Gruppe A	PRÜFUNG AUS "SEMISTRUKTURIERTE DATEN" **181.135**		22. 10. 2009
Kennnr.	Matrikelnr.	Familienname	Vorname

Arbeitszeit: 120 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: (9)

Betrachten Sie die folgende DTD **test.dtd**:

```
<?xml version="1.0" encoding="UTF-8"?>
<!ELEMENT As (A*)>
<!ELEMENT A (B,C?)>
<!ELEMENT B (#PCDATA|D|E)*>
<!ELEMENT C (#PCDATA)>
<!ATTLIST C attr CDATA #REQUIRED>
<!ELEMENT D EMPTY>
<!ELEMENT E (#PCDATA)>
```

Betrachten Sie weiters die sechs verschiedenen XML-Dateien, die unten angeführt sind.
Hinweise:

- Gehen Sie davon aus, dass allen folgenden Dateien die Zeile
  `<!DOCTYPE As SYSTEM "test.dtd">`
  vorangestellt ist.
- Sie können auch davon ausgehen, dass alle folgenden XML-Dateien wohlgeformt sind. Es geht also lediglich darum, ihre Gültigkeit bezüglich **test.dtd** zu entscheiden.

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

1. `<As><A><B>abc</B></A></As>` gültig ⊗ ungültig ◯
2. `<As><A><C attr="abc">def</C></A></As>` gültig ◯ ungültig ⊗
3. `<As><A><B>abc</B><C attr="def">ghj</C><B>ikl</B></A></As>` gültig ◯ ungültig ⊗
4. `<As><A><B>abc</B></A><A><B><D/>def</B></A></As>` gültig ⊗ ungültig ◯
5. `<As><A><B>abc<E>def</E>ghj</B></A></As>` gültig ⊗ ungültig ◯
6. `<As></As>` gültig ⊗ ungültig ◯

(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: (10)

Nehmen Sie an, dass folgender Java Code (links) auf das angegebene XML-Dokument (rechts) ausgeführt wird. Zeichnen Sie den resultierenden DOM-Baum *nach* der Ausführung des Codes auf.

Bemerkung: Die Einrückungen im XML Dokument (Whitespaces) dienen nur der Darstellung und sollen *nicht* als Textknoten im Baum aufscheinen. `documentNode` bezieht sich auf das XML Dokument, `rootNode` bezieht sich auf das Wurzelelement.

```
class Exam {
  public static void main() {
    Document documentNode; // DOCUMENT Node
    Node rootNode; // Wurzelelement (root)
    // Gegeben: Dokument lesen etc...
    rootNode = documentNode.getDocumentElement();
    secret(rootNode);
    // Aufgabe: DOM Baum zeichnen
  }
  private static void secret(Node n) {
    NodeList nl = n.getChildNodes();
    for(int i=0; i < 3; i++) {
      Node child = nl.item(0); // ACHTUNG! 0, nicht "i"
      n.removeChild(child);
    }
  }
```

```
<?xml version="1.0"?>
<!--Author: ssd@dbai.tuwien.ac.at-->
<?exam?>
<dbai>
  <office>1</office>
  <office status="public">2</office>
  <office>
    <suboffice>a</suboffice>
    <suboffice>b</suboffice>
    <suboffice>c</suboffice>
  </office>
  <office>3</office>
  <office>4</office>
</dbai>
```

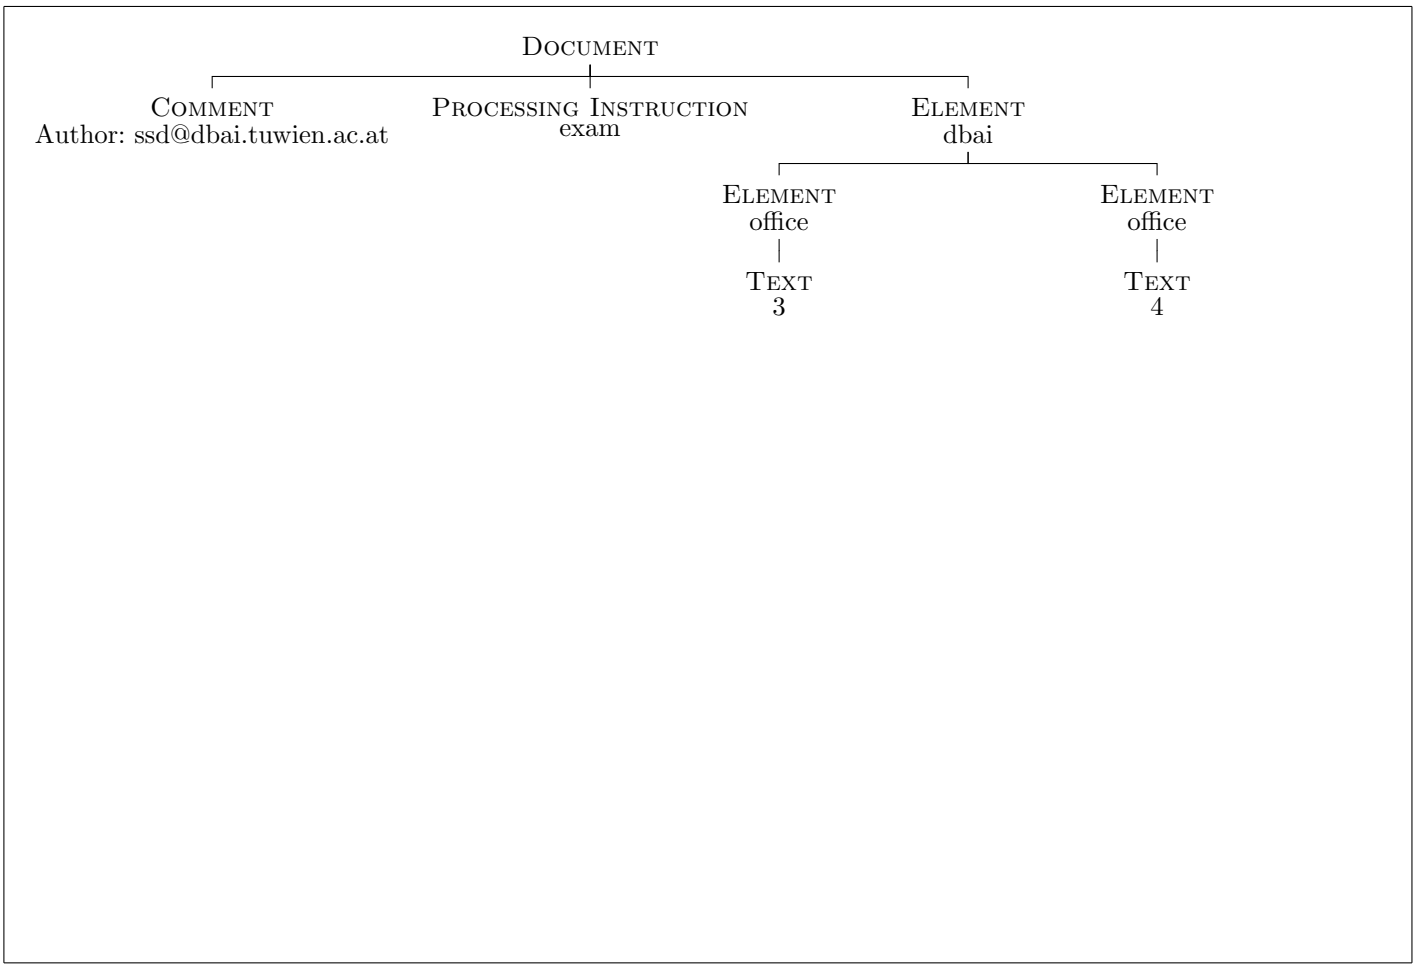

Aufgabe 3: (6)

Betrachten Sie die folgende XML- Datei **ns.xml**:

```
<?xml version="1.0" encoding="UTF-8"?>
<root xmlns="http://dbai.tuwien.ac.at" xmlns:tu="http://tuwien.ac.at">
  <first attr="wert"/>
  <tu:second xmlns:tu="http://tuwis.tuwien.ac.at"/>
</root>
```

Kreuzen Sie an, ob die folgenden Aussagen für die Datei **ns.xml** wahr oder falsch sind.

1. Das Element `first` liegt im Namespace `http://dbai.tuwien.ac.at`. wahr ⊗ falsch ◯
2. Das Attribut `attr` liegt im leeren Namespace. wahr ⊗ falsch ◯
3. Das Element `tu:second` liegt im Namespace `http://tuwien.ac.at`. wahr ◯ falsch ⊗
4. Das Element `root` liegt im Namespace `http://dbai.tuwien.ac.at`. wahr ⊗ falsch ◯

Aufgabe 4: (12)

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

1. `<e><text/>something<text/></e>` ist wohlgeformt. wahr ⊗ falsch ◯
2. Die DTD Elementdeklaration `(A?|B?|C?)+` ist gleichwertig mit `(A|B|C)*`. wahr ⊗ falsch ◯
3. In einer XML-Schema Datei muss der Defaultnamespace immer gleich dem Targetnamespace sein. wahr ◯ falsch ⊗
4. SAX verwendet die DOM API um ein XML Dokument zu lesen. wahr ◯ falsch ⊗
5. Der "parent" eines SAX-Filter kann selbst auch ein SAX-Filter sein. wahr ⊗ falsch ◯
6. Der XPath-Ausdruck `./a[@b=c]` ist die Kurzschreibweise des XPath-Ausdrucks `self::node()/child::a/attribute::b[c]` wahr ◯ falsch ⊗
7. Das Resultat eines XSLT-Stylesheet (angewandt auf ein wohlgeformtes XML-Dokument) ist immer ein wohlgeformtes XML-Dokument wahr ◯ falsch ⊗
8. Ein XSLT-Stylesheet muss nicht unbedingt ein wohlgeformtes XML-Dokument sein. wahr ◯ falsch ⊗

Aufgabe 5: (9)

Geben Sie eine DTD **kino.dtd** an, sodass das XML-Dokument **kino.xml** (siehe Anhang) bezüglich dieser DTD gültig ist. Berücksichtigen Sie beim Erstellen der DTD folgende Punkte:

- Die Reihenfolge der Elemente soll wie in **kino.xml** angegeben fixiert werden.
- Das Wurzelelement beinhaltet jeweils genau ein Element `standort`, `filme` und `spielplan`.
- Ein `saal` beinhaltet genau ein `name` Element.
- Ein `standort` beinhaltet ein oder mehrere `saal` Elemente.
- Ein `film` beinhaltet genau ein `name` und `regie` Element, jedoch zwei oder mehr `darsteller` Elemente.
- Alle weiteren Elemente können beliebig oft vorkommen.
- Alle Attribute sollen verpflichtend sein. Die Attribute `kennung` und `nr` sollen vom Typ `ID` sein, und `film` sowie `saal` sollen Referenzen auf die ID-Attribute sein.

Datei **kino.dtd**:

```
<?xml version="1.0" encoding="UTF-8"?>
<!ELEMENT kino (standort, filme, spielplan)>
<!ELEMENT standort (saal)+>
<!ELEMENT saal (name)>
<!ATTLIST saal kennung ID #REQUIRED>
<!ELEMENT name (#PCDATA)>
<!ELEMENT filme (film)*>
<!ELEMENT film (name, regie, darsteller, darsteller+)>
<!ATTLIST film nr ID #REQUIRED>
<!ELEMENT regie (#PCDATA)>
<!ELEMENT darsteller (#PCDATA)>
<!ELEMENT spielplan (auffuehrung)*>
<!ELEMENT auffuehrung (ort)*>
<!ATTLIST auffuehrung datum CDATA #REQUIRED>
<!ATTLIST auffuehrung film IDREF #REQUIRED>
<!ELEMENT ort (#PCDATA)>
<!ATTLIST ort uhrzeit CDATA #REQUIRED>
<!ATTLIST ort saal IDREF #REQUIRED>
```

Aufgabe 6: (12)

Betrachten Sie die folgenden drei XSLT-Stylesheets. Geben Sie jeweils den Output an, den das entsprechende Stylesheet angewandt auf **kino.xml** (siehe Anhang) liefert. Sie brauchen sich dabei nicht um Whitespaces etc. kümmern.

Anmerkung: Pro Teilaufgabe sind jeweils 4 Punkte erreichbar.

Nehmen Sie an dass jede Datei mit einem korrekten Header versehen ist. zB

```
<?xml version="1.0" encoding="UTF-8"?>
<xsl:stylesheet version="1.0" xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
```

Datei **query1.xsl**:

```
<xsl:output method="text" encoding="UTF-8" version="1.0" />
<xsl:template match="/kino/standort">
  <xsl:apply-templates/>
</xsl:template>
<xsl:template match="/kino/filme">
  <xsl:apply-templates select="./film/name"/>
</xsl:template>
<xsl:template match="/kino/spielplan">
  <!-- empty -->
</xsl:template>
<xsl:template match="/kino/spielplan/auffuehrung">
  <xsl:copy-of select="."/>
</xsl:template>
</xsl:stylesheet>
```

Geben Sie hier den Output von **query1.xsl** angewandt auf **kino.xml** an:

```
Audi Max
Saal 2
Saal 3
Saal 4
Krieg der Sterne - Eine neue Hoffnung
Der Herr der Ringe - Die Gefährten
Der Pate
```

Datei **query2.xsl**:

```
<xsl:output method="text" encoding="UTF-8" version="1.0" />
<xsl:template match="/">
  <xsl:for-each select="/kino/filme/film">
    <xsl:variable name="curFilm" select="./@nr"/>
    <xsl:value-of select="./name"/>
    <xsl:for-each select="/kino/spielplan/auffuehrung[@film=$curFilm]">
      <xsl:value-of select="./@datum"/>
    </xsl:for-each>
  </xsl:for-each>
</xsl:template>
</xsl:stylesheet>
```

Geben Sie hier den Output von **query2.xsl** angewandt auf **kino.xml** an:

```
Krieg der Sterne - Eine neue Hoffnung
2009-10-22
2009-10-23
Der Herr der Ringe - Die Gefährten
2009-10-22
Der Pate
2009-10-22
```

Datei **query3.xsl**:

```
<xsl:output method="xml" encoding="UTF-8" version="1.0" />
<xsl:template match="/">
  <xsl:for-each select="/kino/*[position()=1]/*">
    <xsl:if test="position()=last()">
       <xsl:copy-of select="."/>
    </xsl:if>
  </xsl:for-each>
</xsl:template>
</xsl:stylesheet>
```

Geben Sie hier den Output von **query3.xsl** angewandt auf **kino.xml** an:

```
<saal kennung="s4">
   <name>Saal 4</name>
</saal>
```

Aufgabe 7: (9)

Schreiben Sie einen **XMLFilter** der nur das `filme` Element **und dessen Subelemente** weiterreicht. Sie müssen also alle Events ignorieren außer Sie befinden sich innerhalb des `filme` Elements. Sie brauchen sich lediglich um Elemente und Attribute kümmern. Beispiel (Input → Output):

```
<kino>
  <standort>
    <!-- ... -->
  </standort>
  <filme>
    <film nr="f123">
      <!-- ... -->
    </film>
  </filme>
  <spielplan>
    <!-- ... -->
  </spielplan>
</kino>
```

```
<filme>
  <film nr="f123">
    <!-- ... -->
  </film>
</filme>
```

Tipp: Die Klasse `FilmPassFilter` erweitert `XMLFilterImpl`, dh. per default werden alle Events durchgereicht. Überschreiben Sie die relevanten Methoden und geben Sie ein Event nur dann an die Superklasse weiter (mittels `super...`) wenn Sie es behalten wollen.
Verwenden Sie eine Variable die anzeigt ob sie innerhalb des `filme` Elements sind.

```
class FilmPassFilter extends XMLFilterImpl {

  private boolean inFilme = false;
  public void startElement(String namespaceURI, String localName, String qName, Attributes atts)
  throws SAXException {
    if(localName.equals("filme")) { inFilme = true; }
    if(inFilme) { super.startElement(namespaceURI, localName, qName, atts); }
  }

  public void endElement(String namespaceURI, String localName, String qName)
  throws SAXException {
    if(inFilme) { super.endElement(namespaceURI, localName, qName); }
    if(localName.equals("filme")) { inFilme = false; }
  }

}
```

Aufgabe 8: (8)

Schreiben Sie XPath-Anfragen für folgende Aufgabenstellungen. Zu jeder Abfrage ist ein Beispiel mit der erwarteten Ausgabe (bezgl. `kino.xml`) angegeben. Die Abfragen sollen auf allen Dokumenten, die gültig bezgl. `kino.dtd` sind, funktionieren.

1. Geben Sie die Namen aller bekannten Säle aus.

```
<name>Audi Max</name>
<name>Saal 2</name>
<name>Saal 3</name>
<name>Saal 4</name>
```

```
//saal/name
```

2. Selektieren Sie jene `auffuehrung`-Elemente aus, die keinen `ort`-Subelement haben.

```
<auffuehrung datum="2009-10-23" film="f123"/>
```

```
//auffuehrung[not(./ort)]
```

3. Geben Sie aus, wie oft der Film "f123" am "2009-10-22" gespielt wird (zählen Sie die `ort` Elemente).

```
2
```

```
count(//auffuehrung[@datum='2009-10-22' and @film='f123']/ort)
```

4. Geben Sie alle Regiseure aus, die im "Audi Max" (Sie **dürfen** die Kennung "am" direkt verwenden) gespielt werden.

```
<regie>George Lucas</regie>
<regie>Peter Jackson</regie>
```

```
//film[@nr = //auffuehrung[./ort[@saal='am']]/@film]/regie
```

Sie können diese Seite abtrennen!

kino.xml

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE kino SYSTEM "kino.dtd">
<kino>
  <standort>
    <saal kennung="am"> <name>Audi Max</name> </saal>
    <saal kennung="s2"> <name>Saal 2</name> </saal>
    <saal kennung="s3"> <name>Saal 3</name> </saal>
    <saal kennung="s4"> <name>Saal 4</name> </saal>
  </standort>
  <filme>
    <film nr="f123">
      <name>Krieg der Sterne IV</name>
      <regie>George Lucas</regie>
      <darsteller>Mark Hamill</darsteller>
      <darsteller>Harrison Ford</darsteller>
    </film>
    <film nr="f124">
      <name>Der Herr der Ringe - Die Gefährten</name>
      <regie>Peter Jackson</regie>
      <darsteller>Elijah Wood</darsteller>
      <darsteller>Ian McKellen</darsteller>
    </film>
    <film nr="f125">
      <name>Der Pate</name>
      <regie>Francis Ford Coppola</regie>
      <darsteller>Marlon Brando</darsteller>
      <darsteller>Al Pacino</darsteller>
    </film>
  </filme>
  <spielplan>
    <auffuehrung datum="2009-10-22" film="f123">
      <ort uhrzeit="22:00" saal="am"/>
      <ort uhrzeit="22:30" saal="s4"/>
    </auffuehrung>
    <auffuehrung datum="2009-10-22" film="f124">
      <ort uhrzeit="19:15" saal="am"/>
      <ort uhrzeit="21:00" saal="s2"/>
      <ort uhrzeit="20:45" saal="s3"/>
    </auffuehrung>
    <auffuehrung datum="2009-10-22" film="f125">
      <ort uhrzeit="20:15" saal="s3"/>
    </auffuehrung>
    <auffuehrung datum="2009-10-23" film="f123"/>
  </spielplan>
</kino>
```

Gesamtpunkte: 75