XML feldolgozás

Áttekintés

- XML -bevezetés
- (XML érvényességének vizsgálata (DTD, XSD))
- XML feldolgozók (DOM, SAX)
- XML transformációk (XSLT)

XML

- XML jelentése E**X**tensible **M**arkup **L**anguage (kiterjeszthető jelölő nyelv).

- főként adatreprezentációra alkalmas
- platformfüggetlen- illetve alkalmazástól független adatcserét tesz lehetővé
- a tag-ek nincsenek előre meghatározva
- az XML állományban tárolt adat szerkezete leírható DTD (Document Type Definition) vagy egy XML séma (XSD) segítségével
- új nyelv is definiálható a segítségével (lásd: WML)
- a W3C ajánlása (1998 február)

különbség a HTML-hez képest

- HTML célja - az adatok megjelenítése
- XML célja - az adatok (információ) leírása

XML szintaxis

- egyszerű, szigorú szintaktikai szabályok

XML deklaráció

- az első sor megadja az XML állomány verziószámát, illetve a használt kódolást:

```
<?xml version="1.0" encoding="ISO-8859-2"?>
```

PI.

```
<?xml version="1.0" encoding="ISO-8859-2"?>
<laborhazi sorszam="1">
 <a>ez a hazi a pontja</a>
 <b>ez pedig a b pont</b>
</laborhazi>
```

szintaktikai szabályok:

- minden XML elemnek kell legyen záró tag-je
- XML tag-ek esetén számít a kis- vagy nagybetű
- az XML tag-eket helyesen kell egymásba ágyazni (nem lehetnek egymásba ékelve)
- az XML dokumentumnak egy és csakis egy gyökér eleme lehet
- az attribútumok értékeit kötelező idézőjelbe (" vagy ') tenni
- a fehér karakterek nincsenek figyelmen kívül hagyva
- újsor kódolása: LF
- <!– – így néz ki egy XML megjegyzés – – >

- elemek közti viszonyok: szülő, gyerek, testvér (sibling)

elem felépítése:

- kezdő tag, törzs, záró tag (lehet üres is <tagnev . . . /tagnev>)
- az elemnek lehetnek attribútumai

XML névterek (Namespaces)

- a névterek a különböző XML állományokból származó, azonos nevű elemek esetében a névkonfliktus feloldására szolgálnak

Pl. - konfliktus

```
<ar>
  <penznem>Euro</penznem>
  <ertek>200</ertek>
</ar>
```

```
<ar>
  <ev>2007</ev>
  <vizszint> 7.5m </vizszint>
</ar>
```

Konfliktus feloldása előtag (prefix) használatával

```
<p:ar>
  <p:penznem>Euro
  </p:penznem>
  <p:ertek>200</p:ertek>
</p:ar>
```

```
<v:ar>
  <v:ev>2007</v:ev>
  <v:vizszint> 7.5m
  </v:vizszint>
</v:ar>
```

Konfliktus feloldása névtér használata segítségével

```
<p:ar xmlns:p="http://www.pl.ro/pl1/">
  <p:penznem>Euro</p:penznem>
  <p:ertek>200</p:ertek>
</p:ar>


<v:ar xmlns:v="http://www.pld2.ro/pl2/">
  <v:ev>2007</v:ev>
  <v:vizszint> 7.5m </v:vizszint>
</v:ar>
```

egy elem kezdő tag-jébe helyezett xmlns attribútum:

- szintaxisa: xmlns:namespace-prefix="namespaceURI"
- az illető elembe ágyazott összes elem, melynek ugyanaz a prefix-e, ugyanahhoz a névtérhez fog tartozni
- az URI csupán egy egyedi nevet rendel a névterülethez
- alapértelmezett névtér (prefix nélkül): xmlns="namespaceURI"

Jól formált illetve érvényes XML

- egy XML dokumentum *jól formált* (well formed): ha megfelel az XML szintaktikai szabályainak
- egy XML dokumentum *érvényes* (valid): ha jól formált, és megfelel a dokumentum séma definíciójának
  (pl. egy bizonyos DTD-ben vagy XML sémában –XSD– megadott szabályok)

DTD

DTD – Document Type Definition

- elterjedt séma-leíró módszer
- az XML dokumentum érvényes építőelemeit adja meg (elemek, attribútumok), illetve ennek felépítését
- szabványos, de nem XML alapú, ezért népszerűsége vszínűleg csökkenni fog

megadható:

- az XML állományon belül (ritkábban használt):
  <DOCTYPE gyoker-elem [elem-deklaraciok]>
- külön dtd kiterjesztésű állományban (lásd pl. a web.xml szerkezetét leíró DTD)

egy XML állomány alkotóelemei a DTD sémaleíró szempontjából:

- Elemek
- Attribútumok
- Egyedek (Entities) – speciális karakterkódok
  (pl. < – <, & – &, " – ", ' –')
- PCDATA – parsed character data
- CDATA – character data

elem deklarálása:

<!ELEMENT elem-nev kategoria>
vagy
<!ELEMENT elem-nev (elem-tartalom)>

- üres elem: <!ELEMENT elem-nev EMPTY>
- csak (feldolgozott) szöveget tartalmazó elem:
  <!ELEMENT elem-nev (#PCDATA)>
- bármilyen tartalommal rendelkező elem:
  <!ELEMENT elem-nev ANY>
- beágyazott (gyerek) elemeket tartalmazó elemek:
  <!ELEMENT elem-nev (gyerek1)>
  vagy
  <!ELEMENT elem-nev (gyerek1,gyerek2,...)>
- gyerek egyszeri előfordulása: <!ELEMENT elem-nev (gyerek-nev)>
- gyerek legalább egyszeri előfordulása:
  <!ELEMENT elem-nev (gyerek-nev+)>
- ...nulla vagy többszöri előfordulásnál: $*$, nulla vagy egyszeres előfordulásnál: ?
- ...felsorolásban szereplő "vagy": |

attribútum deklarálása:

szintaxis: <!ATTLIST elem-nev attributum-nev attributum-tipus alapertelmezett-ertek>

attributum-tipus lehetséges értékei:

- CDATA, felsorolás: (en1| en2 | . . .), ID, IDREF, IDREFS, NMTOKEN, NMTOKENS, ENTITY, ENTITIES, NOTATION, xml:

alapertelmezett-ertek lehetséges értékei:

- *ertek*, #REQUIRED, #IMPLIED, #FIXED *ertek*

egyedek (entities)

- belső egyed deklarálása <!ENTITY egyed-nev "egyed-ertek"> használata XML állományban: & egyed-nev;
- külső egyed deklarálása: <!ENTITY entity-name SYSTEM "URI/URL">

XML séma definíció

- XSD – XML Schema Definition
- a DTD-nek XML alapú alternatívája

egy XML séma:

- meghatározza, hogy milyen elemek szerepelhetnek egy dokumentumban
- milyen attribútumok szerepelhetnek egy dokumentumban
- milyen beágyazott (gyerek) elemek vannak
- meghatározza a gyerek elemek előfordulásának sorrendjét
- meghatározza a gyerek elemek számát
- meghatározza, hogy egy elem üres-e vagy tartalmazhat szöveget
- az elemek illetve attribútumok típusa is definiálható
- megadható az elemek illetve attribútumok alapértelmezett illetve rögzített értéke

előnyei a DTD-vel szemben:

- rugalmasabb, bővebb
- XML alapú
- megadható az adatok típusa
- névterek használata

XML séma gyökér eleme:

```
<?xml version="1.0"?>
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema"
targetNamespace="http://www.pltarget.com"
xmlns="http://www.pltarget.com"
...
</xs:schema>
```

a schema elem attribútumai (sorrendben):

- a sémában használt, előre definiált elemek és adattípusok névtere, illetve a prefix (xs), amivel használva lesznek
- ebben a sémában definiált elemek névtere
- alapértelmezett névtér (vagyis az itt definiált elmeket prefix nélkül adjuk meg)

Hivatkozás a sémára egy XML állományból:

```
<?xml version="1.0"?>
<ar xmlns="http://www.pl.ro/pl1/"
xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:schemaLocation="http://www.pl.ro/pl1/ arak.xsd" >
  <penznem>Euro</penznem>
  <ertek>200</ertek>
</ar>
```

egyszerű elem definíciója:

<xs:element name="xx" type="yy" />

- beépített típusok: xs:string, xs:decimal, xs:integer, xs:boolean, xs:date, xs:time

– egyszerű elemnek lehet
  alapértelmezett (default="...” – attribútum) vagy
  rögzített (fixed="...") értéke

attribútum definíciója:

<xs:attribute name="xx" type="yy" />

– az attribútumnak is lehet
  alapértelmezett (default="...” – attribútum) vagy
  rögzített (fixed="...") értéke
– ha kötelező: use="required"

Megszorítások (facets)

- megadhatjuk az elemek illetve attribútumok elfogadható értékeit megszorítások (facet) formájában

Pl. min. max. érték:

```
<xs:element name="ev">
<xs:simpleType>
  <xs:restriction base="xs:integer">
    <xs:minInclusive value="1990" />
    <xs:maxInclusive value="2007" />
  </xs:restriction>
</xs:simpleType>
</xs:element>
```

más megszorítások:

- felsorolás: <xs:enumeration value="ertek" />
- reguláris kifejezés: pl. <xs:pattern value="[a-z]" />
- fehér karakterekre vonatkozó megszorítások:
  <xs:whiteSpace value="preserve|replace|collapse" />
- hosszra vonatkozó megszorítások: <xs:length value="6" />
  (minLength, maxLength)
- stb.

- az egyszerű típushoz rendelhetünk nevet (name attribútum), ekkor elérhető lesz más elem számára is

Összetett (komplex) elemtípus:

- más beágyazott elemeket és/vagy attribútumokat is tartalmazó elemek

összetett elem-típusok:

- üres (törzs nélküli) elemek
- csak más beágyazott elemeket tartalmazó elemek
- csak szöveget tartalmazó elemek
- szöveget, illetve más elemeket is tartalmazó elemek

– mindeniknek lehet attribútuma is

- <any> illetve <anyAttribute> elemek segítségével kibővíthetővé tehetjük a dokumentumot

Összetett elem definíciója (pl.):

```
<xs:element name="ar">
  <xs:complexType>
    <xs:sequence>
      <xs:element name="penznem" type="xs:string" />
      <xs:element name="ertek" type="xs:integer" />
    </xs:sequence>
  </xs:complexType>
</xs:element>
```

- a sequence elem meghatározza, hogy a felsorolt beágyazott elemek a megadott sorrendben kell szerepeljenek
- itt is rendelhetünk nevet az összetett típushoz
- már definiált összetett típus kiterjeszthető további elemekkel, illetve attribútumokkal

Indikátorok

sorrendet meghatározó indikátorok:

- All – a beágyazott elemek bármilyen sorrendben előfordulhatnak
- Choice – egyik vagy másik
- Sequence – az elemek csak a megadott sorrendben fordulhatnak elő

előfordulást meghatározó indikátorok:

- maxOccurs
- minOccurs

csoport indikátorok:

– csoportosíthatjuk az egyes elemeket illetve attribútumokat:

- Group name
- attributeGroup name

XML feldolgozók (parser) – DOM

- XML DOM: XML Document Object Model – az XML dokumentumok feldolgozásához biztosít egy standard API-t.
- a DOM az XML dokumentumot egy fa-szerkezet formájában ábrázolja, melynek csomópontjai az elemek, attribútumok, illetve szövegrészek.

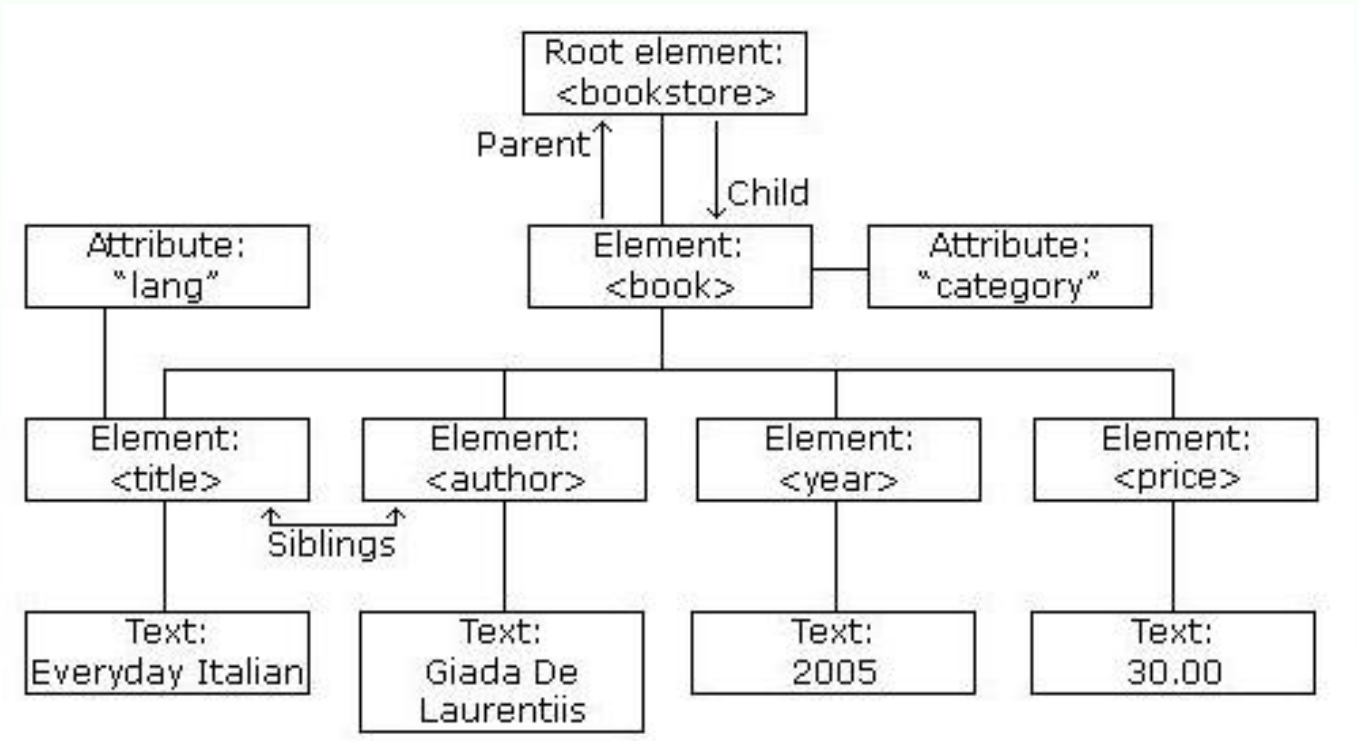

jellemzők:

- az XML DOM (Document Object Model for XML) – objektum modellt definiál az XML dokumentumhoz
- az XML DOM platform- illetve nyelvfüggetlen
- az XML DOM standard hozzáférésmódot biztosít az XML dokumentumokhoz (olvasás, módosítás)
- az XML DOM W3C standard

hozzáférés az egyes csomópontokhoz:

- getElementsByTagName("tag-nev") metódus segítségével – csomópontok listáját téríti vissza
- parentNode, firstChild, lastChild mezőket használva
- gyökér elem: document.documentElement

információ az illető csomópontról az alábbi mezőkben:

- nodeName
- nodeValue
- nodeType

- egy elem *attributes* mezője az attribútumokat tartalmazza map formájában (NamedNodeMap)

lásd pl.

DomParserExample, XMLCreatorExample

XML feldolgozók (parser) – SAX

SAX – Simple API for XML:

- XML dokumentumok szekvenciális feldolgozására szolgáló API.
- a DOM egy igen elterjedt alternatívája
- a DOM-tól eltérően nincs neki megfelelő formális specifikáció (a Java implementációt tekintik iránymutatónak a SAX-ot implementáló többi platformok)

SAX feldolgozó (parser)

- Egy SAX-ot implementáló feldolgozó *adatfolyam feldolgozó*ként (parser) működik, eseményvezérelt API-val.
- Az egyes eseményekre a felhasználó által definiált ún. "callback"-metódusokat fogja meghívni a feldogozó.
- A feldolgozás egyirányú: a már feldolgozott adatot nem lehet újraolvasni (csak ha újrakezdjük a feldolgozást)

SAX

SAX események:

Egy-egy esemény generálódik az alábbi elemek feldolgozásának kezdetén illetve végén:

- szöveget tartalmazó XML csomópontok (Text nodes)
- XML elem csomópontok
- XML feldolgozó utasítások
- XML megjegyzések

az attribútumok az elemet feldolgozó megfelelő callback metódus paramétereként lesznek elérhetőek

előnyök a DOM-al szemben:

- lényegesen kevesebb memóriát vesz igénybe, mint a DOM (ennek esetében a teljes fastruktúrát tartalmazó objektum betöltődik a memóriába)
- gyorsabb feldolgozást tesz lehetővé
- ha a dokumentum mérete akkora, hogy a neki megfelelő objektum nem férne be a memóriába, akkor DOM-al nem dolgozható fel

hátrányok a DOM-al szemben:

- SAX-al nem tudjuk módosítani/lementeni a forrás XML állományt, csak szekvenciálisan feldolgozni
- ezzel szemben DOM-al bármikor hozzáférhető bármelyik csomópont, módosítható, illetve file-ba lementhető

lásd pl.

SAXParserExample

XSL

- XSL – E**X**tensible **S**tylesheet **L**anguage
- XML alapú stílusállomány
- egy XSL állomány leírja, hogy az XML dokumentumot hogyan kell megjeleníteni
- AZ XSL több, mint stílus-leíró nyelv

az XSL három részből áll:

- XSLT - az XML dokumentumok transzformálására szolgáló nyelv
- XPath - XML dokumentumok bejárására, lekérdezésére szolgáló nyelv
- XSL-FO - XML dokumentumok formázására szolgáló nyelv

XPath

az XPath - az XML dokumentumok bejárását, adatok lekérdezését lehetővé tevő nyelv.

az XPath jellemzői:

- az XPath egy szintaxist ad az XML dokumentumok egyes részeinek meghatározására
- kifejezéseket használ az XML dokumentum bejárására
- tartalmaz egy standard függvénykönyvtárat
- az XPath is W3C standard

XPath elérési utat megadó kifejezések (Path Expressions):

- az XPath kifejezéseket használ az egyes csomópontok vagy csomópont-halmazok elérésére/kiválasztására

XPath standard függvények

- több, mint 100 beépített függvényt használ (string-értékek, numerikus adatok, dátum, idő feldolgozása, stb.)

csomópont-típusok:

elem, attribútum, szöveg, névtér, feldolgozó utasítás, megjegyzés, document (gyökér) csomópont.

XSLT

Az XSLT az XML dokumentumok XHTML vagy más XML dokumentummá való transzformálását teszi lehetővé.

XSLT jellemzői:

- XSLT – XSL Transformations (XSL átalakítások)
- az XSL legfontosabb része
- XPath-ot használ az XML dokumentumok bejárására
- W3C ajánlás (1999. novembertől)

- fogalmazhatunk úgy, hogy az XSLT az XML forrás-fát áttranszformálja egy XML eredmény-fává

működési elve:

- a transzformáció során az XSLT az XPath-ot használja arra, hogy meghatározza a forrás dokumentum azon részeit, melyek egy vagy több előredefiniált sablonra (template) illeszkednek
- illeszkedés esetén az XSLT áttranszformálja a forrás dokumentum illeszkedő részét az eredmény dokumentummá

XSL deklaráció:

```
< xsl:stylesheet version="1.0"
xmlns:xsl="http://www.w3.org/1999/XSL/Transform" >
```

vagy:

```
< xsl:transform version="1.0"
xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
```

- Egy XSL stílusállomány szabályok összességéből épül fel – ezeket sablonoknak (template) nevezzük.
- Az egyes sablonok arra vonatkozó szabályokat tartalmaznak, hogy mi történjen, ha egy illeszkedő csomópontot találunk.

Az <xsl:template> elem

- Az <xsl:template> elem segítségével határozhatunk meg egy sablont.
- A *match* attribútum segítségével feleltethetünk meg egy sablont egy XML elemmel.
- Szintén a match attribútum segítségével lehet megadni a teljes XML dokumentumra illeszkedő sablont (match="/").

a <xsl:value-of> elem

A <xsl:value-of> elemet használjuk arra, hogy egy csomópont értékét kinyerjük

<xsl:for-each> elem

A <xsl:for-each> elem lehetővé teszi, hogy ciklusban hajtsuk végre a transzformációt.

a kimenetet szűrhetjük azáltal, hogy különböző kritériumokat rendelünk a select attribútumhoz a <xsl:for-each> elemen belül:
<xsl:for-each select="catalog/cd[artist='Gryllus Vilmos']">

Érvényes szűrő (filter) műveletek:

- =
- !=
- < (kisebb)
- > (nagyobb)

<xsl:sort> elem

A kimenet rendezése a <xsl:sort> elem segítségével történik (az <xsl:for-each> elemen belül).

<xsl:if> elem

Az <xsl:if> elem segítségével valamilyn feltételt szabhatunk az XML tartalmával kapcsolatban.

```
<xsl:if test="expression">
...szoveg amennyiben a kifejezes igaz ...
</xsl:if>
```

<xsl:choose> elem

Az <xsl:choose> elemet együtt használjuk az <xsl:when> és <xsl:otherwise> elemekkel.

<xsl:apply-templates> elem

Az <xsl:apply-templates> elem alkalmazza a sablont az aktuális elemre vagy ennek gyerek-csomópontjaira.

lásd pl.

SimpleXSLTTransform, SimpleTransformXSLTServlet

Tipp Web-alkalmazásban való használatra:

HTML-t generálhatunk szerver oldalon XSLT segítségével – adatok megmutatására (pl. report generálás), form generálására is használható

XML Editor-ok

A specializált XML szerkesztők segítenek

- a hibamentes XML dokumentumok szerkesztésében
- XML érvényességének vizsgálatában
- rákényszeríthetnek, hogy egy megadott XML struktúra szabályait betartsuk

pl. XMLSpy, XMLNotepad 2007 (XML szerkesztők)