

# Ecole Santé Sciences

## Probas & Stats

Hadrien Lorenzo, [hadrien.lorenzo@u-bordeaux.fr](mailto:hadrien.lorenzo@u-bordeaux.fr)

Université de Bordeaux

2018-2019



## Note aux étudiants

Pourrez-vous amener vos ordi pour les cours des 14, 15 et 16 novembre ?

## Les probabilités

Raisonnement statistique :

- ▶ Formulation d'une **hypothèse**,
- ▶ Délimitation d'un **échantillon** : ensemble d'individus avec des caractéristiques communes et d'autres différentes représentant la population générale et permettant donc de tester l'hypothèse formulée,
- ▶ Test de l'hypothèse : calcul de **statistiques** décrivant l'échantillon.

Il faut un **modèle statistique** pour comparer les données de l'échantillon. Une variation **significative** des statistiques décrivant l'échantillon permettent d'assurer que l'hypothèse est **vraisemblable**. Ou pas. La conclusion serait la même, avec un seuil d'assurance suffisant, sur un nouvel échantillon.

# Vocabulaire

- ▶ **Expérience aléatoire** : Expérience dont on ne connaît pas le résultat,
- ▶ **Évènement** : Différents résultats accessibles via une expérience aléatoire,
- ▶  $\Omega$  : **Ensemble des évènements** : Ensemble des évènements possibles,

# Mesure de probabilité

## Mesure de probabilité

Une mesure de probabilité, ou *probabilité*, notée  $\mathbb{P}$  est une application  $\mathbb{P} : \mathcal{F} \rightarrow [0, 1]$  telle que

- ▶  $\mathcal{F}$  soit une famille de sous-ensembles de  $\Omega$  telle que  $\Omega \in \mathcal{F}$ ,  $\forall A \in \mathcal{F}$ ,  $A^c \in \mathcal{F}$  l'évènement complémentaire à  $A$ ,
- ▶  $\mathbb{P}(\Omega) = 1$  et  $\mathbb{P}(\emptyset) = 0$ ,
- ▶  $\forall (A_i)_{i=1..n} \in \mathcal{F}^n$ , **incompatibles** ou **disjoints** (= leur réalisation simultanée est impossible)

$$\mathbb{P}\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n \mathbb{P}(A_i)$$

## Exemples

- ▶ Soit  $\Omega$  l'ensemble des valeurs prenables par un dé :  
 $\Omega = \{1, 2, 3, 4, 5, 6\}$ , on peut définir  $\mathcal{F}_\Omega = \mathcal{P}(\Omega)$ , l'ensemble des **parties** de  $\Omega$  :

$$\mathcal{F}_\Omega = \{\emptyset, \{1\}, \{2\}, \{3\}, \{4\}, \dots, \{1, 5\}, \{3, 4, 6\}, \dots, \Omega\},$$

de cardinalité  $2^6 = 64$ .

- ▶ Soit  $\Omega = \mathbb{R}$ ,  $\mathcal{F}$  est l'ensemble contenant tous les intervalles de la forme  $]a, b]$  avec  $a < b$ , appelée *tribu des Boréliens notée  $\mathcal{B}$* , avec  $F : \mathbb{R} \rightarrow [0, 1]$  une fonction de répartition et  $\mathbb{P} : \mathcal{B} \rightarrow [0, 1]$  telle que  $\forall ]a, b] \in \mathcal{B}$

$$\mathbb{P}(]a, b]) = F(b) - F(a),$$

est une mesure de probabilité.

# Probabilité

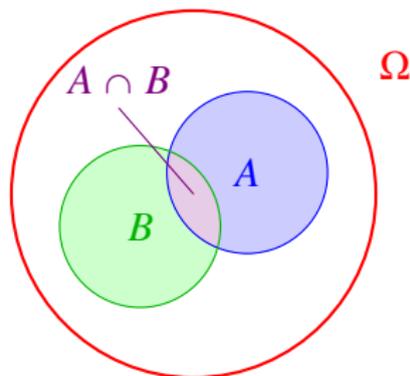
La **probabilité** d'un évènement est un réel positif inférieur à 1 qui représente la vraisemblance de cet évènement.  $\forall \omega \in \Omega$ , on note  $\mathbb{P}(\omega) \in [0, 1]$  ce nombre et  $\mathbb{P}(\omega^c) = 1 - \mathbb{P}(\omega)$ , la probabilité de l'évènement **complémentaire** à  $\omega$ .

**Exemple** : Le dé équilibré :  $\Omega = \{1, 2, 3, 4, 5, 6\}$

$$\mathbb{P}(\Omega) = 1, \mathbb{P}(\{1\}) = \frac{1}{6}, \mathbb{P}(\{1, 2\}) = \frac{1}{3}, \mathbb{P}(\{\text{pairs}\}) = \mathbb{P}(\{2, 4, 6\}) = \frac{1}{2}, \mathbb{P}(\{\text{non multiples de } 3\}) = \mathbb{P}(\{3, 6\}^c) = \frac{2}{3}.$$

# Penser en patates

$$\forall (A, B) \in \Omega^2, \mathbb{P}(A \cup B) = \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B)$$



## Incompatibilité

Deux évènements sont **incompatibles ssi** au plus un de ces deux évènements peut arriver simultanément. Généralisation à une famille quelconque d'évènements.

**Conséquence directe :**

La probabilité d'une **famille d'évènements incompatibles** est égale à la somme de leurs probabilités.

$$(\omega_i)_{i \in \llbracket 1, n \rrbracket}, \text{ incompatibles, alors } \mathbb{P}\left(\bigcup_{i=0}^n \omega_i\right) = \sum_{i=1}^n \mathbb{P}(\omega_i)$$

### Exemple

$$\forall \omega \in \Omega, \mathbb{P}(\omega^c) = 1 - \mathbb{P}(\omega),$$

Si  $\Omega = \{\omega_1, \dots, \omega_n\} \mid \forall (i, j) \in \llbracket 1, n \rrbracket^2, \mathbb{P}(\omega_i) = \mathbb{P}(\omega_j)$ . Alors si tous les évènements sont incompatibles, leur probabilité est

$$\mathbb{P}(\omega_i) = 1/n.$$

## Composition d'évènements

### Multiplication de résultats

Soient deux expériences aléatoires alors l'expérience aléatoire du produit des expériences a un nombre de possibilités égal au produit des nombres de possibilités de chaque expérience.

### Tirages successifs avec remise

On réitère  $N$  fois la même expérience aléatoire à  $k$  états possibles en remettant en jeu à chaque fois l'évènement tiré. Alors le nombre total d'arrangements est  $k^N$ .

**Exemple** : Cadenas à 4 positions de 10 chiffres :  $10^4$  possibilités. *Quid* de si l'on connaît les chiffres mais pas les positions ?

# Dénombrement

## Permutations

Il existe  $n!$ , lire “*factoriel n*“, façons différentes d'ordonner  $n$  objets.  $n! = 1 * 2 * 3 * \dots * (n - 1) * n$

## Tirages successifs sans remise (arrangements)

Il existe  $A_n^p$ , lire “*a n p*“, façons différentes d'ordonner  $n$  objets en  $p$  groupes.  $A_n^p = n * (n - 1) * \dots * (n - (p - 1)) = \frac{n!}{(n - p)!}$

## Tirages simultanés

Il existe  $\binom{n}{p}$ , lire “*p parmi n*“, façons différentes d'ordonner  $n$  objets en  $p$  groupes sans intérêt pour l'ordre.  $\binom{n}{p} = \frac{n!}{p!(n - p)!}$

# Probabilité conditionnelle

## Loi de probabilité conditionnelle

$\forall (A, B) \in \Omega^2 \mid \mathbb{P}(A) \neq 0$ , alors la probabilité conditionnelle de  $B$  sachant  $A$  est

$$\mathbb{P}(B|A) = \frac{\mathbb{P}(B \cap A)}{\mathbb{P}(A)}$$

# Loi de Bayes

## Loi de Bayes

$$\forall (A, B) \in \Omega^2$$

$$\mathbb{P}(B \cap A) = \mathbb{P}(B|A)\mathbb{P}(A) = \mathbb{P}(A|B)\mathbb{P}(B)$$

## Indépendance d'évènements

$\forall (A, B) \in \Omega^2$ ,  $A$  et  $B$  sont dits indépendants **ssi**

$$\mathbb{P}(B \cap A) = \mathbb{P}(B)\mathbb{P}(A),$$

et par la loi de Bayes il vient

$$\mathbb{P}(B|A) = \mathbb{P}(B), \quad \mathbb{P}(A|B) = \mathbb{P}(A)$$

## Évènements indépendants, exemples

On tire un dé équilibré. Dire si les évènements suivants sont **indépendants**

1.  $A$ {Le résultat est pair} et  $B$ {Le résultat supérieur ou égal à 5}
2.  $A$ {Le résultat est pair} et  $B$ {Le résultat supérieur ou égal à 4}

Dire maintenant s'ils sont **incompatibles**.

# Loi des causes totales

## Loi des causes totales

Soit une famille d'évènements  $(C_i)_{i=1..n}$  incompatibles deux à deux et vérifiant  $\Omega = \bigcup_{i=0}^n C_i$ , alors

deux et vérifiant  $\Omega = \bigcup_{i=0}^n C_i$ , alors

$$\mathbb{P}(A) = \sum_{i=1}^n \mathbb{P}(A \cap C_i) = \sum_{i=1}^n \mathbb{P}(A|C_i)\mathbb{P}(C_i),$$

où la deuxième égalité est une implication de la loi de Bayes.

## Exemple

### Maladie à 3 formes lié à un gène

Une maladie a 3 formes, par gravité croissante :  $B_1$ ,  $B_2$ ,  $B_3$ . Le gène  $A$  a deux variations, protecteur ou pas, notés  $A_1$  et  $A_2$ .  $3/4$  des gens présentent  $A_1$  et les autres présentent  $A_2$ . On sait aussi que parmi les gens présentant  $A_1$  90% sont légèrement malades ( $B_1$ ) alors que 10% sont sérieusement malades ( $B_2$ ). On sait aussi qu'un individu ne présentant pas le gène sous la forme  $A_1$  a autant de chance de décéder ( $B_3$ ) que d'être sérieusement malade ( $B_2$ ) mais ne peut pas être légèrement malade ( $B_1$ ).

Quelle est la probabilité qu'une personne rencontrée et ayant la forme sérieuse mais sans pour autant mortelle de la maladie présente la forme protectrice du gène ?

## Variable aléatoire

### Définition

Une variable aléatoire est une application de  $\Omega \rightarrow \mathbb{R}$ . Si les valeurs prises par cette variable sont finies ou dénombrables, on dit que c'est une **variable aléatoire discrète**.

### loi d'une variable aléatoire discrète

Soit une variable aléatoire discrète  $X$ .

La loi de  $X$  est l'ensemble des probabilités associées aux valeurs de  $X(\Omega) = \{x_i\}_{i=1..n}$ , on note alors

$$\forall i = 1..n, p_i = \mathbb{P}(X = x_i),$$

avec  $\sum_{i=1}^n p_i = 1$  car  $\mathbb{P}$  est une mesure de probabilité sur  $\Omega$ .

## Exemple

### 3 tirages d'une pièce équilibrée

On tire successivement 3 fois une pièce équilibrée. A chaque fois que l'on tombe sur face on gagne  $s$ , un pile fait inversement perdre  $s$ . On note  $X$  la somme totale en fin d'expérience. Décrire la loi de  $X$  via un tableau.

# Espérance

## Définition dans le cas fini et dénombrable

Soit une variable aléatoire  $X$  avec pour valeurs  $\{x_i\}_{i=1..n}$  et pour probabilités associées  $\{p_i\}_{i=1..n}$ . On définit alors l'espérance mathématique de  $X$ , notée  $\mathbb{E}(X)$ , via

$$\mathbb{E}(X) = \sum_{i=1}^n x_i p_i$$

L'espérance mathématique d'une variable aléatoire est une application linéaire. Donc  $\forall (\lambda, \mu) \in \mathbb{R}^2$  et  $X$  et  $Y$  deux variables aléatoires, on a  $\mathbb{E}(\lambda X + \mu Y) = \lambda \mathbb{E}(X) + \mu \mathbb{E}(Y)$ . De plus, l'espérance d'une constante est elle même :  $\mathbb{E}(\lambda) = \lambda$ .

# Espérance

Dans les cas non finis mais

- ▶ **Dénombrables** :  $\mathbb{E}(X) = \sum_{i=1}^{\infty} x_i p_i$
- ▶ **Indénombrables** : ... on verra plus tard

# Variance

## Définition

Soit une variable aléatoire  $X$ , on appelle variance de la variable  $X$  la grandeur

$$\text{Var}(X) = \mathbb{E}((X - \mathbb{E}(X))^2) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$$

- ▶ La variance est toujours positive ou nulle.
- ▶ On appelle **écart-type** de la variable  $X$  la grandeur

$$\sigma(X) = \sqrt{\text{Var}(X)}$$

## Variance, propriétés

$\forall (\lambda, \mu) \in \mathbb{R}^2$  et  $X$  et  $Y$  deux variables aléatoires, alors :

- ▶  $Var(\lambda X) = \lambda^2 Var(X)$
- ▶  $Var(X + Y) = Var(X) + Var(Y) + 2Cov(X, Y)$ , où  $Cov$  est la **covariance** et vérifie

$$Cov(X, Y) = \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y)))$$

- ▶ La **corrélation** est définie par

$$\rho(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}}$$

il faut donc  $Var(X)Var(Y) \neq 0$

## Lois et distributions classiques

Parmi les expériences aléatoires observées et modélisées il y a certaines lois et distributions qu'il est bon de connaître.

Par connaître nous entendons : connaître l'espérance mathématique et la variance associée ainsi que les cas d'applications usuels.

Soit une loi  $\mathcal{L}$  de paramètre  $\theta$ , potentiellement vectoriel. Si  $X$  est une variable aléatoire qui se comporte comme la loi  $\mathcal{L}$  de paramètre  $\theta$ , on dit que  $X$  suit une loi  $\mathcal{L}$  de paramètre  $\theta$  et on note

$$X \sim \mathcal{L}(\theta).$$

# Loi uniforme

## Définition

Une variable aléatoire discrète sur  $\{1, \dots, n\}$   $X$  suit une loi uniforme **ssi**

$$\forall i \in \{1, \dots, n\}, \mathbb{P}(X = i) = 1/n.$$

- ▶  $\mathbb{E}(X) = (n + 1)/2$
- ▶  $\text{Var}(X) = (n^2 - 1)/12$

Application à un dé équilibré à 6 faces.

## Démonstrations

$$\mathbb{E}(X) = \sum_{i=1}^n p_i x_i = \sum_{i=1}^n \frac{1}{n} i = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \frac{1}{2} n(n+1) = \frac{n+1}{2}$$

$$\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 \text{ avec } \mathbb{E}(X)^2 = \frac{(n+1)^2}{4}$$

$$\mathbb{E}(X^2) = \sum_{i=1}^n p_i x_i^2 = \sum_{i=1}^n \frac{1}{n} i^2 = \frac{1}{n} \frac{1}{6} n(n+1)(2n+1) = \frac{(n+1)(2n+1)}{6}$$

$$\text{Var}(X) = \frac{n^2 - 1}{12}$$

# Loi de Bernoulli

## Définition

On dit que  $X$  suit une loi de Bernoulli si  $X$  n'a que deux issues possibles notées 1 et 0 et de probabilités :

$$\mathbb{P}(X = 1) = p, \mathbb{P}(X = 0) = q = 1 - p$$

- ▶  $\mathbb{E}(X) = p$
- ▶  $\text{Var}(X) = p(1 - p)$

C'est ce qui se passe lorsqu'une pièce est non équilibrée avec  $p \neq 0.5$ .



# Démonstrations

A vous de faire

# Loi binomiale

## Définition

Une variable aléatoire  $X$  suit une loi Binomiale  $\mathcal{B}(n, p)$  si elle s'écrit comme la somme de  $n$  variables de Bernoulli indépendantes et de même paramètre  $p$ .  $X$  est à valeurs dans  $\{0, \dots, n\}$ . Elle compte donc le nombre de succès. On a alors

$$\forall i \in \{0, \dots, n\}, \mathbb{P}(X = i) = \binom{n}{i} p^i (1 - p)^{n-i}$$

Pourquoi le  $\binom{n}{i}$  ? Par-ce que nous regardons un tirage simultanée à  $i$  succès parmi  $n$  tirages donc sans intérêt pour l'ordre.

## Propriétés

- ▶  $\mathbb{E}(X) = \mathbb{E}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \mathbb{E}(X_i) = np$ , par linéarité de l'espérance mathématique.
- ▶  $Var(X) = Var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n Var(X_i) = np(1 - p)$ , par indépendance des variables aléatoires.

### Exercice

Démontrer que la loi de Bernoulli est bien une loi de probabilité

# Exercice

## Les vaccins

Une entreprise pharmaceutique fabrique des vaccins dont 5% sont efficaces sur la population. On considère 100 vaccins et on se demande la probabilité que :

1. Le vaccin fonctionne sur tout le monde,
2. Le vaccin ne fonctionne pas sur au plus 2 personnes.

Le vaccin est-il efficace ?

## Exercice, suite

$X_i$  la variable aléatoire qui affiche 1 si le vaccin ne fonctionne pas. On lui associe naturellement une loi de Bernoulli de paramètre  $p = 0.05$ . On suppose les variables  $X_i$  indépendantes les unes des autres et on définit la variable

aléatoire  $X = \sum_{i=1}^n X_i$  qui suit donc une loi Binomiale de paramètres  $n = 100$  et  $p = 0.05$ . Ainsi

- $P(X = 0) = 1 * 0.05^0 * 0.95^{100} \approx 5.9 * 10^{-3}$
- $P(X \leq 2) = 1 * 0.05^0 * 0.95^{100} + \binom{100}{1} * 0.05^1 * 0.95^{99} + \binom{100}{2} * 0.05^2 * 0.95^{98} \approx 0.12$

L'efficacité dépend du seuil fixé par les autorités de santé 😊

# Loi de Poisson

## Définition

Une variable aléatoire  $X$  suit une loi de Poisson  $\mathcal{P}(\lambda)$  si elle prend ses valeurs dans l'ensemble des entiers naturels,  $\mathbb{N}$ . On a alors

$$\forall i \in \mathbb{N}, \mathbb{P}(X = i) = e^{-\lambda} \frac{\lambda^i}{i!}$$

- ▶  $\mathbb{E}(X) = \lambda$
- ▶  $Var(X) = \lambda$

Loi utilisée pour modéliser le nombre d'arrivées à un péage pour un intervalle de temps donné.

En premier approximation : le nombre d'ARN d'un gène produit par un groupe de cellules

## Les lois continues

On passe au continue, c'est pareil sauf que les  $\sum$  deviennent des  $\int$  et la probabilité en un point est nul.

En vrai on va tout de même introduire deux trois objets mathématiques.

**Fasten your seatbelts !**

## Nouvelle expérience

### Concentration de magnésium dans une bouteille d'eau

- ▶ **Expérience aléatoire** : Ouvrir une bouteille d'eau et titrer la teneur en magnésium,
- ▶ **Variable aléatoire**  $X$  : La teneur en magnésium de la bouteille ouverte et titrée,

$\Omega \subset \mathbb{R}$ , mais devra valoir  $\approx$  la valeur affichée par la bouteille.

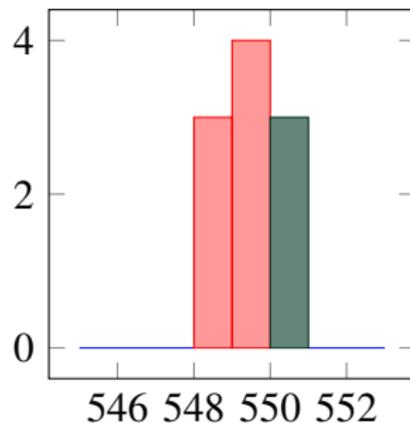
### Comment visualiser $X$ : l'histogramme

**L'histogramme** : En abscisse les valeurs prises par  $X$  et en ordonnée le nombre de fois que la valeur est prise.

# Histogrammes

## Expérience

On teste  $\approx 10$  bouteilles.

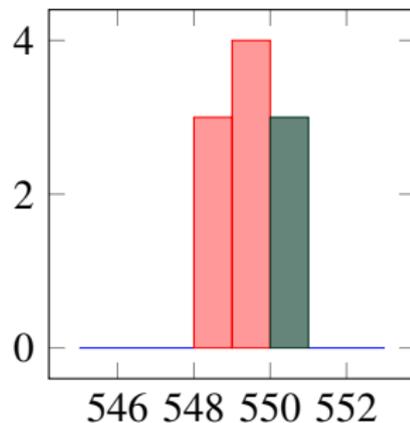


# Histogrammes

## Expérience

En **rouge**, les bouteilles pour lesquelles la valeur est comprise entre  $548\text{mg/L}$  et  $550\text{mg/L}$ .

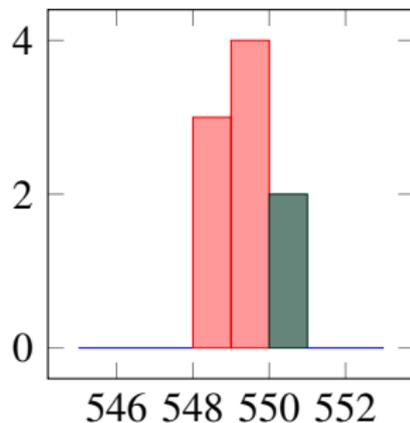
En **vert**, les bouteilles pour lesquelles la valeur est égale à  $\approx 550\text{mg/L}$ .



# Histogrammes

## Probabilités et histogrammes

Le calcul de la probabilité revient à calculer l'aire sous la courbe histogramme.

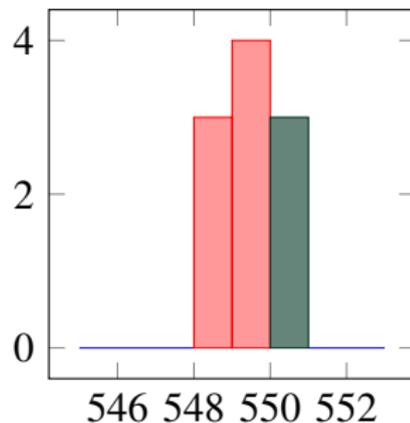


# Histogrammes

## Probabilités et histogrammes

Pour un segment de valeurs :  
indépendant de la taille des **bins**.

Pour une valeur particulière :  
dépendant de la taille du **bin**  
considéré.

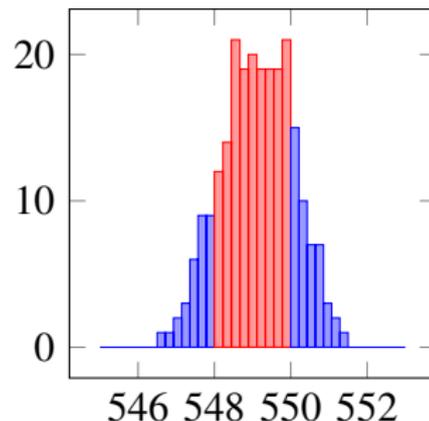


# Histogrammes

## Expérience

On teste plusieurs centaines de bouteilles.

- ▶ La taille des bins tend vers 0 pour que le graphique reste joli.
- ▶ Les probabilités ponctuelles tendent vers 0.
- ▶ Les probabilités sur des segments de  $\mathbb{R}$  se stabilisent.

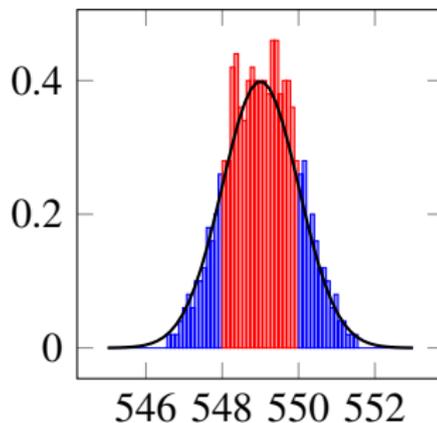


# Histogrammes

## Modification de l'histogramme

Diviser le nombre de chaque barre par le nombre total de bouteilles testées.

L'enveloppe de l'histogramme nous rappelle quelque chose ???



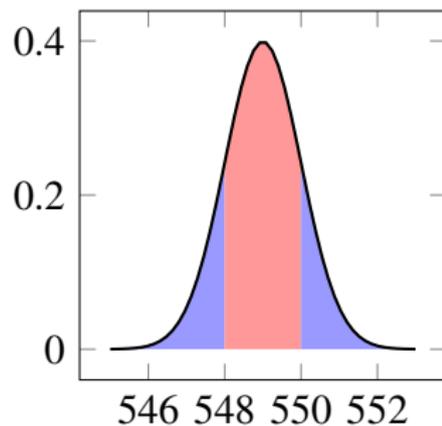
# Densités de probabilité

## Cas limite

En ouvrant une infinité de bouteilles on récupère une figure d'histogrammes avec des bins infiniment fins et une courbe que l'on peut associer à une courbe bien connue, la courbe de Gauss, de moyenne  $\mu = 549$  et de variance  $\sigma^2 = 1$

$$f_X(x, \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}},$$

**la densité de probabilité.**



## Densité de probabilité

### Définition

Soit  $(a, b) \in \mathbb{R}^2 | [a, b] \subset \Omega$ ,  $\Omega$  associée à la variable aléatoire  $X$ .  
On dit que  $X$  est une variable aléatoire **à densité** lorsqu'il existe une fonction positive ou nulle, notée  $f_X : \Omega \rightarrow \mathbb{R}^+$  telle que

$$\mathbb{P}(a \leq X \leq b) = \int_a^b f_X(x) dx,$$

c'est l'aire sous la courbe. On doit avoir  $\mathbb{P}(\Omega) = \int_{\Omega} f_X(x) dx = 1$   
par définition. Souvent  $\Omega = \mathbb{R}$ .

## Application aux bouteilles

### Énoncé

Sur les bouteilles, on veut connaître la probabilité qu'une bouteille ait une concentration en magnésium comprise entre  $548\text{mg/L}$  et  $550\text{mg/L}$ . Quel calcul devons-nous poser ?

## Application aux bouteilles

### Énoncé

Sur les bouteilles, on veut connaître la probabilité qu'une bouteille ait une concentration en magnésium comprise entre  $548\text{mg/L}$  et  $550\text{mg/L}$ . Quel calcul devons-nous poser ?

### Solution

$$\begin{aligned} \mathbb{P}(548 \leq X \leq 550) &= \int_{548}^{550} f_X(x, \mu = 549, \sigma^2 = 1) dx \\ &= \int_{-1}^1 f_X(x, \mu = 0, \sigma^2 = 1) dx \end{aligned}$$

C'est l'aire sous les rectangles à droite !

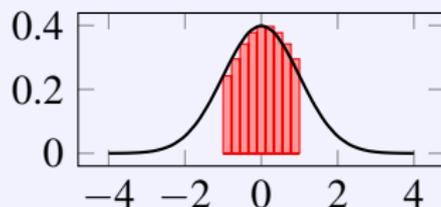
## Application aux bouteilles

### Version approchée

On fixe  $N$  le nombre de bins dans l'intervalle  $[548, 550]$ , alors

$$\mathbb{P}(548 \leq X \leq 550) \approx \frac{2}{N} \sum_{i=0}^{N-1} f_X\left(-1 + \frac{i}{N} * 2, \mu = 0, \sigma^2 = 1\right)$$

Ici un exemple avec  $N = 9$ .



# Fonction de répartition

## Définition

Soit  $X$  une variable aléatoire à densité de densité de probabilités  $f_X$  définie sur  $\Omega \subset \mathbb{R}$ , on appelle **fonction de répartition** la fonction  $F_X$  définie  $\forall t \in \Omega$  par

$$F_X(t) = \mathbb{P}(X \leq t),$$

par positivité de  $f_X$ ,  $F_X$  est croissante et positive. Elle représente la probabilité que  $X$  soit inférieur ou égal à  $t$ .

# Espérance

## Définition de l'espérance

Soit  $X$  une variable aléatoire à densité de densité de probabilités  $f_X$  définie sur  $\Omega \subset \mathbb{R}$ , on appelle **espérance** de  $X$  le réel

$$\mathbb{E}(X) = \int_{\Omega} x f_X(x) dx,$$

définie si l'intégrale précédente a un sens...

Cette espérance a les mêmes propriétés de linéarité que celles définies dans le cas discret.

# Variance

## Variance

Soit  $X$  une variable aléatoire à densité de densité de probabilités  $f_X$  définie sur  $\Omega \subset \mathbb{R}$ , on appelle **espérance** de  $X$  le réel positif

$$\text{Var}(X) = \mathbb{E}((X - \mathbb{E}(X))^2),$$

qui doit aussi avoir un sens...

Qui a les mêmes propriétés de bi-linéarité que celles définies dans le cas discret.

## Loi uniforme sur $[a, b]$

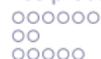
### Définition

La loi uniforme sur  $[a, b]$ , notée  $\mathcal{U}([a, b])$  est une loi à densité de fonction de densité

$$f_X(x) = \begin{cases} \frac{1}{b-a} & \text{si } x \in [a, b] \\ 0 & \text{sinon} \end{cases},$$

naturellement la fonction de répartition s'écrit

$$F_X(x) = \begin{cases} \frac{x-a}{b-a} & \text{si } x \in [a, b] \\ 0 & \text{si } x < a \\ 1 & \text{si } x > b \end{cases},$$



# Loi uniforme

Calculs de l'espérance et de la variance

# Loi uniforme

## Calculs de l'espérance et de la variance

### L'espérance

$$\begin{aligned}
 \mathbb{E}(X) &= \int_{\mathbb{R}} x f_X(x) dx = \int_a^b \frac{x}{b-a} dx \\
 &= \frac{1}{b-a} \int_a^b x dx = \frac{1}{b-a} (b^2 - a^2) / 2 \\
 &= \frac{b+a}{2}
 \end{aligned}$$

# Loi uniforme

## Calculs de l'espérance et de la variance

### La variance

$$\begin{aligned}
 \text{Var}(X) &= \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \int_{\mathbb{R}} x^2 f_X(x) dx - \mathbb{E}(X)^2 \\
 &= \frac{1}{(b-a)} \int_a^b x^2 dx - \mathbb{E}(X)^2 = \frac{1}{(b-a)} (b^3 - a^3)/3 - \mathbb{E}(X)^2 \\
 &= \frac{(b-a)(b^2 + ab + a^2)}{3(b-a)} - \left(\frac{b+a}{2}\right)^2 \\
 &= \frac{4b^2 + 4ab + 4a^2}{12} - \frac{3b^2 + 6ab + 3a^2}{12} = \frac{(b-a)^2}{12}
 \end{aligned}$$

# Loi Normale de paramètres $\mu$ et $\sigma^2$

## Définition

La loi normale de paramètres  $\mu$  et  $\sigma^2$ , notée  $\mathcal{N}(\mu, \sigma^2)$ , est une loi à densité de fonction de densité

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}},$$

sans formule simple de la fonction de répartition.

- ▶  $\mathbb{E}(X) = \mu$
- ▶  $Var(X) = \sigma^2$

## Loi Normale de paramètres $\mu$ et $\sigma^2$

- ▶  $\approx 95\%$  de la masse est concentrée dans un rayon  $2\sigma$  autour de  $\mu$

$$\mathbb{P}(\mu - 2\sigma \leq X \leq \mu + 2\sigma) \approx 0.95$$

- ▶ On a déjà vu

$$\mathbb{P}(\mu - \sigma \leq X \leq \mu + \sigma) \approx 0.68$$

- ▶ C'est la loi la plus répandue : bruits des capteurs de poids, détecteurs d'ADN, répartition des photons dans un faisceau laser...

# Loi Normale de paramètres $\mu$ et $\sigma^2$

## Définition

Soient deux variables aléatoires réelles  $X_1$  et  $X_2$  de moyenne  $\mu_1$  et  $\mu_2$ , et de variance  $\sigma_1^2$  et  $\sigma_2^2$  indépendantes alors  $X = X_1 + X_2$  suit une loi normale telle que

$$X \sim \mathcal{N}(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$$

## Loi exponentielle de paramètre $a$

### Proposition

La loi exponentielle de paramètre  $a > 0$ , est une loi à densité de fonction de densité

$$f_X(x) = \begin{cases} ae^{-ax} & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases},$$

naturellement la fonction de répartition s'écrit

$$F_X(x) = \begin{cases} 1 - e^{-ax} & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases},$$

A démontrer...

# Loi exponentielle de paramètre $a$

## Cas d'utilisation

Très utilisé pour simuler la survenue d'un décès chez un patient. Il est à la base des **modèles de survie**.

Voir par exemple **modèles de Cox**.

- ▶  $\mathbb{E}(X) = 1/a$
- ▶  $Var(X) = 1/a^2$

## Autres lois importantes

### Loi du $\chi^2$ à $n$ degrés de libertés

Soit  $n$  variables aléatoires  $X_1, \dots, X_n$  indépendantes et identiquement distribuées qui suivent une  $\mathcal{N}(0, 1)$  alors la variable aléatoire  $Z = X_1^2 + \dots + X_n^2$  suit une loi dite du  $\chi^2$  à  $n$  degrés de libertés.  $Z \sim \chi^2(n)$

Très utilisé dans le test du  $\chi^2$  : tester la pertinence d'un modèle pour des données.

### Loi de Student à $n$ degrés de libertés

Si  $X \sim \mathcal{N}(0, 1)$  et  $Y \sim \chi^2(n)$ , indépendantes, alors  $Z = \frac{X}{\sqrt{Y/n}}$  suit une loi de Student à  $n$  degrés de libertés.  $Z \sim Student(n)$ .

## Pourquoi ces lois ?

Supposons que les  $X_i$  suivent tous une  $\mathcal{N}(\mu, \sigma^2)$  et soient indépendants.

Estimateur de l'espérance : la moyenne empirique

$$\hat{X}_n = \sum_{i=1}^n X_i/n,$$

alors on a

$$\hat{X}_n \sim \mathcal{N}(\mu, \sigma^2/n)$$

## Pourquoi ces lois ?

L'écart-type empirique  $\hat{\sigma}_n = \sqrt{\sum_{i=1}^n (X_i - \hat{X}_n)^2/n}$ , alors la variable aléatoire  $Z = \frac{\hat{X}_n - \mu}{\hat{\sigma}_n/\sqrt{n-1}}$ , suit une loi de Student à  $n - 1$  degrés de liberté.

## Les tests

### Définition

En pratique on se pose des questions : *Les données suivent-elle bien telle ou telle loi ?*

On y répond en testant une hypothèse  $\mathcal{H}_0$

$\mathcal{H}_0$  : Le médicament est sans effet,

ainsi ce serait "bien" de contredire cette hypothèse et de donc valider l'hypothèse inverse  $\mathcal{H}_1$

$\mathcal{H}_1$  : Le médicament a un effet.

On ramène les data à ce qui devrait ressembler à une distribution connue et on compare l'empirique et le théorique.

## Le test de Student

Le cas de la comparaison de deux échantillons indépendants.  
Le plus simple : passer par la moyenne en prenant en compte la variance.

On suppose données deux échantillons  $A$  et  $B$  indépendants et formés de  $n_A$  et  $n_B$  observations correspondant à deux conditions expérimentales que l'on souhaiterait tester.

Exemple : traitement fonctionne contre traitement fonctionne pas...

### Hypothèse

$\mathcal{H}_0$  : Les deux échantillons suivent deux lois de même espérance  $\mu$ .

## Modèles statistiques

On pose les modèles statistiques sur  $X_A$  et  $X_B$

$$X_A \sim \mathcal{N}(\mu_A, \sigma^2)$$

$$X_B \sim \mathcal{N}(\mu_B, \sigma^2)$$

## Le test de Student

On peut estimer les moyennes des échantillons :

$$\hat{X}_A = \sum_{i_A=1}^{n_A} X_{i_A} / n_A$$

$$\hat{X}_B = \sum_{i_B=1}^{n_B} X_{i_B} / n_B$$

Si l'hypothèse de distribution est vérifiée

$$\hat{X}_A \sim \mathcal{N}(\mu_A, \sigma^2 / n_A)$$

$$\hat{X}_B \sim \mathcal{N}(\mu_B, \sigma^2 / n_B)$$

## Le test de Student

Grâce à ce que l'on a vu

$$\hat{X}_A - \hat{X}_B \sim \mathcal{N}(\mu_A - \mu_B, \sigma^2(1/n_A + 1/n_B))$$

On reformule alors les hypothèses

$$\mathcal{H}_0 : \mu_A = \mu_B$$

$$\mathcal{H}_1 : \mu_A \neq \mu_B$$

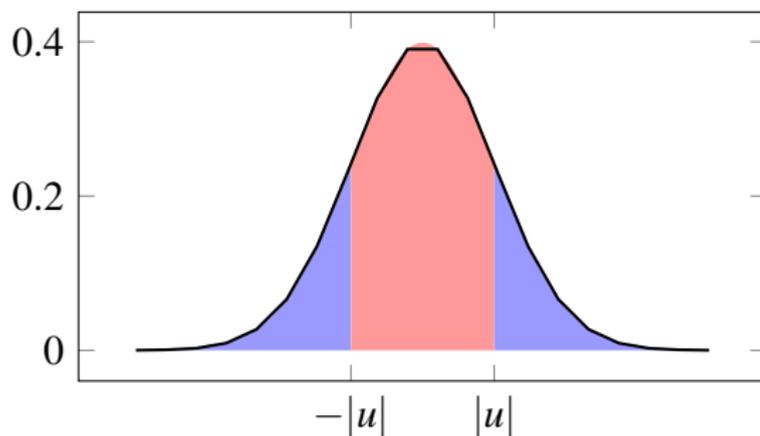
## Cas 1 : la variance est connue

Sous  $\mathcal{H}_0$  :  $U = \frac{\hat{X}_A - \hat{X}_B}{\sigma \sqrt{1/n_A + 1/n_B}} \sim \mathcal{N}(0, 1)$ , On calcule alors la statistique et on estime la **p-value** grâce à la table de la loi normale centrée réduite, en notant  $u$  la valeur estimée pour  $U$  on a

$$p - value = \mathbb{P}(U \leq -|u|) + \mathbb{P}(U \geq |u|)$$

Classiquement on pose une  $p - value$  à 0.05 ou 0.01 ou 0.001 en fonction de pas mal de paramètres empiriques.

# Loi normale



## Cas 2 : la variance est inconnue

Il faut passer par l'estimateur de la variance  $\hat{\sigma}^2$  et alors

$$T_{n_A+n_B-2} = \frac{\hat{X}_A - \hat{X}_B}{\sigma \sqrt{1/n_A + 1/n_B}} \sim \mathcal{T}(n_A + n_B - 2), \text{ suit une loi de}$$

Student à  $n_A + n_B - 2$  degrés de liberté. On utilise pareillement la table de la loi de Student pour estimer la *plausibilité* du résultat via la *p-value* fixée en début d'expérience.