

Notions et mesures de cohérence bayésienne entre informations *a priori* et données de retour d'expérience

Nicolas Bousquet

Séminaire FIMA,
16 Mars 2006.

Introduction

Un exemple introductif

Contexte : données de durée de vie d'un composant \sum de centrale nucléaire supposées suivre un modèle $\mathcal{M}(\theta)$.

temps réels : 134.9, 152.1, 133.7, 114.8, 110, 129, 78.7, 72.8, 132.2, 91.8
temps censurés (à droite) : 70, 159.5, 98.5, 167.2, 66.8, 95.3, 80.9, 83.2

On cherche à estimer θ avec une précision ordonnée par un organisme de contrôle (Agence de sûreté nucléaire).

Méthodes fréquentistes classiques (Newton-Raphson, EM, etc.)
 insuffisantes à estimer θ avec assez de précision.

$$\text{Ex : modèle de Weibull } \mathcal{W}(\eta, \beta) \quad \hat{\eta}_n = 140.8 + / - 7.3,$$

$$\hat{\beta}_n = 4.51 + / - 1.9$$

Appel au **bayésien subjectif** : experts EDF et Westinghouse.

Suite aux premières défaillances, les matériaux de \sum ont été améliorés.

L'expertise prend en compte une certaine évolution technique, de façon difficilement ou non quantifiable \Rightarrow valeurs typiques > 200 .

Problème : l'expertise est en fort **décalage** avec les données.

Une façon **objective** de détecter ce décalage ?

Problème général & Motivations

On note $X \sim \mathcal{M}(\theta)$, $\theta \in \Theta \subset \mathbb{R}^d$ la variable aléatoire d'intérêt (durée de vie, etc.). Soit $p(x|\theta)$ sa densité.

θ est supposé aléatoire.

On connaît une source d'information subjective sur $\sum, X, \theta \dots$
... informations que l'on transforme en une **loi a priori de densité $\pi(\theta)$** .

La détection d'un **conflit** entre les domaines de confiance pour θ apportés

- par la **vraisemblance** $\mathcal{L}(\mathbf{X}_n; \theta)$ des données $\mathbf{X}_n = (X_1, \dots, X_n)$,
- par la densité **a priori** $\pi(\theta)$

est un problème important pour l'emploi **concret** du bayésien subjectif.

D'un point de vue **théorique**, aucune raison de remettre en question le modèle {vraisemblance + *a priori*} (cohérence interne).

Dans l'industrie, bayésien employé comme **palliatif au fréquentiste** : on ne remet pas en cause la vraisemblance.

D'un point de vue pratique, la connaissance d'un tel conflit \Rightarrow

- 1 décalage temporel, technique ... *symétrique* entre expertise et données ;
- 2 remise en cause de π si les données sont bonnes ;
- 3 détection de données "polluant" la connaissance (si consensus d'expert fort) ;
- 4 mise en garde sur le résultat *a posteriori*.

Travaux précédents

- 1 De Finetti (1961), Dawid (1973), Hill (1974) : méthodes automatiques de rejet de données atypiques ($\rightarrow \infty$).
- 2 O'Hagan (1979, 1988, 1990, 2003) : comparaisons des queues des fonctions $\theta \rightarrow \pi(\theta)$ et $\theta \rightarrow \mathcal{L}(\mathbf{X}_n; \theta)$ (*credence orders*).
- 3 West (1984) et Lucas (1990) : même idée de comparaison de scores liés à la "lourdeur" des fonctions de θ .

En général, les outils développés servent à évaluer la robustesse de l'a posteriori vis-à-vis de variations a priori.

- 4 Usureau & Dumon (2001) : une méthode "ingénieur" (produit de convolution entre $\mathcal{L}(\mathbf{X}_n; \theta)$ et $\pi(\theta)$) sans signification statistique.

Objectif

Élaborer une statistique simple $Coh(\pi|\mathbf{X}_n)$ mesurant la cohérence entre *a priori* π et données \mathbf{X}_n , avec la règle du type

$$Coh(\pi|\mathbf{X}_n) \leq 1 \Leftrightarrow \text{cohérence.}$$

Construction d'une règle de cohérence

On considère qu'une **connaissance minimale**, produite à partir des données, est modélisée par π^{MIA} .

Idéalement, π^{MIA} est non informative.

$$\text{Alors } \pi^{MIA}(\theta | \mathbf{X}_n) = \frac{\pi^{MIA}(\theta) \mathcal{L}(\mathbf{X}_n; \theta)}{\int_{\Theta} \pi^{MIA}(\theta) \mathcal{L}(\mathbf{X}_n; \theta)}$$

"mime" la vraisemblance et transmet approximativement la même information que les données.

Hypothèse : $\pi^{MIA}(\theta | \mathbf{X}_n)$ modélise l'avis d'un expert "parfaitement" en accord avec les données.

Choix d'*a priori* non informatifs $\pi^{MIA} = \pi^J$

π^J doit être tel que $\pi^J(\cdot | \mathbf{X}_n)$ a une certaine **validité fréquentiste**.

Soit $\tilde{\theta}_n(\alpha)$ le quantile d'ordre α *a posteriori* sur n observations

$$P_\theta \left(\theta \leq \tilde{\theta}_n(\alpha) \right) = \underbrace{P \left(\theta \leq \tilde{\theta}_n(\alpha) \mid \mathbf{X}_n \right)}_{\alpha} + O \left(n^{-i/2} \right)$$

\Rightarrow **coverage matching priors** [Peers, Mukerjee, Datta, Ghosh (1993, 1995, 1996)], solutions d'une équation différentielle.

$Dim\Theta = 1 \Leftrightarrow$ Jeffreys

$Dim\Theta = 2 \Rightarrow$ Reference prior (Berger-Bernardo, 1992)

L'éventuelle incohérence de π avec \mathbf{X}_n s'exprime alors par la mesure d'une distance $D\{\pi^{MIA}(\cdot|\mathbf{X}_n) \parallel \pi\}$.

Plus cette distance est grande, moins il y a cohérence.

La distance maximale de cohérence est atteinte quand $\pi = \pi^{MIA}$.

Définition

On définit la statistique de cohérence

$$Coh(\pi|\mathbf{X}_n) = \frac{D\{\pi^{MIA}(\cdot|\mathbf{X}_n) \parallel \pi\}}{D\{\pi^{MIA}(\cdot|\mathbf{X}_n) \parallel \pi^{MIA}\}}$$

et la règle

$$Coh(\pi|\mathbf{X}_n) \leq 1 \Leftrightarrow \text{cohérence.}$$

Choix d'une distance $D(\pi_1 || \pi_2)$

Une distance en terme de **quantité d'information portée** par π_1 et π_2 (classe de Ali-Silvey).

Kullback-Leibler : $D(\pi_1 || \pi_2) = KL(\pi_1 || \pi_2) = \int_{\Theta} \pi_1(\theta) \log \frac{\pi_1(\theta)}{\pi_2(\theta)} d\theta$.

- 1 la plus naturelle (information de Shannon) ;
- 2 reflète un *regret* informatif dû au choix de π_2 lorsque le meilleur est π_1 ;
- 3 propriétés analytiques supérieures aux autres (Chernoff) ;
- 4 rend *Coh* indépendante du choix de paramétrisation θ .

Élicitation de π^{MIA}

Difficultés

π^{MIA} représente la **connaissance minimale** que l'on peut placer dans un *a priori*, cohérent avec les données.

Idéalement, $\pi^{MIA} = \pi^J$ où $\pi^J(\theta) = \sqrt{\det I(\theta)}$ = **Jeffreys** (indépendance de paramétrisation), où $I(\theta)$ est la matrice de Fisher de $\mathcal{M}(\theta)$.

Excepté pour des modèles $\mathcal{M}(\theta)$ **discrets**, π^J est toujours **impropre**

$$\int_{\Theta} \pi^J(\theta) d\theta = \infty.$$

et le **dénominateur de Coh** est alors **défini à une constante près** (linéairement).

Exemple : Modèle multinomial avec *a priori* de Dirichlet.

Soit $X \sim \mathcal{M}(m, p_1, \dots, p_d)$ avec $m \in \mathbb{N}$, $p_i > 0 \forall i \in \{1, \dots, d\}$ et $\sum_{i=1}^d p_i = 1$. Soient $(m_1, \dots, m_d) \in [0, m]^d$ les données observées avec $\sum_{i=1}^d m_i = m$. Alors $P\{X = (m_1, \dots, m_d)\} = m! \prod_{i=1}^d p_i^{m_i} / \prod_{i=1}^d m_i!$.

Alors Jeffreys = $\pi^J(p_1, \dots, p_d) \propto 1 / \prod_{i=1}^d p_i$. Celui-ci est proprement défini (Dirichlet) :

$$\pi^J(p_1, \dots, p_d) = \text{Dir}(1/2, \dots, 1/2).$$

En conséquence

$$\pi^J(m, p_1, \dots, p_d | m_1, \dots, m_d) = \text{Dir}(m_1 + 1/2, \dots, m_d + 1/2).$$

Supposons avoir choisi l'*a priori* $\pi(p_1, \dots, p_d)$ comme une densité de la loi de Dirichlet $\text{Dir}(a_1, \dots, a_d)$.

Alors

$$\text{Coh}(\pi | m_1, \dots, m_d) =$$

$$\log \frac{\Gamma(\alpha)}{\Gamma\left(\sum_{j=1}^d a_j\right)} + \sum_{j=1}^d \log \frac{\Gamma(a_j)}{\Gamma(\alpha_j)} + \sum_{j=1}^d [\alpha_j - a_j] [\Psi(\alpha_j) - \Psi(a_j)]$$

$$\log \frac{\Gamma(\alpha)}{\Gamma(d/2)} + d\sqrt{\pi}/2 - \sum_{i=1}^d \log \Gamma(\alpha_i) + \sum_{i=1}^d m_i \Psi(\alpha_i) + m(\gamma + 2 \log 2)$$

avec Ψ la fonction digamma, γ la constante d'Euler ($\simeq 0.577215$),
 $\alpha_i = 1/2 + m_i$ et $\alpha = \sum_{i=1}^d \alpha_i$.

Démarche à suivre

Il faut donc des règles pour trouver π^{MIA} **propre**, élicité d'après les données (ajustement de π^J).

- 1 On construit de façon **objective** un certain nombre de **candidats MIA** formant l'ensemble $\Pi^{MIA} = \{\pi_i^{MIA}, i \in I\}$.
 - maximum d'entropie sous contraintes (Jaynes) ;
 - *a priori* localement uniformes sur un domaine de confiance de la vraisemblance (Box & Tiao) ;
 - *Maximum Likelihood Priors* (Hartigan)
 - *Posterior priors* (Berger & Pérez) ...
- 2 On sélectionne **le moins informatif de tous**.

Élicitation de *Posterior priors*

Les *a priori* élicités sont *objectifs* et ne dépendent que des données.

Les *a priori* élicités sont toujours propres.

Pas de choix de contrainte(s) à faire (maximum d'entropie).

Notion de MTS (1)

Posterior prior : construction liée à la notion d'*échantillon d'apprentissage minimal* (MTS) [Berger & Perrichi, 1996, 2002].

Soit π^J un *a priori* non informatif.

Un MTS $X(I)$ est une quantité minimale de données dans $\mathbf{X}_n = (X_1, \dots, X_n)$ telle que $\pi^J(\theta | X(I))$ est propre.

Un MTS est donc constitué du **nombre de données minimal** pour lequel θ est identifiable .

Notion de MTS (2)

Originellement, les MTS sont introduits dans le contexte de la **sélection de modèles**.

Soient 2 modèles $p_1(x|\theta_1)$ et $p_2(x|\theta_2)$. On cherche à calculer le **facteur de Bayes**

$$B_{ji}^J = \frac{m_j(x)}{m_i(x)} = \frac{\int p_j(x|\theta_j)\pi_j^J(\theta_j) d\theta_j}{\int p_i(x|\theta_i)\pi_i^J(\theta_i) d\theta_i}.$$

où π_i^J et π_j^J sont les plus neutres possibles (*default priors*).

But : améliorer les tests fréquentistes (rapport de vraisemblance, utilisation des p-values, pondération de la dimension, etc.)

Problème : (π_j^J, π_i^J) et donc B_{ji}^J définis à une constante près.

Notion de MTS (3)

Soit $X(l)$ un MTS et $X(-l)$ le reste de l'échantillon.

Berger et Perrichi (1996) : $B_{ji}^{AJ} = B_{ji}^J \sum_{k=1}^L B_{ij}^J(X(l_k))$ où

$$B_{ij}^J(X(l)) = \frac{\int p_i(X(-l)|\theta_i)\pi_i^J(\theta_i|X(l)) d\theta_i}{\int p_j(X(-l)|\theta_j)\pi_j^J(\theta_j|X(l)) d\theta_j}$$

est asymptotiquement équivalent à un facteur de Bayes "propre"

A priori intrinsèques propres π_i et π_j modélisant raisonnablement l'ignorance.

Généralisation des (*expected*) *Posterior priors*

Pérez et Berger (1998, 2002)

Candidats MIA : on fait le choix

- 1 d'un *a priori* non informatif π^J (*coverage matching prior*),
- 2 d'une mesure g_j pour les MTS $X(I)$ (par exemple prédictive, empirique, etc.).

On élicite le candidat π_i^{MIA} comme

$$\pi_i^{MIA}(\theta) \propto \int \pi^J(\theta|X(I)) g_j(X(I)) dX(I).$$

Cohérence arithmétique

Définition

$$\text{Coh}_A(\pi|\mathbf{X}_n) = \frac{1}{L} \sum_{i=1}^L \frac{KL\{\pi^J(\cdot|X(i), \mathbf{X}_n) \parallel \pi\}}{KL\{\pi^J(\cdot|X(i), \mathbf{X}_n) \parallel \pi^J(\cdot|X(i))\}}.$$

Une version “Leave-one-MTS-out” :

$$\text{Coh}_A(\pi|\mathbf{X}_n) = \frac{1}{L} \sum_{i=1}^L \frac{KL\{\pi^J(\cdot|\mathbf{X}_n) \parallel \pi\}}{KL\{\pi^J(\cdot|\mathbf{X}_n) \parallel \pi^J(\cdot|X(i))\}}.$$

Si π^J existe, permet de pallier l'absence de candidats MIA simples à éliciter, explicites, etc.

Règles de sélection

Candidats MIA obtenus : π_i^{MIA} , $i \in I$.

On veut sélectionner le “moins informatif”.

Règle 1 : Regret prédictif *a posteriori* .

$$\mathcal{R}_n(i) = \int KL\{\pi^j(\cdot|\mathbf{Y}_n) \parallel \pi_i^{MIA}(\cdot|\mathbf{Y}_n)\} m_i(\mathbf{Y}_n) d\mathbf{Y}_n$$

avec $m_1(x) = \int_{\Theta} p(x|\theta)\pi_i^{MIA}(\theta)$.

Normalité asymptotique (Clarke, 1999) : $\mathcal{R}_n(i) \xrightarrow{n \rightarrow \infty} 0$.

On sélectionne le candidat avec la meilleure convergence vers 0 :

$$\pi^{MIA} = \arg \min_{i \in I} \lim_{n \rightarrow \infty} \sum_{j \in I, j \neq i} \frac{\mathcal{R}_n(i)}{\mathcal{R}_n(j)}. \quad (C_1)$$

Règle 2 : Gain prédictif en information .

$$\mathcal{K}_n(i) = \int_{S^n} KL\{\pi_i^{MIA}(\cdot | \mathbf{Y}_n) \parallel \pi_i^{MIA}\} m_i(\mathbf{Y}_n) d\mathbf{Y}_n.$$

La distance de Kullback entre *a priori* et *a posteriori* = information transmise par les données (Règle de Bernardo, 1979).

On cherche la divergence la plus rapide quand $n \rightarrow \infty$.

$$\pi^{MIA} = \arg \min_{i \in I} \lim_{n \rightarrow \infty} \sum_{j \in I, j \neq i} \frac{\mathcal{K}_n(j)}{\mathcal{K}_n(i)}. \quad (C_2)$$

Une idée de test de sélection (critère moins général)

- 1 Soit π une densité *a priori* définie sur Θ .
- 2 Soit des simulations marginales $\mathbf{Y}_n = (Y_1, \dots, Y_n)$ ($\Leftrightarrow \pi$ cohérent avec \mathbf{Y}_n).
- 3 Pour tout candidat MIA π_i^{MIA} , soit β_i la puissance du test

$$Coh_i(\pi | \mathbf{Y}_n) - 1 \leq 0.$$

- 4 On sélectionne $\pi^{MIA} = \arg \max_{i \in I} \beta_i$.

Exemples des modèles exponentiel et de Weibull

Modèle exponentiel

$\mathbf{X}_n = (X_1, \dots, X_n)$ de densité $p(x|\theta) = \theta \exp(-\theta x)$.

$\pi^J(\theta) \propto \theta^{-1}$ (Jeffreys).



1 MTS est composé d'une seule donnée (non censurée)

Candidats MIA :

① *Conjugué exhaustif (SCP)* : $\pi_1^{MIA}(\theta) = \pi^J(\theta | \sum_{i=1}^n X_i/n)$.
Propriété : $\mathcal{R}_n(1) \sim (3n)^{-1}$.

② *Posterior Prior empirique (EmPP)* : $\pi_2^{MIA}(\theta) = \frac{1}{L} \sum_{i=1}^L \pi^J(\theta | X_i)$.

③ *Expected Posterior Prior (ExPP)* : $\pi_3^{MIA}(\theta) = \frac{\hat{\theta}_n}{(\hat{\theta}_n + \theta)^2}$.



$\mathcal{R}_n(i)$ (gauche) et $\mathcal{K}_n(i) \Rightarrow$ sélectionnent SCP (*a priori* conjugué)

Cohérence vis-à-vis d'un échantillon simulé

$$\mathbf{X}_n = (142, 143, 470, 419, 185, 84, 8, 27, 573, 17) \sim \mathcal{E}(\theta_0 = 1/150).$$

$$\text{MLE } \hat{\theta}_n = 1/207 < \theta_0.$$


On désire évaluer la cohérence de $\pi(\theta) = \mathcal{G}(a, aX_e)$ (conjugué)

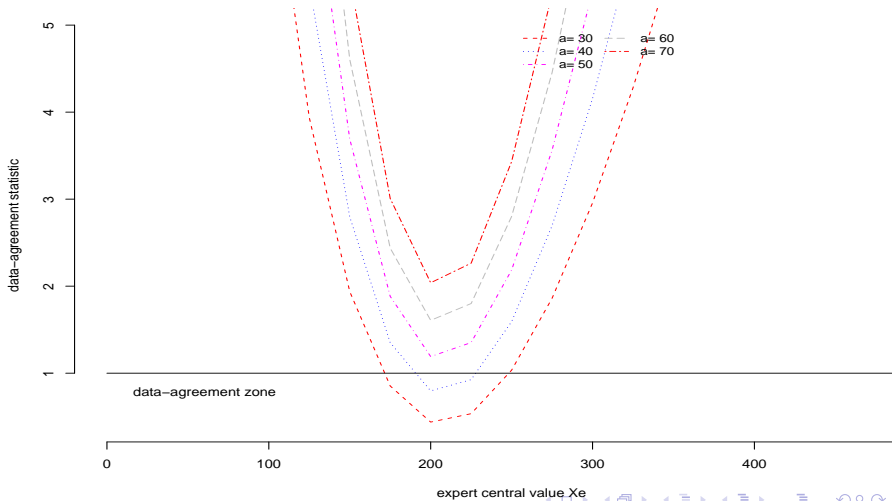
- 1 $X_e =$ avis central d'expert ($= 1/E[\theta]$)
- 2 $a \in \mathbb{N}^*$ correspond à une taille d'échantillon *fictif* $\tilde{\mathbf{X}}_a$ de moyenne X_e .

$$\text{En effet } \pi(\theta) \propto \pi^J(\theta) \mathcal{L}(\tilde{\mathbf{X}}_a, \theta)$$

Le "meilleur" *a priori* possible est en $X_e = \hat{\theta}_n^{-1} = 207$, pour $a = 10$.

<i>A priori</i> π		SCP	EmPP	ExPP	$Coh_A(\pi; \mathbf{X}_n)$
$a = 5$	$X_e = 10$	12.97	8.750	9.823	8.805
	$X_e = 150$	0.444	0.364	0.235	0.316
	$X_e = 207$	0.156	0.097	0.015	0.118
	$X_e = 300$	0.638	0.282	0.402	0.437
	$X_e = 500$	3.444	1.827	2.543	2.323
$a = 10$	$X_e = 10$	25.63	17.24	17.95	17.40
	$X_e = 150$	0.580	0.560	0.402	0.424
	$X_e = 207$	0	0.021	0.004	0.003
	$X_e = 300$	0.966	0.386	0.679	0.665
	$X_e = 500$	6.580	3.481	4.645	4.436

expert central value X_e



Modèle de Weibull

$\mathbf{X}_n = (X_1, \dots, X_n)$ de densité $p(x|\theta) = \beta\eta^{-\beta}x^{\beta-1}\exp(-\eta^{-\beta}x^\beta)$.

Reference prior (Sun, 1997) : $\pi^J(\eta, \beta) \propto (\eta\beta)^{-1}$.

Un MTS = $(X_i, X_j) > 1, (X_i \neq X_j)$.

Le candidat EmPP est explicite.

On peut se faciliter la tâche en reparamétrisant :

$$\begin{cases} \eta & \rightarrow \mu = \eta^{-\beta}, \\ \beta & \rightarrow \beta \end{cases}$$

On obtient alors

$$\pi_1^{MIA}(\mu, \beta) = \frac{1}{L_1 L_2} \sum_{i=1}^{L_1} \sum_{j=1}^{L_2} \pi^{ij}(\mu|\beta) \pi^{ij}(\beta),$$

$$\text{avec } \pi^{ij}(\mu|\beta) = \mathcal{G}\left(2, X_i^\beta + X_j^\beta\right),$$

$$\pi^{ij}(\beta) = \frac{(X_i X_j)^{\beta-2}}{2|\log X_i/X_j| \left(X_i^\beta + X_j^\beta\right)^2}.$$

Facilite les calculs *a posteriori*.

On reprend les données EDF (âge de remplacement de matériels équipant le circuit secondaire)

temps réels : 134.9, 152.1, 133.7, 114.8, 110.0, 129.0, 78.7, 72.8, 132.2, 91.8
temps censurés (à droite) : 70.0, 159.5, 98.5, 167.2, 66.8, 95.3, 80.9, 83.2

MLE : $(\hat{\eta}_n, \hat{\beta}_n) = (140.8, 4.51)$ avec $\hat{\sigma}_n = (7.3, 1.9)$.

<i>Expertises</i>	intervalle à (5%,95%)	valeur médiane
EDF	(200,300)	250
Westinghouse	(100,500)	250

Idée : 4 *a priori* proches et indépendants pour η et β

On fait varier $\pi(\beta)$ principalement dans $[1, 5]$ avec σ_β variable.

$$\pi_1(\beta|\beta_0, \alpha_\beta) = \mathcal{G}(\alpha_\beta, \alpha_\beta \beta_0^{-1}),$$



$$\pi_2(\beta|\beta_0, \alpha_\beta) = \mathcal{N}^+ \left(\beta_0, \sigma_\beta^2 = \frac{\beta_0^2}{\alpha_\beta} \right)$$



On choisit $\tilde{\beta} = 3$ et on décale "à gauche" l'interv. de confiance pour η .

$$\pi_1(\eta|t, \alpha_\eta) = \mathcal{G} \left(\alpha_\eta, \alpha_\eta \frac{\Gamma(1 + 1/\tilde{\beta})}{t} \right),$$

$$\pi_2(\eta|t, \alpha_\eta) = \mathcal{N}^+ \left(\frac{t}{\Gamma(1 + 1/\tilde{\beta})}, \sigma_\eta^2 = \frac{t^2}{\alpha_\eta \Gamma^2(1 + 1/\tilde{\beta})} \right).$$

<i>Expertise</i>	intervalle (5%,95%)	valeur médiane	t	α_η	σ_η
EDF	(224,336)	280	252	60	36.4
Westinghouse	(112,560)	280	269	4.5	142.0





Conclusions

- Il existe des modélisations *a priori* permettant à l'expertise Westinghouse d'être cohérente avec les données (large variances pour β).
- On détecte toujours un conflit entre l'expertise EDF et les données.
- Modélisation *a priori* plus fine (conditionnelle)
- Présence très influente d'anciennes données \Rightarrow nécessité d'*a priori* "forts".

 \Rightarrow Pondérer l'expertise EDF, préciser l'origine des données.

Conclusions et problèmes de calibration

- 1 Un préalable à l'inférence subjective.
- 2 Un jugement de l'expert ou des données facilité.
- 3 Permet de d'utiliser et sélectionner des *a priori* raisonnables.
- 4 Ouvre une voie vers de nombreux problèmes de calibration.

- Lorsqu'on cherche à **calibrer** π sans information particulière sur l'expert, on propose de choisir π telle que

$$Coh(\pi|\mathbf{X}_n) = 1.$$

avec des contraintes **centrales** (ordre 1) sur π (reflétant l'avis quantitatif de l'expert).

⇒ **Compromis raisonnable biais-variance.**

- Candidats MIA (*posterior priors*) parfois encore **trop informatifs** ⇒ la règle peut rejeter des *a priori* moins informatifs.

⇒ pas intéressants pour le problème (n'apportent pas d'info *a posteriori*).

⇒ doivent être automatiquement acceptés.

Il faut définir une **quantité minimale d'information** (nb. ou fraction de données fictives, etc.).

- Exemple : on suppose qu'un expert ne peut pas apporter moins d'une **fraction $1/q$ d'information apportée par une donnée** où $q \in \mathbb{N}^*$.
- $\Leftrightarrow q$ informations minimales subjectives "valent" 1 donnée réelle.
- Le *posterior prior* correspondant serait alors

$$\pi(\theta) \propto \int \pi^J(\theta) [\mathcal{L}(X(I), \theta)]^{1/mq} g(X(I)) dX(I)$$

- $[\mathcal{L}(X(I), \theta)]^{1/mq}$ = **vraisemblance fictive**, où m est la taille des MTS du problème.