

$\frac{1}{m} \sum_{i=1}^m \hat{f}_x^{-i}(x_i)$  est un estimateur sans biais de type "leave-one out" de  $\mathbb{E} \left[ \int \hat{f}_x(x) f_x(x) dx \right]$

Proposition :  $\mathbb{E} \left[ \frac{1}{m} \sum_{i=1}^m \hat{f}_x^{-i}(x_i) \right] = \mathbb{E} \left[ \int \hat{f}_x(x) f_x(x) dx \right]$

Démonstration :

$$\begin{aligned} \mathbb{E} \left[ \frac{1}{m} \sum_{i=1}^m \hat{f}_x^{-i}(x_i) \right] &= \frac{1}{m} \sum_{i=1}^m \mathbb{E} \left[ \hat{f}_x^{-i}(x_i) \right] \stackrel{iid}{=} \mathbb{E} \left[ \hat{f}_x^{-1}(x_1) \right] \\ &= \mathbb{E} \left[ \frac{1}{m-1} \sum_{j \neq i} \frac{1}{h} k \left( \frac{x_j - x_i}{h} \right) \right] \stackrel{iid}{=} \frac{1}{m-1} \mathbb{E} \left[ \frac{1}{h} k \left( \frac{x_2 - x_1}{h} \right) \right] \\ &= \mathbb{E} \left[ \frac{1}{h} k \left( \frac{x_2 - x_1}{h} \right) \right] = \int \frac{1}{h} k \left( \frac{x_2 - x_1}{h} \right) f_x(x_1) f_x(x_2) dx_1 dx_2 \end{aligned}$$

Or  $\mathbb{E} \left[ \int \hat{f}_x(x) f_x(x) dx \right] = \mathbb{E} \left[ \frac{1}{m} \sum_{i=1}^m \int \frac{1}{h} k \left( \frac{x_i - x}{h} \right) f_x(x) dx \right]$

$\stackrel{iid}{=} \mathbb{E} \left[ \int \frac{1}{h} k \left( \frac{x_2 - x}{h} \right) f_x(x) dx \right]$  → au futur : Tonnel et  $k > 0$   
→ au regard de la j et verification

$= \mathbb{E} \left[ \mathbb{E} \left[ \frac{1}{h} k \left( \frac{x_2 - x_1}{h} \right) \mid x_2 \right] \right] = \mathbb{E} \left[ \frac{1}{h} k \left( \frac{x_2 - x_1}{h} \right) \right]$

D'où  $\mathbb{E} \left[ \frac{1}{m} \sum_{i=1}^m \hat{f}_x^{-i}(x_i) \right] = \mathbb{E} \left[ \int \hat{f}_x(x) f_x(x) dx \right]$

La méthode "least squares cross validation" consiste donc à prendre  $h_{LSCV} = \underset{h>0}{\operatorname{argmin}} LSCV(h)$

## V. Estimation du mode

On va proposer une méthode d'estimation non-paramétrique du mode  $\theta$ .

Rappel :  $\theta \in \operatorname{argmax} \{ \mathbb{E} \mathbb{1}_R : f_x(t) \}$

On propose donc de manière assez naturelle l'estimateur du mode suivant

$$\hat{\theta} = \operatorname{argmax} \{t \in \mathbb{R} : \hat{f}_x(t)\}$$

Et  $\operatorname{argmax}$  n'est pas forcément unique. On prend alors l'une des valeurs qui maximise  $\hat{f}_x$ .

En pratique, la méthode la plus basique consiste à estimer  $\hat{f}_x$  sur une grille  $t_1, \dots, t_m$  de points équidistants d'un pas  $\varepsilon$  petit et de prendre comme estimateur du mode le point de la grille où  $\hat{f}_x$  est maximale

$$\hat{\theta} = \operatorname{argmax} \{j \in \llbracket 1, M \rrbracket, \hat{f}_x(t_j)\}.$$

On peut bien entendu utiliser des méthodes plus raffinées :

- ↳ Newton-Raphson
- ↳ méthode du nombre d'or
- ↳ ...

## C - Estimateur à noyau de la fonction de régression

On suppose maintenant que l'on observe pour chaque individu une observation  $(X_i, Y_i)$  de variables réelles.

On suppose  $(X_i, Y_i) \stackrel{iid}{\sim} (X, Y)$   
 $1 \leq i \leq m$

### I - Définition

On souhaite étudier la manière dont la variable d'intérêt (ou réponse)  $Y$  dépend de la variable

explicative (ou auxiliaire)  $X$ .

Il s'agit donc d'un modèle de régression de  $Y$  sur  $X$   
 $Y = \alpha(X) + \varepsilon$ ,  $\alpha$  mesurable et  $E[\varepsilon|X] = 0$ .

Remarque :  $E[Y|X] = E[\alpha(X)|X] + E[\varepsilon|X]$

$$E[Y|X] = \alpha(X)$$

$$\bullet \text{cov}(X, \varepsilon) = E[\varepsilon X] - E[\varepsilon]E[X]$$

$$= E[E[\varepsilon|X]E[X]] - E[E[\varepsilon|X]]E[X]$$

$$= 0 \quad \text{car } E[\varepsilon|X] = 0$$

On cherche à estimer  $\alpha$ , la fonction de régression. On connaît déjà le modèle de régression linéaire

$$Y = aX + b + \varepsilon.$$

Ce modèle fait une hypothèse forte sur la nature du lien entre  $X$  et  $Y$  (fonction de régression  $\alpha$ ) et se ramène à l'estimation des paramètres  $a$  et  $b$ . On parle de modèle paramétrique.

Nous allons maintenant considérer des modèles plus généraux, appelés modèles non-paramétriques pour lesquels, aucune hypothèse n'est faite sur la nature de  $\alpha$  (fonction reliant  $Y$  et  $X$ )

Nous ferons simplement des hypothèses portant sur sa régularité

Estimateur de Nadaraya-Watson (1964).

$$\hat{\alpha}(x) = \begin{cases} \frac{\sum_{i=1}^m Y_i k\left(\frac{X_i - x}{h}\right)}{\sum_{i=1}^m k\left(\frac{X_i - x}{h}\right)} & \text{si } \sum_{i=1}^m k\left(\frac{X_i - x}{h}\right) \neq 0 \\ \bar{Y} & \text{sinon} \end{cases}$$

Comme nous l'avons dit pour l'estimation de la densité, il est intéressant d'utiliser dans un premier temps un estimateur non paramétrique afin de réaliser une étude exploratoire des données.

Si le résultat de cette étude met en évidence que la fonction  $x$  que l'on cherche à estimer est de nature connue (à quelques paramètres près) on pourra alors proposer des méthodes d'estimations paramétriques qui ont l'avantage de converger plus rapidement et d'être plus faciles à interpréter.

Remarques: • L'estimateur  $\hat{x}$  est une moyenne pondérée des  $Y_i$  :

$$\hat{x}(x) = \sum_{i=1}^m Y_i w_i(x) \quad \text{où} \quad w_i(x) = \begin{cases} \frac{k\left(\frac{X_i-x}{h}\right)}{\sum_{j=1}^m k\left(\frac{X_j-x}{h}\right)} & \text{si } \sum_{j=1}^m k\left(\frac{X_j-x}{h}\right) \neq 0 \\ \frac{1}{m} & \text{sinon.} \end{cases}$$

• Cet estimateur peut s'écrire comme quotient de deux estimateurs, dont celui de la densité :

$$\hat{x}(x) = \frac{\hat{g}(x)}{\hat{f}_x(x)} \quad \text{avec} \quad \begin{cases} \hat{g}(x) = \frac{1}{mh} \sum_{i=1}^m Y_i k\left(\frac{X_i-x}{h}\right) \\ \hat{f}_x(x) = \frac{1}{mh} \sum_{i=1}^m k\left(\frac{X_i-x}{h}\right) \end{cases}$$

### Choix de $h$

- Si  $h$  est trop petit, on a un sur-ajustement aux données. Les poids sont nuls sauf au voisinage des observations où ils deviennent proche de 1 (biais faible mais variance forte)
- Si  $h$  est trop grand, on a un sous-ajustement aux

données car les poids sont quasiment tous les mêmes (biais fort mais variance faible).

## II - Propriétés asymptotiques :

Rappel : Convergence presque-complète

- $Z_m \xrightarrow[m \rightarrow +\infty]{p.co} Z \Leftrightarrow \forall \varepsilon > 0, \sum_{m \geq 0} \mathbb{P}(|Z_m - Z| > \varepsilon) < +\infty$
- $Z_m - Z = \mathcal{O}_{p.co}(x_m) \Leftrightarrow \exists K > 0, \sum_{m \geq 0} \mathbb{P}(|Z_m - Z| > Kx_m) < +\infty$ .
- $Z_m - Z = \mathcal{O}_{p.co}(\varepsilon x_m) \Leftrightarrow \forall \varepsilon > 0, \sum_{m \geq 0} \mathbb{P}(|Z_m - Z| > \varepsilon x_m) < +\infty$ .
- convergence presque-complète  $\Rightarrow$  convergence presque-sûr.

### A - Convergence presque complète ponctuelle

Hypothèses : a -  $x$  et  $f$  sont  $k > 0$  fois continuellement dérivable au voisinage de  $x$ .

b -  $f'(x) > 0$

c -  $\lim_{m \rightarrow +\infty} h_m = 0$  et  $\lim_{m \rightarrow +\infty} \frac{mh_m}{\ln(m)} = +\infty$ .

d - On suppose  $k$  borné,  $\ln(m)$  intégrable et à support compact.

e -  $k$  est un noyau d'ordre  $k$  (Gasser et Müller, 1979):

$\forall j = 1, \dots, k-1: \int t^j k(t) dt = 0$  et  $\|\int t^k k(t) dt\| < +\infty$  et  $\neq 0$ .

(note : incompatible avec  $k$  positif si  $k \geq 2$ )

f -  $|f| < M < +\infty$  p.s (peut être généralisé).

Théorème 1 : Sous les hypothèses précédentes, on a :

$$\hat{x}(x) - x(x) = \mathcal{O}_{p.co}(h^k) + \mathcal{O}_{p.co}\left(\sqrt{\frac{\ln(m)}{mh}}\right)$$

## 2 - Convergence presque complète uniforme sur un compact

On appelle  $S$  un compact tel que  $S \subseteq \mathbb{R}$ .

Hypothèses : a)  $x$  et  $f$  sont  $\mathcal{C}^k$  ( $k > 0$ ) sur un voisinage de  $S$   
b)  $\exists \theta > 0$ ,  $\inf_{x \in S} \{f_x(x)\} \geq \theta$

g)  $\exists \beta > 0$ ,  $\exists C < +\infty$ ,  $\forall x \in S, \forall y \in S, |k(x) - k(y)| \leq C|x - y|^\beta$

Théorème 2 : Sous les hypothèses a) b) et c) à g), on a :

$$\sup_{x \in S} |\hat{x}(x) - x(x)| = \mathcal{O}_{p.c.}(h^k) + \mathcal{O}_{p.c.}\left(\sqrt{\frac{\ln(m)}{mh}}\right)$$

## 3 - Convergence presque complète sous hypothèse de type Lipschitz ou de type Holder (sur $f_x$ et $x$ ).

Pour  $\phi = f_x$  et  $x$

Hypothèses : a'')  $\exists \beta > 0, \exists C < +\infty, \exists \beta > 0, \forall y \in ]x - \varepsilon, x + \varepsilon[$ ,  
 $|\phi(x) - \phi(y)| \leq C|x - y|^\beta$

a''')  $\exists \beta > 0, \exists C < +\infty, \forall x \in S, \forall y \in S$   
 $|\phi(x) - \phi(y)| \leq C|x - y|^\beta$

Théorème 3A : Sous les hypothèses a''), b) à d) et f), on a :

$$\hat{x}(x) - x(x) = \mathcal{O}_{p.c.}(h^\beta) + \mathcal{O}_{p.c.}\left(\sqrt{\frac{\ln(m)}{mh}}\right)$$

Théorème 3B : Sous les hypothèses a'''), b) c) d) f) et g), on a :

$$\sup_{x \in S} (|\hat{x}(x) - x(x)|) = \mathcal{O}_{p.c.}(h^\beta) + \mathcal{O}_{p.c.}\left(\sqrt{\frac{\ln(m)}{mh}}\right)$$

#### 4- Convergence en moyenne quadratique :

Hypothèses : c')  $\lim_{m \rightarrow +\infty} h_m = 0$  et  $\lim_{m \rightarrow +\infty} mh_m = +\infty$ .  
h)  $\Phi(u) = \mathbb{E}[Y^2 | X=u]$  est continue au point  $x$ .  
d')  $k$  bornée, intégrable, positif, symétrique et à support compact.

Notation :  $g = x \cdot \int x$

Théorème 4 : Si a) est vérifié avec  $k=2$  et si b), c'), h) et d') sont vérifiées alors on a :

$$\mathbb{E}_x \left[ \left( \hat{x}(x) - x(x) \right)^2 \right] = B(x) h^4 + V(x) \frac{1}{mh} + o\left(h^4 + \frac{1}{mh}\right)$$

où  $B(x) = \frac{1}{2 \int_x(x)} \int_{\mathbb{R}} k^2(t) dt \cdot \left( g^{(2)}(x) - x(x) \int_x^{(2)}(x) \right)$

et  $V(x) = \frac{\Phi(x) - x^2(x)}{\int_x(x)} \int_{\mathbb{R}} k^2(t) dt$

#### 5- Convergence en MISE

•  $MISE(\hat{x}) = \mathbb{E} \left[ \int_{\mathbb{R}} (\hat{x}(x) - x(x))^2 w(x) dx \right]$  où

i)  $w$  est une fonction de poids positive, bornée et à support compact  $S$ .

h')  $\Phi(u) = \mathbb{E}[Y^2 | X=u]$  est continue sur un voisinage de  $S$ .

Théorème 5 : Sous les conditions d') avec  $k=2$  et si de plus b') d') i) et h') sont vérifiées alors :

$$MISE(\hat{x}) = B^2 h^4 + \frac{V}{mh} + o\left(h^4 + \frac{1}{mh}\right)$$

avec  $B^2 = \int_{\mathbb{R}} B^2(x) \omega(x) dx$  et  $V = \int_{\mathbb{R}} V(x) \omega(x) dx$

Remarque: On retrouve l'équilibre biais/variance entière pour la densité. Et on obtient de manière similaire des expressions asymptotiquement optimales pour  $h$  par rapport aux termes dominants de la MISE et de la MSE:

$$\hat{h}_{AMISE} = \left( \frac{V}{4B^2} \right)^{1/5} m^{-1/5} \quad \text{et} \quad \hat{h}_{AMSE} = \left( \frac{V(x)}{4B^2(x)} \right)^{1/5} m^{-1/5}$$

### 6 - Vitesses de convergence

On obtient comme corollaire des résultats précédents:

- Sous les hypothèses du théorème 1 et 2 (respectivement) avec  $h \sim C \left( \frac{m}{\ln(m)} \right)^{-1/2k+1}$

$$\hat{\pi}(x) - \pi(x) = O_{p.co} \left( \left( \frac{m}{\ln(m)} \right)^{-\frac{k}{2k+1}} \right)$$

$$\sup_{x \in S} |\hat{\pi}(x) - \pi(x)| = O_{p.co} \left( \left( \frac{m}{\ln(m)} \right)^{-\frac{k}{2k+1}} \right)$$

- Sous les hypothèses du théorème 3A et 3B avec  $h \sim C \left( \frac{m}{\ln(m)} \right)^{-\frac{1}{2\beta+1}}$

$$\hat{\pi}(x) - \pi(x) = O_{p.co} \left( \left( \frac{m}{\ln(m)} \right)^{-\frac{\beta}{2\beta+1}} \right)$$

$$\sup_{x \in S} |\hat{\pi}(x) - \pi(x)| = O_{p.co} \left( \left( \frac{m}{\ln(m)} \right)^{-\frac{\beta}{2\beta+1}} \right)$$

- Sous les hypothèses du théorème 4 et 5, avec  $h \sim C m^{-1/5}$ .

$$MSE(\hat{\pi}(x)) = O(m^{-4/5}) = \frac{5}{4} B^{2/5}(x) V^{4/5}(x) h^{1/5}$$



$$MISE(\hat{x}) = O(m^{-4/5}) = \frac{5}{4} B^{2/5} V^{4/5} L^{1/5}$$

## 7 - Choix du paramètre de lissage en pratique

Les choix optimaux que nous venons de voir nous fournissent des valeurs théoriques inutilisables en pratique.

Une méthode populaire : la validation croisée :

Notation :  $MISE(\hat{x}) := MISE(h)$ .

On choisit  $h_{cv} = \underset{h \in \mathcal{H}}{\operatorname{argmin}} CV(h)$

avec  $CV(h) = \sum_{i=1}^m (y_i - \hat{x}^{-i}(x_i))^2 w(x_i)$

où :

- $\mathcal{H}$  est un ensemble de valeurs possible pour  $h$
- $\hat{x}^{-i}(x) = \begin{cases} \frac{1}{\sum_{j \neq i}^m k(\frac{x_j - x}{h})} \sum_{j \neq i}^m y_j k(\frac{x_j - x}{h}) & \text{si } \sum_{j \neq i}^m k(\frac{x_j - x}{h}) \neq 0 \\ \bar{y} = \frac{1}{m-1} \sum_{j \neq i}^m y_j & \text{sinon} \end{cases}$

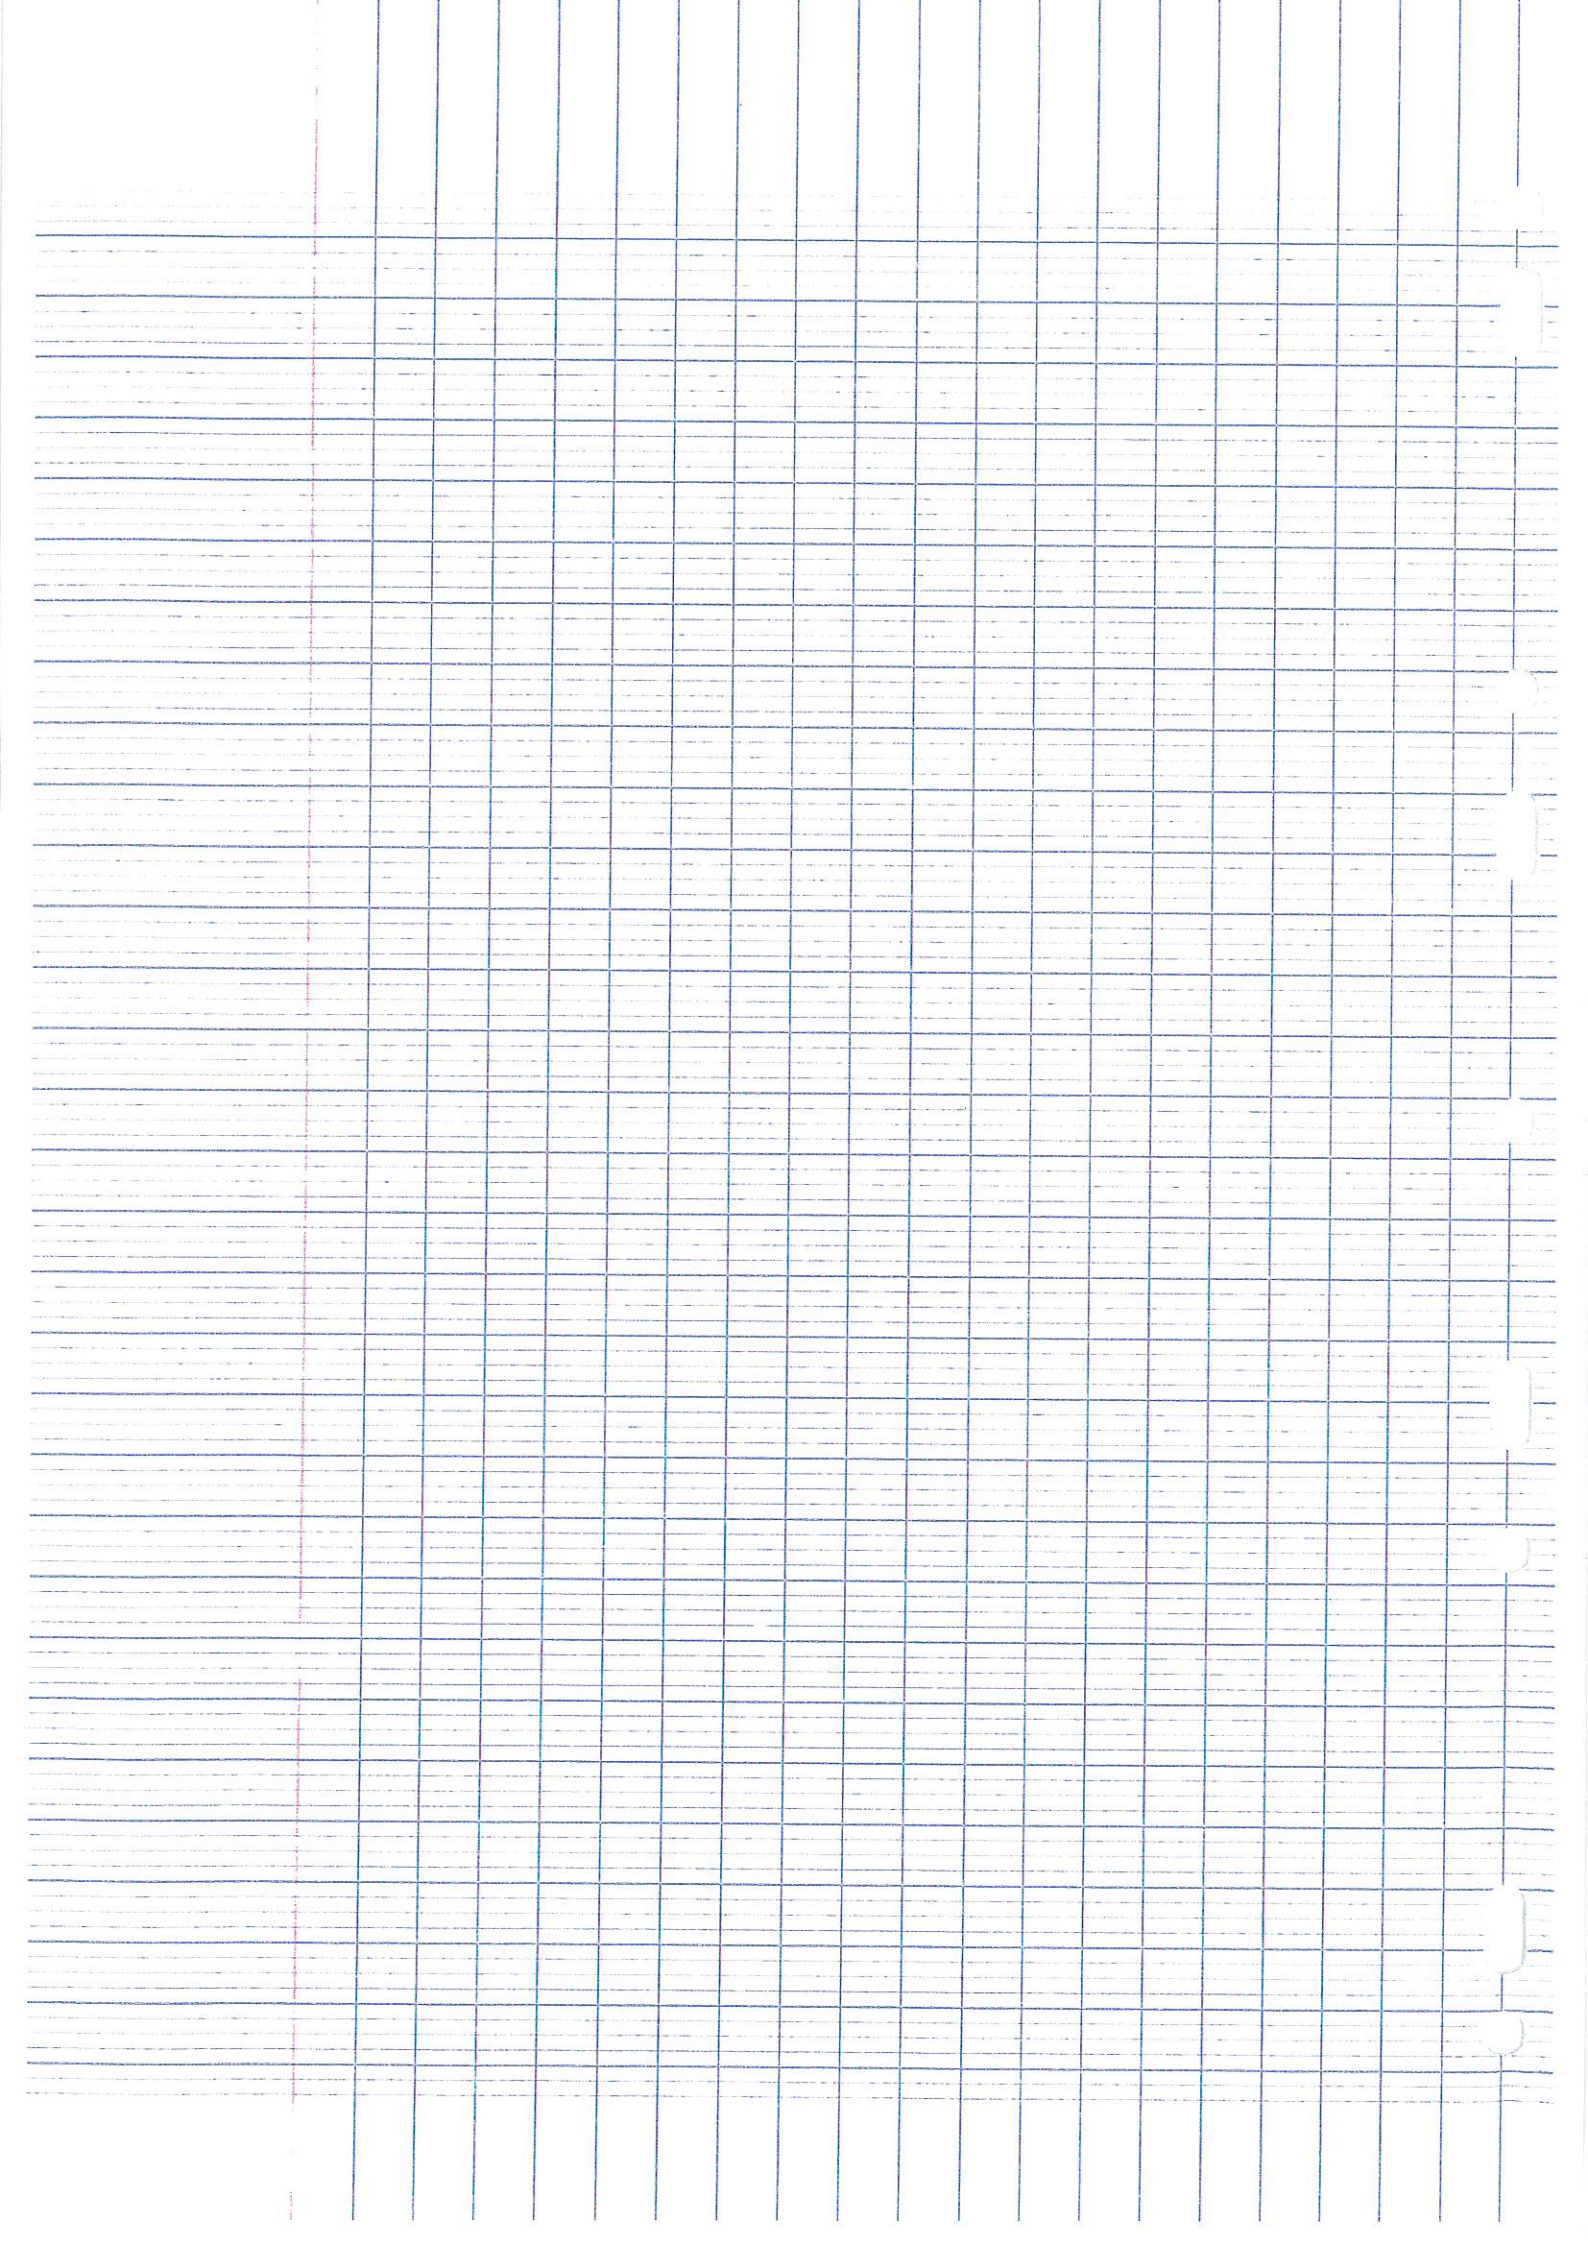
$$CV(h) = \sum_{i=1}^m (x(x_i) + \varepsilon_i - \hat{x}^{-i}(x_i))^2 w(x_i)$$

$$= \sum_{i=1}^m \varepsilon_i^2 w(x_i) + \sum_{i=1}^m (x(x_i) - \hat{x}^{-i}(x_i))^2 w(x_i) + 2 \sum_{i=1}^m \varepsilon_i (x(x_i) - \hat{x}^{-i}(x_i)) w(x_i)$$

$= A \text{ et } E[A] = 0$

*Théorème :* Sous les hypothèses du théorème 4B et si  $\mathcal{H}$  contient que des largeurs de fenêtre vérifiant c) alors

$$\frac{1}{MISE(h_{cv})} \times \inf_{h \in \mathcal{H}} (MISE(h)) \xrightarrow{m \rightarrow +\infty} 1$$



On choisit  $h_{cv} = \underset{h \in H}{\operatorname{argmin}} CV(h)$

$$\text{avec } CV(h) = \sum_{i=1}^n (\gamma_i - \hat{f}^{-i}(X_i))^2 w(X_i)$$

où  $H$  est un ensemble de valeurs possibles pour  $h$ .

$$\hat{f}^{-i}(x) = \begin{cases} \frac{\sum_{j=1, j \neq i}^n \gamma_j k\left(\frac{X_j - x}{h}\right)}{\sum_{j=1, j \neq i}^n k\left(\frac{X_j - x}{h}\right)} & \text{si } \sum_{j \neq i} k(\cdot) \neq 0 \\ \gamma_i & \text{sinon} \end{cases}$$

début cours.

$$\begin{aligned} CV(h) &= \sum_{i=1}^n (r(X_i) + \varepsilon_i - \hat{f}^{-i}(X_i))^2 w(X_i) \\ &= \sum_{i=1}^n \varepsilon_i^2 w(X_i) + \sum_{i=1}^n (r(X_i) - \hat{f}^{-i}(X_i))^2 w(X_i) \\ &\quad + 2 \sum_{i=1}^n \varepsilon_i (r(X_i) - \hat{f}^{-i}(X_i)) w(X_i) \end{aligned}$$

par A - E[F] = 0 E

Théorème : sous les hypothèses du Théorème 4b et si  $H$  contient que des largeurs de fenêtre vérifiant c1) alors :

$$\lim_{h \in H} \frac{MISE(h)}{MISE(h_{cv})} \xrightarrow[n \rightarrow \infty]{p.s.} 1$$

Il existe d'autres méthodes pour choisir la largeur de fenêtre. Choix de  $k$  (cf densité, si on se restreint aux noyaux de cet

Modèle de regression étudié

$$Y = r(X) + \varepsilon \text{ avec } E[\varepsilon | X] = 0$$

d'où  $r(X)$  est l'espérance de la bi conditionnelle de  $Y$  sachant  $X$ .

On peut aussi s'intéresser à l'estimation d'autres paramètres de cette loi : mode, médiane, quantiles qui sont plus robustes à la présence de valeurs extrêmes / outliers

$K_0$  noyau  $> 0$ , d'intégral 1 (densité)

$$H(u) = \int_{-\infty}^u K_0(t) dt \quad (\text{fdr})$$

Mode conditionnel

densité conditionnelle de  $Y$  condition à  $X$

$$\hat{f}_{Y|X}(y, x) = \begin{cases} \frac{\sum_{i=1}^n \frac{1}{h} K_0\left(\frac{x_i - y}{h}\right) K\left(\frac{X_i - x}{h}\right)}{\sum_{i=1}^n K\left(\frac{X_i - x}{h}\right)} & \text{si } x \text{ est dans le support} \\ 0 & \text{sinon} \end{cases}$$

$$\hat{e}_{Y|X}(x) = \underset{y}{\operatorname{argmax}} \hat{f}_{Y|X}(y, x)$$

Médiane conditionnelle

Fdr conditionnelle

$$\hat{F}_{Y|X}(y, x) = \begin{cases} \frac{\sum_{i=1}^n H\left(\frac{x_i - y}{h}\right) K\left(\frac{X_i - x}{h}\right)}{\sum_{i=1}^n K\left(\frac{X_i - x}{h}\right)} & \text{si } x \text{ est dans le support} \\ 0 & \text{sinon} \end{cases}$$

$$\hat{q}_{Y|X}(x) \text{ solution en } y \text{ de } \hat{F}_{Y|X}(y, x) = \alpha$$

(par la médiane  $\alpha = 0,5$ )

## Applications à la discrimination (classification supervisée)

Par un même échantillon on dispose

$Y$  classe  $\in \{0, \dots, k-1\}$

$X$  donnée numérique

Echantillon  $(X_1, Y_1), \dots, (X_n, Y_n) \stackrel{iid}{\sim} (X, Y)$

Objectif Construire à partir de l'échantillon un classifieur qui à une nouvelle valeur  $x_0$  de  $X$  associe une classe (à ce nouvel individu)

### Classifieur de Bayes

$$\hat{y}_0 = \underset{y}{\operatorname{argmax}} P(Y=y | X=x_0)$$

C'est le meilleur classifieur possible mais il n'est pas utilisable car  $y \rightarrow P(Y=y | X=x)$  sont inconnues.

- Approche paramétrique Régression / Modèle logistique

pour  $k=2$  seulement

$$P(Y=1 | X=x_0) = \frac{e^{\beta + \langle \alpha, x_0 \rangle}}{1 + e^{\beta + \langle \alpha, x_0 \rangle}}$$

- Approche non paramétrique propoies

On remarque que  $\forall y, P(Y=y | X=x) = \mathbb{E}[\mathbb{1}_{Y=y} | X=x]$   
 $P(Y=y | X) = \mathbb{E}[\mathbb{1}_{Y=y} | X]$

d'où  $\forall y, X \rightarrow P(Y=y | X)$  est la fonction de régression d'un modèle  $\mathbb{1}_{Y=y} = r_y(X) + \varepsilon_y$  avec  $\mathbb{E}[\varepsilon_y | X] = 0$   
avec  $r_y(X) = P(Y=y | X)$

On propose donc d'estimer  $P(Y=y|X=x)$  par  $\hat{P}(Y=y|X=x) = \hat{f}_y(x) = \begin{cases} \frac{\sum_{i=1}^n \mathbb{1}_{Y=y} K(\frac{X_i-x}{h})}{\sum_{i=1}^n K(\frac{X_i-x}{h})} & \text{si } x \in \text{support} \\ \mathbb{1}_{Y=y} & \text{sinon} \end{cases}$

### Classifieur de Bayes "Estimé"

$$\hat{y}_0 = \underset{y}{\operatorname{argmax}} P(Y=y|X=x_0) = \underset{y}{\operatorname{argmax}} \hat{f}_y(x_0)$$

Exo :  $\sum_{y \in \mathcal{Y}, k=1}^k \hat{f}_y(x) = 1$

### Cas particulier $k=2$

$$\hat{y}_0 = 1 \iff \hat{f}_1(x_0) > 0,5$$


(si  $\hat{f}_0(x_0) = \hat{f}_1(x_0) = 1/2$  alors  $\hat{y}_0 = 0$ )

### Qualité de la méthode

- Taux d'erreur global
- Taux d'erreur relatifs (Matrice de confusion)

classé \ dans	0	1	2
0	ok		
1		ok	
2			ok

• Pour  $k=2$ , courbe ROC



$$\text{Taux de Faux positifs} : \frac{N_{12}}{n_1}$$

$$\text{Taux de Vrai positifs} : \frac{N_{22}}{n_2}$$

$$\hat{y}_0 = 1 \Leftrightarrow \hat{F}_y(x_0) > s, \quad s \in [0, 1]$$

$$s=1, \quad N_{12}=0, \quad N_{22}=n_2$$

$$s=0, \quad \text{Taux de la classe 1} \quad N_{12}=n_1, \quad N_{22}=0$$

+ AVC est grande, meilleure est la classification

$$\text{CV. Jamif} : \frac{1}{n} \sum_{i=1}^n 1_{\{Y_i \neq \hat{y}_i\}}$$

$$\hat{y}_i = \underset{y}{\text{argmax}} \hat{r}_y(x_i)$$

