

Introduction aux processus stochastiques

Examen 2e session — 2007

Durée : 3h30.

Pas de gsm ni de calculatrice.

1 Chaînes de Markov

Suites et sous-suites de nombres.

Soit une chaîne de Markov invariante dans le temps définie sur 5 états.

La chaîne a une distribution initiale π et une matrice de transition Π .

Soit X_t la séquence des états de la chaîne, $t = 1, 2, \dots$

En notant les numéros correspondant aux 10 premiers états réalisés de la chaîne, on obtient une suite de 10 nombres X_1, \dots, X_{10} , avec $1 \leq X_t \leq 5$. On demande :

1. La probabilité que le dernier nombre soit 2.
2. La probabilité de l'événement "Le 7e nombre est impair."

Ensuite, on considère une seconde suite Y_1, \dots, Y_{10} de 10 nombres, obtenue en extrayant des 20 premiers états X_1, \dots, X_{20} de la chaîne ceux des instants pairs. Autrement dit,

$$Y_1 = X_2, Y_2 = X_4, \dots, Y_{10} = X_{20}.$$

On demande, pour la suite des Y :

3. La probabilité de l'événement "Le 3e nombre est 4 et le 6e est strictement inférieur à 3."

Enfin, on considère une troisième suite de 10 nombres Z_1, \dots, Z_{10} obtenue en notant uniquement les états 2, 3, 4, 5 de la suite des états de la chaîne X_1, X_2, \dots

Ainsi on a $2 \leq Z_t \leq 5$, et la chaîne de Markov doit effectuer des transitions jusqu'à ce que la suite des Z compte 10 éléments.

Par exemple, au départ de 1 4 3 5 4 4 2 1 1 3 1 3 2 1 5 on tire la suite 4 3 5 4 4 2 3 3 2 5.

On demande :

4. De montrer que la suite des Z peut être obtenue en notant la séquence des états d'une chaîne de Markov invariante dans le temps (π', Π') . Pour ce faire, donner la distribution initiale π' et la matrice de transition Π' en fonction de π et Π .

Travailler élément par élément si nécessaire (i.e. définir π'_i et Π'_{ij} pour $1 \leq i, j \leq 5$.)

2 Chaînes de Markov cachées

Inférence à partir d'observations d'état bruitées.

Soit une chaîne de Markov cachée invariante dans le temps (π, Π, Σ) à 3 états S_1, S_2, S_3 et 3 observations possibles E_1, E_2, E_3 .

On note \mathcal{X}_t la séquence des états cachés et \mathcal{Y}_t la séquence des observations, pour $t = 1, 2, \dots, N$.

Pour rappel,

$$\pi_i = P(\mathcal{X}_1 = S_i) \quad \Pi_{ij} = P(\mathcal{X}_{t+1} = S_j | \mathcal{X}_t = S_i) \quad \Sigma_{ij} = P(\mathcal{Y}_t = E_j | \mathcal{X}_t = S_i).$$

On considère le cas particulier

$$\pi = [1 \quad 1 \quad 1] / 3 \quad \Pi = \begin{bmatrix} .7 & .3 & 0 \\ 0 & .9 & .1 \\ .4 & 0 & .6 \end{bmatrix} \quad \Sigma = \begin{bmatrix} .8 & .1 & .1 \\ .1 & .8 & .1 \\ .1 & .1 & .8 \end{bmatrix}.$$

On dispose d'une séquence $Y_1 Y_2 \dots Y_N$ d'observations, où chaque $Y_i \in \{E_1, E_2, E_3\}$.

On considère le cas particulier où $N = 3$ et la séquence observée est

$$E_3 \ E_2 \ E_1.$$

Autrement dit, on a $Y_1 = E_3, Y_2 = E_2$ et $Y_3 = E_1$.

Dans les questions qui viennent, la résolution numérique n'est pas demandée.

1. Dessiner le diagramme de transition d'états de la chaîne de Markov (π, Π) .
2. Dessiner le réseau bayésien de la chaîne de Markov cachée (π, Π, Σ) pour les 3 premiers instants.
3. *Propagation α /Estimation d'état.*
Calculer de façon efficace les probabilités $P(\mathcal{X}_N = S_i | \mathcal{Y}_1 = Y_1, \dots, \mathcal{Y}_N = Y_N)$, pour $i \in \{1, 2, 3\}$ et $N = 3$.
En notation abrégée, la question revient à demander $P(\mathcal{X}_N | Y_1 \dots Y_N)$ pour $N = 3$.
Suggestion : se ramener au calcul de $P(\mathcal{X}_t = S_i, \mathcal{Y}_1 = Y_1, \dots, \mathcal{Y}_t = Y_t)$, c'est-à-dire en notation abrégée $P(\mathcal{X}_t, Y_1 \dots Y_t)$, pour t valant successivement 1, 2, 3.
4. *Propagation β /Filtrage.*
Calculer de façon efficace $P(\mathcal{X}_t | Y_1 \dots Y_N)$ pour $t = 1$ et $t = 2$.
Suggestion : se ramener au calcul de $P(\mathcal{Y}_{t+1} = Y_{t+1}, \dots, \mathcal{Y}_N = Y_N | \mathcal{X}_t = S_i)$, c'est-à-dire $P(Y_{t+1} \dots Y_N | \mathcal{X}_t)$, et exploiter le calcul de $P(\mathcal{X}_t, Y_1 \dots Y_t)$ du point précédent.
5. *Prédiction.*
Calculer $P(\mathcal{X}_t | Y_1 \dots Y_N)$ pour $N = 3$ et $t \in \{4, 5\}$.
6. Supposer à présent qu'on n'observe que $Y_1 = E_3$ et $Y_3 = E_1$.
Calculer $P(\mathcal{X}_2 | Y_1, Y_3)$.
Suggestion : Modifier les algorithmes de propagation établis aux points précédents.

3 Estimation statique

Cascade de senseurs.

Soit x un vecteur source de dimension n , distribué selon $\mathcal{N}(\bar{x}, \Sigma_x)$.
Soit $y = Cx + v$ un premier vecteur de senseurs de dimension m_y ,
Soit $z = Fx + Gy + w$ un second vecteur de senseurs de dimension m_z .
Le vecteur de bruit v suit une normale $\mathcal{N}(0, V)$, le vecteur de bruit w suit une normale $\mathcal{N}(0, W)$.
Les vecteurs x, v, w sont mutuellement indépendents.
On demande de déterminer :

1. L'estimateur $\hat{x}_{(1)} = \mathbf{E}\{x|y\}$
et l'espérance de l'erreur quadratique d'estimation $\mathbf{E}\{\|(x - \hat{x}_{(1)})\|^2\}$.
2. L'estimateur $\hat{x}_{(2)} = \mathbf{E}\{x|y, z\}$
et l'espérance de l'erreur quadratique d'estimation $\mathbf{E}\{\|(x - \hat{x}_{(2)})\|^2\}$.
3. L'estimateur $\hat{z} = \mathbf{E}\{z|y\}$
et l'espérance de l'erreur quadratique d'estimation $\mathbf{E}\{\|(z - \hat{z})\|^2\}$.

Solutions

Suites et sous-suites de nombres.

1. La probabilité que le dernier nombre soit 2 :

$$\pi \Pi^9 [0 \ 1 \ 0 \ 0 \ 0]^T.$$

2. La probabilité de l'événement "Le 7e nombre est impair" :

$$\pi \Pi^6 [1 \ 0 \ 1 \ 0 \ 1]^T.$$

3. La probabilité que 3e nombre soit 4 et le 6e nombre strictement inférieur à 3 :

$$(\pi \Pi)(\Pi^2)^2 [0 \ 0 \ 0 \ 1 \ 0]^T [0 \ 0 \ 0 \ 1 \ 0](\Pi^2)^3 [1 \ 1 \ 0 \ 0 \ 0]^T.$$

4. On a $\pi'_1 = 0$ et $\pi'_j = \pi_j + \frac{\pi_1}{1 - \Pi_{11}} \Pi_{1j}$ pour $2 \leq j \leq 5$;

$$\Pi'_{i1} = 0 \text{ pour } 2 \leq i \leq 5; \Pi'_{ij} = \Pi_{ij} + \frac{\Pi_{i1}}{1 - \Pi_{11}} \Pi_{1j} \text{ pour } 2 \leq i, j \leq 5.$$

On peut définir Π_{1j} assez librement car c'est sans incidence sur la chaîne.


Par exemple, $\Pi_{11} = 1$ et $\Pi_{1j} = 0$ pour $2 \leq j \leq 5$.

On vérifie que

$$\begin{aligned} \sum_{j=1}^5 \pi'_j &= \sum_{j=2}^5 \pi'_j = \sum_{j=2}^5 \pi_j + \frac{\pi_1}{1 - \Pi_{11}} \sum_{j=2}^5 \Pi_{1j} \\ &= \sum_{j=2}^5 \pi_j + \frac{\pi_1}{1 - \Pi_{11}} (\sum_{j=1}^5 \Pi_{1j} - \Pi_{11}) = \sum_{j=2}^5 \pi_j + \frac{\pi_1}{1 - \Pi_{11}} (1 - \Pi_{11}) = 1. \end{aligned}$$

De façon similaire, $\sum_{j=1}^5 \Pi'_{ij} = 1$ pour $2 \leq i \leq 5$.

Inférence à partir d'observations d'état bruitées.



3. Comme

$$P(\mathcal{X}_t = S_i | Y_1 \dots Y_N) = \frac{P(\mathcal{X}_t = S_i, Y_1 \dots Y_N)}{\sum_{k=1}^3 P(\mathcal{X}_t = S_k, Y_1 \dots Y_N)},$$

tout se ramène bien à calculer efficacement $P(\mathcal{X}_N = S_i, Y_1 \dots Y_N)$.

Pour y parvenir, on va partir de l'état 1 et ajouter les observations séquentiellement.

Sans observation,

$$\hat{\alpha}_1 = \begin{bmatrix} P(\mathcal{X}_1 = S_1) & P(\mathcal{X}_1 = S_2) & P(\mathcal{X}_1 = S_3) \end{bmatrix} = \pi.$$

Avec Y_1 ,

$$\begin{aligned} \alpha_1 &= \begin{bmatrix} P(\mathcal{X}_1 = S_1, Y_1) & P(\mathcal{X}_1 = S_2, Y_1) & P(\mathcal{X}_1 = S_3, Y_1) \end{bmatrix} \\ &= \begin{bmatrix} P(\mathcal{X}_1 = S_1)P(Y_1 | \mathcal{X}_1 = S_1) & \dots & P(\mathcal{X}_1 = S_3)P(Y_1 | \mathcal{X}_1 = S_3) \end{bmatrix} \\ &= \hat{\alpha}_1 * (\Sigma \mathbf{e}_{Y_1})^T \end{aligned}$$

où $*$ est le produit de Hadamard (produit élément par élément) et \mathbf{e}_{Y_1} un vecteur colonne dont tous les éléments sont nuls, sauf le Y_1 -ème qui vaut 1. $(\Sigma \mathbf{e}_{Y_1})$ est la Y_1 -ème colonne de Σ .

Etat suivant sans observation supplémentaire :

$$\begin{aligned} \hat{\alpha}_2 &= \begin{bmatrix} P(\mathcal{X}_2 = S_1, Y_1) & P(\mathcal{X}_2 = S_2, Y_1) & P(\mathcal{X}_2 = S_3, Y_1) \end{bmatrix} \\ &= \begin{bmatrix} \sum_{k=1}^3 P(\mathcal{X}_1 = S_k, \mathcal{X}_2 = S_1, Y_1) & \dots & \sum_{k=1}^3 P(\mathcal{X}_1 = S_k, \mathcal{X}_2 = S_3, Y_1) \end{bmatrix} \\ &= \begin{bmatrix} \sum_{k=1}^3 P(\mathcal{X}_1 = S_k, Y_1)P(\mathcal{X}_2 = S_1 | \mathcal{X}_1 = S_k) & \dots & \sum_{k=1}^3 P(\mathcal{X}_1 = S_k, Y_1)P(\mathcal{X}_2 = S_3 | \mathcal{X}_1 = S_k) \end{bmatrix} \\ &= \alpha_1 \Pi. \end{aligned}$$

Ajout de l'observation Y_2 :

$$\begin{aligned} \alpha_2 &= \begin{bmatrix} P(\mathcal{X}_2 = S_1, Y_1, Y_2) & P(\mathcal{X}_2 = S_2, Y_1, Y_2) & P(\mathcal{X}_2 = S_3, Y_1, Y_2) \end{bmatrix} \\ &= \begin{bmatrix} P(\mathcal{X}_2 = S_1, Y_1)P(Y_2 | \mathcal{X}_2 = S_1) & \dots & P(\mathcal{X}_2 = S_3, Y_1)P(Y_2 | \mathcal{X}_2 = S_3) \end{bmatrix} \\ &= \hat{\alpha}_2 * (\Sigma \mathbf{e}_{Y_2})^T \end{aligned}$$

Etat suivant sans observation supplémentaire :

$$\hat{\alpha}_3 = \begin{bmatrix} P(\mathcal{X}_3 = S_1, Y_1, Y_2) & \dots & P(\mathcal{X}_3 = S_3, Y_1, Y_2) \end{bmatrix} = \alpha_2 \Pi.$$

Ajout de l'observation Y_3 :

$$\alpha_3 = \left[P(\mathcal{X}_3 = S_1, Y_1, Y_2, Y_3) \quad \dots \quad P(\mathcal{X}_3 = S_3, Y_1, Y_2, Y_3) \right] = \hat{\alpha}_3 * (\Sigma \mathbf{e}_{Y_3})^T.$$

Finalement,

$$p_3 = \left[P(\mathcal{X}_3 = S_1 | Y_1, Y_2, Y_3) \quad \dots \quad P(\mathcal{X}_3 = S_3 | Y_1, Y_2, Y_3) \right] = \alpha_3 / (\alpha_3 \mathbf{1}),$$

où $\mathbf{1} = [1 \ 1 \ 1]^T$.

Avec les observations particulières de l'énoncé, on aboutit à l'algorithme suivant :

$$\begin{aligned} \hat{\alpha}_1 &= \pi = [1 \ 1 \ 1]/3, \\ \alpha_1 &= \hat{\alpha}_1 * (\Sigma \mathbf{e}_3)^T \\ \hat{\alpha}_2 &= \alpha_1 \Pi \\ \alpha_2 &= \hat{\alpha}_2 * (\Sigma \mathbf{e}_2)^T \\ \hat{\alpha}_3 &= \alpha_2 \Pi \\ \alpha_3 &= \hat{\alpha}_3 * (\Sigma \mathbf{e}_1)^T \\ p_3 &= \alpha_3 / (\alpha_3 \mathbf{1}), \end{aligned}$$

$$\text{où } \mathbf{e}_1 = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \mathbf{e}_2 = \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}, \mathbf{e}_3 = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}, \mathbf{1} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}.$$

4. Comme

$$\begin{aligned} P(\mathcal{X}_t = S_i | Y_1 \dots Y_N) &= \frac{P(\mathcal{X}_t = S_i, Y_1 \dots Y_N)}{\sum_{k=1}^3 P(\mathcal{X}_t = S_k, Y_1 \dots Y_N)}, \\ P(\mathcal{X}_t = S_i, Y_1 \dots Y_N) &= P(\mathcal{X}_t = S_i, Y_1 \dots Y_t) P(Y_{t+1} \dots Y_N | \mathcal{X}_t = S_i), \end{aligned}$$

et comme $P(\mathcal{X}_t = S_i, Y_1 \dots Y_t)$ est l'élément i de α_t , il reste à calculer $P(Y_{t+1} \dots Y_N | \mathcal{X}_t = S_i)$.

On part de la dernière observation Y_3 :

$$\hat{\beta}_3 = \left[P(Y_3 | \mathcal{X}_3 = S_1) \quad P(Y_3 | \mathcal{X}_3 = S_2) \quad P(Y_3 | \mathcal{X}_3 = S_3) \right] = (\Sigma \mathbf{e}_{Y_3})^T.$$

On fait remonter le conditionnement à l'état précédent :

$$\begin{aligned} \beta_2 &= \left[P(Y_3 | \mathcal{X}_2 = S_1) \quad P(Y_3 | \mathcal{X}_2 = S_2) \quad P(Y_3 | \mathcal{X}_2 = S_3) \right] \\ &= \left[\sum_{k=1}^3 P(\mathcal{X}_3 = S_k, Y_3 | \mathcal{X}_2 = S_1) \quad \dots \quad \sum_{k=1}^3 P(\mathcal{X}_3 = S_k, Y_3 | \mathcal{X}_2 = S_3) \right] \\ &= \left[\sum_{k=1}^3 P(\mathcal{X}_3 = S_k | \mathcal{X}_2 = S_1) P(Y_3 | \mathcal{X}_3 = S_k) \quad \dots \quad \sum_{k=1}^3 P(\mathcal{X}_3 = S_k | \mathcal{X}_2 = S_3) P(Y_3 | \mathcal{X}_3 = S_k) \right] \\ &= \hat{\beta}_3 \Pi^T. \end{aligned}$$

On ajoute l'observation Y_2 :

$$\begin{aligned} \hat{\beta}_2 &= \left[P(Y_2, Y_3 | \mathcal{X}_2 = S_1) \quad \dots \quad P(Y_2, Y_3 | \mathcal{X}_2 = S_3) \right] \\ &= \left[P(Y_3 | \mathcal{X}_2 = S_1) P(Y_2 | \mathcal{X}_2 = S_1) \quad \dots \quad P(Y_3 | \mathcal{X}_2 = S_3) P(Y_2 | \mathcal{X}_2 = S_3) \right] \\ &= \beta_2 * (\Sigma \mathbf{e}_{Y_2})^T. \end{aligned}$$

On fait remonter le conditionnement à l'état précédent :

$$\beta_1 = \begin{bmatrix} P(Y_2, Y_3 | \mathcal{X}_1 = S_1) & \dots & P(Y_2, Y_3 | \mathcal{X}_1 = S_3) \end{bmatrix} = \hat{\beta}_2 \Pi^T.$$

On peut alors calculer

$$\begin{aligned} \hat{p}_t &= \begin{bmatrix} P(\mathcal{X}_t = S_1, Y_1 \dots Y_N) & \dots & P(\mathcal{X}_t = S_3, Y_1 \dots Y_N) \end{bmatrix} = \alpha_t * \beta_t \\ p_t &= \begin{bmatrix} P(\mathcal{X}_t = S_1 | Y_1 \dots Y_N) & \dots & P(\mathcal{X}_t = S_3 | Y_1 \dots Y_N) \end{bmatrix} = \hat{p}_t / (\hat{p}_t \mathbf{1}). \end{aligned}$$

Avec les observations particulières de l'énoncé, on aboutit à l'algorithme suivant :

$$\begin{aligned} \hat{\beta}_3 &= (\Sigma \mathbf{e}_1)^T \\ \beta_2 &= \hat{\beta}_3 \Pi^T \\ \hat{\beta}_2 &= \beta_2 * (\Sigma \mathbf{e}_2)^T \\ \beta_1 &= \hat{\beta}_2 \Pi^T \\ \hat{p}_1 &= \alpha_1 * \beta_1 & \hat{p}_2 &= \alpha_2 * \beta_2 \\ p_1 &= \hat{p}_1 / (\hat{p}_1 \mathbf{1}) & p_2 &= \hat{p}_2 / (\hat{p}_2 \mathbf{1}), \end{aligned}$$

avec les α_1, α_2 obtenus au point précédent.

5. On utilise la propagation avant, sans ajout d'observations, en partant de p_N .

En général, pour $t > N$,

$$p_t = \begin{bmatrix} P(\mathcal{X}_t = S_1 | Y_1 \dots Y_N) & \dots & P(\mathcal{X}_t = S_3 | Y_1 \dots Y_N) \end{bmatrix} = p_N \Pi^{t-N}.$$

Ici,

$$p_4 = p_3 \Pi \qquad p_5 = p_3 \Pi^2,$$

avec p_3 calculé au point 3.

6. Il suffit de sauter dans les algorithmes de propagation l'étape correspondant à l'observation de Y_2 .

L'algorithme résultant est le suivant :

$$\begin{aligned} \hat{\alpha}_1 &= \pi = [1 \ 1 \ 1] / 3 & \hat{\beta}_3 &= (\Sigma \mathbf{e}_1)^T \\ \alpha_1 &= \hat{\alpha}_1 * (\Sigma \mathbf{e}_3)^T & \beta_2 &= \hat{\beta}_3 \Pi^T \\ \hat{\alpha}_2 &= \alpha_1 \Pi \\ \alpha'_2 &= \hat{\alpha}_2 \\ \hat{p}'_2 &= \alpha'_2 * \beta_2 \end{aligned}$$

$$\text{et } p'_2 = \begin{bmatrix} P(\mathcal{X}_2 = S_1, Y_1, Y_3) & P(\mathcal{X}_2 = S_2, Y_1, Y_3) & P(\mathcal{X}_2 = S_3, Y_1, Y_3) \end{bmatrix} = \hat{p}'_2 / (\hat{p}'_2 \mathbf{1}).$$

Cascade de senseurs.

1. On a $\hat{x}_{(1)} = \mathbf{E}\{x|y\} = \bar{x} + \Sigma_{xy}\Sigma_y^{-1}(y - \bar{y}) = \bar{x} + \Sigma_x C^T (C\Sigma_x C^T + V)(y - C\bar{x})$
 et $\mathbf{E}\{(x - \hat{x}_{(1)})(x - \hat{x}_{(1)})^T\} = \Sigma_x - \Sigma_{xy}\Sigma_y^{-1}\Sigma_{xy}^T = \Sigma_x - \Sigma_x C^T (C\Sigma_x C^T + V)^{-1} C\Sigma_x$.
 L'espérance de l'erreur quadratique d'estimation vaut la trace de $\mathbf{E}\{(x - \hat{x}_{(1)})(x - \hat{x}_{(1)})^T\}$.
2. Par substitution de l'expression de y dans z , on a

$$z = Fx + G(Cx + v) + w = (F + GC)x + Gv + w.$$

On pose $A = F + GC$ et $u = Gv + w$, de sorte que $z = Ax + u$.

On pose ensuite

$$y' = \begin{bmatrix} y \\ z \end{bmatrix} = \begin{bmatrix} C \\ A \end{bmatrix} x + \begin{bmatrix} v \\ u \end{bmatrix}, \quad C' = \begin{bmatrix} C \\ A \end{bmatrix}, \quad v' = \begin{bmatrix} v \\ u \end{bmatrix},$$

de sorte que $y' = C'x + v'$.

Le bruit v' suit $\mathcal{N}(0, V')$ avec $V' = \begin{bmatrix} V & VGT \\ GVT & GVG^T + W \end{bmatrix}$.

On peut à présent recycler les formules du point précédent en remplaçant C par C' et V par V' .

On a ainsi

$$\begin{aligned} \hat{x}_{(2)} &= \mathbf{E}\{x|y, z\} = \mathbf{E}\{x|y'\} = \bar{x} + \Sigma_{xy'}\Sigma_{y'}^{-1}(y' - \bar{y}') \\ &= \bar{x} + \Sigma_x C'^T (C'\Sigma_x C'^T + V')^{-1}(y' - C'\bar{x}) \\ &= \bar{x} + \Sigma_x \begin{bmatrix} C^T & A^T \end{bmatrix} \left(\begin{bmatrix} C \\ A \end{bmatrix} \Sigma_x \begin{bmatrix} C^T & A^T \end{bmatrix} + \begin{bmatrix} V & VGT \\ GVT & GVG^T + W \end{bmatrix} \right)^{-1} \left(\begin{bmatrix} y \\ z \end{bmatrix} - \begin{bmatrix} C \\ A \end{bmatrix} \bar{x} \right) \\ &= \bar{x} + \begin{bmatrix} \Sigma_x C^T & \Sigma_x A^T \end{bmatrix} \begin{bmatrix} C\Sigma_x C^T + V & C\Sigma_x A^T + VGT \\ A\Sigma_x C^T + GVT & A\Sigma_x A^T + GVG^T + W \end{bmatrix}^{-1} \left(\begin{bmatrix} y \\ z \end{bmatrix} - \begin{bmatrix} C \\ A \end{bmatrix} \bar{x} \right) \end{aligned}$$

avec $A = F + GC$.

L'espérance de l'erreur moyenne quadratique est la trace de

$$\mathbf{E}\{(x - \hat{x}_{(2)})(x - \hat{x}_{(2)})^T\} = \Sigma_x - \Sigma_x C'^T (C'\Sigma_x C'^T + V')^{-1} C'\Sigma_x$$

avec substitutions similaires.

3. On a $\hat{z} = \mathbf{E}\{z|y\} = \bar{z} + \Sigma_{zy}\Sigma_y^{-1}(y - \bar{y})$
 et $\mathbf{E}\{\|z - \hat{z}\|^2\} = \text{tr}\{\Sigma_z - \Sigma_{zy}\Sigma_y^{-1}\Sigma_{yz}\}$.
 Les matrices Σ_y , Σ_{zy} et Σ_z peuvent être déduites du point précédent en remarquant que $\Sigma_{y'}$ peut être partitionnée :

$$\Sigma_{y'} = \begin{bmatrix} \Sigma_y & \Sigma_{yz} \\ \Sigma_{zy} & \Sigma_z \end{bmatrix},$$

et par identification on tire

$$\Sigma_y = C\Sigma_x C^T + V \quad \Sigma_{zy} = A\Sigma_x C^T + GVT \quad \Sigma_z = A\Sigma_x A^T + GVG^T + W.$$

Ainsi,

$$\begin{aligned} \hat{z} &= \mathbf{E}\{z|y\} = \bar{z} + \Sigma_{zy}\Sigma_y^{-1}(y - \bar{y}) \\ &= \bar{z} + (A\Sigma_x C^T + GVT)(C\Sigma_x C^T + V)^{-1}(y - C\bar{x}), \end{aligned}$$

$$\begin{aligned}\mathbf{E}\{\|z - \hat{z}\|^2\} &= \text{tr}\{\Sigma_z - \Sigma_{zy}\Sigma_y^{-1}\Sigma_{yz}\} \\ &= \text{tr}\{A\Sigma_x A^T + GVG^T + W - (A\Sigma_x C^T + GV^T)(C\Sigma_x C^T + V)^{-1}(C\Sigma_x A^T + VG^T)\}.\end{aligned}$$

Une variante consiste à partir de l'expression de y, z en fonction de x, v, w

$$y' = \begin{bmatrix} y \\ z \end{bmatrix} = \begin{bmatrix} C & I_{m_y} & 0 \\ A & G & I_{m_z} \end{bmatrix} \begin{bmatrix} x \\ v \\ w \end{bmatrix},$$

puis à calculer directement $\Sigma_{y'}$ à partir de sa définition :

$$\begin{aligned}\mathbf{E}\left\{\begin{bmatrix} y - \bar{y} \\ z - \bar{z} \end{bmatrix} \begin{bmatrix} y - \bar{y} \\ z - \bar{z} \end{bmatrix}^T\right\} &= \begin{bmatrix} C & I_{m_y} & 0 \\ A & G & I_{m_z} \end{bmatrix} \begin{bmatrix} \Sigma_x & 0 & 0 \\ 0 & V & 0 \\ 0 & 0 & W \end{bmatrix} \begin{bmatrix} C^T & A^T \\ I_{m_y} & G^T \\ 0^T & I_{m_z} \end{bmatrix} \\ &= \begin{bmatrix} C\Sigma_x C^T + V & C\Sigma_x A^T + VG^T \\ A\Sigma_x C^T + GV^T & A\Sigma_x A^T + GVG^T + W \end{bmatrix}.\end{aligned}$$