



Informatički praktikum 4

Letnji semestar 2016/2017

Obaveze na predmetu

- 1 test, 15p (u maju)
- 2 seminarska rada
 - BibTeX, 10p
 - XML, 20p
- Prisustvo, 5p
 - dozvoljeno je odsustvovati sa najviše 3 časa
- Pismeni ispit, 50p
 - uslov da bi se ispit položio je bar 20p
- Nema praktikuma

Your company name

Program predmeta

- XML
 - Istorijat
 - Osnovni pojmovi
 - DTD
 - XML Shema
 - Regularni izrazi
 - JSON
 - Primene
- BibTeX

Your company name



1. Obeležavanje teksta i istorijat XML-a

Branislava Šandrih

branislava.sandrih@fil.bg.ac.rs

NAPOMENA: Sadržaj ove prezentacije preuzet je od prof. Cvetane Krstev sa
<http://poincare.matf.bg.ac.rs/~cvetana/kurs-xml/>

Kako predstaviti u računaru?

КАКО СЕ СМАЊИВАЛА РЕАЛНА
ВРЕДНОСТ ЈЕДНОГ КАУБОЈА

100₀%

У ИДЕЈИ — СЈАЈАН,
У ПРИНЦИПУ — ЛАФ,
У ПОБУДИ — БАЈАН,
У НАМЕРИ — ПАФ!
У ЦРТЕЖУ — БЉЕСАК,
У КОНЦЕПТУ — ФЛИТ,
У НАЧЕЛУ — ТРЕСАК,
КАО ЦАКА — ХИТ!
ТЕОРЕТСКИ — ЧУДО,
У ЖЕЉАМА — ГРОМ,
У ПРОЈЕКТУ — ЛУДО,
ЗА ПОЧЕТАК — ЛОМ!

80₀%

МЕЂУТИМ,
ЧИМ НЕГДЕ
ПРАСНЕ
— ОН
ЗА НИЈАНСУ
СПЛАСНЕ.
ЧИМ НЕГДЕ
НЕШТО
ЛУПИ
— ОН СЕ
ПРИМЕТНО
СКУПИ.

60₀%

БУДЕ ЛИ
НЕГДЕ
ТРЕСКА
— ОН СЕ
БУКВАЛНО
СПЉЕСКА.
АКО ГА
НЕШТО
ТАКНЕ
— ОН СЕ
ЗА ПРОЦЕНАТ
СМАКНЕ.

40₀%

ПОЧНЕ ЛИ
РАФАЛ
ДА КРЧКА
— ОН СЕ
ДИРЕКТНО
ЗБРЧКА.
АКО
И С БОКА
КОКА
— ЈОШ СЕ
ЗА РЕЦКУ
СКЉОКА.
ЈОШ АКО
И С ЛЕЂА
ГРУНЕ
— ОН
УПАДЉИВО
ТРУНЕ.

Your company

Samo tekst (gubitak raznih informacija)

KAKO SE SMANJIVALA REALNA VREDNOST JEDNOG KAUBOJA
100% U IDEJI - SJAJAN, U PRINCIPU - LAF, U POBUDI
- BAJAN, U NAMERI - PAF! U CRTEŽU - BLJESAK, U
KONCEPTU - FLIT, U NAČELU - TRESAK, KAO ČAKA -
HIT! TEORETSKI - ČUDO, U ŽELJAMA - GROM, U
PROJEKTU - LUDO, ZA POČETAK - LOM! 80% MEĐUTIM,
ČIM NEGDE PRASNE - ON ZA NIJANSU SPLASNE. ČIM
NEGDE NEŠTO LUPI - ON SE PRIMETNO SKUPI. 60% BUDE
LI NEGDE TRESKA - ON SE BUKVALNO SPLJESKA. AKO GA
NEŠTO TAKNE - ON SE ZA PROCENAT SMAKNE. 40% POČNE
LI RAFAL DA KRČKA - ON SE DIREKTNO ZBRČKA. AKO I S
BOKA KOKA - JOŠ SE ZA RECKU SKLJOKA. JOŠ AKO I S
LEĐA GRUNE - ON UPADLJIVO TRUNE. 20% DESI SE,
STRELA VRISNE

Logička i grafička struktura teksta

[Text Encoding Initiative]

```
<TeiHeader>
<titleStmt>
  <title>Utorak</title><author>Duško
Radović</author>
<language id='SCO' wsd='ISO-8859-2' alpha='Cyrillic'>
.....
<div2 type='ciklus'>
  <head lang='EN'>Western</head>
<div3 type='pesma'>
  <head>KAKO SE SMANJIVALA REALNA
&#RS;&#RE;VREDNOST JEDNOG KAUBOJA</head>
<head rend='bold 14pt'>100%</head>
<lg1 type='strofa' rend='roman 14pt'>
<|>U IDEJI — SJAJAN,</|>
<|>U PRINCIPU — LAF,</|>
<|>U POBUDI — BAJAN,</|>
<|>U NAMERI — PAF!</|>
<|>U CRTEŽU — BLJESAK,</|>
```

```
<|>U KONCEPTU — FLIT,</|>
<|>U NAČELU — TRESAK,</|>
<|>KAO CAKA — HIT!</|>
<|>TEORETSKI — ČUDO,</|>
<|>U ŽELJAMA — GROM,</|>
<|>U PROJEKTU — LUDO,</|>
<|>ZA POČETAK — LOM!</|>
</lg1>
<head rend='bold 12pt'>80%</head>
<lg1 type='strofa' rend='roman 12pt'>
<lg2>
<|>MEĐUTIM,<|>
<| rend='1ind'>ČIM NEGDE</|>
<| rend='2ind'>PRASNE</|></lg2>
<lg2>
<|>— ON</|>
<| rend='1ind'>ZA NIJANSU<|>
```

Obeležavanje teksta (1)

- Uloge:
 - Elementi logičke strukture
 - Funkcije nad elementima
 - Osobine elemenata
 - Različite vrste sadržaja
 - Različite vrste alfabeta
 - Sadržaj iz drugog toka
 - Hipertekstualne veze ...
- Razni formati za obeležavanje teksta:
 - TeX, Word, RTF, HTML, XML, JSON ...

Obeležavanje teksta (2)

- Ukoliko dve strane koriste drugačiji način predstavljanja podataka, mogu da:
 - Usaglase format (nepraktično)
 - Koriste programe za prevođenje različitih formata
 - HTML to LaTeX, XML to JSON, JSON to XML, Word to LaTeX itd...
 - nije baš uvek dobro jer može doći do gubitka informacija
- Važnost standardizacije mašinski čitljivih dokumenata:
 - prenosivost
 - višestruko korišćenje
 - dugovečnost

Šta je SGML? (1)

- **Standard Generalized Markup Language**
 - Standardni generalizovani jezik za obeležavanje
- Kasnih šezdesetih godina, komunikacija između računara odvijala se razmenom puno različitih formata za obeležavanje, što je bilo dosta problematično
- Zaposleni IBM-a smišljaju pravilo kojim bi se logički opisali podaci, tako da to bude nezavisno od operativnog sistema ili hardverskih komponenti
- Obrada jezika za označavanje podataka svodi se na obradu teksta, što omogućuje sistemsku i hardversku nezavisnost
- SGML **nije jezik**, već sistem za definisanje jezika za označavanje

Šta je SGML? (2)

- Svaki jezik definisan SGML-om naziva se SGML aplikacija
- SGML aplikacije se karakterišu:
 - skupom karaktera i delimitera koji se mogu javiti u jeziku
 - definicijom sintakse elemenata za označavanje
 - opisom semantike sadržaja, u vidu sintaksičkih restrikcija koje nisu mogle biti izražene definicijom sintakse
 - same dokumente koji sadrže podatke i oznake
 - svaki dokument sadrži referencu na svoju definiciju sintakse

Najvažnija svojstva SGML-a

- Apstraktna sintaksa
- Konkretna sintaksa
- Deklaracije oznaka
- Proizvoljnost sadržaja podataka
- Upotreba jedinstvenih identifikatora
- Uključivanje i isključivanje delova podataka
- Opciona svojstva jezika

Your company name

Međutim...

- Iako bi formati bili ukalupljeni, i dalje je svaka organizacija mogla imati svoj format za predstavljanje podataka
- Samo ukalupljivanje (opisivanje sopstvenog formata prema pravilima SGML-a) nije bilo jednostavno:
 - specifikacija na 155 stranica
 - 203 pravila kontekstno-slobodne gramatike
 - složena izrada parsera za takav jezik
- Bilo je i uspešnih primena:
 - Američko ministarstvo odbrane, Američko udruženje izdavača, Međunarodni zavod za standardizaciju, Kancelarija za zvanične publikacije EU ...

Deo SGML deklaracije za HTML

```
<!SGML "ISO 8879:1986 (WWW)"
```

```
--
```

```
SGML Declaration for HyperText Markup Language version HTML 4
```

```
With support for the first 17 planes of ISO 10646 and  
increased limits for tag and literal lengths etc.
```

```
--
```

CHARSET

```
BASESET "ISO Registration Number 177//CHARSET  
ISO/IEC 10646-1:1993 UCS-4 with  
implementation level 3//ESC 2/5 2/15 4/6"
```

```
DESCSET 0 9 UNUSED
```

```
9 2 9
```

```
11 2 UNUSED
```

```
13 1 13
```

```
14 18 UNUSED
```

```
32 95 32
```

```
127 1 UNUSED
```

```
128 32 UNUSED
```

```
160 55136 160
```

```
55296 2048 UNUSED -- SURROGATES --
```

```
57344 1056768 57344
```

CAPACITY SGMLREF

```
TOTALCAP 150000
```

```
GRPCAP 150000
```

```
ENTCAP 150000
```

SCOPE DOCUMENT

SYNTAX

```
SHUNCHAR CONTROLS 0 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16
```

```
17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 127
```

```
BASESET "ISO 646(IRV:1991//CHARSET
```

```
International Reference Version
```

```
(IRV)//ESC 2/8 4/2"
```

```
DESCSET 0 128 0
```

FUNCTION

```
RE 13
```

```
RS 10
```

```
SPACE 32
```

```
TAB SEPCHAR 9
```

```
NAMING LCNMSTRT ""
```

```
UCNMSTRT ""
```

```
LCNMCHAR "-_:"
```

```
UCNMCHAR "-_:"
```

```
NAMECASE GENERAL YES
```

```
ENTITY NO
```

```
DELIM GENERAL SGMLREF
```

```
HCRO "&#38;#x" -- 38 is the number for ampersand --
```

```
SHORTREF SGMLREF
```

```
NAMES SGMLREF
```

```
QUANTITY SGMLREF
```

```
ATTCNT 60 -- increased --
```

```
ATTSPLEN 65536 -- These are the largest values --
```

```
LITLEN 65536 -- permitted in the declaration --
```

```
NAMELEN 65536 -- Avoid fixed limits in actual --
```

```
PILEN 65536 -- implementations of HTML UA's --
```

```
TAGLVL 100
```

```
TAGLEN 65536
```

```
GRPGTCNT 150
```

```
GRPCNT 64
```

FEATURES

MINIMIZE

```
DATATAG NO
```

```
OMITTAG YES
```

```
RANK NO
```

```
SHORTTAG YES
```

LINK

```
SIMPLE NO
```

```
IMPLICIT NO
```

```
EXPLICIT NO
```

OTHER

```
CONCUR NO
```

```
SUBDOC NO
```

```
FORMAL YES
```

```
APPINFO NONE
```

```
>
```

Šta je HTML?

- **Hypertext Markup Language**
 - Hipertekstualni jezik obeležavanja
 - <http://www.w3schools.com/html/>
- Jedna jednostavna SGML aplikacija
- Samo jedna u nizu ideja CERN-ovog zaposlenog, Tim Berners-Lee:
 - World Wide Web (1989)
 - Specifikacije za URL, HTTP, HTML (1991)
 - Osnovao W3C pri MIT-u (Massachusetts Institute of Technology) (1994)



Osnovne ideje World Wide Web-a

- WWW omogućava korisnicima da pronadu, pregledaju i pretražuju multimedijalne dokumente (tekstualne, grafičke, animacije, audio i video zapise) bilo kog sadržaja, na način nezavisan od tipa dokumenta
- To je tehnologija deljenja podataka upotrebom tekstualnih dokumenata koji sadrže hiper-linkove
 - WWW nije isto što i internet!
- Klijent-server model kao osnovna arhitektura
 - Korisnik je „klijent“, a podaci se nalaze na računaru koji ima ulogu „servera“
- Usklađivanje formata

Nastanak XML-a

- 1996. godine odvijaju se aktivnosti za pojednostavljenje SGML-a
- Ciljevi su da se zadrže osnovni koncepti, a uklone:
 - duplirana svojstva
 - svojstva koja se teško implementiraju
 - svojstva koja zbunjuju korisnike
 - svojstva koja se empirijski nisu pokazala korisnim
- Rezultat:

