

# Précision et biais des estimations de l'heritabilité avec des SNPs

Andrès Legarra  
(raconté par Hélène Gilbert)

- la notion de parenté / parenté génomique
- l'héritabilité estimée par Yang et al sur la taille chez l'homme
- est ce une erreur d'estimation ?

# Common SNPs explain a large proportion of the heritability for human height

Jian Yang<sup>1</sup>, Beben Benyamin<sup>1</sup>, Brian P McEvoy<sup>1</sup>, Scott Gordon<sup>1</sup>, Anjali K Henders<sup>1</sup>, Dale R Nyholt<sup>1</sup>, Pamela A Madden<sup>2</sup>, Andrew C Heath<sup>2</sup>, Nicholas G Martin<sup>1</sup>, Grant W Montgomery<sup>1</sup>, Michael E Goddard<sup>3</sup> & Peter M Visscher<sup>1</sup>

**first:**

la parenté (génomique):

cet inconnu

*Version 2*

# Messages

- Le LD décrit la parenté (+ ou – ancienne)
- La parenté crée le LD
  - Ce sont deux faces de la même chose – aux mutations près
- Donc ce que l'on fait avec la parenté, on peut le faire avec des SNPs
  - Evaluation génétique
  - Estimation de l'héritabilité
    - J'ai (Andrès) cherché quelle précision d'estimation pour des individus « non apparentés »
  - Corrections lors des études qui impliquent individus « corrélés » (i.e. GWAS appliqué à un ensemble de familles nucléaires)
    - Tout cela en relation avec un article publié dans Nature Genetics

# Mesures de l'apparentement

- Coefficient de parenté  $f_{ij}$  (Malécot coefficient, « kinship ») : se définit comme
  - probability(IBD) pour 2 allèles pris au hasard chez deux individus
  - excès d'allèles partagés par rapport à l'équilibre de H-W (Wright; *can be negative* !!)
- Message : IBD = proxy de l'identité IBS (inconnue) au gène d'intérêt
  - + Coefficient d'apparentement est généralement positif (si fondateurs sont considérés comme non apparentés et équilibre de H-W)
  - + Mais il n'y a pas de besoin d'imposer cette contrainte

# Estimation de l'apparentement à l'aide de SNP

## Rationale for estimating genealogical coancestry from molecular markers

Genetics Selection Evolution 2011, 43:27

***Toro, M.A., García-Cortés, L.A., Legarra, A.***

ETSIA UPM, Ciudad Universitaria 28040 Madrid, Spain.

INIA, Ctra. Coruña Km 7.5 28040 Madrid.

INRA, UR 631 SAGA, F-31326 Castanet Tolosan, France.

Si  $g_{ik}$  est la fréquence (= gene content/2) de l'allèle au SNP  $k$  chez l'individu  $i$

	<i>Individu i</i>	<i>Individu j</i>	$g_{ik}$	$g_{jk}$	$g_{ik} g_{jk}$	$(1-g_{ik})(1-g_{jk})$
Locus 1	AA	AA	1	1	1	0
Locus 2	Bb	Bb	0.5	0.5	0.25	0.25
Locus 3	Cc	CC	0.5	1	0.5	0
.	.	.	.	.	.	.
.	.	.	.	.	.	.
Locus L	mm	MM	0	1	0	0

=2/4

Identité entre individu  $i$  et individu  $j$ , pour  $L$  locus ( $k = 1, \dots, L$ )

$$f_{M(i,j)} = \frac{1}{L} \sum_k [g_{ik} g_{jk} + (1 - g_{ik})(1 - g_{jk})]$$

moléculaire

## 2) Covariance moléculaire

Si  $g_{ik}$  est la fréquence (= gene content/2) de l'allèle au SNP  $k$  chez l'individu  $i$

	<i>Individu i</i>	<i>Individu j</i>	$g_{ik}$	$g_{jk}$
<b>Locus 1</b>	<b>AA</b>	<b>AA</b>	<b>1</b>	<b>1</b>
<b>Locus 2</b>	<b>Bb</b>	<b>Bb</b>	<b>0.5</b>	<b>0.5</b>
<b>Locus 3</b>	<b>Cc</b>	<b>CC</b>	<b>0.5</b>	<b>1</b>
.	.	.	.	.
.	.	.	.	.
<b>Locus L</b>	<b>mm</b>	<b>MM</b>	<b>0</b>	<b>1</b>
		$\bar{g}_i$	<b>2/4</b>	<b>3.5/4</b>

Fréquence allélique  
moyenne intra-  
individu

$$\bar{g}_i = \frac{1}{L} \sum_k g_{ik}$$

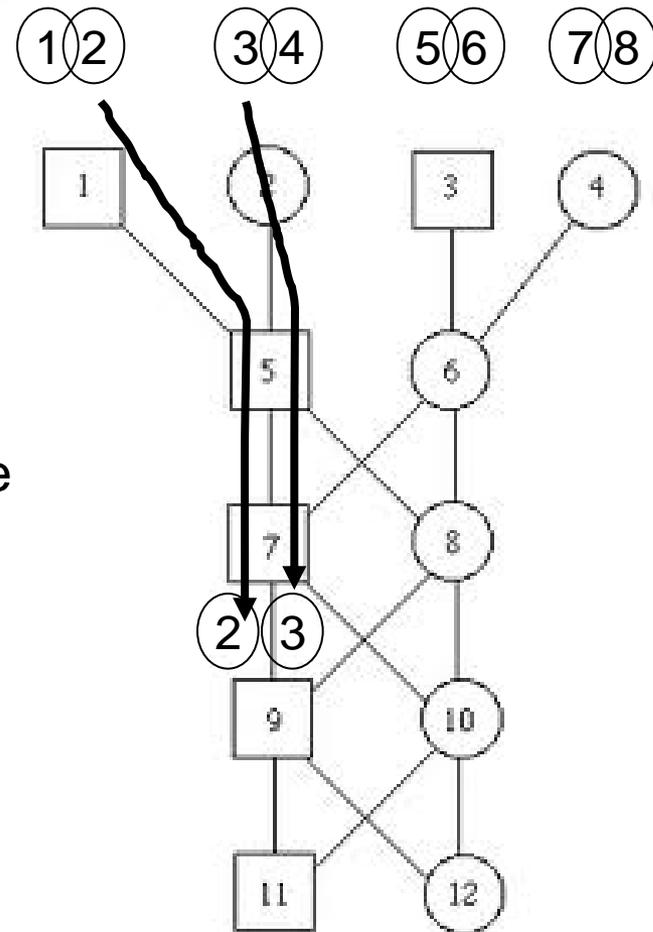
$$Cov_{M(i,j)} = Cov(g_{i...}, g_{j...}) = \frac{1}{L} \sum_k (g_{ik} - \bar{g}_i)(g_{jk} - \bar{g}_j)$$

# Equivalences

- Malécot : suppose  $2N$  allèles fondateurs
- Si on génotype l'individu 9
- *Alors,*
  - Parenté moléculaire = coefficient d'apparentement de Malécot (IBD)

SNP sont bialléliques

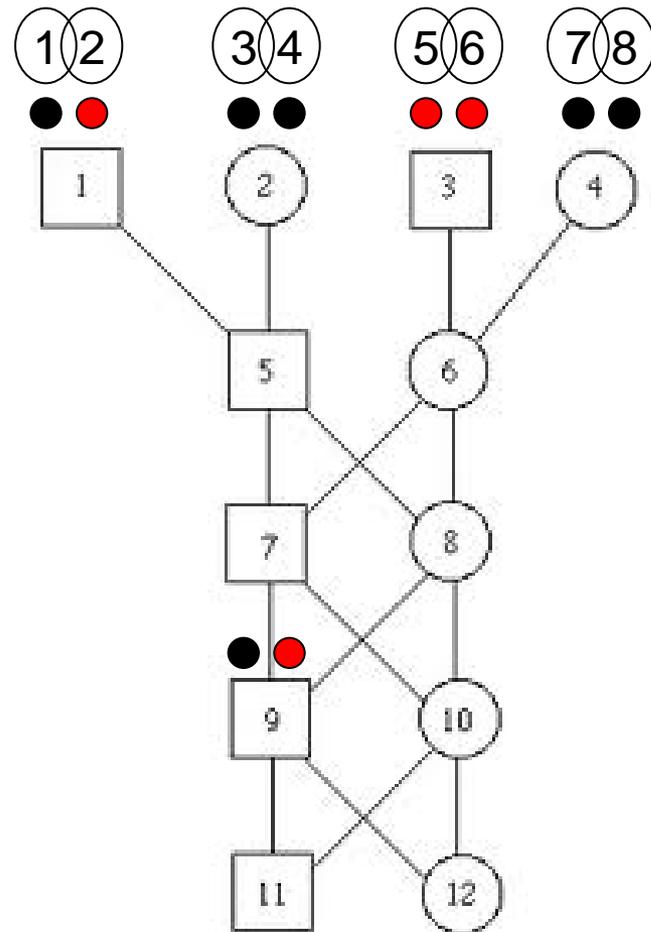
→ Quel effet sur ces équivalences?



# Avec des SNPs...

- Si on assigne un état A ou **a** à chacun des  $2N$  allèles fondateurs au hasard avec une probabilité  $p$  et  $q=1-p$
- Si on génotype l'individu 9

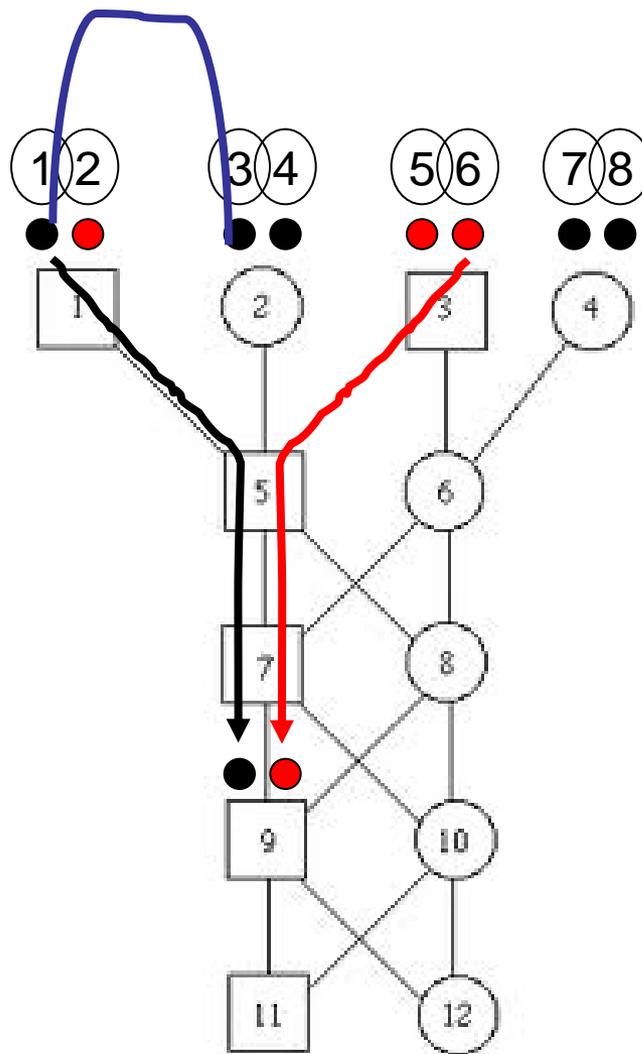
→ Que peut on dire de l'allèle hérité par l'individu 9 parmi les 8 allèles fondateurs?



# Avec des SNPs...

- L'apparentement moléculaire entre deux individus  $i$  et  $j$  est la probabilité que deux allèles soient identiques (alike in state)  $f_{Mij}$ 
  - Soit parce qu'ils sont identiques par descendance
  - Soit parce qu'ils se ressemblent dans la population fondatrice

$$f_{M_{ij}} = p^2 + q^2 + 2pqf_{ij}$$



# En termes de formules (Cockerham, 1969)

- On peut montrer que, *en espérance*,

$$E \text{Cov}_{Mij} = f_{ij}pq$$

Covariance  
moléculaire

apparentement

$$E f_{Mij} = p^2 + q^2 + 2pqf_{ij}$$

Apparentement  
moléculaire

apparentement

- En d'autres termes

$$- \text{Cov}(g_i, g_j) = f_{ij}/pq$$

$$f_{ij} = A_{ij} / 2$$

→ Les estimateurs de l'apparentement  $f_{ij}$  à partir de l'information des SNPs peuvent être obtenus aisément

# Autres estimateurs , exemples de VanRaden's (2008) **G**'s

fondateurs

Not averaged within-  
individual but (possibly)  
within loci

1st  $\Rightarrow \hat{f}_{VR1ij} = \frac{1}{L} \frac{\sum (g_{ik} - p_k)(g_{jk} - p_k)}{\sum p_k(1 - p_k)}$

allelic frequencies are  
« fixed » (not random)

2nd  $\Rightarrow \hat{f}_{VR2ij} = \frac{1}{L} \sum \frac{(g_{ik} - p_k)(g_{jk} - p_k)}{p_k(1 - p_k)}$

numerically unstable if  $p$   
 $\sim 0$

Copied or cited by: Astle & Balding, Aulchenko,  
etc etc

# Message

- Des estimateurs de la parenté « vraie » peuvent être construits comme une forme linéaire de scores de génotypes aux SNPs
- Ces estimateurs sont identiques à une certaine forme d'analyse d'association par régression multiple « tous SNPs »  
(comme on verra ...)

# Common SNPs explain a large proportion of the heritability for human height



Jian Yang<sup>1</sup>, Beben Benyamin<sup>1</sup>, Brian P McEvoy<sup>1</sup>, Scott Gordon<sup>1</sup>, Anjali K Henders<sup>1</sup>, Dale R Nyholt<sup>1</sup>, Pamela A Madden<sup>2</sup>, Andrew C Heath<sup>2</sup>, Nicholas G Martin<sup>1</sup>, Grant W Montgomery<sup>1</sup>, Michael E Goddard<sup>1</sup>, Peter M Visscher<sup>1</sup>

- Ou: La « missing » heritability a toujours été présente

# Missing heritability

- La variation des SNP associée à la taille chez l'homme n'explique qu'une très petite fraction de l'héritabilité estimée sans information marqueurs
- Explication la plus probable:
  - Beaucoup de variabilité et peu de puissance

# Yang et al

- Modèle mixte pour estimer l'héritabilité
- Trouvent une valeur inférieure à leur attente
- Expliquent cela par le fait que la majorité des QTL affectant le caractère doit avoir une MAF  $< 0.1$

# Yang et al, modèle

- Tous les SNP ont un effet : vecteur **a**

$$\mathbf{y} = \sum z_k \mathbf{a}_k + \mathbf{e} = \mathbf{Za} + \mathbf{e}$$

Régression multiple sur tous SNPs en même temps

- Ce qui ressemble à  $\mathbf{g} = \sum z_k \mathbf{a}_k = \mathbf{Za}$   
(valeur génétique = somme des effets SNP)
- En standardisant

$$\text{Var}(\mathbf{g}) = \mathbf{ZZ}' \sigma_u^2 / \mathbf{K} = \mathbf{G} \sigma_u^2$$

$$\hat{f}_{VR1ij} = \frac{1}{L} \frac{\sum (g_{ik} - p_k)(g_{jk} - p_k)}{\sum p_k(1 - p_k)}$$

C'est la même chose (à la notation près)

# Méthodes

- Estimation de l'héritabilité par un REML sur les effets SNPs, appliqué à une population « non apparentée », avec une matrice d'apparentement génomique
- Apparentement estimé avec une formule équivalente à VR1, à une correction de la diagonale près (non utilisée désormais)

$$\hat{f}_{VR1ij} = \frac{1}{L} \frac{\sum_k g_{ik} - p_k}{\sum_k p_k} \frac{g_{jk} - p_k}{1 - p_k}$$

$$A_{jk} = \frac{1}{N} \sum_i A_{ijk} = \begin{cases} \frac{1}{N} \sum_i \frac{(x_{ij} - 2p_i)(x_{ik} - 2p_i)}{2p_i(1 - p_i)}, & j \neq k \\ 1 + \frac{1}{N} \sum_i \frac{x_{ij}^2 - (1 + 2p_i)x_{ij} + 2p_i^2}{2p_i(1 - p_i)}, & j = k \end{cases}$$

- Individus « non apparentés » : apparentements entre -0,025 et 0,025  
 → Est-ce que ce n'est pas la source du problème?

# Résultats

- Estimation de  $h^2 = 0.45 \pm 0.08$
- Estimation pedigree habituelle autour de 0.8

→ Pourquoi?

# Est-ce que l'« apparentement » est un « vrai » apparentement?

- Hypothèse : SNP ne donnent pas l'information d'apparentement réalistes pour l'étude de ce caractères car ce ne sont pas les QTL eux même
  - Quel impact si les MAF des QTL sont < à celles des SNP?
  - Apparentements sous-estimés

Compare  $A_{ij}$  estimés avec les SNP de faibles MAF  $\mathbf{A}^*$  et celles avec les N SNP  $\mathbf{A}$

$$A_{jk}^* = \begin{cases} \beta A_{jk}, & j \neq k \\ 1 + \beta(A_{jk} - 1), & j = k \end{cases} \quad \beta = 1 - \frac{(c + 1/N)}{\text{var}(A_{jk})}$$

$c > 0$  si MAF SNP and QTL sont différentes

# Résultats avec SNP faibles MAF

- $h^2 = 0.84 \pm 0.16$
- Sont ils contents de ce résultat ?

This does not prove that the causal variants have  $MAF < 0.1$ , but it shows that if this were the case, they could explain the estimated heritability of height ( $\sim 0.8$ ).

- Pour Andrès c'est un sous-produit de la manipulation, une propriété mathématique qui ne démontre rien sur les fréquences des QTLs.

# En parallèle

- En bovin lait, poule, porc, nous estimons des  $h^2$  correctement avec la même méthode *sans* manipulation
  - mais les animaux sont assez apparentés
  - donc l'estimation plus précise
- Cherche les biais et précisions des estimateurs de l'héritabilité avec individus « non apparentés »
  - Ou « A la recherche des formules d'autrefois »

# Données

- Individus « non apparentés »
    - suppose
      - $s$  pseudo-familles de
      - $n$  pseudo-cousins liés par
      - $r$ , coefficient corrélation entre individus(parenté).
    - Si estime l'héritabilité:
      - Quel biais?
      - Quelle précision de l'estimateur?
- Formules pour le biais et la précision (standard error) d'estimations de corrélations intra-classes de Ponzoni & James (1978; TAG) pour le biais et Falconer & MacKay (p.182 in "my" Spanish edition) pour les s.e.

# Corrélations intra-classes

- $h^2$  étant considérée comme une corrélation

$$t = \text{Cor } y_{ij}, y_{ik} = \frac{\text{Cov } y_{ij}, y_{ik}}{\sqrt{\text{Var } y_{ij} \text{Var } y_{ik}}} = \frac{\text{Cov } u_{ij}, u_{ik}}{\sigma_y^2} = \frac{r\sigma_u^2}{\sigma_y^2} = rh^2$$

$$\hat{h}^2 = \hat{t} / r$$

- Biais pour l'estimation de  $h^2$  :

$$E \hat{h}^2 - h^2 = \frac{1}{r} \frac{-2(1-t) \left( t + \frac{1-t}{n} \right) \left( t + \frac{1-t}{sn} \right)}{s-1}$$

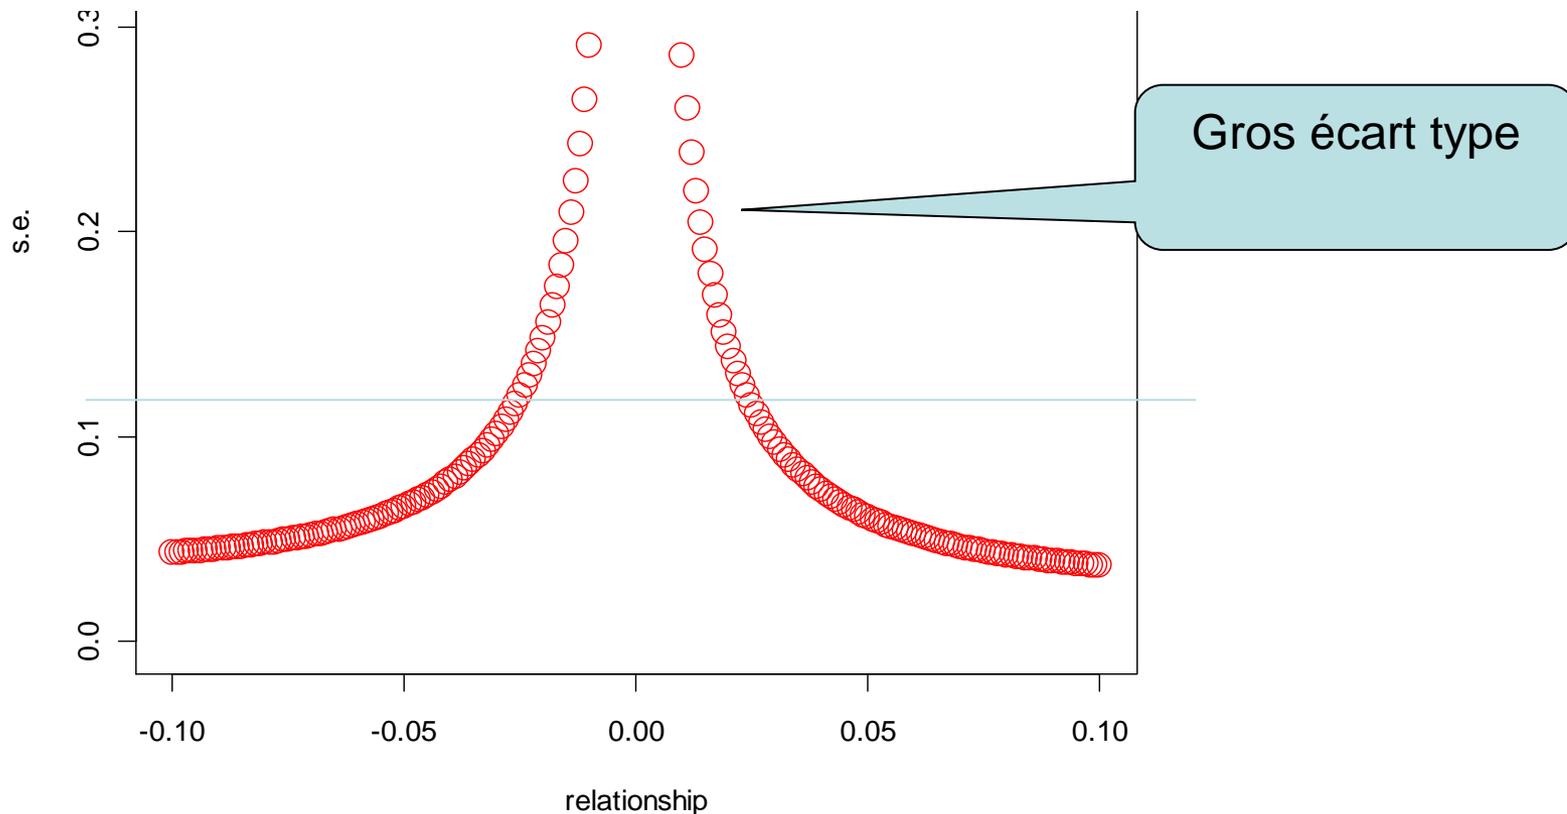
- L'erreur standard est :

$$s.e. \hat{h}^2 = \frac{1}{r} \left\{ \frac{2(1-t)^2 \left( t + \frac{1-t}{n} \right)^2 \left( t + \frac{1-t}{sn} \right)^2}{n(n-1)(s-1)} \right\}^{1/2}$$

Negligible except  
for very small  
« parenté »  
( $<0.001$ )

# Graphiquement

- 63 familles de 63 pseudo-cousins liés par  $r$  « parenté », et caractère de  $h^2=0.8$  (taille chez l'homme)



# Et alors?

- Dans leur étude ils ont trouvé un écart type (théorique) de l'estimateur de 0.08
  - Trop peu?
    - Selon formule le s.e. est  $\sim 0.12$
    - Pas si différent que ça
  - La s.e. publiée est correctement évaluée (d'après le code):
    - Obtenue à partir des dérivées secondes de la vraisemblance, suite à l'algorithme

# Test

- L' $h^2$  a une allure de corrélation, donc on peut utiliser la z-transform de Fisher pour tester si

$h^2 = 0.45 (\pm 0.08)$  est différente de 0.8

→  $p < 0.01$

# (Andrès) Conclusion

- Papier très intéressant
  - Ils ont raison de dire que l'héritabilité n'est pas manquante et que le modèle mixte l'estime correctement
  - L'utilisation d'individus « non apparentés » provoque des problèmes d'estimation
    - énorme écart type: on ne peut (doit) pas tirer trop de conclusions
- + SNP ne permettent pas de retrouver toute la variabilité causale, mais pas seulement à cause des MAF (effets très petits, épistasie, hétérogénéité des locus à effets entre individus)