

# Prévision de la consommation d'électricité par correction itérative du biais

Journées MAS 01/09/2010

V. Lefieux, L. Maillard-Teyssier  
RTE / DMA

En collaboration avec  
P. A. Cornillon, N. Hengartner, E. Matzner-Løber

# Plan

- 1 Problématique
- 2 Présentation de la méthode IBR
- 3 Application de la méthode à la consommation d'électricité
- 4 Quid de la sélection de variables

# Contexte

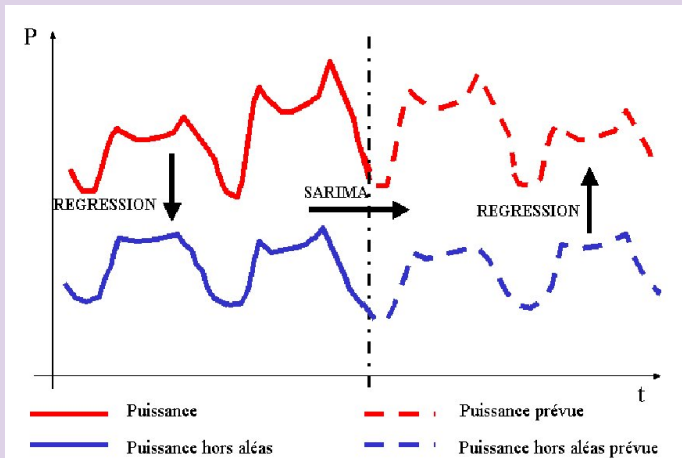
## Les enjeux

- L'électricité ne se stocke pas à l'échelle industrielle
- A tout instant, la production d'électricité doit être égale à celle qui est consommée (fréquence de 50 Hz)

## La solution adoptée

- Prévission de la "courbe de charge" nationale (ou régionale) : caractère autorégressif et variables exogènes (ex : météo, tarifs et prix)
- Juxtaposition de deux modèles paramétriques (régression et SARIMA)
- Problèmes : spécification du modèle, intervalles de confiance...

## Principe de la prévision a court terme



# Etat de l'art

- Modélisation paramétrique : rigide et pas adaptée à la structure de certaines séries temporelles
- Modélisation non-paramétrique : fléau de la dimension
- D'autres points de vue : méthode de réduction de la dimension (semi-paramétrique), correction itérative du biais

# Lutter contre le "fléau de la dimension"

## Approximation fonctionnelle

- Les *modèles additifs généralisés*, étudiés entre autres par Auestad *et al.* (1990), Härdle *et al.* (1996).

En notant  $Y \in \mathbb{R}$  la variable à expliquer et

$X = (X^1, \dots, X^p)^T \in \mathbb{R}^p$  les  $p$  variables explicatives, on suppose que :

$$\mathbb{E}(Y/X) = \sum_{j=1}^p g_j(X^j)$$

où  $g_j : \mathbb{R} \rightarrow \mathbb{R}$  sont  $p$  fonctions mesurables inconnues.

- Les *modèles autorégressifs à coefficients fonctionnels*, étudiés par Chen *et al.* (1993).

On suppose que :

$$X_t = f_1(X_{t-1}^*) X_{t-1} + \dots + f_r(X_{t-1}^*) X_{t-r} + \varepsilon_t$$

où  $f_j : \mathbb{R} \rightarrow \mathbb{R}$  sont  $r$  fonctions mesurables inconnues et

$X_{t-1}^* = (X_{t-i_1}, \dots, X_{t-i_k})^T$  (avec  $i_j \in \mathbb{N}^*$  pour  $j \in \{1, \dots, k\}$ ).

# Lutter contre le "fléau de la dimension"

## Réduction de la dimension 1/2

- Les modèles de "*Projection Pursuit Regression*" (PPR), étudiés entre autres par Huber (1985), Hall (1989), Chen (1991), Xia *et al.* (1997).

On suppose que :

$$\mathbb{E}(Y/X) = \sum_{j=1}^D g_j(\beta_j^T X)$$

où  $g_j : \mathbb{R} \rightarrow \mathbb{R}$  sont  $D$  fonctions mesurables inconnues et  $\beta_j \in \mathbb{R}^p$  sont  $D$  paramètres (vectoriels) inconnus.

- Les modèles à *direction révélatrice unique* (SIM : Single Index Model), étudiés entre autres par Härdle *et al.* (1993), Ichimura (1993), Carroll *et al.* (1997), Delecroix *et al.* (1999), Xia *et al.* (1999), Delecroix *et al.* (2006).

On suppose que :

$$\mathbb{E}(Y/X) = g(\beta^T X)$$

où  $g : \mathbb{R} \rightarrow \mathbb{R}$  est une fonction mesurable inconnue et  $\beta \in \mathbb{R}^p$  est un paramètre (vectoriel) inconnu.

# Lutter contre le "fléau de la dimension"

## Réduction de la dimension 2/2

- Les *modèles à directions révélatrices multiples*, étudiés entre autres par Li *et al.* (2001), Xia *et al.* (2002), Li *et al.* (2004).

On suppose que :

$$\mathbb{E}(Y/X) = g(B^T X)$$

où  $g : \mathbb{R}^D \rightarrow \mathbb{R}$  est une fonction mesurable inconnue et  $B = (\beta^1, \dots, \beta^D)_{p \times D}$  est un paramètre (matriciel) inconnu.



# Modèle

On se place dans un contexte de régression.

Supposons que les données  $(X_i, Y_i) \in \mathbb{R}^d \times \mathbb{R}$  sont liées via le modèle de régression

$$Y_i = m(X_i) + \varepsilon_i, \quad i = 1, \dots, n,$$

$m(\cdot)$  est la fonction inconnue.

Les erreurs sont indépendantes, de moyenne nulle et de variance  $\sigma^2$ .

Ce modèle peut s'écrire sous forme matricielle

$$Y = m + \varepsilon.$$

# Lisseurs

Un lisseur linéaire s'écrit simplement sous la forme

$$\hat{m} = SY.$$

$S$  est matrice de lissage de taille  $n \times n$ .

$\hat{m} = \hat{Y} = (\hat{Y}_1, \dots, \hat{Y}_n)^t$ , sont les valeurs ajustées.

Le lisseur est paramétré par un paramètre de lissage  $\lambda$  (la fenêtre pour un lisseur à noyau, la pénalité pour les splines de lissage...).

Nous écrirons le lisseur de façon à qu'une valeur élevée de  $\lambda$  corresponde à un estimateur très lisse.

Il faut sélectionner le paramètre  $\lambda$ .

# Lisseurs classiques

- Moyenne mobile :  $S_{ij} = 1/\text{nbr de } X \text{ dans le voisinage}$
- Lisseur par cellule :  $S_{ij} = 1/\text{nbr de } X \text{ dans la cellule}$
- Lisseur à noyau :  $S_{ij} = K_h(X_i - X_j) / \sum_l K_h(X_i - X_l)$
- $K$ -pp voisins :  $S_{ij} = 1/K$  si  $X_j \in K - pp(X_i)$
- Spline de régression :  $S = B(B'B)^{-1} B'$
- Spline de lissage :  $S = N(N'N + \lambda\Omega_N)^{-1} N'$

# Méthode IBR 1/2

Nous partons d'un estimateur lisse ( $\lambda$  grand), et calculons les résidus à cette première étape et nous corrigeons l'estimateur initial ou pilote en enlevant les résidus lissés (par simplicité nous conservons le même lisseur à chaque étape) :

$$\begin{aligned} R_1 &= Y - \hat{m}_1 = (I - S_1)Y \\ \hat{m}_2 &= \hat{m}_1 + S_1 R_1 \\ &= (S_1 + S_1(I - S_1))Y. \end{aligned}$$

Nous itérons cette procédure et obtenons à l'étape  $k$  :

$$\begin{aligned} \hat{m}_k &= S_1 Y + S_1(I - S_1)Y + \dots + S_1(I - S_1)^{k-1} Y \\ &= (I - (I - S_1)^k)Y \end{aligned}$$

On peut montrer que le comportement de l'estimateur dépend des valeurs singulières de  $I - S_1$ .

# Méthode IBR 2/2

L'estimateur peut également s'écrire sous la forme

$$\hat{m}_k = S_1[Y + (I - S_1)Y + \dots + (I - S_1)^{k-1} Y].$$

Le problème maintenant consiste à choisir  $k$ .

# Critères d'arrêt classiques

$$\hat{k}_{AIC} = \arg \min_{k \in \mathcal{K}} \left\{ \hat{\sigma}^2 + 2 \frac{\text{trace}(S_k)}{n} \right\},$$

$$\hat{k}_{AIC_C} = \arg \min_{k \in \mathcal{K}} \left\{ \log \hat{\sigma}^2 + 1 + \frac{2(\text{trace}(S_k) + 1)}{n - \text{trace}(S_k) - 2} \right\},$$

$$\hat{k}_{GCV} = \arg \min_{k \in \mathcal{K}} \left\{ \log \hat{\sigma}^2 - 2 \log \left( 1 - \frac{\text{trace}(S_k)}{n} \right) \right\}.$$

# Propriétés théoriques

Le lisseur obtenu avec des splines plaques minces et avec GCV admet des propriétés d'adaptativité.

*Cornillon P. A., Hengartner N., Matzner-Løber E. (2009)  
Recursive Bias Estimation for high dimensional regression  
smoothers, soumis.*

Le problème des splines plaques minces est que le nombre minimum de valeurs propres égales à 1 est fonction de la dimension  $d$ .

# Formalisation du problème

Dans notre problème, nous souhaitons prévoir en premier lieu la série des consommations corrigées des aléas climatiques et tarifaires pour laquelle on dispose de  $n$  observations  $\{X_t\}_{t=1}^n$  :

$$X_{t+l} = f_l(X_t, \dots, X_{t-47}) + \varepsilon_t$$

où  $f_l : \mathbb{R}^{48} \mapsto \mathbb{R}$  est une fonction inconnue dépendant de l'horizon  $l$  (72 au maximum).

Pour estimer cette fonction, nous utilisons la méthode des noyaux.



# Formalisation du problème

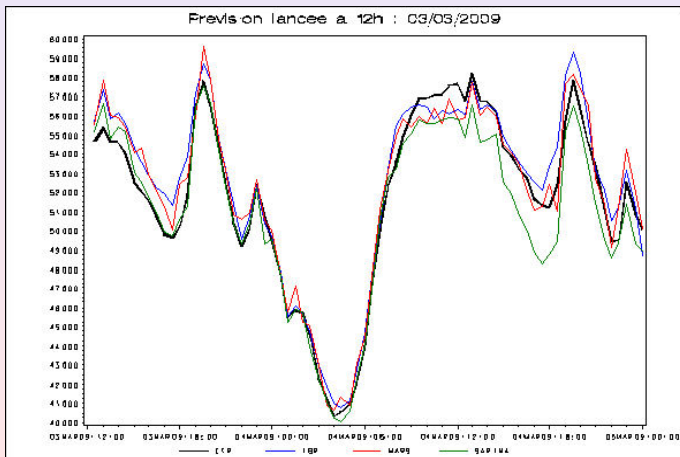
Nous utilisons le noyau produit gaussien :

$$K_h(x - X_i) = \prod_{j=1}^{48} \frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{(x_j - X_{ij})^2}{h_j} \right\}$$

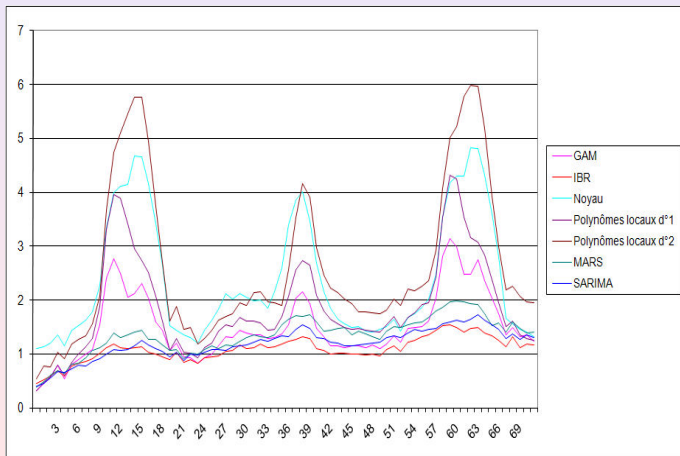
où  $X_i$  représente la  $i$ -ème ligne de la matrice  $X$  et  $h_j \in \mathbb{R}^+$  est la largeur de fenêtre pour la variable  $X_j$ .

Pour choisir cette valeur, nous fixons pour chaque lisseur univarié un ddl (le même en général pour chaque variable).

# Exemple : prévisions SARIMA, MARS et IBR lancées le 03/03/2009 à 12h



# Quelques résultats : MAPE des prévisions lancées du 10 janvier 2009 au 20/12/2009 à 12h



# Variables explicatives

- Données calendaires : type de jour, jours fériés et particuliers, vacances
- Données météorologiques : température, nébulosité, vent
- Pas de temps : 10 min, 30 min, 1h
- Maille géographique : stations, points de grille

# Sélection des variables explicatives

- Dans IBR : procédure Forward avec un critère de type AIC.
- Autre piste en cours d'exploration : utilisation de dictionnaires (bases de Fourier, de Haar, ondelettes...) et de procédures efficaces en grande dimension (Dantzig, LOL, Lasso...)