Tag 5
Inhaltsverzeichnis

- Big Picture "Datenformate"
- XML
- JSON
- CSV
- Zeichenkodierung
- Übungen
- BYOQ

Big Picture
Datenformate

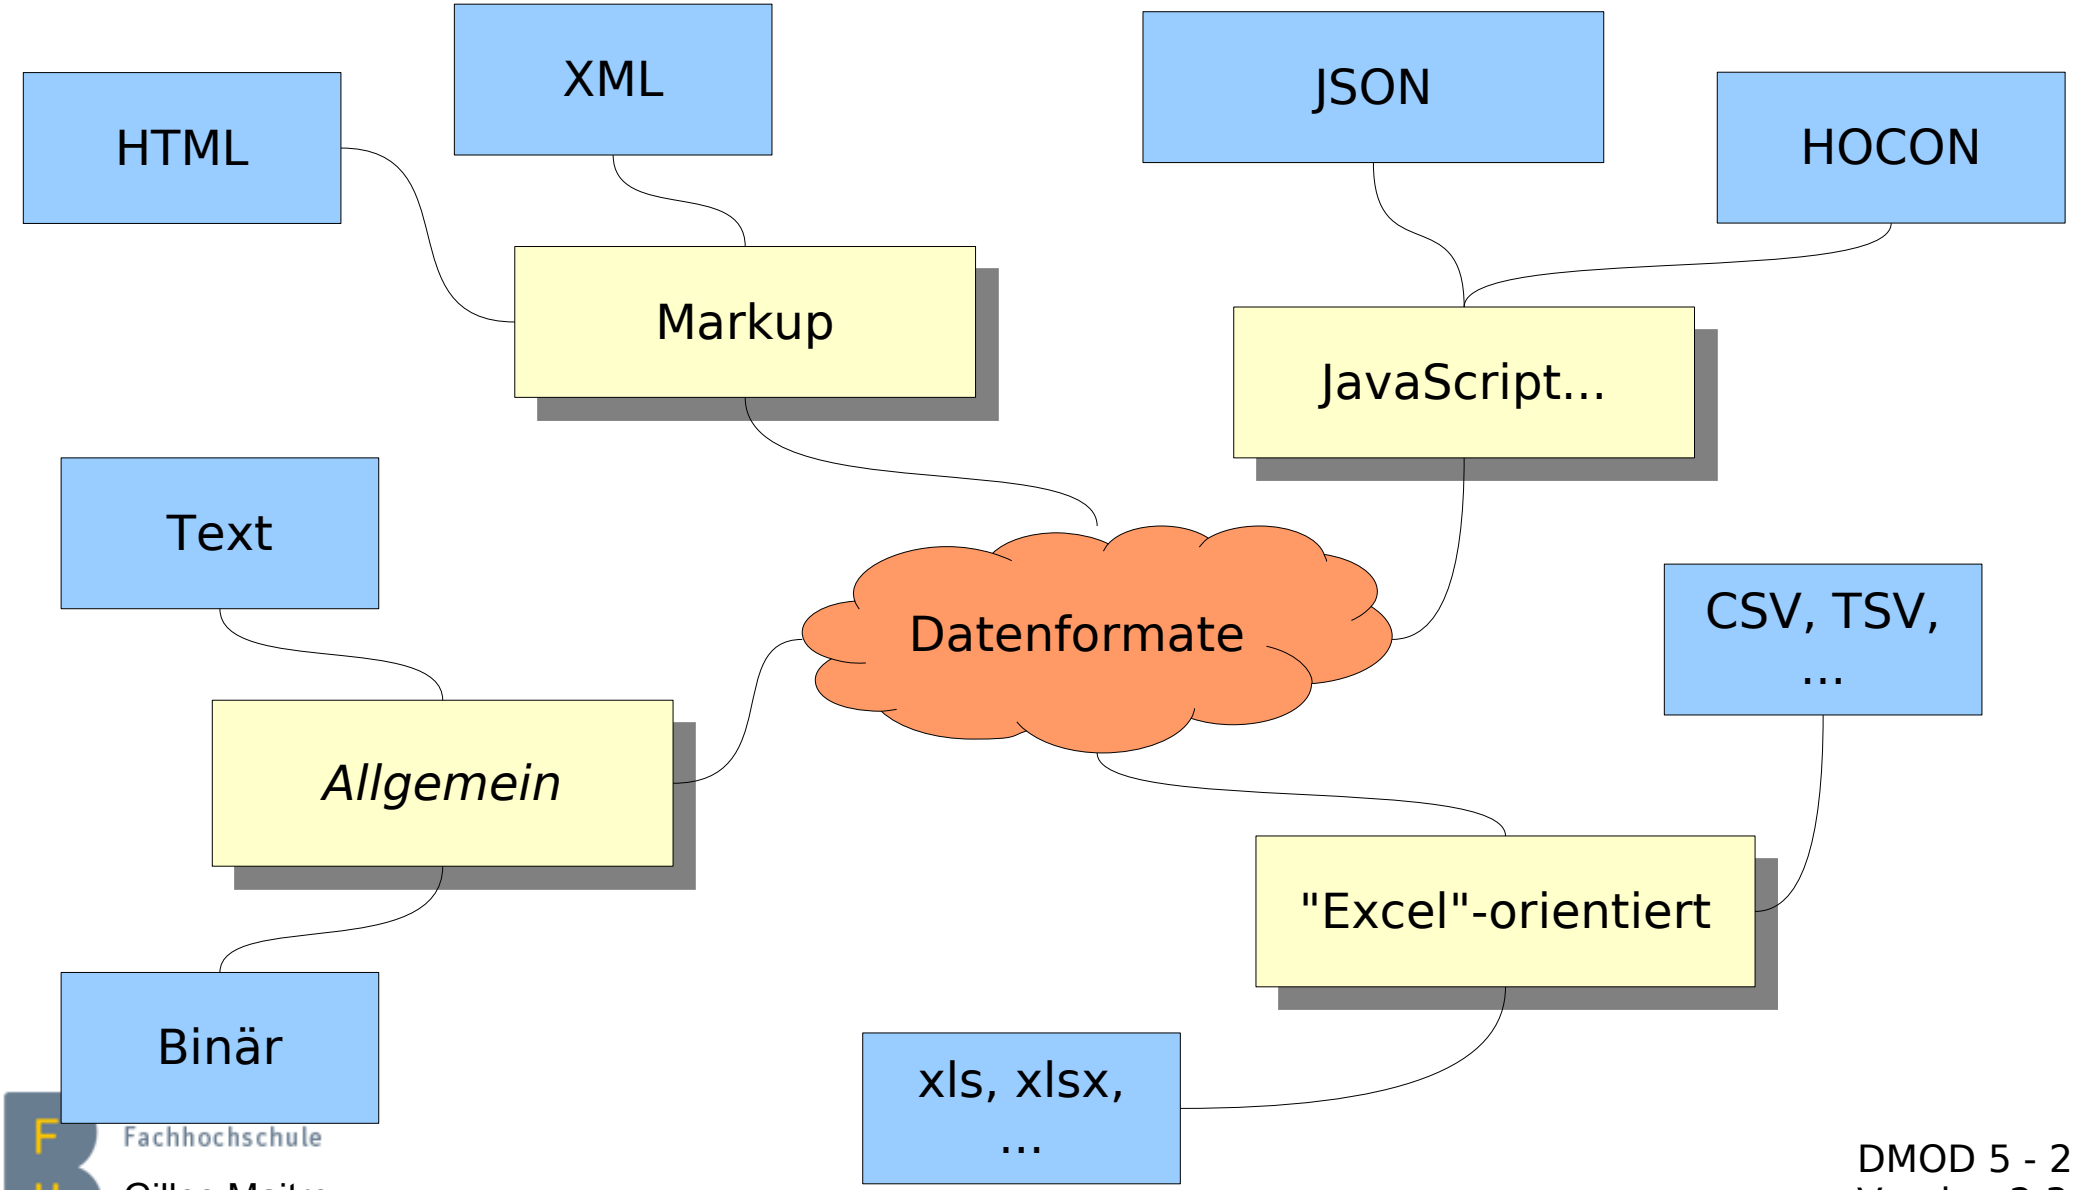

XML
Grundlagen

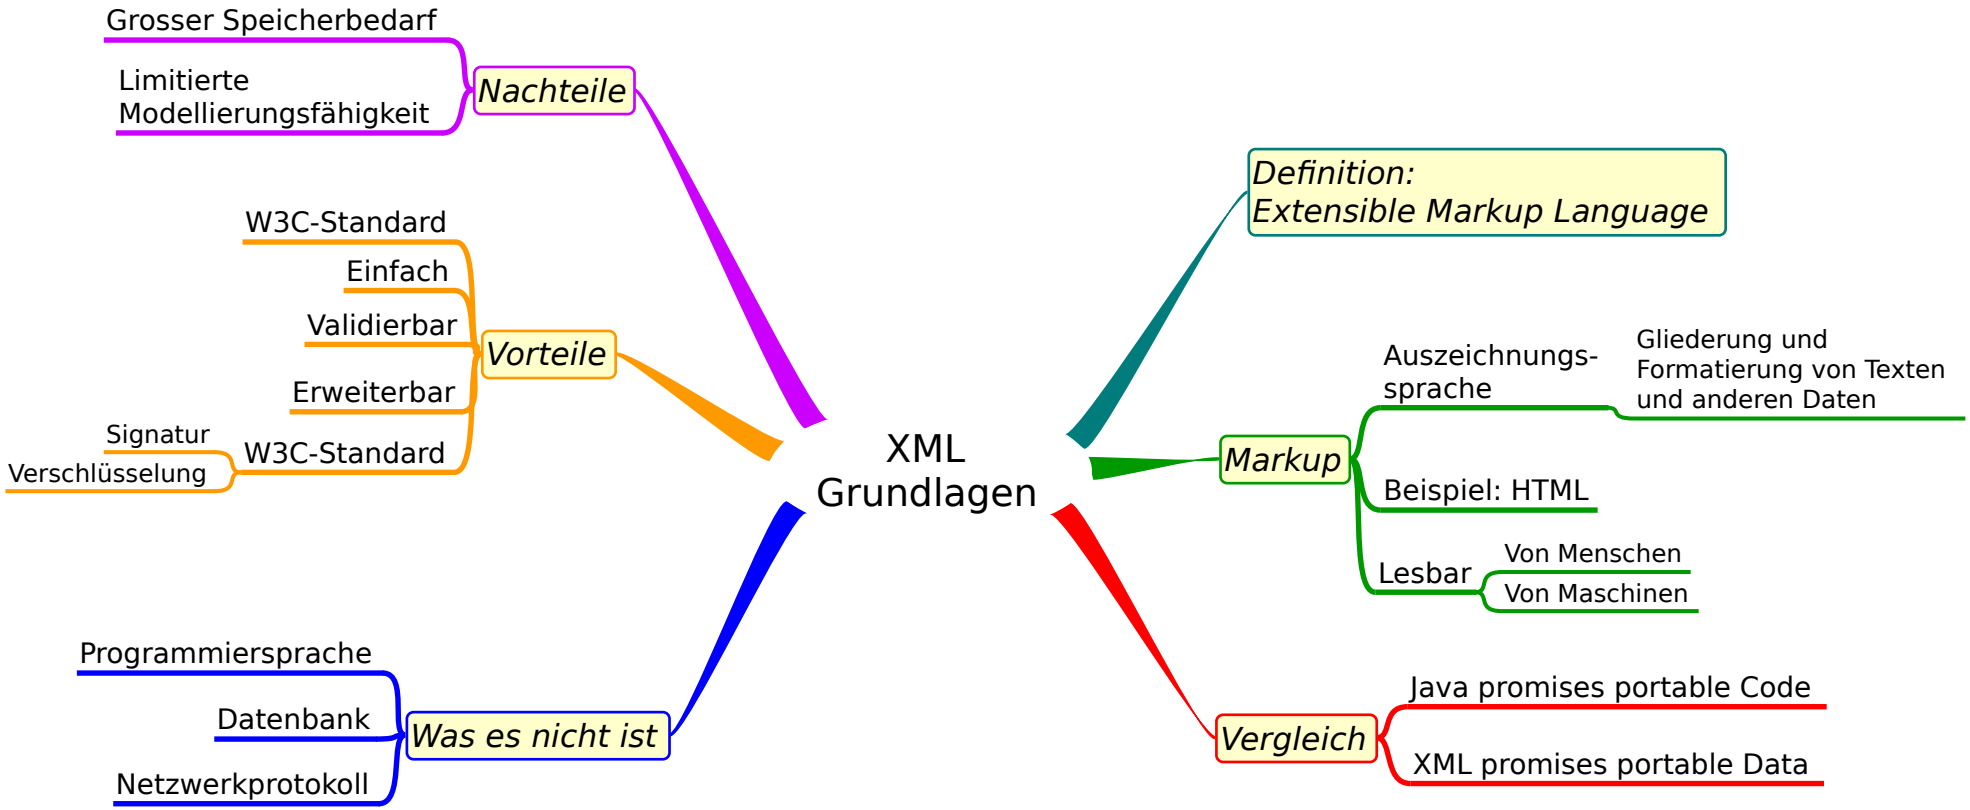

Quellen:
https://de.wikipedia.org/wiki/Extensible_Markup_Language
https://de.wikipedia.org/wiki/World_Wide_Web_Consortium
Tools:
Windows: Notepad++; Linux: Kate

Berner Fachhochschule
Gilles Maitre

XML
Inhalt eines Dokuments (1)

```
<Saeugetier>
  <Raubkatze>
    <Katze/>
  </Raubkatze>
</Saeugetier>
```

- Eine Menge Elemente, delimited by < >
- Elemente mit </element> beendet oder mit "/>" als Abkürzung
- Aufpassen mit Umläuten: Nur im Text

```
<Katze Farbe="schwarz/weiss">
Meine Katze heisst Leo
und hat die Tel-Nummer
031 123 45 67
</Katze>
```

- Elemente können Attribute enthalten
  Syntax: *name = "value"*
- Elemente können character data (= Text) enthalten.

- XML-Namen sind "case-sensitive"
- XML ist Leerzeichen und "Ende der Zeile"-Buchstabe insensitive

XML
Inhalt eines Dokuments (2)

```
<?xml version="1.0"
      encoding="ISO-8859-1"?>

<meinWurzelElement>
  <einElem
    a="&quot;1&quot;"/>
  <!-- a contains \"1\" -->
  <![CDATA[ <irgendwas> ]]>
</meinWurzelElement>
```

- Als Header eine XML-Deklaration muss vorhanden sein.
- Ein XML-Document muss ein sog. Wurzel-Element haben
- Entity references: < > & ' " (<, >, &, ', ")
- Kommentare, in Form <!-- … -->, nicht verschachtelt
- CDATA section, <![CDATA[…]]>, nicht als *XML-Text* interpretiert

XML
XML-Instanz und XML-Schema

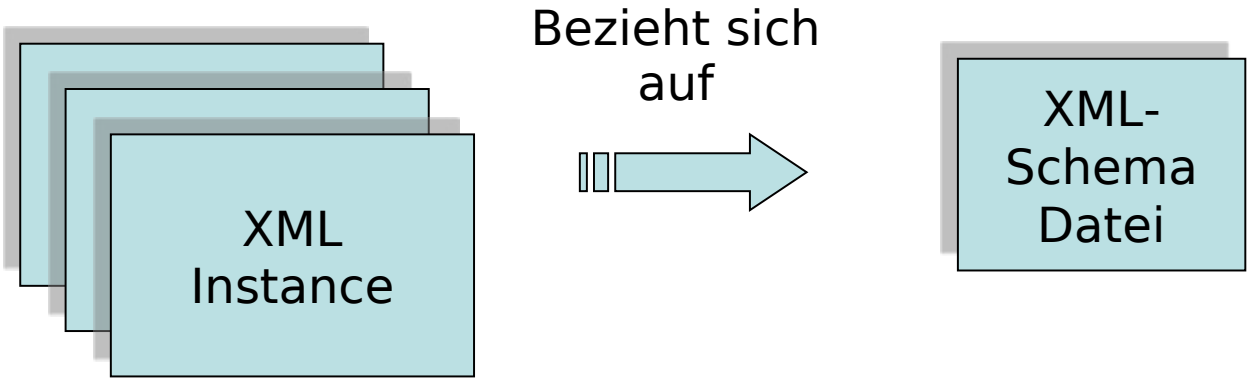

XML
XML-Instanz Beispiel

```
<?xml version="1.0" encoding="ISO-8859-1"?>
<Buch Name="XML Grundlagen"
      xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
      xsi:noNamespaceSchemaLocation="Buch.xsd">
  <isbn id="031-3384417"/>
  <Verlag nb="1"/>
  <Kapitel Titel="Erstes Kapitel">
    Dieses Kapitel enhtält nur eine
    kleine Beschreibung.
  </Kapitel>
  <Kapitel Titel="Letztes Kapitel">
    Ende gut, alles gut ;-)
  </Kapitel>
</Buch>
```

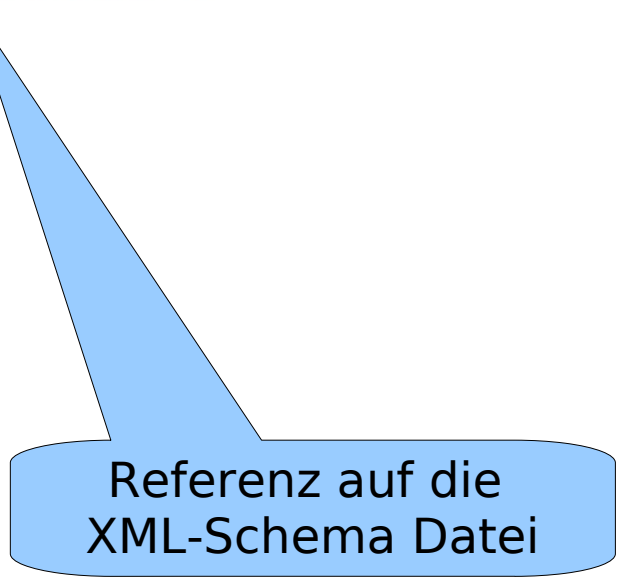

XML
Dazugehörendes XML-Schema (1)

```
<?xml version="1.0" encoding="UTF-8"?>
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema">
  <xs:element name="Buch">
    <xs:complexType>
      <xs:sequence>
        <xs:element name="isbn"    type="isbnType"/>
        <xs:element name="Verlag" type="VerlagType"/>
        <xs:element name="Kapitel" type="KapitelType"
                                maxOccurs="unbounded"/>
      </xs:sequence>
      <xs:attribute name="Name"    type="xs:string"
                    use="required"/>
    </xs:complexType>
  </xs:element>
...
```

XML
Dazugehörendes XML-Schema (2)

```
...
  <xs:complexType name="VerlagType">
    <xs:attribute name="nb" type="xs:byte"   use="required"/>
  </xs:complexType>
  <xs:complexType name="isbnType">
    <xs:attribute name="id" type="xs:string" use="required"/>
  </xs:complexType>

  <xs:complexType name="KapitelType" mixed="true">
    <xs:attribute name="Titel" type="xs:string" use="required"/>
  </xs:complexType>
</xs:schema>
```

XML
XML Namespace

Namespace Definition, als Platzhalter für eindeutige Definition

```
<?xml version="1.0" encoding="UTF-8"?>
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema">
  <xs:element name="Buch">
    <xs:complexType>
      <xs:sequence>
        <xs:element name="ISBN"    type="isbnType"/>
        <xs:element name="Verlag" type="VerlagType"/>
        <xs:element name="Kapitel" type="KapitelType"
                                   maxOccurs="unbounded"/>
      </xs:sequence>
      <xs:attribute name="Name"    type="xs:string"
                    use="required"/>
    </xs:complexType>
  </xs:element>
...
```

Namespace Anwendung

Ziel: Namenskollisionen **vermeiden**

XML
Unterschied wohl-geformt / validiert

*Ein XML-Dokument **muss** wohl-geformt sein.*
*Es **kann** validiert werden.*

Wohl-geformt

- ✔ Ein Wurzel-Element und nur eins
- ✔ Passende Start-/Endelemente
- ✔ Keine überlappende Elemente
- ✔ Eindeutige Attribute innerhalb eines Elements
- ✔ Attribute zwischen "..."
- ✔ etc...

Validiert

Wohl-geformt plus:

Reihenfolge unspezifiziert

- ✔ Korrekte Dokumentstruktur (Elemente und Attribute)
- ✔ Korrekte Attributtypen
- ✔ XML-Schema basiert

Überprüfung mit einem XML-Parser oder online

Einfache Überprüfung mit einem Web-Browser

XML
Daten-Export mit MySQL-Workbench

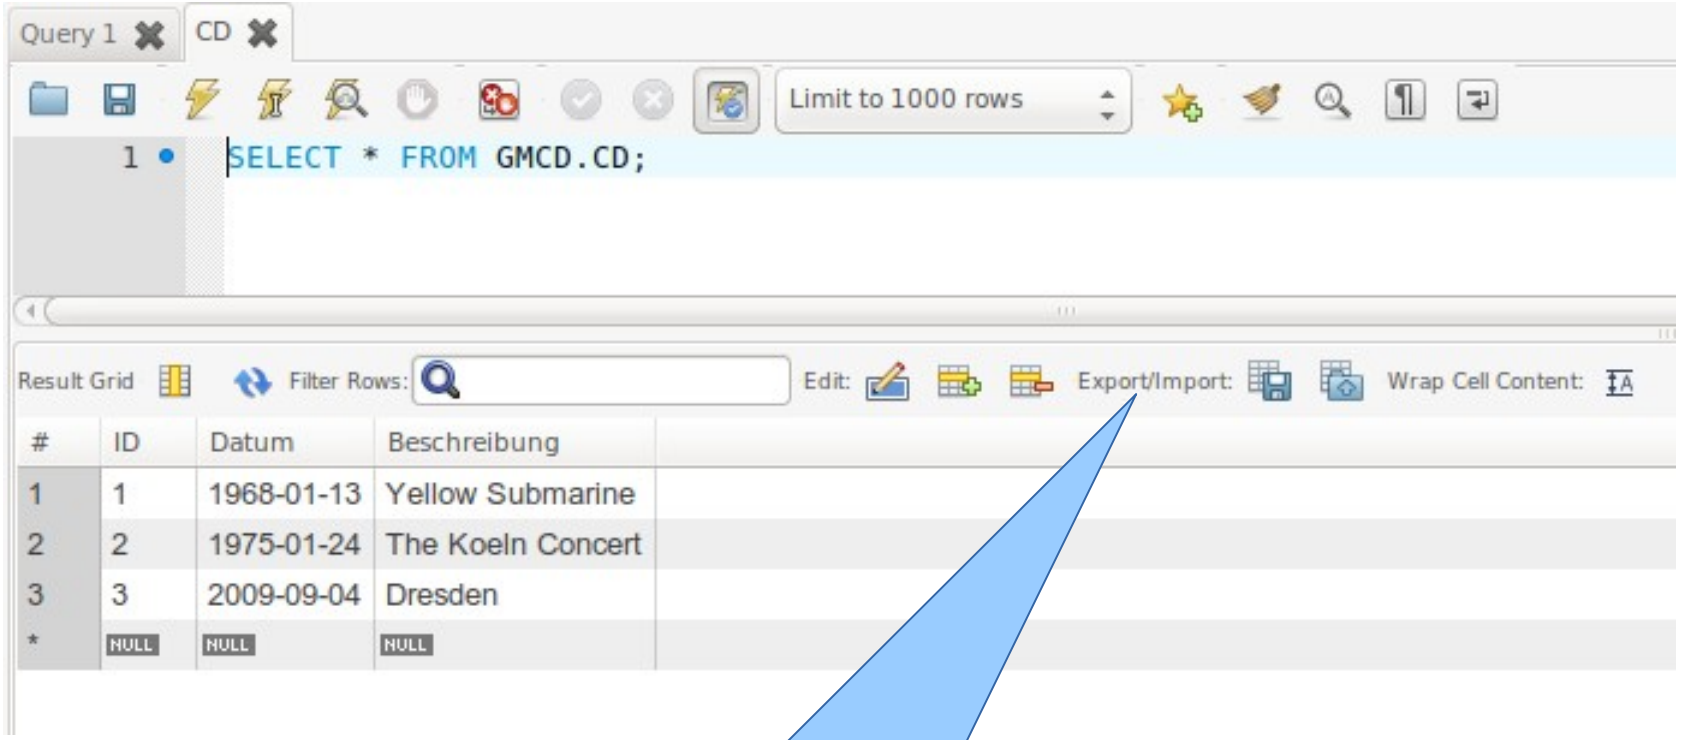

Damit kann ich die Tabelle aus
XML, JSON, CSV, SQL... exportieren

XML
Beispiel Export aus GMCD / CD

```
<?xml version="1.0"?>

<resultset statement="SELECT * FROM GMCD.CD LIMIT 0, 1000"
           xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance">

    <row>
        <field name="ID">1</field>
        <field name="Datum">1968-01-13</field>
        <field name="Beschreibung">Yellow Submarine</field>
    </row>

    <row>
        <field name="ID">2</field>
        <field name="Datum">1975-01-24</field>
        <field name="Beschreibung">The Koeln Concert</field>
    </row>

    <row>
        <field name="ID">3</field>
        <field name="Datum">2009-09-04</field>
        <field name="Beschreibung">Dresden</field>
    </row>
</resultset>
```

JSON
Grundlagen

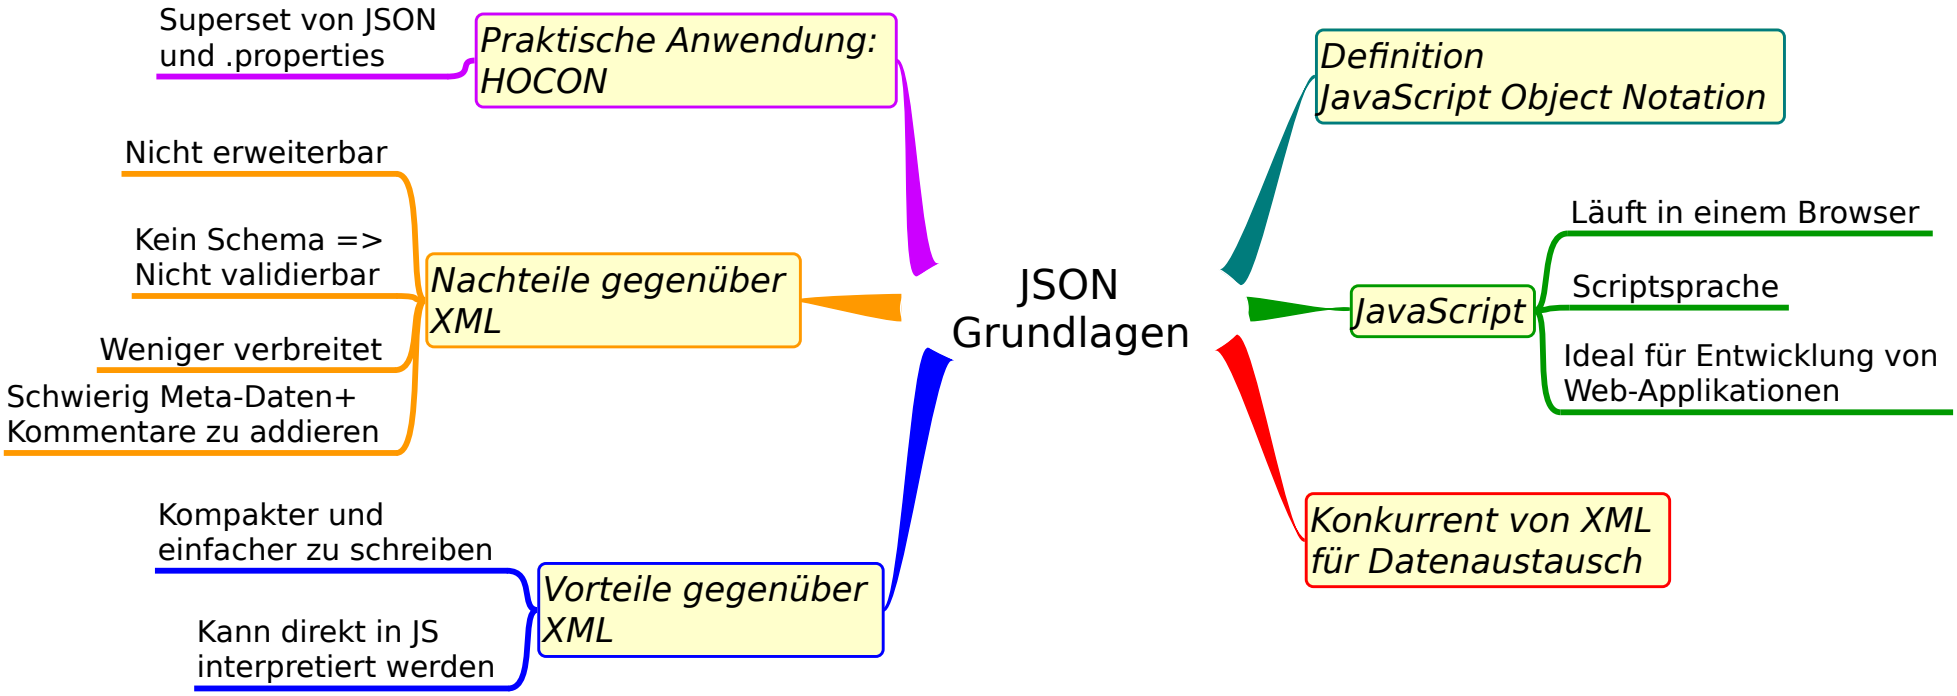

Quellen:
https://de.wikipedia.org/wiki/JavaScript_Object_Notation
https://de.wikipedia.org/wiki/JavaScript
https://github.com/lightbend/config/blob/master/HOCON.md
Tools:
Windows: Notepad++; Linux: Kate

Berner
Fachhochschule
Gilles Maitre

CSV
Grundlagen

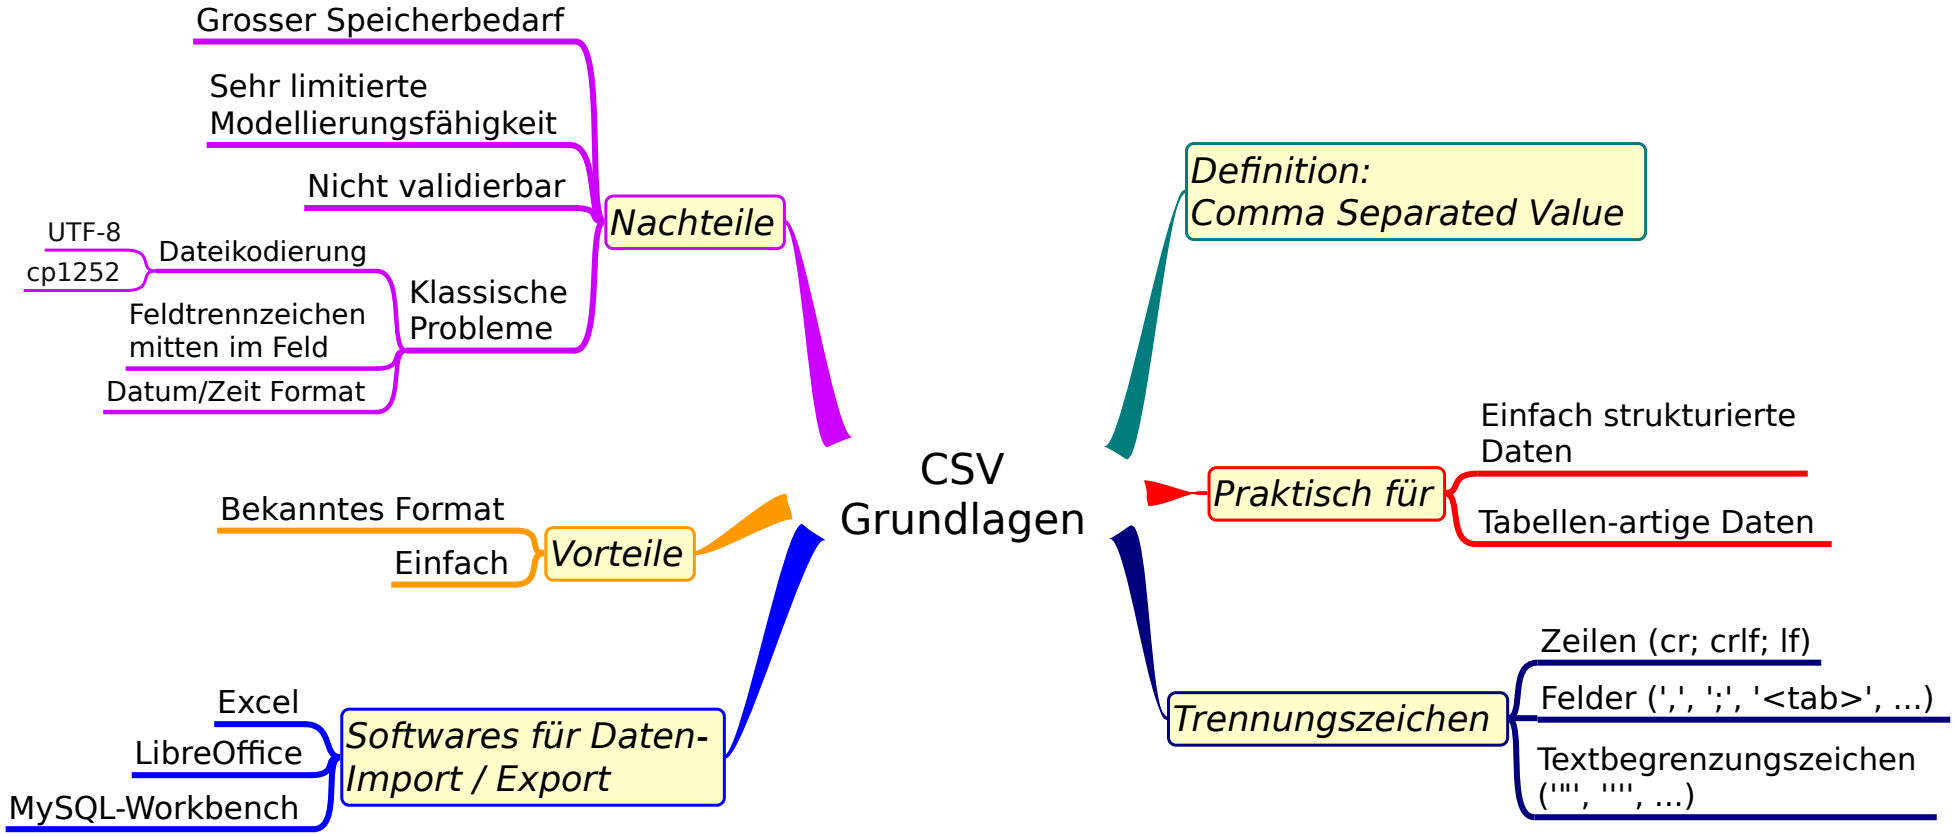

Quellen:
https://de.wikipedia.org/wiki/CSV_(Dateiformat)
https://tools.ietf.org/html/rfc4180
Tools:
Windows: Notepad++, Excel, LibreOffice

Berner Fachhochschule
Gilles Maitre

CSV
Beispiel Export aus GMCD / CD

Comma Separated Value

```
ID,Datum,Beschreibung
1,1968-01-13,"Yellow Submarine"
2,1975-01-24,"The Koeln Concert"
3,2009-09-04,Dresden
```

Semicolon Separated Value

```
ID;Datum;Beschreibung
1;1968-01-13;"Yellow Submarine"
2;1975-01-24;"The Koeln Concert"
3;2009-09-04;Dresden
```

TAB Separated Value

```
ID»	Datum»	Beschreibung
1»	1968-01-13»	"Yellow Submarine"
2»	1975-01-24»	"The Koeln Concert"
3»	2009-09-04»	Dresden
```

Zeichenkodierung
Problematik und Umgang damit

ASCII / ISO-8859-1

- 1 Bytes fix, 0-127 ASCII, Rest abhängig vom Code Page
- Gleiches System, unterschiedliche Namen
  - Windows-1252
  - Latin-1
- Ideal nur für *westeuropäische* Länder
- Nicht ideal für arabische und asiatische Länder

UNICODE / UTF-8

- Variable Länge des Zeichens
- In der Regel UTF-8 im Einsatz
  - Erste 128 Zeichen = ASCII
- Ideal für fast alle / alles
- *Daten leben länger als Programme =>*
  - Konvertierungstools: Notepad++, Kate, LibreOffice, MySQL, iconv

Links:
1) What is the difference between UTF-8 and ISO-8859-1?
2) Minimum Every Developer Must Know About Character Sets

Übungen
XML, JSON und CSV

1) Exportieren Sie aus der GMCD Datenbank die Tabelle "Stück" als XML-Datei (Format: XML-MySQL). Und schauen Sie das Resultat an, mit Kate oder Notepad++.

2) Exportieren Sie aus der GMCD Datenbank die Tabelle "Stück" als CSV-Datei. Und importieren Sie die Datei in Excel / LibreOffice.

3) Exportieren Sie aus der GMCD Datenbank die Tabelle "Stück" als JSON-Datei. Und schauen Sie das Resultat an,
mit Kate oder Notepad++.