Encodages

Karën Fort

karen.fort@univ-lorraine.fr / https://members.loria.fr/KFort

Institut des sciences du Digital Management & Cognition
COMPOSANTE DE L'UNIVERSITÉ DE LORRAINE

UNIVERSITÉ DE LORRAINE

Le langage de l'ordinateur

Normes

Désigner une langue

Conclusion

Pour finir

La langue de l'ordinateur

- Le texte n'existe pas en informatique

La langue de l'ordinateur

- Le texte n'existe pas en informatique
- Quelle langue ≪ parle ≫ l'ordinateur ? Quels sont ses mots ?

La langue de l'ordinateur

- Le texte n'existe pas en informatique
- Quelle langue « parle » l'ordinateur ? Quels sont ses mots ?
- Matériellement, un ordinateur ne comprend que le langage binaire, c'est-à-dire une suite de 0 et de 1
  Pour faire simple : du courant, pas de courant

La langue de l'ordinateur

- Le texte n'existe pas en informatique
- Quelle langue « parle » l'ordinateur ? Quels sont ses mots ?
- Matériellement, un ordinateur ne comprend que le langage binaire, c'est-à-dire une suite de 0 et de 1
  Pour faire simple : du courant, pas de courant
- On appelle **bit** (BInary digiT) cette unité élémentaire d'information, qui peut prendre comme valeur 0 ou 1

Allez, hop tous en combinaison (wooclap)

Exercice

Combien existe-t'il de possibilités de combiner 2 bits ?

Petite parenthèse : ça ne vous rappelle rien ?

(c) DVD Les shadoks, édition intégrale

Compter

Un peu plus loin dans les bases

- En fait, un processeur manipule plutôt des paquets de bits de taille fixe
- Les premiers processeurs fixèrent la taille de ces paquets à huit bits, soit un **octet**
- De huit bits (processeur 8086), les processeurs sont passés à 32 bits (Pentium 4), pour arriver aujourd'hui à 64. Ces paquets correspondent en fait à la capacité de transport (dans ses bus) et de traitement de la machine (taille des registres)

À noter

1 octet = 8 bits = 1 byte (en anglais)

Dites « A » !

- « A » est en fait une entité abstraite dont le nom est « a majuscule » et dont le **glyphe** ressemble à un triangle dont on aurait raccourci et remonté le côté bas [dessin]

Dites « A » !

- « A » est en fait une entité abstraite dont le nom est « a majuscule » et dont le **glyphe** ressemble à un triangle dont on aurait raccourci et remonté le côté bas [dessin]
- Comment dit-on « A » à un ordinateur ?

Dites « A » !

- « A » est en fait une entité abstraite dont le nom est « a majuscule » et dont le **glyphe** ressemble à un triangle dont on aurait raccourci et remonté le côté bas [dessin]

- Comment dit-on « A » à un ordinateur ?
- 01000001

Dites « A » !

- « A » est en fait une entité abstraite dont le nom est « a majuscule » et dont le **glyphe** ressemble à un triangle dont on aurait raccourci et remonté le côté bas [dessin]

- Comment dit-on « A » à un ordinateur ?
- 01000001

À noter

1 caractère = 1 octet (attention, simplification !)

Le byte et ses bits (wooclap)

Exercice

Combien de valeurs peut-on coder sur un octet ?

Quelques exemples

Caractère	Code Binaire	Description
A	01000001	Caractère « A »
a	01100001	Caractère « a »
T	01010100	Caractère « T »
t	01110100	Caractère « t »
3	00110011	Caractère « 3 »
$	00100100	Caractère « $ »
BEL	00000111	Bip

À noter

- pour passer de la majuscule à la minuscule, il suffit de mettre le troisième bit à 1
- les caractères chiffres ont leur propre code
- il n'existe qu'un « A », qui s'affiche différemment selon les polices ou le style (voir Définitions)

Dites « Bonjour » à la dame (wooclap)

Exercice

Combien de bits dans « Bonjour » ?

Donc, l'ordinateur cause octet, so what ?

Il faut un traducteur pour que notre texte soit « codé » et « décodé » proprement, de manière **standardisée**

C'est là qu'interviennent les tables de conversion, ou les encodages

Récapitulons

- un ordinateur ne comprend que le langage binaire, c'est-à-dire une suite de 0 et de 1
- l'objet qui prend comme valeur 0 ou 1 est appelé bit
- en simplifiant : 1 caractère = 1 octet = 8 bits

Le langage de l'ordinateur

Normes
- ASCII
- ISO
- Unicode
- Limitations d'Unicode

Désigner une langue

Conclusion

Pour finir

Da ASCII code

- Au début de l'informatique, on estimait que coder les caractères sur 7 bits, ça suffisait bien, puisque ça permet de représenter 2^7=128 caractères différents. « A » est donc codé 1000001
- C'est ainsi que fut créée la table ASCII (American Standard Code for Information Interchange), publiée en 1968
- Très longtemps ce fut LA table de référence en informatique, à tel point qu'elle devint une norme : ISO-646

Table ASCII : ça suffit, non ?

	0	1	2	3	4	5	6	7
0	NUL	DLE	space	0	@	P	`	p
1	SOH	DC1 XON	!	1	A	Q	a	q
2	STX	DC2	"	2	B	R	b	r
3	ETX	DC3 XOFF	#	3	C	S	c	s
4	EOT	DC4	$	4	D	T	d	t
5	ENQ	NAK	%	5	E	U	e	u
6	ACK	SYN	&	6	F	V	f	v
7	BEL	ETB	'	7	G	W	g	w
8	BS	CAN	(	8	H	X	h	x
9	HT	EM	)	9	I	Y	i	y
A	LF	SUB	*	:	J	Z	j	z
B	VT	ESC	+	;	K	[	k	{
C	FF	FS	,	<	L	\	l	|
D	CR	GS	-	=	M	]	m	}
E	SO	RS	.	>	N	^	n	~
F	SI	US	/	?	O	_	o	del

Non, ça ne suffit pas

Big Blue invente l'ASCII étendu

- 1981, IBM sort son premier PC et ajoute un bit à l'ASCII
- L'ASCII étendu OEM ((Original Equipment Manufacturer) permet donc de coder 256 caractères (2^8) et certains sont contents de pouvoir fêter Noël
- Ce code ASCII étendu n'est pas unique et dépend fortement de la plate-forme utilisée

Table ASCII étendu OEM

	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F
8	Ç	ü	é	â	ä	à	å	ç	ê	ë	è	ï	î	ì	Ä	Å
9	É	æ	Æ	ô	ö	ò	û	ù	ÿ	Ö	Ü	¢	£	¥	₧	ƒ
A	á	í	ó	ú	ñ	Ñ	ª	º	¿	⌐	¬	½	¼	¡	«	»
B	░	▒	▓	│	┤	╡	╢	╖	╕	╣	║	╗	╝	╜	╛	┐
C	└	┴	┬	├	─	┼	╞	╟	╚	╔	╩	╦	╠	═	╬	╧
D	╨	╤	╥	╙	╘	╒	╓	╫	╪	┘	┌	█	▄	▌	▐	▀
E	α	ß	Γ	π	Σ	σ	µ	τ	Φ	Θ	Ω	δ	∞	ø	∈	∩
F	≡	±	≥	≤	⌠	⌡	÷	≈	°	∙	·	√	ⁿ	²	■	

On imagine la tête de ceux qui ont besoin d'écrire водка. . .

La famille ISO

. . .d'où l'idée de créer différents jeux de caractères au gré des besoins de chaque langue

- À partir de 1987 la table ASCII étendue fut déclinée en de multiples variations (toujours codées sur un octet)
- Les 128 premiers caractères de tous les jeux ISO 8859 correspondent aux caractères ASCII
- La norme ISO 8859 contient aujourd'hui 16 tables, numérotées de 1 à 16 :1 pour les langues dites occidentales, 2 pour les langues d'Europe centrale/de l'Est, 5 pour le cyrillique, 6 pour l'arabe, 7 pour le grec, 8 pour l'hébreu, etc

Exemple : ISO-8859-1

La table ISO-8859-1 définit ce qu'elle appelle l'alphabet latin numéro 1 ou latin-1 : 191 caractères de l'alphabet latin

ISO/CEI 8859-1																
	x0	**x1**	**x2**	**x3**	**x4**	**x5**	**x6**	**x7**	**x8**	**x9**	**xA**	**xB**	**xC**	**xD**	**xE**	**xF**
0x	*inutilisés*															
1x																
2x		!	"	#	$	%	&	'	(	)	*	+	,	-	.	/
3x	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4x	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5x	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6x	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7x	p	q	r	s	t	u	v	w	x	y	z	{	|	}	~	
8x	*inutilisés*															
9x																
Ax		¡	¢	£	¤	¥	¦	§	¨	©	ª	«	¬		®	¯
Bx	°	±	²	³	´	µ	¶	•	¸	¹	º	»	¼	½	¾	¿
Cx	À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
Dx	Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
Ex	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
Fx	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

Exemple : ISO-8859-5

Remarquez les 128 premiers caractères. . .

ISO/IEC 8859-5																
	x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF
0x	*unused*															
1x																
2x	SP	!	"	#	$	%	&	'	(	)	*	+	,	-	.	/
3x	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4x	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5x	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6x	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7x	p	q	r	s	t	u	v	w	x	y	z	{	|	}	~	
8x	*unused*															
9x																
Ax	*NBSP*	Ё	Ђ	Ґ	Є	S	І	Ї	J	Љ	Њ	Ћ	Ќ	*SHY*	Ў	Џ
Bx	А	Б	В	Г	Д	Е	Ж	З	И	Й	К	Л	М	Н	О	П
Cx	Р	С	Т	У	Ф	Х	Ц	Ч	Ш	Щ	Ъ	Ы	Ь	Э	Ю	Я
Dx	а	б	в	г	д	е	ж	з	и	й	к	л	м	н	о	п
Ex	р	с	т	у	ф	х	ц	ч	ш	щ	ъ	ы	ь	э	ю	я
Fx	№	ё	ђ	ґ	є	s	і	ї	j	љ	њ	ћ	ќ	§	ў	џ

Exemple : ISO-8859-15

Aussi connue sous le nom de Latin-9 (?), c'est une extension directe d'ISO 1 (mais plus tardive), à l'exception de 8 caractères

Différences ISO 8859-1 / ISO 8859-15 :

Position	0xA4	0xA6	0xA8	0xB4	0xB8	0xBC	0xBD	0xBE
8859-1	¤	¦	¨	´	¸	¼	½	¾
8859-15	€	Š	š	Ž	ž	Œ	œ	Ÿ

Vous en aviez assez ?

Évidemment, parmi les encodages les plus courants se trouve des encodages « maison » :

- Microsoft : Windows1252 et al.
- Apple : MacRoman

Limitations

- Problèmes d'incomplétude ou d'affichage pour certaines langues
- Impossible d'écrire du russe et du français (hors ASCII) dans un seul et même fichier
- Problèmes d'erreurs dues à la quasi-superposition de certains encodages ($ se transformant en £, par exemple)
- Et le milliard de Chinois ?

Parenthèse sur le chinois

- Il existe deux jeux d'écriture du (des) chinois : le **simplifié**, utilisé dans la République Populaire de Chine et à Singapour et le **traditionnel**, plus répandu dans la diaspora, à Taïwan Hong Kong, Macao.

Parenthèse sur le chinois

- Il existe deux jeux d'écriture du (des) chinois : le **simplifié**, utilisé dans la République Populaire de Chine et à Singapour et le **traditionnel**, plus répandu dans la diaspora, à Taïwan Hong Kong, Macao.
- A chaque type d'écriture son encodage, en particulier : GB 2312-80 (ou Guobiao) pour le chinois simplifié, avec 6 763 caractères seulement (! !), et Big5 pour le traditionnel, avec 13 053 caractères.

Parenthèse sur le chinois

- Il existe deux jeux d'écriture du (des) chinois : le **simplifié**, utilisé dans la République Populaire de Chine et à Singapour et le **traditionnel**, plus répandu dans la diaspora, à Taïwan Hong Kong, Macao.
- A chaque type d'écriture son encodage, en particulier : GB 2312-80 (ou Guobiao) pour le chinois simplifié, avec 6 763 caractères seulement (! !), et Big5 pour le traditionnel, avec 13 053 caractères.
- 13 053 caractères ? ! Mais ils les mettent où ?

Parenthèse sur le chinois

- Il existe deux jeux d'écriture du (des) chinois : le **simplifié**, utilisé dans la République Populaire de Chine et à Singapour et le **traditionnel**, plus répandu dans la diaspora, à Taïwan Hong Kong, Macao.
- A chaque type d'écriture son encodage, en particulier : GB 2312-80 (ou Guobiao) pour le chinois simplifié, avec 6 763 caractères seulement (! !), et Big5 pour le traditionnel, avec 13 053 caractères.
- 13 053 caractères ? ! Mais ils les mettent où ?
- Les Chinois ont tout simplement plus de bits pour coder leurs jeux de caractères : 16 exactement (soit 2 octets)

Les éléphants d'Asie

Exercice

Combien de valeurs peut-on représenter sur 16 bits ?

Les éléphants d'Asie

Exercice

Combien de valeurs peut-on représenter sur 16 bits ?

$\rightarrow$ 2x2x2x2x2x2x2x2x2x2x2x2x2x2x2x2=2^{16}=65 536

$\rightarrow$ Ça suffit donc pour le chinois, même traditionnel. D'ailleurs, même 14 bits auraient suffi...(2^{14}=16 384)

Alors pourquoi 16 ?

$\rightarrow$ Parce que c'est incomparablement plus pratique, étant donné que l'ordinateur gère des octets

Récapitulons

Récapitulons

- 1968 - ASCII (7 bits) : c'est pas Noël !

Récapitulons

- 1968 - ASCII (7 bits) : c'est pas Noël !
- 1981 - ASCII étendu (8 bits) : c'est Noël sans la водка

Récapitulons

- 1968 - ASCII (7 bits) : c'est pas Noël !
- 1981 - ASCII étendu (8 bits) : c'est Noël sans la водка
- 1987 - Les ISO (8 bits) : Noël avec водка à part, mais toujours pas d'€

Récapitulons

- 1968 - ASCII (7 bits) : c'est pas Noël !
- 1981 - ASCII étendu (8 bits) : c'est Noël sans la водка
- 1987 - Les ISO (8 bits) : Noël avec водка à part, mais toujours pas d'€
- 1997 - ISO-8859-15 (8 bits) : mise à jour d'ISO-8859-1, on passe à l'€ !

Récapitulons

- 1968 - ASCII (7 bits) : c'est pas Noël !
- 1981 - ASCII étendu (8 bits) : c'est Noël sans la водка
- 1987 - Les ISO (8 bits) : Noël avec водка à part, mais toujours pas d'€
- 1997 - ISO-8859-15 (8 bits) : mise à jour d'ISO-8859-1, on passe à l'€ !
- En parallèle, des encodages « maison » (8 bits) : mêmes défauts qu'ISO. Ne sont pas reconnus comme normes

Récapitulons

- 1968 - ASCII (7 bits) : c'est pas Noël !
- 1981 - ASCII étendu (8 bits) : c'est Noël sans la водка
- 1987 - Les ISO (8 bits) : Noël avec водка à part, mais toujours pas d'€
- 1997 - ISO-8859-15 (8 bits) : mise à jour d'ISO-8859-1, on passe à l'€ !
- En parallèle, des encodages « maison » (8 bits) : mêmes défauts qu'ISO. Ne sont pas reconnus comme normes
- On en reste à 8 bits = 256 caractères possibles, or le chinois en compte beaucoup plus !

Le projet Unicode

En 1988 (?) est élaboré un projet un peu fou : recenser tous les caractères de toutes les langues écrites existantes ou ayant existé et mettre au point une table de référence universelle capable de coder tout ça

L'entreprise colossale est aussitôt baptisée projet Unicode

Unicode se veut :

- universel : toutes les langues doivent être couvertes (même les plus rares)
- efficace : simple à analyser
- uniforme : nombre fixe de bits
- non-ambigu : une valeur = un seul caractère (une fois codé, éternel !)

La couverture d'Unicode

- Les 255 premiers caractères de la table Unicode sont ceux de la table ISO-5589-1

La couverture d'Unicode

- Les 255 premiers caractères de la table Unicode sont ceux de la table ISO-5589-1
- Première étape : les 63 586 caractères les plus utilisés sont réunis dans le Plan Multilingue de Base (PMB ou BMP en anglais)

La couverture d'Unicode

- Les 255 premiers caractères de la table Unicode sont ceux de la table ISO-5589-1
- Première étape : les 63 586 caractères les plus utilisés sont réunis dans le Plan Multilingue de Base (PMB ou BMP en anglais)
- Première publication de la norme Unicode, en 1991 : 65 536 caractères sont recensés et encodés

La couverture d'Unicode

- Les 255 premiers caractères de la table Unicode sont ceux de la table ISO-5589-1
- Première étape : les 63 586 caractères les plus utilisés sont réunis dans le Plan Multilingue de Base (PMB ou BMP en anglais)
- Première publication de la norme Unicode, en 1991 : 65 536 caractères sont recensés et encodés
- Aujourd'hui, Unicode version 17.0 (sept. 2025) contient 159 801 caractères

Ce qu'il y a dans Unicode

https ://tonsky.me/blog/unicode/

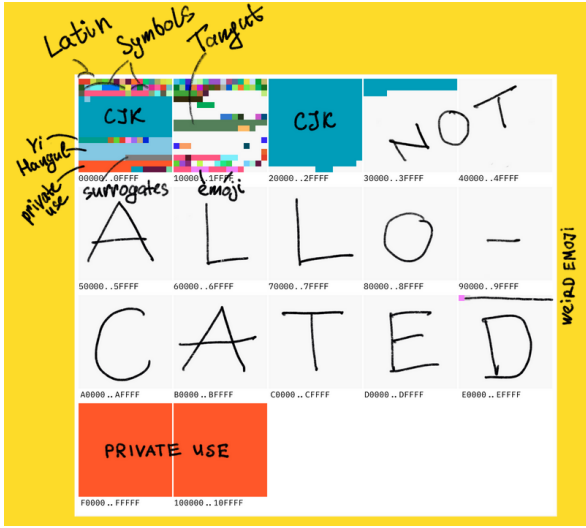

Le point de code Unicode

- En Unicode, une lettre correspond à quelque chose appelé un point de code qui n'est qu'un concept théorique
- Toute les lettres de tous les alphabets se sont vues attribuer un point de code par le consortium Unicode
- Ce point de code s'écrit : U+XXXX. Le U+ signifie « Unicode », et les X derrière sont en héxadécimal. U+FEC9 est la lettre arabe *Ain*. La lettre « A » correspond à U+0041
- Exemple : « Bonjour »
  U+0042 U+006F U+006E U+006A U+006F U+0075 U+0072

Exercice

Que représente U+1F4A9 ?

C'est bien beau tout ça, mais l'ordinateur il en fait quoi ?

- Le consortium Unicode a prévu trois principaux formats « transformés » pour l'encodage des point de code en binaire. Ces formats de transformation sont baptisés UTF(Unicode Transformation Format)
- UTF-32, UTF-16, UTF-8
- Le principe intangible derrière ces transformations étant que tout point de code Unicode doit pouvoir être retrouvé sans ambiguïté à partir de sa version transformée

Le gros simplet : UTF-32

- En UTF-32 (ou UCS-4), tout point de code Unicode est directement codé en sa valeur binaire, sur un nombre fixe de bits (32) l'encodage revenant alors à une simple conversion vers le binaire
- En contrepartie, ce format se révèle également le plus gourmand en ressources puisque chaque caractère, qu'il soit un « e » universel ou un idéogramme sud-indonésien, nécessitera quatre octets pour être codé
- UTF-32 est donc assez peu utilisé

L'indécis : UTF-16

- UTF-16 décompose les caractère Unicode en seizets binaires, soit 2 octets
- Ces 2 octets suffisent largement pour coder les caractères du PMB (partie correspondant à UCS-2)
- On utilise 2 seizets pour coder les autres. Ces seizets sont appelés seizets d'indirection (surrogate pair en anglais)
- UTF-16 est donc un encodage de longueur variable, en 16 ou 32 bits

L'économe : UTF-8

- Le format UTF-8 est, encore plus qu'UTF-16, un procédé d'encodage à « taille variable »

L'économe : UTF-8

- Le format UTF-8 est, encore plus qu'UTF-16, un procédé d'encodage à « taille variable »
- En UTF-8, chaque point de code de 0 à 127 (ASCII) est stocké sur un seul octet

L'économe : UTF-8

- Le format UTF-8 est, encore plus qu'UTF-16, un procédé d'encodage à « taille variable »
- En UTF-8, chaque point de code de 0 à 127 (ASCII) est stocké sur un seul octet
- Les points de code à partir de 128 et au delà sont stockés en utilisant 2, 3, et jusqu'à 4 octets (6 en principe) !

UTF-8 : comment ça marche ?

https ://tonsky.me/blog/unicode/

Code point	Byte 1	Byte 2	Byte 3	Byte 4
U+ 0000 .. 007F	0xxxxxxx			
U+ 0080 .. 07FF	110xxxxx	10xxxxxx		
U+ 0800 .. FFFF	1110xxxx	10xxxxxx	10xxxxxx	
U+ 10000 .. 10FFFF	11110xxx	10xxxxxx	10xxxxxx	10xxxxxx

Conclusion : machin-byte

- UTF-32 code toujours sur 4 octets
- UTF-16 est double-byte, puisqu'il utilise 2 octets (sauf pour les caractères qui nécessite des « surrogate pairs »)
- UTF-8 est lui multibyte, car il utilise entre 1 et 4 octets pour coder un caractère

Résumé

- UTF-32 : ␣ ␣ ␣ ␣

Résumé

- UTF-32 : ␣ ␣ ␣ ␣
- UTF-16 : ␣ ␣ + ␣ ␣

Résumé

- UTF-32 : ⊔ ⊔ ⊔ ⊔
- UTF-16 : ⊔ ⊔ + ⊔ ⊔
- UTF-8 : ⊔ + ⊔ + ⊔ + ⊔

Qui c'est le meilleur ?

- Avantages et inconvénients de chaque UTF ?
- UTF-32 est de longueur fixe, dont facile à traiter, mais il prend de la place
- UTF-16 est parfois plus délicat à manipuler, mais il prend moins de place et permet un bonne efficacité, même sur les caractères plus rares pour nous. C'est l'encodage du langage de programmation Java
- UTF-8 est le plus optimal pour un usage occidental, mais il prend beaucoup de place pour coder certains caractères. Il est en outre délicat à manipuler

Parenthèse sur les œufs durs

- Pour transmettre une séquence d'octets dans un flux de données, par exemple la lettre « A » (U+0041), on a le choix : on peut commencer par l'octet de poids faible puis l'octet de poids fort ([00] puis [41]) ou le contraire ([41] puis [00]), tout dépend du processeur

Parenthèse sur les œufs durs

- Pour transmettre une séquence d'octets dans un flux de données, par exemple la lettre « A » (U+0041), on a le choix : on peut commencer par l'octet de poids faible puis l'octet de poids fort ([00] puis [41]) ou le contraire ([41] puis [00]), tout dépend du processeur
- Par exemple, les SPARC (Solaris) étaient en big-endian alors que les Intel (PC et Mac) étaient/sont en little-endian

Parenthèse sur les œufs durs

- Pour transmettre une séquence d'octets dans un flux de données, par exemple la lettre « A » (U+0041), on a le choix : on peut commencer par l'octet de poids faible puis l'octet de poids fort ([00] puis [41]) ou le contraire ([41] puis [00]), tout dépend du processeur
- Par exemple, les SPARC (Solaris) étaient en big-endian alors que les Intel (PC et Mac) étaient/sont en little-endian
- Comment gérer ça en Unicode ?

Les petits et les grands Boutistes

- solution BE (pour Big Endian) : les octets sont transmis dans un ordre décroissant de poids (le point de code U+0041 est donc décomposé en la séquence [00-41])
- solution LE (pour Little Endian) : les octets sont transmis dans un ordre croissant de poids (le point de code U+0041 est alors décomposé en la séquence [41-00])

Les indéterminés

- solution indéterminée : on peut choisir entre l'une ou l'autre méthode à condition d'indiquer en tout début de transmission la solution retenue, grâce à un point de code particulier appelé BOM (Byte Order Mark) et codé U+FEFF (big-endian) ou FFFE (little-endian)

À noter

la BOM n'est utile qu'en UTF-16 et UTF-32, mais elle est souvent ajoutée pour marquer l'UTF-8 (mais n'est pas obligatoire).
Elle est alors encodée EF BB BF

En quoi ça nous concerne ?

- Avez-vous déjà rencontré un ï»¿ en début de fichier, dans Notepad, par exemple ?

En quoi ça nous concerne ?

- Avez-vous déjà rencontré un ï»¿ en début de fichier, dans Notepad, par exemple ?
- C'est la représentation en ISO 1 d'une BOM et ça prouve que votre fichier est en UTF-8

En quoi ça nous concerne ?

- Avez-vous déjà rencontré un ï»¿ en début de fichier, dans Notepad, par exemple ?
- C'est la représentation en ISO 1 d'une BOM et ça prouve que votre fichier est en UTF-8
- Ça prouve aussi que votre éditeur est une truffe

En quoi ça nous concerne ?

- Avez-vous déjà rencontré un ï»¿ en début de fichier, dans Notepad, par exemple ?
- C'est la représentation en ISO 1 d'une BOM et ça prouve que votre fichier est en UTF-8
- Ça prouve aussi que votre éditeur est une truffe
- La BOM peut aussi poser des problèmes à certains programmes

Récapitulons

- Unicode : norme permettant de coder tous les caractères de toutes les langues du monde de manière non ambiguë
- Distinction points de code et formats de transformation
- Les UTF (formats de transformation) : UTF-32 (4 octets), UTF-16 (2+2 octets), UTF-8 (de 1 à 4 octets)
- La BOM (Byte Order Mark) : sert d'indicateur de sens pour la lecture des octets, peut apparaître au début de certains fichiers utf-8 sous la forme ï»¿

Limitations d'Unicode (1/2)

- Le Consortium Unicode est agité de nombreux débats, ce qui est plutôt bon signe !
- Exemple 1 : le Consortium Unicode et l'ISO considèrent que les caractères chinois, coréens et japonais sont les mêmes, que seuls les glyphes diffèrent... ce qui fait l'objet d'un débat houleux.
- Exemple 2 : certaines écritures africaines représentant des populations importantes (le tifinagh par exemple) ne sont pas aussi bien représentées que des écritures américaines bien moins utilisées (le déséret, par exemple).

Limitations d'Unicode (2/2)

- Exemple 3 : certains Bretons se plaignent de l'absence du K barré et de caractères uniques pour représenter CH et C'H.
- Exemple 4 : d'aucuns reprochent à Unicode d'avoir apparemment favorisé certaines écritures en les codant d'une façon plus simple ou plus adéquate. Le gothique, par exemple, n'est pas codé en tant que tel et son affichage correct nécessite l'ajout d'un protocole de niveau supérieur ou de caractères de commande à sa translittération latine.

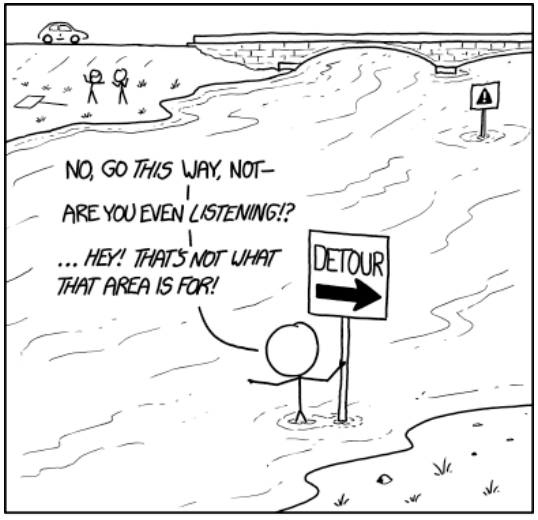

WATCHING THE UNICODE PEOPLE TRY TO GOVERN THE INFINITE CHAOS OF HUMAN LANGUAGE WITH CONSISTENT TECHNICAL STANDARDS IS LIKE WATCHING HIGHWAY ENGINEERS TRY TO STEER A RIVER USING TRAFFIC SIGNS.

Le langage de l'ordinateur

Normes

Désigner une langue

Conclusion

Pour finir

Comment désigner une langue ?

Donner un nom a une langue est délicat. En effet, le nom des langues désignées est défini par la langue d'usage.
ex. : allemand, deutch, German, tedesco, ... désigne la langue allemande (en français, allemand, anglais, slovène, italien, ...)

Il est délicat de choisir une langue particulière pour faire cette désignation (ex : tout désigner en anglais...).

On ne peut pas non plus choisir de désigner une langue sous son nom "propre" (ex : English pour anglais, français pour français,...). Cela serait délicat à écrire pour les langues orales, et difficiles à prononcer pour les langues à système d'écriture inconnu du lecteur...

Comment désigner une langue ?

Il faut donc trouver un système pour nommer une langue qui soit :

- simple à mettre en œuvre,
- facilement transportable (utilisation uniquement de caractères ASCII),
- compréhensible par tous (via une norme).

Il s'agit de la norme ISO-639.

la norme ISO-639

ISO 639 fournit trois [1] ensembles de codes de langues :

- ISO 639-1 (alpha-2) utilise des codes sur 2 caractères, et les associent avec les noms en français, en anglais et dans la langue elle-même ;
- ISO 639-2 (alpha-3) utilise des codes sur 3 caractères et a deux codages possibles : ISO 639-2/B (bibliographiques) et ISO 639-2/T (terminologiques) ; les codes sont associés avec des noms en français et en anglais.
- ISO 639-3 complète l'ISO 639-2 avec de très nombreuses autres langues encore manquantes ; SIL [2] en est l'auteur principal et est en charge des enregistrements dans ce volet de la norme ; seuls les noms en anglais sont associés aux codes ajoutés.

1. nouveau en 2007
2. www.sil.org

la norme ISO-639 (suite)

Ces trois ensembles ont des motivations différentes :

- ISO 639-1 (alpha-2) a été construit principalement pour des utilisation en terminologie, lexicographie et linguistique ; il contient des langues répandues et pour lesquelles il existe de nombreuses ressources terminologiques ;
- ISO 639-2 (alpha-3) a été construit pour des utilisations en bibliographie et terminologie ; il contient les langages de la partie 1, ainsi que de nombreux autres ayant une littérature abondante.
- ISO 639-3 vise à fournir une énumération de langues la plus complète possible, y compris les langues vivantes, les langues mortes, les langues anciennes et les langues construites artificiellement [3], qu'elles soient majeures ou mineures, écrites ou orales.

3. comme l'espéranto, le volapük, le klingon, etc. il ne s'agit pas de langages artificiels

Présentation de la norme ISO 639-3

L'ensemble des codes :

```
CREATE TABLE ISO_639-3 (
   Id       char(3) NOT NULL,
            -- The three-letter 639-3 identifier
   Part2B   char(3) NULL,
            -- Equivalent 639-2 identifier of the bibliographic applications
            -- code set, if there is one
   Part2T   char(3) NULL,
            -- Equivalent 639-2 identifier of the terminology applications
            -- code set, if there is one
   Part1    char(2) NULL,
            -- Equivalent 639-1 identifier, if there is one
   Scope    char(1) NOT NULL,
            -- I(ndividual), M(acrolanguage), S(pecial)
   Type     char(1) NOT NULL,
            -- A(ncient), C(onstructed),
            -- E(xtinct), H(istorical), L(iving), S(pecial)
   Ref_Name    varchar(150) NOT NULL)
          -- Reference language name
```

Extrait de la table des codes

Id	Part2B	Part2T	Part1	Scope	Type	Ref_Name
aao				I	L	Algerian Saharan Arabic
abh				I	L	Tajiki Arabic
ara	ara	ara	ar	**M**	L	Arabic
czh				I	L	Huizhou Chinese
deu	ger	deu	de	I	L	German
epo	epo	epo	eo	I	**C**	Esperanto
fra	fre	fra	fr	I	L	French
frm	frm	frm		I	**H**	Middle French (ca. 1400-1600)
fro	fro	fro		I	H	Old French (842-ca. 1400)
mis	mis	mis		S	S	Uncoded languages
mjy				I	**E**	Mahican
mul	mul	mul		**S**	**S**	Multiple languages
nut				I	L	Nung (Viet Nam)
und	und	und		**S**	**S**	Undetermined
vie	vie	vie	vi	I	L	Vietnamese
zho	chi	zho	zh	M	L	Chinese
zxx	zxx	zxx		S	S	No linguistic content

Présentation de la norme ISO 639-3

Le mapping des "macrolangues" :

```
CREATE TABLE ISO_639-3_Macrolanguages (
   M_Id  char(3) NOT NULL,  -- The identifier for a macrolanguage
   I_Id  char(3) NOT NULL)  -- The identifier for an individual language
                            -- that is a member of the macrolanguage
```

Extrait de la table des Macrolangues

M_Id	**I_Id**	Explication
ara	aao	Algerian Saharan Arabic fait partie de Arabic
ara	abh	Tajiki Arabic fait partie de Arabic
ara	abv	
zho	cjy	
zho	cmn	
zho	cpx	
zho	czh	Huizhou Chinese fait partie de Chinese

Autres informations en vrac

- il existe une table décrivant les code ayant été retirés (si vous ne trouvez pas le votre...)
- les codes qaa à qtz sont des codes réservés à un usage local ; ils ne doivent être transmis qu'après accord entre les parties
- le ISO 639-3 Registration Authority est SIL International, www.sil.org (Dallas, Texas)
- la table des codes contient 7642 entrées (430 langues mortes, 4 spéciales, 63 historiques, 114 anciennes, 17 construites)

Autres problèmes liés au multilinguisme

- Right-to-left (arabe, hébreu) : ou comment insérer un système d'écriture de droite à gauche dans un système d'écriture de gauche à droite (Texte bi-directionnel) ? Facile, des marques de contrôle sont prévues afin de pouvoir changer le sens d'écriture (en HTML, attribut DIR="rtl" ou "ltr").
- Agglutinations (arabe).

Les retours à la ligne, ne quittez pas !

- Selon les plate-formes, le caractère représentant le saut de ligne n'est pas le même.
- Windows : CR+LF (Carriage Return Line Feed, héritage de la machine à écrire !)
- Monde Unix : LF
- Mac : CR

Les raccourcis ? Même pas peur !

- Il existe un UTF-7, utilisé pour les mails, par exemple.

Les raccourcis ? Même pas peur !

- Il existe un UTF-7, utilisé pour les mails, par exemple.
- Des vrais chiffres peuvent être déclarés pour que l'ordinateur fasse des opérations dessus.

Les raccourcis ? Même pas peur !

- Il existe un UTF-7, utilisé pour les mails, par exemple.
- Des vrais chiffres peuvent être déclarés pour que l'ordinateur fasse des opérations dessus.
- Il existe un troisième jeu de caractères en chinois, le nushu, utilisé uniquement par des femmes...

Les outils qui sauvent

- Bon éditeur de texte brut : Notepad++ (Windows), Sublime Text (Windows, Mac, Linux), Gedit (Linux)
- Editeur qui permette l'ouverture en binaire (hexa) : Visual, Eclipse (outils de dév.)

Définitions (Wikipedia) 1/3

- bit : unité de mesure désignant la quantité élémentaire d'information représentée par un chiffre du système binaire.
- octet : une unité de mesure en informatique mesurant la quantité de données. Un octet est lui-même composé de 8 bits, soit 8 chiffres binaires. Le byte, soit la plus petite unité adressable d'un ordinateur, a presque toujours une taille d'un octet et les deux mots sont généralement, mais abusivement, considérés comme synonymes.

Définitions 2/3

- charset / jeu de caractères : ensemble de caractères.
  Exemple : ISO Latin-1, Unicode.
- encodage : façon dont les caractères, dans un alphabet donné, sont convertis en octet. L'encodage n'indique absolument pas comment ces caractères seront affichés à l'écran ou après impression.
  Exemple : iso-8859-1, UTF-8.

Définitions (Wikipedia) 3/3

- police et fonte : une fonte de caractères, en typographie, est un ensemble de glyphes, c'est-à-dire de représentations visuelles de caractères, d'une même famille, de même style, corps et graisse. Elle se distingue de la police d'écriture qui regroupe tous les corps et graisses d'une même famille, dont le style est coordonné.

Le langage de l'ordinateur

Normes

Désigner une langue

Conclusion

Pour finir
- CQFR : Ce Qu'il Faut Retenir
- TD

- bit, octet
- ASCII, tables ISO, Unicode
- ISO 639

Exercice non noté

La fonction *ord* de python3 renvoie le code unicode d'un caractère. *chr* est la fonction inverse.
La liste [233, 112, 97, 116, 97, 110, 116, 32, 33] correspond à la liste des codes unicodes d'une chaîne.

Laquelle ?