

Une approche Bayésienne de l'étude des populations bactériennes pour données méta-génomiques

David Abrial, Xavier Bailly


INRA de Clermont-Ferrand
Unité Epia - CATI IMOTEP

Mars 2019


Plan

- Motivations
- Notre modèle
- État d'avancement et perspectives

Approche méta-génomique



Les fréquences alléliques



Les objectifs

Proportions



Echantillons



	Lignées connues			Lignées inconnues	
	50%	20%	0%	25%	5%
	0%	25%	15%	5%	55%
	10%	5%	25%	35%	25%

Génomomes

Phylogénie




Un modèle hiérarchique bayésien 1/2

O'Brien et al. 2014 'A bayesian approach to inferring the phylogenetic structure of communities from metagenomic data', *Genetics*, 197,925-937.


Modifications :

- le génome binaire est remplacé par un codage en nucléotides
- le triplet génome/arbre/partition est proposé puis accepté ou rejeté dans son ensemble
- un modèle évolutif est utilisé pour proposer un génome
- pour l'arbre, un *a priori* basé sur un processus de pure naissance (Yule) remplace le coalescent

Notre modèle hiérarchique bayésien 2/2




Proposition génotype 1/2



- chaque site évolue selon un poids ϕ combinaison de l'**entropie de Shannon** et d'une pondération de site
- l'entropie prend en compte la variabilité des fréquences alléliques
- la pondération de site favorise les sites variants dans l'ADN des échantillons et pas celui des lignées observées

Proposition génotype 2/2




- le **modèle évolutif** est celui de Juke et Cantor 1969

$$P_{x_j} = \exp(\phi Qt)_{x_j}$$


- le temps d'évolution t est inféré à partir de la phylogénie des lignées connues

Proposition phylogénie




- l'arbre proposé est estimé par **maximum de vraisemblance** selon le modèle de Juke et Cantor 1969

Proposition partition



- le génotype proposé implique une proposition pour la partition des sites en sites variants et non variants

Proposition proportions



- on propose une nouvelle matrice des proportions en modifiant 2 probabilités pour un échantillon tiré aléatoirement
- une loi Dirichlet peut également être utilisée pour modifier toute la distribution

Estimation : Metropolis-Hastings

- les probabilités d'acceptation-rejet doivent être calculées à chaque itération, exemple pour génotype/arbre/partition :


$$\alpha = \alpha_1 \times \alpha_2$$

$$\alpha_1 = \frac{P(D|L^*, S, \eta)}{P(D|L, S, \eta)} \times \frac{P(L^*|\mathcal{P}^*, \mathcal{T}^*, \xi)}{P(L|\mathcal{P}, \mathcal{T}, \xi)} \times \frac{P(\mathcal{P}^*|\lambda)}{P(\mathcal{P}|\lambda)} \times \frac{P(\mathcal{T}^*)}{P(\mathcal{T})}$$


$$\alpha_2 = \frac{q(L|L^*)}{q(L^*|L)} \times \frac{q(\mathcal{T}|\mathcal{T}^*)}{q(\mathcal{T}^*|\mathcal{T})} \times \frac{q(\mathcal{P}|\mathcal{P}^*)}{q(\mathcal{P}^*|\mathcal{P})}$$

Premiers résultats

- données de séquençage (Margos, G) : référence le gène ribosomale rplB de *Borrelia garinii* NP8, 179 échantillons, 200 lignées connues (pubmlst ; Millins, C.) et 5 inconnues.
- 5E6 itérations, 15 jours de calcul!!!



Premiers résultats



4e-05

Perspectives et logiciel

- **Algorithme**

- 5E6 itérations on déjà été conduites, objectif 50E6 !!
- la convergence n'est pas encore satisfaisante (chaîne d'arbre et grande matrice).
- le pilotage de l'algorithme doit être amélioré.
- les lois a priori doivent être testées
- parallélisation par propositions multiples.

- **Validation du modèle**

- tester sur données simulées.
- comparaison avec le modèle de O'Brien 2014 ou d'autres.
- étude du choix du nombre de lignées inconnues (inférence?)

- **Le logiciel *lignee3***

- C++, GSL 2.4; Bio++ 2.4
- CodeLite, GIT, valgrind 3.13, Doxygen 1.8