


## Théorie de l'information – Feuille de TD 4

14/10/2021

Le corrigé de certains exercices sera disponible à l'adresse suivante :

[www.math.univ-paris13.fr/~lavauzelle/teaching/2021-22/theorie-information.html](http://www.math.univ-paris13.fr/~lavauzelle/teaching/2021-22/theorie-information.html)

(★) exercice fondamental    (★★) pour s'entraîner    (★★★) pour aller plus loin     sur machine

**Exercice 1. (★) Codes de Huffman et de Shannon–Fano.**

Soit  $X$  une variable aléatoire donnée par la distribution de probabilité  $(\frac{1}{3}, \frac{1}{3}, \frac{1}{4}, \frac{1}{12})$ .

**Question 1.**– Quel est le code de Shannon–Fano associé à cette variable aléatoire ?

**Question 2.**– Trouver deux codes de Huffman distincts (c'est-à-dire, avec des longueurs de mots différentes) pour la source  $X$ . Comparer leur longueur moyenne à celle du code de Shannon–Fano.

**Exercice 2. (★★) Code sur la loi conjointe.**

Soit  $\mathcal{X} = \{a, b\}$  et  $X, Y$  deux variables indépendantes sur  $\mathcal{X}$  de même loi de Bernoulli de paramètre  $\lambda$ . On note  $Z = (X, Y)$  la variable produit, définie sur  $\mathcal{X}^2$ , de loi conjointe  $p_{X,Y}$ .

**Question 1.**– Calculer  $\mathbb{P}(Z = z)$  pour tout  $z = (x, y) \in \mathcal{X}^2$ .

**Question 2.**– Quelle est l'entropie de  $Z$  ?

**Question 3.**– Décrire le code de Huffman de source  $Z$ . Selon la valeur de  $\lambda$ , on pourra distinguer plusieurs formes pour l'arbre binaire associé au code.

**Question 4.**– Tracer le graphe de la longueur moyenne du code de Huffman en fonction de  $\lambda$ . Sous quelle condition sur  $\lambda$  le code de Huffman est-il strictement meilleur que le code de longueur fixe égale à 2 ?

**Question 5.**– Décrire le code de Shannon–Fano de source  $Z$ . On donnera les longueurs des mots en fonction de  $\lambda$ .

**Question 6.**– Sous quelle condition sur  $\lambda$  le code de Shannon–Fano est-il strictement meilleur que le code de longueur fixe égale à 2 ? On pourra s'aider d'un logiciel pour les résolutions numériques.

**Exercice 3. (★★) Mots prépondérants dans un code de Huffman.**

Considérons le code de Huffman sur une source  $X$  de distribution  $p_1 \geq \dots \geq p_m$ .

**Question 1.**– Démontrer que si la probabilité d'occurrence la plus forte vérifie  $p_1 > 2/5$ , alors le symbole associé à cette probabilité est encodé par un mot de longueur 1.

**Question 2.**– Démontrer que s'il existe un mot de longueur 1, alors la probabilité  $p_1 \geq 1/3$ .

#### **Exercice 4. (\*\*) Code gamma.**

Dans cet exercice, on souhaite coder efficacement une source à valeur dans l'ensemble des entiers naturels, sans avoir d'information préalable sur les entiers émis par la source.

Usuellement, pour coder un entier  $n \in \mathbb{N}$  sous forme de chaîne de bits, on décompose l'entier en base 2 :

$$n = \sum_{i=0}^k n_i 2^i,$$

et on retourne la séquence  $B(n) = (n_0, \dots, n_k) \in \{0, 1\}^{k+1}$  de longueur  $k+1$ , où  $k = \lfloor \log_2(n) \rfloor$  (excepté pour  $n = 0$ , pour lequel on a  $k = 0$ ).

**Question 1.**– Le code  $B : \mathbb{N} \rightarrow \{0, 1\}^+$  est-il préfixe ? Est-il uniquement décodable ? Pourquoi ?

Le code Gamma, introduit par Elias, propose une solution au problème précédent. Avant d'encoder l'entier  $n$  sous la forme de sa décomposition en base 2, on précise à l'aide d'un code unaire la longueur de  $n$ . Ainsi, le code  $\Gamma : \mathbb{N} \rightarrow \{0, 1\}^+$  est défini par :

$$\Gamma(n) = \underbrace{0 \dots 0}_{\leftarrow 1 + \lfloor \log_2(n) \rfloor \rightarrow} 1 B(n) \quad \text{pour } n \geq 1,$$

et  $\Gamma(0) = 10$ .

**Question 2.**– Le code  $\Gamma$  est-il préfixe ?

**Question 3.**– Quelle est la longueur de  $\Gamma(n)$  pour  $n \in \mathbb{N}$  ? Donner une condition sur la distribution  $(p_n)$  de la source pour que la longueur moyenne du code  $\Gamma$  soit finie.

**Question 4.**– (\*\*\*)

1.  Calculer numériquement des valeurs approchées de la longueur moyenne du code  $\Gamma$  lorsque :
  - $X$  suit une loi uniforme sur  $\{0, 1, \dots, N\}$  (et  $p_X(n)$  est nulle pour  $n \geq N$ ),
  - $X$  suit une loi géométrique,
  - $X$  suit une loi de Poisson.
2. Le code Gamma peut être vu comme le codage unaire de la taille en bits de  $n$ , concaténé avec la représentation binaire de  $n$ . Peut-on itérer ce procédé pour obtenir un code encore plus court ? Quelle est la longueur du codage de l'entier  $n$  obtenu ?

#### **Exercice 5. (\*\*\*) Borne entropique et codes optimaux.**

**Question 1.**– Pour quelle valeur de  $\lambda$  la variable de Bernoulli de paramètre  $\lambda$  donne un code de Shannon–Fano optimal ?

**Question 2.**– Soit  $m$  un entier  $\geq 3$  quelconque. Trouver une variable aléatoire sur  $\{x_1, \dots, x_m\}$  telle que le code de Shannon–Fano associé est optimal.

**Question 3.**– Soit  $\epsilon > 0$ . Déterminer une distribution sur une variable aléatoire  $X$  telle que, pour tout code  $C$  sur  $X$ , la longueur moyenne  $\bar{\ell}(C) \geq H(X) + 1 - \epsilon$ .

**Question 4.**– Soit  $\epsilon > 0$ . Déterminer une distribution sur une variable aléatoire  $X$  telle que le code de Shannon–Fano sur  $X$  a une longueur moyenne  $\bar{\ell}(C_{SF}) \geq H(X) + 1 - \epsilon$ , et le code de Huffman sur  $X$  a une longueur moyenne  $\bar{\ell}(C_H) \leq H(X) + \epsilon$ .