

Master Mathématiques et Applications, 1-ière année, Aix-Marseille Université

Modélisation en Traitement du Signal, Fiche d'exercices 3

Année 2015-16

1 Code de Huffman

On considère l'alphabet \mathcal{A} équipé de la distribution de probabilités donnée dans le tableau ci-dessous

Symbole	a	b	c	d	e	f
Probabilité	0,4	0,2	0,15	0,1	0,8	0,7

1. Appliquer l'algorithme de Huffman, et en déduire un code pour cet alphabet.
2. Calculer l'entropie de Shannon de la distribution de probabilités P , ainsi que la longueur moyenne des mots. Donner l'efficacité du code.

2 Code de Huffman

On considère l'alphabet A équipé de la distribution de probabilités donnée dans le tableau ci-dessous

Symbole	a	b	c	d	e	f	g	h	i	j	k	l	m
Probabilité	5/24	3/24	2/24	2/24	2/24	2/24	2/24	1/24	1/24	1/24	1/24	1/24	1/24

1. Appliquer l'algorithme de Huffman, et en déduire un code pour cet alphabet.
2. Calculer l'entropie de Shannon de la distribution de probabilités P , ainsi que la longueur moyenne des mots. Donner l'efficacité du code.

3 Code de Shannon-Fano

Le code de Shannon-Fano, utilisé dans les années 50, est le premier code à avoir exploité la redondance d'une source. Le principe est basé sur une décomposition récursive de l'alphabet en deux parties telles que leur probabilité soit sensiblement égale.

On considère un alphabet $A = \{a\}$, et une distribution de probabilités $P = \{p(a), a \in A\}$. L'algorithme de Shannon-Fano comporte les étapes suivantes :

- Les probabilités d'apparition de chaque symbole sont placées dans un tableau trié par ordre décroissant de probabilités .
- L'alphabet est coupé en deux groupes de symboles A_0 et A_1 dont la somme des probabilités de chaque groupe avoisine 0.5.
- Le groupe A_0 est codé par un "0" et A_1 par un "1".
- Si un groupe A_i n'a qu'un seul élément, c'est une feuille terminale, sinon la procédure reprend récursivement à l'étape 2 sur le groupe A_i .

1. Appliquer l'algorithme de Shannon-Fano ci-dessus à l'alphabet de la section 2, et en déduire un code pour cet alphabet.
2. Calculer l'entropie de Shannon de la distribution de probabilités P , ainsi que la longueur moyenne des mots. Donner l'efficacité du code. Comparer les résultats aux résultats obtenus avec le code de Huffman

4 Théorème de Shannon

Dans cet exercice, on considère un alphabet $\mathcal{A} = \{a_0, \dots, a_{M-1}\}$, muni d'une distribution de probabilités $P = \{p(a), a \in \mathcal{A}\}$, et on se propose de démontrer les principaux éléments liés au théorème de Shannon-Fano. On considère donc un codeur binaire $\alpha : a \in \mathcal{A} \rightarrow \alpha(a)$, et pour tout $a \in \mathcal{A}$ on note $\ell(a)$ la longueur du mot binaire $\alpha(a)$. On note $\bar{\ell} = \sum_{a \in \mathcal{A}} p(a)\ell(a)$ la longueur moyenne des mots associée à α .

1. On considère l'inégalité de Kraft

$$\sum_{a \in \mathcal{A}} 2^{-\ell(a)} \leq 1 .$$

Montrer que si α est un code de longueur constante (c'est à dire $\ell(a) = \ell$ pour tout $a \in \mathcal{A}$), alors $\ell \geq \text{Card}(\mathcal{A})$.

2. Soit maintenant α un code de longueur variable (CLV). On suppose que le codeur satisfait l'inégalité de Kraft, et on veut montrer l'inégalité de Shannon $\bar{\ell} \geq H(P)$, où $H(P)$ est l'entropie de Shannon :

$$H(P) = - \sum_{a \in \mathcal{A}} p(a) \log_2(p(a))$$

- a) En utilisant la définition de ℓ , un logarithme en base 2 et l'inégalité de Kraft, montrer que

$$\bar{\ell} \geq - \sum_{a \in \mathcal{A}} p(a) \log_2(q(a)) \quad \text{où} \quad q(a) = \frac{2^{-\ell(a)}}{\sum_{b \in \mathcal{A}} 2^{-\ell(b)}}$$

- b) En utilisant la concavité du logarithme (inégalité de Jensen), montrer que

$$\sum_{a \in \mathcal{A}} p(a) \log_2(q(a)) \leq \sum_{a \in \mathcal{A}} p(a) \log_2(p(a));$$

déduire du résultat précédent que

$$\bar{\ell} \geq H(P) .$$

- c) Sous quelles conditions l'inégalité peut elle être une égalité ?

Arbre pour le codage de Huffman - "ABCDEF GHIJKLM"




FIGURE 1 – Arbre binaire associé au code de Huffman

Corrections

1 Code de Huffman

1. Pour construire le code, il faut commencer par remplir la table

a (0,4)	a (0,4)	a (0,4)	a (0,4)	defcb (0,6)	adefcb (1)
b (0,2)	b (0,2)	def (0,25)	cb (0,35)	a (0,4)	
c (0,15)	c (0,15)	b (0,2)	def (0,25)		
d (0,1)	ef (0,15)	c (0,15)			
e (0,8)	d (0,1)				
f (0,7)					

On en déduit l'arbre de Huffman, puis le code

lettre	code	longueur
a	1	1
b	010	3
c	011	3
d	001	3
e	0000	4
f	0001	4

2. La longueur moyenne des mots vaut $\bar{\ell} = 2.35$, et l'entropie vaut $H = 2.296$. L'efficacité vaut donc $H/\bar{\ell} = 97\%$.


2 Code de Huffman

1. L'encodage est décrit dans la figure ??, et le code se trouve dans la table ?? (tableau de gauche). L'arbre se trouve ci-dessous :
et le code correspondant est là :
2. L'entropie vaut $H(P) \approx 3.4864$. La longueur moyenne pour un code de longueur constante serait de 4 bits/symbole, la longueur pour le code de Huffman vaut $\bar{\ell}_H \approx 3.5417$.

symbole	code	longueur
A	01	2
B	100	3
C	1011	4
D	1010	4
E	1111	4
F	1110	4
G	1100	4
H	11011	5
I	11010	5
J	0011	4
K	0010	4
L	0001	4
M	0000	4

TABLE 1 – Arbre binaire associé au code de Huffman

3 Code de Shannon-Fano



symbole	code	longueur
A	00	2
B	010	3
C	0110	4
D	0111	4
E	100	3
F	1010	4
G	1011	4
H	1100	4
I	11010	5
J	11011	5
K	1110	4
L	11110	5
M	11111	5

1.

2. L'entropie vaut $H(P) \approx 3.4864$. La longueur moyenne pour un code de longueur constante serait de 4 bits/symbole, la longueur pour le code de Huffman vaut $\bar{l}_{SF} \approx 3.5417$ (même résultat que pour le code de Huffman).

4 Théorème de Shannon

1. Prenons l'inégalité de Kraft dans le cas d'un code de longueur constante L :

$$\sum_{a \in \mathcal{A}} 2^{-L} = \text{Card}(\mathcal{A})2^{-L} \leq 1 ,$$

on en déduit donc

$$2^L \geq \text{Card}(\mathcal{A}) \quad \text{soit} \quad L \geq \log_2(\text{Card}(\mathcal{A})) .$$

L devant être un entier, il est nécessairement supérieur ou égal à l'entier le plus proche par valeur supérieure de $\log_2(\text{Card}(\mathcal{A}))$. Par exemple, si $\text{Card}(\mathcal{A}) = 10$, alors $L \geq 4$.

2. a) Calculons

$$\bar{\ell} = \sum_{a \in \mathcal{A}} p(a)\ell(a) = - \sum_{a \in \mathcal{A}} p(a) \log_2(2^{-\ell(a)}) \geq - \sum_{a \in \mathcal{A}} p(a) \log_2 \left(\frac{2^{-\ell(a)}}{\sum_{b \in \mathcal{A}} 2^{-\ell(b)}} \right) = - \sum_{a \in \mathcal{A}} p(a) \log_2(q(a)) .$$

On a ici utilisé l'inégalité de Kraft, qui donne $2^{-\ell(a)} \geq 2^{-\ell(a)} / \sum_{b \in \mathcal{A}} 2^{-\ell(b)}$.

b) L'inégalité de Jensen donne

$$\sum_{a \in \mathcal{A}} p(a) \log_2 \left(\frac{q(a)}{p(a)} \right) \leq \log_2 \left(\sum_{a \in \mathcal{A}} p(a) \frac{q(a)}{p(a)} \right) = \log_2 \left(\sum_{a \in \mathcal{A}} q(a) \right) = 0$$

car $Q = \{q(a)\}$ est une distribution de probabilités. On en déduit donc

$$\bar{\ell} \geq - \sum_{a \in \mathcal{A}} p(a) \log_2(q(a)) \geq - \sum_{a \in \mathcal{A}} p(a) \log_2(p(a)) = H(P) .$$