

# Partie 5. Etude des relations entre variables

## 5.1. Le coefficient de corrélation

5.1.1. Coefficient de corrélation de Pearson

5.1.2. Coefficient de corrélation de Spearman

## 5.2. De la corrélation au modèle de régression

5.2.1. Régression linéaire simple

5.2.2. Régression linéaire multiple

# Etude de la liaison entre variables: corrélation vs régression



## Rappels :

**Corrélation** : Etablir l'existence d'un lien entre 2 VA ( $X, Y$ ) jouant des rôles **symétriques**

- Pas d'hypothèse sur sens relation (**VD, VI**) ou de cause à effet.
- On s'intéresse seulement à la dispersion du nuage de point, pas à sa pente.

*Ex : Est-ce que la quantité d'azote ( $X$ ) et le rendement en maïs ( $Y$ ) varient ensemble?*

*Si oui, avec quelle intensité et dans quel sens ?*

**Régression** : Trouver le meilleur modèle permettant de décrire et **quantifier l'influence** d'1 ou plusieurs **VI** ( $X_i$ , fixes et/ou aléatoires) **sur** les variations d'1 **VD** ( $Y$ , aléatoire).

- lien **asymétrique** : il y a un sens dans la relation, et c'est ce qu'on cherche à modéliser.
- On s'intéresse à la dispersion ET à la **pente** du nuage de point.

*Ex : Est-ce que le rendement en maïs ( $Y$ ) varie linéairement **en fonction de** la quantité d'azote ( $X$ )?*

*Si oui, de combien?*

# Modèles de régression

## Qu'est ce qu'un modèle ?


« Simplification » de la réalité sous forme d'une équation mathématique traduisant la relation existant entre les variables d'intérêt (ex:  $y = f(x)$  ).

## Quel modèle (équation) correspond le mieux à mes données ?

Importance de la visualisation des données.


$R^2$  = coefficient de détermination; varie entre [0, 1] et mesure de la qualité de l'ajustement du modèle aux observations.

Modèle linéaire,  $R^2 = 1$




Modèle linéaire,  $R^2 = 0.84$

Modèle non linéaire,  $R^2 = 0.98$



Modèle linéaire,  $R^2 = 0.08$

Modèle non linéaire,  $R^2 = 0.93$



# Modèles de régression

## Pourquoi utiliser la régression ?

- **Comprendre / décrire** la relation entre une VD ( $Y$ ) et 1 ou plusieurs VI ( $X_j$ )  
→ Ajuster le meilleur modèle et en estimer les paramètres à partir des données.

Si les variations de  $Y$  sont étudiées en fonction de :

- 1 seule variable  $X \rightarrow$  régression simple
  - Plusieurs variables  $X_j \rightarrow$  régression multiple
- **Prédire**, à partir du modèle, la valeur attendue (= estimée) de  $Y$  pour 1 ou plusieurs nouvelles valeurs de  $X_j$  (= non observées dans l'échantillon).

Ex:

- **Comprendre** comment le rendement en maïs ( $Y$ ) varie en fonction de la quantité d'azote apportée ( $X_1$ ), la température ( $X_2$ ), les précipitations ( $X_3$ ) et la densité de ravageurs ( $X_4$ )?
- **Prédire** le rendement en maïs à partir de valeurs particulières de quantité d'azote, température, précipitation et densité de ravageurs (nouvelles valeurs de  $X_1$  à  $X_4$ ).

# Partie 5. Etude des relations entre variables

## 5.1. Le coefficient de corrélation

5.1.1. Coefficient de corrélation de Pearson

5.1.2. Coefficient de corrélation de Spearman

## 5.2. De la corrélation au modèle de régression linéaire

### 5.2.1. Régression linéaire simple

5.2.2. Régression linéaire multiple

# La régression linéaire simple

**Les données :** n individus statistiques → 1 VD quantitative continue (Y) et 1 VI quantitative (X).

**Objectif :** Evaluer l'existence d'un lien linéaire entre Y et X.



Relation résumée par une droite d'équation :

$$y = \boxed{a} + \boxed{b} x$$

Ordonnée à l'origine = Intercept  
(valeur de Y quand X vaut 0)

Pente (= coefficient directeur)

*Ex : Est ce que le rendement (y) peut être expliqué/prédit par la quantité d'azote apportée (x) ?*



# La régression linéaire simple

## Principe :

Déterminer l'équation de la droite de régression qui passe au plus près de l'ensemble des observations (points  $x_i, y_i$ ), en la faisant pivoter sur le point moyen ( $\bar{x}, \bar{y}$ ).


*Ecriture usuelle droite :*  $\hat{y} = b_0 + b_1 x$

Résidu (erreur) = écart entre chaque observation  $i$  ( $x_i, y_i$ ) et la valeur de  $y$  prédite ( $\hat{y}_i$ ) par le modèle (cad la droite) pour un  $x_i$  donné.

$$\varepsilon_i = y_i - \hat{y}_i$$

La meilleure droite sera celle qui minimise la somme des carrés des résidus  $\varepsilon_i$  (= méthode des moindres carrés).

$$\text{Ecriture modèle : } y_i = \hat{y}_i + \varepsilon_i = b_0 + b_1 x_i + \varepsilon_i$$



# La régression linéaire simple

## Evaluation de la qualité globale du modèle :

La **variabilité totale de Y** (écart entre  $y_i$  et  $\bar{y}$ ) peut se décomposer en 2 parties:

- **Expliquée par le modèle** (écart entre  $\bar{y}$  et  $\hat{y}_i$ ) : pour chaque valeur de  $x_i$ , le modèle prédit  $\hat{y}_i$
- **Non expliquée** (aléatoire) = **Résiduelle** (écart entre  $\hat{y}_i$  et  $y_i$ ) : ≠ prédition vs observation


Quelle part (%) de la variabilité de Y s'explique par X ?

$$SCE_T = SCE_M + SCE_R$$

Variabilité	SCE	ddl	Carré moyen	Test	Proba. crit.
Totale	$SCE_T$	$n - 1$			
Due au modèle	$SCE_M$	1	$CM_F = SCE_F$	$F_{obs} = CM_F / CM_R$	$p_c$
Résiduelle	$SCE_R$	$n - 2$	$CM_R = SCE_R / (n - 2)$		

✓ **Test de Fisher** : Plus  $F_{obs}$  est grand (variance Modèle >> Résiduelle), meilleur est l'ajustement du modèle aux données.

✓ **Coefficient de détermination multiple  $R^2 = SCE_M / SCE_T$**   
= Proportion de la variance totale de Y expliquée par le modèle.



## La régression linéaire (*simple ou multiple*)

**Estimation des coefficients de la régression** (paramètres inconnus, non observables) :

Régression linéaire simple :  $y_i = b_0 + b_1 x_{i1} + \varepsilon_i$

Régression linéaire multiple :  $y_i = b_0 + \underbrace{b_1 x_{i1} + b_j x_{ij} + \dots + b_p x_{ip}}_{\text{combinaison linéaire (somme) de plusieurs VI } (X_j)} + \varepsilon_i$

→ Dans tous les cas on a :

- 1 **constante**  $b_0$  = **ordonnée à l'origine**  
→ Pas vraiment d'intérêt pour évaluer s'il existe 1 relation linéaire entre variables.
- 1 **coefficient** de **pente**  $b_j$  par VI ( $j = 1 \text{ à } p$ ) = variation de Y pour une  $\geq 1$  unité de  $x_j$  (lorsque toutes les autres VI sont maintenues constantes).  
→ Renseigne sur la vitesse d'évolution de la variable y en fonction de la variable  $x_j$ , mais ne présume pas de la significativité de la relation (doit la tester : Student).
- + 1 **résidu**  $\varepsilon_i$  = variation de Y non expliquée par les VI du modèle (erreur)

## La régression linéaire (*simple ou multiple*)

2 niveaux de test de la significativité du modèle :

1. Le test global : *Le modèle est-il pertinent/informatif ?*

Statistique de test : F de Fisher.

Hypothèses :


- $H_0 : b_1 = b_i = \dots = b_p = 0 \rightarrow$  « toutes les pentes = 0, aucune des VI ( $X_j$ ) n'influence Y »  
 (= modèle nul avec seulement  $b_0$ )
- $H_1 : b_1 \neq b_i \neq \dots \neq b_p \neq 0 \rightarrow$  « au moins 1 des pentes  $\neq 0$ , au moins 1 VI joue »

Interprétation :

- Si on conclue  $H_0 \rightarrow$  on s'arrête là !

(Soit les VI sont mal choisies et le modèle n'est pas bon, soit la taille de l'échantillon est insuffisante)

- Si on conclue  $H_1 \rightarrow$  on peut interpréter le  $R^2$  pour apprécier la qualité du modèle.  
(régression simple = « Multiple R-squared », régression multiple = « Adjusted R-squared »)



# La régression linéaire (*simple ou multiple*)

2 niveaux de test de la significativité du modèle :

2. Le test de significativité de chaque coefficient : *La VI  $X_i$  est-elle utile ?*

Statistique de test : t de Student.

Hypothèses :

$H_0 : b_i = 0 \rightarrow$  test de « la pente  $b_i = 0$  » pour chaque VI

$H_1 : b_i \neq 0 \rightarrow$  cette VI est significativement liée linéairement à Y

Interprétation :

- Si on conclue  $H_0 \rightarrow$  cette VI n'est pas liée linéairement à Y (variations de X sans effet sur Y) (en régression multiple, on retire les VI non significatives du modèle pour optimiser sa capacité de prédiction)
- Si on conclue  $H_1 \rightarrow$  valeur du coefficient renseigne sur la taille et sens de l'effet de X sur Y

Remarque : Quand on compare des modèles, on retiendra celui qui maximise le  $R^2$  tout en limitant le nombre de VI  
 $\rightarrow$  principe de parcimonie (cherche à minimiser le critère AIC ou le BIC)

# La régression linéaire simple

## Conditions d'application :

Pour pouvoir utiliser la régression linéaire **4 conditions** doivent être satisfaites :

1. La relation entre X et Y est **linéaire** (au moins grossièrement).

→ Vérification graphique : pas de pattern autre que linéaire (ex: relation en U non linéaire)

2. Les observations sont **indépendantes** (résidus non corrélés) : Très important.

→ C'est le plan d'échantillonnage qui renseigne sur cette condition.

Si les données proviennent d'individus statistiques différents et qu'il n'y a pas d'échantillonnage dans l'espace ou le temps, elles sont généralement indépendantes.

# La régression linéaire simple


3. Les résidus doivent suivre une loi normale centrée sur 0 (i.e. sur droite de régression)
  4. Les résidus doivent avoir une variance homogène (homoscédasticité)
- Vérification graphique et tests.

## Explanation :

*Si on répète un grand nombre de fois les mesures de  $Y$  pour 1  $x_i$ , donné, on s'attend en moyenne à ce que les  $y_i$  se trouvent sur la droite de régression → espérance  $E[y_i]$ .*

*Autour de cette valeur  $E[y_i]$ , on aura une distribution Normale des résidus  $\varepsilon_i$  ( $\mu$  centrée sur 0 –sur la droite- et  $\sigma$ ) dans laquelle se trouvera la valeur réellement observé de  $y_i$ .*

Cette distribution des résidus  $N(0, \sigma)$  doit être la homogène pour toutes les valeurs de  $x_i$ .



# La régression linéaire (*simple ou multiple*)

## Flux de travail :

1. Visualiser les données.
2. Créer un modèle.
3. Tester les conditions d'application de base.
4. Interpréter les résultats du modèle.