

Expresión diferencial con datos RNA-seq

Guillermo Ayala Gallego

5/30/23

Table of contents

Introducción	2
Paquetes	2
Data	2
Una muestra por condición	2
Un test para comparar proporciones	2
edgeR::binomTest	2
edgeR clásico	4
Introducción	4
Estimación de una dispersión común	4
qCML: Quantile-adjusted condicional maximum likelihood	6
Un test exacto	7
Contraste de hipótesis	7
Dispersiones posiblemente distintas	8
Un análisis con edgeR	9
DGEList	9
Eliminando genes con conteos bajos	11
edgeR utilizando modelo lineal generalizado	13
Modelo	13
TCGA-COAD	14
Bibliografía	18

Introducción

Paquetes

```
pacman::p_load(SummarizedExperiment, edgeR, ggplot2)
```

Data

```
data(PRJNA297664, package="tamidata")
```

```
colData(PRJNA297664) [,"treatment"]
```

```
[1] Wild           Wild           SEC66 deletion Wild           SEC66 deletion  
[6] SEC66 deletion  
Levels: Wild SEC66 deletion
```

Una muestra por condición

Un test para comparar proporciones

- Queremos comparar dos condiciones y disponemos de una muestra en cada una de las condiciones.
- En este caso para cada gen tendríamos una tabla 2×2 como

Muestra	Gen	Resto	Total
1	y_1	$m_1 - y_1$	m_1
2	y_2	$m_2 - y_2$	m_2
Total	$y_1 + y_2$	$m_1 + m_2 - y_1 - y_2$	$m_1 + m_2$

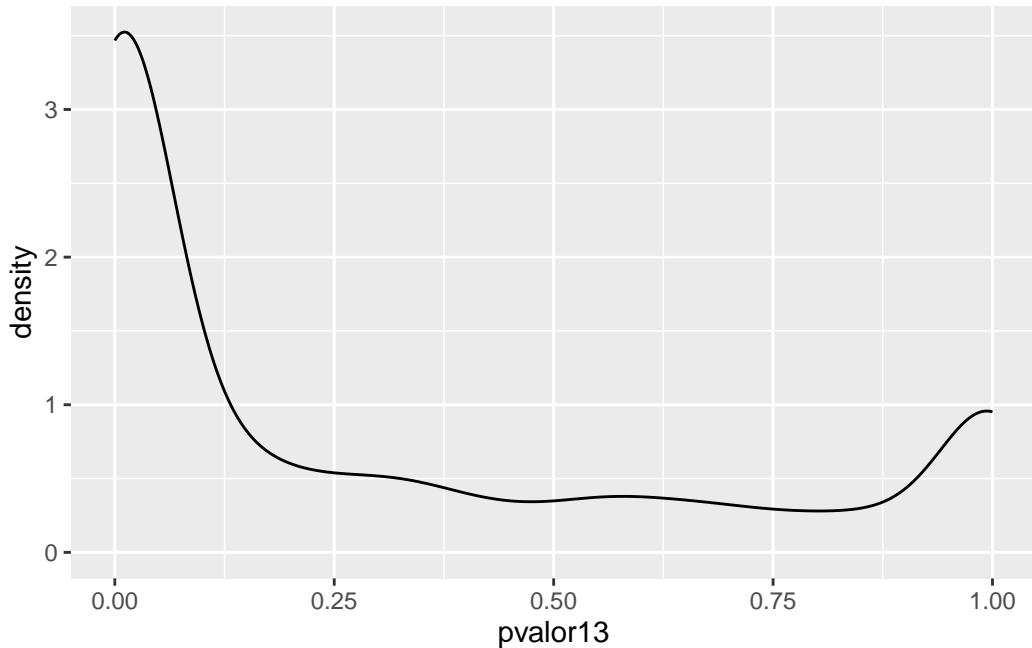
edgeR::binomTest

- Para el gen i -ésimo tendríamos los conteos x_{i1} e x_{i2} en las dos muestras siendo m_1 y m_2 los tamaños de las librerías.
- Suponemos fijo el número total de muestras para el gen i ($n_i = x_{i1} + x_{i2}$) y tamaño total de las dos librerías m_1 y m_2

- Bajo estas dos hipótesis previas vamos a contrastar que $H_0 : p_1 = m_1/(m_1 + m_2)$ frente a $H_1 : p_1 \neq m_1/(m_1 + m_2)$
- Como ilustración nos fijamos en las muestras 1 y 3.

```
pvalor13 = edgeR::binomTest(assay(PRJNA297664) [,1], assay(PRJNA297664) [,3])
```

```
pacman::p_load(ggplot2)
df = data.frame(pvalor13)
ggplot2::ggplot(df,aes(x=pvalor13)) + geom_density()
```



```
pares = rbind(c(1,3),c(1,5),c(1,6),c(2,3),c(2,5),c(2,6),c(4,3),
               c(4,5),c(4,6))
pvalores = apply(pares,1,
                  function(x) binomTest(assay(PRJNA297664) [,x[1]],
                                         assay(PRJNA297664) [,x[2]]))

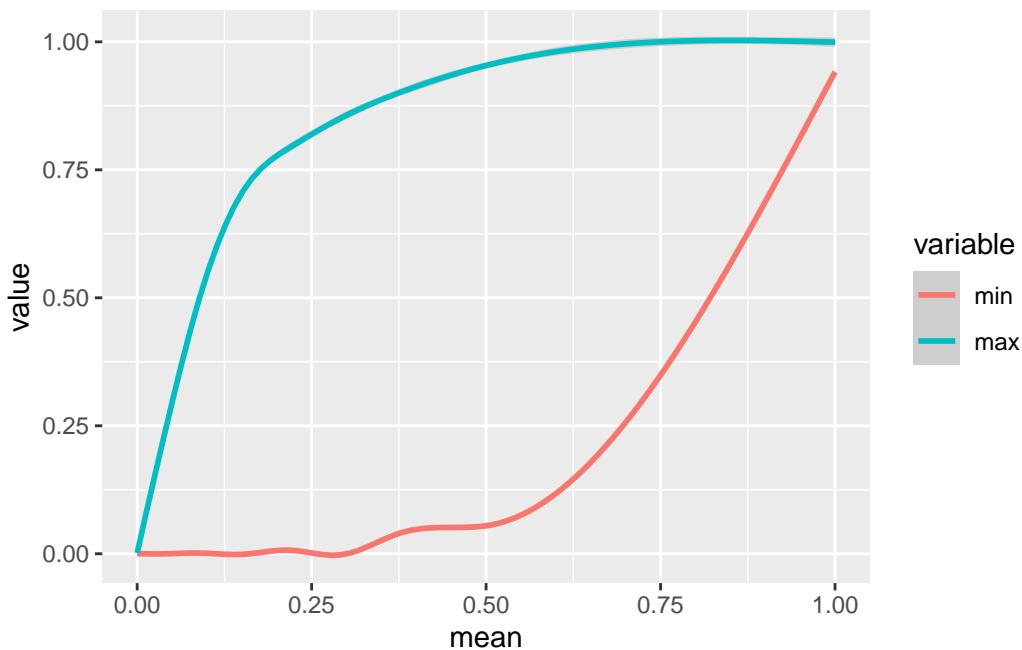
y = apply(pvalores,1,function(x) c(mean(x),min(x),max(x)))
df = data.frame(t(y))
names(df) = c("mean","min","max")
df=df[sort(df[, "mean"], index.return=TRUE)$ix,]
```

```

df1 = reshape2::melt(df,id="mean")
pp = ggplot(df1,aes(x=mean,y=value,color=variable))
pp + geom_smooth()

`geom_smooth()` using method = 'gam' and formula = 'y ~ s(x, bs = "cs")'

```



edgeR clásico

Introducción

- Para dos grupos.
- Es un test exacto.
- Propuesto en Robinson and Smyth (2008) y Robinson and Smyth (2007) (en este orden).

Estimación de una dispersión común

- Consideraremos una característica en n muestras (o librerías) de tamaños distintos.
- Sea m_i el tamaño de la i -ésima librería (total de lecturas).

- Sea λ la proporción que hay en una librería cualquiera de la característica en que estamos interesados.
- Si $Y \sim NB(\mu, \phi)$ entonces la función de probabilidad viene dada por

$$f(y|\mu, \phi) = P(Y = y|\mu, \phi) = \frac{\Gamma(y + \phi^{-1})}{\Gamma(\phi^{-1})\Gamma(y + 1)} \left(\frac{1}{1 + \mu\phi} \right)^{\phi^{-1}} \left(\frac{\mu}{\phi^{-1} + \mu} \right)^y.$$

- Se puede comprobar que:
 - su media es $E(Y) = \mu$,
 - su varianza es $var(Y) = \mu + \phi\mu^2$.
- **Asumimos** que Y_i tiene una distribución binomial negativa con media

$$\mu_i = m_i\lambda$$

y con dispersión ϕ .

- Supongamos un caso ideal (improbable): todas las librerías tienen el mismo tamaño: $m_i = m$ para $i = 1, \dots, n$.
- Bajo esta condición se verifica que $Z = \sum_{i=1}^n Y_i \sim NB(nm\lambda, \phi/n)$.
- Además la logverosimilitud condicionada al valor de $Z = z$ no depende de λ y podemos estimar el valor de ϕ .
- Se estimaría ϕ maximizando la logverosimilitud condicionada (a la suma de todos los conteos del gen) dada por

$$l_{\mathbf{y}|z} = \left[\sum_{i=1}^n \log \Gamma(y_i + 1/\phi) \right] + \log \Gamma(n/\phi) - \log \Gamma(z + n/\phi) - n \log \Gamma(1/\phi),$$

donde $\mathbf{y} = (y_1, \dots, y_n)'$ son los conteos observados.

- En el caso en que los tamaños de las librerías son distintos la verosimilitud no tiene una expresión simple.

- La idea consiste en modificar los valores observados y_i y generar unos datos **nuevos** en que los tamaños de las librerías **sí** que coincidan: los **pseudodatos**.
- El tamaño común de las librerías será la media geométrica de los tamaños observados:

$$m^* = \left(\prod_{i=1}^n m_i \right)^{\frac{1}{n}}.$$

- ¿Y cómo transformamos los conteos y_i ?

qCML: Quantile-adjusted condicional maximum likelihood

1. Inicializamos ϕ (por ejemplo, con el estimador máximo verosímil condicionado sin realizar ningún ajuste).
2. Dado el valor estimado de ϕ , estimamos λ maximizando la verosimilitud para el valor dado de la dispersión.
3. Suponemos que cada conteo y_i es un valor observado de una distribución binomial negativa con media $m_i\lambda$ y parámetro de dispersión ϕ . Calculamos los percentiles

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

para $i = 1, \dots, n$.

4. Suponemos ahora una distribución binomial negativa con media $m^*\lambda$ y dispersion ϕ .
 1. Determinamos qué valor sería el percentil de orden p_i en la nueva distribución. Ya no tiene porqué ser un dato entero e incluso puede ser negativo.
 2. Los pseudodatos para un mismo gen tienen aproximadamente la misma distribución.
5. Estimamos la dispersión ϕ con los pseudodatos utilizando la veromilitud condicionada a la (pseudo) suma total de un gen.
6. Repetimos desde 2 hasta 5 hasta que converja ϕ .

Un test exacto

- Tenemos dos condiciones a comparar.
- Consideramos el gen i y denotamos por
 - y_{ijk} el conteo para la muestra k en la condición j del gen i donde $j = 1, 2$ y $k = 1, \dots, n_j$.
- Los tamaños de la librería k de la condición j será m_{jk} .
- Los tamaños de las librerías **no** son iguales dentro de cada clase.
- Aplicamos el procedimiento qCML dentro de cada clase.
- Tendremos un tamaño común m_j en la condición j .
- Estimamos ϕ maximizando

$$l(\phi) = \sum_{i=1}^N l_i(\phi).$$

con

$$l_i(\phi) = \sum_{j=1}^2 \left(\sum_{k=1}^{n_j} \log \Gamma(y_{ijk} + \phi^{-1}) + \log \Gamma(n_j \phi^{-1}) - \log \Gamma(z_{ij} + n_j \phi^{-1}) - n_j \log \Gamma(\phi^{-1}) \right).$$

siendo $z_{ij} = y_{ij\cdot} = \sum_{k=1}^{n_j} y_{ijk}$.

- El estimador de ϕ será $\hat{\phi}_C$.

Contraste de hipótesis

- Estamos asumiendo

$$EY_{ijk} = m_{jk} \lambda_{ij},$$

- La hipótesis nula de que no hay diferencias entre las medias de los conteos en las dos condiciones para el i -ésimo gen, se formularía como

$$H_i : \lambda_{i1} = \lambda_{i2},$$

$$K_i : \lambda_{i1} \neq \lambda_{i2}.$$

- Bajo la hipótesis nula H_i no tendríamos diferencia en el valor de λ entre las condiciones y sería un valor común λ_i .
- Aplicamos método qCML a **todas** las muestras: y_{ijk} son los pseudodatos.
- Utilizando el estimador $\hat{\phi}_C$ y los conteos y_{ijk} podemos estimar λ_i .
- Bajo la hipótesis nula de no diferencia entre grupos tendríamos que $Y_{ij\cdot} = \sum_{k=1}^{n_j} Y_{ijk} \sim NB(n_j m^* \hat{\lambda}_i, \hat{\phi}_C / n_j)$.
- $Y_{i1\cdot}$ e $Y_{i2\cdot}$ son independientes.
- La suma $Y_{i1\cdot} + Y_{i2\cdot}$ también tiene una distribución binomial negativa: $Y_{i1\cdot} + Y_{i2\cdot} = \sum_{i=1}^2 \sum_{k=1}^{n_j} Y_{ijk} \sim NB((n_1 + n_2)m^* \hat{\lambda}_i, \hat{\phi}_C / (n_1 + n_2))$
- Podemos considerar la distribución condicionada del vector aleatorio $(Y_{i1\cdot}, Y_{i2\cdot})$ a la suma $Y_{i1\cdot} + Y_{i2\cdot}$ y considerar las probabilidades de los conteos conjuntos que **son menos probables que el observado**.
- La suma de estas probabilidades nos daría el p-valor del test.

Dispersiones posiblemente distintas

- Una misma dispersión sobre una cantidad grande de genes no es muy razonable.
- Buena desde el punto de vista del modelo y su estimación pero nos aleja de los datos.
- Supongamos dispersiones posiblemente distintas para los distintos genes, ϕ_i .
- Proponen

$$WL(\phi_i) = \ell_i(\phi_i) + \alpha \ell(\phi_i)$$

siendo α el peso que se da a la verosimilitud global.

- Es una función que propone un compromiso entre considerar l como función a maximizar considerando la misma contribución a todos los genes y l_i en donde solamente consideramos los conteos del propio gen.
- En Robinson & Smyth (2008) proponen un método de estimación de α .

Un análisis con edgeR

DGEList

- Tenemos un `SummarizedExperiment`.
- Construimos un `DGEList`.

```
x = DGEList(counts = assay(PRJNA297664),  
             group = colData(PRJNA297664) [, "treatment"])
```

- La clase del nuevo objeto es

```
class(x)
```

```
[1] "DGEList"  
attr(,"package")  
[1] "edgeR"
```

Y sus atributos son

```
attributes(x)
```

```
$class  
[1] "DGEList"  
attr(,"package")  
[1] "edgeR"  
  
$names  
[1] "counts"   "samples"
```

La matriz de conteos

```
x$counts
```

Tenemos la componente `samples`.

```
class(x$samples)
```

```
[1] "data.frame"
```

Las primeras filas son

```
head(x$samples)
```

	group	lib.size	norm.factors
Sample1	Wild	4788536	1
Sample2	Wild	9387986	1
Sample3	SEC66 deletion	9599910	1
Sample4	Wild	8896028	1
Sample5	SEC66 deletion	9003755	1
Sample6	SEC66 deletion	9002105	1

Tenemos un factor.

```
x$samples[, "group"]
```

```
[1] Wild          Wild          SEC66 deletion Wild          SEC66 deletion  
[6] SEC66 deletion  
Levels: Wild SEC66 deletion
```

Los tamaños de las librerías son

```
x$samples[, "lib.size"]
```

```
[1] 4788536 9387986 9599910 8896028 9003755 9002105
```

Los factores de normalización son

```
x$samples[, "norm.factors"]
```

```
[1] 1 1 1 1 1 1
```

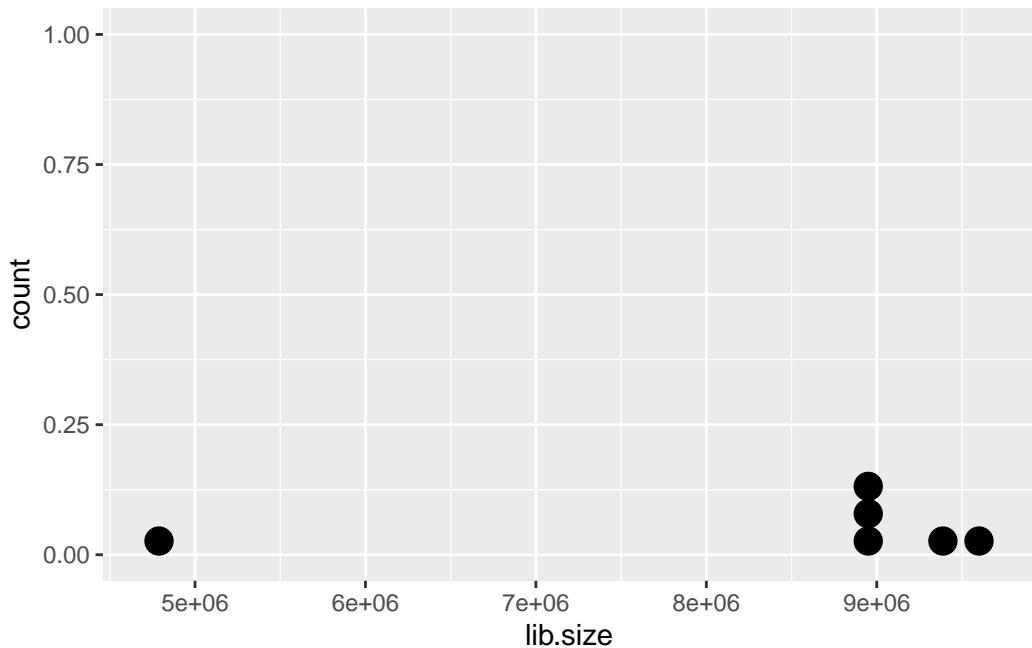
Veamos una descripción de los tamaños de las librerías.

```
summary(x$samples[, "lib.size"])
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
4788536	8922547	9002930	8446387	9291928	9599910

```
ggplot(x$samples,aes(x= lib.size)) + geom_dotplot()
```

Bin width defaults to 1/30 of the range of the data. Pick better value with `binwidth`.



Eliminando genes con conteos bajos

Utilizamos los conteos por millón CPM en lugar de los conteos originales. Obligamos a que se recalculen los tamaños de las librerías.

```
keep = rowSums(cpm(x)>1) >= 2
x <- x[keep, , keep.lib.sizes=FALSE]

dge = DGEList(counts=assay(PRJNA297664),
              group=colData(PRJNA297664)[,"treatment"])
dge.c = estimateCommonDisp(dge) ##Estimamos dispersión común
dge.c$common.dispersion
```

```
[1] 0.01170892
```

```

dge.t = estimateTagwiseDisp(dge.c) ##Dispersiones por gen
et.c = exactTest(dge.c)
et.t = exactTest(dge.t)

```

Y vemos los resultados.

```
topTags(et.c)
```

Comparison of groups: SEC66 deletion-Wild				
	logFC	logCPM	PValue	FDR
YBR171W	-10.150220	6.114922	2.128721e-258	1.516926e-254
YCR021C	-1.928779	8.463733	4.873506e-47	1.736430e-43
YBR054W	-1.878579	7.156683	3.518798e-43	8.358319e-40
YGL255W	-1.846348	7.518466	1.930761e-42	3.439650e-39
YNR034W-A	-2.176676	4.670571	1.175800e-40	1.675750e-37
YBR093C	-1.694281	8.563323	2.731791e-37	3.244457e-34
YFR053C	1.621598	6.384697	2.625927e-31	2.673194e-28
YER150W	-1.560027	5.479642	2.325258e-26	2.071224e-23
YDR171W	-1.383170	7.792428	2.142035e-25	1.696016e-22
YDR214W	1.362108	7.982939	1.024220e-24	7.298590e-22

```
topTags(et.t)
```

Comparison of groups: SEC66 deletion-Wild				
	logFC	logCPM	PValue	FDR
YBR171W	-10.150503	6.114922	5.636512e-296	4.016579e-292
YGL255W	-1.846051	7.518466	5.459134e-30	1.945090e-26
YBR093C	-1.694086	8.563323	5.843701e-27	1.388074e-23
YNR034W-A	-2.174452	4.670571	7.411466e-22	1.320353e-18
YDR214W	1.362104	7.982939	2.334672e-20	3.327375e-17
YLR109W	1.240894	9.510958	4.583075e-20	5.443166e-17
YHR215W	-1.208860	9.533270	2.172522e-18	2.211627e-15
YAR071W	-1.211709	9.219219	3.764430e-18	3.353166e-15
YMR186W	1.109256	11.622933	9.483967e-18	7.509195e-15
YKL161C	1.100257	5.723199	1.070358e-16	7.627369e-14

edgeR utilizando modelo lineal generalizado

Modelo

- Y_{ij} el conteo aleatorio (número de lecturas alineadas) para el gen i en la muestra j .
- Denotamos por $m_j = \sum_{i=1}^N y_{ij}$ la profundidad de secuenciación o total de lecturas de la muestra j .
- Utilizamos como función de enlace el logaritmo natural.
- Consideramos la profundidad de secuenciación como offset (un modelo de tasas sobre la profundidad de secuenciación).
- El modelo para la media es

$$\ln \mu_{ij} = \mathbf{x}_j^T \beta_i + \ln m_j.$$

- En el modelo las variables predictoras son comunes a todos los genes.
- Asumimos que la componente aleatoria sigue una distribución binomial negativa (con el parámetro de dispersión conocido)
- Entonces

$$var(Y_{ijk}) = \mu_{ij} + \phi_i \mu_{ij}^2,$$

siendo ϕ_i el parámetro de dispersión que hemos de asumir conocido o, de otro modo, tenemos que estimarlo previamente.

- En McCarthy, Chen, and Smyth (2012) muestran cómo estimar por máxima verosimilitud el vector de coeficientes β_i .
- Utilizan una modificación de los mínimos cuadrados iterativamente reponderados (IR-WLS).
- El parámetro de dispersión se estima maximizando la logverosimilitud penalizada definida como

$$APL_i(\phi_i) = \ell(\phi_i; \mathbf{y}_i, \hat{\beta}_i) - \frac{1}{2} \ln |\mathbb{I}_i|$$

siendo:

- \mathbf{y}_i los conteos para el gen i ,
- $\hat{\beta}_i$ el vector de coeficientes,
- $\ell()$ es la función de logverosimilitud
- $|\mathbb{I}_i|$ el determinante de la matriz de información de Fisher para el i -ésimo gen.

TCGA-COAD

```
pacman::p_load(edgeR,SummarizedExperiment)
load(paste0(dirTamiData,"tcga_coad.rda"))
```

- Nos centramos en las variables fenotípicas `age_at_diagnosis` y `tissue_or_organ_of_origin`.

```
summary(colData(tcga_coad)[,"age_at_diagnosis"])
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
11391	20604	24896	24146	28204	32872	4

```
table(colData(tcga_coad)[,"tissue_or_organ_of_origin"])
```

Ascending colon		Cecum	Colon, NOS
	72	70	59
Descending colon	Hepatic flexure of colon		Rectosigmoid junction
	15	12	3
Sigmoid colon	Splenic flexure of colon		Transverse colon
	76	6	13

- Hemos de eliminar aquellas muestras que tienen las variables predictoras con datos faltantes ya que las funciones que siguen no los admiten.

```
torm1 = which(is.na(colData(tcga_coad)$"age_at_diagnosis"))
torm2 = which(is.na(colData(tcga_coad)$ "tissue_or_organ_of_origin"))
toremove = union(torm1,torm2)
tcga_coad = tcga_coad[,-toremove]
```

- Construimos el objeto `DGEList` sin indicar ninguna variable `group` ni ninguna matriz de modelo y eliminamos genes con conteos bajos.

```
dge = DGEList(counts=assay(tcga_coad))
to_keep = rowSums(cpm(dge) > 0.5) > 20
dge = dge[to_keep,keep.lib.sizes=FALSE]
dim(dge)
```

```
[1] 16158 324
```

- Construimos la matriz de modelo con las dos variables predictoras, una de carácter categórico y la otra numérica.
- Cambiamos los nombres de las columnas de la matriz de modelo.

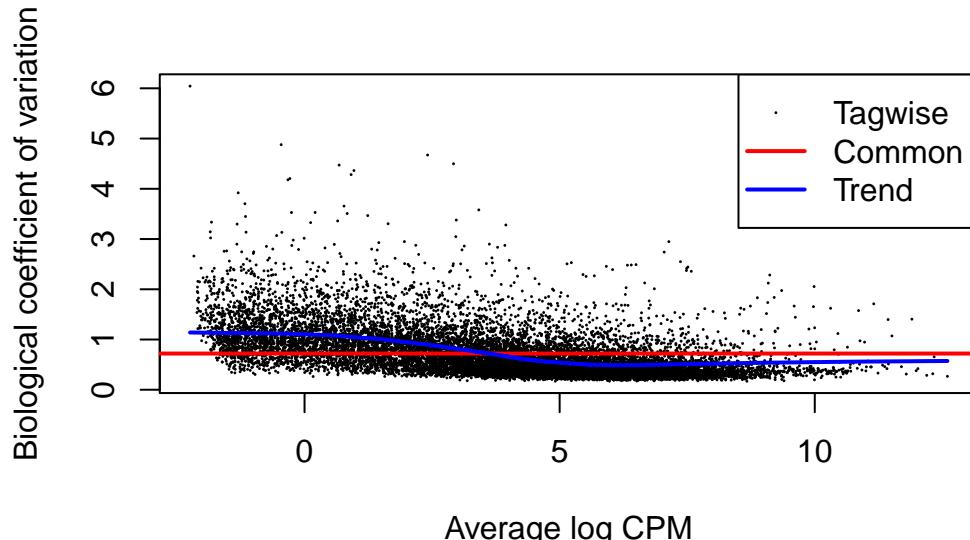
```
design0 = model.matrix(~ 0 +
  colData(tcga_coad)$"tissue_or_organ_of_origin"
  + colData(tcga_coad)$"age_at_diagnosis")
y = levels(colData(tcga_coad)$"tissue_or_organ_of_origin")
y = sapply(y,function(x) gsub(" ","_",x)) ## Eliminamos espacios
y = sapply(y,function(x) gsub(",","_",x)) ## Eliminamos las comas
colnames(design0) = c(y,"age_at_diagnosis")
```

- Estimamos las dispersiones por tres métodos distintos:
 - Asumiendo una dispersión común,
 - una por gen y
 - con una relación media-varianza.

```
dge = estimateDisp(dge,design=design0)
```

Si solo queremos una de las tres opciones podemos usar las funciones `estimateGLMCommonDisp()`, `estimateGLMTagwiseDisp()` y `estimateGLMTrendedDisp()`.

```
plotBCV(dge)
```



```
fit = glmFit(dge, design=design0)
```

- Veamos si influye la variable `age_at_diagnosis`.
- Si observamos la matriz de modelo `design0` corresponde con la columna 10 de la matriz de modelo.
- Se realiza un test del cociente de verosimilitudes.

```
lrt1 = glmLRT(fit,coef="age_at_diagnosis")
lrt1 = glmLRT(fit,coef=10) ## Equivalente a la linea anterior
topTags(lrt1)
```

Coefficient: `age_at_diagnosis`

	logFC	logCPM	LR	PValue	FDR
UGT2B10	-0.0002335397	0.07018047	68.64932	1.176251e-16	1.753945e-12
KCNH3	-0.0001438677	-0.73269543	67.44089	2.170993e-16	1.753945e-12
CPS1	-0.0002306034	4.32352487	60.85641	6.139324e-15	3.306640e-11
SULT1E1	-0.0002374397	0.83203192	57.37333	3.604616e-14	1.456085e-10
GPR64	-0.0001654538	0.52261384	55.61329	8.822524e-14	2.851087e-10
UPK1A	-0.0002044708	-0.94768507	53.99073	2.014376e-13	5.424715e-10
KRT81	-0.0001417146	-0.31911518	50.55783	1.157049e-12	2.670799e-09
DLX5	-0.0001507914	-0.47209136	45.87384	1.261190e-11	2.547288e-08
EPHX3	-0.0001195753	-0.07584401	45.21348	1.766851e-11	2.897626e-08
CACNA1I	-0.0001300370	-0.65221580	45.18437	1.793308e-11	2.897626e-08

- Podemos evaluar toda la variable `tissue_or_organ_of_origin`.

```
lrt2 = glmLRT(fit,coef=1:9)
topTags(lrt2)
```

Coefficient: `Ascending_colon Cecum Colon__NOS Descending_colon Hepatic_flexure_of_colon Rectum`

	logFC.Ascending_colon	logFC.Cecum	logFC.Colon__NOS
RBM44	-23.03403	-22.79346	-23.20739
LPAL2	-22.83425	-22.63042	-22.87998
C6orf52	-22.69677	-22.74012	-22.53655
SLC5A10	-22.59678	-22.67309	-22.35748
APOBEC3H	-22.53489	-22.57474	-22.19753
LINC00574	-22.53141	-22.30988	-21.93773
ATOH7	-22.50255	-22.51006	-22.89692
GRAPL	-22.47544	-21.90377	-21.80912
C6orf201	-22.45426	-22.61184	-22.56993
RPL23AP64	-22.43706	-22.48745	-22.71604

	logFC.Descending_colon	logFC.Hepatic_flexure_of_colon	
RBM44	-22.81666	-22.98087	
LPAL2	-22.60164	-22.63563	
C6orf52	-23.72080	-22.34341	
SLC5A10	-22.81269	-22.55916	
APOBEC3H	-22.89885	-22.24700	
LINC00574	-22.53327	-21.59098	
ATOH7	-22.36426	-21.88149	
GRAPL	-22.20629	-22.98721	
C6orf201	-22.39796	-22.18401	
RPL23AP64	-22.31727	-22.72084	
	logFC.Rectosigmoid_junction	logFC.Sigmoid_colon	
RBM44	-23.39152	-22.83901	
LPAL2	-23.04283	-22.15825	
C6orf52	-22.72652	-22.77770	
SLC5A10	-22.73793	-22.61990	
APOBEC3H	-23.32153	-22.97932	
LINC00574	-22.95598	-22.59596	
ATOH7	-22.15867	-21.84132	
GRAPL	-23.39572	-22.33813	
C6orf201	-23.12831	-22.58081	
RPL23AP64	-22.02019	-22.25008	
	logFC.Splenic_flexure_of_colon	logFC.Transverse_colon	logCPM
RBM44	-23.79191	-19.16905	-1.002324
LPAL2	-21.86348	-22.40498	-1.565987
C6orf52	-23.11693	-22.67335	-1.343997
SLC5A10	-22.40977	-22.32619	-1.460341
APOBEC3H	-23.29649	-22.81347	-1.370931
LINC00574	-22.88247	-22.21847	-1.774904
ATOH7	-23.02326	-22.96452	-1.657356
GRAPL	-22.30881	-21.52397	-1.620106
C6orf201	-22.25201	-21.85007	-1.707904
RPL23AP64	-22.98331	-21.64723	-1.707398
	LR	PValue	FDR
RBM44	3115.908	0	0
LPAL2	1931.307	0	0
C6orf52	1762.968	0	0
SLC5A10	4317.670	0	0
APOBEC3H	1790.031	0	0
LINC00574	1759.550	0	0
ATOH7	2369.495	0	0
GRAPL	1708.911	0	0
C6orf201	2875.556	0	0

RPL23AP64 2940.747 0 0

- Y elegir los contraste que queramos.
- Mostramos una comparación entre dos grupos.

```
AD = makeContrasts(contrast1 = Ascending_colon - Descending_colon,
                     levels=design0)
lrt3 = glmLRT(fit,contrast = AD)
topTags(lrt3)
```

	Coefficient:	1*Ascending_colon -1*Descending_colon	logFC	logCPM	LR	PValue	FDR
ACTL8	-3.626585	1.9449815	41.05906	1.476981e-10	1.765755e-06		
DBH	-2.980882	-0.6717054	40.29327	2.185611e-10	1.765755e-06		
IGFN1	-3.772058	0.1735114	38.82410	4.637663e-10	2.497845e-06		
PCCA	-1.854167	6.0403726	37.84606	7.655289e-10	3.092354e-06		
INHA	-3.544573	-1.2757898	34.69282	3.860522e-09	1.247566e-05		
FLT3	-2.515272	-0.6541790	34.27551	4.783649e-09	1.288237e-05		
MUM1L1	-2.947467	-0.5294079	29.86079	4.642074e-08	1.071523e-04		
MYO3B	-2.250829	-1.0459367	28.57745	9.002435e-08	1.818267e-04		
KRT14	8.581216	2.8419848	26.64655	2.442861e-07	4.385750e-04		
PPP4R4	-2.363616	-1.4762586	24.69543	6.714311e-07	1.084898e-03		

Bibliografía

- McCarthy, Davis J., Yunshun Chen, and Gordon K. Smyth. 2012. “Differential Expression Analysis of Multifactor RNA-Seq Experiments with Respect to Biological Variation.” *Nucleic Acids Research* 40 (10): 4288–97. <https://doi.org/10.1093/nar/gks042>.
- Robinson, Mark D., and Gordon K. Smyth. 2007. “Moderated Statistical Tests for Assessing Differences in Tag Abundance.” *Bioinformatics* 23 (21): 2881–87. <https://doi.org/10.1093/bioinformatics/btm453>.
- . 2008. “Small-Sample Estimation of Negative Binomial Dispersion, with Applications to SAGE Data.” *Biostatistics* 9 (2): 321–32. <https://doi.org/10.1093/biostatistics/kxm030>.