Az XML 1.0 ajánlás

Jeszenszky Péter
Debreceni Egyetem, Informatikai Kar
jeszenszky.peter@inf.unideb.hu

Utolsó módosítás: 2025. szeptember 9.

Szabvány

- Az aktuális szabvány:
  - *Extensible Markup Language (XML) 1.0 (Fifth Edition)* (W3C ajánlás, 2008. november 26.) https://www.w3.org/TR/xml/
- Leírja az XML dokumentumoknak nevezett objektumokat és részben előírja az ezeket feldolgozó programok viselkedését.

XML dokumentumok

- Olyan szöveges objektumok, melyek a szabvány előírásai szerint jólformáltak.
- Fizikai és logikai szerkezetük van.
  - Fizikailag egyedeknek nevezett tárolási egységekből állnak.
  - Logikailag deklarációkból, elemekből, megjegyzésekből, feldolgozási utasításokból és további szerkezeti alkotóelemekből állnak.

Elemek (1)

- Minden elemet nyitó és záró címke határol vagy egyetlen üres elem címke alkot.
  - Példák:

```
<author>Sir Arthur Conan Doyle</author>

<message xml:lang="en">Hello, World!</message>

<img src="logo.png" alt="Logo"/>
```

Elemek (2)

- A nyitó, záró és üres elem címkében adott nevet elemtípusnak nevezzük.
  - **Jólformáltsági megszorítás**: a nyitó és záró címkében adott nevek meg kell, hogy egyezzenek.
- A nyitó és a záró címke fogja közre az elem tartalmát.
- Az elemekhez meg lehet adni attribútum-specifikációknak nevezett név-érték párokat.

Elemek (3)

- Az üres elem tartalom nélküli elem.
  - Megadható közvetlenül egymást követő nyitó és záró címkével vagy üres elem címkével.
    - Példa: `<elem></elem>`, `<elem/>`

Jólformáltság

- Nagyjából az alábbiakat jelenti:
  - Egyetlen felső szintű elem, az úgynevezett **gyökérelem** tartalmazza az összes többi elemet.
  - Minden nyitó címkéhez tartozik egy megfelelő záró címke.
  - Az elemek megfelelő módon egymásba ágyazottak, nem fedhetik át egymást.
  - Minden a dokumentumban hivatkozott elemzett egyed jólformált.
- Sok további követelménynek – úgynevezett **jólformáltsági megszorítás**nak – kell teljesülnie.

Karakterek

- Az XML dokumentumok Unicode karakterekből állnak.
- Minden XML feldolgozó kötelezően kell, hogy támogassa az UTF-8 és UTF-16 kódolásokat.

Whitespace karakterek (1)

- *Whitespace* karakterek az alábbiak:
  - U+0009 (vízszintes tabulátor, `'\t'`)
  - U+000A (új sor, LF, `'\n'`)
  - U+000D („kocsi vissza”, CR, `'\r'`)
  - U+0020 (szóköz)

Whitespace karakterek (2)

- XML dokumentumok szerkesztésekor szokás az elemek egymásba ágyazottságát az emberi szem számára jól átláthatóan mutató *whitespace* karaktereket használni.
  - A sorok elején megfelelő számú szóköz vagy vízszintes tabulátor karakterek elhelyezése.
- Ezek a *whitespace* karakterek az alkalmazások számára általában nem lényegesek.

Whitespace karakterek (3)

- Példa:

```
<?xml version="1.0" encoding="UTF-8"?>
<movie id="0078748"><title xml:lang="en">Alien</title>
<year>1979</year><genres><genre>horror</genre>
<genre>sci-fi</genre></genres></movie>
```

```
<?xml version="1.0" encoding="UTF-8"?>
<movie id="0078748">
  <title xml:lang="en">Alien</title>
  <year>1979</year>
  <genres>
    <genre>horror</genre>
    <genre>sci-fi</genre>
  </genres>
</movie>
```

Névkarakterek

- A nevekben megengedett karakterek pontos felsorolását lásd a szabványban.
  - Megengedettek a betű és a decimális számjegy karakterek.
  - A programozási nyelvekben megszokott `'_'` karakter mellett a `'.'`, `'-'`, `':'` és `'·'` (U+00B7) karakterek is rendelkezésre állnak.
- **Névtoken**: egy vagy több névkarakterből álló karaktersorozat.

Nevek (1)

- Olyan névtokenek, melyek első karakterei csak a szabványban megadott karakterek lehetnek.
  - Nem kezdődhetnek például számjegy, `'-'`, `'.'` és `'·'` (U+00B7) karakterrel sem.
- Névben szereplő `':'` karakter speciális jelentést nyer az XML névterek specifikáció révén.
  - Kizárólag ennek megfelelően használjuk ezt a karaktert!

Nevek (2)

- Nevek például az alábbi karakterláncok:
  - `születési.dátum`
  - `születési-dátum`
  - `jaxb:version`
  - `elem1`, `elem2`, `elem3`, …
  - `β0`
  - `_` (igen, akár egyetlen aláhúzójel is!)
  - `_-_-_` (igen, akár ez is!)
- Nem nevek például az alábbi karakterláncok:
  - `1st`, `2nd`, `3rd`, … (mert név nem kezdődhet számjegy karakterrel)
  - `on/off` (mert név nem tartalmazhat `'/'` karaktert)

Nevek (3)

- A nevek (például az elem és attribútumnevek) kisbetű-nagybetű érzékenyek az XML-ben.
  - Például a `title`, `Title` és `TITLE` különböző nevek.

Literálok

- `'"'` vagy `'''` karakterek által határolt karaktersorozatok, melyek nem tartalmazzák magát a határoló karaktert.
  - Példa: `"/style.css"`, `'/style.css'`
- Használatuk például az alábbiak megadásánál:
  - Attribútumértékek
  - Belső egyedek tartalma

Jelölők

- Nyitó, záró és üres elem címke
- Karakterhivatkozás
- Egyedhivatkozás
- Megjegyzés
- Feldolgozási utasítás
- CDATA-szakasz határolók
- XML deklaráció
- Szövegdeklaráció
- Dokumentumtípus- deklaráció

Karakteres adat

- A dokumentum szövegének az a része, mely nem jelölő.

Szöveg nyelvének jelzése (1)

- Az `xml:lang` attribútummal jelezhető az elemek tartalmának és attribútumértékeink nyelve.
  - Érvényes dokumentumokban az attribútumot a DTD-ben kell deklarálni használat esetén.
  - Az attribútum az elemre és gyermekeire is vonatkozik (beleértve az elem attribútumainak értékeit), azonban a gyermekeknél is megadható más értékkel (lyuk a hatáskörben).

Szöveg nyelvének jelzése (2)

- Az attribútum értéke egy természetes nyelvet azonosító címke kell, hogy legyen, a címkéket az alábbi szabvány definiálja:
  - Addison Phillips (ed.), Mark Davis (ed.). *Tags for Identifying Languages.* RFC 5646, September 2009. https://www.rfc-editor.org/rfc/rfc5646
- Példák az attribútum értékére: `de-AT`, `en-US`, `hu`, `az-Arab`, `az-Cyrl`, `az-Latn`, ...
- Speciálisan megadható az üres karakterlánc annak jelzésére, hogy nem áll rendelkezésre információ a nyelvről.
  - Mintha az `xml:lang` attribútum egyáltalán nem került volna megadásra az elemen vagy valamely felmenőjén.

Szöveg nyelvének jelzése (3)

- Példa:
  - `<para xml:lang="en">The more <phrase xml:lang="fr">outré</phrase> and grotesque an incident is the more carefully it deserves to be examined, and the very point which appears to complicate a case is, when duly considered and scientifically handled, the one which is most likely to elucidate it.</para>`
    - Arthur Conan Doyle, *The Hound of the Baskervilles*.

Speciális karakterek

- Az `'&'` és `'<'` karakterek ebben a formában kizárólag jelölő-határolóként, megjegyzésekben, feldolgozási utasításokban és CDATA-szakaszokban fordulhatnak elő.
  - Helyettünk minden egyéb helyen karakterhivatkozásokat, illetve az `&` és `<` egyedhivatkozásokat kell használni!
  - A `'>'` karakter megadható az `>` egyedhivatkozással.
- Hogy attribútumértékek is tartalmazhassanak aposztrófokat és idézőjeleket, az `'''` és `'"'` karakterek megadhatók az `&apos;` és `&quot;` egyedhivatkozásokkal.

Nyitó, záró és üres elem címke (1)

- **Nyitó címke**:
  - Példa: `<title>`, `<title xml:lang="en">`
- **Záró címke**:
  - Példa: `</title>`
- **Üres elem címke**:
  - Példa: `<br/>`, `<hr />`, `<img src="logo.png" alt="Logo"/>`

Nyitó, záró és üres elem címke (2)

- **Jólformáltsági megszorítás**: nyitó és üres elem címkében minden attribútumnév legfeljebb egyszer szerepelhet.
- Lényegtelen az attribútumok megadásának sorrendje.

Karakterhivatkozások

- Szövegben, attribútum értékekben és literális egyed értékekben Unicode karakterek kifejezhetők az alábbi formájú karakterhivatkozásokkal:
  - &#*nnnn*;, ahol *nnnn* a kódpontot ábrázoló decimális számjegysorozat.
    - Példa: `&#169;` (©), `&#9775;` ( ), `&#128570;`
  - &#x*hhhh*;, ahol *hhhh* a kódpontot ábrázoló hexadecimális számjegysorozat.
    - Példa: `&#xA9;` (©), `&#x262F;` ( ), `&#x1F63A;`

Egyedhivatkozások

- Hivatkozás egy névvel azonosított egyed tartalmára.
  - Hivatkozás elemzett általános egyedre: *&név* ;
    - Példa: `&`, `&Aacute;`, `&copyright;`
  - Paraméteregyed-hivatkozás: *%név*;
    - Példa: `%inline;`, `%ImgAlign;`
- Az egyedhivatkozásokról részletesen később, a dokumentum fizikai szerkezete kapcsán lesz szó.

Megjegyzések

- A dokumentumban bárhol szerepelhetnek más jelölőkön kívül.
  - Az egyetlen kivétel a dokumentumtípus-deklaráció, melyben bizonyos helyeken előfordulhatnak.
- Példa:
  - `<!-- Ez egy megjegyzés -->`

Feldolgozási utasítások

- Az alkalmazások számára tartalmaznak utasításokat.
- Példa:
  - `<?xml-stylesheet type="text/css" href="style.css"?>`

CDATA-szakaszok

- Bárhol előfordulhatnak a dokumentumban, ahol előfordulhat karakteres adat.
  - Olyan karaktereket tartalmazó szövegrészek levédésére szolgálnak, melyek egyébként jelölőként lennének tekintve.
  - A CDATA-részben csak a `']]>'` karakterlánc tekintett jelölőnek.
- Példa:
  - `<![CDATA[if (0 < n && n <= 10)]]>`

XML deklaráció

- Az XML dokumentumoknak egy XML deklarációval ajánlott kezdődniük, mely meghatározza az XML használt verziószámát.
  - A karakterkódolást meg kell adni, ha a használt kódolás nem az UTF-8 vagy az UTF-16, kivéve ha a kódolást egy magasabb szintű protokoll (például a HTTP) határozza meg.
- Példa:
  - `<?xml version="1.0"?>`
  - `<?xml version='1.0' encoding='UTF-8'?>`

Dokumentumtípus-deklaráció (1)

- Dokumentumok egy osztályához egy nyelvtant meghatározó jelölő deklarációkat tartalmaz és/vagy ilyen deklarációkra mutat.
  - Ezt a nyelvtant **dokumentumtípus-definíció**nak (vagy röviden DTD-nek) nevezik.
- A név a dokumentumtípus-deklarációban a gyökérelem elemtípusát írja elő.

Dokumentumtípus-deklaráció (2)

- Egy **külső DTD alkészlet**nek nevezett, jelölő deklarációkat tartalmazó külső egyedre mutató dokumentumtípus-deklaráció:
  - `<!DOCTYPE score-partwise SYSTEM "http://www.musicxml.org/dtds/partwise.dtd">`
  - `<!DOCTYPE score-partwise SYSTEM "partwise.dtd">`
  - `<!DOCTYPE score-partwise PUBLIC "-//Recordare//DTD MusicXML 3.1 Partwise//EN" "http://www.musicxml.org/dtds/partwise.dtd">`
- A fenti példák a MusicXML DTD-t használják.
  - Lásd: https://www.musicxml.com/

Dokumentumtípus-deklaráció (3)

- Jelölő deklarációkat – az úgynevezett **belső DTD alkészlet**et – tartalmazó dokumentumtípus-deklaráció:
  -
```
<!DOCTYPE message [
   <!ELEMENT message (#PCDATA)>
   <!ATTLIST message
      xml:lang CDATA #IMPLIED>
]>
```

Dokumentumtípus-deklaráció (4)

- Egy külső DTD alkészletre mutató dokumentumtípus-deklaráció, mely belső DTD alkészletet is tartalmaz:
  -
```
<!DOCTYPE play SYSTEM "play.dtd" [
  <!ENTITY r "Rosencrantz">
  <!ENTITY g "Guildenstern">
  <!ENTITY rag "&r; and &g;">
]>
```

Dokumentumtípus-definíció (1)

- Lehetővé teszi megszorítások előírását a dokumentum logikai szerkezetére, valamint tárolási egységek használatát támogatja.
- Jelölő deklarációkból áll.

Dokumentumtípus-definíció (2)

- A dokumentumtípus-deklarációban társítható egy dokumentumhoz.
  - A dokumentumtípus-deklaráció mutathat egy külső DTD alkészletre, tartalmazhat egy belső DTD alkészletet, vagy teheti mindkettőt.
- A két alkészlet együtt alkotja egy dokumentum DTD-jét.
  - Ha a külső és belső alkészlet is van, akkor a belső alkészlet megelőzi a külső alkészletet.
    - Ez lehetővé teszi a külső alkészletben lévő egyed- és attribútumlista-deklarációk felülírását.

Érvényesség (1)

- Egy XML dokumentum érvényes akkor, ha tartozik hozzá dokumentumtípus-deklaráció és a dokumentum eleget tesz a DTD által kifejezett megszorításoknak.
  - A specifikáció pontosan előírja, hogy mely megszorítások kell, hogy teljesüljenek. Ezek az úgynevezett **érvényességi megszorítás**ok.
  - Az érvényességi megszorítások megsértése hiba.

Érvényesség (2)

- Nagyjából az alábbiakat jelenti:
  - A dokumentumtípus-deklarációban adott név meg kell, hogy egyezzen a gyökérelem elemtípusával.
  - A dokumentum minden egyes eleme deklarált kell, hogy legyen a DTD-ben és az elem tartalma meg kell, hogy feleljen a deklarációnak.
  - A dokumentum minden egyes attribútuma deklarált kell, hogy legyen a DTD-ben és az attribútum értéke meg kell, hogy feleljen a deklarációnak.
  - Ha egy attribútum kötelezőnek deklarált a DTD-ben, akkor az elemtípus minden egyes előfordulásához explicit módon meg kell adni a dokumentumban.

Jelölő deklarációk

- Elemtípus-deklaráció
- Attribútumlista-deklaráció
- Egyeddeklaráció

Elemtípus-deklaráció

- Egy elemtípus-deklaráció megszorítást ír elő az elem tartalmára.
- **Érvényességi megszorítás**: egy elemtípus nem deklarálható egynél többször.

Elemtípus-deklaráció: üres elemek

- **Érvényességi megszorítás**: az így deklarált elemeknek nem lehet tartalma.
- Példa üres elem deklarálására és használatára:

```
<!ELEMENT br EMPTY>
…
<br/>
<br></br>
```

Elemtípus-deklaráció: elemtartalom (1)

- Egy elemtípus elemtartalmú, ha az ilyen típusú elemek csak elemgyermekeket tartalmazhatnak (karakteres adatot nem), melyek opcionálisan *whitespace* karakterekkel választhatók el.
  - Megjegyzések és feldolgozási utasítások is megengedettek az elemgyermekek között.
- A deklaráció egy **tartalommodell**t határoz meg, egy olyan egyszerű nyelvtant, mely az elemgyermekek típusát és ezek megengedett sorrendjét szabályozza.
  - A tartalommodell egy reguláris kifejezéshez hasonló minta.

Elemtípus-deklaráció: elemtartalom (2)

- Tartalommodell megadásánál használható konstrukciók:
  - Sorozat, mint például
    ```
    (street, city, zip, country)
    ```
  - Alternatíva lista, mint például
    ```
    (ul | ol | dl)
    ```
- Az előfordulások számát szabályozó speciális karakterek (a megelőző részkifejezésre vonatkoznak):
  - **?**: nulla vagy egy (0, 1) előfordulás
  - **+**: tetszőleges számú, de legalább egy (1, 2, 3, …) előfordulás
  - *****: tetszőleges számú (0, 1, 2, …) előfordulás
- Összetett kifejezések alkothatók ezekből a konstrukciókból.

Elemtípus-deklaráció: elemtartalom (3)

- Tegyük fel, hogy az `f`, `g` és `h` elemek üresként deklaráltak.

Deklaráció	The content of e	Az e elem érvényes példányai
`<!ELEMENT e (f)>`	Pontosan egy `f` elem	`<e><f/></e>`
`<!ELEMENT e (f?)>`	0 vagy 1 `f` elem	`<e></e>` `<e><f/></e>`

`<!ELEMENT e (f+)>`	1 vagy több `f` elem	`<e><f/></e>`
		`<e><f/><f/></e>`
		`<e><f/><f/><f/></e>`
		…

`<!ELEMENT e (f*)>`	0 vagy több `f` elem	`<e></e>`
		`<e><f/></e>`
		`<e><f/><f/></e>`
		…

`<!ELEMENT e (f,g,h)>`	Egy `f`, egy `g` és egy `h` elem, ebben a sorrendben	`<e><f/><g/><h/></e>`

`<!ELEMENT e (f|g|h)>`	Pontosan egy `f`, `g` vagy `h` elem	`<e><f/></e>`
		`<e><g/></e>`
		`<e><h/></e>`

Elemtípus-deklaráció: elemtartalom (4)

- **Példa**: olyan a elem deklarálása, mely páros (0, 2, 4, …) számú b elemet kell, hogy tartalmazzon:
  - `<!ELEMENT a (b,b)*>`
- **Példa**: olyan a elem deklarálása, mely páratlan (1, 3, 5, …) számú b elemet kell, hogy tartalmazzon:
  - `<!ELEMENT a (b,(b,b)*)>`
- **Példa**: olyan a elem deklarálása, mely 1, 2 vagy 3 b elemet kell, hogy tartalmazzon:
  - `<!ELEMENT a (b,(b,b?)?)>`

Elemtípus-deklaráció: elemtartalom (5)

- **Érvényességi megszorítás**: az így deklarált elemek tartalma meg kell, hogy feleljen a deklaráció tartalommodelljének.
  - Az első elemgyermek előtt, az elemgyermekek között és az utolsó elemgyermek után megengedettek *whitespace* karakterek, megjegyzések és feldolgozási utasítások.

Elemtípus-deklaráció: vegyes tartalom (1)

- Egy elemtípus vegyes tartalmú, ha az ilyen típusú elemek karakteres adatot tartalmazhatnak elemgyermekekkel vegyítve.
  - Korlátozható az elemgyermekek típusa, de a sorrendjük és az előfordulási számuk nem.

Elemtípus-deklaráció: vegyes tartalom (2)

- Példa vegyes tartalmú elem deklarálására és használatára:

```
<!ELEMENT para (#PCDATA | link)*>
<!ELEMENT link (#PCDATA)>
…
<para>See
  <link>https://sass-lang.com/</link>
  and
  <link>https://stylus-lang.com/</link>.
</para>
```

Elemtípus-deklaráció: vegyes tartalom (3)

- **Érvényességi megszorítás**: az egyedhivatkozások a helyettesítő szövegükkel történő helyettesítése után az így deklarált elemek karakteres adatot, CDATA-szakaszokat, megjegyzéseket, feldolgozási utasításokat kell, hogy tartalmazzanak, valamint olyan elemgyermekeket, melyek típusa megegyezik a tartalommodellben adott nevekkel.
- **Érvényességi megszorítás**: ugyanaz a név nem szerepelhet egynél többször a deklarációban.

Elemtípus-deklaráció: csak szöveget tartalmazó elem (1)

- A vegyes tartalmú deklaráció egy speciális esete szolgál csak szöveget tartalmazó elem deklarálására.
- Példa:

```
<!ELEMENT title (#PCDATA)>
…
<title>Angels &amp;amp; Demons</title>
```

Elemtípus-deklaráció: csak szöveget tartalmazó elem (2)

- **Érvényességi megszorítás**: az egyedhivatkozások a helyettesítő szövegükkel történő helyettesítése után az így deklarált elemek karakteres adatot (beleértve a CDATA-szakaszokat), megjegyzéseket és feldolgozási utasításokat kell, hogy tartalmazzanak.

Elemtípus-deklaráció: gyakorlati példa (1)

- Tartalommodellekel mélyen egymásba ágyazott dokumentum struktúrák is leírhatók.
- Példa: bináris kifejezésfa
  - Az (1280 + (23.85 * 312.63)) / 2 aritmetikai kifejezést ábrázoló kifejezésfa:

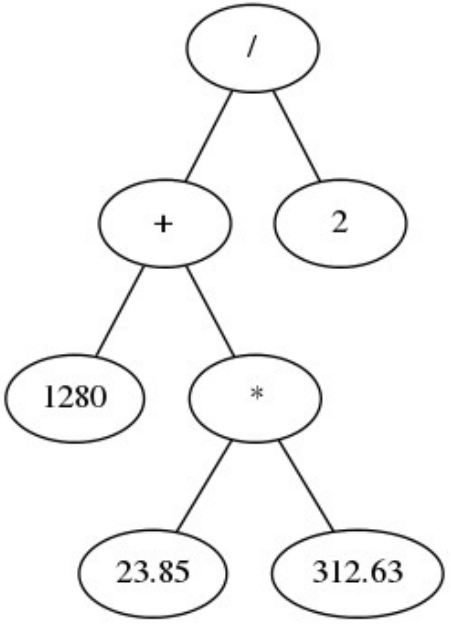

Elemtípus-deklaráció: gyakorlati példa (2)

- `expression.dtd`:

```
<!ELEMENT node ((node | number), (node | number))>
<!ATTLIST node
  op CDATA #REQUIRED>

<!ELEMENT number (#PCDATA)>
```

Elemtípus-deklaráció: gyakorlati példa (3)

- `expression.xml`:

```
<?xml version="1.0"?>
<!DOCTYPE node SYSTEM "expression.dtd">
<node op="/">
    <node op="+">
        <number>1280</number>
        <node op="*">
            <number>23.85</number>
            <number>312.63</number>
        </node>
    </node>
    <number>2</number>
</node>
```

Attribútumlista-deklarációk (1)

- Egy adott elemtípushoz tartozó attribútumok nevét, típusát és alapértelmezett értékét (ha van ilyen) adják meg.
- Egy elemtípushoz egynél több is megadható, ezek tartalma összefésülésre kerül.
- Ha egynél több definíció kerül megadásra egy elemtípus ugyanazon attribútumához, akkor az első deklaráció kerül felhasználásra, a továbbiak pedig figyelmen kívül hagyásra kerülnek.
- Nem hiba egy nem deklarált elemtípushoz attribútumokat deklarálni.

Attribútumlista-deklarációk (2)

- A következő szintaxisúak:
  `<!ATTLIST` *név*
  (*név típus alapértelmezett_érték*)*>
  - Az első név a deklarációban egy elem típusa.
  - A nevet olyan hármasok követik, melyek mindegyike egy attribútumot deklarál az adott elemtípushoz.
    - A hármasok egy attribútumnévből, attribútumtípusból és egy alapértelmezett érték deklarációból állnak.

Attribútumlista-deklarációk (3)

- Példák:

```
<!ATTLIST item id ID #REQUIRED>

<!ATTLIST property
   name CDATA #REQUIRED
   value CDATA #REQUIRED>

<!ATTLIST answer correct (yes|no) "no">

<!ATTLIST todoList
   xmlns CDATA #FIXED
     "http://www.example.com/todoList">
```

Attribútumtípusok

- Az attribútumtípusoknak három fajtája van:
  - **Sztring típus** (`CDATA`)
  - **Tokenizált típusok** (`ID`, `IDREF`, `IDREFS`, `NMTOKEN`, `NMTOKENS`)
  - **Felsorolt típusok** (felsorolások)
- A `CDATA` típusú attribútumok tetszőleges literális sztringet felvehetnek értékül.
- A többi típus érvényességi megszorításokat ír elő az attribútumértékekre.
  - Ezeknek az érvényességi megszorításoknak az ellenőrzése az attribútumérték normalizálása után történik.

Attribútumtípusok: ID

- **Érvényességi megszorítás**: az `ID` típusú attribútumértékek olyan nevek kell, hogy legyenek, melyek nem fordulnak elő egy XML dokumentumban egynél többször ilyen típusú attribútumértékként.
  - Az `ID` értékek tehát egyértelműen kell, hogy azonosítsák az őket hordozó elemeket.
- **Érvényességi megszorítás**: egy elemtípushoz nem adható meg egynél több `ID` típusú attribútum.
- **Érvényességi megszorítás**: egy `ID` típusú attribútumhoz alapértelmezett érték deklarációként `#IMPLIED` vagy `#REQUIRED` kötelező.

Attribútumtípusok: IDREF, IDREFS

- **Érvényességi megszorítás**: az `IDREF` típusú attribútumértékek olyan nevek kell, hogy legyenek, melyek megegyeznek az XML dokumentumban valamely elem egy `ID` típusú attribútumának értékével.
- **Érvényességi megszorítás**: az `IDREFS` típusú attribútumértékek egy vagy több név szóközökkel elválasztott olyan listái kell, hogy legyenek, ahol minden egyes név megegyezik az XML dokumentumban valamely elem egy `ID` típusú attribútumának értékével.

Attribútumtípusok: NMTOKEN, NMTOKENS

- **Érvényességi megszorítás**: az `NMTOKEN` típusú attribútumértékek névtokenek kell, hogy legyenek.
- **Érvényességi megszorítás**: az `NMTOKENS` típusú attribútumértékek egy vagy több névtoken szóközökkel elválasztott listái kell, hogy legyenek.

Attribútumtípusok: felsorolások

- A felsorolt attribútumok deklarációja tartalmazza a megengedett értékeket.
- **Érvényességi megszorítás**: a deklarációban a névtokenek mind különbözőek kell, hogy legyenek.
- **Érvényességi megszorítás**: az ilyen típusú attribútumértékek meg kell, hogy egyezzenek a deklarációban szereplő valamely névtokennel.

Alapértelmezett attribútumérték (1)

- Az alapértelmezett érték deklaráció információt szolgáltat arról, hogy kötelező-e az attribútum megadása, és ha nem, hogyan reagáljon egy XML feldolgozó, ha az attribútum hiányzik a dokumentumban.
- A következő választási lehetőségek állnak rendelkezésre:
  - `#REQUIRED`
    - Azt jelenti, hogy az attribútumot kötelező megadni.
  - `#IMPLIED`
    - Azt jelenti, hogy nem szükséges megadni az attribútumot és nincs alapértelmezett érték.
  - *literál*
    - Azt jelenti, hogy nem szükséges megadni az attribútumot és ez az alapértelmezett érték az attribútum hiányában.
  - `#FIXED` *literál*
    - Azt jelenti, hogy megadás esetén mindig ez kell, hogy legyen az attribútum értéke, és ez is az alapértelmezés az attribútum hiányában.

Alapértelmezett attribútumérték (2)

- **Érvényességi megszorítás**: ha az alapértelmezett érték deklaráció a `#REQUIRED` kulcsszó, akkor az attribútumot meg kell adni minden olyan elemhez, mely az attribútumlista deklarációban adott típusú.
- **Érvényességi megszorítás**: az alapértelmezett érték meg kell, hogy feleljen az attribútumtípus szintaktikus megszorításainak.
- **Érvényességi megszorítás**: ha egy attribútumhoz a `#FIXED` kulcsszóval kerül megadásra alapértelmezett érték, akkor az attribútum példányainak értéke meg kell, hogy egyezzen azzal.

Egyedek (1)

- Az XML dokumentumok fizikailag egyedeknek nevezett tárolási egységekből állnak.
- **Dokumentumegyed**nek nevezzük azt a tárolási egységet, mely kiindulási pontként szolgál az XML feldolgozó számára.
  - Ez a teljes dokumentumot tartalmazhatja.
- Minden egyednek van tartalma.
- A dokumentumegyed és a külső DTD alkészlet kivételével minden egyedet egy név azonosít.
  - A névvel rendelkező egyedek a DTD-ben kerülnek deklarálásra.

Egyedek (2)

- Az egyedek lehetnek elemzettek vagy nem elemzettek.
- A nem elemzett egyedek lényegtelenek számunkra, ezért nem tárgyaljuk őket.
- A továbbiakban tehát minden egyed elemzett.

Elemzett egyedek

- Egy elemzett egyed szöveget tartalmaz, melyet a helyettesítő szövegének nevezünk.
  - A szöveg jelölőket és/vagy karakteres adatot ábrázolhat.
- Szöveg behelyettesítésre szolgálnak.
- Egyedhivatkozásokban kerülnek hivatkozásra a nevükkel.
  - Egy egyedhivatkozás feldolgozása az elemzett egyed helyettesítő szövegének a hivatkozás helyére történő behelyettesítését eredményezi.

Egyedek fajtái (1)

- Minden egyed egy általános egyed vagy egy paraméter egyed.
  - Az általános egyedek a dokumentumban történő felhasználásra szolgálnak.
  - A paraméteregyedek a DTD-ben történő felhasználásra szolgálnak.
- Az egyedek ezen két fajtája eltérő formájú hivatkozásokat használ és eltérően történik ezek kezelése.
- Ráadásul az egyedek ezen két fajtájához különböző névterek is tartoznak.
  - Egy azonos nevű általános egyed és paraméter egyed két különböző entitás.

Egyedek fajtái (2)

- Minden egyed egy belső egyed vagy egy külső egyed.
  - Egy belső egyed tartalmát magában a deklarációban kerül megadásra.
  - Egy külső egyed tartalmát egy külső erőforrás szolgáltatja.

Egyeddeklarációk (1)

- Belső általános egyed deklarálása:
  - Példa:
    ```
    <!ENTITY unideb "University of Debrecen">
    ```
    - Az egyedre az `&unideb;` egyedhivatkozással lehet hivatkozni.
- Belső paraméter egyed deklarálása:
  - Példa: `<!ENTITY % lists "ul | ol | dl">`
    - Az egyedre a `%lists;` egyedhivatkozással lehet hivatkozni. A hivatkozás kizárólag a DTD-ben kerül felismerésre!

Egyeddeklarációk (2)

- Külső általános egyed deklarálása:
  - Példa: `<!ENTITY copyright SYSTEM "copyright.xml">`
    - Az egyedre az `&copyright;` egyedhivatkozással lehet hivatkozni.
- Külső paraméter egyed deklarálása:
  - Példa:

```
<!ENTITY % svg-animation.mod
  PUBLIC "-//W3C//ELEMENTS SVG 1.1
Animation//EN"
  "svg-animation.mod">
```

    - Az egyedre a `%svg-animation.mod;` egyedhivatkozással lehet hivatkozni. A hivatkozás kizárólag a DTD-ben kerül felismerésre!

Egyeddeklarációk (3)

- Ugyanaz az egyed egynél több egyeddeklarációban is deklarálható.
  - Ha ugyanaz az egyed egynél többször is deklarálásra kerül, akkor az első deklaráció kerül felhasználásra, a továbbiak pedig figyelmen kívül hagyásra kerülnek.

Példa egyedek komplex használatára

```
<?xml version="1.0"?>
<!DOCTYPE book SYSTEM "book.dtd" [
   <!ENTITY gc "Grumpy Cat">
   <!ENTITY fw SYSTEM "foreword.xml">
   <!ENTITY ch1 SYSTEM "chapter1.xml">
   <!ENTITY ch2 SYSTEM "chapter2.xml">
   <!ENTITY ch3 SYSTEM "chapter3.xml">
   <!ENTITY biblio SYSTEM "bibliography.xml">
]>
<book>
   <author>&gc;</author>
   <title>How to be Grumpy?</title>
   &fw;
   &ch1;
   &ch2;
   &ch3;
   &biblio;
</book>
```

Előre definiált egyedek

- Előre definiált egyedek speciális karakterekhez: `amp` (`'&'`), `lt` (`'<'`), `gt` (`'>'`), `apos` (`''`), `quot` (`'"'`).
- Ezeket az egyedeket minden XML feldolgozó fel kell, hogy ismerje, függetlenül attól, hogy deklaráltak-e vagy sem.

Jólformált egyedek (1)

- Egy belső vagy külső általános elemzett egyed jólformált, ha a helyettesítő szövege karakteres adatot tartalmaz elemekkel, karakterhivatkozásokkal, általános egyedhivatkozásokkal, CDATA-szakaszokkal, feldolgozási utasításokkal és megjegyzésekkel vegyítve.
  - A külső általános elemzett egyedek egy szövegdeklarációval kezdődhetnek, mely meghatározza a használt karakterkódolást.

Jólformált egyedek (2)

- Az általános egyedek jólformáltságának következménye, hogy a logikai és fizikai szerkezetek megfelelő módon egymásba ágyazottak.
  - Minden nyitó, záró és üres elem címkét, elemet, megjegyzést, feldolgozási utasítást, karakter- és egyedhivatkozást egy egyed kell, hogy tartalmazzon.

Néhány példa DTD-kre

- Checkstyle
  https://checkstyle.org/dtds/configuration_1_3.dtd
- MathML
  http://www.w3.org/Math/DTD/mathml3/mathml3.dtd
- MusicXML
  https://github.com/w3c/musicxml/blob/v4.0/schema/partwise.dtd
- SVG
  http://www.w3.org/Graphics/SVG/1.1/DTD/svg11.dtd

XML feldolgozók

- Egy XML feldolgozó egy szoftvermodul XML dokumentumok beolvasásához és az azok tartalmához és szerkezetéhez való hozzáféréshez.
  - Egy XML feldolgozó egy másik, alkalmazásnak nevezett modul nevében végzi munkáját.
- Az XML feldolgozók két osztályba sorolhatók: érvényesítő és nem érvényesítő.

XML formátumok tervezési kérdései (1)

- Hogyan nevezzük el az elemeket és attribútumok?
  - Ajánlott irodalom:
    - Robert C. Martin. *Clean Code: A Handbook of Agile Software Craftsmanship*. Prentice Hall, 2009.
    - Robert C. Martin. *Tiszta kód: Az agilis szoftverfejlesztés kézikönyve*. Kiskapu Kft., 2010.
      - A *Beszédes nevek* című 2. fejezet nagymértékben vonatkozik XML nevekre is.

XML formátumok tervezési kérdései (2)

- Hogyan nevezzük el az elemeket és attribútumok? (folytatás)
  - Néhány gyakorlati irányelv:
    - Olyan neveket használjunk, melyekből kiderül a szándék.
    - Kerüljük a félrevezető neveket.
    - Ne használjunk olyan túl általános zajszavakat a nevekben, mint például `Data`, `Info` vagy `Content`.
    - Használjunk kiejthető neveket.
    - Következetesen alkossunk neveket.
      - Következetesen használjunk egy névkonvenciót, mint például a *lowerCamelCase*.

XML formátumok tervezési kérdései (3)

- Mikor használjunk attribútumokat?
  - Hogyan ábrázoljunk valamilyen információt: elemtartalommal vagy attribútumokkal?
    - Egy adatra vonatkozó metaadatokat attribútumokkal ajánlott megadni.
      - Lásd például az `xml:lang` attribútumot.
    - Tilos egy attribútumév megadása egy elemhez egynél többször.
      - Tehát nem adhatók meg egy attribútummal ugyanahhoz az elemhez olyan adatok, melyek egynél többször is előfordulhatnak.
    - Nem írható elő az attribútumok megadási sorrendje.
      - Ha tehát számít a sorrend, használjunk attribútumok helyett elemeket.

XML formátumok tervezési kérdései (4)

- Mikor használjunk attribútumokat? (folytatás)
  - Példa:

```
<bookmarks title="Links of Personal Interest">

  <item url="https://www.brothers-brick.com/" title="The Brothers Brick">
    <tag>lego</tag>
    <tag>news</tag>
    <tag>reviews</tag>
  </item>

  <item url="https://thy-catafalque.hu/" title="Thy Catafalque Official">
    <tag>music</tag>
    <tag>ambient</tag>
    <tag>avantgarde</tag>
    <tag>exprimental</tag>
    <tag>metal</tag>
    <tag>band</tag>
  </item>

</bookmarks>
```

XML formátumok tervezési kérdései (5)

- További ajánlott irodalom:
  - *Google XML Document Format Style Guide* https://google.github.io/styleguide/xmlstyle.html