Encodages et multilinguisme

Karën Fort

Karen.Fort[at]loria.fr
LORIA, Equipes Calligramme/TALARIS

Brève présentation

- Traductrice qui a mal tourné en découvrant le Traitement Automatique des Langues (TAL).

Brève présentation

- Traductrice qui a mal tourné en découvrant le Traitement Automatique des Langues (TAL).
- Double compétence : presque linguiste, presque informaticien.

Brève présentation

- Traductrice qui a mal tourné en découvrant le Traitement Automatique des Langues (TAL).
- Double compétence : presque linguiste, presque informaticien.
- 9 ans d'expérience en TAL, principalement en tant que gestionnaire de ressources multilingues.

Brève présentation

- Traductrice qui a mal tourné en découvrant le Traitement Automatique des Langues (TAL).
- Double compétence : presque linguiste, presque informaticien.
- 9 ans d'expérience en TAL, principalement en tant que gestionnaire de ressources multilingues.
- Actuellement ingénieur spécialiste au LORIA (Nancy).

Et vous ?

- Vous venez d'où (Master actuel, formation antérieure) ?

Et vous ?

- Vous venez d'où (Master actuel, formation antérieure) ?
- Vous pratiquez quelles langues ?

Et vous ?

- Vous venez d'où (Master actuel, formation antérieure) ?
- Vous pratiquez quelles langues ?
- Vous allez où ?

Et vous ?

- Vous venez d'où (Master actuel, formation antérieure) ?
- Vous pratiquez quelles langues ?
- Vous allez où ?
- La gestion de projets de traduction, ça vous dit ? Vous l'avez déjà fait ?

Support de cours : sauvons la forêt amazonienne !

Le cours est au format pdf, sur ma page Web :
http ://www.loria.fr/~fortkare/

Avertissement : esprit critique es-tu là ?

J'ai fait de mon mieux pour citer mes sources, les croiser, vérifier les informations présentées, mais je suis loin d'être infaillible ou de tout savoir.
Je n'aurai sûrement pas toutes les réponses à vos questions, mais j'espère vous donner les moyens et l'envie de les chercher par vous-même.

Les encodages et vous

- Les encodages existent, vous les avez déjà rencontrés !

Les encodages et vous

- Les encodages existent, vous les avez déjà rencontrés !
- Exemples, intuitions, problèmes, questions ?

Encodages... à problèmes (1/3)

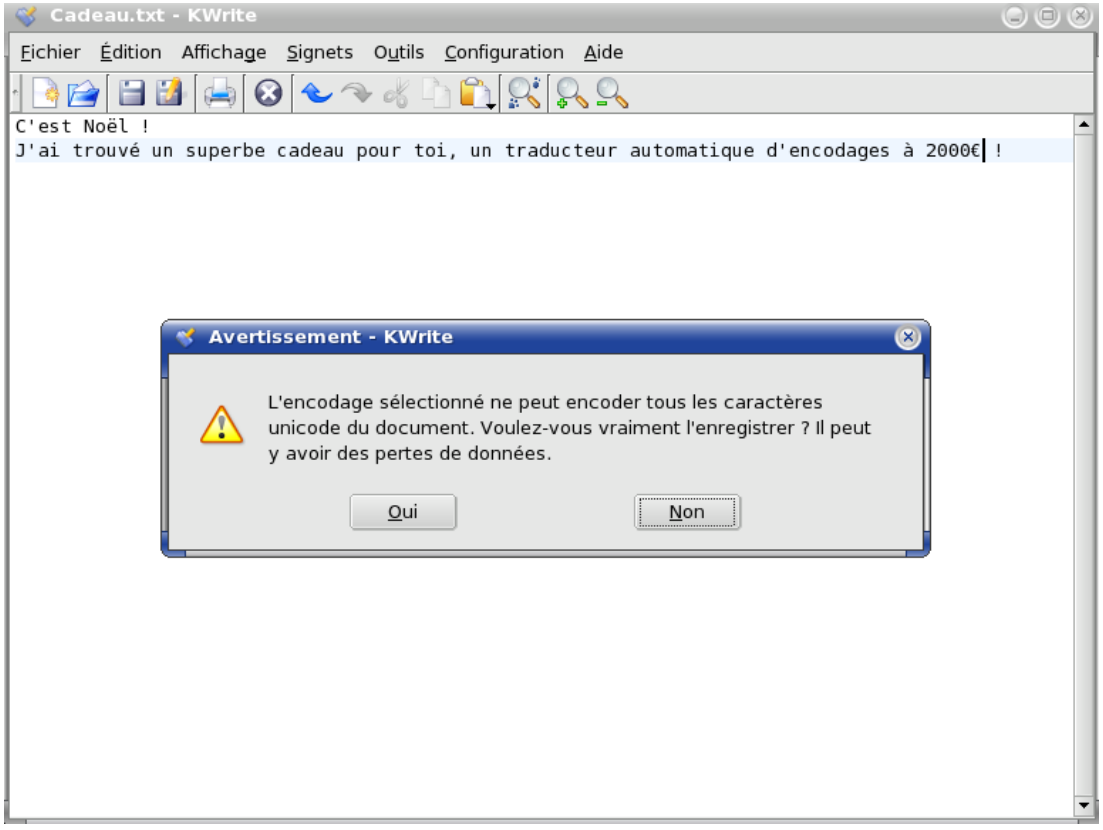

Impossible d'enregistrer...

- Que s'est-il passé ?

- Que s'est-il passé ?
- Qui a tué mon enregistrement (dans l'éditeur de texte) (avec un message d'erreur) ?

- Que s'est-il passé ?
- Qui a tué mon enregistrement (dans l'éditeur de texte) (avec un message d'erreur) ?
- Partons à la recherche du coupable : détaillons les étapes de création d'un document texte pour trouver à quel moment le crime a eu lieu.

Décomposons

1. Création d'un nouveau document texte vide dans un éditeur de texte.

Quelles difficultés peuvent se présenter à chaque étape ?

Décomposons

1. Création d'un nouveau document texte vide dans un éditeur de texte.
2. Ecriture du texte.

Quelles difficultés peuvent se présenter à chaque étape ?

Décomposons

1. Création d'un nouveau document texte vide dans un éditeur de texte.
2. Ecriture du texte.
3. Enregistrement du fichier.

Quelles difficultés peuvent se présenter à chaque étape ?

De mystérieux caractères

Un ou plusieurs caractère(s) que nous avons pu écrire sont apparemment Unicode (?) et ne sont pas enregistrables avec l'encodage par défaut.

De mystérieux caractères

Un ou plusieurs caractère(s) que nous avons pu écrire sont apparemment Unicode (?) et ne sont pas enregistrables avec l'encodage par défaut.

Solution ?

Encodages... à problèmes (2/3)

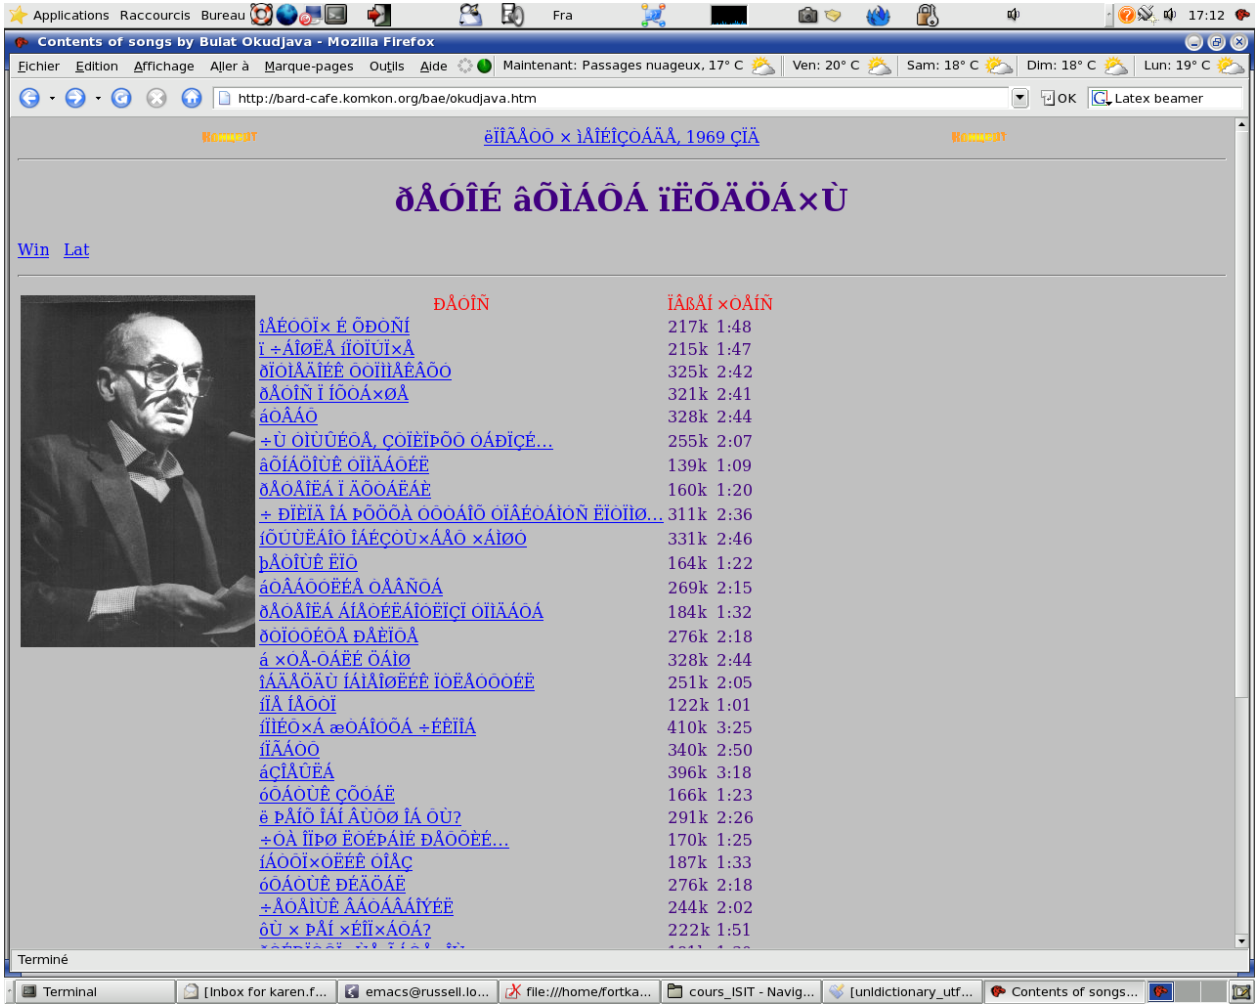

http ://bard-cafe.komkon.org/bae/okudjava.htm

- Que s'est-il passé ?

- Que s'est-il passé ?
- D'après vous, que se passe-t'il au juste quand vous allez à cette adresse Web (URL) ?

- Que s'est-il passé ?
- D'après vous, que se passe-t'il au juste quand vous allez à cette adresse Web (URL) ?
- Détaillez les étapes de création, puis de visualisation, de cette page.

Code source de la page

view-source: - Source de : http://bard-cafe.komkon.org/bae/okudjava.htm - Mozilla Firefox

Fichier Edition Affichage

```
<html>
<head>
<title>
Contents of songs by Bulat Okudjava
</title>
</head>

<BODY BACKGROUND="" BGCOLOR="#c0c0c0" TEXT="#400080" LINK="#0000ff" VLINK="#8080c0" ALINK="#00ffff">

<center>
  <TABLE width=70% border=0>
    <TR>
      <TD width=20%><p align=left><img src="img/koncert.gif" border=0 alt="concert in Leningrad, 1969"></p></TD>
      <TD width=60%><center><a href="okudjava/koncert.ram">ëÏÎÃÅÂÒÔ × ìÅÎÉÎÇÒÁÄÅ, 1969 ÇÏÄ</a></center></TD>
      <TD width=20%><p align=right><img src="img/koncert.gif" border=0 alt="concert in Leningrad, 1969"></p></TD>
    </TR>
  </TABLE>
</center>
<hr>

<h1><center><b>ðÅÓÎÉ âÕÌÁÔÁ ïËÕÄÖÁ×Ù</b></center></h1><p>

<a href="okudjavw.htm">Win</a>   <a href="okudjavt.htm">Lat</a><br>
<hr><p>

<table border=0>
<tr valign=bottom>
    <td rowspan=15>
        <img src="img/okudjava.jpg" border=0 alt="Bulat Okudjava">
    <td><center><font color=red>ÐÅÓÎÑ</font></center>
    <td><center><font color=red>ÏÁßÅÍ </font></center>
    <td><center><font color=red> ×ÒÅÍÑ</font></center>
<tr><td><a href="okudjava/1.ra"> îÅÉÓÓÏ× É ÕÐÒÑÍ</a><td>217k<td>1:48
<tr><td><a href="okudjava/2.ra"> ï ÷ÁÌØÅÂ íÏÔÏÚ×Å</a><td>215k<td>1:47
<tr><td><a href="okudjava/3.ra"> ðÏÓÌÅÄÎÉÊ ÔÒÏÌÌÅÊÂÕÓ</a><td>325k<td>2:42
<tr><td><a href="okudjava/4.ra"> ðÅÓÎÑ Ï ÍÔÒÁ×ØÅ</a><td>321k<td>2:41
<tr><td><a href="okudjava/5.ra"> áÒÂÁÔ</a><td>328k<td>2:44
<tr><td><a href="okudjava/6.ra"> ÷Ù ÓÌÙÛÉÔÅ, ÇÒÏÈÏÞÔÕ ÓÁÐÏÇÉ...</a><td>255k<td>2:07
<tr><td><a href="okudjava/7.ra"> âÕÍÁÖÎÙÊ ÓÏÌÅÁÔÅÊ</a><td>139k<td>1:09
<tr><td><a href="okudjava/8.ra"> ðÅÔÅÎÂÕ Ï ÄÕÔÁÉÁÉ</a><td>160k<td>1:20
<tr><td><a href="okudjava/9.ra"> ÷ ÐÏÈÏÄ ÎÁ ÞÕÔÁ ÓÔÔÁÎÕ ÓÏÅÉÔÁÌÑ ËÏÓÏÎØ...</a><td>311k<td>2:36
```

http ://bard-cafe.komkon.org/bae/okudjava.htm

Une page mal fichue

Le code source de la page ne spécifie pas l'encodage du code, le navigateur utilise un code par défaut qui ne correspond pas.

Une page mal fichue

Le code source de la page ne spécifie pas l'encodage du code, le navigateur utilise un code par défaut qui ne correspond pas.

Solution pour le lecteur ?

Une page mal fichue

Le code source de la page ne spécifie pas l'encodage du code, le navigateur utilise un code par défaut qui ne correspond pas.

Solution pour le lecteur ?

Solution pour le créateur/traducteur de la page ?

Encodages... à problèmes (3/3)

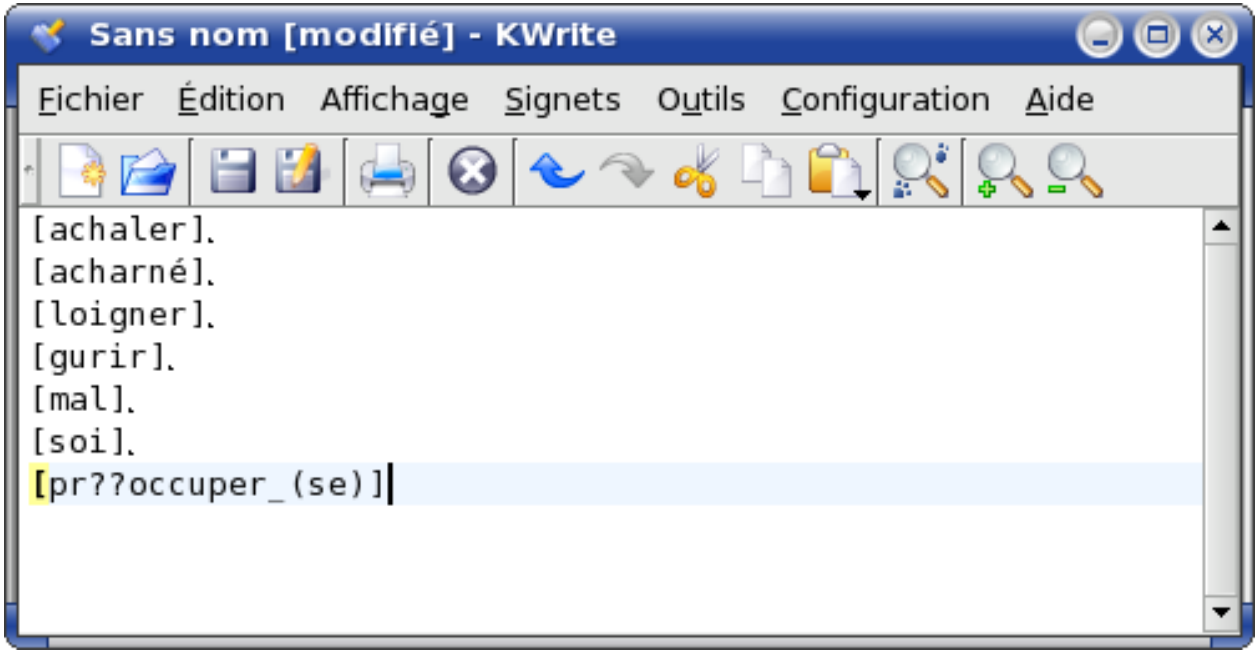

Extrait (tronqué) d'un lexique du français reçu il y a quelques jours... Imaginez, ça pourrait être un fichier à faire traduire, dans une langue que vous ne connaissez pas...

- Que voyez-vous ?

- Que voyez-vous ?
- Que s'est-il passé ?

- Que voyez-vous ?
- Que s'est-il passé ?
- Que faire ?

Des problèmes différents, des solutions différentes

- Enregistrer dans le "bon" encodage (exemple 1).

Des problèmes différents, des solutions différentes

- Enregistrer dans le "bon" encodage (exemple 1).
- Fournir suffisamment d'infos au logiciel de visualisation pour que l'affichage de mon texte soit correct (exemple 2).

Des problèmes différents, des solutions différentes

- Enregistrer dans le "bon" encodage (exemple 1).
- Fournir suffisamment d'infos au logiciel de visualisation pour que l'affichage de mon texte soit correct (exemple 2).
- Ne pas mélanger les encodages (exemple 3).

Des problèmes différents, des solutions différentes

- Enregistrer dans le "bon" encodage (exemple 1).
- Fournir suffisamment d'infos au logiciel de visualisation pour que l'affichage de mon texte soit correct (exemple 2).
- Ne pas mélanger les encodages (exemple 3).
- Un point dont nous n'avons même pas parlé tellement il semble évident : s'assurer de la capacité du logiciel à gérer "proprement" la langue.

C'est toutes ces questions (ainsi que d'autres) que nous allons essayer d'approfondir dans ce cours.

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 language binaire, c'est-à-dire une suite (interminable) 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 language binaire, c'est-à-dire une suite (interminable) 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.

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 language binaire, c'est-à-dire une suite (interminable) 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.
- Petit exercice : combien existe-t'il de possibilités de combiner 2 bits ?

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 language binaire, c'est-à-dire une suite (interminable) 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.
- Petit exercice : combien existe-t'il de possibilités de combiner 2 bits ?
- Voyons... 00 ou 11 ou 01 ou 10 = 4 possibilités.

Un peu plus loin dans les bases

- En fait, un processeur manipule plutôt des paquets de bits de taille fixe.

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**.

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**.
- Mais c'est *imbittable* !

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**.
- Mais c'est *imbittable* !
- NOTE : 1 octet = 8 bits = 1 byte (en anglais dans le texte !).

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**.
- Mais c'est *imbittable* !
- NOTE : 1 octet = 8 bits = 1 byte (en anglais dans le texte !).
- NOTE : 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).

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
- Si.

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
- Si.
- 1 caractère = 1 octet (attention, simplification, on verra pourquoi plus loin !).

Exercice : le byte et ses bits

- Combien de valeurs peut-on coder sur un octet ?

Exercice : le byte et ses bits

- Combien de valeurs peut-on coder sur un octet ?
- 1 octet = 8 bits.
  1 bit peut prendre 2 valeurs (0 ou 1) :

Exercice : le byte et ses bits

- Combien de valeurs peut-on coder sur un octet ?
- 1 octet = 8 bits.
  1 bit peut prendre 2 valeurs (0 ou 1) :
  - 0 0 0 0 0 0 0 0
    1 1 1 1 1 1 1 1

Exercice : le byte et ses bits

- Combien de valeurs peut-on coder sur un octet ?
- 1 octet = 8 bits.
  1 bit peut prendre 2 valeurs (0 ou 1) :
  - 0 0 0 0 0 0 0 0
    1 1 1 1 1 1 1 1
  - ce qui fait bien 2 possibilités à chaque fois.

Exercice : le byte et ses bits

- Combien de valeurs peut-on coder sur un octet ?
- 1 octet = 8 bits.
  1 bit peut prendre 2 valeurs (0 ou 1) :
  - 0 0 0 0 0 0 0 0
    1 1 1 1 1 1 1 1
  - ce qui fait bien 2 possibilités à chaque fois.
- 2x2x2x2x2x2x2x2=2^8=256

Quelques exemples

Caractère	Code Binaire	Code décimal	Description
A	01000001	065	Caractère "A"
a	01100001	097	Caractère "a"
T	01010100	084	Caractère "T"
t	01110100	116	Caractère "t"
3	00110011	051	Caractère "3"
$	00100100	036	Caractère "$"
BEL	00000111	007	Bip

ASTUCE : pour passer de la majuscule à la minuscule, il suffit de mettre le troisième bit à 1, futé, non ?

NOTE : les caractères chiffres ont leur propre code.

NOTE 2 : il n'existe qu'un "A", qui s'affiche différemment selon les polices ou le style (voir Définitions).

Exercice : dites "Bonjour" au PC !

- Combien de bits dans "Bonjour" ?

Exercice : dites "Bonjour" au PC !

- Combien de bits dans "Bonjour" ?
- "Bonjour" contient 7 caractères
  1 caractère = 1 octet
  1 octet = 8 bits
  Donc...

Exercice : dites "Bonjour" au PC !

- Combien de bits dans "Bonjour" ?
- "Bonjour" contient 7 caractères
  1 caractère = 1 octet
  1 octet = 8 bits
  Donc...
- 7 caractères x 8 bits = 56 bits !

Exercice : dites "Bonjour" au PC !

- Combien de bits dans "Bonjour" ?
- "Bonjour" contient 7 caractères
  1 caractère = 1 octet
  1 octet = 8 bits
  Donc...
- 7 caractères x 8 bits = 56 bits !
- Pour l'ordinateur : 11000010011100001001001110101100001101011100111101011011

Rien n'est simple, ma bonne dame !

- Combien d'octets dans un kilo-octet (Ko en français, Kb en anglais) ?

Rien n'est simple, ma bonne dame !

- Combien d'octets dans un kilo-octet (Ko en français, Kb en anglais) ?
- Ca dépend !

Rien n'est simple, ma bonne dame !

- Combien d'octets dans un kilo-octet (Ko en français, Kb en anglais) ?
- Ca dépend !
- Pour les informaticiens : 1 Ko $= 2^{10}$ octets $=$ 1 024 octets

Rien n'est simple, ma bonne dame !

- Combien d'octets dans un kilo-octet (Ko en français, Kb en anglais) ?
- Ca dépend !
- Pour les informaticiens : 1 Ko $= 2^{10}$ octets $= 1\ 024$ octets
- Pour les fabriquants de matériel, depuis la normalisation de 1998, due à un procès : 1 Ko $= 10^3$ octets $= 1\ 000$ octets

Rien n'est simple, ma bonne dame !

- Combien d'octets dans un kilo-octet (Ko en français, Kb en anglais) ?
- Ca dépend !
- Pour les informaticiens : 1 Ko = 2^{10} octets = 1 024 octets
- Pour les fabriquants de matériel, depuis la normalisation de 1998, due à un procès : 1 Ko = 10^3 octets = 1 000 octets
- Pour plus d'infos sur ce sujet brûlant (on devrait maintenant parler de kibi et non de kilo pour les kilos binaires) : http ://fr.wikipedia.org/wiki/Octet

Sous le signe de l'hexa(décimal)

- Si vous ouvrez un fichier en binaire, vous ne verrez pas que des 0 et des 1. Vous verrez ça :

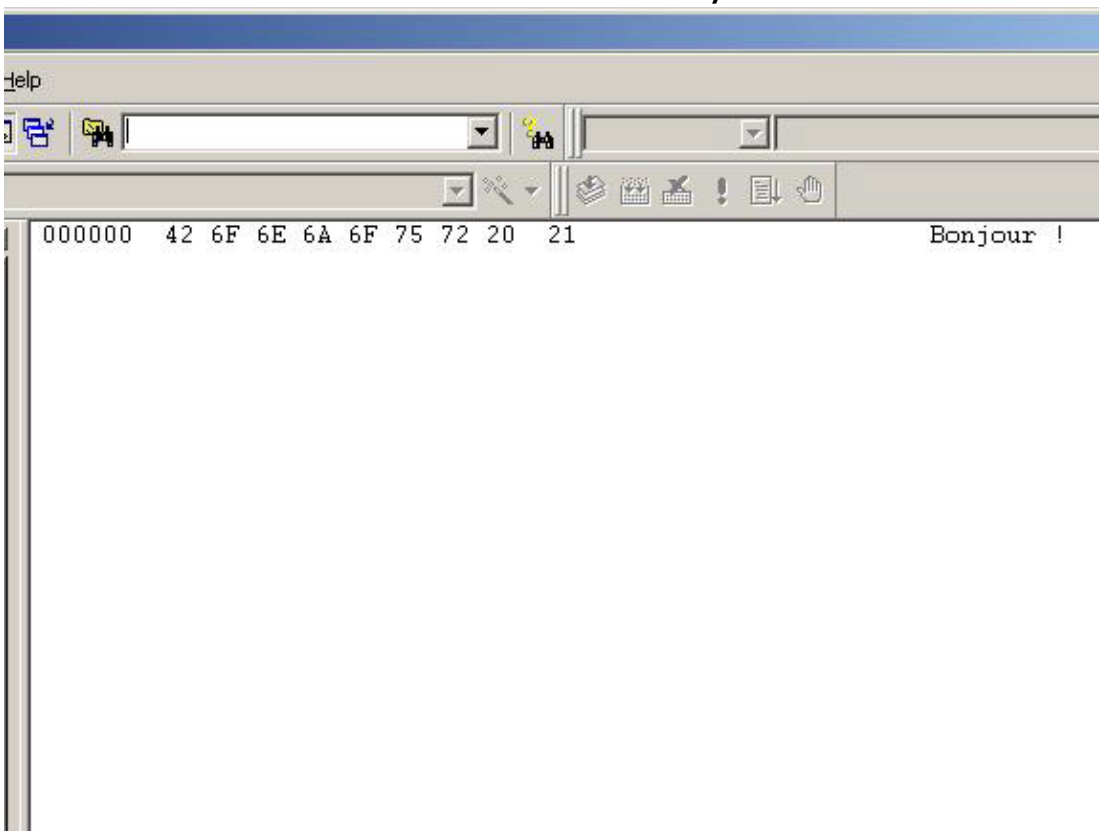

Sous le signe de l'hexa(décimal)

- Si vous ouvrez un fichier en binaire, vous ne verrez pas que des 0 et des 1. Vous verrez ça :

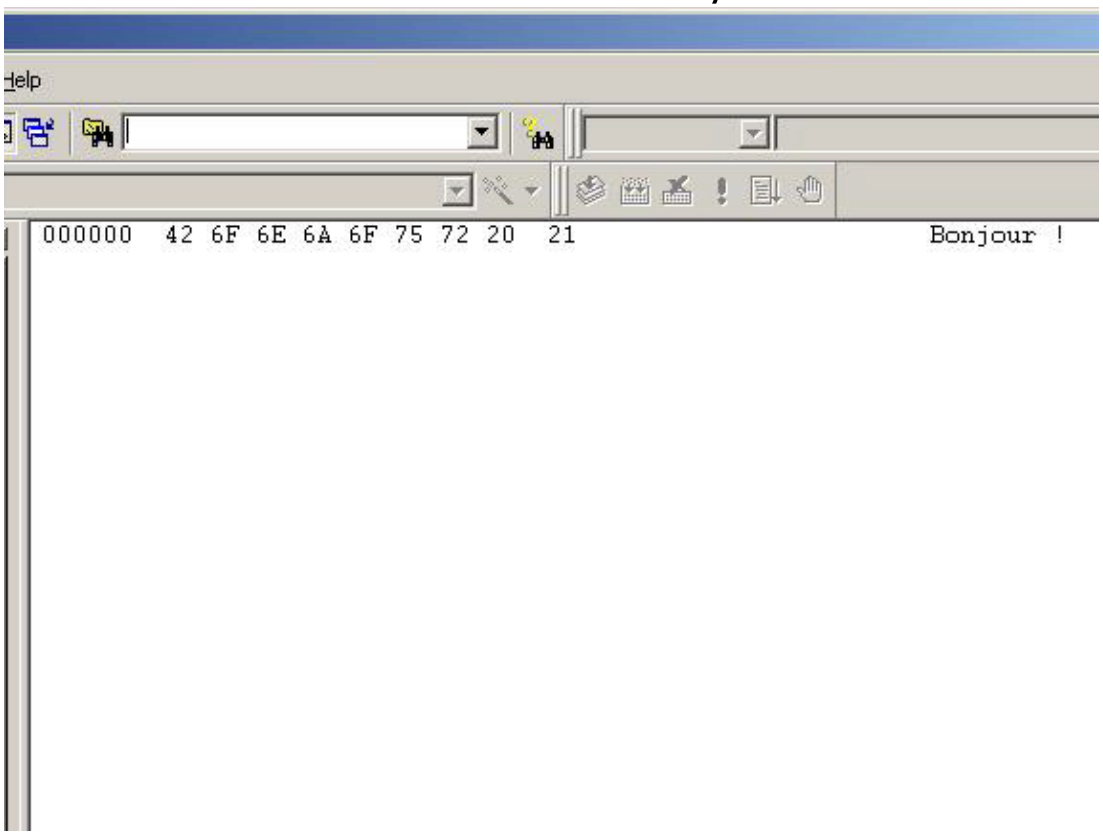

- Et ça, c'est de l'hexa. et c'est quand même plus facile à lire que du binaire.

Sous le signe de l'hexa(décimal)

- L'hexadécimal c'est de la base 16.

Sous le signe de l'hexa(décimal)

- L'hexadécimal c'est de la base 16.
- C'est pratique pour exprimer des octets, parce qu'avec un nombre de deux chiffres en base 16, on a 16 possibilités deux fois de suite, donc :
- $16 \times 16 = 16^2 = 256$

Sous le signe de l'hexa(décimal)

- L'hexadécimal c'est de la base 16.
- C'est pratique pour exprimer des octets, parce qu'avec un nombre de deux chiffres en base 16, on a 16 possibilités deux fois de suite, donc :
- $16 \times 16 = 16^2 = 256$
- Ce qui fait pile 2^8. Ca vous dit quelque chose ?

Sous le signe de l'hexa(décimal)

- L'hexadécimal c'est de la base 16.
- C'est pratique pour exprimer des octets, parce qu'avec un nombre de deux chiffres en base 16, on a 16 possibilités deux fois de suite, donc :
- $16 \times 16 = 16^2 = 256$
- Ce qui fait pile 2^8. Ca vous dit quelque chose ?
- Il a exactement autant de nombres binaires à 8 "chiffres" (des octets) que de nombres hexadécimaux à 2 "chiffres" !

Sous le signe de l'hexa(décimal)

- L'hexadécimal c'est de la base 16.
- C'est pratique pour exprimer des octets, parce qu'avec un nombre de deux chiffres en base 16, on a 16 possibilités deux fois de suite, donc :
- $16 \times 16 = 16^2 = 256$
- Ce qui fait pile 2^8. Ca vous dit quelque chose ?
- Il a exactement autant de nombres binaires à 8 "chiffres" (des octets) que de nombres hexadécimaux à 2 "chiffres" !
- Les informaticiens adorent ! Du coup, les éditeurs qui proposent d'ouvrir des fichiers en binaires les ouvrent en fait en hexa.

Exercice : j'apprends à compter

- Comptez en base 16.

Exercice : j'apprends à compter

- Comptez en base 16.
- Aide : en décimal (base 10), la bascule se fait après 9.

Exercice : j'apprends à compter

- Comptez en base 16.
- Aide : en décimal (base 10), la bascule se fait après 9.
- On doit inventer de nouveaux "chiffres" :
  0 1 2 3 4 5 6 7 8 9 A B C D E F

Donc, l'ordinateur cause octet, et alors ?

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 : qu'avez-vous retenu de ces bases ?

Au moins...

Récapitulons : qu'avez-vous retenu de ces bases ?

Au moins...

- un ordinateur ne comprend que le language binaire, c'est-à-dire une suite (interminable) de 0 et de 1.

Récapitulons : qu'avez-vous retenu de ces bases ?

Au moins...

- un ordinateur ne comprend que le language binaire, c'est-à-dire une suite (interminable) de 0 et de 1.
- l'objet qui prend comme valeur 0 ou 1 est appelé bit.

Récapitulons : qu'avez-vous retenu de ces bases ?

Au moins...

- un ordinateur ne comprend que le language binaire, c'est-à-dire une suite (interminable) 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.

Récapitulons : qu'avez-vous retenu de ces bases ?

Au moins...

- un ordinateur ne comprend que le language binaire, c'est-à-dire une suite (interminable) 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.
- c'est déjà pas mal !

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.

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.

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.

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.
- Ca suffit bien, non ?

Mais où est passé le 8^e passager ?

- On a dit juste avant : 1 caractère = 1 octet = 8 bits.

Mais où est passé le 8^e passager ?

- On a dit juste avant : 1 caractère = 1 octet = 8 bits.
- Or : "A" est codé 1000001 au lieu de 01000001 !

Mais où est passé le 8^e passager ?

- On a dit juste avant : 1 caractère = 1 octet = 8 bits.
- Or : "A" est codé 1000001 au lieu de 01000001 !
- Quid du 8^e bit ?

Mais où est passé le 8^e passager ?

- On a dit juste avant : 1 caractère = 1 octet = 8 bits.
- Or : "A" est codé 1000001 au lieu de 01000001 !
- Quid du 8^e bit ?
- Dans ASCII ce bit est utilisé pour le contrôle de l'intégrité des données (bit de parité), ou inutilisé.

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.

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.

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 plateforme 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	ϵ	∩
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.

La famille ISO

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

- Ainsi, à partir de 1987 la table ASCII étendue fut déclinée en de multiples variations (toujours codées sur un octet).

La famille ISO

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

- Ainsi, 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 famille ISO

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

- Ainsi, 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	Ј	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	ј	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 ?

Evidemment, parmi les encodages les plus courants se trouve des encodages "maison" :

Vous en aviez assez ?

Evidemment, parmi les encodages les plus courants se trouve des encodages "maison" :

- Ceux de Microsoft : Windows1252 et al.

Vous en aviez assez ?

Evidemment, parmi les encodages les plus courants se trouve des encodages "maison" :

- Ceux de Microsoft : Windows1252 et al.
- Ceux d'Apple : MacRoman.

Vous en aviez assez ?

Evidemment, parmi les encodages les plus courants se trouve des encodages "maison" :

- Ceux de Microsoft : Windows1252 et al.
- Ceux d'Apple : MacRoman.
- Pour plus de détails, voir :
  http ://www.alanwood.net/demos/charsetdiffs.html.

Minimou d'un côté

Windows1252 alias CP1252 (CP pour CodePage) alias ANSI (nom historique) : ISO-8859-1 + 27 caractères (dont l'€) dans la plage 80-9F (non-utilisée en ISO).

Windows-1252 (CP1252)																
	x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF
0x	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1x	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
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	{	|	}	~	DEL
8x	€		‚	ƒ	„	…	†	‡	ˆ	‰	Š	‹	Œ		Ž	
9x		‘	’	“	”	•	–	—	˜	™	š	›	œ		ž	Ÿ
Ax	NBSP	¡	¢	£	¤	¥	¦	§	¨	©	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

Minimou encore

- Les 27 caractères dans la plage 80-9F sont aussi utilisés pour compléter d'autres alphabets.

Minimou encore

- Les 27 caractères dans la plage 80-9F sont aussi utilisés pour compléter d'autres alphabets.
- On a donc non seulement CP1252, mais aussi CP1250, CP1251 (cyrillique), CP1253 (grec), CP1254, CP1255, CP 1256 (arabe), CP1257 et CP1258 (vietnamien).

Mac de l'autre

Le MacRoman inclut tous les caractères présents dans l'ISO 8859-1, à l'exception du tiret invisible et y ajoute de nombreux caractères qui ne sont pas dans l'ISO 8859-1, dont l'€.

MacRoman

	x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF
0x										TAB	LF			CR		
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	Ä	Å	Ç	É	Ñ	Ö	Ü	á	à	â	ä	ã	å	ç	é	è
9x	ê	ë	í	ì	î	ï	ñ	ó	ò	ô	ö	õ	ú	ù	û	ü
Ax	†	°	¢	£	§	•	¶	ß	®	©	™	´	¨	≠	Æ	Ø
Bx	∞	±	≤	≥	¥	µ	∂	∑	∏	π	∫	ª	º	Ω	æ	ø
Cx	¿	¡	¬	√	ƒ	≈	Δ	«	»	…	NBSP	À	Ã	Õ	Œ	œ
Dx	–	—	"	"	'	'	÷	◊	ÿ	Ÿ	⁄	€	‹	›	fi	fl
Ex	‡	·	‚	„	‰	Â	Ê	Á	Ë	È	Í	Î	Ï	Ì	Ó	Ô
Fx		Ò	Ú	Û	Ù	ı	ˆ	˜	¯	˘	˙	°	¸	˝	˛	ˇ

Limitations

- Problèmes d'incomplétude ou d'affichage pour certaines langues.

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.

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)

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 6763 caractères seulement (! !), et Big5 pour le traditionnel, avec 13053 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 6763 caractères seulement (! !), et Big5 pour le traditionnel, avec 13053 caractères.
- 13053 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 6763 caractères seulement (! !), et Big5 pour le traditionnel, avec 13053 caractères.
- 13053 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).

Exercice : les élephants d'Asie

- Combien de valeurs peut-on représenter sur 16 bits ?

Exercice : les élephants d'Asie

- Combien de valeurs peut-on représenter sur 16 bits ?
- $2x2x2x2x2x2x2x2x2x2x2x2x2x2x2x2 = 2^{16} = 65536$

Exercice : les élephants d'Asie

- Combien de valeurs peut-on représenter sur 16 bits ?
- 2x2x2x2x2x2x2x2x2x2x2x2x2x2x2x2=2^{16}=65536
- Ca suffit donc pour le chinois, même traditionnel. D'ailleurs, même 14 bits auraient suffi... (2^{14}=16384)
  Alors pourquoi 16 ?

Exercice : les élephants d'Asie

- Combien de valeurs peut-on représenter sur 16 bits ?
- 2x2x2x2x2x2x2x2x2x2x2x2x2x2x2x2=2^{16}=65536
- Ca suffit donc pour le chinois, même traditionnel. D'ailleurs, même 14 bits auraient suffi... (2^{14}=16384)
  Alors pourquoi 16 ?
- Parce que c'est incomparablement plus pratique, étant donné que l'ordinateur gère des octets...

Récapitulons : qu'avez-vous retenu de ces normes ?

Au moins...

Récapitulons : qu'avez-vous retenu de ces normes ?

Au moins...

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

Récapitulons : qu'avez-vous retenu de ces normes ?

Au moins...

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

Récapitulons : qu'avez-vous retenu de ces normes ?

Au moins...

- 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 : qu'avez-vous retenu de ces normes ?

Au moins...

- 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 : qu'avez-vous retenu de ces normes ?

Au moins...

- 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 : qu'avez-vous retenu de ces normes ?

Au moins...

- 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 !

Récapitulons : qu'avez-vous retenu de ces normes ?

Au moins...

- 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 !
- Tableau récapitulatif : http ://www.miakinen.net/vrac/charsets/

Arrgh, c'est trop !

PAUSE !

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 :

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)

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

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

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 4.1.0 (nov. 2005) : plus de 97 755 lettres ou syllabes, chiffres ou nombres, symboles divers, signes diacritiques et signes de ponctuation.

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 4.1.0 (nov. 2005) : plus de 97 755 lettres ou syllabes, chiffres ou nombres, symboles divers, signes diacritiques et signes de ponctuation.
- Mais aussi : 137 468 caractères à usage privé, 8 258 points de codes réservés de façon permanente et plusieurs centaines de caractères de contrôle ou modificateurs.

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 4.1.0 (nov. 2005) : plus de 97 755 lettres ou syllabes, chiffres ou nombres, symboles divers, signes diacritiques et signes de ponctuation.
- Mais aussi : 137 468 caractères à usage privé, 8 258 points de codes réservés de façon permanente et plusieurs centaines de caractères de contrôle ou modificateurs.
- Unicode est donc encore très "vide".

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. Comment ce point de code est représenté en mémoire ou sur disque est une tout autre histoire...

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. Comment ce point de code est représenté en mémoire ou sur disque est une tout autre histoire...
- 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.

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. Comment ce point de code est représenté en mémoire ou sur disque est une tout autre histoire...
- 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

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. Comment ce point de code est représenté en mémoire ou sur disque est une tout autre histoire...
- 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
- Outils : charmap sous Windows 2000/XP, KCharSelect sous Linux.

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).

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).
- 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.

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).
- 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.
- Vous en avez entendu parler, bien sûr, mais quels sont ces 3 UTF ?

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).
- 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.
- Vous en avez entendu parler, bien sûr, mais quels sont ces 3 UTF ?
- UTF-32, UTF-16, UTF-8.

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.

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 sub-indonésien, nécessitera quatre octets pour être codé.

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 sub-indonésien, nécessitera quatre octets pour être codé.
- UTF-32 est donc assez peu utilisé.

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 sub-indonésien, nécessitera quatre octets pour être codé.
- UTF-32 est donc assez peu utilisé.
- Question facile pour vous garder éveillés : combien d'octets dans 32 bits ?

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 sub-indonésien, nécessitera quatre octets pour être codé.
- UTF-32 est donc assez peu utilisé.
- Question facile pour vous garder éveillés : combien d'octets dans 32 bits ?
- 32/8=4

L'indécis : UTF-16

- UTF-16 décompose les caractère Unicode en seizets binaires, soit 2 octets.

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).

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).
- Mais les autres caractères, on les oublie ?

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).
- Mais les autres caractères, on les oublie ?
- Bien sûr que non, on utilise 2 seizets pour les coder. Ces seizets sont appelés seizets d'indirection (surrogate pair en anglais).

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).
- Mais les autres caractères, on les oublie ?
- Bien sûr que non, on utilise 2 seizets pour les coder. 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) !

Conclusion : machin-byte

- UTF-32 code toujours sur 4 octets.

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").

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 : ␣ + ␣ + ␣ + ␣

Exercice : qui c'est le meilleur ?

- Avantages et inconvénients de chaque UTF ?

Exercice : 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.

Exercice : 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.

Exercice : 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) sont en big-endian alors que les Intel (PC) 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) sont en big-endian alors que les Intel (PC) 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]),

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 joyeusement appelé BOM (Byte Order Mark) et codé U+FEFF (big-endian) ou FFFE (little-endian).

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 joyeusement appelé BOM (Byte Order Mark) et codé U+FEFF (big-endian) ou FFFE (little-endian).
- NOTE : 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.
- Ca 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.
- Ca prouve aussi que votre éditeur est une truffe !
- La BOM peut aussi poser des problèmes à certains programmes.

Récapitulons : qu'avez-vous retenu d'Unicode ?

Au moins...

Récapitulons : qu'avez-vous retenu d'Unicode ?

Au moins...

- Unicode : norme permettant de coder tous les caractères de toutes les langues du monde de manière non ambigüe.

Récapitulons : qu'avez-vous retenu d'Unicode ?

Au moins...

- Unicode : norme permettant de coder tous les caractères de toutes les langues du monde de manière non ambigüe.
- Distinction points de code et formats de transformation

Récapitulons : qu'avez-vous retenu d'Unicode ?

Au moins...

- Unicode : norme permettant de coder tous les caractères de toutes les langues du monde de manière non ambigüe.
- 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)

Récapitulons : qu'avez-vous retenu d'Unicode ?

Au moins...

- Unicode : norme permettant de coder tous les caractères de toutes les langues du monde de manière non ambigüe.
- 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»¿

HTML et les encodages

- Que savez-vous d'HTML ?

HTML et les encodages

- Que savez-vous d'HTML ?
- Que savez-vous de la gestion des encodages par HTML ?

Survol (très) rapide de HTML

- HTML = HyperText Markup Language

Survol (très) rapide de HTML

- HTML = HyperText Markup Language
- soit : un langage informatique de balisage (comme XML ou SGML)

Survol (très) rapide de HTML

- HTML = HyperText Markup Language
- soit : un langage informatique de balisage (comme XML ou SGML)
- ... textuel, structuré, non extensible

Survol (très) rapide de HTML

- HTML = HyperText Markup Language
- soit : un langage informatique de balisage (comme XML ou SGML)
- ... textuel, structuré, non extensible
- son “langage” ne peut pas être redéfini

Survol (très) rapide de HTML

- HTML = HyperText Markup Language
- soit : un langage informatique de balisage (comme XML ou SGML)
- ... textuel, structuré, non extensible
- son “langage” ne peut pas être redéfini
- syntaxe assez souple : une balise ouverte n’a pas forcément à être fermée (sauf XHTML)

Les entités nommées

- En HTML, il existe un jeu standard de 252 entités nommées qui sont soit absentes de certains encodages de caractères, soit sensibles au balisage dans certains contextes (par exemple les signes inférieur et guillemets droits).

Les entités nommées

- En HTML, il existe un jeu standard de 252 entités nommées qui sont soit absentes de certains encodages de caractères, soit sensibles au balisage dans certains contextes (par exemple les signes inférieur et guillemets droits).
- Ces entités nommées peuvent être incluses dans un document HTML via l'utilisation de références, qui prennent la forme &EntitéNommée ;, où EntitéNommée est le nom de l'entité.

Les entités nommées

- En HTML, il existe un jeu standard de 252 entités nommées qui sont soit absentes de certains encodages de caractères, soit sensibles au balisage dans certains contextes (par exemple les signes inférieur et guillemets droits).
- Ces entités nommées peuvent être incluses dans un document HTML via l'utilisation de références, qui prennent la forme &EntitéNommée ;, où EntitéNommée est le nom de l'entité.
- Exemple : "é" correspond à l'entité nommée &eacute ;

Les entités numériques

- En HTML, il est possible d'écrire n'importe quel caractère Unicode à l'aide d'entités numériques référençant le code point du caractère.

Les entités numériques

- En HTML, il est possible d'écrire n'importe quel caractère Unicode à l'aide d'entités numériques référençant le code point du caractère.
- Ces entités numériques prennent deux formes : &#CodePoint ;, où CodePoint est en décimal, et &#xCodePoint ;, où CodePoint est en hexadécimal.

Les entités numériques

- En HTML, il est possible d'écrire n'importe quel caractère Unicode à l'aide d'entités numériques référençant le code point du caractère.
- Ces entités numériques prennent deux formes : &#CodePoint ;, où CodePoint est en décimal, et &#xCodePoint ;, où CodePoint est en hexadécimal.
- Exemple : "é" peut être encodé &#0233 ; ou &#x00E9 ;

Les entités numériques

- En HTML, il est possible d'écrire n'importe quel caractère Unicode à l'aide d'entités numériques référençant le code point du caractère.
- Ces entités numériques prennent deux formes : &#CodePoint;, où CodePoint est en décimal, et &#xCodePoint;, où CodePoint est en hexadécimal.
- Exemple : "é" peut être encodé é ou é
- NOTE : le support de l'hexa est plus récent et peut être problématique pour les navigateurs les plus anciens.

Exemple non photogénique !

Karën FORT

Ingénieure spécialiste dans les équipes Calligramme et Langue et Dialogue.

Contact

Adresse :	LORIA / INRIA-Lorraine Campus Scientifique BP 239 54506, Vandœuvre-lès-Nancy, FRANCE
Bureau :	B232
Téléphone :	+33 (0)3 54 95 85 67
E-mail :	Karen.Fort_at_loria.fr
Web :	http://www.loria.fr/~fortkare/

Les dessous

Fichier source

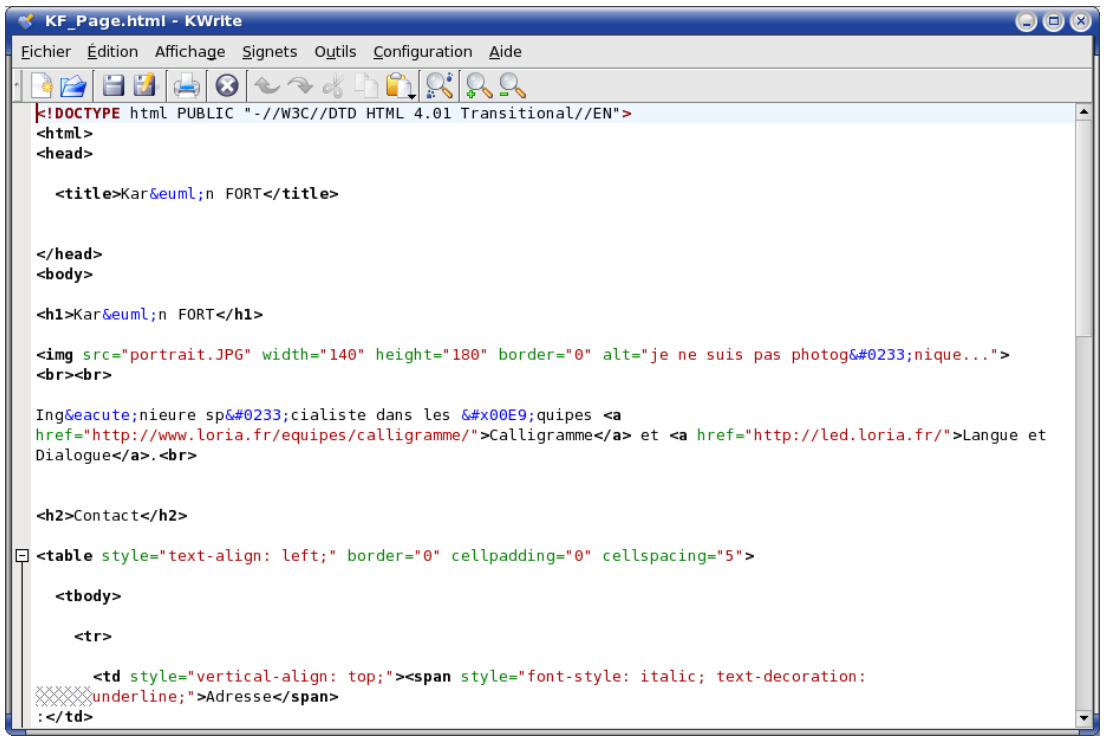

Avantages et inconvénients des entités

- Les entités sont lisibles par n'importe quel navigateur, en particulier les entités nommées.

Avantages et inconvénients des entités

- Les entités sont lisibles par n'importe quel navigateur, en particulier les entités nommées.
- Les entités sont indépendantes de l'encodage du fichier source (pas de problème à l'enregistrement ou à la lecture).

Avantages et inconvénients des entités

- Les entités sont lisibles par n'importe quel navigateur, en particulier les entités nommées.
- Les entités sont indépendantes de l'encodage du fichier source (pas de problème à l'enregistrement ou à la lecture).
- Par contre, le code source n'est pas facile à écrire et à éditer et il prend un peu plus de place.

Le tag meta et son charset

- Comment spécifier un encodage dans du HTML ? Comment lire le fichier HTML tant qu'on ne sait pas quel encodage est à l'intérieur ?

Le tag meta et son charset

- Comment spécifier un encodage dans du HTML ? Comment lire le fichier HTML tant qu'on ne sait pas quel encodage est à l'intérieur ?
- Il faut spécifier dans le header du code HTML une balise (tag) meta contenant des informations sur le fichier source.

Le tag meta et son charset

- Comment spécifier un encodage dans du HTML ? Comment lire le fichier HTML tant qu'on ne sait pas quel encodage est à l'intérieur ?
- Il faut spécifier dans le header du code HTML une balise (tag) meta contenant des informations sur le fichier source.
- Ce meta tag doit vraiment être la première chose dans le header parce que dès que le navigateur voit ce tag, il arrête de parser la page et recommence son interprétation depuis le début en utilisant l'encodage que vous avez spécifié.

Le tag meta et son charset

- Comment spécifier un encodage dans du HTML ? Comment lire le fichier HTML tant qu'on ne sait pas quel encodage est à l'intérieur ?
- Il faut spécifier dans le header du code HTML une balise (tag) meta contenant des informations sur le fichier source.
- Ce meta tag doit vraiment être la première chose dans le header parce que dès que le navigateur voit ce tag, il arrête de parser la page et recommence son interprétation depuis le début en utilisant l'encodage que vous avez spécifié.
- Exemple :
  <meta http-equiv="Content-Type" content="text/html ; charset=utf-8">

HTML : surprise, surprise !

Vérifiez toujours de quoi ça a l'air :

HTML : surprise, surprise !

Vérifiez toujours de quoi ça a l'air :

- sur plusieurs navigateurs

HTML : surprise, surprise !

Vérifiez toujours de quoi ça a l'air :

- sur plusieurs navigateurs
- sur plusieurs plate-formes (non, le monde entier n'est pas sous Windows XP !)

Parenthèse PHP : attention !

- Apparemment, il arrive sur Apache que les fichiers PHP aient un charset HTTP déclaré iso-8859-1 par défaut.

Parenthèse PHP : attention !

- Apparemment, il arrive sur Apache que les fichiers PHP aient un charset HTTP déclaré iso-8859-1 par défaut.
- Il est donc préférable de spécifier :

```
< ?php
header ('Content-Type : text/html ; charset=utf-8') ;
...
?>
```

Parenthèse PHP : attention !

- Apparemment, il arrive sur Apache que les fichiers PHP aient un charset HTTP déclaré iso-8859-1 par défaut.
- Il est donc préférable de spécifier :

```
<?php
header ('Content-Type : text/html ; charset=utf-8') ;
...
?>
```

- ... et de vérifier l'absence de BOM (vous voyez que ça sert !).

XML ?

- Que savez-vous sur XML ?

XML ?

- Que savez-vous sur XML ?
- Que savez-vous de la gestion des encodages en XML ?

Survol (très) rapide de XML

- XML = Extensible Markup Language

Survol (très) rapide de XML

- XML = Extensible Markup Language
- soit : un langage informatique de balisage (comme HTML ou SGML)

Survol (très) rapide de XML

- XML = Extensible Markup Language
- soit : un langage informatique de balisage (comme HTML ou SGML)
- ... textuel, structuré, et extensible car

Survol (très) rapide de XML

- XML = Extensible Markup Language
- soit : un langage informatique de balisage (comme HTML ou SGML)
- ... textuel, structuré, et extensible car
- son “langage” (vocabulaire et grammaire) peut être redéfini (par exemple, *mabalise* peut être un nom de balise)

Survol (très) rapide de XML

- XML = Extensible Markup Language
- soit : un langage informatique de balisage (comme HTML ou SGML)
- ... textuel, structuré, et extensible car
- son "langage" (vocabulaire et grammaire) peut être redéfini (par exemple, *mabalise* peut être un nom de balise)
- syntaxe stricte, peut être validé par des outils automatiques.

XML : déclaration d'encodage

- Comme en HTML, on peut utiliser les entités.

XML : déclaration d'encodage

- Comme en HTML, on peut utiliser les entités.
- Mais la déclaration d'encodage est obligatoire et intervient dès la première ligne du fichier :

XML : déclaration d'encodage

- Comme en HTML, on peut utiliser les entités.
- Mais la déclaration d'encodage est obligatoire et intervient dès la première ligne du fichier :
- <?xml version="1.0" encoding="utf-8" ?>

Récapitulons : qu'avez-vous retenu de la gestion des encodages en HTML/XML ?

Au moins...

Récapitulons : qu'avez-vous retenu de la gestion des encodages en HTML/XML ?

Au moins...

- HTML : langage non extensible

Récapitulons : qu'avez-vous retenu de la gestion des encodages en HTML/XML ?

Au moins...

- HTML : langage non extensible
- Encodages en HTML : utilisation d'entités (nommées ou numériques) ou de la balise meta pour déclarer l'encodage du document.

Récapitulons : qu'avez-vous retenu de la gestion des encodages en HTML/XML ?

Au moins...

- HTML : langage non extensible
- Encodages en HTML : utilisation d'entités (nommées ou numériques) ou de la balise meta pour déclarer l'encodage du document.
- XML : langage extensible

Récapitulons : qu'avez-vous retenu de la gestion des encodages en HTML/XML ?

Au moins...

- HTML : langage non extensible
- Encodages en HTML : utilisation d'entités (nommées ou numériques) ou de la balise meta pour déclarer l'encodage du document.
- XML : langage extensible
- Encodages en XML : utilisation d'entités (nommées ou numériques) possible mais déclaration d'encodage obligatoire.

Limitations d'Unicode (1/2)

- Le Consortium Unicode est agité de nombreux débats, ce qui est plutôt bon signe !

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.

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.

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.

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").

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.

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 !)

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

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 : EmEditor (Windows), Yudit (Unix). Pour Mac ?

Les outils qui sauvent

- Bon éditeur de texte brut : EmEditor (Windows), Yudit (Unix). Pour Mac ?
- Editeur qui permette l'ouverture en binaire : Visual, Eclipse (outils de dév.)

Définitions (Wikipedia) 1/3

- glyphe : représentation graphique (parmi une infinité possible) d'un signe typographique.
- 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.

Je leur ai tout piqué !

- Pour les bases : http ://www.arcanapercipio.com/
- Pour les tables : http ://www.table-ascii.com/ ou http ://alis.isoc.org/index.html
- Pour les définitions et tout le reste : http ://fr.wikipedia.org/
- Pour Unicode, indispensable et drôle : http ://french.joelonsoftware.com/Articles/Unicode.html
- Pour la bidirectionalité : http ://www.i18nguy.com/markup/right-to-left.html
- Mais je n'ai compris tout ça que grâce à Bruno Freudensprung.

Copyright et al

- Ce cours a été réalisé en LaTex Beamer.
- Il est disponible sous licence Creative Commons.