Datenbanksysteme

Kapitel 9

Einführung in XML, XPath, XQuery und XSLT

Martin Gieseking

Was ist XML?

- XML (Extensible Markup Language) ist eine Meta-Auszeichnungssprache zur textbasierten Beschreibung hierarchisch strukturierter Daten
  - Spezifikation des World Wide Web Consortiums (W3C)
  - XML definiert kein konkretes Dateiformat sondern legt fest, welche syntaktischen Bestandteile verwendet und wie sie kombiniert werden dürfen
  - auf Grundlage der Regeln können konkrete Dateiformate mit definierter Struktur und Semantik abgeleitet werden
- ein konkretes Dateiformat, das auf Grundlage der XML-Spezifikation festgelegt wurde, wird allgemein **XML-Format** genannt
  - entsprechend nennt man Dateien in diesem Format **XML-Dateien**
  - Beispiele für XML-Formate sind *RSS*, *MathML*, *SVG*, *XHTML*

Beispiel einer XML-Datei

```
<?xml version="1.0"?>
<!-- Vorlesungsverzeichnis Sommersemester 2011 -->
<vorlesungsverzeichnis>
    <abschnitt titel="Mathematik &amp; Informatik">
        <abschnitt titel="Grundstudium">
            <veranstaltung nr="1.234" typ="v">
                <dozent>
                    <titel>Prof. Dr.</titel>
                    <vname>Klaus</vname>
                    <nname>Meier</nname>
                </dozent>
                <titel>Einführung in die monotone Algebra I</titel>
                <zeit>Mo 10:00-12:00</zeit>
                <raum>12/13</raum>
            </veranstaltung>
            <veranstaltung nr="1.247" typ="ü">
                <dozent>
                    <vname>Sandra</vname>
                    <nname>Schmidt</nname>
                </dozent>
                <titel>Übung zur Einführung in die monotone Algebra I</titel>
                <zeit>Mi 8:00-12:00</zeit>
                <raum>97/E9</raum>
            </veranstaltung>
        </abschnitt>
    </abschnitt>
</vorlesungsverzeichnis>
```

XML-Technologien

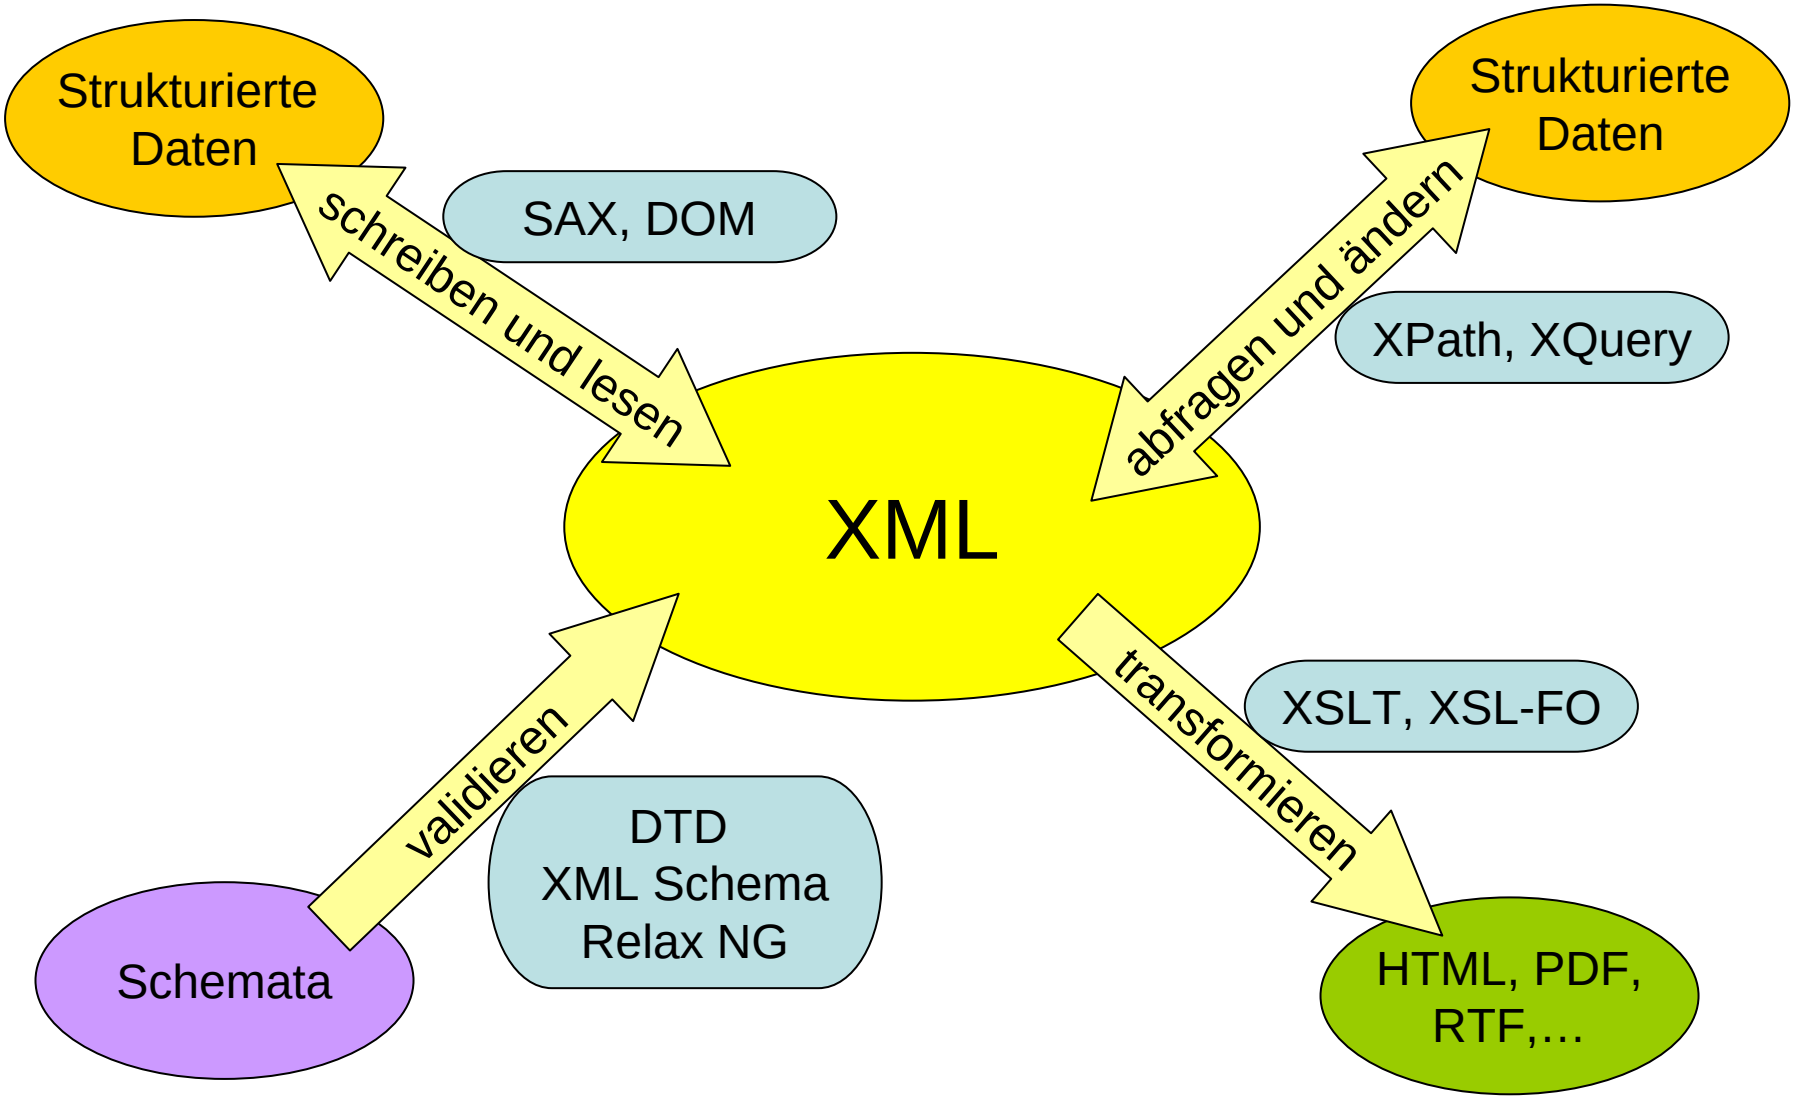

Bausteine einer XML-Datei

- XML-Dateien können aus folgenden Bausteinen zusammengesetzt werden:
  - Elemente
  - Attribute
  - Text und Entities
  - Kommentare
  - Verarbeitungsanweisungen (processing instructions)
  - CDATA-Abschnitte
  - DOCTYPE-Angabe

```
<?xml version="1.0"?>
<!-- Vorlesungsverzeichnis Sommersemester 2011 -->
<vorlesungsverzeichnis>
    <abschnitt titel="Mathematik &amp;amp; Informatik">
        <abschnitt titel="Grundstudium">
            <veranstaltung nr="1.234" typ="v">
                <dozent>
                    <titel>Prof. Dr.</titel>
                    <vname>Klaus</vname>
                    <nname>Meier</nname>
                </dozent>
                <titel>Einführung in die ...</titel>
                <zeit>Mo 10:00-12:00</zeit>
                <raum>12/13</raum>
            </veranstaltung>
        </abschnitt>
    </abschnitt>
</vorlesungsverzeichnis>
```

Elemente

- die strukturierenden Bausteine eines XML-Dokuments werden **Elemente** genannt
- sie bestehen aus einem öffnenden und einem schließenden **Tag** sowie dem **Elementinhalt** (oder **Elementrumpf**)
  - anders als z.B. bei HTML muss jedes Element explizit ein öffnendes und schließendes Tag (Start- und End-Tag) besitzen

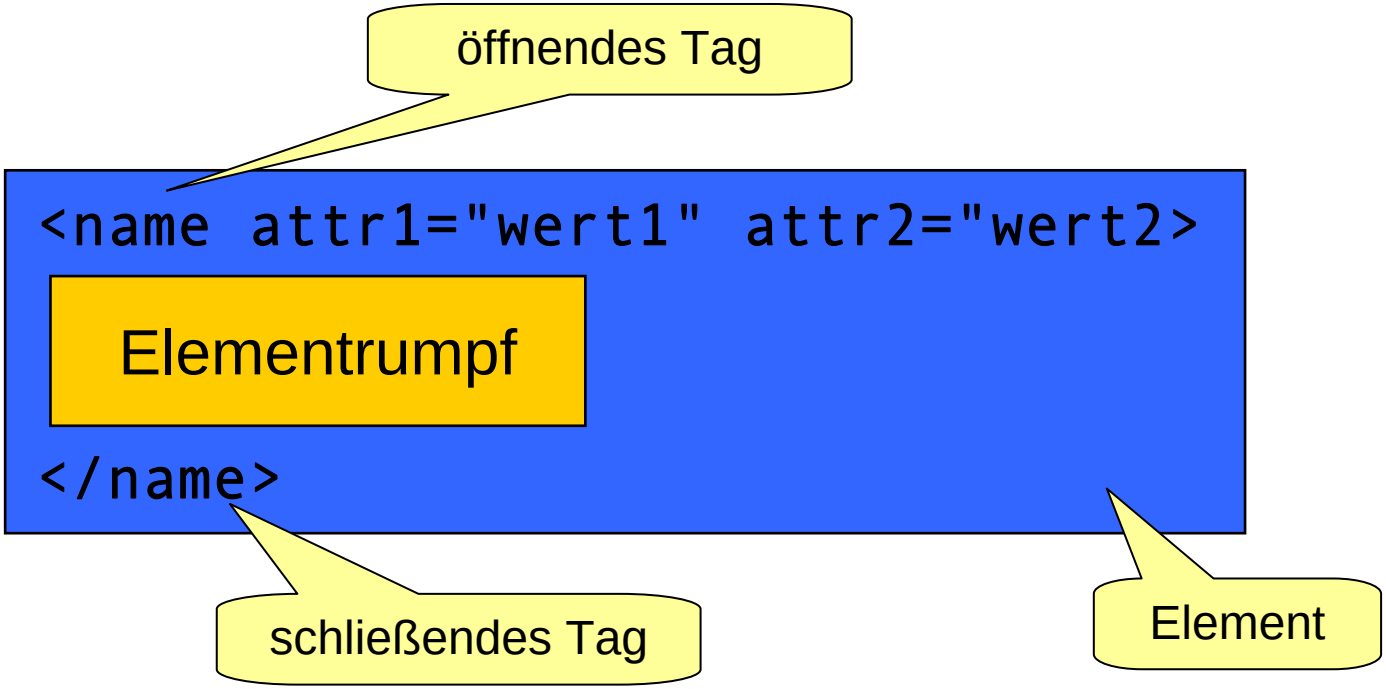

Elemente

- **öffnende Tags** haben immer die Form
  `<name attr1="wert1" attr2="wert2" ...>`
  - der Name kann aus Buchstaben, Ziffern und den Zeichen `_.-·` bestehen
    - erstes Zeichen muss ein Buchstabe sein
    - es wird zwischen Groß- und Kleinschreibung unterschieden
    - darf nicht mit *xml, Xml, xMl, xmL, XMl, XmL, xML* oder *XML* beginnen
  - zwischen „<“ und *name* darf sich kein Leerzeichen befinden
  - Attribute werden in der angegebenen Form durch Whitespaces getrennt hinter dem Elementnamen aufgelistet
  - für Attributnamen gelten die gleichen Vorgaben wie für Elementnamen
  - Attributwerte werden wahlweise in einfache oder doppelte Anführungszeichen eingeschlossen
  - die Reihenfolge der Attribute ist nicht signifikant
  - jeder Attributname darf in der Attributliste nur einmal auftauchen
- **schließende Tags** haben immer die Form
  `</name>`
  - der Name muss mit dem des zugehörigen öffnenden Tags übereinstimmen
  - schließende Tags enthalten keine weiteren Informationen

Elemente

- der Elementrumpf ist entweder leer oder besteht aus einer Folge von weiteren Elementen, Text, Kommentaren und/oder Verarbeitungsanweisungen
  - Elemente können beliebig tief geschachtelt werden

```
<veranstaltung nr="1.234" typ="v">
  <dozent geschlecht="m">
    <!- ein Kommentar -->
    <titel>Prof. Dr.</titel>
    <vname>Klaus</vname>
    <nname>Meier</nname>
  </dozent>
  Dies ist ein Text.
  <titel>Einführung in die ...</titel>
  <zeit>Mo 10:00-12:00</zeit>
  <raum>12/13</raum>
</veranstaltung>
```

- für Elemente mit leerem Rumpf gibt es die Kurzschreibweise `<name attr1="val1" attr2="val2" ... />`

```
<uhrzeit zeitzone="GMT"></uhrzeit>
```

ist identisch mit

```
<uhrzeit zeitzone="GMT"/>
```

Elemente

- jedes XML-Dokument muss genau ein äußeres Element, das so genannte **Wurzelelement** besitzen
  - es stellt quasi den Rahmen oder den Container für die eigentlichen Daten dar
  - außerhalb des Wurzelelements sind nur Kommentare, Verarbeitungsanweisungen, eine DOCTYPE-Anweisung und Whitespace erlaubt

Fehler: kein (eindeutiges) Wurzelelement

```
<?xml version="1.0"?>
<veranstaltung nr="1.234">
  ...
</veranstaltung>

<veranstaltung nr="4.321">
  ...
</veranstaltung>
```

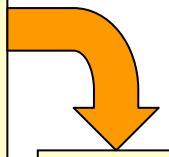

```
<?xml version="1.0"?>
<veranstaltungen>
  <veranstaltung nr="1.234">
    ...
  </veranstaltung>
  <veranstaltung nr="4.321">
    ...
  </veranstaltung>
</veranstaltungen>
```

Kommentare und Entities

- neben Text und Elementen spezifiziert XML noch weitere Konstrukte
  - Kommentare
    `<!-- dies ist ein Kommentar -->`
    - die Zeichenfolge `--` ist innerhalb von Kommentaren nicht erlaubt
  - Entity-Referenzen
    `&name; &#dez; &#xhex;`
    - bezeichnen ein einzelnes Zeichen oder eine Zeichenfolge
    - die Zeichen < und & haben in der XML-Syntax eine besondere Bedeutung (Metazeichen), und dürfen nicht als normaler Textbestandteil verwendet werden
    - zahlreiche Zeichen sind nicht im normalen Zeichenvorrat eines Zeichensatzes enthalten, so dass sie nicht direkt eingegeben werden können (z.B. mathematische oder musikalische Zeichen, Ligaturen usw.)

<	<
>	>
'	'
"	&quote;
&	&

```
<aufgabe punkte="1">
  <!-- eine einfache Frage zum Einstieg -->
  Wofür steht in XML die Zeichenfolge &lt;!-- ... -->?
</aufgabe>
```

Entity-Referenzen

- im Gegensatz zu HTML definiert XML nur fünf benannte Entities
- alle anderen aus HTML bekannten Entities, wie z.B. `&auml;` `&szlig;` ` ` usw. sind in XML nicht definiert und führen bei Verwendung zu einem Fehler
- es gibt die Möglichkeit, neue benannte Entities zu definieren

<	<
>	>
'	'
"	&quote;
&	&

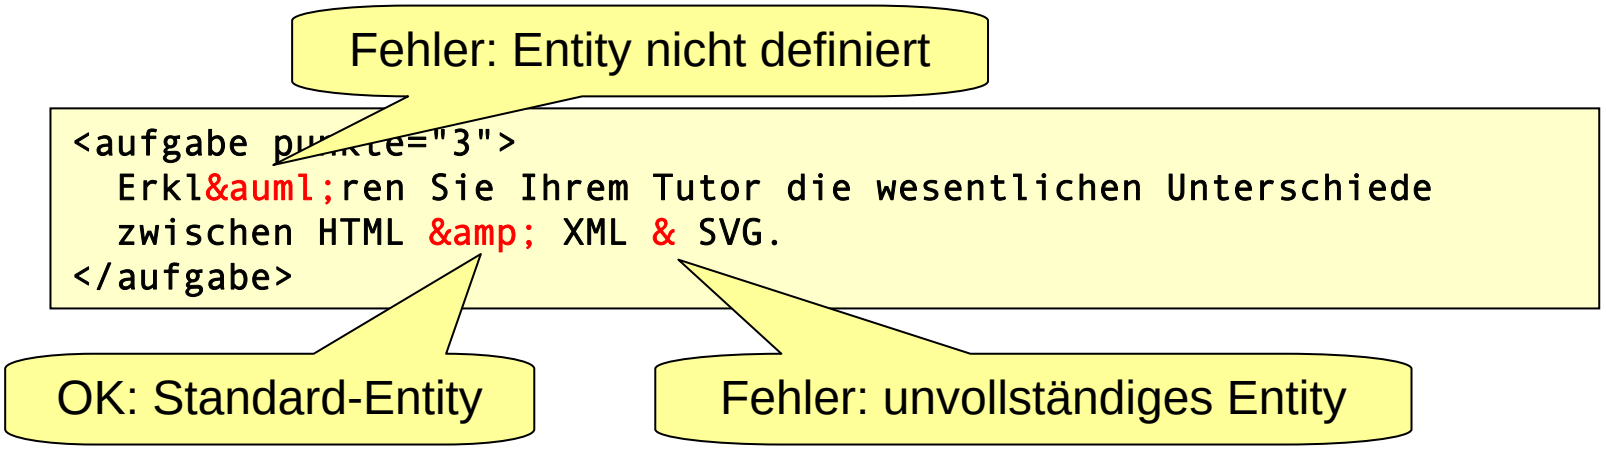

- numerische Entity-Referenzen bezeichnen jeweils ein einzelnes Unicode-Zeichen
  - Eurozeichen: `&#8364;` (dezimal), `&#x20AC;` (hexadezimal)

XML-Namensräume

- Namensräume ermöglichen es, zusammengehörige Elemente zu bündeln und von „fremden“ Elementen abzugrenzen
- Namensräume werden in XML durch eindeutige URIs (Uniform Resource Identifiers) benannt
  - Zeichenkette, die einen Namensraum eindeutig identifiziert
  - haben meist die Form einer URL (muss nicht existieren)
- In XML-Dokumenten werden die Namensräume mit frei definierbaren Präfixen verknüpft, die den Elementen durch einen Doppelpunkt getrennt vorangestellt werden

```
<buch xmlns:pers="http://xyz.de/person">
 <titel>Das Leben der Affen</titel>
 <autor>
  <pers:person>
   <pers:titel>Prof. Dr.</pers:titel>
   <pers:vorname>Jim</pers:vorname>
   <pers:nachname>Panse</pers:nachname>
  </pers:person>
 </autor>
</buch>
```

```
<buch>
 <titel>Das Leben der Affen</titel>
 <autor>
  <person xmlns="http://xyz.de/person">
   <titel>Prof. Dr.</titel>
   <vorname>Jim</vorname>
   <nachname>Panse</nachname>
  </person>
 </autor>
</buch>
```

XML-Namensräume

```
<buch xmlns:pers="http://xyz.de/person">
 <titel>Das Leben der Affen</titel>
 <autor>
  <pers:person>
   <pers:titel>Prof. Dr.</pers:titel>
   <pers:vorname>Jim</pers:vorname>
   <pers:nachname>Panse</pers:nachname>
  </pers:person>
 </autor>
</buch>
```

- definiert den Präfix *pers* für den Namensraum *http://xyz.de/person*
- ist nur innerhalb des Elements bekannt, in dem er definiert wird

```
<buch>
 <titel>Das Leben der Affen</titel>
 <autor>
  <person xmlns="http://xyz.de/person">
   <titel>Prof. Dr.</titel>
   <vorname>Jim</vorname>
   <nachname>Panse</nachname>
  </person>
 </autor>
</buch>
```

- setzt den Standard-Namensraum auf *http://xyz.de/person*
- das Element und die Kindelemente werden dem Namensraum zugeordnet
- ein expliziter Präfix vor den Elementnamen ist hier nicht erforderlich

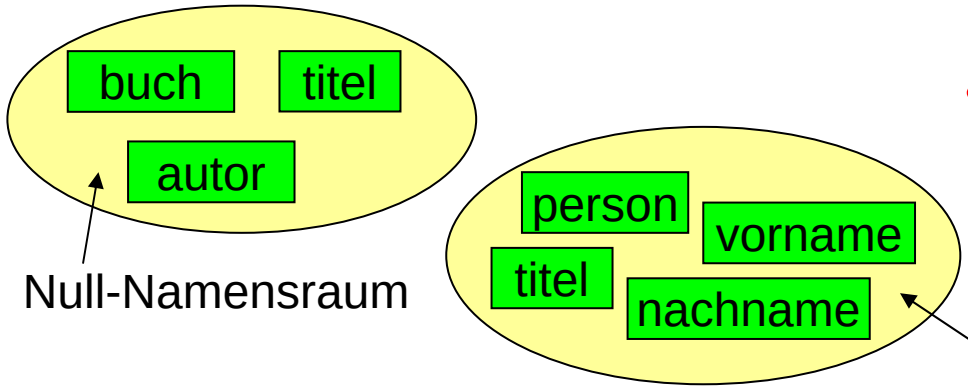

Wohlgeformte XML-Dokumente

- ein XML-Dokument heißt **wohlgeformt**, wenn es die Syntax- und Strukturvorgaben der XML-Spezifikation einhält
  - über 100 Regeln, die größtenteils intuitiv aus den bisher beschriebenen Aspekten hervorgehen
- die Wohlgeformtheit kann ohne Kenntnis der in einem Dokument zulässigen Elemente überprüft werden

nicht wohlgeformt

```
<?xml version="1.0"?>
<blatt nr="1">
  <aufgabe punkte="4">
    <list>
      <li>Punkt 1</li>
      <li>Punkt 2
  </aufgabe>
      </li>
    </list>
</Blatt>

<blatt nr="2">
  <aufgabe Punkte="6"/>
</blatt>
```

wohlgeformt

```
<?xml version="1.0"?>
<blattsammlung>
  <blatt nr="1">
    <aufgabe punkte="4">
      <list>
        <li>Punkt 1</li>
        <li>Punkt 2</li>
      </list>
    </aufgabe>
  </blatt>

  <blatt nr="2">
    <aufgabe PUNKTE="6"/>
  </blatt>
</blattsammlung>
```

Struktur von XML-Dokumenten

- XML-Dokumente besitzen grundsätzlich eine Baumstruktur
  - es gibt genau einen Wurzelknoten vom Typ *Document*
  - bis auf den **Dokumentknoten** haben alle Knoten einen eindeutigen Elternknoten
  - Attribute sind sog. **assoziierte Knoten**, die zwar ein Elternelement besitzen, selbst aber keine Kinder sind
- der Dokumentknoten muss genau einen Element-Kindknoten, das **Wurzelelement**, besitzen

```
<?xml version="1.0"?>
<!- erster Kommentar -->
<A>
  erster Textteil
  <B>
    zweiter Textteil
    <B attr="wert">
      dritter Textteil
    </B>
  </B>
  <!- zweiter Kommentar -->
</A>
```

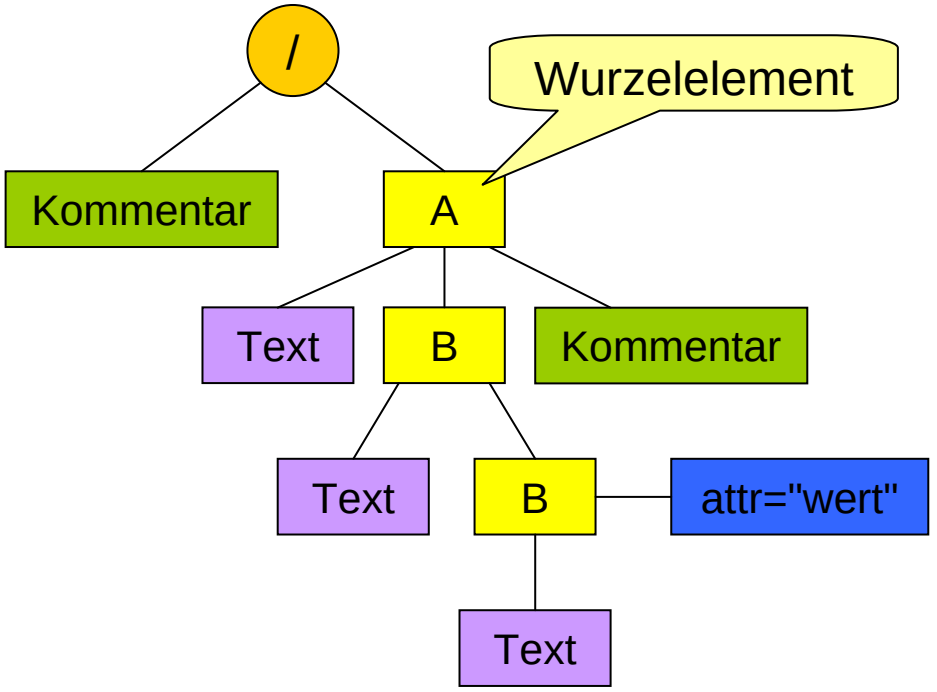

XML-Knotentypen

- entsprechend der syntaktischen Elemente einer XML-Datei wird zwischen verschiedenen Knotentypen unterschieden
  - Dokumentknoten
  - Elementknoten
  - Textknoten
  - Kommentarknoten
  - Attributknoten
  - Namensraumknoten
  - Verarbeitungsanweisungsknoten

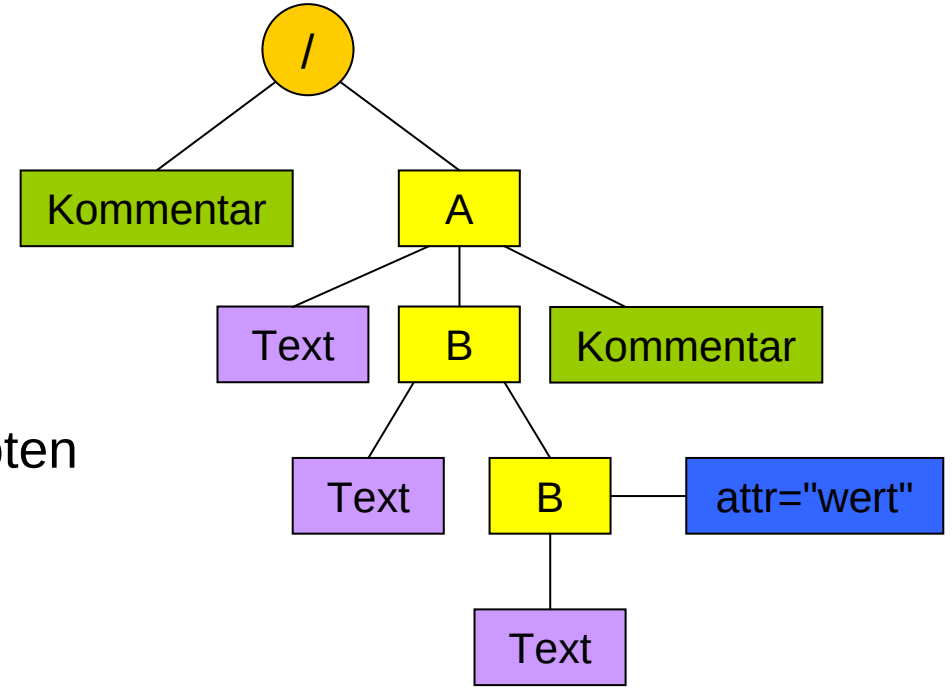

XPath: Navigieren in XML-Bäumen

- eine zentrale Operation auf XML-Bäumen ist das Auswählen von einzelnen Knoten oder Knotenmengen nach bestimmten Kriterien

- die Lokatorsprache **XPath** stellt einen Formalismus zur Adressierung von Knoten in XML-Bäumen bereit
  - zusätzlich werden mathematische und logische Operatoren sowie eine überschaubare Anzahl von Funktionen bereitgestellt (XPath 1.0)

- XPath ist integraler Bestandteil von weiteren XML-Technologien, wie XSLT und XQuery (Obermenge von XPath 2.0)

XPath-Software (Open Source)

- Firebug- und FirePath-Erweiterung für Firefox
  - Firefox unterstützt wie alle anderen Browser nur XPath 1.0
- Libxml2
  - http://xmlsoft.org
  - Kommandozeilen-Programm `xmllint` mit Option `--xpath`

- BaseX
  - http://www.inf.uni-konstanz.de/dbis/basex
  - XML-Datenbank mit grafischer Oberfläche und XQuery-Schnittstelle
  - XQuery ist eine Obermenge von XPath 2.0
- XQilla
  - http://xqilla.sourceforge.net/HomePage
  - XQuery-Prozessor

Beispiel: einfache Pfadangabe

- Knoten werden in XPath mit Hilfe von **Pfadangaben** ausgewählt
  - einfache XPath-Pfadangaben erinnern an Unix-Pfade zur Navigation im Dateisystem
  - ausgehend von der Dokumentwurzel können die Kindknoten schrittweise ausgewählt werden
- das Ergebnis einer Pfadangabe ist immer eine **Knotenmenge**
  - eine Liste mit Referenzen auf alle passenden Knoten ohne Dopplungen
- Beispiel: `/A/B/B`

```
<?xml version="1.0"?>
<!- erster Kommentar -->
<A>
  erster Textteil
  <B>
    zweiter Textteil
    <B attr="wert">
      dritter Textteil
    </B>
  </B>
  <!- zweiter Kommentar -->
</A>
```

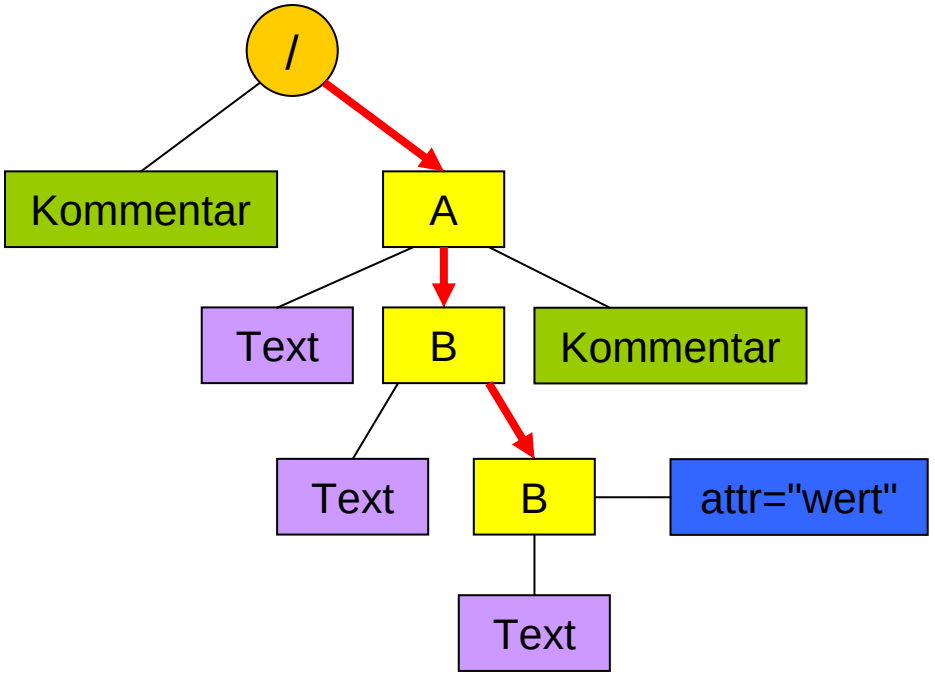

Pfadangaben und Location-Steps

- jede Pfadangabe besteht aus einer Folge sogenannter **Location-Steps**
  - werden durch Slashes (`/`) voneinander getrennt
  - Beispiel: `step1/step2/step3`
  - jeder Location-Step wählt relativ zum vorangehenden Location-Step bzw. zum Kontextknoten eine Knotenmenge des XML-Baums aus

- jeder Location-Step besteht aus maximal drei Komponenten
  - einem optionalen Achsenbezeichner
  - einem Knotentest
  - einem oder mehreren optionalen Prädikat(en)
  - Syntax: `achenbezeichner::knotentest[prädikat]`
  - Beispiel: `ancestor::A[B]`

Knotentests

- im einfachsten Fall besteht ein Location-Step lediglich aus einem **Knotentest**
  - prüft, ob es an der aktuellen Position Knoten eines bestimmten Typs gibt
  - das Ergebnis eines Knotentests ist immer eine Menge aller passenden Knoten
  - falls es keine passenden Knoten gibt, ist die Ergebnismenge leer

Knotentyp	**Syntax des Knotentests**
Dokumentwurzel	`/`
Element *A*	`A`
Attribut *attr*	`@attr`
Text	`text()`
Kommentar	`comment()`
alle Knotentypen	`node()`

Knotentests

- Die Knotentests `text()` und `comment()` selektieren Text- bzw. Kommentarknoten (unabhängig von ihrem Inhalt)
- Elemente und Attribute werden normalerweise über ihren Namen ausgewählt
- der Knotentest `*` selektiert Elementknoten unabhängig vom Namen
- der Knotentest `@*` selektiert Attributknoten unabhängig vom Namen

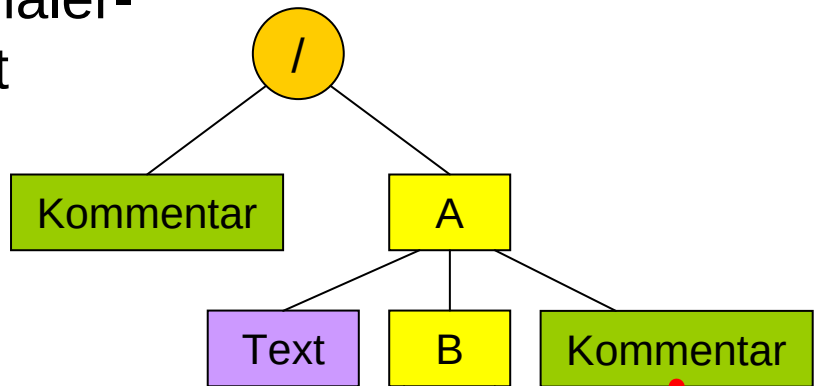

XPath-Ausdruck	Bedeutung
`/`	Dokumentknoten (Wurzel)
`/*`	Wurzelelement
`/A/B/*`	Elementknoten unterhalb von /A/B
`/A/B/A`	A-Element unterhalb von /A/B (leer)
`/A/comment()`	Kommentar unterhalb von A
`/A/B/B/text()`	Textknoten unterhalb von `/A/B/B`

Knotenmengen

- da Elementknoten mehrere gleichnamige und/oder gleichartige Knoten enthalten können, kann auch das Resultat eines Knotentests aus mehreren Knoten bestehen
  - das Resultat ist eine Knotenmenge
  - die Ergebnisknoten werden in Dokumentreihenfolge angeordnet (gilt nicht für alle Achsen)

```
<?xml version="1.0"?>
<!- erster Kommentar -->
<A>
  erster Textteil
  <B>
    zweiter Textteil
    <B>
      dritter Textteil
    </B>
    <B attr="wert">
      vierter Textteil
    </B>
  </B>
  <!- zweiter Kommentar -->
</A>
```

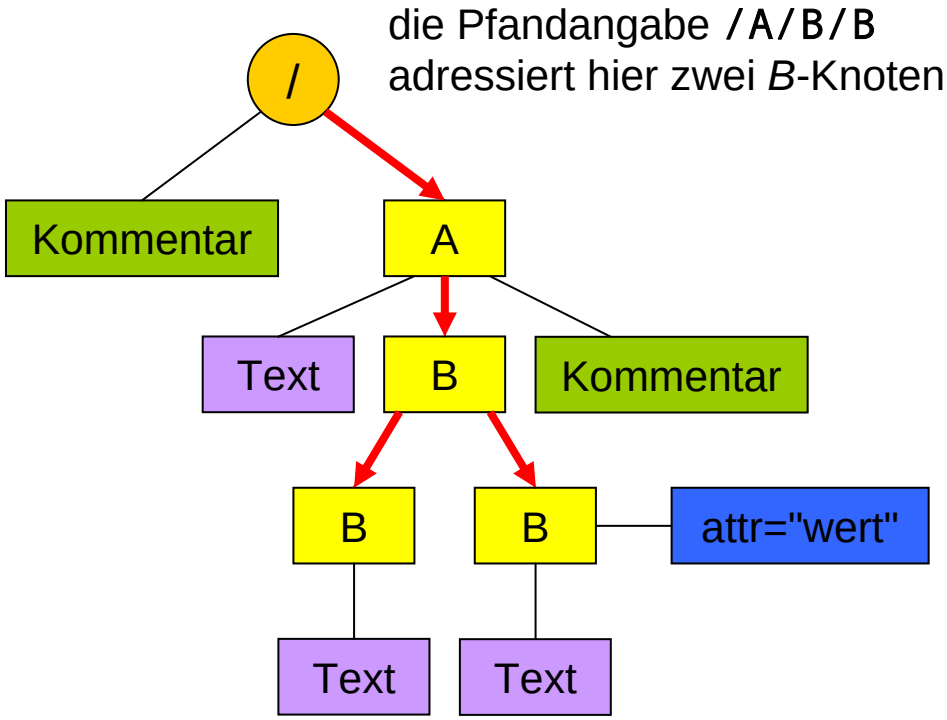

Attributknoten

- die Attributknoten eines Elements werden durch einen Klammeraffen (@) gefolgt vom Attributnamen adressiert
  - mit @* erhält man alle Attributknoten der spezifizierten Elemente
- Attribute, die Namensraum-Präfixe definieren, können nicht mit @ adressiert werden
  - Zugriff muss mit Hilfe der *namespace*-Achse erfolgen

```
<?xml version="1.0"?>
<A attr1="val1" attr2="val2">
  <B attr2="val3">
    Text
  </B>
  <B>Text</B>
  <A>Text</A>
</A>
```

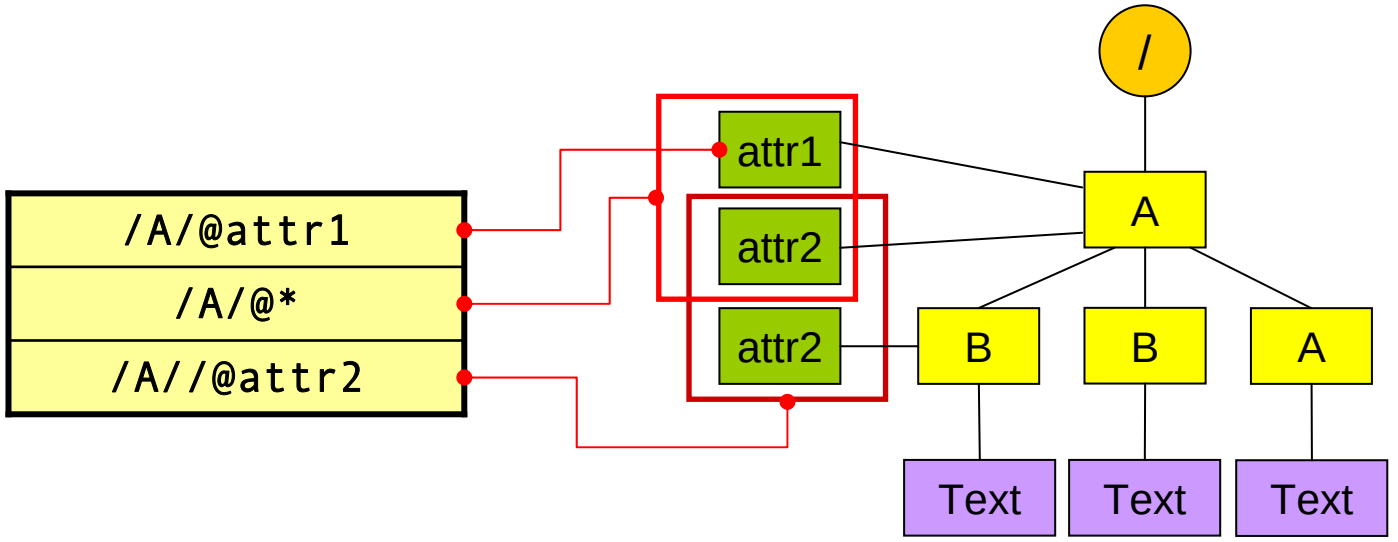

Vereinigung von Knotenmengen

- mit Hilfe des Kompositionsoperators | (senkrechter Strich) lassen sich zwei Knotenmengen vereinigen
  - auf beiden Seiten des Operators steht eine Pfadangabe
  - der Kompositionsoperator bindet schwächer als alle anderen Pfadoperatoren
  - die Knoten der Ergebnismenge sind immer in Dokumentreihenfolge angeordnet
  - Knoten, die von beiden Knotentests ausgewählt werden, tauchen in der Ergebnismenge nur einmal auf

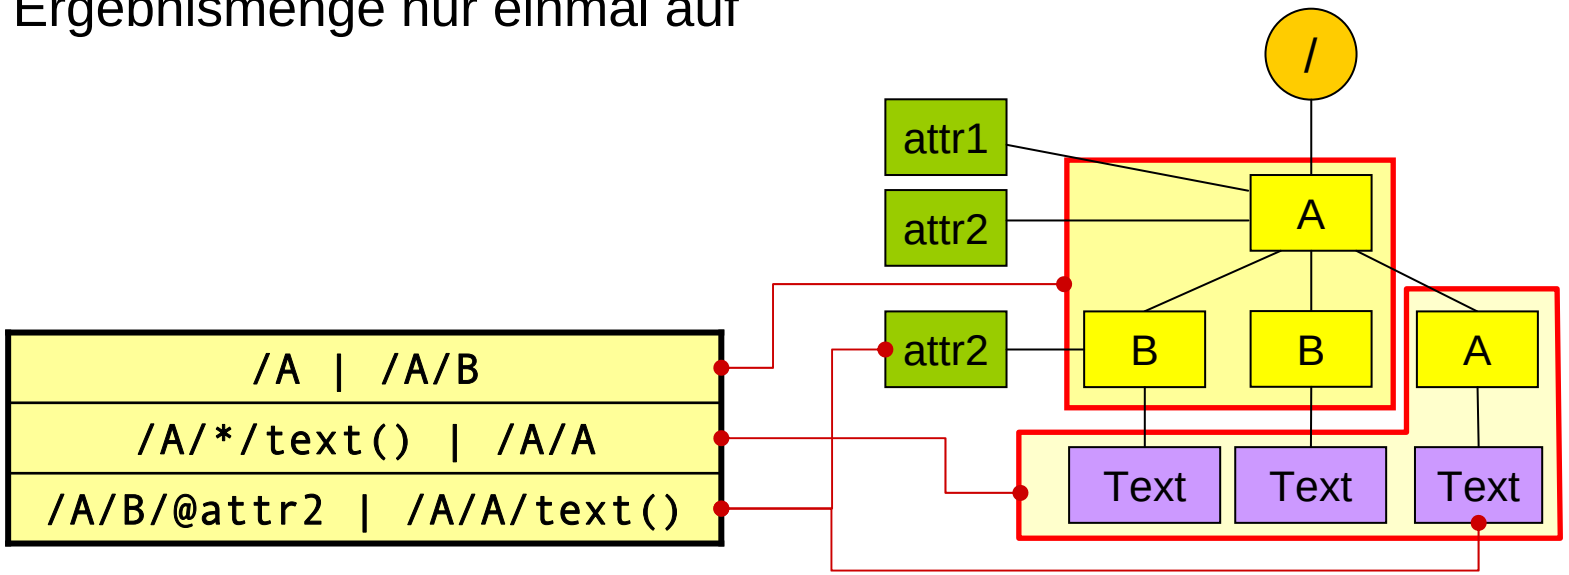

Absolute und relative Pfadangaben

- XPath unterscheidet zwischen absoluten und relativen Pfadangaben
- **absolute Pfadangaben** beginnen immer bei der Dokumentwurzel
  - da die Dokumentwurzel mit einem Slash adressiert wird, beginnen absolute Pfadangaben immer mit einem Slash
  - das Ergebnis einer absoluten Pfadangabe ist für dasselbe XML-Dokument immer gleich
- **relative Pfadangaben** beziehen sich auf zuvor ausgewählte Kontextknoten
  - das Ergebnis einer relativen Pfadangabe ist abhängig vom Kontextknoten

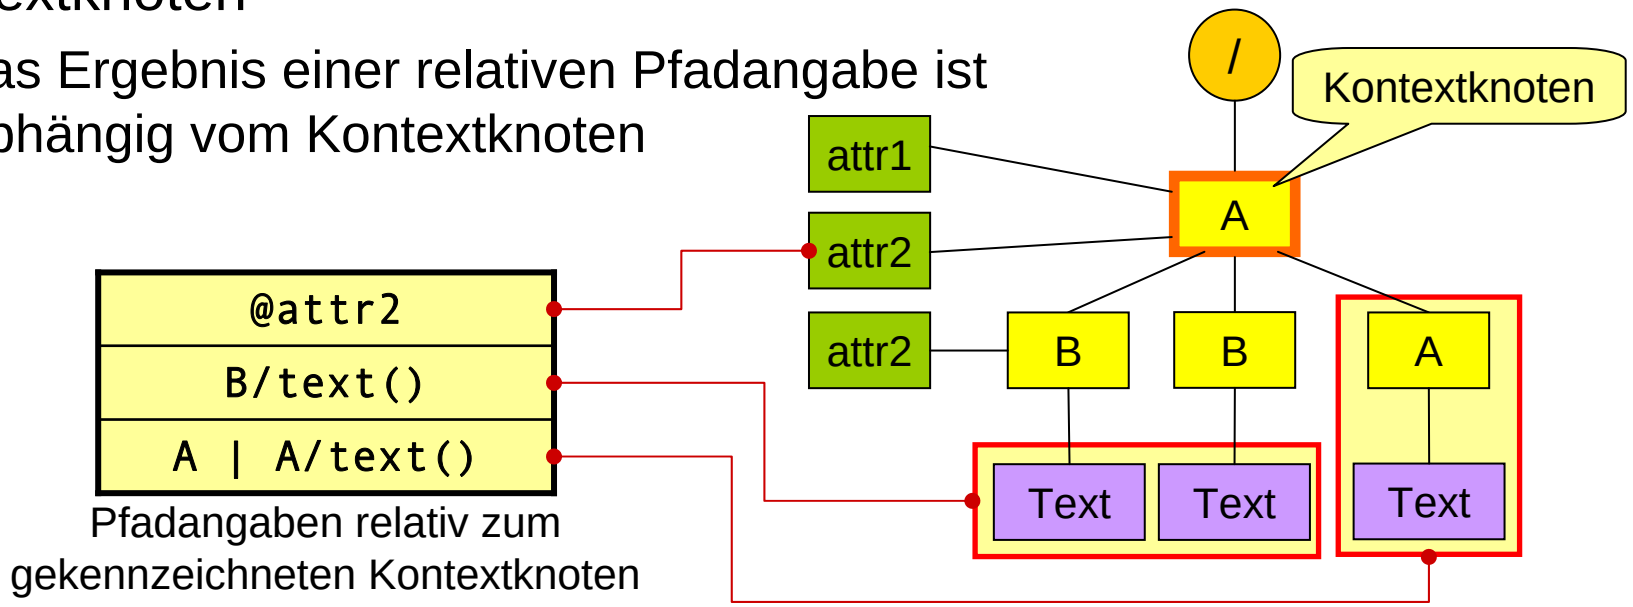

Pfadangaben relativ zum gekennzeichneten Kontextknoten

Achsen: Suchbereich von Knotentests angeben

- wenn nicht anders angegeben, beziehen sich alle Kotentests immer auf die Kinder der aktuell adressierten Knoten
  - `/A/B/C` bedeutet:
    - suche alle *A*-Kindelemente des Dokumentknotens
    - suche in den gefundenen *A*-Elementen nach *B*-Kindelementen
    - suche in den gefundenen *B*-Elementen nach *C*-Kindelementen und liefere sie als Ergebnis zurück
  - jeder Location-Step bewirkt hier also einen Abstieg um eine Ebene im Baum
- mit Hilfe einer **Achsenangabe** kann der Bereich, auf den ein Knotentest angewendet werden soll, geändert werden, z.B. um
  - in Eltern- oder Geschwisterknoten zu suchen
  - rekursiv in allen Vorgänger- oder allen Folgeknoten zu suchen
  - Attribut- oder Namensraumknoten auszuwählen
- XPath 1.0 definiert 13 verschiedene Achsen

Achsen

self

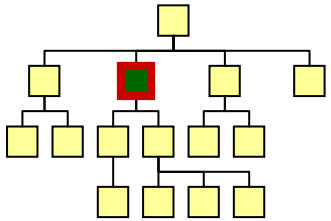

child

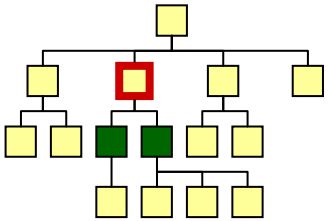

descendant

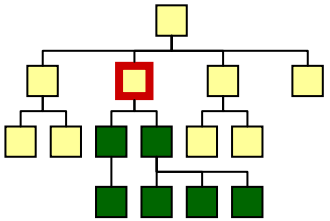

descendant-or-self

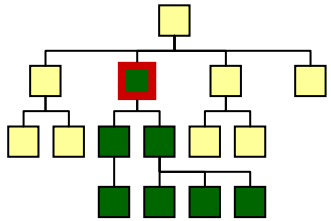

Kontextknoten
Knoten der Achse

parent

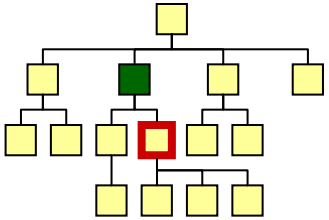

ancestor

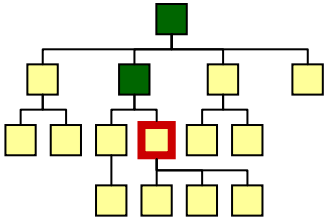

ancestor-or-self

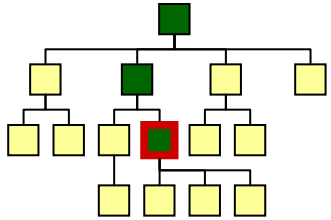

preceding

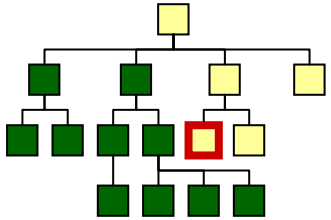

preceding-sibling

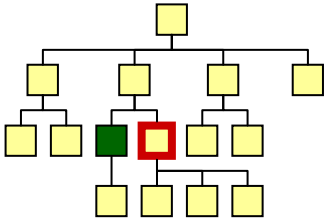

following

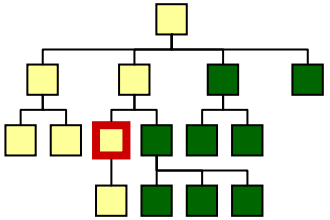

following-sibling

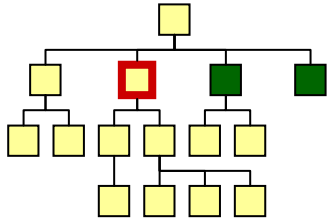

Achsen

Achse	Beschreibung
self	aktueller Knoten
child	alle unmittelbaren Kinder des aktuellen Knotens
descendant	alle Nachfahren des aktuellen Knotens
descendant-or-self	wie *descendant* aber zuzüglich des aktuellen Knotens
parent	Elternknoten des aktuellen Knotens
ancestor	alle Vorfahren des aktuellen Knotens
ancestor-or-self	wie *ancestor* aber zuzüglich des aktuellen Knotens
preceding	alle vorausgehenden Knoten ohne Vorfahren des aktuellen Knotens
preceding-sibling	alle vorausgehenden Geschwisterknoten
following	alle nachfolgenden Knoten ohne Nachfahren des aktuellen Knotens
following-sibling	alle nachfolgenden Geschwisterknoten
attribute	alle Attributknoten des aktuellen Elements

- die preceding-Achse umfasst alle Knoten, die in der XML-Datei vor dem aktuellen Knoten stehen und keine Vorfahren des aktuellen Knotens sind
- die following-Achse umfasst alle Knoten, die in der XML-Datei hinter dem aktuellen Knoten stehen und keine Nachfahren des aktuellen Knotens sind

Auswahl einer Achse

- Achsenangaben werden einem Knotentest zusammen mit zwei Doppelpunkten vorangestellt
  - z.B. `parent::A`
- Achsenangaben gelten nur für den aktuellen Location-Step
  - in der Pfadangabe `ancestor::A/B` bezieht sich die *ancestor*-Achse nur auf die Auswahl der *A*-Knoten; die *B*-Knoten werden in den Kindelementen der gefundenen *A*-Knoten gesucht
    (bei fehlender Achsenangabe wird die *child*-Achse verwendet)
- jeder Location-Step kann eine Achsenangabe enthalten
  - z.B. `ancestor::A/following-sibling::B`

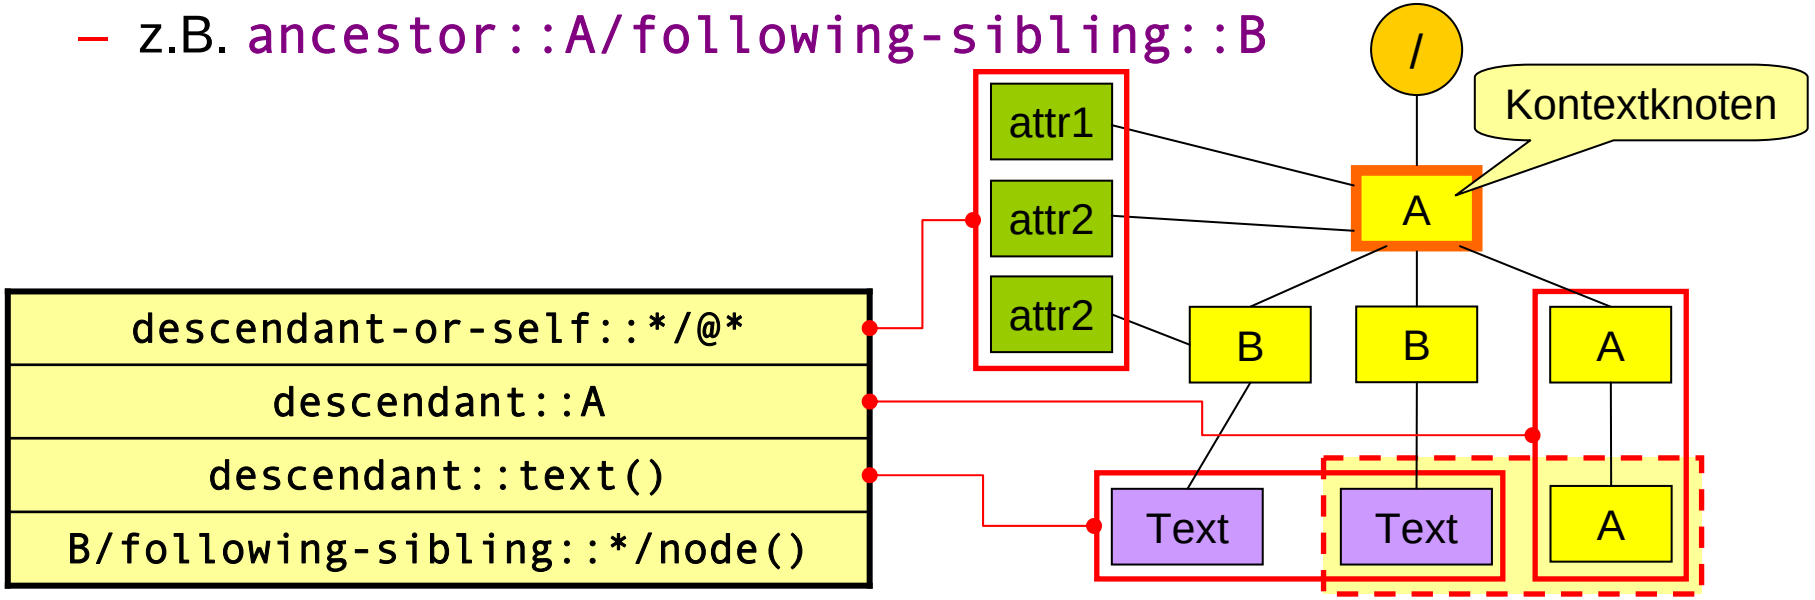

attribute-Achse

- außer *self* berücksichtigen die gerade erwähnten Achsen nur Dokument-, Element-, Text- und Kommentar-Knoten (sowie Processing-Instructions)
- Attribut- und Namespace-Knoten sind nur über die *attribute*- bzw. *namespace*-Achse erreichbar
  - für nebenstehenden XML-Baum liefert `/A/node()` nur den *B*-Knoten
    - `node()` sucht hier auf der *child*-Achse von Element *A*
    - Attributknoten gehören nicht zur *child*-Achse

    → Knotentest `node()` findet nur das *B*-Element
  - zur Adressierung des Attributknotens muss die *attribute*-Achse gewählt werden, z.B.
    - `/A/attribute::node()`
    - `/A/attribute::attr`
    - `/A/attribute::*`

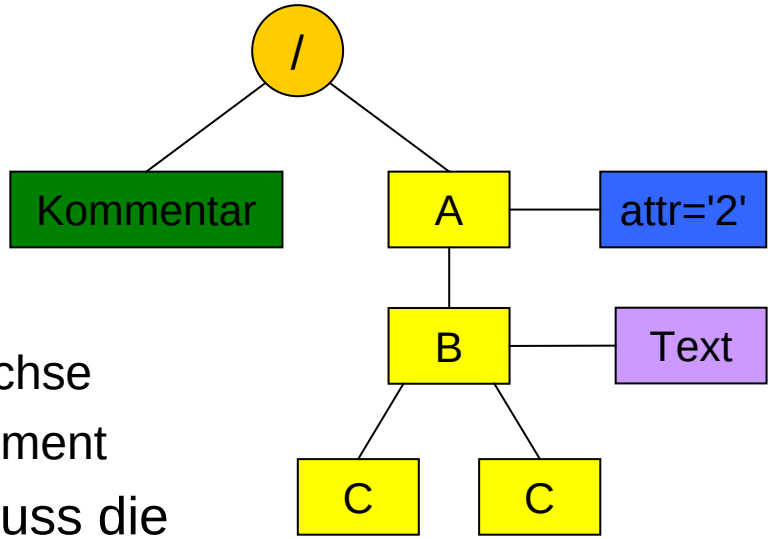

Kurzformen für häufig verwendete Location-Steps

- in der Praxis werden einige Achsen zusammen mit bestimmten Knotentests besonders häufig benötigt
  - → für fünf ausgewählte Location-Steps stellt XPath Kurzschreibweisen zur Verfügung

Kurzform	ausführliche Form
`.`	`self::node()`
`..`	`parent::node()`
`//`	`/descendant-or-self::node()/`
name	`child::`*name*
`@`*name*	`attribute::`*name*

Beispiel:
`A//B/@attr` ist eine Kurzform von
`child::A/descendant-or-self::node()/child::B/attribute::attr`

Anmerkungen zur *attribute*-Achse

- Wichtig: `@a` ist eine Kurzform für `attribute::a`
  - die Kurzform kann nicht direkt mit anderen Achsen kombiniert werden
  - etwas wie `ancestor::@a` ist syntaktisch falsch
    - die Langform wäre hier: `ancestor::attribute::a`
    - da jeder Location-Step nur eine Achsenangabe enthalten kann, ist der vorangehende Ausdruck nicht definiert
  - zur Auswahl von Attributen der Vorgängerelemente müssen zunächst die gewünschten Elemente ausgewählt werden; im zweiten Schritt sind dann die Attribute erreichbar
    - z.B. `ancestor::*/@a`

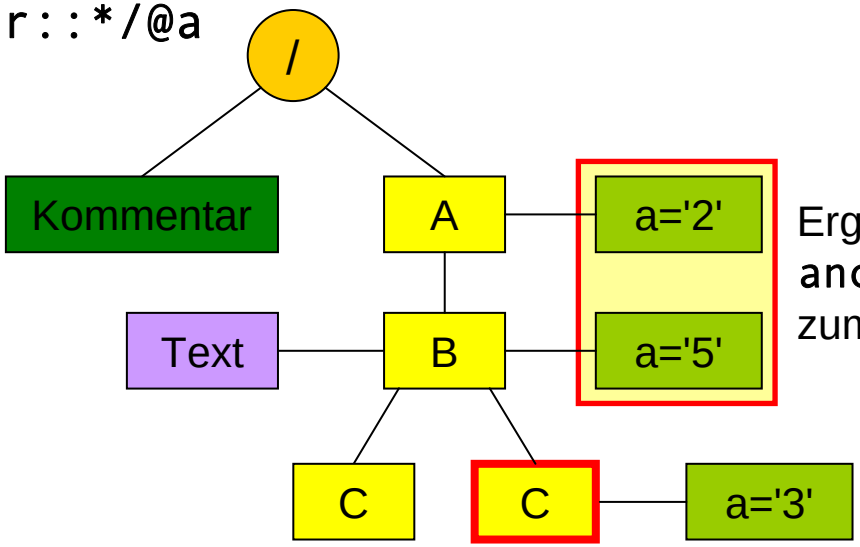

Ergebnismenge von `ancestor::*/@a` relativ zum markierten *C*-Knoten

Rekursiver Abstieg mit //

- die Zeichenfolge `//` ist eine Kurzschreibweise für `/descendant-or-self::node()/`
  - kann anstelle einfacher Slashes verwendet werden, um anschließende Knotentests auf alle Nachfahren anzuwenden
  - sollte sorgsam verwendet werden, da die Auswertung abhängig von der Größe des Teilbaums zeitaufwendig sein kann
  - abhängig vom XPath-Prozessor kann ein direkter Knotentest auf der *descendant*-Achse etwas effizienter sein, z.B. `/descendant::A` statt `//A`
    - nur zwei statt drei Location-Steps
    - Knoten müssen nur einmal geprüft werden

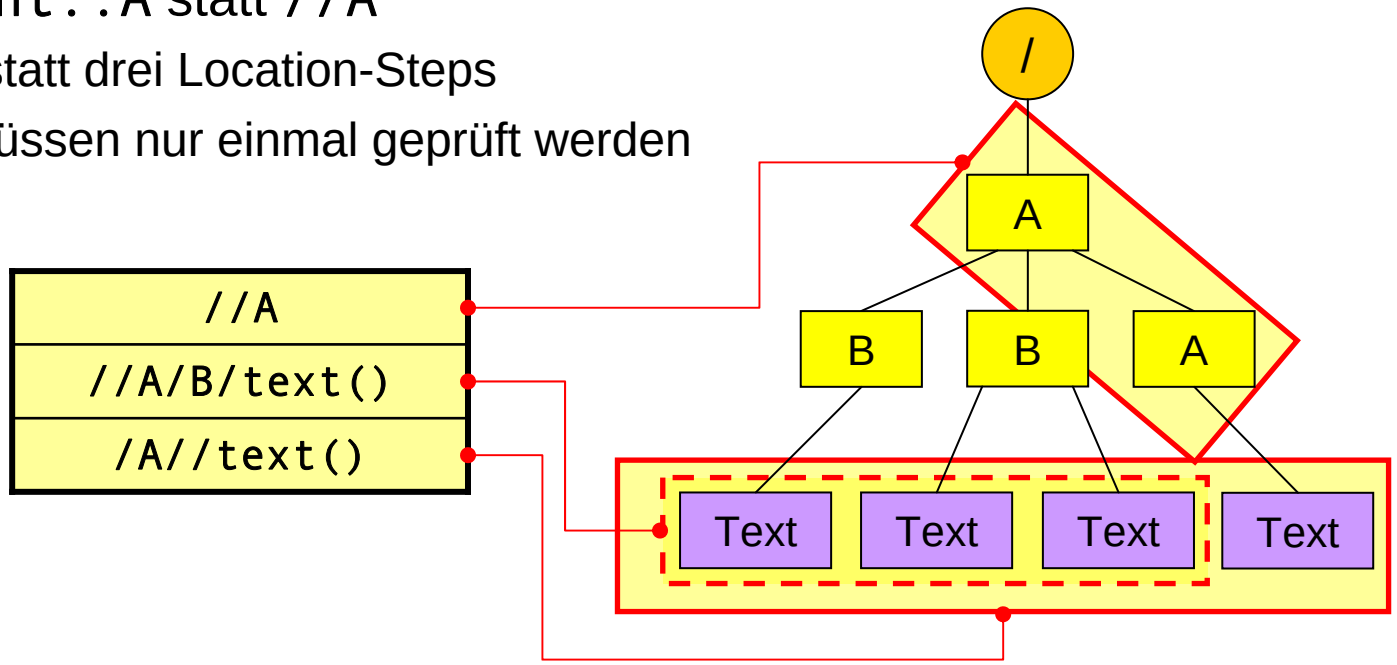

Datentypen in XPath 1.0

- XPath 1.0 unterstützt vier verschiedene Datentypen
  - **boolean** (Wahrheitswerte)
    - die beiden booleschen Konstanten lauten in XPath `true()` und `false()`
  - **number** (Gleitkommazahlen)
  - **string**
    - String-Konstanten können in einfachen oder doppelten Anführungszeichen angegeben werden, z.B. `'Hallo'` oder `"Hallo"`
  - **node-set** (Knotenmengen)
    - Knotenmengen werden üblicherweise durch Pfadangaben erzeugt

XPath-Operatoren

a `=` *b*	a gleich *b*
a `!=` *b*	*a* ungleich *b*
a `<` *b*	*a* kleiner *b*
a `>` *b*	*a* größer *b*
a `<=` *b*	*a kleiner oder gleich b*
a `>=` *b*	*a* größer oder gleich *b*

a `+` *b*	Addition
a `-` *b*	Subtraktion
a `*` *b*	Multiplikation
a `div` *b*	Gleitkomma-Division
a `mod` *b*	Gleitkomma-Modulo
a `or` *b*	logisches ODER
a `and` *b*	logisches UND
a `|` *b*	Vereinigung von Knotenmengen

Ausgewählte XPath-Funktionen

Funktion	Returntyp	Beschreibung
`concat(`*s1*`,...,`*sn*`)`	string	verkettet die Strings *s1* bis *sn* zu einem neuen String
`contains(`*s1*`, `*s2*`)`	boolean	prüft, ob String *s1* den String *s2* enthält
`count(`*K*`)`	number	Anzahl der Knoten in Menge *K*
`name(`*K*`)`	string	Name des ersten Knotens in Menge *K*
`normalize-space(`*s*`)`	string	entfernt Whitespace am Anfang und Ende von *s* und ersetzt die restlichen Whitespace-Folgen durch einfache Leerzeichen
`not(`*b*`)`	boolean	boolsche Negation
`round(`*x*`)`	number	rundet *x*
`starts-with(`*s1*`, `*s2*`)`	boolean	prüft, ob String *s1* mit *s2* beginnt
`string-length(`*s*`)`	number	Länge von String *s*
`substring(`*s*`, `*n*`, `*l*`)`	string	Teilstring von *s*, beginnend beim *n*-ten Zeichen und Länge *l*
`substring-after(`*s1*`, `*s2*`)`	string	sucht *s2* in *s1* und liefert alle Zeichen hinter dem ersten Treffer zurück (liefert Leerstring zurück falls *s2* in *s1* nicht vorkommt)
`substring-before(`*s1*`, `*s2*`)`	string	sucht *s2* in *s1* und liefert alle Zeichen vor dem ersten Treffer zurück (liefert Leerstring zurück falls *s2* in *s1* nicht vorkommt)
`sum(`*K*`)`	number	Addiert die Werte der Knoten in Menge *K*
`translate(`*s1*`, `*s2*`, `*s3*`)`	string	sucht in *s1* der Reihe nach die Zeichen von *s2* und ersetzt in *s1* das *i*-te Zeichen von *s2* durch das *i*-te Zeichen von *s3*

XPath-Ausdrücke

- neben Pfadangaben sind auch Funktionsaufrufe sowie Ausdrücke mit mathematischen und logischen Operatoren gültige XPath-Ausdrücke

- Beispiele:
  - `1+2*3`
  - `concat('XML', 'und', 'XSLT')`
  - `contains('Blumentopferde', 'pferd')`
  - `count(//A)`
  - `translate('Hello', 'eo', 'ae')`
  - `(1+2*3 > (1+2)*3) or starts-with('Hallo', 'ha')`
  - `not(count(ancestor::A) > 5)`

Automatische Typumwandlung

- Falls ein Operand oder ein Funktionsparameter nicht den erwarteten Typ besitzt, führt XPath eine implizite Typkonvertierung durch, z.B.
  `"5.5" + true() * 2` → 7.5

von \ nach	**boolean**	**number**	**string**	**node-set**
boolean		false → 0 true → 1	false → `'false'` true → `'true'`	*nicht erlaubt*
number	0 → false sonst true		Dezimalzahl als String	*nicht erlaubt*
string	`''` → false sonst true	interpretiert den String als Zahl		*nicht erlaubt*
node-set	`{}` → false sonst true	interpretiert den aus erstem Knoten gebildeten String als Zahl	hängt die Texte descendant::text() des ersten Knotens aneinander	

Prädikate

- **Prädikate** sind optionale Bestandteile eines Location-Steps und grenzen Knotenmengen durch Boolesche Ausdrücke weiter ein
  - nur Knoten, auf die der angegebene Ausdruck zutrifft, werden in die Ergebnismenge aufgenommen
- Prädikate werden in eckigen Klammern hinter einem Knotentest angegeben
  - `A[.='Hallo']`
    liefert alle *A*-Kindknoten, die den Text "Hallo" enthalten
  - `A[@attrib = 'Hallo']`
    liefert alle *A*-Kindknoten, die einen Attributknoten *attrib* mit Wert "Hallo" enthalten
  - `A[B]`
    liefert alle *A*-Kindknoten, die mindestens einen *B*-Kindknoten enthalten
- relative Pfadangaben in Prädikaten beziehen sich immer auf die durch den vorangehenden Pfadausdruck ausgewählte Knotenmenge

Prädikate: Beispiele

```
<?xml version="1.0"?>
<A a="5" b="8">
  <B a="20">Guten</B>
  <B>
    <A a="1">Morgen</A>
    <C>Heute</C>
  </B>
  <B a="50">Tag</B>
  <A>Abend</A>
</A>
```

```
//A[not(@a)]
/A/B[@a < 50]
//B[.='Tag']
```

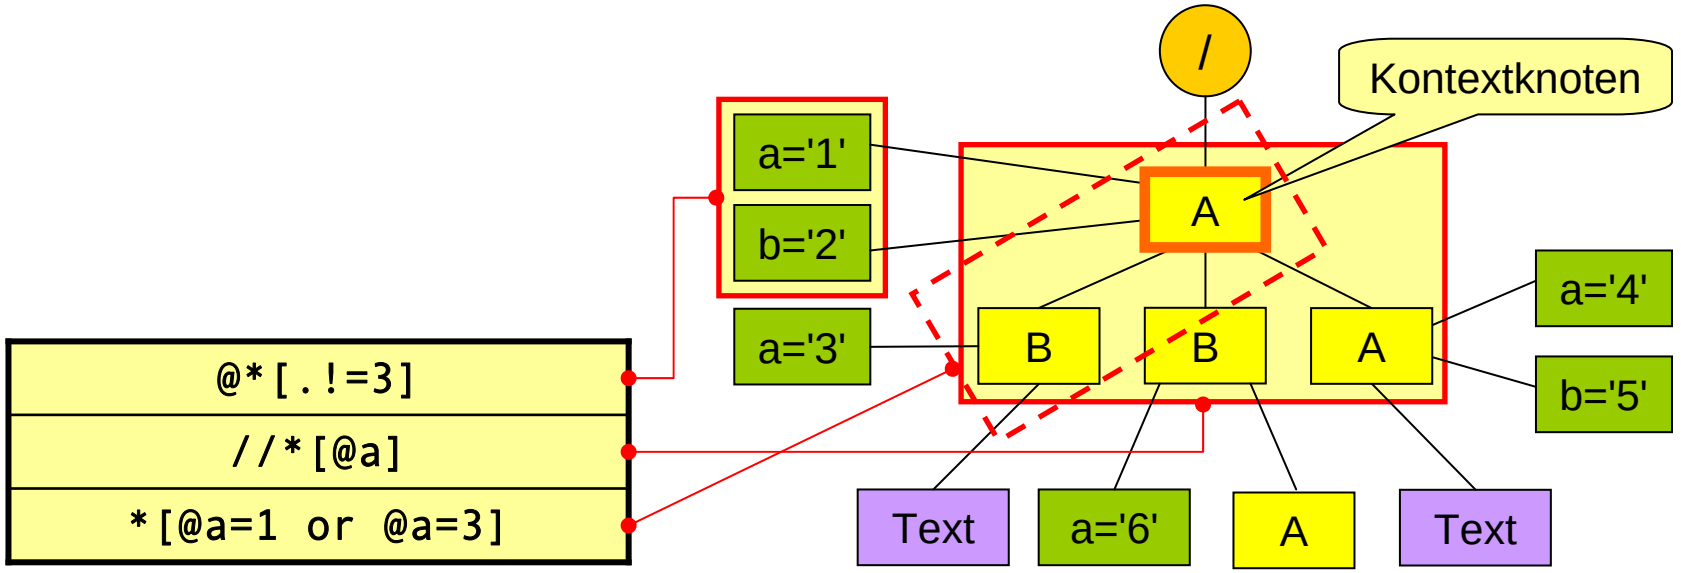

Knotennummerierung und Positionstests

- die von einem Location-Step ausgewählten Knoten werden implizit nummeriert (relativ zu Achse und Knotentest)
  - Nummerierung beginnt immer bei 1
- die XPath-Funktion `position()` liefert die Positionsnummer des aktuellen Kontextknotens
  - der Ausdruck `A[position()=1]` liefert alle *A*-Knoten mit Positionsnummer 1

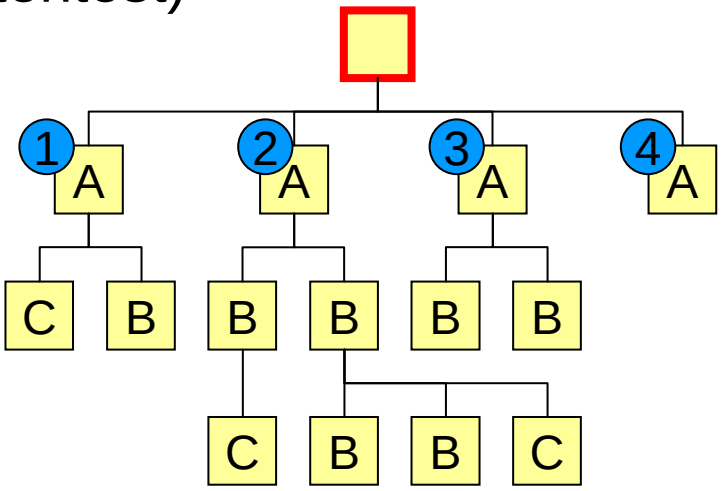

Nummerierung der Ergebnisknoten beim Location-Step `A` relativ zum rot markierten Kontextknoten

- Prädikate der Form `position()=`*n*, wobei *n* eine Zahl (Typ *number*) ist, werden **Positionstests** genannt
- Prädikate, die nur aus einer Zahl bestehen, werden immer als Positionstests interpretiert
  - `A[1]` ist eine Kurzform von `A[position()=1]`

Knotennummerierung und Positionstests

- die Knotennummerierung bezieht sich immer auf die gewählte Achse
  - im Fall der *child*-Achse werden die Kinder des Kontextknotens in Dokumentreihenfolge durchnummeriert
  - wenn ein Knotentest Kindknoten von unterschiedlichen Eltern zurückliefert, beginnt die Nummerierung der Kinder für jeden Elternknoten erneut bei 1
- für den abgebildeten Baum liefert die Pfadangabe `A/B[1]` eine Menge mit drei *B*-Knoten zurück
- zur gezielten Auswahl eines *B*-Knotens muss zuvor der gewünschte *A*-Knoten selektiert werden, z.B. liefert `A[3]/B[1]` den ersten *B*-Kindknoten des dritten *A*-Elements

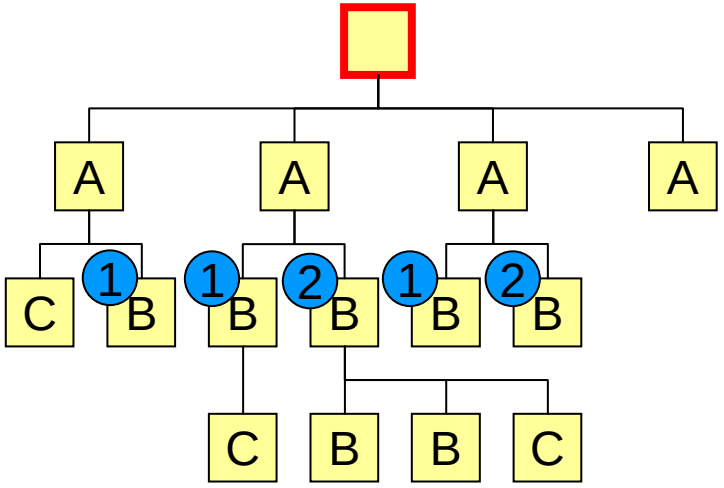

Knotennummerierung und Positionstests

- die Knotennummerierung ist abhängig von
  - dem/den jeweiligen Kontextknoten
  - der gewählten Achse
  - dem Knotentest
- durch Änderung eines dieser Parameter ändert sich ggf. die Nummerierung

Knotennummerierung und Positionstests

- bei allen Achsen, die Dokumentbereiche hinter dem Kontextknoten beschreiben, wächst die Nummerierung in Richtung des Dokumentendes
- bei allen Achsen, die Dokumentbereiche vor dem Kontextknoten beschreiben, wächst die Nummerierung in Richtung des Dokumentanfangs

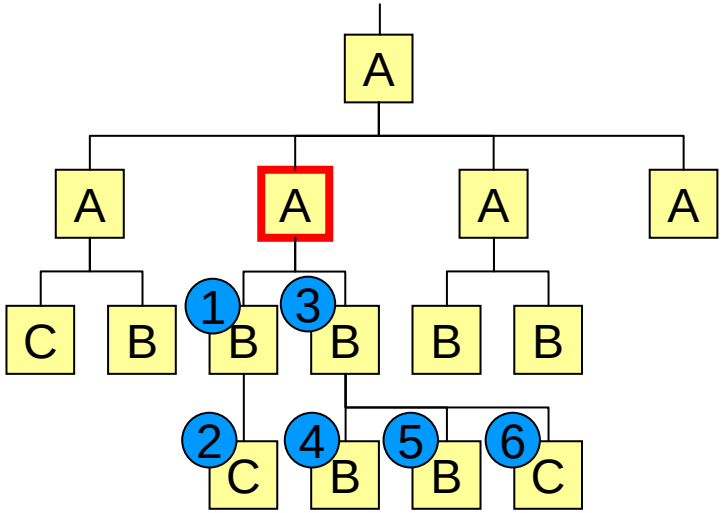

`descendant::*`

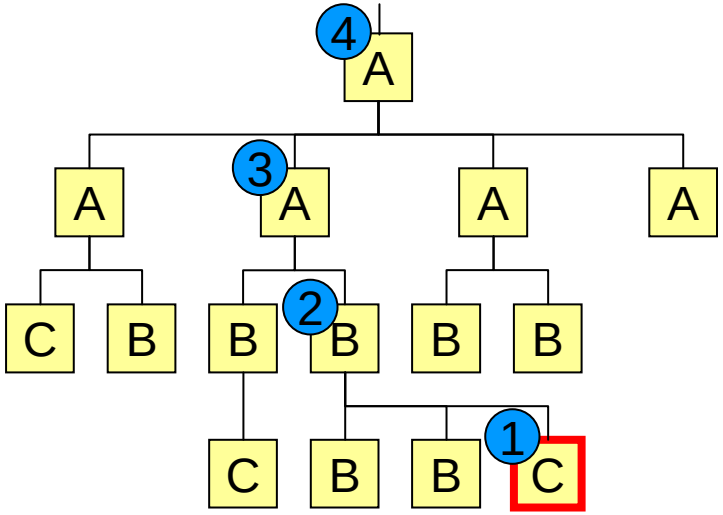

`ancestor-or-self::*`

Knotennummerierung und Positionstests

```
<adressbuch>
  <adresse>
    <name geschlecht="m">
      <vorname>Jim</vorname>
      <nachname>Panse</nachname>
    </name>
    <strasse>Primatenring 16</strasse>
    <ort plz="12345">Affenbach</ort>
  </adresse>
  <adresse>
    <name geschlecht="m">
      <vorname>Bernhard</vorname>
      <nachname>Diener</nachname>
    </name>
    <strasse>Dackelgasse 9</strasse>
    <ort plz="54321">Köteringen</ort>
  </adresse>
  <adresse>
    <name geschlecht="w">
      <vorname>Wanda</vorname>
      <nachname>Düne</nachname>
    </name>
    <strasse>Küstenstraße 1</strasse>
    <ort plz="77777">Süddeich</ort>
  </adresse>
</adressbuch>
```

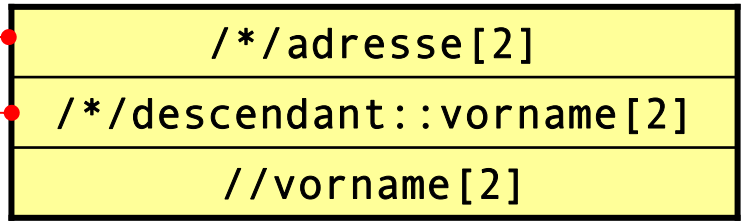

Unterschied `//A[1]` und `/descendant::A[1]`

- `//A` und `/descendant::A` sammeln dieselben Knoten ein
- `//A[1]` und `/descendant::A[1]` beschreiben hingegen unterschiedliche Knotenmengen. Warum?
- die Pfadangabe `//A[1]` besteht aus drei Location-Steps
  - Langform: `/descendant-or-self::node()/A[1]`
  - → das Prädikat bezieht sich auf einen Knotentest der *child*-Achse
  - bei `/descendant::A[1]` bezieht sich das Prädikat auf einen Knotentest der *descendant*-Achse

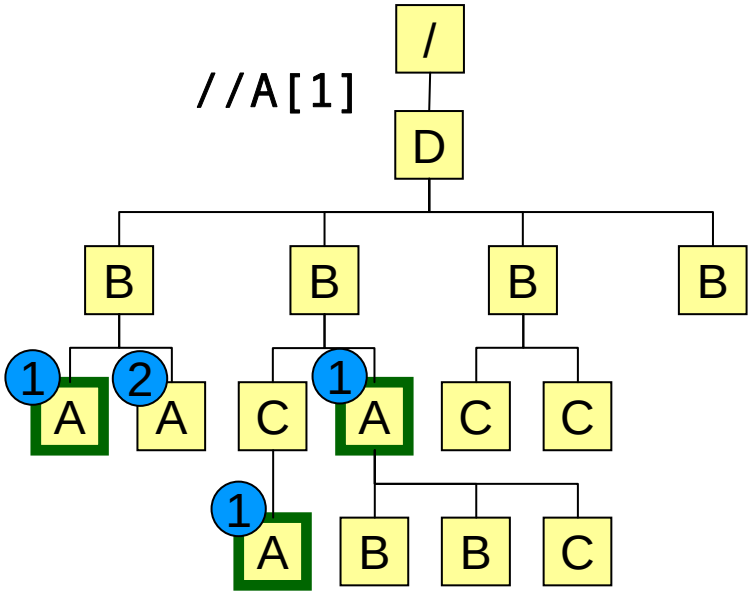

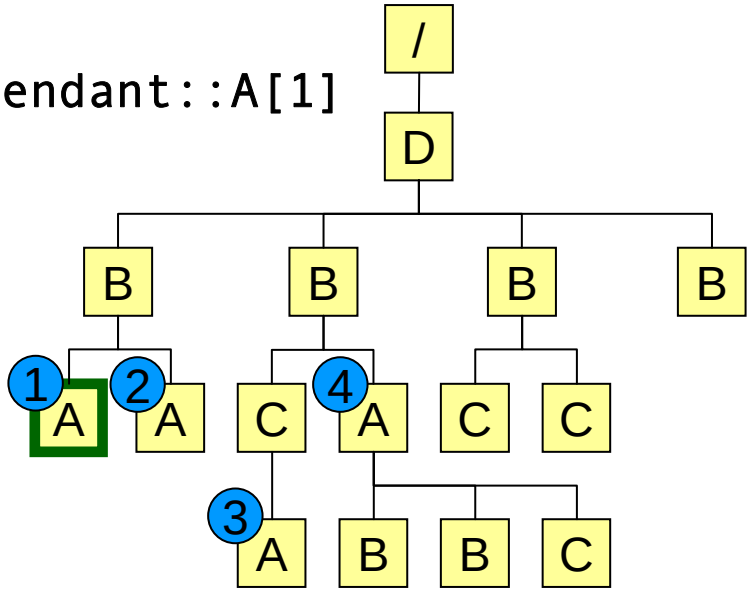

Knotennummerierung und Positionstests

- soll sich ein Positionstest nicht auf die Position eines Knotens im XML-Baum sondern auf die Position in der Ergebnismenge beziehen, muss die Pfadangabe geklammert werden:
  `(`*pfadangabe*`)[position()=`*n*`]` oder kurz `(`*pfadangabe*`)[`*n*`]`

- `//A[1]` liefert alle Knoten des XML-Dokuments, die erstes *A*-Kindelement ihres Elternelements sind

- `(//A)[1]` liefert das erste im XML-Dokument vorkommende *A*-Element

XPath vs. XQuery

- mit XPath kann man:
  - in XML-Bäumen navigieren
  - einzelne Knoten und Knotenmengen aus XML-Bäumen auswählen
- mit XPath kann man nicht:
  - Daten sortieren
  - Daten neu gruppieren
  - Variablen und Funktionen definieren
  - neue XML-Knoten erzeugen
  - XML-Dokumente ändern
- XQuery ist eine deklarative Programmiersprache mit XPath als Untermenge
  - ermöglicht komplexe Abfragen von Daten aus XML-Dokumenten
  - bietet Konstrukte zur Erzeugung neuer XML-Bestandteile
  - kann für bestimmte Aufgaben als Alternative zu XSLT dienen
  - Ändern von XML-Daten nur mit *XQuery Update Facility* möglich

XQuery-Tools

- BaseX, XML-Datenbank mit GUI
  - http://www.inf.uni-konstanz.de/dbis/basex
  - Java
- Saxon-HE von Michael Kay
  - http://saxon.sourceforge.net
  - Java, .NET, kostenlose Home Edition (Open Source)
- AltovaXML
  - http://www.altova.com/de/altovaxml.html
  - proprietär, nur für Windows
- XQilla
  - http://xqilla.sourceforge.net
  - C++
- Zorba XQuery-Prozessor
  - http://www.zorba-xquery.com
  - C++

XQuery: Datentypen und -strukturen

- XQuery (und XPath 2.0) verwendet das Typensystem von XML Schema
  - **atomare (einfache elementare) Typen:**
    xs:boolean, xs:integer, xs:double, xs:string, xs:date, …
  - **Knotentypen:**
    Element, Attribut, Text, Kommentar, Verarbeitungsanweisung, Namensraum
- als einzige komplexe Datenstruktur gibt es die **Sequenz**
  - geordnete Liste von Objekten beliebigen Typs
  - Sequenzen dürfen aus beliebig vielen Komponenten bestehen
  - jede Komponente darf einen anderen Typ haben
  - die Reihenfolge der Komponenten ist signifikant
- Sequenzen können u.a. durch Auflistung der Komponenten oder als Ergebnis von Pfadausdrücken erzeugt werden
  - `(1, 2, 'Hallo', @wert)`
  - `//person/vorname`

XQuery: neues Typensystem

- mit der Einführung des neuen Typensystems findet eine strengere Prüfung der Typen statt
  - im Objekte mit atomarem Typ werden nicht mehr automatisch in andere Typen konvertiert
    - der Ausdruck `1+'2'+true()` ist in XQuery nicht erlaubt
  - Typkonvertierungen müssen explizit notiert werden
    - z.B. `1+xs:integer('2')+xs:integer(true())`
  - Knoten ohne zugewiesenen Schema-Typ bekommen den Typ *xs:untyped* und werden bei der Auswertung ggf. automatisch konvertiert
    - im Ausdruck `1+@wert` wird das *wert*-Attribut des Kontextknotens in eine Zahl (xs:decimal) konvertiert
    - im Ausdruck `concat('Hallo', @wert)` wird das *wert*-Attribut des Kontextknotens in einen String (xs:string) konvertiert

Sequenzen

- in XPath 1.0 erzeugen Pfadausdrücke Knotenmengen, die keinen, einen oder mehrere Knoten enthalten können
- in XQuery sind Sequenzen endliche Listen, die beliebige Objekte mit beliebigen Typen enthalten dürfen
- Sequenzen können explizit durch Aufzählung der Komponenten in runden Klammern erzeugt werden
  - `(1, 2, 'Hallo', 3.0)`
  - `(1 to 10)` ist eine Kurzform für `(1,2,3,4,5,6,7,8,9,10)`
- Sequenzen dürfen auch Sequenzen enthalten
  - geschachtelte Sequenzen werden immer aufgelöst, so dass eine eindimensionale Liste entsteht („innere Klammern werden entfernt“)
  - `(1,(2,(3,4)),('Hallo', 'Welt'))` wird zu `(1,2,3,4,'Hallo','Welt')`
  - `(//bundesland[@typ='stadtstaat'], //name)` kombiniert die Ergebnissequenzen der beiden Pfadausdrücke

XQuery: Variablen definieren mit `let`

- in XPath kann zwar auf Variablen zugegriffen werden, es gibt aber keine Möglichkeit, Variablen zu definieren
- XQuery stellt die Anweisung **let** zur Variablendefinition bereit
  - Variablen dürfen beliebige Objekte oder Sequenzen zugewiesen werden
  - Variablen können nachträglich nicht mehr geändert werden
  - Variablen können optional typisiert werden
- `let $`*var* `:=` *ausdruck*
  - `let $zahl := 5`
  - `let $namen := //person/name`
  - `let $seq := (1,2,6,3,'Hallo')`
- `let $`*var* `as` *typ* `:=` *ausdruck*
  - `let $zahl as xs:double := 5`
  - `let $namen as xs:string* := //person/name`

XQuery: Ergebnis angeben mit `return`

- jeder XPath-Ausdruck produziert ein Ergebnis, das anschließend weiterverarbeitet werden kann
  - das Ergebnis kann aus einem Leerstring oder einer leeren Sequenz bestehen
  - es gibt keinen XPath-Ausdruck vom Typ „void“
- in XQuery gilt im Prinzip das gleiche:
  jeder XQuery-Ausdruck muss ein Ergebnis produzieren
- da eine Variablendefinition kein Ergebnis erzeugt, darf sie nicht isoliert verwendet werden
- das gewünschte Query-Ergebnis muss mit einer folgenden **return**-Anweisung festgelegt werden

```
let $personen := //personen[vorname='Maria']
return $personen/nachname
```

```
let $vornamen := //personen/vorname
return for $vn in $vornamen return concat('Hallo', $vn)
```

XQuery: Definition mehrerer Variablen mit gleichem Namen

- in XQuery gibt es keinen Zuweisungsoperator, so dass Variablen nach ihrer Definition nicht mehr geändert werden können
- trotzdem ist folgendes Query erlaubt:

```
let $n := 1
let $n := $n+1
return $n
```

  - Ergebnis des Querys ist 2
  - wie kann das sein, wenn Variablen nicht geändert werden können?

- jede Variablendefinition erzeugt eine neue Variable
  - gleichnamige Variablen verdecken die jeweils vorangehende Definition
  - auf der rechten Seite von `:=` ist die vorangehende Definition noch sichtbar, deshalb wird dem zweiten *n* der Wert des ersten zugewiesen
  - in der *return*-Anweisung ist nur noch die zweite Variable sichtbar, die erste existiert aber noch
- das Query ist identisch zu folgendem:

```
let $n := 1
let $m := $n+1
return $m
```

  - hier kann im *return*-Statement sowohl auf *n* als auch auf *m* zugegriffen werden

XQuery: Bedingte Ausdrücke mit `if-then-else`

- XQuery erlaubt fallunterscheidende Ausdrücke mit Hilfe einer if-then-else-Konstruktion:
- Syntax: `if (<bedingung>) then <ausdruck1>`
  `else <ausdruck2>`
  - da XQuery-Audrücke immer ein Ergebnis produzieren müssen, ist der *else*-Teil verpflichtend, kann also nicht weggelassen werden
  - ist vergleichbar mit dem ternären Operator `?:` in C/C++/Java
    - Java: `(b > c) ? b : c;`
    - XPath: `if ($b > $c) then $b else $c`
  - die Datentypen vom *then*- und *else*-Teil müssen nicht identisch sein
    - `if (adressen) then adressen/adresse else "Hallo Welt"` ist erlaubt
  - der *then*-Ausdruck wird nur ausgewertet, wenn die Bedingung wahr ist und der *else*-Ausdruck nur, wenn die Bedingung falsch ist
    - `if ($a > 0) then 1 div $a else $a` produziert also keinen Fehler falls `$a=0`

XQuery: Iterieren über Sequenzen mit `for-return`

- um einen Ausdruck auf jede Komponente einer Sequenz anzuwenden wird **for-return** verwendet
  - das Resultat ist eine neue Sequenz mit den Ergebnissen der einzelnen Iterationsschritte
- Syntax: `for $var in <sequenz> return <ausdruck>`
- Beispiele:
  - `for $i in (1 to 10) return $i*0.1`
    erzeugt die Sequenz (0.1, 0.2, .0.3, ..., 1.0)
  - `for $i in //name return concat('Hallo ', $i)`
    iteriert über alle *name*-Elemente des aktuellen Dokuments und erzeugt daraus eine String-Sequenz der Form ('Hallo Jim', 'Hallo Anna', …)
- *for-return* darf überall dort verwendet werden, wo Sequenzausdrücke erlaubt sind, z.B.

```
let $grüße := if (//name) then
  for $i in //name return concat('Hallo ', $i)
else
  'niemand zum Begrüßen da'
return $grüße
```

XQuery: FLWOR – erweiterte **for-return**-Anweisung

- XQuery erlaubt zwischen *for* und *return* zusätzlich die folgenden optionalen Angaben:
  - beliebig viele **let**-Anweisungen zur Variablendefinition
  - eine **where**-Anweisung der Form `where` *bedingung*
    zum Filtern von Sequenzkomponenten
  - eine **order by**-Anweisung der Form `order by` *ausdruck richtung*
    zum Ändern der Iterationsreihenfolge

XQuery: FLWOR – erweiterte **for-return**-Anweisung

- **let:** Definition von Variablen bei jedem Iterationsschritt

```
for $n in (4,7,1,1)
let $m := 2*$n
return $m
```

  - die Variable *m* wird bei jedem Iterationsschritt neu definiert
  - das Query liefert die Sequenz `(8,14,2,2)`
- auch hier gilt, dass eine Variable mit gleichem Namen die vorangehende verdeckt

```
let $m := 5
for $n in (4,7,1,1)
let $m := $n*$m
return $m
```

  - im zweiten *let*-Statement bezeichnet `$m` die erste Variable *m*, im *return*-Statement wird die zweite verwendet
  - liefert die Sequenz `(20,35,5,5)`

XQuery: FLWOR-Ausdrücke

- **where**: Iteration beschränken
  - es werden nur Sequenzelemente berücksichtigt, die die angegebene Bedingung erfüllen

```
for $person in //person
let $vname := $person/name/vorname
where starts-with($vname, 'M')
return $person
```

  - hat den gleichen Effekt wie ein Prädikat
  - im *where*-Ausdruck können zusätzlich "innere" Variablen verwendet werden
- **order by**: Verarbeitungsreihenfolge ändern
  - vor der Iteration wird für jede Komponente der Sortierausdruck ausgewertet und die Sequenz anhand dieser Werte sortiert
  - anschließend wird über die sortierte Sequenz iteriert

```
for $person in //person
order by $person/name/nachname, $person/name/vorname
return $person
```

XQuery: FLWOR-Ausdrücke

- die optionalen Bestandteile von *for-return* müssen immer in der Reihenfolge **let** – **where** – **order by** angegeben werden
- ein kompletter *for-return*-Ausdruck hat also die Form
  for – **let** – **where** – **order by** – **return**
- die Anweisung wird deshalb auch **FLWOR-Ausdruck** genannt, unabhängig davon, ob alle Bestandteile verwendet werden
  - FLWOR wird wie engl. *flower* ausgesprochen

```
for $person in //person
let $vorname := $person/name/vorname
let $nachname := $person/name/nachname
where $person/wohnort = 'Osnabrück'
order by $nachname, $vorname
return concat('Hallo ', $vorname, ' ', $nachname, '&#10;')
```

  - trotz der verschiedenen Schlüsselwörter handelt es sich hier um nur einen Ausdruck
  - liefert als Resultat eine Sequenz mit String-Objekten

XQuery: FLWOR-Ausdrücke

- ein FLWOR-Ausdruck darf mehrere *for*-Anweisungen enthalten
  - werden wie ineinander geschachtelte for-Schleifen behandelt

```
for $i in ('a','e')
for $j in ('b','k','t')
return concat($i, $j)
```

oder

```
for $i in ('a','e'),
    $j in ('b','k','t')
return concat($i, $j)
```

  - liefert die Sequenz `('ab','ak','at','eb','ek','et')`
- zwischen zwei *for*-Anweisungen dürfen beliebig viele *let*-Anweisungen stehen
  - *order by*, *where* und *return* sind nur hinter dem letzten *for* erlaubt

```
for $i in ('a','e')
let $r := concat($i,'r')
for $j in ('b','k','e')
let $s := concat($r,$j)
where contains($s, 'e')
return $s
```

- liefert die Sequenz `('are','erb','erk','ere')`

XQuery: Positionsvariablen in FLWOR-Ausdrücken

- zur Abfrage der Position einer Sequenzkomponente werden in FLWOR-Ausdrücken **Positionsvariablen** verwendet
  - zusätzliche Variable, die in der *for*-Anweisung hinter der Iterationsvariablen mit dem Präfix **at** angegeben wird

```
for $person at $i in //personen[vorname='Maria']
return concat($i,' Maria ',$person/nachname,'&#10;')
```

- eine Positionsvariable enthält einen Integer-Wert, der die Position der aktuellen Komponente in der angegebenen Sequenz enthält
- **order by** ändert die Zuordnung von Position zu Sequenz-komponente nicht!

```
for $z at $i in (5,3,1,2,4)
order by $z
return ('Pos.', $i, ':', $z)
```

Pos. 3 : 1
Pos. 4 : 2
Pos. 2 : 3
Pos. 5 : 4
Pos. 1 : 5

XQuery: Positionsvariablen in FLWOR-Ausdrücken

- sollen die Komponenten der sortierten Sequenz nummeriert ausgegeben werden, benötigt man einen zweiten FLWOR-Ausdruck

```
(: Sequenz sortieren und in Variable ablegen:)
let $sortiert :=
  for $z1 in (5,3,1,2,4)
  order by $z1
  return $z1

(: sortierte Sequenz nummeriert ausgeben :)
for $z2 at $i in $sortiert
return ('Pos.', $i, ':', $z2, '&#10;')
```

```
Pos. 1 : 1
Pos. 2 : 2
Pos. 3 : 3
Pos. 4 : 4
Pos. 5 : 5
```

  - dasselbe ohne zusätzliche Variable:

```
for $z2 at $i in
  (: sortierte Sequenz erzeugen :)
  for $z1 in (5,3,1,2,4)
  order by $z1
  return $z1
return ('Pos.', $i, ':', $z2, '&#10;')
```

```
Pos. 1 : 1
Pos. 2 : 2
Pos. 3 : 3
Pos. 4 : 4
Pos. 5 : 5
```

XQuery: Element-Konstruktoren

- XQuery-Skripte können literale XML-Elemente enthalten
- der Inhalt von Attributen und Elementrümpfen wird als literaler Text interpretiert und nicht weiter ausgewertet
- XQuery-Anweisungen innerhalb von Attributen oder Elementen müssen mit {…} geklammert werden

```
let $personen :=
  <personen>
    <person geschlecht="m">Jim Panse</person>
    <person geschlecht="w">Anna Konda</person>
  </personen>
return
  <personen-neu>{
    for $person at $pos in $personen/person
    return
      <person pos="{$pos}">
        {$person/@geschlecht}
        <vname>{substring-before($person, ' ')}</vname>
        <nname>{substring-after($person, ' ')}</nname>
      </person>
  }</personen-neu>
```

XQuery Update Facility

- XQuery ist von Haus aus eine reine Abfragesprache ohne Seiteneffekte
  - d.h. es gibt keine Möglichkeit, Daten in XML-Dokumenten zu ändern
- bei Verwendung von XML als Datenbankformat ist es allerdings erforderlich, auch Daten ändern, einfügen oder löschen zu können
- daher gibt es die XQuery-Erweiterung **XQuery Update Facility**, kurz: **XUF**
  - separate W3C-Spezifikation neuer XQuery-Sprachbestandteile
  - wird inzwischen von nahezu allen XQuery-Prozessoren unterstützt
- XUF stellt fünf neue XQuery-Anweisungen zur Änderung von Daten zur Verfügung
  - **insert**, **delete**, **replace**, **rename**, **copy**
  - die Anweisungen produzieren im Gegensatz zu allen anderen XQuery-Ausdrücken keinen Rückgabewert, sondern ändern statt dessen das XML-Dokument

XQuery Update Facility: insert

- `insert node(s)` *knoten* `into` *ziel*
  - fügt den/die angegebenen Knoten als Kind in den Zielknoten ein
  - Position innerhalb des Zielknotens ist implementationsabhängig
- `insert node(s)` *knoten* `as first|last into` *ziel*
  - fügt den/die angegebenen Knoten als erstes/letzes Kind in den Zielknoten ein
- `insert node(s)` *knoten* `after|before` *ziel*
  - fügt den/die angegebenen Knoten als Geschwister vor/hinter dem Zielknoten ein

```
insert node <plz>49080</plz>
  as last into //adresse[1]
```

```
insert node <plz>49080</plz>
  after //adresse[1]/ort
```

```
<adressen>
  <adresse>
    <name>Hans Meier</name>
    <ort>Osnabrück</ort>
    <plz>49080</plz>
  </adresse>
  <adresse>...</adresse>
  ...
</adressen>
```

XQuery Update Facility: delete und rename

- `delete node(s)` *knoten*
  - entfernt den/die angegebenen Knoten aus dem XML-Dokument

```
delete node //adresse[1]/plz
```

```
delete nodes //adresse/plz
```

```
<adressen>
  <adresse>
    <name>Hans Meier</name>
    <ort>Osnabrück</ort>
    <plz>49080</plz>
  </adresse>
  <adresse>...</adresse>
  ...
</adressen>
```

- `rename node` *knoten* `as` *neuer_name*
  - weist dem angegebenen Knoten einen neuen Namen zu

```
for $a in //adresse
return
  rename node $a as 'anschrift'
```

```
<adressen>
  <anschrift>
    <name>Hans Meier</name>
    <ort>Osnabrück</ort>
    <plz>49080</plz>
  </anschrift>
  <anschrift>...</anschrift>
  ...
</adressen>
```

XQuery Update Facility: replace

- `replace node` *knoten* `with` *ersatz*
  - ersetzt den angegebenen Knoten durch einen anderen

```
replace node //adresse[1]/plz
  with <PLZ>49078</PLZ>
```

```
<adressen>
  <adresse>
    <name>Hans Meier</name>
    <ort>Osnabrück</ort>
    <PLZ>49078</PLZ>
  </adresse>
  <adresse>...</adresse>
  ...
</adressen>
```

- `replace value of node` *knoten* `with` *ersatz*
  - ersetzt den Inhalt des angegebenen Knotens

```
replace value of
  node //adresse[1]/plz
  with 49090
```

```
<adressen>
  <anschrift>
    <name>Hans Meier</name>
    <ort>Osnabrück</ort>
    <plz>49090</plz>
  </anschrift>
  <anschrift>...</anschrift>
  ...
</adressen>
```

XSLT: Extensible Stylesheet Language Transformations

- XSLT ist eine deklarative Programmiersprache im XML-Format, mit der Transformationen von XML-Dateien in andere Formate beschrieben werden können
- XSLT-Stylesheets werden von einem XSLT-Prozessor ausgeführt
  - eine kleine Auswahl kostenloser Prozessoren:
    - *Saxon* von Michael Kay (http://saxon.sourceforge.net)
    - *Xalan* von der Apache Group (http://xml.apache.org/xalan-j)
    - *libxslt* des Gnome Projekts (http://xmlsoft.org/XSLT)
    - *AltovaXML for Windows* (http://www.altova.com/de/altovaxml.html)
    - alle gängigen Web-Browser (Firefox, Opera, Chrome, IE, Safari, …)

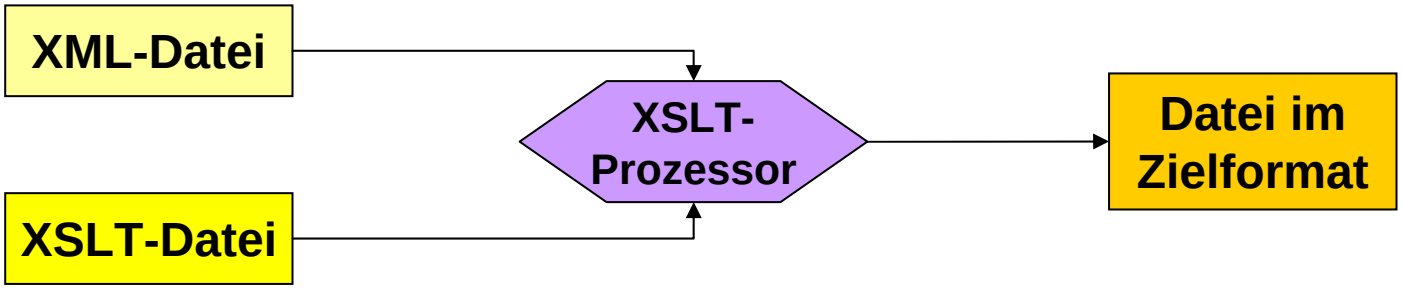

Grundideen von XSLT

- XSLT-Programme, auch XSLT-**Stylesheets** genannt, erzeugen aus einem XML-Dokument ein neues Dokument
  - das XML-Ausgangsdokument wird dabei nicht verändert
- XSLT-Stylesheets enthalten **Templates**, die beschreiben, was der XSLT-Prozessor mit einzelnen Knoten des XML-Dokuments machen soll

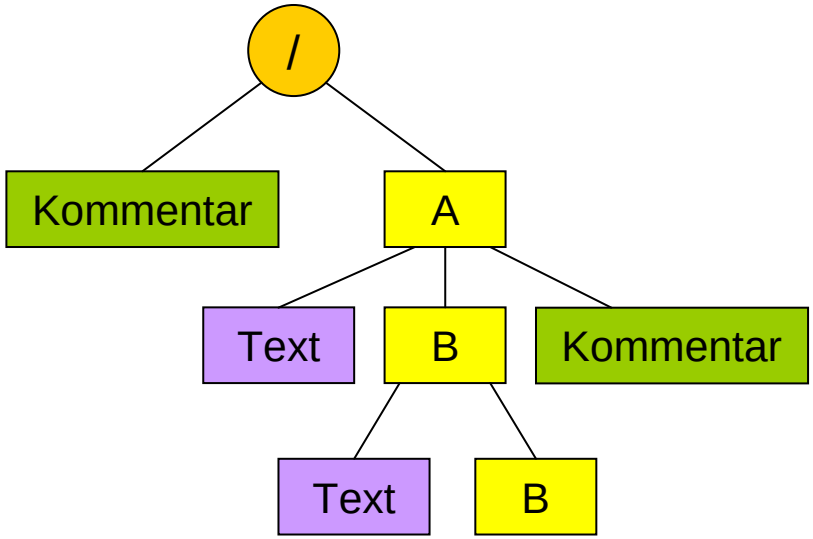

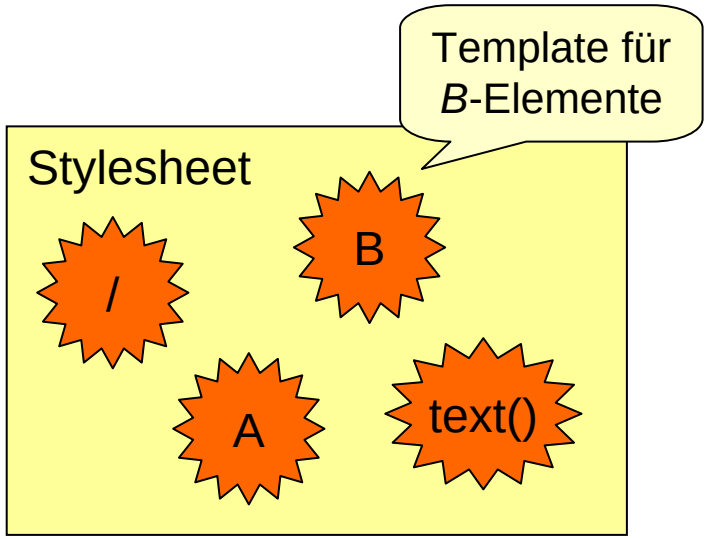

Grundideen von XSLT

- für jeden Knoten des XML-Dokuments muss es ein passendes Template geben
  - XSLT definiert Standard-Templates für jeden Knotentyp
  - nur vom Standardverhalten abweichende Templates müssen implementiert werden
- die Reihenfolge, in der die Templates aufgerufen werden, wird normalerweise nicht im Stylesheet festgelegt
  - die Verarbeitung beginnt immer mit der Dokumentwurzel
  - das zu verarbeitende XML-Dokument bestimmt, welches Template wann verwendet wird (dokumentgetriebene Verarbeitung)
  - das Stylesheet legt fest, wie anschließend die Knoten des XML-Baums durchwandert werden
    - Standardverhalten: Knoten werden in Dokumentreihenfolge verarbeitet
  - abhängig vom aktuellen Knoten wird ein passendes Template ausgewählt und ausgeführt

XSLT-Beispiel

- Gegeben ist eine XML-Datei, die in eine HTML-Datei transformiert werden soll.
  - die XML-Datei enthält nur ein Element *name* mit dem ein Begrüßungstext festgelegt wird

```
<?xml version="1.0" ?>
<name>
  Hans Müller
</name>
```

```
<html>
  <body>
    <h1>
      Hallo
      <font color="blue">
        Hans Müller!
      </font>
    </h1>
  </body>
</html>
```

XSLT-Beispiel

- das zugehörige XSLT-Stylesheet, das die Transformation beschreibt, sieht wie folgt aus:

```
<?xml version="1.0" ?>
<xsl:stylesheet version="1.0" xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
  <xsl:output method="html"/>
  <xsl:template match="/">
    <html>
      <body>
        <h1>
          Hallo
          <font color="blue">
            <xsl:value-of select="name"/>!
          </font>
        </h1>
      </body>
    </html>
  </xsl:template>
</xsl:stylesheet>
```

  - jede XSLT-Datei beginnt mit der üblichen XML-Deklaration
  - danach folgt das Wurzelelement (immer *xsl:stylesheet*) mit Versionsnummer und Angabe zum Namensraum *xsl*
  - das Format der Zieldatei wird mit dem Element *xsl:output* festgelegt
    - mögliche Formate: xml, html, text

XSLT-Beispiel

```
<?xml version="1.0" ?>
<xsl:stylesheet version="1.0" xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
  <xsl:output method="html"/>
  <xsl:template match="/">
    <html>
      <body>
        <h1>
          Hallo
          <font color="blue">
            <xsl:value-of select="name"/>!
          </font>
        </h1>
      </body>
    </html>
  </xsl:template>
</xsl:stylesheet>
```

- die Beschreibung der eigentlichen Transformation folgt im Anschluss in Form eines Templates
  - das Attribut **match** enthält einen XPath-Ausdruck, der festlegt, für welche Knoten des XML-Dokuments das Template gelten soll
  - hier handelt es sich also um ein Template für den Dokumentknoten
  - relative XPath-Ausdrücke innerhalb des Template-Rumpfs beziehen sich auf den ausgewählten XML-Knoten

XSLT-Beispiel

```
<?xml version="1.0" ?>
<xsl:stylesheet version="1.0" xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
  <xsl:output method="html"/>
  <xsl:template match="/">
    <html>
      <body>
        <h1>
          Hallo
          <font color="blue">
            <xsl:value-of select="name"/>!
          </font>
        </h1>
      </body>
    </html>
  </xsl:template>
</xsl:stylesheet>
```

- der Rumpf des Templates enthält das, was in der Zieldatei bei Verarbeitung des ausgewählten Knotens eingefügt werden soll
  - Text und XML-Elemente, die nicht zum XSL-Namensraum gehören, werden unverändert in das Ausgabedokument kopiert
  - <xsl:value-of select="name"/> konvertiert das *name*-Element in einen String, d.h. der Text im Elementrumpf wird ausgegeben
  - das Attribut **select** enthält einen XPath-Ausdruck relativ zum aktuellen Kontextknoten (hier also "/")

Aufruf des XSLT-Prozessors

- **Aufruf im Web-Browser**
  - die meisten Web-Browser besitzen einen integrierten XSLT-Prozessor
  - in der zu transformierenden XML-Datei muss hinter der XML-Deklaration folgende Zeile hinzugefügt werden:
    ```
    <?xml-stylesheet type="text/xsl"
                     href="stylesheet.xsl"?>
    ```
  - beim Öffnen der XML-Datei im Browser wird sie mit dem angegebenen Stylesheet transformiert und das Resultat angezeigt

```
<?xml version="1.0" ?>
<?xml-stylesheet type="text/xsl" href="gruss.xsl"?>

<gruss>
  Hans Müller
</gruss>
```

XSLT-Beispiel

- nun soll das Format der XML-Datei so erweitert werden, dass mehrere Namen abgelegt werden können:

```
<?xml version="1.0"?>
<namen>
  <name>Jim Panse</name>
  <name>Anna Konda</name>
  <name>Bernhard Diener</name>
</namen>
```

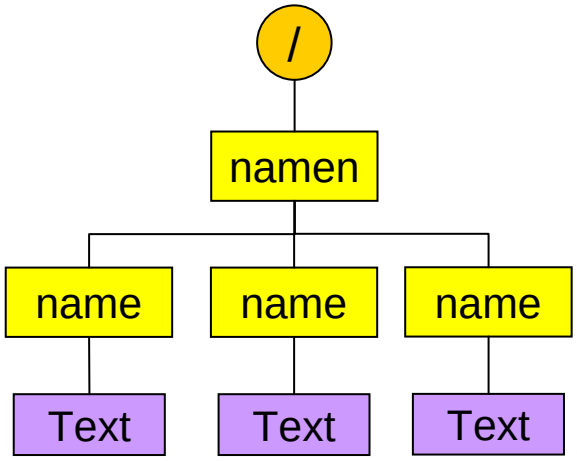

- jeder Name soll wie im vorangegangenen Beispiel transformiert werden
  - vor jedem Namen soll "Hallo" stehen
  - jeder Name soll in blauer Schrift ausgegeben werden

  → man muss dafür sorgen, dass für jedes *name*-Element der gleiche HTML-Ausschnitt erzeugt wird

  → Lösung: das *name*-Element bekommt sein eigenes Template

XSLT-Templates

```
<xsl:template match="name">
  <h1>
    Hallo
    <font color="blue">
      <xsl:value-of select="."/>!
    </font>
  </h1>
</xsl:template>
```

- dieses Template wird immer dann automatisch angewendet, wenn ein *gruss*-Element transformiert werden soll

- da sich das Element `xsl:value-of` hier im Kontext von *gruss* befindet, kann zur Ausgabe des *gruss*-Rumpfes jetzt `select="."` geschrieben werden (oder alternativ: `select="text()"`)
- das Template für den Dokumentknoten sieht nun so aus:

```
<xsl:template match="/">
  <html>
    <body>
      <xsl:apply-templates/>
    </body>
  </html>
</xsl:template>
```

- `<xsl:apply-templates/>` weist den XSLT-Prozessor an, die Verarbeitung des XML-Dokuments bei den Kindknoten (hier das *gruesse*-Element) fortzusetzen
- ohne Aufruf von `apply-templates` findet keine Verarbeitung der Kindknoten statt

XSLT-Templates

```
<xsl:template match="/">
  <html>
    <body>
      <xsl:apply-templates/>
    </body>
  </html>
</xsl:template>
```

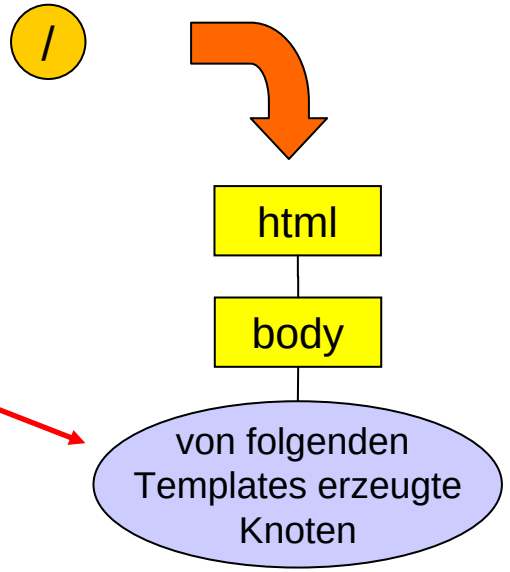


```
<xsl:template match="gruss">
  <h1>
    Gruß des Tages:
    <font color="blue">
      <xsl:value-of select="."/>
    </font>
  </h1>
</xsl:template>
```

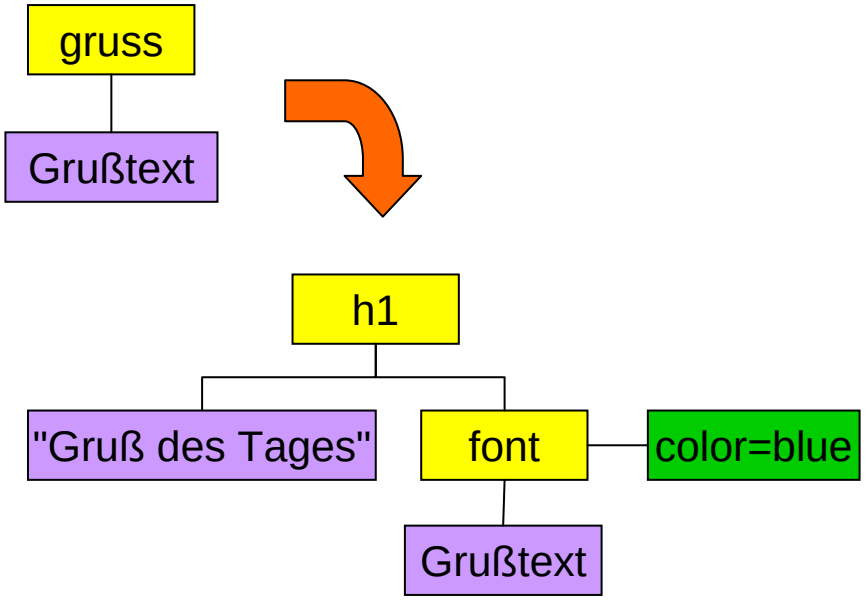

Standard-Templates

- Wenn der XSLT-Prozessor im Stylesheet kein passendes Template für einen Knoten findet, verwendet er eines der vordefinierten **Standard-Templates**:
  - Dokument- und Elementknoten
    - setzt die Verarbeitung bei den Kindknoten fort
      Achtung: Attributknoten liegen nicht auf der *child*-Achse
  - Attributknoten
    - gib den Attributwert aus
  - Textknoten
    - gib den Text aus
  - Kommentarknoten
    - keine Aktion

Standard-Templates von XSLT

```
<xsl:template match="/">
  <xsl:apply-templates/>
</xsl:template>

<xsl:template match="*">
  <xsl:apply-templates/>
</xsl:template>

<xsl:template match="@*">
  <xsl:value-of select="."/>
</xsl:template>

<xsl:template match="text()">
  <xsl:value-of select="."/>
</xsl:template>

<xsl:template match="comment()"/>
```

Push-Processing

- durch den wiederholten Aufruf von *apply-templates* werden die Knoten des XML-Dokuments sukzessive von der Wurzel bis zu den Blättern verarbeitet
  - nicht das Stylesheet sondern das XML-Dokument bestimmt die Reihenfolge der Verarbeitung
  - diese Art der rekursiven Verarbeitung wird **Push-Processing** genannt

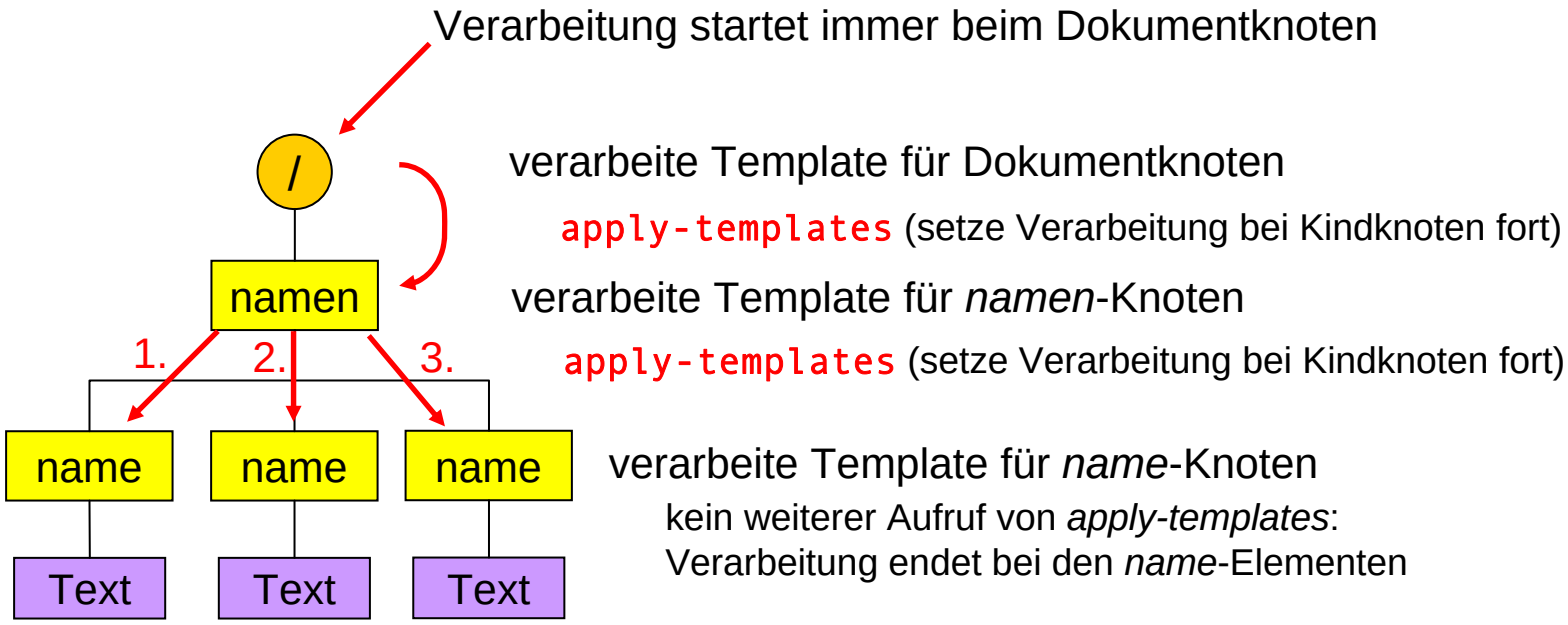

Push-Processing

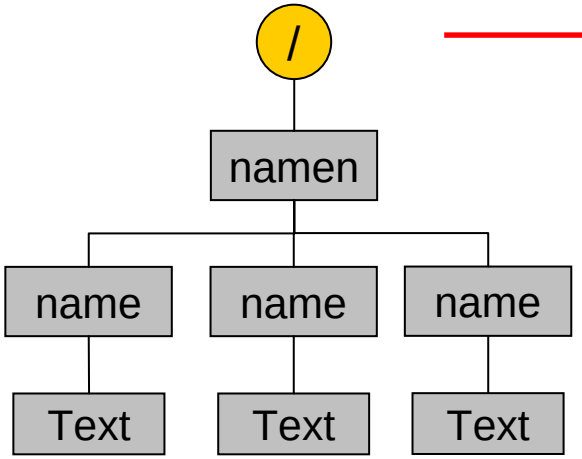

eigenes Template für /

```
<xsl:template match="/">
  <html>
    <body>
      <xsl:apply-templates/>
    </body>
  </html>
</xsl:template>
```

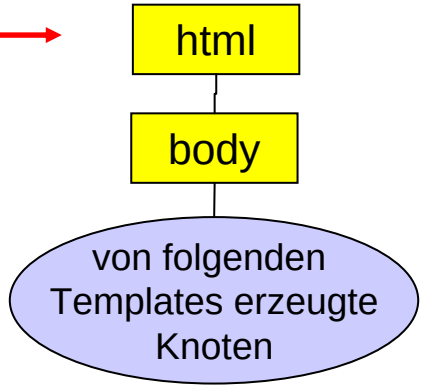

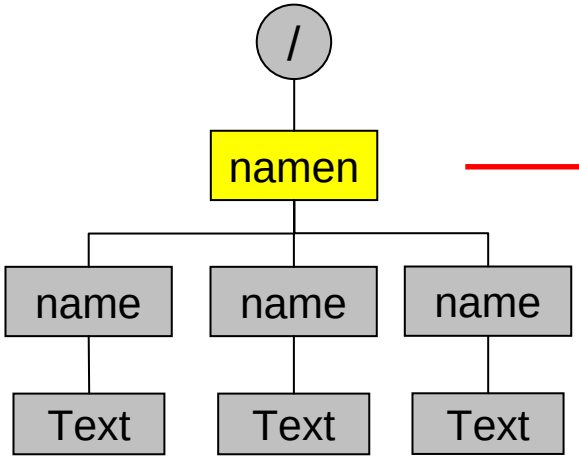

Standard-Template für Elemente
(Matching bei Kindknoten fortsetzen)

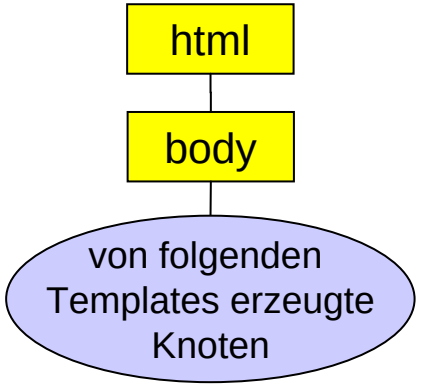

Push-Processing

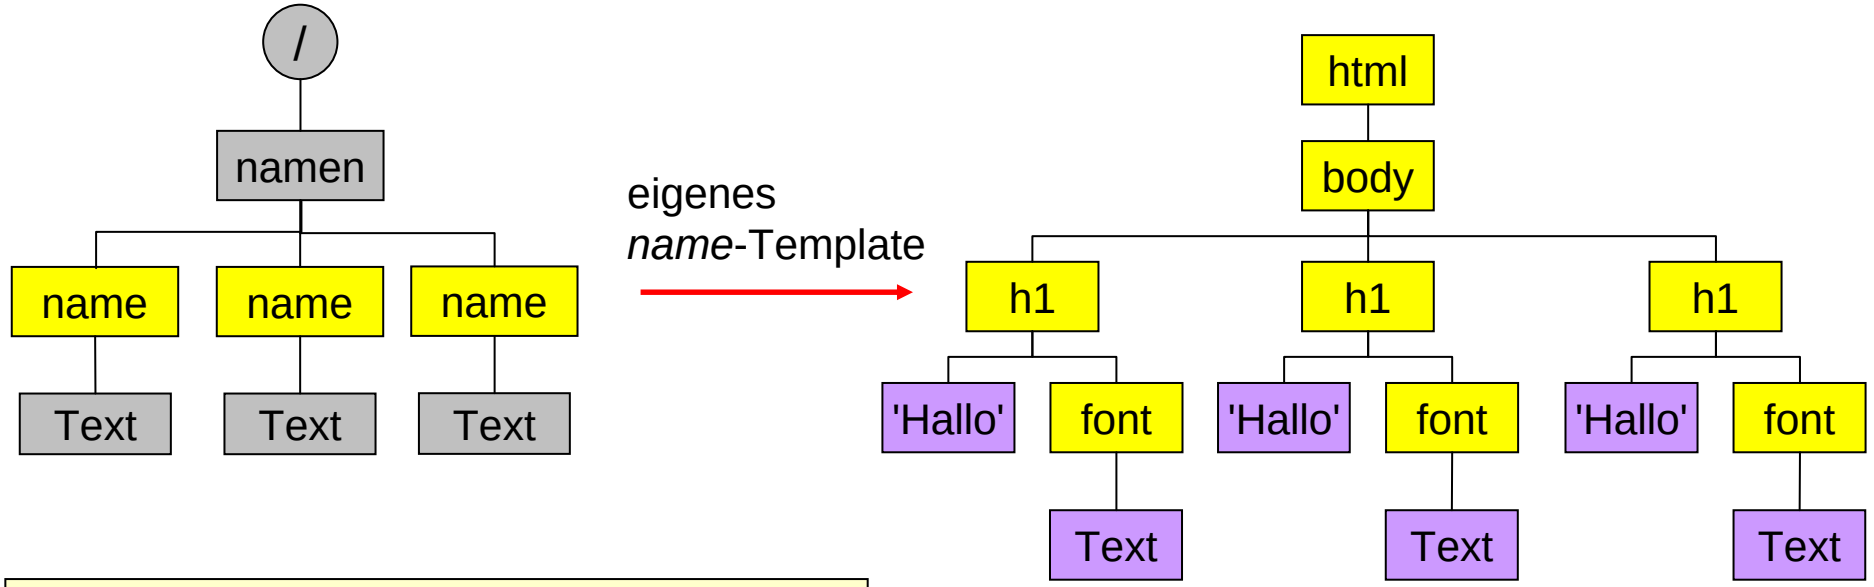


```
<xsl:template match="name">
  <h1>
    Hallo
    <font color="blue">
      <xsl:value-of select="."/>!
    </font>
  </h1>
</xsl:template>
```

Push-Processing

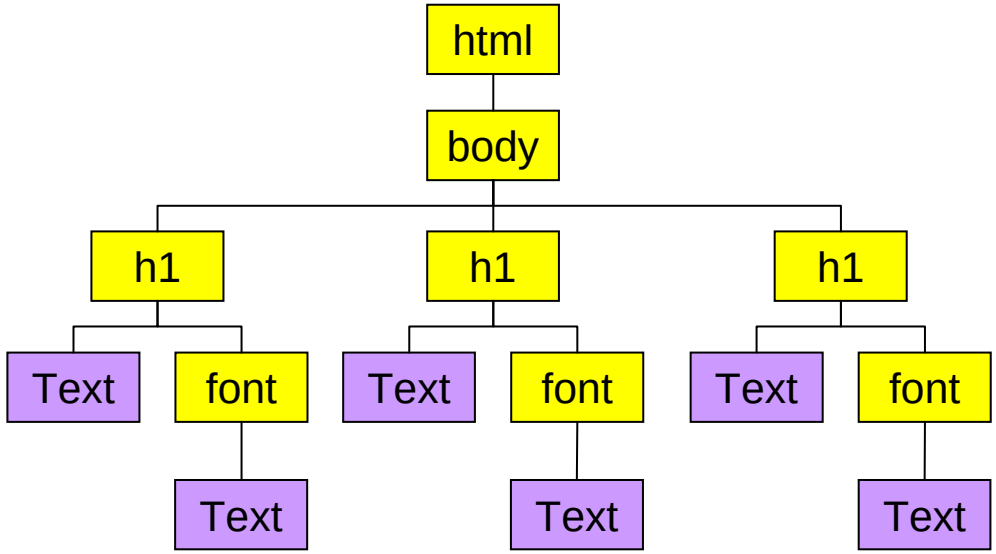


```
<html>
  <body>
    <h1>Hallo <font color="blue">Jim Panse!</font></h1>
    <h1>Hallo <font color="blue">Anna Konda</font></h1>
    <h1>Hallo <font color="blue">Bernhard Diener</font></h1>
  </body>
</html>
```

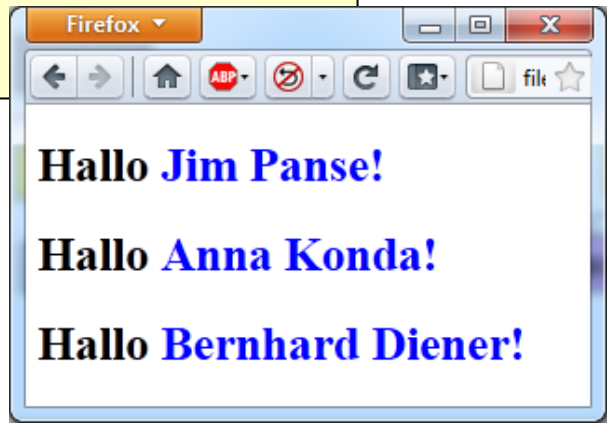

XSLT-Templates

- nun sollen folgende Konstruktionen möglich sein:

```
<?xml version="1.0"?>
<namen>
  <name farbe="green">Anna Konda</name>
  <name>Bernhard <kursiv>Diener</kursiv></name>
</namen>
```

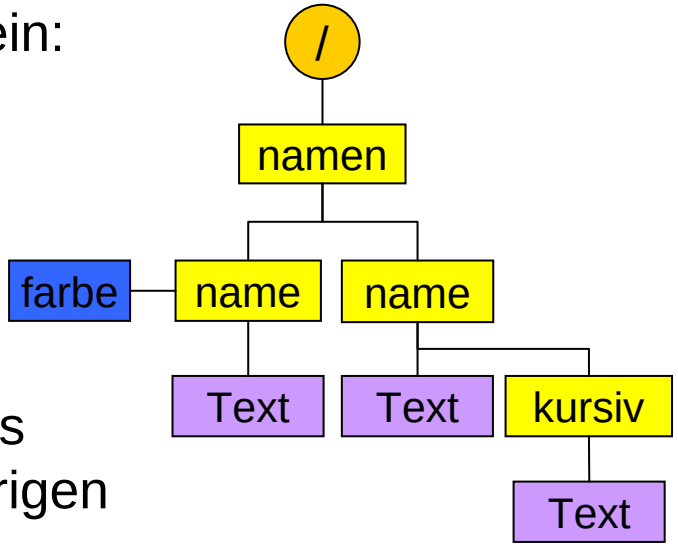

- das Attribut *farbe* soll die Farbe des Grußtextes festlegen; das Element *kursiv* soll den zugehörigen Text kursiv darstellen
- das "/"-Template bleibt unverändert, der Rest sieht wie folgt aus:

```
<xsl:template match="gruss">
  Gruß des Tages:
  <font color="{@farbe}">
    <xsl:apply-templates/>
  </font>
</xsl:template>

<xsl:template match="kursiv">
  <i>
    <xsl:value-of select="."/>
  </i>
</xsl:template>
```

- da `xsl:value-of` innerhalb von Attributwerten nicht verwendet werden kann, gibt es für diesen Fall die Variante {...}
  - das Ergebnis des in Klammern stehenden XPath-Ausdrucks wird in einen String umgewandelt und an der angegebenen Stelle eingefügt

XSLT-Templates

```
<xsl:template match="gruss">
  Gruß des Tages:
  <font color="{@farbe}">
    <xsl:apply-templates/>
  </font>
</xsl:template>

<xsl:template match="kursiv">
  <i>
    <xsl:value-of select="."/>
  </i>
</xsl:template>
```

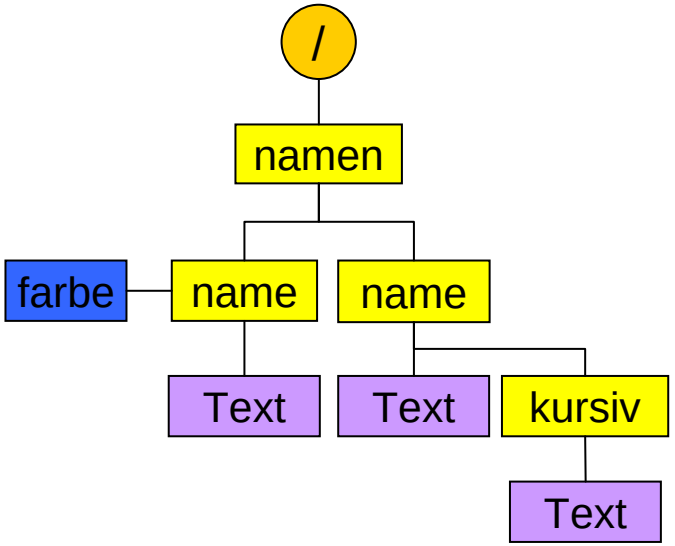

- *xsl:apply-templates* sorgt hier dafür, dass die Verarbeitung bei den Kindknoten der *name*-Elemente fortgesetzt wird
  - wird ein Textknoten gefunden, greift das Standard-Template für `text()` und gibt den Text aus
  - wird ein *kursiv*-Element gefunden, wird das selbst definierte *kursiv*-Template ausgeführt
    - dieses erzeugt ein *i*-Element mit darin enthaltenem Text aus dem *kursiv*-Element der XML-Datei