

## DEVOIR II POUR LE 13 NOVEMBRE

**Exercice 1** (FILTRAGE DE KALMAN)

Un avion se déplace entre Paris et Londres, en tentant de suivre une trajectoire théorique définie par le plan de vol. L'avion est surveillé au sol par des contrôleurs aériens grâce à un radar qui reçoit un écho de l'avion à intervalles réguliers. La trajectoire effective de l'avion s'écarte de la trajectoire théorique pour de multiples raisons (météorologie, imprécision du pilote automatique, turbulences,...). On cherche donc à localiser l'avion au cours de son vol à partir des observations radars successives. On note  $X_n$  l'écart (inconnu) entre la trajectoire théorique et la position de l'avion au temps  $n$ . De plus, on note  $Y_n$  la mesure donnée par le radar au temps  $n$ . Cette mesure est entachée d'erreurs à cause de l'imprécision du radar. Le problème qui se pose à l'aiguilleur est d'estimer au mieux la position de l'avion au temps  $n$  au vu des observations  $Y_0, \dots, Y_n$ . Pour simplifier l'étude, on supposera que l'objet observé évolue dans un espace de dimension 1.

On modélise les suites aléatoires  $(X_n)_{n \geq 0}$  et  $(Y_n)_{n \geq 0}$  en posant

$$\begin{cases} X_0 = W_0, \\ X_n = aX_{n-1} + W_n & n \geq 1 \\ Y_n = X_n + V_n & n \geq 0 \end{cases}$$

où  $a$  est un nombre réel déterministe modélisant l'action du pilote,  $(V_n)_{n > 0}$  et  $(W_n)_{n > 0}$  sont des suites aléatoires indépendantes, avec  $(V_n)_{n > 0} \sim_{i.i.d.} \mathcal{N}(0, \tau^2)$  et  $(W_n)_{n > 0} \sim_{i.i.d.} \mathcal{N}(0, \sigma^2)$ . Les variables aléatoires  $(W_n)_{n > 0}$  représentent les fluctuations instantanées de l'écart entre position théorique et position réelle. Les variables aléatoires  $(V_n)_{n > 0}$  modélisent les erreurs de mesure du radar. Le paramètre  $a$  modélise l'action du pilote. En théorie du signal, on dit que  $(X_n)_{n > 0}$  est un processus autorégressif d'ordre 1, noté AR(1), à bruit gaussien, et on a

$$X_n = \sum_{k=0}^n a^k W_{n-k} = \sum_{k=0}^n a^{n-k} W_k, n \in \mathbb{N}.$$

À présent, le problème est d'estimer  $X_n$  sachant les observations  $Y_0, \dots, Y_n$ . Le candidat naturel est l'espérance conditionnelle  $\mathbb{E}(X_n | Y_0, \dots, Y_n)$ .

1. Que peut-on dire du vecteur aléatoire  $(X_0, \dots, X_n, Y_0, \dots, Y_n)$  ?

**Solution 1 .** C'est un vecteur gaussien car image du vecteur trivialement gaussien

$$\begin{pmatrix} W_0 & \dots & W_n & \vdots & V_0 & \dots & V_n \end{pmatrix}^T$$

par la transformation linéaire de matrice

$$\begin{pmatrix} \mathbf{T} & \vdots & \mathbf{0}_n \\ \dots & & \dots \\ \mathbf{T} & \vdots & \mathbf{Id}_n \end{pmatrix}$$

avec  $\mathbf{T}$  matrice de Toeplitz triangulaire inférieure dont la première colonne est donnée par  $1, a, \dots, a^n$ .

2. Vérifier la formule de Bayes pour le calcul des densités conditionnelles. Si la loi  $P$  du vecteur aléatoire  $(X, Y_0, \dots, Y_{n-1})$  admet une densité jointe  $p$ , alors presque partout :

$$p(x_n | y_0, \dots, y_{n-1}, y_n) = \frac{p(x_n, y_n | y_0, \dots, y_{n-1})}{p(y_n | y_0, \dots, y_{n-1})}$$

**Solution 2 .** On suppose dans la suite que les versions des densités conditionnelles considérées sont calculées à partir d'une même version de la densité jointe. Idem pour les densités marginales.

On considère un tuple où la densité jointe

$$\begin{aligned}
 p(x_n | y_0, \dots, y_n) &= \frac{p(x_n, y_0, \dots, y_n)}{p(y_0, \dots, y_n)} \\
 &= \frac{p(x_n, y_0, \dots, y_n)}{p(y_n | y_0, \dots, y_{n-1})p(y_0, \dots, y_{n-1})} \\
 &= \frac{p(x_n, y_0, \dots, y_n)}{p(y_0, \dots, y_{n-1})} \times \frac{1}{p(y_n | y_0, \dots, y_{n-1})} \\
 &= \frac{p(x_n, y_n | y_0, \dots, y_{n-1})}{p(y_n | y_0, \dots, y_{n-1})}.
 \end{aligned}$$

3. Vérifier que si  $(X, Y_0, \dots, Y_{n-1})$  est un vecteur gaussien dans  $\mathbb{R}^{n+1}$  tel que

$$\text{Loi}(X|Y_0, \dots, Y_{n-1}) = \mathcal{N}(\mu, \gamma^2) \quad \text{Loi}(Y|Y_0, \dots, Y_{n-1}, X) = \mathcal{N}(X, \delta^2),$$

alors

$$\text{Loi}(X|Y_0, \dots, Y_{n-1}, Y) = \mathcal{N}\left(\rho^2 \left(\frac{\mu}{\gamma^2} + \frac{Y}{\delta^2}\right), \rho^2\right), \quad \frac{1}{\rho^2} := \frac{1}{\gamma^2} + \frac{1}{\delta^2}.$$

**Solution 3 .** Conditionnellement à  $Y_0, \dots, Y_{n-1}$ , la loi de  $(X, Y)^T$  est

$$\mathcal{N}\left(\begin{pmatrix} \mu \\ \mu \end{pmatrix}, \begin{pmatrix} \gamma^2 & \gamma^2 \\ \gamma^2 & \gamma^2 + \delta^2 \end{pmatrix}\right).$$

L'énoncé nous indique que  $X$  est indépendant de  $Y_0, \dots, Y_{n-1}$  et que conditionnellement à  $X$ ,  $Y$  est indépendant de  $Y_0, \dots, Y_{n-1}$ .

La loi conditionnelle de  $X$  sachant  $Y$  est gaussienne d'espérance

$$\mu + \frac{\gamma^2}{\gamma^2 + \delta^2}(Y - \mu) = \rho^2 \left(\frac{\mu}{\gamma^2} + \frac{Y}{\delta^2}\right)$$

et de variance

$$\gamma^2 - \gamma^2 \frac{1}{\gamma^2 + \delta^2} \gamma^2 = \frac{\gamma^2 \delta^2}{\gamma^2 + \delta^2} = \rho^2$$

voir section 2.5 dans les notes du cours.

On retrouve les expressions classiques en inférence bayésienne.

4. On souhaite montrer que la loi conditionnelle de  $X_n$  sachant  $Y_0, \dots, Y_n$  est une loi normale  $\mathcal{N}(\tilde{X}_n, P_n)$  où

$$\tilde{X}_n = a\tilde{X}_{n-1} + \frac{P_n}{\tau^2}(Y_n - a\tilde{X}_{n-1}), \quad P_n = \frac{a^2\tau^2 P_{n-1} + \sigma^2\tau^2}{a^2 P_{n-1} + \sigma^2 + \tau^2}.$$

On propose de le faire par récurrence en deux étapes.

a) Initialisation : caractériser la loi de  $X_0$  conditionnellement à  $Y_0$ .

**Solution 4 .** Nous sommes dans le contexte de la question précédente avec

$$\gamma^2 = \sigma^2 \quad \text{et} \quad \delta^2 = \tau^2.$$

La loi jointe de  $(X_0, Y_0)^T$  est

$$\mathcal{N}\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \sigma^2 & \sigma^2 \\ \sigma^2 & \sigma^2 + \tau^2 \end{pmatrix}\right).$$

La loi de  $X_0$  sachant  $Y_0$  est donc

$$\mathcal{N}\left(\frac{\sigma^2}{\tau^2 + \sigma^2} Y_0, \frac{\sigma^2 \tau^2}{\sigma^2 + \tau^2}\right)$$

On peut convenir de  $\tilde{X}_{-1} = X_{-1} = 0$ ,  $P_{-1} = 0$  et on a alors

$$\begin{aligned}
 P_0 &= \frac{a^2 P_{-1} \sigma^2 + \sigma^2 \tau^2}{a^2 P_{-1} + \sigma^2 + \tau^2} \\
 \tilde{X}_0 &= a \times \tilde{X}_{-1} + \frac{P_0}{\tau^2} (Y_0 - a\tilde{X}_{-1})
 \end{aligned}$$

- b) Prédiction : à partir de la loi de  $X_{n-1}$  sachant  $Y_0, \dots, Y_{n-1}$ , en déduire la loi de  $X_n$  sachant  $Y_0, \dots, Y_{n-1}$ .

**Solution 5 .** (Prédiction) On procède par récurrence sur  $n$ . On veut établir que la loi conditionnelle de  $X_{n+1}$  sachant  $Y_0, \dots, Y_n$  est gaussienne d'espérance

$$a\mathbb{E}[X_n | Y_0, \dots, Y_n]$$

et de variance

$$\sigma^2 + a^2 \text{var}(X_n | Y_0, \dots, Y_n).$$

Il suffit de noter

$$\begin{aligned} \mathbb{E}[X_{n+1} | Y_0, \dots, Y_n] &= \mathbb{E}[aX_n + W_n | Y_0, \dots, Y_n] \\ &= a\mathbb{E}[X_n | Y_0, \dots, Y_n] + \mathbb{E}[W_n | Y_0, \dots, Y_n] \\ &= a\mathbb{E}[X_n | Y_0, \dots, Y_n] + \mathbb{E}W_n \\ &= a\mathbb{E}[X_n | Y_0, \dots, Y_n]. \end{aligned}$$

$$\begin{aligned} \text{var}(X_{n+1} | Y_0, \dots, Y_n) &= \text{var}(aX_n + W_n | Y_0, \dots, Y_n) \\ &= \text{var}(aX_n | Y_0, \dots, Y_n) + \text{var}(W_n | Y_0, \dots, Y_n) \\ &= a^2 \text{var}(X_n | Y_0, \dots, Y_n) + \text{var}(W_n) \\ &= a^2 \text{var}(X_n | Y_0, \dots, Y_n) + \sigma^2. \end{aligned}$$

- c) Filtrage : déterminer la loi de  $X_n$  sachant  $Y_0, \dots, Y_n$ .

**Solution 6 .** On procède par récurrence sur  $n$ . Le cas de base  $n = 0$  est traité en réponse au a).

On suppose que l'hypothèse de récurrence est vérifiée jusqu'au rang  $n$ . On invoque la réponse à la question 3 avec

$$\begin{aligned} \mu &= \mathbb{E}[X_{n+1} | Y_0, \dots, Y_n] \\ &= a\mathbb{E}[aX_n | Y_0, \dots, Y_n] \\ &= a\tilde{X}_n \end{aligned}$$

et  $\gamma^2 = a^2 \text{var}(\tilde{X}_n | Y_0, \dots, Y_n) + \sigma^2 = a^2 P_n + \sigma^2$ . Et la variance conditionnelle de  $Y_{n+1}$  sachant  $X_{n+1}, Y_0, \dots, Y_n$  est  $\tau^2$ . On peut donc convenir de  $\delta^2 = \tau^2$ .

Conditionnellement à  $Y_0, \dots, Y_n, Y_{n+1}$ , la variable  $X_n$  est distribuée selon une gaussienne de variance  $P_{n+1} = \rho^2$  avec

$$\begin{aligned} \frac{1}{\rho^2} &= \frac{1}{\tau^2} + \frac{1}{a^2 P_n + \sigma^2} \\ &= \frac{a^2 P_n + \sigma^2 + \tau^2}{\tau^2(a^2 P_n + \sigma^2)} \end{aligned}$$

et d'espérance

$$\begin{aligned} \tilde{X}_{n+1} &= P_{n+1} \left( \frac{a\tilde{X}_n}{a^2 P_n + \sigma^2} + \frac{Y_{n+1}}{\tau^2} \right) \\ &= P_{n+1} \left( \left( \frac{1}{P_{n+1}} - \frac{1}{\tau^2} \right) a\tilde{X}_n + \frac{Y_{n+1}}{\tau^2} \right) \\ &= a\tilde{X}_n + \frac{P_{n+1}}{\tau^2} (Y_{n+1} - a\tilde{X}_n). \end{aligned}$$

Ceci termine l'argument de récurrence.

5. Comparer  $\mathbb{E} \left[ (\tilde{X}_n - X_n)^2 \right]$  et  $\mathbb{E} \left[ (\mathbb{E}[X_n | Y_n] - X_n)^2 \right]$ .

**Solution 7 .** L'inclusion des tribus conditionnantes implique

$$\mathbb{E} \left[ (\tilde{X}_n - X_n)^2 \right] \leq \mathbb{E} \left[ (\mathbb{E}[X_n | Y_n] - X_n)^2 \right].$$

Le membre gauche vaut  $P_n$ , le membre droit vaut  $\tau^2 / (\tau^2 + \sigma^2(1 - a^{2(n+1)}) / (1 - a^2))$

(aller plus loin : conditionnement et filtre de Kalman) cf. Chafai-Malrieu, section 7.2

Dans l'exercice suivant, il est question de la borne de Cramer-Rao. Dans sa forme la plus simple, cette borne stipule que la variance d'un estimateur sans biais est au moins aussi grande que l'inverse de l'information de Fisher. Cette borne est vérifiée dans les modèles exponentiels de dimension 1 (entre autres).

**Exercice 2** Dans cet exercice,  $\begin{pmatrix} X \\ Y \end{pmatrix}$  est un vecteur Gaussien d'espérance  $\mu = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}$  et de covariance connue  $C = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$ . L'objectif est d'estimer  $\theta_1$ . On dispose de  $n$  tirages indépendants distribués selon  $\mathcal{N}(\mu, C) : \begin{pmatrix} X_1 \\ Y_1 \end{pmatrix}, \dots, \begin{pmatrix} X_n \\ Y_n \end{pmatrix}$ .

Dans le scenario 1,  $\theta_2$  est connu du statisticien, dans le scenario 2,  $\theta_2$  n'est pas connu (c'est un paramètre de nuisance par opposition à  $\theta_1$  qui est un paramètre d'intérêt).

- i) Proposer un estimateur de  $\theta_1$  au maximum de vraisemblance dans le scenario 1. Est-il biaisé? Quel est son risque quadratique?

**Solution 8.** Dans ce scenario, comme  $\theta_2$  est connue, la loi de  $Y$  est connue. On peut considérer la loi de  $X$  conditionnellement à  $Y$ . C'est une loi Gaussienne dont la densité est explicitement connue (voir cours), c'est la loi des résidus lorsqu'on cherche à prédire  $X$  à partir de  $Y$ , c'est à dire  $\mathcal{N}(\theta_1 + \rho\sigma_1/\sigma_2(y - \theta_2), \sigma_1^2 - \rho^2\sigma_1^2\sigma_2^2/\sigma_2^2) = \mathcal{N}(\theta_1 + \rho\sigma_1/\sigma_2(y - \theta_2), \sigma_1^2(1 - \rho^2))$ .

La variance de  $X$  sachant  $Y$  n'est autre que le complément de Schur de  $\sigma_2^2$  dans  $C$ , c'est la variance de  $X$  ( $\sigma_1^2$ ) diminuée de la variance dite expliquée  $\rho^2\sigma_1^2$ .

Si on écrit la log-vraisemblance, dans le scenario 1, pour une observation, on obtient

$$\ell(\theta_1) = -\frac{1}{2} \log(2\pi\sigma_1^2(1 - \rho^2)) - \frac{(x - \theta_1 - \rho\sigma_1/\sigma_2(y - \theta_2))^2}{2\sigma_1^2(1 - \rho^2)}.$$

Ceci conduit à

$$\hat{\theta}_1 = x - \rho\sigma_1/\sigma_2(y - \theta_2)$$

et pour un  $n$ -échantillon à

$$\hat{\theta}_1 = \bar{X}_n - \rho\sigma_1/\sigma_2(\bar{Y}_n - \theta_2).$$

Cet estimateur linéaire est sans biais, gaussien de variance  $\frac{\sigma_1^2(1 - \rho^2)}{n}$ .

- ii) Proposer un estimateur de  $\theta_1$  au maximum de vraisemblance dans le scenario 2. Est-il biaisé? Quel est son risque quadratique?

**Solution 9.** Si on écrit la log-vraisemblance, dans le scenario 2, pour un  $n$ -échantillon, on obtient

$$\ell(\theta_1, \theta_2) = -\frac{1}{2} \log((2\pi)^2 \sigma_1^2 \sigma_2^2 (1 - \rho^2)) - \frac{1}{2} (\bar{X}_n - \theta_1 \quad \bar{Y}_n - \theta_2) C^{-1} \begin{pmatrix} \bar{X}_n - \theta_1 \\ \bar{Y}_n - \theta_2 \end{pmatrix}.$$

L'estimateur au maximum de vraisemblance est

$$\begin{pmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{pmatrix} = \begin{pmatrix} \bar{X}_n \\ \bar{Y}_n \end{pmatrix}$$

Cet estimateur est lui aussi linéaire, gaussien, sans biais de covariance,  $\frac{1}{n}C$ . L'estimateur de  $\theta_1$  est donc sans biais, gaussien, de covariance  $\sigma_1^2/n$ . On n'utilise pas  $Y_1, \dots, Y_n$  pour estimer  $\theta_1$ .

- iii) Calculer l'information de Fisher dans les deux scenarios. Les deux estimateurs réalisent-ils la borne de Cramer-Rao?

**Solution 10.** Dans les deux modèles, l'information de Fisher est l'inverse de la covariance, les deux estimateurs réalisent la borne de Cramer-Rao.

- iv) Comparer les risques des deux estimateurs. Le paramètre  $\theta_2$  est-il vraiment une nuisance?

**Solution 11.** Les risques quadratiques sont  $(1 - \rho^2)\sigma_1^2$  et  $\sigma_1^2$ . Le paramètre  $\theta_2$  est bien un paramètre de nuisance (sauf bien sûr si  $\rho = 0$ , c'est-à-dire si  $X$  et  $Y$  sont indépendantes).