

Uvod u XML i XML baze podataka

Jelena Graovac

Matematički fakultet, Univerzitet u Beogradu

jgraovac@matf.bg.ac.rs

www.matf.bg.ac.rs/~jgraovac

Značaj podataka

- Podaci su često loše organizovani, teško je upravljati njima i uglavnom su nedovoljno iskorišćeni.
- Dobro organizovani podaci nisu dovoljno cenjeni s obzirom na njihov značaj.
- Rast količine podataka.
- Snažniji računari.
- Očekivanje: dobijanje kvalitetnijih informacija.
- Kvalitetnije informacije – prednost u odnosu na konkureniju.

Vrste podataka

- Prema svojoj strukturiranosti razlikuju se:
 - Dobro strukturirani podaci
 - Na primer, telefonski imenik sa unapred jasno definisanim poljima - ime, prezime, broj telefona
 - Relacione baze podataka su podesne za skladištenje i upravljanje ovakvim podacima
 - Polustrukturirani podaci
 - Relacione baze podataka nisu najpodesnije

Šta su polustrukturirani podaci?

- Nemaju zajedničku strukturu.
- Mogu sadržati polja koja nisu poznata pre trenutka projektovanja dokumenta.
- Iste vrste podataka se mogu predstaviti na različite načine.

Predstavljanje polustrukturiranih podataka

- XML je jezik za predstavljanje polustrukturiranih podataka.
- Skraćenica od eXtensible Markup Language.
- Jezik označavanja sličan HTML-u.
- Razvijen je od strane W3C (World Wide Web Consortium) sa ciljem prevazilaženja nedostataka HTML-a.
- XML nije zamena za HTML. Tendencija je da se HTML koristi za prikazivanje a XML za opisivanje podataka.

Prednosti XML-a

- Sintaksa etiketa nije fiksirana.
- Ne mora se definisati shema.
- Fleksibilan je i proširiv, omogućava postojanje različitih tipova podataka u okviru jednog dokumenta.
- Opisuje podatke stavljanjem akcenta na to šta podaci jesu a ne kako oni izgledaju.
- Ima format koji je čitljiv za čoveka.
- Ima mogućnost internacionalnog korišćenja zahvaljujući činjenici da koristi Unicode kodnu šemu.
- Nezavisan je od platforme odnosno od softvera i hardvera koji se koristi.
- Postoji veliki broj gotovih aplikacija za procesiranje XML-a koje se mogu koristiti.

Nedostaci XML-a

- Ne mora se definisati shema.
- Fleksibilan je i proširiv.
- Manipulisanje podacima često sporije.
- Optimizacija je kompleksnija zahvaljujući bogatstvu i velikoj izražajnoj moći upitnih jezika koje koristi.

Struktura XML dokumenta

- XML dokument je samoopisujuća, platformski nezavisna tekstualna datoteka
 - Sastoji se iz
 - Podataka (teksta)
 - Etiketa




Struktura XML dokumenta

- Elementi su osnovni blokovi XML-a
 - Kontejner element – par etiketa (početna i krajnja etiketa sa sadržajem)
`<pozdrav> Hello XML! </pozdrav>`
 - Prazan element – obično se za krajnju etiketu koristi skraćenica `/>`
 - `<poruka/>`
 - `<pozdrav tekst=“Hello XML”/>`

Struktura XML dokumenta

- Elementima se mogu pridružiti atributi
 - Obezbeđuju dodatne informacije o elementima



- Imena XML etiketa i imena atributa – case sensitive

Struktura XML dokumenta

- Hijerarhijska struktura (stablo) koja se sastoji iz elemenata, atributa i znakovnih podataka
- XML dokument ima jedan i samo jedan korenji (root) element
- Svi ostali elementi u strukturi su elementi “deca” korenog elementa
 - Dozvoljeno je višestruko ugnježdavanje elemenata

XML deklaracija

- Svaki XML dokument mora da sadrži XML deklaraciju, odnosno instrukciju obrade kojom se dokument identificuje kao XML dokument.
 - Osnovni oblik XML deklaracije:
`<?xml version="1.0"?>`
 - Opcioni oblik XML deklaracije:
`<?xml version="1.0" encoding="UTF-8"?>`

XML deklaracija

<?xml version=“1.0”encoding= “UTF-8”?>

- ? Oznaka za instrukciju obrade
 - Instrukcija obrade je poruka programima koji procesiraju XML dokument
- Atribut **version** specificira XML verziju
- Atribut **encoding** definiše znakovni kod u kome je XML dokument napisan
 - UTF-8 (kompresovana verzija Unicode-a)
 - UTF-16 (Unicode)


Dobro oformljen XML dokument

- Postoji XML deklaracija
- Dokument sadrži jedan i samo jedan koren element u kome su ugnježdeni svi ostali elementi i njihovi sadržaji
- Svi elementi i atributi u dokumentu moraju da budu sintaksno ispravni

Provera sintaksne korektnosti XML dokumenta


- XML parser verifikuje da li je XML dokument dobro-oformljen
- XML parser čita dokument i konvertuje ga u hijerarhijsku strukturu
- XML parser prenosi parsirani dokument do krajnje aplikacije

Obrada XML dokumenta



Kreiranje XML dokumenta

- Tekst editori (na primer Notepad)
- VS.NET XML Desinger
- XML Spy – razvojno okruženje za XML



Validacija XML dokumenta

- Definisanje tipova XML dokumenata
- W3C je ponudio dva standarda za definisanje tipova XML dokumenta, odnosno opisivanje strukture XML dokumenta:
 - Document Type Definition (DTD)
 - XML Schema Definition (XSD)
- Validni XML dokument
 - Dobro-oformljen
 - Konzistentan sa strukturom definisanom u opisu tipa dokumenta

Definisanje tipova dokumenata

- DTD i XSD definišu:
 - Strukturu XML dokumenta
 - Ime i tip svakog XML elementa/atributa
- DTD
 - Nasleđen od SGML-a
 - Poseban jezik za opis strukture dokumenta
 - Vrlo ograničene mogućnosti za definisanje tipova

Primer DTD

```
<!ELEMENT Knjige (Knjiga+)>
<!ELEMENT Knjiga (Naslov, Autor, Godina, ISBN, Izdavac)>
<!ELEMENT Naslov (#PCDATA)>
<!ELEMENT Autor (#PCDATA)>
<!ELEMENT Godina (#PCDATA)>
<!ELEMENT ISBN (#PCDATA)>
<!ELEMENT Izdavac (#PCDATA)>
```

- **#PCDATA** – Parser Character Data, označava znakovni sadržaj
- “+” – element se pojavljuje bar jednom

XML Schema

- Preporuka W3C od maja 2001
- Uputstvo (tutorijal) se može naći na adresi:
<http://www.w3schools.com/schema>
- Data je preko XML sintakse (XML schema je XML dokument)
- Podržava definicije prostih i složenih tipova i poseduje napredne mehanizme za grupisanje XML elemenata u XML dokumentu

Schema element

- Deklaracija XML namespace:

 xmlns:prefix="namespace name"

- Prefix se koristi kao skraćeno ime za "namespace name" u XML shemi
- "namespace name" je lokacija definicije XSD i specificira se preko URL
- Primer

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

Deklaracija elementa u XML shemi

- Za svaki element u XML shemi definiše se naziv i tip (atributi name i type)

```
<xss:element name="Autor" type="xsd:string"/>
```

- Tip može da bude:
 - Korisnički definisan tip (npr. compexType)
 - U opsegu imena definicije XML sheme (npr. string)
 - Kardinalnost elementa može da se specificira u njegovom ocu-elementu. Inače, podrazumevano, kardinalnost elementa je:
 - minOccurs="1", maxOccurs="1"

Definisanje složenih tipova

- Složeni tipovi se konstruišu od prostih i drugih složenih tipova korišćenjem konstruktora:
 - **Sequence** – def. uređenu grupu elemenata koji moraju da se javljaju u definisanom redosledom. Podrazumevano, svaki element je obavezan i jednoznačan ali se to može promeniti indikatorima minOccurs i maxOccurs.
 - **Choice** – def. grupu iz koje se može izabrati samo jedan element
 - **All** – def. grupu u kojoj se svi elementi mogu pojaviti u proizvoljnem redosledu ali tačno jedanput.

Primer

```
<?xml version="1.0" encoding="UTF-8"?>
- <xsd:schema xmlns:xsd="http://www.w3.org/2000/10/XMLSchema">
  - <xsd:element name="Knjige">
    - <xsd:complexType>
      - <xsd:sequence maxOccurs="unbounded">
        <xsd:element name="Knjiga" type="TipKniga"/>
      </xsd:sequence>
    </xsd:complexType>
  </xsd:element>
  - <xsd:complexType name="TipKnjiga">
    - <xsd:sequence>
      <xsd:element name="Naslov" type="xsd:string"/>
      <xsd:element name="Autor" maxOccurs="unbounded" type="xsd:string"/>
      <xsd:element name="Godina" type="xsd:string"/>
      <xsd:element name="ISBN" type="xsd:string"/>
      <xsd:element name="Izdavac" type="xsd:string"/>
    </xsd:sequence>
  </xsd:complexType>
</xsd:schema>
```

Primer

```
<?xml version="1.0" encoding="UTF-8"?>
- <Knjige xsi:noNamespaceSchemaLocation="D:\NASTAVA\pbp\XMLbaze\knjige.xsd"
  xmlns:xsi="http://www.w3.org/2000/10/XMLSchema-instance">
  - <Knjiga>
    <Naslov>Uvod u relacione baze podataka</Naslov>
    <Autor>Gordana Pavlović-Lažetić</Autor>
    <Godina>1999</Godina>
    <ISBN>8675890117</ISBN>
    <Izdavac>Matematički fakultet, Studentski trg 16, Beograd</Izdavac>
  </Knjiga>
  - <Knjiga>
    <Naslov>Database Management Systems, 2nd Edition</Naslov>
    <Autor>Ramakrishnan Raghu</Autor>
    <Autor>Gehrke Johannes</Autor>
    <Godina>2000</Godina>
    <ISBN>0072322063</ISBN>
    <Izdavac>McGraw-Hill Higher Education, Boston, MA</Izdavac>
  </Knjiga>
</Knjige>
```

XML dokument konstruisan u skladu sa XML shemom knjige.xsd

Da li je XML baza podataka?

- Ako se pod bazom podataka podrazumeva bilo kakva kolekcija podataka, XML u tom striktnom smislu, može se smatrati bazom podataka.
- Da li XML i tehnologije koje ga okružuju mogu pretstavljati sistem za upravljanje bazama podataka?
 - XML može obezbiti skladište podataka (XML dokumenti), sheme (DTD, XML sheme), upitne jezike (XQuery, XPath, XQL, XML-QL), interfejse.
 - Nedostaje: efikasno skladištenje, indeksi, bezbednost, transakcije i integritet podataka, pristup od strane više korisnika, upiti nad više dokumentata odjednom.

XML dokumenti

- XML dokumenti upadaju u dve široke kategorije:
 - Data-centric – dokumenti orijentisani ka podacima
 - Document-centric – dokumenti orijentisani ka sadržaju

XML dokumenti

- Data-centric – dokumenti orijentisani ka podacima
 - Karakterišu se regularnom strukturom, fino zrnastim podacima bez mešanog sadržaja.
 - Oni su projektovani tako da se koriste uglavnom za obradu od strane mašina pre nego za ljudsku upotrebu.
 - Ovakvi podaci su najčešće smešteni u nekoj relacionoj bazi podataka i javlja se potreba za transferom podataka iz relacione baze u XML dokument, iz XML dokumenta u relationalnu bazu podataka ili u oba smera.

Primer data-centric dokumenta

```
<?xml version="1.0" encoding="UTF-8"?>
- <meni datum="5.10.2007">
  - <jelo>
    <ime>Domaca pileca supa</ime>
    <cena>100.00</cena>
    <kalorije>650</kalorije>
  </jelo>
  - <jelo>
    <ime>Francuski tost</ime>
    <cena>30.50 din</cena>
    <kalorije>300</kalorije>
  </jelo>
  - <jelo>
    <ime>Bakin dorucak</ime>
    <cena>200.00 din</cena>
    <kalorije>350</kalorije>
  </jelo>
</meni>
```

XML dokumenti

- Document-centric – dokumenti orijentisani ka sadržaju
 - Karakterišu se manje regularnom ili neregularnom strukturom, krupno zrnastim podacima i ima dosta mešanog sadržaja.
 - Dokumenti projektovani uglavnom za ljudsku upotrebu.
 - Redosled elemenata često nije od značaja.
 - Najčešće su ručno pisani u XML-u.

Primer document-centric dokumenta

```
<?xml version="1.0" encoding="UTF-8"?>
- <Proizvod>
  <Ime>KIRKOLINA – čaj za mršavljenje</Ime>
  <Proizvodjac>Kirka-Pharma</Proizvodjac>
  - <Opis>
    - <Paragraf>
      Predstavlja mešavinu lekovitog bilja koje kombinovanim dejstvom regulišu
      promet materija u organizmu, ubrzavaju sagorevanje masnih naslaga i utiču na
      smanjenje telesne težine.
      <i>Krušina, sena, zova</i>
      stimulišu metabolizam, podstiču probavu, smanjuju nadutost.
      <i> Breza, pirevinu, rastavić </i>
      eliminišu nakupljene toksične materije, poboljšavaju cirkulaciju.
      <i>Matičnjak</i>
      oslobađa od stresa koji je često uzrok nekontrolisanog konzumiranja hrane.
      <i>Žalfija</i>
      kao izuzetni antiseptik štiti od mogućih infekcija i utiče na jačanje organizma.
    </Paragraf>
    - <Paragraf>
      <b>Možete:</b>
    </Paragraf>
    - <List>
      - <Item>
        <Link URL="Naruci.html">Naručiti svoj čaj za mršavljenje</Link>
      </Item>
      - <Item>
        <Link URL="Kirkolina.htm">Pročitati više o ovom proizvodu</Link>
      </Item>
      - <Item>
        <Link URL="Katalog.zip">Skinuti katalog naših proizvoda</Link>
      </Item>
    </List>
  </Opis>
</Proizvod>
```

Vrste XML baza podataka

- XML-proširene baze podataka.
 - Koristi postojeći sistem za upravljanje bazama podataka.
 - Preslikava XML podatke u sopstveni model.
 - Čuvaju se hijararhija i podaci.
 - Gubi se identitet dokumenta, redosled čvorova na istom nivou,...
 - Data-centric dokumenta
- Izvorne XML baze podataka.
 - Baze podataka koje smeštaju XML u “izvornom” obliku održavajući prirodnu drvoliku strukturu ovih dokumenata.
 - Document-centric dokumenta.

Šta su izvorne XML baze podataka?

- Osnovne osobine izvornih XML baza podataka:
 - XML dokument je osnovna logička jedinica, kao što je to vrsta u tabeli kod relacionih baza.
 - Minimalno, model mora uključiti elemente, atribute, tekstualne podatke (PCDATA) i redosled dokumenta.
 - Nema zahteva za postojanjem bilo kakvog specifičnog fizičkog modela skladištenja.

Osobine izvornih XML baza podataka

- Kolekcije dokumenata.
- Ažuriranje i brisanje baze.
- Transakcije, zaključavanje i konkurencija.
- Programski interfejsi (Application Programming Interfaces — APIs). Najpoznatiji su XML:DB API i XQJ (XQuery API for Java).
- Kružno putovanje (Round-Tripping).
- Indeksi.
 - Vrednosni indeksi - “Pronaći sve elemente čija je vrednost Santa Cruz”
 - Strukturalni indeksi -“Pronaći sve City elemente čija je vrednost Santa Cruz”
 - Full-text indeksi - “Pronaći sva dokumenta koja sadrže reč Santa Cruz”

Kako izabrati najbolje rešenje




- Pri izboru baze podataka prvo pitanje na koje treba dati odgovor jeste "Zbog čega postoji potreba za korišćenjem baze podataka i na kakav način se ta baza želi koristiti?"
- Možda najznačajniji faktor u izboru baze podataka je da li će se u nju smeštati podaci ili dokumenti.
- Ako se podacima pristupa u skladu sa predefinisanom hijerarhijom ili ako nije definisana shema dokumenta, izvorne baze podataka imaju prednost.
- Ako se očekuju česta ažuriranja onda izvorne baze nisu najbolje rešenje.
- Neke upite je lakše postaviti nad izvornim XML bazama nego nad relacionim bazama.

Jezici za postavljanje upita

- Veliki broj jezika je kreiran za postavljanje upita nad XML dokumentima a najznačajniji su Xpath i XQuery.
- XPath je W3C preporuka a sa pojavom XQuery postaje još popularniji. Koriste se za dobijanje i manipulisanje podacima iz XML baza podataka.
- Veliki broj ugrađenih funkcija.
- Korisnik ima mogućnost definisanja sopstvenih funkcija.
- Indeksi su potrebni radi efikasnijeg izvršavanja upita nad velikim kolekcijama dokumenata.

XPath

- Xpath koristi iskaze putanja za kretanje kroz logičku, hijararhijsku strukturu XML dokumenta.
- Dizajniran je da radi sa jednim XML dokumentom. Vrednost vraćena XML upitom je skup čvorova.
- Primer: Za sve putanje koji počinju od elementa knjiga, ispitati da li se u okviru njih nalazi element odeljak i vratiti kao rezultat element naslov koji je dete elementa odeljak.
 - knjiga//odeljak/naslov



XPath - primeri

- Selektovati sve elemente starost u dokumentu.

```
//starost
```

- Selektovati sve elemente koji su deca korenog elementa student

```
/student/*
```

- Selektovati sve studbr atribute elemenata student u dokumentu.

```
/student[@studbr]
```

- Selektovati sve elemente starost.

```
//*[@name()='starost']
```

- Selektovati sve pretke od svih elemenata starost koji su deca od elementa student.

```
/student/starost/ancestor::*
```

XQuery — XML Query Language

- XQuery je jezik koji je projektovan da bude mali, da se lako implementira i da bude lako razumljiv jezik.
- On je nastao sa idejom da obezbedi upitni jezik koji ima istu širinu funkcionalnosti kao SQL nad relacionim bazama podataka.
- Izrazi u XQuery-u upadaju u 6 širokih tipova:
 - Izrazi putanje.
 - Konstruktori elemenata.
 - FLWR izrazi.
 - Uslovni izrazi.
 - Kvantifikovani izrazi.
 - Izrazi koji u sebi uključuju korisnički definisane funkcije.

XQuery – izrazi putanje

- XQuery obezbeđuje izraze putanja koje su nadskup od onih u XPath-u.
 - Iz dokumenta koji sadrži zapslene i njihovu mesečnu zaradu, izdvojiti godišnju zaradu za zaposlenog sa imenom Marko.

```
//zaposleni [ime="Marko"] /zarada * 12
```
 - U dokumentu "zoo.xml" pronaći sve slike u poglavljima od 2 do 5

```
document ("zoo.xml") //poglavlje[2 TO 5] //slika
```

XQuery – konstruktori elemenata

- Ponekad je neophodno za upit da kreira ili generiše elemente. Takvi elementi se mogu generisati direktno u upitu u okviru iskaza nazvanog konstruktori elemenata.
 - Generisati elemente <zaposleni> koji imaju `zapid` atribut. Vrednost atributa i sadržaj elementa su specifikovani promenljivom `$id` koja je dodeljena u nekom drugom delu upita.

```
<zaposleni zapid = {$id}>  
    {$ime}  
    {$posao}  
</zaposleni>
```

Xquery – FLWR iskazi

- FLWR se izgovara kao "flower".
- Ovaj izraz je upit koji se sastoji od FOR, LET, WHERE I RETURN klauze.
 - Izlistati sve izdavače koji su izdali više od 100 knjiga.

```
<veliki_izdavaci>
{ FOR $p IN distinct(document("bib.xml") //izdavac)
  LET $b := document("bib.xml") //knjiga[izdavac = $p]
  WHERE count($b) > 100
  RETURN $p
}
</ veliki_izdavaci >
```

Xquery – uslovni izrazi

- Uslovni izrazi ocenjuju test izraze i onda vraćaju jedan od dva rezultujuća izraza. Ako je vrednost test izraza tačno onda se vraća kao rezultat vrednost prvog rezultujućeg izraza, u suprotnom, vraća se vrednost drugog.
 - Napraviti listu svih knjiga uređenih po naslovu. Za beletristiku, uključiti izdavača a za sve ostale autora.

```
FOR $k IN //knjiga RETURN  
    <knjiga>  
        {$k/naslov, IF ($k[@zanr = "Beletristica"]) THEN  
        $k/izdavac ELSE $k/autor}  
    </knjiga>  
    SORTBY (naslov)
```

Xquery – kvantifikovani izrazi

- SOME klauza i EVERY klauza - ekvivalentne kvantifikatorima koji se koriste u matematici i logici.
 - Pronalači naslove svih knjiga u kojima su "jedrenje" i "surfovanje" pomenuti u nekom paragrafu.

```
FOR $k IN //knjiga
  WHERE SOME $p IN $b//paragraf SATISFIES
    (contains($p, "jedrenje") AND contains($p,
    "surfovanje"))
  RETURN $k/naslov
```

- Pronalači naslove knjiga u kojima se "jedrenje" pominje u svakom paragrafu.

```
FOR $k IN //knjiga
  WHERE EVERY $p IN $k//paragraf SATISFIES
    contains($p, "jedrenje")
  RETURN $k/naslov
```

Xquery – izrazi koji u sebi uključuju korisnički definisane funkcije

- Osim toga što je podržana centralna biblioteka funkcija sličnih onima u XPath-u, XQuery takođe daje mogućnost korisnicima da definišu funkcije koje će proširiti ovu biblioteku.
- Spisak korisnički definisanih funkcija može se naći na adresi:http://www.w3schools.com/xpath/xpath_functions.asp
- Primer: Napisati funkciju koja za knjigu za koju su date informacije o ceni i popustu (u procentima), izračunati cenu sa popustom.

```
declare function local:minCena ($cena as xs:decimal?,  
$popust as xs:decimal?) AS xs:decimal?  
{ let $pop := ($cena * $popust) div 100  
return ($cena - $pop);  
(: Primer poziva ove funkcija je::)  
<minCena>{local:minCena ($knjiga/cena,$knjiga/popust)}  
</minCena>
```

Izvorne XML baze podataka

- Najpoznatiji sistemi za upravljanje izvornim XML bazama podataka su:
 - eXist
 - Open source sistem za upravljanje izvornim XML bazama podataka, koji jednostavno može biti integriran u druge aplikacije koje koriste i obrađuju XML.
 - Baza podataka je potpuno napisana u Javi.
 - <http://exist-db.org>
 - Berkeley DB XML
 - Oracle XML DB
 - MarkLogic Server, izvorna XML baza podataka koja koristi XQuery.

Literatura

- Bourett, Ronald. XML and Databases.
<http://www.rpbourret.com/xml/XMLAndDatabases.htm>
- Dare **Obasanjo**. An Exploration Of XML In Database Management Systems. http://www.uni-weimar.de/~bauinf/lehre/Bi_3/Vorlesung/Obasanjo_XMLandDatabases.pdf
- Gordana Pavlović-Lažetić. Native XML databases vs. relational databases in dealing with xml documents.
- Dr. Milica Vučković. Uvod u XML i XML tehnologije.
- Jelena Graovac. XML baze podataka u upravljanju leksičkim resursima. Magistarska teza.
<http://poincare.matf.bg.ac.rs/~jgraovac/publications/jt.pdf>