

Détection de SNP


- Méthodologie, Données & outils
- Alignement sur génome de référence
- Détection de SNP
- Sélection de SNP




ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Méthodologie



Méthodologie



Données volumineuses

Projet SNPBB :

Recherche de polymorphisme chez la caille, QTL de comportement

3 run(s) et 0 analyse(s) ont été réalisées sur le projet SNPBB.

L'ensemble des données brutes et des résultats d'analyses occupent **47.37 Gb** d'espace disque pour l'ensemble du projet.

Projet SWANPORC :

Etude de maladies congénitales chez le porc

11 run(s) et 0 analyse(s) ont été réalisées sur le projet SWANPORC.

L'ensemble des données brutes et des résultats d'analyses occupent **123.16 Gb** d'espace disque pour l'ensemble du projet.



Méthodologie, Données & outils

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Portail NG6

The screenshot shows the 'Téléchargement de vos données' (Download your data) page on the Portail NG6. The page has a dark blue header with navigation tabs: 'PROJETS', 'RUNS', and 'DOWNLOAD'. A search bar with the placeholder 'recherche' is on the right. The main content area features a large download icon and the title 'Téléchargement de vos données'. Below this, there is a list of projects and runs with checkboxes. A modal dialog titled 'Création de liens symboliques' is open in the foreground. The dialog contains a square icon with a white arrow pointing up and to the right. The text inside the dialog states: 'Cette fonctionnalité est uniquement valable si vous disposez d'un compte utilisateur sur le serveur snp.toulouse.inra.fr.' Below this text are three input fields: 'Nom d'utilisateur :', 'Mot de passe :', and 'Répertoire : /work/'. At the bottom of the dialog are two buttons: 'Créer' and 'Annuler'. The background page shows a list of files to download, including 'S+ (16-02-11) : données brutes' and 'S- (16-02-11) : données brutes', with a 'Télécharger' button at the bottom right.

PROJETS RUNS DOWNLOAD

recherche

Téléchargement de vos données

Sélectionner les données dont vous voulez télécharger

Création de liens symboliques

Cette fonctionnalité est uniquement valable si vous disposez d'un compte utilisateur sur le serveur snp.toulouse.inra.fr.

Nom d'utilisateur :

Mot de passe :

Répertoire :

Créer Annuler

Liste des fichiers à télécharger :

S+ (16-02-11) : données brutes

S- (16-02-11) : données brutes

Télécharger



Méthodologie, Données & outils

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Données sur snp.toulouse.inra.fr

- Emplacement des bam
[http://ng6.toulouse.inra.fr/fileadmin/data/run/...](http://ng6.toulouse.inra.fr/fileadmin/data/run/.../save/ng6/data/run/...)
[/save/ng6/data/run/...](http://ng6.toulouse.inra.fr/fileadmin/data/run/.../save/ng6/data/run/...)
- Emplacement des génomes de référence
[/save/ng6/TODO/HiSeqIndexedGenomes/](http://ng6.toulouse.inra.fr/fileadmin/data/run/.../save/ng6/TODO/HiSeqIndexedGenomes/) :
arabidopsis canard cheval chevre mouton porc poule
taureau vigne



Pré-traitements NG6 : bwa aln données brutes

Swanporc

Maladie	HS				IS	
Animal	29MQ1081403		44UJ5062010		35HJ3070331	49UAZ080365
Date run	02-02-11	01-03-11	11-05-11	12-07-11	02-02-11	16-02-11
Raw mapped	85478425	150560510	75843154	184420256	54857356	158205686
% Raw mapped	80.28%	77.04%	73.83%	75.95%	69.04%	74.65%
Raw well paired	0	145974614	0	177695072	52216680	153124668
% Raw well paired	0.00%	74.70%	0.00%	73.18%	65.72%	72.25%
Nb Seq	106480566	195422034	102721977	242826148	79457908	211933260

SNPbb

Animal	S+		S-		caille des blés	
	read1	read2	read1	read2	read1	read2
Date run	16-02-11		16-02-11		16-02-11	
Raw mapped	26545363		31636999		27847370	
% Raw mapped	15.13%		13.71%		14.64%	
Raw well paired	25405990		30442382		26836332	
% Raw well paired	14.48%		13.19%		14.11%	
Nb Seq	87730296	87730296	115402866	115402866	95079542	95079542



Méthodologie, Données & outils

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Choix de l'algorithme (SNPbb)

- BWA aln : 14.5% lectures alignées
- Bowtie : 13.6%
- BWA bwasw : 42%
- Glint : 70%
- Blat, Blast, Fasta36 ... ?



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Qualité d'un alignement

- Bonne vieille école : e value, score, % id, nb hits



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Qualité d'un alignement

- Bonne vieille école : e value, score, % id, nb hits

```
HWI-S...681#0 163 CHRMT 153 60 101M =201 149 CTAT...CGT ggg...BBB \
XT:A:U NM:i:0 SM:i:23 AM:i:23 XO:i:1 X1:i:1 XM:i:0 XO:i:0 XG:i:0 MD:Z:101 XA:Z:CHR7,-90650540,101M,1;

HWI-S...498#0 163 CHRMT 154 29 101M =222 169 TATA...GTA ggg...Tc] \
XT:A:R NM:i:2 SM:i:0 AM:i:0 XO:i:2 X1:i:0 XM:i:2 XO:i:0 XG:i:0 MD:Z:15G2G82 XA:Z:CHRMT,+154,101M,2;
```

- MAPQ
- CIGAR
- NM(distance) MD(mismatches)



Alignement sur génome de référence

- X? ex : XA<sup>ALIMENTATION
AGRICULTURE
ENVIRONNEMENT</sup>


INRA



Step 8 XA	9474839	16938343	9242914	20725798	6513547	17398024
Step 8 maxIDX	8306146	8707190	8122316	10956219	3364183	9181211

Reads repartition

Swanporc




Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

MAPQ / mean qual (swanporc)



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

MAPQ / ID

(swanporc)



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

wa aln bugs


HWI:
XT:A

HWI .

18

MAPQ / #XA

(swanporc)



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

MAPQ / #XA

- Paramétrage du nombre de XA

Usage: `bwa sampe [options] <prefix> <in1.sai> <in2.sai> <in1.fq> <in2.fq>`

Options: `-a INT` maximum insert size [500]
`-o INT` maximum occurrences for one end [100000]
`-n INT` maximum hits to output for paired reads [3]

Manual page bwa :

`-n INT` Maximum number of alignments to output in the XA tag for reads paired properly. **If a read has more than INT hits, the XA tag will not be written.** [3]

n	aln	-f 2	XA
1	9926	9926	928
2	9926	9926	1259
3	9926	9926	1272
4	9926	9926	1276



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Filtrage (1)

- Sans contaminations
- Sans N
- MAPQ ≥ 30
- Localisation unique ?
- %id ?
- Séquences bien appairées ?



Alignement sur génome de référence

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Détection de SNP

- **samtools mpileup -uID -q (-B)**

-q INT filter out alignment with MQ smaller than INT [0]
-u do not compress BCF output
-B disable BAQ computation
-D output per-sample DP
-I do not perform indel calling

- **bcftools view -cbvg**

Options: -c SNP calling
 -v output potential variant sites only (force -c)
 -g call genotypes at variant sites (force -c)
 -b output BCF instead of VCF

#CHROM	POS	ID	REF	ALT	QUAL	FILTER	INFO	FORMAT	S-_well-paired_90id_noXA_sorted.bam	S+_well-
paired_90id_noXA_sorted.bam										
CHR10	5738	.	G	A	24.8	.	DP=6;AF1=1;CI95=0.5,1;DP4=0,0,3,1;MQ=17;FQ=-33.3	GT:PL:DP:GQ		
1/1:42,9,0:3:52	1/1:17,3,0:1:46									



Détection de SNP



ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

mpileup

Bam complet :

CHR21 5909579 . A G 36.4 . DP=36;AF1=0.5156;CI95=0.25,0.75;DP4=2,2,0,5;MQ=49;FQ=31;PV4=0.17,1,1,0.0097 ...
GT:PL:DP:GQ 1/1:76,15,0:5:13 0/0:0,12,68:4:9



CHR21 5909579 A 21 GgGggGgGgGgGgGGggggg
CHR21 5909579 A 15 gGGg.GgG.g,G,GG

Bam sur zone restreinte ou option -B sur mpileup :

CHR21 5909579 . A G 181 . DP=36;AF1=0.7487;CI95=0.75,0.75;DP4=2,2,2,7;MQ=48;FQ=20.3;PV4=0.53,1,1,0.0074
... GT:PL:DP:GQ 1/1:179,21,0:7:23 0/1:40,0,52:6:46



Détection de SNP

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Sélection des SNP

- Allèle minoritaire
- Fréquences alléliques
- Profondeur minimale ou maximale
- Qualité du SNP
- Spécificité
- Répétition/environnement
- Conséquence
- Score illumina



Sélection des SNP

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Sélection des SNP

- Allèle minoritaire => comptage à partir du format pileup
- Fréquences alléliques => déduit du comptage
- Profondeur minimale ou maximale => samtools.pl varFilter
- Qualité du SNP => samtools.pl varFilter
- Spécificité => génotype ou calculs sur fréquences alléliques ?
- Répétition/environnement => filtrage en base de données
- Conséquence => Ensembl variant_effect_predictor.pl
- Score illumina => service web

```
CHR21 5909579 . A G 36.4 . DP=36;AF1=0.5156;CI95=0.25,0.75;DP4=2,2,0,5;MQ=49;FQ=31;PV4=0.17,1,1,0.0097 ...
GT:PL:DP:GQ 1/1:76,15,0:5:13 0/0:0,12,68:4:9
```

```
CHR21 5909579 A 21 GgGggGgGgGgGggGGggggg
CHR21 5909579 A 15 gGGg.GgG.g,G,GG
```



Sélection des SNP

ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA

Conclusion

- Les outils sont « neufs », tout comme la techno
- Ils sont nombreux ; parfois hermétiques
- Les données en entrée sont grosses
=> difficile de tâtonner sans perte de temps



ALIMENTATION
AGRICULTURE
ENVIRONNEMENT

INRA