

# Le calcul bayésien approché

Notions de base et ouvertures

Samuel Soubeyrand

19 mars 2010

# 1. Introduction

Qu'est-ce que le calcul bayésien approché (ABC) ?

- ▶ C'est un ensemble de méthodes d'estimation de paramètres
- ▶ L'estimation des paramètres est faite dans une perspective bayésienne : on fournit des lois a posteriori
- ▶ Des simulations du modèle utilisé permettent l'inférence

L'ABC, en tant que méthode d'inférence bayésienne, est soumis au débat entre Bayésiens et Classiques (et le nourrit)

# Les modèles stochastiques implicites

Dans des disciplines comme la biologie évolutive, la dynamique de populations, l'épidémiologie

- ▶ On construit des modèles décrivant des scénarios complexes (structures de dépendance spatio-temporelle complexes)
- ▶ Dont les lois de probabilité ne peuvent être écrites de manière concise (vraisemblance incalculable en pratique)
- ▶ Mais qui peuvent être utilisés pour simuler des données

L'ABC permet d'estimer les paramètres de ces modèles stochastiques implicites


# Principe de l'ABC

Notations :

- ▶  $\mathcal{D}$  : jeu de données observé
- ▶  $\theta$  : paramètres du modèle
- ▶  $\pi$  : loi a priori des paramètres
- ▶  $\mathcal{M}$  : Modèle paramétré par  $\theta$  sensé générer les données  $\mathcal{D}$

Procédure :

- ▶ Simuler des jeux de paramètres  $\theta_i$ ,  $i = 1, \dots, I$ , sous la loi a priori  $\pi$
- ▶ Pour chaque jeu de paramètres  $\theta_i$ , simuler un jeu de données  $\mathcal{D}_i$
- ▶ Retenir les  $\mathcal{D}_i$  "ressemblant" à  $\mathcal{D}$  pour construire la loi a posteriori de  $\theta$



# Le rôle des statistiques résumées

Dernière étape de la procédure ABC :

- ▶ Retenir les  $\mathcal{D}_i$  “ressemblant” à  $\mathcal{D}$  pour construire la loi a posteriori de  $\theta$

Pb quand les  $\mathcal{D}_i$  et  $\mathcal{D}$  sont de grande dimension et dans des espaces continus


Dans l'ABC, on se sert de statistiques résumées pour comparer les jeux de données  $\mathcal{D}_i$  et  $\mathcal{D}$

Notations :

- ▶  $S = s(\mathcal{D})$  : statistiques résumées observées
- ▶  $S_i = s(\mathcal{D}_i)$  : statistiques résumées pour les paramètres simulés  $\theta_i$

## Exemple 1 : Estimer les paramètres d'un modèle de coalescence

- ▶ Coalescence : réunion des lignées phylogénétiques pour arriver à un plus proche ancêtre commun
- ▶ Données pour l'inférence : séquences génétiques ou marqueurs microsatellites pour les populations contemporaines
- ▶ Objectifs de l'inférence : tailles efficaces des populations, temps de divergence, taux de mutation, migration et recombinaison, topologie de l'arbre...
- ▶ Structure de dépendance complexe

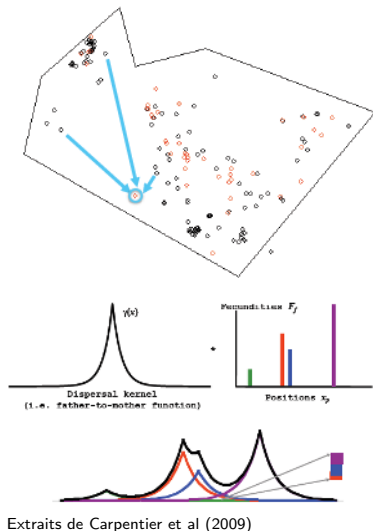


**Figure 14.2.** *Illustration of the three-population model. See text for description of parameters.*

Extrait de Beaumont et al (2008)

## Exemple 2 : Estimer la fonction de dispersion du pollen

- ▶ Dispersion du pollen : composante majeure des flux de gènes chez les végétaux
- ▶ Données pour l'inférence :  
Positions et génotypes de certaines mères, génotypes de leurs graines, positions de certains pères, variation de fertilités
- ▶ Objectifs de l'inférence :  
paramètres de la fonction de dispersion...
- ▶ Structure de dépendance complexe



# Plan

1. Introduction
2. **Quelques algorithmes de calcul bayésien approché**
3. L'émergence de l'ABC
4. Travaux menés par BioSP sur l'ABC



# Quelques algorithmes ABC

- ▶ Acceptation/rejet pour des stats discrètes
- ▶ Acceptation/rejet pour stats continues
- ▶ ABC avec régression linéaire locale
- ▶ ABC MCMC

# Algorithme 1 : Acceptation/rejet pour des stats discrètes

(Fu and Lin, 1997)

Algorithme :

- ▶ Tirer indépendamment  $\theta_i$  ( $i = 1, \dots, l$ ) dans  $\pi$
- ▶ Simuler  $\mathcal{D}_i$  sous  $\mathcal{M}_{\theta_i}$  et calculer  $S_i$
- ▶ Accepter  $\theta_i$  si  $S_i = S$


Ensemble des points acceptés pour construire la loi a posteriori :

$$\{\theta_i : i = 1, \dots, l \text{ et } S_i = S\}$$

Estimation de la loi a posteriori :

$$\hat{p}(\theta | S) = \frac{\sum_{i=1}^l \delta_S(S_i) \delta_{\theta}(\theta_i)}{\sum_{i=1}^l \delta_S(S_i)}$$

converge vers  $p(\theta | S) = \frac{p(S|\theta)\pi(\theta)}{p(S)}$



## Algorithme 2 : Acceptation/rejet pour des stats continues

(Weiss and Von Haeseler, 1998)

Algorithme :

- ▶ Tirer indépendamment  $\theta_i$  ( $i = 1, \dots, l$ ) dans  $\pi$
- ▶ Simuler  $\mathcal{D}_i$  sous  $\mathcal{M}_{\theta_i}$  et calculer  $S_i$
- ▶ Accepter  $\theta_i$  si  $d(S_i, S) \leq \epsilon$  avec  $\epsilon > 0$


Ensemble des points acceptés pour construire la loi a posteriori :

$$\{\theta_i : i = 1, \dots, l \text{ et } d(S_i, S) \leq \epsilon\}$$

Estimation de la loi a posteriori :

$$\hat{p}(\theta | S) = \frac{\sum_{i=1}^l \delta_{B(S, \epsilon)}(S_i) \delta_{\theta}(\theta_i)}{\sum_{i=1}^l \delta_{B(S, \epsilon)}(S_i)}$$

$$\text{converge vers } p(\theta | d(S_i, S) \leq \epsilon) = \frac{p\{d(S_i, S) \leq \epsilon | \theta\} \pi(\theta)}{p\{d(S_i, S) \leq \epsilon\}}$$



## Algorithme 3 : ABC avec régression linéaire locale (Beaumont et al, 2003)

- ▶ Tirer  $\theta_i \sim_{\text{iid}} \pi$ ,  $\mathcal{D}_i \sim_{\text{indép.}} \mathcal{M}_{\theta_i}$ , calculer  $S_i = s(\mathcal{D}_i)$
- ▶ Si  $\theta_i = \alpha + (S_i - S)\beta + \varepsilon_i$ , alors on peut construire la loi a posteriori avec toutes les simulations en utilisant l'ensemble suivant de points :  $\{\theta_i^* = \theta_i - (S_i - S)\hat{\beta} : i = 1, \dots, I\}$
- ▶ Si localement (autour de  $S$ )  $\theta_i = \alpha + (S_i - S)\beta + \varepsilon_i$ , alors on peut construire la loi a posteriori avec l'ensemble suivant de points :  $\{\theta_i^* = \theta_i - (S_i - S)\hat{\beta} : i = 1, \dots, I\}$  où  $\hat{\beta}$  est obtenu par régression linéaire locale en accordant plus de poids aux points tels que  $d(S_i, S)$  est petit  
Est alors proposée l'estimation suivante de la loi a posteriori :

$$\hat{p}(\theta | S) = \frac{\sum_{i=1}^I K_{h_1}(d(S_i, S)) K_{h_2}(\|\theta_i^* - \theta\|)}{\sum_{i=1}^I K_{h_1}(d(S_i, S))}$$

## Algorithme 4 : ABC-MCMC (Marjoram et al, 2003)

Iteration  $i + 1$  de l'algorithme :

- ▶ Tirer un  $\theta^*$  candidat selon la loi de proposition  $q(\theta^* | \theta_i)$
- ▶ Simuler  $\mathcal{D}^*$  sous  $\mathcal{M}_{\theta^*}$  et calculer  $S^* = s(\mathcal{D}^*)$
- ▶ Si  $d(S^*, S) \leq \epsilon$  et  $U(0, 1) \leq \min\left(1, \frac{\pi(\theta^*)q(\theta_i|\theta^*)}{\pi(\theta_i)q(\theta^*|\theta_i)}\right)$  alors  
 $\theta_{i+1} = \theta^*$
- ▶ Sinon  $\theta_{i+1} = \theta_i$

A l'état stationnaire on échantillonne dans la loi

$$p(\theta | d(S_i, S) \leq \epsilon) = \frac{p\{d(S_i, S) \leq \epsilon | \theta\}\pi(\theta)}{p\{d(S_i, S) \leq \epsilon\}}$$

# Améliorations et autres algorithmes ABC (non exhaustif!)

Une littérature foisonnante :

- ▶ ABC avec régression non-linéaire hétéroscédastique (Blum and François, 2009)
- ▶ ABC MCMC avec relaxation de la tolérance dans le MCMC (Wegmann et al., 2009)
- ▶ ABC PMC utilisant l'échantillonnage d'importance (Beaumont et al., 2009)
- ▶ ABC et sélection de modèles (Leuenberger and Wegmann, 2010; Toni et al., 2010)
- ▶ ABC et sélection des statistiques en utilisant l' $\varepsilon$ -exhaustivité relative (Joyce and Marjoram, 2008)

Mais attention à ne pas aller trop vite :

- ▶ Ex : l'algorithme ABC PRC de Sisson et al (2007) est biaisé (cf. Beaumont et al, 2008)

# Limites des algorithmes actuels

- ▶ Choix de la distance entre statistiques  $d(S_i, S)$  pour comparer les jeux de données
- ▶ Trouver des statistiques informatives (tendre vers l'exhaustivité)
- ▶ Sélection des statistiques  $S = s(\mathcal{D})$  car fléau de la dimension et problème de redondance d'information
- ▶ Sélection du seuil de tolérance ( $d(S_i, S) \leq \epsilon$ ) ou d'autres paramètres de tuning
- ▶ On estime  $p(\theta | S)$  et pas  $p(\theta | \mathcal{D})$
- ▶ Modèles simulés lentement qui limitent le nombre d'itérations réalisables

# Plan

1. Introduction
2. Quelques algorithmes de calcul bayésien approché
3. **L'émergence de l'ABC**
4. Travaux menés par BioSP sur l'ABC



# L'émergence de l'ABC

- ▶ La voie évolutionniste
- ▶ La voie statisticienne
- ▶ La jonction des voies



# La voie évolutionniste

- ▶ Pourquoi cette voie ? Parce que les scientifiques travaillant en théorie de l'évolution ont construit des modèles stochastiques implicites dont ils voulaient estimer les inconnues
- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997

# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence

# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence
  - ▶ 1997 - Fu and Li - Approxime par Monte-Carlo la vraisemblance d'une statistique discrète sous un paramètre discret pour inférer l'âge d'un plus proche ancêtre commun

# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence
  - ▶ 1997 - Fu and Li - Approxime par Monte-Carlo la vraisemblance d'une statistique discrète sous un paramètre discret pour inférer l'âge d'un plus proche ancêtre commun
  - ▶ 1998 - Weiss and Von Haesler - Fait du Fu and Li pour des stats continues en intégrant un seuil de tolérance  $d(S_i, S) \leq \varepsilon$

# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence
  - ▶ 1997 - Fu and Li - Approxime par Monte-Carlo la vraisemblance d'une statistique discrète sous un paramètre discret pour inférer l'âge d'un plus proche ancêtre commun
  - ▶ 1998 - Weiss and Von Haesler - Fait du Fu and Li pour des stats continues en intégrant un seuil de tolérance  $d(S_i, S) \leq \varepsilon$
  - ▶ 1999 - Pritchard et al. - Adapte l'algorithme de Weiss and Von Haesler à la mode bayésienne : c'est l'ABC acceptance-rejet

# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence
  - ▶ 1997 - Fu and Li - Approxime par Monte-Carlo la vraisemblance d'une statistique discrète sous un paramètre discret pour inférer l'âge d'un plus proche ancêtre commun
  - ▶ 1998 - Weiss and Von Haesler - Fait du Fu and Li pour des stats continues en intégrant un seuil de tolérance  $d(S_i, S) \leq \varepsilon$
  - ▶ 1999 - Pritchard et al. - Adapte l'algorithme de Weiss and Von Haesler à la mode bayésienne : c'est l'ABC acceptance-rejet
  - ▶ 2003 - Beaumont et al. - Introduit le terme "Approximate Bayesian Computation" ; ABC avec régression linéaire locale

# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence
  - ▶ 1997 - Fu and Li - Approxime par Monte-Carlo la vraisemblance d'une statistique discrète sous un paramètre discret pour inférer l'âge d'un plus proche ancêtre commun
  - ▶ 1998 - Weiss and Von Haesler - Fait du Fu and Li pour des stats continues en intégrant un seuil de tolérance  $d(S_i, S) \leq \varepsilon$
  - ▶ 1999 - Pritchard et al. - Adapte l'algorithme de Weiss and Von Haesler à la mode bayésienne : c'est l'ABC acceptance-rejet
  - ▶ 2003 - Beaumont et al. - Introduit le terme "Approximate Bayesian Computation" ; ABC avec régression linéaire locale
  - ▶ 2003 - Marjoram et al. - Oriente l'exploration de l'espace des paramètres dans l'ABC ; MCMC sans vraisemblance



# La voie évolutionniste

- ▶ Les tenants évolutionnistes de l'ABC font remonter cet ensemble de méthodes à 1997
  - ▶ 1997 - Tavaré et al. - Utilise la vraisemblance calculable de statistiques résumées plutôt que la vraisemblance incalculable du jeu de données pour inférer un temps de coalescence
  - ▶ 1997 - Fu and Li - Approxime par Monte-Carlo la vraisemblance d'une statistique discrète sous un paramètre discret pour inférer l'âge d'un plus proche ancêtre commun
  - ▶ 1998 - Weiss and Von Haesler - Fait du Fu and Li pour des stats continues en intégrant un seuil de tolérance  $d(S_i, S) \leq \varepsilon$
  - ▶ 1999 - Pritchard et al. - Adapte l'algorithme de Weiss and Von Haesler à la mode bayésienne : c'est l'ABC acceptance-rejet
  - ▶ 2003 - Beaumont et al. - Introduit le terme "Approximate Bayesian Computation" ; ABC avec régression linéaire locale
  - ▶ 2003 - Marjoram et al. - Oriente l'exploration de l'espace des paramètres dans l'ABC ; MCMC sans vraisemblance
  - ▶ Depuis : foisonnement des améliorations et des nouvelles procédures

# La voie statisticienne

Pourtant, tout était là...

- ▶ Méthodes des contrastes ou équations estimantes : contourner l'utilisation de la vraisemblance pour faire de l'inférence (cf. en particulier la méthode des moments)
- ▶ Statistiques exhaustives
- ▶ 1962 - Parzen - Estimation de la densité par noyau
- ▶ 1964 - Nadaraya ; Watson - Régression par noyau
- ▶ 1984 - Diggle and Gratton - Estimation (simulation + lissage) de la vraisemblance pour les modèles stochastiques implicites
- ▶ 1984 - Durbin - ABC acceptation-rejet avec seuil de tolérance mais directement sur les jeux de données (n'utilise pas de statistiques résumées)

# La jonction des deux voies

Pour justifier l'ABC et proposer de nouvelles procédures

- ▶ Comportement asymptotique des lois a posteriori issues de l'ABC
- ▶ Sélection automatique du seuil d'acceptation
- ▶ Lien entre ABC et régression par noyau (cf. Blum, 2009)
- ▶ ABC et solutions contre le fléau de la dimension
- ▶ ABC et algorithmes d'exploration efficace de l'espace des paramètres (dont les algorithmes adaptatifs)

# Plan

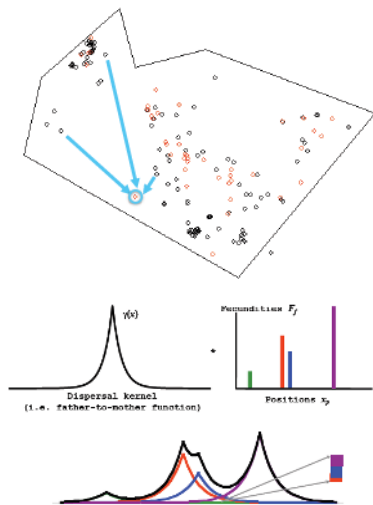
1. Introduction
2. Quelques algorithmes de calcul bayésien approché
3. L'émergence de l'ABC
4. **Travaux menés par BioSP sur l'ABC**

## Quelques travaux sur l'ABC menés au sein de BioSP

- ▶ Travaux s'inscrivant dans le projet ANR EMILE (2009–2013)
  - ▶ Etudes de méthodes inférentielles et logiciels pour l'évolution
  - ▶ Etude des aspects théoriques de l'ABC
  - ▶ Extension de l'ABC à des applications autres que l'évolution
- ▶ Recherche des statistiques résumées informatives pour des dynamiques démo-génétiques (applis en écologie et épidémiologie spatiale)
- ▶ ABC conditionnel aux estimations ponctuelles des paramètres
- ▶ Etude du comportement asymptotique des lois a posteriori issues de l'ABC
- ▶ Loi a posteriori basée sur un contraste
- ▶ Contrast-based ABC

# Statistiques résumées informatives pour des dynamiques démo-génétiques (Carpentier, Guiton & Klein)

- ▶ Modèle dynamique (stochastique implicite) : convolution entre un processus de sources (les pères) marquées (génétique, fertilité) et une fonction de dispersion
- ▶ Données : génotypes de graines échantillonnées sur les mères (récepteurs de pollen)
- ▶ Statistiques résumées pour l'ABC : indices de différenciation génétique (2 à 2) à différentes distances
- ▶ Gérer le très grand nombre de statistiques



# ABC conditionnel aux estimations ponctuelles des paramètres (Soubeyrand, Martin & Carpentier)

ABC basique (acceptation/rejet) :

- ▶  $\theta_i \sim \pi(\cdot)$ ,  $i = 1, \dots, I$ ,  $I$  très grand
- ▶  $S_i = s(\mathcal{M}_{\theta_i}(\omega_i))$  où  $\mathcal{M}_{\theta_i}$  est un modèle implicite
- ▶ Classiquement, on estime la loi a posteriori  $p(\theta \mid d(S_i, S_{obs}) \leq \delta)$
- ▶ Généralement,  $d$  standardisation + distance euclidienne
- ▶ Problèmes : stats redondantes, stats inutiles...

Solution proposée :

- ▶ On introduit un modèle empirique (e.g. ppr ; un métamodèle) qui permet d'obtenir un estimateur  $\hat{\theta}_i$  de  $\theta_i$  sachant  $S_i$  et on estime la loi a posteriori suivante :  $p(\theta \mid d_{\Theta}(\hat{\theta}_i, \hat{\theta}_{obs}) \leq \delta_{\Theta})$

# ABC conditionnel aux estimations ponctuelles des paramètres (Soubeyrand, Martin & Carpentier)

Exemple :


- ▶ Données :  $X_1, \dots, X_{50} \sim N(0, 1)$
- ▶ Stats :  $S = (\bar{X}_{1:40}^3, SD_{1:40}^3, \bar{X}_{11:20}^3, SD_{11:20}^3, \bar{X}_{21:30}^3, SD_{21:30}^3, \beta(0.1, 0.1))$
- ▶  $B = 500$  répétitions,  $I = 50\,000$  simulations pour chaque répét., taux d'acceptation  $\tau = 0.005$
- ▶ QQ-plot :  $P(\theta_{vrai} \leq Q_\alpha^{(b)}) = \alpha$

noir :  $\mu$

rouge :  $\sigma$

continu :  $\cdot \mid S$

tirets :  $\cdot \mid \hat{\theta}$





# Loi a posteriori basée sur un contraste (Soubeyrand, Carpentier, Desassis & Chadœuf, 2009)

- ▶ Let  $(X_i)_{i \leq t}$  be a sample of size  $t$  with distribution  $P_\alpha$ . Then, the posterior distribution of  $\alpha$  is

$$p(\alpha \mid X_i, i \leq t) = \frac{P_\alpha(X_i, i \leq t)\pi(\alpha)}{\int_{\Theta} P_\beta(X_i, i \leq t)\pi(\beta)d\beta} = \frac{\exp(-tU_t^{lik}(\alpha))\pi(\alpha)}{\int_{\Theta} \exp(-tU_t^{lik}(\beta))\pi(\beta)d\beta}$$

- ▶ Substituting  $U_t^{lik}(\alpha)$  with any contrast  $U_t(\alpha)$  leads to a contrast-based (CB) posterior distribution :

$$p_t(\alpha) = \frac{\exp(-tU_t(\alpha))\pi(\alpha)}{\int_{\Theta} \exp(-tU_t(\beta))\pi(\beta)d\beta}$$

- ▶ Utilité :
  - ▶ Dans une perspective fréquentiste : on obtient la loi du MAP en s'affranchissant de certains calculs
  - ▶ Dans une perspective bayésienne : si  $I_\theta = \Gamma_\theta$  la CB-posterior peut être utiliser à la mode bayésienne
  - ▶ Mais comme en ABC, c'est une posterior conditionnelle à l'information contenue dans le contraste utilisé

## Exemple : Modèle de rugosité du sol

- ▶ Modèle : convolution entre un processus ponctuel poissonien d'intensité  $\alpha/\beta$  et des cylindres aléatoires (*rayon = hauteur*  $\sim \text{Exp}(\beta)$ )


$$Y_M = \sum_{(x,r) \in (X,R)} f(x - M, r) \quad \text{with} \quad f(x, r) = r \mathbf{1}_{\{\|x\| < r\}}$$

- ▶ Contraste, basé sur les deux premiers moments

$$\hat{\mu}_A = \left( \frac{1}{\nu(A)} \int_A Y_M dM, \frac{1}{\nu(A)} \int_A Y_M^2 dM \right), \text{ pour lequel } l_\theta = \Gamma_\theta :$$

$$U_A(\theta) = (\hat{\mu}_A - E(\hat{\mu}_A))' V(\alpha, \beta)^{-1} (\hat{\mu}_A - E(\hat{\mu}_A)) / 2$$

- ▶ Données :



## Exemple : Modèle de rugosité du sol


- ▶ Modèle : convolution entre un processus ponctuel poissonien d'intensité  $\alpha/\beta$  et des cylindres aléatoires (*rayon = hauteur*  $\sim \text{Exp}(\beta)$ )

$$Y_M = \sum_{(x,r) \in (X,R)} f(x - M, r) \quad \text{with} \quad f(x, r) = r \mathbf{1}_{\{\|x\| < r\}}$$

- ▶ Contraste, basé sur les deux premiers moments  $\hat{\mu}_A = (\frac{1}{\nu(A)} \int_A Y_M dM, \frac{1}{\nu(A)} \int_A Y_M^2 dM)$ , pour lequel  $I_\theta = \Gamma_\theta$  :

$$U_A(\theta) = (\hat{\mu}_A - E(\hat{\mu}_A))' V(\alpha, \beta)^{-1} (\hat{\mu}_A - E(\hat{\mu}_A)) / 2$$

- ▶ CB-posterior utilisable à la mode bayésienne (car  $I_\theta = \Gamma_\theta$ ) :



# Contrast-based ABC ou le choix raisonné d'une distance

(Carpentier, Chadœuf & Klein, 2010)

- ▶ Idée : Faire de l'ABC en utilisant les résultats obtenus pour la CB-posterior
- ▶ Grandes lignes de l'algorithme :
  - ▶ Tirer  $\theta_i \sim_{\text{iid}} \pi$ ,  $\mathcal{D}_i \sim_{\text{indép.}} \mathcal{M}_{\theta_i}$ , calculer  $S_i = s(\mathcal{D}_i)$
  - ▶ Retenir le mode  $\theta^*$  de la CB-posterior

$$\hat{p}^*(\theta | S) = \frac{\sum_{i=1}^I \exp\{-n(S_i - S)'(S_i - S)\} K_h(\theta_i - \theta)}{\sum_{i=1}^I \exp\{-n(S_i - S)'(S_i - S)\}}$$

- ▶ Estimer  $V = V_{\theta^*}(S_i)$  en simulant sous  $\theta^*$
- ▶ Calculer la posterior

$$\hat{p}(\theta | S) = \frac{\sum_{i=1}^I \exp\{-(n/2)(S_i - S)' \hat{V}^{-1}(S_i - S)\} K_h(\theta_i - \theta)}{\sum_{i=1}^I \exp\{-(n/2)(S_i - S)' \hat{V}^{-1}(S_i - S)\}}$$

# Conclusion

- ▶ Utiliser des statistiques résumées contenant de l'information sur les paramètres d'intérêt, extraire au mieux cette information (c'est de la stat !) et le faire vite

Merci.