

# Assimilation séquentielle de données en géosciences

Thomas Romary

Centre de Géosciences, Equipe Géostatistique

June 13, 2019




# Qu'est-ce que l'assimilation de données ?

## Tentative de définition


L'assimilation de données est la technique selon laquelle des observations et la sortie d'un modèle numérique sont combinées pour produire une estimation optimale de l'état d'un système évolutif

# Exemple : température de surface de la mer

SST: Simulation (BSHcmod)



SST: Satellite (AVHRR)



Information : modèle

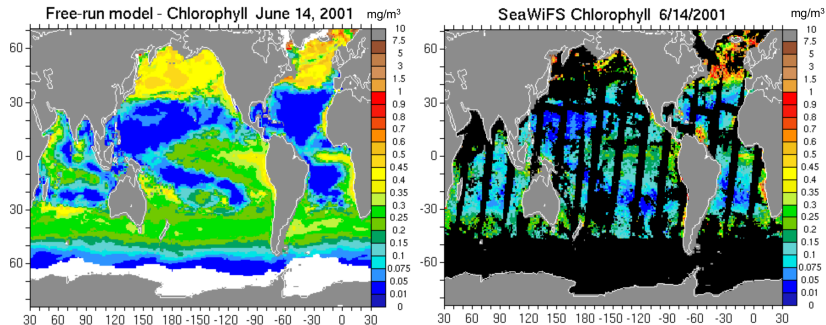
Information : données

On combine les deux types d'information par assimilation de données

⇒ meilleures données d'analyse (rétrospectives), prédictions pour la température, la couverture de glace, etc.

extrait de "An overview of DA", L. Nerger

# Exemple : Chlorophylle dans l'océan



Information : modèle

Information : données

On combine les deux types d'information par assimilation de données

⇒ meilleures données d'analyse (rétrospectives), prédictions

extrait de "An overview of DA", L. Nerger

# Exemples d'application

Historiquement : météorologie, puis océanographie

Aujourd'hui, de plus en plus de domaines d'application

- glaciologie
- sismologie
- fusion nucléaire
- épidémiologie
- agronomie
- qualité de l'air
- etc.

# Pour quoi faire ?

Historiquement : estimation d'un état initial, pour la prédiction de la météo

Aujourd'hui, beaucoup d'autres types d'applications

- conditions initiales pour la prédiction
- calibration et validation de modèles
- conception, validation et surveillance de systèmes d'observation
- réanalyse
- meilleure compréhension des systèmes (erreurs de modélisation, d'observation, interaction de processus physiques, paramètres, etc.)
- etc.

# Formalisation

On cherche à caractériser l'état  $(x_1, \dots, x_T)$  du système au cours du temps discrétisé entre 1 et  $T$ , à partir des observations  $(y_1, \dots, y_T)$

## Deux ingrédients

- 1 un modèle d'évolution  $F$

$$x_t = F(x_{t-1}) + \varepsilon_t^F$$

- 2 un opérateur d'observation  $H$

$$y_t = H(x_t) + \varepsilon_t^H$$

où  $x_0$  est connu (conditions initiales),  $\varepsilon^F$  et  $\varepsilon^H$  sont les erreurs de modélisation et d'observation

**NB**  $x_t$  ne dépend que de  $x_{t-1}$  (Markov)

# Formalisation

On cherche à caractériser l'état  $(x_1, \dots, x_T)$  du système au cours du temps discrétisé entre 1 et  $T$ , à partir des observations  $(y_1, \dots, y_T)$

## Deux ingrédients

- 1 un modèle d'évolution  $F$

$$x_t = F(x_{t-1}) + \varepsilon_t^F$$

- 2 un opérateur d'observation  $H$

$$y_t = H(x_t) + \varepsilon_t^H$$

où  $x_0$  est connu (conditions initiales),  $\varepsilon^F$  et  $\varepsilon^H$  sont les erreurs de modélisation et d'observation

**NB**  $x_t$  ne dépend que de  $x_{t-1}$  (Markov)



# Analyse Bayésienne

## Formule de Bayes

Soit  $x$  l'état du système et  $y$  une observation, on a

$$\begin{aligned}\mathbb{P}(x|y) &= \frac{\mathbb{P}(y|x)\mathbb{P}(x)}{\mathbb{P}(y)} \\ &\propto \mathbb{P}(y|x)\mathbb{P}(x)\end{aligned}$$

# Analyse Bayésienne

Notons  $x_{1:T} = (x_1, \dots, x_T)$  la *trajectoire* de l'état du système et  $y_{1:T} = (y_1, \dots, y_T)$  celle des observations

On a  $\forall t \leq T$

$$\begin{aligned}\mathbb{P}(x_{1:t}|y_{1:t}) &\propto \mathbb{P}(y_t|x_{1:t}, y_{1:t-1})\mathbb{P}(x_{1:t}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{1:t-1}, y_{1:t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1})\end{aligned}$$

On peut donc calculer récursivement le  $\mathbb{P}(x_{1:t}|y_{1:t})$  à partir de  $\mathbb{P}(x_{1:t-1}|y_{1:t-1})$  et de la dernière observation  $y_t$  en utilisant la dernière équation ci-dessus.

# Analyse Bayésienne

Notons  $x_{1:T} = (x_1, \dots, x_T)$  la *trajectoire* de l'état du système et  $y_{1:T} = (y_1, \dots, y_T)$  celle des observations

On a  $\forall t \leq T$

$$\begin{aligned}\mathbb{P}(x_{1:t}|y_{1:t}) &\propto \mathbb{P}(y_t|x_{1:t}, y_{1:t-1})\mathbb{P}(x_{1:t}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{1:t-1}, y_{1:t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1})\end{aligned}$$

On caractérise ainsi séquentiellement la loi de  $x_t$  sachant les observations passées

pour plus de détails, voir Wikle and Berliner [2007]

# Analyse Bayésienne

Notons  $x_{1:T} = (x_1, \dots, x_T)$  la *trajectoire* de l'état du système et  $y_{1:T} = (y_1, \dots, y_T)$  celle des observations

On a  $\forall t \leq T$

$$\begin{aligned}\mathbb{P}(x_{1:t}|y_{1:t}) &\propto \mathbb{P}(y_t|x_{1:t}, y_{1:t-1})\mathbb{P}(x_{1:t}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{1:t-1}, y_{1:t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1})\end{aligned}$$

On caractérise ainsi séquentiellement la loi de  $x_t$  sachant les observations passées  
pour plus de détails, voir Wikle and Berliner [2007]

# Analyse Bayésienne

Notons  $x_{1:T} = (x_1, \dots, x_T)$  la *trajectoire* de l'état du système et  $y_{1:T} = (y_1, \dots, y_T)$  celle des observations

On a  $\forall t \leq T$

$$\begin{aligned}\mathbb{P}(x_{1:t}|y_{1:t}) &\propto \mathbb{P}(y_t|x_{1:t}, y_{1:t-1})\mathbb{P}(x_{1:t}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{1:t-1}, y_{1:t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1})\end{aligned}$$

On caractérise ainsi séquentiellement la loi de  $x_t$  sachant les observations passées

pour plus de détails, voir Wikle and Berliner [2007]

# Analyse Bayésienne

Notons  $x_{1:T} = (x_1, \dots, x_T)$  la *trajectoire* de l'état du système et  $y_{1:T} = (y_1, \dots, y_T)$  celle des observations

On a  $\forall t \leq T$

$$\begin{aligned}\mathbb{P}(x_{1:t}|y_{1:t}) &\propto \mathbb{P}(y_t|x_{1:t}, y_{1:t-1})\mathbb{P}(x_{1:t}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{1:t-1}, y_{1:t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1})\end{aligned}$$

On caractérise ainsi séquentiellement la loi de  $x_t$  sachant les observations passées

pour plus de détails, voir Wikle and Berliner [2007]

# Analyse Bayésienne

Notons  $x_{1:T} = (x_1, \dots, x_T)$  la *trajectoire* de l'état du système et  $y_{1:T} = (y_1, \dots, y_T)$  celle des observations

On a  $\forall t \leq T$

$$\begin{aligned}\mathbb{P}(x_{1:t}|y_{1:t}) &\propto \mathbb{P}(y_t|x_{1:t}, y_{1:t-1})\mathbb{P}(x_{1:t}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{1:t-1}, y_{1:t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1}) \\ &\propto \mathbb{P}(y_t|x_t)\mathbb{P}(x_t|x_{t-1})\mathbb{P}(x_{1:t-1}|y_{1:t-1})\end{aligned}$$

On caractérise ainsi séquentiellement la loi de  $x_t$  sachant les observations passées  
pour plus de détails, voir Wikle and Berliner [2007]

# Analyse Bayésienne

Quels problèmes peut-on résoudre ?

- ① *filtrage*,  $\implies \mathbb{P}(x_t|y_{1:t})$
- ② *prédiction*,  $\implies \mathbb{P}(x_{T+n}|y_{1:T})$
- ③ *lissage*,  $\implies \mathbb{P}(x_t|y_{1:T})$



# Analyse Bayésienne

Quels problèmes peut-on résoudre ?

- 1 *filtrage*,  $\implies \mathbb{P}(x_t|y_{1:t})$
- 2 *prédiction*,  $\implies \mathbb{P}(x_{T+n}|y_{1:T})$
- 3 *lissage*,  $\implies \mathbb{P}(x_t|y_{1:T})$

# Analyse Bayésienne

Quels problèmes peut-on résoudre ?

- 1 *filtrage*,  $\implies \mathbb{P}(x_t|y_{1:t})$
- 2 *prédiction*,  $\implies \mathbb{P}(x_{T+n}|y_{1:T})$
- 3 *lissage*,  $\implies \mathbb{P}(x_t|y_{1:T})$

# Analyse Bayésienne

Quels problèmes peut-on résoudre ?

- 1 *filtrage*,  $\implies \mathbb{P}(x_t|y_{1:t})$
- 2 *prédiction*,  $\implies \mathbb{P}(x_{T+n}|y_{1:T})$
- 3 *lissage*,  $\implies \mathbb{P}(x_t|y_{1:T})$

# Résolution

Séquentiellement et généralement en deux étapes

- ① **Propagation** (*forecast*): on laisse évoluer le système selon  $F$  sans tenir compte des observations
- ② **Correction** (*analysis*): on corrige l'état propagé en fonction des observations


## Cas particulier

Si  $F$  et  $H$  sont linéaires et les erreurs gaussiennes, alors on peut calculer explicitement toutes les distributions conditionnelles

C'est le filtre de Kalman


# Filtrage particulaire

## Principe




# Filtrage particulaire

## Principe



# Filtrage particulaire


## Principe





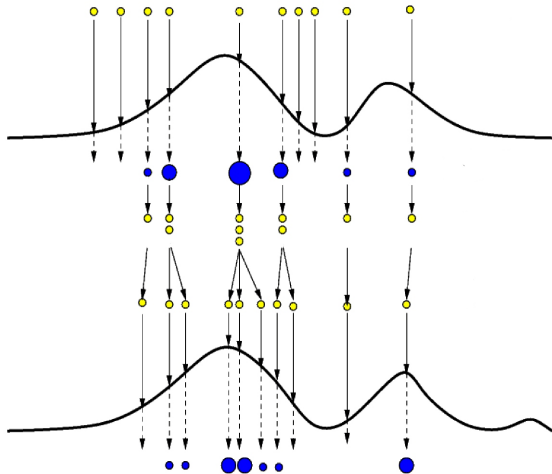
# Filtrage particulaire

## Principe



# Filtrage particulaire

## Principe



# Un aperçu du zoo des méthodes d'assimilation de données

- Variationnelles
  - 3D-var
  - 4D-var
  - ...
- Stochastiques
  - KF-S
  - EKF-S
  - EnKF-S
  - PF-S (SMC)
  - ...
- méthodes hybrides

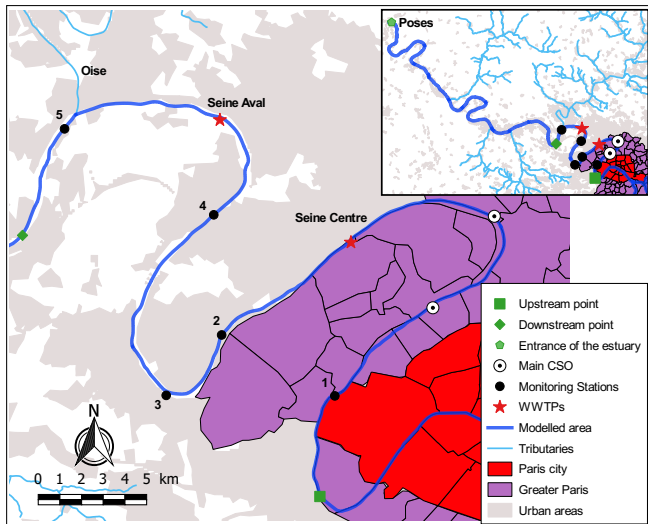
# Exemples d'application

Historiquement : météorologie, puis océanographie

Aujourd'hui, de plus en plus de domaines d'application

- glaciologie
- sismologie
- fusion nucléaire
- épidémiologie
- agronomie
- qualité de l'air
- etc.
- **qualité de l'eau**

# En qualité de l'eau



# Modèle Prose

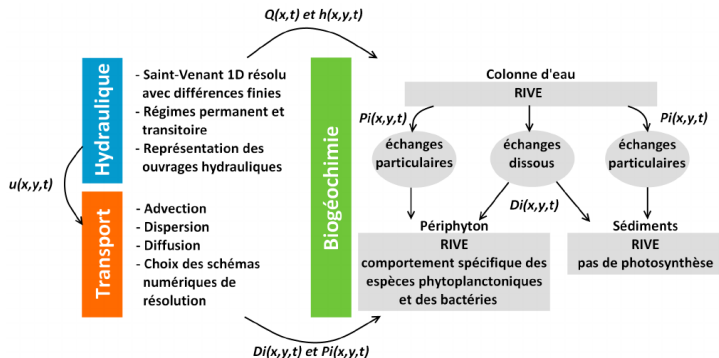
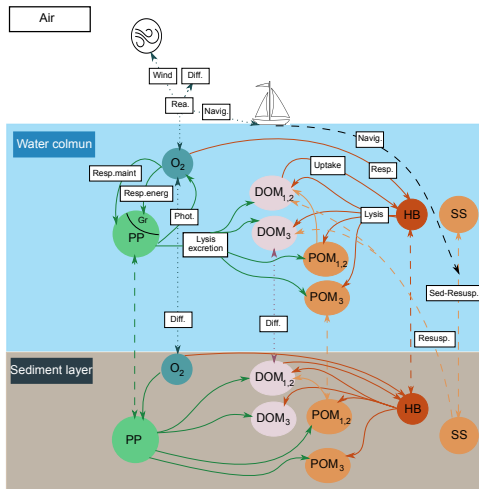





FIGURE A.1 – Structure du modèle PROSE.  $u(x,y,t)$ ,  $h(x,y,t)$ ,  $P_i(x,y,t)$  et  $D_i(x,y,t)$  correspondent à la vitesse d'écoulement, à la hauteur d'eau et flux d'espèces particulières et dissoutes au point  $(x,y)$  à l'instant  $t$ .  $Q(x,t)$  est le débit à la section d'abscisse  $x$  et au temps  $t$ .

# Module biogéochimique C-RIVE



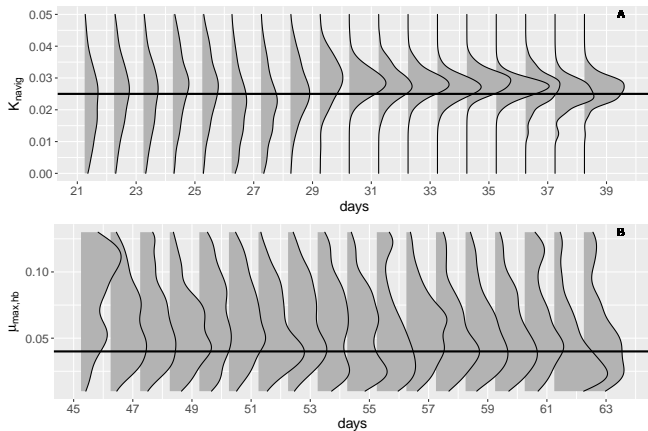
extrait de Wang et al. [2018]

# Quelques résultats






# Quelques résultats






extrait de Wang et al. [2019]

# Quelques résultats



extrait de Wang et al. [2019]

# Quelques résultats



# References

- Shuaitao Wang, Nicolas Flipo, and Thomas Romary. Time-dependent global sensitivity analysis of the c-rive biogeochemical model in contrasted hydrological and trophic contexts. *Water research*, 144:341–355, 2018.
- Shuaitao Wang, Nicolas Flipo, and Thomas Romary. Oxygen data assimilation for metabolism's parameter estimation in urban river systems. *submitted to Water research*, 2019.
- Christopher K Wikle and L Mark Berliner. A bayesian tutorial for data assimilation. *Physica D: Nonlinear Phenomena*, 230(1-2):1–16, 2007.