


la vraie réponse moyenne au point  $x = x_{n+1}$ ;  
Soit une paramètre de la population et non  
une nouvelle observation

- L'IP en  $x_{n+1}$  est toujours plus grand que  $T_e$   
en  $x_{n+1}$  car il dépend de l'erreur associée aux  
futurs observations

- L'IP n'est valide que pour une  
nouvelle observation à la fois



I/2)

Et régression linéaire multiple et modèle matriciels:

2.1) Rapports d'Algèbre linéaire

• Vecteur: un vecteur est un élément d'un espace vectoriel représenté  
souvent sous forme de colonne ou de ligne:  $\vec{v} = \begin{pmatrix} x \\ y \\ z \end{pmatrix}$

•  $\forall \lambda \in \mathbb{R}, \lambda \vec{v} = \lambda \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} \lambda x \\ \lambda y \\ \lambda z \end{pmatrix}$

• Soit  $\vec{u} = \begin{pmatrix} x' \\ y' \\ z' \end{pmatrix}$  un vecteur dans l'espace vectoriel, alors:

$\vec{v} + \vec{u} = \begin{pmatrix} x \\ y \\ z \end{pmatrix} + \begin{pmatrix} x' \\ y' \\ z' \end{pmatrix} = \begin{pmatrix} x+x' \\ y+y' \\ z+z' \end{pmatrix}$


• Combinaison linéaire: une combinaison linéaire des vecteurs

$v_1, \dots, v_n$  données par  $a_1 v_1 + \dots + a_n v_n$ ; tq:  $a_i$  sont des scalaires.

• Matrice: Table de nombres organisée en lignes et colonnes sert à  
représenter des applications linéaires ou des systèmes d'équations.

on note  $(M_{n,m})$  une matrice de  $n$  lignes et  $m$  colonnes, on peut noter  
 $(a_{ij})_{\substack{1 \leq i \leq n \\ 1 \leq j \leq m}}$ , tq:  $a_{ij}$  sont des coefficients réels

• matrice carrée: est une matrice pour laquelle le nombre de  
lignes est égal au nombre de colonnes, on note:  $M_n$ , matrice



carrée de taille  $n \times n$

Produit matriciel: soient deux matrices  $A_{m,n}$


$B_{n,p}$

Produit:  $C = A \times B$  est défini seulement si le nombre

de colonne de A égale à le nombre de lignes de B, Alors C une matrice de taille  $m \times p$  :  $C_{mp}$ .  
**Exemples** Calculer le produit des matrices :

$$A = \begin{pmatrix} 1 & 6 & 3 \\ 4 & 5 & 2 \end{pmatrix}; B = \begin{pmatrix} 5 & 1 \\ 3 & 0 \\ -1 & 2 \end{pmatrix}$$

$$C = \begin{pmatrix} 20 & 7 \\ 33 & 8 \end{pmatrix}$$



**Remarque** :  $AB \neq BA$

Le produit de deux matrices n'est pas commutatif.

**• Somme des matrices**

Soient deux matrices A et B de même taille  $n \times m$ , leur somme  $C = A + B$  est définie élément par élément  $C_{ij} = a_{ij} + b_{ij}$  (C est de taille  $n \times m$ )

**Ex :**  $A = \begin{pmatrix} 1 & 0 \\ -1 & 2 \end{pmatrix}; B = \begin{pmatrix} 1 & 1 \\ 2 & -3 \end{pmatrix}$ ; leur somme est :  $C = \begin{pmatrix} 2 & 1 \\ 1 & -1 \end{pmatrix}$

• La somme de deux matrices est commutatif c.à.d  $AB = B + A$


soit  $k \in \mathbb{R}$ ,  $k(A + B) = kA + kB$

**• Système linéaire :**

est un ensemble d'équations où les variables sont toutes exprimées au premier degré, cela signifie que l'on peut combiner les équation pour trouver une ou plusieurs solutions

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \\ \vdots \\ a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n = b_n \end{cases}$$

ou  $(AX = b)$  écriture matricielle.



Système linéaire de n équations à p inconnues  
 si  $b_i = 0, i = 1, n$  on appelle système homogène

• **Déterminant** D est un nombre (scalaire) associé à une matrice carrée  $(n \times n)$ , il se note  $\det A$  ou  $|A|$ .

• Si  $\det A \neq 0$  on dit  $A$  est inversible

• Si  $A = a \Rightarrow \det A = a$

• Si  $A$  de taille  $2 \times 2$ ;  $A = \begin{pmatrix} a & c \\ b & d \end{pmatrix}$

$\Rightarrow \det A = ad - cb$

Exemple: Calculer le  $\det B$  q :

$B = \begin{pmatrix} 1 & 1 & 3 \\ 2 & 2 & 4 \\ 3 & 2 & 1 \end{pmatrix}$

$\det B = 1 \times \begin{vmatrix} 2 & 4 \\ 2 & 1 \end{vmatrix} - 1 \times \begin{vmatrix} 2 & 4 \\ 3 & 1 \end{vmatrix} + 3 \times \begin{vmatrix} 2 & 2 \\ 3 & 2 \end{vmatrix}$

$\det B = -6 + 10 - 6 = -2$

La matrice transposée:

La transposée d'une matrice  $A$  notée  $A^T$  (ou  $A'$ ) est la matrice obtenue en échangeant les lignes et les colonnes de  $A$ , i.e

$A = a_{ij} \Rightarrow A^T = a_{ji}$

Remarque:  $\det A = \det A^T$

propriétés:  $(A^T)^T = A$

$(AB)^T = B^T A^T$

$(A+B)^T = A^T + B^T$

Ex: la transposée de la matrice:  $A = \begin{pmatrix} -1 & 0 & 1 \\ 2 & 3 & 4 \\ 6 & 3 & 1 \end{pmatrix}$  est  $A^T = \begin{pmatrix} -1 & 2 & 6 \\ 0 & 3 & 3 \\ 1 & 4 & 1 \end{pmatrix}$ .

La matrice inversible: une matrice carrée  $A$  est dite inversible



( $\det A \neq 0$ ) ou régulière s'il existe une matrice  $A^{-1}$  carrée (appelée matrice inverse); T.q:  $A^{-1}A = AA^{-1} = I$

ou  $I$  est la matrice identité.  $A^{-1} = \frac{1}{\det A} \text{Com}(A)^T$

Ex: Calculer la matrice inversible de  $A$ .

$A = \begin{pmatrix} 1 & -1 & 3 \\ -2 & 2 & 4 \\ 3 & -2 & 1 \end{pmatrix}$   $\det A = -2$


$\text{Com}(A) = \begin{vmatrix} + & \begin{vmatrix} 2 & 4 \\ 3 & 1 \end{vmatrix} & - & \begin{vmatrix} 2 & 4 \\ 3 & 1 \end{vmatrix} & + & \begin{vmatrix} 2 & 2 \\ 3 & 2 \end{vmatrix} \\ - & \begin{vmatrix} 1 & 3 \\ 2 & 1 \end{vmatrix} & + & \begin{vmatrix} 2 & 3 \\ 3 & 1 \end{vmatrix} & - & \begin{vmatrix} 1 & 1 \\ 3 & 2 \end{vmatrix} \\ + & \begin{vmatrix} 1 & 3 \\ 2 & 4 \end{vmatrix} & - & \begin{vmatrix} 1 & 3 \\ 2 & 4 \end{vmatrix} & + & \begin{vmatrix} 1 & 1 \\ 3 & 2 \end{vmatrix} \end{vmatrix}$



$$\text{Com}(A) = \begin{vmatrix} -6 & 10 & 4 \\ 5 & -9 & 1 \\ -2 & 2 & -1 \end{vmatrix}$$

$$\text{Com}(A)^T = \begin{vmatrix} -6 & 5 & -2 \\ 10 & -9 & 2 \\ 4 & 2 & -1 \end{vmatrix}$$

$$A^{-1} = \frac{-1}{2} \begin{vmatrix} -6 & 5 & -2 \\ 10 & -9 & 2 \\ 4 & 2 & -1 \end{vmatrix} = \begin{pmatrix} 3 & -\frac{5}{2} & +1 \\ -5 & \frac{9}{2} & -1 \\ -2 & 1 & \frac{1}{2} \end{pmatrix}$$




2-2) Régression linéaire multiple. la régression linéaire multiple est identique à la régression linéaire simple sauf que dans cette cas, on y a expliqués par variable à expliqués par plusieurs variable explicatives.

16/11/2025

2-2-1) forme généralise de le modèle de R.L.M. On souhait prédire et expliqués les valeurs d'une variable quantitative (on dit alors  $y$ ) à partir des valeurs de  $p$  variables  $x_1, x_2, \dots, x_p$  quantitative on dit alors que on expliqués  $y$  par  $x_1, \dots, x_p$  pour ce faire on dispose des données qui sont  $n$  observations de  $(y, x_1, \dots, x_p)$  de réalisation  $(y_1, x_{11}, \dots, x_{p1}); \dots; (y_n, x_{1n}, \dots, x_{pn})$ . Elle se présentent généralement sous forme d'une tableau

$y$	$x_1$	...	$x_p$
$y_1$	$x_{11}$	...	$x_{p1}$
$y_2$	$x_{12}$	...	$x_{p2}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$y_n$	$x_{1n}$	...	$x_{pn}$

s'il ya une liaison linéaire entre  $y$  et  $x_1, \dots, x_p$  on peut considérés le modèle de régression linéaire multiple (R.L.M) de forme générale:  
 $y = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \epsilon$   
 où  $\beta_0, \beta_1, \dots, \beta_p$  sont des Coefficient réels inconnus à déterminer et  $\epsilon$  est un variable quantitative indépendante de  $x_1, \dots, x_p$  avec  $E(\epsilon_i) = 0$  pour  $i = \overline{1, n}$ , pour une réalisation  $(x_{1i}, \dots, x_{pi})$  de  $(x_1, \dots, x_p)$  et  $y$  on peut écrire  $y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_p x_{pi} + \epsilon_i$  pour  $i = \overline{1, n}$




Exemple: La dépendance de le goût d'un fromage (g) et la concentration de plusieurs composés chimiques dont la concentration de l'acide acétique (variable  $x_1$ ).

date 16 / 11 / 2025.

a la concentration d'hydrogène sulfuré ( $x_2$ ).  
 a " " " d'acide lactique ( $x_3$ )  
 et cette matricielle du modèle de RLM  
 peut transformer la forme générale de  
 la modèle de RLM à la forme matricielle  
 suivante:

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & \dots & x_{p1} \\ 1 & x_{12} & \dots & x_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \dots & x_{pn} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \vdots \\ \epsilon_n \end{pmatrix}$$



2.2.2) Estimation des moindres carrés ordinaires

23/11/2025

Notre principal objectif est d'estimer convenablement  $\beta_0, \dots, \beta_p$  à l'aide des données


soient  $\| \cdot \|$  la norme euclidienne pour tout vecteurs colonne  $x_j$   
 $\|x\|^2 = x^T x$

Partant du modèle de RLM écrit sous la forme matricielle

$y = X\beta + \epsilon$ , un estimateur des moindres carrés ordinaires (EMCO),  $\hat{\beta}$  de  $\beta$  vérifie  $\hat{\beta} \in \arg \min_{\beta \in \mathbb{R}^{p+1}} \|y - X\beta\|^2$


on suppose que  $X$  est de rang colonne plein: il n'existe pas de vecteur colonne  $x$  à  $p+1$  composantes non nul tel que  $Xx = 0$  vecteur nul. cela entraîne l'existence de  $(X^T X)^{-1}$ . Alors  $\hat{\beta}$  est unique, et est donnée par la formule  $\hat{\beta} = (X^T X)^{-1} X^T y$

premier vu sur l'estimateur des moindres carrés ordinaires (EMCO) Christophe Chesneau page 8



$$\begin{aligned}
 \hat{\beta} &= \arg \min_{\beta} \|y - X\beta\|^2 \\
 &= \arg \min_{\beta} \sum_{i=1}^n \epsilon_i^2 = \arg \min_{\beta} \| \epsilon \|^2 = \arg \min_{\beta} \epsilon^T \epsilon \\
 &= \arg \min_{\beta} (y - X\beta)^T (y - X\beta) \\
 &= y^T y - 2\beta^T X^T y + \beta^T X^T X \beta
 \end{aligned}$$

$$\begin{aligned}
 \frac{dS}{d\beta} &= -2X^T y + 2X^T X \beta = 0 \\
 \Rightarrow \hat{\beta} &= (X^T X)^{-1} X^T y
 \end{aligned}$$



Propriétés des estimateurs

L'estimateur  $\hat{\beta}$  est le meilleur estimateur

non-biaisé de  $\beta$  avec :  $E(\hat{\beta}) = \beta$

$Var(\hat{\beta}) = \sigma^2 [X^T X]^{-1}$

Coefficient de détermination  $R^2$

$R^2$  est donnée par :  $R^2 = 1 - \frac{\| \hat{y} - y \|^2}{\| y - \bar{y} \|^2}$

où :  $\hat{y} = X\hat{\beta}$  et  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$

plus  $R^2$  est proche de 1 plus la relation linéaire entre  $y$  et  $X_1, X_2, \dots, X_p$  est forte.

Coefficient de détermination ajusté

une version améliorée du  $R^2$  défini par :  $\bar{R}^2 = 1 - \frac{n-1}{n-(p+1)} (1-R^2)$

Ex p on suppose qu'on a le tableau suivant :

Année	$y$	$x_1$	$x_2$
2000	4	1	6
2001	4	3	6
2002	8	4	7
2003	12	6	7
2004	12	6	7

Question: estimer les coefficients de ce modèle.

$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$   
 Form de  $\hat{\beta}$  Fondé sur  $\| \hat{y} - y \|^2$  ?  
 vraisemblance

2.3) Estimateur par maximum de vraisemblance?

2.3.1) La fct vraisemblance

Dépe  $x_1, \dots, x_n$  un échantillon de vraisemblance à paramètres de loi


de probabilité  $P_{\theta}(x_i)$ , la fct de vraisemblance est la fct de  $\theta$

définie par :  $L(\theta, x_1, \dots, x_n) = P(x_1, \dots, x_n | \theta)$ , cette fct

ne calcule pas la probabilité des données mais elle mesure à

quel point un paramètre  $\theta$  rend les données observées plausibles.

C'est l'outil de base pour l'estimation du EMV



### 2.3.2) Estimation par MV en R/MR

Dans le cas général de la régression linéaire multiple, on considère le modèle  $y = X\beta + \epsilon$

où  $\epsilon_i \sim N(0, \sigma^2 \mathbb{I}_n)$

$y$  le vecteur des observations ( $n \times 1$ )

$\hat{y}$  le vecteur des prédictions ( $n \times 1$ )

$X$  est la matrice des prédicteurs ( $n \times p$ )

$\beta$  est le vecteur des paramètres ( $p \times 1$ )

$\epsilon$  est un vecteur de Bruit gaussien

Chaque  $y_i$  suit distribution normale  $y_i \sim N(x_i\beta, \sigma^2)$

$\Rightarrow y \sim N(X\beta, \Sigma \sigma^2 \mathbb{I}_n)$

Sous l'hypothèse d'indépendance des erreurs on écrit la

véraisemblance sous la forme d'un produit

$$L(\beta, \sigma^2) = P(Y|\beta, \sigma^2) =$$

$$= P(y_1, \dots, y_n | \beta, \sigma^2) = \prod_{i=1}^n P(y_i | \beta, \sigma^2)$$

$$= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_i - x_i\beta)^2}{2\sigma^2}\right)$$

on obtient :

$$L(\beta, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - x_i\beta)^2\right)$$

La somme des carrés des erreurs est le produit scalaire :

$$\sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (y_i - x_i\beta)^2 = (y - X\beta)^T (y - X\beta) = \|y - X\beta\|^2$$

Ainsi, en réécrivant sous forme matricielle, on obtient :

$$L(\beta, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} (y - X\beta)^T (y - X\beta)\right)$$



maximiser la log. vraisemblance est équivalente à maximiser la

vraisemblance, donc on obtient  $\log(L(\beta, \sigma^2)) = l(\beta, \sigma^2)$

$$= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (y - X\beta)^T (y - X\beta)$$

maximiser la log. vraisemblance revient à trouver

l'argument de  $\beta$  qui minimise la somme des carrés des erreurs.



$$\hat{\beta}_{MV} = \arg \min_{\beta} l(\beta, \sigma^2)$$

$$= \arg \min_{\beta} \left( -\frac{n}{2} \log(2\pi \sigma^2) - \frac{1}{2\sigma^2} (y - X\beta)^T (y - X\beta) \right)$$

$$= \arg \min_{\beta} (y - X\beta)^T (y - X\beta)$$


$$= \hat{\beta}_{MCO}$$



on retrouve ici le critère des moindres carrés ordinaires qui donne les estimateurs

$$\hat{\beta}_{MV} = (X^T X)^{-1} X^T y = \hat{\beta}_{MCO}$$

Ce qui explique pourquoi les estimateurs MV et MCO coïncident sous l'hypothèse de normalité et d'indépendance des erreurs



Pourquoi ne pas chercher la dérivée seconde? Dans les deux méthodes MCO et MV, la fonction de coût à minimiser est une fonction quadratique en  $\beta$

$$C(\beta) = (y - X\beta)^T (y - X\beta)$$

Pour s'assurer qu'un minimum est bien atteint, on pourrait vérifier la matrice Hessienne:  $\nabla^2 C(\beta) = \frac{\partial^2 C}{\partial \beta^2}$


$$= -2X^T y + 2X^T X \beta \rightarrow \nabla^2 C(\beta) = 2X^T X$$

la matrice de Gram  $X^T X$  est semi-définie positive si les colonnes de  $X$  sont linéairement indépendantes, alors  $X^T X$  est définie positive. Cela garantit que la fonction est convexe et atteint un minimum unique.

2.3) Multicolinéarité et VIF (VIF: facteur d'inflation de la variance)

Déf. Multicolinéarité

On parle de multicolinéarité lorsque deux variables explicatives ou plus d'un modèle de régression sont fortement corrélées entre elles (c, à, d): si une des variables explicatives est une combinaison linéaire d'une plusieurs autres variables explicatives incluses dans le même modèle



Une multicolinéarité prononcée s'avère problématique, car quand on a ce cas, les conséquences peuvent être les suivantes:  
 - Les coefficients deviennent instables (petite


date ..... / .....

Changement dans les données  $\rightarrow$  grands changements dans les coefficients)

• Les erreurs standards augmentent, donc les tests deviennent non significatifs alors que la variable est réellement utile.

• Il devient difficile d'interpréter l'effet individuel des variables corrélées.

• Le modèle peut avoir une faible capacité de généralisation.



- Facteur d'inflation de la variance V.I.F.

V.I.F. est la méthode la plus courante pour détecter la multicolinéarité.

Def. "V.I.F." : Le facteur V.I.F. est une mesure statistique qui quantifie l'étendue de multicolinéarité, en indiquant dans quelle mesure la variance d'un coefficient de régression est gonflée par la corrélation.

• Si l'on considère une variable explicative  $X_i$ ,  $V.I.F. = \frac{1}{1 - R_i^2}$  où  $R_i^2$  est le coefficient de détermination obtenu en régressant  $X_i$  sur toutes les autres variables.

Interprétation :


V.I.F. proche de 1. ( $V.I.F. \leq 1$ ) Aucune corrélation avec d'autres prédicteurs

$1 < V.I.F. < 5$  : corrélation modérée généralement acceptable.

$V.I.F. > 5$  : multicolinéarité importante, à surveiller

$V.I.F. > 10$  : Multicolinéarité sévère

$\rightarrow$  Problème sérieux pour la fiabilité du modèle



Les solutions pour le VIF et trop élevé.

Supprimer une des variables corrélées (garder seulement l'une des deux variables très proches)

Combien de variables par : Moyenne ACP


Centrer ou normaliser les données (cela n'enlève pas la multicollinéarité mais peut

réduire les problèmes numériques.

utiliser une régression pénalisée :

• Ridge

• Lasso



Ex: On souhaite analyser l'effet de plusieurs variables explicatives sur le prix d'une maison, les données suivantes ont été observées:

Prix (\$)	Surface (m <sup>2</sup> )	Nombre de chambre	Age
200	100	3	10
260	150	4	6
320	200	5	3
210	120	3	12

Question: il y a une multicollinéarité entre les variables explicatives?


II) Diagnostic et validation des modèles.

1) Contrôle de l'aptitude du modèle:

1-1) Analyse des résidus:

Dans un modèle de RL le résidu  $\epsilon_i$  est la différence entre la valeur réel et la valeur ajustée  $\epsilon_i = y_i - \hat{y}_i$

L'analyse des résidus permet de vérifier la validation des



Hypothèses au modèle de RL:

Les hypothèses du modèle linéaire: