

Applicability of XML-based Document Formats

Seminar: XML-Based Markup Languages
(WS09/10)

Simon Trang

ISO certified XML-based office formats

JTC 1/SC 34: Document description and processing languages

May 2006

ISO/IEC 26300:2006 Open Document Format for
Office Applications -- OpenDocument -- v1.0 (ODF)

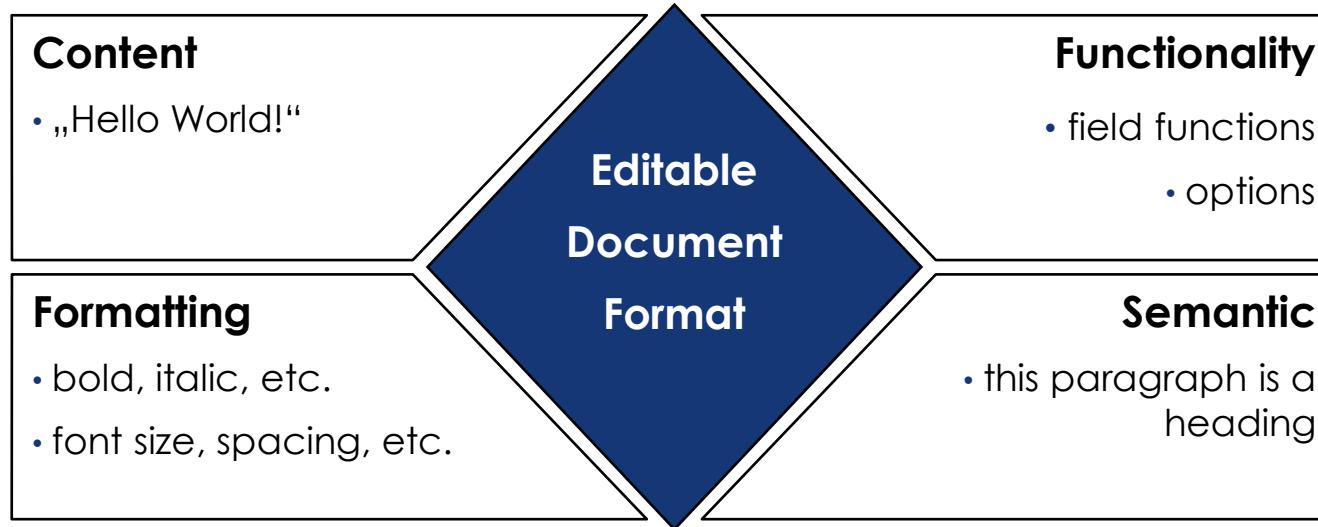
November 2008

ISO/IEC 29500 Document description and
processing languages -- Office Open XML File
Formats -- Part 1-4 (OOXML)

Table of Content

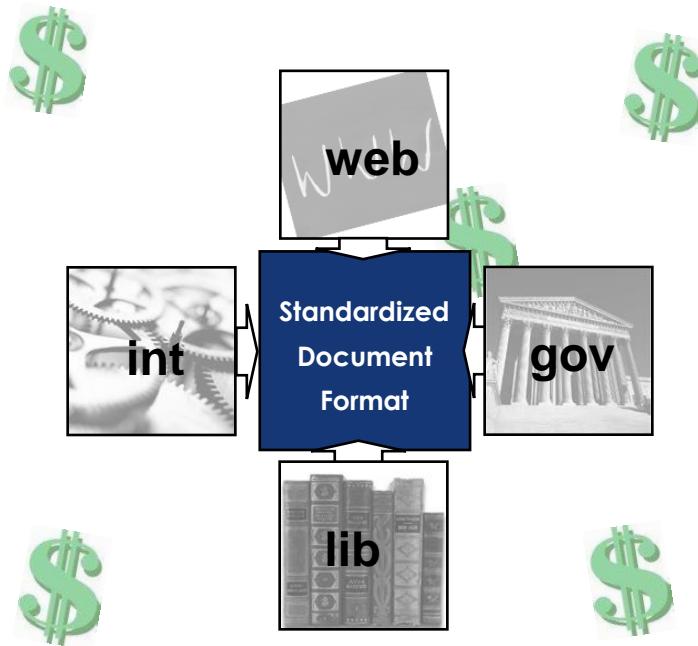
- 
1.
 - **Background**
 - Need for standardized Document Formats and shift to XML
 - Challenges of Document Formats
 - History of ODF and OOXML
 2.
 - **Technical Introduction to ODF and OOXML**
 - Open Office XML
 - Open Document Format
 - Evaluation of OOXML and ODF
 3.
 - **Case Study: Content Management with ODF**
 - Idea
 - Realization
 - Conclusion and Outlook

Challanges of editable Document Formats



Need for standardized Document Formats in XML

Drivers of standardization



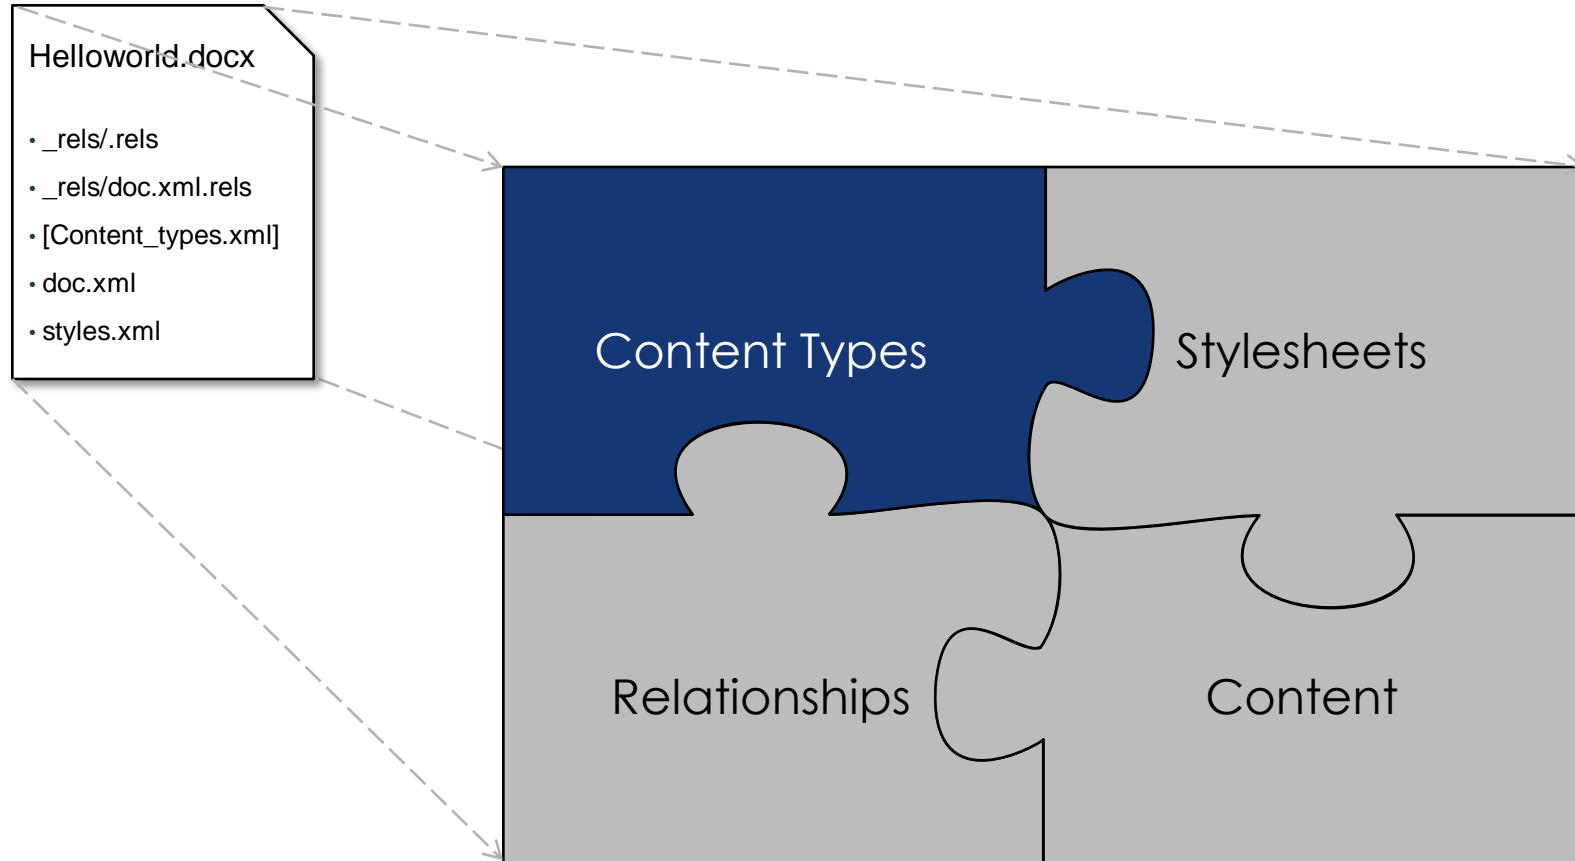
Why XML?

- Already a de-facto standard
- Easy to understand
- Tool support

Table of Content

- 
1.
 - **Background**
 - Need for standardized Document Formats and shift to XML
 - Challenges of Document Formats
 - History of ODF and OOXML
 2.
 - **Technical Introduction to ODF and OOXML**
 - Open Office XML
 - Open Document Format
 - Evaluation of OOXML and ODF
 3.
 - **Case Study: Content Management with ODF**
 - Idea
 - Realization
 - Conclusion and Outlook

Office Open XML: General Structure of a Container



Office Open XML: Content Types

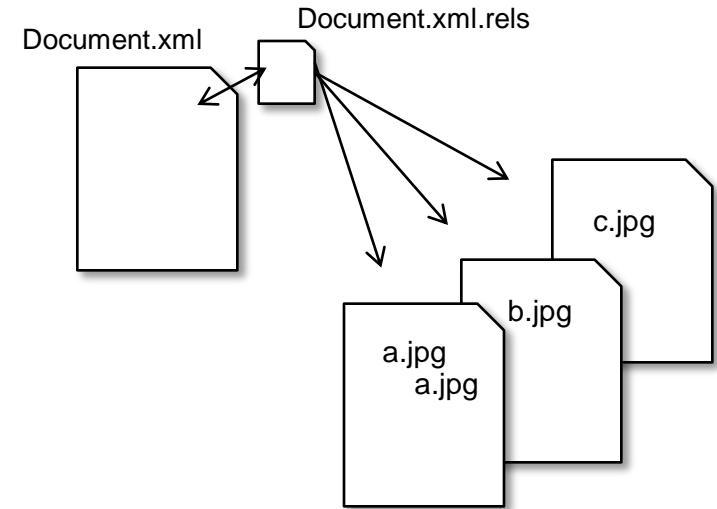
- Defines the MIME media types for all files within the container
- Helps the consumer to identify the content of a file
- Two ways to define the content type of a file:
 - a default file extension (e.g. all .png files are pngs),
 - a direct addressing (e.g. even though this files end with png, it is a text file).

A typical [Content_Types.xml]:

```
<Types>
  <Default Extension="rels" ContentType="application/vnd.openxmlformats-package.relationships+xml"/>
  <Default Extension="xml" ContentType="application/xml"/>
  <Default Extension="png" ContentType="image/png"/>
  <Override PartName="/word/document.xml" ContentType="application/vnd.openxmlformats-officedocument.wordprocessingml.document.main+xml"/>
  <Override PartName="/word/styles.xml" ContentType="application/vnd.openxmlformats-officedocument.wordprocessingml.styles+xml"/>
</Types>
```

Office Open XML: Relationships

- Every file can have a relationship file (filename + .rels extension)
- Every relationship has an id and carries the the path of the linked file within the package
- Relationships within a file are done by the unique identifier
- Even the entry point of the package is specified by an relationship file



A typical relationship file:

```
<Relationships>
  <Relationship Id="rId1"
    Type="http://schemas.openxmlformats.org/officeDocument/2006/relationships/officeDocument"
    Target="word/document.xml"/>
</Relationships>
```

Office Open XML: Content (WordprocessingML)

- Content files have information about content and formatting properties
- In general a file with style sheets is linked

Schematic structure of a Hello World example:

```
<w:document> ...
    <w:body>
        <w:p>
            <w:pPr>
                <w:pStyle w:val="Title"/>
            </w:pPr>
            <w:r>
                <w:t>Hello World!</w:t>
            </w:r>
        </w:p>
    </w:body>
</w:document>
```

Office Open XML: Stylesheet

- Stylesheets are linked to a content file
- They can be assigned to runs, paragraphs, tables, etc.

Schematic structure of a stylesheet file example:

```
<w:styles>
    <w:docDefaults> <w:pPrDefault> ... </w:pPrDefault>
    </w:docDefaults>
    <w:style w:type="paragraph" w:styleId="Title">
        <w:name w:val="Title"/>
        <w:next w:val="StandardforContinuousText"/>
        <w:pPr>
            <w:spacing w:after="120"/>
            <w:jc w:val="center"/>
        </w:pPr>
        <w:rPr>
            <w:rFonts w:ascii="Cambria"/>
        </w:rPr>
    </w:style>
</w:styles>
```

Open Document Format: General Container Structure

Style classes

- ODF has a fixed packet structure
- Similar to the Content Types of OOXML the manifest.xml describes the type of each file
- The mimetype shows assessing applications the document type
- The meta.xml has meta information about the document like author, date, etc.

Helloworld.odf

- _META-INF/manifest.xml
- content.xml
- meta.xml
- mimetype
- styles.xml
- ...

Open Document Format: Styles

Style classes

- Common styles

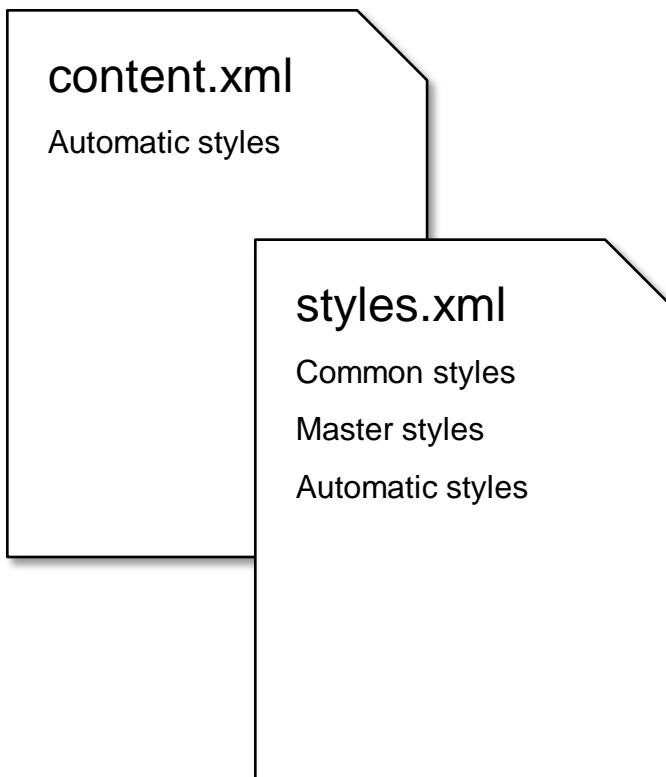
(User-)Predefined style information like paragraph or page formatting

- Master styles

Extend Common styles with additional content like header or footer

- Automatic styles

Automatic defined styles, especially for formatting without user defined styles



content.xml

Automatic styles

styles.xml

Common styles

Master styles

Automatic styles

Open Document Format: document.xml

```
<office:document-content office:version="1.0">
    <office:automatic-styles>
        <style:style style:name="p1" style:family="paragraph" style:parent-style-name="Standard">
            <style:paragraph-properties fo:text-align="center"/>
        </style:style>
    </office:automatic-styles>
    <office:body>
        <office:text>
            <text:p text:style-name="p1">Hello World!</text:p>
        </office:text>
    </office:body>
</office:document-content>
```

Evaluation of OOXML and ODF

OOXML

- Long syntax
- Mixture of content and formatting properties
- File access with relationships
- Little use of existing standards
- A lot of tool support, e.g. APIs for programming languages

ODF

- Short syntax
- Sharp distinction between content and layout
- Fixed packet structure
- Reuse of existing standards like xsl:fo, XLink and SVG

Table of Content

- 
1.
 - **Background**
 - Need for standardized Document Formats and shift to XML
 - Challenges of Document Formats
 - History of ODF and OOXML
 2.
 - **Technical Introduction to ODF and OOXML**
 - Open Office XML
 - Open Document Format
 - Evaluation of OOXML and ODF
 3.
 - **Case Study: Content Management with ODF**
 - Idea
 - Realization
 - Conclusion and Outlook

Idea of a wordprocessing-based Content Management

Content Management System

- Supports easy data storage and retrieval
- Often, manual data input is immature

Wordprocessing Application

- User-friendly and sophisticated
- Macros allow additional functionality

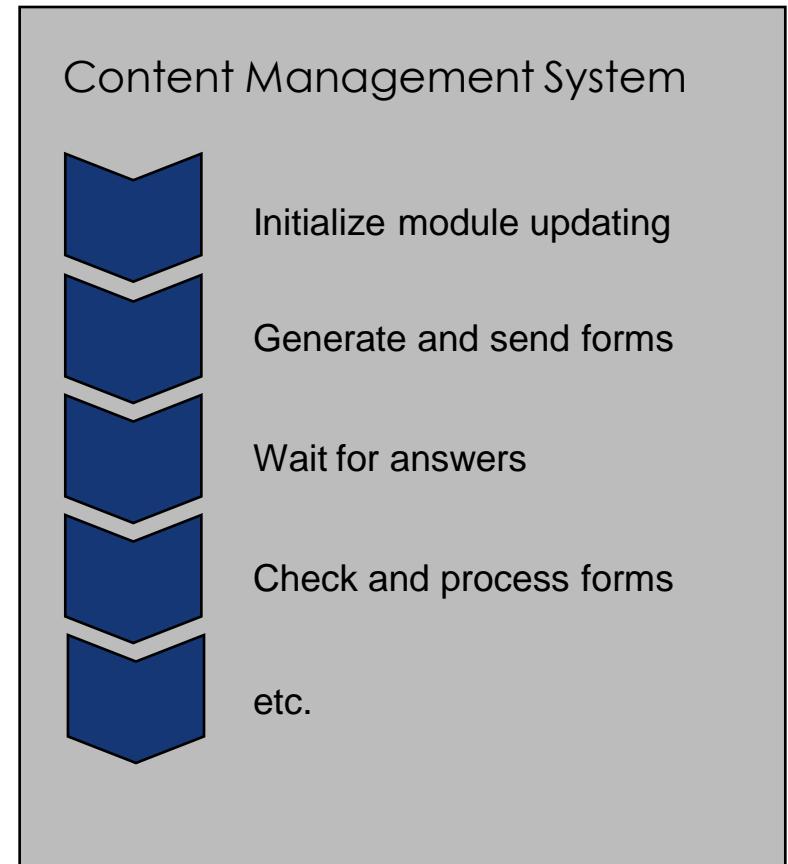
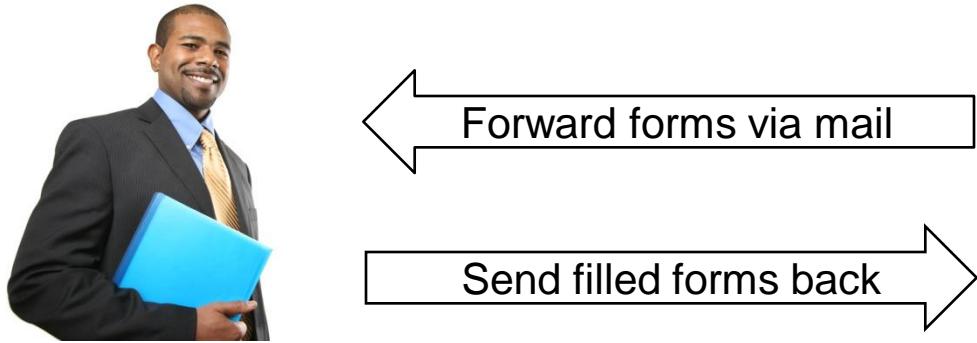
Extensible Stylesheet Language

- Stream-based language to transform XML

Wordprocessing Documents as data input

- Prepared wordprocessing files have input fields
- Fields can be tagged with styles
- Macro can check validation
- XSL script transforms document to a format as requested (e.g. DB)
- Simple formatting properties like bold or italic can be used

Application on university context: updating Modules



Implementation in ODF (Open Office)

Why ODF?
simple syntax and strict distinction of style and content

Field description (is not relevant for processing)

Yellow background color indicates that a style is assigned

Stylesheets indicate text fields

Modul:1 → 1	
Nummer des Moduls	CS B.inf.101.(B.OPH.04)
Bezeichnung des Moduls	
Sprache	
Verantwortliche	
Credits	
Workload	
Leistungsnachwe	
Lehr- und Lernformen	
Erwartete Vorken	
Besondere Empf	
Lernziele	
Überblick über die	
Literatur	

Modul:2 → 1	
Nummer des Moduls	CS B.inf.102.(B.OPH.04)
Bezeichnung des Moduls	Informatik-II
Sprache	deutsch
Verantwortliche Lehrperson	Prof. Dr. Wolfgang Mayr
Credits	9
Workload	270(64/206)
Leistungsnachweise	Klausur (90 Min), Hausarbeit Anmerkung: Hausarbeit oder Klausur 90 Min
Lehr- und Lernformen	Vorlesung (4-SWS), Selbststudium
Erwartete Vorkenntnisse	
Besondere Empfehlung	
Lernziele	Kennenlernen effizienter Algorithmen Kennenlernen von Methoden des Entwurfs und der Analyse effizienter Algorithmen Kennenlernen der Paradigmen NP-Vollständigkeit und NP-Aquivalenz
Überblick über die Modulinhalte	Effiziente Algorithmen für grundlegende Probleme (z.B. Suchen, Sortieren, Graphalgorithmen), Methoden des Entwurfs und der Analyse effizienter Algorithmen, NP-Vollständigkeit und NP-Aquivalenz, Entwurf und Analyse effizienter Algorithmen
Literatur	- Algorithmen und Datenstrukturen von Günter Saake und Kai-Uwe Sattler, erschienen im dpunkt-Verlag (2002), 2.Auflage 2004 - Algoritms in Java von R. Sedgewick, 2003 - Programmieren mit Java von R. Schiedermeier, Pearson Studium, 2004

Comments on XSLT Transformation

content.xml

Two screenshots of the 'content.xml' file showing two modules:

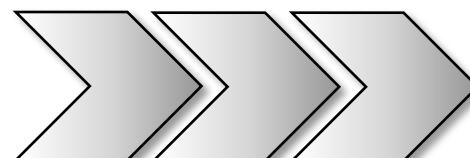
- Modul:-1 → 1:**
 - Nummer des Moduls: CS B inf 101 (B.OPH.04)
 - Bezeichnung des Moduls: Informatik I
 - Sprache: deutsch
 - Vorstandsvollmacht: Prof. Dr. Wolfgang May
 - Credits: 9
 - Werkstoff: 270/64/206
 - Leistungsnachweise: Klausur (90 Min), Hausarbeit, Anmerkung: Hausarbeit oder Klausur 90 Min.
 - Lehr- und Lernformen: Vorlesung (4 SWS), Selbststudium
 - Erwartete Vorkenntnisse: 4
 - Besondere Empfehlung: 4
 - Lernziele: Kennenlernen effizienter Algorithmen, Kennenlernen von Methoden des Entwurfs und der Analyse effizienter Algorithmen, Kennenlernen der Paradigmen NP-Vollständigkeit und NP-Teilvollständigkeit
 - Übersicht über die Modulinhale: Effiziente Algorithmen für grundlegende Probleme (z.B. Suchen, Sortieren, Graphalgorithmen), Methoden des Entwurfs und der Analyse effizienter Algorithmen, NP-Vollständigkeit und NP-Nichtvollständigkeit, Entwurf und Analyse effizienter Algorithmen
 - Literatur: Algorithmen und Datenstrukturen von Günter Saake und Kai-Uwe Sattler, erschienen im dpunkt-Verlag (2002, 2. Auflage 2004), Algorithmen und Datenstrukturen von R. Sedgewick, 2003, Programmierung mit Java von R. Schäfermeier, Pearson Studium, 2004
- Modul:-2 → 1:**
 - Nummer des Moduls: CS B inf 102 (B.OPH.04)
 - Bezeichnung des Moduls: Informatik II
 - Sprache: deutsch
 - Vorstandsvollmacht: Prof. Dr. Wolfgang May
 - Credits: 9
 - Werkstoff: 270/64/206
 - Leistungsnachweise: Klausur (90 Min), Hausarbeit, Anmerkung: Hausarbeit oder Klausur 90 Min.
 - Lehr- und Lernformen: Vorlesung (4 SWS), Selbststudium
 - Erwartete Vorkenntnisse: 4
 - Besondere Empfehlung: 4
 - Lernziele: Kennenlernen effizienter Algorithmen, Kennenlernen von Methoden des Entwurfs und der Analyse effizienter Algorithmen, Kennenlernen der Paradigmen NP-Vollständigkeit und NP-Teilvollständigkeit
 - Übersicht über die Modulinhale: Effiziente Algorithmen für grundlegende Probleme (z.B. Suchen, Sortieren, Graphalgorithmen), Methoden des Entwurfs und der Analyse effizienter Algorithmen, NP-Vollständigkeit und NP-Nichtvollständigkeit, Entwurf und Analyse effizienter Algorithmen
 - Literatur: Algorithmen und Datenstrukturen von Günter Saake und Kai-Uwe Sattler, erschienen im dpunkt-Verlag (2002, 2. Auflage 2004), Algorithmen und Datenstrukturen von R. Sedgewick, 2003, Programmierung mit Java von R. Schäfermeier, Pearson Studium, 2004

```

<xsl:stylesheet version="1.0" encoding="UTF-8">
<xsl:stylesheet version="1.0" encoding="UTF-8" href="http://www.w3.org/1999/XSL/Transform"
  xmlns:xsl="urn: oasis:namestc:opendocument:xmlns:xsl:1.0"
  xmlns:office="urn: oasis:namestc:opendocument:xmlns:office:1.0"
  xmlns:xs="http://www.w3.org/2001/XMLSchema" xmlns:table="urn: oasis:namestc:opendocument:xmlns:table:1.0"
  xmlns:c="urn: oasis:namestc:opendocument:xmlns:style:1.0" xmlns:fct="http://example.org/my" version="1.0">
  <xsl:template match="office:document-content">
    <xsl:apply-templates select="office:body/office:text/text:h"/>
  </xsl:template>
  <xsl:template match="text:h">
    <xsl:attribute name="id">
      <xsl:copy-of select="following-sibling::table:table[1]/textp[@textstyle-name='30_3a_20_Nummer_20_des_20_Moduls']"/>
    </xsl:attribute>
    <!-- Zeichenangaben -->
    <!-- Sprache -->
    <!-- Lehrperson -->
    <!-- Credits -->
    <!-- Werkload -->
    <!-- Leistungsnachweise -->
    <!-- Lehrformen -->
    <!-- Lernziele -->
    <!-- Empfehlung -->
    <!-- Literatur -->
    <!-- Modul -->
  </xsl:template>
  <xsl:function name="fct:addParagraphs">
    <xsl:styleSheet>
  </xsl:styleSheet>
  </xsl:function>
</xsl:stylesheet>

```

stylesheet.xsl



XSL Processor

result.xml

```

<xml version="1.0" encoding="UTF-8">
<result xmlns="http://www.w3.org/2001/XMLSchema">
  <modules>
    <module id="CS_B.inf.101_(B.OPH.04)">
      <modul id="CS_B.inf.101_(B.OPH.04)">
        <Bezeichnung>
          <p>Informatik II</p>
        </Bezeichnung>
        <Sprache>
          <p>deutsch</p>
        </Sprache>
        <Lehrperson>
          <p>Prof. Dr. Wolfgang May</p>
        </Lehrperson>
        <Credits>
          <p>9</p>
        </Credits>
        <Workload>
          <p>270/64/206</p>
        </Workload>
        <Leistungsnachweise>
          <p>Klausur (90 Min), Hausarbeit, Anmerkung: Hausarbeit oder Klausur 90 Min.</p>
        </Leistungsnachweise>
        <Lernformen>
          <p>Vorlesung (4 SWS), Selbststudium</p>
        </Lernformen>
        <Vorkenntnisse>
          <p>4</p>
        </Vorkenntnisse>
        <Empfehlung>
          <p>4</p>
        </Empfehlung>
        <Lernziele />
        <Modulinhale />
        <Literatur>
          <p>Algorithmen und Datenstrukturen von Günter Saake und Kai-Uwe Sattler, erschienen im dpunkt-Verlag (2002, 2. Auflage 2004), Algorithmen und Datenstrukturen von R. Sedgewick, 2003, Programmierung mit Java von R. Schäfermeier, Pearson Studium, 2004</p>
        </Literatur>
      </modul>
    </module>
    <module id="CS_B.inf.102_(B.OPH.04)">
      <modul id="CS_B.inf.102_(B.OPH.04)">
        <Bezeichnung>
          <p>Informatik II</p>
        </Bezeichnung>
        <Sprache>
          <p>deutsch</p>
        </Sprache>
        <Lehrperson>
          <p>Prof. Dr. Wolfgang May</p>
        </Lehrperson>
        <Credits>
          <p>9</p>
        </Credits>
        <Workload>
          <p>270/64/206</p>
        </Workload>
        <Leistungsnachweise>
          <p>Klausur (90 Min), Hausarbeit, Anmerkung: Hausarbeit oder Klausur 90 Min.</p>
        </Leistungsnachweise>
        <Lernformen>
          <p>Vorlesung (4 SWS), Selbststudium</p>
        </Lernformen>
        <Vorkenntnisse>
          <p>4</p>
        </Vorkenntnisse>
        <Empfehlung>
          <p>4</p>
        </Empfehlung>
        <Lernziele />
        <Modulinhale />
        <Literatur>
          <p>Algorithmen und Datenstrukturen von Günter Saake und Kai-Uwe Sattler, erschienen im dpunkt-Verlag (2002, 2. Auflage 2004), Algorithmen und Datenstrukturen von R. Sedgewick, 2003, Programmierung mit Java von R. Schäfermeier, Pearson Studium, 2004</p>
        </Literatur>
      </modul>
    </module>
  </modules>
</result>

```

Evaluation

Advantages

- Wordprocessing applications are very user-friendly
- Everyone can handle them
- They are widely spread and some are for free
- Software is mature
- You can use features like spell- and grammerchecker
- Simple formatting can be used
- Macros are a powerful tool to enhance functionality (e.g. check constraints, ...)

Limits and challenges

- Objects like paragraphs or cells can only be tagged once
- Even though the documents are written in XML, the heading tags are sequential
- The work on document is offline

Conclusion and Outlook

- New XML-based document formats offer easy access on document content
- Tagged content can be processed very easily to extract content
- Some difficulties with non-hierarchical heading structure
- Import of content from ODF files general possible

- Scenario should be extended
- Until now, macros are not implemented
- Generic framework for content extraction with stylesheets is imaginable
- This pattern can be applied to many other problems

Thank you for your attention!

Questions?

Backup

History of XML-based office formats

1999: StarDivision began to work on an XML based interchangeable format

August 1999: Sun acquired StarDivision

2000: Sun released the code of Star Office under an open license and a project for a specification of an open format was initiated.

Mai 2005: ODF format was approved as an OASIS standard

May 2006: ODF achieved ISO certification



November 2003: MS Office 2003 was released with first XML support.

December 2006: OOXML became an ECMA standard

November 2008: OOXML got its ISO certification