

XMLチュートリアル

奈良先端科学技術大学院大学

吉川 正俊

yosikawa@is.aist-nara.ac.jp

<http://db-www.aist-nara.ac.jp/members/Yoshikawa/home.html>

(c) 2000 吉川正俊

Why XML ?


(c) 2000 吉川正俊

Why XML ?

- ◆ 応用プログラムやO.S.に依存しない標準のデータ交換フォーマットが欲しい
 - 特に, Internet や WWW 上での
- ◆ 重要なこと
 - 汎用性
 - 単純性
 - 既存技術との互換性


(c) 2000 吉川正俊

XMLの応用モデル



(c) 2000 吉川正俊

インターネット上の共通言語としてのXML



(c) 2000 吉川正俊

XMLの歴史と標準化の動向

歴史 (菊田昌弘 bit, 1999年1月号)

- ◆ 1960年代に開始
 - GCA (Graphic Communications Association)では、異なるタイプセット間でのドキュメント交換を可能とするGenCodeと呼ばれる汎用的なフォーマットコードを開発
 - IBMでは、GML (Generalized Markup Language)を、社内文書の管理に用いていた。
- ◆ 1980年代
 - GenCodeグループとGMLグループの代表者がANSIにおいて、Computer Language for the Processing of Textの検討組織を開始し、ドキュメント中のマークアップを標準化するための作業を始めた。

(c) 2000 吉川正俊

歴史

- ◆ 1986 SGMLがISO標準になる
- ◆ 1992 最初のHTMLの仕様が出版される
- ◆ 1994秋 W3Cができる
- ◆ 1998 XML 1.0がW3C Recommendationになる
- ◆ 1999.9 Phase II - Query Language WG, XML Digital Signature

(c) 2000 吉川正俊

HTMLの歴史

- ◆ 当初のHTML
 - 単にSGML風のマークアップ言語でしかなかった
- ◆ HTML2.0
 - IETFによってまとめられ、正式なSGMLアプリケーションとなる
- ◆ HTMLの標準化の作業の舞台はW3Cへと移る
- ◆ HTML3.2を経て、現在はHTML4.01(1999.12)が最新版
- ◆ 現在ISOでも、HTML4.0をもとに、より厳格なサブセットという形で、ISO/IEC 15445(通称ISO-HTML)の標準化を進めている。
- ◆ XHTMLへ


(c) 2000 吉川正俊

HTML と XML

- ◆ HTML
 - 言語
 - 内容の記述と表現法の記述が一緒になっている。
 - » 従って、異なる表現法への変換が非効率的
 - 自分でタグを拡張できない
- ◆ XML
 - メタ言語
 - 内容のみを記述
 - » 表現法は、たとえばCSSにまかせる
 - 自分でタグを拡張できる


(c) 2000 吉川正俊

SGML, XML, HTML and XHTML



(c) 2000 吉川正俊

種々の標準、提案の関連



(c) 2000 吉川正俊

XMLの概要

(c) 2000 吉川正俊

XML (eXtensible Markup Language)

- ◆ データおよび構造化文書の表現方法
 - インターネット上での交換性を考慮
 - 汎用性
 - » すべてクリアテキストで表現
⇒ 計算機、O.S.、応用からの独立性
 - » 國際性 (ISO/IEC 10646)
 - 基本的に木構造を表現
- ◆ W3C (World Wide Web Consortium)により標準化

(c) 2000 吉川正俊

整形式のXML文書

(c) 2000 吉川正俊

XMLインスタンスの例

```
<article status="draft">
  <title>Resource Description Framework (RDF)
  Model and Syntax Specification </title>
  <author>Ora Lassila</author>
  <author>Ralph R. Swick</author>
  <date>05 January 1999</date>
  <section>
    <title>Introduction</title>
    <body><paragr>The <em>World Wide
    Web</em> was originally built for ...
    </paragr>
  </body>
  </section>
</article>
```

開始タグ (start tag)
終了タグ (end tag)

内容 (content)

(c) 2000 吉川正俊

要素の階層構造

- ◆ ある要素は、その上位要素に完全に含まれていなければならない
 - <vp>恐れ<placename>入</vp>谷</placename>の鬼子母神のような文書 (GDA日本語タギングマニュアル 橋田 浩一) や
 - 大腸菌ゲノムのような環状データはそのままでは表現できない

(c) 2000 吉川正俊

XML属性

属性

属性名

属性値

◆ 開始タグ中に記述
◆ “ または ‘ で囲む

(c) 2000 吉川正俊

実体参照 (entity reference)

- ◆要素の内容中に文字“<”を含めたいときはどうするか?
 - ✗ <p>不等号<は、数学で使われる。</p>
 - <p>不等号<は、数学で使われる。</p>

実体参照の方法

&実体名;

(c) 2000 吉川正俊

実体参照

- ◆いつでも(DTDなしで)使える実体

文字	実体名
<	lt
>	gt
&	amp
,	apos
”	quot

(c) 2000 吉川正俊

文字参照 (character reference)

- ◆キーボードから直接入力できない文字はどう入力するか?
- ☆ ISO/IEC 10646文字コードを指定して文字を参照する

文字参照の方法

進コード; または 進コード;

(c) 2000 吉川正俊

整形式 (well-formed)のXML文書

- ◆ XMLの構文規則に従っている文書
 - 開始タグと終了タグの対応が正しく取れている
 - タグが正しく入れ子関係になっている
 - ルート要素(文書要素(document element)とも呼ぶ)は、唯一
 - 属性は開始タグに記述されている
 - ...
- ◆先頭行にXML宣言を書く。
 - 例: <?xml version="1.0" encoding="iso-2022-jp"?>
 - <?xml version="1.0" encoding="shift_jis"?>

(c) 2000 吉川正俊

XMLインスタンスのデータ構造

タグの入れ子構造 + 属性



基本的に木構造

(c) 2000 吉川正俊

妥当なXML文書

(c) 2000 吉川正俊

XML文書の構成

- ◆ [XML宣言]
 - バージョンと符号化宣言を指定
 - 例: <?xml version="1.0" encoding="iso-2022-jp"?>
- ◆ [DTD (Document Type Definition)]
 - 要素、属性、エンティティの宣言
- ◆ XMLインスタンス*
 - 実際のタグ付き文書

* XMLインスタンスという用語は仕様書にはない。

(c) 2000 吉川正俊

DTD

- ◆ 要素型宣言 (element type declaration)
- ◆ 属性リスト宣言 (attribute-list declaration)
- ◆ エンティティ宣言 (entity declaration)
- ◆ 記法宣言 (notation declaration)

(c) 2000 吉川正俊

DTDの例

```
<!ELEMENT article (title, author+, date, section+)>
<!ATTLIST article status (final|draft) "draft">
<!ELEMENT title (#PCDATA)>
<!ELEMENT author (#PCDATA)>
<!ELEMENT date (#PCDATA)>
<!ELEMENT section (title, body+)>
<!ELEMENT body (figure | paragr)>
<!ELEMENT figure EMPTY>
<!ATTLIST figure file ENTITY #IMPLIED>
<!ELEMENT paragr (#PCDATA|em)*>
```

(c) 2000 吉川正俊

要素型宣言

- ◆ XMLインスタンスで使用できる要素の名前、階層構造を規定
- ◆ <!ELEMENT 要素名 内容モデル>
これにより要素の階層構造中の一つの親子関係を指定

(c) 2000 吉川正俊

内容モデル(要素内容)

- ◆ 要素内容
 - 子要素だけを含み文字データを含まない
 - 出現順序の指定： 列(.) 選択()
 - 出現回数の指定： 1回以上任意の回数(+) 0回以上任意の回数(*) 0回もしくは1回(?)
例)
<!ELEMENT article (title, author+, date, section+)>
<!ELEMENT section (title, body+)>
<!ELEMENT body (figure | paragr)>

(c) 2000 吉川正俊

内容モデル(要素内容) --- 構文規則

- ◆ children ::= (choice | seq) ('?' | '*' | '+')?
- ◆ cp ::= (Name | choice | seq) ('?' | '*' | '+')?
- ◆ choice ::= '(' S? cp (S? '|' S? cp)* S? ')'
- ◆ seq ::= '(' S? cp (S? ',' S? cp)* S? ')'
(S は「空白」)

(c) 2000 吉川正俊

内容モデル(混在内容)

◆ 混在内容

- 子要素に混在して文字データが含まれる可能性がある
- 例) <!ELEMENT paragr (#PCDATA|em|footnote)*>
 <!ELEMENT paragr (#PCDATA|em)*>
 <!ELEMENT title (#PCDATA)>
 #PCDATAは文字データを表す

(c) 2000 吉川正俊

内容モデル(空要素, 任意要素)

◆ 空要素 (EMPTY)


DTD:

```
<!ELEMENT figure EMPTY>
文書インスタンス:
<figure></figure>
または
<figure/>
```

◆ 任意要素 (ANY)

(c) 2000 吉川正俊

属性リスト宣言



(c) 2000 吉川正俊

ID, IDREFの例

DTD:


```
<!ELEMENT emp (#PCDATA)>
<!ATTLIST emp id ID #required>
<!ATTLIST emp boss IDREF #implied>
```

XMLインスタンス:

```
... <emp id="19" boss="3">上原君</emp>は,
<emp id="3">長嶋さん</emp>と同じ会社で
働いている. ...
```

(c) 2000 吉川正俊

DTDの木表現



(c) 2000 吉川正俊

妥当 (valid) なXML文書

- ◆ 整形式 であり、その上さらにDTDを持ち、DTD中の宣言に従っているXML文書



(c) 2000 吉川正俊

XML文書 --- 二つの側面

- ◆ 単なる文字列である
- ◆ 構造化データであり、しかもその構造は基本的に木でモデル化できる
 - より厳密には、ID/IDREFによる相互参照なども考慮する必要があるため、木ではなく有向グラフでモデル化する必要がある

(c) 2000 吉川正俊

DTDの指定方法

- ◆ DTDが別ファイルにある場合
<!DOCTYPE ルート要素の名前
SYSTEM ファイル名>
- ◆ DTDを直接書く場合
<!DOCTYPE ルート要素の名前
[DTDの記述]>

(c) 2000 吉川正俊

persons.dtd

```
<?xml version="1.0" encoding="iso-2022-jp"?>  
<!ELEMENT persons      (person)+>  
<!ELEMENT person       (name, jobtitle?, affildept?, affilorg?,  
email, homepage?)>  
<!ELEMENT name         (firstname, middlename?, familyname)>  
<!ELEMENT firstname   (#PCDATA)>  
<!ELEMENT middlename  (#PCDATA)>  
<!ELEMENT familyname  (#PCDATA)>  
<!ELEMENT jobtitle    (#PCDATA)>  
<!ELEMENT affildept   (#PCDATA)>  
<!ELEMENT affilorg    (#PCDATA)>  
<!ELEMENT email       (#PCDATA)>  
<!ELEMENT homepage   (#PCDATA)>
```

(c) 2000 吉川正俊


名前空間

(c) 2000 吉川正俊

名前空間

- ◆ ネットワークを介してスキーマ部品(たとえば 要素型や属性)を再利用するための機構

urn:loc.gov:books 'urn:ISBN:0-395-36341-6'



(c) 2000 吉川正俊

名前空間宣言の例

```
<x xmlns:edi='http://ecommerce.org/schema'>
  <!--the "edi" prefix is bound to
  http://ecommerce.org/schema for the "x"
  element and contents -->
</x>
```

- ◆ ediというprefixと、上記名前空間名との対応は、<x ...> と </x> の間でのみ有効
- ◆ この文書のDTDで x の属性として xmlnsを宣言する必要はない。

(c) 2000 吉川正俊

なぜ “URI:” のように直接URIを参照しないか？

- ◆ URI参照はXMLの名前として許されない文字列を含んでも良いため、名前空間のprefixとして直接使うことはできない。



- ◆ 従って、名前空間prefixを導入して、それによってURIを参照するようにしている。

(c) 2000 吉川正俊

名前空間の利用例

```
<x xmlns:edi='http://ecommerce.org/schema'>  
    <!-- 要素型の例 -->  
    <edi:price units='Euro'>32.18</edi:price>  
  
    <!-- 属性の例 -->  
    <lineItem edi:taxClass="exempt">Baby  
        food</lineItem>  
</x>
```

(c) 2000 吉川正俊

複数の名前空間の利用

```
<?xml version="1.0"?>  
<!-- both namespace prefixes are available  
throughout -->  
<bk:book xmlns:bk='urn:loc.gov:books'  
          xmlns:isbn='urn:ISBN:0-395-36341-6'>  
    <bk:title>Cheaper by the Dozen</bk:title>  
    <isbn:number>1568491379</isbn:number>  
</bk:book>
```

(c) 2000 吉川正俊

名前空間の有効範囲の例

```
<?xml version="1.0"?>  
<book xmlns='urn:loc.gov:books'  
      xmlns:isbn='urn:ISBN:0-395-36341-6'>  
    <title>Cheaper by the Dozen</title>  
    <isbn:number>1568491379</isbn:number>  
    <notes>  
      <p xmlns='urn:w3-org-ns:HTML'>  
        This is a <i>funny</i> book!  
      </p>  
    </notes>  
</book>
```

(c) 2000 吉川正俊