

# Elicitation de loi a priori par combinaison d'experts

S. Donnet <sup>3</sup>.

en collaboration avec I. Albert<sup>1</sup>, S.L. Choy<sup>2</sup>, C. Guihenneuc<sup>4</sup>, K.  
Mengersen<sup>2</sup>, J. Rousseau<sup>3</sup>

<sup>1</sup>Unité meta@risk, INRA, Paris

<sup>2</sup>Queensland University of technology, Brisbane, Australia

<sup>3</sup>Université Paris-Dauphine, Cérémade

<sup>4</sup>Université Paris-Descartes, MAP5 et Inserm U754

Journées MAS, Rennes, 27-29 août 2008

# Introduction

## Définition

"Eliciter" est l'action d'aider un expert à formaliser ses connaissances pour permettre de les sauvegarder et/ou les partager.

- **Contexte** : modélisation bayésienne
- **But** : Construction de loi a priori à partir de dires d'experts
- Problème largement étudié dans le passé (d'un point de vue psychologique et statistique)
- **Ici** : proposer un modèle statistique cohérent combinant les avis de plusieurs experts et construire une loi a priori.

## Contexte Bayésien et loi a priori

- Données  $Y_d$  avec modèle paramétrique  $Y_d \sim \mathcal{M}_\theta$  où  $\theta \in \mathbb{R}^d$  sont les paramètres.
- Inférence bayésienne repose sur  $\pi(\theta|Y_d)$  sachant que

$$\pi(\theta|Y_d) \propto \pi(Y_d|\theta)\pi(\theta)$$

avec  $\pi(Y_d|\theta)$  vraisemblance des données et  $\pi(\theta)$  loi a priori sur les paramètres

- Choix de la loi a priori
  - **Pas d'information sur  $\theta$**  (sauf sur le support) : Loi a priori "plate" (Jeffreys par ex)
  - **Etudes antérieures** : Les lois a posteriori des études antérieures servent de loi a priori
  - **Prise en compte de l'avis d'experts** pour construire une loi a priori  $\pi(\theta)$

## Exemple en risque alimentaire

- $Y_d$  = nombre de souris mortes sur  $n$  souris ayant reçu une même dose  $d$  d'agent pathogène (listeria) donc

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

où  $p(d, \alpha)$  la probabilité de mourir

- Modèle exponentiel :  $p(d, \alpha) = 1 - e^{-\alpha d}$
- On cherche à estimer  $\theta = \alpha$ 
  - Très peu de données sont disponibles dans ce cas
  - donc utilisation les avis d'experts (biologistes par ex...) pour pallier à cette lacune
  - i.e. construction d'une loi a priori informative  $\pi(\theta)$  à partir de dires d'experts

## Difficultés et restriction

### Données élicitées

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

- **Difficultés**

- Difficile pour l'esprit humain de quantifier un savoir qualitatif.
- Souvent les experts ne fournissent qu'une petite quantité de données

⇒ Raisonnable de supposer que  $\pi(\theta)$  appartient à une famille paramétrique

$$\pi(\theta) \in \{\pi(\theta|\lambda), \lambda \in \Lambda \subset \mathbb{R}^p\}$$

- **But** : sélectionner la valeur de  $\lambda$  la plus appropriée en fonction du savoir des experts

- **Exemple** :

- $Y_d \sim \text{Bin}(n, 1 - e^{-\alpha d}) \Rightarrow \theta = \alpha$
- $\log(\alpha) \sim \mathcal{N}(\mu, \sigma^2) \Rightarrow \lambda = (\mu, \sigma^2)$

## Collection de données élicitées

- Processus
  1. **Préparation** : Sélection et motivation des experts
  2. **Définition** des quantités à éliciter
  3. **Interrogation** des experts
  4. **Traitement statistique** : estimation de  $\lambda$  à partir des données élicitées
  5. **Validation** auprès des experts
- Nature des données élicitées
  - But : encoder le savoir des experts en distributions de probabilité.
  - Aperçu plus cohérent du savoir des experts obtenu en utilisant 2 types de questions : par ex. probabilités et quantiles.

# Exemple en risque alimentaire : élicitation de probabilités

## Questions structurelles

Dans combien d'expériences parmi 100 obtiendrez-vous moins de  $q\%$  de souris mortes ? avec  $q = 20\%$  ou  $60\%$ .

- **Réponses théoriques** Pour chaque expert  $i$  :

$$P_{i,q} = \mathbb{P}(p(d, \alpha) \leq q | \mu_i, \sigma_i^2)$$

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

- **Traitement statistique**

$$\begin{cases} P_{i,q_1} &= \mathbb{P}(p(d, \alpha) \leq q_1 | \mu_i, \sigma_i^2) \\ P_{i,q_2} &= \mathbb{P}(p(d, \alpha) \leq q_2 | \mu_i, \sigma_i^2) \end{cases}$$

On en déduit  $\lambda_i = (\mu_i, \sigma_i)$  avec

$$\begin{cases} \sigma_i &= \frac{-\log(1-q_1) + \log(1-q_2)}{d(\Phi^{-1}(P_{i,q_1}) - \Phi^{-1}(P_{i,q_2}))} \\ \mu_i &= \sigma_i \Phi^{-1}(P_{i,q_1}) - \frac{\log(1-q_1)}{d} \end{cases}$$

⇒ Quantités non observables donc difficile pour les experts.

# Exemple en risque alimentaire : élicitation de probabilités

## ou bien... Questions prédictives

Une expérience consiste en l'injection de la dose  $d$  à 10 souris.  
Dans combien d'expériences parmi 100 obtiendrez-vous moins de  $q$  souris mortes parmi les 10 ? avec  $q = 2$  ou 6.

- **Réponses théoriques** : Pour chaque expert  $i$ ...

$$P_{i,q} = \mathbb{P}(Y_d \leq q | \mu_i, \sigma_i^2) \quad \text{où} \quad Y_d \sim \text{Bin}(10, p(d, \alpha)) \text{ avec } \log \alpha \sim \mathcal{N}(\mu_i, \sigma_i^2)$$

- Quantités observables mais implique des difficultés calculatoires au moment du traitement



## Exemple en risque alimentaire : élicitation de quantiles

### Question prédictive

Une expérience consiste en l'injection d'une dose  $d$  à 10 souris. Quel serait le nombre  $q$  de souris mortes parmi les 10 tel que  $t\%$  des expériences aboutissent à un nombre de souris mortes inférieur ou égal à  $q$  ? avec  $t = 0.1, 0.5, 0.9$

- **Réponses théoriques**  $Q_{i,t}$  tel que  $\mathbb{P}(Y_d \leq Q_{i,t} | \mu_i, \sigma_i^2) = t$  où  $Y_d \sim \text{Bin}(10, p(d, \alpha))$  avec  $\log \alpha \sim \mathcal{N}(\mu_i, \sigma_i^2)$

### ou bien... Question structurelle

Quelle serait la proportion  $q$  de souris mortes telle que  $t\%$  des expériences aboutissent à une proportion de souris mortes inférieure ou égale à  $q$  ? avec  $t = 0.1, 0.5, 0.9$

- **Réponses théoriques**  $Q_{i,t}$  tel que  $\mathbb{P}(p(d, \alpha) \leq Q_{i,t} | \mu_i, \sigma_i^2) = t$  où  $\log \alpha \sim \mathcal{N}(\mu_i, \sigma_i^2)$

## Erreur et vraisemblance des données élicitées

A chaque quantité  $D_i$ , les experts associent un degré de confiance  $c_i$  compris entre 1 et 10

Donc on peut construire un modèle d'erreur du type Probit :

$$\begin{cases} \Phi^{-1}(D_i) & = & \Phi^{-1}(D(\lambda_i)) + \varepsilon_i \\ \varepsilon_i & \sim & \mathcal{N}(0, v_i) \end{cases}$$

- $D(\lambda_i)$  est le **quantile / probabilité théorique**. Dans notre exemple :  $Q_t(\lambda_i)$  est tel que  $\mathbb{P}(p(d, \alpha) \leq Q_t(\lambda_i) | \mu_i, \sigma_i^2) = t$  d'où
$$Q_t(\lambda_i) = 1 - e^{-d \exp(\mu_i + \sigma_i \Phi(t))}$$
- $\Phi$  est la f.d.r. d'une  $\mathcal{N}(0, 1)$  et  $v_i$  est relié à la confiance et la cohérence  $q^*$  (fixé par le statisticien) par :

$$\mathbb{P}(-q^* \leq \varepsilon_i \leq q^*) = c_i \Leftrightarrow \sqrt{v_i} = \frac{q^*}{\Phi^{-1}\left(\frac{c_i+1}{2}\right)}$$

De là on déduit la **vraisemblance des données élicitées**  $D_1, \dots, D_N$  en fonction des paramètres  $\lambda_i$

## Combinaison des experts

Soient  $N$  experts interrogés. De chaque expert  $i$ , on déduit (après traitement statistique) un  $\hat{\lambda}_i$  donc une loi a priori

$$\forall i, \pi(\theta|\hat{\lambda}_i) \rightarrow \pi(\theta)?$$

1. Approche par mélange  $\pi(\theta) = \sum_{i=1}^N \omega_i \pi(\theta|\hat{\lambda}_i)$   
Permet de modéliser les différences entre experts

2. Approche par moyenne

$$\hat{\lambda} = \sum_{i=1}^N \omega_i \hat{\lambda}_i \Rightarrow \pi(\theta) = \pi(\theta|\hat{\lambda})$$

Permet de trouver un consensus entre experts

### Difficultés

Comment choisir les poids  $\omega_i$ ? Comment prendre en compte les interactions entre experts?

## A propos des interactions entre experts

Les experts peuvent avoir des sources d'information similaires (mêmes expérimentations, mêmes instituts)  $\Rightarrow$  devrait fournir le même genre de valeur.

- Si deux experts sont du même institut, les valeurs qu'ils fournissent ont-elles deux fois plus de chances d'être correctes ?
- Sont-elles aussi informatives que celles d'experts indépendants ?

### Modèle hiérarchique

Proposer un modèle permettant de prendre en compte leurs savoir commun  $\Rightarrow$  Considérer des groupes d'experts avec une structure hiérarchique

## Formulation du modèle hiérarchique

Soient  $K$  groupes d'experts (groupe = institut, laboratoire, équipe...).  
 $ij$  est le  $i$ -ème expert du groupe  $j$ .

### Modèle hiérarchique

$$\begin{array}{lll} \lambda_{ij} & \overset{\text{i.i.d.}}{\sim} & g(\cdot | \lambda_j, b_j) \quad \forall j = 1, \dots, K, \\ \lambda_j & \overset{\text{i.i.d.}}{\sim} & g(\cdot | \lambda, b), \\ \lambda & \sim & \pi_0 \end{array}$$

- Experts regroupés en classes d'homogénéité avec même distribution.  $b_j$ =hyper-paramètre et  $\lambda_j$ =paramètre de centrage
- Savoir des groupes lié par une distribution commune ( $b$ =hyper-paramètre et  $\lambda$ = paramètre de centrage)
- $\pi_0$  loi peu informative représentant l'incertitude globale.  $\lambda$  peut être vu comme le paramètre de consensus entre les experts

# Traitement statistique

"Loi a priori proposée  $\pi(\theta)$ " = "loi a posteriori  $\pi(\theta|D)$ "

- De la forme :

$$\pi(\theta|D) \propto \int \pi(\theta|\lambda) \prod_{ijt} \underbrace{L(D_{ij}|\lambda_{ij})}_{\text{vrais. des don. élicit.}} \prod_{ij} g(\lambda_{ij}|\lambda_j, b_j) \dots$$
$$\dots \prod_j g(\lambda_j|\lambda, b) \pi_0(\lambda) d\lambda_{ij} d\lambda_j d\lambda$$

- **Estimation** (en utilisant les 2 jeux de données élicitées séparément) :
  - Hyper-paramètres  $b_j$  et  $b$  : obtenus par **plug-in** en utilisant le type 1 de données élicitées (les probabilités par ex.)
  - Loi a priori élicitée  $\pi(\theta|D)$  approchée par un **algorithme MCMC** en utilisant le type 2 de données élicitées (les quantiles par ex.)

## Objectifs de l'étude sur données simulées

- Semblable à une analyse de sensibilité : permet de comprendre les hypothèses faites dans le modèle.
- Variation de quantités telles que :
  - le nombre d'experts
  - la composition des groupes d'experts
  - la variabilité entre les groupes et au sein des groupes
  - ...

étude de l'impact de ces variations

- Comparaison des différentes méthodes de combinaison d'experts (moyenne, mélange et modèle hiérarchique)

## Les données simulées : paramètres

On se place dans le modèle exponentiel en risque alimentaire.

- $\log \alpha \sim \mathcal{N}(\mu, \sigma^2)$
- Modèle hiérarchique sur les moyennes

$$\mu_{ij} = \mu_j + \Delta_{ij} \text{ avec } \Delta_{ij} \sim \mathcal{N}(0, \tau_j)$$

$$\mu_j = \mu + \Delta_j \text{ avec } \Delta_j \sim \mathcal{N}(0, \tau)$$

- Modèle hiérarchique sur les variances

$$\sigma_{ij}^2 = \sigma_j^2 \rho_{ij} \text{ avec } \rho_{ij} \sim \Gamma(\xi_j, \xi_j)$$

$$\sigma_j^2 = \sigma^2 \rho_j \text{ avec } \rho_j \sim \Gamma(\xi, \xi)$$

- Nous simulons 2 groupes d'experts d'effectifs  $N_1$  et  $N_2$ .
- Simulation de 2 probabilités (à 20% et 60%) et 5 quantiles (0.1, 0.9, 0.25, 0.75, 0.5) avec **erreurs**.



## Données simulées : phase d'estimation

1. Estimation des variabilités intra-groupes et inter-groupes (hyperparamètres)

$$\tau_j, \xi_j, \tau, \xi$$

par une phase de **plugin** à partir des probabilités élicitées  $p_{ijq}$

2. Approximation de la loi a priori obtenue par elicitation

$$\pi(\alpha | D)$$


en utilisant un algorithme **MCMC** reposant sur les quantiles  $q_{ijt}$

## Données simulées (1)

### Situation 1 :

- Même nombre d'experts dans chaque groupe  $N_1 = N_2 = 5$
- $\tau_1 = \tau_2 = 0.01$  ,  $\frac{1}{\xi_1} = \frac{1}{\xi_2} = 0.01$  (groupes homogènes)
- $\mu_1 = -1.8$ ,  $\mu_2 = -1.1$
- Comparaison des 3 méthodes : tracés des densités des lois a priori  $\pi(\alpha|D)$  obtenues par les 3 méthodes

Case 1 : Hierarchical=blue, Mixture=green, Average=red




## Données simulées (2)

### Situation 2 :

- Même nombre d'experts dans chaque groupe  $N_1 = N_2 = 5$
- Groupes inhomogènes :  $\tau_1 = 0.1$  ,  $\tau_2 = 0.01$   
 $\frac{1}{\xi_1} = \frac{1}{\xi_2} = 0.01$
- $\mu_1 = -1.8$ ,  $\mu_2 = -1.1$
- Comparaison des 3 méthodes :

Case 2 : Hierarchical=blue, Mixture=green, Average=red




## Données simulées (3)


### Situation 3 :

- Groupes déséquilibrés en effectifs  $N_1 = 10$ ,  $N_2 = 2$
- Groupes homogènes :  $\tau_1 = \tau_2 = 0.01$  ,  $\frac{1}{\xi_1} = \frac{1}{\xi_2} = 0.01$
- $\mu_1 = -1.8$ ,  $\mu_2 = -1.1$
- Comparaison des 3 méthodes :

Case 4 : Hierarchical=blue, Mixture=green, Average=red



Case 4 : quantiles of  $p(d)$



Comparaison des densités

Comparaison des intervalles de confiance de  $p(d, \alpha)$   
en fonction de la dose

## Conclusion et travaux en cours

- Méthode générique avec cadre statistique cohérent.
- Applications sur données réelles et simulées :
  - Deux modèles de risque alimentaire
  - Un modèle sur la durée des thèses en mathématiques appliquées dans une université australienne.
- En cours :
  - **Sur données simulées :**
    - Robustesse de la méthode. Ex : erreur sur le nbre de groupes...
    - Mise en place d'un critère de comparaison (autre que graphique)
  - **Sur données réelles**
    - Validation avec les experts i.e vérification par les experts de l'adéquation des distributions avec son ressenti
    - Comparaison sur données réelles entre une loi apriori plate et notre loi a priori.
    - ...