

# Análise de Dados Genéticos

Marcus Nunes

Departamento de Estatística - UFJF

2 e 3 de Outubro de 2014

1 Introdução

2 DNA

3 Métodos

4 Aplicação

# Malcolm Gladwell

Especialista - 10.000 horas

Aprendiz - 2.000 horas

Deficiência Crítica

# Quem já jogou RPG?

NOME DO PERSONAGEM				JOGADOR			
CLASSE E NÍVEL		RAÇA	TENDÊNCIA	DIVINDADE			
TAMANHO	IDADE	SEXO	ALTURA	PESO	OLHOS	CABELOS	PELE
HABILIDADE		VALOR	MOD. DE HABILIDADE	VALOR TEMPORÁRIO	MOD. TEMPORÁRIO		
<b>FOR</b> FORÇA							
<b>DES</b> DESTREZA							
<b>CON</b> CONSTITUIÇÃO							
<b>INT</b> INTELIGÊNCIA							
<b>SAB</b> SABEDORIA							
<b>CAR</b> CARISMA							
		TOTAL		FERIMENTOS / PVs ATUAIS		DANO POR CONTUSÃO	
		<b>PV</b> PONTOS DE VIDA					
		<b>CA</b> CLASSE DE ARMADURA		= 10 + <input type="text"/>			
		TOTAL		BÔNUS DE ARMADURA	BÔNUS DE ESCUDO	MOD. DE DESTREZA	MOD. DE TAMANHO
		<b>TOQUE</b> CLASSE DE ARMADURA				ARMADURA NATURAL	MOD. DE DEFLEXÃO
		<b>SURPRESA</b> CLASSE DE ARMADURA					
		<b>INICIATIVA</b> MODIFICADOR		= <input type="text"/> + <input type="text"/> + <input type="text"/>		OUTROS	
		TOTAL		MOD. DE DESTREZA			
		BÔNUS BASE	MOD. DE HABILIDADE	MOD. MÁGICO	OUTROS		
TESTE DE RESISTÊNCIA		<b>FORTITUDINE</b> (CONSTITUIÇÃO)				MOD. CONDICIONAIS	
			= <input type="text"/> + <input type="text"/> + <input type="text"/> + <input type="text"/> + <input type="text"/>				
		<b>REFLEXOS</b> (DESTREZA)					
		<b>VONTADE</b> (SABEDORIA)					
<b>BÔNUS BASE DE ATAQUE</b> <input type="text"/>				<b>RESISTÊNCIA À MAGIA</b> <input type="text"/>			
<b>AGARRAR</b> <small>MOTRILHARDE</small> <input type="text"/> = <input type="text"/> + <input type="text"/> + <input type="text"/> + <input type="text"/>							

**DUNGEONS & DRAGONS®**

PLANILHA DE PERSONAGEM

PERÍCIAS		GRADUAÇÃO MÁXIMA (CLASSE / OUTRA CLASSE)		/		
PERÍCIA	NOME DA PERÍCIA	HABILIDADE CHAVE	MOD. DE PERÍCIAS	MOD. DE HABILIDADE	GRADUAÇÃO	OUTROS
	<input type="checkbox"/> ABRIR FECHADURAS	DES				
	<input type="checkbox"/> ACROBACIA ■	DES <sup>R</sup>				
	<input type="checkbox"/> ADESTRAR ANIMAIS	CAR				
	<input type="checkbox"/> ARTE DA FUGA ■	DES <sup>R</sup>				
	<input type="checkbox"/> ATUAÇÃO (_____)	CAR				
	<input type="checkbox"/> ATUAÇÃO (_____)	CAR				
	<input type="checkbox"/> ATUAÇÃO (_____)	CAR				
	<input type="checkbox"/> AVALIAÇÃO ■	INT				
	<input type="checkbox"/> BLEFAR ■	CAR				
	<input type="checkbox"/> CAVALGAR ■ (_____)	DES				
	<input type="checkbox"/> CONCENTRAÇÃO ■	CON				
	<input type="checkbox"/> CONHECIMENTO (_____)	INT				
	<input type="checkbox"/> CONVERSAR	INT				

# O que um Bioestatístico precisa saber?

**ESTatística:** descrição, modelagem,  
testes de hipóteses, provar teoremas  
e manipular expressões algébricas

EST

# O que um Bioestatístico precisa saber?

**SISTemas:** ser proficiente em computação  
em geral, sabendo como usar diferentes  
programas e sistemas operacionais

EST      SIS

# O que um Bioestatístico precisa saber?

**ALGoritmos:** conseguir traduzir procedimentos  
em alguma linguagem de programação

EST      SIS      ALG

# O que um Bioestatístico precisa saber?

**COMunicação:** conseguir entender problemas de outras áreas e comunicar suas conclusões para outras pessoas

EST      SIS      ALG      COM

# O que um Bioestatístico precisa saber?

**PERsistência:** tentar diferentes maneiras de encarar os problemas mesmo quando eles parecem sem solução

EST

SIS

ALG

COM

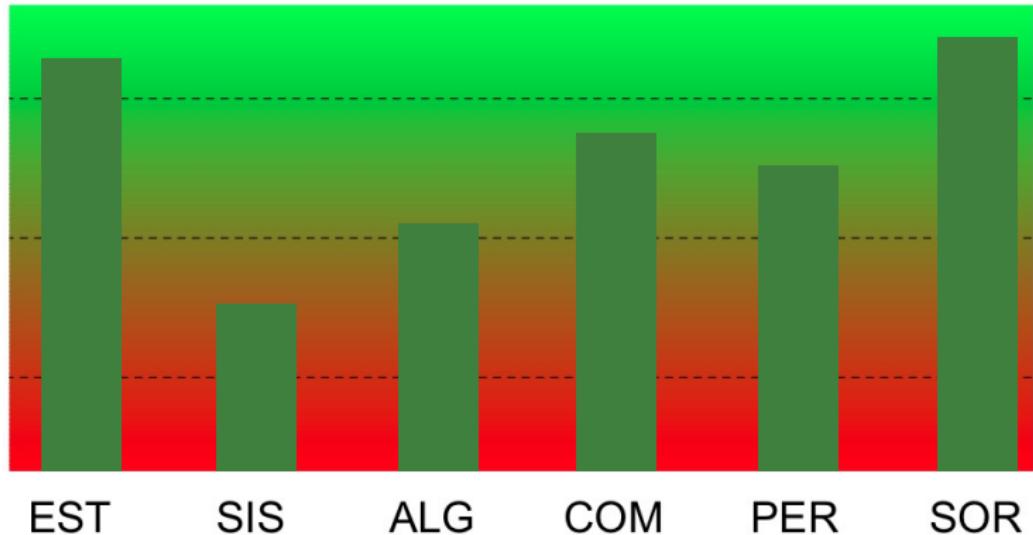
PER

# O que um Bioestatístico precisa saber?

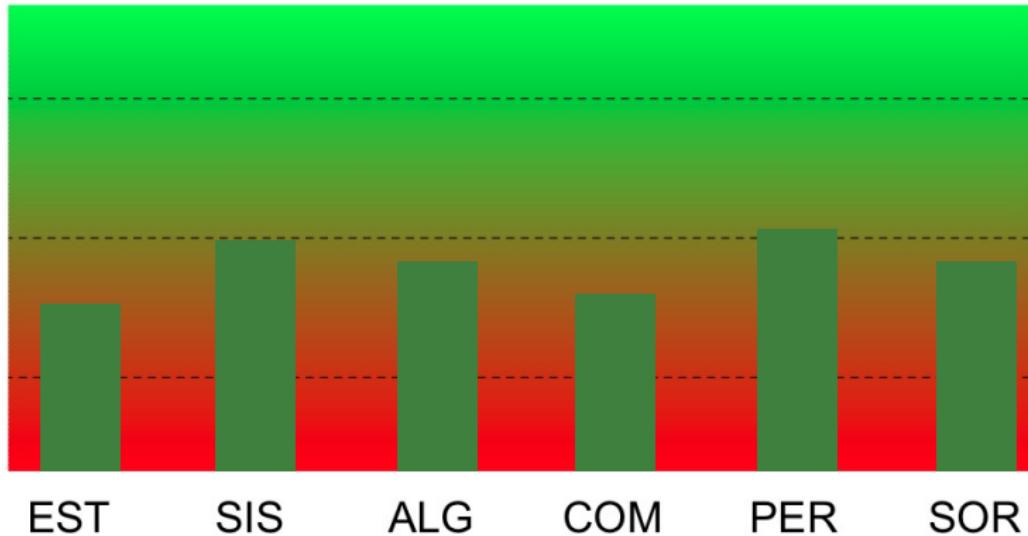
**SORte:** estar no lugar certo e na hora certa  
e ter as habilidades necessárias quando  
esta hora chegar

EST      SIS      ALG      COM      PER      SOR

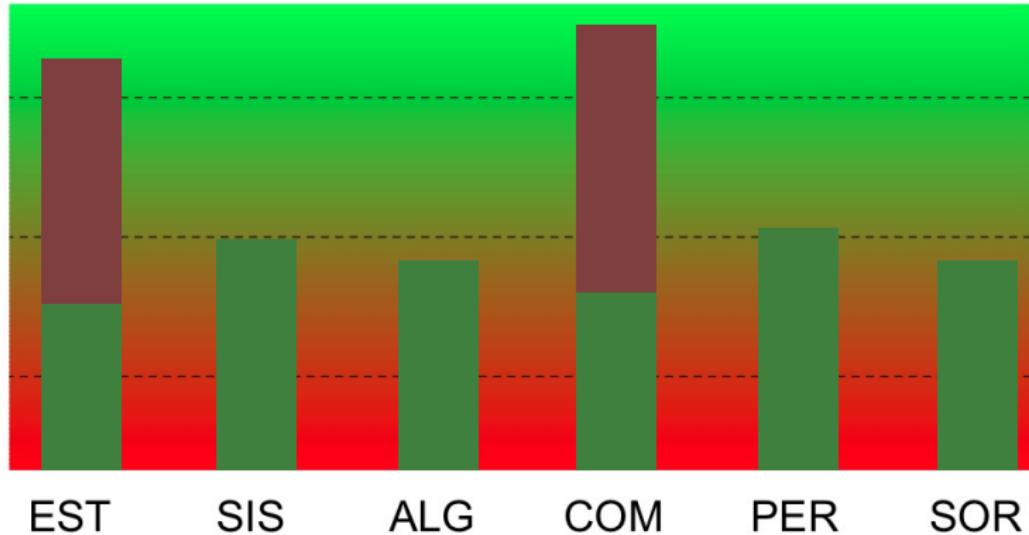
# O que eu sei



# Estar na média não é bom



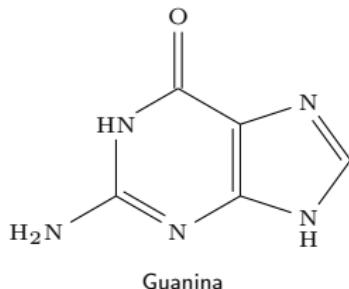
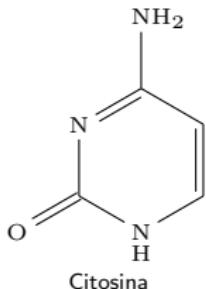
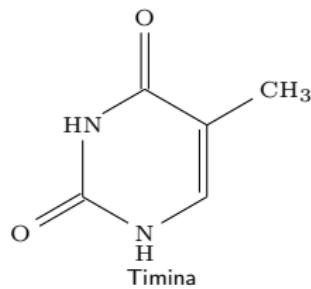
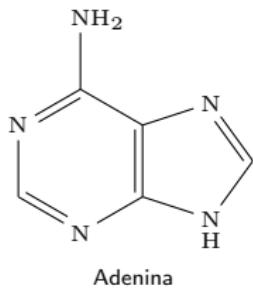
Seja muito bom em algumas áreas



# DNA

- Descrito pela primeira vez em 1948 (Watson e Crick)
- A genética já era conhecida anteriormente
- Mendel e suas ervilhas
- Francis Galton e a eugenia

# Estrutura Química do DNA



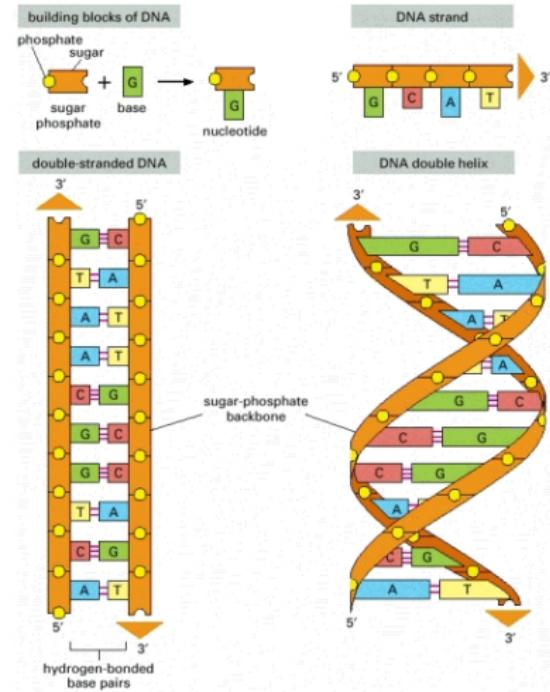
# Mas para que serve o DNA?

- Tudo
- Cor dos olhos, altura, propensão a sofrer de doenças, testes de paternidade no Programa do Ratinho
- Codifica aminoácidos em proteínas

# Mais sobre DNA

- Cada nucleotídeo é uma base
- A adenina liga-se apenas com a timina, enquanto a citosina liga-se apenas com a guanina
- O genoma humano possui mais de 3 bilhões de pares de base

# Estrutura do DNA



# O que desejamos saber sobre o DNA?

- Expressão gênica
- Processo em que a informação de um gene é utilizada na síntese de um produto gênico
- Em geral, transformar um ou mais aminoácidos em proteínas

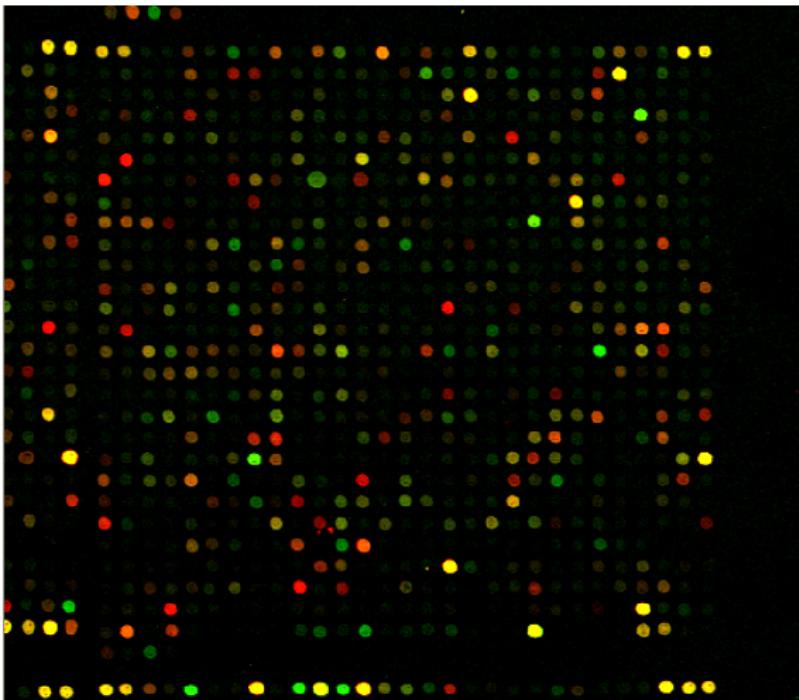
# Tecnologias de Sequenciamento

- Sanger sequencing
- Microarrays
- RNA-Seq

# Sanger Sequencing

- Usado no Projeto Genoma Humano
- Custou US\$ 2,7 bilhões
- 13 anos para ficar pronto

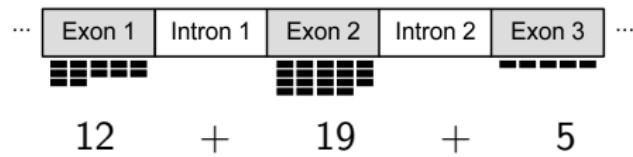
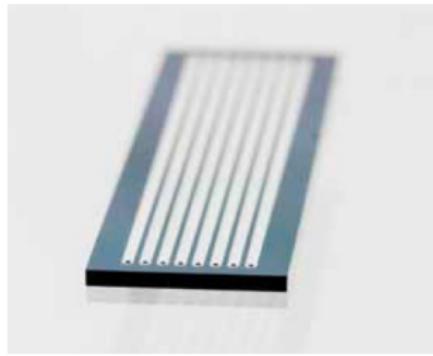
# Microarrays



# Microarrays

- Estão caindo em desuso
- Preço entre US\$ 190 e US\$ 450 por array
- Maior disponibilidade no mercado

# RNA-Seq



# RNA-Seq

- Método cuja utilização vem crescendo mais ultimamente
- Cada sequenciamento custa entre US\$ 805 e US\$1.700 (em setembro de 2014)
- Leva 8 horas para ficar pronto

# MinION

- Tecnologia sendo desenvolvida na universidade de Oxford
- Cada chip de sequenciamento custará US\$ 900
- A análise pode ser feita em tempo real

# MinION



# Pipeline

- ① Preparação da amostra
- ② Sequenciamento
- ③ Controle de qualidade
- ④ Alinhamento das leituras
- ⑤ Análise e descrição dos resultados

# Preparação da Amostra e Sequenciamento

- Não nos interessa aqui
- Função de um biólogo ou bioinformata
- Depende da tecnologia utilizada

## Exemplo de Sequenciamento

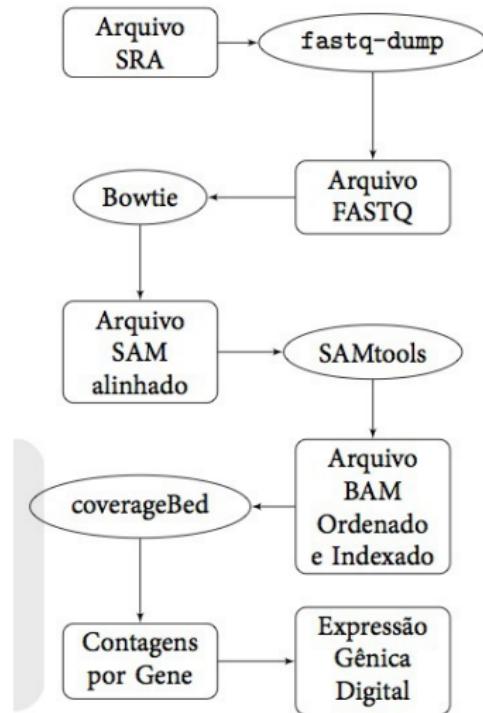
```
@SRR014849.1 EIXKN4201CFU84 length=50
GGGGGGGGGGGGGGGGCTTTTGTGAAACCGAAAGGGTTTGAAAT
+SRR014849.1 EIXKN4201CFU84 length=50
3+&#";;;;;;;;;"7F@71,'";C?,B;?6B;:EA1EA 1EA5'9B:
```

*@título e descrição opcional*  
*linha com o que foi sequenciado*  
*+repetição opcional do título*  
*linha com as qualidades da sequência*

# Alinhamento das Leituras

- Genoma de referência
- bowtie, SAMtools, bedtools
- Análise e descrição dos resultados

# Fluxograma do Pipeline



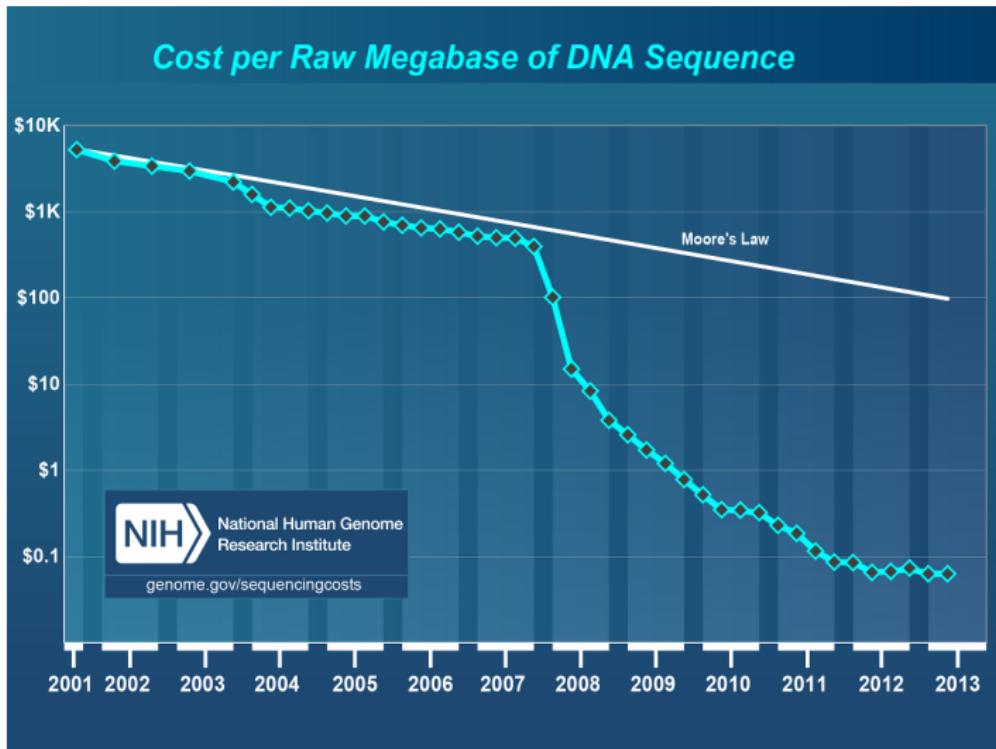
# Recursos

- Bioconductor - <http://bioconductor.org/>
- Gene Expression Omnibus (GEO)  
<http://www.ncbi.nlm.nih.gov/geo/>
- BioStars - <http://www.biostars.org/>

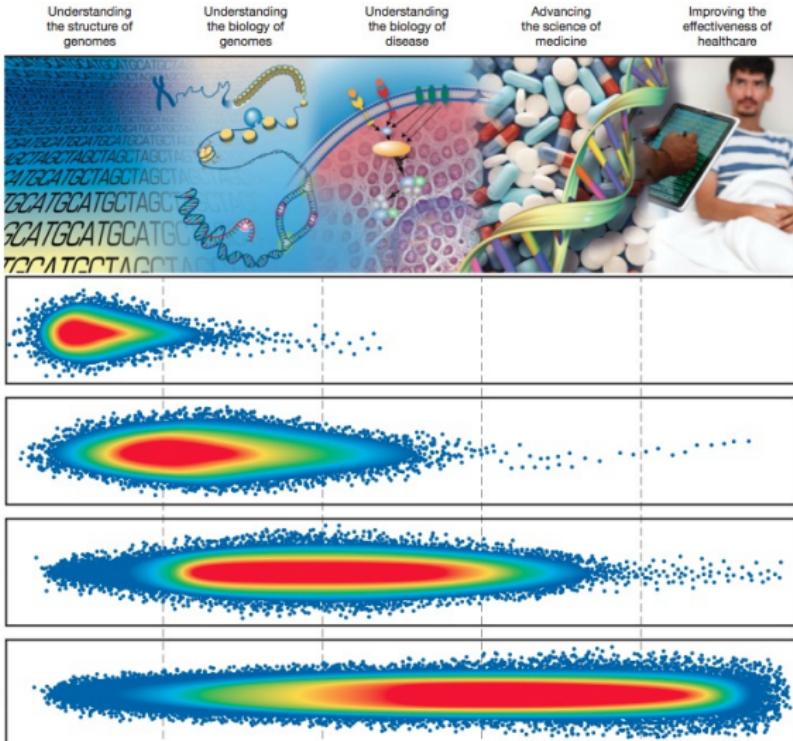
# Sequenciar Genomas é Cada Vez Mais Barato

- Projeto Genoma Humano: 13 anos, US\$ 2,7 bilhões
- RNA-Seq: 8 horas, entre US\$ 805 e \$1.700
- MiniON: tempo real, US\$ 900

# Custo de Sequenciamento



# Futuro da Genômica



# Planejamento de Experimentos

- Experimentos de RNA-Seq devem ser planejados corretamente
- Máximo de informação
- Mínimo de custo

# Planejamento de Experimentos

- Amostragem
- Replicação
- Agrupamento em blocos
- Aleatorização

# Amostragem

- Ideias similares às de outros tipos de experimentos
- Definir claramente a nossa população de interesse
- Obter amostras representativas

# Aleatorização

- Fazer comparações entre tratamentos
- Sujeitos distribuídos de maneira aleatória
- Evitar vícios

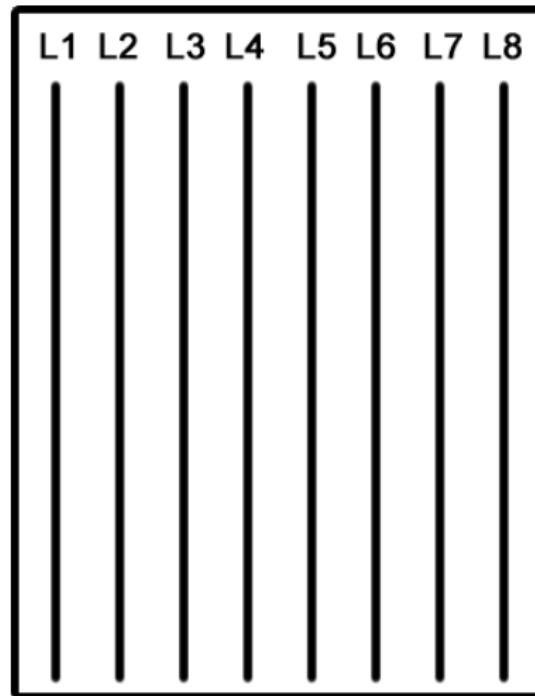
# Replicação

- Número suficiente de sujeitos no estudo
- Replicação biológica
- Replicação técnica

# Agrupamento em blocos

- Reduzir a variabilidade na análise
- Agrupando sujeitos similares
- Bloco incompleto equilibrado

# Agrupamento em blocos

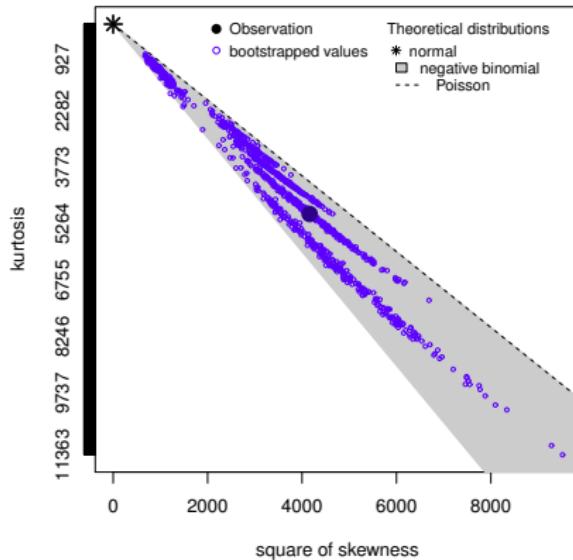


# Modelagem

- Dados discretos
- Não-normalidade
- Testes múltiplos

# Distribuição de Contagens

Cullen and Frey graph



# Distribuições

## Poisson

- $f(x|\lambda) = \frac{e^{-\lambda}\lambda^x}{x!}$
- $E(Y) = \lambda$
- $\text{Var}(Y) = \lambda$

## Binomial Negativa

- $f(y|r,p) = \binom{r+y-1}{y} p^r (1-p)^y$
- $E(Y) = \frac{pr}{1-p}$
- $\text{Var}(Y) = \frac{pr}{(1-p)^2}$
- $f(y|\mu,\phi) = \frac{\Gamma(y+\phi^{-1})}{\Gamma(\phi^{-1})\Gamma(y+1)} \left(\frac{1}{1+\phi\mu}\right)^{\phi^{-1}} \left(\frac{\phi\mu}{1+\phi\mu}\right)^y$
- $E(Y) = \mu$
- $\text{Var}(Y) = \mu + \phi\mu^2$

# Modelos Lineares Generalizados

- uma distribuição de probabilidade, da família exponencial, para o vetor resposta  $\mathbf{Y}$
- um preditor linear para a esperança  $\eta = \mathbf{X}\boldsymbol{\beta}$ , que especifica as variáveis explicativas do modelo
- uma função de ligação  $g(\cdot)$  que relaciona  $\eta$  e  $\mu$  tal que  $\eta = g(\mu)$

# Modelos Lineares Generalizados

- $f(y|\theta, \phi) = \exp \left\{ \frac{y_i \theta_i - \kappa(\theta_i)}{\alpha_i(\phi)} + c(y_i|\phi) \right\}$
- $\kappa'(\theta_i) = E(Y)$
- $\kappa''(\theta_i) = \text{Var}(Y)$

# Excesso de Zeros

- Experimentos RNA-Seq geram um grande número de zeros
- Normalmente, estas observações são descartadas na análise
- O excesso de zeros cria sobredispersão
- Propomos um método que é capaz de lidar com o excesso de zeros

# Modelos Hurdle e Zero-Inflated

$$f_H(y) = \begin{cases} p, & \text{if } y = 0 \\ (1 - p) \frac{f(y)}{1 - f(0)}, & \text{if } y = 1, 2, 3, \dots \end{cases}$$

$$f_{ZI}(y) = \begin{cases} q + (1 - q)f(0), & \text{if } y = 0 \\ (1 - q)f(y), & \text{if } y = 1, 2, 3, \dots \end{cases}$$

# Máxima Verossimilhança - Modelo Hurdle

$$\begin{aligned}
 L(y|p, \beta, \phi) &= \prod_{i=1}^n (1-p)^{I(y=0)} \\
 &\quad \times \left[ p \frac{\Gamma(y + \phi^{-1})}{\Gamma(\phi^{-1})\Gamma(y+1)} \left( \frac{\mu}{\phi^{-1} + \mu} \right)^y \left( \frac{1}{(1 + \phi\mu)^{\phi^{-1}} - 1} \right)^{-\phi^{-1}} \right]^{1-I(y=0)} \\
 &= \prod_{i=1}^n (1-p)^{I(y=0)} p^{1-I(y=0)} \\
 &\quad \times \left[ \frac{\Gamma(y + \phi^{-1})}{\Gamma(\phi^{-1})\Gamma(y+1)} \left( \frac{\mu}{\phi^{-1} + \mu} \right)^y \left( \frac{1}{(1 + \phi\mu)^{\phi^{-1}} - 1} \right)^{-\phi^{-1}} \right]^{1-I(y=0)}
 \end{aligned}$$

$$\begin{aligned}
 \mathcal{L}(y|p, \beta, \phi) &= \log(L(y|p, \beta, \phi)) \\
 &= \log(L_1(y|p)L_2(y|\beta, \phi)) \\
 &= \log(L_1(y|p)) + \log(L_2(y|\beta, \phi)) \\
 &= \mathcal{L}_1(y|p) + \mathcal{L}_2(y|\beta, \phi)
 \end{aligned}$$

# Máxima Verossimilhança - Modelo Hurdle

$$\begin{aligned}\mathcal{L}(y_i|\mu,\phi) &= \log\left(\prod_{i=1}^n f(y_i|\mu,\phi)\right) \\ &= \log\left\{\prod_{i=1}^n \frac{\Gamma(\phi^{-1})}{\Gamma(\phi^{-1})\Gamma(y_i+1)} \left(\frac{1}{1+\phi\mu}\right)^{\phi^{-1}} \left(\frac{\phi\mu}{1+\phi\mu}\right)^{y_i}\right\} \\ &= \sum_{i=1}^n \left\{ y_i \log\left(\frac{1}{1+\mu\phi}\right) - \phi^{-1} \log(1+\phi\mu) + \log\Gamma(y_i+\phi^{-1}) \right. \\ &\quad \left. - \log\Gamma(y_i+1) + \log\Gamma(\phi^{-1}) \right\} \\ &= \sum_{i=1}^n \left\{ y_i \log(\mu\phi) - (y_i + \phi^{-1}) \log(1+\phi\mu) + \log\Gamma(y_i+\phi^{-1}) \right. \\ &\quad \left. - \log\Gamma(y_i+1) - \log\Gamma(\phi^{-1}) \right\}\end{aligned}$$

# Máxima Verossimilhança - Modelo Hurdle

$$\text{logit}(p) = x_i'(1 - p)$$

$$\log(\mu_i) = x_i'\beta$$

# Algoritmo IRLS

- ① Inicializar  $\beta$  e o preditor linear  $\eta$
- ② Calcular os pesos  $W^{-1} = \mathbf{V}g'(\beta)$ , onde  $\mathbf{V}$  é a variânciada dada por  $\kappa''(\theta)$ , onde  $\theta = [\beta, \phi]$
- ③ Calcular  $Z = \eta + (\mathbf{Y} - \beta)g'(\beta)$
- ④ Regressar  $Z$  nos predores  $x_1, x_2, \dots, x_n$  com pesos  $W$  para obter atualizações para  $\beta$
- ⑤ Calcular  $\eta$  baseado nas estimações da regressão
- ⑥ Calcular  $\beta$  como  $g^{-1}(\eta)$
- ⑦ Calcular a função de log-verossimilhança
- ⑧ Iterar até a convergência

# Algoritmo IRLS

$$x_1 = x_0 - \frac{f(x_0)}{f'(x_0)} \Rightarrow x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$$

$$H = \left[ \frac{\partial^2 \mathcal{L}}{\partial \beta_j \partial \beta_k} \right]$$

$$H = \begin{pmatrix} \frac{\partial^2 \mathcal{L}}{\partial \beta_1^2} & \frac{\partial^2 \mathcal{L}}{\partial \beta_1 \partial \beta_2} & \cdots & \frac{\partial^2 \mathcal{L}}{\partial \beta_1 \partial \beta_n} \\ \frac{\partial^2 \mathcal{L}}{\partial \beta_2 \partial \beta_1} & \frac{\partial^2 \mathcal{L}}{\partial \beta_2^2} & \cdots & \frac{\partial^2 \mathcal{L}}{\partial \beta_2 \partial \beta_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 \mathcal{L}}{\partial \beta_n \partial \beta_1} & \frac{\partial^2 \mathcal{L}}{\partial \beta_n \partial \beta_2} & \cdots & \frac{\partial^2 \mathcal{L}}{\partial \beta_n^2} \end{pmatrix}.$$

# Teste de Razão de Verossimilhança

$$H_0 : \beta_q = \beta_{q+1} = \cdots = \beta_{p-1}$$

$H_1$  : nem todos  $\beta_k$  em  $H_0$  são iguais

$$\Lambda(\mathbf{X}) = \frac{\sup_{\theta \in \Theta_0} L(\theta | \mathbf{X})}{\sup_{\theta \in \Theta_1} L(\theta | \mathbf{X})}$$

$$\Lambda(\mathbf{X}) = -2 \log \left( \frac{L_0(\theta | \mathbf{X})}{L_1(\theta | \mathbf{X})} \right),$$

$$\Lambda(\mathbf{X}) \xrightarrow{D} \chi_p^2$$

# edgeR

- Estimador de máxima verossimilhança condicional ajustada pelos quantis (Robinson e Smyth, 2010)
- Todas as amostras  $i$  no experimento possuem o mesmo tamanho (*i.e.*,  $m_i = m$ )
- A soma  $Z = Y_1 + Y_2 + \cdots + Y_k \sim \text{NB}(km\lambda, \phi k^{-1})$  é verdadeira

# edgeR

- Condicionando a verossimilhança em  $Z$  e tomando seu logaritmo natural, temos

$$\begin{aligned}\mathcal{L}(z|\phi) = & \left[ \sum_{i=1}^k \log \Gamma(y_i + \phi^{-1}) \right] + \log \Gamma(n\phi^{-1}) \\ & - \log \Gamma(z + k\phi^{-1}) - k \log \Gamma(\phi^{-1})\end{aligned}$$

- Com a equação acima é possível construir um método de estimativa para o parâmetro  $\phi$

# edgeR

- Seja  $m^* = \left( \prod_{i=1}^k m_i \right)^{\frac{1}{k}}$  a média geométrica dos tamanhos das bibliotecas
- Os dados observados são ajustados como se eles tivessem sido amostrados a partir de uma distribuição  $\text{NB}(m^* \lambda, \phi)$

# edgeR

- ➊ Encontre  $\phi$ , o estimador CML que maximiza a verossimilhança condicional
- ➋ Dada a estimativa de  $\phi$ , estime  $\lambda$
- ➌ Assumindo que  $y_i \sim NB(m_i\lambda, \phi)$ , calcule os percentis observados

$$p_i = P(Y < y_i | m_i\lambda, \phi) + \frac{1}{2}P(Y = y_i | m_i\lambda, \phi), \\ i = 1, 2, \dots, k$$

- ➍ Utilizando a interpolação linear das funções dos quantis, gere pseudo-dados de uma distribuição  $NB(m^*\lambda, \phi)$ , com quantis  $p_i$
- ➎ Calcule  $\phi$  utilizando a CML nos pseudo-dados
- ➏ Repita os passos 2 a 5 até  $\phi$  convergir

# edgeR

- É possível definir um teste exato
- Para dois grupos  $A$  e  $B$ , definimos  $Z_{tA}$  e  $Z_{tB}$  como as somas das pseudo-contagens destes grupos, sobre o número de amostras  $k_A$  e  $k_B$ . Sob a hipótese nula,

$$Z_{tl} \sim \text{NB}(n_l m^* \lambda_t, \phi n_l^{-1}), \quad l \in \{A, B\}$$

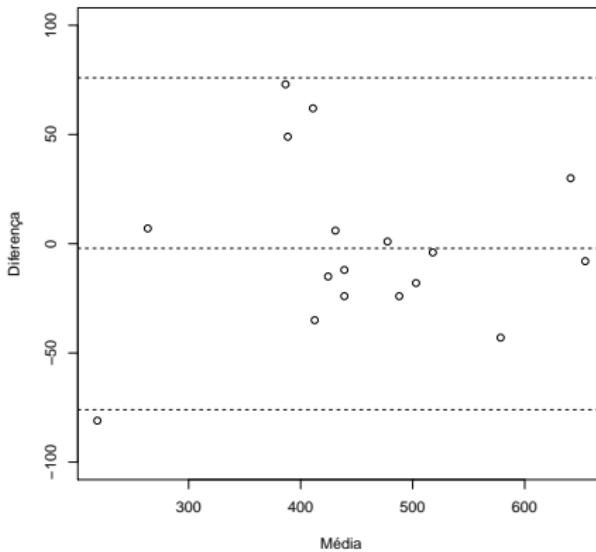
- Condicionando na soma das pseudo-contagens totais,  $Z_{tA} + Z_{tB}$  também é uma variável aleatória Binomial Negativa

# MA Plot

- O MA Plot é uma aplicação do gráfico de Bland-Altman em estudos genéticos
- Visa detectar diferenças sistemáticas entre duas replicações de um mesmo experimento
- Se estamos interessados na certa característica  $R$  de um experimento com duas replicações  $R_1$  e  $R_2$ , então as coordenadas cartesianas  $(x, y)$  do MA Plot são dadas por

$$R(x,y) = \left( \frac{R_1 + R_2}{2}, R_1 - R_2 \right)$$

# MA Plot



## Comparações Múltiplas

- É como chamamos o fato de realizarmos duas ou mais inferências simultâneas
- No caso de testarmos apenas uma hipótese, definimos uma região de rejeição para controlar a taxa de falsos positivos, conhecidos como Erros do Tipo I, enquanto atingimos o mínimo possível para a taxa de falsos negativos, chamados de Erros do Tipo II
- Conforme o número de testes aumenta, torna-se cada vez mais provável que os grupos controle e tratamento diferenciem-se em pelo menos uma característica apenas devido à chance

# Comparações Múltiplas

- Quando determinamos um nível  $\alpha$  para o Erro Tipo I de um teste estatístico, estamos na verdade dizendo que “ $\alpha \times 100\%$  das vezes em que deveríamos rejeitar a hipótese alternativa, nós estamos aceitando-a”
- Ou seja, se testamos a mesma hipótese nula 100 vezes, com um nível  $\alpha = 0,05$ , rejeitaremos  $H_0$  em 5 destes testes, mesmo  $H_0$  sendo verdade
- Existem diversas maneiras deste problema ser corrigido

## Correção de Bonferroni

- Se o nível desejado para erros do Tipo I em  $m$  testes realizados é (no máximo)  $\alpha$ , então  $\alpha/m$  é o valor da correção de Bonferroni para estes testes
- Justificativa:

$$\begin{aligned} P(\text{pelo menos um res. sig.}) &= 1 - P(\text{nenhum res. sig.}) \\ P(\text{pelo menos um res. sig.}) &= 1 - (1 - \alpha)^m \end{aligned}$$

## Correção de Bonferroni

- Se  $\alpha = 0,05$  e  $m = 100$ ,

$$P(\text{pelo menos um res. sig.}) = 1 - P(\text{nenhum res. sig.})$$

$$P(\text{pelo menos um res. sig.}) = 1 - (1 - 0,05)^{100}$$

$$P(\text{pelo menos um res. sig.}) = 0,9941$$

- Método conservador

# FDR

- False Discovery Rate
- Um conjunto de predições possui um percentual esperado de falsas predições
- Para uma série de testes de hipóteses independentes, a FDR é dada por

$$\text{FDR} = E \left( \frac{V}{V + S} \right)$$

onde  $V$  é o número de falsos positivos e  $S$  é o número de verdadeiros positivos

# FDR

Verdade	Decisão		Total
	Não-significativo	Significativo	
Hipótese nula	$U$	$V$	$m_0$
Hipótese alternativa	$T$	$S$	$m - m_0$
Total	$m - r$	$r$	$m$

# FDR

- Combinamos os p-valores de cada teste num único vetor de p-valores. Após este vetor ser compilado, duas etapas são realizadas:
  - ① Ordenar os  $m$  p-valores calculados do menor para o maior, denominando-os como  $p_{(1)}, p_{(2)}, \dots, p_{(m)}$
  - ② Encontrar o maior  $k$  tal que  $p_{(k)} \leq \frac{k}{m}\alpha$
- Assumindo que os testes de hipóteses são independentes, este método controla a FDR desejada

# Aplicação

- O conjunto de dados analisado aqui foi disponibilizado por Blekhman *et al.* (2010)
- As amostras foram obtidas a partir dos fígados de machos e fêmeas de três espécies de primatas: humanos (*Homo sapiens*), chimpanzés (*Pan troglodytes*) e macacos-rhesus (*Macaca mulatta*)

# Análise Exploratória dos Dados

- 3 replicações biológicas de cada tratamento
- Cada replicação biológica foi dividida em 2 faixas
- Foram coletadas 20689 características de cada uma das 36 faixas
- No total, são 71 milhões de leituras de 35 pares de base mapeáveis

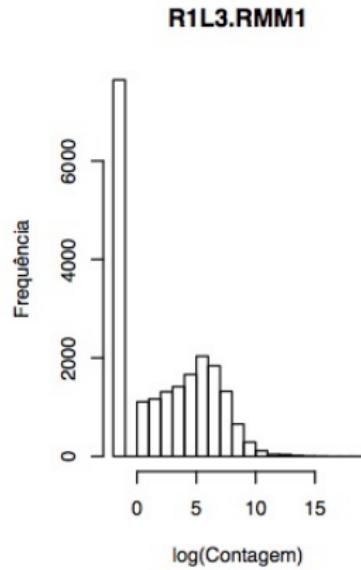
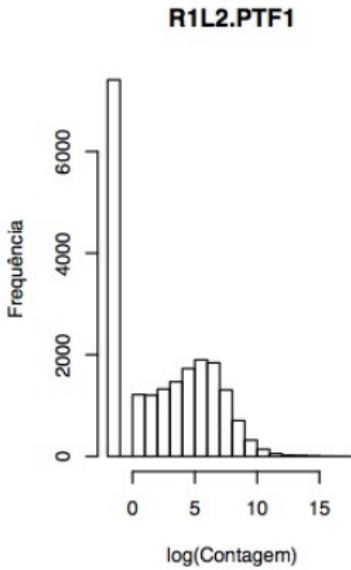
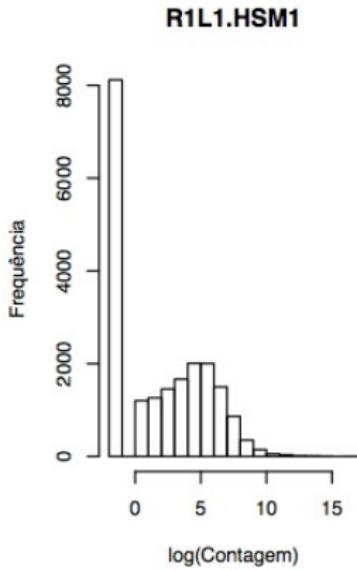
## Colunas da Matriz

```
[1] "EnsemblGeneID" "R1L1.HSM1"      "R1L2.PTF1"  
[4] "R1L3.RMM1"      "R1L4.HSF1"       "R1L6.PTM1"  
[7] "R1L7.RMF1"      "R2L2.RMF2"       "R2L3.HSM2"  
[10] "R2L4.PTF2"      "R2L6.RMM2"       "R2L7.HSF2"  
[13] "R2L8.PTM2"      "R3L1.RMM3"       "R3L2.HSF2"  
[16] "R3L3.PTM1"      "R3L4.RMF3"       "R3L6.HSM3"  
[19] "R3L7.PTF3"      "R3L8.RMM1"       "R4L1.HSM3"  
[22] "R4L2.HSF1"      "R4L3.RMM3"       "R4L4.PTF1"  
[25] "R4L6.PTM2"      "R4L7.RMF3"       "R4L8.HSM2"  
[28] "R5L1.RMF1"      "R5L2.HSM1"       "R5L3.PTF3"  
[31] "R5L4.RMM2"      "R5L8.RMF2"       "R6L2.PTM3"  
[34] "R6L4.PTM3"      "R6L6.PTF2"       "R8L1.HSF3"  
[37] "R8L2.HSF3"
```

# Contagens dos Genes

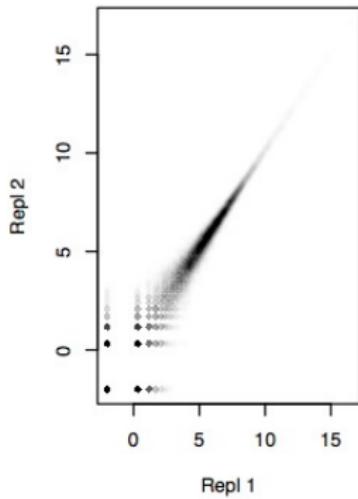
	EnsemblGeneID	R1L1.HSM1	R1L2.PTF1	R1L3.RMM1
1	ENSG00000000003	60	285	207
2	ENSG00000000005	0	1	1
3	ENSG00000000419	17	54	20
4	ENSG00000000457	50	61	68
5	ENSG00000000460	9	6	2
6	ENSG00000000938	32	50	44
7	ENSG00000000971	1726	2617	7207
8	ENSG00000001036	99	135	109
9	ENSG00000001084	155	211	455
10	ENSG00000001167	13	35	52

# Histogramas

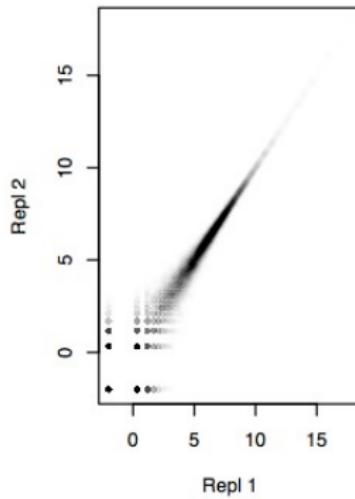


# Gráficos de Dispersão

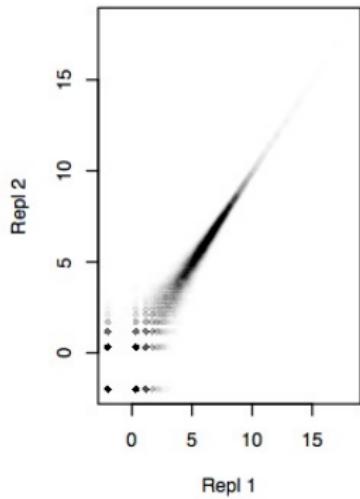
HSM1



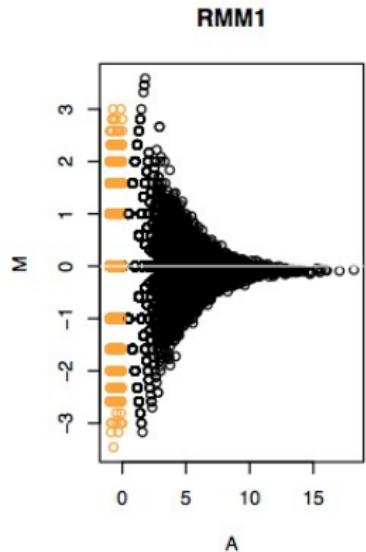
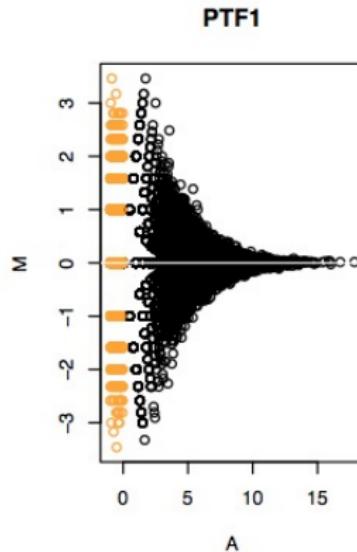
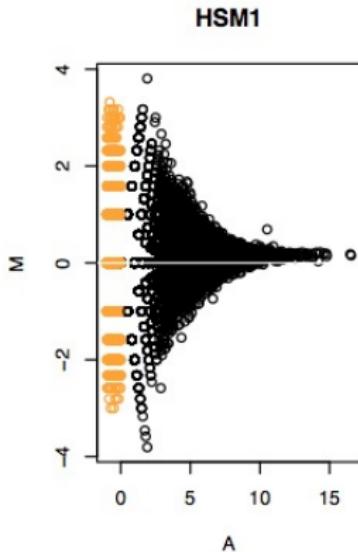
PTF1



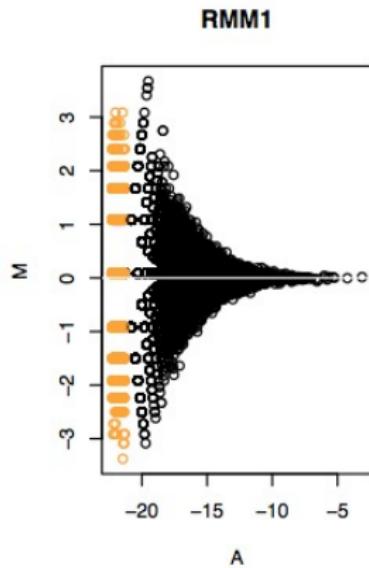
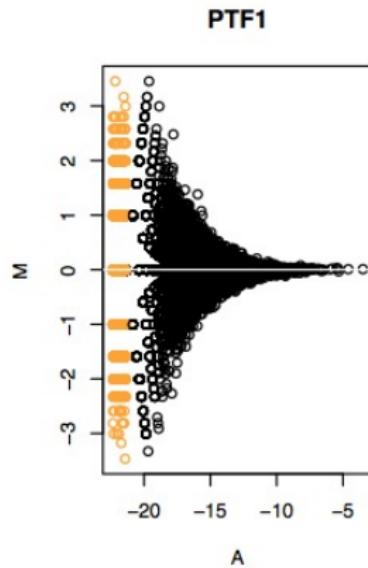
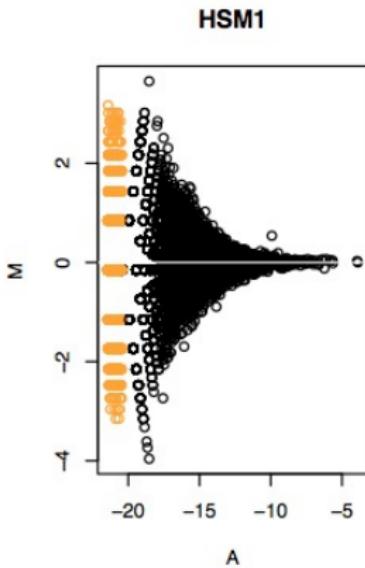
RMM1



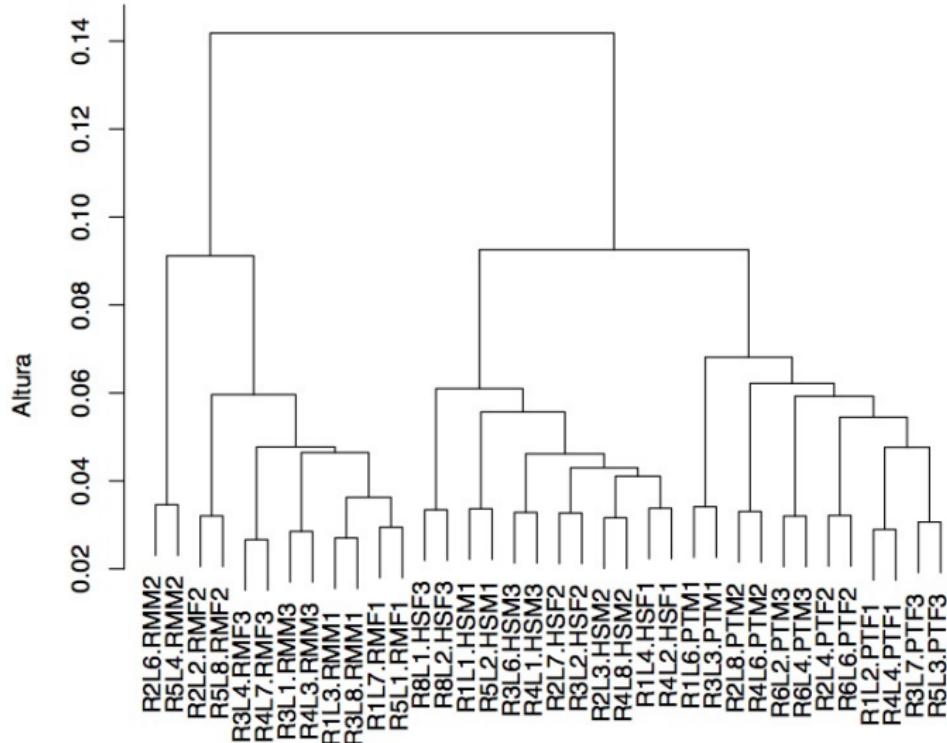
# MA Plot



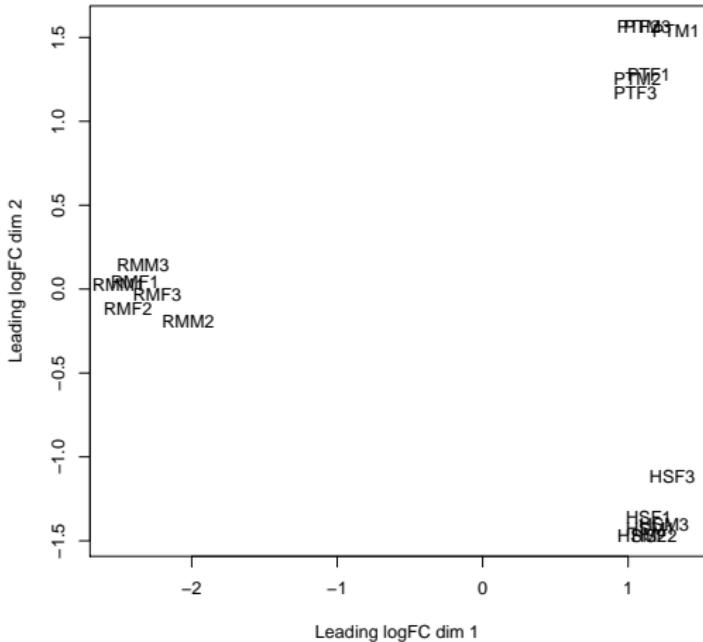
# MA Plot Normalizado



# Dendrograma



# MDS Plot



# Teste Exato

```
> HSM.vs.HSF <- exactTest(d, pair = c(1, 2))
> HSM.vs.HSF

## An object of class "DGEEExact"
## $table
##          logFC  logCPM PValue
## ENSG000000000003 -0.06484 6.9082 0.8985
## ENSG000000000005  1.79476 -0.5125 1.0000
## ENSG000000000419 -0.35879  4.1865 0.4994
## ENSG000000000457  0.18363  5.0917 0.7215
## ENSG000000000460  0.02462  1.4939 1.0000
## 14976 more rows ...
##
## $comparison
## [1] "HSF" "HSM"
##
## $genes
## [1] "ENSG000000000003" "ENSG000000000005"
## [3] "ENSG000000000419" "ENSG000000000457"
## [5] "ENSG000000000460"
## 14976 more rows ...
```

## Estimação Tagwise - HSM versus MSF

```
> d10 <- estimateTagwiseDisp(d, prior.df = 10)
> TW.HSM.vs.HSF <- exactTest(d10, pair = c(1,
+      2))
> head(TW.HSM.vs.HSF$table)

##                                     logFC  logCPM PValue
## ENSG00000000003 -0.06455  6.9082 0.8861
## ENSG00000000005  1.78073 -0.5125 1.0000
## ENSG00000000419 -0.35694  4.1865 0.3604
## ENSG00000000457  0.18184  5.0917 0.6731
## ENSG00000000460  0.02430  1.4939 1.0000
```

## Estimação Tagwise - HSM versus PTM

```
> TW.HSM.vs.PTM <- exactTest(d10, pair = c(2,
+      4))
> head(TW.HSM.vs.PTM$table)

##                                     logFC   logCPM    PValue
## ENSG00000000003  0.9215  6.9082  0.039618
## ENSG00000000005  0.8848 -0.5125  1.000000
## ENSG00000000419  0.3491  4.1865  0.362794
## ENSG00000000457  1.2639  5.0917  0.003564
## ENSG00000000460 -0.3789  1.4939  0.536722
## ENSG00000000938  0.7353  4.4394  0.258405
```

# Estimação Tagwise - HSM versus HSF - FDR

```
> topTags(TW.HSM.vs.HSF, adjust.method = "BH")  
  
## Comparison of groups: HSM-HSF  
##                                genes logFC logCPM      PValue      FDR  
## 6515 ENSG00000138131  5.089 5.3944 2.756e-07 0.004129  
## 9245 ENSG00000163017 -3.058 3.8267 3.206e-05 0.214623  
## 11722 ENSG00000178297  2.189 3.1773 4.298e-05 0.214623  
## 5185 ENSG00000128285 -2.304 1.9543 7.879e-05 0.245900  
## 11344 ENSG00000175084 -2.163 4.9850 9.342e-05 0.245900  
## 6819 ENSG00000140403 -3.190 4.1706 9.848e-05 0.245900  
## 4457 ENSG00000120694 -2.669 6.3453 1.234e-04 0.264174  
## 12473 ENSG00000185031 -4.979 0.9932 2.070e-04 0.387569  
## 750  ENSG00000060566  1.866 5.7418 4.106e-04 0.683441  
## 8849 ENSG00000160181 -4.296 0.5679 6.616e-04 0.991113
```

# Estimação Tagwise - HSM versus PTM - FDR

```
> topTags(TW.HSM.vs.PTM, adjust.method = "BH")  
  
## Comparison of groups: PTM-HSM  
##             genes logFC logCPM      PValue      FDR  
## 14119 ENSG00000208587 14.776  7.931 9.663e-64 1.448e-59  
## 14118 ENSG00000208570 14.097  8.107 2.310e-54 1.731e-50  
## 8570  ENSG00000157399 -6.777  5.252 1.262e-32 6.303e-29  
## 5911  ENSG00000134391 -9.228  6.204 2.453e-29 9.186e-26  
## 399   ENSG00000025423 -6.002  8.026 4.218e-28 1.264e-24  
## 9325  ENSG00000163444  5.757  4.229 6.610e-26 1.650e-22  
## 6712  ENSG00000139540 -8.208  6.585 1.885e-24 4.034e-21  
## 1901  ENSG00000099834 -6.730  6.475 2.650e-23 4.963e-20  
## 14854 ENSG00000219802  9.927  3.164 1.353e-22 2.252e-19  
## 14936 ENSG00000220688  4.526  5.146 5.968e-20 8.940e-17
```

# Site do Minicurso

<http://marcuspunes.me/mgest-2014-minicurso/>

# Análise de Dados Genéticos

Marcus Nunes

Departamento de Estatística - UFJF

2 e 3 de Outubro de 2014