Aufbau von XML-Dokumenten

Heutige Vorlesung

- XML-Syntax
- Namensräume
- Semantik von XML-Elementen

Wiederholung: Was ist XML?

- XML ist eine Methode, um strukturierte Daten in einer Textdatei darzustellen.

- XML sieht fast aus wie HTML, ist aber kein HTML.

- XML ist Text, aber nicht zum Lesen.

- XML ist eine Familie von Techniken.

- XML ist neu, aber nicht so neu.

- XML ist lizenzfrei und plattformunabhängig.

XML-Syntax:

Wohlgeformte XML-Dokumente

Was ist ein XML-Dokument?

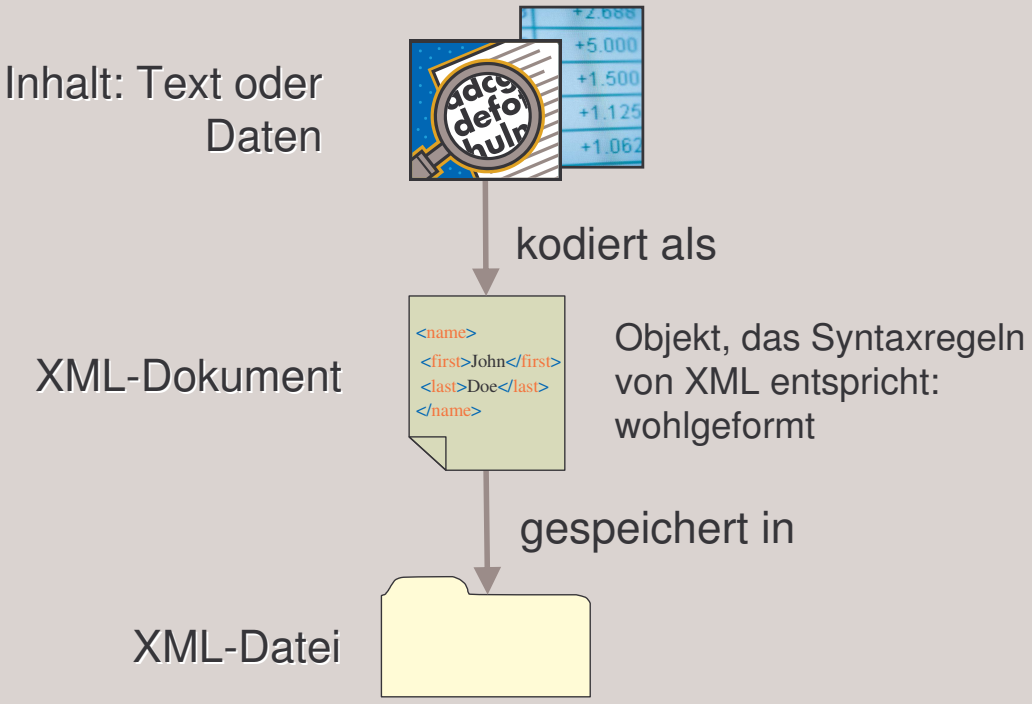

Grundbausteine von XML

- **Elemente**: strukturieren das XML-Dokument
- **Attribute**: Zusatzinformationen zu einzelnen Elementen
- **XML-Deklaration**: Informationen für Parser

```
<?xml version="1.0" encoding="UTF-8"?>
<name id="1232345">
  <first>John</first>
  <middle>Fitzgerald Johansen</middle>
  <last>Doe</last>
</name>
```

- **Namensräume**: lösen Namenskonflikte auf und geben Elemente eine bestimmte Bedeutung

Grundbausteine von XML: Elemente

- Beispiel: `<first>John</first>`
- besteht aus:
  - einem **Anfangs-Tag** (engl. *start tag*): hier <first>
  - einem dazugehörigen **Ende-Tag** (engl. *end tag*): hier </first>
  - einem **Inhalt**: hier „John“
- haben einen **Namen**: hier „first“
- alles zusammen bildet ein **Element**: <first>John</first>

Inhalt von Elementen

vier verschiedene Arten von Inhalt

1. **unstrukturierter Inhalt**
2. **strukturierter Inhalt**
3. **gemischter Inhalt**
4. **leerer Inhalt**

1. Unstrukturierter Inhalt

- Beispiel: <first>John</first>
- einfacher Text *ohne* Kind-Elemente
- **Kind-Element**: Element, das im Inhalt eines Elementes vorkommt
- unstrukturierter Inhalt auch als ***Parsed Character Data*** (**PCDATA**) bezeichnet:
  - *character data*: einfache Zeichenkette
  - *parsed*: Zeichenkette wird vom Parser analysiert, um Ende-Tag zu identifizieren.

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

PCDATA

- Reservierte Symbole < und & in PCDATA *nicht* erlaubt.
- Symbole >, / (,), [,], % etc. hingegen erlaubt.
- statt < und & ***Entity References*** & bzw. < benutzen
- Entity References in XML:

  & ⇨ &

  < ⇨ <

  > ⇨ >

  ' ⇨ '

  " ⇨ "

CDATA

- unstrukturierter Inhalt mit vielen reservierten Symbolen besser als sog. ***Character Data*** (**CDATA**) darstellen
- Beispiel:

```
<formula>
  <![CDATA[ X > Y & Y > Z ]]>
</formula>
```

- Inhalt: String zwischen inneren Klammern [ ]
- hier: X > Y & Y > Z
- XML-Parser sucht in CDATA lediglich]]> , analysiert den Inhalt ansonsten nicht.

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
- Elemente können beliebig tief geschachtelt werden.

3. Gemischter Inhalt (*mixed content*)

- enthält Text mit mind. einem Kind-Element
- Beispiel:

```
<section>
    Text
    <subsection> … </subsection>
    Text
</section>
```


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 Element** <middle/> :

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

Warum leere Elemente?

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

vs.

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

- Kind-Element middle evtl. von einer DTD oder einem XML-Schema vorgeschrieben
- einfacher später mit Inhalten zu füllen
- leeres Element kann Attribute haben:

  <middle status="unknown" ></middle> oder

  <middle status="unknown" />

Grundbausteine von XML: Attribute

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

- Element kann eine beliebige Anzahl von Attributen haben.
- **Attribut**: Name-Wert-Paar der Form **name="wert"** oder **name='wert'**
- Wert *immer* vom Typ PCDATA: < und & *nicht* erlaubt
- ebenfalls ' , " und CDATA *nicht* erlaubt
- Beachte: Reihenfolge der Attribute belanglos

Attribut statt Element

- Jedes Attribut auch als Kind-Element darstellbar:

```
<name id="1232345">
  <first>John</first>
  <middle>Fitzgerald</middle>
  <last>Doe</last>
</name>
```

```
<name>
  <id>12345</id>
  <first>John</first>
  <middle>Fitzgerald</middle>
  <last>Doe</last>
</name>
```

id als Attribut

id als Kind-Element

Element statt Attribut

- Jedes Kind-Element mit *unstrukturiertem* Inhalt auch als Attribut darstellbar:

```
<name>
  <id>12345</id>
  <first>John</first>
  <middle>Fitzgerald</middle>
  <last>Doe</last>
</name>
```

```
<name id="12345"
  first="John"
  middle="Fitzgerald"
  last="Doe" />
```

id, first, middle und last als Kind-Elemente

id, first, middle und last als Attribute

Resultat: leeres Element

Attribut oder Element?

- Attribut kann nur einfachen String (PCDATA) als Wert haben, ein Element kann beliebig strukturiert sein
- CDATA in Element-Inhalt erlaubt, in Attribut-Wert *nicht* möglich
- Reihenfolge der Attribute belanglos, diejenige von Elementen nicht
- Einheitliche Darstellung mit Elementen eleganter, Darstellung mit Attributen kompakter

Fazit: Attribute besonders für einfache, unstrukturierte Zusatzinformationen (Metadaten) geeignet

Beispiel


```
<name id="1232345" creation-date=" 21.05.2003 " >
  <first>John</first>
  <middle>Fitzgerald Johansen</middle>
  <last>Doe</last>
</name>
```

- Schlüssel des Datensatzes (id) und Erstellungsdatum (creation-date) sind Zusatzinformationen.
- Reihenfolge egal
- deshalb jeweils Repräsentation als Attribut
- Nachteil: Datum "21.05.2003" unstrukturiert

Grundbausteine von XML: Deklaration

```
<?xml version="1.0" encoding="UTF-8"?>
<name id="1232345">
  <first>John</first>
  <middle>Fitzgerald Johansen</middle>
  <last>Doe</last>
</name>
```

- enthält Informationen für Parser: z.B. verwendete XML-Version und Kodierung
- muss *immer* am Anfang der Datei stehen

XML-Deklaration

```
<?xml version="1.0" encoding="UTF-8"?>
```

Attribut version

- verwendete XML-Version
- mögliche Versionen: "1.0" und "1.1"
- obligatorisch

Attribut standalone

- Gibt an, ob es eine zugehörige DTD oder ein XML-Schema gibt ("no") oder nicht ("yes").
- optional

Attribut encoding

- Kodierung der XML-Datei
- optional

Beachte: Attribute immer in dieser Reihenfolge!

XML-Deklaration: Kodierung

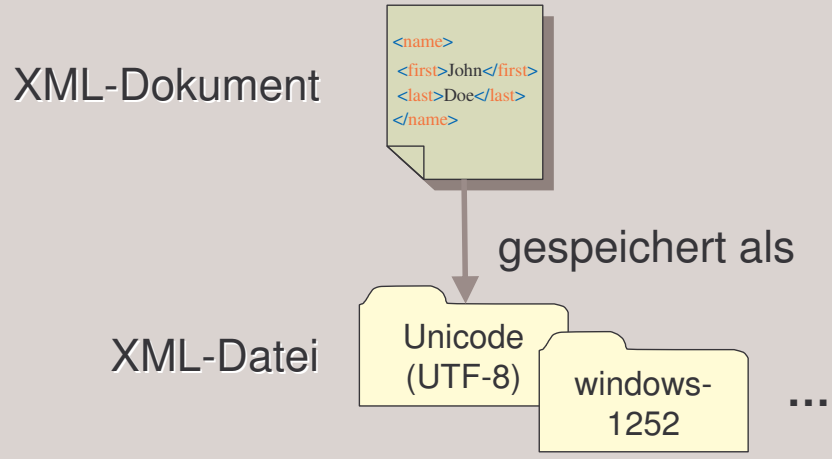

XML-Deklaration: Kodierung

XML-Parser

```
<?xml version="1.0" encoding="UTF-8"?>
```

- müssen gemäß XML-Spezifikation intern mit Unicode (UTF-8 oder UTF-16) arbeiten

Unicode

- kann *alle* nationalen Zeichen darstellen: insgesamt ca. 65.000 Zeichen

encoding-Attribut

- Zeichenkodierung der betreffenden XML-Datei
- Fehlt das Attribut, dann wird Kodierung in Unicode angenommen.
- Beachte: XML-Parser müssen gemäß XML-Spezifikation nur Unicode verarbeiten können!

Regeln für wohlgeformte XML-Dokumente

1. Jedes Anfangs-Tag muss ein zugehöriges Ende-Tag haben.
2. Elemente dürfen sich nicht überlappen.
3. XML-Dokume rzel-Element.
4. Element-Nan Namenskonv
5. XML beachte Kleinschreibung.
6. XML belässt Text.
7. Ein Element darf niemals zwei Attribute mit dem selben Namen haben.

Wie kann aus den Grundbausteinen ein wohlgeformtes XML-Dokument gebildet werden?

Regel 1: Anfangs- und Ende-Tags

- **Jedes Anfangs-Tag muss ein zugehöriges Ende-Tag haben.**
- In HTML gilt diese Regel nicht:

```
<HTML>
 <BODY>
  <P>Text
   <BR>More text in the same paragraph.
  <P>Some text in another paragraph.</P>
 </BODY>
</HTML>
```

- Wo endet das erste P-Element?

⇨ HTML mehrdeutig

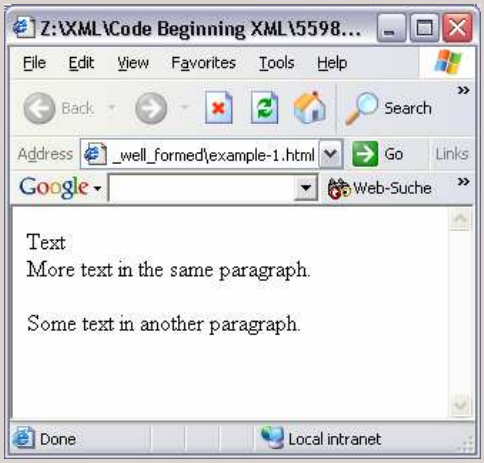

Regel 2: Überlappung von Elementen

- **Elemente dürfen sich nicht überlappen.**
- In HTML gilt diese Regel nicht:

```
<HTML>
 <BODY>
  <P>Some
   <STRONG>formatted
   <EM>text
   </STRONG>, but
   </EM>
   no grammar no good!
  </p>
 </BODY>
</HTML>
```

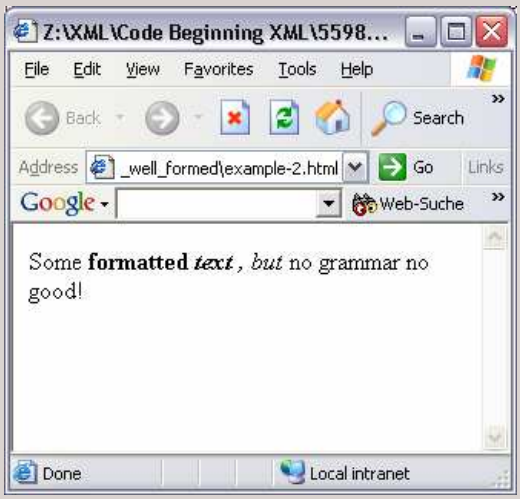

⇨ HTML unstrukturiert

Regel 3: Wurzel-Elemente

- **Jedes XML-Dokument hat genau ein Wurzel-Element.**
- Also z.B. statt zweier Wurzel-Elemente

```
<?xml version="1.0"?>
<name>John</name>
<name>Jane</name>
```

zusätzliches Eltern-Element einführen:

```
<?xml version="1.0"?>
<names>
   <name>John</name>
   <name>Jane</name>
</names>
```

oder

```
<?xml version="1.0"?>
<employees>
   <name>John</name>
   <name>Jane</name>
</employees>
```

Regel 4: Namenskonventionen

Element- und Attribut-Namen:

- beginnen entweder mit einem Buchstaben (Unicode) oder „_“:

  z.B. first, First oder _First
- Nach dem ersten Zeichen zusätzlich Zahlen sowie „-“ und „.“ erlaubt:

  z.B. _1st-name oder _1st.name
- enthalten keine Leerzeichen
- enthalten kein „:“
- beginnen nicht mit „xml“, unabhängig davon, ob einzelne Buchstaben groß- oder kleingeschrieben

Beispiele

- <résumé> ✓
- <xml-tag> *nicht* korrekt: beginnt mit „xml“
- <123> *nicht* korrekt: beginnt mit Zahl
- <fun=xml> *nicht* korrekt: enthält „=“

  erlaubt wären: _, - und .
- <first name> *nicht* korrekt: enthält Leerzeichen

Regel 5: Groß- und Kleinschreibung

- XML beachtet grundsätzlich Groß- und Kleinschreibung.
- Im Gegensatz zu HTML unterscheidet XML also z.B. zwischen <P> und <p>.

Dennoch möglichst nicht gleichzeitig <First> und <first> verwenden!

Regel 6: Unsichtbare Zeichen

- Beispiel:

```
<P>This is a paragraph.          It has a whole bunch
of space.</P>
```

- HTML reduziert unsichtbare Zeichen (Leerzeichen, CR, LF und Tab, engl. *white spaces*) auf ein Leerzeichen

Regel 6: Unsichtbare Zeichen

- **XML belässt alle unsichtbaren Zeichen im Text.**
- Beispiel: Der Inhalt von

```
<P>This is a paragraph.          It has a whole bunch
of space.</P>
```

ist also:

```
This is a paragraph.             It has a whole bunch
of space.
```

- Beachte: Von Browsern werden unsichtbare Zeichen allerdings *nicht* angezeigt.
- Grund: XML-Dokumente werden zur Darstellung im Browser in HTML umgewandelt.

Was gibt es sonst noch?

- Attribut: z.B. **xml:lang="fr"**
- Prozessorinstruktionen: z.B. **<?mySystem value="42"?>**
- Kommentare: z.B. **<!-- Kommentar -->**
- welche **Unicode**-Zeichen, wo erlaubt sind
- Namensräume: z.B. **<xhtml:p>…</xhtml:p>**

XML 1.0 vs. XML 1.1

	XML 1.0	XML 1.1
XML-Deklaration	optional	obligatorisch
Zeilenende (EoL)	LF, CR	LF, CR NEL (IBM-Mainframe)
Unicode in Namen	exklusive Strategie: alle Zeichen verboten, die nicht ausdrücklich erlaubt	inklusive Strategie: alle Zeichen erlaubt, die nicht ausdrücklich verboten

- ⇨ XML 1.1 interoperabel mit IBM-Maineframes
- ⇨ XML 1.1 aufwärtskompatibel zu zukünftige Unicode-Versionen
- ⇨ XML 1.1 nicht abwärtskompatibel!

Viel Lärm um XML 1.1!

- XML 1.0, 3rd Edition zeitgleich mit XML 1.1 veröffentlicht!
- Änderungen in XML 1.1 nur für IBM-Mainframes und Nicht-ASCII-Zeichen relevant
- XML 1.1 verlangt von Parsern, dass beide Versionen erkannt und unterschiedlich behandelt werden:
- wenn keine XML-Deklaration oder explizit Version 1.0:

  Wohlgeformtheit gemäß XML 1.0
- in allen anderen Fällen:

  Wohlgeformtheit gemäß XML 1.1

Kleiner Online-Test zu XML

⇨ http://www.w3schools.com/xml/xml_quiz.asp

- W3 Schools: kostenlose Online-Tutorials zu XML-Technologien

XML-Editoren

- XML-Dokumente werden normalerweise mit speziellen Editoren erstellt und modifiziert.
- meistbenutzter XML-Editor ist XML Spy:
- unterstützt XML-Schemata, XSLT (mit Debugger), Web-Services, Import und Export von Datenbank-Schemata
- steht in den PC-Pools zur Verfügung
- gibt es aber auch als kostenlose vierwöchige Testlizenz

➔ www.xmlspy.com

Namensräume

Namenskonflikte

```
<course>
   <title>Semantic Web</title>
   <lecturers>
      <name>
         <title>Priv.-Doz. Dr. M.S.E</title>
         <first>Steffen</first>
         <last>Staab</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>Priv.-Doz. Dr. M.S.E
          <pers:first>Steffen</pers:first>
          <pers:last>Staab</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
- Auf diese Weise werden auch Namenskonflikte in Programmiersprachen aufgelöst:

  z.B. java.applet.Applet

Namensräume

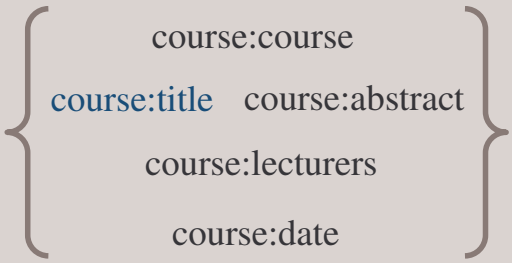

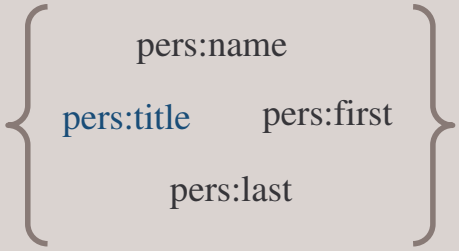

- **Namensraum** (*namespace*): Alle Bezeichner mit identischen Anwendungskontext
- Namensräume müssen eindeutig identifizierbar sein.

Namensräume in XML

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

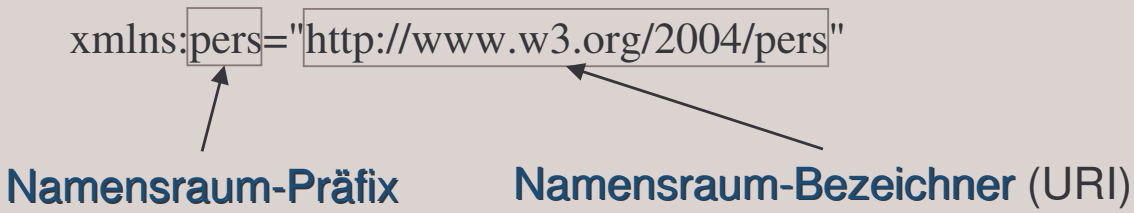

- Anschließend kann das Namensraum-Präfix einem Namen vorangestellt werden: z.B. pers:title
- Beachte: Wahl des Präfixes egal!

Beispiel


```
<course:course xmlns:course="http://www.w3.org/2004/course">
   <course:title>Semantic Web</course:title>
   <course:lecturers>
      <pers:name xmlns:pers="http://www.w3.org/2004/pers">
           <pers:title>Priv.-Doz. Dr. M.S.E</pers:title>
           <pers:first>Steffen</pers:first>
           <pers:last>Staab</pers:last>
      </pers:name>
   </course:lecturers>
   <course:date>12/11/2004</course:date>
   <course:abstract>...</course:abstract>
</course:course>
```

Exkurs: Uniform Resource Identifier (URI)

- eindeutige Bezeichner für Ressourcen im WWW
- URI kann den physischen Aufenthaltsort einer Resource beschreiben:

  http://www.w3.org/1999/xhtml

- Solche URIs werden auch **Uniform Resource Locators** (**URLs**) genannt.

Uniform Resource Indentifier (URI)

- URI kann auch ein Namen einer Resource unabhängig von deren physischen Aufenthaltsort sein:

  urn:oasis:names:specification:docbook:dtd:xml:4.1.2

  urn:isbn:1-861005-59-8

- urn:oasis und urn:isbn werden URI-Schemeta (*URI schemes*) genannt.
- URI-Schemata können bei der IANA registriert werden:
  - genaue Festlegung der Syntax
  - Wer vergibt die dazugehörigen Namen?

URIs als Namensraum-Bezeichner

- Beispiel: http://www.w3.org/1999/xhtml bezeichnet Namensraum für XHTML

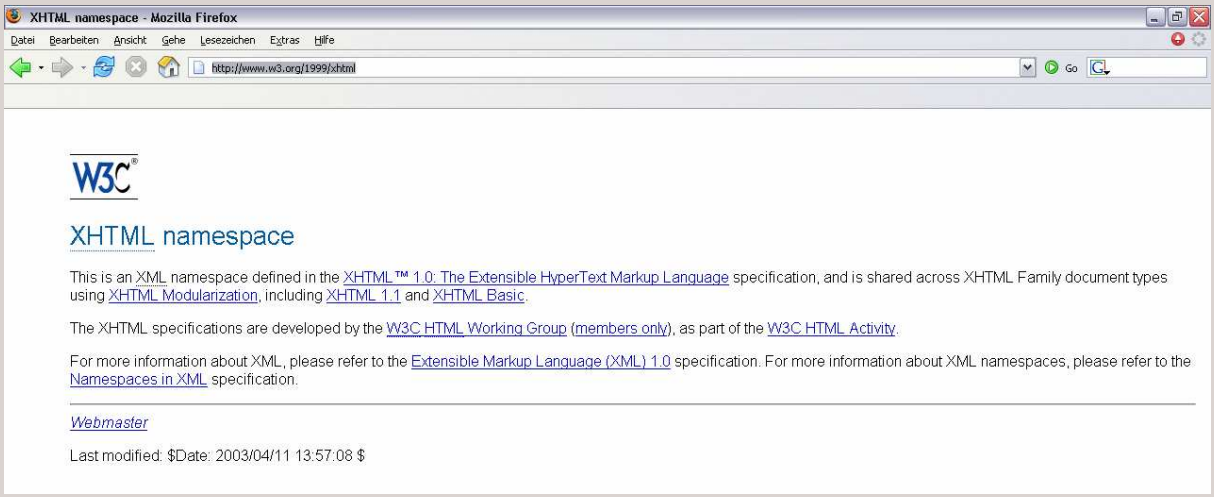

URIs als Namensraum-Bezeichner

- Namensraum-URI *kann* (muss aber nicht) Beschreibung des Namensraumes enthalten.
- Namensraum-URI muss nicht einmal existieren!

URIs als Namensraum-Bezeichner

- Beispiel: xmlns:myns="http://www.book-ns.org"
- http://www.book-ns.org existiert (noch) nicht
- dennoch *kein* Fehler, *keine* Warnung, falls als Namensraum-URL verwendet!
- Eindeutigkeit dann jedoch *nicht* sicher gestellt:
- Jemand anderes kann *gleiche* Namensraum-URL für *anderen* Namensraum verwenden.
- Für eigene Namensräume also am besten nur URLs verwenden, die man selbst besitzt.

Standard-Namensraum


```
<course xmlns="http://www.w3.org/2004/course">
   <title>Semantic Web</title>
   <lecturers>
     <pers:name xmlns:pers="http://www.w3.org/2004/pers">
          <pers:title>Priv.-Doz. Dr. M.S.E</pers:title>
          <pers:first>Steffen</pers:first>
          <pers:last>Staab</pers:last>
     </pers:name>
   </lecturers>
   <date>12/11/2004</da
   <abstract>...</abstract>
</course>
```

- es kann auch ein Standard-Namensraum definiert werden:
  xmlns="*URI*" statt xmlns:prefix="*URI*"
- Namensraum-Präfix kann dann weggelassen werden.

Standard-Namensräume überschreiben

```
<course xmlns="http://www.w3.org/2004/course">
  <title>Semantic Web</title>
  <lecturers>
    <name xmlns="http://www.w3.org/2004/pers">
      <title>Priv.-Doz. Dr. M.S.E</title>
      <first>Steffen</first>
      <last>Staab</last>
    </name>
  </lecturers>
  <date>12/11/2004</date>
  <abstract>...</abstract>
</course>
```

1. Standard-Namensraum

2. Standard-Namensraum

Gültigkeit von Standard-Namensräumen

```
<course xmlns="http://www.w3.org/2004/course">
  <title>Semantic Web</title>
  <lecturers>
    <name xmlns="http://www.w3.org/2004/pers">
      <title>Priv.-Doz. Dr. M.S.E</title>
      <first>Steffen</first>
      <last>Staab</la
    </name>
  </lecturers>
  <date>12/11/2004</
  <abstract>...</abstrac
</course>
```

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

Qualified vs. *Unqualified*

- Element-Name heißt **namensraumeingeschränkt** (*qualified*), wenn er einem Namensraum zugeordnet ist.
- Zwei Möglichkeiten, diese Zuordnung vorzunehmen:
  1. Standard-Namensraum festlegen
  2. Namensraum-Präfix voranstellen

Beispiel 1


```
<?xml version="1.0"?>
<BookStore xmlns="http://www.books.org">
      <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>
```

- alle Element-Namen (einschl. BookStore!) dem Standard-Namensraum zugeordnet
- alle Element-Namen daher namensraumeingeschränkt (*qualified*)

Beispiel 2

```
<?xml version="1.0"?>
<bk:BookStore xmlns:bk="http://www.books.org">
      <bk:Book>
            <bk:Title>My Life and Times</bk:Title>
            <bk:Author>Paul McCartney</bk:Author>
            <bk:Date>July, 1998</bk:Date>
            <bk:ISBN>94303-12021-43892</bk:ISBN>
            <bk:Publisher>McMillin Publishing</bk:Publisher>
      </bk:Book>
</bk:BookStore>
```

- alle Element-Namen haben Namensraum-Präfix
- alle Element-Namen daher namensraumeingschränkt (*qualified*).

Beispiel 3

```
<?xml version="1.0"?>
<bk:BookStore xmlns:bk="http://www.books.org">
      <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>
</bk:BookStore>
```

- hier kein Standard-Namensraum festgelegt
- bk:Bookstore: namensraumeingeschränkt (*qualified*)
- alle anderen Element-Namen: *ohne* Namensraum-Präfix, daher nicht namensraumeingeschränkt (*unqualified*)

Was bedeutet … ?

HTML:

- Bedeutung festgelegt (p = Absatz)

XML:

- Bedeutung offen
- kann aber mit **Namensraum** festlegt werden
- Beispiel: p stammt aus dem Namensraum für XHTML.

xhtml ist Abkürzung für Namensraum

```
<xhtml:p xmlns:xhtml="http://www.w3.org/1999/xhtml">…</xhtml:p>
```

Namensraum:
u.a. p = Absatz

Und das war es schon?

- Ja!
- Syntax wohlgeformter XML-Dokumente (fast) vollständig vorgestellt
- Ausnahmen: Prozessorinstruktionen <?.....?> und erlaubte Unicode-Zeichen
- XML-Syntax also sehr einfach
- gleichzeitig ist XML beliebig erweiterbar
- Und das ist genau die Stärke von XML: einfach und flexibel!

Wie geht es weiter?

- ☑ XML-Syntax
- ☑ Namensräume
- ☑ Semantik von XML-Elementen
- Definition von XML-Sprachen mit DTDs und XML-Schema