

Test d'hypothèses Corrélation et régression sous forme d'analyses bivariées

25 & 26
Octobre 2023



PFS IRD

Analyse de données biologiques sous R



Variabilité d'un paramètre entre les USA et l'UE



**Il y a-t-il une véritable différence
significative ou est-ce le fruit du hasard ?**



Les **statistiques** peuvent répondre à notre question!!

Population VS échantillon

Population: ensemble d'individus ou d'objets de même nature (très grand ou infini)

- On ne peut pas étudier une population en entier : en statistique, on étudie donc un nombre limité d'individus, une partie de la population : **un échantillon**.
- On cherche à **déduire des propriétés** de la population à partir de l'échantillon
- Si on veut étudier la variabilité d'une variable / caractéristique d'intérêt de la population, il faut avoir un **échantillon représentatif** (tiré de façon aléatoire)

Dans une population, on peut mesurer un caractère : une variable qui est le résultat d'un phénomène aléatoire

- Qualitative
- Quantitative (continue)

Une loi de probabilité décrit le comportement aléatoire d'un phénomène dépendant du hasard

Dans une population, on peut mesurer un caractère : une variable qui est le résultat d'un phénomène aléatoire

- Qualitative
- Quantitative (continue)

Une loi de probabilité décrit le comportement aléatoire d'un phénomène dépendant du hasard

La loi normale


Si on dispose de 1000 échantillons issus d'une variable suivant une loi normale, et que l'on trace le nombre d'échantillons égaux à chaque valeur, on obtient une courbe en "cloche" / une distribution gaussienne :

$X \sim N(\mu, \sigma^2)$ avec μ and σ^2 les paramètres de cette distribution:

- μ : moyenne
- σ : écart type = dispersion des valeurs autour de la moyenne



Répartition des valeurs autour de la moyenne




Statistiques descriptives (analyses univariées)





Décrire, afficher et résumer vos données

- **Tendances générales** (moyenne, mediane...)
- **Dispersion** (variance, écart type)
- **Fréquence de distribution** (count, relative, cumulative)



Identifier les caractéristiques de chaque variable de vos données

→ Permet de formuler des hypothèses et guider vos analyses statistiques



Make inferences about the population


- Comment puis-je utiliser mon échantillon pour faire des prédictions sur la population ?
= **Estimation**
- Comment prouver une théorie sur le comportement de mes données (comparaison) ?
- = **Hypothesis Testing**

Comparaison de moyennes et Hypothèses


Essayer de valider une hypothèse relative à un paramètre de la population à partir d'un échantillon de comparaisons

Question: Y a-t-il une **vraie** différence ou est-ce le fruit du hasard?


Null Hypothesis H0



Alternative hypothesis H1




We are testing the null hypothesis!




Comparaison de moyennes et Hypothèses

Si H_0 vraie... pas de différences




Même distribution
→ **Fluctuation d'échantillonnage**

Si H_0 rejetée, H_1 acceptée




2 distributions différentes

**Problème d'inférences : soumises à des erreurs !
Le risque est lié au résultat du test d'hypothèse
A cause de votre échantillonnage !**




Le risque d'erreur de première espèce: α

- C'est une probabilité entre 0 et 1, ou 0% et 100%
- C'est lorsqu'on **affirme une différence alors qu'il n'y en a pas (=Faux positif)!!**




α = Risque de rejeter H_0 , si H_0 est vrai

N= 25 carreaux
→ 80% Bleu




N= 25 carreaux
→ 32% Bleu




Les deux échantillons proviennent t-il du même dallage (même distribution)?

- Test stat non (rejet H0)...
- mais ...

Provient du même dallage/population (50% bleu, 50 % jaune)!!




Risque faible de
tomber sur ce type
d'échantillons (**rare**)




Conclure sur la base de nos échantillons qu'ils provenaient de **deux populations différentes**
--> **Erreur de type I**

Données proviennent d'une même distribution mais...



- Risque α est choisi AVANT le test : **Seuil de significativité**
- α souvent positionné à 5% (rejeter à tort H_0)
- En sciences, le "presque aucune chance" se traduit par dans moins de 5% des cas où H_0 est vraie = **pvalue < 0.05**



Concept de la p-value...



1st Flip 2nd Flip




Ma pièce est spéciale : Pile deux fois de suite !

L'hypothèse nulle H_0 : même si j'ai obtenu deux Pile d'affilée, ma pièce n'est pas différente d'une pièce normale !

Une petite p-value nous dira de rejeter H_0 (p-value < 0.05)!

Testons cette hypothèse en calculant la p-value!



Outcomes	Probability
	0.25
	0.5
	
	0.25

The number of times
we got **2 Heads**.
The total number of
outcomes.

1st Flip



2nd Flip



A **p-value** is composed of three parts:

1) The probability random chance would result in the observation.

2) The probability of observing something else that is equally rare.

3) The probability of observing something rarer or more extreme.

A small p-value will tell us to reject H_0
(p-value < 0.05)!

Nothing

Outcomes Probability



0.25



0.5




0.25

P- value for 2 Heads (Sum of three parts) = $0.25 + 0.25 + 0 = 0.50$!


My coin is not special! p-value >>> 0.05!!!

Le risque d'erreur de deuxième espèce: β


Erreur de type II : On ne conclut pas à une différence alors qu'il y en a 1 (=« **Faux Négatif** »)
→ Probabilité de ne pas rejeter H_0 , si H_1 est vrai



On ne sait pas calculer le risque B




48% de bleu




52% de bleu

Ces deux échantillons proviennent ils de deux dallages
(populations) différents ou non?

60% de bleu




30% de bleu





- 2 dallages différents = 2 populations différentes, H_0 devrait être rejetée
Mais ça n'aurait pas été le cas lors du test avec notre échantillonnage...

Mais dans certains cas...



Scientifiquement ... Cas échantillonnage représentatif de la population




→ H_0 « correctement » rejetée

→ = les données n'appartiennent pas à la même distribution

→ DEUX populations différentes







Relation fondamentale

$$\text{Power} = 1 - \beta$$



Power/Puissance test : Probabilité de rejeter correctement l'hypothèse H_0
= Capacité d'un test stat de détecter les différences ou relation

Plus la taille augmente plus les différences apparaissent!
La puissance du test augmente!




Bilan


Population

TEST échantillons

	H_0 vraie	H_1 vraie
accepter H_0	OK	erreur type 2 β Faux Négatif
rejeter H_0	erreur type 1 α Faux positif	OK



Rappel sur les variables... important pour tests statistiques



- Marié, Célibataire, Divorcé...
- Fumeur/non Fumeur
- >10; [10-20]; >20
- Notes d'examen entre 0 et 20
- Taille, poids : nombre infini
- Nombre limité

Tests d'hypothèses bivariés

- Cherchent à quantifier l'association brute entre **une** variable à expliquer (réponse) et **une** variable explicative (facteur).

- Le choix du test statistique sera fonction du type de variable!

Cas: 1 variable quantitative (réponse) et 1 qualitative (explicatif)!

→ Est-ce que les variations de la **richesse en espèce** (variable réponse) peuvent être expliquées par la variable explicative (facteur) **Traitement**?

→ Comparaison de **moyennes** entre groupes

- Utilisation de test paramétrique, non paramétrique??
- Choix du test?? Significativité ? (pvalue)
- Combien de groupes??
- Faut-il faire un test Post hoc ??



Quel test statistique pour échantillons indépendants?
UNE variable catégorique (H/F) & UNE variable continue (numérique)

Normalité des données?


Shapiro, Q-Q plots

Quel test statistique pour échantillons indépendants?
UNE variable catégorique (H/F) & UNE variable continue (numérique)

Normalité des données?
Shapiro, Q-Q plots

OUI


Test paramétrique



Caractéristiques d'une distribution normale

Symétrique



- Centré sur la moyenne/mean
- Dispersion autour de la moyenne: Standard deviation (SD)
 - 95% data sont dans ± 2 SD



Vérifier la normalité des données: Shapiro Test & QQ-plots!!

Q-Q plot normale: Comparer sa distribution à la distribution normale

Est-ce que mes données suivent une loi normale?






Normal Data ($\mu = 0$, $SD = 1$)




Conclusion?

La droite du QQ-Plot indique la position que doivent avoir les points s'ils obéissent exactement à la distribution normale

Quelles sont les distributions correspondantes à ces QQ-plots?



??????????



Quel test statistique pour échantillons indépendants?
UNE variable catégorique (H/F) & UNE variable continue (numérique)

Normalité des données?
Shapiro, Q-Q plots

OUI


Test paramétrique

Homogénéité Variance?
Bartlett, levene, F-test

Variance = S^2 / σ^2

- Variance mesure le degré de dispersion d'un ensemble de données autour de la moyenne
- Moyenne arithmétique des carrés des écarts à la moyenne! ☹️
- Exprimée en **Unité carré**

$$S^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n - 1}$$



Ecart-type (Standard Deviation) = S / σ

$$S = \sqrt{S^2}$$

L'avantage de l'écart-type est de s'exprimer dans **la même unité** que la série de données


$$S^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1} = \frac{\text{Sum of Squares (SS)}}{n-1}$$

Exple de Résultats stats utilisant la variance

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
groupe	3	13.03	4.343	0.211	0.887
Residuals	14	288.75	20.625		

- **Sum of Squares (= SS, Sum Sq)** dans la description de vos résultats stats!
→ Numérateur de la Variance!!
- **Mean Square (= Mean Sq= Toute la formule = VARIANCE!!!)**


SS sera bien plus grande dans l'échantillon



Appliquer un test paramétrique... check-list!

- Vérifier la **normalité** des données : Shapiro Test & QQ-plots

H0: « données suivent une distribution normale »




- Vérifier **l'homogénéité** de la variance : F-test (2 groups), Bartlett's & Levene's tests

H0: « pas de différence »

$$S^2 = 169$$

$$S^2 = 289$$



Quel test statistique pour échantillons indépendants?
UNE variable catégorique (H/F) & UNE variable continue (numérique)

Normalité des données?
Shapiro, Q-Q plots

OUI

Test paramétrique

Homogénéité Variance?
Bartlett, levene, F-test

NON

Transformation
(racine carrée, log)

OUI

OUI

Combien de groupes?

2 Groupes


3 Groupes
et plus

T-test

One way ANOVA

ANOVA: ANalysis Of VAriance (One way Anova= Univariée) (3 groups minimum)

- Compare la **variance des moyennes des groupes** à celle à l'intérieur des groupes (i.e. **variance intra-groupe**) pour une seule variable explicative (Qualitative!)



ANOVA: ANalysis Of VAriance (One way Anova= Univariée)

- Postulat = Les **VARIATIONS** observées entre les **MOYENNES** des différents groupes (AU MOINS 3) sont si **faibles** qu'elles **s'expliquent facilement par le hasard!!!**
- Evaluation : Compare la **variance inter-groupes (DES MOYENNES)** à celle à l'intérieur des groupes (i.e. **variance intra-groupe**) pour une seule variable/facteur (Qualitative!)
- Pourquoi L'ANOVA → variations à travers la grandeur **Variance** :
- Comment ? Décomposition de la variance totale :

Variance inter-groupes + **Variance intra-groupes**

attribuable au facteur

attribuable à l'expérimentale
(fluctuation de l'échantillonnage, hasard)

• Statistique F =
$$\frac{\text{Effet du facteur!} \quad \text{Variance Inter-groupes}}{\text{Variance Intra-groupes} \quad \text{Effet du hasard!}}$$


	Df	Sum Sq	Mean Sq	F value	Pr(>F)
groupe	3	13.03	4.343	0.211	0.887
Residuals	14	288.75	20.625		

L'idée : si le **facteur** a vraiment un effet, la part des **variations qu'on peut lui attribuer**
 = **Variance inter-groupes** sera **significativement plus élevée** que la part des **variations**
 qu'on ne peut pas lui attribuer = **Variance Intra-groupes**!

Statistique F suit une loi dites de Fisher-Snedecor : = **Distribution F**
 utilisée pour test des variances, distribution des variances n'étant pas normale.

- Mise en relation d'une valeur observée de F , avec la probabilité a priori de rencontrer une telle valeur ($>$ ou $=$) par hasard:
 → **probabilité donnée par la loi = p-value!**

		Dénominateur S^2	Numérateur S^2	S^2		
		Df	Sum Sq	Mean Sq	F value	Pr(>F)
inter	groupe	3	13.03	4.343	0.211	0.887
intra	Residuals	14	288.75	20.625		




- Mise en relation d'une valeur observée de F , avec la probabilité a priori de rencontrer une telle valeur ($>$ ou $=$) par hasard:
 → **probabilité donnée par la loi = p-value!**

	Dénominateur S^2	Numérateur S^2	S^2	
	Df	Sum Sq	Mean Sq	F value Pr(>F)
groupe	3 ÷	13.03	4.343	0.211 0.887
Residuals	14 ÷	288.75	20.625	

variances	ddl	F
entre k groupes	v_k $k-1$	v_k / v_r
résiduelle	v_r $N - k$	

Degré de liberté



- **Two-ways ANOVA** : Influences de **DEUX** variables **qualitatives** sur **UNE** variable **quantitative**.

Exple: Influence du type de sol et de la température (variable ordinale) sur rendement de plantes

Tests non-paramétrique

**Aucune hypothèse n'est faite sur la distribution des données :
Tests sans distribution, ils sont alternatifs aux tests paramétriques**

- **Wilcoxon Rank test** : samples are paired/unpaired, 2 sample groups
- **Mann-Withney test**: Independent samples, 2 sample groups
- **Kruskal wallis test** : Independant samples, Three or more groups

→ Basé sur la moyenne des rangs : on classe les valeurs, on remplace par une position (1,2 etc), Compare la moyenne des rangs entre les groupes

Quel test statistique pour échantillons indépendants?
UNE variable catégorique (H/F) & UNE variable continue (numérique)

Normalité des données?

Shapiro, Q-Q plots

NON

Test non paramétrique

Combien de groupes?

2 Groupes

→ Unpaired
Wilcoxon test
→ Mann-
Whitney

3 Groupes
et plus

Kruskal Wallis

Post-hoc Test (Dunn)

Quel test statistique pour échantillons indépendants?
UNE variable catégorique (H/F) & UNE variable continue (numérique)

Normalité des données?
Shapiro, Q-Q plots

OUI

Test paramétrique

Homogénéité Variance?
Bartlett, levene, F-test

NON

Transformation
(racine carrée, log)

OUI

Combien de groupes?

2 Groupes

T-test

3 Groupes
et plus

One way ANOVA

Post-hoc Test (Tukey)

NON

Test non paramétrique

Combien de groupes?

2 Groupes

→ Unpaired
Wilcoxon test
→ Mann-
Whitney



3 Groupes
et plus

Kruskal Wallis

Post-hoc Test (Dunn)

CAS Mesures répétées – échantillons appariés

Exple= série temporelle, Avant-Après Traitement...



Post-hoc Test

Cas des tests statistiques avec **au moins 3 groupes!**

- ANOVA, Kruskal-wallis etc

→ Le résultat d'un test ANOVA est une **p-value Globale,**

Exple: Vous comparez l'effet de 3 types (de sol A,B,C) sur la croissance plante.

ANOVA vous renvoie une p-value de 0.03 ($<$ au seuil de 0.05), donc significative (H_0 est rejetée).

→ Cela ne vous indique pas quelles paires de groupes sont significativement différents!

Vous devez faire **un Test Post-hoc** pour le savoir :

→ comparaisons multiples (exple: Gp A vs. Grp. B; GrpB vs. Grp C; Grp C vs. Grp A!)

- Paramétrique Post-hoc test (ANOVA) → **Tukey Test**
- Non-paramétrique Post-hoc test (Kruskal wallis) → **Dunn Test**

Connexion à l'évènement wooclap : **YTEIXI**



1

Allez sur wooclap.com

2

Entrez le code d'évènement dans le bandeau supérieur

Code
d'évènement
YTEIXI



1

Envoyez **@YTEIXI** au **06 44 60 96 62**

2

Vous pouvez participer

Le problème des tests multiples : augmentation du risque...

Les tests sont basés sur des probabilités, il y a donc toujours un risque de tirer des conclusions erronées !

→ **Aucun test d'hypothèse n'est fiable à 100 %**

Effectuer des tests d'hypothèse :

Vous avez deux hypothèses :

- H_0 : Hypothèse nulle = l'hypothèse de référence : pas de différence
- H_1 : Hypothèse alternative : Il y a une différence



Vous rencontrez : Erreur de type I : α = Risque alpha

- $\alpha = 0,05$ C'est la probabilité de rejeter H_0 à tort ! (seuil de significativité)
- En d'autres termes, une chance acceptable de faux positif !!!

Abondance différentielle : Tests multiples !!

1 TEST :

$$P_{\text{False Positive}} = P_{\text{error}} = \underline{\alpha} = 0.05$$

Prob complémentaire

$$P_{\text{no_error}} = 1 - \underline{\alpha} = 0.95$$

2 TESTS sans faire d'erreur :

$$P_{\text{no_error in two tests}} = (1 - \underline{\alpha}) * (1 - \underline{\alpha}) = (1 - \underline{\alpha})^2$$

Prob complémentaire

$$P_{\text{at_least_ONE_error in two tests}} = 1 - (1 - \underline{\alpha})^2$$

Generalisation à n TESTS

$$P_{\text{at_least_ONE_error in n tests}} = 1 - (1 - \underline{\alpha})^n$$


It's called the global α risk

What does it means...

- You test **ONE** ASVs ($n=1$) for differential abundance: $1-(1-\underline{\alpha})^n = 1-(1-0.05)^1 = \mathbf{0.05}$
- You test **3** ASVs ($n=3$): $1-(1-0.05)^3 = \mathbf{0.14}$
- You test **100** ASVs ($n=100$): $1-(1-0.05)^{100} = \mathbf{0.9941}$

The global risk $\underline{\alpha}$ reach $0.9941=99.41\%!!!!$

→ 99% de rejet à tort H_0 au moins une fois



Il faut ajuster ce phénomène en utilisant la **p.value ajustée** !

FDR : False Discovery Rate : Benjamini-Hochker


L'idée : Rejeter les mauvaises données qui ont l'air bonnes!!!

Benjamini-hocherk **ajuste la p-values**
Pour limiter le nombre de **faux positifs**
qui sont signalés comme **significatifs** ($pvalue < 0.05$)


p-values ajustées
= augmente la valeur!

Using FDR cutoff < 0.05
signifie que moins de 5% des résultats significatifs seront des faux positifs


Mathematical approach FDR-Benjamini-Hochker



10 pairs of samples taken from the same distribution. (i.e. 10 genes that were not effected by the drug).




Notice that one of the p-values is a false positive (that is to say, less than 0.05)



1- Ranking pvalue

Prepare space for adjusted p-value



2- Largest adjusted pvalue and larger pvalue are same

Next adjusted pvalue

[illegible]


The smallest of the two options

b: the current p-value * $\left(\frac{\text{total \# of p-values}}{\text{p-value rank}} \right)$ a: The previous adjusted p-value = 0.91


b: 0.81 * $\left(\frac{10}{9} \right) = 0.90$

[illegible]

Finalement...



Finalemment...



Le faux positif ne l'est plus grâce à cette méthode d'ajustement !!

Régression linéaire & Corrélation (analyses bivariées)


Objectif : Analyser le lien qui peut exister entre deux variables (ici : quantitatives)
(Deux variables qualitatives -> test Khi2)

Lien/relation/dépendance entre les variables


→ Les valeurs de deux variables **n'évoluent pas indépendamment** mais présentent au contraire une certaine forme, une certaine régularité.



L'intensité de l'association n'indique pas un lien de causalité ...





Quelle est la relation entre les variables dans chaque graphique ?



Association: Coefficient de corrélation r

Intensité & Direction de l'association entre deux variables


- Relation linéaire stricte : Pearson (r , paramétrique)
- Relation monotone: Spearman (Rho , non-paramétrique)
Kendall (Tau , non-paramétrique), Alternative to Spearman (petit échantillonnage)



Coefficient r range between -1 et 1



- **Corrélation positive**: Les valeurs des deux variables ont tendance à augmenter ensemble
- **Corrélation négative**: Les valeurs d'une variable ont tendance à augmenter et les valeurs de l'autre variable à diminuer
- **Zero** : association non **LINEAIRE** (Pearson)

pour information!!!



Parce qu'il n'est jamais inutile de contrôler ses résultats...





- r proche de Zero: pas d'association??



Vraiment pas inutile : Anscombe...

- 4 jeux de données avec les mêmes statistiques descriptives

Propriété	Valeur
Moyenne des x	9,0
Variance des x	10,0
Moyenne des y	7,5
Variance des y	3,75



$r = ?$



0.3?
0.5?
0.8?

- Loi de distribution de r sous l'hypothèse H_0 : Pas de lien statistique entre X et Y
- Accès aux p-values



TP !


Régression linéaire simple

- Uniquement pour les variables quantitatives
- Tracer le diagramme de dispersion : Existe-t-il une **relation**?
- Est-elle **linéaire** ?
- Quelle est son **orientation** (positive, négative)?
- Si l'association est **linéaire** → Faire une **régression**

Nécessite

- Distribution normale
- Homogénéité des variances

Votre régression linéaire favorite... courbe de calibration !!!




Expliquer & prédire !


Modélisation d'une relation de type linéaire($Y=aX+b$)

Modèle cherchant à établir une **relation linéaire** entre une variable, dite **expliquée/dépendante** (Y), et une autre dite **explicative/indépendante** (X).

Le **poids** de la souris permet-il de prédire correctement la **taille** (R^2)?
La relation est-elle due au hasard ? (p-value)





Méthode des moindres carrés




Méthode qui consiste à déterminer la droite dite « de régression de y en x » qui minimise la somme des distances des valeurs/points par rapport à la droite

Rotate the line a little bit more...




Again & again, recalculate

Resume : Sums of squared residuals for each rotation



Meilleure rotation (= position de la droite), celle qui minimise le score de la somme des carrés des distances résiduelles !!!!

Le poids de la souris permet-il de prédire correctement la taille (R^2)?




$$y = 0.1 + 0.78x$$

Dependence to « Mouse weight »

Coefficient R^2 = qualité de la prédiction


A quel point le modèle permet de correctement prédire la taille de la souris en tenant compte de son poids ?

R^2 : Détermination du Coefficient



$$\text{Var}(\text{mean}) = \frac{\text{SS}(\text{mean})}{n}$$

There is less variation around the line that we fit by least-squares.




$$\text{Var}(\text{fit}) = \frac{(\text{data} - \text{line})^2}{n}$$

- Taking into account « weight », less variations?? ($\text{SS}_{\text{fit}} < \text{SS}_{\text{Mean}}$)!

R^2 = % de variation de la variable réponse expliquée par un modèle linéaire (variable poids)

$$R^2 = \frac{\text{Var}(\text{mean}) - \text{Var}(\text{fit})}{\text{Var}(\text{mean})}$$




$$R^2 = \frac{11.1 - 4.4}{11.1} = 0.6 = 60\%$$

$$R^2 = \frac{\text{Variation expliquée}}{\text{Variation totale}}$$

→ Le modèle établi explique 60% de la variabilité/variance de la "taille de la souris".

→ R^2 entre 0 et 1

TO be sure ...



R^2 & significativité ?

- Nécessite une p-value...
- Variance ... la p-value est donnée par le ratio F & distribution F

$$F = \frac{\text{The variation in mouse size explained by weight}}{\text{The variation in mouse size not explained by weight}}$$

Relation entre r & R^2

Le coefficient de corrélation de Pearson r peut être lié à la régression linéaire R^2
Son carré est la variance expliquée par la régression (R^2)

$r = 0.5 \rightarrow R^2 = 0.25 \rightarrow 25\%$ of the Y variance explained by X variable... ☹️