

IV1023 vt2022

Avancerad Datahantering med XML

Semistrukturerade data och XML

nikos dimitrakas
nikosd@kth.se
08-161295
Rum 2423

Läsanvisningar

Utdrag från Data on the Web

Kapitel 1, 4, 5, 6, 10 (speciellt 10.6) i kursboken

Delar av kapitel 31 i Database Systems (Connolly, Begg) upplaga 5

Data - Metadata

- **Data**
 - Johnny, Pasta, Lund, 2001-02-12, true, 677
- **Metadata**
 - namn, namn, stad, startdatum, skickad, vikt
- **Typer av metadata**
 - Struktur
 - Semantik
 - Katalog (klassificering)
 - Integration (mappning)

Struktur

- **Modellering**

- TechTarget: Data modeling is the analysis of data objects that are used in a business or other context and the identification of the relationships among these data objects.

- **Databaslösningar**

- **Relationsmodellen**
 - » Tabeller, kolumner, domäner, nycklar, integritetsregler
- **Objekt-orientering/Objektdatabaser**
 - » Klasser, attribut, referenser, regler
- **XML**
 - » Element, attribut, regler
- **Annat**
 - » ?

Semantik

- **Betydelsen av data och metadata**

- **Metadata**
 - » namn
 - » pris
 - » vikt
 - » skickad
- **Semantik**
 - » Det som unikt identifierar varje produkttyp vi har produkter av
 - » Antalet SEK som kunden måste betala inkl moms för ett exemplar
 - » Anger produktens vikt inkl förpackningen för ett exemplar i gram
 - » Sant om beställningen har lämnat vårt lager, annars falskt

Semistrukturerade data

- Ingen struktur (schemaless)
- Implicit struktur (self-describing)
 - metadata inbyggda i data
 - » inga data → inga metadata

- SSD

```
{namn:{för:"Kalle", efter:"Lind"},
epost:"kalle@lind.nu",
mobil:"07012345678"}
```


```
{namn:"Lisa",
telefon:"0709999999"}
```

Representationer

- SSD

```
{namn:{för:"Kalle", efter:"Lind"},
epost:"kalle@lind.nu",
mobil:"07012345678"}
```

- Graf



- XML

<Rot>

```
<namn för="Kalle" efter="Lind" />
```

```
<epost>kalle@lind.nu</epost>
```

```
<mobil>07012345678</mobil>
```


</Rot>

Träd vs. Nätverk

• SSD

```
{person: &1{namn:{för:"Kalle", efter:"Lind"},
          epost:"kalle@lind.nu",
          mobil:"07012345678"},
 person: &2{namn:{för:"Mia", efter:"Dahl"},
          mobil:"0709090909",
          chef: &1}}
```

• Graf



7

XML

- Står för Extensible Markup Language
- Ett språk för att definiera dokumentstrukturer
- XML är en textuell representation av data
- Används inom olika områden:
 - Datalagring
 - Webb (XHTML)
 - Konfigurationsfiler
 - Transportformat
- Regler kan specificeras via
 - DTD (Document Type Definition)
 - XML Schema
- Case sensitive

8

XML-syntax

- **Element**

```
<Person>Kalle</Person>
```

- **Attribut**

```
<Person namn="Kalle"></Person>
```

- **Nästlade element**

```
<Person id="59">  
  <Fnamn>Kalle</Fnamn>  
  <Enamn>Lind</Enamn>  
  <Adress>  
    <Gata>Kungsgatan 53</Gata>  
    <Postnr>12332</Postnr>  
    <Ort>Stockholm</Ort>  
  </Adress>  
</Person>
```

- **Tomt element**

```
<Person namn="Kalle"></Person>  
<Person namn="Kalle" />
```

XML-dokument

- **XML-deklaration**

```
<?xml version="1.1" encoding="UTF-8" ?>
```

- **DOCTYPE – referens till regler**

```
<!DOCTYPE Person SYSTEM "Person.dtd">
```

- **Namespaces**

- kvalificering av element- och attributnamn

```
<iv1023:Person iv1023:namn="Kalle"></iv1023:Person>
```

- default och andra namespaces

```
<Root xmlns="default ns URI" xmlns:iv1023="iv1023 ns URI">
```

```
...
```

```
</Root>
```

XML-referenser

- **ID**

`<Person namn="Kalle" id="39"></Person>`

- **IDREF**

`<Organisation namn="KTH" chef="39"></Organisation>`

DTD (Document Type Definition)

- **Definierar XML-strukturen (element och attribut)**

`<!ELEMENT db (Person*)>`

`<!ELEMENT Person (Adress)>`

`<!ELEMENT Adress EMPTY>`

`<!ATTLIST Person
 namn CDATA #REQUIRED
 id ID #REQUIRED
 fdatum CDATA #IMPLIED
 pappa IDREF #IMPLIED>`

`<!ATTLIST Adress
 gatuadress CDATA #REQUIRED
 postnr CDATA #REQUIRED
 postort CDATA #REQUIRED>`

XML Schema

- **Starkare än DTD**
 - flexiblare strukturer
 - datatyper
- **XML-syntax**

```
<element name="db" type="dbType"/>
<complexType name="dbType">
  <sequence>
    <element name="Person" type="PersonType" minOccurs="0" maxOccurs="unbounded"/>
  </sequence>
</complexType>
<complexType name="PersonType">
  <sequence>
    <element name="Adress" type="AdressType" />
  </sequence>
  <attribute name="namn" type="string" use="required"/>
  <attribute name="id" type="id" use="required"/>
  <attribute name="fdatum" type="date" use="optional"/>
  <attribute name="pappa" type="idref" use="optional"/>
</complexType>
<complexType name="AdressType">
  ...
```

13

Well-formed & Valid

- **Well-formed XML**
 - Syntaktiskt korrekt
 - Börjar med XML-deklarationen
 - Innehåller endast ett rot-element
 - Matchade öppnings- och stängningstaggar
- **Valid XML**
 - Är well-formed
 - Följer reglerna i den kopplade DTD eller XML Schema

14

XML-baserade språk

- **Definition av struktur**
- **Definition av semantik**

- **XML-grundregler**
 - Alfabet, vokabulär
- **XML Schema (eller DTD)**
 - Grammatik, syntax
- **XML Schema förklaringen (för människor)**
 - Semantik, betydelse

XML-representation

- **Textuell representation (serialiserat XML-dokument)**
- **Abstrakt nodstrukturepresentation**
 - XML Infoset
 - PSVI (Post-schema-validation Infoset)
 - XPath 1.0-modellen
 - XQuery 1.0-modellen
 - (XQuery 3.0-modellen)

XML Infoset

- **Representation av det väsentliga innehållet i ett XML-dokument**
 - Vissa syntaktiska detaljer ignoreras
 - Bryr sig inte om XML Schema eller datatyper
- **11 information items, bl a**
 - Document Information Item ("roten")
 - Element Information Item
 - Attribute Information Item
 - Comment Information Item
 - Processing Instruction Information Item
 - Document Type Declaration Information Item
 - Character Information Item
 - Namespace Information Item

17

PSVI

- **Post-Schema-Validation Infoset**
- **Utökar Infoset med stöd för information från XML Schema**
 - datatyper
 - valideringstillstånd

18

XPath 1.0-modellen

- **Trädrepresentation av XML-dokument**
- **7 nodtyper**
 - root
 - element
 - attribute
 - text
 - namespace
 - comment
 - processing instruction
- **Varje nod har ett värde**
 - konkateneringen av alla underliggande textnoder
- **Nodmängder (node sets)**

19

XQuery 1.0-modellen (XPath 2.0)

- **Kan representera**
 - XML-dokument (trädstruktur)
 - noder
 - värden
 - sekvenser av noder och/eller värden
- **7 typer av noder**
 - document
 - element
 - attribute
 - text
 - comment
 - processing instruction
 - namespace

<http://www.w3.org/TR/xpath-datamodel/>

20

XPath/XQuery 3.0-modellen

- **Utökar föregående version med bl a**
 - funktioner (även map och array)

<https://www.w3.org/TR/xpath-datamodel-30/>

XQuery-modellen - nodegenskaper

- **Elementnod**
 - children (elementnoder, PI-noder, kommentarnoder, textnoder)
 - parent (elementnod eller dokumentnod)
 - attributes (attributnoder)
 - namespaces (namespacenoder)
 - string-value, typed-value
 - Obs! namespaces och attribut är inte children
- **Attributnod**
 - parent (elementnod) (heter owner i Infoset)
 - string-value, typed-value
- **Dokumentnod**
 - children
 - string-value, typed-value

XQuery-modellen - nodegenskaper

- **Textnod**
 - string-value
 - typed-value
 - parent (elementnod)
- **Kommentarnod**
 - string-value
 - parent (elementnod eller dokumentnod)
- **PI-nod**
 - string-value
 - parent (elementnod eller dokumentnod)
- **Namespace-nod**
 - string-value
 - parent (elementnod)

23

DTD (Document Type Definition)

- **Definierar element och deras struktur**
 - subelement
 - innehåll (content)
 - attribut
- **Använder egen syntax**

24

DTD - element

- Tomt element
<!ELEMENT Person EMPTY>
- Subelement
<!ELEMENT Person (Namn, Adress)>
- Subelement som kan saknas
<!ELEMENT Person (Namn, Adress?)>
- Subelement som förekommer noll eller flera gånger
<!ELEMENT Person (Namn, Adress, Tel*)>
- Subelement som förekommer en eller flera gånger
<!ELEMENT Person (Namn, Adress, Tel+)>
- Element med textinnehåll
<!ELEMENT Person (#PCDATA)>
- Element med godtyckligt innehåll
<!ELEMENT Person ANY>

25

DTD - element

- Alternativa subelement
<!ELEMENT Person (Namn, (Anställd|Student))>

Namn, Adress, Tel, Anställd, Student måste förstås också definieras.

26

DTD - attribut

- Attribut definieras per elementtyp
- Ett eller flera attribut kan definieras i samma ATTLIST
- Obligatoriskt attribut
<!ATTLIST Person pnr CDATA #REQUIRED>
- Frivilligt attribut
<!ATTLIST Person längd CDATA #IMPLIED>
- Frivilligt attribut med default-värde
<!ATTLIST Person födelseplats CDATA "Stockholm">
- Attribut med fast värde
<!ATTLIST Person arbetsgivare CDATA #FIXED "KTH">
- Attribut med begränsade möjliga värden
<!ATTLIST Person kön ("man", "kvinna") #REQUIRED>

27

DTD - attribut

- Flera attribut i samma ATTLIST
**<!ATTLIST Person
pnr CDATA #REQUIRED
födelseplats CDATA "Stockholm"
kön ("man", "kvinna") #REQUIRED
längd CDATA #IMPLIED>**
- Attribut med unika värden
<!ATTLIST Person pnr ID #REQUIRED>
- Attribut som refererar ett unikt ID-attribut
<!ATTLIST Person chef IDREF #IMPLIED>

28

DTD – koppling till XML-dokument

- **DOCTYPE**
 - `<!DOCTYPE Kurser SYSTEM "kurser.dtd">`
- **Inline**
 - `<!DOCTYPE Kurser [
deklarationer ELEMENT, ATTLIST, etc.`

XML Schema

- **Definierar element och deras struktur**
 - subelement
 - innehåll (content)
 - attribut
 - datatyper
 - antal förekomster
 - komplexa ordningsregler
- **Använder XML-syntax**
 - XML Schema är ett XML-baserat språk

XML Schema-dokument

- **Namespace**
 - `http://www.w3.org/2001/XMLSchema`
 - rekommenderat alias: `xs`
- **Rotelement**
 - `schema`
 - attribut `targetNamespace`
- **Definierar**
 - `element`
 - `attribut`
 - `typer`

```
<schema xmlns="http://www.w3.org/2001/XMLSchema"
        targetNamespace="...">
    definitioner
</schema>
```

31

XML Schema-dokument

- **Rotelementet schema**
 - attribut `elementFormDefault`
 - » `qualified`
 - » `unqualified (default)`
 - attribut `attributeFormDefault`
 - » `qualified`
 - » `unqualified (default)`
 - Används för att bestämma om namespaces måste anges

```
<iv1023:Kurs xmlns:iv1023="http://ns.kth.se/IV1023">
    <Lärare namn="nikos"/>
</iv1023:Kurs>

<iv1023:Kurs xmlns:iv1023="http://ns.kth.se/IV1023">
    <iv1023:Lärare iv1023:namn="nikos"/>
</iv1023:Kurs>
```

Endast relevanta när man tänker blanda ihop flera namespaces och lokala element/attribut

32

XML Schema - element

- **Elementet element definierar element**
 - attributet name definierar elementets namn
 - attributet type eller innehållet anger elementets typ
- **Element kan ha en av följande typer**
 - En grundtyp (string, integer, date, etc.)
 - » `<element name="Namn" type="string" />`
 - En typ definierad någon annanstans
 - » `<element name="Namn" type="MinTyp" />`
 - En typ definierad i innehållet
 - » `<element name="Namn">`
typdefinitionen
`</element>`

XML Schema - attribute

- **Elementet attribute definierar attribut**
 - attributet name definierar attributets namn
 - attributet type eller innehållet anger attributets typ
 - attributet use anger om attributet är optional (default) eller required
- **Attribute kan ha en av följande typer**
 - En grundtyp (string, integer, date, etc.)
 - » `<attribute name="Namn" type="string" />`
 - En typ definierad någon annanstans
 - » `<attribute name="Namn" type="MinTyp" />`
 - En typ definierad i innehållet
 - » `<attribute name="Namn">`
`<simpleType ... />`
`</attribute>`

XML Schema - typer

- **Grundtyper**
 - string, integer, date, etc.
- **Egendefinierade typer**
 - **complexType**
 - » när man har subelement eller attribut
 - **simpleType**
 - » begränsning av en grunddatatyp

35

XML Schema - simpleType

```
<xs:simpleType name="veckodag">
  <xs:restriction base="xs:string">
    <xs:enumeration value="Måndag"/>
    <xs:enumeration value="Tisdag"/>
    <xs:enumeration value="Onsdag"/>
    <xs:enumeration value="Torsdag"/>
    <xs:enumeration value="Fredag"/>
    <xs:enumeration value="Lördag"/>
    <xs:enumeration value="Söndag"/>
  </xs:restriction>
</xs:simpleType>

<xs:simpleType name="betyg">
  <xs:restriction base="xs:integer">
    <xs:minInclusive value="0"/>
    <xs:maxInclusive value="10"/>
  </xs:restriction>
</xs:simpleType>
```

36

XML Schema - complexType

- Kan innehålla ett av följande
 - **simpleContent**
 - » om elementets innehåll skall vara av en enkel datatyp (en textnod)
 - **complexContent**
 - » om elementets innehåll är baserat på en annan complexType
 - **all**
 - » definierar subelement i obestämd ordning
 - **choice**
 - » definierar alternativa subelement
 - **sequence**
 - » definierar sekvens av subelement
 - **group**
 - » använder en fördefinierad struktur av subelement
- Kan även innehålla (när inte Content)
 - noll eller flera element "attribute" eller "attributeGroup"

37

XML Schema - complexType

```
<xs:complexType name="PersonType">
  </xs:sequence>
  <xs:element name="Förnamn" type="xs:string"/>
  <xs:element name="Efternamn" type="xs:string"/>
  <xs:element name="Födelsedatum" type="xs:date"/>
</xs:sequence>
</xs:complexType>
```



```
<xs:complexType name="PersonType">
  <xs:attribute name="Förnamn" type="xs:string"/>
  <xs:attribute name="Efternamn" type="xs:string"/>
  <xs:attribute name="Födelsedatum" type="xs:date"/>
</xs:complexType>
```

38

XML Schema - förekomster

- **Attributet minOccurs** anger minsta antal förekomster
 - default 1
- **Attributet maxOccurs** anger högsta antal förekomster
 - default 1
 - för obegränsat sätt "unbounded"
- **Används för**
 - choice
 - all (0..1 till 1..1)
 - sequence
 - group
 - element
 - any (godtyckligt element)

39

XML Schema - exempel

```
<xs:group name="InfoGrupp">
  </xs:choice>
    <xs:element name="Epost" type="xs:string"/>
    <xs:element name="Telefon" type="xs:string"/>
    <xs:element name="Webbplats" type="xs:string"/>
  </xs:choice>
</xs:group>

<xs:complexType name="PersonTyp">
  <xs:sequence>
    <xs:group ref="InfoGrupp" minOccurs="0" maxOccurs="unbounded" />
    <xs:element name="Förnamn" type="xs:string"/>
    <xs:element name="Efternamn" type="xs:string"/>
  </xs:sequence>
  <xs:attribute name="Födelsedatum" type="xs:date" use="optional"/>
</xs:complexType>

<xs:complexType name="PersonalTyp">
  <xs:complexContent>
    <xs:extension base="PersonTyp">
      <xs:attribute name="Anställningsnummer" type="xs:string"/>
    </xs:extension>
  </xs:complexContent>
</xs:complexType>
```

40

XML Schema - Övrigt

- **list**
 - definierar att en `simpleType` är en lista
- **union**
 - definierar en ny typ som är unionen av flera andra typer (`simpleTypes`)
- **annotation**
 - för att ange kommentarer (med `documentation` eller `appInfo`)
- **key, unique, field, keyref, selector**
 - definierar "identifierare"/"kandidatnycklar" och referenser
- **datatypbegränsningar med**
 - `length`, `minLength`, `maxLength`
 - `minExclusive`, `minInclusive`, `maxExclusive`, `maxInclusive`
 - `totalDigits`, `fractionDigits`
 - `pattern`, `whiteSpace`

41

XSD - Koppling till XML-dokument

- **Med Namespace**
 - Ett attribut (från `XSI-namespace`) i rotelementet och namespace-definition (default eller med prefix)
 - `xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"`
 - `xsi:schemaLocation="http://ns.kth.se/IV1023/kurser kurser.xsd"`
 - `xmlns="http://ns.kth.se/IV1023/kurser"`
eller
`xmlns:k="http://ns.kth.se/IV1023/kurser"`
- **Utan Namespace**
 - Ett attribut (från `XSI-namespace`) i rotelementet:
 - `xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"`
 - `xsi:noNamespaceSchemaLocation="kurser.xsd"`

**Blanktecken**

42

Fortsättning

- Quiz om semistrukturerade data, XML, DTD, XML Schema