, Nucleotide, Protein, Protein Clusters, PubMed, RefSeq Proteins, Taxonomy.
- General information:** About Gene, FAQ, FTP site, Help, My NCBI help, NCBI Handbook, Statistics.
- Related sites:** BLAST, Genome, BioProject, Genomic Biology, GEO, HomoloGene, Map Viewer, OMIM, Probe, RefSeq, UniGene, UniSTS.
- Feedback:** Contact Help Desk, Submit Correction, Submit GeneRIF.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

Firefox - Home - BioProject - NCBI - virA two-component VirA-like sensor... +

www.ncbi.nlm.nih.gov/gene/1224316

NC_002377.1: 145K..148K (2.9Kbp) ▾

Genes

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](#)

Bibliography

Related articles in PubMed



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

Přístupový kód
I: NC_002377 [1..2490] (1..2490)

GeneBank Identifier
NC_002377

LOCUS NC_002377 2490 bp DNA linear BCT 29-DEC-2003

DEFINITION Agrobacterium tumefaciens extrachromosomal plasmid Ti, complete sequence.

ACCESSION NC_002377 REGION: 145694..148183

VERSION NC_002377.1 GI:10955016

KEYWORDS .

SOURCE Agrobacterium tumefaciens (Rhizobium radiobacter)

Farrand, S.K., Oger, P.M., Schrammeijer, B., Hooykaas, P.J. and Winans, S.C.

TITLE Octopine-type Ti plasmid sequence

JOURNAL Unpublished

REFERENCE 2 (bases 1 to 2490)

AUTHORS Zhu, J., Oger, P.M., Schrammeijer, B., Hooykaas, P.J., Farrand, S.K. and Winans, S.C.

TITLE Direct Submission

JOURNAL Submitted (07-MAR-2000) Microbiology, Cornell University, Wing Hall, Ithaca, NY 14853, USA

COMMENT PROVISIONAL [REFSEQ](#): This record has not yet been subject to final NCBI review. The reference sequence was derived from [AF242881](#).

FEATURES Location/Qualifiers

source 1..2490
/organism="Agrobacterium tumefaciens"
/mol_type="genomic DNA"
/db_xref="taxon:358"
/plasmid="Ti"
/note="extrachromosomal
octopine-type"

gene 1..2490
/gene="virA"
/db_xref="GeneID:1224316"

CDS 1..2490
/gene="virA"
/note="two-component regulator of vir regulon; VirA is a transmembrane histidine kinase"
/codon_start=1
/transl_table=11
/product="virA"
/protein_id="NP_059797.1"
/db_xref="GI:10955141"



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

/translation="MMGRYSPTRQDFPTGAKPWEILALIIVAAMIFAPMAVASQDNAT
TQAILSRLRSINADSASLQRDVILRAHTGTIVANRPIISRLGALKNLEDLKQLPRQEH
IVSBERNAQQLLQLPEVSLSMSADAVAAVPGACNVRQJDSLASPTIALSPGKASTDQT
LEKPTELAEMMLQPLQPEPAISFHESELRELQKQGRGLDRAFPWLAREGPFIILEL
PQVKDVLVNMQTSDTDAEIAEMMQLRECLERVYSLNKVERESARIFLGSASAVGLCIVITI
VYRLKEKTDWLARRLDYELIKEIGVCPFGAAATTESAQAALRIJIQRPFDADTCALAL
VCHDERNAVETPGAKHPKPWDDSVLRERIVERTKADERATVPRIESKKIVHLPBIP
GLSILLAHKSTDKLIAVCSLCYOSYPRPCOGHQLLELATACIHYIDIVEBKOTBCD
VLAJRLHQAQRLAVGTLAGGIAHBNNILGSILGHAEELAQNSVSRSTVTRYIDVII
SSGDRAMLIIDQILTLSKQERNIKPPSVSHLTVEAFLPMLPNPIEFLFRPDQMQ
SVIESESPLELQQVLINICKNASQAMTANGQIDIIBQAFPLVKKILAHGVMPGDYVL
LSISDNGGIGPEAVLPHIPEPFPTTRARNGTGLGLASVHGHISAFAGYIDVESTVGH
GTRFDIYLPPESKRPVNDEPPGRNKAFRGNGHIVALVEPFDLIREAYEDKIAALGYE
PVGFPTVNEIRDWISKNGHEADLUVMDQASLPEDQSPNSVDLVLKTAISIIGGNDLKMT
LSREDVTRDLYLPKPISSERTMAHILTHIKT"

ORIGIN

```
1 atgaacggaa gatattcaco gacgccccac gattttaaa cagggccgaa gccttggct  
61 attttggccc ttatcggttgc tcaatgatt ttccgggttc tggccgggttc gtcttggcc  
121 gacaaatggcc ctacccggc aacttcggc caacttcggc cgattaaacgc cggccggcc  
181 tcactggcc gggatgtact ccggccgttc acgggcaccc tggccgacta cggccggcc  
241 attcggccggc tggggatgt actggggatcc ctggaaaggatt tggccgactt atttagacaaa  
301 tccttatttc taatggcggat caatcgcttc caatcgatca gccaggatcc agttttctta  
361 aatttggccgt aeggggggtt cggccggccaa atgtacggcgtt gcaagatcc  
421 ctggccgggtt tcacttcgtt tttggatgtt ctccggaa gacccggccac cgtatcgact  
481 ttggaaaaaaac caacggaaattttggatgtt atgtcccaat ttcttggcca accaaaggcc  
541 gttatattccat tggatgttccat cttggatcaat gagggccatcc aaaaacaacgg cggttttgtat  
601 gaatccccc tggccgatcaat tggccgatcaat ggttccatttttcttategtt tttccacac  
661 ttggaaatggat tggccgatcaat tggccgatcaat cggatccggc cggatgttcc  
721 cagggccggat tttttggatgtt cttatggatcc aaaaatgttcc agggatggggatcc cggatgttcc  
781 ttctttgggtt cggccggatgtt ctccatataca tccatctttat ctataggctt  
841 cggaaaaaaaatcc cggatgttcc cggccggatgtt tttatggatcc aagagctaat caaagatcc  
901 ggatgtatgtt ttggatgttcc cggccggatgtt atggatgttcc cggatgttcc accctgtt  
961 attcggccgtt tttttggatgtt cggatgttcc atggatgttcc tttttggatgttcc tgaccgtt  
1021 tggccgttgtt aaaaatccatggatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1081 cggccggatccatcc tggccgatcaat cccaaatggccatcc cggatgttcc cccatccatcc  
1141 tggccggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1201 aatcccaatggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1261 cttttggccatcc gggatccatcc gttttggccatcc tggccgatcaat cccatccatcc  
1321 gatgttccggc gtaagccggatcc cggatgttccatcc tggccgatcaat cccatccatcc  
1381 cggccggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1441 gggccatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1501 cggccatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1561 atttttggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1621 tggccgatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1681 agatggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1741 attaaatggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1801 atccatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1861 gactatgttccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1921 cacatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
1981 gttttttggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
2041 gggccatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
2101 gacatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
2161 gacatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
2221 cggccatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
2281 gatccatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt  
2341 ttatggatccatcc tggccgatcaat cccaaatggccatcc tggccgttgtt
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



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

DNA

RNA

protein

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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Page 27

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>



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

RefSeq

The screenshot shows a Firefox browser window displaying the NCBI Reference Sequences (RefSeq) page for the gene *virA*. The URL in the address bar is www.ncbi.nlm.nih.gov/gene/1137489. The page title is "two-component VirA-like sensor kinase".

NCBI Reference Sequences (RefSeq)

Genome Annotation

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]

UniProtKB/Swiss-Prot | P18540
Conserved Domains (3) [summary](#)

cd00075	HATPase_c; Histidine kinase-like ATPases; This family includes several ATP-binding proteins for example: histidine kinase, DNA gyrase B, topoisomerases, heat shock protein HSP90, phytochrome-like ATPases and DNA mismatch repair proteins
cd00082	HisKA; Histidine Kinase A (dimerization/phosphoacceptor) domain: Histidine Kinase A dimers are formed through parallel association of 2 domains creating 4-helix bundles; usually these domains contain a conserved His residue and are activated via ...
PRK13837	PRK13837; two-component VirA-like sensor kinase; Provisional

Location: 580 – 694
Blast Score: 202

Location: 466 – 530
Blast Score: 144

Location: 14 – 833
Blast Score: 2944

Related Sequences

Windows taskbar icons include: virA two-component..., Kalendar - Osobní sl..., Doručená pošta - M..., CG020_2012_Lesson..., 2010-11-15_BCMB01..., Microsoft Excel - TA...



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



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>



Primární databáze

The screenshot shows a genome browser interface for the NC_002377.1 genome. A gene annotation for NP_059797.1 is highlighted in red. A tooltip provides detailed information about the gene:

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](#)

Bibliography

Related articles in PubMed



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

The screenshot shows a web browser window with the following details:

- Title Bar:** Firefox - Home - BioProject - NCBI | virA two-component VirA-like sensor... | Agrobacterium tumefaciens plasmid ... | www.ncbi.nlm.nih.gov/nuccore/NC_002377.1?report=fasta&from=145694&to=148183
- Content Area:**
 - Display Settings:** FASTA
 - Showing 2.49kb region from base 145694 to 148183.
 - Agrobacterium tumefaciens plasmid Ti, complete sequence**
 - NCBI Reference Sequence: NC_002377.1
 - GenBank Graphics**
 - Sequence content:
>gi|10955016|145694-148183 Agrobacterium tumefaciens plasmid Ti, complete sequence
ATGAACGGAAGATAATTCCAGCAGCGGCAAGGATTAAAGACAGGGCGAAGGCCCTGGTCTATACTGGCC
TTATCGCTTGTGATGTTCTGCTCATGGGCTTCAGCAGGACAACTGCAGCTACCCAGGC
AATCTTCAGCCAACTACGATGATTAACGCCGACAGCGCCTACTGCGCGATGTACTCCGGCTCAC
ACGGGACCGTGGCAACTACCGCCCATATTCTCAGGCTGGGAGCTCTCGGGAAGAACTGGAGATT
TGAACCAATTATTAGACAATCTATGTAAGTGAAGACAAUTGCTGCTCAACTGCTAGCGGACAGTAGA
ATGTTCTTAATTCCGCTGACGCCGCTTGGTGGCAAAATGTAACGCTGCAAGATTG
CTGGCAGTTTCACTGTGCTTGTAGCAGTCTTCAGAAAAGCTAACCGATCAGACTTAGAAAAAC
CRAACAGCAATTGGCTGATGCTCAATTCTCGGCAACAGGCCGGTATTCTCATCGAGATCAG
CCTTGAACTAGAGGGCTCAAAACACGGGGTCTGATGAAGCTCCCGTGCCTACACTTGAGGTGAA
GGTCCCATATCTTATCGCTTGTGACAGGTGAAAGATCTGGTGAACATGATTGACAGCTGACACCG
CAGAAATTGGCGAGATGCTGACGGAGTGTGGAGGATCTAGCTTGTGAAAGATCTGGAGGAGCGGAG
CGCAGCTATTTCTGGCTCCGTTCTGGCTCTACATCATCACCTAGTCTATAGGCTA
CGCAAAAAACGATTTGGTAGGGCGCTTGTAGATTAGCAGAAGCTAATCAAAGAGATGGAGTATGTT
TTGAAAGGGCTGACGGCTCCGGCAAGCTGCTTGTAGCTTATTCAGGGCTTCTTGTGATG
CGATACGTGGCTTGTAGCTTGTAGCTGACCATGACGGCTTGTGAAACATTCGCTGCGAAACAC
CCAAAACCTGTGGGAGCACAGCGTGTACCGCAAAATGTCCTCGTACCAAAGCGGACAGGGCGA
CGGGTATTCCGCTCATATCGTGAACATCTGCTCACCAGGAATATTGACTATATCATTCTGCTCAGG
ACTGGCTACAATCCAGATAACTTAATTGGGGTTTGTACTGGGTTACCAAAGCTATCGCCCTG
CCTGGCCAAGGAAATTCACTGCTTGTACTCGGCAACCGCTCTGCTACTATATGATTTGGC
GTAAGCAGGCTGACGGCATGCTGGGAGGATGGGAGCATGGCCAAACGGCCTTGGCAGTGGTAC
ACTTGGCGGGGAATAGCACTGAAATTAAATAACATTGGGCTCAATCTGGGCAAGCAATTAGCA
CAAACACTGGTGTCTGCAACATCTGCTCACCAGGAATATTGACTATATCATTCTGCTCAGG
CCATGCTTGTGACCGGAATTCGCTCCCTTGACTGATGGCTTCTGGCCTAACATCGAGGTTAGTT
CTCAGAGGTTGTGACCGGAATTCGCTCCCTTGACTGATGGCTTCTGGCCTAACATCGAGGTTAGTT
AGATTGATCAAATGACAGCGTGTGCAAGGGAGGCCGCTGAACTCAACAGGTTACTATTAAACATCT
GCAAGAAATGCTTCAAGGACTGAACTGCAATGCTGAAATGCTGAACTCATGACGCCAACTTGTAC
AGTTAAAGAAATTCTGGGCTATGGGTTATGCACTGGCAGACTATGCTCTTATCTTATAGCGACAAAT
GGTGGAGGCACTCCGGAGGCTTGTGATGGCTATGCACTGGGCTTGGGGTTACATGGAGCTGCAACG
GTGGAAACGGCTCGGCCCTGCTCTGTGATGGCTATGCACTGGGCTTGGGGTTACATGGAGCTTAC
TTCAACTGTTGGCCTGGGAGGGCTTGTGACATTATCTCCCTGGCTCTCAAGAACCCGTTAAATCA
GACAGTTTCCGGCAATAAGGACCGCGTGGAAACGGGGAGATGTGGCCTTGTGAGGCCGATG
ACCTCTCGGGGGCTGATGGAGGACTGCAAGGACAAAGTGCCTCTGAGGATATGAGCCGGTGGTTCTG
TAATGAAATTGGGATTGGGATTCAAAAGGCAATGGCCGATCTGGTCTATGGTGAACCAAGGGCTCTT
CCTGAAGATCAAAGCTCAATTGGTGGATTAGTGTGCTCAAGAACGCCCTCATCATTTGGGAAATG
ATCTCAAATGACCCCTTCAGGGGGAGATGTGCAAGGGCCTTATCTCCGAAGGCCGATCTGGCC
AACTATGGCCGATGCAATCTTAACCAAATCAAGGAGCTAG
 - Region Selection:** Change region shown
Whole sequence (radio button selected)
Selected region
from: 145694 to: 148183
Update View
 - Customize view:** Analyze this sequence
Run BLAST
Pick Primers
Highlight Sequence Features
Find in this Sequence
 - Related information:** BioProject, Full text in PMC, Gene, Genome, Identical GenBank Sequence, Protein, Protein Clusters, PubMed, PubMed (Weighted), Taxonomy
 - Recent activity:** Agrobacterium tumefaciens plasmid Ti, complete sequence (Nucleotide), virA [Agrobacterium tumefaciens] (Gene), virA [Agrobacterium tumefaciens str. C58] (Gene), virA (116290) (Gene)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Sekundární databáze

- databáze funkčních nebo strukturálních *motivů* získaných srovnáváním primárních dat (sekvencí)
- PROSITE, <http://www.expasy.org/prosite/>

[ExPASy Home page](http://www.expasy.org/prosite/) [Site Map](#) [Search ExPASy](#) [Contact us](#) [Swiss-Prot](#) [PROSITE](#) [Proteomics tools](#)
Hosted by SIB Switzerland | Mirror sites: [Australia](#) [Bolivia](#) [Canada](#) [China](#) [Korea](#) [Taiwan](#) [USA](#)

Search for

 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 (AC) (for example [P05130](#)) or a sequence identifier (ID) (for example [NOTC_DROME](#)), or a PDB identifier, or paste your own protein sequence in the box below:
`DMVKVTKLIVASRPIVVPCVLAFLWVWPFCIWIWNKETTE
DLVKEVASPTEDLRLTSLVEBEINIKPTYAKTNLTSTGIA
EVIDSYTINNDTGPTELQQTQIAFLIFVAYSTILQVEQVEY
IESDGIMPSYIARSNTEVAVPANSSNSRQDYTWYTQTV
DQLTGSRNLNTKSQSLDVTHTDWNPQAQSNHYTTAPVGT
SIGHDENETLIIQSVVSLSYKKGIWSLQPFVKTUTTVLNLS
HNGHELYMWTKDGTIVLVRBOSLNSPFIENGSICPGRBS
HSLWSQCIPCESSSGYEVBIKRRLRQAPCSVIEVSGVPL`

and specify which motifs 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 send results by e-mail)
 plain text output

Search Swiss-Prot with a PROSITE entry
Enter a PROSITE accession number (for example [PS01253](#)), or type your pattern in [PROSITE format](#):
(leave this box blank to scan a sequence with the entire PROSITE database)

and specify your search limits:

- The Swiss-Prot TrEMBL TrEMBLnew PDB databases
(You may also specify a protein in the box to the left)
 including splice variants
- The following taxa:
(see [NCBI Taxonomy](#); separate multiple taxa with a semicolon, e.g. *Homo sapiens; Drosophila*. Not available for PDB.)
- Sequences with at least hits
- At most 1000 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, overlaps, no includes (for patterns, see [help](#))
 randomize databases no (to test a pattern, see [help](#))



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Sekundární databáze

- databáze funkčních nebo strukturálních **motivů** získaných srovnáváním primárních dat (**sekvencí**)
- PROSITE, <http://www.expasy.org/prosite/>

>[PDOC00003 PS00003 SULFATION](#) Tyrosine sulfation site [rule] [Warning: rule with a high probability of occurrence].

571 - 585 nkeesstYeteiamns

>[PDOC00004 PS00004 CAMP_PHOSPHO_SITE](#) cAMP- and cGMP-dependent protein kinase phosphorylation site [pattern] [Warning: pattern with a high probability of occurrence].

744 - 747 RRvT
814 - 817 KRrS

>[PDOC00005 PS00005 PKC_PHOSPHO_SITE](#) Protein kinase C phosphorylation site [pattern] [Warning: pattern with a high probability of occurrence].

148 - 150 SsR
164 - 166 TgR
171 - 173 SsK
219 - 221 SkK
369 - 371 TrR
460 - 462 SgR
513 - 515 SgR
585 - 587 SsR
602 - 604 TgK
652 - 654 TdK
716 - 718 SpR
726 - 728 SpK
747 - 749 TsK
794 - 796 SsR
854 - 856 ScK
864 - 866 ScR
868 - 870 SeR
921 - 923 SpK
957 - 959 SvR
960 - 962 TgR
974 - 976 TsK
997 - 999 SrK
1002 - 1004 TgK
1018 - 1020 SgR
1031 - 1033 TgR
1119 - 1121 SkR



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Sekundární databáze

- databáze funkčních nebo strukturálních *motivů* získaných srovnáváním primárních dat (*sekvencí*)
- PROSITE, <http://www.expasy.org/prosite/>

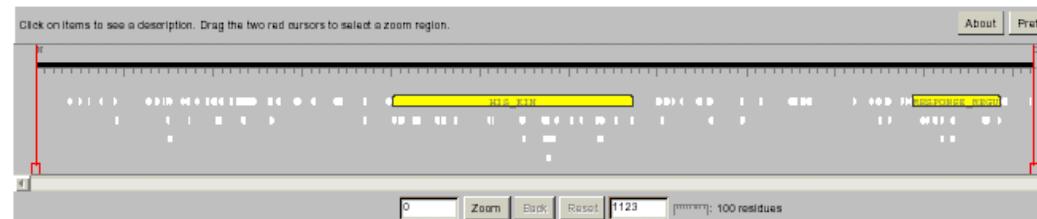
>[PDOC50109 PS50109 HIS_KIN](#) Histidine kinase domain [profile].

```
402 - 671 NASHDIRGALAGMKGLIDICRDGVKPGSDVDTTLNQVNWCALKLVALLNSVLDMSKIESG  
KMQLVERDPNLKEELIEDVIDFYHPVAMMKKGVDVLDPHDgavfKPSHVRGDSRLKQILN  
NLVSENAVKPTVII--GHTIAVRAMAQrgenassvlasypkgvakfvksamfcoknkeesatye  
teisnirnanTMEFVVPVVIDTGKGIMMEMRHKSVFENYVQVREtAQGHQGTGLGLGIVQ  
SLVRLMGGEBIRITDKAMGekGTCQPQPNVLLTT
```

>[PDOC50110 PS50110 RESPONSE_REGULATORY](#) Response regulatory domain [profile].

```
987 - 1085 RVLVVDDNPISRKVATGKLKMGVSeVEQCDSGKEALRLVTRGLtqreeggsvdklpFDY  
IFMDQQMPENDGYEATREIRkvekSYGVRTPIIAVGSHD-----
```

Graphical summary of hits (java applet)



98 hits with 12 PROSITE entries



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Sekundární databáze

- databáze funkčních nebo strukturálních *motivů* získaných srovnáváním primárních dat (*sekvencí*)
- PRINTS, <http://www.bioinf.man.ac.uk/dbbrowser/PRINTS/>



PRINTS is a compendium of protein **fingerprint**s. A fingerprint is a group of conserved motifs used to characterise a protein family; its diagnostic power is refined by iterative scanning of a SWISS-PROT/TrEMBL composite. Usually the motifs do not overlap, but are separated along a sequence, though they may be contiguous 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:

- [PRINT - Search PRINTS-S \(relational PRINTS\)](#)
- [prePRINTS - Search PRINTS' automatic supplement](#)
- [InterPro - Search the integrated InterPro family database](#)

Direct PRINTS access:

- [By accession number](#)
- [By PRINTS code](#)
- [By database code](#)
- [By text](#)
- [By sequence](#)
- [By title](#)
- [By number of motifs](#)
- [By author](#)
- [By query language](#)

PRINTS search:

- [Search PRINTS with NEW FingerPRINTScan](#)

- [FPScan](#)
- [GRAPHScan](#)

- [MUI Scan](#)

FingerPRINTScan binaries and source are available: [contact scordis@bioinf.man.ac.uk](mailto:contact_scordis@bioinf.man.ac.uk)



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Sekundární databáze

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

The screenshot shows the homepage of the German Biotechnology Network (GBF). On the left, there's a sidebar with links to "The GBF", "Research", "Service & Technology Transfer", and "News & Public Relations". Below that is a list of molecular biology topics: Molecular Biotechnology, Bioinformatics, The team, Publications, Projects, Databases, Tools, and Links. To the right, there's a grid of database logos and their descriptions:

Databases	Description
	TRANSFAC Saccharomyces Module 0.1
	The S/MAR transaction database (Release 2.1) Scaffold/Matrix Attached Region transaction Database
	The TRANSFAC Database (Release 5.0)
	This database is no longer available on this server. You can access it on http://www.gene-regulation.de
	The database of physiological systems, organs and cell types



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Strukturální databáze

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

[DEPOSIT data](#)
[DOWNLOAD files](#)
[browse LINKS](#)
[BETA TEST new features](#)
[BETA mmCIF files](#)

Current Holdings
19623 Structures
Last Update: 30-Dec-2002
PDB Statistics

Molecule of the Month:
[Cytochrome c](#)

The Protein Data Bank (PDB) is operated by Rutgers, The State University of New Jersey; the San Diego Supercomputer Center at the University of California, San Diego; and the National Institute of Standards and Technology -- three members of the [Research Collaboratory for Structural Bioinformatics \(RCSB\)](#). The PDB is supported by funds from the [National Science Foundation](#), the [Department of Energy](#), and two units of the National Institutes of Health: the

PROTEIN DATA BANK

Welcome to the PDB, the single worldwide repository for the processing and distribution of 3-D biological macromolecular structure data.

[ABOUT PDB](#) | [DATA UNIFORMITY](#) | [RECENT FEATURES](#) | [USER GUIDES](#) |
[FILE FORMATS](#) | [EDUCATION](#) | [STRUCTURAL GENOMICS](#) | [PUBLICATIONS](#) |
[SOFTWARE](#)

Search the Archive ?

Enter a PDB ID or keyword [Query Tutorial](#)

Find a structure

query by PDB id only match exact word
 remove sequence homologues

[SearchLite](#) keyword search form with examples
[SearchFields](#) customizable search form
[Status Search](#) find entries awaiting release

News [Complete News Newsletter](#) [pdb4 Archive Subscribe](#)

23-Dec-2002 [Happy Holidays from the PDB!](#) The PDB staff wish to extend our best wishes to the community for a happy holiday season and a wonderful new year!

PDB Mirrors

^Please bookmark a mirror site.^

[San Diego Supercomputer Center](#)*
[Rutgers University](#)*
[National Institute of Standards and Technology](#)*
[Cambridge Crystallographic Data Centre, UK](#)
[National University of Singapore](#)
[Osaka University, Japan](#)
[Universidade Federal de Minas Gerais, Brazil](#)
[Max Delbrück Center for Molecular Medicine, Germany](#)

[OTHER SITES](#)



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Strukturální databáze

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

Structure Explorer - 1P5Y



Structure Explorer - 1P5Y

Title The Structures Of Host Range Controlling Regions Of The Capsids Of Canine and Feline Parvoviruses and Mutants
Classification Virus/Viral Protein
Compound Mol_Id: 1; Molecule: Coat Protein Vp2; Chain: A; Fragment: Sequence Database Residues 190-737; Engineered: Yes; Mutation: Yes
Exp. Method X-ray Diffraction

[View Structure](#)

[Summary Information](#)

[View Structure](#)

[Download/Display File](#)

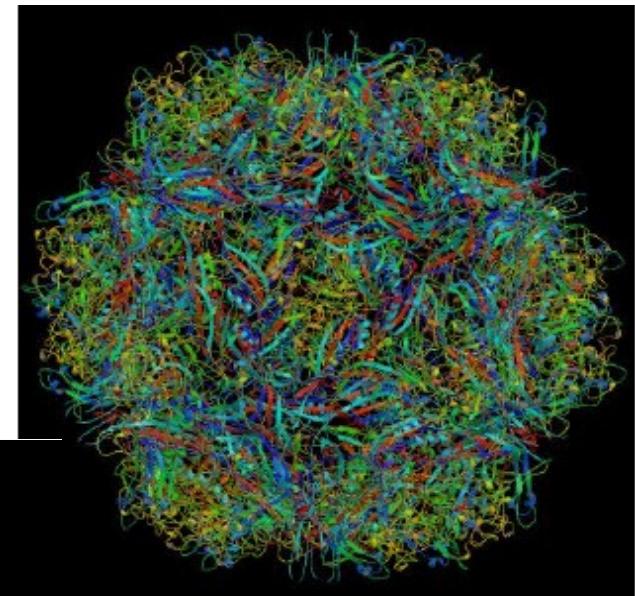
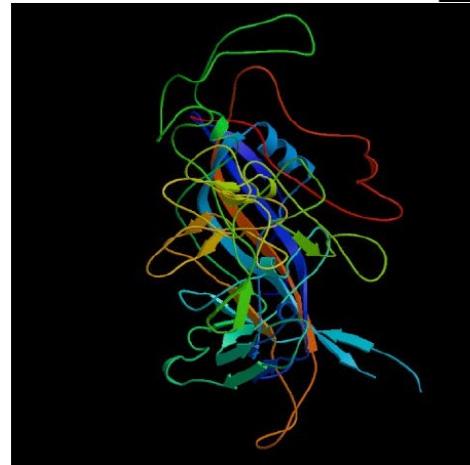
[Structural Neighbors](#)

[Geometry](#)

[Other Sources](#)

[Sequence Details](#)

[Explore](#)
[SearchLite](#) [SearchFields](#)



<http://www.rcsb.org/pdb/cgi/explore.cgi?job=graphics;pdBId=1P5Y;page=;pid=173561064349344&bio=1&opt=show&size=500>

12/29/2003



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

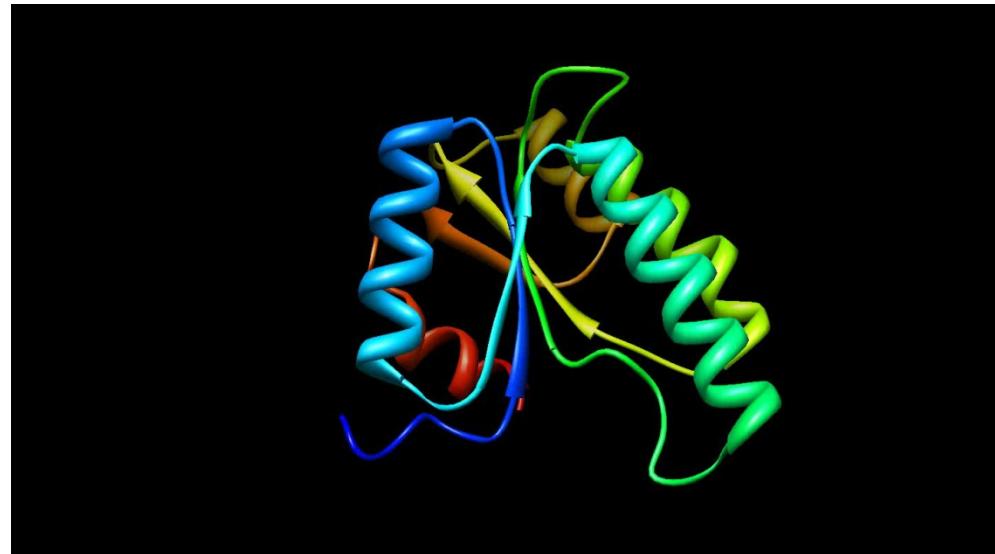


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

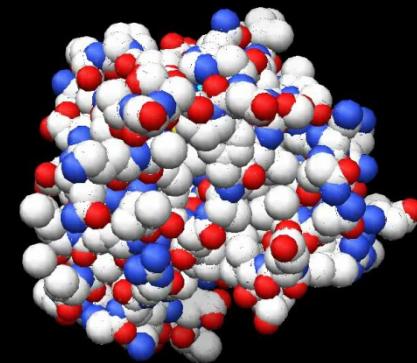
Tato prezentace je spolufinancována
Evropským sociálním fondem
a státním rozpočtem České republiky

Strukturální databáze

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



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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Osnova

- Schéma předmětu
- Definice
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze
 - GENOMOVÉ zdroje

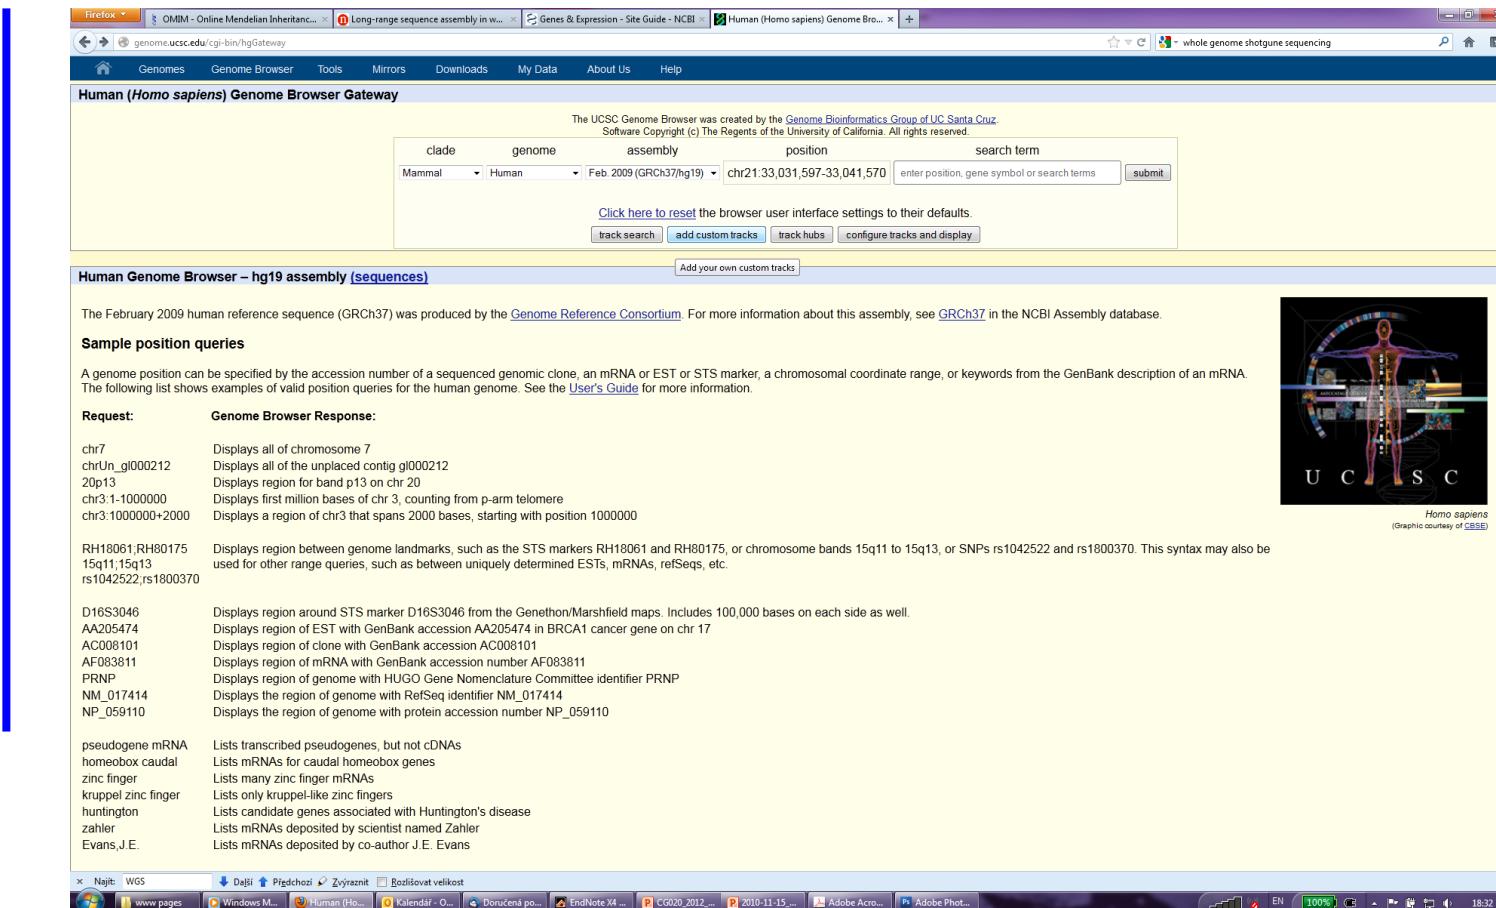


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomové zdroje

- 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

Genomové zdroje

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

UCSC Genes

HBB (uc001mas.1) at chr11:5246696-5248301 - Homo sapiens hemoglobin, beta (HBB), mRNA.
HBF1 (uc001maf.1) at chr11:5254059-5255059 - Homo sapiens hemoglobin, delta (HBD), mRNA.
HBE1 (uc001mal.1) at chr11:5289580-5291386 - Homo sapiens hemoglobin, epsilon 1 (HBE1), mRNA.
HBE1 (uc001mam.1) at chr11:5289580-5526882 - Homo sapiens hemoglobin, epsilon 1 (HBE1), mRNA.
SATB1 (uc003chb.3) at chr3:18389139-18466629 - Homo sapiens SATB homeobox 1 (SATB1), transcript variant 1, mRNA.
SATB1 (uc003chb.3) at chr3:18389139-184680265 - Homo sapiens SATB homeobox 1 (SATB1), transcript variant 2, mRNA.
KLF11 (uc002lraf.1) at chr2:10183682-210194963 - Homo sapiens Kruppel-like factor 11 (KLF11), transcript variant 1, mRNA.
KLF11 (uc001ytc.2) at chr2:10184372-210194963 - Homo sapiens Kruppel-like factor 11 (KLF11), transcript variant 3, mRNA.
KLF11 (uc021vdq.1) at chr2:10183956-210194963 - Homo sapiens Kruppel-like factor 11 (KLF11), transcript variant 2, mRNA.
GATA1 (uc0004dkq.4) at chrX:48644982-48652717 - Homo sapiens GATA binding protein 1 (globin transcription factor 1) (GATA1), mRNA.
HAFY (uc002kcm.3) at chr17:73976142-73983534 - Homo sapiens v-maf musculoaponeurotic fibroblastoma oncogene homolog G (avian) (HAFG), transcript variant 2, mRNA.
HAG1 (uc002kcm.3) at chr17:73976142-73983534 - Homo sapiens v-maf musculoaponeurotic fibroblastoma oncogene homolog G (avian) (HAFG), transcript variant 1, mRNA.
HBG1 (uc001meab.1) at chr11:5269502-5271087 - Homo sapiens hemoglobin, gamma A (HBG1), mRNA.
NFE2 (uc001efq.3) at chr12:54605896-54609544 - Homo sapiens nuclear factor (erythroid-derived 2), 45kDa (NFE2), transcript variant 1, mRNA.
NFE2 (uc001efr.4) at chr12:54605896-54694791 - Homo sapiens nuclear factor (erythroid-derived 2), 45kDa (NFE2), transcript variant 2, mRNA.
NFE2 (uc009znk.3) at chr12:54605896-54694542 - Homo sapiens nuclear factor (erythroid-derived 2), 45kDa (NFE2), transcript variant 1, mRNA.
NFE2 (uc009znk.3) at chr12:54605896-54694542 - Homo sapiens nuclear factor (erythroid-derived 2), 45kDa (NFE2), transcript variant 1, mRNA.
HBG2 (uc001meag.1) at chr11:5274421-5276395 - Homo sapiens hemoglobin, gamma G (HBG2), mRNA.
HBG1 (uc001mal.1) at chr11:5269502-5276395 - Homo sapiens hemoglobin, gamma A (HBG1), mRNA.
HBA2 (uc002cfv.4) at chr16:2220846-223709 - Homo sapiens hemoglobin, alpha 2 (HBA2), mRNA.
HBA1 (uc002cfv.1) at chr16:226679-227520 - Homo sapiens hemoglobin, alpha 1 (HBA1), mRNA.

Non-Human RefSeq Genes

LOC100174873 at chr11:5255223-5275746 - (NM_001267638) beta globin
LOC100174873 at chr11:5247810-5270822 - (NM_001267638) beta globin
LOC100190585 at chr11:5270600-5270823 - (NM_001245467) putative beta-globin
LOC100190585 at chr11:5247806-5248237 - (NM_001245467) putative beta-globin
LOC100190585 at chr11:5248237-5250722 - (NM_001245467) putative beta-globin
LOC100135792 at chr11:5275323-5275746 - (NM_001124188) embryonic beta-type globin2
LOC100135791 at chr11:5269502-5276398 - (NM_001124187) embryonic beta-type globin
LOC100135791 at chr11:5270687-5270822 - (NM_001124187) embryonic beta-type globin
LOC573653 at chr11:5289744-5290908 - (NM_001097585) embryonic 1 beta-globin family member

Human Aligned mRNA Search Results

A18171 - Beta globin gene seq ID No.:
AF494114 - Homo sapiens beta globin chain variant (HBB) mRNA, complete cds.
M25079 - Human sickle cell beta-globin mRNA, complete cds.
M20250 - Human beta-globin gene, intron A.
V00500 - Human messenger RNA for beta-globin.
M14574 - Human beta-globin gene mRNA precursor, 5' end.
M14228 - Human beta-globin mRNA, 3' end.
AY195961 - Homo sapiens beta globin locus control region sequence.

Human Unaligned mRNA Search Results

S77349 - delta-globin...beta-globin (deletion junction) [human, African-American child with beta-thalassemia intermedia, mRNA Partial Mutant, 3 genes, 51 nt].

Non-Human Aligned mRNA Search Results

M19548 - Rana catesbeiana, beta-globin 4B
HQ843793 - Platichthys flesus, beta 2-globin
HQ843794 - Platichthys flesus, beta 1-globin
AY883038 - Trematomus bernardi, beta 1/2 globin
AY775302 - Gallus gallus, beta globin protein 1
AY329629 - Danio rerio, embryonic globin beta e2



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

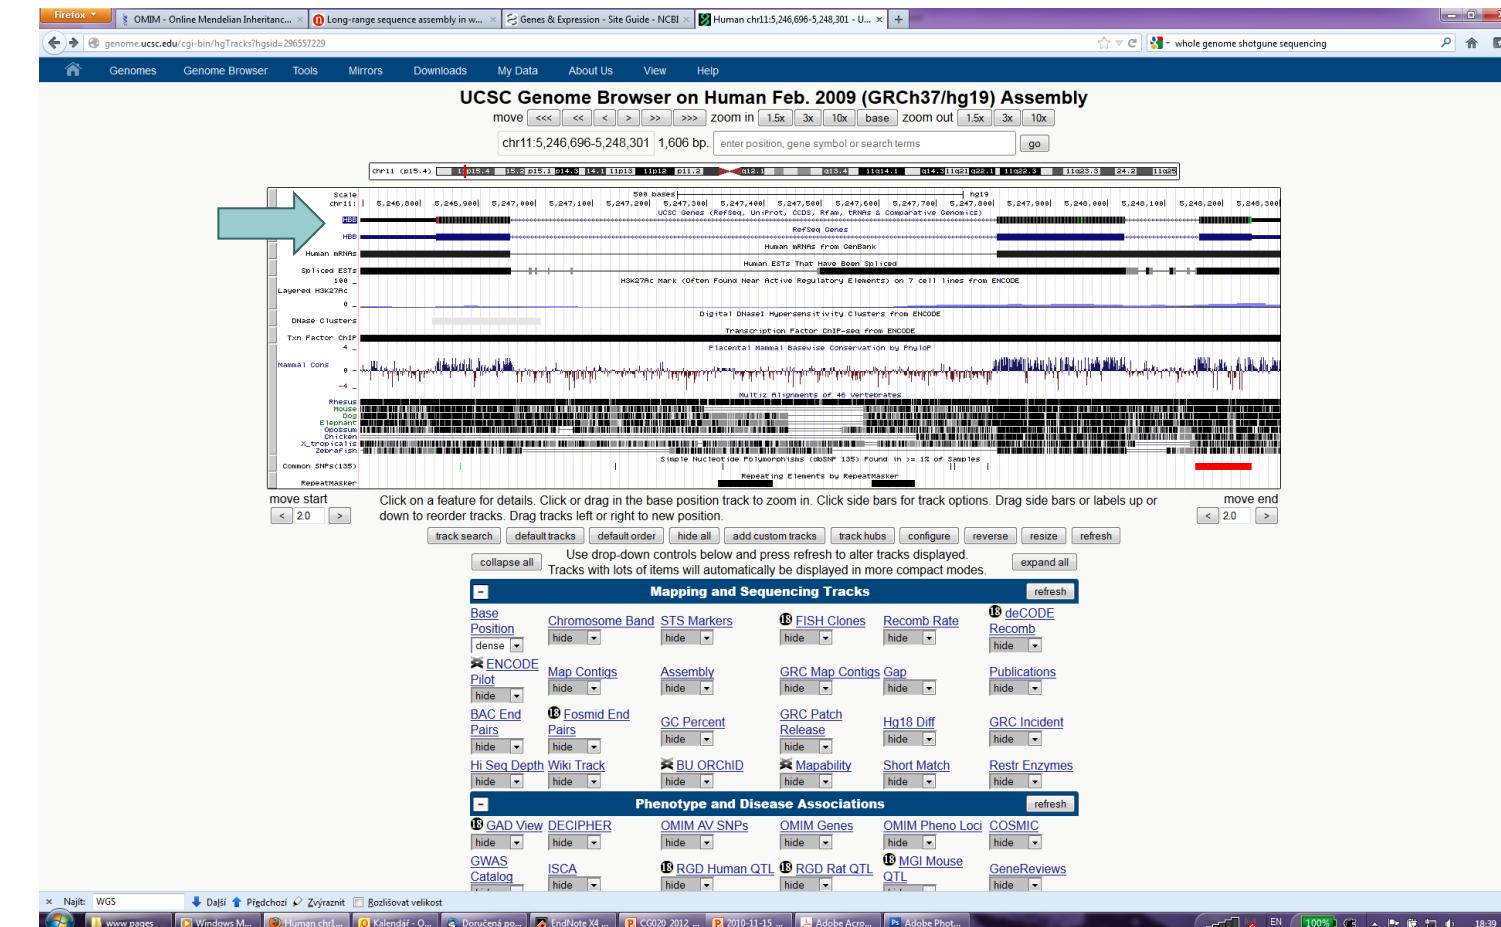


INVESTICE DO ROZVOJE Vzdělávání

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

Genomové zdroje

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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

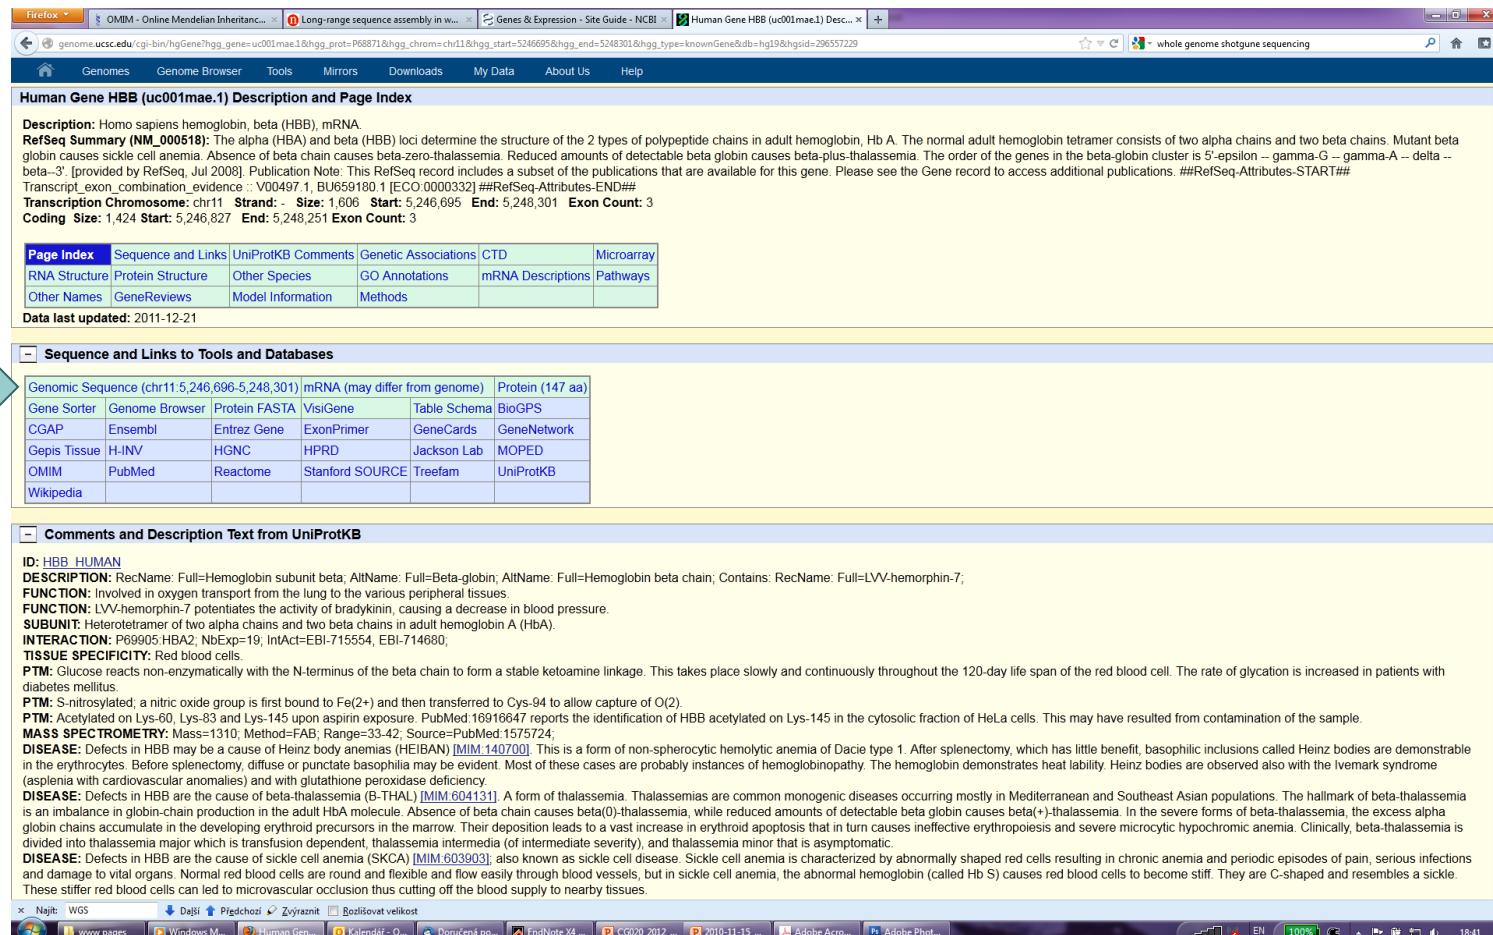


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomové zdroje

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



The screenshot shows the Human Genome Browser interface for the HBB gene. The main content area displays the gene's description, RefSeq summary, transcription details, and a table of links to various databases like UniProtKB, GenBank, and Ensembl. Below this is a section titled 'Comments and Description Text from UniProtKB' containing detailed biological information about the HBB protein. The browser's navigation bar and status bar are visible at the top and bottom respectively.

Description: Homo sapiens hemoglobin, beta (HBB) mRNA.
RefSeq Summary (NM_000518): The alpha (HBA) and beta (HBB) loci determine the structure of the 2 types of polypeptide chains in adult hemoglobin, Hb A. The normal adult hemoglobin tetramer consists of two alpha chains and two beta chains. Mutant beta globin causes sickle cell anemia. Absence of beta chain causes beta-zero-thalassemia. Reduced amounts of detectable beta globin causes beta-plus-thalassemia. The order of the genes in the beta-globin cluster is 5'-epsilon - gamma-G - gamma-A -- delta -- beta-3'. [provided by RefSeq, Jul 2008] Publication Note: This RefSeq record includes a subset of the publications that are available for this gene. Please see the Gene record to access additional publications. ##RefSeq-Attributes-START##
Transcription_Exon_combination_evidence :: V00497.1, BU659180.1 | ECO:0000332##RefSeq-Attributes-END##
Transcription_Chromosome: chr11 Strand: - Size: 1,606 Start: 5,246,695 End: 5,248,301 Exon Count: 3
Coding Size: 1,424 Start: 5,246,827 End: 5,248,251 Exon Count: 3
Data last updated: 2011-12-21

[-] Sequence and Links to Tools and Databases

Genomic Sequence (chr11:5,246,696-5,248,301)	mRNA (may differ from genome)	Protein (147 aa)
Gene Sorter	Genome Browser	Protein FASTA
CGAP	Ensembl	Entrez Gene
Geps Tissue	H-INV	HGNC
OMIM	PubMed	Reactome
Wikipedia	Stanford SOURCE	Treemap
UniProtKB		

[-] Comments and Description Text from UniProtKB

ID: HBB_HUMAN
DESCRIPTION: RecName: Full=Hemoglobin subunit beta; AltName: Full=Beta-globin; AltName: Full=Hemoglobin beta chain; Contains: RecName: Full=LVV-hemorphin-7;
FUNCTION: Involved in oxygen transport from the lung to the various peripheral tissues
SUBUNIT: Heterotetramer of two alpha chains and two beta chains in adult hemoglobin A (HbA).
INTERACTION: P69905 HBA2; NbExp=19; IntAct:EBI-715554; EBI-714680;
TISSUE SPECIFICITY: Red blood cells.
PTM: Glucose reacts non-enzymatically with the N-terminus of the beta chain to form a stable ketoamine linkage. This takes place slowly and continuously throughout the 120-day life span of the red blood cell. The rate of glycation is increased in patients with diabetes mellitus.
PTM: S-nitrosylated; a nitric oxide group is first bound to Fe(2+) and then transferred to Cys-94 to allow capture of O(2).
PTM: Acetylated on Lys-60, Lys-83 and Lys-145 upon aspirin exposure. PubMed:16916647 reports the identification of HBB acetylated on Lys-145 in the cytosolic fraction of HeLa cells. This may have resulted from contamination of the sample.
MASS SPECTROMETRY: Mass=1310; Method=FAB, Range=33-42. Source=PubMed:1575724.
DISEASE: Defects in HBB may be a cause of Heinz body anemias (HEIBAN) [MIM:140700]. This is a form of non-spherocytic hemolytic anemia of Dacie type 1. After splenectomy, which has little benefit, basophilic inclusions called Heinz bodies are demonstrable in the erythrocytes. Before splenectomy, diffuse or punctate basophilia may be evident. Most of these cases are probably instances of hemoglobinopathy. The hemoglobin demonstrates heat lability. Heinz bodies are observed also with the Ivemark syndrome (asplenia with cardiovascular anomalies) and with glutathione peroxidase deficiency.
DISEASE: Defects in HBB are the cause of beta-thalassemia (B-THAL) [MIM:604131]. A form of thalassemia. Thalassemias are common monogenic diseases occurring mostly in Mediterranean and Southeast Asian populations. The hallmark of beta-thalassemia is an imbalance in globin-chain production in the adult HbA molecule. Absence of beta chain causes beta(0)-thalassemia, while reduced amounts of detectable beta globin causes beta(+)-thalassemia. In the severe forms of beta-thalassemia, the excess alpha globin chains accumulate in the developing erythroid precursors in the marrow. Their deposition leads to a vast increase in erythroid apoptosis that in turn causes ineffective erythropoiesis and severe microcytic hypochromic anemia. Clinically, beta-thalassemia is divided into thalassemia major (which is transfusion dependent), thalassemia intermedia (of intermediate severity), and thalassemia minor that is asymptomatic.
DISEASE: Defects in HBB are the cause of sickle cell anemia (SKCA) [MIM:603903]; also known as sickle cell disease. Sickling cell anemia is characterized by abnormally shaped red cells resulting in chronic anemia and periodic episodes of pain, serious infections and damage to vital organs. Normal red blood cells are round and flexible and flow easily through blood vessels, but in sickle cell anemia, the abnormal hemoglobin (called Hb S) causes red blood cells to become stiff. They are C-shaped and resembles a sickle. These stiffer red blood cells can led to microvascular occlusion thus cutting off the blood supply to nearby tissues.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomové zdroje

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

The screenshot shows a Firefox browser window with several tabs open. The active tab is titled 'Genomic Sequence Near Gene'. The page content includes:

- Get Genomic Sequence Near Gene**
- Note: if you would prefer to get DNA for more than one feature of this track at a time, try the [Table Browser](#) using the output format sequence.
- Sequence Retrieval Region Options:**
 - Promoter/Upstream by 1000 bases
 - 5' UTR Exons
 - CDS Exons
 - 3' UTR Exons
 - Introns
 - Downstream by 1000 bases
 - One FASTA record per gene.
 - One FASTA record per region (exon, intron, etc.) with 0 extra bases upstream (5') and 0 extra downstream (3')
 - Split UTR and CDS parts of an exon into separate FASTA records
- Note: if a feature is close to the beginning or end of a chromosome and upstream/downstream bases are added, they may be truncated in order to avoid extending past the edge of the chromosome.
- Sequence Formatting Options:**
 - Exons in upper case, everything else in lower case.
 - CDS in upper case, UTR in lower case.
 - All upper case.
 - All lower case.
 - Mask repeats: to lower case to N
-



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

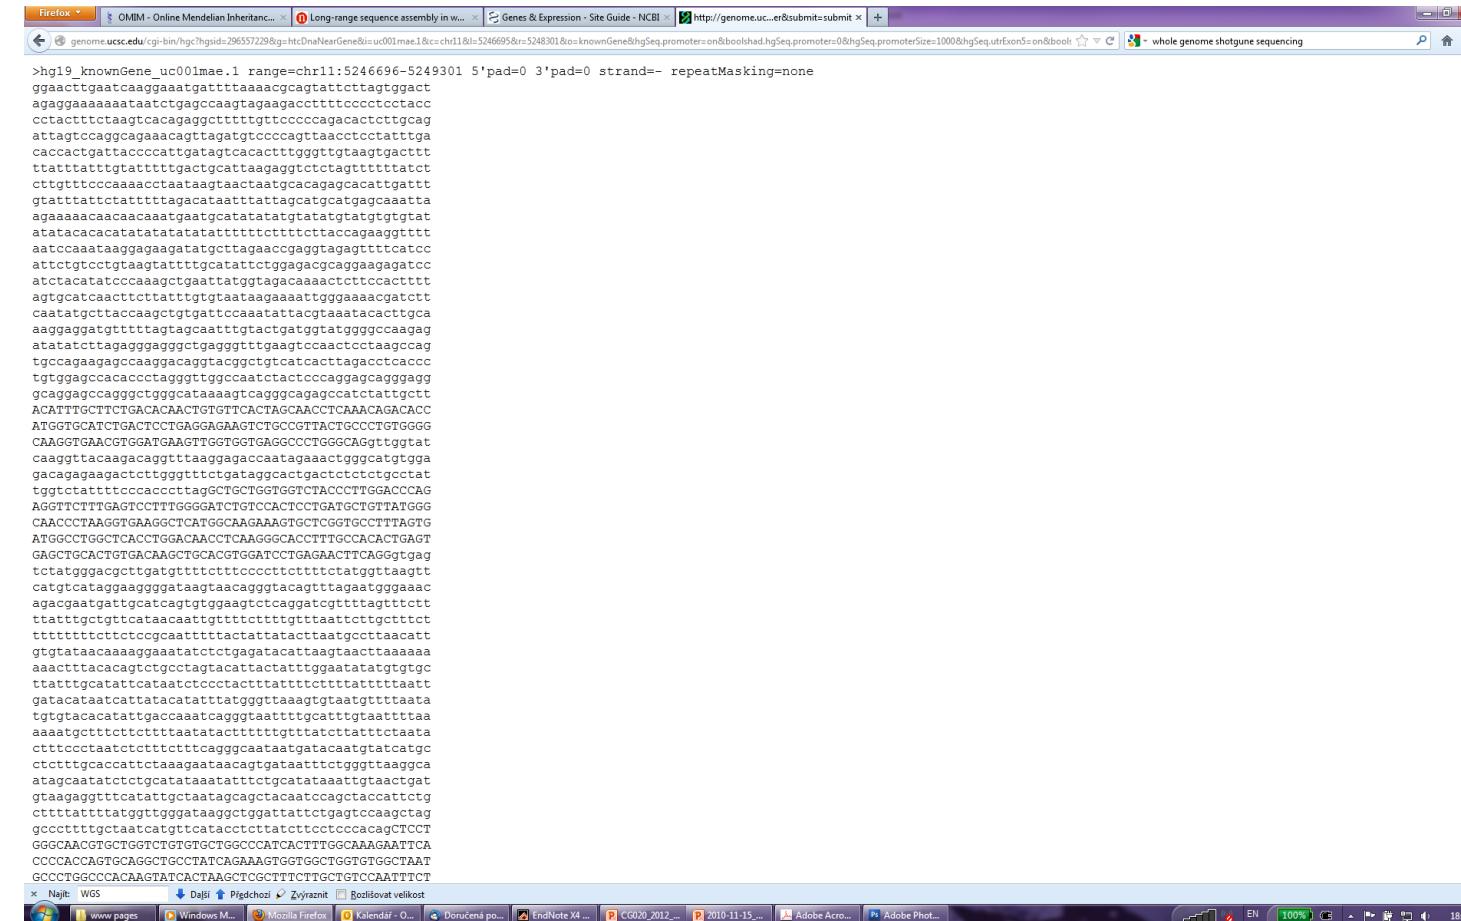


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomové zdroje

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



The screenshot shows a browser window with the URL <http://genome.ucsc.edu/cgi-bin/hgGateway>. The main content area displays a long DNA sequence for hg19 knownGene uc001mae.1, specifically the range chr11:5246696-5249301. The sequence is presented in a monospaced font, showing various nucleotide bases (A, T, C, G) and some gaps represented by dashes. The browser interface includes a navigation bar at the top with tabs for OMIM, Online Mendelian Inheritance in Man, Long-range sequence assembly in whole genome shotgun sequencing, Genes & Expression - Site Guide - NCBI, and the current hgGateway page. Below the sequence, there are several toolbars and status bars typical of a web browser.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomové zdroje

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

The screenshot shows the TAIR homepage in a Firefox browser window. The top navigation bar includes links for Home, Help, Contact, About Us, Login/Register, Search, Browse, Tools, Portals, Download, Submit, News, and ABRC Stocks. The main content area features a section titled "The Arabidopsis Information Resource" with a brief description of the database's purpose and funding. It also highlights the "New Protein Chip and Cell Cultures at ABRC" and "GO Annotations At TAIR". The sidebar contains "Breaking News" with links to news feeds, Twitter, and Facebook, as well as a "2012 MASC Report Now Available" notice. A central graphic illustrates the submission process, showing a laptop with a form and a flower icon.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

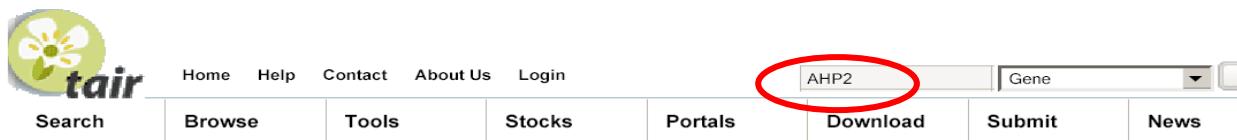


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Genomové zdroje

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



The screenshot shows the TAIR homepage. At the top, there is a navigation bar with links for Home, Help, Contact, About Us, Login, and a dropdown menu currently set to "Gene". Below the navigation bar is a search bar with the placeholder "Search" and a dropdown menu set to "Gene". The main content area features a logo for "tair" with a stylized flower icon, followed by the title "The Arabidopsis Information Resource". A detailed description of TAIR's mission and data content follows. Below this, a section titled "The NEW arabidopsis.org" discusses recent changes to the website's structure. To the right, there are several news and information boxes: "Breaking News" (Data Updates Suspended), "New Phenotype Search Option", and "ASPB Presentations". At the bottom, a smaller screenshot shows a dropdown menu for the "Portals" link, listing options like "Portals Overview", "Clones/DNA Resources", "Education and Outreach", and "ASPB Presentations".



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Osnova

- Schéma přednášky
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze
 - GENOMOVÉ zdroje
- Analytické nástroje
 - Vyhledávání homologií

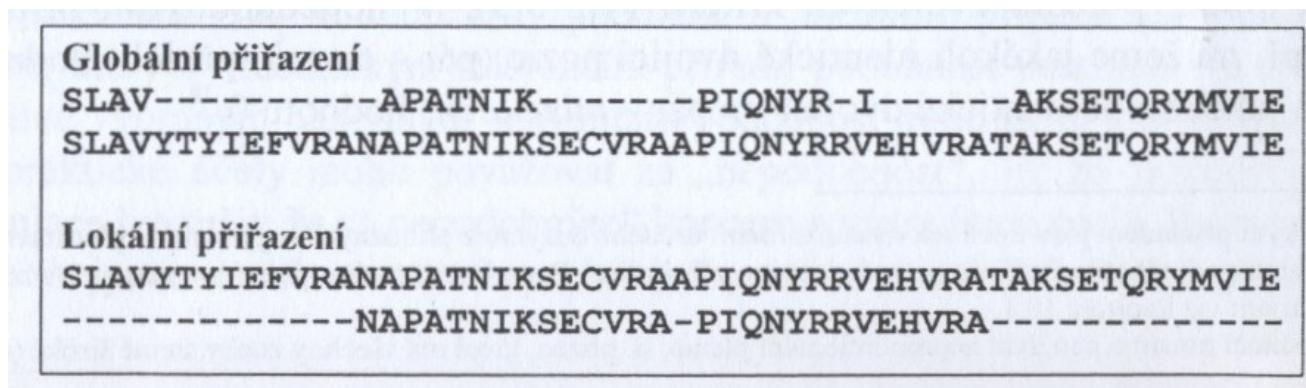


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

□ Globální vs. lokální přiřazení



Cvrčková, Úvod do praktické bioinformatiky

- globální přiřazení pouze u sekvencí, které jsou si podobné (za cenu vnášení mezer do jedné nebo obou sekvencí)
- globální přiřazení se používá především v případě mnohačetného přiřazování (CLUSTALW, viz dále)
- lokální přiřazení umožní identifikaci a srovnání i v případě porovnávání pouze **úseků sekvencí** s významnou mírou podobnosti, např. i při záměně pořadí proteinových domén během evoluce

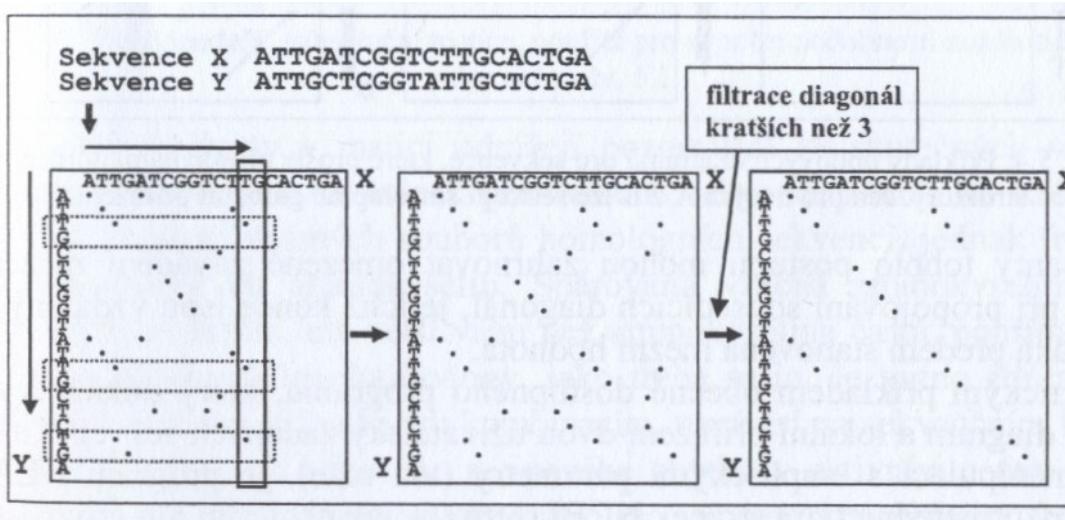


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

- Volba správného typu přiřazení pomocí bodového diagramu (dotplot)



Cvrčková, Úvod do praktické bioinformatiky

- vynesení sekvencí proti sobě
- identifikace shody v okně o dané velikosti (např. 2 bp)
- „odfiltrování“ diagonál o délce menší než je mezní hodnota (threshold)

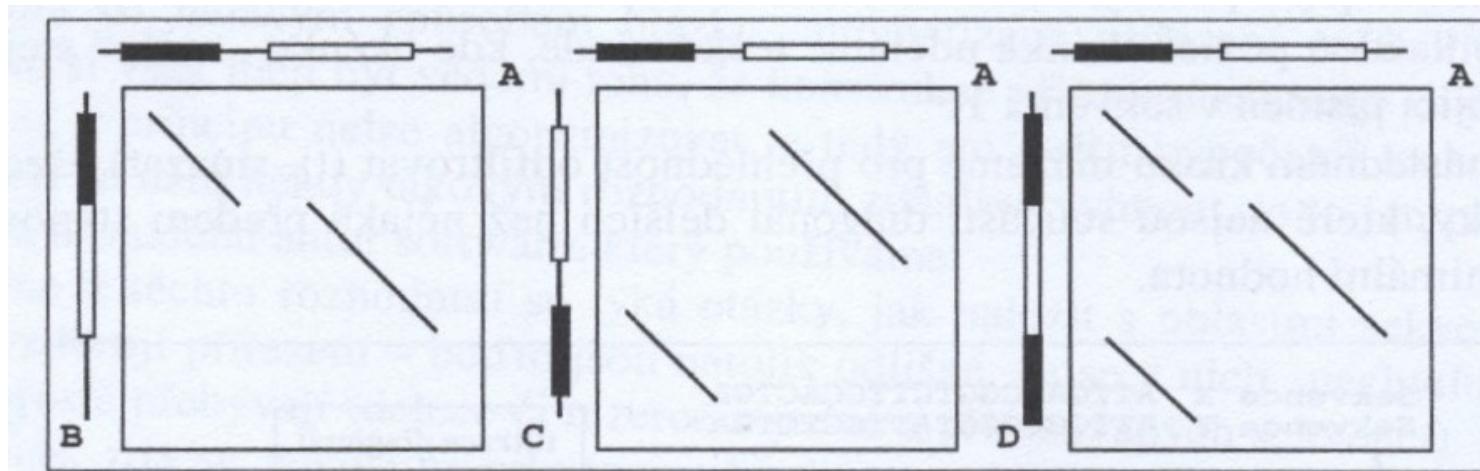


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

- příklady srovnání sekvencí pomocí bodového diagramu



Cvrčková, Úvod do praktické bioinformatiky

- globálně lze srovnávat pouze sekvence A, B
- ostatní sekvence prošly během evoluce záměnou domén a je nutné je porovnávat lokálně
- bodový diagram lze získat pomocí srovnávání programem BLAST2 (viz dále)

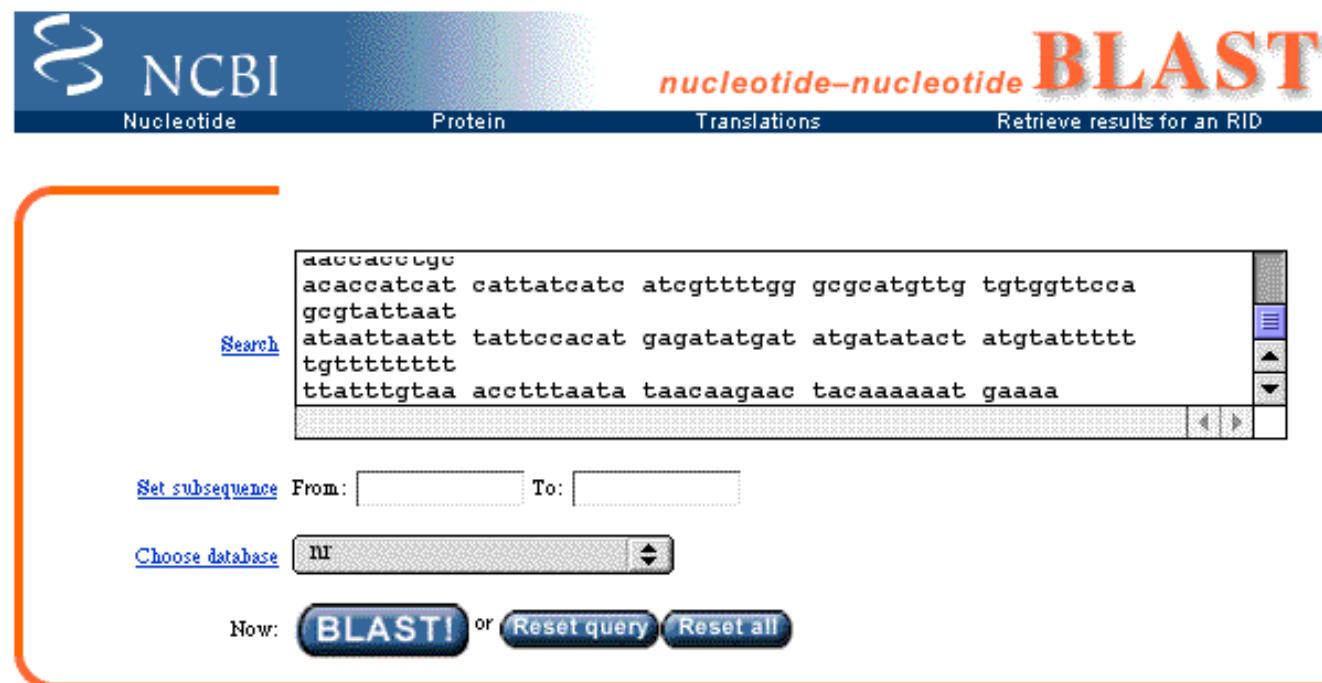


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Basic Local Alignment Search Tool

- Velikost vyhledávacího slova (word size): 10-11 bp, resp. 2-3 aa
 - Primární podobnosti (seed matches)
 - Rozšiřování oblasti homologie doprava i doleva
- Hodnocení homologie pomocí matic PAM (Point Accepted Mutation) nebo BLOSUM (BLOcks Substitution Matrix)
- Zobrazení výsledků

	A	T	G	C
A	1	0	0	0
T	0	1	0	0
G	0	0	1	0
C	0	0	0	1

Cvrčková, Úvod do praktické bioinformatiky

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

ÁVÁNÍ

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



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



BLAST

Basic Local Alignment Search Tool



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Primární databáze

The screenshot shows a genomic browser interface. At the top, a navigation bar includes links for 'Home - BioProject - NCBI' and 'virA two-component VirA-like sensor...'. The main area displays a genomic track for NC_002377.1, spanning from 145,400 to 147,600. A specific gene, NP_059797.1, is highlighted with a red box. A tooltip provides detailed information about the gene:

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](#)

A blue arrow points from the 'Bibliography' section below the tooltip to the 'Related articles in PubMed' section at the bottom.

Bibliography

Related articles in PubMed



INVESTICE DO ROZVOJE Vzdělávání

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

BLAST

Basic Local Alignment Search Tool

The screenshot shows a Firefox browser window displaying the BLINK precomputed BLAST results for the query protein gil16119781. The results indicate 147086 hits in 146754 proteins across 6309 species, filtered with a minimum score of 100. The top navigation bar includes links for Home, Taxonomy Report, Multiple Alignment, Blast, and Help, along with a My NCBI sign-in and register link. Below the navigation, a summary table shows the number of hits for various taxonomic groups: Archaea (1203), Bacteria (138285), Metazoa (13), Fungi (1349), Plants (554), Viruses (6), and The Others (5676). A 'Choose Display Options' button is available. The main results section displays a chart of hits (833 aa) and a table of top hits:

SCORE	ACCESSION	Length	Protein Description
4166	AAK90927	833	two component sensor kinase [Agrobacterium tumefaciens str. C58]
4166	P18540	833	RecName: Full=Wide host range virA protein; Short=WHR virA
4166	AAA79282	833	virA [Plasmid pTiC58]
4159	NP_053380	833	hypothetical protein pTi-SAKURA_p142 [Agrobacterium tumefaciens]
4159	BAA87765	833	tiorf140 [Agrobacterium tumefaciens]
4153	AAA91590	833	virA [Plasmid Ti]
4153	g1 737127	833	virA protein
4153	CAA34777	833	91.3 kDa protein [Agrobacterium tumefaciens]
3800	CAA35780	829	virA [Agrobacterium rhizogenes]
3718	g1 227240	869	virA gene
3148	AAA88643	829	virA [Plasmid Ti]



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specializované verze

- V současnosti existuje celá řad specializovaných verzí programu BLAST
 - vyhledávání podle zdroje (organismu) sekvencí, např. známých genomů mikroorganismů
 - **BLASTP**
 - vyhledávání podobnosti k proteinu v databázi proteinových sekvencí
 - **BLASTN**
 - vyhledávání podobnosti k nukleotidové sekvenci v databázi nukleotidových sekvencí
 - další varianty jako např. MEGABLAST pro identifikaci totožných nebo velice podobných sekvencí (vyhledává dlouhé podobné úseky nukl. sekvencí)
 - **BLASTX**
 - vyhledávání podobnosti k proteinu v databázi nukleotidových sekvencí přeložených do sekvence aa



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specializované verze

- V současnosti existuje celá řad specializovaných verzí programu BLAST
 - **TBLASTN**
 - vyhledávání k sekvenci nukleotidů přeložené do sekvence aa v databázi proteinů
 - **TBLASTX**
 - vyhledávání k sekvenci nukleotidů přeložené do sekvence aa v databázi nukleotidových sekencí přeložených do sekvence aa



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specializované verze

- V současnosti existuje celá řad specializovaných verzí programu BLAST
 - **PSI-BLAST (Position-Specific Iterated Blast)**
 - Prvním krokem je standardní BLAST, při kterém PSI-BLAST identifikuje skupinu podobných sekvencí s E hodnotou lepší než minimální hodnota (standardně 0,005)
 - PSI-BLAST vytváří pro každé přiřazení tzv. PSSM (position specific substitution matrix)
 - PSSM matice zohledňuje výskyt jedné aminokyseliny ve stejné pozici se zvýšenou frekvencí u sekvencí identifikovaných jako podobné v prvním kole pomocí BLAST, což může znamenat funkční konzervovanost



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specializované verze

- V současnosti existuje celá řada specializovaných verzí programu BLAST
 - **PHI-BLAST (Pattern-Hit InitiatedBlast)**
 - Určen k identifikaci specifické sekvence, např. motivu (pattern) v sekvenci podobných proteinových sekvencí
 - Sekvenci motivu je třeba vložit pomocí speciálního syntaxu
 - [LVIMF] znamená buď Leu, Val, Ile, Met nebo Phe
 - - je oddělovník (neznamená nic)
 - x(5) znamená 5 jakýchkoliv aminokyselin
 - x(3, 5) znamená 3 až 5 jakýchkoliv aminokyselin



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

BLAST

Specializované verze

□ Příklad vyhledávání pomocí PHI-BLAST

```
>gi|4758958|ref|NP_004148.1| Human cAMP-dependent protein kinase  
MSHIQIPPGLELLQGYTVEVLRQQPPDLVEFAVEYFTRLREARAPASVLPAATPRQSLGHPPPEPGPDR  
VADAKGDSESEDEDLEVVPVPSRFNRRSVCAETYNPDEEEEDTDPRVIHPKTDEQRCRQLQEACKDILLF  
KNLDQEQLSQVLDAMFERIVKADEHVIDQGDDGDNFYVIERGTYDILVTKDNQTRSVGQYDNRGS  
TSEGSLWGLDRVTFRRRIIVKNNNAKKRKMFESFIESVPLLKSLEVSERMKIVDVIGEK  
IYKDGERIITQGEKADSFYIIESGEVSILIRSRTKSNDGGNQEVEIARCHKGQYFGELALVTNKPRAAS  
AYAVGDVKCLVMDVQAFLERLLGPCMDIMKRNIISHYEEQLVKMFGSSVDLGNLGQ  
[LIVMF] -G-E-x- [GAS] - [LIVM] -x(5,11)-R- [STAQ] -A-x- [LIVMA] -x- [STACV] .
```



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Osnova

- Schéma přednášky
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze
 - GENOMOVÉ zdroje
- Analytické nástroje
 - Vyhledávání homologií
 - Vyhledávání sekvenčních motivů, otevřených čtecích rámců, restrikčních míst....

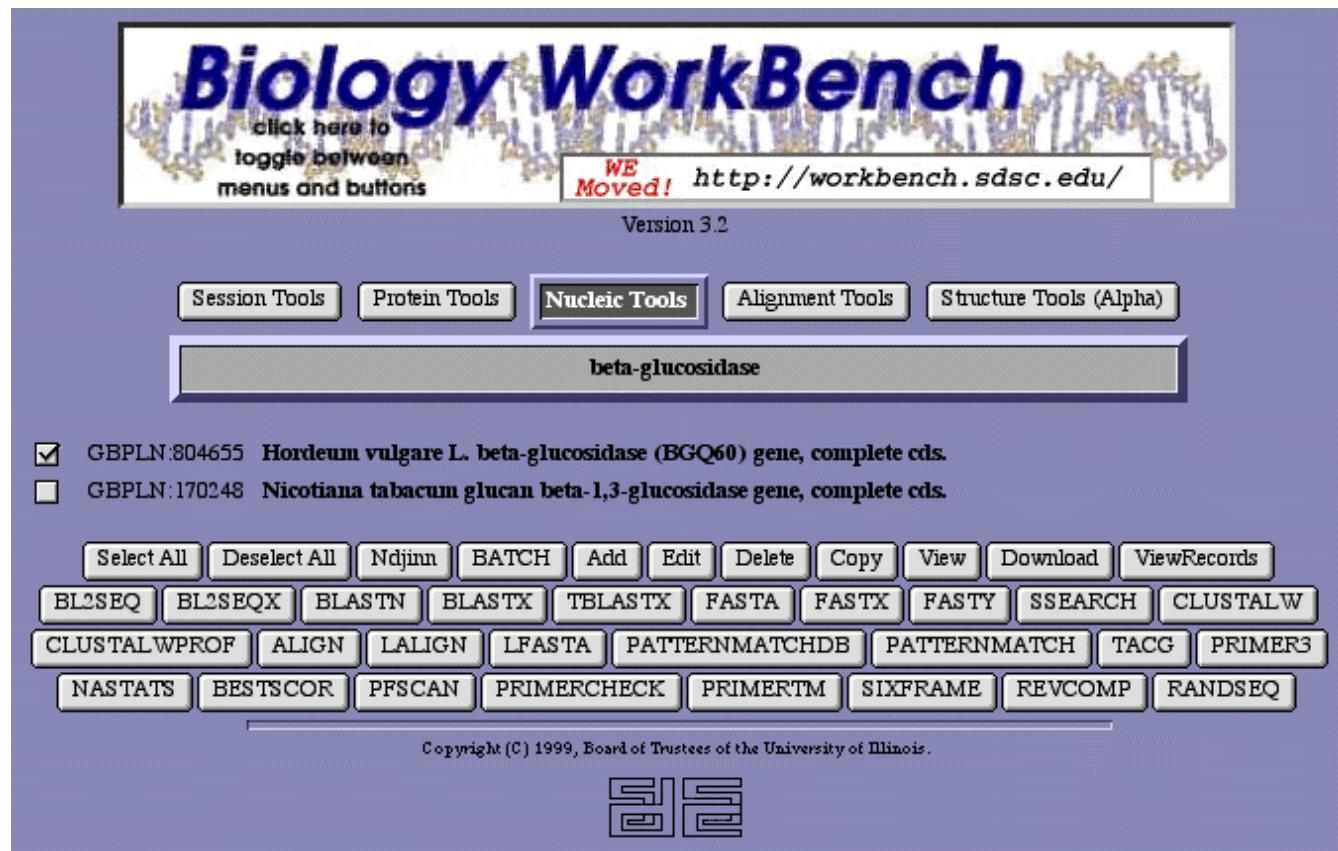


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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

View
View Nucleic Sequence(s)

Format Fasta Case Upper Change Format

[Download/view all sequences in text format](#)

[NEXT] [BOTTOM]

Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds.
GBPLN:170248, 4699 bp

```
>170248
GAGCTCCCTGGGGCAAGGGCAAAACTTTTGCTAAATGGAAAAATTATACCAAGTGTGTAATA
GTTACTCAATTGAAATAACAAAGGGCAAAATTGACTATTGCCCCTTATATCTTTGGTCACAAAAAC
ATAAAATATCCCATCGAAATTCCAATGGICCATTATCGGCCAGTAGCCTTCCTTAATTATAGTTAGTT
GACAAAACACTATCAAGATATCATTATTATAATAAACTTCAAGTCCATCACITTAGCTGCCCTCA
GTAGAGCCGCCAGTAAAATAAGACCGATCAAATAAAAGCCGCCATTAAAATAATGAATTAGGACTCTC
GATTGGCACGTAAGTCCAAAACTCTTCAAACTACTTTGCTGCAACTTGGGGCTGCTAGGTTCTGAGCTTC
CAGATATGGGATATTCTAAGTTATCTCCTAAAGAACATGAACTCCGGTTACTGATTCATGGCCCTTTCAGAG
CAGCAAATCAAAATTCTCTAAAGAACATGAACTCCGGTTACTGATTCATGGCCCTTTCAGAG
TCTGCATGCCATATTICACTAAGGGTCTGGTAAAGAAATAATAATTAATTCGGGATAGAATT
GAGATTGCAATTCTTCTGTTAAATTATAAGTATTAGCTAACTTCAAGAATAAAATTACACTAAATAG
TAAAATCAACTATCACATGTAGAAGGTGGAATGGAATAGCTAACTCCATAGCCACTCACATAGAATATCC
TTATTTATCTCACTATTACCAAATGATGGTTAGTCTTCATGAGAACTCCAGTATCTCAATAAAATGCA
GTAAGAAGTTAGAAAATTTCATTAATCAATTCTATATAATTAAAATATTAGATATGGAGCACTTAAG
ATACAATAAAAGATGTACCGTTATAATAAAAGATAAGAGTAAATAGGAAAAAAACGGTT
CGAGACACTTTATGGAAGGCGTGTCTCAAGTAGATCTCACTTCAATTGCTCTGGTGAATAGCAAAA
TGACATCTTACTCTTAAGATACAGCGAGCCACTCTACAACTCTCTATTTGATACAAATGAAAGTTTTA
GAGAACTTTCAAAATCTCAACTACTTTAAGGGATTCAAAATACGACCAATAATTACTTACTTAC
TTATAGTTAAATGATATGAATTTTATTAAATTGAAATTGAAATAATTAAATTACTTGTATTAAATATAA
```



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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

Regex pattern:

ctt.{1,32}ctt

0 sequences were searched

1 match was found

Matches are indicated in blue

```
> 170248
GAGCTCCCTTGGGGGGCAAGGGCAAAACTTTTTGCTAAATGGAAAAAATTATACCAAGTGTTTGTAAATA
GTTACTCAATTGAAATTAAACAAAGGGCAAATTGACTATTTCGCCCTTATATCTTTGGTCACAAAAAC
ATAAAAATATCCCATCGAAATCCAAATGGTCATTATCGCAAGTAGCTTTCTTTTAATTATAGTTAGTT
GACAAAACACTATCAAGATATCATTATTATAATAAACTICAAAGTCCATCATCTTAGCTGCCTCCTCA
GTAGAGCGCCAGTAAATAAGACCGATCAAAAGGCCCAITAAAATAATGAATTTTAGGACTCTC
GATTGGCACGTAAGTGCCAAACTCTTCCAATACTTTGCTGCAACTTGGGCTGCTAGGTTCTGACCTTC
CAGATATGGGATATTCTAACGTTATCTCTAAATTACATCTCAACTAATAATTAAAGAAATTAAACAGGTA
CAGCAAATCATAAAATTTCCTCTAAAGAACATGAATCCGGTACTGATTCAATTGGCTTTTCAGAG
TCTGCATGCCATATTCACTAAGGGCGTITGGTACAAGAAAATAATAAAATTTCGGGATAGAAATT
GAGATTGCAATTATCTGTGTTAAATTATAAGTAAATTAGCTAATTTCAGAATAAAATTTCACACTAAAATAG
TAAAATCAACTACATGCTAGTAGAAGGTGGAATGGCTAATCCCATGCCACTCACATAGAAATATCC
TTATTATCTCACTATTACCAAAATGATCGGGTAGTCCTCATGAGAAATCCAGTATCCCAATAAATGCA
GTAAGAAGTTAGAAAATTTCATTAAATCAATTCAATTAAATTAAATTAAAGGAAATTAGGATATGGAGCACCTAAG
ATACAATAAAAGATGTACCGTTAAATAATAAAAGATAAGATAGAGTTAAATAGGAAAAAAACGGTT
CGAGACACTCTTATGGAAGGCGTGTCTCAAAGTAGATTCTCAATTCTGCTCTGGTGCAATAGCAAAA
TGACACCTTACTCTTAAGATACAGCGAGCCACTCTACAACTTCTATTGTATACTCAATGAAAGTTTTA
GAGAACTTCAATCTCAACTACTTTAAGGAAATCAAAATGACCAATAATTAACTTACTTAC
TTATTAGTTAAATGATGATGAAATTATTAAATTGAAATTGAAAATTAAATTACTTGATTAAATATAAA
ACAATAGATATCGCTAAGTATTACACAAACATGGAGATACTACAGAAGATTAAATTATTGTAACGAT
GATTAAGCAGCTATTICATCTGGTTGTGCAAGGATGAAAGAAAGTAACTAGCTATAATTCTTTGTAAAGT
```



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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

Frame 1, 1 stop codon

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

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

Frame 2, 1 stop codon

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

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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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

— Linear Map of Sequence:

```
StyI          SspI
BsaJI
CviJI
AluI
SacI
EcoICRI
Bsp1286I
BsiHKAI
BanII BsII
\ \ \
SspI
1 gagctccctggggggcaaggcaaaaacttttgcataatggaaaaattataccaaagt 60
      ^ * ^ * ^ * ^ * ^ * ^ * ^ * ^ *
ctcgagggAACCCCCGTTCCCGTTTgaaaacgtttacctttataatatggttca
      ^ * ^ * ^ * ^ * ^ * ^ * ^ *
1 E L P W G A R A K L F A K W K N I I P S
2 S S L G G Q G Q N F L L N G K I L Y Q V
3 A P 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 K Q * I S F Y * V L

Tsp509I          Tsp509I
MaeIII Tsp509I MseI          ApoI
\ \ \
1 gttttaatagttaactcaattgaattaacaaaggcacaatttactatttgcctta 120
      ^ * ^ * ^ * ^ * ^ * ^ * ^ * ^ *
caaacattatcaatgagttaaacttaattgtttcccgTTTaaactgataaaacggaaat
      ^ * ^ * ^ * ^ * ^ * ^ * ^ *
1 V C N S Y S I * 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 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 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
```



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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

Selected Sequence(s)

- Lycopersicon esculentum beta-1,3-glucanase mRNA, complete cds.
- Capsicum annuum clone GC170 beta-1,3-glucanase-like protein gene.
- Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds.
- Nicotiana plumbaginifolia beta-(1,3)-glucanase gene for a vacuolar, *Hordeum vulgare* L. beta-glucosidase (BGQ60) gene, complete cds.

[Download a PostScript version of the output](#)

The screenshot shows a sequence alignment interface. At the top, it displays the selected sequences: Lycopersicon esculentum beta-1,3-glucanase mRNA, complete cds.; Capsicum annuum clone GC170 beta-1,3-glucanase-like protein gene; Nicotiana tabacum glucan beta-1,3-glucosidase gene, complete cds.; Nicotiana plumbaginifolia beta-(1,3)-glucanase gene for a vacuolar, Hordeum vulgare L. beta-glucosidase (BGQ60) gene, complete cds. Below this, there is a large table of sequence data with columns for position, sequence, and ID. The sequences are color-coded by nucleotide (A, T, C, G). The table is organized into several sections, each starting with a line number (e.g., 24, 1, 2430, 1743, 2620, 32, 1, 2438, 1803, 2680, 79, 1, 2484, 1863, 2740, 132, 45, 2540, 1919, 2800) followed by a sequence of nucleotides. The positions are indicated by numbers above the sequences (e.g., 2660, 2680, 2700, 2720, 2740, 2760, 2780, 2800). The IDs listed are 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655, 170381, 11321163, 170248, 19686, 804655.



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

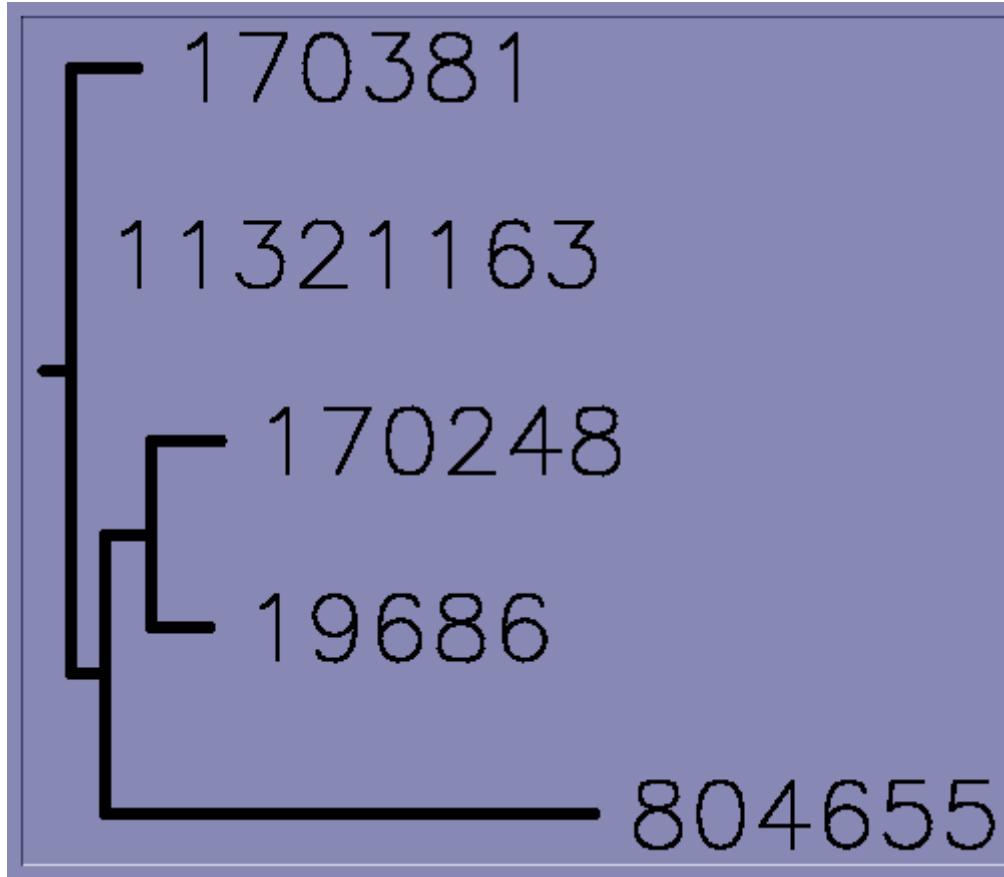


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Analytické nástroje

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

The screenshot shows the VPCR 2.0 web interface. At the top, there is a navigation bar with links for SEARCH, ABOUT, DOWNLOAD, and LINKS. Below the navigation bar, a note explains the search process: "VPCR 2.0 (WWW interface) - Please, enter nucleotide primer sequences ([IUB 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 states: "NOTE: Abilities of VPCR 2.0 are still limited by BLAST capabilities and settings, as well as inability of our current software to deal with more than a couple thousand matches per primer. For example, using primers shorter or roughly equal to our 11-base word size misses most 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 minute, 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 contains 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.

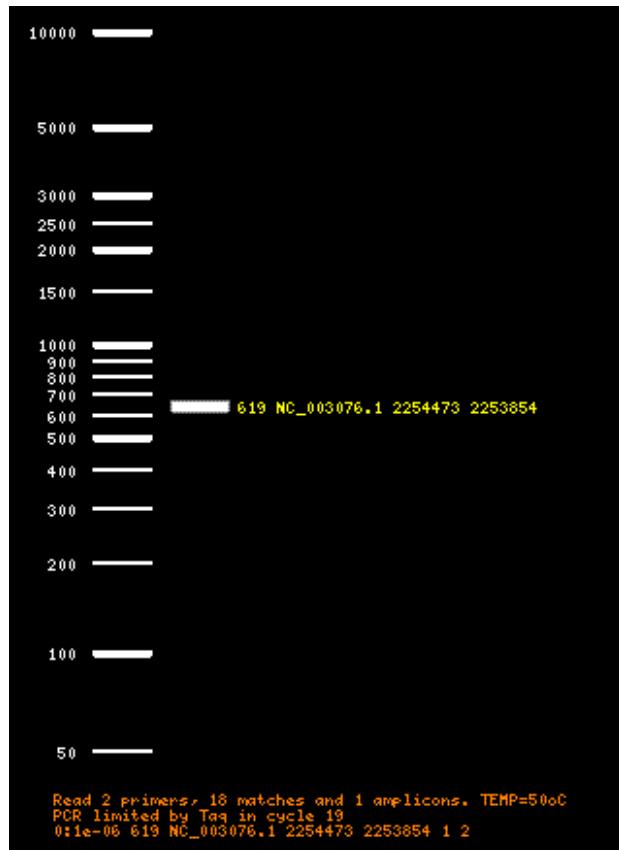


INVESTICE DO ROZVOJE Vzdělávání

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

Analytické nástroje

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



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Osnova

- Schéma přednášky
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze
 - GENOMOVÉ zdroje
- Analytické nástroje
 - Vyhledávání homologií
 - Vyhledávání sekvenčních motivů, otevřených čtecích rámců, restrikčních míst....
 - Další www genomové nástroje



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Další WWW zdroje

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

The screenshot shows a computer screen displaying the NCBI Gene page for the gene PHACTR4. The browser window has multiple tabs open, including 'Diploid Human Genome Browser' and 'PHACTR4 phosphatase and actin reg...'. The main content area shows the gene summary for PHACTR4, which encodes a protein of 442 amino acids. It includes sections for 'Summary', 'Genomic context' (showing the gene's location on Chromosome 1), and 'Genomic regions, transcripts, and products' (showing various transcript variants and their locations). A sidebar on the right provides links to other genomic resources like Ensembl, UniProt, and PDB. At the bottom, there are logos for the European Union, ESF, and the Ministry of Youth and Sports.

PHACTR4 phosphatase and actin regulator 4 [Homo sapiens] - Gene - NCBI - Mozilla Firefox

Soubor Úpravy Zobrazení Historie Záložky Nástroje Nápověda

JCVI Home Diploid Human Genome Browser | H... PHACTR4 phosphatase and actin reg... +

https://www.ncbi.nlm.nih.gov/sites/entrez?Db=Gene&Cmd>ShowDetailView&TermToSearch=65979

institute for genomic research

My NCBI Sign In

NCBI Resources How To Help

Gene Gene Limits Advanced Search

Display Settings: Full Report Send to:

PHACTR4 phosphatase and actin regulator 4 [Homo sapiens]

Gene ID: 65979, updated on 27-Aug-2011

Summary

Official Symbol: PHACTR4 provided by HGNC
Official Full Name: phosphatase and actin regulator 4 provided by HGNC
Primary source: HGNC:25793
Locus tag: RP11-442N24_A1
See related: Ensembl:ENSG00000204138; HPRD:07816; MIM:608726
Gene type: protein coding
RefSeq status: REVIEWED
Organism: Homo sapiens
Lineage: Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi; Mammalia; Eutheria; Euarchontoglires; Primates; Haplorrhini; Catarrhini; Hominoidea; Homo
Also known as: FLJ13171; MGC20618; MGC34186; DKFZp88L07205; RP11-442N24_A1
Summary: This gene encodes a member of the phosphatase and actin regulator (PHACTR) family. Other PHACTR family members have been shown to inhibit protein phosphatase 1 (PP1) activity, and the homolog of this gene in the mouse has been shown to interact with actin and PP1. Multiple transcript variants encoding different isoforms have been found for this gene. [provided by RefSeq, Jul 2008]

Genomic context

Location: 1p35.3
Sequence: Chromosome 1; NC_000001.10 (28896093..28826881)

Chromosome 1 - NC_000001.10

28585963 → MED16 → PHACTR4 → 28865788 ←

SESN2 → SNORD7SA → SNORD7SB → RNWI15A → SNHG63 → RCC1 →

Genomic regions, transcripts, and products

Genomic Sequence: NC_000001 chromosome 1 reference GRCh37.p5 Primary Assembly

Go to reference sequence details

Go to nucleotide Graphics FASTA GenBank

JE VZDĚLÁVÁNÍ

ce je spolufinancována

kým sociálním fondem

počtem České republiky

Další WWW zdroje

▪ Online Mendelian Inheritance in Man (OMIM)

The screenshot shows the homepage of the OMIM website. At the top, there is a navigation bar with links for Home, About, Statistics, Downloads/API, Help, External Links, Terms of Use, and Contact Us. Below the navigation bar, it says "Mirror sites: us-east.omim.org, europe.omim.org". The main title "OMIM®" is prominently displayed, followed by the subtitle "Online Mendelian Inheritance in Man®" and the description "An Online Catalog of Human Genes and Genetic Disorders". It also indicates "Updated 6 September 2012". Below the title, there is a search bar with the placeholder "Search OMIM" and a "Search" button. To the right of the search bar, there is a link to "Sample Searches" and an "Advanced Search" section which includes links to OMIM, Clinical Synopses, and OMIM Gene Map. At the bottom of the page, there are logos for the McKusick-Nathans Institute of Genetic Medicine, Johns Hopkins Medicine, and the National Human Genome Research Institute. A note at the bottom states: "NOTE: OMIM is intended for use primarily by physicians and other professionals concerned with genetic disorders, by genetics researchers, and by advanced students in science and medicine. While the OMIM database is open to the public, users seeking information about a personal medical or genetic condition are urged to consult with a qualified physician for diagnosis and for answers to personal questions." It also mentions that OMIM® and Online Mendelian Inheritance in Man ® are registered trademarks of the Johns Hopkins University.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Shrnutí

- Schéma přednášky
- Role BIOINFORMATIKY v současném pojetí FUNKČNÍ GENOMIKY
- Databáze
 - Spektrum „on-line“ zdrojů
 - PRIMÁRNÍ, SEKUNDÁRNÍ a STRUKTURÁLNÍ databáze
 - GENOMOVÉ zdroje
- Analytické nástroje
 - Vyhledávání homologií
 - Vyhledávání sekvenčních motivů, otevřených čtecích rámců, restrikčních míst....
 - Další www genomové nástroje



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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

Diskuse



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

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