

# Filtre de Kalman pour l'assimilation de données

Pierre Ailliot

Laboratoire de mathématiques de Bretagne Atlantique  
Université de Bretagne Occidentale



26 janvier 2023

# Plan

- 1 Introduction
- 2 Modèles espace-état
- 3 Filtre de Kalman
- 4 Estimation des paramètres
- 5 Un exemple d'application
- 6 Conclusion

## Motivations

Hauteur significative des vagues (Hs) à Ste Anne du Porzic (France)





- Les bouées mesurent la hauteur significative des vagues (Hs) avec une certaine erreur
  - $X_t$  "vraie" valeur de Hs,  $Y_t$  valeur mesurée à l'instant  $t$
  - **Hypothèse 1 (équation d'observation)** :  $Y_t = X_t + \epsilon_t$  avec  $\epsilon_t$  l'erreur de mesure
- Modélisation de l'évolution temporelle de Hs ?
  - **Hypothèse 2 (modèle dynamique)** :  $X_t = MX_{t-1} + \eta_t$




## Motivations

Hauteur significative des vagues (Hs) à Ste Anne du Porzic (France)





- Les bouées mesurent la hauteur significative des vagues (Hs) avec une certaine erreur
  - $X_t$  "vraie" valeur de Hs,  $Y_t$  valeur mesurée à l'instant  $t$
  - **Hypothèse 1 (équation d'observation)** :  $Y_t = X_t + \epsilon_t$  avec  $\epsilon_t$  l'erreur de mesure
- Modélisation de l'évolution temporelle de Hs ?
  - **Hypothèse 2 (modèle dynamique)** :  $X_t = MX_{t-1} + \eta_t$



## Motivations

Hauteur significative des vagues (Hs) à Ste Anne du Porzic (France)



- Les bouées mesurent la hauteur significative des vagues (Hs) avec une certaine erreur
  - $X_t$  "vraie" valeur de Hs,  $Y_t$  valeur mesurée à l'instant  $t$
  - **Hypothèse 1 (équation d'observation) :**  $Y_t = X_t + \epsilon_t$  avec  $\epsilon_t$  l'erreur de mesure
- Modélisation de l'évolution temporelle de Hs ?
  - **Hypothèse 2 (modèle dynamique) :**  $X_t = MX_{t-1} + \eta_t$
- **Objectifs ?** "Reconstruire" le vrai Hs à partir des observations bruitées et parfois manquantes

# Plan

- 1 Introduction
- 2 Modèles espace-état**
- 3 Filtre de Kalman
- 4 Estimation des paramètres
- 5 Un exemple d'application
- 6 Conclusion

## Modèles espace état général, vision "système dynamique"

- Modèle avec deux composantes  $X_t$  et  $Y_t$
- $X_t$  décrit le vrai état du système à l'instant  $t$ .
  - On suppose que cet état est "caché" ou "latent" ou "non-observable".
  - Evolution dynamique décrite par l'**équation d'état**

$$X_t = \mathcal{M}_t(X_{t-1}) + \eta_t$$


- $\mathcal{M}_t$  décrit la partie déterministe de l'évolution temporelle de l'état (en assimilation de données, typiquement un modèle numérique basé sur des EDP)
- $\eta_t$  un suite de variables aléatoire (**v.a.**) qui décrit les erreurs (approximations physiques et numériques, échelles non-résolues, etc)
- On suppose que  $\eta_t$  est indépendant de  $X_{0:t-1} := (X_0, \dots, X_{t-1})$  et  $Y_{0:t-1}$
- $Y_t$  décrit les observations disponibles à l'instant  $t$ .
  - On suppose que les observations sont liées à l'état caché par l'**équation d'observation**

$$Y_t = \mathcal{H}_t(X_t) + \epsilon_t$$

- $\mathcal{H}_t$  décrit le lien entre l'état et les observations (typiquement,  $\mathcal{H}_t = I$  ou projection sur sous-espace)
- $\epsilon_t$  un suite de v.a. indépendantes qui décrit les erreurs d'observations (erreurs de capteur, différences de support entre le modèle et les observations, ...)
- On suppose que  $\epsilon_t$  est indépendant de  $X_{0:t}$  et  $Y_{0:t-1}$ .

## Modèles espace état général, vision "probabiliste"

- **Notation.**  $p(x_t|x_{0:t-1}, y_{1:t-1})$  est la densité de la loi conditionnelle  $P(X_t|X_0 = x_0, \dots, X_{t-1} = x_{t-1}, Y_1 = y_0, \dots, Y_{t-1} = y_{t-1})$  (idem pour autres lois conditionnelles).
- Le processus  $\{X_t, Y_t\}$  vérifie les propriétés d'indépendance conditionnelle suivantes
  - $p(x_t|x_{0:t-1}, y_{1:t-1}) = p(x_t|x_{t-1})$ 
    - Correspond à l'équation  $X_t = \mathcal{M}_t(X_{t-1}) + \eta_t$  avec  $\eta_t$  indépendant de  $X_{0:t-1}$  et  $Y_{0:t-1}$ .
    - L'état du système à l'instant  $t$  dépend uniquement de l'état du système à l'instant  $t - 1$
    - Propriété Markovienne avec oubli de l'état du système et des observations aux instants précédents
  - $p(y_t|x_{1:t}, y_{1:t-1}) = p(y_t|x_t)$ 
    - Correspond à l'équation  $Y_t = \mathcal{H}_t(X_t) + \epsilon_t$  avec  $\epsilon_t$  indépendant de  $X_{0:t}$  et  $Y_{0:t-1}$ .
    - L'observation à l'instant  $t$  dépend uniquement de l'état du système à l'instant  $t$
- La structure probabiliste du modèle espace-état peut être résumée par le diagramme d'indépendance conditionnelle (DAG) suivant




- La loi normale joue un rôle important en assimilation de données

## Rappels sur la loi normale multivariée

- Définition :  $X = (X_1, \dots, X_d)' \sim \mathcal{N}(\mu, \Sigma)$  si sa densité est donnée par

$$\phi(x; \mu, \Sigma) = \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{\det(\Sigma)}} \exp\left(-\frac{1}{2}(X - \mu)' \Sigma^{-1} (X - \mu)\right)$$



- $\mu = E[X] = (E[X_1], \dots, E[X_d])'$  et  $\Sigma = \text{var}(X) = E[XX'] - E[X]E[X]'$
- Fonction caractéristique :  $E[e^{it'X}] = \int_{\mathbb{R}^d} e^{it'x} \phi(x; \mu, \Sigma) dx = e^{it'\mu - \frac{1}{2}t'\Sigma t}$
- N.B. Loi normale = loi gaussienne = loi de Gauss
- Loi la plus utilisée en statistique, machine learning, traitement du signal...Pourquoi ?
  - Théorème central limite...
  - et possibilités de faire de nombreux calculs de manière analytique !

# Rappels sur la loi normale multivariée

## Stabilité par transformation linéaire

### Proposition 1

On suppose que  $Z_0 \sim \mathcal{N}(\mu_0, \Sigma_0)$  et soit  $M$  une matrice à coefficients réels. Alors  $Z_1 = MZ_0 \sim \mathcal{N}(\mu_1, \Sigma_1)$  avec  $\mu_1 = M\mu_0$  et  $\Sigma_1 = M\Sigma_0M'$ .


**Preuve** Utiliser les fonctions caractéristiques.

## Rappels sur la loi normale multivariée Stabilité par conditionnement

### Proposition 2

Soit  $(X, Y) \sim \mathcal{N} \left( \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \Sigma_X & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_Y \end{pmatrix} \right)$ . Si  $\Sigma_Y$  est inversible alors la loi conditionnelle  $\mathcal{L}_{X|Y=y}$  est une loi normale de moyenne  $\mu_X + \Sigma_{XY}\Sigma_Y^{-1}(y - \mu_Y)$  et de matrice de covariance  $\Sigma_X - \Sigma_{XY}\Sigma_Y^{-1}\Sigma_{YX}$

**Preuve**  $p(x|y) = \frac{p(x,y)}{p(y)}$  avec  $p(x, y)$  densité de  $(X, Y)$ ,  $p(x)$  densité de  $X$ ,  $p(x|y)$  densité de  $\mathcal{L}_{X|Y=y}$



## Rappels sur la loi normale multivariée Stabilité par conditionnement

### Proposition 2

Soit  $(X, Y) \sim \mathcal{N} \left( \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \Sigma_X & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_Y \end{pmatrix} \right)$ . Si  $\Sigma_Y$  est inversible alors la loi conditionnelle  $\mathcal{L}_{X|Y=y}$  est une loi normale de moyenne  $\mu_X + \Sigma_{XY}\Sigma_Y^{-1}(y - \mu_Y)$  et de matrice de covariance  $\Sigma_X - \Sigma_{XY}\Sigma_Y^{-1}\Sigma_{YX}$

- **Conséquence** :  $E[X|Y] = \mu_X + \Sigma_{XY}\Sigma_Y^{-1}(Y - \mu_Y)$  est le meilleur prédicteur au sens des moindres carrés de  $X$  à partir de  $Y$  (**estimateur des moindres carrés**)
- **Remarque** : dans le cas général (non-gaussien),  $\mu_X + \Sigma_{XY}\Sigma_Y^{-1}(Y - \mu_Y)$  reste le meilleur prédicteur **linéaire sans biais** au sens des moindres carrés de  $X$  à partir de  $Y$  (**Best Linear Unbiased Prediction**). Ceci peut justifier l'utilisation de ce prédicteur dans le cas non-gaussien

## Modèle espace-état linéaire gaussien

- Le filtre de Kalman est optimal pour le **modèle linéaire gaussien** : modèle espace-état dans lequel les opérateurs sont linéaires et les erreurs sont gaussiennes.
- $X_t = MX_{t-1} + \eta_t$  avec  $\eta_t \sim \mathcal{N}(0, Q)$  et donc

$$\mathcal{L}(X_t | X_{t-1} = x_{t-1}) \sim \mathcal{N}(Mx_{t-1}, Q)$$

- $M$  modélise la dynamique et  $Q$  l'incertitude associée.
- $Y_t = HX_t + \epsilon_t$  avec  $\epsilon_t \sim \mathcal{N}(0, R)$  et donc

$$\mathcal{L}(Y_t | X_t = x_t) \sim \mathcal{N}(Hx_t, R).$$

- $H$  modélise le mécanisme d'observations et  $R$  l'incertitude associée.
- Remarques**
  - $M$ ,  $H$ ,  $Q$  et  $R$  peuvent varier au cours du temps (supposés constants dans la suite du cours pour simplifier les notations)
  - On suppose dans la suite que la loi initiale est telle que  $X_0 \sim \mathcal{N}(\mu_0, \Sigma_0)$ . On en déduit que  $(X_0, X_1, Y_1, \dots, X_T, Y_T)$  est un vecteur gaussien

## Modèle espace-état linéaire gaussien

- Le filtre de Kalman est optimal pour le **modèle linéaire gaussien** : modèle espace-état dans lequel les opérateurs sont linéaires et les erreurs sont gaussiennes.
- $X_t = MX_{t-1} + \eta_t$  avec  $\eta_t \sim \mathcal{N}(0, Q)$  et donc


$$\mathcal{L}(X_t | X_{t-1} = x_{t-1}) \sim \mathcal{N}(Mx_{t-1}, Q)$$

- $Y_t = HX_t + \epsilon_t$  avec  $\epsilon_t \sim \mathcal{N}(0, R)$  et donc

$$\mathcal{L}(Y_t | X_t = x_t) \sim \mathcal{N}(Hx_t, R).$$

### Algorithme pour simuler un modèle espace-état linéaire gaussien

- 1 Simuler  $X_0 \sim \mathcal{N}(\mu_0, \Sigma_0)$ ,  $(\eta_1, \dots, \eta_T) \sim iid \mathcal{N}(0, Q)$  et  $(\epsilon_1, \dots, \epsilon_T) \sim iid \mathcal{N}(0, R)$
- 2 Pour  $t \in \{1, \dots, T\}$ 
  - 1 Simuler  $X_t = MX_{t-1} + \eta_t$
  - 2 Simuler  $Y_t = HX_t + \epsilon_t$



## Prédiction/filtrage/lissage dans les modèles espace-état

- **Objectif** : estimer l'état latent  $X_t$  à l'instant  $t$  connaissant une séquence d'observations  $\{y_1, \dots, y_T\}$
- Information contenue dans la loi conditionnelle  $p(x_t|y_{1:T})$ 
  - En particulier  $E[X_t|y_{1:T}] = \int x_t p(x_t|y_{1:T}) dx_t$  donne la meilleur prévision de  $X_t$  au sens des moindres carrés. On peut aussi en déduire une incertitude sur la prévision
- On distingue trois cas selon la valeur de  $T$ 
  - **Prédiction (forecast)**
    - On cherche à estimer l'état du système à l'instant  $t$  connaissant les observations passées
    - La quantité d'intérêt est la distribution de prédiction  $p(x_t|y_1, \dots, y_{t-1})$
  - **Filtrage (nowcast, analyse)**
    - On cherche à estimer l'état du système à l'instant  $t$  connaissant les observations passées et présentes
    - La quantité d'intérêt est la distribution de filtrage  $p(x_t|y_1, \dots, y_t)$
  - **Lissage (hindcast ou réanalyse)**
    - On cherche à estimer l'état du système à l'instant  $t$  connaissant les observations passées et présentes et futures
    - La quantité d'intérêt est la distribution de lissage  $p(x_t|y_1, \dots, y_T)$  avec  $T > t$
    - Lissage pas discuté dans la suite du cours

## Récursion forward-backward

- Dans le modèle espace-état général, les probabilités de prédiction et de filtrage vérifient les récursions "forward"

- **Prédiction :**

$$p(x_t | y_1, \dots, y_{t-1}) = \int p(x_{t-1} | y_1, \dots, y_{t-1}) p(x_t | x_{t-1}) dx_{t-1}$$


- Interprétation : l'état du système est prédit en appliquant le modèle dynamique  $p(x_t | x_{t-1})$  sur la loi de filtrage  $p(x_{t-1} | y_1, \dots, y_{t-1})$

- **Correction :** l'état du système est corrigé en utilisant l'observation  $y_t$  à l'instant  $t$

$$p(x_t | y_1, \dots, y_t) = \frac{p(y_t | x_t) p(x_t | y_1, \dots, y_{t-1})}{\int p(y_t | x) p(x | y_1, \dots, y_{t-1}) dx}$$

$$\propto p(y_t | x_t) p(x_t | y_1, \dots, y_{t-1})$$

- Interprétation : correction bayésienne de la loi a priori  $\mathcal{L}(X_t | y_1, \dots, y_{t-1})$



• Des expressions exactes sont connues pour ces intégrales seulement dans les deux

## Récursion forward-backward

- Dans le modèle espace-état général, les probabilités de prédiction et de filtrage vérifient les récursions "forward"

- **Prédiction** :

$$p(x_t | y_1, \dots, y_{t-1}) = \int p(x_{t-1} | y_1, \dots, y_{t-1}) p(x_t | x_{t-1}) dx_{t-1}$$

- Interprétation : l'état du système est prédit en appliquant le modèle dynamique  $p(x_t | x_{t-1})$  sur la loi de filtrage  $p(x_{t-1} | y_1, \dots, y_{t-1})$

- **Correction** : l'état du système est corrigé en utilisant l'observation  $y_t$  à l'instant  $t$

$$p(x_t | y_1, \dots, y_t) = \frac{p(y_t | x_t) p(x_t | y_1, \dots, y_{t-1})}{\int p(y_t | x) p(x | y_1, \dots, y_{t-1}) dx} \\ \propto p(y_t | x_t) p(x_t | y_1, \dots, y_{t-1})$$

- Interprétation : correction bayésienne de la loi a priori  $\mathcal{L}(X_t | y_1, \dots, y_{t-1})$

- Des expressions exactes sont connues pour ces intégrales seulement dans les deux cas suivants :
  - $X_t$  à valeurs dans un espace fini (Chaîne de Markov cachée) : algorithme Forward-Backward.
  - Modèle linéaire Gaussien : **filtre de Kalman**
- Alternatives dans les autres cas : approximer les intégrales par des simulations -> méthodes de Monte-Carlo séquentielles : EnKF, filtre particulière,...

# Plan

- 1 Introduction
- 2 Modèles espace-état
- 3 Filtre de Kalman**
- 4 Estimation des paramètres
- 5 Un exemple d'application
- 6 Conclusion

## Filtre de Kalman

**Résultat principal du cours.** On se place sous les hypothèses du modèle linéaire gaussien.

- $X_t = MX_{t-1} + \eta_t$  avec  $\eta_t \sim_{iid} \mathcal{N}(0, Q)$
- $Y_t = HX_t + \epsilon_t$  avec  $\epsilon_t \sim_{iid} \mathcal{N}(0, R)$

Alors les probabilités de prédiction et de filtrage suivent des lois normales

- $\mathcal{L}(X_t | y_1, \dots, y_{t-1}) \sim \mathcal{N}(x_t^f, P_t^f)$
- $\mathcal{L}(X_t | y_1, \dots, y_t) \sim \mathcal{N}(x_t^a, P_t^a)$

avec  $x^f, x^a, P^f, P^a$  qui sont donnés par les récursions de Kalman (1966) ci-dessous

- **Prédiction**

$$x_t^f = Mx_{t-1}^a \text{ (espérance de l'état prédit)}$$

$$P_t^f = MP_{t-1}^a M' + Q \text{ (variance de l'état prédit)}$$

- **Correction (ou mise à jour)**

$$K_t = P_t^f H' (HP_t^f H' + R)^{-1} \text{ (gain de Kalman)}$$

$$x_t^a = x_t^f + K_t(y_t - Hx_t^f) \text{ (espérance de l'état filtré)}$$

$$P_t^a = (I - K_t H) P_t^f \text{ (variance de l'état filtré)}$$

## Schéma de la preuve

Raisonnement par récurrence. Supposons que  $\mathcal{L}(X_{t-1}|y_1, \dots, y_{t-1}) \sim \mathcal{N}(x_{t-1}^a, P_{t-1}^a)$

- ① On va déduire de l'expression

$$p(x_t|y_1, \dots, y_{t-1}) = \int p(x_{t-1}|y_1, \dots, y_{t-1})p(x_t|x_{t-1})dx_{t-1}.$$

que  $\mathcal{L}(X_t|y_1, \dots, y_{t-1}) \sim \mathcal{N}(x_t^f, P_t^f)$ .

- ② On va déduire de l'expression

$$p(x_t|y_1, \dots, y_t) = \frac{p(y_t|x_t)p(x_t|y_1, \dots, y_{t-1})}{\int p(y_t|x)p(x|y_1, \dots, y_{t-1})dx}$$

que  $\mathcal{L}(X_t|y_1, \dots, y_t) \sim \mathcal{N}(x_t^a, P_t^a)$ .

## Preuve du point 1.

- Supposons que  $Z_{t-1} \sim \mathcal{N}(\mu_{t-1}, \Sigma_{t-1})$  et  $Z_t = MZ_{t-1} + \eta$  avec  $\eta \sim \mathcal{N}(0, Q)$  indépendant de  $Z_{t-1}$ . En utilisant la proposition 1, on obtient que  $Z_t \sim \mathcal{N}(\mu_t, \Sigma_t)$  avec  $\mu_t = M\mu_{t-1}$  et  $\Sigma_t = Q + M\Sigma_{t-1}M'$ .
- On peut réécrire ce résultat avec les probabilités conditionnelles : si  $p(z_{t-1}) = \phi(z_{t-1}; \mu_{t-1}, \Sigma_{t-1})$  et  $p(z_t|z_{t-1}) = \phi(z_t; Mz_{t-1}, Q)$  alors

$$p(z_t) = \int p(z_t|z_{t-1})p(z_{t-1})dz_{t-1} = \phi(z_t; \mu_t, \Sigma_t)$$

- L'étape de prédiction du filtre de Kalman se déduit alors de l'expression

$$p(x_t|y_1, \dots, y_{t-1}) = \int p(x_t|x_{t-1})p(x_{t-1}|y_1, \dots, y_{t-1})dx_{t-1}$$

avec

- $p(x_{t-1}|y_1, \dots, y_{t-1}) = \phi(x_{t-1}; x_{t-1}^a, P_{t-1}^a)$  d'après l'hypothèse de récurrence
- $p(x_t|x_{t-1}) = \phi(x_t; Mx_{t-1}, Q)$  d'après la définition du modèle linéaire gaussien

## Preuve du point 2.

### Proposition 2 (rappel)

Soit  $(X, Y) \sim \mathcal{N}\left(\begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \Sigma_X & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_Y \end{pmatrix}\right)$ . Si  $\Sigma_Y$  est inversible alors la loi conditionnelle  $\mathcal{L}_{X|Y=y}$  est une loi normale de moyenne  $\mu_X + \Sigma_{XY}\Sigma_Y^{-1}(y - \mu_Y)$  et de matrice de covariance  $\Sigma_X - \Sigma_{XY}\Sigma_Y^{-1}\Sigma_{YX}$ .

### Conséquences

- Si  $X \sim \mathcal{N}(\mu_X, \Sigma_X)$  et  $Y = HX + \epsilon$  avec  $\epsilon \sim \mathcal{N}(0, R)$  indépendant de  $X$  alors

$$(X, Y) \sim \mathcal{N}\left(\begin{pmatrix} \mu_X \\ \mu_X \end{pmatrix}, \begin{pmatrix} \Sigma_X & \Sigma_X H' \\ H \Sigma_X & H \Sigma_X H' + R \end{pmatrix}\right). \text{ Donc}$$

$$\mathcal{L}_{X|Y=y} \sim \mathcal{N}(\mu_{X|y}, \Sigma_{X|y})$$

avec  $\mu_{X|y} = \mu_X + \Sigma_X H' (H \Sigma_X H' + R)^{-1} (y - \mu_X)$  et

$$\Sigma_{X|y} = \Sigma_X - \Sigma_X H' (H \Sigma_X H' + R)^{-1} H \Sigma_X.$$

- Avec les probabilités conditionnelles : si  $p(x) = \phi(x; \mu_X, \Sigma_X)$  et  $p(y|x) = \phi(y; Hx, R)$  alors

$$p(x|y) \propto \int p(y|x)p(x)dx = \phi(x; \mu_{X|y}, \Sigma_{X|y}).$$

## Preuve du point 2.

### Proposition 2 (rappel)

Soit  $(X, Y) \sim \mathcal{N} \left( \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \Sigma_X & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_Y \end{pmatrix} \right)$ . Si  $\Sigma_Y$  est inversible alors la loi conditionnelle  $\mathcal{L}_{X|Y=y}$  est une loi normale de moyenne  $\mu_X + \Sigma_{XY}\Sigma_Y^{-1}(y - \mu_Y)$  et de matrice de covariance  $\Sigma_X - \Sigma_{XY}\Sigma_Y^{-1}\Sigma_{YX}$ .

### Conséquences

- Avec les probabilités conditionnelles : si  $p(x) = \phi(x; \mu_X, \Sigma_X)$  et  $p(y|x) = \phi(y; Hx, R)$  alors

$$p(x|y) \propto p(y|x)p(x)dx = \phi(x; \mu_{X|y}, \Sigma_{X|y}).$$


- L'étape de correction du filtre de Kalman se déduit alors de l'expression

$$p(x_t|y_1, \dots, y_t) \propto p(y_t|x_t)p(x_t|y_1, \dots, y_{t-1})$$

avec  $p(x_t|y_1, \dots, y_{t-1}) = \phi(x_t; x_t^f, P_t^f)$  et  $p(y_t|x_t) = \phi(y_t; Hx_t, R)$ .

## Quelques remarques sur le filtre de Kalman

- On peut expliciter le lisseur de Kalman de manière similaire



Time series  $\{x_t\}$  (black curve) and  $\{y_t\}$  (black dots) simulated with  $Q^t = 1$  and  $R^t = 1$ , and reconstructions with a Kalman filter/smoothers (red lines and gray 95% confidence interval).

## Quelques remarques sur le filtre de Kalman


- On peut expliciter le lisseur de Kalman de manière similaire
- Avantages du filtre de Kalman
  - Solution exacte
  - Coût de calcul faible en petite dimension
  - Implémenté dans les langages usuels (Python, R, Matlab,...)
- Inconvénients du filtre de Kalman
  - Linéaire+Gaussien : hypothèses fortes !
  - Coûts de calcul (produit et inversion de matrices) et de stockage en grande dimension
- Interprétation
  - Le filtre et le lisseur de Kalman sont des interpolateurs linéaires
  - Dans le filtre de Kalman, l'étape de correction s'écrit  $x_t^a = (I - K_t H)x_t^f + K_t y_t$ .  
L'état analysé est donc une moyenne pondérée entre la prédiction et l'observation et le gain de Kalman  $K_t$  s'interprète comme le "poids" donné à l'observation  $y_t$
  - Le gain de Kalman est donné par  $K_t = P_t^f H' (H P_t^f H' + R)^{-1}$ . Intuitivement,  $K_t$  décroît lorsque le bruit d'observation  $R$  augmente : on donne moins de poids aux observations lorsque le bruit d'observation est important (cf transparent suivant)

# Plan

- 1 Introduction
- 2 Modèles espace-état
- 3 Filtre de Kalman
- 4 Estimation des paramètres**
- 5 Un exemple d'application
- 6 Conclusion

## Estimation des paramètres

- En général les paramètres du modèles sont inconnus
- Les valeurs de  $Q$  et  $R$  ont un impact sur la moyenne et la variance du filtre



Time series  $\{x_t\}$  (black curve) and  $\{y_t\}$  (black dots) simulated with  $Q^t = 1$  and  $R^t = 1$ , and reconstructions with a Kalman filter (red lines and gray 95% confidence interval) with different values of  $Q$  and  $R$ .

## Estimation des paramètres

- En général les paramètres du modèles sont inconnus
- Les valeurs de  $Q$  et  $R$  ont un impact sur la moyenne et la variance du filtre
- Il est important d'estimer les paramètres avant d'utiliser le filtre de Kalman
- Méthode la plus classique : **maximum de vraisemblance** via l'**algorithme EM** ou optimisation numérique
- Alternative classique en assimilation de données : **méthode des moments** (cf exercice 1)

# Plan

- 1 Introduction
- 2 Modèles espace-état
- 3 Filtre de Kalman
- 4 Estimation des paramètres
- 5 Un exemple d'application**
- 6 Conclusion

## Résultats sur les données de Hs à Sainte Anne

### Méthodologie :

- La transformation logarithme permet de "gaussianiser" Hs
- Centrage de la série temporelle
- Modélisation par un modèle espace-état linéaire gaussien
- Estimation des paramètres par maximum de vraisemblance
- Utilisation du lisseur de Kalman pour reconstruire la série temporelle









Figure – Séries temporelles  $\{x_t\}$  (noir),  $\{y_t\}$  (point), et probabilité de lissage (moyenne en rouge et intervalle de prédiction à 95%)

## Extension : inclusion de covariables, non-linéarités (1)



La hauteur des vagues à Sainte Anne dépend de

- la marée (Hs plus grand à marée montante et à marée haute)
- la hauteur des vagues au large (propagation)
- vent local (mer du vent)

et certaines relations sont non-linéaires



## Extension : inclusion de covariables, non-linéarités (2)



# Plan

- 1 Introduction
- 2 Modèles espace-état
- 3 Filtre de Kalman
- 4 Estimation des paramètres
- 5 Un exemple d'application
- 6 Conclusion

## En résumé

- Le filtre de Kalman permet de reconstruire de manière optimale l'état latent dans le cadre du modèle linéaire gaussien
- Il consiste à appliquer une étape de prédiction et une étape de correction à chaque pas de temps
- Il permet de calculer non seulement l'espérance (conditionnelle) de l'état mais aussi sa variance, et donc de quantifier l'incertitude sur l'état reconstruit
- Son implémentation est facile et numériquement efficace
- Nombreuses applications : assimilation de données, mais aussi navigation, contrôle, économétrie, séries temporelles, ...
- Nombreuses généralisations : lisseur de Kalman, filtre de Kalman étendu, EnKF, filtres particuliers,...

## Exercices

### Exercice 1

On considère le modèle espace-état linéaire gaussien univarié ( $X_t$  et  $Y_t$  à valeurs dans  $\mathbb{R}$ ).

- 1 Calculer  $E[X_t]$  et  $\text{var}(X_t)$  en fonction de  $E[X_{t-1}]$  et  $\text{var}(X_{t-1})$ .
- 2 On suppose que  $X_0 \sim \mathcal{N}(\mu_0, \Sigma_0)$  et que  $E[X_t]$  et  $\text{var}(X_t)$  ne dépendent pas de  $t$ . Exprimer alors  $\mu_0$  et  $\Sigma_0$  en fonction de  $M$  et  $Q$ .
- 3 Calculer  $\text{cov}(X_t, X_{t+k})$  (on pourra commencer par  $k = 1$ ). En déduire que le processus  $\{X_t\}$  est stationnaire (sens second ordre).
- 4 Exprimer  $\text{cov}(Y_t, Y_{t+k})$  pour  $k \in \mathbb{N}$  en fonction des paramètres du modèle. En déduire que le processus  $\{Y_t\}$  est stationnaire (sens second ordre).
- 5 En inversant ces relations, en déduire des estimateurs de  $M$ ,  $Q$  et  $R$ .
- 6 Montrer que  $(Y_1, \dots, Y_T)$  est un vecteur gaussien dont on précisera les caractéristiques. En déduire une expression de la fonction de vraisemblance  $p(y_1, \dots, y_T)$ .
- 7 Montrer que  $p(y_1, \dots, y_T) = p(y_1) \prod_{t=2}^T p(y_t | y_1, \dots, y_{t-1})$ . Décrire une méthode pour calculer la fonction de vraisemblance à partir du filtre de Kalman.

## Exercices

### Exercice 2

Soit  $(X, Y) \sim \mathcal{N} \left( \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \Sigma_X & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_Y \end{pmatrix} \right)$ . On suppose que  $\Sigma_Y$  est inversible et on admet que  $E[X|Y] = \beta_0 + AY$ .

- 1 En utilisant que  $E[E[X|Y]] = E[X]$  et  $E[(X - E[X|Y])' Y] = 0$ , donner des expressions pour  $\beta_0$  et  $A$ .
- 2 Calculer  $\text{var}(Y - E[X|Y])$
- 3 Vérifier qu'on retrouve l'expression de la loi conditionnelle de  $X$  sachant  $Y = y$  donnée dans la Proposition 2.

### Exercice 3

On considère le processus ARMA(1,1) défini par

$$Y_t = \alpha_1 Y_{t-1} + E_t + \beta_1 E_{t-1}$$

avec  $E_t \sim_{iid} \mathcal{N}(0, \sigma^2)$ . Montrer que  $Y_t$  a une représentation sous la forme d'un modèle espace-état.

Indication : poser  $\eta_t = \alpha_1 \eta_{t-1} + E_t$  et montrer par récurrence que  $Y_t = \epsilon_t + \beta_1 \epsilon_{t-1}$ .

## Exercices

### Exercice 4

On se place dans le cadre d'un modèle linéaire gaussien sans dynamique

- $X \sim \mathcal{N}(\mu_X, \Sigma_X)$  (loi a priori sur l'état)
- $Y = X + \epsilon$  avec  $\epsilon \sim \mathcal{N}(0, R)$  indépendant de  $X$  (équation d'observation)

Pour simplifier, on suppose que  $X$  et  $Y$  sont des variables aléatoires réelles.

- 1 On pose  $F(b_0, b_1) = E[(X - (b_0 + b_1 Y))^2]$ . Expliciter  $(\beta_0, \beta_1) = \operatorname{argmin}_{(b_0, b_1) \in \mathbb{R}^2} F(b_0, b_1)$ .  $\hat{X} = \beta_0 + \beta_1 Y$  s'interprète comme le prédicteur linéaire de  $X$  qui minimise l'erreur quadratique de prédiction. Montrer que c'est également le prédicteur sans biais qui est de variance minimale parmi les prédicteurs linéaires sans biais (BLUE).
- 2 Quelle est la loi du vecteur  $(X, Y)$ ? Quelle est la loi conditionnelle de  $X$  sachant  $Y = y$ ? Montrer que le résultat de la question précédente se déduit de la Proposition 2. Quel résultat plus fort donne la Proposition 2?

## Références

Certaines figures et résultats sont issus des deux références ci-dessous.

- Chau, T. T. T., Ailliot, P., & Monbet, V. (2021). An algorithm for non-parametric estimation in state-space models. *Computational Statistics & Data Analysis*, 153, 107062.
- Tandeo, P., Ailliot, P., Bocquet, M., Carrassi, A., Miyoshi, T., Pulido, M., & Zhen, Y. (2020). A review of innovation-based methods to jointly estimate model and observation error covariance matrices in ensemble data assimilation. *Monthly Weather Review*, 148(10), 3973-3994.