



ELSEVIER

Available online at [www.sciencedirect.com](http://www.sciencedirect.com)

SCIENCE @ DIRECT®

C. R. Acad. Sci. Paris, Ser. I 336 (2003) 601–604



Statistique/Probabilités

# Une méthode semi-paramétrique pour tester un modèle de régression

## A semi-parametric method to test a regression model

Michel Harel<sup>a,b</sup>

<sup>a</sup> IUFM du Limousin (et UMRC 55830, CNRS, Toulouse), 209, bd de Vanteaux, 87036 Limoges cedex, France

<sup>b</sup> Centro de Modelamiento UMR CNRS 2071, Universidad de Chile, Santiago, Chile

Reçu le 24 octobre 2002 ; accepté après révision le 23 janvier 2003

Présenté par Paul Deheuvels

---

### Résumé

Le but est de tester l'hypothèse  $H_0$  qu'un modèle de régression est paramétrique et appartient à une famille donnée contre l'alternative  $H_1$  approchant l'hypothèse dans une direction spécifique au taux  $n^{-1/2}$ . Pour cela, nous considérons un processus empirique tel que sous l'hypothèse  $H_0$  ce processus dépend d'un paramètre  $\theta_0$ . D'abord, nous commençons par estimer le paramètre et nous montrons que le processus empirique converge en loi vers un certain processus Gaussien si le paramètre est remplacé par son estimateur  $\tilde{\theta}_n$ . Cependant il est important de vérifier l'impact d'une alternative qui approche  $H_0$  dans une direction spécifique (au taux  $n^{1/2}$ ). Pour cela, nous avons besoin de tests qui soient consistants sur toute l'alternative  $H_1$ . Notre idée est d'utiliser un processus empirique marqué basé sur les résidus qui converge en loi vers un processus Gaussien. **Pour citer cet article :** M. Harel, C. R. Acad. Sci. Paris, Ser. I 336 (2003).

© 2003 Académie des sciences/Éditions scientifiques et médicales Elsevier SAS. Tous droits réservés.

### Abstract

The purpose is to test the hypothesis  $H_0$  that a regression model is parametric and belongs to a given family versus the alternative  $H_1$  approaches the hypothesis from a specific direction at the rate  $n^{-1/2}$ . For that, we consider an empirical process such that under  $H_0$  this process depends of a parameter  $\theta_0$ . First, we start by estimating the parameter and we prove that the empirical process converges in distribution to a certain Gaussian process when the parameter is replaced by its estimator  $\tilde{\theta}_n$ . However it is important to check the impact of an alternative approaching  $H_0$  from a specific direction ( at the rate  $n^{1/2}$ ). For that, we need tests which are consistent on the whole of  $H_1$ . Our idea is to use a marked empirical process based on residuals which converges in distribution to a Gaussian process. **To cite this article:** M. Harel, C. R. Acad. Sci. Paris, Ser. I 336 (2003).

© 2003 Académie des sciences/Éditions scientifiques et médicales Elsevier SAS. All rights reserved.

---

### 1. Introduction

Soit  $\{\mathbf{Z}_i = (\mathbf{X}_i, Y_i); i \geq 1\}$  une suite de variables aléatoires de fonctions de répartition continues  $H(\mathbf{z})$ ,  $\mathbf{z} \in \mathbb{R}^{1+d}$ , et nous supposons que  $H(\mathbf{z})$  admet une densité strictement positive et  $H$  possède deux lois marginales  $F$  et  $G$  (respectivement de  $\mathbf{X}_i$  et  $Y_i$ ) où les densités respectives sont notées  $f$  et  $g$ .

---

Adresse e-mail : [harel@unilim.fr](mailto:harel@unilim.fr) (M. Harel).

Supposons que les variables aléatoires  $Y_i$  sont intégrables de sorte que la fonction de régression  $m(\mathbf{x}) = E(Y | \mathbf{X} = \mathbf{x})$  de  $Y$  sur  $\mathbf{X}$  est bien définie où  $\mathbf{x} \in \mathbb{R}^d$ ,  $(\mathbf{X}, Y)$  a la même distribution que  $(\mathbf{X}_i, Y_i)$  et est p.s. en  $\mathbf{x}$  uniquement définie du point de vue de l'équation

$$m(\mathbf{X}) = E(Y | \mathbf{X}). \quad (1)$$

Dans cette Note, nous supposons que la suite  $\{\mathbf{Z}_i\}$  est absolument régulière avec un taux géométrique (pour une définition voir Harel et Puri [3]).

Dans beaucoup de littérature, on considère des modèles paramétriques de telle sorte que  $m$  est supposé appartenir à une famille donnée

$$\mathcal{H} = \{m(\cdot, \theta), \theta \in \Theta\} \quad (2)$$

de fonctions, où  $\theta \in \mathbb{R}^p$  est un ensemble de paramètres.

Nous supposons que  $m(\mathbf{x}) = m(\mathbf{x}, \theta_0)$  pour la vraie valeur du paramètre  $\theta_0$ . Le problème est comment estimer  $\theta_0$  ou tester l'hypothèse que la valeur du paramètre est  $\theta_0$ . Un cas bien connu est le modèle linéaire pour lequel  $m(\mathbf{x}, \theta) = g'(\mathbf{x})\theta$ ,  $g$  est une fonction vectorielle connue. Beaucoup de travaux ont été réalisés sur la manière d'estimer  $m$  d'une façon complètement nonparamétrique voir Stute [5,6] si la suite  $\{\mathbf{Z}_i\}$  est i.i.d. ensuite Yoshihara [8] et Harel et Puri [3] si la suite  $\{\mathbf{Z}_i\}$  est absolument régulière.

Il est important de vérifier l'impact d'une alternative qui approche  $H_0$  dans une direction spécifique (au taux  $n^{1/2}$ ). Pour cela, nous avons besoin de tests qui soient consistants sur tout  $H_1$ . Notre idée est d'utiliser un processus empirique marqué basé sur les résidus convergeant en loi vers un processus Gaussien. Sous l'hypothèse  $H_0$ , nous supposons que la vraie valeur  $m$  est égale à  $m(\cdot, \theta_0)$  et soit  $\tilde{\theta}_n$  un estimateur de  $\theta_0$ , alors nous rejetons l'hypothèse si le processus empirique marqué (sur lequel  $\theta_0$  est remplacé par  $\tilde{\theta}_n$ ) excède une valeur critique.

Maintenant définissons

$$R_n^*(\mathbf{x}) = n^{-1/2} \sum_{i=1}^n I_{[\mathbf{x}_i \leq \mathbf{x}]} (Y_i - m(\mathbf{X}_i, \tilde{\theta}_n)), \quad \mathbf{x} \in \mathbb{R}^d, \quad (3)$$

le processus empirique marqué.

Le résultat principal montrera la convergence faible du processus  $R_n^*$  par rapport à la topologie de Skorohod sous des conditions raisonnables. De tels résultats ont été donnés par Stute [7] seulement quand la suite  $\{\mathbf{Z}_i\}$  est i.i.d., des applications sont données pour des modèles linéaires, son estimateur  $\tilde{\theta}_n$  de  $\theta_0$  est l'estimateur des moindres carrés et son espace alternatif est un sous espace de  $L^2$  (l'espace des fonctions de carré intégrable) puis par Diebold et Zuber [1]. Notre hypothèse d'absolue régularité géométrique nous donnera des applications pour des modèles plus généraux comme les modèles autorégressifs. Notre estimateur  $\tilde{\theta}_n$  de  $\theta_0$  sera le  $\alpha$ -quantile d'autorégression qui est beaucoup plus robuste si les bruits blancs ne sont pas nécessairement des lois normales. Le cas des modèles autorégressifs a été abordé par Koul et Stute [4] avec un estimateur classique de  $\theta_0$  et la consistance de l'alternative n'est pas abordée.

## 2. Conditions et convergence faible du processus empirique marqué

Sans perte de généralité, nous supposons maintenant que  $d = 1$ .

Nous supposons que la suite  $\{\mathbf{Z}_i = (X_i, Y_i), i \geq 1\}$  est absolument régulière avec le taux

$$\beta(m) = O(\rho^m), \quad 0 < \rho < 1. \quad (4)$$

Nous savons que le processus  $R_n^*$  défini dans (3) prend ses valeurs dans l'espace de Skorohod  $D(-\infty, +\infty)$ . Pour traiter de telles statistiques, nous étendons de façon continue  $R_n^*$  à  $-\infty$  et  $+\infty$  en posant  $R_n^*(-\infty) = 0$  et  $R_n^*(+\infty) = n^{-1/2} \sum_{i=1}^n (Y_i - m(\mathbf{X}_i, \tilde{\theta}_n))$ . Alors  $R_n^*$  devient un processus à valeurs dans  $D[-\infty, +\infty]$ .

Pour le comportement du processus  $R_n^*$ , certaines conditions de régularité sur l'estimateur  $\tilde{\theta}_n$  seront nécessaires. Ces conditions sont similaires aux conditions de Stute [7] et nous ne les appliquerons pas à l'estimateur des moindres carrés mais à notre  $\alpha$ -quantile d'autorégression et notre suite  $\{\mathbf{Z}_i\}$  n'est pas i.i.d. mais absolument régulière.

**Condition 1.** Sous  $H_0$ , c'est à dire  $m = m(\cdot, \theta_0)$  pour un certain  $\theta_0 \in \Theta$ , inconnu,  $\tilde{\theta}_n$  admet un développement

$$n^{1/2}(\tilde{\theta}_n - \theta_0) = n^{-1/2} \sum_{i=1}^n \mathbf{1}(X_i, Y_i, \theta_0) + o_p(1)$$

pour une certaine fonction vectorielle  $\mathbf{1}$  telle que (i)  $E[\mathbf{1}(X, Y, \theta_0)] = 0$ ; (ii)  $L_{i,j}(\theta_0) = E[\mathbf{1}(X_i, Y_i, \theta_0)\mathbf{1}'(X_j, Y_j, \theta_0)]$  existe pour tout  $(i, j) \in (\mathbb{N}^*)^2$ .

**Condition 2.** (i)  $m(x, \theta)$  est continuellement différentiable pour chaque  $\theta$  dans l'intérieur  $\Theta^0$  de  $\Theta$ . Posons

$$\mathbf{g}(x, \theta) = \frac{\partial m(x, \theta)}{\partial \theta} = (g_1(x, \theta), \dots, g_p(x, \theta))'. \tag{5}$$

(ii) Il existe une fonction  $F$ -intégrable  $M(x)$  telle que

$$|g_i(x, \theta)| \leq M(x) \quad \text{pour tout } \theta \in \Theta \text{ et } 1 \leq i \leq p. \tag{6}$$

**Théorème 1.** Supposons que  $E(Y^{2+\delta_0}) < +\infty$  où  $\delta_0 > 0$  et que les Conditions 1 and 2 soient satisfaites. Alors sous  $m = m(\cdot, \theta_0)$ ,  $R_n^* \rightarrow R_\infty^*$  en loi dans l'espace  $D[-\infty, +\infty]$  où  $R_\infty^*$  est un processus centré Gaussien avec fonction de covariance

$$\begin{aligned} K^*(x, y) = & K(x, y) + \mathbf{G}'(x, \theta_0) \left( L_{1,1}(\theta_0) + 2 \sum_{k=2}^{+\infty} L_{1,k}(\theta_0) \right) G(y, \theta_0) \\ & - \mathbf{G}'(x, \theta_0) \sum_{k=0}^{+\infty} E[I_{[X_1 \leq x]}(Y_1 - m(X_1, \theta_0))\mathbf{1}(X_{1+k}, Y_{1+k}, \theta_0)] \\ & - \mathbf{G}'(y, \theta_0) \sum_{k=0}^{+\infty} E[I_{[X_1 \leq y]}(Y_1 - m(X_1, \theta_0))\mathbf{1}(X_{1+k}, Y_{1+k}, \theta_0)], \end{aligned} \tag{7}$$

où  $\mathbf{G}(x, \theta) = (G_1(x, \theta), \dots, G_p(x, \theta))$  et  $G_i(x, \theta) = \int_{-\infty}^x g_i(u, \theta) F(du)$ ,  $1 \leq i \leq p$ , et

$$K(x, y) = \int_{-\infty}^{x \wedge y} \text{Var}(Y | X = u) F(du) + 2 \sum_{k=1}^{+\infty} \int_{-\infty}^x \int_{-\infty}^y \text{Cov}(Y_1, Y_{1+k} | X_1 = u, X_{1+k} = v) F_{1,1+k}(du, dv), \tag{8}$$

où  $F_{i,j}$  est la fonction de répartition de  $(X_i, X_j)$ .

### 3. Applications au modèle d'autorégression

Considérons un modèle qui peut être écrit sous la forme

$$X_i^* = \rho_0 + \rho_1 X_{i-1}^* + \dots + \rho_p X_{i-d}^* + \varepsilon_i, \tag{9}$$

où  $\rho = (\rho_0, \dots, \rho_d)$  est un paramètre d'intérêt avec les  $(X_i^*, \varepsilon_i)$  identiquement distribué et géométriquement absolument réguliers.

Les  $\varepsilon_i$  peuvent dépendre de  $X_{i-1}^*$  contrairement aux processus ARMA.

Nous supposons aussi que

- (i)  $E(\|\varepsilon_i\|^5) < +\infty$ ,
- (ii) toute les racines de l'équation  $x^p - \rho_1 x^{p-1} - \dots - \rho_d = 0$  sont à l'intérieur du cercle unité,
- (iii) la densité  $f^*$  de  $F^*$  (fonction de répartition de  $\varepsilon_i$ ) est bornée, strictement positive et différentiable avec  $f^{*'} absolutely bornée.$

Soit  $(\mathbf{X}_i, Y_i)$  la suite de vecteurs aléatoires dans  $\mathbb{R}^{d+1}$  définis par  $Y_i = X_i^*$  et  $\mathbf{X}_i = (X_{i-1}^*, \dots, X_{i-d}^*)$ .

Posons maintenant  $\mathcal{M} = \{m, m(\mathbf{x}) = E(Y_i | \mathbf{X}_i = \mathbf{x})\}$  et  $X_i^*$  est de la forme (9).

Nous utiliserons les résultats de la Section 2 pour tester  $H_0 : m \in \mathcal{M}$  versus la suite d'alternatives  $H_{1,n} : m \equiv m_n \notin \mathcal{M}$ .

Nous pouvons obtenir la puissance des tests si l'alternative approche  $\mathcal{M}$  au taux  $n^{-1/2}$  dans une direction spécifique.

Le paramètre  $\rho$  sera estimé par le  $\alpha^{\text{ème}}$  quantile d'autorégression (voir Harel et Puri [2] pour une définition).

D'après le Théorème 3.1 de Harel et Puri [2], le  $\alpha^{\text{ème}}$  quantile d'autorégression satisfait la Condition 1 et le modèle (9) satisfait la Condition 2.

Notons  $\mathbf{D}_d[-\infty, +\infty]$  la version  $d$ -dimensionnelle de l'espace de Skorohod  $D[-\infty, +\infty]$ .

Nous déduisons facilement le théorème suivant

**Théorème 2.** *Sous  $H_0$  et les conditions (i)–(iii),  $R_n^* \rightarrow R_\infty^*$  en loi dans l'espace  $\mathbf{D}_d[-\infty, +\infty]$  où  $R_\infty^*$  est un processus centré Gaussien avec pour fonction de covariance*

$$K^*(\mathbf{x}, \mathbf{y}) = K(\mathbf{x}, \mathbf{y}) + \mathbf{G}'(\mathbf{x}, \rho) \mathbf{Q}_\alpha^{-1} \left\{ E(V_1^2(\alpha) \mathbf{X}_1^* \mathbf{X}_1^{*\prime}) + 2 \sum_{k=1}^{+\infty} E(V_1(\alpha) V_{1+k}(\alpha) \mathbf{X}_1^* \mathbf{X}_{1+k}^{*\prime}) \right\} \mathbf{Q}_\alpha^{-1} \mathbf{G}(\mathbf{y}, \rho) \\ - \mathbf{G}'(\mathbf{x}, \rho) \mathbf{Q}_\alpha^{-1} \sum_{k=0}^{+\infty} E[I_{[\mathbf{X}_1 \leq \mathbf{x}]} \varepsilon_1 V_{1+k}(\alpha) \mathbf{X}_1^* \mathbf{X}_{1+k}^{*\prime}] - \mathbf{G}'(\mathbf{y}, \rho) \mathbf{Q}_\alpha^{-1} \sum_{k=0}^{+\infty} E[I_{[\mathbf{X}_1 \leq \mathbf{y}]} \varepsilon_1 V_{1+k}(\alpha) \mathbf{X}_1^* \mathbf{X}_{1+k}^{*\prime}], \quad (10)$$

où  $V_i(\alpha) = I_{[F^*(\varepsilon_i) \leq \alpha]} - \alpha$ ,  $\mathbf{G}'(\mathbf{x}, \rho) = (G_0(\mathbf{x}, \rho), G_1(\mathbf{x}, \rho), \dots, G_d(\mathbf{x}, \rho))$ ,  $G_j(\mathbf{x}, \rho) = E[I_{[\mathbf{X}_1 \leq \mathbf{x}]} \mathbf{X}_1^* \mathbf{e}_j]$  et  $\mathbf{Q}_\alpha$  est une  $(d+1) \times (d+1)$  matrice définie positive.

Maintenant nous avons besoin de critères pour tester  $H_0$  contre  $H_{1,n}$ .

Supposons que sous  $H_{1,n}$  le modèle est

$$\mathbf{Y}_n = \xi_n \rho + \mathbf{V}_n \beta_n + \varepsilon_n, \quad (11)$$

où  $\mathbf{V}_n = (v_{j,i})_{\substack{1 \leq j \leq n \\ 1 \leq i \leq q}}$  est une matrice d'ordre  $(n \times q)$ ,  $\beta_n \in \mathbb{R}^q$  non spécifié,  $\mathbf{Y}'_n = (X_1, \dots, X_n)$  et  $\xi_n$  est la  $n \times (d+1)$  matrice dont la  $i^{\text{ème}}$  colonne est  $(1, X_{i-1}, \dots, X_{i-d})'$ .

Nous supposons aussi que (iv)  $\lim_{n \rightarrow \infty} n^{-1} \sum_{j=1}^{i=n} v_{j,i} = v_i$ , où  $-\infty < v_i < +\infty$ ,  $1 \leq i \leq q$  (posons  $\mathbf{V} = (v_1, \dots, v_q)'$ ), (v)  $\beta_n = (\beta_{n,1}, \dots, \beta_{n,q}) = n^{-1/2} \beta_0$ ,  $\beta_0 \in \mathbb{R}^q$ , fixé.

On déduit facilement du Théorème 2

**Théorème 3.** *Sous  $H_{1,n}$  les conditions (i) à (v),  $R_n^* \rightarrow R_\infty^*$  en loi dans l'espace  $\mathbf{D}_d[-\infty, +\infty]$  où  $R_\infty^*$  est un processus Gaussien de moyenne  $\mathbf{V}' \beta_0$  et de fonction de covariance  $K^*(\mathbf{x}, \mathbf{y})$  définie dans (10).*

## Références

- [1] J. Diebold, J. Zuber, Goodness of fit tests for nonlinear heteroscedic regression models, *Statist. Probab. Lett.* 42 (1999) 53–60.
- [2] M. Harel, M.L. Puri, Autoregression quantiles and related rank score processes for generalized random coefficient autoregressive processes, *J. Statist. Plann. Inference* 68 (1998) 271–294.
- [3] M. Harel, M.L. Puri, Conditional empirical processes defined by nonstationary absolutely regular sequences, *J. Multivariate Anal.* 70 (1999) 250–285.
- [4] H.L. Koul, W. Stute, Nonparametric model checks for time series, *Ann. Statist.* 27 (1999) 204–236.
- [5] W. Stute, Asymptotic normality on nearest neighbor regression functions estimates, *Ann. Statist.* 12 (1984) 917–926.
- [6] W. Stute, On almost sure convergence of conditional empirical distribution functions, *Ann. Probab.* 14 (1986) 891–901.
- [7] W. Stute, Nonparametric model checks for regression, *Ann. Statist.* 25 (1997) 613–641.
- [8] K. Yoshihara, Conditional empirical processes defined by  $\varphi$ -mixing sequences, *Comput. Math. Appl.* 19 (1990) 149–158.