

## II. Cadre probabiliste, estimation bayésienne, cadre linéaire gaussien, filtrage de Wiener, filtrage de Kalman

### TRAITEMENT DE DONNÉES ET STATISTIQUES

#### ■ Bruit

$$\mathbf{z} = \phi(\mathbf{x}, \mathbf{b}) \quad (\text{par exemple : } \mathbf{z} = \mathbf{H}\mathbf{x} + \mathbf{b})$$

par définition,  $\mathbf{b}$  mal connu  $\rightsquigarrow$  modèle statistique, *e.g.*, loi à densité  $f_{\mathbf{B}}$

#### ■ Vraisemblance (bruit additif à densité)

$$f(\mathbf{z} | \mathbf{x}) = f_{\mathbf{B}}(\mathbf{z} - \mathbf{H}\mathbf{x}) \quad (\text{modèle linéaire})$$

$$\text{anti-log-vraisemblance : } V(\mathbf{z} | \mathbf{x}) = -\ln f(\mathbf{z} | \mathbf{x})$$

Estimateur du *maximum de vraisemblance (MV)* :

$$\hat{\mathbf{x}}^{\text{MV}} = \arg \max_{\mathbf{x}} f(\mathbf{z} | \mathbf{x}) = \arg \min_{\mathbf{x}} V(\mathbf{z} | \mathbf{x})$$

$$\mathbf{z} = \mathbf{H}\mathbf{x} + \mathbf{b}, \quad \mathbf{b} \text{ réalisation de } \mathcal{N}(\mathbf{m}_b, \mathbf{R}_b)$$

$$\hat{\mathbf{x}}^{\text{MV}} = \arg \min_{\mathbf{x}} (\mathbf{z} - \mathbf{H}\mathbf{x} - \mathbf{m}_b)^t \mathbf{R}_b^{-1} (\mathbf{z} - \mathbf{H}\mathbf{x} - \mathbf{m}_b)$$

$$\leadsto \text{équation normale : } (\mathbf{H}^t \mathbf{R}_b^{-1} \mathbf{H}) \hat{\mathbf{x}}^{\text{MV}} = \mathbf{H}^t \mathbf{R}_b^{-1} (\mathbf{z} - \mathbf{m}_b)$$

Cas particuliers :

- $\mathbf{m}_b = \mathbf{0}, \mathbf{R}_b \propto \mathbf{I} \Rightarrow \hat{\mathbf{x}}^{\text{MV}} = \arg \min \|\mathbf{z} - \mathbf{H}\mathbf{x}\|^2 = \hat{\mathbf{x}}^{\text{MC}}$
- $\mathbf{m}_b = \mathbf{0}, \mathbf{R}_b = \text{diag} \{ \sigma_1^2, \dots, \sigma_N^2 \} \Rightarrow \text{MC pondérés :}$

$$\hat{\mathbf{x}}^{\text{MV}} = \arg \min \sum_{n=1}^N \frac{(z_n - [\mathbf{H}\mathbf{x}]_n)^2}{\sigma_n^2}$$

### AUTRES BRUITS : EXEMPLES

#### ■ Bruit additif de Laplace

$$\mathbf{z} = \mathbf{H}\mathbf{x} + \mathbf{b} \text{ et } f_B(\mathbf{b}) = \prod_{n=1}^N \frac{\alpha}{2} \exp(-\alpha |b_n|)$$

$$\Rightarrow \text{Estimateur } L^1 : \hat{\mathbf{x}}^{\text{MV}} = \arg \min \sum_{n=1}^N |z_n - [\mathbf{H}\mathbf{x}]_n|$$

*Application* : estimateur plus robuste aux données aberrantes

#### ■ Bruit de Poisson : $P(z_n = k) = e^{-\phi_n(\mathbf{x})} \phi_n(\mathbf{x})^k / k!, \quad k \in \mathbb{N}$

*Applications* : tomographie à émission de positon, astronomie

#### ■ Bruit multiplicatif : $z_n = \phi_n(\mathbf{x}) b_n, \quad 1 \leq n \leq N$

$$\text{bruit gaussien réduit : } V(\mathbf{z} | \mathbf{x}) = \sum_{n=1}^N \frac{z_n^2}{2\phi_n^2(\mathbf{x})} + \ln |\phi_n^2(\mathbf{x})|$$

*Applications* : astronomie ( $\approx$  Poisson à nb de photons élevé)

## ■ Règle de Bayes

$$f(\mathbf{x} | \mathbf{z}) = \frac{f(\mathbf{z} | \mathbf{x})f(\mathbf{x})}{f(\mathbf{z})} \propto f(\mathbf{z} | \mathbf{x})f(\mathbf{x})$$

$f(\mathbf{x})$  : loi *a priori* sur  $\mathbf{x}$ , résume les informations disponibles sur l'objet *avant* la mesure

## ■ Décision $f(\mathbf{x} | \mathbf{z}) \overset{?}{\rightsquigarrow} \hat{\mathbf{x}}$

- Espérance *a posteriori* :  $\hat{\mathbf{x}}^{\text{EAP}} = \text{E}[\mathbf{X} | \mathbf{Z} = \mathbf{z}]$
- Maximum *a posteriori* :  $\hat{\mathbf{x}}^{\text{MAP}} = \arg \max_{\mathbf{x}} f(\mathbf{x} | \mathbf{z})$
- MAP Marginal :  $\hat{x}_m^{\text{MAPM}} = \arg \max_{x_m} f(x_m | \mathbf{z}), \quad 1 \leq m \leq M$
- Estimateur linéaire à risque minimal :  $\hat{\mathbf{x}}^{\text{ELMQ}} = \mathbf{R}_{\mathbf{xz}} \mathbf{R}_{\mathbf{z}}^{-1} (\mathbf{Z} - \mathbf{m}_{\mathbf{z}}) + \mathbf{m}_{\mathbf{x}}$

## ■ $\hat{\mathbf{x}}^{\text{MV}} = \hat{\mathbf{x}}^{\text{MAP}}$ pour une loi *a priori* uniforme

$$\begin{aligned} \hat{\mathbf{x}}^{\text{MAP}} &= \arg \max_{\mathbf{x}} f(\mathbf{x} | \mathbf{z}) \\ &= \arg \min_{\mathbf{x}} V(\mathbf{z} | \mathbf{x}) - \ln f(\mathbf{x}) \end{aligned}$$

Le MAP est une solution régularisée obtenue par pénalisation

## ■ Correspondances

« énergétiques »	↔	probabilistes
$F(\mathbf{x}, \mathbf{z})$	$\longleftrightarrow$	$f(\mathbf{x}, \mathbf{z}) = \frac{\exp -F(\mathbf{x}, \mathbf{z})}{\int_{\mathbf{x}, \mathbf{z}} \exp -F(\mathbf{x}, \mathbf{z}) \, d\mathbf{x} \, d\mathbf{z}}$
$\hat{\mathbf{x}}_p = \arg \min_{\mathbf{x}} F(\mathbf{x}, \mathbf{z})$	$=$	$\hat{\mathbf{x}}^{\text{MAP}} = \arg \max_{\mathbf{x}} f(\mathbf{x}, \mathbf{z})$
?	$=$	Espérance conditionnelle (régression)
?	$=$	Marginalisation

$z = \mathbf{H}x + b$ ,  $b \sim \mathcal{N}(m_b, \mathbf{R}_b)$ ,  $x \sim \mathcal{N}(m_x, \mathbf{R}_x)$ ,  $(x, b)$  indépendant

⇓

*Anti-log-vraisemblance a posteriori*

$$L(x | z) \propto \frac{1}{2} \|z - \mathbf{H}x - m_b\|_{\mathbf{R}_b^{-1}}^2 + \frac{1}{2} \|x - m_x\|_{\mathbf{R}_x^{-1}}^2$$

*Forme information :*

$$\hat{x}^{\text{MAP}} = (\mathbf{H}^t \mathbf{R}_b^{-1} \mathbf{H} + \mathbf{R}_x^{-1})^{-1} (\mathbf{H}^t \mathbf{R}_b^{-1} (z - m_b) + \mathbf{R}_x^{-1} m_x)$$

*Forme covariance :*

$$\hat{x}^{\text{MAP}} = m_x + \mathbf{R}_x \mathbf{H}^t (\mathbf{R}_b + \mathbf{H} \mathbf{R}_x \mathbf{H}^t)^{-1} (z - \mathbf{H} m_x - m_b)$$

## ■ Lemme d'inversion de matrice

Soit  $\mathbf{A} (N, N)$  ;  $\mathbf{B} (N, M)$  ;  $\mathbf{C} (M, M)$  ;  $\mathbf{D} (M, N)$ .

Sous réserve d'inversibilité,

$$(\mathbf{A} + \mathbf{BCD})^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1} \mathbf{B} (\mathbf{C}^{-1} + \mathbf{DA}^{-1} \mathbf{B})^{-1} \mathbf{DA}^{-1}$$

- Corrolaires

$$\mathbf{D} (\mathbf{A} + \mathbf{BCD})^{-1} = \mathbf{C}^{-1} (\mathbf{C}^{-1} + \mathbf{DA}^{-1} \mathbf{B})^{-1} \mathbf{DA}^{-1}$$

$$\mathbf{CD} (\mathbf{A} + \mathbf{BCD})^{-1} = (\mathbf{C}^{-1} + \mathbf{DA}^{-1} \mathbf{B})^{-1} \mathbf{DA}^{-1}$$

Soit  $\mathbf{X}$ ,  $\mathbf{Z}$  de moyennes  $\mathbf{m}_x$ ,  $\mathbf{m}_z$ , de covariances  $\mathbf{R}_x$ ,  $\mathbf{R}_z$ , d'intercovariance  $\mathbf{R}_{xz}$  et soit

$$\begin{aligned}\widehat{\mathbf{X}} &= \mathbf{R}_{xz}\mathbf{R}_z^{-1}(\mathbf{Z} - \mathbf{m}_z) + \mathbf{m}_x \\ \mathbf{\Gamma} &= \mathbf{R}_x - \mathbf{R}_{xz}\mathbf{R}_z^{-1}\mathbf{R}_{zx}\end{aligned}$$

- ①  $\widehat{\mathbf{X}}$  possède un biais moyen nul et une matrice de covariance d'erreur moyenne égale à  $\mathbf{\Gamma}$ .
- ②  $\widehat{\mathbf{X}}$  minimise le risque quadratique moyen parmi les estimateurs de structure affine ( $\widehat{\mathbf{X}} = \widehat{\mathbf{x}}^{\text{ELMQ}}$ ). Le minimum atteint est Trace  $\mathbf{\Gamma}$ .
- ③ Si de plus  $(\mathbf{X}, \mathbf{Z})$  est gaussien, alors la loi *a posteriori*  $f_{\mathbf{X} | \mathbf{Z}=\mathbf{z}}$  est gaussienne de moyenne  $\widehat{\mathbf{X}} = \widehat{\mathbf{x}}^{\text{EAP}} = \widehat{\mathbf{x}}^{\text{MAP}} = \widehat{\mathbf{x}}^{\text{MMAP}}$  et de covariance  $\mathbf{\Gamma}$ .

### ■ Application

$\mathbf{Z} = \mathbf{H}\mathbf{X} + \mathbf{B}$  avec  $(\mathbf{X}, \mathbf{B})$  décorréolé donne les résultats du cadre linéaire gaussien pour  $\widehat{\mathbf{X}}$  et

$$\begin{aligned}\mathbf{\Gamma} &= \mathbf{R}_x - \mathbf{R}_x\mathbf{H}^t(\mathbf{H}\mathbf{R}_x\mathbf{H}^t + \mathbf{R}_b)^{-1}\mathbf{H}\mathbf{R}_x \\ &= (\mathbf{H}^t\mathbf{R}_b^{-1}\mathbf{H} + \mathbf{R}_x^{-1})^{-1}\end{aligned}$$

### ■ Remarque

Le biais (au sens « classique ») s'écrit

$$\mathbb{E}[\widehat{\mathbf{X}} | \mathbf{X}] - \mathbf{X} = (\mathbf{H}^t\mathbf{R}_b^{-1}\mathbf{H} + \mathbf{R}_x^{-1})^{-1}(\mathbf{H}^t\mathbf{R}_b^{-1}\mathbf{H}\mathbf{X} + \mathbf{R}_x^{-1}\mathbf{m}_x) - \mathbf{X}$$

Il est nul pour «  $\mathbf{R}_x^{-1} = 0$  », c'est-à-dire pour  $\widehat{\mathbf{x}}^{\text{MV}}$ , solution non régularisée !

$$\mathbb{E}[\|\widehat{\mathbf{X}} - \mathbf{X}\|^2 | \mathbf{X}] = \|\text{biais}\|^2 + \text{Trace Cov}(\widehat{\mathbf{X}} | \mathbf{X})$$

- Soit  $X = \{X_n\}_{\mathbb{Z}}$ ,  $Z = \{Z_n\}_{\mathbb{Z}}$  signaux conjointement stationnaires faibles centrés de corrélation  $r_x$ ,  $r_z$  et d'intercorrélation  $r_{xz}$ .

Soit  $g$  un filtre tel que  $r_{xz} = g \star r_z$ . Alors  $\hat{X} = g \star Z$  minimise à tout instant  $n$  le risque moyen  $E [(\hat{X}_n - X_n)^2]$  parmi les estimateurs linéaires.

Application :  $Z = h \star X + B$ , avec  $(X, B)$  décorrelés :

$$\forall \nu, \quad G(\nu) = \frac{H^*(\nu)\Gamma_x(\nu)}{|H(\nu)|^2 \Gamma_x(\nu) + \Gamma_b(\nu)}$$


### ■ Utilisation « courante »

- ① Si  $X$  et  $B$  sont blancs de puissance  $\sigma_x^2$  et  $\sigma_b^2$ ,

$$\forall \nu, \quad G(\nu) = \frac{H^*(\nu)}{|H(\nu)|^2 + \sigma_b^2/\sigma_x^2}$$

- ② Application au cas fini par circularisation et **fft**  
 $\leftrightarrow$  Approche PTT pour  $\mathbf{Q} = \mathbf{I}$  et  $\alpha = \sigma_b^2/\sigma_x^2$  !

Trait plein :  $|H(\nu)|$   
 Trait mixte :  $|G(\nu)|$   
 Tireté :  $|H(\nu)G(\nu)|$




### EXEMPLE EN ASTRONOMIE


#### ■ Observation à travers l'atmosphère

[extraits d'une communication a SPIE'97, ONERA]


Mots-clés :

- Ouverture télescopique
- Turbulence atmosphérique
- Optique adaptative
- Déconvolution





observation avec  
optique adaptative



optique adaptative  
+ déconvolution quadratique

## FILTRAGE DE KALMAN (1960)

### ■ Premières applications

Asservissement de trajectoire : Apollo, Polaris (1960-65), puis Voyager, ...



Pour des observations vectorielles successives  $\mathbf{z}_0, \dots, \mathbf{z}_k$ , le filtre de Kalman calcule **récurivement** le meilleur estimateur **linéaire** d'un processus vectoriel  $\mathbf{X}_0, \dots, \mathbf{X}_k$  au sens du risque moyen minimum :

$$\hat{\mathbf{X}}_{k|k} \triangleq \text{EL} [\mathbf{X}_k | \mathbf{Z}_0, \dots, \mathbf{Z}_k] \text{ minimise } \text{E} [\|\hat{\mathbf{X}} - \mathbf{X}_k\|^2]$$



Équation d'observation	$\mathbf{Z}_k = \mathbf{H}_k \mathbf{X}_k + \mathbf{B}_k$
Équation d'état	$\mathbf{X}_{k+1} = \mathbf{F}_k \mathbf{X}_k + \mathbf{G}_k \mathbf{U}_k$
Conditions initiales	$E[\mathbf{X}_0, \mathbf{B}_k, \mathbf{U}_k] = \mathbf{0}$
(simplifiées)	$E[\mathbf{B}_k \mathbf{B}_l^t] = \mathbf{R}_k \delta_{kl}, \quad E[\mathbf{U}_k \mathbf{U}_l^t] = \mathbf{Q}_k \delta_{kl},$
	$\text{cov}(\mathbf{X}_0) = \mathbf{P}_0, \quad (\mathbf{X}_0, \mathbf{B}_k, \mathbf{U}_l) \text{ décorrés}$

■ Cas particuliers en signal

- $\mathbf{Z}_k = Z_k = \mathbf{h}^t \mathbf{X}_k + b_k$  convolution bruitée,  $\mathbf{h}$  RIF de taille  $M$ ,  
 $\mathbf{X}_k = [X_k, \dots, X_{k-M+1}]^t$  extrait d'un signal AR d'ordre  $L < M$  :

$$X_k = \sum_{l=1}^L a_l X_{k-l} + U_k$$

$$\Leftrightarrow \mathbf{X}_{k+1} = \mathbf{F} \mathbf{X}_k + \mathbf{G} U_{k+1},$$

avec  $\mathbf{F} = \begin{bmatrix} a_1 & \dots & a_L & 0 & \dots & 0 \\ 1 & & & & & \\ & \mathbf{0} & \ddots & & & \\ & & & 1 & 0 & \end{bmatrix}$  et  $\mathbf{G} = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$

- Extensions inhomogènes  
 ... vis-à-vis de la convolution, du bruit d'observation, du modèle AR.

- Étape de remise à jour

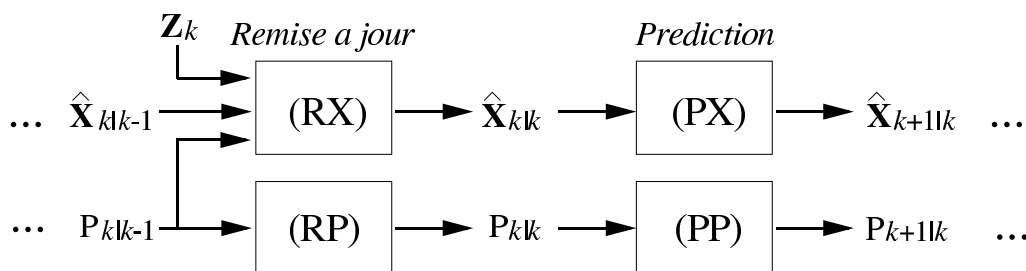
$$(RX) \quad \hat{\mathbf{X}}_{k|k} = \hat{\mathbf{X}}_{k|k-1} + \mathbf{P}_{k|k-1} \mathbf{H}_k^t (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^t + \mathbf{R}_k)^{-1} (\mathbf{Z}_k - \mathbf{H}_k \hat{\mathbf{X}}_{k|k-1})$$

$$(RP) \quad \mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{P}_{k|k-1} \mathbf{H}_k^t (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^t + \mathbf{R}_k)^{-1} \mathbf{H}_k \mathbf{P}_{k|k-1}$$

- Étape de prédiction


$$(PX) \quad \hat{\mathbf{X}}_{k+1|k} = \mathbf{F}_k \hat{\mathbf{X}}_{k|k}$$

$$(PP) \quad \hat{\mathbf{P}}_{k+1|k} = \mathbf{F}_k \mathbf{P}_{k|k} \mathbf{F}_k^t + \mathbf{G}_k \mathbf{Q}_k \mathbf{G}_k^t$$




## ■ Principe géométrique de la démonstration

Étape de remise à jour



Étape de prédiction



Les dimensions vectorielles sont réduites pour la clarté des schémas. Si  $\mathbf{Z}_k$  possède  $N$  composantes,  $\mathcal{V}_k = \text{Vect}(\mathbf{Z}_0, \dots, \mathbf{Z}_k)$  est de dimension maximale  $(k+1)N$  et  $\dim \text{Vect}(\mathbf{E}_k) \leq N$ . D'autre part  $\mathbf{X}_k$  est un vecteur de taille  $M$  qui doit être projeté composante par composante.

- Lisseur à *intervalle fixe* LdK(IF) :  $\hat{\mathbf{X}}_{k|K}$ 
  - ① Étant donné  $\mathbf{Z}_0, \dots, \mathbf{Z}_K$ , appliquer le FdK jusqu'à  $k = K$  ;
  - ② Pour  $k = K - 1, \dots, 0$  :
 
$$\hat{\mathbf{X}}_{k|K} = \hat{\mathbf{X}}_{k|k} + \mathbf{P}_{k|k} \mathbf{F}_k^t \mathbf{P}_{k|k+1}^{-1} (\hat{\mathbf{X}}_{k+1|K} - \hat{\mathbf{X}}_{k+1|k})$$

- Lisseur à *retard fixe* LdK(RF) :  $\hat{\mathbf{X}}_{k|k+D}$

Calcul par la méthode de la *chaîne serpent* :

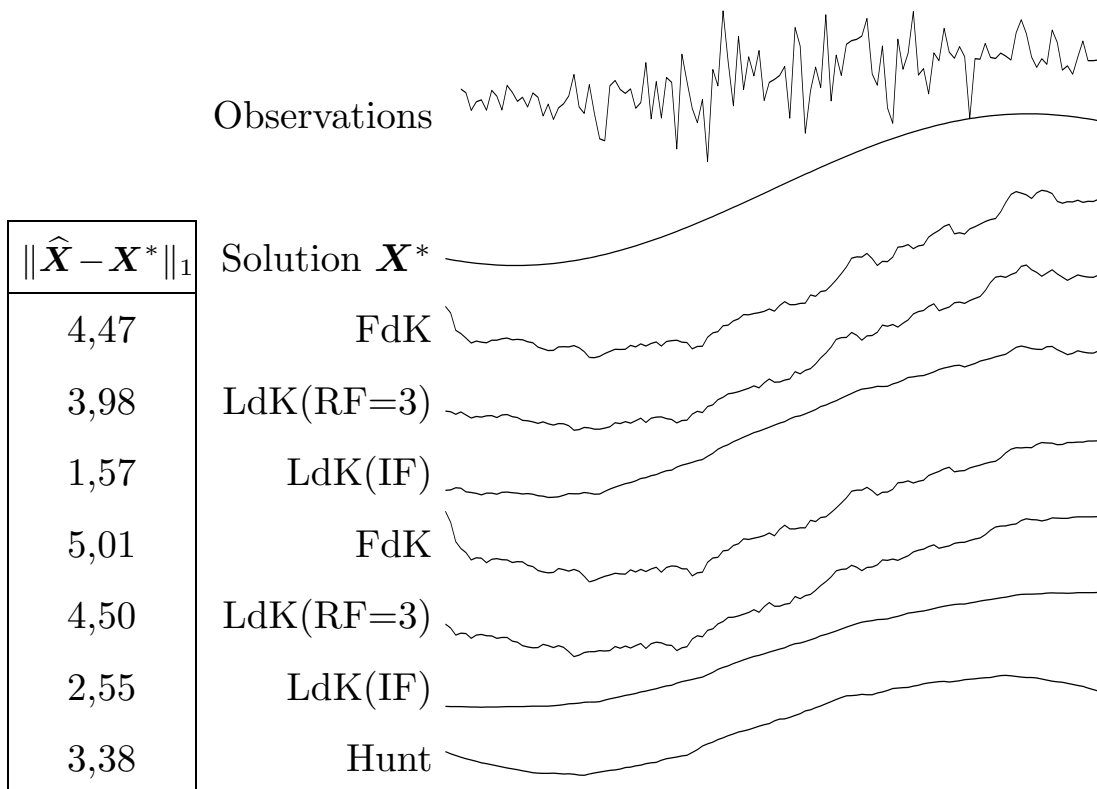
- ① Réécrire les équations d'état pour le vecteur étendu

$$\mathcal{X}_k = (\mathbf{X}_k, \dots, \mathbf{X}_{k-D});$$

- ② Appliquer le FdK et conserver la dernière composante de

$$\hat{\mathcal{X}}_{k|k} = (\hat{\mathbf{X}}_{k|k}, \dots, \hat{\mathbf{X}}_{k-D|k})$$

## ■ Exemple en déconvolution (bruit d'observation inhomogène)



- FdK, LdK(IF) et LdK(RF) permettent des modèles inhomogènes.
- LdK(IF) minimise (d'après ③ dans Gauss-Markov) non récursivement

$$L(x_0, \dots, x_K | z_0, \dots, z_K) \# \sum_{k=0}^K \frac{(z_k - h_k^t \mathbf{x}_k)^2}{r_k} + \sum_{k=1}^K \frac{(x_k - \mathbf{a}_k^t \mathbf{x}_k)^2}{q_k} + \mathbf{x}_0^t \mathbf{P}_0^{-1} \mathbf{x}_0$$

- LdK(RF) est un bon compromis entre FdK et LdK(IF).
- Il existe des formes *rapides* pour les équations d'états homogènes.

[DEMOMENT 1989]

- 
- [DEMOMENT 1989] G. DEMOMENT (1989), « Équations de Chandrasekhar et algorithmes rapides pour le traitement du signal et des images », *Traitement du Signal*, **6**, 103-115.
- [JAZWINSKI 1970] A. H. JAZWINSKI (1970), *Stochastic process and filtering theory*, Academic Press, New York, NY, USA.