

## TD 6 : modèle linéaire

Les questions marquées d'un astérisque (\*) sont facultatives.

**Exercice 1. (Régression polynomiale)** Soit  $n \in \mathbb{N}^*$ . On considère le modèle de régression polynomiale : pour tout  $i \in \{1, \dots, n\}$ ,

$$Y_i = \beta_0 + \beta_1 X_i + \dots + \beta_{m-1} X_i^{m-1} + \varepsilon_i.$$

1. Écrire ce modèle linéaire sous forme matricielle  $Y = \mathbf{X}\beta + \varepsilon$ .
2. (\*) Montrer que si  $m = n$ ,  $\det(\mathbf{X}) = \prod_{1 \leq i < j \leq n} (X_j - X_i)$  (déterminant de matrices de Vandermonde).

*Indication : montrer que ce déterminant est un polynôme de degré  $n(n-1)/2$  en les  $X_i$ , regarder quand il s'annule, et calculer le coefficient de son monôme  $X_2 X_3^2 \dots X_n^{n-1}$ .*

On suppose les  $X_i$  distincts et  $m \leq n$ .

3. Montrer que  $\mathbf{X}^\top \mathbf{X}$  est inversible et écrire l'estimateur des moindres carrés.

**Exercice 2. (Coefficient de détermination)** Soit  $n \in \mathbb{N}^*$ . On considère le modèle linéaire  $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$  pour  $i \in \{0, \dots, n\}$ , avec  $Y_i, X_i \in \mathbb{R}$ . On note  $\hat{\beta}$  l'estimateur des moindres carrés de  $\beta$ ,  $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$  et  $\bar{Y}_n$  la moyenne empirique des  $Y_i$ .

1. Montrer que  $\sum_{i=1}^n (Y_i - X_i \hat{\beta}) = 0$  et que  $\sum_{i=1}^n (Y_i - X_i \hat{\beta}) X_i = 0$ .
2. En déduire  $\sum_{i=1}^n (Y_i - \hat{Y}_i)(\hat{Y}_i - \bar{Y}_n) = 0$ .
3. Prouver que  $\sum_{i=1}^n (Y_i - \bar{Y}_n)(\hat{Y}_i - \bar{Y}_n) = \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2$ .
4. Démontrer que  $\sum_{i=1}^n (\hat{Y}_i - Y_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2 = \sum_{i=1}^n (Y_i - \bar{Y}_n)^2$ .

Le coefficient de détermination est défini comme le rapport

$$R^2 = \frac{\left( \sum_{i=1}^n (Y_i - \bar{Y}_n)(\hat{Y}_i - \bar{Y}_n) \right)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_n)^2 \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2}.$$

5. En utilisant les questions précédentes, montrer que

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_n)^2} = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_n)^2}$$

**Exercice 3. (Régression ridge)** Dans un modèle linéaire  $Y = \mathbf{X}\beta + \varepsilon$ , lorsque la matrice  $\mathbf{X}^\top \mathbf{X}$  n'est pas ou presque pas inversible, l'estimateur des moindres carrés peut ne pas être défini ou être instable et prendre des valeurs anormalement grandes. L'estimateur ridge a été introduit pour résoudre ce problème : c'est le minimiseur du critère des moindres carrés pénalisé

$$\|Y - \mathbf{X}\beta\|^2 + \lambda \|\beta\|^2,$$

où  $\lambda > 0$ . La différence par rapport à l'estimateur des moindres carrés habituel est le terme  $\lambda \|\beta\|^2$ , qui assure que  $\beta$  ne prend pas de trop grandes valeurs.

1. Montrer que le gradient en  $\beta$  du critère des moindres carrés pénalisé s'écrit  $-2(Y - \mathbf{X}\beta)^\top \mathbf{X} + 2\lambda\beta^\top$ .
2. En déduire une matrice  $M$  telle que le minimiseur de ce critère s'écrit  $\hat{\beta} = M^{-1} \mathbf{X}^\top Y$ .
3. Commenter : la matrice  $M$  est-elle inversible ? Est-elle sujette à instabilité comme  $\mathbf{X}^\top \mathbf{X}$  ?