

# Algorithmes randomisés

Nicolas Gast

Inria – Univ. Grenoble Alpes

2020. Maths701, Master MEEF.

# Plan du cours

## 1 Rappel de Probabilités

- Événements et espaces probabilisés
- Variables aléatoires
- Inégalités de concentration, intervalles de confiance

## 2 Génération d'aléatoire et simulation

- Comment générer de l'aléatoire?
- Générer selon une loi donnée
- Exemple de simulation: la formule de Lindley

## 3 Algorithmes randomisés

- Algorithmes "Las Vegas": Quicksort / Quickselect
- Algorithmes "Monte Carlo"
- Algorithmes décentralisés / apprentissage par renforcement

# Espace probabilisé

Un espace probabilité est  $(\Omega, \mathcal{F}, \mathbb{P}[\cdot])$ , où

- $\Omega$  est l'ensemble des possibles.
- $\mathcal{F} \subset 2^\Omega$  est l'ensemble des événements *mesurables*.
- $\mathbb{P}[\cdot] : \mathcal{F} \rightarrow [0, 1]$  est une mesure de probabilité.

$\mathbb{P}[E] =$  probabilité de l'événement  $E$ .

Exemple : lancé de dé à 6 faces

$$\Omega = \{0; 1; 2; 3; 4; 5; 6\}$$
$$\mathcal{F} = \{\emptyset; \{1\}, \{2\}, \dots, \{1, 2\}, \dots\}$$
$$\mathbb{P}(\{1\}) = \frac{1}{6} = \mathbb{P}(\{2\})$$
$$\mathbb{P}(\{1, 2, 5\}) = \frac{1}{2}$$
$$\mathbb{P}(\{0\}) = 0$$
$$\mathbb{P}(\emptyset) = 0; \quad \mathbb{P}(\{1; \dots; 6\}) = 1$$

# Indépendance et probabilité conditionnelle

A et B sont  
indépendants

A et B'  
ne sont pas  
indépendants

Soit  $A, B \in \mathcal{F}$  deux événements.  $A$  et  $B$  sont indépendants si

$$\mathbb{P}[A \cap B] = \mathbb{P}[A]\mathbb{P}[B].$$

$$A = \{1, 3, 5\}$$

$$\Rightarrow \mathbb{P}(A) = \frac{1}{2}$$

$$\mathbb{P}(B) = \frac{1}{3}$$

$$A = \{1, 3, 5\}$$

$$\mathbb{P}(A) = \frac{1}{2}$$

$$B' = \{4\}$$

$$\mathbb{P}(B) = \frac{1}{6}$$

Ex:  $B = \{1, 2\}$

$$\mathbb{P}(A \cap B) = \mathbb{P}(\{1\}) = \frac{1}{6}$$

$$\mathbb{P}(A \cap B') = \frac{1}{6} \neq \frac{1}{2} \cdot \frac{1}{6}$$

Si  $A \in \mathcal{F}$  is un événement de probabilité non nulle, alors:

$$\mathbb{P}[B | A] = \frac{\mathbb{P}[B \cap A]}{\mathbb{P}[A]}$$

"proba de B sachant A"

$$\mathbb{P}(\text{dé est } 1 \mid \text{dé est pair})$$

$$= \frac{\frac{1}{6}}{\frac{1}{2}} = \frac{1}{3}$$

$$\mathbb{P}(\text{dé est impair} \mid \text{dé est } 1)$$

$$= \frac{\frac{1}{6}}{\frac{1}{6}} = 1$$

Ex: lancé de deux dés.

## Règle de Bayes

$$P(B|A) = \frac{P(A \cap B)}{P(A)} \quad (1)$$

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (2)$$

Bayes rule

$$P[B|A] = \frac{P[A|B] P[B]}{P[A]}$$

$$P(A \cap B) = P(B|A) \cdot P(A) \quad (1)$$

$$= P(A|B) \cdot P(B) \quad (2)$$

## Exercice

$$P(\text{test positif} \mid \text{malade}) = 0.95$$

en général  
 $P(A \mid B) \neq P(B \mid A)$

**Example:** Une maladie a touché 10% de la population. Le laboratoire Testex a créé un nouveau test qu'il permet de savoir si on a été infecté ou non. Ce test est censé être fiable à 95% (c'est à dire qu'il donne un résultat juste 95% du temps.)

**Question** – Un individu est testé positif par le test. Quelle est la probabilité qu'il soit malade?

$$P(\text{malade} \mid \text{test positif}) = \frac{P(\text{test positif} \mid \text{malade}) \cdot P(\text{malade})}{P(\text{test positif})}$$

$$x = 0.1 \times 0.95 + 0.9 \times 0.05 = 0.14$$

$$P(\text{malade} \mid \text{test positif}) \approx 0.68 \ll 0.95$$

# Table des matières

## 1 Rappel de Probabilités

- Événements et espaces probabilisés
- Variables aléatoires
- Inégalités de concentration, intervalles de confiance

## 2 Génération d'aléatoire et simulation

- Comment générer de l'aléatoire?
- Générer selon une loi donnée
- Exemple de simulation: la formule de Lindley

## 3 Algorithmes randomisés

- Algorithmes "Las Vegas": Quicksort / Quickselect
- Algorithmes "Monte Carlo"
- Algorithmes décentralisés / apprentissage par renforcement

Variables aléatoire  $\omega \in \Omega \Rightarrow X(\omega)$

Soit  $\mathcal{X}$  un sous-ensemble de  $\mathbb{R}$  (typiquement,  $\mathcal{X} = \mathbb{R}$  ou  $\mathcal{X}$  est fini).

Une variable aléatoire à valeur dans  $\mathcal{X}$  est une fonction mesurable,  $X : \Omega \rightarrow \mathcal{X}$ . On note

$$\underline{\mathbb{P}[X \in A]} = \mathbb{P}[\{\omega : X(\omega) \in A\}].$$

En règle général, on n'écrira pas  $X(\omega)$  mais uniquement  $X$ .

Exemple: lancés de dés.  
 $X =$  le dé est pair  $\Rightarrow X(\omega) = \begin{cases} 1 & \text{si } \omega \in \{0; 2; 4; 6\} \\ 0 & \text{sinon} \end{cases}$

$$\Omega = \{0; 1; \dots; 6\}$$

$$Y = \text{La valeur du dé} \quad Y(\omega) = \omega.$$



## Espérance, variance

Soit  $X$  une variable aléatoire à valeur dans un ensemble fini  $\mathcal{X} \subset \mathbb{R}$   
L'espérance de  $X$ , notée  $\mathbb{E}[X]$  est:

$$\mathbb{E}[X] = \sum_{x \in \mathcal{X}} x \cdot \mathbb{P}(X=x)$$

La variance de  $X$  est:

$$\begin{aligned} \text{var}(X) &= \mathbb{E}[(X - \mathbb{E}[X])^2] \\ &= \sum_{x \in \mathcal{X}} (x - \mathbb{E}[X])^2 \mathbb{P}(X=x) \\ &\geq 0. \end{aligned}$$

# Loi usuelles

	Définition	Espérance	Variance
<ul style="list-style-type: none"> <li>Loi de Bernoulli <math>B</math></li> </ul>	<p>param  <math>p \in [0; 1]</math>  <math>P(B=1) = p ; P(B=0) = 1 - p</math></p>	$p$	$\overline{\text{var}(B)} = (1-p)^2 p + p^2 (1-p)^2 = p(1-p)$
Loi géométrique $G$	<p><math>p \in [0; 1]</math> <math>G =</math> nombre de tirages nécessaires avant d'obtenir à 1.</p> <p> <math>P(G=1) = p</math>  <math>P(G=2) = (1-p)p</math>  <math>P(G=3) = (1-p)^2 p</math></p>	$\frac{1}{p}$	$\frac{1-p}{p^2}$
<ul style="list-style-type: none"> <li>Loi binomiale <math>N</math></li> </ul>	<p><math>n, p \Rightarrow</math> on fait <math>n</math> tirages d'une loi de Bernoulli de param <math>p</math>            on compte le nombre de 1</p> <p> <math>P(N=i) = \binom{n}{i} p^i (1-p)^{n-i}</math>  <math>N = \sum_{k=1}^n B_k</math></p>	$np$	$np(1-p)$
Loi de Poisson $X$	<p>1 param <math>d \geq 0</math></p> <p> <math>P(X=k) = \frac{d^k e^{-d}}{k!}</math></p>	$d$	$d$

# Variables aléatoires indépendantes

Deux variables sont indépendantes si  $\forall A, B$

$$\mathbb{P}[X \in A \text{ et } Y \in B] = \mathbb{P}[X \in A] \mathbb{P}[Y \in B].$$

Exemple: lancés de dés.

on lance deux dés de façon indépendante  $X_1, X_2$   
 $\mathbb{P}(X_1 = i \text{ et } X_2 = j) = \frac{1}{36}$  pour tout  $i, j \in \{1, \dots, 6\}$

$$S = X_1 + X_2$$

$$D = X_1 - X_2$$

$$\mathbb{P}(S = 12) = \frac{1}{36}$$

$$\mathbb{P}(D = 1) > 0$$

$\Rightarrow$  ce qui prouve toutes valeurs de  $s$  et  $d$ :

$$\mathbb{P}(S = s \text{ et } D = d) = \mathbb{P}(S = s) \mathbb{P}(D = d)$$

$$\mathbb{P}(S = 12 \text{ et } D = 1) = 0 \neq \mathbb{P}(S = 12) \mathbb{P}(D = 1)$$

donc:  $S$  et  $D$  ne sont pas indépendantes.

# Espérance, variance et indépendance

Soit  $X$  et  $Y$  deux variables aléatoires:

- $\mathbb{E}[X + Y] = \mathbb{E}[X] + \mathbb{E}[Y]$

- Si  $X$  et  $Y$  sont indépendantes, alors  $\text{var}[X + Y] = \text{var}[X] + \text{var}[Y]$ .

Exemple: loi de Bernoulli.

$X \sim$  Bernoulli de param  $\frac{1}{2}$

$Y = X \sim$  Bernoulli de param  $\frac{1}{2}$

$Z = 1 - X \sim$  Bernoulli de param  $\frac{1}{2}$

$X + Y = \begin{cases} 2 & \text{avec proba } \frac{1}{4} \\ 0 & \text{avec proba } \frac{1}{4} \end{cases}$

$X + Z = 1 \quad \text{var}(X + Z) = 0$

$\rightarrow$  ne sont pas indépendantes.

$$\mathbb{E}[X + Y] = 1$$

$$\text{var}(X + Y) = (2-1)^2 \cdot \frac{1}{4} + (0-1)^2 \cdot \frac{1}{4} = 1$$

$$\text{var}(X) = \frac{1}{2}(1-\frac{1}{2}) = \frac{1}{4}$$

$$\text{var}(Y) = \frac{1}{4}$$

$$\text{var}(Z) = \frac{1}{4}$$

# Table des matières

## 1 Rappel de Probabilités

- Événements et espaces probabilisés
- Variables aléatoires
- Inégalités de concentration, intervalles de confiance

## 2 Génération d'aléatoire et simulation

- Comment générer de l'aléatoire?
- Générer selon une loi donnée
- Exemple de simulation: la formule de Lindley

## 3 Algorithmes randomisés

- Algorithmes "Las Vegas": Quicksort / Quickselect
- Algorithmes "Monte Carlo"
- Algorithmes décentralisés / apprentissage par renforcement

# Inégalité de Markov et de Chebychev

Soit  $X$  une variable aléatoire (réelle)  $\forall a > 0$ :

Inég de Markov:  $\mathbb{P}[X \geq a] \leq \frac{1}{a} \mathbb{E}[|X|]$

preuve:

$$|X| = |X| \mathbb{1}_{\{|X| \geq a\}} + |X| \mathbb{1}_{\{|X| < a\}} \geq 0$$

$\left. \begin{array}{l} 1 \text{ si } |X| \geq a \\ 0 \text{ sinon} \end{array} \right\}$ 
 $\left. \begin{array}{l} 1 \text{ si } |X| < a \\ 0 \text{ sinon} \end{array} \right\}$

$$\geq a \mathbb{1}_{\{|X| \geq a\}}$$

$$\mathbb{P}[|X - \mathbb{E}[X]| \geq a] \leq \frac{1}{a^2} \text{var}[|X|]$$

$$\mathbb{E}[|X|] \geq a \mathbb{E}[\mathbb{1}_{\{|X| \geq a\}}] = a \mathbb{P}(|X| \geq a)$$

$$\geq a \mathbb{1}_{\{|X| \geq a\}} \quad \mathbb{P}(X \geq a) \leq \mathbb{P}(|X| \geq a) \leq \frac{\mathbb{E}[|X|]}{a}$$

Chebyshev :

$$P(|X - \mathbb{E}[X]| \geq a) \leq \frac{1}{a^2} \text{var}(X)$$

Markov :  $P(X \geq a) \leq \frac{1}{a} \mathbb{E}[X]$

$$\begin{aligned} P(|X - \mathbb{E}[X]| \geq a) &= P(|X - \mathbb{E}[X]|^2 \geq a^2) \\ &= P((X - \mathbb{E}[X])^2 \geq a^2) \\ &\stackrel{\substack{\leq \\ \uparrow \\ \text{per Markov}}}{\leq} \frac{1}{a^2} \mathbb{E}[(X - \mathbb{E}[X])^2] \\ &= \frac{1}{a^2} \mathbb{E}[(X - \mathbb{E}[X])^2] \\ &= \frac{1}{a^2} \text{var}(X) . \end{aligned}$$

■

# Application: loi des grands nombres

Soit  $X_1, X_2, \dots$  une suite de variable aléatoire indépendantes et à valeurs

dans  $\mathcal{X}$  fini. Soit  $S_n = \frac{1}{n} \sum_{k=1}^n X_k$  Alors: *← moyenne des n premières valeurs. et de même loi*

$$\forall \epsilon > 0: \quad \lim_{n \rightarrow \infty} \mathbb{P}[|S_n - \mathbb{E}[X]| \geq \epsilon] = 0.$$

Preuve:  $\text{var}(S_n) = \text{var}\left(\frac{1}{n} \sum_{k=1}^n X_k\right)$

$$= \frac{1}{n^2} \text{var}\left(\sum_{k=1}^n X_k\right)$$

$$= \frac{1}{n^2} (\text{var}(X_1) + \text{var}(X_2) + \dots + \text{var}(X_n))$$

*car les  $X_i$  sont indépendants.*

$$= \frac{1}{n^2} n \text{var}(X) = \frac{\text{var}(X)}{n}$$

$$\mathbb{E}[S_n] = \frac{1}{n} (\mathbb{E}[X_1] + \dots + \mathbb{E}[X_n]) = \mathbb{E}[X]$$

Chebyshev:  $\mathbb{P}(|S_n - \mathbb{E}[S_n]| \geq \epsilon) \leq \frac{1}{\epsilon^2} \text{var}(S_n) = \frac{\text{var}(X)}{n \epsilon^2} \xrightarrow{n \rightarrow \infty} 0$




Illustration: Estimation de  $\pi$ .

$$Z_i = \begin{cases} 1 & \text{si } (X_i, Y_i) \text{ est dans la circonférence } \underline{\text{c'est}} \quad X_i^2 + Y_i^2 \leq 1 \\ 0 & \text{sinon} \end{cases}$$

$$\frac{1}{n} \sum_{i=1}^n Z_i \approx \mathbb{E}[Z]$$

et quand  $n$  grand



$$\mathbb{E}[Z] = \frac{\pi}{4}$$

$$\pi \approx 4 \cdot \frac{1}{n} \sum_{i=1}^n Z_i$$

## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaires?

## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaire?

$X = (0,$

## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaire?

$X = (0, 1, 0, 1, 0, 1,$

## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaire?

$X = (0, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 1,$   
 $1, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 1, 1, 0, 1, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 0,$   
 $1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0,$

## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaires?

$X = (0, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 1,$   
 $1, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 0,$   
 $1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0,$   
 $1, 0, 1, 0, 0, 0, 1, 0, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 1, 0, 1, 0, 1, 0, 1, 1,$   
 $0, 0, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1,$   
 $0, 1, 0, 1, 0, 1, 0, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 0, 1, 1, \dots)$

## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaires?

$X = (0, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 1,$   
 $1, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 0,$   
 $1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0,$   
 $1, 0, 1, 0, 0, 0, 1, 0, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 1, 0, 1, 0, 1, 1,$   
 $0, 0, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1,$   
 $0, 1, 0, 1, 0, 1, 0, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 0, 1, 1, \dots)$

$n$	1	3	5				
$\frac{1}{n} \sum_{i=1}^n X_i$	0.0	0.333...	.4				

# Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .

- On cherche à estimer  $p$ .

Combien de tirages sont nécessaires?

$X = (0, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 1,$   
 $1, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 0,$   
 $1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0,$   
 $1, 0, 1, 0, 0, 0, 1, 0, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 1, 0, 1, 0, 1, 0, 1, 1,$   
 $0, 0, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1,$   
 $0, 1, 0, 1, 0, 1, 0, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 0, 1, 1, \dots)$

	1	3	5	10	20	100	
$\frac{1}{n} \sum_{i=1}^n X_i$	0.0	0.333...	.4	0.7	0.7	0.57	





## Confiance?

On dispose d'une pièce biaisée  $\mathbb{P}[X_i = 1] = 1 - \mathbb{P}[X_i = 0] = p$ .


- On cherche à estimer  $p$ .

Combien de tirages sont nécessaires?


$X = (0, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0, 1, 0, 1, 0, 0, 0, 1, 0, 0, 0, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 1, 0, 1, 0, 1, 0, 1, 1, 0, 0, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 0, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 0, 1, 0, 1, 1, 0, 1, 0, 1, 0, 0, 1, 0, 1, 0, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 0, 1, 1, 0, 1, 0, 1, 0, 1, 0, 1, 0, 1, 0, 1, 0, 0, 1, 0, 1, 1, 0, 1, 1, 1, 0, 0, 1, 0, 1, 1, \dots)$

	1	3	5	10	20	100	1000
$\frac{1}{n} \sum_{i=1}^n X_i$	0.0	0.333...	.4	0.7	0.7	0.57	<u>0.606</u>
	0.0	0.666...	0.8	<u>0.7</u>	0.65	0.71	<u>0.62</u>
	1.0	0.666...	0.6	<u>0.4</u>	0.55	0.6	<u>0.597</u>
	0.0	0.0	0.2	<u>0.3</u>	0.45	0.53	<u>0.574</u>
	0.0	0.333...	0.2	<u>0.5</u>	0.6	0.59	<u>0.592</u>
	0.0	0.333...	0.4	<u>0.6</u>	0.55	0.6	<u>0.623</u>


# Étudions $S_n$



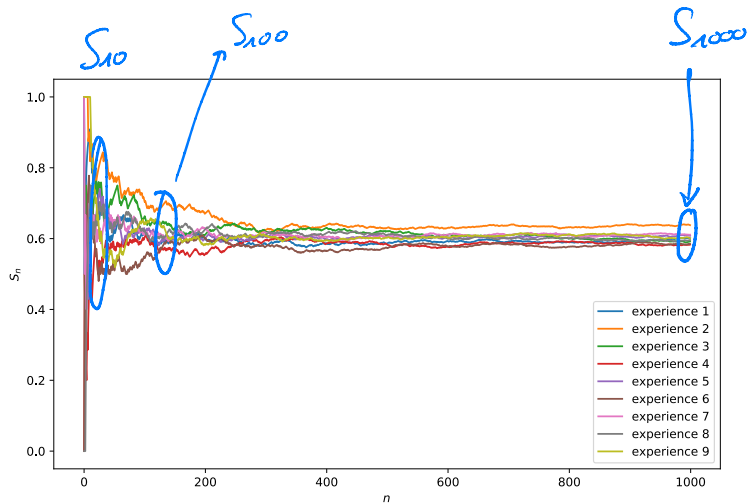
# Étudions $S_n$




# Étutions $S_n$




# Étutions $S_n$



# Distribution de $S_n$ pour $n \in \{10, 100, 1000\}$




# Distribution de $S_n$ pour $n \in \{10, 100, 1000\}$






# Distribution de $S_n$ pour $n \in \{10, 100, 1000\}$




# Distribution de $S_n$ pour $n \in \{10, 100, 1000\}$



# Loi normale

$$(\mu, \sigma)$$

Densité:  $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$ .



# Théorème central limite

*indépendantes et  
identiquement  
distribuées.*

Soit  $X_1, X_2, X_3, \dots$  une suite de variable aléatoires i.i.d. <sup>d'espérance</sup> de moyenne  $\mu$  et de variance  $\sigma^2$ . Alors:

$$\underbrace{\frac{1}{\sigma\sqrt{n}} \sum_{k=1}^n (X_k - \mu)} \rightarrow N(0, 1) \quad \text{en loi}$$

Historique de la démonstration: de Moivre 1733 (pour une pièce non biaisée), Laplace 1812 (pour les pièces biaisées), Pólya 1920 (cas général)


$$S_n = \frac{1}{n} \sum_{k=1}^n X_k \approx \boxed{\mu + \frac{\sigma}{\sqrt{n}} \mathcal{N}(0; 1)}$$
$$\frac{\sqrt{n}}{\sigma} (S_n - \mu) \rightarrow \mathcal{N}(0; 1)$$

# Intervalle de confiance

$$\frac{1}{n} \sum_{k=1}^n X_k \approx \mu + \frac{1}{\sqrt{n}} \sigma.$$

En particulier:

$$\mathbb{P} \left[ \frac{1}{n} \sum_{k=1}^n X_k \in \left[ \mu - \frac{2}{\sqrt{n}} \sigma; \mu + \frac{2}{\sqrt{n}} \sigma \right] \right] \geq 95\%.$$



## Quel $\sigma$ utiliser? Cas des variables sont de Bernoulli

- $\sigma = \sqrt{p(1-p)} \leq 1/2$ . Application: sondage et confiance à 3 points.

$$S_n = \frac{1}{n} \sum_{k=1}^n X_k = \mu + \frac{\sigma}{\sqrt{n}} N(0;1)$$

$$P(|S_n - \mu| \geq \epsilon) \approx P\left(\frac{\sigma}{\sqrt{n}} |N(0;1)| \geq \epsilon\right)$$

$$P(|S_n - \mu| \geq \frac{2\sigma}{\sqrt{n}}) \approx 95\%$$

Population  $\approx 70 \text{ M}$  hab.

Sondage sur 1000 personnes  
 $X_i \in \{0;1\}$  vote de la personne  $i$  pour le candidat qui vous intéresse

si une fraction "p" de la population vote pour un candidat  
 $X_i \sim$  Bernoulli de paramètre p  
les  $X_i$  sont à peu près indépendants car  $1000 \ll 70 \cdot 10^6$ .

$$P(|S_n - p| \geq \frac{2\sqrt{p(1-p)}}{\sqrt{1000}}) \approx 95\%$$

$$\frac{2\sqrt{p(1-p)}}{\sqrt{1000}} \leq \frac{1}{\sqrt{1000}} \approx 0.03 = 3\%$$