

Démarche statistique

Premiers pas avec

David Causeur

L'Institut Agro

IRMAR CNRS UMR 6625

<https://dcauseur.netlify.app>



Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire
 - Linéarité d'un effet
 - Modèle de régression linéaire
 - Ajustement d'un modèle de régression

Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire
 - Linéarité d'un effet
 - Modèle de régression linéaire
 - Ajustement d'un modèle de régression

Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire
 - Linéarité d'un effet
 - Modèle de régression linéaire
 - Ajustement d'un modèle de régression

Données appariées

Etude de cas 'fictive' : 2 produits alimentaires évalués par 3 juges sur une échelle de préférence allant de 1 ('je n'aime pas') à 10 ('j'aime').

Produits	Juges		
	J ₁	J ₂	J ₃
A	2	3	6
B	4	6	8

► Données et première analyse dans R

Soit Y_{ij} la variable réponse mesurée par le j ème individu, $1 \leq j \leq J$, dans le i ème groupe, $1 \leq i \leq I$.

Si le j ème individu est le même dans tous les groupes, alors on dit que les données sont **appariées**.

Données appariées

Peut-on sérieusement conclure que l'effet 'produit' n'est pas significatif ?

Produits	Juges		
	J ₁	J ₂	J ₃
A	2	3	6
B	4	6	8

Analyse de la variance pour données appariées

Soit Y_{ij} la variable réponse mesurée par le j ème individu, $1 \leq j \leq J$, dans le i ème groupe, $1 \leq i \leq I$:

$$Y_{ij} = \mu + \alpha_i + \beta_j + e_{ij},$$

où

- α_i , $i = 2, \dots, I$, paramètres de l'effet *groupe* ($\alpha_1 = 0$),
- β_j , $j = 2, \dots, J$ paramètres de l'effet *individu* ($\beta_1 = 0$).

et l'erreur résiduelle $e_{ij} \sim \mathcal{N}(0; \sigma)$.

Remarque. Le modèle à un facteur est un sous-modèle du modèle à deux facteurs : $\varepsilon_{ij} = \beta_j + e_{ij}$.

Ajustement du modèle pour données appariées

Minimisation du critère des moindres carrés :

$$\sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \hat{\mu} - \hat{\alpha}_i - \hat{\beta}_j)^2 = \min_{\mu, \alpha_i, \beta_j} \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \mu - \alpha_i - \beta_j)^2.$$

► Ajustement du modèle dans \mathbb{R}

Ajustement du modèle pour données appariées

Estimateurs des paramètres :

$$\begin{aligned}\hat{\mu} &= \bar{Y}_{..} + (\bar{Y}_{1.} - \bar{Y}_{..}) + (\bar{Y}_{.1} - \bar{Y}_{..}), \\ \hat{\alpha}_i &= \bar{Y}_{i.} - \bar{Y}_{1.}, \quad i = 2, \dots, I, \\ \hat{\beta}_j &= \bar{Y}_{.j} - \bar{Y}_{.1}, \quad j = 2, \dots, J.\end{aligned}$$

Produits	Juges			$\bar{Y}_{i.}$
	J ₁	J ₂	J ₃	
A	2	3	6	3.67
B	4	6	8	6.00
$\bar{Y}_{.j}$	3.00	4.50	7.00	4.83

Ajustement du modèle pour données appariées

Résidus : $\hat{\varepsilon}_{ij} = Y_{ij} - \hat{\mu} - \hat{\alpha}_i - \hat{\beta}_j = Y_{ij} - \bar{Y}_{i\bullet} - \bar{Y}_{\bullet j} + \bar{Y}_{\bullet\bullet}$.

Estimation de la variance résiduelle σ^2 :

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i\bullet} - \bar{Y}_{\bullet j} + \bar{Y}_{\bullet\bullet})^2}{(I-1)(J-1)}.$$

► Comparaison des écarts-types résiduels dans \mathbb{R}

Test de Fisher pour données appariées

Equation d'analyse de la variance :

$$\begin{aligned}
 & \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{\bullet\bullet})^2 \\
 &= \sum_{i=1}^I J(\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i\bullet})^2, \\
 &= \sum_{i=1}^I J(\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{j=1}^J I(\bar{Y}_{\bullet j} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i\bullet} - \bar{Y}_{\bullet j} + \bar{Y}_{\bullet\bullet})^2.
 \end{aligned}$$

► Table d'analyse de la variance dans \mathbb{R}

Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire
 - Linéarité d'un effet
 - Modèle de régression linéaire
 - Ajustement d'un modèle de régression



Corrélation

- ▶ Description graphique du lien entre LMP et BFAT dans \mathbb{R}

Corrélation

Un indicateur de la linéarité de l'effet de X sur Y ne dépend

- ni de la position,
- ni de la dispersion

des distributions marginales de X et Y .

... il peut être évalué à partir des séries **centrées-réduites**.

Les valeurs \tilde{x}_i de la série (x_1, \dots, x_n) **centrée-réduite** s'obtiennent de la manière suivante :

$$\tilde{x}_i = \frac{x_i - \bar{X}}{s_x}.$$

► Données centrées-réduites dans \mathbb{R}

Corrélation

Le **coefficient de corrélation** r_{xy} est la moyenne des produits des valeurs centrées-réduites :

$$r_{xy} = \frac{\sum_{i=1}^n \tilde{x}_i \tilde{y}_i}{n-1}.$$

De manière équivalente,

$$r_{xy} = \frac{1}{n-1} \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{s_x s_y} = \frac{s_{xy}}{s_x s_y},$$

où s_{xy} est la **covariance** des séries x et y :

$$s_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1}.$$

Corrélation

r_{xy} **s'interprète comme suit** :

- $r_{xy} \approx 1$ peut être un bon indicateur d'une relation linéaire croissante entre X et Y .
- $r_{xy} \approx -1$ peut être un bon indicateur d'une relation linéaire décroissante entre X et Y .
- $r_{xy} \approx 0$ peut être un bon indicateur d'une absence de relation linéaire entre X et Y .

r_{xy} doit **compléter** l'impression visuelle déduite d'un graphique (nuage de points).

▶ Coefficient de corrélation linéaire dans \mathbb{R}

Régression linéaire

Relation entre LMP (Y) et épaisseur de gras (X) : la manière dont $\mathbb{E}(Y \mid X = x)$ dépend de x est décrite par une fonction linéaire de x .

On suppose que, sachant $X = x$, Y suit une loi normale, de même écart-type pour tout x .

Il y a un **effet linéaire de X sur Y** si l'espérance conditionnelle de Y sachant $X = x$ est une fonction linéaire de x :

$$\mathbb{E}(Y \mid X = x) = \beta_0 + \beta_1 x,$$

où β_0 est le **terme constant** et β_1 le **coefficient directeur**. Le modèle ci-dessus s'appelle **modèle de régression linéaire simple**.

Régression linéaire

Pourquoi *régression* ?

Le sens statistique du terme *régression* vient de

Francis Galton (1886). "Regression towards mediocrity in hereditary stature". *The Journal of the Anthropological Institute of Great Britain and Ireland*, Vol. **15**. 246–263

qui s'intéresse à l'héritabilité du phénotype *taille* chez l'humain.

Régression linéaire

De manière alternative,

Le **modèle de régression linéaire simple** de l'effet linéaire de X sur Y est le suivant :

$$Y = \beta_0 + \beta_1 X + \varepsilon,$$

où $\varepsilon = Y - \mathbb{E}(Y | X = x) = Y - \beta_0 - \beta_1 x$ est appelé **erreur résiduelle**.

Sachant $X = x$, ε est distribué selon une loi normale avec

- $\mathbb{E}(\varepsilon | X = x) = 0$;
- et $\text{Var}(\varepsilon | X = x) = \sigma^2$.

Méthode des moindres carrés

Minimisation du **critère des moindres carrés** $SS(\beta_0, \beta_1)$:

$$SS(\beta_0, \beta_1) = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2.$$

Les **estimateurs des moindres carrés** $\hat{\beta}_0$ et $\hat{\beta}_1$ minimisent $SS(\beta_0, \beta_1)$.

▶ Ajustement du modèle dans \mathbb{R}

Estimateurs des moindres carrés

- **Estimateur de β_0 :**

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}.$$

... la droite de régression ajustée passe par l'individu 'moyen', de coordonnées (\bar{x}, \bar{y}) .

- **Estimateur de β_1 :**

$$\hat{\beta}_1 = \frac{s_{xy}}{s_x^2}.$$

Estimateurs des moindres carrés

Pour un individu avec $X = x$, la **valeur ajustée de la réponse** est $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 x$.

De la même manière, la **droite de régression ajustée** a pour équation $x \mapsto \hat{\beta}_0 + \hat{\beta}_1 x$: c'est la droite *la plus proche* des données.

► Droite de régression dans \mathbb{R}

Erreur d'ajustement

Qualité de l'ajustement mesurée par :

$$\text{RSS} = \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

Estimation de σ^2 :

$$\hat{\sigma}^2 = \frac{\text{RSS}}{n-2}.$$

► Ecart-type résiduel dans \mathbb{R}

Effet groupe ou effet linéaire - Résumé

Y a t'il un effet de *ceci* sur *cela*?

- 1 **Effet groupe** : *ceci* est une variable catégorielle
 - Modèle d'analyse de la variance à un facteur
 - Modèle d'analyse de la variance à deux facteurs si données appariées
- 2 **Effet linéaire** : *ceci* est une variable quantitative
 - Modèle de régression linéaire (simple)
 - A suivre : effets linéaires par groupe ...

Une seule fonction d'ajustement : $\text{mod} = \text{lm}(y \sim x_1 + x_2)$

- Tests des effets : `anova(mod)`
- Analyse des effets : `summary(mod)`