

# Modèle état mesure

-①-

On considère le modèle suivant

$$\left\{ \begin{array}{l} Y_t = H \sum_t + w_t \\ \sum_{t+1} = F \sum_t + v_{t+1} \end{array} \right. \quad \begin{array}{l} \text{[équation de} \\ \text{mesure]} \\ \text{[équation} \\ \text{d'état]} \end{array}$$

*(Dimensions:  $Y_t$  is  $n \times 1$ ,  $H$  is  $n \times r$ ,  $\sum_t$  is  $r \times 1$ ,  $w_t$  is  $n \times 1$ ,  $F$  is  $r \times r$ ,  $\sum_{t+1}$  is  $r \times 1$ ,  $v_{t+1}$  is  $r \times 1$ )*

avec

$$w_t \sim BB(0, R)$$

erreurs de mesure

$$v_t \sim BB(0, Q)$$

innovations des états

$$w_t \perp v_s$$

et on suppose de plus que l'état est non corrélé avec les erreurs ou les innovations

$$\mathbb{E} \left[ \sum_{\tau} v_{\tau} \right] = 0 \quad \text{pour } \tau = t-1, t-2, \dots, 1$$

$$\mathbb{E} \left[ \sum_{\tau} w_{\tau} \right] = 0 \quad \text{pour tout } \tau$$

On a aussi

(2)

$$\mathbb{E}[w_t y_t'] = \mathbb{E}[w_t (H \tilde{\Sigma}_t + w_t)'] = 0$$

$\forall t = t-1, t-2, \dots$

$$\text{et } \mathbb{E}[v_t y_t'] = \mathbb{E}[v_t (H \tilde{\Sigma}_t + w_t)'] = 0$$

$\forall t = t-1, t-2, \dots$

On pourrait considérer un modèle plus général avec

- des variables exogènes dans l'équation de mesure ou l'équation d'état.
- une corrélation non nulle entre les innovations des états et les erreurs de mesure
- des matrices  $H, F, R$  et  $Q$  variables dans le temps

Mais cette classe de processus stochastique englobe tout ce que nous avons déjà vu, il y a donc assez de généralité ici -

Exemple 1 Soit le processus AR(p)

(3)

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

avec  $\varepsilon_t \sim \text{iid}(0, \sigma_\varepsilon^2)$ . On peut réécrire ce modèle sous une forme état mesure

Equation d'état ( $r=p$ )

$$\underbrace{\begin{pmatrix} Y_{t+1} \\ Y_t \\ \vdots \\ Y_{t-p+2} \end{pmatrix}}_{\Sigma_{t+1}} = \underbrace{\begin{pmatrix} \phi_1 & \phi_2 & \dots & \phi_p \\ 1 & 0 & \dots & 0 \\ 0 & \diagdown & & \diagdown \\ \vdots & & \ddots & \\ 0 & \dots & 0 & 1 \end{pmatrix}}_F \underbrace{\begin{pmatrix} Y_t \\ Y_{t-1} \\ \vdots \\ Y_{t-p+1} \end{pmatrix}}_{\Sigma_t} + \underbrace{\begin{pmatrix} \varepsilon_{t+1} \\ 0 \\ \vdots \\ 0 \end{pmatrix}}_{\mathcal{V}_{t+1}}$$

condition de stabilité  
 ↓  
 valeurs propres de F inférieures à 1 en module

$$L_0 \mathcal{V}[\mathcal{V}_{t+1}] \equiv Q = \begin{pmatrix} \sigma_\varepsilon^2 & 0 & \dots & 0 \\ 0 & 0 & & \vdots \\ \vdots & & \ddots & \\ 0 & \dots & 0 & 0 \end{pmatrix}$$

une matrice de rang  $1 < r$

Equation de mesure ( $n=1$ )

$$Y_t = \underbrace{(1, 0, \dots, 0)}_H \underbrace{\begin{pmatrix} Y_t \\ Y_{t-1} \\ \vdots \\ Y_{t-p+1} \end{pmatrix}}_{\Sigma_t} + \underbrace{0}_{\mathcal{W}_t}$$

$L_0 \mathcal{V}[\mathcal{W}_t] \equiv R = 0$  une matrice nulle.



Exemple 2 Soit le processus MA(1)

(4)

$$Y_t = \varepsilon_t + \theta \varepsilon_{t-1}$$

Equation d'état (n=2)

$$\underbrace{\begin{pmatrix} \varepsilon_{t+1} \\ \varepsilon_t \end{pmatrix}}_{\mathbb{Z}_{t+1}} = \underbrace{\begin{pmatrix} 0 & 0 \\ 1 & 0 \end{pmatrix}}_F \underbrace{\begin{pmatrix} \varepsilon_t \\ \varepsilon_{t-1} \end{pmatrix}}_{\mathbb{Z}_t} + \underbrace{\begin{pmatrix} \varepsilon_{t+1} \\ 0 \end{pmatrix}}_{\mathcal{V}_{t+1}}$$

Equation de mesure (n=1)

$$Y_t = \underbrace{(1, \theta)}_H \mathbb{Z}_t + \underbrace{0}_{w_t}$$

Notons que la représentation état-mesure n'est pas nécessairement unique. Dans le cas du MA(1) nous pourrions poser :

$$\underbrace{\begin{pmatrix} \varepsilon_{t+1} + \theta \varepsilon_t \\ \theta \varepsilon_{t+1} \end{pmatrix}}_{\mathbb{Z}_{t+1}} = \underbrace{\begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}}_F \underbrace{\begin{pmatrix} \varepsilon_t + \theta \varepsilon_{t-1} \\ \theta \varepsilon_t \end{pmatrix}}_{\mathbb{Z}_t} + \underbrace{\begin{pmatrix} \varepsilon_{t+1} \\ \theta \varepsilon_{t+1} \end{pmatrix}}_{\mathcal{V}_{t+1}}$$

et

$$Y_t = (1, 0) \mathbb{Z}_t$$



Exemple 3 Plus généralement, considérons (5)  
 le processus ARMA(p,q) :

$$Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

où  $\{\varepsilon_t, t \in \mathbb{Z}\}$  est un bruit blanc de variance  $\sigma_\varepsilon^2$ .

En posant  $r = \max\{p, q+1\}$ ,  $\varphi_j = 0 \forall j > p$  et  $\theta_j = 0 \forall j > q$ , nous pouvons réécrire ce processus ARMA sous la forme :

$$Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_r Y_{t-r} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_{r-1} \varepsilon_{t-r+1}$$

Equation d'état ( $r = \max\{p, q+1\}$ )

$$\begin{matrix} \sum_{t+1} \\ \sum_t \end{matrix} = \underbrace{\begin{pmatrix} \varphi_1 & \varphi_2 & \dots & \varphi_{r-1} & \varphi_r \\ 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & \dots & 0 & 1 & 0 \end{pmatrix}}_F \begin{matrix} \sum_t + \\ \underbrace{\begin{pmatrix} \varepsilon_{t+1} \\ 0 \\ \vdots \\ 0 \end{pmatrix}}_{v_{t+1}} \end{matrix}$$

(6)

## Equation de mesure (n=1)

$$Y_t = \underbrace{(1, \theta_1, \dots, \theta_{2-1})}_H \Xi_t$$

Pour vérifier qu'il s'agit bien du même processus stochastique, notons que l'équation d'état nous dit que :

$$\underbrace{\Xi_{2,t+1}}_{\text{deuxième élément de } \Xi_{t+1}} = \underbrace{\Xi_{1,t}}_{\text{premier élément de } \Xi_t}$$

d'après la deuxième ligne, et plus généralement en observant les lignes suivantes :

$$\Xi_{j,t+1} = \Xi_{j-1,t} = \Xi_{j-2,t-1} \dots$$

Par récurrence, on a donc :

$$\Xi_{j,t+1} = L^{j-1} \Xi_{1,t+1}$$

La première ligne de l'équation d'état s'interprète donc comme :

$$\sum_{1,t+1} = \varphi_1 \sum_{1,t} + \varphi_2 \sum_{2,t} + \dots + \varphi_r \sum_{r,t} + \varepsilon_{t+1}$$

$$\Leftrightarrow \sum_{1,t+1} = (\varphi_1 + \varphi_2 L + \dots + \varphi_r L^{r-1}) \sum_{1,t} + \varepsilon_{t+1}$$

$$\Leftrightarrow (1 - \varphi_1 L - \dots - \varphi_r L^r) \sum_{1,t+1} = \varepsilon_{t+1}$$

nous retrouvons ici la partie autorégressive du processus ARMA. L'équation de mesure nous dit que :

$$y_t = (1 + \theta_1 L + \dots + \theta_{r-1} L^{r-1}) \sum_{1,t}$$

en multipliant les deux membres par le polynôme retard associé à la partie autorégressive, il vient

$$(1 - \varphi_1 L - \dots - \varphi_r L^r) y_t = (1 + \theta_1 L + \dots + \theta_{r-1} L^{r-1}) (1 - \varphi_1 L - \dots - \varphi_r L^r) \sum_{1,t}$$

$$\Rightarrow (1 - \varphi_1 L - \dots - \varphi_r L^r) y_t = (1 + \theta_1 L + \dots + \theta_{r-1} L^{r-1}) \varepsilon_t$$

$$(\Rightarrow) Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_{q-1} \varepsilon_{t-q+1}$$

Il s'agit bien de notre processus ARMA(p,q).



Au delà des processus ARMA, la représentation état mesure peut être employée pour caractériser d'autres processus stochastiques. Cette représentation est par exemple souvent employée pour les décompositions Tendance / Cycle

$$Y_t = X_t + Z_t$$

$$X_t = X_{t-1} + \varepsilon_t \quad [\text{Tendance}]$$

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \eta_t \quad [\text{Cycle}]$$

$$\begin{pmatrix} 1 \\ 0 \end{pmatrix} \sum_{t+1} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \varphi_1 & \varphi_2 \\ 0 & 1 & 0 \end{pmatrix} \sum_t + \begin{pmatrix} \varepsilon_t \\ \eta_t \\ 0 \end{pmatrix}$$

$$Y_t = (1, 0, 0) \sum_t$$

⑨  
▲ Dans un modèle état-mesure  
la (les) variable(s) est (sont) déterminé(e)s  
par une (des) combinaison(s) linéaire(s)  
de variables cachées (latentes); les  
variables d'état.

Pour faire des prévisions sur une  
variable observée, il faut faire  
des prédictions sur les variables  
cachées. En principe, étant donnée  
la forme de l'équation d'état  
(autorégressive d'ordre 1) cela ne  
devrait pas être compliqué... Sauf  
que nous n'observons pas les  
variables d'état ( $\mathbf{x}_t$ ). Il faut donc  
révéler ces variables. Le filtre

de Kalman est un algorithme (10)  
récuratif d'inférence dont le but est  
de dévoiler les variables latentes à  
partir d'un échantillon.

# Filtre de Kalman

(11)

- On observe un échantillon  $y_T = \{y_1, y_2, \dots, y_T\}$
- On suppose que les matrices  $H, F, R$  et  $Q$  du modèle état-mesure sont connues (nous pourrions les estimer par MV).
- À partir de ces informations on souhaite révéler les variables latentes  $\mathbb{z}_t$ .

Le filtre de Kalman est un algorithme récursif pour calculer des prévisions des variables latentes en  $t+1$  sachant l'information disponible en  $t$  :

$$\hat{\mathbb{z}}_{t+1|t} = \mathbb{E}[\mathbb{z}_{t+1} | y_t]$$

l'échantillon jusqu'à la date  $t$

L'algorithme génère une chronique (12)  
de prévisions :

$$\hat{\Sigma}_{1|0}, \hat{\Sigma}_{2|1}, \dots, \hat{\Sigma}_{T|T-1}$$

ainsi qu'une suite associée de matrices mesurant l'incertitude attachée à ces prévisions

$$P_{1|0}, P_{2|1}, \dots, P_{T|T-1}$$

où

$$P_{t+1|t} = \mathbb{E} \left[ \left( \hat{\Sigma}_{t+1} - \hat{\Sigma}_{t+1|t} \right) \left( \hat{\Sigma}_{t+1} - \hat{\Sigma}_{t+1|t} \right)' \right]$$

### \* Initialisation du filtre

La prévision  $\hat{\Sigma}_{1|0}$  ne repose sur aucune observation. On pose :

$$\hat{\Sigma}_{1|0} = \mathbb{E}[\hat{\Sigma}_1]$$

l'espérance inconditionnelle du vecteur d'état.

L'erreur quadratique moyenne associée est

(13)

$$P_{1|0} = E \left[ (\underline{z}_1 - E[\underline{z}_1]) (\underline{z}_1 - E[\underline{z}_1])' \right]$$

Si toutes les valeurs propres de  $F$  sont inférieures à 1 en module, l'espérance inconditionnelle de  $\underline{z}_t$  est solution

de

$$E[\underline{z}_{t+1}] = F E[\underline{z}_t]$$

En supposant que  $\{\underline{z}_t, t \in \mathbb{Z}\}$  est stationnaire au second ordre, on doit donc avoir:

$$(I_n - F) E[\underline{z}_t] = 0$$

Puisque 1 n'est pas valeur propre de  $F$ , la matrice  $I_n - F$  est de plein rang et  $E[\underline{z}_t]$  est déterminé de

façon unique :

$$E[\xi_t] = 0_{r \times 1}$$

La variance inconditionnelle du vecteur des variables latentes vérifie

$$E[\xi_{t+1} \xi_{t+1}'] = E[(F \xi_t + v_{t+1})(F \xi_t + v_{t+1})']$$

$$\Rightarrow E[\xi_{t+1} \xi_{t+1}'] = F E[\xi_t \xi_t'] F' + E[v_{t+1} v_{t+1}']$$

$$\Rightarrow \Sigma = F \Sigma F' + Q$$

admet une unique solution finie si les valeurs propres de F ont < 1 en module.

$$L_0 \quad \boxed{\text{vec}(\Sigma) = (I_{r^2} - F \otimes F)^{-1} \text{vec}(Q)}$$

Si les valeurs propres de F sont à l'intérieur du cercle unité, on pose donc :

$$- \hat{\xi}_{110} = 0$$

$$- P_{110} \text{ tq } \text{vec}(P_{110}) = (I_{r^2} - F \otimes F)^{-1} \text{vec}(Q)$$

# \* Predire $y_t$

Notons  $\hat{y}_{t|t-1} = \mathbb{E}[y_t | \mathcal{Y}_{t-1}]$  la prévision sur les observables en  $t$  sachant l'information disponible en  $t-1$ . On a:

$$\begin{aligned} \hat{y}_{t|t-1} &= \mathbb{E}[y_t | \mathcal{Y}_{t-1}] \\ &= \mathbb{E}[H \sum_t + v_t | \mathcal{Y}_{t-1}] \\ &= H \mathbb{E}[\sum_t | \mathcal{Y}_{t-1}] + \mathbb{E}[v_t | \mathcal{Y}_{t-1}] \end{aligned}$$

$$\text{Lo } \boxed{\hat{y}_{t|t-1} = H \hat{\sum}_{t|t-1}}$$

Pour prédire la variable observable il faut prédire les variables latentes. Plus généralement on peut montrer que

$$\hat{y}_{t+p|t} = H \hat{\sum}_{t+p|t}$$

L'erreur de prévision :

$$Y_t - \hat{Y}_{t|t-1} = H \sum_t + w_t - H \hat{\sum}_{t|t-1}$$

$$\begin{aligned}
 (=) Y_t - \hat{Y}_{t|t-1} &= H \left( \underbrace{\sum_t - \hat{\sum}_{t|t-1}}_{\substack{\text{erreur de} \\ \text{prévision} \\ \text{sur les variables} \\ \text{latentes}}} \right) + w_t \quad \leftarrow \substack{\text{erreur de} \\ \text{mesure}}
 \end{aligned}$$

L'erreur quadratique moyenne associée à la prévision est (la variance de l'erreur de prévision) :

$$\begin{aligned}
 E[(Y_t - \hat{Y}_{t|t-1})(Y_t - \hat{Y}_{t|t-1})'] &= H E[(\sum_t - \hat{\sum}_{t|t-1})(\sum_t - \hat{\sum}_{t|t-1})'] H' \\
 &\quad + E[w_t w_t']
 \end{aligned}$$

où les termes croisés n'apparaissent

pas car

$$E[w_t (\sum_t - \hat{\sum}_{t|t-1})'] = 0$$

La variance de l'erreur de prévision <sup>(17)</sup>  
est donc :

$$\mathbb{E}[(Y_t - \hat{Y}_{t|t-1})(Y_t - \hat{Y}_{t|t-1})'] = H P_{t|t-1} H' + R$$

où  $P_{t|t-1}$  est l'erreur quadratique  
moyenne associée à la prévision  
des variables latentes.

\* Comment prédire  $\hat{z}_{t+1}$ ?

La prévision des variables latentes est

$$\hat{z}_{t+1|t} = \mathbb{E}[z_{t+1} | Y_t]$$

$$\Leftrightarrow \hat{z}_{t+1|t} = F \mathbb{E}[z_t | Y_t] + \mathbb{E}[\sigma_{t+1} | Y_t]$$

$$\Leftrightarrow \boxed{\hat{z}_{t+1|t} = F \hat{z}_{t|t}}$$

Pour calculer l'espérance de  $\hat{z}_{t+1}$

sachant l'échantillon jusqu'à la date  $t$ , il faut déjà connaître l'espérance de  $\hat{\Sigma}_t$  sachant l'échantillon jusqu'à la date  $t-1$ . Supposons que l'on connaisse  $\hat{\Sigma}_{t|t-1}$  (cf. l'initialisation de l'algorithme), on veut mettre à jour cette information sur  $\hat{\Sigma}_t$  quand une nouvelle observation ( $y_t$ ) apparaît  $\rightarrow$  Calculer  $\hat{\Sigma}_{t|t}$  en partant de  $\hat{\Sigma}_{t|t-1}$  avec l'information apportée par la nouvelle observation  $y_t$ .

\* Mise à jour des croyances sur  $\hat{\Sigma}_t$

$\hat{\Sigma}_{t|t-1}$  résume ce que nous pouvons dire du vecteur d'état en  $t$  sachant l'échantillon jusqu'à la date  $t-1$  ( $Y_{t-1}$ ). On veut mettre à jour l'inférence sur  $\hat{\Sigma}_t$  quand une

nouvelle information  $y_t$  nous parvienne, ie (19)  
 calculer  $\hat{\Sigma}_{t|t} = \mathbb{E}[\Sigma_t | Y_t]$ . On peut montrer  
 que :

$$\hat{\Sigma}_{t|t} = \hat{\Sigma}_{t|t-1} + \underbrace{P_{t|t-1}}_{\text{covariance}} \underbrace{H'}_{\text{entre les}} \underbrace{\left(HP_{t|t-1}H' + R\right)^{-1}}_{\text{variance de}} \underbrace{\left(y_t - H\hat{\Sigma}_{t|t-1}\right)}_{\text{l'erreur de}} \underbrace{\quad}_{\text{prévision}}$$

$\hat{\Sigma}_{t|t} > \hat{\Sigma}_{t|t-1}$ ssi  
 la prévision sous  
 estime la réalisation

covariance  
 entre les  
 latentes et  
 observables

inverse de la  
 variance de  
 l'erreur de  
 prévision

erreur de  
 prévision

en utilisant les propriétés de la loi  
 normale multivariée, et que l'erreur  
 quadratique moyenne associée est :

$$P_{t|t} = P_{t|t-1} - P_{t|t-1} H' \left( HP_{t|t-1} H' + R \right)^{-1} H P_{t|t-1}$$

$\gg 0$                        $\gg 0$                        $\gg 0$                        $\gg 0$

La variance de l'estimateur des  
 variables latente diminue d'autant  
 plus que la variance des erreurs de  
 prévision est faible -

\* Prédire  $\hat{x}_{t+1}$

(20)

On sait déjà que

$$\hat{x}_{t+1|t} = F \hat{x}_{t|t}$$

en substituant la règle de mise à jour des croyances sur  $\hat{x}$ , il vient:

$$\hat{x}_{t+1|t} = F \hat{x}_{t|t-1} + F P_{t|t-1} H' (H P_{t|t-1} H' + R)^{-1} (y_t - H \hat{x}_{t|t-1})$$

En notant

$$K_t = F P_{t|t-1} H' (H P_{t|t-1} H' + R)^{-1}$$

le gain du filtre de Kalman (qui quantifie ce que nous apprenons des erreurs de prévision), il vient:

$$\hat{x}_{t+1|t} = F \hat{x}_{t|t-1} + K_t (y_t - H \hat{x}_{t|t-1})$$

La variance de cette prévision est:

(21)

$$P_{t+1|t} = \mathbb{E} \left[ \left( \sum_{\tau=t+1}^{\infty} \hat{z}_{\tau|t} \right) \left( \sum_{\tau=t+1}^{\infty} \hat{z}_{\tau|t} \right)' \right]$$

$$\Rightarrow P_{t+1|t} = \mathbb{E} \left[ \left( F \sum_{\tau=t}^{\infty} z_{\tau} + v_t - F \hat{z}_{t|t} \right) \left( F \sum_{\tau=t}^{\infty} z_{\tau} + v_t - F \hat{z}_{t|t} \right)' \right]$$

$$\Rightarrow P_{t+1|t} = F \mathbb{E} \left[ \left( \sum_{\tau=t}^{\infty} z_{\tau} - \hat{z}_{t|t} \right) \left( \sum_{\tau=t}^{\infty} z_{\tau} - \hat{z}_{t|t} \right)' \right] F' + Q$$

$$\Rightarrow \boxed{P_{t+1|t} = F P_{t|t} F' + Q}$$

Finalement, en substituant l'expression pour  $P_{t|t}$ , on obtient:

$$\boxed{P_{t+1|t} = F \left( P_{t|t-1} - P_{t|t-1} H' (H P_{t|t-1} H' + R)^{-1} H P_{t|t-1} \right) F' + Q}$$

l'équation de Ricatti

# RÉSUMÉ DU FILTRE DE KALMAN

(22)

$$\text{Initialisation} \begin{cases} \hat{\mathbf{x}}_{1|0} = \mathbb{E}[\mathbf{x}_t] \\ \hat{\mathbf{P}}_{1|0} = \mathbb{V}[\mathbf{x}_t] \end{cases}$$

moments  
inconditionnels  
d'ordre 1 & 2

$$\left. \begin{aligned} & \bullet K_t = F P_{t|t-1} H' (H P_{t|t-1} H' + R)^{-1} \\ & \bullet \hat{\mathbf{x}}_{t+1|t} = F \hat{\mathbf{x}}_{t|t-1} + K_t (y_t - H \hat{\mathbf{x}}_{t|t-1}) \\ & \bullet P_{t+1|t} = F P_{t|t-1} F' - K_t H P_{t|t-1} + Q \end{aligned} \right\}$$

boucle pour  $t=1, \dots, T$

→ Cet algorithme produit aussi des prévisions pour les observables

$$\hat{y}_{t+1|t} = H \hat{\mathbf{x}}_{t+1|t}$$

→ À partir des erreurs de prévisions sur les observables, on peut construire la fonct° de vraisemblance [ou l'estimateur]