



HAL
open science

Select SNP 4 Imputation (SS4I) : un outil simple de sélection de SNP en fonction du DL

Frédéric Herault, Jérémy Yon, Florian Herry, Sophie Allais, Pascale Le Roy

► To cite this version:

Frédéric Herault, Jérémy Yon, Florian Herry, Sophie Allais, Pascale Le Roy. Select SNP 4 Imputation (SS4I) : un outil simple de sélection de SNP en fonction du DL. Réunion du projet Selgen INCoMINGS, Oct 2016, La Rochelle, France. hal-01455928

HAL Id: hal-01455928

<https://hal.science/hal-01455928>

Submitted on 5 Jun 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Select_SNP_4_Imputation (SS4I) : Un outil simple de sélection de SNP en fonction du DL.

Frédéric Hérault, Jeremy Yon, Florian Herry, Sophie Allais, Pascale Le Roy



Hérault et al. / [Selection de SNP pour l'Imputation: SS4I](#)



Séminaire INCoMINGS La Rochelle 10-11 octobre 2016

Select_SNP_4_Imputation (SS4I)

- ✓ Outil développé en Python
- ✓ Sélection d'un panel réduit de SNP:
 - Puce basse densité
 - Imputation
- ✓ Sélection basé sur le DL entre chaque paire de SNP au sein d'un chromosome.



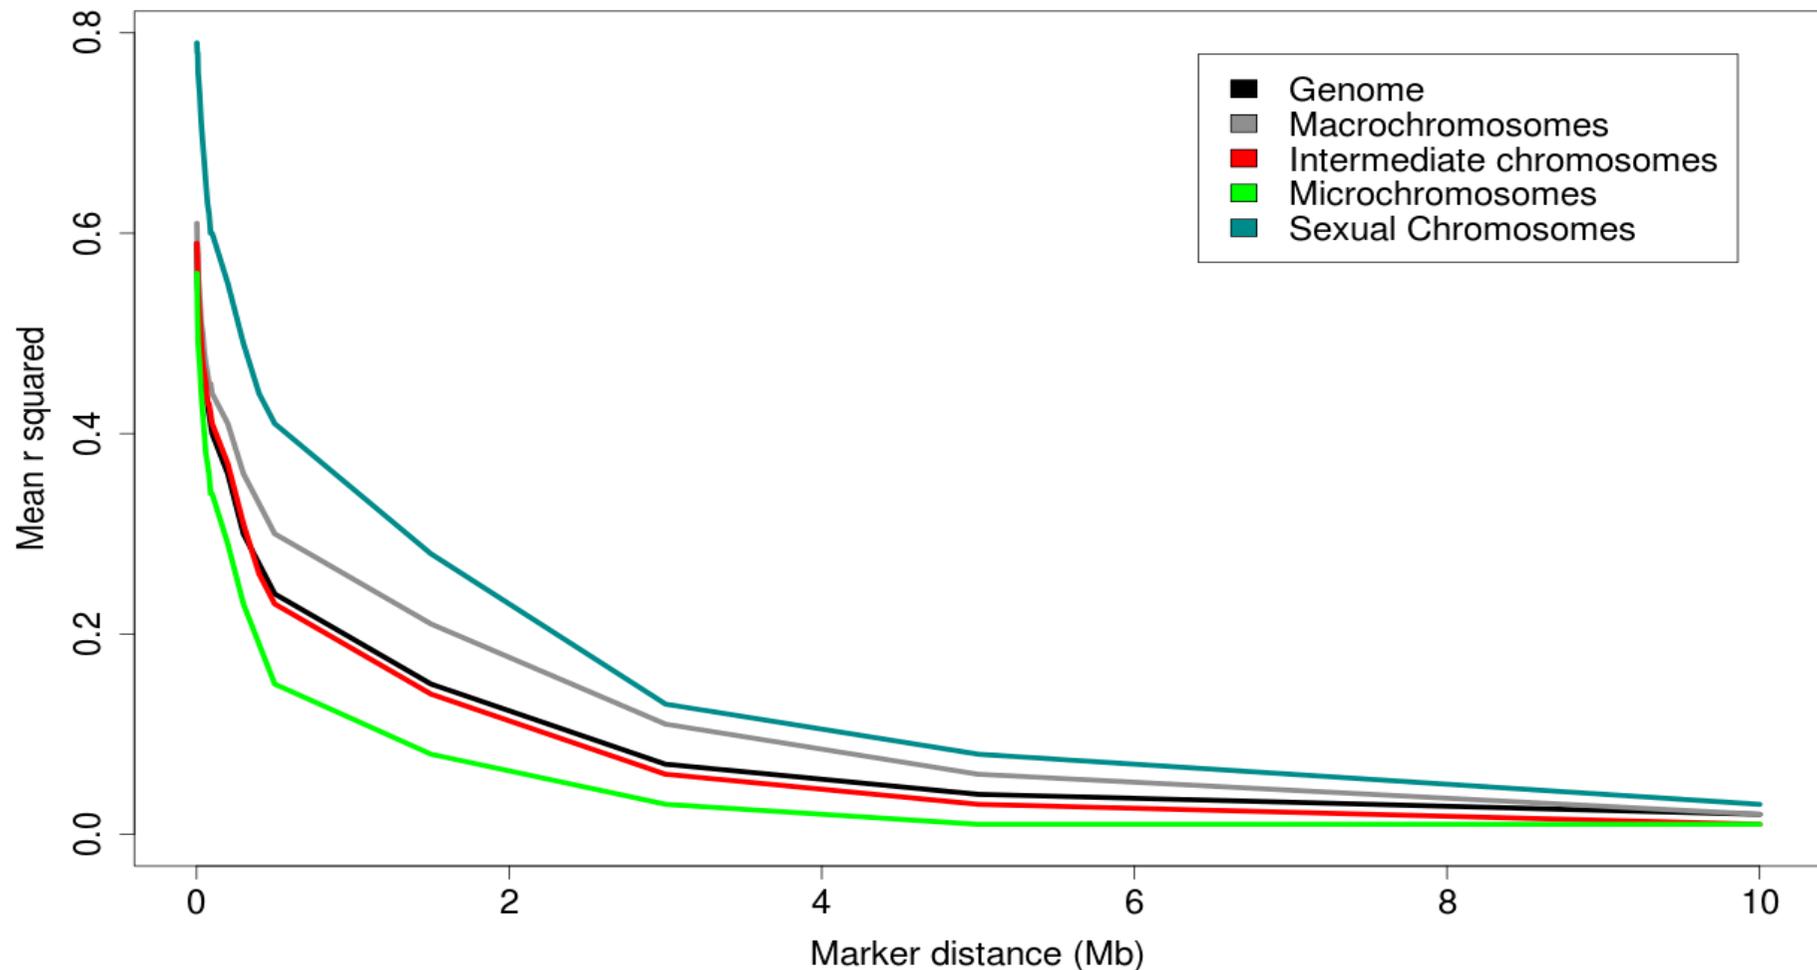
Structure particulière du génome Gallus gallus.

Structure et DL du génome *Gallus gallus*

- ✓ 39 paires de chromosomes.
 - Macrochromosomes (GGA1 to GGA5)
 - Chromosomes intermédiaires (GGA6 to GGA10)
 - Microchromosomes (GGA11 to GGA 38)
 - Sexual chromosomes (Z & W).

Structure et DL du génome *Gallus gallus*

Niveau et étendue du DL entre ≠ catégorie de chromosomes

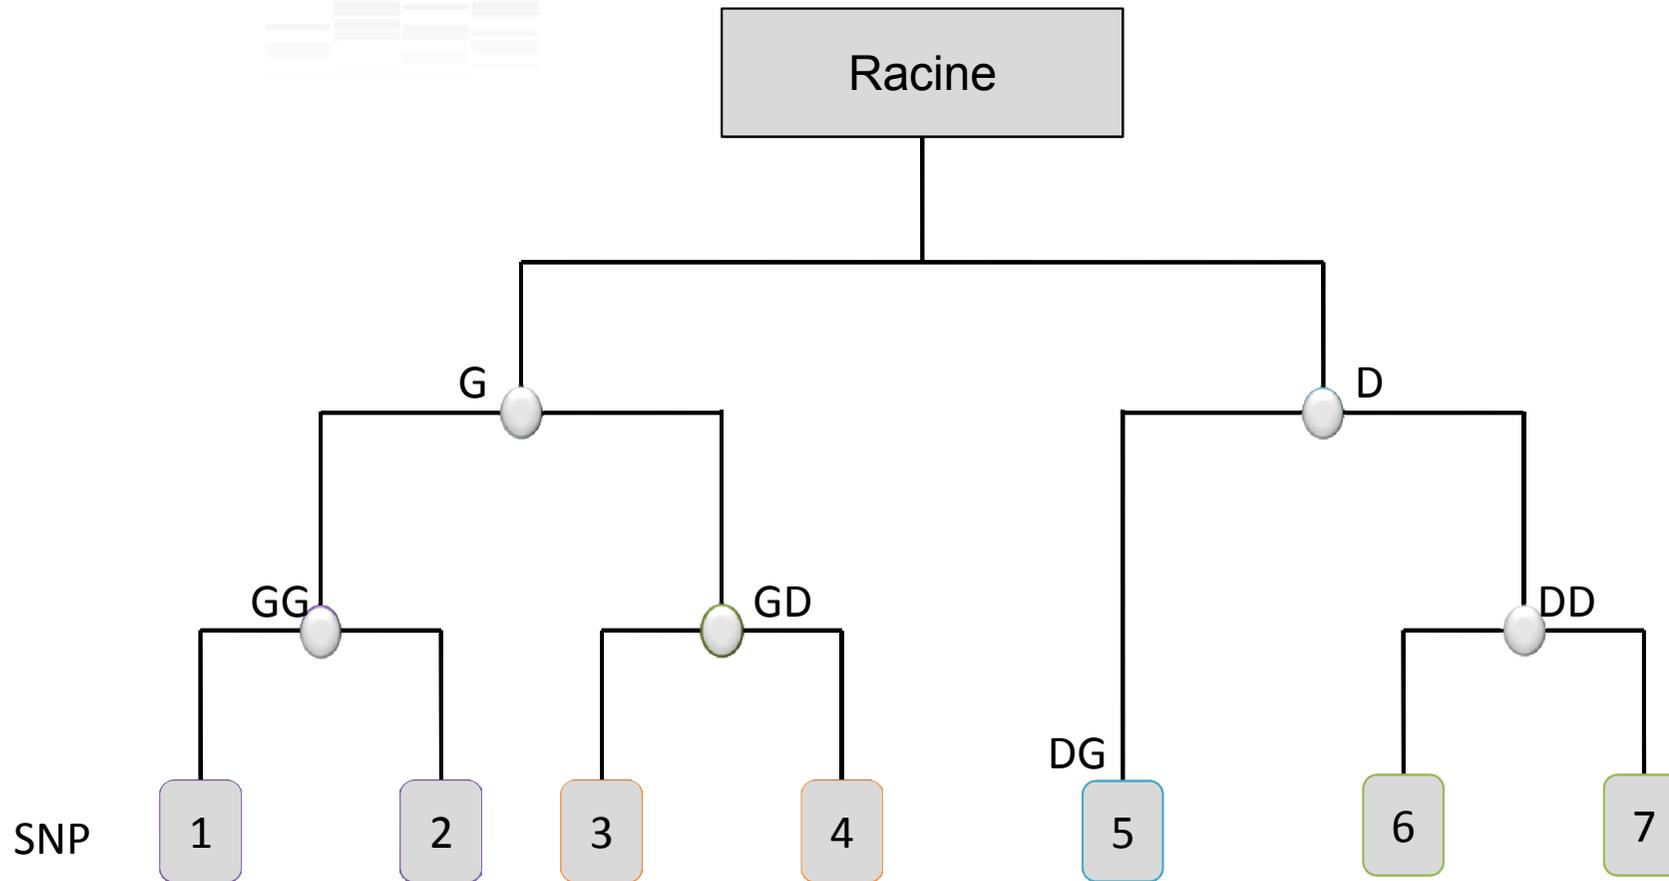


Principe de fonctionnement

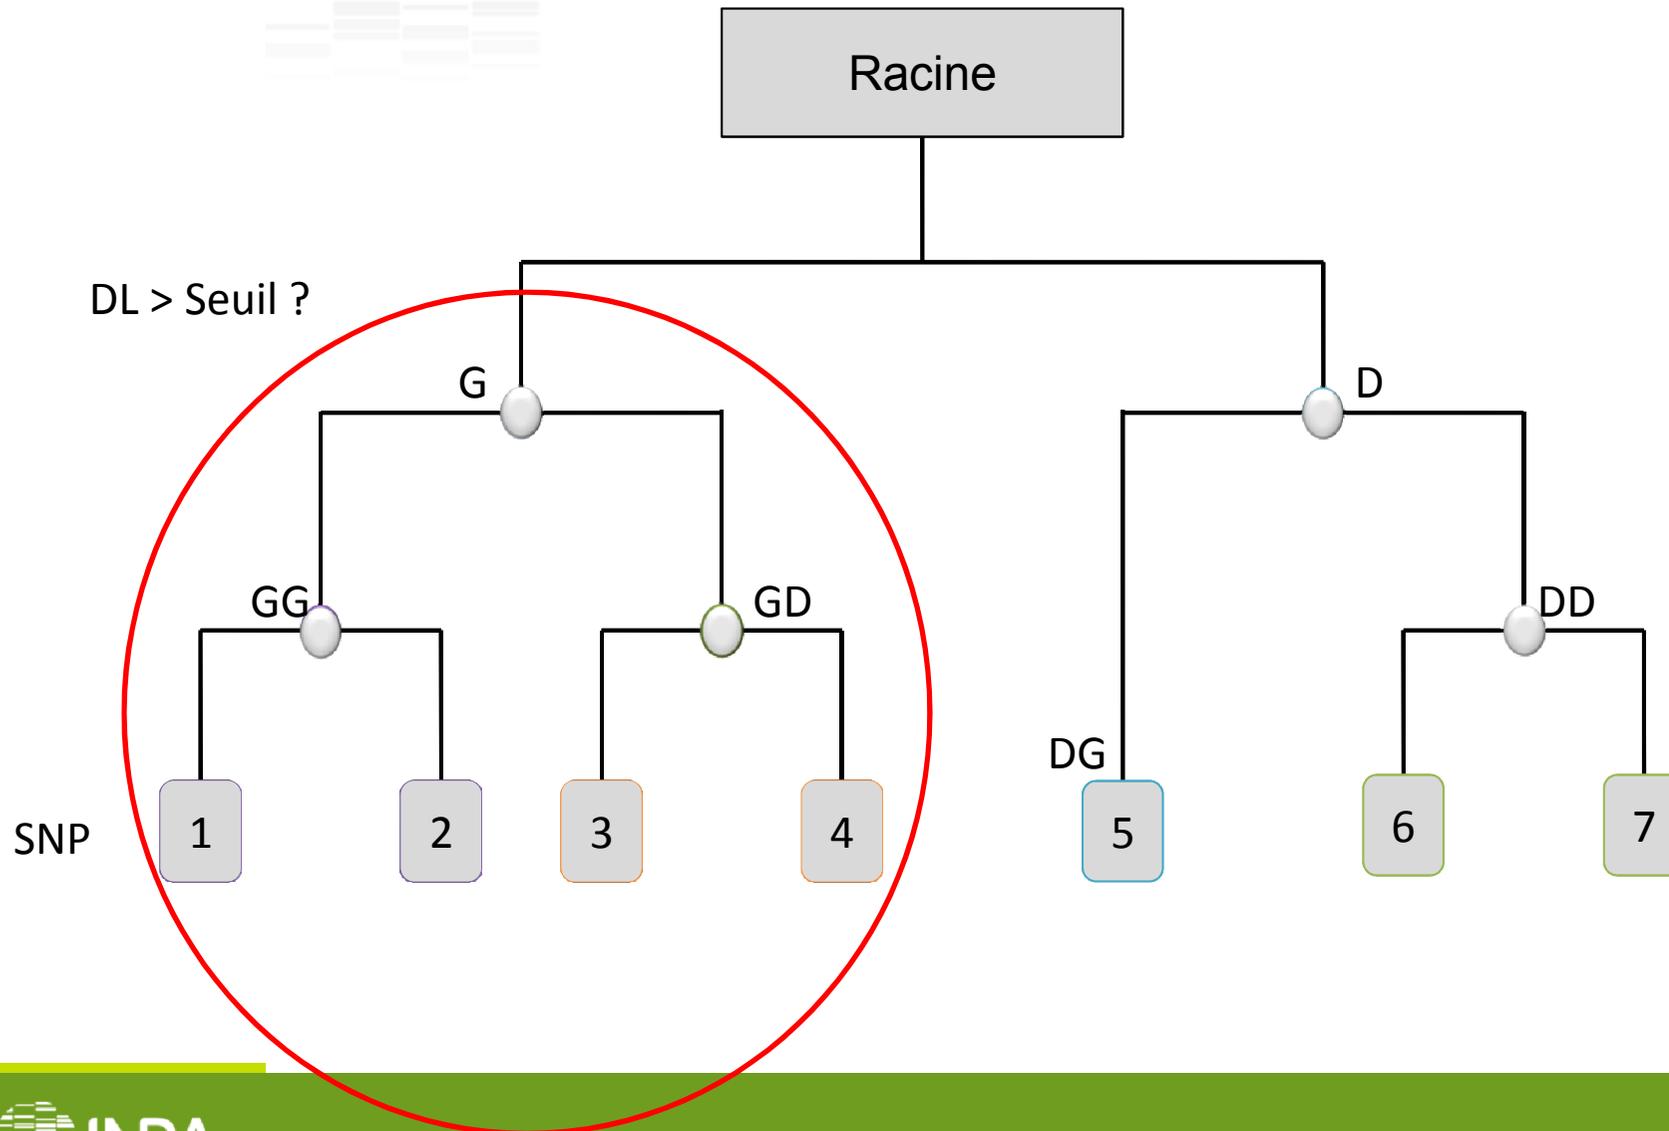
Pour chaque chromosome

- ✓ Calcul du DL entre chaque paire SNP (PLINK).
- ✓ Clustering Hiérarchique Ascendant basé sur le DL.
- ✓ Création dendrogramme.
- ✓ Sélection d'ensemble de SNP répondant au critère de seuil de DL.
- ✓ Sélection d'un SNP représentatif de chaque ensemble.

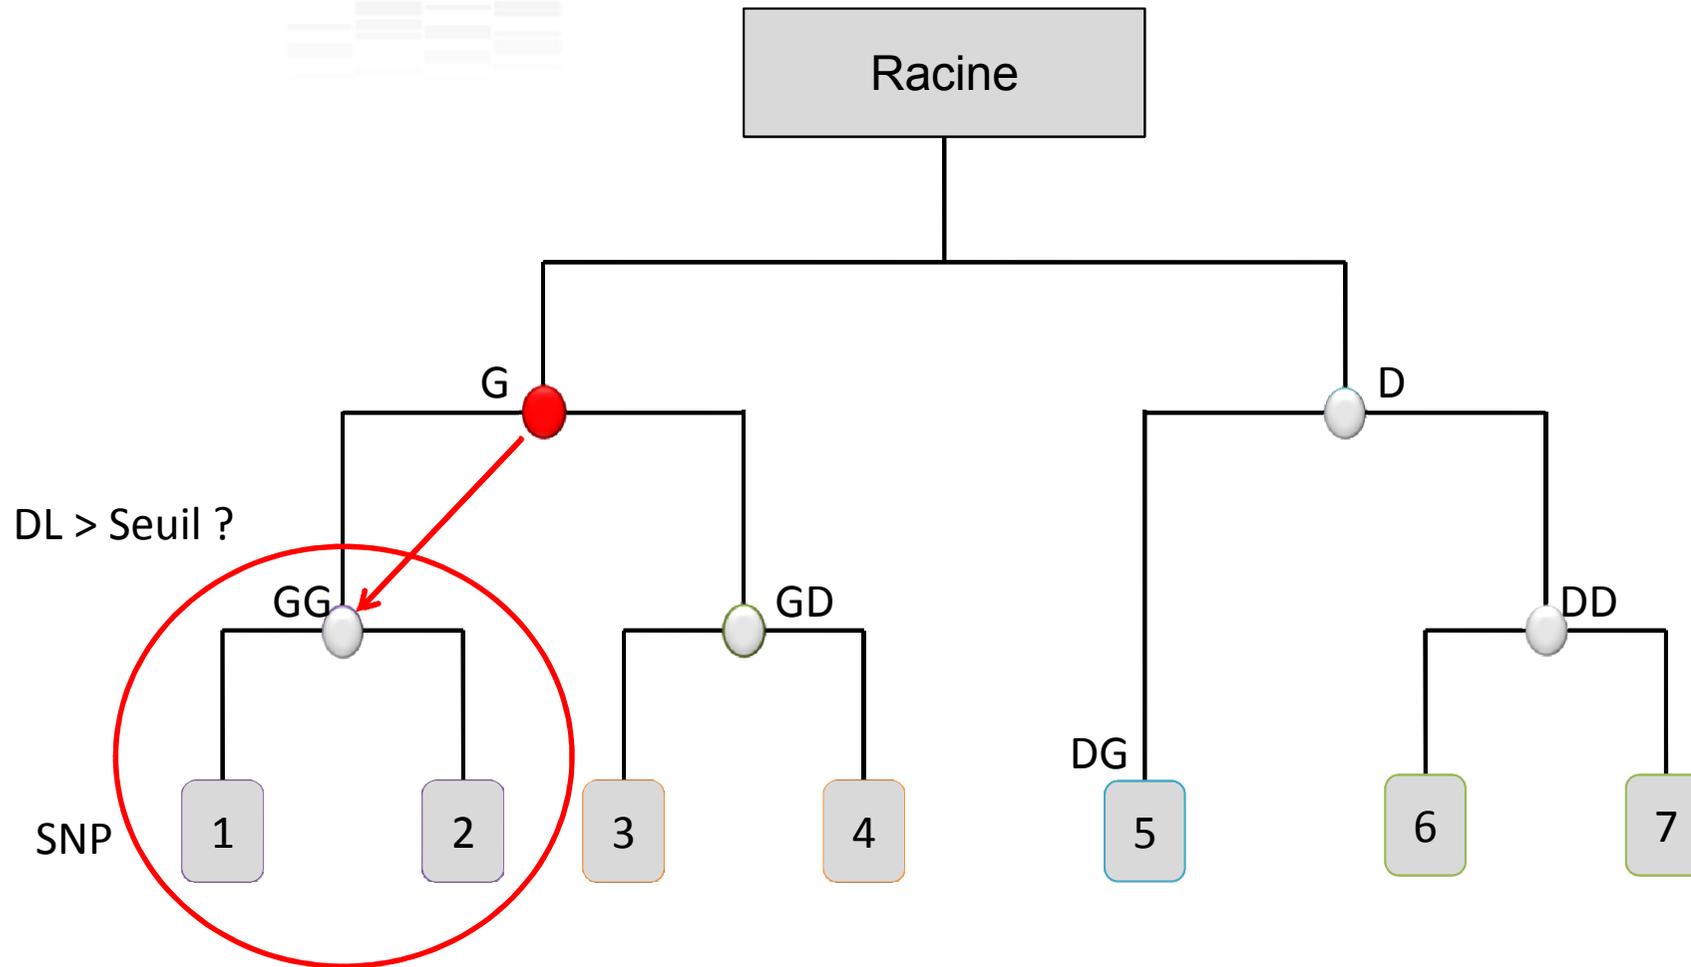
Sélections des ensembles de SNP / DL.



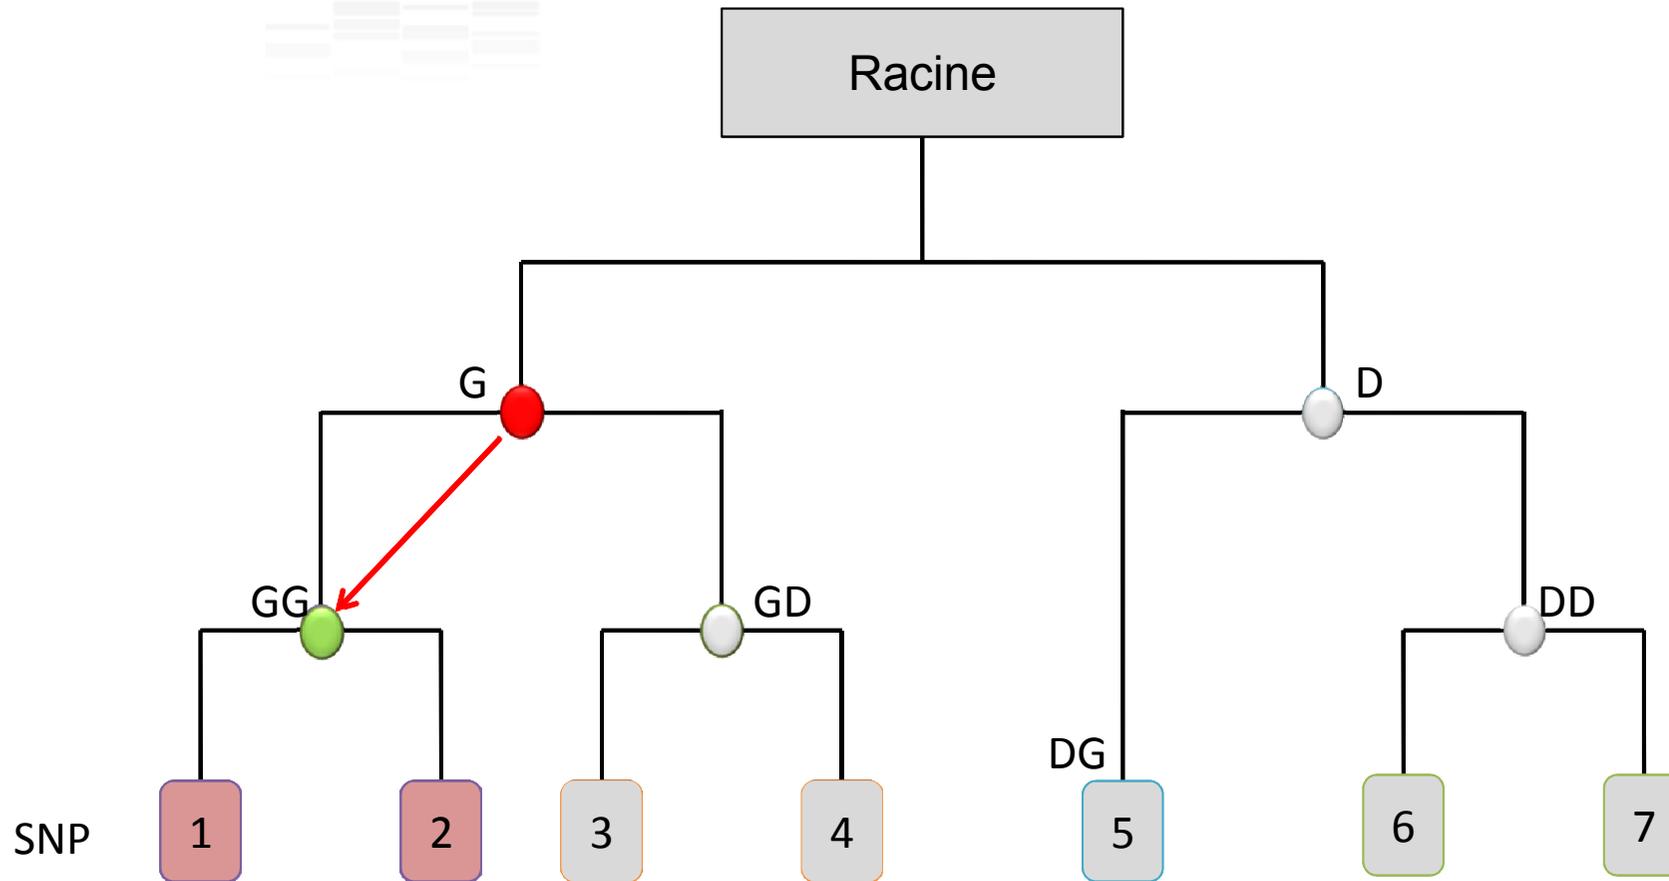
Sélections des ensembles de SNP / DL.



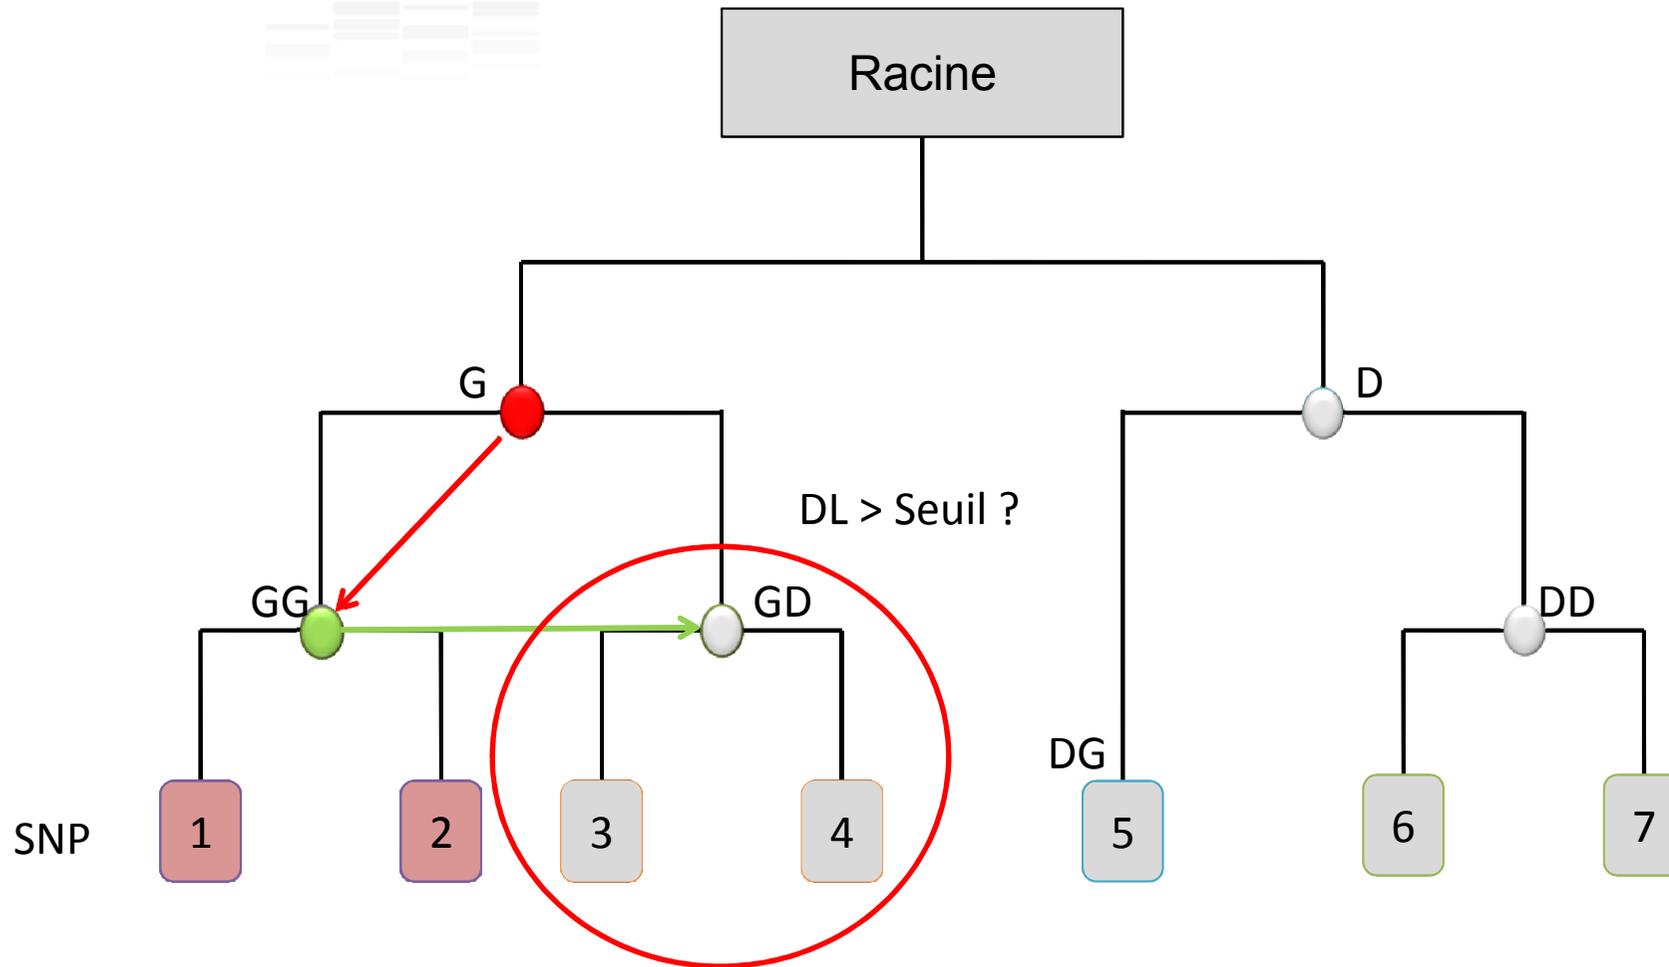
Sélections des ensembles de SNP / DL.



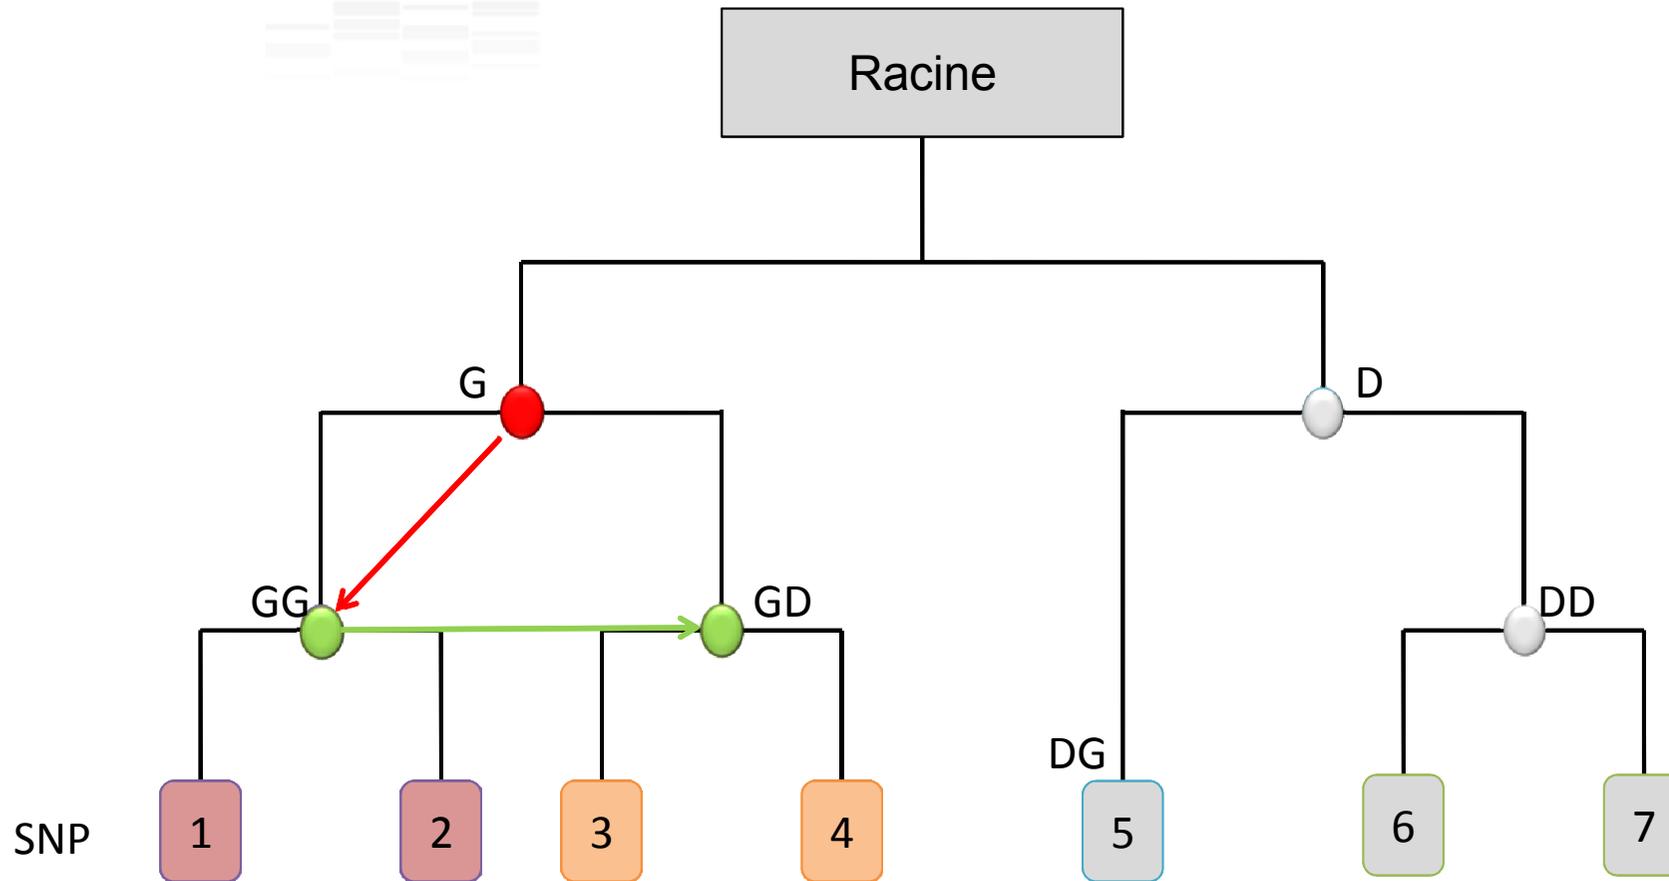
Sélections des ensembles de SNP / DL.



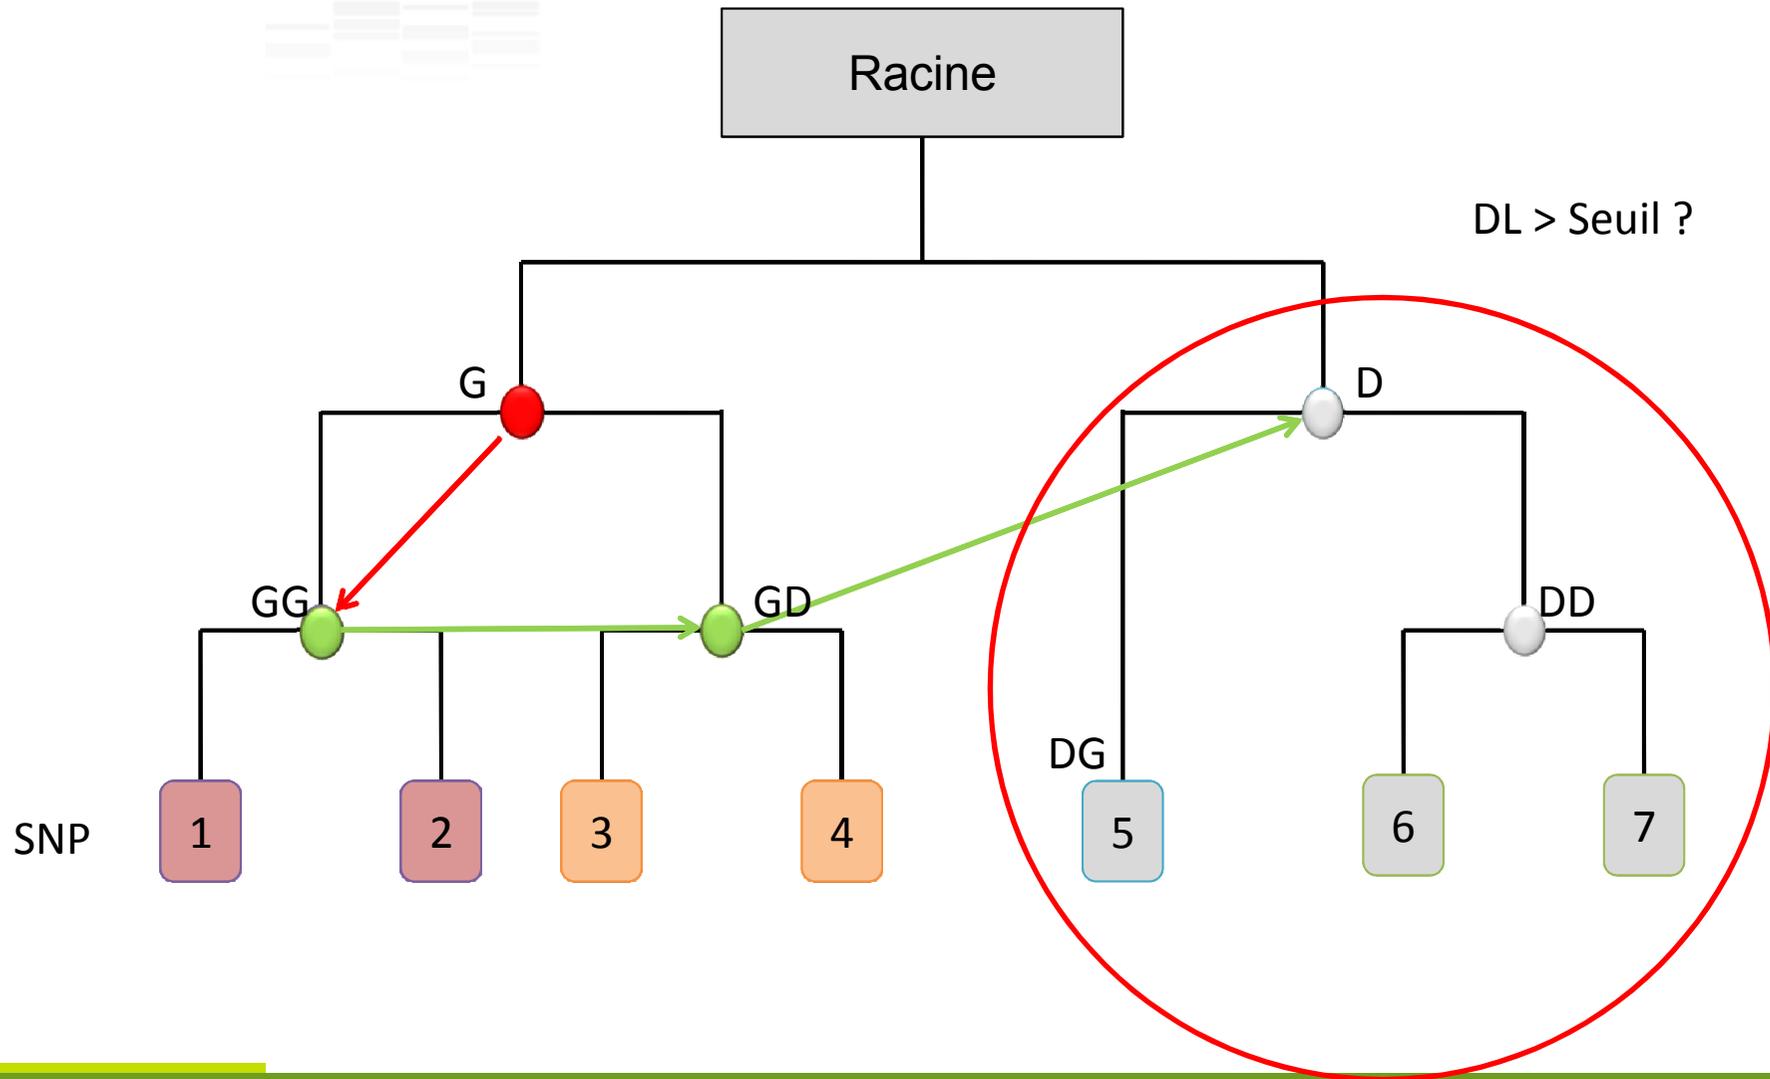
Sélections des ensembles de SNP / DL.



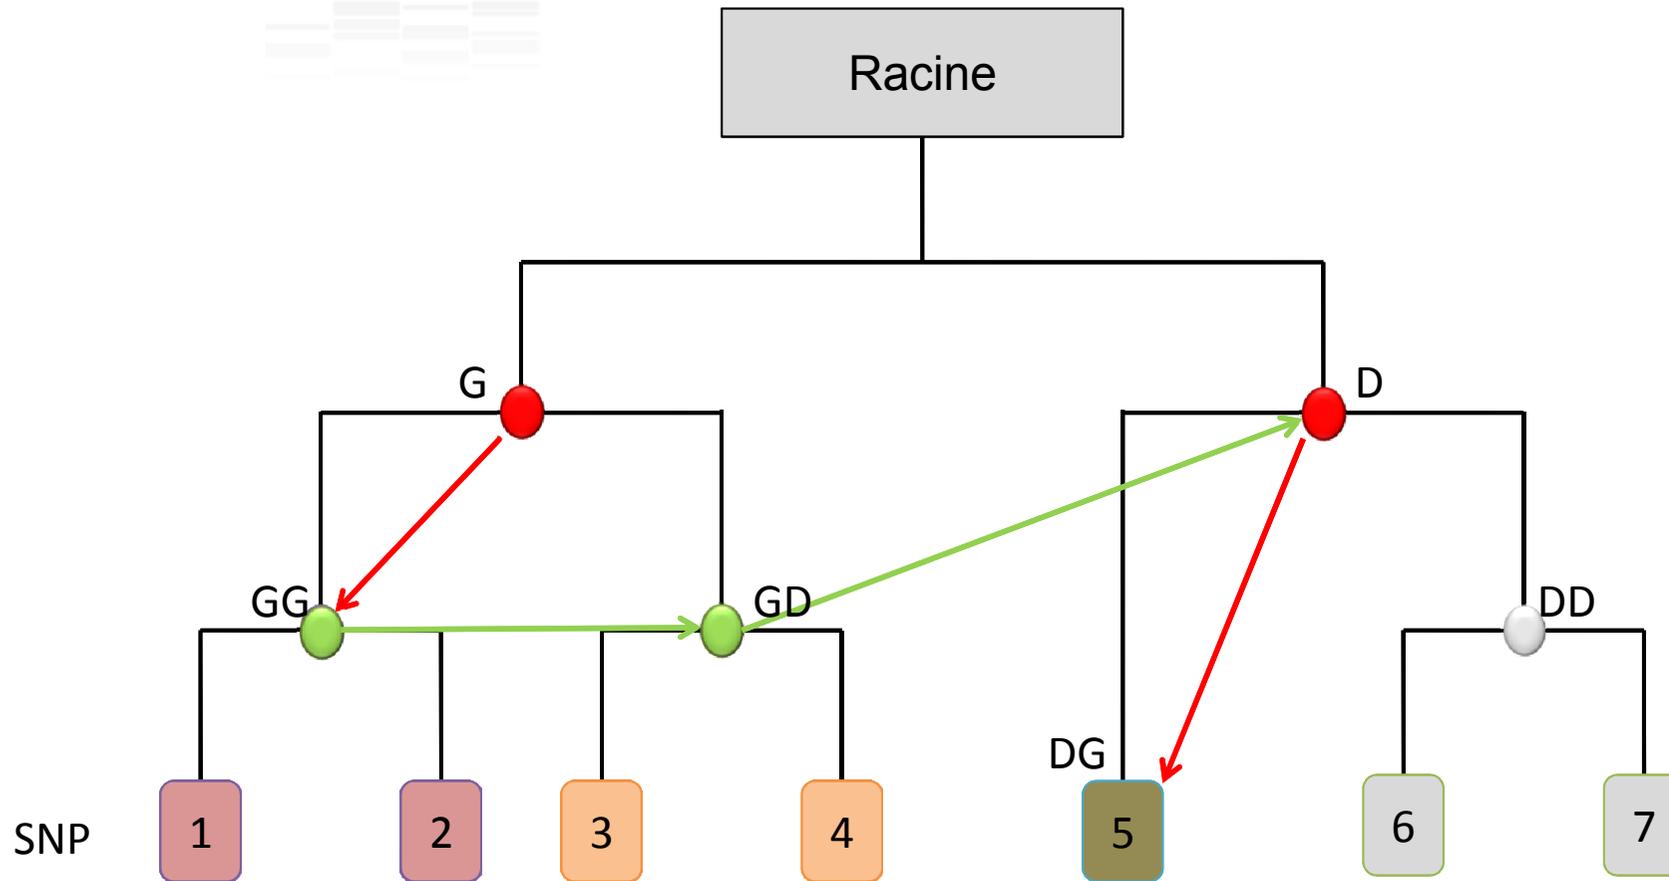
Sélections des ensembles de SNP / DL.



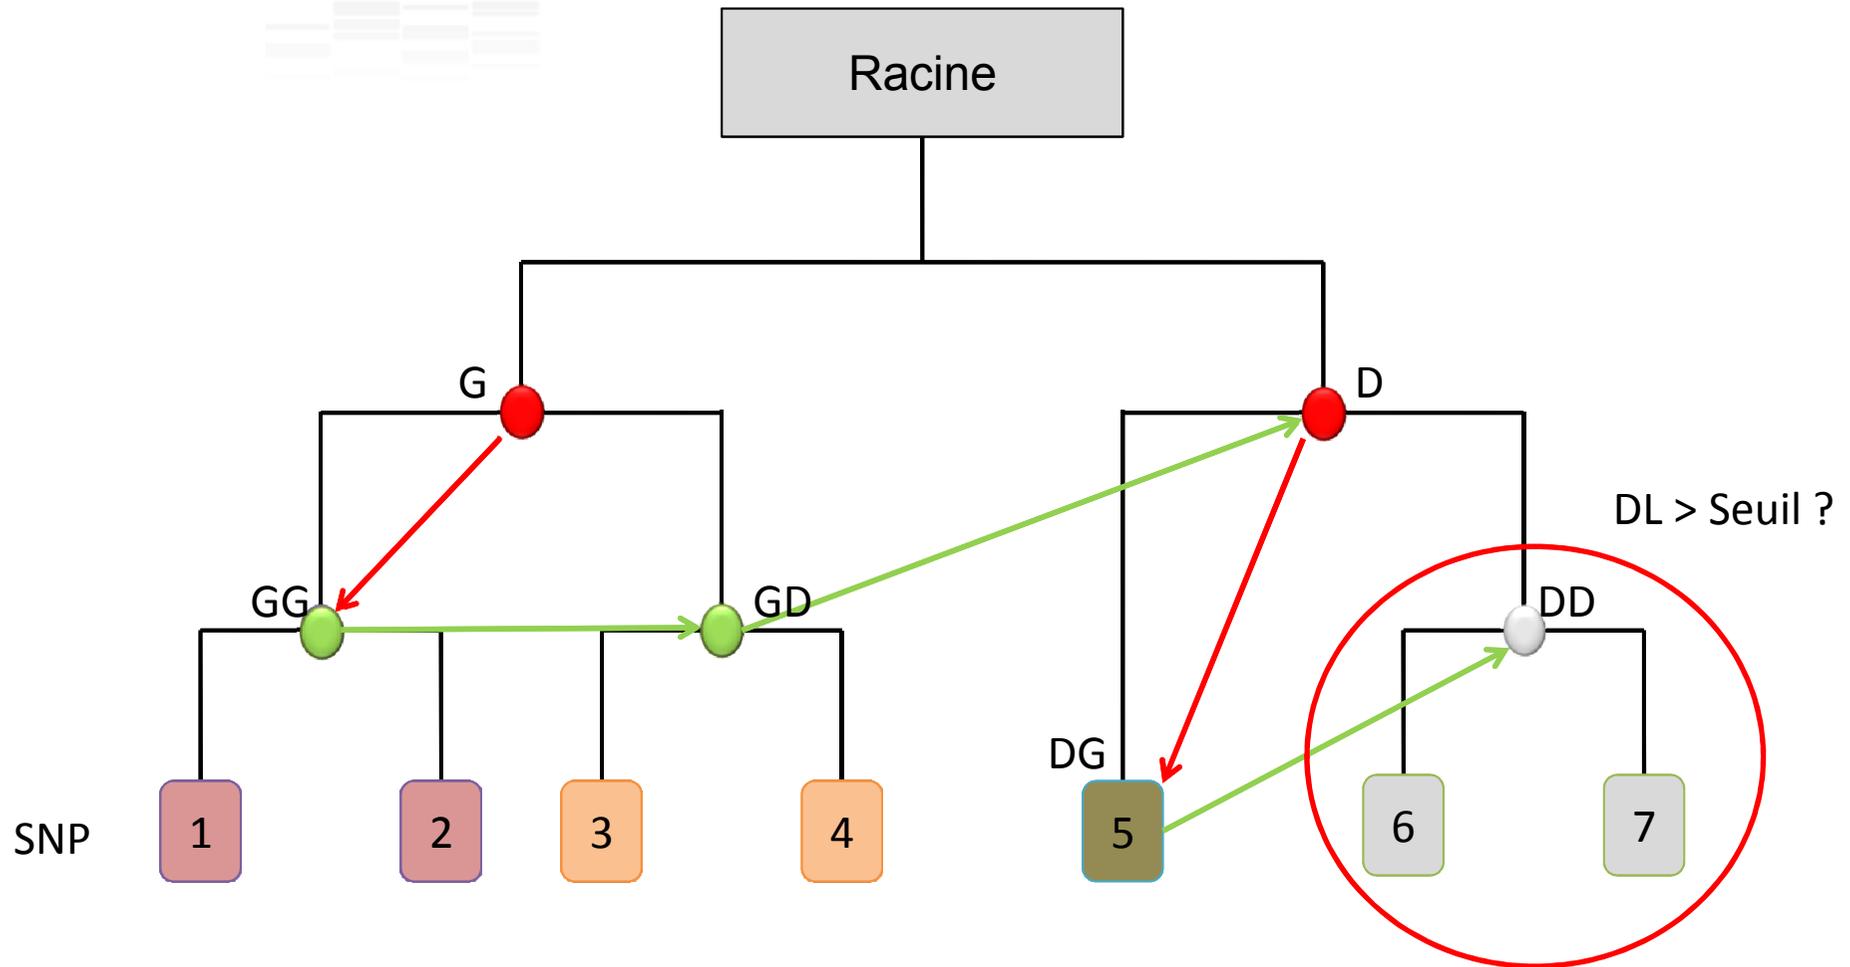
Sélections des ensembles de SNP / DL.



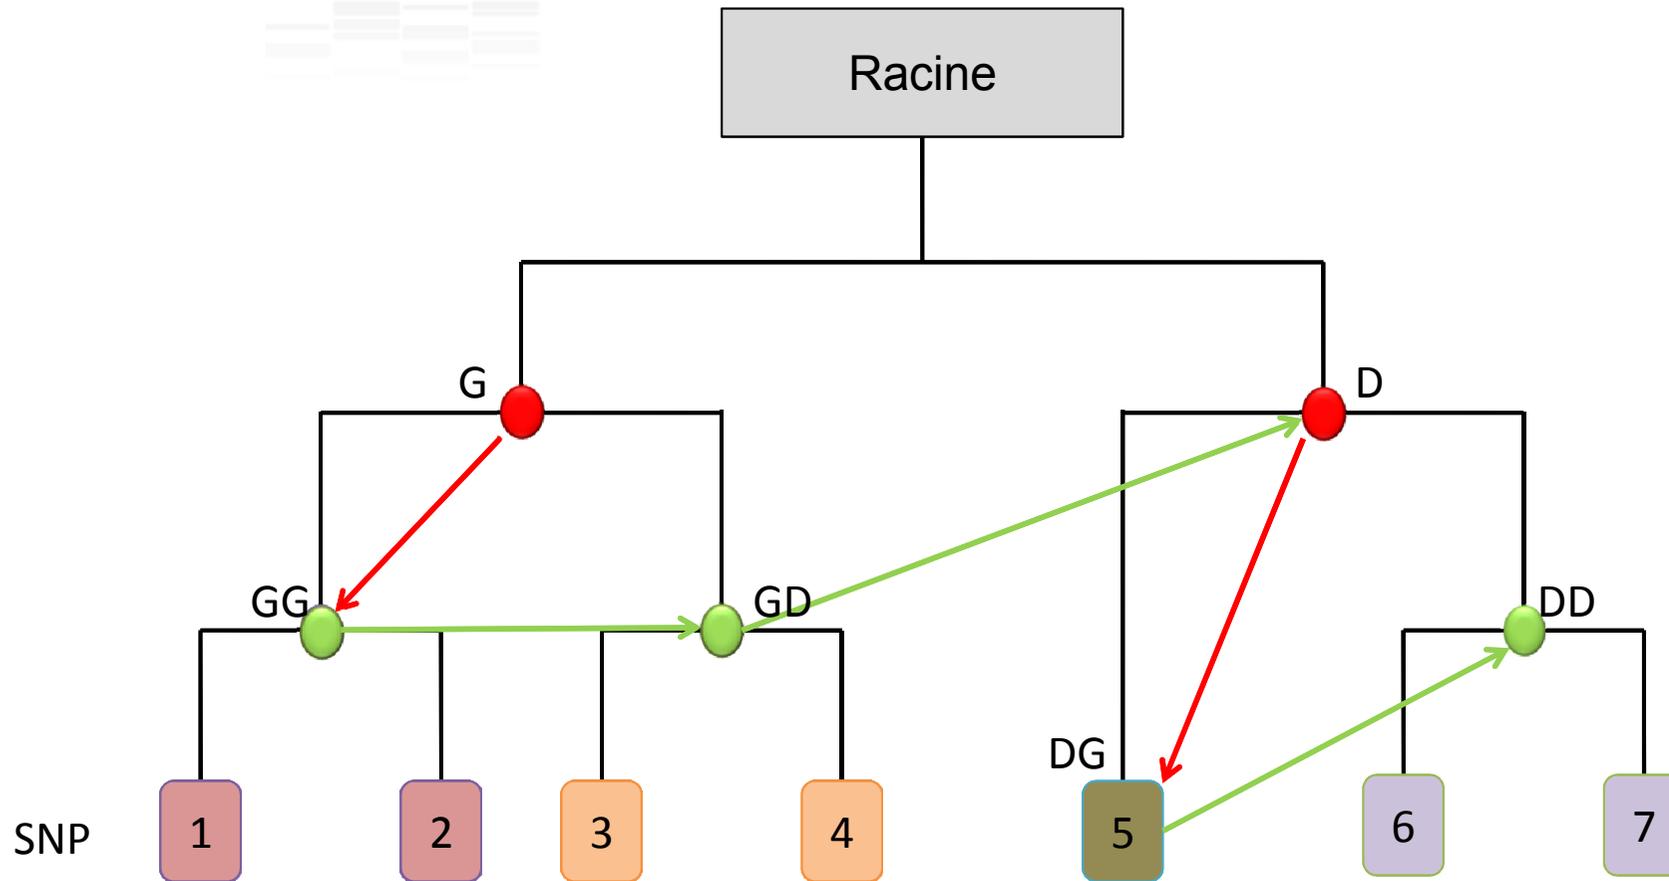
Sélections des ensembles de SNP / DL.



Sélections des ensembles de SNP / DL.



Sélections des ensembles de SNP / DL.



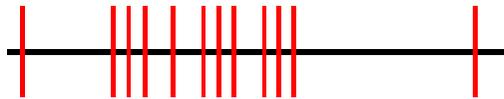


Sélection d'un SNP dans chaque ensemble.

- ✓ Au sein de chaque groupe:
 - MAF du SNP : la plus forte
 - Position du SNP / autres SNP du groupe.

Sélection d'un SNP dans chaque ensemble.

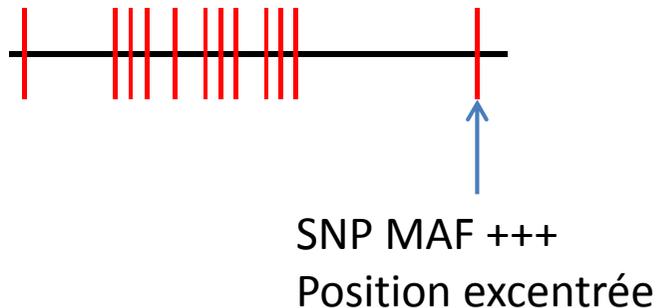
- ✓ Au sein de chaque groupe:
 - MAF du SNP : la plus forte
 - Position du SNP / autres SNP du groupe.



Sélection d'un SNP dans chaque ensemble.

✓ Au sein de chaque groupe:

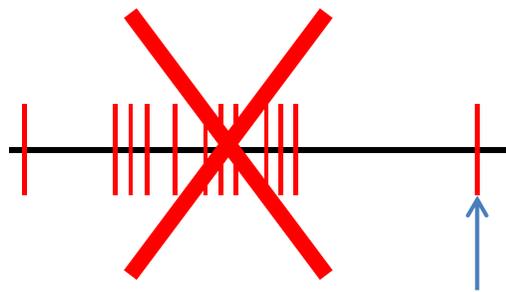
- MAF du SNP : la plus forte
- Position du SNP / autres SNP du groupe.



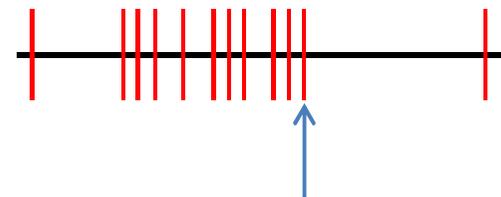
Sélection d'un SNP dans chaque ensemble.

✓ Au sein de chaque groupe:

- MAF du SNP : la plus forte
- Position du SNP / autres SNP du groupe.



SNP MAF +++
Position excentrée



SNP MAF ++
Position représentative du groupe

Fichier « input »

- ✓ Trois fichiers sont nécessaires au fonctionnement du programme.
 - Un fichier de génotypage au format PLINK «.ped»:
6 colonnes + génotype, 1 ligne par individu

Family ID, Individual ID, Paternal ID, Maternal ID, Sex, Phenotype & Genotype

```
Uto_124 Uto_124 0 0 0 -9 G G T T T T
Uto_13 Uto_13 0 0 0 -9 G G T T C T
Uto_243 Uto_243 0 0 0 -9 A G T T T T
Uto_244 Uto_244 0 0 0 -9 G G T T C T
Uto_273 Uto_273 0 0 0 -9 G G T T T T
```

Fichier « input »

- ✓ Trois fichiers sont nécessaires au fonctionnement du programme.
 - Un fichier de génotypage au format PLINK «.ped»
 - Un fichier de carte au format PLINK «.map»:
4 colonnes, 1 ligne par SNP

Chromosome, SNP identifier, Genetic distance, Base-pair position

25	AX-77283174	0	5208
24	AX-80751587	0	6369
28	AX-76388168	0	6695
28	AX-76388358	0	7122
25	AX-80909995	0	7629

Fichier « input »

- ✓ Trois fichiers sont nécessaires au fonctionnement du programme.
 - Un fichier de génotypage au format PLINK «.ped»
 - Un fichier de carte au format PLINK «.map»
 - Un fichier paramètre.

Fichier « input »

```
# PARAMETERS FILE

#----- INPUT FILES -----
#in_genotype : path to the input genotype file
in_genotype =

#in_map : path to the input map file
in_map =

#----- ANALYSIS PARAMETERS -----
#LD (r2) threshold :threshold for analysis (must be a decimal number, use a point, not a comma)
threshold = 0.5

#chr : chromosome to analyse
#for several chromosomes : chr = 7,8,Y
#for all chromosomes : chr = all
chromosome = all

#SNP_window: Maximum number of consecutive SNP to be consider for the selection.
#for chromosome with a large number of SNP, SNP selection will be realized in several steps.
SNP_window = 35000

#----- OUTPUT -----
#path_out : Location for output files
path_out =
```

Fichier « input »

```
# PARAMETERS FILE

#----- INPUT FILES -----
#in_genotype : path to the input genotype file
in_genotype =

#in_map : path to the input map file
in_map =

#----- ANALYSIS PARAMETERS -----
#LD (r2) threshold :threshold for analysis (must be a decimal number, use a point, not a comma)
threshold = 0.5

#chr : chromosome to analyse
#for several chromosomes : chr = 7,8,Y
#for all chromosomes : chr = all
chromosome = all

#SNP_window: Maximum number of consecutive SNP to be consider for the selection.
#for chromosome with a large number of SNP, SNP selection will be realized in several steps.
SNP_window = 35000

#----- OUTPUT -----
#path_out : Location for output files
path_out =
```

Si SNP > 40 k SNP sur 1 chromosome => problème mémoire !

Fichier « output »

- ✓ Deux fichiers sont générés en sortie.
 - Un fichier log:
 - ✓ rappel des paramètres de l'analyse
 - ✓ déroulement de l'analyse.

```
#### Paramètres de l'analyse:

Fichier.carte:...../Geno_Compar_ScriptR_Python.map
Fichier.genotype:...../Geno_Compar_ScriptR_Python.ped
Seuil.DL:.....0.5
Chromosome:.....all
Fenêtre.d'analyse.maximum.35000.SNP.

#####

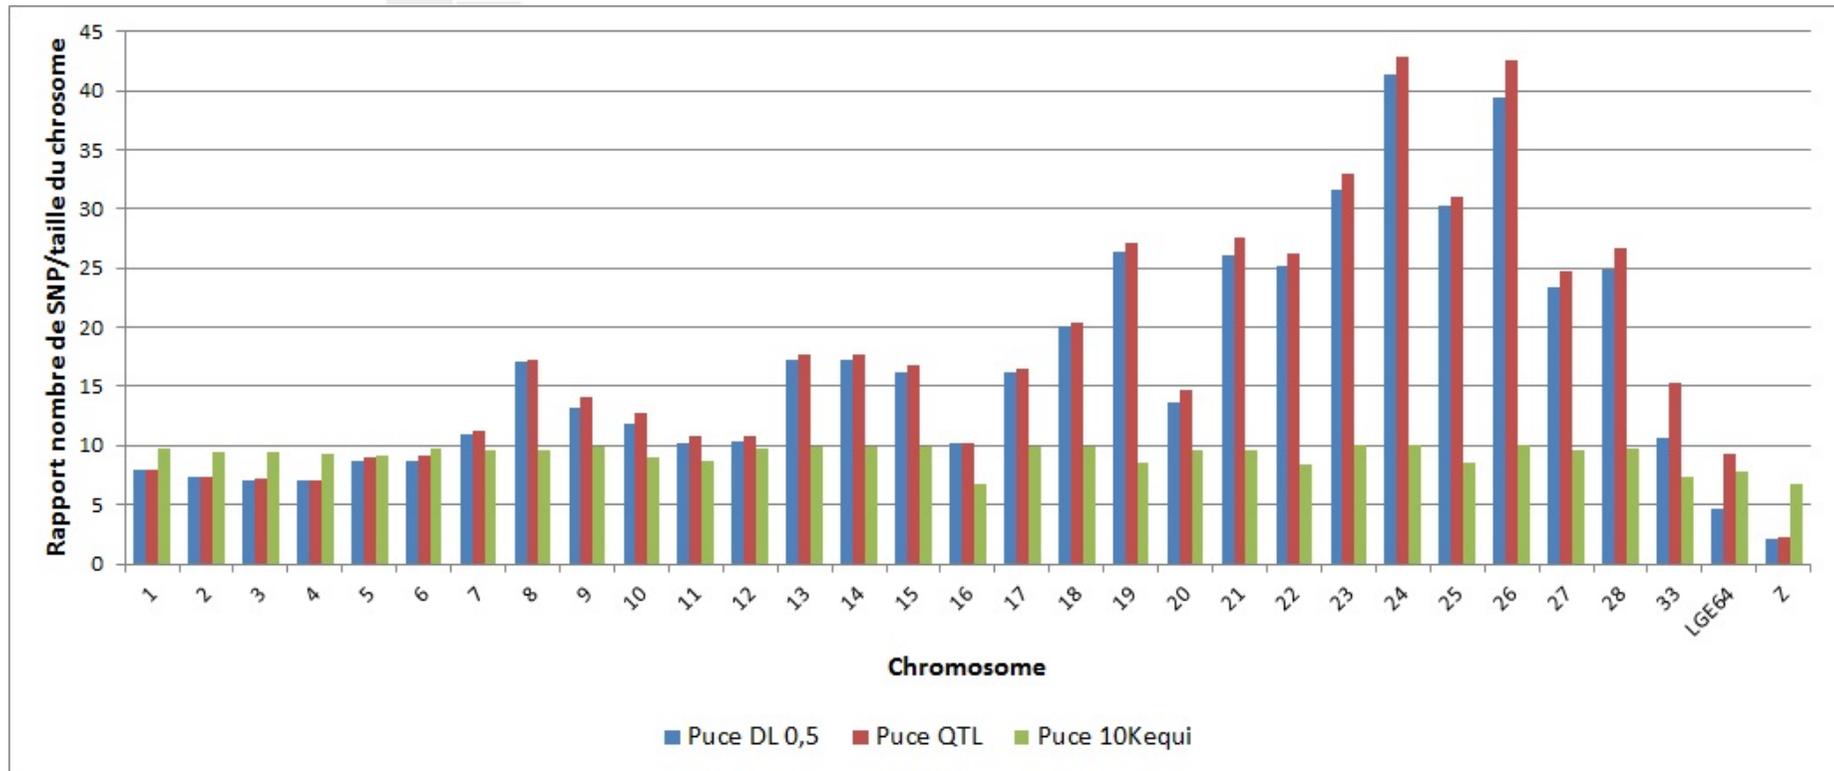
# Chromosome.Z
Le.chromosome.sera.analysé.en.une.seule.fois.
Plink.(fréquence).à.10h48.le.06/10
Plink.(r2).à.10h48.le.06/10
Importation.des.données.MAF.et.DL.à.10h55.le.06/10
SNP.supprimé(s).de.l'analyse.['AX-80820745','AX-77260073','AX-80915400']
Création.du.dendrogramme.à.10h56.le.06/10
Sélection.des.clusters.et.du.snp.représentatif.à.11h00.le.06/10
L'analyse.du.chromosome.Z.s'est.terminée.à.11h00.le.06/10
```

Fichier « output »

- ✓ Deux fichiers sont générés en sortie.
 - Un fichier log
 - Un fichier « Selected_SNP »

```
Nom_SNP : nom du SNP sélectionné dans le clusters
Chromosome : numéro du chromosome sur lequel l'analyse a été réalisé
Position : position physique du SNP sélectionné sur le chromosome
MAF : MAF du SNP sélectionné
Nbre_SNP_cluster : Nombre de SNP présent dans le cluster de SNP
R2_min : R2 minimum au sein du cluster de SNP
R2_max : R2 maximum au sein du cluster de SNP
R2_moyenne : moyenne des R2 au sein du cluster de SNP
R2_écart_type : écart type des R2 au sein du cluster de SNP
Distance_cluster_min : distance minimum entre les SNP du cluster.
Distance_cluster_max : distance maximum entre les SNP du cluster.
Distance_cluster_moyenne : moyenne des distances entre les SNP du cluster.
Distance_cluster_écart_type : écart type à la moyenne des distances entre les SNP du cluster.
SNP_min_distance : distance minimum entre le SNP sélectionné et les autres SNP du cluster
SNP_max_distance : distance maximum entre le SNP sélectionné et les autres SNP du cluster
SNP_moyenne_distance : moyenne des distances entre le SNP sélectionné et les autres SNP du cluster
SNP_écart_type_distance : écart type à la moyenne des distances entre le SNP sélectionné et les autres SNP du cluster
```

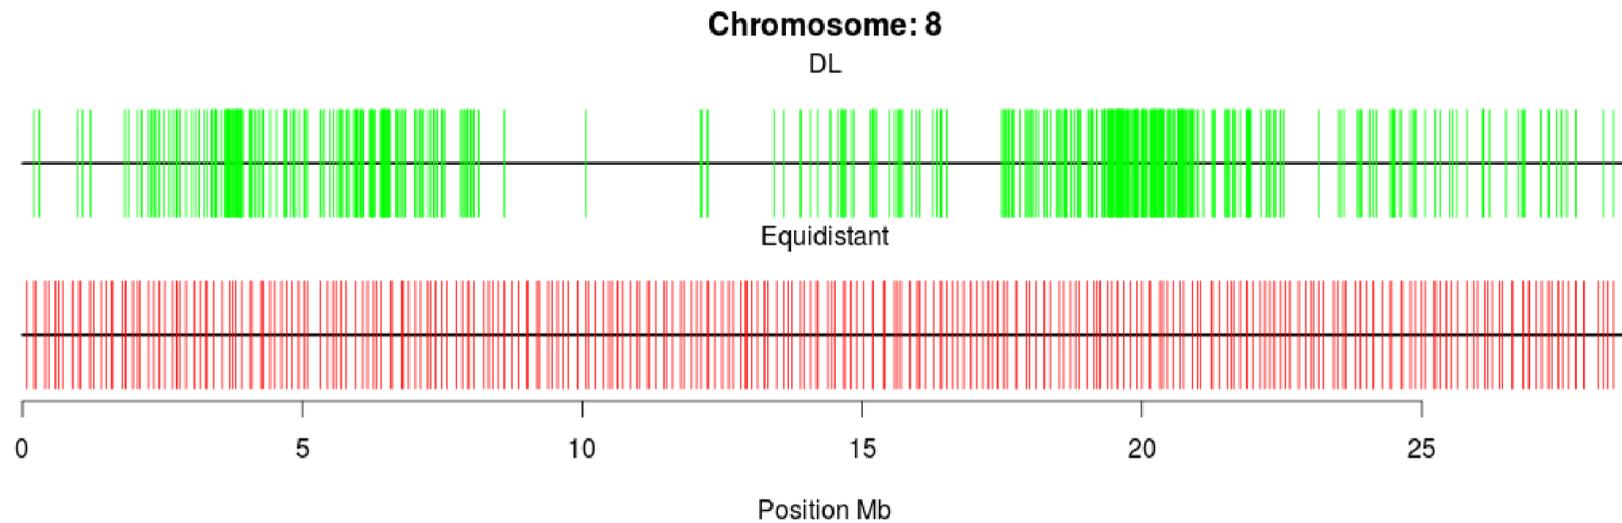
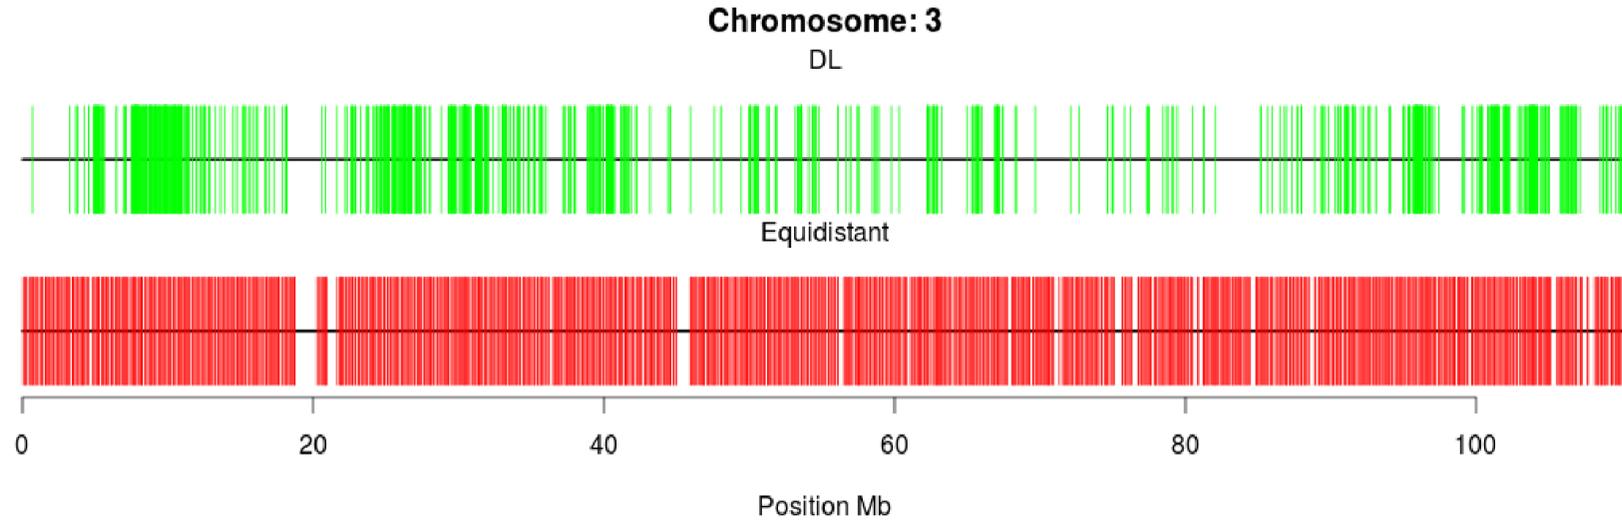
Résultats: Nombre SNP / Chromosome



Florian Herry, mémoire de fin d'études Septembre 2016

- ✓ Optimisation du nombre de SNP sur les macrochromosomes
- ✓ Densification du nombre de SNP sur les microchromosomes

Résultats: Répartition des SNPs.



Exécution du programme:

- ✓ Exécution du programme: bigmem 40 GT
Select_SNP_4_Imputation.py Parameters.txt
- ✓ Analyse de 280 k SNPs sur 31 Chromosomes.
- ✓ Temps d'exécution: 20h.



Merci de votre attention.