

# VÉRIFICATION DES POSTULATS DU MODÈLE LINÉAIRE

## Plan du chapitre 7

1. Importance des postulats
2. Vérification des postulats
3. Que faire si un des postulats n'est pas vérifié ?
4. Si rien ne marche

# Importance des postulats

Premier postulat  $E(\varepsilon_n) = 0$

Le modèle consiste toujours à écrire la variable sous la forme :

$$Y_n = \mu_n + \varepsilon_n \quad \text{avec} \quad \mu_n = \sum x_{pn} \theta_p$$

Indispensable si l'on veut que le modèle soit plausible pour décrire la réalité.

Si les quatre postulats sont vérifiés, les estimateurs  $\hat{\theta}$  et  $\hat{\sigma}^2$  possèdent les propriétés suivantes :

$$- E(\hat{\theta}) = \theta$$

$$- \text{Var}(\hat{\theta}) = \sigma^2(X'X)^{-1}$$

-  $\hat{\theta}$  est gaussien

$$- E(\hat{\sigma}^2) = \sigma^2$$

$$- \hat{\sigma}^2 \sim \frac{\sigma^2 \chi^2(N-P)}{N-P}$$


-  $\hat{\sigma}^2$  est indépendant de  $\hat{\theta}$

Grâce aux **quatre postulats**, il est possible de faire des tests sur l'estimateur  $\hat{\theta}$


# Vérification des postulats

Pour vérifier les postulats, on fait toujours une représentation graphique des résidus estimés.


En analyse de variance




En regression




**Le postulat  $E(\varepsilon_n) = 0$  est-il vérifié ?**  
**en analyse de la variance**





**Le postulat  $E(\varepsilon_n) = 0$  est-il vérifié ?**  
**en regression**



**Le postulat  $\text{Var}(\varepsilon_n) = \sigma^2$  est-il vérifié ?**  
**en analyse de la variance**




**Le postulat  $\text{Var}(\varepsilon_n) = \sigma^2$  est-il vérifié ?**  
**en regression**






## Les $\varepsilon_n$ sont-ils indépendants ?

Représentation graphique de  $\hat{\varepsilon}_n$  en fonction du temps ou de l'ordre des expériences






Les  $\hat{\varepsilon}_n$  ne sont pas indépendants.

Représentation graphique schématique des  $\hat{\varepsilon}_n$  dans l'espace






## Les $\varepsilon_n$ sont-ils normalement distribués ?

Représentations graphiques de la distribution de  $\hat{\varepsilon}_n$



## Les $\varepsilon_n$ sont-ils normalement distribués ?

Représentations graphiques de la distribution de  $\hat{\varepsilon}_n$



# Que faire si un des postulats n'est pas vérifié ?

Si un postulat n'est pas vérifié, les données récoltées gardent leur valeur que faire alors ?

**Postulat 1 :  $E(\varepsilon_n) = 0$  pour tout  $n$**

- en analyse de la variance : introduire de nouveaux facteurs
- en régression : penser à des régresseurs non linéaires et à des produits de régresseurs.

**Postulat 2 :  $\text{Var}(\varepsilon_n) = \sigma^2$  constante**

La technique générale est de transformer la variable mesurée.

## Transformations de variables lorsque $\text{Var}(\varepsilon_n)$ n'est pas constante

Lorsque l'on dispose d'une information sur la distribution de  $Y$

Distribution de Poisson :

$$\sigma^2 \propto \mu : Y \longrightarrow \begin{cases} \sqrt{Y} \\ \sqrt{Y + \text{cste}} \end{cases}$$

Distribution Log-normale :

$$\sigma \propto \mu : Y \longrightarrow \begin{cases} \text{Log } Y \\ \text{Log } (Y + 1) \end{cases}$$

Distribution Binomiale :

$$\sigma \propto \sqrt{\mu(1 - \mu)} : Y \longrightarrow \arcsin \sqrt{Y}$$



Ne pas appliquer sans discernement

- regarder les résidus avant transformation
- choisir éventuellement une transformation
- vérifier les résidus après transformation

## Transformations de variables lorsque $\text{Var}(\varepsilon_n)$ n'est pas constante

Lorsque l'on ne dispose pas d'information sur la distribution de  $Y$

Si l'écart-type est une fonction puissance de la moyenne  $\sigma \propto \mu^k$ ,  
on définit une famille de transformations :

pour  $k \neq 1$ ,  $Y^{1-k}$   
pour  $k = 1$ ,  $\text{Log } Y$

### Exemples

$$k=1 \quad \sigma \propto \mu : \quad Y \longrightarrow \text{Log } Y$$

$$k = \frac{1}{2} \quad \sigma \propto \mu^{1/2},$$

$$\sigma^2 \propto \mu : \quad Y \longrightarrow Y^{1-\frac{1}{2}} = \sqrt{Y}$$

**Trouver  $k$  ?**

si  $\sigma \propto \mu^k$ ,


alors  $\sigma^2 \propto \mu^{2k}$

d'où  $\sigma^2 = c \mu^{2k}$

d'où  $\text{Log } \sigma^2 = c' + 2k \text{Log } \mu$

Relation linéaire entre  $\text{Log } \mu$  et  $\text{Log } \sigma^2$ , pente de la droite =  $2k$ .

**Exemple de choix d'une transformation de variables lorsque  $\text{Var}(\varepsilon_n)$  n'est pas constante**



Comptages de mouches dans des pièges :

4 appâts

4 blocs

5 répétitions

Calcul de 16 moyennes


et de 16 variances

droite de pente très proche de 2


⇒ transformation Log.

Vérification de  $\text{Var}(\varepsilon_n) = \sigma^2$  après transformation des variables

résidus avant transformation



résidus après transformation  $Y \rightarrow \sqrt{Y}$





### **Postulat 3 : les $\varepsilon_n$ sont indépendants**

Les solutions sortent du cadre de ce cours. On peut utiliser :

- La randomisation avant l'expérience (voir module)
- Le modèle mixte ou les séries chronologiques.

### **Postulat 4 : les $\varepsilon_n$ ont une distribution normale**

- Chercher s'il existe des données aberrantes (ou outliers) expliquant le défaut de normalité
- On peut souvent faire quand même des tests si N et N-P sont grands.

# Si rien ne marche

Si aucune transformation ne permet d'avoir des résidus satisfaisants, on peut encore utiliser :

- un modèle linéaire généralisé (voir module)
- un modèle non linéaire.