

Codifiche di caratteri

Gli standard principali

ASCII (e varianti)

La famiglia ISO 8859

ISO/IEC 10646, UCS e Unicode

Ma anche glifi e fonts

Tre concetti indipendenti ma interconnessi

€ Il repertorio di caratteri

£ Il codice

 Le codifiche

Il repertorio di caratteri

Semplicemente un insieme di caratteri.

Non è necessariamente un alfabeto, ma un alfabeto è un buon esempio:

- greco
- latino
- cirillico

I codici

I codici codificano i caratteri dunque mettono in corrispondenza biunivoca i caratteri con dei numeri.

A ciascun elemento (carattere) è associato
Il suo codice numerico detto "code position"

La codifica

La codifica è la mappatura tra code position e bytes e dipende dai casi

- sotto i 256 simboli viene fatta con un byte
- sotto i 65536 simboli con due byte
- oltre con altri byte o con codifiche complesse

Codifica ASCII

ASCII: American Standard Code for Information Interchange

È uno standard ANSI che mappa valori per 128 caratteri usando 7 bit su 8 di un byte (il primo bit - a sinistra non è significativo, viene usato per il controllo di parità).

Il termine ASCII è utilizzato sia per i caratteri che per la codifica

ASCII

**33 caratteri (0-31 e 127) sono di controllo,
con ripetizioni**

Backspace (sposta la testina indietro di un carattere, utile nelle telescriventi - 08 [0x08]) e

Delete (cancella tutti i buchi di un carattere in una scheda perforata, cioè tutti buchi, 1111111 - 127 [0x7F]).

Carriage Return (riporta la testina all'inizio di riga - 13 [0x0C]) e

Form Feed (gira il carrello di una riga - 14 [0x0D])

ASCII

Gli altri 95, composti da caratteri dell'alfabeto latino, maiuscole e minuscole, numeri e punteggiatura sono qui di seguito rappresentati (il primo e l'ultimo sono spazi bianchi):

! " # \$ % & ' () * + , - . /
0 1 2 3 4 5 6 7 8 9 : ; < = > ?
@ A B C D E F G H I J K L M N O
P Q R S T U V W X Y Z [\] ^ _
` a b c d e f g h i j k l m n o
p q r s t u v w x y z { | } ~

Variazioni dell'ASCII

Esistono molte variazioni internazionali dell'ASCII.

In queste variazioni alcuni caratteri sono sostituiti da

- simboli speciali propri della nazione che ha creato la variante.

Qualche volta si parla dell'ASCII a "8 bit" questo nome è utilizzato per indicare varie codifiche che sono estensioni dell'ASCII nel senso che contengono ASCII come sottoinsieme ma utilizzano l'intervallo 128-255 per estendere l'insieme.

Byte	Cod.	Char	Byte	Cod.	Char	Byte	Cod.	Char	Byte	Cod.	Char
00000000	0	Null	00100000	32	Spc	01000000	64	@	01100000	96	`
00000001	1	Start of heading	00100001	33	!	01000001	65	A	01100001	97	a
00000010	2	Start of text	00100010	34	"	01000010	66	B	01100010	98	b
00000011	3	End of text	00100011	35	#	01000011	67	C	01100011	99	c
00000100	4	End of transmit	00100100	36	\$	01000100	68	D	01100100	100	d
00000101	5	Enquiry	00100101	37	%	01000101	69	E	01100101	101	e
00000110	6	Acknowledge	00100110	38	&	01000110	70	F	01100110	102	f
00000111	7	Audible bell	00100111	39	'	01000111	71	G	01100111	103	g
00001000	8	Backspace	00101000	40	(01001000	72	H	01101000	104	h
00001001	9	Horizontal tab	00101001	41)	01001001	73	I	01101001	105	i
00001010	10	Line feed	00101010	42	*	01001010	74	J	01101010	106	j
00001011	11	Vertical tab	00101011	43	+	01001011	75	K	01101011	107	k
00001100	12	Form Feed	00101100	44	,	01001100	76	L	01101100	108	l
00001101	13	Carriage return	00101101	45	-	01001101	77	M	01101101	109	m
00001110	14	Shift out	00101110	46	.	01001110	78	N	01101110	110	n
00001111	15	Shift in	00101111	47	/	01001111	79	O	01101111	111	o
00010000	16	Data link escape	00110000	48	0	01010000	80	P	01110000	112	p
00010001	17	Device control 1	00110001	49	1	01010001	81	Q	01110001	113	q
00010010	18	Device control 2	00110010	50	2	01010010	82	R	01110010	114	r
00010011	19	Device control 3	00110011	51	3	01010011	83	S	01110011	115	s
00010100	20	Device control 4	00110100	52	4	01010100	84	T	01110100	116	t
00010101	21	Neg. acknowledge	00110101	53	5	01010101	85	U	01110101	117	u
00010110	22	Synchronous idle	00110110	54	6	01010110	86	V	01110110	118	v
00010111	23	End trans. block	00110111	55	7	01010111	87	W	01110111	119	w
00011000	24	Cancel	00111000	56	8	01011000	88	X	01111000	120	x
00011001	25	End of medium	00111001	57	9	01011001	89	Y	01111001	121	y
00011010	26	Substitution	00111010	58	:	01011010	90	Z	01111010	122	z
00011011	27	Escape	00111011	59	;	01011011	91	[01111011	123	{
00011100	28	File separator	00111100	60	<	01011100	92	\	01111100	124	
00011101	29	Group separator	00111101	61	=	01011101	93]	01111101	125	}
00011110	30	Record Separator	00111110	62	>	01011110	94	^	01111110	126	~
00011111	31	Unit separator	00111111	63	?	01011111	95	_	01111111	127	Del

Tabella ASCII Estesa

Byte	Cod.	Char	Byte	Cod.	Char	Byte	Cod.	Char	Byte	Cod.	Char
10000000	128	Ç	10100000	160	á	11000000	192	+	11100000	224	Ó
10000001	129	ü	10100001	161	í	11000001	193	-	11100001	225	Ø
10000010	130	é	10100010	162	ó	11000010	194	-	11100010	226	Ô
10000011	131	â	10100011	163	ú	11000011	195	+	11100011	227	Ò
10000100	132	ä	10100100	164	ñ	11000100	196	-	11100100	228	ö
10000101	133	à	10100101	165	Ñ	11000101	197	+	11100101	229	Õ
10000110	134	ã	10100110	166	ª	11000110	198	ä	11100110	230	µ
10000111	135	ç	10100111	167	•	11000111	199	Ã	11100111	231	þ
10001000	136	ê	10101000	168	¿	11001000	200	+	11101000	232	ƒ
10001001	137	ë	10101001	169	®	11001001	201	+	11101001	233	Ú
10001010	138	è	10101010	170	¬	11001010	202	-	11101010	234	Û
10001011	139	ÿ	10101011	171	½	11001011	203	-	11101011	235	Ü
10001100	140	î	10101100	172	¼	11001100	204	-	11101100	236	Ý
10001101	141	ï	10101101	173	¡	11001101	205	-	11101101	237	Ÿ
10001110	142	À	10101110	174	«	11001110	206	+	11101110	238	-
10001111	143	Á	10101111	175	»	11001111	207	α	11101111	239	·
10010000	144	Ê	10110000	176	-	11010000	208	δ	11110000	240	-
10010001	145	æ	10110001	177	-	11010001	209	Ð	11110001	241	±
10010010	146	Æ	10110010	178	-	11010010	210	Ê	11110010	242	-
10010011	147	ô	10110011	179	-	11010011	211	Ë	11110011	243	¾
10010100	148	ö	10110100	180	-	11010100	212	È	11110100	244	¶
10010101	149	ò	10110101	181	À	11010101	213	É	11110101	245	§
10010110	150	û	10110110	182	Â	11010110	214	Í	11110110	246	÷
10010111	151	ù	10110111	183	Ã	11010111	215	Î	11110111	247	·
10011000	152	ÿ	10111000	184	©	11011000	216	Ï	11111000	248	°
10011001	153	Ö	10111001	185	-	11011001	217	+	11111001	249	"
10011010	154	Û	10111010	186	-	11011010	218	+	11111010	250	.
10011011	155	ø	10111011	187	+	11011011	219	-	11111011	251	1
10011100	156	£	10111100	188	+	11011100	220	-	11111100	252	3
10011101	157	Ø	10111101	189	¢	11011101	221	-	11111101	253	2
10011110	158	×	10111110	190	¥	11011110	222	-	11111110	254	-
10011111	159	f	10111111	191	+	11011111	223	-	11111111	255	-

ISO Latin 1

Una estensione dell'ASCII standard che comprende alcuni caratteri un certo numero di caratteri degli alfabeti europei come accenti, ecc. è l'ISO 8859-1 (della famiglia ISO 8859) che comprende il repertorio di caratteri "Latin alphabet No. 1", noto come ISO Latin 1.

ISO Latin 1 è compatibile all'indietro con ASCII, di cui è un'estensione per i soli caratteri >127.

ISO Latin 1

I caratteri dell'ISO Latin 1 che occupano le posizioni da 160 a 255:

A0	A1	A2	A3	A4	A5	A6	A7	A8	A9	AA	AB	AC	AD	AE	AF
	ı	ϕ	£	¤	¥	ı	§	¨	©	ª	«	¬	–	®	–
B0	B1	B2	B3	B4	B5	B6	B7	B8	B9	BA	BB	BC	BD	BE	BF
°	±	²	³	´	µ	¶	·	¸	¹	º	»	¼	½	¾	¿
C0	C1	C2	C3	C4	C5	C6	C7	C8	C9	CA	CB	CC	CD	CE	CF
À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
D0	D1	D2	D3	D4	D5	D6	D7	D8	D9	DA	DB	DC	DD	DE	DF
Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
E0	E1	E2	E3	E4	E5	E6	E7	E8	E9	EA	EB	EC	ED	EE	EF
à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
F0	F1	F2	F3	F4	F5	F6	F7	F8	F9	FA	FB	FC	FD	FE	FF
ä	ñ	õ	ö	ô	ö	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

La famiglia ISO 8859: Estende ascii per altri alfabeti

iso-8859-1, Latin1, L1	Europa dell'Ovest
iso-8859-2, latin2, L2	Europa centrale e dell'Est
iso-8859-3, latin3, L3	Esperanto, Maltese
iso-8859-4, latin4, L4	Lingue baltiche
iso-8859-5, cyrillic	Bulgaro, Bielorusso, Macedone, Russo, Serbo
iso-8859-6, arabic	Arabo
iso-8859-7, greek, greek8	Greco
iso-8859-8, hebrew	Ebraico
iso-8859-9, latin5, L5	Turco
iso-8859-10, latin6, L6	Lingue nordiche
iso-8859-13	Lingue baltiche
iso-8859-14, latin8, L8	Lingue Celte
iso-8859-15	Europa dell'Ovest (Simbolo dell'Euro €)

ISO/IEC 10646, UCS e Unicode

Negli anni '90 sono state avviate due iniziative parallele per sistemare in modo definitivo il problema della rappresentazione dei caratteri:

la prima gestita dal consorzio Unicode (una organizzazione no-profit in cui convergono numerosi produttori di sistemi informatici), e la seconda dall'ISO.

Da queste iniziative sono nati dal consorzio Unicode e ISO 10646/UCS, due codifiche di caratteri che sono perfettamente allineati (le differenze riguardano solo aspetti tecnici) e che possono definirsi 'universali'. UCS sta infatti per "Universal Character Set" e corrisponde ad un vastissimo repertorio di caratteri e il suo corrispondente insieme di codici.

Unicode

Lo standard Unicode definito dallo Unicode Consortium era originalmente progettato per essere un codice a 16 bit (che equivale a 2^{16} 65536 caratteri), ma fu esteso in modo da permettere codici nell'intervallo esadecimale 0..10FFFF vale a dire 1 114 112 caratteri.

Tipicamente un carattere Unicode viene identificato con l'abbreviazione U+xxxx dove xxxx è un numero esadecimale a quattro cifre. Ad esempio la lettera A viene indicata in Unicode come U+0041 (65 in decimale).

UCS-2 e UTF-16

UCS-2 e UTF-16 sono i nomi due codifiche di caratteri quasi identiche.

UCS-2 è uno schema a due byte ed è sostanzialmente un'estensione di ISO Latin 1.

Ad esempio nel caso della lettera maiuscola A rappresentata in ISO Latin 1 con il codice 41 esadecimale in UCS-2 verrebbe rappresentato da 2 bytes 00 41.

UCS-2: svantaggi

L'uso di UCS-2 comporta, però, tre svantaggi:

il file occupano il doppio di spazio rispetto a quelli codificati in ISO Latin 1 (due byte invece di uno);

UCS-2 non è compatibile all'indietro con ASCII (programmi che si aspettano testi codificati con byte singoli non possono leggere testi in UCS-2);

UCS-2 è limitato a rappresentare massimo 65.536 caratteri.

UTF-8

Unicode Transformation Format

UTF-8 è una codifica a lunghezza variabile di Unicode che risolve i primi due problemi dell'UCS-2 di cui si è discusso sopra.

I caratteri da 0 a 127, ovvero il set di caratteri ASCII, vengono codificati con un byte ciascuno, esattamente come avviene nella codifica ASCII.

In ASCII, il byte con valore 65 rappresenta la lettera A e anche in UTF-8 il byte 65 rappresenta la lettera A. Quindi esiste un'identità uno-a-uno tra i caratteri ASCII e i byte di UTF-8.

Questo significa che i file scritti in ASCII puro risultano anche accettabili come file UTF-8.

UTF-8

UTF-8 permette di accedere a tutti i caratteri definiti di UCS-4, ma utilizza un numero compreso tra 1 e 4 byte per farlo

i codici compresi tra 0 - 127 (ASCII a 7 bit) richiedono un byte, in cui ci sia 0 al primo bit;

i codici derivati dall'alfabeto latino e tutti gli script non-ideografici richiedono 2 byte;

i codici ideografici (orientali) richiedono 3 byte;

UTF-8

U-00000000 – U-0000007F:	0xxxxxxx
U-00000080 – U-000007FF:	110xxxxx 10xxxxxx
U-00000800 – U-0000FFFF:	1110xxxx 10xxxxxx 10xxxxxx
U-00010000 – U-001FFFFFF:	11110xxx 10xxxxxx 10xxxxxx 10xxxxxx

Glifi e Fonts

Per mostrarci un testo sullo schermo o stamparlo su carta, il computer ha bisogno di codificare due tipi di informazioni diverse:

- il puro e semplice contenuto del testo (plain text)

- la forma o layout del testo, cioè una serie di codici che ne definiscono il formato (numero di colonne, larghezza dei margini, eccetera)

- e determinati

- attribuiti grafici (il tipo di font, la dimensione del testo, il suo colore, eccetera) - (rich text)

Glifo

Il glifo è una particolare forma con cui un carattere può essere rappresentato sullo schermo o su carta.

Per esempio, il carattere Z potrebbe essere rappresentato come grassetto **Z** o corsivo *Z*.

D'altra parte, il carattere minuscolo z è definito come un carattere separato, il quale a sua volta potrebbe essere associato ad un glifo diverso.

In Unicode ci sono diversi esempi di caratteri che potrebbero essere considerate semplicemente delle varianti tipografiche di uno stesso carattere, ma che per varie ragioni sono tenuti come caratteri separati.

Font

Un repertorio di glifi costituisce un font.

Più tecnicamente un font è un insieme numerato di glifi. Il numero corrisponde al codice del carattere (rappresentato dal glifo).

Quindi in certo senso il font è dipendente dal codice del carattere.

È possibile che un glifo utilizzato per un dato carattere venga utilizzato per altri caratteri.