XML Information Set

http://www.w3.org/TR/xml-infoset

XML Information Set

Übersicht

Begriffsbildung, Beispiel

Item Properties

Beispiel, Was nicht enthalten ist

Einordnung: XML Infoset, XPath

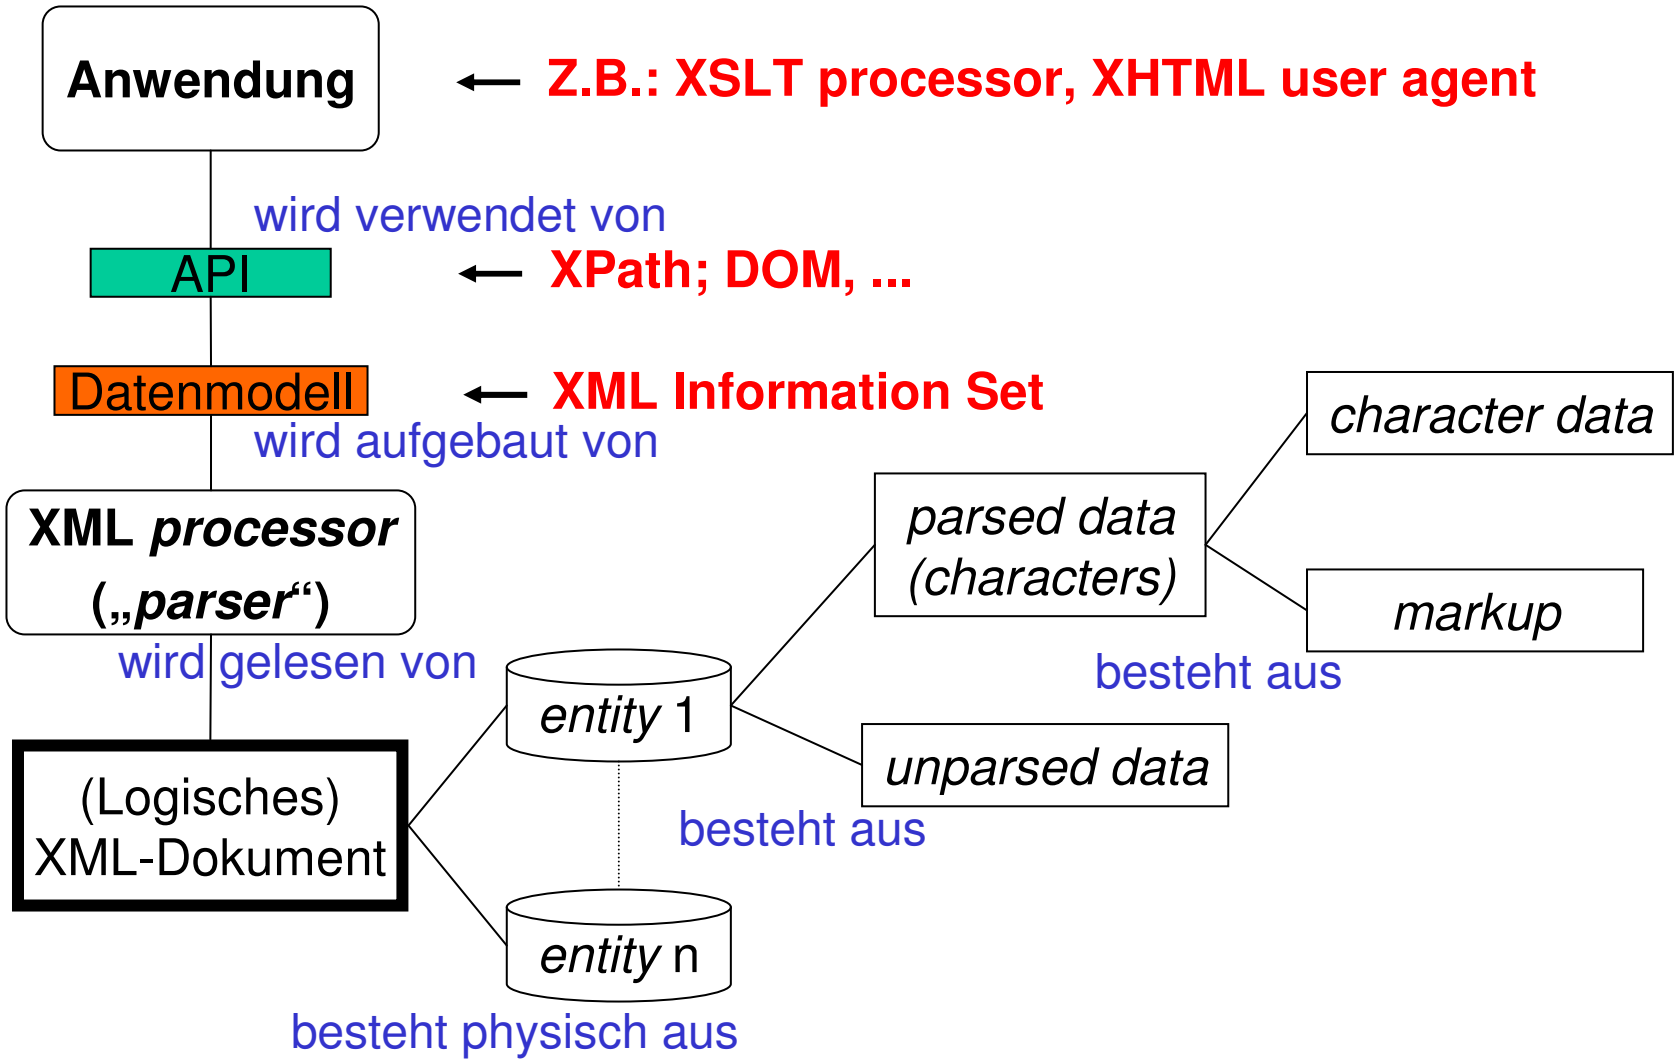

XML Infoset

- **Was ist XML Information Set?**
  - Die Spezifikation abstrakter Datenstrukturen, die den Anwendungen zugänglichen Inhalt von wohlgeformten (nicht unbedingt auch „gültigen“) XML-Dokumenten beschreiben.
  - Eine formale Beschreibung des „Outputs“ von XML-Prozessoren
  - Eine abstrakte Sicht, unabhängig von spezifischen APIs
  - Wie bei W3C üblich: Eine Empfehlung
- **Was ist ein XML Infoset?**
  - Meistens: Eine baumartige Repräsentation eines XML-Dokuments.
  - Auch: Eine künstlich generierte Datenstruktur ohne zugrundeliegendes XML-Dokument, die den Spezifikationen von XML Information Set genügt.
- **Was ist XML Infoset nicht?**
  - Erschöpfend (im Sinne aller Informationen eines XML-Dokuments)
  - Eine Minimalanforderung an den Output von XML-Prozessoren.

XML Infoset

- **Entwicklung von XML Information Set**
  - Quelle: W3C
  - Status: Empfehlung (REC)
  - Dokumentation: http://www.w3.org/TR/xml-infoset
  - Stand:

    2001-10-24 1. Auflage

    2004-02-04 2. Auflage, berücksichtigt XML 1.1 und Namespaces 1.1

XML Infoset

Erinnerung - allgemein gilt:

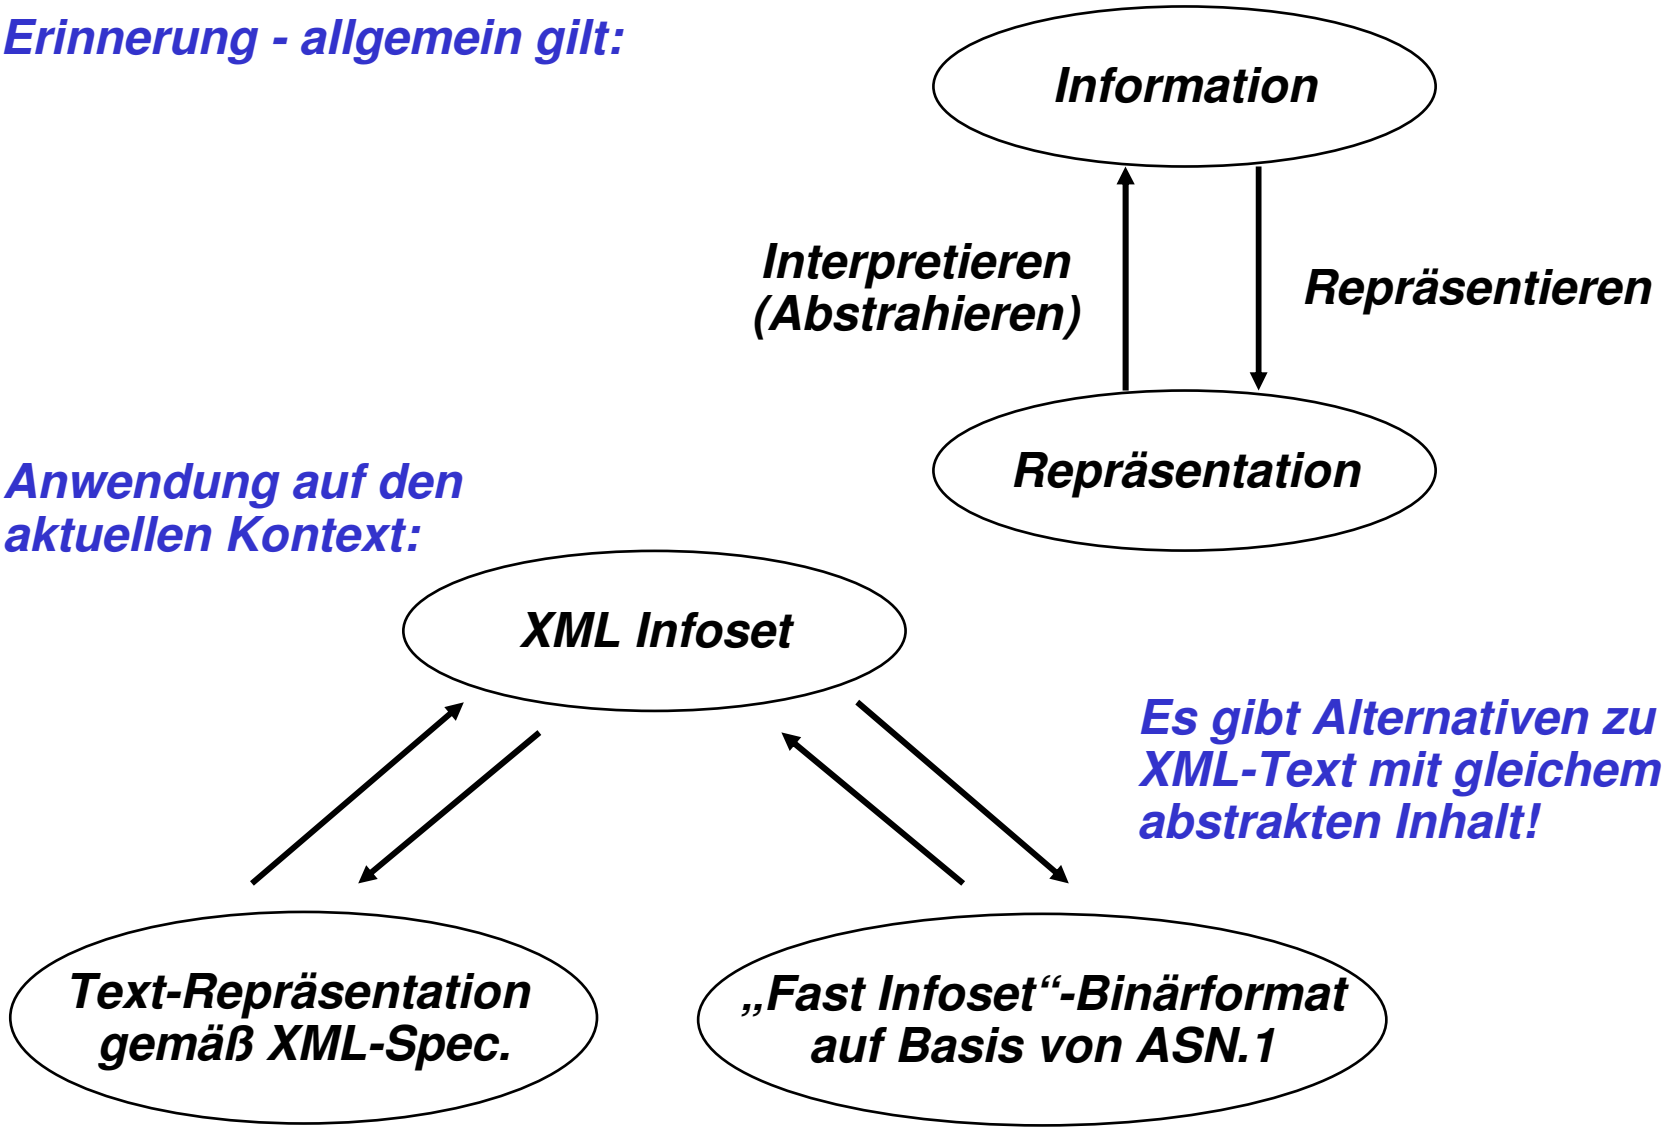

Anwendung auf den aktuellen Kontext:

Es gibt Alternativen zu XML-Text mit gleichem abstrakten Inhalt!

XML Infoset

- **Begriffsbildung**
  - ***Information set*** (Informationssatz)

    Entspricht einem Datenbaum (*tree*)

    Enthält genau ein *document item* und weitere *information items*.
  - ***Information item*** (Ein Element des Infosatzes)

    Entspricht einem Knoten (*node*) in diesem Baum

    Enthält „Eigenschaften“ (*properties*), z.B. Listen weiterer *info items.*
  - Die Begriffe *tree* und *node* wurden vermieden, um zu betonen, dass Zugriffe auf den *information set* auch über andere Schnittstellen als baumartige erfolgen können, z.B. ereignisgesteuerte (*event-based*) oder anfrageartige (*query-based*).
- **Vorsicht:**
  - Elemente des Infosatzes lassen sich **nicht** 1:1 identifizieren mit Knoten des DOM oder Knoten bzw. Teilbäumen von XPath (obwohl dies auf weiten Strecken sehr wohl möglich ist).

XML Infoset

- **Unterscheide folgende Werte von Eigenschaften voneinander:**
  - *„unbekannt“ (unknown)*
  - *„kein Wert“ (no value)*
  - Leere Zeichenkette / Liste / Menge

- **Bemerkungen**
  - Einem Attributwert kann die leere Zeichenkette zugewiesen werden. Dies ist ein anderer Inhalt als das Ausbleiben jeglicher Zuweisung!
  - In anderen Notationen werden die Schlüsselwörter „null“ oder „nil“ verwendet. Dies vermeidet die XML Infoset-Spezifikation, um Verwechslungen vorzubeugen, jedoch besteht konzeptionell eine enge Verwandtschaft.

XML Infoset: *Information items*

- **Übersicht: Typen von *Information Items***
  - *Document*
  - *Element*
  - *Attribute*
  - *Unexpanded entity reference*
  - *Character*
  - *Comment*
  - *Processing instruction*
  - *Notation*
  - *Unparsed entity reference*
  - *Namespace*

XML Infoset: Beispiel 1

- Ein einfaches XHTML 1.1-Beispiel

```
<?xml version="1.0" encoding="iso-8859-1" ?>
<!DOCTYPE html PUBLIC "-//W3C//DTD XHTML 1.1//EN"
  "http://www.w3.org/TR/xhtml11/DTD/xhtml11.dtd">
<?xml-stylesheet href="hello.css" type="text/css"?>
<html
  xmlns="http://www.w3.org/1999/xhtml" xml:lang="de">
  <head>
    <title>Kleines XHTML-Beispiel</title>
  </head>
  <body>
    <p>Hallo, Welt!</p>
    <!-- Kommentar: Hier ergänzen! -->
  </body>
</html>
```

Ein Ordnungsansatz mit Graphen

- XML-Dokumente:
  - Markierte (attributierte), baumartige Graphen
  - Besitzen verschiedene Knotentypen:

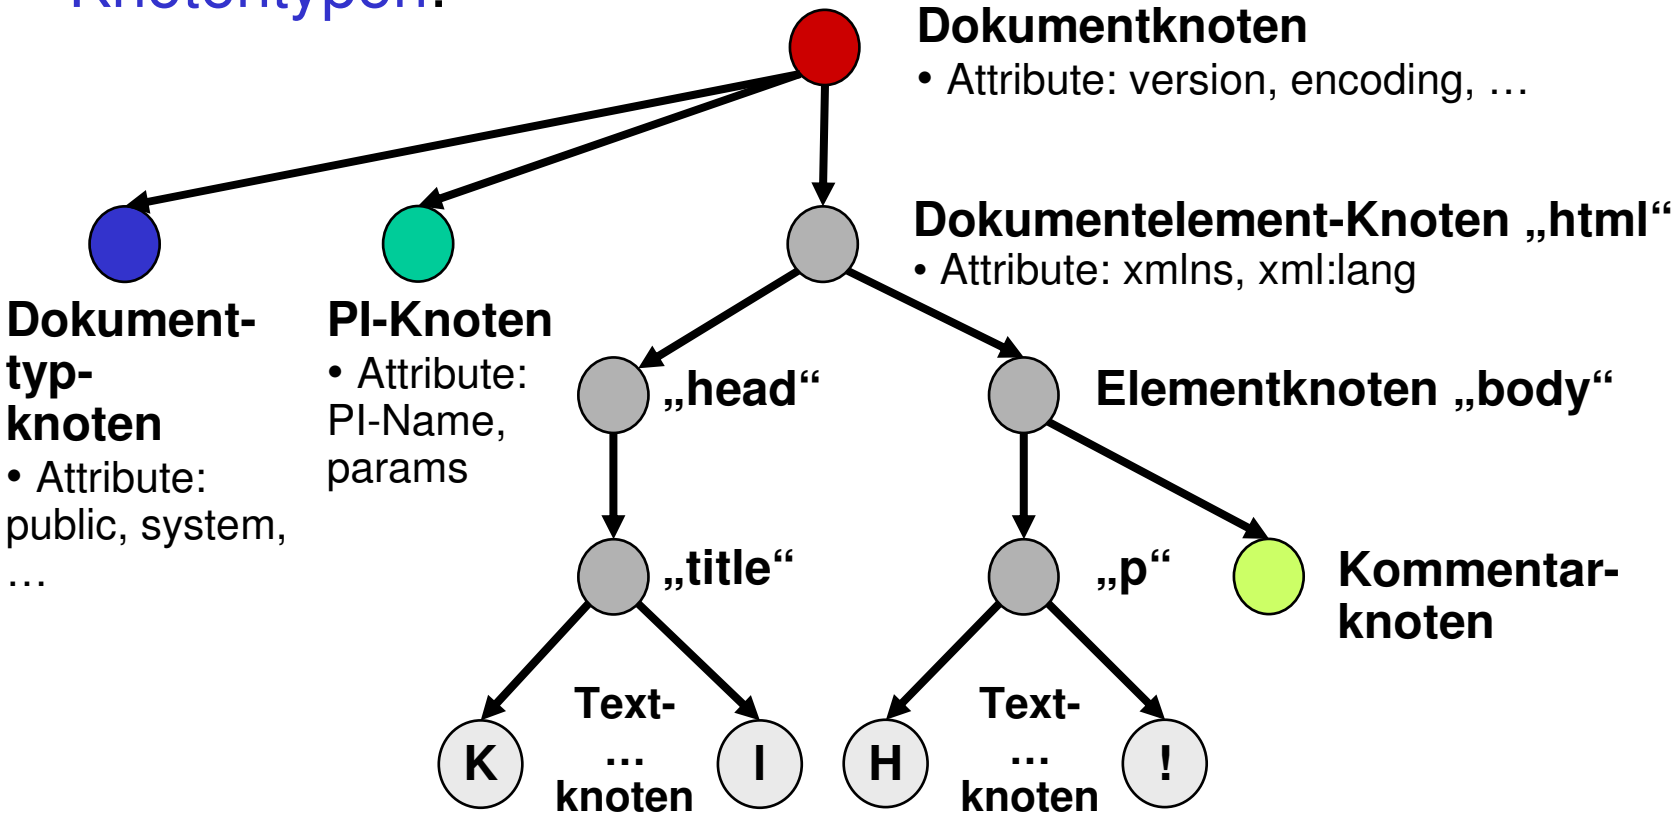

XML Infoset: Beispiel 2

- **Beispiel:**

Anschreiben!

```
<?xml version="1.0"?>
<msg:message doc:date="19990421"
    xmlns:doc="http://doc.example.org/namespaces/doc"
    xmlns:msg="http://message.example.org/">
  Phone home!
</msg:message>
```

erzeugt folgendes XML Infoset:

- Ein `document` *information item*
- Ein `element` *info item*
- Ein `attribute` *info item*
- Drei `namespace` *info items*
- Zwei `attribute` *info items,* für die 2 *namespace*-Attribute
- Elf `character` *info items,* für Zeichenkette „`Phone home!`“

XML Infoset: *Item Properties*

- **Document Information Item**

  - ***children***

    Eine geordnete Liste, in Dokumentenreihenfolge

    Optional ein *document type declaration info item*

    Genau ein *element info item*

    Ein *PI info item* pro Vorkommen außerhalb des Dokumentenelements (Vorkommen innerhalb der DTD sind ausgenommen).

  - ***document element***

    Das *element info item*, entspricht dem Dok.element.

  - ***notations***

    Eine (ungeordnete) Menge von *notation info items*, je eins pro NOTATION-Deklaration in der DTD.

XML Infoset: *Item Properties*

- **Document Information Item** (Forts.)
  - ***unparsed entities***

    Eine (ungeordnete) Menge von *unparsed entity info items*, je eins pro nicht vom Parser aufgelöster ENTITY-Deklaration in der DTD.
  - ***base URI***

    Base URI der *document entity*.
  - ***character encoding scheme***

    Der Name des *encoding*-Schemas, das dem *document entity* zugrunde liegt. Stammt aus der XML-Deklaration
  - ***standalone***

    Der Wert der *standalone*-Deklaration aus der XML-Deklaration, entweder „*yes*“ oder „*no*“. Optional, „kein Wert“ wenn fehlt.

XML Infoset: *Item Properties*

- **Document Information Item** (Forts.)

  - ***version***

    Der Wert der *version*-Anweisung aus der XML-Deklaration. Optional, „kein Wert“ wenn fehlt.

  - ***all declarations processed***

    Ein boolescher Wert, der nicht aus dem XML-Dokument selbst stammt, sondern anzeigt, ob der XML-Prozessor alle Deklarationen verarbeitet hat. Zwingend ist dies nur validierenden Parsern vorgeschrieben.

XML Infoset

- Document info item **D1**:
  - children = (**E1**)
  - document element = **E1**
  - notations = (kein Wert)
  - unparsed entities = (kein Wert)
  - base URI = „file://…“ // irgendeine passende Quelle
  - character encoding scheme = „UTF-8“ // oder (kein Wert) ?
  - standalone = (kein Wert)
  - version = „1.0“
  - all declarations processed = true

XML Infoset: *Item Properties*

- **Element Information Item**

  - ***namespace name***

    Der Name des Namensraums dieses Elements. Optional.

  - ***local name***

    Der Name des Elementtyps, ohne *namespace*-Präfix und Doppelpunkt.

  - ***prefix***

    Das *namespace*-Präfix des Elementtyp-Namens. Optional.

    Bem.: Anwendungen, die *namespaces* unterstützen, sollten die Namensraum-Namen statt der Prafixwerte verwenden.

XML Infoset: *Item Properties*

- **Element Information Item (Forts.)**
  - ***children***

    Eine (eventuell leere) geordnete Liste, in Dokumentenreihenfolge

    Enthaltene *Info items* sind vom Typ:

    element

    processing instruction

    unexpanded entity reference

    character

    comment
  - ***attributes***

    Eine (ungeordnete, ggf. leere) Menge von *attribute info items*, die entweder aus dem Element oder per *default*-Deklaration aus der DTD stammen.

XML Infoset: *Item Properties*

- **Element Information Item (Forts.)**

  - ***namespace attributes***

    Eine (ungeordnete, ggf. leere) Menge von *attribute info items*, je eins pro *namespace*-Deklaration aus dem Element oder per *default*-Deklaration aus der DTD.

    Per Definition lautet das *namespace* URI aller *namespace*-Attribute „http://www.w3.org/2000/xmlns“, auch die ohne Präfix („xmlns=…“)

  - base URI

    Base URI des Elements.

  - parent

    Der *document* bzw. *element info item*, dessen *children*-Liste den vorliegenden Eintrag enthält.

XML Infoset: *Item Properties*

- **Element Information Item (Forts.)**
  - ***in-scope namespaces***

    Eine (ungeordnete) Menge von *namespace info items*, je eins für jeden Namensraum, der auf dieses Element wirkt.

    Sie enthält immer einen Eintrag mit Präfix „`xml`“, der dem Namensraum „`http://www.w3.org/1998/namespace`“ implizit zugeordnet ist (→ Vorlesungseinheit zu Namensräumen).

    Sie enthält nie einen Eintrag mit Präfix „`xmlns`“, denn eine Anwendung kann nie auf ein Element oder Attribut mit diesem Präfix stoßen.

    Sie enthält je einen Eintrag, der dem aus der Liste zu „*namespace attributes*“ stammt - mit folgender Ausnahme: Einträge zu Deklarationen der Form „`xmlns:''`“, welchen den *default*-Namensraum „ent-deklarieren“.

    Bemerkung: Zur Auflösung von Präfixwerten sollte diese Menge Vorrang haben vor der Verwendung von „*namespace attributes*“, da letztere Probleme erzeugen können bei künstlich generierten Infosets.

XML Infoset

- Element info item **E1**:
  - namespace name = „http://message.example.org/“
  - local name = „message“
  - prefix = „msg“
  - children = (**C1**, **C2**, …, **C11**)
  - attributes = { **A1** }
  - namespace attributes = { **AN1**, **AN2** }
  - in-scope namespaces = { **N3**, **N1**, **N2** }
  - base URI = „file://…“ // irgendeine passende Quelle
  - parent = **D1**

XML Infoset: *Item Properties*

- **Attribute Information Item**
  - ***namespace name***

    Der Name des Namensraums dieses Attributs, sofern vorhanden. Sonst „ohne Wert“.
  - ***local name***

    Der Name des Attributtyps, ohne *namespace*-Präfix und Doppelpunkt.
  - ***prefix***

    Das *namespace*-Präfix des Elementtyp-Namens, sonst „ohne Wert“.

    Bem.: Anwendungen, die *namespaces* unterstützen, sollten die Namensraum-Namen statt der Prafixwerte verwenden.
  - ***normalized value***

    Der gemäß XML 1.0 normierte Attributwert.

XML Infoset: *Item Properties*

- **Attribute Information Item (Forts.)**
  - ***specified***

    Ein *flag*, das anzeigt, ob das Attribut tatsächlich im Element spezifiziert wurde (und nicht per default-Deklaration der DTD gefüllt wurde).
  - ***attribute type***

    Gültige Werte sind ID, IDREF, ENTITY, ENTITIES, NMTOKEN, NMTOKENS, NOTATION, CDATA und ENUMERATION.

    „ohne Wert“, falls das Attribut nicht deklariert wurde,

    „unbekannt“, falls es eine ungelesene Deklaration gab.

XML Infoset: *Item Properties*

- **Attribute Information Item (Forts.)**

  – ***references***

  „ohne Wert“, falls ID, NMTOKEN, NMTOKENS, CDATA oder ENUMERATION.

  „unbekannt“, falls der Attributtyp „unbekannt“ ist

  sonst (falls IDREF, IDREFS, ENTITY, ENTITIES, NOTATION):
  Eine geordnete Liste der *info items* vom Typ

  element, unparsed entity oder *notation*,

  in der Reihenfolge ihres Erscheinens im Attributwert, bzw. „ohne Wert“ oder „unbekannt“ im Fall von Inkonsistenzen.

  – ***owner element***

  Der *element info item*, aus dem das Attribut stammt.

XML Infoset

- Attribute info item **A1**:
  - namespace name = „http://doc.example.org/namespaces/doc“
  - local name = „date“
  - prefix = „doc“
  - normalized value = „19990421“
  - specified = „yes“ // „1“, true, ... ?
  - attribute type = (kein Wert)
  - references = (kein Wert) // ?
  - owner element = **E1**

XML Infoset

- Attribute info item **AN1**:
  - namespace name = „http://www.w3.org/2000/xmlns“
  - local name = „doc“
  - prefix = „xmlns“ // ?
  - normalized value = „http://doc.example.org/namespaces/doc“
  - specified = „yes“ // „1“, true, ... ?
  - attribute type = (kein Wert)
  - references = (kein Wert) // ?
  - owner element = **E1** // ?

XML Infoset

- Attribute info item **AN2**:
  - namespace name = „http://www.w3.org/2000/xmlns“
  - local name = „msg“
  - prefix = „xmlns“ // ?
  - normalized value = „ http://message.example.org/“
  - specified = „yes“ // „1“, true, ... ?
  - attribute type = (kein Wert)
  - references = (kein Wert) // ?
  - owner element = **E1** // ?

XML Infoset: *Item Properties*

- **Processing Instruction Information Item**
  - ***target***

    Eine Zeichenkette, die den „*target*“-Teil der PI enthält (ein XML *name*).
  - ***content***

    Eine Zeichenkette, die den Inhaltsteil der PI enthält, ohne den *target*-Teil und führende *whitespace*-Zeichen. Ggf. die leere Zeichenkette.
  - ***base URI***

    Die base URI der PI.
  - ***notation***

    Falls verwendet: Der *notation info item* aus der PI. Sonst: „kein Wert“ bzw. „unbekannt“, je nachdem ob eine Deklaration fehlt oder eventuell nicht gelesen werden konnte.
  - ***parent***

    Der *info item*, in dessen *children*-Liste dieser *PI info item* erscheint. Mögliche Typen sind: *document*, *element*, *document type definition*.

XML Infoset: *Item Properties*

- **Unexpanded Entity Reference Information Item**
  - ***name***

    Eine Zeichenkette, die den „*target*“-Teil der PI enthält (ein XML *name*).
  - ***system identifier***

    Eine Zeichenkette mit dem angegebenen URI, ohne zusätzliche *escape*-Zeichen. Je nach Sachlage auch „ohne Wert“ oder „unbekannt“.
  - ***public identifier***

    Eine Zeichenkette mit dem angegebenen *public identifier* in normierter Darstellung. Je nach Sachlage auch „ohne Wert“ oder „unbekannt“.
  - ***declaration base URI***

    Base URI des *entity*, in dem die nicht aufgelöste *entity*-Referenz erscheint.
  - ***parent***

    Der *element info item*, in dessen *children*-Liste dieser *info item* erscheint.

Bemerkung:

Validierende XML-Prozessoren erzeugen keine solchen *info items*.

XML Infoset: *Item Properties*

- **Character Information Item**
  - ***character code***

    Der ISO 10646 / Unicode-Wert des Zeichens.
  - ***element content whitespace***

    Eine boolesche Variable, „*true*“ falls das dargestellte Zeichen vom Typ *whitespace* ist, „*false*“ wenn nicht.

    Falls die Deklaration des zugrundeliegenden Elements nicht existiert bzw. nicht gelesen wurde, „ohne Wert“ bzw. „unbekannt“.

    Validierende XML-Prozessoren müssen diese Information stets liefern.
  - ***parent***

    Der *element info item*, in dessen *children*-Liste dieser *info item* erscheint.

Bemerkungen

- Vorsicht - erheblicher *overhead* bei großen Dokumenten mit viel Freitext innerhalb von Elementen.
- Anwendungen steht es frei, die Zeichen wieder zu verketten.
- Gerade hier gehen XPath und XSLT andere Wege!

XML Infoset

- Character info item **C1**:
  - character code = „P“
  - element content whitespace = false
  - parent = **E1**
- ...
- Character info item **C6**:
  - character code = „ “
  - element content whitespace = true
  - parent = **E1**
- ...

- Character info item **C11**:
  - character code = „!“
  - element content whitespace = false
  - parent = **E1**

XML Infoset: *Item Properties*

- **Comment Information Item**
  - ***content***

    Die Zeichenkette mit dem Kommentarinhalt.
  - ***parent***

    Der *document* oder *element info item*, in dessen *children*-Liste dieser *info item* erscheint.

- Bemerkungen
  - Kommentare innerhalb von DTDs gelangen nicht in den Infoset!

XML Infoset: *Item Properties*

- **Document Type Declaration Information Item**
  - ***system identifier***

    Eine Zeichenkette mit dem in der DOCTYPE-Deklaration angegebenen URI des externen *Subsets*, ohne zusätzliche *escape*-Zeichen. Je nach Sachlage auch „ohne Wert“ oder „unbekannt“.
  - ***public identifier***

    Eine Zeichenkette mit dem angegebenen *public identifier* in normierter Darstellung. Je nach Sachlage auch „ohne Wert“ oder „unbekannt“.
  - ***children***

    Eine geordnete Liste der *PI info items* in der Reihenfolge, wie die entsprechenden PI in der DTD erscheinen.

    PI im internen Subset erscheinen als erste.
  - ***parent***

    Der *document info item*.

Bemerkungen

- *entities* und *notations* werden vom *document info item* erfasst.

XML Infoset: *Item Properties*

- **Unparsed Entity Reference Information Item**
  - ***name***

    Der Name des *entity*.
  - ***system identifier***

    Eine Zeichenkette mit dem in der Deklaration angegebenen URI.
  - ***public identifier***

    Eine Zeichenkette mit dem angegebenen *public identifier* in normierter Darstellung. Auch „ohne Wert“ oder „unbekannt“ mögl.
  - ***declaration base URI***

    Das base URI des *entity*, in dem die *entity*-Referenz erscheint.
  - ***notation name***

    Der Name der zugeordneten *notation*.
  - ***notation***

    Der *notation info item*, auf den die *entity*-Referenz verweist.

XML Infoset: *Item Properties*

- **Notation Information Item**
  - ***name***

    Der Name der *notation*.
  - ***system identifier***

    Eine Zeichenkette mit dem in der NOTATION-Deklaration angegebenen URI, ggf. „ohne Wert“.
  - ***public identifier***

    Eine Zeichenkette mit dem angegebenen *public identifier* in normierter Darstellung. Je nach Sachlage auch „ohne Wert“.
  - ***declaration base URI***

    Das base URI des *entity*, in dem die NOTATION-Deklaration erscheint.

XML Infoset: *Item Properties*

- **Namespace Information Item**
  - ***prefix***

    Die mit einem *namespace* zu assoziierende Zeichenkette „ohne Wert“ im Fall des *default namespace* (Element-Präfix „xmlns:“).
  - ***namespace name***

    Der zugeordnete Name des *namespace*.

- Bemerkungen:
  - Fast alle *info items* entsprechen direkt bestimmten Objekten aus der XML 1.0-Spezifikation.
  - Dieser hier nicht: Die *namespace*-Spezifikationen finden hier von Anfang an volle Unterstützung, nicht nur im Nachhinein.

XML Infoset

- Namespace info item **N1**:
  - prefix = „msg“
  - namespace name = „http://message.example.org/“
- Namespace info item **N2**:
  - prefix = „doc“
  - namespace name = „http://doc.example.org/namespaces/doc“
- Namespace info item **N3**:
  - prefix = „xml“
  - namespace name = „http://www.w3.org/1998/namespace“

XML Infoset

Das Eingangsbeispiel,
nun genauer

XML Infoset

Das Eingangs-Beispiel 2 noch einmal:

```
<?xml version="1.0"?>
<msg:message doc:date="19990421"
    xmlns:doc="http://doc.example.org/namespaces/doc"
    xmlns:msg="http://message.example.org/">
    Phone home!
</msg:message>
```

Es erzeugt folgendes XML Infoset - diesmal genauer, nur ohne Verkettungen:

- Ein `document` *information item*
- Ein `element` *info item*
  - mit *namespace*-Eintrag „`http://message.example.org/`“
  - mit *local part* „`message`“ und Präfix „`msg`“
- (b.w.)

XML Infoset

- Ein `attribute` *info item*
  - mit *namespace*-Eintrag „`http://doc.example.org/namespaces/doc`“
  - mit *local part* „`date`“ und Präfix „`doc`“
  - mit dem normierten Wert „`19990421`“
- Drei `namespace` *info items*
  - für die Namensräume „`http://www.w3.org/XML/1998/namespace`“, „`http://doc.example.org/namespaces/doc`“ und „`http://message.example.org/`“
- Zwei `attribute` *info items,* für die beiden *namespace*-Attribute
- Elf `character` *info items,* für die Zeichenkette „`Phone home!`“

XML Infoset: Verkettungen

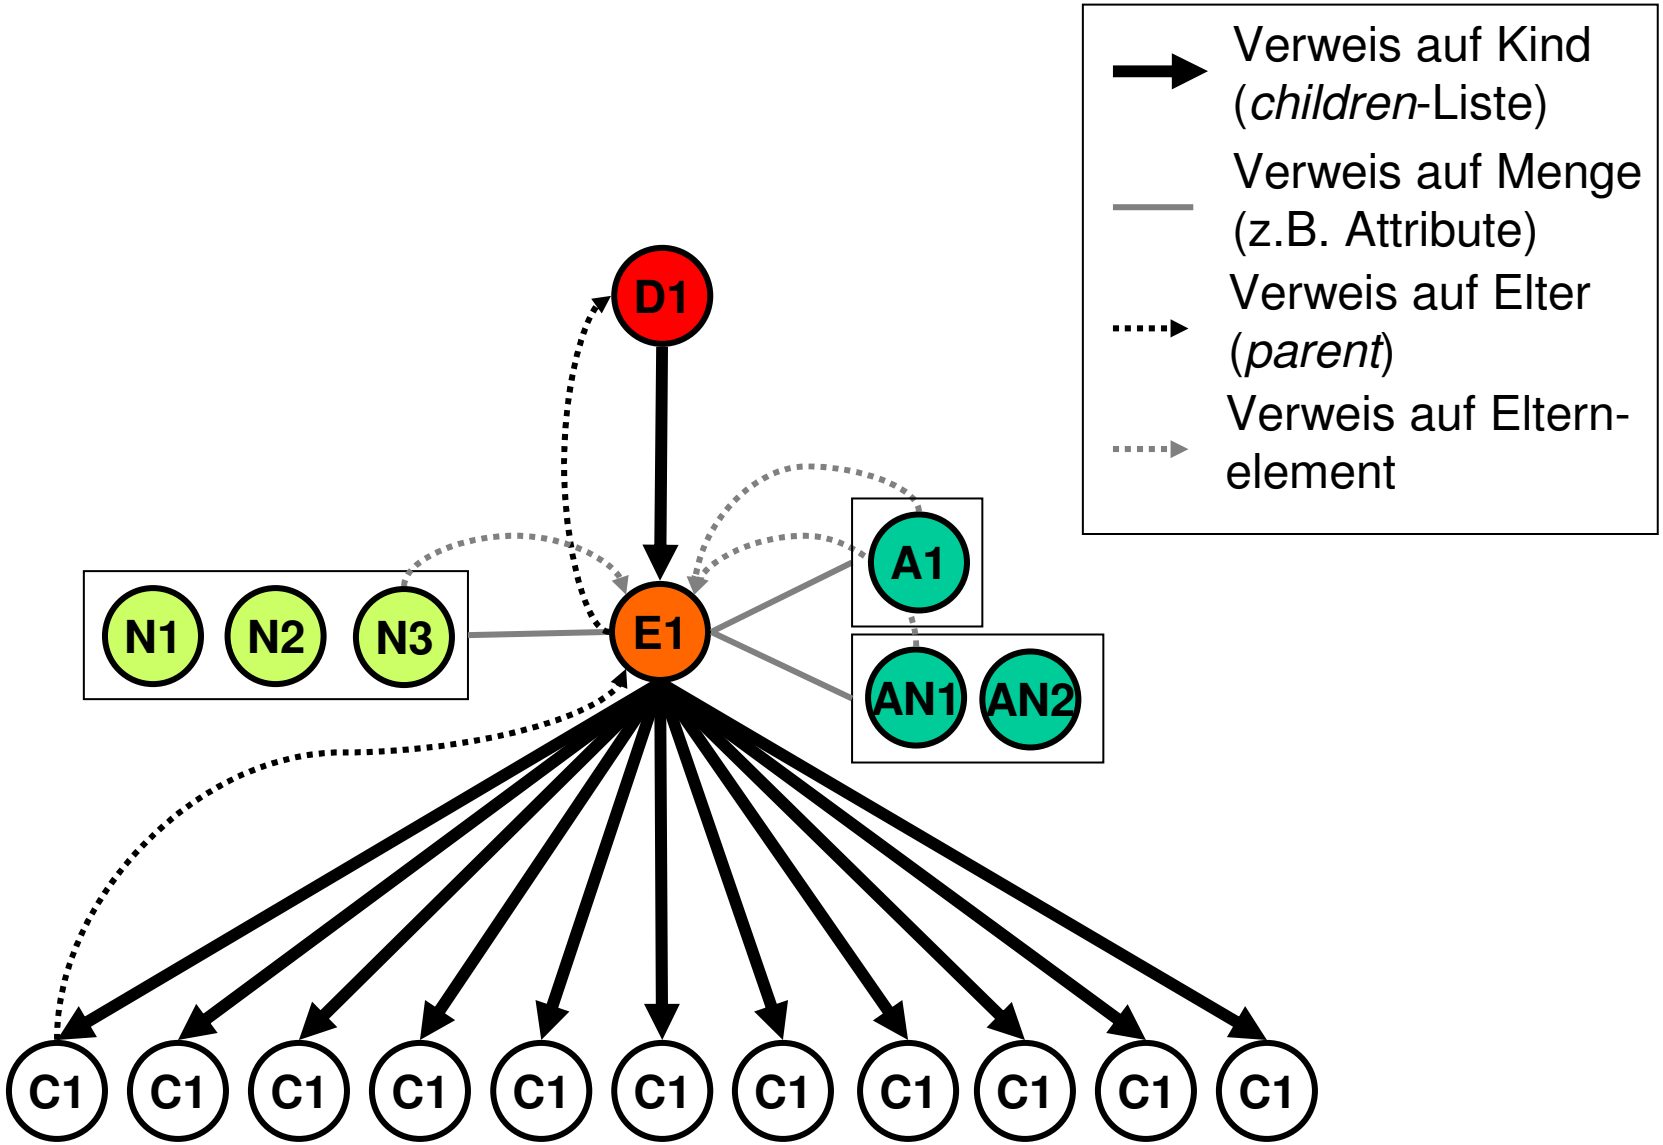

XML Infoset

Was ein XML Infoset nicht enthält

Also: Was eine Anwendung nie über Ihre XML-Dateien erfährt…

XML Infoset

- Was ein XML Infoset nicht enthält
  - Folgen der Expansionen der XML-Prozessoren
    - Die Repräsentation von Zeichen (direkt, per *char ref*, per *entity ref*, per *CDATA section*)
    - Die Grenzen von INCLUDE/IGNORE-Abschnitten in der DTD
    - Die Grenzen von *parameter entities* in der DTD.
    - Überlesene Deklarationen, z.B. innerhalb von IGNORE-Abschnitten
    - Die Grenzen von *general parsed entities*.
    - Die Grenzen von CDATA *sections*.
  - Folgen der Normierung der XML-Prozessoren
    - Die Art der Zeilenende-Codierung.
    - Die Art der verwendeten Anführungszeichen.

XML Infoset

– Sonstiges

Die *content models* der Elementyp-Deklarationen aus der DTD.

Gruppierung/Anordnung von Attributen laut ATTLIST-Deklaration.

Der Name des Dokumenttypen.

White space:

Außerhalb des *document element*

Der dem *target name* einer PI unmittelbar folgende

Innerhalb von *tags*.

Die Darstellung eines leeren Elements (<foo/> vs. <foo></foo>)

Die Reihenfolge der Attribute in einem *start tag.*

Die Reihenfolge der Deklarationen in der DTD*.*

Kommentare in der DTD.

Die Position von Deklarationen, z.B. intern vs. extern vs. indirekt per *parameter entity*.

Die *default*-Werte von Attributen wie in der DTD deklariert.