



**Операции с последовательностями,
доступ к базам и форматы данных. Базы
данных последовательностей ДНК EMBL
и GenBank**

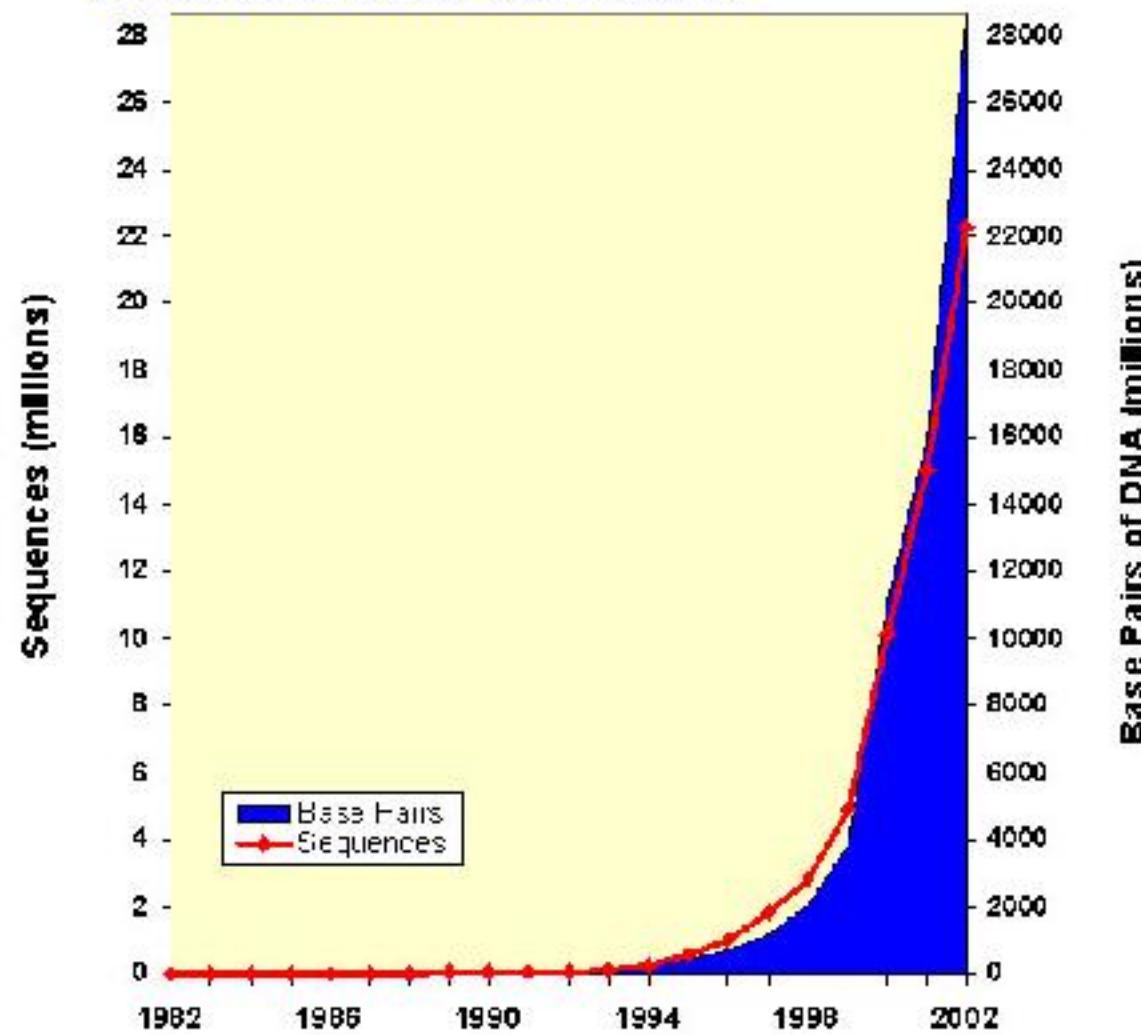
Орлов Юрий Леонидович

Кафедра информационной биологии ФЕННГУ

Международные проекты геномных исследований

Стремительно растут темпы исследований по секвенированию геномной ДНК (Benson et al., 2000; Wheeler et al., 2000). На сентябрь 2003 г. доступны 139 полных геномов прокариот, включая 16 видов архебактерий и 123 вида бактерий.

Рост объема GenBank



GenBank за 2002 год:

28,507,990,166 п.о.

22,318,883

последовательностей

Полностью секвенированы эукариотические геномы мышевидного салата *Arabidopsis thaliana*, червя *Caenorhabditis elegans*, плодовой мушки *Drosophila melanogaster*, дрожжей *Saccharomyces cerevisiae* и *Schizosaccharomyces pombe*, некоторых внутриклеточных паразитических организмов (*Plasmodium falciparum*, *Encephalitozoon cuniculi*).

Информационный взрыв в молекулярной биологии и генетике

Характеристики генома человека:

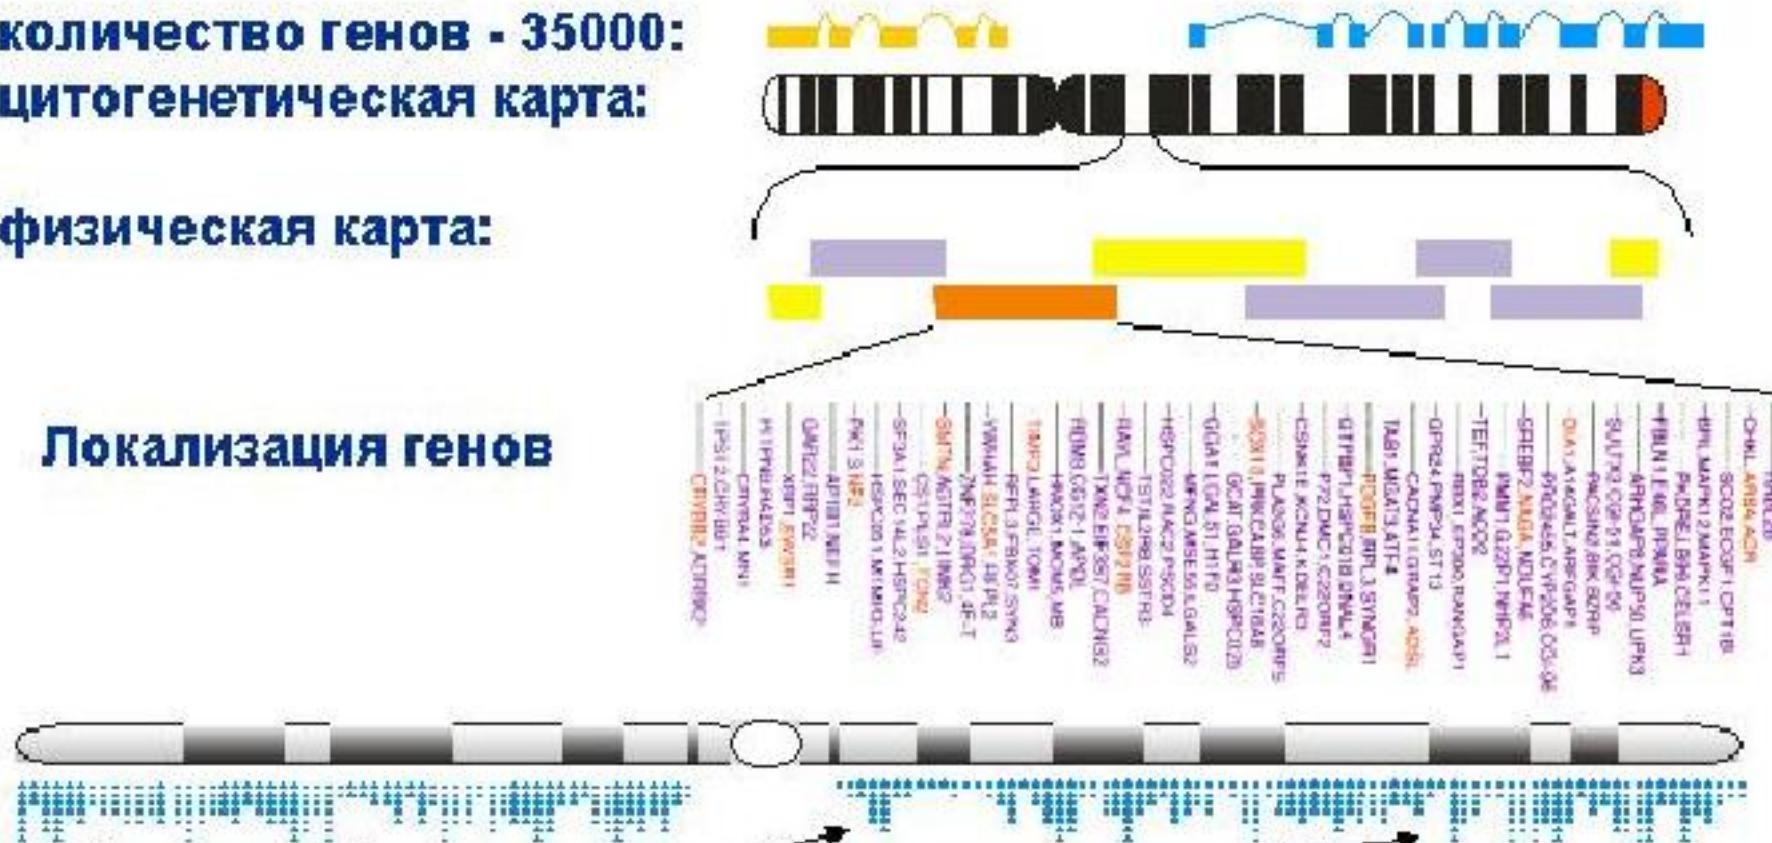
размер - 3.3 миллиарда нуклеотидов: ATGCCCGGGTTTAAATGCGTCAGTGACTGCACA...

количество генов - 35000:

цитогенетическая карта:

физическая карта:

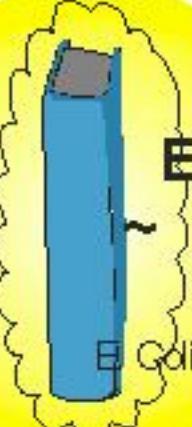
Локализация генов



Локализация мутаций: 1.5 миллиона полиморфизмов

Библиотеки геномных последовательностей

1 ТОМ



E. Coli
 $\sim 10^6$ п.о.

10 ТОМОВ



Дрожжи
 $\sim 10^7$ п.о.

100 ТОМОВ



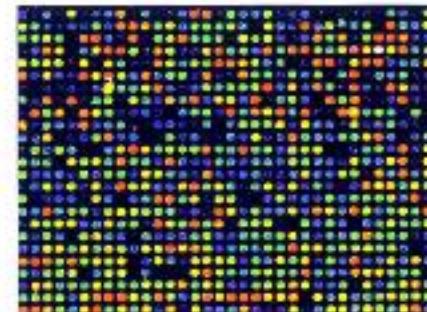
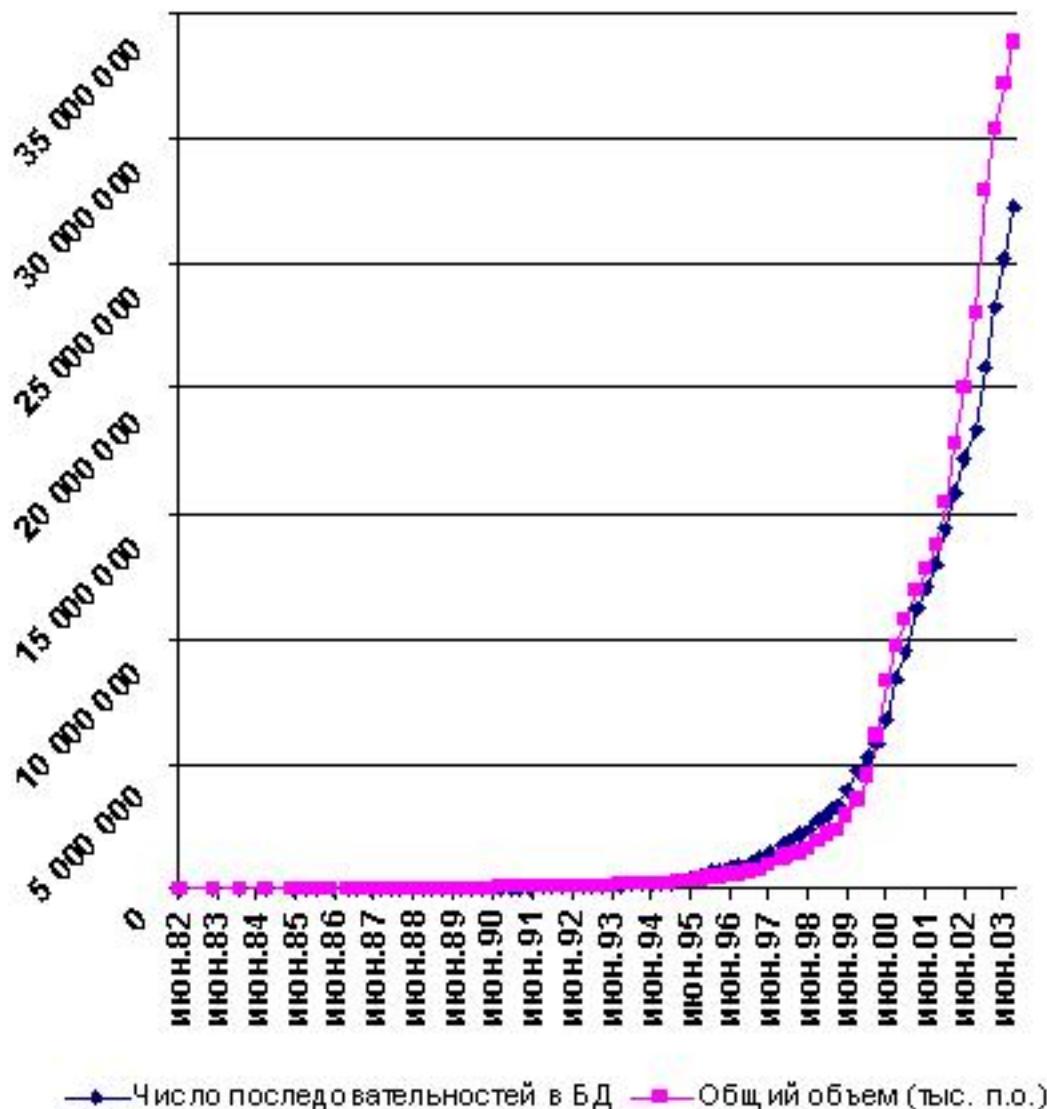
Дрозофилы
 $\sim 10^8$ п.о.

1000 ТОМОВ



Человек
 $\sim 3 \times 10^9$ п.о.

Рост числа последовательностей в банке данных EMBL с 1982 по июнь 2003 г.

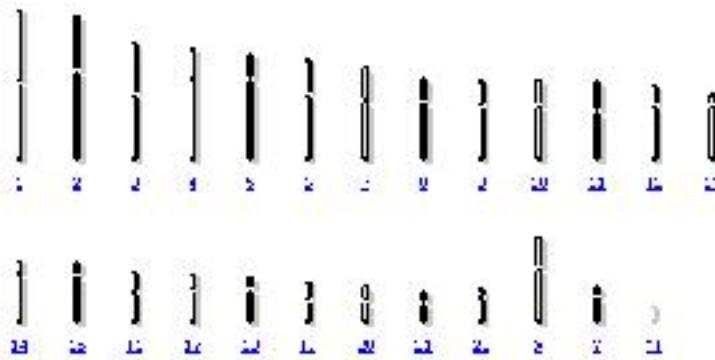


2000 г. – секвенирование
генома человека

постгеномная эпоха

2003 г. – завершение чернового
секвенирования

(6 государств, Россия с 1989 г.)



Дальнейшая структура лекции и курса

Лекция - Базы и банки данных.

Курс - Компьютерная геномика – задачи анализа генетических макромолекул

Структура лекции

- Интернет. Технические компьютерные средства поддержки БД.
- Классификация баз данных. История развития БД. Репозитарии и банки данных.
- Структура карточек GenBank/EMBL
- Поиск информации о нуклеотидных последовательностях. ENTREZ
- Запросы к БД. Перекрестные ссылки (линки).
- Поиск научных статей PubMed

Техническая основа работы с базами данных. Поиск информации в Интернет.

Пример:

http://www.bionet.nsc.ru/SRCG/index.html

http:// тип документа (http = гипертекстовый документ)

www.bionet.nsc.ru адрес сервера в сети Internet

/SRCG/ каталог сервера в котором находится HTML-документ **index.html** имя файла в котором находится HTML-документ

Сервис в Интернет: почта E-mail; FTP, Archie; Gopher; WWW, JAVA.

Просмотр гипертекстовых файлов (броузеры): программа "Netscape Communicator" "Internet Explorer"

Поиск молекулярно-биологической информации проводится по тому же принципу, что поиск любой другой информации в Интернет с использованием поисковых систем.

Сервер ИЦиГ СО РАН. Программа Netscape Navigator

Институт цитологии и генетики - Netscape 6

File Edit View Search Go Bookmarks Tasks Help

http://www.bionet.nsc.ru/ Search

Home My Netscape Search Shop Bookmarks Net2Phone Instant Message WebMail Calendar Radio People Yellow Pages Download Customize

My Sidebar Tabs >

Search Buddy List Stocks News This tab is not available right now

ИНСТИТУТ ЦИТОЛОГИИ И ГЕНЕТИКИ
Сибирское Отделение Российской Академии Наук

По-русски In English



События

Институт

- Контактная информация
- Общие сведения
- Основные направления работ
- + Буклет института

Научная деятельность

- Конференции
- Семинары
- Прикладные разработки
- Учебные материалы

Кольцо сайтов "Информационная биология"

- + Кафедра информационной биологии
- + Молекулярно-генетический скринер

Информационные ресурсы

- + ЦКП: микроскопический анализ
- + Вестник ВОГиС

Новости

- + Архив новостей
- + Доска объявлений

Сентябрь 2003 Совет Научной Молодежи Новосибирского Научного Центра (СНМ ННЦ) СО РАН проводит электронный опрос молодых ученых "Молодые ученые: лидерская роль, проблемы и новые возможности".
[подробнее >>>](#)

Сентябрь 2003 Региональный Общественный Фонд содействия отечественной науке объявляет [ОТКРЫТЫЙ КОНКУРС для членов Российской академии наук](#) на основании грантов Фонда в области естественных и гуманитарных наук.
[подробнее >>>](#)

Вход для сотрудников

Поиск на сервере Найти

«Компьютерная геномика» НГУ, Лекция 1, 2003

Тот же сайт просматривается с помощью Internet Explorer

Институт цитологии и генетики - Microsoft Internet Explorer

File Edit View Favorites Tools Help

Back Search Favorites History Go Links

Address http://www.bionet.nsc.ru/

ИНСТИТУТ ЦИТОЛОГИИ И ГЕНЕТИКИ
Сибирское Отделение Российской Академии Наук

По-русски In English

События

Институт

- Контактная информация
- Общие сведения
- Основные направления работ
- Буклет института

Научная деятельность

- Конференции
- Семинары
- Прикладные разработки
- Учебные материалы

Кольцо сайтов
"Информационная биология"

- Кафедра информационной биологии
- Молекулярно-генетический сервер

Новости

- Архив новостей
- Доска объявлений

Сентябрь 2003 Совет Научной Молодежи Новосибирского Научного Центра (СНМ ННЦ) СО РАН проводит электронный [запрос молодых ученых](#) "Молодые ученые: лидерская роль, проблемы и новые возможности".
[подробнее >>>](#)

Сентябрь 2003 Региональный Общественный Фонд содействия отечественной науке объявляет [ОТКРЫТЫЙ КОНКУРС для ученых Российской академии наук](#) на соискание грантов Фонда в области естественных и гуманитарных наук.
[подробнее >>>](#)

Вход для сотрудников

Поиск на сервере

Найти

Done Internet

Start 19:23

Умение работать с Интернетом – необходимое практическое требование, без которого современная научная работа с информацией, с базами данных просто невозможна.

Список полезных сайтов:

Учебник по Интернет (Microsoft)	http://home.microsoft.com/intl/rus/tutoria/index.htm
Средства поиска в Интернет (собраны вместе)	http://www.yandex.ru/index.html
Список ссылок на поисковые системы	http://www.risp.ru/search/
Средства поиска (Microsoft)	http://www.microsoft.com/intl/ru/access/allinone.asp

Поисковые сервера

Yahoo!	http://www.yahoo.com/
AltaVista	http://www.alavista.com/
100hot	http://www.100hot.com
InfoSeek	http://www.infoseek.com/
Excite	http://www.excite.com/
Lycos	http://www.lycos.com/
WhoWhere	http://www.whowhere.com/

Российские поисковые системы

Rambler	http://www.rambler.ru/
List.ru	http://www.list.ru
Яндекс	http://www.yandex.ru
@Rus	http://www.rus@rus
Апорт	http://www.aport.ru
Weblist	http://www.weblist.ru

Сервера бесплатной электронной почты

Mail.Ru	http://mail.ru
---------	---

Базы данных последовательностей ДНК. Исторический обзор.

Первые последовательности, собранные в базах данных были аминокислотными последовательностями.

Методы секвенирования белков (Sanger and Tuppy, 1951)
Margaret Dayhoff (1925-1983)

National Biomedical Research Foundation (NBRF) (Вашингтон, США)

1960-е Protein Sequence Atlas

коллекция последовательностей, которая перешла в базу данных
Protein Informational Resource (PIR ранее Protein Identification Resorce)
<http://watson.gmu.edu:8080/pirwww/index.html>

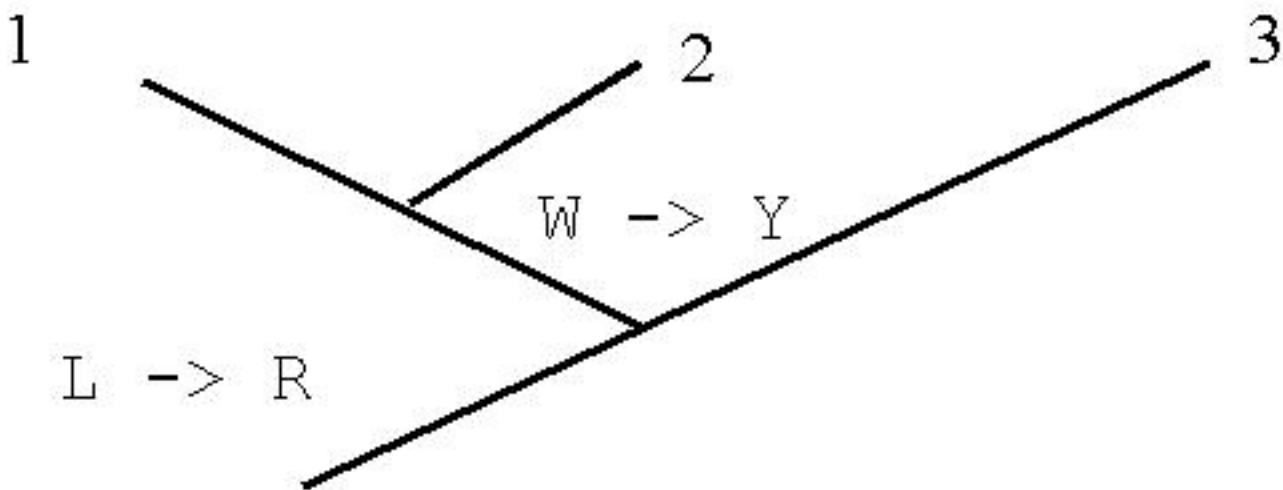


1980-е PIR-International Protein Sequence Database

<http://www-nbrf.georgetown.edu/pir>

Сотрудничество международных центров NBRF, MIPS (Munich Center for Protein Sequences),
JPIID (Japan International Protein Information Database)

Данные были организованы в семейства и суперсемейства на основе схожести
последовательностей.



Organism_1 AWTVASAVRTSI

Organism_2 AYTVA~~A~~AVRTSI

Organism_3 AWTVAAAVLTSI

Таблицы частот замен.

Были отобраны белки с не более 15% различий, чтобы наблюдаемые замены аминокислот отражали только одну замену, а не две.

Метод предсказания филогенетических отношений и вероятных аминокислотных замен в процессе эволюции родственных белковых последовательностей.

Матрицы аминокислотных замен PAM – матрицы Дайхофф (Dayhoff) MDM (Mutation Data Matrix), или PAM (Percent Accepted Mutation)

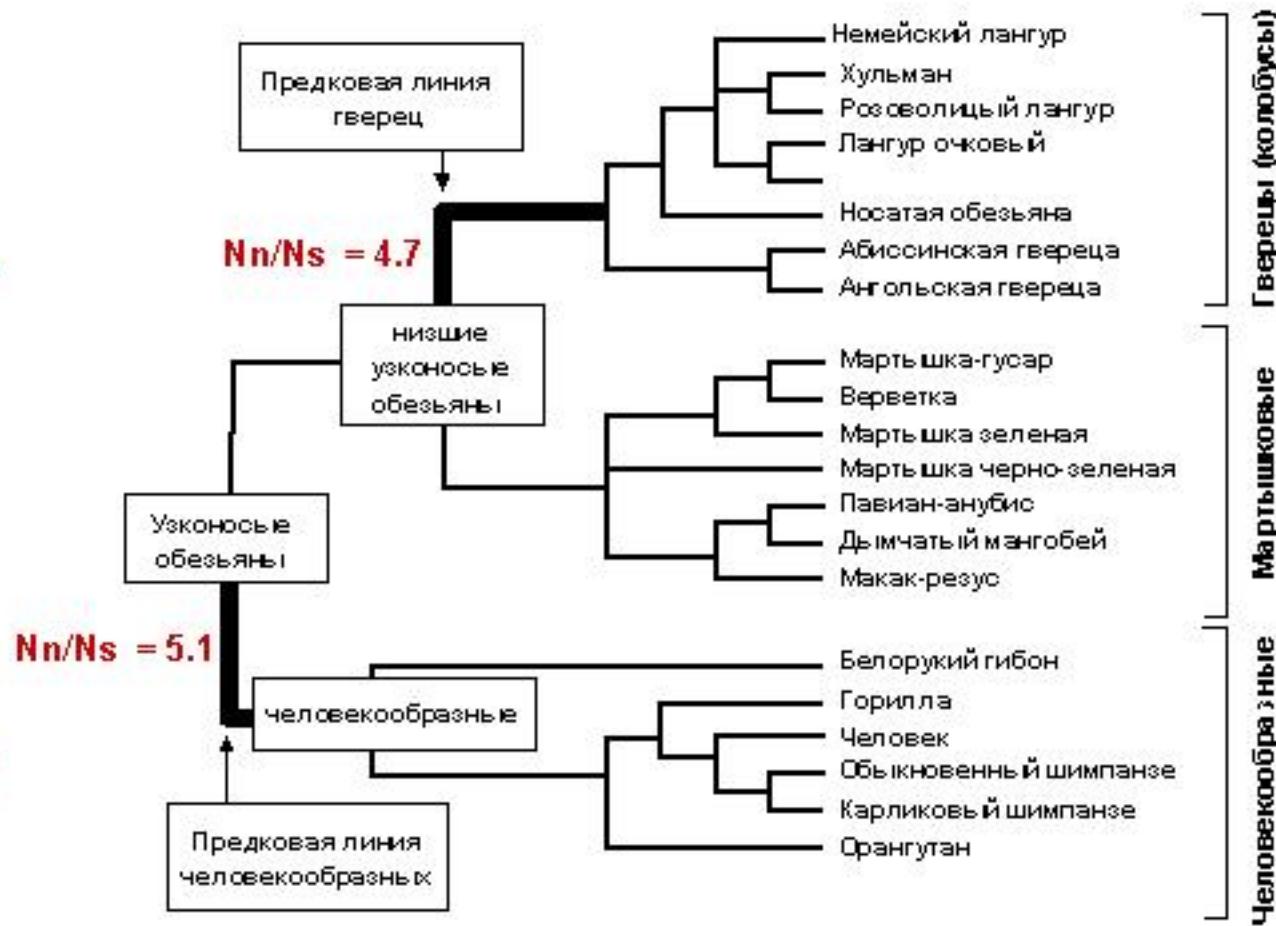
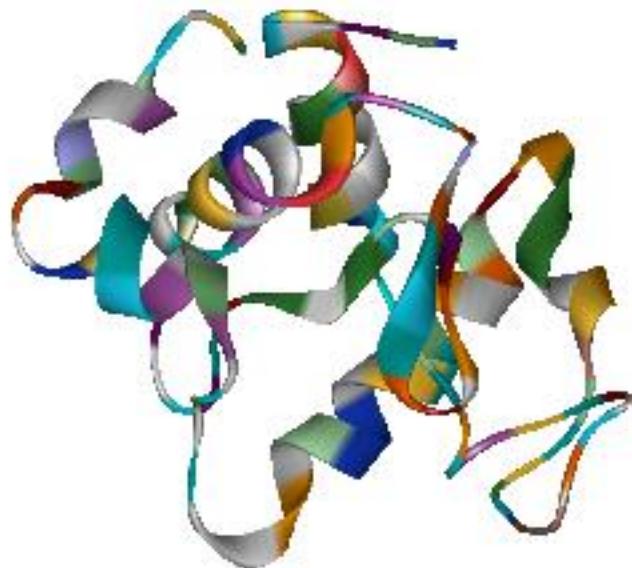
Научные задачи, решаемые с помощью анализа родственных белков

Молекулярный филогенетический анализ: адаптивная эволюция генов, кодирующих лизоцимы обезьян

Критерий адаптивной эволюции
(Кимура, 1984):

$$Nn/Ns > 1$$

Здесь **Nn** и **Ns** - количество несинонимических замен, фиксировавшихся в исследуемом эволюционном маршруте



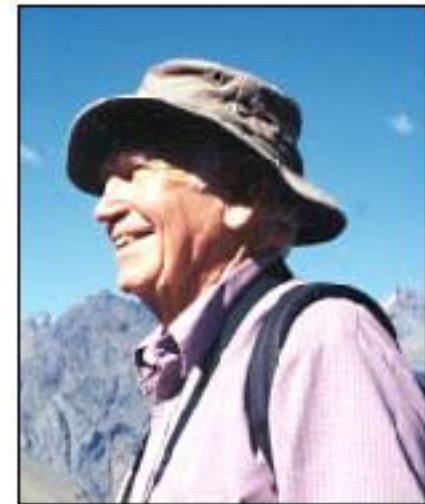
Базы данных последовательностей ДНК

Walter Goad (1925-2000)

LANL (Los Alamos National Laboratory) Нью-Мексико, США

EMBL (European Molecular Biology Laboratory) Гейдельберг, Германия

1979 - прототип GenBank разрабатывался в LANL 1982-1992,
далее в NCBI (National Center for Biotechnology Information)



www.ncbi.nlm.nih.gov

1980 - EMBL Data Library (www.ebi.ac.uk)

1984 – DDBJ (www.ddbj.nig.ac.jp)

1983 - ГЕНЭКСПРЕСС и Программа "Геном человека" СССР (А.А.Баев)

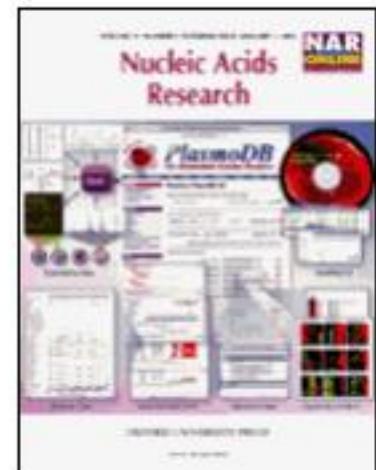
Сейчас эти центры образуют международный консорциум

International Nucleotide Sequence Database Collaboration

www.ncbi.nlm.nih.gov/collab

Описание баз данных (более 300 молбюл баз данных)

NAR - ежегодный первый выпуск (N1, январь) :



Nucleic Acids Research

<http://nar.oupjournals.org/content/vol31/issuel/>

OXFORD
Journals online

Программы анализа последовательностей

Методы секвенирования ДНК

Maxam and Gilbert, 1977 - Sanger et al., 1977

Секвенирование

Программы анализа последовательностей ДНК, РНК и белков.

1982, 1984 - NAR - первые спец.

выпуски по программам

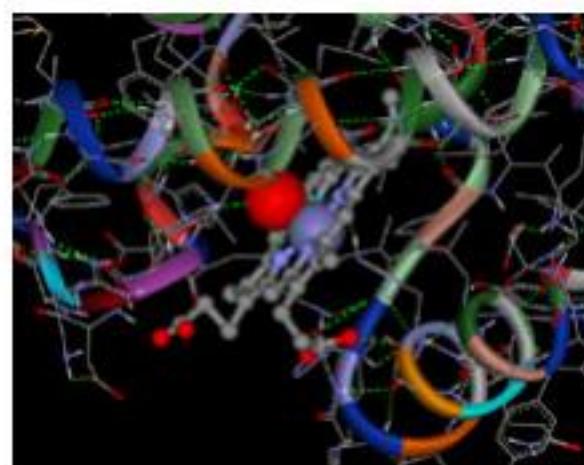
GCG на компьютерах VAX (Ун-т Висконсин)

www.gcg.com/

Intelligenetics, DNAStar

PHRED, PHRAP (www.codoncode.com)

коммерческие и некоммерческие пакеты



Методы, алгоритмы и современные программные реализации
будут подробно рассмотрены в дальнейших разделах курса

Получение последовательностей из открытых баз данных

Важнейший шаг в обеспечении технического доступа к базам данных – разработка Web-страниц.

GENINFO – D.Benson, D.Lipman

Система ENTREZ (позднее включившая MedLine, NLM)

<http://www.ncbi.nlm.nih.gov/entrez/>



Новый релиз выходит каждые два месяца. Образован международный консорциум (International Nucleotide Sequence Database Collaboration), который состоит из Банка данных ДНК Японии (DNA DataBank of Japan, DDBJ), Европейской Молекулярно-биологической Лаборатории (the European Molecular Biology Laboratory, EMBL), и GenBank США (NCBI). Эти три организации обмениваются данными на ежедневной основе.

Коллекции молекулярно-биологических баз данных.

Andreas D. Baxevanis. The Molecular Biology Database Collection: 2003 update. Nucleic Acids Research, 2003, Vol. 31, No. 1 1-12.

Основные репозитарии:

(<http://nar.oupjournals.org/cgi/content/full/31/1/1>)

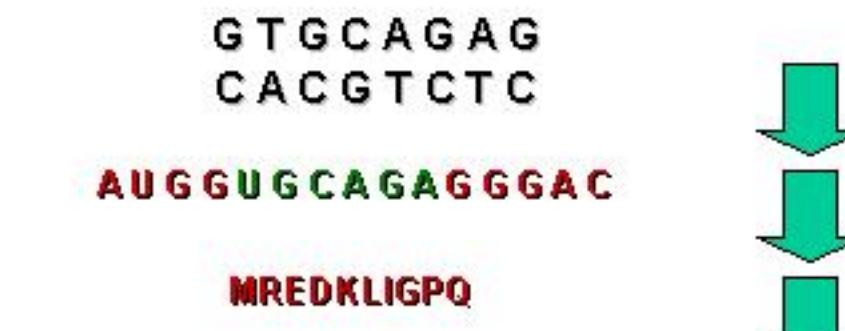
DNA Data Bank of Japan (DDBJ)	http://www.ddbj.nig.ac.jp	последовательности ДНК и белков, консорциум
EMBL Nucleotide Sequence Database	http://www.ebi.ac.uk/embl.html	-/-
GenBank	http://www.ncbi.nlm.nih.gov/	-/-
NCBI Reference Sequence Project	http://www.ncbi.nlm.nih.gov/RefSeq/	Природные биологические молекулы
Ensembl	http://www.ensembl.org/	Аннотированная информация, Геномы эукариот
UCSC Genome Browser	http://genome.ucsc.edu/	Аннотация геномов
STACK	http://www.sanbi.ac.za/Dbases.html	Ген-ориентированные кластеры
TIGR Gene Indices	http://www.tigr.org/tdb/tgi.shtml	-/-
UniGene	http://www.ncbi.nlm.nih.gov/UniGene/	-/-

Ресурсы по молекулярной биологии могут быть классифицированы как **репозитарии, банки данных, базы данных, информационные сайты, электронные библиотеки и Интернет-доступное программное обеспечение.**

Каталог ресурсов: <http://wwwmgs.bionet.nsc.ru/mgs/links/links.html>

Специализированные базы данных можно подразделить в соответствии с иерархической организацией хранения и передачи наследственной информации:

- Уровень ДНК
- Уровень РНК
- Уровень белка
- Генные сети



SYSTEM FOR FORMALIZED DESCRIPTION,
VISUALIZATION, AND MODELLING
OF GENE NETWORKS



[Links of IC&G SB RAS, Novosibirsk] [Priority links] [WWW-Biosciences] [GENOME] [NCBI National Center of Biotechnological Informatic] [Data bases] [Bio Tools] [EBI European Bioinformatics Institute] [BCM Baylor College of Medicine] [GDB Genome Database] [PDB Protein Data Bank Brookhaven National Lab.] [Patents] [PROGR] [France] [SilverPlatter]

Links of IC&G SB RAS, Novosibirsk:

[INSTITUTE OF CYTOLOGY AND GENETICS, The Siberian Division of the Russian Academy of Sciences](#)

[The First International conference on Bioinformatics of Genome Regulation and Structure](#)

[Vogis Courier \(Russian only\)](#)

[Lab. of Experimental Modelling of Evolutionary Processes](#)

[Meiosis Laboratory Home Page](#)

[Sector of Molecular Evolution](#)

[X inactivation](#)

[Methods of Genetic Analysis Lab](#)

[The Laboratory of Animal Molecular Genetics](#)

Priority links:

[Novosibirsk Institute of Bioorganic Chemistry](#)

[Institute of Protein Research, RAS](#)

[Engelhardt Institute of Molecular Biology \(EIMB\)](#)

[A National Laboratory for Computational Science and Engineering \(SDSC\)](#)

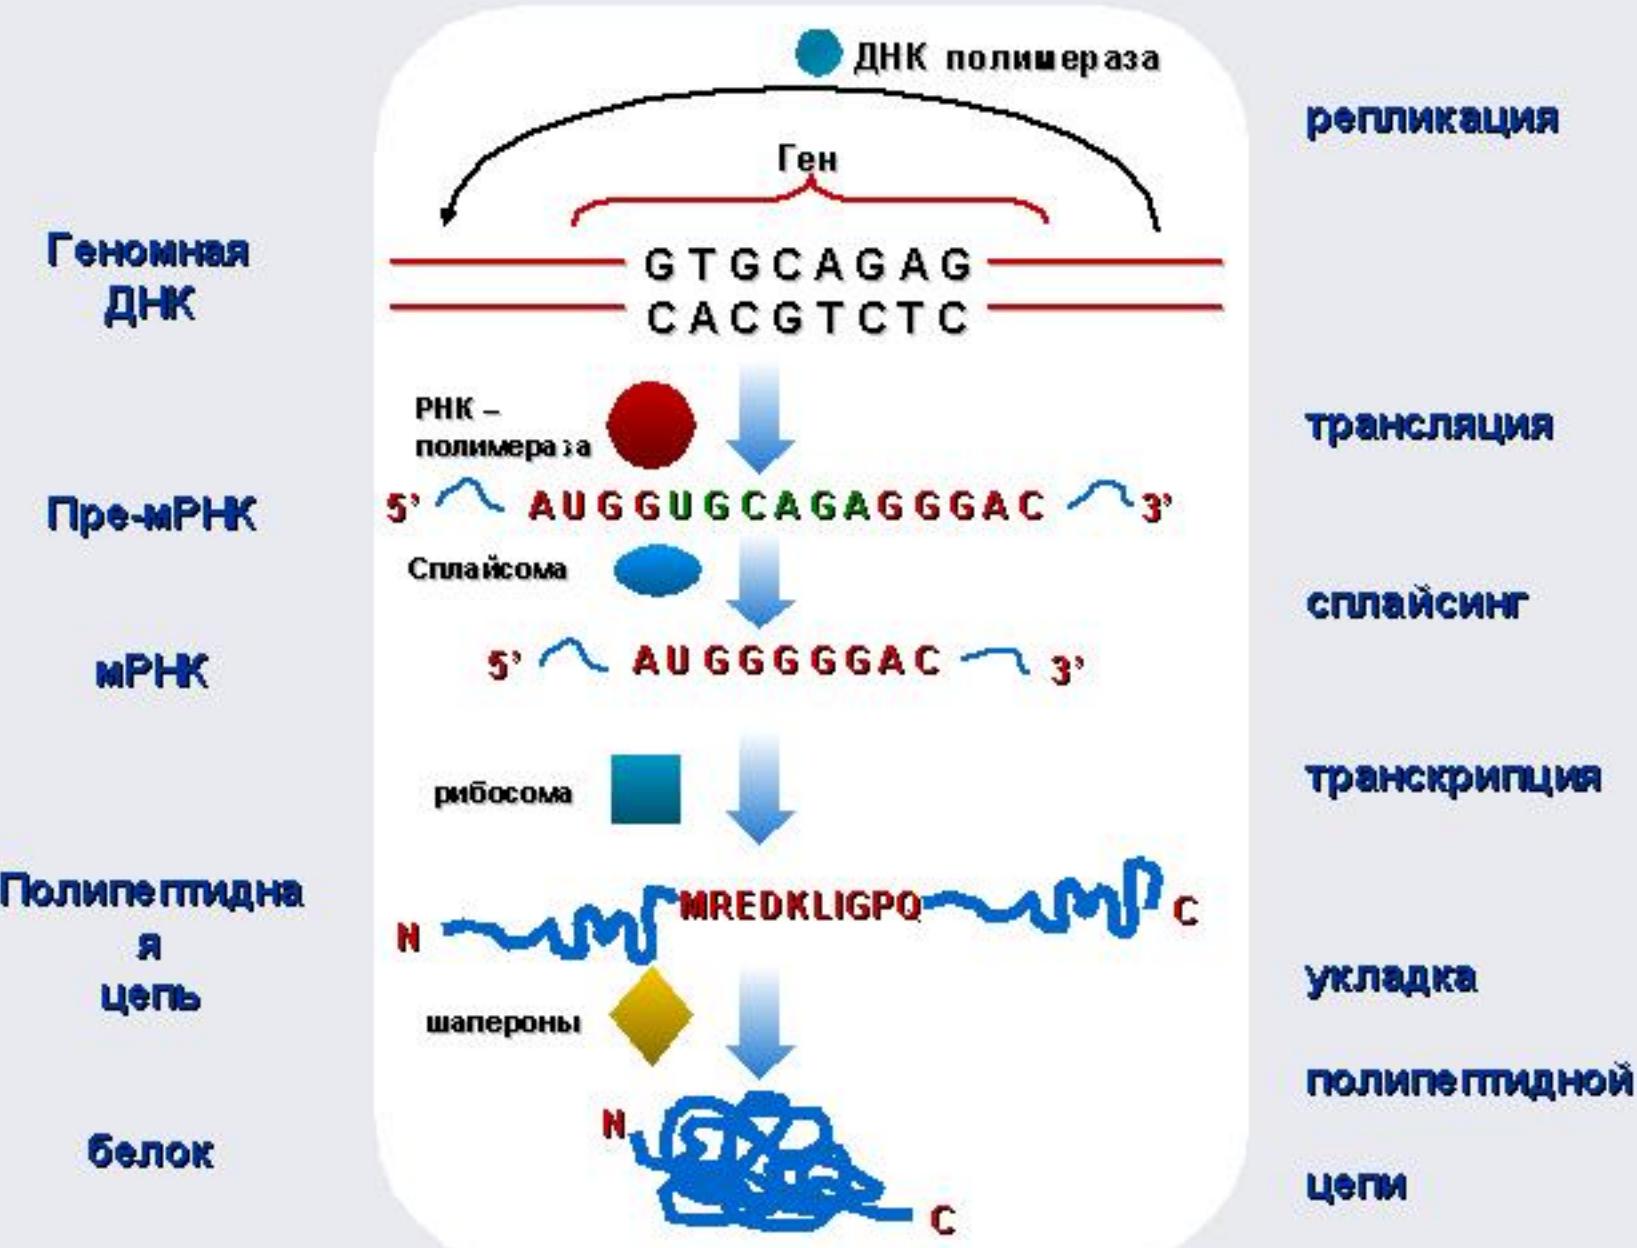
[Molecular Bioinformatics of Gene Regulation, \(Transfac DATA Base\)](#)

[Institute of Advanced Biomedical Technologies \(ITBA\)](#)

Полный каталог содержит более 1000 эл.ресурсов по молекулярной биологии

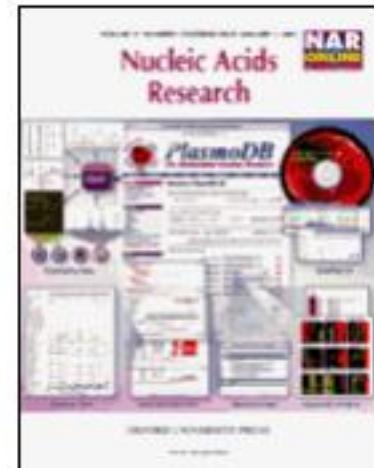
Базы данных и электронные ресурсы по биоинформатике

Фундаментальные генетические процессы



ОСНОВНЫЕ НАПРАВЛЕНИЯ (ГРУППЫ) БАЗ ДАННЫХ ПО МОЛЕКУЛЯРНОЙ БИОЛОГИИ (Более 300 баз данных)

- Сравнительная геномика (Comparative Genomics)
- Экспрессия генов с помощью микрочипов
- Структура и регуляция генов
- Генетическое и физическое картирование
- Геномные базы данных.
- Межмолекулярные взаимодействия
- Метаболические пути и клеточная регуляция
- Мутации
- Белки
- РНК
- Структуры (Пространственные)
- Трансгенные растения и животные
- Другие направления (Литературные базы данных, таксономия)



Andreas D. Baxevanis. The Molecular Biology Database Collection: 2003 update. Nucleic Acids Research, 2003, Vol. 31, No. 1 1-12.

(<http://nar.oupjournals.org/cgi/content/full/31/1/1>)

ОСНОВНЫЕ НАПРАВЛЕНИЯ БАЗ ДАННЫХ ПО МОЛЕКУЛЯРНОЙ БИОЛОГИИ (NAR, 2003)

Сравнительная геномика (Comparative Genomics)

Clusters of Orthologous Groups (COG) <http://www.ncbi.nlm.nih.gov/COG>

содержит филогенетическую классификацию белков из 43 полных геномов



Экспрессия генов с помощью микрочипов (Gene Expression) microarray

TRANSCRIPTION REGULATORY
REGIONS DATABASE



Структура и регуляция генов (Gene Identification and Structure)

SNP Consortium database <http://snp.csbl.org> SNP Consortium data

TRRD <http://www.biomed.nsc.ru/trrd/> Transcription regulatory regions of eukaryotic genes

Генетическое и физическое картирование (Genetic and Physical Maps)

Геномные базы данных (Genomic Databases)

ACEDB information <http://www.acedb.org> *C. elegans*, *S. pombe*, and human sequences and genomic information

GeneCards <http://bioinfo.weizmann.ac.il/cards/> Integrated database of human genes, maps, proteins and diseases

GOLD <http://igwweb.integratedgenomics.com/GOLD/> Information regarding complete and ongoing genome projects



Межмолекулярные взаимодействия (Molecular Interactions)

BIND <http://bind.ca> Molecular interactions, complexes and pathways



ГЕННЫЕ СЕТИ. Метаболические пути и клеточная регуляция (Metabolic Pathways and Cellular Regulation)

EcoCyc <http://ecocyc.org> *Escherichia coli* K-12 genome, metabolic pathways, transporters and gene regulation

EpoDB <http://www.cbl.upenn.edu/EpoDB/> Genes expressed during human erythropoiesis

Kyoto Encyclopedia of Genes and Genomes (KEGG) <http://www.genome.ad.jp/kegg> Metabolic and regulatory pathways

RegulonDB http://www.cifn.unam.mx/Computational_Genomics/regulondb/ *Escherichia coli* transcriptional regulation and operon organization

Мутации

Mutation Databases

Human Gene Mutation Database (HGMD) <http://www.hgmd.org> Known (published) gene lesions underlying human inherited disease

ОСНОВНЫЕ НАПРАВЛЕНИЯ БАЗ ДАННЫХ ПО МОЛЕКУЛЯРНОЙ БИОЛОГИИ (NAR, 2003)

БЕЛКИ (Protein Databases)

Kabat Database <http://immuno.bme.mwu.edu/> Sequences of proteins of immunological interest

PIR-NREF <http://pir.georgetown.edu/pirwww/pirref.shtml> Non-redundant reference database with comprehensive protein sequences

SWISS-PROT/TrEMBL <http://www.expasy.ch/sprot> Curated protein sequences

TRANSFAC <http://transfac.gbf.de/TRANSFAC/index.html> Transcription factors and binding sites

Мотивы в белках (Protein Sequence Motifs)

CluSTR <http://www.ebi.ac.uk/clustr/> Automatic classification of SWISS-PROT+TrEMBL proteins

Pfam <http://www.sanger.ac.uk/Software/Pfam/> Multiple sequence alignments and hidden Markov models of common protein domains

PROSITE <http://www.expasy.org/prosite> Biologically significant protein patterns and profiles

Протеомные ресурсы (Proteome Resources)

Proteome Analysis Database <http://www.ebi.ac.uk/proteome/> Online application of InterPro and CluSTR for the functional classification of proteins in whole genomes

Системы поиска информации (Retrieval Systems and Database Structure)

TESS <http://www.cbil.upenn.edu/tess> Transcription element search system

РНК (RNA Sequences)

ACTIVITY <http://util.bionet.nsc.ru/databases/activity.html> Functional DNA/RNA site activity

RNA Modification Database <http://medlib.med.utah.edu/RNAmods/> Naturally modified nucleosides in RNA

UTRdb/UTR site <http://bighost.area.ba.cnr.it/srs6/> 5'- and 3'-UTRs of eukaryotic mRNAs and relevant functional patterns

Пространственные структуры (Structure)

HSSP <http://www.sander.ebi.ac.uk/hssp/> Structural families and alignments; structurally-conserved regions and domain architecture

PDB <http://www.pdb.org/> Structure data determined by X-ray crystallography and NMR

SCOP <http://scop.mrc-lmb.cam.ac.uk/scop> Familial and structural protein relationships

Трансгенные растения и животные (Transgenics)

Другие направления (Varied Biomedical Context)

PubMed <http://www.ncbi.nlm.nih.gov/PubMed/> MEDLINE and Pre-MEDLINE citations

Tree of Life <http://phylogeny.arizona.edu/tree/phylogeny.html> Information on phylogeny and biodiversity

Поиск литературной информации.

База MEDLINE

Определение базы данных. Поле, вход, запись.

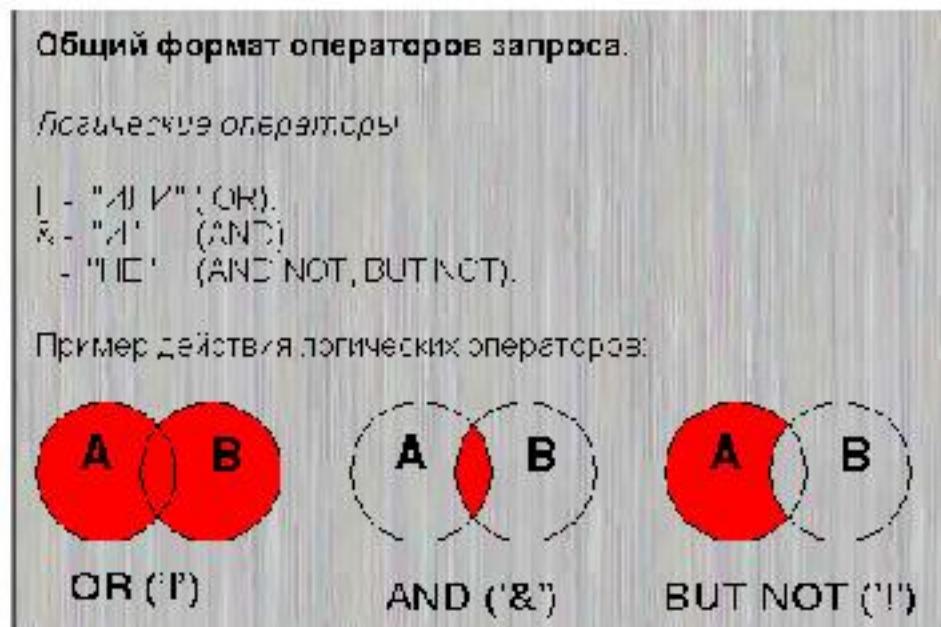
Адрес базы данных MEDLINE : <http://www.ncbi.nlm.nih.gov/PubMed/>

Простой поиск.

Формат запроса: word1 (AND word2 OR word3)

Сложный поиск.

Формат запроса: word1[FieldCode] AND word2[FieldCode]



Сохранение
найденной
информации

(принцип
Cut&Paste)

Ключевые слова структурированы в специальном словаре для поиска литературной (медицинской и др.) информации



NATIONAL
LIBRARY OF
MEDICINE

MEDICAL SUBJECT HEADINGS



Contact NLM | Site Index | Search Our Web Site | NLM Home

Health Information | Library Services | Research Programs | New & Noteworthy | General Information



MeSH Browser

- [Online searching of MeSH vocabulary](#)
- [About the MeSH Browser](#)



All About MeSH

- [MeSH Fact Sheet](#)
- [Presentations and papers by MeSH staff.](#)
- [Online introductory material to the Annotated MeSH](#)
- [Information from Previous Years](#)
- [Suggestions for authors' keywords](#)



Obtaining MeSH

- [Download electronic copies.](#)
- Ordering information for [Printed versions.](#)



What's New



MeSH Staff

- [Biographies and email.](#)
- [Publications and presentations.](#)

Related Efforts

- [Congenital Abnormalities associated with Mental Retardation \(MCA/MR\).](#)
- [Unified Medical Language System \(UMLS®\)](#)
- [NLM Classification](#)



MeSH Suggestions

- [Send MeSH vocabulary suggestions.](#)

Каталог доступен на сервере NCBI
<http://www.nlm.nih.gov/mesh/>

MEDLINE/PubMed

Ссылки и резюме
статей из 4600
биомедицинских
журналов

Понятие карточки банка данных. Пример EMBL

ID - identification entry)	(begins each entry; 1 per
AC - accession number	(>=1 per entry)
SV - sequence version	(1 per entry)
DT - date	(2 per entry)
DE - description	(>=1 per entry)
KW - keyword	(>=1 per entry)
OS - organism species	(>=1 per entry)
OC - organism classification	(>=1 per entry)
OG - organelle	(0 or 1 per entry)
RN - reference number	(>=1 per entry)
RC - reference comment	(>=0 per entry)
RP - reference positions	(>=1 per entry)
RX - reference cross-reference	(>=0 per entry)
RG - reference group	(>=0 per entry)
RA - reference author(s)	(>=0 per entry)
RT - reference title	(>=0 per entry)
RL - reference location	(>=1 per entry)
DR - database cross-reference	(>=0 per entry)
CC - comments or notes	(>=0 per entry)
AH - assembly header	(0 or 1 per entry)
AS - assembly information	(0 or >=1 per entry)
FH - feature table header	(0 or 2 per entry)
FT - feature table data	(>=0 per entry)
XX - spacer line	(many per entry)
SQ - sequence header	(1 per entry)
CO - contig/construct line	(0 or >=1 per entry)
bb - (blanks) sequence data	(>=1 per entry)
// - termination line	(ends each entry; 1 per

Текстовый
файл, длина
строки
ограничена,
Ключевые слова
жестко заданы

Пример карточки EMBL, содержащий ген протеин-киназы дрозофилы

ID DMCAFRCA standard; DNA; ENV; 3950 3T.
AC M18555; J03504;
MM M18555.1
DT 16 JUL 1988 (Rel. 16, Created)
PU 06-JUL-1988 (Rel. 2L, Last updated, Version 1)
DE D.melanogaster cAMP dependent protein kinase catalytic subunit,
PF complete ccs.
KU cAMP dependent protein kinase; kinase; protein kinase.
OS *Drosophila melanogaster* (fruit fly)
OC Eukaryota; Metazoa; Arthropoda; Tracheata; Insecta; Pterygota;
OC Neoptera; Endopterygota; Lepidoptera; Brachycera; Muscomorpha; Drosophilidae;
OC *Drosophila*.
RN [1]
RP 1-3959
RE MEDLINE; 88:15281.
RA Foster J.L., Higgins G.C., Jackson W.F.:
RT "Cloning, sequence, and expression of the *Drosophila* cAMP-dependent protein
RT kinase catalytic subunit gene";
RL J. Biol. Chem. 263:1676-1681(1988).
DR FLYBASE; PEGnCOOC273; Gka C1.
RN SWISS-PROT; P12370; KAL-C_FROME.
CC Draft entry and computer readable copy of sequence [1] kindly
CC provided by J.L.Foster (16-JUL-1988).
FH Key Location/Qualifiers
FT Source 1..3959
FT /db_xref="taxon:7227"

Идентификатор

Код доступа

Описание
последовательности

Литературная ссылка

Разметка

Пример карточки EMBL, продолжение

Размер
Размер
части

```
FT source= 1..3059
FT          /db_xref="taxon:722"
FT          /organism="Drosophila melanogaster"
FT misc_feature= 608..704
FT          /note="cpa repetitive element"
FT CD3      905..1966
FT          /db_xref="FLYBASE:FEgnC00C273"
FT          /db_xref="SWISS-PROT:P12370"
FT          /note="cAMP-dependent protein kinase catalytic subunit"
FT          /protein_id="AAA28412.1"
FT          /translation="MGNNAIISRKVQDAAETVKFLEQKKEEEFEDKQWAPPTVAADE
FERIKTLGTG3FGRVMIVOEEPKTDYTAKKILDKQKVVKLKVQHTLNEEKRILQAIOFF
FLVSLRYHPKDMSNLYYVLETVTCCEMPHSLRERVCRPSEEDESRTYAAQIVLAFELYHVL
DLIYWDLKPENLLIDSGQYKVIDSGLFAKEVKGSTUTLCGTPSYLAFFLILSRGYRKAV
DWWALGVLYVEMAAGYPPFFADOPICYERKIVSGKVRFP3EPFGDLDLRLRNILQVDLT
KDYCNLKACVNDIKNQKWFASSTDIAIFQKKIEATFIIRCKDPCDTENPDDYEEEALRI
SSTEKCIKEFRAEF"
```

Разметка

Разметка кодирующих частей гена

Аминокислотная последовательность

Последова- тельность ДНК

50
120
180
240
300
360
420
480
540
600
660
720
780
840
900
960
1020

3340
3400
3359

Кроме форматов EMBL/GenBank, предназначенных для хранения информации существуют форматы для компьютерной обработки и анализа последовательностей :

NBRF-PIR

GCG

Plain/ASCII Staden

Genetic Data Environment (GDE)

Fasta/Pearson format

Intelligenetics

PIR/CODATA

ASN.1 Abstract Syntax Notation

NEXUS

Fasta

>seq1

aggctgct agct agct

>seq2

aactaact

NBRF

>DL;seq1

seq1., 16 bases, 268 checksum

aggctgctag ctatgc*

>DL;seq2

aactaact



National
Library
of Medicine



PubMed

Nucleotide

Protein

Genome

Structure

PVC

Taxonomy

Search:

for

Limits

Preview/ndex

History

Clipboard

Details

About Entrez

Text Version

Entrez PubMed

Overview

Help | FAQ

Tutorial

New/Noteworthy

E-Utilities

PubMed Services

Journals Database

MeSH Database

Single Nucleotide

Matcher

Reach Cilia in Mammals

Clinical Queries

Lifelines

Cubby

Related Resources

Order Documents

NLM Gateway

TOXNET

Consumer Health

Clinical Alerts

Clinical Trials.gov

PubMed Central

- Enter one or more search terms, or click [Preview/ndex](#) for advanced searching
- Enter [author names](#) as smith jc. Initials are optional.
- Enter journal titles in full or as MEDLINE abbreviations. Use the [Journals Database](#) to find j

PubMed is a service of the National Library of Medicine that provides access to over 12 million MEDLINE citations and abstracts from life science journals and other life science related publications, involving full-text articles.

Entrez – система навигации по базе данных GenBank и электронной библиотеке PubMed

Bookshelf Additions



Now available: new and updated material in *The NCBI Handbook* and *Genes and Disease*.

New PubMed Features

 The Summary page displays a new icon link for free full-text articles.

New data and additional search options, including an [e-mail](#) selection, have been added to PubMed. See [New/Noteworthy](#).

Severe Acute Respiratory Syndrome

Cilia in Severe Acute Respiratory Syndrome ([Болезнь Аденовирусная Синдрома Северного Типа](#) (SARS) является причиной этого заболевания). Болезнь Аденовирусная Синдрома Северного Типа (SARS) является причиной этого заболевания. Болезнь Аденовирусная Синдрома Северного Типа (SARS) является причиной этого заболевания.

Entrez – электронная библиотека PubMed

Entrez-PubMed - Microsoft Internet Explorer

File Edit View Favorites Tools Help

Address <http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?CMD=Search&db=PubMed>

NCBI PubMed National Library of Medicine NLM

Search Go Clear

For: moncy

Limits Preview Index History Details

Display: Show: Send to:

Items 1-20 of 5122 Page: 1 of 262 Next

Fig 1: Quintao T, Mitter EJ, Ivancic V, Rego To, Bieert P, Vladimirov SN, Kothe S, Cao A, Wissner J, McDonald E, Karpova T. Characterization and analysis of posttranslational modifications of the human large cytoplasmic ribosomal subunit processing by mass spectrometry and Edman sequencing. *J Proteome Res* 2003 Aug; 2(8):244-56. PMID: 12962021 [PubMed - in process]

Fig 2: Ammouli S, Odeberg G, Plancoulaine R, Augermeier R, Kyriakis J, Puccio L. Influence of calcium and zinc on the mice resistance to *Listeria monocytogenes* infection. *Microbiol Immunol* 2003;39(2):159-72. PMID: 12980457 [PubMed - in process]

Fig 3: Evans AJ, Faucheu P, Gobertanez E, Vautier H, Romashen L, Valmu L, Kekkonen H, Mekalanis J. Phosphorylation of the rotavirus capsid protein by protein kinase CK2 and its relevance for virus infection. *Plant Cell* 2003 Sep;15(9):2124-35. PMID: 14553115 [PubMed - in process]

Fig 4: Evans A, Cragg MJ, Boulton C, Emms L, Luban N, Blidge TM. Endopolyploid cells produced after severe genotoxic damage have the potential to repair DNA double strand breaks. *J Cell Sci* 2003 Sep 2; 116(18):4191-9. PMID: 14553171 [PubMed - in process]

Fig 5: Kotschek B, Tschernau U, Denner C. <http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Search&db=PubMed&term=Kotschek+AND+Tschernau+AND+Denner>

Related Articles, Links
Related Articles, Links

Просмотр найденной записи – резюме статьи

The screenshot shows the PubMed search interface. The search bar at the top contains the term 'Ivanov'. Below the search bar, the results are displayed. The first result is a study by Odintsova et al. published in J Protein Chem. 2002 Aug;22(3):249-56. The abstract discusses the characterization and analysis of posttranslational modifications of the human large cytoplasmic ribosomal subunit proteins using mass spectrometry and Edman sequencing.

Odintsova II, Müller EC, Ivanov AV, Il'gorsk TA, Bissert R, Vladimirov SN, Kostka S, Otto A, Wittenmaier-Liebold B, Karginova GG.

Vavilov Institute of General Genetics, Russian Academy of Sciences, Moscow, Russian Federation.

The 60S ribosomal proteins were isolated from ribosomes of human placenta and separated by reversed-phase HPLC. The fractions obtained were subjected to trypsin and Chym-C digestion and analyzed by mass fingerprinting (MALDI-TOF), MS/MS (ESI), and Edman sequencing. Forty-six known subunit proteins were found, 22 of which had molecular masses in accordance with HumanProteomeDatabase (Homo 2002) masses (proteins L6, L7, L9, L12, L13, L14, L18, L21, L22, L24, L26, L27, L30, L32, L34, L35, L36, L37, L37A, L38, L39, L40). Eleven (proteins L7, L10A, L11, L12, L13A, L22, L22A, L27A, L30, L39, and P10) resulted in mass fingerprints that are in agreement with N-terminal loss of methionine, acetylation, or both acetylation or hydroxylation. A loss of methionine without acetylation was found for protein L8 and L17. For nine proteins (L3, L4, L5, L7A, L10, L14, L15, L31, and L40), the molecular masses could not be determined. Proteins P1 and protein L3-like were not identified by the methods applied.

PMID: 12952229 [PubMed - in process]

Пример – статья найденная по ключевому слову Ivanov (автор)

Поиск по ключевым словам в базе данных GenBank. Запрос «альбумин».

The screenshot shows a Microsoft Internet Explorer window displaying search results from the NCBI Nucleotide database. The search term 'альбумин' is entered in the search bar. The results list six entries, each with a link to the full record:

- Entry 1: NM_131326
Rat liver albumin (alt), mRNA
g|1970420|NM_131326.1||C970420
- Entry 2: NM_012504
Rat liver albumin group-specific precursor (Gc), mRNA
g|6973878|NM_012504.1||C978738
- Entry 3: AT123003
Home segment c_024A PL_16770 Es, clone '13AB8273/657', highly similar to Rat albumin precursor
g|3152975|AT123003.1||3152975
- Entry 4: NM_007423
Mus musculus alpha-fetoprotein (Afp), mRNA
g|3198261|NM_007423.2||C982612
- Entry 5: NM_006273
Mus musculus plasminogen activator, inhibitor (Plai), mRNA
g|3156021|NM_006273.2||C960216
- Entry 6: NM_001152

Пример найденной карточки GenBank

The screenshot shows the NCBI Nucleotide search interface. At the top, there's a logo for NCBI and a colorful molecular structure graphic. Below the logo is a navigation bar with links for PubMed, Nucleotide, Protein, Genome, Structure, PMC, and Taxonomy. The main search area has a 'Search' field containing 'Nucleotide', a dropdown menu, and a 'for' field. To the right of these are 'Go' and 'Clear' buttons. Below the search area are several buttons: 'Limits', 'Preview/Index', 'History', and 'Clipboard'. Underneath these are 'Display' (set to 'default'), 'Show' (set to 20), 'Send to', 'File' (with a dropdown menu), 'Get Subsequences', and 'Favorites'.

□ 1: [NM_134326](#) *Rattus norvegicus* ... [g:19705430]

LOCUS NM_134326 1956 bp mRNA linear ROT. 1C-STR-2003
DEFINITION *Rattus norvegicus* albumin (Alb), mRNA.
ACCESSION NM_134326
VERSION NM_134326. GT: 9705430
KEYWORDS .
SOURCE *Rattus norvegicus* (Norway rat)
ORGANISM [Rattus norvegicus](#)
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
Mammalia; Eutheria; Rodentia; Sciurognathi; Muridae; Murinae;
Rattus.
REFERENCE 1 (bases 1 to 1956)
AUTHORS Knut, S., Papet, I., Bechereau, F., Fenis, F., Buttiere, C., Gimond, J.,
Giumo, F., Elyousfi, M., Freuelle, D. and Obled, C.
TITLE Increased albumin plasma efflux contributes to hypocalbuminemia only
during early phase of sepsis in rats
JOURNAL Am. J. Physiol. Regul. Integr. Comp. Physiol. 284 (3). R707-R713
(2003)
MEDLINE 22458063
PUBMED 12571074
REMARK ConcRIF: an accelerated plasma efflux of albumin contributes to
hypocalbuminemia only during the early period of sepsis
REFERENCE 2 (bases 1 to 1956)
AUTHORS Esfalt, J., Dongre, H. and Thum, T.
TITLE Aroc-Or 1254 modulates gene expression of nuclear transcription
factors: implications for albumin gene transcription and protein
synthesis in rat hepatocyte cultures

Описание
полей в
GenBank:
Аналогичная
структура
Более длинные
ключевые
слова (11)

Продолжение карточки GenBank.

Описание последовательности с 11-й позиции, нумерация,

Ключевое слово ORIGIN

File Edit View Favorites Tools Help

Back Forward Stop Home Search Favorites History Stop Refresh

Address [Http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?CMD=search&DB=PubMed](http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?CMD=search&DB=PubMed)**PubMed**

National Library of Medicine

PubMed Nucleotide Protein Genome Structure PMC

Search: PubMec

for Go Clear

Limits

Preview/Index

History

Clipboard

Details

About Entrez

Toolbox

Entrez

Overview

Help | FAQ

Topics

New/Noteworthy

E-Utilities

PubMed Services

Journal's Database

MeSH Database

Single Citation

Matcher

Batch Citation Matcher

Clinical Queries

LinkOut

Cited by

Related Resources

Order Documents

NLM Gateway

OxNHL

Consumer Health

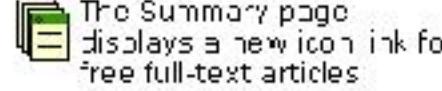
Clinical Alerts

Clinical Trials.gov

PubMed Central

- Enter one or more search terms, or click [Preview/Index](#) for advanced searching
- Enter [author names](#) as Smith, J. Initials are optional
- Enter [journal titles](#) in full or as MEDLINE abbreviations. Use the Journals Database to find journal titles.

PubMed is a service of the National Library of Medicine, providing access to over 12 million MEDLINE citations back to the mid-1960's and additional life science journals. PubMed includes links to many sites providing full text articles and other related resources.

Bookshelf Additions**New PubMed Features**

The Summary page displays a new icon link for free full-text articles

New data and additional search options, including an [e-mail](#) selection, have been added to PubMec. See [New/Noteworthy](#).

Severe Acute Respiratory Syndrome

Citations to articles about [Severe Acute Respiratory Syndrome \(SARS\)](#) are provided during this time of peak interest to facilitate searching this topic.

The screenshot shows the NCBI Genome search interface. The search term 'Homo sapiens' has been entered into the search bar. Below the search bar, a red arrow points from the text 'Текстовый запрос' (Textual query) to the search term. Another red arrow points from the text 'Выбор категории данных' (Selection of data category) to the 'Summary' tab, which is currently selected. The results list shows five entries, each preceded by a checkbox:

- 1: NC_001141**
Saccharomyces cerevisiae chromosome IX, complete chromosome sequence [37]
g: 6422018|ref|NC_001141.1|
- 2: NC_001807**
Homo sapiens mitochondrial, complete genome [12152]
g: 17981352|ref|NC_001807.4|
- 3: NC_004916**
Leishmania tzaifor chromosome 3, complete sequence [17192]
g: 32189599|ref|NC_004916.1|
- 4: NC_004255**
Alphavirus, complete genome [16744]
g: 31152113|ref|NC_004255.1|
- 5: NC_004295**
Human erythrocytic V9, complete genome [16710]
g: 23342515|ref|NC_004295.1|

• Текстовый запрос

Выбор категории данных

The screenshot shows a Microsoft Internet Explorer window displaying the Entrez Genomes interface. The main content area lists seven genome entries:

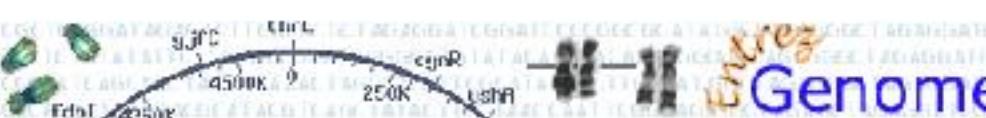
- 1: [N. _00141](#)
Saccharomyces cerevisiae chromosome 2, complete chromosome sequence [27]
g[B3C015] [P_00141]
- 2: [NC_001307](#)
Escherichia coli K12, complete genome [133]
g[17261852] [PNC_001307]
- 3: [N. _004976](#)
Leishmania major chromosome 2, complete sequence [7,82]
g[313999] [P_004976]
- 4: [NC_001233](#)
Arthrobacter aegyptiicola [6,44]
g[2432113] [PNC_001233]
- 5: [N. _004295](#)
Human erythrocyte V9, complete genome [67,0]
g[1323815] [P_004295]
- 6: [NC_005582](#)
Mycoplasmangiganteum, complete genome [14105]
g[253129] [PNC_005582]
- 7: [N. _001973](#)
Acidithiobacillus ferrooxidans [27,0]
g[B9C0845] [P_001973]

The sidebar on the right lists various genome categories:

- Entrez Genomes
- Help
- Submitting
- Genome Project
- Genome sequences
- Microbial Genomes
- Complete Genomes
- List of projects
- PDB neighbors
- Genomic BLAST
- Microbial
- Eukaryotic
- Archaea
- Genome
- Plasmids
- Unfinished
- Bacteria
- Fungi
- Plasmids
- Unfinished
- Eukaryotic
- Genome
- Plasmids
- Organelles
- VIRUSES

A red arrow points from the sidebar menu to the "Genome" link under the "Eukaryotic" section.

Рассмотрим классификация геномов более подробно



ELAST

PubMed

Nucleotide

Protein

Structure

Search Genome

for

Go

Clear

 Limits

Index

History

Clipboard

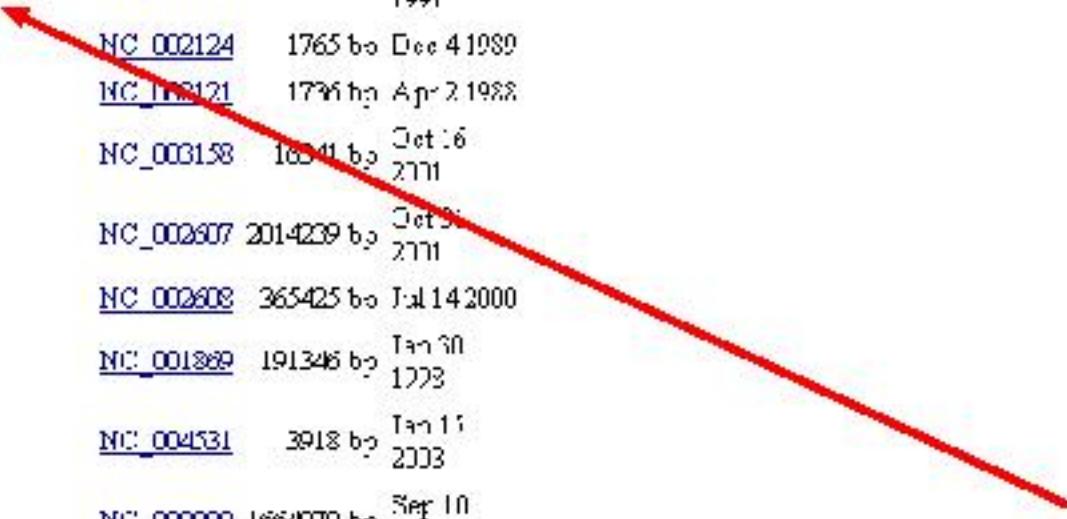
Entrez Genomes

Submitting

Genome
projectGenome
sequenceSequencing
CentersEukaryotic
Genome
ProjectsPlant
Genomes
CentraMicrobial
GenomesComplete
Genomes

Complete Archaea Taxonomy / List 36

Methylophilus permixtus	NC_00854	1699995 bp	Apr 7 2003
Archaeoglobus fulgidus DSM 4304	NC_000917	2178400 bp	Dec 17 1997
Halobacteriaceae LCC-1	NC_002124	1765 bp	Dec 4 1999
Halobacterium salinarum	NC_002121	1796 bp	Apr 2 1998
Halobacterium sp. NRC-1	NC_003158	10341 bp	Oct 16 2001
Halobacterium sp. NRC-1	NC_002607	2014209 bp	Oct 21 2001
Halobacterium sp. NRC-1	NC_002608	365425 bp	Jul 14 2000
Halobacterium sp. NRC-1	NC_001869	191346 bp	Jan 30 1998
Methanococcus jannaschii	NC_004531	3918 bp	Jan 11 2003
Methanococcus jannaschii	NC_000909	1664970 bp	Sep 10 2001
Methanococcus jannaschii	NC_001732	58407 bp	Feb 14 2002
Methanococcus jannaschii	NC_001733	16530 bp	Feb 15 2002
Methanococcus manipulidis	NC_001811	8285 bp	May 7 1997
Methanopyrus kandleri ATCC43219	NC_003551	1694999 bp	Feb 4 2002
Methanopyrus kandleri ATCC43219	NC_000027	5467 bp	Jan 21 2002





NCBI



Taxonomy Browser

PubMed

Entrez

BLAST

OMIM

Taxonomy

Structure

Search for

As complete name

 lock

Go

Clear

Display

3

IEvels using Filter:

none

Archaeoglobus fulgidus DSM 4304

Taxonomy ID: 224325

Rank: no rank

Genetic code: [Translation table 11](#)

Other names:

Archaeoglobus fulgidus str. DSM 4304 [synonym]Lineage (full)cellular organisms; [Archaea](#); [Euryarchaeota](#); [Archaeoglobi](#);[Archaeoglobales](#); [Archaeoglobaceae](#); [Archaeoglobus](#); [Archaeoglobus fulgidus](#)

Comments and References:

[Klenk HP et al. \(1997\)](#)

Klenk, H.P., Clayton, R.A., Tomb, J.-F., White, O., Nelson, K.E., Ketchum, K.A., Dodson, R.J.,

Entrez records

Database name	Direct links
Nucleotide	174
Protein	4827
Genome	1
Taxonomy	1

Более подробная информация о полностью секвенированном геноме архебактерии *A.fulgidus*

NCBI Sequence Viewer Microsoft Internet Explorer

File Edit View Favorites Tools Help

Back Forward Stop Search Favorites History

Address: http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?val=NC_000917

PubMed Nucleotide Protein Genome Structure PDB Taxonomy

Search Nucleotide for: GI Clear

Limits Preview/Index History Clipboard

Display default Show 1 Send to File Get Subsequence Features

1: NC_000917 Archaeoglobus fulgidus DSM 4304 [gi:11497621]

LOCUS NC_000917 3178400 bp DNA circular 3CT 18-JUN-2003

DEFINITION *Archaeoglobus fulgidus* DSM 4304, complete genome.

ACCESSION NC_000917

VERSION NC_000917.1 GI:11497621

KEYWORDS.

SOURCE *Archaeoglobus fulgidus* DSM 4304

ORGANISM *Archaeoglobus fulgidus* DSM 4304
Archaea; Euryarchaeota; Archaeoglobi; Archaeoglobales;
Archaeoglobaceae; Archaeoglobus.

REFERENCE 1 (bases 1 to 3178400)

AUTHORS Klenk, H.P., Clayton, R.A., Tomb, J.-F., White, O., Nelson, K.E., Ketchum, K.A., Dodson, R.J., Swann, M., Hickmey, E.K., Tepcock, J.D., Richardson, D.L., Kerlavage, A.R., Graham, J.E., Kyprides, N.C., Fleischmann, R.D., Ouaknine-Joshi, J., Lee, N.H., Sutton, G.G., Gill, S., Kirkness, E.F., Dougherty, B.A., McKernan, K., Adams, M.D., Loftus, B., Peterson, S., Weisz, U.I., McNeil, L.K., Badger, J.H., Gicdeh, A., Zhou, L., Overbeek, R., Gijsman, J.B., Veldmen, J.F., McDonald, I., Utterback, T., Cotton, M.D., Spriggo, T., Artiach, I., Kaine, B.T., Sykes, S.M., Sadow, P.W., D'Andrea, K.F., Bowman, C., Fujii, C., Garland, S.A., Mason, T.M., Olsen, G.J., Fraser, C.M., Smith, H.O., Woese, C.R. and Venturini, J.C.

TITLE The complete genome sequence of the hyperthermophilic, sulphate-reducing archaeon *Archaeoglobus fulgidus*

JOURNAL Nature 390 (6658), 361-370 (1997)

REVDLINE 93043-43

PUBMED 9389475

Карточка GenBank
генома
архебактерии
A.fulgidus

Рассмотрим карточку GenBank NC_000917 для *A.fulgidus*

LOCUS	NC_000917	2173403 bp	DNA	circular	BCI	13-JUN-2003
DEFINITION	<i>Archaeoglobus fulgidus</i> DSM 4304, complete genome.					
ACCESSION	NC_000917					
VERSION	NC_000917.1	G1:11497621				
KEYWORDS	.					
SOURCE	<i>Archaeoglobus fulgidus</i> DSM 4304					
ORGANISM	<u><i>Archaeoglobus fulgidus</i> DSM 4304</u>					
	Archaeal; Euryarchaeotes; Archaeoglobales; Archaeoglobaceae; Archaeoglobus.					
REFERENCE	1 (bases 1 to 2173403)					
AUTHORS	Klein, H.P., Clayton, R.A., Tam, C.-F., White, O., Nelson, K.E., Retchur, K.A., Dodson, R.J., Swinn, M., Hickley, E.K., Patterson, J.D., Richardson, P.L., Kerlavage, A.R., Graham, D.E., Kyprides, N.V., Fleischmann, R.D., Quashnock, J., Lee, N.H., Sutton, G.G., Gill, S., Kirkness, E.F., Dougherty, B.A., McKenney, K., Adams, M.P., Loftus, B., Peterson, S., Reich, C.I., McNeil, L.K., Badger, J.H., Giardet, I., Zhou, L., Overbeek, R., Godfrey, J.D., Weidman, J.F., McDonald, L., Utterback, T., Cotton, M.D., Spriggs, T., Artiach, P., Raine, D.P., Sykes, S.M., Sadow, P.W., D'Andrea, R.P., Bowman, C., Fujii, C., Bartlani, S.I., Mason, T.W., Olsen, G.J., Fraser, C.M., Smith, H.O., Woese, C.R. and Venter, J.C.					
TITLE	The complete genome sequence of the hyperthermophilic, sulphate-reducing archaeon <i>Archaeoglobus fulgidus</i>					
JOURNAL	Nature 390 (6650), 664-670 (1997)					
MEDLINE	<u>98049343</u>					
PRIMMED	<u>B783475</u>					
COMMENT	PROVISIONAL <u>REFSEQ</u> : This record has not yet been subject to final NCBI review. The reference sequence was derived from <u>AE000782</u> .					
FEATURES	Location/Qualifiers					
source	1..2173403					
	/organism="Archaeoglobus fulgidus DSM 4304"					
	/mol_type="genomic DNA"					
	/db_xref="taxon:224225"					
gene	complement(406..786)					

Рассмотрим далее поля карточки GenBank

FEATURES	Location/Qualifiers
<u>source</u>	1..2178400 /organism="Archaeoglobus fulgidus DSM 4304" /mol_type="Genomic DNA" /db_xref="taxon:224325"
<u>gene</u>	complement(406..786) /locus_tag="AF0001"
<u>CDS</u>	complement(406..786) /locus_tag="AFUUJ1" /note="hypothetical protein; identified by GeneMark; putative" /codon_start=1 /transl_table=11 /product="hypothetical protein" /protein_id=" NP_068342.1 " /db_xref="GI:11437622" /translation="MQLSIDFWSDFNSAEEFVKLFLALSIDFWSDFNSISVSISSM FIFPFSHFGLISTEERKALFGSNPRPQSHFGLISIDTLKEDLRNNLADPFSHFGLIST PRCLPCDPSRRLFCOSHFGLISTIR"
<u>gene</u>	complement(3222..3749) /locus_tag="AFUUJ2"
<u>CDS</u>	complement(3222..3749) /locus_tag="AF0002" /note="hypothetical protein; identified by GeneMark; putative" /codon_start=1 /transl_table=11 /product="hypothetical protein" /protein_id=" NP_068343.1 " /db_xref="GI:11437623" /translation="MKAAASYGVPFO3HFGLISTIRGNDGLPRVVVFQSHFGLISTIVK IVEVLEKDEALSIDFWSDFNSIHLQMDQRIRLAFFQSHFGLISTCTLQTSCTNANFLSI PFWSDFWNLLEKKIEKIEMLFQSHFGL15TRNNVVWGRSELQPA1FQSHFGL15TQ55Q LIMPVKMOTFNPILV"
<u>gene</u>	1200..1784

Продолжение карточки GenBank

```
g:nc complement:21776(3..2178146)
  /locus_tag="AF246"
CDS complement:2177643..2178146
  /locus_tag="AF246"
  /note="identified by sequence similarity; putative"
  /codon_start=1
  /transl_table=11
  /product="conserved hypothetical protein"
  /protein_id="NP_071258.1"
  /db_xref="GI:11500012"
  /db_xref="COG:COG1468"
  /translation="MVEGEELFVRGTEVSTYFVCKTKLULFSRNIAKEHESD2VXLGX
LVHQHFSRDKEVRIGRVALDIVRCEELEVVVEVKEDRMEKADYVQLATVLYVLSK
HQWHLRGPISYPKSRRKNVSVELLENLLVKLKSLKEIKLAKSSSHDPKPEKKSYCTKA
VYELCEB"
```

BASE COUNT 562026 a 527307 g 531003 q 558501 t

۱۰۷

Окончание карточки GenBank

• • •

2

Accession: NC_000517
Total Genes: 2178400 bp
Completed: Dec 17, 1997.

Feature table:
[Protein coding genes](#)
[Structural RNAs](#)

BLAST protein homologs:
[CCGs \(Clusters of Orthologous Groups\)](#)
[3D Structure \(Sequences with known structure\)](#)
[TaxMap \(Sequences grouped by superkingdom\)](#)
[TaxPlot \(3-way genome comparison\)](#)
[CDD \(Conserved Domains Database\)](#)

Contributor: [TIGR](#)

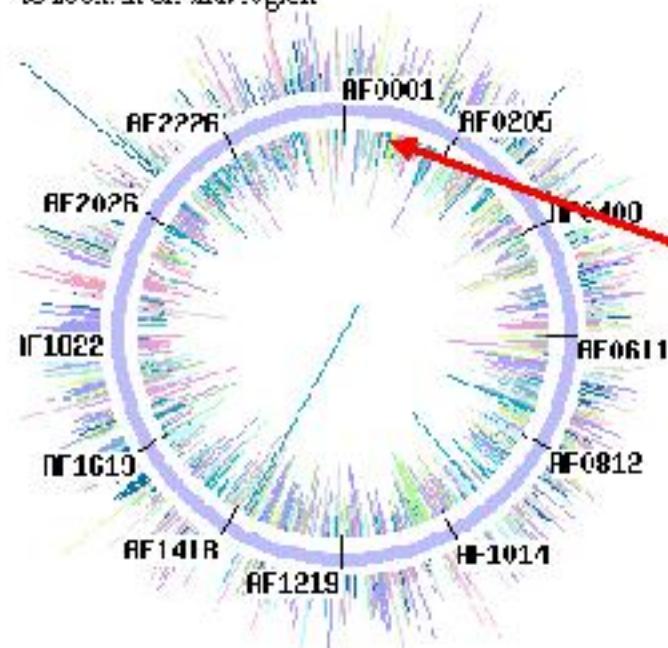
Download chromosome sequence data from [NCBI FTP sites](#)

BLAST your query sequence against the genome ➤

Start from: Go Search for gene: Find

Protein coding genes distribution map

To see map locations of genes, click on a region in the map, to zoom in on that region



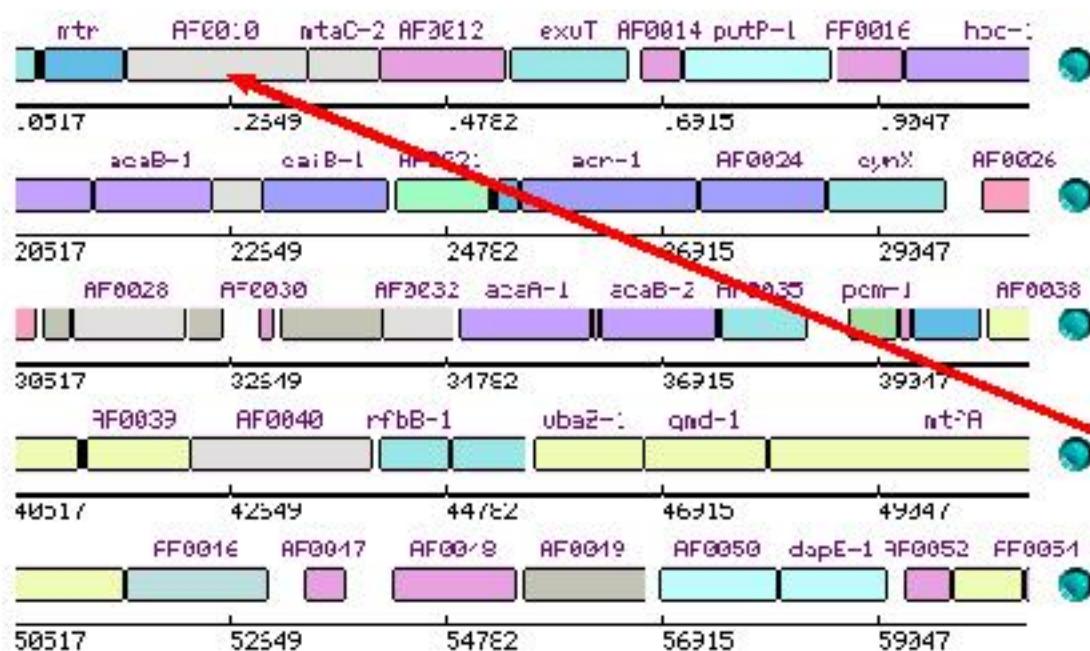
Gene Classification based on COG functional categories

- Translation, ribosomal structure and biogenesis
- Transcription
- DNA replication, recombination and repair
- Cell division and chromosome partitioning
- Post-translational modification, protein turnover, chaperones
- Cell envelope biogenesis, outer membrane
- Cell motility and secretion
- Inorganic ion transport and metabolism
- Signal transduction mechanisms
- Energy production and conversion
- Carbohydrate transport and metabolism
- Amino acid transport and metabolism
- Nucleotide transport and metabolism
- Coenzyme metabolism
- Lipid metabolism
- Secondary metabolites biosynthesis, transport and catabolism
- General function prediction only
- Function unknown
- No COG match

Рассмотрим
графическое
представление
генов в геноме
A.fulgidus

Рассмотрим
район более
подробно

Click on the rectangle to get BLAST neighbors for the gene of interest
or click on the overview below to see a distant region



Указано расположение
генов на
последовательности

Рассмотрим ген
AF0010 более
подробно

- Translation, ribosoma structure and biogenesis
- Transcription
- DNA replication, recombination and repair
- Cell division and chromosome partitioning
- Posttranslational modification, protein turnover
- Cell envelope biogenesis, outer membrane
- Cell motility and secretion
- Inorganic ion transport and metabolism
- Signal transduction mechanisms
- Energy production and conversion
- Carbohydrate transport and metabolism
- Amino acid transport and metabolism
- Nucleotide transport and metabolism
- Coenzyme metabolism
- Lipid metabolism
- Secondary metabolites biosynthesis, transport and catabolism
- General function prediction only
- Function unknown
- No COG match



Рассматриваемый
район на карте генома

Поиск гомологии интегрирован в банк данных GenBank NCBI

Результаты поиска гомологичных генов для AF0010, *A.fulgidus*

Query: [AF0010](#) hypothetical protein [Archaeoglobus fulgidus DSM 1304]
Matching: 2650649, 7463914

COG2871 assigned by Cogulator (7 best hits)

Best hits Common tree phylogeny browser 3D structures COG search Cite

95 BLAST hits in 64 unique species Sort by taxonomic proximity

12 Archaea 82 Bacteria 0 Mitochondria 0 Fungi 1 Plants 0 Viruses 0 Other Eukaryotes

Use only Sort by E-value Select Reset

597 hits

	Accession	E-value	Description
100%	2_ZP_000072	23111570	hypothetical protein [Desulfobacter sp. Strain 10]
100%	2_ZP_000076	23111310	hypothetical protein [Desulfobacterium kishiiense]
100%	2_ZP_000074	23111288	hypothetical protein [Desulfobacterium kishiiense]
100%	2_ZP_00024773	20159210	protein [Desulfobacter sp. Strain 10]
100%	2_ZP_00024770	20515087	hypothetical protein [Thiomicrospira elongata sp. Strain 10]
100%	2_ZP_000558	28167294	A. fulgidus predicted codon usage [ZP0558] [Archaeoglobus fulgidus]
87%	2_MP_1C2E93	3.171508	predicted protein [Archaeal protein] [Archaeoglobus fulgidus]
87%	2_ZP_000077	23111501	PREDICTED PROTEIN [ZP00077] [Archaeoglobus fulgidus]
87%	2_ZP_000078	23111251	hypothetical protein [Archaeoglobus fulgidus]
87%	2_ZP_000079	23111251	hypothetical protein [Archaeoglobus fulgidus]
75%	2_ZP_000501	23737473	hypothetical protein [Closstrilium thermophilum AF0010]
45%	2_ZP_000558	23055585	hypothetical protein [Geobacter metallireducens]
31%	1_AAY742FF	9011555	hypothetical protein (mtr domain) [Methanocaldococcus jannaschii]
31%	1_AAY3113F	20005022	hypothetical protein [Methanocaldococcus jannaschii]
25%	4_ZP_000077	23052981	hypothetical protein [Archaeoglobus fulgidus]

Геномы эукариот в GenBank

Eukaryote Genomes Economy List

Complete genome

- [5] Anopheles gambiae
chromosomes X, 2, 3
 - [5] Arabidopsis thaliana
chromosomes I, II, III, IV, V
 - [5] Caenorhabditis elegans
chromosomes I, II, III, IV, V, X
 - [5] Drosophila melanogaster
chromosomes I, 2, 3, 4, V
 - [11] Encephalitozoon cuniculi genome
chromosomes I, II, III, IV, V, VI, VII, VIII, IX, X, XI
 - [3] Gullardia theta nucleomorph genome
chromosomes I, 2, 3
 - [16] Saccharomyces cerevisiae
chromosomes I, II, III, IV, V, VI, VII, VIII, IX, X, XI, XII, XIII, XIV, XV,
XVI
 - [14] Plasmodium falciparum
chromosomes I, 2, 3, 4, I, 4, 2, 8, 9, 10, 11, 12, 13, 14
 - [3] Schizosaccharomyces pombe

Maps → See genomes in Map Viewer

Vektoren

- [24] *Homo sapiens*
chromosomes: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17,
18, 19, 20, 21, 22, X, Y.
 - [21] *Mus musculus*
chromosomes: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17,
18, 19, X, Y
 - [12] *Rattus norvegicus* (rat)
chromosomes: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17,

Интегрированная система представления данных

[MapViewer Home](#)[MapViewer Help](#)[Human Maps Help](#)[FTP](#)[Data As Table View](#)**Maps & Options** Compress Map

Region Shown:

[Homo sapiens Map View build](#)

33

[BLAST The Human](#)

Genome

Chromosome [1] 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18
21 22 X Y

Master Map: Genes On Sequence

Maps & Options

Total Genes On Chromosome: 3232 [153 not localized]

Region Displayed: 0-245M bp [Download Sequence](#) [View Evidence](#)

Genes Labeled: 20 Total Genes in Region: 3079

Gene	Symbol	LinkOut	Exons	Cyto	Description
DNES5	DNES5	OMIM sv pr cl ev mm ln	C	1p36.1-p36.2 deleted in	
PADD2	PADD2	- sv pr cl ev mm hn	C	1p35.2-p35.1 peptidyl	
LOC284632	LOC284632	- sv pr cl ev mm hn	C	1p36.11 hypothetical	
EPB41	EPB41	OMIM sv pr cl ev mm hn	C	1p33. p32 erythrocyte	
MGC4796	MGC4796	- sv pr cl ev mm hn	C	1p34.2 hypothetical	
KIAA0467	KIAA0467	- sv pr cl ev mm hn	C	1p34.1 KIAA0467	
FLJ12439	FLJ12439	- sv pr cl ev mm ln	C	1p32.3 hypothetical	
FIN1	FIN1	OMIM sv pr cl ev mm hn	C	1p31 protein 3	
KIAA1107	KIAA1107	- sv pr cl ev mm hn	C	1p22.1 KIAA1107	
FLJ11713	FLJ11713	- sv pr cl ev mm hn	C	1p13.1 hypothetical	
HSD3B2	HSD3B2	OMIM sv pr cl ev mm hn	C	1p13.1 hydroxysteroid	
TTC037	TTC037	- sv pr cl ev mm hn	C	1q21 TTC037	
IL6R	IL6R	OMIM sv pr cl ev mm ln	C	1q21 interleukin-6 receptor	
IRTA1	IRTA1	OMIM sv pr cl ev mm hn	C	1q21 immunoreceptor tyrosine	
DKEZP5867.151	DKEZP5867.151	- sv pr cl ev mm hn	C	1q23.1 DKEZP5867.151	

Работа с GenBank**Хромосома I человека**

Европейский институт биоинформатики (EBI)

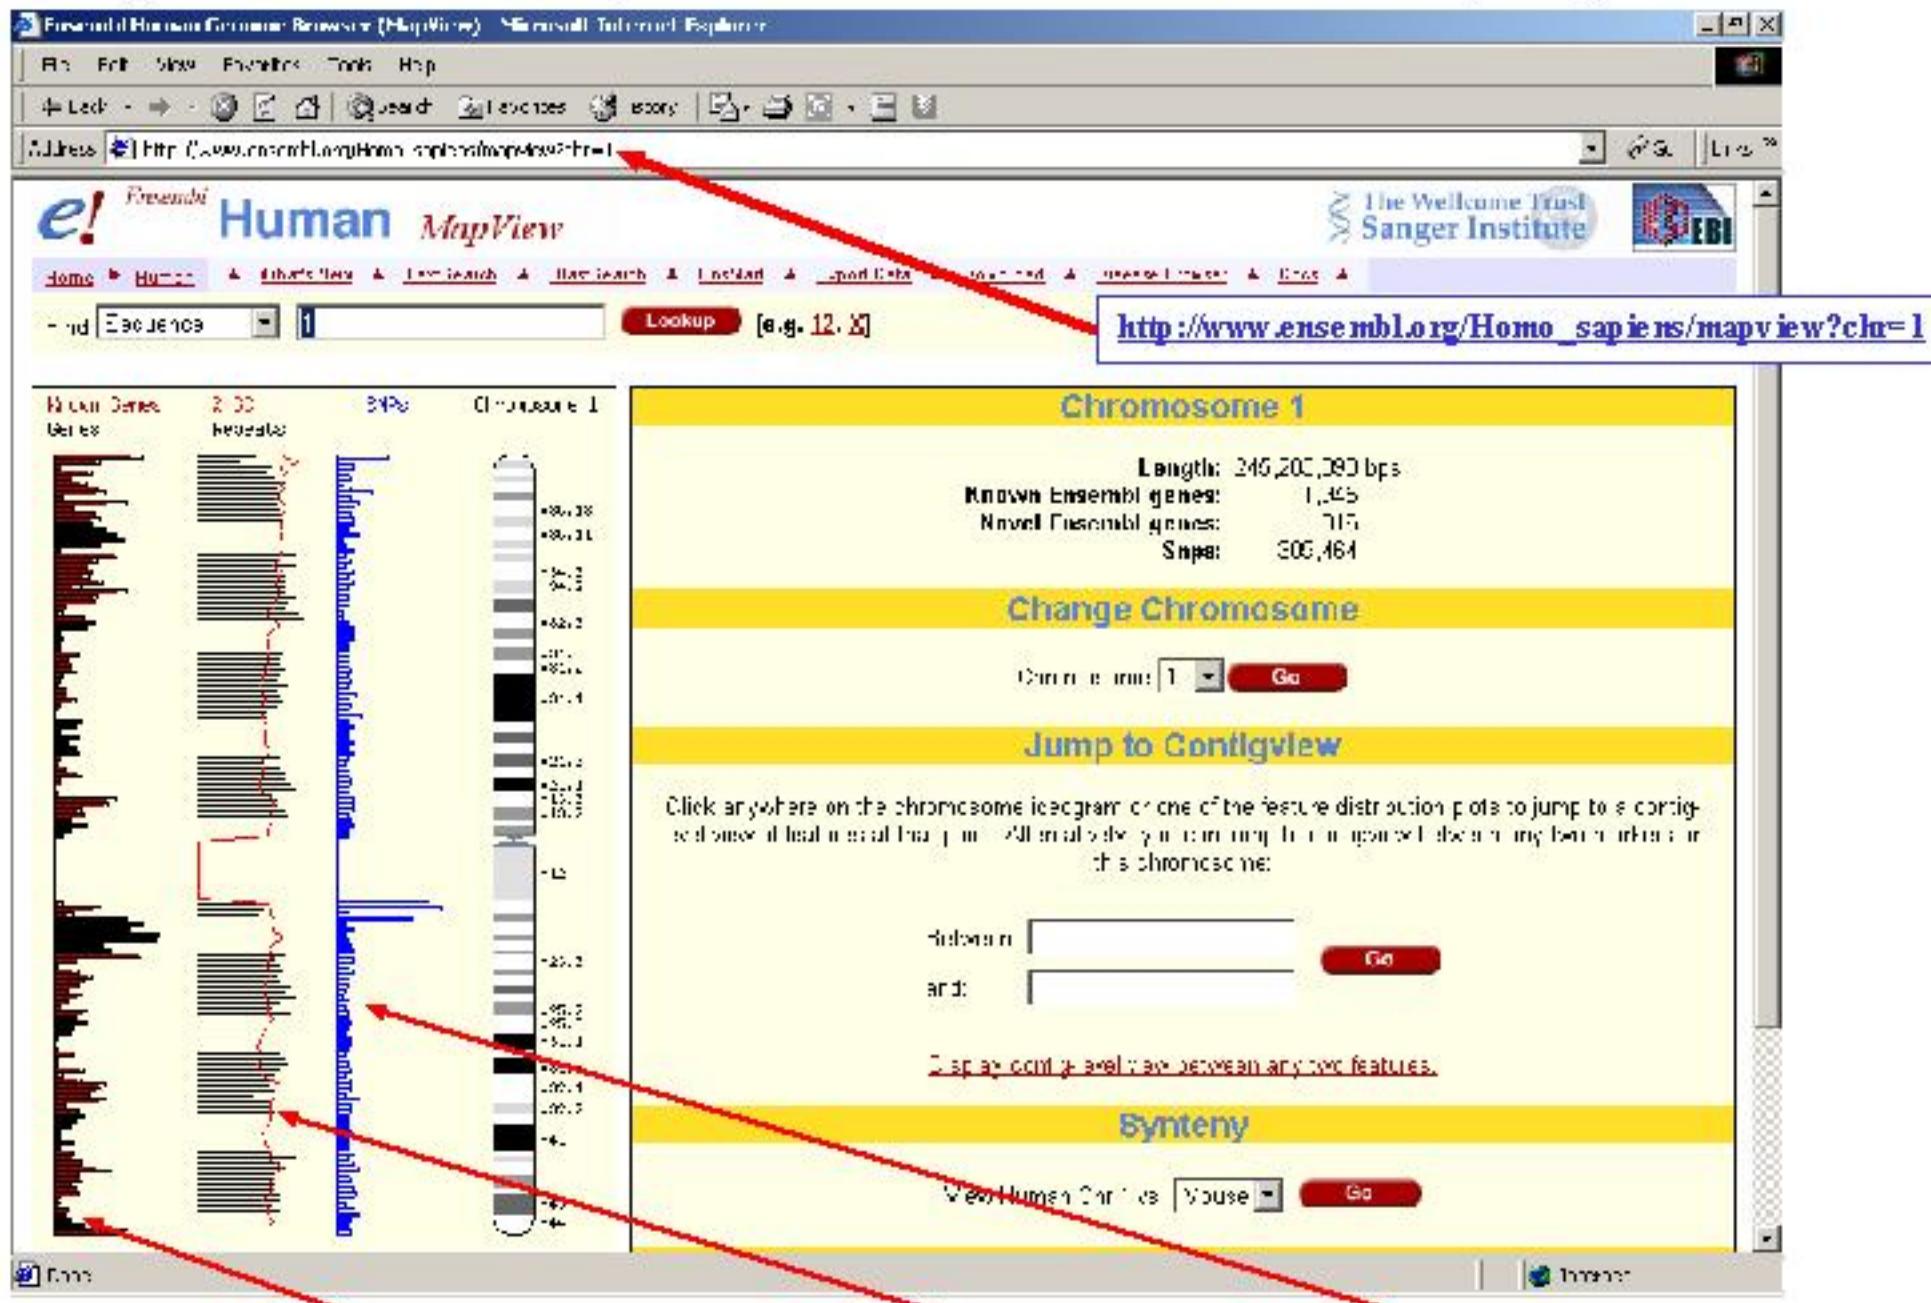
<http://www.ebi.ac.uk>

The screenshot shows the EMBL Nucleotide Sequence Database homepage. At the top, there's a navigation bar with links for File, Edit, View, Reports, Tools, Help, and a search bar. Below that is a toolbar with icons for Back, Forward, Stop, Refresh, Home, and others. The main header features the EMBL-EBI logo and the text "European Bioinformatics Institute". A sub-header reads "EMBL NUCLEOTIDE SEQUENCE DATABASE". The left sidebar has a menu with links for Index, Access, Current data, News, Publications, and Contact. The central content area has a sub-header "EMBL Nucleotide Sequence Database" and a paragraph about the database. It also includes a "TPA" (Third Party Annotation) section and a "NCBI" section. The bottom of the page has a footer with a "LINK" table.

LINK	Description
Access	Completed Genomes Webserver, database files (ERSI) and FTP archives (EMBL release segments)

БД EMBL <http://www.ebi.ac.uk/embl/>

Представление хромосомы I человека на сервере EBI



Информация о плотности генов на хромосоме, GС составе и нуклеотидном полиморфизме

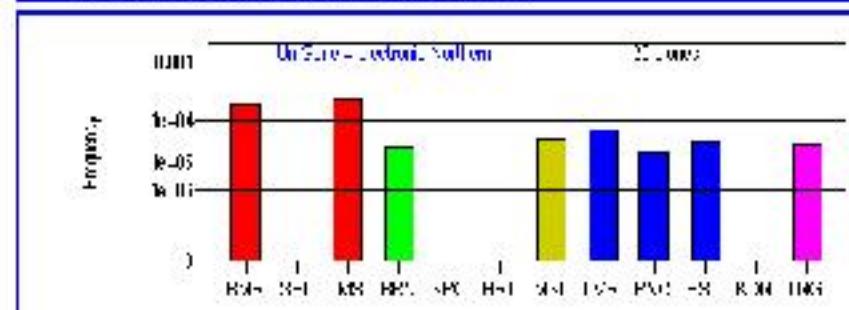
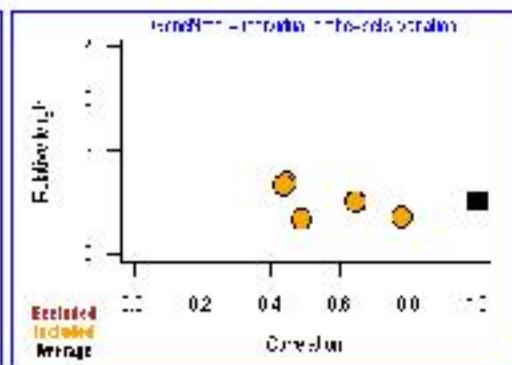
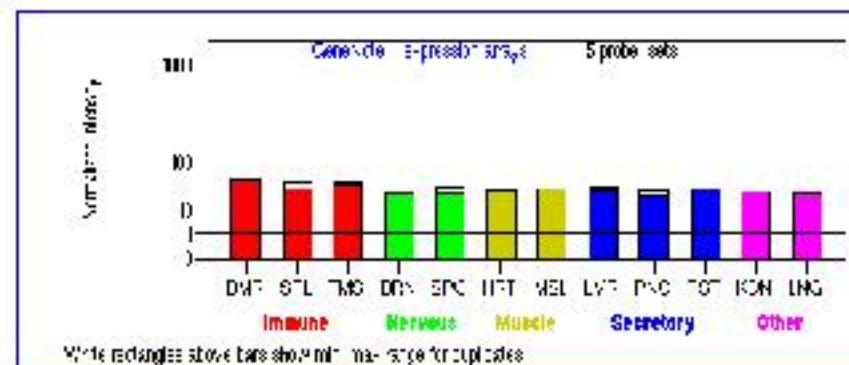
База данных GeneCards (Вейцмановский институт, Израиль)

The screenshot shows the GeneCards interface for the TP53 gene. At the top, there's a navigation bar with links for "GeneCards Home", "GeneCards Database", "Search GeneCards", and "Comment Form". The main content area displays the "GeneCard for gene **TP53** GC17M008311". It includes a brief description: "Approved HGNC-100 Human Gene Nomenclature database symbol: TP53 (tumor protein p53 [Li-Fraumeni syndrome])". Below this, the "Aliases and Additional Descriptions" section lists several names: TP53, TRP53, p53, tumor protein p53 [Li-Fraumeni syndrome], Cellular tumor antigen p53 (tumor suppressor p53), and p53 (Anti-gen NY-OC-13). A previous ID is also mentioned: SCITPC060026. The "Chromosomal Location" section shows the gene's position on chromosome 17, spanning from 8,311,492 to 8,330,670 bp. A genomic map of chromosome 17 is provided, with the TP53 gene highlighted in red. Below the map, specific coordinates are given: Start = 8,311,492 bp from telo, End = 8,330,670 bp from telo.

Основная идея базы GeneCards: анализ и биомедицинских знаний в Интернете и представление их для пользователя.

База данных
GeneCard:
Пример
карточки ген
p53

**Expression
in Human Tissues**
**(Experimental results
according to Geraebol)**
Anisotropic connecting
fibers to Symmetric pos-
sets according to
Geraebol, Electronic
Mechanisms pulsations
according to data from
the Gena Build 130
Home sapiens), other
additions links to
subSIE and/or
WWW-SIE (10)



Tissue	Clones per g/mg	Total clones
BMR	Bone marrow	4
SPL	Spleen	0
TMS	Thymus	1
BRN	Brain	4
SPM	Spinal cord	0
HST	Heart	0
MCL	Skeletal muscle	1
LVR	Liver	6
PNC	Pancreas	1
PST	Prostate	2
KDN	Kidney	0
LNG	Lung	2

Детальная
информация о
генах, включая
данные по SNP,
microarray,
наследственным
заболеваниям

База данных

GeneCard:

Пример карточки гена p53

Disorders & Mutations
(in which this Gene is involved, According to OMIM, SWISS-PROT, GenAtlas, GeneTests, HGMD, BCGD and/or IGD)

OMIM ID: 191170

- search database for MIM named disorders.
- [Colorectal cancer](#)
- [Li-Fraumeni syndrome](#)

SWISS-PROT: P53 | UMAN

- Disease: TP53 is found in increased amounts in a wide variety of transformed cells. TP53 is frequently mutated or inactivated in about 50% of cancers.
- Disease: defects in tp53 are also the cause of germline cancers such as Li-Fraumeni syndrome (LFS) [mim 1911623]. LFS is an abnormal dominant familial cancer syndrome that in its classic form is defined by the existence of both a proband with a sarcoma and two other first-degree relatives with a cancer by age 45 years. In these families the affected relatives develop a diverse set of malignancies including breast carcinomas, sarcomas, and brain tumors at unusually early ages.
- Disease: Variant A-a-143 is temperature sensitive. At 27.5 degrees Celsius it possesses strong DNA binding ability, but at 37.5 degrees Celsius its transcriptional activities are greatly reduced.
- Disease: Defects in TP53 are also the cause of Zollinger-Ellison syndrome (ZE). ZE is a condition in which the normally stratified squamous epithelium of the lower esophagus is replaced by a metaplastic columnar epithelium. This condition develops as a complication in approximately 10% of patients with chronic gastroesophageal reflux disease and predisposes to the development of esophageal adenocarcinoma.
- Disease: Defects in TP53 are the cause of head and neck squamous carcinomas (HNSC) and oral squamous cell carcinomas (OSCC). Cigarette smoke is a primary mutagenic agent in cancer of the head and neck tract.

GeneTests: TP53

- [Li-Fraumeni Syndrome](#)

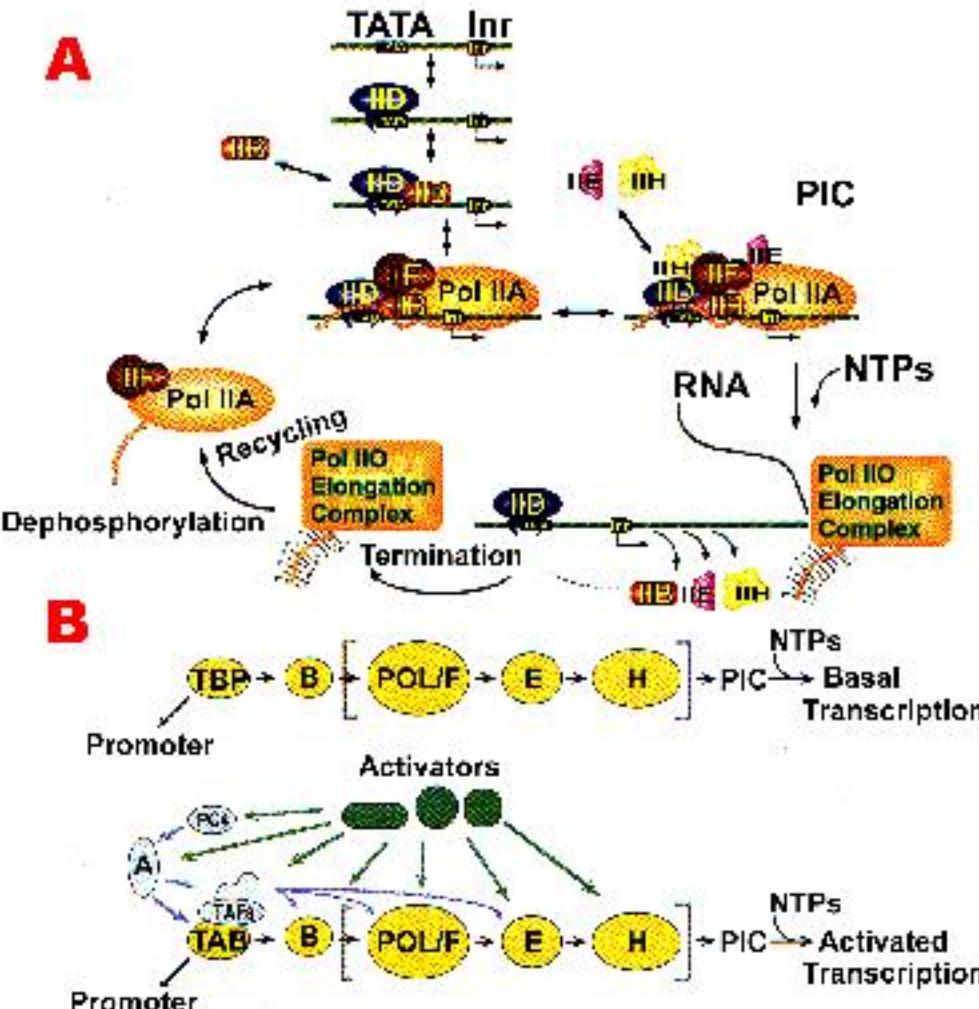
Human Gene Mutation Database entry for TP53

Breast Cancer Gene Database entry for TP53

Информация по мутациям и наследственным заболеваниям

Задачи исследования регуляции генной экспрессии

Следует отметить новые подходы к анализу текстов, связанные с моделированием генных сетей - комплексов взаимодействующих макромолекул, включающих гены и их продукты - РНК, белки и метаболиты. Это новое направление биоинформатики оперирует в качественно иных терминах, связанных с биофизическим и биохимическим моделированием и не затрагивает напрямую анализ самих последовательностей.



Эти задачи будут освещены в
отдельном курсе

Регуляторные геномные
последовательности (РГП)

Список рекомендуемой литературы

Математические методы для анализа последовательностей ДНК. (Под ред. М.С.Уотермена, Перевод с англ. под ред. П.А.Певзнера), Москва, «Мир», 1999.

Франк-Каменецкий М.Д. под ред. (1990) Компьютерный анализ генетических текстов Москва, Наука, 1990, 267 с.

Кель А.Э., Колчанов Н.А., Соловьев В.В. Математическое моделирование в молекулярной биологии и генетике. Теория мутационного процесса: делеции и дупликации. Новосибирск, НГУ, учебное пособие, 1989, 86 с.

David W. Mount «Bioinformatics. Sequence and genome analysis» CSHL Press, New York, 2001.

BLAST By Joseph Bedell, Ian Korf, Mark Yandell. Publisher : O'Reilly, July 2003 (ISBN : 0-596-00299-8) 360 pp.

Durbin R., Eddy S.R., Krogh A., Mitchison G. Biological sequence analysis. 1998, Cambridge: Cambridge University Press, 356 p.

Sequence-Evolution-Function. Computational Approaches in comparative Genomics. (Eds Eugene V. Koonin, Michael Y. Galperin) Kluwer, 2002, 488 pp.

Ресурсы:

ДНК

NCBI (Natl Center Biotech Information) - GenBank <http://www.ncbi.nlm.nih.gov/>

EBI (European Bioinformatics Institute) - EMBL <http://www.ebi.ac.uk/>

ENTREZ <http://www.ncbi.nlm.nih.gov/entrez/query.fcgi>

PUBMED <http://www.ncbi.nlm.nih.gov/pubmed>

DNA Search <http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?db=Nucleotide>

GenBank <http://www.ncbi.nlm.nih.gov/Genbank/GenbankSearch.html>

Выравнивание

BLAST (Basic Local Alignment Sequence Tool) <http://www.ncbi.nlm.nih.gov/blast>

BLAST 2 SEQUENCES <http://www.ncbi.nlm.nih.gov/blast/bl2seq/bl2.html>

Белки

ExPasy (Expert Protein Analysis System, SwissProt, TrEMBL) <http://www.expasy.ch/>

PDB - Protein 3D Structure database <http://www.rcsb.org/pdb/>

Номенклатура IUPAC <http://www.chem.qmul.ac.uk/iupac/misc/naabb.html>

Рекомендуемый ресурс на русском языке

molbiol.ru

Методы, информация и программы для молекулярных биологов.

Поиск



[Вход] [Регистрация]

[ПОГЛАД](#) | [О ПРОЕКТЕ](#) | [СГРАВЧНИК](#) | [МЕТОДЫ](#) | [РАСТВОРЫ](#) | [РАСЧЕТЫ](#) | [ЛИТЕРАТУРА](#) | [Full Text](#) | [СВУЧЕНИЕ](#) | [WEB-РЕСУРСЫ](#)
[ФИРМЫ](#) | [БИОМА](#) | [КАРТА САЙТА](#) | [ПОИСК](#) | [COFFEE BREAK](#) | [РАБОТЕ И УСЛУГИ](#) | [БИРЖА ТРУДА](#) | [ФОРУМ](#)