

Paris Nanterre

M1 - Cours de Modélisation Appliquée

# Introduction aux modèles économétriques

Laurent Ferrara

Janvier 2019

---

# Plan de la présentation

**1. Concepts**

**2. Modèles économétriques**

**3. Exemples de modèles**

# 1. Concepts

## **Objectif**

Prendre des décisions à partir de l'observation d'un ensemble de données

## **Méthode**

Construction d'un modèle économétrique pour chaque type d'étude

## **Outils**

1) Théorie de l'information et concepts d'optimalité

→ construction d'une population exhaustive : pas tjs facile ....

→ Solution : échantillonnage

## 2) Modèles économétriques:

Modèles probabilistes : loi de distribution de l'échantillon

Modèles paramétriques : modèles de régression linéaire et non-linéaire, modèles de séries chronologiques, ....

→ Chaque type de modèle fait appel à des paramètres (de la loi et / ou du modèle), *a priori* inconnus qu'il faudra estimer.

On peut identifier de 2 types de paramètres : paramètres de loi de distribution ou paramètres de structure.

## 3) Estimation et tests :

Inférence statistique basée sur l'échantillon observé

→ Contrôle de la qualité de l'information et de la décision prise associée au test

## Exemples :

- Etude d'une population par sondage (élections, enquêtes d'opinion auprès des ménages et des industriels...)
- Explication de phénomènes macro-économiques et micro-économiques
- Prévision (variables macro, taux de change, actifs financiers, ...)
- Prise de décision de politique économique par le gouvernement, la banque centrale, les institutions internationales

## 2. Modèles économétriques

### Définition formelle

On appelle modèle au sens statistique la donnée d'un triplet

$$(\Omega, F, IP)$$

où :

$\Omega$  est l'ensemble (les données)

$F$  est une tribu sur  $\Omega$

$IP$  est une famille de lois de proba. sur  $(\Omega, F)$  tq :  $IP \rightarrow (IP_\theta)_{\theta \in \Theta}$

$$\theta \in \Theta \subset \mathcal{R}^k$$

qui dépend d'un paramètre vectoriel

## Hypothèse clé de travail :

*Les individus interrogés sont identifiés à des variables aléatoires  $X_1, \dots, X_n$ , à valeurs dans  $\Omega$  ( $\Omega = \mathbb{R}$  ou  $\mathbb{R}^d$ ), indépendantes et de même loi de distribution  $P_\theta$  (i.i.d.)*

## Remarques :

**R1:** En général,  $\Omega \subset \mathbb{R}^d$ , on travaille alors avec la tribu des boréliens  $B_{\mathbb{R}^d}$

**R2 :** Quand  $\Theta \subset (\mathbb{R}^d, B_{\mathbb{R}^d})$  on parle de modèle paramétrique probabiliste. On suppose connaître la loi  $P_\theta$  mais  $\theta$  inconnu.

→ On va donc se servir de l'échantillon qu'on aura construit à partir des individus pour identifier ce paramètre  $\theta$ .

## Définition:

On appelle *n*-échantillon, le vecteur aléatoire :

$X = (X_1, \dots, X_n)$  de loi  $P_\theta^n$ , suite finie de v.a. indépendantes et identiquement distribuées (iid) de loi  $P_\theta$ .

## Définition:

On appelle observation une réalisation du vecteur aléatoire  $X$ , notée :  $x = (x_1, \dots, x_n)$ .

## Remarques :

**R1:** Le modèle statistique associé à  $X$  est :  $(\Omega^n, F^n, IP_\theta^n)$



**R2:** La famille de lois  $P_\theta$  est supposée posséder une densité continue  $f_\theta(x)$  ou discrète  $p(x, \theta)$  (abus de langage)

**R3 :**  $\Delta_\theta = \{x; f_\theta(x) > 0\}$   
est le support de la loi  $P_\theta$  .

**R4 :** Sous l'hypothèse d'indépendance :  $P_\theta^n = P_\theta \times \dots \times P_\theta$

## Définition:

*On appelle statistique toute fonction mesurable  $f$  tq:*

$$f: (X_1, \dots, X_n) \rightarrow f(X_1, \dots, X_n) \in \mathbb{R}^k,$$

*$k$  étant la dimension de la statistique.*

## Exemples :

- $(X_1, \dots, X_n)$  statistique de dimension  $n$
- $(X_{(1)}, \dots, X_{(n)})$  statistique de dimension  $n$
- $X_1$  statistique de dimension 1
- $1/n \sum_i X_i$  statistique de dimension 1

# 3. Exemples de modèles

## Modèle Binomial

$\Omega = \{\text{données}\} = \{\text{réponses à une question binaire (oui/non)}\}$

On interroge  $n$  individus,  $X_i$  est la réponse de l'individu  $i$  :

$X_i = 1$  si oui et  $X_i = 0$  si non

→  $X_i$  est une v.a. qui suit une loi de Bernouilli de paramètre  $\theta$  inconnu tq :

$\theta =$  probabilité que l'individu réponde oui

Le modèle statistique associé au vecteur aléatoire  $X$  est :

$$(\{0,1\}^n, F^n, B(\theta, n))$$

Exemples ?                       $\theta$  ?

## Modèle Log-Normal

Sur  $n$  individus, on mesure une variable  $R_i$ .

On suppose qu'il s'agit d'une variable continue positive

$$R_i \sim \text{LogN}(m, \sigma^2)$$

ie  $\text{Log}(R_i) \sim N(m, \sigma^2)$

On a 2 paramètres d'intérêt  $m$  et  $\sigma^2$

Le modèle statistique associé au vecteur aléatoire  $X$  est :

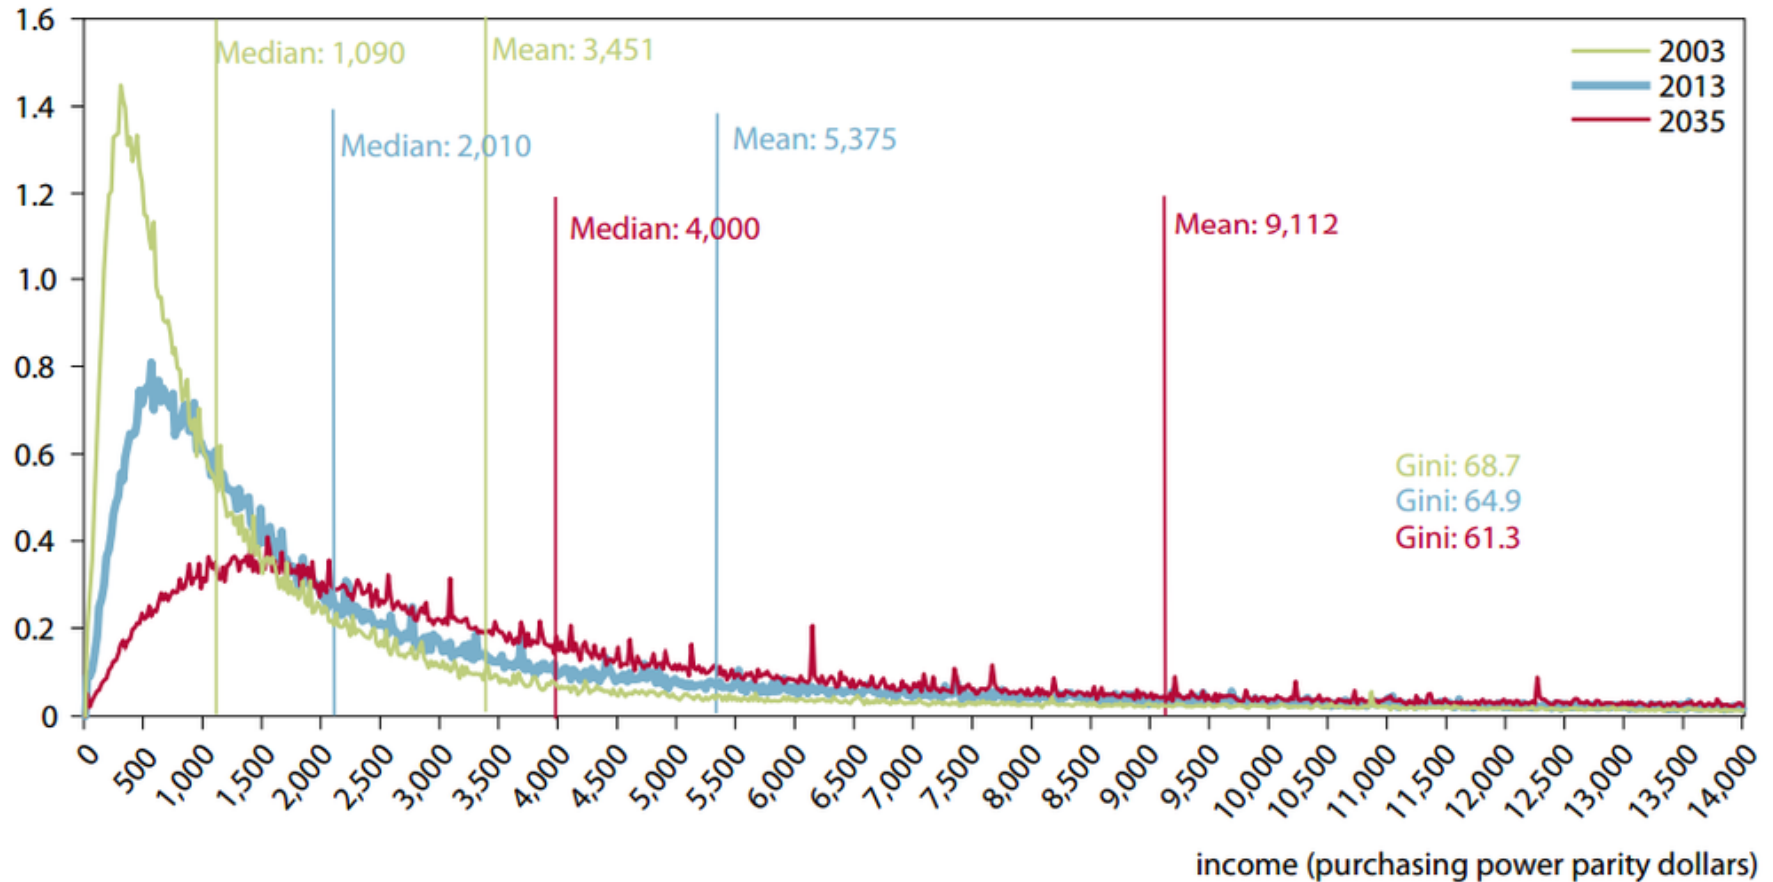
$$(R^n, B_{R^n}, (\text{LogN})^n)$$

Exemples ?

# Distribution des revenus mondiaux à différentes dates

**Figure 5** Frequency plot of global income distribution, 2003, 2013, and 2035

percent of world population



## Modèle linéaire

Sur  $n$  individus, on mesure les variables  $X_i$  et  $Y_i$ ,

On suppose qu'il existe une relation linéaire entre elles, ie:  
pour chaque  $i$  :

$$Y_i = a X_i + b$$

Les paramètres  $(a,b)$  sont inconnus



La relation n'est pas forcément déterministe

ie: il existe une v.a.  $(e)$  telle que :  $e_i \sim N(0, \sigma^2)$  et

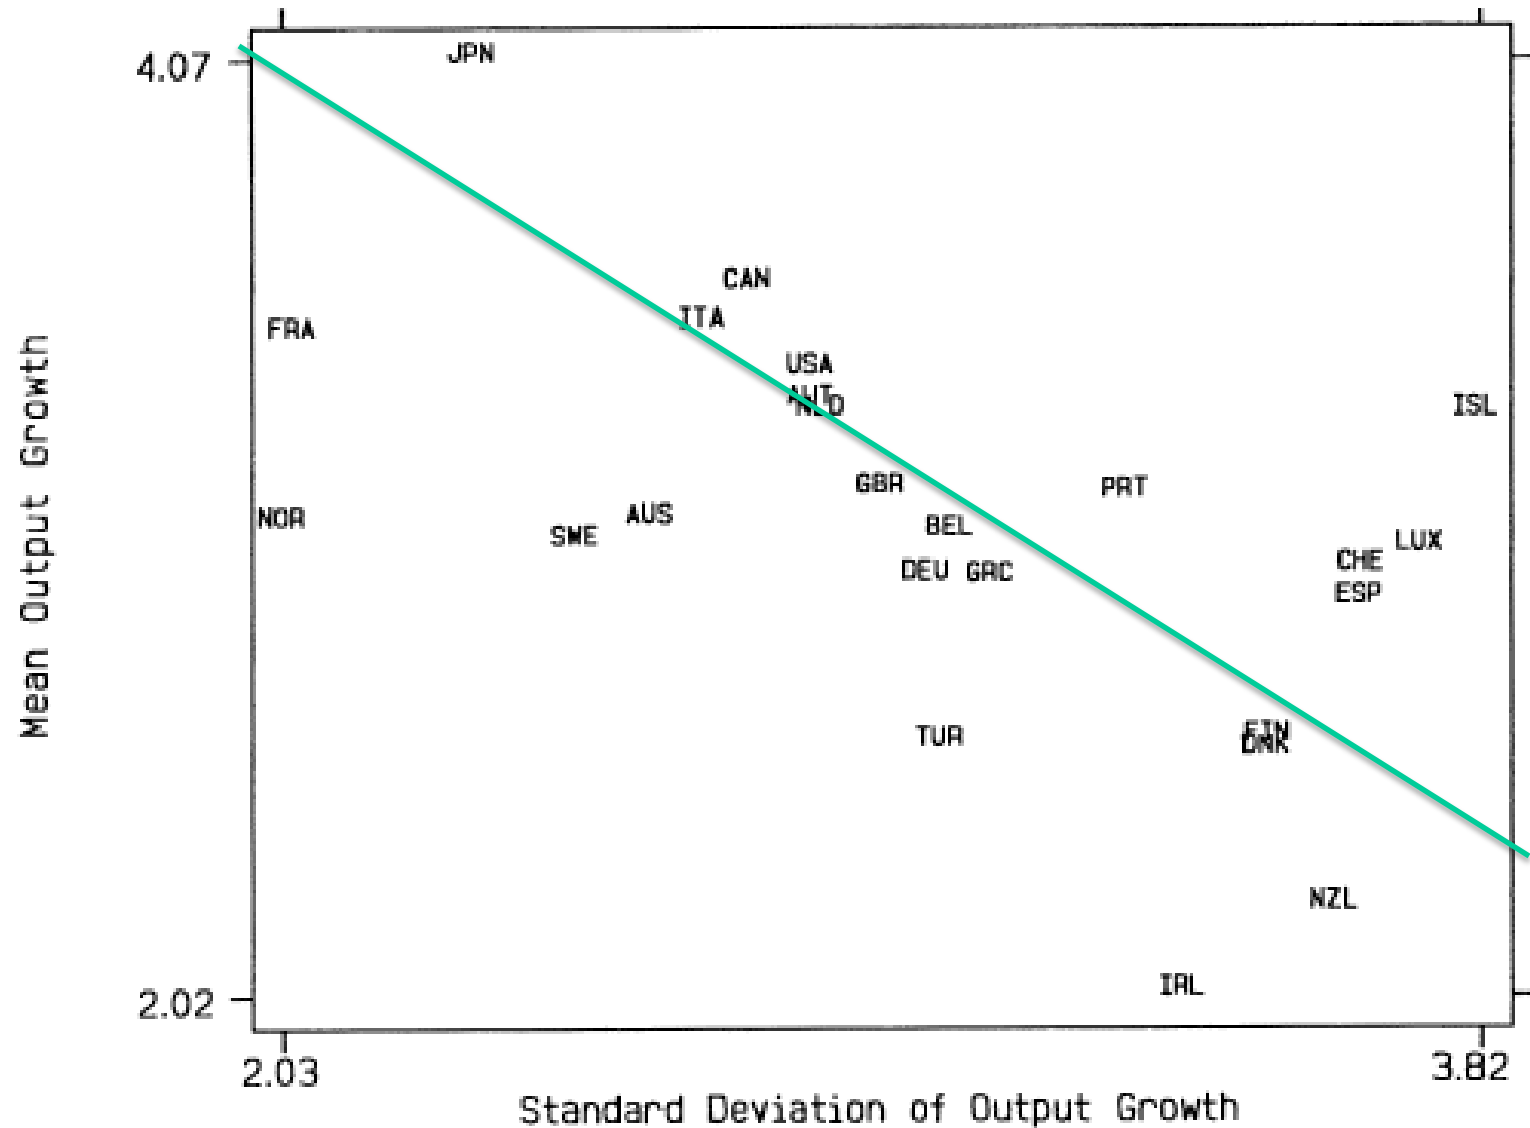
$$Y_i = a X_i + b + e_i$$

Les paramètres  $(a, b, \sigma^2)$  sont inconnus

# Effet de la variance résiduelle sur un nuage de points (voir simulations sous RATS)




# Example: Ramey and Ramey (AER)





# Modèles de séries chronologiques

## Indice de la production industrielle en zone euro



# Modèles de séries chronologiques

Les  $n$  individus  $i$  deviennent  $n$  dates  $t$ ,

On mesure une variable  $R_t$  pour  $t = 1, \dots, T$

Pb: Qu'en est-il de l'hypothèse i.i.d. ?

1/ Indépendance : Hypothèse pas raisonnable

2/ Identiquement distribué : Hypothèse nécessaire

## Modèles de séries chronologiques

Les  $n$  individus  $i$  deviennent  $n$  dates  $t$ ,

On suppose qu'il existe une relation linéaire entre elles, ie:

pour chaque  $t$  :

$$Y_t = a Y_{t-1} + b$$

Les paramètres  $(a,b)$  sont inconnus

La relation n'est pas forcément déterministe, ie: il existe la variable telle que :  $e_t \sim N(0, \sigma^2)$  et

$$Y_t = a Y_{t-1} + b + e_t$$

Les paramètres  $(a,b, \sigma^2)$  sont inconnus

# Modèles de séries chronologiques déterministes

On suppose qu'il existe une relation non forcément linéaire entre elles, ie:

pour chaque  $i$  :

$$Y_t = f(\theta, Y_{t-1})$$

Les paramètres ( $\theta$ ) sont inconnus

*Exemples: Fonctions Chaotiques: logistique, Rossler, Henon*

```
com nn = 10000
```

```
com aa = 3.75
```


```
com xx(1) = 0.8
```

```
do i=2,nn
```

```
com xx(i) = aa*xx(i-1)*(1-xx(i-1))
```

```
enddo i
```

# Squelette de séries chronologiques déterministes (Rossler)



## Remarques

- Quel est le but du jeu de toute tentative de modélisation d'une variable  $Y$  ?

→ **Minimiser la variance résiduelle**

$Y =$  partie déterministe + partie aléatoire

$$Y = f(X) + \varepsilon$$

Par indépendance,  $V(Y) = V(f(X)) + V(\varepsilon)$

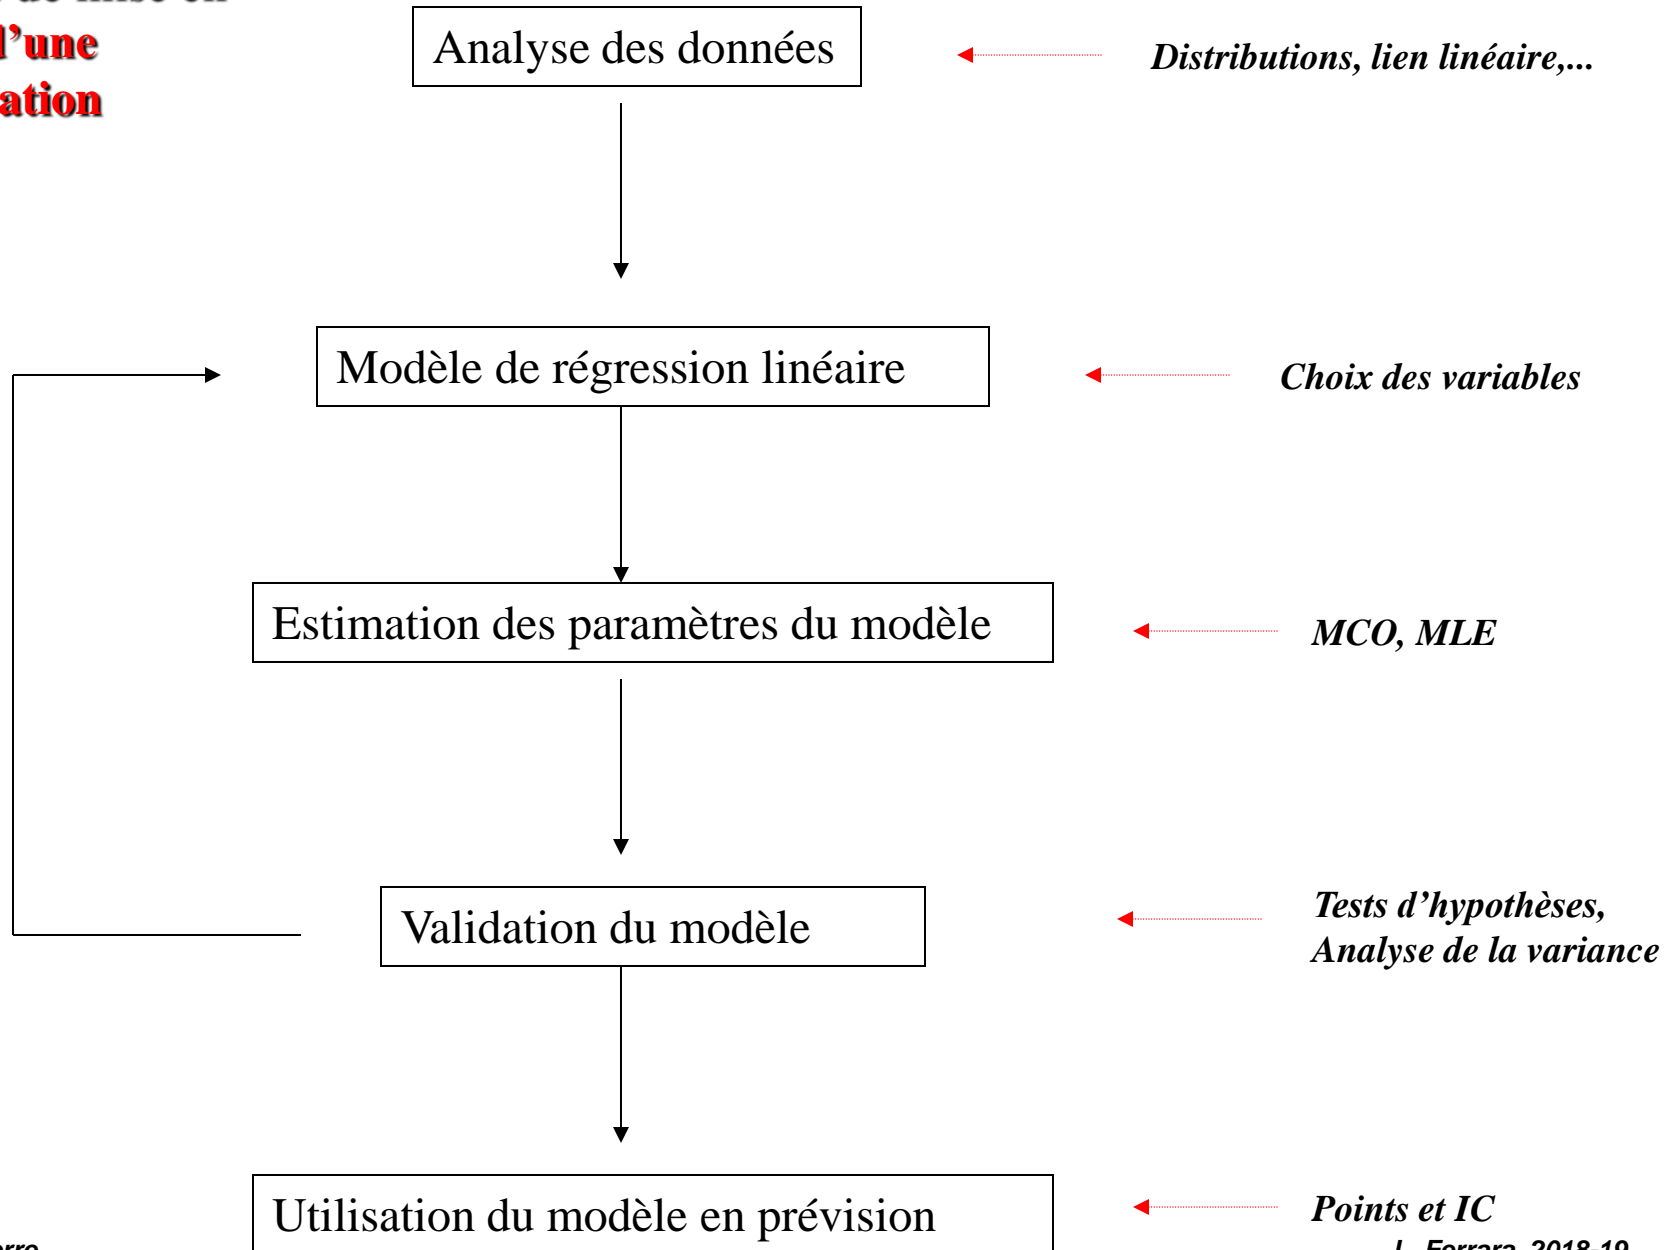
# Conclusion

→ Un modèle économétrique permet de faire un choix économique à partir d'un ensemble d'information

## Algorithme de modélisation statistique:

- Définir l'ensemble d'information
- Spécifier le modèle statistique (= identifier  $P_{\theta}^n$ )
- Estimation du modèle
- Validation / Contrôle
- Prise de décision / Prévision

# Schéma de mise en œuvre d'une modélisation





---

# Conclusion

## Outils:

- Éléments de la théorie des probabilités
- Construction d'échantillon
- Choix de la classe de modèle paramétrique
- Méthodes de spécification du modèle
- Estimation des paramètres
- Tests d'hypothèses