

## Cours 2

Enseignant: A. Tchamkerten

Crédit L. Groléaz and J. Parvillers

Refs: Cover and Thomas Chapitres 2, 5.6-5.8, 2.5, 3, 7.6

## 1 Entropie et questionnement optimal

**Exemple 1.**  $X \in \mathcal{X}$

*But : Identifier  $X$  avec le moins de questions possibles.*

*Questions autorisées :  $X \in A \subseteq \mathcal{X}$  ?*

*Idée : Le questionnement équivaut à un code.*

*Ainsi le nombre moyen de questions est supérieur ou égal à  $H(X)$ .*

*Une stratégie de questionnement optimal correspond donc à un code de Huffman.*

## 2 Entropie et information mutuelle: propriétés

**Definition 1.**

$$\begin{aligned} H(X) &= - \sum_{x \in \mathcal{X}} p(x) \log p(x) \\ &= E_X \left( \log \frac{1}{p(X)} \right) \end{aligned}$$

**Exemple 2.**

$$X \in \{0, 1\}$$

avec  $p(X = 0) = p = 1 - p(X = 1)$

$$H(X) = -p \log p - (1 - p) \log(1 - p)$$

que l'on note  $H_b(p)$ .

**Theorem 2.**

$$0 \leq H(X) \leq \log(|\mathcal{X}|)$$

### Preuve du théorème

$$\begin{aligned} & \forall x \in \mathcal{X} \quad 0 \leq p(x) \leq 1 \\ \Rightarrow & \forall x \in \mathcal{X} \quad 0 \leq -\log(p(x)) \\ \Rightarrow & -\sum_{x \in \mathcal{X}} p(x) \log(p(x)) \geq 0 \end{aligned}$$

Pour l'autre inégalité : On note  $\forall x \in \mathcal{X} \quad u(x) = \frac{1}{|\mathcal{X}|}$   
alors

$$\begin{aligned} H(X) &= -\sum_x p(x) \log\left(\frac{p(x)u(x)}{u(x)}\right) \\ &= -D(P||U) + \log(\mathcal{X}) \end{aligned}$$

or  $D(P||U)$  est positif. D'où le résultat.

Avec égalité si et seulement si  $P$  est uniforme, i.e.  $D(P||U) = 0$ .

**Definition 3** (Entropie conjointe). *On suppose  $(X, Y) \sim P_{X,Y}$*

$$\begin{aligned} H(X, Y) &= -\sum_{x,y} p(x, y) \log p(x, y) \\ &= E_{X,Y}\left(\log \frac{1}{p(X, Y)}\right) \end{aligned}$$

**Definition 4** (Entropie conditionnelle). *On suppose  $(X, Y) \sim P_{X,Y}$*

$$\begin{aligned} H(X|Y) &= -\sum_{x,y} p(x, y) \log p(x|y) \\ &= -\sum_y p(y) \sum_x p(x|y) \log p(x|y) \\ \text{où } -\sum_x p(x|y) \log p(x|y) &\stackrel{\text{def}}{=} H(X|Y = y) \end{aligned}$$

**Remarque 1.**

$$\begin{aligned} X = Y &\Rightarrow H(X|Y) = 0 \\ X \perp Y &\Rightarrow H(X|Y) = H(X) \end{aligned}$$

**Theorem 5** (Chain Rule).  $H(X_1, X_2, \dots, X_n) = \sum_i H(X_{i+1}|X^i)$  où  $X^i = (X_1, X_2, \dots, X_i)$

**Preuve du théorème**

$$H(X_1, \dots, X_n) = -E(\log(p(X_1, \dots, X_n)))$$

Or  $p(X_1, \dots, X_n) = \prod_{i=1}^n p(X_i|X^{i-1})$  et ainsi

$$\begin{aligned} H(X_1, \dots, X_n) &= -\sum_{i=1}^n E(\log p(X_i|X^{i-1})) \\ &= \sum_{i=1}^n H(X_i|X^{i-1}) \end{aligned}$$

**Definition 6** (Information mutuelle).  $(X, Y) \sim P_{X,Y}$

$$I(X, Y) = \sum_{x,y} p(x, y) \log \frac{p(x,y)}{p(x)p(y)}$$

Où  $p(x) = \sum_y p(x, y)$  [Loi marginale]

**Theorem 7.** 1.  $I(X, Y) = I(Y, X)$

2.  $I(X, Y) = H(X) - H(X|Y)$

3.  $I(X, Y) = H(Y) - H(Y|X)$

4.  $I(X, Y) = H(X) + H(Y) - H(X, Y)$

5.  $I(X, X) = H(X)$

6.  $I(X, Y) = D(P_{X,Y} || P_X \cdot P_Y)$

7.  $I(X, Y) = 0 \Leftrightarrow X \perp Y$

8.  $H(Y) \geq H(Y|X)$

9.  $H(X^n) \leq \sum_{i=1}^n H(X_i)$  avec égalité ssi  $X_i$  sont iid

10.  $H(X)$  est concave en  $P_X$

11.  $\forall f H(X) \geq H(f(X))$

**Preuve du théorème**

1. Evident à partir de la définition
2. Développer  $H(X) - H(X|Y)$
3. Immédiat avec 1) et 2)
4. Chain rule.
5. Avec 2) car  $H(X|X) = 0$
6. Définition de  $D(P_{X,Y} || P_X P_Y)$
7.  $I(X, Y) = 0 \Leftrightarrow D(P_{X,Y} || P_X P_Y) = 0 \Leftrightarrow P_{X,Y} = P_X P_Y \Leftrightarrow X \perp Y$
8.  $H(Y) - H(Y|X) = I(X, Y) = D(P_{X,Y} || P_X P_Y) \geq 0$
9.  $H(X^n) = \sum_{i=1}^n H(X_i | X^{i-1})$  et  $H(X_i | X^{i-1}) \leq H(X_i)$  par (8).
10. Soit  $X \sim P_X$ ,  $Y \sim P_Y$ , et  $Z \sim P = \alpha P_X + (1 - \alpha) P_Y$ ,  $0 \leq \alpha \leq 1$ . Il s'agit de vérifier que

$$H(Z) \geq \alpha H(X) + (1 - \alpha) H(Y).$$

Soit  $T$  une variable aléatoire binaire, indépendante de  $X$  et de  $Y$  avec  $Pr(T = 1) = \alpha = 1 - Pr(T = 0)$ . Il suit que

$$Z = T \cdot X + (1 - T) \cdot Y.$$

D'où en utilisant (8),

$$\begin{aligned} H(Z) &\geq H(Z|T) \\ &= H(Z|T = 1)\alpha + H(Z|T = 0)(1 - \alpha) \\ &= H(X)\alpha + H(Y)(1 - \alpha). \end{aligned}$$

11.  $H(X) = H(X, f(X)) = H(f(X)) + H(X|f(X))$  et  $H(X|f(X)) \geq 0$ .

**Définition 2.1.** Pour

$$(X, Y, Z) \sim p(x, y, z).$$

On définit

$$I(X; Y|Z) = \mathbb{E}_{p(x,y,z)} \left[ \log \left( \frac{\mathbb{P}(X, Y|Z)}{\mathbb{P}(X|Z)\mathbb{P}(Y|Z)} \right) \right]$$

**Propriété 2.1.** (chain rule)

$$I(X_1 \dots X_n; Y) = \sum_{i \in [1, n]} I(X_i; Y | X^{i-1})$$

**Preuve:**

$$\begin{aligned} I(X^n; Y) &= H(X^n) - H(X^n | Y) \\ &= \sum_{i \in [1, n]} H(X_i | X^{i-1}) - H(X_i | X^{i-1}, Y) \\ &= I(X_i; Y | X^{i-1}) \end{aligned}$$

### 3 Typicalité

**Rappel: lois des grands nombres** Soit  $(Z_i)_{i \in [1, n]}$  une famille de variables aléatoires i.i.d. Alors:

$$\frac{1}{n} \sum_{i \in [1, n]} Z_i \xrightarrow[n \rightarrow +\infty]{\text{en probabilité}} \mathbb{E}(Z_1)$$

i.e.  $\forall \epsilon > 0, \forall \delta > 0, \exists N \in \mathbb{N}, \forall n \geq N,$

$$\mathbb{P} \left( \left| \frac{1}{n} \sum_{i \in [1, n]} Z_i - \mathbb{E}(Z_1) \right| \geq \epsilon \right) \leq \delta$$

### 4 Probabilité asymptotique d'équipartition

**Théorème 4.1.** (probabilité asymptotique d'équirépartition - A.E.P)

Soit  $(X_i)_{i \in [1, n]}$  une suite de variables aléatoires i.i.d. Alors:

$$-\frac{1}{n} \log [p(X_1, \dots, X_n)] \xrightarrow[n \rightarrow +\infty]{\text{en probabilité}} H(X)$$

**Preuve:**

$$\begin{aligned} -\frac{1}{n} \log [p(X_1, \dots, X_n)] &= -\frac{1}{n} \log \left[ \prod_{i \in [1, n]} p(x_i) \right] \\ &= -\frac{1}{n} \sum_{i \in [1, n]} \log [p(x_i)] \\ &\xrightarrow[n \rightarrow +\infty]{} \mathbb{E} \left[ \log \left( \frac{1}{X} \right) \right] = H(X) \end{aligned}$$

**Définition 4.1.** (ensemble typique)

L'ensemble typique par rapport à une distribution  $p(x)$  est défini par:

$$\mathcal{A}_\epsilon^n = \{x^n : 2^{-n(H(X)+\epsilon)} \leq p(x^n) \leq 2^{-n(H(X)-\epsilon)}\}$$

**Propriété 4.1.**

$\forall \epsilon > 0, \exists N \in \mathbb{N}, \forall n \geq N,$

$$\begin{aligned} \mathbb{P}(\mathcal{A}_\epsilon^n) &\geq 1 - \epsilon \\ |\mathcal{A}_\epsilon^n| &\leq 2^{n(H(X)+\epsilon)} \\ |\mathcal{A}_\epsilon^n| &\geq (1 - \epsilon)2^{n(H(X)-\epsilon)} \end{aligned}$$

**Preuve:**

$\forall \epsilon > 0,$  et pour  $n$  suffisamment grand, l'A.E.P donne:

$$\mathbb{P}(\mathcal{A}_\epsilon^n) = \mathbb{P}\left(\left|\frac{1}{n} \log \left(\frac{1}{p(x_i)}\right) - H(X)\right| \leq \epsilon\right) \geq 1 - \epsilon$$

$$\begin{aligned} 1 = \sum_{x^n \in [1, n]} p(x^n) &\geq \sum_{x^n \in \mathcal{A}_\epsilon^n} p(x^n) \\ &\geq \sum_{x^n \in \mathcal{A}_\epsilon^n} 2^{-n(H(X)+\epsilon)} \\ D'où |\mathcal{A}_\epsilon^n| &\leq 2^{n(H(X)+\epsilon)} \end{aligned}$$

Pour  $n$  suffisamment grand,

$$\begin{aligned} 1 - \epsilon &\leq \mathbb{P}(\mathcal{A}_\epsilon^n) \\ &= \sum_{x^n \in \mathcal{A}_\epsilon^n} p(x^n) \\ &\leq |\mathcal{A}_\epsilon^n| 2^{-n(H(X)-\epsilon)} \end{aligned}$$

D'où  $(1 - \epsilon)2^{n(H(X)-\epsilon)}$

**Remarque:** on notera dès lors " $a_n \doteq b_n$ " lorsque  $\forall \epsilon > 0, \exists N \in \mathbb{N}, \forall n \geq N,$

$$\left|\frac{1}{n} \log \left(\frac{a_n}{b_n}\right)\right| \leq \epsilon$$

## 5 Codage de source revisité

Un code  $\mathcal{C}$  est tel que:

$$\mathcal{C} : x^n = (x_1, \dots, x_n) \mapsto \mathcal{C}(x_1, \dots, x_n)$$

$$\begin{cases} \text{Si } x^n \in \mathcal{A}_\epsilon^n \text{ alors: } \mathcal{C}(x^n) \triangleq c_1 \dots c_k \\ \text{Si } x^n \notin \mathcal{A}_\epsilon^n \text{ alors: } \mathcal{C}(x^n) \triangleq c_1 \dots c_l \end{cases}$$

Avec:

$$\begin{cases} k \leq n(H(X) + \epsilon) + 1 \\ l \leq n \log |\mathcal{X}| + 1 \end{cases}$$

Et alors:

$$\begin{aligned} L(\mathcal{C}) &= \sum_{x \in \mathcal{X}} l(x^n) p(x^n) \\ &= \sum_{x^n \in \mathcal{A}_\epsilon^n} l(x^n) p(x^n) + \sum_{x^n \notin \mathcal{A}_\epsilon^n} l(x^n) p(x^n) \\ &\leq n(H(X) + \epsilon) + 1 + \epsilon(n \log |\mathcal{X}| + 1) \triangleq n(H(X) + \epsilon'(n)) \end{aligned}$$

où  $\epsilon'(n) = \epsilon(1 + \log |\mathcal{X}| + 1/n) + 1/n$

## 6 Typicalité conjointe

**Définition 6.1.**

$$\tilde{\mathcal{A}}_\epsilon^n = \left\{ (x^n, y^n), \begin{cases} \left| -\frac{1}{n} \log(p(x^n)) - H(X) \right| \leq \epsilon \\ \left| -\frac{1}{n} \log(p(y^n)) - H(Y) \right| \leq \epsilon \\ \left| -\frac{1}{n} \log(p(x^n, y^n)) - H(X, Y) \right| \leq \epsilon \end{cases} \right\}$$

**Théorème 6.1.**

Si  $(X^n, Y^n) \sim \prod_{i \in [1, n]} p(x_i, y_i)$ , alors  $\forall \epsilon > 0, \exists N \in \mathbb{N}, \forall n \geq N$ :

$$\begin{aligned} \mathbb{P} \left( (X^n, Y^n) \in \tilde{\mathcal{A}}_\epsilon^n \right) &\xrightarrow{n \rightarrow +\infty} 1 \\ |\mathcal{A}_\epsilon^n| &\leq 2^{n(H(X, Y) + \epsilon)} \end{aligned}$$

Si  $(\bar{X}^n, \bar{Y}^n) \sim \prod_{i \in [1, n]} p(x_i) p(y_i)$  alors  $\forall \epsilon > 0, \exists N \in \mathbb{N}, \forall n \geq N$ :

$$\begin{aligned} \mathbb{P} \left( (\bar{X}^n, \bar{Y}^n) \in \tilde{\mathcal{A}}_\epsilon^n \right) &\leq 2^{-n(I(X, Y) - 3\epsilon)} \\ \mathbb{P} \left( (\bar{X}^n, \bar{Y}^n) \in \tilde{\mathcal{A}}_\epsilon^n \right) &\geq (1 - \epsilon) 2^{-n(I(X, Y) + 3\epsilon)} \end{aligned}$$

**Preuve:**

$$\tilde{\mathcal{A}}_\epsilon^n = \mathcal{A}_1 \cap \mathcal{A}_2 \cap \mathcal{A}_3 \quad \begin{cases} \mathbb{P}(\mathcal{A}_1) \geq 1 - \epsilon/3 \\ \mathbb{P}(\mathcal{A}_2) \geq 1 - \epsilon/3 \\ \mathbb{P}(\mathcal{A}_3) \geq 1 - \epsilon/3 \end{cases}$$

$$\begin{aligned}
\mathbb{P}(\tilde{\mathcal{A}}_\epsilon^n) &= \mathbb{P}(\mathcal{A}_1 \cap \mathcal{A}_2 \cap \mathcal{A}_3) \\
&= 1 - \mathbb{P}((\mathcal{A}_1 \cap \mathcal{A}_2 \cap \mathcal{A}_3)^c) \\
&= 1 - \mathbb{P}(\mathcal{A}_1^c \cup \mathcal{A}_2^c \cup \mathcal{A}_3^c) \\
&\geq 1 - \epsilon
\end{aligned}$$

$$\begin{aligned}
1 &= \sum_{(x^n, y^n) \in \mathcal{X} \times \mathcal{Y}} p(x^n, y^n) \\
&\geq \sum_{(x^n, y^n) \in \mathcal{A}_n^\epsilon} p(x^n, y^n) \\
&\geq 2^{-n(H(X, Y) + \epsilon)} |\tilde{\mathcal{A}}_n^\epsilon|
\end{aligned}$$

$$\begin{aligned}
\mathbb{P}((\bar{X}^n, \bar{Y}^n) \in \mathcal{A}_\epsilon^n) &= \sum_{(x^n, y^n) \in \mathcal{A}_n^\epsilon} p(x^n) p(y^n) \\
&\leq \sum 2^{-n(H(X) - \epsilon)} 2^{-n(H(Y) - \epsilon)} \\
&\leq 2^{n(H(X, Y) - H(X) - H(Y) + 3\epsilon)} \\
&= 2^{n(I(X, Y) + 3\epsilon)}
\end{aligned}$$