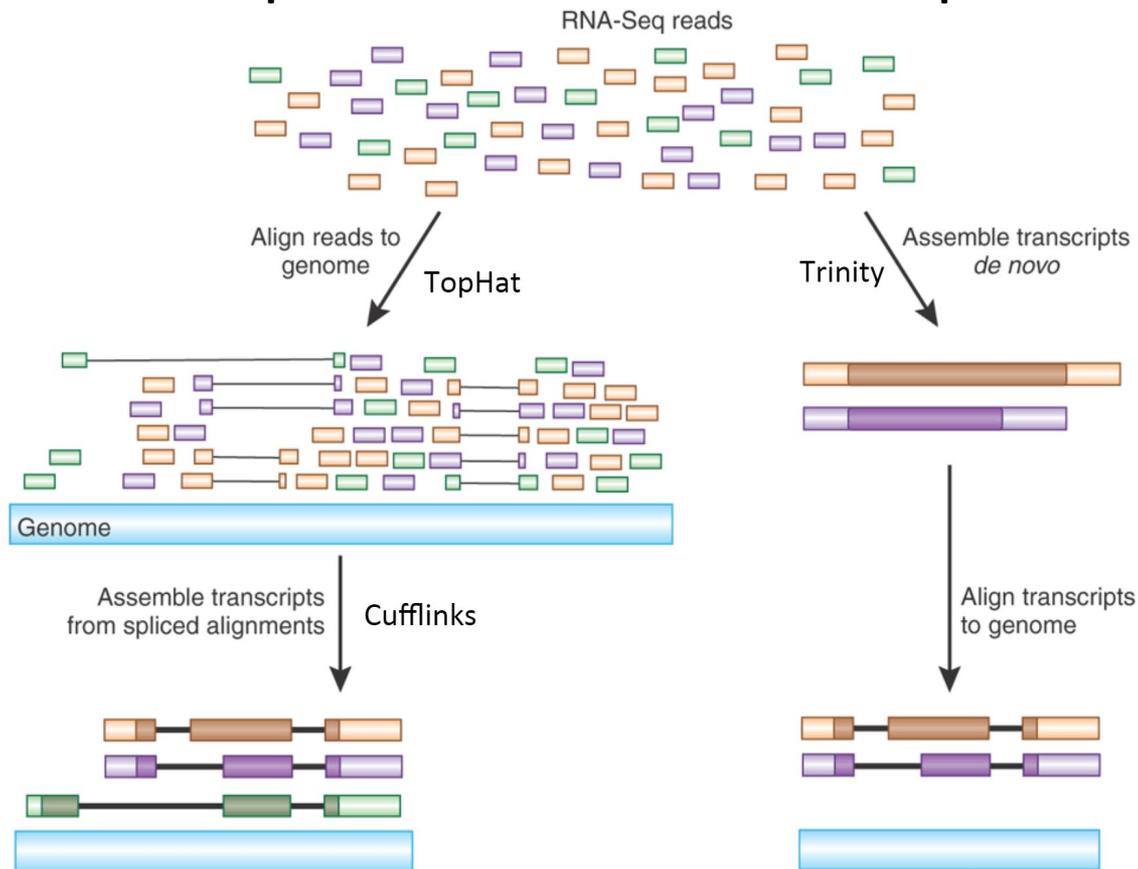


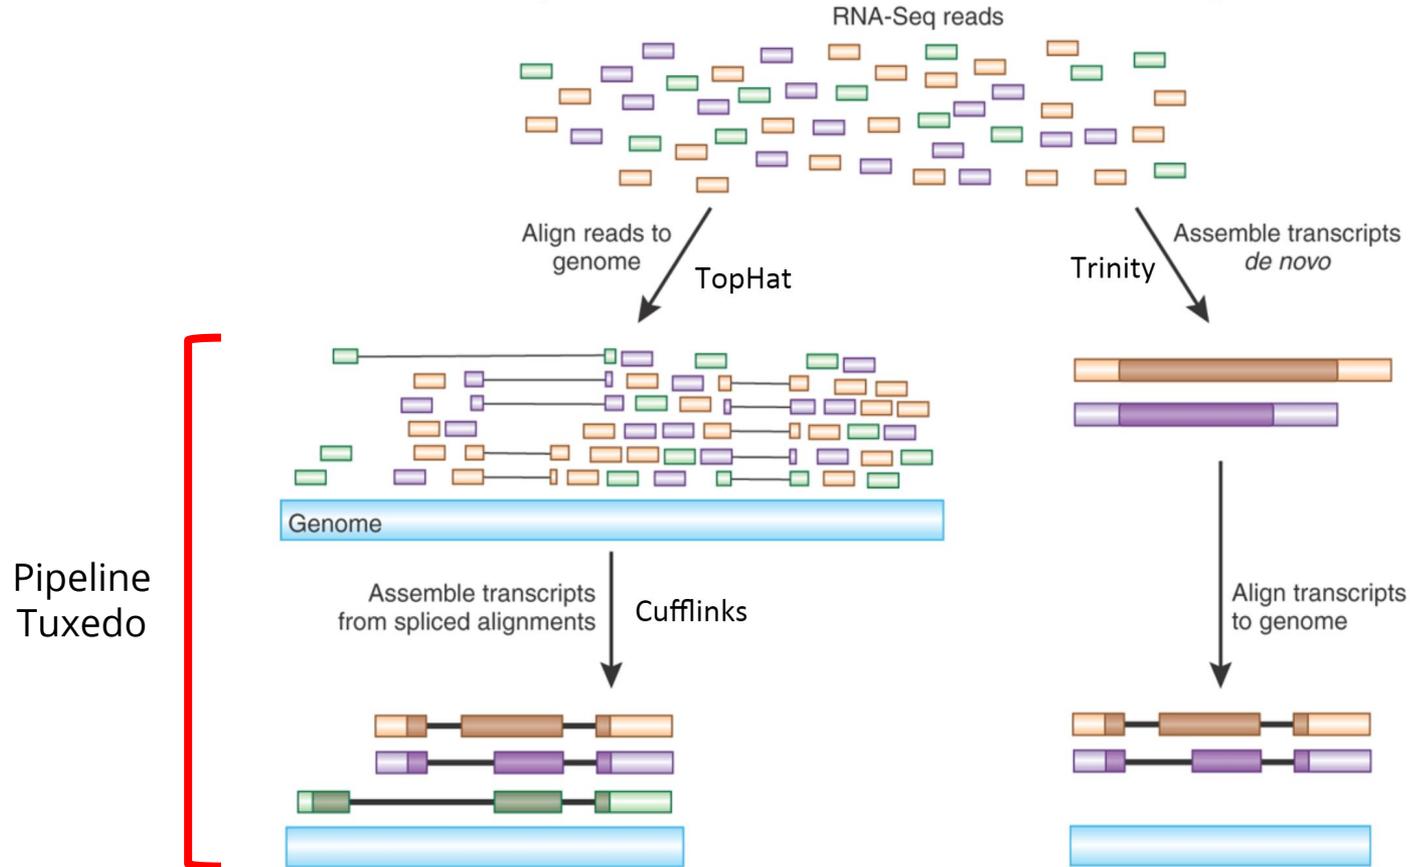


Montagem  
transcriptoma  
utilizando Trinity

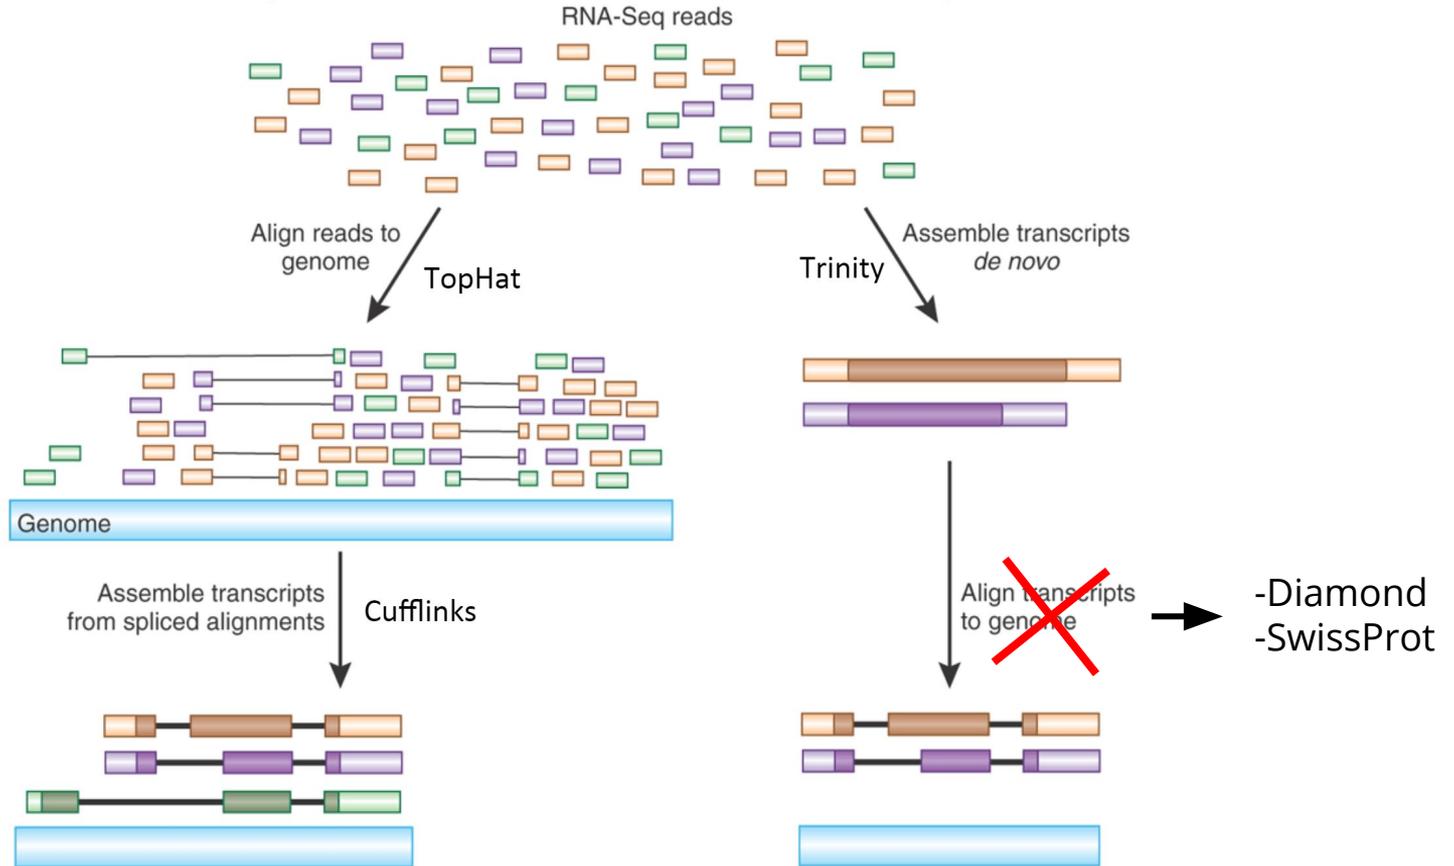
# Transcript Reconstruction from RNA-Seq Reads



# Transcript Reconstruction from RNA-Seq Reads



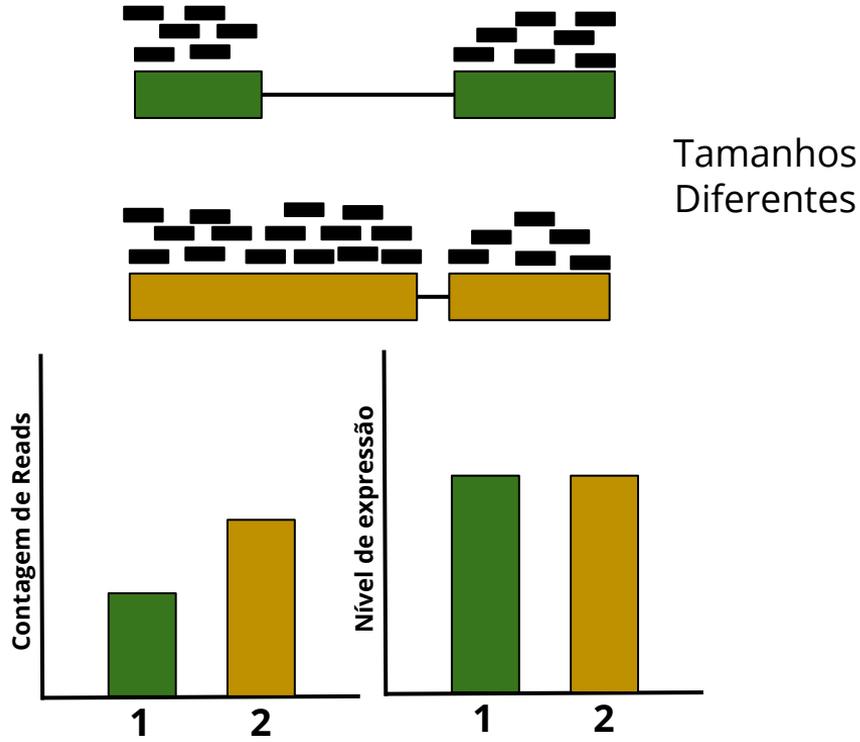
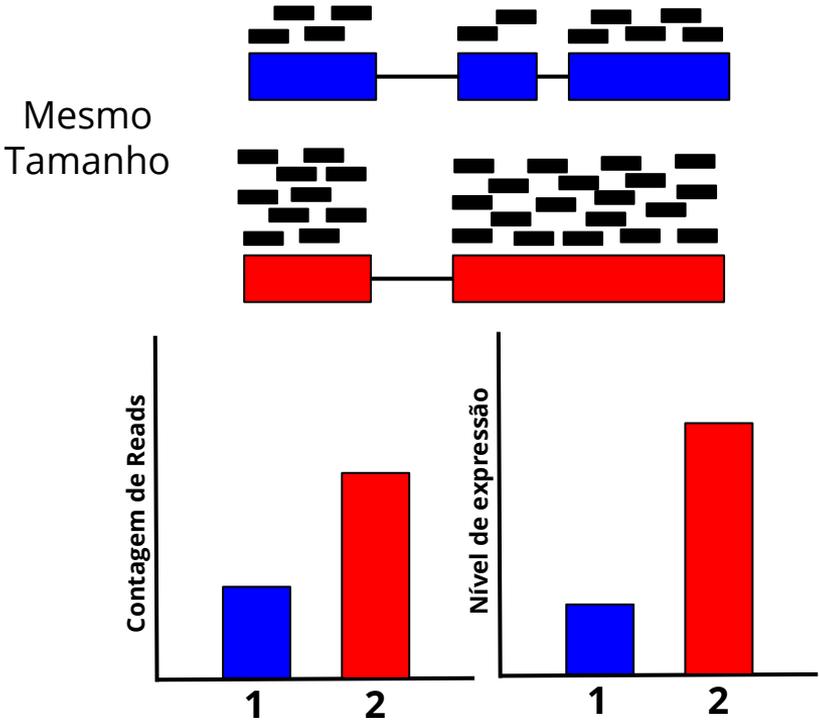
# Transcript Reconstruction from RNA-Seq Reads





Montamos os transcritos, e agora?

# Contagem e estimação de abundância



# Normalização dos dados

**RPM** = single-end

**CPM** = paired-end

**RPM** (**R**eads **P**er **M**illion mapped reads) = **CPM** (**C**ounts **P**er **M**illion mapped reads)

$$\text{RPM ou CPM} = \frac{\text{Número de reads mapeados nos genes} \times 10^6}{\text{Número total de reads mapeadas}}$$

Exemplo: Total de reads mapeadas 4 milhões e 5 mil reads pra um gene:

$$\text{RPM or CPM} = \frac{5000 \times 10^6}{4 \times 10^6} = 1250$$

# Normalização dos dados

**RPKM** = single-end

**FPKM** = paired-end

**RPKM** (**R**eads **P**er **K**ilo base per **M**illion mapped reads) = **FPKM** (**F**ragments **P**er **K**ilo base per **M**illion mapped reads)

$$\text{RPKM ou FPKM} = \frac{\text{Número de reads mapeados no gene} \times 10^3 \times 10^6}{\text{Número total de reads mapeadas} \times \text{Tamanho do gene em bp}}$$

Exemplo: Total de reads mapeadas 4 milhões e 5 mil reads pra um gene com tamanho de 2000 bp:

$$\text{RPKM} = \frac{5000 \times 10^3 \times 10^6}{4 \times 10^6 \times 2000} = 625$$

# Normalização dos dados

## TPM (Transcripts Per Million)

- Permite comparar as bibliotecas (quantidade de reads totais) com tamanhos diferentes

$$\text{TPM} = \frac{\text{RPKM ou FPKM} \times 10^6}{\sum \text{RPKM ou FPKM}}$$

# Normalização dos dados

**TMM** (Trimmed Mean of **M**-values)

$$\log_2(\text{TMM}_k^{(r)}) = \frac{\sum_{g \in G^*} w_{gk}^r M_{gk}^r}{\sum_{g \in G^*} w_{gk}^r} \text{ where } M_{gk}^r = \frac{\log_2\left(\frac{Y_{gk}}{N_k}\right)}{\log_2\left(\frac{Y_{gr}}{N_r}\right)} \text{ and } w_{gk}^r = \frac{N_k - Y_{gk}}{N_k Y_{gk}} + \frac{N_r - Y_{gr}}{N_r Y_{gr}};$$

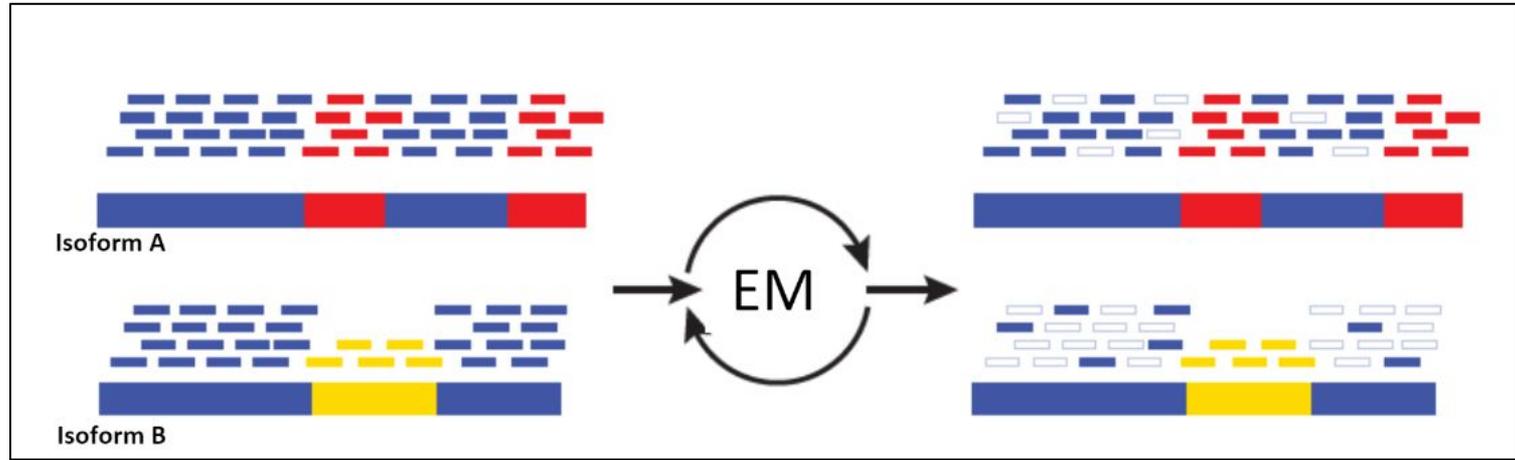
$Y_{gk}, Y_{gr} > 0.$

# Normalização dos dados

## **TMM** (Trimmed **M**ean of **M**-values)

- TMM é um método de normalização que permite comparações entre amostras diferentes;
- É uma boa escolha para remover os “*batch effects*” ao comparar as amostras de diferentes tecidos/genótipos ou nos casos em que a população de mRNA seria significativamente diferente entre as amostras.
- Batch effects = efeito do único sobre o todo;
- Alto valor de expressão de alguns genes = diminuição do valor de TPM dos outros;
- Retira-se os genes que são muito diferentes.

# Vamos utilizar o Salmon!



Azul = Reads multi-mapeadas

Vermelho e Amarelo = Reads únicas mapeadas

Usa-se o método *Expectation Maximization* (EM) para encontrar o melhor assinalamento das reads nos transcritos.

Reads mapeadas, contadas e suas abundâncias  
estimadas: aplicar métodos estatísticos

# Análises de expressão diferencial

Envolve:

- Contagem de reads;
- Testes de significância.

Vamos utilizar o edgeR:

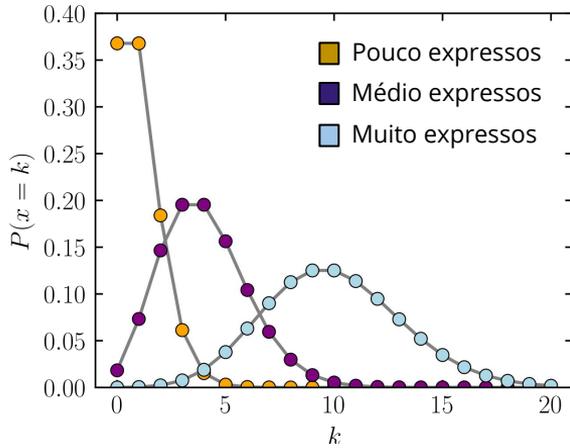
- As variações técnicas na contagem de reads em um experimento de RNA-Seq por *feature* é modelada pela Distribuição de Poisson:

$$P(X=k) = f(k;\lambda) = \frac{e^{-\lambda}\lambda^k}{k!}$$

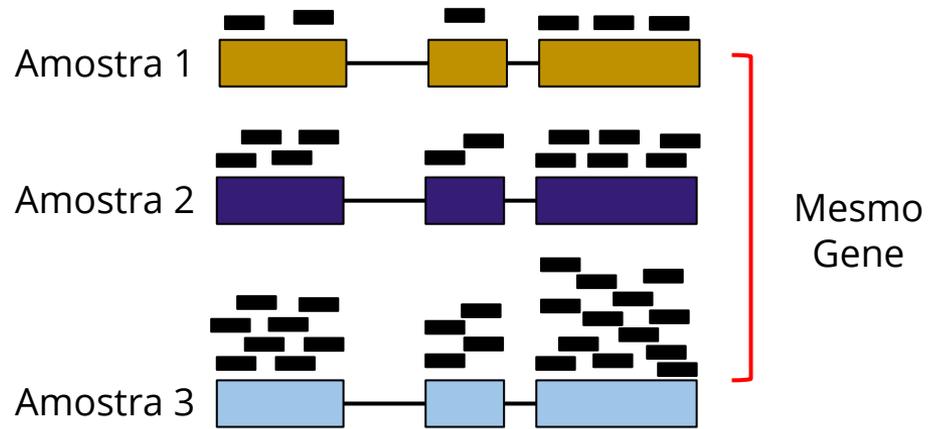
X = variável randômica;  
k = número de ocorrências;  
 $\lambda$  = representa o valor médio "esperado" de uma ocorrência se ela for repetida infinita vezes;  
 $f(k;\lambda)$  = probabilidade de que ocorra k ocorrências dado  $\lambda$ .

# edgeR

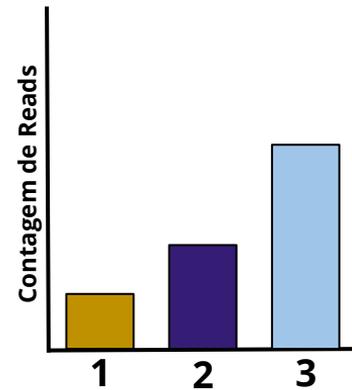
$\lambda$  = média do número de reads



**k = Número de reads**



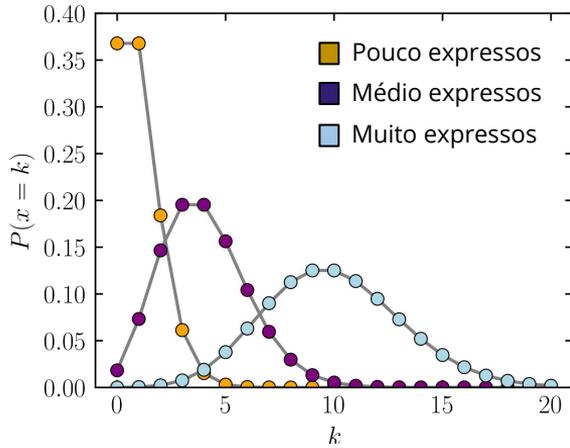
Avaliar a  
significância desta  
diferença na  
contagem de Reads



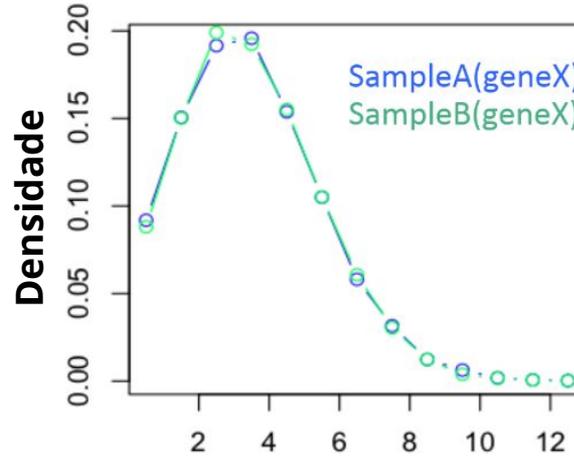
# edgeR

amostra A (gene) = amostra B (gene) = 4 reads

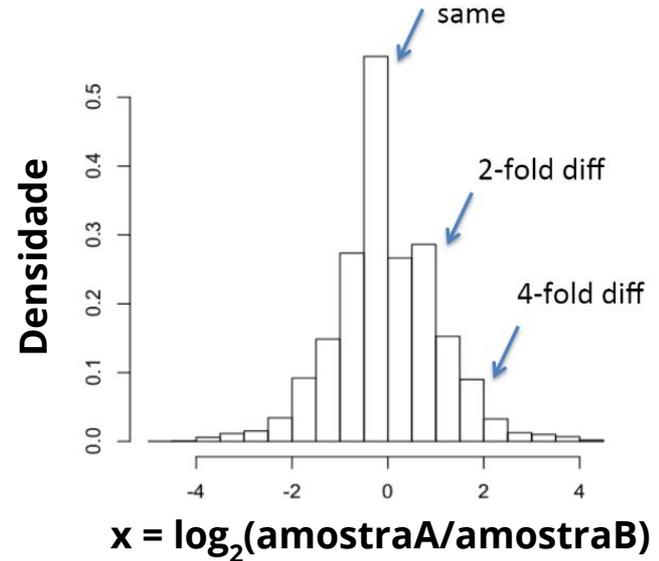
$\lambda$  = média do número de reads



k = Número de reads

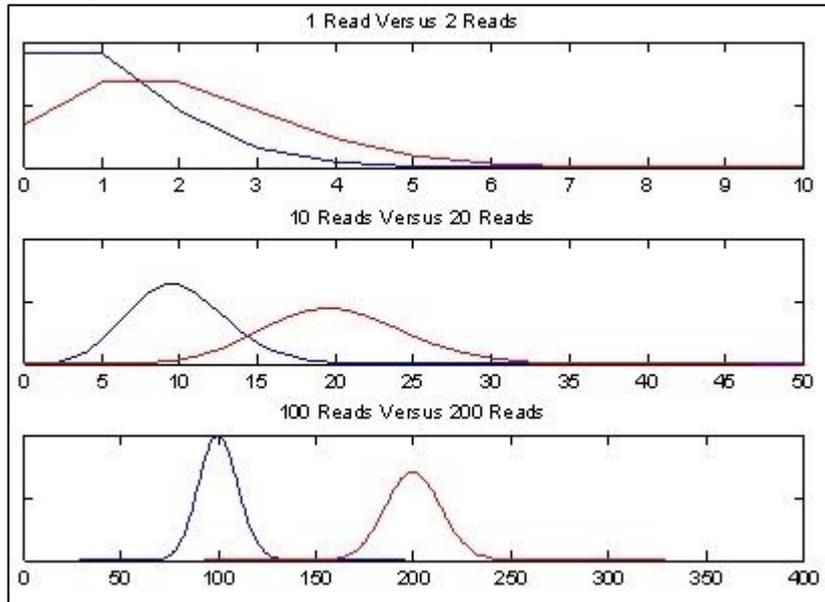


k = Número de reads



x =  $\log_2(\text{amostraA}/\text{amostraB})$

# edgeR



Mais Reads = Maior o poder estatístico

Exemplo de 5000 reads por amostra:

	SampleA	Sample B	Fisher's Exact Test (P-value)
geneA	1	2	1.00
geneB	10	20	0.098
geneC	100	200	< 0.001

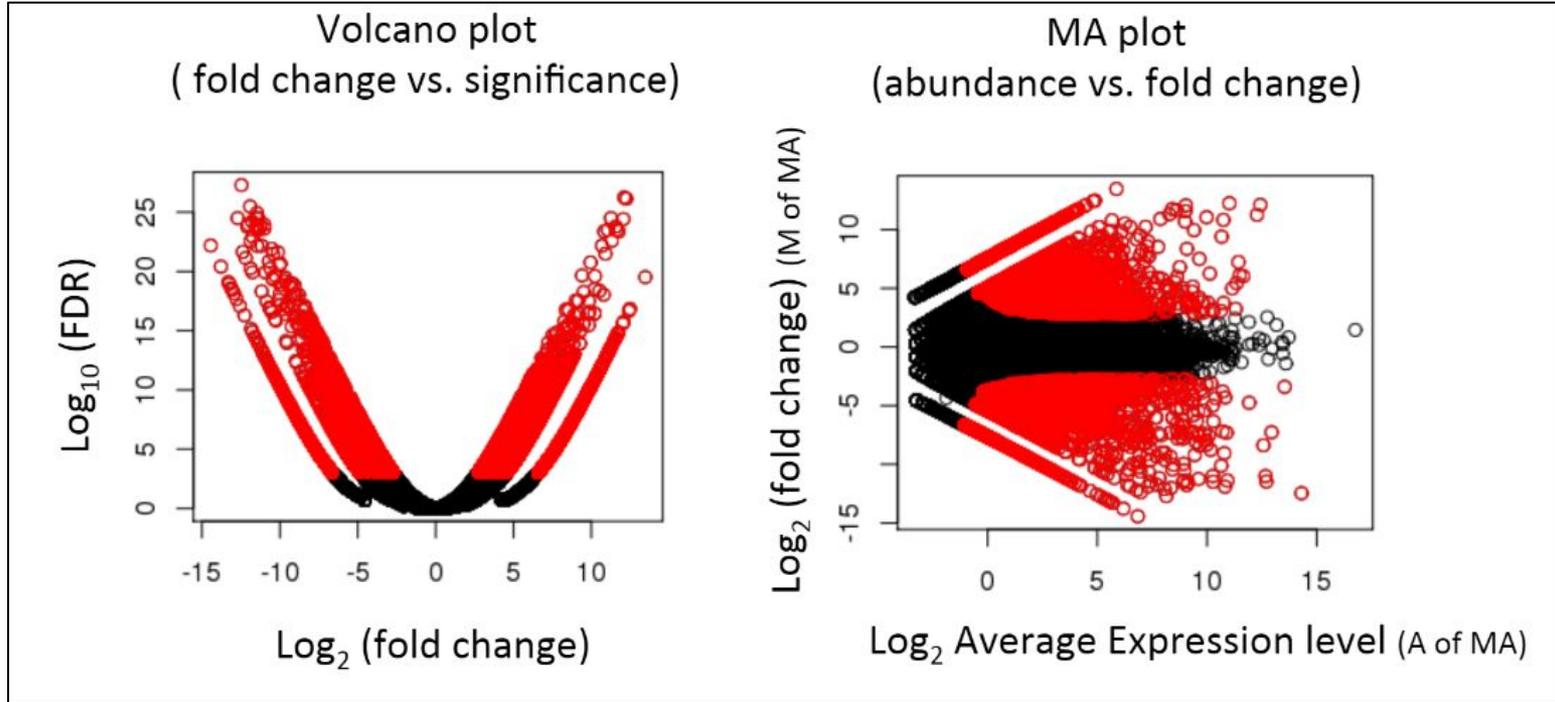
$$\frac{\text{amostraA}}{\text{amostraB}} = \frac{1}{2} = \frac{10}{20} = \frac{100}{200} = 0.5$$

$$\frac{\text{amostraB}}{\text{amostraA}} = \frac{2}{1} = \frac{20}{10} = \frac{200}{100} = 2$$

$$\log_2 0.5 = -1$$
$$\log_2 2 = +1$$

# edgeR

**False Discovery Rate** = probabilidade do gene não ser diferencialmente expresso. Representa a probabilidade do gene não ser diferencialmente expresso dado o seu p-valor e todos os outros testes estatísticos feitos. O p-valor não pode ser usado em condições com muito/pouco genes diferenciados.



Como descobrimos quem são os transcritos se não temos o genoma?



DIAMOND é um alinhador de sequências para proteínas e DNA traduzido, desenhado para ter alta performance em um banco de dados muito grande:

- Alinhamento pairwise com até 100x-10,000x mais velocidade que o BLAST.
- Baixa necessidade de recursos e adequado para execução em computadores pessoais.
- Diferentes formatos de saída, como por exemplo o formato BLAST, tabulado, e em formato XML.

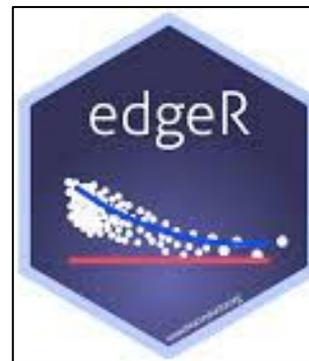
Dr Benjamin Buchfink, Max Planck Institute for Developmental Biology, Tübingen, Germany  
*March 26th*  
**Sensitive tree-of-life scale protein alignment using DIAMOND**  
*Friday,*  
*2PM*  
Chair: Gabriel Fernandes, IRR Fiocruz Minas  
[Link](#) ID: 959 1978 7208 passwd: brazweb21



Montagens dos transcritos



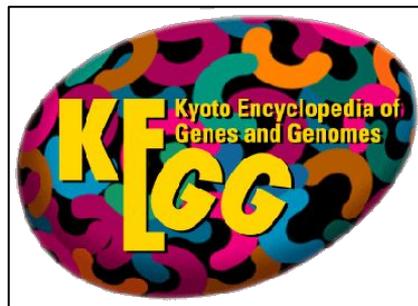
Contagem e abundâncias dos genes



Testes Estatísticos



Anotação dos transcritos



Vias metabólicas



Rede de interações