# XML 1.0 - Die Spezifikation

Schrittweise Erarbeitung
Kommentare und Beispiele



## XML 1.0 - die Spezifikation

- Terminologie
  - XML 1.0 verwendet einige Begriffe in bestimmter Art und Weise. Bitte von deren umgangssprachlichen Gebrauch ggf. unterscheiden!
  - Begriffe/Ausdrücke mit präzisierter Bedeutung:
    - *may, must, error, fatal error, at user option*
    - *validity constraint, well-formedness constraint*
    - *match*
    - *for compatibility, for interoperability*
  - Bem.: Diese Liste hier soll nur sensibilisieren für reservierte Begriffe. Definitionen ggf. direkt in den Spezifikationen nachlesen.

## XML 1.0 - die Spezifikation

- Einschub: Zur Methodik
  - Die nächsten Abschnitte gehen deduktiv vor, denn
  - wir benötigen erst einmal ein formales Rüstzeug, um die Bestandteile von XML präzise beschreiben zu können.
  - Damit wird dann klar werden, was genau in XML erlaubt ist.
  - Zahlreiche Parserfehler liegen in Verletzungen von XML-Regeln begründet, die ohne deren genaue Kenntnis sehr schwer zu beseitigen sind.
  - Ist diese „Durststrecke“ erst überwunden, läßt sich mit XML-Dokumenten umso leichter arbeiten.
  - Früh eingeführte, aber erst später definierte Begriffe dienen der Systematik und dem späteren Nachschlagen der Zusammenhänge. Also: Nicht wundern, wenn sie zunächst nicht verständlich sind.
  - Bei Gefahr des „Verdurstens“ bitte mit Fragen unterbrechen!



## XML-Dokumente: Aufbau

- Datenobjekt
  - XML-Dokument, wenn „wohlgeformt“ im Sinne der XML 1.0 Spezifikationen
  - „gültiges“ XML-Dokument, wenn zusätzlich konsistent mit deklarierter DTD
- XML-Dokument
  - Physischer Aufbau:
    - *Entities*
  - Logischer Aufbau (Bestandteile):
    - Deklarationen
    - Elemente
    - Kommentare
    - *character references*
    - *processing instructions (PI)*

# XML-Dokumente: Aufbau

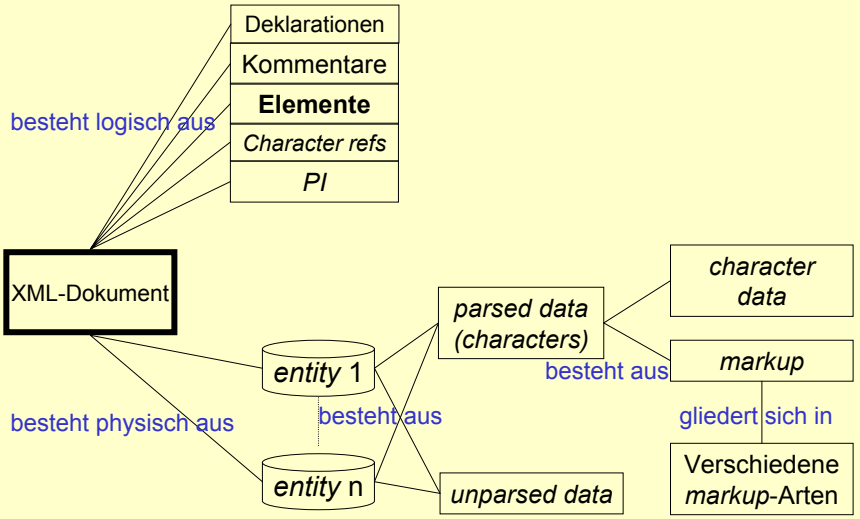




# XML-Dokumente: *Markup*-Arten

- XML-Dokument
  - *Markup*
  - *character data* (der „Rest“)
- *Markup*-Arten
  - ***Tags**: start-tags, end tags, empty-element tags*
  - ***References**: Entity refs., character refs.*
  - ***Comments***
  - *CDATA section delimiters*
  - ***Declarations**: document type, element, attribute, entity, notation, text, XML decl.*
  - ***Processing instructions***
  - *White space* außerhalb des *(vor dem) root element*

- Bemerkungen
  - Die nebenstehende Liste aller *markup*-Arten wird im Folgenden nach und nach vorgestellt.
  - Interessant ist hier ihre Vollständigkeit. Letztlich sollte man jede *markup*-Art kennengelernt haben.
  - Die Liste dient als Leitfaden durch die spezifschen Abschnitte
  - Man mache sich klar, dass wirklich jedes Zeichen, das nicht *markup* ist, irgendwo als *character data* auftauchen muss - z.B. auch Zeilenumbrüche!

# Grundlagen und erste Regeln der XML 1.0-Spezifikation

Tags und Referenzen

Unicode und zulässige Zeichen in XML





## Regeln?

Beispiele:

1. `<Beispiel>Hallo zusammen!</Beispiel>`

2. `<#Beispiel >`
   `Hallo zusammen!`
   `</#Beispiel >`

3. `< Beispiel Sprachschlüssel = "DE" >`
   `Hallo zusammen!`
   `< /Beispiel>`

**Alles zulässig? Ggf: Wirkung?**

XML benötigt präzise Regeln!

## Die Spezifikationsregeln

- Die XML 1.0 Spezifikationen sind in Form von **89 Regeln** („*productions*“) formal präzisiert.
  - Die formale Grammatik von XML wird in einer einfachen „*Extended Backus-Naur Form“ (EBNF*) beschrieben.
  - Die Notation ist in Abschnitt 6 am Ende der Spezifikationen definiert.
- Genereller Aufbau:

  [n] *symbol ::= expression*
- Besonderheiten
  - Die Regeln werden durchnummeriert ([n]).
  - Symbole, die den Ausgangspunkt einer „regulären Sprache“ bilden, fangen mit Großbuchstaben an.
  - *literal strings are quoted*



## Die Spezifikationsregeln

- Regeln für „*tags*“:

```
[40] STag  ::=
     '<' Name (S Attribute)* S? '>'

[41] Attribute ::= Name Eq AttValue

[42] ETag  ::= '</' Name S? '>'

[44] EmptyElemTag  ::=
     '<' Name (S Attribute)* S? '/>'
     [WFC: Unique Att Spec]
[25] Eq    ::= S? '=' S?
```

## Die Spezifikationsregeln

- Also sind folgende *tags* korrekt:
  - `<Beispiel>,`
  - `<Beispiel >,`
  - `<Beispiel key = "value" >,`
  - `</Beispiel >` `# OK`
- aber jene sind FALSCH:
  - `< Beispiel>,`
  - `</ Beispiel>,`
  - `< /Beispiel>,`
  - `< / Beispiel>` `# FALSCH!`
- Noch zu klären:
  - Regeln für: `S, Name, AttValue`





# Einschub: Unicode

… und andere Zeichensätze

## Vorbereitung: Zeichensatz-Angaben

- XML 1.0 basiert auf Unicode/ISO10646. Daher werden konkrete Zeichen (*characters*) grundsätzlich über ihre Unicode-IDs (USC-4) spezifiziert. (Vergleiche dazu die Vorübung.)

- Der numerische ID-Wert eines Zeichens wird - meist in hexadezimaler Form - wie folgt angegeben:
  #xN
- mit N stellvertretend für eine beliebige Folge hexadezimaler Ziffern
  - Hexadezimal-Ziffern sind 0, 1, …, 9, A, B, C, D, E, F
  - Führende Nullen sind nicht signifikant u. dürfen ausgelassen werden.
- Beispiel:
  Der Buchstabe „A“ läßt sich z.B. wie folgt angeben:
  - `#x41, #x0041, #65, #0065, …`



## Unicode

- Informationen:
  - http://czyborra.com/
    - zu Zeichensätzen allgemein, insb. ISO-8859-*x*
  - http://www.unicode.org/
    - Speziell zu Unicode
- Beispiel: Buchstabe „ü“
  - Codepage 437 (DOS): 0x81
  - ISO-8859-1: 0xFC
  - Unicode (composite): U+00FC
  - Unicode (combining): U+0075, U+0308
  - Unicode, UTF-8 (s.u.): U+00FC = 0xC3, 0xBC

## Unicode: Zeichenarten

- Basiszeichen
  - Unser normales Verständnis eines Zeichens
- Ideographische Zeichen
  - z.B. fernöstliche wie Kanji-Zeichen
- *combining characters*
  - „Pünktchen“, Akzentzeichen u.a.
  - Sie ergeben zusammen mit ihrem jeweiligen Vorläuferzeichen in einem String das endgültige Symbol
  - Beispiel: à = a`
  - Diese Zeichenkombinationen ergänzen die bereits vorhandenen Spezialzeichen
  - Die Kombinationsmethode schafft mit relativ wenigen Unicode-Einträgen eine große Vielfalt an möglichen Symbolen.
- *extenders*
  - (Unicode-Spezialthema, hier nicht behandelt)



## Unicode: Codierungen

- UCS-4:
  - Die allgemeine 4-Byte-Angabe: U+dddddddd
- UTF-8, UTF-16, UTF-32
- Unterscheidung im Fall UTF-16:
  - *high-endian* vs. *low-endian* mittels Sonderzeichen xFEFF
- UTF-8 Codierung:

```
U+00000000 – U+0000007F  0xxxxxxx
U+00000080 – U+000007FF  110xxxxx  10xxxxxx
U+00000800 – U+0000FFFF  1110xxxx  10xxxxxx  10xxxxxx
U+00010000 – U+001FFFFF  11110xxx (10xxxxxx)3
U+00200000 – U+03FFFFFF  111110xx (10xxxxxx)4
U+04000000 – U+7FFFFFFF  1111110x (10xxxxxx)5
```

  - 1 bis 6 Oktets pro Unicode-Zeichen (31 bits), niemals xFE oder xFF.
  - Stets klar, ob Folgebyte vorliegt und wieviele Folgebytes notwendig!

## Zulässige Zeichen in XML allgemein

- **XML 1.0:**

```
[2]  Char ::= #x9 | #xA | #xD | [#x20-#xD7FF]
       | [#xE000-#xFFFD] | [#x10000-#x10FFFF]
         /* any Unicode character, excluding the
            surrogate blocks, FFFE, and FFFF. */
```

  – Beachte: NICHT alle Unicode-Zeichen!

- **XML 1.1:**

```
[2]  Char ::= #x9 | #xA | #xD | [#x20-#x7E]
       | #x85 | [#xA0-#xD7FF] |
       [#xE000-#xFFFD] | [#x10000-#x10FFFF]
         /* any Unicode character, excluding most ISO
            controls, the surrogate blocks, FFFE,
            and FFFF. */
```

  – Beachte: NICHT voll abwärtskompatibel zu XML 1.0!



## Notationen – zum Nachlesen…

| | |
|---|---|
| `#xN` | Einfaches Zeichen |
| `[a-zA-Z], [#xN-#xN]` | Zeichenbereiche und ... |
| `[abc], [#xN#xN#xN]` | … Zeichenlisten<br>(Listen und Bereiche sind mischbar). |
| `[^a-z], [^#xN-#xN]` | Auszuschließende Zeichenbereiche |
| `"string", 'string'` | Konstante Strings |
| `(expression)` | Klammerung von Ausdrücken |
| `A B` | Ausdruck A gefolgt von B |
| `A \| B` | A oder B |
| `A - B` | A ohne B (Mengendifferenz) |
| `A?` | String passt höchstens einmal zu A |
| `A+` | String passt ein- oder mehrmals zu A |
| `A*` | String passt beliebig oft zu A |
| `/* … */` | Kommentar (in der Grammatik) |
| `[wfc: …], [vc: …]` | *Well-formedness or validity constraint* |

# …zurück zur Klärung der Regeln…





## *White Space*

- XML 1.0:

```
[3]  S ::= (#x20 | #x9 | #xD | #xA)+
```

  - Also: Beliebige Zeichenfolgen aus *blank, form feed* (FF), *carriage return* (CR) oder *line feed* (LF)

- XML 1.1:
  - Vermutlich Erweiterung um #x85 (IBM: NEL) und #x2028 (Unicode *line separator char*)
  - Bem.: CR-Phase lief am 28.2.03 aus…

## XML names, name tokens

- Einschränkung bei der Namenswahl:
  - XML fordert die Einhaltung bestimmter Regeln bei der Vergabe von z.B. Element- und Attributnamen.

```
[5]  Name ::=
     (Letter | '_' | ':') (NameChar)*

[4]  NameChar ::=
                Letter | Digit |
                '.' | '-' | '_' | ':' |
                CombiningChar | Extender

[6]  Names ::= Name (#x20 Name)*
     /* #x20: Beachte errata in [6] */
```



## XML names, name tokens

- Noch zu klären
  - `Letter, Digit, CombiningChar, Extender`
  - `AttValue (!!)`
- Dazu: Ein Blick in die Spezifikation!

## XML names, name tokens

- Achtung - Neues Konzept bei **XML 1.1:**

```
[5]  Name  ::=
     NameStartChar NameChar*

[4]  NameStartChar ::= ":" | [A-Z] | "_"|
  [a-z] | [#xC0-#x2FF] | [#x370-#x37D] |
  [#x37F-#x1FFF] | [#x200C-#x200D] |
  [#x2070-#x218F] | [#x2C00-#x2FEF] |
  [#x3001-#xD7FF] | [#xF900-#xEFFFF]


[4a] NameChar ::=
  NameStartChar | '-' | '.' | [0-9] |
  #xB7 | [#x0300-#x036F] | [#x203F-
  #x2040]
```



## XML names, name tokens

```
[7]  Nmtoken  ::= (NameChar)+/* XML 1.0 */
[7]  Nmtoken  ::= NameChar+  /* XML 1.1 */

[8]  Nmtokens  ::= Nmtoken (#x20 Nmtoken)*
```

- Bemerkungen
  - *names* fangen also immer mit einem „Buchstaben“, _ oder Doppelpunkt an.
  - *name tokens* unterliegen diesen Einschränkungen nicht.
  - Namen, die mit (‘x‘|‘X‘) (‘m‘|‘M‘) (‘l‘|‘L‘) beginnen, sind von XML reserviert (z.B. xml, Xml, xML, XML, …)
  - Der Doppelpunkt ist i.d.R. für XML-interne Zwecke reserviert - meiden!

## *XML names:* Beispiele

```
<myElem myAttr = 'value'> … </myElem>
```

**korrekt**

```
<myElem:1><myElem:2>…</myElem:2></myElem:1>
```

Doppelpunkt im Namen - möglichst NICHT verwenden

```
<XML-Basis>hier mein Text zu diesem
  Inhalt…</XML-Basis>
```

Verletzung der Reservierungsregel - „XML“ am Anfang des Elementnamens

```
<_myElem -myAttr = '…'> … </_myElem>
```

Attributname fängt mit einem unzulässigen Zeichen an

```
<_myElem my-Attr = '…'> … </_myElem>
```

**korrekt**

```
<myElem my#Attr = '…'> … </myElem>
```

‚#‘ ist kein erlaubtes Zeichen in einem *name*





# *Markup*: Referenzen

Zeichenreferenzen
(*character references*)

*(general) entity references*

## Character references

- Zeichenreferenzen (*char. references*):
  - Eine Methode zur Einbettung beliebiger (einzelner) Zeichen unter ausschließlicher Verwendung der ASCII-Codierung.
  - Ansatz: Angabe entweder des dezimalen oder des hexadezimalen Unicode-Wertes, eingebettet in speziellen XML *markup:*

```
[66] CharRef ::=
              '&#' [0-9]+ ';' |
              '&#x' [0-9a-fA-F]+ ';'
              [WFC: Legal Character]
```



## Character references

- Beispiel:

```
<someText>
  &#x41;&#x0042;&#099;&#100;        /* ABcd */
</someText>
```

- Bemerkungen
  - Angaben entweder in dezimaler oder in hexadezimaler Notation – binär oder oktal sind nicht zulässig.
  - Hex-Darstellung: Kleine wie große Ziffern-Buchstaben sind zulässig.
  - WFC - *Well-formedness constraint*:
    - Gemeint ist hier, dass das derart referenzierte Zeichen aus der Menge der in Regel [2] beschriebenen „Char“ stammt.
    - Andere Zeichen führen zum Parser-Abbruch (*fatal error*)!

## Entity references

- *Entity*-Referenzen:
  - Eine Methode zur Einbettung beliebiger Zeichenfolgen.
  - Expansion durch Parser, analog zu Makros
  - Kaskadierbar (aber ohne Rekursion)

```
[68] EntityRef ::= '&' Name ';'
                   [WFC: Legal Character]
                   [VC:  Entity Declared]
                   [WFC: Parsed Entity]
                   [WFC: No Recursion]
```

- Beispiel:

```
<par>Dieser Text entstand am &heute; im
  Auftrag der Firma &Kunde;.</par>
```



## Vordefinierte *general entities*

- Das Problem:
  - XML *parser* erkennen *markup* anhand bestimmter Zeichen (siehe die CharData-Definition)
  - Was tun, wenn eines dieser Zeichen als normales Textzeichen verwendet werden soll? Insbesondere gilt das für: **<**, **>**, **&**, **'**, und **"**
- Die simple Lösung:
  - Codierung über *character references*.
- Die elegantere Lösung:
  - Zugriff über symbolische Namen in „*entity references*“.

## Vordefinierte *general entities*

- XML kennt 4 bereits vordefinierte *entities*:
  amp, lt, gt, apos, quot
- Verwendung per Referenz:

| | |
|---|---|
| `&` | & |
| `<` und `>` | < und > |
| `&apos;` und `&quot;` | ' und " |

- Beispiel: A < B & C > B

```
<myTag>
  A &lt; B &amp; C &gt; B
</myTag>
```



## *General entities*

- Wunsch:
  - Ganze Symboltabellen, also Listen gängiger Unicode-Spezialzeichen, per *char. ref.* spezifiziert), deren Einträge einfach per *entity reference* verwendbar sind.
  - Möglichkeit, eigene *entities* wie „`heute`“ oder „`Kunde`“ einzuführen.
- Dazu notwendig:
  - Regeln zur Deklaration von *entities*
  - Methoden zur Einbindung externer Dateien
- Nächstes Kapitel!