





Биоинформатические  
подходы к анализу  
РНК.  
Экспрессия генов:  
анализ микроэкранных  
данных



**Лекция  
8**


Многие слайды и материалы используемые в презентации взяты из книги Bioinformatics and Functional Genomics by Jonathan Pevsner Copyright © 2009 by John Wiley & Sons, Inc. и соответствующего курса по биоинформатике Johns Hopkins School of Medicine




Миллер с коллегами (1970, р. 394) визуализировали генную экспрессию. Они показали хромосомную ДНК *Escherichia coli* в процессе транскрипции и трансляции. Темные структуры – полирибосомы на мРНК.

## Дезоксирибонуклеиновая кислота (ДНК) и рибонуклеиновая кислота (РНК).

В то время как ДНК обычно принимает конформацию двойную спиральную, РНК, как правило, одноцепочечна. Заметным исключением является двухцепочечная структура некодирующих РНК, формирующих структуру в виде шпильки.




# Нуклеотидные остатки



# Некодирующие РНК

Несколько ключевых дат:

- 1993 г: демонстрация нового механизма подавления экспрессии: *C.elegans*: гены *lin-4* и *lin-14* (белок LIN-14) антагонисты, но *lin-4* не кодирует белок.



- 1999 г: открытие малых интерферирующих РНК (doi: 10.1126/science.286.5441.950)
- 2000 г: открытие второй микроРНК - *lin-7* (doi: 10.1038/35002607)
- 2001 г: открытие сотни новых малых РНК, появление термина микроРНК (doi: 10.1126/science.1065329)

Первоначально все некодирующие РНК считали малыми; дальнейшие исследования выявили существенные различия по размерам и по функциям.

# Некодирующие РНК (нкРНК)

Большое число и разные функции нкРНК

## Классификация по размерам:

малые нкРНК (sncRNA) - размер до 200 нт (в н.в. известны тысячи)

длинные нкРНК (lncRNA, lincRNA) - размер 200-50 тыс. нт (в н.в. известны десятки тысяч)

очень длинные нкРНК (vlincRNA) - размер от 50 тыс.нт до ~700 тыс.нт (в н.в. известны ~2000-3000) (doi: 10.1186/gb-2013-14-7-r73)

Малые нкРНК - высококонсервативны, длинные нкРНК - низкоконсервативные.

## Наиболее изучены следующие малые нкРНК:

- малые интерферирующие РНК;
- малые ядерные РНК;
- малые ядрышковые РНК;
- малые РНК, образующие комплексы с piwi-белками;
- малые РНК, образующие шпильки;
- микроРНК.

# Малые некодирующие РНК

Наибольшее функциональное значение имеют малые РНК, вовлеченные в процессы генной регуляции - малые интерферирующие РНК (siRNA) и микроРНК (miRNA):

- короткие интерферирующие РНК - длина 20-25 нт
- микроРНК - длина 18-24 нт
  
- ~60% генов человека регулируются микроРНК (doi:10.1016/j.cell.2004.12.035);
- 2014 г: аннотировано ~1900 микроРНК человека; общее число микроРНК может достичь десятков тысяч;
- огромное разнообразие вариантов регуляции:
  - одна miRNA -> несколько mRNA
  - несколько miRNA -> одну mRNA
  - влияние степени комплементарности

Существует значительное число биоинформационных программ для поиска микроРНК и их генов-мишеней

=> необходимо совершенствование расчетных методов поиска микроРНК, их генов-мишеней и других регуляторных участков

Family	Start	End	Bits score
<u>tRNA</u>	9,734,391	9,734,325	31.22
<u>RSV RNA</u>	9,990,192	9,989,909	36.74
<u>RSV RNA</u>	10,142,311	10,142,595	36.83
<u>Metazoa SRP</u>	10,380,661	10,380,378	122.56
<u>SNORA70</u>	10,385,953	10,386,047	42.25
<u>tRNA</u>	10,492,972	10,492,907	26.05
<u>tRNA</u>	10,493,037	10,492,973	37.46
<u>mir-548</u>	11,052,015	11,051,932	82.85
<u>U6</u>	14,419,904	14,420,010	66.41
<u>U6</u>	14,993,898	14,994,004	76.41
<u>U6</u>	15,340,916	15,340,810	63.69
<u>5S rRNA</u>	15,443,192	15,443,307	42.69
<u>pRNA</u>	15,448,359	15,448,271	68.52
<u>U6</u>	16,986,602	16,986,708	75.19
<u>U6</u>	17,407,829	17,407,733	41.70

<u>SNORD74</u>	17,657,089	17,657,017	59.88
<u>mir-10</u>	17,911,414	17,911,485	69.08
<u>let-7</u>	17,912,152	17,912,227	62.65
<u>lin-4</u>	17,962,567	17,962,636	76.22
<u>U1</u>	18,091,317	18,091,476	91.09
<u>U6</u>	18,803,865	18,803,965	62.92
<u>tRNA</u>	18,827,177	18,827,107	63.87
<u>Metazoa SRP</u>	18,878,771	18,879,046	64.51
<u>Y RNA</u>	18,899,565	18,899,458	41.00
<u>Y RNA</u>	18,949,116	18,949,224	40.22
<u>RSV RNA</u>	19,938,102	19,937,818	72.79
<u>U1</u>	20,717,465	20,717,629	93.53
<u>U6</u>	21,728,164	21,728,060	49.35
<u>7SK</u>	21,728,965	21,729,208	75.15
<u>mir-492</u>	21,798,181	21,798,066	40.04
<u>U4</u>	23,577,511	23,577,651	73.90
<u>U2</u>	24,654,231	24,654,058	62.66

**FIGURE 10.4** Noncoding RNA families in the Rfam database that are assigned to human chromosome 21. Only a portion of the entries is shown.

*Bioinformatics and Functional Genomics*, Third Edition, Jonathan Pevsner.  
 © 2015 John Wiley & Sons, Ltd. Published 2015 by John Wiley & Sons, Ltd.  
 Companion Website: [www.wiley.com/go/pevsnerbioinformatics](http://www.wiley.com/go/pevsnerbioinformatics)

<b>МикроРНК</b>	<b>Кол-во генов-мишеней</b>	<b>Гены-мишени</b>	<b>Функции генов-мишеней</b>
hsa-miR-335-5p	15	NOS3, F13B, CYP19A1, LIF, PLAT, ITGA2, ACE, IL6, ESR2, ASPN, NASE4, SERPINB9, KCNH2, RAB11FIP1, LDLR	Регуляция систем свертывания крови, синтеза эстрогенов и иммунных взаимодействий мать-плод; регуляция хондрогенеза, ангиогенеза, поддержание разности потенциалов между внешней и внутренней мембраной клеток; формирование, ориентация и слияние внутриклеточных транспортных везикул, синтез холестерина.
hsa-miR-124-3p	13	IL11, IL6, F13B, AGTR1, GTR2, ASPN, ELF3, IGFBP3, CALR, SNAI2, LDLR, CALU, SYPL1	Регуляция клеточного цикла, артериального давления и системы свертывания крови, регуляция хондрогенеза, синтез холестерина кодирование инсулиноподобного фактора роста, регуляция транскрипции генов рецепторов гормонов, фолдинг белков
hsa-miR-26b-5p	11	AGT, AGTR1, LIF, F13B, GSTP1, ASPN, CXCR4, TK1, RAB11FIP1, C1GALT1C1, COL5A1	Регуляция артериального давления, систем свертывания крови, детоксикации и иммунных взаимодействий мать-плод; регуляция хондрогенеза; формирование, ориентация и слияние внутриклеточных транспортных везикул, синтез коллагена

# Rfam – база данных (<http://rfam.xfam.org/>)



[HOME](#) | [SEARCH](#) | [BROWSE](#) | [FTP](#) | [BLOG](#) | [HELP](#)



## Rfam 12.0 (July 2014, 2450 families)

The Rfam database is a collection of RNA families, each represented by **multiple sequence alignments**, **consensus secondary structures** and **covariance models (CMs)**. [More...](#)

### QUICK LINKS

- [SEQUENCE SEARCH](#)
- [VIEW AN RFAM FAMILY](#)
- [VIEW AN RFAM CLAN](#)
- [KEYWORD SEARCH](#)
- [TAXONOMY SEARCH](#)

### YOU CAN FIND DATA IN RFAM IN VARIOUS WAYS...

- Analyze your RNA sequence for Rfam matches
- View Rfam family annotation and alignments
- View Rfam clan details
- Query Rfam by keywords
- Fetch families or sequences by NCBI taxonomy

### JUMP TO

Enter any type of accession or ID to jump to the page for a Rfam family, sequence or genome

Or view the [help](#) pages for more information

## Citing Rfam


If you find Rfam useful, please consider [citing](#) the references that describe this work:

*Rfam 12.0: updates to the RNA families database.* Eric P. Nawrocki, Sarah W. Burge, Alex Bateman, Jennifer Daub, Ruth Y. Eberhardt, Sean R. Eddy, Evan W. Floden, Paul P. Gardner, Thomas A. Jones, John Tate and Robert D. Finn

*Nucleic Acids Research* (2014) 10.1093/nar/gku1063


# Некодируещи РНК

(a) Rfam sequence space and numbers of families



# Некодируещиe PНК

(b) Rfam taxonomic groupings



**TABLE 10.1** A list of the 13 Rfam entries with the largest number of members. No. full: number of members of the Rfam family (for the full dataset rather than the seed alignment of representative members), rounded to the nearest thousand; Id: the average percent identity of the full alignments.

Name	Accession	No. full	Ave. len. (full)	Id	Type	Description
5_8S_rRNA	RF00002	376,000	152	69	Gene; rRNA	5.8S ribosomal RNA
tRNA	RF00005	298,000	73	46	Gene; tRNA	tRNA
5S_rRNA	RF00001	229,000	116	60	Gene; rRNA	5S ribosomal RNA
UnaL2	RF00436	101,000	54	78	Cis-reg	UnaL2 LINE 3' element
HIV_POL-1_SL	RF01418	83,000	113	77	Cis-reg	HIV pol-1 stem loop
U6	RF00026	72,000	105	77	Gene; snRNA; splicing	U6 spliceosomal RNA
mtDNA ssA	RF01853	62,000	104	67	Gene; antisense	Mitochondrial DNA control region secondary structure A
Intron_gpI	RF00028	60,000	365	36	Intron	Group I catalytic intron
Intron_gpII	RF00029	51,000	87	54	Intron	Group II catalytic intron
Hammerhead_1	RF00163	49,000	59	70	Gene; ribozyme	Hammerhead ribozyme (type I)
RRE	RF00036	44,000	337	97	Cis-reg	HIV Rev response element
HIV_GSL3	RF00376	39,000	84	82	Cis-reg	HIV gag stem loop 3 (GSL3)
SNORA7	RF00409	26,000	140	79	Gene; snRNA; snoRNA; HACA-box	Small nucleolar RNA SNORA7

*Source:* Rfam 11.0. Reproduced under the Creative Commons Zero licence, CC0.

**TABLE 10.2** Summary of the number of tRNA genes in selected organisms. The “other” category refers to selenocysteine tRNAs (TCA), suppressor tRNAs (CTA,TTA), or tRNAs with undetermined or unknown isotypes. Additionally, some organisms have tRNAs with introns (e.g., human, 32; *P. falciparum*, 1; *Arabidopsis*, 83).

Organism	Common name	No. tRNAs decoding the 20 amino acids	No. predicted pseudogenes	Other	Total
<i>Homo sapiens</i>	Human	506	110	9	625
<i>Pan troglodytes</i>	Chimpanzee	456	0	3	459
<i>Mus musculus</i>	Mouse	432	0	3	435
<i>Canis familiaris</i>	Dog (Canfam1)	898	0	8	906
<i>Drosophila melanogaster</i>	Fruit fly	298	4	2	304
<i>Saccharomyces cerevisiae</i>	Baker’s yeast	286	6	3	295
<i>Arabidopsis thaliana</i>	Plant	630	8	1	639
<i>Plasmodium falciparum</i>	Malaria parasite	35	0	0	35
<i>Methanococcus jannaschii</i>	Archaeon	36	0	1	37
<i>Escherichia coli</i> K12	Bacterium	86	1	1	88
<i>Mycobacterium leprae</i>	Bacterium	45	0	0	45

Source:  <http://genome.ucsc.edu>, courtesy of UCSC.

# ТРНК

(a) Isotype / Anticodon Counts:

Ala : 0	AGC:	GGC:	CGC:	TGC:		
Gly : 1	ACC:	GCC: 1	CCC:	TCC:		
Pro : 0	AGG:	GGG:	CGG:	TGG:		
Thr : 0	AGT:	GGT:	CGT:	TGT:		
Val : 0	AAC:	GAC:	CAC:	TAC:		
Ser : 0	AGA:	GGA:	CGA:	TGA:	ACT:	GCT:
Arg : 0	ACG:	GCG:	CCG:	TCG:	CCT:	TCT:
Leu : 0	AAG:	GAG:	CAG:	TAG:	CAA:	TAA:
Phe : 0	AAA:	GAA:				
Asn : 0	ATT:	GTT:				
Lys : 0			CTT:	TTT:		
Asp : 0	ATC:	GTC:				
Glu : 0			CTC:	TTC:		
His : 0	ATG:	GTG:				
Gln : 0			CTG:	TTG:		
Ile : 0	AAT:	GAT:		TAT:		
Met : 0			CAT:			
Tyr : 0	ATA:	GTA:				
Supres: 0			CTA:	TTA:		
Cys : 0	ACA:	GCA:				
Trp : 0			CCA:			
SelCys: 0				TCA:		

(b)

```


Your-seq.trnal (1-71) Length: 71 bp
Type: Gly Anticodon: GCC at 33-35 (33-35) Score: 71.03
Seq: GCATGGGTGGTTTCAGTGGTAGAATTCTCGCCTGCCACGCGGGAGGCCCGGGTTCGATTCCCGGCCCATGCA
Str: >>>>>>...>>>>.....<<<<.>>>>.....<<<<.....>>>>.....<<<<<<<<<<<<.

```

<http://lowelab.ucsc.edu/tRNAscan-SE/>

Кафедра биоинформатики МБФ  
РНИМУ

# ТРНК




<http://lowelab.ucsc.edu/tRNAscan-SE/>

(a) Minimum free energy prediction (colored by base pairing probability): analyzing a tRNA at with Vienna 2.0



(b) Minimum free energy secondary structure




<http://rna.tbi.univie.ac.at/cgi-bin/RNAfold.cgi>

# Экспрессия генов: анализ микроэрейных данных

- Экспрессия генов
- Микрочипы (Microarrays)
- Предварительная обработка
  - нормализация
  - диаграммы рассеяния
- Статистический анализ
  - Т-тест
  - ANOVA
  - расстояния
  - кластеризация
  - анализ главных компонентов (PCA)


# Сравнение экспрессии генов в этом типе клеток ...




...после  
вирусной  
инфекции




... по отношению к  
животному с нокаут  
геном



...с образцами  
от  
пациентов



...после  
применения  
лекарства



...в разное время  
жизни




...в различных  
участках  
тела



# Экспрессия генов зависит от контекста, и регулируется несколькими основными способами

- по тканям и органам (например, мозг по сравнению с почкой)
- в процессе развития (например плода по сравнению с взрослой тканью)
- в динамическом ответе на сигналы внешней среды (например, лекарств)
- при патологических состояниях
- с помощью активности других генов
- эпигенетически



**next-generation sequencing!!!**

Кафедра биоинформатики МБФ  
РНИМУ

# UniGene:

## уникальные гены представленные ESTs

- Unigene в NCBI:  
[www.ncbi.nlm.nih.gov/UniGene](http://www.ncbi.nlm.nih.gov/UniGene)
- Unigene кластеры содержат много ESTs (Expressed Sequence Tags - короткая подпоследовательность кДНК последовательности)
- Данные Unigene приходят из многих библиотек кДНК.
- Таким образом, когда вы смотрите на ген в Unigene вы получите информацию о величине и месте его экспрессии.

UniGene

UniGene

Search

Limits Advanced

Help



## UniGene

UniGene computationally identifies transcripts from the same locus; analyzes expression by tissue, age, and health status; and reports related proteins (protEST) and clone resources.

### Using UniGene

[Getting Started](#)

[FAQ](#)

[Query Tips](#)

[ProtEST](#)

[DDD](#)

[Clustering by transcripts](#)

[Clustering by genomes](#)

### UniGene Tools

[UniGene Statistics](#)

[Library browser](#)

[Digital Differential Display \(DDD\)](#)

[Downloads/FTP](#)

### Also of interest

[BioSample](#)

[EST sequences](#)

[Gene](#)

[HomoloGene](#)

[Map Viewer](#)

[Short Read Archive \(SRA\)](#)

UGID:908333 UniGene Hs.517586 *Homo sapiens* (human) MB

[Order cDNA clone, Links](#)

## Myoglobin (MB)

Human protein-coding gene MB. Represented by 1381 ESTs from 75 cDNA libraries. EST representation biased toward muscle; adult. Corresponds to 3 reference sequences (different isoforms). [UniGene 908333 - Hs.517586]

### SELECTED PROTEIN SIMILARITIES

Comparison of cluster transcripts with RefSeq proteins. The alignments can suggest function of the cluster.

Best Hits and Hits from model organisms		Species	Id(%)	Len(aa)
<a href="#">XP_001156696.1</a>	PREDICTED: myoglobin isoform 7	<i>P. troglodytes</i>	100.0	153
<a href="#">NP_976311.1</a>	MB gene product	<i>H. sapiens</i>	100.0	153
<a href="#">NP_038621.2</a>	Mb gene product	<i>M. musculus</i>	86.4	153
Other hits (2 of 13) <a href="#">[Show all]</a>		Species	Id(%)	Len(aa)
<a href="#">XP_003905518.1</a>	PREDICTED: myoglobin isoform 1	<i>P. anubis</i>	98.7	153
<a href="#">XP_001082215.1</a>	PREDICTED: myoglobin isoform 3	<i>M. mulatta</i>	98.0	153

### GENE EXPRESSION

Tissues and development stages from this gene's sequences survey gene expression. Links to other NCBI expression resources.

Restricted Expression: muscle [\[show more like this\]](#)  
adult [\[show more like this\]](#)

**EST Profile:** Approximate expression patterns inferred from EST sources.  
[\[Show more entries with profiles like this\]](#)

**GEO Profiles:** Experimental gene expression data (Gene Expression Omnibus).

**cDNA Sources:** muscle; heart; uncharacterized tissue; lung; prostate; mouth; mixed; peritoneum; uterus; mammary gland; adrenal gland; thyroid; larynx; liver; eye; ascites; nerve; embryonic tissue; pharynx; thymus; placenta; vascular; esophagus; testis

## EST Profile

Hs.517586 - MB: Myoglobin

### Breakdown by Body Sites

Hs.517586		
adipose tissue	0	0 / 12866
adrenal gland	60	2 / 32940
ascites	75	3 / 39834
bladder	0	0 / 29860
blood	0	0 / 122252
bone	0	0 / 71618
bone marrow	0	0 / 48737
brain	0	0 / 1092688
cervix	0	0 / 48486
connective tissue	0	0 / 149072
ear	0	0 / 16100
embryonic tissue	0	0 / 212896
esophagus	49	1 / 20154
eye	19	4 / 208840
heart	1764	158 / 89524
intestine	0	0 / 231981
kidney	0	0 / 210778
larynx	298	7 / 23466
liver	34	7 / 205291
lung	62	21 / 334815
lymph	0	0 / 44302
lymph node	0	0 / 89748
mammary gland	6	1 / 151230
mouth	120	8 / 66150
muscle	10312	1097 / 106371
nerve	193	3 / 15535
ovary	0	0 / 101488
pancreas	0	0 / 213440

Restricted pools are represented by orange border

Liver	98	13 / 131488
Lung	0	0 / 282332

Pool name      Transcripts per million(TPM)      Spot intensity based on TPM      Gene EST / Total EST in pool

## Breakdown by Health State


Hs.517586		
adrenal tumor	158	2 / 12655
bladder carcinoma	0	0 / 17584
breast (mammary gland) tumor	0	0 / 93090
cervical tumor	0	0 / 34484
chondrosarcoma	0	0 / 82838
colorectal tumor	0	0 / 112517
esophageal tumor	57	1 / 17245
gastrointestinal tumor	25	3 / 118498
germ cell tumor	0	0 / 263230
glioma	0	0 / 107194
head and neck tumor	82	11 / 133826
kidney tumor	0	0 / 68872
leukemia	0	0 / 94479
liver tumor	20	2 / 96023
lung tumor	9	1 / 102765
lymphoma	0	0 / 72196
non-neoplasia	0	0 / 96623
normal	344	1147 / 3328811
ovarian tumor	0	0 / 76185
pancreatic tumor	0	0 / 105004
primitive neuroectodermal tumor...	0	0 / 127001
prostate cancer	38	4 / 103844
retinoblastoma	0	0 / 46439
skin tumor	0	0 / 125373
soft tissue/muscle tissue tumor	7	1 / 125265
uterine tumor	11	1 / 90107

## Breakdown by Developmental Stage

Hs.517586		
embryoid body	0	0 / 69969
blastocyst	0	0 / 61448
fetus	80	45 / 556978
neonate	0	0 / 31070
infant	0	0 / 23511
juvenile	0	0 / 55574
adult	311	598 / 1921829

## **Microarrays: инструмент для измерения экспрессии генов**

микрочипом является твердый носитель (такой как мембрана или предметное стекло микроскопа), на котором ДНК известной последовательности нанесена в виде решетки матрицы.



# Microarrays: инструмент для измерения экспрессии генов



Наиболее распространенная форма микрочипа используется для измерения экспрессии генов. РНК выделяют из образцов, представляющих интерес. РНК, как правило, превращают в кДНК, помеченную флуоресцентной (или радиоактивной) меткой, а затем гибридизуют на микрочип для того, чтобы измерить уровни экспрессии **тысяч генов.**

# Преимущества микроэррейных экспериментов

- **Скорость:** данные о > 20000 транскриптов несколько дней
- **Всесторонность исследования:** весь геном дрожжей или мыши на чипе
- **Гибкость:** Пользовательские микроэрреи могут быть сделаны, для представляющих интерес генов
- **Легкость создания:** Добавление РНК в чип
- **Стоимость?:** Чип, представляющий 20 000 генов за \$ 300

# Недостатки микроэrrayных экспериментов

- **Цена:** Некоторые исследователи не могут позволить себе сделать статистически значимое количество измерений
- **Значимость РНК:**
  - Отсутствие корреляции между экспрессией генов и количеством белка
  - Полная транскрипция генома плохо понимаема
  - Много некодирующих РНК не представлены в микрочипах
- **Контроль качества:**
  - Артефакты при анализе изображения
  - Артефакты при анализе данных
  - Недостаточно внимание к планированию эксперимента
  - Не хватает правильной статистической обработки

**Этап 1:** Экспериментальный дизайн

**Этап 2:** РНК и пробо подготовка


**Этап 3:** Гибридизация с ДНК чипом

**Этап 4:** Анализ изображений

**Этап 5:** Анализ микроэррейных данных

**Этап 6:** Биологическое подтверждение

**Этап 7:** Микроэррейные базы данных



# Этап 1: Экспериментальный дизайн


[1] Биологические образцы: технические и биологические повторы: определить подход к анализу данных с самого начала

[2] Выделение РНК, преобразование, маркировка, гибридизация


[3] Расположение элементов массива на поверхности: рандомизации может уменьшить пространственные артефакты

# Один образец на массив (Affymetrix или платформы на радиоактивных метках)


**Sample 1**



**Sample 2**




**Sample 3**





# Два образца на массив

Samples 1,2



Samples 1,3




## Этап 2: РНК и пробо подготовка

- Для Affymetrix чипов, нужна полная РНК (около 5 мкг)
- Подтвердите чистоту, запустив ее в агарозном геле
- Один из самых больших источников ошибки, связанных с выделением РНК;
- Использование соответствующего сбалансированного, рандомизированного дизайна эксперимента.

# Этап 3: Гибридизация с ДНК чипом

- Массив состоит из кДНК или олигонуклеотидов
- Олигонуклеотиды могут быть нанесены с помощью фотолитографии
- Образец преобразуется в кРНК или кДНК

# Поверхность чипа




## Этап 4: Анализ изображений


- Уровни РНК-транскриптов являются количественными
- Интенсивность флуоресценции или радиоактивности измеряют с помощью сканера

# Дифференциальная генная экспрессия на кДНК микроээррее

Контроль



Синдром Ретта



$\alpha$  B Crystallin гиперэкспрессирован при Синдроме Ретта

# Этап 5: Анализ микроэrrayных данных

- **Проверка гипотезы**


- Как можно сравнить массивы?
- Какие РНК-транскрипты (гены) регулируются?
- Являются ли различия подлинным?
- Каковы критерии для статистической значимости?

- **Кластеризация**

- Есть ли значимые закономерности в данных (например, группы)?

- **Классификация**

- Есть ли у РНК-транскриптов предсказанные заранее группы, такие как подтипы болезней?



Значения экспрессии генов из микроэррейных экспериментов могут быть представлены в виде тепловой карты для визуализации результатов анализа данных

## Этап 6: Биологическое подтверждение

- Микроэкранные эксперименты можно рассматривать как «генераторы гипотез».
- Дифференциальное регулирования РНК-транскриптов может быть измерено с помощью независимых анализов, таких как
  - Нозерн-блот
  - Полимеразная цепная реакция (ПЦР)
  - Гибридизация

# Этап 7: Микроэrrayные базы данных

- Есть две основных базы данных
  - Gene expression omnibus (GEO) в NCBI
  - ArrayExpress в European Bioinformatics Institute (EBI)

# Gene Expression Omnibus



GEO is a public functional genomics data repository supporting MIAME-compliant data submissions. Array- and sequence-based data are accepted. Tools are provided to help users query and download experiments and curated gene expression profiles.

## Getting Started

- [Overview](#)
- [FAQ](#)
- [About GEO DataSets](#)
- [About GEO Profiles](#)
- [About GEO2R Analysis](#)
- [How to Construct a Query](#)
- [How to Download Data](#)

## Tools

- [Search for Studies at GEO DataSets](#)
- [Search for Gene Expression at GEO Profiles](#)
- [Search GEO Documentation](#)
- [Analyze a Study with GEO2R](#)
- [GEO BLAST](#)
- [Programmatic Access](#)
- [FTP Site](#)

## Browse Content

<a href="#">Repository Browser</a>	
DataSets:	3848
Series:	56613
Platforms:	14175
Samples:	1378901

## Information for Submitters

- |   |  |  |
|---|--|--|
| <ul style="list-style-type: none"> <li><a href="#">Login to Submit</a></li> </ul> | <ul style="list-style-type: none"> <li><a href="#">Submission Guidelines</a></li> <li><a href="#">Update Guidelines</a></li> </ul> | <ul style="list-style-type: none"> <li><a href="#">MIAME Standards</a></li> <li><a href="#">Citing and Linking to GEO</a></li> <li><a href="#">Guidelines for Reviewers</a></li> <li><a href="#">GEO Publications</a></li> </ul> |
|---|--|--|

## Search NCBI databases

Help



### Results found in 37 databases for "ubiquitin"

#### Literature

<b>Books</b>	1,009	books and reports
<b>MeSH</b>	333	ontology used for PubMed indexing
<b>NLM Catalog</b>	66	books, journals and more in the NLM Collections
<b>PubMed</b>	43,356	scientific & medical abstracts/citations
<b>PubMed Central</b>	83,307	full-text journal articles

#### Health

<b>ClinVar</b>	3,356	human variations of clinical significance
<b>dbGaP</b>	46	genotype/phenotype interaction studies
<b>GTR</b>	367	genetic testing registry
<b>MedGen</b>	35	medical genetics literature and links
<b>OMIM</b>	985	online mendelian inheritance in man
<b>PubMed Health</b>	9	clinical effectiveness, disease and drug reports

#### Genomes

<b>Assembly</b>	0	genome assembly information
<b>BioProject</b>	261	biological projects providing data to NCBI
<b>BioSample</b>	15	descriptions of biological source materials
<b>Clone</b>	10,754	genomic and cDNA clones
<b>dbVar</b>	33,020	genome structural variation studies

#### Genes

<b>EST</b>	22,145	expressed sequence tag sequences
<b>Gene</b>	159,204	collected information about gene loci
<b>GEO DataSets</b>	615	functional genomics studies
<b>GEO Profiles</b>	2,725,449	gene expression and molecular abundance profiles
<b>HomoloGene</b>	860	homologous gene sets for selected organisms
<b>PopSet</b>	221	sequence sets from phylogenetic and population studies
<b>UniGene</b>	13,193	clusters of expressed transcripts

#### Proteins

<b>Conserved Domains</b>	777	conserved protein domains
<b>Protein</b>	461,008	protein sequences
<b>Protein Clusters</b>	888	sequence similarity-based protein clusters
<b>Structure</b>	2,585	experimentally-determined biomolecular structures

#### Chemicals

<b>BioSystems</b>	18,804	molecular pathways with links to genes, proteins and chemicals
<b>PubChem BioAssay</b>	12,636	bioactivity screening studies
<b>PubChem Compound</b>	9	chemical information with structures, information and links


GEO Profiles

GEO Profiles

Search

[Advanced](#)

[Help](#)



## GEO Profiles

This database stores individual gene expression profiles from curated DataSets in the Gene Expression Omnibus (GEO) repository. Search for specific profiles of interest based on gene annotation or pre-computed profile characteristics.

### Getting Started

[GEO Documentation](#)

[GEO FAQ](#)

[About GEO Profiles](#)

[Construct a Query](#)

[Download Options](#)

### GEO Tools

[Submit to GEO](#)

[Advanced Search](#)

[DataSet Browser](#)

[Programmatic Access](#)

### More Resources

[GEO Home](#)

[GEO DataSets](#)

[Epigenomics](#)

[SRA](#)

### Example Searches

Gene symbol

[CYP1A1\[Gene Symbol\]](#)

Gene symbols in DataSets that contain specific keywords

[\(CYP1A1\[Gene Symbol\] OR ME1\[Gene Symbol\]\) AND \(smok\\* OR diet\)](#)

Partial gene name in a specific DataSet

[kinase\[Gene Description\] AND GDS182](#)

Gene Ontology(GO) term in a specific DataSet

[apoptosis\[Gene Ontology\] AND GDS182](#)

Chromosome region and species

[\(8\[Chromosome\] AND 10000:3000000\[Base Position\]\) AND mouse\[organism\]](#)

Genes that show subset effects in DataSets that examine the effect of an agent

[agent\[Flag Information\] AND "value subset effect"\[Flag Type\]](#)

GEO Profiles

GEO Profiles

ubiquitin

Search

Save search Advanced

Help

Show additional filters

Display Settings: Summary, 20 per page, Sorted by Subgroup effect

Send to:

Filters: Manage Filters

Gene symbol

Select ...

Gene keyword

Select ...

Organism

Select ...

Gene ontology

Select ...

Differential expression

Up/down genes

DataSet keyword

Select ...

GEO accession

Select ...

Clear all


Show additional filters

Results: 1 to 20 of 2725449

<< First < Prev Page 1 of 136273 Next > Last >>


1. [UBD - Alcoholic hepatitis](#)

Annotation: UBD, **ubiquitin** D (multiple annotations exist)  
 Organism: Homo sapiens  
 Reporter: GPL570, 205890\_s\_at (ID\_REF), GDS4389, 10537 (Gene ID), 2550 (Gene ID), NM\_006398  
 DataSet type: Expression profiling by array, transformed count, 22 samples  
 ID: 85455638  
[GEO DataSets](#) [Gene](#) [UniGene](#) [Profile neighbors](#) [Chromosome neighbors](#)  
[Sequence neighbors](#)




2. [HSPA1B - Modeled microgravity effect on activated T lymphocytes](#)

Annotation: HSPA1B, heat shock 70kDa protein 1B (multiple annotations exist)  
 Organism: Homo sapiens  
 Reporter: GPL96, 200800\_s\_at (ID\_REF), GDS1806, 3303 (Gene ID), 3304 (Gene ID), NM\_005345  
 DataSet type: Expression profiling by array, transformed count, 6 samples  
 ID: 20229428  
[GEO DataSets](#) [Gene](#) [UniGene](#) [Profile neighbors](#) [Chromosome neighbors](#)  
[Sequence neighbors](#) [Homologene neighbors](#)



3. [HERC5 - Extracellular matrix protein cysteine rich 61 \(CCN1\) effect on LN229 glioma cells](#)

Annotation: HERC5, HECT and RLD domain containing E3 **ubiquitin** protein ligase 5  
 Organism: Homo sapiens  
 Reporter: GPL570, 205890\_s\_at (ID\_REF), GDS4389, 10537 (Gene ID), 2550 (Gene ID), NM\_006398



Profile data

Download profile data

Profile pathways

Find pathways

Find related data

Database: Select

Find items

Search details

ubiquitin[All Fields]

Search

See more...

GEO Profiles

GEO Profiles

Search

Advanced

Help

Display Settings:  Summary

Send to:

[Ufd1l - 22q11 microdeletion syndrome model: hippocampus](#)

Annotation: Ufd1l, **ubiquitin** fusion degradation 1 like

Organism: *Mus musculus*

Reporter: GPL1261, 418087\_at (ID\_REF), GDS3479, 22230 (Gene ID), BC006630

DataSet type: Expression profiling by array, transformed count, 20 samples

ID: 58037418

[GEO DataSets](#)

[Gene](#)


[UniGene](#)

[Profile neighbors](#)

[Chromosome neighbors](#)

[Sequence neighbors](#)

[Homologene neighbors](#)



Profile data

Download profile data

Profile pathways

Find pathways

Related information

[GEO DataSets](#)

[Gene](#)

[UniGene](#)

[Profile neighbors](#)

[Chromosome neighbors](#)

[Sequence neighbors](#)

[Homologene neighbors](#)

[Free in PMC](#)

[HomoloGene](#)

[Pathways + GO](#)

[PubMed](#)

[Taxonomy](#)

[Nucleotide](#)

Scope:  Format:  Amount:  GEO accession:

**Platform GPL1261**
[Query DataSets for GPL1261](#)

Status	Public on May 25, 2004
Title	[Mouse430_2] Affymetrix Mouse Genome 430 2.0 Array
Technology type	in situ oligonucleotide
Distribution	commercial
Organism	<a href="#">Mus musculus</a>
Manufacturer	Affymetrix
Manufacture protocol	see manufacturer's web site

All probe sets represented on the GeneChip Mouse Expression Set 430 are included on the GeneChip Mouse Genome 430 2.0 Array. The sequences from which these probe sets were derived were selected from GenBank, dbEST, and RefSeq. The sequence clusters were created from the UniGene database (Build 107, June 2002) and then refined by analysis and comparison with the publicly available draft assembly of the mouse genome from the Whitehead Institute for Genome Research (MGSC, April 2002).

Description Affymetrix submissions are typically submitted to GEO using the GEOarchive method described at [http://www.ncbi.nlm.nih.gov/projects/geo/info/geo\\_affy.html](http://www.ncbi.nlm.nih.gov/projects/geo/info/geo_affy.html)

June 03, 2009: annotation table updated with netaffx build 28  
 June 07, 2012: annotation table updated with netaffx build 32

GEO Profiles

GEO Profiles

Search

Advanced

Help

Display Settings: Summary

[Ufd1l - 22q11 microdeletion syndrome model: hippocampus](#)

Annotation: Ufd1l, **ubiquitin** fusion degradation 1 like

Organism: Mus musculus

Reporter: GPL1261, 1418087\_at (ID\_REF), GDS3479, 22230 (Gene ID), BC006630


DataSet type: Expression profiling by array, transformed count, 20 samples

ID: 58037418

[GEO DataSets](#) [Gene](#) [UniGene](#) [Profile neighbors](#) [Chromosome neighbors](#) [Sequence neighbors](#)

[Homologene neighbors](#)

Send to:



Profile data

Download profile data

Profile pathways

Find pathways

Related information

[GEO DataSets](#)

[Gene](#)

[UniGene](#)

[Profile neighbors](#)

[Chromosome neighbors](#)

[Sequence neighbors](#)

[Homologene neighbors](#)

[Free in PMC](#)

[HomoloGene](#)

[Pathways + GO](#)

[PubMed](#)

[Taxonomy](#)


[Nucleotide](#)

Search for

**DataSet Record GDS3479:** [Expression Profiles](#) [Data Analysis Tools](#) [Sample Subsets](#)

<b>Title:</b>	22q11 microdeletion syndrome model: hippocampus		
<b>Summary:</b>	Analysis of hippocampi of Df(16)A/+ animals. Df(16)A/+ animals carry microdeletions of about 1.3Mb in the locus syntenic to human 22q11.2. Individuals with 22q11.2 microdeletions show behavioral and cognitive deficits and are at high risk of developing schizophrenia.		
<b>Organism:</b>	<i>Mus musculus</i>		
<b>Platform:</b>	GPL1261: [Mouse430_2] Affymetrix Mouse Genome 430 2.0 Array		
<b>Citations:</b>	<p>Stark KL, Xu B, Bagchi A, Lai WS et al. Altered brain microRNA biogenesis contributes to phenotypic deficits in a 22q11-deletion mouse model. <i>Nat Genet</i> 2008 Jun;40(6):751-60. PMID: 18469815</p> <p>Xu B, Hsu PK, Stark KL, Karayiorgou M et al. Derepression of a neuronal inhibitor due to miRNA dysregulation in a schizophrenia-related microdeletion. <i>Cell</i> 2013 Jan 17;152(1-2):262-75. PMID: 23332760</p>		
<b>Reference Series:</b>	<a href="#">GSE10784</a>	<b>Sample count:</b>	20
<b>Value type:</b>	transformed count	<b>Series published:</b>	2008/04/10

Cluster Analysis



Download

- 
- 
- 
- 
- 

**Data Analysis Tools**

Find genes [?](#)

Compare 2 sets of samples

Cluster heatmaps

Experiment design and value distribution

Find gene name or symbol:

Find genes that are up/down for this condition(s):  strain

GEO Profiles

GEO Profiles ▾

Search

Advanced

Help

Display Settings:  Summary

[Ufd1l - 22q11 microdeletion syndrome model: hippocampus](#)

Annotation: *Ufd1l*, **ubiquitin** fusion degradation 1 like

Organism: *Mus musculus*

Reporter: GPL1261, 1418087\_at (ID\_REF), GDS3479, 22230 (Gene ID), BC006630


DataSet type: Expression profiling by array, transformed count, 20 samples

ID: 58037418

[GEO DataSets](#) [Gene](#) [UniGene](#) [Profile neighbors](#) [Chromosome neighbors](#) [Sequence neighbors](#)

[Homologene neighbors](#)

Send to: ▾



Profile data

Download profile data

Profile pathways

Find pathways


Related information

- [GEO DataSets](#)
- [Gene](#)
- [UniGene](#)
- [Profile neighbors](#)
- [Chromosome neighbors](#)
- [Sequence neighbors](#)
- [Homologene neighbors](#)
- [Free in PMC](#)
- [HomoloGene](#)
- [Pathways + GO](#)
- [PubMed](#)
- [Taxonomy](#)
- [Nucleotide](#)

**Profile** GDS3479 / 1418087\_at / Ufd11

**Title** 22q11 microdeletion syndrome model: hippocampus

**Organism** Mus musculus



[Graph caption help](#)

Sample	Title	Value	Rank
<a href="#">GSM272346</a>	wt_HPC, biological replicate 1	10.5267	93
<a href="#">GSM272347</a>	wt_HPC, biological replicate 2	10.5365	93
<a href="#">GSM272348</a>	wt_HPC, biological replicate 3	10.5658	93
<a href="#">GSM272349</a>	wt_HPC, biological replicate 4	10.4711	93
<a href="#">GSM272353</a>	wt_HPC, biological replicate 5	10.3992	93
<a href="#">GSM272355</a>	wt_HPC, biological replicate 6	10.4112	92

# Array Express B European Bioinformatics Institute

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

EMBL-EBI  Services Research Training About us

 ArrayExpress

Examples: [E-MEXP-31](#), [cancer](#), [p53](#), [Geuvadis](#)

Home Browse Submit Help About ArrayExpress

## ArrayExpress – functional genomics data

ArrayExpress Archive of Functional Genomics Data stores data from high-throughput functional genomics experiments, and provides these data for reuse to the research community.

[Browse ArrayExpress](#)

### Data Content

Updated yesterday at 07:00

- 57054 experiments
- 1677069 assays
- 28.07 TB of archived data

### Latest News

17 February 2015 - **RNA-seq expression data of many human cancer cell lines now available in ArrayExpress and Expression Atlas**

Have you ever wondered if a commonly used cancer cell line (e.g. [MCF-7](#)) shows similar gene expression patterns when profiled in different labs? Or how about the gene expression patterns across a series of cell line models for the same cancer (e.g. [B-cell lymphoma](#))? Two new RNA-seq data sets in ArrayExpress will shed some light on these questions: [RNA-seq of 675 commonly used human cancer cell lines](#) from Genentech, and [RNA-seq of 39 human cancer cell lines that are in the NCI-60 set](#) from the [Cancer Cell Line Encyclopedia](#) at the Broad Institute.

For those of you who are unsure about how to analyse this large amount of data, we've done the legwork for you: both data sets have been carefully curated, and then processed by our in-house statistical analysis pipeline at EMBL-EBI. The results are publicly available from the Expression Atlas ([Genentech data](#), [Broad data](#)), where you will find FPKM values for genes and be able to browse/filter data by cell line, tissue origin of the cancer, or disease type on the interactive graphical user interface. Happy mining!

p53

Search

Examples: [E-MEXP-31](#), [cancer](#), [p53](#), [Geuvadis](#)[Advanced](#)

Filter search results

Search results for **p53**

+ Show more data from EMBL-EBI

Page **1** 2 3 4 5 6 .. 30Showing **1 - 25** of **741** experimentsPage size **25** 50 100 250 500

Accession	Title	Type	Organism	Assays	Released	Processed	Raw	Views	Atlas
<a href="#">E-GEOD-63731</a>	Transcriptome study of P5424 T-cell line	transcription profiling by array	Mus musculus	2	09/04/2015	<a href="#">↓</a>	-	10	-
<a href="#">E-GEOD-51557</a>	DNA methylation profiling in the Carolina Breast Cancer Study	methylation profiling by array	Homo sapiens	526	07/04/2015	<a href="#">↓</a>	-	19	-
<a href="#">E-GEOD-63252</a>	Induction of ER stress in HCT116 colon cancer cells	transcription profiling by array	Homo sapiens	27	01/04/2015	<a href="#">↓</a>	<a href="#">↓</a>	26	-
<a href="#">E-GEOD-62673</a>	Transcription profiling by array of human MCF-7 and PC3 cells grown under amino acid deprived or rich conditions for 24 or 48 hours	transcription profiling by array	Homo sapiens	94	01/04/2015	<a href="#">↓</a>	<a href="#">↓</a>	8	-
<a href="#">E-GEOD-57240</a>	Expression analysis of p53 <sup>-/-</sup> and p53 <sup>-/-</sup> , Ha-RasV12-transformed MEFs upon E4F1 gene inactivation	transcription profiling by array	Mus musculus	24	01/04/2015	<a href="#">↓</a>	<a href="#">↓</a>	3	-
<a href="#">E-GEOD-62533</a>	Inhibitor of apoptosis proteins as promising therapeutic targets in chronic lymphocytic leukemia	transcription profiling by array	Homo sapiens	12	31/03/2015	<a href="#">↓</a>	<a href="#">↓</a>	8	-
<a href="#">E-GEOD-67358</a>	Promotion of pancreatic cancer	transcription profiling	Mus musculus	19	28/03/2015	<a href="#">↓</a>	<a href="#">↓</a>	6	-



p53

Search

Examples: [E-MEXP-31](#), [cancer](#), [p53](#), [Geuvadis](#)[Advanced](#)[ArrayExpress](#) > [Search results for "p53"](#) > E-GEOD-63731

## E-GEOD-63731 - Transcriptome study of P5424 T-cell line

Status	Released on 9 April 2015, last updated on 10 April 2015	
Organism	Mus musculus	
Samples (2)	<a href="#">Click for detailed sample information and links to data</a> ↳ found inside: Rag2 and <b>P53</b> knockout	
Array (1)	<a href="#">A-GEOD-13912 - Agilent-028005 SurePrint G3 Mouse GE 8x60K Microarray (Feature Number version)</a>	
Protocols (7)	<a href="#">Click for detailed protocol information</a>	
Description	P5424 T-cell line was observed transcriptome in two replicates Total RNAs were extracted from 2 samples of P5424 T-cell line and were profiled in replicate after hybridization with Agilent SurePrint G3 Mouse GE 8x60K	
Experiment type	transcription profiling by array	
Contacts	Aurélien Griffon, Lan T Dao, Laurent Vanhille, Nicolas Fernandez, Salvatore Spicuglia	
MIAME	 <a href="#">Platforms</a> <a href="#">Protocols</a> <a href="#">Variables</a> <a href="#">Processed</a> <a href="#">Raw</a>	
Files	Investigation description	<a href="#">E-GEOD-63731.idf.txt</a>
	Sample and data relationship	<a href="#">E-GEOD-63731.sdrf.txt</a>

# Expression Atlas (EMBL)

## <https://www.ebi.ac.uk/gxa/home>

Enter gene query...

Search

Examples: [ASPM](#), [REACT\\_284558](#), [ENSMUSG00000021789](#), "zinc finger"

## Expression Atlas: Differential and Baseline Expression

The Expression Atlas provides information on gene expression patterns under different biological conditions. Gene expression data is re-analysed in-house to detect genes showing interesting baseline and differential expression patterns. [Read more about Expression Atlas.](#)

### Search...

<b>Gene query ?</b>	<b>Organism</b>	<b>Sample properties ?</b>	<b>Search</b>
<input type="text" value="Enter gene query..."/>	<input type="text" value="Homo sapiens"/>	<input type="text" value="Enter condition query..."/>	<b>Reset</b>
<small>E.g. <a href="#">SFTPA2</a>, <a href="#">zinc finger</a></small>		<small>E.g. <a href="#">lung</a>, <a href="#">leaf</a>, "valproic acid", <a href="#">cancer</a></small>	
<input checked="" type="checkbox"/> <b>Exact match</b>			

### Browse...

#### Baseline Experiments

See all baseline expression data sets in Expression Atlas.

#### Plant Experiments

See all expression data sets in plants in Expression Atlas.

#### All Experiments

Scroll through the complete list of all data sets in Expression Atlas.

### iRAP: RNA-seq analysis tool

iRAP is a flexible pipeline for RNA-seq analysis that integrates many existing tools for filtering and mapping reads, quantifying expression and testing for differential expression. iRAP is used to process all RNA-seq data in Expression Atlas.

### Publications

 [RNA-Seq Gene Profiling - A Systematic Empirical Comparison](#) (*PLoS One*, 2014).

 [Expression Atlas update - a database of gene and transcript expression from microarray and sequencing-based functional genomics experiments](#) (*Nucleic Acids Research*, 2014).



# Expression Atlas

Enter gene query...

Search

Examples: [ASPM](#), [REACT\\_284558](#), [ENSMUSG00000021789](#), "zinc finger"
[Home](#) [Release notes](#) [FAQs](#) [Download](#) [Help](#) [About](#) [Feedback](#)
Expression Atlas results for [ENSG00000185303](#)
[+ Show more data from EMBL-EBI](#)

**SFTPA2** *Homo sapiens* surfactant protein A2
**Synonyms** [COLEC5](#), [SP-A2](#)**Orthologs** [ENSCAFG00000015754](#) (*Canis familiaris*), [hbl4](#) (*Danio rerio*), [hbl3](#) (*Danio rerio*), [hbl1](#) (*Danio rerio*), [ENSDARG00000070813](#) (*Danio rerio*), [hbl2](#) (*Danio rerio*), [SFTPA1](#) (*Equus caballus*), [LL](#) (*Gallus gallus*), [SFTPA1](#) (*Macaca mulatta*), [ENSMMUG00000030564](#) (*Macaca mulatta*), [Sftpa1](#) (*Mus musculus*), [Sftpa1](#) (*Rattus norvegicus*), [SFTPA](#) (*Sus scrofa*), [sftpa](#) (*Xenopus tropicalis*)**Gene Ontology** [respiratory gaseous exchange](#), [proteinaceous extracellular matrix](#), [extracellular space](#), [carbohydrate binding](#), [protein complex](#) (... and 5 more)**InterPro** [C-type lectin \(domain\)](#), [Collagen triple helix repeat \(repeat\)](#), [C-type lectin fold \(domain\)](#)**Ensembl Family** [PULMONARY SURFACTANT ASSOCIATED A PRECURSOR PSAP PSP A SP A](#)**Ensembl Gene** [ENSG00000185303](#)**Entrez** [729238](#)**UniProt** [Q8IWL1](#), [R4GMN3](#), [X6REF7](#)**Gene Biotype** [protein\\_coding](#)**Design Element** [218835\\_at](#), [223678\\_s\\_at](#), [3253941](#), [3254074](#), [3254080](#), [3297057](#), [3297058](#), [3297060](#), [3297071](#), [3297073](#), [3297075](#), [3297077](#), [3297124](#), [3297130](#), [3297131](#), [3297136](#), [3297137](#), [3297138](#), [3297140](#), [A\\_23\\_P115652](#), [A\\_24\\_P223874](#), [A\\_33\\_P3268919](#), [A\\_33\\_P3344574](#), [M13686\\_s\\_at](#), [M68519\\_ma1\\_at](#), [g13346505\\_3p\\_at](#), [g190669\\_3p\\_s\\_at](#)


# Expression Atlas results for *ENSG00000185303*

+ Show more data from EMBL-EBI

**SFTPA2** *Homo sapiens* surfactant protein A2

**Baseline Expression** Results found

FPKM/TPM (Transcriptomics) > 0.5      Within Sample Abundance (Proteomics) > 0



Showing 3 of 3 experiments found:



Experiment	adipose tissue	adrenal gland	animal ovary	appendix	bladder	bone marrow	brain	breast	cerebellum	cerebral cortex	colon	duodenum
XXX <a href="#">Tissues - 32 Uhlen's Lab</a>							NA	NA	NA			
XXX <a href="#">Tissues - Illumina Body Map</a>				NA	NA	NA			NA	NA		NA
XXX <a href="#">Tissues - Mammalian Kaessmann</a>	NA	NA	NA	NA	NA	NA	NA	NA		NA	NA	NA

## Expression Atlas results for *ENSG00000185303*

[+ Show more data from EMBL-EBI](#)

 **SFTPA2** *Homo sapiens* surfactant protein A2 +

 **Baseline Expression** [Results found](#) +

 **Differential Expression** [6 results](#) -

Showing 6 results

cutoffs: adjusted *p*-value 0.05  $\log_2$ -fold change 1.0

[Display  \$\log\_2\$ -fold change](#)

Comparison	Log <sub>2</sub> -fold change
<a href="#">'non-small cell lung cancer' vs 'normal'</a>	
<a href="#">'active Crohn's disease' vs 'normal'</a>	
<a href="#">'lung adenocarcinoma' vs 'normal'</a>	
<a href="#">'primary prostate cancer' vs 'benign prostate tumor'</a>	
<a href="#">'miR221 transfected' vs 'wild type'</a>	
<a href="#">'active ulcerative colitis' vs 'normal'</a>	



# Expression Atlas

Enter gene query...

Search

Examples: [ASPM](#), [REACT\\_284558](#), [ENSMUSG00000021789](#), ["zinc finger"](#)[Home](#) [Release notes](#) [FAQs](#) [Download](#) [Help](#) [About](#) [Feedback](#)

## Expression Atlas: Differential and Baseline Expression

The Expression Atlas provides information on gene expression patterns under different biological conditions. Gene expression data is re-analysed in-house to detect genes showing interesting baseline and differential expression patterns. [Read more about Expression Atlas.](#)

Search...

<b>Gene query ?</b>	<b>Organism</b>	<b>Sample properties ?</b>	
<input type="text" value="Enter gene query"/>	<input type="text" value="Homo sapiens"/>	<input type="text" value="Enter condition query..."/>	<input type="button" value="Search"/>
E.g. <a href="#">SFTPA2</a> <a href="#">zinc finger</a>		E.g. <a href="#">lung</a> , <a href="#">leaf</a> , <a href="#">"valproic acid"</a> , <a href="#">cancer</a>	<input type="button" value="Reset"/>
<input checked="" type="checkbox"/> Exact match			

Browse...

 **Baseline Experiments**

See all baseline expression data sets in Expression Atlas.

 **Plant Experiments**

See all expression data sets in plants in Expression Atlas.

 **All Experiments**

Scroll through the complete list of all data sets in Expression Atlas.

### iRAP: RNA-seq analysis tool

iRAP is a flexible pipeline for RNA-seq analysis that integrates many existing tools for filtering and mapping reads, quantifying expression and testing for differential expression. iRAP is used to process all RNA-seq data in Expression Atlas.

### Publications

 [RNA-Seq Gene Profiling - A Systematic Empirical Comparison](#) (*PLoS One*, 2014).

 [Expression Atlas update - a database of gene and transcript expression from microarray and sequencing-based functional genomics experiments](#) (*Nucleic Acids Research*, 2014).



# Expression Atlas

Examples: [ASPM](#), [REACT\\_284558](#), [ENSMUSG00000021789](#), ["zinc finger"](#)[Home](#) [Release notes](#) [FAQs](#) [Download](#) [Help](#) [About](#) [Feedback](#)Expression Atlas results for *"zinc finger"* **Baseline Expression** 55 results[Anolis carolinensis - Tissues - Vertebrates](#)[Bos taurus - Tissues - 5](#)[Bos taurus - Tissues - 9](#)[Gallus gallus - Tissues - Vertebrates](#)[Homo sapiens - Cell Lines - ENCODE - long non-polyA RNA, cytosol](#)[Homo sapiens - Cell Lines - ENCODE - long non-polyA RNA, nucleus](#)[Homo sapiens - Cell Lines - ENCODE - long non-polyA RNA, whole cell](#)[Homo sapiens - Cell Lines - ENCODE - long polyA RNA, cytosol](#)[Homo sapiens - Cell Lines - ENCODE - long polyA RNA, nucleus](#)[46 more results...](#) **Differential Expression** 5793 results



### Ensembl Genome Browser

 Open

Please select a cell line and a gene from the table

Showing 50 of 324 genes found: [\(show by gene set\)](#)



 [Display levels](#) 

Gene	GM12878	H1-hESC	HUVEC cell line	HeLa-S3	HepG2	K562	NHEK cell line
<a href="#">ZNF460</a>	Dark Blue	Dark Blue	Medium Blue	Medium Blue	Dark Blue	Dark Blue	Dark Blue
<a href="#">ZNF121</a>	Medium Blue	Dark Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">ZNF146</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">ZNF768</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">ZNF282</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">ZNF687</a>	Medium Blue	Dark Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">ZNF672</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">ZNF124</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Dark Blue	Medium Blue	Medium Blue
<a href="#">ZFX</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue
<a href="#">RLF</a>	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Medium Blue	Dark Blue	Medium Blue
<a href="#">ZNF358</a>	White	Medium Blue	Medium Blue	Dark Blue	Medium Blue	Medium Blue	Medium Blue



# Expression Atlas

Enter gene query...

Search

Examples: [ASPM](#), [REACT\\_284558](#), [ENSMUSG00000021789](#), ["zinc finger"](#)[Home](#) [Release notes](#) [FAQs](#) [Download](#) [Help](#) [About](#) [Feedback](#)

## Expression Atlas: Differential and Baseline Expression

The Expression Atlas provides information on gene expression patterns under different biological conditions. Gene expression data is re-analysed in-house to detect genes showing interesting baseline and differential expression patterns. [Read more about Expression Atlas.](#)

Search...

<b>Gene query ?</b>	<b>Organism</b>	<b>Sample properties ?</b>	
<input type="text" value="Enter gene query..."/>	<input type="text" value="Homo sapiens"/>	<input type="text" value="Enter condition query..."/>	<input type="button" value="Search"/>
E.g. <a href="#">SFTPA2</a> , <a href="#">zinc finger</a>		E.g. <a href="#">lung</a> , <a href="#">leaf</a> , <a href="#">"valproic acid"</a> , <a href="#">cancer</a>	<input type="button" value="Reset"/>
<input checked="" type="checkbox"/> Exact match			

Browse...

 **Baseline Experiments**

See all baseline expression data sets in Expression Atlas.

 **Plant Experiments**

See all expression data sets in plants in Expression Atlas.

 **All Experiments**

Scroll through the complete list of all data sets in Expression Atlas.

### iRAP: RNA-seq analysis tool

iRAP is a flexible pipeline for RNA-seq analysis that integrates many existing tools for filtering and mapping reads, quantifying expression and testing for differential expression. iRAP is used to process all RNA-seq data in Expression Atlas.

### Publications

 [RNA-Seq Gene Profiling - A Systematic Empirical Comparison](#) (*PLoS One*, 2014).

 [Expression Atlas update - a database of gene and transcript expression from microarray and sequencing-based functional genomics experiments](#) (*Nucleic Acids Research*, 2014).

## Expression Atlas results for *lung*

+ Show more data from EMBL-EBI

### Baseline Expression 29 results

[Bos taurus - Tissues - 5](#)

~~[Bos taurus - Tissues - 9](#)~~

[Homo sapiens - Cell Lines - ENCODE - long non-polyA RNA, whole cell](#)

[Homo sapiens - Cell Lines - ENCODE - long polyA RNA, cytosol](#)

[Homo sapiens - Cell Lines - ENCODE - long polyA RNA, nucleus](#)

[Homo sapiens - Cell Lines - ENCODE - long polyA RNA, whole cell](#)

[Homo sapiens - Cell Lines - ENCODE - total RNA, whole cell](#)

[Homo sapiens - Cell Lines - NCI-60 cancer \(CCLE\) - lung squamous cell carcinoma](#)

[Homo sapiens - Tissues - 68 FANTOM5 project - adult](#)

[Homo sapiens - Tissues - 68 FANTOM5 project - fetal](#)

[Homo sapiens - Tissues - 32 Uhlen's Lab](#)

[Homo sapiens - Tissues - Illumina Body Map](#)

[Macaca mulatta - Tissues - 9](#)

[Mus musculus - Tissues - 6](#)

[Mus musculus - Tissues - 9 in 3 strains - C57BL/6](#)

[Mus musculus - Tissues - 9 in 3 strains - CD1 mus strain](#)

**Gene query** <sup>?</sup>   **Exact match**

**Filtered by** <sup>?</sup>  
**RNA:** long non-polyA RNA  
**Cellular component:** whole cell  
[Change filters](#) >

**Cell line** <sup>?</sup>  
 **Specific** <sup>?</sup>

**Expression level cutoff** <sup>?</sup>



**Ensembl Genome Browser**


Please select a cell line and a gene from the table

Showing 50 of 23595 genes found:


Gene	A549	AG445	BJ	CD14-positive...	CD20-positive B...	GM12878	H1-hESC	HMEC cell line	HSMM cell line	HUVEC cell line	HeLa-S3
<a href="#">CTD-2328D6.1</a>	Dark Blue	Dark Blue	Dark Blue	Light Blue	Light Blue	Light Blue	Light Blue	Dark Blue	Dark Blue	Light Blue	Light Blue
<a href="#">RN7SK</a>	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Light Blue	Light Blue	Dark Blue	Dark Blue	Light Blue	Light Blue
<a href="#">MT-RNR2</a>	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Light Blue	Light Blue	Dark Blue	Dark Blue	Light Blue	Light Blue
<a href="#">RN7SL2</a>	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Light Blue	Light Blue	Dark Blue	Dark Blue	Light Blue	Light Blue
<a href="#">MT-RNR1</a>	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Light Blue	Light Blue	Dark Blue	Dark Blue	Light Blue	Light Blue
<a href="#">MIR3609</a>	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Dark Blue	Light Blue	Light Blue	Dark Blue	Dark Blue	Light Blue	Light Blue

# RNASeq


Isolate Total RNA



Fragmentation and/or Isolation  
In this case, isolation via Poly(T) coated magnetic beads




Poly(A) RNA molecules bind to the Poly(T) magnetic beads




(РНК Секвенирование), также называемый Whole Transcriptome Shotgun Sequencing (WTSS), является технология, которая использует возможности секвенирования следующего поколения выявлять снимок наличия и количества РНК генома в данный момент времени


Magnetically isolate  
and wash beads




Fragment and/or Reverse Transcribe



Fragmentation (if not done already),  
size selection, and sequence




Illumina Solexa, Roche 454, or ABI SOLiD  
Graphic shown here is Illumina




# Лекарственно-индуцированное изменение генной экспрессии

Исходные данные  
микроэрейных  
экспериментов

Лекарственно-индуцированное  
изменение профиля генной  
экспрессии или генетическая



Cells/tissue



Cells/tissue

Normalization  
Comparative analysis by  
statistical methods  
(e.g. Student's t-test  
or hypergeometric test)

ПОДПИСЬ


**Up regulated  
genes**

CASP3  
CDKN1A  
CDKN1B  
FAS  
GPX5  
TP53

**Down regulated  
genes**

CCND1  
CCND2  
MYC  
NFKB1  
PCNA  
PTGS2

# Connectivity map (СMap) подход



*Lamb, J. et al. (2006) The Connectivity Map: using gene-expression signatures to connect small molecules, genes, and disease. Science 313, 1929–1935*

# Применение CMap подхода

**Human Disease-Drug Network Based on Genomic Expression Profiles** - used Connectivity Map and GEO DataSets for drug repositioning of 395 drugs  
(*PLoS ONE*, 2009, 4(8): e6536)

**Comprehensive gene expression profiles of NK cell neoplasms identify vorinostat as an effective drug candidate** – used Connectivity Map data analysis for 6 drugs (*Cancer Lett.* 2013 pii: S0304-3835(13)00020-7)

**Computational repositioning of the anticonvulsant topiramate for inflammatory bowel disease** - GEO DataSets for 143 drugs  
(*Sci Transl Med.* 2011 August 17; 3(96): 96ra76)

**Identification of Identical Transcript Changes in Liver and Whole Blood during Acetaminophen Toxicity** – used *in house* data of gene expression profiles for acetaminophen. (*Front Genet.* 2012;3:162)

**Prediction of synergistic effects of pairwise drug combinations from gene microarray data** - used *in house* data of gene expression profiles from MCF-7 cells for docetaxel and gefitinib in different concentrations.  
(*Bioinformatics*, 2011, 27, i310-i316).

# MIAME

В целях стандартизации представления и анализ данных микроэкреев, Alvis Brazma и его коллеги из 17 учреждений ввели формат Minimum Information About a Microarray Experiment (Минимальные сведения о микроэкреевом эксперименте) - MIAME. В рамках MIAMI стандартизируется шесть областей информации:

1. Планирование эксперимента
2. Дизайн микрочипа
3. Проба подготовка
4. Процедура гибридизации
5. Анализ изображений
6. Контроль в отношении нормализации

<http://fged.org/projects/miame/>

# Экспрессия генов: анализ микроэрейных данных

- Экспрессия генов
- Микрочипы (Microarrays)
- Предварительная обработка (препроцессинг)
  - нормализация
  - диаграммы рассеяния (Scatter plots)
- Статистический анализ
  - Т-тест
  - ANOVA
  - расстояния
  - кластеризация
  - анализ главных компонент (PCA)

# Анализ микроэррейных данных

Начинаем с матрицы данных  
(значения генной экспрессии в различных образцах)

	A	B	C	D
1	Gene Sym	Chromoso	DS_Cereb	DS_Cereb
2	ATP5O	21	10.3957	10.2149
3	CRYBB2	21	5.95712	6.07945
4	C21orf33	21	8.9064	8.74096
5	WRB	21	9.67306	9.3076
6	ALOX5	10	4.35077	4.4185
7	HRMT1L1	21	9.16597	8.91893
8	PTPN1	20	6.32176	6.27589
9	SBF1	22	5.06861	4.94405
10	ATP5J	21	9.27822	8.95333
11	CAMKK2	12	8.13921	7.9926
12	NRTN	19	3.39505	3.33395
13	CTDSPL	3	5.77447	5.69664
14	USP16	21	7.64692	7.42381
15	RUNX1	21	3.52972	3.58988
16	DONSON	21	5.37143	4.72189
17	FLOT1	6	9.50971	9.38725
18	USP25	21	6.94273	7.08138
19	SOD1	21	10.7198	10.3198
20	ATP5O	21	7.4918	7.50782
21	RARA	17	5.1042	4.90355
22	DCTN6	8	8.65151	8.69294
23	TIMM23	10	5.42184	5.42443
24	SP100	2	3.98977	3.97176
25	PDXK	21	7.95603	7.80782
26	PAPD1	10	5.99899	5.87142
27	SUMO3	21	9.36959	9.30012
28	MSC	8	4.59863	4.58913
29	SPRR2C	1	4.50502	4.70578
30	DOCK6	19	4.4069	4.40616

гены  
(уровни транскрипции РНК)

Обычно много генов  
( $\gg 20,000$ ) и несколько  
образцов ( $\sim 10$ )

# Предварительная обработка (препроцессинг)

Наблюдаемые различия в экспрессии генов могут быть связаны с транскрипционными изменениями, или же они могут быть вызваны артефактами, такими, как:

- различная эффективность окрашивания Cy3 (зеленый), Cy5 (красный)
- неравномерное распределение ДНК на поверхности массива
- изменения связанные с чистотой или количеством РНК
- изменения связанные с эффективностью отмывки
- изменения связанные с эффективностью сканирования

# Предварительная обработка (препроцессинг)

- Основная цель предварительной обработки данных заключается в как можно более полном удалении систематической погрешности в данных, сохраняя при этом различия в экспрессии генов, которое происходит из-за биологически соответствующих изменений в транскрипции.
- Основное предположение большинства процедур нормализации является то, что средний уровень экспрессии генов не меняется в эксперименте.

# Глобальная нормализация данных

Глобальная нормализация используется для коррекции двух или более наборов данных. В одном общем случае образцы помеченные Cy3 (зеленый краситель) или Cy5 (красный краситель) гибридизовали с ДНК-элементов на микрочипе. После промывки зонды возбуждаются с помощью лазера и исследуются с помощью сканирующего конфокального микроскопа.

# Глобальная нормализация данных

Глобальная нормализация используется для коррекции двух или более наборов данных.

Пример: общая флуоресценция в  
Су3 канал = 4 млн. единиц  
Су 5 канал = 2 млн. единиц

Тогда нескорректированное отношение для гена может показать 2000 единиц в сравнении 1000 единиц. Появление такого артефакта, приводит к тому, что показывает 2-кратное увеличение экспрессии.

## Глобальная процедура нормализации



- Шаг 1: вычесть значения интенсивности фона (используется пустая область массива)
- Шаг 2: глобальная нормализация, так чтобы среднее соотношение было равно 1 (применяется к 1-канальным или 2-канальным наборам данных)

# Диаграммы рассеяния (Scatter plots)


Полезны для представления значений экспрессии генов из двух экспериментов микрочипов (например, контроль, эксперимент)

- Каждая точка соответствует значению экспрессии генов
- Большинство точек находятся вдоль линии
- Выбросы составляют гипо- и гиперэкспрессируемые гены


# Дифференциальная генная экспрессия в различных тканях и клетках




Уровень экспрессии (образец 2)



Уровень экспрессии (образец 1)



# Логарифмическая трансформация данных



# Диаграммы рассеяния (Scatter plots)

Обычно данные изображаются логарифмических координатах

Время	Изменение	исходное значение	$\log_2$ значение
t=0	начальное	1.0	0.0
t=1h	нет изменений	1.0	0.0
t=2h	2-fold up	2.0	1.0
t=3h	2-fold down	0.5	-1.0



## About R

- [What is R?](#)
- [Contributors](#)
- [Screenshots](#)
- [What's new?](#)

## Download


[CRAN](#)

## R Project

- [Foundation](#)
- [Members & Donors](#)
- [Mailing Lists](#)
- [Bug Tracking](#)
- [Developer Page](#)
- [Conferences](#)
- [Search](#)

## Documentation

- [Manuals](#)
- [FAQs](#)
- [Newsletter](#)
- [Wiki](#)
- [Books](#)
- [Certification](#)
- [Other](#)





## Getting Started:

- R is a free software environment for statistical computing and graphics. It compiles and runs on a wide variety of UNIX platforms, Windows and MacOS. To download R, please choose your preferred [CRAN mirror](#).
- If you have questions about R like how to download and install the software, or what the license terms are, please read our [answers to frequently asked questions](#) before you send an email.

<http://www.r-project.org>

# Эффект нормализации



После RMA (Robust multi-array analysis) процедуры нормализации, the медиана значений близка к нулю и исправлены перекосы.

# Экспрессия генов: анализ микроэрейных данных

- Экспрессия генов
- Микрочипы (Microarrays)
- Предварительная обработка (препроцессинг)
  - нормализация
  - диаграммы рассеяния (Scatter plots)
- Статистический анализ
  - Т-тест
  - ANOVA
  - расстояния
  - кластеризация
  - анализ главных компонент (PCA)

# T-тест

T-тест широко используется для оценки различия в средних значениях между двумя группами.

$$t = \frac{x_1 - x_2}{SE}$$

**Разница между средними**

**Изменчивость  
(стандартная ошибка отклонения)**

Вопросы

Адекватный ли размер выборки (N)?

Являются ли данные нормально распределенными?

Есть ли разница между двумя группами?

Уместно ли задать уровень значимости для  $p < 0,05$ ?