

## TD 1 : Codes et Codage de caractères

## 1 Codage de caractères

**Exercice 1** Convertissez

- les nombres  $(17)_{10}$ ,  $(42)_{10}$ ,  $(555)_{10}$  en base 16 et 2
- les nombres  $(3A)_{16}$  et  $(DEC)_{16}$  en base 10 et 2

**Exercice 2** Quelle partie de l'espace de code est utilisée par UTF-32 ?

**Exercice 3** Quelle est la taille (en octets) d'un texte avec  $n$  caractères ASCII codé en format

1. UTF-8
2. UTF-16
3. UTF-32

**Exercice 4** Voici des extraits de la table de codage Unicode pour l'alphabet hébreu, japonais et phénicien.

	059	05A	05B	05C	05D	05E
0		◊ 05A0	◊ 05B0	 05C0	Ⲁ 05D0	ⲁ 05E0
1	◊ 0591	◊ 05A1	◊ 05B1	◊ 05C1	Ⲃ 05D1	ⲃ 05E1

(a) Hebrew

	30A	30B	30C	30D	30E	30F
0	= 30A0	グ 30B0	ダ 30C0	バ 30D0	ム 30E0	キ 30F0
1	ア 30A1	ケ 30B1	チ 30C1	パ 30D1	メ 30E1	エ 30F1

(b) Katakana

	1090	1091
0	𐤀 10900	𐤁 10910
1	𐤂 10901	𐤃 10911

(c) Phoenician

Codez les caractères Alef, Bet et Nun (05D0, 05D1, 05E0), les caractères Gu et We (30B0, 30F1) et Alf, Bet (10900, 10901) en UTF-8, UTF-16, UTF-32.

## 2 Codes et codages

**Exercice 5** Cochez les cases où  $m_1 \preceq m_2$  :

$m_1 / m_2$	01	010	110
01	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
101	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
10	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
11	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

**Exercice 6** On dit qu'une relation  $R$  est un ordre si elle est

- réflexive :  $\forall x.R(x, x)$
- antisymétrique :  $\forall xy.R(x, y) \wedge R(y, x) \rightarrow x = y$
- transitive :  $\forall xy.R(x, y) \wedge R(y, z) \rightarrow R(x, z)$

 Pour la relation  $\preceq$ , on utilise une notation *infixe*, c.à.d. on écrit  $x \preceq y$  au lieu de  $\preceq(x, y)$ .

 Montrez que la relation  $\preceq$  définie par  $m \preceq m' =_{def} \exists r.m' = m \cdot r$  est un ordre.

**Exercice 7** On définit trois codes  $c_1, c_2, c_3$  pour un alphabet  $A = \{a, b, c, d\}$  selon le tableau suivant :

$x$	$c_1(x)$	$c_2(x)$	$c_3(x)$
a	0	10	0
b	010	00	10
c	01	11	110
d	10	110	111

Montrez que :

- $c_1$  est injectif, mais son extension homomorphe  $c_1^*$  n'est pas unique
- $c_2$  n'est pas un code préfixe, mais son extension homomorphe  $c_2^*$  est unique
- $c_3$  est un code préfixe

**Exercice 8** Montrez formellement que tout codage unique est un codage injectif.

*Remarque :* L'exercice 7 montre que cette inclusion est stricte.

**Exercice 9** Montrez formellement que tout codage  $c^*$  qui est l'extension homomorphe d'un code préfixe  $c$  est injectif.

**Exercice 10** Est-ce que le code Morse est unique / injectif / un code préfixe ?

**Exercice 11** Appliquez l'algorithme `arbre_dec` aux codages  $c_1$  et  $c_2$  de la table suivante.

$x$	$c_1(x)$	$c_2(x)$	$c_3(x)$
a	00	01	0
b	01	11	10
c	10	00	110
d	11	001	1110

Si la construction de l'arbre échoue, identifiez les causes. Est-ce que vous pouvez proposer des codages qui évitent le problème ?

**Exercice 12** Appliquez l'algorithme `tab_cod` aux arbres de décodage obtenus dans l'exercice 11 et vérifiez que vous obtenez bien les tables d'origine.

**Exercice 13** Pourquoi est-ce que l'algorithme `tab_cod` termine ?

**Exercice 14** (*Devoir maison*)

Analyse de l'algorithme `arbre_dec` :

1. Quels problèmes se poseraient pour un algorithme de décodage si l'arbre n'était pas un arbre binaire (mais si un noeud intérieur pouvait avoir un seul successeur) ?
2. Un invariant de `arbre_dec` est qu'il prend la représentation d'une table `tab` d'un codage préfixe. Démontrez que cet invariant est maintenu par les appels récursifs, donc, que

$$\{(c, m) \mid (c, 0 \cdot m) \in \text{tab}\}$$

représente bien une table d'un codage préfixe (et pareil pour  $1 \cdot m$ ).

3. Démontrez que si  $(c, []) \in \text{tab}$ , alors il n'est pas possible d'avoir un  $(d, m) \in \text{tab}$ , pour un  $c \neq d$ .
4. Démontrez que l'algorithme termine.

**Exercice 15**

- Utilisez l'inégalité de Kraft pour déterminer s'il est possible de construire un code préfixe pour les caractères  $a \dots d$  avec les longueurs de code suivants :
 

caractère	a	b	c	d
longueur	1	2	2	3
- Quelle serait votre réponse si on admet un code de longueur 3 pour le caractère  $b$ ? Proposez effectivement un code.

**Exercice 16**

- Une entreprise veut installer un système téléphonique interne où les 5 membres du directoire ont un numéro à un seul chiffre (de 0 à 9) et les 80 autres employés un nombre à deux chiffres. Est-ce possible?
- Serait-il possible d'avoir des numéros à deux chiffres pour les membres du directoire et de trois chiffres pour les autres employés? Faites une proposition concrète.

*A noter :* L'inégalité de Kraft se généralise d'un code binaire à un code  $n$ -aire (alphabet à  $n$  chiffres) comme suit : Il existe un code préfixe  $n$ -aire avec  $k$  codes  $u_1 \dots u_k$  si et seulement si

$$\sum_{i=1}^k n^{-|u_i|} \leq 1$$

où  $|u_i|$  est la longueur du code  $u_i$ .