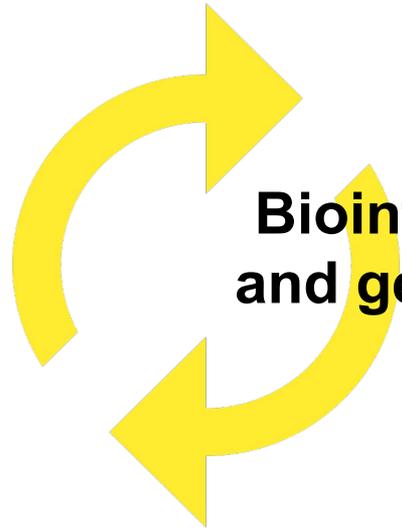


South Green

bioinformatics platform

Trainings 2019





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



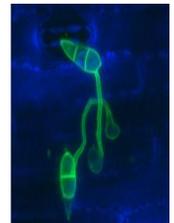
Sorghum



Coffee



Cassava



Magnaporthe



Larmande Pierre
Sabot François
Tando Ndomassi
**Tranchant-Dubreuil
Christine**



Comte Aurore
Dereeper Alexis



Orjuela-Bouniol Julie



Bocs Stephanie
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



Mahé Frédéric
Ravel Sébastien



Sempere Guilhem

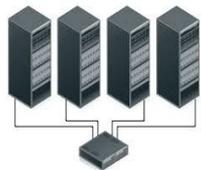
Workflow manager

TOOLBOX
Toolbox for generic NGS analyses

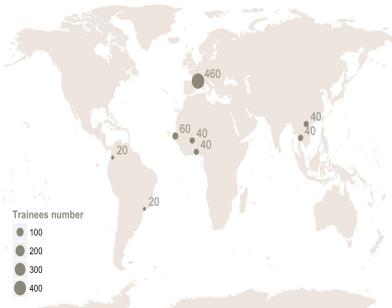
SNAKEMAKE

Galaxy

HPC and trainings....



37 courses organized last 7 years



IRD
Institut de Recherche
pour le Développement

cirad

Genome Hubs & Information System



Gigwa

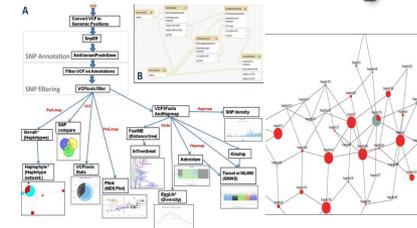
SNPs and Indels

GreenPhyl

Family Id	Family Name	Number of sequences	Status
GP000010	Cytochrome P450 superfamily	6542	●
GP000017	AP2/EREBP transcription factor family: ERF/ERF3 group (partial)	5142	●
GP000020	NAC transcription factor family	4574	●
GP000028	MADS transcription factor family		
GP000018	Haem peroxidase superfamily		
GP000095	General substrate transporter superfamily		
GP000022	Subtilisin-like Serine Proteases family		
GP000019	NPF, NRT1/PTR FAMILY		

Gene families

SNIPlay



<https://github.com/SouthGreenPlatform>



@green_bioinfo

South Green

bioinformatics platform



Erwan Corre



Marie Simonin
Sébastien Cunnac



Etienne Loire
Julie Reveillaud



Florentin Constancias



Valentin Klein



Valérie Noël



And more collaborators !

- 18-19/03 - Guide de survie à Linux - IRD
- 21/03 - Initiation à l'utilisation du cluster CIRAD - CIRAD
- 22/03 - Initiation à l'utilisation du cluster itrop - IRD
- 15-16/04 - Initiation au gestionnaires de workflow SG & Gigwa - IRD
- 18-19/04 - Guide du Jedi en Linux & bash - CIRAD
- 13-16/05 - Python - IRD
- 17/05 - Initiation aux analyses de données transcriptomiques - IRD
- 21/05 - Utilisation avancée du cluster IRD - IRD
- 23-24/05 - Initiation aux analyses de données métagénomiques - IRD
- 6/06 - Manipulation de données et figures sous R - CIRAD
- 25-27/09 - Assemblage et annotation de transcriptomes - IRD

Trainings 2019

- South Green Trainings :
<https://southgreenplatform.github.io/trainings/>
- Slides & Practices : RNAseq
- Working environment : Softwares to install

Initiation aux analyses de données transcriptomiques

www.southgreen.fr

<https://southgreenplatform.github.io/trainings>



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 TOGGLE : Hisat2 + stringtie
- Pseudo-alignment using Galaxy : kallisto
- Differential expression analysis: EdgeR, Deseq2 : package shiny Pivot
- Clustering, co-expression network: R

L'accès aux séquences d'ARN permet de :

- Annoter un génome
- Réaliser un catalogue de gènes exprimés
- Identifier des nouveaux gènes
- identifier des transcripts alternatifs
- Quantifier l'expression des gènes et comparer entre différentes conditions expérimentales
- Identifier des petits ARNs (Regulation de l'expression, silencing ...)

Le choix technologique (depletion/enrichissement, démultiplexage, séquençage directionnel) dépendra de la question biologique

1- Design experimental

Basic experiment : trouver les différences entre condition
contrôle/traitée

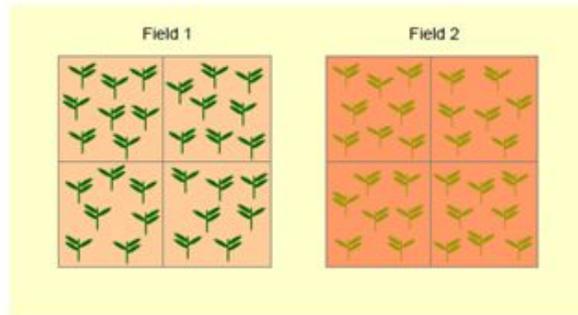


control group plant



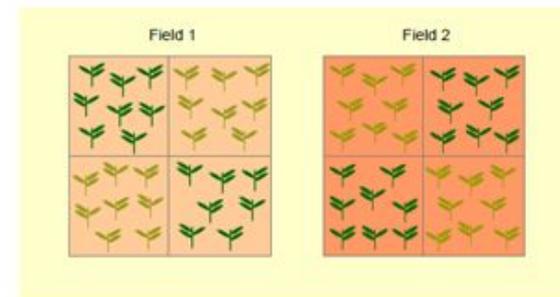
treated group plant

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

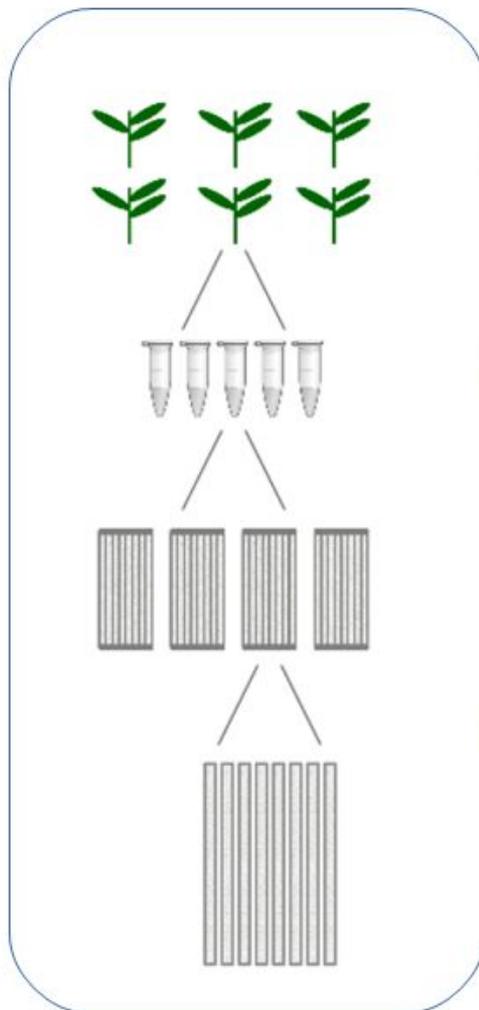


Pas de possibilité de différencier
l'effet champs de l'effet traitement

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

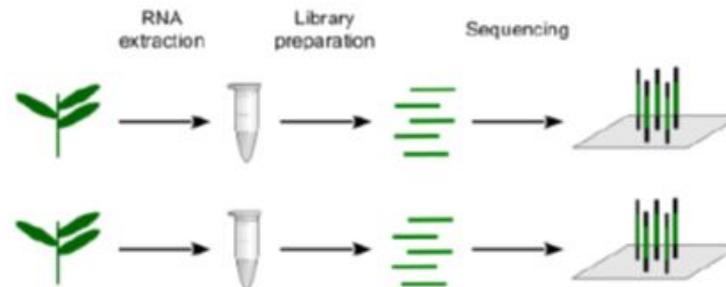
2 – Variations techniques :
effet de la préparation
des librairies

cDNA on lane of flowcell

3 – Variation techniques : effet des
lane et des flowcell

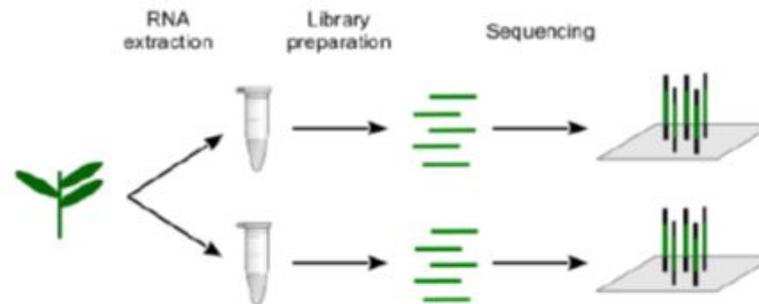
Effet lane < Effet Flowcell < Effet de la préparation de la librairie << Effet biologique

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

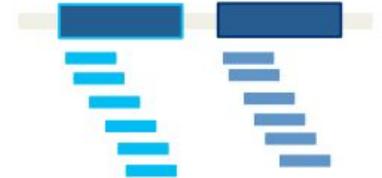
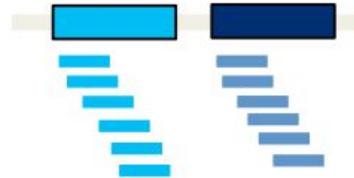


2- Des reads aux transcripts

Reads



Mapping against genome



Read clusters



Putative transcripts



de novo assembly



Genome based



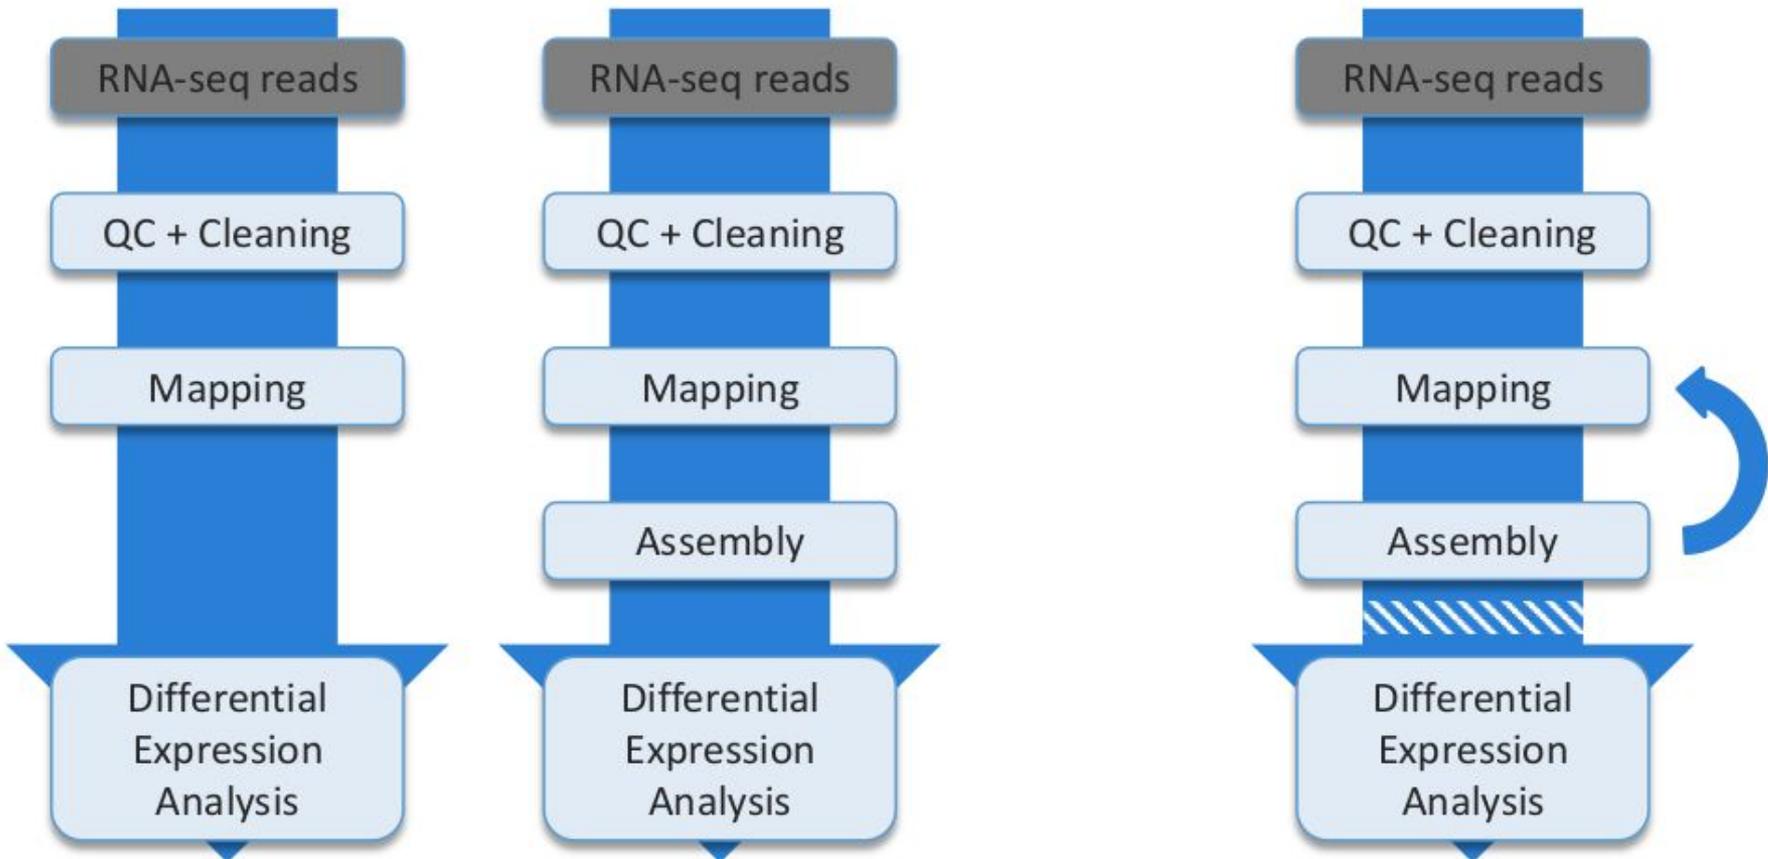
Genome guided de novo

- Reference genome
- Reference transcriptome

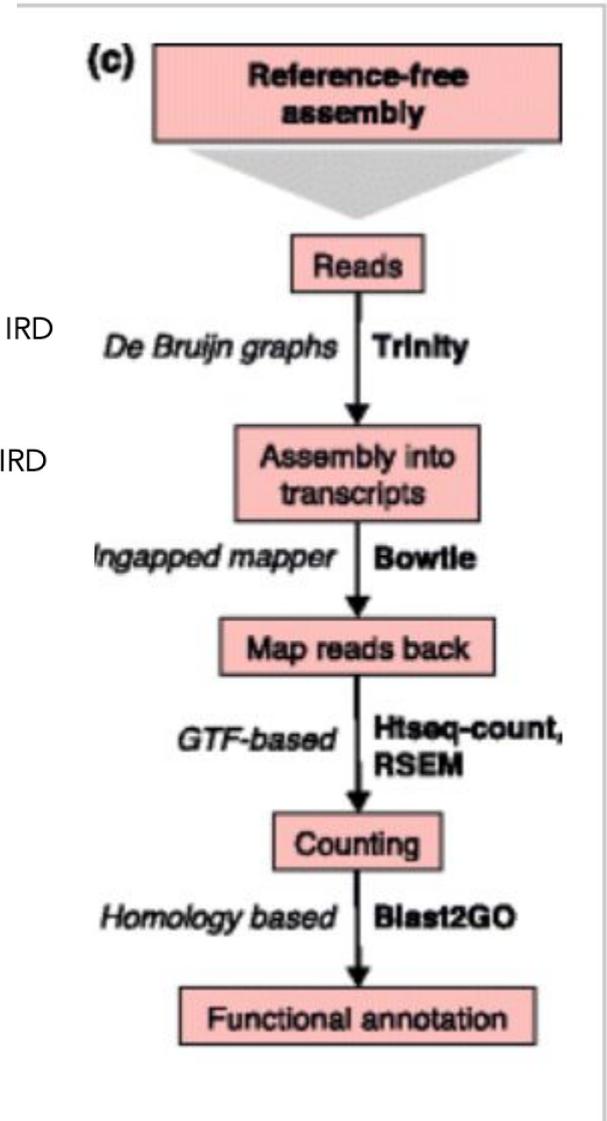
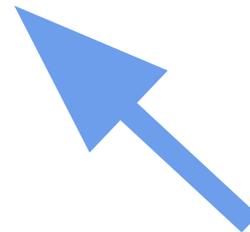
- Reference genome
- No reference transcriptome

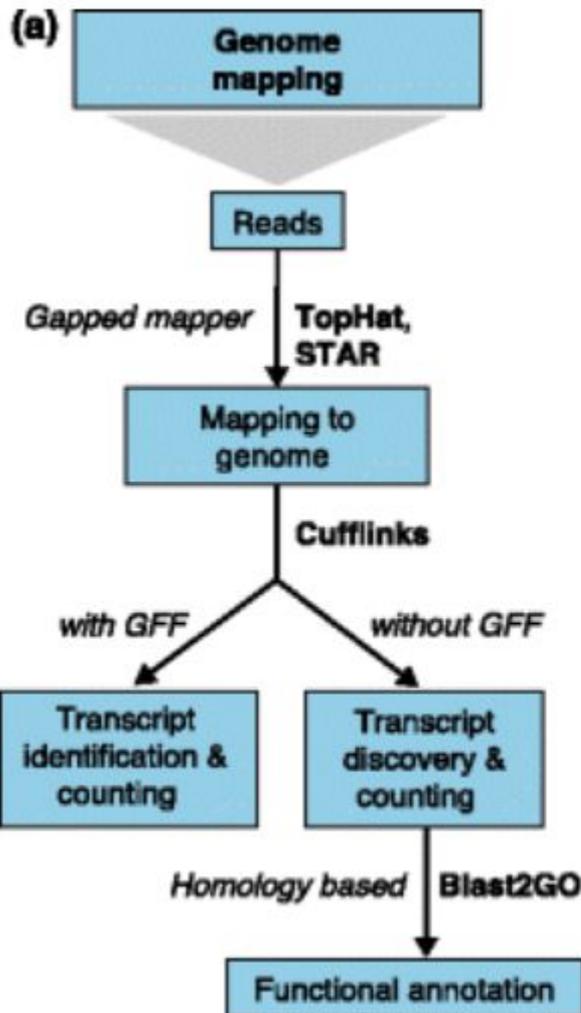
Non discovery mode

Discovery mode

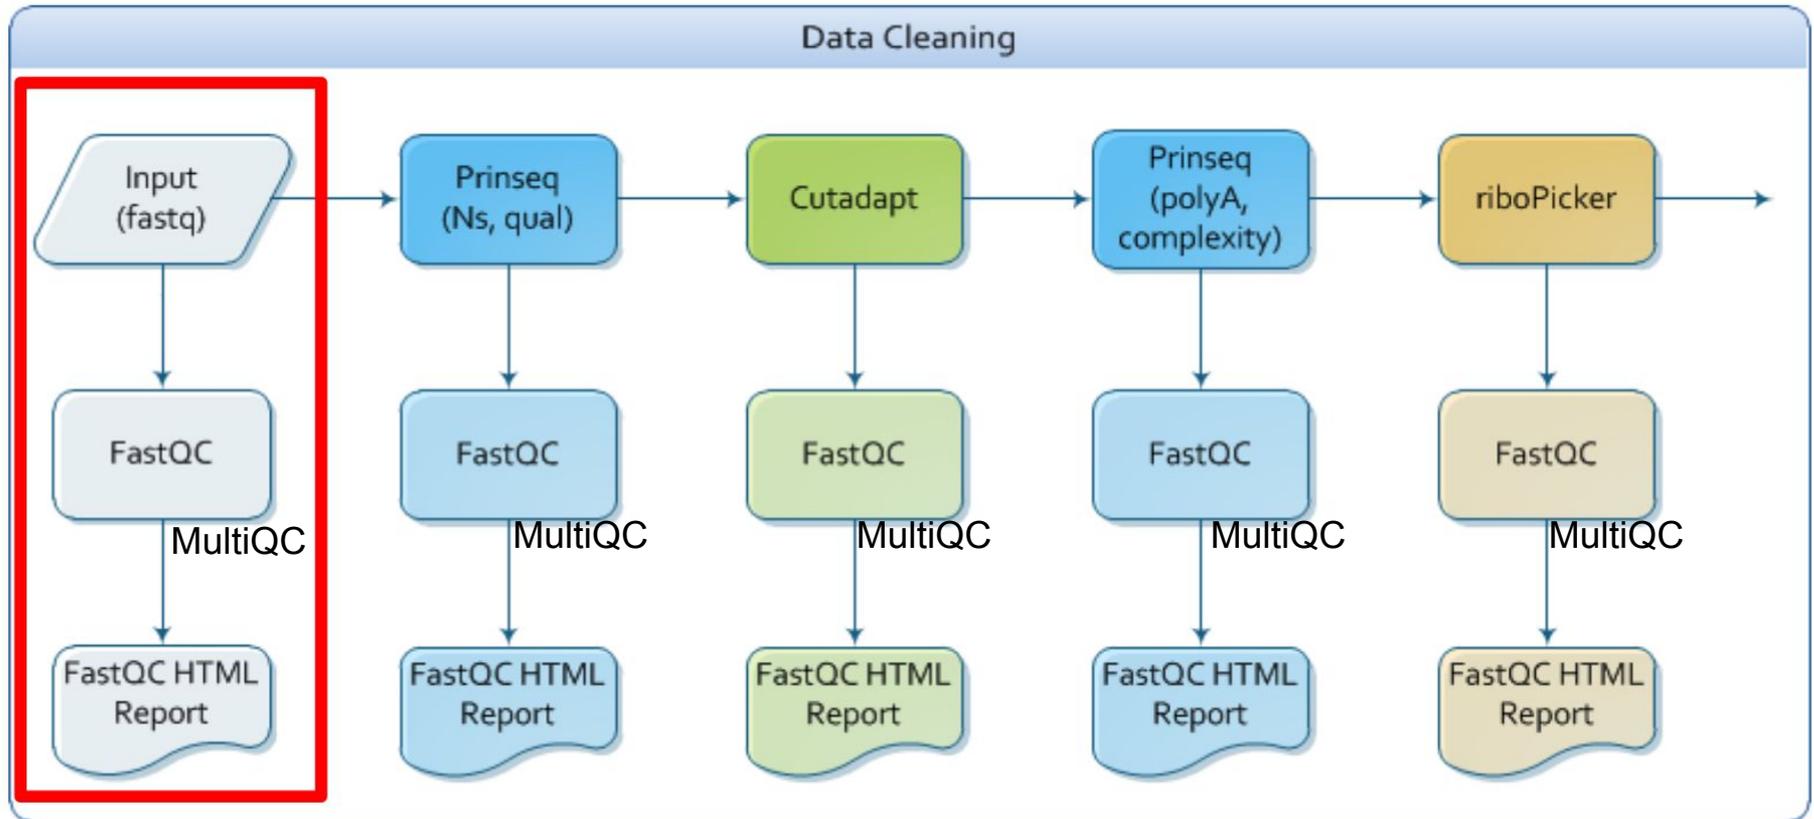


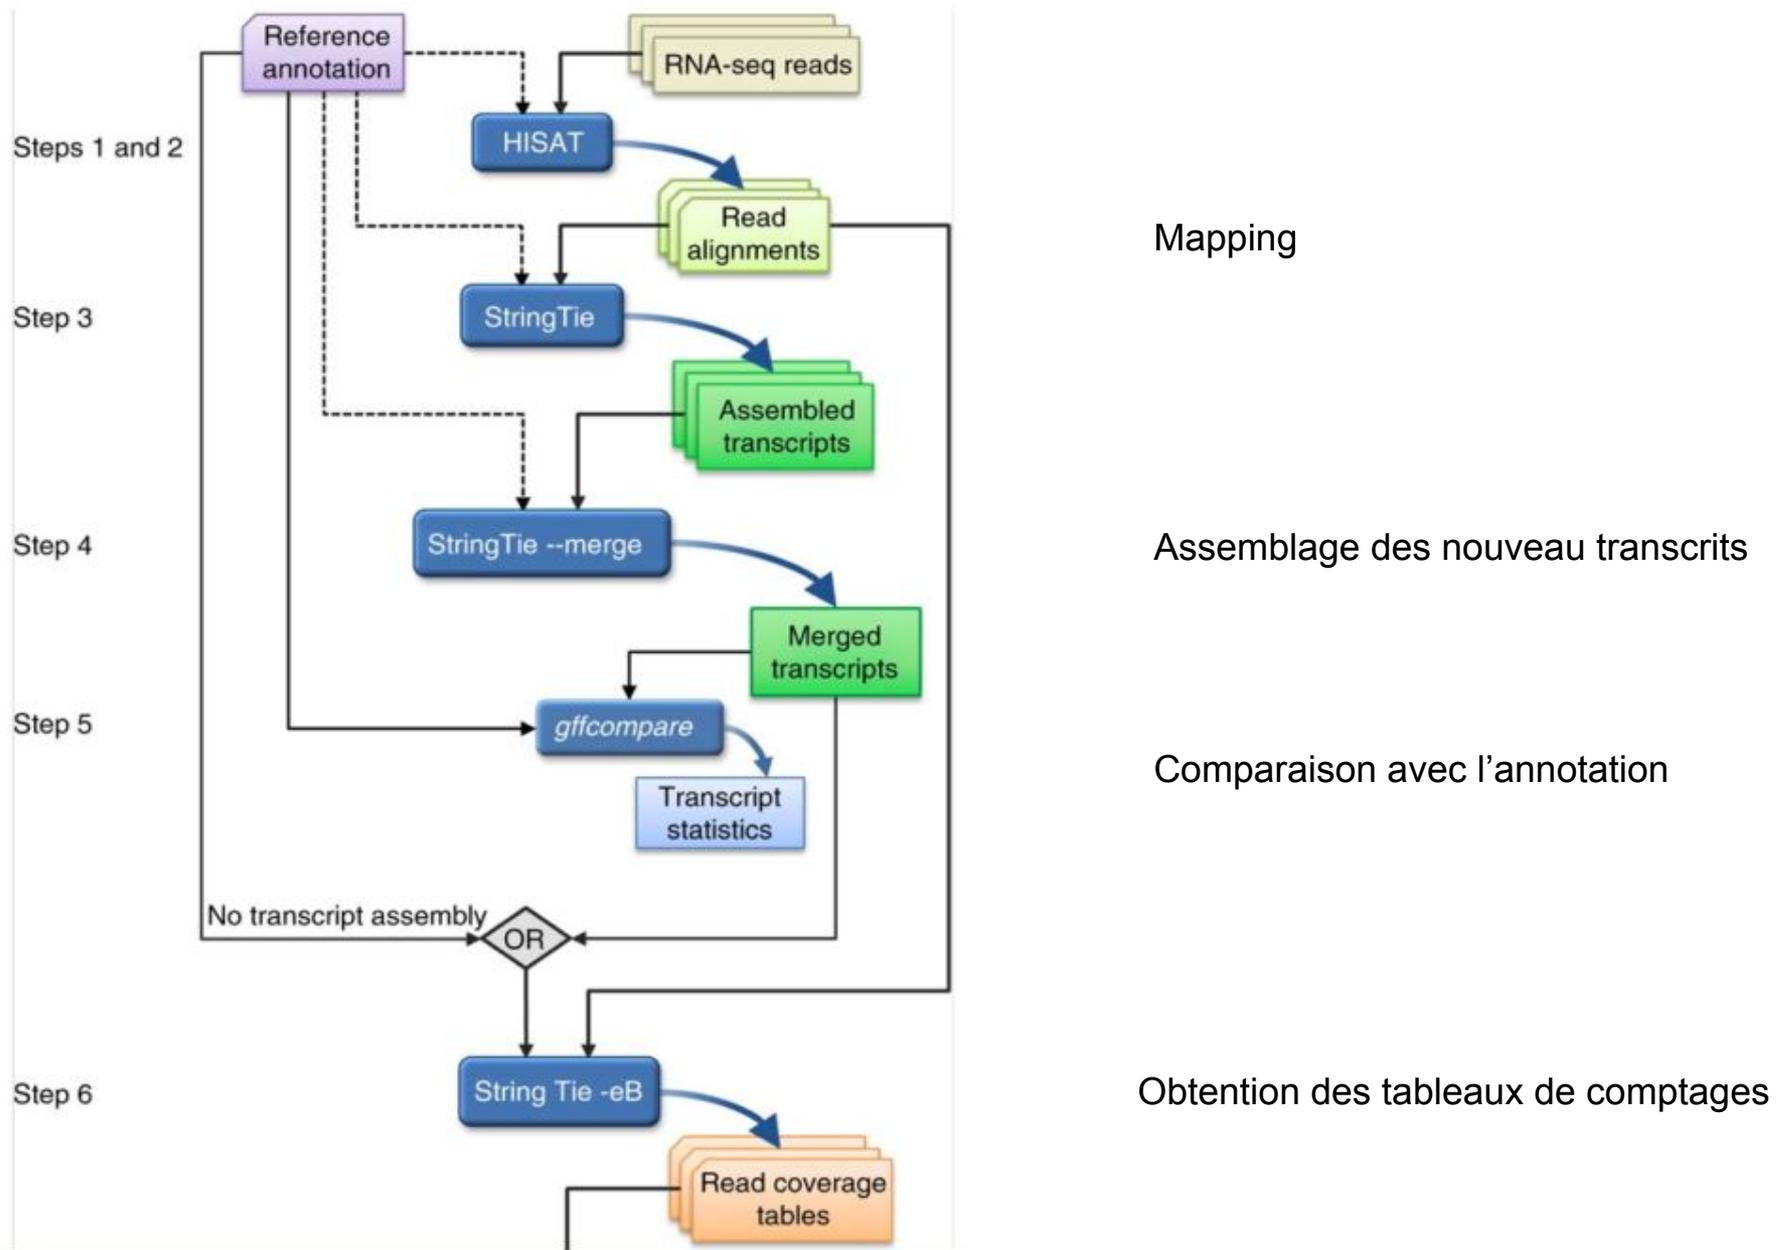
- 17/05 —●— Initiation aux analyses de données transcriptomiques – IRD
- 21/05 —●— Utilisation avancée du cluster IRD – IRD
- 23-24/05 —●— Initiation aux analyses de données métagénomiques – IRD
- 6/06 —●— Manipulation de données et figures sous R – CIRAD
- 25-27/09 —●— Assemblage et annotation de transcriptomes - IRD



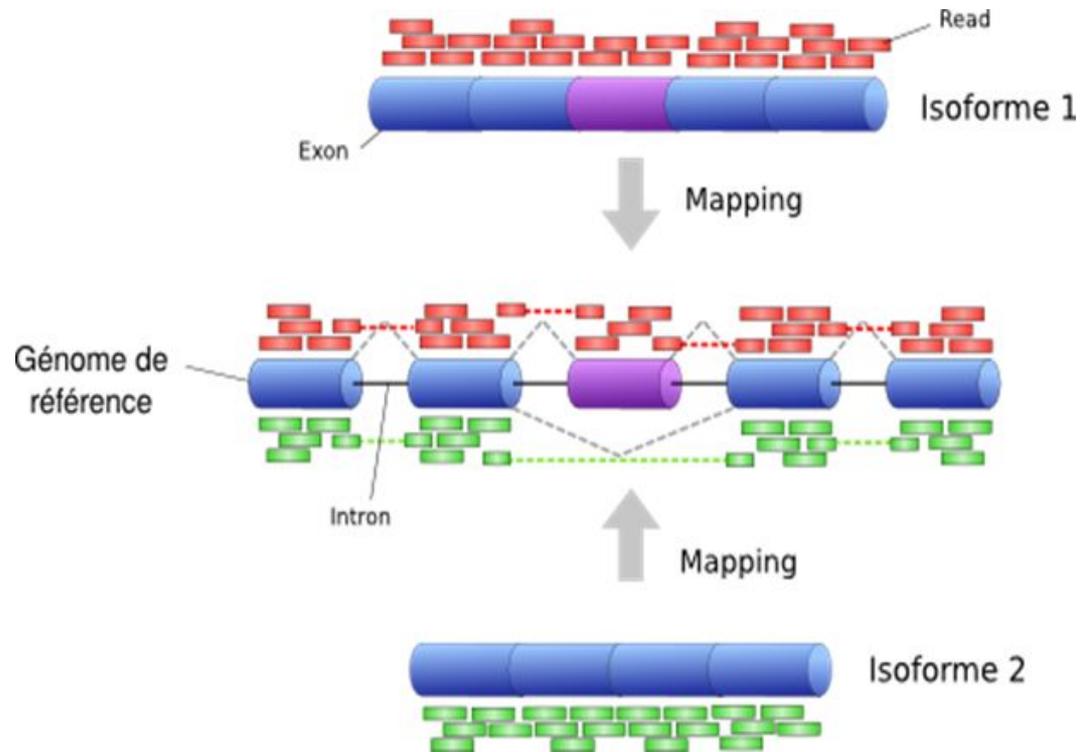


	Problème	Pourquoi les éliminer?	Outils
Sequences biases	Ns, mauvaise qualité des nucléotides, biais hexamères (random priming)	Pour éliminer des erreurs de sequencing. Désastreux pour la plupart des assembleurs	PRINSEQ2 FASTX Toolkit <i>Trimmomatic</i>
Adaptors and primers	Peuvent être trouvés dans le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



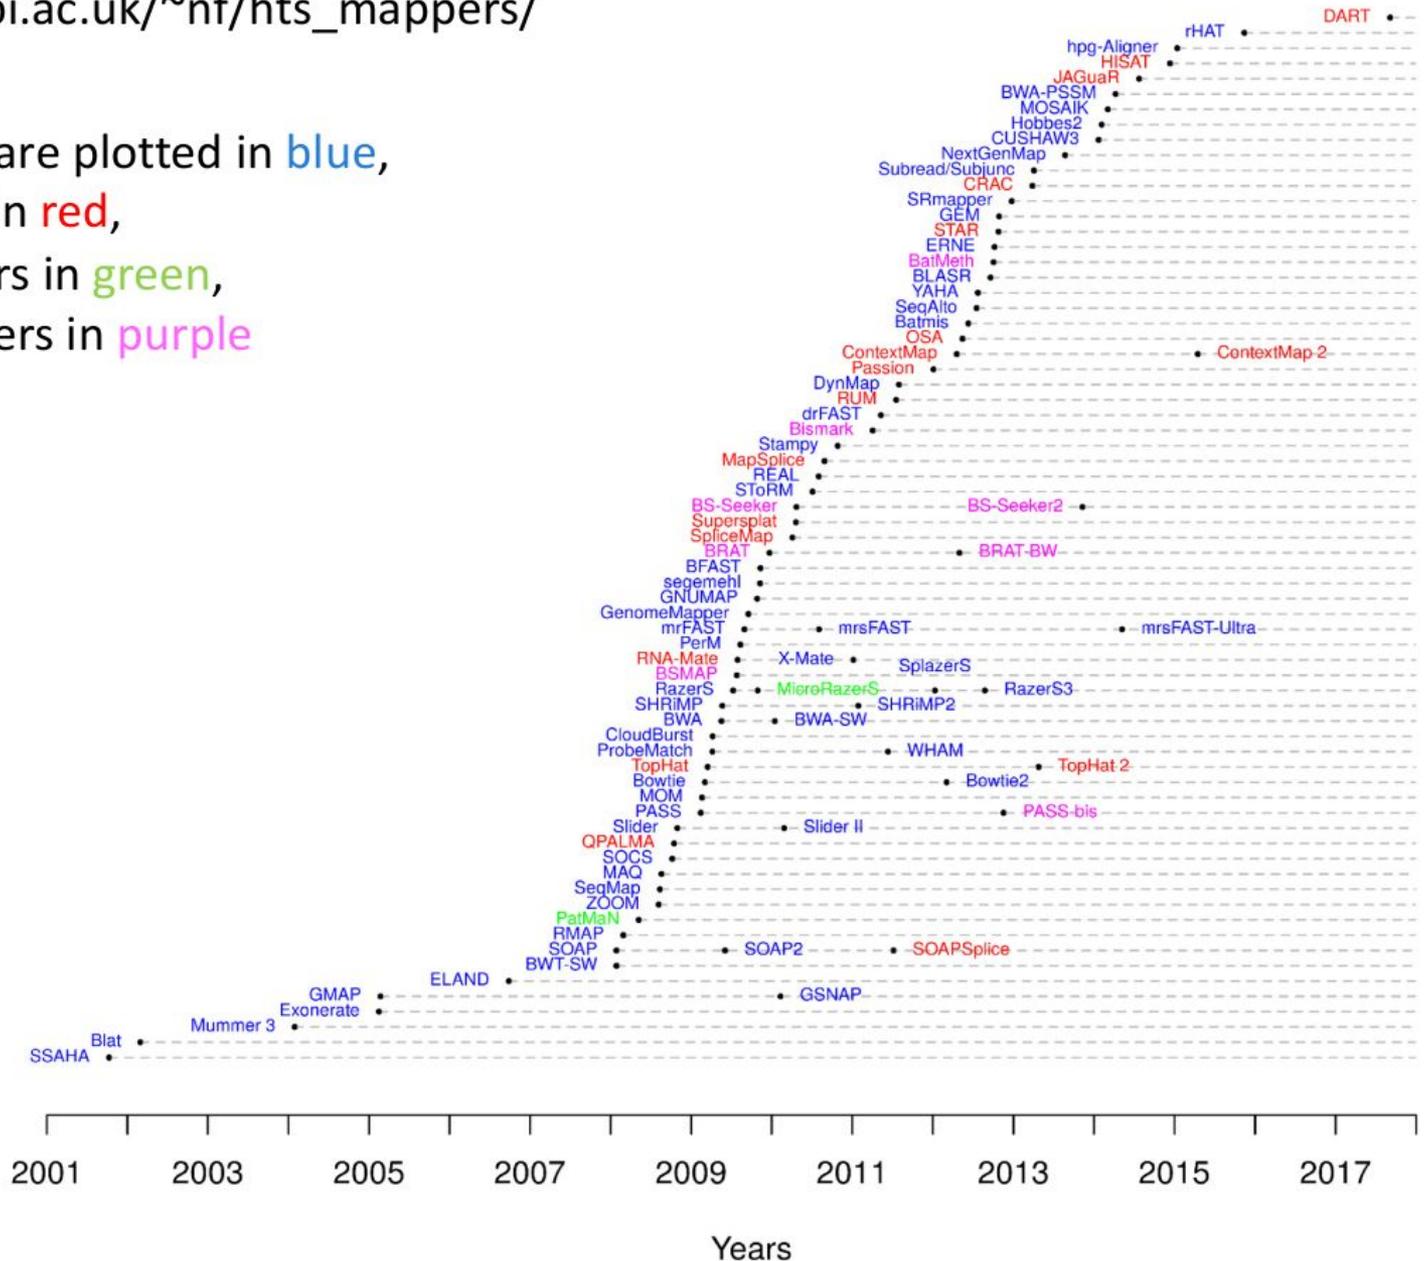


- Permet la mise en évidence d'isoformes
- Aide à l'annotation structurale du génome

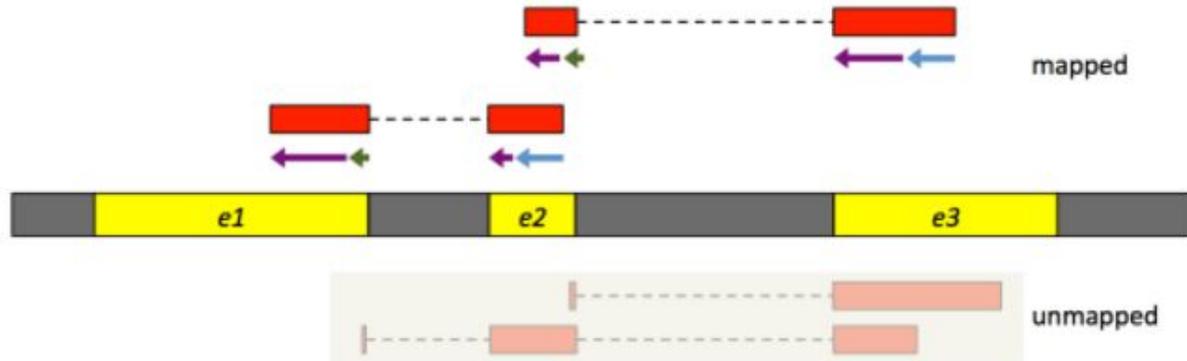


http://www.ebi.ac.uk/~nf/hts_mappers/

DNA mappers are plotted in blue,
 RNA mappers in red,
 miRNA mappers in green,
 bisulfite mappers in purple



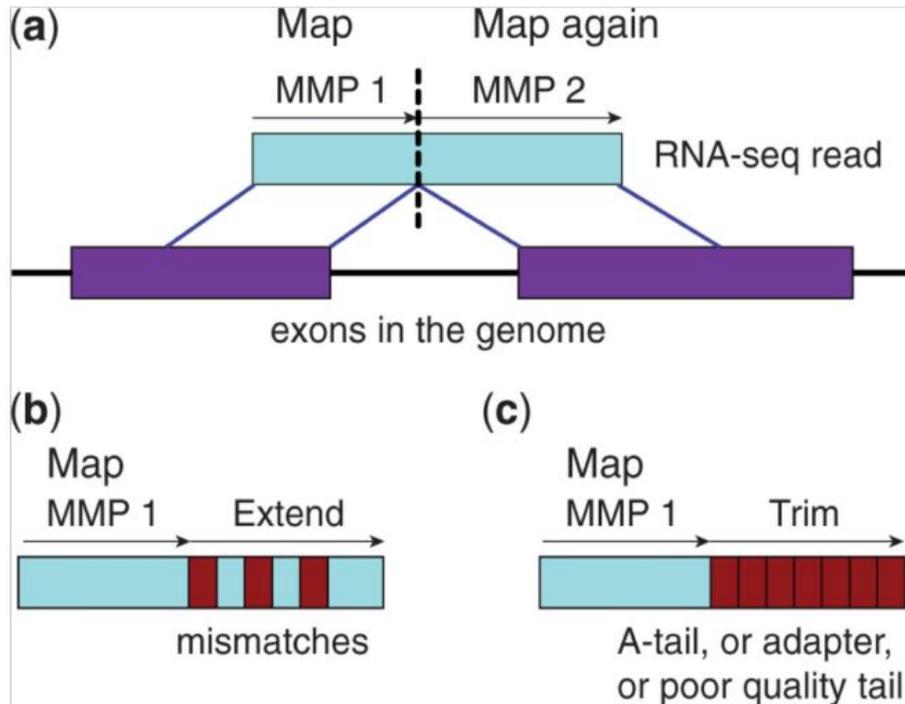
1st run of HISAT to discover splice sites



2nd run of HISAT to align reads by making use of the list of splice sites collected above



1st step Maximum Mapability Prefix search
-> no mismatches



2nd 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.

A. Dobin & *al.*, *Bioinformatics*, 2013

3- Comptage

mRNA-seq for measuring gene expression

Myers Lab


Selection of mRNA with polyA tail :



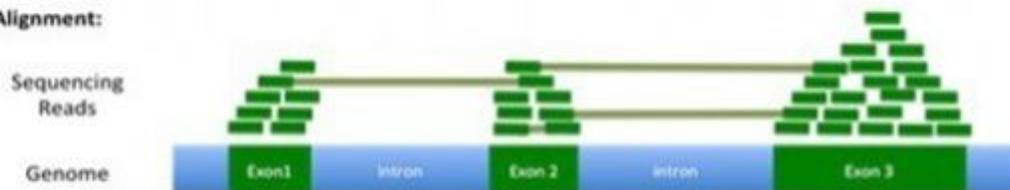
Random Primed cDNA synthesis :



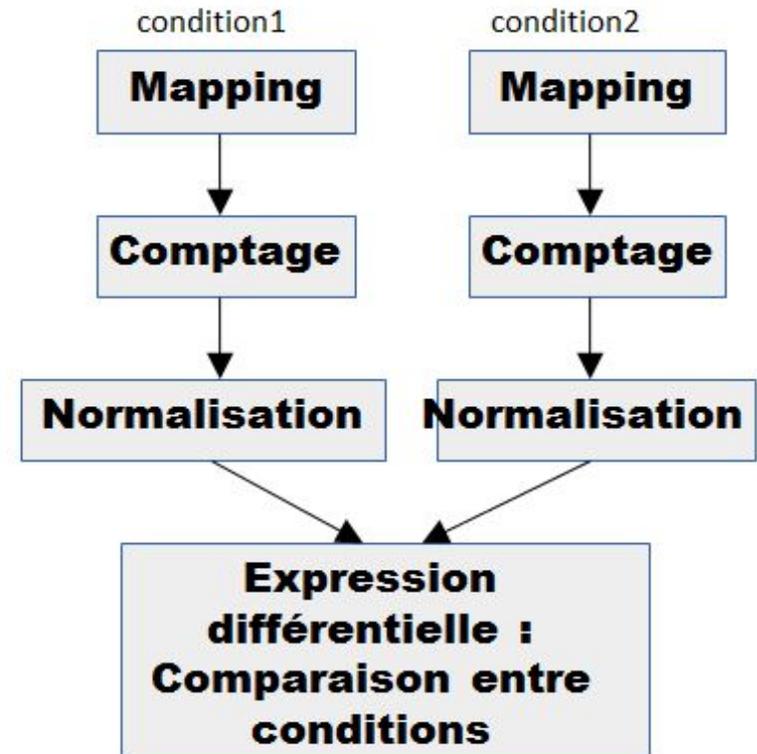
Paired-end sequencing of fragmented cDNA:



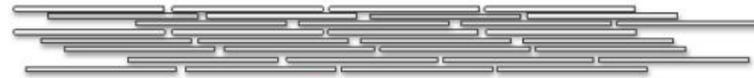
Alignment:



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

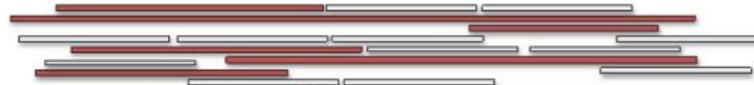


RNA-Seq reads



Step 1: assemble reads into "super-reads" (optional)

Super-reads



Step 2: map super-reads to the genome

Genome



isoform 1

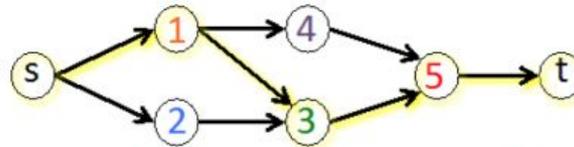
isoform 2

isoform 3

Mapped
(super)-reads

Step 3: build alternative splice graph

Splice graph with
heaviest path
highlighted



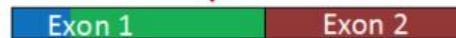
Step 4: construct flow network for path in splice graph with heaviest coverage



Step 5: assemble transcripts and update coverage



isoform 1



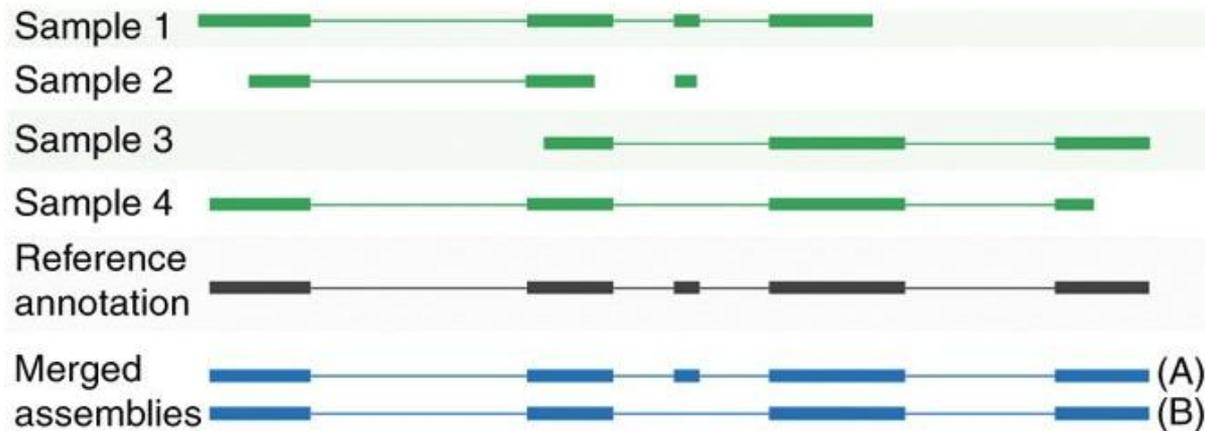
isoform 2



isoform 3

Figure 2 : Merging transcript assemblies using StringTie's merge function.

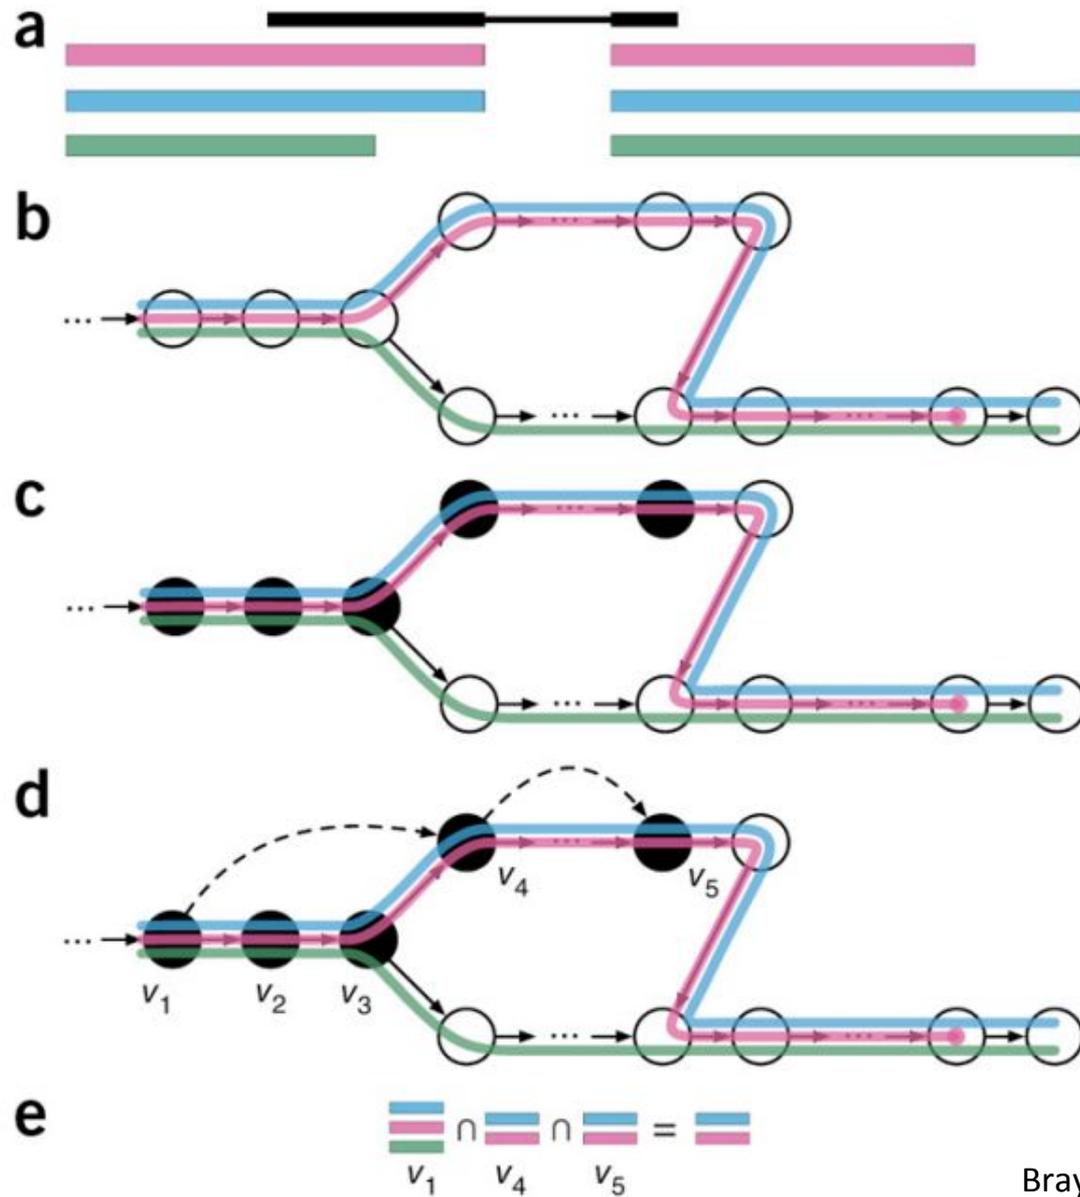
From: Transcript-level expression analysis of RNA-seq experiments with HISAT, StringTie and Ballgown



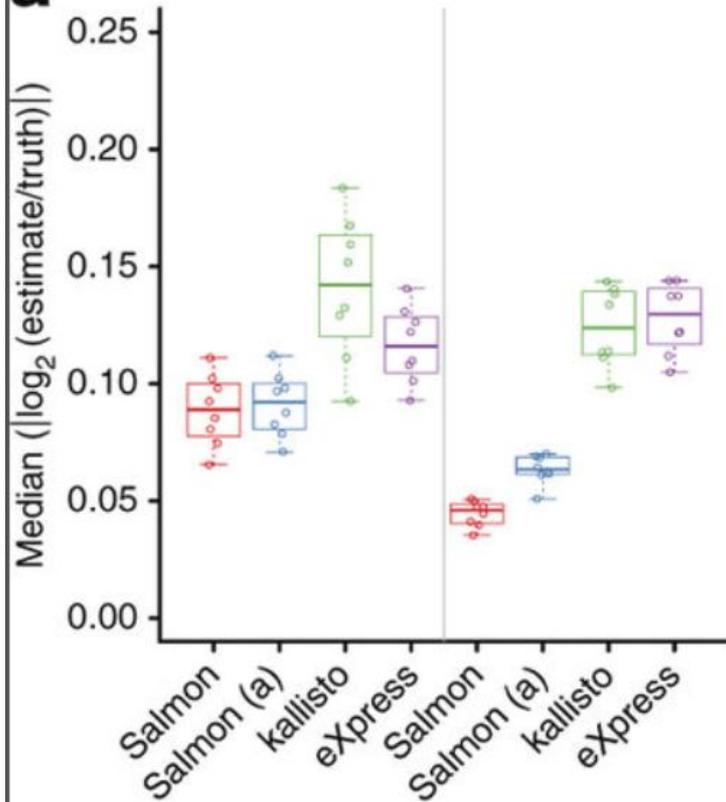
In this example, four partial assemblies from four different samples are merged into two transcripts A and B. Samples 1 and 2 are both consistent with the reference annotation, which is used here to merge and extend them to create transcript A. Samples 3 and 4 are consistent with each other but not with the annotation, and these are merged to create transcript B.

Quantifying abundances of transcripts by *pseudoalignment* for rapidly determining the compatibility of reads with targets, without the need for alignment.

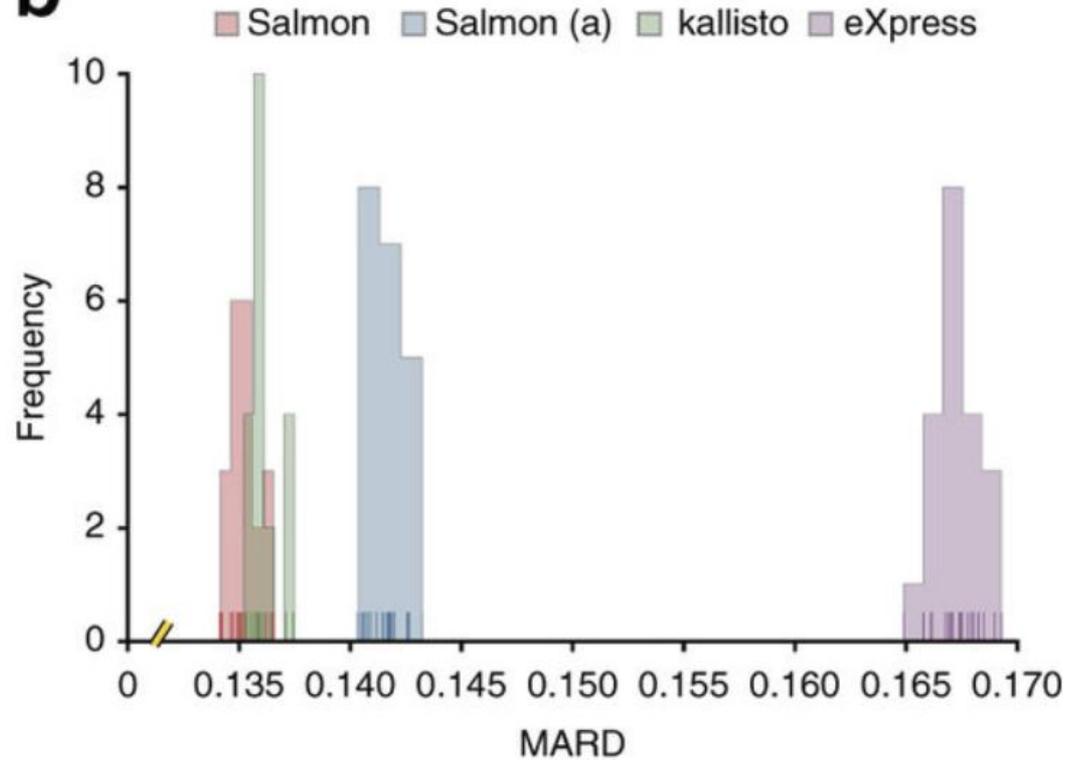




a



b

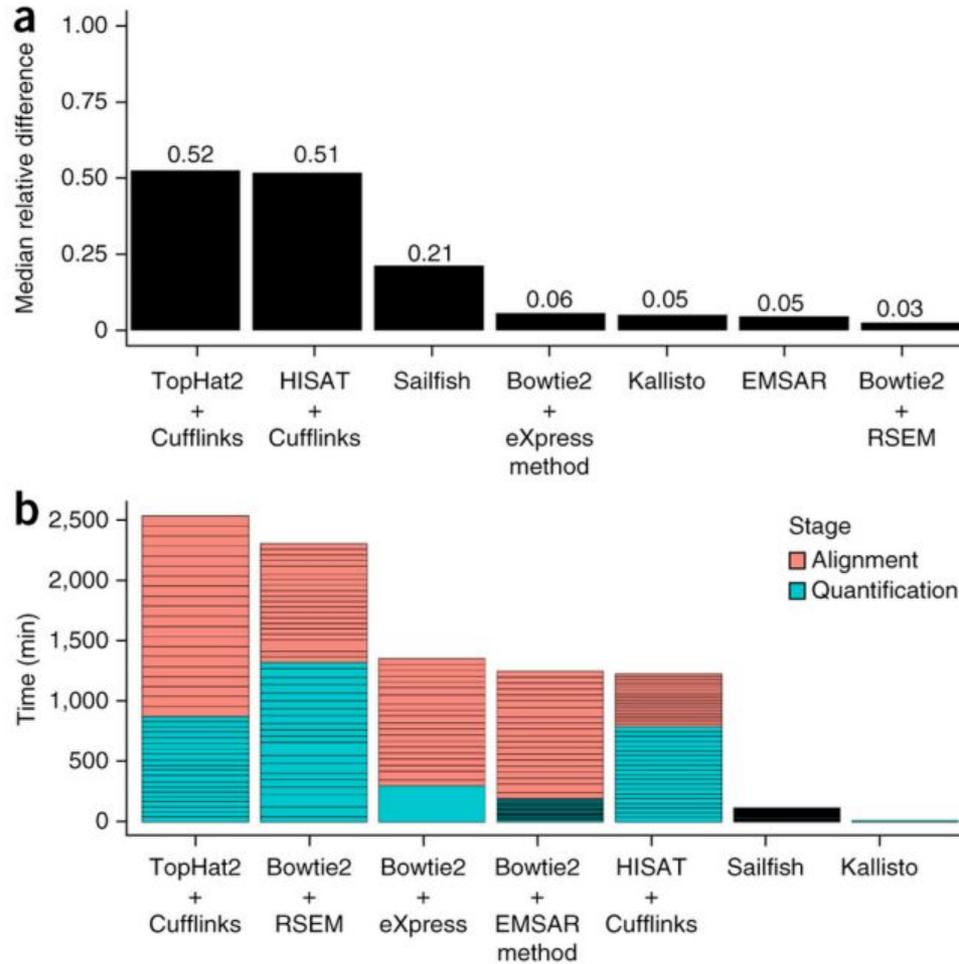


c

FDR	Sensitivity at given FDR			
	Salmon	Salmon (a)	kallisto	eXpress
0.01	0.326	0.233	0.072	0.128
0.05	0.409	0.379	0.248	0.162
0.1	0.454	0.442	0.296	0.211

d

Type	Salmon	Salmon (a)
All transcripts	1,183	1,197
Two-isoform genes	228	244
Type	kallisto	eXpress
All transcripts	2,620	2,472
Two-isoform genes	545	531



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

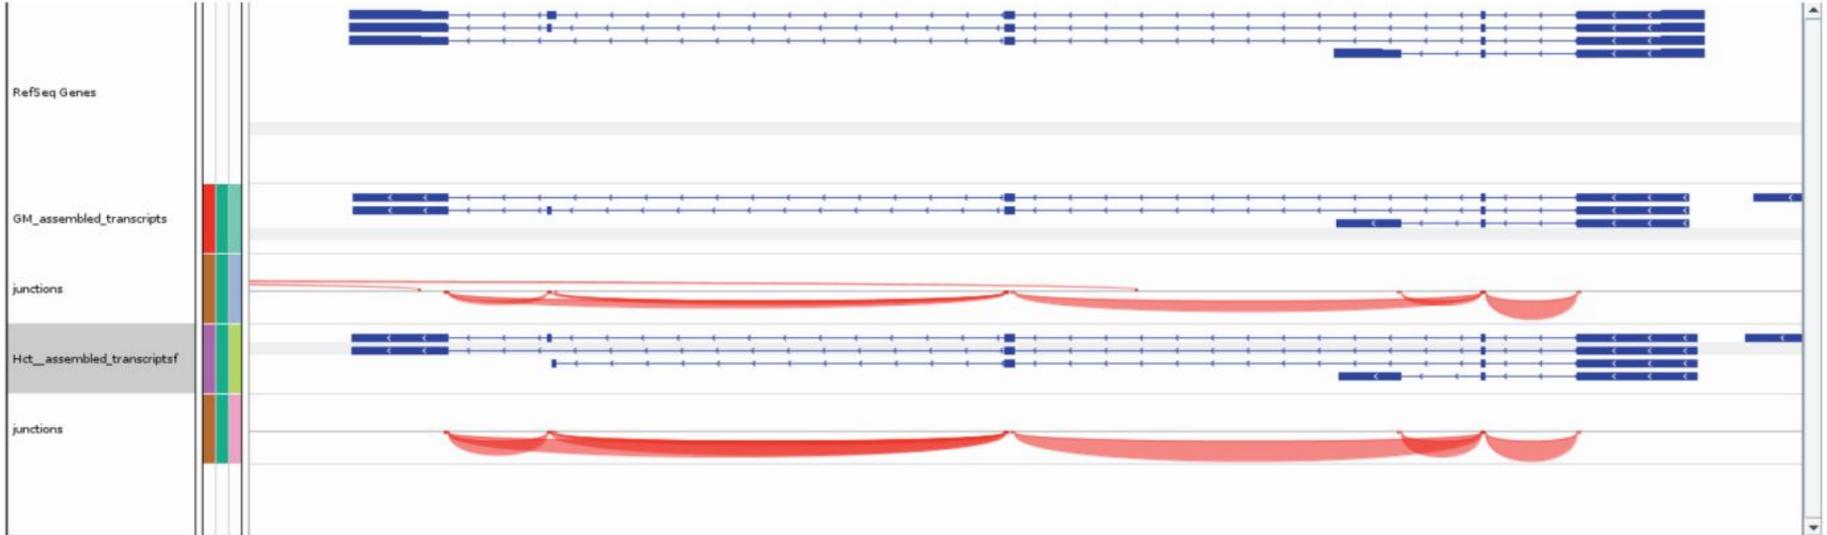
gff3

Seqname	Source	Score	Strand	Frame	Attribute		
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

The following table shows the code used by Cufflinks to classify the transcripts in comparison with the reference annotation

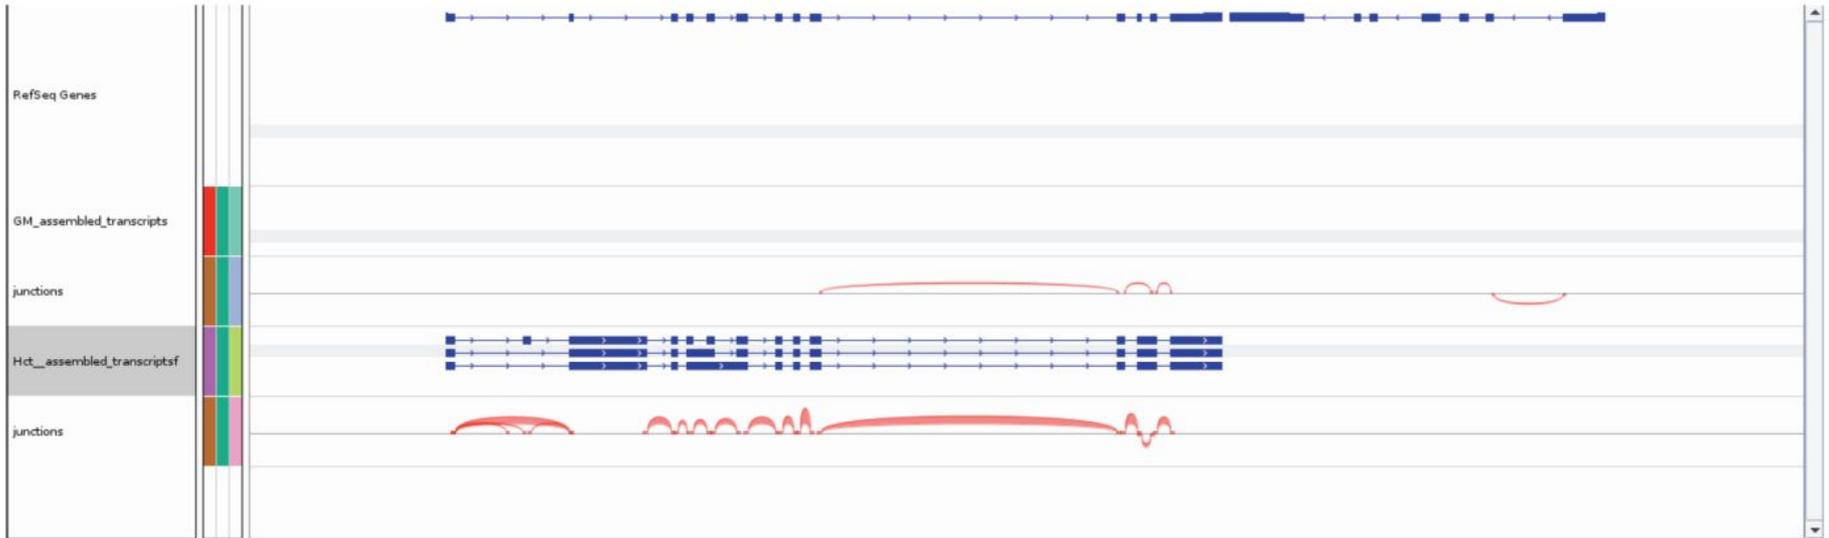
Priority	Code	Description
1	=	Complete match of intron chain
2	c	Contained
3	j	Potentially novel isoform (fragment): at least one splice junction is shared with a reference transcript
4	e	Single exon transfrag overlapping a reference exon and at least 10 bp of a reference intron, indicating a possible pre-mRNA fragment
5	i	A transfrag falling entirely within a reference intron
6	o	Generic exonic overlap with a reference transcript
7	p	Possible polymerase run-on fragment (within 2Kbases of a reference transcript)
8	r	Repeat. Currently determined by looking at the soft-masked reference sequence and applied to transcripts where at least 50% of the bases are lower case
9	u	Unknown, intergenic transcript
10	x	Exonic overlap with reference on the opposite strand
11	s	An intron of the transfrag overlaps a reference intron on the opposite strand (likely due to read mapping errors)
12	.	(.tracking file only, indicates multiple classifications)

=



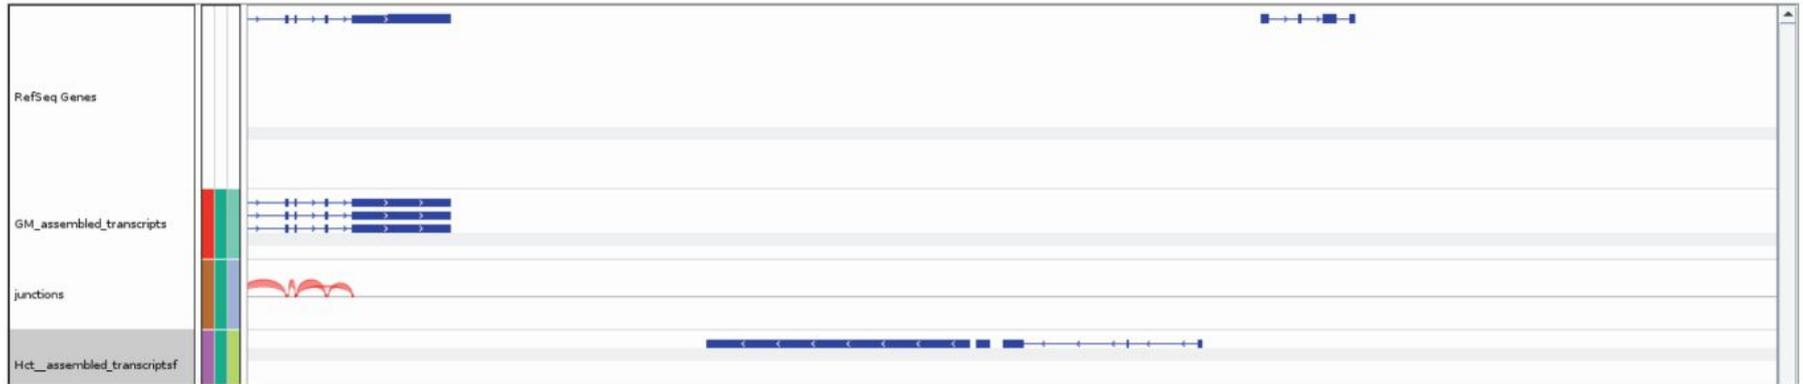
Complete match of intron chain

J

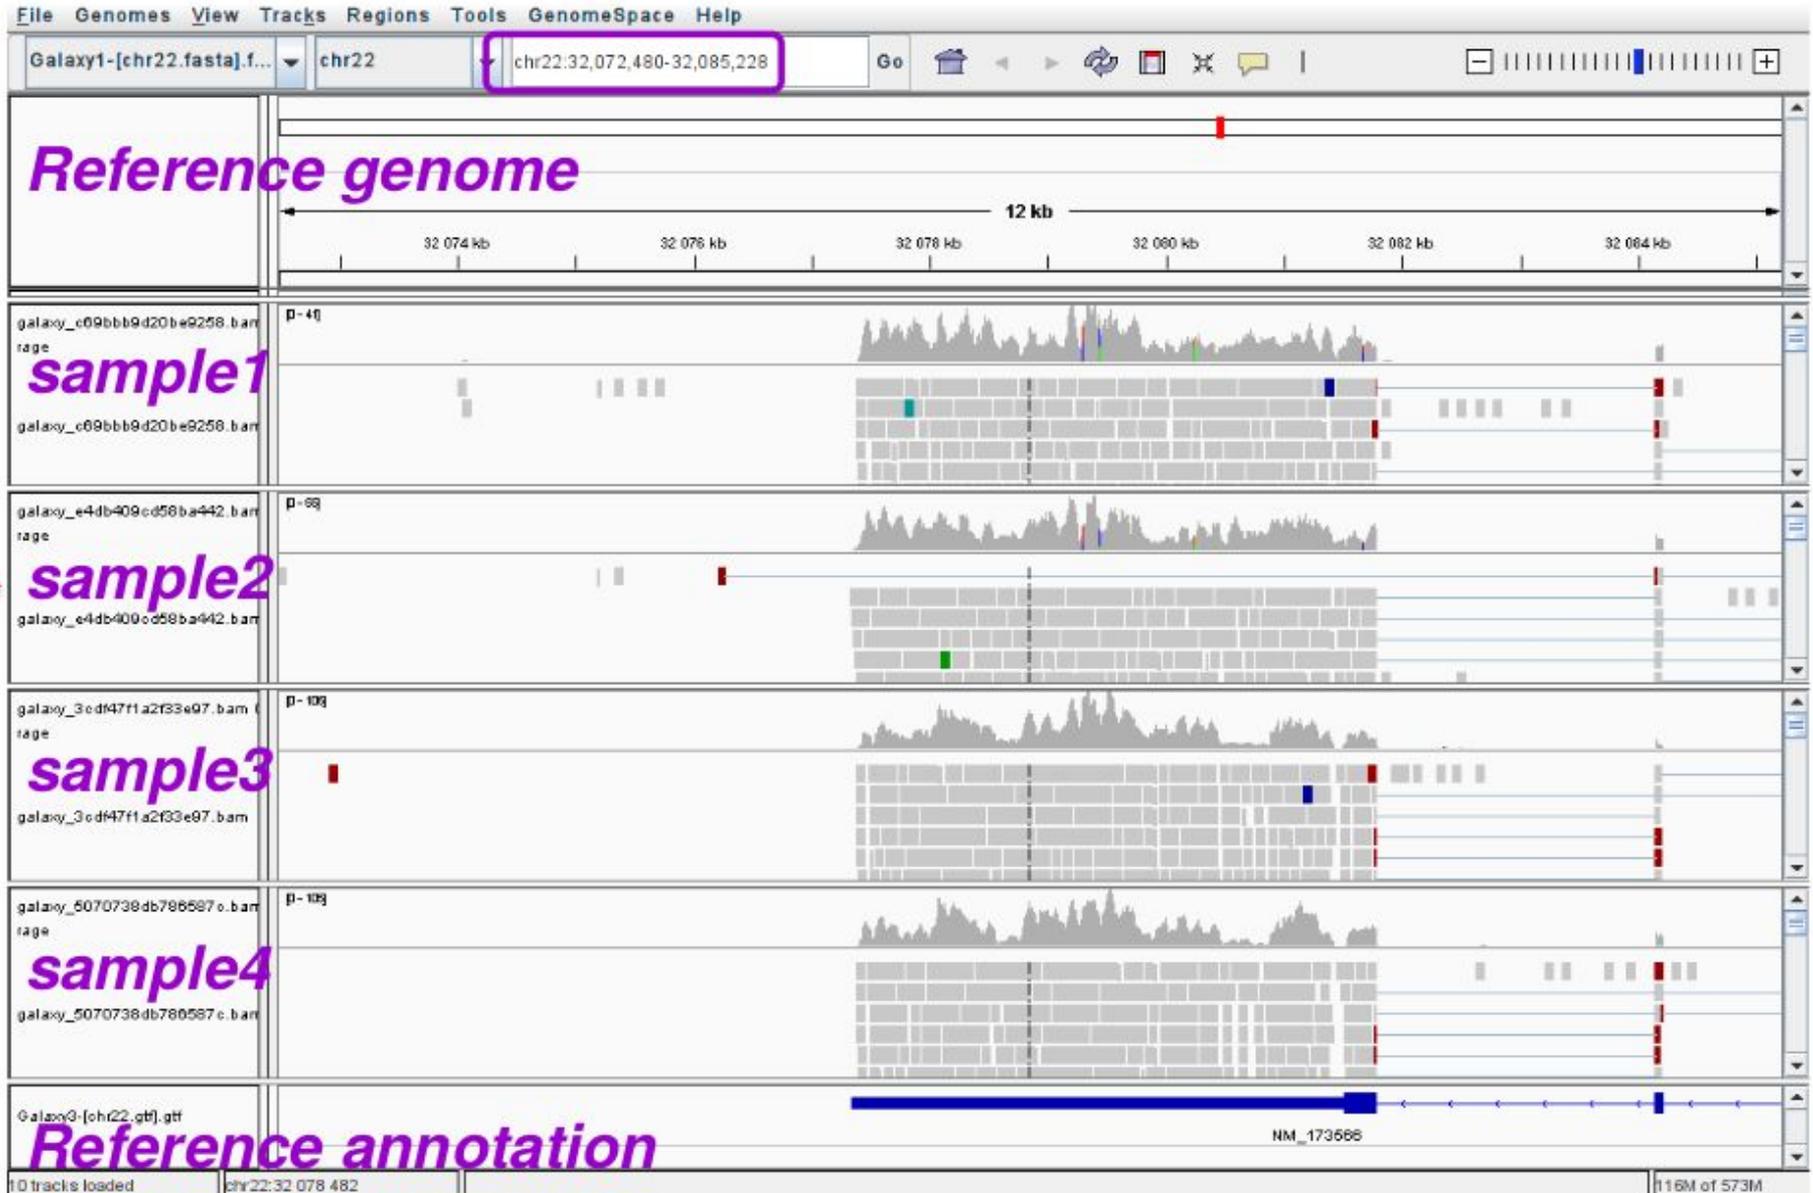


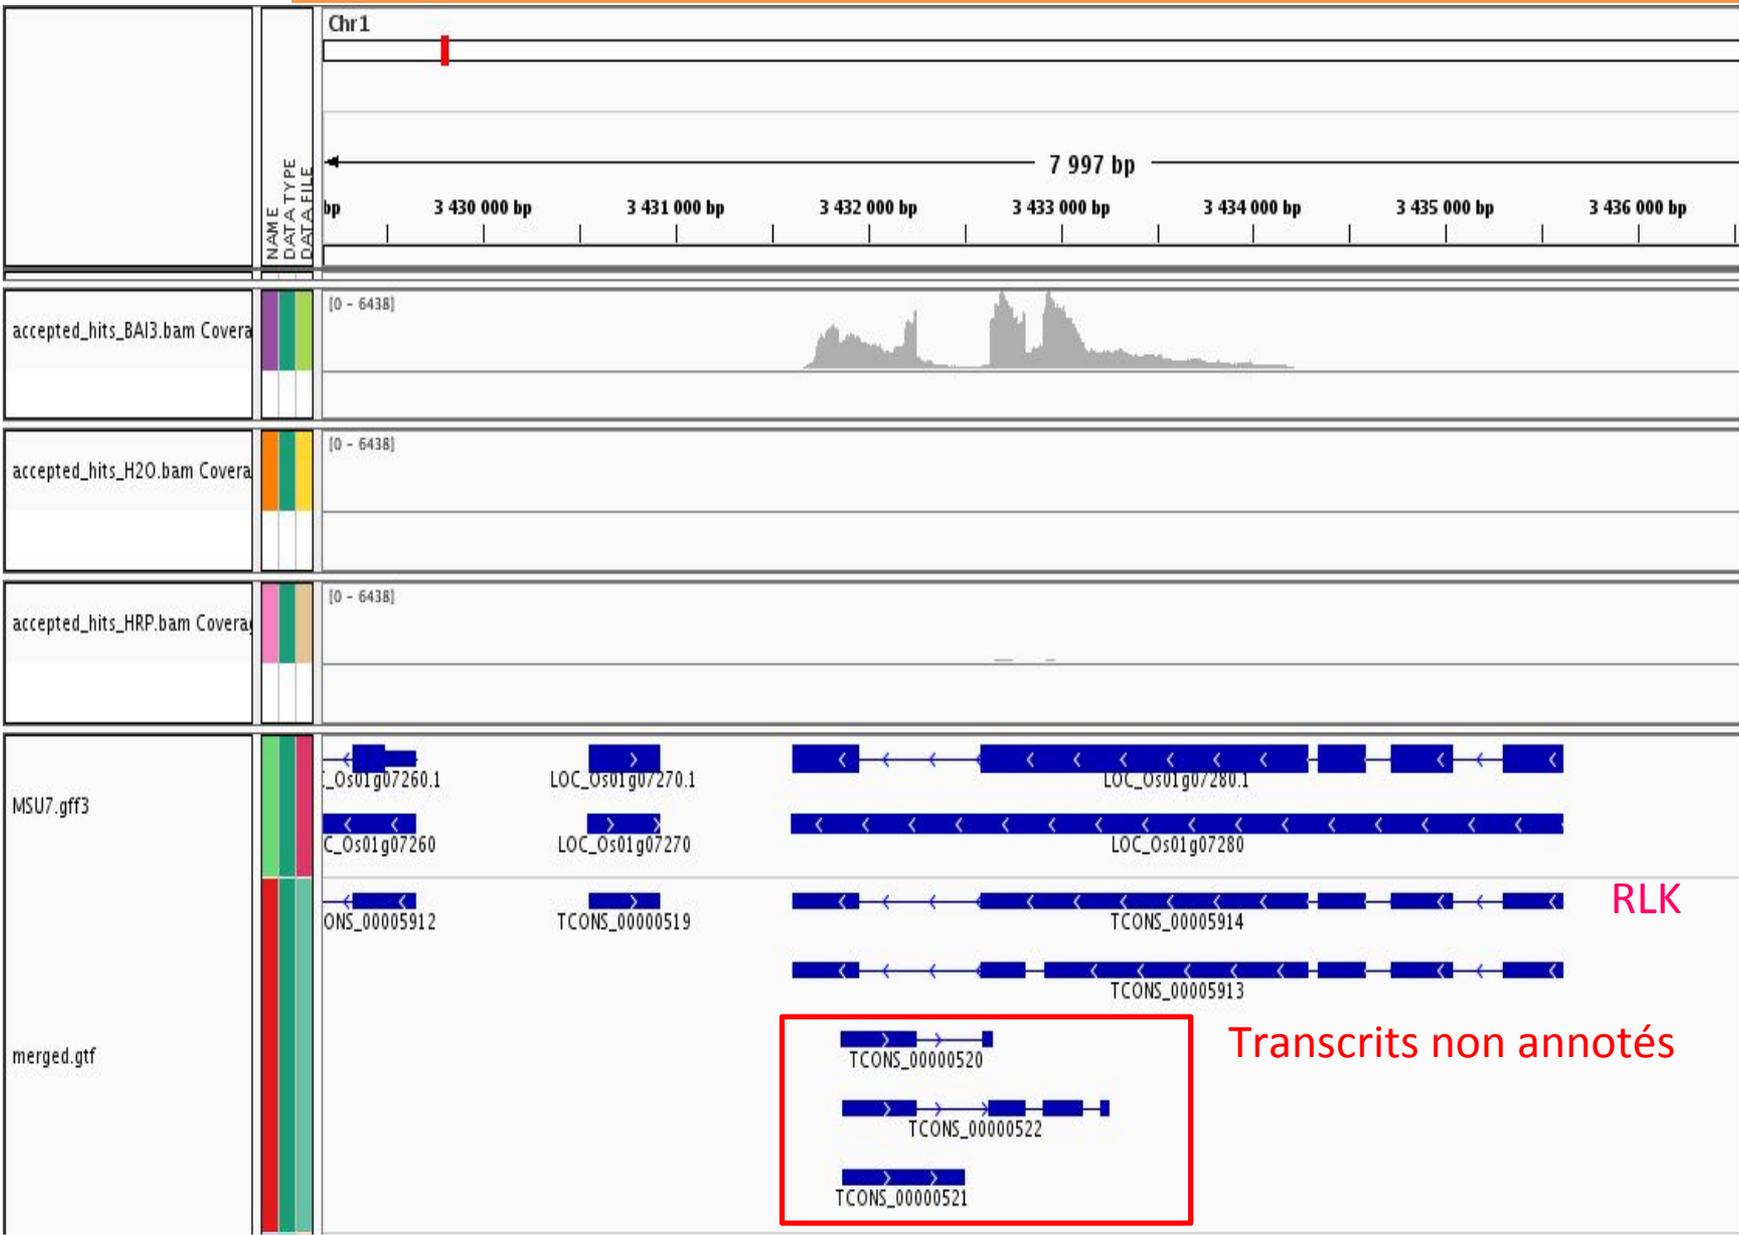
Potentially novel isoform (fragment): at least one splice junction is shared with a reference transcript

U



Unknown, intergenic transcript





Practice : Galaxy and TOGGLE

[TP-Galaxy-TOGGLE](#)

4- Normalisation des données

- Identifier et corriger les biais techniques dus au séquençage, pour les rendre comparable
- Types de Normalisation : intra-echantillons (meme sequençage) et inter-echantillons (deux sequençages)

Taille de la banque
Longueur de gènes
Composition en GC des gènes




	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.



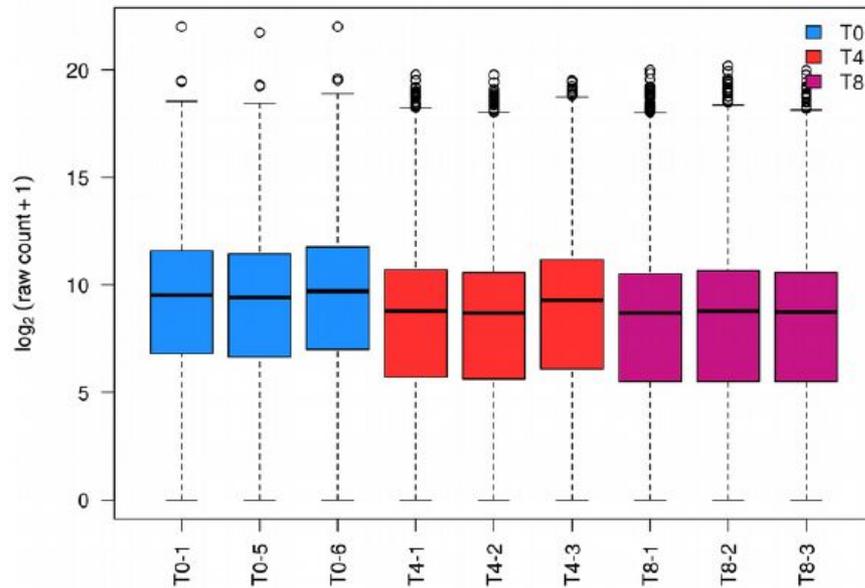
Le gène A est exprimé dans les échantillons 2 et 3, mais la profondeur de séquençage est plus importante dans l'échantillon 3 que dans le 2 (différences de taille des librairies).



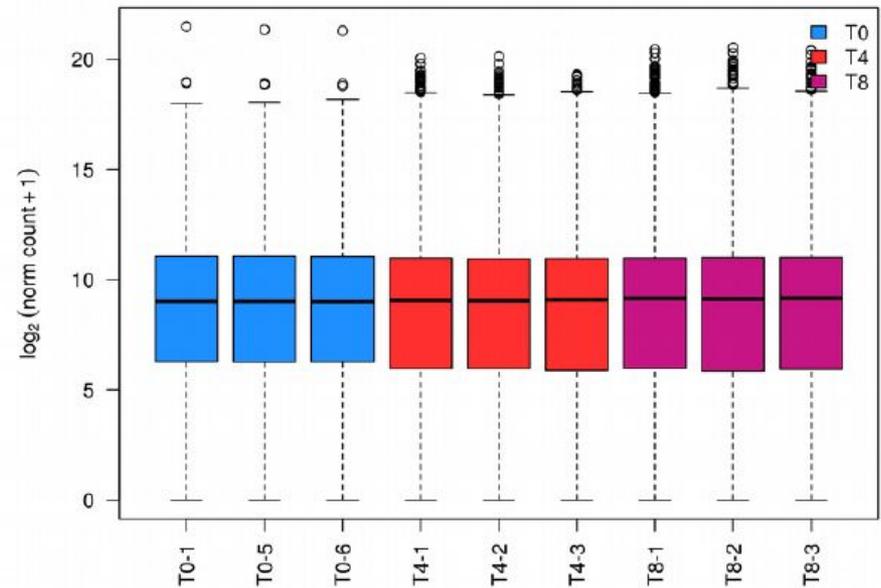
- Permettre la comparaison de gènes pour différents échantillons.
- Les sources de variabilités : taille des librairies

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

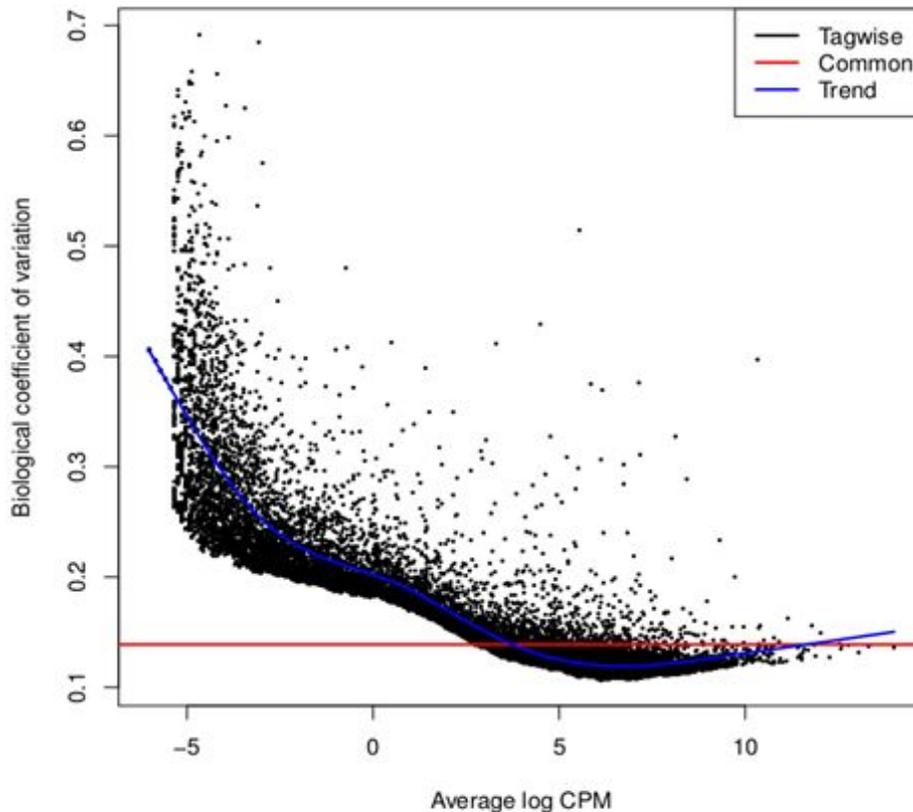
Raw counts distribution



Normalized counts distribution



EdgeR



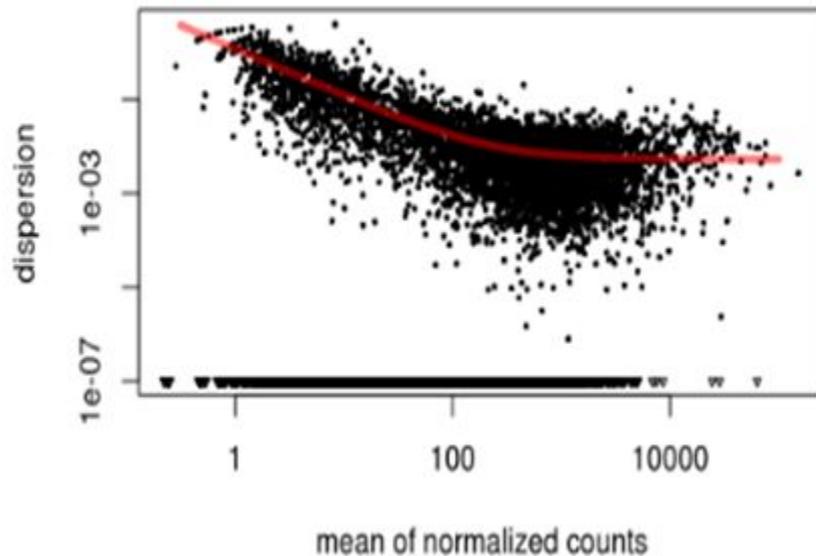
Estimation de la dispersion
(entre réplicats biologiques)

- 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



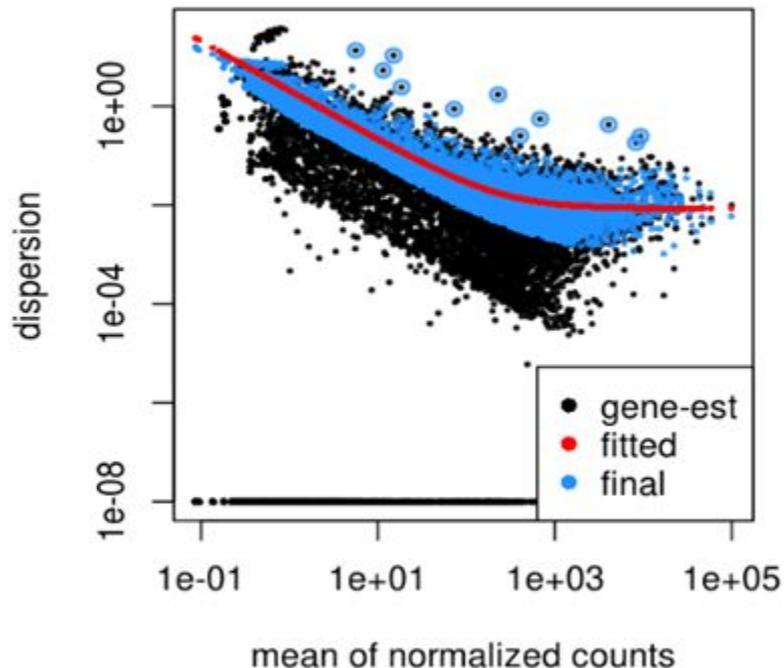
Estimation de la dispersion

- 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

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, même s'il y a une grande différence entre conditions.

A l'opposé, quand la variabilité intra-condition est plus faible, DESeq fait plus confiance et sélectionne même les gènes qui ont un fold-Change plus faible que ceux sélectionnés par EdgeR.

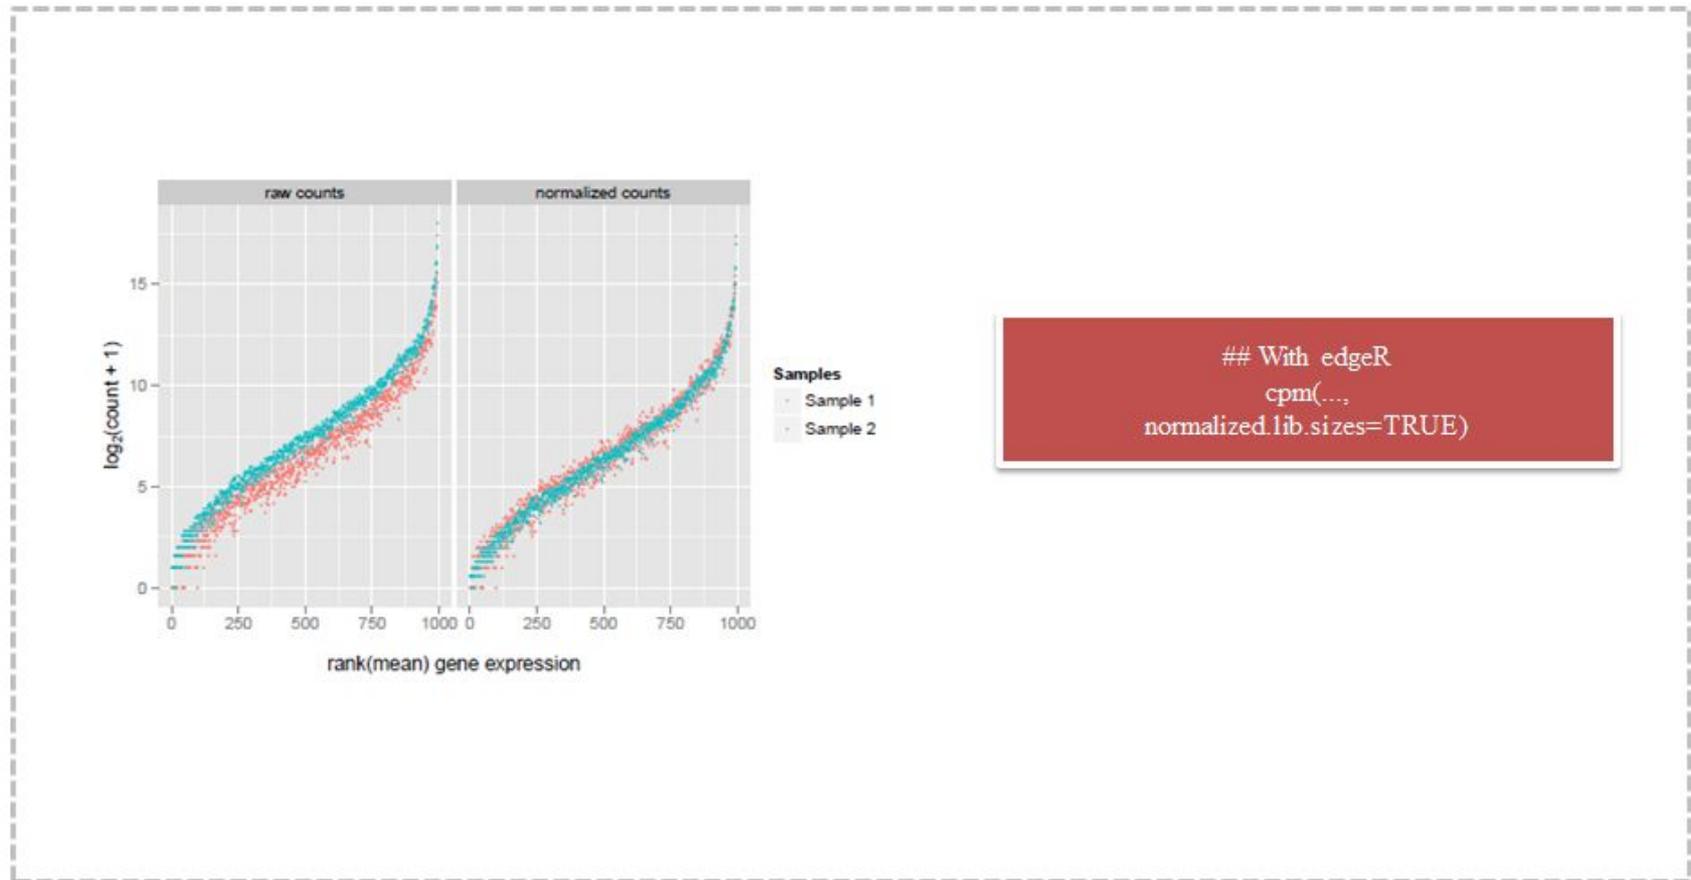
=> DESeq à privilégier pour des expérimentations très répétables

DESeq2 plus souple, sera moins stringent et détectera plus de gènes différentiellement exprimés.

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 librairies.

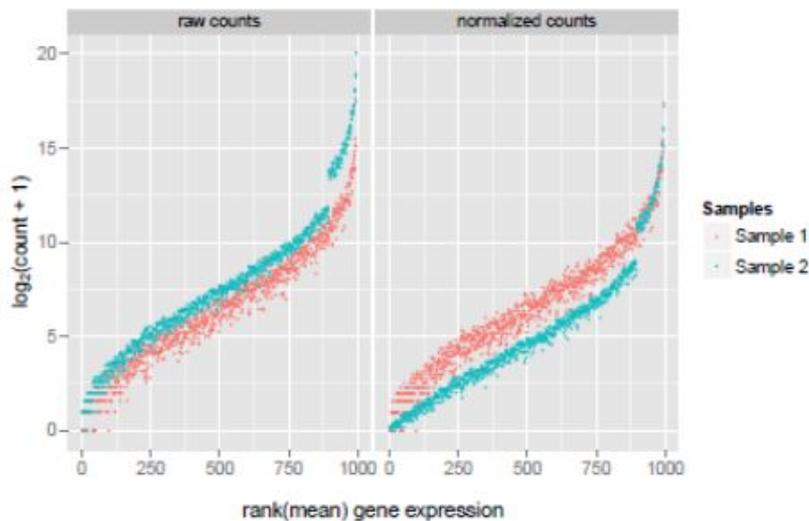
Ref : Mortazavi et al., 2008



Upper Quartile

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.

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



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

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

Méthodes de normalisation :

2) Reads Per Kilobase per Million (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 gènes

=> mélange de normalisation inter et intra-banque

=> permet de comparer des gènes entre eux mais pas forcément nécessaire pour comparer 2 conditions sur un même gène

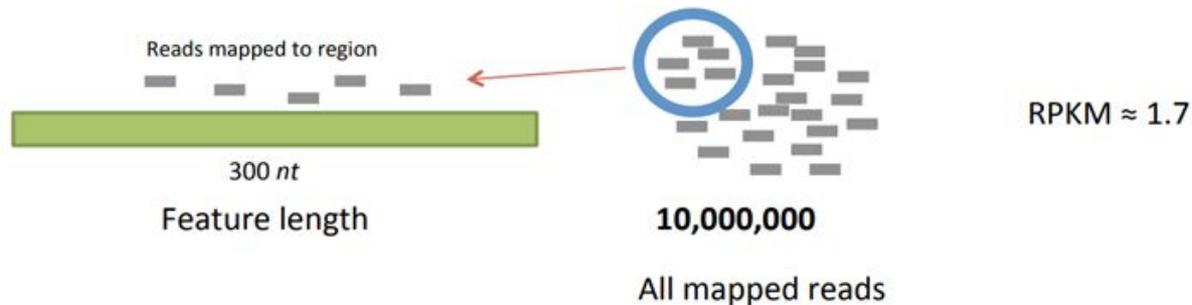
3) Normalisation prenant en compte le biais associé à la composition en GC

- méthode du Total Count peu efficace (pas de prise en compte des différences possibles entre les compositions en ARN des conditions)
- méthode RPKM peu efficace (même dans les cas où un biais lié à la longueur des gènes existe, l'utilisation du RPKM ne permet pas de le corriger complètement)
- méthodes à privilégier : Upper-Quartile, RLE, TMM

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.



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

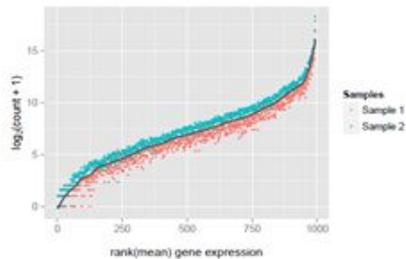
RPKM: Reads Per Kilo base of transcript per Million reads

RLE

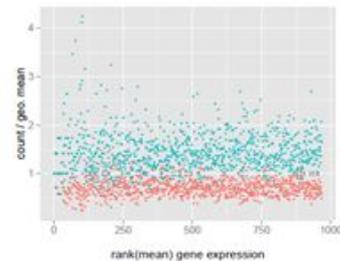
La normalisation RLE (Relative Log Expression) a été développée dans le package Bioconductor DESeq. Elle se base sur l'hypothèse selon laquelle la plupart des gènes ne sont pas différentiellement exprimés. Le facteur de normalisation pour un échantillon est obtenu en calculant pour chaque gène le ratio 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 ratios constitue une estimation du facteur correctif qui doit être appliqué à l'ensemble des comptages.

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

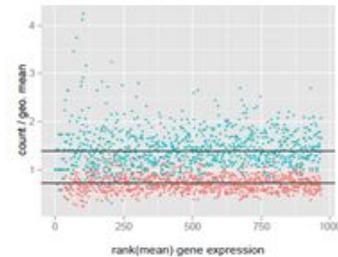
1 – Calcule une pseudo référence



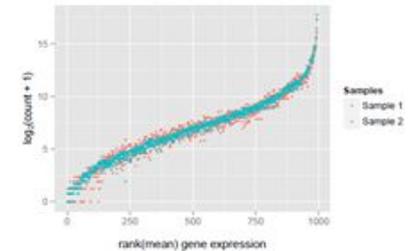
2 – Centre les échantillons comparés à la référence



3 – Calcule un facteur de normalisation : médiane des ratios 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.

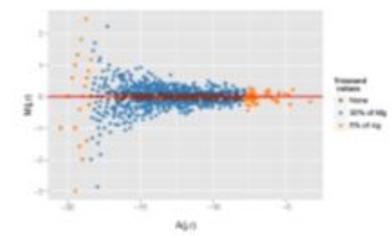
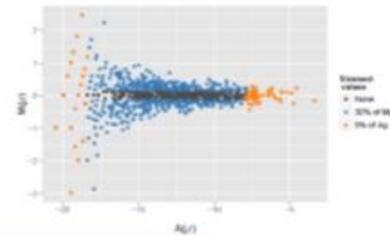
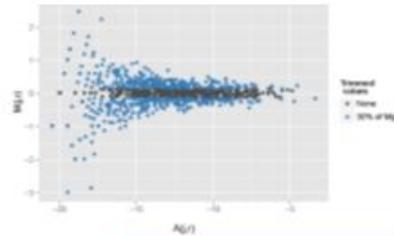
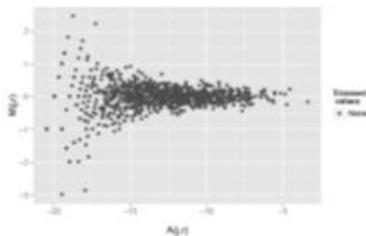
Ref : Robinson, M. and Oshlack, A. (2010). Dans edgeR.

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

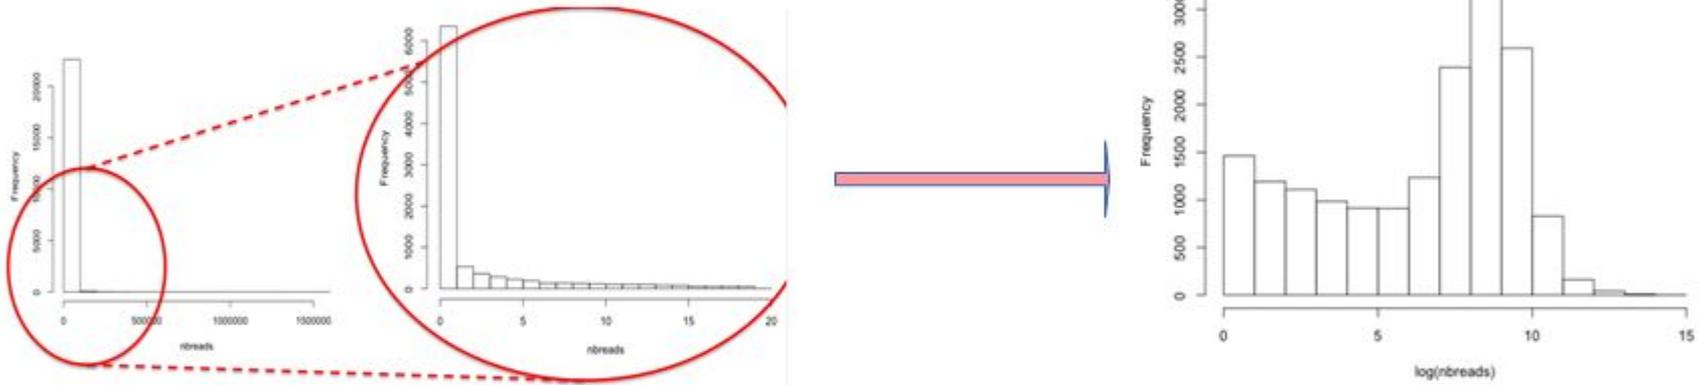


```
## With edgeR
calcNormFactors(..., method="TMM")
```

- **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

5- Recherche de gènes différentiellement exprimés

- Utilisation non pas du nombre de reads mais de $\log(\text{nb reads})$ pour que cela suive une loi statistique
- + nécessité de transformer les « 0 »
- => loi binomiale négative



- Utilisation du $\log(\text{FoldChange})$

Fold Change = ratio entre les 2 niveaux d'expression
 = ratio de la valeur finale sur la valeur initiale

pvalue= risque/probabilité de déclarer un gène différentiellement exprimé alors qu'il ne l'est pas

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

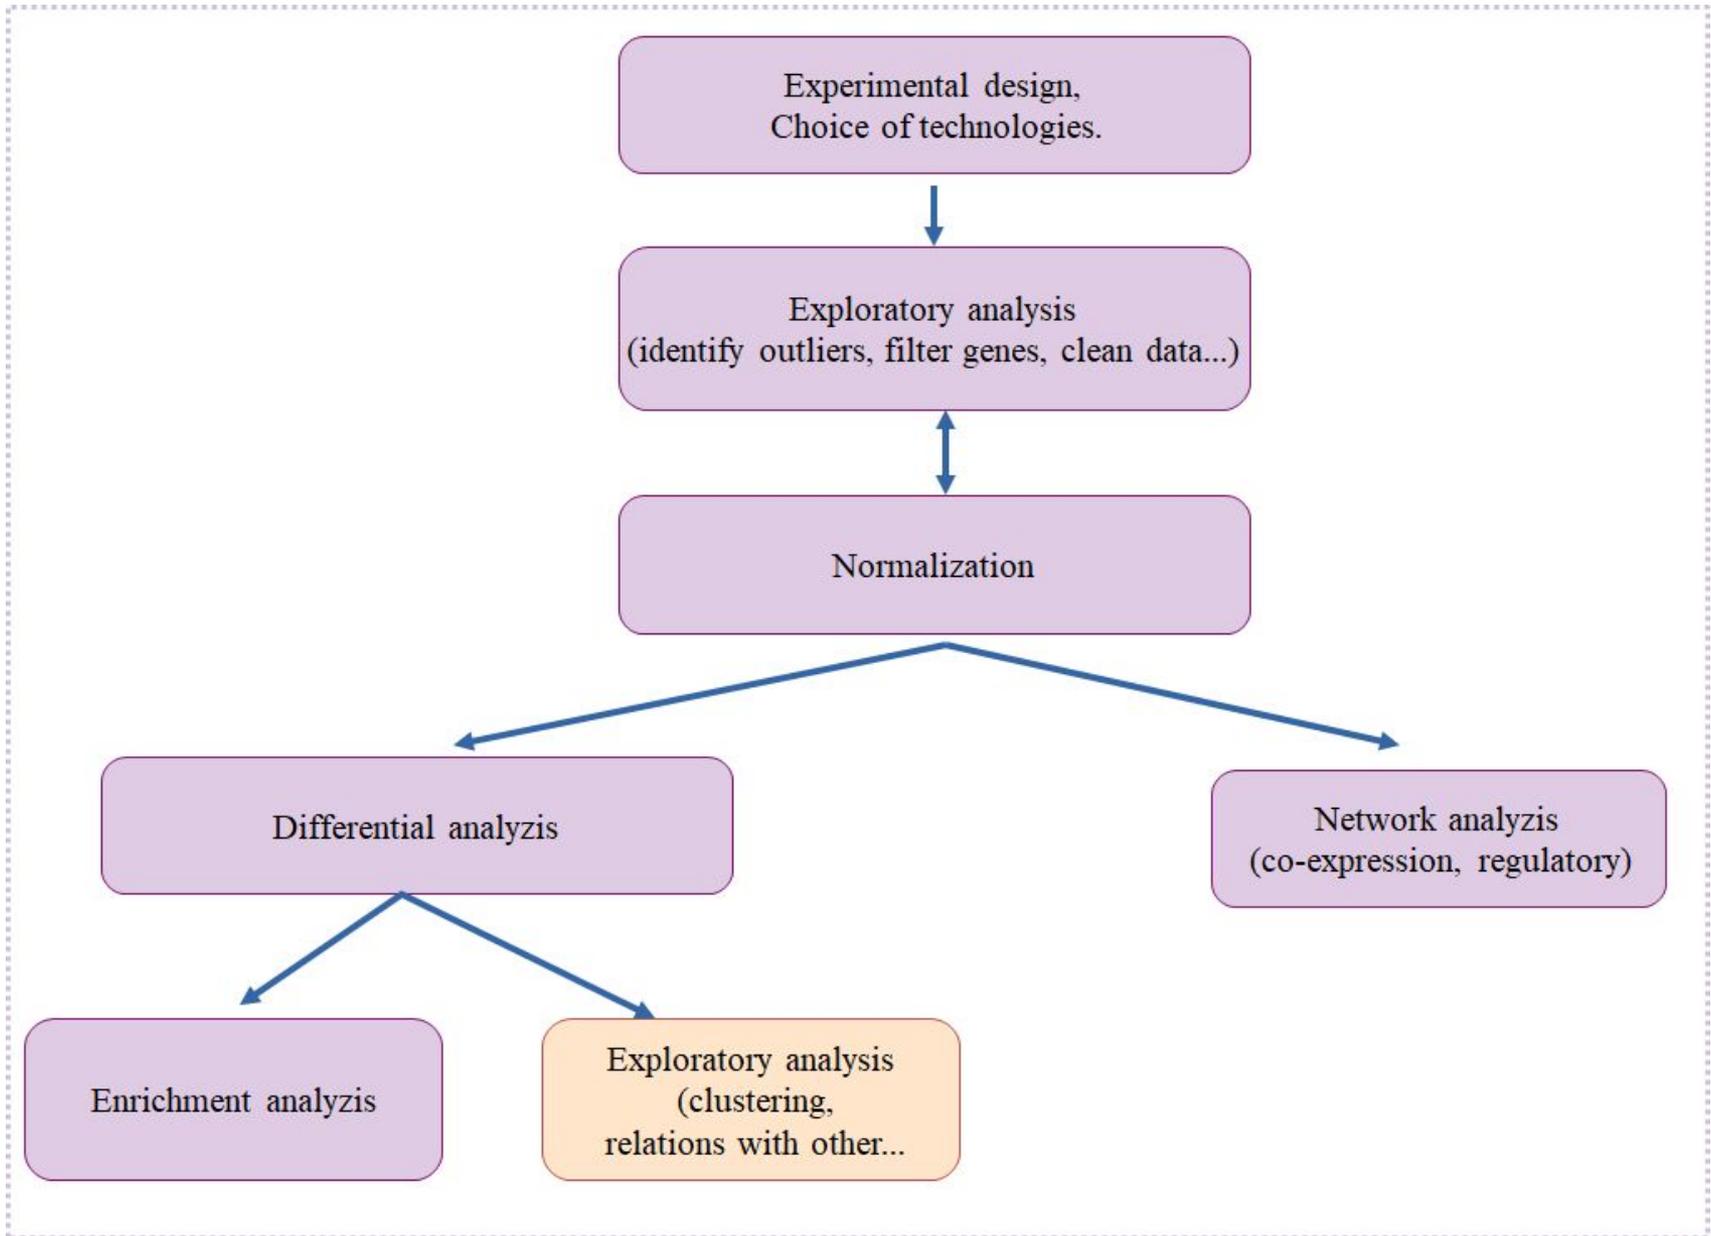
=> Problème des tests multiples: si on teste 10000 gènes non différentiellement exprimés, on autorise 500 gènes à être déclarés DE alors qu'ils ne le sont pas

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

=> besoin de correction et utiliser une pvalue 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)

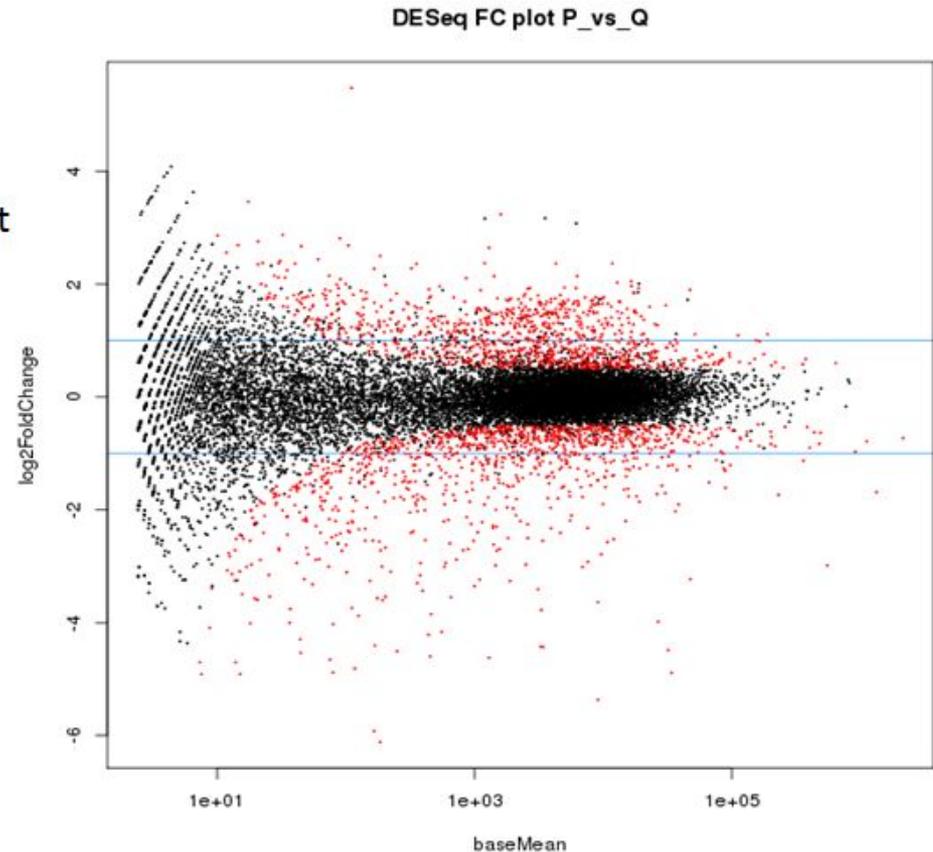
6- Plots and Graphical Représentations



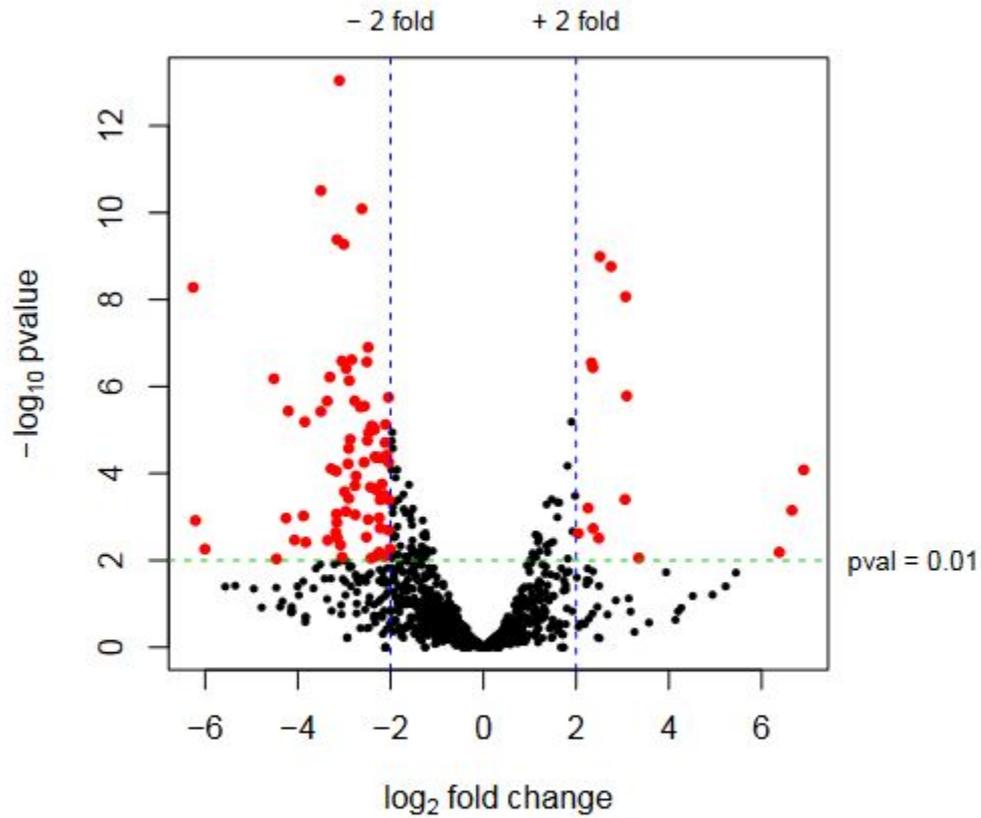
Smear plot / MA plot
 Pvalue adj < 0.05

MA plot

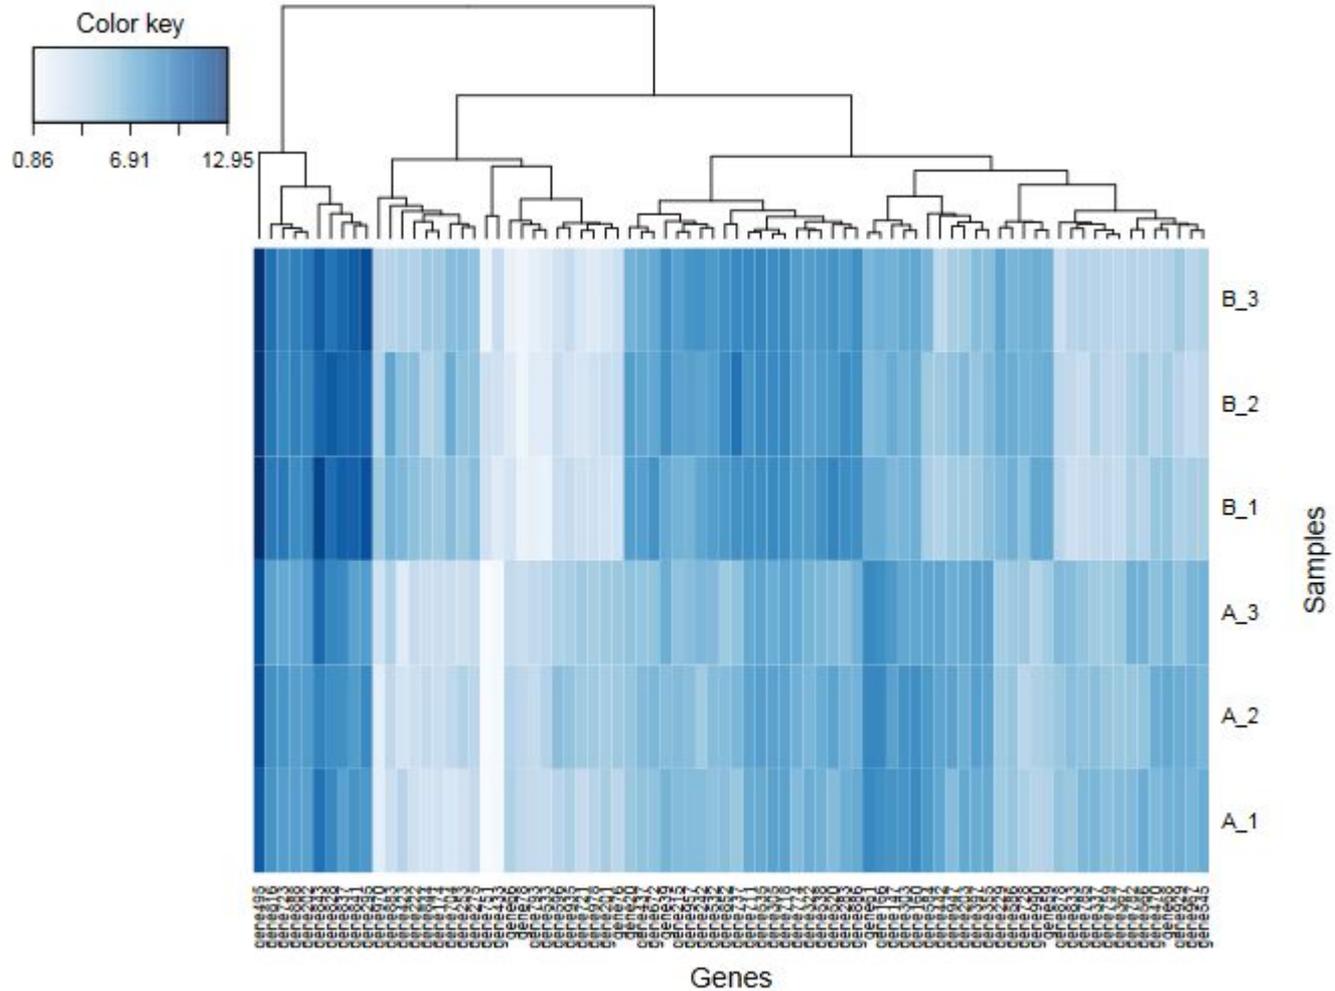
Le MA plot est un graphe qui était initialement utilisé dans les analyses de puce à ADN. C'est un nuage de points représentant en abscisse l'expression moyenne du gène à travers les différents échantillons, et en ordonnée le log-ratio des expressions moyennes d'une condition par rapport à l'autre. En 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).



Volcano plot
Pvalue adj < 0.01



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



Practice : R et PIVOT

[TP Pivot](#)



Alexis Dereeper



Sebastien Ravel



Christine Tranchant-Dubreuil



Sebastien Cunnac



Gautier Sarah



Julie Orjuela-Bouniol



Catherine Breton



Aurore Compte



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/>