

## MÉTHODE DES MOINDRES CARRÉS PÉNALISÉS (H3, J1)

(21 / 09 / 2020, © Monfort, Dicostat2005, 2005-2020)

(i) Soit :

$$(1) \quad y_n = \rho(x_n) + u_n, \quad \forall n \in \mathbb{N}_N^*,$$

un **modèle de régression** (non linéaire), basé sur une **fonction de régression**  $\rho$ , et dans lequel les  $y_n$  et les  $x_n$  sont des **vars** supposées **observables**. On suppose aussi que  $a \leq x_1 < \dots < x_N \leq b$ , où  $(a, b) \in \mathbb{R}^2$ , et que  $(u_n)_{n=1, \dots, N}$  est une **suite iid** tq :

$$(2) \quad E u_n = 0 \text{ et } V u_n = \sigma^2, \quad \forall n \in \mathbb{N}_N^*.$$

On remplace souvent (2) par l'hypothèse plus étroite :

$$(2)' \quad u_n \sim \mathcal{N}(0, \sigma^2).$$

Dans ce **contexte**, on appelle **méthode des moindres carrés pénalisés** une méthode d'estimation de  $\varphi$  à l'aide de la solution (en  $\rho$ ) du **problème d'optimisation** suivant (cf **estimateur spline de la régression**) :

$$(3) \quad \begin{aligned} & \min \sum_{n=1}^N (y_n - \rho(x_n))^2 \\ & \text{sous } \int \mathbf{1}([a, b]) \cdot \{\rho''(x)\}^2 dx \leq c \quad (\text{pénalisation}), \end{aligned}$$

dans lequel  $c$  est une **constante** donnée,  $\mathbf{1}(B) = \mathbf{1}_B$  est l'**indicatrice** d'une **partie**  $B \in \mathcal{B}(\mathbb{R})$  (**tribu des boréliens** de  $\mathbb{R}$ ) et  $\rho''$  la **dérivée** seconde de  $\rho$  (cf **dérivation**).

(ii) La méthode consiste ainsi à choisir un estimateur de  $\rho$  qui concilie à la fois :

(a) une bonne **adéquation** (au sens des moindres carrés) de  $\rho$  pr aux **données**  $(x_n, y_n)_{n=1, \dots, N}$  ;

(b) et une **variation locale moyenne** (sous forme de **courbure moyenne**) minimale.

La solution de (3) est aussi appelée **estimateur par lissage spline** de la régression. On peut la calculer à l'aide des multiplicateurs de LAGRANGE du problème de **calcul des variations** (3) (cf **programmation mathématique**, **lagrangien**).

(iii) Lorsque les données sont des **séries temporelles**, l'estimation du **paramètre secondaire**  $\sigma^2$  (cf aussi **paramètre principal**) s'effectue généralement après élimination de la **tendance** de la série  $(y_n)_{n=1, \dots, N}$ .

Un estimateur possible de  $\sigma^2$  est alors :

$$(4) \quad (s^2)^\sim = \{2 \cdot (N - 1)\}^{-1} \cdot \sum_{n=2}^N (y_n^\sim - y_{n-1}^\sim)^2,$$

où  $(y_n^\sim)_{n=1, \dots, N}$  est la série corrigée d'une éventuelle tendance.