論文

中国語学習コンテンツの制作

XMLデータベースとJavaScriptをつかって

非常勤講師　齊藤正高

1.　はじめに

商用のショップサイトに劣らず、教育においてもデータベースが果たす役割は重大である。うまく構造化したデータベースを作成し、学習者による適切な入力を設定し、その入力を判断するしくみを作れば、基本的な学習コンテンツを作ることができる。

また、Unicodeの伝送形態であるUTF-8の浸透にともない、中国語の学習コンテンツもパッケージ化されたソフトから、ウェブベースのコンテンツに移行しつつある。検定試験問題のデータベース化や講義で使われるCALL副教材にも多くの実績がある。[1]

本稿はデータベースをもつウェブベースの学習コンテンツについて、その作成方法を報告する。筆者が作成したコンテンツは以下である。

1)中国語単語ドリル　2)中国語あいさつ文タイピング　3)音声つき単語タイピング
4)中国語偏旁名テスト　5)中国語量詞テスト　6)成語タイピング　7)発音分類別単語表

http://taweb.aichi-u.ac.jp/saitom/chuugokugo/chuugokugo.html

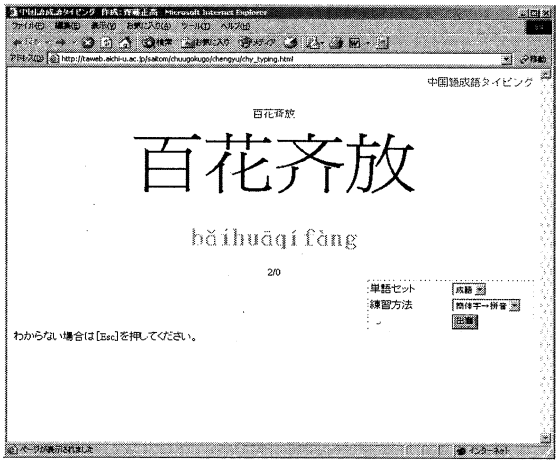

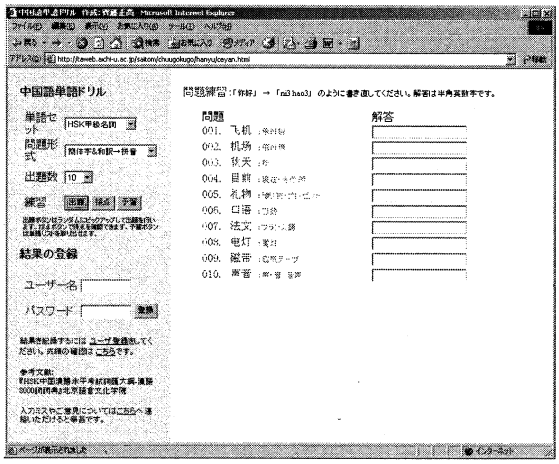

これらはじつに同工異曲であって、すべてXMLによるデータベースをJavaScriptで問題に加工し、HTMLでインターフェースを作成したものである。以下にくわしく述べる。

1　漢字文献情報処理研究会『漢字文献情報処理研究』創刊号2000年

2. XMLについて

まず、XMLについて簡単にまとめておきたい。XMLは1998年にW3Cから勧告された「拡張可能なマークアップ言語」であり、タグを自由に定義できる点が特長である。HTMLが文書の表示を行う言語だと考えれば、XMLはデータの構造をマークアップする言語と考えることができよう。一般的なXMLデータベースは以下の部分からなる。

2.1 XML宣言

XML宣言はXML文書の最初に書く宣言である。省略するとXMLとして認識されない場合があるので書いた方がよい。

例：

```
<?xml version="1.0" encoding="utf-8" standalone="no"?>
```

この宣言の書き方はHTMLよりも厳密で、xmlの部分を大文字にしたり、<?とxmlの間に空白を入れたり、version属性とencoding属性を転倒することはできない。versionは現在1.0である。encodingはShift_JISやUTF-8などの文字エンコーディングスキームを指定する。standaloneは外部にマーク付け宣言があるかどうかを記述する。省略するとnoになる。

2.2 DTD(Docment Type Definiton)

DTDではXML文書の構造（スキーマ）を定義する。本稿の使い方では省略しても動くので省く。ところで、昨年からDTDにかわるスキーマ言語「RELAX」、「XML Schema」をめぐって、XML開発者のあいだで「ボヘミアンと貴族の階級闘争」と呼ばれる対立がある。データの型を明確に定義し、XMLをバイナリでも扱えるようにしようと考える派閥（貴族）と、XMLを基本的にテキストデータと考える派閥（ボヘミアン）の対立である。吉松史彰氏はこれを「スキーマが重要か、それともインスタンスが重要か」という問題としてとらえ、以下のように「XMLの挑戦」をまとめる。

> 私たち現代の技術者にとっては、インスタンスはスキーマなしには存在し得ない。インスタンスの解釈は厳密にスキーマに依存する。ところが、現実を見てみると、実はスキーマなしでも立派にデータが流通し、運用できているシステムが世の中にはたくさん存在する。その代表例がWebだ。（中略）まずインスタンスありきで世界をつなぐシステムを構築する。それがXMLの挑戦であり、

パラダイムシフトなのだ。[2]

本稿の立場は、既存のデータを再利用を重視するので、「ボヘミアン」的な立場である。

2.3 XML 文書

XML 文書は HTML と同じように内容をタグで囲む。タグ名は自由に定義でき、漢字・ひらがななど２バイト文字を使うこともできる。ただし、半角カタカナと全角英数字が使えず、一文字目は文字かアンダースコアでなくてはならないという禁則もある。XML 文書としての形式は、HTML よりも厳密にかかねばならない。以下に、XML 文書の必要な形式を書く。

2.3.1 XML 宣言を除いた、すべてのタグは開始タグと終了タグがなければいけない。

例：

```
<単語リスト>～</単語リスト>
```

たとえば、HTML の
タグは終了要素がないが、XML の内部にこれを書く場合は、
</br>と書くか
と書かねばならない。/>は終了要素を省略した形である。

2.3.2 XML 宣言を除いた、全ての要素を包み込む「ルート要素」が１つだけ必要である。

×悪い例

```
<?xml version="1.0" encoding="utf-8"?>
<詞><ピンイン>ni3hao3</ピンイン></詞>
<詞><ピンイン>zai4jian4</ピンイン></詞>
```

○よい例……<単語リスト>がルート要素

```
<?xml version="1.0" encoding="utf-8"?>
<単語リスト>
<詞><ピンイン>ni3hao3</ピンイン></詞>
<詞><ピンイン>zai4jian4</ピンイン></詞>
</単語リスト>
```

---

[2] 吉松史彰「XML がもたらす夢と現実」2003/03/20
(http://www.atmarkit.co.jp/fdotnet/opinion/yoshimatsu/onepoint07.html)

2.3.3　タグには属性が付加できるが、属性の代入には必ず引用符（=”～”か=’　’）が必要である。

例：

<単語リスト language="Chinese" category="あいさつ">～
</単語リスト>

以上の約束を守れば、XML として認識され、ブラウザーでも表示できる。

3. XML文書の作成

XML 文書はエディターでも作成できる。また、フリーの XML エディターもいくつかあるが、大量のデータを扱う際には少々つかいにくい面がある。そこで、表計算ソフトのワークシートを直接マークアップし、XML データを作成する手法を紹介したい。この方法は既存のデータベースを XML に変換する場合に有効である。また、Excel2003 には XML 文書を更新する機能がついているので、すでにある XML 文書の追記に使うことができる。また、XML Schema（.xsd）ファイルをよみこめば XML をエクスポートできる。

たとえば、以下の会話表現のデータがあるとき

	A	B	C	D	E
1					
2					
3		你好	ni3hao3	こんにちは	
4		您好	nin2hao3	(目上に)こんにちは	
5		再见	zai4jian4	さようなら	
6		对不起	dui4bu5qi3	ごめんなさい	
7		谢谢	xie4xie5	ありがとう	
8					

１行をレコードと考え、行を挿入しながら、以下のマークアップを行う。

	A	B	C	D	E	F	G
1							
2							
3	<juzi no='1'><zi>	你好	</zi><pinyin>	ni3hao3	</pinyin><riyu>	こんにちは	</riyu></juzi>
4		您好		nin2hao3		(目上に)こんにちは	
5		再见		zai4jian4		さようなら	
6		对不起		dui4bu5qi3		ごめんなさい	
7		谢谢		xie4xie5		ありがとう	
8							

これにルート要素と XML 宣言を書き加え、以下のようにする。

	A	B	C	D	E	F	G
1	<?xml version='1.0' encoding='utf-8'?>						
2	<huihua>						
3	<juzi no='1'><zi>	你好	</zi><pinyin>	ni3hao3	</pinyin><riyu>	こんにちは	</riyu></juzi>
4	<juzi no='2'><zi>	您好	</zi><pinyin>	nin2hao3	</pinyin><riyu>	(目上に)こんにちは	</riyu></juzi>
5	<juzi no='3'><zi>	再见	</zi><pinyin>	zai4jian4	</pinyin><riyu>	さようなら	</riyu></juzi>
6	<juzi no='4'><zi>	对不起	</zi><pinyin>	dui4bu5qi3	</pinyin><riyu>	ごめんなさい	</riyu></juzi>
7	<juzi no='5'><zi>	谢谢	</zi><pinyin>	xie4xie5	</pinyin><riyu>	ありがとう	</riyu></juzi>
8	</huihua>						
9							

このワークシートを「.xml」の拡張子をつけて、Unicode（UTF16）テキストとして保存する。ブラウザーで表示するにはエディターを使い、UTF-8 で保存しなおす必要がある。


```
  <?xml version="1.0" encoding="utf-8" ?>
- <huihua>
  - <juzi no="1">
      <zi>你好</zi>
      <pinyin>ni3hao3</pinyin>
      <riyu>こんにちは</riyu>
    </juzi>
  - <juzi no="2">
      <zi>您好</zi>
      <pinyin>nin2hao3</pinyin>
      <riyu>(目上に)こんにちは</riyu>
    </juzi>
```

このままでは大量のタブをふくむので、ワードプロセッサの置換機能でとり除いてもよい。

4. XPath

XML のデータを自在に抽出するには XPath を用いるのが便利である。XPath を用いるには、事前に XML 文書のマークアップ構造を知っておく必要があるが、教材作成者が XML のマークアップを行った場合、この点は問題にならないと考えてよい。

XPath は次のような構造をもっている。

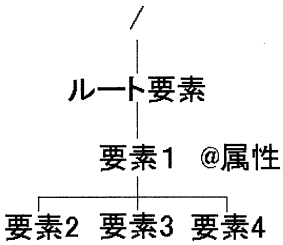

最上位は半角スラッシュで「/」で、XML 文書のルート要素がその後にくる。属性は@を前に書いて表し、各要素のレベルの間は URL のように半角スラッシュで区切って表す。

例：

/huihua/juzi/zi

/huihua/juzi/@no

また、XPath には[～]をつかい、条件を追加することもできる。

例：

/huihua/juzi[@no='2']/zi

/huihua/juzi[@no='2' or @no='3']/zi

/huihua/juzi[pinyin='ni3hao'][@no='1']/zi

……[～]を追加すればand条件を設定。

/huihua/juzi[@no>2]/zi

……「>」は実体参照（>）で表現する。

さらに、XPathには関数がある。

四則演算（とくに除算の記号に注意）

+　加算
-　減算
*　乗算
div 除算
mod 剰余

数値関数（主なもの）

sum( )　合計をとる
count( )　要素の数を返す
floor( )　小数点以下の切り捨て
ceiling( )　小数点以下の切り上げ
round( )　四捨五入した整数を返す

文字関数（主なもの）

contains(stringA, stringB)	StringAにstringBが含まれる場合True
Substring(StringA, B, C)	StringAのB番目からC文字分切り出す。
Substring-after(StringA, StringB)	StirngAからStringBより後の部分を返す。
Substring-before(StringA, StringB)	StirngAからStringBより前の部分を返す。

例：日本酒店のXMLデータを処理するXPath

- sum(酒[価格>=10000]/価格) div count(酒[価格>=10000] /価格)

  →1万円以上の酒の平均価格を算出。

- count(酒[contains(名前,'蓬莱泉')])

  →名前のタグに「蓬莱泉」をふくむデータの個数を算出。

XPathは以下のようにXSL（eXtensible Stylesheet Language）で使うこともできる。

例：nihonshu.xml

```
<?xml version='1.0' encoding='Shift_JIS'?>
<?xml-stylesheet type="text/xsl" href="kakakuhyou.xsl"?>
<商品データ>
<酒>（以下略）
```

↓kakakuhyou.xsl

```
<?xml version="1.0" encoding="Shift_JIS"?>
<xsl:stylesheet version="1.0" xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
<xsl:template match="/商品データ">
<p align="center"><font color="Blue">価格表</font></p>
<table align="center" width="50%" border="1">
<xsl:for-each select="酒[価格&lt;3000]">
<xsl:sort select="価格" data-type="number" order="descending"/>
<tr><td width="40%"><xsl:value-of select="名前"/></td>
<td width="30%"><xsl:value-of select="容量"/>ml</td>
<td width="30%">¥<xsl:value-of select="価格"/>－</td></tr>
</xsl:for-each>
</table>
</xsl:template></xsl:stylesheet>
```

（XSLの解説）

- 1行目xml宣言、2行目はxslの開始タグ（ネームスペースを指定している）
- xsl:template match="XPath"（match以下の要素に以下の書式を適応）
- xsl:for-each select="XPath"（select以下の要素がある限り、以下の書式を適応）
- xsl:sort select="タグ名"（for-eachの内容をタグ名をキーに並べかえ）
- xsl:value-of select="XPath"(select以下のXPathのテキストを取り出す)

5. スクリプト言語による制御

XPathはXSLで用いるほか、XMLパーサをつかって、Javascriptなどのスクリプト言語で制御することができる。XML文書を呼び出す場合、Javascriptでは以下のように書く。

```
var DOM = new ActiveXObject("Msxml2.DOMDocument");
DOM.async = false;
DOM.load ("ファイル名.xml");
```

"Msxml2"とはInternetExplore6以降に附属している「XMLパーサ」で、XMLを読むための部品である。これをオブジェクトに作成する。asyncというプロパティは、Trueのとき以下のXML文書を読込ながらスクリプトを実行する。Falseにすれば、XML文書を読み込んでから以下のスクリプトが動く。loadというメソッドはファイル名を指定してXML文書を読み込む。XML文書はインターネットテンポラリーフォルダーに保存される。

このXML文書に対してXPathを用いるには以下のように書く。

```
var riyu=DOM.documentElement.selectNodes("XPath");
```

documtentElment に対して selectNodes メソッドを実行し、実行結果をオブジェクトに格納する。このXML文書の部分集合からテキストを取り出すには以下のようにする。

```
yaku=riyu.item(0).text
```

item(N).text プロパティが個別の要素のテキストである。selectNodes メソッドの結果が複数である場合は item(N)が配列となっており、添え字による指定が可能である。結果の長さは以下で知ることができる。

```
nagasa=riyu.length;
```

6. 中国語教材作成の実際

中国語の単語ドリルを作成した際、入力と表示を考慮し以下のデータ構造をつくった。

```
  <?xml version="1.0" encoding="utf-8" ?>
- <hsk_jia_dong>
  - <ci no="1">
      <zi lang="zh">爱</zi>
      <pinyin1 lang="zh">ài</pinyin1>
      <pinyin2 lang="en">ai4</pinyin2>
      <english lang="en">love</english>
      <yisi lang="ja">愛する、愛</yisi>
    </ci>
  - <ci no="2">
      <zi lang="zh">安排</zi>
      <pinyin1 lang="zh">ānpái</pinyin1>
      <pinyin2 lang="en">an1pai2</pinyin2>
      <english lang="en">arrange ;arrangement</english>
      <yisi lang="ja">手はずを整える</yisi>
    </ci>
  - <ci no="3">
      <zi lang="zh">摆</zi>
      <pinyin1 lang="zh">b□i</pinyin1>
      <pinyin2 lang="en">bai3</pinyin2>
      <english lang="en">put</english>
      <yisi lang="ja">並べる</yisi>
    </ci>
```

hsk_jia_dong はルート要素であり、漢語水平考試（HSK）の甲級単語の動詞であることを表す。ci は単語のレコードを表す。no 属性はプライマリキーである。zi は簡体字での単語表記を指す。pinyin1 は表示用の発音記号である。pinyin2 は入力の照合用データでピンインの声調部分を数値化してある。english は zi の英訳である。yisi は日本語訳である。

ピンインについては、IME の一般的な入力方法と、表記方法が異なるので、このように分割しておくのがよい。具体的には以下のテーブルを使って、Excel マクロで変換をおこなっている。全部で 132 パターンの変換例を作れば、pinyin2 のデータから pinyin1 のデータを作成できる。

	A	B	C
1	iang1	iāng	
2	iang2	iáng	
3	iang3	iǎng	
4	iang4	iàng	
5	uang1	uāng	
6	uang2	uáng	

この XML データベースをつかって、ランダム出題の単語ドリルをつくる手順は以下になる。

出題関数　（出題ボタンのイベント onclick で起動する）

1. XML パーサーのオブジェクトを読み込み、ファイルをロードする。
2. 出題範囲を１のオブジェクトの.length から求める。
3. 出題数分の重複しない乱数を配列に作成する。
4. XPath をつかって３で作成した乱数の no 属性（プライマリキー）をもつ zi、pinyin1、pinyin2、english、yisi の要素を抽出する。
5. 出題形式に応じて、問題として表示する要素の.text を格納する。
6. ５のあとで解答となる要素を配列に格納する。
7. ５の内容をページの中に表示する。（このとき、document.write ()を用いるか、あるいは ここに問題を表示 のように、HTML タグに ID を指定しておき、document.all.id 名.innerHTML=書き出すメッセージ、のように innerHTML 属性を強制的に書き換える方法をつかってもよい。解答を入力するテキストボックスには name 属性を指定しておき、採点関数で呼び出せるようにしておく。）

採点関数　（採点ボタンのイベント onclick で起動する）

8. 出題関数が作成した解答配列を受け取る。
9. 学習者がテキストボックスに書き込んだ解答を.value 属性を使い受け取る
10. ８と９の内容を比較し、点数をつけ、正解とともに表示する。

7. TTS（Text To Speech）との連携

ＴＴＳは音声合成のことである。WindowsXP では OS の標準機能になっている。

中国語の音声合成エンジンも、Microsoft のサイトから、「SpeechSDK51.exe」と「SpeechSDK51LangPack.exe」をダウンロードすれば使用することができる。現在、アル化ができないなどいくつかの欠点もあるが、発音速度の調整しだいで使用に耐える音声を作ることができる。

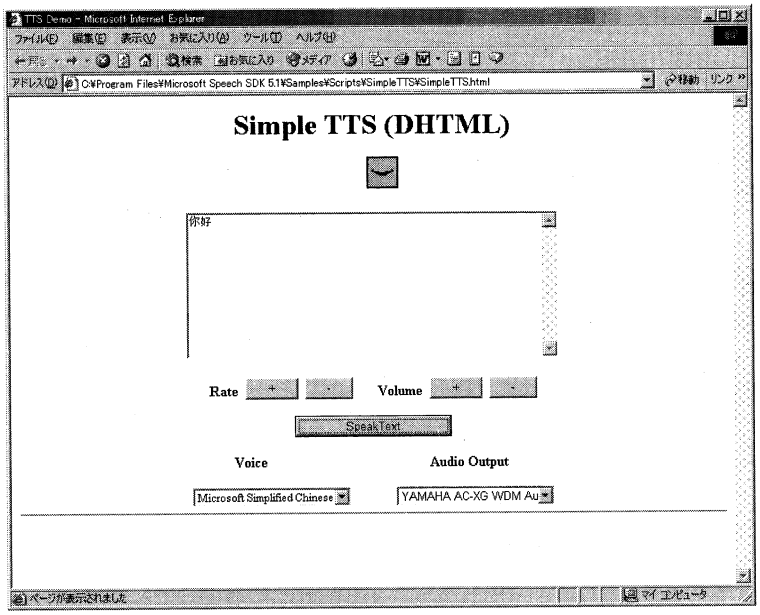

また、SpeechSDK 付属の TTSAPP をつかうと、wav 形式のファイルに保存できる。

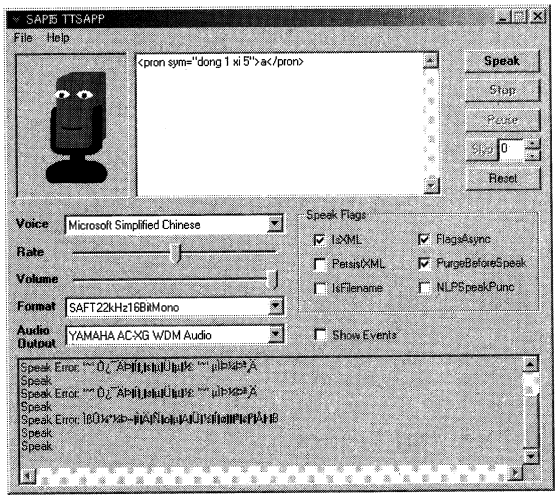

ところで、中国語の規範的な発音では、同じ「大意」という形態素でも、dàyi と発音すると「あらすじ」の意味、dàyi と軽声で読んだ場合は「うかつだ」という意味になる。このような微妙な差異を表すために、発音をマークアップする XML が準備されている。アルファベットと声調数値の間に空白が必要である点に注意せねばならない。

```
<pron sym="da 4 yi 4">a</pron>
<pron sym="da 4 yi 5">a</pron>
```

TTS エンジンに与えるデータのうち、pron 要素の sym 属性には使う文字はアルファベットと以下の記号である。

Symbol	PhoneID	Example
-	1	Syllable boundary (hyphen)
!	2	Sentence terminator (exclamation mark)
&	3	word boundary
,	4	Sentence terminator (comma)
.	5	Sentence terminator (period)
?	6	Sentence terminator (question mark)
_	7	Silence (underscore)
+	8	primary stress　これは英語のアクセント
*	9	secondary stress　英語のアクセント
1	10	Tone 1　これが第１声
2	11	Tone 2　これが第２声
3	12	Tone 3　これが第３声
4	13	Tone 4　これが第４声
5	14	Tone 5　これが軽声

(Microsoft Speech SDK SAPI 5.1 Chinese Phonemes　より抜粋)

これをスクリプトで制御するには以下のスクリプトを書けばよい。これを６節のスクリプトと連携させれば、音声付の単語テストを実現することができる。その際、入力用の pinyin2 の XML 要素を TTS の pron タグ sym 属性に代入できるように変換することも必要である。

```
<HTML><HEAD>
<TITLE>Speak Chinese</TITLE>
<SCRIPT LANGUAGE="JavaScript">
var V = new ActiveXObject("Sapi.SpVoice");
for (i=0;i<V.GetVoices().count;i++){
T = V.GetVoices().Item(i);
```

```
TT=T.GetDescription();
if (TT=="Microsoft Simplified Chinese"){V.Voice = V.GetVoices().Item(i);}
}
V.Rate = 5;
V.Volume = 100;
V.Speak("<pron sym='ni 2 hao 3'>a</pron>", 1 );
delete V;
</SCRIPT></HEAD><BODY>しゃべります。</BODY></HTML>
```

8. おわりに

XML データベースを使った、学習コンテンツは基本的に HTML ファイルと XML ファイルだけで構成されており、ブラウザーだけで実行できる。学習ソフトのインストールがいらない点では、教材を「配布」するように使うことができよう。また、ウェブサーバに載せた XML は、HTML のなかに書かれたスクリプトによってダウンロードされると、インターネットテンポラリーフォルダーの中に保存され、以降は回線が切れても使用可能である。DBMS との関連を意識せずとも、データベースを背景にしたコンテンツを公開できる点は注目すべきである。csv ファイルを操作する「データバインド」でも、この点は実現可能だが、XPath を使うことでより柔軟性を持たせることができる。ただし、本稿で紹介した方法はあくまでもクライアント側の技術であって、データをセレクトすることはできるものの、クライアントコンピュータに存在する情報をウェブ上のデータベースに集約することはできない。これは別に SQL をあつかえるサーバーサイドの技術によらねばならない。本稿で紹介した中国語学習コンテンツも成績の登録だけは ASP で書いている。

今後の課題としては、教材の組織化が必要である。現在は単純な単語ドリルであるが、学習者の習熟度を反映した内容にする必要がある。そのためには XML 構造も変更せねばならないだろう。また、1万件程度の大きな XML 文書を操作すると処理速度がおちるので対策が必要である。また、本稿で用いた DOM のほかに、SAX を使っても XML を操作できる。この点についても今後の課題としておく。

参考文献

- 松尾好洋『よくわかるトレーニングテキスト XML 認定資格取得講座』FOM 出版 2002 年
- 西谷亮「VBScript で XML プログラミング（2）DOM を使って目的の情報へダッシュ」2001/3/23（http://www.atmarkit.co.jp/fxml/rensai/msxml02/msxml01.html）
- 日本工業規格 JIS X 4159:2002　http://www.jsa.or.jp/