

Gruppe A	PRÜFUNG AUS "SEMISTRUKTURIERTE DATEN" 184.705		26. 06. 2013
Kennnr.	Matrikelnr.	Familienname	Vorname

Arbeitszeit: 100 Minuten. Aufgaben sind auf den Angabeblättern zu lösen; Zusatzblätter werden nicht gewertet. Bitte tragen Sie Namen, Studienkennzahl und Matrikelnummer ein. Halten Sie Ihren Studentenausweis bereit.

Aufgabe 1:

(12)

Betrachten Sie die folgende XML-Schema Datei **test.xsd**:

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

  <xsd:element name="a" type="atype"/>

  <xsd:complexType name="atype">
    <xsd:sequence>
      <xsd:element name="b" type="btype" minOccurs="0" maxOccurs="2"/>
      <xsd:element name="a" type="atype" minOccurs="0" maxOccurs="2"/>
    </xsd:sequence>
  </xsd:complexType>

  <xsd:complexType name="btype">
    <xsd:choice minOccurs="0" maxOccurs="1">
      <xsd:element name="c" type="xsd:int"/>
      <xsd:element name="a" type="atype"/>
    </xsd:choice>
  </xsd:complexType>
</xsd:schema>
```

Betrachten Sie weiters die acht verschiedenen XML-Dateien, die unten angeführt sind.

Sie können davon ausgehen, dass alle folgenden XML-Dateien wohlgeformt sind. Es geht also lediglich darum, ihre Gültigkeit bezüglich **test.xsd** zu entscheiden.

Kreuzen Sie an, welche der folgenden XML-Dateien gültig bezüglich **test.xsd** sind.

- | | | |
|----------------------------------|--|--|
| 1. <a/> | gültig <input checked="" type="checkbox"/> | ungültig <input type="checkbox"/> |
| 2. | gültig <input type="checkbox"/> | ungültig <input checked="" type="checkbox"/> |
| 3. <a><a/><a/> | gültig <input checked="" type="checkbox"/> | ungültig <input type="checkbox"/> |
| 4. <a><a/><a/><a/><a/> | gültig <input type="checkbox"/> | ungültig <input checked="" type="checkbox"/> |
| 5. <a><c>1</c> | gültig <input checked="" type="checkbox"/> | ungültig <input type="checkbox"/> |
| 6. <a><a/> | gültig <input checked="" type="checkbox"/> | ungültig <input type="checkbox"/> |
| 7. <a><a> | gültig <input checked="" type="checkbox"/> | ungültig <input type="checkbox"/> |
| 8. <a><a><c>1</c> | gültig <input type="checkbox"/> | ungültig <input checked="" type="checkbox"/> |

(Pro korrekter Antwort 1.5 Punkte, **pro inkorrekter Antwort -1.5 Punkte**, pro nicht beantworteter Frage 0 Punkte, für die gesamte Aufgabe mindestens 0 Punkte)

Aufgabe 2:

(15)

Kreuzen Sie an, ob die folgenden Aussagen wahr oder falsch sind.

1. XML gibt es schon wesentlich länger als HTML. wahr falsch
2. Um die Wohlgeformtheit eines XML-Dokuments zu überprüfen wird eine DTD oder ein XML Schema benötigt. wahr falsch
3. Eine XML Schema Definition muss ein wohlgeformtes XML-Dokument sein. wahr falsch
4. Pro XML-Schema Datei ist maximal ein Target-Namespace erlaubt. wahr falsch
5. SAX ist keine W3C-Recommendation, aber ein de-facto Standard. wahr falsch
6. SAX Filter dürfen nicht verschachtelt verwendet werden. wahr falsch
7. Der Speicherbedarf eines DOM-Parsers ist unabhängig von der Größe des geparsen XML-Files. wahr falsch
8. In XPath gilt $(1,2) = (2,3)$ wahr falsch
9. In XPath gilt $(1,2) \neq (2,3)$ wahr falsch
10. XSLT Stylesheets sind wohlgeformte XML Dokumente. wahr falsch

(Pro korrekter Antwort 1.5 Punkte, **pro inkorrektter Antwort -1.5 Punkte**, pro nicht beantworteter Frage 0 Punkte, für die gesamte Aufgabe mindestens 0 Punkte)

Die folgenden Aufgaben 3 – 7 beziehen sich auf das XML-Dokument **struktur.xml**, das Sie auf der letzten Seite dieser Prüfungsangabe finden.

Aufgabe 3:

(12)

Erstellen Sie das DTD Dokument **struktur.dtd**, sodass XML-Dokumente in der Gestalt von **struktur.xml** (siehe Anhang) bezüglich dieser DTD gültig sind. Berücksichtigen Sie beim Erstellen der DTD folgende Punkte:

- Das Element **struktur** ist das Wurzelement und besteht aus genau einem **knoten**-Element gefolgt von zumindest einem **typ**-Element.
- Das Element **knoten** besteht aus beliebig vielen **inhalt** Elementen gefolgt von beliebig vielen **knoten** Elementen. Der Wert des Attributs **id** soll global eindeutig sein.
- Das Element **inhalt** besitzt Textinhalt. Das Attribut **typ** der **inhalt**-Elemente verweist auf das Primärschlüssel-Attribut **name** des **typ**-Elements.
- Das Element **typ** besitzt leeren Inhalt und drei Attribute.
- Spezifizieren Sie die Attribute (wählen Sie sinnvolle Typen aus!) sowie die nicht näher erläuterten Häufigkeiten entsprechend dem **struktur.xml** Dokument im Anhang. Beachten Sie auch die Rekursion der **knoten**-Elemente. Alle Attribute sollen verpflichtend sein. Versuchen Sie weiters entsprechende Fremdschlüssel zu finden und in der DTD abzubilden.

Datei **struktur.dtd**:

```
<!ELEMENT struktur (knoten, typ+)>

<!ELEMENT knoten (inhalt*, knoten*)>
<!ATTLIST knoten
  id ID #REQUIRED
>

<!ELEMENT inhalt (#PCDATA)>
<!ATTLIST inhalt
  typ IDREF #REQUIRED
>

<!ELEMENT typ EMPTY>
<!ATTLIST typ
  name ID #REQUIRED
  min CDATA #REQUIRED
  max CDATA #REQUIRED
>
```

Aufgabe 4:

(10)

Betrachten Sie die folgenden XPath-Abfragen angewandt auf das Dokument **struktur.xml** (siehe Anhang).

- Falls als Ergebnis **knoten** Elemente selektiert werden, geben Sie jeweils das Attribut **id** an.
- Falls als Ergebnis mehrere Elemente selektiert werden, trennen Sie die jeweiligen Ausgaben durch Leerzeichen.
- Falls der angegebene XPath Ausdruck keine Knoten selektiert, notieren Sie im entsprechenden Feld "leere Ausgabe".

Betrachten Sie dazu folgendes Beispiel:

```
//knoten
```

```
a b c d e f g
```

Geben Sie nun die entsprechende Ausgaben der folgenden XPath-Abfragen an.

```
//knoten[not(*)]
```

```
g
```

```
//knoten[ancestor::knoten]
```

```
b c d e f g
```

```
//knoten[2]
```

```
c
```

```
(//knoten)[2]
```

```
b
```

```
//knoten[knoten[.//@typ='int']]
```

```
a c
```

Aufgabe 5:

(8)

Betrachten Sie folgende-XQuery Abfrage **struktur.xq** angewandt auf **struktur.xml**:

```
let $x := //knoten[sum(inhalt) > 0]
for $y in //knoten[inhalt/@typ='int']
return
  <k id="{ $y/@id }">{
    if ($y = $x)
    then attribute b {"true"}
    else <pm/>,
    sum($y/inhalt)
  }</k>
```

Geben Sie zuerst die id Attribute aller Knoten an, die in **\$x** gespeichert sind:

d e

Geben Sie nun die id Attribute aller Knoten an, die **\$y** durchläuft:

a b d

Geben Sie nun die Ausgabe von **struktur.xq** angewandt auf **struktur.xml** an.

Die exakte Behandlung von Whitespaces ist dabei nicht relevant.

```
<k id="a"><pm/>-1</k>
<k id="b"><pm/>0</k>
<k id="d" b="true">6</k>
```

Erstellen Sie ein XSLT-Stylesheet **struktur.xml**, das angewandt auf Dokumente der Gestalt **struktur.xml** folgende Ausgabe erzeugt:

- Als Dokumentelement soll das Element **out** erzeugt werden.
- Für jedes **knoten** Element, das weitere **knoten** Elemente enthält, wird ein Element **inner** erzeugt.
- Für jedes Kindelement **inhalt** des Typs **pos** oder **int**, wird ein **val** Element erzeugt, das dessen Textinhalt enthält.

Für das Dokument **struktur.xml** soll beispielsweise folgende Ausgabe erzeugt werden:

```
<out>
  <inner>
    <val>2</val>
  </inner>
  <inner>
    <val>5</val>
  </inner>
</out>
```

Vervollständigen Sie hier das XSLT-Stylesheet **struktur.xml**. Die Verwendung von Kontrollstrukturen wie **xsl:for-each**, **xsl:if**, etc. ist für die Lösung *nicht* erlaubt (und auch nicht sinnvoll)! Sie brauchen sich nicht um Whitespaces etc. zu kümmern.

Datei **struktur.xml**:

```
<xsl:stylesheet version="2.0" xmlns:xsl="http://www.w3.org/1999/XSL/Transform">

  <xsl:template match="/">
    <out>
      <xsl:apply-templates/>
    </out>
  </xsl:template>

  <xsl:template match="knoten[knoten]">
    <inner>
      <xsl:apply-templates/>
    </inner>
  </xsl:template>

  <xsl:template match="inhalt[@typ='pos' or @typ='int']">
    <xsl:value-of select="."/>
  </xsl:template>

  <xsl:template match="text()|knoten"/>

</xsl:stylesheet>
```

Aufgabe 7:

(9)

Vervollständigen Sie den folgenden SAX Handler, der angewandt auf Dokumente der Gestalt **struktur.xml** die Summe aller **inhalt** Elemente des Typs **pos** berechnet. Die Summe soll in die Variable **sum** geschrieben werden.

Für das Dokument **struktur.xml** wird beispielsweise folgende Summe erreicht: 9 (= 4 + 5)

Denken Sie daran, dass **character** Events nicht immer den gesamten Textinhalt auf einmal zurückliefern!

```
public class PosSum extends DefaultHandler {

    int sum = 0;
    boolean inPos = false;
    StringBuffer sb = new StringBuffer();

    public void startElement(String uri, String localName, String qName, Attributes atts)
        throws SAXException {
        if ("pos".equals(atts.getValue("typ"))) {
            inPos = true;
        }
    }

    public void endElement(String uri, String localName, String qName) throws SAXException {
        inPos = false;
        sum += Integer.parseInt(sb.toString());
        sb.delete(0, sb.length());
    }

    public void characters(char[] ch, int start, int length) throws SAXException {
        if (inPos) {
            sb.append(ch, start, length);
        }
    }
}
```


Sie können diese Seite abtrennen!

Datei struktur.xml:

```
<struktur>
  <knoten id="a">
    <inhalt typ="int">2</inhalt>
    <inhalt typ="neg">-3</inhalt>

    <knoten id="b">
      <inhalt typ="pos">4</inhalt>
      <inhalt typ="int">-4</inhalt>
    </knoten>

    <knoten id="c">
      <knoten id="d">
        <inhalt typ="int">6</inhalt>
      </knoten>
    </knoten>

    <knoten id="e">
      <inhalt typ="pos">5</inhalt>
      <knoten id="f">
        <inhalt typ="neg">-9</inhalt>
      </knoten>
    </knoten>

    <knoten id="g"/>
  </knoten>

  <typ name="int" min="-15" max="16"/>
  <typ name="neg" min="-32" max="-1"/>
  <typ name="pos" min="1" max="32"/>
</struktur>
```

Gesamtpunkte: 75