Kapitel 15

Objektorientierte Datenbanken

Relationale Datenbanksysteme sind derzeit in administrativen Anwendungsbereichen marktbeherrschend, da sich die sehr einfache Strukturierung der Daten in flachen Tabellen als recht benutzerfreundlich erwiesen hat. Unzulänglichkeiten traten jedoch zutage bei komplexeren, ingenieurwissenschaftlichen Anwendungen, z.B. in den Bereichen CAD, Architektur und Multimedia.

Daraus ergaben sich zwei unterschiedliche Ansätze der Weiterentwicklung:

- Der *evolutionäre* Ansatz: Das relationale Modell wird um komplexe Typen erweitert zum sogenannten *geschachtelten* relationalen Modell.
- Der *revolutionäre* Ansatz: In Analogie zur Objektorientierten Programmierung wird in einem Objekttyp die *strukturelle* Information zusammen mit der *verhaltensmäßigen* Information integriert.

15.1 Schwächen relationaler Systeme

Die Relation

$$\text{Buch} \quad : \quad \{[\ \underline{\text{ISBN}}, \text{Verlag}, \text{Titel}, \text{Autor}, \text{Version}, \text{Stichwort}]\}$$

erfordert bei 2 Autoren, 5 Versionen, 6 Stichworten für jedes Buch $2 \times 5 \times 6 = 60$ Einträge.

Eine Aufsplittung auf mehrere Tabellen ergibt

$$\begin{aligned} \text{Buch} &: \{[\ \underline{\text{ISBN}}, \text{Titel}, \text{Verlag}\ ]\} \\ \text{Autor} &: \{[\ \underline{\text{ISBN}}, \text{Name}, \text{Vorname}\ ]\} \\ \text{Version} &: \{[\ \underline{\text{ISBN}}, \text{Auflage}, \text{Jahr}\ ]\} \\ \text{Stichwort} &: \{[\ \underline{\text{ISBN}}, \text{Stichwort}\ ]\} \end{aligned}$$

Nun sind die Informationen zu einem Buch auf vier Tabellen verteilt. Beim Einfügen eines neuen Buches muß mehrmals dieselbe ISBN eingegeben werden. Die referentielle Integrität

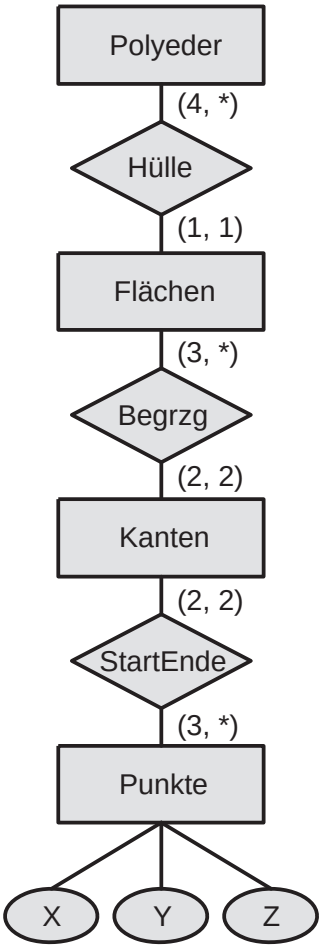

(a) ER-Diagramm

Polyeder

PolyID	Gewicht	Material	...
cubo#5	25.765	Eisen	...
tetra#7	37.985	Glas	...
...	...	...	...

Flächen

FlächenID	PolyID	Oberflächen
f1	cubo#5	...
f2	cubo#5	...
...	...	...
f6	cubo#5	...
f7	tetra#7	...

Kanten

KantenID	F1	F2	P1	P2
k1	f1	f4	p1	p4
k2	f1	f2	p2	p3
...	...	...	...	...

Punkte

PunktId	X	Y	Z
p1	0.0	0.0	0.0
p2	1.0	0.0	0.0
...	...	...	...
p8	0.0	1.0	1.0
...	...	...	...

(b) Relationales Schema

Abbildung 15.1: Modellierung von Polyedern

muß selbst überwacht werden. Eine Query der Form "*Liste Bücher mit den Autoren Meier und Schmidt*" ist nur sehr umständlich zu formulieren.

Abbildung 15.1a zeigt die Modellierung von Polyedern nach dem Begrenzungsflächenmodell, d. h. ein Polyeder wird beschrieben durch seine begrenzenden Flächen, diese wiederum durch ihre beteiligten Kanten und diese wiederum durch ihre beiden Eckpunkte. Abbildung 15.1b zeigt eine mögliche Umsetzung in ein relationales Schema, wobei die Beziehungen *Hülle, Begrzg* und *StartEnde* aufgrund der Kardinalitäten in die Entity-Typen integriert wurden.

Die relationale Modellierung hat etliche Schwachpunkte:

- **Segmentierung:** Ein Anwendungsobjekt wird über mehrere Relationen verteilt, die immer wieder durch einen Verbund zusammengefügt werden müssen.

- **Künstliche Schlüsselattribute:** Zur Identifikation von Tupeln müssen vom Benutzer relationenweit eindeutige Schlüssel vergeben werden.

- **Fehlendes Verhalten:** Das anwendungsspezifische Verhalten von Objekten, z.B. die Rotation eines Polyeders, findet im relationalen Schema keine Berücksichtigung.

- **Externe Programmierschnittstelle:** Die Manipulation von Objekten erfordert eine Programmierschnittstelle in Form einer Einbettung der (mengenorientierten) Datenbanksprache in eine (satzorientierte) Programmiersprache.

15.2 Vorteile der objektorientierten Modellierung

In einem objektorientierten Datenbanksystem werden *Verhaltens*- und *Struktur*-Beschreibungen in einem Objekt-Typ integriert. Das anwendungsspezifische Verhalten wird integraler Bestandteil der Datenbank. Dadurch können die umständlichen Transformationen zwischen Datenbank und Programmiersprache vermieden werden. Vielmehr sind die den Objekten zugeordneten Operationen direkt ausführbar, ohne detallierte Kenntnis der strukturellen Repräsentation der Objekte. Dies wird durch das *Geheimnisprinzip* (engl.: *information hiding*) unterstützt, wonach an der Schnittstelle des Objekttyps eine Kollektion von Operatoren angeboten wird, für deren Ausführung man lediglich die *Signatur* (Aufrufstruktur) kennen muß.

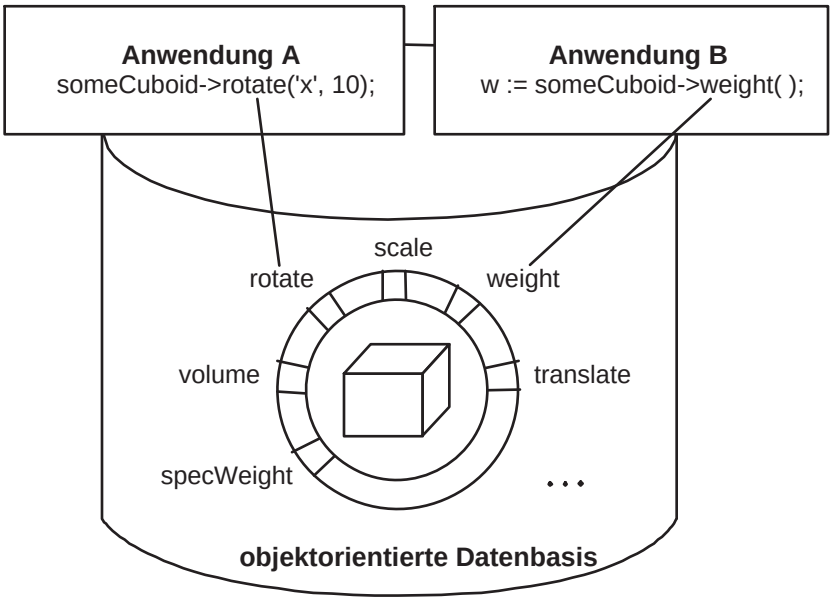

Abbildung 15.2: Visualisierung der Vorteile der objektorientierten Datenmodellierung

Abbildung 15.2 visualisiert den objektorientierten Ansatz bei der Datenmodellierung. Ein Quader wird zusammen mit einer Reihe von Datenfeldern und Operatoren zur Verfügung gestellt. Unter Verwendung dieser Schnittstelle rotiert Anwendung A einen Quader und bestimmt Anwendung B das Gewicht.

15.3 Der ODMG-Standard

Im Gegensatz zum relationalen Modell ist die Standardisierung bei objektorientierten Datenbanksystemen noch nicht so weit fortgeschritten. Ein (de-facto) Standard wurde von der *Object Database Management Group* entworfen. Das ODMG-Modell umfaßt das objektorientierte Datenbanksystem und eine einheitliche Anbindung an bestehende Programmiersprachen. Bisher wurden Schnittstellen für C++ und Smalltalk vorgesehen. Außerdem wurde eine an SQL angelehnte deklarative Abfragesprache namens *OQL* (Object Query Language) entworfen.

15.4 Eigenschaften von Objekten

Im relationalen Modell werden Entitäten durch Tupel dargestellt, die aus atomaren *Literalen* bestehen.

Im objektorientierten Modell hat ein Objekt drei Bestandteile:

- **Identität:** Jedes Objekt hat eine systemweit eindeutige Objektidentität, die sich während seiner Lebenszeit nicht verändert.
- **Typ:** Der Objekttyp, auch *Klasse* genannt, legt die Struktur und das Verhalten des Objekts fest. Individuelle Objekte werden durch die *Instanziierung* eines Objekttyps erzeugt und heißen *Instanzen*. Die Menge aller Objekte (Instanzen) eines Typs wird als (Typ-)*Extension* (eng. *extent*) bezeichnet.
- **Wert** bzw. **Zustand:** Ein Objekt hat zu jedem Zeitpunkt seiner Lebenszeit einen bestimmten Zustand, auch Wert genannt, der sich aus der momentanen Ausprägung seiner Attribute ergibt.

Abbildung 15.3 zeigt einige Objekte aus der Universitätswelt. Dabei wird zum Beispiel der Identifikator id_1 als Wert des Attributs *gelesenVon* in der Vorlesung mit dem Titel *Grundzüge* verwendet, um auf die Person mit dem Namen *Kant* zu verweisen. Wertebereiche bestehen nicht nur aus atomaren Literalen, sondern auch aus Mengen. Zum Beispiel liest *Kant* zwei Vorlesungen, identifiziert durch id_2 und id_3.

Im relationalen Modell wurden Tupel anhand der Werte der Schlüsselattribute identifiziert (*identity through content*). Dieser Ansatz hat verschiedene Nachteile:

- Objekte mit gleichem Wert müssen nicht unbedingt identisch sein. Zum Beispiel könnte es zwei Studenten mit Namen "*Willy Wacker*" im 3. Semester geben.
- Aus diesem Grund müssen künstliche Schlüsselattribute ohne Anwendungsemantik (siehe Polyedermodellierung) eingeführt werden.
- Schlüssel dürfen während der Lebenszeit eines Objekts nicht verändert werden, da ansonsten alle Bezugnahmen auf das Objekt ungültig werden.

In Programmiersprachen wie Pascal oder C verwendet man Zeiger, um Objekte zu referenzieren. Dies ist für kurzlebige (transiente) Hauptspeicherobjekte akzeptabel, allerdings nicht für persistente Objekte.

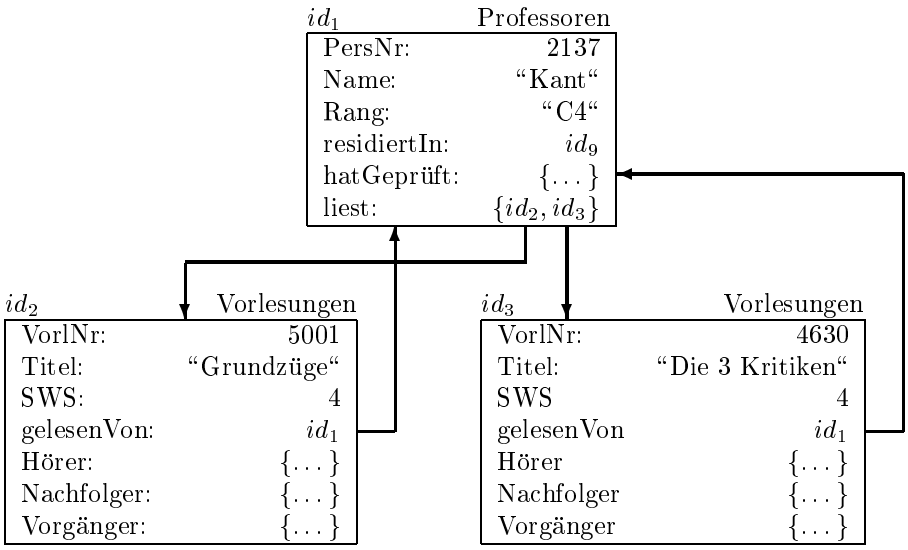

Abbildung 15.3: Einige Objekte aus der Universitätswelt

Objektorientierte Datenbanksysteme verwenden daher zustands- und speicherungsort-unabhängige *Objektidentifikatoren* (OIDs). Ein OID wird vom Datenbanksystem systemweit eindeutig generiert, sobald ein neues Objekt erzeugt wird. Der OID bleibt dem Anwender verborgen, er ist unveränderlich und unabhängig vom momentanen Objekt-Zustand. Die momentane physikalische Adresse ergibt sich aus dem Inhalt einer Tabelle, die mit dem OID referiert wird.

Die Objekttyp-Definition enthält folgende Bestandteile:

- die Strukturbeschreibung der Instanzen, bestehend aus Attributen und Beziehungen zu anderen Objekten,
- die Verhaltensbeschreibung der Instanzen, bestehend aus einer Menge von Operationen,
- die Typeigenschaften, z.B. Generalisierungs- und Spezialisierungsbeziehungen.

15.5 Definition von Attributen

Die Definition des Objekttyps *Professoren* könnte wie folgt aussehen:

```
class Professoren {
  attribute long   PersNr;
  attribute string Name;
  attribute string Rang;
};
```

Attribute können strukturiert werden mit Hilfe des Tupelkonstruktors **struct{...}**:

```
class Person {
  attribute string Name;
  attribute struct Datum {
    short Tag;
    short Monat;
    short Jahr;
  } GebDatum;
};
```

15.6 Definition von Beziehungen

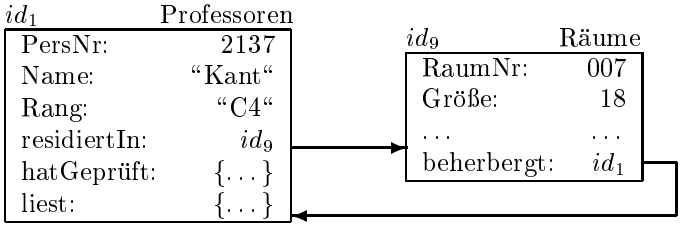

Abbildung 15.4: Ausprägung einer 1:1-Beziehung

Eine 1 : 1-Beziehung wird symmetrisch in beiden beteiligten Objekt-Typen modelliert:

```
class Professoren {
  attribute long  PersNr;
  ...
  relationship Raeume residiertIn;
};

class Raeume {
  attribute long  RaumNr;
  attribute short Groesse;
  ...
  relationship Professoren beherbergt;
};
```

Abbildung 15.4 zeigt eine mögliche Ausprägung der Beziehungen *residiertIn* und *beherbergt*.

Allerdings wird durch die gegebene Klassenspezifikation weder die Symmetrie noch die 1:1-Einschränkung garantiert. Abbildung 15.5 zeigt einen inkonsistenten Zustand des Beziehungspaars *residiertIn* und *beherbergt*.

Um Inkonsistenzen dieser Art zu vermeiden, wurde im ODMG-Objektmodell das **inverse**-Konstrukt integriert:

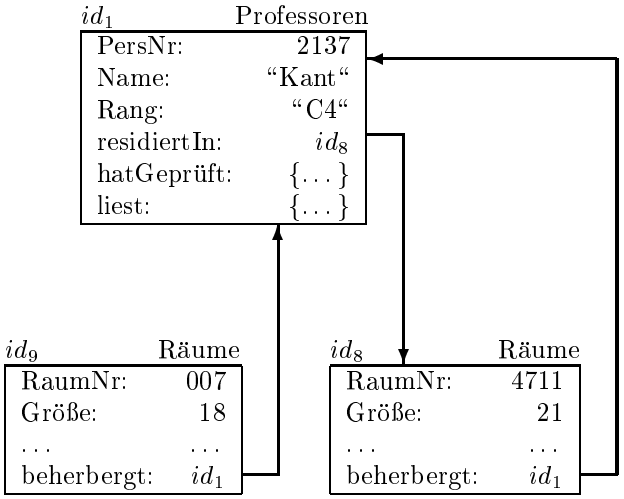

Abbildung 15.5: Inkonsistenter Zustand einer Beziehung

```
class Professoren {
  attribute long  PersNr;
  ...
  relationship Raeume residiertIn inverse Raeume::beherbergt;
};

class Raeume {
  attribute long  RaumNr;
  attribute short Groesse;
  ...
  relationship Professoren beherbergt inverse Professoren::residiertIn;
};
```

Damit wird sichergestellt, daß immer gilt:

$$p = r.beherbergt \quad \Leftrightarrow \quad r = p.residiertIn$$

Binäre *1:N* - Beziehungen werden modelliert mit Hilfe des Mengenkonstruktors **set**, der im nächsten Beispiel einem Professor eine Menge von Referenzen auf *Vorlesungen*-Objekte zuordnet:

```
class Professoren {
  ...
  relationship set (Vorlesungen) liest inverse Vorlesungen::gelesenVon;
};

class Vorlesungen {
  ...
  relationship Professoren gelesenVon inverse Professoren::liest;
};
```

Man beachte, daß im relationalen Modell die Einführung eines Attributs *liest* im Entity-Typ *Professoren* die Verletzung der 3. Normalform verursacht hätte.

Binäre *N:M* - Beziehungen werden unter Verwendung von zwei **set**-Konstruktoren modelliert:

```
class Studenten {
  ...
  relationship set (Vorlesungen) hoert inverse Vorlesungen::Hoerer;
};

class Vorlesungen {
  ...
  relationship set (Studenten) Hoerer inverse Studenten::hoert;
};
```

Durch die **inverse**-Spezifikation wird sichergestellt, daß gilt:

$$s \in v.Hoerer \quad \Leftrightarrow \quad v \in s.hoert$$

Analog lassen sich rekursive $N : M$ - Beziehungen beschreiben:

```
class Vorlesungen {
  ...
  relationship set (Vorlesungn) Vorgaenger inverse Vorlesungen::Nachfolger;
  relationship set (Vorlesungn) Nachfolger inverse Vorlesungen::Vorgaenger;
};
```

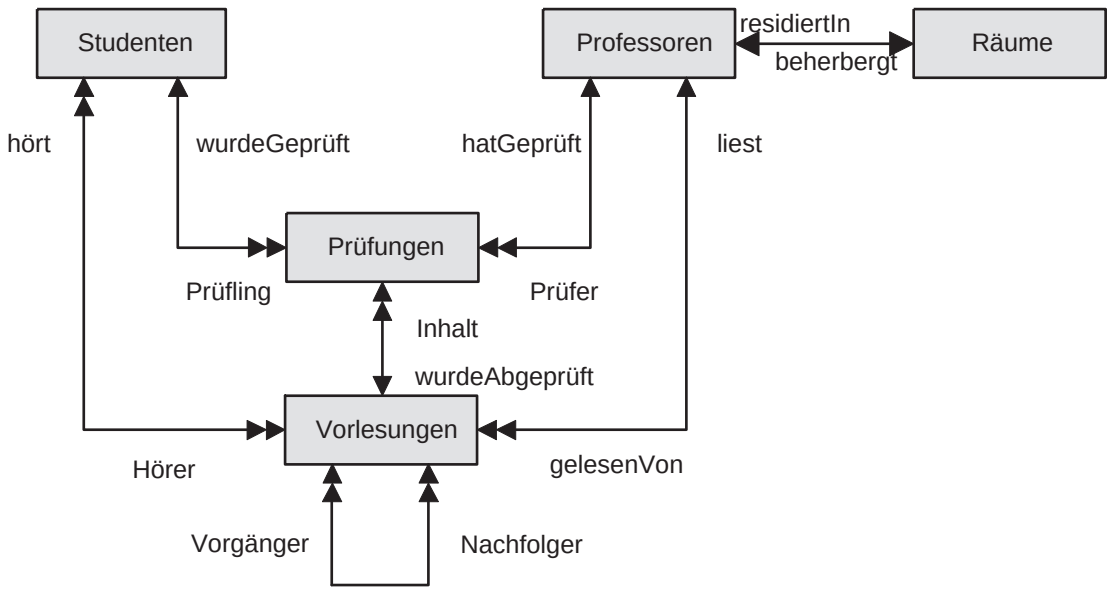

Abbildung 15.6: Modellierungen von Beziehungen im Objektmodell

Ternäre oder $n \geq 3$ stellige Beziehungen benötigen einen eigenständigen Objekttyp, der die Beziehung repräsentiert. Zum Beispiel wird die ternäre Beziehung

pruefen : {[MatrNr, VorlNr, PersNr, Note]}

zwischen den *Studenten*, *Vorlesungen* und *Professoren* wie folgt modelliert:

```
class Pruefungen {
  attribute    float       Note;
  relationship Professoren Pruefer   inverse Professoren::hatgeprueft;
  relationship Studenten   Pruefling inverse Studenten::wurdegeprueft;
  relationship Vorlesungen Inhalt    inverse Vorlesungen::wurdeAbgeprueft;
};

class Professoren {
  attribute    long             PersNr;
  attribute    string           Name;
  attribute    string           Rang;
  relationship Raeume           residiertIn inverse Raeume::beherbergt;
  relationship set(Vorlesungen) liest       inverse Vorlesungen::gelesenVon;
  relationship set(Pruefungen)  hatgeprueft inverse Pruefungen::Pruefer;
};

class Vorlesungen {
  attribute    long             VorlNr;
  attribute    string           Titel;
  attribute    short            SWS;
  relationship Professoren      gelesenVon inverse Professoren::liest;
  relationship set(Studenten)   Hoerer     inverse Studenten::hoert;
  relationship set(Vorlesungen) Nachfolger inverse Vorlesungen::Vorgaenger;
  relationship set(Vorlesungen) Vorgaenger inverse Vorlesungen::Nachfolger;
  relationship set(Pruefungen)  wurdeAbgeprueft inverse Pruefungen::Inhalt;
};

class Studenten {
  attribute    long             MatrNr;
  attribute    string           Name;
  attribute    short            Semester;
  relationship set(Pruefungen)  wurdeGeprueft inverse Pruefungen::Pruefling;
  relationship set(Vorlesungen) hoert         inverse Vorlesungen::Hoerer;
};
```

Abbildung 15.6 visualisiert die bislang eingeführten Beziehungen. Die Anzahl der Pfeilspitzen gibt die Wertigkeit der Beziehung an:

- $\leftrightarrow$ bezeichnet eine 1 : 1-Beziehung
- $\leftrightarrow\!\!\!\!\rightarrow$ bezeichnet eine 1 : N-Beziehung
- $\leftarrow\!\!\!\!\rightarrow$ bezeichnet eine N : 1-Beziehung
- $\leftarrow\!\!\!\!\rightarrow\!\!\!\!\rightarrow$ bezeichnet eine N : M-Beziehung

15.7 Extensionen und Schlüssel

Eine *Extension* ist die Menge aller Instanzen eines Objekt-Typs incl. seiner spezialisierten Untertypen (siehe später). Sie kann verwendet werden für Anfragen der Art "*Suche alle Objekte eines Typs, die eine bestimmte Bedingung erfüllen*". Man kann zu einem Objekttyp auch *Schlüssel* definieren, deren Eindeutigkeit innerhalb der Extension gewährleistet wird. Diese Schlüsselinformation wird jedoch nur als Integritätsbedingung verwendet und nicht zur Referenzierung von Objekten:

```
class Studenten (extent AlleStudenten key MatrNr) {
  attribute    long             MatrNr;
  attribute    string           Name;
  attribute    short            Semester;
  relationship set(Vorlesungen) hoert         inverse Vorlesungen::Hoerer;
  relationship set(Pruefungen)  wurdeGeprueft inverse Pruefungen::Pruefling;
};
```

15.8 Modellierung des Verhaltens

Der Zugriff auf den Objektzustand und die Manipulation des Zustands geschieht über eine *Schnittstelle*. Die Schnittstellenoperationen können

- ein Objekt erzeugen (instanziieren) und initialisieren mit Hilfe eines *Konstruktors*,
- freigegebene Teile des Zustands erfragen mit Hilfe eines *Observers*,
- konsistenzerhaltende Operationen auf einem Objekt ausführen mit Hilfe eines *Mutators*,
- das Objekt zerstören mit Hilfe eines *Destruktors*.

Die Aufrufstruktur der Operation, genannt *Signatur*, legt folgendes fest:

- Name der Operation,
- Anzahl und Typ der Parameter,
- Typ des Rückgabewerts, falls vorhanden, sonst **void**,
- ggf. die durch die Operation ausgelöste *Ausnahme* (engl. *exception*).

Beispiel:

```
class Professoren {
  exception hatNochNichtGeprueft { };
  exception schonHoechsteStufe   { };
  ...
  float wieHartAlsPruefer() raises (hatNochNichtgeprueft);
  void befoerdert() raises (schonHoechsteStufe);
};
```

Hierdurch wird der Objekttyp *Professoren* um zwei Signaturen erweitert:

- Der Observer *wieHartalsPruefer* liefert die Durchschnittsnote und stößt die Ausnahmebehandlung *hatNochNichtGeprueft* an, wenn keine Prüfungen vorliegen.
- Der Mutator *befoerdert* erhöht den Rang um eine Stufe und stößt die Ausnahmebehandlung *schonHoechsteStufe* an, wenn bereits die Gehaltsstufe C4 vorliegt.

Man bezeichnet den Objekttyp, auf dem die Operationen definiert wurden, als *Empfängertyp* (engl *receiver type*) und das Objekt, auf dem die Operation aufgerufen wird, als *Empfängerobjekt*.

Die Aufrufstruktur hängt von der Sprachanbindung ab. Innerhalb von C++ würde befördert aufgerufen als

```
meinLieblingsProf->befoerdert();
```

In der deklarativen Anfragesprache OQL (siehe Abschnitt 15.13) ist der Aufruf wahlweise mit Pfeil (`->`) oder mit einem Punkt (`.`)durchzuführen:

```
select p.wieHartAlsPruefer()
from p in AlleProfessoren
where p.Name = "Kant";
```

15.9 Vererbung

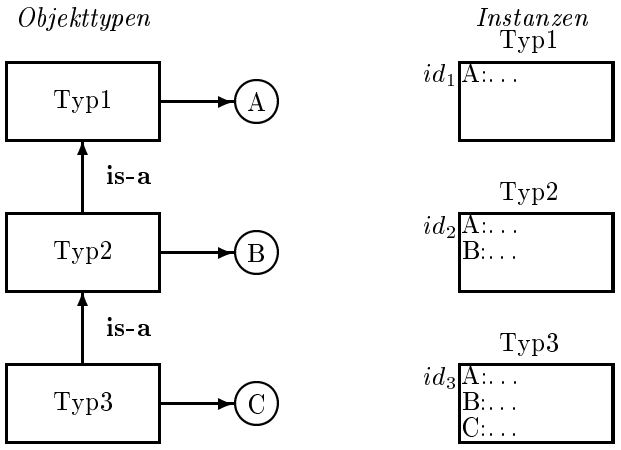

Abbildung 15.7: Schematische Darstellung einer abstrakten Typhierarchie

Das in Kapitel 2 eingeführte Konzept der Generalisierung bzw. Spezialisierung läßt sich bei objektorientierten Datenbanksystemen mit Hilfe der *Vererbung* lösen. Hierbei erbt der Untertyp nicht nur die Struktur, sondern auch das Verhalten des Obertyps. Außerdem sind

Instanzen des Untertyps überall dort einsetzbar (*substituierbar*), wo Instanzen des Obertyps erforderlich sind.

Abbildung 15.7 zeigt eine Typhierarchie, bei der die Untertypen *Typ2* und *Typ3* jeweils ein weiteres Attribut, nämlich B bzw. C aufweisen. Operationen sind hier gänzlich außer Acht gelassen. Instanzen des Typs *Typ3* gehören auch zur Extension von Typ *Typ2* und von Typ *Typ1*.

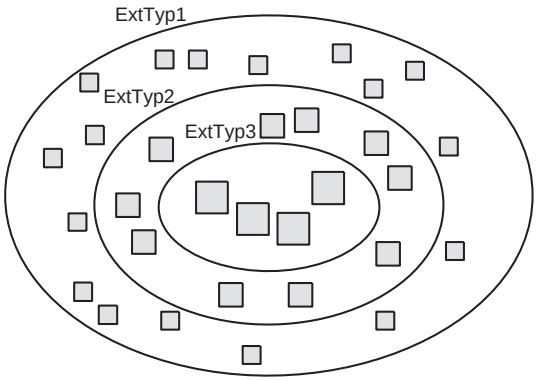

Abbildung 15.8: Darstellung der Subtypisierung

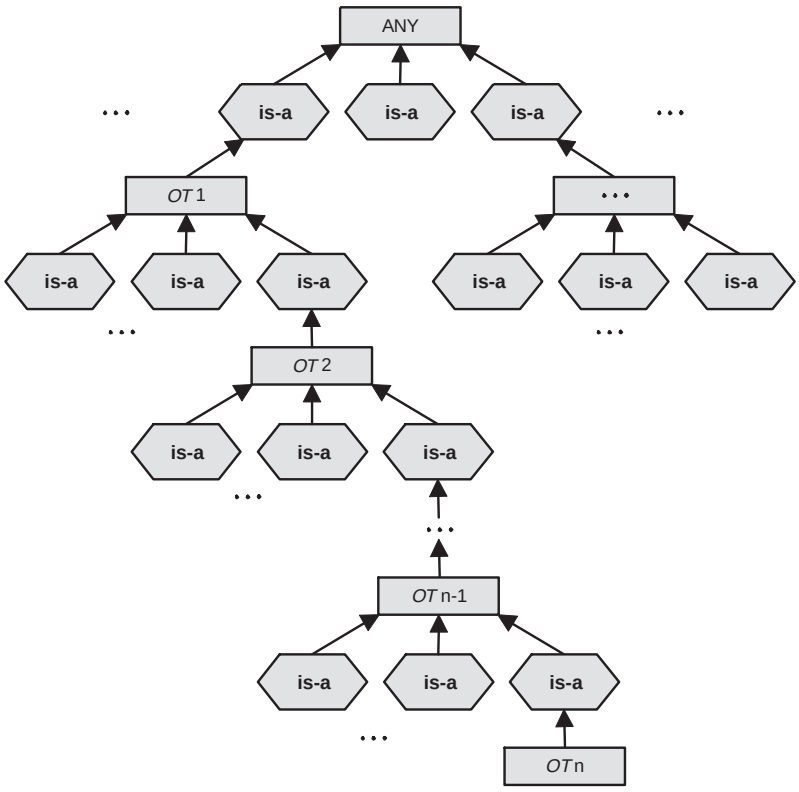

Abbildung 15.9: Abstrakte Typhierachie bei einfacher Vererbung

Abbildung 15.8 zeigt die geschachtelte Anordung der drei Extensionen der Typen *Typ1*, *Typ2* und *Typ3*. Durch die unterschiedliche Kästchengröße soll angedeutet werden, daß Untertyp-Instanzen mehr Eigenschaften haben und daher mehr wissen als die direkten Instanzen eines Obertyps.

Man unterscheidet zwei unterschiedliche Arten der Vererbung:

- *Einfachvererbung* (*single inheritance*):
  Jeder Objekttyp hat höchstens einen direkten Obertyp.
- *Mehrfachvererbung* (*multiple inheritance*):
  Jeder Objekttyp kann mehrere direkte Obertypen haben.

Abbildung 15.9 zeigt eine abstrakte Typhierarchie mit Einfachvererbung. Der Vorteil der Einfachvererbung gegenüber der Mehrfachvererbung besteht darin, daß es für jeden Typ einen eindeutigen Pfad zur Wurzel der Typhierarchie (hier: ANY) gibt. Ein derartiger Super-Obertyp findet sich in vielen Objektmodellen, manchmal wird er *object* genannt, in der ODMG C++-Einbindung heißt er *d_Object*.

15.10 Beispiel einer Typhierarchie

Wir betrachten eine Typhierarchie aus dem Universitätsbereich. *Angestellte* werden spezialisiert zu *Professoren* und *Assistenten*:

```
class Angestellte (extent AlleAngestellte) {
  attribute long PersNr;
  attribute string Name;
  attribute date GebDatum;
  short Alter();
  long Gehalt();
};

class Assistenten extends Angestellte (extent AlleAssistenten) {
  attribute string Fachgebiet;
};

class Professoren extends Angestellte (extent AlleProfessoren) {
  attribute string Rang;
  relationship Raeume           residiertIn inverse Raeume::beherbergt;
  relationship set(Vorlesungen) liest       inverse Vorlesungen::gelesenVon;
  relationship set(Pruefungen)  hatgeprueft inverse Pruefungen::Pruefer;
};
```

Abbildung 15.10 zeigt die drei Objekttypen *Angestellte*, *Professoren* und *Assistenten*, wobei die geerbten Eigenschaften in den gepunkteten Ovalen angegeben ist.

Abbildung 15.11 zeigt schematisch die aus der Ober-/Untertyp-Beziehung resultierende Inklusion der Extensionen *AlleProfessoren* und *AlleAssistenten* in der Extension *AlleAngestellte*.

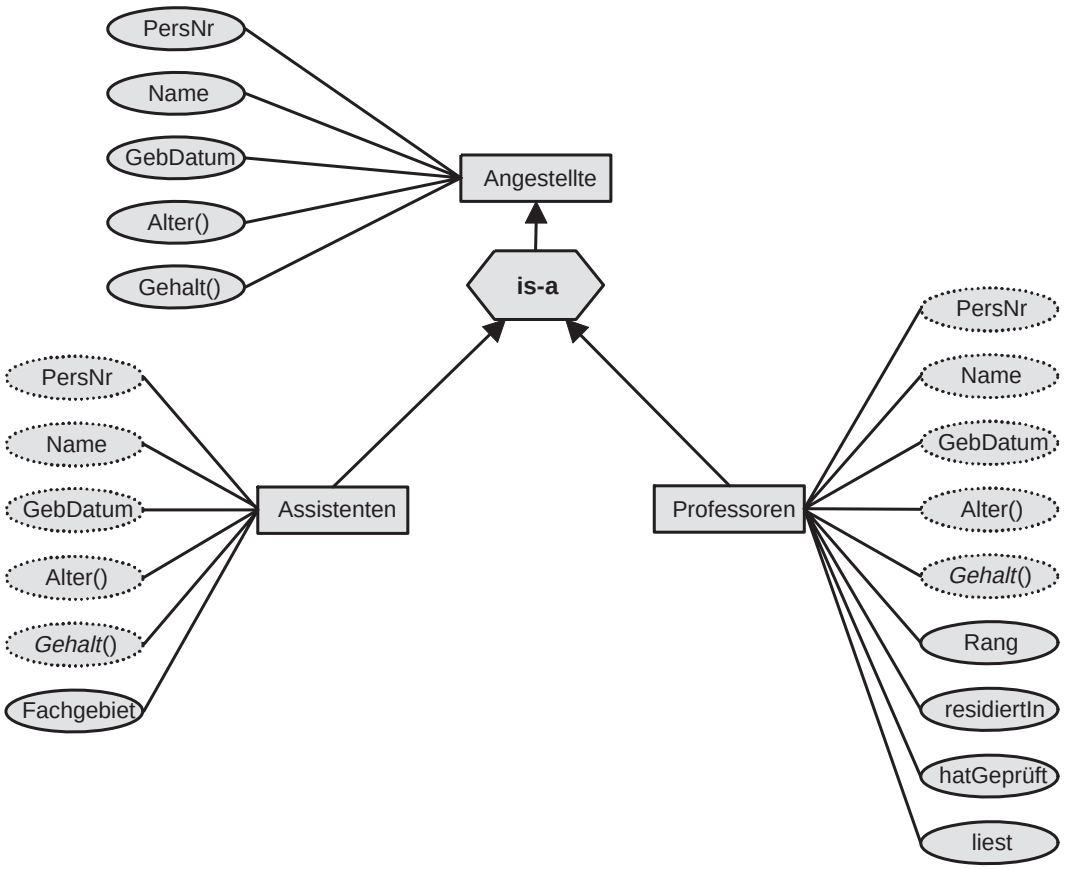

Abbildung 15.10: Vererbung von Eigenschaften

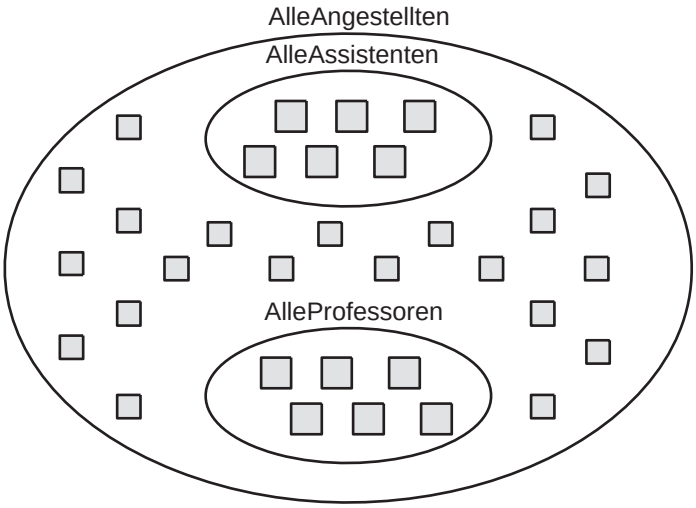

Abbildung 15.11: Visualisierung der Extensionen

15.11 Verfeinerung und spätes Binden

Genau wie Attribute werden auch Operationen vom Obertyp an alle Untertypen vererbt. Zum Beispiel steht der bei *Angestellte* definierte Observer *Gehalt()* auch bei den Objekttypen *Professoren* und *Assistenten* zur Verfügung.

Wir hätten auch eine *Verfeinerung* bzw. *Spezialisierung* (engl. *Refinement*) vornehmen können. Das Gehalt würde danach für jeden Objekttyp unterschiedlich berechnet:

- Angestellte erhalten 2000 + (Alter() - 21) * 100 DM,
- Assistenten erhalten 2500 + (Alter() - 21) * 125 DM,
- Professoren erhalten 3000 + (Alter() - 21) * 150 DM.

In Abbildung 15.10 ist dies durch den kursiven Schrifttyp der geerbten *Gehalt*-Eigenschaft gekennzeichnet.

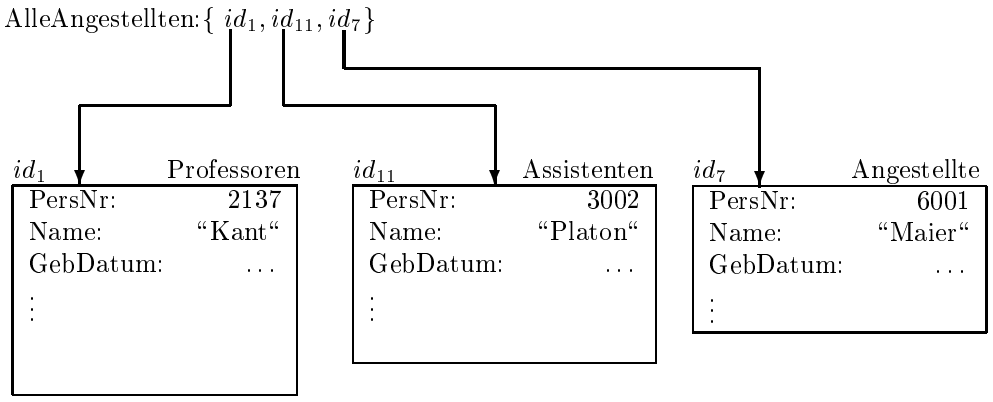

Abbildung 15.12: Die Extension AlleAngestellten mit drei Objekten

Abbildung 15.12 zeigt die Extension *AlleAngestellten* mit drei Elementen:

- Objekt id_1 ist eine direkte *Professoren*-Instanz,
- Objekt id_1 ist eine direkte *Assistenten*-Instanz,
- Objekt id_7 ist eine direkte *Angestellte*-Instanz.

Es werde nun die folgende Query abgesetzt:

```
select sum(a.Gehalt())
from a in AlleAngestellten;
```

Offensichtlich kann erst zur Laufzeit die jeweils spezialisierteste Version von *Gehalt* ermittelt werden. Diesen Vorgang bezeichnet man als *spätes Binden* (engl. *late binding*).

15.12 Mehrfachvererbung

Bei der Mehrfachvererbung erbt ein Objekttyp die Eigenschaften von mehreren Obertypen. Abbildung 15.13 zeigt ein Beispiel dafür. Der Objekttyp *Hiwi* erbt

- von *Angestellte* die Attribute *PersNr*, *Name* und *GebDatum* sowie die Operationen *Gehalt()* und *Alter()*,
- von *Studenten* die Attribute *MatrNr, Name, Semester, hört* und *wurdeGeprüft*.

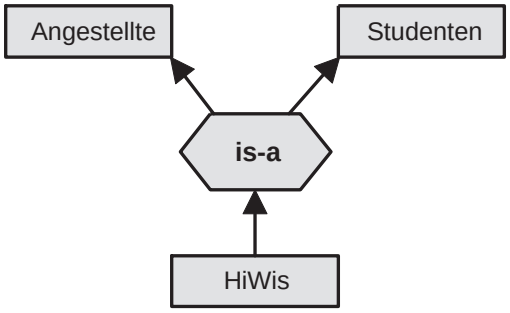

Abbildung 15.13: Beispiel für Mehrfachvererbung

Die Syntax könnte lauten:

```
class HiWis extends Studenten, Angestellte (extent AlleHiwis) {
  attribute short Arbeitsstunden;
  ...
};
```

Nun wird allerdings das Attribut *Name* sowohl von *Angestellte* als auch von *Studenten* geerbt. Um solchen Mehrdeutigkeiten und den damit verbundenen Implementationsproblemen aus dem Weg zu gehen, wurde in der Version 2.0 von ODL das Schnittstellen-Konzept (engl *interface*) eingeführt, das es in ähnlicher Form auch in der Programmiersprache *Java* gibt.

Eine **interface**-Definition ist eine abstrakte Definition der Methoden, die alle Klassen besitzen müssen, die diese Schnittstelle implementieren. Eine Klasse im ODBG-Modell kann mehrere Schnittstellen implementieren, darf aber nur höchstens von einer Klasse mit **extends** abgeleitet werden

Also würde man für die Angestellten lediglich die Schnittstelle *AngestellteIF* festlegen. Die Klasse *HiWis* implementiert diese Schnittstelle und erbt den Zustand und die Methoden der Klasse *Studenten*. Die Liste der Schnittstellen, die eine Klasse implementiert, wird in der Klassendefinition nach dem Klassennamen und der möglichen **extends**-Anweisung hinter einem Doppelpunkt angegeben. Zusätzlich muß der nicht mitgeerbte, aber benötigte Teil des Zustandes der ursprünglichen *Angestellten*-Klasse nachgereicht werden.

```
interface AngestellteIF {
  short Alter();
  long  Gehalt();
};

class Angestellte : AngestellteIF (extent AlleAngestellte) {
  attribute long   PersNr;
  attribute string Name;
  attribute date   GebDatum;
};

class Hiwis extends Studenten : AngestellteIF (extent AlleHiwis) {
  attribute long  PersNr;
  attribute date  GebDatum;
  attribute short Arbeitsstunden;
};
```

Man beachte, daß die *HiWis* nun nicht in der Extension *AlleAngestellten* enthalten sind. Dazu müßte man diese Extension der Schnittstelle *AngestellteIF* zuordnen, was aber nach ODMG-Standard nicht möglich ist. Konflikte bei gleichbenannten Methoden werden im ODBG-Modell dadurch vermieden, daß Ableitungen, bei denen solche Konflikte auftreten würden, verboten sind.

15.13 Die Anfragesprache OQL

OQL (Object Query Language) ist eine an SQL angelehnte Abfragesprache. Im Gegensatz zu SQL existiert kein Update-Befehl. Veränderungen an der Datenbank können nur über die Mutatoren der Objekte durchgeführt werden.

Liste alle C4-Professoren (als Objekte):

```
select p
from p in AlleProfessoren
where p.Rang = 'C4';
```

Liste Name und Rang aller C4-Professoren (als Werte):

```
select p.Name, p.Rang
from p in AlleProfessoren
where p.Rang = 'C4';
```

Liste Name und Rang aller C4-Professoren (als Tupel):

```
select struct (n: p.Name, r: p.Rang)
from p in AlleProfessoren
where p.Rang = "C4";
```

Liste alle Angestellte mit einem Gehalt über 100.000 DM:

```
select a.Name
from a in AlleAngestellte
where a.Gehalt() > 100.000;
```

Liste Name und Lehrbelastung aller Professoren:

```
select struct (n: p.Name, a: sum(select v.SWS from v in p.liest))
from p in AlleProfessoren;
```

Gruppiere alle Vorlesungen nach der Semesterstundenzahl:

```
select *
from v in AlleVorlesungen
group by kurz: v.SWS <= 2, mittel: v.SWS = 3, lang: v.SWS >= 4;
```

Das Ergebnis sind drei Tupel vom Typ

```
struct (kurz: boolean, mittel: boolean, lang: boolean,
        partition : bag(struct(v: Vorlesungen)))
```

mit dem mengenwertigen Attribut *partition*, welche die in die jeweilige Partition fallenden Vorlesungen enthält. Die booleschen Werte markieren, um welche Partition es sich handelt.

Liste die Namen der Studenten, die bei Sokrates Vorlesungen hören:

```
select s.Name
from s in AlleStudenten, v in s.hoert
where v.gelesenVon.Name = "Sokrates"
```

Die im relationalen Modell erforderlichen Joins wurden hier mit Hilfe von Pfadausdrücken realisiert. Abbildung 15.14 zeigt die graphische Darstellung des Pfadausdrucks von *Studenten* über *Vorlesungen* zu *Professoren*.

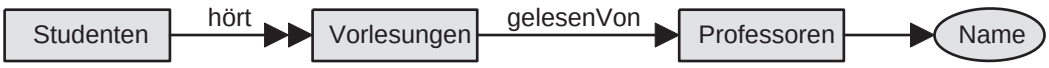

Abbildung 15.14: Graphische Darstellung eines Pfadausdrucks

Der Ausdruck *s.hoert* ergibt die Menge von Vorlesungen des Studenten *s*. Pfadausdrücke können beliebige Länge haben, dürfen aber keine mengenwertigen Eigenschaften verwenden. Verboten ist daher eine Formulierung der Form

```
s.hoert.gelesenVon.Name
```

da *hoert* mengenwertig ist. Stattdessen wurde in der from-Klausel die Variable *v* eingeführt, die jeweils an die Menge *s.hoert* gebunden wird.

Die Erzeugung von Objekten geschieht mit Hilfe des Objektkonstruktors:

```
Vorlesungen (vorlNr: 4711, Titel: "Selber Atmen", SWS: 4, gelesenVon : (
  select p
  from p in AlleProfessoren
  where p.Name = "Sokrates"));
```

15.14 C++-Einbettung

Zur Einbindung von objektorientierten Datenbanksystemen in eine Programmiersprache gibt es drei Ansätze:

- **Entwurf einer neuen Sprache**
- **Erweiterung einer bestehenden Sprache**
- **Datenbankfähigkeit durch Typ-Bibliothek**

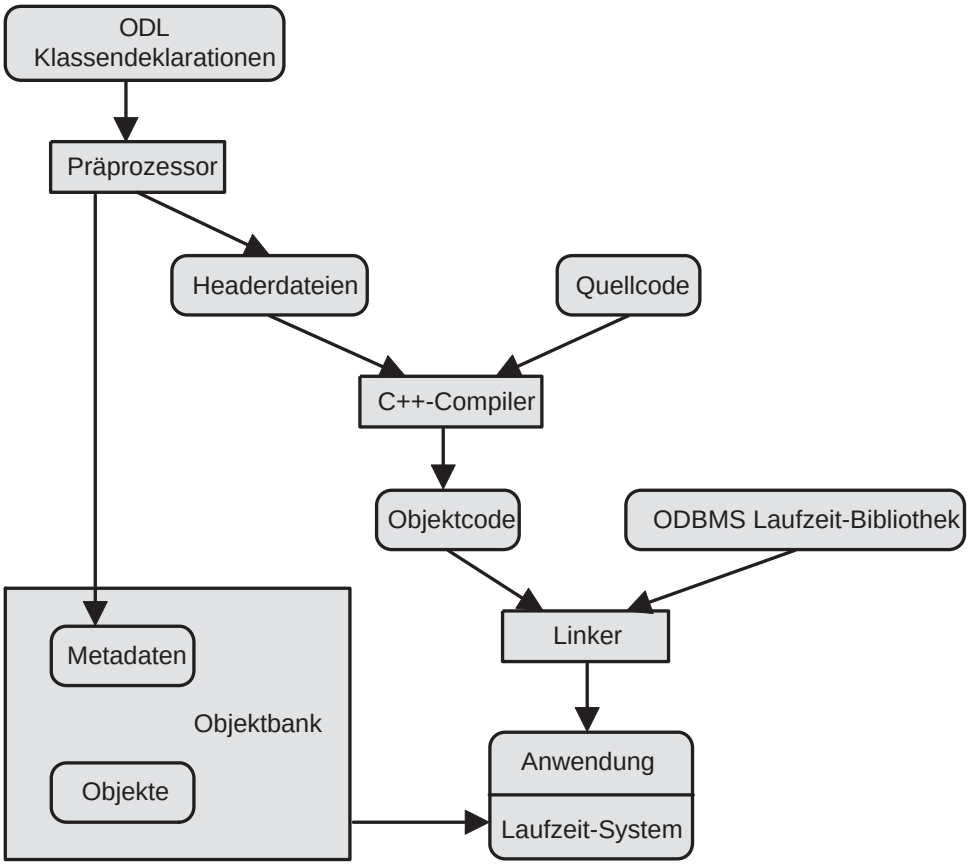

Abbildung 15.15: C++-Einbindung

Die von der ODMG gewählte Einbindung entspricht dem dritten Ansatz. Ihre Realisierung ist in Abbildung 15.15 dargestellt. Der Benutzer erstellt die Klassendeklarationen und den Quellcode der Anwendung. Die Klassendeklarationen werden mit Hilfe eines Präprozessors in die Datenbank eingetragen. Zusätzlich werden Header-Dateien in Standard-C++ erzeugt, die durch einen handelsüblichen C++-Compiler übersetzt werden können. Der Quellcode enthält die Realisierungen der den Objekttypen zugeordneten Operationen. Der übersetzte Quellcode wird mit dem Laufzeitsystem gebunden. Das Laufzeitsystem sorgt in der fertigen Anwendung für die Kommunikation mit der Datenbank.

Zur Formulierung von Beziehungen zwischen persistenten Objekten bietet die C++-Einbettung die Typen *d_Rel_Ref* und *d_Rel_Set* an:

```
const char _liest[]      = "liest";
const char _gelesenVon[] = "gelesenVon";

class Vorlesungen : public d_Object {
  d_String Titel;
  d_Short  SWS;
  ...
  d_Rel_ref <Professoren, _liest> gelesenVon;
}

class Professoren : public Angestellte {
  d_Long PersNr;
  ...
  d_Rel_Set <Vorlesungen, _gelesenVon> liest;
}
```

Es wurden hier zwei Klassen definiert. *Vorlesungen* ist direkt vom Typ *d_Object* abgeleitet, *Professoren* ist über *d_Object* und dann über *Angestellte* (nicht gezeigt) abgeleitet. Der Typ *d_object* sorgt dafür, daß von *Vorlesungen* und *Professoren* nicht nur transiente, sondern auch persistente Instanzen gebildet werden können. Die Typen *d_String*, *d_Short* und *d_Long* sind die C++-Versionen der ODL-Typen **string**, **short** und **long**.

In der Klasse *Vorlesungen* referenziert das Attribut *gelesenVon* durch *d_Rel_Ref* ein Objekt vom Typ *Professoren*. Als zweites Argument in der Winkelklammer wird die entsprechende inverse Abbildung *liest* angegeben. In der Klasse *Professoren* referenziert das Attribut *liest* durch *d_Rel_Set* eine Menge von Objekten vom Typ *Vorlesungen*. Als zweites Argument in der Winkelklammer wird die entsprechende inverse Abbildung *gelesenVon* angegeben.

Zum Erzeugen eines persistenten Objekts verwendet man den Operator **new**:

```
d_Ref <Professoren> Russel =
  new(UniDB,"Professoren") Professoren (2126,"Russel","C4", ...);
```

Hierbei ist *Russel* eine Variable vom Typ *d_Ref* bezogen auf *Professoren*, die auf das neue Objekt verweist (im Gegensatz zu *d_Rel_Ref* ohne inverse Referenz). Als zweites Argument wird der Name des erzeugten Objekttypen als Zeichenkette angegeben.

Als Beispiel einer Anfrage wollen wir alle Schüler eines bestimmten Professors ermitteln:

```
d_Bag <Studenten> Schüler;
char * profname = ...;
d_OQL_Query anfrage ("select s
                      from s in v.Hörer,
                      v in p.liest,
                      p in AlleProfessoren
                      where p.Name = $1");
anfrage << profname;
d_oql_execute(anfrage, Schüler);
```

Zunächst wird ein Objekt vom Typ *d_OQL_Query* erzeugt mit der Anfrage als Argument in Form eines Strings. Hierbei können Platzhalter für Anfrageparameter stehen; an Stelle von $1 wird der erste übergebene Parameter eingesetzt. Dies geschieht mit dem <<-Operator der Klasse *d_OQL_Query*. Die Anfrage wird mit der Funktion *d_oql_execute* ausgeführt und das Ergebnis in der Kollektionsvariablen vom Typ *d_Bag* (Multimenge mit Duplikaten) zurückgeliefert.

Kapitel 16

Data Warehouse

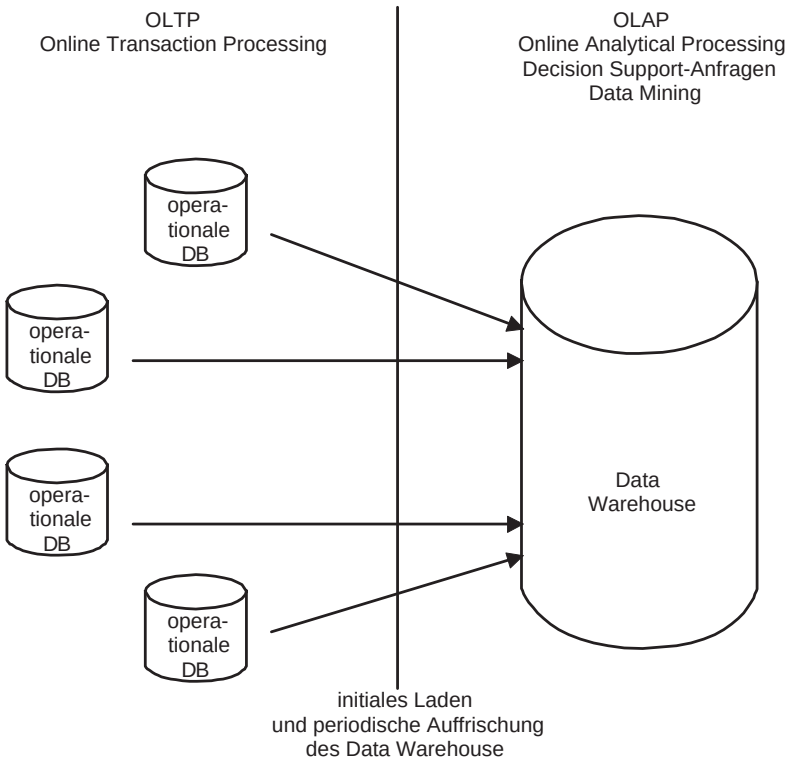

Abbildung 16.1: Zusammenspiel zwischen OLTP und OLAP

Man unterscheidet zwei Arten von Datenbankanwendungen:

- **OLTP** (*Online Transaction Processing*):
  Hierunter fallen Anwendungen wie zum Beispiel das Buchen eines Flugs in einem Flugreservierungssystem oder die Verarbeitung einer Bestellung in einem Handelsunternehmen. OLTP-Anwendungen verarbeiten nur eine begrenzte Datenmenge und operieren auf dem jüngsten, aktuell gültigen Zustand der Datenbasis.

- **OLAP** (*Online Analytical Processing*):
  Eine typische OLAP-Query fragt nach der Auslastung der Transatlantikflüge der letzten zwei Jahre oder nach der Auswirkung gewisser Marketingstrategien. OLAP-Anwendungen verarbeiten sehr große Datenmengen und greifen auf historische Daten zurück. Sie bilden die Grundlage für *Decision-Support-Systeme*.

OLTP- und OLAP-Anwendungen sollten nicht auf demselben Datenbestand arbeiten aus folgenden Gründen:

- OLTP-Datenbanken sind auf Änderungstransaktionen mit begrenzten Datenmengen hin optimiert.
- OLAP-Auswertungen benötigen Daten aus verschiedenen Datenbanken in konsolidierter, integrierter Form.

Daher bietet sich der Aufbau eines *Data Warehouse* an, in dem die für Decision-Support-Anwendungen notwendigen Daten in konsolidierter Form gesammelt werden. Abbildung 16.1 zeigt das Zusammenspiel zwischen operationalen Datenbanken und dem Data Warehouse. Typischerweise wird beim Transferieren der Daten aus den operationalen Datenbanken eine Verdichtung durchgeführt, da nun nicht mehr einzelne Transaktionen im Vordergrund stehen, sondern ihre Aggregation.

16.1 Datenbankentwurf für Data Warehouse

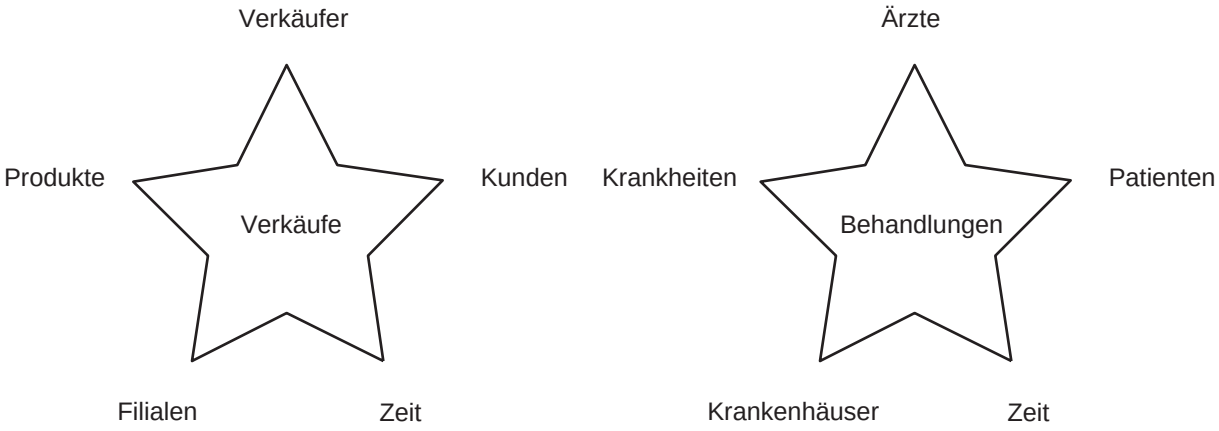

Abbildung 16.2: Sternschemata für Handelsunternehmen und Gesundheitswesen

Als Datenbankschema für Data Warehouse-Anwendungen hat sich das sogenannte *Sternschema* (engl.: *star scheme*) durchgesetzt. Dieses Schema besteht aus einer *Faktentabelle* und mehreren *Dimensionstabellen*. Abbildung 16.2 zeigt die Sternschemata für zwei Beispielanwendungen in einem Handelsunternehmen und im Gesundheitswesen.

Bei dem Handelsunternehmen können in der Faktentabelle *Verkäufe* mehrere Millionen Tupel sein, während die Dimensionstabelle *Produkte* vielleicht 10.000 Einträge und die Dimensions-

Verkäufe					
VerkDatum	Filiale	Produkt	Anzahl	Kunde	Verkäufer
30-Jul-96	Passau	1347	1	4711	825
...	...	...	...	...	...

Filialen			
Filialenkennung	Land	Bezirk	...
Passau	D	Bayern	...
...	...	...	...

Kunden			
KundenNr	Name	wiealt	...
4711	Kemper	38	...
...	...	...	...

Verkäufer					
VerkäuferNr	Name	Fachgebiet	Manager	wiealt	...
825	Handyman	Elektronik	119	23	...
...	...	...	...	...	...

Zeit								
Datum	Tag	Monat	Jahr	Quartal	KW	Wochentag	Saison	...
...	...	...	...	...	...	...	...	...
30-Jul-96	30	Juli	1996	3	31	Dienstag	Hochsommer	...
...	...	...	...	...	...	...	...	...
23-Dec-97	27	Dezember	1997	4	52	Dienstag	Weihnachten	...
...	...	...	...	...	...	...	...	...

Produkte					
ProduktNr	Produkttyp	Produktgruppe	Produkthauptgruppe	Hersteller	...
1347	Handy	Mobiltelekom	Telekom	Siemens	...
...	...	...	...	...	...

Abbildung 16.3: Ausprägung des Sternschemas in einem Handelsunternehmen

tabelle *Zeit* vielleicht 1.000 Einträge (für die letzen drei Jahre) aufweist. Abbildung 16.3 zeigt eine mögliche Ausprägung.

Die Dimensionstabellen sind in der Regel nicht normalisiert. Zum Beispiel gelten in der Tabelle *Produkte* folgende funktionale Abhängigkeiten: $ProduktNr \rightarrow Produkttyp$, $Produkttyp \rightarrow Produktgruppe$ und $Produktgruppe \rightarrow Produkthauptgruppe$. In der *Zeit*-Dimension lassen sich alle Attribute aus dem Schlüsselattribut *Datum* ableiten. Trotzdem ist die explizite Speicherung dieser Dimension sinnvoll, da Abfragen nach Verkäufen in bestimmten Quartalen oder an bestimmten Wochentagen dadurch effizienter durchgeführt werden können.

Die Verletzung der Normalformen in den Dimensionstabellen ist bei Decision-Support-Systemen nicht so gravierend, da die Daten nur selten verändert werden und da der durch die Redundanz verursachte erhöhte Speicherbedarf bei den relativ kleinen Dimensionstabellen im Vergleich zu der großen (normalisierten) Faktentabelle nicht so sehr ins Gewicht fällt.

16.2 Star Join

Das Sternschema führt bei typischen Abfragen zu sogenannten *Star Joins*:

> Welche Handys (d.h. von welchen Herstellern) haben junge Kunden in den bayrischen Filialen zu Weihnachten 1996 gekauft ?

```
select sum(v.Anzahl), p.Hersteller
from  Verkäufe v, Filialen f, Produkte p, Zeit z, Kunden k
where z.Saison = 'Weihnachten' and z.Jahr = 1996 and k.wiealt < 30
and   p.Produkttyp = 'Handy' and f.Bezirk = 'Bayern'
and   v.VerkDatum = z.Datum and v.Produkt = p.ProduktNr
and   v.Filiale = f.Filialenkennung and v.Kunde = k.KundenNr
group by Hersteller;
```

16.3 Roll-Up/Drill-Down-Anfragen

Der Verdichtungsgrad bei einer SQL-Anfrage wird durch die **group by**-Klausel gesteuert. Werden mehr Attribute in die **group by**-Klausel aufgenommen, spricht man von einem *drill down*. Werden weniger Attribute in die **group by**-Klausel aufgenommen, spricht man von einem *roll up*.

> Wieviel Handys wurden von welchem Hersteller in welchem Jahr verkauft ?

```
select Hersteller, Jahr, sum(Anzahl)
from   Verkäufe v, Produkte p, Zeit z
where  v.Produkt = p.ProduktNr
and    v.VerkDatum = z.Datum
and    p.Produkttyp = 'Handy'
group  by p.Hersteller, z.Jahr;
```

Das Ergebnis wird in der linken Tabelle von Abbildung 16.4 gezeigt. In der Tabelle rechts oben bzw. rechts unten finden sich zwei Verdichtungen.

Durch das Weglassen der Herstellerangabe aus der **group by**-Klausel (und der **select**-Klausel) entsteht ein *roll up* entlang der Dimension *p.Hersteller*:

> Wieviel Handys wurden in welchem Jahr verkauft ?

```
select Jahr, sum(Anzahl)
from   Verkäufe v, Produkte p, Zeit z
where  v.Produkt = p.ProduktNr
and    v.VerkDatum = z.Datum
and    p.Produkttyp = 'Handy'
group  by z.Jahr;
```

Handyverkäufe nach Hersteller und Jahr		
Hersteller	Jahr	Anzahl
Siemens	1994	2.000
Siemens	1995	3.000
Siemens	1996	3.500
Motorola	1994	1.000
Motorola	1995	1.000
Motorola	1996	1.500
Bosch	1994	500
Bosch	1995	1.000
Bosch	1996	1.500
Nokai	1995	1.000
Nokai	1996	1.500
Nokai	1996	2.000

Handyverkäufe nach Jahr	
Jahr	Anzahl
1994	4.500
1995	6.500
1996	8.500

Handyverkäufe nach Hersteller	
Hersteller	Anzahl
Siemens	8.500
Motorola	3.500
Bosch	3.000
Nokai	4.500

Abbildung 16.4: Analyse der Handy-Verkäufe nach unterschiedlichen Dimensionen

Durch das Weglassen der Zeitangabe aus der **group by**-Klausel (und der **select**-Klausel) entsteht ein *roll up* entlang der Dimension *z.Jahr*:

Wieviel Handys wurden von welchem Hersteller verkauft ?

```
select Hersteller, sum(Anzahl)
from   Verkäufe v, Produkte p
where  v.Produkt = p.ProduktNr and v.VerkDatum = z.Datum
and    p.Produkttyp = 'Handy'
group  by p.Hersteller;
```

Die ultimative Verdichtung besteht im kompletten Weglassen der **group-by**-Klausel. Das Ergebnis besteht aus einem Wert, nämlich 19.500:

Wieviel Handys wurden verkauft ?

```
select sum(Anzahl)
from   Verkäufe v, Produkte p
where  v.Produkt = p.ProduktNr
and    p.Produkttyp = 'Handy';
```

Durch eine sogenannte *cross tabulation* können die Ergebnisse in einem n-dimensionalen Spreadsheet zusammengefaßt werden. Abbildung 16.5 zeigt die Ergebisse aller drei Abfragen zu Abbildung 16.4 in einem 2-dimensionalen Datenwürfel *data cube*.

Hersteller \ Jahr	1994	1995	1996	Σ
Siemens	2.000	3.000	3.500	8.500
Motorola	1.000	1.000	1.500	3.500
Bosch	500	1.000	1.500	3.000
Nokai	1.000	1.500	2.000	4.500
Σ	4.500	6.500	8.500	19.500

Abbildung 16.5: Handy-Verkäufe nach Jahr und Hersteller

16.4 Materialisierung von Aggregaten

Da es sehr zeitaufwendig ist, die Aggregation jedesmal neu zu berechnen, empfiehlt es sich, sie zu materialisieren, d.h. die vorberechneten Aggregate verschiedener Detaillierungsgrade in einer Relation abzulegen. Es folgen einige SQL-Statements, welche die linke Tabelle von Abbildung 16.6 erzeugen. Mit dem **null**-Wert wird markiert, daß entlang dieser Dimension die Werte aggregiert wurden.

```
create table Handy2DCube (Hersteller varchar(20),Jahr integer,Anzahl integer);
insert into  Handy2DCube
(select p.Hersteller, z.Jahr, sum(v.Anzahl)
from Verkäufe v, Produkte p, Zeit z
where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
and    v.VerkDatum = z.Datum
group  by z.Jahr, p.Hersteller)
union
(select p.Hersteller, to_number(null), sum(v.Anzahl)
from  Verkäufe v, Produkte p
where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
group by p.Hersteller)
union
(select null, z.Jahr, sum(v.Anzahl)
from Verkäufe v, Produkte p, Zeit z
where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
and   v.VerkDatum = z.Datum
group by z.Jahr)
union
(select null, to_number(null), sum(v.Anzahl)
from  Verkäufe v, Produkte p
where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy');
```

Offenbar ist es recht mühsam, diese Art von Anfragen zu formulieren, da bei n Dimensionen insgesamt 2^n Unteranfragen formuliert und mit **union** verbunden werden müssen. Außerdem sind solche Anfragen extrem zeitaufwendig auszuwerten, da jede Aggregation individuell berechnet wird, obwohl man viele Aggregate aus anderen (noch nicht so stark verdichteten) Aggregaten berechnen könnte.

Handy2DCube		
Hersteller	Jahr	Anzahl
Siemens	1994	2.000
Siemens	1995	3.000
Siemens	1996	3.500
Motorola	1994	1.000
Motorola	1995	1.000
Motorola	1996	1.500
Bosch	1994	500
Bosch	1995	1.000
Bosch	1996	1.500
Nokai	1995	1.000
Nokai	1996	1.500
Nokai	1996	2.000
null	1994	4.500
null	1995	6.500
null	1996	8.500
Siemens	**null**	8.500
Motorola	**null**	3.500
Bosch	**null**	3.000
Nokai	**null**	4.500
null	**null**	19.500

Handy3DCube			
Hersteller	Jahr	Land	Anzahl
Siemens	1994	D	800
Siemens	1994	A	600
Siemens	1994	CH	600
Siemens	1995	D	1.200
Siemens	1995	A	800
Siemens	1995	CH	1.000
Siemens	1996	D	1.400
...	...	...	...
Motorola	1994	D	400
Motorola	1994	A	300
Motorola	1994	CH	300
...	...	...	...
Bosch	...	...	...
...	...	...	...
null	1994	D	...
null	1995	D	...
...	...	...	...
Siemens	**null**	**null**	8.500
...	...	...	...
null	**null**	**null**	19.500

Abbildung 16.6: Materialisierung von Aggregaten in einer Relation

16.5 Der Cube-Operator

Um der mühsamen Anfrageformulierung und der ineffizienten Auswertung zu begegnen, wurde vor kurzem ein neuer SQL-Operator namens **cube** vorgeschlagen. Zur Erläuterung wollen wir ein 3-dimensionales Beispiel konstruieren, indem wir auch entlang der zusätzlichen Dimension *Filiale.Land* ein *drill down* vorsehen:

```
select p.Hersteller, z.Jahr, f.Land, sum(Anzahl)
from   Verkäufe v, Produkte p, Zeit z, Filialen f
where  v.Produkt    = p.ProduktNr
and    p.Produkttpy = 'Handy'
and    v.VerkDatum  = z.Datum
and    v.Filiale    = f.Filialenkennung
group  by z.Jahr, p.Hersteller, f.Land with cube;
```

Die Auswertung dieser Query führt zu dem in Abbildung 16.7 gezeigten 3D-Quader; die relationale Repräsentation ist in der rechten Tabelle von Abbildung 16.6 zu sehen. Neben der einfacheren Formulierung erlaubt der Cube-Operator dem DBMS einen Ansatz zur Optimierung, indem stärker verdichtete Aggregate auf weniger starken aufbauen und indem die (sehr große) *Verkäufe*-Relation nur einmal eingelesen werden muß.

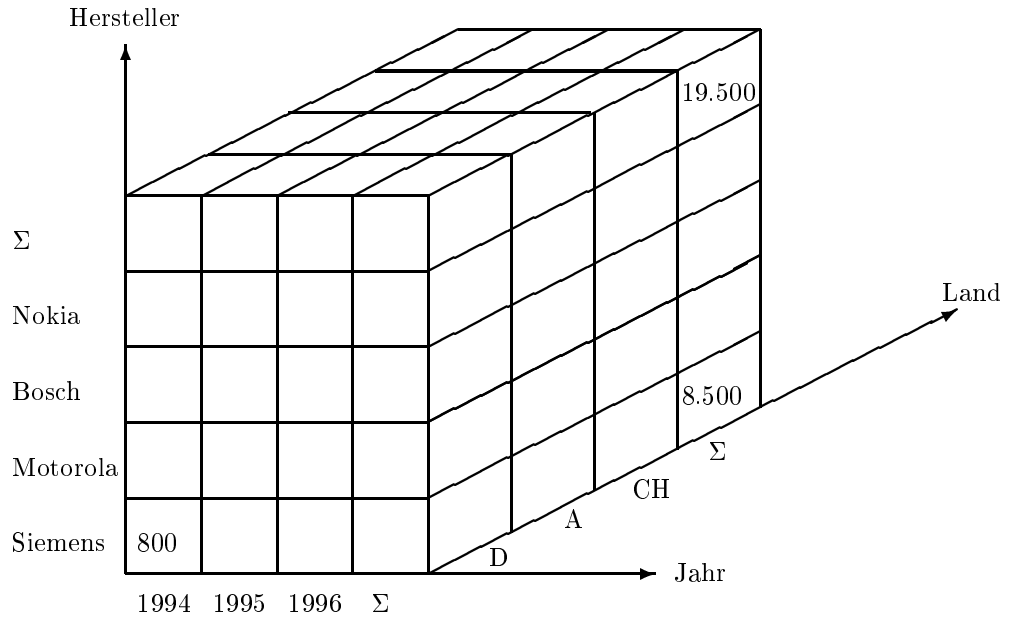

Abbildung 16.7: Würfeldarstellung der Handyverkaufszahlen nach Jahr, Hersteller und Land

16.6 Data Warehouse-Architekturen

Es gibt zwei konkurrierende Architekturen für Data Warehouse Systeme:

- **ROLAP**: Das Data Warehouse wird auf der Basis eines relationalen Datenmodells realisiert (wie in diesem Kapitel geschehen).
- **MOLAP**: Das Data Warehouse wird auf der Basis maßgeschneiderter Datenstrukturen realisiert. Das heißt, die Daten werden nicht als Tupel in Tabellen gehalten, sondern als Einträge in mehrdimensionalen Arrays. Probleme bereiten dabei dünn besetzte Dimensionen.

16.7 Data Mining

Beim *Data Mining* geht es darum, große Datenmengen nach (bisher unbekannten) Zusammenhängen zu durchsuchen. Man unterscheidet zwei Zielsetzungen bei der Auswertung der Suche:

- Klassifikation von Objekten,
- Finden von Assoziativregeln.

Bei der Klassifikation von Objekten (z. B: Menschen, Aktienkursen, etc.) geht es darum, Vorhersagen über das zukünftige Verhalten auf Basis bekannter Attributwerte zu machen. Abbildung 16.8 zeigt ein Beispiel aus der Versicherungswirtschaft. Für die Risikoabschätzung

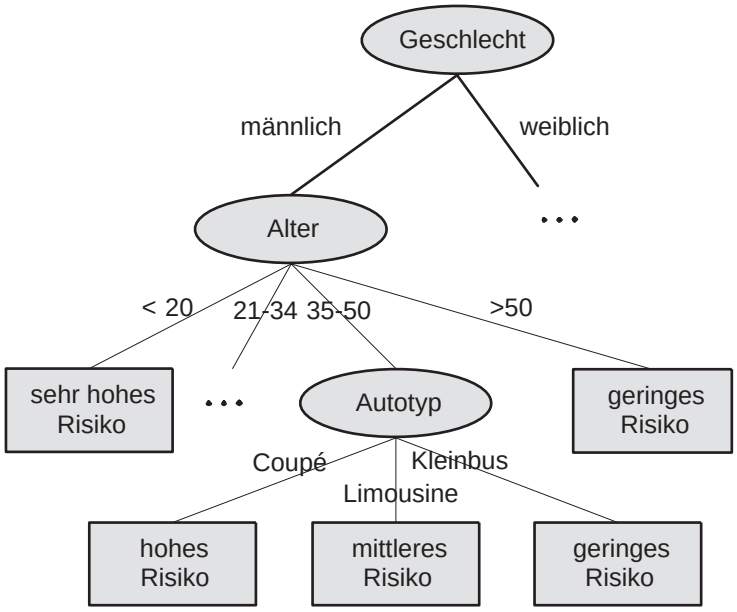

Abbildung 16.8: Klassifikation für Haftpflicht-Risikoabschätzung

könnte man beispielsweise vermuten, daß Männer zwischen 35 und 50 Jahren, die ein Coupé fahren, in eine hohe Risikogruppe gehören. Diese Klassifikation wird dann anhand einer repräsentativen Datenmenge verifiziert. Die Wahl der Attribute für die Klassifikation erfolgt benutzergesteuert oder auch automatisch durch "Ausprobieren".

Bei der Suche nach Assoziativregeln geht es darum, Zusammenhänge bestimmter Objekte durch Implikationsregeln auszudrücken, die vom Benutzer vorgeschlagen oder vom System generiert werden. Zum Beispiel könnte eine Regel beim Kaufverhalten von Kunden folgende (informelle) Struktur haben:

> **Wenn** jemand einen PC kauft
> **dann** kauft er auch einen Drucker.

Bei der Verifizierung solcher Regeln wird keine 100 %-ige Einhaltung erwartet. Stattdessen geht es um zwei Kenngrößen:

- **Confidence:** Dieser Wert legt fest, bei welchem Prozentsatz der Datenmenge, bei der die Voraussetzung (linke Seite) erfüllt ist, die Regel (rechte Seite) auch erfüllt ist. Eine *Confidence* von 80% sagt aus, daß vier Fünftel der Leute, die einen PC gekauft haben, auch einen Drucker dazu genommen haben.
- **Support:** Dieser Wert legt fest, wieviel Datensätze überhaupt gefunden wurden, um die Gültigkeit der Regel zu verifizieren. Bei einem Support von 1% wäre also jeder Hundertste Verkauf ein PC zusammen mit einem Drucker.