

X-Technologien

XML and Friends

9. Juli 2001

Jörn Clausen

joern@TechFak.Uni-Bielefeld.DE

Übersicht

XML Extensible Markup Language

SAX Simple API for XML

DOM Document Object Model

XSL Extensible Stylesheet Language

XPath XML Path Language

XSLT XSL Transformations

XSL FO XSL Formatting Objects

SGML Standard Generalized Markup Language

DSSSL Document Style Semantics and Specification Language

Markup – Wofür?

- ursprüngliche Domäne: Textdokumente
- Auszeichnung von *Bedeutung* statt *Formatierung*
- Stylesheets beschreiben Formatierung
- Anwendungen: DocBook, CALS, HTML
- heute: strukturierte Beschreibung von Daten aller Art
- Bioinformatik: BioXML (GAME), MAML, GEML, Pise, ...

XML – Extensible Markup Language

- ist ...
 - *keine* Markupsprache
 - *kein* Allheilmittel, trotz des Hypes
 - SGML--
- ist aber auch ...
 - einfach zu erlernen
 - weithin akzeptiert
 - durch viele Implementierungen etabliert

ein Beispiel

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



<presentation>



  <slide>



    <title use="internal">XML & Friends for Dummies</title>



    <title use="external">Doing B2B with XML & Friends</title>



    <ilist>



      <item>XML is not a markup language  
        (unlike HTML)</item>



      <item>XML is a meta language for  
        defining markup languages</item>



      <item>XML instances can be <emph>well  
        formed</emph> or even  
        <emph>validating</emph></item>



    </ilist>



  </slide>


</presentation>
```

Aufbau von XML: Elemente

- öffnendes und schließendes tag:

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

- keine Minimierungsregeln
- leeres Inhaltsmodell:

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

- Schachtelung muß „passen“: *well-formed*

Aufbau von XML: Attribute

- Zusatzinformationen zu Elementen

```
<title use="internal">... for Dummies</title>
```

- Attribute im öffnenden tag
- Wertebereich: Aufzählungstyp, Zahlen, Freitext
- schlechte Typisierung
- Design-Frage: Wann Element, wann Attribut?

```
<date y="2001" m="7" d="9" />
```

vs.

```
<date><y>2001</y><m>7</m><d>9</d></date>
```

Aufbau von XML: Entitäten

- Makros und Sonderzeichen
- aus HTML bekannt: ä ê ©
- in XML vordefiniert: & < > ' "
- XML verwendet Unicode

Document Type Definition

- Grammatik kann durch DTD beschrieben werden
- `<!DOCTYPE presentation SYSTEM "presentation.dtd">`
- Parser kann XML-Instanz gegen DTD *validieren*
- Definition von
 - Elementen: Inhaltsmodell
 - Attributen: Wertebereich, Vorbelegung
 - Entitäten: character entities, parameter entities
- DTD sehr eingeschränkt
- XML Schema, RELAX NG, ca. 10 weitere Vorschläge

DTD zum Beispiel

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

<!ELEMENT presentation (slide)+>
<!ELEMENT slide        (title*, ilist)>
<!ELEMENT title         %text;>
<!ATTLIST title        use      (internal|external) #IMPLIED>

<!ELEMENT ilist        (item)+>
<!ELEMENT item         %text;>

<!ELEMENT emph         %text;>
<!ELEMENT bold         %text;>
<!ELEMENT ital         %text;>
```

Name Spaces

- Kombination von verschiedenen XML-Sprachen
- z.B. allgemeine, wiederverwendbare Definition von Tabellen:

```
<pr:presentation xmlns:pr="http://www.slides.org/presentation-1.0">
  <pr:slide>
    <pr:title>increasing use of XML</pr:title>
    <cals:table xmlns:cals="http://www.army.mil/SPEC-CALS">
      <cals:tr>
        <cals:th>year</cals:th>
        <cals:th>applications</cals:th>
      </cals:tr>
      <cals:tr>
        <cals:td>1998</cals:td>
        <cals:td>15</cals:td>
      </cals:tr>
```

Verarbeitung von XML

- zwei Verfahren:
 - event-basiert
 - Baumstruktur
- Speicherplatz vs. freier Zugriff
- Geschwindigkeit vs. startup-Zeit
- stream-Fähigkeit

SAX – The Simple API for XML

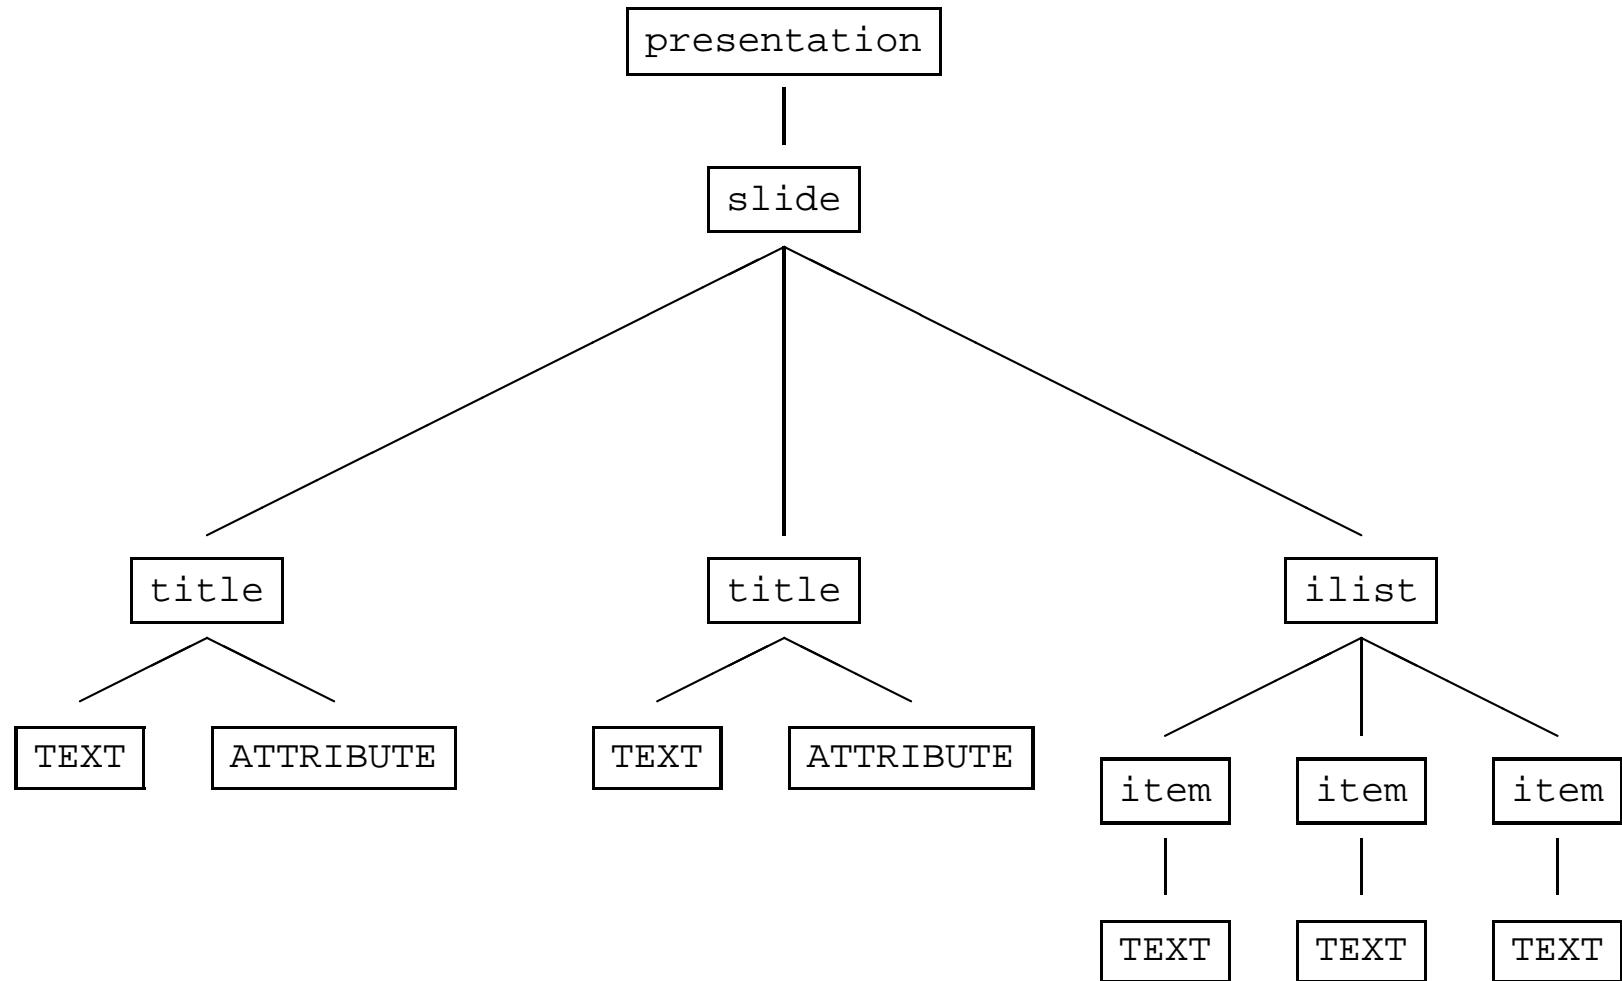
- events: u.a.
 - startDocument, endDocument
 - startElement, endElement
 - characters
- z.B. einfache Übersetzung nach L^AT_EX:

<slide>	→	\begin{slide}
</slide>	→	\end{slide}
<item>	→	\item
</item>	→	
<bold>	→	\textbf{
</bold>	→	}

DOM – Document Object Model

- Dokument als Baum
- Elemente, Attribute, Text usw. sind die Knoten
- Klassen: Node, NodeList, Element, Text
- Methoden: childNodes, nextSibling, parentNode, getElementsByTagName

das Beispiel als Baum



XSL – Extensible Stylesheet Language

- XML beschreibt Syntax
- Formatierung? Semantik?
- XSL besteht aus mehreren Standards:
 - Zugriff auf bestimmte Knoten (ähnlich DOM)
 - Transformation von XML nach XML
 - XML-Sprache für Layout-Anweisungen

XPath

- enthält
 - Pfadbeschreibung, Bedingungen
 - Funktionen
- *Achsen:* child, parent, sibling, attribute
- Verwendung:

slide	slide-Kind des aktuellen Knotens
slide/title	title-Element unter slide
slide/title/@use	use-Attribut
//title[@use="internal"]	bestimmte title-Elemente

Beispiele für XPath

```
juser@hobel> xpath slides.xml '/presentation/slide/title'  
<title use="internal">XML & Friends for Dummies</title>  
<title use="external">Doing B2B with XML & Friends</title>  
  
juser@hobel> xpath slides.xml '/presentation/slide'  
<slide>  
    <title use="internal">XML & Friends for Dummies</title>  
    <title use="external">Doing B2B with XML & Friends</title>  
  
juser@hobel> xpath slides.xml '//title/@use'  
use="internal"  
use="external"  
  
juser@hobel> xpath slides.xml '//title[@use="internal"]'  
<title use="internal">XML & Friends for Dummies</title>  
  
juser@hobel> xpath slides.xml '//item[position()=2]'  
<item>XML is a meta language for  
    defining markup languages</item>
```

XSLT – XSL Transformations

- Umformung von XML nach
 - XML: Extraktion von Daten, Vorstufe der Formatierung
 - HTML: Visualisierung
- *style sheet* definiert *templates*
- Verarbeitung durch XSLT-Prozessor
- diverse Implementierungen

das Beispiel in HTML

```
<xsl:template match="/presentation">
  <html>
    <body>
      <xsl:apply-templates/>
    </body>
  </html>
</xsl:template>

<xsl:template match="slide">
  <xsl:apply-templates select="title[@use='external']"/>
  <xsl:apply-templates select="ilist"/>
</xsl:template>

<xsl:template match="title">
  <h1>
    <xsl:value-of select=". "/>
  </h1>
</xsl:template>
```

XSL Formatting Objects

- XML-Sprache zur Beschreibung von Formatierung
- sehr komplex, aber universell
- FO wird durch XSLT-style-sheet erzeugt
- FO wird durch FO-Engine in Ausgabeformat umgewandelt
- FOP (Apache) erzeugt PDF, FrameMaker, PCL, ASCII, Preview

XML-Ausgabe von blast in HTML

File Edit View Go Window Help

Back Forward Reload Home Search Guide Print Security Stop N

Bookmarks Location file:///homes/joern/lehre/talks/pi-xml/blast/blastout.html

News Search Perl TeX XML

blast of dm|gi|7290022|gb|AAF45489.1| CG13377 gene product against ./vert

Sequence	Score (bits)	E Value
emb RNDHYDEH Sprague-Dawley D-beta-hydroxybutyrate dehydrogenase mRNA, completecds.	88	4.50265e-17
emb MM17BDTII M.musculus mRNA for 17-beta-hydroxysteroid dehydrogenase type II	77	7.94792e-14
emb MM17BDTII M.musculus mRNA for 17-beta-hydroxysteroid dehydrogenase type II	77	7.94792e-14
emb AF030513 Mus musculus cis-retinol androgen dehydrogenase 1 mRNA, completecds.	59	2.23983e-08
emb RN1TBHD1 R.norvegicus mRNA for 17-beta-hydroxysteroid dehydrogenase type 1	48	5.16365e-05
emb RNBHD1 R.norvegicus mRNA for 17-beta-hydroxysteroid dehydrogenase type I	48	5.16365e-05
emb RH33501 Rattus norvegicus retinol dehydrogenase type III mRNA, completecds.	47	0.000115034
emb MM17BDH M.musculus mRNA for 17-beta-hydroxysteroid dehydrogenase type 1	45	0.000256269
emb RH13762 Rattus norvegicus liver microsomal retinol dehydrogenase type I mRNA, complete cds.	45	0.000437129
emb AF100830 Oncorhynchus mykiss carbonic anhydrase/20beta-hydroxysteroid dehydrogenase B mRNA, complete cds.	34	0.590798
emb AF100831 Oncorhynchus mykiss carbonic anhydrase/20beta-hydroxysteroid dehydrogenase A mRNA, complete cds.	34	0.590798

emb|RNDHYDEH Sprague-Dawley D-beta-hydroxybutyrate dehydrogenase mRNA, completecds.

Length = 1420
Score = 88 bits (216), Expect = 4.50265e-17
Identities = 63/258 (24%), Positives = 122/258 (47%), Gaps = 3/258 (1%)
SAHADSHPSRWLTTSADTDALGLQLCTHLANKGYRFAIG--MKEAQDQSPAKLKGMMKIREYSEEPIASTIIPMRLDVTRDVLREATVIIGANLNADERGIARVINTSGSVFRQQVESQNQQMEHLRTNLGTL
++ AD+ + VL+T D+ G L HL +KG+ VFAG +KE D+ +RE + + + ++L+V + + +A + + L E+G+ ++N +G G+VE +++ ++ +N+ GT+R K+F+ LR +GR++ ++ G R + ++ V+ ++ L
T\$QADARS\$KAVLVLTGCGSGFGFSLAKHLH\$KGFLVFGCLLKEQGDA-----GVREL-DSLKSDLRLTIQLNVNCSEEVEKAVETVRSGLKPEKGMMGLVNAGISTFGEVEFTSMETYKEVENVLWGT

emb|MM17BDTII M.musculus mRNA for 17-beta-hydroxysteroid dehydrogenase type II

Length = 1342