

XML

I.Savnik, FAMNIT

Ozadje

- 1978 - ANSI (*American National Standards Institute*) - ustanovljena skupina za pripravo standarda jezika za opis besedil.
- 1984 - ANSI in ISO (*International Standards Organization*) - priprava mednarodnega standarda. Osnutek je bil objavljen leta 1985, naslednje leto pa tudi sam standard SGML.

Ozadje

- SGML je bil že med nastanjnjem in ob samem začetku podprt z dvema večjima projektoma:
 - 1983-1987 je delovna skupina pri *Association of American Publishers* pripravila v SGML opise zvrsti *knjiga*, *časopis* in *članek* – **EMP** (Electronic Manuscript Project)
 - 1987 *US DoD* zahteva enotno tehnično dokumentacijo vseh naročenih izdelkov – **CALS** (Continuous Acquisition and Life-cycle Support)
- 1990 – nov projekt – **HTML** (Tim Berners-Lee uporabi SGML in zgradi DTD (specifična množica označb) za hipertekst – *podobno lahko obravnavamo LaTeX, pdflatex, html2latex, ... kot ~SGML/XML s specifičnim DTD*)

SGML - HTML

- HTML – specifična fiksna množica značk
- HTML – opis prezentacije
- SGML - ločuje med **obliko in vsebino**
- SGML - objavljanje (*publishing*)
- SGML – elektronski dokumenti, arhivi, knjižnice

Zakaj XML ?

- Kompleksnost SGML
- Definicija strukture dokumenta/podatkov
 - HTML ne omogoča
- Jezik za opis podatkov
- Prenos podatkov med aplikacijami
(v organizacijah, med organizacijami)
- Shranjevanje/prenos podatkov na spletu

XML – zahteve

- XML mora biti neposredno uporaben na spletu
- XML mora podpirati veliko množico uporab
- XML mora biti skladen s SGML
- Pisanje programov, ki procesirajo XML dokumente, mora biti preprosto
- Število dodatnih (opcijskih) elementov XML naj bo minimalno, idealno nič
- XML dokumenti morajo biti berljivi in jasni
- Priprava modela XML jezika mora biti hitra
- XML mora biti formalen in jedrnat Priprava XML dokumentov mora biti preprosta
- Razumljivost XML dokumentov je bistvenega pomena (in zgoščenost minimalnega pomena)

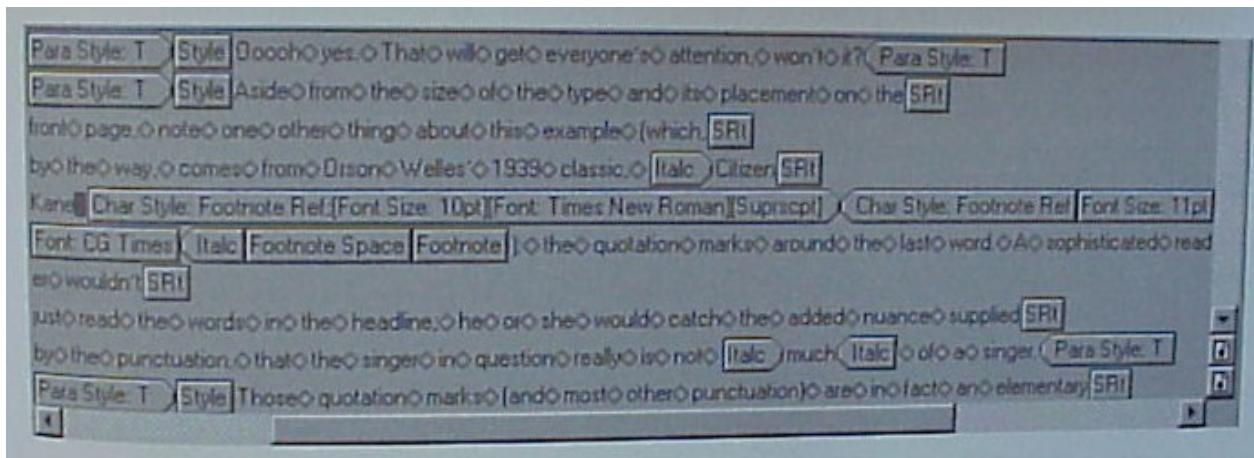
<Tag – značka>

- Očitno: označevalni jeziki uporabljajo značke
- Ideja označevanja je zelo stará: presledki (*white spaces*), označevanje začetka in konca stavka, odstavki, ..., uredniški popravki,

Cap i have learned to look on nature not as in the Bf
 guvva the hour of thoughtless youth but hearing oftentimes the less #
 ^ still, sad music of humanity, nor harsh nor grating, ital
 though of ample power to chasten and subdue. Bf ital

<Tag – značka>

- dandanašnje značke, ...



Word Codes okno

LaTeX, Word, HTML, ...

<Tag – značka>

- Značke:
 - Postopkovno označevanje: značka določa **kaj se zgodi** z označenim delom besedila
 - Vsebinsko označevanje:
 - opisno – oblikovanje glede na izbran stil ((La)TeX, Word, ...)
 - posplošeno – določitev značilnih sestavin in njihove medsebojne povezanosti – tvorimo *znakovno podatkovno bazo* (SGML, XML)

<Tag – značka>

- SGML navodilo: značka se naj začne z znakom < in konča z znakom >
- Zakaj tekstovne značke? Večja prenosljivost med različnimi okolji! Boljša berljivost!

XML

- XML je namenjen
 - Strukturiranju,
 - shranjevanju in
 - prenosu podatkov
- XML opisuje podatke in zveze med podatki
- XML nima definiranih značk
 - značke definiramo sami - slovnica
 - XML je množica podobnih jezikov
(prim. kontekstno neodvisni jeziki)
- XML uporablja DTD ali XML Schema za opis strukture podatkov - slovnice

XML – zgradba jezika

- Struktura + Vsebina
- DTD (*Document Type Definition* – zvrst spisa) definira strukturo zvrsti dokumenta
 - slovnica G in organizacija značk
- XML dokument, ki uporablja te značke za označevanje vsebine
 - beseda w , ki je v jeziku $L(DTD)$

XML – struktura dokumenta

- **Uvod** (*Prolog*) – ukazi za definiranje razpoznavalnika (*parser*)
 - slovnica, G
- **Telo** – vsebina, pomembna za ljudi
 - beseda w
- **Zaključek** (*Epilog*) – zaključni komentarji

XML - jezik

- XML dokument je beseda w v jeziku, ki ga definira slovnica DTD $G=(\Sigma, \Gamma, S, P)$:
 - vsak dokument ima korenski element (S)
 - med elementi veljajo odnosi kot jih definirajo produkcije P (drevo izpeljave)
 - simbole ($X \in \Gamma$) imenujemo tudi imenujejo **veje**, črke ($a \in \Sigma$) pa **listi**
 - elementi lahko vsebujejo atributte ali prilastke, ki jim dodajo funkcionalnost (npr. podajajo opise, omogočajo iskanje ipd.)
- Napake v besedilu bodo programsko opremo ustavile
 - prevajanje
 - do napake pride, če $w \notin L$ (DTD)

XML - osnovni gradniki

- Elementi
 - Značke – opisujejo podatkovni objekt
- Atributi (prilastki)
 - Opisujejo lastnosti objektov - elementov
- Entitete
 - Deli skupnega teksta
- Komentarji

XML - primer

```
<?xml version="1.0"?>
<!-- File Name: Inventory.xml -->

<inventory>
    <book genre="comp" id="b724">
        <title>Database Management Systems</title>
        <author><firstname>Raghuram</firstname>
            <lastname>Ramakrishnan</lastname>
        </author>
        <publisher>McGraw Hill</publisher>
        <year>2000</year>
    </book>
    ...
</inventory>
```

XML - osnovna pravila

- Vsebuje deklaracijo dokumenta
- Vsaka začetna značka mora imeti tudi pripadajočo končno značko
- Strukture morajo biti pravilno gnezdene
- Vrednosti atributov so navedene v narekovajih
- Na najvišjem nivoju je lahko le en element – korenski element (S)

XML - veljaven dokument

- XML dokument je *dobro oblikovan*, če veljajo v njem osnovna pravila
 - Ima pravo obliko in strukturo
 - Preverjanje vsebine (telo XML dokumenta)
- XML dokument je *veljaven*, če:
 - je dobro oblikovan in
 - njegova struktura ustreza slovnici (DTD definiciji)
 - Preverjanje DTD in XML
 - Beseda jezika L (DTD)

XML - atribut

- Alternativni način opisa informacij
 - Opis lastnosti elementa
- Vrednost atributa je v narekovajih “”

```
<book genre="comp">
```

XML - identifikatorji

- Zgolj oblikovni gradnik
- Veljajo znotraj celotnega dokumenta

```
<person id="o555"> <name>Janez</name> </person>
<person id="o456"> <name>Marija</name>
                      <children idref="o123 o555"/>
</person>
<person id="o123" mother="o456"><name>Tone</name>
</person>
```

DTD

- Document Type Descriptor
- Podedovan od SGML
- Podoben DB shemi, čeprav ni zares ...
- BNF slovnica (prim. kontekstno neodvisni jezik)
- Definicija elementov specifičnega XML jezika

DTD - primer

```
<!element book (title,author*,publisher,year) >
<!element title #PCDATA >
<!element publisher #PCDATA >
<!element year #PCDATA >
<!element author (firstname,lastname,address?,age?) >
<!attlist book id ID #required >
<!attlist book genre CDATA #required >
...
```

DTD - zgradba

- **Elementi**
 - `<!ELEMENT element-name category>`
 - `<!ELEMENT element-name (element-content)>`
 - `E1,E2,... ; E*` ; `E+` ; `E?` ; `E1 | E2`
 - Tipi: `#PCDATA`, `EMPTY`, `ANY`

DTD - zgradba

- **Atributi**
 - `<!ATTLIST el-name attr-name attr-type default-value>`
 - Tipi: CDATA, (en1|en2|..), ID, IDREF, ENTITY,...
 - Določila: #required, #implied, #fixed

DTD - zgradba

- **Entitete**
 - <!ENTITY entity-name "entity-value">
 - <!ENTITY writer "Donald Duck."> -- uporaba:
 &writer;

DTD+XML vs. Relacije

- XML
 - Primeren bolj za dokumente kot podatke
 - Ime in tip elementov so povezani globalno
 - Ni podpore podatkovnim tipom
 - Ni validacije podatkov
 - Imamo lahko en sam ključ
 - Ni ključev z več atributi
 - Ni tujih ključev (reference na ključe)
 - Ni omejitev za IDREF
 - Ni podpore za ponovno uporabo strukture
 - OO strukture niso podprte
- Ni mogoče ohraniti informacije pri prevajanju iz relacijskega podatkovnega modela v XML

XML – pomembni standardi

- CSS,XSL/XSLT:
 - Prezentacija in transformacija dokumentov in podatkov
- RDF: resource description framework
 - Meta-info, kategorije, semantične mreže, ...
- Xpath/Xpointer/Xlink:
 - standard za povezovanje dokumentov in elementov
- Namespaces:
 - Delo z imeni
- DOM: “Document Object Model”
 - Delo z XML dokumenti v prog. jezikih
- SAX: Enostaven API za XML
- XQL,XQuery, XML-QL: poizvedovalni jezik

Zaključek

- Podjetja uvajajo XML kot medij za prenos podatkov med oddelki
- Sistemi (distribuirani) uporabljajo XML kot medij za prenos podatkov
- Konfiguracijske datoteke, logi, ... sistemov so pogosto v XML
- Večina DBMS ima XML vmesnik

Viri

- Peter Peer, Andrej Brodnik
 - prosojnice za 2003/04
- Raghu Ramakrishnan
 - Knjiga: Database Management Systems
- <http://www.w3.org/XML>
<http://www.w3schools.com/>