

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 $E(\epsilon_n) = 0$ est-il vérifié ?
en regression






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




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 ε_n sont-ils normalement distribués ?

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



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.

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

Distribution de Poisson :

$$\sigma^2 \propto \mu : Y \longrightarrow \left\{ \begin{array}{l} \sqrt{Y} \\ \sqrt{Y + cste} \end{array} \right.$$

Distribution Log-normale :

$$\sigma \propto \mu : Y \longrightarrow \left\{ \begin{array}{l} \text{Log } Y \\ \text{Log}(Y + 1) \end{array} \right.$$

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


$$\begin{array}{lll} k=1 & \sigma \propto \mu : & Y \longrightarrow \text{Log } Y \\ k = \frac{1}{2} & \sigma \propto \mu^{1/2}, & \\ & \sigma^2 \propto \mu : & Y \longrightarrow Y^{1-\frac{1}{2}} = \sqrt{Y} \end{array}$$

Trouver k ?

$$\begin{array}{ll} \text{si } \sigma \propto \mu^k, & \text{alors } \sigma^2 \propto \mu^{2k} \\ & \text{d'où } \sigma^2 = c \mu^{2k} \\ & \text{d'où } \text{Log } \sigma^2 = c' + 2k \text{ Log } \mu \end{array}$$

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

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 ε_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 ε_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.