

Etat d'avancement de la tâche 4

4 Juin 2010

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

Modèle

Le **phénotype** Y d'un individu vérifie :

$$Y = \begin{cases} \mu + q + \varepsilon & \text{si génotype } Q_1 Q_1 \text{ au QTL} \\ \mu - q + \varepsilon & \text{si génotype } Q_1 Q_2 \text{ au QTL} \end{cases}$$

où $\varepsilon \sim N(0, \sigma^2)$

On souhaite **tester** :

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

L'Interval Mapping de Lander et Botstein (1989)

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 $q = a/\sqrt{n}$ ”

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 :

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


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

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

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

A propos des tests multiples

Théorème

$$\text{Soit } \xi^2 = \frac{\{Z(0)\}^2 + \{Z(T)\}^2 - 2 e^{-2T} Z(0) Z(T)}{\{1 + e^{-2T}\} \{1 - e^{-2T}\}} \quad \text{alors,}$$

$$\sup_{t \in [0, T]} \{Z(t)\}^2 = \max \left[\{Z(0)\}^2, \xi^2 \frac{1 + \frac{Z(T)}{Z(0)}}{2} \in] e^{-2(T)}, e^{2(T)} [, \{Z(T)\}^2 \right]$$

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

$$P_{H_0}(\sup \{Z(\cdot)\}^2 > c) = 1 - \alpha$$

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

$H_{a\vec{t}^*}$: “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
- pour simplifier, on teste uniquement sur les marqueurs et on suppose que les QTL sont présents sur les marqueurs
- on note t_k l'emplacement du marqueur k

$\Rightarrow \Lambda_n(\cdot)$ converge vers le carré d'un processus G sous $H_{a\vec{t}^*}$

Definition (Processus G)

$$G(t_k) = m_{\vec{t}^*}(t_k) + Z(t_k)$$

$$\text{où } m_{\vec{t}^*}(t_k) = \sum_{i=1}^M \frac{a_i}{\sigma} \exp(-2 \left| t_j^* - t_k \right|)$$

et $Z(\cdot)$ processus d'Ornstein-Uhlenbeck

Approche multi-QTL

⇒ Estimation des paramètres :


- M : nombre de QTL
- a_1, \dots, a_M : effets des QTL
- t_1^*, \dots, t_M^* : positions des QTL

$\text{argmin} \| V^{-1/2} \mathbf{G} - V^{-1/2} m_{\vec{t}^*} \|^2 + \text{pénalité}$
avec V matrice de covariance de $Z(\cdot)$

⇒ Exemple :

- $T = 100\text{cM}$, 21 marqueurs tous les 5cM
- 1000 individus
- 4 QTL sur les **marqueurs 2, 10, 15, 17** avec
 $q_1 = \dots = q_4 = 0.21$

Approche multi-QTL



Modèle

Le **phénotype** Y d'un individu vérifie :

$$Y = \begin{cases} \mu + \gamma + \varepsilon & \text{si pas de recombinaison entre } t_1 \text{ et } t_2 \\ \mu - \gamma + \varepsilon & \text{si recombinaison entre } t_1 \text{ et } t_2 \end{cases}$$

où $\varepsilon \sim N(0, \sigma^2)$

On souhaite **tester** :

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

pdfpa

Stratégie adoptée

⇒ on scanne le domaine

$$\mathcal{D} = \{(t_1, t_2) \in [0, T]^2 \text{ tels que } t_1 < t_2\}.$$

⇒ tests du rapport de vraisemblance sur tout le domaine

- Pour chaque position $(t_1, t_2) \in \mathcal{D}$, vraisemblance pour n observations j iid :

$$L_n(\theta, t_1, t_2) = \prod_{j=1}^n (1-r)f_{(\mu+\gamma, \sigma)}(y_j) + rf_{(\mu-\gamma, \sigma)}(y_j)$$

où :

- $\theta = (\gamma, \mu, \sigma)$
- $f_{(\mu, \sigma)}(\cdot)$ densité Gaussienne de moyenne μ et de variance σ^2
- r probabilité d'avoir une recombinaison entre t_1 et t_2

Stratégie adoptée

- $\Lambda_n(t_1, t_2)$ LRT à la position (t_1, t_2)
- les $\Lambda_n(t_1, t_2)$ définissent un processus bi-dimensionnel $\Lambda_n(\cdot)$

On recherche une interaction significative sur \mathcal{D}

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

Objectifs :

- Caractériser le processus $\Lambda_n(\cdot)$ sous $\mathcal{H}_0, \mathcal{H}_{1,t^*}, \mathcal{H}_{1,t_1^*, \dots, t_Q^*}$ en LA, LDLA, LD

Modèle à effets aléatoires

Soit le modèle :

$$y_i = \mathbf{x}_i^T \boldsymbol{\beta} + u_i + v_i^p + v_i^m + e_i$$

où :

- y_i est la valeur phénotypique de l'individu i
- \mathbf{x}_i^T est un vecteur connu, $\boldsymbol{\beta}$ est un vecteur d'effets fixes inconnu
- u_i est un effet polygénique
- v_i^p et v_i^m sont les effets à la position testée de l'allèle d'origine paternel et de l'allèle d'origine maternel
- e_i est une erreur résiduelle

Modèle à effets aléatoires

Ce modèle se réécrit :

$$Y = X\beta + Zu + Z_qv + e$$

- Y le vecteur des valeurs phénotypiques
- X , Z et Z_q sont des matrices connues
- β est le vecteur d'effets fixes inconnu
- u est un vecteur gaussien centré de matrice de covariance $\sigma_a^2 A$ où A est une matrice connue et σ_a^2 est une variance inconnue
- v est un vecteur gaussien centré de matrice de covariance $\sigma_q^2 A_q$ où A_q est une matrice connue et σ_q^2 est une variance inconnue
- e est le vecteur des résidus

Modèle à effets aléatoires

On teste :

$$\sigma_q^2 = 0 \text{ vs } \sigma_q^2 > 0 \forall t \in [0, T]$$

- On note $S_n(t)$ la statistique de test au point t .
- $\forall t \in [0, T]$, la loi asymptotique de $S_n(t)$, sous l'hypothèse nulle, est $\frac{1}{2}\chi_0^2 + \frac{1}{2}\chi_1^2$

C'est-à-dire :

$$S_n(t) \rightarrow \frac{1}{2}X(t)^2 1_{\{X(t) \geq 0\}}$$

où $X(\cdot)$ est un processus gaussien.

Modèle à effets aléatoires

Objectifs :

- Caractériser le processus limite X sous \mathcal{H}_0 , \mathcal{H}_{1,t^*} , $\mathcal{H}_{1,t_1^*, \dots, t_Q^*}$ en LA, LDLA, LD