

Cours sur le codage des caractères

Thème représentation des données : types et valeurs de base



Introduction

Le but de ce chapitre est de comprendre comment les textes sont représentés dans un ordinateur et d'apprendre à manipuler le type `str` de Python qui leur est dédié.



Crédits



Le contenu de ce cours est directement inspiré du chapitre 21 du *Manuel de première NSI* chez Ellipses.
La plupart des exercices sont tirés de la plateforme <https://codex.forge.apps.education.fr/>.

1 Chaînes de caractères en Python



Méthode

- Une chaîne de caractères est une séquence éventuellement vide de caractères. Chaque caractère est une chaîne de longueur 1. Nous étudierons la représentation informatique d'un caractère un peu plus loin.

En Python, les chaînes de caractères définissent le type `str`. La longueur d'une chaîne de caractères s'obtient avec la fonction `len`.

```
In [6]: a = 1

In [7]: type(a)
Out[7]: int

In [8]: b = str(a)

In [9]: b, type(b)
Out[9]: ('1', str)

In [10]: len(b), len('un'), len('')
Out[10]: (1, 2, 0)
```

- Les chaînes de caractères partagent certaines propriétés avec les tableaux de type `list` et les *p*-uplets de type `tuple` :
 - Une chaîne de caractères `chaine` peut être vue comme un tableau de caractères indexés de 0 à `len(chaine) - 1` de gauche à droite et de `-1` à `-len(chaine)` de droite à gauche. L'opérateur crochet permet d'accéder au caractère d'index `i` avec la syntaxe `chaine[i]` ou à la tranche de caractères d'index appartenant à l'intervalle `[i; j[` avec la syntaxe `chaine[i:j]` si $0 \leq i \leq j$ ou à l'intervalle `]j; i]` avec la syntaxe `chaine[i:j:-1]` si $-1 \geq i \geq j$.



Le découpage en tranches et les index négatifs peuvent être pratiques pour manipuler les

chaînes de caractères mais ne sont pas au programme de première NSI.

```
In [26]: chaine = 'XYZT'

In [27]: chaine[0], chaine[1], chaine[len(chaine)-1]
Out[27]: ('X', 'Y', 'T')

In [28]: chaine[-1], chaine[-2], chaine[-len(chaine)]
Out[28]: ('T', 'Z', 'X')

In [29]: chaine[1:3], chaine[-1:-len(chaine):-1]
Out[29]: ('YZ', 'TZY')
```

- On peut itérer sur une chaîne de caractères avec une boucle for.

```
In [18]: for c in 'XY':
...:     print(c)
...:
X
Y
```

- On peut concaténer deux chaînes pour créer une nouvelle chaîne avec l'opérateur +.

```
In [19]: a, b, c = 'belle', '-', 'ile'

In [20]: a + b + c
Out[20]: 'belle-ile'
```

👉 Une chaîne de caractères d'identifiant `chaine` est un objet Python qui intègre de nombreuses méthodes accessibles avec la notation pointée `chaine.methode()`. On peut les découvrir en saisissant `dir(chaine)` ou dans la documentation en ligne :

<https://docs.python.org/3/library/stdtypes.html#text-sequence-type-str>

```
In [24]: a = 'un beau marin'

In [25]: a.find('beau')
Out[25]: 3

In [26]: a.replace('b', 'v')
Out[26]: 'un veau marin'

In [27]: a.upper()
Out[27]: 'UN BEAU MARIN'

In [28]: 'un beau marin'.replace(' ', '')
Out[28]: 'unbeaumarin'

In [29]: dir(a)
Out[29]: ['__add__', '__class__', '__contains__', ... ]
```

 Exercice 1

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/liste_longueurs/ de la plateforme Codex.

 Exercice 2

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice <https://codex.forge.apps.education.fr/exercices/channiv/> de la plateforme Codex.

 Exercice 3

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/anonymat_1/ de la plateforme Codex.

 Exercice 4

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/renverse_chaine/ de la plateforme Codex.

 Exercice 5

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/est_nb_palindrome/ de la plateforme Codex.

 Exercice 6

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice <https://codex.forge.apps.education.fr/exercices/dentiste/> de la plateforme Codex.

 Exercice 7

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/validation_mdp/ de la plateforme Codex.

 Exercice 8

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/est_inclus/ de la plateforme e-nsi.

2 Du code ASCII à l'Unicode

Humans use text. Computers speak bytes.

Esther Nam and Travis Fischer, *Character encoding and Unicode in Python*

2.1 Table de codage et encodage



Point de cours 1

Une représentation informatique des caractères nécessite d'associer à chaque caractère une unique séquence d'octets. Cette conversion s'effectue à l'aide d'une **table de codage** et d'un **encodage**.

- ☞ Une **table de codage** ou **jeu de caractères** ou **charset**, associe un entier nommé **point de code** à un caractère.
- ☞ Un **encodage** associe à un **point de code** une séquence d'octets.



Remarque 1

- **Table de codage** et **encodage** sont des bijections : deux caractères distincts ont des points de code et des encodages distincts.
- Il peut exister plusieurs encodages pour une même table de codage. Par exemple la table Unicode admet les encodages UTF-8, UTF-16, UTF-32 ...

Par exemple le caractère '€' dont le point de code Unicode est 8364 a pour encodages (voir <https://www.compart.com/fr/unicode/U+20AC>) :

- 0xE2 0x82 0xAC en UTF-8 sur 3 octets notés en hexadécimal
- 0x20 0xAC en UTF-16 sur 2 octets notés en hexadécimal
- 0x00 0x00 0x20 0xAC en UTF-32 sur 4 octets notés en hexadécimal

- Avec l'internationalisation des échanges, on a besoin d'un encodage *compact* (économique en octets), *portable* (compatibilité entre les différents programmes) et *universel* (représentation de tous les caractères possibles).

2.2 Table de codage ASCII



Point de cours 2

Au début des années 1960, devant la multiplication des encodages de caractères et leurs incompatibilités mutuelles, l'ANSI (*American National Standards Institute*), définit une norme appelée **ASCII** (*American Standard Code for Information Interchange*).

Ce standard permet de coder 128 caractères sur 7 bits ($2^7 = 128$), le bit de poids fort étant réservé à des contrôles d'erreur : ce bit de parité est choisi pour que le nombre total de bits à 1 dans l'octet soit toujours pair.

La table de codage **ASCII** représentée en Annexe 9 contient :

- les lettres de l'alphabet latin en majuscule et minuscule et les chiffres de 0 à 9;
- des signes de ponctuation et des opérateurs arithmétiques;
- des caractères spéciaux (tabulation, retour chariot, nouvelle ligne ...) et des caractères de contrôle non imprimables pour des protocole de communication et des contrôles de périphériques (Fin de transmission, EOT, demande de transmission ENQ ...).

Méthode

- ☞ En Python, la fonction `ord` associe à un caractère son point de code ASCII (en fait Unicode) et la fonction `chr` est sa réciproque :

```
In [39]: ord('a'), ord('z'), ord('A'), ord('Z')
Out[39]: (97, 122, 65, 90)

In [40]: chr(65), chr(90)
Out[40]: ('A', 'Z')

In [41]: [chr(ord('a') + k) for k in range(26)]
Out[41]: ['a', 'b', 'c', '...', 'y', 'z']

In [42]: ''.join([chr(ord('a') + k) for k in range(26)])
Out[42]: 'abcdefghijklmnopqrstuvwxyz'
```

- ☞ Les opérateurs de comparaison entre caractères `==`, `<` et `>` comparent les points de code.

```
In [3]: 'a' < 'A'
Out[3]: False

In [4]: ord('a'), ord('A')
Out[4]: (97, 65)
```

- ☞ Pour les chaînes de caractères, la comparaison s'effectue de gauche à droite caractère par caractère. En cas d'inclusion d'une chaîne dans l'autre, la plus petite est celle qui est incluse. On parle d'**ordre alphabétique**.



Si on compare deux entiers convertis en chaînes de caractères l'ordre alphabétique peut ne pas donner le même résultat que l'ordre numérique.

```
In [7]: 'abc' < 'abcd'
Out[7]: True

In [8]: 'bbc' > 'ab'
Out[8]: True

In [9]: '2' > '10'
Out[9]: True
```

 Exercice 9

Traiter dans le carnet Capytale de code **9aac-5273384** l'exercice https://codex.forge.apps.education.fr/exercices/conversion_chaines/ de la plateforme Codex.

 Exercice 10

1. Définir le chiffrement d'une chaîne de caractères par l'algorithme rot13.

Ressources : <https://fr.wikipedia.org/wiki/ROT13>

.....
.....

2. L'image par rot13 du caractère 'R' est 'E'.

- on calcule d'abord le rang alphabétique d'un caractère :

```
In [56]: ord('R') - ord('A')  
Out[56]: 17
```

- puis on ajoute 13 à ce rang et on prend le reste dans la division euclidienne par 26

```
In [59]: (ord('R') - ord('A') + 13) % 26  
Out[59]: 4
```

- enfin on retrouve le rang du caractère associé au rang alphabétique calculé :

```
In [60]: chr(ord('A') + 4)  
Out[60]: 'E'
```

Écrire une fonction `rot13(chaine)` qui chiffre ou déchiffre la chaîne (en majuscules ou convertie en majuscules avec `chaine.upper()`) passée en paramètre, avec l'algorithme rot13.

.....
.....
.....
.....
.....

3. Dans un interpréteur Ipython, importer le module `this`, lire le *Zen de Python*, méditer puis afficher le code source du module avec la commande `%psource this`.

2.3 Tables de codages ISO-8859



Point de cours 3

La table **ASCII** possédait les propriétés de compacité et de portabilité mais pas celle d'universalité. Par exemple les caractères accentués de l'alphabet latin ne figurent pas dans la table **ASCII**.

Pour y remédier, l'**ISO** (*Organisation internationale de normalisation*) a proposé la norme **ISO-8859** qui étend la table **ASCII** en utilisant le huitième bit. Sur un octet, on peut ainsi représenter deux fois plus de caractères, soit $2^8 = 256$.

La norme **ISO 8859** comprend seize tables de codages, certes compatibles entre elles et avec ASCII sur les 128 premiers caractères, mais avec 256 caractères il n'est pas possible d'écrire un texte avec un mélange de caractères arabes et russes.

La table de codage **ISO 8859-1** ou **Latin1** est la plus utilisée en Occident. Les applications Microsoft utilisent une variante de Latin1 nommé **cp1252** où les caractères de contrôle de point de code entre 128 et 159 ont été remplacés par des caractères imprimables comme le symbole de l'euro €.

La multiplicité des encodages a posé des problèmes d'**interopérabilité** avec l'internationalisation des échanges informatiques au-delà des aires de proximité linguistique. Qui n'a jamais reçu de courriel avec d'étranges caractères comme ci-dessous ?

Je transf??re le message ?? Valentin

L'encodage du message n'étant pas reconnu par le client de messagerie, les caractères accentués è et à ont été remplacés par des signes ?.



Exercice 11 QCM E3C 2

1. Sur une page web qui s'affiche sur notre navigateur on peut lire :

« En consÃ©quence, l'AssemblÃ©e Nationale reconnaÃ®t et dÃ©clare, en prÃ©sence »

Quelle peut être la cause des affichages étranges de cette page ?

- a. l'encodage des caractères n'est pas celui attendu par le navigateur
 - b. le texte original est en japonais
 - c. la taille des caractères n'est pas celle attendue par le navigateur
 - d. la connexion à Internet présente des coupures
2. Le code ASCII permet de représenter en binaire les caractères alphanumériques. Quel est son principal inconvénient ?
- a. Il utilise beaucoup de bits.
 - b. Il ne différencie pas les majuscules des minuscules.
 - c. Il ne représente pas les caractères accentués.
 - d. Il n'est pas compatible avec la plupart des systèmes informatiques.

2.4 Table de codage universelle et encodages Unicode



Point de cours 4

Pour assurer l'universalité de la représentation des caractères, l'**ISO** a défini une table de codage universelle, l'*Universal Character Set* sous la norme **ISO-10646**. Cette norme a défini une plage de **points de codes** pouvant être associés à 1 114 112 caractères. Les points de code sont codés sur 20 ou 21 bits. Depuis 1991, le Consortium Unicode collabore avec l'ISO pour développer le Standard Unicode qui partage la même plage de points de codes que la norme **ISO-10646** avec des informations complémentaires (normalisation de forme). En mars 2020, 137 929 caractères sont recensés.

Chaque point de code est de la forme $U+xx \dots xx$ où chaque chiffre x est un caractère hexadécimal (base 16) avec au moins quatre chiffres.

Il est possible d'encoder chaque point de code sur 4 octets mais des encodages plus compacts ont été imaginés dans la norme **Unicode**. En effet, il suffit d'un octet pour stocker les caractères **ASCII** et de deux octets pour les plus courants dont le point de code est compris entre 0 et $2^{16} - 1 = 65\,535$.

Les encodages **Unicode** sont notés **UTF- n** où n est le nombre minimal de bits pour représenter un point de code.

L'encodage **Unicode** le plus courant est **UTF-8**.



Remarque 2



En Python 3, l'encodage par défaut des fichiers sources est **UTF-8**. Si le fichier n'est pas encodé en **UTF-8** mais par exemple en **cp1252**, on peut avoir un message d'erreur à l'exécution :

```
File "script-encodage-cp1252.py", line 1
SyntaxError: Non-UTF-8 code starting with '\xe9' in file script-encodage-
cp1252.py on line 1, but no encoding declared; see http://python.org
/dev/peps/pep-0263/ for details
```

Pour éviter ce type d'erreur, on peut placer un commentaire spécial précisant l'encodage sur la première ligne du fichier :

```
# coding: cp1252
```

La meilleure solution est tout de même de convertir le fichier source en **UTF-8**, ce que permet un bon éditeur de texte comme **Notepad++**.



Exercice 12 QCM E3C 2

1. Parmi les caractères ci-dessous, lequel ne fait pas partie du code ASCII ?

a. a

b. B

c. ©

d. é

2. Laquelle de ces affirmations concernant le codage UTF-8 des caractères est vraie ?

a. le codage UTF-8 est sur 7 bits

c. le codage UTF-8 est sur 1 à 4 octets

b. le codage UTF-8 est sur 8 bits

d. le codage UTF-8 est sur 8 octets

3. Quel est un avantage du codage UTF-8 par rapport au codage ASCII?

- il permet de coder un caractère sur un octet au lieu de deux
- il permet de coder les majuscules
- il permet de coder tous les caractères
- il permet de coder différentes polices de caractères

ANNEXE

Table de codage ASCII

Hex	Dec	Char	Hex	Dec	Char	Hex	Dec	Char	Hex	Dec	Char
0x00	0	NULL null	0x20	32	Space	0x40	64	@	0x60	96	`
0x01	1	SOH Start of heading	0x21	33	!	0x41	65	A	0x61	97	a
0x02	2	STX Start of text	0x22	34	"	0x42	66	B	0x62	98	b
0x03	3	ETX End of text	0x23	35	#	0x43	67	C	0x63	99	c
0x04	4	EOT End of transmission	0x24	36	\$	0x44	68	D	0x64	100	d
0x05	5	ENQ Enquiry	0x25	37	%	0x45	69	E	0x65	101	e
0x06	6	ACK Acknowledge	0x26	38	&	0x46	70	F	0x66	102	f
0x07	7	BELL Bell	0x27	39	'	0x47	71	G	0x67	103	g
0x08	8	BS Backspace	0x28	40	(	0x48	72	H	0x68	104	h
0x09	9	TAB Horizontal tab	0x29	41	)	0x49	73	I	0x69	105	i
0x0A	10	LF New line	0x2A	42	*	0x4A	74	J	0x6A	106	j
0x0B	11	VT Vertical tab	0x2B	43	+	0x4B	75	K	0x6B	107	k
0x0C	12	FF Form Feed	0x2C	44	,	0x4C	76	L	0x6C	108	l
0x0D	13	CR Carriage return	0x2D	45	-	0x4D	77	M	0x6D	109	m
0x0E	14	SO Shift out	0x2E	46	.	0x4E	78	N	0x6E	110	n
0x0F	15	SI Shift in	0x2F	47	/	0x4F	79	O	0x6F	111	o
0x10	16	DLE Data link escape	0x30	48	0	0x50	80	P	0x70	112	p
0x11	17	DC1 Device control 1	0x31	49	1	0x51	81	Q	0x71	113	q
0x12	18	DC2 Device control 2	0x32	50	2	0x52	82	R	0x72	114	r
0x13	19	DC3 Device control 3	0x33	51	3	0x53	83	S	0x73	115	s
0x14	20	DC4 Device control 4	0x34	52	4	0x54	84	T	0x74	116	t
0x15	21	NAK Negative ack	0x35	53	5	0x55	85	U	0x75	117	u
0x16	22	SYN Synchronous idle	0x36	54	6	0x56	86	V	0x76	118	v
0x17	23	ETB End transmission block	0x37	55	7	0x57	87	W	0x77	119	w
0x18	24	CAN Cancel	0x38	56	8	0x58	88	X	0x78	120	x
0x19	25	EM End of medium	0x39	57	9	0x59	89	Y	0x79	121	y
0x1A	26	SUB Substitute	0x3A	58	:	0x5A	90	Z	0x7A	122	z
0x1B	27	FSC Escape	0x3B	59	;	0x5B	91	[	0x7B	123	{
0x1C	28	FS File separator	0x3C	60	<	0x5C	92	\	0x7C	124	
0x1D	29	GS Group separator	0x3D	61	=	0x5D	93	]	0x7D	125	}
0x1E	30	RS Record separator	0x3E	62	>	0x5E	94	^	0x7E	126	~
0x1F	31	US Unit separator	0x3F	63	?	0x5F	95	_	0x7F	127	DEL