

## Kapitel 9

# Schemaabbildung und -integration

---

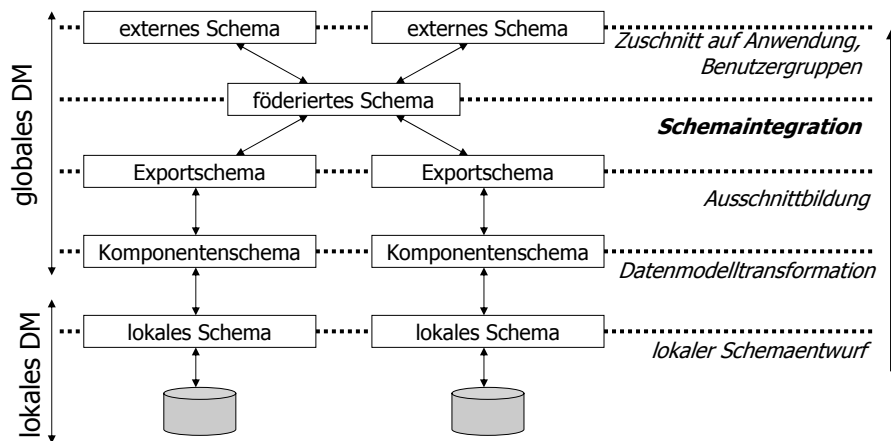
## Schemaintegration

---

- Datenintegration als ein wesentlicher Aspekt der Entwicklung neuer, globaler Informationssysteme
  - Randbedingung: Autonomie der beteiligten lokalen Systeme soll erhalten bleiben
- Verschiedene Systemarchitekturen möglich
  - Föderiertes DBS
    - logische Datenintegration
    - Föderierungsdienst integriert lokale Komponentensysteme in ein Gesamtsystem
    - Einheitlicher Zugriff auf integrierten Datenbestand
  - Data Warehouse
    - physische Datenintegration
    - Daten aus verschiedenen Quellsystemen werden in ein gemeinsames Format kopiert
    - komplexe Auswertung und Analyse auf integriertem und aufbereitetem Datenbestand
- Schemaintegration<sup>(1)</sup> ist ein zentrales Problem

<sup>(1)</sup>S. Conrad: *Schemaintegration: Integrationskonflikte, Lösungsansätze, aktuelle Herausforderungen*, in Informatik Forschung und Entwicklung 17(3), 2002.

# Schema-Referenzarchitektur



# Komponenten der Schema-Referenzarchitektur

- **Lokales Schema**
  - entspricht dem konzeptionellen Schema der lokalen Datenbank
  - basiert auf lokalem Datenmodell
- **Komponentenschema**
  - Beschreibung der lokalen Datenbank in globalem Datenmodell
  - Überwindung der DM-Heterogenität
- **Exportschema**
  - Beschreibung des Ausschnitts der lokalen Daten, die für globale Anwendungen zur Verfügung stehen sollen
  - Festlegung in der Praxis oft lokal durch das Komponentensystem getroffen
    - "Vertauschen" von Exportschema und Komponentenschema
- **Föderiertes Schema**
  - beschreibt die Gesamtheit des föderierten Datenbestandes
  - wird durch Schemaintegration gebildet
- **Externes Schema**
  - entspricht dem klassischen ext. Schema für das föderierte System

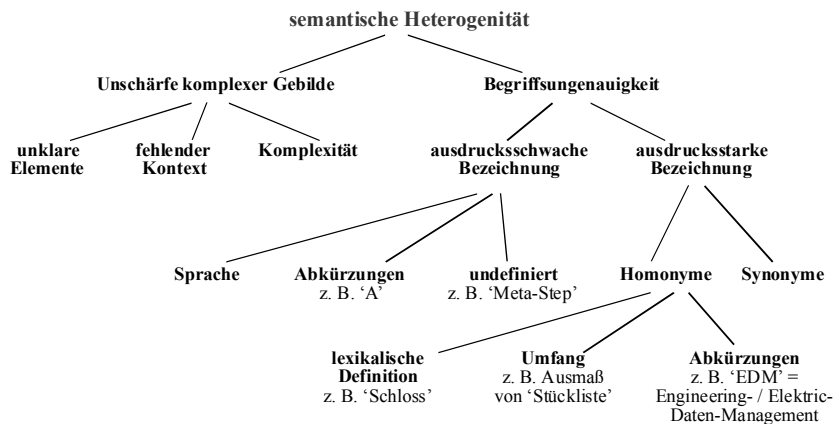
# Integrationskonflikte

siehe:

Theo Härder, Günter Sauter, Joachim Thomas: *The Intrinsic Problems of Structural Heterogeneity and an Approach to Their Solution*. VLDB Journal 8(1): 25-43 (1999)


## Semantische Heterogenität

- Bezieht sich auf Modellierungsinhalte



## Strukturelle Heterogenität

- Bezieht sich auf die jeweils zur Verfügung stehenden Modellierungskonstrukte
- Szenario



- Q1, ... Qn Quell-DBS, Legacy oder Anwendungssysteme
- Z Integrierte/heterogene Sicht (Zielschema bzw. -system)
- Q1, ... Qn → Z Schema-Integration (Datentransfer nach Anfrage)
- Z → Q1, ... Qn Propagierung von Änderungen
- Z → Z' Migration


- Schemata sind *kongruent*, wenn sie semantisch identische Objekttypen und Eigenschaften beinhalten
  - meist inkongruent, überlappend
  - Kongruenzeigenschaft zwischen Quell- und Zielschema (*vertikal*) oder zwischen versch. Quellschemata (*horizontal*)

## Probleme der strukturellen Heterogenität


- Problembereiche
  - Elementare Abbildungsprobleme
  - Probleme durch den Einsatz objektorientierter Datenmodelle
  - Abbildungskardinalität
  - Schemakardinalität
  - Weitere Probleme
- Ausgangsszenario (Betrachtung elementarer Probleme)
  - homogene, relationale Schemata
  - transiente Verwaltung der Zieldaten
  - unidirektionale (1:1)-Beziehung:  $Q \rightarrow Z$

## Vertikale Kongruenz

- Projektion: Z beschreibt kleineren Ausschnitt des Anwendungsbereichs als Q
  - View-Update-Problematik
  - Beispiel:




- Q beschreibt kleineren Ausschnitt als Z
  - häufig bei integrierten Sichten
  - Beispiel:




## Vertikale Datenverteilung

- Z verwaltet mehr Daten als Q
  - z. B. abgeleitete Attribute, die in Q nicht enthalten
  - Beispiel: in Q Nullwerte für Preis erlaubt, nicht jedoch in Z



- Selektion: Z erfasst weniger Daten als Q
  - über Prädikate zu erfassen
  - Beispiel




Prädikat: "nur Konstruktionsbereiche 'A' und 'B' aus Q"

# Datentypkorrespondenz

- Unterstützung unterschiedlicher Datentypen durch Q und Z
- Problem: finde Abbildung, die semantikerhaltende Rücktransformation erlaubt
  - Beispiel: REAL (Q)  $\rightarrow$  INTEGER (Z) durch Rundung (genaue Rücktransformation nicht möglich)
  - generell: korrekte und vollständige Transformation von Daten eines semantisch mächtigeren Modells in ein semantisch ärmeres Modell kann nicht durchgeführt werden!

# Attributkorrespondenz


- Zusammenhang zwischen Attributen aus Q und Z
  - Verknüpfung/Aggregation 'nach' Z
  - Trennung 'nach' Q ?
  - bedingte Abbildung (sowohl bzgl. der Zuordnung der Attribute als auch bzgl. der Abbildung der Werte)
- Beispiel für (n:m)-Zusammenhang



- i.a. komplexe Berechnungsfunktionen notwendig für die Umrechnung von Q 'nach' Z
- (komplexe) Berechnungsfunktionen für die Umrechnung von Z 'nach' Q ?

## Entitykorrespondenz


- (n:1)-Zusammenhang zwischen Entities aus Q und Z
  - Instanzen aus Q, die einem Entity in Z entsprechen, müssen identifiziert werden können
- (1:n)-Zusammenhang zwischen Entities aus Q und Z



- kontextabhängige Abbildung ( $Q \rightarrow Z$ ): Endpunkte können nur im entsprechenden 'Kabel'-Kontext (in Z) instanziiert werden
- Verdrängungsabhängigkeit ( $Z \rightarrow Q$ ): in Z könnte für ein Kabel nur ein Endpunkt instanziiert sein; dann kann keine korrespondierende Leitungsinstantz in Q erzeugt werden
- (n:m)-Zusammenhang: alle Probleme können auftreten


## Vernetzung von Quellkonstrukten

- abhängige Quellentities
- vgl. Entitykorrespondenz
- besondere Mechanismen der Abbildung notwendig bei (n:1)-Abbildung (Zielentity entsteht durch Join)



## Vernetzung von Zielentities


- abhängige Zielentities
- bei Abbildung vernetzter Quellstrukturen in vernetzte Zielstrukturen können die Referenzen voneinander abweichen
  - z. B. können (gerichtete) Beziehungen invertiert sein
  - Beziehungstypen zwischen Entities in Q können auf Beziehungstypen zwischen 'anderen' Entities in Z abgebildet werden



- Anmerkung: dieses Problem tritt häufig bei Abbildungen zwischen normalisierten relationalen und objektorientierten Schemata auf

## Identitätskonflikt


- Durch Einsatz objektorientierter Datenmodelle
- ID-erhaltende Abbildung
  - nicht möglich, falls (n:m)-Verhältnis zwischen Instanzen aus Q und Z mit  $n < m$
- ID-erzeugende Abbildung
  - Erzeugung der ID bei Erzeugung von Instanz in Z
  - Zuordnung von neuen IDs zu Instanzen in Z muss jedoch dokumentiert werden, um Propagierungen zu ermöglichen
- hybride Abbildung
  - sowohl ID-erhaltende als auch ID-erzeugende Abbildung
  - Beispiel





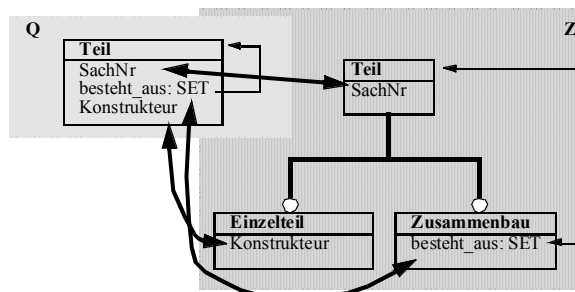
## Abbildung mengenwertiger Attribute

- Durch Einsatz objektorientierter Datenmodelle
- unterschiedliche Sortierung in Kollektionen erfordert die Beachtung der entsprechenden Sortierprädikate bei der Transformation
- falls geordnete Kollektion aus Q in ungeordnete Kollektion in Z transformiert wird, kann Propagierung unmöglich gemacht werden
- Abbildung einer Instanz mit einem mengenwertigen Attribut in mehrere Instanzen mit jeweils einwertigem (korrespondierendem) Attribut
- Nest-/Unnest-Operationen notwendig
- Beispiel:




## Abbildung von Abstraktionskonzepten

- Durch Einsatz objektorientierter Datenmodelle
- Darstellung gleicher Sachverhalte auf unterschiedlichen Abstraktionsebenen
- Beispiel: Datenebene vs. Typebene



## Abbildung von Abstraktionskonzepten (2)

- Beispiel: Datentypenebene vs. Objektebene



## Dynamische Aspekte und Integritätsbedingungen


- zu berücksichtigen: Seiteneffekte von Funktionen, Rückgabewerte von Methoden, Repräsentation der Zeit, unterschiedliche Programmiersprachen, ...
- Abbildung nicht automatisierbar !

# Abbildungskardinalität


- in bisheriger Diskussion Annahme der unidirektionalen Abbildung
  - bzw. impliziter Definition der Rücktransformation
  - hier jedoch Einschränkungen wie bei View-Update
  - evtl. mit speziellen Vorkehrungen für Rücktransformation
- bidirektionale Abbildung
  - $Q \rightarrow Z$  und  $Z \rightarrow Q$
  - explizite Definition der Rücktransformation

# Abbildungskardinalität (Forts.)

- bidirektionale Abbildung
  - Beispiel: mögliche Semantik bei Änderung des Attributs `erstellt_von` in Z



- Beispiel: Checkin-Abhängigkeit



## Schemakardinalität

- In der bisherigen Diskussion Annahme der Zuordnung genau eines Quellschemas zu genau einem Zielschema (Schemaabbildung)
- Nun: mehrere Quellschemata zu einem Zielschema (Schemaintegration)
- Horizontale Kongruenz
  - **identische** Anwendungsbereiche
    - semantisch gleiche Information, aber unterschiedliche Darstellungsformen und unterschiedliche ID (Entity-Identifikationsproblem)
    - Problem der DB-übergreifenden Konsistenz
  - **teilweise überlappende** Anwendungsbereiche
    - nicht alle Informationen können in der integrierten Sicht dargestellt werden
    - impliziert Projektion von Elementen der Quellschemata
    - höhere Wahrscheinlichkeit der Verwendung unterschiedlicher Darstellungsformen und ID in den  $Q_i$
  - **disjunkte** Anwendungsbereiche
    - Integration wenig sinnvoll

## Horizontale Datenverteilung

- disjunkte Verteilung der Daten auf die  $Q_i$ 
  - es sind Prädikate zu spezifizieren, anhand derer abgeleitet werden kann, auf welche  $Q_i$  neu erzeugte Instanzen aus  $Z$  zu propagieren sind
- replizierte Verteilung der Daten auf die  $Q_i$ 
  - es ist zu beachten, dass Daten unterschiedlich strukturiert und identifiziert werden können
- teilweise überlappende Verteilung der Daten auf die  $Q_i$ 
  - Vorkehrungen der beiden vorgenannten Punkte sind zu beachten
  - beim Integrationsprozess müssen Daten zusammengefügt werden

## Weitere Probleme

---

- Dauerhaftigkeit von Zieldaten
  - bisher Annahme der transienten Verwaltung der Zieldaten
  - persistente Datenhaltung in Z in der Regel nur zur Datenmigration
  - dabei in der Regel nur unidirektionale Abbildung und keine Propagierung
- Heterogenität von Datenmodellen
  - unterschiedliche Mächtigkeit kann zum Verlust von Information führen
- Datenstrukturierungsgrad
  - bisher Annahme der Nutzung von 'strukturierten' Quellsystemen mit 'generischen' Schnittstellen ('strukturiert' heißt: es gibt ein Schema; 'generisch' heißt: Datenzugriffsschnittstelle ist unabhängig von der Semantik der Daten)
  - bei semi-strukturierten Daten (z. B. ADTs, HTML) oder unstrukturierten Daten trifft dies nicht zu
    - hier ist keine Schemaintegration möglich
    - lediglich operationale, wrapper-basierte Abbildung

## Schemaintegrationstechniken

---

# Schemaintegrationstechniken

- **Zusicherungs-basierte Schemaintegration**
  - **Zusicherungen: Inter-Schema-Korrespondenzen**
    - beschreiben welche Schemabestandteile in Beziehung zueinander stehen
  - **Integrationsregeln**
    - bestimmen wie die korrespondierenden Bestandteile in das integrierte Schema eingebracht werden
- **Integration von Klassenhierarchien mit Upward Inheritance**
  - Erweiterung der zusicherungs-basierten Schemaintegration
- **Generic Integration Model – GIM**
  - Analyse extensionaler Beziehungen zwischen Objekttypen/-klassen der Schemata
  - Zerlegung der Klassen in sog. Basisextensionen
- **Multidatenbanksprachen**
  - Sichtenbildung als Integrationsmittel
- **Abbildungssprachen**
  - Beschreibung der Abbildung zwischen Schemata und Konfliktlösungs-schritte in deklarativer oder prozeduraler Form

# Zusicherungs-basierte Schemaintegration

- **Grundidee**
  - Beschreibung von paarweisen Beziehungen zwischen Elementen der Schemata als Inter-Schema-Korrespondenzen
  - Integrationsregeln für die zu Verfügung stehenden Korrespondenzformen bestimmen das Auftreten im integrierten Schema
  - Korrespondenzen entsprechen datenquellenübergreifende Integritätsbedingungen
    - Garantie durch das System?
- **Generisches Datenmodell als Grundlage**
  - **Bestandteile**
    - Objekttypen (und Extensionen)
    - wertbasierte Attribute
    - Links (Referenzattribute)
  - **abstrahiert von spezifischen Datenmodellen**
    - Besonderheiten der spezifischen Datenmodelle werden jedoch nicht vollständig abgedeckt

## Inter-Schema-Korrespondenzen

- Semantische Korrespondenz von Schemabestandteilen, weiter beschrieben durch Beziehung auf extensionaler Ebene
  - Äquivalenz, Teilmenge, Überlappung, Disjunktheit
- Korrespondenzformen
  - Element-Korrespondenz
    - Beispiel:  $S1.Personal \supseteq S2.Projektmitarbeiter$
  - Element-und-Attribut-Korrespondenz
    - Beispiel:  $S1.Personal.PNr = S2.Projektmitarbeiter.PersNr$
  - Pfad-Korrespondenz
    - Korrespondenz von Beziehungen
    - Beispiel:  $S1.Personal-Abteilung \subseteq S2.Projektmitarbeiter-Projekt-Abteilung$

## Integrationsregeln

- Jeweils für Form der Korrespondenz
  - Beispiel:  $S1.X1 \equiv S2.X2$ 
    - S.X im integrierten Schema, Bezeichner X kann mit X1 oder X2 übereinstimmen
    - Für korrespondierende Attributpaare wird jeweils ein Attribut übernommen, Wert repräsentiert immer die Vereinigung der einzelnen Werte
    - Zusätzlich werden alle Attribute ohne Korrespondenz aus den beteiligten Schemata übernommen.
- Zusätzliche Regeln für Übernahme von Schemabestandteilen ohne Korrespondenz


# Upward Inheritance

- Ausgangspunkt: Schemazusicherungen mit extensionalen Korrespondenzen
  - betrachtet ausschliesslich objektorientierte Klassenhierarchien
- Integrationsregeln


- $A = B$



- $A \supseteq B$



- $A \cap B$   
oder  
 $A \neq B$



# Generic Integration Model – GIM

- Analyse der extensionalen Beziehungen für beteiligte Schemata führen zu einer Zerlegung von Klassen in sog. Basisextensionen
  - Mengen von Objekten, die gleichzeitig Mitglieder derselben Klassen sind
- GIM Matrix
  - Betrachtet werden nun die den Klassen zugeordneten Attribute
  - Menge von Extensionen mit einer gemeinsamen Attributmenge  
-> Klasse K
  - K1 besitzt Teilmenge der Extensionen von K2, K1 besitzt Obermenge der Attribute von K2  
-> **K1** ist Subklasse von **K2**
- Ableitung eines integrierten Schemas
  - Permutation von Zeilen und Spalten zur Bestimmung von formalen Konzepten
    - "maximale mit Kreuzen ausgefüllte Rechtecke"
  - Ableitung einer Klassenhierarchie

	E1	E2	E3	...	En
A1	X	X		...	X
A2	X	X	X	...	
A3	X		X	...	
...					
Am		X	X	...	




# Abbildungssprache

- Nachteile herkömmlicher Verfahren
  - Betrachten vor allem extensionale Konflikte, in homogenem Datenmodell
  - Unterstützen keine zufriedenstellende Auflösung struktureller Konflikte
  - Updateproblematik
- Überwindung der Heterogenität durch Entwicklung einer Abbildungssprache
  - Integration mehrerer Schemata, die möglicherweise in verschiedenen Datenmodellen erstellt sind, d. h., Abbildung von Daten zwischen heterogenen Schemastrukturen
  - Deskriptive Sprache, d. h. deklarative Abbildungsspezifikationen
  - Technologieunabhängigkeit der Abbildungsspezifikation
  - Unterstützung von sowohl Retrieval als auch Update (vergleiche: View-Update-Problematik)

# BRIITY

- Forschungsansatz einer Abbildungssprache
  - AG DBIS, FB INF, UNI KL
  - wurde entworfen, um vorgenannte Probleme zu überwinden
  - unterstützt bi-direktionale Abbildungen
  - deskriptiv
  - technologieunabhängig
  - unterstützt Benutzer-spezifizierte Update-Anweisungen
  - besonderes Anliegen: Unterstützung von objektorientierten Zielschemata, wobei Abbildung mengenorientiert und deskriptiv (d. h. wie in relationalen Systemen) beschrieben kann
  - Unterstützung von EXPRESS als Ziel-Datenmodell

## Struktur einer Abbildungsspezifikation



```

BEGIN
MAPPED_SCHEMAS
  ts := target_schema <- rel_db:=rel_db@rel_dbs@localhost;
END_MAPPED_SCHEMAS;
INCLUDE
  LIB /usr/users/sauter/libstring.a;
INC string.h;
END_INCLUDE;
TYPE_MAPPING
  MAP ts.DM <- rel_db.USS;
  ts.DM <- 0.67 * rel_db.USS;
  rel_db.USS <- 1.5 * ts.DM;
END_MAP;
END_TYPE_MAPPING;

```

## Struktur einer Abbildungsspezifikation (Forts.)

- Allgemeine Struktur einer Abbildungsspezifikation (Forts.)

```

...
ENTITY_MAPPING
  MAP item <- _item := rel_db.ITEM, _pers := rel_db.PERS;
  ON_RETRIEVE
    name <- _item.name;
    created_by <- _pers.name;
    IDENTIFIED_BY(_item.name, _pers.key);
    WHERE(_item.created_by = _pers.key);
  ON_UPDATE ...
  ON_INSERT ...
  ON_DELETE ...
  END_MAP;
END_ENTITY_MAPPING;
END.

```

## Elementare mengenorientierte Abbildungsregeln

- Grundlegender Aufbau einer MAP-Anweisung

Ziel

item
OID
name
created_by

Abbildung

```
MAP item <- _item := rel_db.ITEM,
           _pers := rel_db.PERS;
ON_RETRIEVE
IDENTIFIED_BY (_item.name, _pers.key);
name <- _item.name;
created_by <- _pers.name;
WHERE (_item.created_by = _pers.key);
```

Quelle

```
SELECT _item.name, _pers.name
FROM ITEM _item, PERS _pers
WHERE _item.created_by =
      _pers.key
```


## Bedingte Abbildung

- Abbildung mehrerer Quellinstanzen auf eine Zielinstanz oder
- Konvertierung von Datentypen



```
MAP item <- _item := rel_db.ITEM;
ON_RETRIEVE
assembly_type <- IF (_item.assembly_type = 512) THEN "manufacturing"
                 ELSE IF (_item.assembly_type = 918) THEN "configurable"
                 ELSE ...;
```

## Referentielle Integrität in relationalen Zielschemata



```

MAP item <- _item:=oo_db.ITEM, _ip:=oo_db.ITEM-PERS, _pers:=oo_db.PERSON;
ON_RETRIEVE
  name <- _item.name;
  approved_by <- CASCADED_MAP person.key
                WITH_ID _item.INV(_ip:item).pers.id
  IDENTIFIED_BY (_item.name);
END_MAP;

```


## Abbildung netzartiger Strukturen

- betrachte Beispiel auf vorangegangener Folie, wobei jedoch nun auch Z objektorientiert sein soll


```

MAP person <- oo_db.PERSON;
ON_RETRIEVE
  name <- oo_db.PERSON.id;
  IDENTIFIED_BY (oo_db.PERSON.id);
END_MAP;
MAP item <- _item:=oo_db.ITEM, _ip:=oo_db.ITEM-PERS, _pers:=oo_db.PERSON;
ON_RETRIEVE
  name <- _item.name;
  approved_by <- CASCADED_MAP person
                WITH_ID _item.INV(_ip:item).pers.id
  IDENTIFIED_BY (_item.name);
END_MAP;

```



# Generalisierung



```

...
MAP Teil <- _t := oo_db.Teil;
  ON_RETRIEVE
    SachNr <- _t.SachNr;
    IDENTIFIED_BY (OID(_t));
  END_MAP;
MAP Einzelteil SUBTYPE_OF(Teil) <- _t := oo_db.Teil;
  ON_RETRIEVE
    Konstrukteur <- _t.Konstrukteur;
    IDENTIFIED_BY (OID(_t));
  END_MAP;
...

```

# Abbildung von Aggregaten

- dienen der Abbildung mengenwertiger Attribute sowie für NEST/UNNEST

```

<set valued attribute mapping> ::=
  [NEST] (LIST|SET|ARRAY) ('<right hand side of attr mapping or nested set valued mapping>')
  [WHERE <DNF expression>]
  [ORDER_BY <sort expression>]
  [GROUPED_BY <source attr identification>].


```

- Beispiel:


```

MAP Kaufauftrag <- _k := oo_db.Kundenwunsch;
  ON_RETRIEVE
    Kunde <- _k.Kunde;
    Auftragsbez <- SET (_k.Auftraege * 98,5%)
    WHERE (_k.Auftraege > 20);
    IDENTIFIED_BY (OID(_k));
  END MAP

```




# NEST-Operation



```

MAP assembly <- _item:=rel_db.ITEM;
ON_RETRIEVE
  name <- _item.name;
  items <- NEST(_item.name)
    GROUPED_BY(_item.assembly);
  
```

# UNNEST-Operation



```

MAP Kaufauftrag <- _k:=oo_db.Kundenwunsch;
ON_RETRIEVE
  FOR_ALL(_unnest_auftrag := UNNEST(_k.Auftraege),
    _unnest_preis := UNNEST(_k.Preise))
  FOR_ALL(_unnest_sachbearbeiter := UNNEST(_k.Sachbearbeiter))
    Kunde <- _k.Kunde;
    Auftragsbez <- _unnest_auftrag;
    Preis <- _unnest_preis;
    Sachbearbeiter <- _unnest_sachbearbeiter;
  IDENTIFIED_BY(OID_k);
END_MAP;
  
```

## Regeln zur Propagierung von Updates

```

<update_clause> ::=
  'ON_UPDATE' (<update_statement> {',' <update_statement>}
    | 'INVERSE_TO_RETRIEVE' ');


<update_statement> ::=
  <target_attribute_id> 'OF' <update_statement_body_list>
  | <update_statement_for_set_valued_target_attributes>.

<update_statement_body> ::=
  ('NEW'|'MODIFIED'|'DELETED') ':' ('RESTRICTED'|'INVERSE_TO_RETRIEVE'|<assign_stmt_list>);

<assign_statement> ::=
  'ASSIGN' <conjunction_of_assgn_statement_expr>
    ['WHERE' <where_clause_containing_bool_expr_of_assign_statement>].

<assign_statement_expr> ::=
  ['NOT_'|'IS_INSTANCE'('<source_entity_id>[<with_instance_id>']':<attr_value_expr_list>')]
  | <is_element_expr>
  | <has_value_expr>.
  
```

## Update-Operation



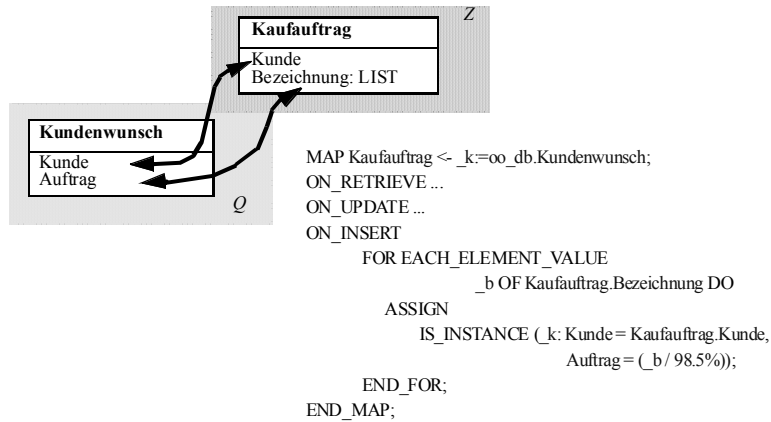
ON\_UPDATE created\_by OF

NEW:       ASSIGN ( IS\_INSTANCE(\_item: name = ts.item.name, created\_by = ?1) AND  
                   IS\_INSTANCE(\_pers: key = ?1, name = ts.item.created\_by));

MODIFIED:   ASSIGN ( IS\_INSTANCE(\_pers: name = ts.item.created\_by);  
               ASSIGN ( IS\_INSTANCE(\_item: name = ts.item.name, created\_by = ?1))  
               WHERE ( IS\_INSTANCE(\_pers: key = ?1, name = ts.item.created\_by));


DELETED:    ASSIGN ( NOT\_IS\_INSTANCE(\_pers: key = ?1))  
               WHERE ...;

## Update-Regeln für mengenorientierte Ziel-Attribute



## Multiple Instanzierung

### ■ Partitionen




```

MAP end_of_cable <- PARTITION _part_end1: _c:=rel_db.CABLE,
  PARTITION _part_end2: _c:=rel_db.CABLE;
PARTITION _part_end1:
  ON_RETRIEVE
    ID <- _c.ID_of_end_1;
    IDENTIFIED_BY (_c.ID);
PARTITION _part_end2:
  ON_RETRIEVE
    ID <- _c.ID_of_end_2;
    IDENTIFIED_BY (_c.ID);
END_MAP;
  
```



## Multiple Instanzierung (Forts.)

- Partitionen (Forts.)



```

...
MAP cable <- _c:=rel_db.CABLE;
ON_RETRIEVE
  end_1 <- CASCADED_MAP end_of_cable
    PARTITION _part_end1
    WITH_ID (_c.ID, _c.ID_of_end_1);
  end_2 <- CASCADED_MAP end_of_cable
    PARTITION _part_end2
    WITH_ID (_c.ID, _c.ID_of_end_2);
  IDENTIFIED_BY (_c.ID);
END_MAP;

```


## Integration mehrerer Quell-Schemata

- Überlappende Anwendungsbereiche → DB-übergreifende Verbundoperationen

```

BEGIN
MAPPED_SCHEMAS
  z := integriert <- q1 = teile_db@db2@host1,
    q2 = pers_db@oracle@host2;
END_MAPPED_SCHEMAS;
ENTITY_MAPPING
MAP Teil <- _t := q1.Teil, _p := q2.Pers;
ON_RETRIEVE
  SachNr <- _t.SNR;
  erstellt_von <- _p.Name;
  ...
  WHERE (_t.erstellt_von = _p.PersNr);
  ...
END_ENTITY_MAPPING;
END.

```

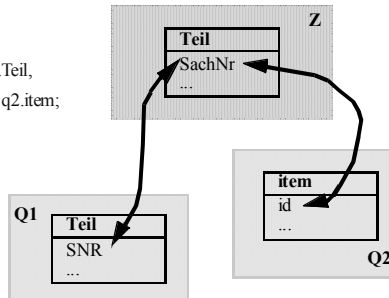


## Identische Anwendungsbereiche → kontextabhängige Abbildung

```

MAP Teil <- PARTITION db_q1: _t:=q1.Teil,
             PARTITION db_q2: _i:=q2.item;
PARTITION db_q1
ON_RETRIEVE
  SachNr <- _t.SNR;
  IDENTIFIED_BY(_t.SNR);
...
PARTITION db_q2
ON_RETRIEVE
  SachNr <- _i.id;
  IDENTIFIED_BY(_i.id);
END_ENTITY_MAPPING;
...
END.

```

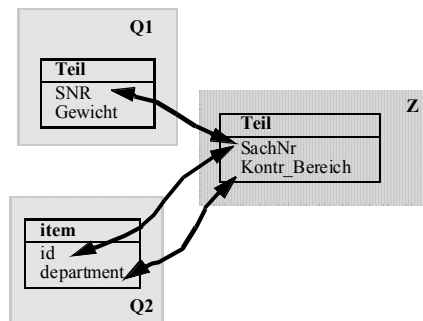


## Globale Identität

```


MAP Teil <- PARTITION db_q1: _t:=q1.Teil,
             PARTITION db_q2: _i:=q2.item;
PARTITION db_q1
ON_RETRIEVE
  SachNr <- _t.SNR;
  Konstr_Bereich <- "EntwicklungPkw"
  IDENTIFIED_BY(_t.SNR);
  GLOBAL_IDENTITY(_t.SNR,
                  "EntwicklungPkw");
...
PARTITION db_q2
ON_RETRIEVE
  SachNr <- _i.id;
  Konstr_Bereich <- _i.department
  IDENTIFIED_BY(_i.id, _i.department);
END_ENTITY_MAPPING;
...
END.

```



# Zusätzliche Integritätsbedingungen

- IBs für Konflikte auf Instanzebene: ECA-Regeln
- Checkin-Abhängigkeiten



```

INTEGRITY_CONSTRAINTS
DEPENDENCIES
    GROUP    cable, end_of_cable
    WHERE    (cable.end_1 = OID(end_of_cable)) AND (cable.end_2 = OID(end_of_cable))
END_DEPENDENCIES;
END_INTEGRITY_CONSTRAINTS;
    
```

- Initialisierung von Primärschlüsselattributen in Quellschemata

# Ausführungsmodell

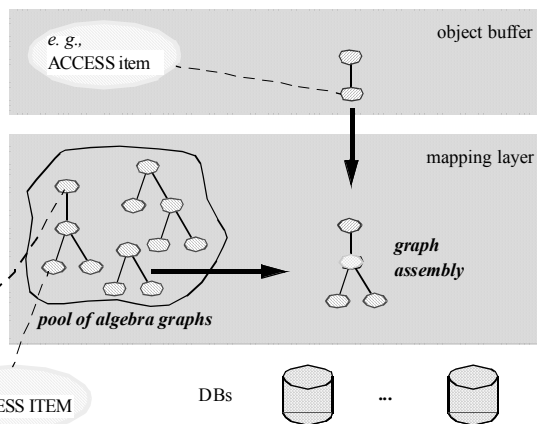
**mapping definition**  
 (specified in BRITY and  
 stored in an ASCII file)



**parser**  
 BRITY algebra

e. g.,  
MAP item

e. g.,  
ACCESS ITEM



## Ausführungsmodell (Forts.)

- Parsen der Abbildungsspezifikation
- Anfragetransformation
  - Transformation in Abbildungsgraph (Algebra-Graph)
  - Blattknoten: Operationen zum Zugriff auf die DBSs
  - innere Knoten: Algebraoperatoren
  - Wurzelknoten: Operator zum Erzeugen von Zielinstanzen
- Auswahl der relevanten Abbildungsgraphen
  - für die Bearbeitung einer Query sind die Abbildungsgraphen relevant, die für die Erzeugung der in der Query angesprochenen Objekttypen des Zielschemas verantwortlich sind
  - Abbildungsgraph wird anhand des Wurzelknotens selektiert
- Assemblierung
  - Query-Graph und Abbildungsgraph werden zusammengefügt
  - Wurzel-Operator des Abbildungsgraphen und Zugriffsoperator des Query-Graphen werden verschmolzen
- Optimierung und Ausführung des assemblierten Graphen durch Mapping-Layer

## Zusammenfassung

- Schemaabbildung und -integration
  - Zielvorstellung
    - Bereitstellung eines integrierten Schemas
    - Bearbeitung der Zieldaten mit generischen Operatoren
    - Unterstützung eines breiten Spektrums von Quellsystemen und Auswahlmöglichkeit hinsichtlich der Nutzung eines Zielsystems
  - Schemaintegrationstechniken
  - Abbildungssprache BRIITY
    - löst die wesentlichen Probleme struktureller Heterogenität
    - unterstützt sowohl relationale als auch objektorientierte Modelle auf beiden Seiten (Quellsysteme, Zielsystem)
    - erlaubt bi-direktionale Abbildung und unterstützt so beliebige Update-Operationen auf den Zieldaten
    - hoher Spezifikationsaufwand