

Estimation de tailles efficaces variables dans le temps à partir de données génomiques actuelles


Flora Jay¹, Simon Boitard²

1 : CNRS, Laboratoire de Recherche en Informatique (LRI), Orsay

2 : INRA, Génétique Physiologie et Systèmes d'Elevage (GenPhySE), Toulouse

Réseau des Ressources Génétiques Animales

12 et 13 mai 2016



- Vision dynamique, identifier les populations en déclin.
- Interprétation des variations de taille: évènements géologiques, climatiques, anthropomorphiques ...
- Meilleure détection des locus sous sélection.

- 1 Estimation à partir de locus indépendants
 - Généalogie à un locus
 - Méthodes d'estimation

- 2 Estimation à partir de données génomiques haut débit
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3 Conclusions

- 1 Estimation à partir de locus indépendants
 - Généalogie à un locus
 - Méthodes d'estimation


- 2 Estimation à partir de données génomiques haut débit
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3 Conclusions


Modèle de Wright-Fisher à un locus

○ ○ ○ ○ ○ ○ ○ ○ ○ ○ ○ ○ ○ ○ population de taille N

Modèle de Wright-Fisher à un locus





Modèle de Wright-Fisher à un locus




population de taille N

Modèle de Wright-Fisher à un locus







Généalogie



Mutations





Mutations



- 1 Le temps de coalescence augmente avec la taille efficace.
- 2 Le nombre de mutations sur une branche augmente avec le temps de coalescence.

Application

- Population croissante → temps de coalescence plus longs en bas de l'arbre → plus de fréquences alléliques extrêmes.
- Population décroissante → temps de coalescence plus longs en haut de l'arbre → plus de fréquences alléliques intermédiaires.



- 1** Estimation à partir de locus indépendants
 - Généalogie à un locus
 - Méthodes d'estimation

- 2** Estimation à partir de données génomiques haut débit
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3** Conclusions

- Pour un locus i donné:

$$\mathbb{P}(\mathcal{D}_i \mid N()) = \sum_G \mathbb{P}(\mathcal{D}_i \mid G) \mathbb{P}(G \mid N())$$

\mathcal{D}_i allèles observés, $N()$ démographie, G généalogie.

- En pratique, simulation “intelligente” de généalogies car énumération impossible.
- Pour p locus indépendants:

$$\mathbb{P}(\mathcal{D} \mid N()) = \prod_{i=1}^p \mathbb{P}(\mathcal{D}_i \mid N())$$

Méthode	N()	données	approche
Bottleneck (Cornuet et Luikart, 1996)	1 changement	microsatellites	test heuristique
Msva (Beaumont, 1999)	1 changement	microsatellites	MCMC
Beast (Drummond et Rambaut, 2007)	continu	séquences	MCMC
VarEff (Nikolic et Chevalet, 2014)	continu	microsatellites	formule approchée

- 1 Estimation à partir de locus indépendants
 - Généalogie à un locus
 - Méthodes d'estimation

- 2 Estimation à partir de données génomiques haut débit
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3 Conclusions

■ Intérêt:

- Données disponibles (puces de génotypage, séquençage, RADseq).
- Plus de locus \rightarrow estimation plus précise.

■ Obstacles:


- Généalogies G_i et G_j pour deux locus proches différentes mais corrélées.
- Corrélation difficile à modéliser, prise en compte de la recombinaison.

- 1** Estimation à partir de locus indépendants
 - Généalogie à un locus
 - Méthodes d'estimation

- 2** Estimation à partir de données génomiques haut débit
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)


- 3** Conclusions

Estimation basée sur le génome entier d'un individu diploïde.





PSMC = Pairwise Sequentially Markovian Coalescent

- Généalogie simplifiée: $G = T_2$.
- Approximation de Markov: $G_{i+1} = f(G_i)$
→ Chaîne de Markov cachée.



Autres méthodes SMC

- dical (Sheehan *et al*, 2013), MSMC (Schiffels et Durbin, 2014).
- Petit nombre d'individus (≈ 5 diploïdes max).
 - Faible précision pour la démographie récente.



- 1 Estimation à partir de locus indépendants**
 - Généalogie à un locus
 - Méthodes d'estimation


- 2 Estimation à partir de données génomiques haut débit**
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3 Conclusions**

- Remplacer les données complètes \mathcal{D} par un ensemble de statistiques \mathcal{S} résumant ces données.
- **Avantage:** $\mathbb{P}(\mathcal{S} | N())$ plus facile à calculer que $\mathbb{P}(\mathcal{D} | N())$
- **Inconvénient:** Estimation un peu moins précise.

Spectre des fréquences alléliques (AFS)


- Proportion de SNPs sur le génome.
- Parmi ces SNPs, proportion de ceux ayant i copies de l'allèle le moins fréquent, pour i de 1 à $n/2$ (n taille de l'échantillon).
- Formule analytique approchée pour $\mathbb{P}(\mathcal{S} | N())$ (Bhaskar *et al*, 2015; Liu *et al*, 2015).




Déséquilibre de liaison (LD)

- r^2 = corrélation des génotypes observés entre deux SNPs.
- r^2 diminue quand le taux de recombinaison c augmente.
- Approximation de Hayes *et al* (2003):

$$r^2(\hat{c}) \approx \frac{1}{1 + 2N(1/2c)c}$$




Exemple



The Bovine HapMap consortium (2009)

Segments IBS (Identical By State)

- Zone du génome sans polymorphisme.
- McLeod et al (2013), Harris et Nielsen (2013):
formules approchées pour $\mathbb{P}(\mathcal{S} | N())$, \mathcal{S} distribution de la longueur des segments IBS chez un individu.



- 1 Estimation à partir de locus indépendants**
 - Généalogie à un locus
 - Méthodes d'estimation

- 2 Estimation à partir de données génomiques haut débit**
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3 Conclusions**

■ Approche par simulation:

- 1 Tirer une histoire démographique selon une loi a priori.
- 2 Simuler un échantillon de génomes selon cette histoire.
- 3 Caculer les statistiques résumantes.
- 4 Conserver les paramètres de l'histoire si les statistiques simulées ressemblent à celles observées.


■ Avantages:

- Combiner différentes catégories de statistiques.
- Pas d'approximations du modèle.
- Mesure de l'incertitude du résultat (approche Bayesienne).


■ Inconvénients: temps de calcul important!

■ Boitard *et al* (2016): combiner AFS et LD.




Erreur de prédiction moyenne ($n = 50$)



AFS et LD complémentaires






Comparaison avec les approches SMC




Utiliser des grands échantillons améliore l'estimation de l'histoire récente.

Comparaison avec les approches SMC



Application chez la vache (projet 1000 génomes)



- Les histoires dans chaque race **divergent à partir de la domestication**.
- Déclin continu **antérieur à la domestication**, similaire MacLeod *et al* (2013).
- Classement des races d'après leur taille récente cohérent.

- 1 Estimation à partir de locus indépendants
 - Généalogie à un locus
 - Méthodes d'estimation

- 2 Estimation à partir de données génomiques haut débit
 - Données complètes: les modèles SMC
 - Données résumées
 - L'approche ABC (Approximate Bayesian Computation)

- 3 Conclusions

- Diversité génomique présente contient beaucoup d'information sur variations passées de la taille efficace.
- Résolution accrue par le haut débit.
- Approche SMC très prometteuse mais:
 - Méthodes actuelles peu précises pour l'histoire récente.
 - Séquences continues nécessaires.
- Approches par statistiques résumantes: bonne alternative, adaptées à données plus variées.
- ABC: grande flexibilité mais mise en oeuvre plus longue.