Institut für Informatik

Vorlesung
Werkzeuge der Informatik

Grundlagen und Werkzeuge des WWW (Teil 2)

Jörg P. Müller

Inhalt

- **Entwicklung von Internet und WWW**
- **WWW-Architektur und Protokolle**
  - **Web Ressourcen (oder: Was ist eine URL)**
  - **Basisprotokoll des Internet: TCP/IP**
  - **WWW-Architektur (Client-Server)**
  - **Das HTTP-Protokoll**
- **Darstellung von WWW-Inhalten**
  - **HTML als Web Content Sprache**
  - **Die eXtensible Markup Language (XML)**
  - **XML Schema (Basics)**

Das Dokumentenmodell des WWW

- **Dokumente kann Referenzen (Hyperlinks) auf ein anderes Dokument enthalten**
- **Hyperlinks werden durch Browser explizit angezeigt → Auswahl durch Anklicken**
- **Auswahl eines Hyperlinks erzeugt Anforderung an den Server, auf dem das entsprechende Dokument abgelegt ist (über URL)**
- **Von dort wird es auf die Maschine des Nutzers übertragen und im Browser angezeigt**
- **Sprache für Webdokumente:**
  HTML: Hypertext Markup Language

Hypertext Markup Language

- **Markup-Sprache zur Annotation und Strukturierung von Dokumenten**
- **HTML-Dokumente bestehen aus Kopfteil** <HEAD> **und Rumpf** <BODY>
- **HTML-Sprachelemente (=Tags) zum**
  - **Markieren von Überschriften, Listen, Tabellen, Formularen**
  - **Einfügen von Bildern und Animationen**
  - **Gestaltung der Darstellung im Browser (z.B. Schriften, Schriftgrößen, kursive oder fettgedruckte Anzeige, Ausrichtung, Farben, Textabsätze)**
- **Notation von HTML-Tags in spitzen Klammern, z.B.**
  - **<H1>Hello World</H1>**
- **HTML-Tags schließen in der Regel Text ein**
- **Web Browser verwendet HTML-Parser: Software, die HTML-Tags erkennt und in strukturierten Text umsetzt.**
- **Erweiterungen erlauben die Darstellung von Teilen eines Dokumentes in Form eines im Browser ausführbaren Skriptes (z.B. Javascript)**

HTML – Ein erstes Beispieldokument

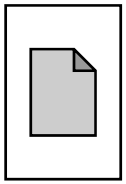

```
<HTML>
 <HEAD>
  <TITLE>Meine Homepage</TITLE>
 </HEAD>
 <BODY>
  <H1>Homepage von J&ouml;rg M&uuml;ller</H1>
   Dies ist meine erste HTML-Seite.
   <p>
   Sie enth&auml;lt einen Paragraphen und einen <br>Zeilenumbruch.
   </p>
   Au&szlig;erdem kann man auch <b>fett</b> und <i>kursiv</i>
  schreiben.
 </BODY>
</HTML>
```

Zeichendarstellung in HTML

- **HTML-Texte werden in Dateien in binärer Form (bytes) abgespeichert**
- **Web-Browser muss Bytes wieder in Zeichen (Buchstaben etc.) umwandeln**
  - **Zeichenkodierung, erfolgt mithilfe einer Codetabelle, die jedem erlaubten Zeichen aus dem Zeichenvorrat eine fortlaufende Nummer zuweise**
  - **Verschiedene Zeichenkodierungsschemata**
  - **z.B. UNICODE: "a"→97, "b"→98, "c"→99, etc.**
- **Browser muss bei der Anzeige die gleiche Kodierung angeben, die der Editor beim Abspeichern verwendet**
  - **Spezifikation der Zeichenkodierung im Kopf des HTML-Dokumentes**

Zeichendarstellung in HTML (2)

- **Beispiel:**

```
<head>
<meta http-equiv="content-type"
      content="text/html; charset=ISO-8859-1">
<!-- ... andere Angaben im Dateikopf ... -->
</head>
```

- **Darstellung von Sonderzeichen mittels benannter HTML-Elemente, z.B.**
  - `&uuml;` für "ü", `&Uuml;` für "Ü"
  - `&` für "&", `&szlig;` für "ß"
- **Beispiel:**

```
J&ouml;rg M&uuml;ller trinkt im Hofbr&auml;uhaus
Bier aus Ma&szlig;kr&uuml;gen.
```

Elemente zur Textstrukturierung

- **Bereits kennengelernt: Überschriften, Textabsätze**
- **Darstellung von Listen und Aufzählungen**

```
<ul> <!-- dies ist eine unsortierte Liste -->
<li>Element 1</li>
<li>Element 2</li>
<li>Element 3</li>
</ul>

<ol> <!-- dies ist eine nummerierte Liste -->
<li>Element 1</li>
<li>Element 2</li>
<li>Element 3</li>
</ol>
```

- **Listen können geschachtelt sein**

Beispiel: Listen in HTML

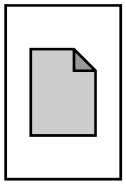

```
<HTML>
 <HEAD><TITLE>Meine Homepage</TITLE></HEAD>
 <BODY>
  <H1>Homepage von J&ouml;rg M&uuml;ller</H1>
   Berufliche Laufbahn:
     <ul>
     <li>seit 2005: Professor an der TU Clausthal</li>
     <li>1999-2006: Principal Research Scientist bei Siemens
       Corporate Technology, München</li>
     <li>Davor: <ol><li> Drei Jahre Berufserfahrung</li>
                  <li> Studium und Promotion</li>
                  <li> Schule und Kindergarten</li>
                </ol>
     </li>
     </ul>
</BODY>
</HTML>
```

HTML Tabellen

- **Tabellen werden häufig zur Strukturierung von HTML-Dokumenten eingesetzt**
- **Aufbau einer Tabelle in HTML**
  - **Tabelle `<table>`**
  - **Zeile `<tr>`**
  - **Tabellenkopfelement `<th>`**
  - **Tabellendatenelement `<td>`**
  - **Weitere Attribute für Form (z.B. `border`)**

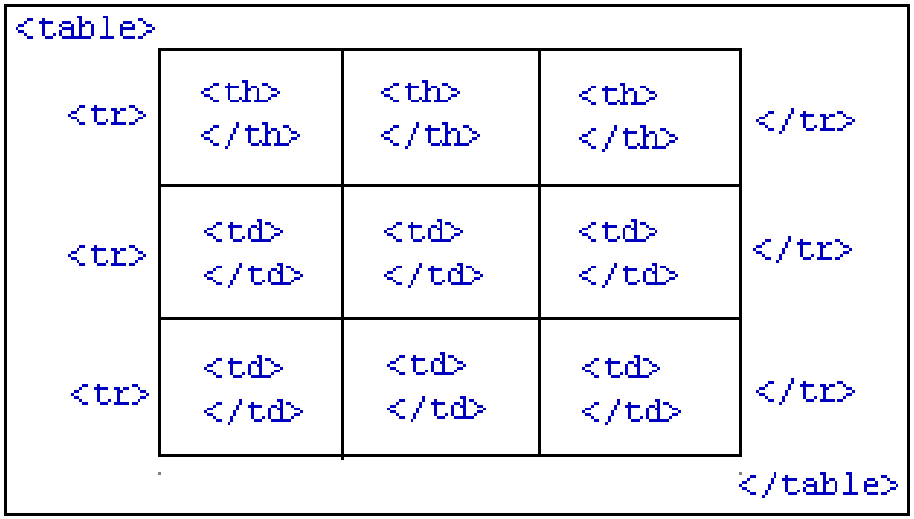

Quelle: de.selfhtml.org

Beispiel: Tabellen zur Strukturierung von Dokumenten

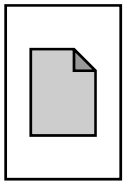

```
<HTML>
 <HEAD><TITLE>Meine Homepage</TITLE></HEAD>
 <BODY>
  <H1>Homepage von J&ouml;rg M&uuml;ller</H1>
 <table border="1">
  <tr> <td colspan="3">Berufliche Laufbahn</td></tr>
  <tr> <th>Jahr</th> <th>T&auml;tigkeit</th>
       <th>Organisation / Ort</th></tr>
  <tr> <td>seit 2005</td> <td>Professor</td>
       <td>TU Clausthal</td> </tr>
  <tr> <td>1999-2006</td> <td>Principal Research Scientist</td>
       <td>Siemens Corporate Technology, München</td> </tr>
  <tr> <td colspan="3">und so weiter</td></tr>
  </table>
</BODY>
</HTML>
```

HTML Formulare

- **Zweck: Eingabe (über Eingabefelder o. Auswahllisten) und Senden (über Button) von Daten vom Client zum Server**
- **Erstellen eines Formulars in HTML, dabei wird spezifiziert, was mit den eingegebenen Daten passieren soll**
- **Anwendungen:**
  - **Suchmaschinen**
  - **Benutzeranmeldung bei einer Web-Applikation**
  - **Erfassen von Nutzer- und Bestelldaten in E-Shops**

Definition von Formularen: Das <form> Tag

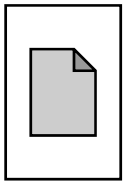

```
<HEAD><TITLE>Meine Homepage</TITLE></HEAD>
 <BODY>
  <H1>Homepage von J&ouml;rg M&uuml;ller</H1>
<p> Mit diesem Formular können Sie mit mir Kontakt aufnehmen
  </p>
  <form action="http://de.selfhtml.org/cgi-bin/comments.pl">
   <!-- Hier wird das Formular definiert -->
  </form>
 </body>
</html>
```

Der Formularinhalt (1)

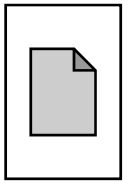

```
<form action="http://de.selfhtml.org/cgi-bin/comments.pl">
 <table border="0" cellpadding="5" cellspacing="0"
        bgcolor="#E0E0E0">
  <tr>
   <td align="right">Vorname:</td>
   <td><input name="Vorname" type="text" size="30"
              maxlength="30"> </td>
  </tr>
  <tr>
   <td align="right">Zuname:</td>
   <td><input name="Zuname" type="text" size="30"
              maxlength="40"></td>
  </tr>
  <tr>
   <td align="right" valign="top">Kommentar:</td>
   <td><textarea name="Text" rows="5" cols="50">
       </textarea></td>
  </tr>
 </table>
</form>
```

So sieht‘s dann im Web Browser aus …

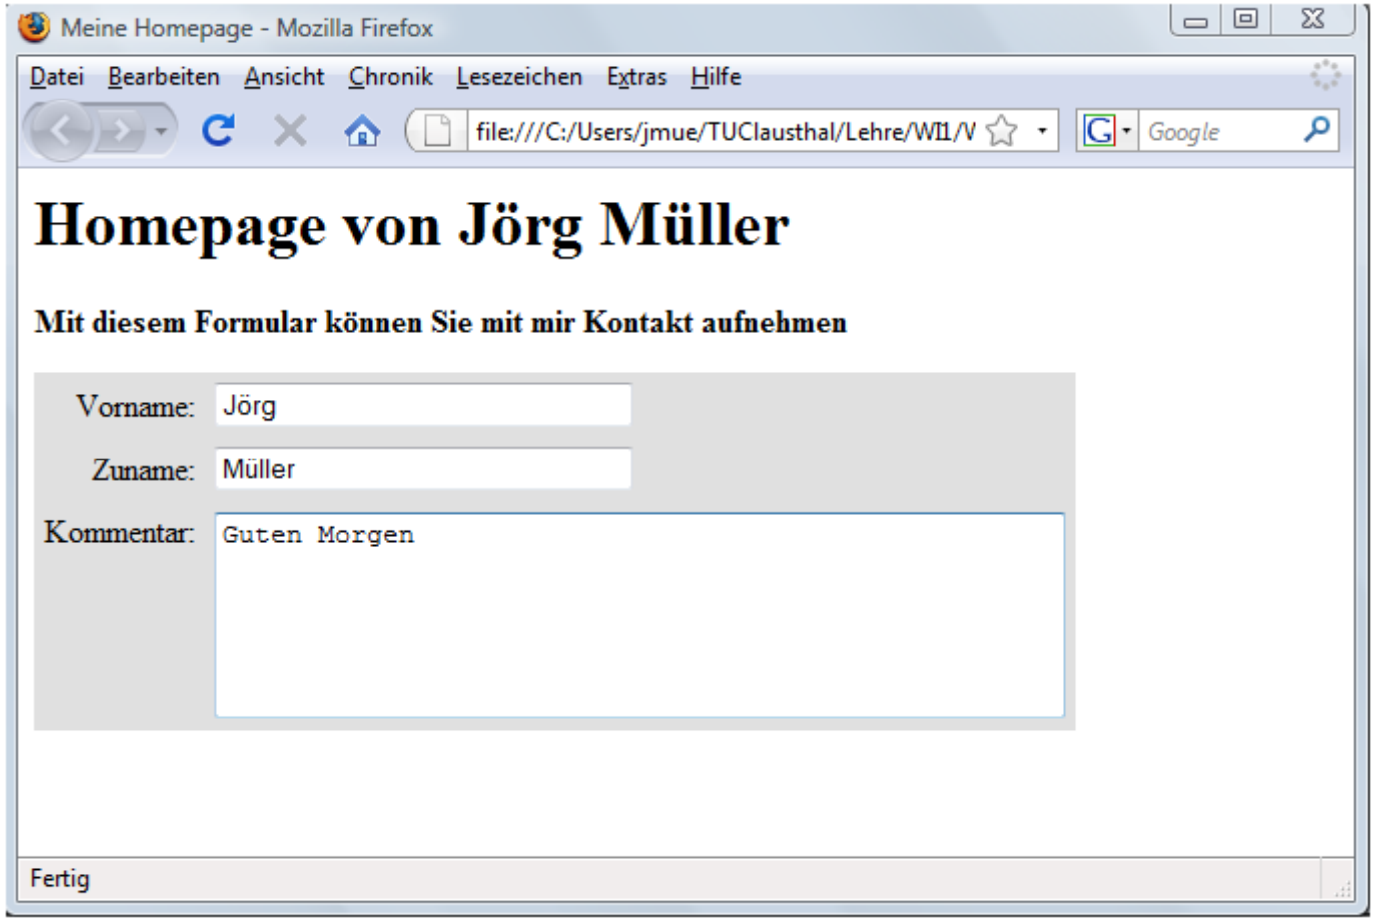

Was fehlt hier?

Der Button zum Absenden!

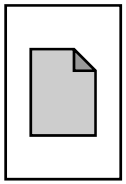

```
<form action="http://de.selfhtml.org/cgi-bin/comments.pl">
  <table border="0" cellpadding="5" cellspacing="0"
         bgcolor="#E0E0E0">
    <tr><!-- Hier Vorname --> </tr>
    <tr><!– Hier Zuname --> </tr>
    <tr><!– Hier Kommentar --> </tr>
    <tr>
      <td align="right">Formular:</td>
      <td>
        <input type="submit" value=" Absenden ">
        <input type="reset" value=" Abbrechen">
      </td>
    </tr>
  </table>
</form>
```

Das sieht dann so aus:

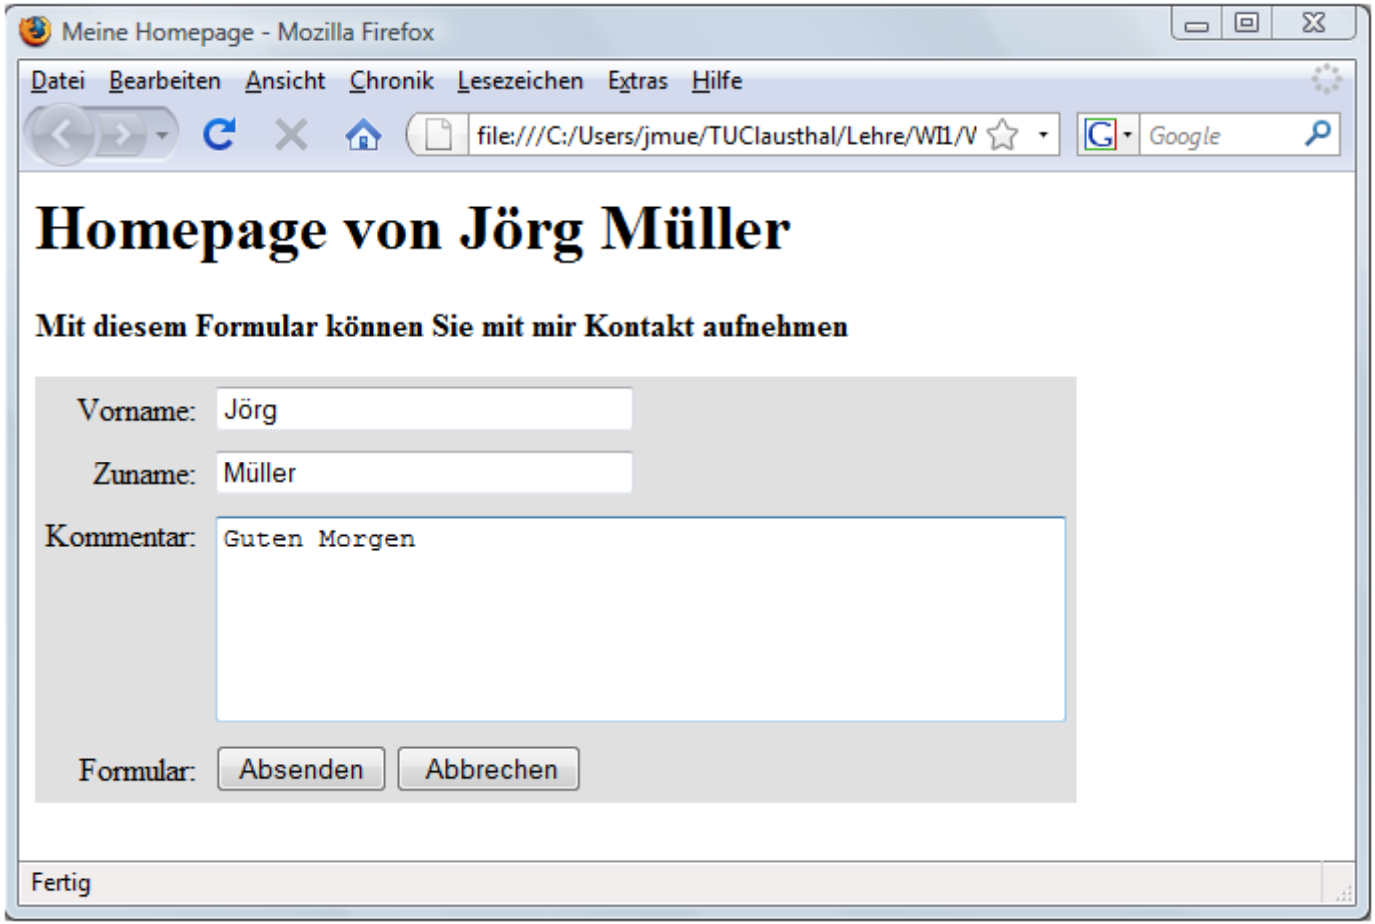

Und das wird übertragen:
http://de.selfhtml.org/cgi-bin/comments.pl?Vorname=J%F6rg&Zuname=M%FCller&Text=Guten+Morgen

Und hier nochmal der ganze HTML Code

```
<HEAD><TITLE>Meine Homepage</TITLE></HEAD>
 <BODY>
  <H1>Homepage von J&ouml;rg M&uuml;ller</H1>
  <p><b>Mit diesem Formular können Sie mit mir Kontakt aufnehmen </b></p>
  <form action="http://de.selfhtml.org/cgi-bin/comments.pl">
   <table border="0" cellpadding="5" cellspacing="0" bgcolor="#E0E0E0">
    <tr> <td align="right">Vorname:</td>
     <td> <input name="Vorname" type="text" size="30" maxlength="30"> </td> </tr>
    <tr> <td align="right">Zuname:</td>
     <td><input name="Zuname" type="text" size="30"  maxlength="40"></td></tr>
    <tr> <td align="right" valign="top">Kommentar:</td>
     <td> <textarea name="Text" rows="5" cols="50"> </textarea></td> </tr>
    <tr><td align="right">Formular:</td>
     <td> <input type="submit" value=" Absenden ">
          <input type="reset" value=" Abbrechen">
     </td></tr>
   </table>
  </form>
 </body>
</html>
```

Attribute des <form> Tags

- **`action`: Gibt an, was mit den Eingabedaten passieren soll, wenn das Formular abgesendet wird, z.B.**
  - **Email senden:**
    ```
    <form action="mailto:mueller@tu-clausthal.de" …>
    ```
  - **Programm auf dem Server aufrufen, das die Daten weiterverarbeitet**
    ```
    <form action="http://www.tu-clausthal.de/cgi-bin/feedback.pl" …>
    ```
- **`method`: Auswahl der http-Übertragungsmethode für die Formulardaten (s.o.)**
  - **`get`: Daten des ausgefüllten Formulars als Parameter an die Aufrufadresse angehängt**
  - **`post`: Daten des ausgefüllten Formulars werden vom Web-Server über den Standardeingabekanal (d.h. im Body des HTTP-Requests) zur Verfügung gestellt**
  - **`put`: Verwendet für das Upload einer Datei vom Client zum Server**

HTML: Zusammenfassung

- **Hypertext Markup Language (HTML)**
  - **einheitliches, fixes Markup-System**
- **Vorteile:**
  - **einfach**
  - **portabel**
  - **einheitliche Handhabung von Verweisen (Links)**
- **HTML erlaubt erstmals den breiten Einsatz einheitlicher Schnittstellen zu Information und Software-Applikationen innerhalb einer Organisation**

Nachteile von HTML

- **HTML ist nicht erweiterbar:**
  - **Markup (Elemente und Attribute)**
  - **Verweise**
- **HTML unterstützt nicht die Modellierung strukturierter Informationen (Objektmodelle, relationale Datenbanken)**
- **Integration von Software-Applikationen**
  - **JavaScript, PlugIns**
  - **Proprietäre Formate und Sprachen**
- **Handhabbarkeit: unzureichende Entkopplung von Inhalt und Präsentation / Layout**
- **Ständiger Wandel der HTML Sprache**

XML

- **XML = eXtended Markup Language**
- **Ursprung: HTML4.0 $\in$ XML $\subset$ SGML (Standard Generalized Markup Language, ISO 8879)**
- **Web-Standard (W3C) für semi-strukturierte Dokumente**
- **Zwei Arten von Dokumenten:**
  - **Document-Type-Definitions (DTD‘s) definieren über eine kontextfreie Grammatik, was ein legales XML Dokument ist**
  - **XML Dokumente: sind die Datendokumente, strukturiert bzgl. einer DTD**
- **HTML & XML:**
  - **HTML beschreibt die Präsentation eines Dokumentes durch feste Tags**
  - **XML beschreibt den Inhalt durch benutzerdefinierte Tags**
- **Grundidee von XML: Trennung von Inhalt, Struktur und Präsentation**

Beispiel eines XML Dokumentes

```
<?xml version="1.0" encoding="ISO-8859-1" standalone="yes">
<ORDER>
   <SOLD-TO>
     <PERSON><LASTNAME>Layman</LASTNAME>
             <FIRSTNAME;>Andrew</FIRSTNAME>
     </PERSON>
   </SOLD-TO>
   <SOLD-ON>19970317</SOLD-ON>
   <ITEM>
     <PRICE>5.95</PRICE>
     <BOOK>
       <TITLE>Number, the Language of Science</TITLE>
       <AUTHOR>Dantzig, Tobias</AUTHOR>
     </BOOK>
   </ITEM>
   <ITEM">
     <PRICE>12.95</PRICE>
     <BOOK>
       <TITLE>Introduction to Objectivist
           Epistemology</TITLE>
       <AUTHOR>Rand, Ayn</AUTHOR>
       <ISBN>0-452-01030-6</ISBN>
     </BOOK>
   </ITEM>
</ORDER>
```

XML Element

- **Ein XML Element ist ein Dokumentfragment eingeschlossen in Name Tags <my_element> .... </my_element >**
  - **<my_element> Markiert den Elementanfang**
  - **</my_element> Markiert das Elementende**
- **Zwischen Anfangs- und End Tag können sein :**
  - **beliebiger Freitext**
  - **Andere Elemente (Verschachtelung)**
  - **nichts, leere Elemente können abgekürzt werden durch: <my_element />**
- **Beispiel:**

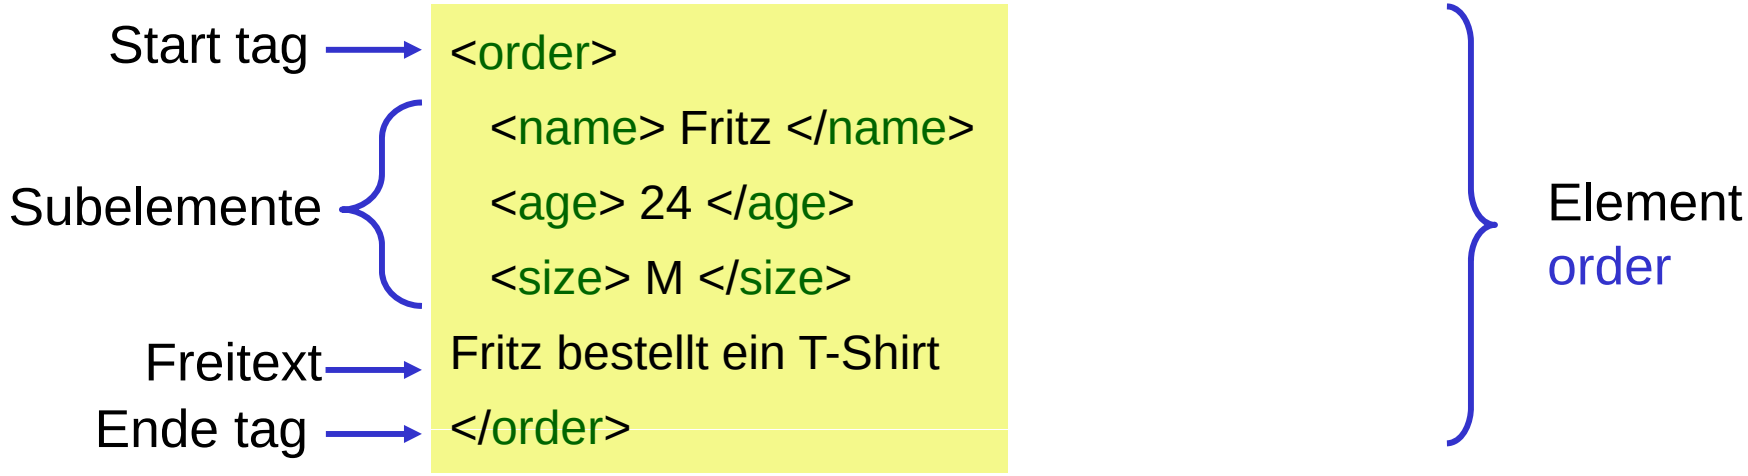

XML Attribute

- **XML Elemente können Attribute besitzen.**
- **Ein XML Attribut wird als Attribut-Wert-Paar dargestellt**
- **XML Attribute werden im Start-Tag kodiert**

  <my_element my_attr1="value1" my_attr2="value2" >

- **Beispiel:**


```
<order name="Fritz" age="24 " size="M">
Fritz bestellt ein T-Shirt
</order >
```

Document Type Definitions (!ELEMENT)

- **Bescheibung der zulässigen XML Dokumente**
  - **Deklaration der Tags und Attribute**
  - **Deklaration der Verschachtelungsstruktur**

- **Syntax: <!ELEMENT name (definition)>**
  - **name: Name des Element Tags**
  - **definition: erlaubte Sub-Elemente und andere Inhalte**
- **Syntax für definition:**
  - EMPTY**: nur leeres Element erlaubt**
  - #PCDATA **(Parsed Character DATA): Freitext**
  - (a,b,c)**: Liste der Sub-Elemente (a,b,c sind die Namen der Sub-Elemente die in dieser Reihenfolge vorkommen müssen)**
  - (a|b|c)**: Liste alternativer Sub-Elemente (Auswahl)**
  - **Jedes Sub-Element kann eine Kardinalitätsspezifikation besitzen:**
    - * **Element kommt kein mal oder beliebig oft vor**
    - \+ **Element kommt mindestens einmal vor (oder öfter)**
    - ? **Element kommt kein mal oder einmal vor**

    Ohne Angabe: Element kommt genau einmal vor

Beispiel

- **DTD Fragment**

```
<!ELEMENT person (name, age?, size?)>
<!ELEMENT name (#PCDATA)>
<!ELEMENT age (#PCDATA)>
<!ELEMENT size (#PCDATA)>
```

- **XML Document**

```
<person>
   <name> Fritz </name>
   <age> 24 </age>
   <size> M </size>
</person>
```

Sonstige XML Sprachkonstruktue

- **Objekt-Referenzen, z.B.**

```
&lt; &gt; &amp; &apos; &quot;&uuml;&tuclogo;
```

- **Kommentare**

```
<!-- dies ist ein Kommentar -->
```

- **Anweisungen**
  - **dienen zur Übergabe von Information an Applikationen, z.B.**

```
<?XML VERSION=1.0 RMD="NONE" ENCODING="UTF-8"?>
```

  - **allgemeine Form:**

```
<?name parameterliste?>
```

- **CDATA Sektionen**
  - **Zeichen in CDATA Sektionen werden vom XML-Prozessor ignoriert; z.B. Programm-Listings:**

```
<! [CDATA[ *p = &q;
           b = ( I <= 3 ); ]]>
```

Eigenschaften von XML-Dokumenten: Wohlgeformtheit und Gültigkeit

- **Strikte Sprachdefinition erlaubt Test auf wichtige Eigenschaften**
  - **Wohlgeformtheit (bzgl. der Syntax von XML)**
  - **Gültigkeit (bezüglich einer DTD)**
- **XML-Dokument heißt wohlgeformt, wenn:**
  - **Es mit der Anweisung `<?xml …>` beginnt**
  - **das gesamte Dokument in ein einzelnes Wurzelelement eingeschlossen ist**
  - **Alle unbedingt erforderlichen Attribute angegeben sind**
  - **Alle Attribute den richtigen Wertebereich / Typ haben**
  - **Alle eingesetzten Elemente korrekt ineinander verschachtelt sind**
- **XML-Dokument heißt gültig (bzgl. einer DTD), wenn:**
  - **das Dokument ist wohlgeformt**
  - **eine zugehörige interne oder externe DTD existiert und ist verfügbar**
  - **das Dokument entspricht den in der DTD ausgestellten Regeln**

Interne Darstellung eines XML-Dokuments

- **Darstellung als Baumstruktur**
- **Knoten sind Elemente**
- **Kanten: Beziehungen zwischen Elementen**
  - **Nachfolger ("Kind")**
  - **Vorgänger ("Elternknoten")**
- **Existenz eines "Wurzelknoten„**
- **Nachfolger ("Kinder") eines Knotens sind die in ihm enthaltenen Elemente**
- **Attribute sind dem ihr Element entsprechenden Knoten zugeordnet**
- **XML-Anwendungen (Parser, XSLT) arbeiten auf dieser Baumstruktur**
- **Standard-Modell: (www.w3.org/DOM)**
  DOM (Document Object Modell) mit Implementierungen z.B. für Java

Beispiel: DOM Darstellung eines XML-Dokuments

```
<table border="1">
 <tbody>
  <tr>
   <th>Hamburg</th>
   <th>M&uuml;nchen</th> </tr>
  <tr>
   <td>Flensburger</td>
   <td>Augustiner</td>
  </tr>
 </tr>
 <tbody>
</table>
```

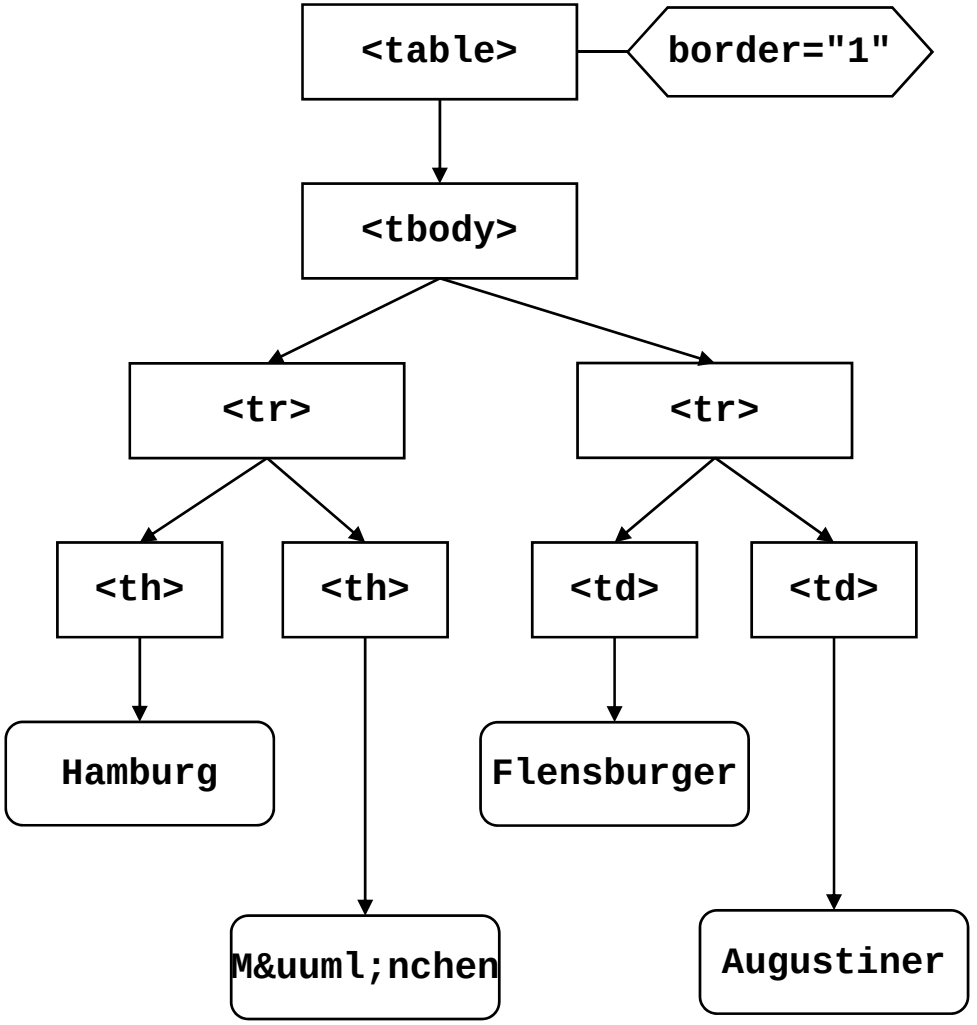

XML Schema

- **Schwäche von XML: Es gibt keine Datentypen, es gibt nur STRINGs**

```
<ITEM>
    <PRICE>5.95</PRICE>
</ITEM>
```

Keine Möglichkeit, auszudrücken, dass hier nur Zahlen erlaubt sind

- **XML Schema:**
  - **Standard entwickelt vom W3C (siehe : www.w3.org/XML/Schema)**
- **Standardisierte Beschreibung komplexerer (auch zusammengesetzter) Datenformate**
  - **Vordefinierte Datentypen**
  - **Untertypenbildung**
  - **Namensräume**
- **XML Schema beschreibt ein XML Dokument**
  - **ähnliche Funktion wie die DTD, aber mehr Struktur**
  - **ist selbst ein XML Dokument (Meta-Beschreibung) und keine DTD**

Einfache Datentypen

- **Standard-Datentypen sind vordefiniert z.B.:**
  - **string, integer, positiveInteger, boolean,**
  - **time, date, duration,**
  - **ID und IDREF (aus XML)**
- **Datentypen können eingeschränkt werden, z.B.:**
  - **length, minLength, maxLength (z.B. Länge von Strings)**
  - **minInclusive, maxInclusive: Wertebereiche bei numerischen Typen**
  - **enumeration: Definition von Aufzählungstypen (basierend auf string)**
- **Definiert durch Schema-Elemente: `<xsd:simpleType>` und `<xsd:restriction>`**

Syntaxbeispiele

```
<xsd:simpleType name="sizeType">
  <xsd:restriction base="xsd:string">
   <xsd:enumeration value="S" />
   <xsd:enumeration value="M" />
   <xsd:enumeration value="L" />
  </xsd:restriction>
</xsd:simpleType>

 <xsd:simpleType name="ageType">
  <xsd:restriction base="xsd:integer">
   <xsd:minInclusive value="0" />
   <xsd:maxInclusive value="150" />
  </xsd:restriction>
</xsd:simpleType>
```

Aufzählungstyp {S, M, L}

Range [0...150]

Komplexe Datentypen

- **Definiert durch Schema-Elemente: `<xsd:complexType>`**
- **Definition von verschachtelten XML-Elementen:**
  - **`<xsd:sequence>` : Folge von Elementen**
  - **`<xsd:choice>` : Auswahl aus einer Menge von Elementen**
  - **`<xsd:all>` : Menge von Elementen, Reihenfolge egal**
  - **`<xsd:group>` : Definition und Referenz auf wiederverwendbare Gruppe von Elementen**
- **Innerhalb dieser Schemaelemente werden lokale XML-Elemente definiert durch:**
  - **<xsd:element name="...Elementname..." type="...Typname..." minOccurs="...Zahl..." maxOccurs="...Zahl..."/>**

Kardinalität: untere Schranke

Kardinalität: obere Schranke

Syntaxbeispiele

```
<xsd:complexType name="personType">
  <xsd:sequence>
   <xsd:element name="name" type="xsd:string" />
   <xsd:element name="age" type="ageType" minOccurs="0"/>
   <xsd:element name="size" type="sizeType" minOccurs="0"/>
  </xsd:sequence>
</xsd:complexType>

<xsd:element name="person" type="personType" />
```

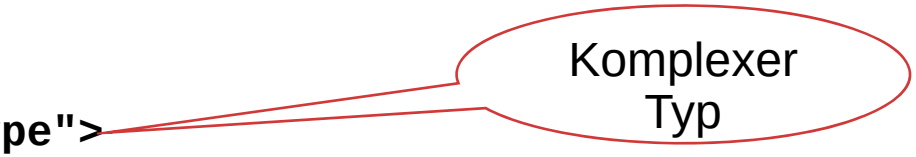

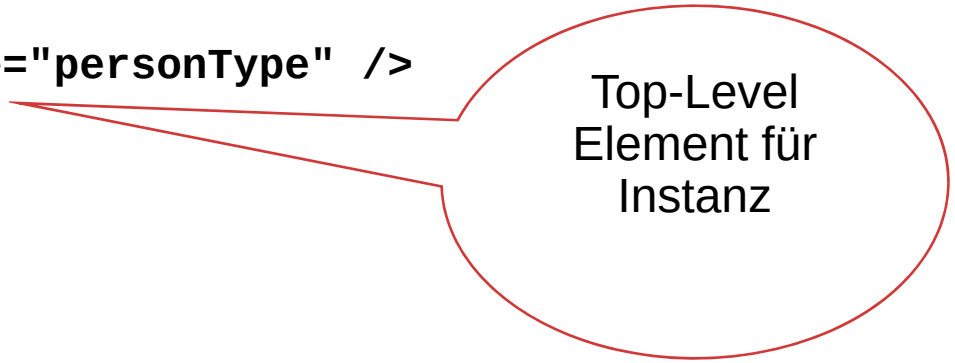

Instanz des Schemas:

```
<person>
  <name> Fritz </name>
  <age> 24 </age>
  <size> M </size>
</person>
```