Freie Universität Berlin

Vorlesung XML-Technologien – SoSe 2013
Rückblick und Klausurvorbereitung

Markus Luczak-Rösch
Freie Universität Berlin
Institut für Informatik
Netzbasierte Informationssysteme

markus.luczak-roesch@fu-berlin.de

XML

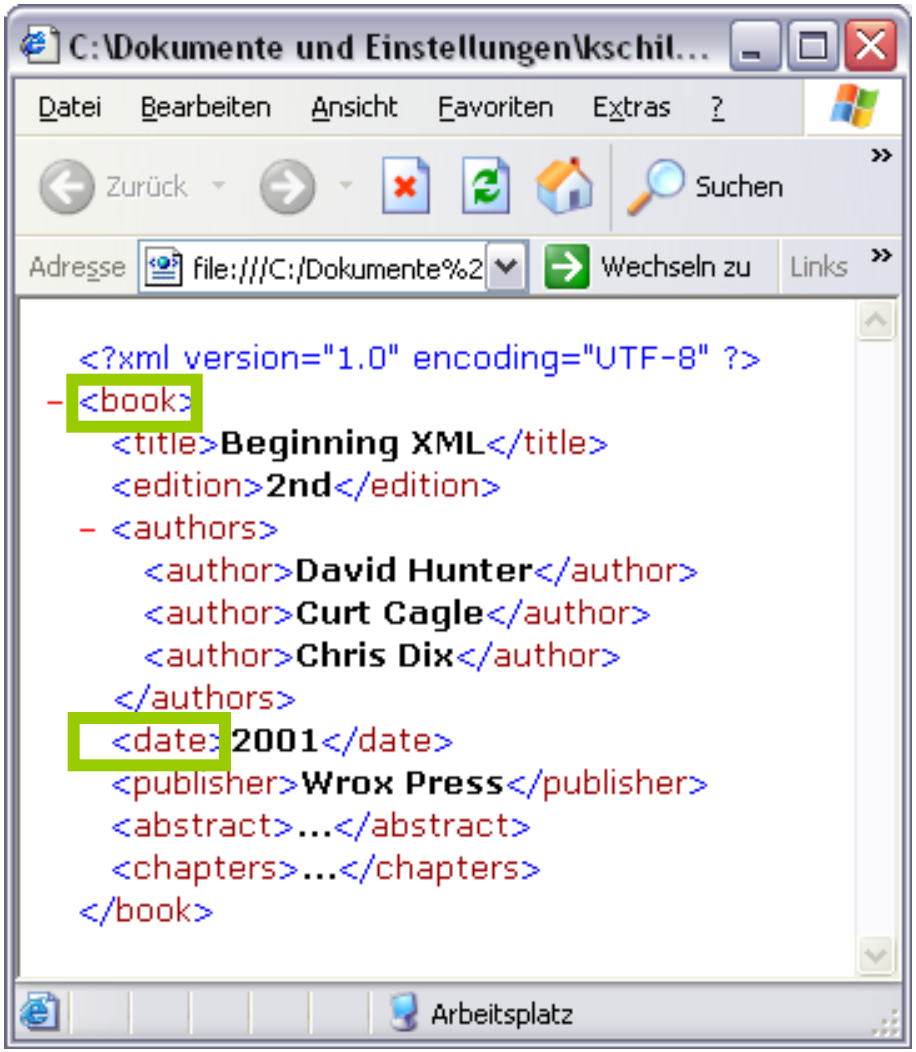

- Extensible Markup Language
- erlaubt Strukturieren von Inhalten
- Unterschiede zu HTML:
  - Medienneutral
- Tag-Namen <name>…</name> beliebig
- generische Auszeichnungssprache

SGML

- gibt zwar keine konkreten Tags vor
- Mit Document Type Definitions (DTDs) können aber spezielle Auszeichnungssprachen mit konkreten Tags definiert werden:
  - werden Anwendungen von SGML genannt
  - bekannteste Anwendung von SGML: HTML

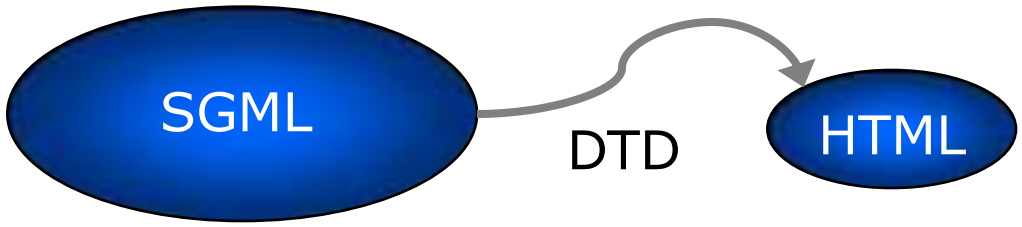

Anwendung: spezieller Wortschatz und Grammatik

- Anwendung selbst kann keine Anwendung definieren

SGML- vs. XML-Anwendungen

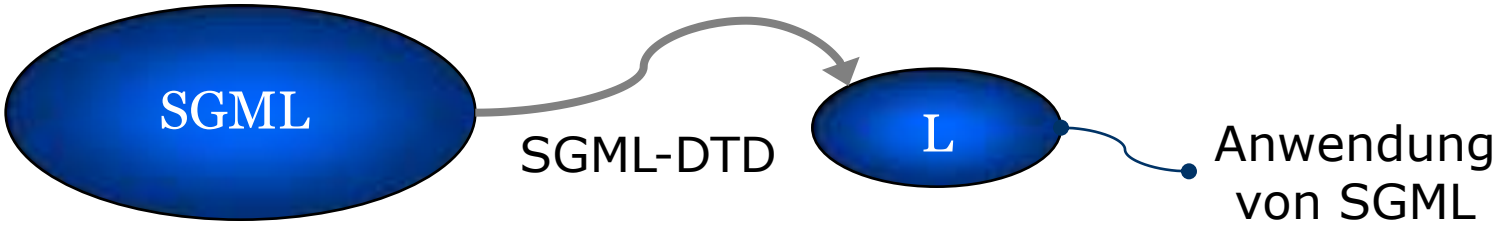

- L muss *nicht* Teilsprache von SGML sein.
- L kann *keine* neue Sprache definieren.
- Beispiel: HTML

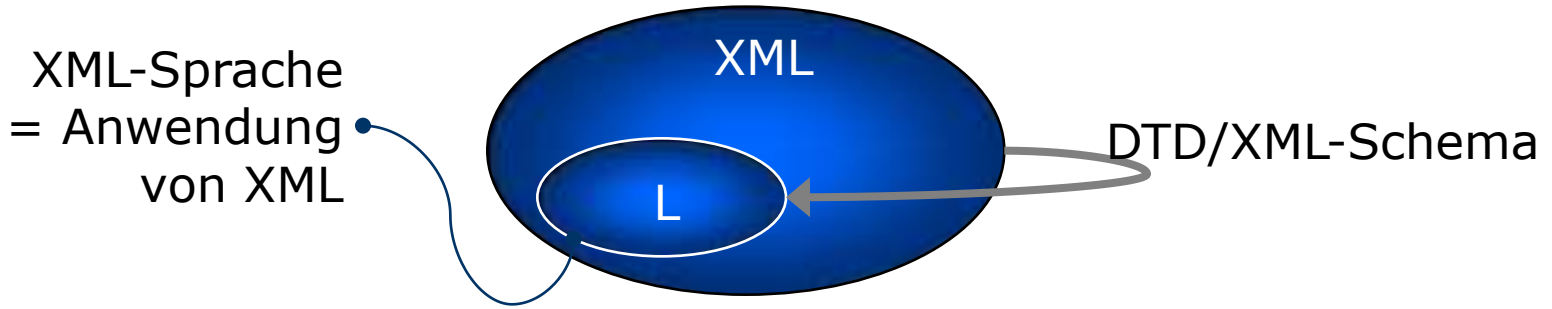

- L immer Teilsprache von XML
- L kann *keine* neue Sprache definieren.
- Beispiel: XHTML

SGML, HTML, XML, XHTML?!

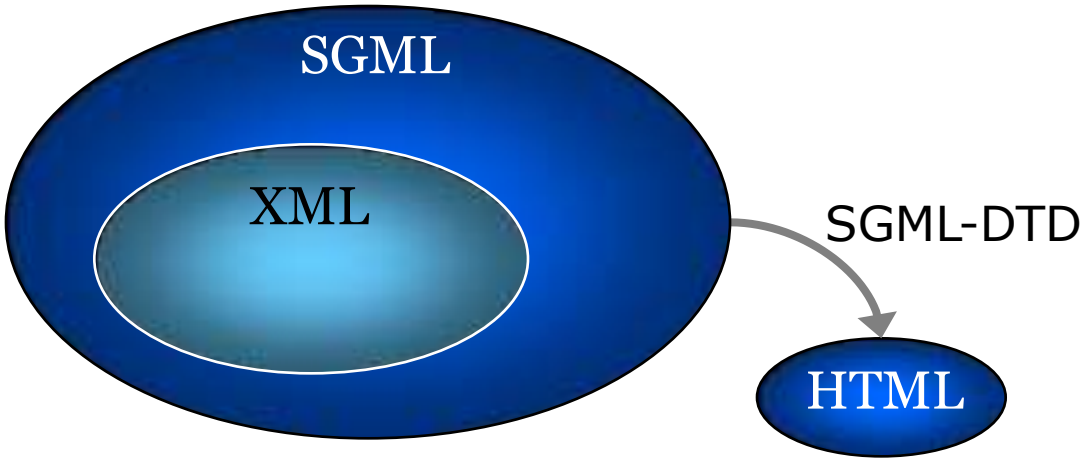

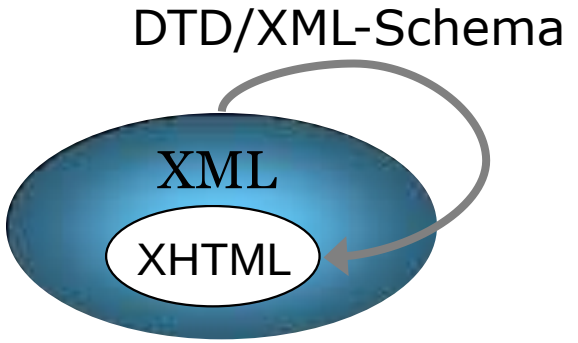

HTML

- Anwendung von SGML

XML

- Teilsprache von SGML

XHTML

- XML-Sprache = Anwendung von XML
- alle XHTML-Dokumente immer wohlgeformte XML-Dokumente

1. Unstrukturierter Inhalt

- Beispiel: <first>John</first>
- einfacher Text ohne Kind-Elemente

  Kind-Element: Element, das im Inhalt eines Elementes vorkommt
- unstrukturierter Inhalt → *Parsed Character Data (PCDATA)*:
  - character data: einfache Zeichenkette
  - parsed: Zeichenkette wird vom Parser analysiert, um Ende-Tag zu identifizieren
  - Normalisierung: u.a. Zeilenumbruch (CR+LF)➔

Anmerkung: Auf den Folien schreibe ich der besseren Lesbarkeit wegen *Kind-Element* statt *Kindelement* !

2. Strukturierter Inhalt

- Beispiel:

```
<name>
        <first>John</first>
        <last>Doe</last>
</name>
```

- Sequenz von > 0 Kind-Elementen:
  - hier: <first>John</first> und <last>Doe</last>
- kein Text vor, nach oder zwischen den Kind-Elementen
- Kind-Elemente immer geordnet:
  Reihenfolge, so wie sie im XML-Dokument erscheinen
- Elemente können beliebig tief geschachtelt werden.

3. Gemischter Inhalt (mixed content)

- enthält Text mit mindestens einem Kind-Element
- Beispiel:

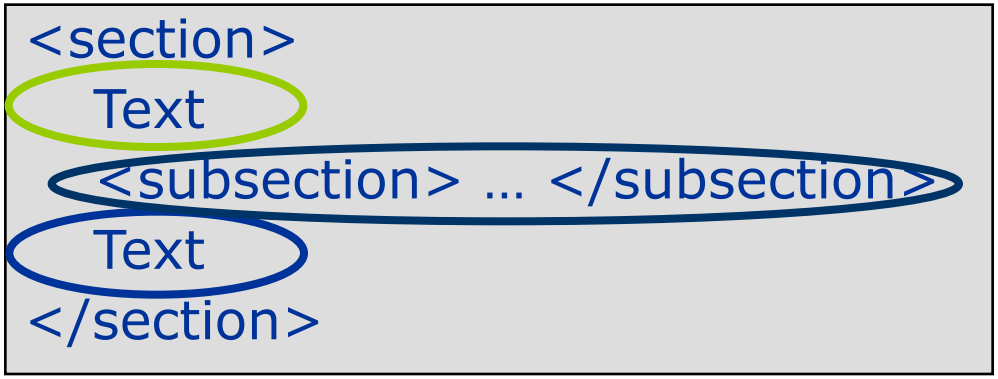

4. Leerer Inhalt

- Beispiel:

```
<name>
   <first>John</first>
   <middle></middle>
   <last>Doe</last>
</name>
```

- weder Text noch Kind-Element
- <middle></middle> auch **leeres Element** genannt
- Abkürzung: **selbstschließendes Tag** (engl.: *self-closing tag*) <middle/> :

```
<name>
   <first>John</first>
   <middle/>
   <last>Doe</last>
</name>
```

Grundbausteine: XML-Attribute

```
<name id="1232345" nickname="Shiny John">
  <first>John</first>
   <last>Doe</last>
</name>
```

- Attribut: Name-Wert-Paar
  - name="wert" oder name='wert' aber ~~name= "wert'~~
- Attribut-Wert:
  - immer PCDATA: keine Kind-Elemente, kein < und &
  - "we"rt" und 'we'rt' ebenfalls nicht erlaubt
  - Normalisierung: u.a. Zeilenumbruch ➔

- Beachte: Reihenfolge der Attribute belanglos

Wohlgeformte XML-Dokumente

Freie Universität Berlin

1. Jedes Anfangs-Tag muss ein zugehöriges Ende-Tag haben.
2. Elemente dürfen sich nicht überlappen.
3. XML-Dokumente haben genau ein Wurzel-Element.
4. Element-Namen müssen bestimmten Namenskonventionen entsprechen.
5. XML beachtet grundsätzlich Groß- und Kleinschreibung.
6. XML belässt White Space im Text.
7. Ein Element darf niemals zwei Attribute mit dem selben Namen haben.

Beispiel DTD

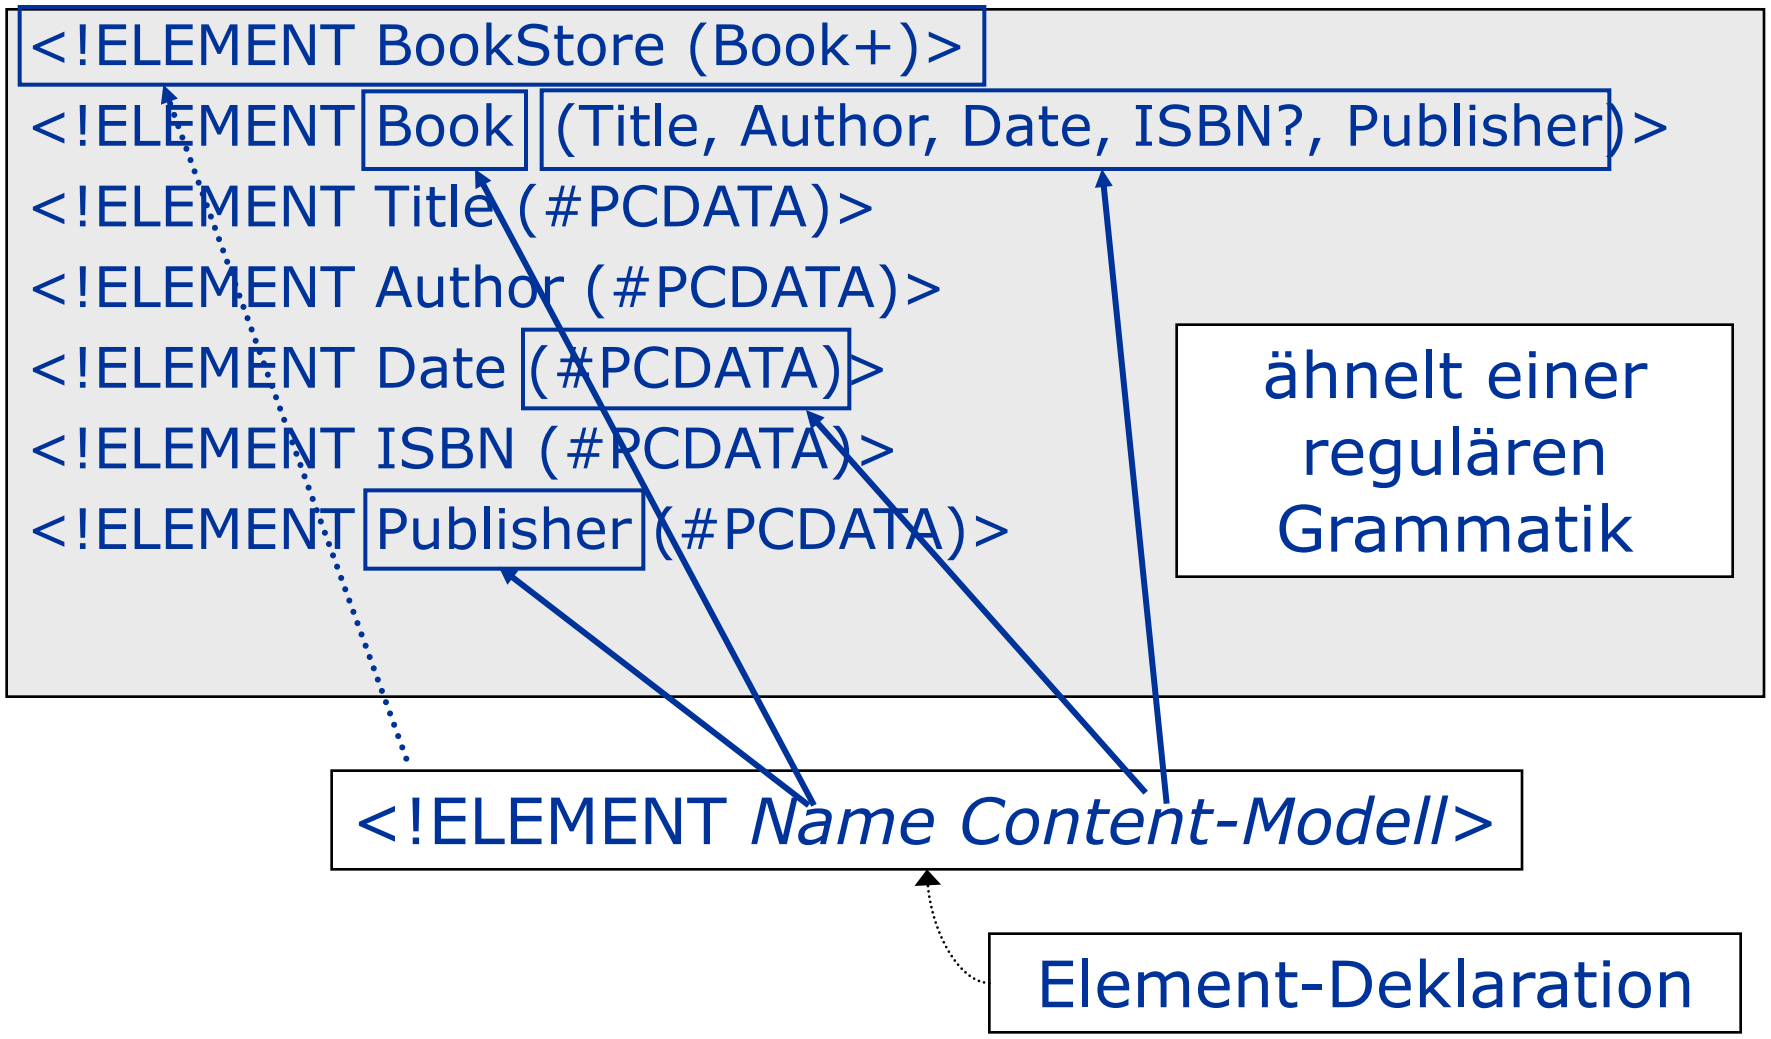

Elementdeklaration: Datentypen für Inhalte

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

Rekursive vs. iterative Deklaration

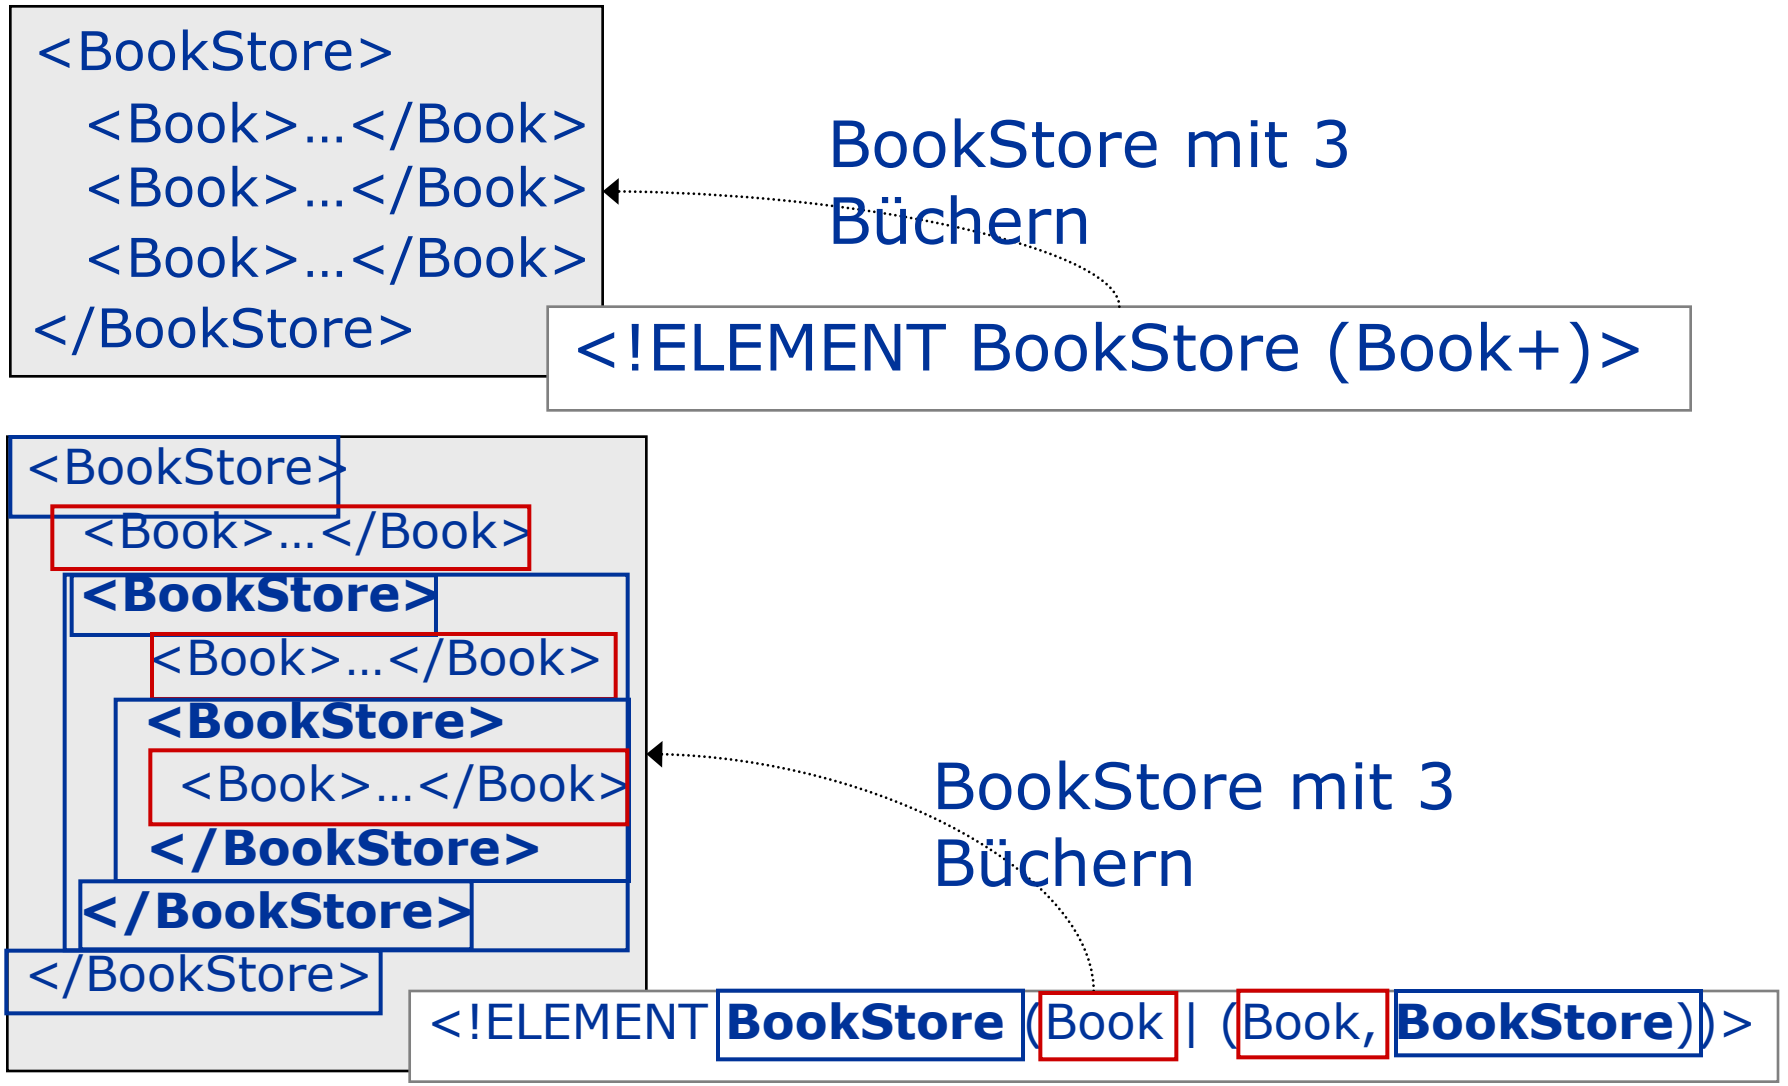

Deklaration von Attributen

```
<!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.

Optionale / erforderliche Attribute


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

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

Wohlgeformheit vs. Zulässigkeit

Freie Universität Berlin

- 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

Vorteile von XML-Schemata

- XML-Sprache statt eigener Syntax
- Vielzahl von vordefinierten Datentypen
- eigene Datentypen ableitbar
- Namensraumunterstützung
- Reihenfolgeunabhängige Strukturen

Einfache vs. komplexe Datentypen

Freie Universität Berlin

einfache Datentypen (simple types)

- beschreiben unstrukturierten Inhalt ohne Elemente oder Attribute (PCDATA)

komplexe Datentypen (complex types)

- beschreiben strukturierten XML-Inhalt mit Elementen oder Attributen
- natürlich auch gemischten Inhalt

Kategorien von Datentypen

	(primitive)	abgeleitete
einfache	xsd:string xsd:language xsd:integer …	<xsd:simpleType name="longitudeType"> **<xsd:restriction base="xsd:integer">** <xsd:minInclusive value="-180"/> <xsd:maxInclusive value="180"/> **</xsd:restriction>** </xsd:simpleType>
komplexe	<xsd:complexType> <xsd:sequence> … </xsd:sequence> </xsd:complexType>	<xsd:complexType name="BookTypeWithID"> <xsd:complexContent> **<xsd:extension base="BookType">** <xsd:attribute name="ID" type="xsd:token"/> **</xsd:extension>** </xsd:complexContent> </xsd:complexType>

Namenskonflikte

```
<course>
   <title>Semantic Web</title>
   <lecturers>
      <name>
         <title>Prof. Dr.-Ing.</title>
         <first>Robert</first>
         <last>Tolksdorf</last>
      </name>
   </lecturers>
   <date>12/11/2004</date>
   <abstract>...</abstract>
</course>
```

- **Namenskonflikt**: gleicher Name, aber unterschiedliche Bedeutung
- z.B. Titel einer Veranstaltung vs. Titel einer Person
- in einem Dokument unterschiedliche Vokabularien

Auflösung durch Präfixe

```
<course:course>
  <course:title>Semantic Web</course:title>
  <course:lecturers>
    <pers:name>
      <pers:title>Prof. Dr.-Ing.</pers:title>
      <pers:first>Robert</pers:first>
      <pers:last>Tolksdorf</pers:last>
    </pers:name>
  </course:lecturers>
  <course:date>12/11/2004</course:date>
  <course:abstract>...</course:abstract>
</course:course>
```

- Präfixe geben Kontext an: Aus welchem Bereich stammt der Name
  - z.B. pers:title vs. course:title

Namensräume in XML

- WWW: Namensräume müssen global eindeutig sein.
- In XML wird Namensraum mit URI identifiziert.
- Zuerst wird Präfix bestimmter Namensraum zugeordnet, z.B.:

- Anschließend kann der Namensraum-Präfix einem Namen vorangestellt werden: z.B. pers:title
- Beachte: Wahl des Präfixes egal!

Standard-Namensraum

- **xmlns="URI"** statt xmlns:prefix="URI"
- Namensraum-Präfix kann weggelassen werden.

- Standard-Namensraum gilt für das Element, wo er definiert ist.
- Kind-Elemente erben Standard-Namensraum von ihrem Eltern-Element.
- Ausnahme: Standard-Namensraum wird überschrieben
- Beachte: Standardnamensräume gelten nicht für Attribute

Qualified vs. Unqualified

- Element- oder Attribut-Name heißt namensraumeingeschränkt (qualified), wenn er einem Namensraum zugeordnet ist.

- Einschränkung vom Element-Namensraum:
  1. Standard-Namensraum festlegen
  2. Namensraum-Präfix voranstellen

- Einschränkung vom Attribut-Namensraum:
  1. Namensraum-Präfix voranstellen

- ähnliches Modell wie in DOM
  - XML-Dokument als Baum mit Elementen, Attributen und PCDATA als Knoten

- virtuelle Dokument-Wurzel (Wurzelknoten):
  durch "/" repräsentiert (links von "/" steht nichts)
  ⇨ Wurzel-Element immer Kind von "/":
  z.B. /root

Dokumentenreihenfolge

- Baummodell als Basis
- feste Dokumentreihenfoge (document order) = Reihenfolge der Start-Tags im Dokument
- Tiefensuche

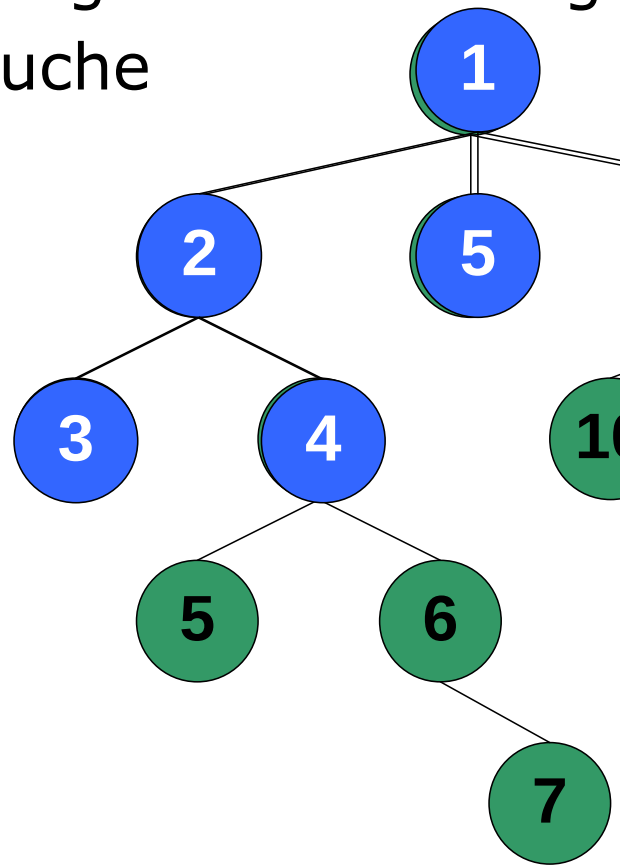


```
1 <buch>
2  <autoren>
3   <name> Anna Baum</name>
4   <name>Hans Gruber</name>
    </autoren>
5   <titel>Ein Buch</titel>
6   <preis>45</preis>
  </buch>
```

Zugriff auf Elemente und Attribute

- Elemente werden einfach **über ihren Namen** identifiziert:

  z.B. **order** oder order/**item**

- Attribute werden mit **"@name"** identifiziert:

  z.B. **@id** oder order/**@id**

```
<?xml version="..." encoding="..."?>
<order id="O56">
  <item item-id="E16-2">
    <name>buch</name>
  </item>
</order>
```

Was ist XSLT?

Freie Universität Berlin

- in XML beschriebene Sprache zur Transformation von XML-Dokumenten
- eine beschreibende Sprache
- XSLT-Programme (stylesheets) haben XML-Syntax
  - plattformunabhängig
- erlaubt XML-Dokumente in beliebige Textformate zu transformieren:
  - XML ➔ XML/HTML/XHTML/WML/RTF/ASCII …
- W3C-Standard seit 1999

Funktionsweise des XSLT-Prozessors

Freie Universität Berlin

a) K := Dokument-Wurzel ("/") des Ursprungsdokumentes

b) Identifiziere alle Templates, die auf K anwendbar sind.

1. Ist genau ein Template anwendbar
   - wende es an
   - Fertig.
2. Sind mehre Templates anwendbar, dann
   - wende das speziellste an
     - z.B. ist "/order" spezieller als "/*".
   - Fertig.
3. Ist kein Template anwendbar
   - wiederhole b) für alle Kinder K' mit K := K'.

Template-Konflikte

- mehrere Templates auf den gleichen Knoten anwendbar

- Lösung → Prioritätsregeln:
  1. Eine spezifische Information hat Vorrang vor einer Regel für allgemeinere Information

     Beispiel: match="/buch/authors/autor"

     match="//autor"
  2. Suchmuster mit Wildcards (* oder @*) sind allgemeiner als entsprechende Muster ohne Wildecards
  3. Nur wenn 1. & 2. nicht zutreffen → Reihenfolge der Templates entscheidend
  4. Priorität der Templates durch Attribut priority bestimmbar
     - Standard = 0
     - niedrigere Priorität < 0 < höhere Priorität

Transformations-Beispiel

Freie Universität Berlin

Stylesheet

```
<xsl:template match="A">
  <xsl:value-of select="@id"/>
</xsl:template>

<xsl:template match="B">
   <xsl:value-of select="@id"/>
 </xsl:template>

 <xsl:template match="C">
   <xsl:value-of select="@id"/>
 </xsl:template>

<xsl:template match="D">
  <xsl:value-of select="@id"/>
 </xsl:template>
```

Dokument

```
<source>
  <A id="a1">
     <B id="b1"/>
     <B id="b2"/>
  </A>
  <A id="a2">
     <B id="b3"/>
     <B id="b4"/>
     <C id="c1">
        <D id="d1"/>
     </C>
     <B id="b5">
        <C id="c2"/>
     </B>
  </A>
</source>
```

kein Template anwendbar

Template "A" wird angewandt

Ausgabe

a1

a2

Template "B" wäre anwendbar, es werden aber keine Templates aufgerufen!

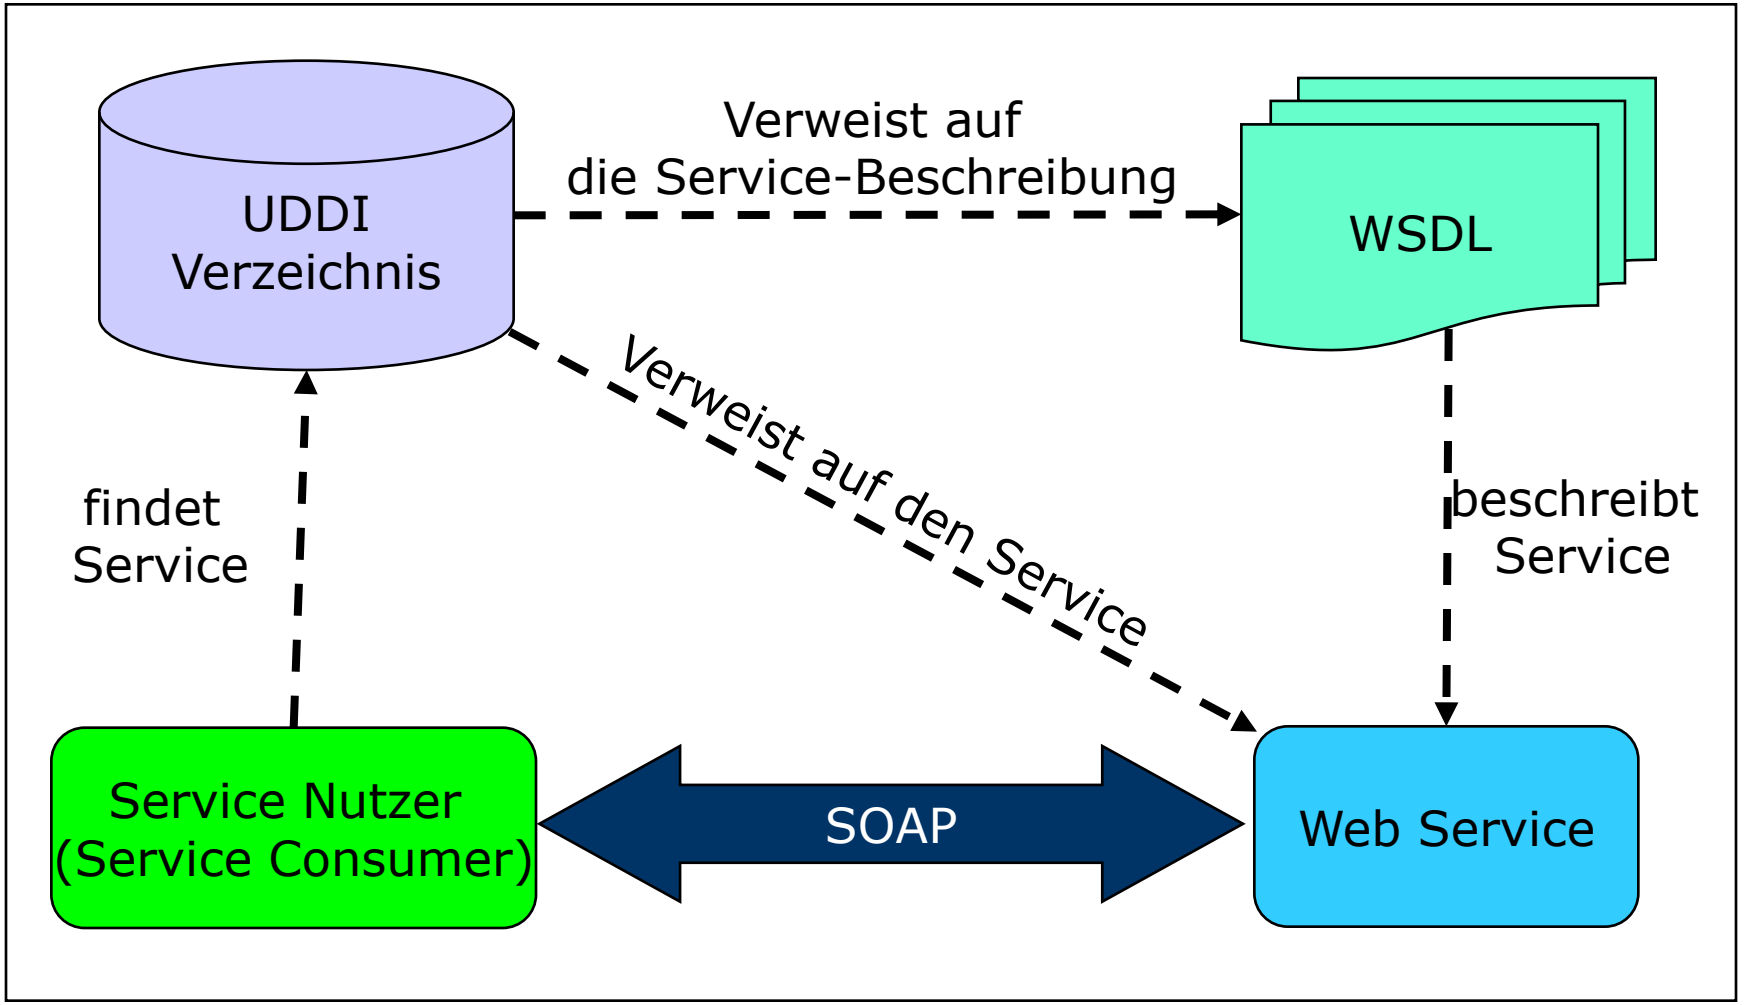
UDDI
Verzeichnis
Verweist auf
die Service-Beschreibung
WSDL
Verweist auf den Service
findet
Service
beschreibt
Service
Service Nutzer
(Service Consumer)
SOAP
Web Service

Aufbau einer SOAP-Nachricht

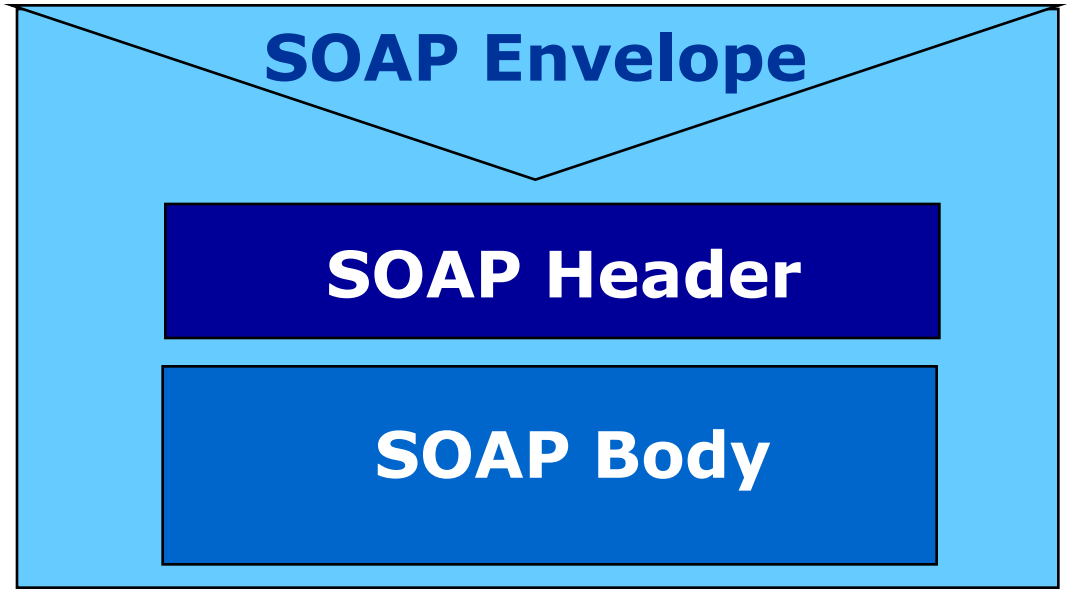

XML-Deklaration

```
<?xml version='1.0' encoding='UTF-8'?>
<env:Envelope xmlns:env="http://www.w3.org/2003/05/soap/envelope/">
    <!- SOAP Header -->
    <!- SOAP Body -->
</env:Envelope>
```

SOAP Version 1.2

SOAP Version 1.1:
http://schemas.xmlsoap.org/soap/envelope/

REST Prinzip 1 – Client-Server

- abgeleitet vom Prinzip zur Aufteilung von Aufgaben („separation of concerns“)
  - erlaubt unabhängige Evolution der Einzelkomponenten
  - Beispiel:
    - Rendering von HTML im Web-Browser (Client) – Serven von HTML-Seiten auf einem Web-Server (Server)

REST Prinzip 2 – Stateless

- jede Nachricht enthält alle notwendigen Informationen, die dem Empfänger die Verarbeitung erlauben
  - kein gespeicherter Kontext am Server
  - Sitzungszustand beim Client
    - Beispiele:
      - Cookies
      - Session IDs

REST Prinzip 3 – Cache

- Antworten auf Anfragen implizit oder explizit als cachable oder non-cachable klassifizieren
  - Client darf cachable-Antworten für spätere Anfragen wiederverwenden

REST Prinzip 4 – Uniform Interface

- Vereinfachung der Systeminfrastruktur und hohe Sichtbarkeit von Interaktionen durch standardisierten Zugriff auf Komponenten
  - Ressourcenidentifikation
    - universelle Syntax für Identifier
    - Identifikation von „Dingen“ (Things)
  - Manipulation von Repräsentationen
    - wohldefinierte Aktionen auf einer Sequenz von Bytes + Metadaten (=Repräsentation), die den aktuellen oder gewünschten Zustand einer Ressource darstellt
  - selbstbeschreibende Nachrichten
  - Hypermedia

REST Prinzip 4 – Uniform Interface

- Vereinfachung der Systeminfrastruktur und hohe Sichtbarkeit von Interaktionen durch standardisierten Zugriff auf Komponenten
  - Ressourcenidentifikation
  - Manipulation von Repräsentationen
  - selbstbeschreibende Nachrichten
    - die Semantik von Nachrichten ist für alle verarbeitenden Komponenten (Mittler) sichtbar
    - Mittler können Inhalte verändern
  - Hypermedia
    - alle Inhalte UND Informationen zum Zustandsübergang (Hyperlinks) werden an den Client weitergegeben

REST Prinzip 5 – Layered System

- Unabhängigkeit der einzelnen Komponenten durch beschränkte Sicht auf das hierarchisch geschichtete Gesamtsystem
  - Komponenten „sehen“ nur bis zum Interaktionspartner

REST Prinzip 6 – Code-on-Demand

- Erweiterbarkeit des Systems durch Download von Code nach dem Deployment
  - Beispiele:
    - Applets
    - Scripte
  - optionales Prinzip, weil es die Sichtbarkeit von Interaktionen reduziert

Das Web

- HTTP
  - Stateless Client-Server
  - Caching
  - Uniform Interface: standardisierte Manipulation von Repräsentationen via GET, PUT, POST, DELETE
  - Layered System
- HTTP-URIs
  - Uniform Interface: Ressourcenidentifikation
- Hypertext und Hyperlinks
  - Uniform Interface: standardisierte Repräsentation von Ressourcenzustand und Zustandsübergängen

Client

```
GET / HTTP/1.1
User-Agent: Mozilla/5.0 … Firefox/10.0.3
Host: markus-luczak.de:80
Accept: */*
```

```
HTTP/1.1 200 OK
Server: Apache/2.0.49
Content-Language: en
Content-Type: text/html
Content-length: 2990

<!DOCTYPE html>
<html xml:lang="en"
...
```

Server

abgeleitet von: R. Tolksdorf

Ressourcen und Repräsentationen

- Information Resources
  - URI-identifizierte Ressourcen, deren Repräsentation in einer Nachricht elektronisch übertragen werden kann
  - eine bestimmte Repräsentation anzufordern und zu erhalten nennt man **Dereferenzierung**

- Non-Information Resources
  - abstrakte Konzepte wie z.B. in Ontologien modelliert
    - Beispiel: Meter
      Ich kann lediglich andere Information Resources ausliefern, die „Meter" beschreiben aber eben keine Repräsentation von Meter sind.
  - URI-identifizierbar aber nicht dereferenzierbar

Content Negotiation – Req.-Resp.

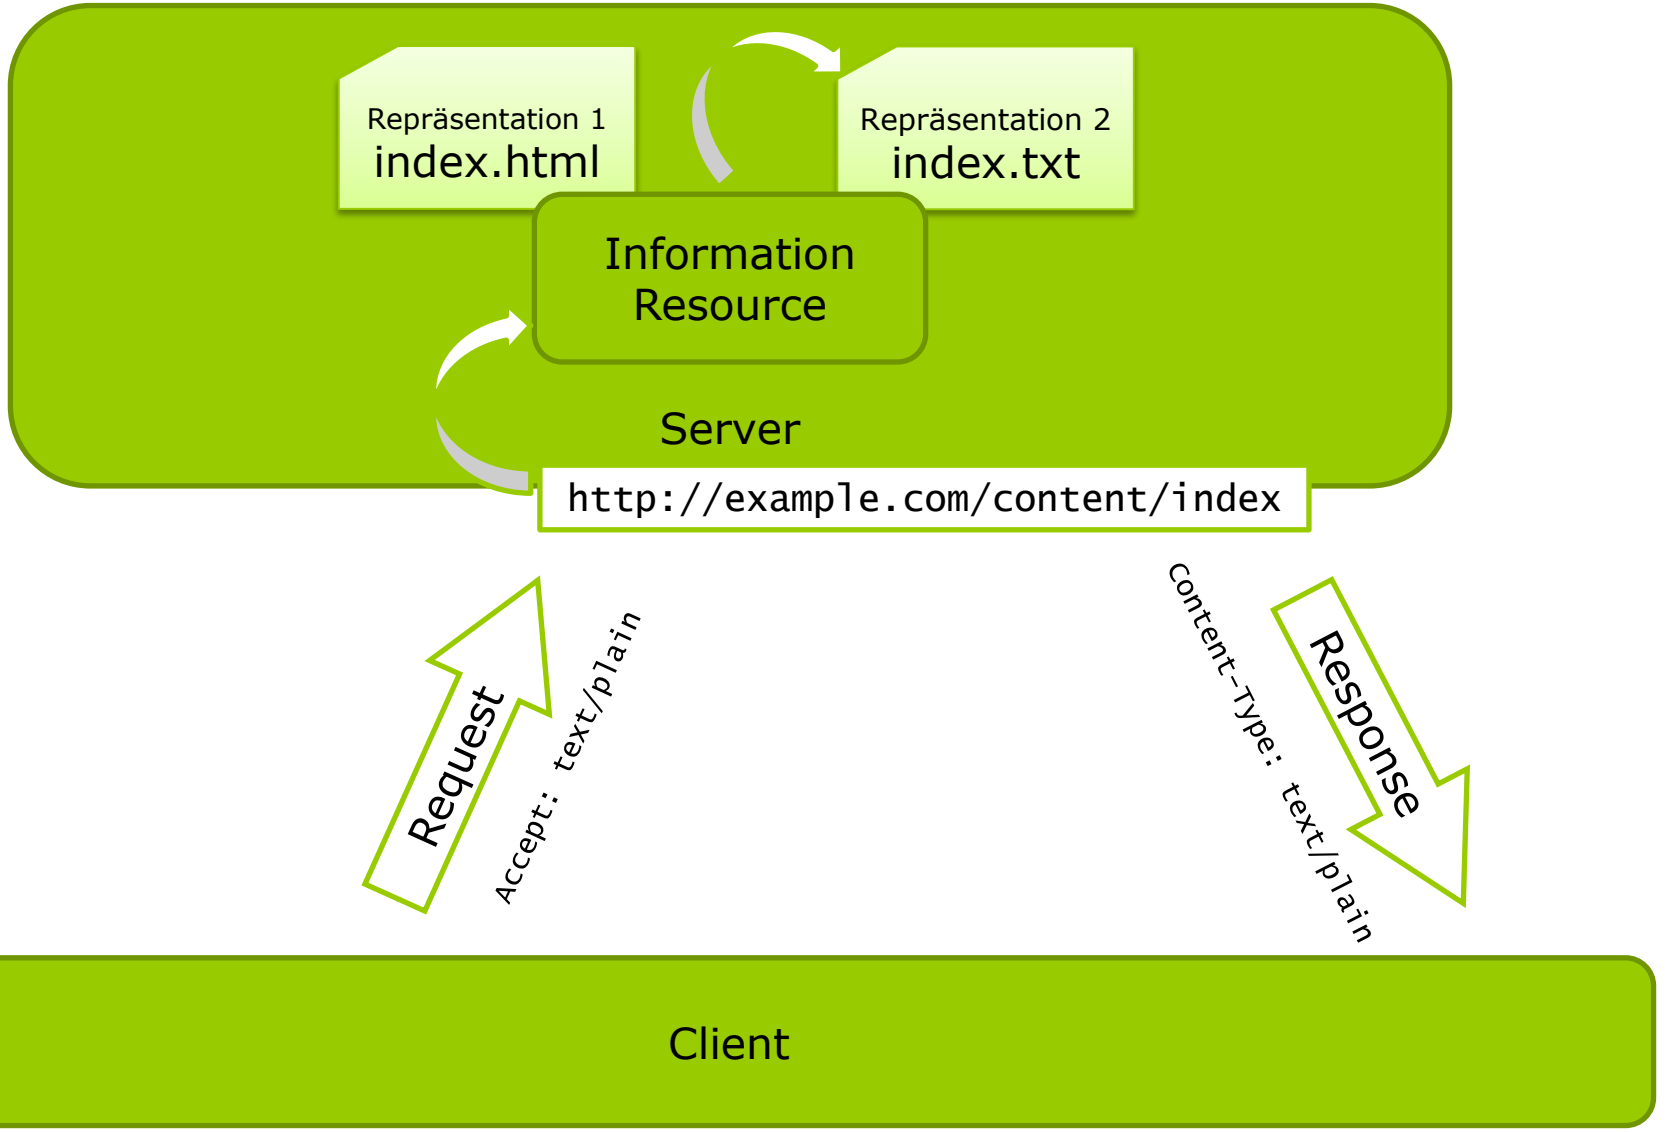

Towards RDF

- <Buch>Dieses Buch</Buch> hat den Titel <Titel>Semantic Web Grundlagen</Titel>

- <foo>Dieses Buch</foo> hat den Titel <bar>Semantic Web Grundlagen</bar>

- natürliche Sprache
- Mehrdeutigkeit

<Apple>

<http://apple.com/>

<http://applefuits.com/>

RDF Sätze

- Informationen und Metainformationen:

- In RDF als Satz ausgedrückt:

"www.robert-tolksdorf.de	Subjekt
hat als Autor	Prädikat
Robert Tolksdorf"	Objekt

Datenmodell

- „RDF-Welt“: Gerichteter Graph
  - Knoten (Ressourcen)
  - Kanten (Properties)
- Ressourcen (RDF Resource)
  - Alles worüber man Aussagen machen kann
  - Identifiziert durch URIs (qualified URIs = URI + fragment identifier)
  - Aussagen sind auch Ressourcen
- Eigenschaften/Beziehungen (RDF Property)
  - Verbinden Ressourcen miteinander oder Ressourcen zu Werten (RDF Literal)
- Aussagen (RDF Statement)
  - (Subjekt, Prädikat, Objekt)
  - “Resource has Property with Value”

RDF vs. XML

Als XML-Baum

```
<author>
        <uri>page</uri>
        <name>Ora</name>
</author>
```

```
<document>
        <details>
                <uri>href="page"</uri>
                <author>
                        <name>Ora</name>
                </author>
        </details>
</document>
```

```
<document>
        <author>
        <uri>href="page"</uri>
        <details>
                <name>Ora</name>
        </details>
        </author>
</document>
```

```
<document href="page">
        <author>Ora</author>
</document>
```

```
<document href="http://www.w3.org/test/page" author="Ora" />
```

Als RDF-Graph

```
<Description about="http://www.w3.org/test/page"
        s:Author ="http://www.w3.org/staff/Ora" />
```

```
...
```

SPARQL-Anfragen

- SPARQL: Anfragesprache für RDF-Daten

- Grundsatz: Pattern-Matching
  - beschreibe Graphpattern
  - frage RDF-Graph mit diesem Pattern an
  - Subgraphen, die Pattern matchen kommen in die Ergebnismenge

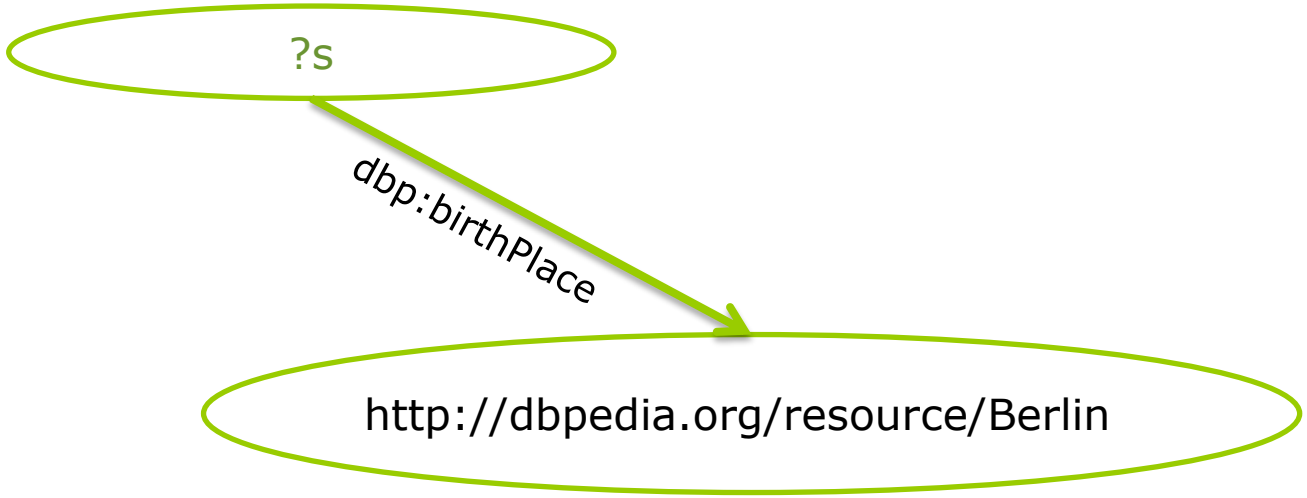

SPARQL-Anfragen

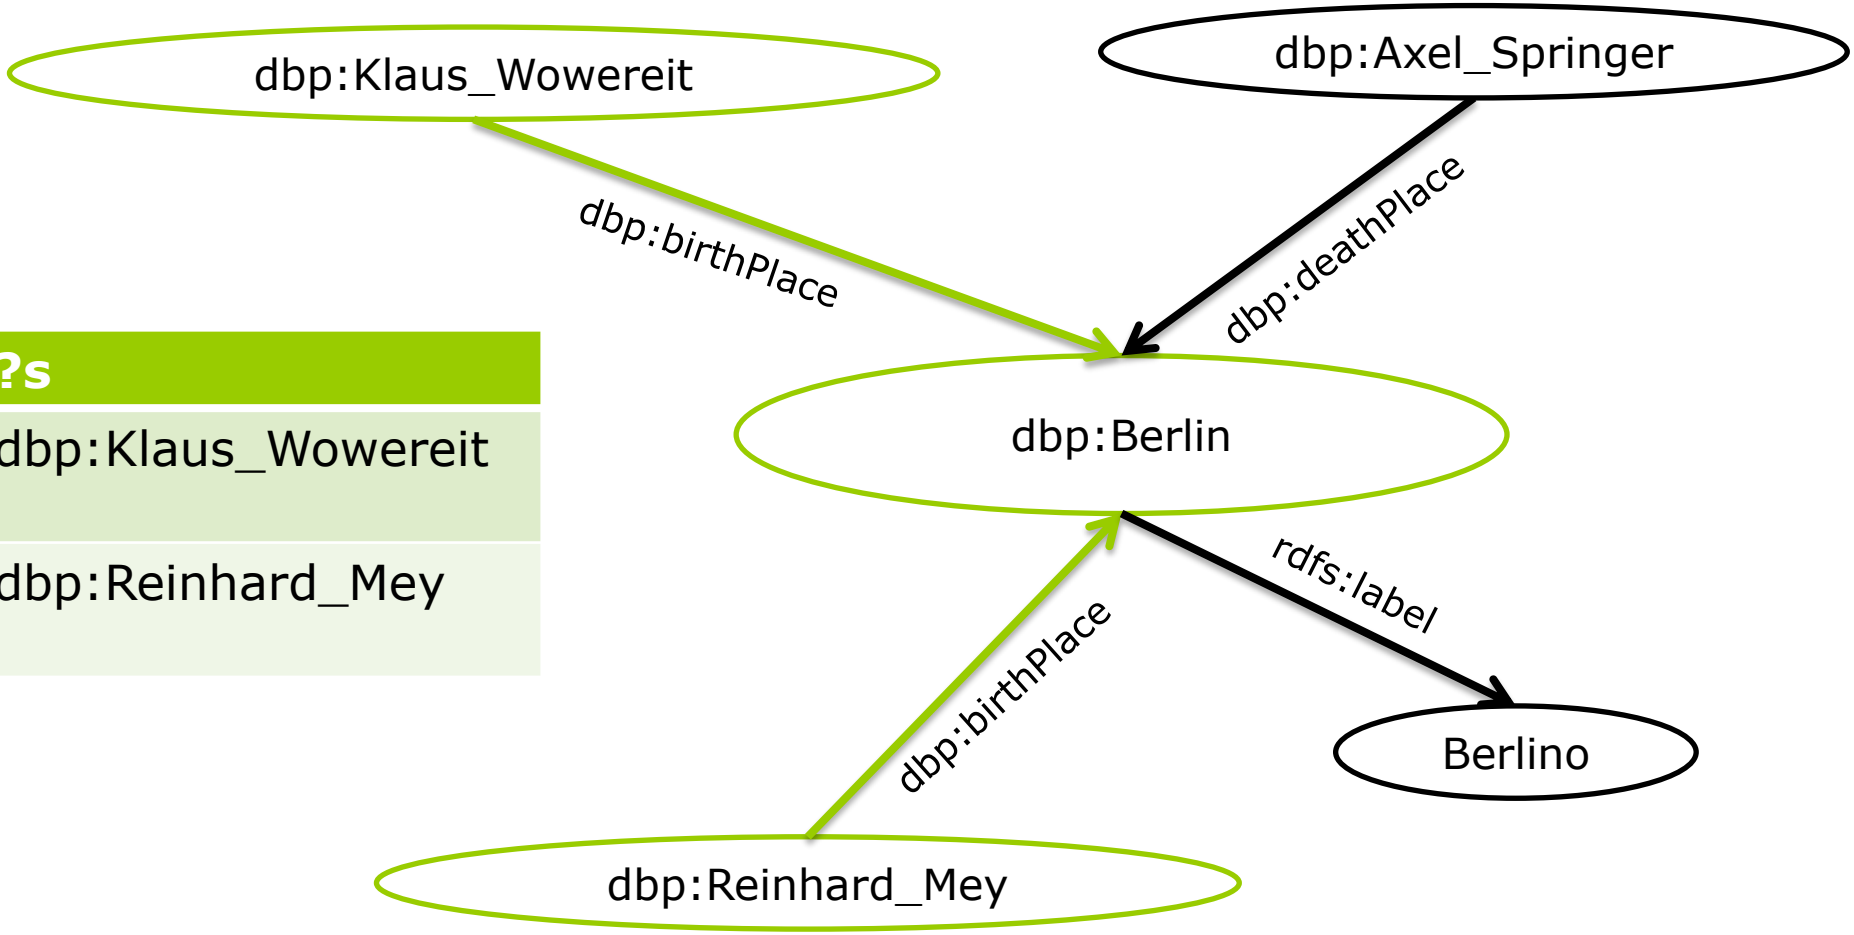

?s
dbp:Klaus_Wowereit
dbp:Reinhard_Mey

Linked Data Prinzipien

1. URIs als Namen für alle "Dinge"
2. http:// URIs damit man im Web auf diese Namen zugreifen kann
3. Wenn eine URI aufgerufen wird sollen sinnvolle Informationen entsprechend der Standards (RDF, SPARQL) geliefert werden
4. Links zu anderen URIs, damit Nutzer mehr "Dinge" finden können

http://dbpedia.org/resource/Berlin

Content Negotiation

http://dbpedia.org/page/Berlin
http://dbpedia.org/data/Berlin

yago-res:Berlin S
owl:sameAs P
dbpedia:Berlin O

http://www.w3.org/DesignIssues/LinkedData.html

Linked Data Infrastruktur

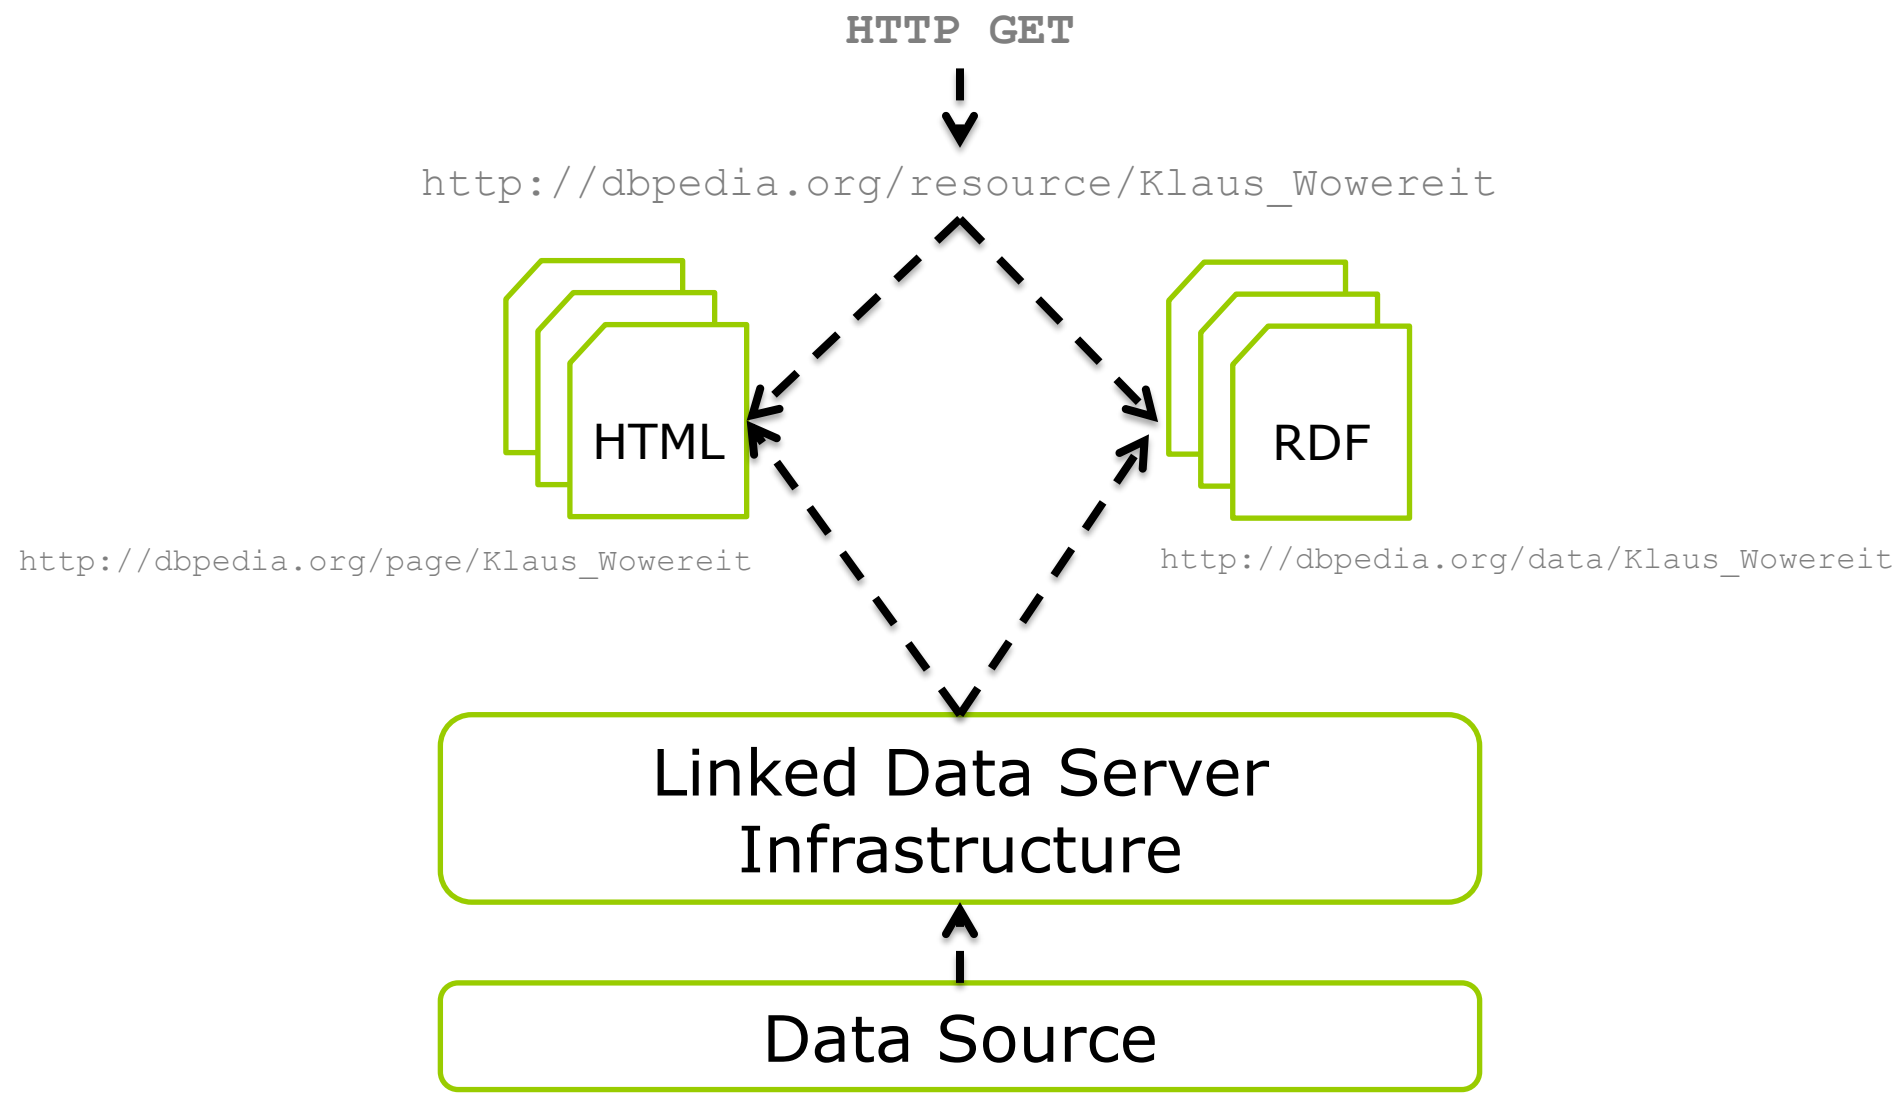

Linked Data Infrastruktur

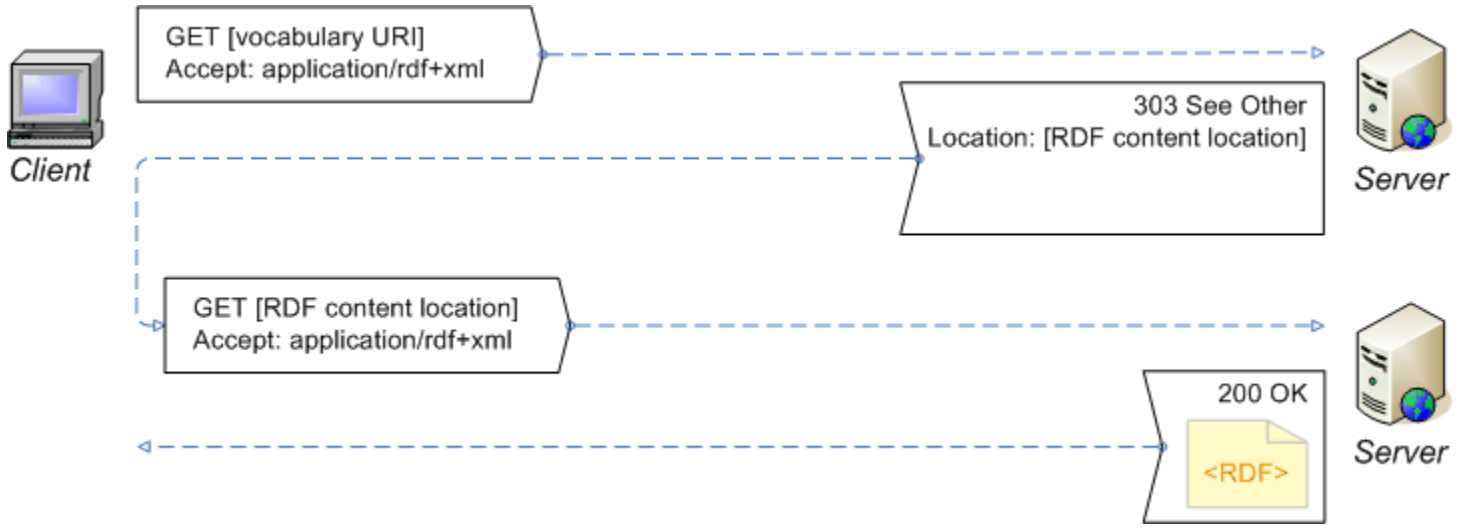

Microdata, RDFa, Microformats

Freie Universität Berlin

Feature	RDFa 1.1	Microdata 1.0	Microformats 1.0
Relative Complexity	High	Medium	Low
Data Model	Graph	Tree	Tree
Item optionally identified by IRI	Yes	Yes	No
Item type optionally specified by IRI	Yes	Yes	No
Item properties specified by IRI	Yes	Yes	No
Multiple objects per page	Yes	Yes	Yes
Overlapping objects	Yes	Yes	No
Plain Text properties	Yes	Yes	Yes
IRI properties	Yes	Yes*	No
Typed Literal properties	Yes	No	No
XML Literal properties	Yes	No	No
Language tagging	Yes	Yes	Inconsistent

...

http://manu.sporny.org/2011/uber-comparison-rdfa-md-uf/