Freie Universität Berlin

Document Type Definitions (DTDs)

Markus Luczak-Rösch
Freie Universität Berlin
Institut für Informatik
Netzbasierte Informationssysteme
mail@markus-luczak.de

Sprachfamilie

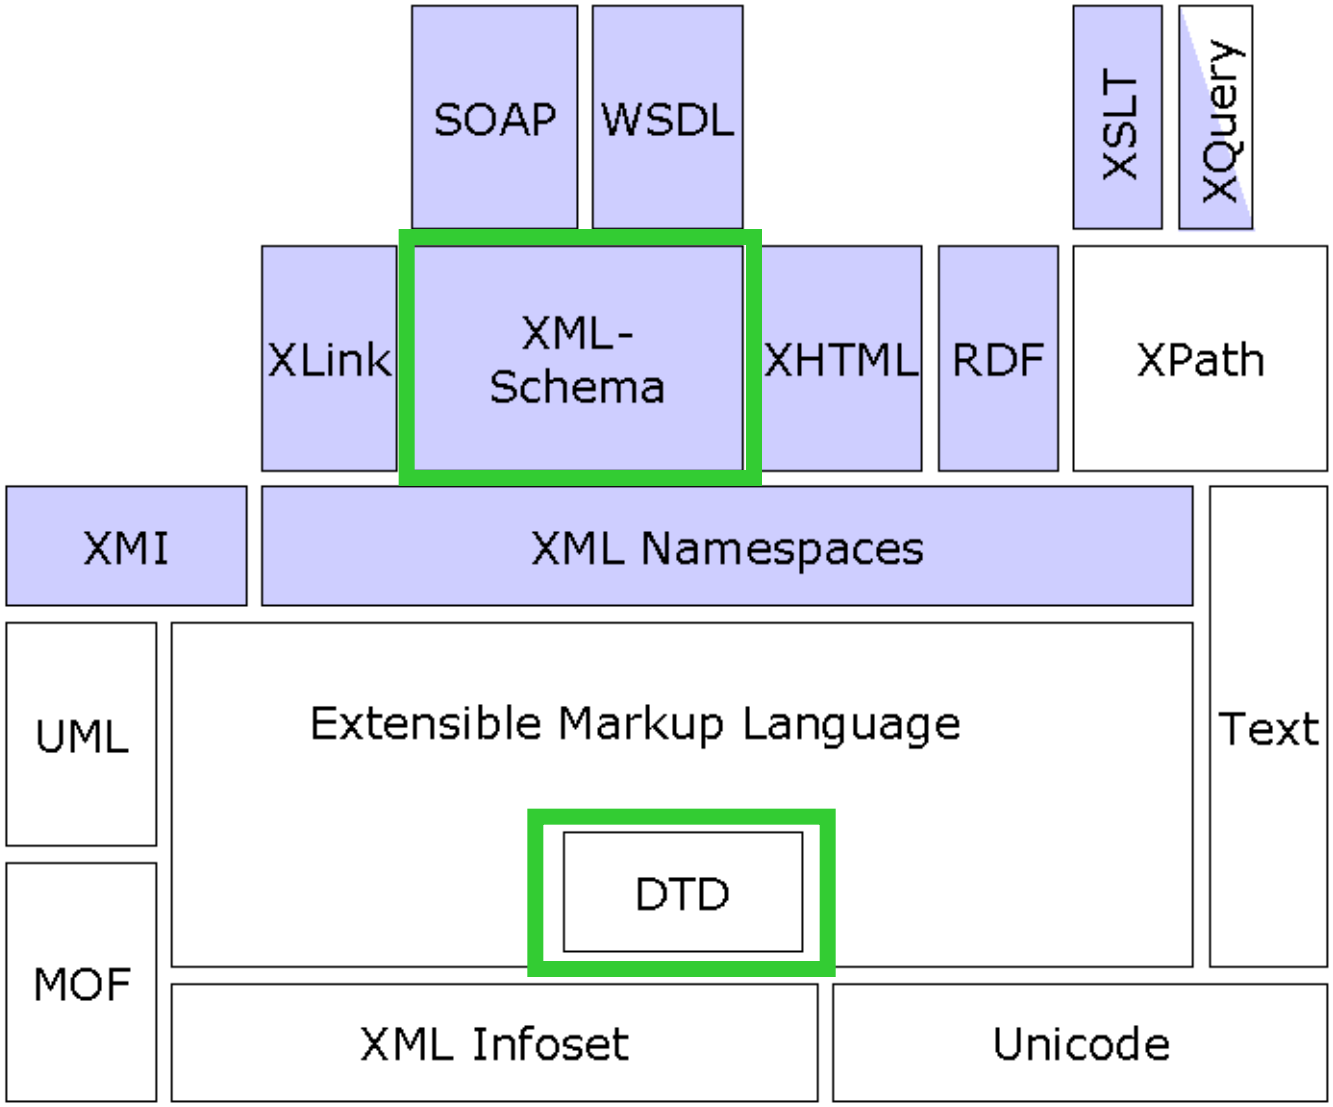

Quelle:http://www.jeckle.de/images/xml/languageFamily.gif

Motivation

Freie Universität Berlin

```
<book>
  <title>My Life and Times</title>
  <authors>
    <author>
      <first>Paul</first>
      <last>McCartney</last>
    </author>
  </authors>
  <date>
    <year>1998</year>
    <month>July</month>
  </date>
  <isbn>94303-12021-43892</isbn>
  <publisher>McMillin
  Publishing</publisher>
</book>
```

oder so?

so?

```
<Book>
  <Title>My Life and Times</Title>
  <Author>Paul McCartney</Author>
  <Date>July, 1998</Date>
  <ISBN>94303-12021-43892</ISBN>
  <Publisher>McMillinPublishing</Publisher>
</Book>
```

⇨ einheitliches Format nötig

⇨ Format sollte durch XML-Prozessor validierbar sein

Typen von Daten im Netz

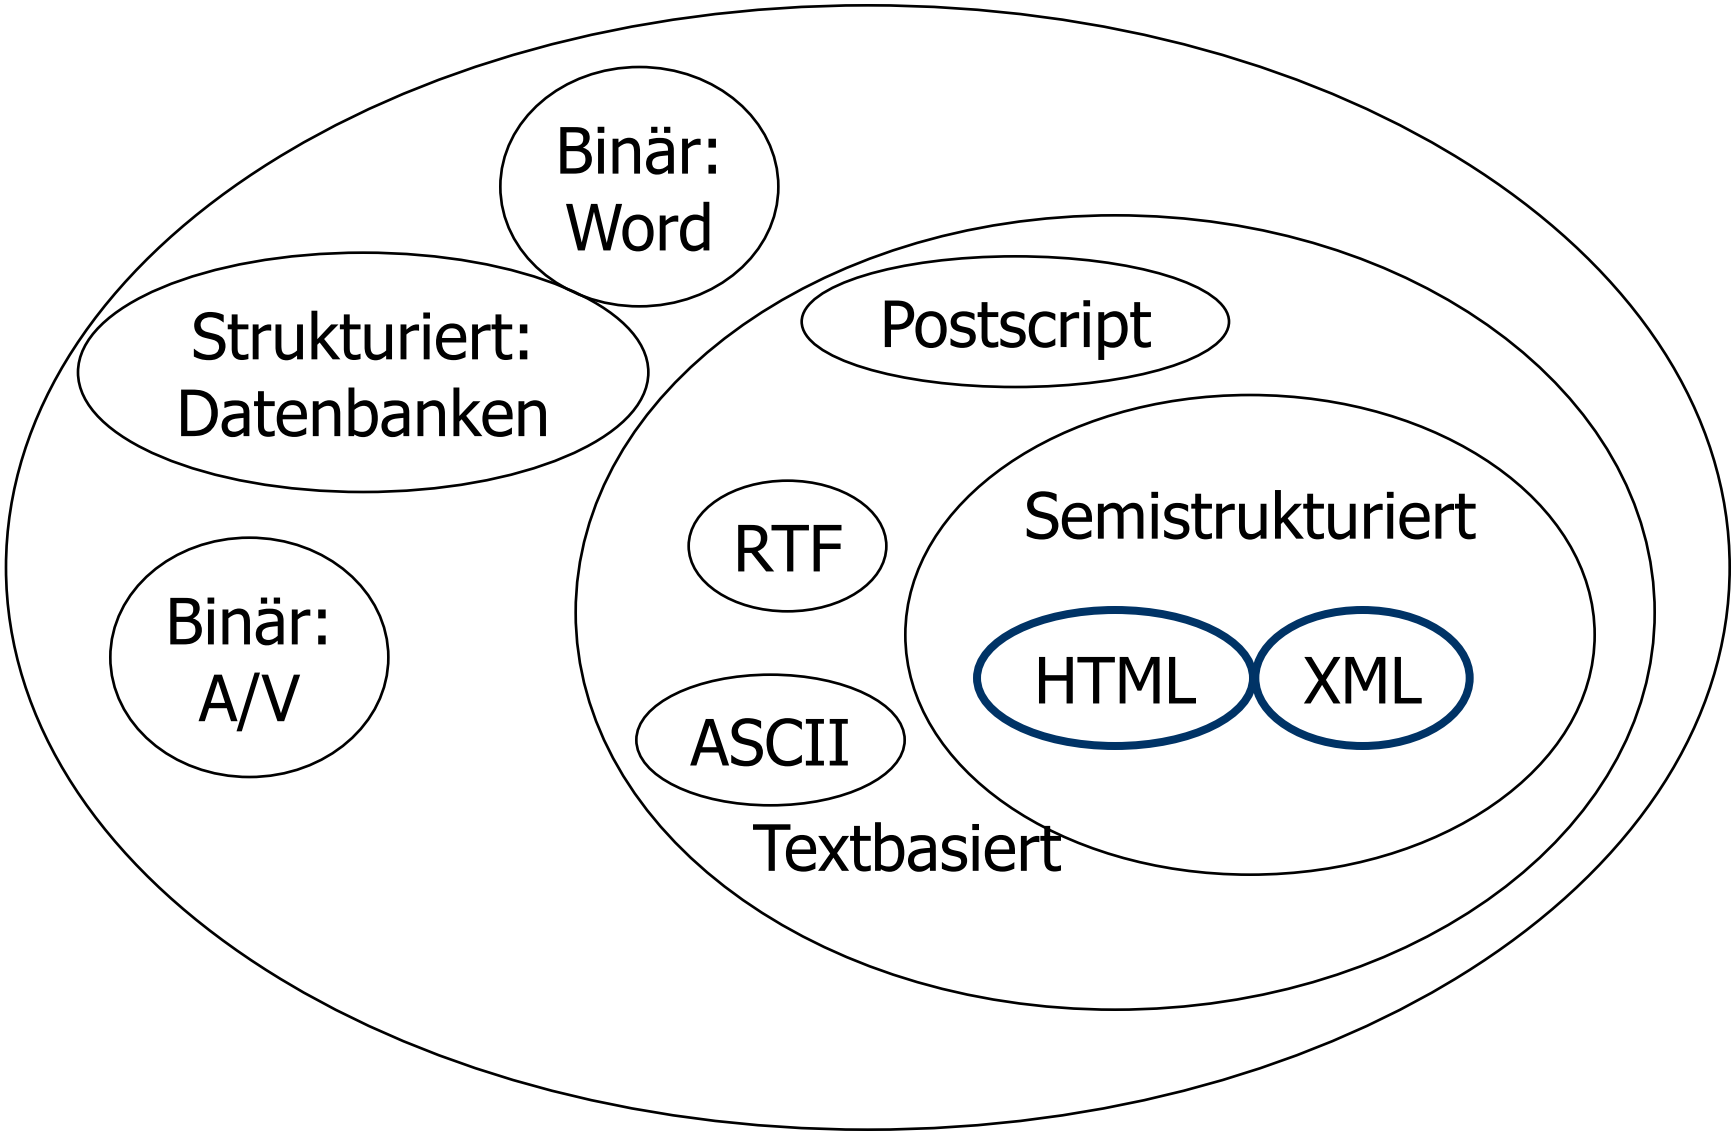

Typen von XML Dokumenten

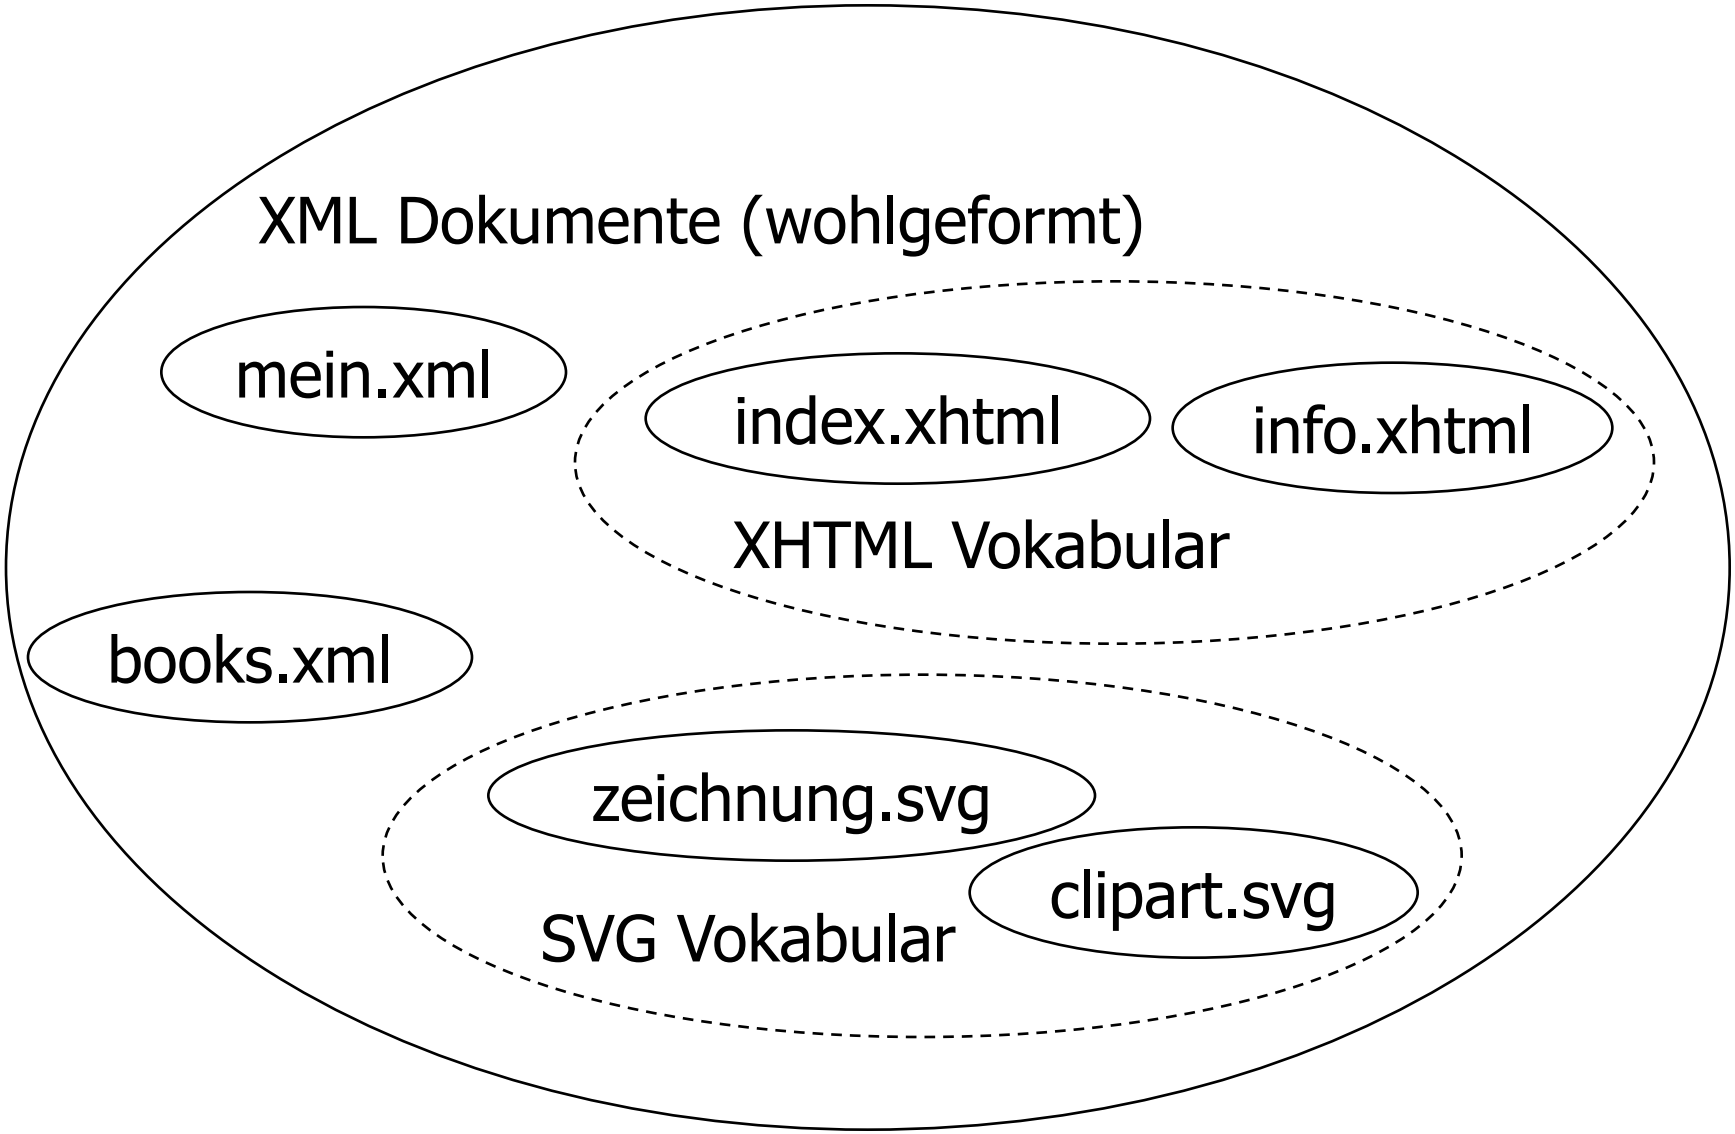

Dokument-Typ

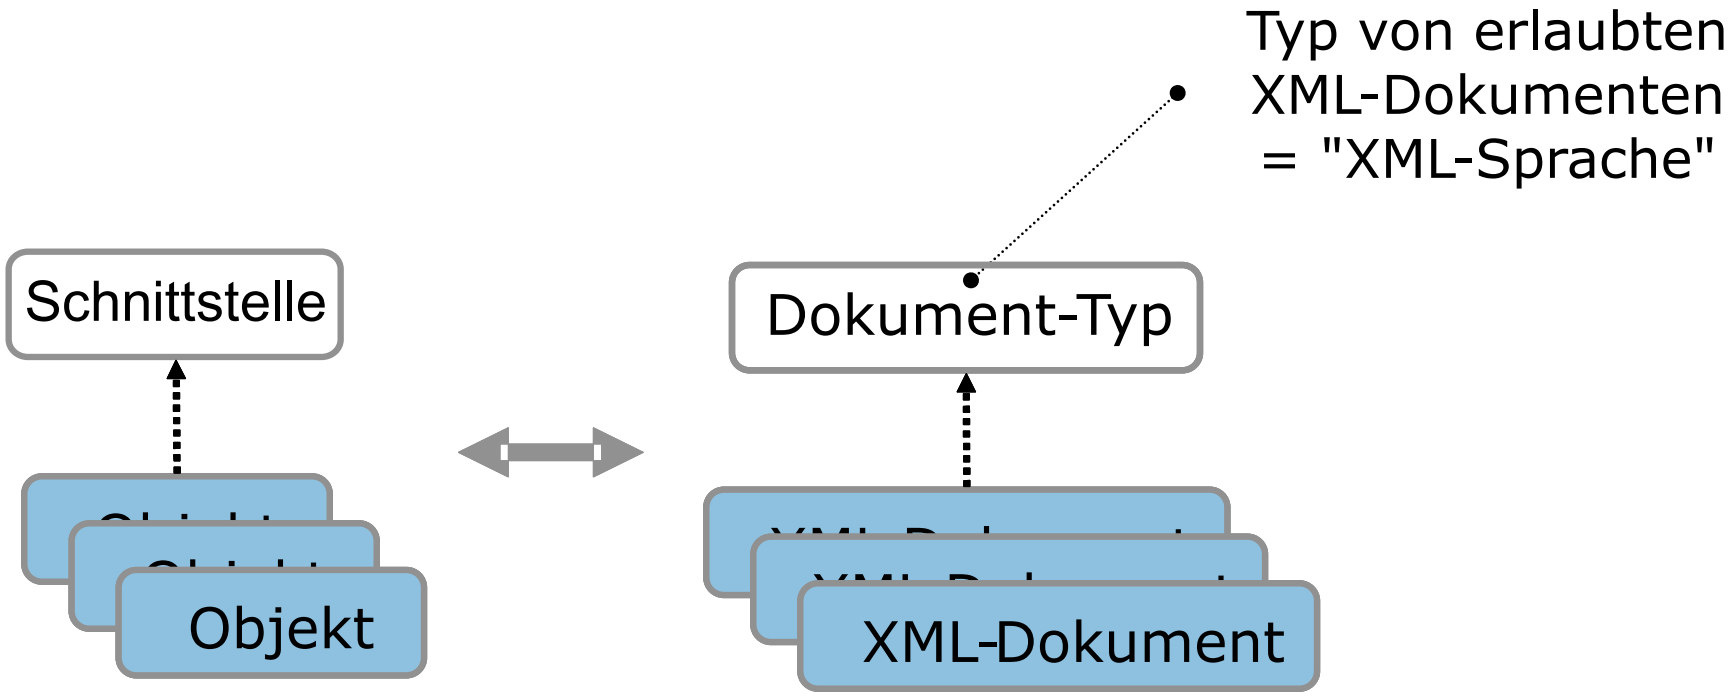

- Dokument-Typ definiert mit einer DTD, einem XML-Schema oder ähnlichen Formalismen

Spezifische Formate

- **prinzipieller Aufbau von Dokumenten**: Welche Elemente/Attribute?
- **Datentypen der Inhalte**: Welche Inhalte?

```
<Book>
  <Title> PCDATA </Title>
  <Author> PCDATA
  </Author>
  <Date> PCDATA </Date>
  <ISBN> PCDATA </ISBN>
  <Publisher> PCDATA
  </Publisher>
</Book>
```

- konkrete Inhalte werden nicht beschrieben

⇨ Klasse von erlaubten XML-Dokumenten

Document Type Definitions (DTDs)

Wie sieht eine DTD hierfür aus?

```
<BookStore>
  <Book>
      <Title>My Life and Times</Title>
      <Author>Paul McCartney</Author>
      <Date>July, 1998</Date>
      <ISBN>94303-12021-43892</ISBN>
      <Publisher>McMillin Publishing</Publisher>
  </Book>
</BookStore>
```

- BookStore soll mindestens ein Buch enthalten.
- ISBN optional
- alle anderen Kind-Elemente obligatorisch

Die DTD für das Beispiel-Dokument

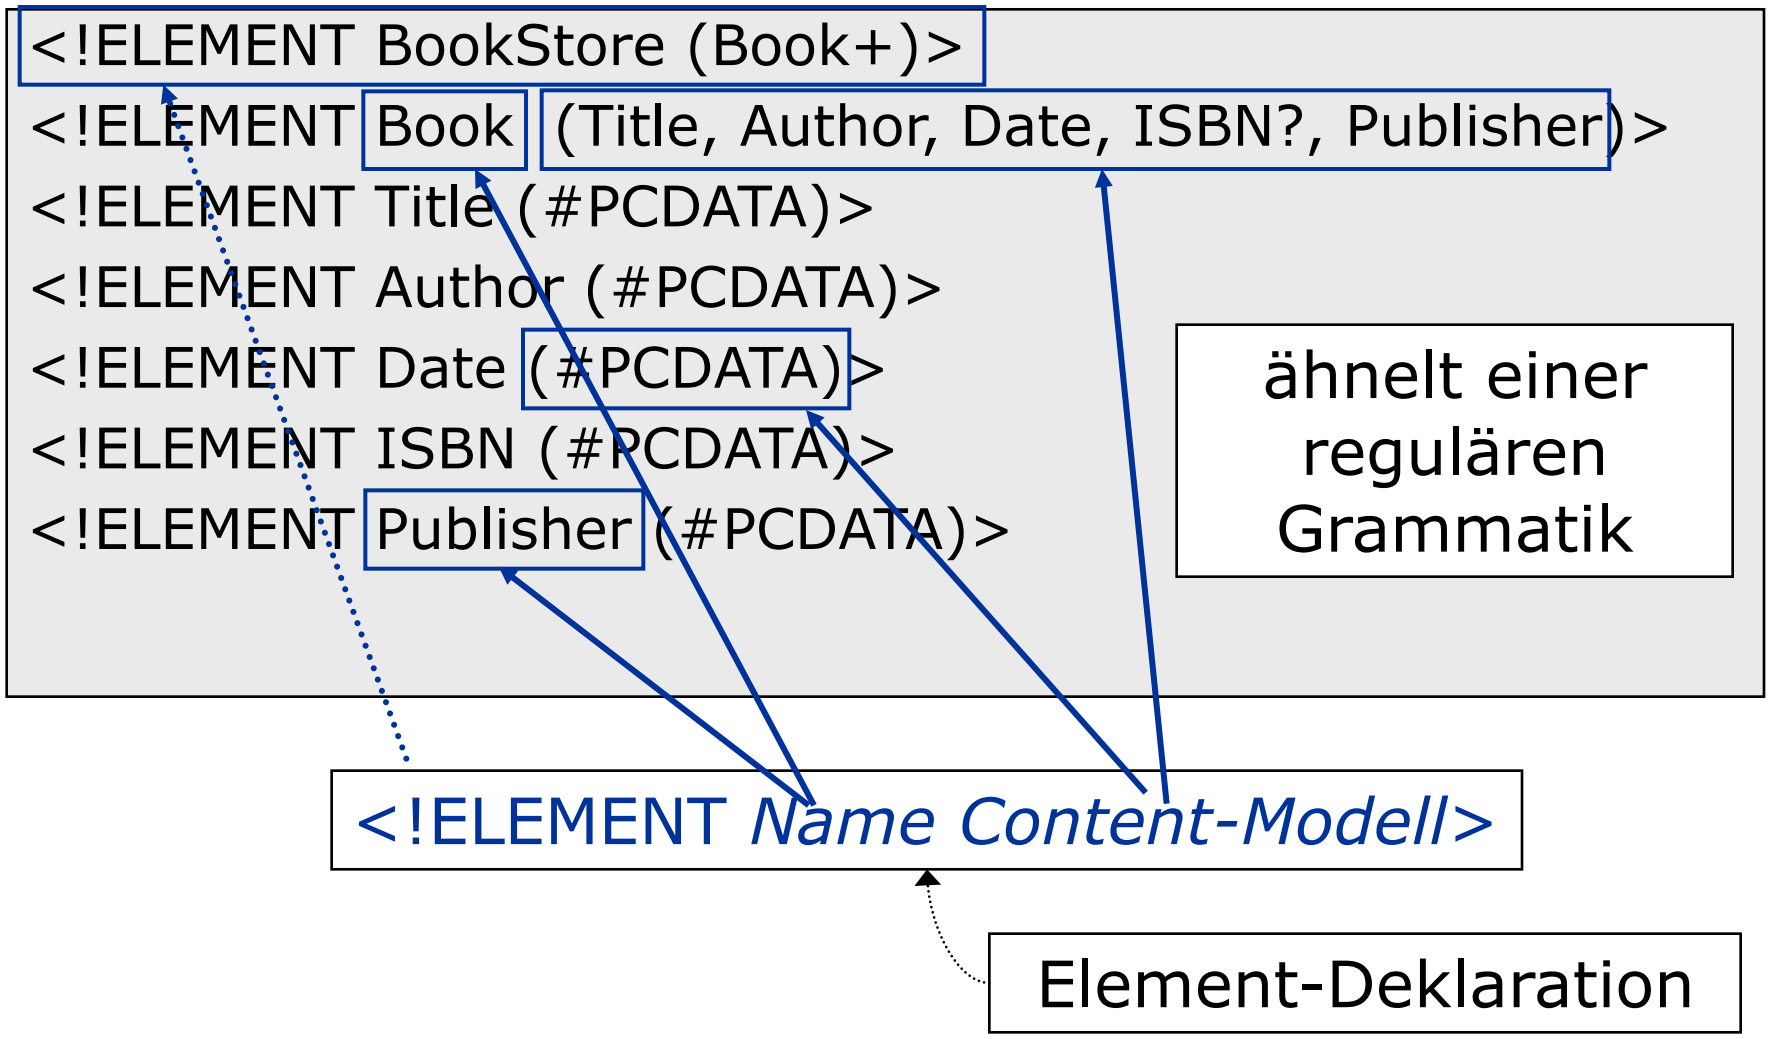

Elementdeklaration: Datentypen für Inhalte

Freie Universität Berlin

- Element:
  Ausdruck über Elemente mit Symbolen , + * | ?
- #PCDATA:
  unstrukturierter Inhalt ohne reservierte Symbole (<,&)
  <!ELEMENT Title (#PCDATA)>
- EMPTY:
  leerer Inhalt, Element kann Attribute haben
  <!ELEMENT hr EMPTY>:<hr height="3"/>
- ANY:
  beliebiger Inhalt (strukturiert, unstrukturiert, gemischt oder leer)
  <!ELEMENT Absatz ANY>

- Keine gewohnten Datentypen wie INTEGER oder FLOAT

Deklaration von BookStore


```
<!ELEMENT BookStore (Book+)>
```

```
<BookStore>
  <Book>…</Book>
  <Book>…</Book>
</BookStore>
```

- +: n Wiederholungen mit n > 0.
- *: n Wiederholungen mit n ≥ 0.

- BookStore hat mindestens ein Kind Book
- Außer Book darf BookStore keine anderen Kind-Elemente haben.

Rekursive Deklarationen

```
<!ELEMENT BookStore (Book | (Book, BookStore))>
```

- Bookstore besteht aus genau einer der Alternativen:
  - genau ein Kind-Element Book
  - zwei Kind-Elemente: Book und BookStore

- | : Auswahl, genau eine der beiden Alternativen
- , : Sequenz von Elementen.

- Beachte: Rekursive Deklaration nicht äquivalent zur vorherigen, iterativen Definition!

Rekursive vs. iterative Deklaration

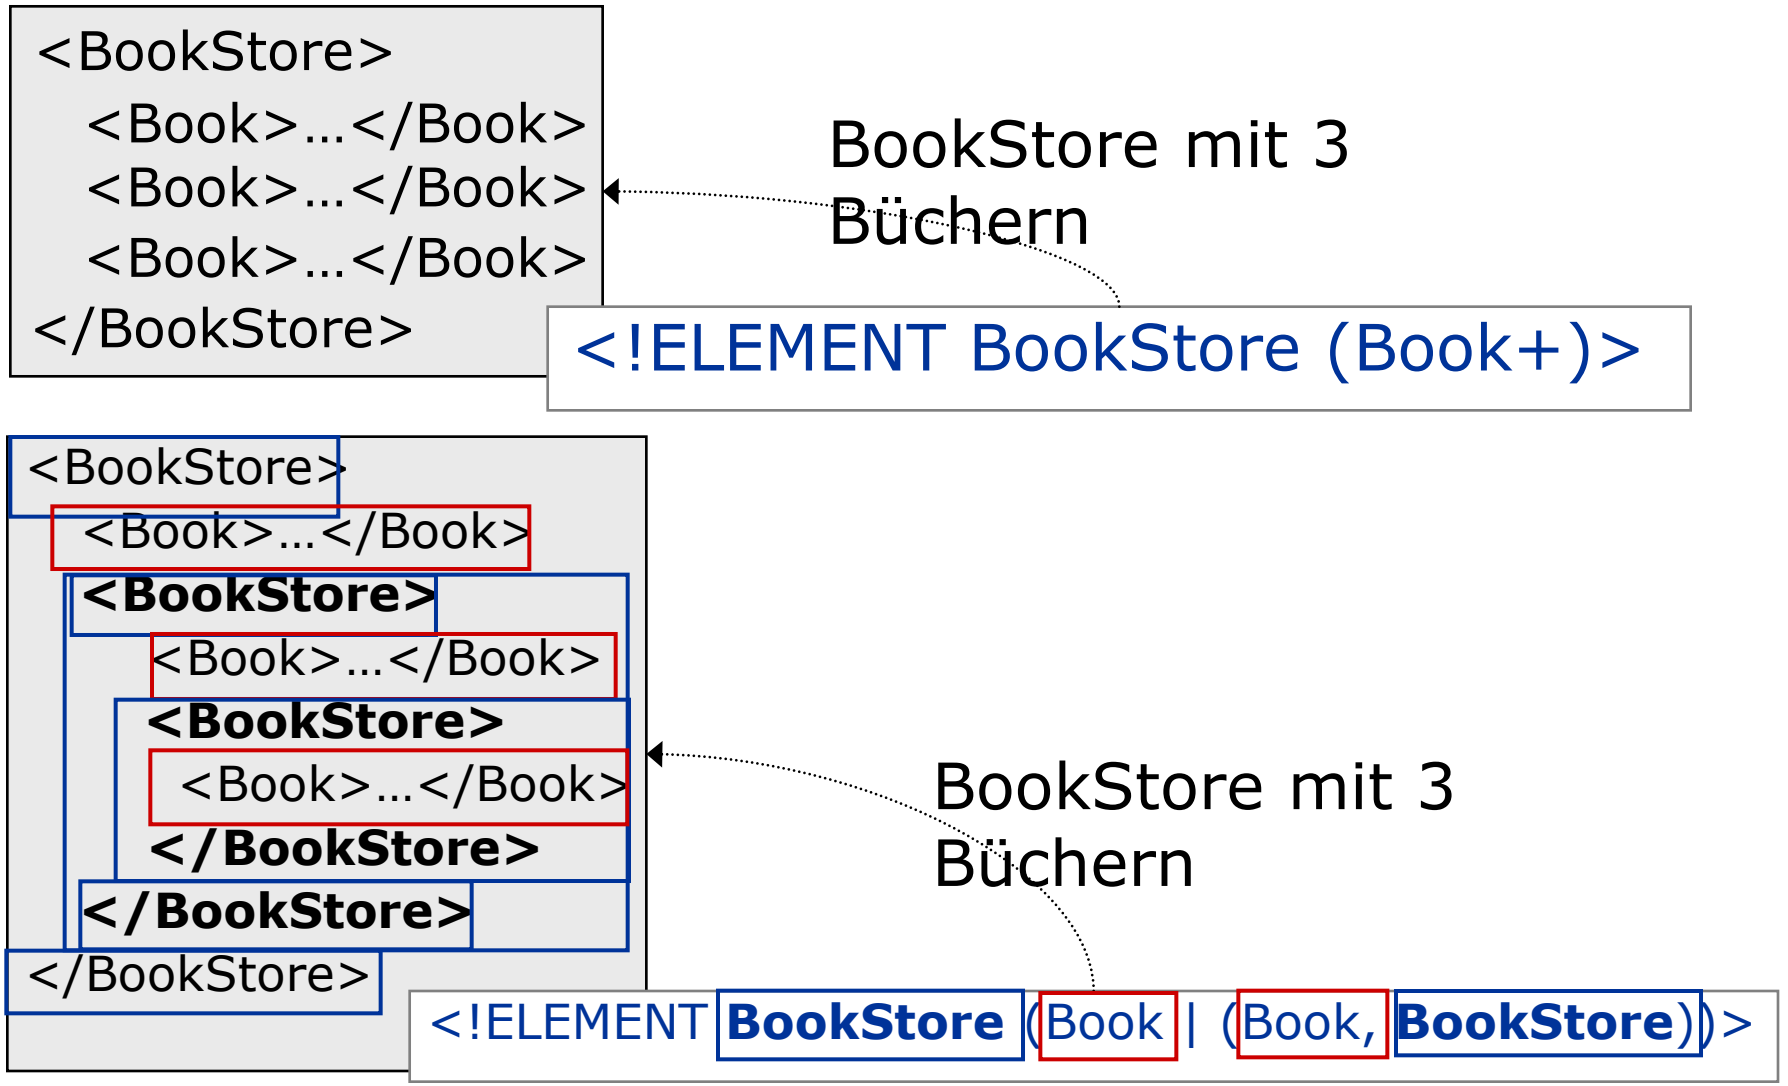

Die DTD für das Beispiel-Dokument

```
<!ELEMENT BookStore (Book+)>
<!ELEMENT Book (Title, Author, Date, ISBN?, Publisher)>
<!ELEMENT Title (#PCDATA)>
<!ELEMENT Author (#PCDATA)>
<!ELEMENT Date (#PCDATA)>
<!ELEMENT ISBN (#PCDATA)>
<!ELEMENT Publisher (#PCDATA)>
```

Deklaration von Book


```
<!ELEMENT Book (Title, Author, Date, ISBN?, Publisher)>
```

- Title, Author, Date, ISBN und Publisher (in dieser Reihenfolge) Kind-Elemente von Book
- außer diesen keine anderen Kind-Elemente
- ? : optional

```
<Book>
   <Title>…</Title>
   <Author>…</Author>
   <Date>…</Date>
   <ISBN>…</ISBN>
   <Publisher>…</Publisher>
</Book>
```

Die DTD für das Beispiel-Dokument

```
<!ELEMENT BookStore (Book+)>
<!ELEMENT Book (Title, Author, Date, ISBN?, Publisher)>
<!ELEMENT Title (#PCDATA)>
<!ELEMENT Author (#PCDATA)>
<!ELEMENT Date (#PCDATA)>
<!ELEMENT ISBN (#PCDATA)>
<!ELEMENT Publisher (#PCDATA)>
```

Deklaration von Title etc.

```
<!ELEMENT Title (#PCDATA)>
<!ELEMENT Author (#PCDATA)>
<!ELEMENT Date (#PCDATA)>
<!ELEMENT ISBN (#PCDATA)>
<!ELEMENT Publisher (#PCDATA)>
```

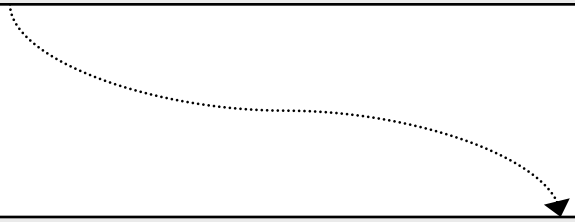

```
<Title>My Life and Times</Title>
<Author>Paul McCartney</Author>
<Date>July, 1998</Date>
<ISBN>94303-12021-43892</ISBN>
<Publisher>McMillin Publishing</Publisher>
```

Verschachtelungen

- beliebige Verschachtelung von Sequenz, Auswahl |, ?, *, + und Rekursion erlaubt
- Beispiel:

```
<!ELEMENT Chap (Title, (Para | Chap)+)>
<!ELEMENT Para ANY>
<!ELEMENT Title (#PCDATA)>
```

```
<Chap>
  <Title>Kap1</Title>
  <Para>Ein Absatz</Para>
  <Chap>
    <Title>Kap1.1</Title>
    <Para>…</Para>
  </Chap>
  <Para>…</Para>
  <Chap>
    <Title>Kap1.2</Title>
    <Para>…</Para>
  </Chap>
</Chap>
```

Einschränkung der Verschachtelung

Freie Universität Berlin

- Beispiel: ((b, c) | (b, d)) ist **nicht-deterministisch**
- Grund: Wenn erstes Element = b, dann kann XML-Prozessor keine der beiden Alternativen ausschließen.

- XML erlaubt nur **deterministische** Content Modelle
- jedes nicht-deterministische Content Modell kann in ein äquivalentes deterministisches umgeformt werden

- Beispiel: ((b, c) | (b, d)) = (b, (c | d))

DTDs: Attribut-Deklaration

Deklaration von Attributen

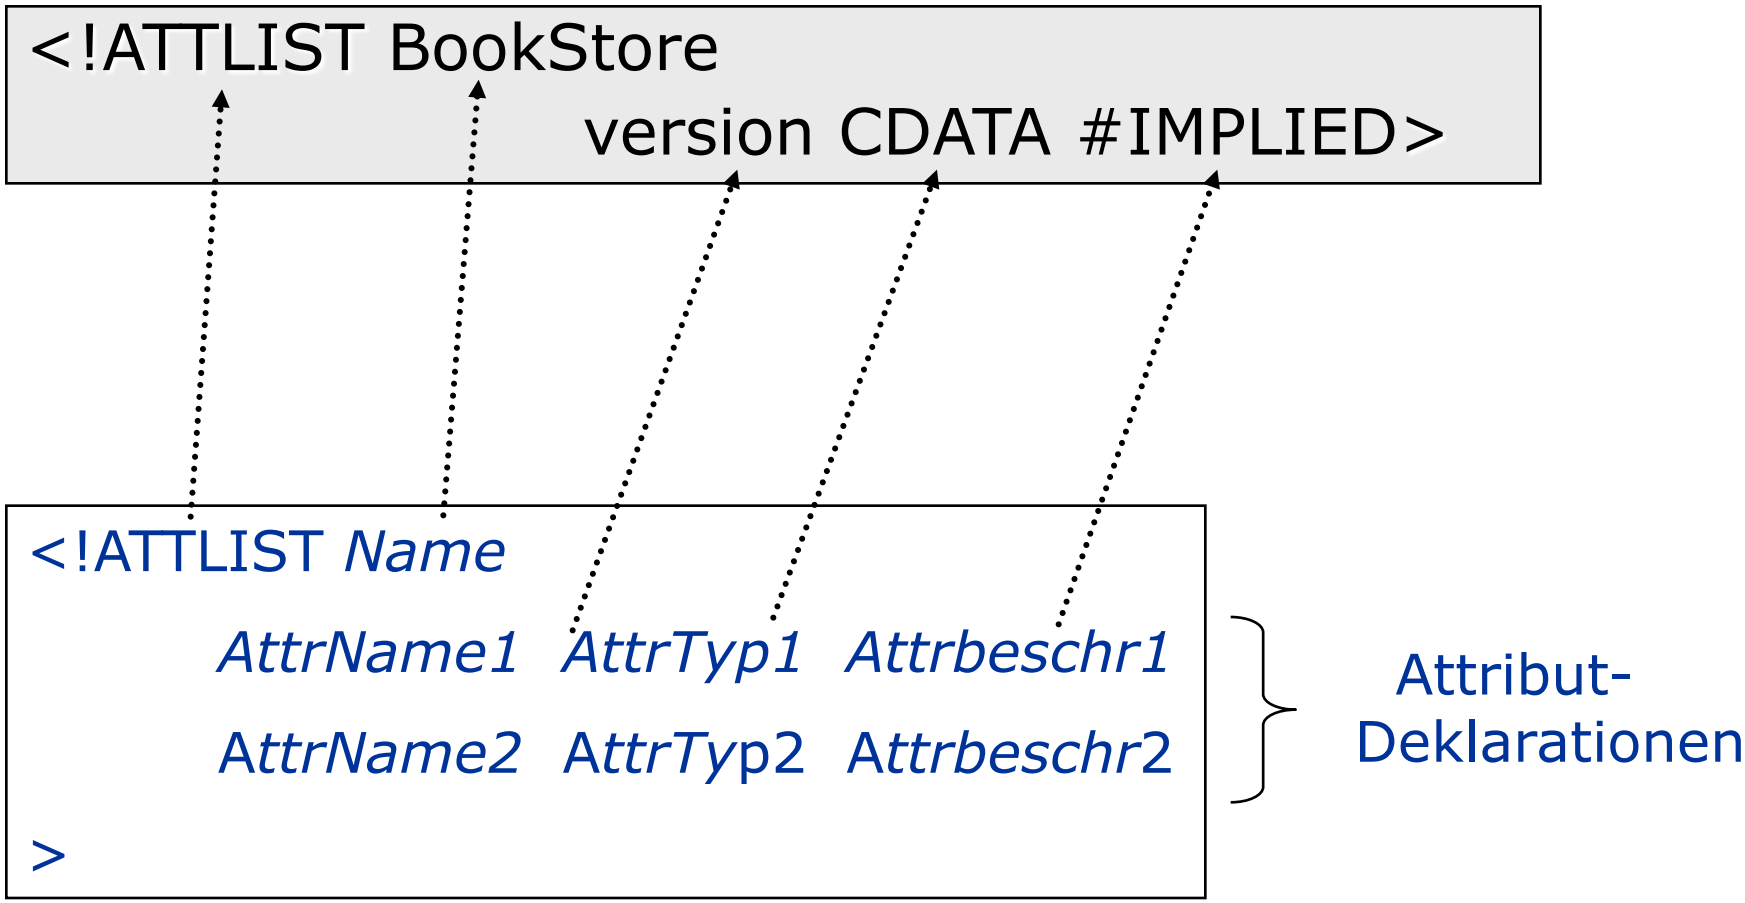

Deklaration von Attributen

```
<!ATTLIST BookStore
                    version CDATA #IMPLIED>
```

```
<BookStore version="1.0">
  …
</BookStore>
```

- BookStore hat Attribut version
- Außer version hat BookStore keine weiteren Attribute
- **CDATA**: Attribut-Wert = String ohne <, &, ', "
- Beachte: nicht verwechseln mit <![CDATA[…]]>
- daher Entity References für <, & und ' bzw. " verwenden

Aufzählungstypen

```
<!ATTLIST Author
                    gender (male | female) "female">
```

- hier statt CDATA **Aufzählungstyp**:
- Attribut gender hat entweder Wert male oder female.
- "female" ist Standard-Wert von gender.

Weitere Datentypen für Attribute

Freie Universität Berlin

Zusätzlich zu CDATA (Strings) und Aufzählungstypen:

- **NMTOKEN**: String, der Namenskonventionen von XML entspricht
- **ID**: eindeutiger Bezeichner, der Namenskonventionen von XML entspricht
- **IDREF**: Referenz auf einen eindeutigen Bezeichner

NMTOKEN

- Leerzeichen nicht zulässig
- eignet sich somit dazu Werte mit Leerzeichen auszuschließen

```
<!ELEMENT Datei EMPTY>
<!ATTLIST Datei Name NMTOKEN  #REQUIRED>
```

```
<Datei Name="readme.txt"/>
```

```
<!ELEMENT Woerterbuch (#PCDATA)>
<!ATTLIST Woerterbuch ISBN NMTOKEN #REQUIRED>
```

```
<Woerterbuch ISBN="3-57710-446-5">
Deutsches Wörterbuch
</Woerterbuch>
```

Beispiel von: http://www.maik-stuehrenberg.de/arbeit/projekte/milca/a-5-4/A-5-4-3-3-3-3-2-7.xhtml

ID/IDREF

```
<!ATTLIST Author
                key ID #IMPLIED
                keyref IDREF #IMPLIED>
```

- Wert des Attributes key muss eindeutig sein:
  Zwei Attribute vom Typ ID dürfen nie gleichen Wert haben
- Wert von keyref muss gültige Referenz sein:
  keyref muss Wert eines Attributes vom Typ ID sein

Beispiel

```
<BookStore>
  <Book>
      <Title>Text</Title>
      <Author key="k1">Text</Author>
      <Date>Text</Date>
      <Publisher pkey="p1">Text</Publisher>
  </Book>
  <Book>
      <Title>Text</Title>
      <Author keyref="k1"/>
      <Date>Text</Date>
      <Publisher pkey="p1">Text</Publisher>
  </Book>
</BookStore>
```

Wert `k1` muss eindeutig sein: kein anderes Attribut vom Typ ID darf diesen Wert haben.

Referenz `k1` muss existieren: ein Attribut vom Typ ID muss den Wert `k1` haben.

Deklaration von Attributen

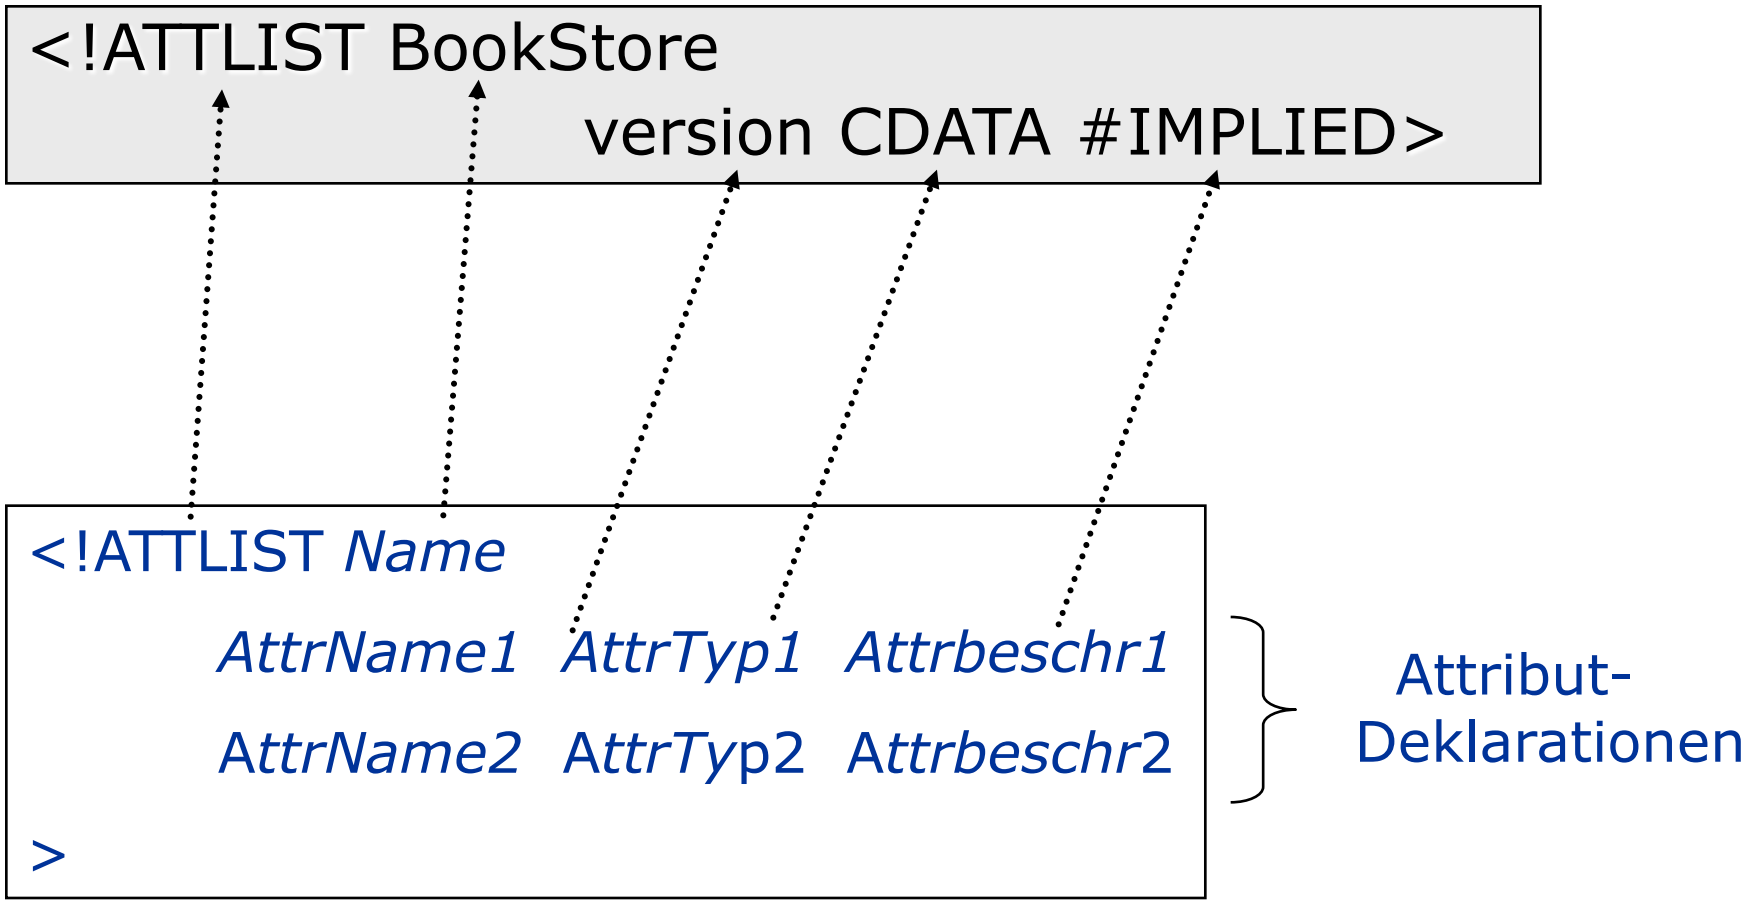

Optionale / erforderliche Attribute

Freie Universität Berlin

```
<!ATTLIST BookStore version CDATA #FIXED "1.0">
```

- **#FIXED**: Attribut hat immer den gleichen Wert
- **#IMPLIED**: Attribut optional
- **#REQUIRED**: Attribut obligatorisch

DTDs: Entitäten

XML Entitäten

- Vom letzten Mal:
  - Entity References in XML:
    - & ⇨ &
    - < ⇨ <
    - > ⇨ >
    - ' ⇨ ,
    - " ⇨ „
- Entities sind Abkürzungen für Zeichenfolgen
- In DTDs selbst definierbar

Deklaration von Entitäten

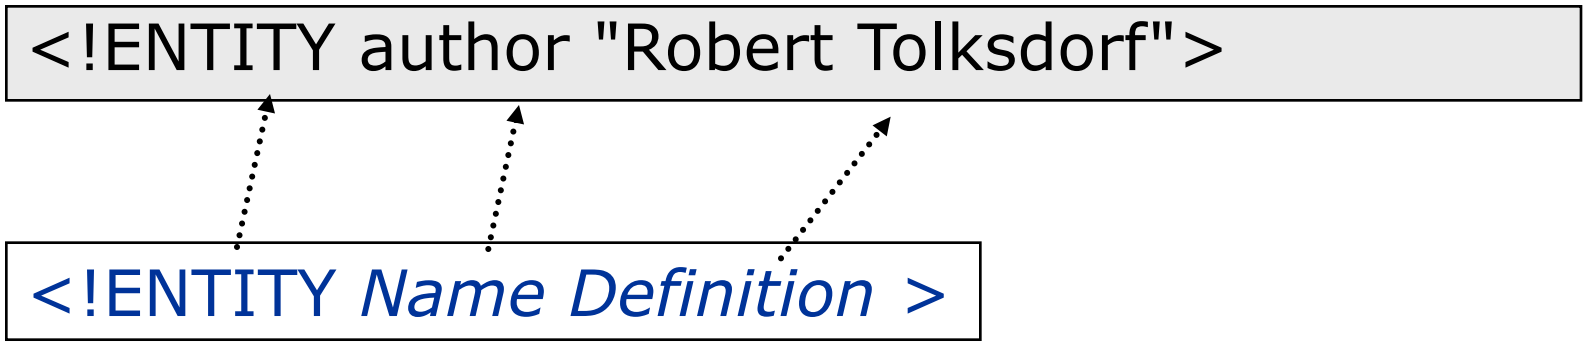

- Verwendung: <Fusszeile>Autor: &author</Fusszeile>
- "Import" aus externen Definitionen:
  <!ENTITY *fub* SYSTEM "http://www.fu-berlin.de/defs.dtd">
  <!ENTITY c PUBLIC "-//W3C//TEXT copyright//EN"
  "http://www.w3.org/xmlspec/copyright.xml">
- „General Entity" zur Verwendung in Dokumenten

Deklaration von Entitäten

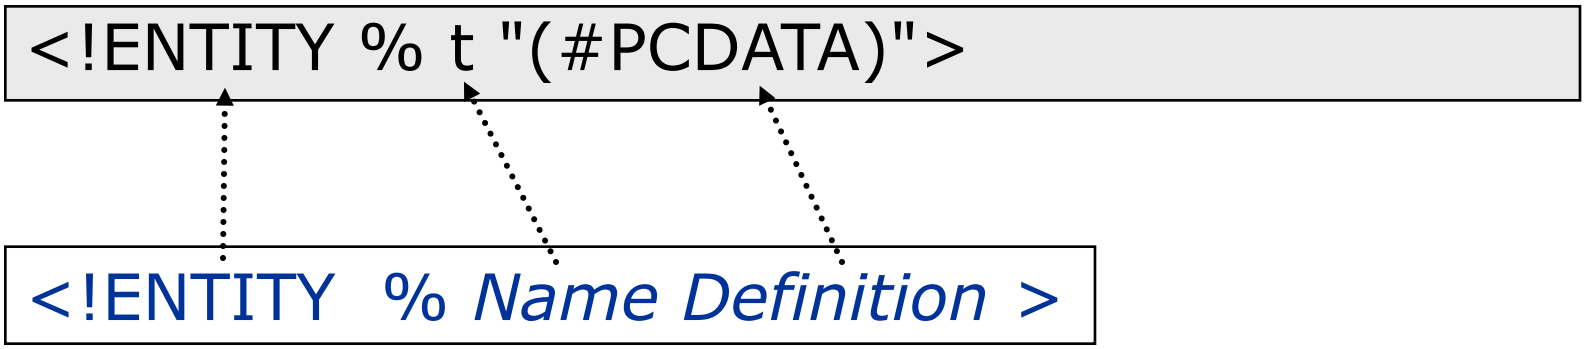

- „Internal Entity“ zur Verwendung in DTDs
- Verwendung: <!ELEMENT Fusszeile %t;>

- “Import” aus externen Definitionen:

```
<!ENTITY % fu-attribs SYSTEM "http://www.fu-berlin.de/defs.dtd">
<!ENTITY  % Shape PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"
 "http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
```

- %fu-attribs; übernimmt alle Definitionen aus der Datei

DTDs: Deklaration von Dokument-Typ

Deklaration des Dokument-Typs (Document Type Declaration)

Freie Universität Berlin

- vollständige DTD intern im XML-Dokument

  <!DOCTYPE *Wurzel-Element* **[...]**>

- ein Verweis auf eine externe DTD im XML-Dokument

  <!DOCTYPE *Wurzel-Element* SYSTEM "*DTD*">
  oder
  <!DOCTYPE *Wurzel-Element* PUBLIC "*DTD*" "*URL*" >

- Dokument-Typ direkt nach XML-Deklaration einfügen

Interne DTD

```
<?xml version="1.0" encoding="UTF-8" ?>
<!DOCTYPE BookStore [
 <!ELEMENT BookStore (Book+)>
 <!ELEMENT Book (Title, Author, Date, ISBN?, Publisher)>
 <!ELEMENT Title (#PCDATA)>
 <!ELEMENT Author (#PCDATA)>
 <!ELEMENT Date (#PCDATA)>
 <!ELEMENT ISBN (#PCDATA)>
 <!ELEMENT Publisher (#PCDATA)>
]>
 <BookStore>
   …
 </BookStore>
```

Externe DTD

<!DOCTYPE *Wurzel-Element* **SYSTEM** "*DTD*">

```
<?xml version="1.0" encoding="UTF-8" ?>
<!DOCTYPE BookStore SYSTEM "Bookstore.dtd">
<BookStore>
  ...
</BookStore>
```

```
<?xml version="1.0" encoding="UTF-16" ?>
<!DOCTYPE Book SYSTEM "Book.dtd">
<Book>
  ...
</Book>
```

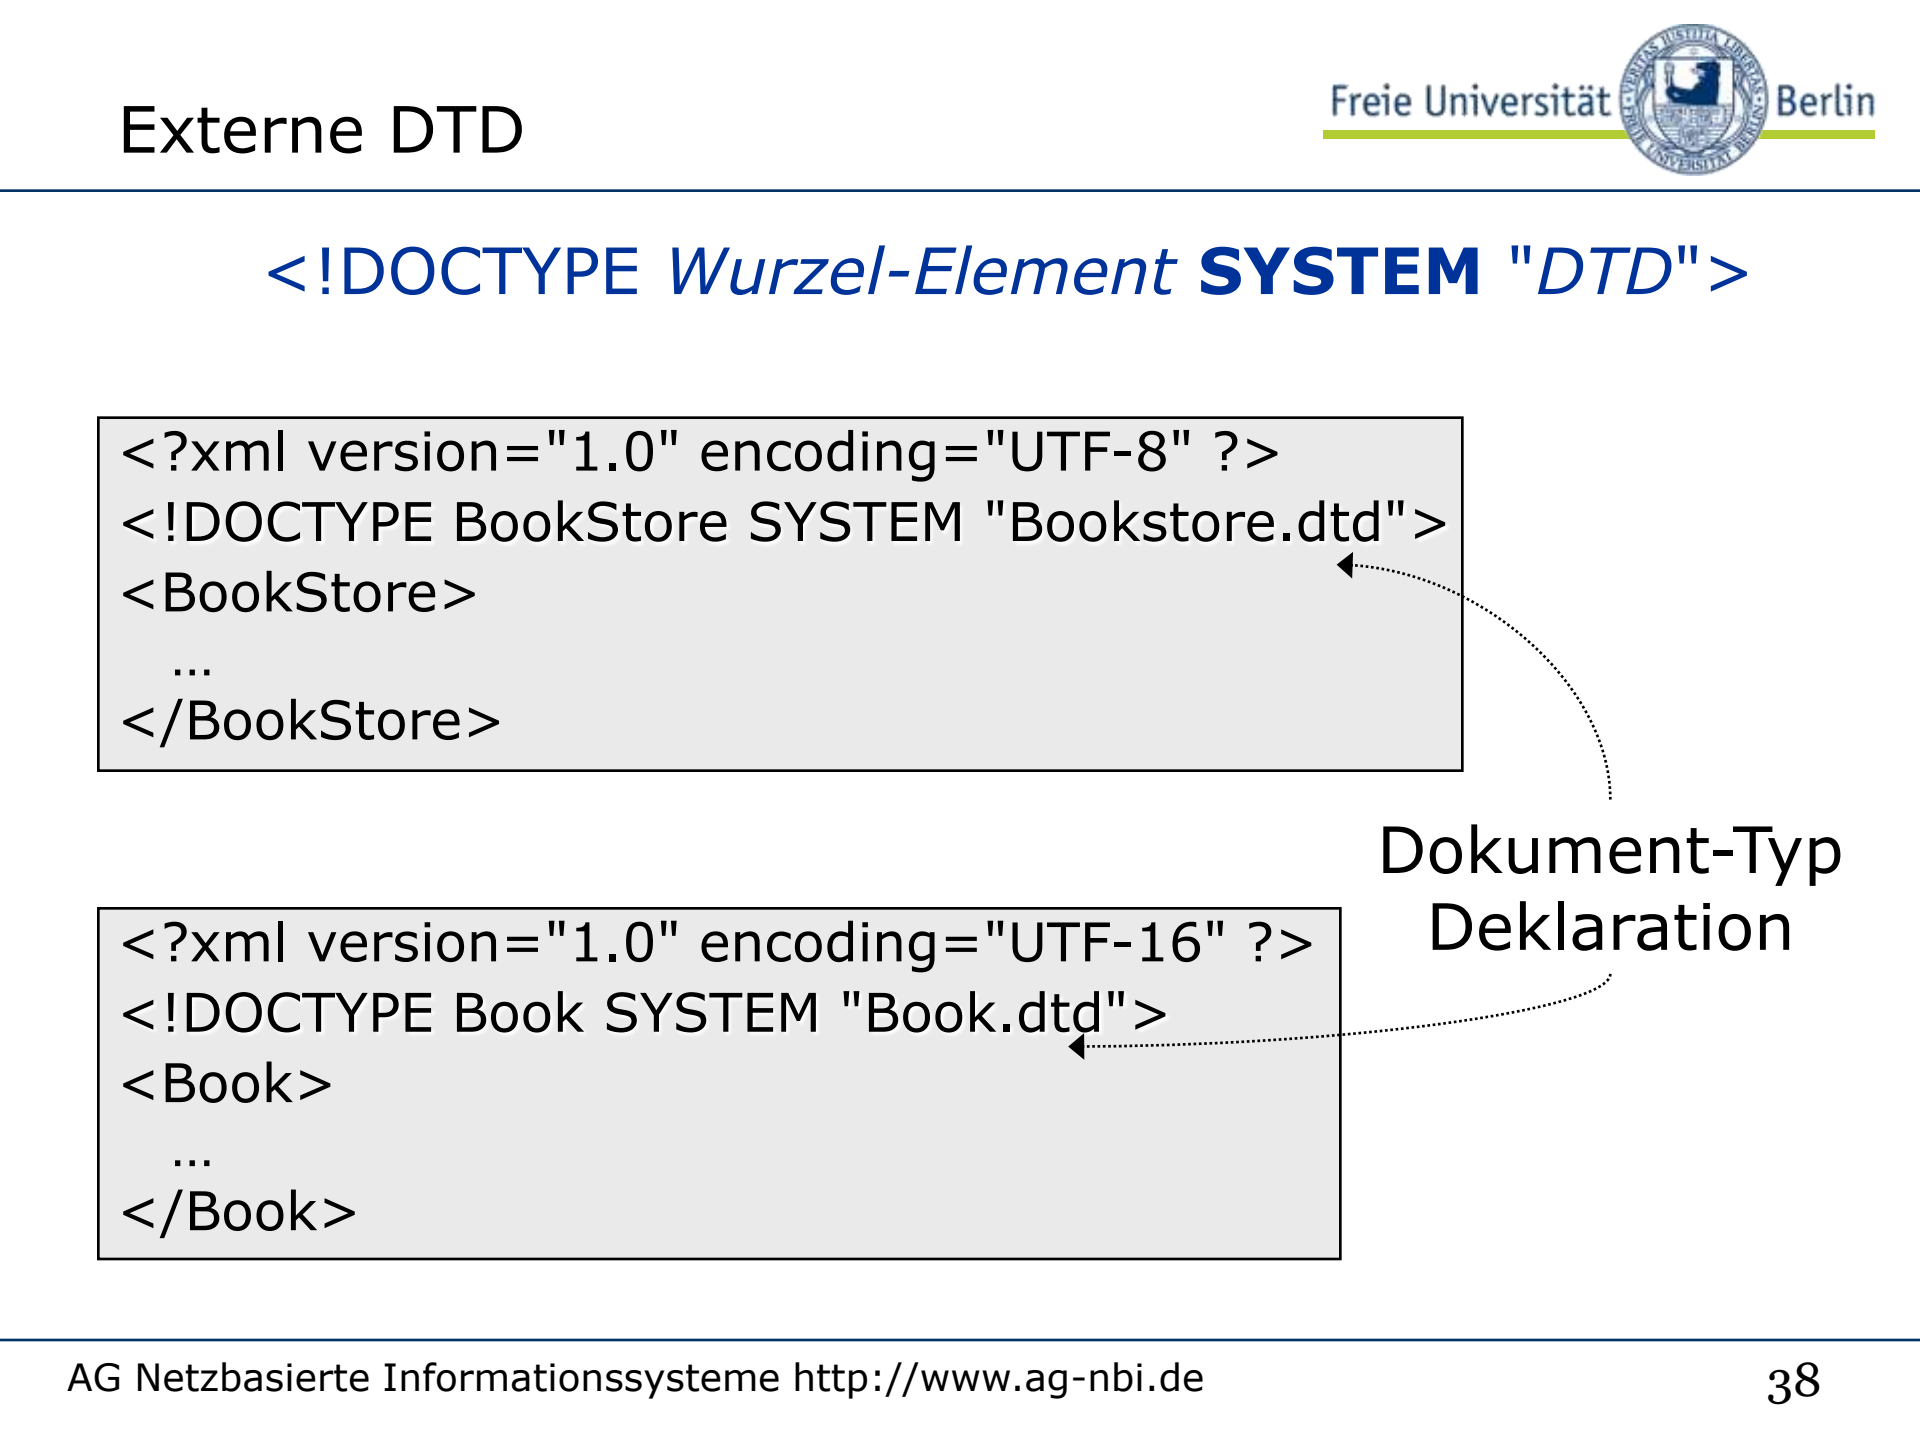

DTDs: Wohlgeformt & zulässig

Wohlgeformheit vs. Zulässigkeit

- wohlgeformt (well formed):

  XML-Dokument entspricht Syntaxregeln von XML

- zulässig (valid) bzgl. einer DTD:

  1. Wurzel-Element des XML-Dokumentes in DTD deklariert
  2. Wurzel-Element hat die in der DTD festgelegte Struktur

Ein Blick in die damalige DTD von XHTML

Beginn und Import von Entitäten

Freie Universität Berlin

```
<!--
   Extensible HTML version 1.0 Strict DTD
   […]
   Copyright (c) 1998-2002 W3C (MIT, INRIA, Keio),
   All Rights Reserved.

   This DTD module is identified by the PUBLIC and SYSTEM identifiers:

   PUBLIC "-//W3C//DTD XHTML 1.0 Strict//EN"
   SYSTEM "http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd"

   $Revision: 1.1 $
   $Date: 2002/08/01 13:56:03 $
-->

<!--============== Character mnemonic entities ==============-->

<!ENTITY % HTMLlat1 PUBLIC
   "-//W3C//ENTITIES Latin 1 for XHTML//EN"
   "xhtml-lat1.ent">
%HTMLlat1;
```

Importierte Entitäten


```
<!-- Portions (C) International Organization for Standardization 1986
     Permission to copy in any form is granted for use with
     conforming SGML systems and applications as defined in
     ISO 8879, provided this notice is included in all copies.
-->
[…]

<!ENTITY nbsp   " "> <!-- no-break space = non-breaking space,
                               U+00A0 ISOnum -->
<!ENTITY iexcl  "&#161;"> <!-- inverted exclamation mark, U+00A1 ISOnum --
    >
<!ENTITY cent   "&#162;"> <!-- cent sign, U+00A2 ISOnum -->
<!ENTITY pound  "&#163;"> <!-- pound sign, U+00A3 ISOnum -->
<!ENTITY curren "&#164;"> <!-- currency sign, U+00A4 ISOnum -->
<!ENTITY yen    "&#165;"> <!-- yen sign = yuan sign, U+00A5 ISOnum -->
<!ENTITY brvbar "&#166;"> <!-- broken bar = broken vertical bar,
                               U+00A6 ISOnum -->
<!ENTITY sect   "&#167;"> <!-- section sign, U+00A7 ISOnum -->
<!ENTITY uml    "&#168;"> <!-- diaeresis = spacing diaeresis,
                               U+00A8 ISOdia -->
```

Entitäten für Standardattribute

Freie Universität Berlin

```
<!---------- Generic Attributes ---------------->

<!-- core attributes common to most elements
  id       document-wide unique id
  class    space separated list of classes
  style    associated style info
  title    advisory title/amplification
-->
<!ENTITY % coreattrs
 "id          ID            #IMPLIED
  class       CDATA         #IMPLIED
  style       %StyleSheet;   #IMPLIED
  title       %Text;        #IMPLIED"
  >

<!ENTITY % i18n
 "lang        %LanguageCode; #IMPLIED
  xml:lang    %LanguageCode; #IMPLIED
  dir         (ltr|rtl)     #IMPLIED"
  >
<!ENTITY % attrs "%coreattrs; %i18n; %events;">
```

Elementdefinitionen

Freie Universität Berlin

```
<!ENTITY % lists "ul | ol | dl">
<!ENTITY % block
     "p | %heading; | div | %lists; | %blocktext; | fieldset | table">

<!-- Unordered list -->

<!ELEMENT ul (li)+>
<!ATTLIST ul
  %attrs;
  >
```

Inhaltsmodell durch Entität

Freie Universität Berlin

```
<!-- list item -->

<!ELEMENT li %Flow;>
<!ATTLIST li
  %attrs;
  >

<!-- %Flow; mixes block and inline and is used for list items etc. -->
<!ENTITY % Flow "(#PCDATA | %block; | form | %inline; | %misc;)*">
```

Nachteile von DTDs

Freie Universität Berlin

- keine XML-Syntax, eigener Parser nötig
- sehr wenige Datentypen
- keine eigenen Datentypen definierbar
- keine Namensräume:
  DTDs können nur dann kombiniert werden, wenn es keine Namenskonflikte gibt!
- keine Vererbungshierarchien für Typen

Und noch ein Nachteil

- Sequenzen einfach zu definieren:
  <!ELEMENT Book (Title, Author)>

- Aber: Soll Reihenfolge der Kind-Elemente egal sein, müssen alle Permutationen explizit aufgezählt werden:
  <!ELEMENT Book ((Title, Length) | (Length, Title))>

- nicht praktikabel: bei n Kind-Elementen n! Permutationen

Freie Universität Berlin

DTD deklariert das erlaubte Vokabular

DTD definiert für jedes Element ein Content-Modell

- Content-Modell legt fest:
  - Elemente oder Daten
  - Reihenfolge & Anzahl von Elementen/Daten innerhalb eines Elements
  - Pflicht oder optionale Elemente

DTD deklariert für jedes Element eine Menge von erlaubten Attributen