

# Paradigme bayésien et traitement des incertitudes

A. PASANISI





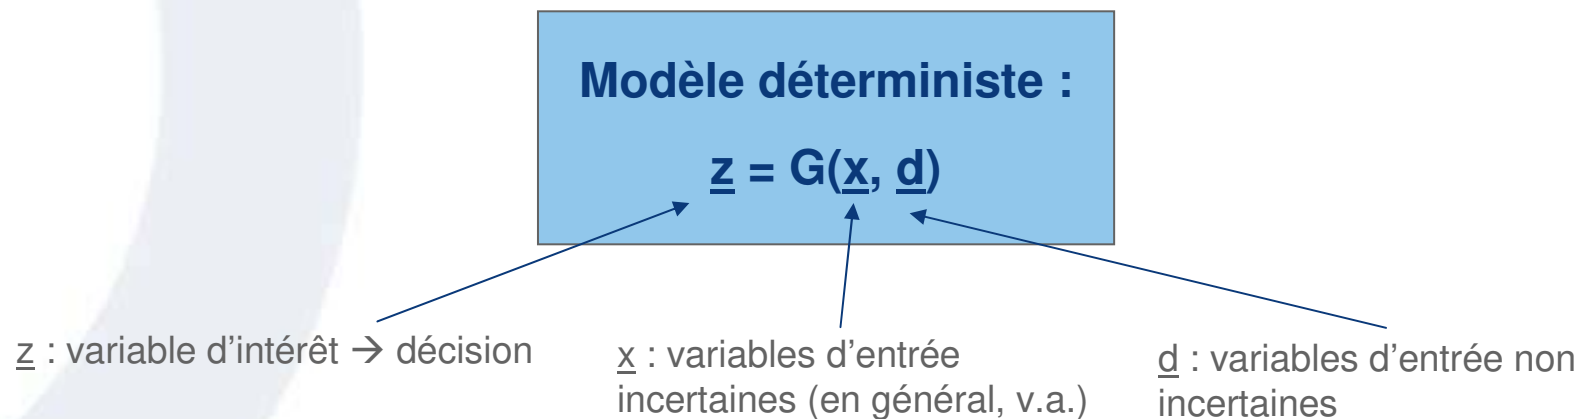
La problématique  
« Incertitudes » à EDF-R&D



# Traitement des incertitudes à EDF-R&D

## Problématique :

- $\underline{z}$  : variable d'intérêt → enjeux décisionnels (ex. débit de crue d'une rivière, émissions CO<sub>2</sub> d'une centrale thermique, prix demain à 7h d'1 MWh électrique ...)
- $\underline{z}$  est issue d'un modèle déterministe (physique, économique ...) dont certaines variables d'entrée ( $\underline{x}$ ) sont incertaines
- Objectif : quantifier proprement l'incertitudes sur la variable d'intérêt  $\underline{z}$

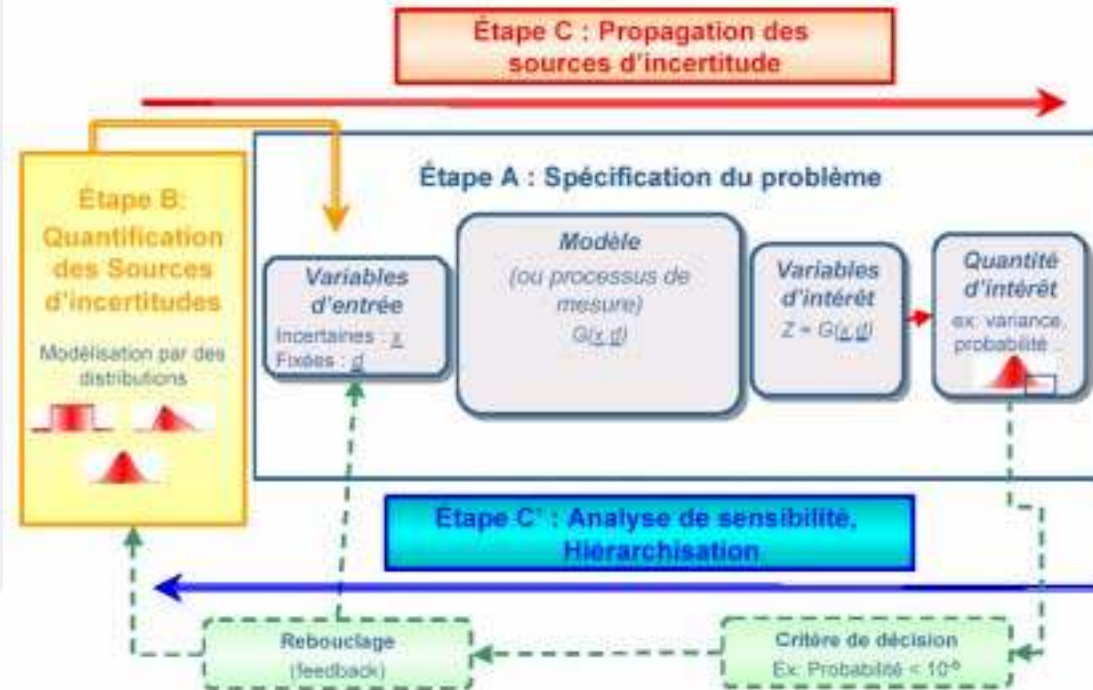




# Cadre méthodologique

Grandes étapes d'une étude d'incertitudes :


- Spécification du problème : Quel modèle  $G$  ? Quelle variable d'intérêt ? Quelle quantité associée à la variable  $z$  (moyenne, éc. type, prob. de dépassement ...)
- Modélisation des sources d'incertitudes  $\rightarrow$  établir la loi de probabilité de  $x$
- Propagation des sources d'incertitudes de  $x$  vers  $z$  (méthodes Monte-Carlo adaptées ...)
- Analyse de sensibilité, hiérarchisation des sources d'incertitudes





# Un sujet de recherche très actif

OPUS



Ecole Nationale Supérieure des Mines SAINT-ETIENNE

CSDL – Complex System Design Lab

Thalès, DA, Renault, EADS, MDBA, INRIA, ONERA, ECP, SUPELEC, École des Mines




- Univ. Paul Cézanne
- Univ. d'Orsay
- Univ. Joseph Fourier
- Univ. of Florida
- TOTAL
- IRSN
- ONERA
- RENAULT
- EDF

**Groupement De Recherche MASCOT NUM**

Méthodes d'Analyse Stochastique pour les Codes et Traitements NUMériques



Institut pour la Maîtrise des Risques  
Sûreté de Fonctionnement - Management - Cindyniques




**ESReDA**  
European Safety, Reliability & Data Association





# Un sujet de recherche très actif



Ouvrage ESReDA :  
traitement des  
incertitudes dans la  
pratique industrielle





Plate-forme de calcul  
probabiliste et  
propagation  
d'incertitudes Open  
URNS (EDF-EADS-  
Phimeca)

R&D « amont » (thèses, Post-doc, publications scientifiques)

- Méthodes Monte-Carlo avancées pour l'estimation de faibles probabilités
- Modélisation de la dépendance statistique par la théorie des copules
- Modélisation inverse probabiliste
- Application de la théorie de Dempster-Schäfer
- Chaos polynomial



Paradigme bayésien et  
incertitudes : quelques  
idées clés



# Paradigme bayésien

Elements de base :

- Données  $x$  (réalisations d'une v.a. observable)
- Un modèle statistique paramétré par  $\theta$
- Les paramètres  $\theta$  sont inconnus mais on dispose d'une connaissance préalable (a priori) exprimée sous la forme d'une distribution de probabilité  $\pi(\theta)$
- La formule de Bayes donne la distribution de probabilité de  $\theta$  conditionnellement aux données observées  $\pi(\theta|x)$

$$\begin{array}{c} \text{Loi a priori de } \theta \quad \text{Vraisemblance} \\ \downarrow \qquad \qquad \downarrow \\ \pi(\theta) \cdot f(x|\theta) \\ \text{Loi a posteriori} \longrightarrow \pi(\theta|x) = \frac{\pi(\theta) \cdot f(x|\theta)}{\int \pi(\theta) \cdot f(x|\theta) d\theta} \\ \text{de } \theta \\ \uparrow \\ \text{Constante de normalisation} \end{array}$$





# Paradigme bayésien et incertitudes

- La formule de Bayes donne la distribution de probabilité a posteriori  $\pi(\theta|x)$  des paramètres du modèle.
- Cette incertitude se propage naturellement sur la variable observable  $x$  et sur toute autre v.a. issue d'un modèle paramétré par  $\theta$

$$\underbrace{\pi(\tilde{x} | x)} = \int \pi(\tilde{x}, \theta | x) d\theta = \int \underbrace{\pi(\tilde{x} | \theta)} \cdot \underbrace{\pi(\theta | x)} d\theta$$

Distribution  
« prédictive » de la  
v.a observable  $x$

Modèle  
statistique

Distribution a  
posteriori de  $\theta$

La distribution prédictive intègre :

- L'incertitude d'échantillonnage (pour  $\theta$  fixées la valeur de  $x$  est incertaine)
- L'incertitude d'estimation sur les paramètres  $\theta$ , décrite par la distrib. a posteriori

L'incertitude décrite par la loi prédictive peut être propagée sur toute variable  $z$ , liée à  $x$  par un modèle déterministe :  $z = G(x, d)$



# Paradigme bayésien et incertitudes

Le cadre bayésien est particulièrement adapté au traitement et à la propagation des incertitudes :

- **L'approche bayésienne est, par essence, une approche de niveau 2 :**
  - Incertitude sur les variables observables  $X$  (aléatoire).
  - Incertitude sur les paramètres  $\theta$  des lois de probabilités de  $X$  (épistémique).
  - Éventuellement, il est possible de rajouter un troisième niveau d'incertitude sur le modèle statistique (facteurs de Bayes, cf. exemple).
  - Ces différents niveaux d'incertitudes se propagent **naturellement** par marginalisation d'une loi jointe de probabilité.
- **L'approche bayésienne est adaptée aux applications industrielles :**
  - Souvent, peu de données mais expertise disponible.
  - Historique important à EDF-R&D (MRI) dans le domaine de la fiabilité des composants (Lannoy, Procaccia, Clarotti, Celeux ... )




# Perspectives

Une thèse est déjà prévue (début d'un stage en février, puis thèse en septembre 2009)

## **Montrer par l'exemple la pertinence de l'approche bayésienne dans un contexte industriel**

- Analyse et étude de 3 cas issus de différents champs d'application (ex. fiabilité, hydraulique, thermique des bâtiments ...).
- Déploiement des méthodes et outils de l'analyse bayésienne (élicitation, inférence par méthodes Monte-Carlo, choix de modèle, propagation).
- Comparaison avec les résultats obtenus avec une approche fréquentiste de niveau 2
- ...




Quelques résultats  
d'une première étude  
(Andrianov, Fisher,  
Nabahane, 2008)



# Un modèle analytique simple

Problème : protection d'un centre habité vis-à-vis du risque « inondation »



- **Zc : côte maximale atteinte par la crue (variable d'intérêt)**
- Zm et Zv : côtes du fond du cours d'eau (v.a.)
- Q : débit du cours d'eau (v.a.)
- Ks : coefficient de frottement de Strickler (v.a.)
- B, L : Largeur et longueur du tronçon du cours d'eau (déterministe)

$$Zc = \left( \frac{Q}{K_s \cdot \sqrt{\frac{Z_m - Z_v}{L}} \cdot B} \right)^{3/5}$$



# Problème

On veut évaluer la probabilité que la cote  $Z_c$  dépasse la hauteur  $Z_d$  (fixée) d'une digue de protection

L'incertitude sur  $Z_m$  et  $Z_v$  est décrite par des lois triangulaires.

L'incertitude sur  $K_s$  est décrite par une loi normale.

Pour décrire l'incertitude sur  $Q$ , on teste plusieurs variables :

- Gumbel
- Log-Normale
- Normale (on choisit volontairement une loi qui n'est pas adaptée)

Dans ce cas, aucune loi n'est rejetée par les tests d'ajustement classiques ! En théorie, on serait tenté de prendre le résultat le plus conservatif !

Avec la technique des facteurs de Bayes, il est possible d'évaluer la « probabilité a posteriori » associée à chacun des 3 modèles en compétition



# Probabilités à posteriori des modèles

Ensemble de  $n$  modèles en compétition  $M_1, M_2, \dots, M_n$   
paramétrés par  $\theta_1, \theta_2, \dots, \theta_n$

$$B(M_i, M_j) = \frac{P(M_i) \cdot \int f(D|\theta_i, M_i) \cdot \pi(\theta_i|M_i) d(\theta_i)}{P(M_j) \cdot \int f(D|\theta_j, M_j) \cdot \pi(\theta_j|M_j) d(\theta_j)}$$

Facteurs de Bayes

$$\frac{P(M_i) \cdot \int f(D|\theta_i, M_i) \cdot \pi(\theta_i|M_i) d(\theta_i)}{\sum_j P(M_j) \cdot \int f(D|\theta_j, M_j) \cdot \pi(\theta_j|M_j) d(\theta_j)}$$

Probabilités a posteriori des  $n$  modèles

Deux façons d'utiliser ces probabilités :

- On choisit le modèle le plus probable
- On introduit une incertitude "de niveau 3" sur le modèle → mélange des 3 modèles selon les probabilités respectives (Bayesian Model Averaging, Raftery)



# Quelques résultats

Probabilités de surverse pour une valeur fixée de la hauteur de la digue de protection (espérance a posteriori)

<b>Zd (m)</b>	<b>Q modelling</b>	<b>P(S&lt;0 Zd, Q)</b>
57.8	Gumbel	$1.18 \cdot 10^{-3}$
57.8	Normal	$7.4 \cdot 10^{-4}$
57.8	LogNormal	$2.58 \cdot 10^{-3}$
57.8	Bayesian MA (gaussian prior)	$1.40 \cdot 10^{-3}$
57.8	Bayesian MA (uniform prior)	$1.13 \cdot 10^{-3}$

L'utilisation du modèle log-normal aurait mené à une surestimation de la prob. de défaillance, ou à un surdimensionnement de la digue (à probabilité fixée)