



X

Bonus : Régression linéaire

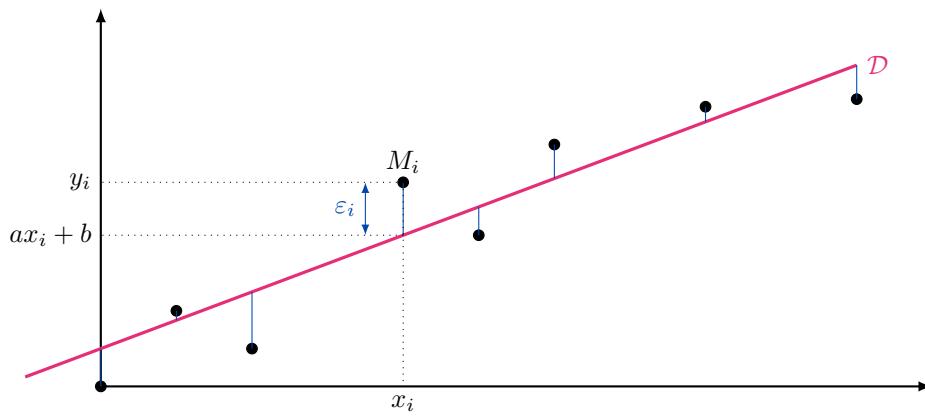
Introduction

Lors d'expériences visant à comparer des données expérimentales à un modèle mathématique, il apparaît souvent des erreurs de mesure ; des points $M_i = (x_i, y_i)$ qui devraient être alignés (ou suivre un modèle) ne sont pas alignés, mais sont "presque" sur une même droite \mathcal{D} .

On cherche *une* droite \mathcal{D} , d'équation $y = ax + b$ qui passe *au plus près* des n points du nuage, c'est à dire, en notant $\varepsilon_i = y_i - (ax_i + b)$ qui *minimise* la quantité

$$\Delta(a, b) = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - (ax_i + b))^2.$$

Effectuer une régression linéaire, ou appliquer la méthode des moindres carrés, revient à déterminer les valeurs de a et de b (et donc l'équation de la droite \mathcal{D}) qui minimise Δ .



On propose ci-après de retrouver les formules pour a et pour b avec deux méthodes différentes : une projection orthogonale et une étude de fonction de deux variables.

On renvoie aux **Chapitres 11 & 14** du cours pour les détails théoriques et au **TP n°8** pour la pratique.

Méthode 1 : Projection orthogonale

On équipe \mathbb{R}^n de sa structure euclidienne canonique. Notons $X = (x_1, x_2, \dots, x_n)$ le vecteur de \mathbb{R}^n dont les composantes sont les abscisses des points du nuage, $Y = (y_1, \dots, y_n)$ celui avec les ordonnées des points du nuage et $\mathbf{1} = (1, 1, \dots, 1)$ le vecteur dont toutes les composantes sont égales à 1.

On observe alors que

$$\Delta(a, b) = \|Y - (aX + b\mathbf{1})\|^2.$$

Ainsi, en notant $F = \text{Vect}(X, \mathbb{1})$ le sous-espace de \mathbb{R}^n engendré par X et par $\mathbb{1}$, le cours permet d'affirmer que le minimum cherché est atteint à l'aide du projeté orthogonal $p_F(Y)$ de Y sur F :

$$\min_{a,b \in \mathbb{R}} \Delta(a,b) = \min_{a,b \in \mathbb{R}} \|Y - (aX + b\mathbb{1})\|^2 = \min_{Z \in F} \|Y - Z\|^2 = \|Y - P_F(Y)\|.$$

On sait alors parfaitement obtenir l'expression du projeté orthogonal (sinon, on ira vite relire le chapitre susmentionné). Commençons par obtenir une base orthonormée (b.o.n) de F par le procédé de Gram-Schmidt :

$$\tilde{\mathbb{1}} = \frac{1}{\|\mathbb{1}\|} \mathbb{1} = \frac{1}{\sqrt{n}} (1, 1, \dots, 1).$$

Ensuite on commence par trouver X' orthogonal à $\tilde{\mathbb{1}}$, qu'on normalisera ensuite.

$$X' = X - \langle X, \tilde{\mathbb{1}} \rangle \tilde{\mathbb{1}} = (x_1 - \bar{x}, \dots, x_n - \bar{x}),$$

où on a noté $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ la moyenne des x_i . On notera de même \bar{y} la moyenne des y_i . Une fois normalisé, on prend donc

$$\tilde{X} = \frac{1}{\|X'\|} X' = \frac{1}{\sqrt{\sum_{j=1}^n (x_j - \bar{x})^2}} (x_1 - \bar{x}, \dots, x_n - \bar{x}).$$

Il suit que :

$$\begin{aligned} P_F(Y) &= \langle Y | \tilde{\mathbb{1}} \rangle \tilde{\mathbb{1}} + \langle Y | \tilde{X} \rangle \tilde{X} \\ &= (\bar{y}, \dots, \bar{y}) + \frac{\sum_{i=1}^n y_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} (x_1 - \bar{x}, \dots, x_n - \bar{x}) \\ &= \frac{\sum_{i=1}^n y_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} X + \left(\bar{y} - \left(\frac{\sum_{i=1}^n y_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \right) \bar{x} \right) \mathbb{1} = aX + b\mathbb{1}. \end{aligned}$$

En notant $\sigma_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \|X\|^2 - \bar{x}^2$ (on pourra réfléchir au choix de cette notation), on conclut que

$$a = \frac{\sum_{i=1}^n y_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\frac{1}{n} \sum_{i=1}^n y_i x_i - \bar{x} \cdot \bar{y}}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\frac{1}{n} \langle X | Y \rangle - \bar{x} \cdot \bar{y}}{\sigma_x^2}, \quad b = a \cdot \bar{y} - \bar{x}.$$

Le point de coordonnées (\bar{x}, \bar{y}) s'appelle le **point moyen** du nuage ; on observe que la droite de régression passe par le point moyen.

Méthode 2 : Point critique d'une fonction de deux variables

On montre dans cette section qu'on retrouve les résultats précédents (la valeur de a et b qui minimise Δ) en montrant que Δ présente un minimum (local) en (a, b) qui donc un point critique.

On a :

$$\begin{aligned} \frac{\partial \Delta}{\partial a}(a, b) &= 2 \left(\sum_{i=1}^n x_i^2 \right) a + 2 \left(\sum_{i=1}^n x_i \right) b - 1 \sum_{i=1}^n x_i y_i \\ \frac{\partial \Delta}{\partial b}(a, b) &= 2 \left(\sum_{i=1}^n x_i \right) a + 2nb - 2 \sum_{i=1}^n y_i \end{aligned}$$

On trouve le(s) point(s) critique(s) en résolvant un système linéaire, dont on omet les étapes ici

$$(a, b) \text{ point critique de } \Delta \iff \nabla \Delta(a, b) = 0$$

$$\iff \begin{cases} a &= \frac{\sum_{i=1}^n y_i \sum_{j=1}^n x_j - n \sum_{i=1}^n x_i y_i}{\left(\sum_{i=1}^n x_i\right)^2 - n \sum_{i=1}^n x_i^2} = \frac{1}{n} \langle X | Y \rangle - \bar{x} \cdot \bar{y} \\ b &= \frac{\sum_{i=1}^n y_i - a \sum_{i=1}^n x_i}{n} = \bar{y} - a \cdot \bar{x} \end{cases}$$

Il s'agit des mêmes valeurs que précédemment, on vérifie que c'est un minimum local en explicitant sa matrice hessienne :

$$H_\Delta(a, b) = \begin{pmatrix} 2 \sum_{i=1}^n x_i^2 & 2 \sum_{i=1}^n x_i \\ 2 \sum_{i=1}^n x_i & 2n \end{pmatrix},$$

qu'on remarque indépendante de a et b (bien que ce soit aux valeurs de a et b calculées précédemment qu'elle nous intéresse, et pas ailleurs, car c'est le seul point critique). Par Cauchy-Schwarz,

$$\langle X | 1 \rangle^2 = \left(\sum_{i=1}^n x_i \right)^2 < \|X\|^2 \|1\|^2 = n \sum_{i=1}^n x_i^2,$$

et donc

$$\det(H_\Delta(a, b)) = 4 \left(n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 \right) > 0$$

on a bien un extremum et

$$\text{Tr}(H_\Delta(a, b)) = 2 \left(n + \sum_{i=1}^n x_i^2 \right) > 0$$

c'est donc bien un minimum (local). Easy.

Coefficient de corrélation linéaire

Définition 1.1.

Coefficient de corrélation linéaire

On appelle coefficient de corrélation linéaire la quantité $\rho_{X,Y}$ souvent simplement notée ρ définie par

$$\rho = \frac{\frac{1}{n} \langle X | Y \rangle - \bar{x} \cdot \bar{y}}{\|X\| \|Y\|}.$$

Proposition.

Soit ρ le coefficient de corrélation linéaire du couple (X, Y) . Alors

- i. $\rho \in [-1; 1]$;
- ii. $\rho = \pm 1$ si et seulement si la régression $Y = aX + b$ est exacte.

☞ Il paraît alors assez naturel de penser que si ρ est "assez proche" de 1 (en valeur absolue), l'approximation *affine* pourrait être pertinente.

Si $|\rho|$ est proche de 1 et qu'on a visualisé une relation linéaire entre les données, on peut confirmer qu'il y a bien corrélation linéaire entre X et Y .

☞ En sciences humaines, en sciences économiques et en sciences physiques, une valeur de $|\rho|$ de l'ordre de 0,85 est souvent considérée comme bonne et justifie la pertinence de la régression linéaire.

Régression linéaire avec transformations

Dans certains cas, on peut appliquer le principe de régression linéaire à un couple obtenu par transformées de Y (ou aussi de X) et obtenir une relation de la forme

$$Y \simeq a\varphi(X) + b, \quad \text{ou} \quad \varphi(Y) \simeq a\varphi(X) + b.$$

Considérons un exemple avec des données correspondant à l'évolution du PIB par habitant (en USD) et du pourcentage de la population en zone urbaine de la Norvège, de 1960 à 2020 (source: [World Bank Data](#)).

1. Recopier et exécuter les instructions suivantes. Commenter le nuage de points.

```
import pandas as pd
data2=pd.read_csv('http://frederic.gaunard.com/2223/tp2_nor.csv', sep=';')

X=data2['PIB per capita']
Y=data2['Pop urbaine %']

plt.grid()
plt.plot(X,Y, '.') # nuage de points
plt.show()
```

2. Représenter le nuage de points $(\ln(X), Y)$.
3. Calculer le coefficient de corrélation linéaire de Y en $\ln(X)$.
4. Déterminer l'équation de la droite de régression de Y en $\ln(X)$.
5. En déduire qu'on peut supposer que la dépendance entre Y et X est de la forme

$$Y = a \ln(X) + b.$$

6. Représenter le nuage de points précédent sur lequel on fera apparaître la courbe d'équation $y = a \ln(t) + b$.

