

8^{èmes} Journées

Fiabilité des
MATÉRIAUX & DES STRUCTURES

Aix-en-Provence,
9 et 10 avril 2014



ECOSYSTEMES CONTINENTaux
ECCOREV
ET RISQUES ENVIRONNEMENTaux



Evaluation stochastique de la profondeur de carbonatation et actualisation des prédictions

R. Décatoire, T. De Larrard, T.
Yalamas, F. Schoefs, S-M. Elachachi



PHIMECA



ANR

AGENCE
NATIONALE
DE LA
RECHERCHE



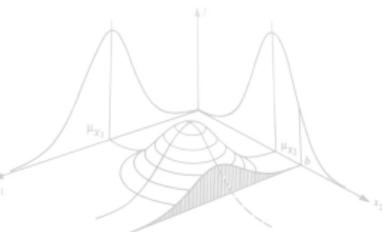
Contexte et objectifs

Contexte

- Les enjeux liés aux plans de maintenance des infrastructures en béton armé ;
- La capacité à prévoir l'évolution de leur état.

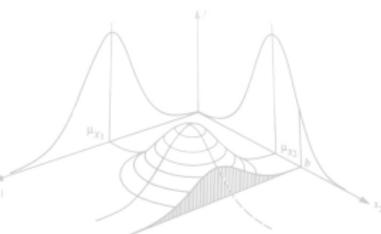
Objectifs

- 1 Explorer les possibilités des modèles analytiques de carbonatation ;
- 2 Identifier les paramètres de ces modèles sur la base de mesures fictives.



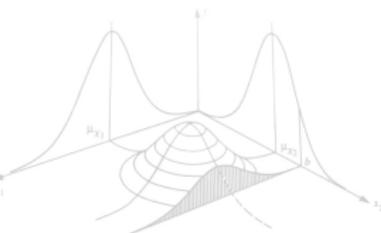
Plan

- 1 Introduction du contexte
- 2 Principe de l'actualisation Bayesienne
- 3 Cas d'étude



Plan

- 1 Introduction du contexte
 - ANR EVADEOS
 - Apports scientifiques
- 2 Principe de l'actualisation Bayésienne
- 3 Cas d'étude



Contexte du projet ANR EVADEOS

Optimisation du suivi des structures

Problématique

- Infrastructures en béton armé vieillissantes ;
- Coûts de maintenances très élevés ;
- Contexte de maintenances préventives (défaillances acceptables).

Enjeux

- Prévoir efficacement l'évolution de la dégradation ;
- Planifier les campagnes d'inspections réalisées par contrôles non-destructifs ;
- Optimiser l'espérance du coût annuel d'exploitation des structures en intégrant :
 - Les erreurs de mesures/post-traitement ;
 - La variabilité spatiale.



Apports scientifiques du projet ANR EVADEOS

L'erreur de mesure

- Utiliser les résultats des inspections pour actualiser les modèles de dégradation ;
- Données CND entachées d'erreurs ;
- Prendre en compte les erreurs d'inspections dans le processus d'actualisation.

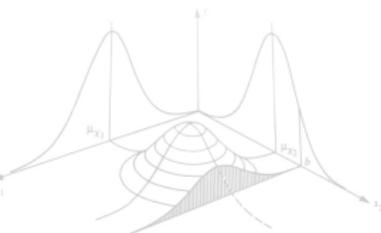
La variabilité spatiale

- Caractéristiques du béton variant spatialement ;
- Caractéristiques du béton corrélées ;
- Introduire cette variabilité spatiale dans le processus d'optimisation.



Plan

- 1 Introduction du contexte
- 2 Principe de l'actualisation Bayésienne
 - Erreur de prédiction
 - Actualisation basée sur la mesure de la sortie modèle
 - Actualisation basée sur la mesure des entrées et de la sortie modèle
- 3 Cas d'étude



L'erreur de mesure, de modèle

Décomposition de l'erreur

L'écart entre les mesures de la dégradation et les prévisions est décomposable en :

- une erreur E_{mesure} liée à l'incertitude de la mesure CND ;
- une erreur E_{modele} liée à l'imprécision du modèle de dégradation.

Réalisation de l'erreur

En considérant les deux sources d'erreurs comme étant indépendantes il vient

$$\mathbf{E} = \mathbf{E}_{mesure} + \mathbf{E}_{modele}.$$

A chaque observation Y_{obs} correspond donc une réalisation de l'erreur

$$\mathbf{E} = \{e(z_p, t_q), p = (1, \dots, P); (q = 1 \dots, Q)\}.$$



Actualisation basée sur la mesure de la sortie modèle

Écriture de la fonction de vraisemblance

- L'erreur de mesure/modèle est supposée suivre une loi normale $N(0, \sigma_e)$;
- Comme à chaque observation correspond une réalisation de l'erreur de mesure, on peut écrire les observations en fonction de l'erreur de mesure et de la sortie modèle

$$y(z_p, t_q) = M(X, t) + e(z_p, t_q);$$

- La vraisemblance s'écrit donc

$$L(\sigma_e, Y^{obs}) = \prod_{p=1}^P \prod_{q=1}^Q \varphi\left(\frac{M(x, t_q) - y(z_p, t_q)}{\sigma_e}\right);$$

- La densité *a posteriori* ne dépend que des lois *a priori* des paramètres d'entrée non mesurés X^{nobs}

$$f_{X^{nobs}, \sigma}(x, \sigma) = \frac{1}{c} p_X(x) p_\sigma(\sigma) L(\sigma_e, Y^{obs});$$

- Cette méthode prend directement en compte les erreurs d'inspections/de modèle.

Actualisation basée sur la mesure des entrées et de la sortie modèle

Écriture de la fonction de vraisemblance

- L'erreur de mesure/modèle est supposée suivre une loi normale $N(0, \sigma_e)$;
- Les entrées se décomposent en :
 - Les entrées mesurées, qui s'écrivent

$$X^{obs} \sim \{N(x^{obs}(z_p, t_q), \sigma^{obs}), p = (1, \dots, P); (q = 1 \dots, Q)\},$$

en supposant que l'erreur de mesure suit une loi normale non biaisée.

- La vraisemblance s'écrit donc

$$L(\sigma_e, Y^{obs}) = \prod_{p=1}^P \prod_{q=1}^Q \varphi \left(\frac{M[x^{obs}(z_p, t_q), x^{nobs}, t_q] - y(z_p, t_q)}{\sigma_e} \right);$$



Actualisation basée sur la mesure des entrées et de la sortie modèle

Écriture de la densité à posteriori

- La vraisemblance s'écrit

$$L(\sigma_e, Y^{obs}) = \prod_{p=1}^P \prod_{q=1}^Q \varphi \left(\frac{M[x^{obs}(z_p, t_q), x^{nobs}, t_q] - y(z_p, t_q)}{\sigma_e} \right);$$

- La densité *a posteriori* ne dépend que des lois *a priori* des paramètres d'entrée non mesurés X^{nobs}

$$f_{X^{nobs}, \sigma}(x, \sigma) = \frac{1}{c} p_{X^{nobs}}(x^{nobs}) p_{\sigma}(\sigma) L(\sigma_e, Y^{obs});$$

- Les lois *a priori* des paramètres d'entrée mesurés sont actualisées dans un deuxième temps.

Evaluation de la qualité de prédiction

Estimateur du biais des prédictions

$$\epsilon_{\mu} = \frac{|\mu_{data} - \mu_{prév}|}{\mu_{data}}$$

- Un biais minimum est souhaitable.

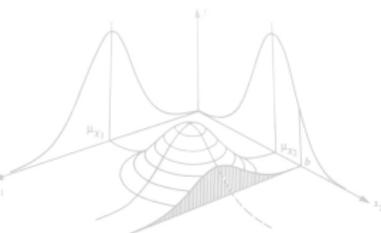
Estimateur de l'erreur de variabilité

$$\epsilon_{var} = \frac{|\Delta L_{data} - \Delta IC_{95_{prév}}|}{\Delta L_{data}}$$

- ΔL_{data} est la distance constatée entre les mesures maximum et minimum à une date donnée ;
- $\Delta IC_{95_{prév}}$ est la largeur de l'intervalle de confiance à 95% des prévisions à cette date ;
- Une valeur inférieure à 5% est un résultat parfait si la moyenne n'est pas biaisée.

Plan

- 1 Introduction du contexte
- 2 Principe de l'actualisation Bayésienne
- 3 Cas d'étude**
 - Le modèle Duracrete et un modèle personnalisé
 - Les données virtuelles
 - Les schémas d'actualisation
 - Résultats



Le modèle DuraCrete [DuraCrete, 2000]

Définition

$$x_c(t) = \sqrt{\frac{2k_e k_c k_t C_{CO_2} t}{R_{carb}}} \left(\frac{t_0}{t}\right)^n$$

- $x_c(t)$ est l'épaisseur carbonatée au temps t (ans) ;
- k_e, k_c, k_t sont des facteurs tenant compte des conditions d'exposition, du type de ciment, des conditions de cure et de passage de résultats en conditions accélérées aux conditions ambiante ;
- C_{CO_2} est la concentration en CO_2 à la surface du béton ;
- t_0 est un temps de référence ;
- n est un facteur de vieillissement.



Le modèle DuraCrete

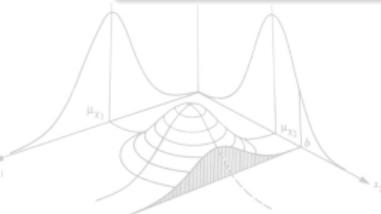
Définition de R_{carb}

- R_{carb} est la quantité de matériau carbonatable

$$R_{carb} = 1000 * \frac{C_1 M_{CaO} V_p}{D_{CO_2}};$$

- Le coefficient de diffusion du CO_2 dans le béton D_{CO_2} est calculé suivant la relation empirique suivante, dépendant du taux de saturation Sr et de la porosité ϕ

$$D_{CO_2} = D_{CO_2,air} \phi^{4/3} (1 - Sr)^{10/3}.$$

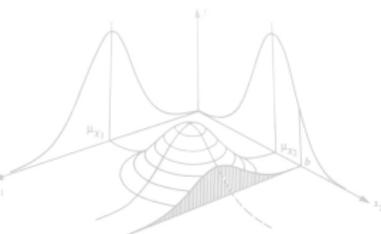


Un modèle personnalisé

Définition

$$\begin{cases} x_c(t) = A * (t - t_0)^n, & \forall t > t_0 \\ x_c(t) = 0, & \forall t < t_0 \end{cases}$$

- Modèle très simple disposant d'un temps d'initiation et de deux paramètres de cinétique.



Les données virtuelles

Description

- 150 mesures indépendantes de carbonatation disponibles chaque année pendant 60 ans, issues du modèle EF SCARABET [de Larrard et al.,] ;
- Il fournit également des mesures du taux de saturation et de la porosité, non utilisées ;
- Le béton simulé est un C25 aux caractéristiques connues.

Justification

- Dans le futur, le nombre de mesures CND réalisables à moindre coût est amené à devenir important ;
- L'utilisation des entrées des modèles de dégradation s'est révélée ineffective.



Les schémas d'actualisation

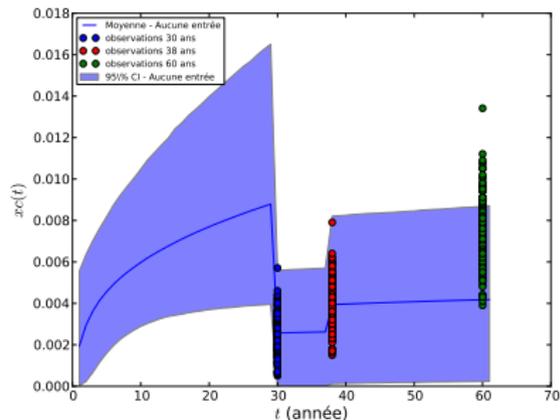
Deux schémas d'actualisation

- Objectif : la prévision à long terme ;
- Premier schéma : actualisations séquentielles sans historique des observations ;
- Deuxième schéma : actualisations séquentielles avec historique des observations ;
- Actualisations réalisées à l'aide d'un algorithme MCMC - Metropolis Hastings [Andrieu et al., 2003, Metropolis and Ulam, 1949, Robert and Casella, 2004].

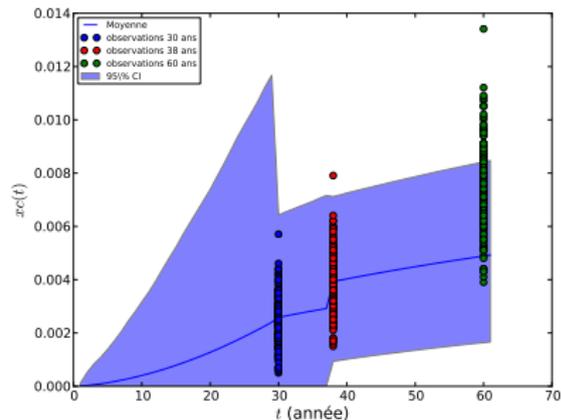
Cas n°	1ère inspection	2ème inspection	3ème inspection	Prévision à
1	$t^0 + 30$ ans	$t^0 + 38$ ans		$t^0 + 60$ ans
2	$t^0 + 15$ ans (N.A)	$t^0 + 30$ ans	$t^0 + 38$ ans	$t^0 + 60$ ans

Premier schéma d'actualisation

Modèle DuraCrete



Modèle Personnalisé



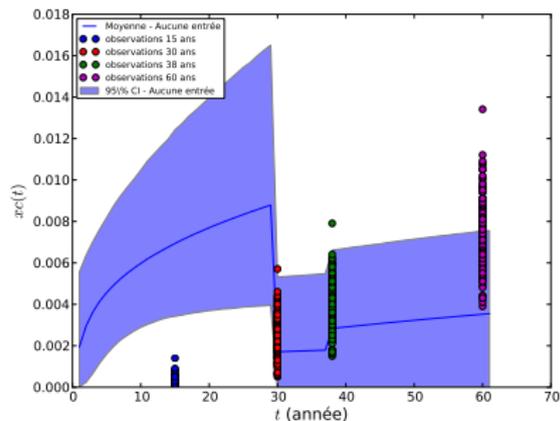
Modèle	ϵ_{μ}	ϵ_{var}
Duracrete	44%	40%
Personnalisé	34%	16%

Conclusions

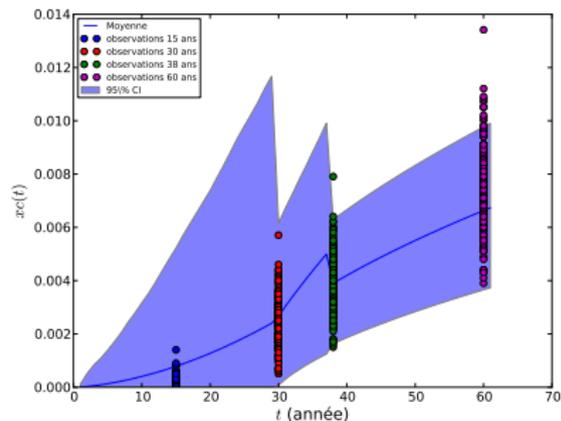
- Seul le modèle personnalisé arrive à approcher la cinétique du modèle EF ;
- Cependant les résultats restent insuffisants.

Deuxième schéma d'actualisation

Modèle DuraCrete



Modèle Personnalisé



Modèle	ϵ_μ	ϵ_{var}
Duracrete	52%	11%
Personnalisé	10%	22%

Conclusions

- Le modèle Duracrete donne encore des résultats insuffisants ;
- Le modèle personnalisé est beaucoup plus satisfaisant.

Conclusions et perspectives

Conclusions

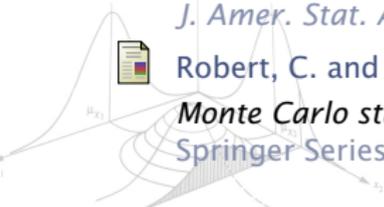
- La méthodologie d'actualisation Bayésienne est performante pour améliorer les prévisions si :
 - ① Le modèle actualisé est en adéquation avec la cinétique observée ;
 - ② La cinétique des observations est prise en compte dans le processus.
- En conséquence, la hiérarchisation des mesures effectuées se révèle importante dans ce cadre là.

Perspectives

- Mise en pratique sur des données réelles (pour l'instant insuffisantes pour justifier d'une qualité de prédiction) ;
- Prise en compte de la variabilité spatiale.



References

- 
-  Andrieu, C., De Freitas, N., Doucet, A., and Jordan, M. (2003).
An introduction to MCMC for machine learning.
Machine learning, 50(1-2) :5-43.
 -  de Larrard, T., Bastidas-Arteaga, E., Duprat, F., and Schoefs, F.
Effects of climate variations and global warming on the durability of rc structures subjected to carbonation.
Civil Engineering and Environmental Systems, in press.
 -  DuraCrete (2000).
Final technical report : General guidelines for durability design and redesign.
Technical report, The European Union - Brite EuRam III - Contract BRPR-CT95-0132 - Project BE95-1347/R17.
 -  Metropolis, N. and Ulam, S. (1949).
The Monte Carlo method.
J. Amer. Stat. Assoc., 44(247) :335-341.
 -  Robert, C. and Casella, G. (2004).
Monte Carlo statistical methods (2nd Ed.).
Springer Series in Statistics. Springer Verlag.