

Théorie de l'Information

Devoir # 3
25 octobre 2006

SIC-SICOM

Maria-João Rendas

1. Lequel de ces codes ne peut pas être un code de Huffman?

- (a) {1, 01, 00}
- (b) {00, 01, 10, 110}
- (c) {01, 10}

Justifiez toutes vos réponses.

2. Considérez la variable aléatoire avec la loi de probabilité dans le tableau suivant:

$x \in \mathcal{X}$	$p(x)$
x_1	0.5
x_2	0.26
x_3	0.11
x_4	0.04
x_5	0.04
x_6	0.03
x_7	0.02

- (a) Construisez un code de Huffman pour X .
 - (b) Calculez la longueur moyenne du code obtenu.
 - (c) Construisez un code ternaire pour X .
3. Des mots comme "Stop" ou "Feu" sont petits, pas car leur utilisation est fréquente, mais peut-être car on souhaite minimiser le temps nécessaire pour les dire. Supposez que $X = i$ avec probabilité $p_i, i = 1, \dots, m$. Soit ℓ_i le nombre de bits nécessaires pour coder $X = i$, et c_i le coût par lettre du mot X_i . Le coût moyen du code est donc

$$C = \sum_{i=1}^m p_i \ell_i c_i$$

- (a) Minimisez C défini par l'équation précédente sur toutes les longueurs $\{\ell_i\}_{i=1}^m$, telles que l'inégalité de Kraft est satisfaite:

$$\sum_{i=1}^m 2^{-\ell_i} \leq 1.$$

Ignorez, pour cette minimisation, les contraintes qui imposent que les ℓ_i soient des entiers. Calculez les longueurs optimales ℓ_i^* , et le coût minimal qui leur est associé, C^* .

(b) Comment pouvez-vous utiliser l'algorithme de Huffman pour minimiser C sur tous les codes (binaires) uniquement décodables ? Soit C_{Huffman} le coût de ce code optimal.

(c) Montrez que

$$C^* \leq C_{\text{Huffman}} \leq C^* + \sum p_i c_i.$$

4. Soit $\mathcal{X} = \{1, 2, 3, 4, 5\}$. Considérez les deux lois de probabilité p et q définies sur cet alphabet, et les deux codes C_1 et C_2 dans le tableau suivant

$x \in \mathcal{X}$	$p(x)$			
1	0.5	0.5	0	0
2	0.25	0.125	10	100
3	0.125	0.125	110	101
4	0.0625	0.125	1110	110
5	0.0625	0.125	1111	111

(a) Calculez $H(p)$, $H(q)$, $D(p||q)$ et $D(q||p)$.

(b) Vérifiez que C_1 est optimal pour p et que C_2 est optimal pour q (calculez leurs longueurs moyennes).

(c) Admettez que l'on utilise C_2 pour une source $X \sim p$. Quelle est la longueur moyenne des mots de code? De combien elle dépasse l'entropie $H(p)$?

(d) Quelle est la pénalité si nous utilisons C_1 pour une source $X \sim q$?

5. On nous donne 6 bouteilles de vin. On sait qu'une des bouteilles est mauvaise. L'analyse visuelle des bouteilles permet de déterminer la probabilité pour que chacune d'entre elles soit celle qui est mauvaise:

bouteille # i	p_i
1	7/26
2	5/26
3	4/26
4	4/26
5	3/26
6	3/26

Nous souhaitons déterminer la mauvaise bouteille.

Supposez que l'on goute les vins un à un. Choisissez l'ordre par laquelle ils doivent être goûtés pour que le nombre d'essais soit minimisé. Rappelez-vous que si les premières 5 bouteilles sont bonnes, vous ne devez pas gouter la dernière.

- (a) Quel est le nombre moyen d'essais qui doivent être réalisés?
- (b) Quelle bouteille doit être testée en premier?

Admettez maintenant que vous pouvez goûter le mélange du contenu de plusieurs bouteilles, au lieu de les goûter une à une.

- (c) Quelle est la valeur minimale du nombre moyen de tests qui doivent être faits pour déterminer la mauvaise bouteille?
- (d) Quel mélange doit être testé en premier ?