XML

Eine Einführung

März 2006

Themen

- Allgemeine Vorbemerkungen
- Die Sprache XML:
  - Grundlagen und Geschichte
  - Sprachgebrauch, Wohlgeformtheit
  - Dokumentstrukturen, DTD, Validierbarkeit
- Erstellung von XML-Dateien:
  - Editoren: GNU Exml, Emacs, XMLSpy
  - Parser: SP von James Clark, msxml von Microsoft
- Ausgabemöglichkeiten von XML:
  - XML-fähige Dateien über WWW-Browser
    - Microsoft Internet Explorer, Mozilla, Opera
- Stilvorlagen und Transformation
  - XSL/XSLT
  - Cocoon-Projekt als XML-Framework

Dokumentation

- **XML 1.0 – Grundlagen, Juni 2001, RRZN Skript**

- **H. Behme u. S. Mintert: XML in der Praxis, professionelles Web-Publishing mit der Extensible Markup Language**
  Addison Wesley, ISBN: 3827313309
- **Jon Bosak: XML, Java, and the future of the Web**
  sunsite.unc.edu/pub/sun-info/standards/xml/why/xmlapps.html
- **Michael Smith: Take My Advice: Don't Learn XML**
  xml.oreilly.com/news/dontlearn_0701.html

- **Ansonsten: Suchmaschine (www.google.de) ;-)**

Verfügbarkeit der Programme

- **Viele der hier vorgestellten Programme sind frei verfügbar**
  - **Im World Wide Web**
  - **Auf CDROM**

Was ist falsch an HTML?

- **HTML ist daraufhin optimiert, leicht erlernt und angewendet zu werden**
  - **Einheitliches Tag-Set für alle Anwendungen**
  - **Vordefinierte Semantik für jeden Tag**
  - **Verzicht auf die Validierbarkeit zu Gunsten der leichteren Anwendbarkeit**
  - **Ideal für kleinere Web-Anwendungen (*Homepages*) aber viel zu unflexibel für die Organisation größere Datenmengen (*Web-Sites*)**
  - **Wenig Möglichkeit zur modularen Wiederverwertbarkeit**
  - **die Daten lassen sich nur schwer für unterschiedliche Ausgabegeräte präsentieren**
  - **Schwer zu realisierende Navigationsstruktur und der damit verbundenen Pflege**
  - **Bietet keine kontextabhängige Suchmöglichkeit, da keine semantische Auszeichnung**
  - **Datenstrukturen eignen sich kaum für Datenbanken**

Was ist falsch an HTML? (cont.)

- **HTML eignet sich gut zur Verteilung von Dokumenten im Web**
- **Die Unzufriedenheit über den Funktionsumfang von HTML demonstriert die stürmische Weiterentwicklung durch Erweiterungen wie**
  - **Spracherweiterungen: Frames, Layers (Netscape), Marquee (Microsoft), etc.**
  - **Scriptsprachen: JavaScript, VB-Script**
  - **Programme: Java-Applets**
  - **Animierte Vektorgrafiken: Macromedia Flash, SVG, VML**
  - **Virtuelle Realitäten: VRML**
  - **umfangreiche *Sitemanager* diverser Web-Autorensysteme**
  - **Dynamische Generierung aus Datenbanken heraus: kommerzielle (Zusatz-)Produkte von DBMS-Anbietern**
  - **Serverseitige Erweiterung durch ASP, PHP, ColdFusion, Java-Servlets, JSP, Webobjects**
- **die fortlaufenden Ergänzungen der Sprache durch die von Herstellern bereitgestellten Tools und Elemente führen leicht ins Web-Chaos**

Nachteile von HTML

- **HTML besteht aus ca. 70 Elementtypen für die Basisstruktur von Texten und Anweisungen für Stilarten**
- **HTML ist nicht erweiterbar – die Implementierung eigener Markup-Elemente ist erwünscht, ohne dabei wiederum auf die Implementierung in den Browsern angewiesen zu sein**
- **HTML ist darstellungsorientiert – sie bietet zahlreiche Sprachelemente besonders für die Präsentation der Dokumente**
- **HTML ist weniger wiederverwendbar und nicht geeignet, für Dokumente, deren Inhalte sich ändern, deren Form aber gleich bleibt; Konvertierungen aus den Textverarbeitungssystemen müssen so immer wieder aufs Neue geschehen**
- **HTML zeigt die Daten nur in einer Weise – eine unterschiedliche Sichtweise der Daten in Abhängigkeit der Anforderungen seitens der Benutzer ist kaum möglich**
- **HTML bietet kaum semantische strukturelle Information – sie zeigt, wie die Information dargestellt werden soll aber nicht was sie enthält, daraus resultieren auch die Probleme der Suchmaschinen, die richtige Information zu finden**

Text-Dokumente

- **Seit der Einführung des WYSIWYG und DTP (ca. 1984) orientiert man sich bei der Texterstellung eher am Layout**
- **Dokument besteht aus**
  - **dem Inhalt = dem eigentlichen Text**
  - **der visuellen Darstellung = der Formatierung**
  - **der möglichst maschinenlesbaren logischen Struktur**
- **Ausrichtung nicht auf die Anweisung bzgl. der Formatierung (procedural markup), sondern auf die logische Struktur (generic markup bzw. generic coding)**
  - **W. Tunnicliffe (1967) und Ch. Goldfarb (1969)**
  - **Goldfarb, Mosher und Lorie entwickelten ende der 60er Jahre bei IBM die Generalized Markup Language (GML)**
  - **SGML als ISO Standard 1986**

SGML

- Die verfügbaren Pseudo-Standards: ASCII, RTF (Microsoft), PostScript, Adobe PDF
- SGML ist ein internationaler Standard (ISO 8879:1986) für elektronischen Dokumentenaustausch
- Strikte Trennung von Struktur und Formatierung von Dokumenten
- SGML ist eine Metasprache zur Beschreibung von Dokumentstrukturen und Dokumenttypen
- Sprachen, die mit SGML erstellt werden, nennt man Applikationen
  HTML ist so eine Applikation von SGML: eine kleine Menge von Elementen, ursprünglich ausgelegt für die Dokumente der Physiker am CERN – später für Web-Dokumente allgemein
- Für den Einsatz im World Wide Web ist SGML allerdings viel zu komplex

Hypertext

- Erste Gedanken dazu von Vannevar Bush in seinem Artikel „As we may think“ (1945)
- Ted Nelson prägte in seinen Veröffentlichungen zu diesem Thema die Begriffe **Hypertext** und **Hypermedia** (1965)
- 1989 legte Tim Berners-Lee den Grundstein zur Entwicklung des World Wide Webs
- Zusammenführung der Konzeptionen des Hypertextes mit strukturorientierten Texten auf der Basis von SGML

Geschichte von XML

- **Sommer 1996 gründet Jon Bosak (*SUN Microsystems*) ein Team zur Entwicklung einer webfähigen SGML-Version**
  - **Diese XML Arbeitsgruppe stand unter der Schirmherrschaft der W3C (Dan Connolly)**
- **November 1996 war das Grundgerüst von XML fertiggestellt**
- **März 1997 entstand Bosaks Aufsatz: „XML, Java and the Future of the Web“**
- **Dezember 1997 wurde das erste Proposal vorgelegt**
- **Februar 1998 entstand der erste Entwurf**

WWW-Konsortium (W3C)

http://www.w3c.org

- ca. 150 Mitglieder (Firmen)
- 3 Institute: MIT Lab for Computer Science (USA), INRIA (Frankreich), Keio University (Japan)
- ca. 30 hauptberufliche Angestellte
- Chairman ist Tim Berners-Lee
- Vermittlertätigkeit zwischen den Mitgliedern
- Erstellung von Empfehlungen
- Veranstalten von Treffen, Workshops und Organisation von Arbeitsgruppen
- WWW-Technologieförderung in den Bereichen
  - Benutzerschnittstellen (HTML, CSS, PNG, VRML, SVG)
  - Technologie und Gesellschaft (PICS, Sicherheit, Zahlungsverkehr, Protokoll-Erweiterungen)
  - WWW-Architektur (HTTP, Audio, Video)

Design-Ziele von XML

XML soll sich im Internet auf einfache Weise nutzen lassen

XML als SGML für das Web

- **Kompatibilität zu SGML – als eine leicht überschaubare Teilmenge ist sie somit eine Spezifikation für die Schaffung beliebig vieler Auszeichnungssprachen**
- **Programme, die XML-Dokumente verarbeiten, sollen einfach zu schreiben sein**
- **Unterstützung eines breiten Spektrums von Anwendungen**
- **XML-Dokumente sollen leicht lesbar und angemessen verständlich sein**
- **XML-Dokumente sollen leicht zu entwerfen sein**
- **Der Entwurf von XML soll formal und präzise sein**
  - **Die Knappheit innerhalb der XML-Auszeichnungselemente ist dabei von geringerer Bedeutung – der Schwerpunkt liegt hier mehr auf der Lesbarkeit durch Maschinen als der durch Menschen**
- **Leichter zu archivieren - Langzeitspeicherung**
- **Wiederverwendbarkeit für die unterschiedlichsten Zwecke**
- **Generierung der unterschiedlichsten Ausgabeformate von einer Quelle**

Weiterer Einsatz von XML

- **Nicht mehr nur beschränkt auf die Auszeichnung von Dokumenten**
- **XML generell als Mittel zum Informationsaustausch, für verteilte, entfernte Prozeduraufrufe (RPC, Remote Procedure Calls)**
- **RPC für Web Services:**
  - **mit dem vom W3C vorangetriebenen SOAP (Simple Object Access Protocol) werden Informationen über HTTP als Transport-Protokoll auf festgelegte Weise ausgetauscht bzw. auf auf darin enthaltenen Daten reagiert**
  - **Die in XML kodierten Daten erlauben den Verzicht auf binäre Protokolle und sind damit verträglich für Firewalls (Port 80), durch SSL verschlüsselbar und mittels Web-Server-Farmen und Load-Balancing skalierbar**
  - **Web Services ermöglichen automatisierte Interaktionen zwischen Applikationen im Web**
  - **Auch bei Microsofts .NET-Strategie zum Aufbau einer Web-fähigen, integrierten Unternehmenskommunikation spielt XML die tragende Rolle**

Extensible Markup Language

- **XML steht für EXtensible Markup Language**
- **Extensible:**
  - **im Gegensatz zu HTML ist man nicht auf ein vereinbartes *Tagset* festgelegt, sondern es lassen sich eigene Sprachelemente kreieren**
    - **als eine Metasprache lassen sich mit XML sogar beliebig viele Auszeichnungssprachen generieren**
    - **so besteht die Möglichkeit zum Design von spezifischen Sprachen für spezielle Wissenschaftsbereiche oder Anwendungsgebiete**
  - **Ziel ist dabei jedoch, dass sie Aussagekraft bzgl. des Inhaltes haben `<kursthemen>`, `<kursort>`, ...**
  - **Die Schöpfung neuer Tags erfordert somit ein gründliches Verständnis des Dokumentinhaltes**
- **Keine Begrenzung der Namensräume (Namespace) und in der strukturellen Komplexität**

Extensible Markup Language

Markup:

- **Texte werden ausgezeichnet (Markup), um Teilen von ihnen eine Bedeutung zu geben**
  = Auszeichnung eines Textes durch Anweisungen
- **Nur so werden Texte für Maschinen „lesbar“**
  ohne diese Auszeichnung würde der Computer einen Text als eine lange Zeichenkette begreifen
- **Procedural Markup: Auszeichnung eines Textes mit Formatanweisungen für die optische Aufbereitung**
  - **Formatanweisungen der Text(satz)systeme wie Troff und TeX/LaTeX**
- **Generalized Markup: Abheben auf die Dokumentenstruktur und das Ziel, die Strukturanweisungen zu formalisieren**
  - **SGML, XML**
- **Über die Auszeichnungselemente erhalten die Textteile eine Bedeutung im Zusammenhang des Dokumentes (Semantik)**

Extensible Markup Language

- Sprachen dienen i. allg. dazu, etwas zu beschreiben
- Bei einer Sprache wie XML hat man es mit einem festen Umfang von Regeln zu tun
- Auch wenn die Sprachelemente frei definierbar sind, muss doch die Syntax und Struktur klar und eindeutig festgelegt sein
- Die Struktur wird definiert durch die Beziehungen, die jedes Element mit den anderen hat
- Die Bedeutung der Elemente ist deutlich getrennt von der visuellen Erscheinung
- Die Dokumentstruktur wird auch als Baumstruktur interpretiert
- Struktur und Formatierung ist deutlich zu trennen
  Beispiel:
  - Struktur: dies ist eine Überschrift
    Formatierung: setze den Text in 24pt Helvetica

Konzept von XML

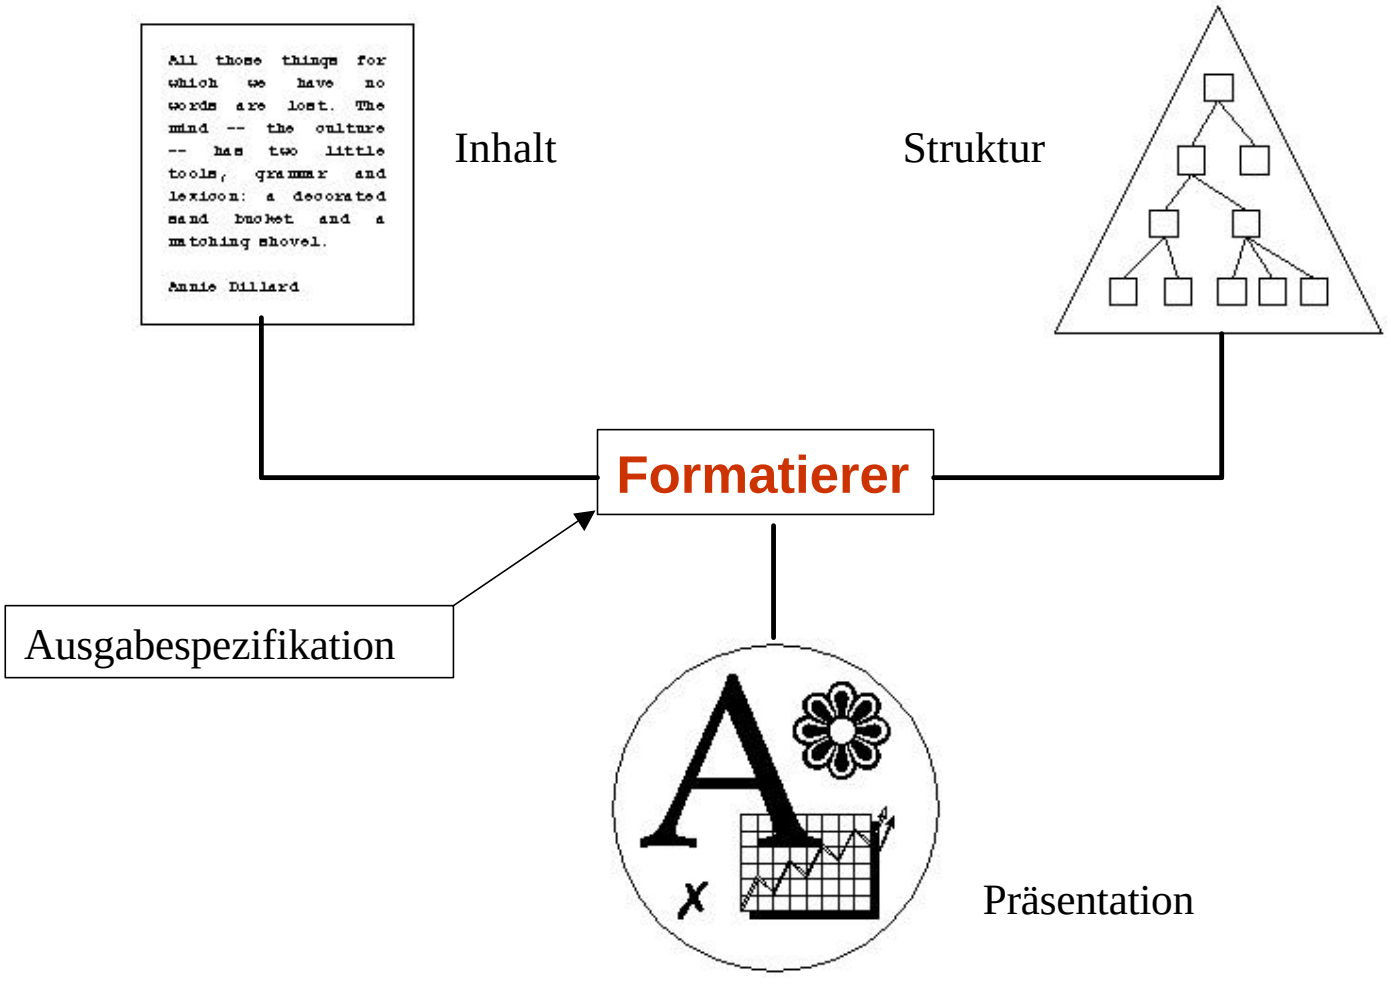

XML im Vergleich

Word	LaTeX	XML
Dokumentvorlage	Dokumentklasse *documentclass*	Dokumenttyp Definition DTD
Formatvorlagen	Befehle, Umgebungen	Elementtypen

Vorteile von XML

- **Basiert auf internationalen Standards**
  - **Internationalisierung durch Unicode-Unterstützung**
- **Keine Begrenzung durch ein beschränktes Tag-Arsenal**
- **Kontrollmöglichkeit der Gültigkeit der Dokument-Strukturen**
- **Automatische Generierung von Navigation und Datenstrukturen**
- **Bessere Langzeit-Archivierung**
- **Leichte Wiederverwendung von Dokumenten: Formatierung auf verschiedene Ausgabemedien hin bei ein und derselben Datenquelle**
  - **ermöglicht so benutzerspezifische Betrachtungsweisen**
- **Leichtere Pflege größerer Web-Sites**
- **Neu: dient zum Aufbau von verteilten Web-Services**

XML beschreibt nicht, wie eine Seite aussieht und was sie tut (Aktion), sondern was jedes Wort im Text bedeutet (Semantik)

XML-Dateien im Web

- XML wird HTML bei kleineren Projekten (eigene Homepages, etc.) nicht verdrängen
- XML bietet sich im besonderen Maße zur Strukturierung größerer Web-Sites an
- Damit ergibt sich die Anforderung, XML-Dokumente visualisieren zu können – zwei Verfahren:
- Clientseitig: die Darstellung übernimmt ein XML-fähiger Browser
  - Über Processing Instructions wird festgelegt, welche Stylesheets zur Anwendung kommen (CSS oder XSL)
- Serverseitig: Programme auf dem WWW-Server übernehmen die Umwandlung der XML-Dateien in Abhängigkeit des verwendeten Browsers
  - Über Content Negotiation versucht der Server herauszufinden, was dem jeweiligen Browser genehm ist
  - Der Server liefert generell HTML aus

Einsatz von XML heute?

- **XML soll HTML nicht ersetzen sondern überall dort ergänzen, wo die semantische Bedeutung des Datenmaterials von Bedeutung ist**
  - **z. B. bei der Konvertierung, bei dem Einsatz von Datenbanken**
- **Durch die deutliche Trennung von Dokumentinhalt und deren Visualisierung benötigt XML allerdings Präsentationshilfen: CSS, XSL, DSSSL**
- **Wie reagieren die Hersteller?**
  - **Microsoft bietet XML-Unterstützung bereits im Internet Explorer 4 und deutlich verbessert im IE 6.0**
  - **Rudimentäre Unterstützung auch in Office 2000/2002**
  - **Netscape unterstützt XML erst in seiner neuen Layout-Engine „Gecko“ des Netscape 6.1 bzw. Mozilla**
  - **Unterstützung auch in WordPerfect 2000, Adobe FrameMaker 5.5.6/6.0,**
  - **KDE KOffice, GNOME-Office: Abiword, StarOffice 6.0 verwenden XML bereits als internes Datenformat**

XML Dokument

- **Eine XML-Datei besteht aus ASCII-Text**
  - **Je nach Encoding-Anweisung im Prolog sind auch Sonderzeichen erlaubt**
- **Es setzt sich zusammen aus einem Prolog**
  - **Deklaration,**
  - **Eine optionale Angabe des Dokumenttyps bzw. der DTD, die die Strukturanweisungen vorgibt**

  und den Elementen
  - **Der mit den vereinbarten Tags ausgezeichnete Inhalt**
- **Die Dateiextension ist .xml**
- **XML-Dokumente sind wohlgeformt, d. h. sie müssen regelkonform sein**
- **Sie können darüber hinaus als Instanz einer DTD auch noch gültig sein**

XML Dokument - Prolog

- **Der Prolog enthält die XML-Deklaration, die besagt, dass es sich hier um ein XML-Dokument handelt:**
  `<?xml version="1.0"?>` **sollte jedes XML-Dokument einleiten**
- **mögliche Angaben:**
  `<?xml version="1.0" standalone="yes" encoding="UTF-8"?>`
- **version: derzeit aktuell ist die Version 1.0 – für den Fall, dass mehrere Versionen existieren, wird diese Angabe an Bedeutung gewinnen**
  `<?xml version="1.0" standalone="yes" encoding="UTF-8"?>`
- **standalone: hiermit wird einem Programm mitgeteilt, dass es keine DTD gibt**
  `<?xml version="1.0" standalone="yes" encoding="UTF-8"?>`
- **encoding: die Art und Weise, wie Sonderzeichen und Umlaute im XML-Dokument kodiert werden – der Standard ist UTF-8**
  `<?xml version="1.0" encoding="UTF-8"?>`
  `<?xml version="1.0" encoding="ISO-8859-1"?>`
- **Optionale Angabe des Dokumenttyps:**
  `<!DOCTYPE hallo SYSTEM "test.dtd">`

XML Dokument – ein Beispiel

- **Beispiel eines wohlgeformten XML-Dokuments, das hier auch noch gültig ist gegenüber einer DTD (Slide.dtd) – d. h. es kann überprüft werden, ob die Struktur korrekt ist und die verwendeten Tags somit richtig gesetzt sind**

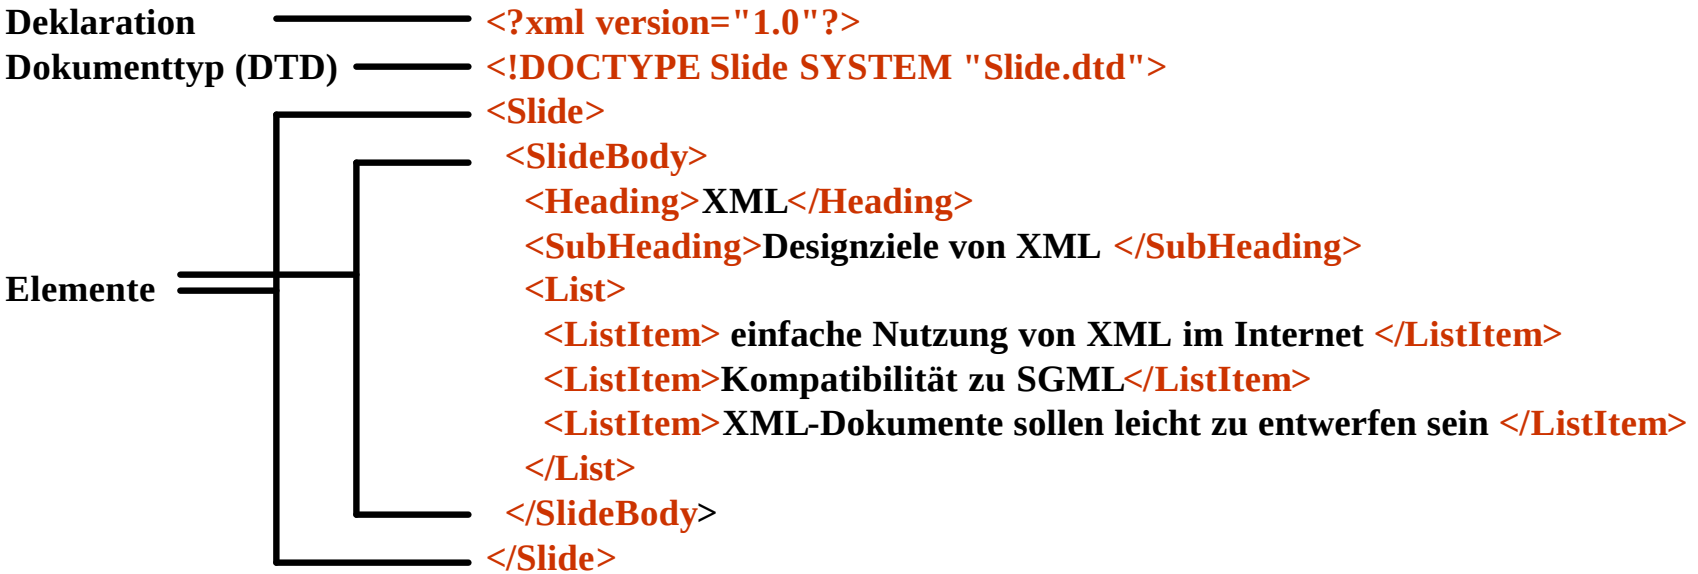

XML Dokument - Regeln

- **Element: sie sind die elementaren Konstrukte in XML-Dokumenten**
  - **Elemente werden durch die umgebenden *Tags* gekennzeichnet**
    ```
    <author>Arno Amoebe</author>
    ```
  - **Wie in HTML/SGML werden auch hier die Elemente (*Tags*) in Spitzklammern gesetzt**
    ```
    <list>
    ```
- **Attribut: ermöglicht eine nähere Beschreibung der Elemente**
  - **Attribute setzen sich aus einem Namen und einem Wert zusammen**
    ```
    <author kap="4">Arno Amoebe</author>
    ```
  - **jedes Attribut darf pro Element nur einmal vergeben werden**
- **Attributwert:**
  - **Attributnamen und Werte werden durch Gleichheitszeichen verbunden und die Werte müssen in Anführungszeichen stehen**
    ```
    <author kap="4">Arno Amoebe</author>
    ```

XML Dokument – Regeln (2)

- **im Gegensatz zu HTML und das ihm zugrundeliegende SGML ist auf die Groß- und Kleinschreibung zu achten**

  `<author>` **ist nicht gleich** `<Author>`

- **Alle Tags müssen geschlossen werden - XML-Befehle sind somit stets Umgebungsbefehle**

  `<author> ...Text... </author>`

  - **Hier kann also nicht auf die „Gutmütigkeit“ der Browser vertraut werden**

- **auch „leere“ Tags, die keine wirkliche Umgebung spezifizieren, müssen geschlossen sein**

```
<img src="mr.gif" />
<br />
```

- **Die Elemente müssen korrekt ineinander verschachtelt sein.**
  Wird ein *Tag* innerhalb eines anderen geöffnet, muss er auch vor dem Ende der ihn umschließenden Umgebung geschlossen werden

```
<liste> das ist der <wichtig>Aspekt</wichtig></liste>
   1                    2                 2       1
```

XML Dokument – Regeln (3)

- **Kommentare werden wie in HTML gesetzt**
  `<!-- dies ist ein Kommentar -->`
  innerhalb der Kommentare dürfen die Zeichen `--` nicht auftreten
- **Ein XML-Dokument muss mindestens ein Element enthalten**
- **Es darf allerdings nur ein Wurzel-Element geben**
- **Erlaubte Zeichen für Element- und Attributnamen sind:**
  a - z, A – Z, 0 -9, -, _, : und Punkte innerhalb einer Zeichenkette
- **Elementnamen dürfen nicht mit dem reservierten Wort "xml" oder "XML" beginnen**
- **XML-Dokumente sollten stets mit einer XML-Deklaration beginnen**

XML Dokument – Entities

- **Der von XML verwendete Zeichensatz (ISO/IEC 10646) deckt im allgemeinen den westeuropäische Zeichenvorrat ab (ISO latin 1)**
- **Zeichenreferenz für Zeichen, die in XML eine besondere Bedeutung haben (Maskierung)**
  - `&` **&** **(ampersand)**
    `<` **<** **(less than)**
    `>` **>** **(greater than)**
    `&apos;` **'** **(apostrophe)**
    `&quot;` **"** **(quotation mark)**
- **oder solche, die über die Tastatur nur schwer einzugeben sind**
  - `&#`***Zahl***`;` **bzw.** `&#x`***Hexzahl***`;`
    `&#187;` **für »**
    `&#171;` **für «**

XML Dokument – weitere Regeln

- **Definitionen eigener Entity-Referenzen für eine abkürzende Schreibweise, auf die man sich später beziehen kann (s. a. bei DTDs)**

```
<?xml version="1.0"?>
<!DOCTYPE buch system "buch.dtd" [ <!ENTITY kurs "Kurs: WWW
für Fortgeschrittene" ]>
```

  Verwendung dann im XML-Dokument:

```
<absatz>Im &kurs; wird folgendes zur Sprache kommen
...</absatz>
```

- **Processing Instruction (PI) erlauben Anweisungen für die Verarbeitung von XML-Dateien und werden in <? ?> eingeschlossen**

```
<?xml version="1.0"?>
<?xml-stylesheet href="test.xsl" type="text/xsl"?>
```

- **für wörtlich übernommenen Text eignet sich die CDATA-Anweisung (Character Data)**

```
<![CDATA[<absatz>das ist ein XML-</absatz>]]>
```

Wohlgeformtheit (*wellformed*)

- **Jedes XML-Dokument muss wohlgeformt (well-formed) sein, d. h. es muss den folgenden Regeln genügen**
  - **Unterscheidung von Groß-/Kleinschreibung**
  - **Jeder Start-*Tag* muss auch einen korrespondierenden Ende-*Tag* haben**
  - **„Leere“*Tags* werden durch einen Schrägstrich <br /> abgeschlossen**
  - **Die Elemente müssen korrekt ineinander verschachtelt werden**
  - **Die Attributwerte müssen in Anführungszeichen gesetzt werden**
  - **Sind die Zeichen <, >, " gemeint, dann müssen die dafür bereitgestellten Entitäten (`<`, `>`, `&quot;`) verwendet werden**
  - **Es darf nur ein Wurzelelement geben**
- **Damit erst ist ein XML-Dokument – im Gegensatz zu HTML - auch für Maschinen/Programme - den sog. Parser - überprüfbar**

Gültigkeit

- **Soll das Dokument darüber hinaus auch noch gültig sein, überprüft der Parser, ob die Struktur und die Anzahl der Tags gemäß einer Strukturanweisung korrekt und sinnvoll eingesetzt wurden**
- **Diese Anweisungen liefert die optionale DTD (Document Type Definition)**
- **Die DTD bestimmt das Regelwerk, die Grammatik für eine bestimmte in XML verfasste Auszeichnungssprache**
- **Der durch die DTD festgelegte Dokumenttyp bestimmt, welche Elementtypen mit welchen Attributen in welcher Verschachtelung verwendet werden dürfen**
- **XML stellt als Metasprache somit die Anleitungen zum Verfassen von DTDs zur Verfügung**

Parser

- **Parser sind Programme, die ein XML-Dokument einlesen und auf Wohlgeformtheit überprüfen; bei nicht wohlgeformten Dokumenten wird eine entsprechende Fehlermeldung ausgegeben**
- **Es gibt validierende und nicht-validierende Parser, je nachdem ob sie auch auf Gültigkeit prüfen**
- **nicht-validierende Parser müssen aber immer noch Verletzungen bzgl. der Wohlgeformtheitsbeschränkung vermelden**
- **Validierende Parser vermelden Verletzungen der Beschränkungen, die durch die Deklarationen in der DTD formuliert werden, sowie jedes Nicht-Erfüllen der in dieser Spezifikation formulierten Gültigkeitsbeschränkung**
  - **Dazu müssen sie die gesamte DTD und natürlich auch alle extern deklarierten Entitäten, auf die im Dokument verwiesen wird, einlesen und verarbeiten**

Parser (2)

- **Grundlage aller Parser sind die SAX-APIs von Megginson**
  „SAX“ steht für Simple API for XML
- **Expat von James Clark**
  http://www.jclark.com/xml/expat.html
  - **Ein nicht-validierender nur auf Wohlgeformtheit prüfender Parser**
  - **Wird in vielen Programmen eingesetzt, u. a. in Mozilla, PHP4**
  - **Aufruf: xmlwf (Unix) bzw. xmlwf.exe (Windows)**
- **Java Project X von SUN Microsystems**
  http://java.sun.com/xml
  - **Komplett in Java geschriebene XML-Bibliothek, basiert auf SAX**
  - **Sie unterstützt die Prüfung auf Wohlgeformtheit, der Gültigkeit gegen eine DTD und bietet diverse Manipulationsmöglichkeiten bzgl. der XML-Struktur (z. B. Visualisierung)**
  - **Bestandteil des Java JDK 1.3**

Parser (3)

MSXML von Microsoft

http://msdn.microsoft.com/xml

- **Leistungsfähiger im Internet Explorer integrierter XML-Parser**
  - **MSXML 2.0 wird mit dem Internet Explorer 5.0 ausgeliefert**
  - **MSXML 2.5 kommt mit Windows 2000**
- **MSXML 3.0 integriert im Internet Explorer 6.0 und in Windows XP**
  - **Unterstützt u. a. XSLT 1.0**
- **Installation des Updates**
  - **Download und Aufruf der Datei msxmlwr.exe**
  - **Zum Update der XML-Engine xmlinst.exe aufrufen (**unter win9x in \windows\system, unter NT in \winnt\system32**), damit msxml3.dll Version 8.0.7820.0 zum Standard-Parser im IE wird**
  - **iexmltls.exe dient zur erweiterten Darstellung des Parsers (zusätzliches Kontextmenü) im Internet Explorer**

Parser (4)

SP 1.3.4 *von James Clark*
http://www.jclark.com/sp

- **nsgmls (wird auch von PSGML verwendet) parst und validiert SGML - und XML-Dokumente**
  - **Nur textbasiert! - Für UNIX und Win32 verfügbar**
- **Optionen:**
  - **-w*Typ*: kontrolliert die Warnungen und Fehlermeldungen**
  - **-wxml: informiert darüber, dass es sich um eine XML-Instanz handelt ausgelegt auf die XML-spezifischen Warnungen vor Konstruktionen, die in XML nicht erlaubt sind**
  - **-s: unterdrückt die Ausgabe, Fehlermeldungen sind davon aber nicht betroffen**
  - **-c *Katalog*: Angabe einer Katalogdatei, im Falle von XML enthält sie nur den Verweis auf die entsprechenden Deklarationen**
    xml.soc mit dem Inhalt: SGMLDECL "xml.dcl"

Parser (5)

- **XML4J - XML for Java Parser v2.0/3.0 von IBM,**
- **Jetzt als Xerces im Apache-Projekt**
  http://xml.apache.org
- **Modularer in Java geschriebener Parser**
- **Validiert, generiert und manipuliert XML-Daten**
- **Unterstützt die SAX-API**
- **Dient als Grundlage für viele Applikationen wie auch Editoren**
- **Prüfen auf Wellformness:**
  xml4j.bat *Datei*
  Prüfen auf Gültigkeit:
  xml4jv.bat *Datei*

XML-Browser: Mozilla

- Netscape‘s neue Layout-Engine „Gecko“ im Netscape 6.1/Mozilla
  www.mozilla.org
- Netscape 6.1 entspricht Mozilla 0.9.2.1
- Die neueste Version Gecko/20011011 wird mit Mozilla 0.95 geliefert
- Mit Hilfe von Erweiterungen, sog. xpi-Dateien, lässt sich Mozilla zum Funktionsumfang von Netscape 6 hochrüsten
- Unterstützung von
  - HTML 4
    abwärtskompatibel
    zu Communicator 4
  - CSS1 und CSS2
  - XML 1.0 standardmäßig
    über CSS 1/2
  - Parser: Expat v. J. Clark
  - XSLT über TransforMiiX

XML-Browser: MS Internet Explorer

- **Microsofts Internet Explorer 6.0 (`6.0.2600.0000`)**
- **Unterstützt**
  - **HTML 4 und proprietäre Erweiterungen**
  - **CSS1 und CSS2**
  - **XML 1.0 über CSS und XSL**
  - **XSL/XSLT 1.0**
  - **Parser: MS-eigener Msxml 3.0**
  - **Update auf Msxml 3.0 SP1**

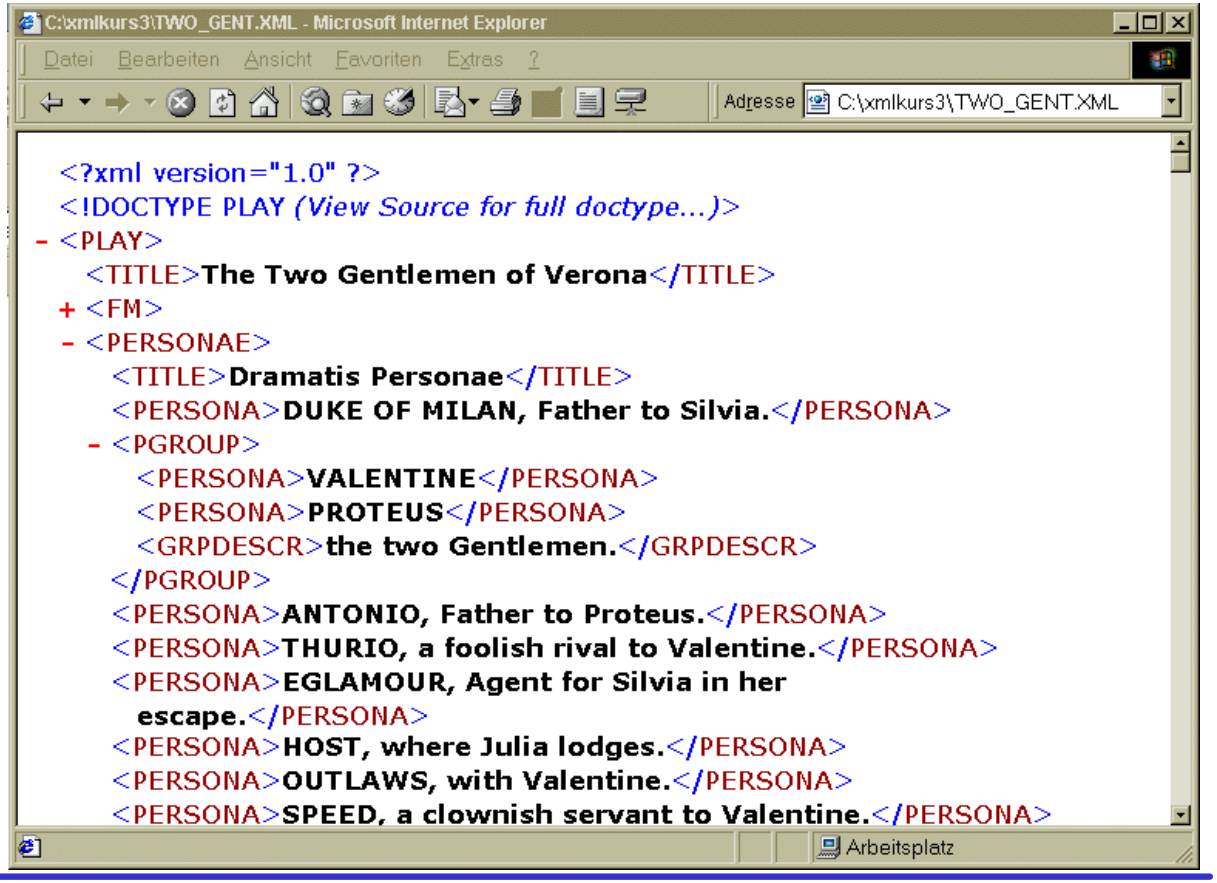

XML-Browser: Opera

- **Opera 5.12 avanciert zum dritthäufigsten Browser**
- **Shareware - seit der Version 5 mit Werbebanner frei verfügbar**
- **Linux-Version, MAC-Version derzeit im Beta-Test**
- **Unterstützt CSS1, CSS2, XML, WML**
- **Darstellung von XML über CSS1 und CSS2**
  - **Interessanter XML-Präsentationsmodus: Operashow**
- **Expat-Parser**

XML-Editoren

- **PSGML 1.2.2 *v. Lennart Staflin***
- **GNU Emacs ab 20.3 und Xemacs ab 19.9**
- **Kostenfrei**
- **Für Win32, Unix**
- **Integriert den Parser SP von J. Clark**
- **Separater DTD-Mode: TDTD 0.7.1 *v. Tony Graham***
- **Separater XSL-Mode xslide 0.1.2 *v. Tony Graham***

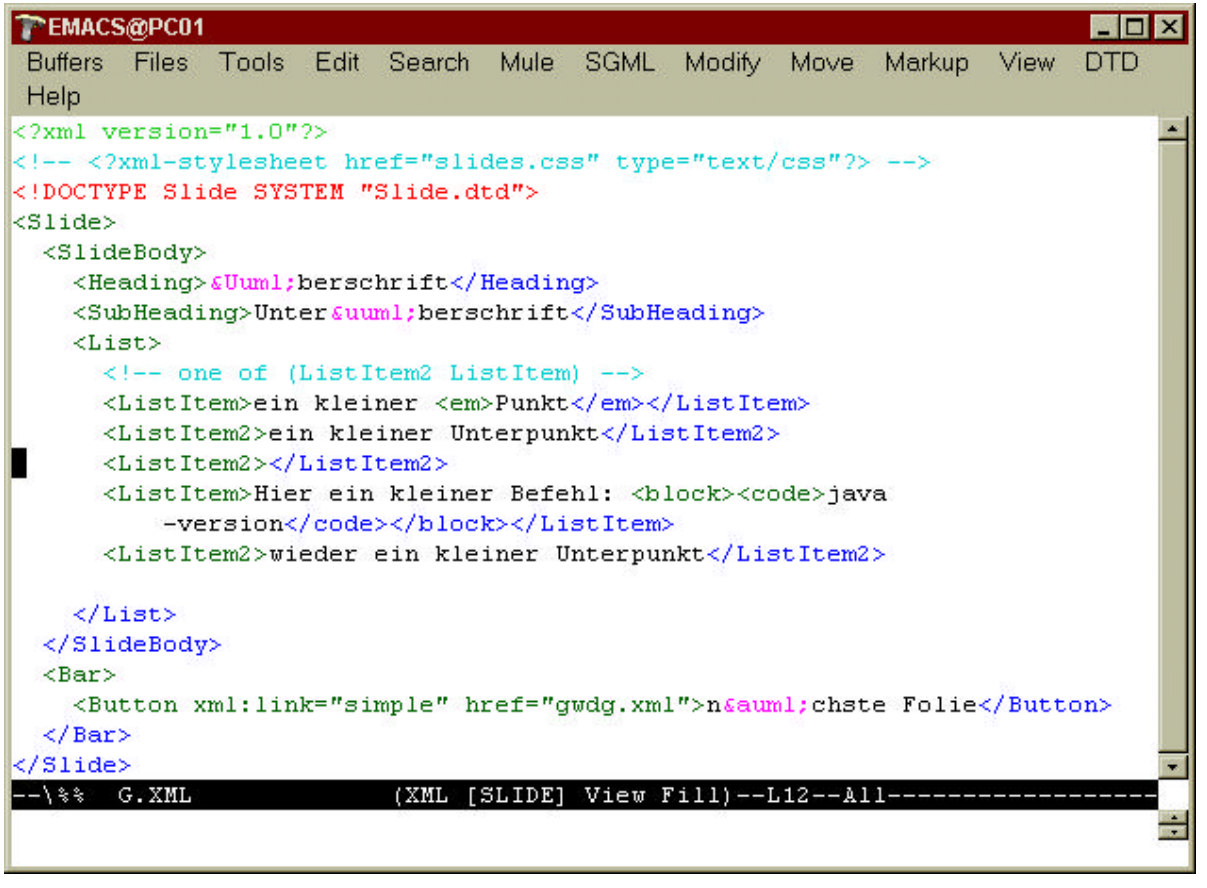

Emacs als XML-IDE

- **PSGML-Mode 1.2.2 von Lennart Staflin**
  http://sourceforge.net/projects/psgml
- **XSLT-process 2.1 von Ovidiu Predescu**
  http://sourceforge.net/projects/xslt-process/
  - **Bietet eine Entwicklungsumgebung mit integriertem XSLT-Formatierer (Xalan) und Debugger auf Basis von Java**
  - **Ausgabe nach HTML und PDF**
  - **Ausrichtung auf die DocBook-DTD**
- **XAE – Authoring Environment for Emacs von Paul Kinnucan**
  http://sunsite.dk/jde/xae/
  - **Bietet ebenfalls eine Entwicklungsumgebung auf Java-Basis**
  - **Dokumentenerstellung derzeit noch auf DocBook-Basis**
  - **Umwandlung nach HTML über XSLT (Saxon-Enging)**

EXML

- **Exml 1.2 *v. CUESoft***
- **Zeigt sowohl die hierarchische Struktur als auch den XML-Quellcode**
- **Frei verfügbar**
- **Klein und handlich**

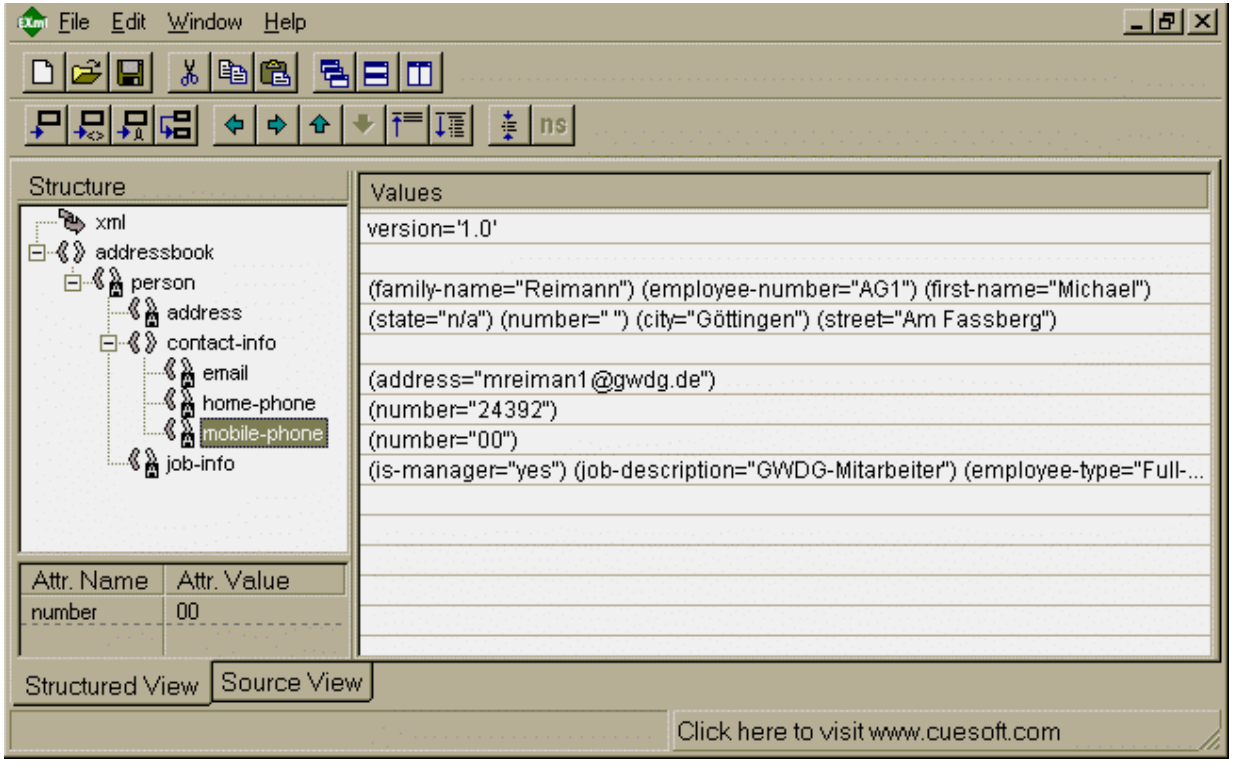

Kxmleditor

- **Kxmleditor 0.7 *v. Lumir Vanek***
- **KDE2 Linux**
- **SAX2-Parser**
- **Unterstützt die Kpart-Technologie**
- **Liest KOffice-Dateien**
- **Integration mit dem Konqueror**

kxmleditor.sourceforge.net/

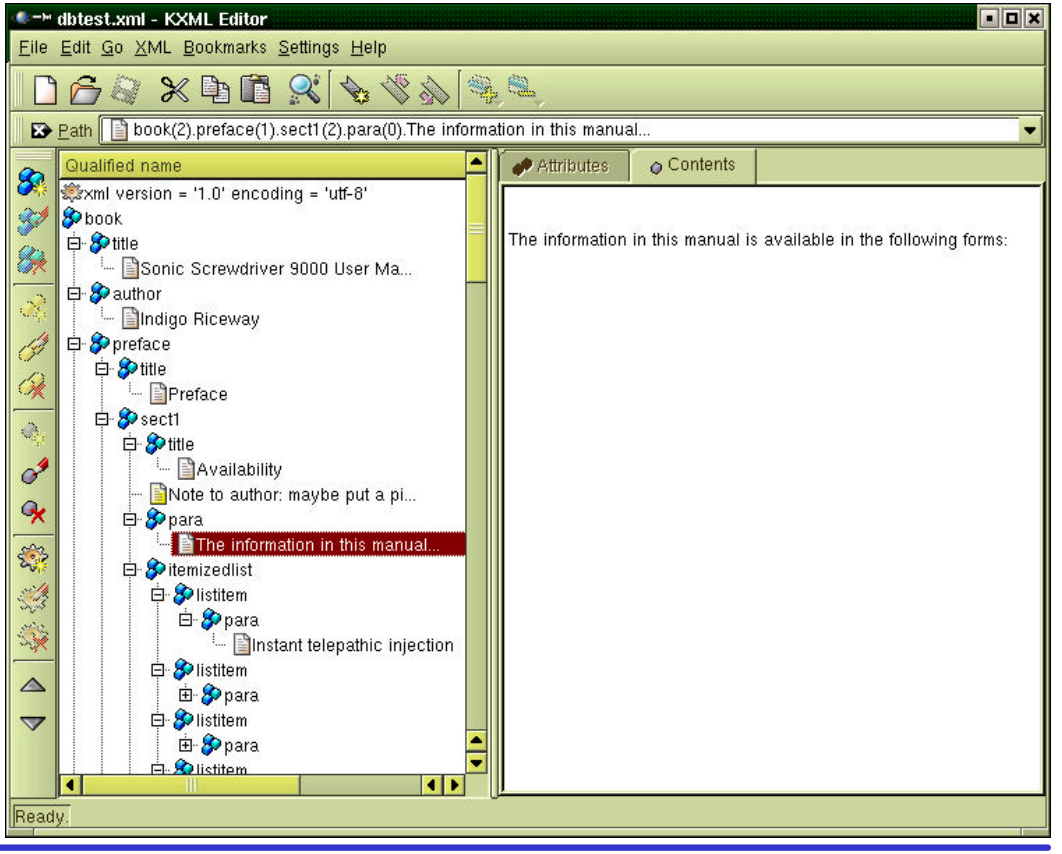

Weitere Editoren

- **XML Notepad 1.5 von Microsoft**
  - **Kostenfreier Editor, wird nicht mehr weiterentwickelt**

Kommerzielle Editoren

- **XMetaL 2.1 v. SoftQuad**
- **XMLSpy 4.0.1 v. Altova (the XML Spy Company)**
- **Adobe FrameMaker 6.0**
  - **unterstützt XML durch CSS und XSL über Zusatzprodukt WebWorks-Publisher (Standard)**
  - **Verfügbar unter Win32, MAC, UNIX (Solaris, etc., nicht Linux)**
- **Corel WordPerfect 2000**
  - **Windows und Linux**
- **SUN StarOffice 6.0 / baugleich mit OpenOffice**
  - **Dateiformat XML im gepackten ZIP-Format**
- **MS Office 2000/2002 – über die Funktion „*Als Webseite speichern...*“**
- **AbiWord 0.9.2 (Linux und Windows), KOffice 1.1 (Linux)**

WAP/WML

- Das Wireless Application Protocol (WAP) ermöglicht das Abrufen von Informationen aus dem Internet über ein mobiles Devices, z. B. Handy, PDA, etc.
- derzeit über das GSM-Netz (Global System of Mobile Communication)
- Bestandteil dieses Protokolls ist die auf XML aufbauende Sprache WML (Wireless Markup Language), die die Möglichkeit zur Darstellung von Text und Grafik liefert, und die dazugehörige Scriptsprache WMLScript
- die WML-Spezifikation (derzeit 1.1) definiert lediglich die Syntax sog. WML-Dokumente, die Darstellung bleibt den Micro-Browsern in den Handys überlassen
- In Anbetracht der geringen Größe der Displays (z. B. Nokia 7110 mit 96x65 Pixel, ca. 4-6 Textzeilen) sollte sowohl Umfang als auch Erscheinungsbild entsprechend angepasst werden
- brauchbare WAP-Handys: z. B. Nokia 7110, 6210, Siemens S35i
- Die non-profit Organisation WAP-Forum sorgt für die Standardisierung http://www.wapforum.com
- Testumgebung: Nokia WAP Toolkit 1.2 http://www.forum.nokia.com/developers/wap/wap.html
- Phone.com Software Developer's Kit (UP.SDK) http://www.phone.com/developers/index.html
- WAP-Funktionalität auch im Web-Browser Opera 5.02

XML-Dokument als gültige Instanz

- **DTD innerhalb des Dokumentes**

```
<?xml version="1.0"?>
<!DOCTYPE hallo [
<!ELEMENT hallo (#PCDATA)>
<!-- intern --> ]>
<hallo>Hallo Kurs!</hallo>
```

- **Dokument und DTD getrennt**
  - **DTD (*hallo.dtd*)**

```
<!ELEMENT hallo (#PCDATA)>
```

  - **XML-Dokument als Instanz**

```
<?xml version="1.0"?>
<!DOCTYPE hallo SYSTEM "hallo.dtd">
<!-- extern -->
<hallo>Hallo Kurs!</hallo>
```

DTD (1)

- **Eine DTD ist eine Ansammlung von Regeln, die festlegen,**
  - **Welche *Elemente* in einem Dokument verwendet werden dürfen, welche *Inhalte* sie haben und wie sie sich aufeinander beziehen (Baumstruktur),**
  - **Welche *Attribute* für ein Element erlaubt sind und welche *Werte* sie annehmen dürfen**
- **Eine DTD beschreibt die Struktur eines Schriftstücks und aller gleich aufgebauten Schriftstücke**
- **DTD steht für Document Type Definition und darf nicht verwechselt werden mit der Dokumenttyp Deklaration zu Beginn einer XML-Instanz**
- **In Verbindung mit Parsern und XML-Editoren erlaubt es eine DTD zu kontrollieren, ob Autoren sich an die strukturellen Vorgaben eines Texttyps, z.B. eines Artikels für eine Zeitschrift, halten. Sie wirkt unterstützend und normierend**
- **Eine DTD ist zu einem XML-Dokument nicht zwingend notwendig.**

DTD (2)

- **Soll ein XML-Dokument gültig sein, dann wird es gegen seine Strukturanweisungen (DTD) geprüft, d. h., es wird nicht nur getestet, ob es regelkonform ist, sondern ob auch alle Tags richtig gesetzt sind.**
- **Wann braucht man eine DTD?**
  - **Das Dokument ist Teil einer größeren Dokumentsammlung, die alle die gleiche Struktur haben sollen**
  - **Es soll maschinell überprüft werden können, ob eine bestimmte Anzahl von Daten aufgeführt ist**
  - **Es soll generell maschinell verarbeitbar sein, so daß es mit anderen Dokumenten verglichen und einheitlich in andere Datenformate (z. B. Datenbanken) umgesetzt werden kann**

DTD (3)

- **Bevor eine DTD erstellt wird, sollte zuerst eruiert werden, ob es nicht schon eine solche oder ähnliche gibt**
  - **Docbook-DTD von Oasis, oft für technisch-wissenschaftliche Texte eingesetzt, wurde von Norm Walsh nach XML konvertiert und mit Stylesheets versehen**
  - **Eine auf XML basierende HTML-Version: XHTML**
- **Eine selbsterstellte DTD muss nicht notwendig umfangreich werden**
- **Für komplexe Dokumentationen kann das Design einer optimalen DTD eine längere Zeit in Anspruch nehmen**
- **Interne DTD: üblicherweise werden die DTDs in separaten Dateien (mit der Endung .dtd) angelegt**
  sofern die Anweisungen im XML-Dokument selber stehen, spricht man von einer internen DTD

DTD (4)

- **Die Elementtyp-Deklaration definiert ein Element durch einen Namen und den ihm zugewiesenen Inhalt**
  `<!ELEMENT` name *Inhalt* `>`
- **Aus dem Namen, den spitzen Klammern und dem Schrägstrich werden dann Start-Tag `<name>` und End-Tag `</name>` gebildet, die im XML-Dokument das Element eingrenzen.**

- **Einige Beispiele**

```
<!ELEMENT adresse ((firma | person), strasse, ort)>
<!ELEMENT firma (firmenname)>
<!ELEMENT person (anrede?, vorname, nachname)>
<!ELEMENT adressbuch (adresse)+>
```

DTD (5)

- **Die *Namen* (von Elementen oder Attributen) können mit einem Buchstaben oder dem Unterstrich beginnen**
- **Auch ein Doppelpunkt ist am Anfang möglich; doch sollten Doppelpunkte nur im Zusammenhang mit Namespaces verwendet werden**
- **Als weitere Zeichen sind außer Buchstaben und Unterstrich noch Ziffern, der Punkt und der Bindestrich erlaubt**
- **Ein Unterschied zwischen Groß- und Kleinschreibung erzeugt unterschiedliche Namen**
- **Der im Zusammenhang mit Attributwerten verwendete Datentyp NMTOKEN ist ähnlich eingeschränkt wie ein Name**

DTD (6)

- Das *Inhaltsmodell* gibt an, welche untergeordneten Elemente in einem Element in welcher Kombination erlaubt sind
- `<!ELEMENT eintrag (lemma, wa, bd )>`
  Alle Elemente, die durch das Komma als Sequenz-Operator verbunden sind, müssen vorkommen, und zwar in der Reihenfolge, in der die entsprechenden Namen auftreten
  `<!ELEMENT lemma (#PCDATA)>`
  Der Inhalt besteht nur aus Zeichen(ketten): Parsed Character Data
- `<!ELEMENT bd (txt, wa?)>`
  Das Fragezeichen (?) signalisiert Optionalität, das betreffende Element kann fehlen
- `<!ELEMENT wb (eintrag)+ >`
  Das Pluszeichen (+) besagt: das voranstehende Element muss einmal, kann mehrfach vorkommen

DTD (7)

- `<!ELEMENT eintrag (wort,Idiom*) >`
  Der Stern-Operator (*) erlaubt, dass das vorangehende Element sowohl fehlen als auch mehrfach vorkommen darf
- `<!ELEMENT head (access | meta) >`
  Hier wird der ODER-Operator (|) verwendet: Nur eines der beiden Elemente darf benutzt werden
- `<!ELEMENT head (access | meta)+ >`
  Der ODER-Operator (|) in Kombination mit +: Eines der beiden Elemente muss auftreten, ansonsten können beide Elemente beliebig oft und in beliebiger Reihenfolge vorkommen
- `<!ELEMENT idiomA ( (txt,lmref,txt?) | (lmref,txt) )>`
  Treten sowohl Sequenz- als auch ODER-Operator in einem Inhaltsmodell auf, müssen ihre Gültigkeitsbereiche durch Klammern abgegrenzt werden

DTD (8)

- **Kombinierte Inhaltsmodelle i. e. S. enthalten sowohl PCDATA als auch Elementnamen.**
- `<!ELEMENT absatz (#PCDATA | em | foreign)* >`
  Bei der Mischung von Text und weiteren Elementen soll #PCDATA am Anfang stehen. Reihenfolgebeziehungen können nicht festgelegt werden. Es ist nur die Operatorkombination wie im Beispiel erlaubt
- `<!ELEMENT hr EMPTY >`
  EMPTY deklariert ein leeres Element, wie etwa der hr in HTML
- `<!ELEMENT alles-in-einem ANY >`
  ANY erlaubt gemischte Inhalte mit *jedem beliebigen* Element, das in der DTD deklariert ist.

DTD (9)

- welche DTD dem jeweiligen XML-Dokument zugrunde liegt, wird durch eine Document Type Declaration vermittelt
  ```
  <!DOCTYPE wb SYSTEM "/usr/global/sgml/diz5.dtd">
  ```
  Das Wurzelelement im Dokument ist <wb> und die Regeln befinden sich in der genannten Datei
- Document Type Declaration mit öffentlichem Bezeichner:
  ```
  <!DOCTYPE wml PUBLIC "-//WAPFORUM//DTD WML 1.1//EN"
  "/usr/global/sgml/wml_1_1.dtd">
  ```
- Document Type Declaration mit (partiell) interner DTD:
  ```
  <!DOCTYPE wb SYSTEM "diz2.dtd"[
  <!ELEMENT bedeutet      (kontext?, bd+)>
  <!ATTLIST bedeutet seq NMTOKEN #IMPLIED>
  <!ELEMENT eintrag       (lemma, wa, bedeutet+)>
  <!ELEMENT kontext       (#PCDATA)>  ]>
  ```
  Interne Definitionen haben Vorrang!

DTD (10)

- **Attribute von Elementen enthalten Informationen *zum* Text, die nicht *im* Text erscheinen**
- **Deklaration der Attributlisten:**
  hier wird festgelegt, welche Attribute für einen Elementtyp existieren, von welchem Typ die Attributwerte sind, und ob sie einen Vorgabe-Wert enthalten

```
<!ATTLIST img
     src    CDATA #REQUIRED
     alt    CDATA #REQUIRED
     height        CDATA #IMPLIED
     width  CDATA #IMPLIED >
```

- **Es gibt notwendige (required) und implizite (implied) Attribute. Bei den impliziten Attributen müssen die Werte nicht explizit angegeben werden. Alle vier Attribute erwarten eine Zeichenkette (CDATA)**

DTD (11)

```
<!ATTLIST h1
        id ID #IMPLIED
        align (left|center|right|justify) "left" >
```

- **id dient dazu, eine eindeutige *Identifikation* an einem Element anzubringen, damit darauf mit einem Attribut vom Typ idref verwiesen werden kann**
- **align ist vom Typ Aufzählungstyp, dessen Wertebereich *vollständig* in den Klammern enthalten ist. Die Vorgabe ist hier der Wert left.**

DTD (12)

- **Eine Entity (Einheit) ist eine Ansammlung von Zeichen, auf die man als Ganzes Bezug nehmen kann**
- **Allgemeine Entities werden in der DTD vereinbart und in einer Dokumentinstanz benutzt**
- **Vereinbarung:** `<!ENTITY Aring "&#196;">`
  Dabei wird eine Zeichenreferenz verwendet
- **Benutzung:** `&Aring;land <!-- ergibt: Åland -->`
- `<!ENTITY FHDW "Fachhochschule f&uuml;r die Wirtschaft">` `<! -- Zeichenkette als Entity -->`

DTD (13)

- Parameter-Entities haben die gleiche Funktionalität wie allgemeine Entities, nur ist ihr Gebrauch auf die DTD beschränkt
- Für die Parameter Entity Reference (PEReference) dient ein Prozentzeichen (%) als Präfix

```
<!ENTITY % block "absatz | listing | abbildung | kasten">
<!ELEMENT buch (kapitel+)>
<!ELEMENT kapitel (ueberschrift, (%block;)*, abschnitt+)>
```

- Dies ermöglicht eine verkürzte Schreibweise, die leichtere Wartbarkeit einer DTD und erhöht auch die Lesbarkeit
- Externe Entities, um Elementtypen, die in *mehreren* DTDs enthalten sind, nicht in jede DTD-Datei einzeln hineinschreiben zu müssen

```
<!ENTITY % tab-modell SYSTEM "/usr/local/sgml/tabelle.dtd">
%tab-modell;
<!ENTITY % block "absatz | ... | kasten | tabelle">
```

- die Tabellen-Definition im Block block wurde hier aus der externen Datei tabelle.dtd entnommen, sodann expandiert (%tab-modell;)
  damit ist die Deklaration des Elementtyps tabelle verfügbar

DTD (14)

- **Zusätzlich zu den systemabhängigen Bezeichnern gibt es auch noch die Public Identifier. Sie sind system-unabhängig und müssen vom XML-Prozessor in geeigneter Weise in einen Dateinamen o.ä. umgewandelt werden**

```
<!ENTITY % HTMLlat1 PUBLIC
"-//W3C//ENTITIES Latin1//EN//HTML"
"http://www.w3.org/DTD/ISOlat1.ent">
%HTMLlat1;
```

Hier wurden die Entities für den ISO-Latin-1-Zeichensatz mit einer Kombination aus Public und System Identifier geladen

Beispiel

- **Eine kleine DTD für E-Mails.**
  Im Wesentlichen besteht eine E-Mail aus einem Empfänger, einem Absender, einem Thema (Betreff oder »Subject«) und der eigentlichen Nachricht

```
<!-- E-Mail-DTD Version 1 -->
<!ELEMENT email (empfaenger, absender, thema, nachricht)>
<!ELEMENT empfaenger (#PCDATA)>
<!ELEMENT absender (#PCDATA)>
<!ELEMENT thema (#PCDATA)>
<!ELEMENT nachricht (#PCDATA)>
```

  - **PCDATA steht für den Text (Parsed Character Data)**

- **Beispiel eines XML-Dokumentes**

```
<?xml version="1.0"?>
<!DOCTYPE email SYSTEM "email1.dtd">
<email>
<empfaenger>Marta Mikrobe</empfaenger>
<absender>Arno Amoebe</absender>
<thema>XML-Kurs</thema>
<nachricht>der Kurs beginnt Dienstag um 9.15 </nachricht>
</email>
```

Beispiel (2)

- **Erweiterung der DTD für E-Mails.**

```
<!-- E-Mail-DTD Version 1 -->
<!ELEMENT email (empfaenger, kopieAn*, absender, thema,
nachricht)>
<!ELEMENT empfaenger (#PCDATA)>
<!ELEMENT kopieAn (#PCDATA)>
<!ELEMENT absender (#PCDATA)>
<!ELEMENT thema (#PCDATA)>
<!ELEMENT nachricht (#PCDATA)>
```

  - **PCDATA steht für den Text (Parsed Character Data)**

- **Beispiel eines XML-Dokumentes**

```
<?xml version="1.0"?>
<!DOCTYPE email SYSTEM "email1.dtd">
<email>
<empfaenger>Marta Microbe</empfaenger>
<absender>Arno Amoebe</absender>
<kopieAn>Kollegen</kopieAn>
<kopieAn>XML-Liste</kopieAn>
<thema>XML-Kurs</thema>
<nachricht>der Kurs beginnt Dienstag um 9.15 </nachricht>
</email>
```

Multimedia

- **Einbindung von Grafiken über eine Entity-Deklaration**
  ```
  <!ENTITY kurs_fhdw SYSTEM "fhdw/kursfoto.JPEG" NDATA JPEG>
  ```
  Benutzung dann in der Instanz:
  ```
  &kurs_fhdw;
  ```
  ndata steht für non-XML-Data, Daten in einer bestimmten Notation (hier JPEG)
- **die Notation-Deklaration für derartige Formate (JPEG), sollte in der DTD stehen, damit sie in jeder Instanz zur Verfügung steht**
  ```
  <!NOTATION JPEG PUBLIC "ISO/IEC 10918:1993//NOTATION
  Digital Compression and Coding of Continuous-tone Still
  Images (JPEG)//EN">
  ```
- **Der Name des Public Identifier ist in diesem Fall der internationale Standard**
- **Alternativ dazu gibt es auch System Identifier, der beispielsweise den Dateinamen eines Programms zum Anzeigen der Inhalte enthält**
  ```
  <!NOTATION WAV SYSTEM "C:\windows\player.exe" >
  ```

DocBook DTD

- DocBook wurde anfang der 90er Jahren von O‘Reilly entwickelt
- Diente als SGML Sprachdefinition ursprünglich zur Unix-Dokumentation (*man-Pages*), wurde aber auch bald für die technisch-wissenschaftliche Dokumentation eingesetzt
- Zwei Arten von Dokumenten: Artikel und Bücher
- Inzwischen ist DocBook in einer XML-Version verfügbar (Version 4.1.2)
- mittlerweile wird es für viele Dokumentationsprojekte zu freier Software eingesetzt: FreeBSD, Gnome, Darwin, KDE, etc.
- Liefert in der SGML-Variante über DSSSL / Jade diverse Ausgabeformate: HTML, RTF, TeX, PDF über TeX TeXinfo, man-Pages
- Für die XML-Version bietet sich die Formatierung über XSLT hin nach HTML, über XSLT/FO nach PDF und über dblatex nach LaTeX
- Als Eingabe-Editor bietet sich der Emacs/XEmacs mit dem PSGML-Mode an
- Abiword bietet eine Import/Export-Funktion für DocBook
- FrameMaker SGML setzt ebenfalls auf DocBook auf

Ausgabemöglichkeiten

- **Präsentation des Datenmaterials wird nicht von XML geleistet – deutliche Trennung von Inhalt und Form**
- **Da XML Informationen über das Dokument liefert, bietet es ideale Voraussetzungen zur Möglichkeit der unterschiedlichen visuellen Aufbereitung des Inhaltes in Abhängigkeit zu seiner Semantik und der damit verbundenen adäquaten Ausgabe**
  - **Für verschiedene Sichtweisen des einen Datenmaterials**
  - **Für unterschiedliche Ausgabegeräte (Drucker, PDA, etc.)**
- **Browser können nicht wissen, wie die einzelnen Elemente repräsentiert werden - zwei Lösungsmöglichkeiten**
- **Wandlung nach HTML über Programme wie Java, Python, Perl, etc.**
- **Einsatz von Stilvorlagen**
  - **CSS – Cascading StyleSsheets**
  - **XSL – Extensible Stylesheet Language**
  - **DSSSL – Document Style Semantics and Specification Language**

CSS

- **CSS bietet eine Zuordnung von Präsentationsanweisungen zu den Bereichen und Objekten einer Seite**
- **Vorteile**
  - **Leichtverständliche Syntax**
  - **Hoher Bekanntheitsgrad durch die Verwendung mit HTML**
  - **Wird häufig für einfachere XML-Dokumente bei den Browsern eingesetzt (IE6, Mozilla, Opera)**
- **Nachteile**
  - **Einfaches Box-orientiertes Formatierungsmodell, welches kein aufwendiges Layout erlaubt**
  - **Berücksichtigt keine Verwandtschaftsbeziehungen (kann z. B. nicht alle Abschnitte mit gleichen Nummern auch gleich formatieren)**
  - **Keine Programmierstrukturen**
  - **Wenig Möglichkeiten zur Parametrisierung der Stylesheets**
  - **Kann keinen Text generieren (Seitennummern)**

CSS Box-Modell

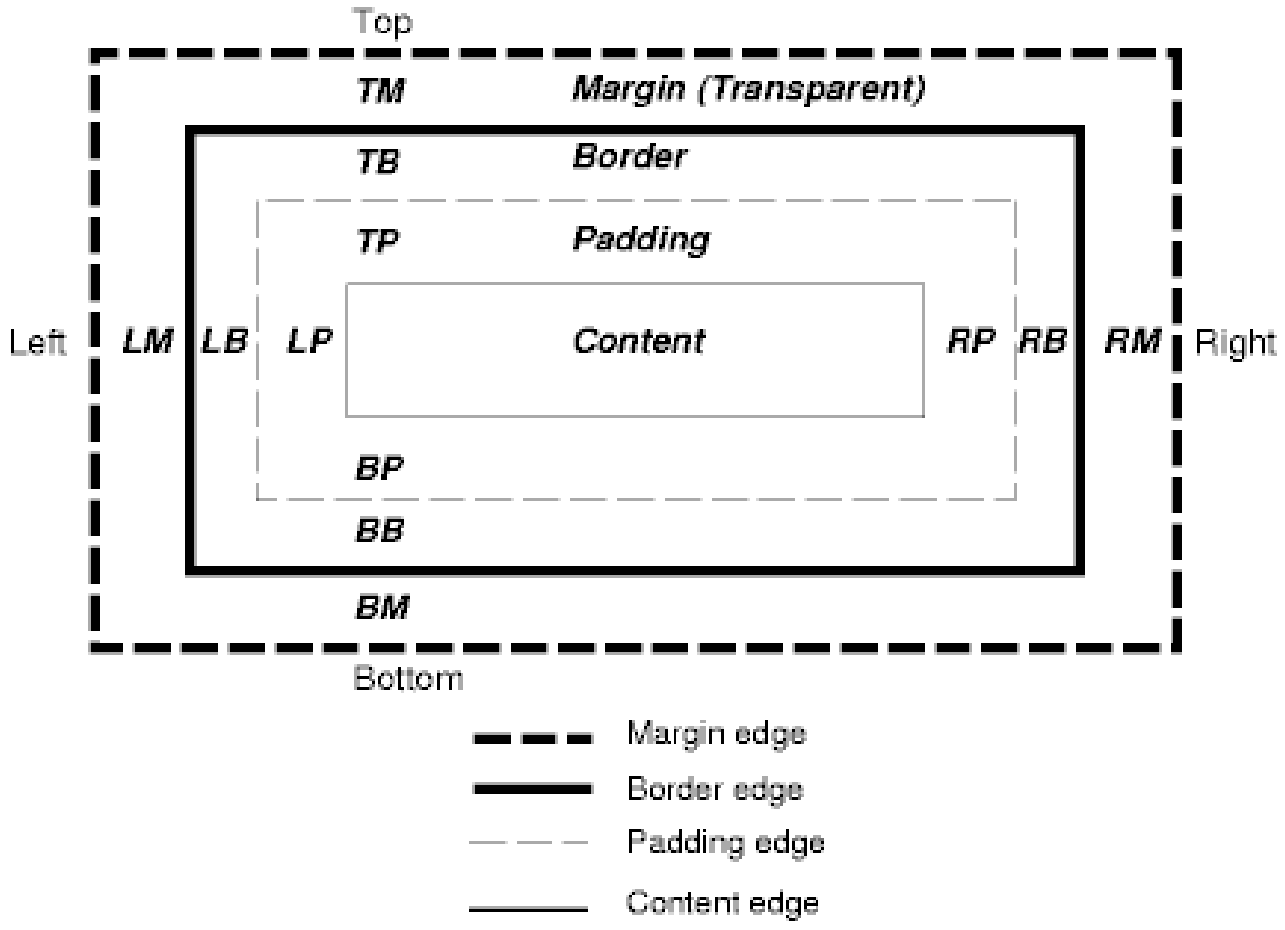

CSS (1)

- **Wachsende Akzeptanz seit der Vorstellung 1996**
  - **MS Internet Explorer ab 4.0**
  - **Netscape Communicator ab 4**
  - **Amaya (X11) - Erprobungssoftware des W3C**
  - **Opera**
  - **Netscape 6.1 / Mozilla**
- **die derzeit verfügbaren modernen Versionen der HTML-Editoren unterstützen ebenfalls das Erstellen von CSS-Anweisungen**
  - **MS Frontpage/Office 2000, Dreamweaver 3/4, Golive 4/5, StarOffice**
- **in einer eigenen Datei oder innerhalb eines HTML-Dokuments werden dem Browser typographische Anweisungen für bestimmte Auszeichnungselemente übergeben (z. B. Schrifttype, Schriftschnitt, Größe, Farbe, Einzug und Durchschuss)**

CSS (2)

- CSS erlaubt es, Formatierung vom Basisdokument zu trennen und eine Stilvorlage für beliebig viele (HTML-)Dokumente zu nutzen
- Es orientiert sich an die in der DTD (z. B. HTML) festgelegten Elemente und diese Stilanweisungen befinden darüber, welche visuelle Ausprägung diese Elemente haben sollen
- Für XML sind die Stilvorlagen zwingend notwendig, da die Browser die neuen Sprachelemente gar nicht kennen können und dementsprechend auch nicht mit Formaten vorbesetzt haben
- Dem Browser muss also mit der XML- auch mindestens eine CSS-Datei mitgeschickt werden
- Da sich die Cascading Style Sheets auf das reine Formatieren von Markup (H1, div etc.) beschränken und keine programmiertechnischen Konstrukte erlauben gehört die Zukunft DSSSL und XSL
- MS Internet Eplorer, Opera und Mozilla unterstützen CSS für die Formatierung von XML-Dokumenten

CSS (3)

- **Zuordnung zwischen HTML-Element und dessen Präsentation auf dem Ausgabemedium**

```
H1 { color: blue }
```

  Alles was in der <H1>-Umgebung steht, wird blau eingefärbt

- **Die Syntax sieht wie folgt aus:**

```
Selektor {Eigenschaft: Wert}
```

- **die zulässigen Selektoren werden durch die DTD bestimmt**
- **Gruppierung von Selektoren durch Kommata getrennt**

```
H1, H2, H3 { color: blue }
```

- **Angabe mehrerer Eigenschaften durch Semikola getrennt**

```
H1 { color: blue; font-size: 16pt;
          font-weight: bold }
```

- **unabhängige Formate: Zur Unterscheidung von Elementselektoren erhalten ID-Selektoren das Präfix #**

```
#gelb { color: yellow }
```

  im XML-Dokument:

```
<text ID="gelb"> .... </text>
```

CSS (4)

- **Möglichkeit zur Verschachtelung durch kontextsensitive Zuweisung**

```
ol       { list-style: decimal }
ol ol    { list-style: lower-roman }
ol ol ol { list-style: lower-alpha }
```

  - **Mit dieser Definition erhalten die Aufzählungen eine jeweils andere Nummerierung**
- **Vererbung: HTML-Elemente vererben ihre Eigenschaftswerte an die eingebetteten Elemente**
- **CSS unterscheidet Textblöcke und Zeichenelemente (Box-Modell)**
- **Da der Browser bei einem XML-Dokument nicht wissen kann, mit welcher Art von Elementen er es zu tun hat, muss hier eine CSS-Anweisung helfen**

  bei Textblöcken

```
text     { display: block }
```

  bei Zeichenelementen

```
zeichen  { display: inline }
```

CSS (5)

- Da dem Browser bei ihm unbekannten XML-Elementen keine impliziten Wertvorgaben existieren, müssen die CSS-Anweisungen ausführlicher ausfallen
- Deklaration der Stilanweisungen in der XML-Datei

```
<?xml version="1.0"?>
<?xml-stylesheet type="text/css" href="kurs.css"?>
```

- unter Einbeziehung von Namensräumen ist es den Autoren von XML-Dokumenten erlaubt, Elemente aus fremden DTDs zu verwenden, die öffentlich zur Verfügung stehen

```
<html:img src="kursraum.jpg"/>
```

- Dazu sollte im Hauptelement diese externe DTD bekannt gemacht werden

```
<element xmlns:html="http://www.w3.org/TR/REC-html40">
```

hier werden Elemente aus der HTML-DTD verwendet

Erweiterungen in CSS 2

- **Es lässt sich ermitteln, welche Elemente benachbart sind**

```
abb + absatz {text-indent: 2cm }
```

nur der nach einer Abbildung folgende Absatz soll um 2 cm eingerückt werden

- **Abfragen der Attributwerte**

```
absatz[align="left"] {text-indent: 1cm }
```

nur der Absatz mit dem Attribut „left“ wird entsprechend eingerückt

```
absatz[test="no"] {display: none }
```

alle Absätze mit dem Attribut test=„no“ werden nicht dargestellt

- **über ein Stylesheet lässt sich (über content:) Text hinzufügen**

```
absatz:after {
  display: block;
  content: "Absatzende";}
```

hinter jedem Absatz wird der Text „Absatzende“ eingefügt

```
kapitel para ueberschrift:before {
 content: counter(kapzaehler) ". ";
 counter-increment: kapzaehler;}
```

vor jeder Kapitelüberschrift wird eine Kapitel-Nummerierung eingefügt

Erweiterung in Opera

- **Die CSS 2 Funktionalität bietet derzeit nur der Opera 5.12**
- **Präsentationsmodus in Opera 5**
  `@media projection { }`
  alle hier vorgenommenen Einstellungen gelten nur für den Fall, dass in Opera der Vollbildmodus (F11) aktiviert wird
- **Unterstützung von XML derzeit nur über CSS, da offenbar ein XSLT-Prozessor den Browser zu groß werden lässt**

Processing Instructions (PI)

- **PI (Processing Instructions) erlauben es, Anweisungen für die Verarbeitung in einem XML-Dokument unterzubringen**
- **Sie stehen zwischen den Zeichen `<? ... ?>` z. B.**

```
<?xml version="1.0" encoding="ISO-8859-1"?>
```

- **xml wird hier als Schlüsselwort festgelegt und muss fortan stets am Anfang der PIs stehen**
- **die PIs stellen hier Verarbeitungshinweise dar, in denen festgelegt wird, welche Stylesheets zum Einsatz kommen**

```
<?xml-stylesheet type="text/css2" href="tl.css""?>
```

  - **Sie entspricht der HTML-Anweisung**

```
<LINK href="mystyle.css" rel="stylesheet" type="text/css">
```

- **daraufhin schickt der Web-Server die CSS-Datei mit an den Client**
- **Die PI `xml-stylesheet` muss im Prolog der XML-Datei stehen**
- **Es sind durchaus mehrere derartige PIs erlaubt**

Namensräume (*Namespaces*)

- **Namensräume dienen als eine Möglichkeit**
  - **Für die Hersteller, um die Zusammenstellung von Dokumentteilen zu bewerkstelligen**
  - **Für die *Working Groups*, um Namen zu reservieren, ohne die Freiheit des Anwenders in seiner Tag-Wahl zu beeinträchtigen**
- **Namensräume werden gekennzeichnet durch zwei Namen, die durch eine Kolon getrennt werden**

  `xmlns:html`
- **Der Namespace-Prefix wird als eine Abkürzung für den nachfolgenden URI angesehen**

  `<Slide xmlns:html="http://www.w3.org/TR/REC-html40">`

  Hier ist html als Entsprechung für den URI der HTML-Beschreibung zu sehen; so dass innerhalb des Slide-Elementes stets html der Namensraum ist, dessen Verantwortlichkeit durch den URI beschrieben wird
- **Die Validierbarkeit wird davon nicht berührt**
- **Einsatz von Namensräumen sind nur in XML-Instanzen, nicht aber in DTD‘s vorgesehen**

XML-Link

- Generell besteht auch in XML die Möglichkeit, Daten aus anderen Dokumenten in das eigene XML-Dokument einzublenden
- Als eine einfache Rekonstruktion des `<a>`-Elementes in HTML
- XML-Link spezifiziert eine zweiseitige Verknüpfung

```
<Button xml:link="simple" href="slide2.xml">
```

  In diesem Fall wird ein anklickbarer Bereich `Button` festgelegt
- Folgendes bietet XML-Link:
  - Beschreibt Links mit einem Link-Element
  - Identifiziert Links und deren Ziele durch ihren Typ und ihre Rolle
  - Lokalisiert Links durch eine mächtige Syntax
  - Legt das Standard-Verhalten fest

XML und CSS – Beispiel 1

```
<?xml version="1.0"?>
<?xml-stylesheet href="slides.css" type="text/css"?>
<!DOCTYPE Slide>
<Slide  xmlns:html="http://www.w3.org/TR/REC-html40">
<html:img src="fhdw.gif" width="61" height="131" id="logo" />
  <SlideBody>
    <Heading>XML</Heading>
    <SubHeading>Grundlagen - Unterscheidung zu HTML</SubHeading>
    <List>
      <ListItem>Unterscheidung zwischen Form und Inhalt</ListItem>
      <ListItem>prozedurales vs. generisches MarkUp</ListItem>
      <ListItem>Uebliche Visualierungsprobleme</ListItem>
      <ListItem>das laeuft ja schon hervorragend mit XML und
   Folien</ListItem>
    </List>
  </SlideBody>
  <Bar>
    <Button xml:link="simple" href="next.gif">naechste Folie</Button>
  </Bar>
</Slide>
```

XML und CSS – Beispiel 1

```
Slide { display: block }

SlideBody {
  display: block;
  padding-left: 4px;
  border-left: 80px solid rgb(0,128,200);
  border-top: 4px solid rgb(0,128,200);
  border-bottom: 4px solid rgb(0,128,200);
  font-family: Verdana;
  font-size: 16pt;
  width: 940px;
  height: 618px;
  margin: 0px;
}
Heading {
  text-align: center;
  text-decoration: underline;
  font-size: 24pt;
  font-weight: bold;
  display: block;
  margin-top: 1em;
  margin-bottom: 0.75em;
}
```

XML und CSS – Beispiel 2

```
<?xml version="1.0"?>
<?xml-stylesheet href="email.css" type="text/css"?>
<mail>
        <Recipient>Marta Microbe</Recipient>
        <Sender>Arno Amoebe</Sender><br />
        <Date>Mon, 31. Jan 2000 010:30:00</Date>
        <Subject>XML-Kurs</Subject>
<Textbody>
        <p>Hallo <Name>Marta</Name>,</p>
        <p>Bitte schaue dir doch einmal den Aufsatz <br />
        "SGML, Java and the Future of the Web"<br />
        von <Name>Jon Bosak</Name> an.</p>
        <p>bis dann,</p>
        <p><Name>Arno</Name></p>
</Textbody>
</mail>
```

XML und CSS – Beispiel 2

```
mail       { display: block; background-color: rgb(255,255,255);
             margin-left: 10px; width: 500px }
Recipient  { display: inline; font-weight: bold; color: green }
Sender     { display: inline; font-weight: bold; color: red;
             margin-left: 100px }
Date       { display: block; font-family: monospace;
             fontweight: bold; font-size: 10pt; margin-top: 15px;
             margin-bottom: 15px }
Subject    { display: block; font-weight: bold;
             font-family: helvetica; margin-left: 10px;
             margin-top: 5px; margin-bottom: 10px; width: 400px;
             border-style: solid; border-color: blue;
             text-align: center }
Textbody   { display: block; background-color: cyan;
             margin-left: 10px; width: 400px }
br         { display: block }
p          { display: block }
name       { font-style: italic; font-weight: bold }
```

XSL

- XSL steht für Extensible Stylesheet Language und ist eine auf XML basierende Sprache für Stilvorlagen
- Von Microsoft, Inso und Arbortext initiiert und dem W3C vorgelegt
- Ein Stylesheet dient dazu, einem Prozessor (Browser, etc.) Anweisungen zu geben, damit er die logische Struktur in eine Präsentationsstruktur überführen kann
- XSL stellt Programmroutinen zur Verfügung, mit denen sich vom Ausgangsdokument abweichende Strukturen aufbauen lassen
- Erste Realisation war der Prozessor msxsl von Microsoft
- Letztes Draft Mitte Januar 2000

XSL-Prozessoren

- **msxml von Microsoft**
  - **Empfehlenswert ist der Einsatz ab der Version 3.0**
- **xalan der Apache-Group**
  - **Wird im Apache-Projekt Cocoon eingesetzt**
- **Saxon von Michael Kay**

  http://saxon.sourceforge.net/
- **XT von James Clark**
  - **Verfügbar entweder als Java-Klassen oder als Windows-Executable**
- **xsltproc schneller in C geschriebener Prozessor unter Linux und Win32, ursprünglich für das Gnome-Projekt entwickelt**
- **FOP von James Tauber bzw. der Apache-Group**
  - **Ziel ist die Formatierung nach PDF 1.3 (Portable Document Format), MIF (Framemaker) und SVG (Scalable Vector Graphics)**
  - **Verfügbar in Form von Java-Klassen, benötigt xalan und xerces**

MSXML-Versionen

- **Installation: msxml3_de.exe (für die Version 3.0SP1) oder msxml4.exe (für Version 4)**
- **Installation der Datei xmlinst.exe in `windows\system` (win9x) bzw. `winnt\system32` (NT, W2k)**
- **Aufruf von xmlinst registriert die neue DLL**
- **Mit xmlinst /u msxml4 wird die Registrierung wieder auf die ältere Version zurückgenommen**
- **Versionen:**
  - **V. 2.0 – [...] – Internet Explorer 5.0, Office 2000**
  - **V. 2.5 SP1 – [8.0.5226] - Internet Explorer 5.5, Windows 2000**
  - **V. 3.0 – [8.0.7820.0] - Internet Explorer 6.0**
  - **3.0SP1 – [8.20.8730.1]**
  - **4.0 – [4.0.8411.1] - Technology Preview July Version**
- **Es empfiehlt sich für XSLT-Transformationen generell der Einsatz ab Version 3.0**
- **msxsl.exe ist die Kommandozeilen-Version für den Microsoft XSL-Prozessor (nur msxml 3.0 und 4.0)**

Aufruf einiger XSLT-Prozessoren

- **Voraussetzung für die meisten XSLT-Prozessoren ist eine JVM möglichst ab 1.2**
- **Xt:**

```
xt test.xml test.xsl –o test.html
```

- **Xalan:**

```
java -cp xalan-2.1.0.jar;xerces.jar
org.apache.xalan.xslt.Process –in test.xml –xsl test.xsl
–out test.html
```

- **Msxsl – Kommandozeilenversion:**

```
msxsl test.xml test.xsl –o test.html
```

- **Fop – Formating Object Processor:**

```
java -cp fop-0.20.1.jar;batik.jar;xalan-2.1.0.jar;
xerces.jar;jimi-1.0.jar org.apache.fop.apps.Fop
-fo test.fo –xml test.xml –xsl test.xsl [-awt| -pdf| -mif]
test.pdf/.mif
```

  bei der Option „awt“ wird eine Bildschirmdarstellung versucht
- **bei JVM 1.1.8 müssen die JAR-Dateien im separaten Klassenpfad gesetzt werden**

XSL/XSLT (1)

- **XSL besteht aus zwei Teilen**
  - **Eine Sprache zur Beschreibung von Transformationen von XML-Dokumenten (XSLT)**
  - **Eine Sprache zur Spezifizierung der Formatierungssyntax**
- **Ein XSL-Prozessor benötigt als Eingabe eine XML-Datei und eine Stil-Anweisung und erzeugt daraus die gewünschte Präsentation in zwei Phasen:**
  - **Baumtransformation – die XML-Struktur des Ausgangsdokumentes (Baumstruktur) wird in eine andere überführt, den Ergebnisbaum**
  - **Die eigentliche Formatierung**

XSL/XSLT (2)

- die Baumtransformation erfolgt durch Angabe von Regeln
- Jede Regel hat einen Pattern-Teil, der die möglichen Anwendungsstellen im XML-Strukturbaum festlegt und einen Template-Teil, der bestimmt, durch welche Struktur die Anwendungsstelle im Ergebnisbaum ersetzt werden soll
- Der Transformationsprozess ermöglicht den flexiblen Zugriff auf bestimmte Bereiche des XML-Dokuments.
  - Damit lassen sich aus einer XML-Instanz durch entsprechende XSL-Anweisungen Dokumente für jeweils unterschiedliche Ausgabegeräte erstellen
  - → ideal für die Strukturierung umfangreicher Web-Angebote s. Cocoon-Projekt

XSLT

- Üblicherweise erfolgt die Transformation in eine Struktur, die bereits darstellungsorientiert ist und möglichst auf einer XML-Struktur aufbaut, d.h. der Ergebnisbaum ist ebenfalls XML
  - XML →HTML
    nicht so ideal, da HTML auf SGML aufbaut
  - XML →XHTML, HTML auf Basis von XML
  - XML → WML (**W**ireless **M**arkup **L**anguage), eine in XML verfasste Sprache für Dokumente, die von sog. WAP-Handys dargestellt werden können
- Soll eine geräteunabhängige Formatierung für Print/Online-Medien erzielt werden, benötigt man zusätzlich den Formatierungsprozess durch **XSL:FO**
- FO steht für **F**ormatting **O**bjects
- Formatierungsobjekte sind Rechtecke, die bestimmte Eigenschaften aufweisen

XSL vs. CSS

- XSL baut auf XML-Syntax auf
- Ziel ist eine möglichst einfache Nutzung im Internet (daher nicht DSSSL)
- CSS bietet nur Formatanweisungen für die entsprechenden Tags
- In XSL muss der zu formatierende Strukturbaum nicht gleich dem Ergebnisbaum sein, es bietet somit die Möglichkeit zu weitreichenden programmtechnischen Manipulationen
- Beide Verfahren bieten einen Mechanismus, die jeweiligen XML-Elemente zu präsentieren
  - CSS: über Selektoren und Eigenschaften
  - XSL: über Pattern und Formatting Objects
- Verfügbare Programme:
  - XSL wird derzeit nur vom IE und serverseitigen Publishing Systemen unterstützt
  - CSS hingegen von fast allen modernen Browsern (IE, Mozilla, Opera) und Editor-/Textsystemen, die XML unterstützen

DSSSL

- DSSSL steht für Document Style Semantic and Specification Language
  - Internationaler Standard ISO/IEC 10179:1996
- Ein an dem Scheme-Lisp-Dialekt angelehnte Programmiersprache
- Eine mächtige und daher schwer zu erlernende Sprache
- Besteht aus mehreren Komponenten:
  - Style Language zur Formatierung von SGML/XML-Dokumenten
  - Transformation Language zur Umwandlung von SGML/XML-Dokumente, die einer DTD entsprechen in solche, die einer anderen entsprechen
  - Query Language zur Möglichkeit der Abfrage von Elementen und Attributen
- Ermöglicht somit auch die Transformation von XML nach HTML
- Als Tool kommt hierfür zum Einsatz James Clarks Programm Jade (von James‘ DSSSL Engine)
  http://www.jclark.com/jade/

DOM

- **DOM steht für Document Object Model und beschreibt in einer objektorientierten Annäherung eine Web-Seite als eine Ansammlung von Objekten, die einzeln adressierbar sind**
  - **Die Web-Seite kann hierbei als HTML- aber auch als XML-Objekt begriffen werden**
  - **Die Modularisierung in Objekten ermöglicht deren Wiederverwendbarkeit**
  - **Objekttypen als Vorlage (*template*) und die Instanzen als die jeweilige konkreten Realisierungen**
- **Für den Zugriff auf diese Objekte eignen sich bestens objektorientierte Programmiersprachen wie Java, Python, aber auch JavaScript, TCL, Perl**
- **API (Application Programming Interface) als eine Sammlung von Regeln, wie die einzelnen Objekte erreicht und verändert werden können**
- **Hieraus ergeben sich im wesentlichen drei Funktionen des DOM:**
  - **WER: wie werden XML-Objekte hier repräsentiert**
  - **WAS: was können die Objekte und wie hängen sie miteinander zusammen**
  - **WIE: wie können diese Objekte adressiert werden**
- **Während XML die Daten strukturiert und identifiziert, ermöglicht das DOM die Manipulation über Programme, d. h. die Aktion der Daten untereinander**

Zusammenspiel von XML und DOM für eine dynamische Web-Präsentation

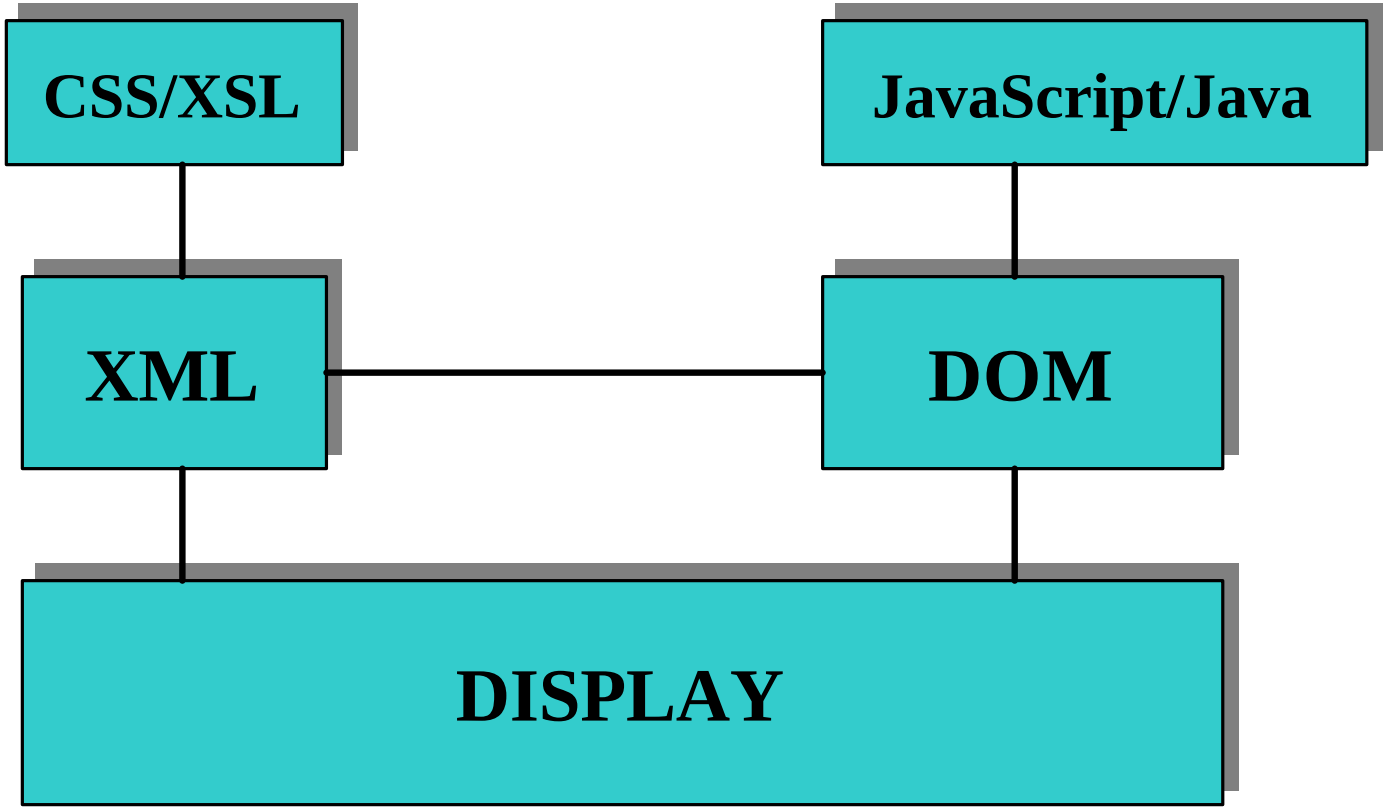

XHTML

- **XHTML: EXtensible HyperText Markup Language**
  - **August '99 Proposed Recommendations for XHTML 1.0**
    Working Draft am 24.12.1999
    Neuformulierung am 24.1.2000
- **Während HTML als Applikation von SGML entwickelt wurde, ist XHTML eine Applikation von XML**
- **Gründe für XHTML:**
  - **Verbreitete Nachlässigkeit bei der Verwendung von HTML-Tags**
  - **Unvollkommene Implementierung der Stilvorlagen**
  - **Neue Browser-Arten erfordern modifizierte/reduzierte HTML-Sprache**
  - **Bessere Integration von HTML in andere Tag-orientierte Sprachen**
- **XHTML erfordert Wohlgeformtheit und ist somit Parser-gerecht**
- **Die Tags und Attribute müssen kleingeschrieben werden!**

Tidy

- **Programm von Dave Raggett zur Umwandlung von HTML-Dokumenten nach XHTML**
  http://www.w3.org/People/Raggett/tidy
- **Korrektur der HTML-Auszeichnung in Richtung Wohlgeformtheit**
- **Unbekannte Sprachelemente und Attribute werden aufgezeigt**
- **Der Quellcode wird entsprechend eingerückt ausgegeben (pretty printing)**
- **Darstellung der Sonderzeichen: US ASCII, ISO Latin-1, UTF-8 in HTML-Entitäten**
- **Presentational Markups werden möglichst in CSS-Notation überführt**
- **Erstellung von Slides, indem bei jeder <h2>-Umgebung eine neue Datei erzeugt wird**
- **Binaries für Win32, Mac, RPMs für Linux, Quellen für C und Java**
  Plugin für den freien HTML-Editor Phase 5^2
  `tidy -f err.txt -im foo.html`
  korrigiert die Datei *foo.html*, rückt die Sprachelemente ein und gibt etwaige Fehler in *err.txt* aus

Tidy - Optionen

-config *file*	**liest die Konfigurationsdatei *file* ein**
-indent *oder* -i	**Einrückung der Sprachelemente**
-omit *oder* -o	**läßt optionale Ende-Tags weg**
-wrap 72	**Zeilenumbruch nach 72 (Standard ist 68)**
-upper *oder* -u	**Großschreibung der Tags (Standard ist klein)**
-clean *oder* -c	**ersetzt font, nobr & center durch CSS**
-raw	**keine Entitäten für ASCII 128 - 255**
-ascii	**Ausgabe ASCII, Eingabe Latin-1**
-latin1	**Aus-/Eingabe Latin-1**
-utf8	**Aus-/Eingabe UTF-8**
-numeric *oder* -n	**Ausgabe von numerischen Entitäten**
-modify *oder* -m	**Veränderung an der Originaldatei**
-errors *oder* -e	**nur Ausgabe der Fehlermeldungen**
-f *file*	**gibt Fehler in *file* aus**
-xml	**Eingabedatei ist XML**
-asxml	**konvertiert HTML nach XML**
-slides	**Folienausgabe getrennt durch das <h2>-Element**
-help	**Kommandooptionen**

Publishing Framework

- **mittelfristig wird jede größere Applikation Web-fähig sein müssen**
- **Problem 1:**
  - **Die Konstruktion von aufwendigen Web-Interfaces zieht zeitraubende HTML-Programmierung nach sich**
  - **Dies kompliziert sich noch durch die Verfügbarkeit unterschiedlicher Devices (Handys, Print-Medien, etc.)**
- **Lösung: ein Publishing-System, dass die Dokumente in XML vorhält und die Anpassung an die Ausgabegeräte über XSL/XSLT ermöglicht**
- **Problem 2: mittels JSP (Java Server Pages) lässt sich zwar elegant Java-Code in HTML-Seiten einbetten, hier wird aber nicht zwischen Inhalt und Darstellung getrennt und weiterhin auch nicht die Transformation in andere Formate ermöglicht**
- **Lösung: XSP (Extensible Server Pages) baut auf XML auf, erlaubt somit die Trennung des Inhaltes von der Darstellung und weiterhin lassen sich die XSP-Prozesse durch Stylesheets in ein anderes Format transformieren**

Cocoon (1)

- **Apache Cocoon-Projekt, begründet von Stefano Mazzocchi**
  http://xml.apache.org/cocoon
- **basiert vollständig auf Java, als Java-Servlet lässt es sich in jede Servlet-Engine eines Web-Servers integrieren (z. B. im Apache mit Apache-Jserv)**
- **In Abhängigkeit vom Ausgabegerät werden die unterschiedlichen Formate zur Laufzeit generiert und ausgeliefert**
- **Funktion:**
  - **Der XML-Parser xerces, überführt ein vorliegendes XML-Dokument in eine interne Baumstruktur, der DOM-Repräsentation**
  - **Diese Datenstruktur transformiert der XSL-Prozessor xalan und erzeugt eine Ausgabe**
  - **Zur Print-Ausgabe dient der Formatierer FOP (Formatting Object Processor)**
  - **Für komplexere Dokumente und als Bindeglied zu Cocoon 2 dient das Apache Stylebook**

Cocoon (2)

- **Aktuelle Version 1.81,**
  Version 2 befindet sich noch in der Entwicklung
- **Orientiert sich vollständig an den W3C-Standards**
- **Liefert verschiedene Ausgabeformate: derzeit HTML, WML, PDF, SVG**
- **Unterstützt unter anderem folgende Ausgabeprogramme/-geräte: MS Internet Explorer, Opera, Lynx, Nokia (WAP), UP (WAP), Netscape/Mozilla**
- **Macht den Web-Server XML-fähig**
  Ermöglicht den Weg hin zu eine bessere Strukturierung der Web-Site und fördert die Arbeitsteilung, um die drei unterschiedlichen Komponenten (Inhalt, Struktur, Format) zu erstellen