

## DEVOIR MAISON 1

*Les notations qui ne sont pas rappelées sont celles du cours. Vous êtes autorisés à réfléchir à plusieurs sur les exercices (pas plus de deux ou trois). Cependant, la rédaction doit être individuelle et chacun doit rendre une copie. Précisez les noms de vos collaborateurs.*

**Exercice 1**

On considère une source ayant un alphabet de  $M = 4$  symboles ayant des probabilités  $p_1 \geq p_2 \geq p_3 \geq p_4 > 0$ .

1. Quels sont les arbres de Huffman possibles si  $p_1 = p_3 + p_4$  ?
2. Quelle est la plus grande valeur de  $p_1$  telle que  $p_1 = p_3 + p_4$  ? La plus petite ?

On note respectivement  $p_{\max}$  et  $p_{\min}$  ces valeurs.

3. Montrer que si  $p_1 > p_{\max}$ , alors tout code de Huffman a un mot-code de longueur 1.
4. Montrer que si  $p_1 < p_{\max}$ , alors tous les mots-code ont longueur 2 pour tout code de Huffman.
5. On suppose  $M > 4$ . Trouver la plus petite valeur  $p'_{\max}$  telle que  $p_1 > p'_{\max}$  garantisse qu'un code de Huffman aura un mot-code de longueur 1.

**Exercice 2****Codage de Huffman pour des lettres équiprobables**

Une variable aléatoire prend ses valeurs dans un alphabet de  $K$  lettres et chaque lettre a la même probabilité. Ces lettres sont encodées dans des mots binaires de façon à minimiser la longueur moyenne des mots-code. On définit l'entier  $j$  et le réel  $1 \leq x < 2$  tel que  $K = x2^j$ .

1. Montrer que tous les mots-code sont de longueur  $j$  ou  $j + 1$ .
2. Quelle est la longueur moyenne d'un mot-code ?

**Exercice 3****Le paradoxe de St Petersburg**

On considère le jeu suivant : le joueur paye un droit d'entrée de  $c$  euros, et reçoit  $2^k$  euros avec probabilité  $2^{-k}$ .

1. Quel est le gain moyen du joueur ?

On pourrait donc penser que quelque soit  $c$ ,  $c$  est un juste prix... On suppose maintenant que le joueur peut jouer une fraction de  $c$  : s'il paye  $c/2$ , alors il reçoit la récompense  $X/2$  où  $\mathbf{P}(X = 2^k) = 2^{-k}$ . Supposons que  $X_1, X_2, \dots$ , sont i.i.d. distribuées comme  $X$  et sont les gains successifs lorsque  $c$  est payé. On suppose que le joueur réinvestit toute sa fortune à chaque fois. Au début sa fortune est 1. Après un tout, sa fortune est donc  $X_1/c$ .

2. Donne une expression de la fortune  $S_n$  du jour après  $n$  tours. Montrer que  $S_n$  tend vers 0 ou  $+\infty$  selon que  $c < c^*$  ou  $c > c^*$ . Quelle est la valeur de  $c^*$  ?

On appelle  $c^*$  le juste prix d'entrée.

On admet que le joueur peut garder une partie de sa fortune. On suppose qu'à chaque tour il garde une proportion  $\bar{b} = 1 - b$  de sa fortune.

3. Donner une nouvelle expression pour la fortune du joueur après  $n$  tours. On note toujours  $S_n$  cette quantité.

4. À partir de quelle valeur de  $c$  le joueur choisit-il de miser toute sa fortune ?  
 5. Si le gain est maintenant tel que  $\mathbf{P}(X = 2^{2^k}) = 2^{-k}$ , faut-il miser toute sa fortune ?

#### Exercice 4

Soit  $X$  une variable aléatoire à valeurs dans  $\mathbb{N} = \{0, 1, 2, \dots\}$  et de distribution  $(p(x))_{x \in \mathbb{N}}$ . Un encodage binaire de  $X$  est une injection  $\varphi : \mathbb{N} \rightarrow \{0, 1\}^*$  de  $\mathbb{N}$  dans l'ensemble des mots binaires finis (y compris le mot vide). La longueur moyenne de l'encodage  $\varphi$  est :  $\ell(\varphi) = \sum_{x \in \mathbb{N}} p(x) |\varphi(x)|$ , où  $|\varphi(x)|$  est la longueur du mot  $\varphi(x)$ .

Dans certain cas, s'il existe un symbole encodant la fin d'un message, il n'est pas nécessaire de considérer des codes ayant la propriété du préfixe. On définit donc

$$\mathcal{L}_{1:1}(X) = \min\{\ell(\varphi), \varphi \text{ est un encodage de } X\}.$$

1. Montrer que  $\mathcal{L}_{1:1}(X) \leq H(X)$ . Donner un encodage optimal.
2. Montrer que pour toute variable aléatoire  $U$  à valeurs dans  $\mathbb{N}$ , on a  $H(U) \leq \log(\mathbf{E}[U] + 1) + \log e$ .
3. En déduire que  $H(X) \leq \mathcal{L}_{1:1}(X) + \log(\mathcal{L}_{1:1}(X) + 1) + \log e$ , puis donner une borne inférieure pour  $\mathcal{L}_{1:1}(X)$ . On pourra utiliser l'axiome (A8) du TD1 dans la définition axiomatique de l'entropie, avec une partition bien choisie.

On considère maintenant le problème suivant :  $(X, Y)$  est un couple de variables aléatoires à valeurs dans l'espace dénombrable  $\mathcal{X} \times \mathcal{Y}$  de distribution  $p(x, y)$ . Alice connaît  $X$ , Bob connaît  $Y$  et veut connaître  $X$ . On suppose qu'Alice peut communiquer vers Bob sans erreur ; que Bob doit pouvoir déterminer la fin d'un message d'Alice ; qu'Alice et Bob se sont mis d'accord sur un protocole déterministe qui peut dépendre de  $p$ . Le but est de trouver le nombre moyen de bits qu'Alice doit envoyer à Bob. On définit le support  $S = \{(x, y), p(x, y) > 0\}$  et  $x \neq x'$  sont ambigus s'il existe  $y$  tel que  $(x, y), (x', y) \in S$ . Un protocole pour des entrées restreintes est une fonction  $\varphi : \mathcal{X} \rightarrow \{0, 1\}^*$  telle que pour  $x$  et  $x'$  ambigus,  $\varphi(x)$  n'est pas un préfixe (au sens large) de  $\varphi(x')$ . On définit le nombre de bits moyens pour  $\varphi$  comme précédemment :  $\ell(\varphi) = \sum_{x \in \mathbb{N}} |\varphi(x)| p(x)$ .

On définit alors  $\bar{L} = \min\{\ell(\varphi), \varphi \text{ est un protocole pour entrées restreintes } (X, Y)\}$ .

4. Montrer que  $H(X|Y) \leq \bar{L} \leq H(X) + 1$ , que ces bornes sont les meilleures possibles et qu'elles peuvent être arbitrairement éloignées l'une de l'autre.

Clairement,  $\bar{L}$  ne dépend de  $(X, Y)$  que par  $S$  et la distribution  $p(x)$  (les valeurs de  $p(y|x)$  n'interviennent pas dans les définitions). On définit donc le graphe  $G$  dont l'ensemble des sommets est  $\mathcal{X}$  et deux sommets distincts  $x$  et  $x'$  sont connectés si ils sont ambigus. Le graphe probabiliste  $(G, X)$  est défini par le graphe  $G$  et la distribution de probabilité sur ses sommets  $p(x)$ .  $\bar{L}$  ne dépend que de  $(G, X)$ .

Si  $X$  est une variable aléatoire à valeur dans  $\mathcal{X}$  et  $c$  est une fonction définie sur  $X$  alors  $c(X)$  est une variable aléatoire d'entropie :

$$H[c(X)] = - \sum_{\gamma \in c(X)} p[c^{-1}(\gamma)] \log p[c^{-1}(\gamma)],$$

où  $c^{-1}$  est l'inverse de  $c$  et la probabilité d'un ensemble est la somme des probabilités de ses éléments. On définit l'entropie chromatique d'un graphe probabiliste  $(G, X)$  par

$$H(G, X) = \min\{H[c(X)], c \text{ est un coloriage de } G\}.$$

5. Donner l'entropie chromatique pour : le graphe vide, le graphe complet, le pentagone avec la distribution uniforme sur ses sommets, le cycle avec  $p_0 = 0.3$ ,  $p_1 = p_2 = p_3 = 0.2$  et  $p_4 = 0.1$ .
6. Un protocole pour des entrées non-restreintes est une fonction  $\varphi : \mathcal{X} \rightarrow \{0, 1\}^*$  telle que pour  $x \neq x'$ ,  $\varphi(x)$  n'est pas un préfixe propre de  $\varphi(x')$  et si  $x$  et  $x'$  sont ambigus,  $\varphi(x) \neq \varphi(x')$ . Soit  $\bar{\mathcal{L}} = \min\{\ell(\varphi) : \varphi \text{ est un protocole pour entrées non-restreintes } (X, Y)\}$ . Montrer que  $H(G, X) \leq \bar{\mathcal{L}} \leq H(G, X) + 1$ .
7. En utilisant la première partie de l'exercice, montrer que

$$H(G, X) - \log[H(G, X) + 1] - \log e \leq \bar{\mathcal{L}} \leq H(G, X) + 1.$$