

## Propriétés d'une probabilité

- $0 \leq P(A) \leq 1$
- $P(\emptyset) = 0$  et  $P(S) = 1$
- Si  $A_1, A_2, A_3, \dots$  sont mutuellement exclusifs, alors  $P(A_1 \cup A_2 \cup A_3 \dots) = \sum_i P(A_i)$ .
- $P(A) = 1 - P(\bar{A})$
- Si  $A \subset B$ , alors  $P(A) \leq P(B)$
- $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- $P(A \cup B \cup C) = P(A) + P(B) + P(C) - P(A \cap B) - P(B \cap C) - P(A \cap C) + P(A \cap B \cap C)$
- Si les  $n$  résultats de  $\mathcal{S}$  sont équiprobables, alors  $P(A) = n(A)/n$ .

## Techniques de dénombrement

- *Permutations* :
  - il existe  $n!$  arrangements ordonnés de  $n$  éléments distincts ;
  - il existe  $P_r^n = \frac{n!}{(n-r)!}$  façons de choisir  $r$  objets parmi  $n$  objets distincts en tenant compte de l'ordre de pige.
  - il existe  $\frac{n!}{n_1!n_2! \dots n_k!}$  façons de permuter  $n$  objets séparés en  $k$  groupes formés respectivement de  $n_1, n_2, \dots, n_k$  objets indiscernables.
- *Combinaisons* :
  - il existe  $C_r^n = \binom{n}{r} = \frac{n!}{r!(n-r)!}$  façons de choisir  $r$  objets parmi  $n$  objets distincts sans tenir compte de l'ordre de pige.

## Probabilités conditionnelles

- $P(A | B) = \frac{P(A \cap B)}{P(B)}$
- $P(A \cap B) = P(A)P(B | A) = P(B)P(A | B)$
- $A$  et  $B$  sont indépendants si et seulement si  $P(A \cap B) = P(A)P(B)$
- Si  $B_1, B_2, \dots, B_k$  forment une partition de  $\mathcal{S}$ , alors
  - $P(A) = \sum_{i=1}^k P(A | B_i) P(B_i)$  (théorème des probabilités totales)
  - $P(B_r | A) = \frac{P(A | B_r) P(B_r)}{P(A)} = \frac{P(A | B_r) P(B_r)}{\sum_{i=1}^k P(A | B_i) P(B_i)}$  (théorème de Bayes)

## Variables aléatoires et distributions

Notion abordée	Cas d'une variable discrète	Cas d'une variable continue
Fonction de répartition	$F(x) = P(X \leq x) = \sum_{t \leq x} p(t)$	$F(x) = P(X \leq x) = \int_{-\infty}^x f(t) dt$
Fonction de masse/densité	$p(x) = P(X = x)$	$f(x) = \frac{d}{dx} F(x)$
Probabilité $P(a < X \leq b)$	$F(b) - F(a) = \sum_{a < x \leq b} p(x)$	$F(b) - F(a) = \int_a^b f(x) dx$
Espérance de $X$ : $E(X)$	$\mu = \sum_i x_i p(x_i)$	$\mu = \int_{-\infty}^{\infty} x f(x) dx$
Variance de $X$ : $V(X)$	$\sigma^2 = \sum_i (x_i - \mu)^2 p(x_i)$	$\sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx$

Notons que  $V(X) = E[(X - \mu)^2] = E(X^2) - \mu^2$ .

Notion abordée	Cas d'une variable discrète	Cas d'une variable continue
Distribution conjointe	$p(x_1, x_2) = P(X_1 = x_1 \text{ et } X_2 = x_2)$	$f(x_1, x_2)$
Distribution marginale de $X_1$	$p_{X_1}(x_1) = P(X_1 = x_1) = \sum_{x_2} p(x_1, x_2)$	$f_{X_1}(x_1) = \int_{-\infty}^{\infty} f(x_1, x_2) dx_2$
Dist. conditionnelle de $X_1$ sachant que $X_2 = b$	$p_{X_1 b}(x_1) = P(X_1 = x_1   X_2 = b) = \frac{p(x_1, b)}{p_{X_2}(b)}$	$f_{X_1 b}(x_1) = \frac{f(x_1, b)}{f_{X_2}(b)}$
Espérance conditionnelle de $X_1$ sachant que $X_2 = b$	$E(X_1 b) = \sum_{x_1} x_1 p_{X_1 b}(x_1)$	$E(X_1 b) = \int_{-\infty}^{\infty} x_1 f_{X_1 b}(x_1) dx_1$

### • Indépendance de deux variables aléatoires

- $X_1$  et  $X_2$  sont indépendantes si et seulement si

$$p(x_1, x_2) = p_{X_1}(x_1) p_{X_2}(x_2) \quad \text{pour tout } (x_1, x_2) \quad (\text{cas discret})$$

$$f(x_1, x_2) = f_{X_1}(x_1) f_{X_2}(x_2) \quad \text{pour tout } (x_1, x_2) \quad (\text{cas continu})$$

- Si  $X_1$  et  $X_2$  sont indépendantes, alors leur covariance et leur corrélation sont nulles.

### • Covariance et corrélation

Covariance :  $\text{Cov}(X_1, X_2) = E[(X_1 - \mu_1)(X_2 - \mu_2)] = E(X_1 X_2) - E(X_1)E(X_2)$

Corrélation :  $\rho = \frac{\text{Cov}(X_1, X_2)}{\sqrt{V(X_1)V(X_2)}}$

## Lois discrètes usuelles

Lois discrètes	Fonction de masse	Espérance	Variance
Bernoulli ( $p$ )	$p(k) = p^k(1-p)^{1-k}$ , pour $k = 0, 1$	$p$	$p(1-p)$
Binomiale ( $n, p$ )	$p(k) = \binom{n}{k} p^k(1-p)^{n-k}$ , pour $k = 0, 1, \dots, n$	$np$	$np(1-p)$
Géométrique ( $p$ )	$p(k) = (1-p)^{k-1}p$ , pour $k = 1, 2, 3, \dots$	$\frac{1}{p}$	$\frac{1-p}{p^2}$
Pascal ( $r, p$ )	$p(k) = \binom{k-1}{r-1} p^r(1-p)^{k-r}$ , pour $k = r, r+1, \dots$	$\frac{r}{p}$	$\frac{r(1-p)}{p^2}$
Poisson ( $\lambda$ )	$p(k) = e^{-\lambda} \frac{\lambda^k}{k!}$ , pour $k = 0, 1, 2, \dots$	$\lambda$	$\lambda$

## Lois continues usuelles

Lois discrètes	Fonction de masse	Espérance	Variance
Uniforme ( $\alpha, \beta$ )	$f(x) = \frac{1}{\beta - \alpha}$ , pour $\alpha \leq x \leq \beta$	$\frac{\alpha + \beta}{2}$	$\frac{(\beta - \alpha)^2}{12}$
Exponentielle ( $\lambda$ )	$f(x) = \lambda e^{-\lambda x}$ , pour $x > 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$
Gamma ( $r, \lambda$ )	$f(x) = \frac{\lambda^r}{\Gamma(r)} x^{r-1} e^{-\lambda x}$ , pour $x > 0$	$\frac{r}{\lambda}$	$\frac{r}{\lambda^2}$
Normale ( $\mu, \sigma^2$ )	$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$ , pour $-\infty < x < \infty$	$\mu$	$\sigma^2$

### Loi normale univariée : $X \sim N(\mu, \sigma^2)$

- Fonction de densité :  $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left[\frac{x-\mu}{\sigma}\right]^2}$ , pour  $-\infty < x < \infty$
- Si  $X \sim N(\mu, \sigma^2)$ , alors  $Z = \frac{X - \mu}{\sigma} \sim N(0, 1)$  (loi normale centrée réduite)

### Théorème central limite

<p>Si <math>X_1, X_2, \dots, X_n</math> sont des variables aléatoires          → indépendantes,          → identiquement distribuées (loi quelconque),          → de moyenne <math>\mu &lt; \infty</math>,          → de variance <math>\sigma^2 &lt; \infty</math>,          → et si <math>n</math> est assez grand,</p>	}	<p>alors</p> $\sum_{i=1}^n X_i \approx N(n\mu, n\sigma^2)$ <p>et</p> $\bar{X} \approx N\left(\mu, \frac{\sigma^2}{n}\right).$
---	---	---

- Si les  $X_i$  sont des variables aléatoires discrètes, on utilise une correction pour la continuité.

**Loi normale bivariée :**  $(X_1, X_2) \sim N_2(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$

- Fonction de densité conjointe :

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[ \left( \frac{x_1-\mu_1}{\sigma_1} \right)^2 - 2\rho \left( \frac{x_1-\mu_1}{\sigma_1} \right) \left( \frac{x_2-\mu_2}{\sigma_2} \right) + \left( \frac{x_2-\mu_2}{\sigma_2} \right)^2 \right] \right\},$$

pour  $-\infty < x_1, x_2 < \infty$ .

- Lois marginales :

◦  $X_1 \sim N(\mu_1, \sigma_1^2)$     et     $X_2 \sim N(\mu_2, \sigma_2^2)$

- Lois conditionnelles :

◦  $X_1|x_2 \sim N \left( \mu_1 + \rho\sigma_1 \left( \frac{x_2 - \mu_2}{\sigma_2} \right), \sigma_1^2(1 - \rho^2) \right)$

◦  $X_2|x_1 \sim N \left( \mu_2 + \rho\sigma_2 \left( \frac{x_1 - \mu_1}{\sigma_1} \right), \sigma_2^2(1 - \rho^2) \right)$

### Statistique descriptive

- Valeurs observées de la variable  $X$

— Dans l'ordre de collecte :  $x_1, x_2, \dots, x_n$

— En ordre croissant :  $x_{(1)}, x_{(2)}, \dots, x_{(n)}$

- Mesures de position

Statistique	Symbole	Formule
Moyenne	$\bar{x}$	$\frac{1}{n} \sum_{i=1}^n x_i$
Médiane	$\tilde{x} = Q2$	$q_{0,5} = x_{(\frac{n+1}{2})}$
Mode	$m$	valeur la plus fréquente
Quantile d'ordre $\gamma$	$q_\gamma$	$x_{(\gamma n + 0,5)}$
Premier quartile	$Q1$	$q_{0,25} = x_{(0,25 n + 0,5)}$
Troisième quartile	$Q3$	$q_{0,75} = x_{(0,5 n + 0,5)}$

- Mesures de dispersion

Statistique	Symbole	Formule
Variance	$s^2$	$\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
Écart-type	$s$	$\sqrt{s^2}$
Étendue	$R$	$x_{(n)} - x_{(1)}$
Coefficient de variation	$CV$	$\frac{s}{\bar{x}}$
Écart interquartile	$EIQ$	$Q3 - Q1$

## Distributions échantillonnales

Nom de la loi	Notation	Espérance	Variance	Quantile* d'ordre $1 - \alpha$	Exemple de statistique**
Normale centrée réduite	$N(0, 1)$	0	1	$z_\alpha$	$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$
Khi-carré avec $k$ degrés de liberté	$\chi_k^2$	$k$	$2k$	$\chi_{\alpha; k}^2$	$\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$
Student avec $k$ degrés de liberté	$t_k$	0	$\frac{k}{k-2}$	$t_{\alpha; k}$	$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1}$
Fisher avec $u$ et $v$ degrés de liberté	$F_{u,v}$	$\frac{v}{v-2}$	$\frac{2v^2(u+v-2)}{u(v-2)^2(v-4)}$	$F_{\alpha; u,v}$	$\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2} \sim F_{n_1-1, n_2-1}$

\* Quantile d'ordre  $1 - \alpha$  :  $P(\text{Variable} > \text{Quantile}) = \alpha$

\*\* Basé sur des échantillons provenant d'une distribution  $N(\mu, \sigma^2)$

## Inférence à un échantillon :

Conditions	Para- mètre	Estimation	Err.-type estimée	Intervalle de confiance de niveau $1 - \alpha$	Distribution de la statistique de test	Région de rejet au seuil $\alpha$
Échantillon aléatoire de taille $n$ issu d'une loi $N(\mu, \sigma^2)$	$\mu$	$\bar{x} = \frac{1}{n} \sum x_i$	$\frac{s}{\sqrt{n}}$	$\bar{x} \pm t_{n-1, \alpha/2} \frac{s}{\sqrt{n}}$	$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1}$	$H_0 : \mu = \mu_o$ vs $H_1 : \mu > \mu_o$ Rejet de $H_0$ si $\frac{\bar{x} - \mu_o}{s/\sqrt{n}} \geq t_{n-1, \alpha}$
Échantillon aléatoire de taille $n$ issu d'une loi $N(\mu, \sigma^2)$	$\sigma^2$	$s^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}$	$\frac{\sqrt{2} s^2}{\sqrt{n-1}}$	$\left[ \frac{(n-1)s^2}{\chi_{n-1, \alpha/2}^2}, \frac{(n-1)s^2}{\chi_{n-1, 1-\alpha/2}^2} \right]$	$\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$	$H_0 : \sigma^2 = \sigma_o^2$ vs $H_1 : \sigma^2 > \sigma_o^2$ Rejet de $H_0$ si $\frac{(n-1)s^2}{\sigma_o^2} \geq \chi_{n-1, \alpha}^2$
Échantillon aléatoire de grande taille $n$ issu d'une loi dichotomique	$p$	$\hat{p} = \frac{\text{nb de cas}}{n}$	$\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$	$\hat{p} \pm z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$	$\frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \approx N(0, 1)$	$H_0 : p = p_o$ vs $H_1 : p > p_o$ Rejet de $H_0$ si $\frac{\hat{p} - p_o}{\sqrt{\frac{p_o(1-p_o)}{n}}} \geq z_\alpha$

## Tests d'hypothèses

$$\alpha = P(\text{Rejeter } H_0 \mid H_0 \text{ est vraie}) = P(\text{erreur de 1}^{\text{re}} \text{ espèce}) = \text{Seuil du test}$$

$$\beta = P(\text{Ne pas rejeter } H_0 \mid H_1 \text{ est vraie}) = P(\text{erreur de 2}^{\text{e}} \text{ espèce})$$

$$1 - \beta = P(\text{Rejeter } H_0 \mid H_1 \text{ est vraie}) = \text{Puissance du test}$$

Seuil observé (valeur  $P$ ) : probabilité que la statistique du test prenne une valeur au moins aussi extrême que celle observée, si  $H_0$  est vraie. (On rejette  $H_0$  si la valeur  $P$  est inférieure à  $\alpha$ .)

## Inférence à deux échantillons indépendants :

Échantillons aléatoires indépendants de tailles $n_1$ et $n_2$ issus de lois...	Paramètre	Estimation	Erreur-type estimée	Intervalle de confiance de niveau $1 - \alpha$	Distribution de la statistique de test	Région de rejet au seuil $\alpha$
$N(\mu_1, \sigma^2)$ et $N(\mu_2, \sigma^2)$  (Variances égales)	$\mu_1 - \mu_2$	$\bar{x}_1 - \bar{x}_2$	$s_c \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$  $s_c^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$	$(\bar{x}_1 - \bar{x}_2) \pm t_{k, \alpha/2} s_c \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$  $k = n_1 + n_2 - 2$	$\frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{s_c \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t_k$  $k = n_1 + n_2 - 2$	$H_0 : \mu_1 = \mu_2$ vs $H_1 : \mu_1 > \mu_2$ Rejet de $H_0$ si $\frac{\bar{x}_1 - \bar{x}_2}{s_c \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \geq t_{k, \alpha}$  (TEST DE STUDENT)
$N(\mu_1, \sigma_1^2)$ et $N(\mu_2, \sigma_2^2)$  (Variances inégales)	$\mu_1 - \mu_2$	$\bar{x}_1 - \bar{x}_2$	$\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$	$(\bar{x}_1 - \bar{x}_2) \pm t_{k, \alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$  $k = \frac{(s_1^2/n_1 + s_2^2/n_2)^2}{\frac{(s_1^2/n_1)^2}{n_1 - 1} + \frac{(s_2^2/n_2)^2}{n_2 - 1}}$	$\frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \sim t_k$  $k = \frac{(s_1^2/n_1 + s_2^2/n_2)^2}{\frac{(s_1^2/n_1)^2}{n_1 - 1} + \frac{(s_2^2/n_2)^2}{n_2 - 1}}$	$H_0 : \mu_1 = \mu_2$ vs $H_1 : \mu_1 > \mu_2$ Rejet de $H_0$ si $\frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \geq t_{k, \alpha}$  (TEST DE WELCH)
$N(\mu_1, \sigma_1^2)$ et $N(\mu_2, \sigma_2^2)$	$\frac{\sigma_1^2}{\sigma_2^2}$	$\frac{S_1^2}{S_2^2}$	à omettre	$\left[ \frac{1}{F_{k, \ell, \alpha/2}} \frac{s_1^2}{s_2^2}, \frac{1}{F_{k, \ell, 1 - \alpha/2}} \frac{s_1^2}{s_2^2} \right]$  $k = n_1 - 1$ et $\ell = n_2 - 1$	$\frac{S_1^2/S_2^2}{\sigma_1^2/\sigma_2^2} \sim F_{k, \ell}$  $k = n_1 - 1$ et $\ell = n_2 - 1$	$H_0 : \sigma_1^2 = \sigma_2^2$ vs $H_1 : \sigma_1^2 > \sigma_2^2$ Rejet de $H_0$ si $\frac{s_1^2}{s_2^2} \geq F_{k, \ell, \alpha}$  (TEST DE FISHER)
Binomiale(1, $p_1$ ) et Binomiale(1, $p_2$ )  ( $n_1$ et $n_2$ grands)	$p_1 - p_2$	$\hat{p}_1 - \hat{p}_2$	$\sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}$	$(\hat{p}_1 - \hat{p}_2) \pm z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}$	$Z = \frac{(\hat{p}_1 - \hat{p}_2) - (p_1 - p_2)}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$  $\hat{p} = \frac{n_1 \hat{p}_1 + n_2 \hat{p}_2}{n_1 + n_2}$	$H_0 : p_1 = p_2$ vs $H_1 : p_1 > p_2$ Rejet de $H_0$ si $z_{obs} \geq z_\alpha$

## Plan d'expérience complètement aléatoire à un facteur

$a$  échantillons indépendants de taille  $n$  (donc  $N = an$  observations), variances égales

**Modèle :**  $Y_{ij} = \mu + \tau_i + E_{ij}$ , où  $E_{ij} \sim N(0, \sigma^2)$ , ( $i = 1, \dots, a, j = 1, \dots, n$ )

**Analyse de la variance :**  $H_0 : \tau_1 = \tau_2 = \dots = \tau_a = 0$  (ou  $H_0 : \mu_1 = \mu_2 = \dots = \mu_a$ )

Source de variation	Somme des carrés	Degrés de liberté	Moyenne des carrés	Statistique $F_0$	Valeur $P$
Traitements	$SS_{traitements}$	$a - 1$	$MS_{traitements} = \frac{SS_{traitements}}{a-1}$	$f_0 = \frac{MS_{traitements}}{MS_E}$	$P(F > f_0)$
Erreur	$SS_E$	$N - a$	$MS_E = \frac{SS_E}{N-a}$		où $F \sim F_{a-1, N-a}$
Total	$SS_T$	$N - 1$			

<ul style="list-style-type: none"> <li>• <math>SS_{traitements} = \sum_{i=1}^a n(\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^a \frac{Y_{i\bullet}^2}{n} - \frac{Y_{\bullet\bullet}^2}{N}</math></li> <li>• <math>SS_E = \sum_{i=1}^a \sum_{j=1}^n (Y_{ij} - \bar{Y}_{i\bullet})^2 = (n-1) \sum_{i=1}^a S_i^2</math></li> </ul>	<ul style="list-style-type: none"> <li>• <math>SS_T = \sum_{i=1}^a \sum_{j=1}^n (Y_{ij} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^a \sum_{j=1}^n Y_{ij}^2 - \frac{Y_{\bullet\bullet}^2}{N}</math></li> <li>• <math>e_{ij} = Y_{ij} - \bar{Y}_{i\bullet} = \text{résidu}</math></li> </ul>
--	--

## Plan d'expérience en blocs aléatoires complets

$b$  blocs de  $a$  unités expérimentales recevant chacune un des  $a$  traitements (donc  $ab$  observations)

**Modèle :**  $Y_{ij} = \mu + \tau_i + \beta_j + E_{ij}$ , où  $\beta_j \sim N(0, \sigma_\beta^2)$  et  $E_{ij} \sim N(0, \sigma^2)$ , ( $i = 1, \dots, a, j = 1, \dots, b$ )

**Analyse de la variance :**  $H_0 : \tau_1 = \tau_2 = \dots = \tau_a = 0$

Source de variation	Somme des carrés	Degrés de liberté	Moyenne des carrés	Statistique $F_0$	Valeur $P$
Traitements	$SS_{traitements}$	$a - 1$	$MS_{traitements} = \frac{SS_{traitements}}{a-1}$	$f_0 = \frac{MS_{traitements}}{MS_E}$	$P(F > f_0)$
Blocs	$SS_{blocs}$	$b - 1$	$MS_{blocs} = \frac{SS_{blocs}}{b-1}$		où $F \sim F_{a-1, (a-1)(b-1)}$
Erreur	$SS_E$	$(a-1)(b-1)$	$MS_E = \frac{SS_E}{(a-1)(b-1)}$		
Total	$SS_T$	$ab - 1$			

<ul style="list-style-type: none"> <li>• <math>SS_{traitements} = \sum_{i=1}^a b(\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^a \frac{Y_{i\bullet}^2}{b} - \frac{Y_{\bullet\bullet}^2}{ab}</math></li> <li>• <math>SS_{blocs} = a \sum_{j=1}^b (\bar{Y}_{\bullet j} - \bar{Y}_{\bullet\bullet})^2 = \sum_{j=1}^b \frac{Y_{\bullet j}^2}{a} - \frac{Y_{\bullet\bullet}^2}{ab}</math></li> <li>• <math>SS_E = \sum_{i=1}^a \sum_{j=1}^b e_{ij}^2 = SS_T - SS_{traitements} - SS_{blocs}</math></li> </ul>	<ul style="list-style-type: none"> <li>• <math>SS_T = \sum_{i=1}^a \sum_{j=1}^b (Y_{ij} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^a \sum_{j=1}^b Y_{ij}^2 - \frac{Y_{\bullet\bullet}^2}{N}</math></li> <li>• <math>e_{ij} = Y_{ij} - \bar{Y}_{i\bullet} - \bar{Y}_{\bullet j} + \bar{Y}_{\bullet\bullet} = \text{résidu}</math></li> </ul>
--	---

---

## Plan d'expérience complètement aléatoire à deux facteurs

---

$a \times b$  échantillons indépendants de taille  $n$  (donc  $abn$  observations), variances égales

**Modèle :**  $Y_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + E_{ijk}$ , où  $E_{ijk} \sim N(0, \sigma^2)$ , ( $i = 1, \dots, a, j = 1, \dots, b, k = 1, \dots, n$ )

**Analyse de la variance :** 1)  $H_0 : (\tau\beta)_{ij} = 0$  pour tout  $(i, j)$   
 2)  $H_0 : \tau_1 = \tau_2 = \dots = \tau_a = 0$   
 $H_0 : \beta_1 = \beta_2 = \dots = \beta_b = 0$

Source de variation	Somme des carrés	Degrés de liberté	Moyenne des carrés	Statistique $F_0$	Valeur $P$
Facteur $A$	$SS_A$	$a - 1$	$MS_A = \frac{SS_A}{a-1}$	$f_{0A} = \frac{MS_A}{MS_E}$	$P(F_{a-1, ab(n-1)} > f_{0A})$
Facteur $B$	$SS_B$	$b - 1$	$MS_B = \frac{SS_B}{b-1}$	$f_{0B} = \frac{MS_B}{MS_E}$	$P(F_{b-1, ab(n-1)} > f_{0B})$
Interaction $AB$	$SS_{AB}$	$(a - 1)(b - 1)$	$MS_{AB} = \frac{SS_{AB}}{(a-1)(b-1)}$	$f_{0AB} = \frac{MS_{AB}}{MS_E}$	$P(F_{(a-1)(b-1), ab(n-1)} > f_{0AB})$
Erreur	$SS_E$	$ab(n - 1)$	$MS_E = \frac{SS_E}{ab(n-1)}$		
Total	$SS_T$	$abn - 1$			

<ul style="list-style-type: none"> <li>• <math>SS_A = bn \sum_{i=1}^a (\bar{Y}_{i\bullet\bullet} - \bar{Y}_{\bullet\bullet\bullet})^2 = \sum_{i=1}^a \frac{Y_{i\bullet\bullet}^2}{bn} - \frac{Y_{\bullet\bullet\bullet}^2}{abn}</math></li> <li>• <math>SS_B = an \sum_{j=1}^b (\bar{Y}_{\bullet j\bullet} - \bar{Y}_{\bullet\bullet\bullet})^2 = \sum_{j=1}^b \frac{Y_{\bullet j\bullet}^2}{an} - \frac{Y_{\bullet\bullet\bullet}^2}{abn}</math></li> <li>• <math>SS_E = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n e_{ijk}^2 = SS_T - SS_{AB} - SS_A - SS_B</math></li> </ul>	<ul style="list-style-type: none"> <li>• <math>SS_{AB} = n \sum_{i=1}^a \sum_{j=1}^b (\bar{Y}_{ij\bullet} - \bar{Y}_{i\bullet\bullet} - \bar{Y}_{\bullet j\bullet} + \bar{Y}_{\bullet\bullet\bullet})^2</math></li> <li>• <math>SS_T = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (Y_{ijk} - \bar{Y}_{\bullet\bullet\bullet})^2 = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n Y_{ijk}^2 - \frac{Y_{\bullet\bullet\bullet}^2}{abn}</math></li> <li>• <math>e_{ijk} = Y_{ijk} - \bar{Y}_{ij\bullet} = \text{résidu}</math></li> </ul>
---	--



## Régression linéaire simple

**Modèle :**  $Y_i = \beta_0 + \beta_1 X_i + E_i \quad (i = 1, \dots, n)$

où les  $Y_i$  sont indépendantes et suivent une loi  $N(\beta_0 + \beta_1 X_i, \sigma^2)$ .

Quantité à estimer	Estimateur	Intervalle de niveau $1 - \alpha$
Pente $\beta_1$	$\hat{\beta}_1 = \frac{S_{XY}}{S_{XX}}$	$\hat{\beta}_1 \pm t_{\alpha/2; n-2} \sqrt{\frac{MSE}{S_{XX}}}$
Ordonnée à l'origine $\beta_0$	$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$	$\hat{\beta}_0 \pm t_{\alpha/2; n-2} \sqrt{MSE \left( \frac{1}{n} + \frac{\bar{X}^2}{S_{XX}} \right)}$
Variance $\sigma^2$	$\hat{\sigma}^2 = MSE$	
Moyenne $E(Y x_0)$	$\hat{Y}_0 = \hat{\beta}_0 + \hat{\beta}_1 x_0$	$\hat{Y}_0 \pm t_{\alpha/2; n-2} \sqrt{MSE \left( \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{S_{XX}} \right)}$
Observation future $Y_0$	$\hat{Y}_0 = \hat{\beta}_0 + \hat{\beta}_1 x_0$	$\hat{Y}_0 \pm t_{\alpha/2; n-2} \sqrt{MSE \left( 1 + \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{S_{XX}} \right)}$
Corrélation $\rho$	$r = \frac{S_{XY}}{(S_{XX} S_{YY})^{1/2}}$	$\left[ \tanh \left( \frac{1}{2} \ln \left( \frac{1+r}{1-r} \right) - \frac{z_{\alpha/2}}{\sqrt{n-3}} \right), \tanh \left( \frac{1}{2} \ln \left( \frac{1+r}{1-r} \right) + \frac{z_{\alpha/2}}{\sqrt{n-3}} \right) \right]$

**Test de signification de la régression :**  $H_0 : \beta_1 = 0$   
 $H_1 : \beta_1 \neq 0$

Source de variation	Sommes de carrés	Degrés de liberté	Moyenne des carrés	Statistique $F_0$	On rejette $H_0$ si...
Régression	$SS_R$	1	$MS_R = SS_R/1$	$F_0 = \frac{MS_R}{MSE}$	$f_0 > F_{\alpha; 1, n-2}$
Erreur	$SS_E$	$n - 2$	$MS_E = SS_E/(n - 2)$		
Total	$SS_T$	$n - 1$			

- $S_{XY} = \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = \sum_{i=1}^n X_i Y_i - n \bar{X} \bar{Y}$
- $S_{XX} = \sum_{i=1}^n (X_i - \bar{X})^2 = \sum_{i=1}^n X_i^2 - n \bar{X}^2$
- $S_{YY} = \sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n Y_i^2 - n \bar{Y}^2$
- $R^2 = \frac{SS_R}{SS_T} = \hat{\beta}_1^2 \frac{S_{XX}}{S_{YY}} = \text{coefficient de détermination}$
- $SS_R = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \hat{\beta}_1 S_{XY}$
- $SS_E = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n e_i^2$
- $SS_T = S_{YY}$
- $e_i = Y_i - \hat{Y}_i = Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i)$

## Régression linéaire multiple

**Modèle :**  $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + E_i \quad (i = 1, \dots, n)$

où les  $E_i$  sont indépendantes et suivent une loi  $N(0, \sigma^2)$ .

**Forme matricielle :**  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{E}$

Quantité à estimer	Estimateur	Intervalle de niveau $1 - \alpha$
Variance $\sigma^2$	$\hat{\sigma}^2 = MS_E$	
Vecteur $\boldsymbol{\beta}$	$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$	
Coefficient $\beta_j$	$\hat{\beta}_j$	$\hat{\beta}_j \pm t_{\alpha/2; n-k-1} \sqrt{MS_E \cdot C_{jj}}$
Moyenne $E(Y \mathbf{x}_0)$	$\hat{Y}_0 = \mathbf{x}'_0 \boldsymbol{\beta}$	$\hat{Y}_0 \pm t_{\alpha/2; n-k-1} \sqrt{MS_E (\mathbf{x}'_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0)}$
Observation future $Y_0$	$\hat{Y}_0 = \mathbf{x}'_0 \boldsymbol{\beta}$	$\hat{Y}_0 \pm t_{\alpha/2; n-k-1} \sqrt{MS_E (1 + \mathbf{x}'_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0)}$

**Test de signification de la régression :**  $H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$   
 $H_1 : \beta_j \neq 0$  pour au moins un  $j$

Source de variation	Sommes de carrés	Degrés de liberté	Moyenne des carrés	Statistique $F_0$	On rejette $H_0$ si...
Régression	$SS_R$	$k$	$MS_R = SS_R/k$	$F_0 = \frac{MS_R}{MS_E}$	$f_0 > F_{\alpha; k, n-k-1}$
Erreur	$SS_E$	$n - k - 1$	$MS_E = SS_E/n - k - 1$		
Total	$SS_T$	$n - 1$			

- $C_{jj}$  = élément  $(j, j)$  de  $(\mathbf{X}'\mathbf{X})^{-1}$
- $SS_R = \hat{\boldsymbol{\beta}}' \mathbf{X}' \mathbf{Y} - \frac{1}{n} \left( \sum_{i=1}^n Y_i \right)^2$
- $R^2 = \frac{SS_R}{SS_T} = 1 - \frac{SS_E}{SS_T}$
- $SS_E = \mathbf{E}' \mathbf{E} = \mathbf{Y}' \mathbf{Y} - \hat{\boldsymbol{\beta}}' \mathbf{X}' \mathbf{Y}$
- $R_{aj}^2 = 1 - \frac{SS_E/n - k - 1}{SS_T/n - 1}$
- $SS_T = \mathbf{Y}' \mathbf{Y} - \frac{1}{n} \left( \sum_{i=1}^n Y_i \right)^2$