

Vortrag gehalten am 20. Januar 2004
Otto-von-Guericke-Universität Magdeburg



XML

Document Object Model

Ein Vortrag von Markus Durzinsky

Student der Otto-von-Guericke-Universität
Magdeburg



0. Gliederung

1. Modelle zum Einlesen von XML
2. DOM – Document Object Model
 1. Node-Schnittstelle
 2. spezialisierte Knoten
 3. andere Schnittstellen
3. JavaScript und DOM
4. Zusammenfassung
5. Quellenangabe



Modelle zum Einlesen von XML

- Einlesen von XML-Dokumenten als
 - reiner Text
 - Folge von Ereignissen
 - Baumstruktur



Ereignisorientiertes Modell

- spezifiziert in SAX (Simple API for XML)
- ein Beispiel:


- ```
<person alter="25">
 <name>Peter Schmidt</name>
 <beruf>Student</beruf>
</person>
```
- attribut: alter, Wert: "25"
- startElement: person
- startElement: name
- content: "Peter Schmidt"
- endElement: name
- startElement: beruf
- content: "Student"
- endElement: beruf
- endElement: person



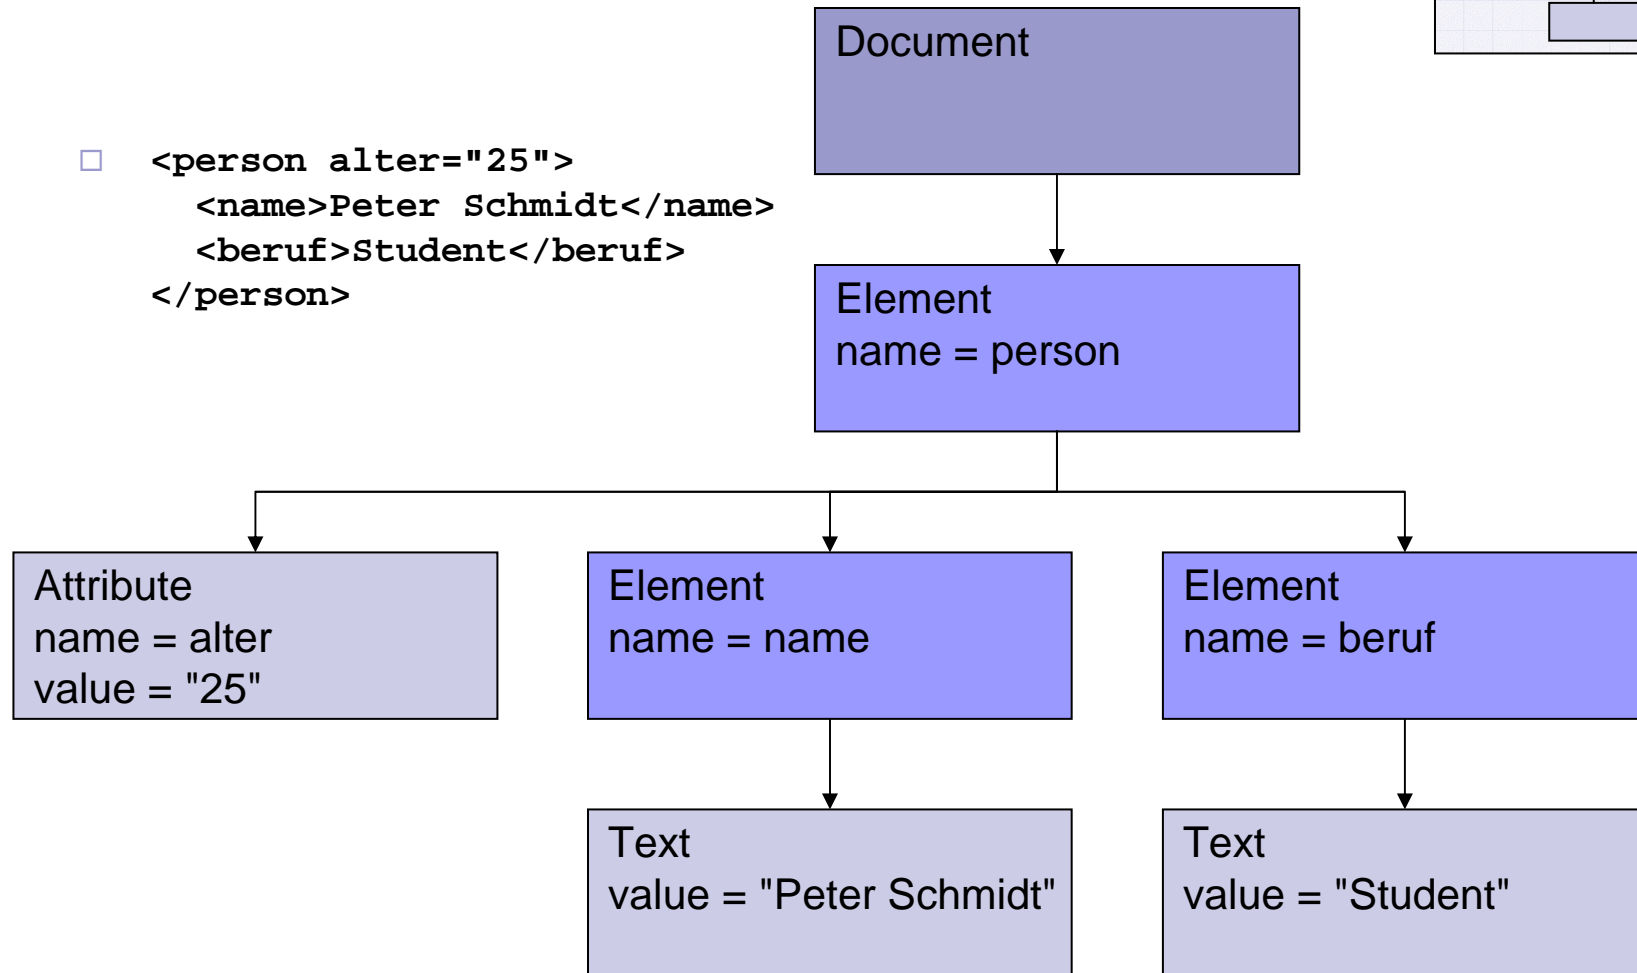
# Baum-Modell

- wohlgeformte XML-Dokumente bilden Baumstrukturen
  - Ein Dokument besteht aus einem Element, das Attribute, Text und Elemente enthält
  - Attribute und Text können auch als Knoten des Baumes betrachtet werden
- Spezifikation bildet DOM (Document Object Model)

# Ein Beispiel



- `<person alter="25">`  
    `<name>Peter Schmidt</name>`  
    `<beruf>Student</beruf>`  
`</person>`





# Vor- und Nachteile

## ■ DOM

- lange "Wartezeit" beim Einlesen
- hoher Speicherbedarf
- + beliebiger Zugriff auf Elemente
- + Änderung möglich

## ■ SAX

- + Abarbeitung beginnt sofort
- + kaum Speicherbedarf
- Dokument wird genau einmal durchlaufen
- nur Lesen




# DOM – Document Object Model

- Level-weise entwickelter Standard
- zur Beschreibung von Dokumenten in Baumstruktur
- Einlesen der Dokumente, Bearbeiten im Speicher
- Menge von objektorientierten APIs
  - generische Schnittstellen (**Node**, **NodeList**)
  - spezialisierte Schnittstellen von **Node**




# Node-Schnittstelle



- Basisschnittstelle für alle Knoten
- Allgemeine Methoden zum Durchlaufen und Analysieren von Baumstrukturen
- Umwandlung in speziellen Knoten durch Casting
- nicht direkt erzeugbar (abstract)

# Node-Schnittstelle



## ■ Attribute

- DOMString nodeName
- DOMString *nodeValue*
- Short nodeType
- Node parentNode
- NodeList childNodes
- Node firstChild
- Node lastChild
- Node previousSibling
- Node nextSibling
- NamedNodeMap attributes
- Document ownerDocument
- DOMString namespaceURI
- DOMString *prefix*
- DOMString localName

## ■ Methoden

- Boolean hasAttributes
- Boolean hasChildNodes
- Node insertBefore
  - Node newChild
  - Node refChild
- Node replaceChild
  - Node newChild
  - Node oldChild
- Node removeChild
  - Node oldChild
- Node appendChild
  - Node newChild

# NodeList

## ■ Zugriff auf geordnete Kinder eines Knotens

### ■ Attribute

- Long      length

### ■ Methoden

- Node      item
  - Long      index

```
□ <person alter="25">
 <name>Peter Schmidt</name>
 <beruf>Student</beruf>
</person>
```

```
□ Node p = <Node person>
NodeList l = p.getChildNodes();
l.getLength(); -> 2
l.item(0); -> <Node name>
l.item(1); -> <Node beruf>
```

# NamedNodeMap

- Zugriff auf ungeordneten Inhalt eines Knotens (i.A. Attribute)

- Attribute

- Long length

- ```
<person alter="25">
  <name>Peter Schmidt</name>
  <beruf>Student</beruf>
</person>
```

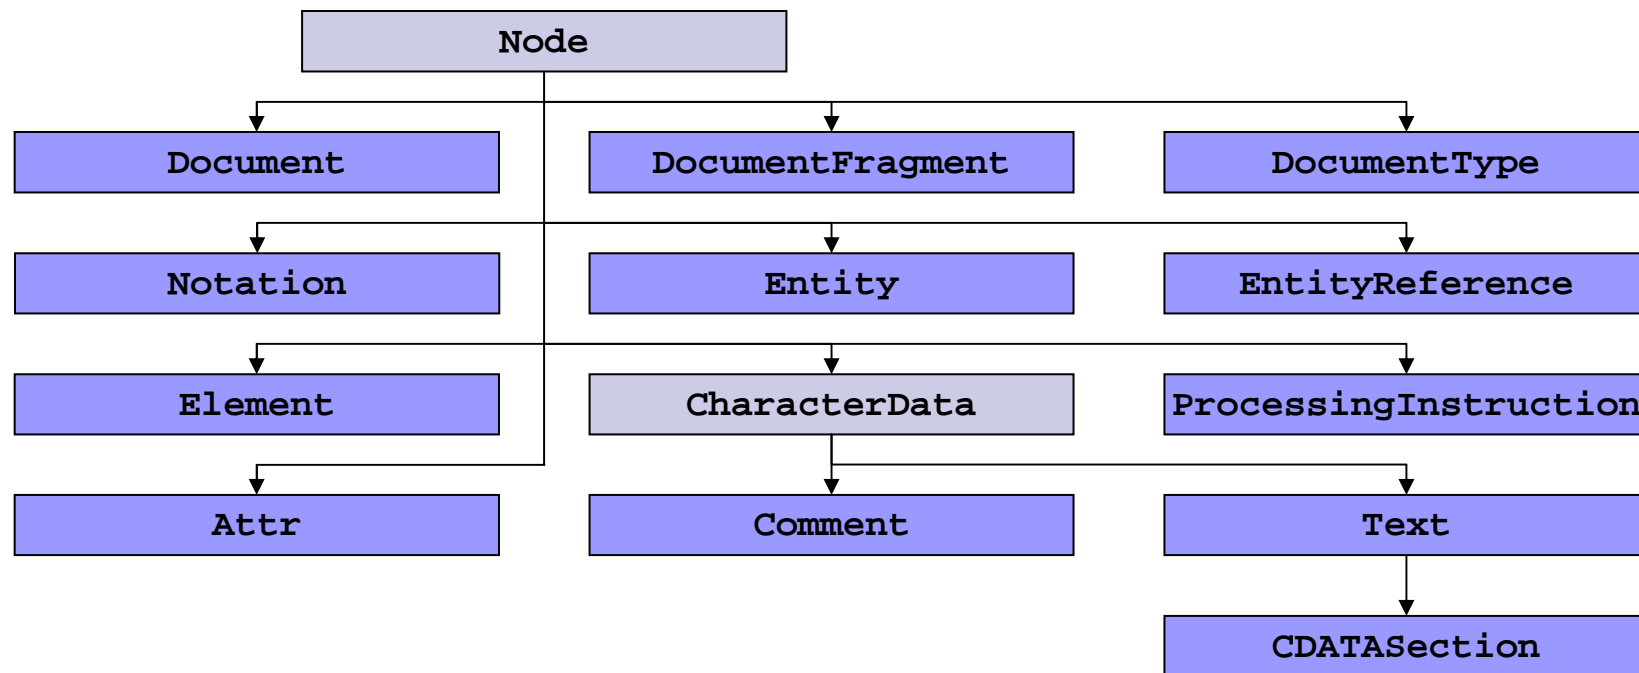
- Methoden

- Node item
 - Long index
 - Node getNamedItem
 - DOMString name
 - Node setNamedItem
 - DOMString arg
 - Node removeNamedItem
 - DOMString name

- ```
Node p = <Node person>
NamedNodeMap l = p.getAttributes();
l.getLength(); -> 1
l.item(0); -> <Attr alter>
l.getNamedItem("alter");
```

# spezialisierte Schnittstellen

- erweitern `Node` durch Methoden und Attribute
- Behandlung von Dokument-spezifischen Aspekten






# Werte für `nodeType`

- Knoten können in diese Schnittstellen gecastet werden

|                                                                   |                                    |
|-------------------------------------------------------------------|------------------------------------|
| <input type="checkbox"/> Wert                                     | DOM-Schnittstelle                  |
| <input type="checkbox"/> <code>DOCUMENT_NODE</code>               | <code>Document</code>              |
| <input type="checkbox"/> <code>DOCUMENT_FRAGMENT_NODE</code>      | <code>DocumentFragment</code>      |
| <input type="checkbox"/> <code>DOCUMENT_TYPE_NODE</code>          | <code>DocumentType</code>          |
| <input type="checkbox"/> <code>NOTATION_NODE</code>               | <code>Notation</code>              |
| <input type="checkbox"/> <code>ENTITY_NODE</code>                 | <code>Entity</code>                |
| <input type="checkbox"/> <code>ENTITY_REFERENCE_NODE</code>       | <code>EntityReference</code>       |
| <input type="checkbox"/> <code>PROCESSING_INSTRUCTION_NODE</code> | <code>ProcessingInstruction</code> |
| <input type="checkbox"/> <code>ELEMENT_NODE</code>                | <code>Element</code>               |
| <input type="checkbox"/> <code>ATTRIBUTE_NODE</code>              | <code>Attr</code>                  |
| <input type="checkbox"/> <code>COMMENT_NODE</code>                | <code>Comment</code>               |
| <input type="checkbox"/> <code>TEXT_NODE</code>                   | <code>Text</code>                  |
| <input type="checkbox"/> <code>CDATA_SECTION_NODE</code>          | <code>CDATASection</code>          |

# Document-Schnittstelle



- von `Node` abgeleitet
- Wurzel des DOM-Baumes
- Attribute
  - `DocumentType`      `doctype`
  - `DOMImplementation` `implementation`
  - `Element`              `documentElement`
- Methoden
  - `Node`                  `getElementById`
    - `DOMString`    `elementId`
  - `NodeList`            `getElementsByTagName`
    - `DOMString`    `tagname`
  - `NodeList`            `getElementByTagNameNS`
    - `DOMString`    `namespaceURI`
    - `DOMString`    `localName`
  - Methoden zum Erstellen aller spezialisierter Knoten



# DocumentFragment-Schnittst.

- von `Node` abgeleitet
- keine neuen Attribute und Methoden
- z.B. zum temporären Ablegen von Knoten





# DocumentType-Schnittstelle

- von `Node` abgeleitet

- Keine Kindknoten

- Attribute

- `NamedNodeMap entities`
- `DOMString name`
- `NamedNodeMap notations`
- `DOMString publicId`
- `DOMString systemId`

XML Ausschnitt:

```
<!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.0 Transitional//EN"
 "DTD/xhtml11-transitional.dtd">
```



# Notation-Schnittstelle

- von `Node` abgeleitet
- keine Kindknoten
- Attribute
  - `DOMString`     `publicId`
  - `DOMString`     `systemId`

XML Ausschnitt:

```
<!NOTATION jpeg SYSTEM "bild/jpeg">
```



# Entity-Schnittstelle

- von `Node` abgeleitet
- befinden sich im `DocumentType`-Knoten
- Attribute
  - `DOMString`     `notationName`
  - `DOMString`     `publicId`
  - `DOMString`     `systemId`

XML Ausschnitt:

```
<!ENTITY mein_text "Hallo Welt">
<!ENTITY ein_bild SYSTEM "img/pic.jpeg" NDATA jpeg>
```



# EntityReference-Schnittst.

- von `Node` abgeleitet
- keine neuen Attribute und Methoden
- Entityname in `nodeName` (aus `Node`)
- ein Parser muss diese Schnittstelle nicht benutzen

XML Ausschnitt:  
`&mein_text;`  
`<bild quelle="ein_bild" />`




# ProcessingInstruction

- von `Node` abgeleitet
- keine Kindknoten
- Attribute
  - `DOMString` `data`
  - `DOMString` `target`

XML Ausschnitt:

```
<?php
 echo 'Hello World';
?>
```

# Element-Schnittstelle



- von `Node` abgeleitet
- bei XML am häufigsten verwendet

- Attribute

- `DOMString`      `tagName`

- Methoden

- `Boolean`      `hasAttribute`

- `DOMString`      `name`

- `Attr`      `getAttributeNode`

- `DOMString`      `name`

- `Attr`      `setAttributeNode`

- `Attr`      `newAttr`

- `Attr`      `removeAttributeNode`

- `DOMString`      `name`

- `NodeList`      `getElementsByTagName`


- `DOMString`      `name`

- ```
<person alter="25">
  <name>Peter Schmidt</name>
  <beruf>Student</beruf>
</person>
```

- ```
Node p = <Node person>
Element e = (Element) p;
e.hasAttribute("alter");
 -> true

e.getAttributeNode("alter");
 -> <Attr alter>
```

# Attr-Schnittstelle



- von `Node` abgeleitet
  - Enthält Text und EntityReferenzen als Kindknoten
  - Attribute
    - `DOMString`     `name`
    - `DOMString`     `value`
    - `Element`        `ownerElement`
    - `Boolean`        `specified`
- XML Ausschnitt:  
``

# CharacterData-Schnittstelle

- von `Node` abgeleitet, abstract

- für Blöcke mit Zeichendaten

- Attribute

- `DOMString` `data`

- `Long` `length`

- Methoden

- `Void` `appendData`

- `DOMString` `arg`

- `Void` `deleteData`

- `Long` `offset`

- `Long` `count`

- `Void` `insertData`

- `Long` `offset`

- `DOMString` `arg`

- `Void` `replaceData`

- `Long` `offset`

- `Long` `count`

- `DOMString` `arg`






# Comment-Schnittstelle

- von `CharacterData` abgeleitet
- keine Kindknoten
- keine neuen Attribute und Methoden
- Parser müssen diese Knoten nicht erstellen

XML Ausschnitt:

```
<!-- Ein Kommentar -->
```

# Text-Schnittstelle



- von `CharacterData` abgeleitet
- keine Kindknoten
- kann in zwei Knoten geteilt werden
- Methoden
  - `Text`                    `splitText`
  - `Long`                    `offset`



# CDATASection-Schnittstelle

- von `Text` abgeleitet
- keine Kindknoten
- keine neuen Attribute und Methoden

# geerbte Attribute in spezialisierten Schnittstellen

| ■ Schnittstelle         | nodeName           | nodeValue    | Attribute    | Kinder          |
|-------------------------|--------------------|--------------|--------------|-----------------|
| ■ Document              | #document          | -            | -            | genau ein Kind  |
| ■ DocumentType          | Typ                | -            | -            | -               |
| ■ DocumentFragment      | #document-fragment | -            | -            | beliebig viele  |
| ■ Entity                | Entityname         | -            | -            | Ersetzung       |
| ■ EntityReference       | Entityname         | -            | -            | Ersetzung       |
| ■ Notation              | Notationname       | -            | -            | -               |
| ■ ProcessingInstruction | Ziel               | Inhalt       | -            | -               |
| ■ Element               | Tag-Name           | -            | NamedNodeMap | Kindknoten      |
| ■ Attribut              | Attributname       | Attributwert | -            | Inhalt als Text |
| ■ Comment               | #comment           | Inhalt       | -            | -               |
| ■ Text                  | #text              | Inhalt       | -            | -               |
| ■ CDATASection          | #cdata-section     | Inhalt       | -            | -               |



# DOMImplementation

- Schnittstelle, mit der Dokumente erzeugt werden können
  
- Methoden
  - Document          createDocument
    - DOMString    namespaceURI
    - DOMString    qualifiedName
    - DocumentType doctype
  
  - DocumentType createDocumentType
    - DOMString    qualifiedName
    - DOMString    publicId
    - DOMString    systemId
  
  - Boolean          hasFeature
    - DOMString    feature
    - DOMString    version



# DOMParser

- keine offizielle Spezifikation
- Einlesen und Validieren von XML-Dateien
- Erstellen einer **Document**-Instanz
- Beispiel:

```
□ DOMParser dp = new DOMParser();
 dp.parse("myfile.xml");
```

```
Document doc = dp.getDocument();
Node root = doc.getDocumentElement();
```



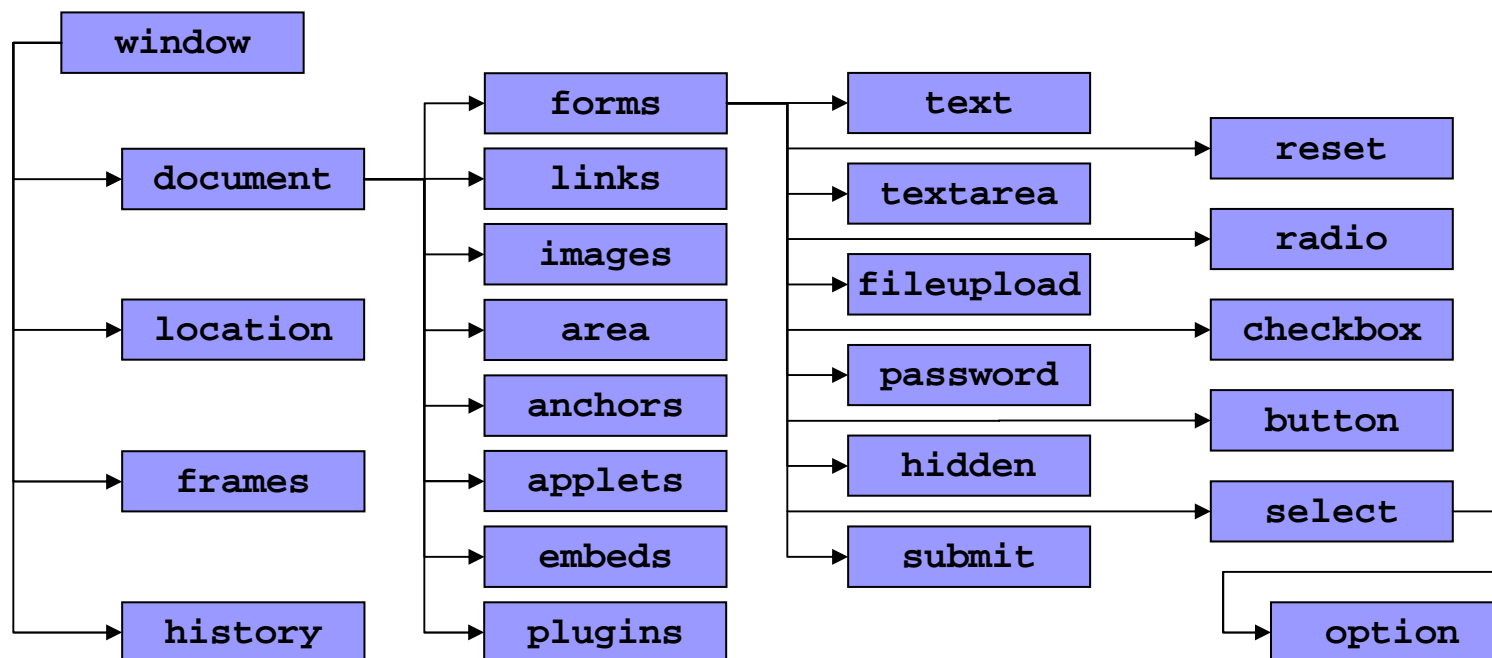
# JavaScript und DOM

- DOM ist in JavaScript integriert
- Zugriff auf das Dokument direkt im Browser

- ```
<html>
<head><title>my first JavaScript</title></head>
<body>
<script language="JavaScript">
  document.writeln('Hello World!');
</script>
</body>
</html>
```

DOM-Struktur in JavaScript

- der Hierarchiebaum, der im Browser zur Verfügung steht:





Zugriff auf Kindknoten

- stark vereinfachter Zugriff
- Attribute von Elementen direkt als Attribute der Objekte
- Knotenliste
 - `window.frames[0]`
- Namen
 - `<any_tag id="foo">` oder `<any_tag name="foo">`
 - `document.all.foo`
 - `document.getElementById("foo")`

Ändern von Attributen

■ mouseover-Funktion bei Bildern

- ```
<script>
function picin() {
 document.pic.src = 'otto2.gif';
}

function picout() {
 document.pic.src = 'otto.gif';
}
</script>
```
- ```

```



Auflisten aller Knoten

■ Durchlaufen aller Knoten des Dokumentes

- ```
<script>
function showElements() {
 var s = '';
 for (var i = 0; i < document.all.length; i++) {
 s = s + document.all.item(i).tagName + '\n';
 }
 document.myform.text2.value = s;
}
</script>
```
  
- ```
<form name="myform">
    <textarea rows="10" cols="40" name="text2">old text</textarea>
</form>
```



Hinzufügen von Knoten

■ Text in einem neuen Abschnitt hinzufügen

- `<script>`

```
function insertText() {  
    var parent = document.createElement("p");  
    var textNode = document.createTextNode("the text goes here");  
  
    parent.appendChild(textNode);  
    document.getElementById("foo").appendChild(parent);  
}
```

`</script>`
- `<p name="foo">`

```
    new text goes here:  
</p>
```

Hinzufügen von Knoten

■ ein Bild hinzufügen

- ```
<script>
function insertText() {
 var img = document.createElement("img");
 img.src = "otto.gif";

 document.getElementById("foo").appendChild(img);
}
</script>
```
- ```
<p name="foo">
    image goes here:
</p>
```



Zusammenfassung

- Was man aus diesem Vortrag erfahren sollte
 - DOM spezifiziert Datentypen zur Verarbeitung von Dokumenten in Baumstruktur
 - DOM legt das Bewegen durch den Baum und den Zugriff auf die Daten fest
 - Elemente aus XML-Dateien sind Knoten des DOM-Baumes
 - Attribute, Text und Unterelemente sind Kindknoten



Quellenangabe

- Elliotte Rusty Harold, W. Scott Means;
XML in a nutshell; Deutsche Übersetzung der 2.
Auflage 2003; O'Reilly Verlag GmbH & CO. KG
- Client-Side JavaScript Guide - Version 1.3;
Netscape Communications Comporation 1999