

APPLICATION 2: MOINDRE CARRÉS,
RÉGRESSION LINÉAIRES + VARIANTES

1. Projection orthogonale.

Rappel. E, F supplémentaires s' $\mathbb{R}^n = E \oplus F$
 $\hookrightarrow P_{E/F}$ = proj. sur E parallèlement à F .

(i) Produit scalaire et norme

- $\vec{u} = (x_1, \dots, x_n), \vec{v} = (y_1, \dots, y_n) \in \mathbb{R}^n,$
- $\langle \vec{u}, \vec{v} \rangle = x_1 y_1 + x_2 y_2 + \dots + x_n y_n \in \mathbb{R}$
 produit scalaire de \vec{u} et \vec{v} .
- $(\langle \vec{u}, \vec{u} \rangle)^{1/2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2} \in \mathbb{R}^+$
 norme (euclidienne) de \vec{u} .

- (ii) $\vec{u} = \vec{0} \iff \langle \vec{u}, \vec{u} \rangle = 0,$
- $\vec{u} \perp \vec{v} \iff \langle \vec{u}, \vec{v} \rangle = 0.$

Def. E un sev de \mathbb{R}^n , on définit le **sev orthogonal** à E , E^\perp , comme l'ensemble des vecteurs

orthogonaux à E ;
 $E^\perp = \{ \vec{v} \in \mathbb{R}^n \mid \forall \vec{u} \in E, \langle \vec{u}, \vec{v} \rangle = 0 \} -$

$\mathcal{F} = (\vec{u}_1, \dots, \vec{u}_p)$

Thm. E sev de \mathbb{R}^n .

- 1. E^\perp sev de \mathbb{R}^n ,
- 2. Si \mathcal{F} engendre E (i.e $E = \text{vect}(\mathcal{F})$)
 $E^\perp = \{ \vec{v} \in \mathbb{R}^n \mid \forall \vec{u}_i \in \mathcal{F}, \langle \vec{u}_i, \vec{v} \rangle = 0 \}.$

3. $\mathbb{R}^n = E \oplus E^\perp$ (E, E^\perp supplémentaires).

dém. 1 et 2 viennent de la linéarité du produit scalaire (\vec{u} fixé, $\vec{v} \mapsto \langle \vec{u}, \vec{v} \rangle$),
3. admis - □

Def. Soit E un sev, on définit la **projection orthogonale de \mathbb{R}^n sur E** , notée P_E , la projection de \mathbb{R}^n sur E parallèlement à E^\perp .
 i.e $P_E = P_{E/E^\perp}$

Thm. (Pythagore). Si $\vec{u} \perp \vec{v}$, alors
 $\|\vec{u} + \vec{v}\|^2 = \|\vec{u}\|^2 + \|\vec{v}\|^2$.

dém. $\|\vec{u} + \vec{v}\|^2 = \langle \vec{u} + \vec{v}, \vec{u} + \vec{v} \rangle$
 $= \langle \vec{u}, \vec{u} \rangle + \langle \vec{u}, \vec{v} \rangle + \langle \vec{v}, \vec{u} \rangle + \langle \vec{v}, \vec{v} \rangle$
 $= \|\vec{u}\|^2 + \|\vec{v}\|^2$ \square

Caractérisation géométrique de la proj. orthogonale.

Thm E un sev de \mathbb{R}^n , P_E proj. orthog. sur E .
 Soit $\vec{u} \in \mathbb{R}^n$, $P_E(\vec{u})$ est le vecteur de
 E le plus proche de \vec{u} : \leftarrow le "moindre carré"
 $\forall \vec{v} \in E, \|\vec{v} - \vec{u}\|^2 \geq \|P_E(\vec{u}) - \vec{u}\|^2$
 avec égalité si et seulement si $\vec{v} = P_E(\vec{u})$.

dém. Par Pythagore,
 $\vec{v}_1, \vec{v}_2 \in E$, les segments gris sont tous plus longs que le segment bleu sauf si $\vec{v} = P_E(\vec{u})$.

$$\vec{v} - \vec{u} = \underbrace{(\vec{v} - P_E(\vec{u}))}_{\in E} + \underbrace{(P_E(\vec{u}) - \vec{u})}_{\in E^\perp}$$

Donc par Pythagore: $\|\vec{u} - P_E(\vec{u})\|^2 = \|\vec{u} - P_E(\vec{u})\|^2 + \|\vec{v} - P_E(\vec{u})\|^2$

$$\|\vec{v} - \vec{u}\|^2 = \|\vec{v} - P_E(\vec{u})\|^2 + \|P_E(\vec{u}) - \vec{u}\|^2$$

$$\geq 0 \text{ et } = 0 \text{ si } \vec{v} = P_E(\vec{u}) \quad \square$$

2. Régression linéaire:

Idee: Étant données 2 séries de données de même taille (x_1, \dots, x_n) et (y_1, \dots, y_n) , on veut déterminer la droite de \mathbb{R}^2 la plus proche $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$.

Si $\forall i, x_i = x_0$ constante, alors la droite verticale d'équation $x = x_0$ passe par tous les points.

Si non on cherche $a, b \in \mathbb{R}$ tq $Y = (2X + 6U)$ soit minimal, où $U = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$ en colonne!

On forme la matrice $M = (X \mid U)$ et on veut minimiser $\|M \begin{pmatrix} a \\ b \end{pmatrix} - Y\|^2$.

$C = \begin{pmatrix} 2 \\ 6 \end{pmatrix}$ "vecteur coefficients" est cherché tq $\|nC - y\|^2$ est minimal.

Rmq. nC = élément de l'image de n .

i.e on cherche l'élément de l'image de n le plus proche de y

i.e on cherche le projeté orthogonal de y sur l'image de n :

$$C \text{ tq } nC = P_{\text{im}(n)}(y)$$

Il y a des formules (horribles!) en fonction $x_1, \dots, x_n, y_1, \dots, y_n$ pour déterminer C .

En pratique, méthode lstsq de np.linalg

(Least Squares = moindres carrés).

- import numpy as np
- X, Y donné, $n = \begin{pmatrix} 1 \\ x \end{pmatrix}$, y colonne.
- $C = \text{np.linalg.lstsq}(n, y, rcond = \text{None})[0]$
éviter mes. error



renvoie $[[2], [6]]$.

• $2, 6 = C[:, 0]$ so $y = 2x + 6$ est la droite de la régression linéaire.

É l'ensemble des \tilde{y} obtenus de x via une transformation affine $2x + 6$.

3. Qualité de l'approximation.

def. Le coefficient de corrélation de y par rapport à $\tilde{y} \in E$ est le nombre $r = \cos \theta \in [0, 1]$ où $\cos \theta = \frac{\|P_E(y)\|}{\|y\|}$.




Dans notre cas, X, Y so $C \text{ tq } nC = P_E(y)$

Donc $P_E(y) = n \cdot C$ ($P = \text{np.dot}(n, C)$)
et $r^2 = \text{np.dot}(P, \text{transpose}(P)) / \text{np.dot}(y, \text{transpose}(y))$.

$$(\langle \vec{u}, \vec{u} \rangle = U^T \cdot U = (x_1, \dots, x_n) \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} -)$$

4. Variantes.

2. Vous représentez les données, s'il est clair que la régression linéaire est inadéquate.



6. On trouve a, b , et $r^2 < 0,5$ no changer de modèle.

oui mais en gardant la puissance des moindres carrés.

(i) Approximation quadratique - $y_i \approx ax_i^2 + bx_i + c$

On forme $M = (X^2 | X | U)$.

$$\begin{pmatrix} x_1^2 \\ \vdots \\ x_n^2 \end{pmatrix} \quad \begin{matrix} \nearrow \\ \searrow \end{matrix} \quad (2X^2 + 6X + cU) - Y$$

Trouver $C = \begin{pmatrix} a \\ b \\ c \end{pmatrix}$ tq $\|MC - Y\|^2$ est minimal.

(ii) Approximation sinusoïdale - $y_i \approx a + b \cos(\omega x_i) + c \sin(\omega x_i)$.

$$M = (U | \cos(\omega X) | \sin(\omega X))$$

$$X = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \quad \cos(\omega X) = \begin{pmatrix} \cos(\omega x_1) \\ \vdots \\ \cos(\omega x_n) \end{pmatrix} \quad \sin(\omega X) = \begin{pmatrix} \sin(\omega x_1) \\ \vdots \\ \sin(\omega x_n) \end{pmatrix}$$

On cherche $C = \begin{pmatrix} a \\ b \\ c \end{pmatrix}$ tq $\|MC - Y\|^2$ minimal.

(iii) Approximation exponentielle - $y_i \approx k e^{\alpha x_i}$

On applique \ln : $\ln(y_i) = \ln(k) + \ln(e^{\alpha x_i})$

$$= \underbrace{\ln k}_b + \underbrace{\alpha x_i}_a$$

$$M = (X | U)$$

$$C = \begin{pmatrix} a \\ b \end{pmatrix} \quad \text{avec } Y \text{ so } \ln Y = \begin{pmatrix} \ln y_1 \\ \vdots \\ \ln y_n \end{pmatrix}$$

$C = \text{lsq}$ ✓ et $\alpha = a$ et $k = e^b$

(iv) Plus de variables - $P_i \approx a + bT_i + cA_i + dG_i$

$$M = (U | T_i | A_i | G_i), \text{ on cherche } C = \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix}$$

tq $\|MC - Y\|^2$ minimal. ✓