

## Modules de formation 2022



Alliance



# Lancement des VMs

- Sur Biosphere:

<https://biosphere.france-bioinformatique.fr/catalogue/>

**VM RNASeq\_SG**

**Configurer**

**Groupe: RNA-Seq SG**

**Gabarit XLarge (4 vCPUs)**



**Bioinformatics platform dedicated to the genetics and genomics of tropical and Mediterranean plants and their pathogens**

genome assembly SNP detection  
phylogeny structural variation  
comparative genomics transcriptome assembly differential expression  
GWAS pangenomics  
population genetics metagenomics  
polyploidy



Rice



Banana



Palm



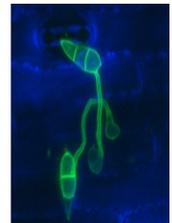
Sorghum



Coffee



Cassava



Magnaporthe



Larmande Pierre  
**Orjuela-Bouniol Julie**  
Sabot François  
Tando Ndomassi  
**Tranchant-Dubreuil  
Christine**



Comte Aurore  
Dereeper Alexis  
**Ravel Sébastien**



Bocs Stephanie  
Boizet Alice  
De Lamotte Frédéric  
**Droc Gaetan**  
Dufayard Jean-François  
Hamelin Chantal  
Martin Guillaume  
Pitollat Bertrand  
**Ruiz Manuel**  
**Sarah Gautier**  
Summo Marilyne



**Rouard Mathieu**  
Guignon Valentin  
Catherine Breton



Sempere Guilhem

Alliance

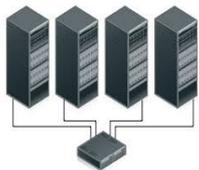
## Workflow manager

TOOLBOX  
Toolbox for generic NGS analyses

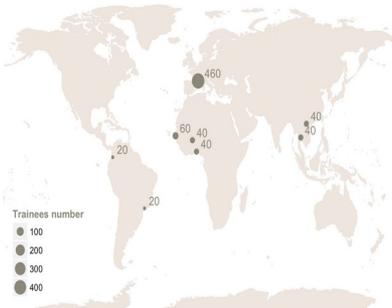
●●●●●  
SNAKEMAKE

Galaxy

## HPC and trainings....



37 courses organized last 7 years



## Genome Hubs & Information System



Gigwa

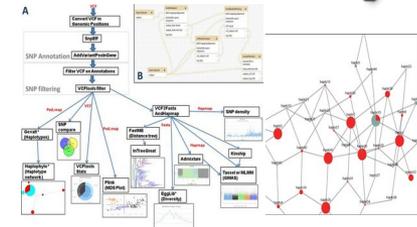
SNPs and Indels

GreenPhyl

Family Id	Family Name	Number of sequences	Status
EP000010	Cytochrome P450 superfamily	6542	●●●
EP000017	AP2/ERF transcription factor family: ERF/ERF3 group (partial)	5142	●●●
EP000020	NAC transcription factor family	4574	●●●
EP000028	MADS transcription factor family		
EP000018	Haem peroxidase superfamily		
EP000066	General substrate transporter superfamily		
EP000022	Subtilisin-like Serine Proteases family		
EP000019	NPF, NRT1/PTR FAMILY		

Gene families

SNIPlay



<https://github.com/SouthGreenPlatform>



@green\_bioinfo

Formations 2022  
Montpellier

4-5 Avril

**Guide de survie à linux**  
Agropolis, salle Badiane

19-20 Avril

**Linux avancé**  
Agropolis, salle Badiane

18-19 Mai

**Utilisation avancée  
d'un cluster de calcul**  
IRD, amphî capmeditrop

14 Juin

**Génomique bactérienne  
comparative**  
Agropolis, salle Badiane

10 Juin

**Initiation à l'analyse de  
données RNAseq**  
Agropolis, salle Badiane

30 Mai - 2 Juin

**Python**  
Agropolis, salle Badiane

21-24 Juin

**Analyse de variants  
à partir de short and long reads**  
Agropolis, salle Bambou

Métagénomique

## Trainings 2022

- Toutes nos formations :  
<https://southgreenplatform.github.io/trainings/>
- Slides & Practices : [RNAseq](#)

# Initiation aux analyses de données transcriptomiques

[www.southgreen.fr](http://www.southgreen.fr)

[https://southgreenplatform.github.io/  
trainings](https://southgreenplatform.github.io/trainings)



Alliance

## Objectifs

- Connaître et manipuler des packages/outils disponibles pour la recherche de gènes différentiellement exprimés
- Réfléchir sur les différentes techniques de normalisation des données
- Détecter les gènes différentiellement exprimés entre 2 conditions

## Applications

- Mapping and counting using STAR , HTSeq-Count
- Differential expression analysis: EdgeR, Deseq2 : DIANE

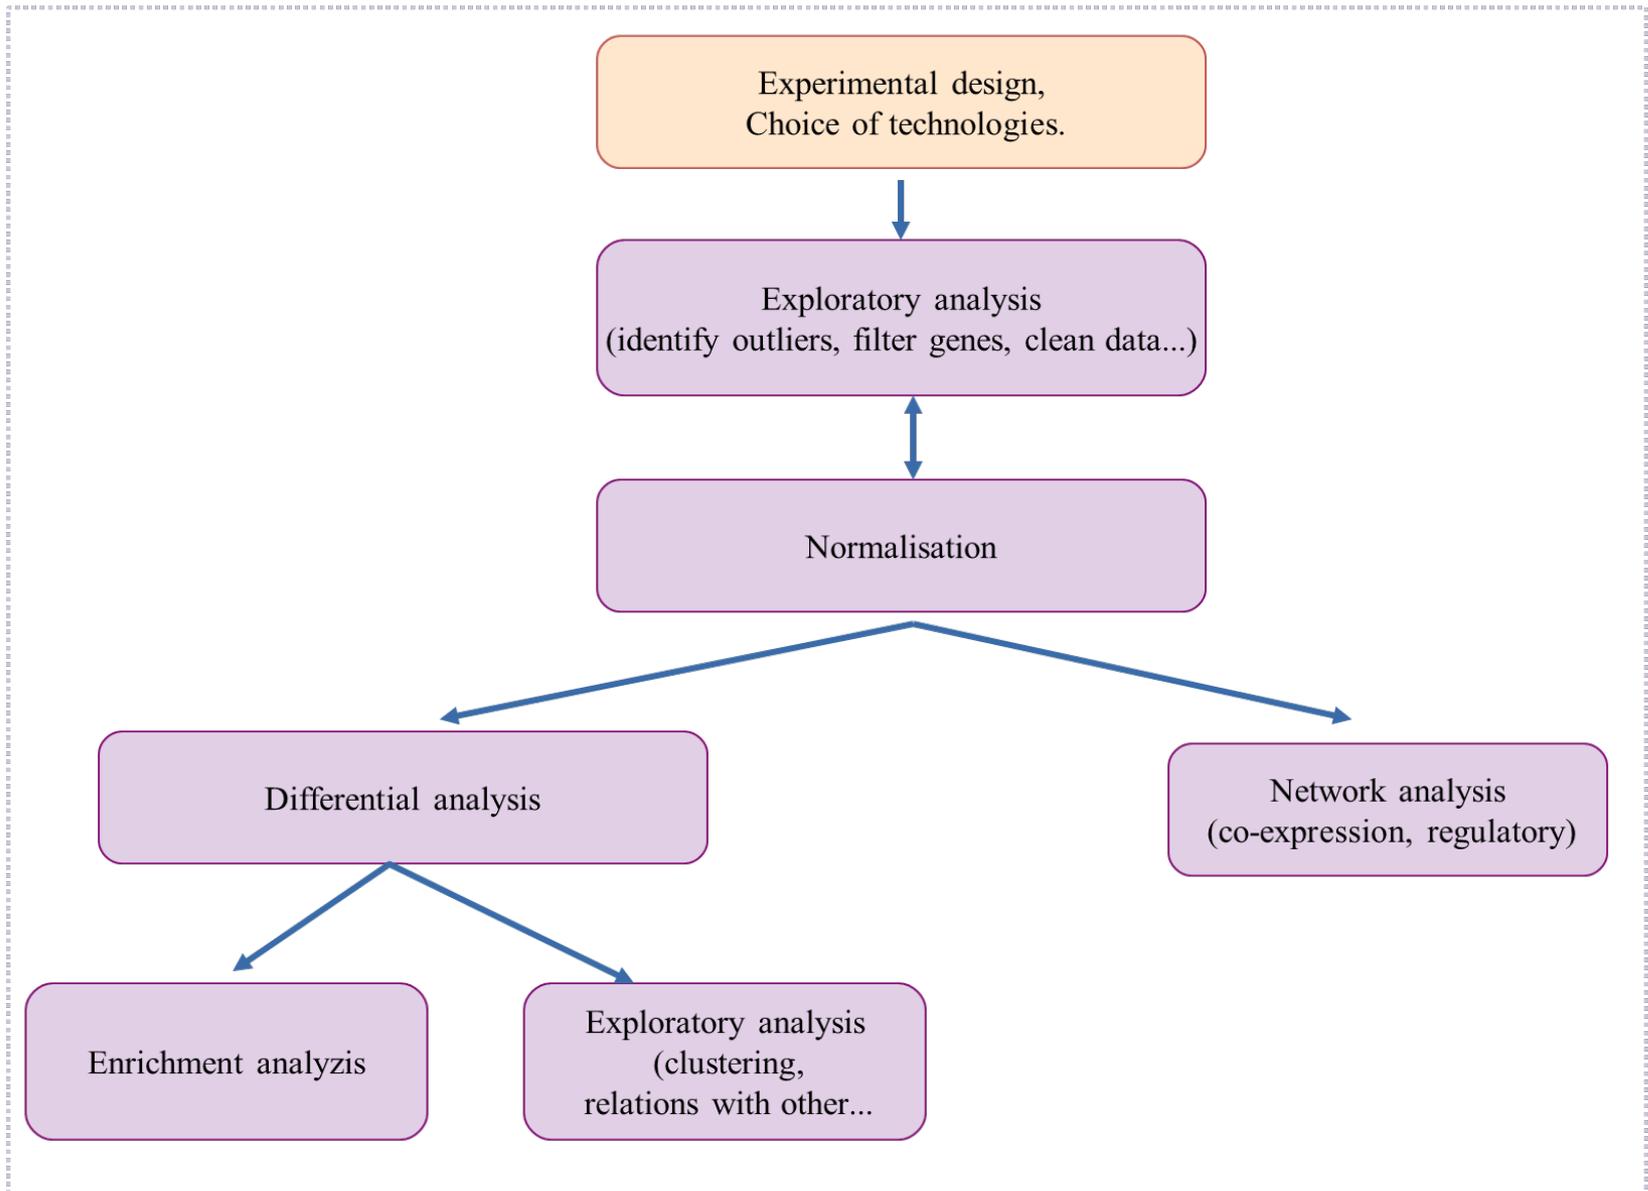
## Pourquoi faire du RNAseq ?

- **L'analyse d'expression différentielle** (différence d'expression dans des conditions précises) au niveau transcriptomique.
- Etude de **l'épissage alternatif** (isoformes) et recherche de nouveaux transcrits.
- **Recherche d'allèles spécifiques** et quantification de leur expression.
- **Construction d'un transcriptome de novo** pour les organismes non modèles.

## Choix technologiques

- **Déplétion / enrichissement :**
  - Déplétion des ARNr (eucaryote ou procaryote)
  - Sélection des transcrits poly-A (eucaryotes)
- **Séquençage directionnel**
  - Dans le cas des études ARN anti-sens
- **Multiplexage**
  - Ajouts de séquences tags afin de grouper plusieurs échantillons à séquencer sur une même piste de flowcell.

# 1- Design experimental



Basic experiment : trouver les différences entre condition  
contrôle/traitée

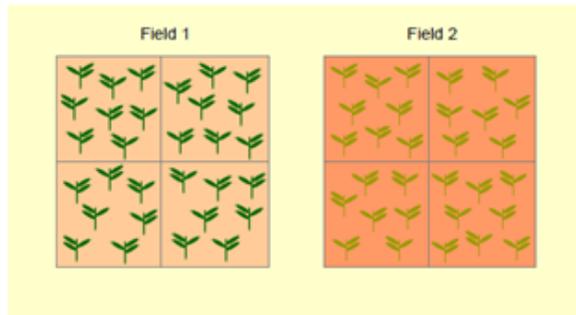


control group plant



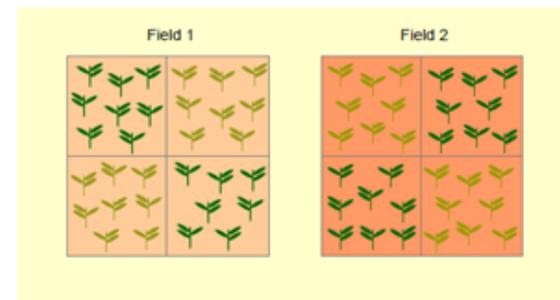
treated group plant

Mauvais plan expérimental : les  
plantes traitées sont dans un champs  
et les contrôles dans un autre.

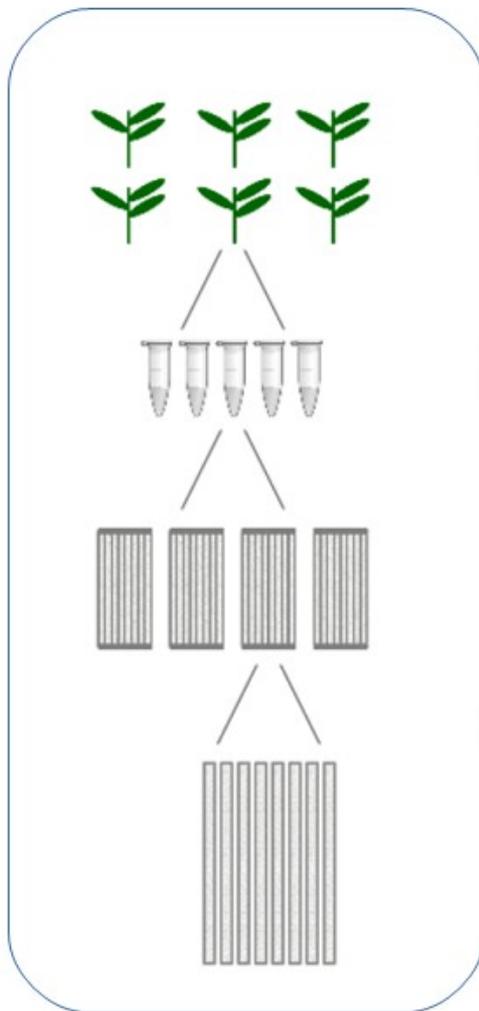


Pas de possibilité de différencier  
l'effet champs de l'effet traitement

Bon plan expérimental : la moitié  
des plantes traitées poussent avec un  
contrôle dans un même champs et  
l'autre moitié dans un autre champs



Possibilité de différencier l'effet  
champs de l'effet traitement.



collect

1 – Variations biologiques :  
variations individuelles dues  
aux effets génétiques,  
de l'environnement

Sample preparation

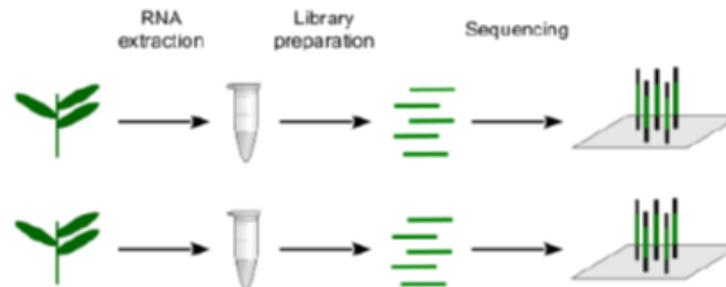
2 – Variations techniques :  
effet de la préparation  
des librairies

cDNA on lane of flowcell

3 – Variation techniques : effet des  
lane et des flowcell

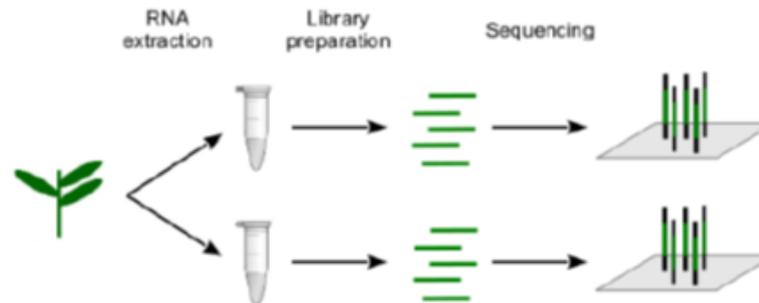
Effet lane < Effet Flowcell < Effet de la préparation de la librairie < < Effet biologique

**Réplicat biologique** : Différents échantillons biologiques, répétés plusieurs fois séparément (au moins 3 fois).



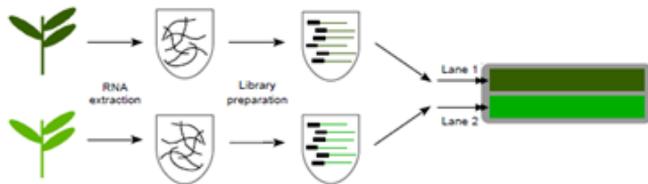
**Réplicat Technique** : Même matériel biologique, répété plusieurs fois indépendamment des étapes techniques.

- Plusieurs extractions d'une même échantillon
- Plusieurs séquençages d'une même librairie



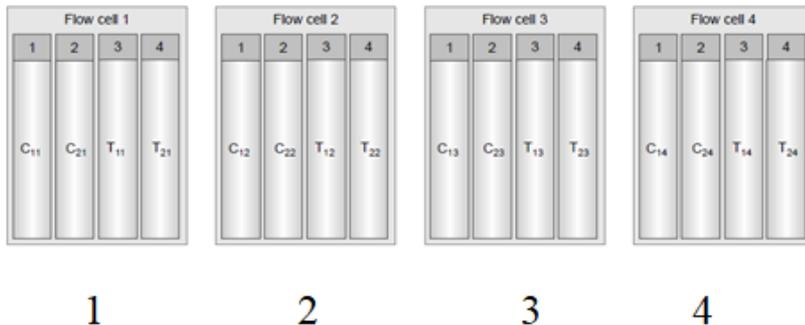
Échantillons séquencés sur deux lanes différentes.

- l'effet lane ne peut pas être mesuré mais la comparaison entre échantillon est préservée.



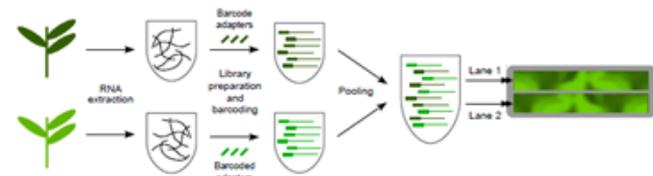
Exemple :

2 réplicats biologiques par condition et 4 réplicats techniques par réplicats biologiques



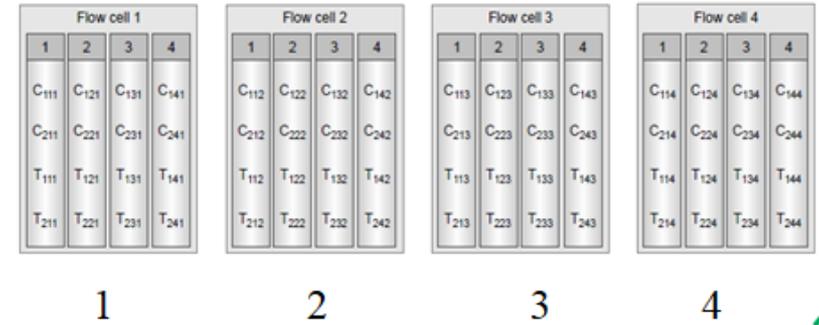
Multiplexes RNAseq plan d'expérimentation :

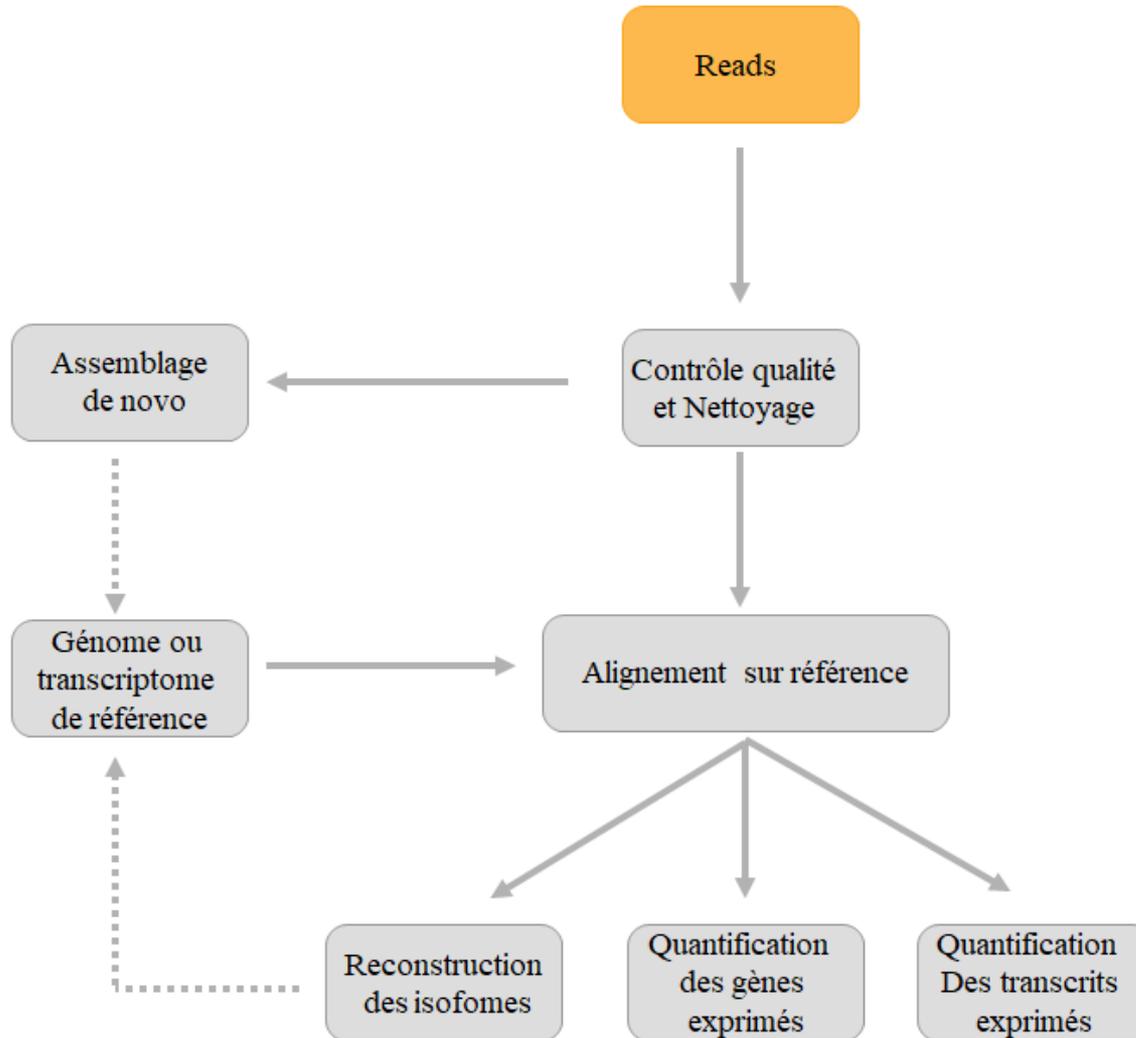
- Les fragments d'ADN sont barcodés, donc plusieurs échantillons sont séquencés sur la même lane

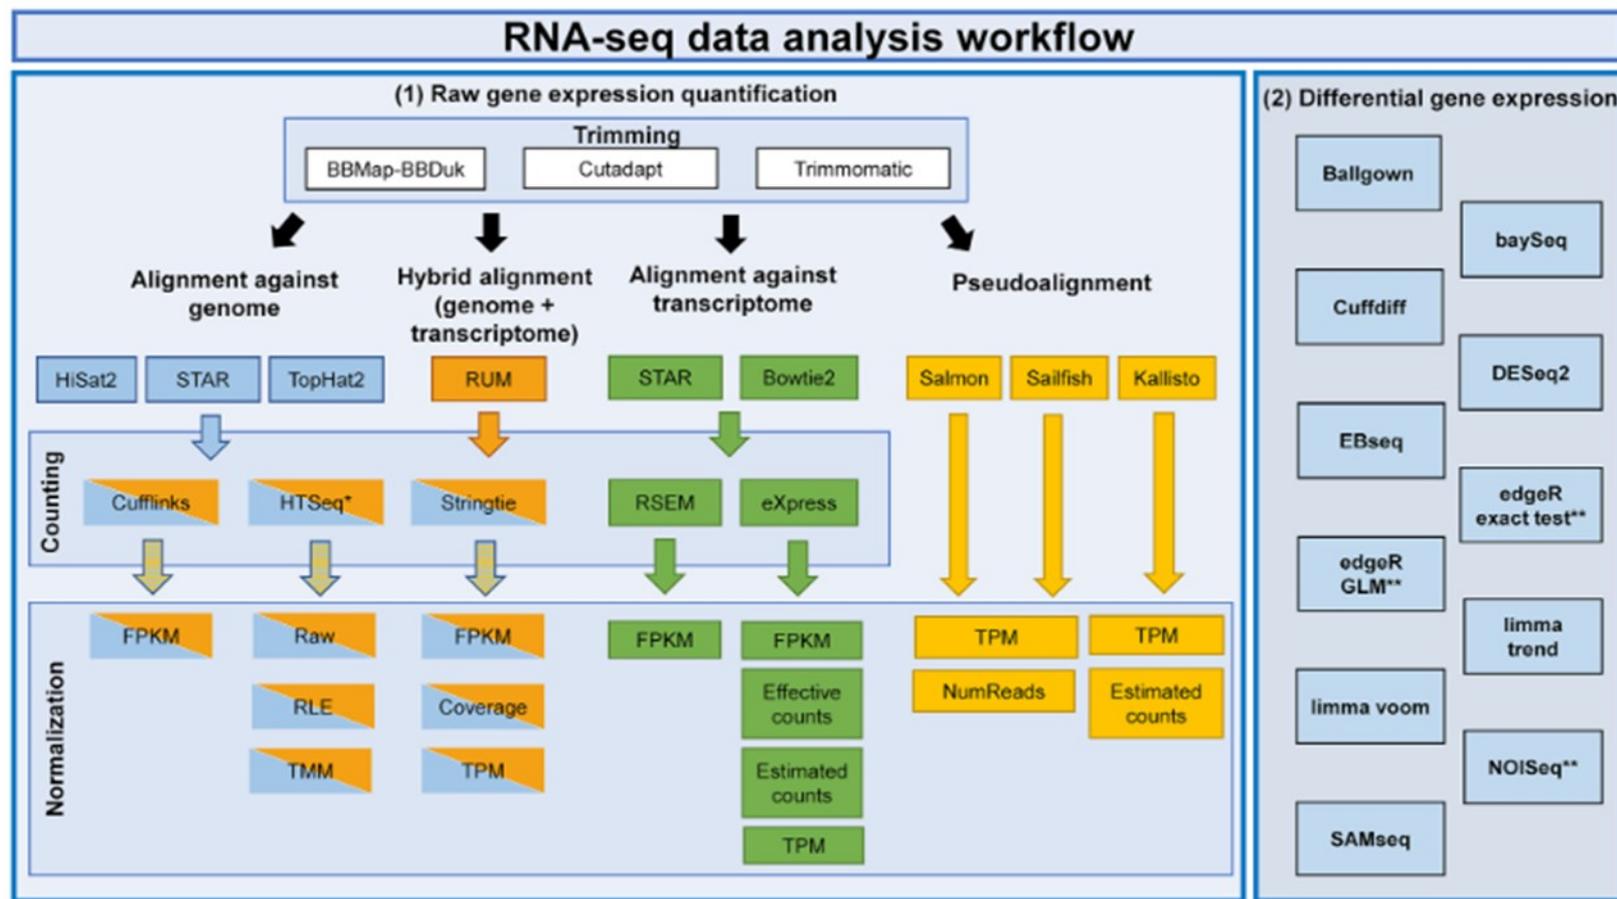


Exemple :

2 réplicats biologiques par condition et 4 réplicats techniques par réplicats biologiques répartis sur 4 flowcell







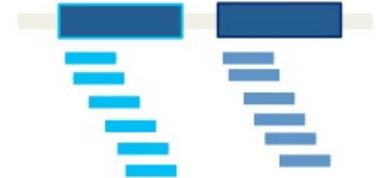
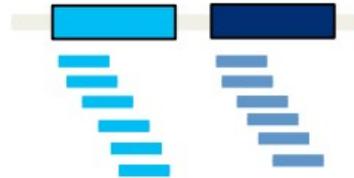
**Figure 1.** RNA-seq analysis workflow. Left panel (1) represents the raw gene expression quantification workflow. Every box contains the algorithms and methods used for the RNA-seq analysis at trimming, alignment, counting, normalization and pseudoalignment levels. The right panel (2) represents the algorithms used for the differential gene expression quantification. \*HTSeq was performed in two modes: union and intersection-strict. \*\*EdgeR exact test, edgeR GLM and NOISeq have internally three normalization techniques that were evaluated separately.

## **2- Des reads aux transcrits**

Reads



Mapping against genome



Read clusters



Putative transcripts



*de novo assembly*

*Genome based*

*Genome guided de novo*

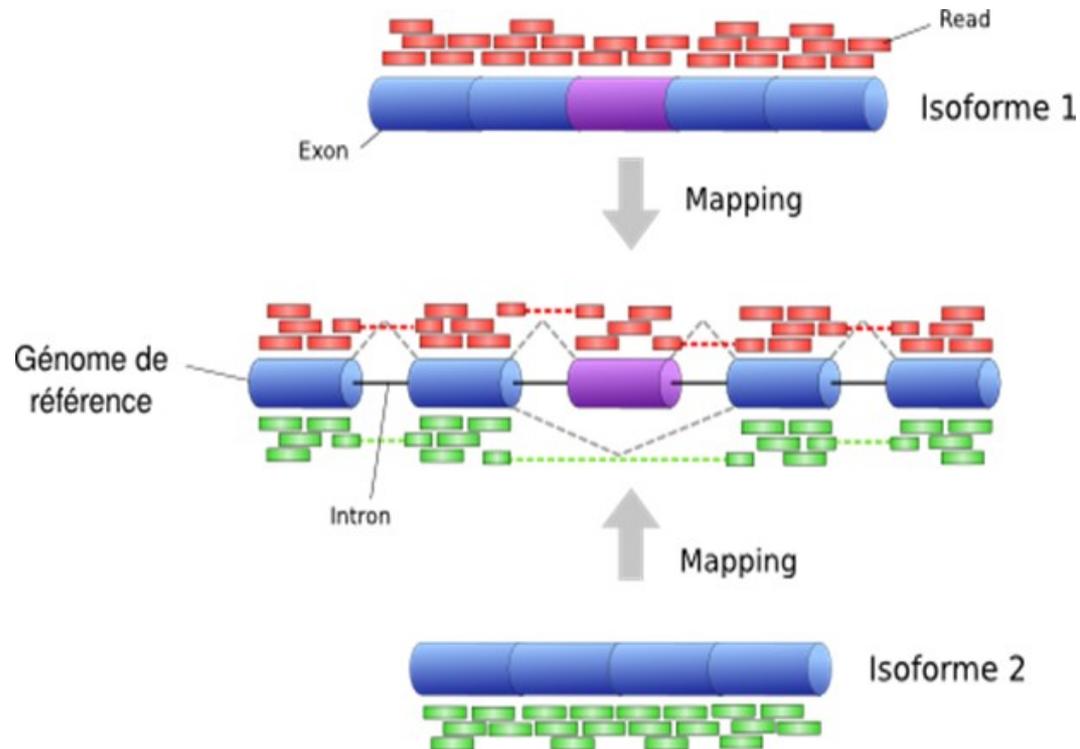


	<b>Problème</b>	<b>Pourquoi les éliminer?</b>	<b>Outils</b>
<b>Sequences biases</b>	Ns, mauvaise qualité des nucléotides, biases hexamères (random priming)	Pour éliminer des erreurs de sequencing.  Désastreux pour la plupart des assembleurs	PRINSEQ2 FASTX Toolkit <i>Trimmomatic</i> <i>Fastp</i>
<b>Adaptors and primers</b>	Peuvent être trouvés dans le 3' final d'un insert très court	Des ponts entre séquences sans relation aucune: Chimères	<i>Fastp</i> , <i>Trimmomatic</i> , cutadapt, far, btrim, SeqTrim, TagCleaner, solexaQA
<b>Poly A/T tails, low complexity reads</b>	Des queues poly A/T peuvent être laissés pendant la préparation de la librairie	Des ponts entre séquences sans relation aucune: Chimères	<i>PRINSEQ2</i> <i>Fastp</i>
<b>Contaminations</b>	RNA Ribosomal RNA/DNA étrangère (PhiX, Bacteria, ...)		SortMeRNA, riboPicker, DeconSeq

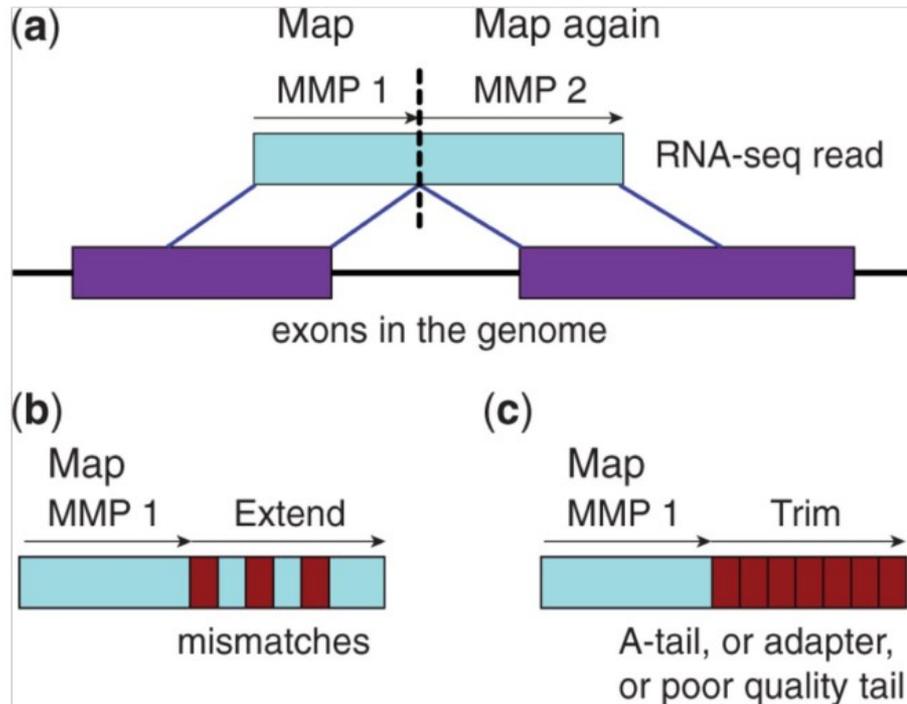
# Practice : Nettoyage des reads

[TP Fastp](#)

- Permet la mise en évidence d'isoformes
- Aide à l'annotation structurale du génome



1st step Maximum Mapability Prefix search  
-> no mismatches



2<sup>nd</sup> step :  
At the second stage STAR switches MMPs to generate read-level alignments that (contrary to MMPs) can contain mismatches and indels.

STAR is extremely fast but requires a substantial amount of RAM to run efficiently.



# Practice : Mapping

[TP Mapping](#)

# 3- Comptage

## mRNA-seq for measuring gene expression Myers Lab

Selection of mRNA with polyA tail :



Random Primed cDNA synthesis :



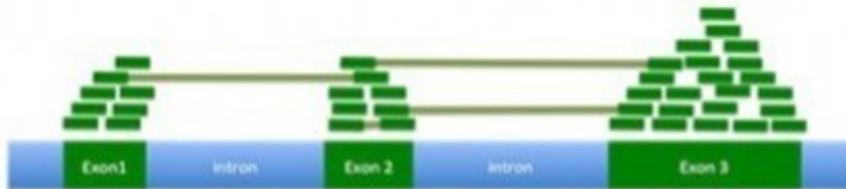
Paired-end sequencing of fragmented cDNA:



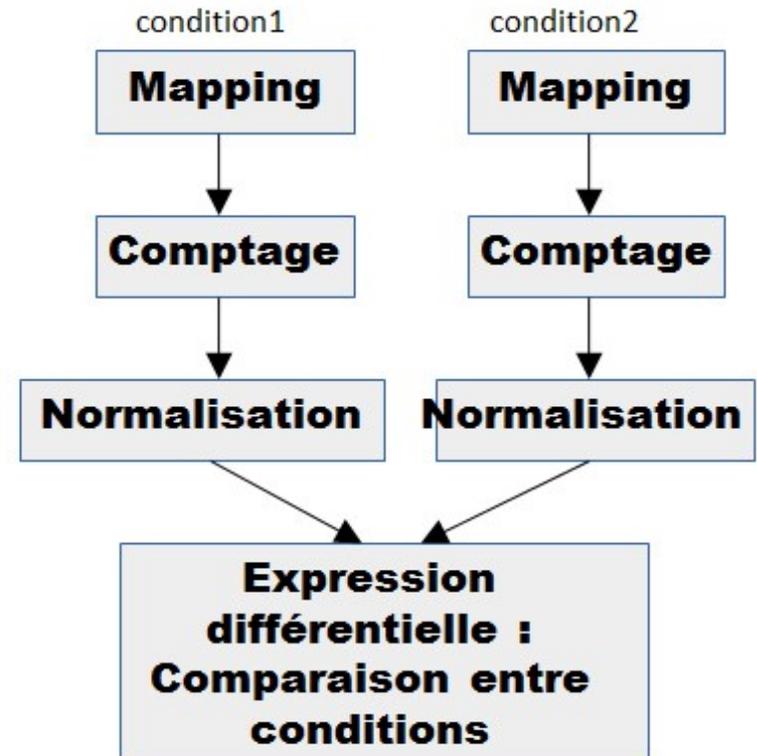
Alignment:

Sequencing Reads

Genome

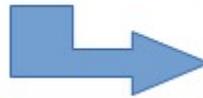


Quantify expression levels = RPKM (# of aligned Reads Per Kb of transcript per Million total reads)



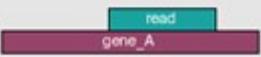
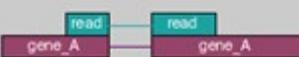
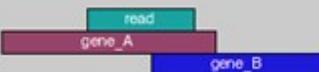
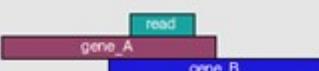
**1) Si le mapping a été fait sur un génome de référence annoté**

**=> Utilisation de HTSeq-count (prend en entrée l'annotation GFF)**



**2) Si le mapping a été fait sur un transcriptome de référence**

**=> samtools idxstats**

	union	intersection_strict	intersection_nonempty
	gene_A	gene_A	gene_A
	gene_A	no_feature	gene_A
	gene_A	no_feature	gene_A
	gene_A	gene_A	gene_A
	gene_A	gene_A	gene_A
	ambiguous	gene_A	gene_A
	ambiguous	ambiguous	ambiguous

GFF (general feature format) is a file format used for describing genes and other features of DNA, RNA and protein sequences.


## gff3

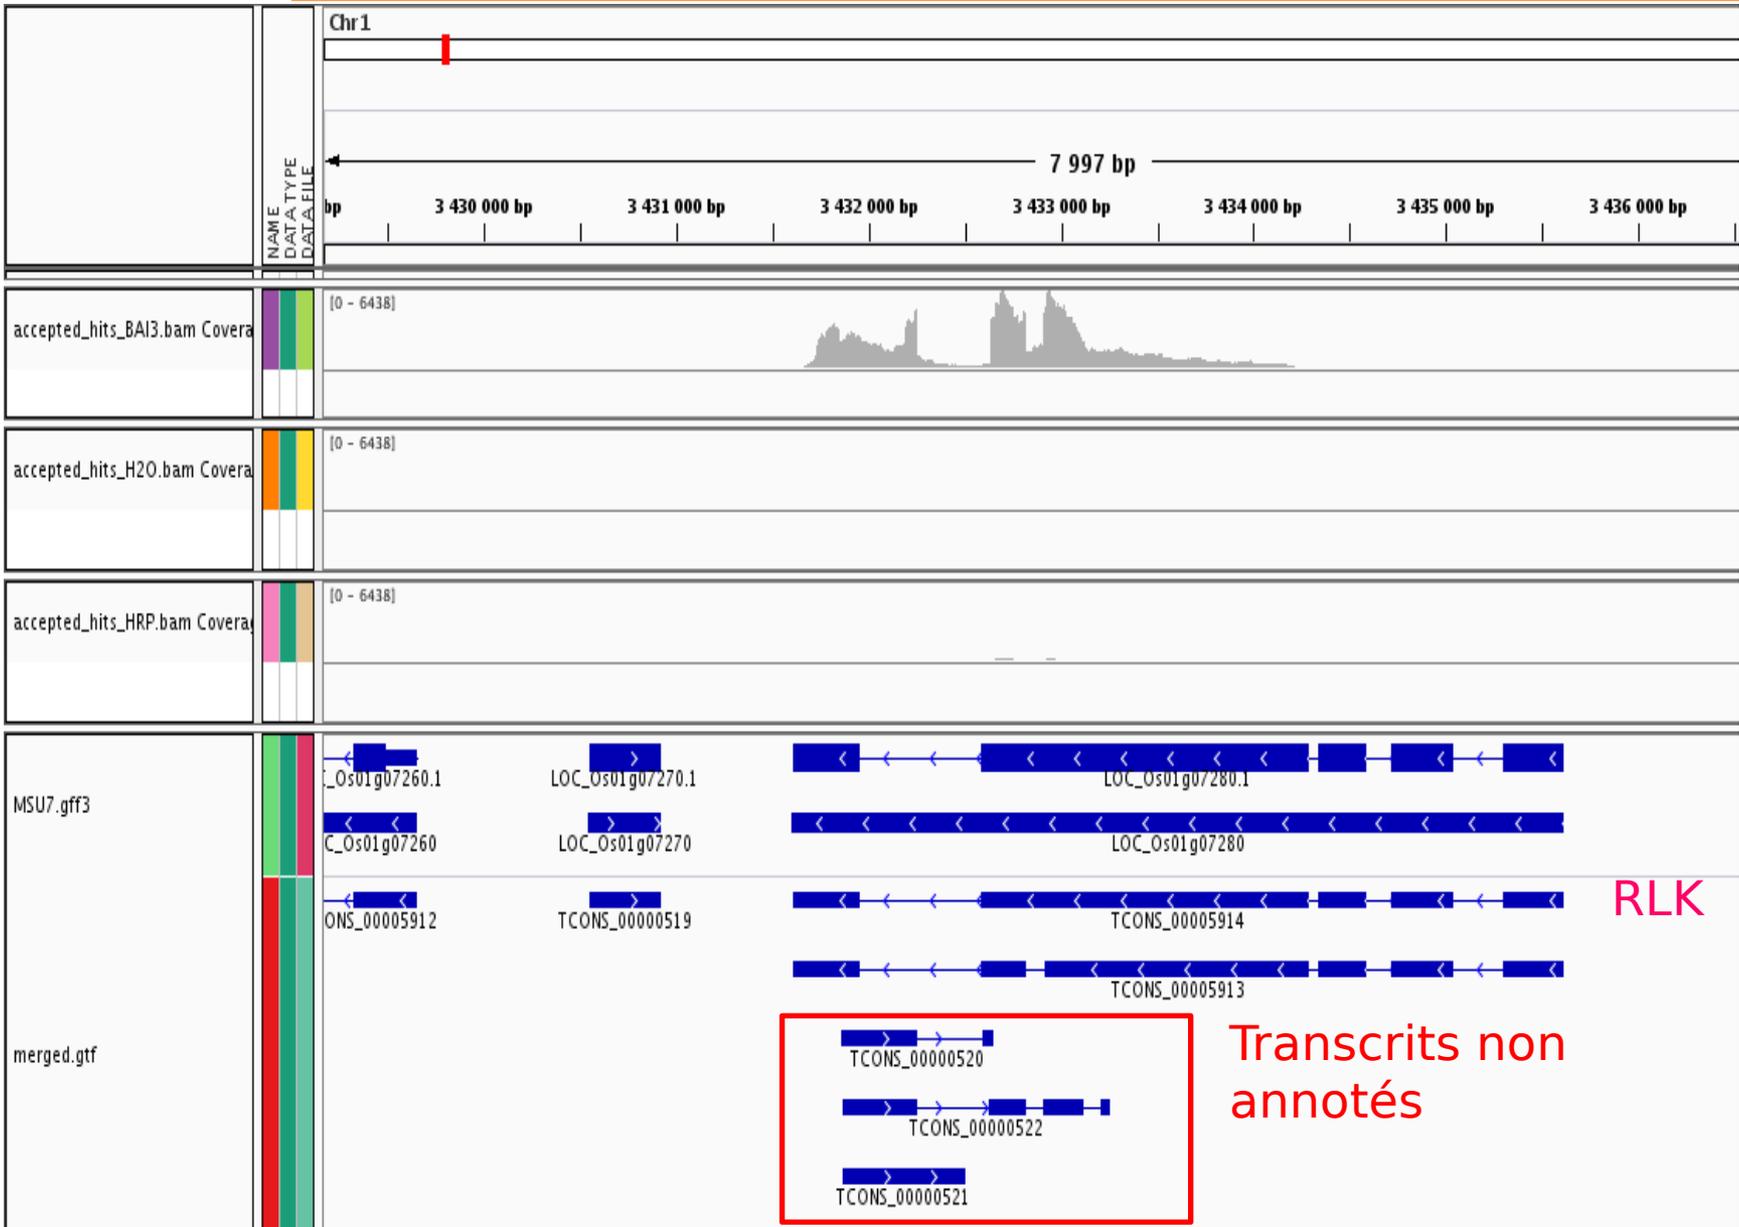
Seqname	Source		Score	Strand	Frame			
chr22	protein_coding	gene	19701987	19712295	.	+	.	ID=ENSG00000184702;Name=SEPT5
chr22	protein_coding	mRNA	19707711	19708397	.	+	.	ID=ENST00000413258;Name=SEPT5-016;Parent=ENSG00000184702
chr22	protein_coding	protein	19707711	19708397	.	+	.	ID=ENSP00000404673;Name=SEPT5-016;Parent=ENST00000413258
chr22	protein_coding	CDS	19707711	19707761	.	+	1	Name=CDS:SEPT5;Parent=ENST00000413258
chr22	protein_coding	CDS	19707843	19707977	.	+	1	Name=CDS:SEPT5;Parent=ENST00000413258
chr22	protein_coding	CDS	19708165	19708189	.	+	1	Name=CDS:SEPT5;Parent=ENST00000413258
chr22	protein_coding	CDS	19708291	19708397	.	+	0	Name=CDS:SEPT5;Parent=ENST00000413258
chr22	protein_coding	exon	19707711	19707761	.	+	.	Parent=ENST00000413258
chr22	protein_coding	exon	19707843	19707977	.	+	.	Parent=ENST00000413258
chr22	protein_coding	exon	19708165	19708189	.	+	.	Parent=ENST00000413258
chr22	protein_coding	exon	19708291	19708397	.	+	.	Parent=ENST00000413258

Diagram labels: Feature (under Source), Start (under 3rd column), End (under 4th column), Attribute (under 8th column).

# Practice : Comptage

[TP Comptage](#)





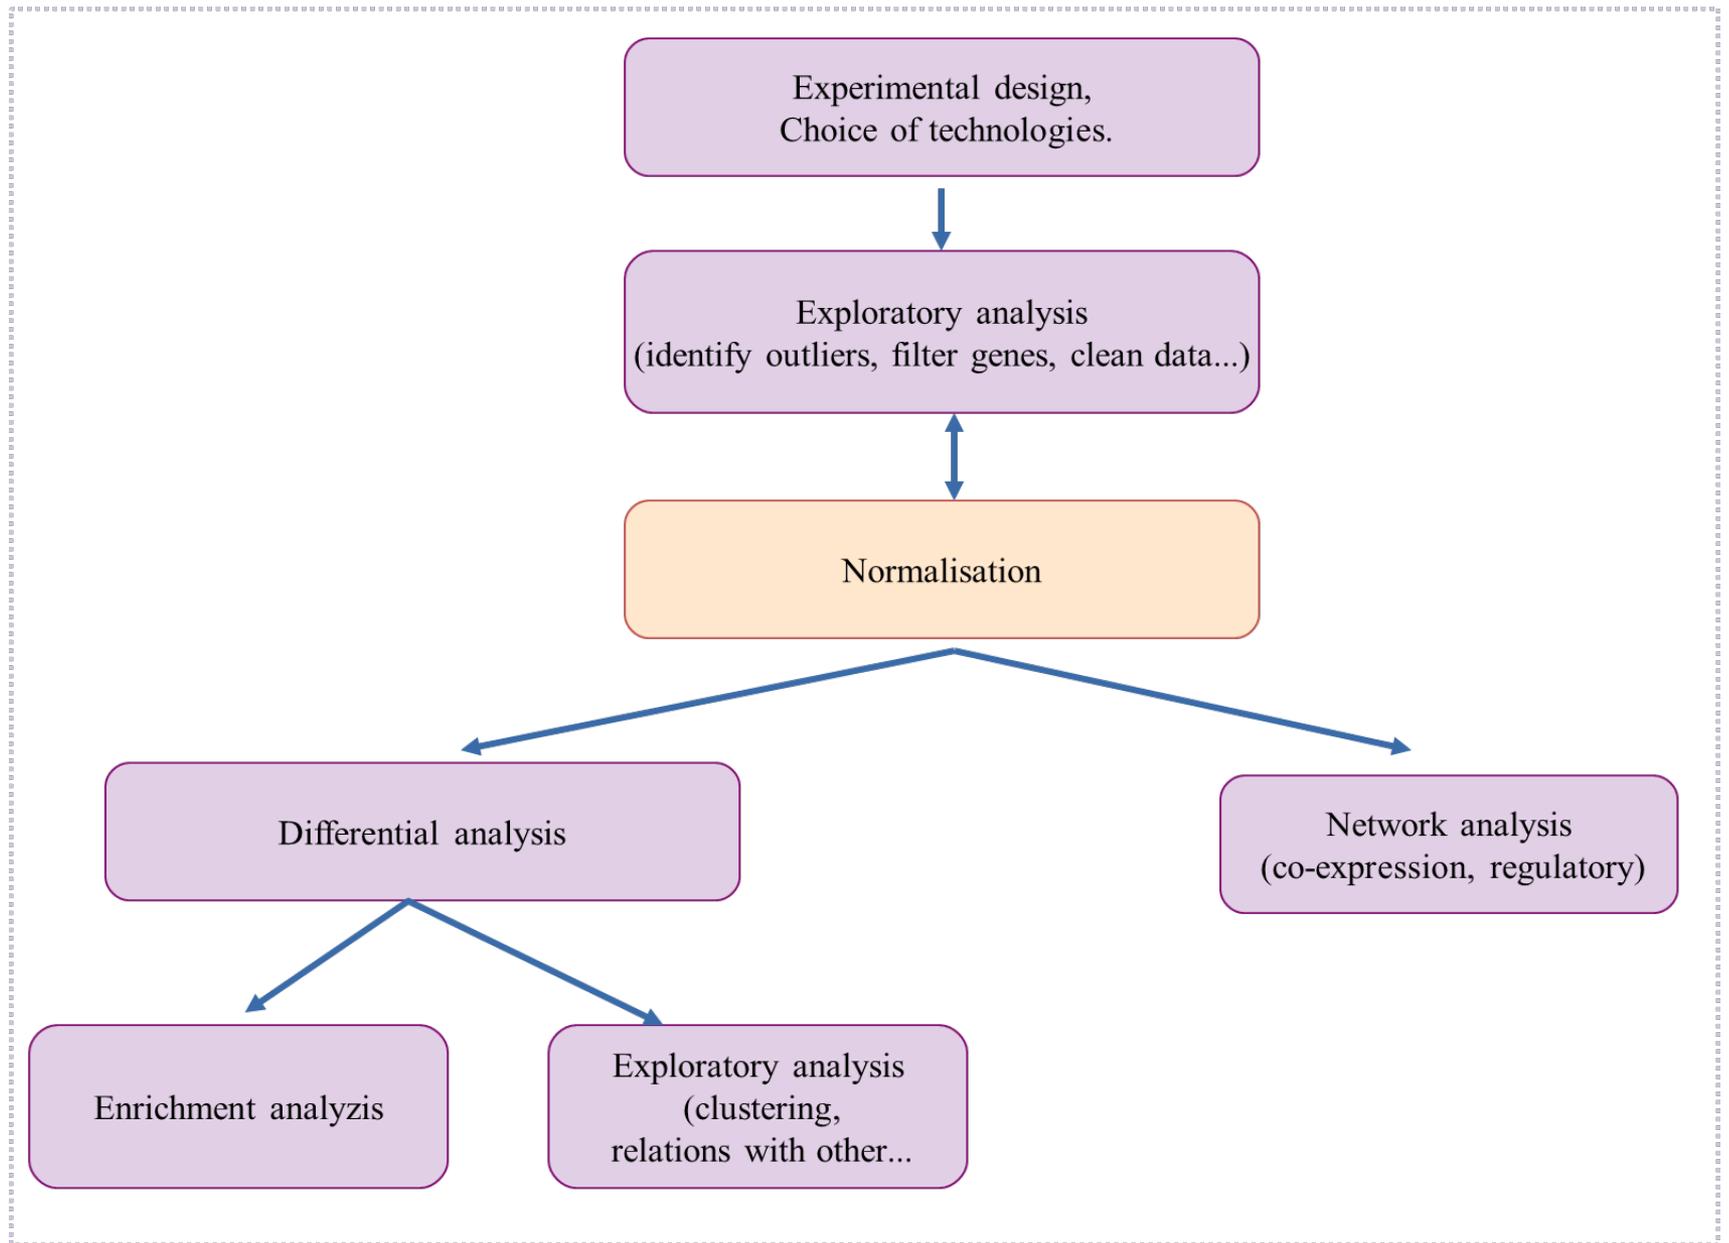


# Recherche de gènes différentiellement exprimés

- Un gène est déclaré **différentiellement exprimé** (DE) entre 2 conditions si la différence d'expression observée est **statistiquement significative** i.e plus grande qu'une variation naturelle aléatoire.
  - Besoin d'un test statistique
  - Les principaux étapes de l'analyse :
    - Design experimental
    - Normalization
    - Analyse différentielle
    - Tests statistiques multiples



## **4- Normalisation des données**



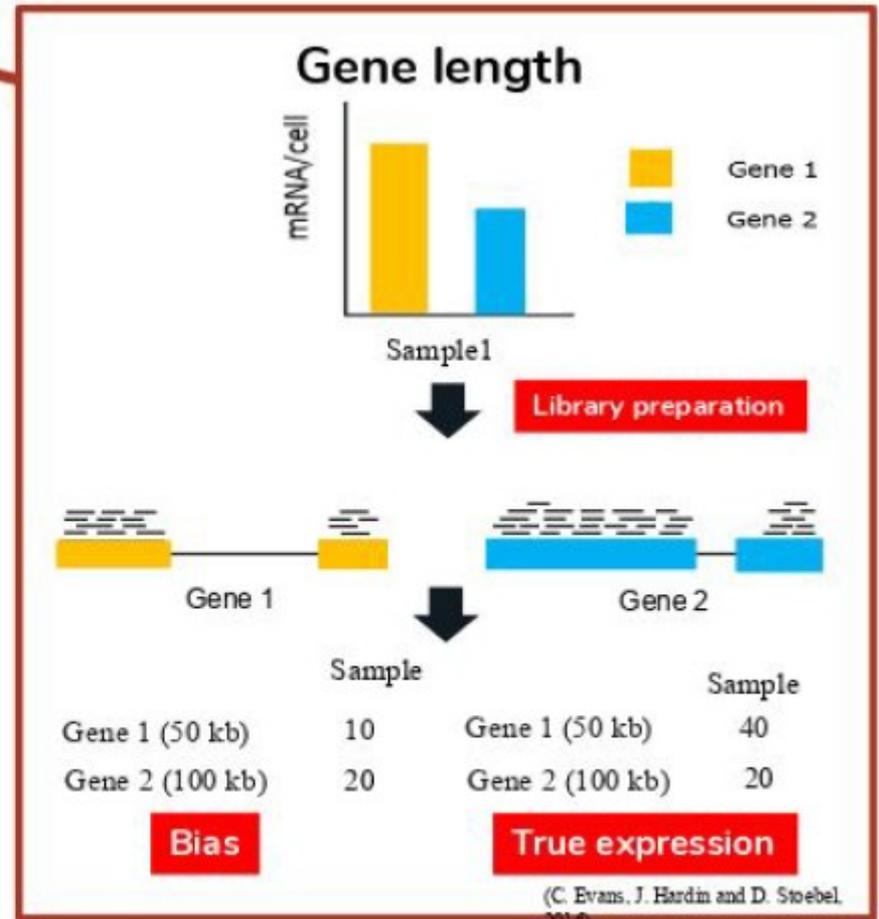
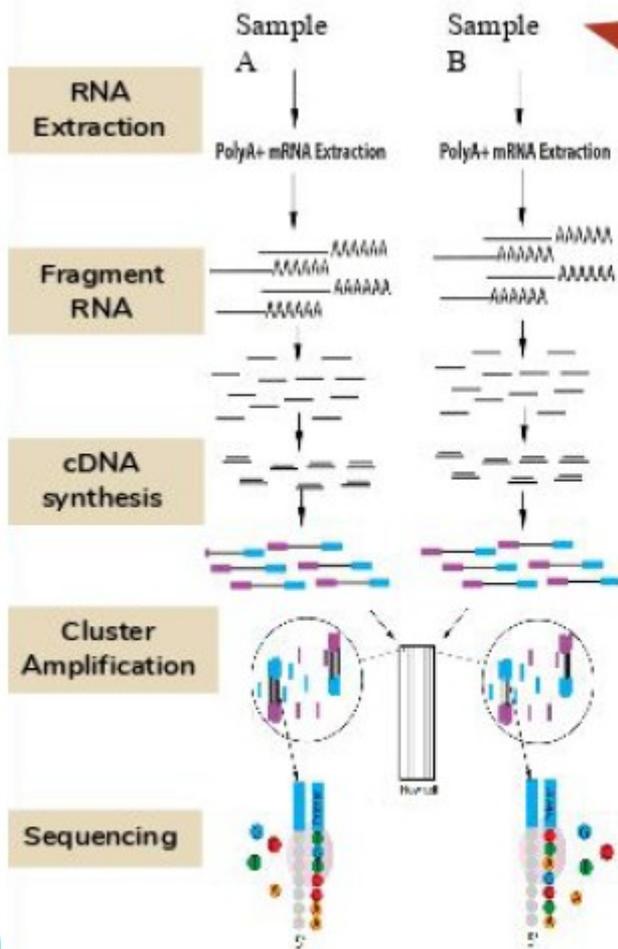
- **Identifier et corriger** les biais techniques dus au séquençage, pour les rendre comparable
  - S'assurer que les données sont exploitables
  - Réduire les biais techniques expérimentaux
  - De pouvoir comparer les données des différentes conditions entre elles
  - De s'approcher des hypothèses favorables pour l'analyse différentielle (distribution gaussienne des données)
  
- **Types de Normalisation :**
  - Intra-échantillon (même séquençage)
  - Inter-échantillon ( deux séquençage)
  
- Ce qui **influence** la normalisation:
  - Taille de la banque
  - Longueur de gènes
  - Composition en GC



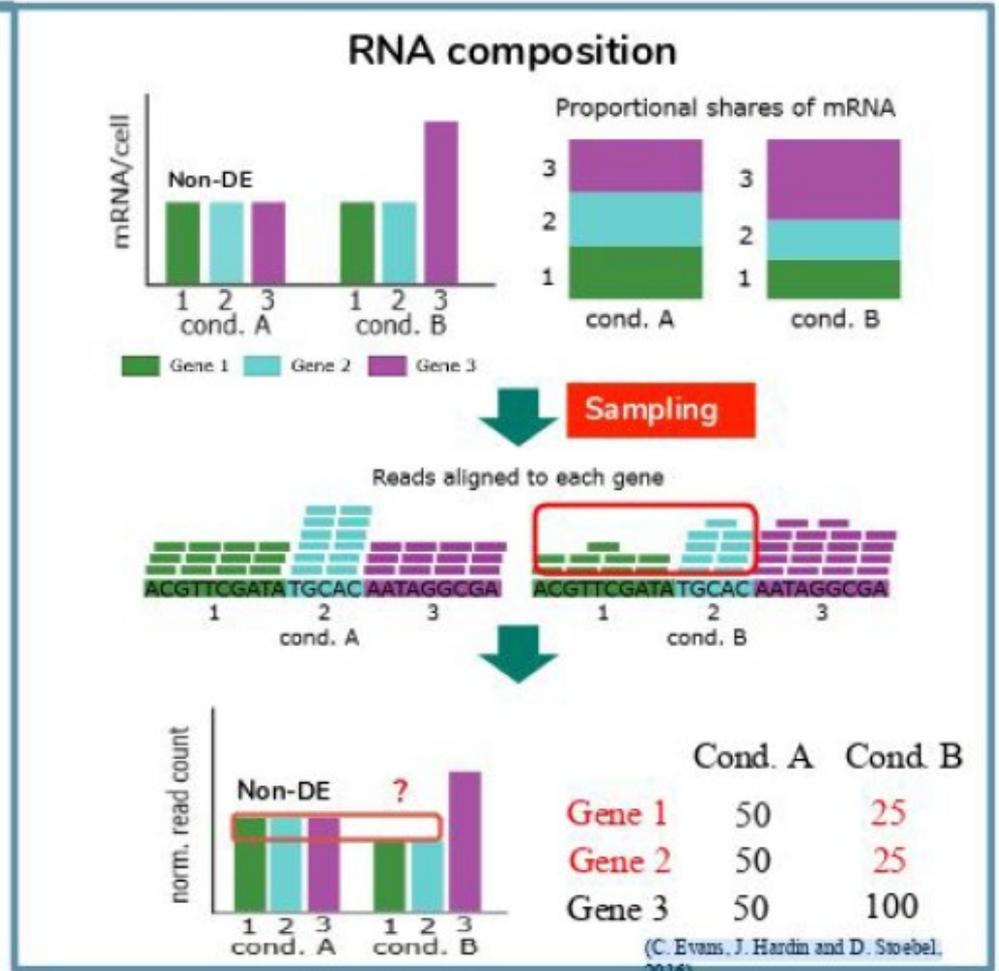
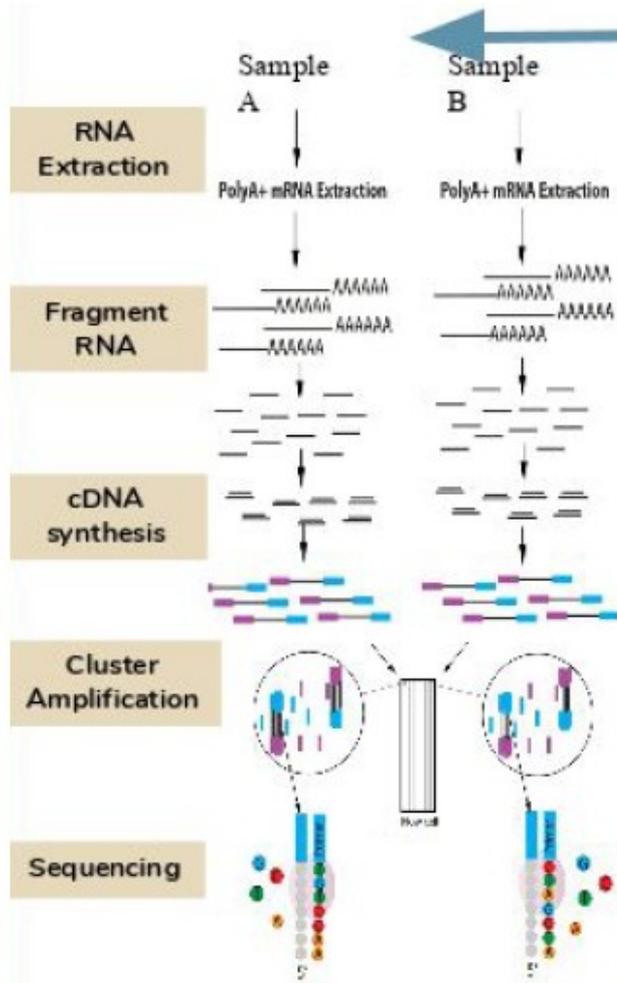
## ● Pourquoi réaliser une normalisation ?

- Entre échantillon -> Comparer le niveau d'expression d'un gène entre différent échantillons
  - Profondeur du séquençage == taille de la banque
  - Biais d'échantillonnage durant la construction de la banque == effet batch
  - Présence de fragments majoritaires == saturation
  - Composition de la séquence dûe à l'étape d'amplification PCR (composition en GC)
- Parmi les échantillons -> comparer les gènes dans un échantillon
  - Longueur des gènes
  - Composition de la séquence (GC content)

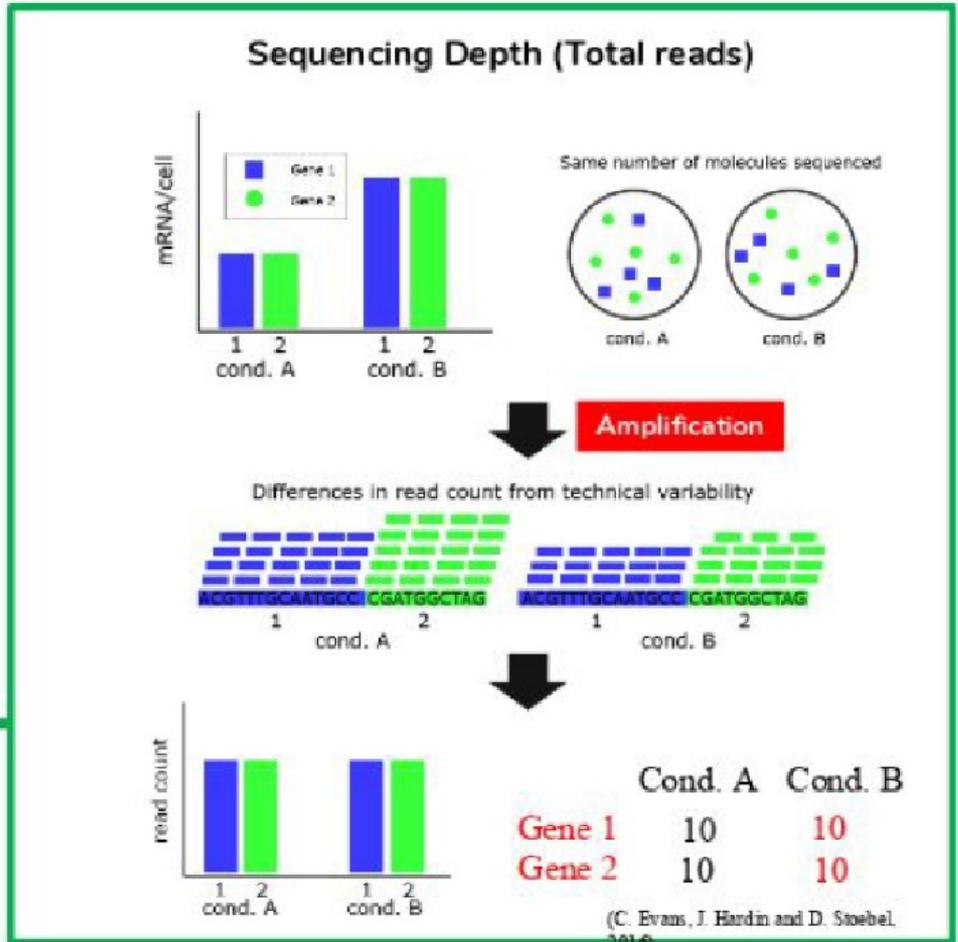
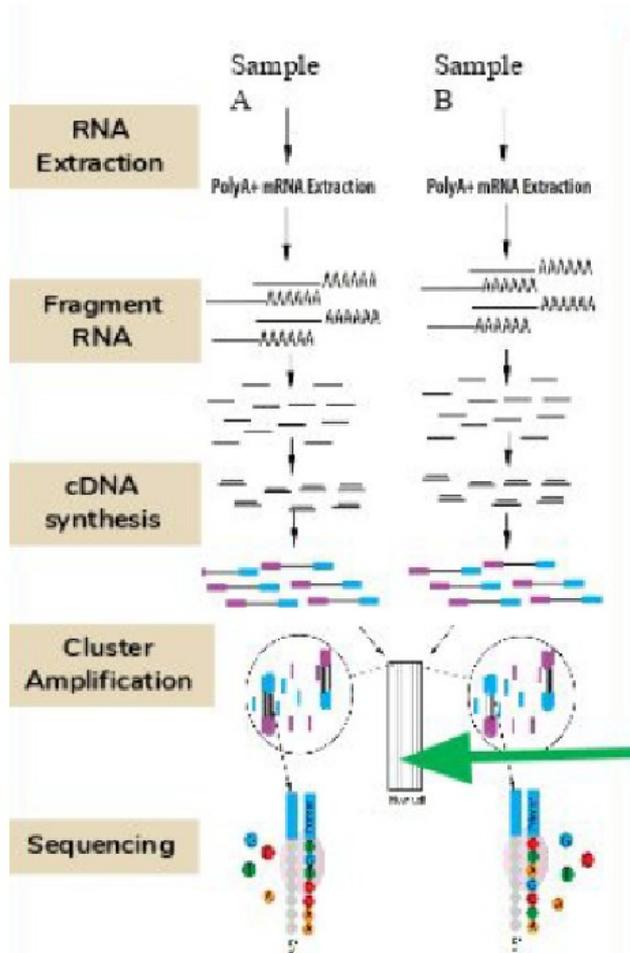




(B)



(C)



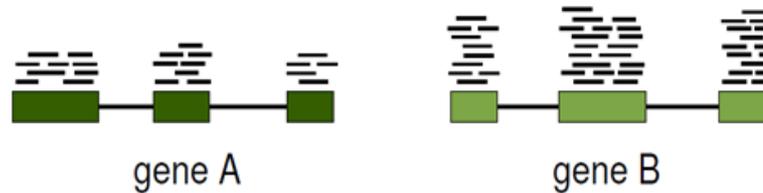
(A)

## ● Facteurs à prendre en compte avant la comparaison des conditions :

- Taille de la banque (i.e. profondeur de séquençage) qui varie entre échantillons venant de différentes lanes de la flow cell du séquenceur.
- Longueur des gènes ayant nombre important de séquences
- Composition de la banque (taille relative du transcriptome) peut être différente entre deux conditions biologiques
- Composition en GC parmi différent échantillons peut conduire à un biais d'échantillonnage des gènes (Risso et al, 2011)
- La couverture des séquences des transcrits peut être biaisée et non uniformément distribuée le long du transcrit (Mortazavi et al, 2008)

	sample 1	sample 2	sample 3
gene A	752	615	1203
gene B	1507	1225	2455

Le comptage du gène B est deux fois plus important que pour le gène A, pourquoi ?



Le nombre de transcrits pour le gène B est deux fois plus important que pour le gène A



Les deux gènes ont le même nombre de transcrits, mais le gène B est deux fois plus long que le gène A.



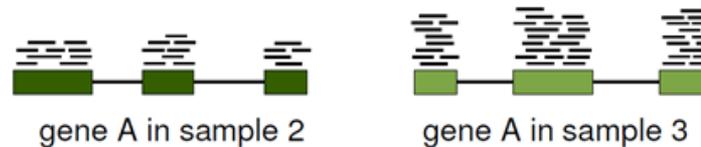
- Permettre la comparaison de gènes pour un même échantillon.
- Les sources de variabilités : longueur du gène et composition en GC.

	sample 1	sample 2	sample 3
gene A	752	615	1203
gene B	1507	1225	2455

Le comptage dans l'échantillon 3 est plus important que dans l'échantillon 2.



Le gène A est plus exprimé dans l'échantillon 3 que dans le 2.



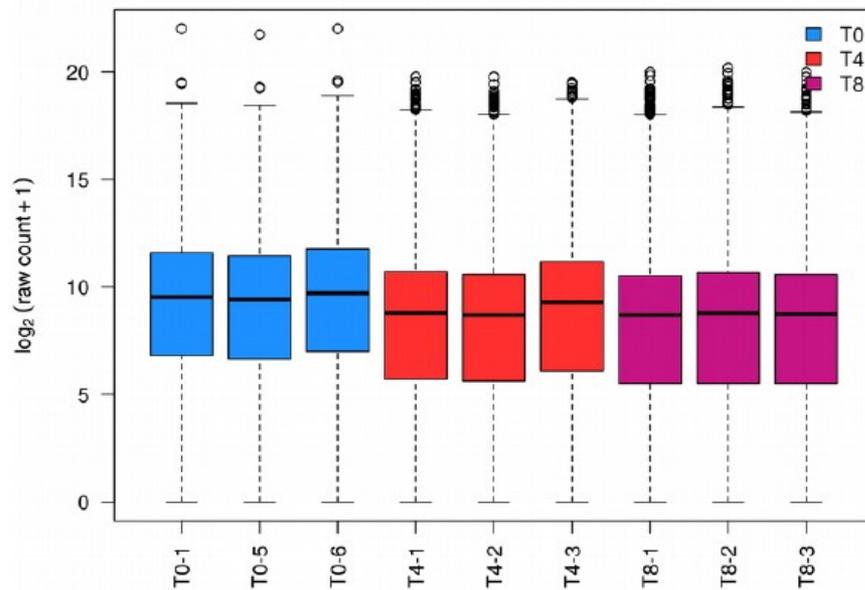
Le gène A est exprimé dans les échantillons 2 et 3, mais la profondeur de séquençage est plus importante dans l'échantillon 3 que dans le 2 (différences de taille des bibliothèques).



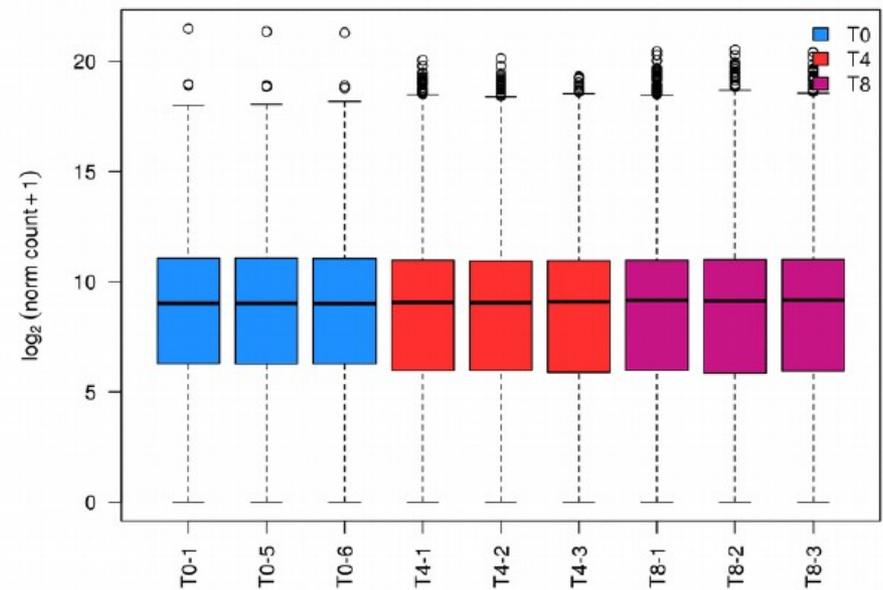
- Permettre la comparaison de gènes pour différents échantillons.
- Les sources de variabilités : taille des bibliothèques

## Effet de la normalisation : Variance des banques RNAseq avant et après normalisation

Raw counts distribution



Normalized counts distribution



## Méthodes de Normalisation Intra-banques

Objectif : calculer un facteur d'échelle appliqué à chaque banques

- **Total Count (TC)** : On divise chaque nombre de reads par le nombre total de reads (c'est-à-dire la taille de la banque) et on multiplie par le nombre moyen de reads des banques.
- **Upper Quartile (UQ)** :
  - **Objectif** : On applique la méthode TC en remplaçant le nombre total de reads par le 3<sup>ième</sup> quartile des comptes différents de 0.
    - Normalisation moins sensible aux valeurs extrêmes
    - Normalisation plus robuste, notamment dans le cas où plusieurs genes très abondants sont différenciellement exprimés.
- **Reads Per Kilobase per Millions (RPKM)** :
  - **Objectif** : réaliser une normalisation qui tient compte de la taille de la banque (par une méthode de type Total Count) et de la longueur des genes.
    - Mélange normalisation inter et intra banque
    - Permet de comparer les genes entre eux mais inadaptée pour comparer 2 conditions sur un même gene.

## Méthodes de Normalisation Intra-banques

Objectif : calculer un facteur d'échelle appliqué à chaque banques

### ● **TMM** : Trimmed Mean of M-values

- TMM normalization method Considère que la plupart des gènes ne sont pas différentiellement exprimés.
- TMM normalise l'output totale d'ARN parmi les échantillons et ne tient pas compte de la longueur du gène ou de la taille de la bibliothèque pour la normalisation.
- Le TMM sera un bon choix pour éliminer les effets de lot tout en comparant les échantillons de différents tissus ou génotypes ou dans les cas où la population d'ARN serait significativement différente parmi les échantillons.
- TMM is implemented in edgeR and performs better for between-samples comparisons
- edgeR does not consider gene length for normalization as it assumes that the gene length would be constant between the samples

### ● **RLE** : Relative Log Expression (RLE) : Semblable à TMM, cette méthode de normalisation est basée sur l'hypothèse que la plupart des gènes ne sont pas DE. Pour un échantillon donné, le facteur d'échelle RLE est calculé comme la médiane du rapport, pour chaque gène, de son nombre de lectures sur sa moyenne géométrique sur tous les échantillons.

## Méthodes de Normalisation Intra-banques

Objectif : calculer un facteur d'échelle appliqué à chaque banques

- **Méthode Total Count (TC) => Peu efficace**
  - Pas de prise en compte des différences possibles entre les compositions en ARN des conditions.
- **Méthode RPKM => Peu efficace**
  - Même dans le cas où un biais lié à la longueur des gènes existe, l'utilisation du RPKM ne permet pas de le corriger complètement.
- **Méthode à Privilégier => Upper-Quartile, RLE, TMM**
  - Même dans le cas où un biais lié à la longueur des gènes existe, l'utilisation du RPKM ne permet pas de le corriger complètement.

## Méthodes de Normalisation Intra-banques Les biais techniques

- **Effet de la Taille de la Banque :**

- Deux échantillons de même composition en ARN.
  - Une banque pour chaque échantillon
  - Banque A : 2 781 315 reads
  - Banque B : 2 254 901 reads
  - On aura donc artificiellement 1,2334 fois plus de reads dans A que dans B
  - Pourtant les quantités “réelles” sont identiques
  - Biais de la Taille de la banque

- **Effet de la Longueur des Gènes:**

- Pour un même niveau d'expression.
  - Un long transcrits est plus facilement séquencé
  - Donc plus de reads
  - Il sera plus facilement mis en evidence en DE
  - Corriger le Bias

# **5- Choix de la méthode de normalisation**

Méthodes de Normalisation intra –  
banque

RLE , TMM, Upper-  
Quartile

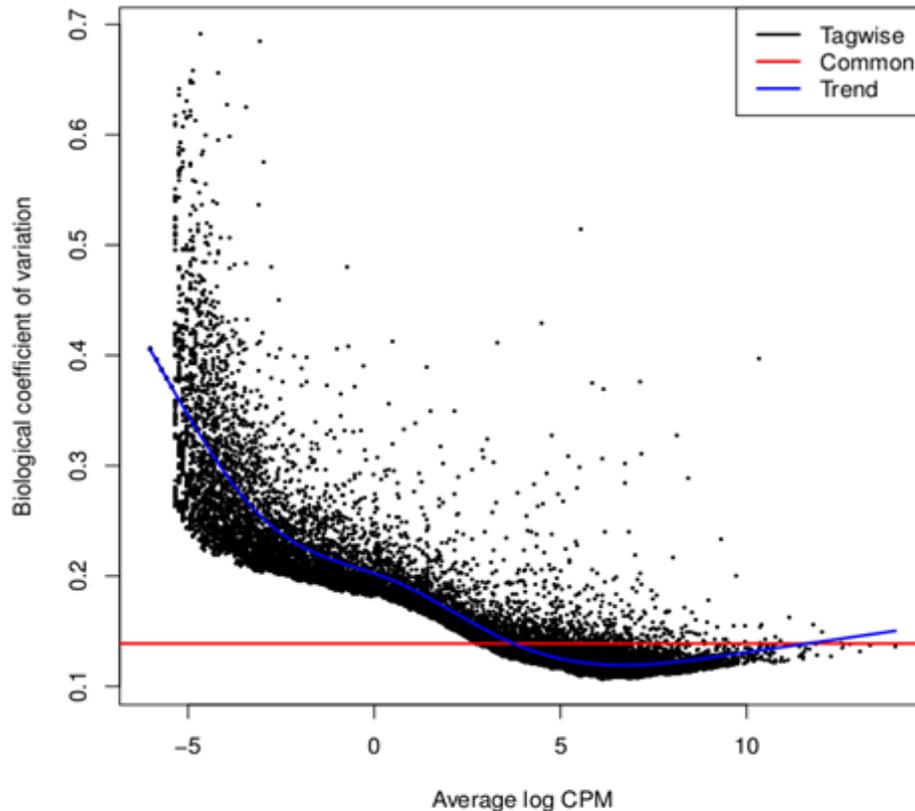
Correction par la variance

Loi binomiale négative

Edge R , DESeq



## EdgeR



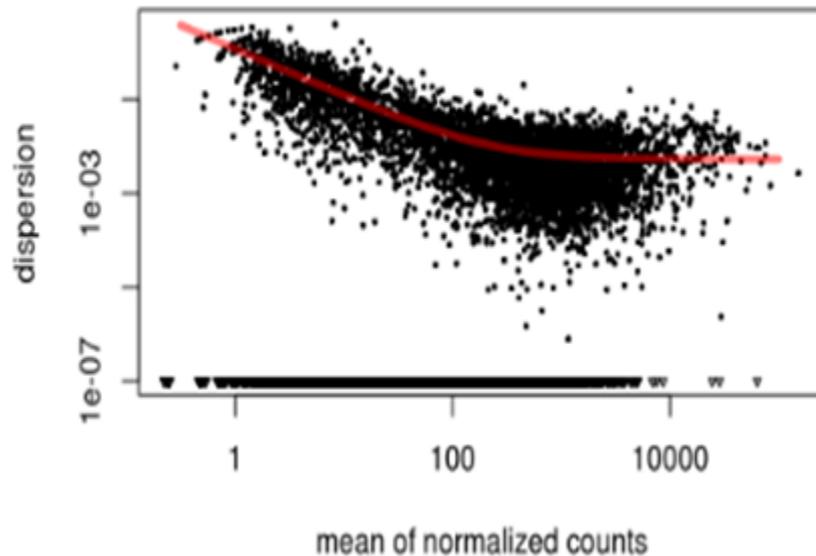
Estimation de la dispersion  
(entre réplicats biologiques)

- utilisation de la valeur individuelle (« tagwise ») ou de la valeur ajustée « trend » ou « common » pour le calcul des tests statistiques de DE

- Utiliser la méthode « tagwise » lorsqu'on a au moins 4 réplicats
- Utiliser la méthode commune lorsqu'on a peu de réplicats (2 ou 3)

=> Utilisation de ces valeurs de dispersion pour le calcul des tests statistiques de DE (p-value)

## DESeq



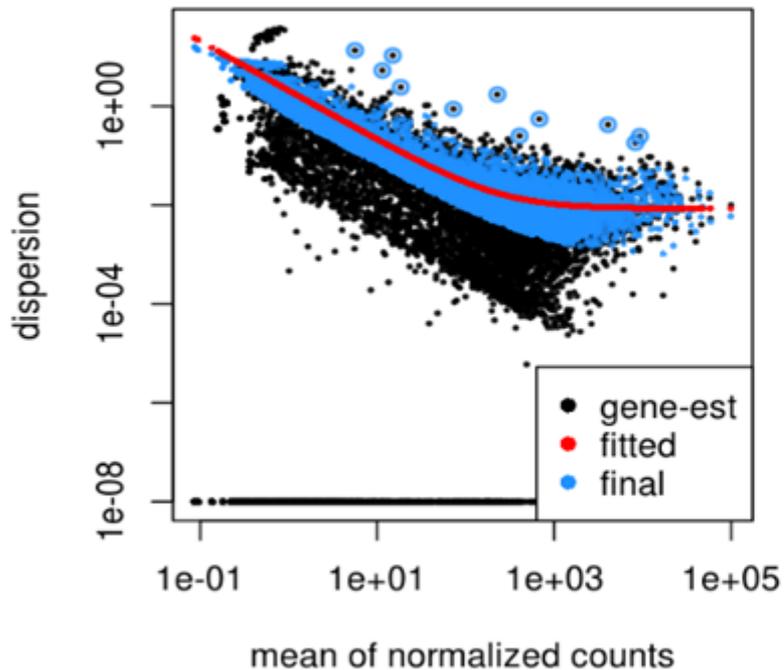
### Estimation de la dispersion

- utilisation de la valeur ajustée pour les transcrits dont l'estimateur individuel (en noir) inférieur à la valeur ajustée
- utilisation de la valeur individuelle pour les transcrits dont l'estimateur individuel est supérieur à la valeur ajustée

=> Utilisation de ces valeurs de dispersion pour le calcul des tests statistiques de DE (p-value)

=> Plus sensible à la dispersion des données

## DESeq2



### Estimation de la dispersion

- utilisation d'une valeur intermédiaire (en bleu) entre la dispersion individuelle (en noir) et la dispersion ajustée (en rouge)
- utilisation de la dispersion individuelle si celle-ci est considérée comme extrême par rapport à la distribution globale (points entourés de bleu)

=> Utilisation de ces valeurs de dispersion pour le calcul des tests statistiques de DE (p-value)

## Comparaison des outils

Objectif : Choisir l'outil le plus adapté

- **DESeq** utilise une estimation de la variance qui la rend moins permissive pour les grandes variabilités entre conditions.
  - Dès qu'au moins l'une des conditions présente une variabilité importante, la méthode ne fait pas confiance à ce gène et ne va pas le considérer comme différentiellement exprimé.
  - En revanche, quand la variabilité intra-conditions est plus faible, DESeq fait plus confiance et sélectionne même les gènes qui ont un fold-Change plus faible que ceux sélectionnés par EdgeR.
  - DESeq est à privilégier pour des expérimentations très répétables.
- **DESeq2** est plus souple, moins stringent et il détectera plus de gènes différentiellement exprimés.

# Practice : DIANE

[TP Diane](#)

Data:

\* ref : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3488244/>

\* data : NCBI SRA database under accession number SRS307298 *\_S. cerevisiae\_*.

Genome size of *\_S. cerevisiae\_* : 12M (12.157.105)

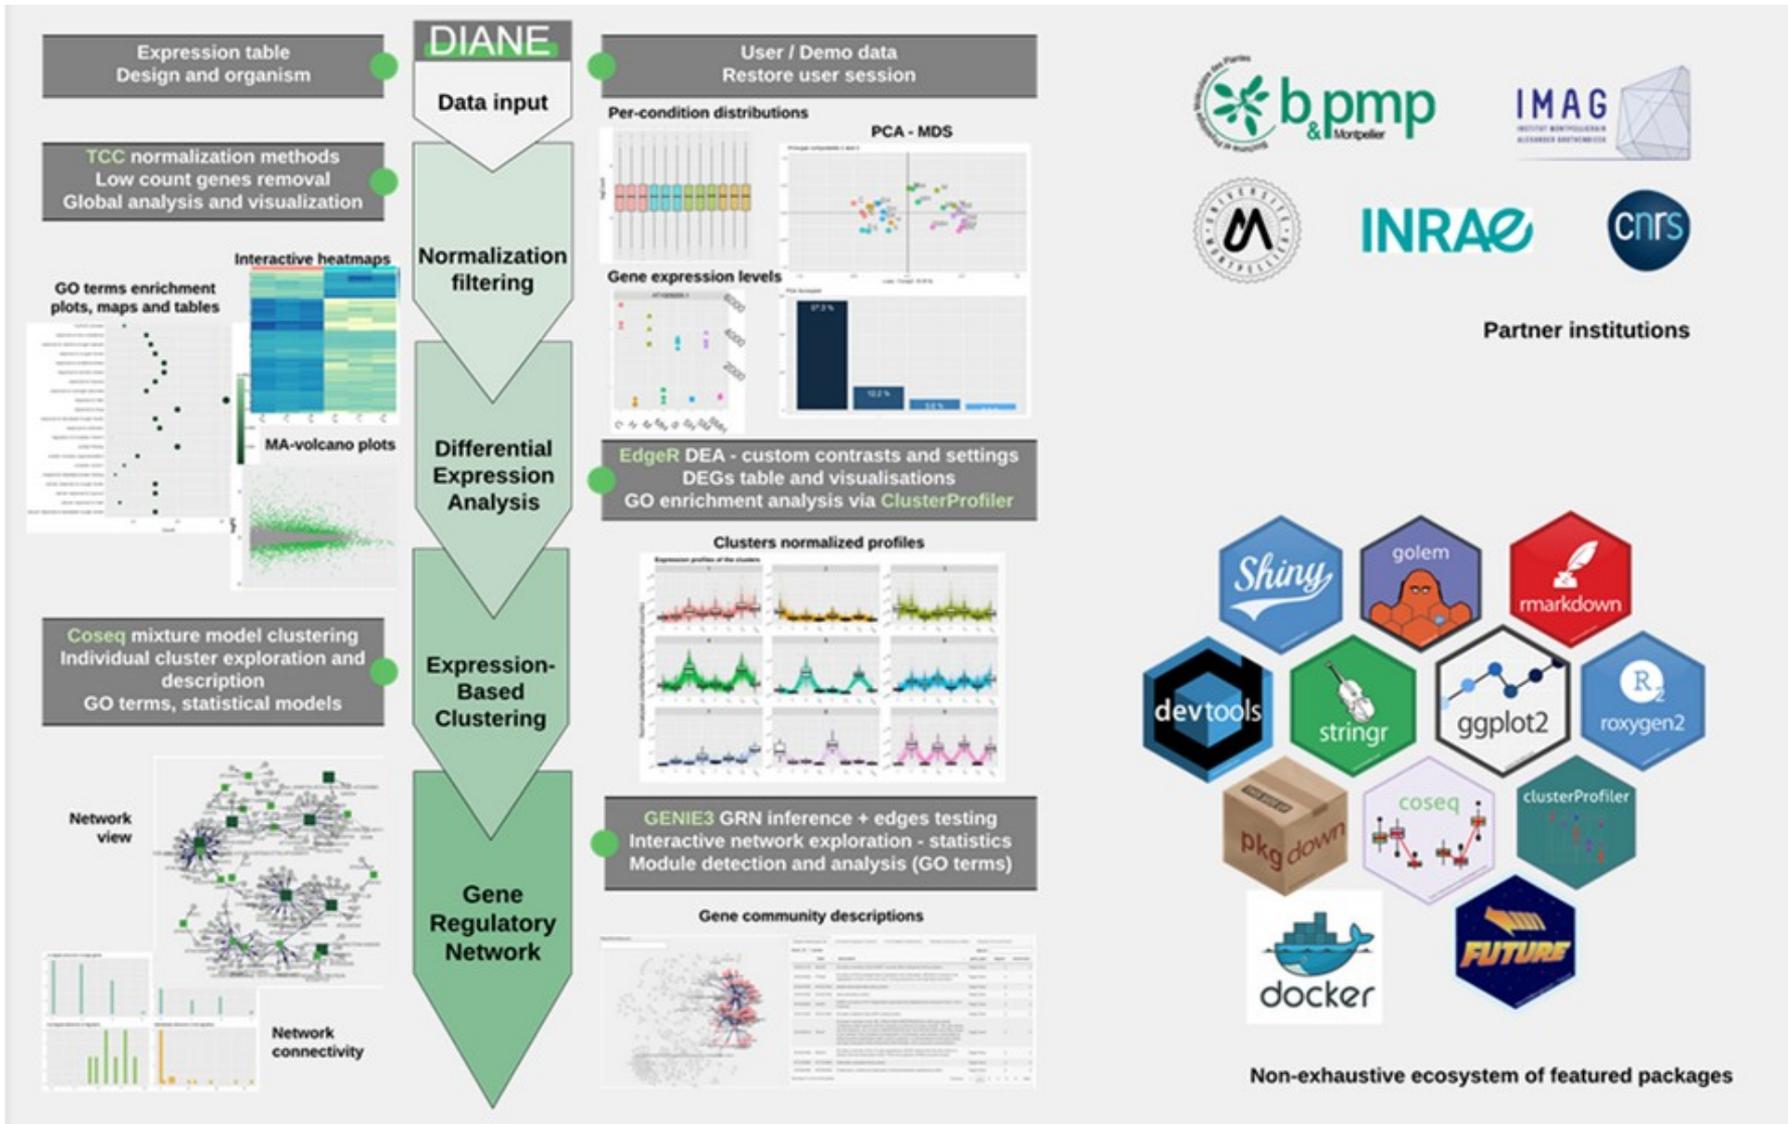
([https://www.yeastgenome.org/strain/S288C#genome\\_sequence](https://www.yeastgenome.org/strain/S288C#genome_sequence))

Outils :

DIANE : (<https://diane.bpmp.inrae.fr/>)

- Après avoir aligné les séquences contre la référence de *Saccharomyces cerevisiae* déterminer une liste de gènes différentiellement exprimés entre les conditions batch et CENPK.
  - Vous avez à votre disposition la matrice reads counts.
  - Etape 1 Normalisation :
    - Quelle est l'influence de la méthode de normalisation ,
      - tmm,
      - Deseq2
      - aucune normalization.
  - Etape 2 Analyse différentielle avec DIANE
  - Etape 3 Générer une liste et des graph, MA plot , volcano plot et Heatmap.

# Practice DIANE Tools Presentation



To cite DIANE in publication use:

Cassan, O., Lèbre, S. & Martin, A. Inferring and analyzing gene regulatory networks from multi-factorial expression data: a complete and interactive suite. *BMC Genomics* 22, 387 (2021). <https://doi.org/10.1186/s12864-021-07659-2>

# Practice : DIANE Import Data

**DIANE**

Context

**Data import** ← add expression data and experimental design

Normalisation

Exploratory analysis

Differential Expression

Expression based clustering

Run a clustering

Explore clusters

Gene Regulatory Network

Network inference

Network analysis

Ready to upload datasets

Legal mentions

Software versions

**Expression file upload**

Demo Arabidopsis data

Toggle to import your data

Expected gene IDs are in the form  
**No gene ID requirement**  
FOR OTHER.

Your organism :  
Other

Separator :  
 Comma  Semicolon  Tab

Choose CSV/TXT expression file ?  
Browse... count\_table.txt

Separator :  
 Tab

Choose CSV/TXT gene information file (optional) ?  
Browse... No file selected

Other ORGANISM DATABASE

Seed ensuring reproducibility (optional, can be left as default value) :  
34

CHANGE SEED SET SEED

**Preview of the expression matrix**

This might help you visualize the general aspect of the data and different sequencing depths of your conditions.

**Design and gene information files**

Separator :  
 Comma  Semicolon  Tab

Choose CSV/TXT design file (optional)  
Browse... No file selected

Describe the levels of each factors for your conditions

← Reads\_count.csv

← GeneInformation

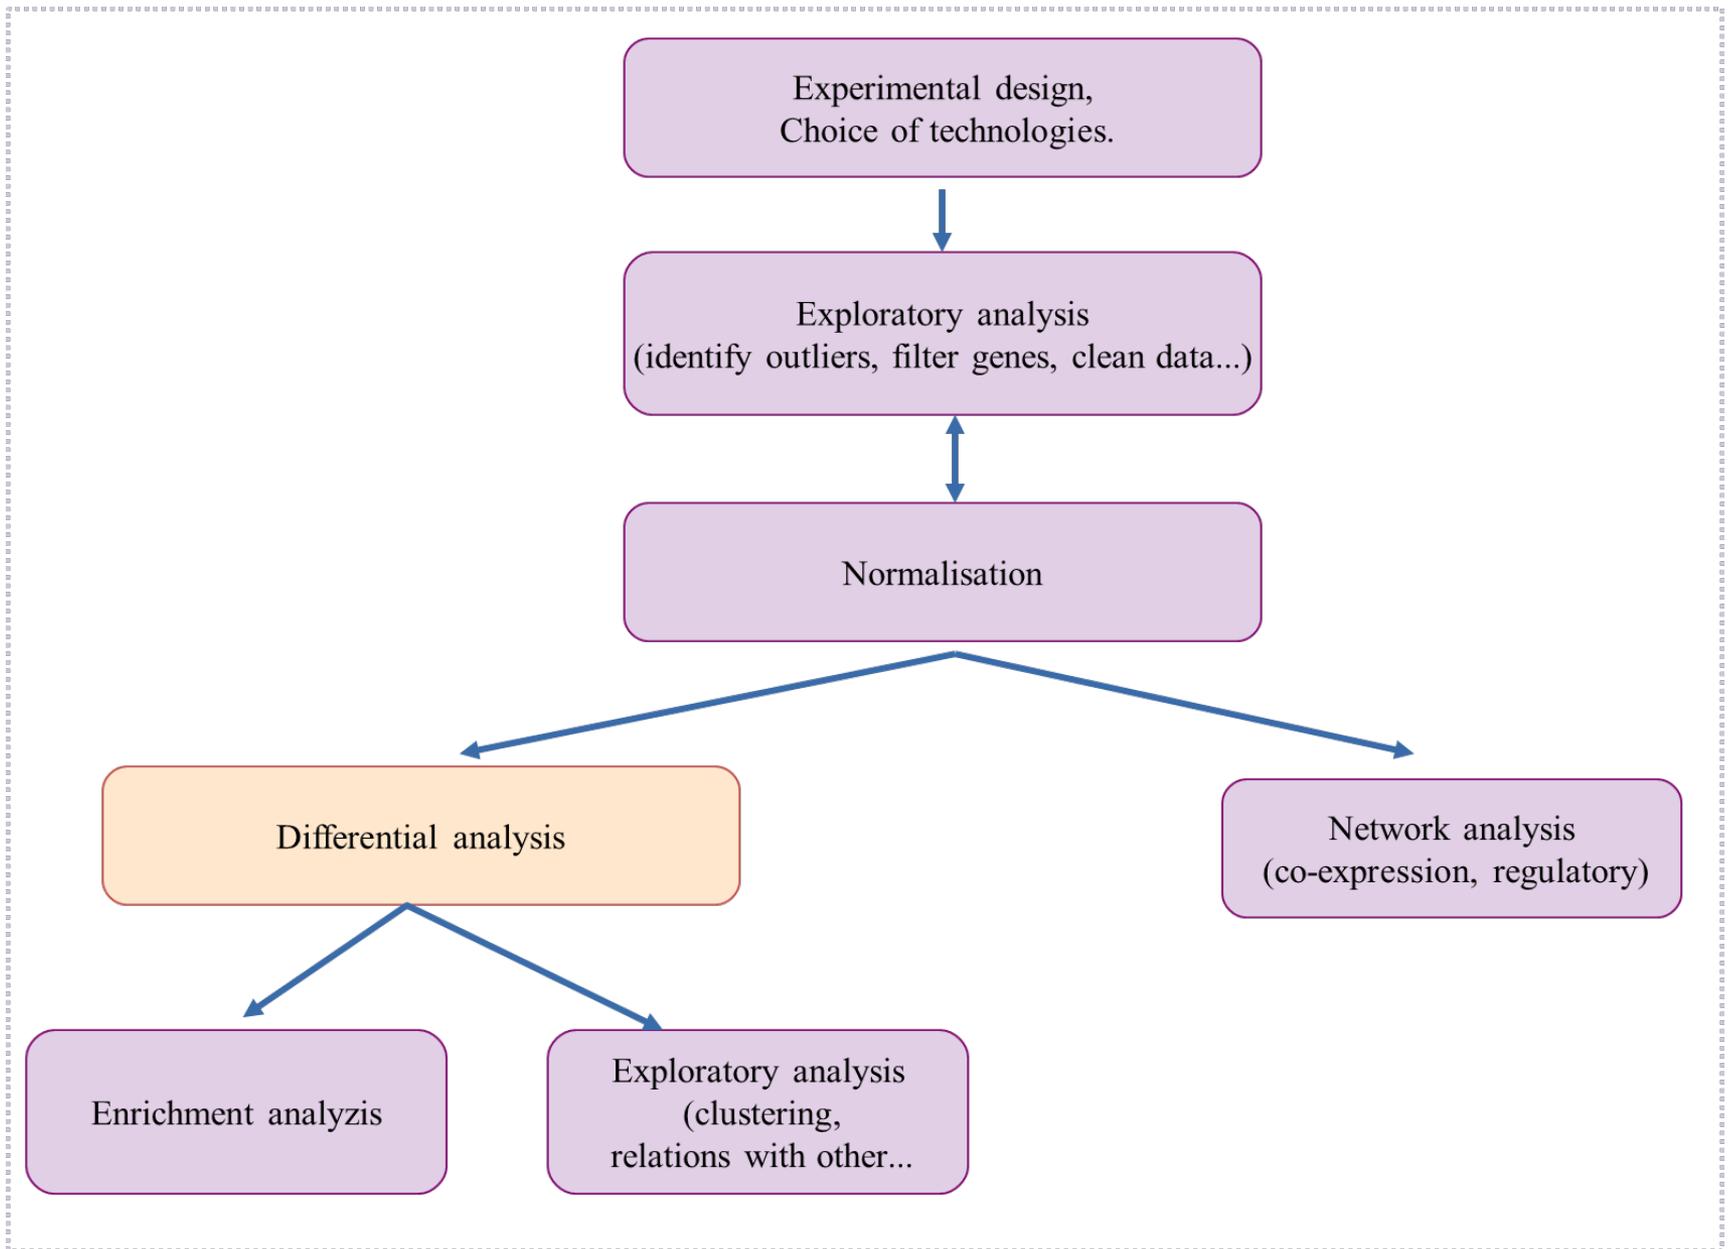
↑ Designed.csv

# DIANE Normalisation Filtration

The screenshot displays the DIANE web interface for data filtering and normalization. The interface is divided into several sections:

- Navigation Sidebar:** Located on the left, it includes options like Context, Data import, Normalisation (highlighted with a red arrow), Exploratory analysis, Differential Expression, and Expression based clustering.
- Settings Panel:** Contains two main sections:
  - Normalization:** Features a toggle for 'Prior removal of differentially expressed genes' (set to ON), a 'Normalization method' dropdown (set to tmm), and a 'NORMALIZE' button. A red arrow points to this section.
  - Low counts filtering:** Includes a 'Minimal gene count sum across conditions' input (set to 60) and a 'FILTER' button. A red arrow points to this section. Below the filter, it shows '6420 genes before filtering' and '5628 genes after filtering'. Download buttons for '.CSV' and '.RDATA' formats, and a 'GENERATE HTML REPORT' button are also present.
- Visualization:** A boxplot titled 'Per-condition expression distributions' showing log<sub>2</sub> expression levels across six samples: Batch\_1, Batch\_2, Batch\_3, CENPK\_1, CENPK\_2, and CENPK\_3. The y-axis ranges from 0.0 to 10.0. The legend indicates 'Batch' (red) and 'CENPK' (teal). A red arrow points to the CENPK\_2 sample.

## **6- Recherche de gènes différentiellement exprimés**





Rappel : définition du Fold-Change :

$$FC = \frac{\text{expression condition } V}{\text{expression condition } G}$$

Gene	V1	V2	V3	G1	G2	G3	FC	<i>p</i> -valeur
Gene1	5	7	6	2	2	2	3	0.06
Gene2	800	1000	900	350	250	200	3	0.03
Gene3	700	900	1100	350	200	250	3	0.10
Gene4	900	500	1300	200	550	50	3	0.06
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

● **p-value** : risque/probabilité de déclarer un gène différentiellement exprimé alors qu'il ne l'est pas.

● **Ho** : le gène g a un niveau d'expression constant

● P-value de 0.05= on autorise qu'un gène ait 5% de risque d'être appelé DE alors qu'il ne l'est pas

● **Problème des tests multiples**: si on teste 10000 gènes non différentiellement exprimés, on autorise 500 gènes à être déclarés DE alors qu'ils ne le sont pas

=> **nécessité de filtrer au préalable les gènes** (ex: niveau total d'expression < 10) pour limiter le nombre de tests

=> **Plus on augmente le nombre de tests , plus on a de chance de décider qu'un gène est différentiellement exprimé alors qu'il ne l'est pas.**

=> **besoin de correction** et utiliser une p-value ajustée adaptée aux tests multiples:

- procédure de Benjamini-Hochberg (BH) qui consiste à contrôler le False Discovery Rate (**FDR**), c'est à dire la proportion de faux positifs dans les gènes déclarés différentiellement exprimés
- procédure de Bonferroni (+ stringent)

- **Erreur de 1ere espèce (Type 1 error):**

- Probabilité  $\alpha$  de rejeter  $H_0$  alors qu'elle est vraie
- Probabilité de décider qu'un gène est différentiellement exprimé alors qu'il ne l'est pas.
- **Faux positif**

- **Erreur de 2eme espèce (Type 2 error):**

- Probabilité  $\beta$  de rejeter  $H_0$  alors qu'elle est fausse
- Probabilité de décider qu'un gène n'est pas différentiellement exprimé alors qu'il l'est.
- **Faux négatif**

- **Conséquence :**

- En testant les 20000 gènes avec  $\alpha = 5\%$
- **On s'attend à obtenir 20000 x 0,05 faux positifs soit 1000 gènes qui ne sont en réalité pas différentiellement exprimés.**

Situation	Décision	
	accepter $H_0$	rejeter $H_0$
$H_0$ vraie	$1-\alpha$	$\alpha$
$H_0$ fausse (diff. expr.)	$\beta$	$1-\beta$

## ● **Filtre = risque**

- Le nombre est la valeur seuil que nous mesurons contre la p-value.
  - Elle indique à quel point les résultats observés doivent être extrêmes pour rejeter l'hypothèse nulle d'un test significatif
  - Ex
- ⇒ Résultat avec un niveau de 90% de niveau de confiance , alpha est  $1 - 0,90 = 0,10$
- ⇒ Résultat avec un niveau de 95% de niveau de confiance , alpha est  $1 - 0,95 = 0,05$
- ⇒ Résultat avec un niveau de 99% de niveau de confiance , alpha est  $1 - 0,99 = 0,01$
- ⇒  $\alpha > p\text{-value}$  Ho Rejetée

- False Discovery Rate (FDR)**

- Principe** : ajuster le seuil  $\alpha$  en fonction des résultats observés (p-value obtenues)
- M tests ayant des p-value  $p_1 \dots p_m$  triées par ordre croissant
- Pour un seuil  $\alpha$  trouver le plus grand  $k$  tel que  $P_k \leq \frac{k}{m}\alpha$  et déclarer les gènes  
1 à  $k$  différentiellement exprimés

	$R_1$	$R_2$	$G_1$	$G_2$	p-value	$\alpha * k/m$
267628_at	441.8	431.5	347.2	375.2	0.036937	<b>0.01</b>
267629_at	226.5	205.6	185.2	175.9	0.090013	0.02
267630_at	1142.6	1080.7	1019.8	1018.6	0.096209	0.03
267627_at	57	6	45.5	38.6	0.721558	0.04
267631_at	77.7	58	84.4	57.4	0.872008	0.05

- Ici **aucun gène** n'est déclaré différentiellement exprimé pour  $\alpha = 0,05$

# Practice : DIANE

[TP Diane](#)

# Practice Expression différentielle DIANE

The screenshot displays the DIANE web interface for differential expression analysis. The left sidebar contains navigation options, with 'Differential Expression' highlighted. The main panel is titled 'Differential expression analysis' and includes a 'Settings' section on the left and a 'Results table' on the right. The 'Settings' section allows users to define reference and perturbation conditions, set an adjusted p-value (FDR) of 0.05, and an absolute log fold change of 1. The 'Results table' shows a list of genes with columns for logFC, logCPM, FDR, and Regulation. A summary section below the table indicates 820 up-regulated genes and 583 down-regulated genes. A 'DOWNLOAD RESULT TABLE AS .TSV' button and a 'GENERATE HTML REPORT' button are also visible.

## Differential expression analysis

Settings

Conditions to compare for differential analysis :

Reference	Perturbation
<input checked="" type="checkbox"/> Batch	<input type="checkbox"/> Batch
<input type="checkbox"/> CENPK	<input checked="" type="checkbox"/> CENPK

Adjusted pvalue ( FDR )  
0.05

Absolute Log Fold Change ( Log<sub>2</sub> ( Perturbation / Reference ) ) :  
1

**DETECT DIFFERENTIALLY EXPRESSED GENES**

Done ✓  
See plots and tables for more details

820 +  
up regulated  
GENES

583 -  
down-regulated  
GENES

**DOWNLOAD RESULT TABLE AS .TSV**

**GENERATE HTML REPORT**

Results table | MA - Volcano plots | Heatmap | Gene Ontology enrichment | Compare genes lists (Venn) | Results

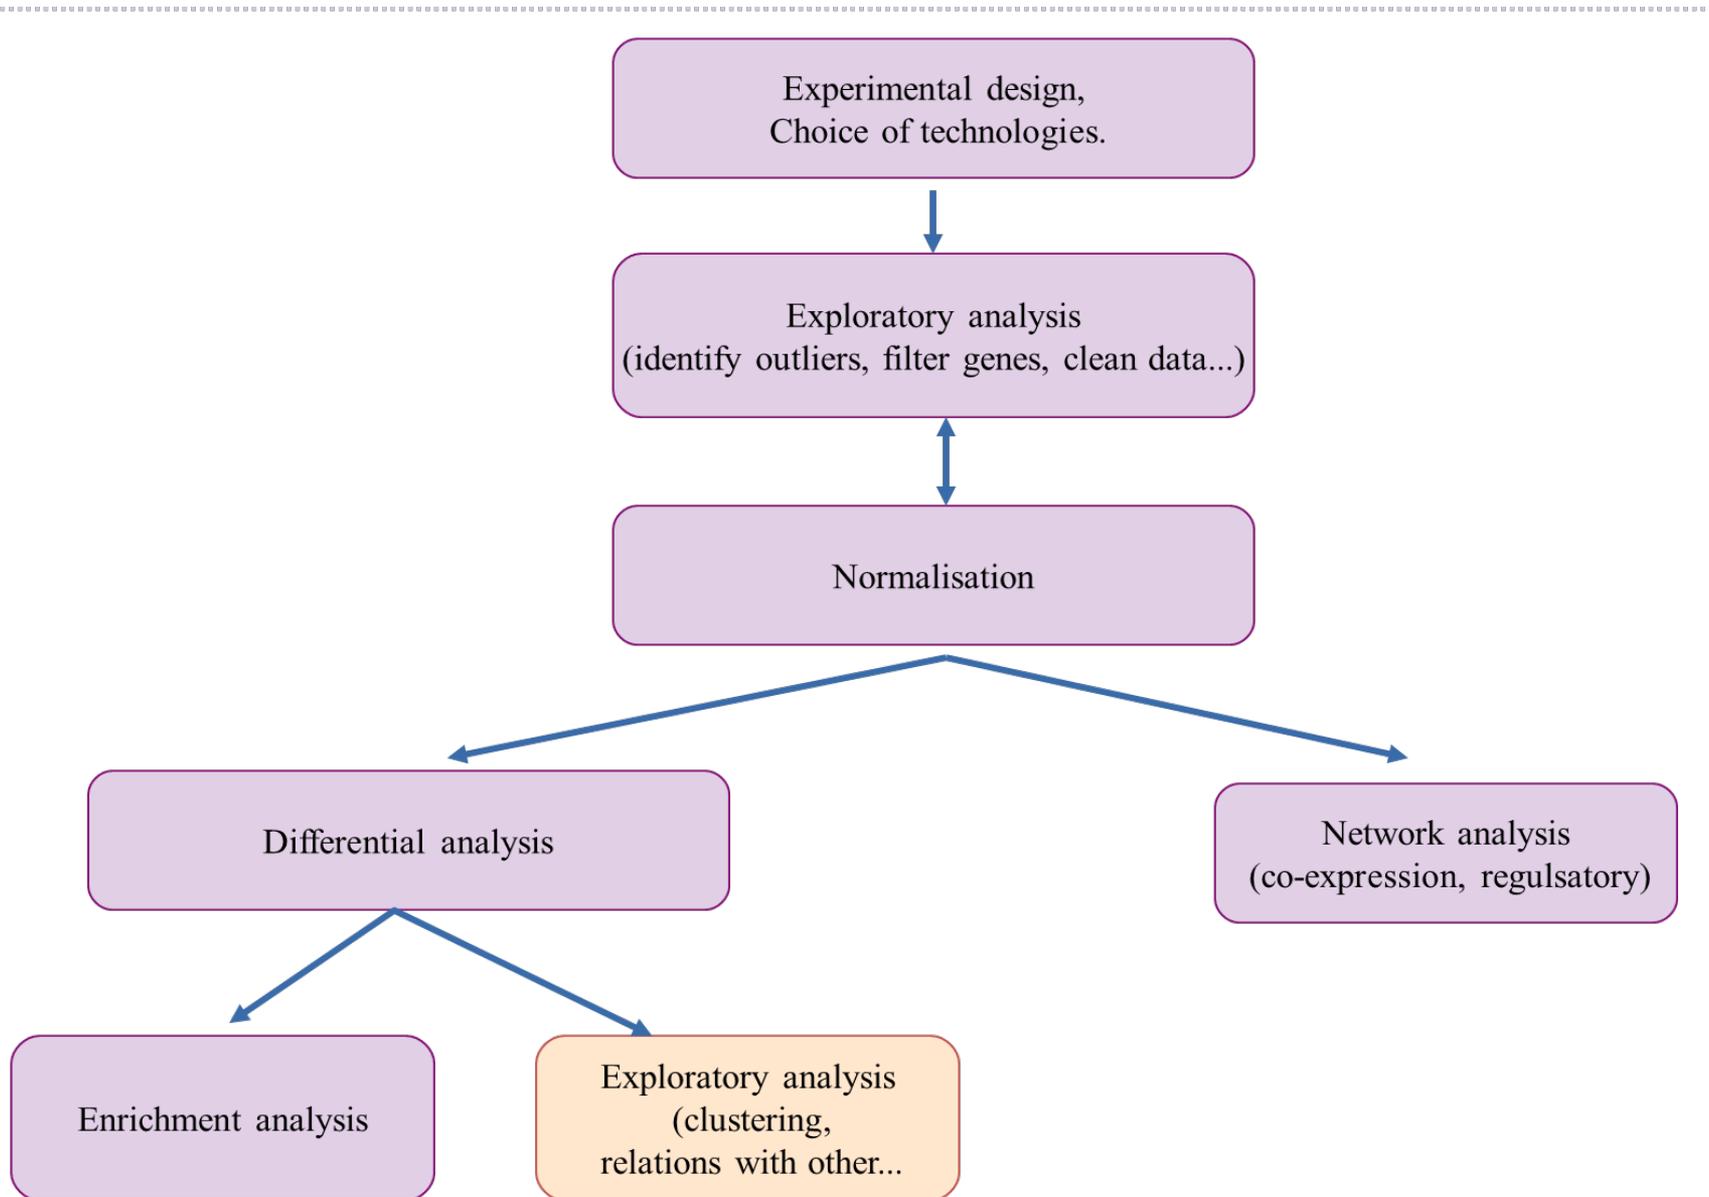
Show 10 entries

	logFC	logCPM	FDR	Regulation
YIL057C	10.76	8.602	0.000	Up
YMR107W	9.953	9.671	0.000	Up
	8.602	11.42	0.000	Up
YJK095W	8.407	7.856	0.000	Up
YMR303C	7.902	10.69	0.000	Up
YCR010C	7.094	8.400	0.000	Up
YGL205W	6.950	8.828	0.000	Up
YHR096C	6.890	9.951	0.000	Up
YAL054C	6.768	10.41	0.000	Up
YBR067C	6.734	10.29	0.000	Up

Showing 1 to 10 of 1,403 entries

Previous 1 2 3 4 5 ... 141 Next

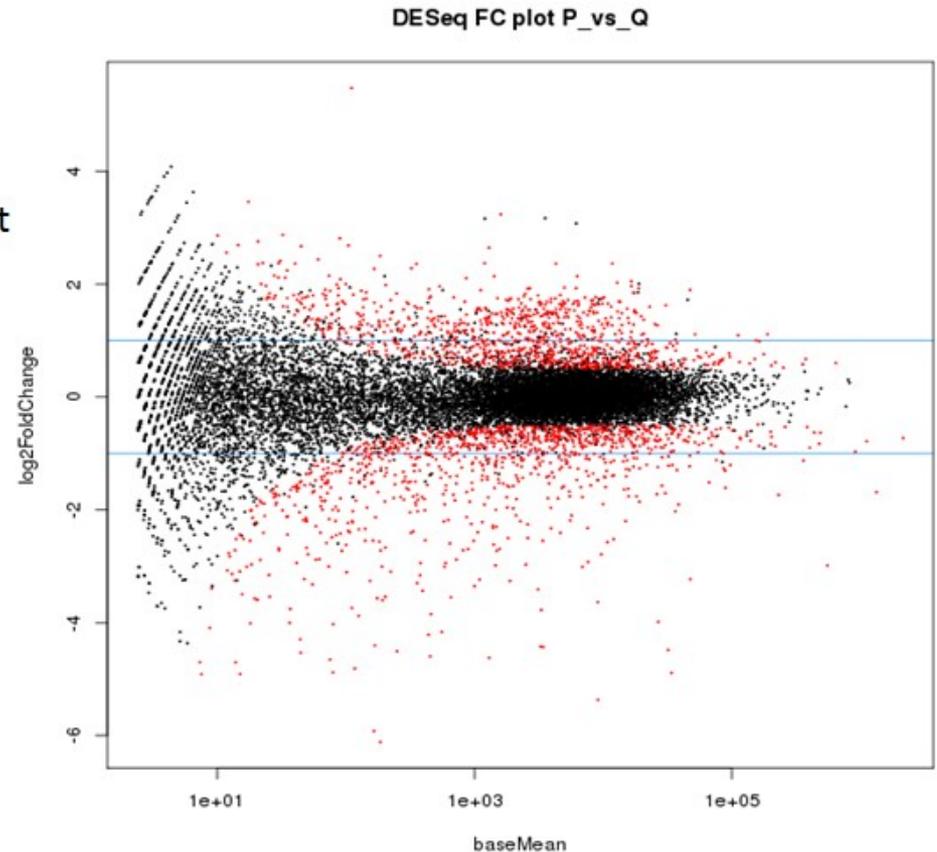
# **6- Plots and Graphical Representations**



Smear plot / MA plot  
Pvalue adj < 0.05

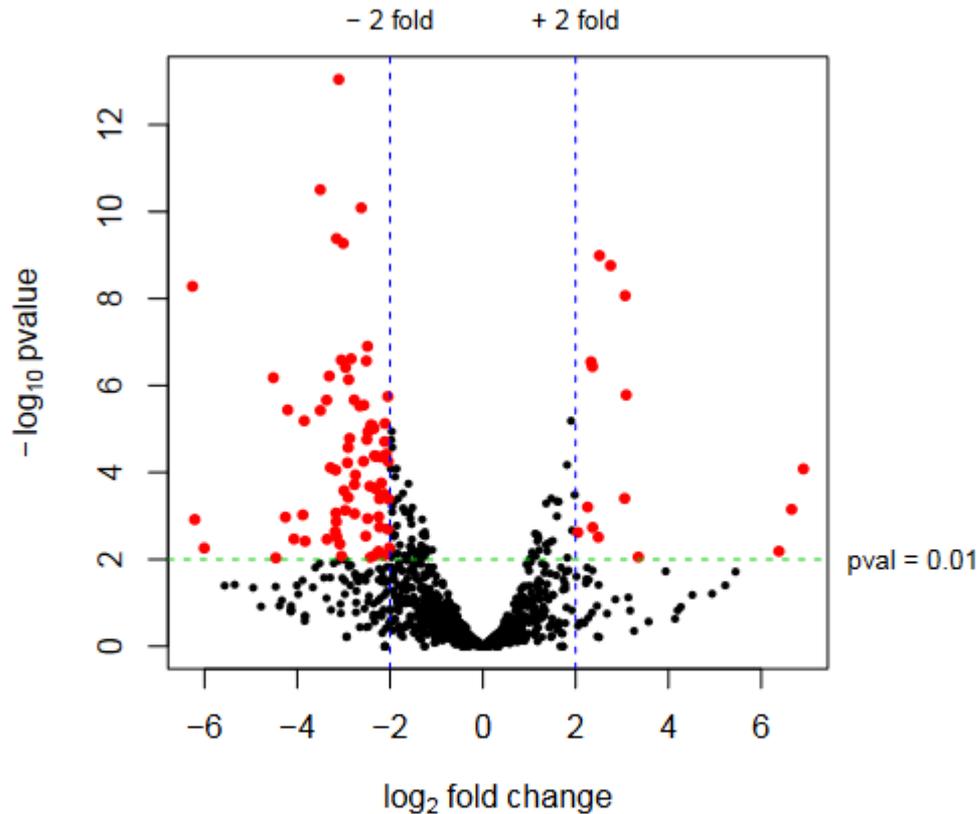
## MA plot

Le MA plot est un graphe qui était initialement utilisé dans les analyses de puce à ADN. C'est un nuage de points représentant en abscisse l'expression moyenne du gène à travers les différents échantillons, et en ordonnée le log-ratio des expressions moyennes d'une condition par rapport à l'autre. En RNA-Seq, après normalisation, on s'attend à ce que les points soient repartis symétriquement autour de 0 en ordonnée (c'est-à-dire un ratio de 1).



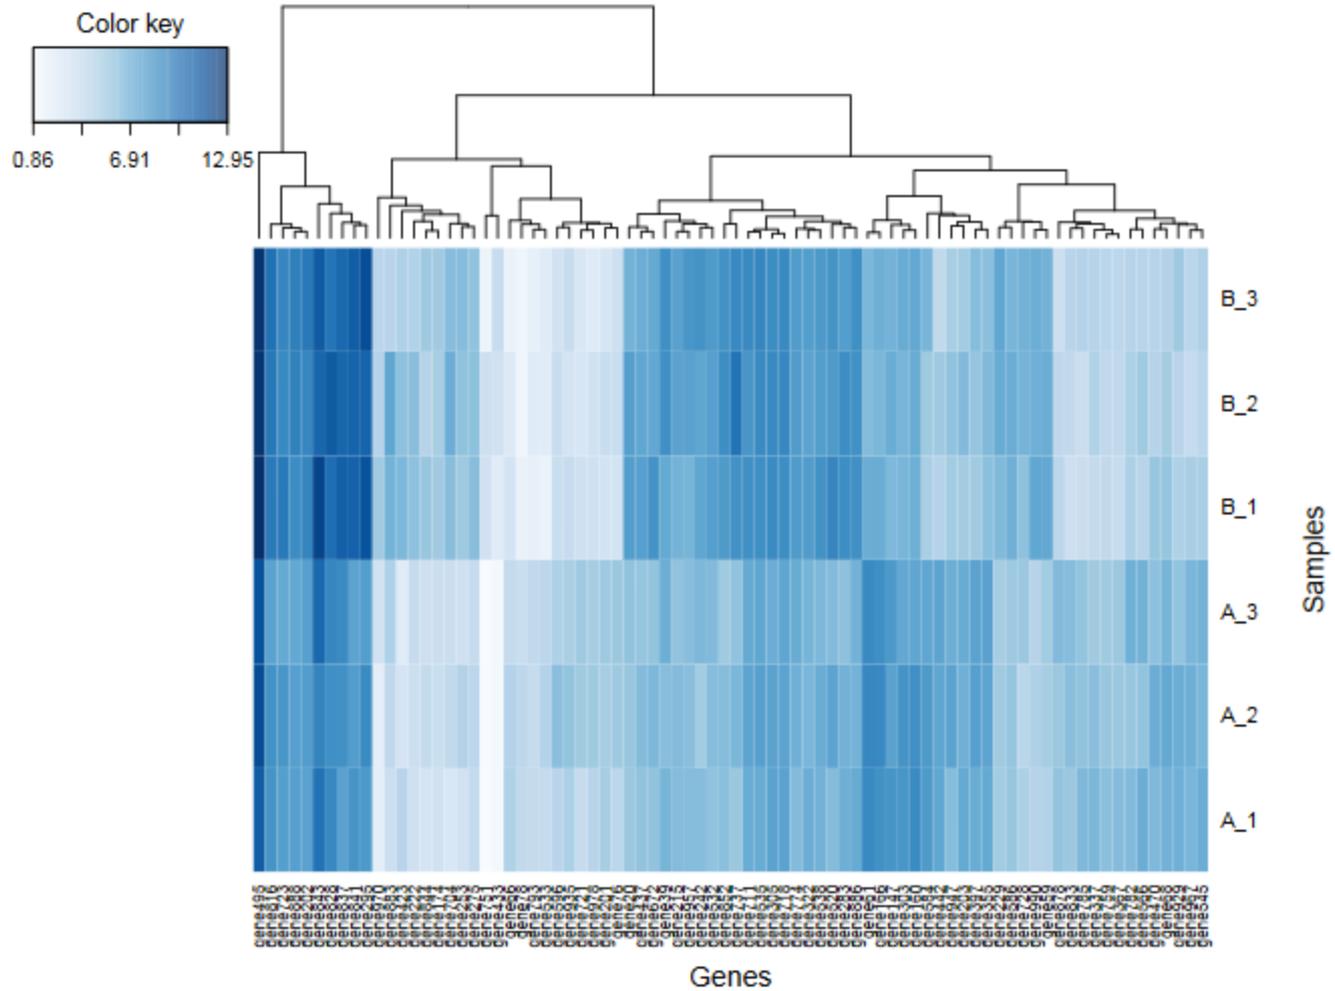
M : ordonnés, ratios des intensités.  $\log_2 R - \log_2 G = \log_2(R/G)$   
A : abscisses, moyenne des intensités du spot.  $\frac{1}{2}(\log_2 R + \log_2 G)$

Volcano plot  
Pvalue adj < 0.01



Tutorial: <http://www.nathalievilla.org/doc/pdf/tutorial-rnaseq.pdf>

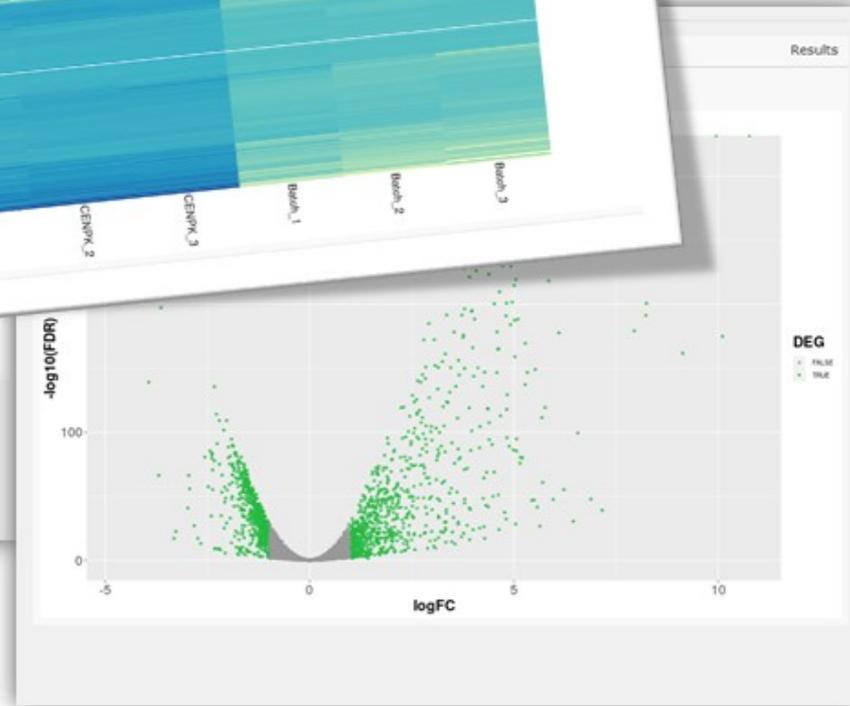
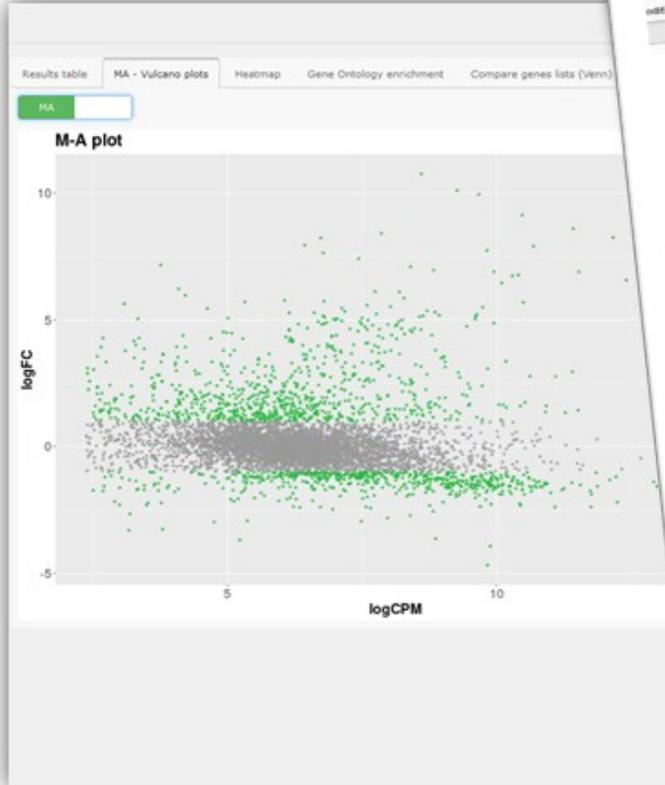
Fold change vs. P-valeur (t-test ou autre)



# Practice : DIANE

[TP Diane](#)

# Practice Graphical representation



## DIANE - Differential Expression Analysis report

[Code ▾](#)

### Dashboard for the Inference and Analysis of Networks from Expression data



This report was automatically generated by [DIANE](#) to improve research reproducibility.

It contains the main settings and results for the DEA tab of the application, reporting the last transcriptome comparison that was performed.

### Your settings

Normalization method :

[Hide](#)

```
print(the_r$norm_method)
```

```
## [1] "deseq2"
```

Reference and perturbation condition :

[Hide](#)

```
paste(r$ref, r$trt)
```

```
## [1] "Batch CENPK"
```

Threshold adjusted p-value and minimal expected absolute log fold change :

[Hide](#)

```
paste("FDR = ", r$fdr, "LFC = ", r$lfc)
```

```
## [1] "FDR = 0.05 LFC = 1"
```



**Alexis Dereeper**



**Sebastien Ravel**



**Christine Tranchant-Dubreuil**



**Sebastien Cunnac**



**Gautier Sarah**



**Julie Orjuela-Bouniol**

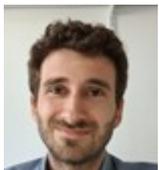


**Catherine Breton**

Alliance



**Aurore Comte**



**Alexandre Soriano**



# Links

Related courses : <https://www.nathalievialaneix.eu/>

Related courses : <https://southgreenplatform.github.io/trainings/linuxJedi/>

Tutorial RNAseq : <http://nathalievilla.org/doc/pdf/slides-rnaseq.pdf>

Book : <http://compgenomr.github.io/book/>

Degust : <http://degust.erc.monash.edu/>

MeV: <http://mev.tm4.org/>

MicroScope: <http://microscopebioinformatics.org/>

Comparison of methods for differential expression:

[https://southgreenplatform.github.io/trainings//files/Comparison\\_of\\_methods\\_for\\_differential\\_gene\\_expression\\_using RNA-seq\\_data.pdf](https://southgreenplatform.github.io/trainings//files/Comparison_of_methods_for_differential_gene_expression_using_RNA-seq_data.pdf)

PIVOT: <https://github.com/qinzhu/PIVOT/>

DESeq2: <http://www.bioconductor.org/packages/release/bioc/html/DESeq2.html>

EdgR: <https://bioconductor.org/packages/release/bioc/html/edgeR.html>

DIANE: <https://diane.bpmp.inrae.fr/>

# Merci pour votre attention !

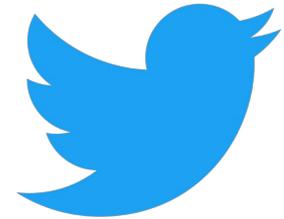


Le matériel pédagogique utilisé pour ces enseignements est mis à disposition selon les termes de la licence Creative Commons Attribution - Pas d'Utilisation Commerciale - Partage dans les Mêmes Conditions (BY-NC-SA) 4.0 International:

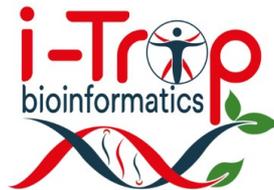
<http://creativecommons.org/licenses/by-nc-sa/4.0/>



**SUIVEZ NOUS SUR TWITTER !**



South Green : [@green\\_bioinfo](https://twitter.com/green_bioinfo)



I-Trop : [@ltropBioinfo](https://twitter.com/ltropBioinfo)



**N'oubliez pas de nous citer !**

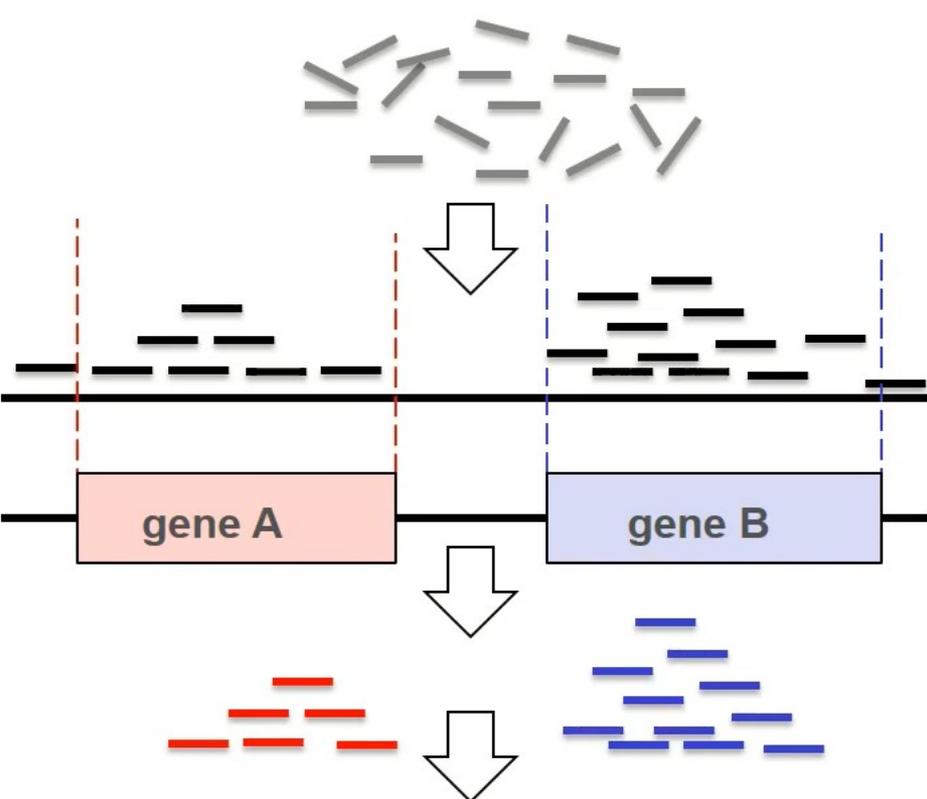
## **Comment citer les clusters?**

"The authors acknowledge the IRD i-Trop HPC at IRD Montpellier for providing HPC resources that have contributed to the research results reported within this paper. URL: <http://bioinfo.ird.fr/> "

"The authors acknowledge the CIRAD UMR-AGAP HPC (South Green Platform) at CIRAD montpellier for providing HPC resources that have contributed to the research results reported within this paper. URL: <http://www.southgreen.fr>"

- **limma** (i.e., voom+limma and vst+limma)
  - unaffected by outliers
  - but they required at least 3 samples per condition
- **SAMseq, ShrinkSeq** (The non-parametric)
  - top performing methods for data sets with large sample sizes
  - required at least 4-5 samples per condition
  - fold change required for statistical significance was lower → compromise the biological significance
  - Small sample sizes inaccuracies in the estimation of the mean and dispersion parameters
- **TSPM**
  - most affected by the sample size
- **DESeq, edgeR and NBPSeq**
  - showed, overall, relatively similar accuracy with respect to gene ranking
  - recommended parameters well chosen and often provide the best results
  - pre-specified FDR threshold varied considerably between the methods
  - DESeq : overly conservative
  - edgeR, NBPSeq : too liberal and called a larger number of false (and true) DE genes.
  - edgeR, DESeq : varying the parameters of can have large effects on the results
- **EBSeq, baySeq and ShrinkSeq** (posterior probability)
  - baySeq performed well under some conditions ; results were highly variable, especially when all DE genes were upregulated in one condition
  - EBSeq In the presence of outliers, found a lower fraction of false positives for large sample sizes not for small sample sizes
  - baySeq In the presence of outliers, found a lower fraction of false positives true for small sample sizes not for large sample sizes

# RNA-seq data analysis: steps, tools and files



	Control 1	Control 2	Control 3	Sample 1	Sample 2	Sample 3
Gene A	6	5	7	170	100	110
Gene B	11	11	10	3	4	2
Gene C	200	150	355	50	1	3
Gene D	0	1	0	2	0	1

STEP	TOOL	FILE
Quality control	FastQC	FASTQ
Pre-processing	Trimmo-matic	FASTQ
Alignment	HISAT2	BAM
Quality control	RSeQC	
Quantitation	HTSeq	Read count file (TSV)
Combine count files to table	Define NGS experiment	Read count table (TSV)
Quality control	PCA, clustering	
Differential expression analysis	DESeq2, edgeR	Gene lists (TSV)

CSC

# Omics data: multiple testing issue

## Context:

We perform a large number  $N$  of statistical tests for which we reject or not  $H_0$ .

## Possible conclusions:

		Decisions	
		Non rejects of $H_0$	Rejects of $H_0$
Unknown truths	$H_0$ true	TN	FP
	$H_0$ false	FN	TP

Among all the genes told differentially expressed, the False Discovery Rate (FDR) is:

$$\frac{FP}{FP + TP}$$

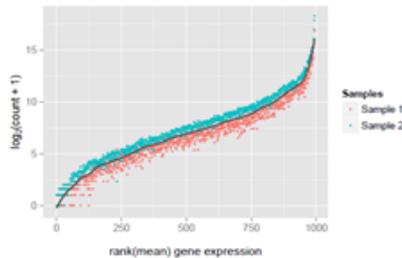
Normalization Technique	Name authors	Description	Software
UQ	Upper Quartile Ref : Bullard et al., 2010 (Upper Quartile normalization)	Les comptages par gène sont divisés par le 3e quartile des comptages non nuls de l'échantillon, puis multipliés par la moyenne des 3e quartiles de tous les échantillons.	EdgeR
TC	Total read count adjustment Ref : Mortazavi et al., 2008	Chaque nombre reads est divisé par le nombre total de reads (taille de la banque), puis multiplié par le nombre total moyen de reads des librairies.	
RPKM	Reads Per Kilobase per Million	La normalisation RPKM (Reads Per Kilobase per Million) a été introduite initialement pour faciliter les comparaisons entre gènes d'un même échantillon ; elle combine donc une normalisation inter et intra échantillons. Ainsi, les comptages sont corrigés pour prendre en compte la taille de la librairie et la longueur des gènes. Cependant, il a été montré que la correction de la longueur des gènes a pour effet d'introduire un biais dans la variance par gène, en particulier pour les gènes faiblement exprimés. Cette méthode reste toutefois très populaire dans de nombreuses applications.	EdgeR
RLE	Relative Log Expression Ref : Anders and Huber, 2010.	La normalisation RLE (Relative Log Expression) a été développée dans le package Bioconductor DESeq. Elle se base sur l'hypothèse selon laquelle la plupart des gènes ne sont pas différentiellement exprimés. Le facteur de normalisation pour un échantillon est obtenu en calculant pour chaque gène la médiane des ratios de ses comptages par rapport à sa moyenne géométrique entre les différents échantillons. L'idée sous-jacente est que les gènes non différentiellement exprimés doivent avoir des comptages similaires entre différents échantillons, et donc un ratio proche de 1. Si l'on suppose que la plupart des gènes ne sont pas différentiellement exprimés, la médiane des ratios constitue une estimation du facteur correctif qui doit être appliqué à l'ensemble des comptages.	DESeq, DESeq2, EdgeR
TMM	Trimmed Mean of M-values Ref : Robinson, M. and Oshlack, A. (2010).	La normalisation TMM (Trimmed Mean of M-values) est implémentée dans le package Bioconductor edgeR. Elle se base sur l'hypothèse selon laquelle la plupart des gènes ne sont pas différentiellement exprimés. Le facteur TMM est calculé pour chaque échantillon, l'un d'eux étant considéré comme l'échantillon de référence et les autres comme des échantillons test. Pour chaque échantillon test, le facteur TMM est la moyenne pondérée des log-ratios entre ce test et la référence, après exclusion des gènes les plus exprimés et des gènes ayant les plus forts log-ratios. D'après l'hypothèse selon laquelle il y a peu de gènes différentiellement exprimés, le facteur TMM doit être proche de 1. S'il ne l'est pas, sa valeur donne une estimation du facteur correctif à appliquer aux tailles des librairies (et pas aux comptages bruts) afin de rendre l'hypothèse vraie.	EdgeR

## RLE

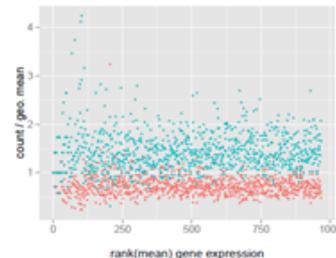
La normalisation RLE (Relative Log Expression) a été développée dans le package Bioconductor DESeq. Elle se base sur l'hypothèse selon laquelle la plupart des gènes ne sont pas différentiellement exprimés. Le facteur de normalisation pour un échantillon est obtenu en calculant pour chaque gène la médiane des ratio de ses comptages par rapport à sa moyenne géométrique entre les différents échantillons. L'idée sous-jacente est que les gènes non différentiellement exprimés doivent avoir des comptages similaires entre différents échantillons, et donc un ratio proche de 1. Si l'on suppose que la plupart des gènes ne sont pas différentiellement exprimés, la médiane des ratio constitue une estimation du facteur correctif qui doit être appliqué à l'ensemble des comptages.

Ref : Anders and Huber, 2010. Dans edgeR, DESeq – DESeq2

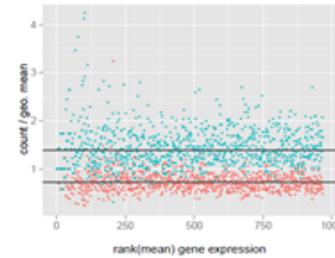
1 – Calcule une pseudo référence



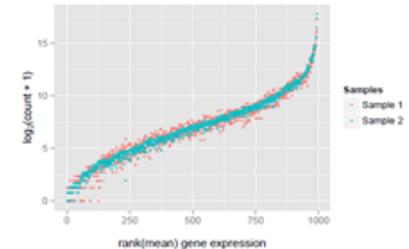
2 – Centre les échantillons comparés à la référence



3 – Calcule un facteur de normalisation : médiane des ratio de ses comptages par rapport à sa moyenne géométrique entre les différents échantillons



```
## With edgeR
calcNormFactors(..., method="RLE")
## with DESeq
estimateSizeFactors(...)
```



## TMM

La normalisation TMM (Trimmed Mean of M-values) est implémentée dans le package Bioconductor edgeR. Elle se base sur l'hypothèse selon laquelle la plupart des gènes ne sont pas différentiellement exprimés. Le facteur TMM est calculé pour chaque échantillon, l'un d'eux étant considéré comme l'échantillon de référence et les autres comme des échantillons test. Pour chaque échantillon test, le facteur TMM est la moyenne pondérée des log-ratios entre ce test et la référence, après exclusion des gènes les plus exprimés et des gènes ayant les plus forts log-ratios. D'après l'hypothèse selon laquelle il y a peu de gènes différentiellement exprimés, le facteur TMM doit être proche de 1. S'il ne l'est pas, sa valeur donne une estimation du facteur correctif à appliquer aux tailles des bibliothèques (et pas aux comptages bruts) afin de rendre l'hypothèse vraie.

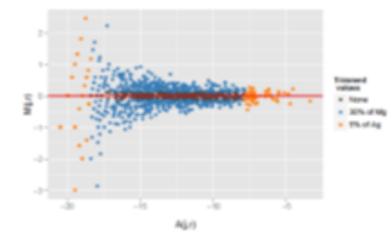
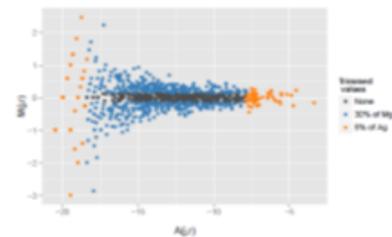
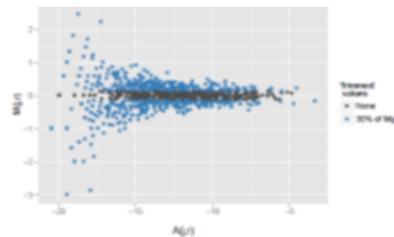
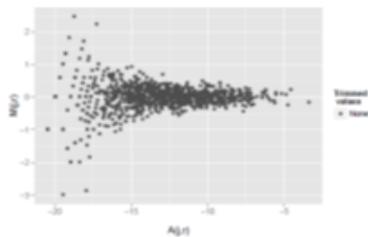
Ref : Robinson, M. and Oshlack, A. (2010). Dans edgeR.

1 – Sélectionner un échantillon pour servir de référence :  
L'échantillon  $r$  avec le quartile supérieur plus proche du quartile de la moyenne supérieure.

2 – Trim 30% on M-values

3 – Trim 5% on A-values

3 – Sur les données restantes, calculer la moyenne pondérée des valeurs M

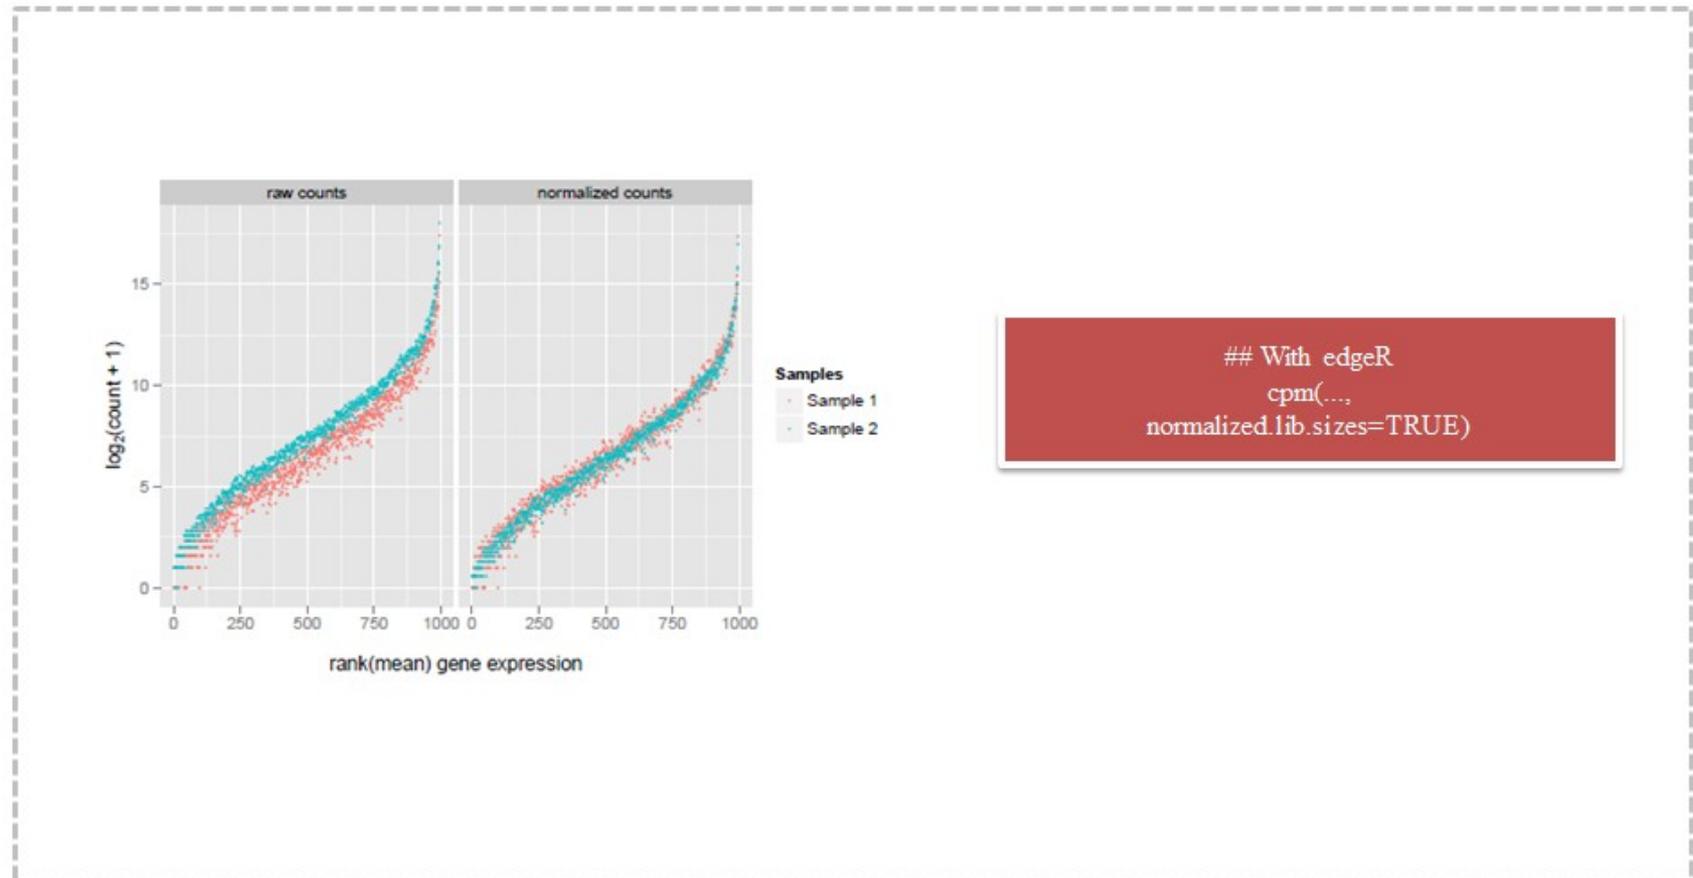


```
## With edgeR
calcNormFactors(..., method="TMM")
```

## Total read count adjustment

Chaque nombre reads est divisé par le nombre total de reads (taille de la banque), puis multiplier par le nombre total moyen de reads des bibliothèques.

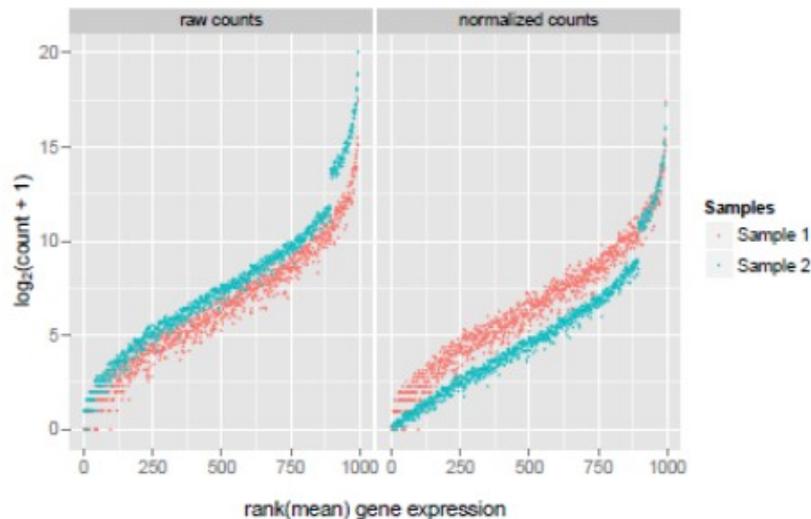
Ref : Mortazavi et al., 2008



## Upper Quartile

Les comptages par gène sont divisés par le 3<sup>e</sup> quartile des comptages non nuls de l'échantillon, puis multipliés par la moyenne des 3<sup>e</sup> quartiles de tous les échantillons.

Ref Bullard et al., 2010 (Upper) Quartile normalization



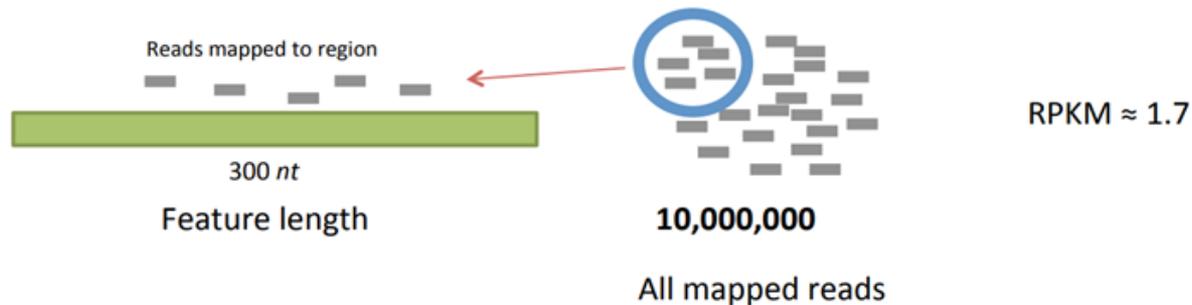
1 – dans lequel  $Q(p)_j$  est un quantile donné (généralement le 3<sup>e</sup> quartile) de la distribution des comptes dans l'échantillon  $j$ .

```
## With edgeR
calcNormFactors(..., method = "upperquartile",
  p = 0.75)
```

## Correcting for **transcript length** and **total number of reads**

### RPKM

La normalisation RPKM (Reads Per Kilobase per Million) a été introduite initialement pour faciliter les comparaisons entre gènes d'un même échantillon ; elle combine donc une normalisation inter et intra échantillons. Ainsi, les comptages sont corrigés pour prendre en compte la taille de la librairie et la longueur des gènes. Cependant, il a été montré que la correction de la longueur des gènes a pour effet d'introduire un biais dans la variance par gène, en particulier pour les gènes faiblement exprimés. Cette méthode reste toutefois très populaire dans de nombreuses applications.



$$RPKM = 10^9 \times \frac{\text{Number of reads mapped to a region}}{\text{Total reads} \times \text{region length}}$$

RPKM: Reads Per Kilo base of transcript per Million reads