

---

## Problème – Minimisation de l’erreur de prédiction

Dans ce problème, on s’intéresse à l’erreur de prédiction dans le modèle linéaire. On travaille ici avec un modèle linéaire, non supposé gaussien, et on note  $\sigma^2$  la variance (constante) du bruit.

**Première partie : cas à une variable explicative.** On cherche à apprendre le modèle linéaire suivant pour prédire le réel  $Y_i$  en fonction d’une variable explicative réelle  $z_i$  :

$$\forall 1 \leq i \leq n, \quad Y_i = \beta_0 + \beta_1 z_i + \varepsilon_i.$$

On notera  $\bar{y}$  et  $\bar{z}$  les moyennes empiriques de  $z = (z_1, \dots, z_n)^T$  et de  $Y = (Y_1, \dots, Y_n)^T$  (attention, elles dépendent de  $n$ ). On suppose que le modèle est identifiable et on note  $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1)$  l’estimateur des moindres carrés de  $\beta$ .

Sous le même modèle, on observe une nouvelle valeur  $z_{n+1}$  de la variable explicative et on cherche à prédire la variable réponse  $Y_{n+1}$  avec l’estimateur

$$\hat{y}_{n+1} := \hat{\beta}_0 + \hat{\beta}_1 z_{n+1} = x_{n+1}^T \hat{\beta}, \quad \text{où } x_{n+1} := \begin{bmatrix} 1 \\ z_{n+1} \end{bmatrix}.$$

L’erreur de prédiction est définie par :

$$\text{err}(z_{n+1}) := \mathbb{E} [(Y_{n+1} - \hat{y}_{n+1})^2].$$

*Notons que dans cette espérance, l’aléa vient du bruit  $\varepsilon_{n+1}$  dans  $Y_{n+1}$  ainsi que de l’aléa dans le  $\hat{\beta}$ .*

1. Redémontrer que si  $S$  est un vecteur aléatoire de  $\mathbb{R}^m$  de matrice de covariance (finie)  $C$ , alors pour tout vecteur  $u \in \mathbb{R}^m$ ,  $\text{Var}(u^T S) = u^T C u$ .
2. Que vaut  $\mathbb{E}[Y_{n+1} - \hat{y}_{n+1}]$  ?
3. Ecrire la matrice  $X$  du plan d’expérience dans ce modèle (on mettra l’intercept dans la première colonne), et montrer que

$$(X^T X)^{-1} = \frac{1}{nv(z)} \begin{bmatrix} \frac{1}{n} \sum_{i=1}^n z_i^2 & -\bar{z} \\ -\bar{z} & 1 \end{bmatrix},$$

avec  $v(z)$  la variance empirique de  $z$ .

4. En utilisant les résultats des questions 1, 2 et 3, montrer que

$$\text{err}(z_{n+1}) = \sigma^2 \left( 1 + \frac{1}{n} + \frac{(z_{n+1} - \bar{z})^2}{\sum_{i=1}^n (z_i - \bar{z})^2} \right).$$

5. Pour quelle(s) valeur(s) de  $z_{n+1}$  l’erreur de prédiction est-elle minimale ? Interpréter ce résultat.
6. Quelle est la limite de l’erreur de prédiction minimale lorsque  $n \rightarrow \infty$  ? Interpréter cette valeur limite.

**Deuxième partie : cas général.** Nous considérons cette fois-ci le cas général à plusieurs covariables. Ici, pour tout  $1 \leq i \leq n$ ,

$$Y_i = \beta_0 + \beta_1 z_{1,i} + \dots + \beta_p z_{p,i} + \varepsilon_i.$$

---

On note

$$Z := \left[ \begin{array}{c|c|c} z_1 & \dots & z_p \end{array} \right] \in \mathbb{R}^{n \times p},$$

avec pour tout  $1 \leq \ell \leq p$ ,  $z_\ell := [z_{\ell,1} \ \dots \ z_{\ell,n}]^T \in \mathbb{R}^n$ . On note  $\bar{z}$  le vecteur des moyennes empiriques  $\bar{z} := [\bar{z}_1 \ \dots \ \bar{z}_p]^T \in \mathbb{R}^p$  (dont les entrées dépendent de  $n$ ).

7. En notant  $\beta = [\beta_0 \ \beta_1 \ \dots \ \beta_p]^T$ , écrire le modèle matriciellement sous la forme  $Y = X\beta + \varepsilon$  en précisant  $X$ .

8. Ecrire la matrice  $X^T X$  sous forme de 4 blocs faisant intervenir  $Z$ ,  $\bar{z}$  et  $n$ .

Dans toute la suite, on suppose que le modèle est identifiable.

9. On donne la formule d'inversion matricielle par blocs : soit  $A$  une matrice inversible s'écrivant par blocs  $A = \begin{bmatrix} T & U \\ V & W \end{bmatrix}$  avec  $T$  inversible. Alors  $Q = W - VT^{-1}U$  est inversible et l'inverse de  $A$  est :

$$A^{-1} = \begin{bmatrix} T^{-1} + T^{-1}UQ^{-1}VT^{-1} & -T^{-1}UQ^{-1} \\ -Q^{-1}VT^{-1} & Q^{-1} \end{bmatrix}.$$

On note  $\Gamma := \frac{1}{n}Z^T Z - \bar{z}\bar{z}^T$ . Ecrire la matrice  $(X^T X)^{-1}$  sous la forme d'une matrice par blocs en fonction de  $n$ ,  $\bar{z}$  et  $\Gamma^{-1}$ .

10. Comme dans la première partie, on observe désormais un vecteur

$$x_{n+1} = (1, z_{n+1}) = (1, z_{1,n+1}, \dots, z_{\ell,n+1})$$

et l'on cherche à prédire la variable réponse  $Y_{n+1}$  avec l'estimateur  $\hat{y}_{n+1} := x_{n+1}^T \hat{\beta}$ . L'erreur de prédiction est définie comme précédemment.

Exprimer  $\text{err}(z_{n+1})$  en fonction de  $n$ , de  $\sigma^2$ , du vecteur  $(z_{n+1} - \bar{z})$  et de la matrice  $\Gamma^{-1}$ .

11. On admet dans cette question que  $\Gamma$  est symétrique définie positive. Pour quelle(s) valeur(s) de  $z_{n+1}$  l'erreur de prédiction est-elle minimale ?

12. (★) Montrer que  $\Gamma = \frac{1}{n}Z^T Z - \bar{z}\bar{z}^T$  est bien symétrique définie positive. On pourra chercher à l'écrire sous la forme  $\frac{1}{n}WW^T$  avec  $W$  une matrice bien choisie.