

# Conceitos fundamentais sobre a metodologia para análise de RNA-Seq

**Pablo Rodrigo Sanches**

Departamento de Genética – FMRP/USP

[psanches@usp.br](mailto:psanches@usp.br)

# Pablo Rodrigo Sanches

- É **Analista de Sistemas e Bioinformata** desde 2003 na Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo (FMRP-USP), onde desenvolve soluções em tecnologia para projetos de pesquisa, entre outros.
- É **Professor** desde 2011 em cursos de graduação na Universidade de Ribeirão Preto (UNAERP), em disciplinas correlatas a tecnologia de informação e engenharia de software.
- **TITULAÇÃO:** Doutor em Genética pela FMRP-USP, Mestre em Física Computacional pelo Instituto de Física de São Carlos da USP (IFSC-USP), MBA em Tecnologia da Informação e Gestão de Negócios pela Fundação Getulio Vargas (FGV) e Bacharel em Análise de Sistemas pela UNAERP.

# O que é isso para você?



```
>Sequence_1 assembly1  
CCCTAAACCCTAAACCCCTAAACCTAAACCTCTGAATCCTAACCTAAATCCCTAAAT  
CTTTAAATCCTACATCCATGAATCCCTAAATACCTAATTCCCTAAACCCGAAACCGGTTT  
CTCTGGTTGAAAATCATTGTGTATATAATGATAATTTCATCGTTTATGTAATTGCTTA  
TTGTTGTGTGTAGATTTTAAAAATATCATTGAGGTCAATACAAATCCTATTCTTGT  
GGTTTCTTCCTTCACTTAGCTATGGATGGTTATCTCATTGTATATTGGATACAA  
GCTTGCTACGATCTACATTGGGAATGTGAGTCTCTTATTGTAACCTAGGGTTGGTTT  
ATCTCAAGAATCTTATTAATTGTTGGACTGTTATGTTGGACATTATTGTCATTCTT
```

Uma sequência de caracteres?  
Um arquivo texto?



VS.

Um Gene?  
A parte de um genoma?



# E isso?

```
while(my $seq = $seqio->next_seq) {  
    @idseqs = `cat $ARGV[0]`;  
    foreach $idseq (@idseqs)  
    {  
        chomp $idseq;  
        if($seq->desc =~ /$idseq/)  
        {  
            if($seq->desc =~ m/$ARGV[3]/) {  
                $pos = $-[0];  
            }  
            $desc = substr($seq->desc,$pos);  
            print INFO ">" . $idseq . " " . $desc . "\n";  
            print INFO $seq->seq . "\n";  
        }  
    }  
}
```

Um texto em uma língua desconhecida?  
Palavras sem sentido organizadas?



Um algoritmo?  
Um código-fonte escrito em linguagem Perl?

VS.




# Mercado de trabalho



Piloto de drones, Engenheiro de robôs, Youtuber, Streamer gamer, Cyber atleta, Influenciador digital, Cientista de dados, Técnico de saúde assistida por Inteligência Artificial, Walker/Talker, ...

# E ainda...

- Bioinformata → Bioinformática
  - Etimologia
    - Bio = “*bios*” (vida) + Informática = “*informatik*” (informação automática)
  - Não é exatamente nova, porém pouco conhecida... Ainda



Existe uma relação entre Biologia e Informática?



# Histórico



A história começa na década de 1940 com a invenção do moderno computador digital



Ele se chama digital, pois os dados são armazenados com um alfabeto binário (0 e 1)



A descoberta da dupla hélice, em 1953, por Watson e Crick, mostrou que a informação genética também é armazenada de forma digital



Mas diferente do alfabeto binário dos computadores, os dados genéticos são armazenados com um alfabeto quaternário (A, C, G e T)




Mais tarde se descobriu que a forma dos genes operam também é digital. Até certo ponto, os genes podem ser “ligados” ou “desligados”



Apenas estas observações já seriam suficientes para prever, na década de 1950, que um dia informática e biologia molecular iriam juntas fazer nascer uma nova área de conhecimento

# Histórico



Apesar da estrutura do DNA ter sido desvendada em 1953, a informação nela contida não podia ser “lida”



Foi preciso esperar até fins da década de 1980 para que aparecesse uma “lente de aumento” suficientemente boa que permitisse a leitura do DNA em grande quantidade



Na década de 1970 a unidade básica de armazenamento de informação era o kilobyte - aproximadamente 1000 letras;

Um computador da época tinha alguns kbytes de memória;


Com tal memória um computador desses não seria capaz de processar nem sequer o genoma de um vírus (20 kb), ou 20 mil letrinhas; que dirá o genoma humano, com seus 3 bilhões de letrinhas.



Foi preciso esperar alguns anos para que essas duas áreas alcançassem formas de produzir a biologia em larga-escala. Produção de dados em massa gera demanda para análises computacionais => Bioinformática.


# Bioinformática

- “...aplicação das **técnicas da informática**, no sentido de **análise da informação** na área de estudo da **biologia**...”;
- “...a utilização de **técnicas computacionais e matemáticas** relacionadas ao **conhecimento químico, físico, biológico, biomédico,...**”.




# Desafios

- Sequenciamento
- *Base Calling*
- Qualidade do sequenciamento
- Alinhamento/Montagem
- Predição/Anotação
- Vias metabólicas
- Expressão diferencial
- *Splicing* alternativo
- Identificação de mutações
- Filogenia
- Regiões promotoras
- Regiões não-codificantes
- RNA-Seq, miRNA-Seq, ChIP-Seq
- Domínios de proteínas
- Bioinformática estrutural
- Bancos de dados biológicos
- *Big Data*
- *Machine Learning*
- Biologia sintética
- Medicina personalizada
- ...



"And that's why we need a computer."

# Como processar os dados de RNA-Seq?




# O que é RNA-Seq?

- Nome dado às novas tecnologias de sequenciamento (*Next-generation sequencing*) aplicadas aos transcriptomas, ou seja, às regiões do DNA transcritas em moléculas de RNAs.
- Podemos fazer:
  - Analisar a expressão diferencial em diferentes tecidos ou condições ambientais;
  - Analisar diferentes isoformas (*alternative splicing*);
  - Descobrir novas regiões dos genomas que são transcritas;
  - Identificar moléculas de RNAs que participam de processos regulatórios;
  - etc.


# Por que sequenciar?

- Identificar sequências funcionais e possibilitar a caracterização dos componentes moleculares dos sistemas biológicos (ex: genoma/transcriptoma);
- Pesquisar as regiões gênicas;
- Acelerar o processo de anotação genômica;
- Obter a expressão gênica relativa para diferentes células sob diferentes condições;
- Detectar mutações pontuais e/ou estruturais;
- Auxiliar na identificação de eventos de processamento alternativo de transcritos (*Alternative Splicing*) em condições biológicas específicas.

# Evolução do sequenciamento




# Custo por Genoma




# Análise de RNA-Seq

Controle (ex. não tratado)



Desafio (ex. tratado com droga)



Reads (leituras)  
do RNA-Seq



Genoma de  
referência



Desafio vs. Controle (Tratado vs. Não tratado)

Gene A - UP




Gene B - DOWN




# Bibliotecas de sequenciamento (RNA-Seq)

- Bibliotecas de fragmentos (***single-end***)
  - Resultam no sequenciamento de apenas uma das extremidades do fragmento, sendo a metodologia mais simples e barata.
- Bibliotecas de extremidades pareadas (***paired-end***)
  - Resultam em duas leituras para cada fragmento sequenciado, uma referente à fita *forward* e outra à fita *reverse*.



# Exemplo de pipeline (RNA-Seq)



# Dados brutos do sequenciamento

- Dados gerados pelos sequenciadores automáticos;
- Exemplos de formatos de arquivos gerados:
  - FASTA
  - SFF (ROCHE 454)
  - CSFASTA (ABI SOLiD)
  - FASTQ
  - ...

# Formato FASTA

```
>Sequence_1 assembly1
CCCTAAACCCTAAACCCCTAAACCCCTAAACCTCTGAATCCTTAATCCCTAAATCCCTAAAT
CTTTAAATCCTACATCCATGAATCCCTAAATACTAATTCCCTAAACCCGAAACCGGTTT
CTCTGGTTGAAAATCATTGTGTATATAATGATAATTTCATCGTTTATGTAATTGCTTA
TTGTTGTGTGTAGATTTTAAAAAATCATTTGAGGTCAATAACAAATCCTATTCTTGT
GGTTTCTTCCTCACTTAGCTATGGATGGTTATCTCATTGTTATATTGGATACAA
GCTTGCTACGATCTACATTGGGAATGTGAGTCTCTTATTGTAACCTTAGGGTTGGTTT
ATCTCAAGAACATCTTATTAAATTGTTGGACTGTTATGTTGGACATTATTGTCATTCTT
>Sequence_2
CCCTAAACCCTAAACCCCTAAACCCCTAAACCTCTGAATCCTTAATCCCTAAATCCCTAAAT
CTTTAAATCCTACATCCATGAATCCCTAAATACTAATTCCCTAAACCCGAAACCGGTTT
CTCTGGTTGAAAATCATTGTGTATATAATGATAATTTCATCGTTTATGTAATTGCTTA
TTGTTGTGTGTAGATTTTAAAAAATCATTTGAGGTCAATAACAAATCCTATTCTTGT
GGTTTCTTCCTCACTTAGCTATGGATGGTTATCTCATTGTTATATTGGATACAA
GCTTGCTACGATCTACATTGGGAATGTGAGTCTCTTATTGTAACCTTAGGGTTGGTTT
ATCTCAAGAACATCTTATTAAATTGTTGGACTGTTATGTTGGACATTATTGTCATTCTT
```

# Formato FASTQ

```
@SRR001666.1 071112_SLXA-EAS1_s_7:5:1:817:345 length=36
GGGTGATGGCCGCTGCCGATGGCGTCAAATCCCACC
+SRR001666.1 071112_SLXA-EAS1_s_7:5:1:817:345 length=36
IIIIIIIIIIIIIIIIIIIIIIIIIIIIII9IG9IC
```

Cada read é representada por 4 linhas no arquivo

@ read ID  
Sequência  
+ read ID  
Qualidade

The screenshot shows the NCBI GEO Accession Display page for series GSE102872. At the top, there's a banner about COVID-19 and a link to the NIH coronavirus page. Below the banner, the page header includes 'HOME', 'SEARCH', 'SITE MAP', 'GEO Publications', 'FAQ', 'MIAME', 'Email GEO', and a 'Not logged in | Login' link. The main content area has sections for 'Scope', 'Format', 'Amount', and 'GEO accession'. The 'Scope' dropdown is set to 'Self', 'Format' to 'HTML', 'Amount' to 'Quick', and the 'GEO accession' field contains 'GSE102872'. A 'Query DataSets for GSE102872' button is also present. The detailed experiment description follows, including sections for Status, Title, Organism, Experiment type, Summary, Methods, Results, Conclusions, Overall design, Contributor(s), and Citation(s). The 'Overall design' section notes that T. rubrum transcriptome was assessed using RNA-seq. The 'Contributor(s)' section lists Mendes NS, Bitencourt TA, Sanches PR, Rocha RS, Martinez-Rossi NM, Rossi A, and Mendes NS, Bitencourt TA, Sanches PR, Silva-Rocha R et al. The 'Citation(s)' section refers to a paper in Sci Rep 2018 Feb 6(1):2520, PMID: 29410524.

# Dados brutos disponíveis na web

- GEO Gene Expression Omnibus
  - <http://www.ncbi.nlm.nih.gov/geo/>
- Exemplo:
  - *A transcriptome survey of Trichophyton rubrum exposed to undecanoic acid*
  - <https://www.ncbi.nlm.nih.gov/geo/query/acc.cgi?acc=GSE102872>
- Após download converter arquivos SRA para FASTQ
  - `$ fastq-dump -B arquivo.sra`

The screenshot shows the NCBI SRA Record page for SRX3110626. At the top, it says 'SRX3110626: GSM2747498: Oh\_I; Trichophyton rubrum; RNA-Seq'. Below that, it indicates '1 ILLUMINA (Illumina HiSeq 2000) run: 40.5M spots, 4G bases, 2.4Gb downloads'. The 'Submitted by: NCBI (GEO)' section is shown, along with a 'Study' description: 'A transcriptome survey of Trichophyton rubrum exposed to undecanoic acid'. The 'Sample' section lists 'Oh\_I' with links to 'SAMN07522977' and 'SRS2445718'. The 'Instrument' is listed as Illumina HiSeq 2000. The 'Library' section includes 'Strategy: RNA-Seq', 'Source: TRANSCRIPTOMIC', 'Selection: cDNA', and 'Layout: SINGLE'. The 'Construction protocol' is described as using the Illumina RNAspn Mini Isolation Kit and NanoDrop ND-1000 spectrophotometer. The 'Experiment attributes' section shows 'GEO Accession: GSM2747498'. The 'Links' section provides a table of runs:

Run	# of Spots	# of Bases	Size	Published
SRR5952133	40,489,531	4G	2.4Gb	2018-02-06


The bottom of the page shows the ID: 4404554.

# Qualidade do sequenciamento


- Avaliar a qualidade das reads
  - Identificar contaminantes;
  - Identificar amostras com baixa performance de sequenciamento.
  - Softwares: **FastQC**, SAMStat, ...
- Download do software FastQC
  - <http://www.bioinformatics.babraham.ac.uk/projects/fastqc/>
- Exemplo de uso do software FastQC
  - `$ fastqc arquivo.fastq`
- Resultado do software FastQC
  - Serão gerados arquivos formato .html para visualização em navegador web

# Exemplos de resultados - FASTQC

## Qualidade boa



## Qualidade ruim



# Exemplos de resultados - FASTQC

## Qualidade boa

### Overrepresented sequences

No overrepresented sequences

## Qualidade ruim

### Overrepresented sequences

Sequence	Count	Percentage	Possible Source
AGAGTTTATCGCTTCATGACGCAGAAGTTAACACTTC	2065	0.5224039181558763	No Hit
GATTGGCGTATCCAACCTGCAGAGTTTATCGCTTCATG	2047	0.5178502762542754	No Hit
ATTGGCGTATCCAACCTGCAGAGTTTATCGCTTCATGA	2014	0.5095019327680071	No Hit
CGATAAAATGATTGGCGTATCCAACCTGCAGAGTTTAT	1913	0.4839509420979134	No Hit
GTATCCAACCTGCAGAGTTTATCGCTTCATGACGCAGA	1879	0.47534961850600066	No Hit
AAAAATGATTGGCGTATCCAACCTGCAGAGTTTATCGCT	1846	0.4670012750197325	No Hit
TGATTGGCGTATCCAACCTGCAGAGTTTATCGCTTCAT	1841	0.46573637449150995	No Hit
AACCTGCAGAGTTTATCGCTTCATGACGCAGAAGTTAA	1836	0.46447147396328753	No Hit
GATAAAAATGATTGGCGTATCCAACCTGCAGAGTTTATC	1831	0.4632065734350651	No Hit
AAATGATTGGCGTATCCAACCTGCAGAGTTTATCGCTTC	1779	0.45005160794155147	No Hit
ATGATTGGCGTATCCAACCTGCAGAGTTTATCGCTTCCA	1779	0.45005160794155147	No Hit
AATGATTGGCGTATCCAACCTGCAGAGTTTATCGCTCC	1760	0.4452449859343061	No Hit
AAAATGATTGGCGTATCCAACCTGCAGAGTTTATCGCTT	1729	0.4374026026593269	No Hit
CGTATCCAACCTGCAGAGTTTATCGCTTCATGACGCAG	1713	0.43335492096901496	No Hit
ATCCAACCTGCAGAGTTTATCGCTTCATGACGCAGAAG	1708	0.43209002044079253	No Hit
CAGAGTTTATCGCTTCATGACGCAGAAGTTAACCTT	1684	0.42601849790532476	No Hit
TGCAGAGTTTATCGCTTCATGACGCAGAAGTTAACCT	1668	0.4219708162150128	No Hit
CAACCTGCAGAGTTTATCGCTTCATGACGCAGAAGTTA	1668	0.4219708162150128	No Hit
TATCCAACCTGCAGAGTTTATCGCTTCATGACGCAGAA	1630	0.4123575722005221	No Hit

# Aparar “trimar” *reads*

- Processo que permite fazer os cortes e ajustes necessários nas *reads* (leituras)
  - Retirada das sequências de adaptadores;
  - Manutenção de sequências com escore mínimo de qualidade e tamanho mínimo;
  - Softwares: **Trimmomatic**, Prinseq, FASTX-Toolkit, ...

- Download do software Trimmomatic
  - <http://www.usadellab.org/cms/?page=trimmomatic>



- Exemplo de uso do software Trimmomatic para biblioteca *paired-end*

```
$ java -jar trimmomatic-0.36.jar PE -threads 8 -phred33 ARQ_R1.fastq.gz  
ARQ_R2.fastq.gz ARQ_R1.paired.fastq.gz ARQ_R1.unpaired.fastq.gz ARQ_R2.paired.fastq.gz  
ARQ_R2.unpaired.fastq.gz ILLUMINACLIP:/adapters/TruSeq3-PE-2.fa:2:30:10 LEADING:3  
TRAILING:3 SLIDINGWINDOW:4:15 MINLEN:36
```

- Resultado do software Trimmomatic
  - Serão gerados arquivos formato .fastq com *reads* “trimadas”

# Exemplos de resultados - Trimmomatic

Arquivo de resultado

```
Input Read Pairs: 28987947
Both Surviving: 27213240 (93.88%)
Forward Only Surviving: 784150 (2.71%)
Reverse Only Surviving: 863068 (2.98%)
Dropped: 127489 (0.44%)
```


Outros resultados

Sample	Raw reads	High-quality reads
0 hour I (SR)	40,489,531	40,149,007
0 hour II (PE)	28,987,947	27,213,240
0 hour III (PE)	28,893,017	27,136,542
3 hours I (SR)	60,724,079	60,235,207
3 hours II (PE)	67,859,806	63,440,961
3 hours III (PE)	28,182,638	26,438,636
12 hours I (SR)	45,617,478	44,174,487
12 hours II (PE)	30,746,489	28,524,813
12 hours III (PE)	12,463,078	10,635,512

SR=Single-read; PE=Paired-end

# Alinhamento das *reads*

- Processo de alinhamento das *reads* sequenciadas (já “trimadas”) no genoma de referência.
  - Quando não houver um genoma de referência, utilizar o método de Alinhamento *de novo*.
  - Softwares: **STAR**, BWA, Bowtie, Bowtie2, Tophat, Tophat2, HISAT, HISAT2, Velvet, ...



# Exemplo de uso do software STAR

- Passo 1 - Criando o arquivo de índice do genoma de referência

```
$ STAR --runThreadN 8 --runMode genomeGenerate --genomeDir  
dir_do_genoma --genomeFastaFiles arquivo_supercontigs.fasta --  
sjdbGTFfile arquivo_transcripts.gtf --sjdbOverhang 99
```

**GTF**

Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	start_codon	14925	14927	.	-	0	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	stop_codon	12841	12843	.	-	0	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	exon	14609	14927	.	-	.	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	CDS	14609	14927	.	-	0	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	exon	13933	14529	.	-	.	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	CDS	13933	14529	.	-	2	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	exon	13702	13869	.	-	.	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	CDS	13702	13869	.	-	2	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	exon	13470	13638	.	-	.	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	CDS	13470	13638	.	-	2	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	exon	12841	13414	.	-	.	gene_id "TERG_00002"; transcript_id "TERG_00002T0";
Supercontig21	TR_CBS118892_V2_FINAL_CALLGENES_5	CDS	12844	13414	.	-	1	gene_id "TERG_00002"; transcript_id "TERG_00002T0";

**FASTA**

```
>Supercontig21 of Trichophyton rubrum CBS 118892  
ATAGTATTACTTACTACTATAAGTCCTATTATAGAACGGTATGCTCTACTATTAGTA  
TCTAACTAGATAACTATAAAACTATATAAAATCTTTAAACTTAGATATATAGCG  
GTAGTTAAACTACTAGTATAACCTCTATTAGAACGGGTAGATAGCTTATTAACTCTA  
GATAATACTAAAGTATAGAGATTAAATATTAAGTACTACCTATATTAGCCTTTATAAT  
ATTAATAATAATCTCTATAAAAGTAGTAATAACCTATAAAAAAGCTATTACTATTCTATA  
GAGTGTAATAATAATTATCTAATTCTAATAGTACTTTAGAGGGATAATTAAATATAAAA  
GATAACTCCACTACTATTTAATAGCCCCCTACTATATCTAGACCCCCCTAAGTACCGTAAG  
TATAAGGACGCGTCCCTAATAGAGCTACTATAGCTAAGTAGCTAAAAGTAGATAGGCTA  
ATATCTTATAATTATAAGGACTAATATAGTACTAAATATACTAATAAAATCTAAAAAA  
GATAGTAAAGGTTTATATTAGATTTAGAATATATTAAATCTAGAGTATTACT
```

# Exemplo de uso do software STAR

- Passo 2 – Alinhando as *reads* ao genoma de referência

```
$ STAR --runThreadN 8 --genomeDir dir_do_genoma --readFilesIn ARQ_R1_TRIMMED.paired.fastq.gz ARQ_R2_TRIMMED.paired.fastq.gz --readFilesCommand zcat --outSAMtype BAM SortedByCoordinate --outReadsUnmapped Fastx --outSJfilterReads Unique --twoPassMode Basic --outFilterMultimapNmax 1 --outFilterType BySJout --alignSJoverhangMin 15 --alignSJDBoverhangMin 3 --outFilterMismatchNoverLmax 0.06 --quantMode TranscriptomeSAM GeneCounts --outFileNamePrefix dir_de_saida
```

- Resultado do software STAR

- Serão gerados arquivos formato .BAM com *reads* alinhadas;
- Caso utilize o parâmetro GeneCounts, será gerado o arquivo de contagem de *reads*.

# Exemplos de resultados - STAR

```

Number of input reads | 46661059
Average input read length | 271
UNIQUE READS:
  Uniquely mapped reads number | 45099456
  Uniquely mapped reads % | 96.65%

```

LOG

Sample	High-quality reads	Mapped reads STAR	Total mapped reads (%)
Amostra I	46,661,059	45,099,456	96.65
Amostra II	31,721,176	22,577,724	71.18
Amostra III	42,817,030	42,286,629	98.76

TERG_00002	2441
TERG_00003	7014
TERG_00004	12719
TERG_00008	9056
TERG_00009	1960
TERG_00010	35
TERG_00011	483
TERG_00012	4716
TERG_00013	691
TERG_00014	83
TERG_00015	3444



## COUNT

SAM/BAM

## Outros resultados

# Expressão diferencial

- Ideal que se tenha 3 ou mais sequenciamentos independentes para cada tratamento e para cada grupo controle;
- Podemos usar softwares como: **DESeq2**, EdgeR para normalizar e extrair o diferencial de expressão (estatísticas);
- Ainda outras opções: cuffdiff, limma, baySeq, ...



# DESeq2

- Baseada em *read counts*
- Pacote do Bioconductor/R
  - <https://www.bioconductor.org/>
- R
  - <https://www.r-project.org/>


The screenshot shows the Bioconductor website with the following details:

- Header:** Bioconductor OPEN SOURCE SOFTWARE FOR BIOINFORMATICS, Home, Install, Help, Developers, About, Search: [input field].
- Breadcrumbs:** Home » Bioconductor 3.11 » Software Packages » DESeq2
- Title:** DESeq2
- Statistics:** platforms all, rank 27 / 1905, posts 283 / 1 / 3 / 42, in Bioc 7.5 years, build ok, updated since release, dependencies 93.
- DOI:** 10.18129/B9.bioc.DESeq2 [f](#) [t](#)
- Description:** Differential gene expression analysis based on the negative binomial distribution.
- Author:** Michael Love [aut, cre], Constantin Ahlmann-Eltze [ctb], Simon Anders [aut, ctb], Wolfgang Huber [aut, ctb]
- Maintainer:** Michael Love <michaelisaiahlove@gmail.com>
- Citation:** (from within R, enter `citation("DESeq2")`): Love MI, Huber W, Anders S (2014). "Moderated estimation of fold change and dispersion for RNA-seq data with DESeq2." *Genome Biology*, 15, 550. doi: [10.1186/s13059-014-0550-8](https://doi.org/10.1186/s13059-014-0550-8).
- Installation:** To install this package, start R (version "4.0") and enter:


```
if (!requireNamespace("BiocManager", quietly = TRUE))
  install.packages("BiocManager")
BiocManager::install("DESeq2")
```
- Documentation:** To view documentation for the version of this package installed in your system, start R and enter:

```
browseVignettes("DESeq2")
```
- Documentation Sidebar:** Documentation > Bioconductor
  - Package vignettes and manuals.
  - Workflows for learning and use.
  - Course and conference material.
  - Videos.
  - Community resources and tutorials.R / CRAN packages and documentation
- Support Sidebar:** Support > Please read the [posting guide](#). Post questions about Bioconductor to one of the following locations:
  - Support site - for questions about Bioconductor packages
  - Bioc-devel mailing list - for package developers


# RStudio - <https://rstudio.com/>




# Exemplos de resultados – DESeq2



# Exemplos de resultados – DESeq2



# Exemplos de resultados – DESeq2



# Exemplos de resultados – DESeq2

gene	baseMean	log2FoldChange	IfcSE	stat	pvalue	padj	Control1	Control2	Control3	Keratin1	Keratin2	Keratin3
1 TERG_08353	5263,696589	-9,002452266	0,457685141	-19,66953142	3,93E-86	3,35E-82	12972,30597	8400,824323	10148,10033	25,66658515	23,4192922	11,86303686
2 TERG_00867	8034,057675	-6,924413959	0,449552077	-15,40291839	1,56E-53	6,65E-50	21224,51933	16861,695	9725,389828	177,182233	117,096461	98,46320595
3 TERG_03274	39068,16881	-6,010855869	0,410694252	-14,63584122	1,66E-48	4,70E-45	75212,20447	101602,9569	54013,45959	911,57775	1348,458193	1320,356003
4 TERG_06242	9819,287482	5,837124878	0,403135796	14,47930184	1,64E-47	3,48E-44	323,0069501	284,3704525	405,4362701	19229,24	24895,9402	13777,73101
5 TERG_01435	1004,302718	5,852167669	0,406323546	14,40272839	4,97E-47	8,46E-44	36,85314196	33,9885003	31,5			
6 TERG_02842	4997,657133	-8,213330898	0,751223985	-10,93326499	7,99E-28	1,13E-24	10492,3063	699,0301561	1869			
7 TERG_05652	1815,001137	5,907089754	0,547900611	10,78131623	4,22E-27	5,12E-24	96,10721335	40,78620035	40,6			
8 TERG_02974	5210,880922	-5,450595199	0,510534625	-10,67624982	1,31E-26	1,40E-23	5386,339611	18580,38016	6599			
9 TERG_04580	85237,93713	-5,637341532	0,533843746	-10,5599093	4,57E-26	4,32E-23	238209,3157	163247,8999	9989			
10 TERG_00856	1096,023656	-4,605000909	0,44760248	-10,28814877	7,97E-25	6,78E-22	2089,067322	3030,641276	1197			
11 TERG_06585	4478,365775	-7,364525546	0,723264717	-10,18233764	2,38E-24	1,84E-21	1282,633862	20739,78288	4685			
12 TERG_04942	3811,654367	-4,396265658	0,437335943	-10,05237672	8,97E-24	6,36E-21	4557,505223	9213,14948	8061			
13 TERG_03223	3494,277166	6,577117485	0,657796482	9,998711852	1,54E-23	1,01E-20	21,6783188	49,84980043	146,			
14 TERG_01841	160,0771112	5,859269453	0,586463982	9,990842806	1,67E-23	1,02E-20	3,613053134	10,19655009	3,04			
15 TERG_03226	5420,83863	5,624314883	0,564531946	9,962792936	2,22E-23	1,26E-20	76,59672643	140,4858012	429,			
16 TERG_02844	16356,73185	-7,115805721	0,721553954	-9,861779122	6,10E-23	3,24E-20	30338,80716	3611,844631	6348			
17 TERG_06548	804,7925492	-5,693311316	0,586368898	-9,709436045	2,75E-22	1,38E-19	1157,622224	2977,392626	602,			
18 TERG_11610	293,7058974	4,113211732	0,427687852	9,617321872	6,76E-22	3,19E-19	26,01398256	35,12145031	35,			
19 TERG_12038	4566,96921	-5,693308736	0,592763145	-9,604694199	7,64E-22	3,42E-19	10717,76082	13017,59561	3147			
20 TERG_05627	465,3771355	5,890375985	0,618818924	9,518739255	1,75E-21	7,45E-19	24,56876131	5,664750049	15,2			
21 TERG_06509	7364,750494	-5,777097642	0,607896269	-9,503426708	2,03E-21	8,23E-19	14262,16594	21570,23524	7566			
22 TERG_04228	12204,28639	-3,970785992	0,42008175	-9,452412526	3,31E-21	1,28E-18	18508,94859	28842,64135	2148			
23 TERG_06807	457,7852227	3,709139395	0,402693409	9,210827178	3,24E-20	1,20E-17	50,58274387	66,84405058	78,2			
24 TERG_02169	561,5525446	5,384599423	0,588892347	9,143605702	6,04E-20	2,14E-17	33,24008883	24,92490022	20,3			

## Exemplo de aplicação de filtros


- pvalue < 0,05
- log2FoldChange >= 1,5 (*up-regulated*)
- log2FoldChange <= -1,5 (*down-regulated*)

ID	Gene Product Name	log2(Fold change)
<b>24 hours</b>		
<b>Up-regulated</b>		
TERG_01599	hypothetical protein	7.81
TERG_05652	leucine aminopeptidase 1	6.23
TERG_03223	N-acetylglucosamine-6-phosphate deacetylase	6.07
TERG_05627	LysM domain-containing protein ( <i>M. canis</i> )	6.04
TERG_06242	glucanase, putative ( <i>T. verrucosum</i> )	5.67
TERG_12035	NB-ARC and TPR domain protein ( <i>A. benhamiae</i> )	5.64
TERG_07909	isochorismatase family hydrolase, putative ( <i>A. benhamiae</i> )	5.11
TERG_01841	hypothetical protein	5.06
TERG_03226	glucosamine-6-phosphate deaminase	4.92
TERG_01435	flavin containing polyamine oxidase, putative ( <i>A. benhamiae</i> )	4.78
<b>Down-regulated</b>		
TERG_02842	6-hydroxy-D-nicotine oxidase ( <i>T. equinum</i> )	-9.33
TERG_08353	cytochrome P450 55A3 ( <i>T. tonsurans</i> )	-8.87
TERG_02746	hypothetical protein	-8.29
TERG_06049	dimethylallyl tryptophan synthase, putative ( <i>T. verrucosum</i> )	-8.11
TERG_06054	hypothetical protein	-8.05
TERG_02844	major facilitator superfamily transporter ( <i>T. tonsurans</i> )	-7.69
TERG_02412	HHE domain protein ( <i>T. verrucosum</i> )	-7.52
TERG_02024	hypothetical protein	-6.95
TERG_11792	hypothetical protein	-6.73
TERG_00867	DUF1212 domain membrane protein ( <i>A. benhamiae</i> )	-6.67

# Enriquecimento funcional

- Identificar classes de genes que estão super-representadas em um grande conjunto de genes;
- Uso de Bancos de Dados e Ferramentas como:
  - Gene Ontology
  - Blast2GO
  - BayGO
  - FunRich
  - ...

# Exemplos de resultados – Enriquecimento funcional



# Habilidades essenciais - Bioinformata

- Conhecimento na área de Biologia Molecular, Computação e Estatística;
- Conhecimento no uso de ferramentas e pacotes de Bioinformática;
- Desejável conhecimento em linguagens de programação;
- Não ter “medo” da interface de linha de comandos (ex. Linux).

# Principais softwares utilizados - Bioinformática

- Sistemas operacionais
  - Linux, MacOS e Windows
- Linguagens de programação
  - R, Python, Perl, Java, C/C++, etc.
- Sistemas Gerenciadores de Bancos de Dados
  - MySQL, PostgreSQL, MariaDB, MongoDB, etc.
- Outros
  - MySQL Workbench, Microsoft Excel, Power BI, etc.



# Considerações finais

Resultados ruins também são resultados.

O software auxilia o processo de tomada de decisão, mas quem toma a decisão final é você.

“*Garbage in, garbage out (GIGO)*” -> “lixo entra, lixo sai”.  
George Fuechsel (Técnico da IBM)

“se devidamente torturados, os dados contam qualquer coisa”.  
Darrel Huff - Como Mentir com Estatísticas.

