


Filtres de Kalman : lissage de données et estimation de paramètres

Philippe Ricka

27 septembre 2018



— état réel x_k • observation y_k

Que peut-on tirer des observations y_k ?

Modèle

On suppose :

- $\exists (f_k)_k, \forall k \in \mathbb{N},$

$$x_{k+1} = f_k(x_k) + w_k$$

où $w_k \sim \mathcal{N}(0, R_k)$

- $\exists (h_k)_k, \forall k \in \mathbb{N},$

$$y_k = h_k(x_k) + v_k$$

où $v_k \sim \mathcal{N}(0, Q_k)$

Modèle

On suppose :

- $\exists (f_k)_k, \forall k \in \mathbb{N},$

$$x_{k+1} = f_k(x_k) + w_k$$

où $w_k \sim \mathcal{N}(0, R_k)$

- $\exists (h_k)_k, \forall k \in \mathbb{N},$

$$y_k = h_k(x_k) + v_k$$

où $v_k \sim \mathcal{N}(0, Q_k)$

Modèle

On suppose :

- $\exists (f_k)_k, \forall k \in \mathbb{N},$

$$x_{k+1} = f_k(x_k) + w_k$$

où $w_k \sim \mathcal{N}(0, R_k)$

- $\exists (h_k)_k, \forall k \in \mathbb{N},$

$$y_k = h_k(x_k) + v_k$$

où $v_k \sim \mathcal{N}(0, Q_k)$

Dynamique

$f_k \longleftarrow$ connaissance de la dynamique du phénomène

$w_k \longleftarrow$ ce qu'on *ne connaît pas* sur la dynamique : bruit Gaussien

- Souvent, $f_k(x) = f(x, \theta_k)$ où θ_k est un paramètre du modèle
- Si on ne sait rien de la physique, on prend $f_k = Id, \forall k \in \mathbb{N}$

Dynamique

$f_k \longleftarrow$ connaissance de la dynamique du phénomène

$w_k \longleftarrow$ ce qu'on *ne connaît pas* sur la dynamique : bruit Gaussien

- Souvent, $f_k(x) = f(x, \theta_k)$ où θ_k est un paramètre du modèle
- Si on ne sait rien de la physique, on prend $f_k = Id, \forall k \in \mathbb{N}$

Dynamique

$f_k \longleftarrow$ connaissance de la dynamique du phénomène

$w_k \longleftarrow$ ce qu'on *ne connaît pas* sur la dynamique : bruit Gaussien

- Souvent, $f_k(x) = f(x, \theta_k)$ où θ_k est un paramètre du modèle
- Si on ne sait rien de la physique, on prend $f_k = Id, \forall k \in \mathbb{N}$

Observation

h_k \leftarrow fonction d'observation : décrit les infos disponibles sur l'état

v_k \leftarrow erreur de mesure : bruit Gaussien

- Si on observe directement l'état, on a :

$$h_k = Id, \forall k \in \mathbb{N}$$

En bref

On dispose a priori :

- de mesures $(y_k)_k$
- d'une info sur la confiance qu'on accorde aux mesures Q_k
- d'un modèle physique $(f_k)_k$
- d'une estimation initiale de l'état x_0^f

En bref

On dispose a priori :

- de mesures $(y_k)_k$
- d'une info sur la confiance qu'on accorde aux mesures Q_k
- d'un modèle physique $(f_k)_k$
- d'une estimation initiale de l'état x_0^f

En bref

On dispose a priori :

- de mesures $(y_k)_k$
- d'une info sur la confiance qu'on accorde aux mesures Q_k
- d'un modèle physique $(f_k)_k$
- d'une estimation initiale de l'état x_0^f

En bref

On dispose a priori :

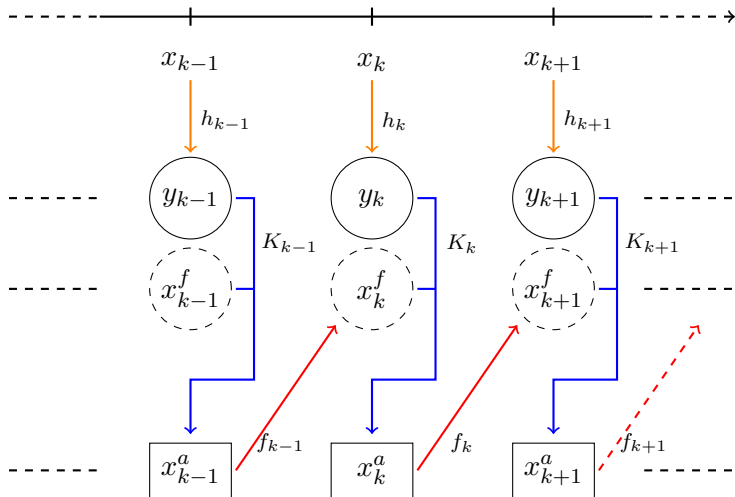
- de mesures $(y_k)_k$
- d'une info sur la confiance qu'on accorde aux mesures Q_k
- d'un modèle physique $(f_k)_k$
- d'une estimation initiale de l'état x_0^f

En bref

On dispose a priori :

- de mesures $(y_k)_k$
- d'une info sur la confiance qu'on accorde aux mesures Q_k
- d'un modèle physique $(f_k)_k$
- d'une estimation initiale de l'état x_0^f

Idée générale



Modèle

Le filtre de Kalman discret :

- f_k est linéaire de matrice A_k
- h_k est linéaire de matrice H_k

$$\begin{cases} x_{k+1} = A_k x_k + w_k \\ y_k = H_k x_k + v_k \end{cases}$$

Modèle

Le filtre de Kalman discret :

- f_k est linéaire de matrice A_k
- h_k est linéaire de matrice H_k

$$\begin{cases} x_{k+1} = A_k x_k + w_k \\ y_k = H_k x_k + v_k \end{cases}$$

Modèle

Le filtre de Kalman discret :

- f_k est linéaire de matrice A_k
- h_k est linéaire de matrice H_k

$$\begin{cases} x_{k+1} = A_k x_k + w_k \\ y_k = H_k x_k + v_k \end{cases}$$

Analyse

Au temps k , on dispose :

- d'une mesure y_k
- d'une prévision de l'état courant x_k^f (issue du temps $k - 1$)

Analyse “optimale” des données :

$$x_k^a = L_k x_k^f + G_k y_k$$

où L et G sont des matrices à définir.

Erreurs

On définit :

- l'erreur de prédiction :

$$e_k^f = x_k^f - x_k$$

- l'erreur d'analyse :

$$e_k^a = x_k^a - x_k$$

Proposition :

Si $\mathbb{E}(e_k^f) = 0$ et si $L_k = I - G_k H_k$, alors :

$$\mathbb{E}(e_k^a) = 0$$

Covariances d'erreurs

On définit :

- la covariance de l'erreur de prédiction :

$$P_k^f = \mathbb{E}(e_k^f \cdot^T e_k^f)$$

- la covariance de l'erreur d'analyse :

$$P_k^a = \mathbb{E}(e_k^a \cdot^T e_k^a)$$

Gain de Kalman

Proposition :

$$P_k^a = (I - G_k H_k) P_k^f \text{ }^T (I - G_k H_k) + G_k R_k \text{ }^T G_k$$

$$P_{k+1}^f = A_k P_k^a \text{ }^T A_k - Q_k$$

Le gain de Kalman est $K_k = \operatorname{argmin}(G \mapsto \operatorname{Tr}(P_k^a))$.

Théorème :

$$\begin{aligned} K_k &= P_k^f \text{ }^T H_k \left(H_k P_k^f \text{ }^T H_k + R_k \right)^{-1} \\ &= P_{xy_k} \quad P_{yy_k}^{-1} \end{aligned}$$

En résumé

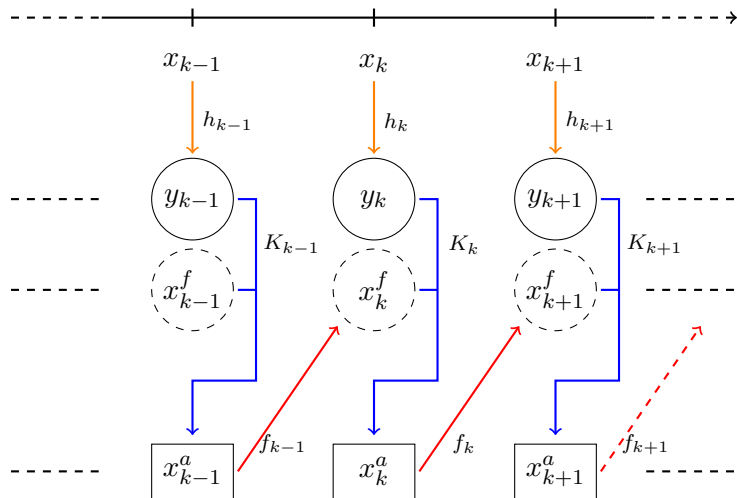
Analyse


$$\left| \begin{aligned} K_k &= P_{xy_k} P_{yy_k}^{-1} \\ x_k^a &= x_k^f + K_k (y_k - H_k x_k^f) \\ P_k^a &= (I - K_k H_k) P_k^f \end{aligned} \right.$$


Prévision

$$\left| \begin{aligned} x_{k+1}^f &= A_k x_k^a \\ P_{k+1}^f &= A_k P_k^a A_k^T + Q_k \end{aligned} \right.$$

Rappel







Incertitude modélisée par une Gaussienne

Deux stratégies :

- Monte-Carlo \rightarrow Ensemble Kalman Filter (EnKF)
- “précis et efficace” \rightarrow Uhlmann-Kalman Filter (UKF)

Incertitude modélisée par une Gaussienne

Deux stratégies :

- Monte-Carlo \longrightarrow Ensemble Kalman Filter (EnKF)
- “précis et efficace” \longrightarrow Uhlmann-Kalman Filter (UKF)

Incertitude modélisée par une Gaussienne

Deux stratégies :

- Monte-Carlo \longrightarrow Ensemble Kalman Filter (EnKF)
- “précis et efficace” \longrightarrow Uhlmann-Kalman Filter (UKF)

Sigma-points

État estimé $x_k^f \mapsto \mathcal{N}(x_k^f, \Sigma_{x_k}) \longrightarrow$ on propage une gaussienne, représentée par un ensemble pondéré de $2n + 1$ points :

$$\begin{aligned}
 X_0 &= x_k^f & W_0 &= \frac{\kappa}{n + \kappa} \\
 X_i &= x_k^f + \left[\sqrt{(n + \kappa) \Sigma_{\mathbf{x}}} \right]_i & W_i &= \frac{1}{2(n + \kappa)} \\
 X_{n+i} &= x_k^f - \left[\sqrt{(n + \kappa) \Sigma_{\mathbf{x}}} \right]_i & W_{n+i} &= \frac{1}{2(n + \kappa)}
 \end{aligned}$$

On note de plus $Y_i = h_k(X_i)$ et \bar{Y} leur moyenne.

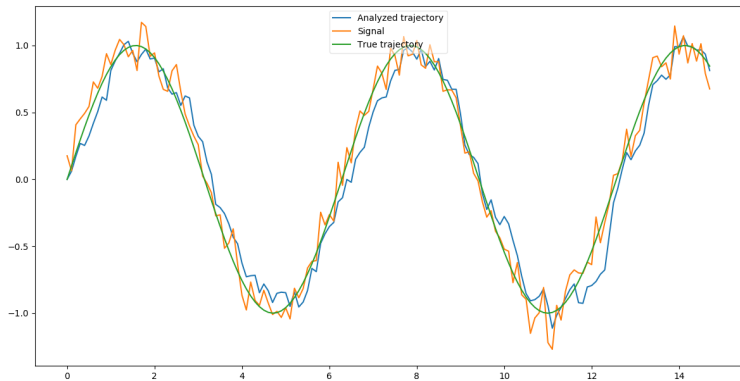
Gain de Kalman

Dans ce contexte, on définit :

$$P_{xy_k} = \sum_{i=0}^{2n+1} W_i (X_i - x_k^f)(Y_i - \bar{Y})$$

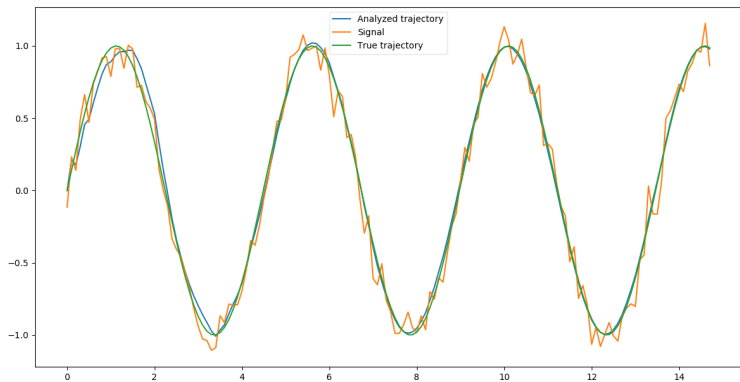
$$P_{yy_k} = \sum_{i=0}^{2n+1} W_i (Y_i - \bar{Y})(Y_i - \bar{Y}) + R_k$$

Estimation de l'état, marche aléatoire)




$$\begin{array}{l}
 t \mapsto \sin(t) \quad f(x) = x \quad h(x) = x \\
 dt = 0.1 \quad R_k = 0 \quad Q_k = 0.1
 \end{array}
 \left| \begin{array}{l}
 \text{erreur } L^2 \text{ relative} \\
 0.22
 \end{array}
 \right.$$

Estimation de l'état, physique connue



erreur L^2 relative : 0.14

Estimation du paramètre



erreur quadratique finale : $4.8 \cdot 10^{-3}$

Merci pour votre attention !