

# Formation et Analyse d'Images

James L. Crowley

ENSIMAG 3

Premier Bimestre 2006/2007

Séance 9

24 novembre 2006

## Suivi et estimation de mouvements Le filtre de Kalman

### Plan de la Séance :

Le Filtre de Kalman.....	2
Prédiction de l'évolution temporelle de l'état.....	4
Modèle du capteur.....	6
Aproximations des modèle non-linéaires.....	6
Validation.....	8
Mise à Jour.....	9
Le Matrice de Gain K .....	10

## Le Filtre de Kalman

Le filtre de Kalman est un estimateur récursif optimal.

Son origine se trouve dans le problème de l'estimation de la trajectoire des satellites et des avions. Dans un tel problème, on cherche à estimer la position  $(x, y, z)$  et la vitesse  $(v_x, v_y, v_z)$  à partir de l'observation de deux angles : Site et azimut. ( , )

Dans la terminologie de Kalman : la position et vitesse est un vecteur d'état :  $X$  et l'observation est  $Y$

$$X = \begin{pmatrix} x \\ y \\ z \\ v_x \\ v_y \\ v_z \end{pmatrix} \quad Y =$$

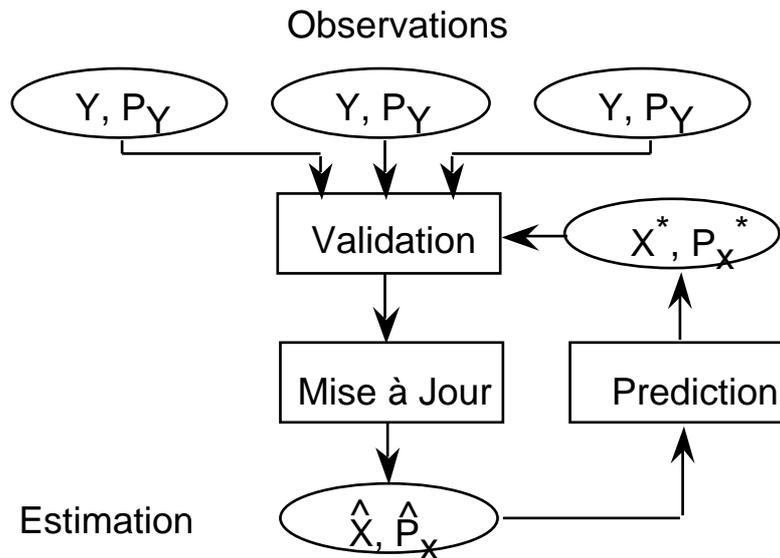
Pour chaque instant,  $t$ , le filtre donne une estimation  $\hat{X}_t$  ainsi que sa précision  $P_t$ , à partir de l'observation et l'estimation précédente,  $\hat{X}_{t-1}$ ,  $P_{t-1}$ , et l'observation  $Y$ , et sa précision,  $P_y$ . Les précisions sont des covariances.

$$\hat{X}_t, P_t := F \{ \hat{X}_{t-1}, P_{t-1}, Y, P_y \}$$

Ce permet d'estimer un vecteur de  $N$  variable aléatoire à partir de  $M < N$  observations. Les précisions sont des 2ieme moments de l'erreur.

Le filtre récursif est un processus cyclique avec 5 phases :

- 1) Prédiction de l'évolution temporelle de l'état.
- 2) Observation
- 3) Prédiction de l'observation
- 4) Validation de l'observation.
- 5) Mise à jour de l'estimation.



Techniques :

- Prédictions:           Modèle Linéaire
- validation :         Distance de Mahalanobis  
(Distance normalisée par Covariance)
- Mise à Jour           Estimation linéaire

Notation:

- Vecteur d'état a temp t :        $X_t$
- Estimation du vecteur d'état :    $\hat{X}_t, \hat{P}_t$
- Observation :                    $Y, P_y$
- Prédiction :                      $X_t^*, P_t^*$
- Modèle du capteur :              $H_X^Y$  avec précision  $P_y$
- Modèle du processus :           ( t ) avec précision  $Q_t$
- Affectation :                    :=
- Définition :

Le modèle de Kalman suppose que les estimations sont corrompues par un bruit B.

$$\hat{X} = X + B$$

Le bruit est une variable aléatoire de moyenne nul.  
La précision est le deuxième moment de ce bruit.

$$P = E\{ B B^T \} = E\{ (X - \hat{X})(X - \hat{X})^T \}$$

On ne peut connaître ni  $X$  ni  $B$ . Kalman nous fourni les estimations  $\hat{P}_t$

## Prédiction de l'évolution temporelle de l'état

La phase de prédiction projette  $\hat{X}_{t-1}$  et  $\hat{P}_{t-1}$  à temps  $t$  afin de produire  $X_t^*$  et  $P_t^*$

On inclut les dérivées temporelles des paramètres dans le vecteur d'état.  $\hat{X}_{t-1}$

Soit une propriété,  $\hat{x}$ , du vecteur  $\hat{X}$ , avec variance  $\hat{x}^2$ .

La prédiction de premier ordre  $x^*(t)$  exige la dérivée temporelle  $\hat{x}'(t-1)$ .

$$\hat{x}'_t \cong \frac{\hat{x}_t}{t}$$

Par série de Taylor, on peut écrire :

$$x^*_t := \hat{x}_{t-1} + \hat{x}'_{t-1} t + r$$

avec l'hypothèse que  $E\{r\} = 0$ .

Soit un vecteur de deux propriétés  $\hat{x}_1$  et  $\hat{x}_2$  avec une prédiction de premier ordre.

$$\hat{X}_t = \begin{pmatrix} \hat{x}_1 \\ \hat{x}_1' \\ \hat{x}_2 \\ \hat{x}_2' \end{pmatrix}$$

La prédiction est :  $X^*_t := (t)X_{t-1} + R$

avec le matrice de transition,  $(t) = \begin{pmatrix} 1 & t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & t \\ 0 & 0 & 0 & 1 \end{pmatrix}$

La précision de  $X^*_t$  est la covariances les propriétés  $\hat{x}$

$$P_t^* \cong \begin{pmatrix} \hat{x}_1^2 & \hat{x}_1'x_1 & \hat{x}_2x_1 & \hat{x}_2'x_1 \\ \hat{x}_1x_1' & \hat{x}_1'^2 & \hat{x}_2x_1' & \hat{x}_2'x_1' \\ \hat{x}_1x_2 & \hat{x}_1'x_2 & \hat{x}_2^2 & \hat{x}_2'x_2 \\ \hat{x}_1x_2' & \hat{x}_1'x_2' & \hat{x}_2x_2' & \hat{x}_2'^2 \end{pmatrix}$$

où

$$x x' \cong E\{ (x - \hat{x})(x' - \hat{x}') \}$$

et

$$x^2 \cong E\{ (x - \hat{x})^2 \}$$

La covariance  $P_t^*$  est prédite par  $P_t^* := (t)\hat{P}_{t-1}(t)^T + E\{R_t R_t^T\}$

Le processus peut avoir les dérivés d'ordre supérieur à le modèle.

Ces dérivés donnent lieu au "résidu"  $R$ .

$R$  est supposée d'être moyenne nul.

Son deuxième moment indique la perte de précision dû au modèle linéaire.

$$X_t^* := \hat{X}_{t-} + \frac{X_{t-} - \hat{X}_{t-}}{t} T + R_t.$$

avec

$$Q = E\{R_t R_t^T\}$$

Prédiction :

$$I: \quad X_t^* := \hat{X}_{t-} + R_t.$$

$$II: \quad P_t^* := \hat{P}_{t-} + Q_x$$

## Modèle du capteur

Un capteur projet l'estimation de l'état du monde vers un vecteur d'observation en  $o$  dimensions

$$\begin{aligned} \text{III : } Y_t^* &:= \mathbf{H}_X^Y X_t^* \\ \text{IV : } \mathbf{P}_y^* &= \mathbf{H}_X^Y \mathbf{P}_t^* (\mathbf{H}_X^Y)^T \end{aligned}$$

La matrice de  $\mathbf{H}_X^Y$  est un modèle linéaire du capteur. Les observations sont corrompues par les bruits aléatoires ainsi que une erreur d'approximation.

Ceci est représenté par l'erreur du capteur :  $W_t$ , calibré au Laboratoire.

On suppose que  $E\{W_t\} = 0$   
 tandis que  $\mathbf{P}_y = E\{W_t W_t^T\}$

Par exemple, considère l'observation  $Y$  ( $o=2$ ) d'un état  $X_t$  ( $d = 4$ ).

$$Y_t^* := \mathbf{H}_X^Y X_t^* \Rightarrow \begin{matrix} y_1 \\ y_2 \end{matrix} = \begin{matrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{matrix} \begin{matrix} x_1 \\ x_1' \\ x_2 \\ x_2' \end{matrix}$$

$$\mathbf{P}_y^* = \mathbf{H}_X^Y \mathbf{P}_t^* (\mathbf{H}_X^Y)^T = \begin{matrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{matrix} \begin{matrix} \hat{x}_1^2 & \hat{x}_1'x_1 & \hat{x}_2x_1 & \hat{x}_2'x_1 & 1 & 0 \\ \hat{x}_1x_1' & \hat{x}_1'^2 & \hat{x}_2x_1' & \hat{x}_2'x_1' & 0 & 0 \\ \hat{x}_1x_2 & \hat{x}_1'x_2 & \hat{x}_2^2 & \hat{x}_2'x_2 & 0 & 1 \\ \hat{x}_1x_2' & \hat{x}_1'x_2' & \hat{x}_2x_2' & \hat{x}_2'^2 & 0 & 0 \end{matrix}$$

## Approximations des modèle non-linéaires

Souvent le vrai capteur n'est pas linéaire.

$$Y = F(X)$$

Dans ce cas, on peut faire une approximation linéaire avec la dérivée première, (la Jacobienne), calculé au tour de l'estimation actuelle.

$$\mathbf{H}_X^Y \quad \mathbf{J}_X^Y = \frac{F(\hat{X}_t)}{\hat{X}_t} = \begin{matrix} \frac{y_1}{x_1} & \frac{y_1}{x_2} & \frac{y_1}{x_3} & \frac{y_1}{x_4} \\ \frac{y_2}{x_1} & \frac{y_2}{x_2} & \frac{y_2}{x_3} & \frac{y_2}{x_4} \end{matrix}$$

et donc :

$$\begin{matrix} y_1 \\ y_2 \end{matrix} = \begin{matrix} \frac{y_1}{x_1} & \frac{y_1}{x_2} & \frac{y_1}{x_3} & \frac{y_1}{x_4} \\ \frac{y_2}{x_1} & \frac{y_2}{x_2} & \frac{y_2}{x_3} & \frac{y_2}{x_4} \end{matrix} \begin{matrix} x_1 \\ x_1' \\ x_2 \\ x_2' \end{matrix}$$

## Validation

Validation repose sur une mesure de similarité. Une telle mesure est la "Distance de Mahalanobis" ou "Différence normalisée par covariance"

Soit la prédiction  $Y_t^*$  avec sa précision  $P_t^*$   
et l'observation  $Y$  avec sa précision  $P_y$

L'Innovation :  $V = (Y - Y_t^*)$  est l'information obtenu par l'observation.

Il doit être validé par une distance de Mahalanobis

$$V : d^2 = \frac{1}{2} \{ (Y - Y_t^*)^T (P_t^* + P_y)^{-1} (Y - Y_t^*) \}$$

Pour une scalaire :

$$d^2 = \frac{(x^* - y)^2}{2 \left( \frac{1}{x^*} + \frac{1}{y} \right)}$$

On considère que  $X_t^*$ ,  $P_t^*$  définie une probabilité d'une observation  $Y$ .

Si il y a  $K$  prédictions :  $X_{kt}^*$ ,  $P_{kt}^*$ , l'observation est associée a :

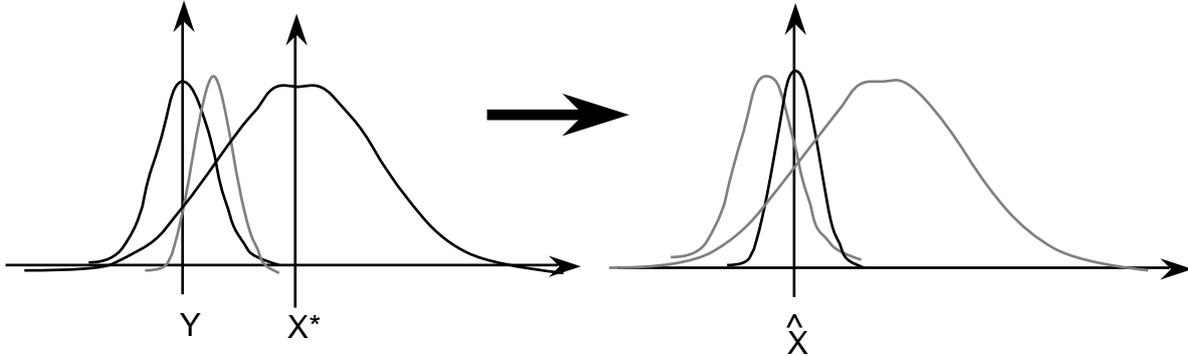
$$\text{Arg}_k \text{Min} \{ d_k^2 \} \text{ tel que } d_k \leq \text{seuil.}$$

Le seuil est un multiple de l'écart type.  
Son choix dépend du problème

## Mise à Jour

Contraint d'un modèle par une Observation

Soit un modèle  $X_t^*$ ,  $P_t^*$  et une observation  $Y$ ,  $P_y$



$Y$  fournit une contrainte sur  $X^*$ .

La nouvelle valeur est donnée par un moyen, pondérée par la variance:

Les variances combine comme les résistances parallèles :

$$\frac{1}{\hat{\sigma}_x^2} = \frac{1}{\sigma_x^2} + \frac{1}{\sigma_y^2}$$

et

$$\hat{X}_{nt} = \hat{\sigma}_x^2 \left( \frac{X^*}{\sigma_x^2} + \frac{Y}{\sigma_y^2} \right)$$

Formulation Kalman (estimation récursif): Le Gain de Kalman

$$K = \frac{\sigma_x^2}{\sigma_y^2 + \sigma_x^2}$$

$K$  détermine la contribution que l'innovation porte à l'estimation  $K = \frac{\sigma_x^2}{\sigma_y^2 + \sigma_x^2}$

Puis :

$$\hat{\sigma}_x^2 = \sigma_x^2 - K \sigma_x^2$$

et

$$\hat{X} = X^* + K (Y - Y^*)$$

En plusieurs dimensions, le gain de Kalman est une matrice.

Supposons que  $Y$  et  $X$  sont dans le même espace. (Même nombre de variables.)

$$K := P_t^* (P_t^* + P_y)^{-1}$$

puis :

$$\hat{X}_t = X_t^* + K (Y - Y_t^*)$$

et

$$\hat{P}_t = P_t^* - K P_t^*$$

