

QUALITA 2011 - ANGERS



Crédits photographiques © Ville d'Angers - th. Bonnet



## Estimation d'un modèle générique pour un parc de machines

**Farah Ankoud, Gilles Mourot, Roger Chevalier,  
Nicolas Paul, José Ragot**

Institut National Polytechnique de Lorraine

Centre de Recherche en Automatique de Nancy

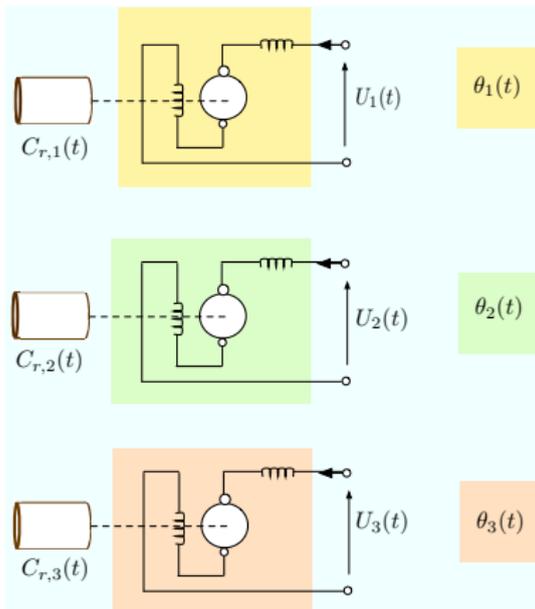
Electricité de France

Nancy-Université  
SINPL



## Définition et objectifs

- ▶ Parc de machines : collection de machines a priori identiques
- ▶ Estimer un a modèle générique d'un parc de machines identiques
- ▶ Déduire une stratégie générique pour le diagnostic d'un parc de machines



## Motivations

- ▶ Réduction du coût d'estimation des machines du parc
- ▶ Facilité de construire le modèle d'une nouvelle machine
- ▶ Facilité de remplacement d'une machine par une autre
- ▶ Réduction du coût de maintenance du parc

## 1 Introduction

## 2 Méthode

- Identification des modèles de chaque machine
- Identification des coefficients identiques des machines
- Estimation les paramètres en considérant les parties communes
- Validation du choix des coefficients identiques

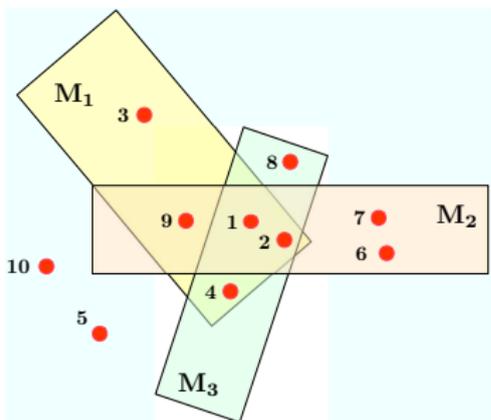
## 3 Simulation

## 4 Conclusions et perspectives

# Introduction

# Introduction : modèle générique

- ▶ Le problème consiste à établir un modèle générique traduisant le comportement de toutes les machines du parc.
- ▶ Un modèle générique comporte deux parties :
  - ▶ une partie commune aux variables des machines du parc
  - ▶ une partie distincte relative aux variables environnementales de chaque machine.
- ▶ Le problème consiste en :
  - classification des variables : extraction des variables communes
  - identification des modèles partageant des parties communes
- ▶ Exemple : 3 machines  $M_1$ ,  $M_2$  et  $M_3$  avec 10 variables



	1	2	3	4	5	6	7	8	9	10
$M_1$	×	×	×	×	.	.	.	.	×	.
$M_2$	×	×	.	.	.	×	×	.	×	.
$M_3$	×	×	.	×	.	.	.	×	.	.

Variables 1 and 2

Variables 4 and 9

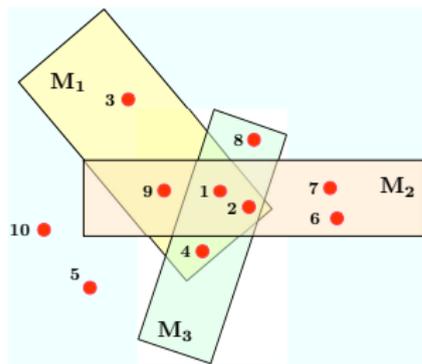
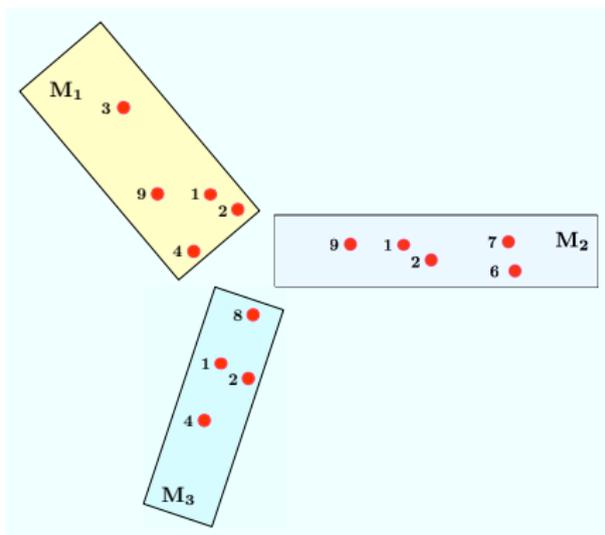
Variables 3, 5, 6, 7, 8

- ▶ Multitask learning  
<http://books.nips.cc/papers/files/nips19/NIPS2006-0251.pdf>
- ▶ Fleet Maintenance Systems  
<http://www.serco-na.com/Download.aspx?ID=288&Type=Story>
- ▶ Fleet Inventory Tracking  
<http://www.mex.com.au/Products/FleetMEX.aspx>
- ▶ Patents on fleet of machines  
<http://www.freepatentsonline.com/5737215.html>

**Identification des modèles avec leur  
partie commune**

# Identification des modèles et de leurs parties communes

- 1 Identifier séparément le modèle de chaque machine
- 2 Identifier les variables communes dans les modèles des différentes machines
- 3 identifier les paramètres potentiellement identiques  $\rightarrow$  partie commune
- 4 estimer les paramètres des modèles compte tenu de leurs parties communes
- 5 valider le choix de la partie commune



# Identifier les modèles de chaque machine

► Considérons la kème machine, avec :

- $y^{*k}$  variable à expliquer
- $W^k$  variables pouvant expliquer  $y^{*k}$
- $X^k$  variables sélectionnées pour expliquer  $y^{*k}$
- $\hat{\theta}^k$  paramètres du modèle

► Modèle

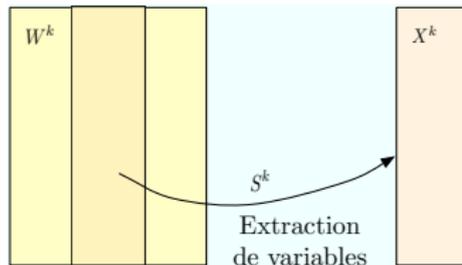
$$\hat{y}^k = X^k \hat{\theta}^k$$

$$X^k = W^k S^k$$

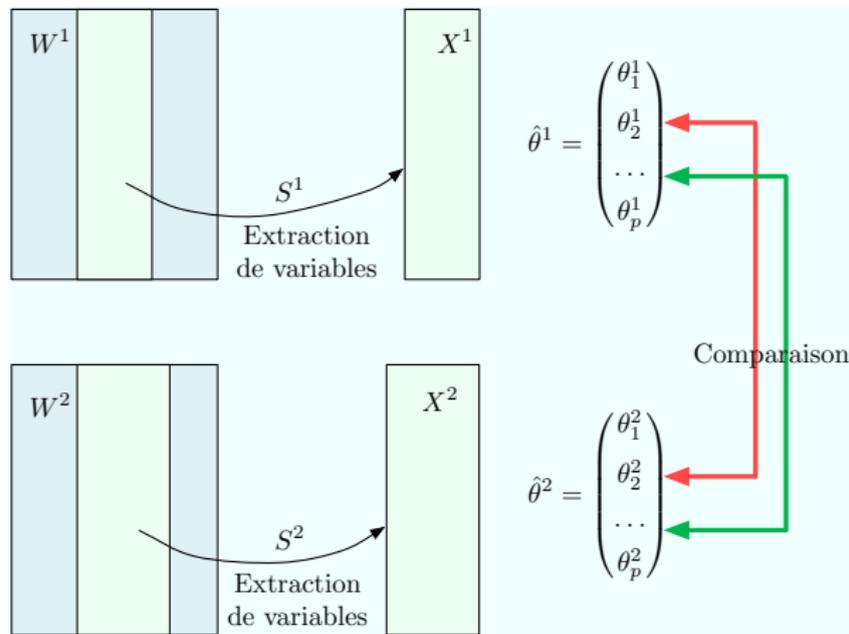
$$\hat{\theta}^k = (X^{kT} X^k)^{-1} X^{kT} y^k$$

►  $S^k$  est une matrice de sélection. Par exemple, la matrice ci-dessous permet de sélectionner les variables 2 et 4 dans un ensemble de 5 variables :

$$S^k = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix}^T$$



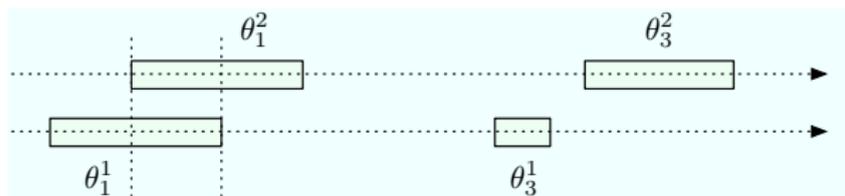
# Identifier les modèles de plusieurs machines



- ▶ Identifier séparément les paramètres des modèles
- ▶ Analyser les proximités des coefficients des variables  $\hat{\theta}^1$  et  $\hat{\theta}^2$
- ▶ Décider quels coefficients doivent être forcés à être identiques

# Identification des coefficients identiques des machines

► Principe :



► Intervalles de confiance des paramètres

L'écart-type  $\hat{\sigma}_i^k$  est évalué de la façon suivante :

$$\tilde{y}^k = y^k - \hat{y}^k, \quad \hat{\sigma}^2 = \frac{1}{n_k - p_k} \|\tilde{y}^k\|^2 \quad \rightarrow \quad \boxed{\hat{\Sigma}_\theta^k = \hat{\sigma}^2 (X^{kT} X^k)^{-1}}$$

$\hat{\sigma}_i^k$  est le  $i^{th}$  terme de la diagonale de  $\hat{\Sigma}_\theta^k$ .

$$I_i^k = [\hat{\theta}_i^k - 2.32\hat{\sigma}_i^k ; \hat{\theta}_i^k + 2.32\hat{\sigma}_i^k]$$

► Les coefficients  $\hat{\theta}_i^k$  ( $\forall k$ ) sont considérés identiques si il existe intersection non vide entre leurs intervalles de confiance  $I_i^k$  :

$$I_i^{k1} \cap I_i^{k2} \neq \emptyset \rightarrow \hat{\theta}_i^{k1} \text{ and } \hat{\theta}_i^{k2} \text{ are identical}$$

# Estimer les paramètres compte tenu des parties communes

- Modèle de la machine  $k$

$$y^k = X^k \theta^k$$

La partie commune des coefficients est constituée des  $p$  coefficients  $\alpha$  :

$$\theta^k = \begin{pmatrix} \alpha \\ \beta^k \end{pmatrix}, \quad X^k = \begin{pmatrix} U^k \\ V^k \end{pmatrix}$$

Les deux matrices  $U^k$  et  $V^k$  sont sélectionnées avec  $S_p^k$  et  $S_p^k$ , from  $X^k$  :

$$U^k = X^k S_p^k \quad \text{and} \quad V^k = X^k S_p^k$$

- Modèle du parc de machines

$$\underbrace{\begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^K \end{bmatrix}}_Y = \underbrace{\begin{bmatrix} U^1 & V^1 & 0 & \dots & 0 \\ U^2 & 0 & V^2 & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & 0 \\ U^K & 0 & \dots & 0 & V^K \end{bmatrix}}_Z \underbrace{\begin{bmatrix} \alpha \\ \beta^1 \\ \beta^2 \\ \vdots \\ \beta^K \end{bmatrix}}_\theta$$

- Estimer les nouveaux coefficients

$$\hat{\theta} = (Z^T Z)^{-1} Z^T Y \implies \hat{\alpha}, \hat{\beta}^1, \dots, \hat{\beta}^K$$

# Validation du choix des coefficients identiques

▷ Première estimation  $\hat{y}^k$  de  $y^k$  sans effet de couplage

$$\tilde{y}^k = y^k - \hat{y}^k, \quad \hat{y}^k = X^k \hat{\theta}^k,$$

$$\Phi_1 = \sum_{k=1}^K \|\tilde{y}^k\|^2$$

▷ Seconde estimation  $\hat{\hat{y}}^k$  de  $y^k$  avec effet de couplage

$$\tilde{\tilde{y}}^k = y^k - \hat{\hat{y}}^k, \quad \hat{\hat{y}}^k = \begin{bmatrix} U^k & V^k \end{bmatrix} \begin{bmatrix} \hat{\alpha} \\ \hat{\beta}^k \end{bmatrix},$$

$$\Phi_2 = \sum_{k=1}^K \|\tilde{\tilde{y}}^k\|^2$$

▷ Comparaison des sommes des carrés des erreurs

$$\tau = \frac{N - P}{(K - 1)p} \cdot \frac{\Phi_2 - \Phi_1}{\Phi_1}$$

$$\begin{cases} N = \sum_{k=1}^K n_k, & \text{Nombre de données} \\ P = \sum_{k=1}^K p_k, & \text{Nombre de paramètres} \end{cases}$$

*Si  $\tau \leq \mathcal{F}_\alpha((K-1)p, N-P) \rightarrow$  pas de perte significative d'information*

# Remarque : une formulation directe ?

## Formulation initiale

- ▶ Construction des modèles individuellement

$$\Phi_i = \| y_i - X_i \theta_i \|^2, \quad i = 1, \dots, K$$

- ▶ Détermination de la partie commune des différents modèles
- ▶ Analyse de la structure des modèles
- ▶ Construction d'un modèle global prenant en compte l'identité de certains coefficients

## Une formulation en une étape

- ▶ Objectif global

$$\begin{aligned} \Phi = & \sum_{i=1}^K \frac{1}{2} \| y_i - X_i \theta_i \|^2 \\ & + \sum_{i=1}^{K-1} \sum_{j=i+1}^K \frac{1}{2} \gamma_{i,j} (\theta_i - \theta_j)^T W_{i,j}^2 (\theta_i - \theta_j) \end{aligned}$$

- ▶ Estimation simultanée

$$\theta_i, W_{i,j}$$

- ▶ des valeurs des poids mettant directement en évidence les liens entre paramètres

## **Exemple (simulation)**

# Exemple

Trois modèles, trois bases de données de 250 observations chaque :

$$y^1 = x_1^1 + 5x_3^1 + 5.5x_5^1 - 10 + \varepsilon^1$$

$$y^2 = x_2^2 + 5x_3^2 + 0.6x_4^2 + 5.68x_5^2 - 12 + \varepsilon^2$$

$$y^3 = 0.5x_1^3 + 1.2x_2^3 + 5.1x_3^3 + 0.7x_4^3 + 5.3x_5^3 - 14 + \varepsilon^3$$

où  $\varepsilon^k$  est un signal de valeur moyenne nulle

## Etape 1 : Identification séparée des modèles

Les estimés de  $y^k$  évalués sans l'effet de couplage :

$$\hat{y}^1 = 0.89x_1^1 + 5.09x_3^1 + 5.66x_5^1 - 10.29$$

$$\hat{y}^2 = 1.15x_2^2 + 4.89x_3^2 + 0.54x_4^2 + 5.40x_5^2 - 11.52$$

$$\hat{y}^3 = 0.58x_1^3 + 1.18x_2^3 + 4.98x_3^3 + 0.66x_4^3 + 5.31x_5^3 - 13.84$$

# Exemple

## Etape 2 : Recherche des coefficients identiques

Coef.	Interval
$\hat{\theta}_0^1$	[-11.13 ; -9.46]
$\hat{\theta}_1^1$	[0.62 ; 1.15]
$\hat{\theta}_3^1$	[4.86 ; 5.34]
$\hat{\theta}_5^1$	[5.41 ; 5.91]

Coef.	Interval
$\hat{\theta}_0^2$	[-12.38 ; -10.66]
$\hat{\theta}_2^2$	[0.89 ; 1.39]
$\hat{\theta}_3^2$	[4.66 ; 5.12]
$\hat{\theta}_4^2$	[0.31 ; 0.78]
$\hat{\theta}_5^2$	[5.19 ; 5.61]

Coef.	Interval
$\hat{\theta}_0^3$	[-14.87 ; -12.81]
$\hat{\theta}_1^3$	[0.34 ; 0.81]
$\hat{\theta}_2^3$	[0.87 ; 1.49]
$\hat{\theta}_3^3$	[4.73 ; 5.22]
$\hat{\theta}_4^3$	[0.39 ; 0.93]
$\hat{\theta}_5^3$	[5.09 ; 5.53]

Les coefficients des variables  $x_3$  et  $x_5$  sont unique pour toutes les base de données : une intersection non nulle de [4.86 ; 5.12] et [5.41 ; 5.53] existe entre leurs intervalles de confiance.

## Etape 3 : Validation du choix des coefficients identiques

Expressions des nouveaux estimés de  $y^k$  :

$$\tilde{y}^1 = 0.94x_1^1 + 4.98x_3^1 + 5.44x_5^1 - 9.72$$

$$\tilde{y}^2 = 1.13x_2^2 + 4.98x_3^2 + 0.54x_4^2 + 5.44x_5^2 - 11.75$$

$$\tilde{y}^3 = 0.58x_1^3 + 1.16x_2^3 + 4.98x_3^3 + 0.66x_4^3 + 5.44x_5^3 - 14.09$$

Avant couplage :  $\Phi_1 = 127.95$ , après couplage :  $\Phi_2 = 129.31$

$$\tau = \frac{N - P}{(K - 1)p} \cdot \frac{\Phi_2 - \Phi_1}{\Phi_1} = 1.95$$

avec :  $N = 750$ ,  $P = 15$ ,  $K = 3$ ,  $p = 2$  et pour un niveau de confiance de 99%

$$F_a = 3.34$$

Donc  $\tau \leq F_a$  et ainsi l'effet de couplage peut être pris en compte sans perte significative d'information.

# Exemple

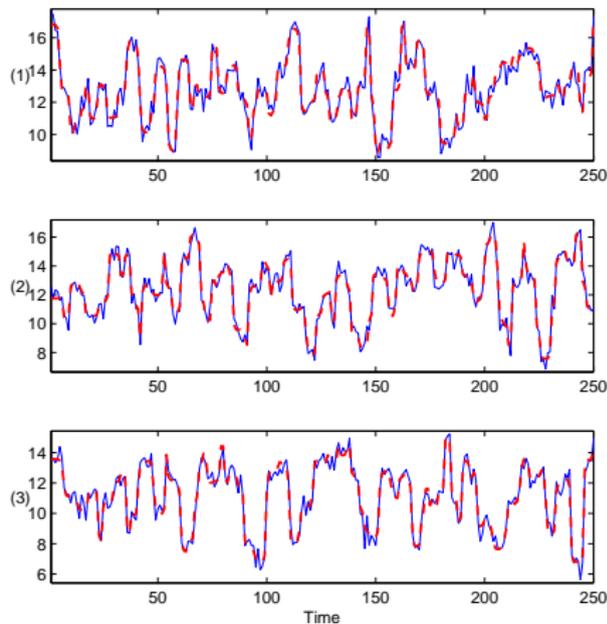


FIGURE:  $y^k$  (bleu plein) and  $\hat{y}^k$  (pointillé rouge) dans chaque base de données

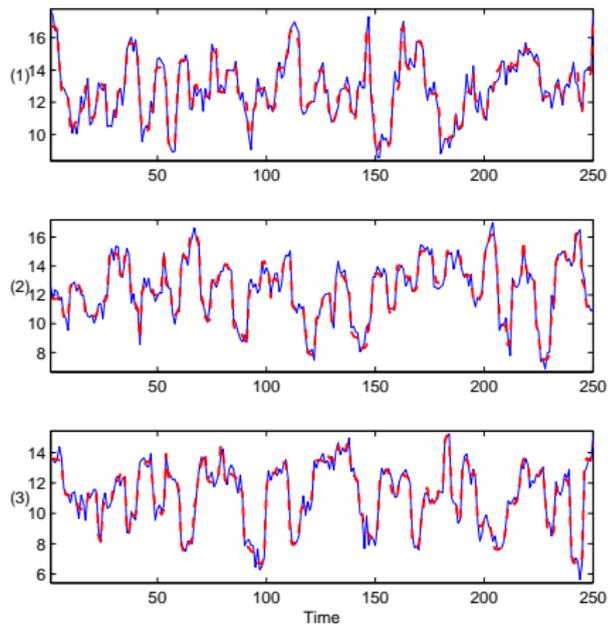


FIGURE:  $y^k$  (bleu plein) and  $\tilde{y}^k$  (pointillé rouge) dans chaque base de données

Interpretation :

## **Conclusions et perspectives**

# Conclusions et perspectives

## Conclusions

- ▶ Méthode pour identifier la partie commune dans le comportement des machines d'un parc, en utilisant des données collectées sur ce parc.
- ▶ Modèle générique caractérisant le fonctionnement normal des machines établi à partir de leurs caractéristiques communes.

## Perspectives

- ▶ La méthode peut être complétée pour identifier la partie des modèles à associer à l'environnement des machines.
- ▶ Quand une nouvelle machine est acquise, comment reconnaître si elle peut être associée au parc existant ?
- ▶ Quand une nouvelle machine est ajoutée au parc, comment établir son modèle compte tenu du modèle générique du parc ?
- ▶ Test de la méthodologie sur un parc de pompes de tranches de centrales nucléaire (EDF).

**Merci pour votre attention**

