

# Cours de statistiques et probabilités, ENS Rennes

---

Janvier 2022 - avril 2022.

Planing.

Créneaux :

- Mardi, 14h, Ker-Lann
- Jeudi 14h, Beaulieu
- ① Tronc commun, 10 séances de 2h.  
Évaluation par devoir maison a la fin du tronc commun
- ② Deuxième partie, 10 séances de 2h au choix:
  - ▶ Partie pratique sur les statistiques descriptives et l'apprentissage automatique, évaluation par projets en groupe.
  - ▶ Partie théorique sur les preuves des resultats de probabilités, évaluation par examen.

# Informations pratiques

Lien vers la page du cours.

Installer jupyter notebook avec numpy/scipy pour les exercices en cours.

Enseignant: Louis Thiry

- Formation en maths appliquees: analyse numerique, traitement du signal et apprentissage.
- Stage chez Deep Mind: apprentissage d'une fonctionnelle pour la mecanique quantique numerique.
- Doctorat à l'ENS Paris, directeur S. Mallat
  - ▶ Modélisation mathématiques des réseaux de neurones profonds pour la classification d'images
  - ▶ Régression de l'énergie de systèmes d'atomes (molécules, solides...)
  - ▶ dispositifs de création artistes-algorithmes
- Postdoc a l'INRIA Rennes, équipe Fluminance: analyse de données satellites sur l'océan, modèles et assimilation de données pour les océans, projet ERC STUOD.
- <https://www.di.ens.fr/louis.thiry/>

# Questionnaire

*pour savoir où vous en êtes sur les probas et stats.*

# Probabilités


- Probabilités: étude et modélisation mathématique des phénomènes contenant une part de hasard / incertitude.

ex:

- ▶ Modéliser le lancer d'une pièce.
- ▶ Modéliser des processus de texture



- ▶ Évènements rares en météo




# Statistiques

- Statistiques: recueillir, traiter, interpréter des données sur un phénomène.
  - ▶ ex: déterminer si une pièce est déséquilibrée à partir d'une série de lancer.
  - ▶ Reconnaître un arbre à partir de la texture de son écorce



- ▶ Estimer les chances qu'un cyclone s'intensifie ou disparaisse:



→ Liens forts entre les deux domaines.

# Modélisation probabiliste

Objet central de modélisation: **Variable aléatoire.**

Exemples de modèles:

- Variable aléatoire réelle: temps d'attente a une caisse de magasin.
- Vecteur aléatoire: temps aux 5 caisses d'un magasin.
- Processus aléatoire (stochastique) a temps discret: taux d'occupation de la RAM, nombre requêtes sur un serveur.
- Processus aléatoire (stochastique) a temps continu: solution d'une équation aux dérivées partielle stochastique

$$f(t) = f_0 + \int_0^t \sigma \underbrace{dB_t}_{\text{Brownien}}$$

# Statistiques

" Parmi les thèmes à propos desquels les statisticiens ne sont pas d'accord, se trouve la définition de leur science." Maurice Kendall (1907-1983).

- **Statistique descriptive** : rendre lisible un ensemble de données fini.  
ex: ensemble des notes de tous les élèves de L3 SIF à l'ENS.
- **Statistique mathématique** : Déduire des informations générale à partir d'un échantillon.  
ex: sondage électoral, étude médicale de l'efficacité d'un traitement.  
→ intervalles de confiance, test statistique...
- **Statistique prédictive (explicative)**: modéliser un phénomène à partir de données ( $\neq$  modélisation physique).

$$Y = F(X)$$

→ apprentissage statistique.

# Partie 1: tronc commun

- 1 Introduction aux probabilités
  - ▶ Variables aléatoires discrètes
  - ▶ Espérance et Variance
  - ▶ Indépendance et conditionnement
  - ▶ Variables aléatoires continues
  - ▶ Fonction de répartition
  - ▶ Simulation d'une v.a.
  - ▶ Loi des grands nombres (LGN)
  - ▶ Théorème de la limite centrale (TLC)
- 2 Statistiques mathématiques
  - ▶ Sondages et intervalles de confiance
  - ▶ Méthode de Monte-Carlo
  - ▶ Test statistiques et p-valeur
  - ▶ Tests d'adéquation et d'indépendance du  $\chi^2$
- 3 Statistiques prédictives: Régression linéaire.
- 4 Statistiques descriptives: généralités.

# Partie 2: option pratique

## ① Statistiques descriptives

- ▶ Analyse et visualisation de données en python.
- ▶ Analyse en composantes principales
- ▶ Clustering avec les k-moyennes.
- ▶ Implémentations
- ▶ Optimisation: descente de gradient
- ▶ Régression non-linéaire: arbres de décision, réseaux de neurones...

## ② Statistiques prédictives

- ▶ Implémentation autour de la régression linéaire.
- ▶ Régression non-linéaire: généralités sur les méthodes a noyaux.
- ▶ Régression non-linéaire en pratique: arbres de décision, réseaux de neurones.

## Partie 2: option théorique

### Fondements mathématiques des probabilités

- Opérations sur les ensembles
- Notions de dénombrabilité
- Notions Convergences des V.A.
- Preuve de la Loi des Grands Nombres
- Fonction caractéristique et transformée de Fourier
- Preuve du théorème de la Limite Centrale

# Variable aléatoire

Une variable aléatoire (v.a.)  $X$  est une quantité dont la valeur, a priori incertaine, est déterminée à l'issue du tirage.

Son espace d'états  $V$  est l'ensemble des valeurs qu'elle peut prendre.

- Espace d'états  $\subset \mathbb{C}$ : **variable** aléatoire.
- Espace d'états  $\subset \mathbb{C}^d$ : **vecteur** aléatoire.

ex:

- lancer de dé.
- nombre serveurs en panne.
- température dans 5 jours à Rennes.
- durée de vie d'un ordinateur.
- lancer de deux dés.

# Variable aléatoire discrète

## Cas discret.

Une variable aléatoire  $X$  est discrète si son espace d'états est fini ou infini dénombrable ( $V = \{v_n, n \in \mathbb{N}\}$ ).

Propriété:

Une variable aléatoire discrète est caractérisée par les probabilités

$$P(X = v) \text{ (ou } P_X(v)), v \in V$$

L'ensemble  $\{P_X(v), v \in V\}$  est appelé la loi de  $X$ , et les probabilités  $P_X(v)$  sont positive est somment a un:

$$P(v) \leq 0, \sum_{v \in V} P(v) = 1$$

Rq: dans le cas infini,  $P(v_n)$  est le terme d'une série absolument convergente. Le résultats sur les séries nous seront donc utiles.

# Exercice

## **Somme de deux des équilibrés.**

On considère la variable aléatoire  $S$  somme des valeurs de deux des équilibrés.

- 1 Quel est son espace d'états ?
- 2 Déterminer sa loi
- 3 Vérifier numériquement que les fréquences correspondent au probabilités obtenues

## Exercice

$$V = \{2, \dots, 12\}$$

On écrit le tableau qui donne les résultats en fonction des deux dés :

	1	2	3	4	5	6
1	2	3	4	5	6	7
2	3	4	5	6	7	8
3	4	5	6	7	8	9
4	5	6	7	8	9	10
5	6	7	8	9	10	11
6	7	8	9	10	11	12

$$P(2) = P(12) = 1/36, P(3) = P(11) = 2/36 = 1/18,$$

$$P(4) = P(10) = 3/36 = 1/12, P(5) = P(9) = 4/36 = 1/9,$$

$$P(6) = P(8) = 5/36, P(7) = 6/36 = 1/6.$$

# Espérance d'une variable aléatoire discrète

L'espérance d'un variable aléatoire (v.a.)  $X$  discrète est donnée par

$$\mathbb{E}(X) = \sum_{v \in V} P(v)v$$

ex: Jeu de loto où l'on coche 6 numéros sur une grille de 49. On joue 2 euros et on reçoit un gain en fonction du nombre de numéros gagnants:

numéros gagnants	gain	probabilité
6	2,132,885	$7.2 \cdot 10^{-8}$
5	3,575	$7.8 \cdot 10^{-5}$
4	94	$9.7 \cdot 10^{-4}$
3	11	$7.8 \cdot 10^{-2}$

- 1 Quelle est l'espérance du gain  $G$ ?
- 2 A-t-on intérêt à jouer ?

# Espérance d'une variable aléatoire discrète

- 1 Quelle est l'espérance de gain?

$$\mathbb{E}(G) = 2,132,885 \times 7.2 \cdot 10^{-8} + 3,575 \times 7.8 \cdot 10^{-5} + 94 \times 9.7 \cdot 10^{-4} + 11 \times 7.8 \cdot 10^{-2}$$

Python :

$$2132885*7.2*10^{**(-8)} + 3575*7.8*10^{**(-5)} + 94*9.7*10^{**(-4)} + 11*7.8*10^{**(-2)} = 1.38159772$$

- 2 A-t-on intérêt à jouer ?

Bénéfice moyen :

$$\mathbb{E}(G) - 2 \approx 1.38 - 2 \approx -0.62$$

D'un point de vue comptable, non. D'un quelconque autre point de vue...

# Espérance d'une variable aléatoire discrète

Propriétés:

- linéarité

$$\mathbb{E}(aX + bY) = a\mathbb{E}(X) + b\mathbb{E}(Y)$$

- positivité

$$X \geq 0, \mathbb{E}(X) \geq 0$$

- $X$  constante de valeur  $a$ ,  $\mathbb{E}(X) = a$

- inégalités:

$$|\mathbb{E}(X)| \leq \mathbb{E}(|X|), \quad f \text{ convexe, } f(\mathbb{E}(X)) \leq \mathbb{E}(f(X)).$$

triangulaire  Jensen

# Variance d'une variable aléatoire discrète

Propriété:

$$|\mathbb{E}(X)| \leq \mathbb{E}(|X|) \leq \sqrt{\mathbb{E}(X^2)}$$

Si  $\mathbb{E}(X^2) < \infty$ , on peut définir la variance:

$$\text{Var}(X) = \mathbb{E}((X - \mathbb{E}(X))^2) = \sum_{v \in V} (v - \mathbb{E}(X))^2 P(v)$$

- $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$
- $\text{Var}(X)$  est positive ( car  $(X - \mathbb{E}(X))^2 \geq 0$ .)
- $\text{Var}(aX) = a^2 \text{Var}(X)$

Écart type:

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

# Variables aléatoires discrètes usuelles

Bernoulli  $X$ :

$$V = \{0, 1\}$$

$$P(X = 1) = p, P(X = 0) = 1 - p$$

$$\mathbb{E}(X) = p$$

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

Binomiale  $S$ :

$$V = \{0, \dots, n\}$$

$$P(S = k) = \binom{n}{k} p^k (1 - p)^{n-k}$$

$$\mathbb{E}(X) = np$$

$$\text{Var}(X) = np(1 - p)$$

# Variables aléatoires discrètes usuelles

Poisson  $X$  de paramètre  $\theta > 0$ :

$$V = \mathbb{N}$$

$$P(X = k) = e^{-\theta} \frac{\theta^k}{k!}$$

$$\mathbb{E}(X) = \theta$$

$$\text{Var}(X) = \theta$$

# Loi conditionnelle

Définition:

$X, Y$  v.a. a valeurs dans  $V, W$

Pour  $v \in V$  tel que  $P(X = v) > 0$ , la loi conditionnelle de  $Y$  sachant  $X = v$  est définie par la probabilité:

$$\forall w \in W, \quad P(Y = w | X = v) = \frac{P(Y = w, X = v)}{P(X = v)}$$

Remarques:

- La loi conditionnelle de  $Y$  sachant  $X = v$  est une fonction de  $v$ .
- Les loi conditionnelle peuvent êtres très différentes en fonction de  $v$ .

# Indépendance des variables aléatoires

Définition:

Les variables aléatoires  $X$  et  $Y$  sont indépendantes s.s.i.:

- 1  $\forall v, w, \quad P(X = v, Y = w) = P(X = v)P(Y = w)$
- 2  $\forall v$  t.q.  $P(X = v) > 0, \forall w, P(Y = w|X = v) = P(Y = w)$

Remarque:

- La notion d'indépendance se comprend bien avec la deuxième équivalence: quelle que soit la valeur que prend la v.a.  $X$ , cela ne change pas la loi de la v.a.  $Y$ .

# Indépendance des variables aléatoires

Propriétés:

Les variables aléatoires  $X$  et  $Y$  sont indépendantes.

- Espérance.

$\forall f, g$  fonctions :

$$\mathbb{E}(f(X)g(Y)) = \mathbb{E}(f(X))\mathbb{E}(g(Y))$$

- Somme.

On suppose  $X$  et  $Y$  a valeur dans  $\mathbb{Z}$

$$P(X + Y = i) = \sum_{j \in \mathbb{Z}} P(X = i - j)P(Y = j)$$

La loi de  $X + Y$  est obtenue par **convolution discrète** des probabilités de  $X$  et  $Y$ .

## Somme de Bernoulli indépendantes

$X_i, i \in \mathbb{N}$  v.a. Bernoulli indépendantes. On considère la somme

$$S_n = \sum_{i=1}^n X_i.$$

Déterminer la loi de  $S_n$ .

- Son espace d'états est  $\{0, \dots, n\}$ .
- $k \{0, \dots, n\} \in P(S_n = k)$ .

Il faut que exactement  $k$  des  $n$  variable  $X_i$  soient égales a 1 et les autre a 0, ce qui fait  $\binom{n}{k}$  possibilités.

Soit une telle configuration :  $i_1, \dots, i_k$ , sont les indices des v.a. égales a 1 et  $i_{k+1}, \dots, i_n$  les indices des v.a. égales a 0.

Par indépendance:

$$\begin{aligned} P(X_{i_1} = 1, \dots, X_{i_k} = 1, X_{i_{k+1}} = 0, \dots, X_{i_n} = 0) \\ &= P(X_{i_1} = 1) \dots P(X_{i_k} = 1) P(X_{i_{k+1}} = 0) \dots P(X_{i_n} = 0) \\ &= p^k (1-p)^{n-k} \end{aligned}$$

# Somme de Bernoulli indépendantes

$$P(S_n = k) = \binom{n}{k} p^k (1-p)^{n-k}$$

On reconnaît une loi binomiale.

Espérance:

$$\mathbb{E}(S_n) = \mathbb{E}\left(\sum_i X_i\right) = \sum_i \mathbb{E}(X_i) = np$$

Et la variance ?

La variance n'est pas linéaire :  $\text{Var}(aX) = a^2 \text{Var}(X)$ .

## Variance d'une somme de v.a. **indépendantes**

$X, Y$  v.a. indépendantes:

$$\begin{aligned} \text{Var}(X + Y) &= \mathbb{E} [(X - \mathbb{E}(X)) + Y - \mathbb{E}(Y)]^2 \\ &= \mathbb{E} [(X - \mathbb{E}(X))^2 + (Y - \mathbb{E}(Y))^2 + 2(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))] \\ &= \mathbb{E} [(X - \mathbb{E}(X))^2] + \mathbb{E} [(Y - \mathbb{E}(Y))^2] + 2\mathbb{E}[X - \mathbb{E}(X)]\mathbb{E}[Y - \mathbb{E}(Y)] \\ &= \text{Var}(X) + \text{Var}(Y) \end{aligned}$$

Si  $X, Y$  v.a. **indépendantes**, la variance de la somme est la somme des variances.

$$\text{Var}(S_n) = \text{Var} \left( \sum_i X_i \right) = \sum_i \text{Var}(X_i) = np(1 - p)$$

# Variable aléatoire réelle et fonction de répartition

Définition:

Une variable aléatoire réelle est a valeur dans  $\mathbb{R}$ .

Remarque:

$\mathbb{R}$  n'est pas dénombrable, on ne peut pas simplement numéroter les valeurs de  $\mathbb{R} = \{v_n, n \in \mathbb{N}$  et leur associer une probabilité  $p_n > 0, \sum_n p_n = 1$ .

Définition:

Soit  $X$  un v.a. réelle. La fonction de répartition de  $X$  est la fonction définie par

$$\forall x \in \mathbb{R}, F_X(x) = P(X \leq x)$$

# Fonction de répartition

Propriétés:

$X$  v.a. réelle.

La fonction de répartition caractérise la probabilité de  $X$  et vérifie les propriétés suivantes

- $F_X$  est croissante.
- $F_X$  est continue à droite
- $\lim_{x \rightarrow -\infty} F_X(x) = 0$  et  $\lim_{x \rightarrow +\infty} F_X(x) = 1$

Remarque:

La réciproque est vraie.

Si  $F$  vérifie les trois propriétés, c'est la fonction de répartition d'une loi de probabilité sur  $\mathbb{R}$ .


# Propriétés de la fonction de répartition

Nota: comme  $F$  est croissante, elle admet une limite à gauche  $F_X(x-)$  en tout point  $x$ .

Propriétés:

- $P(X = x) = F_X(x) - F_X(x-)$
- $P(X = x) = 0 \iff F_X$  continue en  $x$
- $P(x < X \leq y) = P(X \leq y) - P(X \leq x) = F_X(y) - F_X(x)$
- $P(x < X < y) = P(X < y) - P(X \leq x) = F_X(y-) - F_X(x)$
- $P(x \leq X \leq y) = P(X \leq y) - P(X < x) = F_X(y) - F_X(x-)$
- $P(x \leq X < y) = P(X < y) - P(X < x) = F_X(y-) - F_X(x-)$


# Exemple de fonction de répartition



Quelle est la loi ?

Bernoulli de paramètre  $p = 0.5$


# Exemple de fonction de répartition



Quelle est la loi ?

Valeurs  $\{0, 1, \dots, 9\}$ , probabilité uniforme de  $1/10$ .


# Exemple de fonction de répartition



Quelle est la loi ?

Probabilité uniforme sur  $[0, 1]$ .

# Exemple de fonction de répartition



Quelle est la loi ?

Probabilité uniforme sur  $[-10, 10]$ .

## Exemples de fonction de répartition

- $X$  v.a. constante de valeur  $a$ .

$$F_X(x) = 1_{[a, \infty[}$$

- $X$  a valeur dans  $\mathbb{N}$ , on note  $p_n = P(X = n)$ .

$$F_X(x) = \begin{cases} 0 & \text{si } x < 0 \\ p_0 + \dots + p_n & \text{si } n \leq x < n + 1 \end{cases}$$

- $X$  a valeur dans  $V = (v_n)_{n \in \mathbb{N}}$ . On note  $p_n = P(X = v_n)$ .


$$F_X(x) = \sum p_n 1_{[v_n, \infty[}$$

- $X$  v.a. uniforme sur  $[a, b]$ , ( $a < b$ ).

$$F_X(x) = \frac{x - a}{b - a} 1_{[a, b[} + 1_{[b, \infty[}$$

$F_X$  affine sur  $[a, b]$ .

# Exemple de fonction de répartition



Quelle est la loi ?

$$P(X \in [-1, 0]) = 0.2, P(X \in [1, 2]) = 0.8$$

Probabilité uniforme  $[-1, 0]$  et  $[1, 2]$ .

## Lois a densité

Définition:

Une fonction  $f$  définie sur  $\mathbb{R}$  est une densité de probabilité si elle est positive, intégrable et d'intégrale 1;

$$\int_{-\infty}^{+\infty} f(x)dx = 1$$

Propriété:

La fonction

$$F(x) = \int_{-\infty}^x f(y)dy$$

vérifie les propriétés d'une fonction de répartition:

- $F$  est croissante (sa dérivée est positive)
- $F$  est continue a droite (elle l'est partout car dérivable)
- $\lim_{x \rightarrow -\infty} F(x) = 0$   
 $\lim_{x \rightarrow +\infty} F(x) = \int_{\mathbb{R}} f = 1$

D'après la réciproque de la propriété sur les fonctions de répartition,  $F$  est une fonction de répartition qui caractérise une loi de probabilité.

## Lois a densité

Propriétés:

Soi  $X$  une v.a. réelle de loi de densité  $f$ .

- Sa fonction de répartition  $F_X$  est continue et

$$\forall x, P(X = x) = 0$$

- Sa fonction de répartition  $F_X$  est dérivable et

$$\forall x, F'_X(x) = f(x)$$

Réciproquement, si la v.a.  $X$  est telle que sa fonction de répartition  $F_X$  est dérivable,  $X$  admet la densité


$$\forall x, f(x) = F'_X(x)$$

Remarques:

- Les v.a. discrètes n'admettent pas de densité (continue par rapport a la mesure de Lebesgue).
- La réciproque n'est pas vraie.

## Exemple



Fonction de répartition non dérivable qui caractérise la loi d'une v.a. non discrète:



- $P(X = -1) = 0.2$ ,  $P(X \in [1, 2]) = 0.8$ .
- N'admet pas de densité car discontinue en -1.
- N'est pas discrète car  $[1, 2]$  est inclus dans son espace d'états.





# Exemple de fonction de répartition

N'admettent pas de densité les fonctions de répartition suivantes:



# Exemple de fonction de répartition

Les fonctions de répartition suivantes ont pour densité:



# Générateurs de nombres aléatoires.

Générer des nombre (vraiment) aléatoires:

- Utiliser un processus physique : fluctuations thermiques, bruit photonique, rayonnements parasites atmosphériques
- Utiliser un processus "social" : temps de ping sur wikipedia.com, mesure du trafic automobile...

Pose un certain nombre de problèmes:

- Processus physique: dépend d'un capteur et des paramètres.
- Processus "social" : fluctuations temporelles

Vraiment aléatoire, mais peu fiable.

## Générateurs de nombres pseudo-aléatoires.

Générer des variables uniformes sur  $[0, 1[$

- Suite récurrente a valeur dans  $\{0, 1, \dots, m - 1\}$

$$x_{n+1} = \phi(x_n)$$

- Suite périodique de période  $p$ ,  $p \leq m$
- On considère la suite  $u$  a valeur dans  $[0, 1[$

$$u_n = \frac{x_n}{m}$$

- Les tirages successif doivent avoir les caractéristiques de tirages indépendants

ex: générateurs congruentiels

$$x_0 \in \mathbb{N}, x_{n+1} = ax_n + b \text{ modulo } m$$

Scilab:  $m = 2^{31}$ ,  $a = 843314861$ ,  $b = 453816693$ .

Python: Mersenne Twister, voir les docs python.

## Inverse de la fonction de répartition.

A partir d'une v.a. uniformes sur  $[0, 1]$ , on peut simuler n'importe quelle v.a. dont on connaît la fonction de répartition.

Définition:

$G$  inverse continue a gauche de  $F$  est définie par

$$G(u) = \inf \{x : F(x) \geq u\}$$


Propriétés:

- 1  $G(u) \leq x \iff u \leq F(x)$
- 2  $F(G(u)) = u$  si  $F$  continue en  $u$ .

Preuve: 1 découle de la définition de inf, 2 au tableau.

# Inverse de la fonction de répartition.

- Si  $F$  bijective (continue, strict. croissante), c'est l'inverse (= la réciproque)  $F^{-1} : ]0, 1[ \mapsto \mathbb{R}$  de  $F : \mathbb{R} \mapsto ]0, 1[$ .  
ex:  $F(x) = 1/(1 + e^{-x})$ ,  $F^{-1}(y) = -\log(1/y - 1)$



- $F$  constante sur  $[a, b]$ : au tableau.
- $F$  discontinue en  $a$ : au tableau.

## Méthode de l'inversion de la fonction de répartition.

Propriété:

Soit  $F$  une fonction de répartition d'inverse continue à gauche  $G$ .

$U$  v.a. uniforme sur  $[0, 1]$

$X = G(U)$  est une v.a. de fonction de répartition  $F$ .

Preuve:

Quelle est la fonction de répartition de  $X$  ?

$\forall x \in \mathbb{R}$ :

$$\begin{aligned} P(X \leq x) &= P(G(U) \leq x) && \text{car } X = G(U) \\ &= P(U \leq F(x)) && \text{car } G(U) \leq x \iff U \leq F(x) \\ &= F_U(F(x)) && \text{par déf. de } F_U \\ &= F(x) && \text{car } F_U(y) = y, \forall y \in [0, 1]. \end{aligned}$$

# Méthode de l'inversion de la fonction de répartition.

Exercice:

En utilisant le générateur de nombre pseudo-aléatoire code précédemment, simulez une v.a. de Fonction de répartition

$$F(x) = 1/(1 + e^{-x})$$

et vérifiez que l'histogramme des valeurs tirées converge vers la densité  $F'(x)$ .

# Espérance d'une variable aléatoire réelle

La notion d'espérance d'une variable aléatoire réelle se définit par passage à la limite des fonctions en escaliers (v.a. discrètes).

La différence est qu'on exige que  $\mathbb{E}(|X|) < \infty$ , c.a.d.  $X \in L^1$ .

Propriétés:

- linéarité

$$\mathbb{E}(aX + bY) = a\mathbb{E}(X) + b\mathbb{E}(Y)$$

- positivité

$$X \geq 0, \mathbb{E}(X) \geq 0$$

- v.a. constante

$$X \text{ constante de valeur } a, \mathbb{E}(X) = a$$

- inégalité

$$|\mathbb{E}(X)| \leq \mathbb{E}(|X|)$$

## (Co)variance d'une variable aléatoire réelle

Si  $\mathbb{E}(X^2) < \infty$ , on peut définir la variance:

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

Ecart type:

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

Covariance:

Soit  $X, Y$  deux v.a. réelles

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

Coefficient de corrélation:

$$\text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$

# (Co)variance d'une variable aléatoire réelle

Propriétés:

- $Var(aX + b) = a^2 Var(X)$
- $Var(X + Y) = Var(X) + Var(Y) + 2Cov(X, Y)$ .
- $X, Y$  indépendantes:  $Cov(X, Y) = 0$  donc  
 $Var(X + Y) = Var(X) + Var(Y)$
- $Cov(aX + b, cY + d) = acCov(X, Y)$

Remarque:

$\forall X$  t.q.  $\mathbb{E}(X^2) < \infty$ , la v.a.

$$\frac{X - \mathbb{E}(X)}{\sigma_X}$$

est d'espérance nulle (i.e. centrée) et de variance 1 (réduite).

## Espérance de v.a. réelles a densité

$X$  v.a. réelle qui admet une densité  $f$ .

Si  $g$  fonction t.q.  $g(X) \in L^1$ :

$$\mathbb{E}(g(X)) = \int_{\mathbb{R}} g(x)f(x)dx$$

En particulier:

$$\mathbb{E}(X) = \int_{\mathbb{R}} xf(x)dx$$



$$\text{Var}(X) = \int_{\mathbb{R}} x^2f(x)dx - \mathbb{E}(X)^2$$

Remarque:

C'est la limite continue du cas discret:  $\sum \rightarrow \int$ ,

$p_n = P(X = n) \rightarrow f(x)dx$ .



# Loi uniforme sur $[a, b]$



Exemple avec  $a = 0$  et  $b = 1$ .

- Densité  $f(x) = \frac{1}{b-a} \mathbf{1}_{[a,b]}$
- Espérance  $\int_a^b \frac{x}{b-a} dx = \frac{1}{2(b-a)} (b^2 - a^2) = \frac{(b-a)(b+a)}{2(b-a)} = \frac{a+b}{2}$
- Variance  $\int_a^b \frac{x^2}{b-a} dx - \left(\frac{a+b}{2}\right)^2 = \frac{(b-a)^2}{12}$



# Loi exponentielle de paramètre $\lambda$



- Densité  $f(x) = \lambda e^{-\lambda x} \mathbf{1}_{[0, \infty[}$
- Fonction de répartition  $F(x) = (1 - e^{-\lambda x}) \mathbf{1}_{[0, \infty[}$
- Espérance:  $\int_0^{\infty} x \lambda e^{-\lambda x} dx = 1/\lambda$
- Variance  $1/\lambda^2$


Notebook: simuler une v.a. exponentielle par méthode d'inversion.

# Loi Normale (Gaussienne) centrée réduite



- Densité  $f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$
- Fonction de répartition non analytique  $F(x) = \int_{-\infty}^x f(x) dx$ .
- Espérance 0, Variance 1.

# Loi Normale $\mathcal{N}(m, \sigma^2)$



- Densité  $f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right)$
- Fonction de répartition non analytique  $F(x) = \int_{-\infty}^x f(x)dx$ .
- Espérance  $m$
- Variance  $\sigma^2$

# Variables aléatoire usuelles en python

Bibliothèque `scipy.stats` donne accès aux caractéristiques de nombreuses lois: normale, exponentielle,  $\chi^2$ , ...

Exemple: `scipy.stats.norm`

- densité: `scipy . stats . norm . pdf`.
- Fonction de répartition: `scipy . stats . norm . cdf`
- Inverse de la fonction de répartition: `scipy . stats . norm . ppf`
- Moyenne, Variance, Moments...

Pour échantillonner, on utilisera la bibliothèque `numpy.random`.

# Convergence presque sûre des variables aléatoires

Définition de la convergence presque sûre:

On dit que la suite  $X_n$  converge presque sûrement vers la variable aléatoire  $X$ , et on note  $X_n \xrightarrow[\text{p.s.}]{} X$ , si

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$$

Remarques:

- Dans le cas des suites de nombre déterministe, une suite  $a$  qui converge ne peut avoir deux sous-suites qui convergent vers deux valeurs différentes
- Dans le cas probabiliste, il peut exister des événements tels que  $X_n \not\rightarrow X$ , mais ils doivent être de probabilité nulle.

## Convergence presque sure des variables aléatoires

$X_i$  Bernoulli indépendantes de paramètre  $p \in ]0, 1[$ .

La suite  $M_n = \frac{\sum_{i=1}^n X_i}{n}$  converge-t-elle ?

- Si  $\forall i, X_i = 1$ , alors  $M_n = 1 \forall n$ .
- Si  $\forall i, X_i = 0$ , alors  $M_n = 0 \forall n$ .

Donc  $M_n$  ne converge pas. FAUX!

Ces deux évènements n'empêchent pas la convergence presque sure de  $M_n$  parce que leur probabilité est nulle:

- $P(M_n = 1) = p^n \xrightarrow[n \rightarrow \infty]{} 0$
- $P(M_n = 0) = (1 - p)^n \xrightarrow[n \rightarrow \infty]{} 0$ .

La convergence p.s. est donc plus "souple" que la notion déterministe de convergence simple.

# La loi forte des grands nombres

## Théorème:

Soient  $X_n$  variables aléatoires indépendantes de même loi et intégrables. On note  $m = \mathbb{E}(X_i)$ .

La moyenne empirique  $M_n$  des v.a.  $X_i$  converge presque sûrement vers la *moyenne théorique*  $m = \mathbb{E}(X_i)$  des v.a.  $X_i$  quand  $n$  tend vers l'infini.

$$M_n = \frac{X_1 + \dots + X_n}{n} \xrightarrow[\text{p.s.}]{} m \text{ qd } n \rightarrow \infty$$

Remarques:

- exemple:  $X_i$  Bernoulli indépendantes de paramètre  $p$ :

$$M_n = \frac{\sum_{i=1}^n X_i}{n} \xrightarrow[\text{p.s.}]{} \mathbb{E}(X_i) = p$$

- Vitesse de convergence ? Théorème de la limite centrale.

# La loi forte des grands nombres

## Corrolaire:

Soient  $X_n$  variable aléatoires indépendantes de même loi et  $f$  fonction t.q.  $f(X_i)$  intégrables.

$$\frac{f(X_1) + \dots + f(X_n)}{n} \xrightarrow[\text{p.s.}]{} \mathbb{E}(f(X_i))$$

# Méthode de Monte-Carlo pour calcul d'intégrales

Soient  $X_n$  variables aléatoires indépendantes uniformes sur  $[0, 1]$ .  $f$  fonction intégrable sur  $[0, 1]$ .

$$\lim_n \frac{f(X_1) + \dots + f(X_n)}{n} = \int_0^1 f(x) dx$$

Preuve:

Une v.a.  $X$  de loi uniforme sur  $[0, 1]$  a pour densité  $1_{[0,1]}$  donc

$$E(f(X)) = \int_{\mathbb{R}} 1_{[0,1]}(x) f(x) dx = \int_0^1 f(x) dx$$

# Méthode de Monte-Carlo pour calcul d'intégrales

Generalisation en dimension  $d$ .

Soient  $X_n$  vecteurs aléatoires indépendants de loi uniforme sur l'hyper-cube  $A = [-a, a]^d$ .  $f$  fonction intégrable sur  $A$ .

$$\lim_{n \rightarrow \infty} \frac{(2a)^d}{n} (f(X_1) + \dots + f(X_n)) = \int_A f$$

Preuve:

Un vecteur aléatoire  $X$  de loi uniforme sur  $A$  a pour densité  $1_A/(2a)^d$  donc

$$E(f(X)) = \int_{\mathbb{R}} 1_A(x) f(x) dx = \int_A f(x) dx$$


Remarques:

- $f$  peut être très irrégulière, simplement bornée.
- temps de calcul proportionnel à  $nd$

# Monte-Carlo vs méthode des rectangles pour les intégrales

Méthode des rectangles en dimension 1: on découpe l'intervalle  $[0, 1]$  en  $N$  segments de centre  $x_i$  de longueur  $\Delta x$  et

$$\int_{[0,1]} f(x) dx \approx \sum_{i=1}^N f(x_i) \Delta x$$




## Monte-Carlo vs méthode des rectangles pour les intégrales

Méthode des rectangles en dimension 2: on découpe la surface  $[0, 1]^2$  en  $N^2$  de centre  $x_{i,j}$  de surface  $\Delta x^2$  et

$$\int_{[0,1]^2} f(x) dx \approx \sum_{i,j=1}^N f(x_{i,j}) \Delta x^2$$

Rectangles en 2D avec 10 points par axes



$10^2$  valeurs à calculer en 2D.

## Monte-Carlo vs méthode des rectangles pour les intégrales

Méthode des rectangles en dimension  $d$ : on découpe le domaine  $[0, 1]^d$  en  $N^d$  hyper-cubes de centre  $x_{i,j,\dots}$  de volumes  $\Delta x^d$ .

$$\int_{[0,1]^d} f(x) dx \approx \sum_{i,j,\dots=1}^N f(x_{i,j,\dots}) \Delta x^d$$

Rappel sur les intégrales en dimension  $> 1$ .

Si  $f : \mathbb{R}^5 \mapsto \mathbb{R}$  est une fonction séparable en les coordonnées  $u, v, w, x, y$ :

$$f(u, v, w, x, y) = f_1(u)f_2(v)f_3(w)f_4(x)f_5(y)$$

l'intégrale de  $f$  sur l'hyper-cube  $[0, 1]^5$  est le produit des intégrales des  $f_i$  sur les segments  $[0, 1]$ :

$$\int_{[0,1]^5} f(u, v, w, x, y) dudvdwdxdy = \int_{[0,1]} f_1(u)du \int_{[0,1]} f_2(v)dv \int_{[0,1]} f_3(w)dw \int_{[0,1]} f_4(x)dx \int_{[0,1]} f_5(y)dy$$

# Monte-Carlo vs méthode des rectangles pour les intégrales

Exercice:

$$f(u, v, w, x, y) = e^u 2v \sin(w) \cos(x) \frac{1}{1+y}$$

Calculer  $\int_{[0,1]^5} f$

- $f$  est une fonction séparable en les coordonnées  $u, v, w, x, y$ , l'intégrale est le produit des intégrales.
- Primitives:  $u \mapsto e^u$ ,  $v \mapsto v^2$ ,  $w \mapsto -\cos(w)$ ,  $x \mapsto \sin(x)$  et  $y \mapsto \log(1+y)$
- Valeur: 0.4607...

Notebook: comparer, a temps d'exécution comparable, la précision des méthodes de Monte-Carlo et des rectangles pour  $\int_{[0,1]^5} f$ .

## Convergence en loi des variables aléatoires

On dit que la suite  $X_n$  converge en loi vers la variable aléatoire  $X$ , et on note  $X_n \xrightarrow{\mathcal{L}} X$ , si pour toute fonction continue bornée  $f$

$$\lim_{n \rightarrow \infty} \mathbb{E}(f(X_n)) = \mathbb{E}(f(X))$$

exemple:  $X_i$  v.a. a valeurs dans  $\{1, \dots, N\}$ .  $\forall i \in \{1, \dots, N\}$ :

$$\lim_{n \rightarrow \infty} P(X_n = i) = P(X = i)$$

On a

$$\lim_{n \rightarrow \infty} \mathbb{E}(f(X_n)) = \sum_{i=1}^N f(i) \left( \lim_{n \rightarrow \infty} P(X_n = i) \right) = \mathbb{E}(f(X))$$

# Convergence en loi des variables aléatoires

Exemples:

Soient  $X_n$  suite de variable  $\mathcal{N}(0, \sigma_n)$  t.q.  $\lim_{n \rightarrow \infty} \sigma_n = 1$ .  $X_n$  converge en loi vers  $X$  variable aléatoire de loi  $\mathcal{N}(0, 1)$ .

Pour toute fonction continue bornée  $f$

$$\begin{aligned}\mathbb{E}(f(X_n)) &= \int \frac{f(x)e^{-x^2/2(1+1/n)^2}}{\sqrt{2\pi}(1+1/n)} dx \\ &\xrightarrow{n \rightarrow \infty} \int \frac{f(x)e^{-x^2/2}}{\sqrt{2\pi}} dx\end{aligned}$$

par théorème de convergence dominée.

Plus généralement, si  $X$  v.a. de densité  $d$ , et  $X_n$  suite de v.a. de densité  $d_n$  t.q.  $\lim_{n \rightarrow \infty} d_n = d$  et que  $\forall n, d_n < h \in L^1(\mathbb{R})$ ,  $X_n$  converge en loi vers  $X$ .

## Convergence en loi des variables aléatoires

Propriété:

$X_n$  suite de v.a. qui converge en loi vers  $X$ . On note  $F_n$  les fonctions de répartition des v.a.  $X_n$ . Si la fonction de répartition  $F$  de la v.a.  $X$  est continue en  $x$ , on a :

$$\lim_{n \rightarrow \infty} F_n(x) = F(x)$$

Conséquence:

$X_n$  suite de v.a. qui converge en loi vers v.a.  $X$  a densité  $f$ ,  $a < b$  réels.

$$\lim_{n \rightarrow \infty} P(a \leq X_n \leq b) = \int_a^b f(x) dx$$

Avec cette propriété, la notion de convergence en loi est d'autant plus claire. La loi des  $X_n$ , c.a.d. les probabilités que  $X_n$  soient dans  $[a, b]$  converge vers la loi de  $X$  donnée par la densité  $f$ .

# Théorème de la limite centrale

Théorème:

Soit  $X_n$  une suite de variable aléatoires indépendantes et de même loi, de moyenne  $m$  et de variance  $\sigma^2 > 0$ . On note  $M_n = \frac{X_1 + \dots + X_n}{n}$  la moyenne empirique. La suite de variables aléatoires

$$\frac{\sqrt{n}(M_n - m)}{\sigma}$$

converge en loi vers une variable aléatoire de loi normale  $\mathcal{N}(0, 1)$  quand  $n$  tend vers  $+\infty$ .

$$\begin{aligned} & \frac{\sqrt{n}(M_n - m)}{\sigma} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1) \\ \iff & \frac{(S_n - nm)}{\sqrt{n}\sigma} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1) \end{aligned}$$

## Remarques sur le Théorème de la limite centrale

D'après la propriété sur la convergence en loi, le Théorème de la limite centrale (TLC) donne :

$$\lim_{n \rightarrow \infty} P \left( \frac{\sqrt{n}(M_n - m)}{\sigma} \in [a, b] \right) = \int_a^b \frac{e^{-x^2/2}}{\sqrt{2\pi}}$$

Remarques:

- Le TLC donne une vitesse de convergence pour la loi des grands nombres
- Moyen mémo-technique:  $\sigma > 0 \implies$  sigma au dénominateur.  $M_n - m \rightarrow 0$ . Retenir: loi  $\mathcal{N}(0, 1)$ , et convergence en  $1/\sqrt{n}$

$$\frac{M_n - m}{\sigma} \underset{n \rightarrow \infty}{\approx} \frac{\mathcal{N}(0, 1)}{\sqrt{n}}$$

- C'est vrai en particulier pour les lois discrètes alors que la limite est une v.a. continue.
- Pas de vitesse de convergence pour la convergence en loi.

## Pratique du Théorème de la limite centrale

1. Notebook: vérifier empiriquement le TLC pour un suite de v.a. de Bernoulli.
2.  $B_n$  suit une loi binomiale  $\mathcal{B}(n, 1/2)$ . Calculer  $P(B_{2000} > 1111)$ .  
Méthode 1:

$$P(B_{2000} > 1111) = \sum_{k=1112}^{2000} \binom{2000}{k} \left(\frac{1}{2}\right)^{2000}$$

Méthode 2:

$B_n$  suit la même loi qu'une somme  $S_n$  de  $n$  variables de Bernoulli indépendantes de paramètre  $p = 1/2$ , d'espérance  $p = 1/2$  et d'écart-type  $\sqrt{p(1-p)} = 1/2$ . TLC (version avec  $S_n$ ):

$$\frac{(S_n - n/2)}{\sqrt{n}/2} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$$

Comme  $n = 2000 \gg 1$ , on s.q.  $Y = \frac{S_{2000} - 2000/2}{\sqrt{2000}/2}$  suit exactement une loi  $\mathcal{N}(0, 1)$ .

## Pratique Théorème de la limite centrale

Faisons apparaître la v.a.  $Y = \frac{S_{2000} - 2000/2}{\sqrt{2000}/2}$  dans notre inégalité  $S_{2000} > 1111$ :

$$\begin{aligned}P(S_{2000} > 1111) &= P(S_{2000} - 1000 > 111) \\&= P\left(\frac{S_{2000} - 1000}{\sqrt{2000}/2} > \frac{111}{\sqrt{2000}/2}\right) \\&= P\left(Y > \frac{111}{\sqrt{500}}\right) \\&= 1 - P\left(Y \leq \frac{111}{\sqrt{500}}\right) \\&\stackrel{TLC}{\approx} 1 - F_{\mathcal{N}(0,1)}\left(\frac{111}{\sqrt{500}}\right)\end{aligned}$$

Résultat:  $P(S_{2000} > 1111) \stackrel{TLC}{\approx} 3.2 \cdot 10^{-7}$ .

## Probabilités exactes d'une somme de Bernoulli

**Exercice:** calcul exact de  $P(B_{2000} > 1111)$  (sans LGN, sans TLC).

Problème: overflow dans le calcul

$$\binom{2000}{k} \left(\frac{1}{2}\right)^{2000}$$

Méthode 1: réécrire ce terme comme un produit de nombres proches de 1

$$\begin{aligned} \binom{2000}{k} \left(\frac{1}{2}\right)^{2000} &= \frac{2000!}{k!(2000-k)!2^{2000}} \\ &= \frac{1/2 \times 2/2 \times \dots \times 2000/2}{1 \times \dots \times k \times 1 \times \dots \times n-k} \\ &= \frac{1/2 \times 2/2 \times \dots \times 2000/2}{1^2 \times 2^2 \times \dots \times m^2 \times (m+1) \times \dots \times M} \end{aligned}$$

avec  $m = \min(k, n-k)$  et  $M = \max(k, n-k)$ .

## Probabilités exactes d'une somme de Bernoulli

**Exercice:** calcul exact de  $P(B_{2000} > 1111)$  (sans LGN, sans TLC).

Problème: overflow dans le calcul

$$\binom{2000}{k} \left(\frac{1}{2}\right)^{2000}$$

Méthode 2: produit de convolution. Si  $X$  et  $Y$  deux v.a. indépendantes à valeur dans  $\mathbb{Z}$  la loi de  $X + Y$  s'obtient par convolution discrète des lois de  $X$  et  $Y$

$$P(X + Y = k) = \sum_i P(Y = i)P(X = k - i)$$

Se généralise pour une somme de  $n$  v.a. indépendantes.

Les v.a.  $X_i$  de Bernoulli sont à valeur dans  $\mathbb{Z}$  avec  $P(X_i \neq 0, 1) = 0$ . On utilise `numpy.convolve` avec `mode='full'`.

Résultat:  $2.997 \cdot 10^{-7}$ .

# Intervalles de confiance

Principe: référendum, deux possibilités 0 ou 1. On veut déterminer statistiquement la proportion  $p$  des votes pour 1. On choisit  $n$  individus au hasard (sans remise). On note  $X_i = 1$  si le  $i$ -ème individu vote 1,  $X_i = 0$  s'il vote 0.

Comment estimer de  $p$  a partir des observation ?

- On s.q. les v.a.  $X_i$  suivent une loi de Bernoulli de paramètre  $p$ .
- On les suppose indépendantes. Ok ? pas exactement à cause du tirage sans remise.
- on définit:  $\hat{P}_n = \frac{\sum_{i=1}^n X_i}{n}$ .
- $\forall n, \mathbb{E}(\hat{P}_n) = p$  par linéarité de l'espérance ( $\hat{P}_n$  est **non biaisé**).
- $\lim_{n \rightarrow \infty} \hat{P}_n = p$ , par la LGN, i.e.  $\hat{P}_n$  est asymptotiquement bon.

Mais  $\hat{P}_n$  est une variable aléatoire. Peut-on avoir un résultat qui tienne compte des aléas ?

# Intervalles de confiance

On suppose que le sondage porte sur 2000 individus, on a 1042 intentions de vote pour 1 et 958 pour 0,  $\hat{P}_{2000} = 52.1\%$ , cette valeur prédit que 1 remporte. Mais  $\hat{P}_{2000}$  est une variable aléatoire, et un nouveau tirage me donnera une valeur différente, potentiellement  $< 50\%$ . Quel niveau de confiance peut on avoir en cette prédiction ?

## Intervalle de confiance

On se donne une probabilité  $\alpha$  proche de 1, qui correspond à la probabilité de ne pas se tromper, typiquement  $\alpha = 95\%$ . on cherche  $\epsilon > 0$  tel que

$$P(p \in [\hat{P}_n - \epsilon, \hat{P}_n + \epsilon]) = \alpha$$

$$P(p \in [\hat{P}_{2000} - \epsilon, \hat{P}_{2000} + \epsilon]) = 95\% \text{ dans notre cas.}$$

Calcul de  $\epsilon$  ?  $\Rightarrow$  Théorème de la limite centrale.

# Intervalle de confiance

D'une part

$$P(p \in [\hat{P}_n - \epsilon, \hat{P}_n + \epsilon]) = P(p \leq \hat{P}_n + \epsilon) - P(p \leq \hat{P}_n - \epsilon)$$

Calculons  $P(p \leq \hat{P}_n + \epsilon)$  :

$$\begin{aligned} P(p \leq \hat{P}_n + \epsilon) &= P(-\epsilon \leq \hat{P}_n - p) \\ &= P\left(-\frac{\epsilon\sqrt{n}}{\sqrt{p(1-p)}} \leq \frac{\sqrt{n}(\hat{P}_n - p)}{\sqrt{p(1-p)}}\right) \\ &= P(-a \leq Y_n), \quad a = \frac{\epsilon\sqrt{n}}{\sqrt{p(1-p)}}, \quad Y_n = \frac{\sqrt{n}(\hat{P}_n - p)}{\sqrt{p(1-p)}} \\ &= 1 - P(Y_n < -a) \\ &\stackrel{TLC}{\approx} 1 - F_{\mathcal{N}(0,1)}(-a) \\ &\quad n \gg 1 \end{aligned}$$

## Intervalles de confiance

Calculons  $P(p \leq \hat{P}_n - \epsilon)$  :

$$\begin{aligned}P(p \leq \hat{P}_n - \epsilon) &= P(\epsilon \leq \hat{P}_n - p) \\&= P\left(\frac{\epsilon\sqrt{n}}{\sqrt{p(1-p)}} \leq \frac{\sqrt{n}(\hat{P}_n - p)}{\sqrt{p(1-p)}}\right) \\&= P(a \leq Y_n) \\&= 1 - P(Y_n < a) \\&\stackrel{TLC}{\approx} 1 - F_{\mathcal{N}(0,1)}(a) \\&\quad n \gg 1\end{aligned}$$

Donc

$$P(p \in [\hat{P}_n - \epsilon, \hat{P}_n + \epsilon]) = F_{\mathcal{N}(0,1)}(a) - F_{\mathcal{N}(0,1)}(-a) = 2F_{\mathcal{N}(0,1)}(a) - 1$$

## Intervalle de confiance

$$2F_{\mathcal{N}(0,1)}\left(\epsilon\sqrt{\frac{n}{p(1-p)}}\right) - 1 = \alpha \iff \epsilon = \sqrt{\frac{p(1-p)}{n}} F_{\mathcal{N}(0,1)}^{-1}\left(\frac{\alpha+1}{2}\right)$$

Problème:  $p(1-p)$  ?

$$p(1-p) \leq \frac{1}{4}, \forall p \in [0, 1]$$

Donc  $\epsilon$  borné par

$$\epsilon_{\max} = \frac{1}{2\sqrt{n}} F_{\mathcal{N}(0,1)}^{-1}\left(\frac{\alpha+1}{2}\right)$$

Python:  $F_{\mathcal{N}(0,1)}^{-1}$  est donnée par `scipy.stats.norm.ppf`.

# Intervalles de confiance

Propriété:

$X_i$  variables de Bernoulli indépendantes de paramètre  $p$ ,  $\hat{P}_n = \sum_{i=1}^n X_i/n$ .

Soit  $\alpha \in ]0, 1[$  le **niveau de confiance asymptotique de l'intervalle**.

L'intervalle

$$I_\alpha^n = \left[ \hat{P}_n - \frac{F_{\mathcal{N}(0,1)}^{-1}\left(\frac{\alpha+1}{2}\right)}{2\sqrt{n}}, \hat{P}_n + \frac{F_{\mathcal{N}(0,1)}^{-1}\left(\frac{\alpha+1}{2}\right)}{2\sqrt{n}} \right]$$

est tel que

$$\lim_{n \rightarrow \infty} P(p \in I_\alpha^n) = \alpha$$

Exemples:

- 95%  $\Rightarrow \left[ \hat{P}_n - \frac{0.98}{\sqrt{n}}, \hat{P}_n + \frac{0.98}{\sqrt{n}} \right]$ , 99%  $\Rightarrow \left[ \hat{P}_n - \frac{1.29}{\sqrt{n}}, \hat{P}_n + \frac{1.29}{\sqrt{n}} \right]$
- Ces intervalles sont des variables aléatoires.
- $n = 2000$ ,  $\hat{p}_{2000} = 0.521$ ,  $I_{99\%}^{2000} = [49.2\%, 55.0\%]$

## Méthode de Monte-Carlo générale

On a vu la méthode de Monte-Carlo pour une intégrale sur un hyper-cube  $[-a, a]^d$ . Si  $f : \mathbb{R}^d \mapsto \mathbb{R}$  est à support compact  $S \subset [-a, a]^d$ , on définit  $g = 1_S f$ , et on applique la méthode à  $g$ .

S'il existe  $p(x) > 0$ , et si on définit  $\phi(x) = f(x)/p(x)$ ,  $X$  v.a. de densité  $p$

$$\int_{\mathbb{R}^d} f(x) dx = \int_{\mathbb{R}^d} \phi(x) p(x) dx = \mathbb{E}(\phi(X))$$

$X_i$  v.a. indépendantes de densité  $p$ , d'après la Loi des grands nombres :

$$M_n = \frac{\phi(X_1) + \dots + \phi(X_n)}{n} \xrightarrow[n \rightarrow \infty]{p.s.} \mathbb{E}(\phi(X)) = \int_{\mathbb{R}^d} f(x) dx$$

Vitesse de convergence ?

# Vitesse de convergence de la méthode de Monte-Carlo

Exercice:

On note  $e = \mathbb{E}(\phi(X))$ . Comme pour l'intervalle de confiance du sondage, on se donne  $\alpha$  proche de 1, on cherche  $\epsilon$  t.q.:

$$P(e \in [M_n - \epsilon, M_n + \epsilon]) = \alpha$$

Cette fois ci on ne pourra pas se débarrasser du  $\sigma$ . L'intervalle de confiance fera donc intervenir

$$\sigma_n = \sqrt{\frac{\phi(X_1)^2 + \dots + \phi(X_n)^2}{n} - (M_n)^2}$$

## TLC amélioré

### Lemme de Slutsky

$X_n$  et  $Y_n$  deux suites de v.a. réelles telles que

$$X_n \xrightarrow{\mathcal{L}} X, Y_n \xrightarrow{p.s.} C \text{ constante.}$$

Pour toute fonction continue  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$

$$g(X_n, Y_n) \xrightarrow{\mathcal{L}} g(X, C)$$

Application:

$$\frac{\sqrt{n}(M_n - m)}{\sigma} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1), \quad \frac{\sigma}{\sigma_n} \xrightarrow{p.s.} 1$$

Donc

$$\frac{\sqrt{n}(M_n - m)}{\sigma_n} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$$

# Vitesse de convergence de la méthode de Monte-Carlo

$$P(e \in [M_n - \epsilon, M_n + \epsilon]) = P(e \leq M_n + \epsilon) - P(e \leq M_n - \epsilon)$$

$$\begin{aligned}P(e \leq M_n + \epsilon) &= P(-\epsilon \leq M_n - e) \\&= P\left(-\frac{\epsilon\sqrt{n}}{\sigma_n} \leq \frac{\sqrt{n}(M_n - e)}{\sigma_n}\right) \\&= P(-a \leq Y_n), \quad a = \frac{\epsilon\sqrt{n}}{\sigma_n}, \quad Y_n = \frac{\sqrt{n}(M_n - e)}{\sigma_n} \\&= 1 - P(Y_n < -a) \\&\stackrel{TLC}{\underset{n \gg 1}{\approx}} 1 - F_{\mathcal{N}(0,1)}(-a)\end{aligned}$$

# Vitesse de convergence de la méthode de Monte-Carlo

$$\begin{aligned}P(e \leq M_n - \epsilon) &= P(\epsilon \leq M_n - e) \\&= P\left(\frac{\epsilon\sqrt{n}}{\sigma_n} \leq \frac{\sqrt{n}(M_n - e)}{\sigma_n}\right) \\&= P(a \leq Y_n), \quad a = \frac{\epsilon\sqrt{n}}{\sigma_n}, \quad Y_n = \frac{\sqrt{n}(M_n - e)}{\sigma_n} \\&= 1 - P(Y_n < a) \\&\stackrel{TLC}{\underset{n \gg 1}{\approx}} 1 - F_{\mathcal{N}(0,1)}(a)\end{aligned}$$

$$P(e \in [M_n - \epsilon, M_n + \epsilon]) = F_{\mathcal{N}(0,1)}(a) - F_{\mathcal{N}(0,1)}(-a) = 2F_{\mathcal{N}(0,1)}(a) - 1$$

# Vitesse de convergence de la méthode de Monte-Carlo

On a donc

$$2F_{\mathcal{N}(0,1)}\left(\epsilon\frac{\sqrt{n}}{\sigma_n}\right) - 1 = \alpha \iff \epsilon = \frac{\sigma_n}{\sqrt{n}}F_{\mathcal{N}(0,1)}^{-1}\left(\frac{\alpha+1}{2}\right)$$

Ce qui nous permet d'obtenir  $\epsilon$ :

$$\epsilon = \frac{\sigma_n}{\sqrt{n}}F_{\mathcal{N}(0,1)}^{-1}\left(\frac{\alpha+1}{2}\right)$$

# Vitesse de convergence de la méthode de Monte-Carlo

Propriété:

$X_i$  v.a. i.i.d. de densité  $p(x) > 0$ , et  $\phi(x) = f(x)/p(x)$ .

$$M_n = \frac{\phi(X_1) + \dots + \phi(X_n)}{n} \text{ moyenne emp.}$$

$$\sigma_n = \sqrt{\frac{\phi(X_1)^2 + \dots + \phi(X_n)^2}{n} - (M_n)^2} \text{ ec. type emp.}$$

Soit  $\alpha \in ]0, 1[$  le **niveau de confiance asymptotique de l'intervalle**.

L'intervalle

$$I_\alpha^n = \left[ M_n - \frac{\sigma_n}{\sqrt{n}} F_{\mathcal{N}(0,1)}^{-1} \left( \frac{\alpha + 1}{2} \right), M_n + \frac{\sigma_n}{\sqrt{n}} F_{\mathcal{N}(0,1)}^{-1} \left( \frac{\alpha + 1}{2} \right) \right]$$

est tel que

$$\lim_{n \rightarrow \infty} P \left( \int f \in I_\alpha^n \right) = \alpha$$

# Changement de variable affine d'une v.a. a densité

Propriété:

$X$  v.a. de densité  $p_X(x)$ ,  $a \in \mathbb{R}^*$  et  $b \in \mathbb{R}$ ,  $Y = aX + b$ .

$Y$  admet la densité

$$p_Y(y) = \frac{1}{|a|} p_X\left(\frac{y-b}{a}\right)$$

- Si  $X \sim \mathcal{N}(m, \sigma^2)$  alors  $\frac{X-m}{\sigma} \sim \mathcal{N}(0, 1)$ .
- Si  $X \sim \mathcal{N}(0, 1)$  alors  $aX + b \sim \mathcal{N}(b, a^2)$ .
- Si  $X \sim \mathcal{U}(\alpha, \beta)$  alors  $aX + b \sim \mathcal{U}(a\alpha + b, a\beta + b)$ .

## Somme de deux v.a. a densité

Propriété:

$X$  et  $Y$  v.a. **indépendantes** de densité respectives  $p_X$ , et  $p_Y$ .

$Z = X + Y$  admet la densité

$$p_Z(z) = \int_{\mathbb{R}} p_X(z-x)p_Y(x)dx = \int_{\mathbb{R}} p_X(x)p_Y(z-x)dx$$

$p_Z$  est le produit de convolution  $p_X * p_Y = p_Y * p_X$  des densités  $p_X$  et  $p_Y$ .

Remarques: C'est la généralisation au cas continu de la somme de deux v.a. discrètes a valeur dans  $\mathbb{Z}$  avec le produit de convolution discret. En effet, si  $Z$  vaut  $z$  alors  $X$  et  $Y$  peuvent valoir  $z-x$  et  $x$  pour tout  $x$ , et par indépendance

$$P(X = z-x, Y = x) = P(X = z-x)P(Y = x)$$

## TLC pour variables centrées réduites.

$X_i$  une suite de v.a. i.i.d. de moyenne  $m$  et de variance  $\sigma^2 > 0$ , sans perte de généralité on peut supposer que  $m = 0$  et  $\sigma = 1$ , simplement en remplaçant  $X_i$  par la variable centrée réduite  $\frac{X_i - m}{\sigma}$ , ce qui simplifie l'énoncé du TLC.

### **Théorème:**

Soit  $X_n$  une suite de v.a. i.i.d. de moyenne  $m = 0$  et de variance  $\sigma^2 = 1$ ,.  
Alors

$$\frac{\sum_{i=1}^n X_i}{\sqrt{n}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1)$$

# Comprendre le TLC

$X_i$  une suite de v.a. i.i.d. de loi  $\mathcal{N}(m, \sigma^2)$ .

- Quelle est la loi de  $\frac{X_i - m}{\sigma}$  ?  $\rightarrow \mathcal{N}(0, 1)$
- Quelle est la loi de  $X_i + X_j$  ?

# Comprendre le TLC

Loi de  $X_i + X_j$ :

$$\begin{aligned} p_{X_i+X_j}(y) &= \frac{1}{2\pi} \int e^{-x^2/2} e^{-(y-x)^2/2} dx \text{ convolution} \\ &= \frac{1}{2\pi} \int e^{-(2x^2-2xy+y^2)/2} dx \\ &= \frac{e^{-y^2/4}}{2\pi} \int e^{-(x^2-xy+(y/2)^2)} dx \\ &= \frac{e^{-y^2/4}}{2\pi} \int e^{-(x-y/2)^2} dx \\ &= \frac{1}{\sqrt{2\pi}\sqrt{2}} e^{-y^2/2(\sqrt{2}^2)}, \text{ chgt var. } z = x - y/2 \\ &= p_{\mathcal{N}(0,2)}(y) \end{aligned}$$

Exercice:  $X \sim \mathcal{N}(m_1, \sigma_1^2)$ ,  $Y \sim \mathcal{N}(m_2, \sigma_2^2)$ ,  $X$  et  $Y$  indépendantes. Loi de  $X + Y$  ?

# Comprendre le TLC

$X_i$  une suite de v.a. i.i.d. de loi  $\mathcal{N}(m, \sigma^2)$ .

- Quelle est la loi de  $\frac{X_i - m}{\sigma}$  ?  $\rightarrow \mathcal{N}(0, 1)$
- Quelle est la loi de  $X_i + X_j$  ?  $\rightarrow \mathcal{N}(0, 2)$ .
- Quelle est la loi de  $\sum_{i=1}^n X_i$  ?  $\rightarrow \mathcal{N}(0, n)$
- Quelle est la loi de  $\frac{\sum_{i=1}^n X_i}{\sqrt{n}}$  ?  $\rightarrow \mathcal{N}(0, 1)$

Les v.a. Gaussiennes vérifient exactement le TLC des  $n = 1$  (!!).

# Comprendre le TLC

Soient l'ensemble et la fonctionnelle

$$\mathcal{P}_{\text{cr}} = \{p : \mathbb{R} \rightarrow \mathbb{R}^+, \int p = 1, \int xp(x)dx = 0, \int x^2 p(x)dx = 1\}$$

$$\mathcal{F}_n : (p : \mathbb{R} \rightarrow \mathbb{R}) \mapsto \left(\frac{p^{*n}}{\sqrt{n}} : \mathbb{R} \rightarrow \mathbb{R}\right) \text{ p convolé } n \text{ fois ac p div par } \sqrt{n}$$

- Quelle est la structure de  $\mathcal{P}_{\text{cr}}$  ? Espace fonctionnel stable par combinaison convexe.
- Comment interprétez vous cet ensemble ? Densités des v.a. centrées réduites.
- $\mathcal{F}$  est elle définie et a valeur  $\mathcal{P}_{\text{cr}}$  ? Oui
- Quelle est l'interprétation de  $\mathcal{F}_n(p)$ ? Densité de  $\sum_i X_i/\sqrt{n}$ ,  $X_i \sim p$
- La densité de la loi  $\mathcal{N}(0, 1)$  présente une propriété particulière pour  $\mathcal{F}_n$  quelle est-elle ? C'est un point fixe de  $\mathcal{F}_n \forall n$ .
- Que nous dit le TLC sur  $\lim_n \mathcal{F}_n(p)$  ? Ca converge vers la densité de la loi  $\mathcal{N}(0, 1)$ , point fixe. Le TLC est un sorte de Thm de point fixe.

# Tests d'hypothèses

## But

Contredire/confirmer une affirmation concernant un phénomène aléatoire étudié en se fondant sur l'observation de données.

Exemples:

- On veut savoir si une pièce de monnaie est équilibrée ou non à partir d'une série de 500 lancers.
- On veut savoir si un traitement médical rallonge la durée de vie des patients
- On veut savoir si un nouveau procédé accélère la fabrication industrielle d'un objet.

# Tests d'hypothèses

## Les hypothèses

Dans un test d'hypothèses, on formule deux hypothèses:

- 1 La première hypothèse  $H_0$ , souvent appelée **hypothèse nulle**, affirme que la situation est "normale", que rien n'a évolué. Elle est considérée comme vraie a priori.
  - ▶ Dans l'exemple de la pièce de monnaie,  $H_0$  affirme que la pièce est normale, c'est à dire équilibrée.
  - ▶ Dans l'exemple du traitement médical,  $H_0$  affirme que le traitement médical n'a pas d'effet sur la durée de vie.
- 2 La deuxième hypothèse  $H_1$  est **l'hypothèse de travail** ou **l'hypothèse alternative**. C'est souvent la négation de l'hypothèse nulle  $H_0$ .
  - ▶ Dans l'exemple de la pièce de monnaie, l'hypothèse  $H_1$ , "La pièce de monnaie est déséquilibrée", est l'hypothèse contraire de  $H_0$ .
  - ▶ Dans l'exemple du traitement médical, l'hypothèse  $H_1$  est "Le traitement médical rallonge la durée de vie". Ce n'est pas l'hypothèse contraire, et l'hypothèse "Le traitement médical raccourcit la durée de vie" n'est pas envisagée dans ce cas.

# Tests d'hypothèses

## Les hypothèses

Remarques:

- Un test n'est pas symétrique.  $H_0$  supposée vraie a priori. Par exemple, une pièce de monnaie est supposée équilibrée a vue d'oeil.
- Le rejet de l'hypothèse nulle  $H_0$  doit être basé sur des arguments forts. Ex: obtenir 995 piles sur 2000 lancers a pile ou face n'est pas particulièrement surprenant si la pièce est équilibrée, ça ne doit pas conduire a conclure a rejeter  $H_0$ .

# Tests d'hypothèses

## Modélisation probabiliste et choix de la statistique de test

On modélise le phénomène aléatoire en supposant l'hypothèse nulle  $H_0$  vraie.

- Dans l'exemple de la pièce de monnaie, on modélise le lancer d'une pièce dans le cas où elle est équilibrée, c.a.d. par une Bernoulli  $X_i$  de paramètre  $p = 0.5$ .

On choisit la statistique de test  $Z$ : grandeur calculée à partir de l'échantillon qui permet de prendre la décision. On doit connaître la loi de  $Z$ .

- Dans l'exemple de la pièce de monnaie, on calcule  $Z$  le nombre de piles sur  $n$  lancers, ce nombre suit une loi Binomiale de paramètre  $(n, 1/2)$ . On peut également choisir comme statistique de test l'écart à la moyenne  $Z' = |Z - \frac{n}{2}|$ .
- Dans l'exemple de l'essai médical, la statistique  $Z$  peut-être la moyenne des durées de vies des patients.

# Tests d'hypothèses

## Le niveau d'erreur du test

On se donne une marge d'erreur  $\alpha$  qui correspond à la probabilité de se tromper.

- En général,  $\alpha = 5\%$  ou  $\alpha = 1\%$ .
- Plus on a "confiance" en l'hypothèse  $H_0$  (ou bien plus l'hypothèse  $H_1$  est surprenante), plus on doit choisir une petite valeur pour  $\alpha$ .

# Tests d'hypothèses

## La p-valeur

**La p-valeur est la probabilité sous l'hypothèse  $H_0$  que la statistique de test  $Z$  prenne une valeur au moins aussi extrême que la valeur observée, compte tenu de l'hypothèse  $H_1$ .**

Le calcul de la p-valeur dépend de l'hypothèse  $H_1$ .

- Pour la pièce de monnaie, si l'hypothèse  $H_1$  est "la pièce est déséquilibrée en défaveur du cote pile", et que la statistique de test  $Z$  est la somme des piles, p-valeur est

$$p = P(Z \leq z_{\text{obs}})$$

ou  $z_{\text{obs}}$  est la valeur de  $Z$  l'on observe. Si on observe 933 piles sur les 2000 lancers, la p-valeur est

$$p = P(Z \leq 933)$$

# Tests d'hypothèses

## La p-valeur

**La p-valeur est la probabilité sous l'hypothèse  $H_0$  que la statistique de test  $Z$  prenne une valeur au moins aussi extrême que la valeur observée, compte tenu de l'hypothèse  $H_1$ .**

Le calcul de la p-valeur dépend de l'hypothèse  $H_1$ .

- Si l'hypothèse  $H_1$  est "la pièce est déséquilibrée", et que la statistique de test est  $Z' = |Z - 1000|$ , la p-valeur est

$$p = P(Z' \geq z'_{\text{obs}})$$

ou  $z'_{\text{obs}}$  est la valeur de  $Z'$  l'on observe. Si on observe 933 piles sur les 2000 lancers, la p-valeur est

$$p = P(Z' \geq 67) = P(Z \leq 933) + P(Z \geq 1067)$$

# Tests d'hypothèses

- La p-valeur mesure le caractère exceptionnel des données observées si l'on suppose que  $H_0$  est vraie : si la p-valeur est très petite, il est très peu probable d'obtenir une valeur plus extrême que ce qu'on observe. La statistique de test observée est peu probable.
- Le calcul de la p-valeur fait intervenir la loi de  $Z$  que l'on doit être capable de calculer, et les données observées via le calcul de  $z_{\text{obs}}$ .

## Décision

- Si la p-valeur est plus petite que le niveau  $\alpha$  fixé **au préalable**, on rejette  $H_0$ ,  $H_1$  est supposée vraie.
- Si la p-valeur est plus grande que le niveau  $\alpha$  fixé **au préalable**, on accepte  $H_0$ .

# Tests d'hypothèses

## Petite règle empirique sur les p-valeurs

Plus la p-valeur est petite, plus le résultat est significatif.

- Une p-valeur  $< 0.001$  signifie que le test sera extrêmement significatif.
- Une p-valeur entre 0.001 et 0.01 signifie que le test sera très significatif.
- Une p-valeur entre 0.01 et 0.05 signifie que le test significatif.
- Une p-valeur supérieure 0.05 conduit à accepter  $H_0$  si  $\alpha = 0.05$ .

# Tests d'hypothèses

## Mise en oeuvre d'un test d'hypothèses

- 1 Choix des hypothèses  $H_0$  et  $H_1$ .
- 2 Modélisation du phénomène aléatoire et détermination de la statistique de test  $Z$ .
- 3 Calcul de la valeur observée  $z_{\text{obs}}$  et calcul la p-valeur  $p$ .
- 4 Décision par comparaison de  $p$  à  $\alpha$  (et commentaire).

# Tests d'hypothèses pour la pièce de monnaie

On désire savoir si une pièce de monnaie est équilibrée.

On effectue 2000 lancers et on obtient 933 piles et 1067 faces.

Soupçonnant un déséquilibre, on souhaite effectuer un test d'hypothèse de niveau  $\alpha = 1\%$ .

# Tests d'hypothèses pour la pièce de monnaie

- 1 **Hypothèses:**  $H_0$ : La pièce est équilibrée,  $H_1$ : La pièce est déséquilibrée en défaveur du pile
- 2 **Modélisation:** on modélise les lancers par des v.a. de Bernoulli  $X_i$  **indépendantes** de paramètre  $p = 1/2$ .  
**Statistique de test:**  $Z = \sum_{i=1}^n X_i$  suit une loi  $\mathcal{B}(2000, 1/2)$ .
- 3 **p-valeur:** On observe  $z_{\text{obs}} = 933$ . Vues  $H_0$  et  $H_1$ , une valeur  $Z$  sera plus extrême si  $Z \leq 933$ :

$$p = P(Z \leq 933) = \sum_{k=0}^{933} \binom{2000}{k} 0.5^{2000} = 0.00146$$

- 4 **Décision:**  $p \leq \alpha = 1\%$ . On rejette  $H_0$ , la pièce est déséquilibrée en faveur du pile. Le test est très significatif compte tenu de la p-valeur.

# Tests d'hypothèses pour la pièce de monnaie

- 1 **Hypothèses:**  $H_0$ : La pièce est équilibrée,  $H_1$ : La pièce est déséquilibrée.
- 2 **Modélisation:** lancers v.a. de Bernoulli  $X_i$  indép. de paramètre  $p = 1/2$ .  
**Statistique de test:**  $Z = \sum_{i=1}^n X_i$  suit une loi  $\mathcal{B}(2000, 1/2)$ .
- 3 **p-valeur:** On observe  $z_{\text{obs}} = 933$ . Vues  $H_0$  et  $H_1$ , une valeur  $Z$  sera plus extrême si  $Z \leq 933$  ou si  $Z \geq 1067$ :

$$\begin{aligned} p &= P(Z \leq 933) + P(Z \geq 1067) = 1 - P(933 < Z < 1067) \\ &= 1 - \sum_{k=934}^{1066} \binom{2000}{k} 0.5^{2000} = 0.293\% \end{aligned}$$

- 4 **Décision:**  $p \leq \alpha = 0.01$ . On rejette  $H_0$ , la pièce est déséquilibrée en faveur du pile. Le test est très significatif compte tenu de la p-valeur.

## Tests d'hypothèses pour un temps de moyen

Un ouvrier spécialisé passe un temps variable sur chaque pièce. Le temps moyen est de  $m = 270$  secondes et l'écart-type est de  $\sigma = 24$  secondes. Une modification technique du montage est proposée pour diminuer ce temps moyen. Pour le tester, on chronomètre  $n = 50$  montages avec la modification technique et on obtient une moyenne empirique  $M_n = 266$ .

Proposer un test d'hypothèse de niveau  $\alpha = 0.05$  pour savoir si le temps moyen  $m'$  avec le nouveau procédé est inférieur au temps moyen  $m$  actuel.

# Test d'hypothèse pour un temps moyen

Données:  $m = 270$  s,  $\sigma = 24$  s,  $n = 50$  et  $M_n = 266$  s.

① **Hypothèses:**  $H_0$ : le temps moyen ne change pas :  $m' = m$ ,  $H_1$ : Le temps moyen diminue  $m' < m$ .

② **Modélisation:** Les temps de montage  $T_i$  de chaque pièce sont des v.a. indépendantes, de même loi (moyenne  $m$ , écart-type  $\sigma$ ) .

**Statistique de test:**  $Z = \frac{\sqrt{n}(M_n - m)}{\sigma}$  qui suit une loi normale  $\mathcal{N}(0, 1)$  par le TLC.

③ **p-valeur:** On observe  $z_{\text{obs}} = -1.18$ . Vues  $H_0$  et  $H_1$ ,  $Z$  sera plus extrême que  $z_{\text{obs}}$  si  $Z \leq -1.18$ .

$$P(Z \leq -1.18) = F_{\mathcal{N}(0,1)}(-1.18) = 11.9\%$$

④ **Décision:**  $p \geq \alpha = 1\%$ . On accepte  $H_0$ . La différence n'est pas *statistiquement significative*.

## Asymétrie du test d'hypothèse

Un test d'hypothèses est asymétrique car on part du principe que  $H_0$  est vraie. On ne s'est servi nulle part de l'écart-type  $\Sigma_n$  de la nouvelle technique de temps de montage.

On a  $\sigma_n = 10$  secondes. Tester l'hypothèse  $m' = m$  en supposant  $H_1$  vraie, donc en utilisant les valeurs  $M_n = 266$  et  $\sigma_n = 10$  pour la statistique de test, avec et le même niveau  $\alpha = 0.05$ .

- 1 **Hypothèses:**  $H_0 : m = m'$  et  $H_1 : m > m'$ .
- 2 **Modélisation:** Statistique de test  $Z = \frac{\sqrt{n}(m - M_n)}{\Sigma_n}$  qui suit une loi normale  $\mathcal{N}(0, 1)$  par le TLC.
- 3 **p-valeur:** On observe  $z_{\text{obs}} = 2.83$ . Vues  $H_0$  et  $H_1$ ,  $Z$  sera plus extrême que  $z_{\text{obs}}$  si  $Z \geq 2.83$ .

$$\begin{aligned}P(Z \geq 2.83) &= 1 - P(Z < 2.83) \\ &= 1 - F_{\mathcal{N}(0,1)}(2.83) \\ &= 0.233\%\end{aligned}$$

# Asymétrie du test d'hypothèse

Tester l'hypothèse  $m' = m$  en prenant  $M_n$  et  $\Sigma_n$  comme valeurs de référence. Rappel:  $m = 270$  s et  $n = 50$ .

- 4 **Décision:**  $p \leq \alpha = 1\%$ . On rejette  $H_0$  dans ce cas, et la différence est *statistiquement très significative*.

Illustration concrète de l'asymétrie : avec  $H_0$  comme référence, on confirme  $H_0$  tandis qu'avec  $H_1$ , on rejette  $H_0$  et la p-valeur (0.2%) est 50 fois plus petite qu'en prenant  $H_0$  comme référence (10%).

## Dépendance en $n$ du test d'hypothèse.

Pour savoir précisément, on réitère l'expérience de la pièce  $n = 4000$  fois, et on obtient la même moyenne empirique  $M_n = 266$  s. Que nous donne le test d'hypothèse classique (en supposant  $H_0$  vraie) avec ces valeurs ?

Rappel:  $m = 270$  s,  $\sigma = 24$  s.

① **Hypothèses**  $H_0$ :  $m' = m$ ,  $H_1$ :  $m' < m$ .

② **Modélisation**: idem.

Statistique de test  $Z = \frac{\sqrt{n}(M_n - m)}{\sigma}$  qui suit une loi normale  $\mathcal{N}(0, 1)$  par le TLC.

③ **p-valeur**: On observe  $z_{\text{obs}} = \frac{-4\sqrt{4000}}{24} = -10.55$ . Vues  $H_0$  et  $H_1$ ,  $Z$  sera plus extrême que  $z_{\text{obs}}$  si  $Z \leq -10.54$ .

$$P(Z < -10.54) = -2.82 \cdot 10^{-26}\%$$

④ **Décision**:  $p \ll \alpha = 1\%$ . On rejette  $H_0$  dans ce cas, et la différence est *statistiquement extrêmement significative*.

## Dépendance en $n$ du test d'hypothèse.

### Remarques:

- Quand on change un procédé de montage, il est extrêmement probable que le temps de montage moyen ne soit pas exactement le même, c'est à dire que  $H_0$  soit fausse.
- Même si la nouvelle moyenne est très proche de l'ancienne, avec  $n$  assez grand, la nouvelle moyenne aura converge vers sa valeur. Le TLC nous donnera toujours une très petite p-valeur si  $\sqrt{n}$  est assez grand.
- On a le même principe sur l'effet moyen d'un médicament ou d'une substance chimique.

# Tests d'hypothèses

## Autre possibilité de mise en oeuvre

- 1 Choix des hypothèses  $H_0$  et  $H_1$ .
- 2 Modélisation du phénomène aléatoire et détermination de la statistique de test  $Z$ .
- 3 On fixe la p-valeur  $p = \alpha$  et on calcule le  $z_\alpha$  correspondant.
- 4 Calcul de  $z_{\text{obs}}$ . Décision par comparaison  $z_{\text{obs}}$  a  $z_\alpha$  (et commentaire).

### Remarques:

- Avantage: on fait le calcul de  $z_\alpha$  une fois pour toutes.
- Inconvénient: il faut calculer la p-valeur  $p$  pour connaître la "force" du résultat.

# Tests d'hypothèses pour un temps de vie sans vieillissement

Selon le fabricant, la durée de vie des ampoules suit une loi exponentielle et la durée de vie moyenne des ampoules est de 4 ans.

J'ai acheté une ampoule qui a grillé au bout de 1 mois et 28 jours (= 59 jours).

- Avec une probabilité de me tromper de 1%, puis-je faire une réclamation au fabricant pour ampoule défectueuse ?
- Et avec une probabilité de me tromper de 5% ?

Essayer les deux mises en oeuvre: par calcul de la p-valeur et par calcul de  $Z_\alpha$ .

Rappel: une v.a.  $X$  de loi exponentielle est a valeur dans  $\mathbb{R}^+$  et a pour densité de probabilité  $f(x) = \lambda \exp(-\lambda x)$  et  $\mathbb{E}(X) = 1/\lambda$ .

# Tests d'hypothèses pour un temps de vie sans vieillissement

Par calcul de la p-valeur  $p$ :

- 1 **Hypothèses**  $H_0$ : L'ampoule est conforme (elle suit une loi exponentielle de moyenne 4 ans  $\lambda = 0.25$ )  $H_1$ : L'ampoule est défectueuse.
- 2 **Modélisation**: donnée.  
**Statistique de test**:  $Z$  temps de vie de l'ampoule.
- 3 **p-valeur**: On observe  $z_{\text{obs}} = 59j = 0.161\text{an}$ . Vues  $H_0$  et  $H_1$ , une valeur  $Z$  sera plus extrême si  $Z \leq 0.161$ :

$$p = P(Z \leq 0.161) = 3.95\%$$

- 4 **Décision** :
  - ▶  $\alpha = 0.01$ ,  $p > \alpha$ . On ne rejette pas  $H_0$ .
  - ▶  $\alpha = 0.05$ ,  $p \leq \alpha$ . On rejette  $H_0$ .

# Tests d'hypothèses pour un temps de vie sans vieillissement

Par calcul de  $z_\alpha$ :

- 1 **Hypothèses**  $H_0$ : L'ampoule est conforme (elle suit une loi exponentielle de moyenne 4 ans  $\lambda = 0.25$ )  $H_1$ : L'ampoule est défectueuse.
- 2 **Modélisation**: donnée.  
**Statistique de test**:  $Z$  temps de vie de l'ampoule.
- 3 **Calcul de  $z_\alpha$** :

$$P(Z \leq z_\alpha) = \alpha \iff Z \leq -4 \log(1 - \alpha)$$

- ▶  $\alpha = 0.01$ ,  $z_\alpha = 0.040 = 14j \leq z_{\text{obs}}$ . On ne rejette pas  $H_0$ .
- ▶  $\alpha = 0.05$ ,  $z_\alpha = 0.205 = 73j > z_{\text{obs}}$ . On rejette  $H_0$ .

## Loi multinomiale

Une loi **binomiale** modélise le comptage des valeurs dans une expérience a **deux** possibilités (ex. pile ou face) répétée  $n$  fois. Si on connaît le nombre de piles  $n_1$  et la probabilité  $p$  d'avoir pile, le nombre de face est  $n - n_1$  et la probabilité d'avoir face est  $1 - p$ .

Une loi **multinomiale** modélise le comptage des valeurs dans une expérience a  $d$  possibilités. Comme il y a plus de 2 valeurs, c'est la loi d'un vecteur aléatoire  $M$ . Dans l'exemple d'un dé non pipé à 6 faces lancé 30 fois obtenant 3 faces un, 4 faces 2, 6 faces 3, 7 faces quatre, 6 faces cinq et 4 faces 6, le vecteur aléatoire de comptage vaut

$$M = (M^1, M^2, M^3, M^4, M^5, M^6) = (3, 4, 6, 7, 6, 4)$$

Ce vecteur aléatoire suit une loi multinomiale de paramètre  $n = 30$  et  $\pi = (1/6, 1/6, 1/6, 1/6, 1/6, 1/6)$  On peut écrire formellement la loi d'une multinomiale en fonction de  $\pi$ .

## Loi multinomiale

Une v.a.  $B$  de loi **binomiale**  $\mathcal{B}(n, p)$  compte les occurrences de 1 de v.a. de Bernoulli a **deux** valeurs quand on fait  $n$  lancers indépendants. Classiquement on écrit sa loi

$$\mathbb{P}(B = k) = \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k}$$

On peut la reecrite en definissant  $B_0$  qui compte les occurences de 0 et  $B_1 (= B)$  qui compte les occurences de 1. On a

$$B^1 + B^2 = n$$

On définit également les probabilités  $p_0 = 1 - p$  et  $p_1 = p$  d'avoir 0 ou 1. On a

$$\mathbb{P}((B^0, B^1) = (n_0, n_1)) = \frac{n!}{n_0!n_1!} p_0^{n_0} p_1^{n_1}, \quad n_0 + n_1 = n$$

# Loi multinomiale

La loi multinomiale s'écrit par généralisation de cette écriture avec le paramètre  $\pi = (\pi_1, \dots, \pi_d)$  et  $n$ :

$$\mathbb{P}((M^1, \dots, M^d) = (n_1, \dots, n_d)) = \frac{n!}{n_1! \dots n_d!} \pi_1^{n_1} \dots \pi_d^{n_d}, \quad n_1 + \dots + n_d = n$$

- Il faut bien entendu que  $\pi_k \geq 0$  et  $\sum_{k=1}^d \pi_k = 1$
- Cette écriture est un fastidieuse mais bien pratique pour les calculs.

## Test d'hypothèse pour une loi multinomiale

On a vu le test d'hypothèse pour la pièce de monnaie (loi binomiale). Comment le généraliser pour le dé équilibré à 6 faces, ou à  $d$  faces (loi multinomiale  $M = (M^1, \dots, M^d)$  avec  $n$  lancers ?

Les variables aléatoires  $M^i$ ,  $i = 1 \dots d$  comptent les occurrences de chacune des faces. Elle suivent une loi binomiale de paramètres  $n$  et  $p_i = 1/d$  dans le cas équilibré, ou  $p_i = \pi_i$  dans le cas général. On peut les tester séparément.

- Cela oblige à faire  $d$  tests. On aimerait en faire un.
- il suffit que le test soit négatif pour une seule des binomiales  $B^i$  pour invalider l'hypothèse.
- les  $B_i$  ne sont pas indépendances car leur somme vaut  $n$  le nombre de lancers

Que faire ? Un test de  $\chi^2$ .

## Loi $\chi_d^2$

### Définition

Une variable aléatoire  $X$  suit une loi  $\chi_d^2$  (prononcer "qui deux") à  $d$  degrés de liberté si elle suit la même loi que la somme de  $d$  carrés des variables aléatoires  $N_i$  normales  $\mathcal{N}(0, 1)$  indépendantes.

De plus  $\mathbb{E}(X) = \sum_{i=1}^d \text{Var}(N_i) = d$ .


### Propriété

Une variable aléatoire  $X$  suit une loi  $\chi_d^2$  à  $d$  degrés de liberté admet la densité de probabilité

$$f_d(x) = \frac{1}{2^{d/2}\Gamma(d/2)} x^{d/2-1} e^{-x/2}$$

# Densité de loi $\chi_d^2$


Python: `scipy.stats.chi2.pdf`



# Fonction de répartition de loi $\chi^2$

Python: `scipy.stats.chi2.cdf`

Fonctions de repartition des lois de Chi 2 a d degrés de liberté



# Propriété sur les lois multinomiales

## Propriété

Soit  $M = (M^1, \dots, M^d)$  un vecteur aléatoire de loi multinomiale de paramètres  $n$  et  $\pi = (\pi_1, \dots, \pi_d)$ . La variable aléatoire

$$Z = \sum_{k=1}^d \frac{(M^k - n\pi_k)^2}{n\pi_k}$$

converge en loi vers une v.a. de loi  $\chi^2$  à  $d - 1$  degrés de libertés quand  $n$  tend vers l'infini.

$$\sum_{k=1}^d \frac{(M^k - n\pi_k)^2}{n\pi_k} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \chi_{d-1}^2$$

# Propriété sur les lois multinomiales

Remarques:

- $M^k$  est le nombre qu'on observe  $n_{\text{obs}}^k$  pour la valeur  $k$ .  $n\pi_k$  est le nombre moyen  $n_{\text{moy}}^k$  pour la valeur  $k$  (l'espérance).  $Z$  s'écrit alors

$$Z = \sum_{k=1}^d \frac{(n_{\text{obs}}^k - n_{\text{moy}}^k)^2}{n_{\text{moy}}^k}$$

- Cela nous donne une statistique de test  $Z$  idéale pour un test d'hypothèse: elle se calcule directement et on connaît sa loi.
- Moyen mémotechnique pour les  $d - 1$  degrés de liberté du  $\chi^2$ : la contrainte  $\sum_k \pi_k = 1$  fait que  $\pi$  a  $d - 1$  degrés de liberté.
- Attention: les termes de la somme ne sont pas le carré des v.a. qui interviennent dans le TLC appliqué aux lois binomiales  $M_k$  séparément :

$$\left( \frac{M^k - n\pi_k}{\sqrt{n\pi_k(1 - \pi_k)}} \right)^2 \neq \frac{(M^k - n\pi_k)^2}{n\pi_k}$$

## Propriété sur les lois multinomiales

**Preuve** pour  $d=2$ :

Par définition,

$$Z = \frac{(M^1 - n\pi_1)^2}{n\pi_1} + \frac{(M^2 - n\pi_2)^2}{n\pi_2}$$

En utilisant le fait que  $M^1 + M^2 = n$  et  $\pi_2 = 1 - \pi_1$ , on a

$$\begin{aligned} Z &= \frac{(M^1 - n\pi_1)^2}{n\pi_1} + \frac{(n - M^1 - n(1 - \pi_1))^2}{n(1 - \pi_1)} \\ &= \frac{(M^1 - n\pi_1)^2}{n\pi_1} + \frac{(M^1 - n\pi_2)^2}{n(1 - \pi_1)} \\ &= \frac{(M^1 - n\pi_1)^2}{n} \left( \frac{1}{\pi_1} + \frac{1}{1 - \pi_1} \right) \\ &= \left( \frac{M^1 - n\pi_1}{\sqrt{n\pi_1(1 - \pi_1)}} \right)^2 \end{aligned}$$

## Propriété sur les lois multinomiales

$$Z = \left( \frac{M^1 - n\pi_1}{\sqrt{n\pi_1(1 - \pi_1)}} \right)^2$$

On reconnaît le carré de la loi  $\frac{M^1 - n\pi_1}{\sqrt{n\pi_1(1 - \pi_1)}}$  qui suit une loi  $\mathcal{N}(0, 1)$  quand  $n \rightarrow \infty$  d'après le TLC pour la v.a.  $M^1$  de loi binomiale  $\mathcal{B}(n, \pi_1)$ .  
La v.a.  $Z$  suit donc la même loi que le carré d'une v.a. de loi  $\mathcal{N}(0, 1)$ , ce qui est par définition une loi  $\chi_1^2$ , et  $d = 2$ .

La preuve dans le cas général  $d \geq 3$  est un peu plus technique.

## Test d'adéquation du $\chi^2$ pour une loi multinomiale

On effectue 60 lancers de dé et on obtient pour les valeurs 1 à 6 (7, 8, 12, 15, 10, 8). Peut-on dire que le dé est-il équilibré avec  $\alpha = 1\%$ ?

- $H_0$ : Le dé est équilibré.  $H_1$ : le dé n'est pas équilibré.
- Sous  $H_0$ , le comptage des valeurs suit une loi multinomiale de paramètre  $(1/6, \dots, 1/6)$ .

**Statistique de test:**

$$Z = \frac{(7 - 10)^2}{10} + \frac{(8 - 10)^2}{10} + \frac{(12 - 10)^2}{10} \\ + \frac{(15 - 10)^2}{10} + \frac{(10 - 10)^2}{10} + \frac{(8 - 10)^2}{10}$$

suit une loi  $\chi^2_5$ .

## Test d'adéquation du $\chi^2$ pour une loi multinomiale

On effectue 60 lancers de dé et on obtient pour les valeurs 1 à 6 (7, 8, 12, 15, 10, 8). Le dé est-il équilibré ?

- On observe  $z_{\text{obs}} = 4.6$ . Une valeur est plus extrême si  $Z \geq 4.6$ .

$$p = P(Z \geq 4.6) = 1 - F_{\chi_5^2}(4.6) = 46.6\%$$

- Décision:  $p > 1\%$ : on ne rejette pas  $H_0$ . On a une chance sur deux d'obtenir une valeur plus extrême.

Soit  $M$  une loi multinomiale de paramètre  $n$  et  $\pi = (\pi_1, \dots, \pi_d)$ .

# Test d'adéquation du $\chi^2$ pour une loi multinomiale

Cas général:

On observe  $m = (m^1, \dots, m^d)$  d'une multinomiale  $M$  de paramètre  $n$  connu et  $\pi$  inconnue. On souhaite savoir si cela correspond à une multinomiale de paramètre  $n$  et  $\pi = (p_1, \dots, p_d)$  avec une erreur alpha.

- $H_0: \pi = p$   $H_1: \pi \neq p$ .
- Statistique de test:

$$Z = \sum_{k=1}^d \frac{(M^k - np_k)^2}{np_k} \text{ suit une loi } \chi_{d-1}^2.$$

- Calcul de  $z_{\text{obs}}$  et de la p-valeur

$$z_{\text{obs}} = \sum_{k=1}^d \frac{(m^k - np_k)^2}{np_k}$$
$$p = 1 - F_{\chi_{d-1}^d}(z_{\text{obs}})$$

- on conclut.

# Test d'adéquation du $\chi^2$ pour une loi multinomiale

Exercice python:

- Générer un v.a. de loi multinomiale équilibrée sur  $\{1, \dots, 6\}$  avec  $n = 60$  et faire un test d'adéquation de  $\chi^2$  avec  $\alpha = 0.01$
- Répéter l'opération  $N = 1000$  fois et compter le nombre  $n_r$  de cas qui rejettent  $H_0$ .  
Qu'observe-t-on sur  $n_r$  ?
- Répéter cette expérience en faisant varier  $n$ ,  $N$  et  $\alpha$ .

Fonctions python:

- `np.random.multinomial` pour échantillonner une loi multinomiale.
- `scipy.stats.chisquare` pour faire un test d'adéquation de  $\chi^2$ .

# Test d'adéquation du $\chi^2$

Dans le cas général:

- on n'a pas une loi multinomiale: on s'y ramène en faisant une partition finie de taille  $d$  de l'espace des valeurs. Une règle empirique veut que le nombre moyen d'éléments par partie sous l'hypothèse  $H_0$  soit supérieur ou égal à 5.
- On ne connaît pas systématiquement les paramètres de la loi. Par exemple, si on veut vérifier que des données sont tirées d'une loi normale, on doit souvent estimer la moyenne et la variance. On estime alors ces paramètres. Si on estime  $n_p$  paramètres, le nombre de degrés de liberté dans le test de  $\chi^2$  diminue de  $n_p$ : il passe de  $d - 1$  à  $d - n_p - 1$

## Test d'adéquation du $\chi^2$

Exemple: adéquation à une loi de Poisson.

On veut savoir le nombre de pièce défectueuses par lot de 100 pièces suit une loi de poisson:  $P(X = k) = \exp(-\lambda)\lambda^k/k!$ . On teste  $n = 52$  lots et on trouve les valeurs suivantes:

pièces défectueuses	0	1	2	3	4	5
lots	16	20	8	5	2	1

- On estime  $\hat{\lambda} = \mathbb{E}(X) = 1.23$ .
- On choisit par défaut la partition de  $\mathbb{N}$  la plus naturelle au vu des données et on calcule les effectifs théoriques

$$\{\{0\}, \{1\}, \{2\}, \{3\}, \{4\}, \{5, \dots\}, \}, [15.2, 18.7, 11.5, 4.7, 1.46, 0.44]$$

- On regroupe donc les trois dernières parties pour dépasser 5. On a la partition et effectifs théoriques et observes suivants

$$\{\{0\}, \{1\}, \{2\}, \{3, \dots\}, \}, [15.2, 18.7, 11.5, 6.6], [16, 20, 8, 8]$$

## Test d'adéquation du $\chi^2$

Exemple: adéquation à une loi de Poisson.

On veut savoir le nombre de pièce défectueuses par lot de 100 pièces suit une loi de poisson:  $P(X = k) = \exp(-\lambda)\lambda^k/k!$ . On teste  $n = 52$  lots et on trouve les valeurs suivantes:

pièces défectueuses	0	1	2	3	4	5
lots	16	20	8	5	2	1

- On effectue un test de  $\chi_2$  avec  $4 - 1 - 1 = 2$  degrés de liberté.
- $H_0$  : le nombre de pièces défectueuses par lot suit une loi de Poisson de paramètre  $\hat{\lambda} = 1.23$ ,  $H_1 = \overline{H_0}$ .
- Avec python: `scipy.stats.chisquare([16, 20, 8, 5], [15.187, 18.692, 11.502, 6.617], ddof=1)`

$$Z = 1.49, p = 47\%$$

- Décision: on accepte l'hypothèse  $H_0$ .

## Test d'adéquation du $\chi^2$

Exercice: adéquation à une loi Normale.

On veut savoir si le rendement  $X$  (quintaux par hectares d'une parcelle de blé) suit une loi normale  $\mathcal{N}(m, \sigma^2)$ . L'observation du rendement de 1000 parcelles a donné les résultats suivants :

rendement	0-10	10-20	20-30	30-40	40-50	50-60	60-70
parcelles	5	6	40	168	288	277	165
rendement	70-80	80-90	Total				
parcelles	49	2	1000				

Effectuer un test d'adéquation du  $\chi^2$ .

## Test d'indépendance du $\chi^2$

On étudie deux caractères sur une population et on veut tester si ces caractères sont statistiquement indépendants. On suppose ces caractères qualitatifs, c'est à dire qu'ils ne correspondent pas à une quantité et qu'on ne peut pas les comparer entre eux.

Ce peut être, par exemple, la couleur des yeux et la couleur des cheveux.

Supposons que le premier caractère  $X$  prenne  $r$  valeurs  $x_i$  (ex: les yeux bleu, vert, marron, noir) et que le deuxième caractère  $Y$  prenne  $s$  valeurs  $y_j$  (ex: cheveux blonds, bruns, châains, roux, gris, blancs). L'hypothèse  $H_0$ , "les caractères sont indépendants" donne  $\forall 1 \leq i \leq r, 1 \leq j \leq s$

$$P(X = x_i, Y = y_j) = P(X = x_i)P(Y = y_j)$$

# Test d'indépendance du $\chi^2$

## Méthode

- on calcule  $\hat{p}_{x_i}$  et  $\hat{p}_{y_j}$  estimations des probabilités  $P(X = x_i)$  et  $P(Y = y_j)$ , ( $r - 1 + s - 1$  estimations au total).
- On se ramène au test d'adéquation du  $\chi^2$  avec une loi multinomiale. Au total, il y a  $r \times s$  valeurs ( $X = x_i, Y = y_j$ ).
- Sous  $H_0$ , les valeurs théoriques sont

$$P(X = x_i, Y = y_j) = \hat{p}_{x_i} \hat{p}_{y_j}$$

- Lorsqu'on travaille sur  $r \times s$  valeurs, il y a  $r \times s - 1$  degrés de liberté dans le  $\chi^2$ . Comme on a estimé  $r - 1 + s - 1$  paramètres, il y en a

$$rs - 1 - (r - 1 + s - 1) = (r - 1)(s - 1).$$

## Test d'indépendance du $\chi^2$

Si on note  $n_{\text{moy}}^{i,j} = n\hat{p}_{x_i}\hat{p}_{y_j}$  l'effectif théorique moyen de  $(x_i, y_j)$ , et  $n_{\text{obs}}^{i,j}$  l'effectif observé de  $(x_i, y_j)$ , la statistique de test est

$$Z = \sum_{i,j} \frac{(n_{\text{obs}}^{i,j} - n_{\text{moy}}^{i,j})^2}{n_{\text{moy}}^{i,j}}$$

et elle suit une loi de  $\chi^2$  avec  $(r-1)(s-1)$  degrés de liberté.

- Si il y a 2 degrés de libertés ou plus, alors on prend la statistique de test  $Z$  définie ci-dessus.
- S'il n'y a qu'un degré de liberté dans le  $\chi^2$ , c.a.d  $(r-1)(s-1) = 1$  soit  $r = 2$  et  $s = 2$ , on applique en général la correction suivante dite de Yates à la statistique  $Z$

$$Z^{\text{yates}} = \sum_{i,j} \frac{(|n_{\text{obs}}^{i,j} - n_{\text{moy}}^{i,j}| - 0.5)^2}{n_{\text{moy}}^{i,j}}$$

# Test d'indépendance du $\chi^2$

## Correction de Yates:

- S'il n'y a qu'un degré de liberté dans le  $\chi^2$ , c.a.d  $(r - 1)(s - 1) = 1$  soit  $r = 2$  et  $s = 2$ , on applique en général la correction suivante dite de Yates à la statistique  $Z$

$$Z^{\text{yates}} = \sum_{i,j} \frac{(|n_{\text{obs}}^{i,j} - n_{\text{moy}}^{i,j}| - 0.5)^2}{n_{\text{moy}}^{i,j}}$$

- [Wikipedia FR sur la correction de Yates](#)
- [Wikipedia EN sur la correction de Yates](#)

# Test d'indépendance du $\chi^2$

## Exemple

Tester l'indépendance du type de film regarde et de la consommation ou non de snack en regardant le film.

Voici la **table de contingence**:

<i>film</i>	snack		total
	oui	non	
action	50	65	125
comédie	125	175	300
familial	90	30	120
horreur	45	10	55
total	310	290	600

Effectuer un test d'indépendance du  $\chi^2$ .

# Test d'indépendance du $\chi^2$

<i>film</i>	snack		total
	oui	non	
action	50	65	125
comédie	125	175	300
familial	90	30	120
horreur	45	10	55
total	310	290	600

Probabilités:

snack	oui	non
P	31 / 60	29 / 60

film	action	comédie	familial	horreur
P	5 / 24	1 / 2	1 / 5	11/120

# Test d'indépendance du $\chi^2$

Effectifs théoriques:

Sous l'hypothèse nulle d'indépendance:  $n_{th} = P(x) \times P(x) \times n$

<i>film</i>	snack		total
	oui	non	
action	65	60	125
comédie	155	145	300
familial	62	58	120
horreur	28	27	55
total	310	290	600

## Test d'indépendance du $\chi^2$

Contribution a la statistique de test:

$$\frac{(n_{\text{obs}} - n_{\text{th}})^2}{n_{\text{th}}}$$

<i>film</i>	snack	
	oui	non
action	3.3	3.5
comédie	5.8	6.2
familial	12.6	13.5
horreur	9.7	10.3

$$Z = 3.3 + 3.5 + 5.8 + 6.2 + 12.6 + 13.5 + 9.7 + 10.3 = 64.9$$

Degrés de liberté:  $(r - 1)(s - 1) = 3$

$$p = 1 - \mathcal{F}_{\chi^2_3}(64.9) = 5.310^{-14}$$

## Test d'indépendance du $\chi^2$

On teste un médicament X destiné à soigner une maladie. On traite des patients avec ce médicament tandis que d'autres reçoivent un placebo. On note dans la variable statut *oui* si les patients ont survécu plus de 48 jours et *non* sinon. Voici le tableau des résultats obtenus:

	statut		total
	oui	non	
médicament	17	29	46
placebo	8	38	46

Faire un test d'indépendance du  $\chi^2$  avec et sans correction de Yates.

## Test d'indépendance du $\chi^2$

Python: `scipy.stats.chi2_contingency`.

```
import scipy.stats  
table = [[17,29],[8,38]]  
scipy.stats.chi2_contingency(table, correction=False)  
→(4.448955223880597, 0.03492260605235841, ...)
```

P-valeur de 3.49%, on rejette  $H_0$  et on conclut à l'efficacité du médicament.

# Test d'indépendance du $\chi^2$

Avec la correction :

```
import scipy.stats
table = [[17,29],[8,38]]
scipy.stats.chi2_contingency(table, correction=True)
→ (3.515223880597015, 0.0608074408980542, ...)
```

P-valeur de 6%. On accepte  $H_0$ . Comme quoi en changeant un seul paramètre dans le test, on change la conclusion.

# Test d'indépendance du $\chi^2$

## Correction de Yates:

difficile de trouver un justification... Peut on proposer une expérience pour en vérifier le bien fonde ?

- Répéter N fois un test de  $\chi^2$  de niveau  $\alpha$  sur deux lois binomiales indépendantes avec des paramètres de votre choix ( $n > 20$ , et  $0 < p < 1$ ) **avec** la correction de Yates.
- Répéter N fois un test de chi2 de niveau  $\alpha$  sur deux lois binomiales indépendantes avec les même paramètres ( $n > 20$ , et  $0 < p < 1$ ) **sans** la correction de Yates.
- Faire varier une ou deux fois les paramètres pour estimer la sensibilité aux paramètres

Python: `scipy.stats.chi2_contingency`.

## Temps d'arrêt dans les tests

Dans un plan d'expérience, on a souvent les résultats qui tombent les uns après les autres. Supposons qu'on ait prévu de faire une expérience sur 100 personnes pour démontrer que l'hypothèse nulle n'est pas vérifiée. En pratique, on effectue les expériences par groupes de 5 personnes, et on commence à calculer une p-valeur à partir de 20 personnes minimum, sans quoi on n'a pas convergence dans le TCL ou le  $\chi^2$ . On peut être tenté de s'arrêter dès que la p-valeur est inférieure au niveau alpha fixé, après avoir fait un minimum de test (30 par exemple) mais avant d'avoir fait les expériences sur les 100 personnes.

- Dans ce cas nos hypothèses sont-elles toujours vérifiées ?
- A-t-on toujours correspondance entre alpha et la fréquence de rejet de l'hypothèse nulle alors qu'elle est vérifiée ?

## Tests d'hypothèse Bayesiens

- Dans les test d'hypothèses que nous avons vus jusqu'ici, nous calculons la p-value, qui est la probabilité d'observer des données au moins aussi extrêmes :

$$P(\text{donnees plus extremes} | H_0)$$

- Dans une démarche scientifique, on émet des hypothèses. Ce qui nous intéresse, c'est de savoir quelle est la probabilité que notre hypothèse soit vraie sachant les données

$$P(H|\text{données}) = \frac{P(\text{données}|H)P(H)}{P(\text{données})}$$

- On calcule les ratios de probabilités (odd-ratios) entre les différentes hypothèses

$$\frac{P(H_1|\text{données})}{P(H_2|\text{données})}$$

## Exemple Tests d'hypothèse Bayesiens

- Un médecin recoit un patient qui tousse.
- Il envisage trois hypothèse pour la maladie: gastro, cancer, covid.
- Au vu de la situationa actuelle, il a les informations suivantes :  
 $P(\text{cancer}) = 0.05\%$ ,  $P(\text{gastro}) = 20\%$ ,  $P(\text{covid}) = 50\%$ .
- De son expérience de médecin, il a les probabilités suivantes:  
 $P(\text{toux}|\text{cancer}) = 95\%$ ,  $P(\text{toux}|\text{gastro}) = 0.3\%$ ,  
 $P(\text{toux}|\text{covid}) = 89\%$ .

Faire un test d'hypothèse Bayésien pour évaluer le ratio entre les différentes probas.

## Exemple Tests d'hypothèse Bayesiens

$$P(H|\text{données}) = \frac{P(\text{données}|H)P(H)}{P(\text{données})}$$

- Hypothèses: 1. gastro, 2. cancer, 3. covid.
- Donnée: toux
- $P(\text{données}|H)$ :  $P(\text{toux}|\text{cancer}) = 95\%$ ,  $P(\text{toux}|\text{gastro}) = 0.3\%$ ,  
 $P(\text{toux}|\text{covid}) = 89\%$
- $1/P(\text{données}) = k$ .
- $P(H)$ :  $P(\text{cancer}) = 0.05\%$ ,  $P(\text{gastro}) = 20\%$ ,  $P(\text{covid}) = 50\%$ .
- $P(\text{cancer}|\text{toux}) = k0.05 \times 0.95 = k0.000475$
- $P(\text{gastro}|\text{toux}) = k0.003 \times 0.2 = k0.0006$
- $P(\text{covid}|\text{toux}) = k0.5 \times 0.89 = k0.445$

## Exemple Tests d'hypothèse Bayesiens

On fait le rapport entre les probabilités (odd-ratio):

- Il y a 936 fois plus de chances que le patient ait le covid que le cancer:

$$\frac{P(\text{covid}|\text{toux})}{P(\text{cancer}|\text{toux})} = 936$$

- Il y a 741 fois plus de chances que le patient ait le covid que la gastro:

$$\frac{P(\text{covid}|\text{toux})}{P(\text{gastro}|\text{toux})} = 741$$

## Exemple Tests d'hypothèse Bayesiens

### Remarques:

- Dans la démarche scientifique, on émet des hypothèses. Ce qui nous intéresse, c'est de savoir quelle est la probabilité que notre hypothèse soit vraie sachant les données, précisément  $P(H|\text{données})$ .
- Ces test sont Bayesiens dans la mesure ou ils utilisent la regle de Bayes

$$P(H|\text{données}) = \frac{P(\text{données}|H)P(H)}{P(\text{données})}$$

- Cela nécessite d'avoir  $P(H)$ , c.a.d une information a priori (prior).
- On peut tester plusieurs hypothèses.
- Ces test sont donc plus précis car ils prennent en compte plus d'information, mais beaucoup moins "généraux" car la structure de l'information a priori dépend du problème.

## Régression linéaire univariée

- La régression linéaire univariée vise à prédire une variable "expliquée"  $y$  comme fonction linéaire (ou affine) d'une variable explicative  $x$ .
- La régression affine unidimensionnelle prédit la variable (aléatoire)  $Y$  avec une fonction affine de la variable (aléatoire)  $X$

$$Y = aX + b$$

- Pour déterminer les paramètres du modèle linéaire (par ex.  $a$  et  $b$ ), il faut choisir une méthode d'estimation. La plus courante est la méthode des moindres carrés:

$$a, b = \operatorname{argmin}_{\alpha, \beta} \mathbb{E} \left( [Y - (\alpha X + \beta)]^2 \right)$$

Il existe d'autres méthodes comme le modèle par maximum de vraisemblance ou l'inférence bayésienne.

# Minimum d'une fonction réelle de deux variables

La fonction

$$f : \mathbb{R}^2 \rightarrow \mathbb{R} \\ (\alpha, \beta) \mapsto \mathbb{E} \left( [Y - (\alpha X + \beta)]^2 \right)$$

est une fonction continue dérivable.

En effet

$$\frac{\partial}{\partial \alpha} \mathbb{E} \left( [Y - (\alpha X + \beta)]^2 \right) = \mathbb{E} \left( \frac{\partial}{\partial \alpha} [Y - (\alpha X + \beta)]^2 \right)$$

- par linéarité de l'espérance
- par convergence dominée pour le passage à la limite

## Minimum d'une fonction réelle de deux variables

**Propriété:** Si  $f : (x, y) \in \mathbb{R}^2 \mapsto f(x, y) \in \mathbb{R}$  une fonction dérivable admet un minimum en  $m = (m_1, m_2)$  alors son gradient s'annule en  $m$

$$\nabla_m f = \left( \frac{\partial f}{\partial x}(m_1, m_2), \frac{\partial f}{\partial y}(m_1, m_2) \right) = (0, 0)$$

Preuve:

Si  $(m_1, m_2)$  est minimum de  $f$  alors  $m_1$  est minimum de  $f_{.,m_2}(x) = f(x, m_2)$  donc la dérivée de  $f_{.,m_2}$  s'annule en  $m_1$  et

$$f'_{.,m_2}(m_1) = \frac{\partial f}{\partial x}(m_1, m_2)$$

# Régression linéaire aux moindres carrés

On cherche à trouver le minimum de

$$f(\alpha, \beta) = \mathbb{E} \left( [Y - (\alpha X + \beta)]^2 \right)$$

Une condition nécessaire est l'annulation du gradient (i.e. des dérivées partielles).

- Quelles sont les dérivées partielles de  $f$  ?
- Que nous donne la condition d'annulation du gradient ?
- Reconnaissez vous un terme connu dans l'expression de  $\alpha$  ?

Aide: Dérivée de  $\alpha \mapsto (K\alpha + L)^2$ :  $\alpha \mapsto 2K^2\alpha + 2KL$ .

# Régression linéaire aux moindres carrés

Dérivées partielles:

$$\frac{\partial f}{\partial \alpha} = \mathbb{E} (2X^2\alpha - 2X(Y + \beta)) = 2\alpha\mathbb{E}(X^2) - 2\mathbb{E}(XY) - 2\beta\mathbb{E}(X)$$

$$\frac{\partial f}{\partial \beta} = \mathbb{E} (2\beta + 2(Y - \alpha X)) = 2\beta - 2\mathbb{E}(Y) + 2\alpha\mathbb{E}(X)$$

## Régression linéaire aux moindres carrés

On a

$$\frac{\partial f}{\partial \alpha} = 2\alpha\mathbb{E}(X^2) - 2\mathbb{E}(XY) - 2\beta\mathbb{E}(X)$$

$$\frac{\partial f}{\partial \beta} = 2\beta - 2\mathbb{E}(Y) + 2\alpha\mathbb{E}(X)$$

Soit  $(a, b)$  minimum de  $f$ . On a nécessairement

$$b = \mathbb{E}(Y) - a\mathbb{E}(X)$$

$$a = \frac{\mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)}{\mathbb{E}(X^2) - E(X)^2} = \frac{\text{cov}(X, Y)}{\text{var}(X)} = \text{corr}(X, Y) \frac{\sigma_Y}{\sigma_X}$$

avec la corrélation de  $X$  et  $Y$  compris entre -1 et +1

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}$$

# Régression linéaire aux moindres carrés

Remarques:

- $b = \mathbb{E}(Y) - a\mathbb{E}(X)$  est un "correcteur de moyenne". Il ajoute la moyenne de  $Y$  et enlève  $a$  fois la moyenne de  $X$  qui vient du terme  $aX$ .
- $a$  correspond de la corrélation entre  $X$  et  $Y$  avec un rescaling de l'écart type
- L'erreur quadratique moyenne vaut

$$\mathbb{E}((Y - (aX + b))^2) = \sigma_Y^2(1 - \text{corr}(X, Y)^2)$$

Si la corrélation est proche de 1 ou -1, l'erreur est quasiment nulle, tandis que la corrélation est proche de 0 l'erreur est maximale,  $a$  est proche de zéro et l'estimation est réduite à la moyenne de  $Y$ .

# Régression linéaire aux moindres carrés

Exercice python:

$X$  v.a. uniforme sur  $[0, 1]$  et  $Y = X + \epsilon U$  ou  $U$  v.a. uniforme sur  $[0,1]$  indépendante de  $X$  .

- 1 Calculer  $\mathbb{E}(X)$  et  $\sigma_X$
- 2 Calculer  $\mathbb{E}(Y)$  et  $\sigma_Y$  en fonction de  $\epsilon$ .
- 3 Calculer  $Cov(X, Y)$ ,  $Corr(X, Y)$  et l'erreur quadratique moyenne théorique en fonction de  $\epsilon$ .
- 4 Choisir  $\epsilon > 0$  et générer avec `np.random.random()` 1000 tirages de  $(X, Y)$ . Estimer  $a$ ,  $b$  et l'erreur quadratique par méthode de Monte-Carlo à partir des données. Comparer aux valeurs théoriques.

# Régression linéaire aux moindres carrés

Exercice python:

$X$  v.a. uniforme sur  $[0, 1]$  et  $Y = X + \epsilon U$  ou  $U$  v.a. uniforme sur  $[0,1]$  indépendante de  $X$  .

- 1  $\mathbb{E}(X) = 0.5$  et  $\sigma_X = 1/\sqrt{12}$
- 2  $\mathbb{E}(Y) = 0.5(1 + \epsilon)$  et  $\sigma_Y = \sqrt{(1 + \epsilon^2)/12}$ .
- 3  $Cov(X, Y) = Var(X)$  ,  $Corr(X, Y) = \sigma_X/\sigma_Y = 1/\sqrt{1 + \epsilon^2}$  et l'erreur quadratique moyenne théorique en fonction de  $\epsilon$ .
- 4  $MSE = \frac{\epsilon^2}{12}$ .

## Régression linéaire multivariée

La régression linéaire multivariée étend la régression linéaire simple pour décrire une variable  $y$  comme combinaison linéaire (affine) de plusieurs variables explicatives  $x_1, \dots, x_D$ , ou bien fonction linéaire (affine) du vecteur  $x = (x_1, \dots, x_D)$ :

$$y = \sum_{d=1}^D a_d x_d + b = \langle a, x \rangle_{\mathbb{R}^d} + b$$

Pour déterminer les paramètres du modèle linéaire (par ex.  $a$  et  $b$ ) à partir d'un échantillon de données  $(x^n, y^n)_{n=1\dots N}$ , on choisit une méthode d'estimation, par exemple la méthode des moindres carrés:

$$a, b = \operatorname{argmin}_{\alpha, \beta} \frac{1}{N} \sum_{n=1}^N \left( y^n - (\langle \alpha, x^n \rangle + \beta) \right)^2$$

# Régression linéaire multivariée

Remarques:

- Dans le cas de la régression univariée, on avait écrit la méthode des moindres carrés comme :

$$a, b = \operatorname{argmin}_{\alpha, \beta} \mathbb{E} \left( [Y - (\alpha X + \beta)]^2 \right)$$

- Dans le cas multi-dimensionnel, on a écrit la méthode des moindres carrés comme

$$a, b = \operatorname{argmin}_{\alpha, \beta} \frac{1}{N} \sum_{n=1}^N \left( y^n - (\langle \alpha, x^n \rangle + \beta) \right)^2$$

- $\frac{\sum_{n=1}^N Z_n}{N}$  est l'estimation par Monte-Carlo de  $\mathbb{E}(Z)$  **si les  $Z_i$  sont i.i.d.**

## Régression linéaire multivariée

On a un échantillon de données  $(x^n, y^n)_{n=1\dots N}$ , et on veut estimer  $a$  et  $b$ .  
On considère la norme usuelle sur  $\mathbb{R}^N$ , les matrices et vecteurs

$$y = \begin{pmatrix} y^1 \\ \vdots \\ y^N \end{pmatrix}, X = \begin{pmatrix} 1 & x_1^1 & \cdots & x_D^1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_1^N & \cdots & x_D^N \end{pmatrix}, a = \begin{pmatrix} b \\ a_1 \\ \vdots \\ a_D \end{pmatrix},$$

- Comment s'écrit la linéaire relation entre les  $y^n$  et les  $x^n$  ?
- Comment s'écrit l'erreur que l'on minimise

$$\frac{1}{N} \sum_{n=1}^N \left( y^n - (\langle a, x^n \rangle + b) \right)^2 \quad ?$$

# Régression linéaire multivariée

$$y = \begin{pmatrix} y^1 \\ \vdots \\ y^N \end{pmatrix}, X = \begin{pmatrix} 1 & x_1^1 & \cdots & x_D^1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_1^N & \cdots & x_D^N \end{pmatrix}, a = \begin{pmatrix} b \\ a_1 \\ \vdots \\ a_D \end{pmatrix},$$

- Relation entre les  $y^n$  et les  $x^n$ :

$$y = Xa$$

- L'erreur que l'on minimise

$$\frac{1}{N} \|y - Xa\|_{2, \mathbb{R}^N}^2 = \frac{1}{N} \langle y - Xa, y - Xa \rangle_{\mathbb{R}^N}$$

# Gradient d'une fonction

Soit  $f : \mathbb{R}^D \mapsto \mathbb{R}$  dérivable.

## Définition dans un système de coordonnées:

- Dans un système de coordonnées (cartésiennes, le gradient d'une fonction  $f(x_1, x_2, \dots, x_D)$  est le vecteur des dérivées partielles  $f$  par rapport aux coordonnées:

$$\nabla_{(x_1, \dots, x_D)} f = \begin{bmatrix} \frac{\partial f}{\partial x_1}(x_1, \dots, x_D) \\ \vdots \\ \frac{\partial f}{\partial x_D}(x_1, \dots, x_D) \end{bmatrix}$$

- Il pointe dans la direction où la fonction croît le plus rapidement, et sa norme correspond au taux de croissance dans cette direction.
- C'est la généralisation à plusieurs variables de la dérivée d'une fonction d'une seule variable.

# Gradient d'une fonction

Soit  $f : \mathbb{R}^D \mapsto \mathbb{R}$  dérivable.

## Définition générale:

Comme  $f$  est différentiable Pour une variation  $h$  autour de  $x$ , la variation de  $f$  est au premier ordre une fonction linéaire de  $h$ :

$$f(x + h) = f(x) + L(h) + o(h)_{\|h\| \rightarrow 0}$$

Le gradient est le représentant de cette forme linéaire tangente:

$$f(x + h) = f(x) + \nabla f \cdot h + o(h)_{\|h\| \rightarrow 0}$$

# Gradient d'une fonction

Soit  $f : \mathbb{R}^N \mapsto \mathbb{R}$  dérivable.

## Propriété:

Si  $f$  admet un minimum en  $m$  alors son gradient s'annule en  $m$

$$\nabla_m f = 0_{\mathbb{R}^N}$$

- Calculer le gradient de

$$f(a) = \frac{1}{N} \|y - Xa\|_{2, \mathbb{R}^N}^2 = \frac{1}{N} \langle y - Xa, y - Xa \rangle_{\mathbb{R}^N}$$

- Que donne la condition d'annulation du gradient ?

# Régression linéaire multivariee

- Gradient de  $f$ :

$$\nabla f = \frac{2}{N} (X^T X a - X^T y)$$

- Condition d'annulation du gradient":

$$a = (X^T X)^{-1} X^T y$$

Notebook python sur les régressions linéaires multivariees.

# Régression linéaire régularisée

Problème: on a suppose que  $X^T X$  est inversible, mais si elle ne l'est pas... En particulier si  $N \neq D$ ,  $\text{rg}(X^T X) = N$ , la matrice n'est pas inversible.

On pose

$$f(a) = \|y - Xa\|^2 + \epsilon \|a\|^2$$

- Gradient de  $f$  ?
- Condition d'annulation du gradient" ?

# Régression linéaire régularisée

On pose

$$f(a) = \|y - Xa\|^2 + \epsilon \|a\|^2$$

- Gradient de  $f$  ?

$$\nabla f = 2(X^T X a - X^T y) + 2\epsilon a$$

- Condition d'annulation du gradient ?

$$a = (X^T X + \epsilon I_N)^{-1} X^T y$$

La matrice  $X^T X + \epsilon I_N$  est toujours inversible.

## Régression linéaire régularisée

Supposons que l'on fasse une régressions affine avec deux données et deux variables explicatives:

$$a_1x_1^1 + a_2x_2^1 + b = y^1$$

$$a_1x_1^2 + a_2x_2^2 + b = y^2$$

$$a_1x_1^3 + a_2x_2^3 + b = y^3$$


- Que peut-on dire de ce système ?
- Que vaudra l'erreur quadratique ?
- Cela vous paraît raisonnable ?
- Qu'est ce qui pourrait résoudre ce problème ?

# Statistiques descriptives

La statistique descriptive est la branche des statistiques qui cherche à décrire et à résumer un ensemble important de données.


- *Les faits sont têtus. Il est plus facile de s'arranger avec les statistiques.* Mark Twain.
- *Faites attention, la statistique est toujours la troisième forme du mensonge.* Jacques Chirac.
- *La mort d'un homme est une tragédie. La mort d'un million d'hommes est une statistique.* Joseph Staline.
- *Les hommes politiques ne connaissent la misère que par les statistiques. On ne pleure pas devant les chiffres.* L'Abbe Pierre.

# Graphiques



## Graphiques


Nombre d'agressions par an de 2001 à 2005




# Graphiques

année	2001	2002	2003	2004	2005
agressions	670	667	672	677	686


## Attention à l'axe !



# Graphiques




## Graphiques






# Graphiques

Evolution des salaires moyens, echelle log




année	2000	2010
salaire moyen ouvriers	1000	1100
salaire moyen cadres	3000	3150

**Attention aux choix d'échelles et de références!**




# Graphiques



distribution des scores au test de logique




# Graphiques



## Distribution $\neq$ répartition !




# Graphiques



Tiré de *Statistiques, méfiez-vous!*, N. Gauvrit, Ed. Ellipses.

# Graphiques



Tiré de *Statistiques, méfiez-vous!*, N. Gauvrit, Ed. Ellipses.

# Pourcentages

- *La dette de la France qui avait augmenté de 10 % l'an passé n'a augmenté que de 9.5 % cette année, se félicite le gouvernement.*
- *La gestion du gouvernement, qui avait déjà du emprunter 200 milliards d'euros l'an dernier, est tellement catastrophique qu'il faudra emprunter cette année 209 milliard d'euros sur les marchés financiers pour payer les dépenses, déplore l'opposition.*
- En combinant les deux informations, quelle était la dette il y a deux ans ? Est-ce plausible ?
- Dette de 2000 milliards, puis 2200 milliards puis 2409 milliards.  
Déficit de 10 % puis 9.5 %.

# Pourcentages

## Le paradoxe de Simpson.

- Une université américaine a fait de la lutte contre les discriminations un objectif phare.
- Apprenant que dans la section littérature, sur une promotion contenant 15 garçons et 15 filles, 6 filles ont réussi l'examen de fin de licence contre 9 garçons. Ils convoquent les responsable pour leur faire part de leurs soupçons.
- Surprise des professeurs, qui chiffrèrent à l'appui, montrent que les garçons réussissent moins bien que les filles !
- Il y a deux groupes : lettres modernes et lettres classiques. Construire un tel paradoxe :

	Filles		Garçons	
	réussite	échecs	réussite	échecs
lettres modernes				
lettres classiques				

# Pourcentages

## Le paradoxe de Simpson.

- Explication:

	Filles		Garçons		
	réussite	échecs	réussite	échecs	total
lettres modernes	1	9	0	5	15
lettres classiques	5	0	9	1	15
total	6	9	9	6	15

- Pourcentage de réussite:

	Filles	Garçons
lettres modernes	11%	0 %
lettres classiques	100 %	90%

	Filles	Garçons
lettres	40%	60%

## Statistiques: erreurs, choix, faux et cadre.

- Erreur de données: exemple de la mortalité infantile en Espagne.
- Choix dans les statistiques: classement de l'immobilier comme dépense d'investissement.
- Faux: Lancet Gate 1, 2.

Cadrage: En psychologie du raisonnement et de la décision ainsi qu'en psychologie sociale, le cadrage est l'action de présenter un *cadre cognitif* comme approprié pour réfléchir sur un sujet. Ce cadrage peut avoir un effet sur le raisonnement et conduire à des choix différents en fonction de la façon dont le problème a été formulé (Wikipédia).

# Statistiques, méfiez-vous.

- Les données sont factuelles.
- Les statistiques les rendent lisibles.

Mais...

- D'où viennent les données ? Qui les a collectées et comment sont-elles stockées ?
- Qui produit les statistiques? Dans quel but? Ces personnes ont-elles des conflits d'intérêts sur ces sujets (*There is no free lunch.*) ? Ces personnes sont-elles sujettes a des biais ?
- Qui présente les statistiques ? A qui ? Et dans quel but? Ces personnes ont-elles des conflits d'intérêts sur ces sujets ? Ces personnes sont-elles sujettes a des biais ?

## Conseils.

- Connaissez les notions du cours, et sachez les expliquer simplement.
- Suivez votre intuition, cherchez à la vérifier avec des petites expériences numériques simples. Reconnaissez quand votre intuition est bonne, ou quand elle ne l'est pas bonne.
- Pratiquez la discussion ou le débat contradictoire.