

## Lecture 1: Un peu de probabilités

Prof.:

Scribes:

### 1.1 Rappels et Définitions

#### 1.1.1 Probabilités et distributions

On définit une variable aléatoire  $X$  comme une variable dont la valeur dépend du hasard : elle peut prendre une valeur différente à chaque essai.

- Pour  $X$  une variable aléatoire discrète, chaque issue a une probabilité associée  $p_i \in (0, 1)$  correspondant à la probabilité que la variable aléatoire prenne la valeur de l'issue.

**Exemple 1** Dans le cas d'un lancer de dé on peut écrire:

$$\mathbb{P}(X = i) = \frac{1}{6}, \quad i = 1, 2, 3, 4, 5, 6 ; \quad \text{avec} \quad \sum_{i=1}^6 p_i = \sum_{i=1}^6 \mathbb{P}(X = i) = 1. \quad \blacksquare$$

- Pour  $X$  une variable aléatoire continue il est impossible de déterminer une probabilité pour une valeur précise<sup>1</sup>. Néanmoins il est possible d'exprimer la probabilité de trouver la variable aléatoire dans un certain intervalle : elle est définie par la fonction de densité de probabilité.


**Définition 1.1** (Fonction de densité de probabilité  $p_X$  (p.d.f.))

Fonction mathématique non-négative décrivant la probabilité qu'une variable aléatoire continue  $X$  prenne une certaine valeur  $x$  ou plus précisément appartienne à l'intervalle  $[x, dx]$  pour  $dx$  un nombre réel positif infiniment petit. On définit  $p_X(x)$  t.q.

$$p_X(x)dx = \mathbb{P}(X \in [x, x + dx]) \quad \text{avec } p_X \text{ normalisée} \quad \int_{-\infty}^{\infty} p_X(x)dx = 1. \quad (1.1)$$

Il est également possible de décrire le cas des variables aléatoires discrètes avec une p.d.f. En reprenant l'exemple du jet de dé :

$$p_X(x) = \frac{1}{6} \sum_{i=1}^6 \delta(i - x). \quad (1.2)$$

 Le facteur de  $\frac{1}{6}$  devant la somme de l'Eq.(1.2) correspond à la normalisation de la fonction.

<sup>1</sup>À proprement parler, chaque point a probabilité nulle, voir Prop. 1.2 ci-après.

**Proposition 1.2** On peut élargir la définition précédente à un intervalle choisi  $[a, b]$ , avec  $a, b \in \mathbb{R}$ . La probabilité que  $X$  prenne une valeur comprise dans cet intervalle est alors :

$$\mathbb{P}(X \in [a, b]) = \int_a^b p_X(x) dx. \quad (1.3)$$

**Exemple 2** Voici un exemple de plusieurs distributions de base avec la p.d.f correspondante :

1. Distribution de Dirac : voir Fig.1(a)

Pour une moyenne  $c$  et une variance de 0, la p.d.f. s'écrit

$$p_X = \delta(x - c) \quad (1.4)$$

Ainsi dans le cas de variables aléatoires discrètes, le graphe de la p.d.f. correspond à un ensemble de pics placés selon les valeurs possibles de l'expérience.

2. Loi normale (ou Gaussienne) : voir Fig.1(b)

Pour une moyenne  $\mu$  et une variance  $\Delta$ , la p.d.f. s'écrit

$$p_X(x) = \mathcal{N}(x; \mu, \Delta) = \frac{1}{\sqrt{2\pi\Delta}} e^{-\frac{(x-\mu)^2}{2\Delta}} \quad (1.5)$$

 Noter que pour  $\Delta \rightarrow 0$  la Gaussienne tends vers une distribution de Dirac centrée en  $\mu$ .

3. Loi uniforme : voir Fig.1(c)

$$p_X(x) = \mathcal{U}(x; a, b) = \begin{cases} \frac{1}{b-a} & \text{si } a \leq x \leq b \\ 0 & \text{sinon.} \end{cases}$$

4. Loi exponentielle : voir Fig.1(d)

$$p_X(x) = \frac{1}{\lambda} e^{-\frac{x}{\lambda}} \quad (1.6)$$

avec  $x \geq 0$  et  $\lambda \geq 0$  la moyenne.

 En radioactivité,  $\lambda$  est nommée constante de temps (ou durée de vie moyenne) .

■

**Définition 1.3** (Espérance) L'espérance d'une variable aléatoire  $X$  est définie

$$\mathbb{E}[X] = \int_{-\infty}^{\infty} x p_X(x) dx. \quad (1.7)$$

Le cas discret est défini de manière analogue avec une somme. Pour une fonction  $g$  mesurable, on a

$$\mathbb{E}[g(X)] = \int_{-\infty}^{\infty} g(x) p_X(x) dx. \quad (1.8)$$

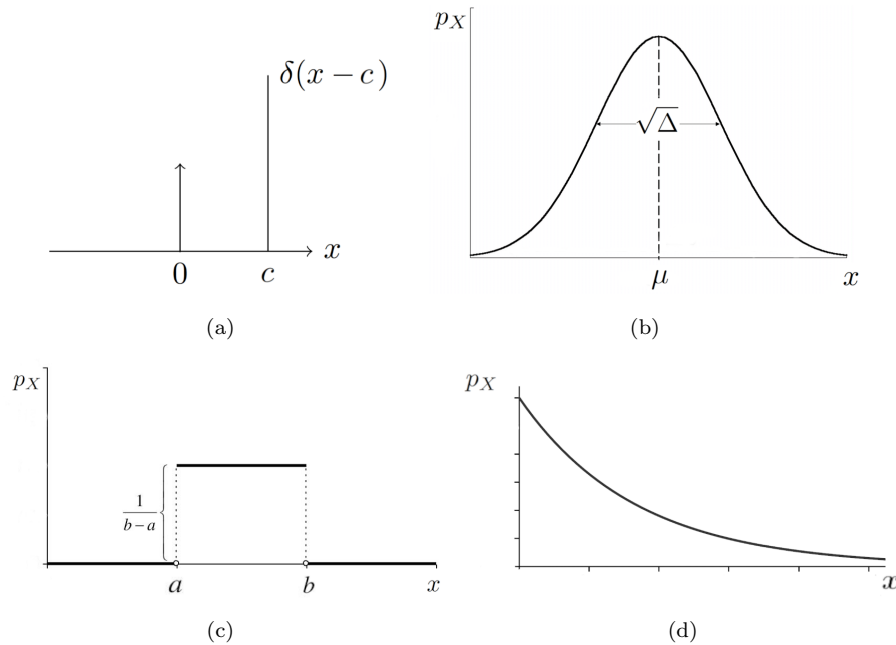


Figure 1.1: Distributions: (a) de Dirac, (b) Normale, (c) Uniforme et (d) Exponentielle.

**Définition 1.4** (Moment d'ordre  $n$ )

$$\mu_n = \mathbb{E}[X^n] = \int_{-\infty}^{\infty} x^n p_X(x) dx \quad (1.9)$$

le moment d'ordre  $n = 1$  :  $\mu_1 = \mu = \int_{-\infty}^{\infty} x p_X(x) dx$  est plus communément appelé la moyenne.

**Définition 1.5** Soient deux variables  $X$  et  $Y$ :

1. Loi jointe:  $\mathbb{P}(X, Y) \equiv$  probabilité que  $X$  et  $Y$  soient vrais.
2. Loi conditionnelle:  $\mathbb{P}(X|Y) \equiv$  probabilité que  $X$  soit vrai quand  $Y$  est vrai  
 $\Rightarrow \mathbb{P}(X, Y) = \mathbb{P}(X|Y)\mathbb{P}(Y)$

**Définition 1.6** (Covariance)

$$\mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y] = \text{Cov}(X, Y) \quad (1.10)$$

**R** (X et Y indépendants)  $\Leftrightarrow \mathbb{P}(X, Y) = \mathbb{P}(X)\mathbb{P}(Y)$ .

**R** Attention, (X et Y indépendants)  $\Rightarrow \text{Cov}(X, Y) = 0$ , mais la réciproque est fausse en général. L'équivalence tient pour  $X, Y$  gaussiennes.

### 1.1.2 Propriétés de base

**Proposition 1.7** (*Changement de variable*)

Soit  $X$  distribuée selon  $p_X$  et une autre variable  $Y$  t.q.  $Y = g(X)$ , on trouve:

$$p_Y(y) = \int_{-\infty}^{\infty} p_X(x) \delta(y - g(x)) dx \quad (1.11)$$

En utilisant le résultat de la fonction de Dirac  $\forall x_i$  t.q.  $f(x_i) = 0$

$$\delta(f(x)) = \frac{\delta(x - x_i)}{|f'(x_i)|}, \quad (1.12)$$

on obtient alors  $\forall x_i$  solutions de  $g(x_i) = y$ :

$$p_Y(y) = \sum_i \int dx p_X(x) \frac{\delta(x - x_i)}{|g'(x_i)|} = \sum_i \frac{1}{|g'(x_i)|} p_X(x_i). \quad (1.13)$$

Pour  $g$  une fonction monotone, la p.d.f. de  $Y$  peut donc être écrite :

$$p_Y(y) = p_X(x) \left| \frac{dx}{dy} \right| \quad (1.14)$$

tirée également de l'égalité des probabilités  $p_Y(y)dy = p_X(x)dx$ .

 Attention à ne pas oublier le jacobien  $|\frac{dx}{dy}|$  dans les calculs!

**Exemple 3** Soit une variable aléatoire  $X \sim \mathcal{U}[0, 1]$ . On définit  $Y = -\ln(X)$  ( $\Leftrightarrow e^{-y} = x$ )

La distribution de  $Y$  est donc donnée par  $p_Y(y) = p_X(x) \left| \frac{dx}{dy} \right| = \left| \frac{dx}{dy} \right| = e^{-y}$ . ■

## 1.2 Bornes de bases

**Proposition 1.8** (*Inégalité de Markov*) - Soit  $X$  une variable aléatoire non-négative, et  $a > 0$ , alors

$$\mathbb{P}[X \geq a] \leq \frac{\mathbb{E}[X]}{a} \quad (1.15)$$

### Preuve 1

$$\begin{aligned} \mathbb{P}(X \geq a) &= \int_a^{+\infty} p_X(x) dx \\ &\leq \int_a^{+\infty} \frac{x}{a} p_X(x) dx \\ &\leq \frac{1}{a} \int_0^{+\infty} x p_X(x) dx \\ &= \frac{\mathbb{E}[X]}{a}, \end{aligned} \quad (1.16)$$

en utilisant que  $x \geq a$ , et ensuite que  $x p_X(x) \geq 0$ .

**Proposition 1.9** (Inégalité de Chebyshev) - Soit  $X$  une variable aléatoire qui admet une variance non-nulle  $\sigma^2$  ainsi qu'une moyenne. Alors pour tout  $k > 0$ ,

$$\mathbb{P}(|X - \mathbb{E}[X]| \geq k\sigma) \leq \frac{1}{k^2}. \quad (1.17)$$

### Preuve 2

$$\begin{aligned} & \text{Considérons la variable aléatoire } (X - \mathbb{E}[X])^2 \text{ de variance } \sigma^2 \\ & \mathbb{P}(|X - \mathbb{E}[X]| \geq k\sigma) = \mathbb{P}((X - \mathbb{E}[X])^2 \geq k^2\sigma^2) \\ & \leq \frac{\mathbb{E}[(X - \mathbb{E}[X])^2]}{k^2\sigma^2} = \frac{\mathbb{E}[X^2] - \mathbb{E}[X]^2}{k^2\sigma^2} = \frac{\sigma^2}{k^2\sigma^2} \text{ en utilisant l'inégalité de Markov} \\ & = \frac{1}{k^2} \end{aligned} \quad (1.18)$$



Cette inégalité permet de borner la probabilité qu'une variable aléatoire dévie de la moyenne, et ce en utilisant la variance de cette variable.

**Exemple 4** Soit  $Y_n = \frac{1}{n} \sum_{i=1}^n X_i$  la moyenne empirique, avec  $X_i$  des variables aléatoires i.i.d. d'espérance  $\mu$  et de variance  $\Delta$ .

Alors  $\mathbb{E}[Y_n] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] = \frac{1}{n} \cdot n\mu = \mu$  tandis que  $\text{Var}[Y_n] = \frac{1}{n^2} \cdot n\Delta = \frac{\Delta}{n}$ . Appliquant l'inégalité de Chebyshev, nous obtenons  $\mathbb{P}(|Y_n - \mu| \geq \epsilon) \leq \frac{\Delta}{n\epsilon^2}$ . Cette probabilité tend vers 0 lorsque  $n \rightarrow \infty$ . Ce résultat mène à la loi des grands nombres, qui est énoncée maintenant. ■

**Définition 1.10** (Convergence en probabilité) - Soient  $X, X_1, X_2, \dots$  des variables aléatoires. On dit que  $X_n$  tend vers  $X$  en probabilité,  $X_n \xrightarrow{P} X$ , si pour tout  $\epsilon > 0$ ,

$$\lim_{n \rightarrow \infty} \mathbb{P}(|X_n - X| > \epsilon) = 0 \quad (1.19)$$

**Définition 1.11** (Convergence en distribution) - Soient  $X, X_1, X_2, \dots$  des variables aléatoires, ayant une fonction de répartition  $F_X, F_{X_1}, F_{X_2}, \dots$ . On dit que  $X_n$  tend vers  $X$  en distribution,  $X_n \xrightarrow{D} X$ , si

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x) \quad (1.20)$$

en tout  $x$  où  $F_X(x)$  est continue.

**Théorème 1.12** (Loi des grands nombres) - Soit  $(X_n)$  une suite de variables aléatoires i.i.d d'espérance  $\mu$ . Alors la moyenne empirique  $Y_n = \frac{1}{n} \sum_{k=1}^n X_k$  converge en probabilité vers l'espérance  $\mu$

$$Y_n \xrightarrow{P} \mu \quad (1.21)$$

Ainsi,  $\forall \epsilon > 0, \mathbb{P}[|Y_n - \mu| \geq \epsilon] \rightarrow 0$ .

**Théorème 1.13** (*Théorème Central Limite*) - Soit  $(X_n)$  une suite de variables aléatoires i.i.d. de moyenne  $\mu$  et de variance  $\Delta$ . On considère également la moyenne empirique  $Y_n = \frac{1}{n} \sum_{i=1}^n X_i$ , alors la variable aléatoire

$$S_n = \frac{\sqrt{n}(Y_n - \mu)}{\sqrt{\Delta}} \quad (1.22)$$

converge en distribution vers une loi normale de moyenne 0 et de variance 1 :  $S_n \xrightarrow{D} X \sim \mathcal{N}(0, 1)$ .

### 1.3 Fonctions génératrices

**Définition 1.14** (*Fonction génératrice des moments, MGF*)

Soit  $X$  une variable aléatoire de densité  $p_X(x)$  et de support  $S$ . La MGF  $M_X(t)$  est définie comme

$$M_X(t) = \mathbb{E}[e^{tX}] = \int_S dx p_X(x) e^{tx}. \quad (1.23)$$

Le cas discret est analogue en remplaçant l'intégrale par une somme.

**R** La MGF est la transformée de Laplace de la densité, et n'existe pas  $\forall t$  en général (il faut que la densité décroisse "assez vite" quand  $x \rightarrow \infty$ ).

Par construction la proposition suivante est vraie :

**Proposition 1.15**

$$\left. \frac{\partial^n M_X(t)}{\partial t^n} \right|_{t=0} = \mu_n = \mathbb{E}[X^n], \quad (1.24)$$

où  $\mu_n$  est le  $n$ -ième moment.

On peut définir de manière analogue la fonction caractéristique en utilisant la transformée de Fourier et non celle de Laplace :

**Définition 1.16** (*Fonction caractéristique*)

Soit  $X$  une variable aléatoire de densité  $p_X(x)$  et de support  $S$ . La fonction caractéristique  $\phi_X(t)$  est définie comme

$$\phi_X(t) = \mathbb{E}[e^{itX}] = \int_S dx p_X(x) e^{itx}. \quad (1.25)$$

**R** Dans ce cas, la transformée est toujours bien définie pour l'intégrale de Lebesgue puisque  $e^{itx}$  est dominé en module par 1, et que la densité est normalisée (théorème de convergence dominée).

On a de la même manière que pour la MGF:

**Proposition 1.17**

$$\left. \frac{\partial^n \phi_X(t)}{\partial t^n} \right|_{t=0} = i^n \mu_n. \quad (1.26)$$

**Définition 1.18** (Fonction génératrice des cumulants, CGF)

Soit  $X$  une variable aléatoire de densité  $p_X(x)$  et de support  $S$ . La CGF  $K_X(t)$  est définie comme

$$K_X(t) = \ln(M_X(t)) = \ln(\mathbb{E}[e^{tX}]). \quad (1.27)$$

Les cumulants sont alors définis  $\kappa_n = \left. \frac{\partial^n K_X(t)}{\partial t^n} \right|_{t=0}$ .

**Exemple 5** Les deux premiers cumulants sont donnés par

$$\kappa_1 = \left. \frac{\partial \ln(M_X(t))}{\partial t} \right|_0 = \overbrace{\frac{1}{M_X(0)}}^1 \overbrace{\frac{\partial}{\partial t} M_X(t)}^\mu \Big|_0 = \mu, \quad (1.28)$$

$$\kappa_2 = \left. \frac{\partial^2 \ln(M_X(t))}{\partial t^2} \right|_0 = - \overbrace{\frac{1}{M_X^2(0)}}^1 \overbrace{\left( \frac{\partial M_X(t)}{\partial t} \right)^2}^{\mu_1^2} \Big|_0 + \overbrace{\frac{1}{M_X(0)}}^1 \overbrace{\frac{\partial^2}{\partial t^2} M_X(t)}^{\mu_2} \Big|_0 = \mu_2 - \mu_1^2 = \Delta. \quad (1.29)$$

■

**Proposition 1.19** (Additivité des fonctions génératrices)

Soient  $X, Y$  deux variables aléatoires indépendantes. En général

$$M_{X+Y}(t) = M_X(t)M_Y(t), \quad (1.30)$$

$$K_{X+Y}(t) = K_X(t) + K_Y(t). \quad (1.31)$$

**Preuve 3**

$$M_{X+Y}(t) = \mathbb{E}[e^{t(X+Y)}] = \mathbb{E}[e^{tX}e^{tY}] = \mathbb{E}[e^{tX}]\mathbb{E}[e^{tY}] = M_X(t)M_Y(t) \quad (1.32)$$

en utilisant l'indépendance pour factoriser les espérances. En prenant le logarithme de 1.32 prouvée ci-dessus, il vient la relation 1.31.

**R** Cela signifie en particulier que pour  $Y = \sum_{i=1}^n X_i$ , où les  $\{X_i\}_{i=1,\dots,n}$  sont i.i.d,  $M_Y(t) = (M_{X_1}(t))^n$  et  $K_Y(t) = nK_{X_1}(t)$ .

**R** Il suit en dérivant la relation 1.31 que pour deux variables aléatoires indépendantes, les cumulants des sommes sont les sommes des cumulants.

## 1.4 Grandes déviations

Si l'on a vu à l'aide du CLT que les écarts à la moyenne d'une variable aléatoire du type  $Y = \sum_{i=1}^n X_i$  avec  $\{X_i\}_{i=1,\dots,n}$  i.i.d. sont répartis comme une gaussienne d'écart type  $\sqrt{\Delta/n}$ , il est aussi intéressant de considérer les événements beaucoup plus rares lors desquels une valeur extrême est atteinte. Pour ce faire, les quelques résultats suivants sont utiles.

**Proposition 1.20** (*Borne de Chernof*)

Soient  $X, X_1, \dots, X_n$  i.i.d,  $a \in \mathbb{R}$ . Alors

$$\mathbb{P}\left[\frac{1}{n} \sum_{i=1}^n X_i \geq a\right] \leq e^{-n(\lambda a - K_X(\lambda))} \quad \forall \lambda > 0. \quad (1.33)$$

**Preuve 4**

$$\begin{aligned} \mathbb{P}\left[\frac{1}{n} \sum_{i=1}^n X_i \geq a\right] &= \mathbb{P}\left[\sum_{i=1}^n X_i \geq na\right] \stackrel{\lambda \geq 0}{\leq} \mathbb{P}\left[\lambda \sum_{i=1}^n X_i \geq \lambda na\right] = \mathbb{P}\left[\overbrace{e^{\lambda \sum_{i=1}^n X_i}}^{>0} \geq e^{\lambda na}\right] \stackrel{\text{Markov}}{\leq} \\ &\frac{\mathbb{E}[e^{\lambda \sum_{i=1}^n X_i}]}{e^{\lambda na}} \stackrel{i.i.d}{=} \frac{\mathbb{E}[e^{\lambda X}]^n}{e^{\lambda na}} = e^{n[\ln(\mathbb{E}[e^{\lambda X}]) - \lambda a]} = e^{-n(\lambda a - K_X(\lambda))} \end{aligned} \quad (1.34)$$

Puisque l'inégalité 1.33 est valide pour toute valeur de  $\lambda$ , il est naturel de chercher à trouver une valeur minimisant la borne, i.e. prendre le supremum sur  $\lambda$  de la valeur absolue de l'exponent. Le résultat suivant indique que cette borne optimale est saturée pour  $n \rightarrow \infty$  :

**Théorème 1.21** (*Théorème de Cramér*)

$$\frac{1}{n} \ln \mathbb{P}\left[\frac{1}{n} \sum_{i=1}^n X_i \geq a\right] \xrightarrow{n \rightarrow \infty} - \sup_{\lambda > 0} (\lambda a - K_X(\lambda)) \quad (1.35)$$

On définit alors la fonction de grande déviation

$$I(a) := \sup_{\lambda > 0} (\lambda a - K_X(\lambda)). \quad (1.36)$$

**R** Le théorème peut se reformuler  $\mathbb{P}\left[\frac{1}{n} \sum_{i=1}^n X_i \geq a\right] \asymp e^{-nI(a)}$ , où  $\asymp$  se lit "se comporte, quand  $n$  est grand, comme".

**R** Il est intéressant de noter que la fonction  $I(a)$  est la transformée de Legendre de la fonction génératrice des cumulants.

**Exemple 6** Soit  $X_i$  des v.a. iid selon la loi de probabilité Rademacher, i.e. que  $X_i = \pm 1$  avec probabilité  $\frac{1}{2}$ . Définissons alors la v.a.  $Y_n := \frac{1}{n} \sum_{i=1}^n X_i$ . L'esperance des  $X_i$  est de 0, leur variance est de 1. On voit donc que  $Y_n \approx 0 \pm \frac{1}{\sqrt{n}}$ . Intéressons nous maintenant aux grandes déviations de  $Y_n$ . Pour cela, calculons la fonction de grande déviation  $I(a)$ :

$$M_X(t) = \mathbb{E}[e^{tX}] = \frac{1}{2} (e^t + e^{-t}) = \cosh(t). \quad (1.37)$$

Pour obtenir  $I(a)$ , il reste à trouver  $\sup_{\lambda \in \mathbb{R}} (\lambda a - \ln(\cosh(\lambda))) = \sup_{\lambda \in \mathbb{R}} g_a(\lambda)$ :

$$\frac{dg_a}{d\lambda}(\lambda^*) = a - \tanh(\lambda^*) = 0 \Rightarrow \lambda^* = \operatorname{atanh}(a), \quad a \in [0; 1[. \quad (1.38)$$



La seconde dérivée étant strictement négative,  $\lambda^*$  correspond bien au maximum de  $g_a$  pour  $a \in [0; 1[$ . Si  $a = 1$ ,  $\sup_{\lambda \in \mathbb{R}} (\lambda - \ln(\cosh(\lambda))) = \ln(2)$ , si  $a > 1$ ,  $\sup_{\lambda \in \mathbb{R}} (\lambda a - \ln(\cosh(\lambda))) = +\infty$ , et si  $a < 0$ , le supremum de  $g_a$  est 0.

Ainsi,

$$I(a) = \begin{cases} (\ln(\sqrt{1-a^2}) + a \operatorname{atanh}(a)), & \text{si } a \in ]-1; 1[ \\ \ln(2), & \text{si } a = -1, 1 \\ +\infty, & \text{si } |a| > 1, \end{cases} \quad (1.39)$$

où on a utilisé  $\cosh(\operatorname{atanh}(a)) = \frac{1}{\sqrt{1-a^2}}$ . Enfin, en utilisant le théorème de Cramér sur  $X_i$  et  $-X_i$ , on obtient que

$$\mathbb{P} \left[ \left| \frac{1}{n} \sum_{i=1}^n X_i \right| \geq a \right] \asymp e^{-nI(a)} = \begin{cases} e^{-n(\ln(\sqrt{1-a^2}) + a \operatorname{atanh}(a))}, & \text{si } a \in [0; 1[ \\ \frac{1}{2^n}, & \text{si } a = 1 \\ 0, & \text{si } a > 1. \end{cases} \quad (1.40)$$

■



En utilisant le théorème de Cramér seulement sur les  $X_i$ , on utilise le supremum sur les  $\lambda > 0$ , et on trouve que le supremum pour  $a \leq 0$  est 0. La probabilité que la moyenne empirique soit supérieure à  $a \leq 0$  est alors d'exactement 1. Ceci est surprenant si on compare aux probabilités très petite mais approximées pour  $a \in [0; 1]$  qui restent vraies. C'est comme s'il ne pouvait pas y avoir de déviations inférieures à la moyenne. Cela est sûrement dû à un manque d'information donné par l'inégalité de Chernof, qui pour  $\forall a \leq 0$  donne  $\mathbb{P} \left[ \frac{1}{n} \sum_{i=1}^n X_i \geq a \right] \leq 1$ . Ceci est corrigé en appliquant le théorème de Cramér aussi aux  $-X_i$ , ce qui permet de trouver la déviation par rapport à la moyenne, par symétrie de la loi de Rademacher autour de son espérance.

### Théorème 1.22 (Théorème de Sanov)

Soient  $X_1, X_2, \dots, X_k$  des variables aléatoires i.i.d. suivant une distribution de probabilité  $P$ , où  $P = \{p_i\}_{i=1}^k$  désigne les probabilités théoriques associées à chaque  $X_i$ .

La probabilité d'observer une distribution empirique  $\hat{P} = \{\hat{p}_i\}_{i=1}^k$  après  $n$  observations est donnée par l'expression suivante :

$$\mathbb{P}[\hat{P}] \asymp e^{-n \cdot D_{KL}(\hat{P}||P)}, \quad (1.41)$$

où  $D_{KL}(\hat{P}||P)$  désigne la divergence de Kullback-Leibler (aussi appelée entropie relative) définie par :

$$D_{KL}(\hat{P}||P) := \sum_{i=1}^k \hat{p}_i \ln \left( \frac{\hat{p}_i}{p_i} \right). \quad (1.42)$$

et où le symbole  $\asymp$  signifie que c'est  $\frac{1}{n}$  fois le logarithme des deux expressions qui est égal dans la mesure où  $n$  tend vers l'infini (ie  $a_n \asymp b_n \leftrightarrow \lim_{n \rightarrow \infty} \frac{1}{n} \ln(a_n) = \lim_{n \rightarrow \infty} \frac{1}{n} \ln(b_n)$ )



En probabilité et en théorie de l'information, le théorème de Sanov est un peu différent, il traite de la probabilité de trouver la loi empirique *à l'intérieur* d'un ensemble  $A$ , plutôt que de trouver exactement une loi empirique  $\hat{p}$ . Le théorème prend alors une forme un peu différente avec des préfacteurs qui apparaissent devant l'exponentielle. Nous nous contenterons dans ce cours de la forme donnée ci-dessus.

**Exemple 7** Pour illustrer le théorème, on peut s'imaginer la situation suivante : Munis de  $n$  boules, on considère un ensemble de  $k$  boîtes où lors d'un lancée d'une boule, la probabilité que cette dernière tombe

dans la boîte  $k$  est de  $p_k$ .

Maintenant, on fixe nos distributions de probabilités  $P$  et  $\hat{P}$ . On va supposer que  $P$  correspond à la distribution de probabilité réelle qui dépend de la taille des boîtes les unes par rapport aux autres tandis que  $\hat{P}$  correspond à la distribution de probabilité étudiée par le lanceur.

Dans notre exemple, faisons l'hypothèse que le lanceur cherche à déterminer la probabilité d'observer une distribution uniforme au bout de  $n$  lancers, ie  $\hat{P} \sim U([1, k])$ .

En ce qui concerne la distribution de probabilité réelle  $P$ , on va considérer 2 cas de figures :

- *Distribution conforme* : les boîtes sont de tailles identiques donc la distribution de probabilité réelle  $P$  est aussi uniforme ie  $P \sim U([1, k])$ .
- *Distribution biaisée* : les boîtes ne sont pas de la même taille. On suppose que les boîtes impaires sont deux fois plus grandes que les boîtes paires ce qui peut se modéliser par la loi de probabilité suivante :

$$p_i = P(X_i = m) = \begin{cases} \frac{4}{3k} & \text{si } m \text{ est impaire} \\ \frac{2}{3k} & \text{si } m \text{ est paire} \end{cases} \quad (1.43)$$

$$\text{Sanity check : } \sum_i p_i = \frac{k}{2} \cdot (p_{\text{paire}} + p_{\text{impaire}}) = \frac{k}{2} \cdot \left(\frac{2}{3k} + \frac{4}{3k}\right) = \frac{k}{2} \cdot \frac{2}{k} = 1$$

À présent, on calcule la divergence de Kullbach-Leibler  $D_{KL}(\hat{P}||P)$  dans les deux cas de figures :

- Dans le premier cas où  $P$  est uniforme,  $\Rightarrow D_{KL}(\hat{P}||P) = \sum_{i=1}^k p_i \ln \left( \frac{p_i}{p_i} \right) = 0$
- Dans le deuxième cas où  $P$  est biaisée,  $\Rightarrow D_{KL}(\hat{P}||P) = \sum_{i=1}^k \frac{1}{k} \ln \left( \frac{1/k}{p_i} \right) = \sum_{p_{\text{paire}}} \frac{1}{k} \ln \left( \frac{1/k}{p_{\text{paire}}} \right) + \sum_{p_{\text{impaire}}} \frac{1}{k} \ln \left( \frac{1/k}{p_{\text{impaire}}} \right) = \frac{1}{2} \left[ \ln \left( \frac{1}{k} \cdot \frac{3k}{2} \right) + \ln \left( \frac{1}{k} \cdot \frac{3k}{4} \right) \right] = \frac{1}{2} \ln \left( \frac{9}{8} \right) = \ln \left( \frac{3}{2\sqrt{2}} \right) \approx 0.0257$

À partir de ces coefficients, on va pouvoir illustrer notre exemple, à savoir la probabilité d'observer une certaine distribution  $\hat{P}$ , ici uniforme, en fonction d'une distribution donnée  $P$  (en supposant  $n$  assez grand pour que le théorème s'applique), ici conforme et biaisée.

De cette exemple, on peut conclure que lorsque la distribution réelle  $P$  est uniforme, la probabilité d'observer une distribution  $\hat{P}$  uniforme vaut logiquement 1 tandis que pour la distribution  $\hat{P}$  biaisée, la probabilité de l'observer tend vers zéro à mesure que le nombre de lancers  $n$  augmente. ■

Avant de prouver le théorème de Sanov, il est nécessaire de s'intéresser à la notion d'entropie, en présentant l'entropie de Gibbs-Shannon et l'entropie relative.

## 1.5 Entropie de Gibbs-Shannon

**Définition 1.23** (Entropie de Gibbs-Shannon)

**Cas discret** Soit  $\{p_1, \dots, p_n\}$  avec  $0 \leq p_i \leq 1$ ,  $\sum_{i=1}^n p_i = 1$

$$H(p) = -\sum_{i=1}^n p_i \ln p_i. \quad (1.44)$$




Figure 1.2: Probabilité d'observation d'une distribution  $\hat{P}$  uniforme selon de la distribution réelle  $P$  en fonction du nombre de lancers  $n$

**Cas continu** Soit  $0 \leq p_X(x)$  avec  $\int_{-\infty}^{+\infty} p_X(x)dx = 1$

$$H(p) = - \int_{-\infty}^{+\infty} dx p_X(x) \ln p_X(x). \quad (1.45)$$

**Théorème 1.24** Soit le coefficient binomial  $C_n^k = \binom{n}{k} = \frac{n!}{k!(n-k)!}$ , alors ce coefficient est borné inférieurement et supérieurement tel que

$$\frac{\exp(nH(p = \frac{k}{n}))}{n+1} \leq \binom{n}{k} \leq \exp(nH(p = \frac{k}{n})) \quad (1.46)$$

On établit ainsi que  $\binom{n}{k} \asymp \exp(nH(p = \frac{k}{n}))$ .

**Preuve 5** On se concentre d'abord sur la borne supérieure.

On utilise la propriété  $\sum_{i=0}^n \binom{n}{i} (\frac{k}{n})^i (1 - \frac{k}{n})^{n-i} = 1$  (binôme de Newton), et en particulier

$$\begin{aligned} \binom{n}{k} \left(\frac{k}{n}\right)^k \left(1 - \frac{k}{n}\right)^{n-k} &\leq 1 \\ \binom{n}{k} \exp\left(n\left[\frac{k}{n} \ln\left(\frac{k}{n}\right) + \frac{n-k}{n} \ln\left(1 - \frac{k}{n}\right)\right]\right) &\leq 1 \\ \binom{n}{k} &\leq \exp(nH(p = \frac{k}{n})) \end{aligned} \quad (1.47)$$

Pour la borne inférieure, en reprenant le terme du binôme  $i = k$ , on a cette fois ci

$$\begin{aligned} (n+1) \binom{n}{k} \left(\frac{k}{n}\right)^k \left(1 - \frac{k}{n}\right)^{n-k} &\geq 1 \\ \binom{n}{k} &\geq \frac{\exp(nH(p = \frac{k}{n}))}{n+1} \end{aligned} \quad (1.48)$$

Le comportement du coefficient binomial lorsque  $n$  devient grand s'étend aux coefficients multinomiaux:

$$\binom{n}{k_1 k_2 \dots k_n} = \frac{n!}{k_1! k_2! \dots k_n!} \asymp \exp(nH(\{p_i = \frac{k_i}{n}\})). \quad (1.49)$$

Même si la preuve ci-dessus s'adapte bien au cas multinomial, une esquisse de preuve alternative est présentée ci-dessous en utilisant la formule de Stirling pour  $n$  et  $\{k_i\}_{i=1, \dots, n} \gg 1$ :

$$\frac{n!}{k_1! k_2! \dots k_n!} \asymp \frac{n^n}{\prod_i k_i^{k_i}} \frac{\overbrace{e^{-n}}^1}{e^{-\sum_i k_i}} = e^{-n(\sum_i \frac{k_i}{n} \ln(k_i) - \overbrace{\sum_i \frac{k_i}{n} \ln(n)}^1)} = e^{nH(\{p_i = \frac{k_i}{n}\})}, \quad (1.50)$$

en utilisant que  $\sum_i \frac{k_i}{n} = 1$  et que les termes en  $\sqrt{n}$ ,  $\sqrt{k_i}$  de la formule de Stirling sont exponentiellement négligeables asymptotiquement.

## 1.6 Entropie relative

**Définition 1.25** (*Entropie relative, ou divergence de Kullback-Leibler*)

L'entropie relative est définie entre deux distributions de probabilités,  $p$  et  $q$ , discrètes ou continues.

**Cas discret** Soient  $p = \{p_i\}$ ,  $q = \{q_i\}$  avec  $0 \leq p_i, q_i \leq 1$ ,  $\sum_{i=1}^n p_i = 1$  et  $\sum_{i=1}^n q_i = 1$ ,

$$D_{KL}(p||q) = \sum_{i=1}^n p_i \ln \left( \frac{p_i}{q_i} \right). \quad (1.51)$$

**Cas continu** Soient  $p_X(x)$  et  $q_X(x)$  les fonctions de densité de probabilité associées à respectivement  $p$  et  $q$ ,

$$D_{KL}(p||q) = \int_{\mathbb{R}} dx p_X(x) \ln \left( \frac{p_X(x)}{q_X(x)} \right) = \mathbb{E} \left[ \ln \left( \frac{p_X(x)}{q_X(x)} \right) \right]. \quad (1.52)$$



Noter que pour  $q = \{\frac{1}{n}\}$  une distribution uniforme sur  $n$  valeurs discrètes,  $D_{KL}(p||q) = -H(p) - \ln(\frac{1}{n})$ , i.e. la divergence de Kullback-Leibler se comporte alors à une constante près comme l'entropie de Gibbs-Shannon.

**Proposition 1.26** (*Propriété de Gibbs*)

Soient deux distributions de probabilités,  $p$  et  $q$ . Alors la divergence de Kullback-Leibler respecte

$$D_{KL}(p||q) \geq 0, \text{ avec } D_{KL}(p||q) = 0 \text{ ssi } p = q. \quad (1.53)$$

**Preuve 6** Puisque  $\ln(x) \leq x - 1 \ \forall x > 0$ , en particulier

$$\ln \left( \frac{q_i}{p_i} \right) \leq \frac{q_i}{p_i} - 1 \Rightarrow \sum_i p_i \ln \left( \frac{q_i}{p_i} \right) \leq \sum_i p_i \left( \frac{q_i}{p_i} - 1 \right) = \sum_i p_i - \sum_i q_i = 1 - 1 = 0 \quad (1.54)$$

en utilisation la normalisation des deux lois. Il apparaît ensuite que le cas d'égalité est bien donné par  $q_i = p_i \ \forall i$  puisque l'inégalité sur le logarithme est saturée seulement en 1. Le cas continu se traite de manière similaire, à la différence qu'il est possible d'exiger uniquement  $p = q$  presque partout pour le cas

d'égalité.

**R** La divergence de Kullback-Leibler exprime en quelque sorte à quel point deux lois de probabilité sont différentes l'une de l'autre puisqu'elle vaut 0 seulement quand les deux lois sont identiques. Cependant puisque elle n'est pas symétrique (et ne respecte pas l'inégalité triangulaire) on ne peut pas parler de distance au sens mathématique du terme, mais plutôt de divergence.

À partir de cela, montrons notre version du théorème de Sanov.

**Preuve 7** (*Théorème de Sanov*) La probabilité d'observer la distribution empirique  $\hat{p} = \{p_i\}_{i=1}^k$  à partir de  $N$  observations suivant la distribution "réelle"  $p$  est:

$$\begin{aligned}\mathbb{P}[\{\hat{p}_1, \dots, \hat{p}_k\}] &= p_1^{N\hat{p}_1} \dots p_k^{N\hat{p}_k} \binom{N}{N\hat{p}_1, \dots, N\hat{p}_k} \\ &= \binom{N}{N\hat{p}_1, \dots, N\hat{p}_k} e^{N \sum_i \hat{p}_i \ln(p_i)}.\end{aligned}\tag{1.55}$$

Et en utilisant l'approximation des coefficients multinomiaux :

$$\mathbb{P}[\{\hat{p}_1, \dots, \hat{p}_k\}] \asymp e^{N \sum_i \hat{p}_i \ln(p_i) - N \sum_i \hat{p}_i \ln(\hat{p}_i)} = e^{-ND_{KL}(\hat{p}||p)}.\tag{1.56}$$