

Entropie et codes de compression

1. a. Déterminer si le codage suivant est *i)* sans pertes, *ii)* instantané, et *iii)* uniquement décodable (avec justification) :

x	A	B	C	D
$C(x)$	000	001	01	1

- b. Calculer l'entropie de $\mathcal{X} = \{A, B, C, D\}$ avec fonction de probabilité

$$p(A) = p(B) = 0,125, \quad p(C) = 0,250, \quad \text{et} \quad p(D) = 0,500,$$

et déterminer si C est optimal.

2. Soit $\mathcal{X} = \{A, B, C, D, E, F, G, H\}$ l'espace de probabilité avec les probabilités suivantes :

x	A	B	C	D	E	F	G	H
$p(x)$	0,25	0,25	0,20	0,14	0,10	0,04	0,01	0,01

- a. Calculer l'entropie $H(\mathcal{X})$.
- b. Construire l'arbre de codage associé à un codage de Huffman C pour X , et donner les codes $C(x)$ pour chaque élément x .
- c. Trouver l'espérance mathématique de la fonction longueur de $C(x)$, et vérifier le théorème *Codage source* de Shannon.
3. Soit $\mathcal{A} = \{A, B, C, D, E\}$ un alphabet avec probabilités

$$p(A) = 0,40, \quad p(B) = 0,1, \quad p(C) = p(D) = 0,20, \quad \text{et} \quad p(E) = 0,1,$$

et $m = \text{AAACDCBDCEAADADACEDAEADCABEDADDCECAAAAAD}$.

- a. Trouver un codage instantané $C : \mathcal{A} \rightarrow \{0, 1\}^*$, avec $E(\ell_C) \leq H(\mathcal{A}) + 1$.
- b. Comparer la longueur de m multiplié par $\log_2(5)$ et la longueur de $C(m)$.
4. Soit $\mathcal{A} = \{A, B, C\}$, et supposons que les digrammes suivent les probabilités :

		y			
		$p(xy)$	A	B	C
x	A	0	4/15	1/15	
	B	8/27	8/27	0	
	C	1/27	4/135	1/135	

- a. Calculer les probabilités $p(x)$ pour chaque lettre x dans \mathcal{A} .
- b. Déterminer $H(\mathcal{A}^2)$, $H(\mathcal{A})$ et vérifier $H(\mathcal{A}^2) \leq 2H(\mathcal{A})$.
- c. Trouver des codages $C_1 : \mathcal{A} \rightarrow \{0,1\}^*$, et $C_2 : \mathcal{A}^2 \rightarrow \{0,1\}^*$, qui sont uniquement décodable, avec l'espérance des longueurs bornée par $H(\mathcal{A}) + 1$ et $H(\mathcal{A}^2) + 1$.
- d. Trouver les longueurs des codes $C_1(m)$ et $C_2(m)$ où

$m = \text{ABBABABABABABABBBBABBBBBBABABABABBBBACACABBABBBBABBBABACBBBBABA.}$

5. On considère un texte source formé à partir de 5 symboles distincts (a, b, c, d, r) avec les fréquences d'apparition suivantes :

$$p(\mathbf{a}) = 0,43, \quad p(\mathbf{b}) = 0,20, \quad p(\mathbf{c}) = 0,10, \quad p(\mathbf{d}) = 0,09, \quad p(\mathbf{r}) = 0,18.$$

- a. Générer un arbre de Huffman binaire et proposer le codage correspondant en affectant les 0 aux probabilités les plus grandes.
- b. Coder le texte suivant et calculer le gain de compression par rapport à un code binaire de longueur fixe et minimale : `abracadabrabracadabra.`

Rendement des codes correcteurs

6. Déterminer le rendement du codage $C : \{\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}\} \rightarrow \{0,1\}^2$, donné par

$$C(\mathbf{A}) = 00, \quad C(\mathbf{B}) = 01, \quad C(\mathbf{C}) = 10, \quad C(\mathbf{D}) = 11.$$

7. Soit C le codage $\mathcal{X} = \{\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}\} \rightarrow \{0,1\}^*$, donné par

$$C(\mathbf{A}) = 0, \quad C(\mathbf{B}) = 10, \quad C(\mathbf{C}) = 110, \quad C(\mathbf{D}) = 111.$$

- a. Remplir le tableau suivant, où $r_n = \frac{\log_2(|C(\mathcal{X}^*) \cap \mathcal{A}^n|)}{\log_2 |\mathcal{A}^n|}$.

n	$ C(\mathcal{X}^*) \cap \mathcal{A}^n $	$ \mathcal{A}^n $	r_n
1			
2			
3			
4			
5			
6			

- b. Quel est le rendement de C ?

8. Trouver le rendement pour les codages suivants : $x_1x_2x_3x_4 \mapsto x_1x_2x_3x_4y_1y_2y_3y_4$ où les bits y_i sont définés par

<p>a.</p> $y_1 = x_1$ $y_2 = x_2$ $y_3 = x_3$ $y_4 = x_4$	<p>b.</p> $y_1 = x_1$ $y_2 = x_1 + x_2$ $y_3 = x_3$ $y_4 = x_3 + x_4$	<p>c.</p> $y_1 = x_1 + x_2 + x_3$ $y_2 = x_1 + x_2 + x_4$ $y_3 = x_1 + x_3 + x_4$ $y_4 = x_2 + x_3 + x_4$
--	--	--

Combien d'erreurs peuvent être détectés et corrigés par chaque codage ?