

MULLER
0.0.2
Guide de l'Utilisateur

Olivier Filangi *†‡ Anne Ricard §¶ Jean-Michel Elsen ||¶

1^{er} octobre 2013

*`olivier.filangi [at] rennes.inra.fr`

†INRA, UMR1348 PEGASE, Domaine de la Prise, F-35590 Saint Gilles, France

‡Agrocampus Ouest, UMR1348 PEGASE, Domaine de la Prise, F-35590 Saint Gilles, France

§`anne.ricard [at] toulouse.inra.fr`

¶INRA, UMR 1313, 78352 Jouy-en-Josas, France

||`Jean-Michel.Elsen [at] toulouse.inra.fr`

Table des matières

1	Généralités	3
1.1	Introduction	3
1.2	Modèle	3
2	Installation	3
2.1	Pré-requis	3
2.2	Téléchargement	4
2.3	Compilation	4
2.4	Arborescence du package MULLER	4
3	Format des fichiers utilisateurs	4
3.1	Le fichier de pédigree	5
3.2	Le fichier des génotypes	5
3.3	Le fichier des animaux phénotypés	5
3.4	Le fichier carte	6
3.5	Le fichier de description du modèle pour les BLUP	6
3.6	La gestion des données manquantes	7
4	Exécution	7
4.1	Arguments en entrée du programme	7
4.2	Résultat de l'analyse	8
5	Exemple d'analyse	13
5.1	Description du jeu de données	13
5.2	GWAS et obtention des seuils	13

1 Généralités

1.1 Introduction

Müller et al (2011)¹ ont proposé une méthode pour le contrôle de l'erreur de première espèce dans les analyses d'association ou de liaison, basée sur une méthode rapide de simulation. Cette méthode est applicable aux approches de type « genome scan » dans lesquels chaque chromosome est exploré en testant successivement la présence d'un QTL en une succession de localisations. La méthode prend en compte la non-indépendance, engendrée par la liaison génétique, entre les distributions des statistiques de test aux différentes positions. Elle le fait très rapidement par le calcul des éléments de la matrice des covariances entre ces statistiques de test et sa décomposition spectrale.

Le logiciel développé dans le cadre de Rules & Tools est une application directe de l'algorithme proposé et permet d'exécuter des BLUP (programme BLUPF90 de Ignacy Misztal et collaborateurs, University of Georgia) afin d'obtenir les tests statistiques pour chaque SNP du groupe de liaison testé et enfin de calculer des seuils de rejets objectifs de l'hypothèse d'absence de QTL sur un groupe de liaison.

1.2 Modèle

Le GWAS est réalisé avec un modèle mixte pour chaque SNP.

$$y = \mathbf{1}\mu + \mathbf{X}b + \mathbf{Z}u + \mathbf{e} \quad (1)$$

y le vecteur des performances

μ l'effet moyen général à la population

b l'effet de l'allèle

\mathbf{X} le vecteur des génotypes au SNP testé (=0/1/2)

\mathbf{Z} la matrice d'incidence des performances sur les valeurs polygéniques.

\mathbf{e} la résiduelle

$V(\mathbf{u}) = \mathbf{A}\sigma_u^2$, \mathbf{A} étant la matrice de parenté.

2 Installation

2.1 Pré-requis

- Un compilateur fortran : gfortran (GNU) ou ifort (Intel)
- L'outil de génération de makefile CMake - Cross Platform Make
- L'une des bibliothèques suivantes :
 - Automatically Tuned Linear Algebra Software (ATLAS)
 - Librairie LAPACK (Linear Algebra PACKage)

1. Müller BU, Stich B, Piepho HP, 2011. A general method for controlling the genome-wide type I error rate in linkage and association mapping experiments in plants. *Heredity* 106 : 825-831

- Intel Math Kernel Library (Intel MKL)
- Le logiciel R (The R Project for Statistical Computing) pour la génération des graphiques

2.2 Téléchargement

Le programme est régi sous la licence GPLv3. Les versions figées de MULLER sont librement téléchargeables sur la forge du département de Génétique Animale de l'INRA.

2.2.1 Obtenir la version de développement sous Linux

```
svn export https://forge-dga.jouy.inra.fr/svn/ldmuller muller-dev
```

Il faut générer l'environnement de développement en utilisant cmake :

```
mkdir -p build/debug;cd build/debug
cmake -DCMAKE_BUILD_TYPE=Debug -DCMAKE_Fortran_COMPILER=gfortran ../..
```

2.3 Compilation

Si les bibliothèques ATLAS/LAPACK/MKL ne sont pas installées dans `/usr/lib` :

```
export LD_LIBRARY_FLAGS=<path-lapack-ou-atlas-ou-mkl>:${LD_LIBRARY_FLAGS}
```

Pour compiler et installer le programme dans le répertoire `<path-for-pls4snp>` :

```
cmake -DCMAKE_INSTALL_PREFIX=<path-install> ../..;make;make install
```

2.4 Arborescence du package MULLER

Description du contenu du répertoire d'installation de MULLER :

- `bin/muller` L'exécutable ;
- `share/doc/muller.pdf` Cette documentation ;
- `share/muller/README` Information sur le logiciel ;
- `share/muller/example` Jeu de données exemple.

3 Format des fichiers utilisateurs

Le programme MULLER utilise un fichier de génotypes (au format AIPL), un fichier de phénotypes et un fichier de généalogies. Les identifiants des animaux sont numériques.

3.1 Le fichier de pédigree

Le fichier pédigree a trois colonnes : animal, père, mère. Les champs sont séparés par un espace. Tous les animaux doivent être renumérotés de 1 à N. Les parents inconnues sont identifiées par la valeur 0.

```
1 0 0
2 0 0
3 0 0
4 0 0
5 1 2
6 1 2
7 1 2
8 3 4
9 3 4
10 3 4
```

3.2 Le fichier des génotypes

Le fichier des données de génotype contient l'information aux marqueurs pour chacun des descendants. Ce format renseigne l'identifiant de l'individu en première colonne (numérique) et en deuxième colonne une chaîne de caractères décrivant l'information moléculaire. Ce fichier ne contient pas d'entête

3.2.1 Le format AIPL

L'identifiant des animaux (entier positif) est codé sur les 10 premiers caractères. Une option d'exécution permet de réduire ou d'augmenter ce champ. L'identifiant et le génotype sont séparés par un espace. Le génotype d'un individu est codé sur une chaîne de caractères. Ce codage utilise 4 valeurs entières. Une valeur est associée à chaque marqueur SNP :

- 0 pour le statut homozygote au premier allèle ;
- 1 le statut hétérozygote ;
- 2 le statut homozygote au deuxième allèle ;
- 5 le statut "valeur manquante".

```
4500 11211211
4501 01112102
4502 01211102
4503 01111102
...
```

3.3 Le fichier des animaux phénotypés

Ce fichier contient plusieurs colonnes avec les données suivantes (il n'est pas obligatoire de donner ces informations dans cet ordre) :

- identifiant

- effets fixés
- covariables
- mesure des phénotypes

L'exemple ci-dessous décrit un fichier avec l'identifiant en première colonne, un effet fixé en deuxième colonne et une mesure en troisième colonne.

```
10538 2 24.80373324
10722 2 20.58580806
9960 1 24.32563858
10239 2 18.3071405
...
```

3.4 Le fichier carte

Ce fichier décrit les groupes de liaison du jeu de données. Un groupe de liaison est défini sur une ligne et contient trois champs : le nom du groupe de liaison, l'index du premier SNP, l'index du dernier SNP.

```
CH1 1 4998
CH2 4999 9995
```

3.5 Le fichier de description du modèle pour les BLUP

Ce fichier décrit (avec la même syntaxe que GS3 ou BLUPF90) le fichier de performances et permet de prendre en compte les effets de nuisance dans le modèle.

- **NUMBER_OF_EFFECTS** : nombre d'effets de nuisance dans le modèle
- **RECORD ID** : indice de la colonne où se trouvent les identifiants dans le fichier des phénotypes
- **OBSERVATION(S)** : indice de la colonne de la performance à étudier (indiquez une seule colonne !)
- **EFFECTS : POSITIONS_IN_DATAFILE NUMBER_OF_LEVELS TYPE_OF_EFFECT** : description des effets de nuisances
 - indice de la colonne de l'effet
 - nombre de niveaux de l'effet (0 si covariable)
 - nature de l'effet : *cross* (effet fixé), *cov* (covariable)

```
NUMBER_OF_EFFECTS
1
RECORD ID
1
OBSERVATION(S)
3
EFFECTS: POSITIONS_IN_DATAFILE NUMBER_OF_LEVELS TYPE_OF_EFFECT
2 2 cross
```

3.6 La gestion des données manquantes

Seul le fichier de génotypes peut contenir des valeurs manquantes. Les individus sans statut au génotype ne seront pas utilisés dans le BLUP à cette position.

4 Exécution

4.1 Arguments en entrée du programme

- --geno <pathfile>, -g <pathfile> : Le fichier des génotypes ;
- --model <patternfile>, -z <pathfile> : Le fichier décrivant le fichier des performances ;
- --pedig <pathfile>, -p <pathfile> : Le fichier pedigree ;
- --data <pathfile>, -d <pathfile> : Le fichier des performances ;
- --map <pathfile>, -c <pathfile> : Le fichier carte
- --solution <pathfile>, -b <pathfile> : Le fichier des résultats des BLUP sur le groupe de liaison ;
- --out <pathfile>, -o <pathfile> : Le fichier des résultats de l'analyse ;
- --h2 <integer>, -h <integer> : Héritabilité du caractère étudié.

4.1.1 Arguments optionnels

- --idlength <integer>, -i <integer> : Nombre de caractères utilisés pour le codage de l'identifiant numérique dans le fichier de génotypage (10 par défaut).
- --vary <float>, -v <float> : La variance phénotypique (par défaut on utilise l'estimateur classique) ;
- --nsim <integer>, -s <integer> : nombre de simulations pour le calcul des seuils de rejet de H0 (1000 par défaut) ;
- --maf <float>, -m <integer> : fréquence minimum pour le calcul des BLUP. (les autres positions sont ignorées) ;
- --nmaxpval <integer>, -x <integer> : nombre de positions à afficher dans un ordre décroissant (pour l'affichage des plus gros effets) (30 par défaut) ;
- --nthread <integer>, -N <integer> : Nombre de processus utilisés par l'application.

4.1.2 Ligne de commande

Execution du programme en ligne de commande :

```
>${MULLER_PATH}/muller --geno <genotype-file> --model <parameter-file>
--pedig <pedigree-file> --data <data-file> --c <carte-file> --solution <solution-file>
--out <output.file>
--h2 <real> --nthread <number-of-threads>
```

4.2 Résultat de l'analyse

4.2.1 Interprétation de la sortie standard

La sortie standard peut être redirigée dans un fichier avec l'option `-out`. La sortie standard donne :

- un récapitulatif des données en entrée du programme
- l'état de l'exécution et son étape

Affichage des options disponibles et information sur le jeux de données de l'utilisateur

```
===== OPTIONS =====
--geno,      -g      : genotype file
--model,     -z      : Model file
--pedig,     -p      : Pedigree file
--data,      -d      : Data file
--map,       -c      : map file
--solution,  -b      : Solution file
--out,       -o      : Result file
--idlength,  -i      : Length ID in the genotype file (default=10)
--vary,      -v      : phenotypic variance (optional, by default
                    this quantity is compute with the classical estimator)
--h2,       -h      : heritability
--nsim,      -s      : Number of simulation (default=1000)
--maf,       -m      : Minimum MAF (default=0.02)
--nmaxpval,  -x      : Maximum number of pvalue to rank (default=30).
--nthread,   -N      : Number of thread usable by the program (default=1).

read model file...
[data] number of record =          781
[pedigree] Number of record=       17000
read      1609 genotype.
Genotype First ID [          6625 ] =>          1          1          0          0
          0          2          0          0          0          0 ...          2
Genotype Last ID [        15500 ] =>          0          0          1          1
          0          2          1          0          0          1 ...          2
```

Les deux dernières lignes donnent l'information au premier marqueur et dernier marqueur du premier et du dernier individu. Il permet de vérifier que le logiciel interprète correctement le fichier de typage. Attention, L'ID de l'individu est codé sur les 10 premiers caractères de la ligne (format fixe). L'option `-idlength` permet de changer ce codage.

Pour obtenir un format valide, vous pouvez appliquer ce script awk à votre fichier (un nouveau fichier de génotypage est créé) :

```
>awk '{printf("%10s %s\n", $1, $2)}' mon_fichier_genotypes > mon_fichier_genotypes.new
```

Calcul des BLUP

```
=====
call      3704 BLUPF90.
==> [100%]
Writing sol.txt file [id snp maf perfo test pvalue sol solmu std stdmu].
```

Construction de la matrice des covariances entre les statistiques de test

```
===== Prepare covariance matrix to compute rejection thresholds =====
===
==> [100%]
Apply an ACP (DSYEV, Matrix dim=      3704      3704 )
=====
size(Eigenvalues<0) =      2831
```

Phase de simulation pour l'obtention des seuils

```
===== SIMUL =====
# ID      1
# Jump Ahead by (1)*2^256
# ID      3
# Jump Ahead by (3)*2^256
# ID      7
# Jump Ahead by (7)*2^256
# ID     11
# Jump Ahead by (11)*2^256
# ID      9
# Jump Ahead by (9)*2^256
# ID      5
# Jump Ahead by (5)*2^256
# ID     12
# Jump Ahead by (12)*2^256
# ID      6
# Jump Ahead by (6)*2^256
# ID      8
# Jump Ahead by (8)*2^256
# ID      4
# Jump Ahead by (4)*2^256
# ID      2
# Jump Ahead by (2)*2^256
# ID     10
# Jump Ahead by (10)*2^256
==> [ 97%] ==> [100%]
```

4.2.2 Le Fichier solution

id	snp	chr	maf	nbani	test	pvalue	sol	solmu	std	stdmu
1	1	CH1	0.615	781	1.22830570	0.26807502	0.31856695	22.37480354	0.28744018	1.64028180
2	2	CH1	0.446	781	0.16485445	0.68482065	0.12362301	22.80883217	0.30447313	1.61913240
3	3	CH1	0.138	781	0.60847157	0.43559730	0.33388221	22.59590340	0.42802894	1.62698805
4	4	CH1	0.139	781	0.70767516	0.40046349	0.36049289	22.56092072	0.42852852	1.62768149
5	5	CH1	0.212	781	2.92809749	0.08744607	0.65049422	22.11792183	0.38014624	1.62162852
6	7	CH1	0.156	781	1.21609950	0.27046061	0.44494802	22.46688461	0.40348253	1.61345613
7	8	CH1	0.237	781	2.35459590	0.12531815	0.56575000	22.21228027	0.36869425	1.62136519
....										

Ce fichier donne les résultats des BLUP calculés sur le génome.

- Identifiant du blup
- Identifiant du SNP
- Chromosome porteur du SNP
- *Minor Allele Frequency* du SNP
- Nombre d'animaux utilisé dans le calcul du BLUP (les génotypes manquants au SNP ne sont pas dans l'analyse)

- Test de Fisher
- Pvalue
- Solution pour b et μ et leurs écarts types.

4.2.3 Seuils de rejets

Le programme écrit dans le fichier paramétré par l'option `-out` les seuils de rejets (10, 5 et 1%) et les SNP ayant les plus grands effets.

```
[out file=out.txt]
[genotype file=genotypes1.uga]
[map file=carte]
[sizeid=10]
[nmaxpval=      30 ]
* no phenotyped variance defined *
[h2=  0.8500000000000000 ]
[maf=  1.999999955296516E-002 ]
[number of simulation=      1000 ]
[model file=parm]
[pedigree file=genealogie]
[data file=performances]
[solution file=performances]
[nthread=      6 ]

=====

Number of Linkage Groupe:      2

      Chr  Start      End  Number
CH1          1      4998      4998
CH2         4999      9995      4997

[phenotypic variance=  33.2113082290613 ]
[residual variance=   4.98169623435920 ]
[genetic variance=   28.2296119947021 ]

-----
+++++ REJECTION THRESHOLDS GL=CH1+++++
-----

=====
|  Level  |  PValue  | -Log10(Pvalue) |
-----
|   10%  | 0.00010 |         4.003  |
|    5%  | 0.00004 |         4.378  |
|    1%  | 0.00000 |         5.390  |
=====

-----
+++++ HIGHEST PVALUES GL=CH1 +++++
-----

=====
|  Rank  |  SNP    | -Log10(Pvalue) |
-----
|    1  | 3777   |         4.159  |
|    2  | 3785   |         4.048  |
|    3  | 3778   |         3.968  |
|    4  | 3781   |         3.807  |
|    5  | 3787   |         3.698  |
|    6  | 3784   |         3.650  |
|    7  | 3779   |         3.383  |
|    8  | 3776   |         3.236  |
|    9  | 3807   |         3.178  |
|   10  | 3432   |         3.090  |
|   11  | 3435   |         3.090  |
```

12	3766	3.063
13	1591	2.977
14	3699	2.920
15	3769	2.915
16	3772	2.915
17	3795	2.901
18	3815	2.854
19	3817	2.854
20	3786	2.833
21	3775	2.811
22	3801	2.772
23	3803	2.738
24	3804	2.738
25	3805	2.738
26	3774	2.733
27	3197	2.607
28	3170	2.588
29	4024	2.571
30	3179	2.532

 ++++++ VISUALIZATION (USING R) GL=CH1 ++++++

Pvalues distribution (compare theoretical distribution with real pvalues) / Manha
 ttan plot

run "R -f out.txt_CH1_genGraphR.R" to generate all graphics.

 ++++++ REJECTION THRESHOLDS GL=CH2 ++++++

Level	PValue	-Log10(Pvalue)
10%	0.00012	3.936
5%	0.00005	4.336
1%	0.00001	4.903

 ++++++ HIGHEST PVALUES GL=CH2 ++++++

Rank	SNP	-Log10(Pvalue)
1	5998	5.136
2	6000	5.136
3	6002	5.136
4	6004	4.984
5	5045	3.853
6	5052	3.700
7	6073	3.670
8	6076	3.668
9	5046	3.635
10	6075	3.574
11	7138	3.439
12	6059	3.309
13	6063	3.190
14	7169	3.084
15	5075	2.949
16	7156	2.926
17	6077	2.796
18	6070	2.604
19	5077	2.564

20	7161	2.475
21	7165	2.475
22	6389	2.397
23	5068	2.336
24	6362	2.318
25	5069	2.305
26	5073	2.284
27	5074	2.284
28	6230	2.275
29	6231	2.275
30	6548	2.261

```
-----
+++++++ VISUALIZATION (USING R) GL=CH2 ++++++
```

```
Pvalues distribution (compare theoretical distribution with real pvalues) / Manha
ttan plot
```

```
run "R -f out.txt_CH2_genGraphR.R" to generate all graphics.
```

```
The GWAS solutions in file : sol.txt
```

```
+++++++ END GWAS ++++++
```

```
Elapsed time:          25 min          26 sec
```

Interprétation des Graphiques le script `genGraphR.R` est généré par l'application pour créer deux graphiques :

- Un QQplot pour vérifier la distribution du test (sous H_0 les pvalues sont distribuées uniformément).
- Un Manhattan plot (pvalues en fonction de la position du SNP)

Pour obtenir les graphes :

```
>R -f genGraphR.R
```

4.2.4 Paramétrage applicatif

Redirection de la sortie standard L'option `-out` permet de rediriger les résultats dans un fichier (seuils de rejets et ordonnancement des SNP ayant les plus grand effets).

Filtre sur la MAF des SNP Par défaut le programme enlève les SNP ayant une MAF < 0.02 . Ce comportement est paramétrable avec l'option `-maf`.

Tableau des SNP ayant un fort effet Par défaut l'application affiche les 30 meilleurs SNP. L'option `-nmaxpval` permet de changer ce comportement.

Performance pour l'exécution La vitesse d'exécution est fortement dépendante du nombre de thread donné en argument du programme (option `-nthread`). Vous devez vous assurer que la machine dispose des ressources suffisantes pour paramétrer cette option.

5 Exemple d'analyse

5.1 Description du jeu de données

Un phénotype est simulé sur 2 chromosomes (9995 marqueurs, 1 Morgan/Chr). 1609 animaux sont génotypés et 781 sont phénotypés. La généalogie comporte 17000 animaux. L'héritabilité est de 0.85.

5.1.1 Position des marqueurs sur le génome

CHR	Start	End
1	1	4998
2	4999	9995

5.1.2 Effets des QTL sur le génome

CHR	Pos Morgan	SNP flanquant	Effet additif	Effet de dominance
1	20.00	1000	0.5	0.0
1	73.14	3655	1.0	0.0
2	20.00	5999	1.5	0.2
2	33.24	6660	0.5	0.2
2	59.60	7977	0.5	0.0

5.2 GWAS et obtention des seuils

Analyse

```
>${MULLER_PATH}/muller -g genotypes1.uga -z parm -p genealogie  
-d performances -c carte --h2 0.85 --nsim 10000 --solution sol.txt --nthread 6 --out out.txt
```

p_values observées en fonction des théoriques

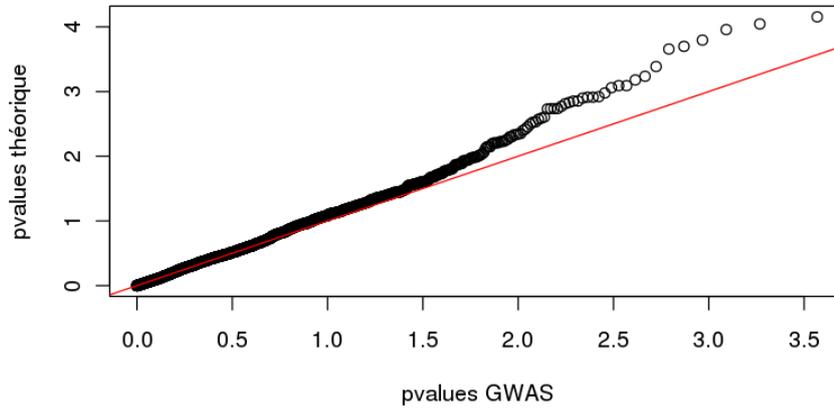


FIGURE 1 – QQ plot du chromosome 1

Manhattan plot - Seuils Muller/Bonferroni

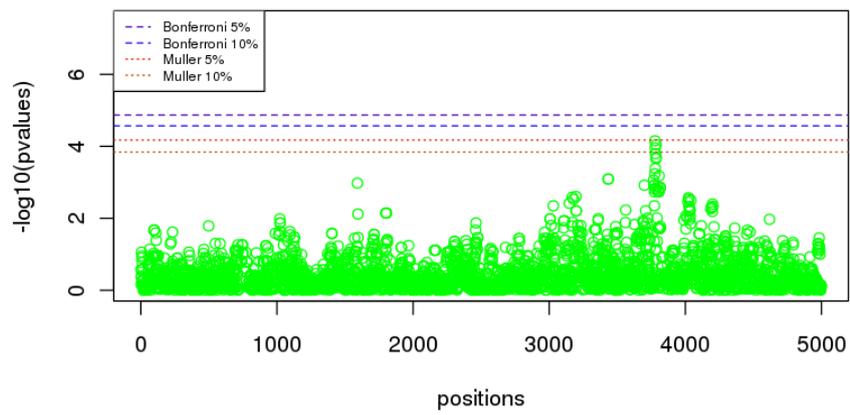


FIGURE 2 – Manhattan plot du chromosome 1

p_values observées en fonction des théoriques CH2

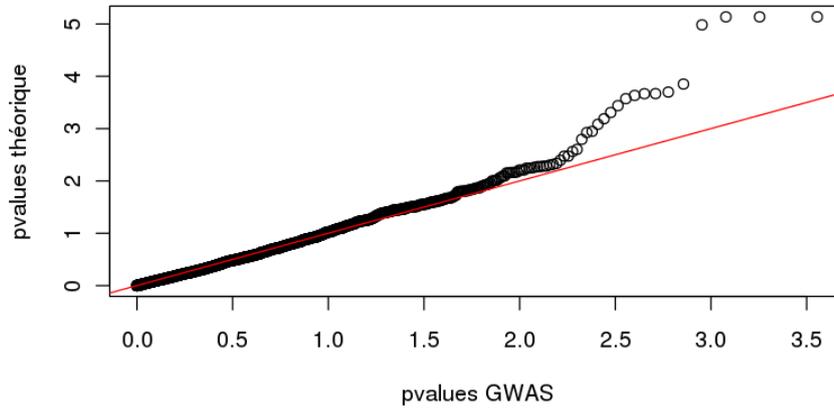


FIGURE 3 – QQ plot du chromosome 2

Manhattan plot - Seuils Muller/Bonferroni CH2

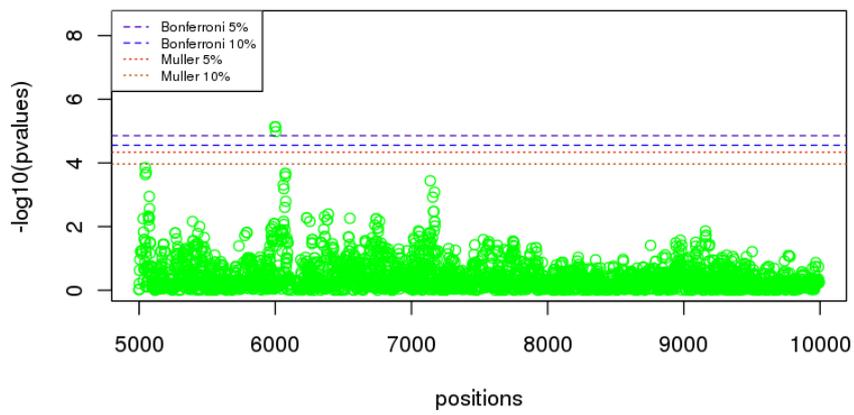


FIGURE 4 – Manhattan plot du chromosome 2