Departamento de Lenguajes y Sistemas Informáticos

Universitat d'Alacant
Universidad de Alicante

XML

Programación en Internet
Curso 2009-2010

Contenidos

- Introducción
- Versiones
- Estructura de un documento
- Definición de un DTD
- Validación de un documento

Programación en Internet – Curso 2009-2010

Introducción

- XML
- Versiones
- Ventajas
- Objetivos de diseño
- Qué necesito para usar XML

Programación en Internet – Curso 2009-2010

XML

- *Extensible Markup Language*
- *World Wide Web Consortium* (W3C)
- Problema:
  - HTML inflexible, mezcla contenido y presentación
  - SGML demasiado complejo
- Subconjunto de SGML

GML (IBM, 1969)
⇓
SGML (ISO 8879, 1986)
⇓
XML (W3C, 1998)

XML

- No es un lenguaje (no etiquetas predefinidas), es un **metalenguaje**:
  - Definir etiquetas y sus atributos
  - Definir relaciones estructurales
- XHTML: híbrido HTML + XML
  - HTML escrito según XML (aplicación de XML)
  - Sustituto de HTML

Versiones

- 10/2/1998: XML 1.0
- 6/10/2000: XML 1.0 Second Edition
- 4/2/2004: XML 1.0 Third Edition
- 16/8/2006: XML 1.0 Fourth Edition
  - Las tres ediciones corrigen erratas y clarifican/detallan el estándar, pero no son una nueva versión

Versiones

- 4/2/2004: XML 1.1
  - Actualiza 1.0 respecto al juego de caracteres (no depende de una versión específica de Unicode, permite utilizar siempre la última), añade verificación de normalización de caracteres y las normas de final de línea se ajustan más a Unicode
  - W3C: "*You are encouraged to create or generate XML 1.0 documents if you do not need the new features in XML 1.1; XML Parsers are expected to understand both XML 1.0 and XML 1.1*"
- 16/8/2006: XML 1.1 Second Edition
  - Corrige erratas y clarifica/detalla el estándar, pero no es una nueva versión

Programación en Internet – Curso 2009-2010

Versiones

- **Extensible Markup Language (XML) 1.0 (Fourth Edition)**
  - W3C Recommendation 16 August 2006
  - http://www.w3.org/TR/2006/REC-xml-20060816/
  - Para obtener siempre la última versión:
    - http://www.w3.org/TR/xml/

Programación en Internet – Curso 2009-2010

Ventajas

- Mejora búsquedas → Metadatos
- Facilita intercambio información → Estándar
- Visión estructurada → Tratamiento local
- Integración diferentes fuentes
- Actualizaciones granulares → División de la información
- **Separación contenido (datos) / presentación**
  - Facilita mantenimiento
  - Ofrece múltiples presentaciones

Programación en Internet – Curso 2009-2010

Ventajas

- Permite crear lenguajes de marcado para dominios específicos:
  - Química: *Chemical Markup Language* (CML)
  - Matemáticas: *Mathematical Markup Language* (MathML)
  - Música: MusicXML
  - Información monetaria: *Open Financial Exchange* (OFX)
  - Recursos humanos (ofertas de trabajo, currículos, etc.): HR-XML

Programación en Internet – Curso 2009-2010

Ventajas

- El contenido se describe a sí mismo:

```
<persona id=“p110” sexo=“m”>
<nombre>Pedro López</nombre>
<direccion>de los Palotes, 120</direccion>
<fnacimiento>30/06/1970</fnacimiento>
</persona>
-------------
p110;m;Pedro López;de los Palotes, 120; 30/06/1970
-------------
0A 11 3C 2E 52 78 90 AA BC EA ...
```

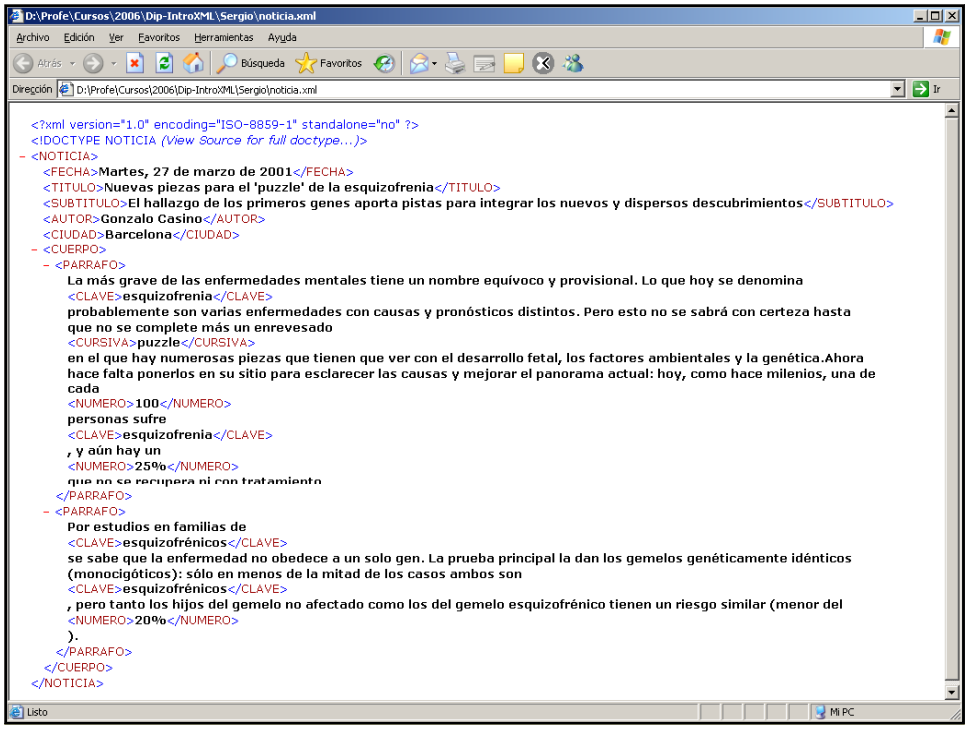

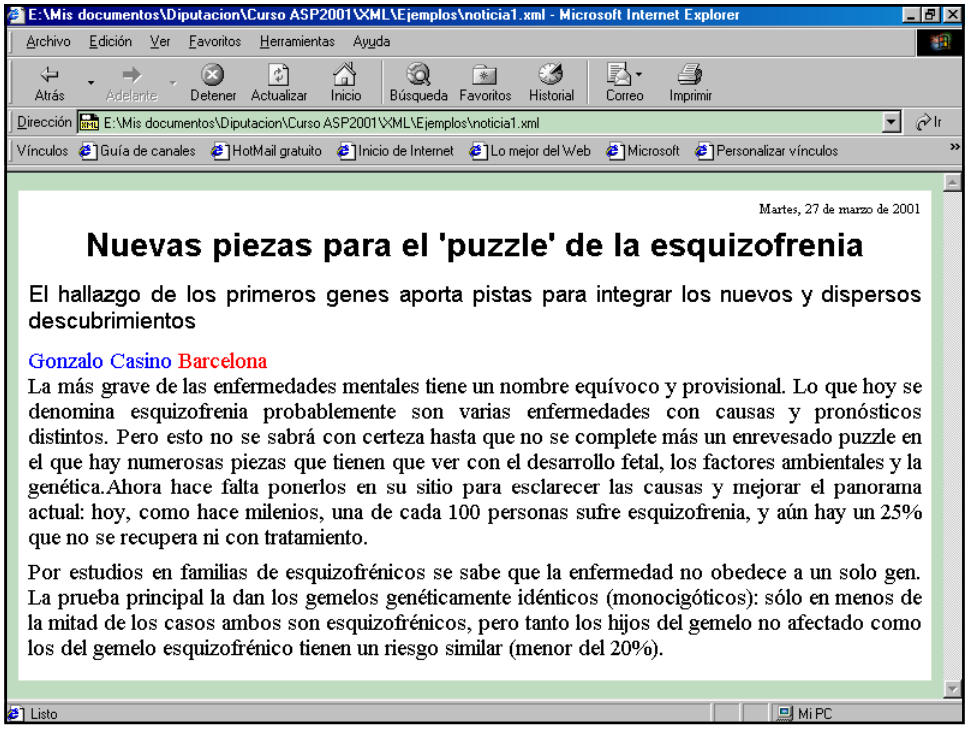
E:\Mis documentos\Diputacion\Curso ASP2001\XML\Ejemplos\noticia1.xml - Microsoft Internet Explorer
Archivo Edición Ver Favoritos Herramientas Ayuda
Atrás Adelante Detener Actualizar Inicio Búsqueda Favoritos Historial Correo Imprimir
Dirección E:\Mis documentos\Diputacion\Curso ASP2001\XML\Ejemplos\noticia1.xml
Vínculos Guía de canales HotMail gratuito Inicio de Internet Lo mejor del Web Microsoft Personalizar vínculos
Martes, 27 de marzo de 2001
Nuevas piezas para el 'puzzle' de la esquizofrenia
El hallazgo de los primeros genes aporta pistas para integrar los nuevos y dispersos descubrimientos
Gonzalo Casino Barcelona
La más grave de las enfermedades mentales tiene un nombre equívoco y provisional. Lo que hoy se denomina esquizofrenia probablemente son varias enfermedades con causas y pronósticos distintos. Pero esto no se sabrá con certeza hasta que no se complete más un enrevesado puzzle en el que hay numerosas piezas que tienen que ver con el desarrollo fetal, los factores ambientales y la genética.Ahora hace falta ponerlos en su sitio para esclarecer las causas y mejorar el panorama actual: hoy, como hace milenios, una de cada 100 personas sufre esquizofrenia, y aún hay un 25% que no se recupera ni con tratamiento.
Por estudios en familias de esquizofrénicos se sabe que la enfermedad no obedece a un solo gen. La prueba principal la dan los gemelos genéticamente idénticos (monocigóticos): sólo en menos de la mitad de los casos ambos son esquizofrénicos, pero tanto los hijos del gemelo no afectado como los del gemelo esquizofrénico tienen un riesgo similar (menor del 20%).
Listo
Mi PC

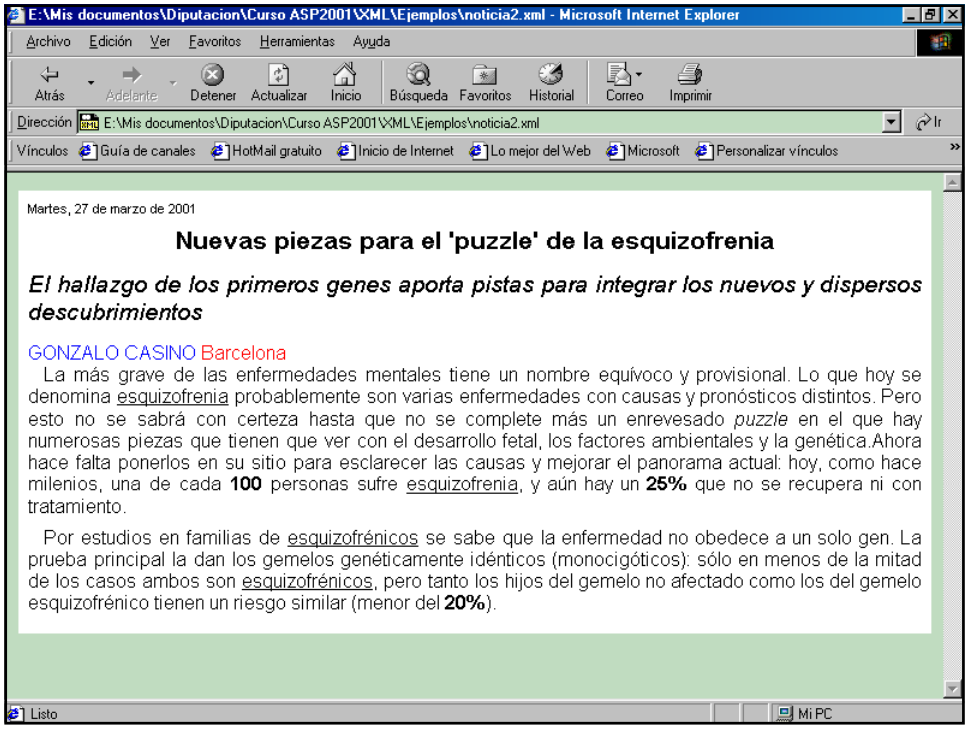
E:\Mis documentos\Diputacion\Curso ASP2001\XML\Ejemplos\noticia2.xml - Microsoft Internet Explorer
Archivo Edición Ver Favoritos Herramientas Ayuda
Atrás Adelante Detener Actualizar Inicio Búsqueda Favoritos Historial Correo Imprimir
Dirección E:\Mis documentos\Diputacion\Curso ASP2001\XML\Ejemplos\noticia2.xml
Vínculos Guía de canales HotMail gratuito Inicio de Internet Lo mejor del Web Microsoft Personalizar vínculos
Martes, 27 de marzo de 2001
Nuevas piezas para el 'puzzle' de la esquizofrenia
El hallazgo de los primeros genes aporta pistas para integrar los nuevos y dispersos descubrimientos
GONZALO CASINO Barcelona
La más grave de las enfermedades mentales tiene un nombre equívoco y provisional. Lo que hoy se denomina esquizofrenia probablemente son varias enfermedades con causas y pronósticos distintos. Pero esto no se sabrá con certeza hasta que no se complete más un enrevesado puzzle en el que hay numerosas piezas que tienen que ver con el desarrollo fetal, los factores ambientales y la genética.Ahora hace falta ponerlos en su sitio para esclarecer las causas y mejorar el panorama actual: hoy, como hace milenios, una de cada 100 personas sufre esquizofrenia, y aún hay un 25% que no se recupera ni con tratamiento.
Por estudios en familias de esquizofrénicos se sabe que la enfermedad no obedece a un solo gen. La prueba principal la dan los gemelos genéticamente idénticos (monocigóticos): sólo en menos de la mitad de los casos ambos son esquizofrénicos, pero tanto los hijos del gemelo no afectado como los del gemelo esquizofrénico tienen un riesgo similar (menor del 20%).
Listo
Mi PC

Objetivos de diseño

1. Se debe de poder usar en Internet
   - Parte de HTML
   - Tan fácil de ver como HTML
2. Amplia variedad de aplicaciones (estructurada, textual, multimedia, etc.)
3. Compatible con SGML (reutilización de herramientas)
4. Sencillo de emplear (más fácil que SGML)
5. Características opcionales: mínimas (no dos formas de hacer lo mismo)

Objetivos de diseño

6. Lectura y estructura clara (lectura por un humano)
7. Diseño rápido (1996-1998)
8. Diseño formal y conciso (reglas)
9. Documentos fáciles de crear (simple editor ASCII)
10. Concisión etiquetas: mínima importancia (no ahorro etiquetas)

Programación en Internet – Curso 2009-2010

Qué necesito para usar XML

- Editor ASCII estándar
- Visualización:
  - Microsoft Internet Explorer 5
  - Netscape 6
- Ficheros: `.xml`
  - Nombres cortos y sencillos
  - No caracteres especiales ni espacios en blanco
- Qué vamos a usar:
  - Microsoft Internet Explorer con XML/XSL Viewer Tools
  - Microsoft XML Notepad 2007
  - ezDTD 1.5
  - Altova XML Spy 2004

Programación en Internet – Curso 2009-2010

Estructura de un documento

- Estructura lógica
- Estructura de un documento
- Estructura de un DTD

Programación en Internet – Curso 2009-2010

Estructura lógica

- Plantilla:
  - Etiquetas
  - Atributos
  - Posición
- Estructura definida por un DTD (*Document Type Definition*)
  - Opcional
  - Define jerarquía (organización) y granularidad (grado de división en partes más pequeñas)

Programación en Internet – Curso 2009-2010

Estructura lógica

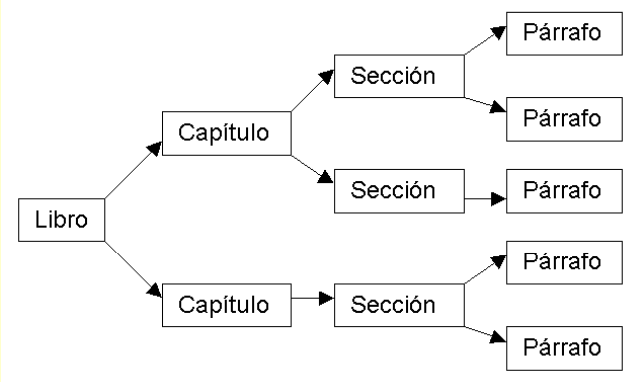

Estructura lógica

- Documento “bien formado”: respeta sintaxis de XML
- Documento válido: respeta DTD

Programación en Internet – Curso 2009-2010

Estructura de un documento

- Comentarios:
  ```
  <!-- Comentario -->
  ```
- Cabecera (declaración XML) → Instrucción de procesamiento:
  ```
  <?xml
    version=”1.0”
    encoding=”ISO-8859-1”
    standalone=”yes” ?>
  ```
- Si no se incluye:
  - Versión: 1.0
  - Codificación de caracteres: UTF-8
  - Entidades externas: sí

Programación en Internet – Curso 2009-2010

Estructura de un documento

- Etiquetas → Definen un elemento: `<LIBRO></LIBRO>`
- Etiquetas vacías (inicial y final): `<LIBRO/>`
- Distinción mayúsculas / minúsculas

Programación en Internet – Curso 2009-2010

Estructura de un documento

- Estructura jerárquica
  - Organización fija
  - No solapamiento
- Elemento raíz único
- Atributos: siempre “” o ‘’
  - `&quot;` y `&apos;`
- Atributos reservados:
  - `xml:lang`
  - `xml:space: default | preserve`

Estructura de un documento

- Ejemplo de xml:lang:

```
<p xml:lang="en">The quick brown fox jumps over the
   lazy dog.</p>
<p xml:lang="en-GB">What colour is it?</p>
<p xml:lang="en-US">What color is it?</p>
<sp who="Faust" desc='leise' xml:lang="de">
  <l>Habe nun, ach! Philosophie,</l>
  <l>Juristerei, und Medizin</l>
  <l>und leider auch Theologie</l>
  <l>durchaus studiert mit heißem Bemüh'n.</l>
</sp>
```


Estructura de un documento

- Espacios en blanco:
  - Tabulador
  - Avance de línea
  - Retorno de carro
  - Espacio en blanco
- Normalización caracteres final de línea:
  - Macintosh CR → LF
  - MS-DOS / Windows CR+LF → LF
  - Unix LF

Estructura de un documento

- Caracteres especiales:

Carácter	Codificación
<	&lt;
>	&gt;
&	&amp;
“	&quot;
‘	&apos;

Estructura de un documento

- Secciones CDATA: permite que el analizador ignore ciertas secciones del documento
- Sintaxis:

```
<![CDATA[
…
]]>
```

- Solo la cadena final (]]>) se reconoce como marcado y se pueden emplear los caracteres especiales
- Las secciones CDATA no se pueden anidar
- Utilidad: incluir código de script que suele contener los caracteres &, <, >, ‘ y “

Programación en Internet – Curso 2009-2010

Estructura de un documento

```
<?xml version="1.0"?>
<!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"
    "http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
<html>
<head>
<title>Una prueba del CDATA</title>
<script type="text/javascript">
if(a < 5 && a > 1)
  alert("El valor de a no es correcto");
</script>
</head>
<body>
<p>Una prueba del CDATA</p>
</body>
</html>
```

Programación en Internet – Curso 2009-2010

Estructura de un documento

```
<?xml version="1.0"?>
<!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"
    "http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
<html>
<head>
<title>Una prueba del CDATA</title>
<script type="text/javascript">
<![CDATA[
if(a < 5 && a > 1)
  alert("El valor de a no es correcto");
]]>
</script>
</head>
<body>
<p>Una prueba del CDATA</p>
</body>
</html>
```

Estructura de un DTD

- Representa una gramática
- Declaración:

```
<! ... >
```

- Cuatro tipos:
  - Elemento (ELEMENT)
  - Atributo (ATTLIST)
  - Entidad (ENTITY)
  - Notación (NOTATION)

Declaración de elemento

- Define un elemento (etiqueta) nuevo:

```
<!ELEMENT nombre
contenido >
```

- Nombre:
  - Primer carácter: letra, '_', ':'
  - Resto: letra, '_', ':', dígitos, '.' o '-'

Declaración de elemento

- Contenido:
  - Nada: `EMPTY`
  - Elementos hijo: `ANY` o modelo de grupo
  - Texto
  - Mezcla

Declaración de elemento

- Modelo de grupo:
  - Secuencia de aparición: `,` `|`
  - Secuencia de cantidad: `?` `+` `*`
- Texto: #PCDATA

Ejemplos

```
<!ELEMENT algo (a, b?, c+, d*)>

<!ELEMENT algo ((a | b), c?)>

<!ELEMENT algo ((a | b)+, c?)>

<!ELEMENT algo ((a, b)+, (c | d)+)>
```


Declaración de elemento

- Modelo de contenido mixto:
  - #PCDATA primer elemento
  - Conectores de elección (|)
  - Grupo opcional y repetible (*)

Declaración de atributo

- Define atributos de un elemento (etiqueta):

```
<!ATTLIST elemento
  atributo1 contenido1 defecto1
  atributo2 contenido2 defecto2>
```

Programación en Internet – Curso 2009-2010

Declaración de atributo

- Contenido:
  - CDATA
  - NMTOKEN
  - NMTOKENS
  - ENTITY
  - ENTITIES
  - ID
  - IDREF
  - NOTATION
  - Grupo de tokens

Programación en Internet – Curso 2009-2010

Declaración de atributo

- `NMTOKEN` (name token) parecidos a `CDATA`, pero sólo aceptan los caracteres válidos para nombrar cosas (letras, números, puntos, guiones, subrayados y los dos puntos)
- `NMTOKENS` lista de `NMTOKEN` separados por espacios en blanco

Programación en Internet – Curso 2009-2010

Declaración de atributo

- `ENTITY` referencia un fichero externo an external file. Each entity name must match the name of an unparsed entity declared in the DTD.
- `ENTITIES` references a list of entity references, employing syntax separated by blank spaces.

Declaración de atributo

- `NOTATION`: su valor se ajusta a una notación declarada

```
<!ATTLIST mensaje fecha NOTATION (ISO-
  DATE | EUROPEAN-DATE) #REQUIRED>
```

Programación en Internet – Curso 2009-2010

Declaración de atributo

- Valor por defecto (opcional):
  - `#REQUIRED` → El atributo es obligatorio
  - `#IMPLIED` → El atributo es opcional
  - `#FIXED "valor"` → El atributo tiene un valor fijo
  - `"valor"` → Valor por defecto

Ejemplos

```
<!ATTLIST img
  src CDATA #IMPLIED
  align (left | center | right)
  size NMTOKEN #REQUIRED>

<!ATTLIST alumno
  nombre CDATA #REQUIRED
  matricula ID #REQUIRED>
```


Declaración de entidad

- Asocia un nombre con un fragmento de contenido
- Ventajas:
  - Facilita la escritura
  - Disminuye los posibles errores
  - Clarifica la estructura
  - Facilita el mantenimiento
- Tres tipos:
  - Internas
  - Externas
  - Paramétricas

Declaración de entidad

- Internas:
  - `<!ENTITY  entidad “valor”>`
  - `&entidad;`
- Externas:
  - `<!ENTITY  entidad SYSTEM “fichero.xml”>`
  - `&entidad;`

Declaración de entidad

- Entidades predefinidas:

```
<!ENTITY lt "&#38;#60;">
<!ENTITY gt "&#62;">
<!ENTITY amp "&#38;#38;">
<!ENTITY apos "&#39;">
<!ENTITY quot "&#34;">
```

Escapar

Declaración de entidad

- Paramétrica: asocia un nombre con un fragmento de DTD que se repite varias veces:

```
<!ENTITY % nombre contenido>
```

- Cuando se usa ⇒ sustitución:

```
%nombre;
```


Ejemplos

```
<!ENTITY % TextAlign "align (left|center|right|justify)
   #IMPLIED">

<!ATTLIST div
  %attrs;
  %TextAlign;
  >

<!ATTLIST p
  %attrs;
  %TextAlign;
  >

<!ATTLIST h1
  %attrs;
  %TextAlign;
  >
```

Declaración de notación

- Especifica tipo ficheros binarios referenciados:

```
<!NOTATION GIF87A SYSTEM
  “GIF”>
```


Colocación en un documento

- Al principio:
  - Incluir el DTD

```
<!DOCTYPE NOTICIA [...]>
```

  - Referenciar el DTD
    - PUBLIC: global, un estándar
    - SYSTEM: local, definido por el usuario

```
<!DOCTYPE NOTICIA SYSTEM
  "noticia.dtd">
```

  - Una combinación

Orden de procesamiento

<?xml version="1.0" encoding="ISO-8859-1" **standalone="yes"** ?>

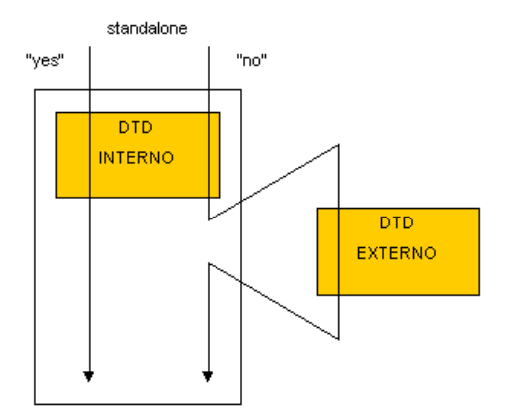

DTDs ya definidos

- Book XML DTD
- Channel Definition Format (CDF)
- Chemical Markup Language (CML)
- Genealogical Data in XML (GedML)
- Mathematical Markup Language (MathML)
- Open Software Description (OSD)
- Resource Description Framework (RDF)
- Web Distributed Data Exchange (WDDX)

Programación en Internet – Curso 2009-2010

Validación de un documento

- Documento bien formado → XML
- Documento válido → DTD

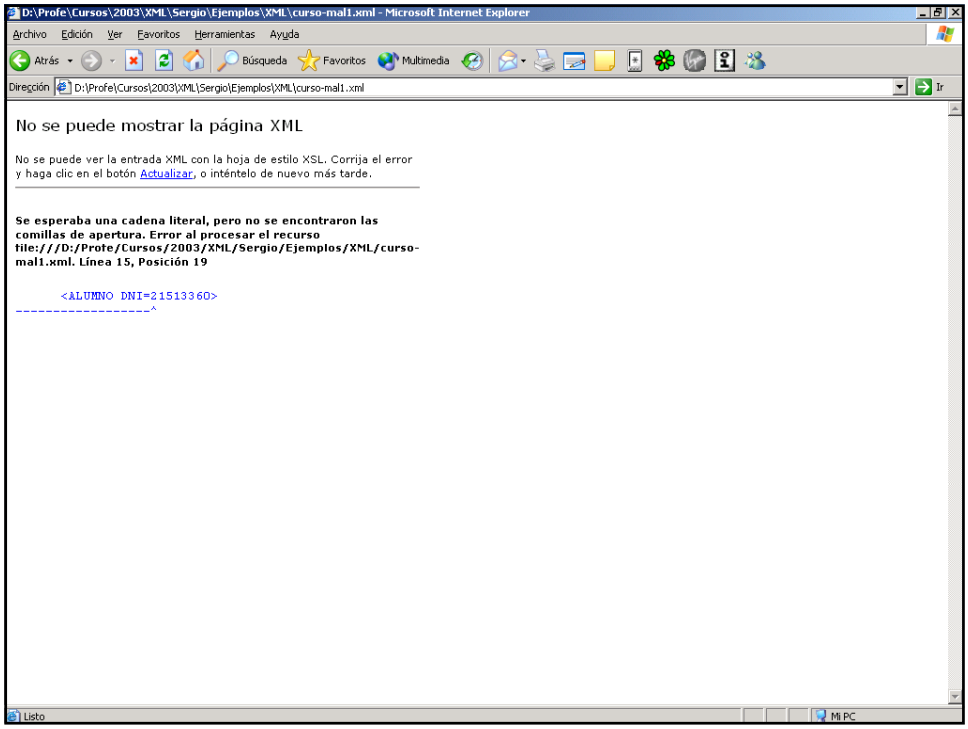

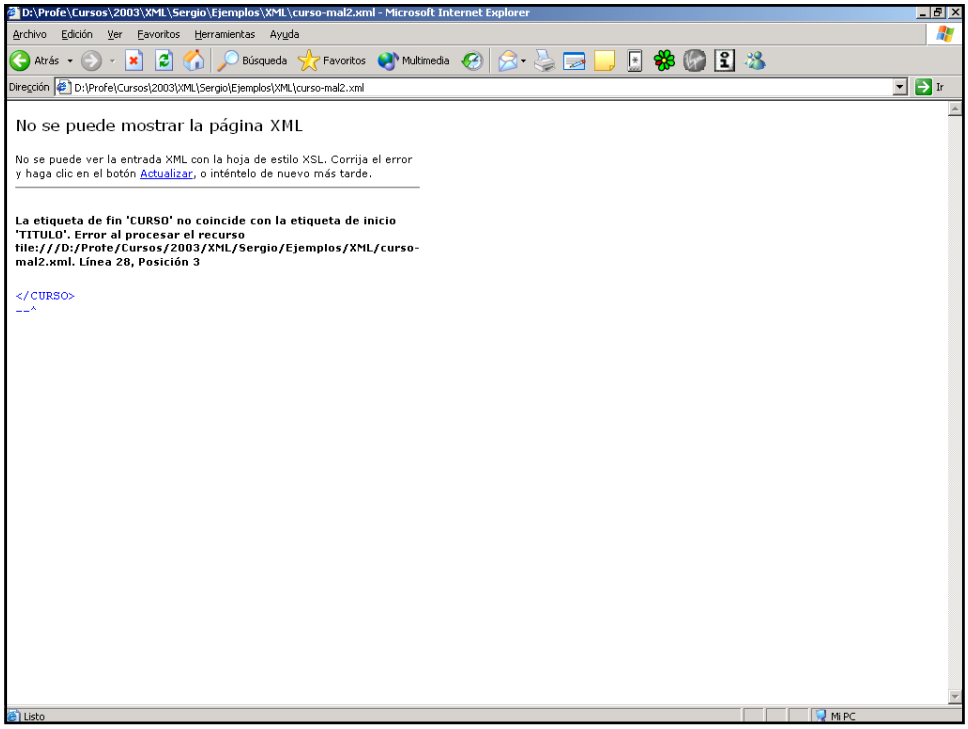
D:\Profe\Cursos\2003\XML\Sergio\Ejemplos\XML\curso-mal2.xml - Microsoft Internet Explorer
Archivo Edición Ver Favoritos Herramientas Ayuda
Atrás Búsqueda Favoritos Multimedia
Dirección D:\Profe\Cursos\2003\XML\Sergio\Ejemplos\XML\curso-mal2.xml
Ir
No se puede mostrar la página XML
No se puede ver la entrada XML con la hoja de estilo XSL. Corrija el error y haga clic en el botón Actualizar, o inténtelo de nuevo más tarde.
La etiqueta de fin 'CURSO' no coincide con la etiqueta de inicio 'TITULO'. Error al procesar el recurso file:///D:/Profe/Cursos/2003/XML/Sergio/Ejemplos/XML/curso-mal2.xml. Línea 28, Posición 3
</CURSO>
--^
Listo
Mi PC

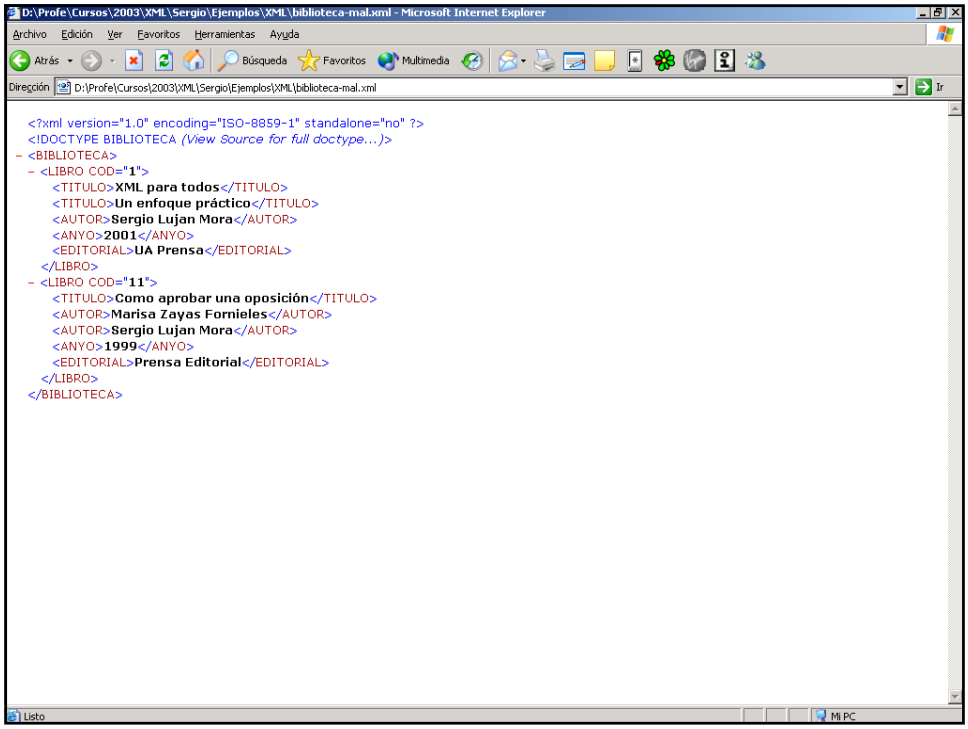
D:\Profe\Cursos\2003\XML\Sergio\Ejemplos\XML\biblioteca-mal.xml - Microsoft Internet Explorer
Archivo Edición Ver Favoritos Herramientas Ayuda
Atrás Búsqueda Favoritos Multimedia
Dirección D:\Profe\Cursos\2003\XML\Sergio\Ejemplos\XML\biblioteca-mal.xml
Ir
<?xml version="1.0" encoding="ISO-8859-1" standalone="no" ?>
<!DOCTYPE BIBLIOTECA (View Source for full doctype...)>
- <BIBLIOTECA>
- <LIBRO COD="1">
<TITULO>XML para todos</TITULO>
<TITULO>Un enfoque práctico</TITULO>
<AUTOR>Sergio Lujan Mora</AUTOR>
<ANYO>2001</ANYO>
<EDITORIAL>UA Prensa</EDITORIAL>
</LIBRO>
- <LIBRO COD="11">
<TITULO>Como aprobar una oposición</TITULO>
<AUTOR>Marisa Zayas Fornieles</AUTOR>
<AUTOR>Sergio Lujan Mora</AUTOR>
<ANYO>1999</ANYO>
<EDITORIAL>Prensa Editorial</EDITORIAL>
</LIBRO>
</BIBLIOTECA>
Listo
Mi PC

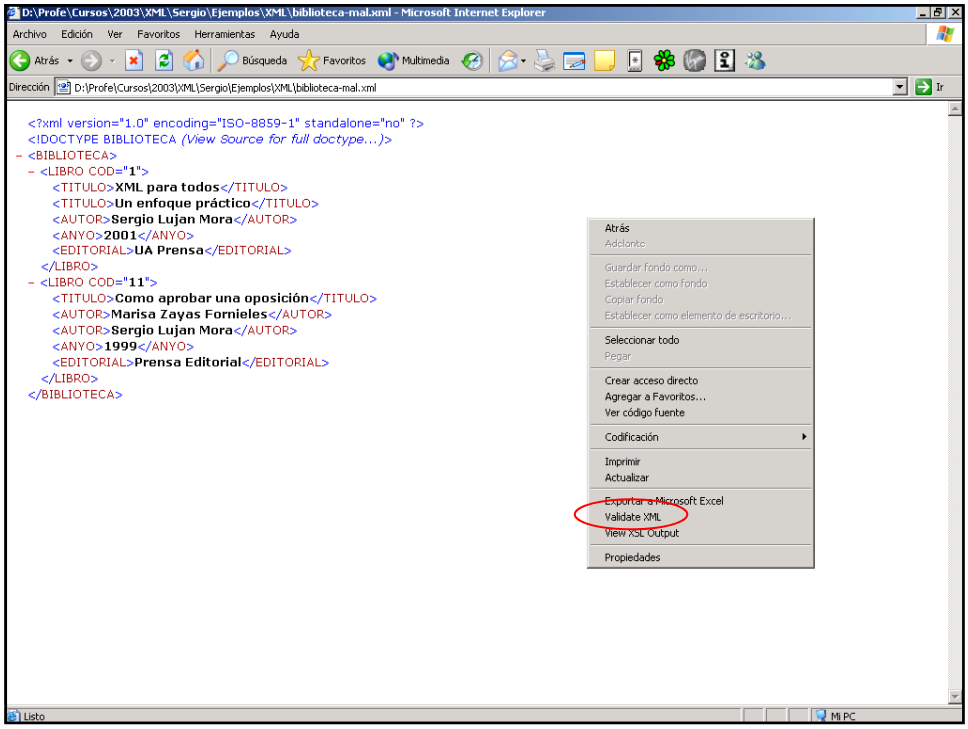
D:\Profe\Cursos\2003\XML\Sergio\Ejemplos\XML\biblioteca-mal.xml - Microsoft Internet Explorer
Archivo Edición Ver Favoritos Herramientas Ayuda
Atrás Búsqueda Favoritos Multimedia
Dirección D:\Profe\Cursos\2003\XML\Sergio\Ejemplos\XML\biblioteca-mal.xml
Ir
<?xml version="1.0" encoding="ISO-8859-1" standalone="no" ?>
<!DOCTYPE BIBLIOTECA (View Source for full doctype...)>
- <BIBLIOTECA>
- <LIBRO COD="1">
<TITULO>XML para todos</TITULO>
<TITULO>Un enfoque práctico</TITULO>
<AUTOR>Sergio Lujan Mora</AUTOR>
<ANYO>2001</ANYO>
<EDITORIAL>UA Prensa</EDITORIAL>
</LIBRO>
- <LIBRO COD="11">
<TITULO>Como aprobar una oposición</TITULO>
<AUTOR>Marisa Zayas Fornieles</AUTOR>
<AUTOR>Sergio Lujan Mora</AUTOR>
<ANYO>1999</ANYO>
<EDITORIAL>Prensa Editorial</EDITORIAL>
</LIBRO>
</BIBLIOTECA>
Atrás
Adelante
Guardar fondo como...
Establecer como fondo
Copiar fondo
Establecer como elemento de escritorio...
Seleccionar todo
Pegar
Crear acceso directo
Agregar a Favoritos...
Ver código fuente
Codificación
Imprimir
Actualizar
Exportar a Microsoft Excel
Validate XML
View XSL Output
Propiedades
Listo
Mi PC

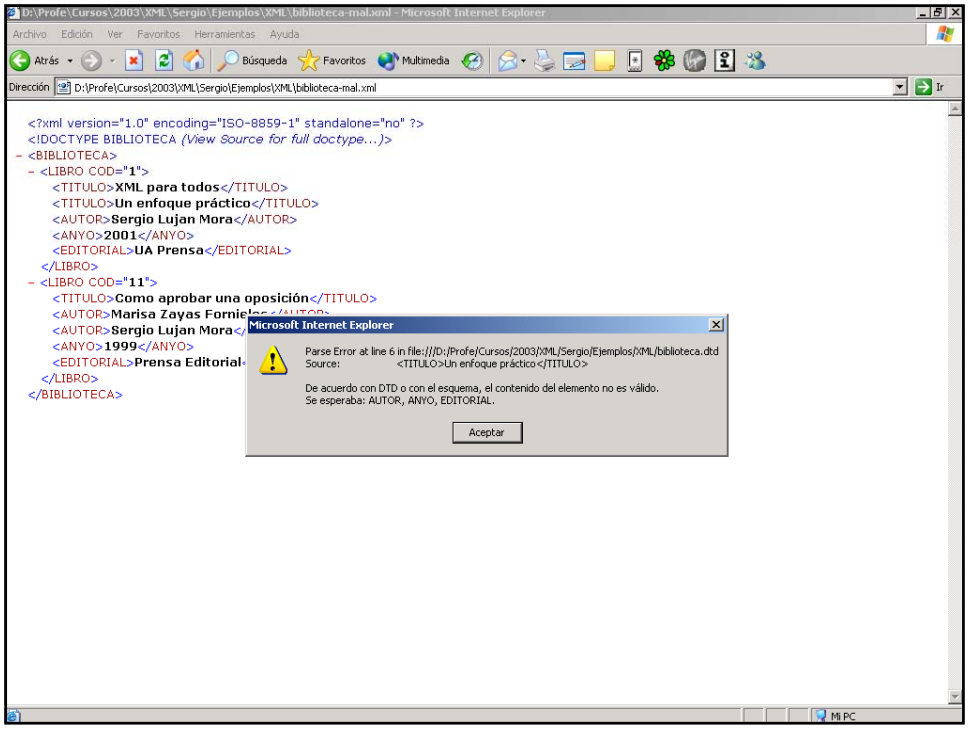
Microsoft Internet Explorer
Parse Error at line 6 in file:///D:/Profe/Cursos/2003/XML/Sergio/Ejemplos/XML/biblioteca.dtd
Source: <TITULO>Un enfoque práctico</TITULO>
De acuerdo con DTD o con el esquema, el contenido del elemento no es válido.
Se esperaba: AUTOR, ANYO, EDITORIAL.
Aceptar