

Statistiques non-paramétriques :
Ch. 3. Économétrie non-paramétrique 2018-19
M2 CEE

Pr. Philippe Polomé, Université Lumière Lyon 2



Sommaire

Estimation de fonction de densité et probabilité

Régression

Modèles semiparamétriques

LOESS

Densités & histogrammes lissés

- ▶ On commence par une analyse non-conditionnelle
 - ▶ Une régression est une analyse conditionnelle
 - ▶ Ici on veut la courbe des “y”
 - ▶ Possiblement y est multidimensionnel
- ▶ On va regarder une façon de présenter un histogramme
 - ▶ de façon graphique
 - ▶ en lissant les bords avec un “kernel smoother”
 - ▶ Smooth : lisser
 - ▶ Kernel : noyau
 - ▶ “Densité par lissage noyau”
 - ▶ ou “densité noyau”

Histogramme

- ▶ Un histogramme
 - ▶ est une estimation non-param. de la densité $f(x)$ d'une va x
 - ▶ que l'on forme en divisant le **support** de x en intervalles **également espacés**
 - ▶ et en calculant la fraction de l'échantillon dans chaque intervalle
- ▶ Dans R
 - ▶ Données DataFrame cps
 - ▶ Dans package [AER](#)
 - ▶ Si vous utilisez le projet "Cours R" du cours de programmation
 - ▶ vous avez le fichier cps qui est chargé (sur les salaires)
 - ▶ Fonction `hist()`
 - ▶ est un basique de R
 - ▶ pas besoin de charger un package
 - ▶ `hist(cps$wage)`


Histogramme dans R : personnalisations

```
hist(cps$wage, main="Histogramme du salaire dans cps",  
xlab="salaire", border="blue", col="green", xlim=c(0,50), las=1,  
breaks=10)
```

- ▶ `breaks` est le nombre d'intervalles
 - ▶ Peut changer beaucoup l'aspect
 - ▶ On y revient + loin
- ▶ Mettre les noms d'axes & de couleurs entre " "
- ▶ `las` sert a changer la présentation des labels sur Y (0,1,2,3)
- ▶ On peut présenter des freq. rel. avec "`freq = F`"
 - ▶ Plutôt que des fréq. abs.
- ▶ On peut ajouter une densité lisse par dessus avec
 - ▶ `lines(density(cps$wage))`
 - ▶ Cette densité lisse est prédéfinie
 - ▶ On va explorer des méthodes pour la tracer

Histogramme dans R \rightarrow np2017.r

Histogramme du salaire dans cps




Effet de la bandwidth dans un histogramme → np2017.r


```
hist(cps$wage, breaks=10)
```

- ▶ `breaks` est le nombre d'intervalles
- ▶ Donc de leur largeur, appelé **bandwidth**


Histogramme du salaire dans cps



Histogramme du salaire dans cps



Histogramme du salaire dans cps



- ▶ Exercice
- ▶ Ajuster le nombre d'intervalles
- ▶ Changer la couleur (`rcolor.pdf` sur google)

Estimateur Histogramme

- ▶ Plus formellement, dans un histogramme,
 - ▶ on veut estimer la densité $f(x_0)$ d'une v.a. scalaire continue x
 - ▶ évaluée en x_0
- ▶ Si on a un échantillon $\{x_i, i = 1, \dots, N\}$,
 - ▶ **l'estimateur histogramme** de $f(x_0)$ est

$$\hat{f}_{\text{hist}}(x_0) = \frac{1}{N} \sum_{i=1}^N \frac{\mathbf{1}(x_0 - h < x_i < x_0 + h)}{2h}$$

- ▶ $2h$ est la longueur de l'intervalle
 - ▶ base du rectangle
- ▶ $\mathbf{1}(A)$ est une fonction indicatrice = 1 si A arrive et 0 sinon
 - ▶ Donc : on compte le nbr d'obs. **autour** de x_0 dans un rayon h
 - ▶ C'est un estimateur **local** car il n'utilise que de l'info locale

Densité noyau

- ▶ Cette procédure amène à une **estimation de la densité** qui est en escalier
 - ▶ Même si la véritable densité est lisse
- ▶ On réécrit l'estimateur Histogramme comme

$$\hat{f}_{\text{hist}}(x_0) = \frac{1}{Nh} \sum_{i=1}^N \frac{1}{2} \mathbf{1} \left(\frac{|x_i - x_0|}{h} < 1 \right)$$

- ▶ L'estimateur **densité noyau** DN généralise cette définition
 - ▶ en remplaçant la fonction $\mathbf{1}(\cdot)$ par une alternative $K(\cdot)$

$$\hat{f}_{\text{NOYAU}}(x_0) = \frac{1}{Nh} \sum_{i=1}^N K \left(\frac{x_i - x_0}{h} \right)$$

- ▶ $K(\cdot)$ est dite "fonction noyau" (kernel)
 - ▶ un "kernel" est simplement une fonction de pondération
- ▶ h est appelé largeur de bande
 - ▶ Paramètre de lissage ou **bandwidth**

Densité noyau

- ▶ Un estimateur noyau d'une densité
 - ▶ est donc une version lisse de son **histogramme**
 - ▶ évaluée **en chaque point** de l'échantillon
 - ▶ au lieu de quelques points comme dans l'histogramme
- ▶ Il s'agit d'un **estimateur** de la fonction de densité
 - ▶ souvent appelé Rosenblatt–Parzen
 - ▶ Rosenblatt (1956), Parzen (1962)

Densité noyau

- ▶ La fonction noyau K est positive, intégrable et à valeurs réelles
 - ▶ Souvent sym autour de 0, on note $z = \frac{x-x_0}{h}$
 - ▶ L'uniforme $\frac{1}{2} \mathbf{1}(|z| < 1)$ correspond à l'histogramme
 - ▶ Quadratique $\frac{3}{4} (1 - z^2) \mathbf{1}(|z| < 1)$
 - ▶ Gaussienne(0, 1) : $(2\pi)^{-1/2} \exp(-z^2/2)$
 - ▶ Gaussienne(μ, σ^2) : $(2\pi)^{-1/2} \exp\left(-\left(\frac{z-\mu}{\sigma}\right)^2 / 2\right)$
 - ▶ Le choix (arbitraire) du noyau est réputé comme peu influent sur l'estimateur
- ▶ h , le paramètre de lissage, est plus difficile à choisir
 - ▶ Le + petit le + lisse
 - ▶ Mais trop petit, il provoque l'apparition de détails artificiels sur le graphe
 - ▶ car trop peu de données entrent dans l'intervalle
 - ▶ Trop grand, la majorité du relief est effacée

Kernel smoother : Exemple density

- ▶ `density(x, bw = "nrd0", kernel, n = 512)`
 - ▶ `x` : vecteur des données
 - ▶ `bw` : le choix de la bandwidth
 - ▶ Pls “rules of thumb” : `SJ` based on derivatives, `nrd0` (défaut, mais pour raisons de compatibilité), `ucv` (unbiased cross-validation), `bcv` (biased cross-validation)
 - ▶ On verra + loin la cross-validation
 - ▶ `kernel =`
 - ▶ `"gaussian"`, `"epanechnikov"`, `"rectangular"`, `"triangular"`, `"biweight"`, `"cosine"`, `"optcosine"`
 - ▶ `n` : nbr des points equidistants auxquels estimer le kernel “gridsize”
 - ▶ On pourrait estimer en chaque point de l'éch.
- ▶ On va utiliser `plot` pour comparer les options de `density`

Kernel smoother : Autre exemple bkde

- ▶ Charger/installer le package `KernSmooth`
 - ▶ Comme dans le cours de programmation
 - ▶ `library("KernSmooth")`
- ▶ `wage_bkde <- bkde(cps$wage, kernel = "normal", bandwidth=1)`
 - ▶ `bkde` : Binned Kernel Density Estimate
 - ▶ Utiliser la variable "wage" dans le DataFrame `cps`
 - ▶ Kernel (noyau) : normal (arbitraire)
 - ▶ Autres : `box`, `epanech`, `biweight`, `triweight`
 - ▶ Bandwidth : 1 (arbitraire)
 - ▶ défaut : un calcul à partir de la variance de `x`
- ▶ `lines(wage_bkde)`
 - ▶ On voit que `bkde` est comme `density`
 - ▶ `plot` pour comparer les options de `bkde` & de `density`

```
plot(bkde(cps$wage, kernel = "normal", bandwidth=1))
```

- ▶ Dans les 2 cas, density & bkde
 - ▶ On voit que le bandwidth impacte beaucoup
 - ▶ Par contre, le kernel lui-même n'impacte pas beaucoup
 - ▶ La gridsize ne change que la question du dessin et n'impacte pas la forme de la courbe
- ▶ Quelques options de présentation de plot
 - ▶ `plot(wage_bkde, col=rev(rainbow(400, s = 1, v = 1, start = 0, end = max(1,400 - 1)/400, alpha = 1)), xlab = "wage", ylab="density")`
 - ▶ La couleur reflète la valeur de wage pas celle de density
- ▶ Diapo suivante : généraliser à deux dimensions
 - ▶ Cfr cours Prog dans R

Kernel smoother : Exemple 2D → np2017.R

- ▶ Densité des observations en bivarié
 - ▶ **bivariate** binned kernel density estimator `bkde2D()`
- ▶ `cps_bkde <- bkde2D(cbind(cps$experience, log(cps$wage)),
bandwidth=c(3.5, 0.5), gridsize=c(200, 200))`
 - ▶ Il faut choisir la bandwidth et la taille de la grille sur chacune des 2 dimensions
 - ▶ expérience & log(wage)
 - ▶ gridsize en 2D
- ▶ `image(cps_bkde$x1, cps_bkde$x2, cps_bkde$fhat,
col=rev(gray.colors(10, gamma=1)), xlab = "experience",
ylab="log(wage)")`
 - ▶ “heatmap” / courbes de niveau
- ▶ Exercice
 - ▶ Récupérer les données CPS1988 du package AER
 - ▶ Essayer de trouver la meilleure représentation en 1D et 2D
 - ▶ En changeant la bandwidth et/ou le kernel

Interpréter les densités

- ▶ Sur le fond, la densité noyau (univariée) est une ligne
 - ▶ que l'on dessine
 - ▶ qui s'ajuste d'une certaine manière au nuage de points
 - ▶ concrètement : elle représente la fréquence locale en chaque point
- ▶ On est proche d'une logique de régression
 - ▶ Il faut conditionner
 - ▶ Il y a d'autres façons de dessiner
 - ▶ Splines, "nearest neighbor", "neural network"...
 - ▶ Dans ce cours, on reste sur le noyau.

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Propriétés de l'estimateur noyau univarié

- ▶ En 1D, 2D ou plus,
 - ▶ La fonction kernel doit se comporter comme une densité
 - ▶ de moyenne nulle
 - ▶ et de variance finie

$$\int K(z) dz = 1 \quad \int zK(z) dz = 0 \quad \int z^2 K(z) dz = \kappa_2 < \infty$$

- ▶ Le support est généralement $-\infty, +\infty$

Erreur carrée moyenne (mean square error) MSE

- ▶ Les fonctions noyau sont svt choisies sur un critère de MSE
- ▶ Le biais de l'estimateur $\hat{f}_{NOYAU}(x)$ est

$$\hat{f}(x) - f(x)$$

(on laisse tomber "NOYAU" quand il n'y a pas confusion)

- ▶ La MSE est

$$mse\hat{f}(x) = E(\text{biais}^2) = var\hat{f}(x) + \text{biais}^2$$

on peut montrer que

$$\text{biais}\hat{f}(x) \approx \frac{h^2}{2} \frac{\partial^2 f(x)}{\partial x^2} \kappa_2$$

$$var\hat{f}(x) \approx \frac{f(x)}{nh} \int K^2(z) dz$$

Erreur carrée moyenne (mean square error) MSE

- ▶ On voit que
 - ▶ La variance **diminue** avec la bandwidth h
 - ▶ Le biais **augmente** avec le carré de la bandwidth h
 - ▶ Le biais augmente avec la dérivée 2^o de $f()$
 - ▶ il est donc au + fort autour du/des pics de la distribution
- ▶ Ces formules ont lieu en un point
- ▶ On peut intégrer le mse sur z pour obtenir une mse globale

$$imse \hat{f} = \int_{support x} mse \hat{f}(x) dx$$

- ▶ On cherche le kernel K et la bandwidth h qui minimisent $imse$

Erreur carrée moyenne (mean square error) MSE

- ▶ Le Kernel optimal est

$$K_e(z) = \begin{cases} \frac{3}{4\sqrt{5}} \left(1 - \frac{1}{5}z^2\right) & -\sqrt{5} \leq z \leq \sqrt{5} \\ 0 & \text{sinon} \end{cases}$$

qu'on appelle kernel d'Epanechnikov du nom de son inventeur

- ▶ Il se fait que pas mal de kernels ont des propriétés semblables
 - ▶ donc le kernel est souvent choisi pour des raisons informatiques
 - ▶ le kernel gaussien est le + souvent choisi

Choix de bandwidth

- ▶ Au contraire du Kernel,
 - ▶ l'optimisation précédente n'amène pas à une bandwidth utilisable en pratique
 - ▶ Mais la bandwidth détermine l'ajustement bien plus que le kernel
- ▶ Il est important d'en choisir une appropriée au problème traité
 - ▶ Il y a 4 grandes approches
 1. Heuristique (rule of thumb)
 2. Plug-in – je ne poursuis pas
 3. Validation croisée
 - 3.1 par Moindres Carrés
 - 3.2 par Maximum de Vraisemblance
 4. Bootstrap

Heuristique “référence”

- ▶ Le principe est d'utiliser le kernel choisi pour calculer la bandwidth optimale
- ▶ Comme souvent ce kernel est le kernel gaussien
 - ▶ Ça donne une bandwidth de $1.06\sigma n^{-1/5}$
 - ▶ n est la taille d'éch.
 - ▶ σ est l'écart-type de la normale utilisée dans le kernel
 - ▶ en pratique, on prend $\hat{\sigma}$ l'écart-type de l'échantillon

Autres méthodes

- ▶ Validation croisée par Moindres Carrés
 - ▶ Il est possible d'estimer le imse à partir de l'éch.
 - ▶ Cet imse dépend du bandwidth
 - ▶ On peut alors choisir le bandwidth qui minimise l'imse
 - ▶ Cette approche est la meilleure de celles présentées
 - ▶ mais est sensible à de petites variations des données (arrondis...)
- ▶ Validation croisée par Maximum de Vraisemblance
 - ▶ Même idée que la précédente, autre façon d'estimer le imse
 - ▶ Tend à sur-lisser (gommer les variations)
- ▶ Par bootstrap
 - ▶ Toujours l'idée d'estimer le imse
 - ▶ Trop exigeante sur le plan calculatoire

Conclusion

- ▶ On pourrait poursuivre avec
 - ▶ Comment estimer une densité discrète
 - ▶ Comment estimer une multivariée
 - ▶ Illustration graphique prochaine dia
- ▶ On va plutôt passer à l'analyse conditionnelle
 - ▶ Prélude à la régression
- ▶ Sur l'estimation d'une densité inconditionnelle
 - ▶ La comparaison n'est pas tellement "paramétrique" vs. np
 - ▶ car paramétrique est souvent mal spécifié, donc inconsistant
 - ▶ alors que np ne peut pas être mal spécifié
 - ▶ mais par contre est assez inefficent

Estimations de densités multivariées par np dans R

- ▶ ##### dynamic bivariate density plot avec donnees simulees
 - ▶ Exécuter le programme
 - ▶ Sélectionner tout le progr
 - ▶ jusque ##### FIN dynamic bivariate density plot simulation normales
 - ▶ et "run"
 - ▶ Mettez en grand la fenêtre de sortie (zoom ou agrandir manuellement)
 - ▶ 'sliders' and 'pickers' qui permettent de changer
 - ▶ kernel function & order (une propriété math du kernel qu'on ne voit pas)
 - ▶ scale factors (la bandwidth est calculée automatiquement, scale factor prend une part de cette bandwidth, donc équivalent à la bandwidth)
 - ▶ azimuthal viewing direction (point de vue)
 - ▶ number of training (essentiellement = gridsize)
 - ▶ number of evaluation observations (taille de l'éch.)
- ▶ ##### dynamic bivariate density plot avec donnees réelles Geyser
 - ▶ Idem sur données réelles

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité conditionnelle

Régression

Kernel Local Constant KLC

Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Estimation d'une densité conditionnelle

- ▶ La densité conditionnelle est sous-jacente à l'analyse de régression
 - ▶ Mais est rarement modélisée directement
 - ▶ En np, il est plus clair de passer par cette étape
- ▶ Soit $f(\cdot)$ la densité jointe de (X, Y)
 - ▶ pour rappel $\Pr\{X \leq x, Y \leq y\} = \int^x \int^y f(\cdot) dy dx = f(x, y)$
 - ▶ $\mu(\cdot)$ la densité marginale de X
 - ▶ $\mu(\cdot) = \int f(\cdot) dY$
 - ▶ "integrate Y out"
- ▶ Pour la suite,
 - ▶ Y est la variable dépendante
 - ▶ est expliquée
 - ▶ X est un régresseur
 - ▶ est explicative

Densité conditionnelle

- ▶ La densité conditionnelle est

$$\Pr\{Y \leq y | X \leq x\} = g(y|x) = f(x, y) / \mu(x)$$

- ▶ L'estimateur noyau de cette densité est

$$\hat{g}(y|x) = \hat{f}(x, y) / \hat{\mu}(x)$$

- ▶ $\hat{\mu}(x)$ est l'estimateur noyau univarié vu à la section précédente
- ▶ $\hat{f}(x, y)$ est une extension bivariée de cet estimateur
- ▶ Il faudrait discuter le choix de bandwidth
- ▶ La commande correspondante de np est `npcondensbw`
 - ▶ Conditionnal DENSity avec BandWidth par cv.ls (cross-validation par Least squares)
 - ▶ En général, on n'utilise pas directement cette commande, qui est appelée par d'autres procédures

R ##### Least-squares cross-validated conditional density estimation

- ▶ Génération de données (normale bivariée)
 - ▶ `n <- 500`
 - ▶ `rho <- 0.25` pour sigma ci-dessous
 - ▶ `mu <- c(0,0)` moyenne des variables a generer
 - ▶ `Sigma <- matrix(c(1,rho,rho,1),2,2)` matrice de var-cov des variables a générer
 - ▶ donc ici : générer un normale bivariée dont le mu contient 2 moyennes nulles (dist. marg.) et sigma indique une matrice avec des variance a 1 et des cov a rho=.25
 - ▶ rem. les deux chiffres qui suivent dans sigma indiquent "2L 2C"
 - ▶ `data <- mvrnorm(n=n, mu, Sigma)` génère des valeurs d'une normale multivariée
 - ▶ `mydat <- data.frame(x=data[,2],y=data[,1])`
 - ▶ y et x dont la corrélation est contrôlée par rho

Estimation

- ▶ `npcdensbw` va estimer la bandwidth associée à $\hat{g}(y|x) = \hat{f}(x, y) / \hat{\mu}(x)$
 - ▶ On verra + précisément comment + loin
 - ▶ Prend un peu de temps, selon la machine
 - ▶ Output summary assez sommaire (juste bandwidth)
 - ▶ Bandwidth type : fixed = kernel, il y en a d'autres
- ▶ Output graphique
 - ▶ Sélectionner la fenêtre plot
 - ▶ (x, y, densité) : on doit voir un graphique qui tourne
- ▶ Exercice : Pour voir comment la relation entre x et y change, changer les paramètres de la normale bivariée
 - ▶ corrélation rho élevée, \oplus ou \ominus
 - ▶ moyennes mu non-nulles
 - ▶ variances fort différentes (à l'intérieur de sigma)

Régresseurs non-pertinents

- ▶ Pour estimer une fonction $g(y|x) = f(x, y) / \mu(x)$
 - ▶ conditionnelle à pls régresseurs x vecteur
 - ▶ il faut intégrer autant de fois que de régresseurs
 - ▶ pour obtenir la distribution multidim. des régresseurs
- ▶ On peut montrer que la convergence de $\hat{f}(\cdot)$ à $f(\cdot)$
 - ▶ se détériore rapidement lorsque le nombre de variables continue augmente
 - ▶ “**malédiction de la dimensionalité**”
- ▶ Il est donc particulièrement important en np
 - ▶ d'éviter les régresseurs non-pertinents
 - ▶ Idéalement, ils sont “smoothed out” :
 - ▶ Pour un x non pertinent, le graphe de y reste le même pour tous les niveaux de x

Régresseurs non-pertinents

- ▶ Hall et al. (2004) montre que
 - ▶ Une version de la validation croisée par MC
 - ▶ assigne automatiquement un fort paramètre de lissage aux régresseurs non-pertinents
 - ▶ leur dist. marginale tend à l'uniforme
 - ▶ cela supprime leur contribution à la variance de l'estimateur
 - ▶ et donc montre qu'ils sont indép. de la variable expliquée
 - ▶ Les variables pertinentes par contre sont lissées de façon usuelle
 - ▶ Pas vers l'uniforme
- ▶ Donc choisir la validation croisée par MC
 - ▶ permet de trier les régresseurs pertinents et non.

Sommaire

Estimation de fonction de densité et probabilité

Régression

Modèles semiparamétriques

LOESS

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC

Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Cas bivarié

- ▶ Cet estimateur de régression est connu aussi sous le nom “Nadaraya–Watson”
 - ▶ de ceux qui l’ont proposé
- ▶ On ne prend qu’un régresseur pour commencer
 - ▶ par simplicité de notation

Moyenne conditionnelle $\hat{g}(x)$

- ▶ Par définition, la moyenne conditionnelle de Y continue est

$$g(x) = \int yg(y|x) dy = \int y \frac{f(y, x)}{f(x)} dy = \frac{m(x)}{f(x)}$$

- ▶ $g(y|x)$ est la densité conditionnelle de la section précédente
- ▶ $m(x) = \int yf(y, x) dy$ une moyenne "partielle"
- ▶ L'estimateur Kernel Local Constant KLC
 - ▶ est celui défini à la section précédente

$$\hat{g}(x) = \int y \frac{\hat{f}(y, x)}{\hat{f}(x)} dy = \frac{\sum_{i=1}^n y_i K\left(\frac{x_i - x}{h}\right)}{\sum_{i=1}^n K\left(\frac{x_i - x}{h}\right)}$$

- ▶ c'est un estimateur consistant de la moyenne conditionnelle

Biais et variance

- ▶ L'estimateur Kernel Local Constant KLC
 - ▶ souffre de "biais sur les bords"
 - ▶ p.e. on peut calculer dans le cas bivarié que

$$\text{biais} \approx h^2 \left(\frac{1}{2} g''(x) + \frac{g'(x) f'(x)}{f(x)} \right) \kappa_2$$

- ▶ Quand on approche du "bord" des données
 - ▶ $f(x) \rightarrow 0$ donc le biais augmente
 - ▶ Ce problème n'est pas partagé par l'estimateur "polynome local" de la section suivante car le 2^o terme à l'intérieur de la parenthèse disparaît dans le cas linéaire

Bandwidths : optimale et basée sur données

- ▶ La bandwidth optimale de l'estimateur KLC
 - ▶ dépend de quantités inconnues, comme précédemment
 - ▶ Elle ne peut être calculée dans le cas de régression
 - ▶ On va donc utiliser une bandwidth basée sur les données
- ▶ Deux calculs de bandwidth basés sur les données
 - ▶ Sont populaires
 - ▶ Validation croisée moindres carrés (cfr section précédente)
 - ▶ Minimiser le critère d'information d'Akaike (Hurvich)
 - ▶ On a montré qu'ils sont asymptotiquement équivalents

Régresseurs pertinents et non-pertinents

- ▶ Il a été montré (cfr sect. densité cond.) que
 - ▶ la validation croisée par MC
 - ▶ mène à un lissage optimal des 2 types de régresseurs
 - ▶ Les non-pertinents n'ont plus d'effet sur la variance de l'estimateur
- ▶ La malédiction de la dimensionalité
 - ▶ implique que les non-pertinents doivent être retirés de la régression
 - ▶ afin de réduire le bruit autour des pertinents

Effets marginaux avec KLC “ $\hat{\beta}(x)$ ”

- ▶ On appelle “effet marginal” ou “réponse”
 - ▶ L’effet de x sur $g(x) = \int yg(y|x) dy$
 - ▶ donc sur la moyenne conditionnelle de y
 - ▶ Par analogie avec le modèle de régression linéaire $y = x\beta + \epsilon$
 - ▶ on appelle cette réponse $\beta(x)$
- ▶
$$\beta(x) = \frac{\partial g(x)}{\partial x} = \frac{f(x)m'(x) - m(x)f'(x)}{f^2(x)}$$
 - ▶ puisque $g(x) = \frac{m(x)}{f(x)}$
 - ▶ donc $\beta(x) = \frac{m'(x)}{f(x)} - g(x) \frac{f'(x)}{f(x)}$
- ▶ On remplace par les estimations de ces valeurs

Effets marginaux avec KLC “ $\hat{\beta}(x)$ ”

$$\hat{\beta}(x) = \frac{\hat{m}'(x)}{\hat{f}(x)} - \hat{g}(x) \frac{\hat{f}'(x)}{\hat{f}(x)} \text{ avec}$$

$\hat{m}(x) = \frac{1}{nh} \sum_{i=1}^n y_i K\left(\frac{x_i - x}{h}\right)$	$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x_i - x}{h}\right)$
$\hat{m}'(x) = -\frac{1}{nh^2} \sum_{i=1}^n y_i K'\left(\frac{x_i - x}{h}\right)$	$\hat{f}'(x) = -\frac{1}{nh^2} \sum_{i=1}^n K'\left(\frac{x_i - x}{h}\right)$

- ▶ L'effet marginal n'est jamais constant \leftrightarrow régression linéaire
 - ▶ On verra mieux dans les exemples
- ▶ En multivarié (plusieurs régresseurs)
 - ▶ C'est plus compliqué, mais le fond est le même

Conclusion sur Kernel Local Constant

- ▶ On a donc un estimateur de **régression** np
 - ▶ à Validation croisée moindres carrés
 - ▶ qui fait que
 - ▶ les régresseurs non-pertinents disparaissent d'eux mêmes
 - ▶ on peut calculer les effets marginaux $\hat{\beta}(x)$
- ▶ On va voir un autre estimateur

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC

Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Analogie

- ▶ Le KLC peut être réécrit comme minimisation de

$$\hat{g}(x) \equiv \min_a \sum_{i=1}^n (y_i - a) K\left(\frac{x_i - x}{h}\right)$$

- ▶ On généralise en mettant un polynôme à la place de a
 - ▶ Le plus populaire est le linéaire

$$\hat{g}(x) \equiv \min_{a,b} \sum_{i=1}^n (y_i - a - b(x_i - x))^2 K\left(\frac{x_i - x}{h}\right)$$

qui s'interprète en disant qu'autour d'un point x_0 , la régression est approx. linéaire

$$g(x_0) \approx a + b(x_0 - x)$$

- ▶ C'est l'estimateur Kernel Local Polynomial (ou Linéaire)
 - ▶ KLP ou KLL

Propriétés

- ▶ Le terme a est alors la moyenne conditionnelle $g(x)$
 - ▶ Comme l'intercept dans une régression linéaire
- ▶ Le terme b est la pente,
 - ▶ donc l'effet d'un changement marginal de x sur $g(x)$
 - ▶ c'est-à-dire le $\hat{\beta}(x)$ de l'estimateur KLC
- ▶ Cet estimateur KLP souffre moins du "biais de bord" que KLC
 - ▶ mais est sujet à des problème de singularité
 - ▶ = n'est pas défini
 - ▶ lorsqu'il y a localement peu de données
- ▶ On peut calculer des biais et variances approximés
 - ▶ comme avec KLC
- ▶ Les régresseurs non-pertinents
 - ▶ ne disparaissent pas d'eux-mêmes
 - ▶ ne sont pas "smoothed-out" comme avec KLC
 - ▶ provoquent une variabilité excessive

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Ex 1. Régression sur données simulées ##### Repr. sim.

- ▶ Génération des données
 - ▶ `n <- 50` Ech de taille 50
 - ▶ `x <- sort(runif(n))` runif : suffixe r pour données sim, unif pour uniforme
 - ▶ `x.seq <- seq(0,1,length=1000)` séquence de 1000 chiffres de 0 à 1, servira à faire des graphes
 - ▶ `y <- sin(2*pi*x) + rnorm(n,sd=0.25)` valeurs simulées de y

Ex 1. Régression sur données simulées ##### Repr. sim.

- ▶ Régressions np
 - ▶ Calcul des bandwidths
 - ▶ `bw.lc <- npregbw(y~x,regtype="lc")` $y \sim x$, kernel local constant
 - ▶ `bw.ll <- npregbw(y~x,regtype="ll")` idem, kernel local linéaire
 - ▶ Commande `npreg`
 - ▶ `model.lc <- npreg(bws=bw.lc,gradient=TRUE)` il faut donner la bandwidth
 - ▶ les points de données sont appelés "training points"
 - ▶ `gradient = true` indique que les gradients (donc les pentes, les betas) sont stockés dans un objet "npregression"
 - ▶ `summary(model.lc)` la sortie, assez fruste, pas de coef estimé par définition

Ex 1. Régression sur données simulées

- ▶ Premières sorties graphiques
 - ▶ `plot(x,y,cex=0.2)` les données
 - ▶ `lines(x.seq,sin(2*pi*x.seq),col="black",lty=1)` les y sans erreur (bruit)
 - ▶ `lines(x,sin(2*pi*x),col="red",lty=1)` idem mais sur les n=50 points de l'éch.
 - ▶ `lines(x,fitted(model.lc),col="red",lty=2)` y ajustés avec lc, `fitted(model.ll)`
 - ▶ $\hat{g}(x)$ = estimation de l'espérance cond. de $y|x$
 - ▶ "biais de bord"
 - ▶ `lines(x,fitted(model.ll),col="blue",lty=3)` y ajustés avec ll - assez proche
 - ▶ pls comparaisons avec moindres carrés
- ▶ Exercice. Répétez le programme en changeant
 - ▶ la taille d'éch. à 100
 - ▶ la façon de générer y
 - ▶ p.e. comme la somme ou le ratio de 2 normales pour avoir une dist. bimodale

Ex 1. Régression sur données simulées

- ▶ Deuxième sortie graphique
 - ▶ gradient $\hat{\beta}(x) = \frac{\partial \hat{g}(x)}{\partial x}$ en fonction de x : non-linéaire
 - ▶

```
plot(x,2*pi*cos(2*pi*x),ylab="dy/dx",col="black",type="l",lty=1)
```


 $\beta(x)$ "réel" dy/dx
 - ▶

```
lines(x,gradients(model.lc)[,1],col="red",lty=2)
```

 $\hat{\beta}(x)$ estimé par lc
 - ▶

```
lines(x,gradients(model.ll)[,1],col="blue",lty=3)
```

 $\hat{\beta}(x)$ estimé par ll
- ▶ Exercice : gradient MCO du MRL bien spécifié $\text{lm}(y \sim \sin(2\pi x))$ et du quadratique $\text{lm}(y \sim x + I(x^2))$

Ex 1. Régression sur données simulées

- ▶ Troisième sortie graphique : Effet de la bandwidth
 - ▶ `bw.lc$bw[1] <- 1e05` Change la bandwidth : bcp trop grande
 - ▶ `bw.ll$bw[1] <- 1e05`
 - ▶ `model.lc <- npreg(bws=bw.lc,gradient=TRUE)` Recalculer les régressions à p. de ces bandwidths
 - ▶ `model.ll <- npreg(bws=bw.ll,gradient=TRUE)`
 - ▶ Graphique
 - ▶ `plot(x,y,cex=0.2)` Les données
 - ▶ `lines(x.seq,sin(2*pi*x.seq),col="black",lty=1)` les y sans erreurs
 - ▶ `lines(x,fitted(model.lc),col="red",lty=2)` valeurs ajustées : droite plate
 - ▶ `lines(x,fitted(model.ll),col="blue",lty=3)` valeurs ajustées : droite pente nég.
- ▶ On voit pourquoi on appelle aussi les régressions np "scatterplot smoothing"
 - ▶ Elles aident à voir les relations entre variables

Ex. Comparaison de méthodes de choix de Bandwidth

- ▶ ##### 3.2.3.b Repr. bandwidth (data Prestige du pack. car)
- ▶ 5 bandwidths
 - ▶ 1 plug-in du package KernSmooth
 - ▶ Avec la commande `locpoly` de régression `np` de ce package
 - ▶ Pour les 4 autres, commande `npregbw` du package `np`
 - ▶ servant à optimiser la bandwidth
 - ▶ 2 arbitraires à partir du package `np` sans optimiser, avec Local Linear
 - ▶ On prend un chiffre en lien avec la mesure du régresseur
 - ▶ On divise : “undersmoothed bandwidth” trop fine → ajustement trop collé aux données
 - ▶ On multiplie “oversmoothed badnwidth” trop large → faible ajustement
 - ▶ 2 optimales selon package `np`, avec cross-validation : Moindres carrés et AIC
 - ▶ Ce sont les 2 cross-validations fournies par le package
- ▶ Plot en 4 tableaux
 - ▶ Regroupe les 2 cv

Ex. Comparaison de méthodes de choix de Bandwidth

- ▶ Exercice
 - ▶ Séparer le plot des 2 cv en 2 et supprimer le plug-in
 - ▶ Changer les 2 bw arbitraires under et over pour les rapprocher
 - ▶ Comparer avec lc au lieu de ll

Et le t ?

- ▶ Comment voit-on la significativité de l'effet marginal ?
- ▶ Les graphes mettent des intervalles de confiance
 - ▶ On va voir ça dans le prochain exemple
- ▶ La section suivante "Test d'hypothèse consistant"
 - ▶ présente des tests formels (non graphiques)

Ex. Multivariate Mixed-Data Application

- ▶ ##### 3.2.3.c Ex. regr. mixte (cont. & cat) Part 1
 - ▶ D'abord un graphique exploratoire
 - ▶ Graphique en 3D et en perspective
 - ▶ `npudensbw(~lwage+ordered(numdep),data=wage1)` calcule la bandwidth pour une bivariee (les 2 var sont a D du ~)
 - ▶ Pq ordered? pcq + loin on utilise pour le graphique, il faut que les natures des variables restent les mêmes

Ex. Multivariate Mixed-Data Application

- ▶ ##### 3.2.3.c Ex. regr. mixte (cont. & cat) Part 2
 - ▶ On calcule une bandwidth pour la régression de lwage sur female, married, educ, exper, tenure
 - ▶ Pas besoin de exper^2 c'est la régression qui regarde la relation
 - ▶ La bandwidth diffère par régresseur
 - ▶ Graphique de la moyenne conditionnelle de y à chaque niveau du régresseur
 - ▶ On voit les effets "classiques" : salaire plus bas pour les femmes, rendement décroissant de l'exp. (plus prononcé que d'habitude à cause de tenure sans doute)
 - ▶ Constater graphiquement que la significativité n'est pas constante puisque l'intervalle de confiance évolue selon x
 - ▶ Graphique du gradient
 - ▶ Évolution du "coefficient" $\hat{\beta}(x)$ en fonction du x
 - ▶ Avec son intervalle de confiance graphique

Exercice

- ▶ Répliquer en changeant la CV ou le kernel (LC au lieu de LL)
- ▶ Répliquer avec les données `bwages` du package `Ecdat`

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Intro

- ▶ On ne revient pas sur les tests np de la 1^o partie du cours
 - ▶ il s'agit de tests en contexte de régression
- ▶ Soit tester une spécification paramétrique
 - ▶ Permet de justifier une approche np
- ▶ Soit tester la significativité des régresseurs d'une régression np
 - ▶ l'équivalent des t-stats
 - ▶ Un régresseur parmi pls
 - ▶ On n'a pas d'équivalent au test F

Un test de significativité pour des régressions np

- ▶ Il y a pls approches
 - ▶ On prend ici celle de Racine qui accepte des régresseurs continus & cat.
- ▶ On va regarder d'abord cat.
 - ▶ puis continu

Un test de significativité : régresseurs catégoriques

- ▶ Soit
 - ▶ z le régr. cat qui peut être non-pertinent
 - ▶ X tous les autres régresseurs
 - ▶ L'hyp. nulle est

$$H_0 : E(Y|X, z) = E(Y|X)$$

presque partout

L'alternative est que l'égalité est en fait \neq (2-tailed)

- ▶ Pour simplifier on écrit
 - ▶ $g(x) = E(Y|x)$ et $m(x, z) = E(Y|X, z)$
 - ▶ disons que z prend c valeurs dont la 1^o est zéro
 - ▶ si $c = 2$, z est une dichotomique, le cas le + fréquent
 - ▶ H_0 peut alors s'écrire $m(x, z = 1) = m(x, z = 0) \forall x$

Un test de significativité : régresseurs catégoriques

- ▶ La stat de test est un estimateur de

$$I = \sum_{l=1}^{c-1} E \left\{ [m(x, z = l) - m(x, z = 0)]^2 \right\}$$

- ▶ Pour la calculer
 - ▶ On prend les valeurs estimées par KLC ou KLL de m
 - ▶ On somme sur toutes les $l \neq 0$
 - ▶ et sur toutes les obs.
 - ▶ On voit bien que $I \geq 0$
 - ▶ et que z est non signif. si I est proche de zéro
- ▶ Il n'y a pas de distribution connue
 - ▶ Il faut faire du bootstrap
 - ▶ Mis en oeuvre dans `npsigtest()`
 - ▶ On verra dans l'exemple

Un test de significativité : régresseurs continus

- ▶ H_0 est la même,
 - ▶ mais “presque partout”
 - ▶ car on a en quelque sorte ∞ catégories
 - ▶ Équivalent à $\frac{\partial E(y|x, z)}{\partial z} = \beta(z) = 0$ presque partout
- ▶ La stat de test est un estimateur de $I = E\left\{[\beta(z)]^2\right\}$
 - ▶ On calcule son estimation KLC ou KLL $I_n = \frac{1}{n} \sum_{i=1}^n \hat{\beta}(z_i)^2$
 - ▶ Comme dans le cas catégorique, la distribution de I_n est inconnue
 - ▶ On utilise bootstrap

Ex. Regression mixte (cont & cat.)

- ▶ On poursuit l'exemple précédent – part 3
 - ▶ ##### 3.2.3.c Ex. regr. mixte (cont. & cat)
 - ▶ # Part 3 Tests de significativité
 - ▶ On avait estimé
 - ▶ `bw.all <- npregbw(formula=lwage~factor(female)+factor(married)+educ+exper+tenure, regtype="ll", bwmethod="cv.aic", data=wage1)`
 - ▶ En pratique, le test est simple
 - ▶ on passe l'objet bandwidth de la régression associée
 - ▶ Par contre le temps de calcul est plus long
- ▶ Le package
 - ▶ distingue le cat et le cont
 - ▶ fait le test adéquat
- ▶ Pas de test sur plusieurs coef conjointement

Tester une spécification paramétrique

- ▶ On veut tester si un modèle **param.** est correct

$$H_0 : E(Y|x) = m(x, \gamma_0)$$

pour presque tous les x

pour un certain γ_0 vecteur $(p \times 1)$ de paramètres

et $m(x, \gamma)$ une fonction connue (possiblement non-linéaire)

- ▶ En définissant

$$\mu_i = y_i - m(x_i, \gamma_0)$$

alors on peut écrire

$$H_0 : E(\mu_i|x_i) = 0$$

pour presque toutes les valeurs possibles de x

- ▶ Fondamentalement : les résidus μ_i ne devraient pas dépendre des x_i

Tester une spécification paramétrique

- ▶ Un test consistant de spécification du modèle paramétrique peut être construit
 - ▶ sur la base des résidus du modèle paramétrique
$$\hat{\mu}_i = y_i - m(x_i, \hat{\gamma})$$
 - ▶ en estimant $E(\mu_i|x_i)$ de manière non-paramétrique
 - ▶ au moyen d'une technique de bootstrap
- ▶ La stat calculée se nomme J_n
 - ▶ Mis en oeuvre dans `npcmstest()`
 - ▶ Il faut d'abord estimer soit un `lm` soit un `glm`
 - ▶ le `y` doit être continu, donc pas `probit`, `logit`, `Poisson`
 - ▶ en précisant les arguments `x=TRUE`, `y=TRUE` qui font que `x` et `y` vont être stockés dans l'objet résultat
 - ▶ Ensuite il faut stocker les `x` dans un dataframe
 - ▶ `npcmstest` prend comme arg l'objet résultat du modèle param., le `x` et le `y`
 - ▶ On peut employer `summary` sur `npcmstest`
 - ▶ Si on $R H_0$, le modèle param est mal spécifié

Ex. Tester une spécification paramétrique

- ▶ On poursuit l'exemple précédent – part 4
 - ▶ ### 3.2.3.c Ex. regr. mixte (cont. & cat)
 - ▶ # Part 4. Test de spécification param.
 - ▶ On prend un modèle linéaire classique du modèle np qu'on a estimé auparavant

$$l\text{wage} = \beta_0 + \beta_1 \text{Femme} + \beta_2 \text{Marié} + \beta_3 \text{Educ} + \beta_4 \text{Exp} + \beta_5 \text{Tenure}$$

Rem. Tenure = durée dans l'emploi actuel

- ▶ Ici, on obtient une p-valeur <5% largement
 - ▶ R le modèle linéaire
- ▶ Exercice
 - ▶ Refaites le test en ajoutant l'exp. quadratique

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Qualité de l'ajustement (Goodness-of-Fit)

- ▶ Essentiellement, une mesure de R^2 en np

$$R^2 = \frac{[\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{y})]^2}{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{y})^2}$$

\hat{y}_i est la valeur ajustée de y_i

- ▶ donc $\hat{g}(x_i)$
- ▶ $0 \leq R^2 \leq 1$
 - ▶ 1 est un ajustement parfait
 - ▶ 0 aucun pouvoir prédictif au-delà de la moyenne inconditionnelle
 - ▶ Cette mesure est un des produits de la commande `npreg`
 - ▶ accessible par `R2` et `summary`
- ▶ Dans le cas d'un modèle linéaire
 - ▶ estimé par MCO avec un intercept
 - ▶ Cette définition du R^2 produit le même chiffre que la définition classique
 - ▶ basée sur les résidus

Régression np – **résumé** de l'approche kernel

- ▶ D'abord il faut calculer une bw
 - ▶ `bw.all<- npregbw`
 - ▶ on peut préciser ici LL ou LC & la cross-validation
- ▶ Ensuite la régression
 - ▶ `model.np <- npreg(bws=bw.all)`
 - ▶ `summary(model.np)` présente la qualité de l'ajustement "R-squared"
 - ▶ À ce stade on peut "plot"
 - ▶ avec les marges d'erreur
- ▶ Puis les tests
 - ▶ Significativité des régresseurs
 - ▶ Spécification paramétrique
 - ▶ Si celle-ci n'est pas rejetée, mieux vaut l'utiliser, car + efficiente

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Rappel

- ▶ Un panel est une coupe transversale répétée dans le temps t
 - ▶ en principe sur les mêmes i
 - ▶ sauf attrition, qu'on suppose non-endogène
 - ▶ Pour simplifier tous les i sont observés T fois
 - ▶ Je ne suis pas sûr que tous les modèles aient été développés pour des panels non-cylindrés
- ▶ Lorsque T est grand
 - ▶ chaque série de i peut être analysée séparément en séries temp.
 - ▶ qu'on ne voit pas pour np
- ▶ Donc, on se place en panels courts : $n \rightarrow \infty$ mais T cst
- ▶ Les données de panel sont notées $\langle y_{it}, x_{it} \rangle$

Panels non-paramétriques

- ▶ Dans le modèle panel linéaire

$$y_{it} = \alpha_i + x'_{it}\beta + \epsilon_{it}$$

on pouvait accepter que

- ▶ α_i soit la partie constante dans le temps, par i , du terme d'erreur
 - ▶ qu'elle soit corrélée avec x_{it} (les "effets fixes")
 - ▶ car on pouvait s'en débarrasser par les estimateurs within ou différence 1^o
- ▶ Cette hyp. d'additivité de l'hétérogénéité inobservée
 - ▶ Fait disparaître les régresseurs constants dans le temps
- ▶ En np, on n'a pas d'hyp. d'additivité
 - ▶ Une série d'estimateurs a été proposée

Panel dans np

- ▶ Le package np propose l'estimateur suivant
- ▶ Soit le modèle np

$$y_{it} = g(x_{it}) + u_{it}$$

$g(\cdot)$ est une fonction lisse inconnue

x contient q régresseurs

$E(u_{it} | x_{i1}, \dots, x_{iT}) = 0$ exogénéité stricte

- ▶ On introduit l'hétérogénéité inobservée constante dans le temps
 - ▶ par une variable discrète non-ordonnée

$$\delta_i = i, i = 1, \dots, n$$

ce qui introduit de fait n catégories qui ressemblent au α_i du model panel

- ▶ $x_{it} \rightarrow (z_{it}, \delta_i)$
- ▶ Ces cat nous rapprochent du contexte de la régression np
 - ▶ avec un mélange de régresseurs cat. et continus

Panel dans np

- ▶ Le paramètre de bandwidth λ pour les catégoriques
 - ▶ est limité à $[0,1]$ par construction dans le package np
- ▶ Si $\hat{\lambda}$, la bandwidth estimée est proche de
 - ▶ 1 alors $g(z_{it}, \delta_i) = g(z_{it})$
 - ▶ δ_i est “smoothed out” : son influence est gommée
 - ▶ Les données peuvent être vues comme une grande coupe transversale
 - ▶ 0 alors $g(z_{it}, \delta_i) = g_i(z_{it})$
 - ▶ Le modèle estime chaque $g_i(\cdot)$ en utilisant seulement la série temporelle de chaque i
 - ▶ entre 0 et 1, on est peut-être dans un cas proche aux panel plus standards
 - ▶ une partie propre à i ,
 - ▶ une partie “mélangeable” : les i peuvent être utilisés ensemble pour estimer des pentes communes






Panel dans np : test

- ▶ Si le “régresseur” δ catégorique n'est pas significatif
 - ▶ $g(z_{it}, \delta_i) = g(z_{it})$: Les données sont de fait mélangées
 - ▶ Pas de diff entre i
 - ▶ `npsigtest()` permet ce test (toujours le même)
- ▶ Par contre, s'il est significatif
 - ▶ Les pentes par i sont différentes $g(z_{it}, \delta_i) = g_i(z_{it})$
 - ▶ Donc les données de différents i ne sont pas mélangeables
- ▶ L'analyse Panel n'est donc pas complètement implémentée dans np
 - ▶ Car l'endogénéité ne paraît pas traitée / éliminée comme avec effets fixes
 - ▶ mais np apporte un complément d'analyse

Ex. Panel dans np

- ▶ ##### Ex. regr. panel
- ▶ Panel annuel sur les coûts de 6 cies aériennes US
 - ▶ 15 ans 1970 à 1984 (cylindré)
 - ▶ airline i traité comme factor non-ordonné
 - ▶ year t factor ordonné
 - ▶ log of cost lcost, log output (passagers \times miles), log prix fuel lpf, "load factor" lf capacité utilisée moyenne de la flotte
- ▶ BW : petite pour "airline"
 - ▶ suggère de ne pas mélanger les données
 - ▶ Donc de faire pls séries temp
 - ▶ `npsigtest` semble produire des résultats aberrants (significativité extrême)
 - ▶ Mais il faudrait un test qui tienne compte de la structure d'hétéroc. & de corrél.
- ▶ Dans le plot diapo suivante
 - ▶ On voit un effet marqué par airline ($\approx \alpha_i$)
 - ▶ et des pentes plutôt linéaires
 - ▶ au total, plutôt favorable au modèle param. linéaire classique ?

Panel dans np – exemple



Exercice

- ▶ Répliquer en utilisant les données Grunfeld du package plm
 - ▶ En changeant CV ou kernel (LC / LL)

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Régressions np

- ▶ On part d'un histogramme lissé par un kernel
 - ▶ Estimateur de la fct de densité d'un va continue
 - ▶ Importance du bandwidth
 - ▶ Dans quel rayon autour de x_0 compte-t-on ?
 - ▶ Minimiser la Integrated MSE - par LS Cross-validation
 - ▶ Par contre le Kernel optimal est à peu près toujours Gaussien
- ▶ Généralisation à
 - ▶ v.a. catégorique
 - ▶ v.a. multivariée
 - ▶ Malédiction de la dimensionalité

Régressions np

- ▶ Ces éléments permettent de
 - ▶ calculer un estimateur kernel de la densité conditionnelle
 - ▶ Une régression est l'espérance de la densité conditionnelle
 - ▶ conditionnée sur un ou pls régresseurs
 - ▶ Estimateur kernel local constant
 - ▶ ou local linéaire
- ▶ L'effet marginal $\partial E(y|x) / \partial x$
 - ▶ dépend des niveaux des x et de y

Régressions np

- ▶ On peut tester la significativité d'un régresseur
 - ▶ Calculer l'équivalent d'un R^2
 - ▶ Tester une spécification param. avec les même régresseurs
 - ▶ Si on ne la rejette pas, la préférer car + efficiente
- ▶ Il existe une version panel
 - ▶ Resterait à évoquer l'endogénéité
 - ▶ Les séries temp.
 - ▶ La théorie existe, mais moins des packages

Devoir # 3 : Régressions

1. **3.1.1 Graphes** Effet de la bandwidth dans un histogramme
 - ▶ Ajuster le nombre d'intervalles
2. **3.1.1 Graphes** Récupérer les données CPS1988 du package AER
 - ▶ Essayer de trouver la meilleure représentation en 1D et 2D en changeant la bandwidth et/ou le kernel
3. **3.2.3.a Reagr. sim.** Gradient MCO du MRL bien spécifié $lm(y \sin(2 * pi * x))$ et du quadratique $lm(y x + I(x^2))$
 - ▶ Comparer avec le gradient de la régression np
4. **3.2.3.c Ex. regr. mixte (cont. & cat) Part 2**
 - ▶ Répliquer avec les données `bwages` du package `Ecdat`
5. **3.2.3.c Ex. regr. mixte (cont. & cat) Part 4** Tester une spécification paramétrique
 - ▶ Refaites le test en ajoutant l'exp. quadratique

Récapitulatif devoirs np

- ▶ Devoir # 1 : tests np
- ▶ Devoir # 2 : bootstrap
- ▶ Devoir # 3 : régression np

Sommaire

Estimation de fonction de densité et probabilité

Régression

Modèles semiparamétriques

LOESS

Méthodes semi-paramétriques sp

- ▶ Assez populaires
- ▶ Combinent des éléments des 2 approches
 - ▶ Compromis
 - ▶ S'appuient sur des paramètres
 - ▶ Donc inconsistant en cas de fausse spécification
- ▶ Utiles lorsque
 - ▶ La malédiction de la dimensionalité fait que le np ne fonctionne pas bien
 - ▶ On veut utiliser un modèle paramétrique pour seulement une partie des régresseurs
 - ▶ ...
- ▶ Pas une méthode
 - ▶ plutôt un cahier de recettes propres à des cas particuliers

4 cas sp implémentés dans le package np

- ▶ Extensions du modèle linéaire
 - ▶ Modèles partiellement linéaires
 - ▶ Les splines sont un autre cas partiellement linéaire
 - ▶ Coefficients aléatoires
- ▶ Modèles à index unique
 - ▶ y dichotomique
 - ▶ y continu

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC

Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Modèle partiellement linéaire

- ▶ Modèle d'apparence simple
 - ▶ Mais le calcul de bandwidth le rend assez lourd
 - ▶ Bien plus qu'un modèle paramétrique
 - ▶ Du moins quand on base la bandwidth sur les données
- ▶ Un modèle sp linéaire

$$y_i = x_i' \beta + g(z_i) + u_i$$

x et β ont la signification habituelle avec p régresseurs

- ▶ u n'est pas corrélée avec x ou z
 - ▶ mais peut être hétéroscédastique
- ▶ z comprend q régresseurs
- ▶ $g()$ n'est pas spécifiée
- ▶ L'important est d'obtenir un estimateur consistant de β
 - ▶ Puisque quand on l'a, $g()$ est estimée par régression np de $y - x\hat{\beta}$ sur $g(x)$

Estimation de β

- ▶ Dans le modèle sp linéaire

$$y_i = x_i' \beta + g(z_i) + u_i$$

on prend l'espérance conditionnelle à z

$$E(y_i|z_i) = E(x_i|z_i)' \beta + g(z_i)$$

en soustrayant les 2 :

$$y_i - E(y_i|z_i) = (x_i - E(x_i|z_i))' \beta + u_i$$

- ▶ On ne connaît ni $E(y_i|z_i)$ ni $E(x_i|z_i)$
 - ▶ Mais on peut les estimer par regr. np de façon consistante
 - ▶ Régression car espérance conditionnelle

Estimation de β

- ▶ Soit $\hat{E}(y_i|z_i)$ et $\hat{E}(x_i|z_i)$ ces estimations
- ▶ On écrit

$$\tilde{y}_i = y_i - \hat{E}(y_i|z_i) \text{ et } \tilde{x}_i = x_i - \hat{E}(x_i|z_i)$$

alors

$$\hat{\beta}_{p.linéaire} = [\tilde{X}'\tilde{X}]^{-1} \tilde{X}'\tilde{Y}$$

- ▶ À présent, on réécrit le modèle sp linéaire

$$y_i - x_i' \hat{\beta}_{p.lin} = g(z_i) + \epsilon_i$$

où le u_i devient un ϵ_i

- ▶ pour souligner qu'au lieu de β , on utilise $\hat{\beta}_{p.lin}$
- ▶ Ce modèle est alors estimé par la technique np habituelle
 - ▶ Mais il est d'un intérêt limité puisque que c'est la partie linéaire qui nous intéresse

Ex. Modèle partiellement linéaire

- ▶ Données Wage 1
 - ▶ Comme précédemment
 - ▶ ### Modele partiellement lineaire
 - ▶ Commande principale
 - ▶ `nplregbw` pour la bw
 - ▶ `nplregbw(formula=lwage~factor(female)+ factor(married)+ educ+ tenure|exper, data=wage1)`
 - ▶ la partie non linéaire va après le | dans la formula
 - ▶ `nplreg(bw)` pour la régression
 - ▶ Bug pour le plot ?
 - ▶ Les t-stats ?
 - ▶ `npsigtest` ne fonctionne pas pour ce cas
 - ▶ mais on peut extraire des `ec.types` pour la partie linéaire
 - ▶ et donc calculer des t-stats pour cette partie
 - ▶ mais on reste sans savoir si la partie $g(z_i)$ est significative

Exercice Modèle partiellement linéaire

- ▶ Au lieu de exper, traiter educ comme non-linéaire
 - ▶ Exper en quadratique
- ▶ Traiter educ et exper comme non-linéaires

Modèle à coefficients aléatoires

- ▶ Coefficients “lissés” ou “variables”

$$\left\{ \begin{array}{l} y_i = \alpha(z_i) + x_i' \beta(z_i) + u_i \\ 1 @ \quad 1 @ @ 1 @ \quad 1 @ \quad = \left(1 + x_i' \right) \begin{pmatrix} \alpha(z_i) \\ \beta(z_i) \end{pmatrix} + u_i \\ \quad \quad \quad \quad \quad \quad = w_i' \gamma(z_i) + u_i \end{array} \right.$$

- ▶ en mots : les coef α et β sont des fonctions de z
 - ▶ non-spécifiées & lisses
 - ▶ comme ça, on va pouvoir les estimer par np
- ▶ Pourquoi choisir certaines variables comme z ?
 - ▶ P.e. des pentes différentes selon certains niveaux de factors
 - ▶ Les rendements de l'éduc, de l'exp dépendent-ils de si on est marié ? p.e.

Modèle à coefficients aléatoires

- ▶ Prémultiplier par w_i
 - ▶ et prendre l'espérance conditionnelle à z_i

$$E [w_i y_i | z_i] = E [w_i w_i' | z_i] \gamma (z_i) + E [w_i u_i | z_i]$$

$\gamma (z_i)$ sort de l'espérance car il est déjà conditionnel à z_i

- ▶ On se retrouve dans une situation proche du modèle partiellement linéaire
 - ▶ On peut exprimer $\gamma (z_i)$ comme dans MCO

$$\gamma (z_i) = \left(E [w_i w_i' | z_i] \right)^{-1} E [w_i y_i | z_i]$$

- ▶ Les espérances conditionnelles sur z_i peuvent être estimées par np
 - ▶ En utilisant l'ensemble de l'échantillon, pas L à L

Ex. Modèle à coefficients aléatoires

- ▶ Données Wage 1
- ▶ ### Modèle à coefficients aléatoires
 - ▶ Commande principale
 - ▶ `npscoefbw` pour la `bw`
 - ▶ `npscoefbw(formula=lwage~ educ+ tenure+ exper+ exersq|factor(female)+factor(married))`
 - ▶ Les `z` sont spécifiés après la `|`
 - ▶ `npscoef(bw,betas=TRUE)` pour les coef
 - ▶ Assez peu d'output
 - ▶ Comment interpréter les moyennes des coef aléatoires ?
- ▶ Exercice
 - ▶ Essayer de calculer les t-stats (sans garantie)

Sommaire

Estimation de fonction de densité et probabilité

Choisir la bandwidth

Estimation d'une densité
conditionnelle

Régression

Kernel Local Constant KLC
Kernel Local Polynomial KLL

Exemples

Tests d'hypothèses

Qualité de l'ajustement

Modèles à données de panel

Résumé

Modèles semiparamétriques

Extensions du modèle linéaire

Modèles à index unique

LOESS

Index unique / "Single index"

- ▶ Modèles de forme

$$y_i = g \left(X_i' \beta \right) + u_i$$

où les notations sont celles du MRL

avec q régresseurs

et $E(u_i | X_i) = 0$

- ▶ $X_i' \beta$ est une forme linéaire (= un index)
 - ▶ dont on ne connaît pas les paramètres β
- ▶ Lorsque $g(\cdot)$ est
 - ▶ identité : MRL
 - ▶ La fonction de probabilité Logistique ou normale : Logit / probit

Single index semi-paramétriques

- ▶ On a un modèle semi-paramétrique lorsque
 - ▶ $g(\cdot)$ est une fonction inconnue, non-spécifiée
 - ▶ “Semi” car paramètres β
 - ▶ inconnus également
- ▶ + flexible que paramétrique
 - ▶ moins susceptible à la malédiction de la dimensionalité
 - ▶ car $x_i' \beta$ est de fait un seul régresseur
 - ▶ On appelle cela une “réduction de la dimensionalité”
 - ▶ Donc convergence + rapide de l'estimation

Identification

- ▶ Avant de pouvoir estimer,
 - ▶ il faut que le modèle soit identifiable
 - ▶ c'est-à-dire qu'il ait la capacité de produire une estimation
 - ▶ et que ce soit de manière unique
- ▶ Plus précisément, si on a ∞ obs.
 - ▶ peut-on théoriquement découvrir les vrais paramètres (ou fonction) du modèle de manière unique ?
- ▶ Ex. 1. le MRL $y = \alpha + X\beta + \epsilon$, $E(\epsilon|x) = 0$ est identifiable
 - ▶ ssi $X'X$ est invertible
- ▶ Ex. 2. Modèle probit $\Pr(\alpha + X\beta + \epsilon < 0)$
 - ▶ Soit $y = 1$ ssi $\alpha + X\beta + \epsilon < 0$, $\epsilon \sim n(0, \sigma^2)$
 - ▶ Comme $(\alpha + X\beta + \epsilon < 0) \iff a(\alpha + X\beta + \epsilon < 0)$, $a > 0$,
 - ▶ il résulte que σ^2 n'est pas identifiable
 - ▶ Probit est partiellement identifiable avec ce type de données

Identification des modèles single-index

- ▶ Le MRL comme Probit sont 2 cas particuliers de single index
 - ▶ On voit donc 2 conditions d'identification
 - ▶ Il faut aussi que $g(\cdot)$ ne soit pas une fonction constante
 - ▶ $g(X\beta) = c \forall X$
- ▶ Soit 2 constantes γ quelconque et $\delta \neq 0$, alors
 - ▶ $E(Y|X = x) = g(x'\beta)$ et
 - ▶ $E(Y|X = x) = g^*(\gamma + \delta x'\beta)$
 - ▶ sont dites "observationnellement équivalentes"
 - ▶ Même si on connaissait la distribution de (Y, X)
 - ▶ On ne pourrait pas distinguer ces 2 modèles (savoir lequel est le bon)
 - ▶ Il faut donc des restrictions additionnelles
 - ▶ pour identifier β et $g(\cdot)$

Identification des modèles single-index

- ▶ La restriction sur γ est appelée **normalisation de localisation**
 - ▶ Le point glisse sur le support
 - ▶ Essentiellement la moyenne
 - ▶ Est obtenue en imposant que X ne contienne pas de constante
 - ▶ (y compris des combinaisons lin. des col. de X)
- ▶ Sur δ : **normalisation d'échelle**
 - ▶ Essentiellement la variance, la dispersion
 - ▶ Est obtenue en imposant qu'un des coef. de β soit égal à un
- ▶ Il faut aussi que
 - ▶ $g()$ soit différentiable (sans preuve)
 - ▶ un au moins des éléments de X soit une variable continue
 - ▶ diapo suivante

Single-index à variables catégoriques uniquement

- ▶ Soit $X = (X_1, X_2)$ à supports $\{0, 1\}$ pour les 2 éléments de X
 - ▶ On normalise le coef de X_1 à 1
 - ▶ Normalisation d'échelle
 - ▶ Le modèle $E(Y|X = x) = g(x' \beta)$ devient
 - ▶ $E(Y|X = x) = g(x_1 + x_2 \beta_2)$
- ▶ Supposons que les données soient t.q.

(x_1, x_2)	$E(Y X = x)$	$g(x_1 + x_2 \beta_2)$
(0, 0)	0	$g(0)$
(1, 0)	0.1	$g(1)$
(0, 1)	0.3	$g(\beta_2)$
(1, 1)	0.4	$g(1 + \beta_2)$

- ▶ Comme on peut choisir à la fois $g(\cdot)$ et β_2
 - ▶ il y a ∞ de solutions : pas identifié

2 cas sont traités dans le package np

- ▶ Ichimura : y est continu
- ▶ Klein & Spady : y est une dichotomique
 - ▶ Intéressant car on n'a pas d'équivalent logit/probit en np

Ichimura : y est continu

- ▶ Si on connaissait $g()$
 - ▶ On pourrait estimer β par Moindres Carrés Non-Linéaires

$$\hat{\beta} \equiv \arg \min_{\beta} \frac{1}{n} \sum_i W_i \left(y_i - g \left(X_i' \beta \right) \right)^2$$

- ▶ W_i est un poids, sur lequel on ne s'attarde pas ici
 - ▶ À cause de la non-linéarité de $g()$:
 - ▶ Il n'y a pas de solution analytique
 - ▶ On n'a que des approches numériques
 - ▶ Mais on ne connaît pas $g()$
 - ▶ Et on ne peut pas appliquer un estimateur Kernel
 - ▶ car on ne connaît pas β
 - ▶ Ichimura propose une modification de MC non-lin.
 - ▶ dans laquelle $g()$ est estimé par un kernel modifié

Ex. Ichimura

- ▶ Même exemple avec wage1 qu'on a déjà utilisé
- ▶ ### 3.3.a Ichimura
- ▶ L'estimateur d'Ichimura est invoqué en 2 étapes comme toujours
 - ▶ `npindexbw` pour la bandwidth
 - ▶ `npindex` pour les coefficients
- ▶ La fonction `g()` n'est pas dans l'output
 - ▶ puisqu'on l'estime de façon np
 - ▶ Les coefficients sont comparables avec un modèle linéaire
 - ▶ au sens où on peut comparer leur impact relatif
 - ▶ Les gradients peuvent être "plot" par la commande usuelle
 - ▶ Mais l'interprétation est difficile, voir le script
- ▶ La méthode est intensive en ordinateur : long
- ▶ Exercice. La commande semble accepter une matrice `vcov` des coefficients, trouver comment estimer des t-stat

Estimateur de Klein & Spady

- ▶ Ici, y est dichotomique
 - ▶ Alors $g(x_i' \beta) = \Pr\{Y = 1 | X = x_i\}$
- ▶ Si $g(\cdot)$ était connue,
 - ▶ alors l'estimation se ferait par max. vraisemblance
 - ▶ Avant de poursuivre, on va faire un rappel sur MV

Maximum de vraisemblance

- ▶ La fonction de densité de probabilité d'une va y
 - ▶ conditionnellement à des paramètres θ
 - ▶ est notée $f(y|\theta)$
- ▶ Si on a un éch. de n obs. iid de cette va
 - ▶ Alors, on peut définir la densité jointe de l'éch. comme le produit des densités de chaque obs.

$$f(y_1, \dots, y_n|\theta) = \prod_{i=1}^n f(y_i|\theta) = L(\theta|y)$$

- ▶ Cette densité jointe est appelée **fonction de vraisemblance (likelihood)**
- ▶ Très souvent, on prend le log

$$\ln L(\theta|y) = \sum_{i=1}^n \ln f(y_i|\theta)$$

Maximum de vraisemblance

- ▶ Il est souvent nécessaire de généraliser pour introduire des régresseurs
- ▶ Soit le MRL $y_i = x_i\beta + \epsilon_i$
 - ▶ On suppose que ϵ est normale
 - ▶ avec moyenne 0 & variance σ^2
 - ▶ Donc $y_i|x_i$ est normale
 - ▶ avec moyenne $\mu_i = x_i\beta$ et variance σ^2
- ▶ Donc, les obs. de la va **ne sont pas iid**
 - ▶ Elles ont des moyennes différentes
 - ▶ Mais elles restent indépendantes
 - ▶ Et on peut les standardiser pour qu'elles aient la même moyenne
 - ▶ Ça donne la fonction de vraisemblance

$$\ln L(\theta|y, X) = \sum \ln f(y_i|x_i, \theta) = -\frac{1}{2} \sum_{i=1}^n \left[\ln \sigma^2 + \ln(2\pi) + (y_i - x_i\beta)^2 / \sigma^2 \right]$$

Maximum de vraisemblance : Probit

- ▶ Le même MRL avec un seul régresseur + 1 cst

$$y_i = \beta_1 + \beta_2 x_i + \epsilon_i$$

où $\epsilon_i | x_i \sim n(0, \sigma^2)$

- ▶ Contexte d'un achat important, p.e. une voiture
 - ▶ x_i est le revenu de i
 - ▶ y_i est la \neq entre la disposition à payer p_i^* , et le prix de la voiture p_i
- ▶ On n'observe pas y_i mais seulement si i achète la voiture ou non
 - ▶ Soit $y_i^* = 1$ lorsque $y_i = p_i^* - p_i > 0$
 - ▶ Et donc $y_i^* = 0$ sinon
 - ▶ (quels sont ces i qu'on "n'observe pas" acheter?)

Maximum de vraisemblance : Probit

- ▶ La proba d'achat est

$$\begin{aligned}\Pr \{y_i^* = 1 | \beta_1, \beta_2, \sigma, x_i\} &= \Pr \{y_i > 0 | \beta_1, \beta_2, \sigma, x_i\} \\ &= \Pr \{\beta_1 + \beta_2 x_i + \epsilon_i > 0 | \beta_1, \beta_2, \sigma, x_i\} \\ &= \Pr \{\epsilon_i > -\beta_1 - \beta_2 x_i | \beta_1, \beta_2, \sigma, x_i\} \\ &= \Pr \{\epsilon_i / \sigma > (-\beta_1 - \beta_2 x_i) / \sigma | \beta_1, \beta_2, \sigma, x_i\} \\ &= \Pr \{z_i > (-\beta_1 - \beta_2 x_i) / \sigma | \beta_1, \beta_2, \sigma, x_i\}\end{aligned}$$

où z_i a une dist. normale standard

- ▶ La proba de ne pas acheter est un moins cette proba

Probit : identification par normalisation

- ▶ Donc la fonction de vraisemblance est

$$\prod_{i=\text{achat}} [\Pr \{ach|\beta_1, \beta_2, \sigma, x_i\}] \times \prod_{i=\text{pas ach}} [1 - \Pr \{ach|\beta_1, \beta_2, \sigma, x_i\}]$$

- ▶ Souvent réécrite comme

$$\prod_i [\Pr \{ach|\beta_1, \beta_2, \sigma, x_i\}^{y_i} [1 - \Pr \{ach|\beta_1, \beta_2, \sigma, x_i\}]^{(1-y_i)}]$$

- ▶ Les paramètres β_1, β_2, σ de ce modèle **ne sont pas identifiés** :
 - ▶ S'ils sont multipliés par une même constante non-nulle
 - ▶ le nouveau modèle est observationnellement équivalent
 - ▶ $\Pr \{ach\}$ et la fct de vrais. ne changent pas
- ▶ La **normalisation** généralement utilisée est $\sigma = 1$

Interprétation

- ▶ Avec une va discrète, $f(y_i|\theta)$ est la proba d'observer y_i conditionnellement à θ
 - ▶ La fct de vraisemblance est la proba d'observer l'éch.
- ▶ On suppose que l'éch. qu'on a est le + probable
 - ▶ Sorte de principe de médiocrité
- ▶ Si on choisit θ de sorte à maximiser la fonction de vraisemblance
 - ▶ alors on max la proba de l'éch.
 - ▶ Ce qui correspond bien à l'hyp de médiocrité

Maximum de vraisemblance : notes

- ▶ Cette maximisation produit l'estimateur max. de vraisemblance
 - ▶ Généralement numériquement + simple de max. la log-vraisemblance
 - ▶ Comme \ln est monotone, c'est le même max
- ▶ La condition de 1^o ordre de la max

$$\partial \ln L(\theta | data) / \partial \theta = 0$$

est appelée équation de vraisemblance

Maximum de vraisemblance : propriétés

- ▶ Si l'hypothèse de distribution est correcte
 - ▶ dans le probit : $\epsilon_i | x_i \sim n(0, \sigma^2)$
 - ▶ Alors MV a de très bonnes propriétés
 - ▶ **Notation** : $\hat{\theta}$ estimateur ; θ_0 vraie valeur ; θ toute autre valeur
- ▶ **Consistance** : $\text{plim } \hat{\theta} = \theta_0$
- ▶ **Normalité asymptotique** : $\hat{\theta} \sim N \left[\theta_0, \{I(\theta_0)\}^{-1} \right]$
 - ▶ $I(\theta_0) = -E \left[\partial^2 \ln L / \partial \theta_0 \partial \theta_0' \right]$ est dite **information matrix**
- ▶ **Asymptotiquement efficient**
 - ▶ $\hat{\theta}$ atteint la borne de Cramer–Rao pour les estimateurs consistants
- ▶ **Invariance** : l'estimateur de $\gamma_0 = c(\theta_0)$ est $c(\hat{\theta})$
 - ▶ si $c(\theta)$ est continue et différentiable
- ▶ MV n'a que des propriétés asymptotiques
 - ▶ En petits éch. il peut être biaisé/inefficient

Retour à Klein & Spady

- ▶ Un estimateur sp pour le cas probit
 - ▶ $g(x_i' \beta) = \Pr \{Y = 1 | X = x_i\}$
- ▶ Si $g()$ était connue,
 - ▶ alors l'estimation se ferait par max. vraisemblance
 - ▶ p.e. probit, on suppose que $g()$ est la probabilité normale, donc

$$\ln L(\beta | y, x) = \sum_i [y_i \ln \Pr \{y_i = 1 | \beta, x_i\}] [(1 - y_i) \ln (1 - \Pr \{y_i = 1 | \beta, x_i\})]$$

- ▶ $g()$ n'étant pas connue
 - ▶ on a le même problème qu'avec Ichimura
 - ▶ Klein & Spady proposent un estimateur Kernel modifié

Ex. Klein & Spady

- ▶ Données sur le poids à la naissance (détails dans le script)
- ▶ ### 3.3.b Klein & Spady
 - ▶ Voir le script, c'est long mais simple
 - ▶ Matrice de confusion

			Prédit	
			0	1
Réal	0	Logit	119	11
		K&S	119	11
			vrais \ominus	faux \oplus
	1	Logit	34	25
		K&S	22	37
			faux \ominus	vrais \oplus

- ▶ Léger avantage à K&S

Exercice

- ▶ Est-il possible de calculer des t-stats ?

Sommaire

Estimation de fonction de densité et probabilité

Régression

Modèles semiparamétriques

LOESS

Intro

- ▶ Local Polynomial Regression Fitting / locally weighted smoothing
 - ▶ Aussi appelé LOWESS (Locally Weighted Scatterplot Smoothing)
 - ▶ Dans R, `lowess` ne prend qu'un seul régresseur
- ▶ Approche "local polynomial kernel" qu'on a déjà vue
- ▶ Scatterplot smooting est un autre nom
 - ▶ attention aux régresseurs manquants avec cette interprétation
- ▶ loess est une alternative au package np
 - ▶ Mais fait moins de choses

commande

```
loess(formula, data, span = 0.75, degree = 2, parametric =  
FALSE, family = c("gaussian", "symmetric"), ...)
```

- ▶ **formula** permet de spécifier le modèle
 - ▶ Ne prend pas de factor !
 - ▶ Pas plus de 4 régresseurs !
- ▶ **span** : la proportion de points de l'éch. utilisés pour le "local fitting" (ad hoc)
- ▶ **degree** =1 indique locally linear regressions
 - ▶ =2 (défaut) locally quadratic regressions
- ▶ **parametric** : permet de spécifier certains régresseurs comme paramétrique
 - ▶ Ça fait juste $\text{span}=1$ pour ce ou ces régresseurs-là, mais ne produit pas un coefficient
 - ▶ Ça n'est pas comme les modèles partiellement linéaires
- ▶ **family** est le kernel

Représentation graphique

- ▶ Ne présente pas de paramètre, comme toujours
 - ▶ Les résultats de la régression sont visibles graphiquement
 - ▶ Mais il faut détailler le plot
 - ▶ `fit.wage1 <- matrix(predict(model.loess, newwage1), 25, 25)`
prédiction du modele
 - ▶ `persp(edu, exp, fit.wage1, theta=0, phi=30, ticktype="detailed", xlab="Education", ylab="Experience", zlab="Wage", expand=2/3, shade=0.5)` le plot en 3D
 - ▶ Changer `theta` pour faire tourner l'image à l'horizontale
 - ▶ `phi` pour la verticale
 - ▶ On voit bien que le rendement de l'expérience est croissant avec l'éducation
 - ▶ La forme est assez intéressante

Significativité

- ▶ Pas de commande directe, il faut
 - ▶ répliquer la régression moins un régresseur
 - ▶ calculer un F-test sur base des “residual sums of squares” dans les 2 régressions
 - ▶ anova(modèle moins un régresseur, modèle initial)
 - ▶ Il reste une hypothèse de normalité des résidus derrière le test en F
 - ▶ Les régresseurs sont tous très significatifs
- ▶ Il ne semble pas y avoir de “goodness-of-fit” associé à loess
- ▶ Exercice. Répliquer l’analyse avec les données Airq du package Ecdat

Smoothing d'une série temporelle

- ▶ Une application graphiquement intéressante
- ▶ Data economics de ggplot2
 - ▶ `uempmed` median duration of unemployment, in weeks,
 - ▶ `date` Month of data collection
 - ▶ Remplacé par `index` (=row nbr) pour loess qui n'accepte que du numérique
 - ▶ Estimation à plusieurs niveaux de span
 - ▶ Plot des prédictions à plusieurs niveaux de span