

# Détection d'individus atypiques en régression SIR

Hadrien Lorenzo, Jérôme Saracco

Equipe ASTRAL, Inria

Equipe OptimAI, IMB

Dataquitaine 2022, Bordeaux, jeudi 10 février



## Qu'est-ce qu'une observation **normale** ?

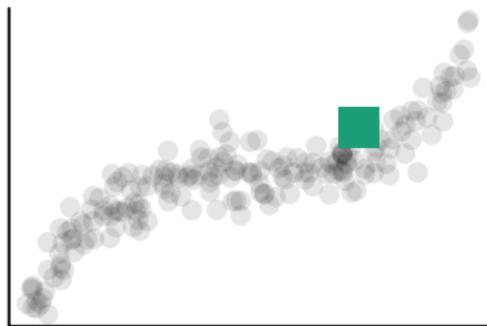
Avant toute chose, qu'est-ce qu'une observation **normale** ?

Une observation qui ressemble aux autres. Elles sont en majorité.

# Qu'est-ce qu'une observation **normale** ?

Avant toute chose, qu'est-ce qu'une observation **normale** ?

Une observation qui ressemble aux autres. Elles sont en majorité.



# Qu'est-ce qu'une observation **outlier** ?

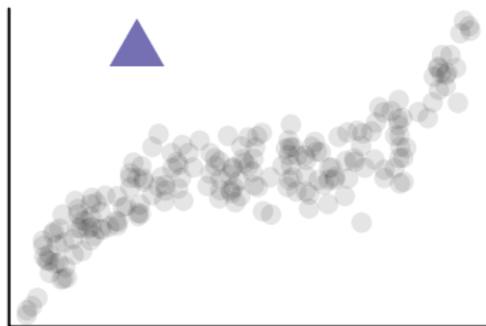
## Quid d'une observation **outlier** ?

Une observation qui ne ressemble pas aux autres et qu'il serait absurde de comparer aux autres.

# Qu'est-ce qu'une observation **outlier** ?

## Quid d'une observation **outlier** ?

Une observation qui ne ressemble pas aux autres et qu'il serait absurde de comparer aux autres.

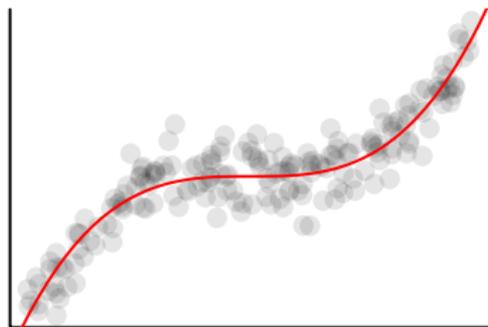


# Notion de modèle

Un modèle régit la structure des données. Dans notre cas

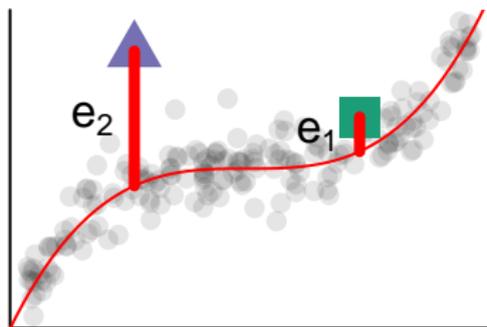
$$y = x^3 + \varepsilon/7,$$

où  $x \sim \mathcal{U}_{[-1,1]}$  et  $\varepsilon \sim \mathcal{N}(0, 1)$ .



## Notion de distance au modèle

On peut mesurer à quel point une observation est loin du modèle:



Ici  $e_2 \gg e_1$ .

$e_1$  est à peu près la valeur prise par tous les points, le point est dans la norme.

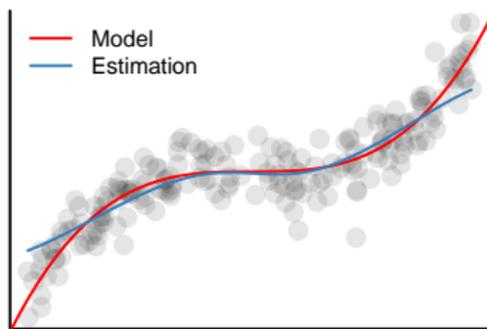
Le point **violet** est certainement un **outlier**.

# Problème: le modèle est inconnu

## Estimation

Le modèle doit être estimé sur un jeu de données d'**entraînement**, noté  $\mathcal{D}_n$ , de taille finie  $n$ .

Dans notre exemple  $n = 200$  :



Bonne estimation au centre et mauvaise estimation sur les bords.

⇒ Moins d'observations et donc moins d'information.

# Implication

Les conclusions sur les bords sont à surveiller.

Qu'est-ce qu'un **borderline** ?

Une observation pouvant être classée **normale**/**outlier** selon l'estimation du modèle qui dépend du jeu de données disponible.

## Notre travail

### Certaines zones sont sensibles

Ceci à cause :

- Du modèle supposé.
- Du faible échantillonnage ( $n$  faible)

### Notre travail

- Perturber l'échantillon pour enrichir le jeu de données.
- Estimer à chaque fois un modèle.
- Tester la pertinence du modèle sur certaines observations (inclus (ou pas!) dans le jeu de données d'entraînement)
- Regrouper tous les résultats.
- Conclure sur la sensibilité de certaines observations (**normale**/**borderlines**/**outlier**?)

# Le bootstrap

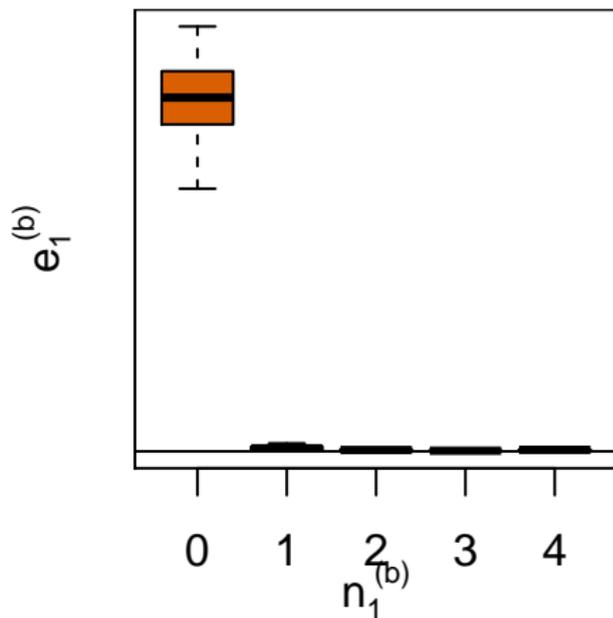
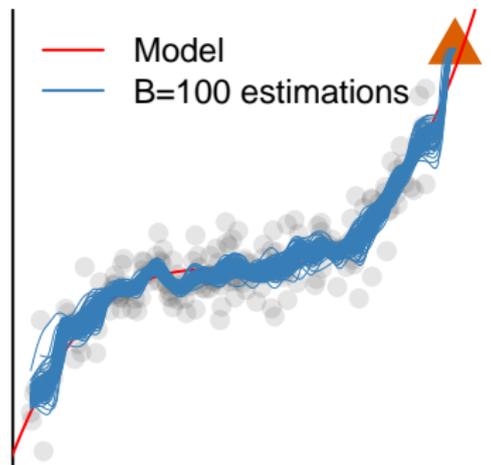
## Le bootstrap

On crée  $B$  jeux de données  $(\mathcal{D}_b)_{b=1\dots B}$  de taille  $n$  en piochant dans  $\mathcal{D}_n$  avec remise.

⇒ Une observation peut être observée plusieurs fois dans un même jeu de donnée  $\mathcal{D}_b$ , elle n'est donc plus dans une zone dépeuplée.

⇒ Pour chaque observation  $i$ :  $e_i^{(b)}$  erreur de modèle pour l'estimation obtenue sur  $\mathcal{D}_b$  où l'observation  $i$  apparaît  $n_i^{(b)}$  fois.

# Plus concrètement



## Plusieurs solutions imaginées (1-2/3)

### MONO

Regarde les erreurs sur le jeu d'entraînement seulement.

Un seul jeu de données,

⇒ un seul modèle,

⇒ beaucoup de **Faux Positifs (FP)**.

### TTR

Divise  $R \approx 2000$  fois  $\mathcal{D}_n$  (de taille 90% (*train*) et 10% (*test*) de  $n$ ).

Estimer le modèle sur le *train* et évaluer l'erreur  $e_j$  sur le *test*.

⇒  $R$  jeu de données,

⇒  $R$  modèles de taille  $0.9n$ ,

⇒ Moins de **Faux Positifs (FP)**.

## Plusieurs solutions imaginées (3/3)

### BOOT

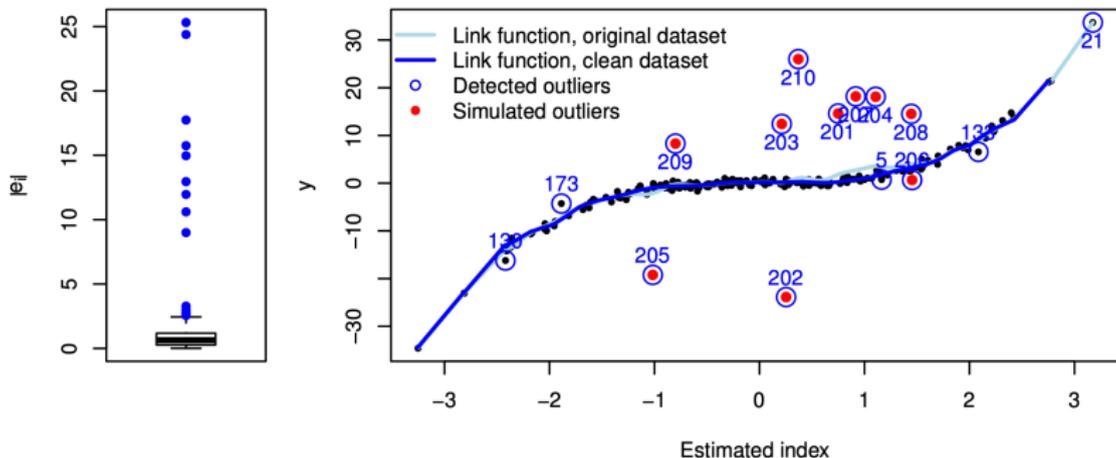
- Comme **TTR** mais avec du **bootstrap**, où les individus
- tirés au sort forment les **In Bag (IB)**,
  - non tirés forment les **Out Of Bag (OOB)**.

## Comment décider du type d'observation ?

### 2 critères possible au regard des $e_i$

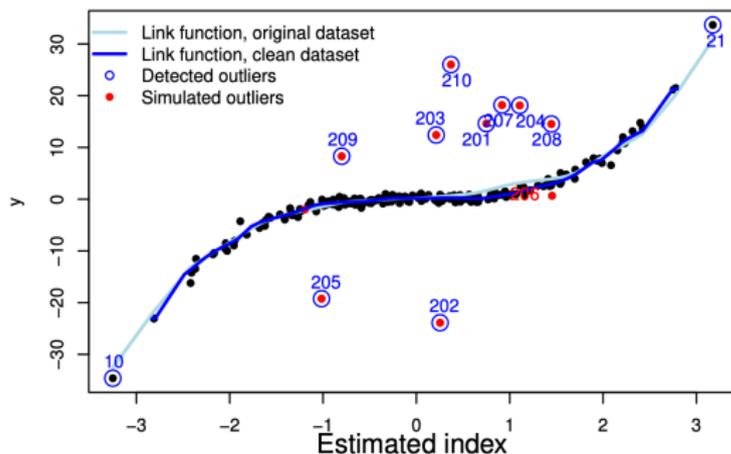
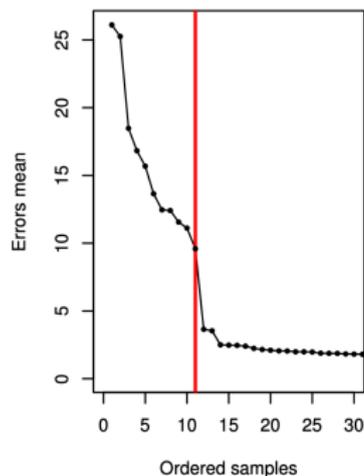
- Critère sur les quantiles, ce qui dépasse de la boîte à moustaches:  
**MONO** et **BOOT**.
- **TTR** : détection d'une rupture dans la série ordonnée des  $e_i$  moyennés.

# Un exemple pour MONO



Effectivement il y a des **FP**...

# Voyons avec TTR



Moins de **FP**, mais des problèmes en **queues** de distribution.

⇒ Zones des modèles les moins stables (cf plus haut).



# Un modèle de régression

## Un modèle semi-paramétrique

$$y = f(\beta^t x) + \epsilon,$$

où

- $x$  sont les variables permettant de prédire.
- $y$ , la variable à expliquer.
- $\beta$  est estimable par la méthode SIR  $\implies$  paramétrique.
- $f$  est inconnue et est estimée localement  $\implies$  non-paramétrique.
- $\epsilon$  est l'erreur aléatoire du modèle.

## Intérêts

L'indice  $\beta^t x$  permet de réduire la dimension, ce qui est utile pour la partie non paramétrique.

Rendre compte de relations non linéaires en prédiction sans avoir à choisir de base de représentation (splines, ondelettes, sigmoïdes,...).

## Un jeu de données multivarié : ozone Cornillon *et al.* (2012)

- $n = 112$  mesures journalières de variables météorologiques à Rennes.
- `maxO3` : concentration max. en ozone en  $\text{gr}/\text{m}^3$ .
- Les températures à 9h, 12h et 15h.
- Les mesures de nébulosité à 9h, 12h et 15h.
- Les vitesses du vent à 9h, 12h et 15h.
- La concentration max. en ozone mesurée la veille.

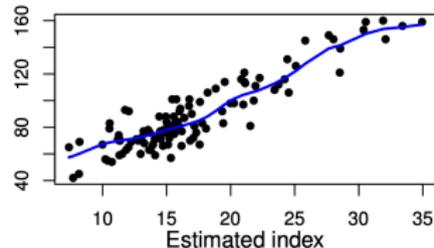
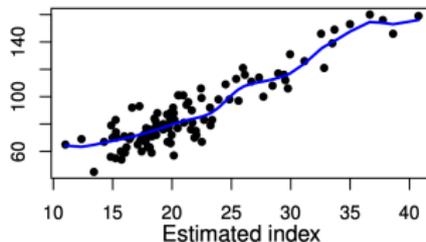
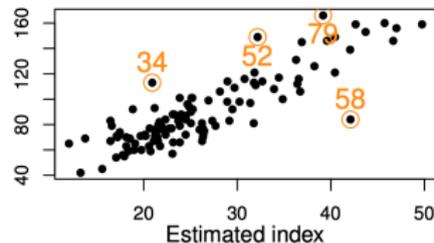
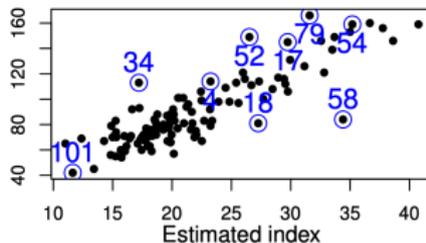
**Objectif** : Prédire `maxO3` en fonction des autres variables. . .

**Mais pour nous!** Regarder si les observations sont normales/**borderlines**/**outliers**

# Résultats

A gauche : **TTR**.      A droite : **BOOT**.

En bleu : **outliers**.      En orange : **borderlines**.



# Commentaires

## 4 borderlines

Connus par la littérature : Dates de chassés-croisés!

Ecarts non dues aux conditions météo, mais à un excès de circulation automobile.

⇒ Le modèle supposé est limite (ne prend pas en compte la circulation automobile).

⇒ Bien **borderlines** et non pas **outliers**.

# Conclusion

Cette approche a pour l'instant été appliquée à la méthode SIR mais peut être élargie à tout modèle de régression.

Elle est à la limite entre détection d'outliers/événements rares.

**Intérêt pratique :** Détecter des anomalies en fonctionnement dans une chaîne de production.

**Intérêt académique :** Chapitre d'un livre, édité chez Springer, voir Lorenzo & Saracco (2021).

# References I

CORNILLON, P.-A., GUYADER, A., HUSSON, F., JEGOU, N., JOSSE, J., KLOAREG, M., MATZNER-LOBER, E., & ROUVIÈRE, L. (2012) *R for statistics*, ed. CRC press.

LORENZO, H. & SARACCO, J. (2021) Computational outlier detection methods in sliced inverse regression. *Advances in contemporary statistics and econometrics.*, ed. (Daouia A., R.-G.A. ed). Springer, Cham.