

XML-Praxis

XML – Extensible Markup Language

Jörn Clausen

joern@TechFak.Uni-Bielefeld.DE

Übersicht

- Woher? Wohin? Warum?
- Bestandteile von XML
- XML-Dokumente erstellen und bearbeiten

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

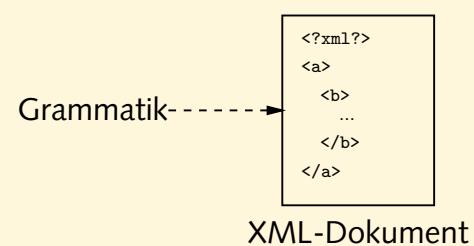
- Standard Generalized Markup Language
- 1986 als ISO-Standard 8879 verabschiedet
- *keine* Markup-Sprache, sondern Grammatik-Sprache
- Einsatz vor allem im Verlagswesen
- 1989: Hypertext Markup Language, World Wide Web
- Problem: komplexe Regeln, Parser schwer zu implementieren
- ab 1996: Entwicklung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

Verarbeitung von XML

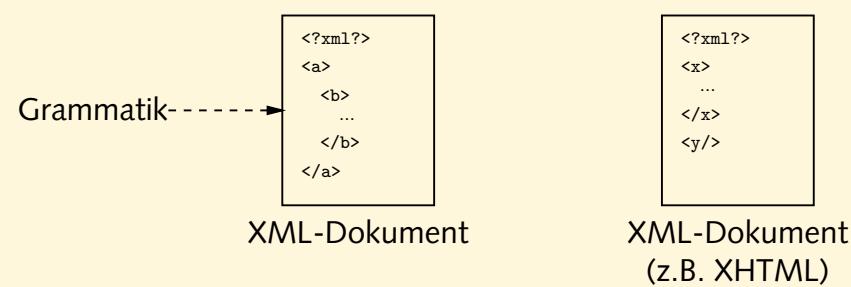
```
<?xml?>
<a>
  <b>
    ...
  </b>
</a>
```

XML-Dokument

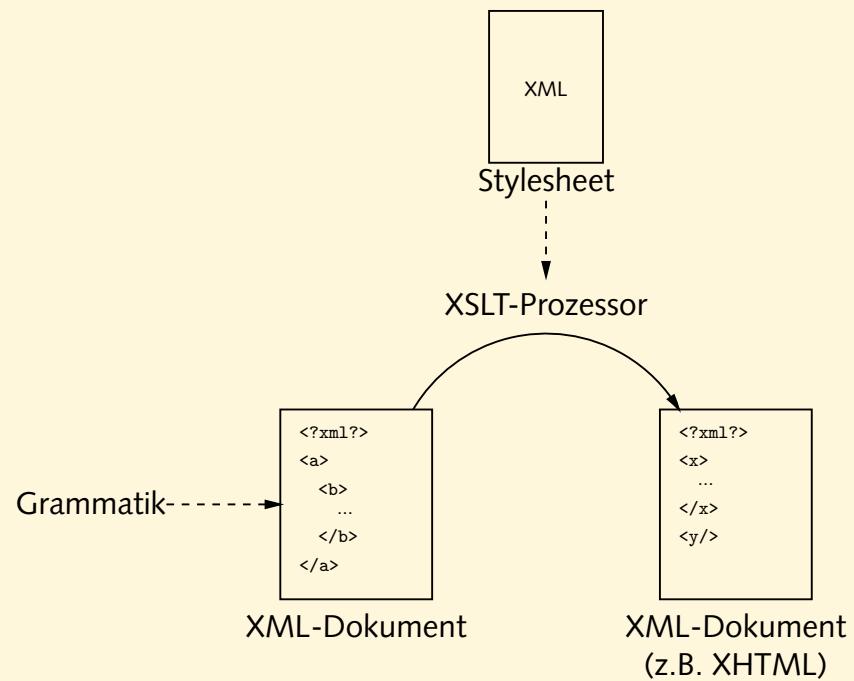
Verarbeitung von XML



Verarbeitung von XML



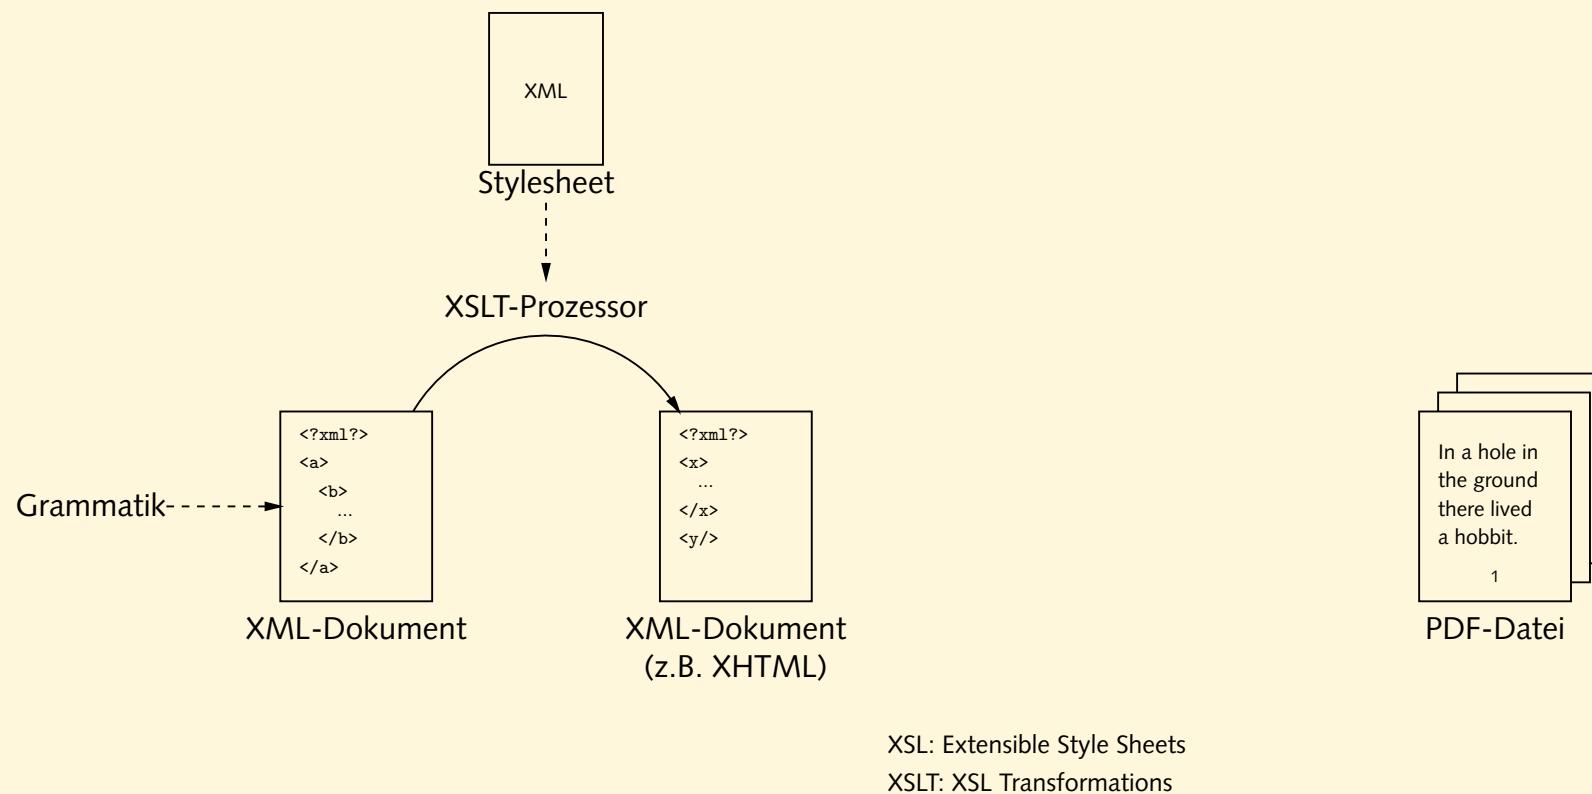
Verarbeitung von XML



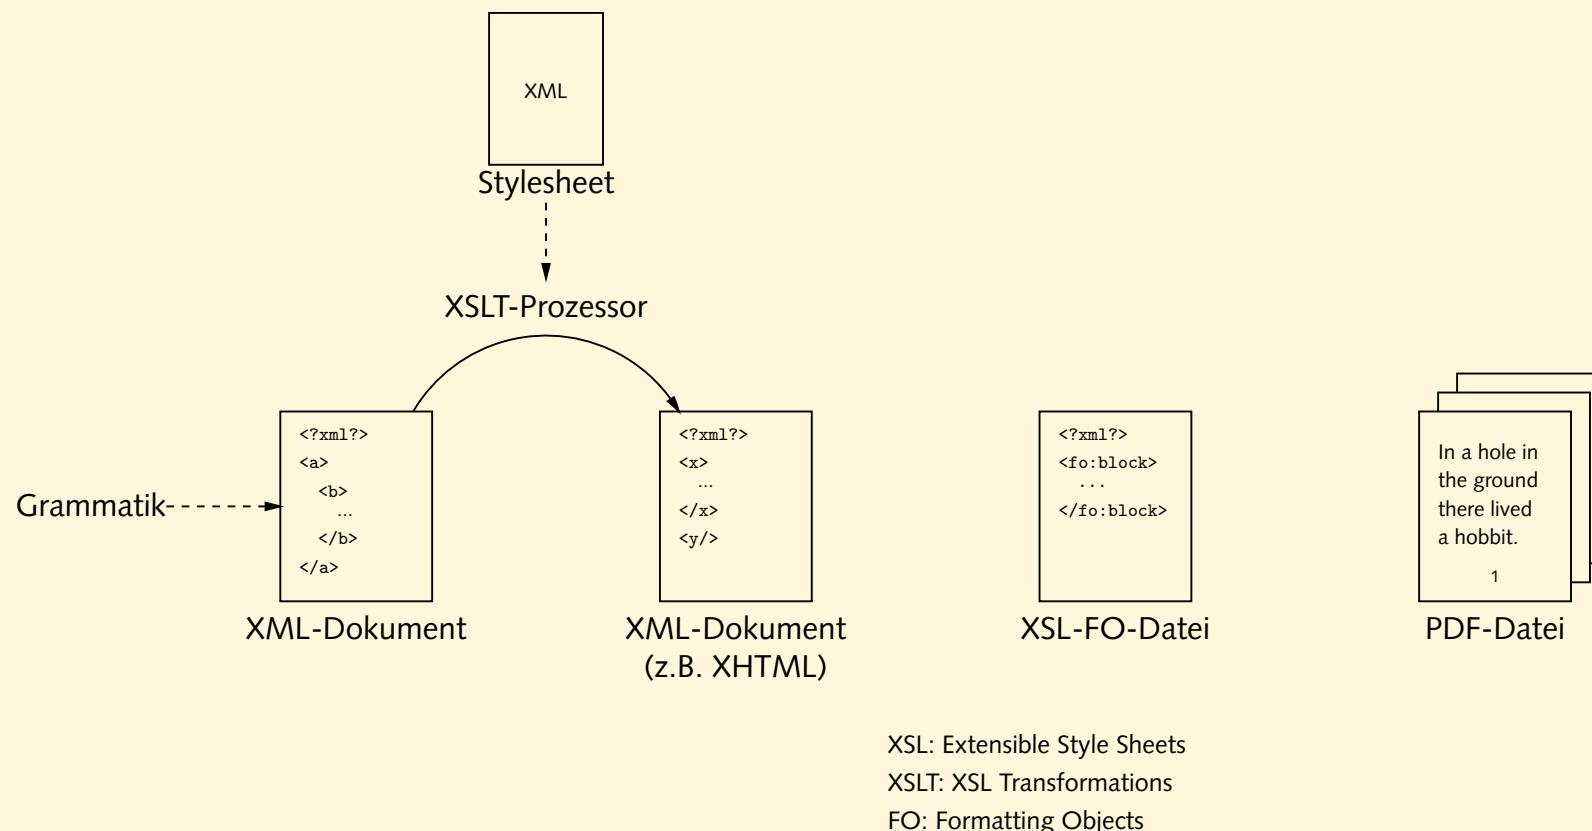
XSL: Extensible Style Sheets

XSLT: XSL Transformations

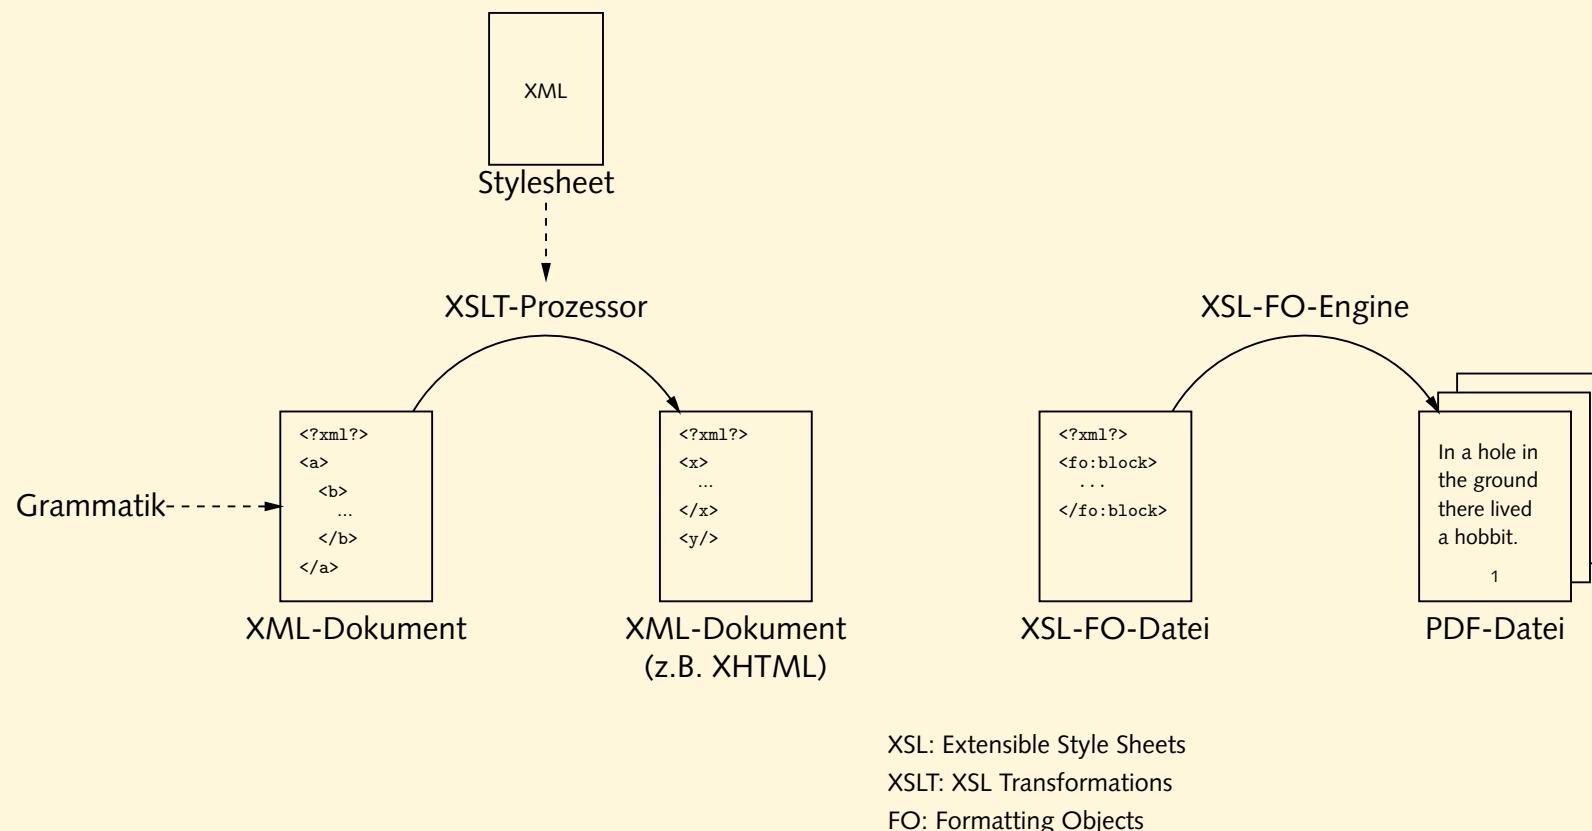
Verarbeitung von XML



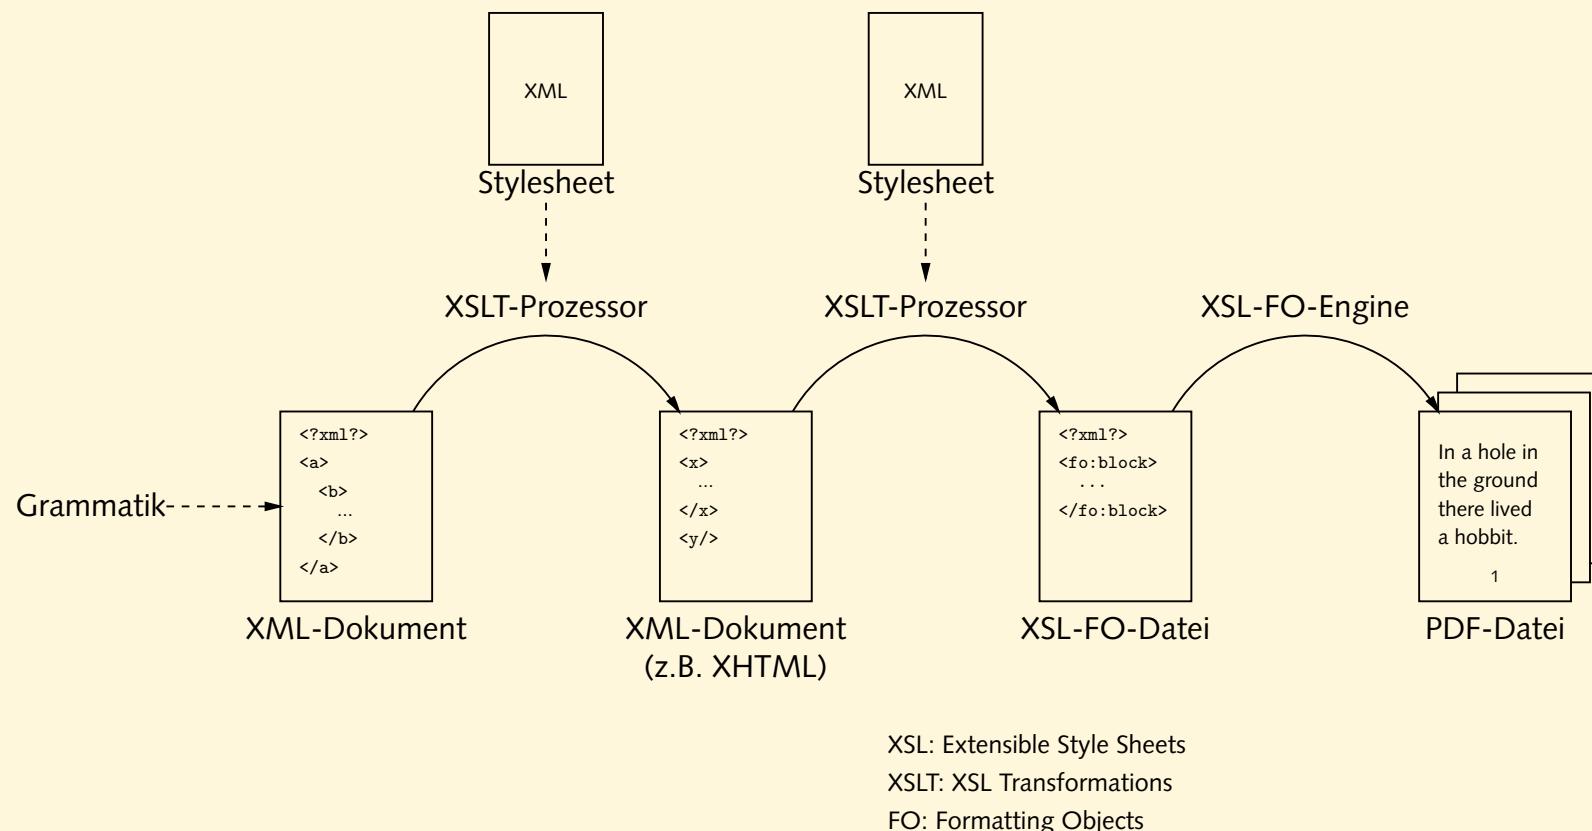
Verarbeitung von XML



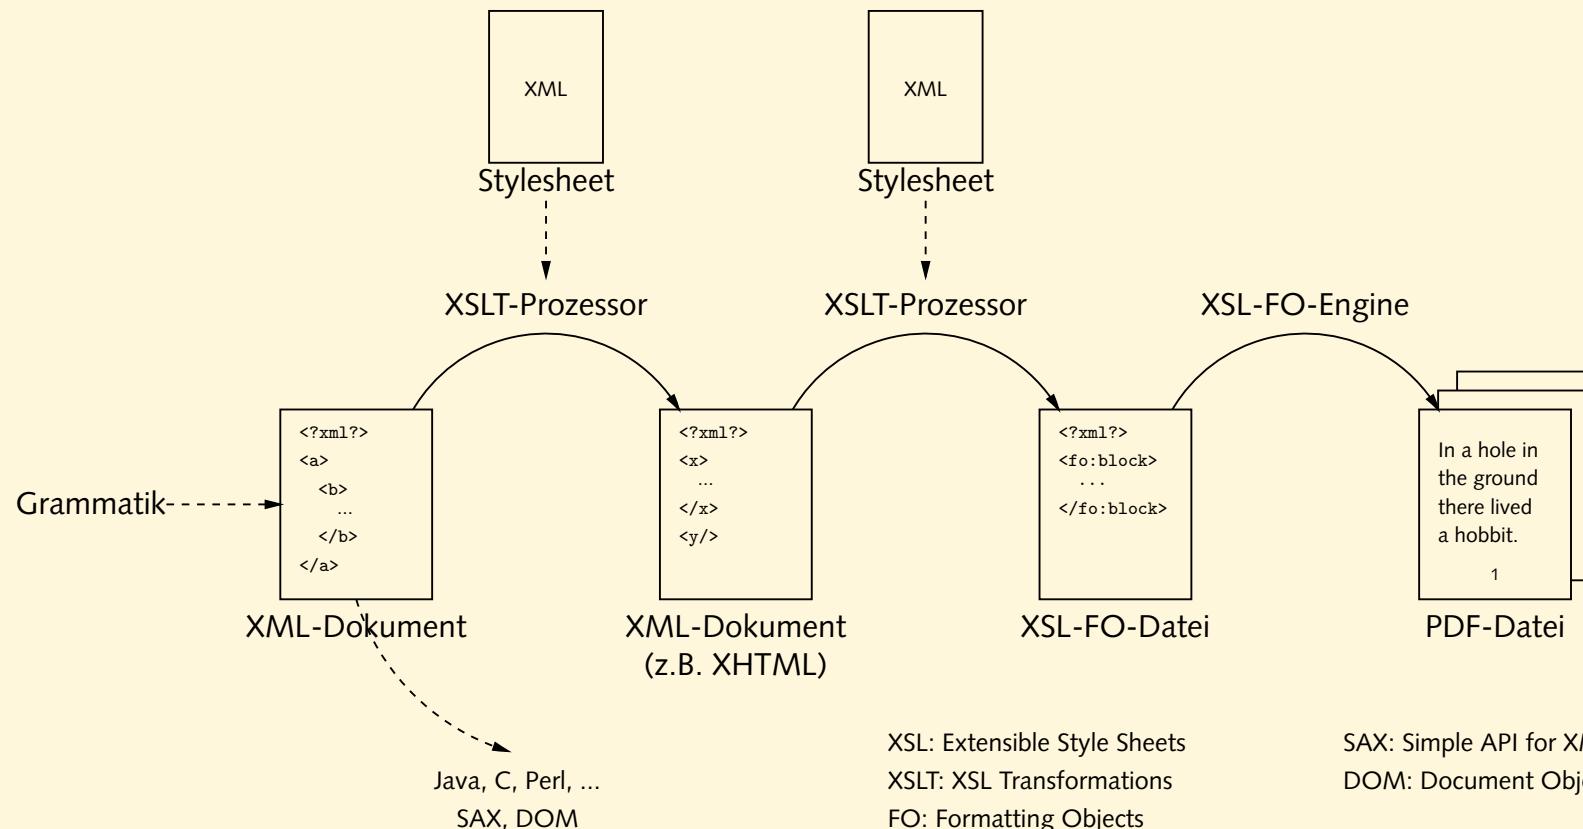
Verarbeitung von XML



Verarbeitung von XML



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

Aufgabe

- Sieh Dich etwas auf den Web-Seiten des W3-Konsortiums um:
<http://www.w3.org>
- Finde die Spezifikationen („Recommendations“) der folgenden Standards:
 - XML 1.0 (Second Edition)
 - XSLT 1.0
 - XPath 1.0
- Sieh Dir die Web-Seiten der „Organization for the Advancement of Structured Information Standards“ (OASIS) an:

<http://www.oasis-open.org>

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>
```

```
<comment>
```

```
...
```

```
</comment>
```

Aufgaben

- Was stimmt mit den Dateien `bogus1.xml`, `bogus2.xml` und `bogus3.xml` nicht? Überprüfe sie mit Hilfe der Programme `xmlwf` und `xml lint`. Verbessere die Fehler.
- Erstelle mit Hilfe des Emacs eine einfache Telefonliste in Form einer XML-Datei. Achte auf die Dateiendung `.xml` und darauf, daß der XML-Mode verwendet wird.

Verwende die folgenden Tastenkombinationen beim Schreiben der XML-Datei:

- TAB-Taste: Zeile einrücken
- CTRL-C /: schließendes Tag einfügen

Kommentare

- Kommentare kennzeichnen:

```
<!-- fix some spelling errors here -->
```

- mehrzeilige Kommentare möglich
- -- darf nicht im Kommentar vorkommen
- keine geschachtelten Kommentare

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">
```

- Design-Frage: Wann Elemente, wann Attribute?

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

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

Aufgaben

- Erweitere die XML-Datei aus der letzten Ausgabe um folgende Angaben:
 - Anschrift
 - EMail-Adresse
 - Geburtsdatum
- Pro Person sollen mehrere Telefonnummern gespeichert werden können. Es soll zwischen Festnetz, Handy und Fax unterschieden werden.
- Die bevorzugte Form der Kontaktaufnahme (Telefon, Handy, Fax, EMail) soll kenntlich gemacht werden.

Entitäten (entities)

- Makros und Sonderzeichen
- in XML vordefinierte *entity references*
`& < > ' "`
- weitere können definiert werden
- *character references*: Zugriff auf beliebige Unicode-Zeichen
`© 2002 by Jörn Clausen`

Aufgaben

- Was passiert, wenn Du die Zeichen
 & < > ' "
direkt im Text (zwischen zwei Tags) oder in einem Attribut
verwendest? Teste wieder mit `xmlwf` bzw. `xmllint`.
- Was passiert, wenn Du die character reference
 ``
verwendest?

Aufgaben

- Beschreibe die folgenden Dinge mit Hilfe von XML:
 - Fußball-Tabelle
 - Liste mit Fußball-Ergebnissen
 - Periodensystem der chemischen Elemente
 - DNA-Sequenz
 - Gedicht
 - Lebenslauf
 - Brief
 - Roman
- Wofür ist XML ungeeignet?