

# Taller 1

## Introducción al análisis de datos epigenómicos

**Jenny Johana Gallo Franco**

Doctorado en Ingeniería y Ciencias Aplicadas


Pontificia Universidad Javeriana Cali



# Contenido:

1. Teoría de secuenciación por bisulfito y control de calidad
2. Control de calidad (FastQC), alineamiento y extracción de la metilación – Práctica (Bismark)
3. Visualización y exploración de los niveles de metilación – Práctica (MethylKit)
4. Metilación diferencial, Teoría y práctica (MethylKit)


# Epigenética





Estudio de los cambios en la expresión de los genes que no están relacionados con la secuencia de ADN

- Modificaciones de histonas
- RNAs no-codificantes
- **Metilación del ADN**

# Metilación del ADN




Cytosine




5-methyl Cytosine

# Metilación del ADN




## Tipos de metilación en el ADN


CG context



non-CG context




# Proceso de metilación




Zhang et al. 2018

# Posibles funciones celulares de la metilación en plantas




Zhang et al. 2018

# Posibles funciones celulares de la metilación en plantas



Zhang et al. 2018


# Cambios epigenéticos en respuesta a estrés




Zhang et al. 2018



# Cambios epigenéticos en respuesta a estrés



Zhang et al. 2018




Turgut-Kara et al. 2020

**¿ Cómo se puede estudiar la metilación del ADN ?**




# ¿ Cómo se puede estudiar la metilación del ADN ?



MSCC: Methyl-Sensitive Cut Counting  
 LUMA: Luminometric Methylation Assay  
 LINE: Long Interspersed Nuclear Elements  
 ELISA: Enzyme-Linked Immunosorbent Assay  
 AFLP: Amplified Fragment Length Polymorphism  
 RFLP: Restriction Fragment Length Polymorphism  
 HRM: High Resolution Melting  
 COLD-PCR: explained in chapter 4.6



## Secuenciación de genoma completo por bisulfito (WGBS)



- Los nucleótidos de **citosa no metilados** se convierten en **uracilo**, que se identifican como timinas (T) cuando se secuencia.

- Las **citosinas metiladas** están protegidas de la conversión, por lo que aún se identifican como **citosa (C)**.

# Análisis de datos de secuenciación bisulfito

CCAGT<sup>me</sup>CGCTATAGC<sup>me</sup>GCGATATCGTA



Convert

TTAGTTGCTATAGTGCGATATTGTA



Map


TTAGTTGCTATAGTGCGATATTGTA

||| | | | | | | | | | | | | | | |


... CCAGTCGCTATAGC GCGATATCGTA ...

# Análisis de datos de secuenciación bisulfito

## En realidad...



# Análisis de datos de secuenciación por bisulfito.



Wreczycka et al. 2017

# Formato FASTA

```
>Identifier1 (comment)
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
>Identifier2 (comment)
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XX
```

**¿ Que tipo de secuencias se obtienen de la secuenciación?**

FASTA es un formato familiar en datos genómicos



# Formato FASTA

```
>Identifier1 (comment)
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
>Identifier2 (comment)
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
XX
```

## ¿ Que tipo de secuencias se obtienen de la secuenciación?

FASTA es un formato familiar en datos genómicos



# Formato FASTQ

```
@Identifier1 (comment)
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
+
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
@Identifier2 (comment)
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
+
XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX
```

### Cuatro líneas:

- @ + identificador en la primera línea
- Secuencia
- +
- Valores de calidad





Llamado de metilación

Filtrado por cobertura

Visualización y agrupamiento

Resultados como tablas, estadísticos de resumen, etc.

Metilación diferencial

Anotación de DMR/DMCs

Segmentación de la metilación

# Parte I: Análisis de calidad de las secuencias




## Summary

- ✔ [Basic Statistics](#)
- ✔ [Per base sequence quality](#)
- ✔ [Per tile sequence quality](#)
- ✔ [Per sequence quality scores](#)
- ✘ [Per base sequence content](#)
- ✘ [Per sequence GC content](#)
- ✔ [Per base N content](#)
- ✔ [Sequence Length Distribution](#)
- ✔ [Sequence Duplication Levels](#)
- ✔ [Overrepresented sequences](#)
- ✔ [Adapter Content](#)

## ✔ Basic Statistics


Measure	Value
Filename	MCL1-DK.gz
File type	Conventional base calls
Encoding	Sanger / Illumina 1.9
Total Sequences	1000
Sequences flagged as poor quality	0
Sequence length	100
%GC	50

## ✔ Per base sequence quality




## ¿ Que nos dice un análisis de FASTQC?

Phred Quality Score	Probability of incorrect base call	Base call accuracy
10	1 in 10	90%
20	1 in 100	99%
30	1 in 1000	99.9%
40	1 in 10,000	99.99%
50	1 in 100,000	99.999%
60	1 in 1,000,000	99.9999%




¿Qué es bueno y que es malo de acuerdo al valor de calidad por base?

# Valor de calidad por base



Buena calidad


# Valor de calidad por base



Calidad intermedia




# Valor de calidad por base




Mala calidad

## Contenido de secuencias por base en un set de datos "normal"




¿Se debería ver igual  
en secuenciación  
bisulfito?

## ✖ Per base sequence content




**Este sería el  
resultado normal  
en secuenciación  
bisulfito**

## Algunos problemas comunes en secuenciación por bisulfito




No se observa en  
librerías normales”  
como ChIP o  
RNAseq




# FASTQC - Eliminación de bases o lecturas de baja calidad

Antes




Después




# FASTQC - Remoción de la contaminación por adaptadores


## Antes




## Después




✖ Adapter Content



✔ Adapter Content




## Parte II: Alineamiento de secuencias y llamado de la metilación



**Bismark**  
v0.22.3

Babraham  
Bioinformatics

(Krueger & Andrews, 2011)



**Bismark v0.23.0**



<https://github.com/FelixKrueger/Bismark/tree/master/Docs>

(Krueger & Andrews, 2011)

Bismark es un programa para mapear lecturas de secuenciación tratadas con bisulfito a un genoma de interés y realizar el llamado de la metilación en un solo paso.

El archivo de salida se puede importar fácilmente a un visor de genoma, como SeqMonk y permite al investigador analizar los niveles de metilación de sus muestras de inmediato.





**Bismark v0.23.0**



<https://github.com/FelixKrueger/Bismark/tree/master/Docs>

(Krueger & Andrews, 2011)


Bismark es un programa para mapear lecturas de secuenciación tratadas con bisulfito a un genoma de interés y realizar el llamado de la metilación en un solo paso.

El archivo de salida se puede importar fácilmente a un visor de genoma, como SeqMonk y permite al investigador analizar los niveles de metilación de sus muestras de inmediato.

### **Sus principales características son:**

- Mapeo de bisulfito y llamado de la metilación en un solo paso -  
Admite alineaciones de lectura single-end y paired-end
- Admite alineaciones sin gaps y con gaps
- Tiene parámetros de alineamiento ajustables
- Los archivos de salida se discriminan entre metilación de citosina en los contextos CpG, CHG y CHH





**Bismark v0.23.0**



<https://github.com/FelixKrueger/Bismark/tree/master/Docs>

(Krueger & Andrews, 2011)

Bismark es un programa para mapear lecturas de secuenciación tratadas con bisulfito a un genoma de interés y realizar el llamado de la metilación en un solo paso.


El archivo de salida se puede importar fácilmente a un visor de genoma, como SeqMonk y permite al investigador analizar los niveles de metilación de sus muestras de inmediato.

El mapeo de secuencias tratadas por bisulfito a un genoma de referencia constituye un reto computacional debido a:


- La reducida complejidad del **código de ADN**
- Hasta **cuatro cadenas de ADN** tienen que ser analizadas
- Cada lectura puede existir en **todos los estados posibles de metilación**



# Enfoque de Bismark para el mapeo de secuencias bisulfito



# Determinación del estado de metilación de cada posición



Dependiendo de la hebra, una lectura mapeada contra una secuencia dada puede implicar buscar sustituciones de C a T (como se muestra aquí) o G a A.

# Corriendo Bismark...

## (I) Corriendo bismark\_genome\_preparation

El genoma de interés debe ser convertido a bisulfito e indexado para permitir el alineamiento por Bowtie

### USAGE:

```
insert your code bismark_genome_preparation [options] <path_to_genome_folder>
```

Un comando estandar para correr la preparación del genoma se vería así:

```
bismark_genome_preparation --path_to_aligner /usr/bin/bowtie2 --verbose /home/jenny/Analysis-I/genome/
```

or

```
bismark_genome_preparation --bowtie2 --verbose ./genome/
```

# Corriendo Bismark...

## (I) Corriendo bismark\_genome\_preparation

El genoma de interés debe ser convertido a bisulfito e indexado para permitir el alineamiento por Bowtie

### USAGE:

```
insert your code bismark_genome_preparation [options] <path_to_genome_folder>
```

Un comando estandar para correr la preparación del genoma se vería así:

```
bismark_genome_preparation --path_to_aligner /usr/bin/bowtie2 --verbose /home/jenny/Analysis-I/genome/
```

or

```
bismark_genome_preparation --bowtie2 --verbose ./genome/
```

Solo se debe correr una vez para el genoma de interés

## (II) Corriendo `bismark`

### USAGE:

```
bismark [options] --genome <genome_folder> {-1 <mates1> -2 <mates2> | <singles>}
```

Ejemplo típico de un alineamiento:

```
bismark --multicore 4 --genome ./genome/ -1 WABQ1_L2_1.fq.gz,WABQ2_L1_1.fq.gz  
-2 WABQ1_L2_2.fq.gz,WABQ2_L1_2.fq.gz --output_dir ./out/
```

Esto va a producir dos archivos de salida:

```
test_dataset_bismark_bt2.bam (Contiene todos los alineamientos y el llamado de metilación)
```

```
test_dataset_bismark_SE_report.txt (contiene el resumen del alineamiento y la metilación)
```

## Alineamiento y llamado de la metilación

### (II) Corriendo `bismark`

#### USAGE:

```
bismark [options] --genome <genome_folder> {-1 <mates1> -2 <mates2> | <singles>}
```

Ejemplo típico de un alineamiento:

```
bismark --multicore 4 --genome ./genome/ -1 WABQ1_L2_1.fq.gz,WABQ2_L1_1.fq.gz  
-2 WABQ1_L2_2.fq.gz,WABQ2_L1_2.fq.gz --output_dir ./out/
```

Esto va a producir dos archivos de salida:

```
test_dataset_bismark_bt2.bam (Contiene todos los alineamientos y el llamado de metilación)
```

```
test_dataset_bismark_SE_report.txt (contiene el resumen del alineamiento y la metilación)
```

# Alineamiento de secuencias

## Archivo de salida del primer alineamiento en Bismark (BAM file)

Read 1

chromosome

position

```
HISEQ2000-06:366:C3G4NACXX:3:1101:1316:2067_1:N:0: 99 16 71322125 255 100M =
71322232 207
NTTATTTAGTTTTTTAGGGTTTGTGTGTAGGAGTGTGGGAATTATGTTTTTTATGGTTGATATTTATTTAAAAGTGAGTATAAATTATATATATTTTTTT
#1=DDDDDAAFFHIIIA:<FGHCCEFGHD?CFFBBBGEHHGHIII<FEHIIIII==DE?EHHFHEEEEEEEEC>;>66;@CDEEEDCEEEEEEDDDCBB
NM:i:14 XX:Z:G8C2C7C21C13C6CC1C17CC3C4CC4
XM:Z:.....h..h.....x.....h.....x.....hh.h.....hh...h...hh....
XR:Z:CT XG:Z:CT XA:Z:1
```

sequence

quality

Read 2

```
HISEQ2000-06:366:C3G4NACXX:3:1101:1316:2067_1:N:0: 147 16 71322232 255 100M =
71322125 -207
GGTTATTTTATTTAGGGTTATTGTTTTAGAGTTTTATTGTTGTGAACAGATATATGATTAAGGTAATTTTTATAAGGATAATTTAATTGGAGTTGGTT
CCCEEECADCFFFHGHGHIIIGIHFIIJJIJIHFGHGGGEHIJIIJGIGFJJJJJJJJJJGJJJJGJJJIIIIJJIJIJJJJJIJHHHHHFFFFFCCC
NM:i:21 XX:Z:2G2CC1C1C1C11C11C2C10C1C4CC4C2C1C3C5C2C12C3C1
XM:Z:.....hh.h.h.x.....h.....x..x.....X...h.h...hh...h..h.h...h....h..h.....x...h.
XR:Z:GA XG:Z:CT XB:Z:1
```

methylation call



### (III) Corriendo `deduplicate_bismark`

#### USAGE:

```
deduplicate_bismark --bam [options] <filenames>
```

Este comando deduplicará el archivo BAM de alineación Bismark y eliminará todas las lecturas excepto una que se alinee en la misma posición y en la misma orientación. Este paso se recomienda para muestras de bisulfito de genoma completo, pero no debe usarse para bibliotecas de representación reducida como RRBS, amplicones o bibliotecas de enriquecimiento.



## (IV) Corriendo `bismark_methylation_extractor`

### USAGE:

```
bismark_methylation_extractor [options] <filenames>
```

Un comando típico para extraer la metilación contexto-dependiente (CpG/CHG/CHH) sería así:

```
bismark_methylation_extractor --gzip --bedGraph test_dataset_bismark_bt2.bam
```

or

```
bismark_methylation_extractor --gzip --bedGraph --buffer_size 10G --comprehensive ./out/  
WABQ1_L2_1_bismark_bt2_pe.deduplicated.bam --output ./out/met_extractor
```



## (IV) Corriendo `bismark_methylation_extractor`

### USAGE:

```
bismark_methylation_extractor [options] <filenames>
```

Un comando típico para extraer la metilación contexto-dependiente (CpG/CHG/CHH) sería así:

```
bismark_methylation_extractor --gzip --bedGraph test_dataset_bismark_bt2.bam
```

or

```
bismark_methylation_extractor --gzip --bedGraph --buffer_size 10G --comprehensive ./out/  
WABQ1_L2_1_bismark_bt2_pe.deduplicated.bam --output ./out/met_extractor
```

Esto va a producir tres archivos de salida:

```
CpG_context_test_dataset_bismark_bt2.txt.gz
```

```
CHG_context_test_dataset_bismark_bt2.txt.gz
```

```
CHH_context_test_dataset_bismark_bt2.txt.gz
```

Formato de salida



1. seq-ID
2. methylation state
3. chromosome
4. start position (= end position)
5. methylation call

# Extracción de la metilación

Read 1

....z....h..h.....x....z.....x.....hh.h.....z...hx...h...hh.z...

....x.....hh.h.....z...hx...h...hh.z...hh....x....z.h....h..h.....x..h.....

redundant methylation calls

Read 2

Read 1

....z....h..h.....x....z.....x.....hh.h.....z...hx...h...hh.z...

hh....x....z.h....h..h.....x..h.....

Read 2

CpG methylation output

```
Bismark methylation extractor version v0.10.1
HS9_11915:8:2311:4022:38651#13/1      +      1      3029229 Z
HS9_11915:8:1208:13025:95413#13/1    +      1      3079409 Z
HS9_11915:8:1301:11752:81850#13/1    -      1      3104640 z
HS9_11915:8:2112:15483:84166#13/1    +      1      3104862 Z
HS9_11915:8:2110:8777:33683#13/1     -      1      3104862 z
HS9_11915:8:2208:16561:25806#13/1    +      1      3104862 Z
HS9_11915:8:2308:15290:100335#13/1   -      1      3124392 z
HS9_11915:8:2308:15290:100335#13/1   +      1      3124416 Z
HS9_11915:8:2212:13818:79056#13/1    +      1      3124416 Z
HS9_11915:8:2105:9522:91783#13/1     +      1      3124392 Z
HS9_11915:8:2105:9522:91783#13/1     +      1      3124416 Z
```

read ID                      meth state    chr            pos    context



# Extracción de la metilación I

```
Bismark methylation extractor version v0.10.1
HS9_11915:8:2311:4022:38651#13/1      +      1      3029229 Z
HS9_11915:8:1208:13025:95413#13/1    +      1      3079409 Z
HS9_11915:8:1301:11752:81850#13/1    -      1      3104640 z
HS9_11915:8:2112:15483:84166#13/1    +      1      3104862 Z
HS9_11915:8:2110:8777:33683#13/1    -      1      3104862 z
HS9_11915:8:2208:16561:25806#13/1    +      1      3104862 Z
```

CpG methylation output



bismark2bedGraph

```
1      5705370 5705370 100      1      0
1      5706335 5706335 60       3      2
1      5706336 5706336 100      3      0
1      5706453 5706453 75       3      1
1      5706454 5706454 0        0      2
1      5706845 5706845 71.4285714285714      5      2
1      5706846 5706846 66.6666666666667     2      1
1      5707925 5707925 0        0      1
1      5707926 5707926 66.6666666666667     2      1
1      5709177 5709177 100      2      0
1      5709178 5709178 0        0      1
1      5710030 5710030 66.6666666666667     4      2
```

bedGraph/coverage output

chr                    pos                    methylation percentage                    meth    unmeth

# Extracción de la metilación II

1	10525	10525	66.6666666666667	2	1
1	10542	10542	100	3	0
1	10563	10563	66.6666666666667	2	1
1	10571	10571	100	3	0
1	10577	10577	66.6666666666667	2	1
1	10579	10579	100	3	0
1	10589	10589	50	2	2
1	10609	10609	0	0	1
1	10617	10617	0	0	1
1	10620	10620	0	0	1

coverage output



coverage2cytosine

1	10525	+	2	1	CG	CGC
1	10526	-	0	0	CG	CGG
1	10542	+	3	0	CG	CGA
1	10543	-	0	0	CG	CGG
1	10563	+	2	1	CG	CGC
1	10564	-	0	0	CG	CGT
1	10571	+	3	0	CG	CGC
1	10572	-	0	0	CG	CGG
1	10577	+	2	1	CG	CGC
1	10578	-	0	0	CG	CGA
1	10579	+	3	0	CG	CGG
1	10580	-	0	0	CG	CGC
1	10589	+	2	2	CG	CGG

optional: merge into  
CpG dinucleotide entities

Genome wide CpG report

chr pos strand meth unmeth di-nuc tri-nuc



## (IV) Corriendo `bismark_methylation_extractor`

### USAGE:

```
bismark_methylation_extractor [options] <filenames>
```

Un comando típico para extraer la metilación contexto-dependiente (CpG/CHG/CHH) incluyendo el archivo .bed y el reporte por pares de nucleótidos sería así:

```
bismark_methylation_extractor --gzip --bedGraph --buffer_size 10G --comprehensive --cyto  
sine_report --genome_folder /path_to_genome_folder/ WABQ1_L2_1_bismark_bt2_pe.deduplicat  
ed.bam --output ./out
```

## (V) Corriendo `bismark2report` and `bismark2summary`

### USAGE:

```
bismark2report [options]
```

```
bismark2summary [options]
```






# Bismark Processing Report

SRR5008109\_WGBS\_Seq\_E14\_d11\_1\_control\_1\_val\_1.fq.gz and SRR5008109\_WGBS\_Seq\_E14\_d11\_1\_control\_2\_val\_2.fq.gz

Data processed at 11:25 on 2018-08-16

## Alignment Stats

Sequence pairs analysed in total	9399055
Paired-end alignments with a unique best hit	7018098
Pairs without alignments under any condition	1722286
Pairs that did not map uniquely	658671
Genomic sequence context not extractable (edges of chromosomes)	6






# Bismark Processing Report

## Cytosine Methylation

Total C's analysed	264469464
Methylated C's in CpG context	8364359
Methylated C's in CHG context	755431
Methylated C's in CHH context	2166832
Methylated C's in Unknown context	535
Unmethylated C's in CpG context	3380818
Unmethylated C's in CHG context	57592010
Unmethylated C's in CHH context	192210014
Unmethylated C's in Unknown context	56967
Percentage methylation (CpG context)	71.2%
Percentage methylation (CHG context)	1.3%
Percentage methylation (CHH context)	1.1%
Methylated C's in Unknown context	N/A%




[https://www.bioinformatics.babraham.ac.uk/projects/bismark/PE\\_report.html](https://www.bioinformatics.babraham.ac.uk/projects/bismark/PE_report.html)





# Bismark Project Overall Summary

## Alignment Statistics




[https://www.bioinformatics.babraham.ac.uk/projects/bismark/bismark\\_summary\\_WGBS.html](https://www.bioinformatics.babraham.ac.uk/projects/bismark/bismark_summary_WGBS.html)






# Bismark Project Overall Summary





# Bismark Project Overall Summary


## Cytosine Methylation






# Bismark Project Overall Summary

## Cytosine Methylation



# Visualización de datos utilizando Seq-Monk




## Datos de entrada:

- BAM/SAM** provenientes de Bismark
- Archivos de **cobertura** provenientes de Bismark
- BedGraph** archivos provenientes de Bismark
  
- Archivos de llamado de la metilación generados en methylkit (.txt)

# Visualización de datos utilizando Seq-Monk

Archivos de cobertura



**Rojo = Metilado**








**Azul = No-Metilado**

# Visualización de datos utilizando Seq-Monk




**Rojo = Metilado**

**Azul = No-Metilado**




**Análisis de datos para datos de secuenciación por bisulfito.**



**MethylKit v.1.15**

(Akalin et al., 2012)



## **Methylkit v.1.15**

(Akalin et al., 2012)

<https://bioconductor.org/packages/devel/bioc/vignettes/methylKit/inst/doc/methylKit.html>

MethylKit es un paquete de R para el análisis y anotación de datos de metilación del ADN obtenidos por tecnologías de secuenciación masiva.

### **Descarga de archivos para la parte practica**

<https://drive.google.com/drive/folders/11l8hNlqHVw00Bo-arh3MtBxM5rykD1?usp=sharing>



# Corriendo MethyKit...

## 1.1 Crear el objeto methylkit a partir de los archivos BAM provenientes de Bismark

```
my.methRaw = processBismarkAln(location = Bam_files, sample.id=samples, assembly="rice",  
                               treatment = c(0,1), read.context="CpG",  
                               mincov=10, save.folder=outDir)
```

1	chrBase	chr	base	strand	coverage	freqC	freqT
2	Chr1.10145	Chr1	10145	F	24	0.00	100.00
3	Chr1.10149	Chr1	10149	F	24	0.00	100.00
4	Chr1.10290	Chr1	10290	F	29	0.00	100.00
5	Chr1.10327	Chr1	10327	F	29	0.00	100.00
6	Chr1.10366	Chr1	10366	F	25	0.00	100.00
7	Chr1.10419	Chr1	10419	F	19	0.00	100.00
8	Chr1.10429	Chr1	10429	F	18	0.00	100.00
9	Chr1.10476	Chr1	10476	F	19	0.00	100.00
10	Chr1.10544	Chr1	10544	F	16	0.00	100.00
11	Chr1.10549	Chr1	10549	F	16	0.00	100.00
12	Chr1.10573	Chr1	10573	F	15	0.00	100.00
13	Chr1.10592	Chr1	10592	F	16	0.00	100.00
14	Chr1.10596	Chr1	10596	F	15	0.00	100.00
15	Chr1.10646	Chr1	10646	F	11	0.00	100.00
16	Chr1.1192	Chr1	1192	F	10	100.00	0.00
17	Chr1.1218	Chr1	1218	F	13	100.00	0.00
18	Chr1.1222	Chr1	1222	F	14	100.00	0.00
19	Chr1.1238	Chr1	1238	F	15	100.00	0.00

**Archivo generado  
en Methykit  
sativaCpG.txt**



## Corriendo MethyKit...

1.1 Crear el objeto methylkit a partir de los archivos BAM provenientes de Bismark

```
my.methRaw = processBismarkAln(location = Bam_files, sample.id=samples, assembly="rice",  
                             treatment = c(0,1), read.context="CpG",  
                             mincov=10, save.folder=outDir)
```

1.2 Crear el objeto methylkit a partir de los **archivos de texto** obtenidos en el paso anterior y los guarda como archivos "flat file database" en la carpeta methylDB\_CpG

```
my.methRaw2 = methRead(location = files, sample.id=samples, assembly="rice",  
                      treatment = c(0,1), context="CpG",  
                      dbtype = "tabix", dbdir = "methylDB_CpG")
```

## 2. Estadísticos descriptivos de las muestras

```
getMethylationStats(my.methRaw2[[1]],plot=FALSE,both.strands=FALSE)
```

methylation statistics per base

summary:


Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.00	0.00	76.67	51.66	95.24	100.00

percentiles:

0%	10%	20%	30%	40%	50%	60%	70%
0.00000	0.00000	0.00000	0.00000	6.25000	76.66667	87.50000	92.85714
80%	90%	95%	99%	99.5%	99.9%	100%	
100.00000	100.00000	100.00000	100.00000	100.00000	100.00000	100.00000	

## 2. Estadísticos descriptivos de las muestras

```
getMethylationStats(my.methRaw2[[1]],plot=TRUE,both.strands=FALSE)
```



En cualquier célula dada, se esperaría que cualquier base esté metilada o no.

## 2. Estadísticos descriptivos de las muestras – Estadísticas de cobertura

```
getCoverageStats(my.methRaw2[[1]],plot=FALSE,both.strands=FALSE)
```

read coverage statistics per base

summary:


Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
10.00	12.00	16.00	19.39	22.00	298.00

percentiles:

0%	10%	20%	30%	40%	50%	60%	70%	80%	90%	95%	99%	99.5%	99.9%
10	11	12	13	14	16	18	20	24	30	37	70	101	196
100%													
298													

## 2. Estadísticos descriptivos de las muestras – Estadísticas de cobertura

```
getCoverageStats(my.methRaw2[[1]],plot=TRUE,both.strands=FALSE)
```



Experimentos con un alto sesgo de duplicación por PCR tendrán un pico secundario hacia el lado derecho del histograma.

# Análisis comparativo

## 3. Filtrado de secuencias de acuerdo a la cobertura de lecturas

```
filtered.obj=filterByCoverage(my.methRaw2_p, lo.count=10, lo.perc=NULL,  
                             hi.count=NULL, hi.perc=99.9)
```

Puede resultar útil filtrar muestras según la cobertura...

- Si las muestras sufren un sesgo de PCR, sería útil descartar bases con una cobertura de lectura muy alta.
- Es necesario descartar las bases que tienen una cobertura de lectura baja para aumentar la potencia de las pruebas estadísticas.

# Análisis comparativo

## 4. Unión de las muestras

```
meth = unite(my.methRaw2, destrand=TRUE)
```

La función 'unite' unirá todas las muestras en un objeto para la ubicación de las pares de bases que están cubiertas en todas las muestras



# Análisis comparativo


## 4. Análisis de agrupamiento

```
clusterSamples(meth, dist="correlation", method="ward", plot=TRUE)
```

## 5. Análisis de componentes principales (PCA)

```
PCASamples(meth, adj.lim=c(0.5,0.5))
```



# Correlación de las muestras según el contexto CpG




Mismo patrón con  
metilación CHG y CHH

Método de distancia: 1 - Pearson  
Método de agrupamiento: Ward

# Análisis de datos para datos de secuenciación por bisulfito.



# Regiones diferencialmente metiladas (DMRs)




# Regiones diferencialmente metiladas (DMRs)



# Metilación diferencial

La principal ventaja de MethylKit es que puede tener en cuenta la cobertura de secuenciación, puede incorporar covariables adicionales en el modelo y trabajar con la metilación de CHG o CHH.

También proporciona funcionalidades como compilación de la metilación de muestras, agrupación de muestras, anotación y visualización de DM, etc.



## Identificación de DMRs utilizando el método de sliding windows

La función `calculateDiffMeth ()` es la función principal para calcular la metilación diferencial.

Dependiendo del tamaño de la muestra por cada conjunto, se utilizará la regresión logística o exacta de Fisher para calcular los valores P.

Los valores P se ajustarán a los valores Q utilizando el método SLIM (Wang et al. 2011) <https://pubmed.ncbi.nlm.nih.gov/21098430/>.

Si tiene réplicas, la función utilizará automáticamente la regresión logística.



# Metilación diferencial

## 6. Creación de ventanas de tamaño fijo

```
tiles = tileMethylCounts(filtered.obj, win.size=200, step.size=100, cov.bases = 5)
```


## 7. Prueba estadística para evaluar regiones diferencialmente metiladas


```
myDiff=calculateDiffMeth(meth)  
  
myDiff_25.hyper = getMethylDiff(myDiff,difference=25, qvalue=0.01, type="hyper")  
myDiff_25.hypo = getMethylDiff(myDiff,difference=25, qvalue=0.01, type="hypo")  
myDiff_25.all = getMethylDiff(myDiff,difference=25, qvalue=0.01)
```


## Archivo de DMRs generado en Methykit

chr	start	end	strand	pvalue	qvalue	meth.diff
Chr1	187001	187200	*	1.93764753115302e-87	1.99415148344453e-85	82.258064516129
Chr1	462901	463100	*	6.57156447709056e-113	1.05162024158083e-110	77.6978417266187
Chr1	1568901	1569100	*	2.53152713915354e-90	2.73362509307498e-88	76.926630499159
Chr1	1569001	1569200	*	2.53152713915354e-90	2.73362509307498e-88	76.926630499159
Chr1	1796401	1796600	*	7.97959506948184e-80	7.01657687799872e-78	78.5371800081268
Chr1	2727401	2727600	*	3.29611893933131e-157	1.14938655527887e-154	76.0563891193848
Chr1	3252101	3252300	*	2.88236421602144e-158	1.01788331029976e-155	89.9892536396899
Chr1	3252201	3252400	*	5.89790362651076e-232	6.02377375603014e-229	88.6363636363636
Chr1	3252301	3252500	*	3.58679465910954e-170	1.54725014245526e-167	86.4347826086956
Chr1	3252401	3252600	*	1.51639682666867e-200	1.00620012407043e-197	93.2238193018481
Chr1	3252501	3252700	*	2.26634872711875e-258	3.44673041781404e-255	90.1129943502825
Chr1	3308401	3308600	*	2.57630453533704e-129	5.48016841641078e-127	80.058524173028
Chr1	3498601	3498800	*	2.68419784838244e-81	2.43369218350417e-79	77.382618159204
Chr1	3498701	3498900	*	2.34218774279022e-107	3.41619463935642e-105	83.1172839506173
Chr1	3499301	3499500	*	1.05513305365792e-131	2.33624697716072e-129	79.1142857142857
Chr1	3499401	3499600	*	2.77744899572657e-235	2.96764965250914e-232	80.7422166160197
Chr1	3499501	3499700	*	2.38813036203415e-228	2.33056542111386e-225	75.7549570637308
Chr1	3994901	3995100	*	5.91581743991558e-155	1.97213160789924e-152	75.6989247311828

# Un resumen general del flujo de trabajo...








**GRACIAS...**



**PREGUNTAS??**

# ómica

## Aliados



## Apoyan



## Referencias...

Akalin, A., Kormaksson, M., Li, S., Garrett-Bakelman, F. E., Figueroa, M. E., Melnick, A., & Mason, C. E. (2012). MethylKit: a comprehensive R package for the analysis of genome-wide DNA methylation profiles. *Genome Biology*, 13(10), R87. <https://doi.org/10.1186/gb-2012-13-10-R87>

Krueger, F., & Andrews, S. R. (2011). Bismark: A flexible aligner and methylation caller for Bisulfite-Seq applications. *Bioinformatics*, 27(11), 1571–1572. <https://doi.org/10.1093/bioinformatics/btr167>

Shafi, A., Mitrea, C., Nguyen, T. and Draghici, S. 2018. A survey of the approaches for identifying differential methylation using bisulfite sequencing data. *Briefings in Bioinformatics*. 737–753

Wreczycka, K., Godschan, A., Yusuf, D., Grüning, B., Assenov, Y. & Akalin, A. (2017) Strategies for analyzing bisulfite sequencing data. *Journal of biotechnology*. 261: 105-115.

Zhang, H., Lang, Z. & Zhu J.K. (2018). Dynamics and function of DNA methylation in plants Huiming. *Molecular cell biology*. Pag: 489-506.