

## Introduction

### 1 Modèle graphique




Figure 1: Filtrage.




Figure 2: Réseau de neurones.

## 2 Modèles d'états, le cas linéaire avec bruit gaussien.

Soit un processus  $(x_t)_{t \in \mathbb{N}}$  où à chaque instant  $t$  l'état  $x_t \in \mathbb{R}^p$ . Le processus  $(y_t)_{t \in \mathbb{N}}$  représente les observations et pour tout  $t$ ,  $y_t \in \mathbb{R}^q$ .

On suppose que l'on observe  $y_1, y_2, \dots, y_s$ . Des vecteurs de bruits gaussiens centrés et i.i.d  $\varepsilon_t \in \mathbb{R}^p$  et  $\xi_t \in \mathbb{R}^q$  ont des variances respectives  $\Sigma_\varepsilon$  et  $\Sigma_\xi$ . De plus on suppose que  $\varepsilon_t$  et  $\xi_t$  sont indépendants.

**Remark.** *Il est facile de rajouter des variables exogènes si besoin.*

**Exemple.**

- *Marche aléatoire bruitée.*  
 $x_t = x_{t-1} + \varepsilon_t$  où  $\varepsilon_t$  est de variance  $\sigma_\varepsilon^2$ .  
 $y_t = x_t + \xi_t$  où  $\xi_t$  est de variance  $\sigma_\xi^2$ .




Figure 3: Marche aléatoire.

- *Modèle structurel exponentiel.*

$$\begin{cases} x_t = \varphi x_{t-1} + \varepsilon_t \\ y_t = x_t + s_t + \xi_t \end{cases} \quad (1)$$

$s_t$  est une saisonnalité trimestrielle et  $s_t + s_{t-1} + s_{t-2} + s_{t-3} = \eta_t$  avec  $\eta_t$  un gaussien centré de variance  $\sigma_\eta^2$ . On peut écrire ce modèle sous forme matricielle:

$$\begin{pmatrix} x_t \\ s_t \\ s_{t-1} \\ s_{t-2} \end{pmatrix} = \begin{pmatrix} \varphi & 0 & 0 & 0 \\ 0 & -1 & -1 & -1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} x_{t-1} \\ s_{t-1} \\ s_{t-2} \\ s_{t-3} \end{pmatrix} + \begin{pmatrix} \varepsilon_t \\ \eta_t \\ 0 \\ 0 \end{pmatrix}$$

et

$$y_t = (1 \quad 1 \quad 0 \quad 0) \begin{pmatrix} x_t \\ s_t \\ s_{t-1} \\ s_{t-2} \end{pmatrix} + \xi_t.$$

avec  $\varepsilon_t$ ,  $\xi_t$  et  $\eta_t$  sont indépendants.

$$\text{Var} \begin{pmatrix} \varepsilon_t \\ \eta_t \\ 0 \\ 0 \end{pmatrix} = \begin{pmatrix} \sigma_\varepsilon^2 & 0 & 0 & 0 \\ 0 & \sigma_\eta^2 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

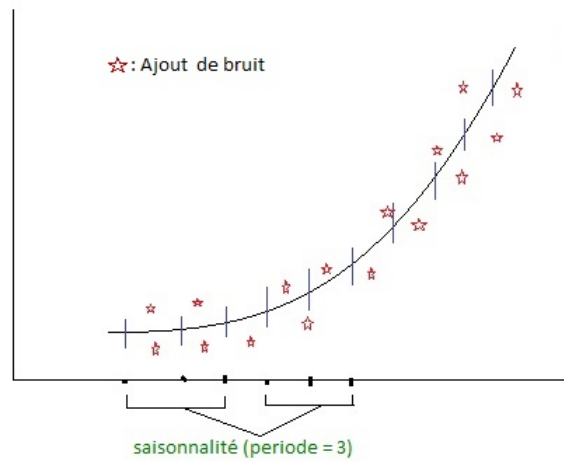



Figure 4: Modèle structurel exponentiel.

**Exemple.** *Poursuite d'objet: exemple farfelu d'un drone qui suit un chat dans un champs...*

$$\begin{pmatrix} x_t(1) \\ s_t(2) \\ v_t(1) \\ v_t(2) \end{pmatrix} = \begin{pmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 1 & \varphi & 0 \\ 0 & 0 & 0 & \varphi \end{pmatrix} \begin{pmatrix} x_{t-1}(1) \\ s_{t-1}(2) \\ v_{t-1}(1) \\ v_{t-1}(2) \end{pmatrix}$$

les  $x_t(1)$  et  $x_t(2)$  constituent les états,  $v_t(1)$  et  $v_t(2)$  les vitesses et  $\varphi$  est l'accélération constante.



### 3 Modèle d'observation

On modélise les observations sous forme matricielle par

$$\begin{pmatrix} y_t(1) \\ y_t(2) \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix} \begin{pmatrix} x_t(1) \\ s_t(2) \\ v_t(1) \\ v_t(2) \end{pmatrix} + \mathcal{N}\left(0, \begin{pmatrix} \tau_2 & 0 \\ 0 & \tau_2 \end{pmatrix}\right). \quad (2)$$

On observe uniquement la position de l'objet au lieu de la vitesse. Intéressons nous au modèle suivant:

$$\begin{cases} x_t = \varphi x_{t-1} + \varepsilon_t \\ y_t = Ax_t + \xi_t \end{cases} \quad (3)$$

On initialise l'espace états par  $x_0$  qui suit la loi  $\mathcal{N}(\mu_0, \Sigma_0)$ .

**Notation:** On note l'espérance conditionnelle de  $x_t$  sachant  $y_1, y_2, \dots, y_s$  par

$$x_t^s := \mathbb{E}[x_t | y_{1:s}] \quad \text{avec} \quad y_{1:s} = (y_1, y_2, \dots, y_s)$$

et la covariance conditionnelle en  $t_1, t_2$  sachant qu'on a observé jusqu'à  $s$  par la matrice de variance conditionnelle

$$P_{t_1, t_2}^s := \mathbb{E}\left[(x_{t_1} - x_{t_1}^s)(x_{t_2} - x_{t_2}^s)^\top\right].$$

On note aussi que  $P_t^s = P_{t,t}^s$ .

#### Filtre de Kalman:

**Definition.** Le filtre de Kalman est un filtre linéaire aux observations  $y_1, \dots, y_s$ . On le définit par:

$$x_t^t = \sum_{s=1}^{+\infty} B_s y_s \quad \text{avec} \quad B_s \quad \text{une matrice.} \quad (4)$$

**Theorem.** Conditions d'initialisation:  $x_0^0 = \mu_0$  et  $P_0^0 = \Sigma_0$ .

Par récurrence sous l'hypothèse d'évolution décrite en (3), on obtient:

1.  $x_t^{t-1} = \Phi x_{t-1}^{t-1} \in \mathbb{R}^p$  c'est la prédiction.

2.  $P_t^{t-1} = \Phi P_{t-1}^{t-1} \Phi^\top + \Sigma_\varepsilon \in \mathbb{R}^{p \times p}$ .

$$\begin{cases} x_t^t = x_t^{t-1} + K_t (y_t - Ax_t^{t-1}) \\ P_t^t = (\text{Id} - K_t A) P_t^{t-1} \end{cases} \quad K_t \text{ est défini par } P_t^{t-1} A^\top (A P_t^{t-1} A^\top + \Sigma_\xi)^{-1}$$

3. Le terme de résidu (ou d'erreur entre la prédiction et l'observation) est:

$$\begin{aligned}\delta_t &= y_t - \mathbb{E}(y_t | y_{1:t-1}) \\ &= y_t - \mathbb{E}(Ax_t | y_{1:t-1}) \\ &= y_t - Ax_t^{t-1}\end{aligned}$$

4. La variance de l'erreur est:

$$\begin{aligned}\Sigma_{\delta_t} &= \text{Var}(\delta_t) \\ &= \text{Var}(y_t - Ax_t^{t-1}) \\ &= \text{Var}(Ax_t + \xi_t - Ax_t^{t-1}) \\ &= \text{Var}(\xi_t) + \text{Var}(A(x_t - x_t^{t-1})) \\ &= \Sigma_\xi + A \text{Var}(x_t - x_t^{t-1})A^\top\end{aligned}$$

On retrouve  $P_t^{t-1} = \text{Var}(x_t - x_t^{t-1})$ .

*Proof.* 1.

$$\begin{aligned}x_t^{t-1} &= \mathbb{E}(x_t | y_{1:t-1}) \\ &= \mathbb{E}(\Phi x_{t-1} | y_{1:t-1}) \\ &= \Phi \mathbb{E}(x_{t-1} | y_{1:t-1}) \\ &= \Phi x_{t-1}^{t-1}.\end{aligned}$$

2.

$$\begin{aligned}P_t^{t-1} &= \mathbb{E} \left[ (x_t - x_t^{t-1}) (x_t - x_t^{t-1})^\top \right] \\ &= \mathbb{E} \left[ (\Phi(x_t - x_{t-1}^{t-1}) + \varepsilon_t) (\Phi(x_{t-1} - x_{t-1}^{t-1}) + \varepsilon_t)^\top \right] \\ &= \text{Var}(\varepsilon_t) + \text{Var}(\Phi(x_t - x_{t-1}^{t-1})) \\ &= \Sigma_\varepsilon + \Phi P_{t-1}^{t-1} \Phi^\top\end{aligned}$$

3. On a  $\text{Cov}(\delta_s, y_t) = 0$  pour tout  $t > s$ .

En effet

$$\begin{aligned}\text{Cov}(\delta_s, y_t) &= \mathbb{E} \left[ (\delta_t - \mathbb{E}(\delta_t))(y_s - \mathbb{E}(y_s))^\top \right] \\ &= \mathbb{E} \mathbb{E} \left[ (\delta_t - \mathbb{E}(\delta_t))(y_s - \mathbb{E}(y_s))^\top | y_{1:s} \right] \\ &= 0 \text{ par mesurabilité.}\end{aligned}$$

$$\begin{aligned}\text{Cov}(x_s, \delta_t | y_{1:t-1}) &= \text{Cov}(x_t, y_t - Ax_t^{t-1} | y_{1:t-1}) \\ &= \text{Cov}(x_t - x_t^{t-1}, y_t - Ax_t^{t-1} | y_{1:t-1}) \\ &= \text{Cov}(x_t - x_t^{t-1}, A(x_t - x_t^{t-1}) + \xi_t | y_{1:t-1}) \\ &= \text{Var}(x_t - x_t^{t-1})A^\top \\ &= P_t^{t-1}A^\top.\end{aligned}$$

Ainsi,  $\begin{pmatrix} x_t \\ \delta_t \end{pmatrix}$  suit une loi normale  $\mathcal{N}\left(\begin{pmatrix} x_t^{t-1} \\ 0 \end{pmatrix}, \begin{pmatrix} \mathbf{P}_t^{t-1} & \mathbf{P}_t^{t-1} \mathbf{A}^\top \\ \mathbf{P}_t^{t-1} \mathbf{A}^\top & \Sigma_{\delta_t} \end{pmatrix}\right)$  avec  $\mathbf{A} \mathbf{P}_t^{t-1} = \mathbf{P}_t^{t-1} \mathbf{A}^\top$  et  $\Sigma_{\delta_t} = \mathbf{A} \mathbf{P}_t^{t-1} \mathbf{A}^\top + \Sigma_\xi$ .

On notera  $\mu_{i|j}$  l'espérance de la distribution conditionnelle de  $x_i$  sachant  $x_j$  et  $\Sigma_{i|j}$  sa variance. Les paramètres conditionnels sont alors donnés par les relations suivantes:

$$\begin{cases} \mu_{i|j} = \mu_i + \Sigma_{ij} \Sigma_{jj}^{-1} (x_j - \mu_j) \\ \Sigma_{i|j} = \Sigma_{ii} - \Sigma_{ij}^\top \Sigma_{jj}^{-1} \Sigma_{ij} \end{cases} \quad (5)$$

Ainsi,

$$x_t^t = \mathbb{E}(x_t | y_{1:t}, \delta_t) = x_t^{t-1} + (\mathbf{P}_t^{t-1} \mathbf{A}^\top) (\Sigma_j)^{-1} (\delta_t) . \quad (6)$$

□