

TD n° 1 : Probabilités, entropie et information

1.

Montrer que la *quantité d'information*, exprimée en *shannons*, associée à une source S, dont les N signes de son alphabet sont équiprobables, peut se mettre sous la forme :

$$H(S) = \frac{\log_B N}{\log_B 2} [sh]$$

La *quantité d'information* est parfois exprimée en « *dits* », cette unité représentant l'information d'une expérience présentant N=10 issues équiprobables. Préciser la relation qui existe entre le « *dit* » et le « *shannon* ».

Calculer la *quantité d'information* associée à une expérience dont le résultat est certain. Choisissons, par exemple, la une source qui émet la phrase suivante : « Demain il fera jour ».

Analyser la fonction H(p) qui définit l'entropie d'une expérience à deux issues (dont les probabilités sont égales à p et 1-p). Les propriétés de continuité, valeur maximum, intersection avec l'axe devront être abordées. Représenter graphiquement cette fonction lorsque p varie de 0 à 1.

2.

Calculer la *quantité d'information* associée à une expérience ayant 8 résultats équiprobables. Montrer que l'on peut décomposer cette expérience en 3 expériences successives indépendantes ayant chacune 2 résultats équiprobables. Montrer que la quantité d'information totale est la somme des quantités d'information associées à chacune des 3 expériences partielles.

3.

Quelle est la *quantité d'information* associée à l'expérience qui consiste à déterminer si « une carte extraite d'un jeu de 52 cartes est un honneur » ou « n'est pas un honneur ». C'est à dire de calculer la quantité moyenne d'information contenue dans le message créé par l'expérience : « la carte tirée est un honneur ». Comparer cette valeur avec celle qui serait obtenue pour le message « la carte tirée est le roi du coeur ».

4.

Considérons un texte écrit en français. Ce texte a été modifié de manière à ne plus présenter majuscules, accents et ponctuation. Calculer $H_{\max}(S)$ – la valeur maximum de la *quantité d'information moyenne* par lettre. Quand est-ce que ce maximum est atteint?

Une étude probabiliste effectuée sur document d'environ 150 pages écrit en français conduit à une modélisation du texte par une source sans mémoire (cf. tableau ci-dessous). Calculer $H_0(S)$ – la *quantité d'information moyenne* par lettre. Si on disposait d'une modélisation du texte par une source avec une mémoire d'ordre 1, quelle serait la valeur de $H_1(S)$ par rapport à $H_0(S)$.

| lettre | % | Lettre | % | Lettre | % | Lettre | % | Lettre | % | Lettre | % |
|--------|-------|--------|------|--------|------|--------|------|--------|-------|--------|------|
| A | 6,4 | B | 0,64 | C | 2,59 | D | 2,6 | E | 14,86 | G | 0,83 |
| H | 0,61 | I | 5,91 | J | 0,23 | K | 0,01 | L | 4,65 | M | 2,45 |
| N | 6,23 | O | 4,59 | P | 2,56 | Q | 0,81 | R | 5,55 | S | 6,97 |
| T | 5,72 | U | 5,06 | W | 0 | X | 0,31 | Y | 0,21 | Z | 0,08 |
| Espace | 18,35 | | | | | | | | | | |

5.

Supposons que nous avons une course de chevaux dont les probabilités de gagner pour chacun de 8 chevaux participants à la course sont : $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$. Calculer l'entropie de cette course.

Deduire la *logueur moyenne du message* contenant le résultat de cette course. Proposer une *méthode de codage du message* contenant le résultat de cette course.

6.

Une source émet selon un code décimal codé binaire (DCB). Déterminer la *quantité moyenne d'information* par symbole binaire. Calculer cette quantité par symbole décimale.

7.

Soit deux sources discrètes X et Y liées par la loi de couple $P(y_i, x_j)$ donnée ci-dessous :

| $y_j \backslash x_i$ | x_1 | x_2 | x_3 | P_j |
|----------------------|-------|-------|-------|-------|
| y_1 | 0.1 | 0.2 | 0 | 0.3 |
| y_2 | 0 | 0.3 | 0 | 0.3 |
| y_3 | 0 | 0.2 | 0.2 | 0.4 |
| P_i | 0.1 | 0.7 | 0.2 | |

Déterminer :

- l'entropie $H(XY)$ de la source composée (XY),
- les entropies $H(X)$ et $H(Y)$ des sources X et Y,
- les entropies conditionnelles moyennes $H(Y|X)$ et $H(X|Y)$,
- l'information mutuelle moyenne $I(X; Y)$ des sources X et Y. Montrer que l'on peut calculer cette quantité de 3 manières différentes.