

Caractères français et ordre alphabétique

Jacques.Andre@irisa.fr

3 mai 2003

Ce document est essentiellement formé d'un tableau des lettres françaises triées par ordre alphabétique avec pour chacune leur code en Ascii (quand il existe), en Latin-1 ou 9, en Unicode et la façon de les coder en T_EX, Mime et HTML. Par ailleurs on montre comment lire les courriers électroniques qui ont été codés en UTF-8 et lus par un navigateur qui travaille en Latin-1, par exemple passer de « La rÃ©fÃ©rence franÃ§aise considÃ©re » à « La référence française considère » !

L'inventaire des lettres françaises et leur ordre alphabétique est issu de :

Alain LABONTÉ, « Règles du classement alphabétique en langue française et procédure informatisée pour le tri », Conseil du trésor, Québec, Canada, 2002 : <http://www.tresor.gouv.qc.ca/doc/classm.htm>

document qui sert de base à son auteur pour rédiger un projet de norme internationale de classement (projet ISO/CEI 14651) pour l'ensemble des caractères du jeu universel de caractères codés sur plusieurs octets (norme ISO/CEI 10646-1:1993, correspondant au standard UNICODE).

Autres liens utiles

- Liste typographie (où nombre de discussions ont eu lieu sur ce thème, notamment en février 2003 sous la plume de Jean-François Robert, Jean Fontaine et ... Alain laBonté) : <https://www.irisa.fr/wws/info/typographie>
- Les archives du forum [fr.lettres.langue.francaise](http://www.langue-fr.net/) à <http://www.langue-fr.net/>.
- Le site <http://pages.infinit.net/hapax> avec la traduction française d'Unicode et une introduction de Patrick Andries à Unicode.
- Voir aussi <http://www.eki.ee/letter/> pour divers inventaires de caractères par langues et le transcodage d'un code à l'autre.

Légende du tableau des lettres françaises

Car. le caractère (ou plutôt un glyphe au sens d'Unicode).

Ascii son code en Ascii, quand il existe (sinon il est marqué « — »), en base 10 (on retrouvera cette même valeur en octal en colonne « Latin » et en hexadécimal en colonne « Unicode »).

T_EX son nommage en T_EX, en n'utilisant que les caractères Ascii.

HTML le nommage des caractères par des entités (écrites en Ascii). On peut aussi les nommer sous la forme `&#x...` ; où ... en est le code Unicode (colonne Unicode), par exemple saisir `Ÿ` ; pour avoir Ÿ.

QP son codage en Mime *quoted printable*¹ (comparer avec le code Unicode).

Latin son codage en ISO 8859-1 (Latin-1) et -15 (Latin-9). Lorsque le code diffère de Latin-1 à Latin-9 (c'est le seul cas des caractères œ, Œ et Ÿ), la première ligne indique « — » (pas de code en Latin-1) et la seconde le code en Latin-9.

Unicode son codage en Unicode, en hexadécimal.

UTF-8 la forme de stockage par 8 bits du code Unicode : le principe de cette forme est de recoder sur 1 octet les caractères Unicode de code U+0000 à U+007F (c'est-à-dire ceux de l'Ascii), sur 2 octets les codes de U+0080 à U+07FF, etc.² Dans le second cas, le principe est de répartir ainsi les bits :

0000 0yyy yyxx xxxx => 110y yyyy 10xx xxxx

mais pour les caractères français de Latin-1 : yyx yy=000 11 ; en effet « À », le premier d'entre eux, a pour code U+00C0 soit 1100 0000. Tous les codes UTF-8 des caractères français avec diacritique vont donc avoir pour premier octet la valeur C3 (on donne ici leur code en hexa, et on sépare les deux octets éventuels par un espace) sauf donc ceux de œ, Œ et Ÿ pour lequel ce premier octet sera C5.

⇒ si on reçoit dans un courrier électronique un texte français stocké en UTF-8 et qu'on le lit comme si c'était du Latin-1 (c'est ce qui arrive souvent par défaut quand on n'a pas paramétré son navigateur pour recevoir de l'UTF-8) les lettres de l'Ascii étant codées sur 1 octet apparaissent bien ; les autres sont sur 2 octets interprétés comme 2 lettres : la première, de code C3 (ou plus rarement C5) apparaît alors comme Â (ou Á) ; la seconde, de code binaire 10xx xxxx, va correspondre soit à un des caractères de commande de Latin-1 (codes 80 à 9F) qui ne sont pas imprimables³ et n'apparaissent alors en général pas (nous les indiquons ici par un □), soit à un des premiers caractères spéciaux de Latin-1 (codes A0₁₆ à BF₁₆). Notons que parmi ces derniers se trouvent des caractères qui varient de Latin-1 à Latin-9, par exemple A6₁₆ (' en Latin-1 et Š en Latin-9).

¹On retrouve ici ce qui apparaît dans le courrier électronique en mode *quoted printable*, codage sur 7 bits de caractères 8 bits. Voir <http://www.ietf.org/>.

²Voir la transformation détaillée dans <http://staff.dstc.edu.au/ilister/utf8.html>.

³Sauf lorsque des standards propriétaires réutilisent ces codes pour y mettre des caractères qui ne sont pas de Latin-1, c'est par exemple le cas des Mac, de certains codages de Windows, voire de... T_EX.

Tableau des lettres françaises triées par ordre alphabétique

Car. base	Ascii 10	T _E X Ascii	HTML Ascii	QP Ascii	Latin 8	Unicode 16	UTF-8 16	⇒ lat1
a	97	a	a	a	141	0061	61	a
A	65	A	A	A	101	0041	41	A
à	—	\'a	à	=E0	340	00E0	C3 A0	Ã
À	—	\'A	À	=C0	300	00C0	C3 80	Ã□
â	—	\^a	â	=E2	342	00E2	C3 A2	Ã¢
Â	—	\^A	Â	=C2	302	00C2	C3 82	Ã□
æ	—	{\ae}	æ	=E6	346	00E6	C3 A6	Ã
Æ	—	{\AE}	Æ	=C6	306	00E6	C3 86	Ã□
b	98	b	b	b	142	0062	62	b
B	66	B	B	B	102	0042	42	B
c	99	c	c	c	143	0063	63	c
C	67	C	C	C	103	0043	43	C
ç	—	\c{c}	ç	=E7	347	00E7	C3 A2	Ã§
Ç	—	\c{C}	Ç	=C7	307	00C7	C3 87	Ã□
d	100	d	d	d	144	0064	64	d
D	68	D	D	D	104	0044	44	D
e	101	e	e	e	145	0065	65	e
E	69	E	E	E	105	0045	45	E
é	—	\'e	é	=E9	351	00E9	C3 A9	Ã©
É	—	\'E	É	=C9	311	00C9	C3 89	Ã□
è	—	\'e	è	=E8	350	00E8	C3 A8	Ã¨
È	—	\'E	È	=C8	310	00C8	C3 88	Ã□
ê	—	\^e	ê	=EA	352	00EA	C3 AA	Ãª
Ê	—	\^E	Ê	=CA	312	00CA	C3 8A	Ã□
ë	—	\"e	ë	=EB	353	00EB	C3 AB	Ã«
Ë	—	\"E	Ë	=CB	313	00CB	C3 8B	Ã□
f	102	f	f	f	146	0066	66	f
F	70	F	F	F	106	0046	46	F
g	103	g	g	g	147	0067	67	g
G	71	G	G	G	107	0047	47	G
h	104	h	h	h	150	0068	68	h
H	72	H	H	H	110	0048	48	H
i	105	i	i	i	151	0069	69	i
I	73	I	I	I	111	0049	49	I
î	—	\^{i}	î	=EE	356	00EE	C3 AE	Ã©
Î	—	\^{I}	Î	=CE	316	00CE	C3 CE	Ã□
ï	—	\"i	ï	=EF	357	00EF	C3 AF	Ã-
Ï	—	\"I	Ï	=CF	317	00CF	C3 CF	Ã□
j	106	j	j	j	152	006A	6A	j
J	74	J	J	J	112	004A	4A	J
k	107	k	k	k	153	006B	6B	k
K	75	K	K	K	113	004B	4B	K
l	108	l	l	l	154	006C	6C	l
L	76	L	L	L	114	004C	4C	L

Car. base	Ascii 10	T _E X Ascii	HTML Ascii	QP Ascii	Latin 8	Unicode 16	UTF-8 16	⇒ lat1
m	109	m	m	m	155	006D	6D	m
M	77	M	M	M	115	004D	4D	M
n	110	n	n	n	156	006E	6E	n
N	78	N	N	N	116	004E	4E	N
o	111	o	o	o	157	006F	6F	o
O	79	O	O	O	117	004F	4F	O
ô	—	\^o	ô	=F4	364	00F4	C3 B4	Ã´
Ô	—	\^O	Ô	=D4	324	00D4	C3 94	Ã
œ	—	{\oe}	œ	—	—	0153	C5 93	Å
Œ	—	{\OE}	Œ	—	275 —	0152	C5 92	Å
p	112	p	p	p	160	0070	70	p
P	80	P	P	P	120	0050	50	P
q	113	q	q	q	161	0071	71	q
Q	81	Q	Q	Q	121	0051	51	Q
r	114	r	r	r	162	0072	72	r
R	82	R	R	R	122	0052	52	R
s	115	s	s	s	163	0073	73	s
S	83	S	S	S	123	0053	53	S
t	116	t	t	t	164	0074	74	t
T	84	T	T	T	124	0054	54	T
u	117	u	u	u	165	0075	75	u
U	85	U	U	U	125	0055	55	U
ù	—	\'u	ù	=F9	371	00F9	C3 B9	Ã
Ù	—	\'U	Ù	=D9	331	00D9	C3 99	Ã
û	—	\^u	û	=FB	373	00FB	C3 BB	Ã»
Û	—	\^U	Û	=DB	333	00DB	C3 9B	Ã
ü	—	\"u	ü	=FC	374	00FC	C3 BC	Ã¼
Ü	—	\"U	Ü	=DC	334	00DC	C3 9C	Ã
v	118	v	v	v	166	0076	76	v
V	86	V	V	V	126	0056	56	V
w	119	w	w	w	167	0077	77	w
W	87	W	W	W	127	0057	57	W
x	120	x	x	x	170	0078	78	x
X	88	X	X	X	130	0058	58	X
y	121	y	Y	Y	171	0079	79	y
Y	89	Y	Y	Y	131	0059	59	Y
ÿ	—	\"y	ÿ	=FF	377	00FF	C3 BF	Ã
Ÿ	—	\"Y	Ÿ	—	—	0178	C5 B8	Å
z	122	z	z	z	276 172	007A	7A	z
Z	90	Z	Z	Z	132	005A	5A	Z

Page accessible à <http://www.irisa.fr/fagtypo/unicode/alpha-fr.pdf>