

Joaquín Seoane, DIT/UPM

Estas transparencias se ven perfectamente con Mozilla 1.4 y derivados. Aquí [\[inter.pdf\]](#) puede ver una transcripción rudimentaria en PDF, por si tiene dificultades. O bajarse todo [\[inter.zip\]](#), incluidas fuentes.

# Introducción

## Introducción

# Motivación

- **Acceso universal a programas, datos y servicios.**
- **Acceso a mercados globales.**
- **Creación de comunidades globales.**
- **Creación de mercados y comunidades locales.**
- **Cultura:**
  - **Idioma.**
  - **Creencias, usos y costumbres.**
  - **Regulaciones legales.**
  - **(Dis)capacidad física.**

# Términos y siglas

<b>i18n (internacionalización):</b>	<b>Construir para la localización fácil.</b>
<b>l10n (localización):</b>	<b>Adaptar a culturas locales.</b>
<b>Locale (localidad):</b>	<b>Descripción de una cultura local.</b>
<b>g11n (globalización):</b>	<b>i18n + l10n</b>

# ¿Qué se localiza?

- **La interfaz de usuario:**
  - **Mensajes.**
  - **Iconos.**
- **Los objetos manipulados por el programa:**
  - **Documentos.**
  - **Datos.**

# ¿Como se localiza?

- **Estáticamente.**
- **Dinámicamente:**
  - **Tablas.**
  - **Bibliotecas dinámicas.**

# Problemas fundamentales

- **Idioma:**
  - Repertorio de caracteres.
  - Construcción de frases.
  - Ordenación.
  - Organización del espacio.
  - Procesamiento (búsqueda, normalización, pronunciación, ...)
- **Cultural y legal:**
  - Fechas, números, moneda, impuestos, etc.
  - Iconos significativos, no ofensivos.

# Interfaz de usuario

- Mensajes de salida y error en catálogos.
  - ¡No construirlos concatenando!

`"Mary" + "'s balance is USD" + "15"`

`"Mary" + "tiene un saldo de dólares" + "15"`

- ¡No basarse en ellos para guiones (scripts)!
  - Disminuye (un poco) la eficiencia.
- Mensajes de entrada, opciones.
- Tener en cuenta los límites espaciales.
- Los iconos deben ser significativos y no ofensivos: catálogos.
- Si hay E/S hablada: pronunciación.



# Interfaz de usuario

# Clasificación de caracteres

- **Determinar legalidad, análisis léxico o sintáctico, búsquedas aproximadas.**
- **Predicados:**
  - ¿Es alfabético?
  - ¿Es dígito?
  - ¿Es espacio?
  - ¿Es signo de puntuación?
  - ¿Es mayúscula?
  - ¿Es acentuada?
  - ¿Es ligadura?
  - ¿Es diacrítico?
  - ¿Es ideograma?

# Trasliteración de caracteres

- **Convertir a mayúscula o a minúscula.**
  - **Sin sentido en árabe.**
  - **No tiene por qué ser trivial:**

```
#define toupper(c) ((c) - 'a' + 'A')  
#define tolower(c) ((c) - 'A' + 'a')
```

- **Utilizar tabla (puede ser muy grande).**
- **Quitar acento (u otro adorno).**

# Ordenación de caracteres

- Ayuda para la búsqueda: el código numérico puede valer:
  - En ASCII las mayúsculas salen antes que las minúsculas.
- Conviene usar el orden del diccionario:
  - Las letras acentuadas van juntas.
  - Los guiones no importan.
  - En alemán, la letra *ß* se ordena como *ss* (es una ligadura).
  - En castellano, el par *ch* se ordena(ba) entre la *c* y la *d*.
- Los ideogramas se ordenan por:
  - Representación fonética.
  - Número de *radicales* o de *trazos*.

# Ordenación de caracteres

# Búsqueda de cadenas

- **Codificación única (normalizada).**
  - **Letras acentuadas: *á* o *a'*, pero no ambas.**
  - **Ligaduras: ligar siempre o nunca (*ß* o *ss*).**
- **Problemas con códigos multiocteto.**
  - **Codificación sin estado (no ISO 2022).**
  - **Fácil sincronización (eg: multiocteto UTF-8).**
- **Búsquedas especiales:**
  - **Independiente de mayúsculas o minúsculas.**
  - **Independiente de acentos.**

# Patrones (expresiones regulares)

- Expresar conjuntos de caracteres (POSIX 1003.2)
  - Minúscula no es `[a-z]`, sino `[[:lower:]]`.
  - Letra no es `[A-Za-z]`, sino `[[:alpha:]]`.
  - Incluir caracteres múltiples: `[a-[.ch.]]`.
- Los comodines (`?`, `*`) deben referirse a caracteres (no a octetos).

# Fechas y horas

- Transmitir y ¿mantener? hora universal.
- Presentar hora local (incluyendo cambios estacionales).
- Mostrar fecha con el calendario local.
  - España: *lun 13 dic 2004*
  - USA: *Mon Dec 13 2004*
  - Árabe:
    - Gregoriano: *13 ### 2004* (al revés)
    - Hégira: *22 ##### 1483* (al revés)
  - Japón:
    - Gregoriano: *2003#1#13#*.
    - Emperador: *##15#1#13# (#####)*.



# Representación de números

- **EEUU: 5,434.25**
- **España: 5.434,25**
- **Francia: 5 434,25**
- **Países árabes: dígitos árabes o indis.**
- **Representación de los negativos:**
  - **-100**
  - **100-**
  - **(100)**

# Representación de monedas

- **EEUU: USD 1,000**
- **España: 158.433,5 pta**
- **Francia: 1F56**

# Los caracteres

## Los caracteres

# Repertorios

- **Hello!**
- **¡Hola!**
- **E#o#an#o #iu#a#de**
- **Grüß Gott**
- **#### ###**
- **### #####**
- **####**
- **#####!**
- **##### , #####**
- **##**

# De baudot a UCS

- **Baudot: 5 bits**
- **ASCII: 7 bits**
- **Variantes nacionales de ISO-8859: 8 bits**
- **Repertorios orientales: 16 bits.**
- **UCS / ISO 10646 / Unicode**  
**[<http://www.unicode.org>]**
  - **Unificación HAN # 16 bits (BMP)**
  - **Planos adicionales # 31 bits**

# Unicode

- **Propiedades de los caracteres.**
- **Caracteres de combinación.**
- **Repertorio del Web: HTML 4.0, XML, ECMAScript, Java, ...**
- **Esquemas de codificación:**
  - **UCS-2 y UCS-4 para memoria.**
  - **UTF-7, *UTF-8* y UTF-16 (extensibles) para compatibilidad, transmisión y almacenamiento.**
  - **Repertorios tradicionales + entidades de carácter.**

# Caracteres y juegos de caracteres

**Gran *confusión* de términos:**

**Carácter:**

**Objeto gráfico abstracto usado en un lenguaje escrito:**

- **A veces tiene relación con los *fonemas* (letras, sílabas).**
- **A veces representa una *idea*.**
- **Casi siempre se extiende con controles diversos: *retorno de carro, fin de línea, tabu-***

# Caracteres y juegos de caracteres

*lador, campana,  
sincronismos,  
porciones de pro-  
tocolos, ...*

**Conjunto/juego/repertorio de  
caracteres:**

**Los usados en un  
idioma, conjunto de  
idiomas o aplica-  
ción.**



# Representación gráfica de los caracteres

**Glifo:**

**Objetos gráficos concretos de la escritura:**

- A veces se corresponden uno a uno con los caracteres.
- A veces un carácter tiene varias formas.
- A veces los caracteres se ligan en un glifo.

**Tipo, fundición, font:**

**Juego de glifos del mismo estilo...**

- Formas: vertical, cursiva, inclinada, ..
- Pesos: normal, ne-

# Representación gráfica de los caracteres

**grita, ...**

- **Anchura: estrecho, normal, ancho.**
- **Tamaños: escalables o fijos.**

# Codificación de los caracteres 1

**Charset = Juego de caracteres codificado = Tabla de caracteres = CCS**  
**Punto = posición = code position:**

**Forma de codificación (CEF):**

**Esquema de codificación (CES):**

**Página de códigos:**

**Repertorio de caracteres numerados.**

**Número de un carácter en un juego de caracteres codificado.**

**Función de puntos a secuencias de *unidades de código*.**

**Función reversible de secuencias de *unidades de código* a *secuencias de octetos*.**

**Correspondencia en-**

# Codificación de los caracteres <sup>1</sup>

tre esquemas de codificación y secuencias de glifos<sup>2</sup> .

<sup>1</sup>Ver modelo de Unicode [<http://www.unicode.org/unicode/reports/tr17/>].

<sup>2</sup>No estoy seguro, hay que verificarlo.

# Entrada de caracteres

- A veces se corresponden uno a uno las teclas con los caracteres.
- A veces un carácter es combinación modificador y tecla.
- A veces un carácter es secuencia de tecla muerta y tecla.
- A veces se usan *métodos de entrada* más complejos:
  - Basados en punto.
  - Basados en menús (fonéticos).

# Esquemas de codificación sencillos

- Cada carácter se representa en binario por su posición en el juego de caracteres codificado.
- Códigos sucesivos para caracteres sucesivos:
  - Ordenación de cadenas de caracteres.
  - Conversiones de cadenas de dígitos a números y viceversa.
- Necesidad de mayúsculas y minúsculas.
- Facilidad de conversión: mayúsculas / minúsculas.
- Ejemplos:
  - Baudot (5 bits), ASCII (7 bits), EBCDIC de IBM (7 bits)...

# ASCII y variantes de 7 bits

- **Permite representar minúsculas.**
- **Ordenación sencilla (códigos ascendentes).**
- **Conversiones y atributos sencillos (un bit).**
- **Caracteres de control.**
- **Sin diacríticos ni otros caracteres latinos # Variantes nacionales ISO 646.**
- **Incompatibles.**
- **Pierden signos de puntuación.**
- **Casi compatibles ASCII.**
- **Pierden facilidad de ordenar, convertir, clasificar...**

# Esquemas de codificación sencillos de 8

- 7 bits bastan para los alfabetos latinos nacionales.
- Extensiones para representar símbolos gráficos: CP437, CP850 (Llamados ASCII por los usuarios de PC).
- A 10 de los 20 idiomas más hablados les bastan 8 bits.
- No bastan 8 bits para todos los alfabetos latinos.
- 8 bits son un problema para canales de comunicación de 7 bits.
  - Ciertas conexiones asíncronas (7 bits + paridad).
  - Ciertos agentes de correo electrónico y otros protocolos de internet.



# ISO 8859

- **8 bits**
- **Compatibles con ASCII**
- **Preferidos en el correo electrónico MIME.**
- **10 variantes.**
- **Todos *contienen* ASCII.**
- **Latin-1 fué el código oficial de HTML (2.0).**

# Variantes de ISO 8859

- **ISO 8859-1: Idiomas del oeste europeo (Latin-1)**
- **ISO 8859-2: Idiomas del este europeo (Latin-2)**
- **ISO 8859-3: Idiomas europeos de sudeste, esperanto (Latin-3)**
- **ISO 8859-4: Idiomas escandinavos/Balcanes (Latin-4)**
- **ISO 8859-5: Latin/Cirílico**
- **ISO 8859-6: Latin/Árabe**
- **ISO 8859-7: Latin/Griego**
- **ISO 8859-8: Latin/Hebreo**
- **ISO 8859-9: Modificación de Latin-1 para el Turco (Latin-5)**
- **ISO 8859-10: Idiomas Lapón/Nórdicos/Esquimal (Latin-6)**

# Variantes de ISO 8859

- **ISO 8859-15: Idiomas del oeste europeo con € y ¢ (Latin-9).**

# Idiomas más importantes

- ***Chino:*** 885.000.000 hablantes.
- ***Inglés:*** 450.000.000 hablantes.
- ***Hindi-Urdu:*** 333.000.000 hablantes.
- ***Español:*** 266.000.000 hablantes.
- ***Portugués:*** 175.000.000 hablantes.
- ***Ruso:*** 153.000.000 hablantes.
- ***Árabe:*** 150.000.000 hablantes.
- ***Japonés:*** 126.000.000 hablantes.
- ***Francés:*** 122.000.000 hablantes.
- ***Alemán:*** 118.000.000 hablantes.
- ***Bengalí:*** 110.000.000 hablantes.
- ***Wu:*** 77.000.000 hablantes.
- ***Javanés:*** 75.000.000 hablantes.

# Idiomas más importantes

- ***Coreano:*** 72.000.000 hablantes.
- ***Italiano:*** 63.000.000 hablantes.
- ***Marathi:*** 65.000.000 hablantes.
- ***Telugu:*** 55.000.000 hablantes.
- ***Tamil:*** 48.000.000 hablantes.
- ***Cantonés:*** 47.000.000 hablantes.
- ***Ucraniano:*** 46.000.000 hablantes.

Nota

De BABEL/Alis [<http://alis.isoc.org/langues/grandes.htm>].

# Extensiones del juego de caracteres

- **Secuencias de escape.**
- **Muy usados en terminales.**
- **ISO 2022:**
  - **Dos juegos de 16 caracteres de control: C0 y C1.**
  - **Cuatro juegos de 94 caracteres gráficos: G0, G1, G2, G3.**
  - **Operaciones para:**
    - **cambiar de juego activo (shift in, shift out)**
    - **cargar juego (escape ...)**
  - **Muy complicado al necesitar mantener estados.**
  - **Poco usado para manipular texto multilingüe.**

# ISO10646 o UCS

- **Consenso de organismos de normalización.**
- **Contentar a todas las partes.**
- **Espacio de 32 bits.**
  - **256 grupos de 256 planos asignados a comités nacionales.**
  - **Primer plano: básico multilingüe, único asignado.**
- **Inmanejable.**
- **No define un orden de transmisión en octetos.**

# Caracteres de ISO10646 o UCS

- **Introducidos:** Latinos, Griego, Cirílico, Hebreo, Árabe, Armenio, Gregoriano, Japonés, Chino, Hiragana, Katakana, Coreano, Hanguliano, Devangari, Bengalí, Gurmuki, Gujarati, Oriya, Tamil, Telugu, Kannada, Malayam, Tai, Lao, Bopomofo, y algunos otros.
- **Trabajando en:** Tibetano, Kumer, Rúnico, Etíope, Jeroglíficos y varios idiomas indo-europeos.
- **No alfabéticos:** símbolos gráficos, tipográficos, matemáticos y científicos, como los proporcionados por TeX, PostScript, MS-DOS, Macintosh, Videotext, OCR, ...



# Unicode

- Alianza de fabricantes.
- Convergencia con plano multilingüe de ISO10646 (inicialmente).
- Los 256 primeros puntos son Latin-1.
- Principio: unificación # mismo punto para caracteres parecidos.
  - Unificación HAN: Chino, Japonés, Coreano
- En evolución (actualmente versión 4.0, Mayo de 2002).
- FFFE y FEFF para detectar orden de transmisión.
- E000 a F8FF de libre uso (usuarios y fabricantes).

# Grados de realización de Unicode

- Grado 1** No combinación ni Hangul Jamo.
- Grado 2** Algunos de combinación: Hebreo, Árabe, Devangari, Bengalí, Gurmukhi, Oriya, Tamil, Telugo, Kannada, Malayalam, Tai, y Lao.
- Grado 3** Todos.

# Arquitectura de unicode

**Nota**

**Verlo con gucharmap o en el consorcio Unicode  
[<http://www.unicode.org/charts/>] .**

# Esquemas de codificación multibyte

- **16 bits ocupan el doble, pero manejables.**
- **Muy incompatible con sistemas de 8 bits.**
- **Difícil internacionalizar programas hechos.**
- **Problemas de transmisión.**
- **Codificar caracteres más frecuentes con 8 bits y extender.**

# Esquemas de codificación multibyte

- Problemas de
  - tamaño de campos.
  - cursores.
  - cortar y pegar.
  - edición de líneas.
  - casar patrones.
- Problemas del sistema de ficheros, etc...: segundo octeto "/".
- Problemas con fin de cadena (nulo).
- Problemas de sincronización.
- Solución: códigos extendidos que:
  - no contienen bytes que son códigos ASCII.
  - no contienen caracteres prefijos de otros.

# Esquema de codificación UTF-8

- **Puntos 0 a 7F: un octeto y tal cual.**
- **Puntos mayores que 7F: como secuencias de 80-FD: elimina problemas de fin de cadena, sistema operativo, sincronización.**
- **Preserva orden de UCS.**
- **C0 a FD comienzan secuencia multiocteto: determinan longitud.**
- **El resto son siempre de 80 a BF.**
- **Representación (la más corta posible).**
- **FE y FF no se usan.**

# Rangos en codificación UTF-8

- Unicode

0x00000000 - 0x0000007F: 0xxxxxxx  
0x00000080 - 0x000007FF: 110xxxxx 10xxxxxx  
0x00000800 - 0x0000FFFF: 1110xxxx 10xxxxxx 10xxxxxx

- Resto de UCS

0x00010000 - 0x001FFFFF: 11110xxx 10xxxxxx 10xxxxxx  
0x00200000 - 0x03FFFFFF: 111110xx 10xxxxxx 10xxxxxx  
0x04000000 - 0x7FFFFFFF: 1111110x 10xxxxxx 10xxxxxx

# Ejemplos de codificación UTF-8

- **Copyright (©):**

`0xa9 = 1010 1001`

`-> 11000010 10101001 = 0xc2 0xa9`

- **Desigual (#):**

`0x2260 = 0010 0010 0110 0000`

`-> 11100010 10001001 10100000 = 0xe2 0x89`



# UTF-16

- Representa puntos de 0000 a 10FFFF.
- Puntos menores que 10000 con 16 bits.
- Puntos mayores o iguales que 10000 con 32 bits.
- D800 a DFFF para extender como UTF-8.

# UTF-7

- Definido en RFC 1642, codifica UNICODE en 7 bits
  - Tal cual: A--Z a--z 0--9 ' ( ) , - . / :  
? +
  - Opcionalmente: ! " # \$ % & \* ; < = > @  
[ ] ^ \_ ` { | } +
  - Resto: +base64- (- no es necesario si no sigue de base64)
  - Signo +: +-
  - Ejemplo:

Hi Mom #!	hex	48, 69, 20, 4D, 6F, 4D, 20, 263A, 21
	utf-7	Hi Mom +Jjo-!

# Transferencia de información por canales

- Puede usarse UTF-7 para Unicode.
- De hecho se usan métodos generales para datos de 8 bits:
  - Un volcado hexadecimal es poco compacto.
    - Expande 100%.
  - Histórico: uuencode para uucp.
    - Poco robusto cuando se sale de sistemas unix.
    - Expande 37%.
  - Modernamente base64 u otras (eg: base82 en PDF).
    - Expande 35%.

# Internacionalización en C y Unix

## Internacionalización en C y Unix

# Caracteres estrechos y anchos

- **Caracteres estrechos, soportados por C (ISO 9899)**

- **Octetos:**

```
char c = 'æ';
```

- **Cadenas multiocteto:**

```
char mensaje[] = "ÁÉÍÓÚ ÀÈÌÒÙ";
```

- **Caracteres anchos: tipos derivados y bibliotecas:**

- **ISO C89**
- **XPG2 / Unix 98**

# Ejemplo: ISO C89

- **Caracteres anchos:**

```
wchar_t mensaje_ancho[];
```

- **Conversiones:**

```
mbstowcs (wchar_t *, const char *, size_t)  
wcstombs (char *, const wchar_t *, size_t)  
mbtowc (wchar_t *, const char *, size_t)  
wctomb (char *, wchar_t)  
...
```

- **Determinación de longitud:**

```
int mblen (const char *, size_t)
```

- **`mbtowc` y `mblen` mantienen estado para juegos**

# **Ejemplo: ISO C89**

**con secuencias de conmutación (no reentrantes).**

# Localizaciones

- Pasadas por variables de entorno o fijadas por programa.
- Las *localizaciones* tienen categorías con nombres
  - LC\_COLLATE: Ordenación: `strcoll`.
  - LC\_CTYPE: Clasificación, conversión.
  - LC\_MESSAGES: Idioma de los mensajes (`catdoc` o `gettext`).
  - LC\_MONETARY: Unidades monetarias (`localeconv`).
  - LC\_NUMERIC: Otros números (`localeconv`, quizá `printf`).
  - LC\_TIME: Impresión de fecha y hora (`strftime`).
  - LC\_ALL: todos.



# Localizaciones

- **LANG:** valor por omisión.
- **LANGUAGE:** lista de valores ordenada por preferencias.

# strftime

- 

```
size_t strftime(char *s, size_t max,  
                const char *format,  
                const struct tm *tm);
```

- **Mucha elección de formatos:**

%c :	Representación preferida de día y hora.
%x :	Representación preferida de la fecha.
%X :	Representación preferida de la hora.
%a :	Abreviatura de día de la semana.
%A :	Nombre de día de la semana.
%b :	Abreviatura del mes.
%B :	Nombre del mes.
%p :	`am' o `pm' o lo que sea...
%d :	Número de día del mes.
%H :	Hora (de 24).

# strftime

# localeconv

- 

```
struct lconv *localeconv(void);
```

- 

```
struct lconv {  
    char *decimal_point;      /* Caracter usado con  
    char *thousands_sep;     /* Separador de miles  
    char *grouping;           /* Agrupamiento de dí  
    char *int_curr_symbol;    /* Basado en ISO 4217  
    char *currency_symbol;    /* Símbolo monetario  
    char *mon_decimal_point; /* Caracter usado con  
    char *mon_thousands_sep; /* Separador de miles  
    char *mon_grouping;       /* Igual que el campo  
    char *positive_sign;      /* Signo para valores  
    char *negative_sign;      /* Signo para valores  
    char int_frac_digits;     /* Dígitos fraccionarios  
    char frac_digits;         /* Dígitos fraccionarios  
    ...
```

# localeconv

# langinfo

- `char * nl_langinfo (nl_item ITEM)`
- `strftime (s, len, "%X %D", tp);`  
  
**produce**  
  
`08:53:09 03/15/00`
- **Lo correcto es**  
  
`strftime (s, len, nl_langinfo (D_T_FMT), tp);`

# Ajuste de localizaciones

- **C** especifica que por omisión se arranca en el **C**.
- Por lo menos `setlocale (LC_ALL, "");`;
- Ajuste fino: `setlocale (CATEGORÍA, VALOR)`.
- Consulta: `setlocale (CATEGORÍA, NULL)`.
- **Valores**
  - **"C" o "POSIX":** obligatorio y por omisión.
  - **"":** variable de entorno.
  - **Dependientes del sistema:**
    - **"spanish"**
    - **Códigos internacionales de idiomas:**  
**"es\_ES", "en\_GB", "en\_US".**
    - **Idem + nombres de códigos de caracteres:**  
**"es\_ES.ISO-8859-1".**
  - **Como ficheros precompilados (por ejemplo en**

# Ajuste de localizaciones

`/usr/lib/locale).`



# Códigos de idiomas

<b>Idioma</b>	<b>ISO639</b>	<b>ISO639-2</b>
<b>Árabe</b>	<b>ar</b>	<b>ara</b>
<b>Aymara</b>	<b>ay</b>	<b>aym</b>
<b>Catalán</b>	<b>ca</b>	<b>cat</b>
<b>Inglés</b>	<b>en</b>	<b>eng</b>
<b>Esperanto</b>	<b>eo</b>	<b>epo</b>
<b>Castellano</b>	<b>es</b>	<b>esl/spa</b>

# Códigos de países ISO3166

<b>es_ES</b>	<b>Castellano de España</b>
<b>es_MX</b>	<b>Castellano de México</b>
<b>en_US</b>	<b>Inglés de USA</b>
<b>en_GB</b>	<b>Inglés británico</b>

# Catálogos de mensajes: X/Open XPG4

## Catálogos de mensajes numerados por módulos

```
#include <stdio.h>
#include <nl_types.h>

#define SET 1
#define MSG_HELLO 1

nl_catd catfd;

int main (int argc, char **argv) {
    setlocale (LC_ALL, "");
    catfd = catopen (basename (argv [0]), MCLoadA
    printf (catgets (catfd, SET, MSG_HELLO, "hell
    catclose (catfd);
    return 0;
}
```

# Catálogos de mensajes: Uniform/

## Indexación por mensaje original

```
#include <locale.h>
#include <gettext.h>
#include <stdio.h>

main( )
{
    setlocale (LC_ALL, "");
    textdomain("helloprogram");
    printf(gettext("Hello, world\n"));
}
```

# catgets y gettext

**catgets**    dificultad para mantener los números de los mensajes, según se añaden o eliminan en los fuentes.

**gettext**    • El programador no se preocupa del catálogo.  
• Colisión de nombres: difícil porque conviene usar frases:

```
gettext("A spring in the spring");
```

- Acceso más lento (índices o tablas *hash*).

ge  
ge  
ge  
ge

# Traducción de cadenas de formato

- No construir plurales ni géneros por programa
- A veces hace falta reordenar para traducir
- Ordenación en `printf`:

`"String '%s' has %d characters\n"`

`"%2$d Zeichen lang ist die Zeichenkette '%1$s'"`

# Herramientas

- **Editores.**
- **Transcodificadores.**
- **Compiladores de localizaciones y bibliotecas.**
- **Ayudas a la internacionalización.**
- **Ayudas a la localización.**
- **...**

# Transcodificadores

- **Transformación:**
  - **Código intermedio con todos los caracteres: A # UCS # B (e.g: `iconv`, `tcs`)**
  - **Concatenación de transformaciones conocidas (no siempre reversibles):**  
**A # M# B**  
**A # X # Y # B**  
**(e.g: `recode` de François Pinard).**



# Compiladores de localizaciones

- La localización depende de los convenios locales y el juego de caracteres.
- Debe escribirse en algo muy transportable: Eg: Subconjunto de 83 caracteres *invariantes* de ISO646.
  - Utilizable directamente en todas las ISO646 nacionales, ISO8859-x, UTF-7, UTF-8, IBM-PC, Mac...
  - Utilizable traducido en todas las EBCDIC...
- Requiere describir todos los caracteres con los invariantes.
- Requiere describir los locales en función de esos caracteres.

# Descripción de caracteres

Glifo	RFC1345	UCS	ISO10646
¼	14	00bc	VULGAR FRACTION ONE QUARTE
½	12	00bd	VULGAR FRACTION ONE HALF
¾	34	00be	VULGAR FRACTION THREE QUAR
¿	?I	00bf	INVERTED QUESTION MARK
À	A!	00c0	LATIN CAPITAL LETTER A WIT
Á	A'	00c1	LATIN CAPITAL LETTER A WIT
Â	A>	00c2	LATIN CAPITAL LETTER A WIT
Ã	A?	00c3	LATIN CAPITAL LETTER A WIT
Ä	A:	00c4	LATIN CAPITAL LETTER A WIT
Å	AA	00c5	LATIN CAPITAL LETTER A WIT
Æ	AE	00c6	LATIN CAPITAL LETTER AE
Ç	C,	00c7	LATIN CAPITAL LETTER C WIT
È	E!	00c8	LATIN CAPITAL LETTER E WIT

# Descripción de locales

## LC\_TIME

```
abday "<d><o><m>"; "<l><u><n>"; "<m><a><r>"/  
      "<m><i><e'>"; "<j><u><e>"; "<v><i><e>"; "<s>  
  
day  "<d><o><m><i><n><g><o>"; "<l><u><n><e><s>"/  
      "<m><a><r><t><e><s>"; "<m><i><e'><r><c><o><l>  
      "<j><u><e><v><e><s>"; "<v><i><e><r><n><e><s>  
      "<s><a'><b><a><d><o>"
```

## LC\_CTYPE

```
digit  <0>;<1>;<2>;<3>;<4>;<5>;<6>;<7>;<8>;<9>  
blank  <SP>;<HT>;<NS>  
space  <SP>;<LF>;<VT>;<FF>;<CR>;<HT>;<NS>  
upper  <A>;<B>;<C>;<D>;<E>;<F>;<G>;<H>;<I>;<J>;<K>  
        <O>;<P>;<Q>;<R>;<S>;<T>;<U>;<V>;<W>;<X>;<Y>  
        <A/>;<A?>;<A:>;<AA>;<AE>;<C,>;<E!>;<E'>;<E  
        <I/>;<I:>;<D->;<N?>;<O!>;<O'>;<O/>;<O?>;<O
```

# Descripción de locales

# El compilador de localizaciones de POSIX

- `localedef -i en_CA -f ISO_8859-1 en_CA`

- 

```
-rw-rw-r-- 1 joaquin profes 10399 Jan 7 08:00
-rw-rw-r-- 1 joaquin profes 10940 Jan 7 08:00
-rw-rw-r-- 1 joaquin profes 93 Jan 7 08:00
-rw-rw-r-- 1 joaquin profes 27 Jan 7 08:00
-rw-rw-r-- 1 joaquin profes 480 Jan 7 08:00
-rw-rw-r-- 1 joaquin profes 42 Jan 7 08:00
```

- O todo junto (`/usr/lib/locale/locale-archive`).
- Los fuentes se pueden encontrar en <ftp://dkuug.dk/i18n/WG15-collection>

# Correo y conferencias

## Correo y conferencias

# Internacionalización del correo y las confe-

- Fuera de línea.
- Sin posibilidad de negociación entre agentes de usuario.
- Pueden negociar agentes de transferencia (insuficiente).
- Generalmente sólo se tiene en cuenta el esquema de codificación.
- Podría tenerse en cuenta el idioma si hay que
  - Dar formato (partir palabras, etc).
  - Comprobar palabras, sintaxis, estilo, etc.
  - Analizar el texto.
  - Dictar.
- **SOLUCIÓN:**
  - Nombrar esquema de codificación.

# Internacionalización del correo y las confe-

- **Restringir la variabilidad.**



# Mime 1.0 y ESMTP

- Correo tradicional basado en RFC 822 / SMTP:
  - ASCII (7 bits).
  - Tamaño limitado de líneas.
  - Una línea con un punto termina el mensaje.
  - Algunos agentes de transferencia transforman el mensaje:
    - ASCII <-> EBCDIC.
    - >From

# Requisitos de Mime 1.0 y ESMTP

- **Mime 1.0**
  - **Enviar mensajes de cualquier tipo (no sólo texto).**
  - **Enviar mensajes compuestos (de varios tipos).**
  - **Enviar mensajes a trozos.**
  - **Resistir las peores pasarelas, pero aprovechar las buenas.**
  - **Poder enviar varios tipos de texto.**
  - **Poder seleccionar el alfabeto.**
  - **Compatible con RFC-822**
- **ESMTP.**
  - **Datos de 8 bits (EHLO, 8BITMIME).**
  - **Transparencia (SIZE).**

# Mensaje RFC 822

- RFC 822:

```
Received: (from joaquin@localhost) by colibri.c  
Date: Tue, 7 Jan 1997 12:50:37 +0100  
From: Joaquin Seoane <joaquin@dit.upm.es>  
Message-Id: <199701071150.MAA02005@colibri.dit  
To: joaquin@colibri.dit.upm.es  
Subject: probando
```

Hola

# Mensaje Mime 1.0 transferible por ESMTP

- Nuevas cabeceras

```
Received: (from joaquin@localhost) by colibri.c
Date: Tue, 7 Jan 1997 12:50:37 +0100
From: Joaquin Seoane <joaquin@dit.upm.es>
Message-Id: <199701071150.MAA02005@colibri.dit
Subject: =?ISO-8859-1?Q?A=F1o_nuevo=2C_vida_nue
MIME-Version: 1.0
Content-Type: TEXT/PLAIN; charset=ISO-8859-1
Content-Transfer-Encoding: 8BIT
```

Feliz año 1997.

# Mensaje Mime 1.0 transferible por SMTP

- Con 7 bits, expandiendo sólo los códigos mayores de 128:

```
Received: (from joaquin@localhost) by colibri.c
Date: Tue, 7 Jan 1997 12:50:37 +0100
From: Joaquin Seoane <joaquin@dit.upm.es>
Message-Id: <199701071150.MAA02005@colibri.dit
Subject: =?ISO-8859-1?Q?A=F1o_nuevo=2C_vida_nue
MIME-Version: 1.0
Content-Type: TEXT/PLAIN; charset=ISO-8859-1
Content-Transfer-Encoding: QUOTED-PRINTABLE

Feliz a=F1o 1997.
```

# Tipos MIME 1.0 simples

- **Tipo y subtipo de contenido: Content-Type**
  - `text/plain`, `text/richtext`, `text/enriched`, `text/html`
  - `image/gif`, `image/jpeg`, ...
  - `audio/basic`
  - `video/mpeg`
  - `application/octet-string`, `application/postscript`, `application/msword`, `application/pdf`, `application/pgp-signature`, ...

# Tipos MIME 1.0 compuestos o referencias

- *multipart/mixed, multipart/alternative, multipart/parallel, multipart/related.*
- *message/rfc822, message/partial, message/external-body.*

# Parámetros de tipos texto MIME 1.0

- **Parámetros del tipo `text/*`: juego de caracteres**
  - **US-ASCII.**
  - **ISO-8859-x.**
  - **En la práctica se usan otros, incluidos UTF-7 y UTF-8.**
  - **UTF-7 y UTF-8.**
  - **En la práctica se usan otros, incluido windows-1252.**



# Codificación de transferencia MIME 1.0

- **Permite pasar distintos medios**
- **Puede cambiarla el agente de transferencia**
- **Independiente del tipo del contenido**
- **Valores**
  - **7BIT**
  - **8BIT**
  - **BINARY**
  - **QUOTED-PRINTABLE**
  - **BASE64**
- **No se han definido compresiones (sí en HTTP)**

# Mime.types, mailcap

- Suele asociarse un tipo Mime a un sufijo de nombre de fichero al enviarlo (tabla / `etc/mime.types`).

<b>application/ postscript</b>	<b>ps,eps</b>
<b>image/jpeg</b>	<b>jpeg, jpg</b>
<b>text/richtext</b>	<b>rtx</b>

- Suele configurarse el agente de correo (o navegador) para lanzar visores externos (tabla / `etc/mailcap`).

<b>application/ postscript</b>	<b>gv '%s'</b>
<b>image/jpeg</b>	<b>display '%s'</b>

# Mime.types, mailcap

<b>text/richtext</b>	<b>shownonascii iso-8859-1 -e richtext -p</b>
----------------------	---

**El web**

**El web**

# Internacionalización del WEB

- Sistema en línea.
- Es posible la negociación.
- Aspectos:
  - HTTP 1.1
  - HTML 4.0, XHTML y XML.
  - URI/URL
  - Hojas de estilo.
  - ....

# HTTP

- **Protocolo de transferencia de hipertexto.**
- **En uso las versiones 0.9, 1.0, y 1.1.**
- **Diseñado para transferir cualquier objeto (html, imágenes, vídeo, ...)**
- **Sin estado.**
- **Pensado para utilización de proxis con y sin cache, pasarelas.**
- **Permite la consulta y la manipulación.**
  - **Método GET.**
  - **Método HEAD.**
  - **Método POST.**
  - **Método PUT.**
  - **Método DELETE.**
  - **Método TRACE.**

# HTTP

- **Pensado parcialmente para negociar contenidos.**
- **Utiliza cabeceras similares a MIME.**

# Ejemplo de interacción HTTP

```
GET / HTTP/1.0
HTTP/1.0 200 Document follows
MIME-Version: 1.0
Server: CERN/3.0
Date: Tuesday, 07-Jan-97 13:43:18 GMT
Content-Type: text/html
Content-Length: 3487
Last-Modified: Tuesday, 24-Sep-96 09:26:31 GMT
<HTML> <HEAD>
  <title>Página de bienvenida del DIT-UPM</title>
</HEAD>
<BODY BACKGROUND="/figures/patterns/bwbackg.gif"
      TEXT="#000000" LINK="#0000FF" VLINK="#0000A0">
<table border=0>
<tr><td> 
```



# Algunas cabeceras

- Pueden ir en peticiones y respuestas (entidades)
- En las respuestas
  - `Content-Type: text/html; charset=ISO-8859-4`
  - `Content-Encoding: gzip`
  - `Content-Length: 2438`
  - `Content-Language: es`
  - `Date: Tuesday, 07-Jan-97 13:43:18 GMT`
  - `Last-Modified: Tuesday, 07-Jan-97 13:43:18 GMT`
  - `Expires: Tuesday, 07-Jan-97 13:43:18 GMT`
  - `Server: CERN/3.0 libwww/2.17`

# Algunas cabeceras en peticiones

- En las peticiones

```
From: joaquin@dit.upm.es
Referer: http://www.dit.upm.es/sitios.html
If-Modified-Since: Tuesday, 07-Jan-97 13:43:18
Authorization: Basic QWxFGHvhfvGHHFgXXtTiI==
User-Agent: CERN-LineMode/2.15 libwww/2.17b3
Accept: text/plain; q=0.5, text/html, text/x-d
Accept-charset: iso-8859-5, unicode-1-1;q=0.8
Accept-encoding: compress,gzip
Accept-language: da,en-gb;q=0.8,en;q=0.7
```

# Negociación

**Un único URI con varias alternativas: ¿cómo se negocia?**

- **Dirigida por servidor.**
- **Dirigida por agente.**
- **Otros mecanismos: cookies.**

# Negociación dirigida por servidor

- El agente dice sus preferencias y capacidades (si quiere).
- El servidor selecciona automáticamente.
- Ventajas:
  - Una vuelta.
- Desventajas:
  - Ineficiente por:
    - La longitud de las peticiones.
    - La escasez de recursos negociables.
    - Difunde información que puede ser confidencial.
  - El servidor no sabe todas las capacidades del cliente o el uso (ver, imprimir...).
  - Complica el servidor.

# Negociación dirigida por servidor

- Dificulta caches.
- Ejemplo: Debian [<http://www.debian.org>]

# Negociación dirigida por agente

- El agente no dice sus preferencias y capacidades.
- El servidor manda lista de alternativas.
- El agente selecciona manual o automáticamente.
- Las alternativas las puede mandar un proxy.
- No está normalizada todavía (¿HTTP-NG?).
- Implementada en Apache 1.3.4, EmWeb, al menos.

# Negociación transparente

- **Combina ambas**
- **Permite a las caches realizar negociación dirigida por servidor**
- **Distribuye la carga de la negociación**

# HTTP 1.1

- **RFC - 2068 (Enero 1997)**
- **Mejoras**
  - **Tratamiento correcto de la negociación dirigida por servidor en caches y proxis.**
  - **Normaliza extensiones propietarias de HTTP 1.0.**
  - **Varias transacciones por conexión.**
  - **Versiones.**
  - **Servidores virtuales.**



# Conversaciones HTTP 1.1

- **Petición:**

```
GET / HTTP/1.1  
Host: www.unicode.org
```

- **Algunas cabeceras nuevas:**

- HTTP-Version: HTTP/1.1
- Host: www.dit.upm.es
- Cache-Control: no-cache
- Cache-Control: max-age
- Content-Version: "2.1.2"
- Vary: accept,accept-language
- Vary: \*
- Content-Location:  
http://www.dit.upm.es/index.html.es

# Conversaciones HTTP 1.1

- **Reservados:**
  - **Alternates:** para negociación en cliente.
  - **Negotiate:** para expresar que el cliente acepta negociación.

# Negociación dirigida por servidor

- El servidor origen debe mandar campo `Vary`: (si *cacheable*).
- La cache puede decidir si responde con la copia o redirige la petición.
- La selección se hace por alternativas y calidades.
- No decir calidad, supone 1.
- El servidor puede ponderar calidades:
  - Mala traducción.
  - Mala imagen.
- Se pueden incluir comodines.
- Ejemplos:
  - `Accept-charset: iso-8859-5, unicode-1-1;q=0.8`
  - `Accept: text/plain; q=0.5, text/html,`

# Negociación dirigida por servidor

`application/postscript; q=0.8`

- `Accept: audio/*; q=0.2, audio/basic`
- `Accept-language:`  
`da,en-gb;q=0.8,en;q=0.7`

# Negociación dirigida por cliente

- El servidor (origen o proxy) ofrece alternativas.
- Puede combinarse con preferencias del cliente.
- La cache puede hacer negociación dirigida por servidor.
- Petición:

```
GET /paper HTTP/1.1  
Host: x.org  
User-Agent: WutxaWeb/2.4  
Negotiate:
```

# Ejemplo respuesta intermedia

HTTP/1.1 300 Multiple Choices

Date: Tue, 11 Jun 1996 20:02:21 GMT

Alternates:

```
{ "paper.html.en" 0.9 {type text/html} {language en}
{ "paper.html.fr" 0.7 {type text/html} {language fr}
{ "paper.ps.en"   1.0 {type application/postscript} {language en}
```

Vary: negotiate, accept, accept-language

Content-Type: text/html

Content-Length: 227

<h2>Multiple Choices:</h2>

<ul>

<li><a href=paper.html.en>HTML, English version

<li><a href=paper.html.fr>HTML, French version

<li><a href=paper.ps.en>Postscript, English version

</ul>

# Propuestas genéricas de cliente

- Propuestas de *características* del cliente:
  - `tables paper=a4`
  - `frames colordepth=5`
  - `textonly pagewidth=200`
- El servidor puede generar *al vuelo* la respuesta:
  - Basado en User-Agent :
  - Basado en Accept-\* :
    - Transliteración automática.
    - Traducción de características.
    - Traducción automática.
  - Imposible listar las alternativas.
  - Difícil cachear.
  - El servidor puede mandar la lista de variables

# Propuestas genéricas de cliente

que controla.



# HTML

- **Creado por Tim Berners-Lee (CERN, 1991)**
- **HTML 2.0 (RFC1866, 1995)**
- **HTML3.2 (1997)**
  - **Applets, tablas, formularios, flujo de texto sobre imágenes.**
  - **Elementos de presentación (FONT).**
- **HTML 4.0 (1997) y 4.01 (1999) e ISO (2000/2003)**
  - **Internacionalización:**
    - **Juego de caracteres del documento: ISO 10646.**
    - **Idioma, direccionalidad,...**
    - **Ruby**
  - **Accesibilidad**
    - **Énfasis en estructura (no presentación).**

# HTML

- **Mejoras en tablas, formularios, etc.**
- **Soporte general de documentos compuestos**
- **Soporte de hojas de estilo.**
- **Soporte para impresión.**

# XHTML

- Transición hacia XML.
- XHTML 1.0 (2000)
  - Estricto
  - De transición
  - Con *frames*.
- XHTML 1.1 (2001)
  - Modular
- XHTML 2.0 (borrador 2004)
  - Incompatible

# Entidades tipo carácter

- **Ahora todo ISO 10646**
  - **Representables como `&#0`; hasta `&#2147483645`;**
  - **Soporte de partición de líneas:**
    - **Blanco no partible: `&nbspsp`;**
    - **Indicación de donde partir: `&shy`; .**
  - **Soporte para enlace de cursivas**
    - **Separador sin espacio: `&zwnj`;**
    - **Juntador sin espacio: `&zwj`;**
  - **Soporte para texto bidireccional (por defecto UNICODE)**
    - **Marca de izquierda a derecha: `&lrm`;**
    - **Marca de derecha a izquierda: `&rlm`;**
    - **Fijar direccionalidad...**

# Entidades tipo carácter

- **Anidar direccionalidad...**

# Atributos de idioma

- **Atributo LANG aplicable a casi cualquier elemento:**

```
<P LANG=es-ES>Esto es un  
    <STRONG LANG="en">silly example</STRONG>  
    de marcaje por idioma.  
</P>
```

- **Atributo xml:lang en XML (y XHTML).**

```
<p>The title in Chinese is  
    <span lang="zh-guoyu" xml:lang="zh-guoyu">  
</p>
```

# Atributos de direccionalidad

- Atributo DIR (LTR o RTL) para fijar direccionalidad (a veces redundante con UNICODE)

**ABxyCDzwEF # AByxCDwzEF**

```
<SPAN DIR="LTR">AB
  <SPAN DIR="RTL">xy
    <SPAN DIR="LTR">CD</SPAN>zw
  </SPAN>EF
</SPAN>
#      ABwzCDxyEF
```

# Citas cortas, superíndices

- Citas cortas: `<Q>Esto es una cita</Q>`
  - "Esto es una cita"
  - `Esto es una cita'
  - «Esto es una cita»
- Superíndices/subíndices: `M<SUP>lle</SUP> Dü-`  
`pont`



# Formularios

- **Atributo ACCEPT-CHARSET en INPUT y TEXTAREA**
- **Usar método POST con tipo MIME `multipart/form-data`**

# Hojas de estilo

- **HTML se ha degradado por el interés en el diseño.**
- **El estilo debe especificarse aparte**
  - **Contrarestar tendencia a poner estilo en HTML**
  - **Especificable por el usuario**
  - **Recomendable por el publicador**
- **Deben poderse especificar estilos alternativos, dependientes del medio (posiblemente parametrizados):**
  - **screen**
  - **tty**
  - **print**
  - **braille**
  - **aural**

# CSS

- **CSS, CSS2.**
- **Anidables (usuario, enlaces, detalles).**
- **Un usuario puede elegir o deshabilitar los del autor.**
- **Permite ajustar tipos, colores tamaños, separaciones, márgenes, sonidos, fondos visuales y musicales, voces.**
- **Estilos, fondos, sujetos a negociación de idioma.**
- **Asociados a elementos (anidados o no) y clases**
- **Ejemplo:**

```
<!DOCTYPE HTML PUBLIC "-//W3C//DTD HTML 4.01 T  
<html>  
  <meta http-equiv="Content-Type" content="text  
                                     charset=UTF-8
```

# CSS

```
<head>
  <title>Título</title>
  <link rel=stylesheet type="text/css" media=
      href="http://www.dit.upm.es/~joaquin.
  <style type="text/css">
    h1 {color: blue}
    h2 {color: green}
  </style>
</head>
<body>
  <h1>La cabecera es azul</h1>
  <p style="color:red">Y el párrafo es rojo.</p>
  <p>Y este del color por omisión.</p>
</body>
</html>
```

**Ver [estilo.html]**

# Las hojas de estilo CSS2

```
body {color: blue; font-size: 26pt}  
:lang(ar) {color: red}  
:lang(zh-Hans) {color: green}
```

```
<p>It is polite to welcome people in their own la  
<ul>  
  <li xml:lang="zh-Hans" lang="zh-Hans">##</li>  
  <li xml:lang="el" lang="el">#####</li>  
  <li xml:lang="ar" lang="ar">#### </li>  
  <li xml:lang="ru" lang="ru">##### </li>  
</ul>
```

**Ver [lang.html]**

# Los URL

- **IDN: Unicode # Normalización # Conversión a subconjunto de ASCII**
  - **http://bücher.ch # http://xn--bcher-kva.ch**
  - **http://#####.w3.mag.keio.ac.jp**
  - **RFC's 3490, 3491, 3492**
- **Parte local: Suconjunto imprimible de ASCII (RFC2936):**
  - **Permite enviar octetos arbitrarios en hexadecimal (e.g.: %0D%0A%20).**
    - **Caracteres de control.**
    - **Caracteres inseguros: "<>{ } | \ ^ ~ [ ] ` .**
    - **Caracteres reservados: ; / ? : @ = & % .**
  - **Nada se dice del código de los caracteres (no se puede imprimir cómodamente)**

# Los URL

- **RFC 2718: usar RFC2936 con UTF-8.**

# Iniciativa WAI [<http://www.w3.org/WAI>]

- **Iniciativa de accesibilidad en el WEB (Abril 1997)**
- **Recomendaciones para HTML (mejor HTML 4)**
  - **Formateo lógico**
    - **Anidar correctamente**
    - **Usar hojas de estilo**
    - **Utilizable sin interpretar el estilo**
    - **Facilita herramientas**
  - **Imágenes con texto alternativo o con explicaciones**
  - **Mapas de imagen en cliente o lista de alternativas**
  - **No poner texto en imágenes**
  - **No poner texto en columnas múltiples**
  - **Enlaces descriptivos y separados**



# Iniciativa WAI [<http://www.w3.org/WAI>]

- Páginas alternativas

**Para saber más**

**Para saber más**

# Sitios web

- **Consortio Unicode** [<http://www.unicode.org>], **The Unicode Standard V4.0** [<http://www.unicode.org/versions/Unicode4.0.0/bookmarks.html>] (publicado por Addison Wesley en 2003).
- **Actividad i18n del W3C** [<http://www.w3c.org/international>]
- **i18n and Multilingual support in Internet mail** [<http://www.terena.nl/multiling/ml-mua/mldoc-review.html>] (Yuri Demchenko, TERENA).
- **Iniciativa Babel de ISOC/Alis** [<http://alis.isoc.org>]
- **Internacionalización de Java** [<http://java.sun.com/j2se/corejava/intl/index.jsp>].
- **Open directory of links to internationalization (i18n) resources and related material.**

# Sitios web

**[<http://www.i18ngurus.com>]**

- **Internationalization (I18n), Localization (L10n), Standards, and Amusements**  
**[<http://www.i18nguy.com>].**

# Libros

- Yves Savourel, *XML Internationalization and Localization*, SAMS., 2001.
- Luong et al., *Internationalization: developing software for global markets*, John Wiley and Sons Inc., 1994.
- Galdo, *International user interfaces*, John Wiley and Sons Inc., 1996.
- XOPEN, *Internationalization Guide*, Ver. 2, Prentice Hall, 1995.
- Madell and Hewlett, *Developing and localizing international software*, Prentice Hall, 1994.
- Schmitt, *Designing international software*, Prentice Hall, 1996.
- Uren et al. *Software Internationalization and localization*, International Thomson Pub, 1993.

# Libros