

Techniques statistiques pour la détection de gènes à effets quantitatifs

Charles-Elie Rabier

Institut de Mathématiques de Toulouse (IMT)
Station d'Amélioration Génétique des Animaux, INRA Toulouse

Directeurs de thèse :
Jean-Marc Azaïs (IMT), Jean-Michel Elsen (INRA)

Co-encadrante :
Céline Delmas (INRA)

16 Juin 2010

Qu'est-ce qu'un QTL ?

QTL = Quantitative Trait Locus

Un QTL est un locus à l'origine
de la variation d'un caractère quantitatif



Comment détecter et localiser un QTL ?

On a besoin :

- d'une population en ségrégation (obtenue à l'aide de croisements)
- de marqueurs génétiques positionnés le long du génome
- de valeurs phénotypiques

⇒ les méthodes statistiques vont nous permettre de détecter et localiser le QTL

Feuille de route

Première partie : Selective Genotyping

- Problème soulevé par les généticiens
- Modèle applicable à d'autres domaines

Deuxième partie : Génome Scan

- Etude d'un modèle propre à la génétique

Première partie :

Selective Genotyping

Le QTL est présent sur un marqueur donné

Modèle en l'absence de censure

- X : variable aléatoire correspondant au génotype au QTL

$$X = \begin{cases} -1 & \text{avec probabilité } 1 - p \\ 1 & \text{avec probabilité } p \end{cases}$$

On suppose $p \neq \{0, 1\}$

- Y : variable aléatoire correspondant au phénotype

$$Y = \mu + q X + \varepsilon \quad \text{où } \varepsilon \sim N(0, \sigma^2)$$

Modèle en l'absence de censure

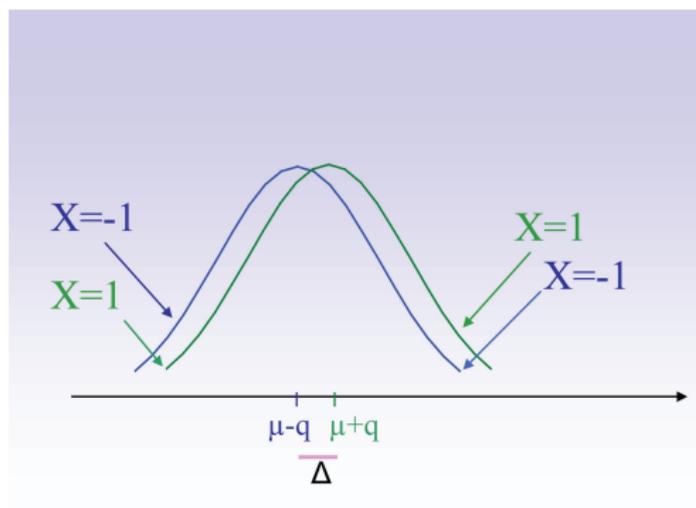


FIG.: Distribution des phénotypes Y

Test statistique oracle (μ, q, σ)

- A l'aide de n observations (X_j, Y_j) iid, on souhaite tester :

$$H_0 : q = 0 \text{ vs } H_1 : q \neq 0$$

On considère une alternative locale $H_a : q = \frac{a}{\sqrt{n}}$

- Test statistique oracle :

$$T = \frac{\sum_{j=1}^n \frac{1}{p}(Y_j - \bar{Y}) 1_{X_j=1} - \frac{1}{1-p}(Y_j - \bar{Y}) 1_{X_j=-1}}{\hat{\sigma} \sqrt{\frac{n}{p(1-p)}}}$$

$$T \xrightarrow{H_0} N(0, 1) \quad \text{et} \quad T \xrightarrow{H_a} N\left(\frac{2a \sqrt{p(1-p)}}{\sigma}, 1\right)$$

Selective Genotyping

Génotyper coûte très cher

⇒ Selective Genotyping : génotypage uniquement des individus présentant des phénotypes Y extrêmes.

Le nombre d'individus génotypés, afin d'obtenir une puissance donnée, est réduit considérablement à condition que le nombre d'individus phénotypés ait été augmenté

Lebowitz et al. (Theoretical and Applied Genetics, 1987)

Questions abordées

- Combien d'individus supplémentaires faut-il phénotyper pour avoir même puissance qu'en situation oracle ?
- Doit-on génotyper uniquement les individus présentant les plus grands phénotypes, ou au contraire ceux présentant les plus petits phénotypes, ou bien un mélange des deux ?
- Doit-on conserver les phénotypes non extrêmes dans l'analyse statistique ?

Modèle correspondant au Selective Genotyping

X disponible uniquement pour les individus présentant un phénotype extrême Y

⇒ On n'observe plus X mais \bar{X} :

$$\bar{X} = \begin{cases} X & \text{si } Y \notin [S_-, S_+] \\ 0 & \text{sinon} \end{cases}$$

où S_- et S_+ sont deux réels tels que $S_- \leq S_+$.

Modèle correspondant au Selective Genotyping

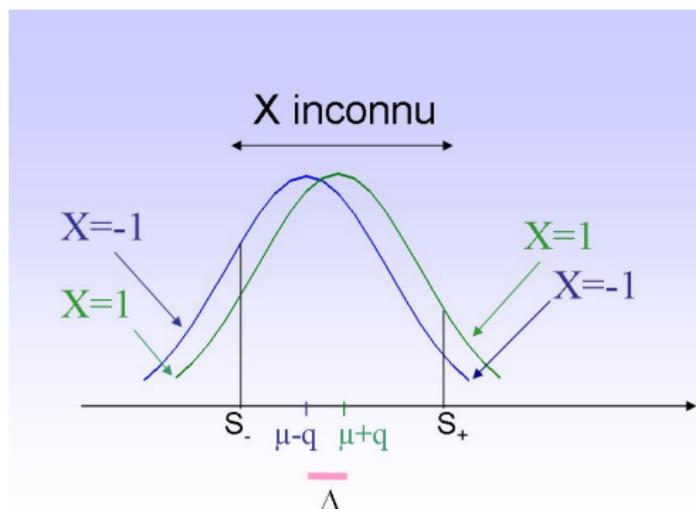


FIG.: Distribution des phénotypes Y

Ecriture de la vraisemblance

- Vraisemblance pour une observation (Y, \bar{X})

$$L = \frac{1-p}{\sigma} \varphi\left(\frac{y-\mu+q}{\sigma}\right) 1_{\bar{X}=-1} + \frac{p}{\sigma} \varphi\left(\frac{y-\mu-q}{\sigma}\right) 1_{\bar{X}=1} \\ + \left\{ \frac{1-p}{\sigma} \varphi\left(\frac{y-\mu+q}{\sigma}\right) + \frac{p}{\sigma} \varphi\left(\frac{y-\mu-q}{\sigma}\right) \right\} 1_{\bar{X}=0}$$

avec φ densité d'une loi normale standardisée

- Vraisemblance très difficile à maximiser

⇒ Algorithme EM nécessaire afin d'obtenir les EMV $\hat{\mu}$, \hat{q} et $\hat{\sigma}$

Test de Wald (μ, q, σ)

$$H_0 : q = 0 \text{ vs } H_1 : q \neq 0$$

On considère une alternative locale $H_a : q = \frac{a}{\sqrt{n}}$

- Test de Wald

$$W_1 = \frac{2\sqrt{n}}{\hat{\sigma}^2} \sqrt{\hat{A} p(1-p)} \hat{q} \quad , \quad W_1 \xrightarrow{H_0} N(0, 1)$$

$$\text{où } \mathcal{A} = E_{H_0} \left[(Y - \mu)^2 1_{\bar{X} \neq 0} \right] \quad , \quad \hat{A} = \frac{1}{n} \sum_{j=1}^n (Y_j - \bar{Y})^2 1_{\bar{X}_j \neq 0}$$

loi sous l'alternative locale ?

Test de Wald (μ, q, σ)

3ème lemme de Le Cam

Soient P_n et Q_n deux suites de mesures de probabilité sur des espaces $(\Omega_n, \mathcal{B}_n)$ et $T_n : \Omega_n \mapsto \mathbb{R}^d$ une suite de variables aléatoires.

Si

$$\left(T_n, \log \left(\frac{dQ_n}{dP_n} \right) \right)' \xrightarrow{P_n} N_{d+1} \left(\left(\begin{array}{c} \xi \\ -\frac{1}{2}\nu^2 \end{array} \right), \left(\begin{array}{cc} \Sigma & \tau \\ \tau' & \nu^2 \end{array} \right) \right)$$

alors ,

$$T_n \xrightarrow{Q_n} N_d(\xi + \tau, \Sigma)$$

Théorème

Soient C_1, \dots, C_n un échantillon iid provenant d'une distribution P_θ . Supposons que Θ est un ouvert de \mathbb{R}^d et que le modèle $(P_\theta : \theta \in \Theta)$ est régulier. On note $\theta_0 \in \Theta$ et $\hat{\theta}$ l'EMV de θ , alors pour toute séquence convergente de type $h_n \rightarrow h$, on a :

- i) sous P_{θ_0} : $\sqrt{n} (\hat{\theta} - \theta_0) \rightarrow N(0, I^{-1}(\theta_0))$
- ii) sous $P_{\theta_0 + h_n/\sqrt{n}}$: $\sqrt{n} (\hat{\theta} - \theta_0) \rightarrow N(h, I^{-1}(\theta_0))$

Test de Wald (μ, q, σ)

$$H_0 : q = 0 \text{ vs } H_1 : q \neq 0$$

On consid re une alternative locale $H_a : q = \frac{a}{\sqrt{n}}$

- Test de Wald

$$W_1 = \frac{2\sqrt{n}}{\hat{\sigma}^2} \sqrt{\hat{A} p(1-p)} \hat{q} \quad , \quad W_1 \xrightarrow{H_0} N(0, 1)$$

$$\text{alors } W_1 \xrightarrow{H_a} N\left(\frac{2a \sqrt{\hat{A} p(1-p)}}{\sigma^2}, 1\right)$$

Efficacité du test de Wald (μ, q, σ)

Comment est affectée la puissance du test de Wald lorsque le nombre d'individus est augmenté tout en conservant le même effet QTL $q = \frac{a}{\sqrt{n}}$?

- n^* nouveau nombre d'individus
- ratio $\zeta = \frac{n^*}{n}$

Définition

On définit **l'efficacité** du test de Wald, $\kappa_1 = \frac{1}{\zeta_{\text{eff}}}$, où ζ_{eff} désigne la valeur de ζ pour laquelle la puissance du test de Wald est égale à la puissance du test oracle

Efficacité du test de Wald (μ, q, σ)

On note $\gamma = \mathbb{P}_{H_0} (Y \notin [S_-, S_+])$

A la fois sous H_0 et sous H_a , γ correspond

asymptotiquement au pourcentage d'individus génotypés

De la même manière, on note :

- $\gamma_+ = \mathbb{P}_{H_0} (Y > S_+)$
- $\gamma_- = \mathbb{P}_{H_0} (Y < S_-)$

Bien évidemment : $\gamma = \gamma_+ + \gamma_-$

Efficacité du test de Wald :

$$\forall p, \kappa_1 = \gamma + z_{\gamma_+} \varphi(z_{\gamma_+}) - z_{1-\gamma_-} \varphi(z_{1-\gamma_-})$$

Optimisation du génotypage

- On souhaite génotyper uniquement un pourcentage γ de la population

⇒ Comment choisir les γ_+ et γ_- optimaux ?

$\forall p$, κ_1 atteint son maximum M pour $\gamma_+ = \gamma_- = \gamma/2$

$$M = \gamma + 2 z_{\gamma/2} \varphi(z_{\gamma/2})$$

$\forall p$, on doit génotyper le même pourcentage d'individus
à "droite" qu'à "gauche" !

Si $\gamma = 0.3$ alors $M = 78\%$

Illustration graphique

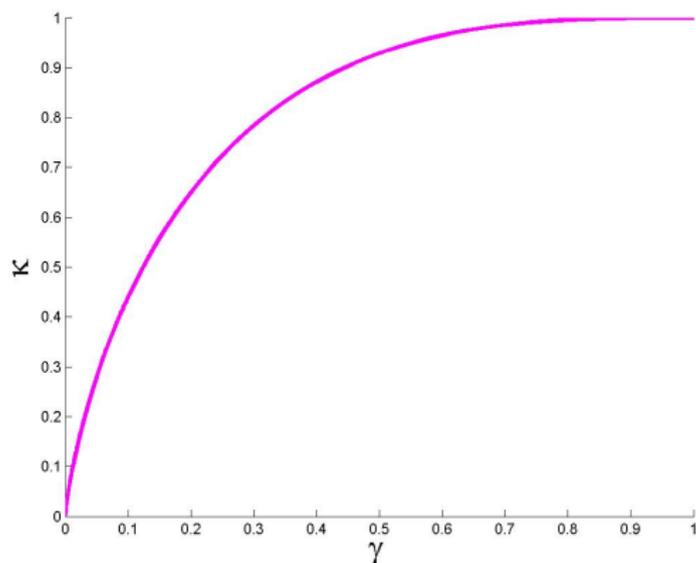


FIG.: Efficacit  du test de Wald en fonction de γ ($\gamma_+ = \gamma_- = \gamma/2$)

Une autre question propre au Selective Genotyping

Existe-t-il de l'information dans la "bande" ?

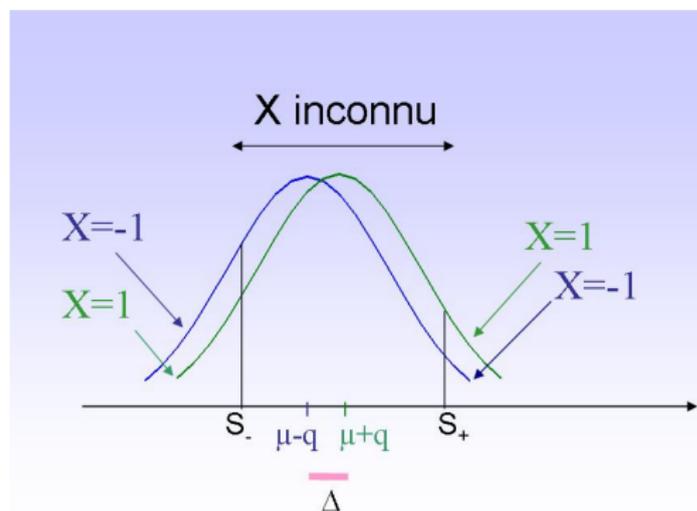
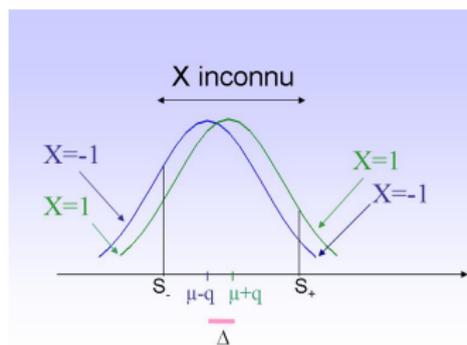


FIG.: Distribution des phénotypes Y

Comparaison des 3 stratégies

3 stratégies pour l'analyse de données en Selective Genotyping :

- 1 Test de Wald basé sur l'ensemble des phénotypes
- 2 Comparaison de moyenne basée sur les phénotypes extrêmes
- 3 Test de Wald basé sur les phénotypes extrêmes



Comparaison des 3 stratégies (μ , q , σ)

Lemme

$$W_1 := \frac{2\sqrt{n}}{\hat{\sigma}^2} \sqrt{\hat{A} p(1-p)} \hat{q}_1$$

$$T_2 := \sqrt{p(1-p)} \left\{ \frac{\sum_{j=1}^n \frac{1}{p} (Y_j - \bar{Y}) 1_{\bar{X}_j=1} - \frac{1}{1-p} (Y_j - \bar{Y}) 1_{\bar{X}_j=-1}}{\sqrt{n \hat{A}}} \right\}$$

$$W_3 := \frac{2\sqrt{n}}{\hat{\sigma}^2} \sqrt{\hat{A} p(1-p)} \hat{q}_3$$

présentent les mêmes lois asymptotiques sous H_0 et sous H_a , à savoir :

$$N(0, 1) \quad \text{et} \quad N\left(\frac{2a \sqrt{A} p(1-p)}{\sigma^2}, 1\right)$$

où \hat{q}_1 et \hat{q}_3 sont les EMV de q pour les stratégies une et trois, et où

$$\hat{A} = \frac{1}{n} \sum_{j=1}^n (Y_j - \bar{Y})^2 1_{\bar{X}_j \neq 0}, \quad \bar{Y} = \frac{1}{n} \sum_{j=1}^n Y_j$$

$$A = \sigma^2 \left\{ \gamma + z_{\gamma+} \varphi(z_{\gamma+}) - z_{1-\gamma-} \varphi(z_{1-\gamma-}) \right\}, \quad \hat{\sigma}^2 = \frac{1}{n-1} \sum_{j=1}^n (Y_j - \bar{Y})^2$$

Comparaison des 3 stratégies (μ , q , σ)

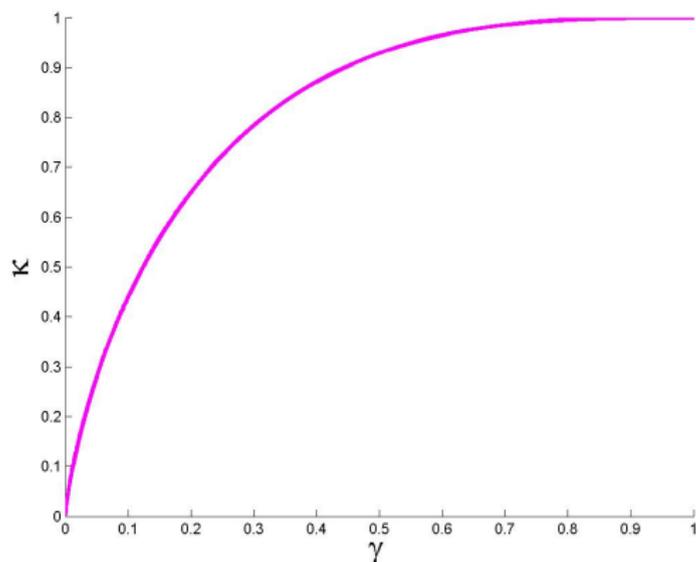


FIG.: Efficacité des tests, correspondant aux différentes stratégies, en fonction de γ ($\gamma_+ = \gamma_- = \gamma/2$)

Convergence vers l'asymptotique (q)

γ	β_{MC}	β_{th}	IC en %
0.1	38.27%	37.45%	[37.32 ; 39.22]
0.2	48.80%	48.61%	[47.82 ; 49.78]
0.3	54.64%	54.77%	[53.66 ; 55.62]
0.4	58.60%	58.58%	[57.63 ; 59.57]
0.5	61.48%	60.93%	[60.53 ; 62.43]
0.6	61.73%	62.33%	[60.78 ; 62.68]
0.7	63.21%	63.13%	[62.26 ; 64.16]
0.8	63.27%	63.52%	[62.33 ; 64.21]
0.9	63.79%	63.68%	[62.85 ; 64.73]
1	63.56%	63.68%	[62.62 ; 64.50]

TAB.: Puissance théorique (β_{th}) et puissance par Monte-Carlo (β_{MC}) en fonction du pourcentage de génotypés γ ($\gamma_+ = \gamma_- = \gamma/2$, $p = 1/2$, $nb_{ech} = 10000$, $n = 30$, $q = \frac{2}{\sqrt{30}} = 0.3651$)

Conclusions sur le Selective Genotyping

- On doit génotyper le même pourcentage d'individus aux deux extrêmes
- Il n'y a pas d'information dans la "bande"
- Mêmes conclusions pour un selective genotyping avec deux caractères corrélés

Deuxième partie :

Génome Scan

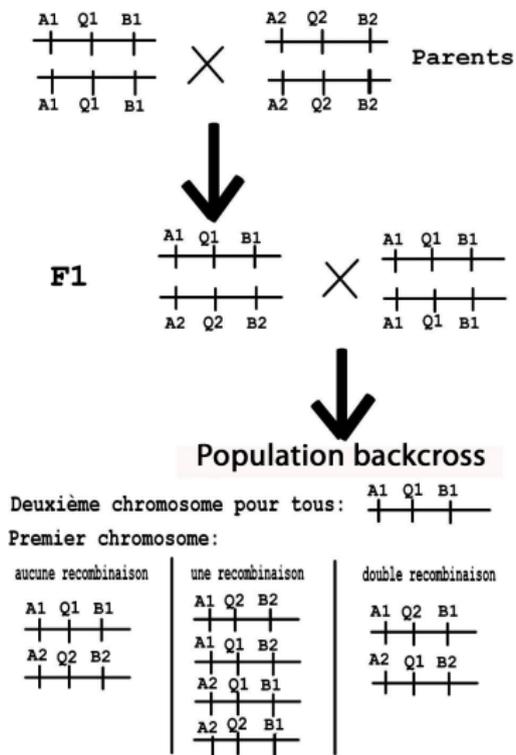
La position du QTL est inconnue

Contexte

- On modélise un chromosome par un segment $[0, T]$
- Considérons tout d'abord seulement deux marqueurs génétiques A et B présents aux extrémités du chromosome
- A et B possèdent chacun deux allèles (A_1 et A_2 pour A et B_1 , B_2 pour B)
- Existe-t-il un QTL Q (allèles Q_1 et Q_2) sur $[0, T]$? Si oui, à quelle position ?

On s'intéressera ici au backcross, schéma expérimental fondamental chez les végétaux

Un schéma expérimental : le backcross



Modèle

- X : variable aléatoire correspondant au génotype au QTL

On utilise le codage : $\begin{cases} 1 \text{ pour } Q_1 Q_1 \\ -1 \text{ pour } Q_1 Q_2 \end{cases}$

D'où

$$X = \begin{cases} 1 & \text{avec probabilité } 1/2 \\ -1 & \text{avec probabilité } 1/2 \end{cases}$$

- Y : variable aléatoire correspondant au phénotype

$$Y = \mu + q X + \varepsilon \quad \text{où } \varepsilon \sim N(0, \sigma^2)$$

L'Interval Mapping de Lander et Botstein (1989)

On souhaite tester : $H_0 : q = 0$ vs $H_1 : q \neq 0$

L'Interval Mapping

- Position du QTL inconnue

⇒ on scanne l'intervalle $[0, T]$.

⇒ tests du rapport de vraisemblance sur tout l'intervalle

Construction du LRT

- Pour chaque position $t \in [0, T]$, **génotype au QTL inconnu**

⇒ calcul des probabilités du génotype au QTL grâce aux recombinaisons et à la formule de Haldane (1919)

⇒ modèle de mélange

L'Interval Mapping de Lander et Botstein (1989)

- Vraisemblance pour n observations j iid :

$$L_n(\theta, t) = \prod_{j=1}^n p_t^j f_{(\mu+q,\sigma)}(y_j) + (1 - p_t^j) f_{(\mu-q,\sigma)}(y_j)$$

où :

- $\theta = (q, \mu, \sigma)$
- $f_{(\mu,\sigma)}(\cdot)$ densité Gaussienne de moyenne μ et de variance σ^2
- p_t^j probabilité que l'individu j soit de génotype $Q_1 Q_1$ en t , sachant son génotype aux marqueurs A et B

L'Interval Mapping de Lander et Botstein (1989)

- $\Lambda_n(t)$ LRT à la position t
- les $\Lambda_n(t)$ définissent un processus $\Lambda_n(\cdot)$

On recherche un seul QTL sur l'intervalle $[0, T]$

⇒ statistique naturelle : $\sup \Lambda_n(\cdot)$

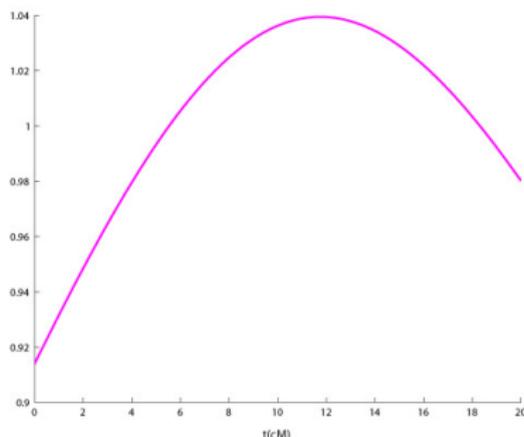


FIG.: Une trajectoire du processus $\Lambda_n(\cdot)$ ($T = 20\text{cM}$)

Quelques précisions sur les hypothèses testées

H_0 : “il n’y a pas de QTL sur l’intervalle $[0, T]$ ”

H_{at^*} : “le QTL est situé en $t^* \in [0, T]$ avec un effet $q = a/\sqrt{n}$ ”

⇒ Théorie de Le Cam (1986)

Une interpolation non linéaire

Théorème

$$\Lambda_n(\cdot) \xrightarrow{F.d.} \{Z(\cdot)\}^2 \quad \text{où}$$

- $Z(\cdot)$ est le processus d'interpolation non linéaire tel que

$$\forall t \in [0, T] \quad Z(t) = \frac{\alpha(t) Z(0) + \beta(t) Z(T)}{\sqrt{\{\alpha(t)\}^2 + \{\beta(t)\}^2 + 2\alpha(t)\beta(t)e^{-2T}}}$$

$$\alpha(0) = 1, \beta(0) = 0, \alpha(T) = 0, \beta(T) = 1 \quad \text{et} \quad \text{Cov}\{Z(0), Z(T)\} = e^{-2T}$$

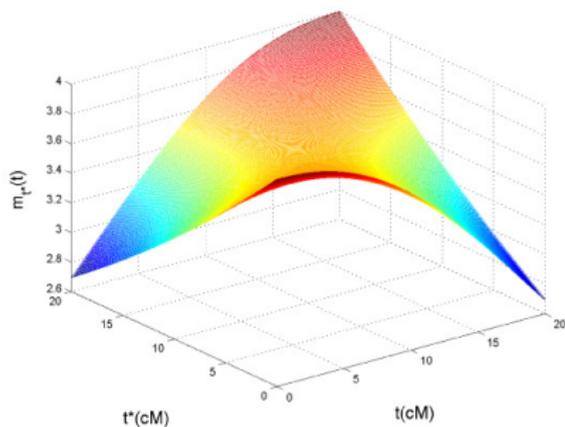
- $Z(\cdot)$ est un processus Gaussien de variance 1 et de fonction moyenne :

$$\text{sous } H_0 : m(t) = 0 \quad \forall t \in [0, T]$$

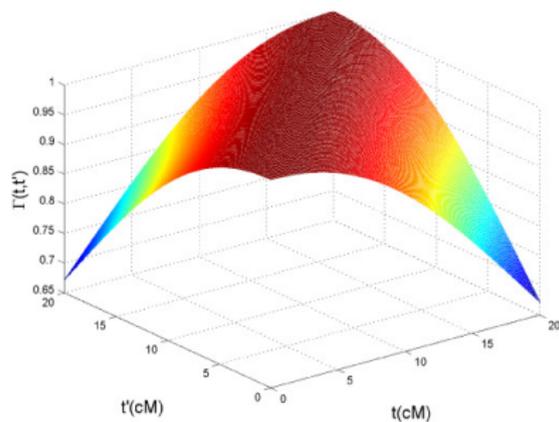
$$\text{sous } H_{at^*} : m_{t^*}(0) = \frac{a}{\sigma} g(0, t^*) \quad , \quad m_{t^*}(T) = \frac{a}{\sigma} g(T, t^*)$$

$$\forall t \in [0, T] \quad m_{t^*}(t) = \frac{\alpha(t) m_{t^*}(0) + \beta(t) m_{t^*}(T)}{\sqrt{\{\alpha(t)\}^2 + \{\beta(t)\}^2 + 2\alpha(t)\beta(t)e^{-2T}}}$$

Illustrations graphiques



Fonction moyenne



Fonction covariance

FIG.: Fonction moyenne et fonction covariance ($a = 4$, $\sigma = 1$, $T = 20$ cM)

Illustrations graphiques

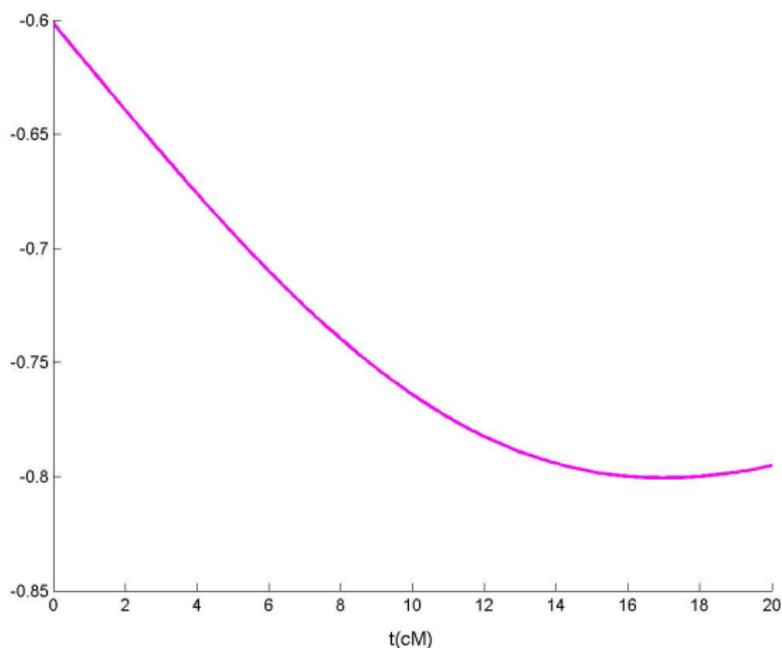


FIG.: Une trajectoire du processus $Z(\cdot)$ sous H_0 ($T = 20$ cM)

Illustrations graphiques

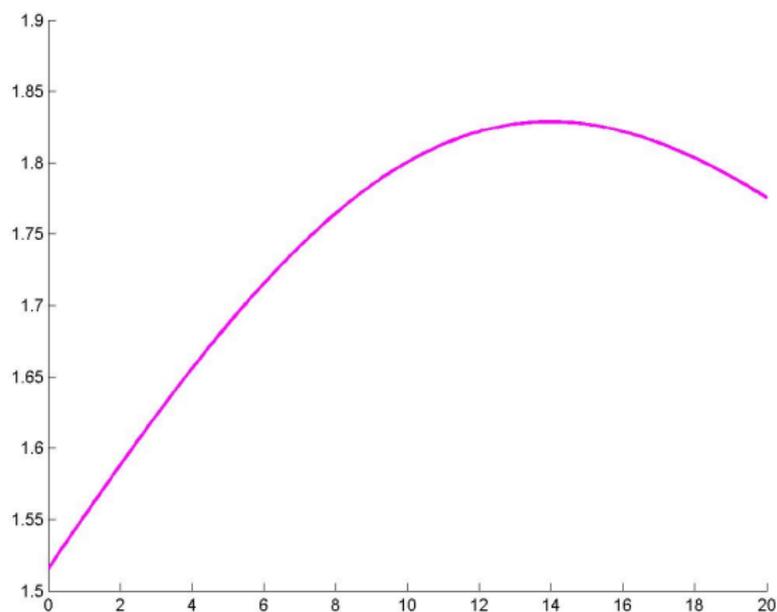


FIG.: Fonction moyenne ($a = 2$, $\sigma = 1$, $t^* = 14\text{cM}$, $T = 20\text{cM}$)

Illustrations graphiques

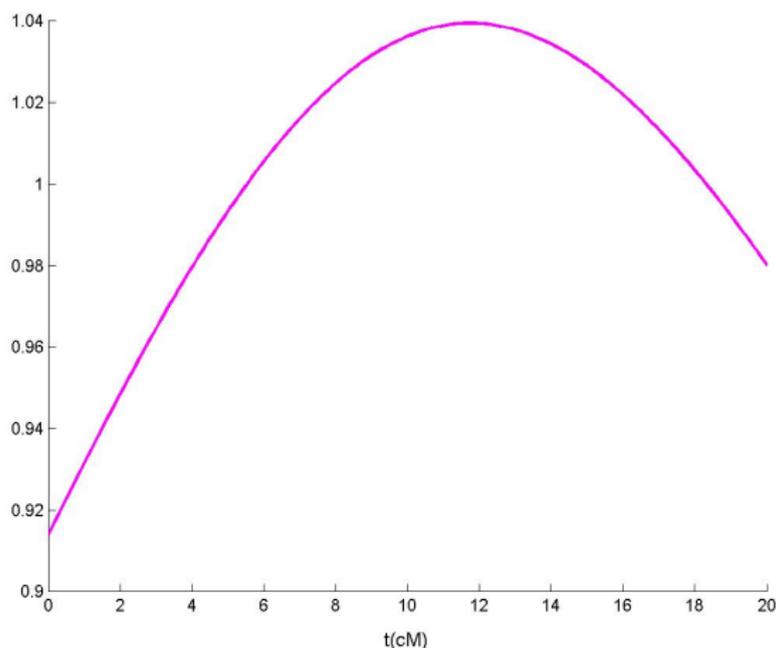


FIG.: Même trajectoire de $Z(\cdot)$ que sous H_0 mais sous H_{at^*} ($a = 2$, $\sigma = 1$, $t^* = 14\text{cM}$, $T = 20\text{cM}$)

Retour sur les poids du modèle de mélange

Ici, les poids du modèle de mélange considéré
correspondent à la modélisation de Haldane

Modélisation de **Haldane** : le nombre de recombinaisons dans l'intervalle $[0, T]$ suit un processus de Poisson d'intensité 1

Dans **Rebaï et al.**(94 et 95), les auteurs n'autorisent qu'**une seule recombinaison entre 2 marqueurs** (Phénomène d'interférence)

⇒ nouveaux poids du modèle de mélange

⇒ le processus $\Lambda_n(\cdot)$ tend vers le carré d'un processus d'interpolation linéaire $V(\cdot)$

Interpolation linéaire/ Interpolation non linéaire

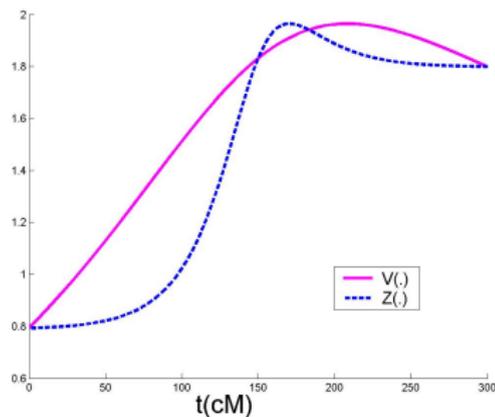
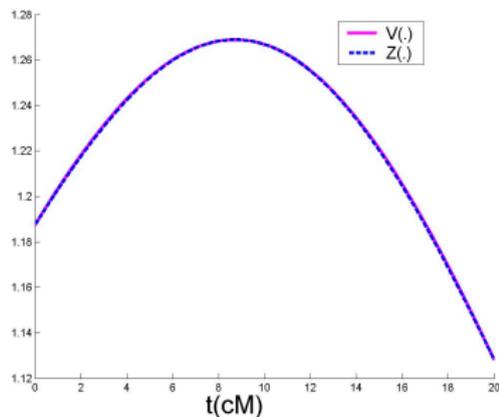


FIG.: Une trajectoire des processus $Z(\cdot)$ et $V(\cdot)$ sous H_0 ($T = 20\text{cM}$ à gauche, $T = 300\text{cM}$ à droite)

A propos des tests multiples

Lemme

On rappelle que $V(0) = Z(0)$ et $V(T) = Z(T)$.

Soient ξ et ξ' tels que $\xi = \frac{T \{e^{-2T} V(0) - V(T)\}}{\{e^{-2T} - 1\} \{V(0) + V(T)\}}$ et $\frac{T\beta(\xi')}{\alpha(\xi') + \beta(\xi')} = \xi$,

alors sous H_0 et H_{at^*}

$$\{Z(\xi')\}^2 = \{V(\xi)\}^2 = \frac{\{V(0)\}^2 + \{V(T)\}^2 - 2 e^{-2T} V(0) V(T)}{\{1 + e^{-2T}\} \{1 - e^{-2T}\}}$$

et

$$\sup_{t \in [0, T]} \{Z(t)\}^2 = \sup_{t \in [0, T]} \{V(t)\}^2$$

$$= \{V(\xi)\}^2 \mathbf{1}_{\frac{V(T)}{V(0)} \in] e^{-2T}, e^{2T} [} + \max \left[\{V(0)\}^2, \{V(T)\}^2 \right] \mathbf{1}_{\frac{V(T)}{V(0)} \notin] e^{-2T}, e^{2T} [}$$

Inutile d'effectuer des tests partout sur le chromosome !

L'Interval Mapping lisse les trajectoires

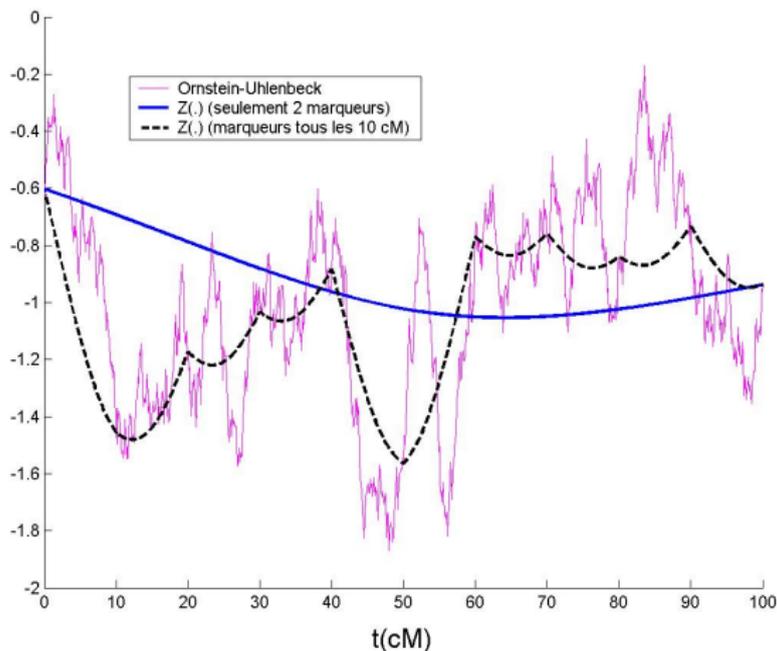


FIG.: 3 processus Gaussiens ($T = 100\text{cM}$)

Application au calcul de valeurs critiques

Calcul de la valeur critique c vérifiant $P_{H_0}(\sup \{Z(\cdot)\}^2 > c) = 1 - \alpha$

⇒ fonction QSIMVNEF de Genz (1992)

Méthode	<i>la notre</i>	<i>Rebai</i>	<i>Feingold</i>
Valeur critique	8.23	9.09	8.26

FIG.: Valeurs critiques en fonction de la méthode considérée (51 marqueurs positionnés tous les 2cM, $T = 1M$, $\alpha = 95\%$)

Méthode	<i>la notre</i>	<i>Feingold</i>
Valeur critique	5.40	5.78

FIG.: Valeurs critiques en fonction de la méthode considérée (2 marqueurs, $T = 1M$, $\alpha = 95\%$)

Approche multi-QTL

$H_{\vec{at}^*}$: "il existe M QTL situés en t_1^*, \dots, t_M^* avec des effets
 $q_1 = \frac{a_1}{\sqrt{n}}, \dots, q_M = \frac{a_M}{\sqrt{n}}$ "

On supposera les effets QTL additifs

Approche multi-QTL

Théorème

$$\Lambda_n(\cdot) \xrightarrow{F.d.} \{Z^*(\cdot)\}^2 \quad \text{où}$$

- $Z^*(\cdot)$ est le processus d'interpolation non linéaire tel que

$$\forall t \in [0, T] \quad Z^*(t) = \frac{\alpha(t) Z^*(0) + \beta(t) Z^*(T)}{\sqrt{\{\alpha(t)\}^2 + \{\beta(t)\}^2 + 2\alpha(t)\beta(t)e^{-2T}}}$$

$$\alpha(0) = 1, \beta(0) = 0, \alpha(T) = 0, \beta(T) = 1 \quad \text{et} \quad \text{Cov}\{Z^*(0), Z^*(T)\} = e^{-2T}$$

- $Z^*(\cdot)$ est un processus Gaussien de variance 1 et de fonction moyenne :

$$\text{sous } H_0 : m(t) = 0 \quad \forall t \in [0, T]$$

$$\text{sous } H_{a_{t^*}} : m_{t^*}(0) = \sum_{s=1}^M \frac{a_s}{\sigma} g(0, t_s^*) \quad , \quad m_{t^*}(T) = \sum_{s=1}^M \frac{a_s}{\sigma} g(T, t_s^*)$$

$$\forall t \in [0, T] \quad m_{t^*}(t) = \frac{\alpha(t) m_{t^*}(0) + \beta(t) m_{t^*}(T)}{\sqrt{\{\alpha(t)\}^2 + \{\beta(t)\}^2 + 2\alpha(t)\beta(t)e^{-2T}}}$$

Population avec une structure de famille

On admettra qu'une population backcross = une famille de père

⇒ généralisation à une **population comprenant l familles de pères**

H_0 : "Il n'y a de QTL dans aucune des familles"

H_{at^*} : "Un QTL est présent dans au moins une famille "

$$\Lambda_n(\cdot) \xrightarrow{F.d.} \sum_{i=1}^l \left\{ Z^i(\cdot) \right\}^2$$

Les $Z^i(\cdot)$ sont des processus d'interpolation non linéaires indépendants

Chaque $Z^i(\cdot)$ est :

- centré en l'absence de QTL dans la famille i
- décentré en présence de QTL dans la famille i

Processus de Chi deux d'Ornstein-Uhlenbeck

Hypothèse de carte dense

- Cas d'une seule famille :

$\Lambda_n(\cdot)$ converge vers le carré d'un processus d'Ornstein-Uhlenbeck

Lander et Botstein (1989) et Cierco (1998)

- Cas de I familles :

$\Lambda_n(\cdot)$ converge vers le carré d'un processus de Chi deux d'Ornstein-Uhlenbeck à I degrés de liberté

Processus de Chi deux d'Ornstein-Uhlenbeck

Définition (Processus d'Ornstein-Uhlenbeck)

Un processus O.U. est un processus Gaussien stationnaire, de moyenne nulle, de variance égale à un, et de covariance égale à $r(t) = \exp(-2 | t |)$

Définition (Processus de Chi deux d'Ornstein-Uhlenbeck)

*Soient $\tilde{Z}^1(\cdot), \dots, \tilde{Z}^l(\cdot)$ l processus O.U. indépendants.
 $S(t) = \sum_{i=1}^l \left\{ \tilde{Z}^i(\cdot) \right\}^2$ est appelé Processus de Chi deux d'Ornstein-Uhlenbeck à l degrés de liberté*

Processus de Chi deux d'Ornstein-Uhlenbeck

On établit la relation :

$$\sup_{t \in [0, T]} S(t) = \sup_{t \in [1, e^{4T}]} \left(\frac{\|\vec{W}(t)\|}{\sqrt{t}} \right)^2$$

avec $\vec{W}(t) = \begin{pmatrix} W_1(t) \\ \vdots \\ W_l(t) \end{pmatrix}$ mouvement brownien en dimension l .

Ainsi, pour le calcul de valeurs critiques, on dispose :

- des tables de Delong (81) et de Estrella (2003)
- de la formule approximative de Delong (81) à condition que c et T soient grands

$$\mathbb{P} \left(\sup_{t \in [0, T]} S(t) < c \right) = \frac{(c/2)^{l/2} e^{-c/2}}{\Gamma(d/2)} \left[4T \left(1 - \frac{l}{c} \right) + \frac{2}{c} + O\left(\frac{1}{c^2}\right) \right]$$

- d'une borne inf, obtenue par MCQMC (en collaboration avec Alan Genz)

Conclusions et perspectives

Selective Genotyping :

- On doit génotyper le même pourcentage d'individus aux deux extrêmes
- Il n'y a pas d'information dans la bande
- Mêmes conclusions pour un selective genotyping avec deux caractères corrélés

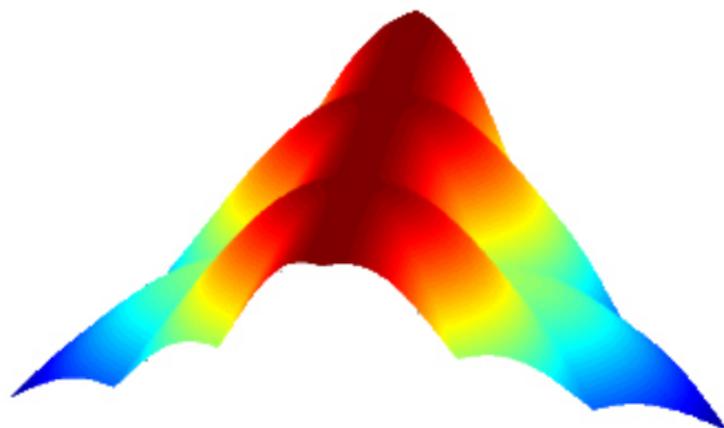
Génome Scan :

- L'Interval Mapping est une interpolation non linéaire
- On doit effectuer un seul test au maximum entre deux marqueurs
- Si Carte dense et I familles :
⇒ Processus de Chi deux d'Ornstein-Uhlenbeck à I degrés de liberté

Perspectives :

- Sélection de modèle pour la recherche de plusieurs QTL
- Génome Scan couplé au Selective Genotyping
- Extension à l'analyse d'association

Merci de votre attention



Introduction d'un deuxième phénotype

2 phénotypes sont désormais disponibles : Y et Z

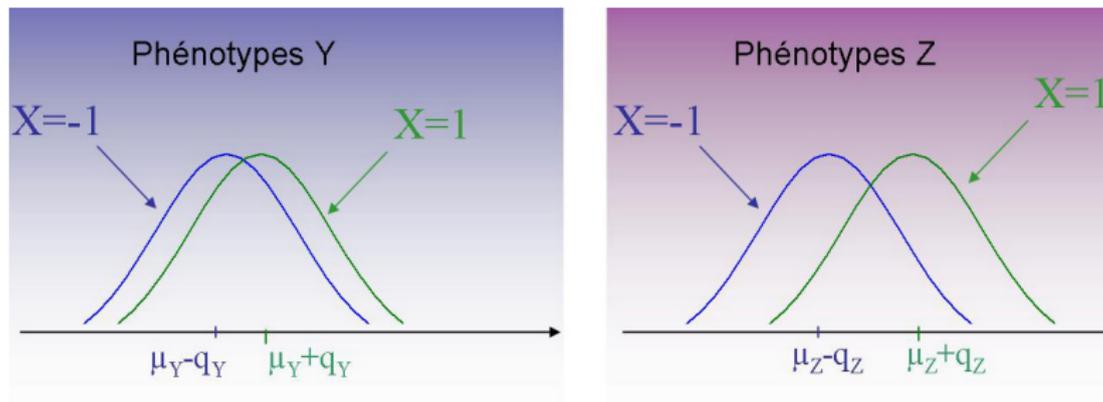


FIG.: Distribution des phénotypes Y et Z

Y/X et Z/X corrélées

Modèle en l'absence de censure

Les phénotypes Y et Z sont tels que :

$$\begin{pmatrix} Y \\ Z \end{pmatrix} = \begin{pmatrix} \mu_Y + q_Y X \\ \mu_Z + q_Z X \end{pmatrix} + \varepsilon$$

où

$$\varepsilon \sim N\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \sigma^2 & r\sigma^2 \\ r\sigma^2 & \sigma^2 \end{pmatrix}\right)$$

On supposera :

- r et σ^2 connus
- $r \notin \{-1, 1\}$

Existe-t-il un QTL affectant le phénotype Z ?

Test statistique oracle (μ_Z, q_Z)

- A l'aide de n observations (X_j, Y_j, Z_j) iid, on souhaite tester :

$$H_{0Z} : q_Z = 0 \text{ vs } H_{1Z} : q_Z \neq 0$$

On considère une alternative locale $H_{bZ} : q_Z = \frac{b}{\sqrt{n}}$

- Test statistique oracle :

$$T = \frac{\sum_{j=1}^n \frac{1}{p} (Z_j - \bar{Z}) 1_{X_j=1} - \frac{1}{1-p} (Z_j - \bar{Z}) 1_{X_j=-1}}{\sigma \sqrt{\frac{n}{p(1-p)}}}$$

$$T \xrightarrow{H_{0Z}} N(0, 1) \quad T \xrightarrow{H_{bZ}} N\left(\frac{2b \sqrt{p(1-p)}}{\sigma}, 1\right)$$

Selective Genotyping en présence de deux caractères corrélés

Génotyper coûte très cher

Le phénotype Z est difficile à mesurer pour des raisons biologiques

⇒ Selective Genotyping effectué sur Y

⇒ Z mesuré uniquement pour les individus présentant un phénotype Y extrême

Existe-t-il un QTL affectant le phénotype Z ?

Comparaison de deux stratégies (μ_Z, q_Z, μ_Y, q_Y)

2 stratégies pour l'analyse de données en Selective Genotyping :

- 1 Test de Wald basé sur l'ensemble des phénotypes
- 2 Test de Wald basé sur les phénotypes extrêmes

$$\tilde{\kappa}_1 = \tilde{\kappa}_2 = \left\{ \frac{1 - r^2}{\gamma} + \frac{r^2}{\kappa_1} \right\}^{-1}$$

$$\text{où } \kappa_1 = \gamma + \mathbf{z}_{\gamma+} \varphi(\mathbf{z}_{\gamma+}) - \mathbf{z}_{1-\gamma-} \varphi(\mathbf{z}_{1-\gamma-})$$

$\forall p, \forall S_+, \forall S_-$, il n'existe pas d'information dans la bande !

$\forall p$, on doit génotyper le même pourcentage d'individus

à "droite" qu'à "gauche" !

Illustration graphique

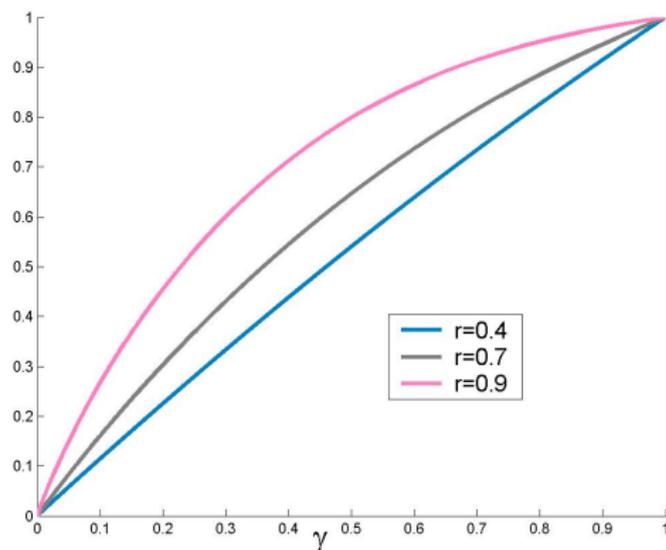


FIG.: Efficacit  en fonction de γ et de r ($\gamma_+ = \gamma_- = \frac{\gamma}{2}$)

Doit-on analyser les familles simultanément ?

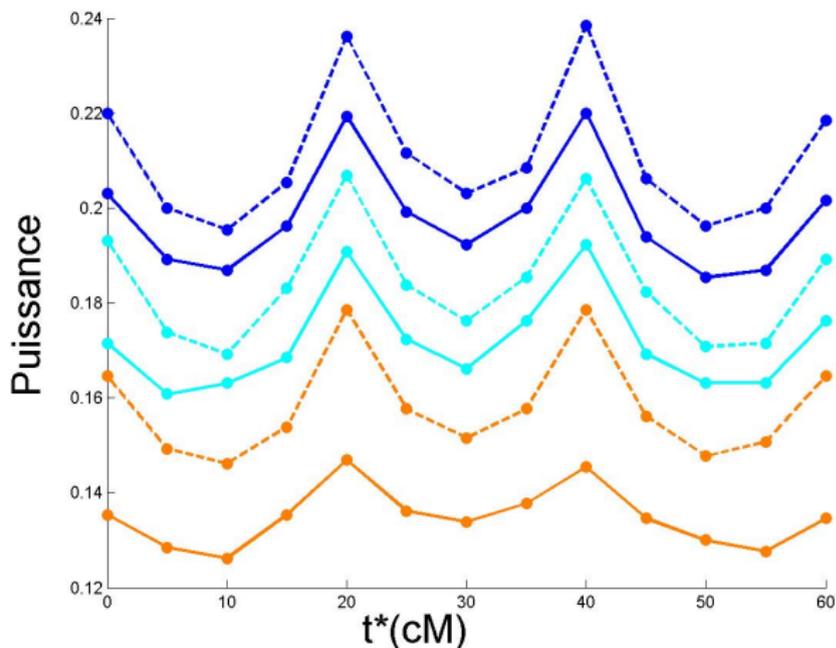


FIG.: Puissance approche globale (ligne continue) vs puissance approche Bonferroni (ligne pointillée). Une seule famille présente un QTL. Orange ($I=12$), Cyan ($I=7$), Bleu ($I=5$).