Attribut-Konventionen und Normierungsregeln

xml:lang, xml:space

Zeilenenden, Attributwerte

Perspektivwechsel

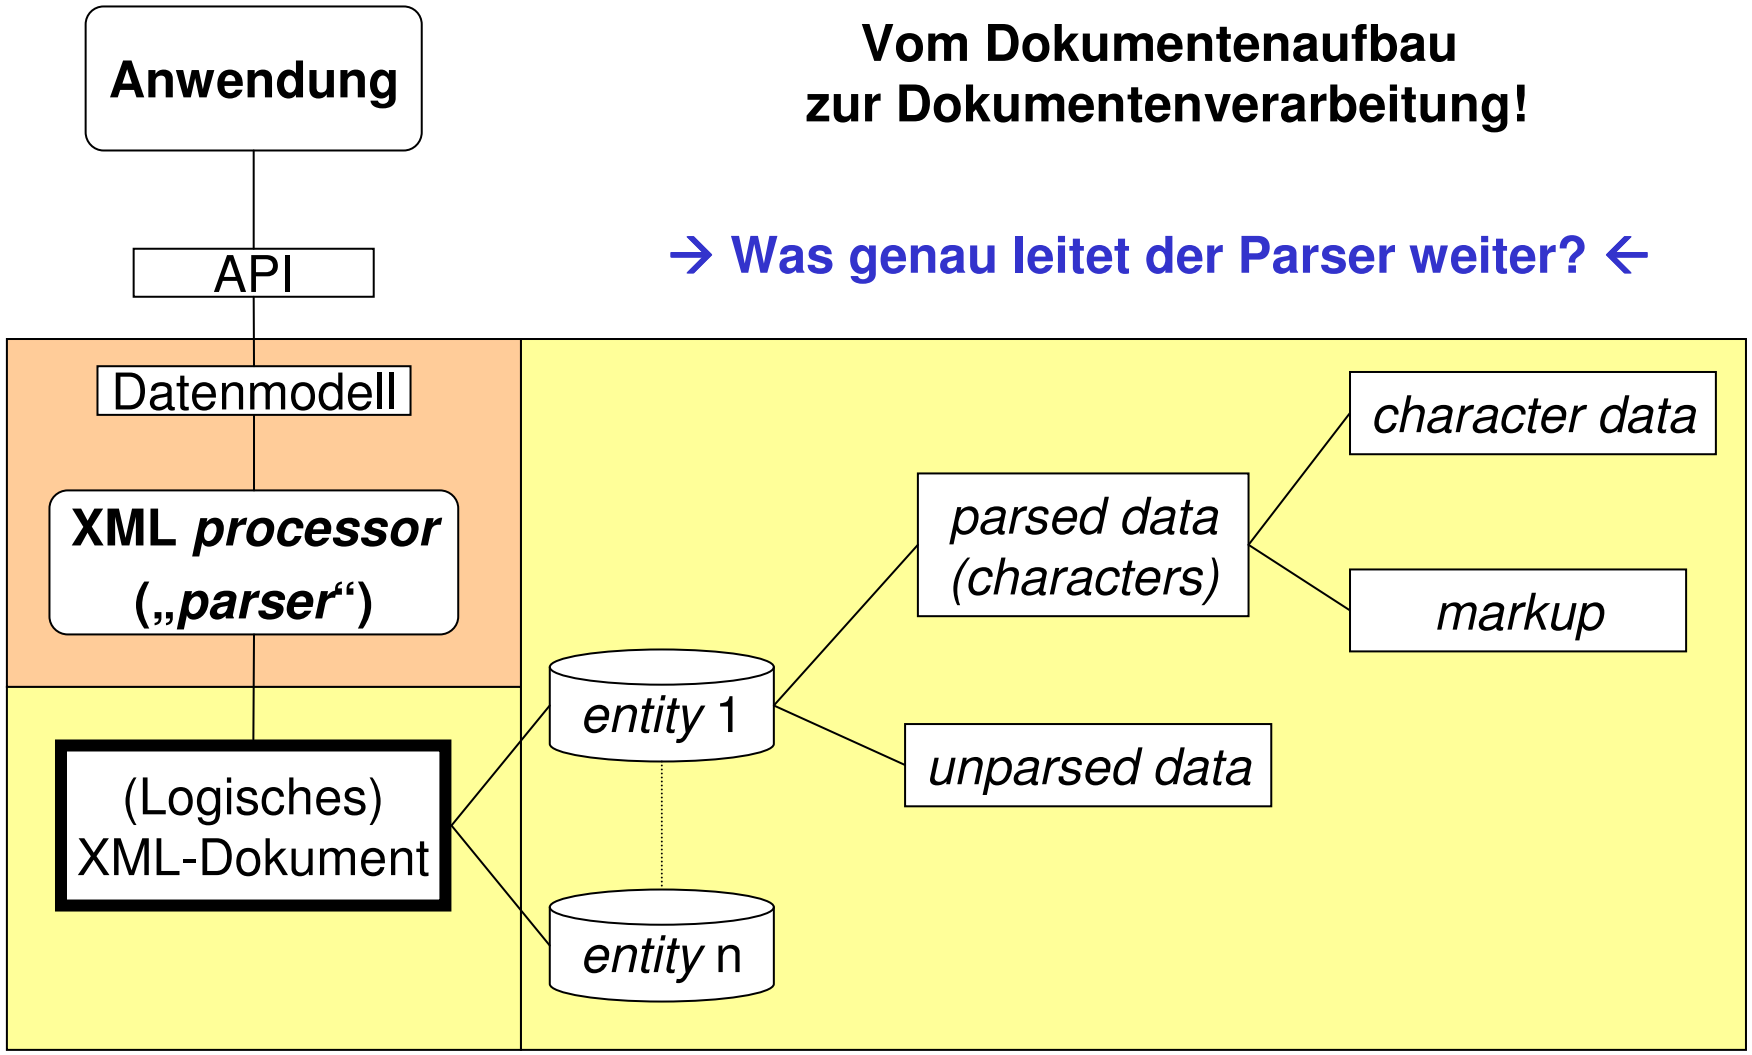

Vom Dokumentenaufbau zur Dokumentenverarbeitung!

→ Was genau leitet der Parser weiter? ←

Attribut-Konventionen - xml:lang

- Zur Kennzeichnung der Sprache eines Elementinhalts sollte folgendes Standardverfahren eingehalten werden. Beispiel:

```
<p xml:lang="en">The quick brown fox jumps over the
    lazy dog.</p>
<p xml:lang="en-GB">What colour is it?</p>
<p xml:lang="en-US">What color is it?</p>
<sp who="Faust" desc='leise' xml:lang="de">
  <l>Habe nun, ach! Philosophie,</l>
  <l>Juristerei, und Medizin</l>
  <l>und leider auch Theologie</l>
  <l>durchaus studiert mit heißem Bemüh'n.</l>
</sp>
```

- Zur Konvention, die das reservierte Attribut „xml:lang“ verwendet, gehört ein Vererbungskonzept: Sprachschlüsselwerte vererben sich implizit vom definierenden Element auf alle Kind-Elemente, bis dass sie von einem lokalen Wert überschrieben werden.

Attribut-Konventionen - xml:lang

- „Gültige“ XML-Dokumente müssen das reservierte Attribut xml:lang in allen Elementen, die es verwenden, normal deklarieren.

- „xml:lang“ lässt zwar nur bestimmte Sprach- bzw. Länder-Codes zu (Details: Siehe XML 1.0, Kap. 2.12), aber diese müssen nicht explizit - etwa per NOTATION – deklariert werden, sondern verstehen sich als Teil der Konvention.
- Beispiel für eine einfache Deklaration:

```
xml:lang CDATA #IMPLIED
```

- Vollständiges Beispiel:

```
<!ATTLIST poem   xml:lang CDATA 'fr'>
<!ATTLIST gloss  xml:lang CDATA 'en'>
<!ATTLIST note   xml:lang CDATA 'en'>
```

  – Im Beispiel wird ein Gedicht in französischer Sprache unterstellt, das Ergänzungen/Anmerkungen in Englisch erhalten soll. Daher verwendet die DTD kontextabhängig *default*-Werte für xml:lang.

Attribut-Konventionen - xml:space

- Das Problem:
  - Grundsätzlich müssen XML-Prozessoren alle Zeichen, die nicht *markup* sind, an die Anwendung weiterreichen.
  - Validierende *Parser* müssen darüber hinaus der Anwendung mitteilen, welche Zeichen eines Elementinhalts *white space* sind (!).
  - Andererseits verwenden XML-Autoren gerne *white space* nur zur besseren Lesbarkeit der XML-Rohdaten.
  - **Wie kann man nun „*significant white space*“ (z.B. in Gedichten) von diesem unterscheiden?**

- Der Lösungsansatz:
  - Per Konvention wird das Attribut **xml:space** zu dieser Unterscheidung eingeführt.
  - Es kann nur die Werte „*default*“ und „*preserve*“ annehmen.
  - Dieses Attribut ist ein Signal an die Anwendung - nicht an den *Parser*!
  - Für xml:space gilt eine Vererbungsregel analog zu xml:lang.

Attribut-Konventionen - xml:space

- Deklaration
  - „Gültige“ XML-Dokumente müssen das reservierte Attribut xml:space in allen Elementen, die es verwenden, normal deklarieren.

- Beispiele:

```
<!ATTLIST poem xml:space
          (default|preserve) 'preserve'>
<!ATTLIST pre  xml:space
          (preserve) #FIXED 'preserve'>
```

Normierungsregeln

… für Zeilenenden

… für Attributwerte

Normierungsregeln für Zeilenenden

- Situation:
  - Verschiedene Betriebssysteme verwenden unterschiedliche Konventionen zur Kennzeichnung von Zeilenumbrüchen

    (DOS/Windows: (#xD, #xA); Unix: nur #xA, MacOS 9, OS/9: nur #xD,

    IBM Mainframe: #xD, #x85 bzw. #x85; Unicode: #x2028).
- Ziel
  - XML-basierte Anwendungen sollen unabhängig von der Herkunft der XML-Dokumente arbeiten können.
- Lösung:
  - XML 1.0 legt fest, dass XML-Prozessoren alle *external parsed entities* noch vor Beginn des *parsing* wie folgt normiert:

    Jede 2-Zeichen Sequenz #xD #xA wird umgesetzt in ein #xA

    Jedes #xD, das nicht direkt von einem #xA gefolgt wird, wird ersetzt durch ein #xA.
  - D.h. beim Einlesen werden alle Zeilenenden auf den Unix-Standard normiert.

Normierungsregeln für Attributwerte

- Situation:
  - *White space* in Attributwerten kann
    - Bedeutungsträger sein (CDATA),
    - zur *Token*-Bildung benötigt werden (bei Listentypen wie NMTOKENS),
    - nur der besseren Lesbarkeit halber eingegeben worden sein,
    - schlicht die Anwendung stören, zu vielfältig oder gar ungültig sein.
- Ziele:
  - Die Prüfung auf Einhaltung der deklarierten Attributtypen soll möglichst einfach erfolgen können.
  - Die Anwendung soll nur „signifikante“ Leerzeichen erhalten.
- Lösungsansatz:
  - *White space* in Attributwerten wird vor der Validierung und Weiterleitung an die Anwendung vom XML Prozessor kontextabhängig normiert.

Normierungsregeln: Attributwerte

- **Der Normierungsalgorithmus für Attributwerte**:
  1) Zeilenenden werden als bereits normiert vorausgesetzt (s.o.).
  2) Die Normierung eines Attributwerts beginnt mit einem leeren String
  3) Für jedes Zeichen, *entity reference*, oder *char reference* im noch nicht normierten Attributwert:
     a) Falls *char reference*:
        Leite das Ersetzungszeichen weiter (expandiere).
     b) Falls *entity reference*:
        Expandiere, wende Regel (3) rekursiv auf den Ersetzungstext an.
     c) Falls *white space*-Zeichen:
        Leite ein *space char* (Leerzeichen, #x20) weiter.
     d) Falls ein anderes Zeichen:
        Leite das Zeichen unverändert weiter.
- Anschließend - falls das Attribut nicht vom Typ CDATA ist:
  – Entferne führende und endende Leerzeichen (*leading & trailing blanks*).
  – Ersetze Leerzeichenketten durch einzelne Leerzeichen.

Normierungsregeln: Attributwerte

- Beispiele (vgl. Kap. 3.3.3 der XML 1.0-Spezifikationen)
  - Vorbereitende *entity*-Deklarationen:

```
<!ENTITY d  "&#xD;">
<!ENTITY a  "&#xA;">
<!ENTITY da "&#xD;&#xA;">
```

- Attributspezifikation 1:

```
att="

  x y z"
```

  - Normiert, NMTOKENS: `x y z`
  - Normiert, CDATA: `#x20 #x20 x y z`
- Attributspezifikation 2:

```
att="&d;&d;A&a;&#x20;&a;B&da"
```

  - Normiert, NMTOKENS: `A #x20 B`
  - Normiert, CDATA: `#x20 #x20 A #x20 #x20 #x20 B #x20 #x20`
- Attributspezifikation 3:

```
att=
"&#xd;&#xd;A&#xa;&#xa;B&#xd;&#xa;"
```

  - Normiert, NMTOKENS: `#xD #xD A #xA #xA B #xD #xA`
  - Normiert, CDATA: `#xD #xD A #xA #xA B #xD #xA`

Normierungsregeln: Attributwerte

- Bemerkungen zu Fall 1 …:
  - Die beiden Leerzeilen zu Beginn des Attributwertes wurden gemäß (3c) in #x20-Zeichen umgewandelt.
  - Da diese zu Beginn stehen, wurden sie im Fall NMTOKENS schließlich ganz entfernt

- … zu Fall 2 …:
  - Die *entity references* auf *char references* von *white space* wurden rekursiv aufgelöst: (3b), (3a), (3c) und in #x20-Zeichen umgewandelt.
  - Im Fall NMTOKENS wurden die zu Beginn und am Ende ganz entfernt und die drei mittleren zu einem zusammengefasst.

- … und zu Fall 3:
  - Ersatzzeichen der *char references* wurden gemäß (3a) weitergereicht.
  - Da diese *white space*, aber keine Leerzeichen sind, griff die letzte Regel nicht.
  - Anmerkungen aus den Spezifikationen:
    Fall NMTOKENS ist wohlgeformt, aber nicht gültig!

Abschließendes kleines Beispiel eines XML-Dokuments mit DTD

Einleitendes Beispiel-Dokument

```
<Dozent>
    <Name>
        <Vorname MI= 'W'>Heinz</Vorname>
        <Nachname Titel="Dr">Werntges</Nachname>
    </Name>
    <Beschäftigungsverhältnis Art="Prof"/>
</Dozent>
```

- Aufgabe:
  - Nun zu vervollständigen um Prolog und insbesondere um eine DTD.
  - Ziel: Validierung ermöglichen.

Einleitendes Beispiel-Dokument

```
<?xml version="1.0" encoding="ISO-8859-1" standalone="yes"?>
<!DOCTYPE Dozent [
   <!ELEMENT Dozent (Name, Beschäftigungsverhältnis)>
   <!ELEMENT Name (Vorname, Nachname)>
   <!ELEMENT Vorname (#PCDATA)>
   <!ELEMENT Nachname (#PCDATA)>
   <!ELEMENT Beschäftigungsverhältnis EMPTY>
   <!ATTLIST Beschäftigungsverhältnis
        Art (LB | Prof | Stud) #REQUIRED>
   <!ATTLIST Nachname Titel NMTOKEN #IMPLIED>
   <!ATTLIST Vorname MI
(A|B|C|D|E|F|G|H|I|J|K|L|M|N|O|P|Q|R|S|T|U|V|W|X|Y|Z|Ä|Ö|Ü) # IMPLIED>
]> <!-- Hier endet der hinzugefügte Prolog -->
<Dozent>
   <Name>
        <Vorname MI= 'W'>Heinz</Vorname>
        <Nachname Titel="Dr">Werntges</Nachname>
   </Name>
   <Beschäftigungsverhältnis Art="Prof"/>
</Dozent>
```

Nachwort zu XML 1.0

- Errata zu 1.0
  - Die 2006-Ausgabe von XML 1.0 enthält bereits alle früheren Errata.
  - Neue „Errata“ sollten ggf. herangezogen werden, wenn man
    einen Fehler in den Spezifikationen vermutet
    sich ein Parserverhalten partout nicht erklären kann.

- XML 1.1
  - Alle Errata aus 1.0 sind berücksichtigt
  - Berücksichtigt Änderungen zwischen Unicode 2.0 und 4.0/5.0
  - Flexibler in den Regeln zu *Name(s)* und *Nmtoken(s)*
  - Änderungen bei Steuerzeichen (neue kommen hinzu), aber auch:
  - Nicht abwärtskompatibel bez. Zeichen #x7F - #x9F (umstritten!)
  - Normierung der Zeilenenden verallgemeinert: #x85, #x2028 neu

Anhang

Markup-Übersicht

XML *literals*

Markup: Übersicht nach Erscheinungsbild

„Nicht-essenzielle“ *markup*-Arten:

`<!-- … -->`

Kommentar

`<?…?>`

XML-Deklaration, Text-Deklaration, PI (*processing instruction*)

`<![`*`NAME`*`[ … ]]>`

Besondere Code-Abschnitte; *NAME* ∈ {CDATA, INCLUDE, IGNORE}

Kern der XML-*Markups*:

`<name attr="value"> … </name>, <name attr='value'/>`

Elemente und Attribute

`<!DOCTYPE docname … [ … ] >`

Dokumententyp-Deklaration (hier: *root element* heißt „docname“)

`<!`*`NAME`*` … >`

Markup-Deklarationen. Einzelfälle:

NAME ∈ {ENTITY, ELEMENT, ATTLIST, NOTATION}

XML *literals*

```
[9] EntityValue ::= '"' ([^%&"] | PEReference | Reference)* '"' |
                    "'" ([^%&'] | PEReference | Reference)* "'"

[10] AttValue ::= '"' ([^<&"] | Reference)* '"' |
                  "'" ([^<&'] | Reference)* "'"

[11] SystemLiteral ::= ('"' [^"]* '"') | ("'" [^']* "'")

[12] PubidLiteral ::=      '"' PubidChar* '"' |
                  "'" (PubidChar - "'")* "'"

[13] PubidChar ::=  #x20 | #xD | #xA | [a-zA-Z0-9] |
                    [-'()+,./:=?;!*#@$_%]
```

- *Literals* sind Strings (ohne die *quotation marks*)
- Sie werden verwendet als
  - Inhalte interner *entities (EntityValue),*
  - Attributwerte (*AttValue*)
  - Externe *identifier (SystemLiteral, PubidLiteral)*
- Man beachte die Doppel-Beschreibung für die beiden *quotation marks!*

XML *literals*

- Bemerkungen:
  - *Entities* werden mit **&** oder **%** eingeleitet, daher sollten ihre Werte mit diesen Zeichen gerade nicht beginnen.
  - Attributwerte sollten weder wie ein *tag* (**<**) noch wie ein *entity ref.* (**&**) anfangen.
  - *System literals* dürfen aus allem bestehen, nur nicht aus dem jeweils verwendeten *quotation mark* selbst.
  - *Public ID literals* lassen andere Zeichen zu als *name tokens*. Das wird verständlich, wenn man sich z.B. URLs darunter vorstellt.
  - Die Definition von *PubidLiteral* ist bez. der beiden *quotation marks* nur deshalb asymmetrisch, weil nur eines der beiden (‘) in der Menge der explizit erlaubten *PubidChar*-Zeichen auftaucht - daher Sonderbehandlung!