



Régression linéaire dans \mathbb{R}^2

L3{*MA, Info_SI, Info_Reseaux*} - UFR S.A.T

Pr. Ousmane THIARE

`othiare@ugb.edu.sn`
[www.ousmanethiare.com]

16 avril 2020

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Régression linéaire dans \mathbb{R}^2

Notions d'espace vectoriel euclidien

Espace vectoriel \mathbb{R}^n

Soit n un entier strictement positif et \mathbb{R} le corps des nombres réels.

L'ensemble \mathbb{R}^n des n -uples (x_1, \dots, x_n) de nombres réels est muni de sa structure usuelle d'**espace vectoriel réel**, définie par les opérations :

$$\blacksquare (x_1, \dots, x_n) + (x'_1, \dots, x'_n) = (x_1 + x'_1, \dots, x_n + x'_n)$$

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression



Notions d'espace vectoriel euclidien

Espace vectoriel \mathbb{R}^n

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Soit n un entier strictement positif et \mathbb{R} le corps des nombres réels.

L'ensemble \mathbb{R}^n des n -uples (x_1, \dots, x_n) de nombres réels est muni de sa structure usuelle d'**espace vectoriel réel**, définie par les opérations :

- $(x_1, \dots, x_n) + (x'_1, \dots, x'_n) = (x_1 + x'_1, \dots, x_n + x'_n)$
- $l(x_1, \dots, x_n) = (lx_1, \dots, lx_n), l \in \mathbb{R}.$



Notions d'espace vectoriel euclidien

Espace vectoriel \mathbb{R}^n

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Soit n un entier strictement positif et \mathbb{R} le corps des nombres réels.

L'ensemble \mathbb{R}^n des n -uples (x_1, \dots, x_n) de nombres réels est muni de sa structure usuelle d'**espace vectoriel réel**, définie par les opérations :

- $(x_1, \dots, x_n) + (x'_1, \dots, x'_n) = (x_1 + x'_1, \dots, x_n + x'_n)$
- $l(x_1, \dots, x_n) = (lx_1, \dots, lx_n), l \in \mathbb{R}$.
- On identifiera un élément $X = (x_1, \dots, x_n)$ de \mathbb{R}^n avec la

matrice $X = \begin{pmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{pmatrix}$ à n lignes et 1 colonne.



Notions d'espace vectoriel euclidien

Opérations dans \mathbb{R}^n

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Les opérations dans \mathbb{R}^n sont alors définies par des opérations sur les matrices :

■ Addition :

$$\begin{pmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{pmatrix} + \begin{pmatrix} x'_1 \\ \vdots \\ x'_i \\ \vdots \\ x'_n \end{pmatrix} = \begin{pmatrix} x_1 + x'_1 \\ \vdots \\ x_i + x'_i \\ \vdots \\ x_n + x'_n \end{pmatrix}$$
$$(x_1, \dots, x_n) + (x'_1, \dots, x'_n) = (x_1 + x'_1, \dots, x_n + x'_n)$$



Notions d'espace vectoriel euclidien

Opérations dans \mathbb{R}^n

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

■ Multiplication par un scalaire :

$$l \begin{pmatrix} x_1 \\ \vdots \\ x_j \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} lx_1 \\ \vdots \\ lx_j \\ \vdots \\ lx_n \end{pmatrix}$$
$$l(x_1, \dots, x_n) = (lx_1, \dots, lx_n)$$



Notions d'espace vectoriel euclidien

Opérations dans \mathbb{R}^n

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

■ Multiplication par un scalaire :

$$l \begin{pmatrix} x_1 \\ \vdots \\ x_j \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} lx_1 \\ \vdots \\ lx_j \\ \vdots \\ lx_n \end{pmatrix}$$
$$l(x_1, \dots, x_n) = (lx_1, \dots, lx_n)$$

- Dans \mathbb{R}^n , les n éléments $e_i, i \in \{1, \dots, n\}$, dont toutes les coordonnées sont nulles, sauf la i^{me} qui vaut 1, forment une base, appelée la **base canonique** de \mathbb{R}^n .

Tout élément $X = (x_1, \dots, x_n)$ de \mathbb{R}^n s'écrit : $X = \sum_{i=1}^{i=n} x_i e_i$



Produit scalaire dans \mathbb{R}^n

Définition

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Soit F une application de $\mathbb{R}^n \times \mathbb{R}$ dans \mathbb{R} .

On notera aussi $\langle X|F|Y \rangle$ ou $\langle X|Y \rangle_F$, le nombre réel $F(X, Y)$.

On appelle produit scalaire dans \mathbb{R}^n , toute application F de $\mathbb{R}^n \times \mathbb{R}^n$ dans \mathbb{R} qui possède les propriétés suivantes :

a) Bilinéarité

- Linéarité par rapport à la première variable :

$$F(X + X', Y) = F(X, Y) + F(X', Y) \text{ et}$$

$$F(lX, Y) = lF(X, Y), \text{ quels que soient } l \text{ dans } \mathbb{R}, \\ X, X', Y \in \mathbb{R}^n ; \text{ cette propriété s'écrit aussi}$$

$$\langle X + X'|F|Y \rangle = \langle X|F|Y \rangle + \langle X'|F|Y \rangle$$



Produit scalaire dans \mathbb{R}^n

Définition

a) Bilinéarité

- Linéarité par rapport à la deuxième variable :

$$F(X, Y + Y') = F(X, Y) + F(X, Y') \text{ et}$$

$$F(X, lY) = lF(X, Y), \text{ quels que soient } l \text{ dans } \mathbb{R}, \\ X, X', Y \in \mathbb{R}; \text{ cette propriété s'écrit aussi}$$

$$\langle X|F|Y + Y' \rangle = \langle X|F|Y \rangle + \langle X|F|Y' \rangle$$

b) Symétrie

c) Positivité

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression



Produit scalaire dans \mathbb{R}^n

Définition

a) Bilinéarité

- Linéarité par rapport à la deuxième variable :

$$F(X, Y + Y') = F(X, Y) + F(X, Y') \text{ et}$$

$$F(X, lY) = lF(X, Y), \text{ quels que soient } l \text{ dans } \mathbb{R}, \\ X, X', Y \in \mathbb{R}; \text{ cette propriété s'écrit aussi}$$

$$\langle X|F|Y + Y' \rangle = \langle X|F|Y \rangle + \langle X|F|Y' \rangle$$

b) Symétrie

- $F(X, Y) = F(Y, X)$, quels que soient X et Y dans \mathbb{R}^n :

$$\langle X|F|Y \rangle = \langle Y|F|X \rangle$$

c) Positivité

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression



Produit scalaire dans \mathbb{R}^n

Définition

a) Bilinéarité

- Linéarité par rapport à la deuxième variable :

$$F(X, Y + Y') = F(X, Y) + F(X, Y') \text{ et}$$

$$F(X, lY) = lF(X, Y), \text{ quels que soient } l \text{ dans } \mathbb{R}, \\ X, X', Y \in \mathbb{R}; \text{ cette propriété s'écrit aussi}$$

$$\langle X|F|Y + Y' \rangle = \langle X|F|Y \rangle + \langle X|F|Y' \rangle$$

b) Symétrie

- $F(X, Y) = F(Y, X)$, quels que soient X et Y dans \mathbb{R}^n :

$$\langle X|F|Y \rangle = \langle Y|F|X \rangle$$

c) Positivité

- $F(X, X)$ est un nombre réel supérieur ou égal à 0, quel que soit X dans \mathbb{R}^n : $\langle X|F|X \rangle = 0$

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression



Produit scalaire dans \mathbb{R}^n

Définition

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

d) Non dégénérescence

- $F(X,X)=0$ entraîne $X=0_{\mathbb{R}^n}$:

$$\langle X|F|X \rangle = 0 \Rightarrow X = 0$$

Autrement dit, le vecteur $0 = (0, \dots, 0, \dots, 0)$ de \mathbb{R}^n est l'unique solution de l'équation $F(X,X)=0$.

On dit aussi qu'un produit scalaire sur \mathbb{R}^n est une **forme bilinéaire symétrique positive non dégénérée**. Le mot "forme" fait simplement référence au fait que les valeurs sont des scalaires. Lorsqu'il est muni d'un produit scalaire, \mathbb{R}^n est appelé un **espace vectoriel euclidien**.



Produit scalaire dans \mathbb{R}^n

Exemples

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

a) Produit scalaire canonique

- L'application de $\mathbb{R}^n \times \mathbb{R}^n$ dans \mathbb{R} définie par :

$$((x_1, \dots, x_n), (y_1, \dots, y_n)) \mapsto \langle X | Y \rangle = X^t Y =$$

$$(x_1 \dots, x_j, \dots, x_n) \begin{pmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{pmatrix} = \sum_{i=1}^{i=n} x_i y_i \text{ est un produit}$$

scalaire sur \mathbb{R}^n qu'on appelle le **produit scalaire canonique** de \mathbb{R}^n .



Produit scalaire dans \mathbb{R}^n

Exemples

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

b) Produit scalaire défini par une matrice diagonale à éléments positifs

Soit une matrice réelle M à n lignes et n colonnes dont tous les éléments en dehors de la diagonale principale sont nuls et dont tous les éléments de la diagonale principale sont des **nombre réels strictement positifs**.

Alors l'application : $(X, Y) \mapsto \langle X|M|Y \rangle = X^tMY =$

$$(x_1 \cdots, x_j, \cdots, x_n)M \begin{pmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{pmatrix} =$$

$m_{ij}x_jy_i = m_{ii}x_iy_i$ est un produit scalaire sur \mathbb{R}^n . M mat des **poids**.



Produit scalaire dans \mathbb{R}^n

Exemples

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

b) Produit scalaire défini par une matrice diagonale à éléments positifs

- Le produit scalaire canonique correspond au cas où la matrice M est la matrice unité I_n (tous les éléments de la diagonale sont égaux à 1 et les éléments en dehors de la diagonale sont 0) : tous les poids sont égaux à 1.



Produit scalaire dans \mathbb{R}^n

Exemples

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

b) Produit scalaire défini par une matrice diagonale à éléments positifs

- Le produit scalaire canonique correspond au cas où la matrice M est la matrice unité I_n (tous les éléments de la diagonale sont égaux à 1 et les éléments en dehors de la diagonale sont 0) : tous les poids sont égaux à 1.
- Autre exemple : $M = D_{\frac{1}{n}} = \frac{1}{n}I_n$. Tous les poids sont égaux à $\frac{1}{n}$ et la somme des poids vaut 1.



Régression linéaire dans \mathbb{R}^2

Matrice d'un produit scalaire

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Pour tout produit scalaire F de \mathbb{R}^n , on peut écrire :

$$F(X, Y) = F\left(\sum_{i=1}^n x_i e_i, \sum_{j=1}^n y_j e_j\right) = \sum_{i,j=1}^n F(e_i, e_j) x_i y_j =$$

$$(x_1, \dots, x_i, \dots, x_n) M_F \begin{pmatrix} y_1 \\ \vdots \\ y_j \\ \vdots \\ y_n \end{pmatrix} \quad \text{La matrice } M_F = [F(e_i, e_j)]$$

s'appelle la **matrice du produit scalaire** F dans la base canonique. Cette matrice est symétrique :

$$F(e_i, e_j) = F(e_j, e_i).$$

Les éléments de sa diagonale sont : $F(e_i, e_i) > 0$.



Régression linéaire dans \mathbb{R}^2

Matrice d'un produit scalaire (suite et fin)

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Remarquons que ces propriétés ne sont pas suffisantes : une matrice symétrique dont les éléments de la diagonale sont des nombres réels strictement positifs bilinéaire

$((x_1, x_2), (y_1, y_2)) \mapsto (x_1, x_2) \begin{pmatrix} 1 & 2 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}$ qu'elle définit

n'est pas un produit scalaire car le "produit scalaire" du vecteur propre $(1, -1)$ pour la valeur propre négative, par lui même, est un nombre réel strictement négatif

$$(1, -1) \begin{pmatrix} 1 & 2 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} 1 \\ -1 \end{pmatrix} = -2$$

La matrice $\begin{pmatrix} 1 & 2 \\ 2 & 1 \end{pmatrix}$ n'est donc pas la matrice d'un produit scalaire sur \mathbb{R}^2 , bien qu'elle soit symétrique et que les éléments de sa diagonale soient strictement positifs.



Régression linéaire dans \mathbb{R}^2

Matrice d'un produit scalaire

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Théorème

En réalité, pour qu'une matrice carrée symétrique réelle soit la matrice d'un produit scalaire, il faut et il suffit que toutes ses valeurs propres, qui sont toujours des nombres réels, soient strictement positives.



Régression linéaire dans \mathbb{R}^2

Norme d'un vecteur

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Si F est un produit scalaire sur \mathbb{R}^n , le nombre réel positif $\|X\|_F = \sqrt{F(X, X)}$ s'appelle la **F-norme** de X , ou **F-longueur** de X . Quand il n'y a pas de confusion à craindre, on parlera simplement de norme ou de longueur, qu'on notera $\|X\|$ au lieu de $\|X\|_F$.

On dit qu'un vecteur est **normé pour F** si sa F-longueur est 1.

Par exemple, dans \mathbb{R}^2 muni du produit scalaire canonique, la longueur de $X = (x_1, x_2)$ est $\|X\|_F = \sqrt{x_1^2 + x_2^2}$ et le vecteur $(1, 0)$ est normé.



Régression linéaire dans \mathbb{R}^2

Angle de deux vecteurs

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , pour tout nombre réel l , on a :

$$\blacksquare F(X + lY, X + lY) = \|X + lY\|_F^2 \geq 0$$

Comme cette relation est vraie pour tout nombre réel l , c'est que le déterminant de ce trinôme du second degré est négatif :

$$(\langle X | Y \rangle_F)^2 - \|X\|_F^2 \|Y\|_F^2 \leq 0 \implies |\langle X | Y \rangle_F| \leq \|X\|_F \|Y\|_F$$

(inégalité de Schwarz).



Régression linéaire dans \mathbb{R}^2

Angle de deux vecteurs

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , pour tout nombre réel l , on a :

- $F(X + lY, X + lY) = \|X + lY\|_F^2 \geq 0$
- $l^2 F(Y, Y) + l(F(Y, X) + F(X, Y)) + F(X, X) \geq 0$

Comme cette relation est vraie pour tout nombre réel l , c'est que le déterminant de ce trinôme du second degré est négatif :

$$(\langle X | Y \rangle_F)^2 - \|X\|_F^2 \|Y\|_F^2 \leq 0 \implies |\langle X | Y \rangle_F| \leq \|X\|_F \|Y\|_F$$

(inégalité de Schwarz).



Régression linéaire dans \mathbb{R}^2

Angle de deux vecteurs

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , pour tout nombre réel l , on a :

- $F(X + lY, X + lY) = \|X + lY\|_F^2 \geq 0$
- $l^2 F(Y, Y) + l(F(Y, X) + F(X, Y)) + F(X, X) \geq 0$
- $l^2 F(Y, Y) + 2lF(X, Y) + F(X, X) \geq 0$

Comme cette relation est vraie pour tout nombre réel l , c'est que le déterminant de ce trinôme du second degré est négatif :

$$(\langle X | Y \rangle_F)^2 - \|X\|_F^2 \|Y\|_F^2 \leq 0 \implies |\langle X | Y \rangle_F| \leq \|X\|_F \|Y\|_F$$

(inégalité de Schwarz).



Régression linéaire dans \mathbb{R}^2

Angle de deux vecteurs

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , pour tout nombre réel l , on a :

- $F(X + lY, X + lY) = \|X + lY\|_F^2 \geq 0$
- $l^2 F(Y, Y) + l(F(Y, X) + F(X, Y)) + F(X, X) \geq 0$
- $l^2 F(Y, Y) + 2lF(X, Y) + F(X, X) \geq 0$
- $\|Y\|_F^2 l^2 + 2\langle X|Y \rangle_F l + \|X\|_F^2 \geq 0$

Comme cette relation est vraie pour tout nombre réel l , c'est que le déterminant de ce trinôme du second degré est négatif :

$$(\langle X|Y \rangle_F)^2 - \|X\|_F^2 \|Y\|_F^2 \leq 0 \implies |\langle X|Y \rangle_F| \leq \|X\|_F \|Y\|_F$$

(inégalité de Schwarz).



Régression linéaire dans \mathbb{R}^2

Angle de deux vecteurs (suite et fin)

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Si les deux vecteurs X et Y sont différents de 0, leur longueur n'est pas nulle, le produit de leurs longueurs n'est pas nul, le rapport $\frac{\langle X|Y \rangle_\phi}{\|X\|_\phi \|Y\|_\phi}$ est compris entre -1 et 1, et il existe donc un angle compris entre 0 et π radians dont le cosinus est égal au rapport $\frac{\langle X|Y \rangle_\phi}{\|X\|_\phi \|Y\|_\phi}$.

Par définition, cet angle unique a compris entre 0 et π , vérifiant :

$$\cos a = \frac{\langle X|Y \rangle_\phi}{\|X\|_\phi \|Y\|_\phi} = \frac{\langle X|\phi|Y \rangle}{\|X\|_\phi \|Y\|_\phi}$$

est appelé **l'angle des deux vecteurs non nuls X et Y** .



Régression linéaire dans \mathbb{R}^2

Orthogonalité

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , on dit que X et Y sont **F-orthogonaux** (ou simplement "orthogonaux" s'il n'y a pas de confusion à craindre) si, et seulement si, leur produit scalaire est nul :

$$F(X, Y) = \langle X | Y \rangle_F = 0$$

Exemples :

- 0 est F-orthogonal à tout vecteur de \mathbb{R}^n .



Régression linéaire dans \mathbb{R}^2

Orthogonalité

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , on dit que X et Y sont **F-orthogonaux** (ou simplement "orthogonaux" s'il n'y a pas de confusion à craindre) si, et seulement si, leur produit scalaire est nul :

$$F(X, Y) = \langle X | Y \rangle_F = 0$$

Exemples :

- 0 est F-orthogonal à tout vecteur de \mathbb{R}^n .
- L'angle de deux vecteurs non nuls F-orthogonaux est $\frac{\pi}{2}$



Régression linéaire dans \mathbb{R}^2

Orthogonalité

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Etant donnés deux vecteurs X et Y de \mathbb{R}^n et un produit scalaire F sur \mathbb{R}^n , on dit que X et Y sont **F-orthogonaux** (ou simplement "orthogonaux" s'il n'y a pas de confusion à craindre) si, et seulement si, leur produit scalaire est nul :

$$F(X, Y) = \langle X | Y \rangle_F = 0$$

Exemples :

- 0 est F-orthogonal à tout vecteur de \mathbb{R}^n .
- L'angle de deux vecteurs non nuls F-orthogonaux est $\frac{\pi}{2}$
- La base canonique de \mathbb{R}^n muni du produit scalaire canonique est formée de vecteurs normés orthogonaux deux à deux : on parle alors de **base orthonormée**.



Régression linéaire dans \mathbb{R}^2

Projeté orthogonal

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Soient X et Y deux vecteurs non nuls de \mathbb{R}^n et F un produit scalaire sur \mathbb{R}^n .

Il existe un unique vecteur Z de \mathbb{R}^n , proportionnel à Y tel que $X-Z$ soit orthogonal à Y .

Preuve

Pour tout vecteur Z , on peut écrire :

$$\blacksquare \langle X - Z | Y \rangle_F = \langle X | Y \rangle_F - \langle Z | Y \rangle_F$$

Si l'on prend un Z proportionnel à Y , on a $Z = aY$, donc :

Pour que $X-Z$ soit orthogonal à Y , soit $\langle X - Z | Y \rangle_F = 0$, il faut et il suffit que l'on prenne $a = \frac{\langle X | Y \rangle_F}{\|Y\|_F^2}$



Régression linéaire dans \mathbb{R}^2

Projeté orthogonal

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Soient X et Y deux vecteurs non nuls de \mathbb{R}^n et F un produit scalaire sur \mathbb{R}^n .

Il existe un unique vecteur Z de \mathbb{R}^n , proportionnel à Y tel que $X-Z$ soit orthogonal à Y .

Preuve

Pour tout vecteur Z , on peut écrire :

$$\blacksquare \langle X - Z | Y \rangle_F = \langle X | Y \rangle_F - \langle Z | Y \rangle_F$$

Si l'on prend un Z proportionnel à Y , on a $Z = aY$, donc :

$$\blacksquare \langle X - Z | Y \rangle_F = \langle X | Y \rangle_F - a \langle Y | Y \rangle_F = \langle X | Y \rangle_F - a \|Y\|_F^2$$

Pour que $X-Z$ soit orthogonal à Y , soit $\langle X - Z | Y \rangle_F = 0$, il

faut et il suffit que l'on prenne $a = \frac{\langle X | Y \rangle_F}{\|Y\|_F^2}$



Régression linéaire dans \mathbb{R}^2

Propriété du projeté orthogonal

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Le projeté orthogonal Z_0 de X sur Y est le vecteur Z de \mathbb{R}^n proportionnel à Y , qui minimise $\|X - Z\|_F^2$.

Preuve

Soit Z un vecteur proportionnel à Y

Soit $Z_0 = \frac{\langle X|Y \rangle_\phi}{\|Y\|_\phi^2} Y$ le projeté orthogonal de X sur Y .

$$\|X - Z\|_F^2 = \|X - Z_0 + Z_0 - Z\|_F^2$$

Comme Z est proportionnel à Y et que Z_0 est proportionnel à Y , la différence $Z_0 - Z$ est proportionnelle à Y . Or $X - Z_0$ est orthogonal à Y , donc $X - Z_0$ est orthogonal à $Z_0 - Z$ qui est proportionnel à Y . Il en résulte que l'on a :

$$\begin{aligned} \|X - Z\|_F^2 &= \|X - Z_0 + Z_0 - Z\|_F^2 = \\ &= \|X - Z_0\|_F^2 + \|Z_0 - Z\|_F^2 \geq \|X - Z_0\|_F^2. \end{aligned}$$

$\|X - Z\|_F^2$ atteint son minimum lorsque $Z = Z_0$.



Régression linéaire dans \mathbb{R}^2

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Considérons une variable statistique quantitative bidimensionnelle (X, Y) à valeurs dans \mathbb{R}^2 , définie dans une population Ω de taille n . Elle est définie par l'ensemble des couples $\{(X(w), Y(w))\}_{w \in \Omega}$. \mathbb{R}^2 est l'**espace des variables**.

La variable statistique est représentée par un nuage de points dans \mathbb{R}^2 et chaque point du nuage statistique représente un individu dans la population Ω .



Régression linéaire dans \mathbb{R}^2

Espace des variables

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Les n valeurs $X(w)$ de X pour les n individus de la population peuvent être considérées comme les coordonnées d'un vecteur de \mathbb{R}^n . Ce vecteur est noté

$$\text{encore } X = \begin{pmatrix} x_1 \\ \vdots \\ x_j \\ \vdots \\ x_n \end{pmatrix}$$

Même chose pour les n valeurs $Y(w)$ de Y pour les n individus de la population.

L'espace $E = \mathbb{R}^n$ apparaît alors comme l'**espace des variables**.



Régression linéaire dans \mathbb{R}^2

Produit scalaire

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Dans cet espace des variables, la matrice $D_{\frac{1}{n}} = \frac{1}{n}I_n$, où I_n est la matrice unité à n lignes et n colonnes, définit un **produit scalaire** :

$$\langle X|Y \rangle_{D_{\frac{1}{n}}} = \langle X|D_{\frac{1}{n}}|Y \rangle = \sum_{i=1}^{i=n} \frac{1}{n} x_i y_i = \frac{1}{n} \sum_{i=1}^{i=n} x_i y_i = \frac{1}{n} \langle X|Y \rangle$$

en notant $\langle X|Y \rangle$ le produit scalaire canonique de \mathbb{R}^n . On

note $1_n = \begin{pmatrix} 1 \\ \vdots \\ 1 \\ \vdots \\ 1 \end{pmatrix}$ le **vecteur unité** de \mathbb{R}^n . Le vecteur unité

est normé.



Régression linéaire dans \mathbb{R}^2

Moyenne d'une variable statistique

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

la moyenne \bar{X} de la variable statistique X est donné par :

$$\bar{X} = \frac{1}{n} \sum_w X(w) = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{i=1}^n x_i \times 1 = \langle X | D_{\frac{1}{n}} | 1_n \rangle = \langle X | 1_n \rangle$$

La moyenne de X est le produit scalaire de X par le vecteur unité 1_n .

Notons X_0 la variable centrée correspondant à X : pour chaque individu w de la population, sa valeur est $X(w) - \bar{X}$:



Régression linéaire dans \mathbb{R}^2

Moyenne d'une variable statistique (suite et fin)

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

$$X_0 = \begin{pmatrix} x_1 - \bar{X} \\ \vdots \\ x_i - \bar{X} \\ \vdots \\ x_n - \bar{X} \end{pmatrix} = \begin{pmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{pmatrix} - \bar{X} \begin{pmatrix} 1 \\ \vdots \\ 1 \\ \vdots \\ 1 \end{pmatrix} = X - \bar{X}1_n$$
$$X = X_0 + \bar{X}1_n = X_0 + \langle X | 1_n \rangle D_{\frac{1}{n}} 1_n$$



Régression linéaire dans \mathbb{R}^2

Variance d'une variable statistique

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

$$s^2(X) = \overline{X_0^2} = \frac{1}{n} \sum_{i=1}^{i=n} (x_i - \bar{X})^2 = \langle X_0 | D_{\frac{1}{n}} | X_0 \rangle = \|X_0\|^2$$
$$s^2(X) = \|X_0\|^2$$

La variance de X est le carré de la norme de la variable centrée.



Régression linéaire dans \mathbb{R}^2

Covariance

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

La covariance de deux variables quantitatives réelles X et Y définies sur Ω est la moyenne du produit des variables centrées :

$$\begin{aligned} \text{Cov}(X, Y) &= \frac{1}{n} \sum_{i=1}^{i=n} (x_i - \bar{X})(y_i - \bar{Y}) = \langle X_0 | D_{\frac{1}{n}} | Y_0 \rangle = \\ & \langle X_0 | Y_0 \rangle D_{\frac{1}{n}} \\ \text{Cov}(X, Y) &= \langle X_0 | D_{\frac{1}{n}} | Y_0 \rangle \langle X_0 | Y_0 \rangle D_{\frac{1}{n}} \end{aligned}$$

La covariance est le produit scalaire des variables centrées.



Régression linéaire dans \mathbb{R}^2

Coefficient de corrélation linéaire

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

$$r_{XY} = \frac{\text{Cov}(X, Y)}{s(X)s(Y)} = \frac{\langle X_0 | D_{\frac{1}{n}} | Y_0 \rangle}{\|X_0\|_{\phi} \|Y_0\|_{\phi}} = \cos(X_0, Y_0)$$
$$r_{XY} = \cos(X_0, Y_0)$$

Le coefficient de corrélation linéaire est le cosinus de l'angle des variables centrées.



Régression linéaire dans \mathbb{R}^2

Prédicteur linéaire

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Soient Y la variable à expliquer, X la variable explicative, X_0 et Y_0 les variables centrées.

Le prédicteur linéaire $D_{Y|X}$ est $y^* = a + bx$ ou $y^* - \bar{Y} = b(x - \bar{X})$, soit $y_0^* = bx_0$.

Il est représenté par la **droite de régression** de Y en X dans l'espace des individus.

Le coefficient b s'obtient par

$$b = \frac{\text{Cov}(X, Y)}{s^2(X)} = \frac{\text{Cov}(X, Y)}{s^2(X_0)} = \frac{\langle X_0 | Y_0 \rangle_{D_1}}{\|X_0\|_{D_1}^2}.$$



Régression linéaire dans \mathbb{R}^2

Prédicteur linéaire (suite)

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

D'après ce qui précède (I.1.2.3.e), $bX_0 = \frac{\langle X_0 | Y_0 \rangle_{D_{\frac{1}{n}}}}{\|X_0\|_{D_{\frac{1}{n}}}^2} X_0$

est le projeté orthogonal de Y_0 sur X_0 , $Y_0 - bX_0$ est orthogonal à X_0 et b est la valeur qui minimise l'expression

$$s^2 = \frac{1}{n} \sum_{i=1}^{i=n} (Y_{0i} - bX_{0i})^2 = \|Y_0 - bX_0\|_{D_{\frac{1}{n}}}^2 = s^2(Y - bX) = s^2(Y - a - bX) = s^2(Y - Y^*) = s^2(Y_0 - Y_0^*)$$



Régression linéaire dans \mathbb{R}^2

Prédicteur linéaire (suite)

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Le prédicteur linéaire de la variable centrée Y_0 est le projeté orthogonal de Y_0 sur X_0 dans \mathbb{R}^n . C'est la variable Y_0^* qui minimise la variance de $Y_0 - Y_0^*$.

Nous avons alors :

$$s^2(Y) = \|Y_0\|_{D_{\frac{1}{n}}}^2 = \|Y_0 - bX_0 + bX_0\|_{D_{\frac{1}{n}}}^2 = \|Y_0 - bX_0\|_{D_{\frac{1}{n}}}^2 + \|bX_0\|_{D_{\frac{1}{n}}}^2$$

$$s^2(Y) = S_{min}^2 + b^2\|X_0\|_{D_{\frac{1}{n}}}^2 = S_{min}^2 + \left(\frac{\text{Cov}(X, Y)}{s^2(X)}\right)s^2(X) =$$

$$S_{min}^2 + \left(\frac{\text{Cov}(X, Y)}{s(X)s(Y)}\right)s^2(Y)$$

$$s^2(Y) = S_{min}^2 + r_{XY}^2 s^2(X).$$



Régression linéaire dans \mathbb{R}^2

Prédicteur linéaire (fin)

Notions
d'espace
vectoriel
euclidien

Produit scalaire
dans \mathbb{R}^n

Propriétés

Approche
euclidienne de la
régression

Nous retrouvons la variance résiduelle S_{min}^2 et la variance expliquée par la régression $r_{XY}^2 s^2(X)$.

De façon symétrique, si X est la variable explicative et Y la variable à expliquer, nous aurons une expression :

$$s^2(X) = S_{min}^2 + r_{XY}^2 s^2(X).$$

avec la variance résiduelle S_{min}^2 et la variance expliquée par la régression $r_{XY}^2 s^2(X)$.

