7. Semistrukturierte Daten und XML

Stefan Deßloch

Technische Universität
Kaiserslautern

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Überblick

- Semistrukturierte Daten
  - Motivation, Grundkonzepte
- XML-Einführung
  - dokumentorientierte vs. datenorientierte Sicht
  - Grundkonzepte (Syntax)
    - wohlgeformtes (*well-formed*) XML
  - Vergleich XML ↔ Relationenmodell
  - Welches Modell gewinnt?
- Schemadefinition für XML-Dokumente
  - Dokumenttypdefinitionen
  - XML-Schema
- Anfrageverarbeitung mit XML
  - Pfadausdrücke (XPath)
  - Anfragen mit XQuery
  - Auswertungsbeispiele

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Konventionelle Datenmodelle

- Unterstützung für strukturierte Daten
  - Trennung von Schema (Strukturinformation) und Daten
- DB-Schema
  - Vollständige Strukturbeschreibung (strukturelle Meta-Daten)
  - Wird vor der Speicherung von Datenobjekten spezifiziert
  - Grundlage zur Interpretation, Manipulation von Daten
- Daten
  - Sind immer Instanzen des Schemas
    - Struktur festgelegt, keine Abweichungen möglich
  - Tragen selbst keine Strukturinformation
    - Müssen mit Hilfe des Schemas interpretiert, manipuliert werden

Person		
Name	Adresse	Alter

Müller	Schlossallee 1, …	55
Maier	Badstraße 3, …	20
Schmidt	Opernplatz 5, …	35

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Semistrukturierte Daten

- Probleme mit konventionellen DM
  - Keine Flexibilität bzgl. Strukturvorgaben
  - Schlechte Eignung für Daten- und Informationsintegration
    - Heterogenität muss immer auf Schemaebene aufgelöst werden
  - Datenaustausch
- Semistrukturierte DM
  - Daten sind selbstbeschreibend
    - Daten und Strukturbeschreibung sind integriert
  - Keine Schemadefinition a priori notwendig
    - Breites Spektrum bzgl. Typisierung
    - Schema als “nachträgliche” Beschreibung von Struktur zur Optimierung bzw. Unterstützung der Datenmanipulation
      - Schemaextraktion, Schemainferenz
  - Flexiblere, mächtigere Anfrage- und Verarbeitungsmodelle

⇨ Nutzung von XML

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Semistrukturierte Daten – Beispiel*

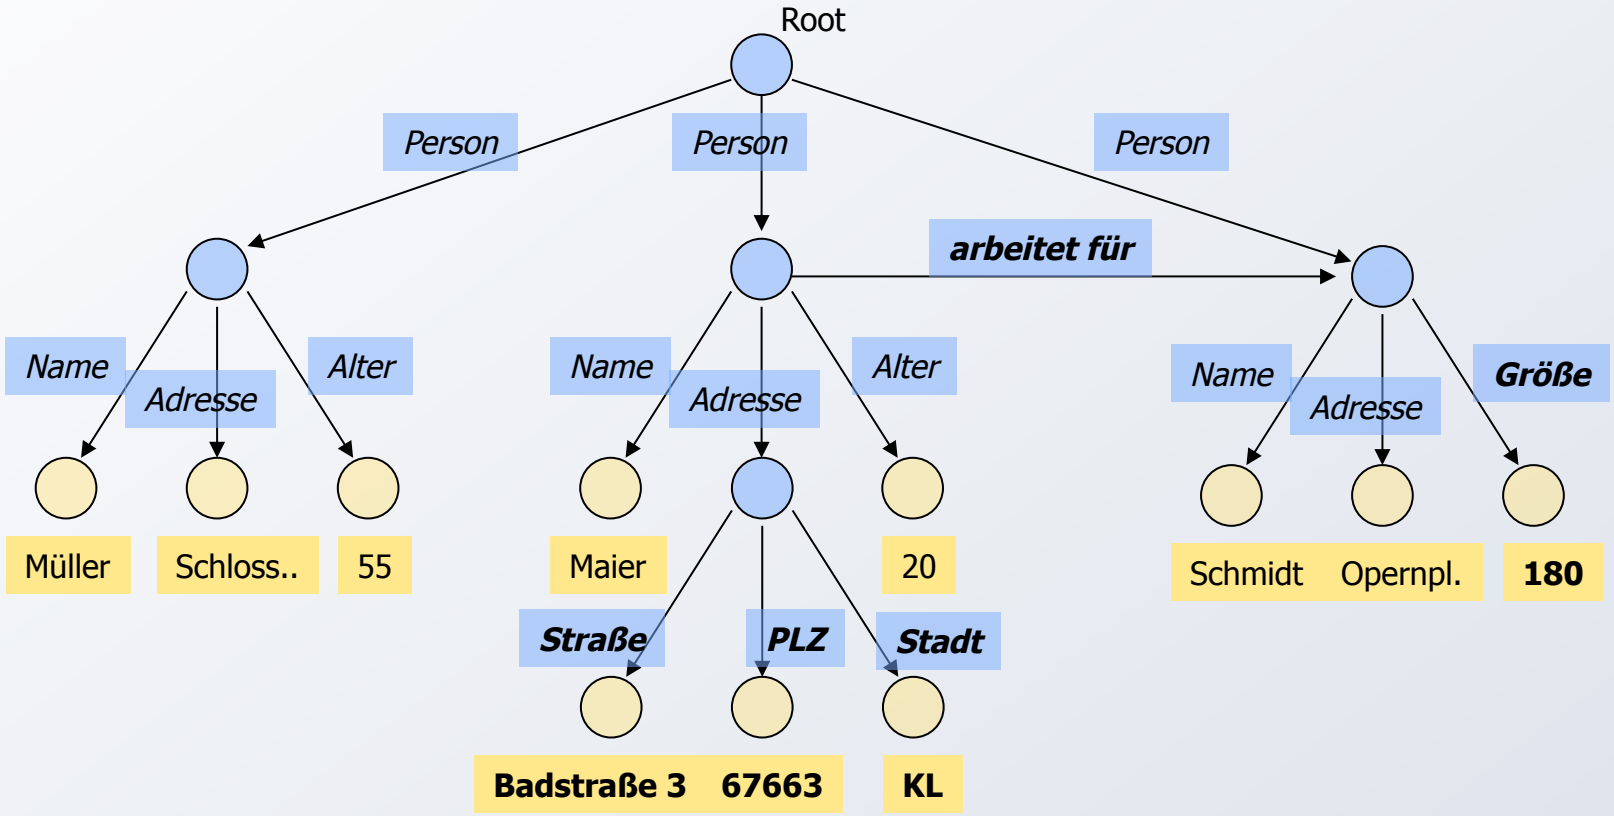

- Blattknoten: Daten
- innere Knoten, Kanten: Struktur/Schemainformation
- Kantenbeschriftung entspricht Attributname, Beziehungsname

* Darstellung als Object Exchange Model (OEM) graph
S. Abiteboul, D. Quass, J. McHugh, J. Widom, and J. Wiener: The Lorel Query Language for Semistructured Data, 1996.

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

XML-Ursprünge – Strukturierte Dokumente

- **Zentrales Problem:** Dokumentformate sind format- bzw. darstellungsorientiert, deshalb Probleme bei
  - Austausch von Dokumenten
  - Wiederverwendung von Inhalten für unterschiedliche Darstellungsformen
- **SGML** (Standard Generalized Markup Language)
  - Int. Standard zur Dokumentrepräsentation (1986)
  - Auszeichnungssprache
    - Definition von beliebigen Tags zur Auszeichnung von (mglw. geschachtelten) Dokument-Elementen
      - Meta-Sprache: erlaubt Definition beliebiger Sprachen (z.B. HTML)
      - Tags haben keine vordefinierte Semantik
    - Trennung von Form und Struktur/Inhalt
    - Dokumente sind selbstbeschreibend
- **XML** (Extensible Markup Language) ist vereinfachte Form von SGML

XML – Beispiel

HTML

- Vermischung von Struktur und Darstellung

```
<h1>Personen</h1>
<p><i>Müller</i>
   <br>Schlossalle 1, …
   <br>55
<p><i>Maier</i>
   <br>Badstraße 3, …
   <br>20
<p><i>Schmidt</i>
   <br>Opernplatz 5, …
   <br>35
```

- Menge von Formatierungs-anweisungen (Tags) mit vorgegebener Bedeutung
- zur Darstellung für den menschlichen Benutzer geeignet

XML

- kann den Inhalt (Struktur und Daten) beschreiben

```
<Personen>
   <Person>
     <Name>Müller</Name>
     <Adresse>
                Schlossalle 1, …
     </Adresse>
     <Alter>55</Alter>
   </Person>
   <Person>
     <Name>Maier</Name>
     …
   </Person>
   …
</Personen>
```

- erlaubt maschinelle Verarbeitung

Nutzung von XML

Dokumentorientierte Sicht

- Dokumentverarbeitung
  - Nutzung eines Dokuments in verschiedenen, sich verändernden Systemen
  - Aspekte: Struktur, Inhalt, Darstellung

Datenorientierte Sicht

- Datenaustausch
  - Daten oft strukturiert, getypt, schemabehaftet
- semistrukturierte Daten und Informationsintegration
  - Schema möglicherweise unbekannt, dynamisch

XML-Sprachspezifikationen (W3C)[1]

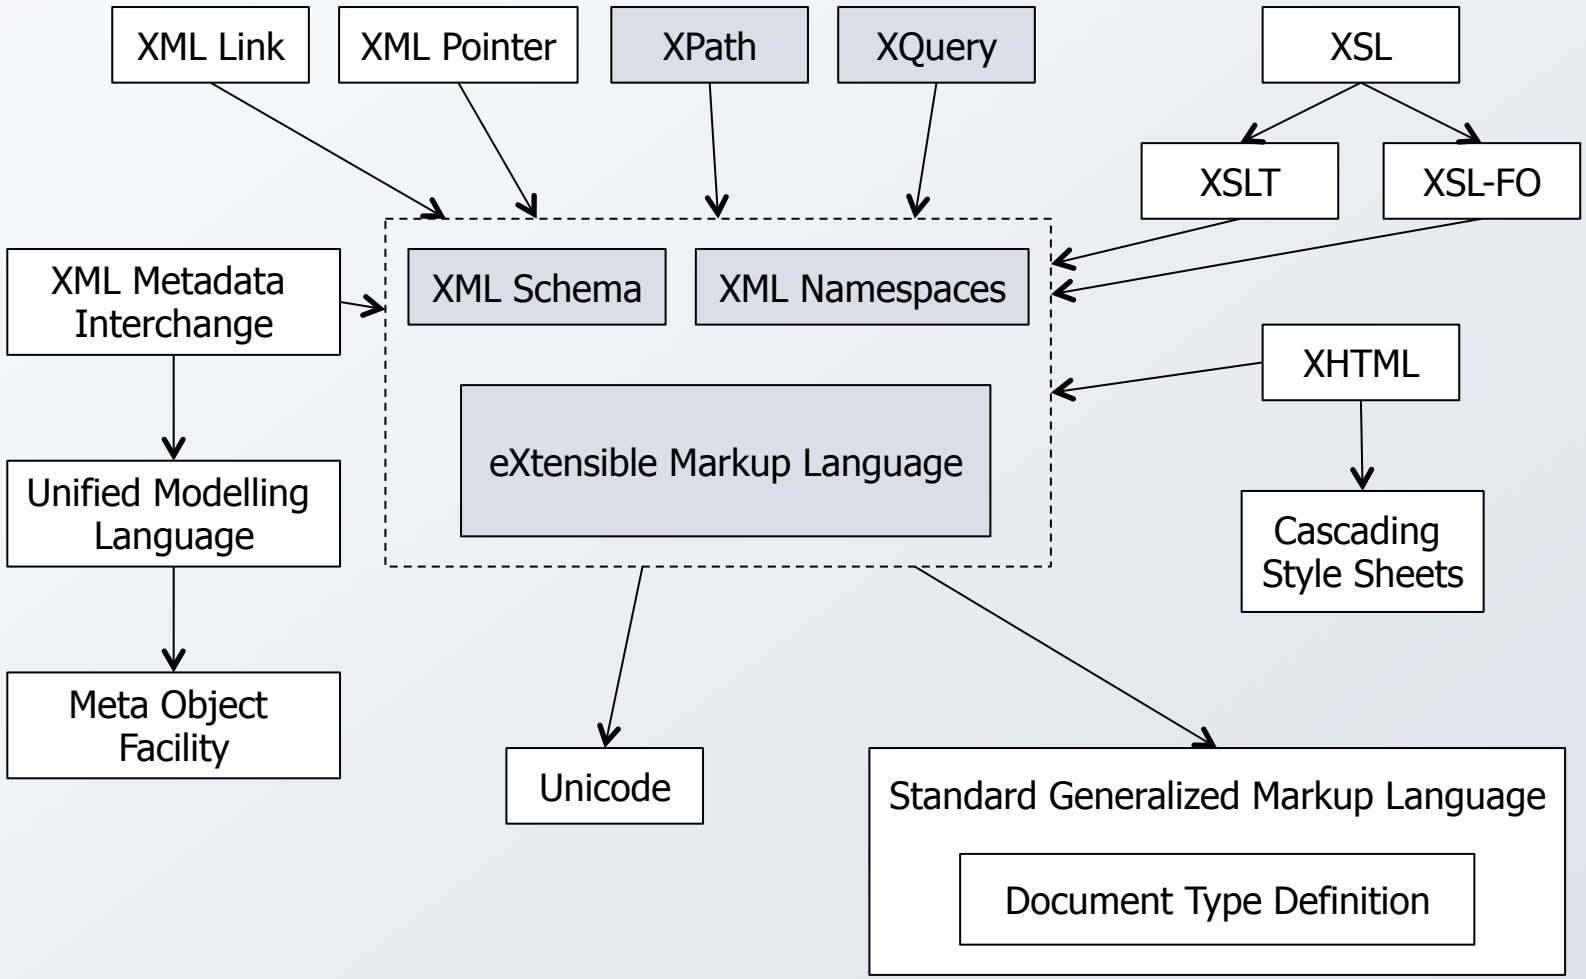

1) http://www.w3.org/XML/

XML-Dokumente

- sind Text (Unicode)
  - Markup (beginnt immer mit '<' oder '&')
    - (Start-/Ende-) Tags (z.B. <Person>, </Person>)
    - Referenzen (<, &, ...)
    - Deklarationen, Kommentare, Verarbeitungsanweisungen, ...
  - Daten (character data)
    - Zeichen '<' oder '&' müssen im Text durch Referenzen (z.B. <) oder direkte Verwendung des Zeichencodes angegeben werden
    - Alternative: Syntax <![CDATA[Formel: (a<b)&(c<d)]]>
- folgen syntaktischen Regeln (**wohlgeformt – *well formed***)
  - Logische Struktur
    - (optionaler) Prolog (XML-Version, ...)
    - (optionales) Schema (dazu später mehr)
    - (Wurzel-) Element (Schachtelung möglich)
    - Kommentare, ...
  - Korrekte Folge von Start-/Ende-Tags (Schachtelung!)
  - Eindeutigkeit von Attributnamen
  - ...
- werden von "XML-Prozessoren" verarbeitet (Parser, etc.)

Elemente und Attribute

- Element
  - beginnt mit <*tagname*> , endet mit </*tagname*>
    - Ausnahme: leeres Element <*tagname*/>
  - kann Textdaten, andere Elemente oder beides beinhalten (element content)
    - *Mixed content* ist insb. für dokumentorientierte Anwendungen gedacht
  - Schachtelung: Start-Tag und zugeordnetes Ende-Tag haben gleichen Namen und befinden sich im gleichen (umgebenden) Element
  - Elemente des gleichen Typs (d.h., mit gleichem Tag-Namen) können mehrfach vorkommen
- Attribut
  - Name/Wert-Paar im Kontext eines Elements
    - beschränkt auf atomare Werte
    - Syntax: *attname="value"* innerhalb des Start-Tags
    - Attributname ist eindeutig innerhalb eines Elements
    - es ist keine Ordnung für Attribute eines Elementes definiert

⇨ Welches Konzept soll man wann nutzen?

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Beispiel

```
<?xml version="1.0"?>
<Personen>
   <Person>
     <Name>Müller</Name>
     <Adresse>Schlossalle 1, ... </Adresse>
     <Alter>55</Alter>
   </Person>
   <Person>
     <Name>Maier</Name>
     <Adresse>
                <Straße>Badstraße 3, ... </Straße>
                <PLZ>67663</PLZ>
                <Ort>KL</Ort>
     </Adresse>
     <Alter>20</Alter>
   </Person>
   <Person>
     <Name>Schmidt</Name>
     <Adresse>Opernplatz 5, ... </Adresse>
     <Größe Maß="cm" Gemessen_am="01.07.2006">180</Größe>
   </Person>
</Personen>
```

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

XML-Datenmodell

- Es existiert kein einheitliches Datenmodell für XML
  - Verschiedene Ansätze mit unterschiedlichem Ziel
    - XML Information Set, DOM Structure Model, **XQuery-Datenmodell** (enthält XPath), …
  - Gemeinsame Sicht: XML-Dokument als Baumstruktur mit unterschiedlichen Knotentypen
    - Document, Element, Attribute, Text, Comment, …

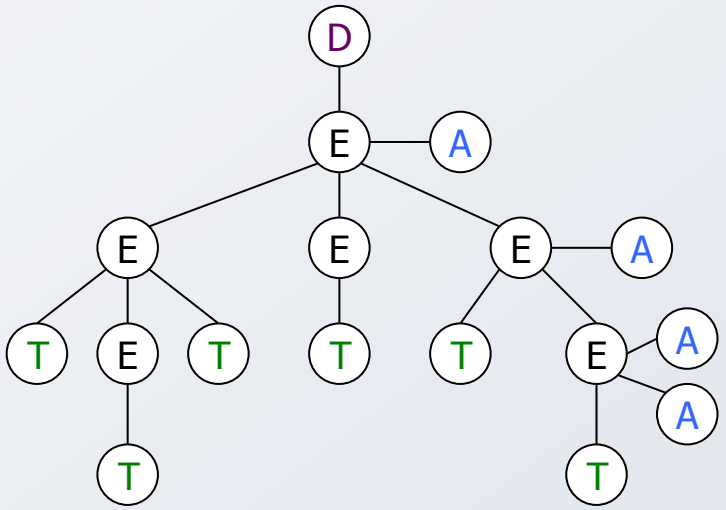

- Konzeptuelle Repräsentation: Bäume mit Knoten und Kanten
- Dokumentenordnung muss erhalten bleiben / wiederherstellbar sein: **Knotenordnung ist wichtig!**

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Beispiel: XML ⇔ Relationenmodell

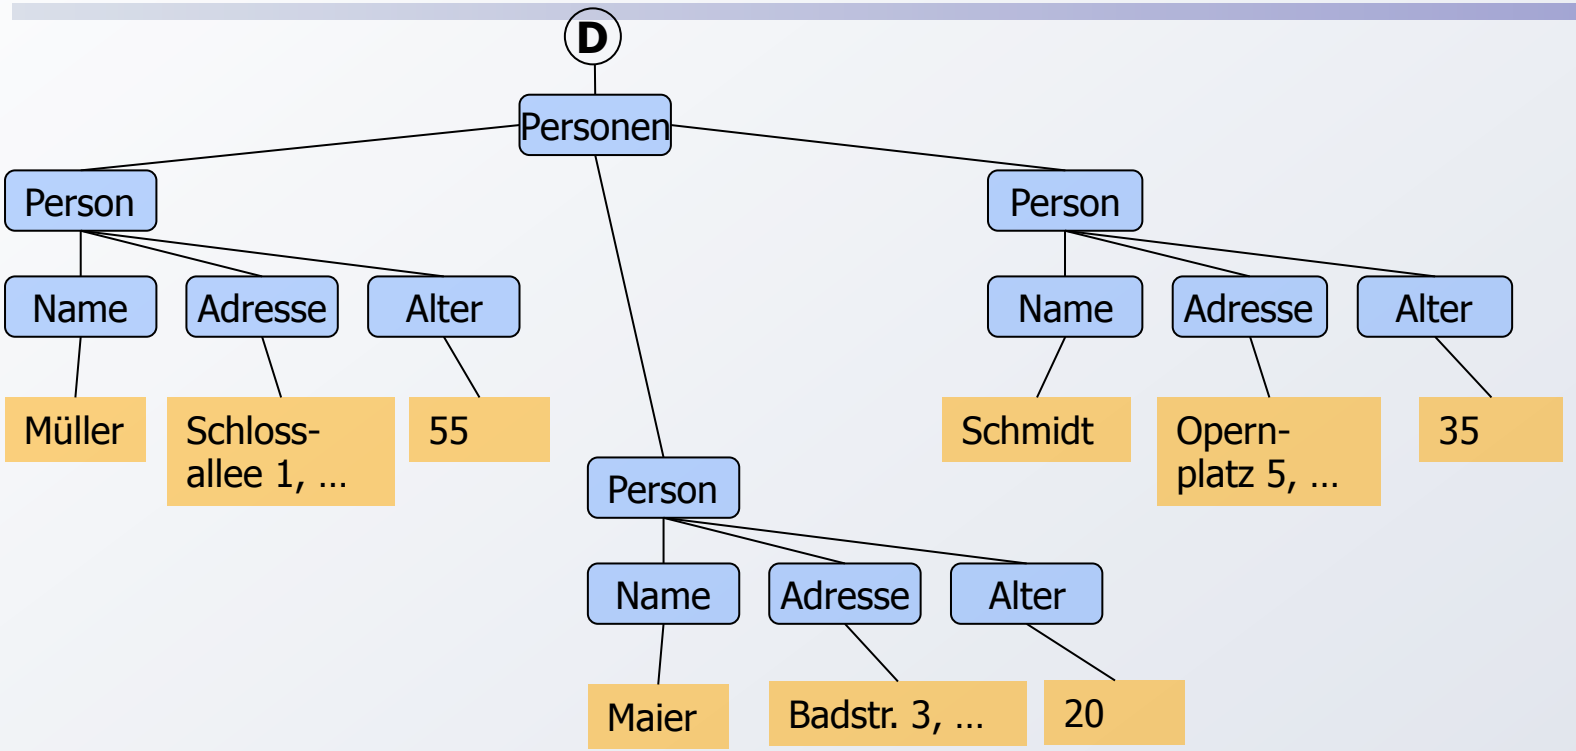

Person		
Name	Adresse	Alter
Müller	Schlossallee 1, ...	55
Maier	Badstraße 3, ...	20
Schmidt	Opernplatz 5, ...	35

Perfekte Abbildung im RM nur, wenn
- gleichförmige Objekte (Entities)
- genau dreistufige Beschreibung O/A/W
- atomare Werte
- keine Aspekte (Attribute von XML-Elementen)
- Ordnung ohne Bedeutung ist.

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Erweitertes Beispiel: XML ↔ Relationenmodell

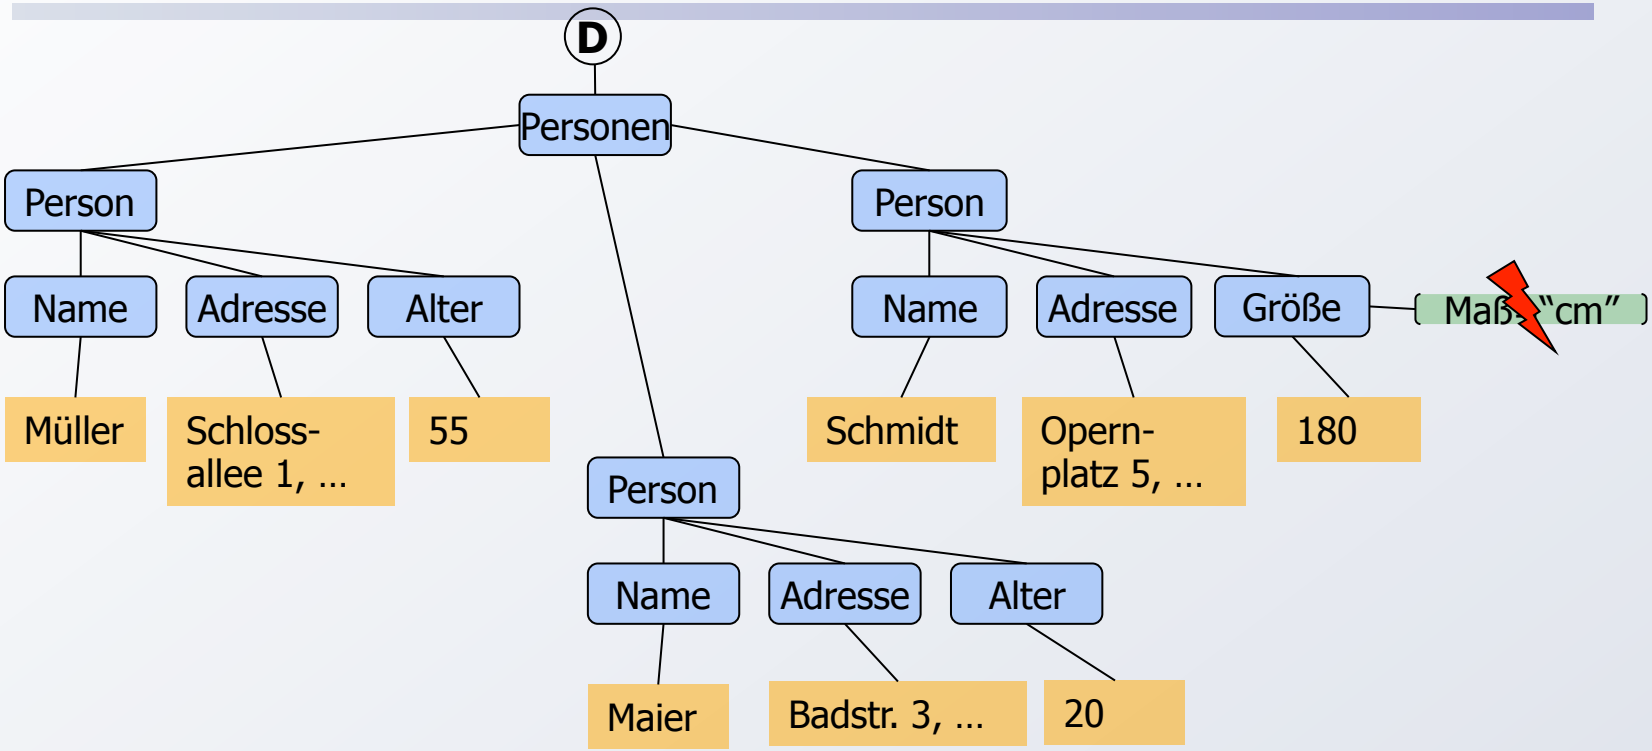

Person			
Name	Adresse	Alter	Größe
Müller	Schlossallee 1, …	55	--
Maier	Badstraße 3, …	20	--
Schmidt	Opernplatz 5, …	--	180

Einfache Abbildung im RM möglich

- bei Bedingungen für perfekte Abbildung,
- aber geringfügigen Strukturabweichungen (z. B. Alter/Größe)
- jedoch keine Aspekte (Attribute von XML-Elementen); sie müssten auf eine separate Spalte abgebildet werden

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Erweitertes Beispiel: XML ↔ Relationenmodell (2)

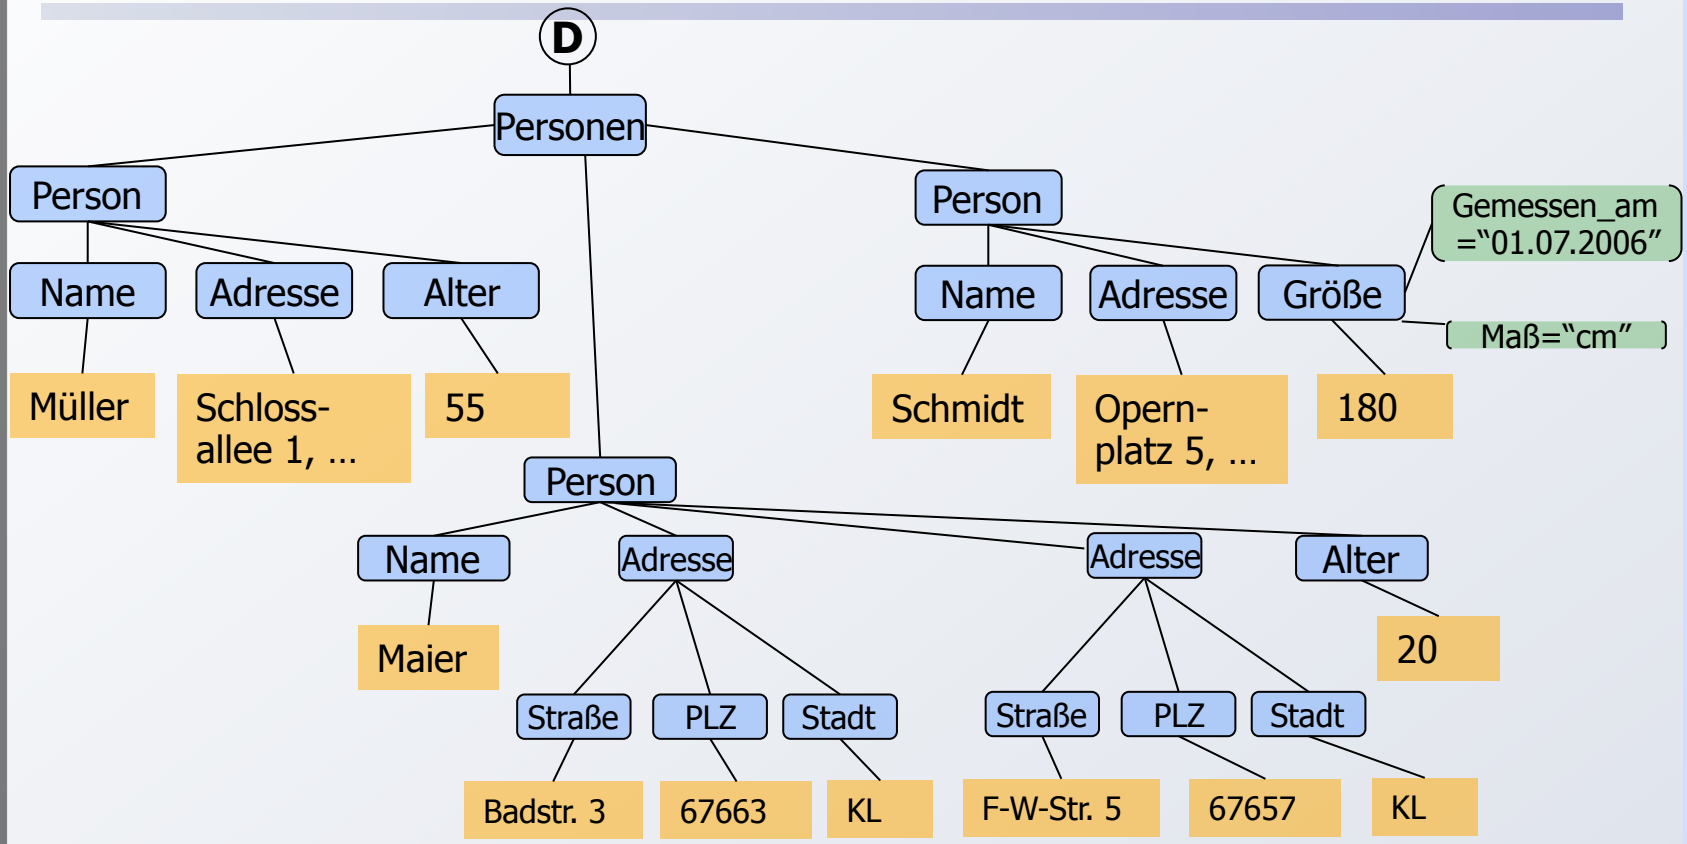

Person			
Name	Adresse	Alter	Größe
Müller	Schlossallee 1,..	55	--
Maier	?	20	--
Schmidt	Opernplatz 5, …	--	180

Abbildung im RM in einer Tabelle scheitert, wenn Objektbeschreibung

- mehr als drei Stufen hat (zusammengesetzte Attribute),
- mehrwertige oder relationenwertige Attribute (n-stufige Wiederholungsgruppen) besitzt

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Erweitertes Beispiel: XML ↔ Relationenmodell (3)

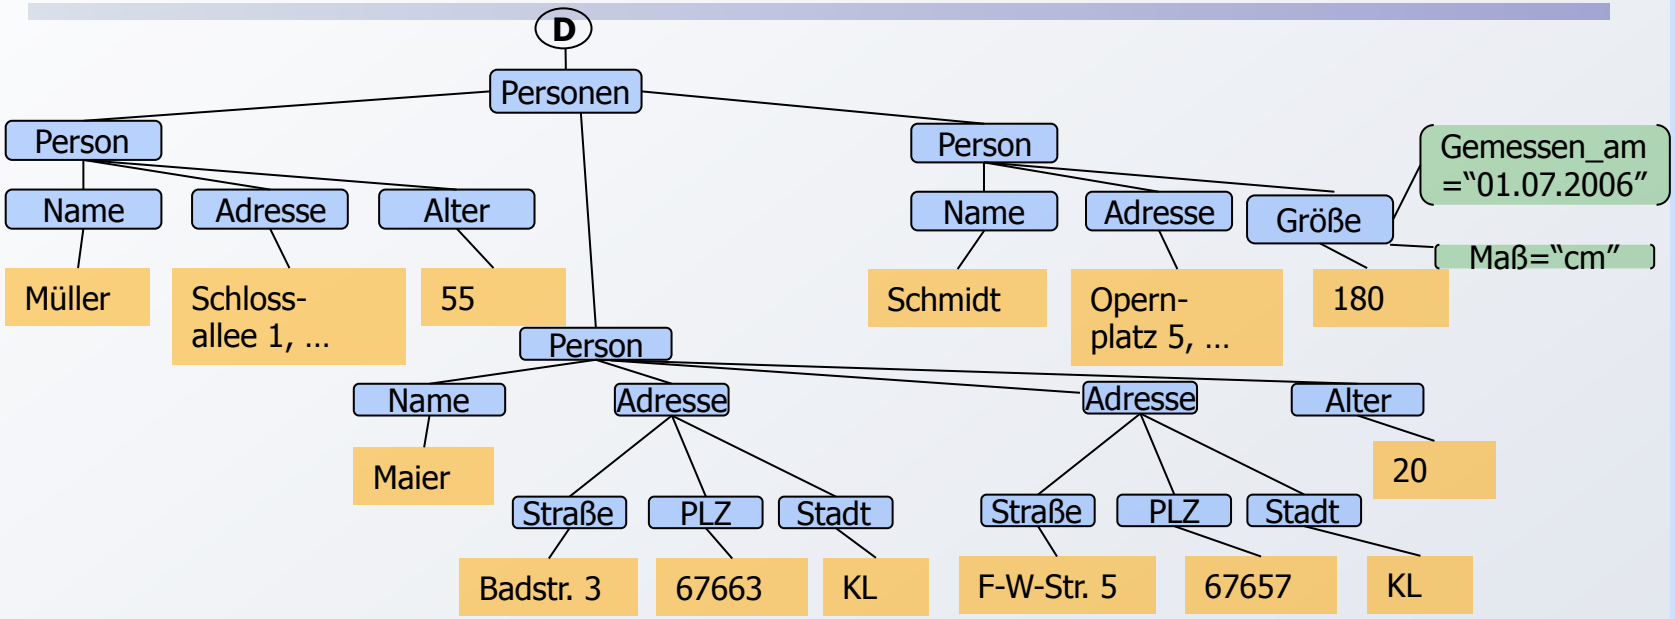

Person

LfdNr	Name	Adresse	AdNr	Alter	Größe
1	Müller	Schlossallee 1, …	--	55	--
2	Maier	- -	1	20	--
3	Schmidt	Opernplatz 5, …	--	--	180

Adresse

AdNr	LfdNr	Straße	PLZ	Stadt
1	1	Bachstr. 3	67663	KL
1	2	F-W-Str. 5	67657	KL
…				

Abbildung im RM über mehrere Tabellen

- wird zumindest sehr komplex und unverständlich (siehe Kap. 4),
- zusätzlich muss auch Ordnung erhalten werden,
- wird auch „Shredding“ genannt

Welches Modell setzt sich durch?

- Zunehmende Entwicklung von verteilten Anwendungen auch im Internet
  - Standardisierte XML-Austauschformate sind für AW-Klassen vordefiniert
  - Nachrichten sind aber auch (in DBs zu speichernde) Daten!
  - ständiges Konvertieren: RM ↔ XML?
- Koexistenz
  - native XML-Verarbeitung löst RM nicht ab
  - beide Modelle bestehen nebeneinander und ergänzen sich!
- XML wird bereits intensiv für Kommunikation und Datenbeschreibung (Web Services, SOA) benutzt, weil es
  - wesentlich flexibler ist und die Datenintegration vereinfacht
  - selbstbeschreibend, erweiterbar, hersteller- und plattformunabhängig ist

B1 sieht eine hoch entwickelte relationale DB, die auch XML unterstützt

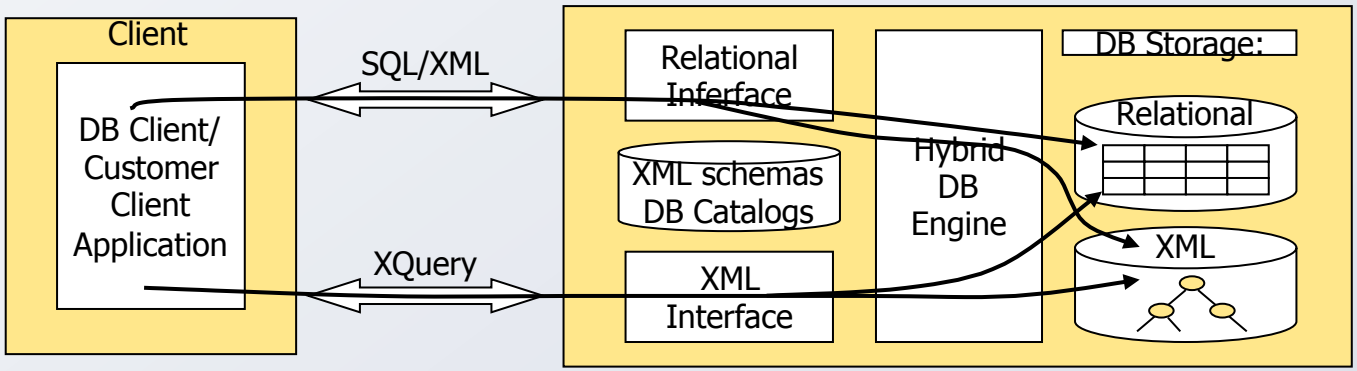

B2 sieht eine hoch entwickelte native XML-DB, die auch SQL unterstützt

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Warum XML-Datenbanksysteme (XDBS)?

- Erwünschte Eigenschaften:
  - Instanzen tragen Struktur und Daten (integrierte Metadaten)
  - Modellierungsflexibilität und Schemaevolution
  - DB- oder Applikations-kontrollierte Konsistenz
  - zusätzlich zu den in der Praxis bewährten DBS-Eigenschaften
    - ACID-Transaktionen
    - deklarative Anfrageverarbeitung
    - effiziente und parallele Verarbeitung von großen Datenvolumina
    - hohe Verfügbarkeit und Fehlertoleranz
    - Skalierbarkeit für transaktionale Arbeitslasten und Datenvolumina
- Beispiele:
  - Dokument-zentrierte Sicht: Dokumentkollektionen
    - Bücher, Artikel, Web-Seiten, …
    - ➥ Applikationen: Struktur-sensitives Information Retrieval, …
  - Daten-zentrierte Sicht: semi-strukturiertes Datenmodell
    - Nachrichten, Konfigurationsdateien, semi-strukturierte Daten per se
    - ➥ Applikationen: Informationsverwaltung für Administration, Krankenhäuser, E-Business, …

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Relationale, native oder hybride Speicherung?

- Speicherung als **„lange Felder“** (LOBs) ermöglichen keine feinkörnige Verwaltung, keine inhaltsbasierte Suche und keine Mehrbenutzer-Verarbeitung
- **Abbildung auf relationale Tabellen?**
  - dazu gibt es viele Lösungen: „Shredding”
  - **Leistungsverhalten** (Suche, IUD-Ops) ungeklärt
  - XML-Anfragesprachen (z.B. XQuery, XPath, DOM, SAX) sind auf SQL abzubilden
  - Nutzung des SQL-Optimizer!
  - Aber: Kontrolle des Mehrbenutzerbetriebs (Sperren) ist sehr kompliziert, weil ein Dokument über n Tabellen verteilt sein kann
- **Hybrider Ansatz**
  - Beispiel: DB2-Viper
  - SQL mit XQuery-Teilanfragen von SQL-Funktionen xmlQuery, xmlExists und xmlTable
  - „stand-alone“ XQuery-Schnittstelle
    - bietet Zugriff auf XML-Spalten
    - db2-fn:xmlcolumn importiert eine ganze XML-Spalte als Sequenz von Items

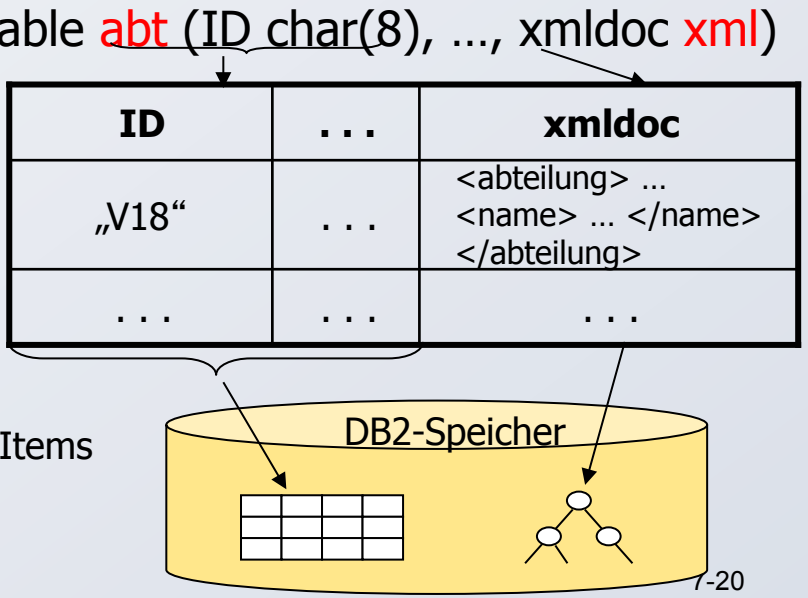

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Transformation eines XML-Dokuments (Bsp. DB2)

Native Speicherung: Transformation in einen internen XML-Baum;
Elementnamen werden mithilfe eines Wörterbuchs (Dictionary) ersetzt

```
<abteilung>
  <angestellter id="450">
            <name> Tom Meier</name>
            <tel>0211-126812</tel>
            <raum>119</raum>
  </angestellter>
  <angestellter id="426">
            <name>Tina Lint</name>
            <tel>0211-679088</tel>
            <raum>113</raum>
  </angestellter>
</abteilung>
```

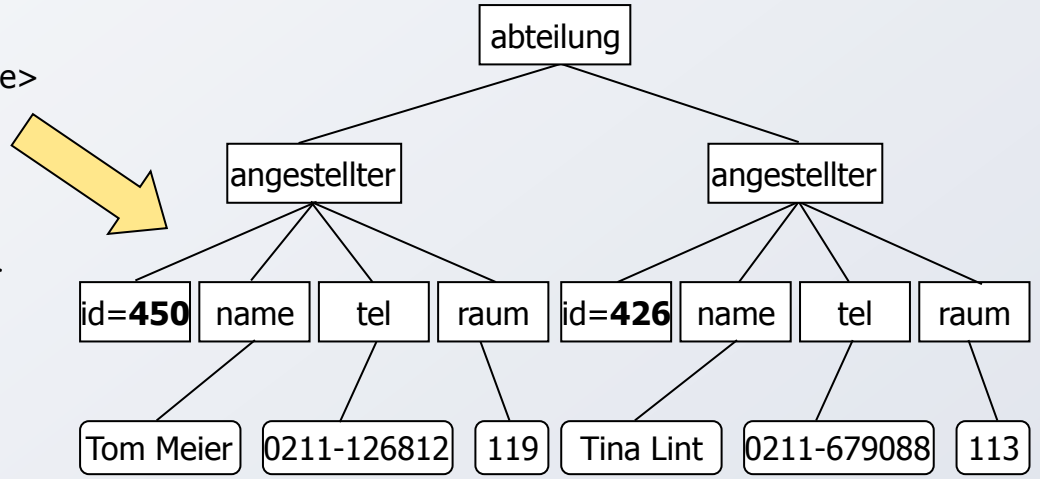

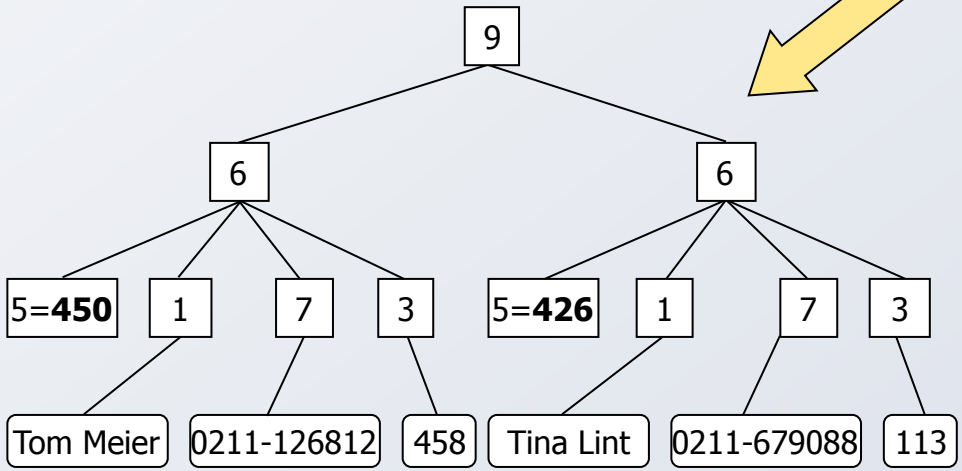

SYSIBM:SYSXMLSTRINGS

String table	
9	abteilung
6	angestellter
1	name
5	id
7	tel
3	raum

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Vogelperspektive – XML-Datenbankverwaltung

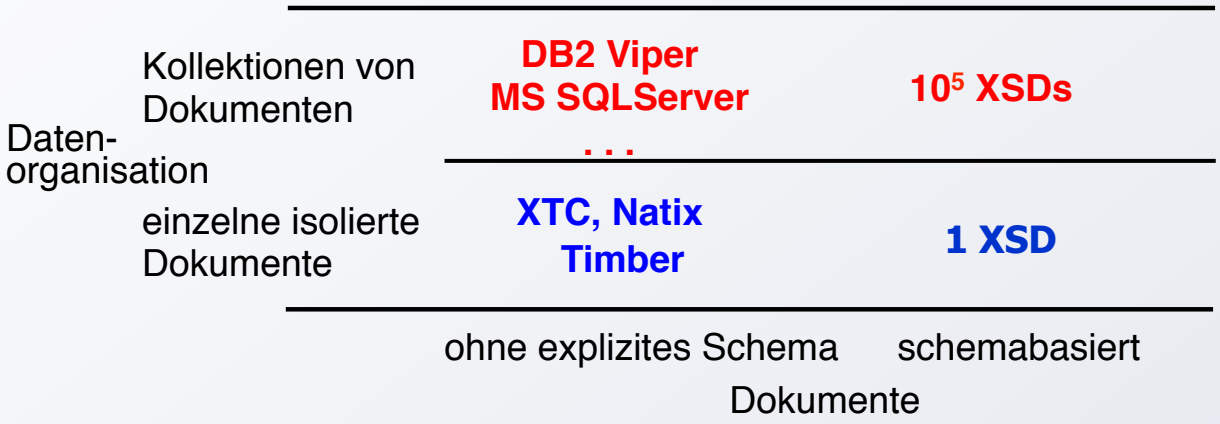

- „Ganze Welt“ ein einziges Dokument
  - heterogene Teilbäume
  - typische Index-unterstützte Ops: XPath-Verarbeitung, TWIGs, …
  - unterschiedliche Sprachmodelle DOM, SAX, XPath, XQuery
- Flexibilität und Schemaevolution
  - schemaloser Ansatz (Konsistenz-garantien, Suche?)
  - multiple oder sich entwickelnde Schemata oder
  - Schemata mit Erweiterungspunkten (Really Simple Syndication, Atom, …)
- Kollektion von kleineren (<1MB) Dokumenten
  - heterogen
  - Filterung durch Indexeinsatz
  - XQuery, XSQL, SQL/XML
- DB-kontrollierte Konsistenz
  - XSD-Entwurf zuerst
  - Schema-unterstützte Suche
  - strenge Konsistenzprüfung
  - Wie geht man mit 10^5 Schemata um?

Schemadefinition für XML-Dokumente

- XML-Dokument kann (optional) Schema besitzen
  - standardisierter Datenaustausch, ...
- Schema schränkt die für das Dokument erlaubten Strukturen und Datentypen ein
  - Dokument heisst **gültig (*valid*)**, falls es die Anforderungen des Schemas erfüllt
  - rekursive Schemadefinitionen erlaubt
    - Bauteil besteht aus weiteren Bauteilen ...
- Zwei wichtige Ansätze
  - Document Type Definition (DTD)
    - im Dokument enthalten, oder
    - in einer separaten Datei gespeichert, im Dokument referenziert
  - XML Schema

XML Document Type Definition (DTD)

- Definition von Elementtypen
  - Welche Elemente dürfen vorkommen
  - Welche Attribute darf bzw. muss ein Element haben
  - Welche Unterelemente dürfen bzw. müssen in einem Element auftreten, und wie oft
- DTD bietet keine Unterstützung für Datentypen
  - Daten sind, wie gehabt, nur Zeichenketten ohne weitere Einschränkungen
- DTD-Syntax
  - <!ELEMENT element (subelements-specification) >
  - <!ATTLIST element (attributes) >

Elementspezifikation

- Mögliche Unterelemente
  - Name des Elements
  - #PCDATA (parsed character data), d.h., beliebige Zeichenkette
  - EMPTY (keine Unterelemente) or ANY (beliebige Unterelemente)
- Strukturierung mit Hilfe von regulären Ausdrücken
  - Sequenz (*subel* , *subel* , ...), Alternative (*subel* | *subel* | ...)
  - Wie oft darf *subel* vorkommen?
    - "?" - 0 oder 1
    - "+" - mindestens 1
    - "*" - beliebig oft
- Beispiel

```
<!DOCTYPE  Personen [
        <!ELEMENT Personen (Person*)
        <!ELEMENT Person (Name, Adresse+, (Alter | Größe) )
        <!ELEMENT Name (#PCDATA)
        <!ELEMENT Adresse (#PCDATA | (Straße, PLZ, Stadt) )
        ...
```

Attributspezifikation

- Für jedes Attribut
  - Name
  - Attributtyp
    - Zeichenkette (CDATA) oder XML Name Token
    - Aufzählungstyp
    - ...
  - Vorkommen
    - Attribut(wert) muss vorhanden sein, oder
    - Attribut ist optional, oder
    - Defaultwert
- Beispiel
  - <!ATTLIST Größe Maß (cm | inches) #REQUIRED>

Elementidentität und Referenzen

- Attributtyp ID, IDREF
  - Element kann max. ein Attribut vom Typ ID besitzen
    - Wert muss eindeutig sein im ganzen Dokument (-> Objekt-ID)
- Attribut vom Typ IDREF muss den ID-Wert eines (beliebigen) Elements im gleichen Dokument enthalten
  - Typ IDREFS: ein oder mehrere REFs
- Beispiel

```
<!ATTLIST Person      oid ID #REQUIRED
                      arbeitetFür IDREF #IMPLIED>
```

- Erlaubt mit großen Einschränkungen Repräsentation von Beziehungen
  - ID, IDREFs sind ungetypt, d.h., die Menge der referenzierbaren Elemente ist nicht einmal auf Typebene definierbar
    - Bsp.: arbeitetFür könnte auch Adressenelemente referenzieren, wenn diese eine ID hätten …

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Document Type Definition – Beispiel

```
<!DOCTYPE Personen [
    <!ELEMENT Personen (Person*)>
    <!ELEMENT Person (Name, Adresse+, (Alter|Größe))>
    <!ATTLIST Person oid ID #REQUIRED
                     arbeitetFür IDREF #IMPLIED>
    <!ELEMENT Name (#PCDATA)>
    <!ELEMENT Adresse (#PCDATA|(Straße, PLZ Stadt))>
    <!ELEMENT Alter (#PCDATA)>
    <!ELEMENT Größe (#PCDATA)>
    <!ATTLIST Größe  Gemessen_am CDATA #IMPLIED
                     Maß (cm | inches) #REQUIRED>
    <!ELEMENT Straße (#PCDATA)>
    <!ELEMENT PLZ (#PCDATA)>
    <!ELEMENT Stadt (#PCDATA)>
]>
```

Schemabeschreibung mit XML Schema

- Unterstützung von Datenmodellierungskonzepten, u.a.
  - Datentypen
    - integer, string, ...
  - Constraints
    - min/max-Werte für mgl. Anzahl von Elementwiederholungen
    - Werteindeutigkeit (unique), Fremdschlüssel
  - Getypte Referenzen
  - Namensräume in XML (name spaces)
  - Benutzerdefinierte Typen
    - lokale Definition oder Referenz auf entsprechenden Namensraum
    - mehrfache Benutzung
- Modularisierung und Wiederverwendung von Schemadefinitionen
- Schemadefinition ist wiederum ein XML-Dokument
- Deutlich komplizierter als DTDs

Namensräume (Namespaces)

- Ziel: Vermeidung von Namenkollisionen bei Nutzung von verschiedenen Vokabularen (Schemata) im gleichen Dokument
  - Beispiel
    - Ein Element Titel kommt sowohl im Kontext von Büchern (Buchtitel) als auch im Kontext von Personen (z.B. akademischer Titel) vor
    - Ein Dokument das Information über Bücher und Autoren enthält soll Bestandteile aus beiden Schemata verwenden können
- Namensraum
  - „enthält“ eine Menge von Namen
  - durch URI „weltweit“ eindeutig identifiziert
  - kann in einem XML-Dokument oder Element genutzt werden
    - Deklaration als Default-Namespace
    - Definition und Angabe von “Kürzeln” (prefix)
      - <lit:titel>, <pers:titel>, …

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

XML Schema – Beispiel (1)

```
<xsd:schema xmlns:xsd="http://www.w3.org/2001/XMLSchema"
    targetNamespace="http://www.personen.org" xmlns ="http://www.personen.org" >
    <xsd:element name="Personen">
        <xsd:complexType>
            <xsd:sequence>
                <xsd:element name="Person" minOccurs="0" maxOccurs="unbounded" >
                    <xsd:complexType>
                        <xsd:sequence>
                            <xsd:element name="Name" type="xsd:string"/>
                            <xsd:element name="Adresse" type="AdresseTyp"
                                    minOccurs="1" maxOccurs="3"/>
                            <xsd:choice>
                                <xsd:element name="Alter" type="xsd:integer" />
                                <xsd:element name="Größe" type="GrößeTyp" />
                            </xsd:choice>
                        </xsd:sequence>
                        <xsd:attribute name="oid" type="xsd:ID" />
                        <xsd:attribute name="arbeitetFür" type="xsd:IDREF" />
                    </xsd:complexType>
                </xsd:element>
            </xsd:sequence>
        </xsd:complexType>
    </xsd:element>
```

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

XML Schema – Beispiel (2)

```
<xsd:complexType name="AdresseTyp " mixed="true" >
    <xsd:sequence>
        <xsd:element name="Straße" type="xsd:string"/>
        <xsd:element name="PLZ" type="PLZTyp"/>
        <xsd:element name="Stadt" type="xsd:string"/>
    </xsd:sequence>
</xsd:complexType>
<xsd:complexType name="GrößeTyp" >
    <xsd:simpleContent>
        <xsd:extension base="xsd:positiveInteger ">
            <xsd:attribute name="Gemessen_am" type="xsd:date" />
            <xsd:attribute name="Maß" type="MaßTyp" />
        </xsd:extension>
    </xsd:simpleContent>
</xsd:complexType>
<xsd:complexType name="PLZTyp" >
    <xsd:simpleContent>
        <xsd:restriction base="xsd:string">
            <xsd:pattern value="[0-9]{5}"/>
        </xsd:restriction>
    </xsd:simpleContent>
</xsd:complexType>
<xsd:complexType name="MaßTyp">
    <xsd:simpleContent>
  <xsd:restriction base="xsd:string">
        <enumeration value="cm"/>
        <enumeration value="inches"/>
  </xsd:restriction>
    </xsd:simpleContent>
</xsd:complexType>
</xsd:schema>
```

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

XML Schema – Definition und Nutzung

- XML-Schema-Dokument
  - deklariert Elemente/Attribute bzw. definiert (einfache oder zusammengesetzte) Datentypen
  - ordnet (optional) die deklarierten/definierten Konzepte einem Namensraum zu (target namespace)

```
<xsd:schema xmlns:xsd="http://www.w3.org/2001/XMLSchema"
        targetNamespace="http://www.personen.org" xmlns ="http://www.personen.org" >
  <xsd:element name="Personen">
    <xsd:complexType>
      <xsd:sequence>
        <xsd:element name="Person" minOccurs="0" maxOccurs="unbounded" >
          <xsd:complexType>
            <xsd:sequence>
              <xsd:element name="Name" type="xsd:string"/>
              <xsd:element name="Adresse" type="AdresseTyp"
                           minOccurs="1"  maxOccurs="3"/>
              <xsd:choice>
                <xsd:element name="Alter" type="xsd:integer" />
                <xsd:element name="Größe" type="GrößeTyp" />
              </xsd:choice>
            </xsd:sequence>
            <xsd:attribute name="oid" type="xsd:ID" />
            <xsd:attribute name="arbeitetFür" type="xsd:IDREF" />
          </xsd:complexType>
        </xsd:element>
      </xsd:sequence>
    </xsd:complexType>
  </xsd:element>
```

- XML-Dokument
  - nutzt ein Schema durch Deklaration/Referenz des entsprechenden Namensraums
    - Nutzung mehrerer Schemata im gleichen Dokument
    - Namensraumdefinition für Wurzelelement und/oder beliebige Unterelemente

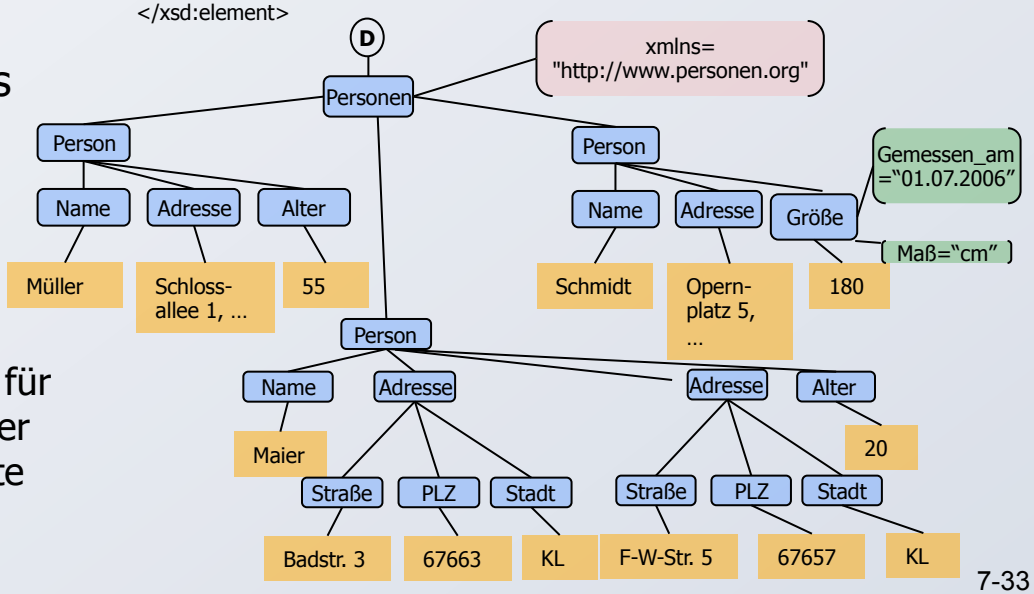

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Abbildung ER-Modell -> XML Schema

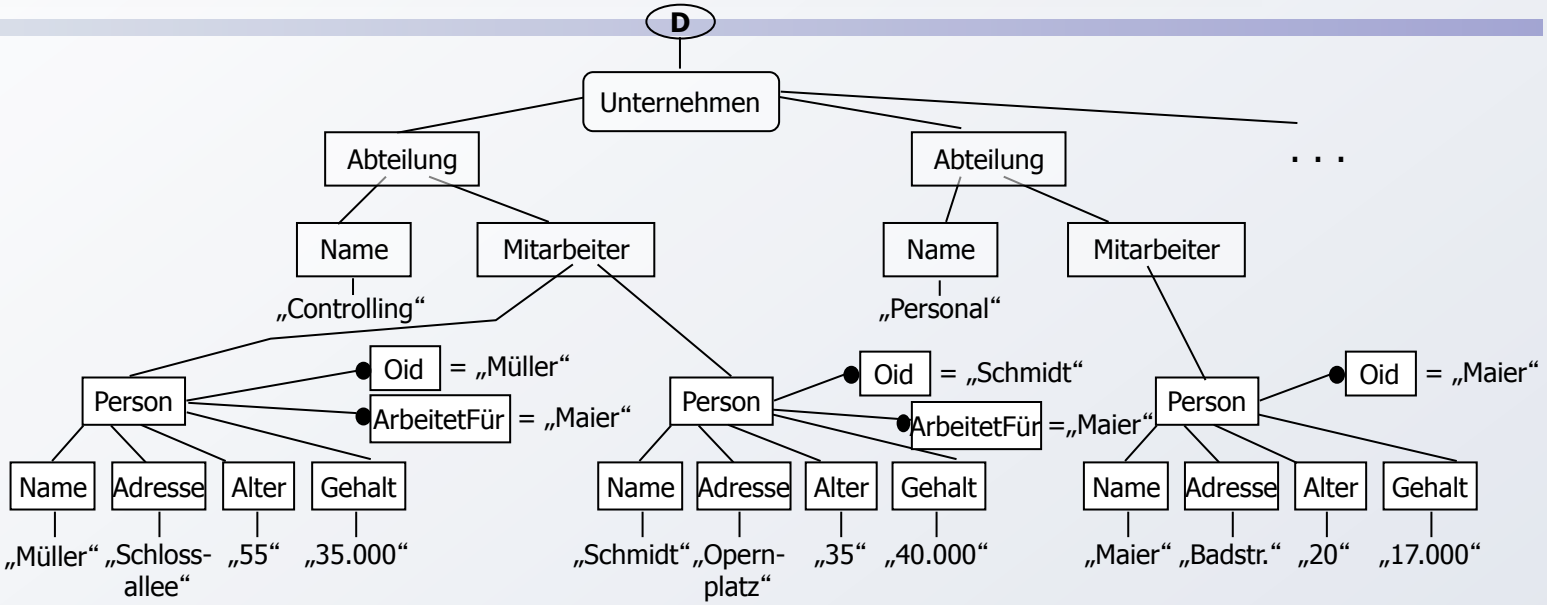

- **Entities**
  - 1:1-Abbildung auf XML-Elemente
  - <key> in XML-Schema, um Schlüsselattribute darzustellen
- **Relationships**
  - 1:1, 1:N
    - Schachtelung von Elementen
      - Probleme: Existenzabhängigkeit, Eindeutigkeit von Schlüsselattributen in geschachtelten Elementen, …
    - „flache“ Repräsentation
      - Nutzung von Schlüsseln, Fremdschlüsseln
  - N:M
    - flache Repräsentation mit Hilfselementen

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Anfragesprachen

- Anfragen auf
  - (großen) XML-Dokumenten
  - XML-Daten in nativen XML-Datenbanken
  - logischen XML-Sichten auf beliebigen Datenquellen
- Semistrukturierter Ansatz erfordert Umgang mit
  - schemalosen Daten/Dokumenten
  - heterogenen Dokumentstrukturen
- Funktionalität
  - Pfadausdrücke zur Lokalisierung von Knoten im XML-Baum
  - Komplexe Anfragen
- XML-Anfragesprache XQuery *
  - beinhaltet u. a. wesentliche Funktionen von XPath
  - W3C-Standard

* W. Lehner, H. Schöning: *XQuery – Grundlagen und fortgeschrittene Methoden*, dpunkt-Verlag, 2004.

Datenmodell für XML-Anfragen

- Ziel: Abgeschlossenheit bzgl. der Operationen der Anfrageverarbeitung
  - Baummodell nicht ausreichend
- Datenmodell in XPath, XQuery
  - Objekte des Datenmodells sind Sequenzen
    - Sequenz hat 0, 1 oder mehrere Einträge (*items*)
      - Entweder Knoten (*nodes*) oder atomare Werte (*atomic values*)
    - Einträge sind geordnet
  - Knoten als Sequenzeinträge
    - Repräsentieren Baumstruktur eine Dokuments bzw. Fragments
      - 7 Knotentypen: Element, Dokument, Attribut, Namensraum, Verarbeitungsanweisung, Kommentar, Text
    - Knoten haben eine Identität (nicht verwechseln mit ID, IDREF)
    - Ordnung im Baum entspricht Dokumentordnung
      - Eltern < Kinder
      - Namenräume < andere Attribute < Kinder
      - Geschwister in Dokumentreihenfolge
- Anfrageausdrücke operieren auf einer oder mehreren Sequenzen und liefern wieder eine Sequenz

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Pfadausdrücke in XPath, XQuery

- Pfadausdruck adressiert (selektiert) eine Sequenz von Knoten in einem Dokument
  - besteht aus Schritten, durch "/" voneinander getrennt
    - Bsp.: Namen aller Personen
      /child::Personen/child::Person/child::Name
  - wird sukzessive, von links nach rechts ausgewertet
    - Pfadanfang: Dokumentwurzel oder von außen vorgegebener Kontext
    - Jeder Schritt geht von Knotensequenz aus
      - Sucht für jeden Knoten in der Sequenz weitere Knoten auf
      - Duplikateliminierung aufgrund der impliziten Knotenidentität
      - Mglw. Sortierung der Knoten in Dokumentreihenfolge
    - Leere Resultate erzeugen keine Fehler

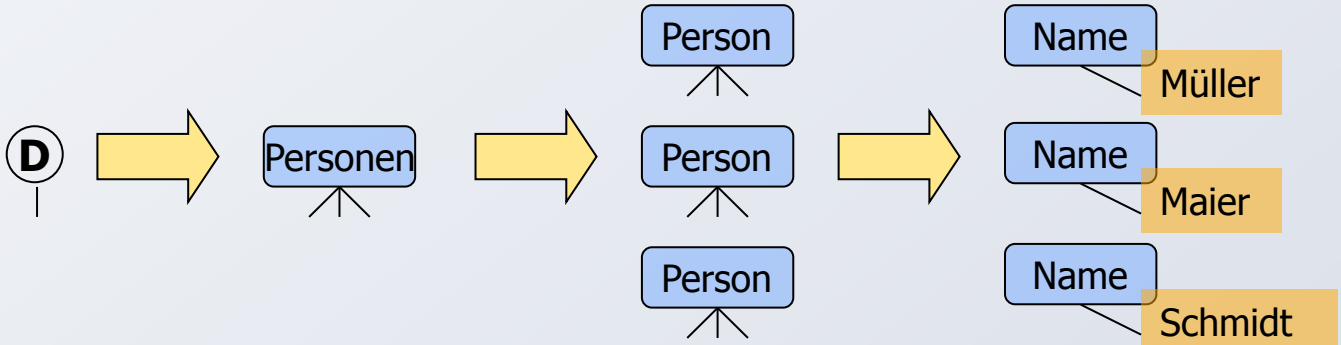

Pfadausdrücke – Schritte

- Initialer "/" bezeichnet Dokumentknoten (Wurzel)
- Ein Achsenschritt hat i. Allg. drei Bestandteile
  - Achse – beschreibt Navigationsrichtung vom Kontextknoten ausgehend
  - Knotentest – Auswahl von Knoten aufgrund des Namens oder Typs
  - Optionale Prädikate – Weitere Selektion von sich qualifizierenden Knoten
  - Beispiel: Alle Personen älter als 30

    child::Person[child::Alter > 30]

    Syntax: Achse::Knotentest [Prädikat] ...
- Alternativ: Filterschritt
  - Anstelle von Achse::Knotentest kann ein Ausdruck stehen, der für Knoten aus dem Kontext weitere Knoten lokalisiert

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Mögliche Achsen

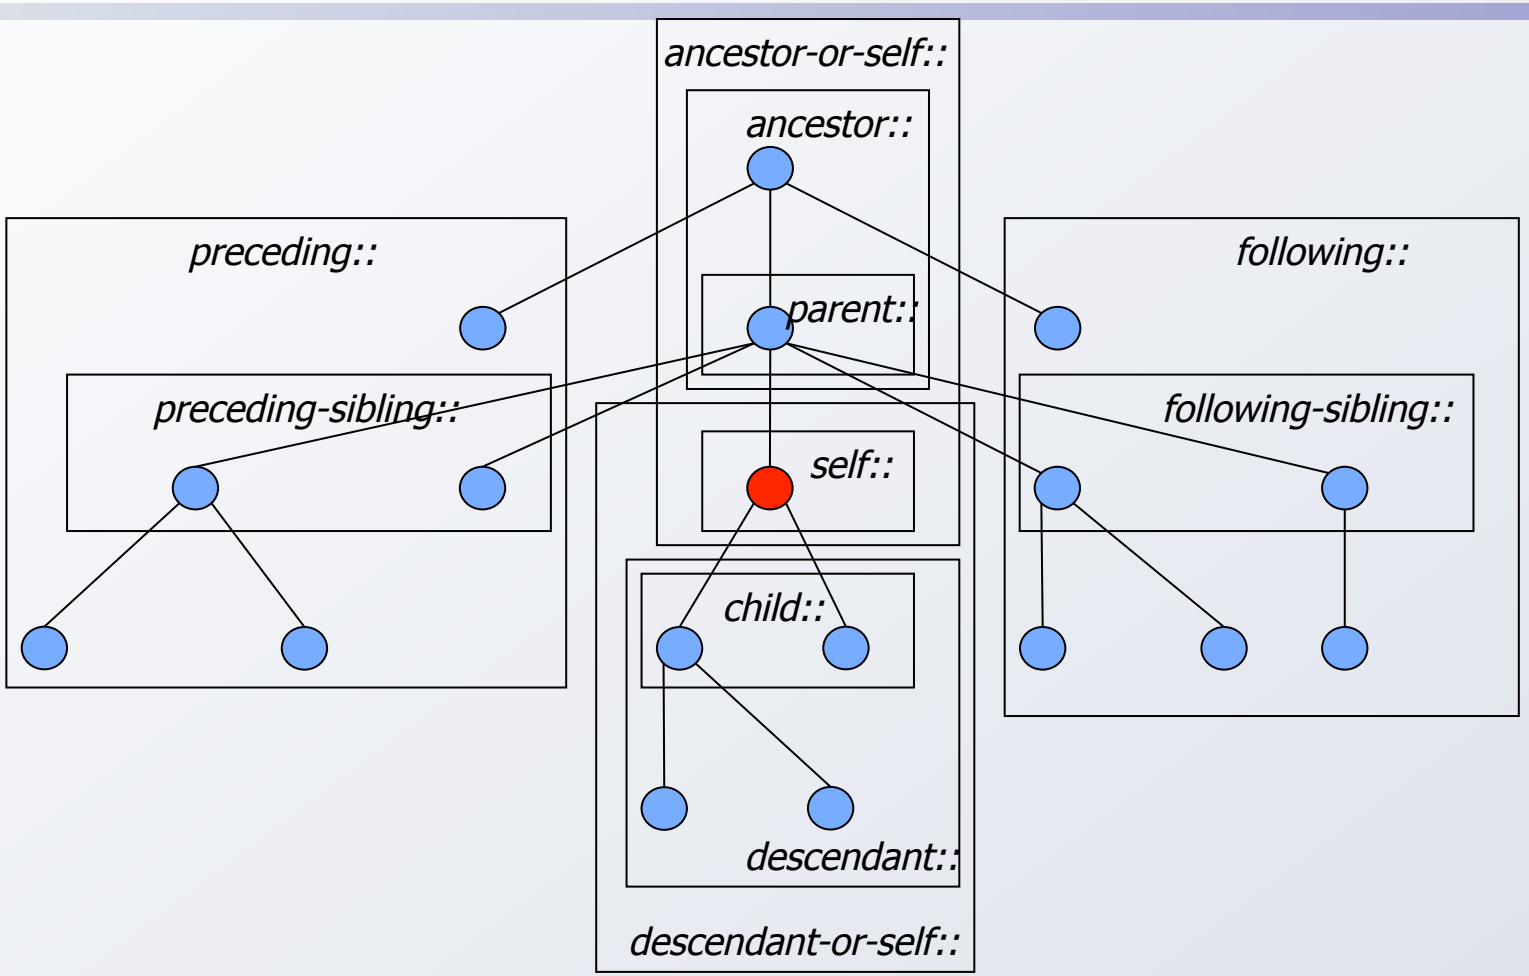

- Ausgabe erfolgt in Dokumentenordnung
  (außer bei positionalen Prädikaten, z. B. ancestor[1] liefert “parent”)
- Attribute und Namensräume sind hier weggelassen
  - Weitere (künstliche) Achse: *attribute::*

Knotentests

- Namenstest
  - Element- oder Attributname
    - child::*name* – <*name*> Elementknoten
    - child::* - alle Elementknoten
    - attribute::*name*, attribute::* - analog für Attributnamen
  - *namespace*:*name*, *namespace*:* – Beschränkung auf angegebenen Namensraum
- Knotentyptest
  - Wählen nur Knoten des entsprechenden Typs aus
    - comment()
    - text()
    - processing-instruction()
    - node() – beliebiger Knoten
    - element()
      - element(*name*)
      - element(*name, type*)

Pfadausdrücke – Beispiele

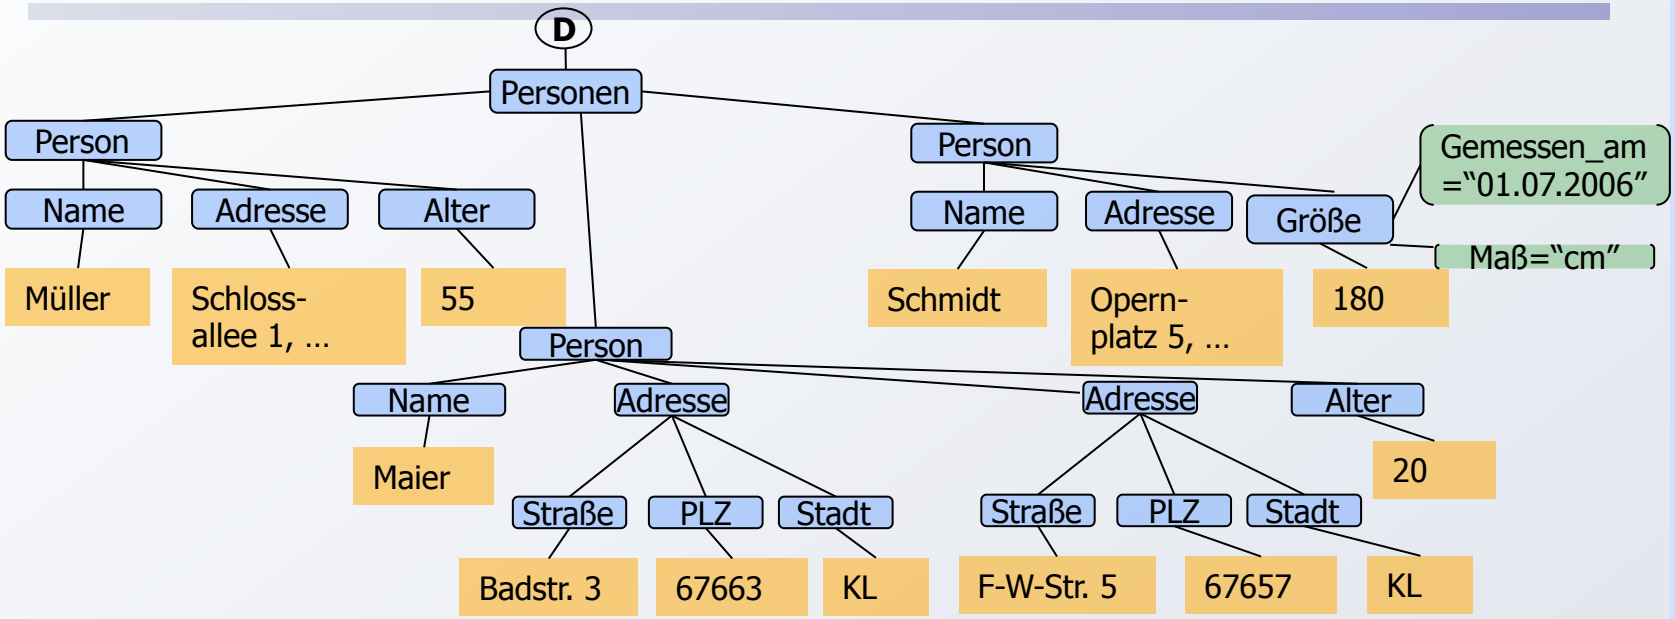

- /descendant::Person/child::Name

  <Name>Müller</Name>
  <Name>Maier</Name>
  <Name>Schmidt</Name>

- /descendant::Person/child::Name/child::text()

  Müller
  Maier
  Schmidt

- Ausgabe: Sequenz von Items (Item kann Wert oder einer von 7 verschiedenen Knotentypen sein!)

Pfadausdrücke – Beispiele (2)

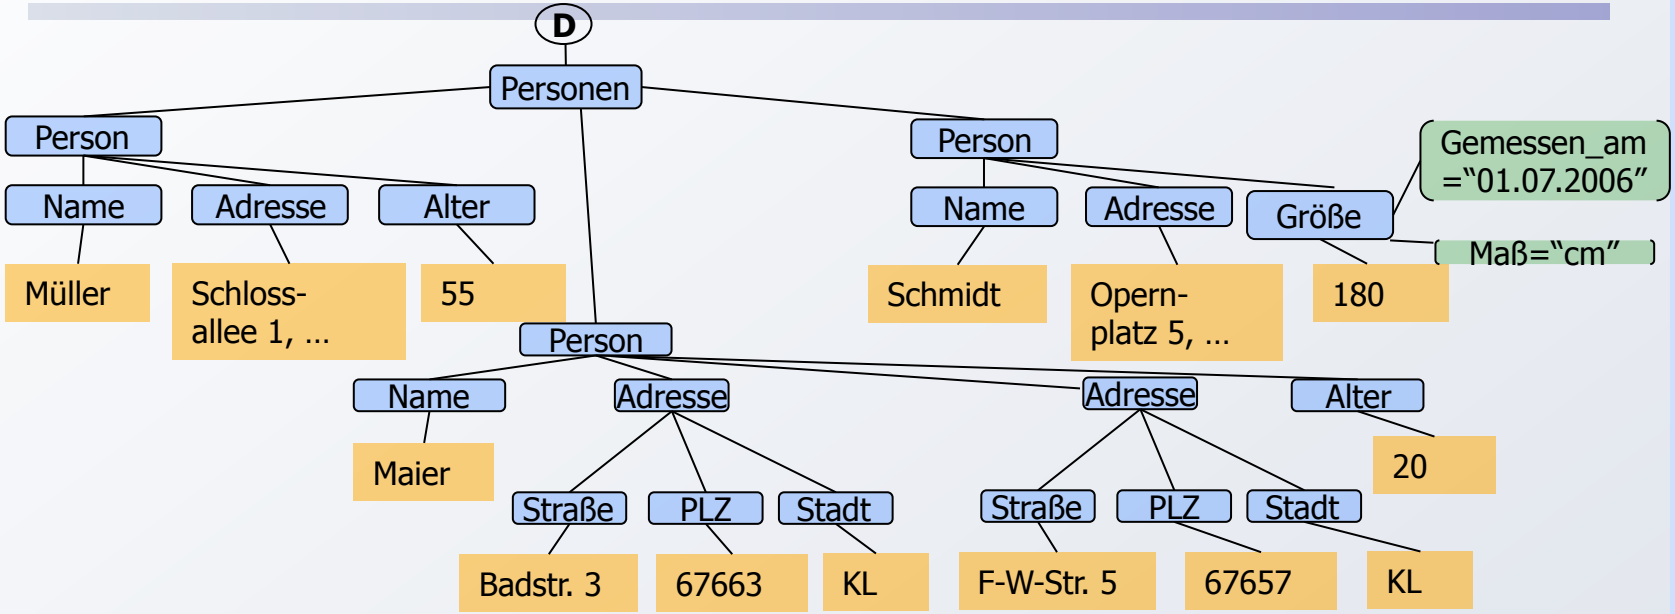

- /descendant::Person/child::Größe/attribute::Maß
  - Maß="cm"
- Was ändert sich bei (…/attribute::*)?
  - Gemessen_am="01.07.2006" Maß="cm"
- /descendant::Adresse/child::*
  - <Straße>Badstraße 3</Straße>
    <PLZ>67663</PLZ>
    <Stadt>KL</Stadt>
    <Straße>F.-W.-Straße 5</Straße>
    <PLZ>67657</PLZ>
    <Stadt>KL</Stadt>
    …
    child::* qualifiziert nur Elementknoten
- /descendant::Adresse
  - wie ändert sich die Ausgabe?

Prädikate

- Wertevergleiche (und viele Funktionen) betrachten nicht Knoten, sondern deren (getypte) Werte
  - "Atomisierung"
- Boolesche Ausdrücke
  - /descendant::Person[child::Name = "Maier"]
    - logische Konnektoren unterstützt
- Numerische Ausdrücke
  - /descendant::Person[2]
    --> liefert das zweite Personenelement
- Existenztests
  - /descendant::Person[child::Größe]
    --> Personenelemente, die ein Element „Größe" besitzen
  - /descendant::*[attribute::Maß]
    --> Elemente mit Maß-Attribut
- Nutzung von Funktionen
  - /child::Personen/child::Person[fn:position() = fn:last()]
    --> letztes Personenelement unter <Personen>

Nutzung von Funktionen

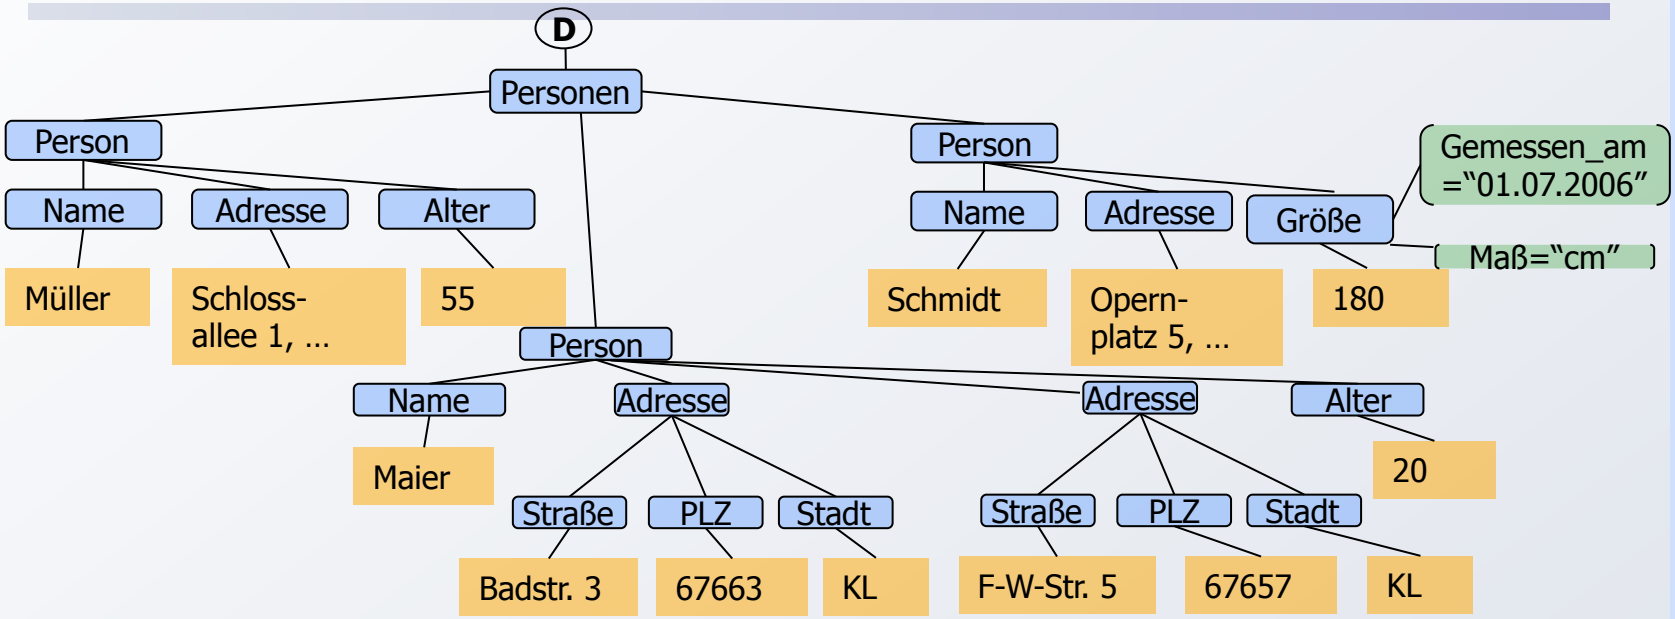

- Nutzung von Funktionen
  - /descendant::Person[child::Name="Maier"]
    /fn:string(child::Adresse[2])
    - string() liefert textuellen Wert eines Knotens

      > F.-W.-Str. 567657KL
    - string() funktioniert nur, wenn Sequenz aus einem Element besteht

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Nutzung von Funktionen (2)

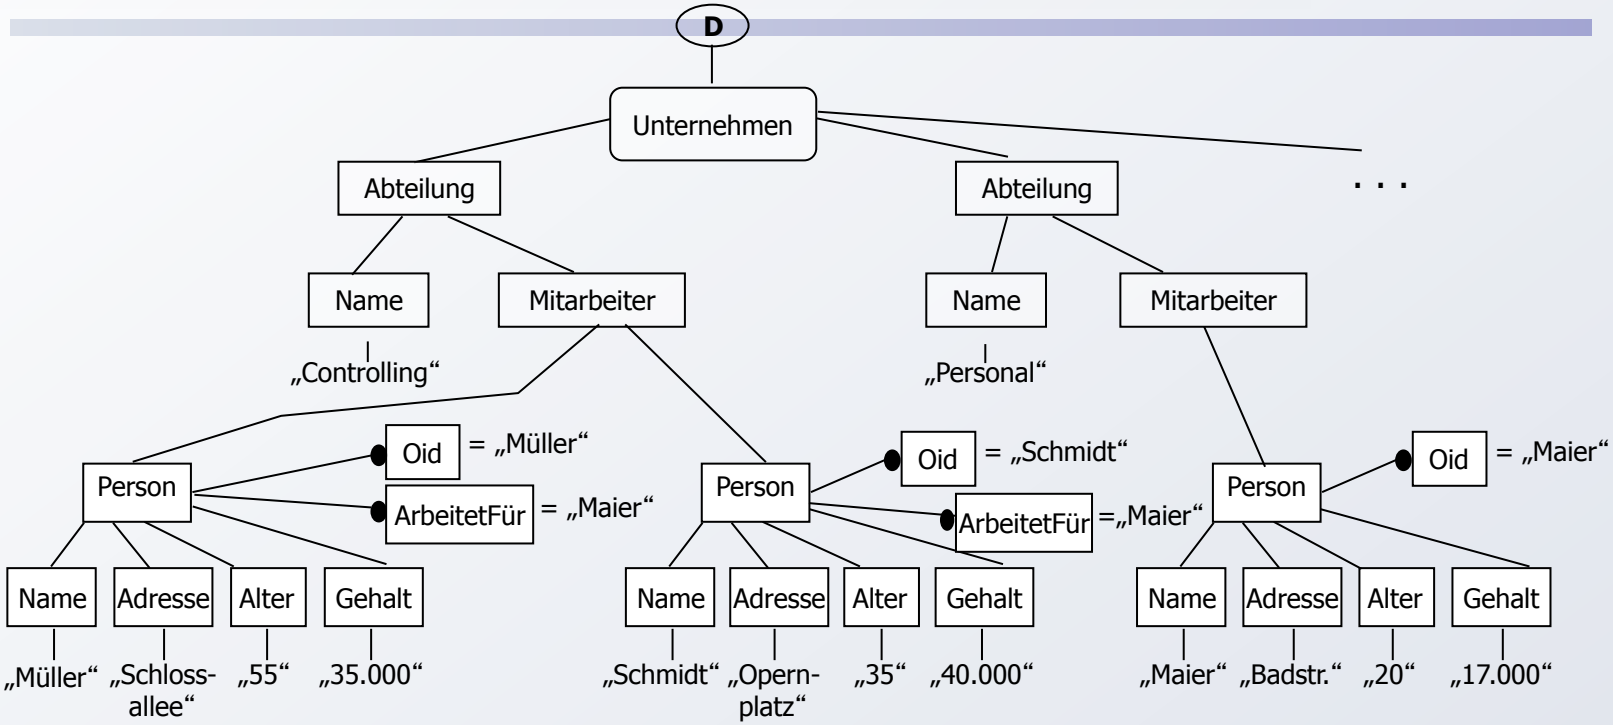

- Nutzung von Funktionen
  - /descendant::Person [fn:id(attribute::ArbeitetFür)/child::Alter < 30]/child::Name
    - Funktion id() liefert Elemente mit angegebenen ID-Wert
    - *> Namen der Personen, die für Personen jünger als 30 arbeiten*
  - /descendant::Person[child::Alter>30] /fn:id(attribute::ArbeitetFür)/child::Name
    - Verwendung von id() in Filterschritt
    - *> Name von Personen, für die Personen älter als 30 arbeiten*

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Nutzung von Funktionen (3)

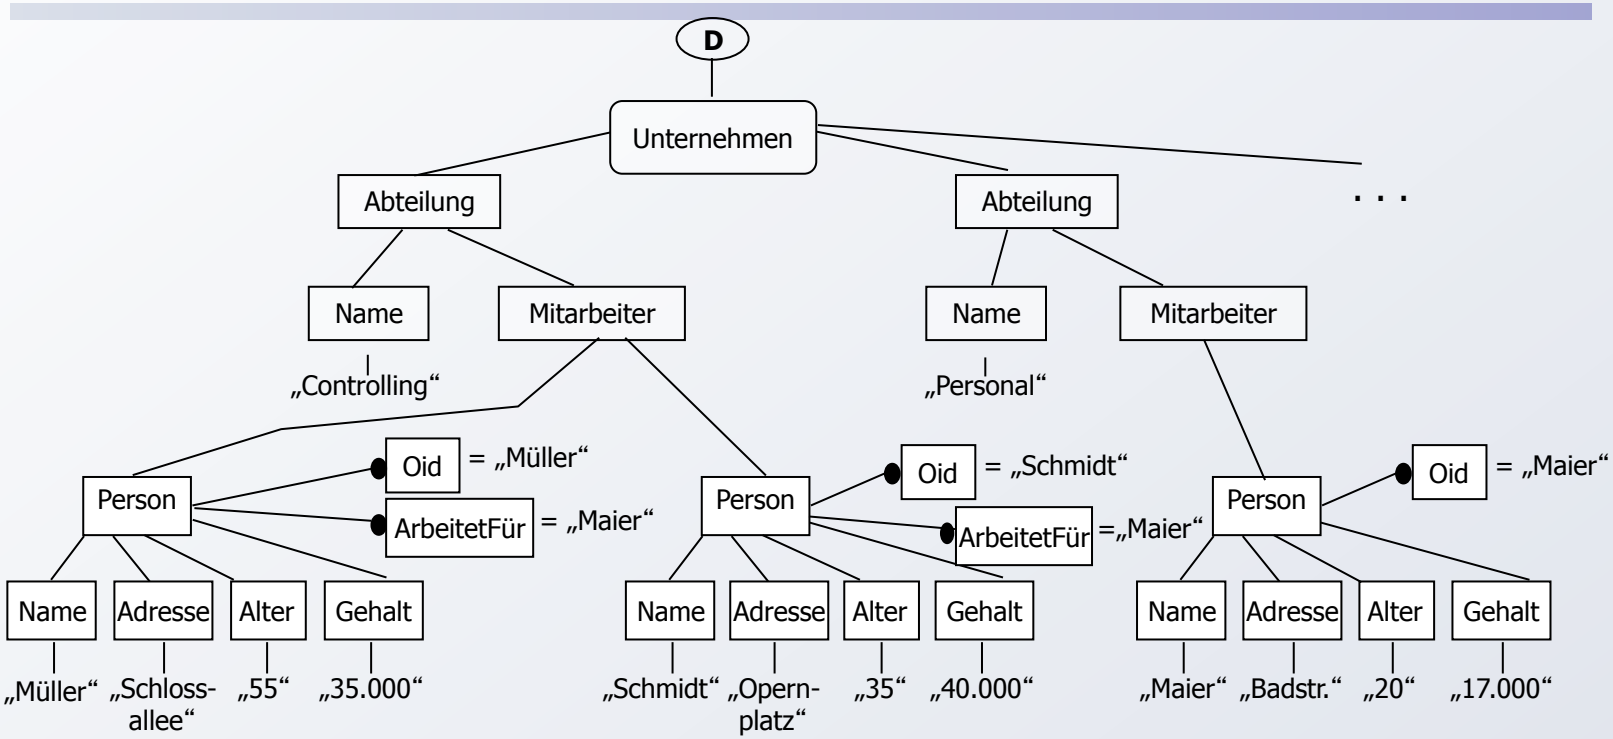

- Zugriff auf externe Dokumente
  - fn:doc(“Personen.xml”)/descendant::*
    - *> alle Elemente im angegebenen Dokument*
      - *auf beliebiger Schachtelungsebene*

  - Vorsicht: Was bedeutet „jedes Element auf jeder Ebene wird ausgegeben“?

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Verkürzte XPath-Syntax

- Verkürzte Schreibweisen für häufig genutzte Konstrukte
  - Punkt (“.”) - aktueller Referenzknoten
  - Doppelter Punkt (“..”) - parent::node()
  - “//” - /descendant-or-self::node()/
  - “@” - attribute::
  - Achse fehlt - child::
    (bzw. attribute:: bei Attributtest)
- Folgende Ausdrücke sind bspw. äquivalent
  - /descendant-or-self::Person
    [fn:id(attribute::arbeitetFür)/child::Alter < 30]/child::Name
  - //Person[fn:id(@arbeitetFür)/Alter < 30]/Name

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

XQuery – Überblick

- Pfadausdrücke sind wesentlicher Bestandteil einer XML-Anfragesprache
- Weitere Sprachkonstrukte werden benötigt
  - Konstruktion neuer XML-Objekte als Anfrageresultat
    - Bsp.: Schachtelung der durch einen Pfadausdruck lokalisierten Elemente in ein neues Element zur Ausgabe
  - Binden und Nutzen von Variablen zur Iteration über mehreren Sequenzen von Knoten
  - Verbundoperationen
  - Sortierung
  - Aggregation
  - ...
- Wesentliche zusätzliche Konzepte in XQuery
  - Konstruktoren
  - FLWOR-Ausdrücke (gespr.: *flower*)

Konstruktoren

- Nutzung der XML-Dokumentsyntax, um Dokumentfragmente zu konstruieren

```
<buch isbn = "12345">
  <titel>Huckleberry Finn</titel>
</buch>
```

- Geschweifte Klammern, um Resultate eines Anfrageausdrucks als Inhalt zu berücksichtigen

```
<buch isbn = "{$x}">
  {$b/title }
</buch>
```

  - Variablenbelegungen sind hier durch umgebenden Ausdruck vorgegeben
  - Dynamische Berechnung von Namen und Inhalten möglich.
    - element {*name-expr*} {*content-expr*}
    - attribute {*name-expr*} {*content-expr*}

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

FLWOR – Ausdrücke

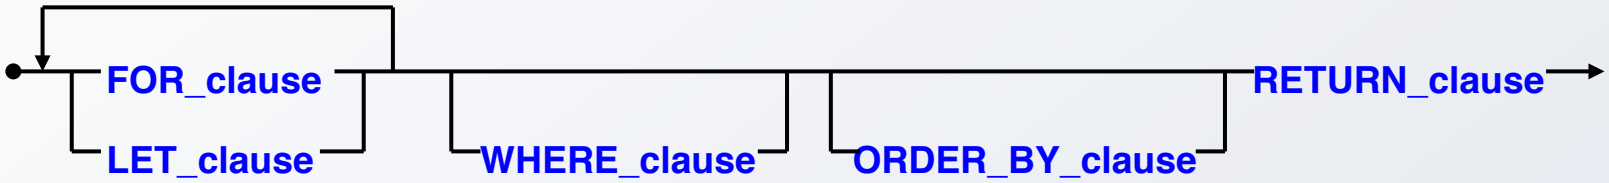

- FOR, LET binden Variablen durch
  - Iteration über eine Sequenz von Knoten (FOR)
  - Auswertung eines Ausdrucks (LET): Ausdruck liefert Sequenz von Items, welche an Variable gebunden wird
- WHERE ermöglicht Selektion von Variablenbelegungen aufgrund von Prädikaten
- ORDER BY erlaubt Sortieren von Inhalten
- RETURN generiert Resultat des Ausdrucks anhand der Variablenbelegungen
- Vergleichbar mit folgenden Konzepten in SQL:
  for ⇔ SQL from
  where ⇔ SQL where
  order by ⇔ SQL order by
  return ⇔ SQL select
  let hat keine Entsprechung

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Auswertung von FLWOR-Ausdrücken

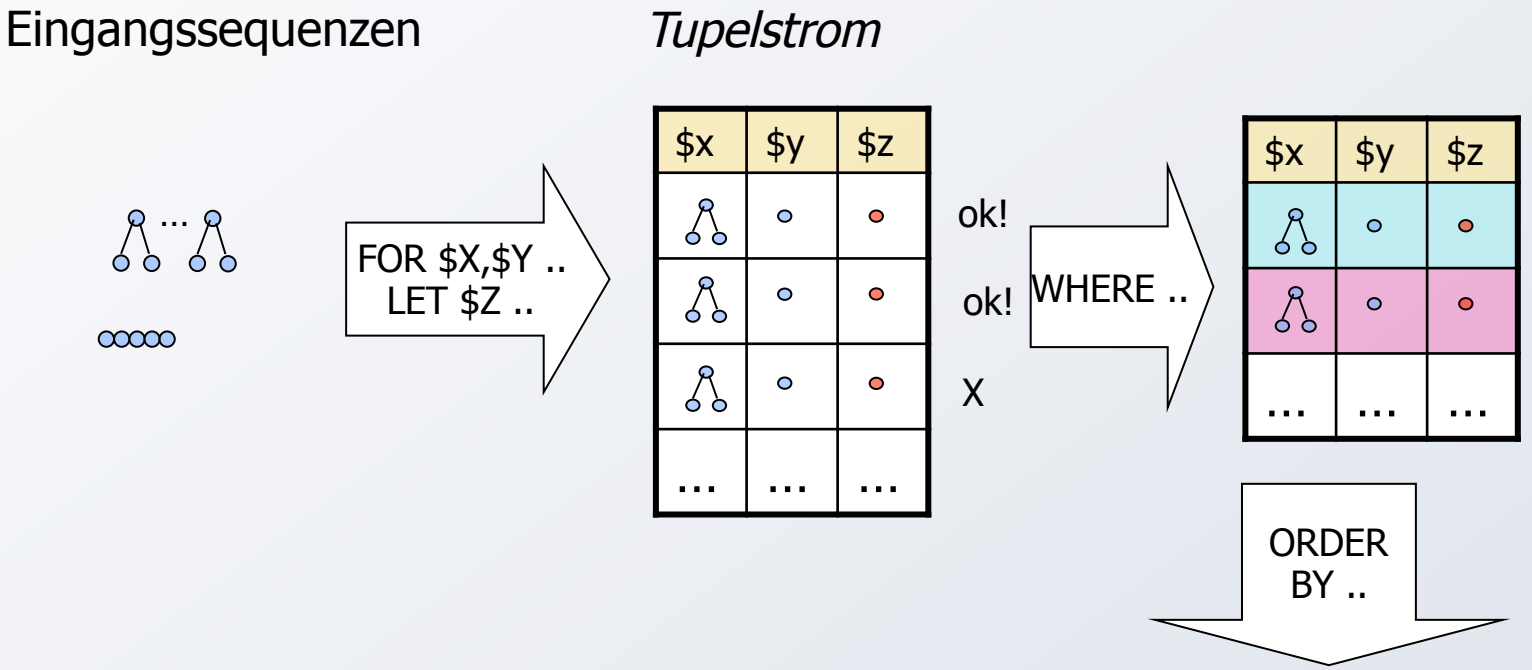

FLWOR – Beispiel

- Suche alle Personen (Name, Alter) jünger als 25
  - Variablen beginnen mit "$"-Präfix
  - Anfrage ohne LET, WHERE:
    - for $p in //Person[Alter < 25]
      order by $p/Name
      return <jungePerson> {$p/Name, $p/Alter} </jungePerson>
  - Einfache (äquivalente) FLWOR-Ausdrücke
    (siehe Auswertungsbeispiel 1: Sequenzen Name und Alter bestehen in allen Fällen nur aus einem Element)
    - for $p in //Person
      let $n := $p/Name, $a := $p/Alter
      where $a < 25
      order by $n
      return <jungePerson> {$n, $a } </jungePerson>
    - for $p in //Person[Alter < 25]
      let $n := $p/Name, $a := $p/Alter
      order by $n
      return <jungePerson> {$n, $a } </jungePerson>

Auswertungsbeispiel 1 – FLWOR-Ausdruck

```
for     $p in //Person
let     $n := $p/Name, $a := $p/Alter
where   $a < 25
order by $n
return <jungePerson>
          {$n, $a }
       </jungePerson>
```

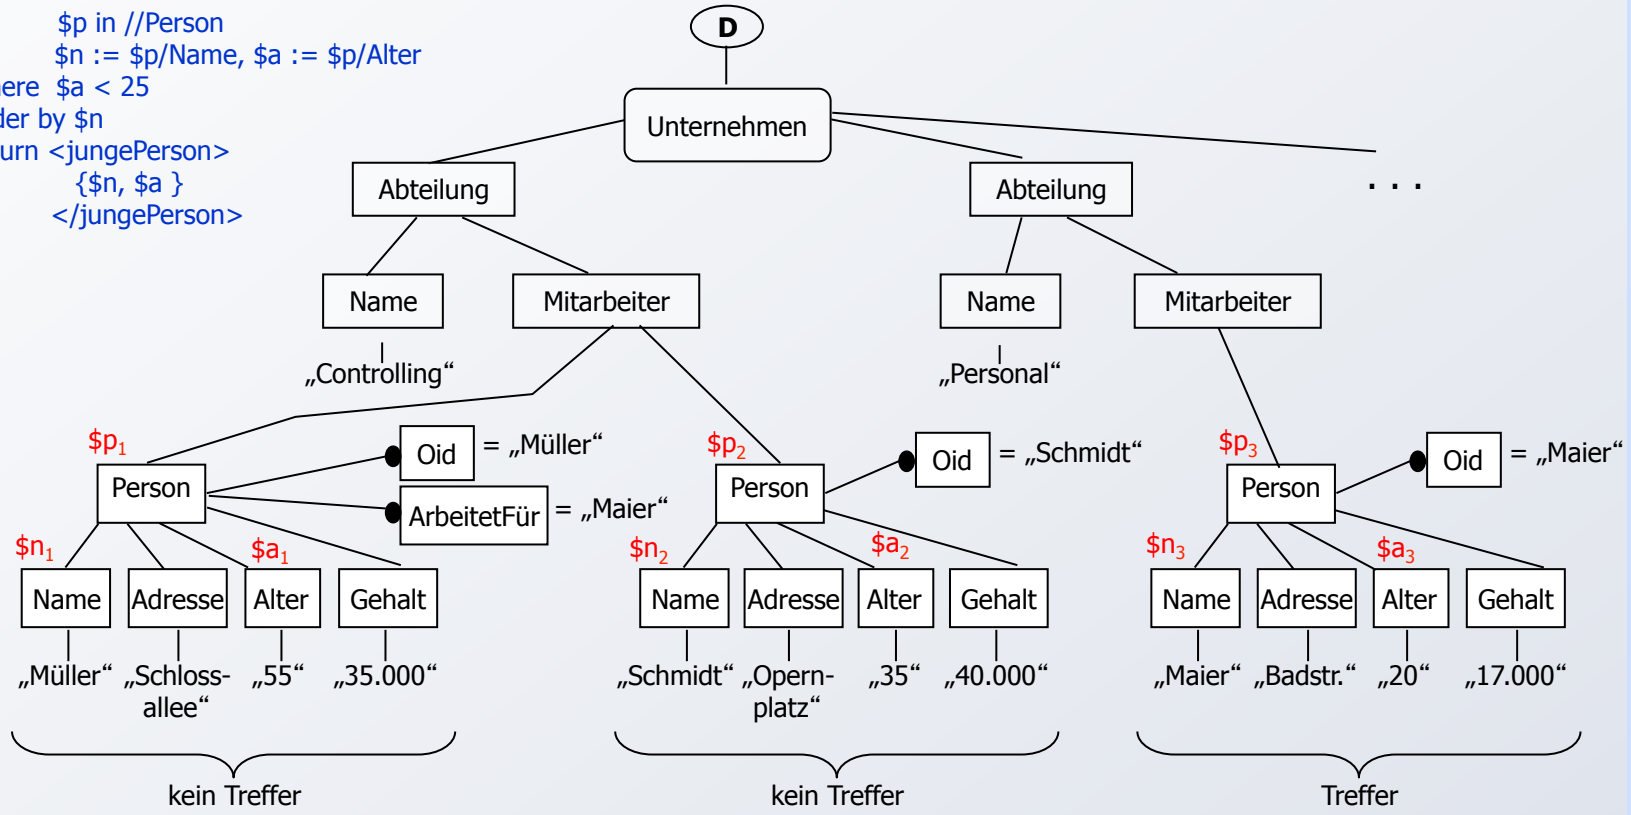

1) $p iteriert über alle „Person“-Elemente und bindet jeweils die Kinder „Name“ und „Alter“ an $n bzw. $a.
2) Bei jedem Iterationsschritt wird überprüft, ob „where“-Bedingung zutrifft
3) Treffer werden in einer Sequenz gespeichert und nach $n (Namen) sortiert
4) Ausgabe wird generiert

Ausgabe

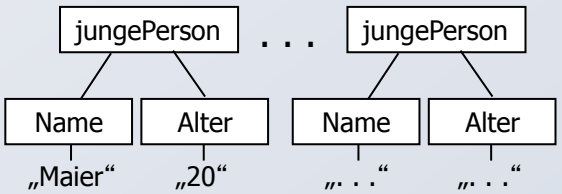

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Let-Klausel

- Erleichtert Sequenz-Auswertung

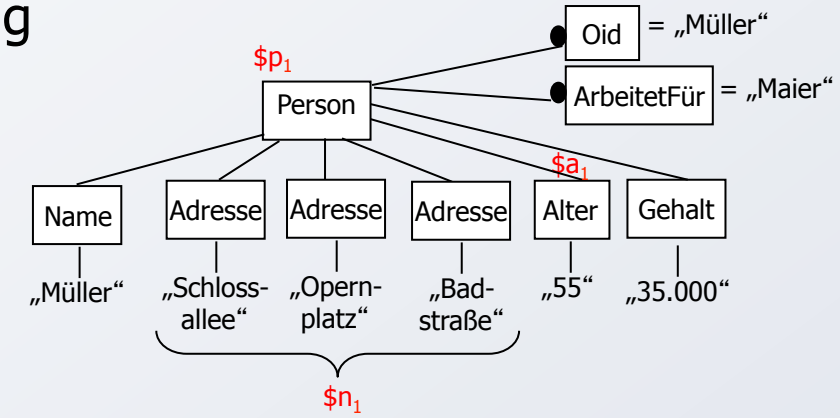

- for $p in //Person
  let $n := $p/Adresse,
  $a := $p/Alter
  where fn:count($n) > 2
  return . . .

- for $p in //Person
  let $n := $p/Adresse,
  $a := $p/Alter
  where $n = „Badstraße“
  return . . .

- for $p in //Person
  let $n := $p/Adresse,
  $a := $p/Alter
  where $n EQ „Badstraße“
  return . . .

- for $p in //Person
  let $n := $p/Adresse,
  $a := $p/Alter
  where $a < 25
  return . . .

Verbundoperationen

- Verfolgung von Referenzen

```
for $p in //Person[@ArbeitetFür]
let $chef := fn:id($p/@ArbeitetFür)
return
  <arbeitetFür>
            <person> {$p/Name} </person>
            <chef> {$chef/Name}  </chef>
  </arbeitetFür>
```

- Symmetrischer Verbund

```
for $p in //Person, $chef in //Person
where $p/@ArbeitetFür = $p/@Oid
return
  <arbeitetFür>
            <person> {$p/Name} </person>
            <chef> {$chef/Name}  </chef>
  </arbeitetFür>
```

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Auswertungsbeispiel 2 – Verfolgung von Referenzen

```
for $p in //Person[@ArbeitetFür]
let $chef := fn:id($p/@ArbeitetFür)
return
  <arbeitetFür>
    <person> {$p/Name} </person>
    <chef> {$chef/Name}  </chef>
  </arbeitetFür>
```

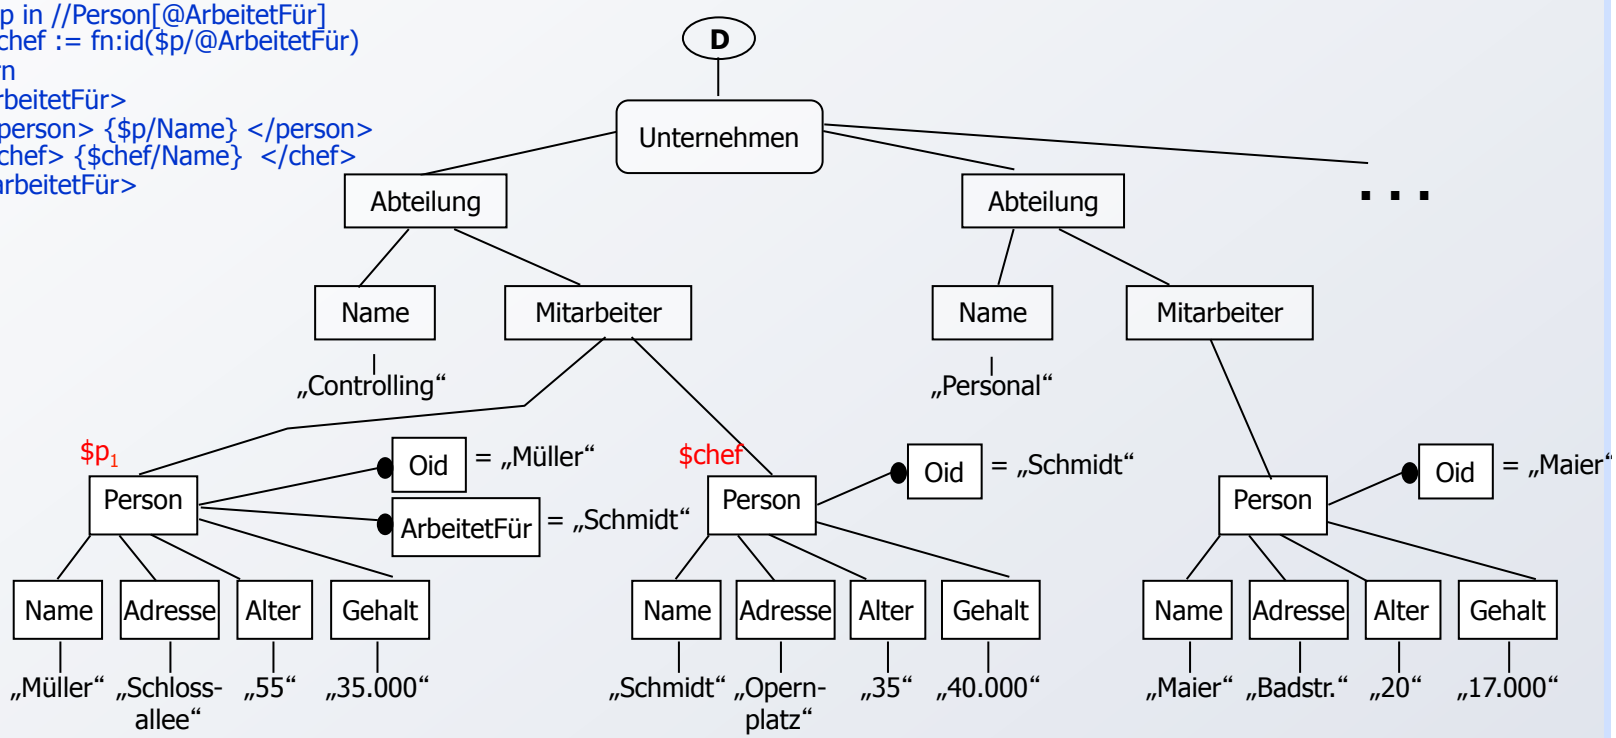

Funktion fn:id() verfolgt ID-Referenzen IDREF und liefert alle XML-Elemente zurück, deren ID-Attribut den referenzierten Wert besitzen. (Attr. vom Typ ID/IDREF müssen im XML-Schema bekannt gegeben werden)

1) $p wird im dargestellten XML-Fragment nur 1x gebunden (an Person Müller), da nur diese Person ein „ArbeitetFür“-ID-Attr. hat
2) für $p wird $chef an die Person „Schmidt“ gebunden
3) Ausgabe wird erzeugt

Ausgabe

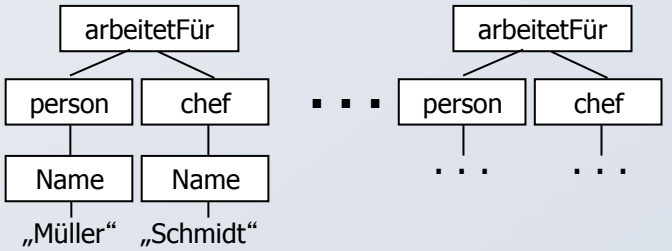

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Auswertungsbeispiel 3 – Symmetrischer Verbund

```
for $p in //Person, $chef in //Person
where $p/@ArbeitetFür = $p/@Oid
return
  <arbeitetFür>
    <person> {$p/Name} </person>
    <chef> {$chef/Name}  </chef>
  </arbeitetFür>
```

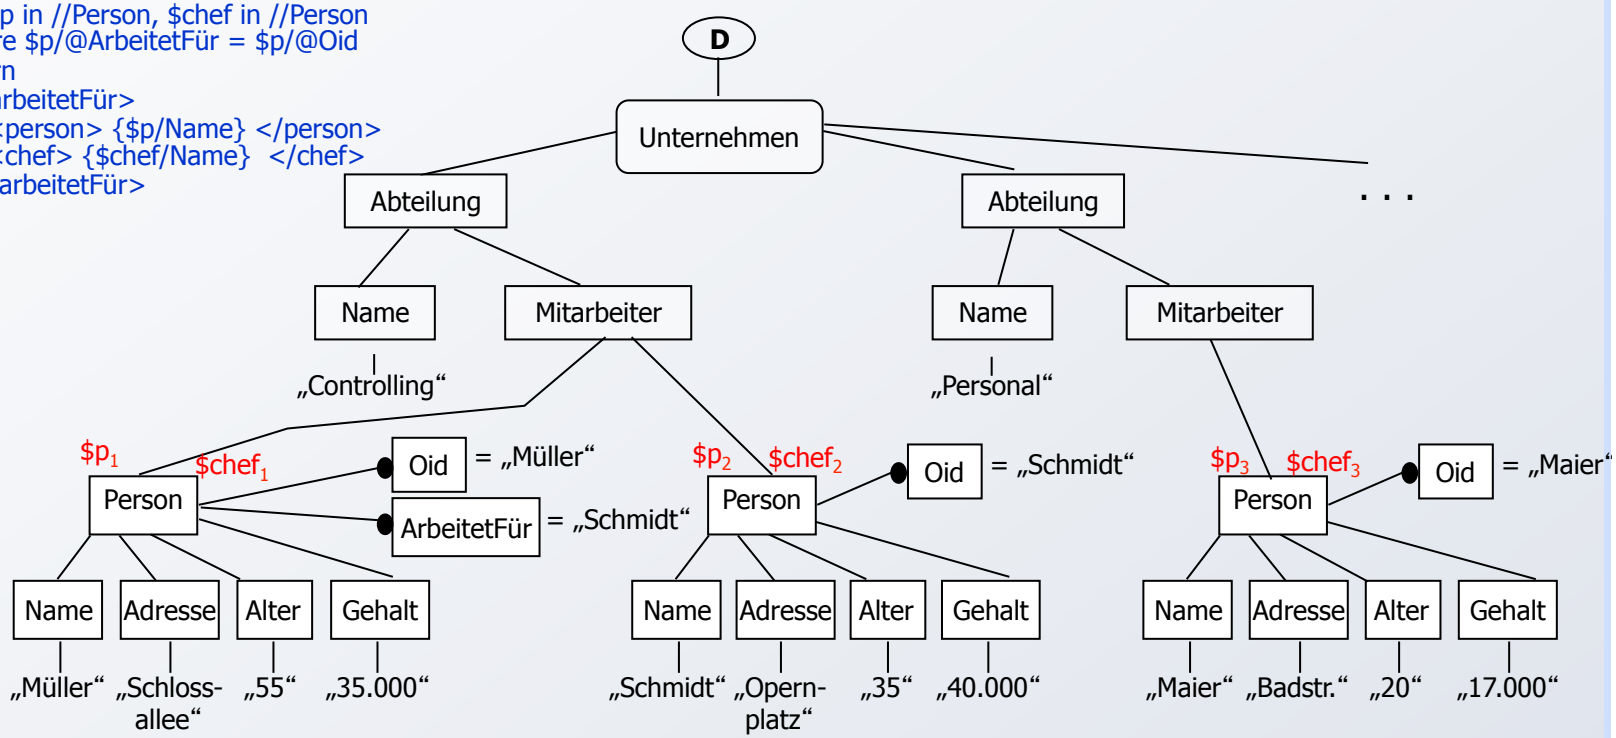

1) Ausdruck in der for-Klausel ergibt klassischen Nested-Loops-Verbund, wobei jeweils $p an der äußeren Verbundpartner und $chef an den inneren Verbundpartner gebunden wird.

2) Für solche ($p, $chef)-Paare, für die die where-Bedingung gilt, wird eine Ausgabe erzeugt.

Ausgabe

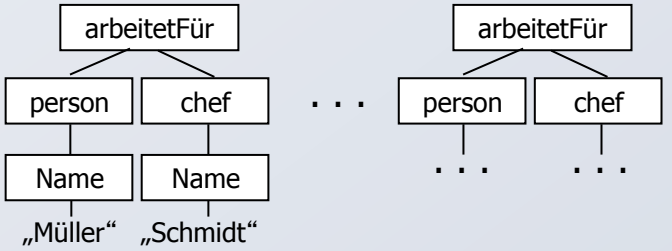

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Left Outer Join

- Beispiel: Liste alle Personen mit Namen und Chef (falls vorhanden)
  - for $p in //Person
    return
      <person>
        { $p/Name,
          for $chef in fn:id($p/@ArbeitetFür)
          return <chef> {$chef/Name} </chef> }
      </person>

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Auswertungsbeispiel 4 – Left Outer Join

```
for $p in //Person
return
 <person>
   { $p/Name,
     for $chef in fn:id($p/@ArbeitetFür)
     return <chef> {$chef/Name}
     </chef>}
 </person>
```

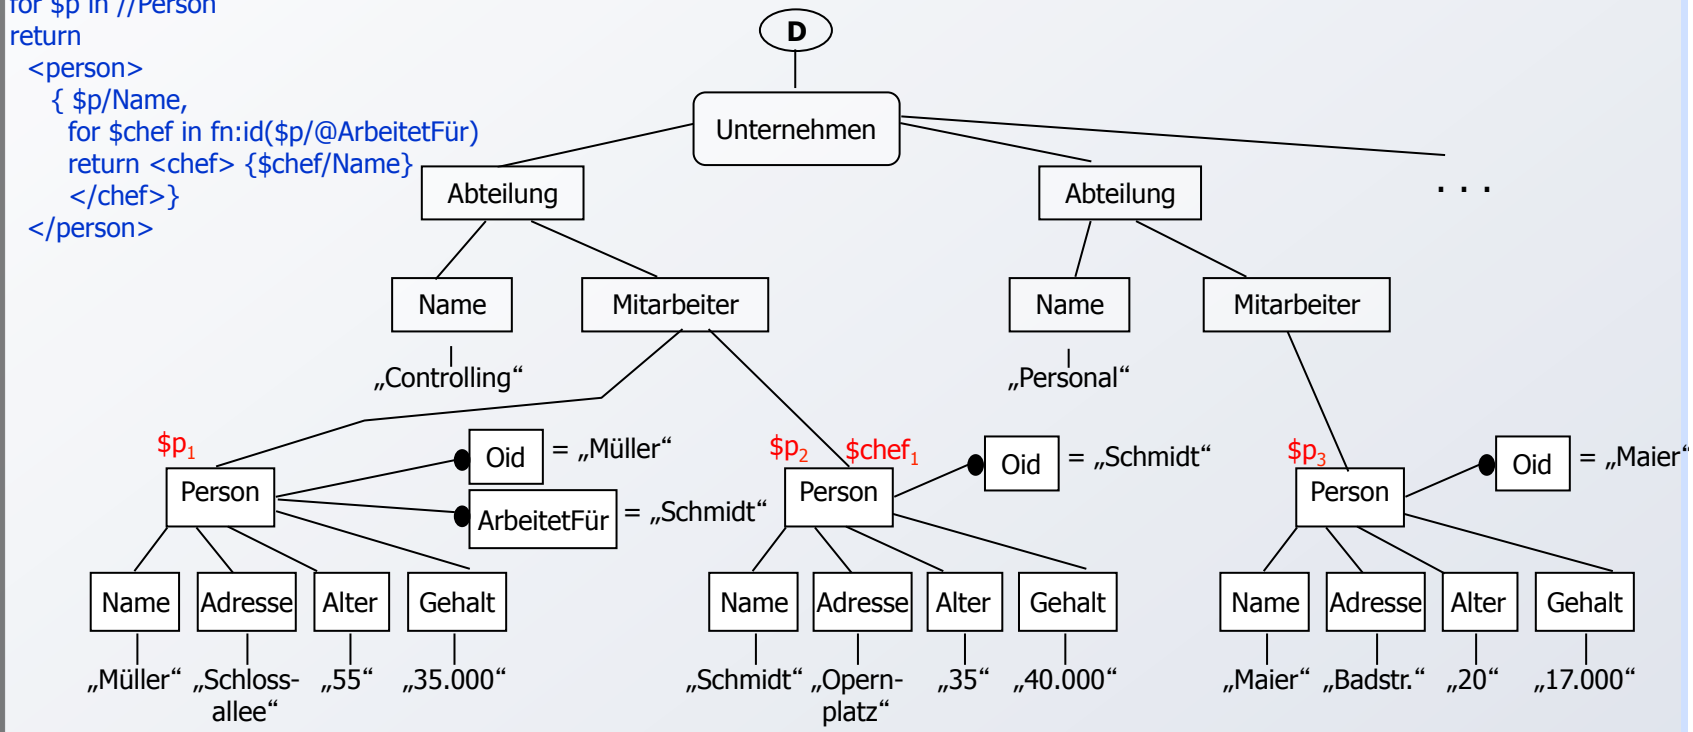

1) Iteration über alle Personen, Binden von $p

2) Für jede Person wird ein Element „Person“ erzeugt, welches das Element „Name“ der Person enthält

3) Falls eine Person ein Attribut „ArbeitetFür“ enthält, wird mit Hilfe der fn:id()-Funktion das „Person“-Element des Chefs an $chef gebunden und dessen Name innerhalb eines „Chef“-Elements ausgegeben (passiert im dargestellten Fragment nur 1x)

Ausgabe

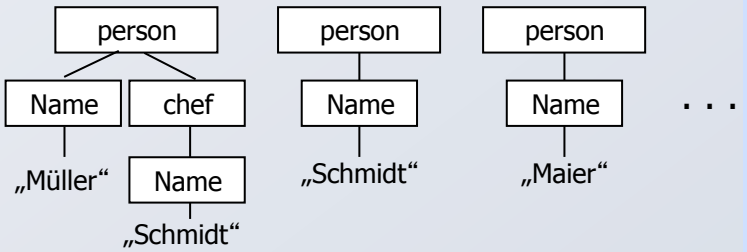

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Geschachtelte FLWOR-Ausdrücke

```
for $p in fn:distinct-values(//Person)
order by $p/Name
return
  <person>
        <name> $p/Name/text() </name>
        { for $a in //Abteilung[.//Person = $p])
          return <abteilung> $a/Name </abteilung>}
  </person>
```

```
<Abteilung>
  <Name>…</Name>
   <Mitarbeiter>
     <Person>…<Person>
     <Person>…</Person>
   </Mitarbeiter>
</Abteilung>
<Abteilung>
   <Name>
      ...
</Abteilung>
```



```
<person>
  <name>…</name>
  <abteilung>…</abteilung>
</person>
      .
      .
      .
```

Ausgabe:

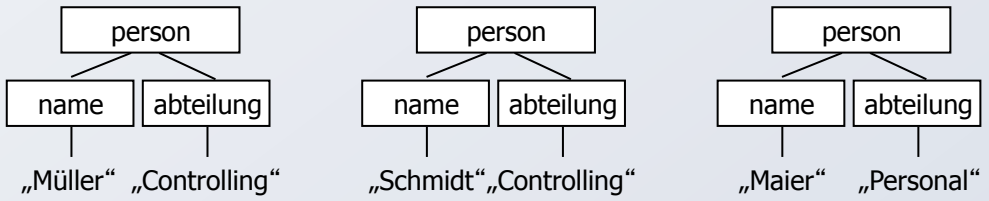

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Sortierung & Schachtelung

- Suche alle Ableitungen, sortiert nach Name; liste alle Mitarbeiter absteigend nach Gehalt

```
<abteilungen>
 { for $a in //Abteilung
   order by $a/Name
   return <abteilung>
            <name> $a/Name/text() </name>
             { for $p in $a//Person
               order by $p/Gehalt descending
               return <person>
                        {$p/Name}
                        {$p/Gehalt}
                      </person>
             }
          </abteilung>
 }
</abteilungen>
```

Ausgabe:

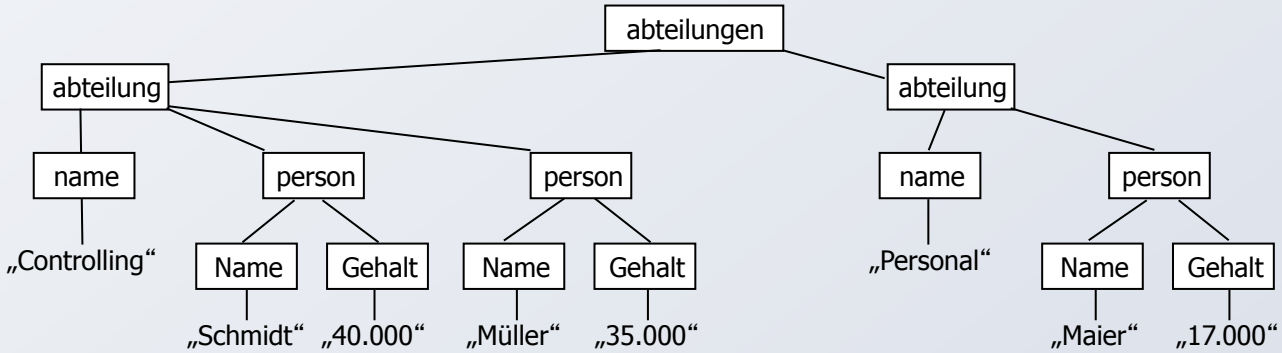

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Gruppierung und Aggregation

- entlang einer XML-Hierarchie

```
for $a in //Abteilung
let $g := $a//Person/Gehalt
return
        <abteilung>
           {$a/Name}
           <d-Gehalt> {fn:avg($g)} </d-Gehalt>
        </abteilung>
```

- aufgrund von Werten

```
for $j in fn:distinct-values(//Person/Einstell-Jahr)
let $g := //Person[Einstell-Jahr = $j]/Gehalt
return <d-Gehalt> {$j}
            <betrag> {fn:avg($g)}/</betrag>
        </d-Gehalt>
```

Ausgaben:

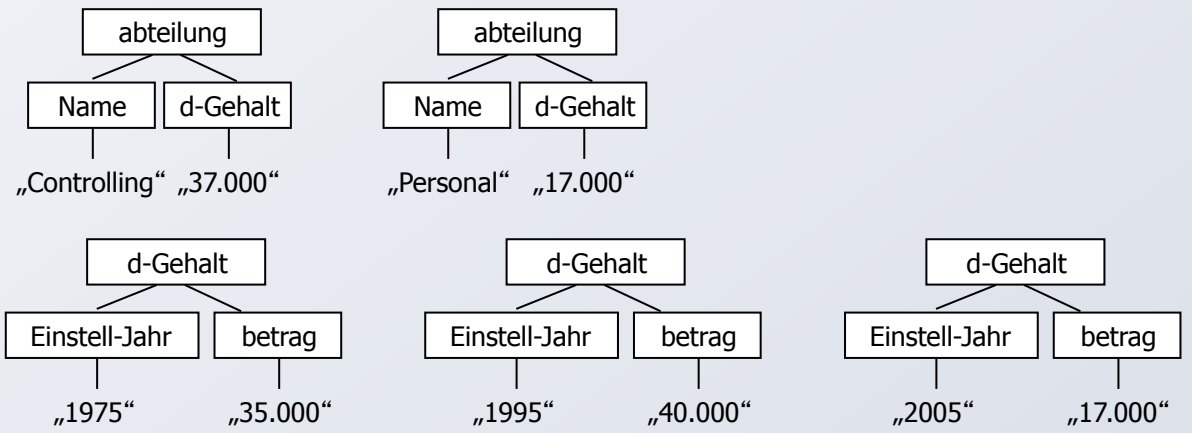

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Zusätzliche Funktionalität

- Ausdrücke
  - arithmetische und konditionale Ausdrücke
  - Mengenoperationen
  - quantifizierte Ausdrücke
  - Typumwandlung
- Funktionen
  - Definition und Nutzung
- Anfrageverarbeitungsmodell
  - Statische Analyse und dynamische Evaluierung
  - Nutzung von Typinformation
- ...

Semistrukturierte Daten
XML-Einführung
Vergleich XML<-> RM
Schemadefinition
XPath-Prädikate
XQuery-Anfragen

Zusammenfassung

- Semistrukturierte Daten
  - selbstbeschreibend (Integration von Schema und Daten)
- XML
  - Meta-Sprache zur Beschreibung von Dokumenten
    - Struktur und Inhalt
    - wohlgeformtes (*well-formed*) XML
  - Dokumentorientiert vs. Datenorientierte Sicht
- Schemadefinition für XML Dokumente
  - DTDs
    - rudimentäre, struktur-orientierte Schemata
  - XML Schema
    - unterstützte effektivere Datenmodellierung mit XML
- Anfrageverarbeitung mit XML
  - Pfadausdrücke (XPath)
    - wichtiges Konzept zur flexiblen Lokalisierung von Knoten in XML-Bäumen
  - XQuery
    - komplexe Anfragen und Transformationen auf XML-Daten/Dokumenten