

BE Numéro 2: Méthodes probabilistes pour les problèmes inverses

Cours: Problèmes inverses Professeur: A. Mohammad-Djafari

Problème 1 : Dans un système d'imagerie, nous avons établi la relation $\mathbf{y} = \mathbf{A}\mathbf{x} + \boldsymbol{\epsilon}$ où

- \mathbf{y} est un vecteur contenant les projections (mesures) $\{y_m, m = 1 \dots, M\}$,
- $\boldsymbol{\epsilon}$ est un vecteur représentant les erreurs de mesures $\{\epsilon_m, m = 1 \dots, M\}$,
- \mathbf{x} est un vecteur représentant les pixels de l'image $\{x_n, n = 1 \dots, N\}$, et
- \mathbf{A} est une matrice dont les éléments $\{a_{mn}\}$ dépendent de la géométrie du système et sont supposés connus.

1. Supposons d'abord que $M = N$ et que la matrice \mathbf{A} soit inversible. Pourquoi la solution $\hat{\mathbf{x}}_0 = \mathbf{A}^{-1}\mathbf{y}$ n'est, en général, pas une solution satisfaisante ?

Quelle relation existe-t-il entre $\frac{\|\delta\hat{\mathbf{x}}_0\|}{\|\hat{\mathbf{x}}_0\|}$ et $\frac{\|\delta\mathbf{y}\|}{\|\mathbf{y}\|}$?

2. Revenons maintenant au cas général $M \neq N$. Montrez alors qu'on peut définir des solutions au sens des moindres carrés (MC), *i.e.* $\hat{\mathbf{x}}_1$ qui minimise

$$J_1(\mathbf{x}) = \|\mathbf{y} - \mathbf{A}\mathbf{x}\|^2$$

Montrer que, toute solution de l'équation $\mathbf{A}^t\mathbf{A}\mathbf{x} = \mathbf{A}^t\mathbf{y}$ est une solution au sens des moindres carrés du problème et lorsque $\mathbf{A}^t\mathbf{A}$ est inversible il existe une solution unique donnée par

$$\hat{\mathbf{x}}_1 = [\mathbf{A}^t\mathbf{A}]^{-1}\mathbf{A}^t\mathbf{y}$$

Quelle relation existe-t-il alors entre $\frac{\|\delta\hat{\mathbf{x}}_1\|}{\|\hat{\mathbf{x}}_1\|}$ et $\frac{\|\delta\mathbf{y}\|}{\|\mathbf{y}\|}$?

3. Une manière d'obtenir une solution régularisée $\hat{\mathbf{x}}_2$ à ce problème est de définir et de minimiser un critère de la forme

$$J_2(\mathbf{x}) = \|\mathbf{y} - \mathbf{A}\mathbf{x}\|^2 + \lambda\|\mathbf{D}\mathbf{x}\|^2,$$

où \mathbf{D} est une matrice approximant un opérateur linéaire de dérivation.

Montrer que cette solution s'écrit:

$$\hat{\mathbf{x}}_2 = \arg \min_{\mathbf{x}} \{J_2(\mathbf{x})\} = [\mathbf{A}^t\mathbf{A} + \lambda\mathbf{D}^t\mathbf{D}]^{-1}\mathbf{A}^t\mathbf{y}$$

Pourquoi cette solution est-elle préférable à $\hat{\mathbf{x}}_0$ et à $\hat{\mathbf{x}}_1$?

4. Supposons que \mathbf{A} et \mathbf{D} soient des matrices circulantes et symétriques. Dans ce cas montrer que la solution régularisée $\hat{\mathbf{x}}_2$ peut être obtenue à l'aide de la TFD (Transformée de Fourier Discrète). Plus précisément montrer la relation suivante:

$$X(\omega) = \frac{1}{H(\omega)} \frac{|H(\omega)|^2}{|H(\omega)|^2 + \lambda|D(\omega)|^2} Y(\omega)$$

où

- $H(\omega)$ est la TFD de la première ligne de la matrice \mathbf{A} ,
 - $D(\omega)$ est la TFD de la première ligne de la matrice \mathbf{D}
 - $X(\omega)$ est la TFD du vecteur solution $\hat{\mathbf{x}}_2$, et
 - $Y(\omega)$ est la TFD du vecteur de mesure \mathbf{y} .
5. Commenter les expressions de $\hat{\mathbf{x}}_2$ dans la question 3. et de $X(\omega)$ dans la question 4. lorsque $\lambda = 0$ et lorsque $\lambda \rightarrow \infty$.
 6. Dans une approche d'estimation au sens du maximum de vraisemblance (MV) supposons que le bruit $\boldsymbol{\epsilon}$ soit supposé blanc, centré et gaussien. Montrez que l'estimation au sens du MV de \mathbf{x} , *i.e.*;

$$\hat{\mathbf{x}}_{\text{MV}} = \arg \max_{\mathbf{x}} \{p(\mathbf{y}|\mathbf{x})\}$$

s'obtient en minimisant

$$J_1(\mathbf{x}) = \|\mathbf{y} - \mathbf{A}\mathbf{x}\|^2.$$

7. Quelle est l'expression de cet estimateur si ϵ est supposé suivre une loi gaussienne généralisée, *i.e.*;

$$\epsilon \sim p(\epsilon) \propto \exp[-\|\epsilon\|^\alpha] = \exp\left[-\sum_m |\epsilon_m|^\alpha\right], \quad 1 < \alpha \leq 2$$

8. Dans une approche bayésienne pour résoudre ce problème, supposons que l'on puisse attribuer des lois gaussiennes aux deux vecteurs ϵ et \mathbf{x} :

$$\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_\epsilon), \quad \mathbf{x} \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_X),$$

où $\mathbf{R}_\epsilon = \sigma_\epsilon^2 \mathbf{I}$ et $\mathbf{R}_X = \sigma_x^2 \mathbf{P}_0 = \sigma_x^2 (\mathbf{D}^t \mathbf{D})^{-1}$ sont les matrices de covariance de ϵ et de \mathbf{x} .
Ecrivez l'expression des lois $p(\mathbf{x}), p(\epsilon), p(\mathbf{y}, \mathbf{x})$ et $p(\mathbf{y}|\mathbf{x})$.

9. Montrer que la loi *a posteriori* $p(\mathbf{x}|\mathbf{y})$ est une loi gaussienne de la forme

$$p(\mathbf{x}|\mathbf{y}) \propto \exp\left[-\frac{1}{2} [[\mathbf{y} - \mathbf{A}\mathbf{x}]^t \mathbf{R}_\epsilon^{-1} [\mathbf{y} - \mathbf{A}\mathbf{x}] + \mathbf{x}^t \mathbf{R}_X^{-1} \mathbf{x}]\right]$$

10. Si on note $\hat{\mathbf{x}}_3$ la solution qui maximise $p(\mathbf{x}|\mathbf{y})$ (l'estimation au sens du maximum *a posteriori* MAP), montrer qu'elle s'obtient par

$$\hat{\mathbf{x}}_3 = \arg \min_{\mathbf{x}} \{J_3(\mathbf{x}) = [\mathbf{y} - \mathbf{A}\mathbf{x}]^t \mathbf{R}_\epsilon^{-1} [\mathbf{y} - \mathbf{A}\mathbf{x}] + \mathbf{x}^t \mathbf{R}_X^{-1} \mathbf{x}\}$$

11. Si $\mathbf{R}_\epsilon = \sigma_\epsilon^2 \mathbf{I}$ et $\mathbf{R}_X = \sigma_x^2 \mathbf{P}_0$, montrer que $\hat{\mathbf{x}}_3$ s'obtient par

$$\hat{\mathbf{x}}_3 = [\mathbf{A}^t \mathbf{A} + \lambda \mathbf{P}_0^{-1}]^{-1} \mathbf{A}^t \mathbf{y} \quad \text{avec} \quad \lambda = \frac{\sigma_\epsilon^2}{\sigma_x^2}$$

Que peut-on conclure en comparant les solutions $\hat{\mathbf{x}}_2$ et $\hat{\mathbf{x}}_3$?

12. En développant le terme

$$[[\mathbf{y} - \mathbf{A}\mathbf{x}]^t \mathbf{R}_\epsilon^{-1} [\mathbf{y} - \mathbf{A}\mathbf{x}] + \mathbf{x}^t \mathbf{R}_X^{-1} \mathbf{x}]$$

dans l'expression de $p(\mathbf{x}|\mathbf{y})$ montrer que l'on peut écrire

$$p(\mathbf{x}|\mathbf{y}) \propto \exp\left[-\frac{1}{2} [\mathbf{x} - \hat{\mathbf{x}}_3]^t \hat{\mathbf{P}}^{-1} [\mathbf{x} - \hat{\mathbf{x}}_3]\right]$$

Quelle est alors l'expression de la matrice de covariance *a posteriori* $\hat{\mathbf{P}}$?
Que représentent les éléments diagonaux de cette matrice?

13. Ecrivez l'expression des lois $p(x_n|\mathbf{y}), p(y_m|\mathbf{y})$ et $p(b_m|\mathbf{y})$. A qui peuvent-elle servir ?

14. Supposons maintenant la suite $\{x_1, \dots, x_N\}$ puissent être modélisée par une chaîne de Markov d'ordre un, c'est à dire :

$$p(x_n|x_1, \dots, x_N) = p(x_n|x_{n-1})$$

Peut-on calculer $p(\mathbf{x})$? Et si on connaît de plus $p(x_1)$?

Que devient alors la solution au sens du MAP ?

Etudiez cette solution dans les deux cas suivants:

$$p(x_n|x_1, \dots, x_N) = p(x_n|x_{n-1}) = \mathcal{N}(x_n - x_{n-1}, \sigma_x^2), \quad \text{et} \quad p(x_1) = \mathcal{N}(0, \sigma_x^2)$$

et

$$p(x_n|x_1, \dots, x_N) = p(x_n|x_{n-1}) \propto \exp[-\alpha \phi(x_n - x_{n-1})], \quad \text{et} \quad p(x_1) \propto \exp[-\alpha \phi(x_1)]$$

15. Supposons maintenant que $x_n > 0$ et que nous puissions faire l'hypothèse que les x_n suivent une lois Gamma :

$$p(x_n) = \frac{1}{Z(\alpha, \beta)} x_n^{-\alpha} \exp[-\beta x_n], \quad x_n > 0, \alpha > -1, \beta > 0, \quad Z(\alpha, \beta) = \frac{\Gamma(\alpha + 1)}{\beta^{\alpha+1}}$$

et que x_k et x_n sont indépendantes.

Que devient alors la solution au sens du MAP ?

Peut-on donner une expression explicite à cette solution ?

Comment peut-on calculer cette solution ?

16. Supposons maintenant que l'on nous donne \mathbf{x} et on nous demande d'estimer les paramètres (α, β) .
Considérons d'abord la méthode du maximum de vraisemblance (MV) :

$$(\hat{\alpha}, \hat{\beta}) = \arg \max_{(\alpha, \beta)} \{p(\mathbf{x}|\alpha, \beta)\}$$

Montrer que dans ce cas nous avons à résoudre le systèmes d'équations suivantes :

$$\begin{cases} -\frac{\partial \ln Z(\alpha, \beta)}{\partial \alpha} = \frac{1}{N} \sum_{n=1}^N \log x_n \\ -\frac{\partial \ln Z(\alpha, \beta)}{\partial \beta} = \frac{1}{N} \sum_{n=1}^N x_n \end{cases}$$

où

$$Z(\alpha, \beta) = \int x^\alpha \exp[-\beta x] dx,$$

Considérons ensuite la méthode des moments (MM) qui consiste à résoudre le système d'équations :

$$\begin{aligned} E\{X\} &= \int x p(x; \alpha, \beta) dx = \mu = \frac{1}{N} \sum_{n=1}^N x_n \\ E\{(X - m)^2\} &= \int (x - m)^2 p(x; \alpha, \beta) dx = v = \frac{1}{N} \sum_{n=1}^N (x_n - m)^2 \end{aligned}$$

Montrer qu'il y a une relation analytique entre (μ, v) et (α, β) qui est

$$\begin{cases} \mu = \frac{(1-\alpha)}{\beta} \\ v = \frac{(1-\alpha)}{\beta^2} \end{cases}, \begin{cases} \alpha = \frac{(v-\mu^2)}{v} \\ \beta = \frac{\mu}{v} \end{cases}$$

17. Supposons maintenant que nous voulons estimer à la fois \mathbf{x} et les paramètres $\boldsymbol{\theta} = (\alpha, \beta)$ à partir des données \mathbf{y} par la méthode du maximum de vraisemblance généralisée (MVG) :

$$(\hat{\mathbf{x}}, \hat{\boldsymbol{\theta}}) = \arg \max_{(\mathbf{x}, \boldsymbol{\theta})} \{p(\mathbf{x}, \boldsymbol{\theta}|\mathbf{y})\}$$

La maximisation conjointe par rapport à \mathbf{x} et $\boldsymbol{\theta}$ étant difficile, on peut envisager une optimisation (sous-optimal) par l'algorithme itératif suivant:

$$\begin{cases} \hat{\boldsymbol{\theta}}^{(k)} &= \arg \max_{\boldsymbol{\theta}} \{p(\hat{\mathbf{x}}^{(k)}, \boldsymbol{\theta}|\mathbf{y})\} \\ \hat{\mathbf{x}}^{(k+1)} &= \arg \max_{\mathbf{x}} \{p(\mathbf{x}, \hat{\boldsymbol{\theta}}^{(k)}|\mathbf{y})\} \end{cases}$$

Montrer que si on choisit $p(\boldsymbol{\theta})$ uniforme cet algorithm devient:

$$\begin{cases} \hat{\boldsymbol{\theta}}^{(k)} &= \arg \max_{\boldsymbol{\theta}} \{p(\hat{\mathbf{x}}^{(k)}|\boldsymbol{\theta})\} \\ \hat{\mathbf{x}}^{(k+1)} &= \arg \max_{\mathbf{x}} \{p(\mathbf{x}|\mathbf{y}, \hat{\boldsymbol{\theta}}^{(k)})\} \end{cases}$$

où dans l'étape 1 pour obtenir $\hat{\boldsymbol{\theta}}^{(k)} = (\hat{\alpha}^{(k)}, \hat{\beta}^{(k)})$ on aura à résoudre

$$\begin{cases} -\frac{\partial \ln Z(\alpha, \beta)}{\partial \alpha} = \frac{1}{N} \sum_{n=1}^N \log \hat{x}_n^{(k)} \\ -\frac{\partial \ln Z(\alpha, \beta)}{\partial \beta} = \frac{1}{N} \sum_{n=1}^N \hat{x}_n^{(k)} \end{cases}$$

et dans l'étape 2 on aura à trouver le minimum du critère

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{Ax}\|^2 + \lambda \sum_{n=1}^N \log x_n + \mu \sum_{n=1}^N x_n$$

avec $\lambda = \alpha\sigma_\epsilon^2$ et $\mu = \beta\sigma_\epsilon^2$.

Étudier la structure et les difficultés de la mise en œuvre de cet algorithme.

18. Supposons maintenant que nous voulons estimer d'abord les paramètres $\theta = (\alpha, \beta)$ à partir des données \mathbf{y} par la méthode du maximum de vraisemblance :

$$\hat{\theta} = \arg \max_{\theta} \{p(\mathbf{y}|\theta)\}$$

et ensuite l'utiliser pour l'estimation de \mathbf{x} .

Étudier l'algorithme EM pour l'estimation θ .

19. Revenons au problème de départ, mais cette fois, nous allons modéliser chaque pixel de l'image par un modèle de mélange de gaussiennes.

$$p(x_n) = \sum_{k=1}^K p(z_n = k) \mathcal{N}(m_k, \sigma_k^2) = \sum_{k=1}^K \alpha_k \mathcal{N}(m_k, \sigma_k^2)$$

avec z_n une variable qui prend des valeurs discrètes $1, 2, \dots, K$.

– Étudier, dans un premier temps l'estimation *supervisée* de $\theta = \{(\alpha_k, m_k, \sigma_k^2), k = 1, \dots, K\}$ à partir de l'observation directe de \mathbf{x} .

– Ensuite étudier l'estimation *non supervisée* de θ à partir de \mathbf{y} .

20. Modélisation hiérarchique: Dans la modélisation précédente, on peut remarquer que

$$x_n | z_n = k \sim \mathcal{N}(m_k, \sigma_k^2)$$

On peut alors construire la structure hiérarchique suivante :

$$\begin{aligned} \mathbf{y} | \mathbf{x} &\sim \mathcal{N}(\mathbf{A}\mathbf{x}, \sigma_\epsilon^2 \mathbf{I}) \\ x_n | z_n &\sim \mathcal{N}(m_k, \sigma_k^2) \\ z_n &\sim P(z_n = k) = \alpha_k \end{aligned}$$

– Montrez que la loi *a posteriori* $p(x_n | \mathbf{y})$ est aussi une loi de mélange de gaussienne

$$p(x_n | \mathbf{y}) = \sum_{k=1}^K \alpha_k \mathcal{N}(m_k, \sigma_k^2)$$

– Exprimer $(\alpha_k, m_k, \sigma_k^2)$ en fonction de des données \mathbf{y} et $(\alpha_k, m_k, \sigma_k)$ et proposez un algorithme d'estimation pour $x_n | \mathbf{y}$.

– Trouvez l'expression de $P(z_n = k | \mathbf{y})$ et proposez un algorithme de classification (estimation de $z_n | \mathbf{y}$).

– Étudiez la structure d'un algorithme d'estimation hiérarchique du type itératif

$$\begin{cases} \hat{\mathbf{z}}^{(k)} &= \arg \max_{\mathbf{z}} \{p(\mathbf{z} | \mathbf{y}, \hat{\mathbf{x}}^{(k-1)})\} \\ \hat{\mathbf{x}}^{(k+1)} &= \arg \max_{\mathbf{x}} \{p(\mathbf{x} | \mathbf{y}, \hat{\mathbf{z}}^{(k)})\} \end{cases}$$

ou

$$\hat{\mathbf{z}} = \arg \max_{\mathbf{z}} \{p(\mathbf{z} | \mathbf{y})\} \longrightarrow \hat{\mathbf{x}} = \arg \max_{\mathbf{x}} \{p(\mathbf{x} | \mathbf{y}, \hat{\mathbf{z}})\}$$

tout en notant que $\hat{\mathbf{z}} = \arg \max_{\mathbf{z}} \{p(\mathbf{z} | \mathbf{y})\}$ ne peut se faire que d'une manière itérative par l'algorithme EM.

– Comparer le coût de calcul de chacun de ces deux algorithmes.

Problème 2 : Considérons maintenant le problème sans bruit $\mathbf{y} = \mathbf{A}\mathbf{x}$.

- Supposons que nous savons que \mathbf{x} représente une quantité positive. Nous cherchons alors une solution positive à ce problème. L'outil "entropie" peut alors être utilisé. Considérons le problème d'optimisation suivant :

$$\max \left(- \sum_{n=1}^N x_n \log x_n + \sum_{n=1}^N x_n \right) \text{ sous les contraintes } y_m = \sum_{n=1}^N a_{m,n} x_n, \quad m = 1, \dots, M.$$

En utilisant le Lagrangien

$$\mathcal{L} = - \sum_{n=1}^N x_n \log x_n + \sum_{n=1}^N x_n + \sum_{m=1}^M \lambda_m \left(y_m - \sum_{n=1}^N a_{m,n} x_n \right)$$

montrer que ce problème admet une solution unique (lorsqu'elle existe) qui est de la forme

$$x_n = \exp \left[- \sum_{m=1}^M a_{m,n} \lambda_m \right],$$

où $\{\lambda_m, m = 1, \dots, M\}$ sont solution du système d'équations

$$y_m = \sum_{n=1}^N a_{m,n} \exp \left[- \sum_{m=1}^M a_{m,n} \lambda_m \right].$$

Interpréter cette solution. Proposez un algorithme pour le calculer.

- Considérons maintenant que \mathbf{x} représente une image moyenne, *i.e.* chaque x_n correspond à l'espérance d'une grandeur $Z_n > 0$. Supposons que le vecteur aléatoire \mathbf{Z} admet une densité de probabilité $p_z(\mathbf{z})$. Les mesures y_m peuvent alors être considérées comme une combinaison linéaire de $E\{Z_n\}$, *i.e.*

$$\mathbf{y} = \mathbf{A}\mathbf{x} \longrightarrow y_m = \sum_{n=1}^N a_{m,n} x_n = \sum_{n=1}^N a_{m,n} E\{Z_n\}, \quad m = 1, \dots, M.$$

On cherchera alors la densité de probabilité $p(\mathbf{z})$ qui satisfait ces contraintes et qui maximise

$$- \int p(\mathbf{z}) \log \left(\frac{p(\mathbf{z})}{\mu(\mathbf{z})} \right) d\mathbf{z}.$$

Pour cela il faut définir le Lagrangien

$$\mathcal{L} = - \int p(\mathbf{z}) \log \left(\frac{p(\mathbf{z})}{\mu(\mathbf{z})} \right) d\mathbf{z} - \sum_{m=1}^M \lambda_m \left(y_m - \sum_{n=1}^N a_{m,n} \int z_n p(\mathbf{z}) d\mathbf{z} \right)$$

et le dériver par rapport à p .

- Montrer alors que $p(\mathbf{x})$ est de la forme

$$p(\mathbf{x}) \propto \mu(\mathbf{z}) \exp \left[\sum_{m=1}^M \lambda_m \sum_{n=1}^N a_{m,n} z_n \right]$$

- Montrer ensuite que lorsque $\mu(\mathbf{z})$ est séparable, *i.e.*; $\mu(\mathbf{z}) = \prod_{j=1}^N \mu(z_n)$, alors $p(\mathbf{z})$ l'est aussi et si $\mu(z_n) \propto \exp \left[-\frac{1}{2} z_n^2 \right]$ on a

$$p(\mathbf{z}) = \prod_{j=1}^N p(z_n) \text{ avec } p(z_n) \propto \exp \left[-\frac{1}{2} z_n^2 + \sum_{m=1}^M a_{m,n} \lambda_m z_n \right],$$

- Notant maintenant que $x_n = E\{Z_n\}$. Montrez que x_n est de la forme

$$x_n = \sum_{m=1}^M a_{m,n} \lambda_m, \quad \text{ou encore } \mathbf{x} = \mathbf{A}^t \boldsymbol{\lambda}$$

où $\{\lambda_m\}$ sont solution de

$$y_m = \sum_{n=1}^N a_{m,n} \sum_{m=1}^M a_{m,n} \lambda_m, \quad \text{ou encore } \mathbf{y} = \mathbf{A} \mathbf{A}^t \boldsymbol{\lambda}$$

ce qui permet d'écrire

$$\mathbf{x} = \mathbf{A}^t (\mathbf{A} \mathbf{A}^t)^{-1} \mathbf{y}$$

Interpréter cette solution.

- Que deviennent \mathbf{x} si $\mu(z_n) \propto \exp[-z_n]$, $z_n > 0$?
Pour cela montrer que

$$p(z_n) \propto \exp \left[-z_n - \sum_{m=1}^M a_{m,n} \lambda_m z_n \right], \quad z_n > 0$$

et par conséquent

$$x_n = 1 + \sum_{m=1}^M a_{m,n} \lambda_m, \quad \text{ou encore } \mathbf{x} = \mathbf{1} + \mathbf{A}^t \boldsymbol{\lambda}$$

où $\{\lambda_m\}$ sont solution du système d'équations

$$y_m = \sum_{n=1}^N a_{m,n} (1 + \sum_{i=1}^M a_{m,n} \lambda_m), \quad \text{ou encore } \mathbf{y} = \mathbf{A} \mathbf{1} + \mathbf{A} \mathbf{A}^t \boldsymbol{\lambda},$$

ce qui permet d'écrire (supposons que $\mathbf{A} \mathbf{A}^t$ est inversible)

$$\mathbf{x} = \mathbf{1} + \mathbf{A}^t [\mathbf{A} \mathbf{A}^t]^{-1} (\mathbf{y} - \mathbf{A} \mathbf{1}) = \mathbf{A}^t [\mathbf{A} \mathbf{A}^t]^{-1} \mathbf{y} + (\mathbf{I} - \mathbf{A}^t [\mathbf{A} \mathbf{A}^t]^{-1} \mathbf{A}) \mathbf{1}$$

Interpréter alors ce resultat.

- Que deviennent \mathbf{x} si $\mu(z_n) \propto z_n^{(\alpha-1)}$, $z_n > 0$?
Pour cela montrer que

$$p(z_n) \propto \exp \left[(\alpha - 1) \log z_n - \sum_{m=1}^M a_{m,n} \lambda_m z_n \right], \quad z_n > 0$$

qui est une loi *Gamma*(α, β) avec $\beta = \sum_{m=1}^M a_{m,n} \lambda_m$ et par conséquent

$$x_n = E\{Z_n\} = \frac{\alpha}{\beta} = \frac{\alpha}{\sum_{m=1}^M a_{m,n} \lambda_m},$$

où $\{\lambda_m\}$ sont solution du système d'équations

$$y_m = \sum_{n=1}^N a_{m,n} \frac{\alpha}{\sum_{m=1}^M a_{m,n} \lambda_m}$$

ce qui permet d'écrire (symboliquement ou avec les notations Matlab)

$$\begin{aligned} \mathbf{x} &= \frac{\alpha}{\mathbf{A}^t \boldsymbol{\lambda}} & \text{ou encore} & \quad \mathbf{x} = \alpha \mathbf{1} ./ \mathbf{A}^t \boldsymbol{\lambda} \\ \mathbf{y} &= \mathbf{A} \frac{\alpha}{\mathbf{A}^t \boldsymbol{\lambda}} & \text{ou encore} & \quad \mathbf{y} = \mathbf{A} (\alpha \mathbf{1} ./ \mathbf{A}^t \boldsymbol{\lambda}) = \alpha (\mathbf{A} \mathbf{1}) ./ (\mathbf{A}^t \boldsymbol{\lambda}) \end{aligned}$$

Interpréter alors ce resultat.

- Que deviennent \mathbf{x} si $\mu(z_n) \propto z_n^{(\alpha-1)} \exp[\beta z_n]$, $z_n > 0$?