

---

**Sujet 14: Test sur le coefficient directeur d'une droite de régression**

---

• **Quelques rappels sur la définition mathématique des tests d'hypothèses:**

Soit  $X$  une variable aléatoire à valeurs dans un ensemble  $\mathcal{X}$ , de loi  $P_\theta$  où  $\theta \in \Theta$ . Supposons que l'on veuille effectuer un test statistique d'hypothèses portant sur  $\theta$ . On formule deux hypothèses contradictoires notées  $H_0$  et  $H_1$  dont on suppose que l'une et seulement l'une est vraie. Mathématiquement, formuler  $H_0$  et  $H_1$  revient à choisir deux sous-ensembles disjoints de  $\Theta$  notés  $\Theta_0$  et de  $\Theta_1$  de sorte que l'hypothèse  $H_0$  s'écrit alors  $\{\theta \in \Theta_0\}$  tandis que l'hypothèse  $H_1$  s'écrit  $\{\theta \in \Theta_1\}$ . Soit  $(X_1, \dots, X_n)$  un échantillon i.i.d. issu d'une variable parente  $X$  et soit  $(x_1, \dots, x_n) \in \mathcal{X}^n$  une réalisation de  $(X_1, \dots, X_n)$ . Construire un test de  $H_0$  contre  $H_1$  revient à construire une région critique  $\mathcal{R}$  de telle sorte que l'on rejette  $H_0$  lorsque  $(x_1, \dots, x_n) \in \mathcal{R}$  et que l'on s'assure que le risque de 1ère espèce est inférieur ou égal à  $\alpha$ .

Dans ce cadre, on parle de **fonction de risque de 1ère espèce** définie sur  $\Theta_0$  pour

$$\theta \rightarrow \alpha(\theta) = \mathbb{P}_\theta((X_1, \dots, X_n) \in \mathcal{R}).$$

On appelle **taille du test** la probabilité maximale de rejeter  $H_0$  alors que  $H_0$  est vraie:

$$\sup_{\theta \in \Theta_0} \{\mathbb{P}_\theta((X_1, \dots, X_n) \in \mathcal{R})\}.$$

On dit qu'un test est de **niveau**  $\alpha$  si sa taille est égale à  $\alpha$  ie si

$$\sup_{\theta \in \Theta_0} \{\mathbb{P}_\theta((X_1, \dots, X_n) \in \mathcal{R})\} = \alpha.$$

On parle de **fonction de risque de 2nde espèce** définie sur  $\Theta_1$  pour

$$\theta \rightarrow \beta(\theta) = \mathbb{P}_\theta((X_1, \dots, X_n) \notin \mathcal{R}).$$

On parle de **fonction puissance** définie sur  $\Theta_1$  pour

$$\theta \rightarrow 1 - \beta(\theta) = \mathbb{P}_\theta((X_1, \dots, X_n) \in \mathcal{R}).$$

• **Introduction à la régression:**

Le but de tout modèle de régression (d'une manière générale) est de spécifier une relation (de nature stochastique) entre une variable  $Y$  appelée variable à expliquer (ou variable de réponse ou variable endogène ou variable dépendante) et un certain nombre de variables explicatives  $X^{(1)}, \dots, X^{(p)}$  (ou variables de contrôle ou variables exogènes ou régresseurs ou covariables). Ici, on supposera que les covariables sont de loi continue.

Notons  $(Y_i, X_i^{(1)}, \dots, X_i^{(p)})$  pour  $i = 1, \dots, n$  les observations recueillies sur  $n$  individus que l'on suppose distribuées comme  $(Y, X^{(1)}, \dots, X^{(p)})$ . Le modèle de régression linéaire gaussien standard à  $n$  observations indépendantes s'écrit sous la forme générique suivante:

$$Y_i = \beta_0 + \sum_{k=1}^p \beta_k X_i^{(k)} + \varepsilon_i, \quad \text{où } \varepsilon_i \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2). \quad (1)$$

Le modèle de régression linéaire gaussien standard repose donc sur les hypothèses suivantes:

(M<sub>1</sub>) **normalité**: conditionnellement à  $X_i^{(1)}, \dots, X_i^{(p)}$ , la variable de réponse  $Y_i$  suit la loi normale.

(M<sub>2</sub>) **homoscédasticité**: les lois conditionnelles de  $Y_i$  sachant  $X_i^{(1)}, \dots, X_i^{(p)}$  ont même variance donc pour  $i = 1, \dots, n$ , on a  $\sigma_i^2 = \sigma^2$ .

(M<sub>3</sub>) **linéarité**: le prédicteur linéaire  $\eta_i = \beta_0 + \sum_{k=1}^p \beta_k X_i^{(k)}$  est une combinaison affine des covariables, la linéarité s'apprécie relativement à la linéarité de  $\eta_i$  en les paramètres. Attention, la linéarité du modèle ne doit pas prêter à confusion: un modèle dit linéaire est linéaire en les paramètres  $\beta_0, \beta_1, \dots, \beta_p$ . Ainsi, le modèle de régression linéaire simple

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

est, comme son nom l'indique, linéaire, tout comme l'est le modèle de régression linéaire multiple ( $p > 1$ ):

$$Y = \beta_0 + \sum_{k=1}^p \beta_k X^{(k)} + \varepsilon.$$

Le modèle de régression polynomiale

$$Y = \beta_0 + \beta_1 X^{(1)} + \beta_2 (X^{(1)})^2 + \varepsilon$$

est un modèle linéaire bien que la relation entre  $Y$  et  $X^{(1)}$  soit quadratique. En revanche, un modèle de la forme

$$Y = \beta_0 + \beta_1 \exp(\beta_2 X^{(1)} + \beta_3 X^{(2)}) + \varepsilon_i$$

ou bien de la forme

$$Y = \frac{\exp(\beta_0 + \beta_1 X)}{1 + \exp(\beta_0 + \beta_1 X)} + \varepsilon$$

n'est pas linéaire!

(M<sub>4</sub>) **centrage des erreurs**:  $\mathbb{E}[\varepsilon_i] = 0$  pour  $i = 1, \dots, n$ .

Remarquons que cela équivaut à l'existence d'une relation "identité" entre le prédicteur linéaire  $\eta_i$  d'une part et l'espérance conditionnelle de la variable réponse d'autre part:

$$\mu_i := \mathbb{E}[Y_i | X_i^{(1)}, \dots, X_i^{(p)}] = \eta_i := \beta_0 + \sum_{k=1}^p \beta_k X_i^{(k)}.$$

(M<sub>5</sub>) **non-corrélation**: les vecteurs  $(Y_i, X_i^{(1)}, \dots, X_i^{(p)})$  sont non-corrélés pour  $i = 1, \dots, n$ . Si la normalité est effectivement respectée, cela revient alors à dire que les vecteurs  $(Y_i, X_i^{(1)}, \dots, X_i^{(p)})$  sont mutuellement indépendants.

(M<sub>6</sub>) **exogénéité = non-endogénéité**:  $(X_i^{(1)}, \dots, X_i^{(p)})$  est indépendant de  $\varepsilon_i$ , pour  $i = 1, \dots, n$ .

(M<sub>7</sub>) **non-colinéarité des covariables**: les covariables sont non-corrélées entre elles, ce qui se traduit en pratique par le fait que les vecteurs  $(X_1^{(k)}, \dots, X_n^{(k)})$  sont non-colinéaires pour  $k = 1, \dots, p$ . On écartera également le cas trivial où l'un de ces vecteurs serait colinéaire au vecteur de longueur  $n$  dont toutes les composantes sont égales à 1.

• **Test de Student sur l'effet des covariables:**

Dans le cadre du modèle linéaire gaussien standard présenté ci-dessus, on se demande si les covariables introduites dans le modèle ont un effet statistiquement significatif ou non. Autrement dit, on souhaite tester au niveau de risque  $\alpha$  l'hypothèse nulle  $H_0: \beta_j = 0$  contre l'hypothèse alternative  $H_1: \beta_j \neq 0$ , ceci pour un  $j \in \{1, \dots, p\}$  fixé quelconque. Pour cela, on s'intéressera ici au test de Student qui est fondé sur l'estimateur des moindres carrés ordinaires (qui coïncide ici avec l'EMV) de  $\beta_j$  que l'on notera  $\hat{\beta}_j$ . Notons  $\widehat{\text{Var}}(\hat{\beta}_j)$  un estimateur de la variance de  $\hat{\beta}_j$ . La statistique de test de Student pour le test de  $H_0: \beta_j = 0$  s'écrit:

$$T_n^{(j)} = \frac{\hat{\beta}_j}{\sqrt{\widehat{\text{Var}}(\hat{\beta}_j)}}.$$

Sous  $H_0$ , la loi de  $T_n$  est une loi de Student à  $(n - (p + 1))$  degrés de liberté.

Le logiciel R permet d'effectuer simplement ces calculs. Pour ajuster un modèle linéaire sur un échantillon  $(Y_i, X_i^{(1)}, \dots, X_i^{(p)})_{i=1, \dots, n}$ , on stockera les  $n$  valeurs des  $Y_i$  dans un vecteur  $\mathbf{y}$ , puis, pour  $k = 1, \dots, p$  on stockera les  $n$  valeurs des  $X_i^{(k)}$  dans un vecteur  $\mathbf{xk}$ . Le modèle linéaire est alors ajusté au moyen de l'instruction suivante (où  $p = 3$ )

```
mylm <- lm(y ~ x1 + x2 + x3)
```

et le résultat est stocké dans l'objet `mylm`. Pour accéder à l'ensemble des quantités calculées, on peut exécuter l'instruction suivante:

```
summary(mylm)
```

Sont notamment calculées, les estimations des  $\beta_j$  pour  $j = 0, \dots, p$ , les estimations de leurs écarts-types, la statistique de test de Student correspondante et la p-valeur du test associé. L'objet `summary(mylm)` est une liste dont on peut récupérer chacune des composantes qui nous intéresse. Pour cela, l'instruction `str(summary(myfit))` permet de voir le nom et la structure des différentes composantes de cette liste.

**Exercice 1.**

1. Illustrer de manière empirique à partir de données simulées le comportement de la taille du test.
2. Illustrer de manière empirique à partir de données simulées le comportement de la fonction puissance.

Vous veillerez à faire varier tour à tour:

- le risque de 1ère espèce  $\alpha$ ,
- la taille de l'échantillon  $n$ ,
- le cas échéant l'ampleur de l'écart à  $H_0$ .

Que pensez-vous de la robustesse du test de Student à la bonne spécification du modèle (cf les hypothèses  $(\mathbf{M}_1)$ - $(\mathbf{M}_7)$ )?

NB: on dit que le modèle est bien spécifié lorsqu'il correspond effectivement au mécanisme ayant servi à générer les données.