

Modèle Linéaire Gaussien

Introduction

Achille Thin

7 Décembre 2023

Executive Master Statistique et Big Data



Contact

- ▶ Achille Thin (Maître de Conférences), thin.achille@gmail.com

Syllabus

- ▶ 15 heures de cours/TP.
- ▶ Matériel disponible sur <https://achillethin.github.io/teaching/>
- ▶ Évaluation finale : projet sur R.

Exemple introductif

Description

Données: salaire horaire en dollars (WAGE) de 534 personnes (États-Unis, 1985) accompagné de 10 caractéristiques économiques dont

- ▶ la catégorie professionnelle (OCCUPATION) : *Management* (1), *Sales* (2), *Clerical* (3), *Service* (4), *Professional* (5), *Other* (6),
- ▶ le nombre d'années d'étude (EDUCATION),
- ▶ le nombre d'années d'expérience (EXPERIENCE),
- ▶ l'âge (AGE),
- ▶ le genre (SEX),
- ▶ le statut marital (MARR).

Référence: Berndt, E. R. (1991). *The Practice of Econometrics : Classical and Contemporary*. (Source : www.economicswbinstitute.org/glossary/wages.htm)

Question : existe-t-il un effet des caractéristiques socio-démographiques sur le salaire des employé·e·s ?

Chargement des données

Chargement à partir d'un fichier Excel:

```
library(readxl)
donnees <- read_excel("../data/wagesmicrodata.xls")
```

Chargement à partir d'un fichier .csv:

```
donnees <- read_csv("../data/wagesmicrodata.csv",
  sep = ";", dec = ",")
```

	ID	WAGE	OCCUPATION	EDUCATION	EXPERIENCE	AGE
1	1	5.10	6	8	21	35
2	2	4.95	6	9	42	57
3	3	6.67	6	12	1	19
4	4	4.00	6	12	4	22
5	5	7.50	6	12	17	35
6	6	13.07	6	13	9	28

Étude descriptive des données : variables quantitatives

Variable quantitative: représente une « mesure », *e.g.*, WAGE, EDUCATION,...

Résumés: indicateurs numériques comme la moyenne ou les quartiles.

```
mean (donnees$WAGE)
```

```
[1] 9.0241
```

```
quantile (donnees$WAGE, c(0.25, 0.5, 0.75))
```


```
 25%   50%   75%  
5.25  7.78 11.25
```

```
summary (donnees$WAGE)
```

```
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.  
  1.00   5.25   7.78   9.02  11.25  44.50
```

Étude descriptive des données : variables quantitatives

Représentations graphiques: histogramme (`hist`) ou box-plot (`boxplot`).



Étude descriptive des données : variables qualitatives

Variable qualitative: représente des « catégories », *e.g.*, OCCUPATION, SEX,...

Si les catégories sont représentées par des nombres, il faut le spécifier à R pour qu'il ne voit pas ces variables comme des variables quantitatives.

```
donnees$OCCUPATION <- as.factor(donnees$OCCUPATION)
```


Résumés: effectifs ou fréquences de chacune des catégories (modalité).

```
summary(donnees$OCCUPATION)
```

1	2	3	4	5	6
55	38	97	83	105	156


Étude descriptive des données : variables qualitatives

Représentation graphique: diagramme en bâtons (barplot).




1. Identifier les variables quantitatives et qualitatives du jeu de données.
2. Faire une étude descriptive de l'ensemble des données.

Relation entre variables quantitatives



Question: peut-on résumer ce nuage de point par une droite et établir un lien entre le salaire et le nombre d'années d'étude ?

Relation entre variable quantitative et variables qualitatives



Question: est ce qu'il y a un lien entre le salaire et le genre?

Cadre du cours

Démarche générale

- ▶ En statistique, on cherche à expliquer ou prédire, une variable d'intérêt y en fonction d'une autre variable x .
- ▶ On dispose de n valeurs (x_1, \dots, x_n) et (y_1, \dots, y_n) pour *apprendre* la relation en x et y :

$$y \approx f(x)$$

- ▶ On ne sait pas à *l'avance*
 - si x explique correctement y (x est-elle en particulier suffisante pour prévoir y ?),
 - quelle est la forme de f .

Modèle linéaire: modèle mathématique décrivant le lien entre une variable explicative **quantitative** (le salaire) et des variables explicatives (le nombre d'années d'expérience, le nombre d'années d'étude, le genre, ...) à l'aide d'une relation linéaire.

- ▶ Chapitre 1 – Régression linéaire simple : expliquer en fonction d'une variable quantitative.
- ▶ Chapitre 2 – Régression linéaire multiple : expliquer en fonction de plusieurs variables quantitatives.
- ▶ Chapitre 3 – Analyse de la variance : expliquer en fonction d'une ou plusieurs variables qualitatives.
- ▶ Chapitre 4 – Analyse de la covariance : expliquer en fonction d'une variable quantitative et d'une variable qualitative.

Cours en ligne:

- ▶ **S. Donnet**: <https://sophiedonnet.github.io/linearmodel.html>
- ▶ **C. Chouquet**: <https://www.math.univ-toulouse.fr/~barthe/M1modlin/poly.pdf>

Livre:

- ▶ Le modèle linéaire par l'exemple, Jean-Marc Azaïs, Jean-Marc BarDET, Dunod, 2005.
- ▶ Le modèle linéaire et ses extensions, Liliane Bel et al., 2016.