

Un référentiel européen sur les incertitudes et quelques nouveaux défis pour la simulation

E. de Rocquigny

Mission transverse EDF R&D
« statistiques et incertitudes »

Chairman, ESReDA Uncertainties

Plan de la conférence

- ESReDA : un *référentiel industriel européen* sur les incertitudes
- Nouveaux défis pour la simulation

ESReDA – a European industry-reference on uncertainty

- ESReDA = European Safety Reliability & Data Association
 - Established 1990, gathering some 52 members Europe-wide (80% industrial)
- Key goals of the Uncertainty Project Group (est. end 2004)
 - Provide a European industry-realistic guidelines on “Uncertainties”
 - Facilitate cultural dissemination for non-specialists
- Key steps
 - A book in early 2008 with John Wiley
 - Prepare through *intensely cooperative* working meetings

Key success features

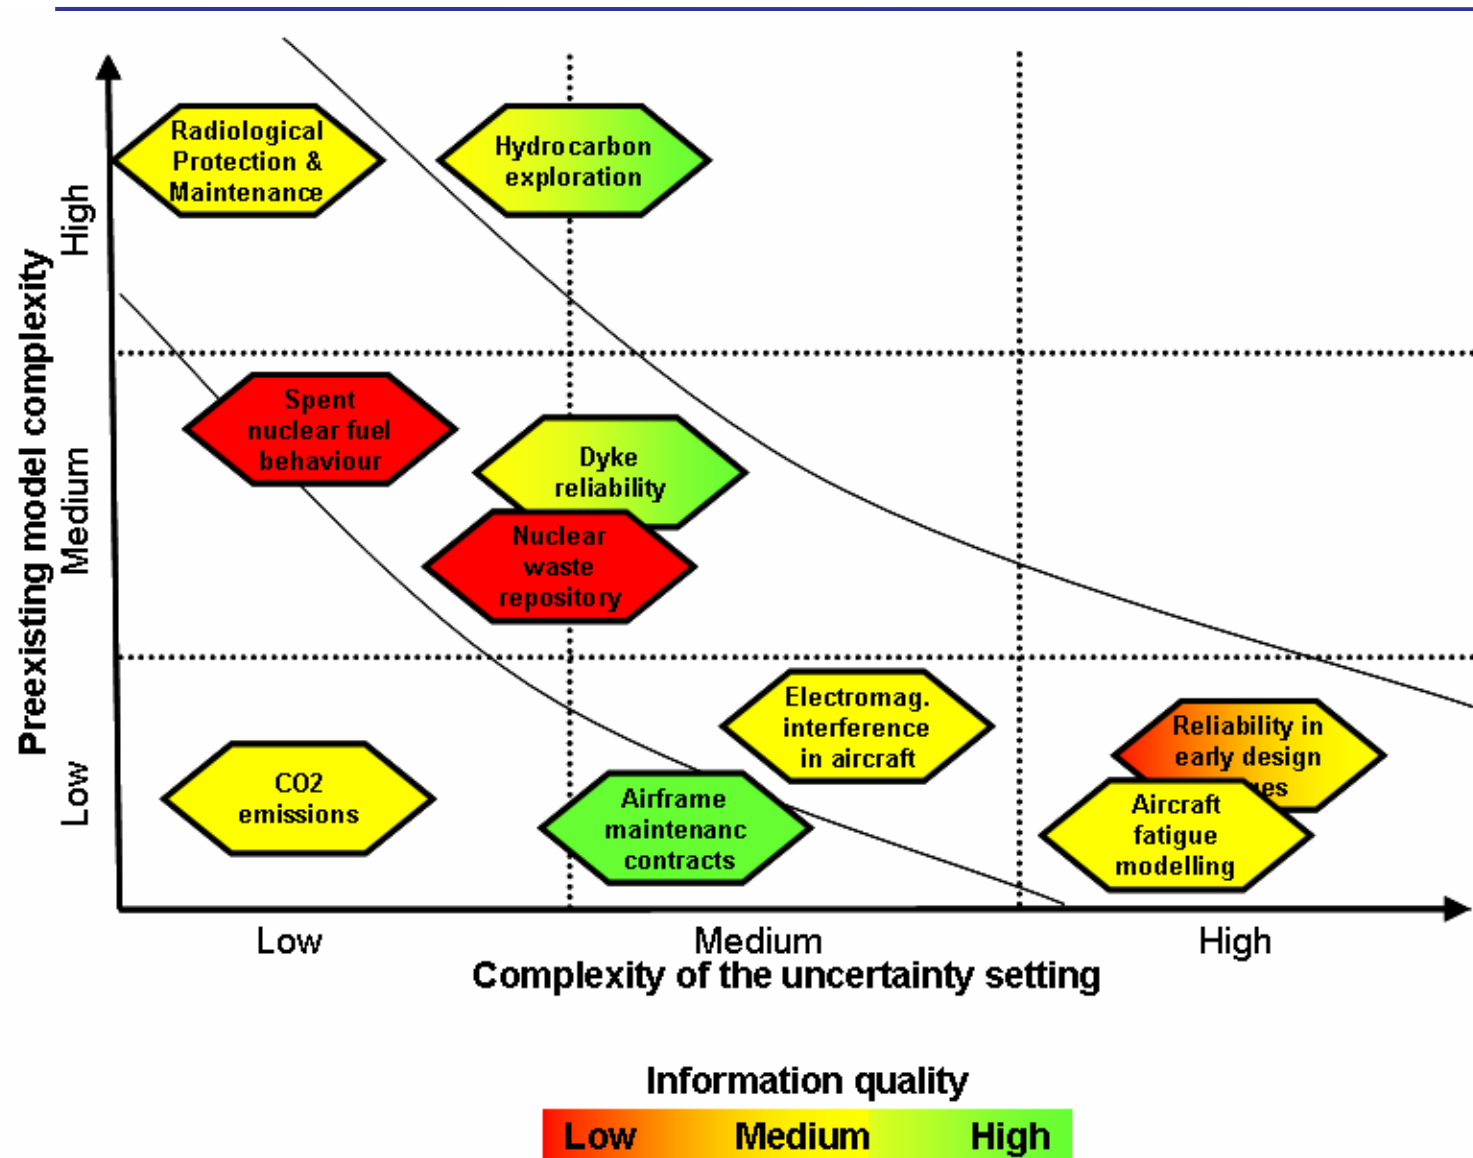
- Build on practical industrial examples
 - practice vs theory
- Be cross-disciplinary ... *uncertainties in the real world do not restrict to one field*
 - Ex1 : in flood protection, use statistics on flow ; metrology and command/control uncertainties ; SRA on flood defence ; PSA in decision-making
 - Ex2 : external costs ; mix uncertainties on pollutant measurement, propagation, and uncertainties on health impacts + costs
- Refer to existing standards + best scientific references
 - Ex: IPCC guidelines, GUM/ISO in metrology, Sandia Labs etc.
- *Not a standardisation effort as such, but link to on-going reg. (EU Comm.)*

Diversity of case studies

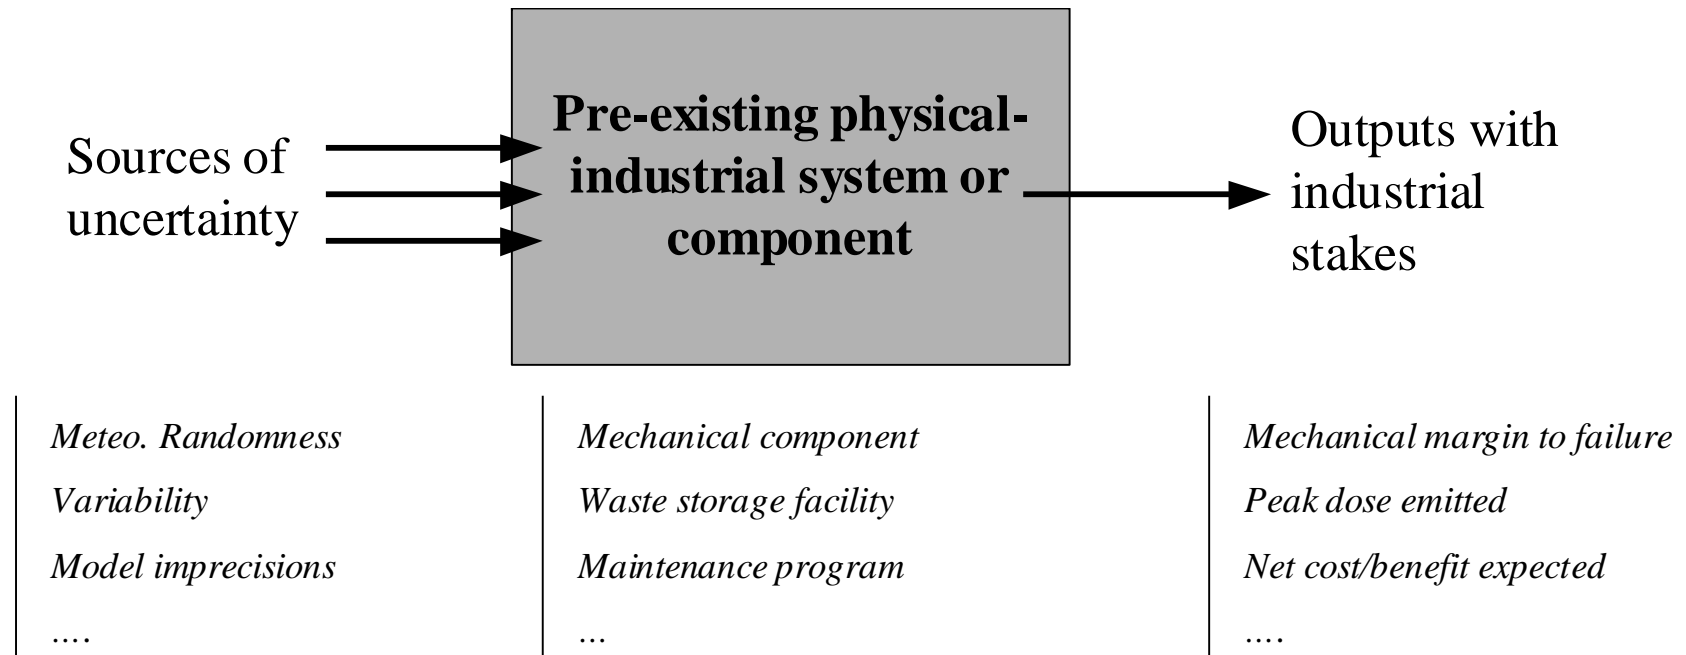
- **Power (thermal) - CO2 emission control**
- **Nuclear – Maintenance and radioprotection**
- **Nuclear - Safety of Waste**
- **Nuclear – safety of interim storage**
- **Aerospace – EM compatibility – Personal Electrical Devices**
- **Aerospace – Fatigue modelling**
- **Aerospace - Maintenance contracts**
- **Reliability in early Design / Mechanical industry**
- **Civil engineering – safety of river dikes**
- **Oil industry – performance of oil exploration**

Nationalities : France, Germany, Holland, Italy, Spain / European Commission JRCs

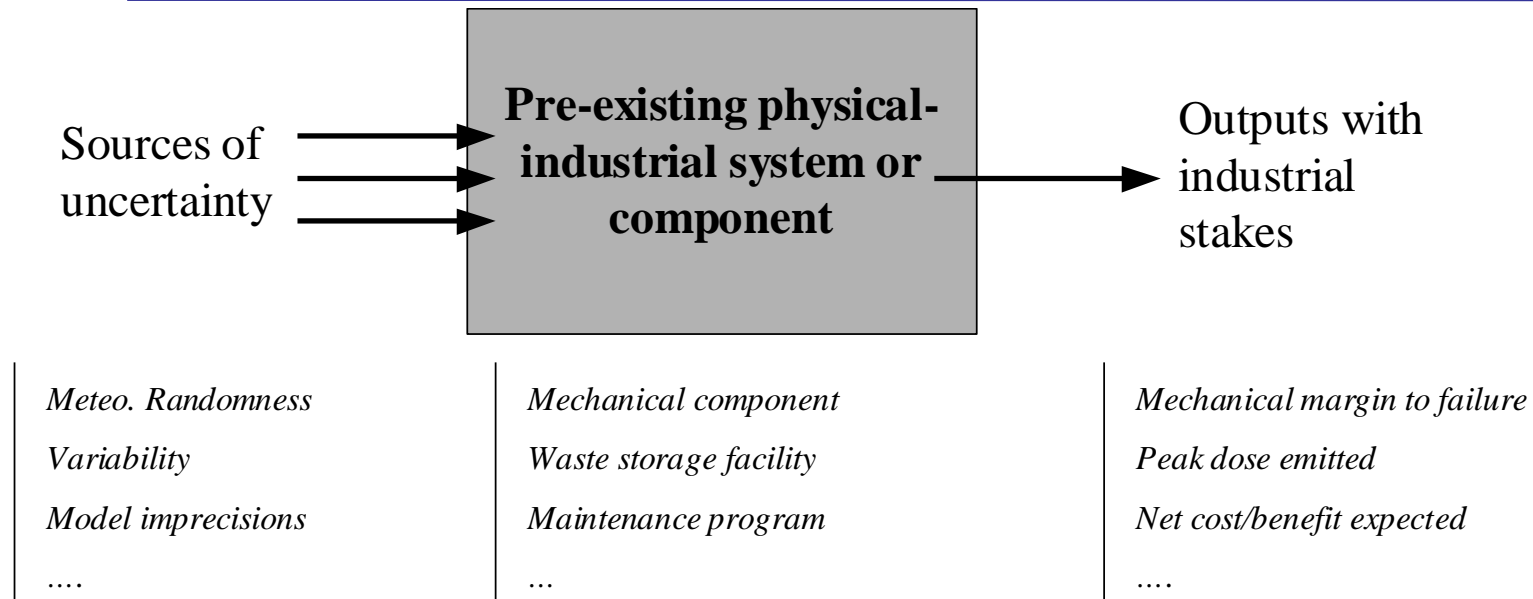
Diversity of case studies



Basic framework



Key items for an uncertainty study



- One of 4 salient goal
- The role of the quantity(ies) of interest (+ variable(s) of interest, decision criterion, uncertainty setting)
- Key features of the pre-existing model
- A necessary feedback process

Common framework – key goals of an Uncertainty study

Four final goals for most uncertainty studies => a key difference for the methods :

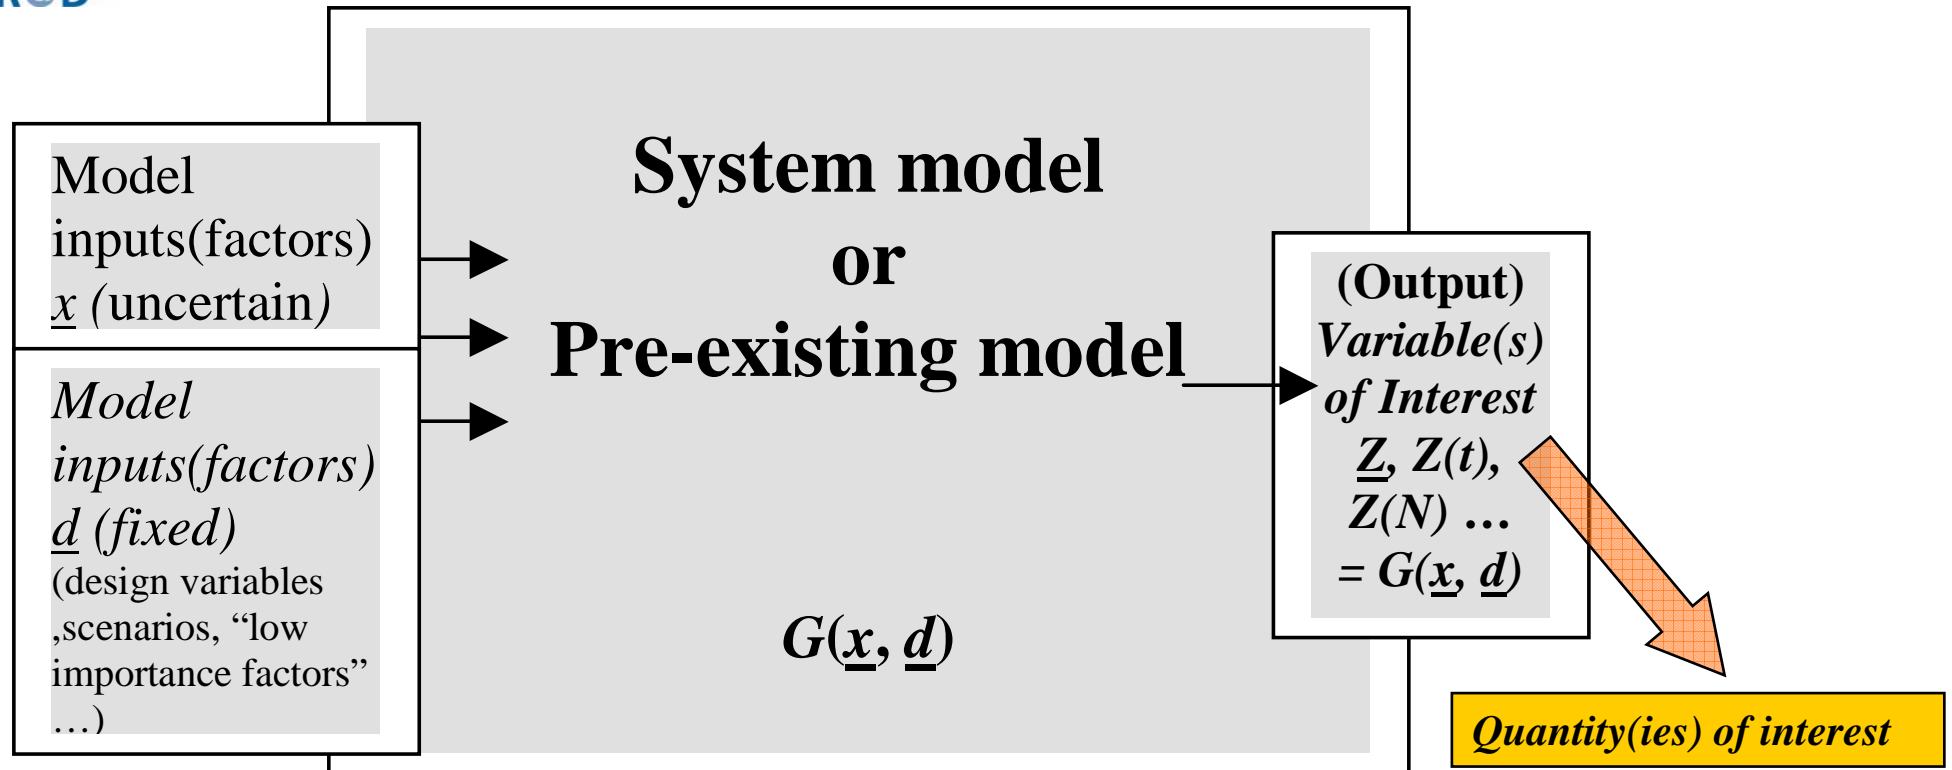
Understand Influence of sources/ Rank Importance / Prioritize uncertainty

Validate / Trust, through model calibration / simplification

Select through comparison of relative performance (on quantities of interest) / Optimisation

Comply with threshold / criterion

Modelling framework and *quantities of interest*



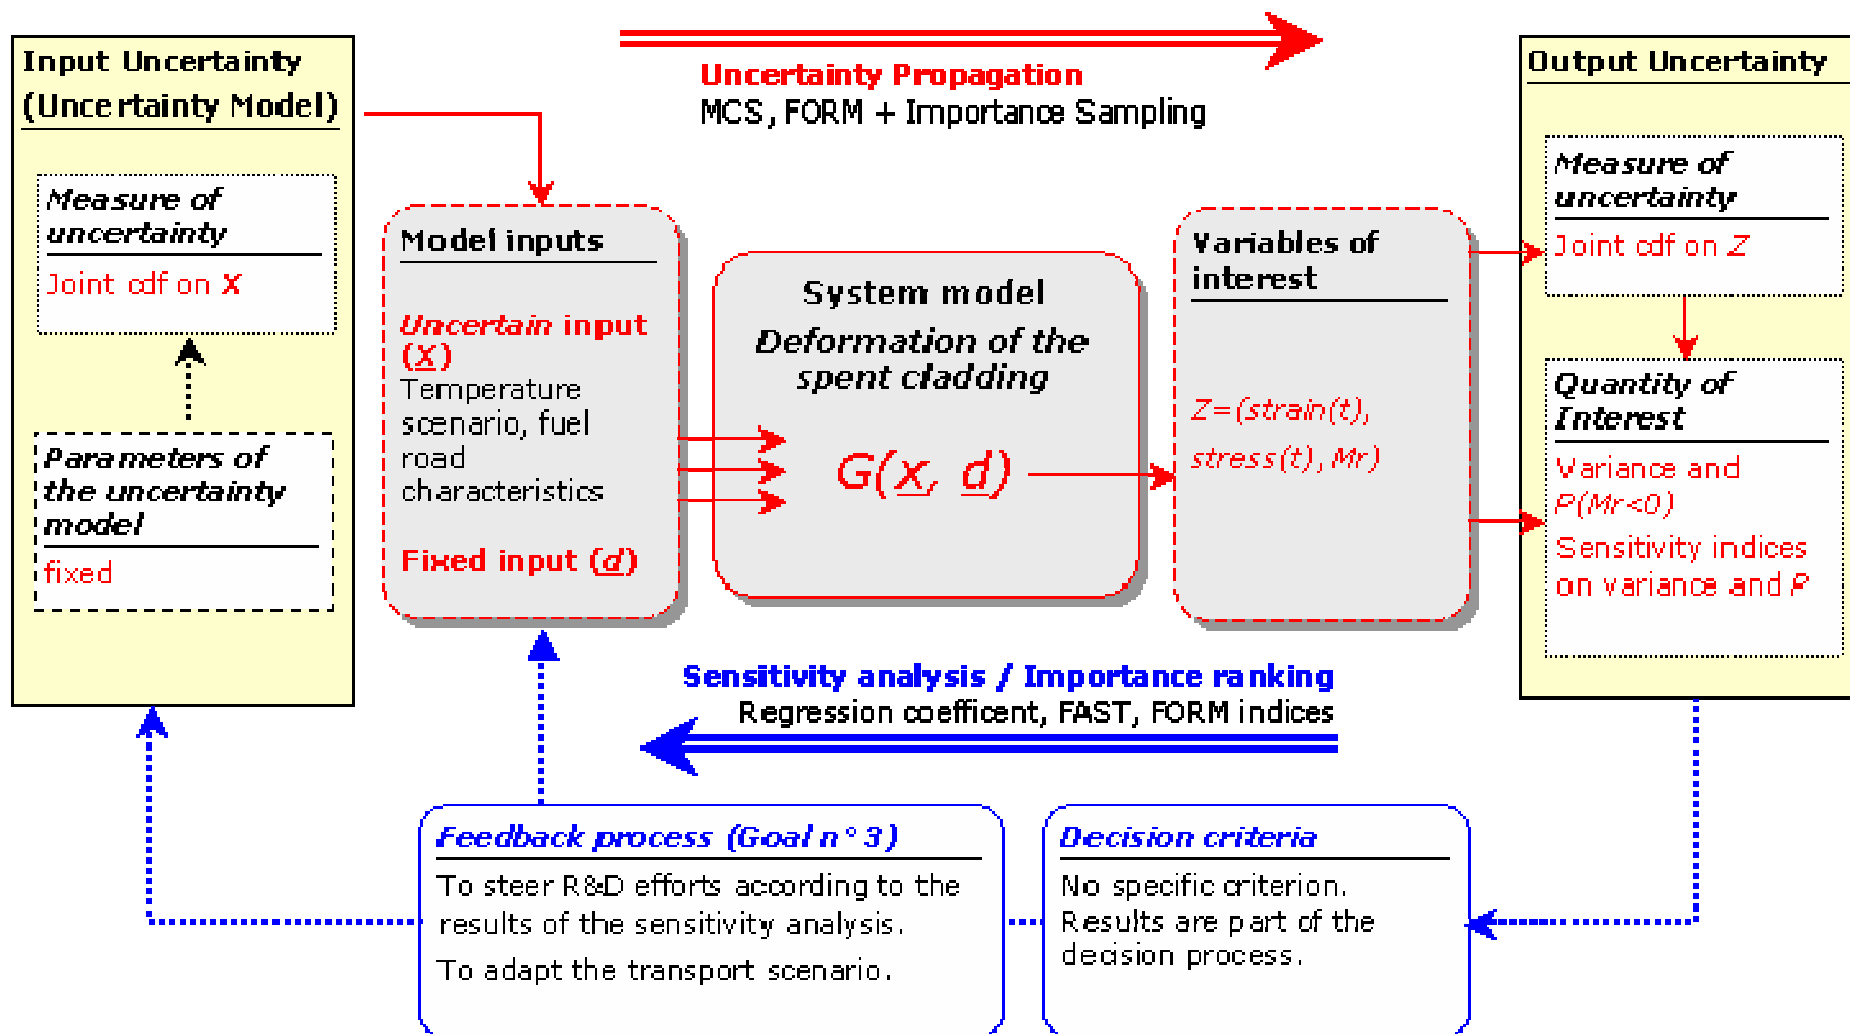
$$P(z < z_s) \text{ (e.g. } z=R-S < 0)$$

$$C_v(z), \text{ Var}(z), f_z \text{ (pdf)}$$

$$Bel(z < z_s \mid d_1) > Pl(z < z_s \mid d_2)$$

$$P(d_i = \text{Argmax}_d(G(X, d)))$$

Common conceptual framework



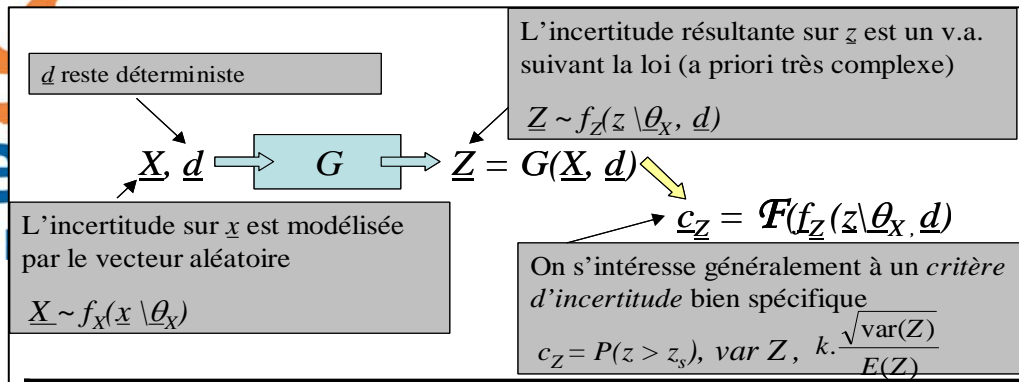
Common framework – goals and quantities of interest

| Goals | Handling the q.o.i. | Comments |
|-------------------------------------|--|---|
| Comply | Demonstrate a threshold on a q.o.i., e.g. $P(Z < z_s d) < 10^{-x}$, $cv(z) < b\%$... | Mostly mixed deterministic / proba. |
| Select | Choose d to minimize a q.o.i. e.g. $E(G(x,d))$, $G(x,d)^{95\%}$ | Mostly a few scenarios ... <i>towards frontier optimisation</i> |
| Understand | Which x^i contributes most to the q.o.i. e.g. $Var[G(X,d)]$, $P(Z < z_s d)$... ? | Large literature on variance or distribution analysis |
| Validate (calibrate / simplify ...) | Identify X / measurements, or downscale X or G , provided control on q.o.i. ... | Largely empirical ... <i>towards complex stats.</i> |

Common framework – key steps of an uncertainty study

- Specify final goal, chain of model and choose uncertainty setting
 - Build Uncertainty model
 - Propagation
 - Sensitivity analysis / importance ranking
- + *Feed-back process (New data ; Adjust X, d ; Simplify model ; Deterministic compliance)*

Les grandes étapes



| | | | |
|----------|---|---|--|
| Etape A | Spécifier le problème | Choisir \underline{x} , \underline{d} , $G(.,.)$ et un critère ($C_Z = P(Z > z_s)$ ou $\text{var } Z \dots$) | Sciences de la décision, analyse du risque, cadre classique ou bayésien ... |
| Etape B | Modéliser /Quantifier les sources | Modéliser \underline{X} en estimant θ_X d'après $(X_j)_j$ ou expertise | Echantillonnage paramétrique classique ou bayésien <i>Mais aussi</i> : non-paramétrique, copules (loi jointe) ... |
| Etape C | Propager | Estimer f_Z (ou plutôt C_Z) | Taylor, Monte-Carlo et accélérées, Form-Sorm, Plans d'Exp./Surfaces de Réponse ... |
| Etape C' | Hiérarchiser l'importance des sources <i>Sensitivity analysis</i> | Estimer des S_X (selon C_Z) $S_X = \frac{\text{Corr}(Z, X^i)^2}{\sum_{i=1}^N \text{Corr}(Z, X^i)^2} \cdot \frac{\text{Var}(E[Z X^i])}{\text{Var}(Z)}$ | Idem + RCC/ PRCC, indices de Sobol estimés par MCS, quasi-MC ... , FAST, |

Characteristics of pre-existing models and choice of methods

The key characteristics to choose between methods
(MCS, Form, response surface, chaos polynomials, ...)

:

- *Quantity of interest*
- *Data available*
- *Computing constraints on $G(\cdot)$*
 - Dimension of X
 - Dimension of Z
 - Regularity of $G(\cdot)$

Role of probabilistic settings ?

- Probabilistic/statistical settings : a central but non exclusive role
 - Proba/stat. modelling refines purely deterministic margins
 - Not necessarily applicable to all types of uncertainties – *mix deterministic/probabilistic - according to the case*
 - Separate epistemic / aleatory natures ? *Inventory is useful as a check-list ... adapt to criterion / model etc.*
 - Mixed non proba. / proba. : *not yet industrially mature ... to be followed on*

? Common framework –Uncertainty settings

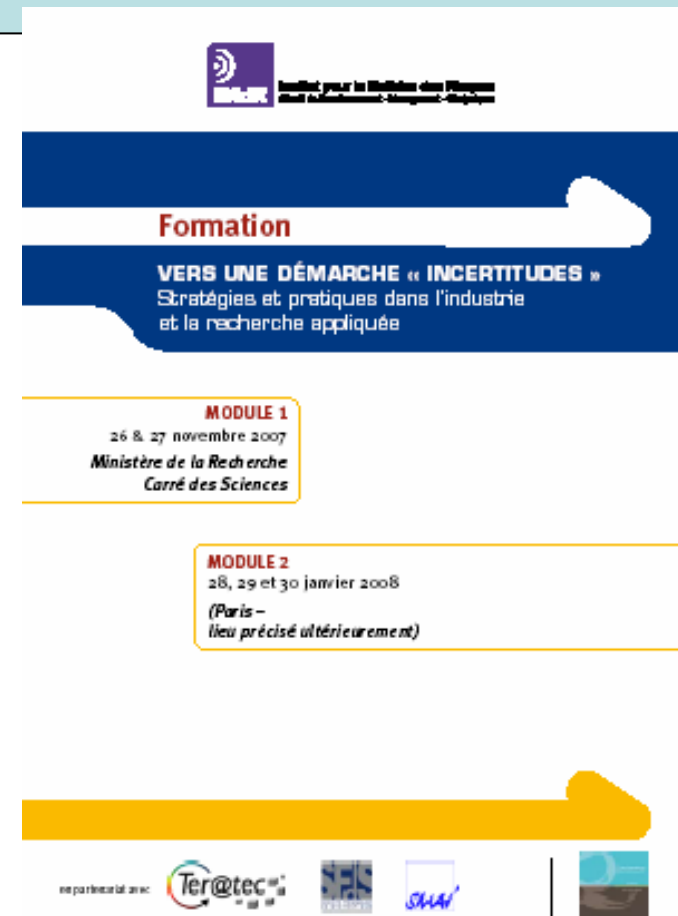
| Name | Level 1 uncertainty | Level 2 Parameters of the uncertainty (« epistemic ») |
|--------------------|----------------------------------|---|
| Determ. | X at « Worst value » (intervals) | Fixed (fixed bounds) |
| Standard proba. | $X \sim \text{pdf}$ | Fixed parameters θ_x of the pdf |
| Proba + L2 Determ. | idem | Deterministic interval for θ_x |
| Double Proba | idem | θ_x becomes a random vector |
| Mixed proba. / DST | Idem (or not ...) | θ_x becomes DST belief / plausibility df. |

- Book release around early 2008

« Uncertainty in Industrial Practice », Wiley

• Formation IMdR – Teratec
- SFdS – SMAI

*26/27 novembre 07 + 28/30
janvier 08*



IMdR Institut pour la Maîtrise des Risques
dans les Activités Technologiques


Formation

VERS UNE DÉMARCHE « INCERTITUDES »
Stratégies et pratiques dans l'industrie
et la recherche appliquée

MODULE 1
26 & 27 novembre 2007
Ministère de la Recherche
Carré des Sciences

MODULE 2
28, 29 et 30 janvier 2008
(Paris –
lieu précisé ultérieurement)


en partenariat avec



Nouveaux défis pour la simulation

- *Understand* >> Sensibilité (en grande dimension)
- *Comply* >> Propagation d'incertitudes (robuste, et de « niveau 2 »)
- *Validate* >> Calibration / assimilation / méthodes inverses probabilistes

Cumuler les « incertitudes des incertitudes »



La *source d'incertitude* sur \underline{x} est modélisée par le vecteur aléatoire

$$\underline{X} \sim f_X(\underline{x} \mid \underline{\theta}_X)$$

L'*estimation* de $\underline{\theta}_X$ à données finies produit \Rightarrow variance non négligeable sur $\hat{\theta}_X$

$$c_Z = \mathcal{F}(f_Z(\underline{z} \mid \underline{\theta}_X, \underline{d}))$$

On s'intéresse généralement à un *critère d'incertitude* bien spécifique

$$c_Z = P(z > z_s), \text{ var } Z,$$

Même à $\underline{\theta}_X$ parfaitement connu, contraintes CPU de **propagation** \Rightarrow variance d'estimation parfois non négligeable $\hat{C}_z(\theta_X)$

Ordres de grandeurs des défis pour la simulation

$Z=G(X,d)$ où $X \sim f(x|\theta)$, $\dim X=p$, $\dim \theta =t$ (nb. optimal selon « régularité »)

– Propager

- Niveau 1 - $Var Z$: $n= 10^1$ à 10^2 ;
- Niveau 1 - quantile Z^α (ou $P(Z>z_s)$) : $n=10^1p$ (ou 10^2) à $>10^4$ selon α
- Niveau 2 – $x10$ (ou $x3p$) à $x10^2$

– Hiérarchiser

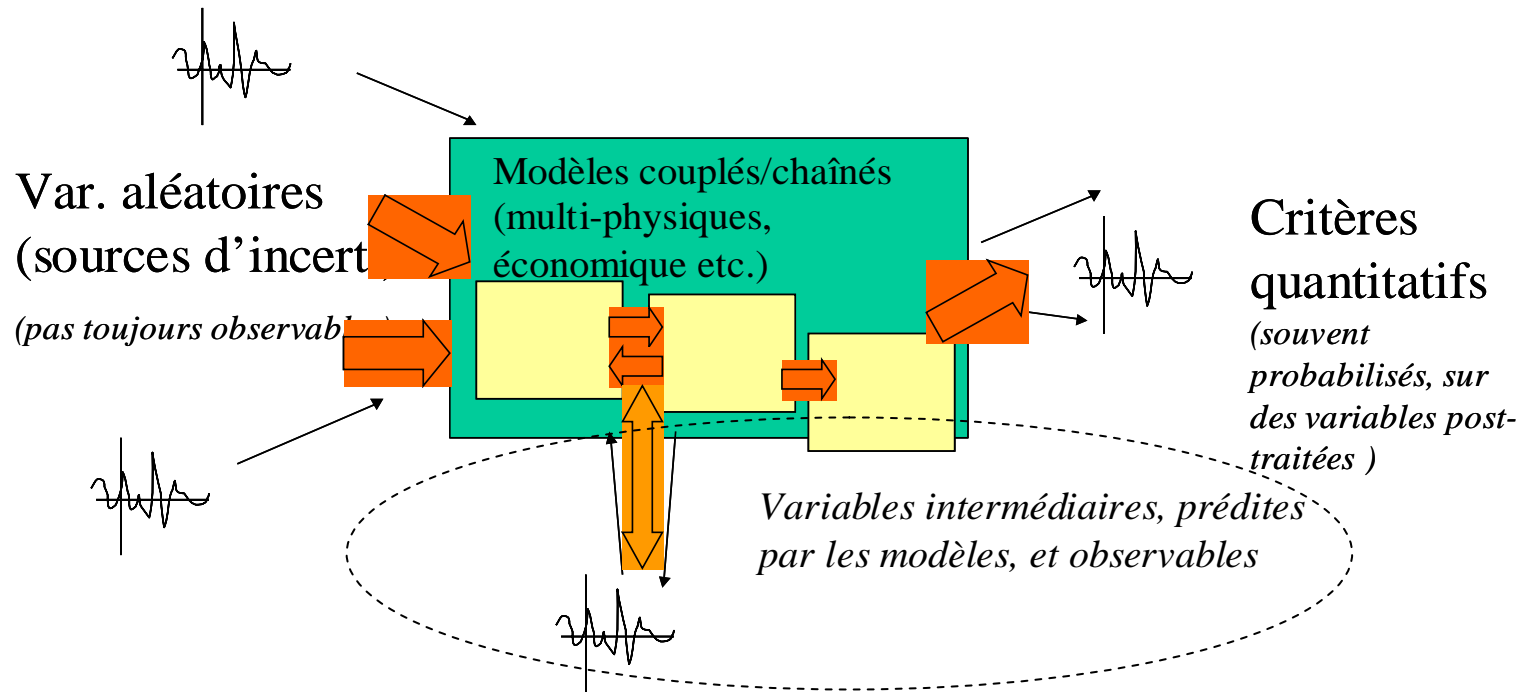
- Pour $var Z$: $n= 3p$ à $>10^3p$ (voire a^p) selon régularité code
- Pour quantile/proba dépassement : mal connu

– Calibrer / assimiler / identifier


- 10^0p à $>10^1p$ en calibration / assimilation classique
- 10^1p à $>10^4p$ en identification complète de la variabilité (du linéaire/gaussien au cas général ...)

Calibration de modèles et identification inverse d'incertitudes

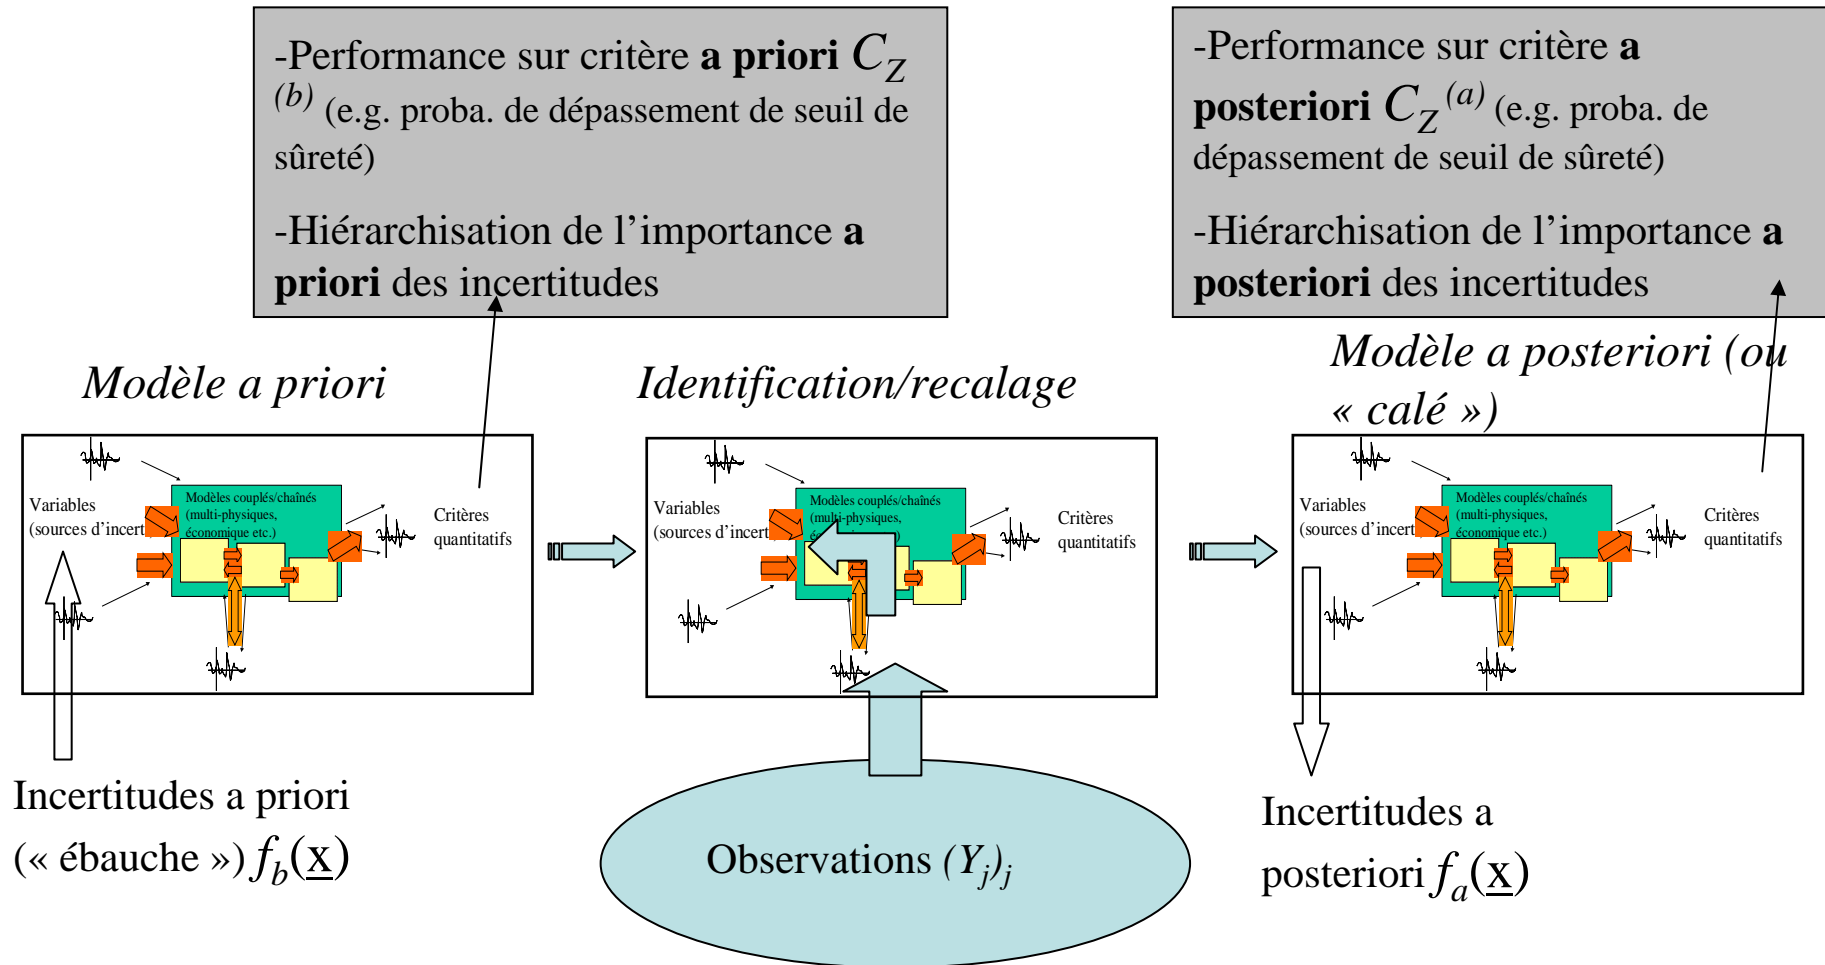
Des observations et un modèle à calibrer



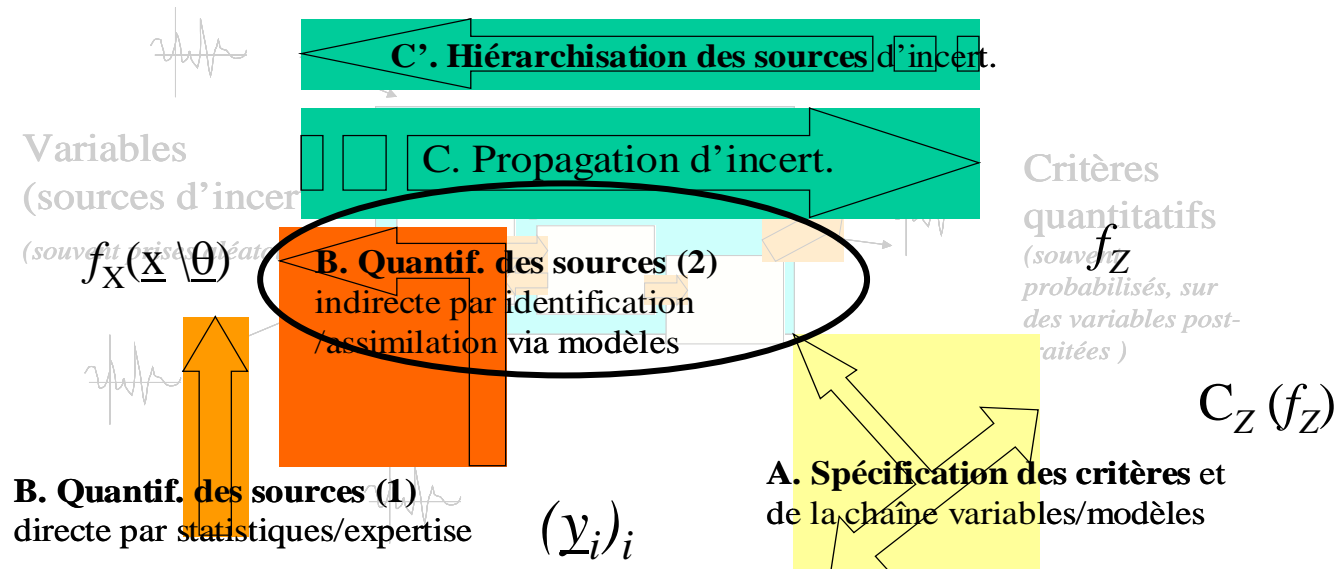
Des observations, non pas sur les paramètres \underline{x} du modèle mais sur \underline{y} (via l'erreur modèle/mesures \underline{u}) $\underline{y}_m = \underline{y} + \underline{u}$



L'étape inverse dans le processus « incertitudes »




L'étape inverse dans le processus « incertitudes »



- B, C et C' sont relativement « classiques » pour les spécialistes d'incertitudes
- B' l'est beaucoup moins ... elle a un potentiel industriel énorme ! (maîtrise dynamique des incertitudes)

Formalisation du problème de calibration inverse (sous incertitude)



d = conditions de fonctionnement / d'essais variant de façon déterministe et connue selon les p observations

$$Y_i = H(X_i^*, d_i) + \varepsilon_i^*, \quad i = 1..p$$

H est le modèle physique déterministe ... éventuellement non-linéaire

On observe les \underline{y} avec des bruits mesure-modèle incertains ... typiquement aléatoires, indépendants ... de loi parfois connue

$$\varepsilon_i^* \sim F_\varepsilon(R(d_i))$$

X_i est inobservable ... on cherche à identifier sa meilleure valeur ... voire son incertitude (taille vectorielle = 3 - 15 ...)



Une première approche : régression / assimilation de données

Depuis l'identification par méthodes inverses déterministes ...

- Techniques d'optimisation : moindres carrés ou d'autres fonctions de coût ...

$$x_a = \min_{x \in R^k} J(x) = \min_{x \in R^k} \sum_{i=1}^N \|y_i - H_i(x)\|_\alpha$$

- Avec parfois de la sensibilité « déterministe » / optimum

... généralisable par de « l'optimisation bruitée »

- En rajoutant simplement une matrice de coût

$$J(x) = \sum_{i=1}^N (y_i - H_i(x))^T R_i^{-1} (y_i - H_i(x))$$

- une interprétation proba. devient possible : variance de $X_a \sim A = \left(\frac{1}{2} J''(x_a) \right)^{-1}$

Ce sont les algorithmes de « l'assimilation de données » (i.e. régression, mais avec un modèle physique)

- Largement pratiquée en météo., etc.

Le contenu des algo. d'assimilation - cas linéarisé (1)

- Cadre linéarisé (en stationnaire) : les moindres carrés classiques ...

$$Y = H(x_t) + \varepsilon$$

On linéarise le modèle

$$H(x) = H(x_l) + \mathbf{H}(x - x_l)$$

On observe les y avec une incertitude de mesure de covariance R (sans biais)

$$\varepsilon \sim F(0, R)$$

- L'estimateur BLUE est
- de variance

$$\hat{X}_a = x_l + (\mathbf{H}^T \cdot R^{-1} \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot R^{-1} \cdot (Y - H(x_l))$$

$$V(X_a) = A = (\mathbf{H}^T \cdot R^{-1} \cdot \mathbf{H})^{-1}$$

>> c'est simplement une régression linéaire multiple un peu généralisée, ... en notant « H » par « X » et $R = \text{Id}$, on retrouve $(X'X)^{-1}$

Des limites à la calibration type « régression – assimilation » ...

- Mais la variance estimée A ne représente pas toute l'incertitude possible ...

- On montre que $A \rightarrow 0$ si $N \rightarrow \infty$

- Avec N observ. à R et H constant

$$Y_i = H(x_t, d_i) + \mathcal{E}_i = H(x_t) + \mathcal{E}_i \quad \text{avec} \quad \mathcal{E}_i \sim L(0, R)$$

$$A = \left(B^{-1} + \mathbf{H}^T \cdot \left(\frac{R}{N} \right)^{-1} \cdot \mathbf{H} \right)^{-1} \mathbf{A} \rightarrow \mathbf{0} \quad (\text{quelque soit l'ébauche})$$

- Ce qui reste vrai, même à essais/variances d'erreurs variables (démontré sous conditions algébriques raisonnables (injectivité de H – intersection nulle $\text{Ker } H_i$)

- Ce modèle probabiliste suppose l'absence de variabilité physique intrinsèque

- On a modélisé en fait l'observation de :
(x_t est inconnu mais déterministe)

$$Y_i = H(x_t, d_i) + \mathcal{E}_i = H_i(x_t) + \mathcal{E}_i$$

- Là où, physiquement, on a parfois

$$Y_i = H(X_i, d_i) + \mathcal{E}_i = H_i(X_i) + \mathcal{E}_i$$

- (X_i est inconnu ET varie aléatoirement pour $i \neq j$)

Une classe plus générale pour la variabilité intrinsèque : algo. issus d'EM

- Partir du modèle probabiliste « intrinsèque » (cadre linéaire gaussien)

$$Y_i = H(X_i^*, d_i) + \mathcal{E}_i = H_i(X_i^*) + \mathcal{E}_i$$

$$X_i^* \sim N(x_m, V) \quad \text{iid} \quad x_m, V \text{ inconnus}$$

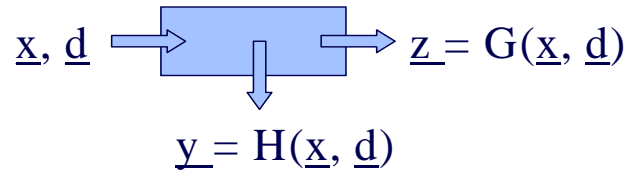
Différence majeure / régression-assimilation : X_i est non seulement méconnu mais physiquement variable (variance V inconnue)

- Minimiser une nouvelle fonction (log-vraisemblance)

$$LL((y_i)_i \setminus x_m, V, R_i) = -\frac{1}{2} \sum_i [y_i - H_i(x_m)]^T [H_i V H_i^T + R_i]^{-1} [y_i - H_i(x_m)] + \dots$$

- Ce n'est plus du tout le « moindres carrés » classique : des algorithmes itératifs plus complexes sont alors nécessaires (type E-M Expectation-maximisation)

Formalisation du problème (3)



$$\underline{y}_{m j} = H(\underline{x}^*_{j}, \underline{d}_j) + \underline{U}_j^*, \quad j = 1..n$$

Par exemple, maximiser la vraisemblance (en ajustant $\underline{\theta}_X^{un}$)

Linéaire gaussien $LL(\underline{y}_{m j} \setminus \underline{\theta}_X^{un}) = \dots \sum_j (\underline{y}_{m j} - H_j \underline{x}_m)' (R + H_j \underline{\underline{V}} H_j')^{-1} (\underline{y}_{m j} - H_j \underline{x}_m)$

...Non linéaire non Gaussien

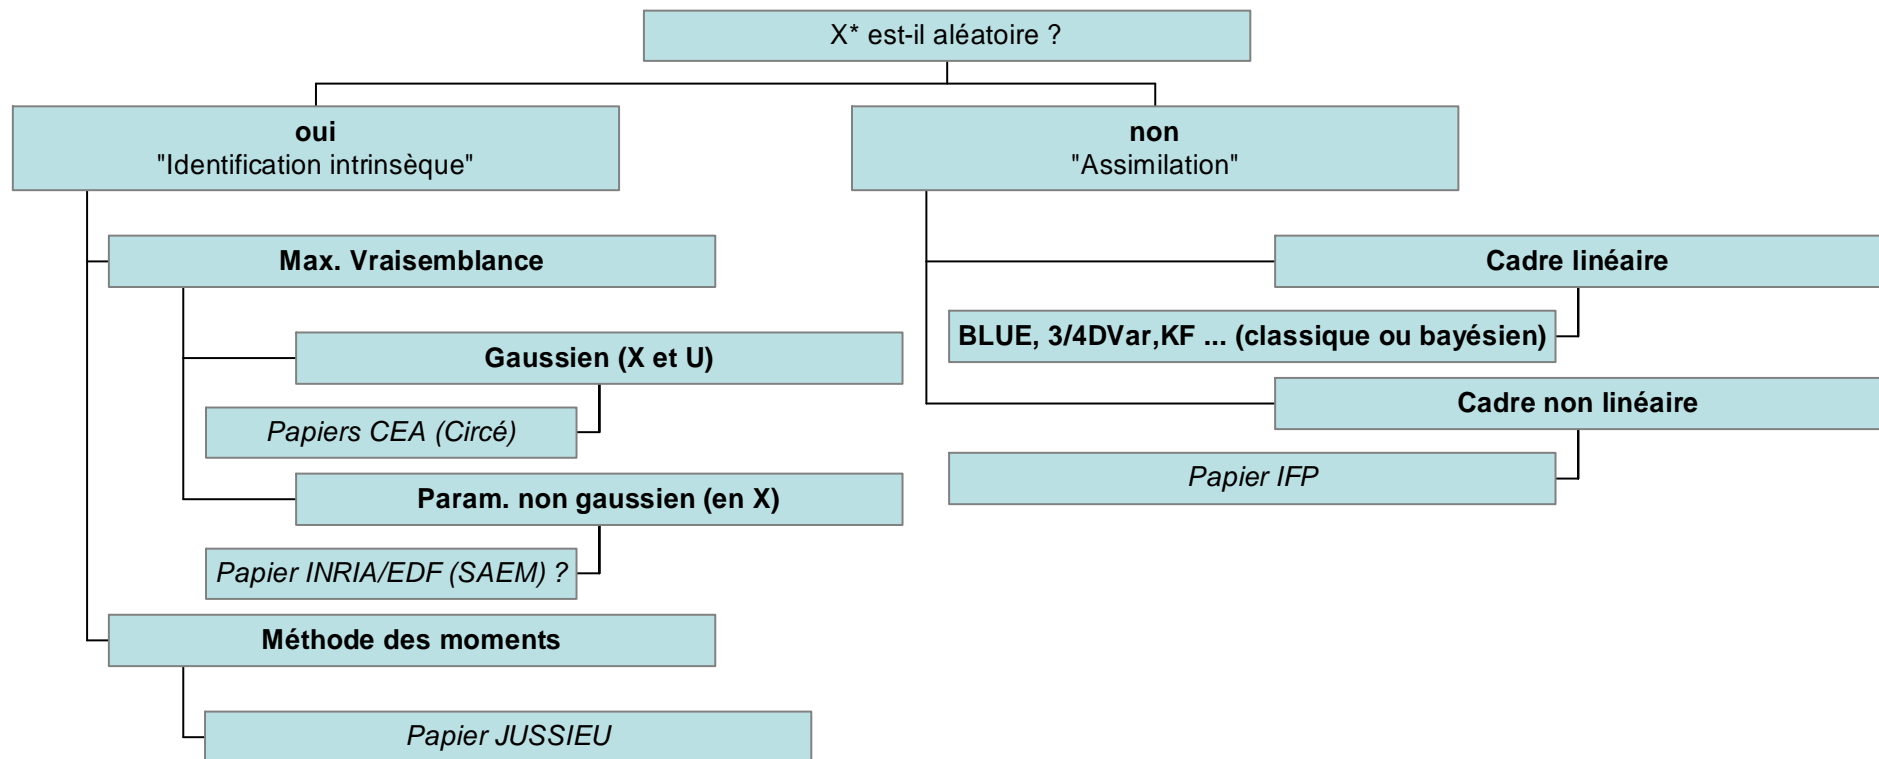
$$Lik \left[\left(\underline{y}_{m j} \right)_{j=1..n} \setminus \underline{\theta}_X^{un} \right] = \prod_j \int_{\underline{u}_j^*} f_{U_j}(\underline{u}_j^*) \left[\int_{\underline{x}^*} f_X(\underline{x}^* \setminus \underline{\theta}_X^{un}) 1_{\left[\underline{y}_{m j} = H_j(\underline{x}^*) + \underline{u}_j^* \right]} d\underline{x}^* \right] d\underline{u}_j^*$$

$$= \prod_j \int_{\underline{u}_j^*, \underline{x}^*} f_{U_j}(\underline{u}_j^*) f_X(\underline{x}^* \setminus \underline{\theta}_X^{un}) 1_{\left[\underline{y}_{m j} = H_j(\underline{x}^*) + \underline{u}_j^* \right]} d\underline{x}^* d\underline{u}_j^*$$

Algorithmes de résolution

- Max. Vraisemblance trop « gros » en général à optimiser en direct
- Idée : insérer un PE/SR adaptatif dans les algorithmes itératifs MV
 - Linéarisation (adaptative) puis E-M gaussien (Circé)
 - SAEM
 - MCMC ...

Cf. www.jds2006.fr/prob-ouverts.php



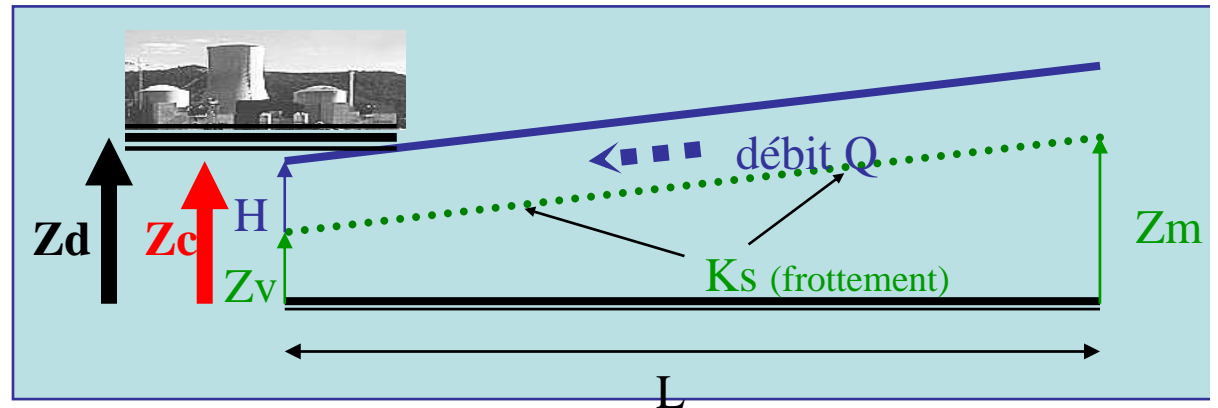
- *La 1ère question essentielle : en A.D., X^* ne devient une v.a. que par erreur d'estimation : sa vraie valeur est unique, déterministe*

L'exemple numérique des crues

- Un modèle physique simplifié (analytique, à 4 var. incertaines) ... mais à l'image d'un modèle physico-probabiliste industriel

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

$$Z = G(\underline{X}, \underline{d}) = Z_{seuil} - (Z_v + h)$$



- Critère d'intérêt = probabilité de débordement $< 10^{-3}$

$$c_Z = 1_{\{P[Z < 0] < 10^{-3}\}}$$

- On mesure (à bruits de variances connues) :
- $$\underline{Y}_m = \begin{pmatrix} Z_c \\ V \end{pmatrix} = \begin{pmatrix} Z_c^* \\ V^* \end{pmatrix} + \underline{U} = H(\underline{X}, \underline{d}) + \underline{U} = \begin{pmatrix} Z_v + h \\ \frac{Q}{h \cdot B} \end{pmatrix} + \begin{pmatrix} U_z \\ U_v \end{pmatrix}$$

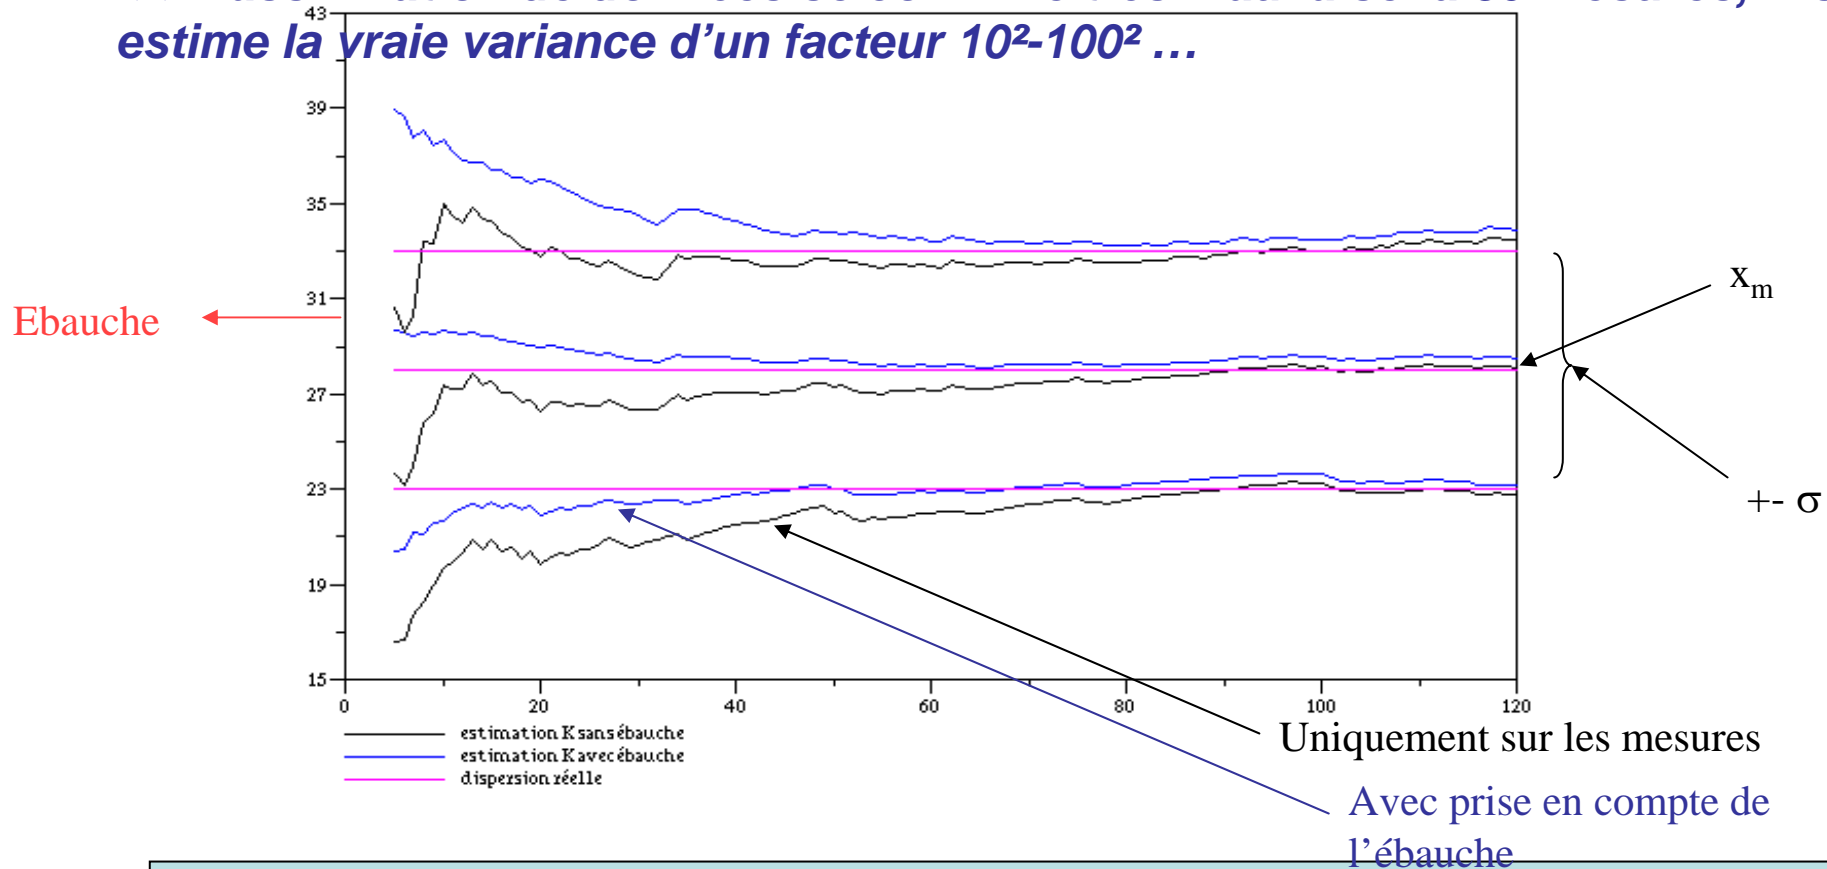
- 4 variables aléatoires, triangulaires ou gaussiennes ; 3 v.a. de paramètres inconnus, à identifier

$$\underline{X} = (X_Q \quad K_s \quad Z_v \quad Z_m) \quad X^* = X_Q \quad \underline{d} = (Q_e \quad L \quad B)$$

$$Q = Q_e \cdot (1 + X_Q)^{-1}$$

Résultats sur les crues en gaussien linéaire

•>> l'assimilation de données se confirme très mauvaise : à 30 mesures, A sous-estime la vraie variance d'un facteur 10^2-100^2 ...



Estimation raisonnable de l'incertitude, l'ébauche améliorant l'estimation à faible nb d'observations, mais détériorant un peu à N grand