



**Combinaison de dires d'experts en  
élicitation de lois a priori.  
Application à un modèle dose-  
réponse pour *Listeria* chez la souris.**

**Exposé AppliBugs**



# INTRODUCTION

Cet exposé présente une partie du travail publié dans l'article :

I. Albert, S. Donnet, C. Guihenneuc-Jouyaux, S. Low Choy, K. Mengersen, J. Rousseau.

**Combining expert opinions in prior elicitation**  
(with Discussion (French et Gosling)),  
*Bayesian analysis*, 7(3): 503-532, 2012.

## Définition :

« Éliciter » : est l'action d'aider un expert ou des experts à formaliser leurs connaissances pour permettre de les sauvegarder, les partager et/ou les utiliser.

**Contexte** : Statistique bayésienne

**Objectif** : Construire la loi a priori à partir de dires d'experts.

Littérature abondante sur le sujet d'un point de vue psychologique et statistique.

Proposer une approche cohérente avec la démarche bayésienne (les données élicitées vont mettre à jour un a priori vague) et pouvant prendre en compte d'éventuelles interactions entre experts.

# SOMMAIRE

- ❖ Contexte bayésien et loi a priori
- ❖ Exemple en risque alimentaire
- ❖ Construction de la loi a priori à partir des dires d'experts
- ❖ Combiner des experts
- ❖ Résultats
- ❖ Conclusions et discussion

\_01

# Contexte bayésien et loi a priori

# Contexte bayésien et loi a priori

$Y = \text{Données, Modèle paramétrique : } Y|\theta \sim M_\theta$   
 $\theta = \text{paramètres}$

Loi a priori sur  $\theta$  :  $[\theta]$

Vraisemblance (données) :  $[Y|\theta]$

Loi a posteriori sur  $\theta$  :  $[\theta|Y]$  par le théorème de Bayes :  $[\theta|Y] \propto [Y|\theta] [\theta]$

- ❖ Choix de la loi a priori
  - ❖ **Pas d'information** sur  $\theta$  (sauf sur le support) : loi a priori « plate » (gaussienne avec une large variance) ou loi a priori de Jeffreys (utilisant l'information de Fisher)
  - ❖ **Des études antérieures** : la loi a posteriori d'études antérieures peut servir de loi a priori
  - ❖ **Prise en compte de l'avis d'experts** pour construire la loi a priori

\_02

## Exemple en risque alimentaire


# Modèle dose-réponse à Listeria

- ❖ Choix d'un modèle exponentiel :

$$p(d, \alpha) = 1 - e^{-\alpha d}, \alpha > 0$$

où  $p(d, \alpha)$  est la probabilité pour une souris de mourir avec la dose  $d$ .

P(d) exponential



- ❖ Des études antérieures ont montré que  $\alpha$  est très mal connu après inférence (grande imprécision sur son estimation).
- ❖ Donc utiliser de l'avis d'experts biologistes réalisant ces expériences pour mieux estimer  $\alpha$ .
- ❖ Utiliser la statistique bayésienne et construire une loi a priori informative [ $\alpha$ ] à partir des dires de ces experts.

**\_03**

## **Construction de la loi a priori à partir des dires d'experts**



# Construction de la loi a priori

Soit  $D = \{D_1, \dots, D_N\}$  les données fournies par les experts. Ces données sont appelées **données élicitées**.

**Difficultés pour définir l'a priori :**

- les experts ont une connaissance limitée, ne connaissent pas la loi sur tout son support
- en un temps raisonnable, on ne peut leur poser qu'un nb de questions limité, donc ne fournissent souvent qu'une petite quantité de données

**Donc raisonnable de supposer que  $[\theta]$  appartienne à une famille paramétrique :**

$$[\theta] \in \{[\theta|\lambda], \lambda \in \Lambda\}$$

Donc **But** de l'élicitation : **trouver les valeurs de  $\lambda$  les plus appropriées pour représenter le savoir des experts**

❖ Dans l'exemple :  $p(d, \alpha) = 1 - e^{-\alpha d}$

❖  $\theta = \alpha$

❖  $\log(\alpha) \sim N(\mu, \sigma^2)$  donc  $\lambda = (\mu, \sigma^2)$

# Construction de la loi a priori

## Processus d'élicitation :

1. Préparation : sélection et motivation des experts, formation aux probabilités.
2. Définir les quantités à éliciter : interroger les experts sur des quantités tangibles pour eux.
3. Interroger les experts
4. Traitement statistique : estimation de  $\lambda$  à partir des données élicitées
5. Validation auprès des experts

## Nature des données élicitées :

- encoder le savoir des experts en distributions de probabilités donc les interroger « **en probabilité** » ;
- aperçu plus cohérent de leur savoir en utilisant **différents types** de questions : des probabilités et des quantiles par exemple d'une quantité tangible  $X$ .

# Dans l'exemple : modèle dose-réponse à Listeria

**Problème** :  $\alpha$  n'a pas d'interprétation concrète pour nos experts (paramètre de forme sur les courbes)

❖ Élicitation de probabilités :

❖ Question structurelle (directement sur  $p(d, \alpha)$ ) :

« Vous avez fait un grand nombre d'expériences, donnez le pourcentage d'expériences qui ont conduit à moins de  $q = 20\%$  de souris mortes. » (avec aussi  $q = 60\%$ )

❖ Réponse théorique pour chaque expert  $i$  :

$$P_{iq}^* = P\left(p(d, \alpha) \leq q \mid \mu_i, \sigma_i^2\right)$$

avec  $\log(\alpha) \sim N(\mu_i, \sigma_i^2)$

❖ Traitement statistique :

$$\begin{cases} \mu_i = \sigma_i \Phi^{-1}(P_{iq_1}) - \frac{\log(1 - q_1)}{d} \\ \sigma_i = \frac{-\log(1 - q_1) + \log(1 - q_2)}{d \left( \Phi^{-1}(P_{iq_1}) - \Phi^{-1}(P_{iq_2}) \right)} \end{cases}$$

Mais questions difficiles pour les experts

# Dans l'exemple : modèle dose-réponse à Listeria

**Problème** :  $\alpha$  n'a pas d'interprétation concrète pour nos experts (paramètre de forme sur les courbes)

**Idée** : interroger sur  $X_n =$  Nombre de souris mortes sur  $n$  souris ayant reçu une même dose  $d$  de Listeria

$$X_n \sim \text{Bin}(n, p(d, \alpha))$$

❖ Élicitation de probabilités :

❖ Question **prédictive** :

« Une expérience consiste en l'injection de la dose  $d$  à 10 souris. Dans combien d'expériences parmi 100, obtiendriez-vous moins de  $q = 2$  souris mortes parmi les 10 ? » (aussi avec  $q = 6$ )

❖ Réponse théorique pour chaque expert  $i$  :

$$P_{iq}^* = P(X_{10} \leq q | \mu_i, \sigma_i^2)$$

où  $X_{10} \sim \text{Bin}(10, p(d, \alpha))$  avec  $\log(\alpha) \sim N(\mu_i, \sigma_i^2)$

Quantités observables mais plus difficile de trainement

❖ Traitement statistique :

$$(\mu_i, \sigma_i) = \arg \min_{\lambda} \sum [P_{iq} - P_{iq}^*]^2$$

$$\text{avec } P_{iq}^* = \sum_{r=0}^q C_{10}^r \int_0^{\infty} (1 - e^{-td})^r e^{-(10-r)td} f((\log t - \mu_i) / \sigma_i) \sigma_i^{-1} t^{-1} dt$$

(réponse théorique)

# Dans l'exemple : modèle dose-réponse à Listeria

## ❖ Élicitation de quantiles :

### ❖ Question prédictive :

« Une expérience consiste en l'injection de la dose  $d$  à 10 souris. Vous faites un grand nombre d'expériences, quel serait le nombre  $Q$  de souris mortes parmi les 10 tel que  $t \cdot 100\%$  des expériences aboutissent à un nombre de souris mortes inférieur ou égal à  $Q$  ? (avec  $t = 0.1, 0.5$  et  $0.9$ )

### ❖ Réponse théorique pour chaque expert $i$ :

$$P(X_{10} \leq Q_{it}^* | \mu_i, \sigma_i^2) = t$$

$$\text{où } X_{10} \sim \text{Bin}(10, p(d, \alpha)) \text{ avec } \log(\alpha) \sim N(\mu_i, \sigma_i^2)$$

### ❖ Question structurelle :

« Quelle serait la proportion  $Q$  de souris mortes telle que  $t \cdot 100\%$  des expériences aboutissent à un nombre de souris mortes inférieur ou égal à  $Q$  ? (avec  $t = 0.1, 0.5$  et  $0.9$ )

### ❖ Réponse théorique pour chaque expert $i$ :

$$P(p(d, \alpha) \leq Q_{it}^* | \mu_i, \sigma_i^2) = t$$

$$\text{où } \log(\alpha) \sim N(\mu_i, \sigma_i^2)$$

# Dans l'exemple : modèle dose-réponse à Listeria

## ❖ Traitement statistique des quantiles :

❖ Prise en compte de l'incertitude des experts sur les quantiles donnés :

- ❖ À chaque quantile donné, les experts associent un degré de confiance  $c_{it}$  compris entre 1 et 10.
- ❖ Donc on peut construire un modèle d'erreur de type Probit : (vraisemblance des données élicitées)

$$\begin{cases} \Phi^{-1}(Q_{it}) = \Phi^{-1}(Q_{it}^*) + \varepsilon_{it} \\ \varepsilon_{it} \sim N(0, v_{it}) \end{cases}$$

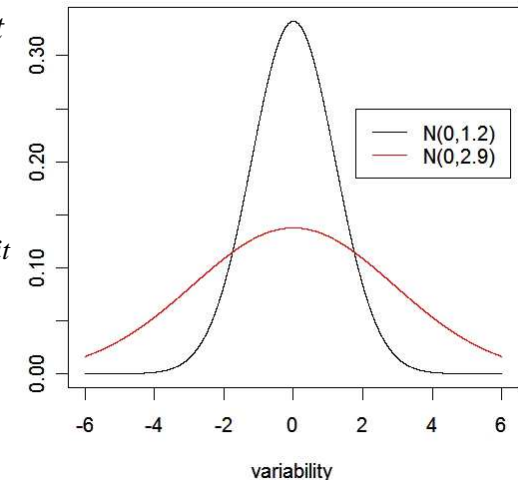
où  $Q_{i,t}^*$  est le quantile théorique  $P(p(d, \alpha) \leq Q_{i,t}^* | \mu_i, \sigma_i^2) = t$

(d'où  $Q_{i,t}^* = 1 - e^{-d \exp(\mu_i + \sigma_i \Phi^{-1}(t))}$ ) et  $v_{it}$  est reliée au degré de confiance : ( $q_i^*$  précision fixée par le statisticien)

$$P(|\Phi^{-1}(Q_{it}) - \Phi^{-1}(Q_{it}^*)| < q_i^*) = c_{it} \Leftrightarrow P(-q_i^* \leq \varepsilon_{it} \leq q_i^*) = c_{it}$$

$$\Leftrightarrow \sqrt{v_{it}} = q_i^* / \Phi^{-1}((c_{it} + 1)/2)$$

Par ex. :  $q_i^* = 1.96$ , si  $c_{it} = 90\% \rightarrow \sqrt{v_{it}} = 1.2$   
 et si  $c_{it} = 50\% \rightarrow \sqrt{v_{it}} = 2.9$



\_04

## Combiner des experts

# Combiner des experts

❖ Soient plusieurs experts interrogés. De chaque experts  $i$ , on déduit une loi a priori mais comment obtenir une loi unique ?

$$\forall i, [\theta | \hat{\lambda}_i] \rightarrow [\theta] ?$$

1. Approche par mélange

$$[\theta] = \sum_i w_i [\theta | \hat{\lambda}_i]$$

modélise les différences entre experts

2. Approche par moyenne

$$\hat{\lambda} = \sum_i w_i \hat{\lambda}_i \Rightarrow [\theta] = [\theta | \hat{\lambda}]$$

modélise un consensus entre experts

Difficultés :

Comment choisir les poids  $w_i$  ? Comment prendre en compte des interactions entre experts (non indépendance des experts s'ils proviennent par exemple de mêmes instituts) ?

**Proposition : Modélisation hiérarchique**

Permet de prendre en compte leurs connaissances communes mais permet une variabilité entre et à l'intérieur des groupes d'experts



# Formulation du modèle hiérarchique

- ❖ Soient  $J$  groupes de  $N_j$  experts indicés par  $j$  ( $i$  l'expert, et au total  $N$  experts) :

- ❖ Modèle hiérarchique :

$$\lambda_{ij} \sim g(\cdot | \lambda_j, b_j) \forall i = 1, \dots, N_j,$$

$$\lambda_j \sim g(\cdot | \lambda, b), \forall j = 1, \dots, J,$$

$$\lambda \sim \pi_0.$$

- ❖ Les experts regroupés en classes homogènes avec une même distribution (première ligne)
- ❖ La connaissance des groupes liée à une distribution commune (ligne 2)
- ❖  $\pi_0$  **loi peu informative** représentant l'incertitude globale sur  $\lambda$ .  $\lambda$  peut être vu comme le paramètre de consensus entre experts.
- ❖ Dans l'exemple :  $\lambda_j = (\mu_j, \sigma_j^2)$ ,  $b_j = (\tau_j, \xi_j)$ ,  $\lambda = (\mu, \sigma^2)$  et  $b = (\tau, \xi)$

$$\mu_{ij} | \mu_j, \tau_j \stackrel{i.i.d}{\sim} N(\mu_j, \tau_j) \text{ et } \frac{\sigma_{ij}^2}{\sigma_j^2} | \sigma_j^2, \xi_j \stackrel{i.i.d}{\sim} \Gamma(\xi_j, \xi_j) \forall j = 1, \dots, J, i = 1, \dots, N_j$$

$$\mu_j | \mu, \tau \stackrel{i.i.d}{\sim} N(\mu, \tau) \text{ et } \frac{\sigma_j^2}{\sigma^2} | \sigma^2, \xi \stackrel{i.i.d}{\sim} \Gamma(\xi, \xi) \forall j = 1, \dots, J$$

$$\mu \sim N(\mu_0, V) \text{ et } \sigma^2 \sim \sigma_0^2 \Gamma(a, a)$$

# Formulation du modèle hiérarchique

- ❖ Traitement statistique (proche du bayésien empirique) :
  - ❖ **Idée : loi  $[\alpha]$  = loi a posteriori  $[\alpha|D]$**  (approche supra-bayésienne) de la forme :

$$[\alpha|D] \propto \int [\alpha|\lambda] \prod_{ijt} [D_{ijt} | \lambda_{ij}] \prod_{ij} [\lambda_{ij} | \lambda_j, b_j] \prod_j [\lambda_j | \lambda, b] \pi_0(\lambda) d\lambda_{ij} d\lambda_j d\lambda$$

- ❖ Dans l'exemple (5 experts) : 2 gps d'experts : gp « Pasteur » avec 3 experts et gp « INRA-Tours » avec 2 experts – **Deux étages dans l'estimation**

- 1) Estimation des hyper-paramètres  $\tau_j, \xi_j, \tau, \xi$  par la méthode des moments en utilisant les **probabilités élicitées** :  $(\hat{\mu}_{ij}, \hat{\sigma}_{ij}) = \arg \min_{\lambda} \sum_q [P_{ijq} - P_{ijq}^*]^2$

$$- \hat{\tau}_j = \frac{1}{N_j - 1} \sum_{i=1}^{N_j} (\hat{\mu}_{ij} - \hat{\mu}_j)^2 \text{ avec } \hat{\mu}_j \text{ la moyenne des } \hat{\mu}_{ij} \text{ dans chaque gp } j.$$

$$- \hat{\tau} = \frac{1}{J - 1} \sum_{j=1}^J (\hat{\mu}_j - \hat{\mu})^2 \text{ avec } \hat{\mu} \text{ la moyenne des } \hat{\mu}_j$$

$$- \hat{\xi}_j^{-1} = \frac{1}{N_j - 1} \sum_{i=1}^{N_j} \left( \frac{\hat{\sigma}_{ij}^2}{\hat{\sigma}_j^2} - 1 \right)^2 \text{ avec } \hat{\sigma}_j \text{ la moyenne des } \hat{\sigma}_{ij} \text{ dans chaque gp } j$$

$$- \hat{\xi}^{-1} = \frac{1}{J - 1} \sum_{j=1}^J \left( \frac{\hat{\sigma}_j^2}{\hat{\sigma}^2} - 1 \right)^2 \text{ avec } \hat{\sigma}^2 \text{ la moyenne des } \hat{\sigma}_j^2$$

$$- \hat{V} = \frac{1}{J} \sum_{j=1}^J \hat{\tau}_j + \hat{\tau}, \quad \hat{a}^{-1} = \frac{1}{J} \sum_{j=1}^J \hat{\xi}_j^{-1} + \hat{\xi}^{-1}, \quad \mu_0 = \hat{\mu}, \quad \sigma_0^2 = \hat{\sigma}^2.$$

# Formulation du modèle hiérarchique

❖ Traitement statistique :

❖ Dans l'exemple :

2) **Loi  $[\alpha|D]$  approchée par un algorithme MCMC** (programmable sous jags) en utilisant **les quantiles élicités et les hyper-paramètres obtenus précédemment « plugés »** (mis directement dans la vraisemblance)

❖ Comparaison avec la méthode par « moyenne » où  $\lambda$  est remplacé par les estimateurs de la méthode des moments sur toutes les données élicitées :

$$\log \alpha \sim N(\hat{\mu}, \hat{\sigma}^2)$$

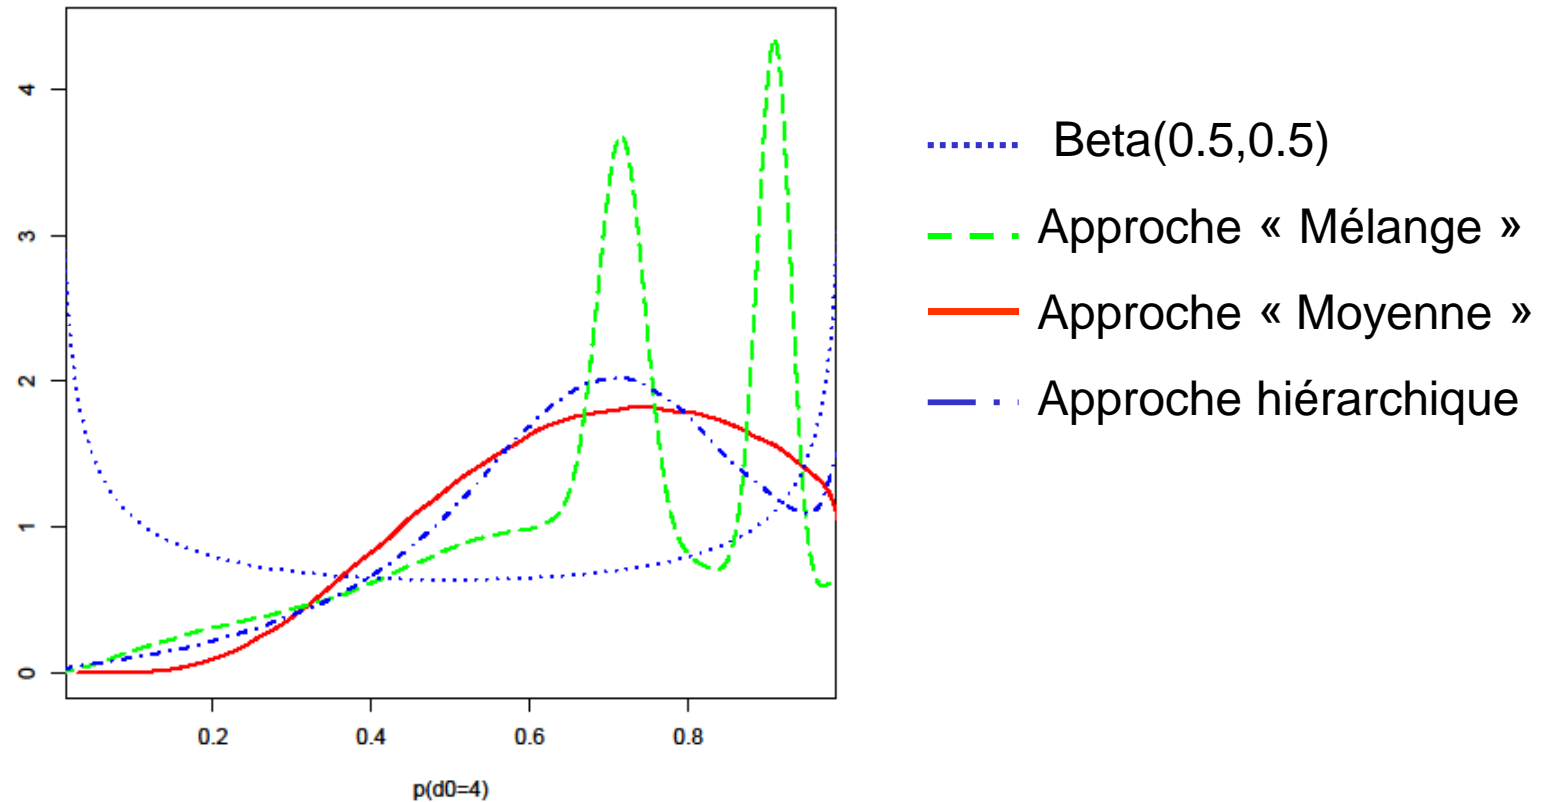
❖ Comparaison avec la méthode par mélange ( $N$  experts) avec les  $\lambda_{ij}$  obtenus sur toutes les données élicitées par la minimisation des moindres carrés :

$$\log \alpha \sim \frac{1}{N} \sum_{ij} N(\hat{\mu}_{ij}, \hat{\sigma}_{ij}^2)$$

# \_05

## Résultats

# Résultats : Listeria/souris



\_06

# Conclusions et Discussion

# Conclusions et discussion

- ❖ Approche qui garde la cohérence de l'approche d'apprentissage via la mise à jour bayésienne de la loi a priori par les données élicitées
- ❖ Approche qui utilise le cadre de la modélisation hiérarchique pour combiner les dires d'experts (*vers un consensus*) et tenir compte des interactions éventuelles entre experts
- ❖ Combinaison d'élicitations indirectes (sur des observables) de différents experts et de différentes natures (proba. et quantiles)
- ❖ Prise en compte de l'incertitude des experts en leur demandant leur confiance en leur répons (*envisager un autre type de calibration*)
- ❖ Chaque expert peut choisir la dose où il est le plus à l'aise

# Conclusions et discussion

- ❖ Dans l'article, étude de simulation qui fait varier le nombre d'experts par groupe (même nombre, fort déséquilibre), la composition des groupes (deux groupes alors qu'il y en a qu'un)
- ❖ Autre exemple, modélisation de la durée d'une thèse en mathématiques dans une université australienne (3 groupes, modèle log-normal, 1 étape d'estimation)
- ❖ Feedback : consensus ?
- ❖ Modélisation plus fine : ex. : Déséquilibrer les gps : l'importance d'un groupe vs un autre ou un gp qui a un biais systématique :

(connaissance autre)  $\lambda_1 \stackrel{i.i.d}{\sim} g(\cdot | \lambda + \Delta, b), \Delta > 0$  ou  $\lambda_1 \stackrel{i.i.d}{\sim} g(\cdot | \lambda, bb'), bb' > b$





**Merci de votre attention**

