

# CRCM

Centre de Recherche  
en Cancérologie de Marseille

---

Les mardis de la technologie gourmande de DISC

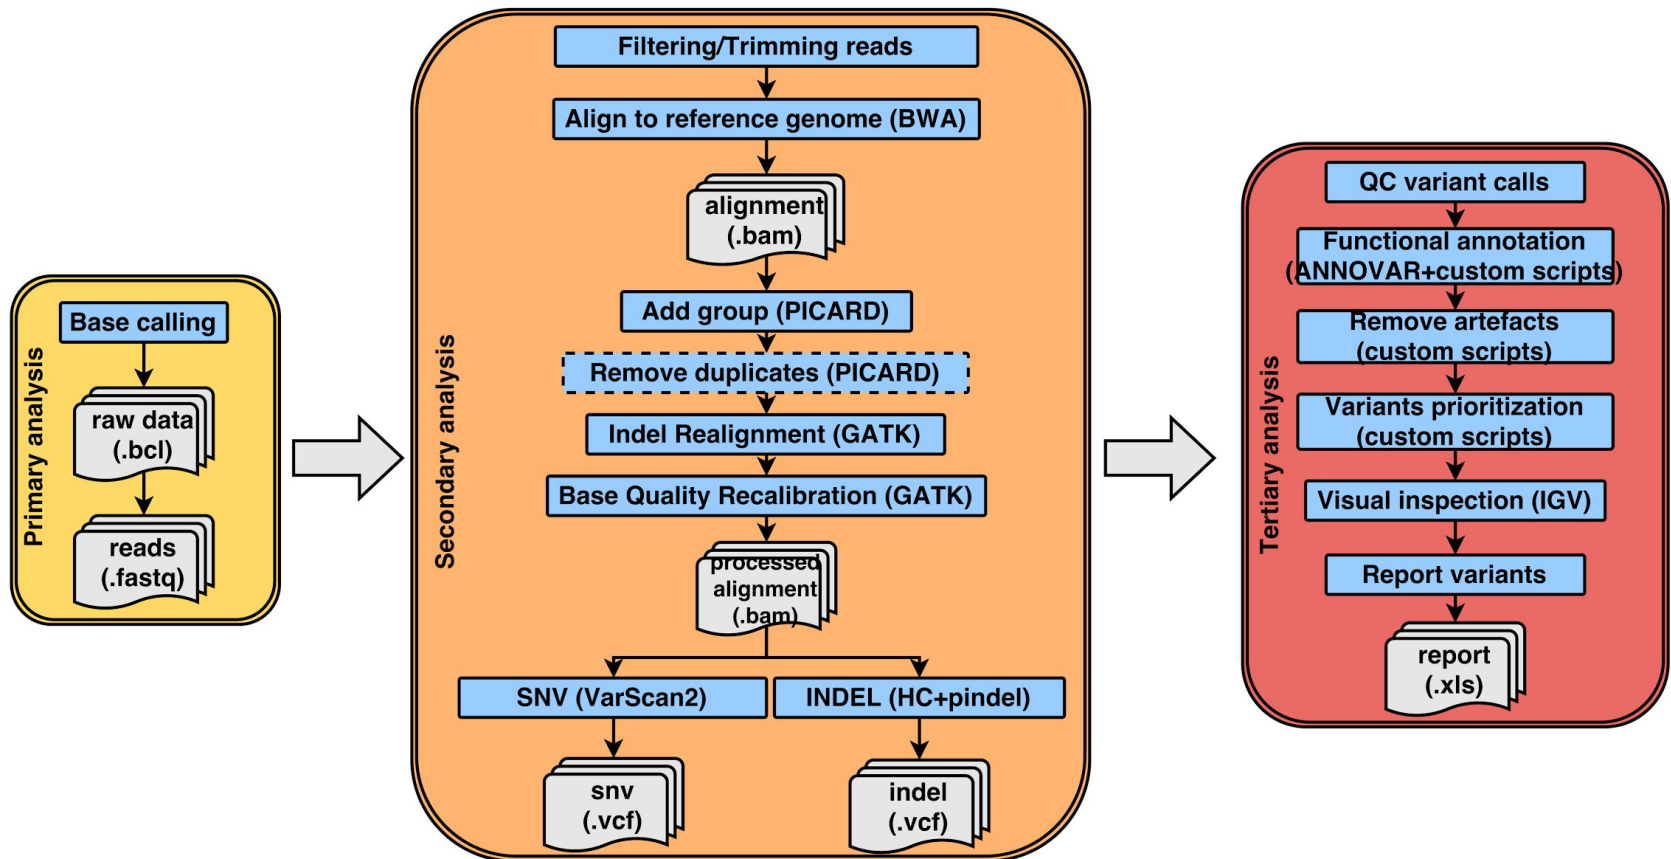
## Analyse bio-informatique appliquée à la détection de variants (NGS)

### Besoins et Solutions


---

Arnaud Guille

# Workflow



# Analyse primaire : Base-calling



- Déconvolution du signal en séquence ATCG
- Assignation d'un score de qualité à chaque base (score phred)
- Généralement réalisé par le séquenceur lui même
- Fichier Fastq en sortie

# Format : Fastq

- **Description**

Read ID

Sequence

Quality


```
@NS500754:36:H7GL7AFX:1:11101:12209:1023 1:N:0:AACGTGAT
ACATCNCCTAGGAAATAGCAGGTA CTCAATGTAAGTAGATCCTACATT
+
AAAAA#EEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEEE
```

- Inventé dans les années 90 par Jim Mullikin
- Séquence et score codées avec un seul caractères ASCII

- **Score Phred**

- $Q = -10 * \log_{10} p$
- « A »  $\Leftrightarrow$  65  $\Leftrightarrow$  Q32  $\Leftrightarrow$   $p = 6,3e-4$  (phred +33)

# Analyse secondaire : Contrôle qualité et trimming





- **Contrôle qualité des reads avec FastQC**
- **Les extrémités des reads sont souvent de moins bonne qualité**
- **Trimming des reads avec Trimmomatic**

# Analyse secondaire : L'alignement

	Bowtie	BWA	SOAP2	MAQ	RMAP	GSNA P	FANGS	Novoalign	mrFAST
Seed mm.	Up to 3	Any	Up to 2	Any	Any				
Non-seed mm.	QS	Count	Count	QS	Count	Count	Count	QS	Count
Var. seed len.	> 5	Any	> 28						
Mapping qual.		Yes		Yes				Yes	
Gapped align.		Yes	PE	PE		Yes	Yes	Yes	Yes
Colorspace	Yes	Yes		Yes				Yes	
Splicing						Yes			
SNP tolerance						Yes			
Bisulphite reads					Yes	Yes		Yes	Yes

# Analyse secondaire : L'alignement



# Format : SAM/BAM

- **SAM (Sequence Alignment Map)**

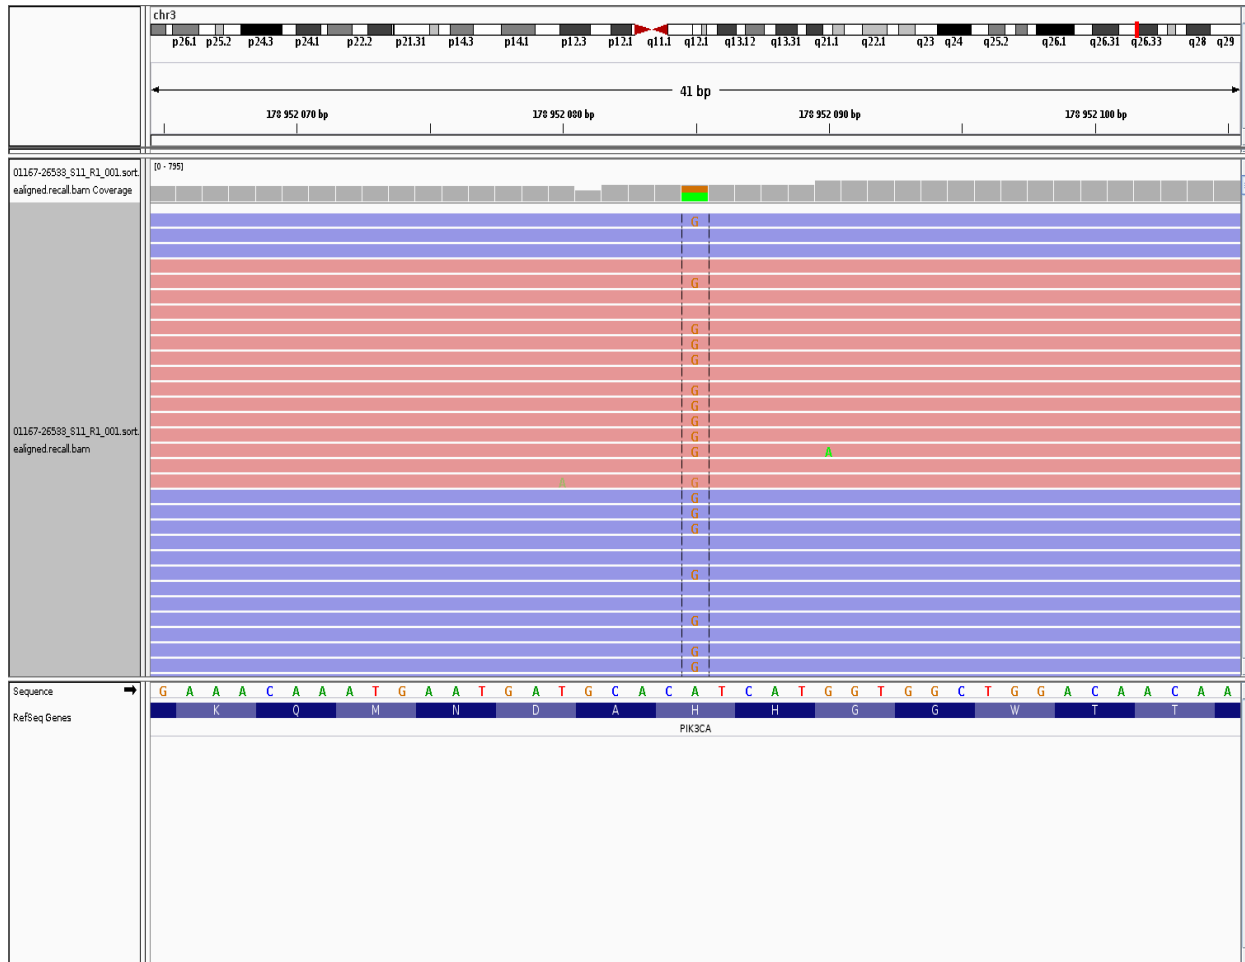
Col	Field	Type	Regexp/Range	Brief description
1	QNAME	String	[!-?A-~]{1,254}	Query template NAME
2	FLAG	Int	[0,2 <sup>16</sup> -1]	bitwise FLAG
3	RNAME	String	\*  [!-( )+-<>-~] [!-~]*	Reference sequence NAME
4	POS	Int	[0,2 <sup>31</sup> -1]	1-based leftmost mapping POSition
5	MAPQ	Int	[0,2 <sup>8</sup> -1]	MAPping Quality
6	CIGAR	String	\*  ([0-9]+[MIDNSHPX=])+	CIGAR string
7	RNEXT	String	\*  =  [!-( )+-<>-~] [!-~]*	Ref. name of the mate/next read
8	PNEXT	Int	[0,2 <sup>31</sup> -1]	Position of the mate/next read
9	TLEN	Int	[-2 <sup>31</sup> +1,2 <sup>31</sup> -1]	observed Template LENgth
10	SEQ	String	\*  [A-Za-z=.]+	segment SEQUENCE
11	QUAL	String	[!-~]+	ASCII of Phred-scaled base QUALity+33

- **BAM**

- Format binaire
- Compact (~ 80 % plus petit)
- Peut être indexé



# Visualisation : SAM/BAM



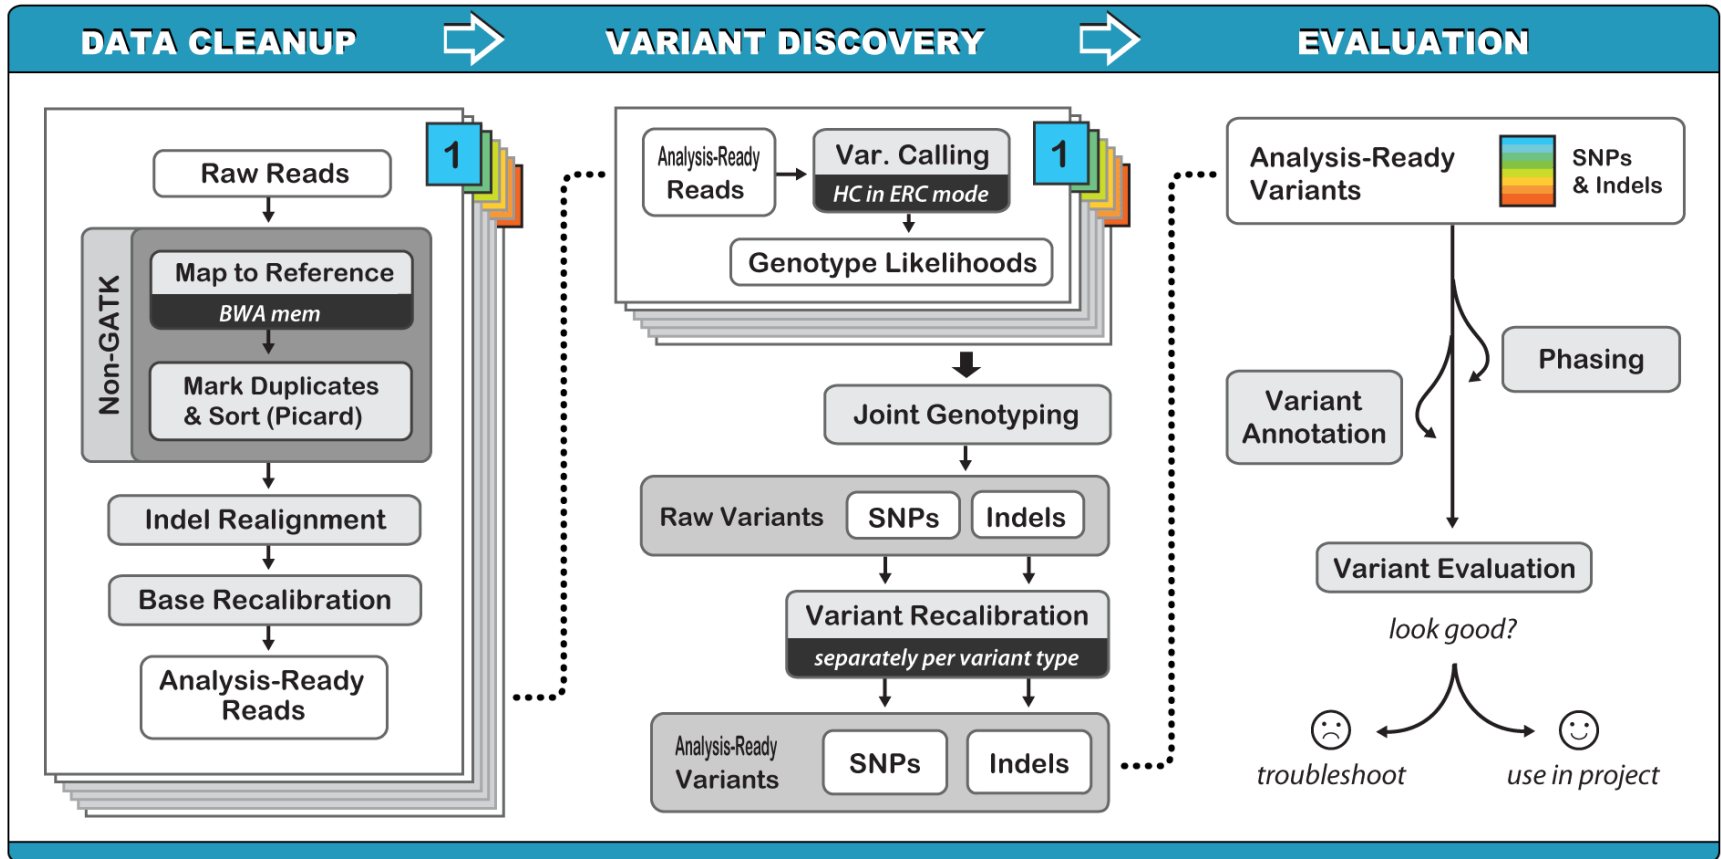
# API/Outils de manipulation : SAM/BAM

---

- **Samtools (C)**
  - index, stats, view, sort, merge, mpileup, etc ....
- **Picard tools (java)**
  - AddOrReplaceReadGroups, SortSam, MarkDuplicates, etc ...
- **Pysam (Python)**

```
import pysam
samfile = pysam.AlignmentFile("ex1.bam", "rb")
pairedreads = pysam.AlignmentFile("allpaired.bam", "wb",
template=samfile)
for read in samfile.fetch():
    if read.is_paired:
        pairedreads.write(read)
pairedreads.close()
samfile.close()
```

# Analyse secondaire : GATK Best Practices



# Analyse secondaire : Réalignement autour des indels

---

- **Ce que dit le GATK :**

## Answers



**Geraldine\_VdAuwera** Posts: **9,634** Administrator, Dev admin

September 2013

I'm not familiar enough with BWA mem to give you a definitive answer, but basically the key point is that traditionally mappers like BWA only align one read at a time, which is why realignment around indels is necessary to provide consistent mapping -- the indel realigner sees all the reads in a region, not just one. So it depends if BWA mem has that added capability. I'm not aware that it does, so I would still recommend doing indel realignment according to our best practices, but I could be wrong.

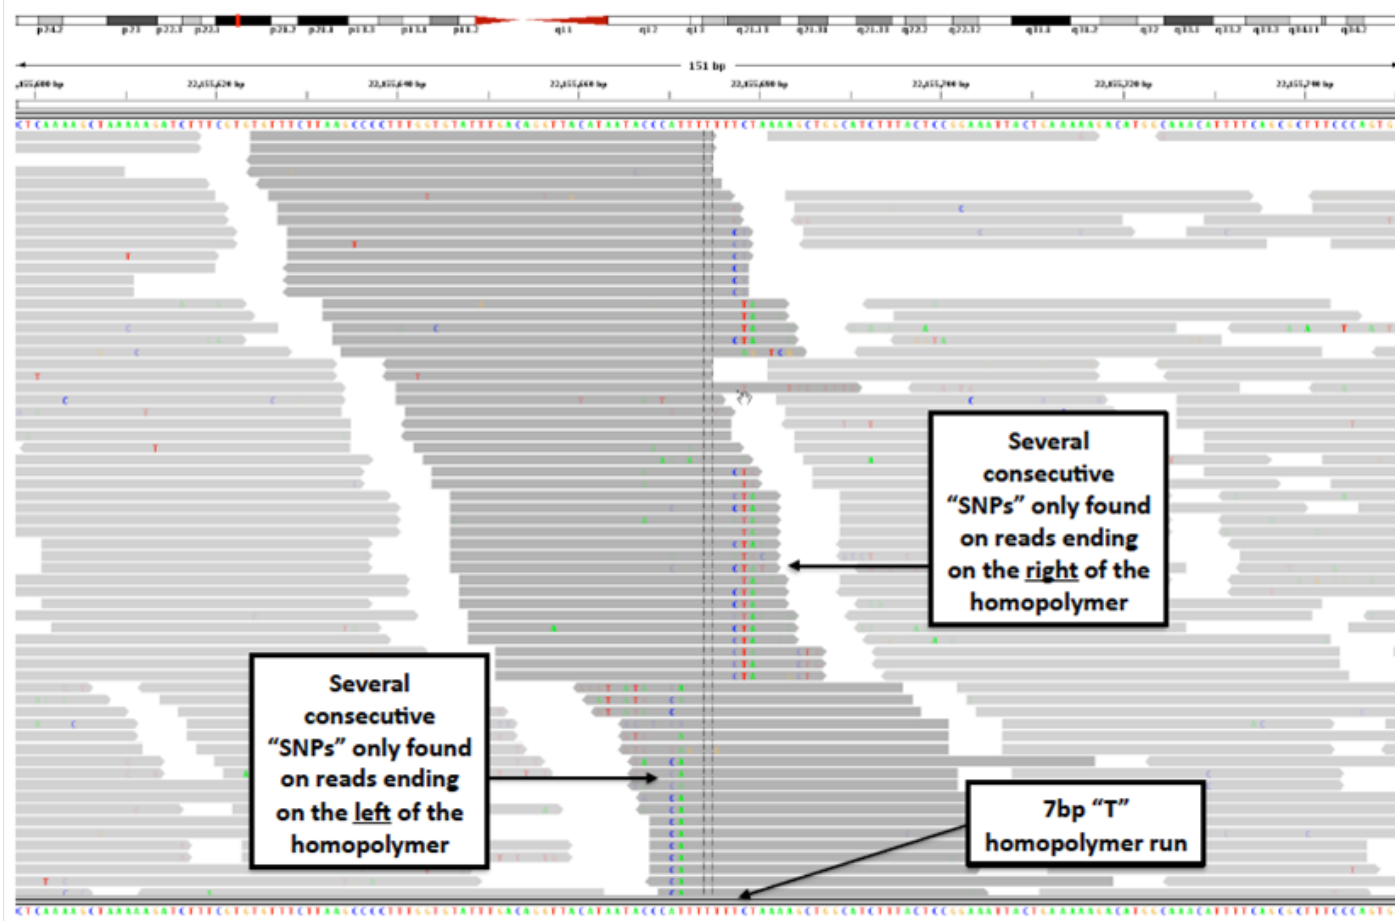
---

Geraldine Van der Auwera, PhD




# Analyse secondaire : Réalignement autour des indels

An example of a strand-discordant locus



# Analyse secondaire : Réalignement autour des indels

Local realignment uncovers the hidden indel in these reads and eliminates all the potential FP SNPs



# Analyse secondaire : Réalignement autour des indels

---

- **Comment ça marche :**
  - **Les régions avec des indel connus (1000g, dnSNP) et détectés sont ciblées.**
  - **Pour une région donnée, trouve la meilleur séquence consensus.**
  - **Le score de la séquence consensus est égal à la somme des qualités des bases ayant un mésappariement**
  - **Si le score du consensus est supérieur à celui de l'alignement de départ, le nouvel alignement est conservé**

# Analyse secondaire : Recalibration du score de qualité

---

- **Ce que dit le GATK :**
  - **Les constructeurs des séquenceurs actuels ont tendance à un peu trop sur-estimer les scores de qualité.**
  - **En général les séquenceurs actuels ont du mal dans les homopolymères**





# Analyse secondaire : Recalibration du score de qualité

---

- **Comment ça marche :**
  - Recherche des mésappariements dans l'alignement
  - Si un mésappariement n'est pas un variant connu alors on considère que c'est une erreur de séquençage
  - Calcul de covariance sur plusieurs caractéristiques (qualité des bases, position, cycle, contexte, etc ...)
  - Correction du score de qualité

# Analyse secondaire : Détection des variants

Name	OS	BAM/SAM input	Other inputs	Output	Identifies	Data set	Result <sup>a</sup>
<b>Germline callers</b>							
CRISP	Lin	Yes	–	VCF	SNP, INDEL	KTS	24 034 SNPs, 259 INDELS
GATK (UnifiedGenotyper)	Lin	Yes	–	VCF	SNP, INDEL	KTS	49 476 SNPs, 1959 INDELS
SAMtools	Lin	Yes	FASTA	VCF	SNP, INDEL	KTS	21 852 SNPs, 332 INDELS
SNVer	Lin, Mac, Win	Yes	–	VCF	SNP, INDEL	KTS	22 105 SNPs, 234 INDELS
VarScan 2	Lin, Mac, Win	No	pileup/mpileup	VCF, VarScan CSV	SNP, INDEL	KTS	34 984 SNPs, 1896 INDELS
<b>Somatic callers</b>							
GATK (SomaticIndelDetector)	Lin	Yes	–	VCF	INDEL	WES	151 INDELS
SAMtools	Lin	Yes	FASTA	BCF	SNP, INDEL	WES	Canceled <sup>b</sup>
SomaticSniper	Lin	Yes	–	VCF, somatic sniper output	SNP, INDEL	WES	6926 SNPs
VarScan 2	Lin, Mac, Win	No	pileup/mpileup	VCF, VarScan CSV	SNP, INDEL, CNV	WES	1685 SNPs, 324 INDELS
<b>CNV identification tools</b>							
CNVnator	Lin	Yes	FASTA	CSV	CNV	cnv.sim	39 CNVs
RDXplorer	Lin, Mac	Yes	FASTA	CSV	CNV	cnv.sim	4 CNVs <sup>c</sup>
CONTRA	Lin, Mac	Yes	FASTA	VCF, CSV	CNV	WES	3 CNVs
ExomeCNV	Lin, Mac, Win	Yes	pileup + BED + FASTA	CSV	CNV, LOH	WES	137 CNVs
<b>SV identification tools</b>							
BreakDancer	Lin, Mac	Yes	config file	CSV, BED	INDEL, INV, TRANS, CNV	WGS (tumor + normal)	6219 DELs, 0 INSSs, 7 INVs, 17 303 ITX, 5037 CTX <sup>d</sup>
Breakpointer	Lin	Yes	–	GFF	INDEL	WGS (tumor)	<sup>d</sup>
CLEVER	Lin	Yes	FASTA	CLEVER format	INDEL	WGS (tumor)	<sup>d</sup>
GASVPro (GASVPro-HQ)	Lin, Mac	Yes	–	clusters file	INDEL, INV, TRANS	WGS (tumor)	2529 DELs, 207 INVs
SVMerge	Lin	Yes	FASTA	BED	INDEL, INV, CNV	–	Aborted <sup>e</sup>

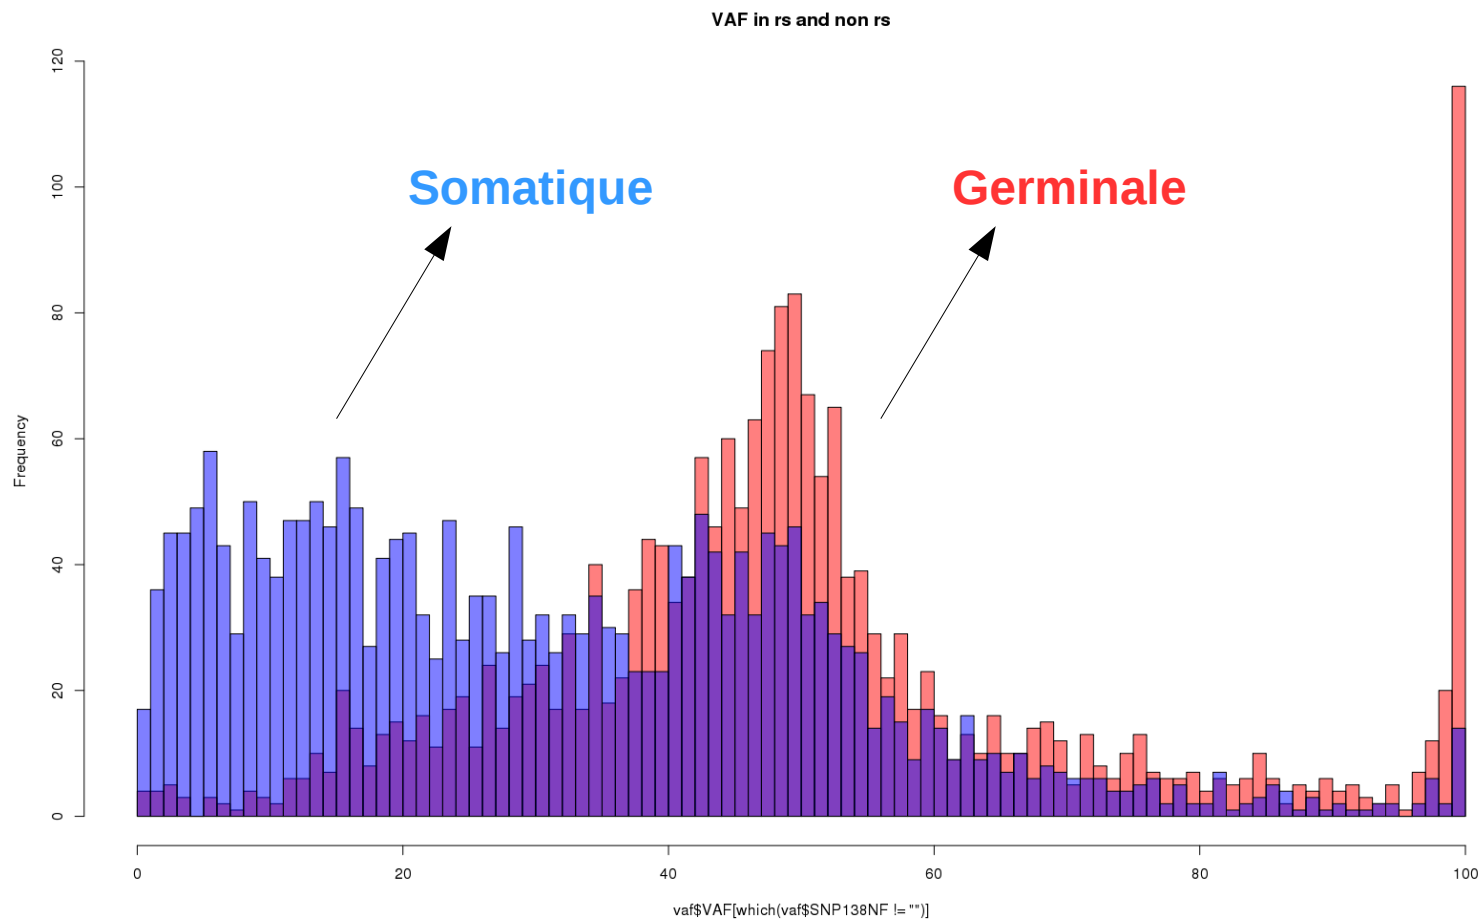
# Somatique Versus Germinale

---

- **Germinale :**
  - **Héritable**
  - **Présent dans toutes les cellules de la descendance**
  - **Cancer Familiaux (BRCA1)**
- **Somatique :**
  - **Non Héritable**
  - **Uniquement présent dans le clone de cellules portant la mutation**



# Somatique Versus Germinale



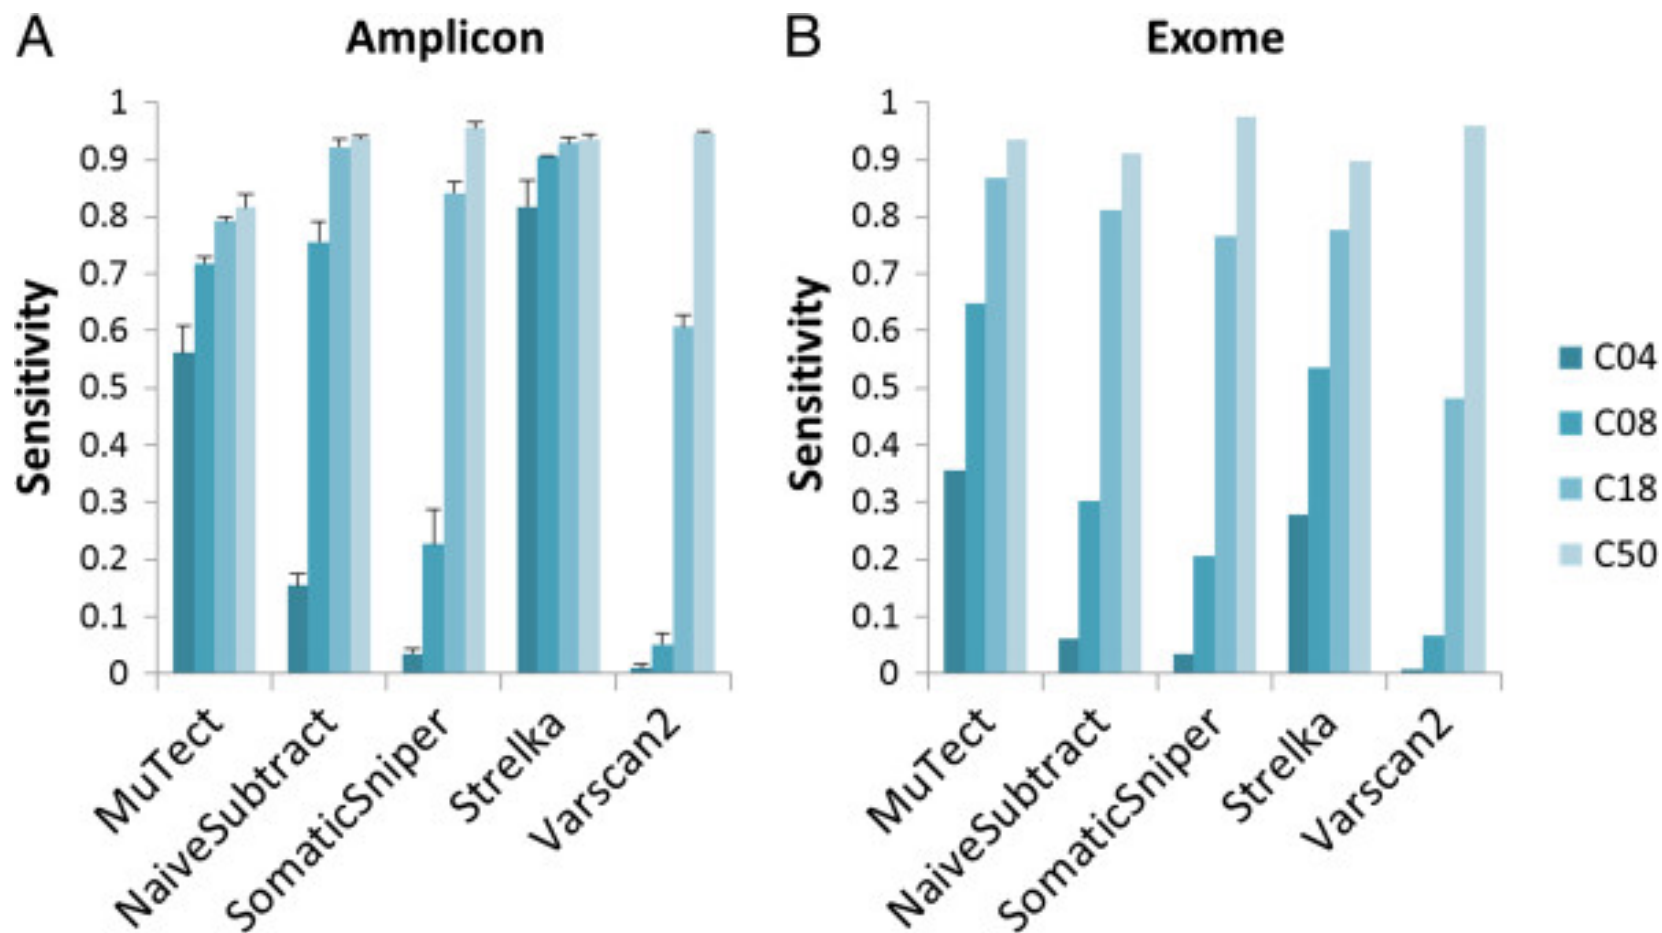
# Mutation somatique : Détection

---

- **Les mutations somatiques peuvent apparaître à des fréquences très faibles (< 5%) en partie à cause de :**
  - **L'hétérogénéité tumorale**
  - **La cellularité tumorale du prélèvement**
- **Requiert un niveau de sensibilité beaucoup plus important que pour la détection germinale**
- **Compromis Sensibilité/Spécificité compliqué**
- **Beaucoup d'outils disponible avec des performances variables.**



# Mutation somatique : Performances



# Format : VCF

**VCF header**

```
##fileformat=VCFv4.0
##fileDate=20100707
##source=VCFtools
##reference=NCBI36
##INFO=<ID=AA,Number=1,Type=String,Description="Ancestral Allele">
##INFO=<ID=H2,Number=0,Type=Flag,Description="HapMap2 membership">
##FORMAT=<ID=GT,Number=1,Type=String,Description="Genotype">
##FORMAT=<ID=GQ,Number=1,Type=Integer,Description="Genotype Quality (phred score)">
##FORMAT=<ID=GL,Number=3,Type=Float,Description="Likelihoods for RR,RA,AA genotypes (R=ref,A=alt)">
##FORMAT=<ID=DP,Number=1,Type=Integer,Description="Read Depth">
##ALT=<ID=DEL,Description="Deletion">
##INFO=<ID=SVTYPE,Number=1,Type=String,Description="Type of structural variant">
##INFO=<ID=END,Number=1,Type=Integer,Description="End position of the variant">
```

**Mandatory header lines** (indicated by a red arrow pointing to the first line)

**Optional header lines** (meta-data about the annotations in the VCF body) (indicated by a black arrow pointing to the remaining header lines)

**Body**

#CHROM	POS	ID	REF	ALT	QUAL	FILTER	INFO	FORMAT	SAMPLE1	SAMPLE2
1	1	.	ACG	A,AT	.	PASS	.	GT:DP	1/2:13	0/0:29
1	2	rs1	C	T,CT	.	PASS	H2;AA=T	GT:GQ	0 1:100	2/2:70
1	5	.	A	G	.	PASS	.	GT:GQ	1 0:77	1/1:95
1	100	.	T	<DEL>	.	PASS	SVTYPE=DEL;END=300	GT:GQ:DP	1/1:12:3	0/0:20

**Reference alleles** (GT=0) (indicated by a blue arrow pointing to the first '0' in the first row)

**Alternate alleles** (GT>0 is an index to the ALT column) (indicated by a blue arrow pointing to the '1' in the first row)

**Phased data** (G and C above are on the same chromosome) (indicated by a blue arrow pointing to the '|1' in the second row)

**Deletion** (indicated by a blue arrow pointing to the '<DEL>' in the fourth row)

**SNP** (indicated by a blue arrow pointing to the 'A,AT' in the first row)

**Large SV** (indicated by a blue arrow pointing to the '<DEL>' in the fourth row)


**Insertion** (indicated by a blue arrow pointing to the 'T,CT' in the second row)

**Other event** (indicated by a blue arrow pointing to the 'T,CT' in the second row)

- **Format standardisé pour enregistrer les variants**
- **Peut être indexé, compressé**
- **Flexible**

# Analyse Tertiaire : L'annotation

**dbSNP**  
Short Genetic Variations



ESP




1000g

TATATCT  
ACCTCAC **ClinVar**

 **COSMIC**  
Catalogue of somatic mutations in cancer

**UniProt**

**RefSeq**




Polyphen









# Analyse Tertiaire : L'annotation

Name	OS	Input	Output	SNP	INDEL	CNV	GUI	CLI	Web	Function/Location Parameters	DB IDs	Number of scores
ANNOVAR	Lin, Mac, Win, web interface	VCF, pileup, CompleteGenomics, GFF3-SOLID, SOAPsnp, MAQ, CASAVA	TXT	Yes	Yes	Yes	No	Yes	No	9 (func) + 11 (exonic-func)	Yes	GERP++ conservation, LRT, MutationTaster, PhyloP conservation, PolyPhen, SIFT
AnnTools	Lin, Mac	VCF, pileup, TXT	VCF	Yes	Yes	Yes	No	Yes	No	5 (position) + 4 (functional class)	Yes	-
NGS-SNP	Lin, Mac	VCF, pileup, MAQ, diBayes, TXT	TXT	Yes	No	No	No	Yes	No	17	Yes	Condel, PolyPhen, SIFT
SeattleSeq	web interface	VCF, MAQ, CASAVA, GATK BED, custom	VCF, SeattleSeq	Yes	Yes	No	No	No	Yes	11 (dbSNP) + 5 (GVS)	Yes	GERP, Grantham, phastCons, PolyPhen
snpEff	Lin, Mac, Win	VCF, pileup/TXT (deprecated)	VCF, TXT, HTML overview	Yes	Yes	No	No	Yes	No	34	Yes	-
SVA	Lin	VCF, SV.events file, BCO	CSV	Yes	Yes	Yes	Yes	Yes	No	17 (SNP), 17 (INDEL), 10 (CNV)	Yes	-
VARIANT	web interface	VCF, GFF2, BED	web report, TXT	Yes	Yes	No	No	Yes	Yes	26	Yes	-
VEP	Lin, web interface	VCF, pileup, HGVS, TXT, variant identifiers	TXT	Yes	Yes	No	No	Yes	Limited	28	Yes	Condel, PolyPhen, SIFT





















# L'annotation : dbSNP

RefSNP	Allele	HGVS Names	<a href="#">Links</a>
Organism: human ( <a href="#">Homo sapiens</a> )	<b>Variation Class:</b> SNV: single nucleotide variation	NC_000007.13:g.11584142T>C	<a href="#">...more</a>
Molecule Type: Genomic	RefSNP Alleles: A/G (REV)	NC_000007.14:g.11544515T>C	
Created/Updated in build: 36/146	Allele Origin:	NG_027670.1:g.292683A>G	
Map to Genome Build: <a href="#">107/Weight</a>	Ancestral Allele: A	NM_015204.2:c.1454-1398A>G	
<b>Validation Status:</b>	Variation Viewer: 	XM_006715659.1:c.1454-1398A>G	
	Clinical Significance: NA	XM_006715660.1:c.1454-1398A>G	
	<b>MAF/MinorAlleleCount:</b> T=0.4846/2427	XM_006715661.2:c.1454-1398A>G	
	MAF Source: 1000 Genomes	XM_006715662.1:c.1454-1398A>G	
		XM_011515193.1:c.1247-1398A>G	
		XM_011515194.1:c.1247-1398A>G	

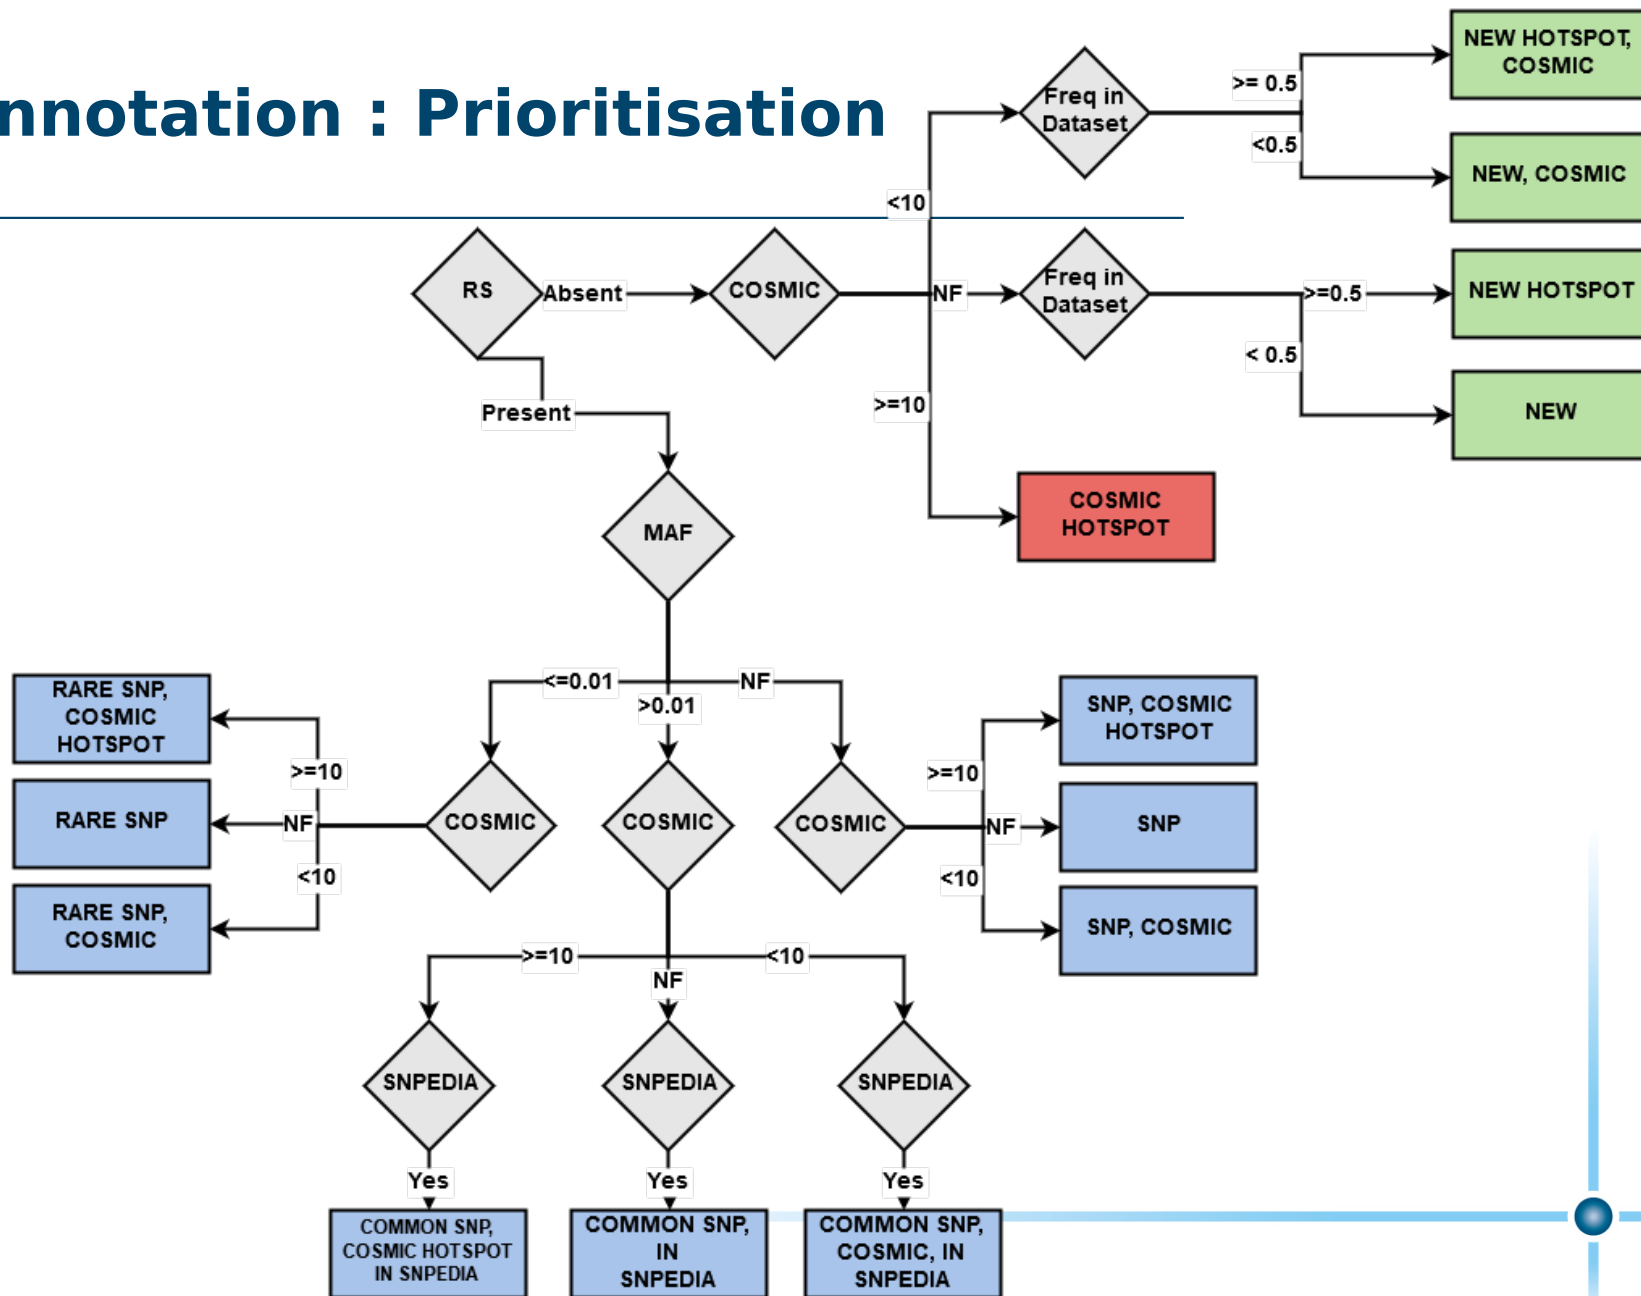
ss#	Sample Ascertainment			Genotype Detail				Alleles		
	Population	Individual Group	Chrom. Sample Cnt.	Source	A/A	A/G	G/G	HWP	A	G
<a href="#">ss115929711</a>	<a href="#">YRI</a>		2	IG		1.00000000			0.50000000	0.50000000
<a href="#">ss1323907305</a>	<a href="#">EAS</a>		1008	AF					0.47419998	0.52579999
	<a href="#">EUR</a>		1006	AF					0.52090001	0.47910002
	<a href="#">AFR</a>		1322	AF					0.49319997	0.50680000
	<a href="#">AMR</a>		694	AF					0.38329998	0.61669999
	<a href="#">SAS</a>		978	AF					0.51840001	0.48159999



# L'annotation : Cosmic

Tissue	Point Mutations		Copy Number Variation		Gene Expression		Methylation	
	% Mutated	Tested	Variant %	Tested	% Regulated	Tested	% Diff. Methylated	Tested
<a href="#">Adrenal gland</a>		<a href="#">395</a>		<a href="#">72</a>		<a href="#">79</a>		-
<a href="#">Autonomic ganglia</a>		<a href="#">1109</a>		-		-		-
<a href="#">Biliary tract</a>		<a href="#">811</a>		-		-		-
<a href="#">Bone</a>		<a href="#">1006</a>		-		-		-
<a href="#">Breast</a>		<a href="#">11706</a>		<a href="#">997</a>		<a href="#">1104</a>		-
<a href="#">Central nervous system</a>		<a href="#">3736</a>		<a href="#">811</a>		<a href="#">695</a>		-
<a href="#">Cervix</a>		<a href="#">688</a>		<a href="#">174</a>		<a href="#">307</a>		-
<a href="#">Endometrium</a>		<a href="#">3753</a>		<a href="#">424</a>		<a href="#">602</a>		-
<a href="#">Eye</a>		<a href="#">168</a>		-		-		-
<a href="#">Fallopian tube</a>		<a href="#">4</a>		-		-		-
<a href="#">Gastrointestinal tract (site indeterminate)</a>		<a href="#">957</a>		-		-		-
<a href="#">Genital tract</a>		<a href="#">28</a>		-		-		-

# L'annotation : Prioritisation



## Workflow : Ressources

---

- **Le Base calling nécessite peu de ressource CPU/RAM**
- **L'alignement requiert beaucoup de RAM/CPU**
- **L'analyse bio-info d'un échantillon nécessite entre 2 et 24 heures**
- **Quantité de données générée très élevée (~Gb/Sample)**
- **Délais court pour rendre les résultats pour les projets de médecine personnalisée (PERMED/HEMATO BIO)**



**Traitement séquentiel sur machine personnel impossible**

## **Solution : DISC**

---

- **Alambic**
  - **236 CPU-CORES**
  - **1168 Gb RAM**
  - **18 noeuds**
- **Agui**
  - **260 CPU-CORES**
  - **1608 Gb RAM**
  - **15 noeuds**



## Solution : Parallélisation

---

- **Parallélisation par les données**
  - **Simple à mettre en œuvre**
  - **Parfaitement adaptée à un environnement de type cluster de calcul (oar)**
  - **Les données doivent pouvoir être « découpées »**
  - **Les données doivent pouvoir être rassemblées**
  - **Limité par les processus I/O**

```
for i in $(ls $fastq_dir/*R1*)
do
    oarsub ...
done
```



# Solution : Parallélisation

---

```
import multiprocessing


def worker():
    """worker function"""
    print 'Worker'
    return

if __name__ == '__main__':
    jobs = []
    for i in range(5):
        p = multiprocessing.Process(target=worker)
        jobs.append(p)
        p.start()
```

- **Parallélisation par le code (Python : Multiprocessing)**
  - **Natif avec Python 2.6**
  - **Nécessite des compétences avancées en programmation**



# Solution : Parallélisation




# Résultats : Séquençage ciblé PERMED

## Mutations HOTSPOT ou potentiellement dommageables :

Symbol	CNA	Mutation	Note	Freq	Drugs*
<a href="#">ERBB2</a>	Normal	p.L755S	HotSpot	0.14	ado-trastuzumab.emtansine, afatinib, canertinib, ertumaxomab, lapatinib, neratinib, pelitinib, pertuzumab, sapitinib, trastuzumab, varlitinib, mubritinib, margetuximab, ado-trastuzumab.emtansine, T-DM1
<a href="#">ESR1</a>	Normal	p.D538G	Damaging	0.13	Tamoxifen Anti-A
<a href="#">MLL2</a>	Normal	p.G1995R	Damaging	0.31	
<a href="#">RAD51D</a>	Not found	p.S144F	Damaging	0.52	
<a href="#">RB1</a>	Normal	p.R621C	Damaging	0.56	
<a href="#">SACS</a>	Normal	p.D4116Y	Damaging	0.24	
<a href="#">STAT5B</a>	Normal	p.V696I	Damaging	0.15	dasatinib
<a href="#">USH2A</a>	Normal	p.G1871D	Damaging	0.69	
<a href="#">WRN</a>	Loss or Del	p.T1262R	Damaging	0.56	

\* Cliquez sur le gène pour plus de détails

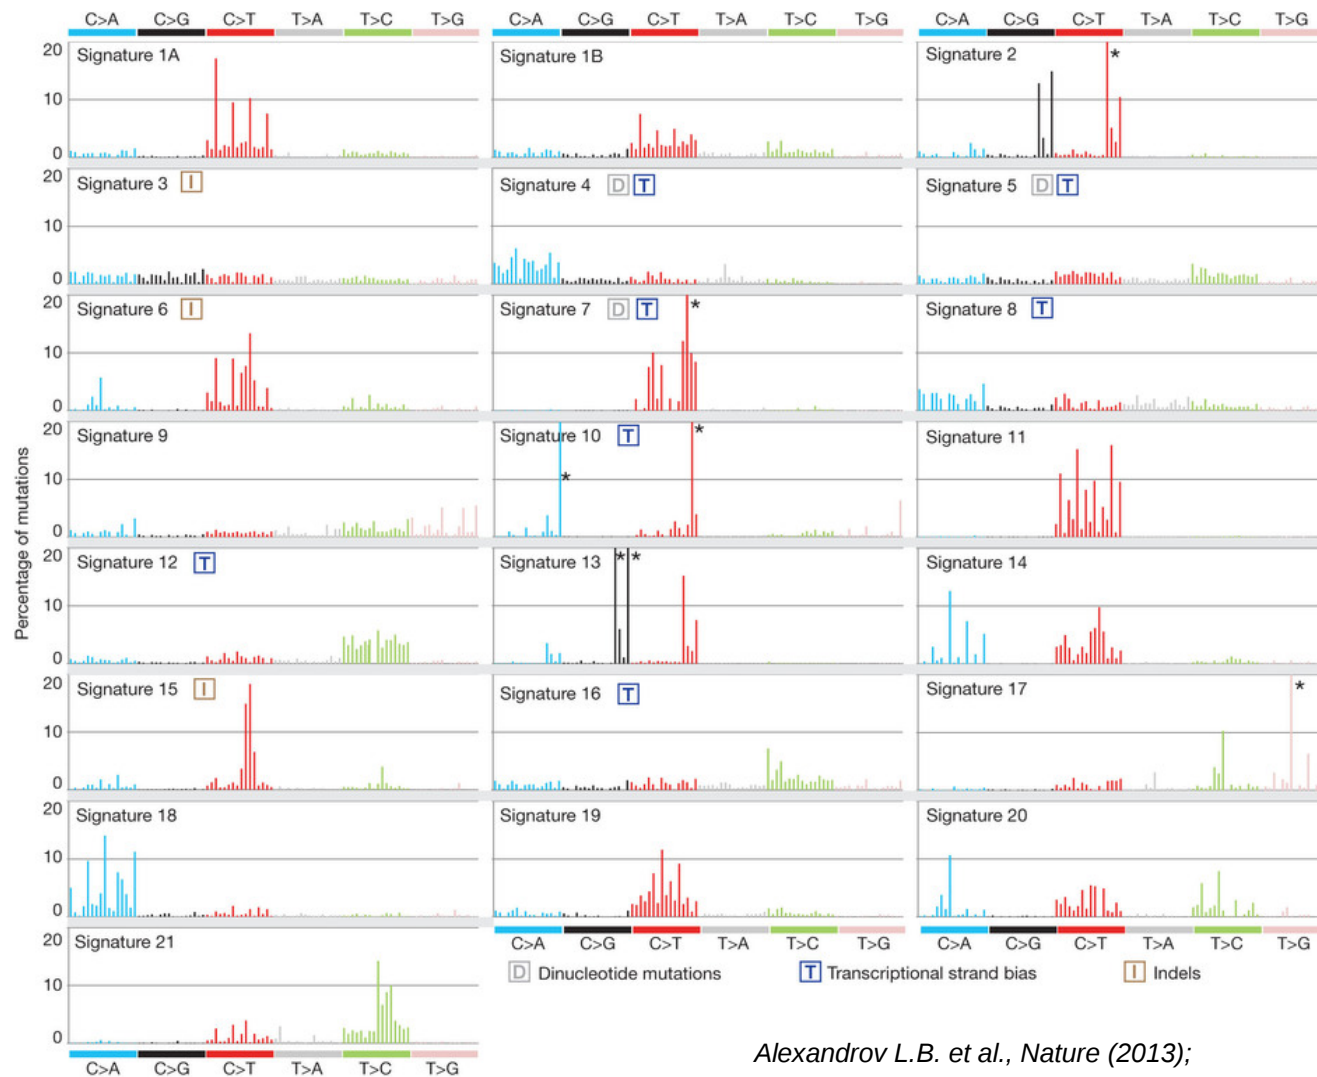
# Résultats : Signature mutationnelle



Alexandrov L.B. et al., Nature (2013);



# Résultats : Signature mutationnelle



Alexandrov L.B. et al., Nature (2013);


## Résultats : PERMED 1002

Symbol	CNA	Loc	Mutation	Note	Freq
<a href="#">ADAMTS16</a>	Normal	chr5 :5182400	NM_139056 exon4 c.T745G p.C249G	DAMAGING	0.41
<a href="#">BRCA1</a>	Normal	chr17 :41256250	NM_007294 exon6 c.G330T p.K110N	DAMAGING	0.70
<a href="#">MAP3K4</a>	Normal	chr6 :161470401	NM_005922 exon3 c.C1097G p.A366G	DAMAGING	0.61
<a href="#">MYH9</a>	Normal	chr22 :36681312	NM_002473 exon38 c.C5338T p.R1780W	DAMAGING	0.88
<a href="#">NTRK1</a>	Normal	chr1 :156846234	NM_002529 exon14 c.C1675T p.R559C	DAMAGING	0.02
<a href="#">PPP2R1A</a>	Normal	chr19 :52714679	NM_014225 exon4 c.C437T p.S146L	DAMAGING	0.43
<a href="#">PTEN</a>	Normal	chr10 :89692904	NM_000314 exon5 c.C388G p.R130G	HOTSPOT	0.53
<a href="#">PTEN</a>	Normal	chr10 :89685270	NM_000314 exon3 c.166dupT p.R55...	frameshift in- sertion	0.35
<a href="#">SMARCA4</a>	Normal	chr19 :11094931	NM_003072 exon2 c.C104T p.S35L	DAMAGING	0.86
<a href="#">STAT5B</a>	Normal	chr17 :40353869	NM_012448 exon19 c.C2251T p.L751F	DAMAGING	0.45
<a href="#">TP53</a>	Normal	chr17 :7577599	NM_000546 exon7 c.681dupT p.D22...	stopgain SNV	0.57


\* Cliquez sur le gène pour plus de détails

# Résultats : Exome PERMED 1002


Exome\_01002-T\_S2\_R1\_001



Signature.1 : 0.567 & Signature.3 : 0.241




error = 0.087



**PERMED 1002 associée avec la signature 1 et 3**



# Résultats : Exome PERMED 1002



- **Types de cancer** : la signature 1 a été trouvée dans presque tous les types de cancer.
- **Étiologie** : la signature 1 est le résultat d'un processus mutational endogène initié par la désamination des 5-methylcytosines
- **Caractéristiques des mutations** : la signature 1 est associée à un petit nombre de petits indels dans la plupart des tissus.





**Merci !!!**

**Des questions ???**

