Prof. Dr.-Ing. Stefan Deßloch
AG Heterogene Informationssysteme
Geb. 36, Raum 329
Tel. 0631/205 3275
dessloch@informatik.uni-kl.de

Technische Universität Kaiserslautern

Kapitel 8
Schemaabbildung und -integration

Schemaintegration

- Datenintegration als ein wesentlicher Aspekt der Entwicklung neuer, globaler Informationssysteme
  - Randbedingung: Autonomie der beteiligten lokales 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[1] ist ein zentrales Problem

[1]S. Conrad: *Schemaintegration: Integrationskonflikte, Lösungsansätze, aktuelle Herausforderungen,* in Informatik Forschung und Entwicklung 17(3), 2002.

Schema-Referenzarchitektur

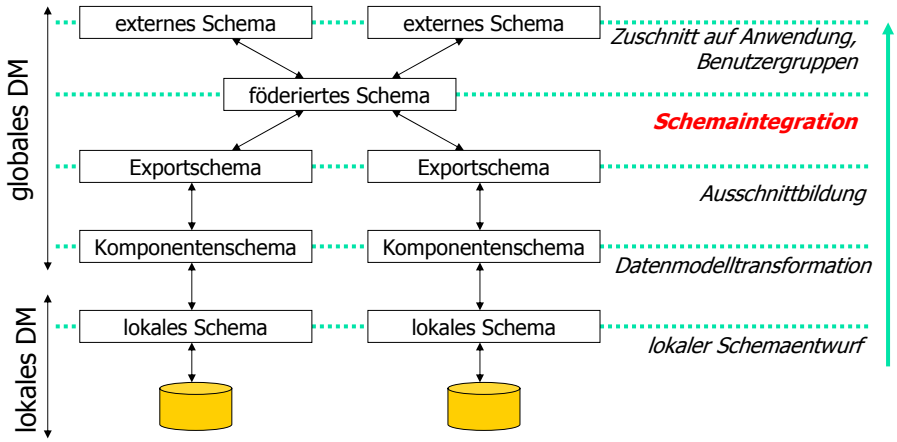

Komponenten der Schema-Referenzarchitektur

- 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

Prof. Dr.-Ing. Stefan Deßloch
AG Heterogene Informationssysteme
Geb. 36, Raum 329
Tel. 0631/205 3275
dessloch@informatik.uni-kl.de

TECHNISCHE UNIVERSITÄT KAISERSLAUTERN

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

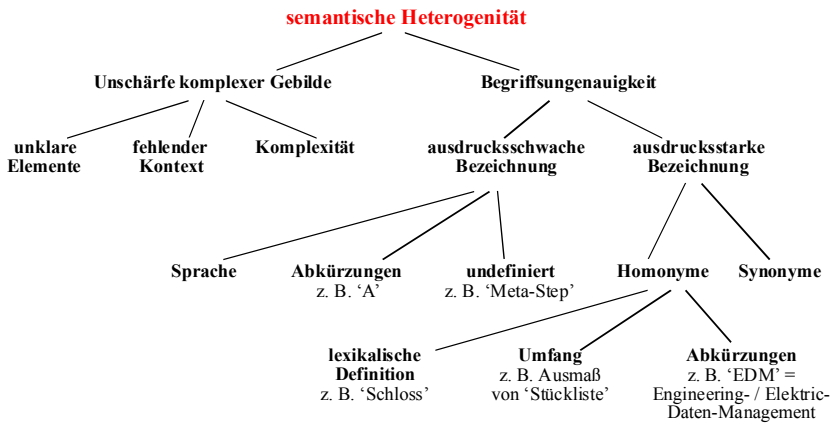

Strukturelle Heterogenität

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

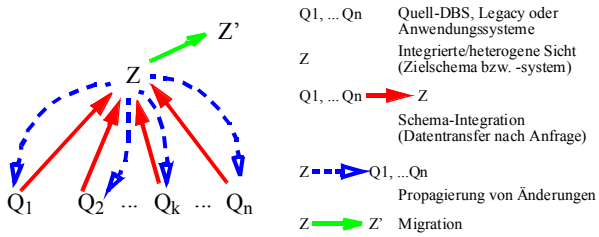

- Schemata sind *kongruent*, wenn sie semantisch identische Objekttypen und Eigenschaften beinhalten
  - meist inkongruent, überlappend
  - Kongruenzeigenschaft zwischen Quell- und Zielschema (*vertikal*) oder zwischen versch. Quellschemata (*horizontal*)

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:

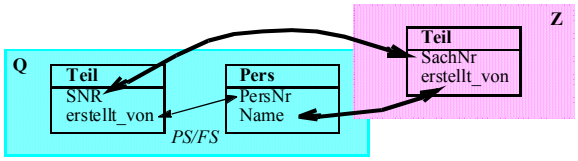

- Q beschreibt kleineren Ausschnitt als Z
  - häufig bei integrierten Sichten
  - Beispiel:

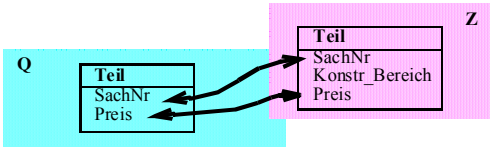

Vertikale Datenverteilung

- 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

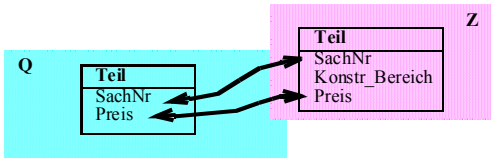

- Selektion: Z erfasst weniger Daten als Q
  - über Prädikate zu erfassen
  - Beispiel

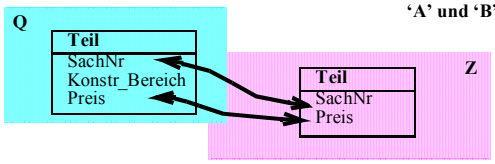

Datentypkorrespondenz

- Unterstützung unterschiedlicher Datentypen durch Q und Z
- Problem: finde Abbildung, die semantikerhaltende Rücktransformation erlaubt
  - Beispiel: REAL (Q) → 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

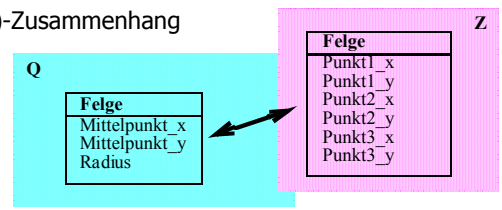

  - i.a. komplexe Berechnungsfunktionen notwendig für die Umrechnung

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

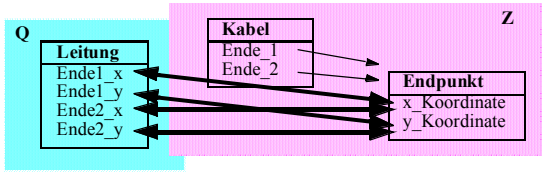

  - kontextabhängige Abbildung (Q → Z): Endpunkte können nur im entsprechenden 'Kabel'-Kontext (in Z) instanziiert werden
  - Verdrängungsabhängigkeit (Z → Q):
    in Z könnte für ein Kabel nur ein Endpunkt instanziiert sein; dann kann keine korrespondierende Leitungsinstanz in Q erzeugt werden
- (n:m)-Zusammenhang: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

Vernetzung von Quellkonstrukten

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

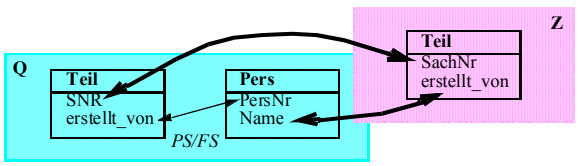

Vernetzung von Zielentities

- 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

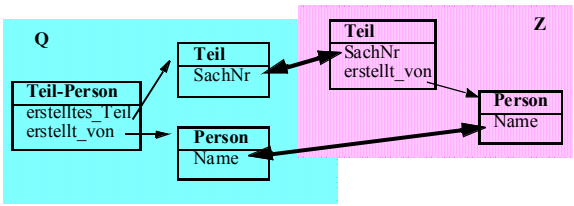

  - Anmerkung: dieses Problem tritt häufig bei Abbildungen zwischen normalisierten relationalen und objektorientierten Schemata auf

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

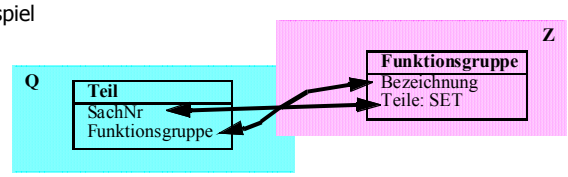

Abbildung mengenwertiger Attribute

- 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:

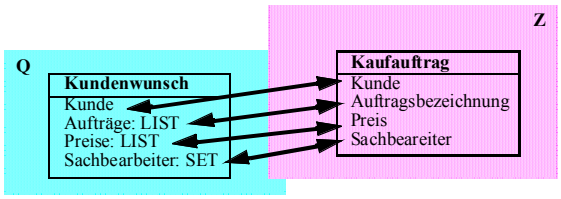

Abbildung von Abstraktionskonzepten

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

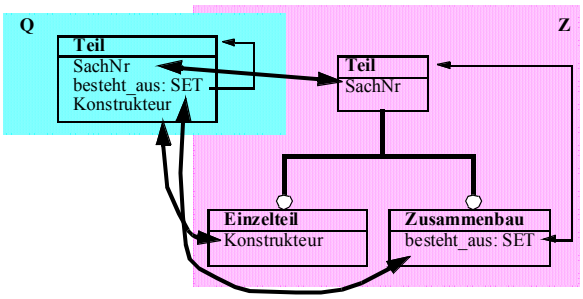

Abbildung von Abstraktionskonzepten (2)

- Beispiel: Datentypebene vs. Objektebene

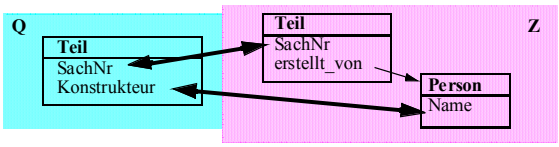

Dynamische Aspekte und Integritätsbedingungen

- 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 → Z und Z → Q
  - explizite Definition der Rücktransformation

Abbildungskardinalität (Forts.)

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

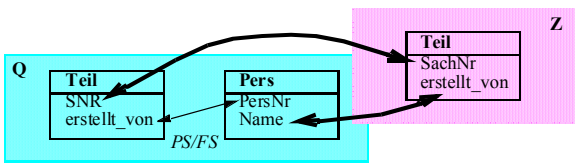

  - Beispiel: Checkin-Abhängigkeit

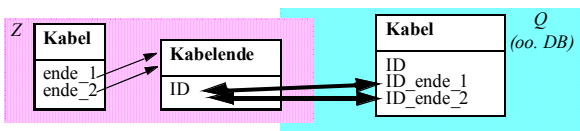

Schemakardinalität

- 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 Qi
  - **disjunkte** Anwendungsbereiche
    - Integration wenig sinnvoll

Horizontale Datenverteilung

- disjunkte Verteilung der Daten auf die Qi
  - es sind Prädikate zu spezifizieren, anhand derer abgeleitet werden kann, auf welche Qi neu erzeugte Instanzen aus Z zu propagieren sind
- replizierte Verteilung der Daten auf die Qi
  - es ist zu beachten, dass Daten unterschiedlich strukturiert und identifiziert werden können
- teilweise überlappende Verteilung der Daten auf die Qi
  - 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

Prof. Dr.-Ing. Stefan Deßloch
AG Heterogene Informationssysteme
Geb. 36, Raum 329
Tel. 0631/205 3275
dessloch@informatik.uni-kl.de

Technische Universität Kaiserslautern

Schemaintegrationstechniken

Schemaintegrationstechniken

- Zusicherungsbasierte 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 zusicherungsbasierten 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 Konfliktlösungschritte in deklarativer oder prozeduraler Form

Zusicherungsbasierte 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
  - Korrepondenzen 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
    - Beipiel: S1.Personal-Abteilung $\subseteq$ S2.Projektmitarbeiter-Projekt-Abteilung

Integrationsregeln

- Jeweils für Form der Korrepondenz
  - Beipiel: 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 Korrepondenz 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 ⊇ B

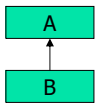

  - A ∩ B
    oder
    A ≠ B

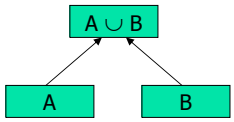

Generic Integration Model – GIM

- 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

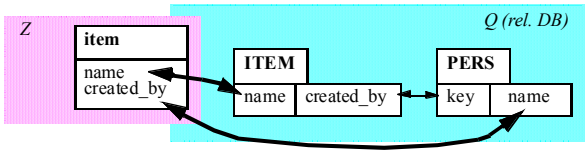


```
BEGIN
MAPPED_SCHEMAS
      ts := target_schema <- rel_db:= rel_db@rel_dbs@localhost;
END_MAPPED_SCHEMAS;
INCLUDE
      LIB /usr/users/sauter/libstring.a;
      INC string.h;
END_INCLUDE;
TYPE_MAPPING
      MAP ts.DM <- rel_db.US$;
            ts.DM <- 0.67 * rel_db.US$;
            rel_db.US$ <-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

Ausführungsmodell

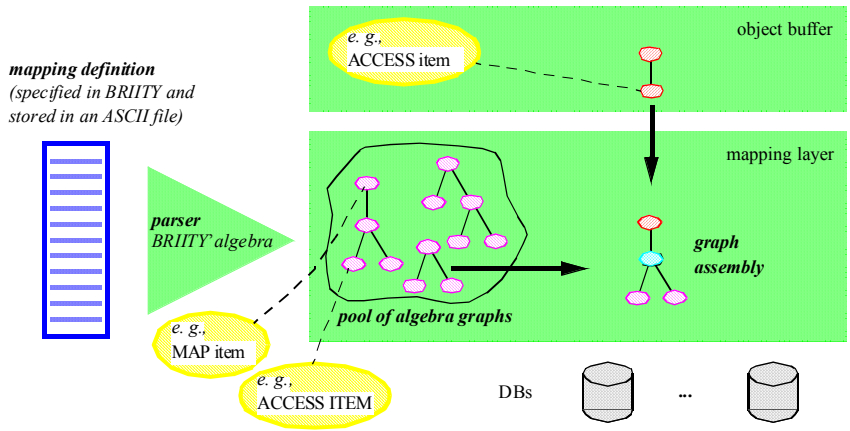

Ausführungsmodell (Forts.)

- 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
  - Bereitstellung eines integrierten Schemas
  - Bearbeitung der Zieldaten mit generischen Operatoren
  - Unterstützung eines breiten Spektrums von Quellsystemen und Auswahlmöglichkeit hinsichtlich der Nutzung eines Zielsystems
- Schema-Referenzarchitektur
  - Föderiertes Schema
- Integrationskonflikte
  - Strukturelle vs. semantische Heterogenität
- Schemaintegrationstechniken
  - Zusicherungsbasierte Schemaintegration
  - Integration von Klassenhierarchien mit Upward Inheritance
  - Generic Integration Model – GIM
  - Zerlegung der Klassen in sog. Basisextensionen
  - Abbildungssprachen