3. Von relationalen zu objekt-relationalen DBS

- Beschränkungen des relationalen Datenmodells
  - Beispiel: Modellierung von 3D-Objekten
  - Impedance Mismatch
  - Anwendungsgebiete mit besonderen Anforderungen
- Entwicklung von Datenmodellen
- NF2-Ansatz
- OODBS und ORDBS
  - Objekttypen, Kapselung
  - Generalisierung, spätes Binden
  - komplexe Objekte: Objektidentität, Typkonstruktoren
  - ORDBS-Besonderheiten

Objekt-Darstellung

- Standard-Anwendung: pro Objekt gibt es genau eine Satzausprägung, die alle beschreibenden Attribute enthält

Schema

ANGESTELLTER

Satztyp (Relation)

Ausprägungen

PNR	NAME	TAETIGKEIT	GEHALT	ALTER
496	Lange	Pfoertner	3100	53
497	Christen	Kopist	3800	45
498	Franke	Kalligraph	4500	56

Objekt-Darstellung (2)

- CAD-Anwendung: das komplexe Objekt „Werkstück“ setzt sich aus einfacheren (komplexen) Objekten verschiedenen Typs zusammen

Schema

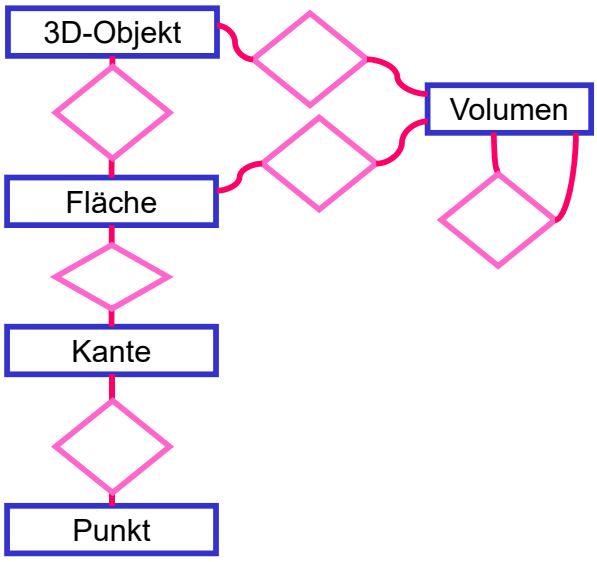

Objektausprägung

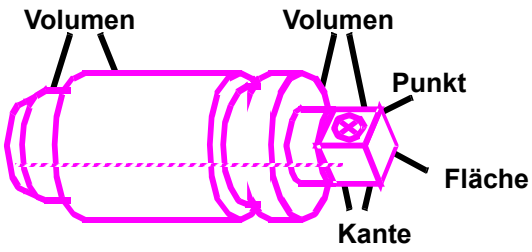

Modellierung von 3D-Objekten im ER-Modell

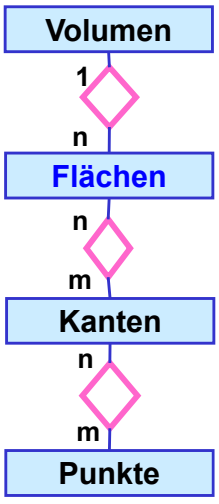

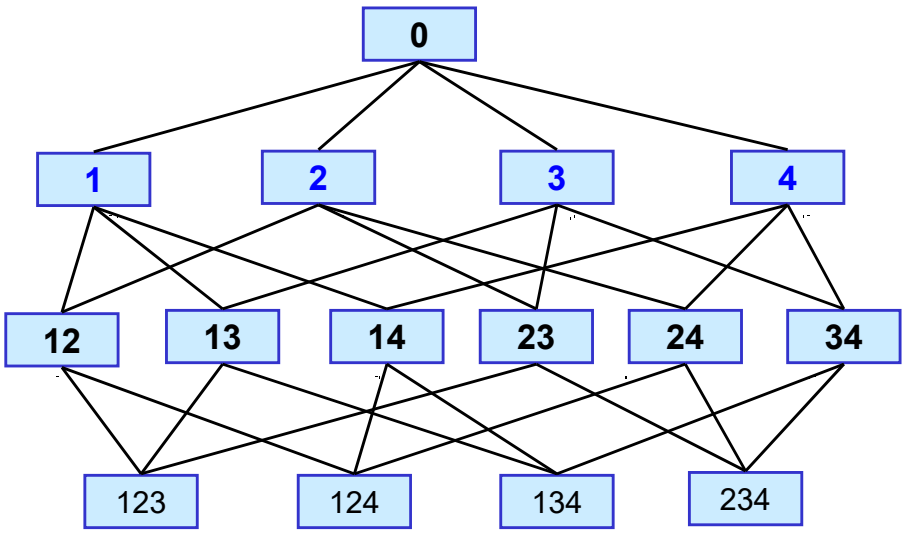

Beispiel: **Tetraeder**

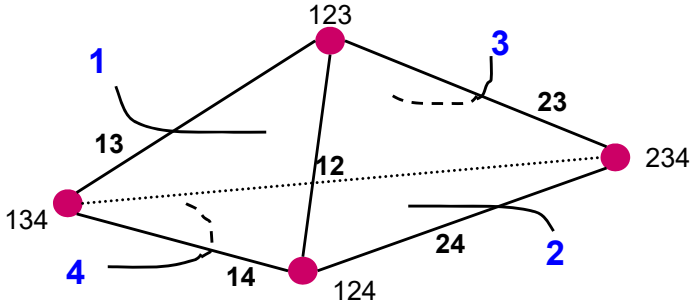

Modellierung von Polyedern im RM

UML

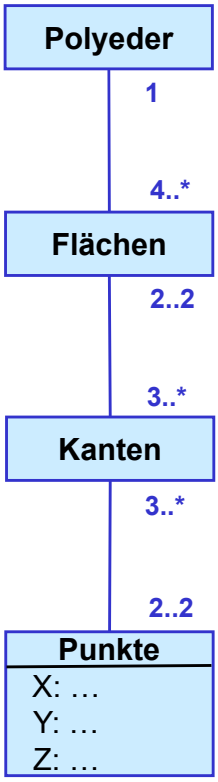

Modellierung im Relationenmodell

```
CREATE TABLE Polyeder
      (polyid:      INTEGER,
      anzflächen: INTEGER,
      PRIMARY KEY (polyid));
```

```
CREATE TABLE Fläche
      (fid:          INTEGER,
      anzkanten:  INTEGER,
      pref:          INTEGER,
      PRIMARY KEY (fid),
      FOREIGN KEY (pref)
REFERENCES Polyeder);
```

```
CREATE TABLE Kante
      (kid:          INTEGER,
      ktyp:          CHAR(5),
      PRIMARY KEY (kid));
```

```
CREATE TABLE Punkt
      (pid:          INTEGER,
      x, y, z:       FLOAT,
      PRIMARY KEY (pid));
```

```
CREATE TABLE FK_Rel
      (fid:    INTEGER,
      kid:    INTEGER,
      PRIMARY KEY  (fid, kid),
      FOREIGN KEY (fid)
        REFERENCES Fläche,
      FOREIGN KEY (kid)
        REFERENCES Kante);
```

```
CREATE TABLE KP_Rel
      (kid:    INTEGER,
      pid:    INTEGER,
      PRIMARY KEY  (kid, pid),
      FOREIGN KEY (kid)
        REFERENCES Kante,
      FOREIGN KEY (pid)
        REFERENCES Punkt);
```


Relationenmodell – angemessene Modellierung?

Darstellung eines Tetraeder mit vid = 0

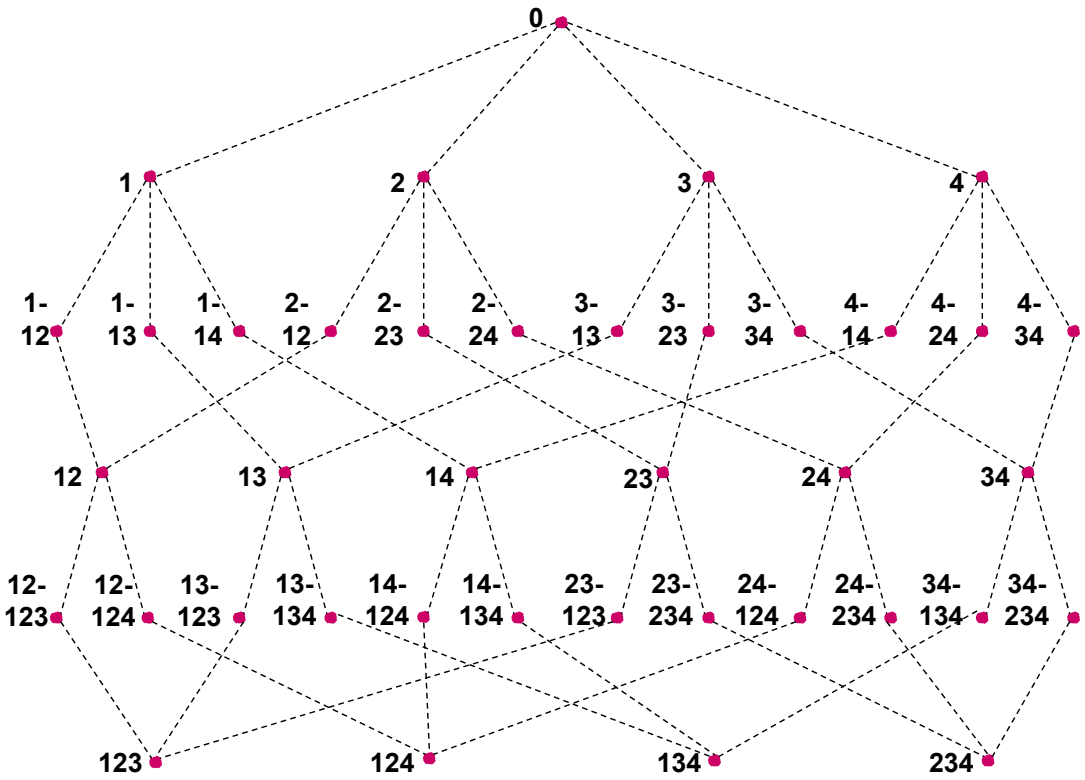

Relationen

Polyeder

Fläche

FK-Rel

Kante

KP-Rel

Punkt

Beispielanfragen

- Bestimme alle Punkte, die zu Flächenobjekten mit F.fid < 3 gehören

```
SELECT  F.fid, P.x, P.y, P.z
FROM    Fläche F NATURAL JOIN FK-Rel
                 NATURAL JOIN Kante
                 NATURAL JOIN KP-Rel
                 NATURAL JOIN Punkt P
WHERE   F.fid < 3
```

  - aufwändige Join-Anfrage zur Rekonstruktion komplexer Objekte

- Flächen, die mit Punkt (50,44,75) assoziiert sind

```
SELECT  F.fid
FROM    Punkt P NATURAL JOIN KP-Rel
                NATURAL JOIN Kante
                NATURAL JOIN FK-Rel
                NATURAL JOIN Fläche F
WHERE   P.x = 50 AND P.y = 44 AND P.z = 75
```


Impedance Mismatch

- Auseinanderklaffen von Datenbanksystem und Programmiersprachen: *"Impedance mismatch"* (Fehlanpassung)
  - "Struktur" wird durch DBS, "Verhalten" weitgehend von Anwendungsprogrammen (Programmiersprache) abgedeckt
  - unterschiedliche Datentypen und Operationen
  - Mengen- vs. Satzverarbeitung
  - unterschiedliche Behandlung transienter und persistenter Objekte
  - umständliche, fehleranfällige Programmierung

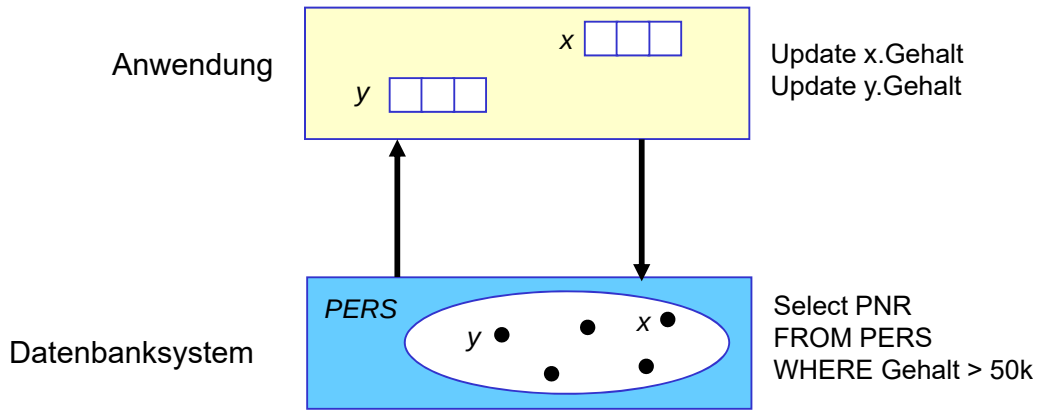

Heterogene Datenarten

- Multimedia-Daten (Bilder, Videos, Audio, Text ...)
  - großer Datenumfang und aufwändige Operationen
  - Speicherung in Dateien: fehlende Anfragemöglichkeiten, kein Transaktionsschutz ...
- Dokumente/Texte ohne feste Struktur, semistrukturierte Daten (XML, JSON)
  - erfordern unscharfe Textsuche (Homonym/Synonym-Probleme etc.), Relevanzbewertung (Precision, Recall), Ranking von Ergebnissen
  - semi-strukturierte Daten (Mischung von Text und strukturierten Daten): optionaler Schemaeinsatz
- Geoinformationssysteme: räumliche Daten und Operationen
- vernetzte Daten/Graph-Daten: schnelle Traversierung statt aufwändige Joins

…

- unterschiedliche Datenarten erfordern Speicherungs- und Auswertungsmöglichkeiten
- Erweiterbarkeit von DBS auf unterschiedliche Datenarten von Daten oder Spezialsysteme (z.B. Information-Retrieval-Systeme, NoSQL)

Wissensbasierte Anwendungen

- Verwaltung von Fakten (formatierte Daten = extensionale DB) und Regeln (intensionale DB)
  - Regeln dienen zur Ableitung von implizit vorhandenen Informationen
  - Nutzung nicht nur in KI-Anwendungen: Stücklistenauflösung, Wegeprobleme (Berechnung der transitiven Hülle)
- Hauptanforderung: effiziente Regelauswertung (Inferenz), Behandlung von Rekursion

Anfrage: ? Vorfahr (x, A)

Fakten:

F1: Elternteil(C, A) <-
F2: Elternteil (D, A) <-
F3: Elternteil (D, B) <-
F4: Elternteil (G, B)<-
F5: Elternteil (E, C) <-
F6: Elternteil (F, D) <-
F7: Elternteil (H, E) <-

Regeln:

R1: Vorfahr (x, y) <- Elternteil (x, y)
R2: Vorfahr (x, y) <- Elternteil (x, z), Vorfahr (z, y)

R3: Geschwister (x, y) <- Elternteil (z, x), Elternteil (z, y), x <>y

Beschränkungen des Relationenmodells

- nur einfach strukturierte Daten
  - einfache (Standard-) Datentypen
  - Sätze mit fester Anzahl atomarer Attribute (festes Satzformat)
- Relationenmodell ist "wertebasiert"
  - Identifikation von Daten durch Schlüsselwerte
    - häufig künstliche Schlüsselattribute zu definieren
  - Modellierung von Beziehungen über Fremdschlüssel
    - umständliche Modellierung komplexer Strukturen
- oft schlechte Effizienz für anspruchsvolle Anwendungen
  - viele Joins
- geringe Semantik
  - Benutzer muss Bedeutung der Daten/Namen kennen
  - nur einfache Integritätsbedingungen
  - keine direkte Unterstützung der Abstraktionskonzepte (Generalisierung, Aggregation)

Beschränkungen des Relationenmodells (2)

- unzureichende Spezifikation von "Verhalten" (Funktionen)
  - Verbesserung der Situation durch Stored Procedures
  - weitere Unterstützung durch benutzerdefinierte Methoden wünschenswert
- begrenzte Auswahlmächtigkeit der Anfragesprachen
  - keine Unterstützung von Rekursion (Berechnung der transitiven Hülle)
  - trotz SQL-Erweiterungen weiterhin Notwendigkeit allgemeine Programmiersprachen zu nutzen
- umständliche Einbettung in Programmiersprachen (impedance mismatch)
- auf kurze Transaktionen zugeschnitten (ACID)
  - Alles-oder-Nichts ungünstig für längere Verarbeitungsvorgänge

Entwicklung von Datenmodellen

- (logisches) Datenmodell
  - generische Datenstruktur zum Aufbau von Datenbanken (z.B. Relationen im RM)
  - Menge von Operatoren und modellinhärenten Integritätsbedingungen auf Datenstruktur
- grobe historische Entwicklung:

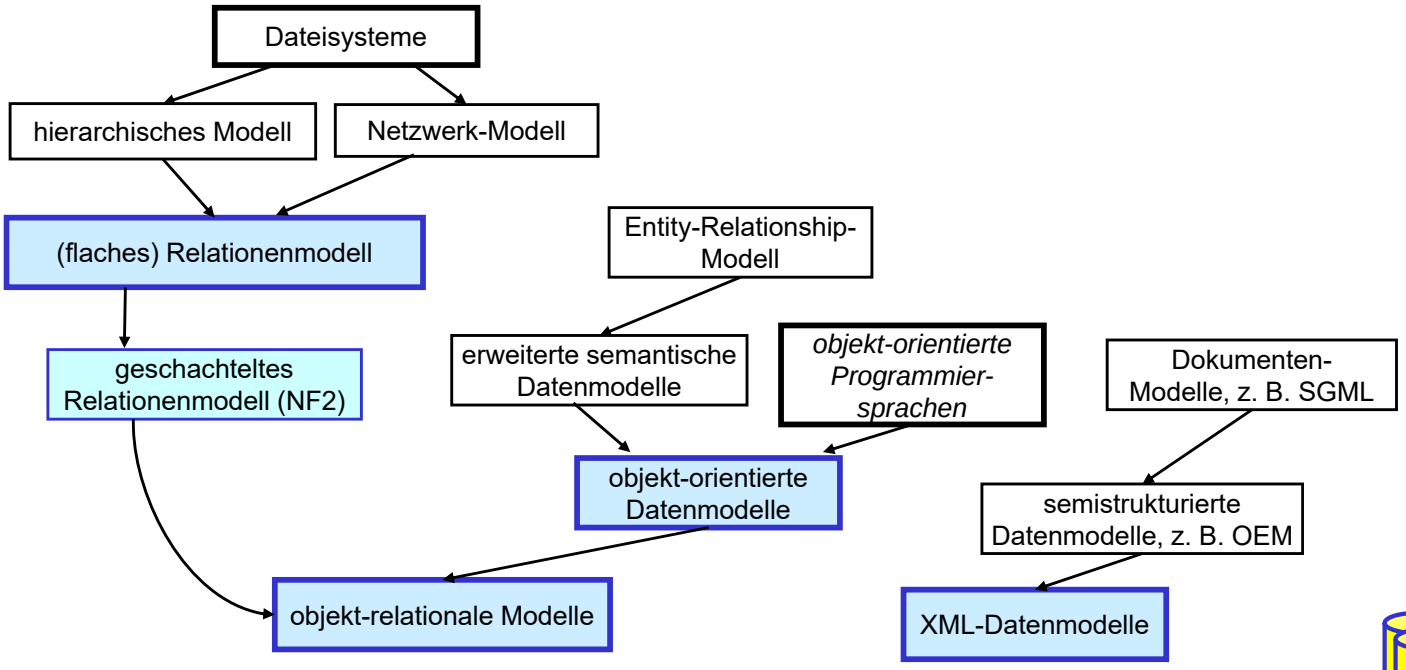

NF2-Modell

- Non-First Normal Form (NF^2)
  - wie Relationenmodell, jedoch können Attributwerte auch Relationen (Mengen von Tupeln) sein
  - unnormalisierte, geschachtelte Relationen (’nested relations’)
- Polyeder-Beispiel

```
CREATE  TABLE Volumen (
        VId             INT,
        Bez             CHAR(20),
        AnzFlaechen     INT,
        Flaechen        SET ( ROW ( FId          INT,
                                    AnzKanten    INT,
                                    Kanten SET (ROW (  Kid      INT,
                                                       Punkte SET (ROW (  PId  INT,
                                                                          X    INT,
                                                                          Y    INT,
                                                                          Z    INT ) )
                                                    ) )
                                    ) )
    )
```

SET *Mengenkonstruktor,* ***ROW*** *Tupelkonstruktur*

NF²-Ausprägung (1 Tupel)

Volumen							
Vld	Bez	Flaechen					
		Fld	Kanten				
			Kld	Punkte			
				Pld	X	Y	Z
0	Tetraeder	1	12	123	0	0	0
				124	100	0	0
			13	123	0	0	0
				134	50	44	75
			14	124	100	0	0
				134	50	44	75
		2	12	123	0	0	0
				124	100	0	0
			23	123	0	0	0
				234	50	87	0
			24	124	100	0	0
				234	50	87	0
		3	13	123	0	0	0
				134	50	44	75
			23	123	0	0	0
				234	50	87	0
			34	134	50	44	75
				234	50	87	0
		4	14	124	100	0	0
				134	50	44	75
			24	124	100	0	0
				234	50	87	0
			34	134	50	44	75
				234	50	87	0

NF2-Modell: Operatoren

- erweiterte relationale Algebra
  - Erweiterung von Projektion, Selektion und Join auf geschachtelte Strukturen
- NEST-Operation
  - Erzeugen geschachtelter Relationen aus flachen Relationen
  - $NEST_{A1,A2,\ldots An:\ A}(R)$ fasst Attribute *A1, … An* zu neuem Attribut *A* zusammen, d.h. A entspricht SET (ROW (A1, A2, … An))
  - mehrere (*A1, …, An*)-Tupel werden dabei zu einer Menge zusammengefasst, wenn die Werte der Tupel auf den anderen R-Attributen *An+1, … Am* übereinstimmen (entspricht einem SQL Group-By auf *An+1, … Am)*

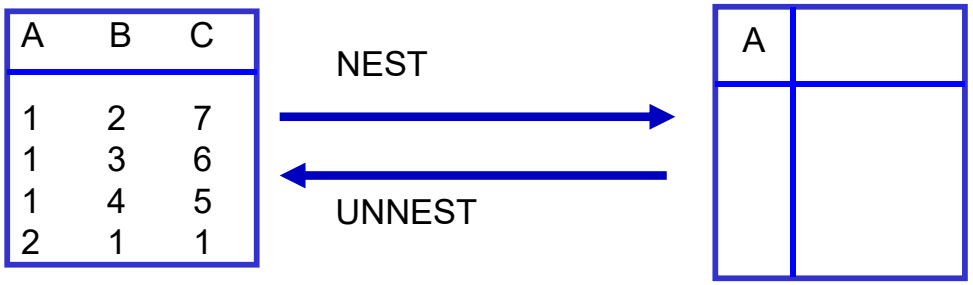

NF2-Modell: Operatoren (2)

- UNNEST-Operation
  - Normalisierung ("Flachklopfen") geschachtelter Relationen
  - $UNNEST_{A:A1, \ldots An}$ (R) überführt tabellenwertiges Attribut A = SET(ROW(A1, ..., An)) in Menge einfacher Attribute A1, … An
  - $UNNEST_{\mathbf{A: A1 \ldots An}}$ ($NEST_{\mathbf{A1,A2, \ldots An: A}}$ (R)) = R
- NEST und UNNEST sind dennoch i. a. nicht invers zueinander !
  - somit i.a. NEST (UNNEST (R)) R

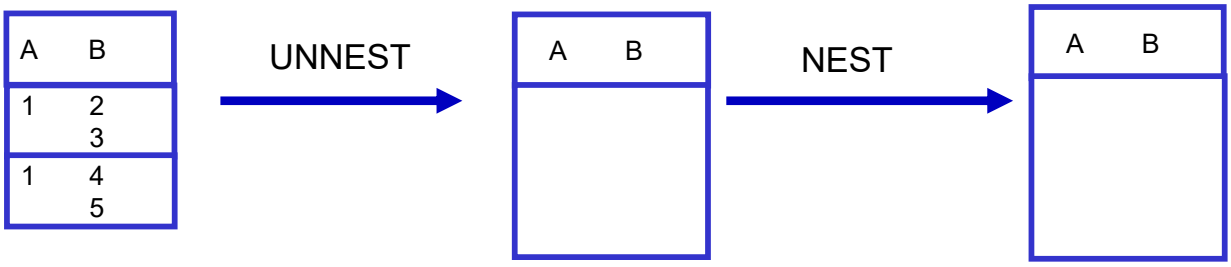

NF2-Modell: Operatoren (3)

- erweiterter natürlicher Join

R1

A	B	X	
		C	D
a1	b1	c1	d1
		c2	d2
		c1	d3
a2	b2	c1	d2
		c3	d2

E	B	X	
		C	D
e1	b1	c1	d1
		c1	d3
		c3	d4
e3	b2	c3	d2

R2

- zwei Join-Semantiken für tabellenwertige Join-Attribute
  a) vollständige Übereinstimmung der Tabellenwerte für Verbundtupel
  b) nur tupelweise Übereinstimmung

R1 ⋈ R2

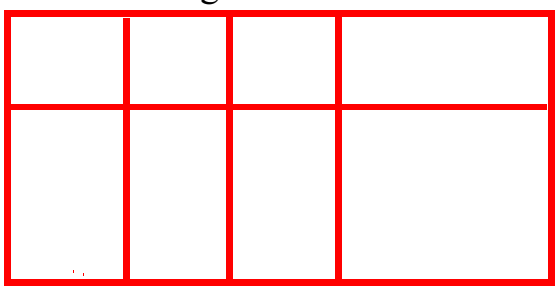

Bewertung des NF2-Modells

- Vorteile:
  - einfaches Relationenmodell als Spezialfall enthalten
  - Unterstützung komplex-strukturierter Objekte / Clusterung
  - reduzierte Join-Häufigkeit
  - sicheres theoretisches Fundament (NF2-Algebra)
- Nachteile:
  - überlappende/gemeinsame Teilkomponenten (n:m-Beziehungen) führen zu Redundanz
  - unsymmetrischer Zugriff
  - rekursiv definierte Objekte nicht zulässig
  - keine Unterstützung von Generalisierung und Vererbung
  - keine benutzerdefinierten Datentypen und Operationen

OODBS und ORDBS

- objekt-orientierte Datenverwaltung erfordert
  - Modellierung der Struktur (komplexe Objekte, Vererbung) +
  - Verhalten (abstrakte/benutzerdefinierte Datentypen, Methoden)

- 2 Ansätze
  - Anreicherung von objekt-orientierten Programmiersprachen um DB-Eigenschaften (Persistenz, Integrität, ...) -> *persistente Programmiersprachen / objekt-orientierte DBS (OODBS)*
  - Anreicherung von DBS um objekt-orientierte Konzepte -> *objekt-relationale DBS (ORDBS)*

Definition eines objekt-orientierten DBS

- OODBS muss DBS + objekt-orientiertes System sein
- *DBS-Aspekte:* Persistenz, Datenunabhängigkeit, Transaktionsverwaltung, Ad-Hoc-Anfragesprache
- OOS-Aspekte:
  - Objekttypen, Kapselung
  - Typ-/Klassenhierarchie mit Methoden, Vererbung, Überladen und spätes Binden
  - Objektidentität, komplexe Objekte
  - operationale Vollständigkeit
- OODBS (im Unterschied zu ORDBS)
  - Erweiterung objektorientierter Programmierung um DB-Sprache
  - Beseitigung des "impedance mismatch"/ bessere Effizienz
  - einheitliche Verwaltung transienter und persistenter Objekte
  - effiziente Traversierung komplexer (persistenter) Objektstrukturen

Objekttypen / Kapselung

- Objekt = Struktur + Verhalten + OID
- Spezifikation durch Objekttyp / Klasse
  - Struktur: Attribute und ihre Wertebereiche
  - Verhalten: zulässige Operationen / Methoden
- Objekt = Instanziierung eines Typs mit konkreten Wertebelegungen der Attribute
- strenge Objekt-Orientierung verlangt Kapselung (Information Hiding)
  - Verhalten des Objektes ist ausschließlich durch seine Operationen (Methoden) bestimmt
  - nur Namen und Signatur (Argumenttypen, Ergebnistyp) von Operationen werden bekannt gemacht
  - Struktur von Objekten wird verborgen
  - Implementierung der Operationen bleibt verborgen

PERS
PNAME: STRING GEHALT: INT GEBDATUM: DATUM
INT Alter ()

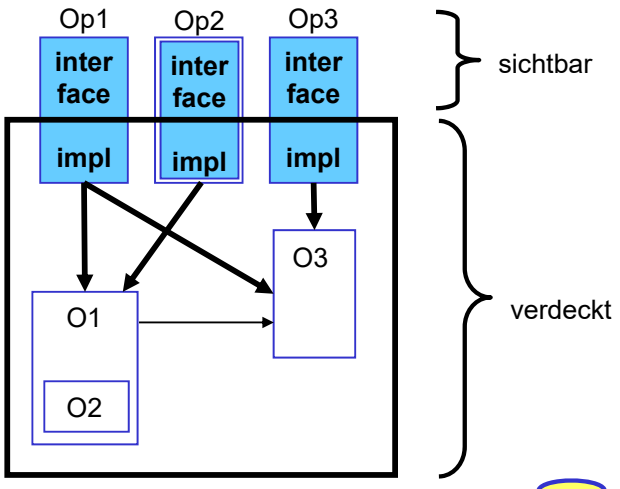

Kapselung (2)

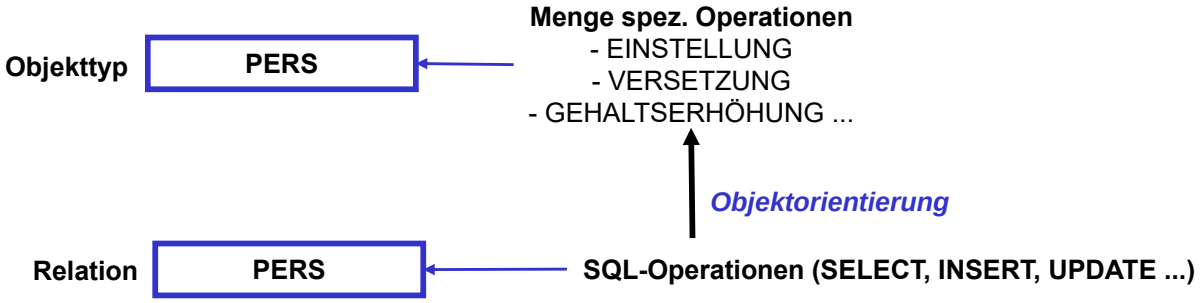

- Verwaltung von Objekttypen und Operationen im DBS
  - zusätzliche Anwendungsorientierung im DBS gegenüber Stored Procedures
  - verringerte Kommunikationshäufigkeit zwischen Anwendung und DBS
  - Reduzierung des "impedance mismatch"
- Vorteile der Kapselung: höherer Abstraktionsgrad
  - logische Datenunabhängigkeit, Datenschutz
- aber: strikte Kapselung oft zu restriktiv (unflexible, keine Ad-Hoc-Anfragen)
- Kompromiss: Zugriff aus ausgewählte Attribute durch get/put-Methoden

Generalisierung

- Generalisierungs-/Spezialisierungshierarchie (IS-A-Beziehung)
  - Vererbung von Attributen, Methoden, Integritätsbedingungen ...
  - Arten der Vererbung: einfach (Hierarchie) vs. mehrfach (Typverband)
  - Prinzip der *Substituierbarkeit*: Instanz von Subklasse kann in jedem Kontext verwendet werden, in dem Instanzen der Superklasse möglich sind (jedoch nicht umgekehrt)
    - impliziert, dass Klasse heterogene Objekte enthalten kann

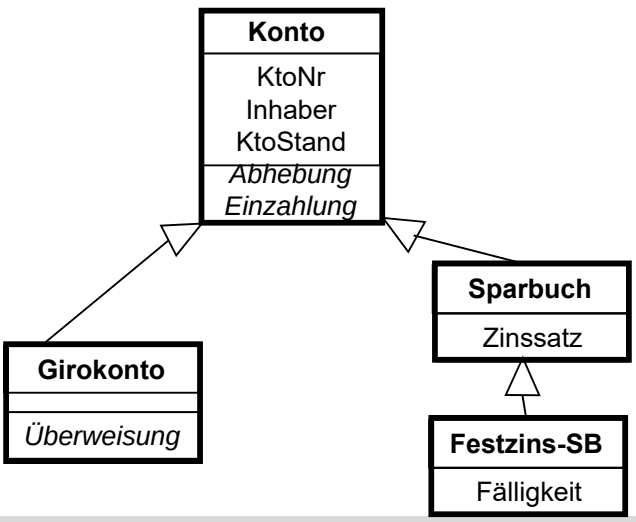

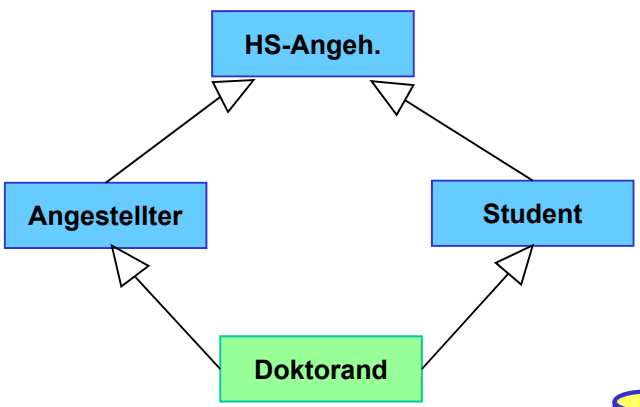

Überladen (Overloading)

- derselbe Methodenname wird für unterschiedliche Prozeduren verwendet (polymorphe Methoden)
  - erleichtert Nutzung und verbessert Software-Wiederverwendbarkeit
- Overloading innerhalb von Typ-Hierarchien:
  - Redefinition von Methoden für Subtypen (Overriding)
  - spezialisierte Methode mit gleichem Namen
- Überladen impliziert dynamisches (spätes) Binden zur Laufzeit (*late binding*)

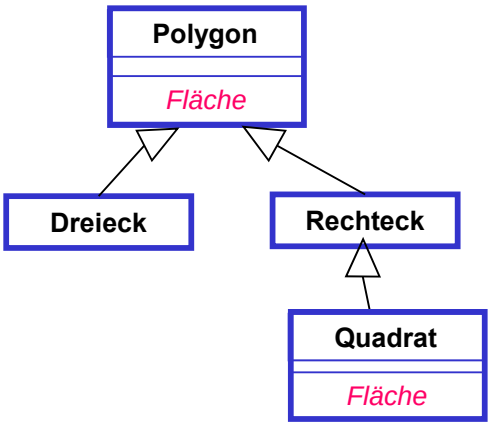


```
Quadrat q;
Rechteck r;
…
Polygon p1 = q;
Polygon p2 = r;
…
double f1=p1.Fläche();
double f2=p2.Fläche();
```


Objektidentität

- OODBS: Objekt = (OID, Zustand, Operationen)
  - OID: Identifikator
  - Zustand: Beschreibung mit Attributen
  - Operationen (Methoden): definieren externe Schnittstelle

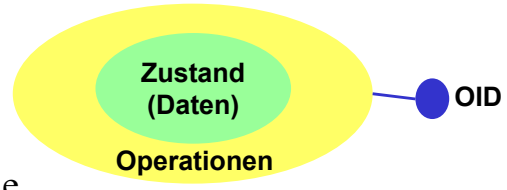

- Objektidentität
  - systemweit eindeutige Objekt-Identifikatoren
  - OID während Objektlebensdauer konstant, üblicherweise systemverwaltet
  - OID tragen keine Semantik (<-> Primärschlüssel im RM)
  - Änderungen beliebiger Art (auch des Primärschlüssels im RM) ergeben *dasselbe* Objekt
- Vorteile gegenüber „wertebasiertem“ Relationenmodell
  - Trennung von Identität und (Werte) Gleichheit (OID- vs. Zustandsübereinstimmung)
  - keine Notwendigkeit künstlicher Primärschlüssel
  - Beziehungen realisierbar über stabile OID-Referenzen anstelle von Fremdschlüsseln
    - einfachere Realisierung komplexer (aggregierter) Objekte
    - effizienterer Zugriff auf Teilkomponenten (ohne Joins)

OIDs: Komplexe Objekte

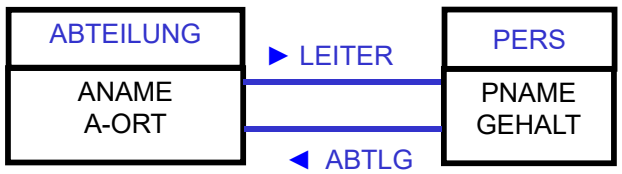

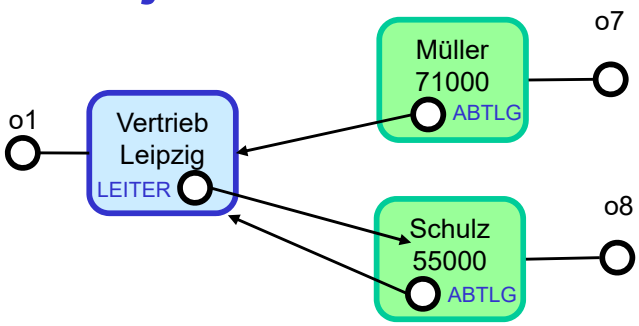

class ABT (ANAME: STRING,
A-ORT: STRING,
LEITER: REF (PERS) ...

class PERS (PNAME: STRING,
GEHALT: INT,
ABTLG: REF (ABT) (* Referenz-Attribut *) ...

- Realisierung von Beziehungen über OIDs (Referenz-Attribute)
  - Objekt-Ids / Referenzen erlauben Bildung komplexer Objekte bestehend aus Teilobjekten
  - gemeinsame Teilobjekte ohne Redundanz möglich (referential sharing)

- implizite Dereferenzierung über *Pfadausdrücke* anstatt expliziter Verbundanweisungen

  p->ABTLG.A-ORT (p sei PERS-Objekt)

  a->LEITER.PNAME (a sei ABTEILUNG-Objekt)

Komplexe Objekte: Typkonstruktoren

- Relationenmodell
  - nur einfache Attribute, keine zusammengesetzte oder mengenwertige Attribute
  - nur zwei Typkonstruktoren: Bildung von Tupeln und Relationen (Mengen)
  - keine rekursive Anwendbarkeit von Tupel- und Mengenkonstruktoren

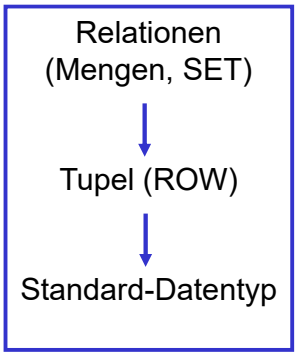

- OODBS
  - Objekte können Teilobjekte enthalten (Aggregation):
    - eingebettet (Komposition, Wertesemantik)
      - einfache Attribute (Standardtypen: Integer, Char, ...)
      - über Typkonstruktoren strukturierte / zusammengesetzte Attribute
      - Instanzen von (benutzerdefinierten) Objekttypen
    - Referenzen (über OID) auf benutzerdefinierte Objekttypen (Referenzsemantik)
    - Kombinationen

Komplexe Objekte: Typkonstruktoren

- Typkonstruktoren zum Erzeugen strukturierter (zusammengesetzter) Datentypen aus Basistypen
  - TUPLE (ROW, RECORD)
  - SET, BAG (MULTISET)
  - LIST (SEQUENCE), ARRAY (VECTOR)

- SET/BAG/LIST/ARRAY verwalten homogene Kollektionen: Kollektionstypen

Typ	Duplikate	Ordnung	Heterogenität	#Elemente	Elementzugriff über
TUPLE	JA	JA	JA	konstant	Namen
SET	NEIN	NEIN	NEIN	variabel	Iterator
BAG	JA	NEIN	NEIN	variabel	Iterator
LIST	JA	JA	NEIN	variabel	Iterator / Position
ARRAY	JA	JA	NEIN	konstant	Index

Komplexe Objekte: Beispiel

- UML-Darstellung

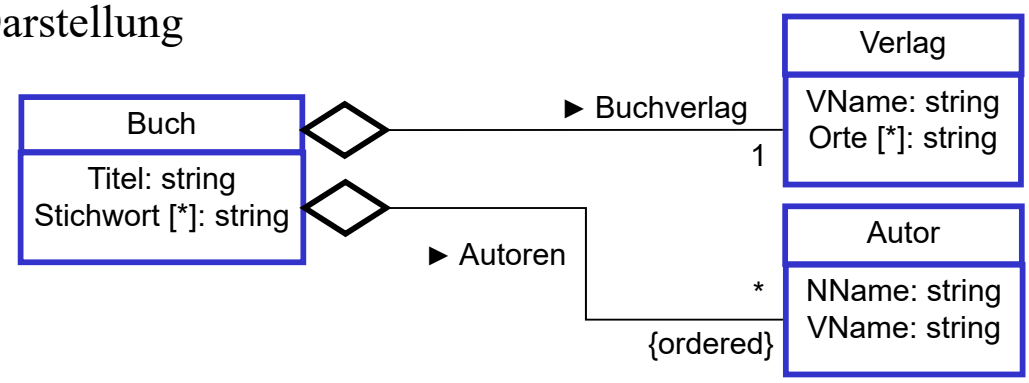

- Verwendung von Typkonstruktoren:

class AUTOR (NName, VName: string)

class VERLAG (VName: string,
Orte: SET (string))

class BUCH (Titel: string,
Stichwort: SET (string),
Buchverlag; REF (VERLAG),
Autoren: LIST (REF (AUTOR)))

Vergleich Datenmodelle

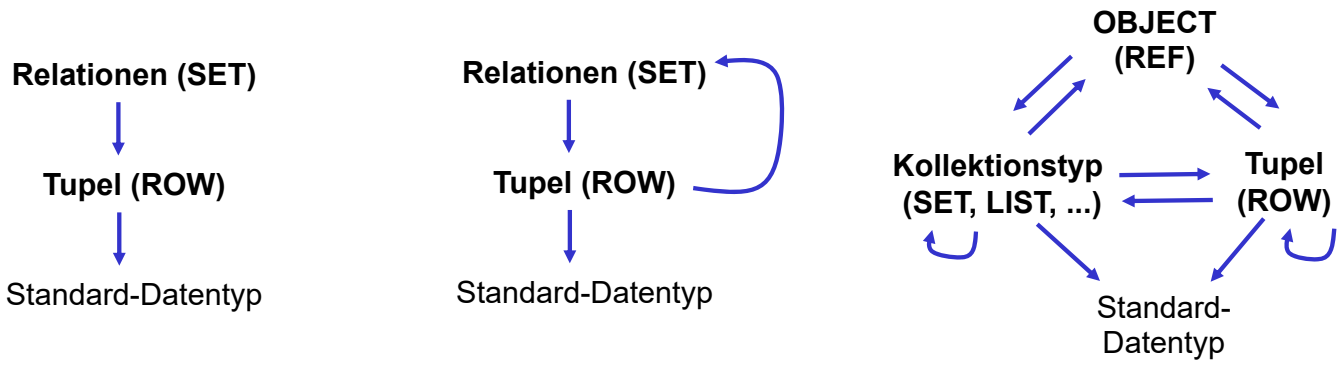

- Ziel: beliebige (rekursive) Kombinierbarkeit der Typkonstrukturen
- OODBS-Standardisierung erfolgte im Rahmen der ODMG (Object Data Management Group): www.odmg.org

Objekt-relationale DBS: Merkmale

- Erweiterung des relationalen Datenmodells um Objekt-Orientierung
- Bewahrung der Grundlagen relationaler DBS, insbesondere deklarativer Datenzugriff (Queries), Sichtkonzept etc.
- alle Objekte müssen innerhalb von Tabellen verwaltet werden
- Standardisierung von ORDBS v.a. in SQL:1999 und SQL:2003
- komplexe, nicht-atomare Attributtypen (z.B. relationenwertige Attribute)
- erweiterbares Verhalten über gespeicherte Prozeduren und benutzerdefinierte Datentypen und Funktionen

Grobvergleich nach Stonebraker

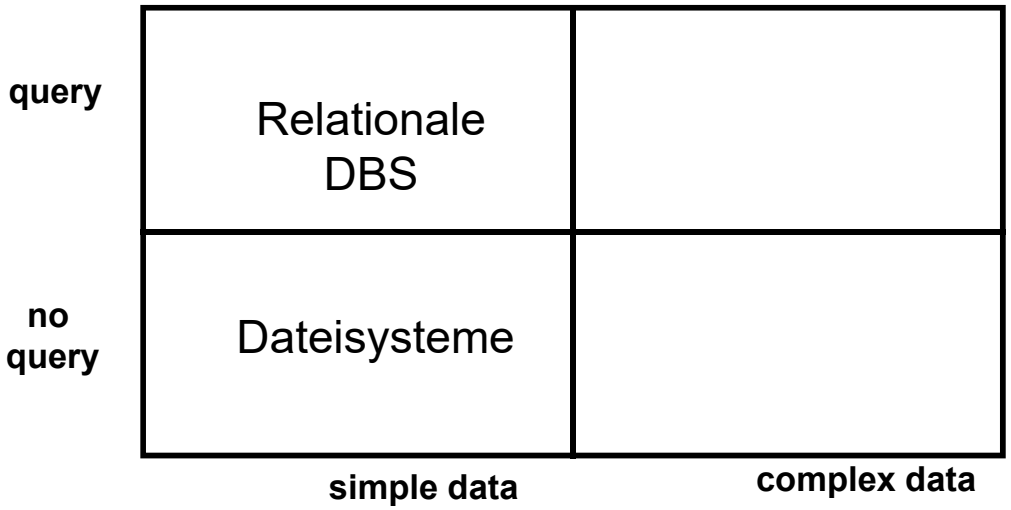

- kein Systemansatz erfüllt alle Anforderungen gleichermaßen gut
  - relationale DBS: einfache Datentypen, Queries, ...
  - OODBS: komplexe Datentypen, gute Programmiersprachen-Integration, hohe Leistung für navigierende Zugriffe
  - ORDBS: komplexe Datentypen, Querying ...
- OODBS haben keine Marktbedeutung mehr -> ORDBS

Zusammenfassung

- RM ist auf einfache strukturierte Daten beschränkt
  - unzureichende Unterstützung für komplexe Objekte, keine Erweiterbarkeit für neue Datenarten …
- OODBS und ORDBS unterstützen
  - komplexe Objekte und Objektidentität
  - Typhierarchien und Vererbung
  - Erweiterbarkeit bezüglich Objekttypen und Verhalten
- strikte Kapselung zu inflexibel (Ad-hoc-Anfragemöglichkeit wichtig)
- ORDBS
  - Erweiterung des RM / SQL um objekt-orientierte Konzepte
  - NF2 erweitert Relationenmodell, jedoch unzureichend
- OODBS haben keine Marktbedeutung mehr
  - ermöglichten einheitliche Verarbeitung transienter und persistenter Daten, effiziente Navigation für komplexe Objekte
  - Teile der Eigenschaften über O/R-Mappingsoftware (z.B. Hibernate)