

XML-Praxis

# XML – Extensible Markup Language

Jörn Clausen

[joern@TechFak.Uni-Bielefeld.DE](mailto:joern@TechFak.Uni-Bielefeld.DE)

XML? Das sind doch bloß spitze Klammern!

Ja, und Programme sind nur Folgen von Bytes.

# Übersicht

- Was ist XML?
- Verarbeitung von XML
- Aufbau von XML-Dokumenten
- XML-Grammatiken

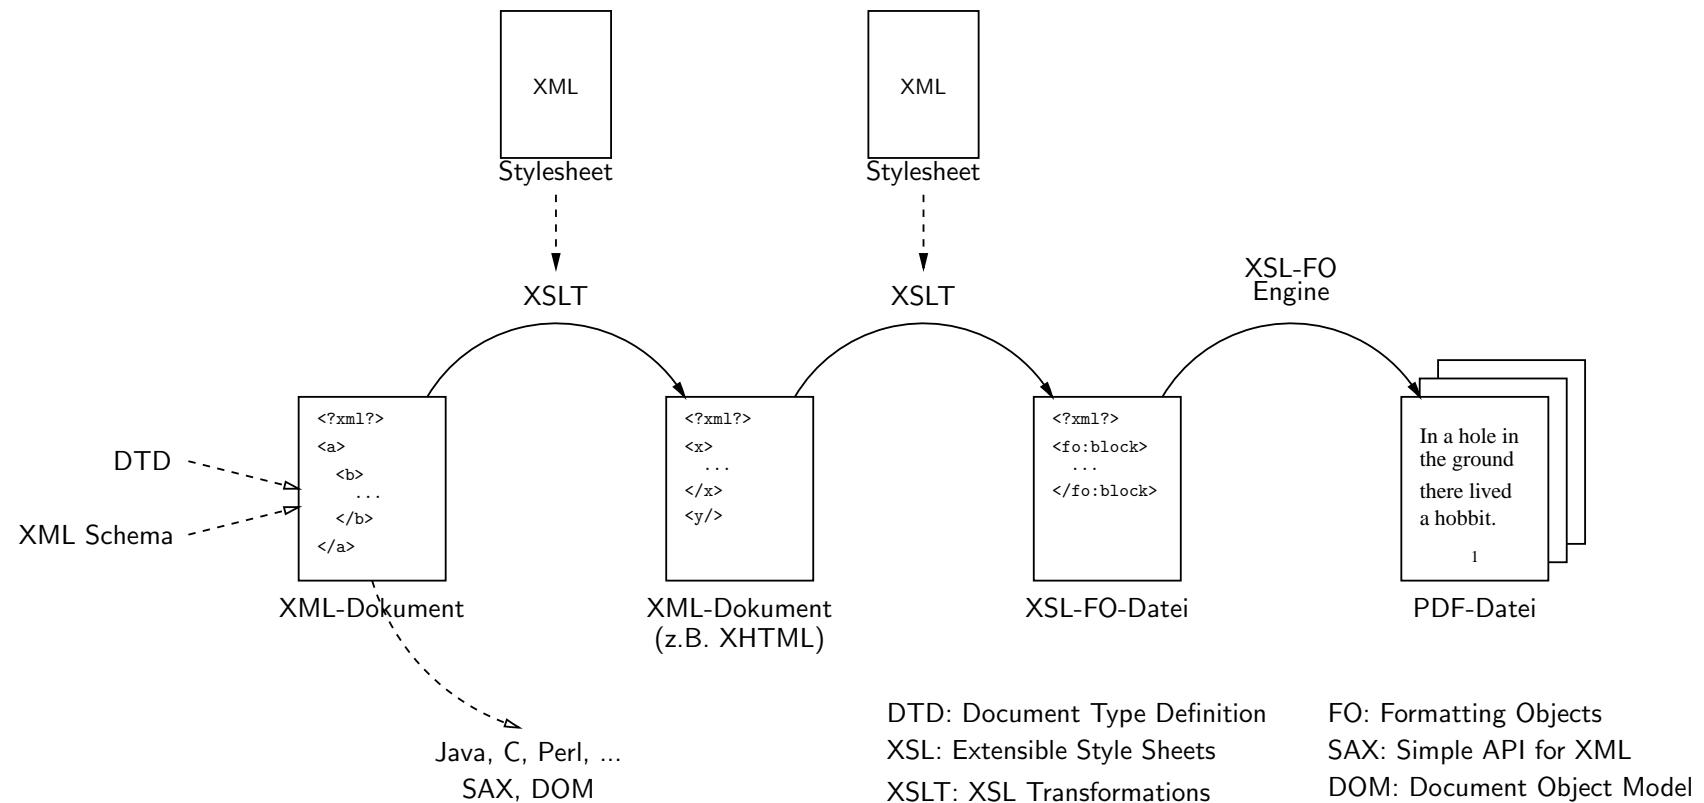
# Was ist XML?

- Daten sind strukturiert (Texte, Bilder, Meßergebnisse, ...)
- maschinelle Verarbeitung erfordert Kenntniss der Strukturen
- gesucht: Formalismus, um beliebige Strukturen zu beschreiben
- XML kann textuelle Daten strukturieren
- standardisierte Methoden zur Verarbeitung von XML

# Ursprung von XML: SGML

- Standard Generalized Markup Language
- 1986 als ISO-Standard 8879 verabschiedet
- *keine* Markup-Sprache, sondern Grammatik-Sprache
- Einsatz vor allem im Verlagswesen
- 1989: Hypertext Markup Language, World Wide Web
- Problem: komplexe Regeln, Parser schwer zu implementieren
- ab 1996: Entwicklung von XML
- SGML--, nicht HTML++

# Verarbeitung von XML



# Verarbeitung von XML, cont.

- (fast) alles ist XML
- wenige Werkzeuge nötig (XML-Parser, XML-Editor, ...)
- wiederverwendbare Komponenten
- Textformat Unicode: portabel, einfach zu verarbeiten
- offene Standards, viele Open Source-Lösungen

# ein Beispiel

```
<?xml version="1.0"?>

```

# Aufbau von XML

- XML-Datei beginnt mit *XML declaration*

```
<?xml version="1.0"?>
```

- bisher nur Version 1.0 spezifiziert, neue Versionen in Planung
- verwendete Kodierung

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

- sonst Unicode (UTF-8), Obermenge von ASCII
- Kodierung im Dokument nicht unproblematisch

# Elemente (elements)

- öffnendes und schließendes *tag*

```
<item>XML is not a ...</item>
```

- Elemente können geschachtelt werden

```
<ilist>
  <item>XML is not a ...</item>
  <item>... <emph>well formed</emph> ...</item>
</ilist>
```

- keine Minimierungsregeln
- leeres Element

```
<hr /> statt <hr></hr> statt <hr>
```

# Elemente, cont.

- Schachtelung muß „passen“

```
<a> <b> ... </a> </b>
```

- Groß/Klein-Schreibung relevant

```
<html> ... </HTML>
```

- XML-Dokument muß genau ein oberstes Element enthalten

```
<?xml version="1.0"?>
<presentation>
  ...
</presentation>
```

# Attribute (attributes)

- Zusatzinformationen zu Elementen

```
<presentation status="draft" date="2002-10-04">
```

- nur im öffnenden tag
- Anführungszeichen " (double quote) oder ' (single quote)
- Attribut darf nur einmal vorkommen

```
<presentation lang="en" lang="de">
```

- Designfrage: Wann Elemente, wann Attribute?

```
<date y="2002" m="10" d="7" />  
<date><y>2002</y><m>10</m><d>7</d></date>
```

# Entitäten (entities)

- Makros und Sonderzeichen
- in XML vordefinierte *entity references*  
`&amp; &lt; &gt; &apos; &quot;`
- weitere können definiert werden
- *character references*: Zugriff auf beliebige Unicode-Zeichen  
`© 2002 by Jörn Clausen`

# wohlgeformtes vs. valides XML

- *well formed XML*: bestimmte Kriterien erfüllt
  - korrekte Kodierung
  - korrekte Schachtelung der Elemente
  - korrekte Attribute
  - definierte Entitäten
- XML-Parser kann Wohlgeformtheit überprüfen
- *valid XML*: Dokument entspricht einer Grammatik

# XML-Grammatiken

- formale Beschreibung der Syntax eines XML-Dokuments
  - Welche Elemente gibt es?
  - Wie dürfen/müssen Elemente geschachtelt werden?
  - Welche Attribute dürfen in welchen Elementen vorkommen?
  - Welche Entitäten sind definiert?
- erleichtert den Austausch von XML-Dokumenten
- kann bei der Erstellung eines XML-Dokuments helfen

# XML-Grammatiken, cont.

- von SGML übernommen: *Document Type Definition* (DTD)
  - für XML etwas eingeschränkt
  - DTD selber ist nicht XML
- alternative Vorschläge:
  - W3C XML Schema
  - RelaxNG
  - Schematron
  - Document Schema Definition Language (ISO/IEC 19757)
- zur Zeit *sehr* kontrovers diskutiert

# Document Type Definition

- für allgemeine Daten nicht immer ideal
- für textuelle Daten aber (immer noch) geeignet
- große Anzahl an etablierten DTDs
- große Anzahl an Werkzeugen (XML/SGML-Editoren)

# Elemente definieren

- Element besitzt *content model*

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

- #PCDATA: Text ohne weitere Elemente
- Container-Elemente

```
<!ELEMENT slide     (title, ilist)>
<!ELEMENT ilist    (item*)>
```

- Quantoren: ?, +, \* (wie in regulären Ausdrücken)
- Konnektoren:
  - a , b: erst a, dann b
  - a | b: a oder b

# Elemente definieren, cont.

- Mischung von Text und *inline*-Elementen

```
<item>... can be <emph>well formed</emph>  
or even ...</item>
```

- *mixed content*

```
<!ELEMENT item (#PCDATA | emph)*>
```

- kann bei der Verarbeitung problematisch sein

# Attribute definieren

- „Aufzählungstyp“

```
<!ATTLIST presentation  
        status (draft|final|publ) #REQUIRED>
```

- Vorgabe definieren

```
<!ATTLIST presentation  
        status (draft|final|publ) "draft">
```

- beliebiger Text

```
<!ATTLIST presentation  
        status (draft|final|publ) #REQUIRED  
        date   CDATA #IMPLIED>
```

# Entitäten definieren

- textuelle Makros

```
<!ENTITY xml "Extensible Markup Language">
```

- Umlaute wie in HTML

```
<!ENTITY Äuml "&#196;">
<!ENTITY äuml "&#228;">
```

- *parameter entities*, für Makros in der DTD

```
<!ENTITY % text "(#PCDATA|ital|bold)*">
<!ELEMENT item %text;>
<!ELEMENT ital %text;>
<!ELEMENT bold %text;>
```

# DTD einbinden

- Verweis auf DTD im XML-Dokument
- *system identifier*

```
<?xml version="1.0"?>
<!DOCTYPE presentation SYSTEM "presentation.dtd">
```

- *public identifier* und *system identifier*

```
<?xml version="1.0"?>
<!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"
"http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
```