## Université Paris 8

Année 2022–2023

# M1 Mathématiques et applications, parcours ACC

# Théorie de l'information – Solutions feuille de TD 8

### 23/11/2022

Retrouvez le sujet du TD et d'autres exercices à l'adresse :

www.math.univ-paris13.fr/~lavauzelle/teaching/2022-23/theorie-information.html

(\*) exercice fondamental

(★★) pour s'entraîner

 $(\star\star\star)$  pour aller plus loin

## Exercice 1. $\square$ (\*\*) Implantation de l'algorithme LZW.

**Question 1.–** Implanter l'algorithme de codage LZW vu dans le cours. L'algorithme prendra en entrée le message à coder, ainsi que l'alphabet de la source.

(si besoin, on pourra commencer par supposer que l'alphabet est  $\{0,1\}$ )

Question 2.- Tester l'algorithme sur les instances et exemples présentés en cours.

**Question 3.–** Implanter une source X sans mémoire sur  $\mathcal{X} = \{0,1\}$  telle que pour tout  $n \in \mathbb{N}$ , on a  $p(X_n = 1) = 0.1$ . Puis, calculer la longueur moyenne du codage d'une suite N bits par LZW (avec N grand), et comparer avec  $\overline{H}(X)$ .

**Question 4.–** Implanter une source binaire X markovienne (pas nécessairement stationnaire) de son choix. Puis, calculer la longueur moyenne du codage d'une suite N bits par LZW (avec N grand), et comparer avec  $\overline{H}(X)$ .

### Solutions de l'Exercice 1.

Voir scripts.

## Exercice 2. $(\star\star)$ Entropie et codage par plage.

Soit  $X = (X_1, ..., X_N)$  une séquence finie de  $N \ge 1$  variables aléatoires binaires. On définit  $R = (R_1, ..., R_M)$ , où les variables  $R_m$  sont à valeurs sur  $\mathbb{N}^+$ , comme la séquence des longueurs de plages de symboles identiques dans X. Notons que  $M \le N$ , et que la valeur de M dépend de la réalisation des  $X_n$ . Par exemple, si N = 13 et si X se réalise comme (1100010000111), alors la variable R vaut (2,3,1,4,3) et M = 5.

On note H(X) l'entropie de la variable conjointe des  $(X_1, ..., X_N)$ . De même, H(R) est l'entropie de la variable conjointe des  $(R_1, ..., R_M)$ .

**Question 1.–** Démontrer que  $H(R, X_1) = H(X)$ .

**Question 2.–** En déduire que  $H(X) - H(X_1) \le H(R) \le H(X)$ .

### Solutions de l'Exercice 2.

**Solution Q1.** Par définition, les variables R et  $X_1$  sont construites de manière déterministe en fonction de X. Autrement dit, il existe une fonction déterministe g telle que  $g(X) = (R, X_1)$ : cette fonction correspond exactement à calculer les entiers et la première lettre du codage RLE (codage par plage). D'après le principe de non-création d'information, on a donc

$$H(\mathbf{R}, X_1) = H(g(\mathbf{X})) \le H(\mathbf{X})$$

Inversement, soit

$$f:(r_1,\ldots,r_m,x_1)\mapsto(\underbrace{x_1\ldots x_1}_{r_1\text{ fois}}\underbrace{\overline{x_1}\ldots\overline{x_1}}_{r_2\text{ fois}}\underbrace{x_1\ldots x_1}_{r_3\text{ fois}}\ldots)$$

où  $\overline{x_1} = 1 - x_1$ , c'est-à-dire  $\overline{x_1} = 0$  si  $x_1 = 1$ , et inversement. On observe que  $f(R, X_1) = X$ . Ainsi, par le même principe de non-création d'information, on a  $H(X) \le H(R, X_1)$ . On en déduit :

$$H(\mathbf{R}, X_1) = H(\mathbf{X})$$
.

Solution Q2. On utilise les formules du cours sur l'encadrement de l'entropie conjointe. D'une part :

$$H(\mathbf{R}) \leq H(\mathbf{R}, X_1) = H(\mathbf{X}).$$

D'autre part :

$$H(X) = H(R, X_1) \le H(R) + H(X_1)$$
.

## Exercice 3. $(\star\star)$ Longueurs de plages.

Soit  $X = (X_n)_{n \ge 1}$  un processus stochastique sans mémoire, dont les variables  $X_n$  sont binaires et uniformes. On note N la variable aléatoire comptant la longueur de la première plage de symboles identiques, c'est-à-dire telle que

$$X_{N+1} \neq X_N$$
 et  $\forall 2 \leq n \leq N, X_n = X_{n-1}$ .

On note enfin  $Y := (X_1, \dots, X_N)$ .

**Question 1.–** Déterminer le domaine des valeurs prises par les variables *N* et *Y*?

**Question 2.–** Déterminer la loi de *N*, la loi de *Y* conditionnée à *N* puis en déduire la loi de *Y*.

Question 3.- Démontrer que :

- 1. H(Y) = 3,
- 2. H(Y|N) = 1 (et interpréter),
- 3. I(Y; N) = 2.

#### Solutions de l'Exercice 3.

**Solution Q1.** La variable N prend les valeurs  $n \in \mathbb{N}^+$ . La variable Y, quant à elle, peut prendre les valeurs  $\underbrace{0\dots0}_{n \text{ fois}}$  et  $\underbrace{1\dots1}_{n \text{ fois}}$  pour n'importe quel  $n \ge 1$ .

#### Solution O2.

— **Loi de** *N*. Pour tout  $n \ge 1$  on a

$$\mathbb{P}(N=n) = \sum_{c \in \{0,1\}} \mathbb{P}(X_1 = c \text{ et } \cdots \text{ et } X_n = c \text{ et } X_{n+1} = 1 - c) = 2 \times \frac{1}{2^{n+1}} = \frac{1}{2^n}.$$

— Loi de Y conditionnée à N. Pour  $c \in \{0,1\}$  et  $\ell \ge 1$  on note  $c^{(\ell)} \coloneqq \underbrace{c \cdots c}_{\ell \text{ fois}}$ . On a alors

$$\mathbb{P}(Y = c^{(\ell)} \mid N = \ell) = \frac{1}{2}$$

car si  $N=\ell$ , les deux seuls valeurs pour Y sont  $c^{(\ell)}$  et son complément  $\overline{c^{(\ell)}}$ , et ces évènements sont équiprobables

— Loi de Y. Enfin, pour tout  $c \in \{0,1\}$  et tout  $\ell \ge 1$ , on a :

$$\mathbb{P}(Y = c^{(\ell)}) = \sum_{i=1}^{+\infty} \mathbb{P}(Y = c^{(\ell)} \mid N = i) \mathbb{P}(N = i) = \frac{1}{2} \times \frac{1}{2^{\ell}} = \frac{1}{2^{\ell+1}}$$
.

Solution Q3. On utilise les résultats de la Question 2.

1. D'abord,

$$H(\mathbf{Y}) = -\sum_{c \in \{0,1\}} \sum_{n \geq 1} \mathbb{P}(\mathbf{Y} = \mathbf{c}^{(n)}) \log_2 \mathbb{P}(\mathbf{Y} = \mathbf{c}^{(n)}) = 2 \sum_{n \geq 1} \frac{n+1}{2^{n+1}}.$$

On rappelle que la série  $\sum_{n\geq 0} n\gamma^n$  converge vers  $\frac{\gamma}{(1-\gamma)^2}$ . Pour  $\gamma=\frac{1}{2}$ , on obtient donc :

$$H(Y) = 2 \cdot \left(\frac{1/2}{(1-1/2)^2} - \frac{1}{2}\right) = 3.$$

2. La loi de Y conditionnée à N est connue. On peut donc l'utiliser ici :

$$H(Y \mid N) = \sum_{n \ge 1} \mathbb{P}(N = n) H(Y \mid N = n) = \sum_{n \ge 1} \frac{1}{2^n} \times h(1/2) = \sum_{n \ge 1} \frac{1}{2^n} = 1.$$

Interprétation : lorsque N est connu, il ne reste qu'un bit d'indétermination : la valeur prise par la plage de symboles identiques.

3. On utilise la formule bien connue du cours :

$$I(Y; N) = H(Y) - H(Y \mid N) = 3 - 1 = 2.$$