6. Semistrukturierte Daten (XML, JSON)

- Einleitung
- Einführung in XML
  - XML-Dokumente
  - DTD (Document Type Definition)
- XML Schema
  - Typen (simpleType, complexType)
  - Schemaaufbau
  - Element/Attribut-Deklarationen
  - Integritätsbedingungen
  - Nutzung mehrerer Schemas / Namensräume
- XML-Datenbanken, SQL/XML
  - Datentyp XML und XML-Operatoren
  - Datenkonversion relational <-> XML
  - Auswertung von XML-Inhalten: XMLQUERY
- JSON-Format, SQL JSON

Kap. 7: Anfragesprachen:
XPath, XQuery

Strukturiertheit von Daten

Unstrukturiert Prosa-Text	**Semi-strukturiert**	**(stark) strukturiert** Datenbanken

- regelmäßige Struktur durch Schema
  - Datensätze mit gleichartigem Aufbau
  - leichtere und effiziente automatische Verarbeitung
  - weniger flexibel
- semi-strukturierte Daten
  - Kompromiss zwischen unstrukturierten und stark strukturierten Daten
  - hohe Flexibilität
  - Text- und Daten-orientierte *Dokumente* möglich
  - optionales Schema

Repräsentation von semistrukturierten Daten / Dokumenten

- Markup-Sprache: Dokumentabschnitte werden durch Marker ausgezeichnet
  - SGML (Standard Generalized Markup Language): hohe Komplexität
  - HTML (HyperText Markup Language): SGML-Anwendung, feste Menge an Auszeichnungselementen
  - **XML (eXtensible Markup Language):**
    - Empfehlung des W3C - World Wide Web Consortium
    - SGML-Kompatibilität, jedoch einfacher
    - optionale Schemaunterstützung (DTD, XML Schema)
    - Anfragemöglichkeiten (XPath, Xquery)
    - XML-Datenbanken / SQL-Integration

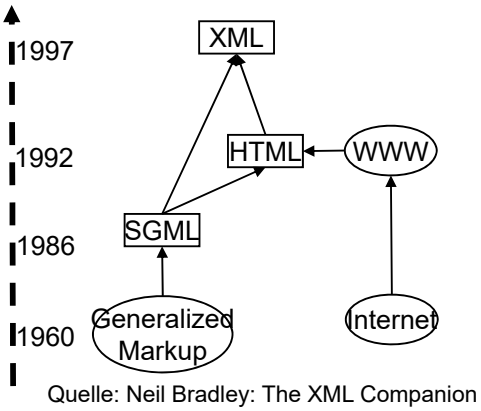

Quelle: Neil Bradley: The XML Companion

- starke XML-Verbreitung u.a. zum Datenaustauch
- leichtgewichtigere XML-Alternative: **JSON (JavaScript Object Notation)**
  - schemalose Repräsentation von Dokumenten / geschachtelten Datenobjekten
  - Unterstützung in SQL und durch Document Stores (NoSQL-Datenbanken), zB MongoDB

XML - Beispiel

- XML-Dokumente haben Baumstruktur
  - Schachtelung von Elementen (= Baumknoten)
  - Elemente können neben Unterelementen Attribute bzw. Inhalt (z.B. Text) aufweisen

```
<?XML version="1.0"?>
<!DOCTYPE Vorlesungsverzeichnis SYSTEM
   "http://dbs.uni-leipzig.de/dtd/VLVerzeichnis.dtd">
<VLVerzeichnis>
      <Vorlesung Uhrzeit=„15:15">
         <Thema>DBS2</Thema>
         <Dozent>
            <Name>Prof. Rahm</Name>
            <Einrichtung>Uni Leipzig</Einrichtung>
         </Dozent>
      </Vorlesung>
</VLVerzeichnis>
```

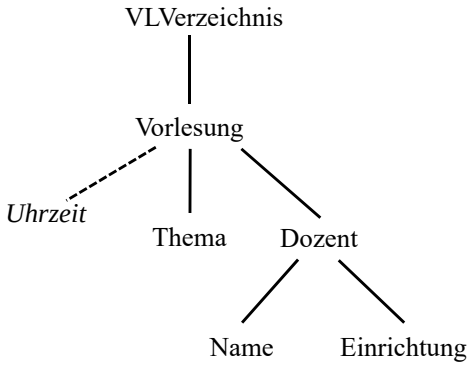

XML: Elemente und Attribute

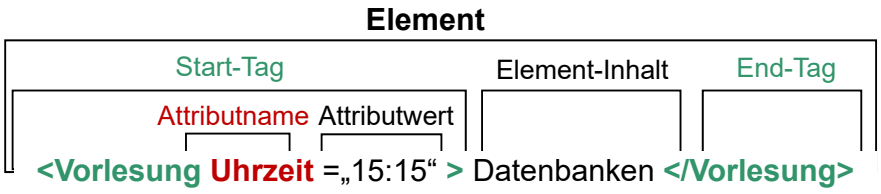

- Elemente
  - Start- und End-Tag müssen vorhanden sein.
    Ausnahme: leeres Element (Bsp. <Leer />)
  - feste Reihenfolge von Geschwisterelementen (Reihung ist wichtig!)
  - Element-Inhalt besteht entweder nur aus weiteren Elementen (element content) oder aus Zeichendaten optional vermischt mit Elementen (mixed content)
- Attribute
  - Attributwerte können nicht strukturiert werden
  - Attributreihenfolge beliebig
- Groß-/Kleinschreibung ist relevant (gilt für alle Bezeichner in XML)
- weitere XML-Bestandteile (hier nicht behandelt):
  Entities, Processing Instructions, Kommentare

XML-Strukturdefinition: DTD

- DTD (Document Type Definition) / Schema optional
- XML-Dokumente sind wohlgeformt, d.h. syntaktisch korrekt
  - alle (außer leere) Elemente müssen ein Start-Tag und ein Ende-Tag haben
  - korrekte Schachtelung von Tags
  - eindeutige Attributnamen pro Element; Attributwerte in Hochkommas …
- XML-Daten sind gültig: wohlgeformt und DTD- bzw- Schema-konform

```
<?XML version="1.0"?>
<!DOCTYPE Vorlesungsverzeichnis SYSTEM
   "http://dbs.uni-leipzig.de/dtd/VLVerzeichnis.dtd">
<VLVerzeichnis>
      <Vorlesung Uhrzeit=„15:15">
        <Thema>DBS2</Thema>
        <Dozent>
          <Name>Prof. Rahm</Name>
          <Einrichtung>Uni Leipzig</Einrichtung>
        </Dozent>
      </Vorlesung>
</VLVerzeichnis>
```

VLVerzeichnis.dtd:

```
<?xml version="1.0" encoding="UTF-8"?>
<!ELEMENT VLVerzeichnis (Vorlesung)* >
<!ELEMENT Vorlesung (Thema, Dozent) >
<!ATTLIST Vorlesung
      Uhrzeit  CDATA #REQUIRED >
<!ELEMENT Thema (#PCDATA) >
<!ELEMENT Dozent (Name, Einrichtung?)>
<!ELEMENT Name (#PCDATA)>
<!ELEMENT Einrichtung (#PCDATA)>
```

DTD – Document Type Definition

- beschreibt Dokumentstruktur und legt damit einen Dokumenttyp fest
- im Dokument verweist *Dokumenttyp-Deklaration* auf DTD
  - interne DTD

```
<!DOCTYPE Vorlesungsverzeichnis [<!ELEMENT VLVerzeichnis (Vorlesung)*>...]>
```

  - externe DTD

```
<!DOCTYPE Vorlesungsverzeichnis SYSTEM „http://dbs.uni-leipzig.de/dtd/VLVerzeichnis.dtd“>
```

- Definition von Elementen in einer DTD
  - Sequenz: (A , B) - vorgegebene Reihenfolge

```
<!ELEMENT Vorlesung (Thema, Dozent)
```

  - Alternative: (A | B) - entweder A oder B (XOR)

```
<!ELEMENT Adresse (PLZ, Ort, (Str, Nr) | Postfach)>
```


DTD (2)

- Element-Wiederholung / Kardinalität:
  - A? - 0..1 Mal

```
<!ELEMENT Dozent (Name, Einrichtung?)>
```

  - A+ - 1..n Mal

```
<!ELEMENT Name (Vorname+, Nachname)>
```

  - A* - 0..n Mal

```
<!ELEMENT VLVerzeichnis (Vorlesung)*>
```

- Mixed Content:
  - *(#PCDATA | A | B)**
    Elemente A, B und Text treten in beliebiger Reihenfolge und Anzahl auf

```
<!ELEMENT Text (#PCDATA | Link)*>
```

- leeres Element (kein Element-Inhalt)

```
<!ELEMENT br EMPTY>
```

DTD (3)

- Definition von Attributen in einer DTD

```
<!ATTLIST  Elementname          (Attributname Typ Auftreten)* >
```

- Attribute gehören zu einem Element
- jedes Attribut hat Namen, Typ und Auftretensangabe
- mögliche Attribut-Typen
  - CDATA
  - ID
  - IDREF/IDREFS
  - Aufzählung möglicher Werte (wert1 | wert2 | ...)
  - NMTOKEN/NMTOKENS, ENTITY/ENTITYS
- ID- und IDREF-Attribute ermöglichen Querverweise innerhalb eines Dokumentes (Graphstruktur)

DTD (4)

- **Auftretens**angabe eines Attributs
  - Obligatheit: #REQUIRED - das Attribut muss angegeben werden
  - Defaultwert-Regelung: #IMPLIED - es gibt keinen Defaultwert
    defaultwert - wird angenommen, wenn Attribut nicht angegeben wird
    #FIXED defaultwert - Attribut kann nur den Defaultwert als Wert besitzen
- Beispiele:

```
<!ATTLIST Entfernung     Einheit CDATA #FIXED „km“>

<!ATTLIST Karosse        Farbe („rot“ | „gelb“ | „blau“) „blau“>

<!ATTLIST Artikel                id  ID  #REQUIRED>

<!ATTLIST Rechnungsposten        Artikel IDREF #REQUIRED>
```

Elemente vs. Attribute

- Datenmodellierung oft durch Element als auch durch Attribut möglich
- Einsatzkriterien unter Verwendung einer DTD

	Element	Attribut
Inhalte	komplex	nur atomar
Ordnungserhaltung	ja	nein
Quantoren / Kardinalität	1 / ? / * / +	REQUIRED / IMPLIED
Alternativen	ja	nein
Identifikation	nein	ID / IDREF / IDREFS
Defaultwerte	nein	ja
Aufzählungstypen	nein	ja

- bei XML Schema anstelle DTD können Elemente alle Eigenschaften von Attributen erhalten; trotzdem Attribute zu bevorzugen wenn:
  - Aufzählungstypen mit atomaren Werten und Defaultwert zu modellieren sind
  - es sich um 'Zusatzinformation' handelt (Bsp. Währung, Einheit)
  - das Dokument effizient verarbeitet (geparsed) werden soll

6. Semistrukturierte Daten (XML, JSON)

- Einleitung
- Einführung in XML
  - XML-Dokumente
  - DTD (Document Type Definition)
- XML Schema
  - Typen (simpleType, complexType)
  - Schemaaufbau
  - Element/Attribut-Deklarationen
  - Integritätsbedingungen
  - Nutzung mehrerer Schemas / Namensräume
- XML-Datenbanken, SQL/XML
  - Datentyp XML und XML-Operatoren
  - Datenkonversion relational <-> XML
  - Auswertung von XML-Inhalten: XMLQUERY
- JSON-Format, SQL JSON

XML Schema-Sprachen

- Schemainformationen wichtig für
  - Korrektheit von Daten/Dokumenten: Validierung von Struktur und Datentypen
  - effiziente DB-Speicherung und Verarbeitung von Anfragen
  - Interoperabilität in verteilten Umgebungen: feste Formatierungen für Datenaustausch (z.B. in Schnittstellen für Web-Services)

- Defizite der DTD
  - zusätzliche Syntax (kein XML-Format) -> extra Parser notwendig
  - kaum Typisierung von Elementinhalt (Text) und Attributwerten möglich
  - mehrere DTDs pro Dokument sind nicht erlaubt
  - keine Unterstützung von Namensräumen
  - unzureichende Unterstützung der Interoperabilität und Wiederverwendbarkeit

XML Schema*

- XML Schemabeschreibungssprache, entwickelt durch das W3C
  - Recommendation seit 2001 , 2012: V1.1
  - auch als *XML Schema Definition* (XSD) bezeichnet

- Eigenschaften
  - verwendet XML-Syntax
  - Unterstützung von Namenräumen (Namespaces)
  - erweiterbares Typsystem (simple, complex types)
  - erlaubt Definition einfacher Integritätsbedingungen (unique, key)
  - komplexer und weniger kompakt gegenüber DTD

* http://www.w3c.org/XML/Schema

XML Schema: vordefinierte Typhierarchie

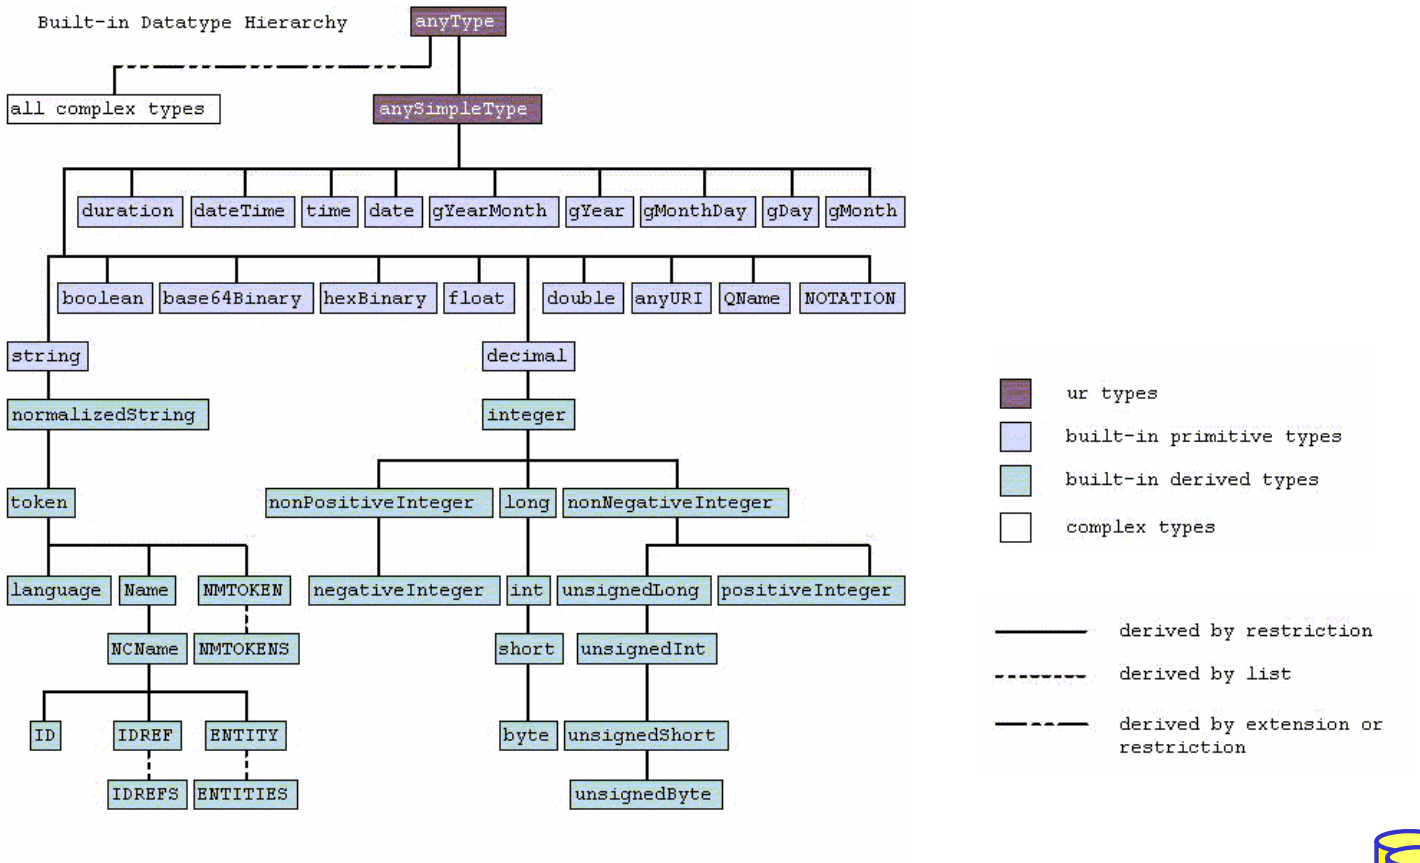

XML Schema: simpleType

- simpleType: benutzerdefinierter, einfacher Datentyp
  - hat keine Attribute oder Kindelemente
- 3 Möglichkeiten zur Bildung einfacher Typen
  - Einschränkung (restriction) von Eigenschaften (facets)
  - Listenbildung (list)
  - Vereinigung (union)
- Beispiel: simpleType-Definition mit length-Einschränkung
  - Präfix **xs:** bezeichne standardisierten XML-Schema-Namensraum

```
<xs:simpleType name="LoginName">
  <xs:restriction base="xs:string">
    <xs:length value="8" />
  </xs:restriction>
</xs:simpleType>
```

- anonyme vs. benannte Typen: ohne / mit name-Attribut
  - benannte Typen ermöglichen Mehrfach/Wiederverwendung

XML Schema: simpleType (2)

- Möglichkeiten der Einschränkung (restriction)
  - Längenbeschränkung für Zeichenketten /Listen: length, minLength, maxLength
  - Längenbeschränkung für Dezimalzahlen: totalDigits, fractionDigits
  - Wertebereichs-Unter/Obergrenzen: minInclusive, maxInclusive, minExclusive, maxExclusive
  - Aufzählung zulässiger Werte: enumeration
  - Muster: pattern value = <regulärer Ausdruck>
- Listenbildung (list): definiert leerzeichen-separierte Liste von simpleType-Werten
- Vereinigung (union): ermöglicht Typ mit mehrere Wertebereichen

```
<xs:simpleType name="BibId">
  <xs:restriction base="xs:string">
    <xs:pattern value="[A-Z][1-9][0-9]*" />
  </xs:restriction>
</xs:simpleType>
```

```
<xs:simpleType name="Kontakt">
  <xs:union memberTypes="TelefonTyp EmailTyp"/>
</xs:simpleType>
```

```
<xs:simpleType name="Lottozahlen">
  <xs:list>
    <xs:simpleType>
      <xs:restriction base="xs:integer">
        <xs:minInclusive value="1" />
        <xs:maxInclusive value="49" />
      </xs:restriction>
    </xs:simpleType>
  </xs:list>
</xs:simpleType>
```

XML Schema: complexType

- komplexe Datentypen dienen der Beschreibung von Elementinhalten
  - Beschränkung (restriction) oder Erweiterung (extension) bestehender Typen
  - einfaches Inhaltsmodell (simple content): für Elemente ohne Subelemente
  - Default: komplexes Inhaltsmodell (complexContent), Basistyp anyType
- Elementstrukturierung bei complexContent
  - Reihung: sequence
  - Auswahl/Alternative: choice
  - Gruppe: all (jedes Element kann max. 1-mal auftreten; reihenfolgeunabhängig)
- Kardinalitätsrestriktionen: minOccurs, maxOccurs
  - Defaultwert: 1
  - unbeschränkte Anzahl: "unbounded"

XML Schema: complexType (2)

- Definition durch **Beschränkung (restriction)**

```
<xs:complexType name="DozentTyp">
  <xs:complexContent>
    <xs:restriction base="xs:anyType">
      <xs:sequence>
        <xs:element   name="Name"
                type="xs:string"/>
        <xs:element   name="Einrichtung"
                type="xs:string"
                minOccurs="0"/>
      </xs:sequence>
    </xs:restriction>
  </xs:complexContent>
</xs:complexType>
```

≅

```
<xs:complexType name="DozentTyp">
  <xs:sequence>
    <xs:element      name="Name"
                type="xs:string"/>
    <xs:element      name="Einrichtung"
                type="xs:string"
                minOccurs="0"/>
  </xs:sequence>
</xs:complexType>
```

Vergleich Kardinalitätsrestriktionen

DTD	XML Schema	
	minOccurs	maxOccurs
1	1	1
?		
+		unbounded
*		unbounded

XML Schema: complexType (3)

- Definition durch **Erweiterung (extension)**:

```
<xs:complexType name="UniDozentTyp">
 <xs:complexContent>
  <xs:extension base="DozentTyp">
   <xs:sequence>
    <xs:element   name="Adresse"  type="AdressTyp"/>
    <xs:choice>
     <xs:element  name="Mail" type="xs:string"/>
     <xs:element  name="URL" type="xs:string"/>
    </xs:choice>
   </xs:sequence>
  </xs:extension>
 </xs:complexContent>
</xs:complexType>
```


XML Schema: Schemaaufbau

- Schema in *schema*-Element eingeschlossen
  - Namensraum *http://www.w3.org/2001/XMLSchema* für Schemaelemente
  - Spezifikation eines „target namespace“, dem das Schema zugeordnet wird
- Schemakomponenten, die direkt unter *schema*-Element liegen, sind *global*; tiefer liegende Komponenten sind *lokal*

```
<xs:schema      xmlns:xs="http://www.w3.org/2001/XMLSchema"
                targetNamespace="...">
 <xs:import ... />
 <xs:complexType name= "...">...</xs:complexType>
 <xs:attribute name="..." ... />
 <xs:element name="..." >
   <xs:complexType>
     <xs:sequence>
       <xs:element    name="..." ... />
     </xs:sequence>
     <xs:attribute name="..." ... />
   </xs:complexType>
 </xs:element>
</xs:schema>
```

benannt → global

anonym → lokal

XML Schema: Elementdeklaration

- verschiedene Möglichkeiten der Elementdeklaration
  - **direkte Deklaration** des Elementinhalts

```
<xs:element name=„Einrichtung“ type=„xs:string“ minOccurs=„0“ />
<xs:element name=„Dozent“>
  <xs:complex Type> ... </xs:complex Type>
</xs:element>
```

  - Verweis auf **komplexen Datentyp**

```
<xs:element name=„Dozent“ type=„DozentTyp“/>
```

  - Verweis auf **globale Elementdeklaration**

```
<xs:element ref=„Dozent“/>
```

Vergleich DTD - XML Schema Elementdeklaration

DTD:

```
<1ELEMENT Dozent (Titel?, Vorname+, Name, (Vorlesung | Seminar)*)>
```

XML Schema:

```
<xs:element name="Dozent">
  <xs:complexType>
    <xs:sequence>
      <xs:element name="Titel" type="xs:string" minOccurs="0" />
      <xs:element name="Vorname" type="xs:string" maxOccurs="unbounded" />
      <xs:element name="Name" type="xs:string" />
      <xs:choice minOccurs="0" maxOccurs="unbounded">
        <xs:element name="Vorlesung" type="xs:string" />
        <xs:element name="Seminar" type="xs:string" />
      </xs:choice>
    </xs:sequence>
  </xs:complexType>
</xs:element>
```

XML Schema: Attributdeklaration

- Attributdeklarationen
  - global oder lokal am Ende einer ComplexType-Definition
  - direkte Deklaration oder über *ref* bzw. vordef. Typen
  - nur SimpleType-Datentypen erlaubt
  - *Attribute für Attribute*: name, type, use (optional/required), default, fixed

```
<xs:element name="Vorlesung">
  <xs:complexType>
    <xs:sequence>...</xs:sequence>
    <xs:attribute name="Uhrzeit" type="xs:time" use="required"/>
  </xs:complexType>
</xs:element>
```

- Beispiele

```
<xs:attribute name="Einheit" type="xs:string" fixed="km"/>
```

```
<xs:attribute name="Farbe" default="blau">
  <xs:simpleType>
    <xs:restriction base="xs:NMTOKEN">
      <xs:enumeration value="rot" />
      <xs:enumeration value="gelb" />
      <xs:enumeration value="blau" />
    </xs:restriction>
  </simpleType>
</xs:attribute>
```

```
<xs:attribute name="id" type="xs:ID" use="required"/>
```

```
<xs:attribute name="Artikel" type="xs:IDREF" use:="required"/>
```


XML Schema: Schlüsselbedingungen

- Eindeutigkeitsbedingung: unique
  - Selector-Ausdruck: Teilobjekte eines Dokuments, auf die Bedingung anzuwenden ist (XPath-Ausdruck)
  - field-Ausdruck: Element- bzw. Attributwert, bzgl. dessen (Eindeutigkeit) getestet werden soll

```
<xs:element name="VLVerzeichnis">
  <xs:complexType>...</xs:complexType>
  <xs:unique name="UniqueBed">
    <xs:selector xpath=„//Vorlesung" />
    <xs:field xpath="Thema/text()" />
  </xs:unique>
</xs:element>
```


XML Schema: Schlüsselbedingungen (2)

- Schlüsselbedingung: key
- Schlüsselreferenz: keyref

```
<xs:key name="ArtikelKey">
  <xs:selector xpath=„//Produkte/Artikel" />
  <xs:field xpath="@aID" />
</xs:key>

<xs:keyref name="ArtikelKeyRef" refer="ArtikelKey">
  <xs:selector xpath="//Verzeichnis/Artikel" />
  <xs:field xpath="@artikelID" />
 </xs:keyref>
```

```
<Produkte>
    <Artikel aID=„A1">
      <Name>  … </Name>
    </Artikel>
….
<Verzeichnis>
  <Artikel artikelID=„A1">
      ….  </Artikel>  …
</Verzeichnis>
```

- Vergleich zu ID / IDREF
  - anwendbar für Attribute und Elemente
  - anwendbar für viele Typen
  - Einschränkbarkeit bzgl. Teildokumenten

XML Schema und Namensräume

- XML Schema baut auf und unterstützt Namensräume
- Namensraumzuordnung im Schema und im Dokument erforderlich
  - Attribut targetNamespace im Schema
  - Verweise im Schema auf definierte Elemente müssen qualifizierte Namen verwenden
  - kein Präfix erforderlich für Default-Namensraum

```
<schema xmlns="http://www.w3.org/2001/XMLSchema"
   targetNamespace="http://uni-leipzig.de/VLV"
     xmlns:v= "http://uni-leipzig.de/VLV" >

 <element name="VLVerzeichnis">
  <complexType>
   <sequence>
    <element ref="v:Vorlesung"
             minOccurs="0" maxOccurs="unbounded" />
   </sequence>
  </complexType>
 </element>

 <element name="Vorlesung"> ...  </element>
 <element name="Thema" type="string" /> ...
```

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

<VLVerzeichnis xmlns="http://uni-leipzig.de/VLV">

 <Vorlesung Uhrzeit=„15:15">

  <Thema>DBS2</Thema>
  <Dozent>
   <Name>Prof. Rahm</Name>
   <Einrichtung>Uni Leipzig</Einrichtung>
  </Dozent>

 </Vorlesung>

</VLVerzeichnis>
```

Nutzung mehrerer Schemas

- import-Anweisung: Einbindung anderer Schemas / Namensräume
  - Zugriff per Referenz auf globale Komponenten (Elemente, Attribute, Typen) des importierten Schemas
  - Referenz muss qualifizierten Namen verwenden

```
<schema xmlns="http://www.w3.org/2001/XMLSchema"
            targetNamespace="urn:de.uni-leipzig.bibl"
            xmlns:bib="urn:de.uni-leipzig.bibl"
            xmlns:dc="http://purl.org/dc/elements/1.1/">
<import namespace="http://purl.org/dc/elements/1.1/" />
 ...
 <element name="book">
  <complexType>
   <sequence>
    <element ref = "dc:title" />
    <element ref = "dc:publisher" />
    <element ref = "dc:identifier" />
    <element name="location" type="string" />
    <element name="identifier" type="string" />
   </sequence>
  </complexType>
 </element>    ...
</schema>
```

```
<book xmlns="urn:de.uni-leipzig.bibl"
      xmlns:dc="http://purl.org/dc/elements/1.1/">

 <dc:title>Web und Datenbanken</dc:title>
 <dc:publisher>dpunkt-Verlag</dc:publisher>
 <dc:identifier>3-89864-189-9</dc:identifier>

 <location>Zweigstelle 1</location>
 <identifier>ST 6519</identifier>

</book>
```

6. Semistrukturierte Daten (XML, JSON)

- Einleitung
- Einführung in XML
  - XML-Dokumente
  - DTD (Document Type Definition)
- XML Schema
  - Typen (simpleType, complexType)
  - Schemaaufbau
  - Element/Attribut-Deklarationen
  - Integritätsbedingungen
  - Nutzung mehrerer Schemas / Namensräume
- XML-Datenbanken, SQL/XML
  - Datentyp XML und XML-Operatoren
  - Datenkonversion relational <-> XML
  - Auswertung von XML-Inhalten: XMLQUERY
- JSON-Format, SQL JSON

XML-Datenbanken, SQL/XML

- mehrere Alternativen zur Speicherung von XML-Dokumenten in Datenbanken

1. ganzheitliche Speicherung von Dokumenten (BLOB, UDT XML)
   - schnelles Einbringen der Daten und originalgetreue Dokumentrekonstruktion
   - hoher Aufwand für Queries und Änderungen
   - weniger geeignet für strukturierte Daten
2. Zerlegung (Dekomposition) der XML-Daten auf Tabellen
   - 2a) generisch: Graphmodell (Document object model, DOM)
     - allgemeine Lösung mit Tabellen für Elemente und Attribute
     - aufwändige (SQL-) Query-Verarbeitung mit vielen Joins
   - 2b) schemabasiert: aufgrund Tabellen-Mapping („Shredding“)
     - schneller Zugriff auf ausgewählte Teile
     - vereinfachte SQL-Queries
     - günstig für strukturierte Daten
3. Kombinationen (SQL/XML unterstützt 1 und 2b)

Schemabasierte Dekomposition: Beispiel

- manuelles Mapping
  - Mapping zwischen XML-Dokument und Datenbank wird manuell festgelegt
  - Mapping muss nicht vollständig sein

XML-Daten

```
<Vorlesung Uhrzeit=„15:15">
    <Thema>DBS2</Thema>
    ...
</Vorlesung>
```

Mapping-Vorschrift

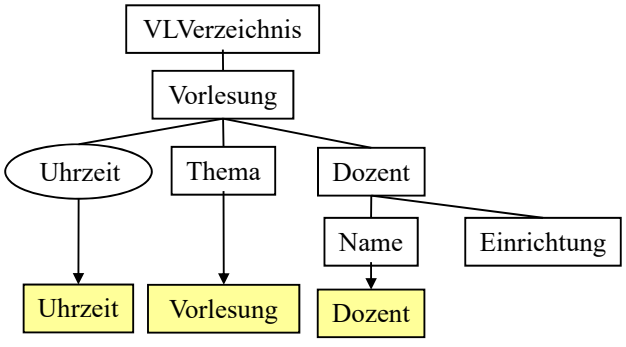

Datenbank

Vorlesung	Uhrzeit	Dozent
DBS2	15:15	Prof. Rahm

VLVerzeichnis

SQL-Datentyp: XML

- SQL-Standard Teil 14: SQL/XML
- XML-Dokument wird als Ganzes gespeichert
  - Beibehaltung der Originaldokumente/-daten (ähnlich LOB)
- DBMS erlaubt XPath/XQuery-Anfragen auf XML-Dokumenten
- Beispiel: Tabelle Vorlesungsverzeichnis

```
- CREATE TABLE Vorlesungsverzeichnis (
     Universitaet  VARCHAR (255),
     Semester      VARCHAR (255),
     Vorlesungen   XML
  )
- INSERT INTO Vorlesungsverzeichnis
  (Universitaet, Semester, Vorlesungen)
  VALUES
  ('Uni Leipzig', 'SoSe 2022',
     XMLPARSE ( DOCUMENT'<VLVerzeichnis><Vorlesung
       Uhrzeit="15:15"><Thema> DBS2 </Thema><Dozent>
       <Name> Rahm </Name> <Einrichtung> IfI </Einrichtung> ...'))
```

SQL/XML-Operatoren

- Erweiterung der SQL-Anfragesprache zur XML-Verarbeitung
- Operatoren zur Erzeugung von XML-Daten
  - XMLELEMENT, XMLATTRIBUTES : Konstruktion von XML-Elementen bestehend aus Name, Attributen und Inhalt (Text oder andere XML-Elemente)
  - XMLAGG: Konstruktion gruppierter XML-Elemente
  - XMLFOREST, XMLCONCAT, XMLNAMESPACES, XMLDOCUMENT, ...
- Operatoren für Anfragen auf XML-Dokumenten
  - XMLQUERY: einfache XPath-Anfragen auf XML-Dokumente
  - XMLEXISTS: Selektionsbedingung für XML-Dokumente (in SQL-WHERE-Klausel)
- XMLTABLE: Konvertierung eines XML-Anfrageergebnisses in Relation

XMLELEMENT, XMLATTRIBUTES

- Erstellung von XML-Elementen bzw. –Attributen aus relationalen Tabellen
- Beispiel: Vorlesungen jeweils als XML-Fragment

```
SELECT Id, XMLELEMENT (Name "Vorlesung",
             XMLATTRIBUTES (Uhrzeit AS "Uhrzeit"),
             XMLELEMENT (Name "Thema", Thema),
             XMLELEMENT (Name "Dozent" ,
               XMLELEMENT (Name "Name", DName),
               XMLELEMENT (Name "Einrichtung", DEinr))) AS X
FROM Vorlesung
```

Vorlesung				
Id	Thema	Uhrzeit	DName	DEinr
1	DBS2	15:15	Rahm	IfI
2	NoSQL	13:15	Köpcke	IfI

Id	X (Typ:XML)
1	<Vorlesung Uhrzeit="15:15"><Thema>DBS2</Thema><Dozent><Name>Rahm</Name><Einrichtung>IfI</Einrichtung></Dozent></Vorlesung>
2	<Vorlesung Uhrzeit="13:15"><Thema>NoSQL</Thema><Dozent><Name>Köpcke</Name><Einrichtung>IfI</Einrichtung></Dozent></Vorlesung>

XMLQUERY

- Unterstützung einfacher XPath-Anfragen
  - Ergebnis ist Knotenmenge (serialisiert als konkatenierte XML-Elemente)
  - PASSING-Klausel gibt an, in welcher Tabellen-Spalte XML-Dokumente ausgewertet werden sollen
- Beispiel: Alle Themen von 15:15-Uhr-Vorlesungen

```
SELECT Universitaet, XMLQUERY(
  '//Vorlesung/Thema[../@Uhrzeit="15:15"]'
  PASSING Vorlesungen) AS X
FROM Vorlesungsverzeichnis
WHERE Semester = 'SoSe 2022'
```

Vorlesungsverzeichnis		
Univ.	Semester	Vorlesungen
Uni LE	SoSe 2022	<VLVerzeichnis ...
Uni LE	WiSe 21/22	<VLVerzeichnis ...
Uni DD	SoSe 2022	<VLVerzeichnis ...

Univ.	X (*kein well-formed XML*)
Uni LE	<Thema>DBS2</Thema><Thema>DWH </Thema>
Uni DD	<Thema>AlgoDat</Thema><Thema>Logik</Thema>

XMLTABLE

- Konvertierung von XML-Anfrageergebnis in Relation
  - Verwendung mehrerer XPath-Ausdrücke
- Aufbau
  - XPath-Ausdruck zur Selektion von Basiselementen
    → je ein Datensatz pro Basiselement in Ergebnisrelation
  - pro Attribut der Relation ein XPath-Ausdruck
    → Auswertung des XPath-Ausdrucks relativ vom Basiselement
- Einsatzbereiche
  - Definition (relationaler) Sichten auf XML-Dokumente
  - nutzerdefinierte Speicherung von XML-Daten in Tabellen
  - Kombination von XML-Daten mit relationalen Daten (z.B. JOIN)

XMLTABLE (2)

- Beispiel: relationale Darstellung des Vorlesungsverzeichnis

Vorlesungsverzeichnis		
Uni	Sem	Vorlesungen
..	..	<VLVerzeichnis> <Vorlesung Uhrzeit="15:15"> <Thema>DBS2</Thema> <Dozent> <Name>Rahm</Name> <Einrichtung>IfI</Einrichtung> </Dozent> </Vorlesung> <Vorlesung Uhrzeit="9:15"> <Thema>NoSQL</Thema> <Dozent> <Name>Köpcke</Name> <Einrichtung>IfI</Einrichtung> </Dozent> </Vorlesung> </VLVerzeichnis>

```
SELECT X.*
FROM Vorlesungsverzeichnis,
XMLTABLE (
 '//Vorlesung' PASSING Vorlesungen
 COLUMNS
  "THEMA" VARCHAR(255) PATH 'Thema',
  "ZEIT"  VARCHAR(255) PATH '@Uhrzeit',
  "DNAME" VARCHAR(255) PATH 'Dozent/Name'
)AS X
```

Thema	Zeit	DName
DBS2	15:15	Rahm
NoSQL	9:15	Köpcke

6. Semistrukturierte Daten (XML, JSON)

- Einleitung
- Einführung in XML
  - XML-Dokumente
  - DTD (Document Type Definition)
- XML Schema
  - Typen (simpleType, complexType)
  - Schemaaufbau
  - Element/Attribut-Deklarationen
  - Integritätsbedingungen
  - Nutzung mehrerer Schemas / Namensräume
- XML-Datenbanken, SQL/XML
  - Datentyp XML und XML-Operatoren
  - Datenkonversion relational <-> XML
  - Auswertung von XML-Inhalten: XMLQUERY
- JSON-Format, SQL JSON

JSON-Datenrepräsentation

- schemalose Repräsentation von Dokumenten
- JSON (JavaScript Object Notation)
  - geschachtelte Objekt-Notation
  - Objekt { ….} umfasst Menge von Key-Value (Attribut/Wert-) Paaren
  - Datentypen: String, Zahl, Array [...], Boolean, Nullwert
- JSON einfacher als XML, leicht lesbar / schreibbar
  - besonders geeignet für „datenorientierte“ Objekte (statt Dokumenten mit viel Text)
  - starke Verbreitung in mobilen und Web Anwendungen
- Beispiel (JSON vs. XML)

```
{
   "Herausgeber": "Mastercard",
   "Nummer": "1234-5678-9012-3456",
   "Währung": "EURO",
   "Inhaber": {
              "Name": "Mustermann",
             "Vorname": "Max",
             "männlich": true,
             "Hobbys": [ "Reiten", "Golfen", "Lesen" ],
             "Kinder": [],
              "Partner": null          }
}
```

```
<Kreditkarte Herausgeber="Mastercard"
             Nummer="1234-5678-9012-3456"
             Waehrung="EURO">
 <Inhaber Name="Mustermann" Vorname="Max"
                    maennlich=true Partner="null">
   <Hobbys>
     <Hobby>Reiten</Hobby>
     <Hobby>Golfen</Hobby>
     <Hobby>Lesen</Hobby>
   </Hobbys>
   <Kinder />
 </Inhaber>
</Kreditkarte>
```

SQL/JSON

- wesentlicher Bestandteil von SQL:2016
  - Unterstützung u.a. in Oracle, DB2, MS SQL-Server, PostgresSQL
- kein vordefinierter Datentyp wie für XML, sondern Speicherung von JSON-Objekten als Strings/CLOBs
  - Test auf Gültigkeit (korrekte JSON-Syntax) als Constraint möglich

```
CREATE TABLE JTAB ( jcol CLOB CHECK (jcol IS JSON) )
```

- Erzeugen von JSON-Daten über Funktionen *json_object, json_array, …*

```
UPDATE JTAB SET jcol = json_object ('id': 2345, 'name': 'Stefan') WHERE …
```

- JSON-Abfragen über Funktionen *json_exists, json_value, json_query* unter Nutzung von Pfadausdrücken

```
… WHERE json_exists (jcol, '$.name')
```

- Funktion *json_table* zur Erzeugung von Tabellen aus JSON-Daten

```
SELECT JT.* FROM JTAB,  json_table (jcol, '$[*]' COLUMNS (id   NUMERIC      PATH '$.id',
                                    name VARCHAR(255) PATH '$.name') AS JT …
```

https://modern-sql.com/blog/2017-06/whats-new-in-sql-2016

Zusammenfassung

- XML:
  - flexibles Format für strukturierte und semistrukturierte Daten
  - dominierendes Austauschformat zwischen Web-Anwendungen
- DTD hat nur limitierte Schema-Eignung
  - mangelhafte Typisierung, keine Namensräume
- XML Schema
  - mächtigere Strukturbeschreibung als DTD
  - ermöglicht Typisierung von Elementinhalten und Attributwerten
  - zusätzliche Integritätsbedingungen
- Namensräume erlauben gemeinsame Nutzung verschiedener Schemas / globaler Typen in einem Dokument
- SQL-Standard unterstützt UDT XML
  - Konversion XML -> relational: XMLTABLE
  - Konversion relational -> XML: XMLELEMENT, XMLATTRIBUTE …
- JSON: leichtgewichtigere XML-Alternative ohne Schema