Datenintegration

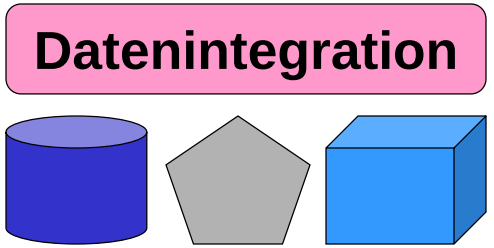

Kapitel 4: Architekturen von Integrationssystemen

Dr. Anika Groß
Sommersemester 2016

Universität Leipzig
Institut für Informatik
http://dbs.uni-leipzig.de

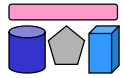

Inhalt

- Übersicht über Arten von Integrationssystemen
- Data Warehouse
  - Definition und Architektur
  - Mehrdimensionale Datenmodellierung und -analyse
- Föderierte Datenbanken
  - Taxonomie von DBMS
  - Schichtenaufbau Integrierter Systeme
- Mediator-Wrapper-Ansatz
  - Architektur, Funktionen von Mediatior & Wrapper
  - Web Wrapper
- Peer Data Management Systeme
  - Definition und Architektur
  - Vergleich zu P2P-Systemen
- Weitere Architekturen
- Architekturen vs. Integrations(teil)aufgaben

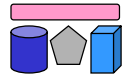

Integrationssysteme: Übersicht (Auswahl)

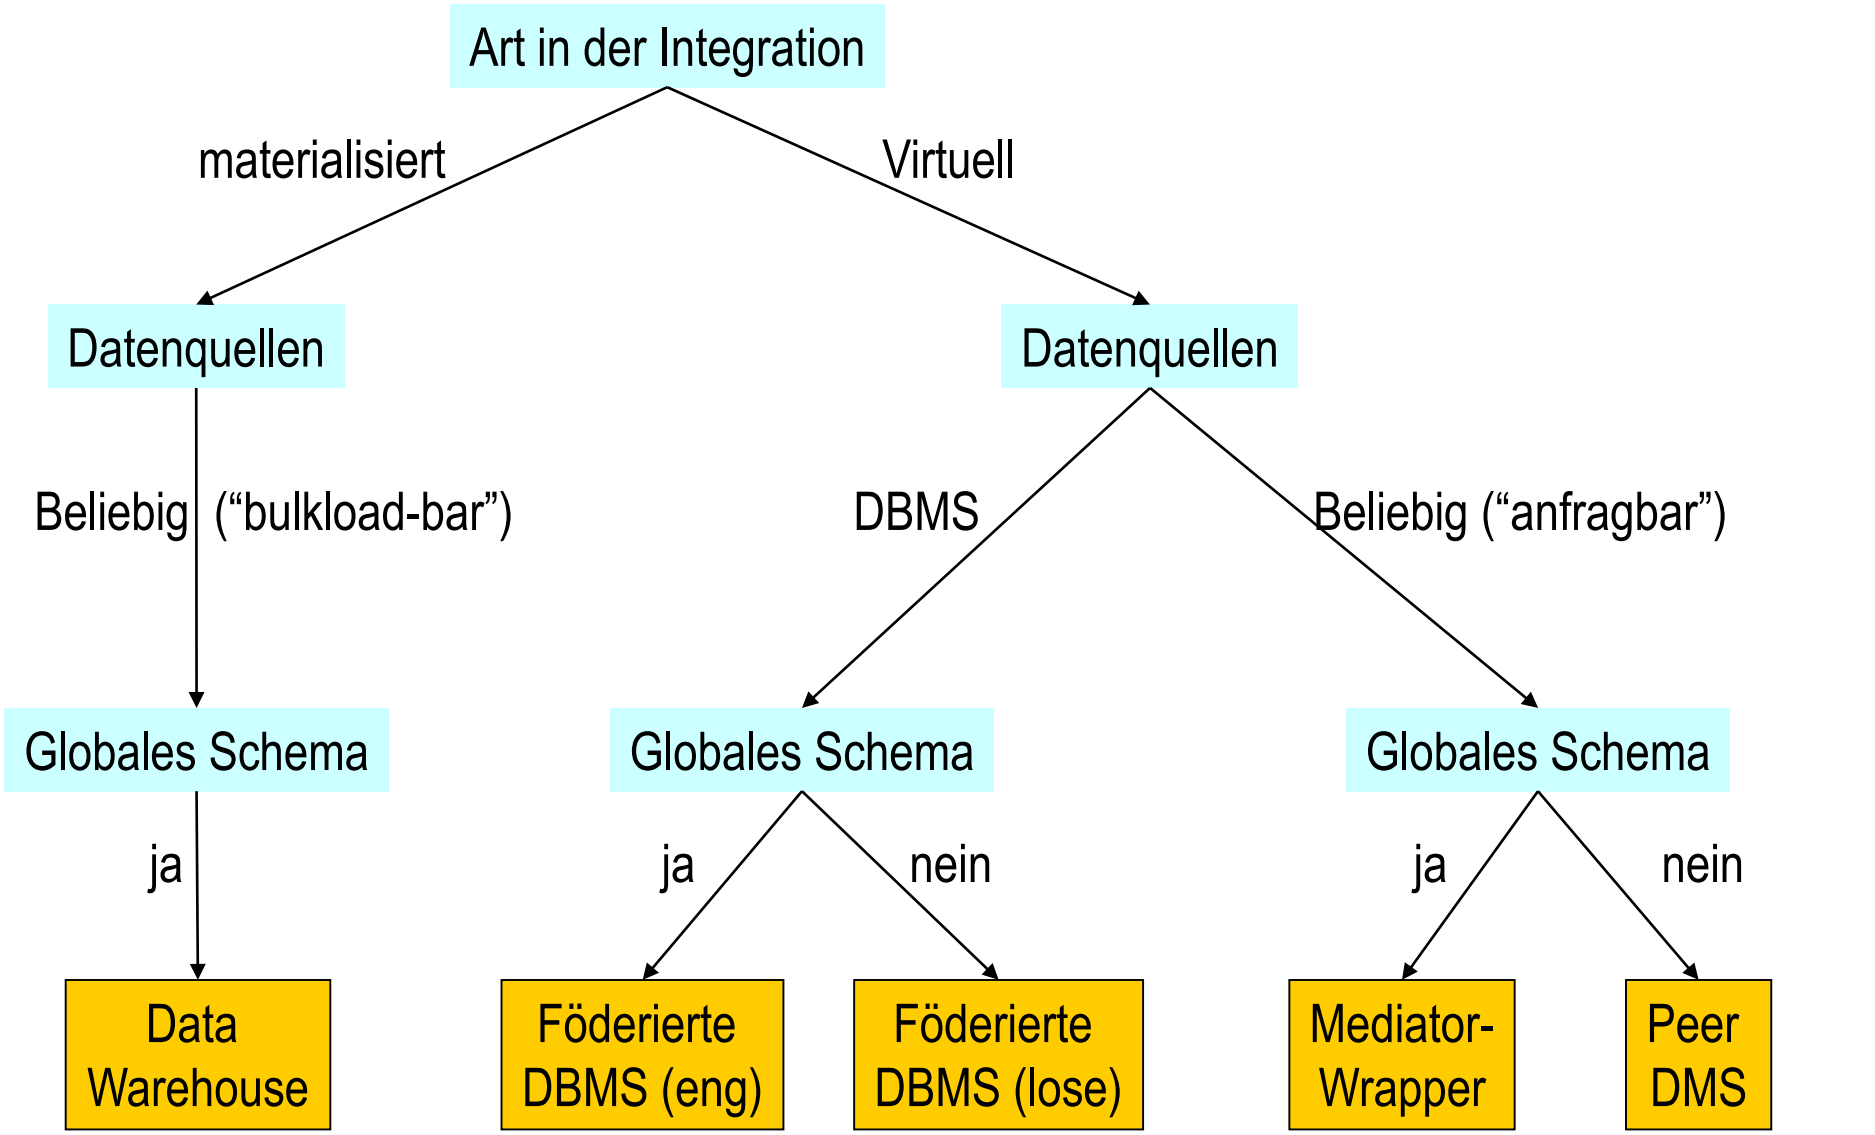

Data Warehouse: Szenario

- Handelshaus mit mehreren Filialen
  - Physikalische Datenverteilung (Niederlassungen, …)
  - Zentrale Beschaffung, Planung, Verteilung
- Fragen & Entscheidungen
  - Was wird wann wo angeboten?
  - Was muss man wo geliefert werden?

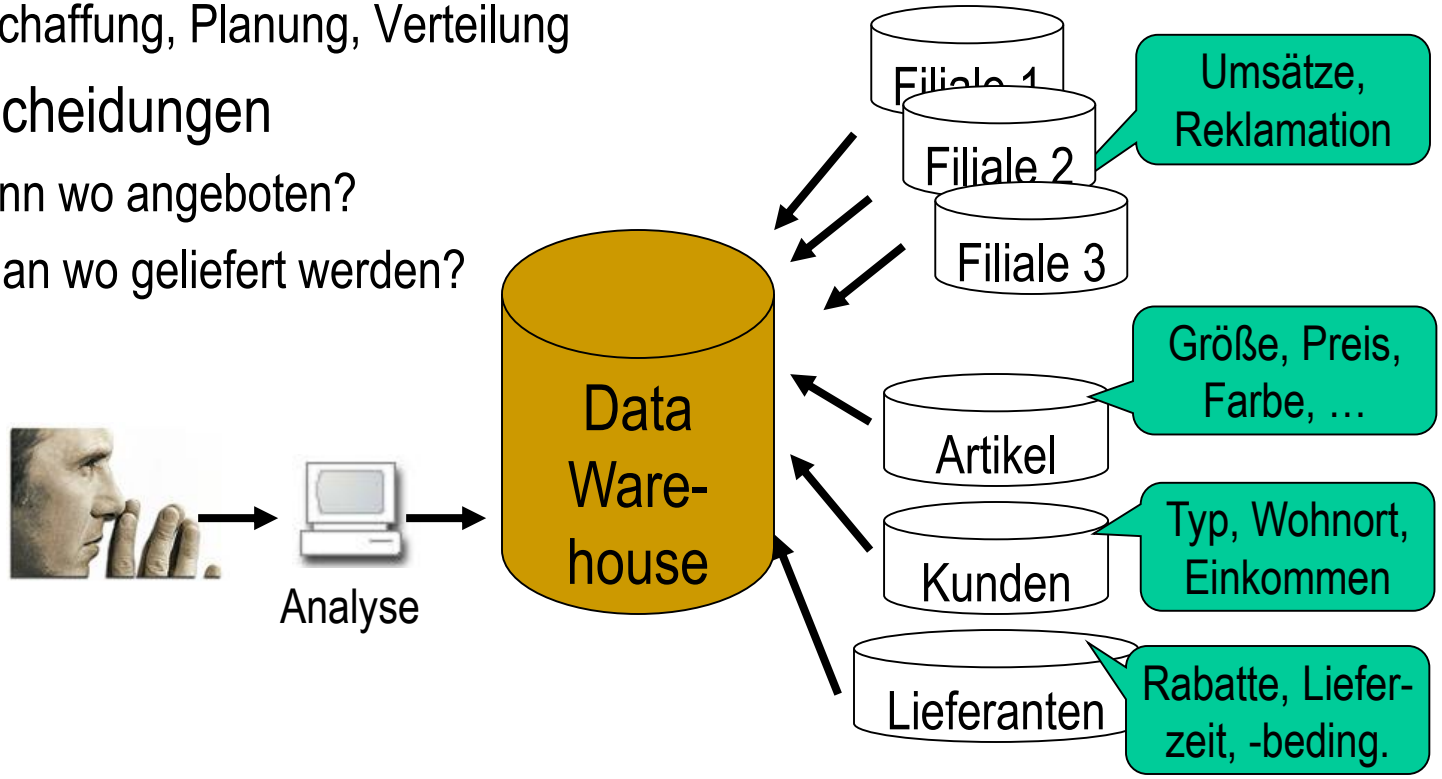

- Analysen
  - Welches sind die Topkunden? Welches sind die Topfilialen?
  - Welche Produkte hatten im letzten Jahr im Bereich Leipzig einen Umsatzrückgang um mehr als 10%?
  - Haben Fillialen einen höheren Umsatz, die gemeinsam gekaufte Produkte zusammen stellen?

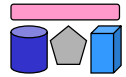

Data Warehouse: Problem & Definition

- Problem: viele Unternehmen haben Unmengen an Daten, ohne daraus ausreichend Informationen und Wissen für kritische Entscheidungsaufgaben ableiten zu können
- Data Warehouse ist eine für Analysezwecke optimierte zentrale Datenbank, die Daten aus mehreren, i.a. heterogenen Quellen zusammenführt und verdichtet (Integration und Transformation)
- *A data warehouse is a subject-oriented, integrated, non-volatile, and time-variant collection of data in support of management's decision.* [In96]
  - Subject-oriented: Verkäufe, Personen, Produkte, etc. (*nicht* task-oriented)
  - Integrated: Erstellt aus vielen Quellen
  - Non-Volatile: Hält Daten unverändert über die Zeit
  - Time-Variant: Vergleich von Daten über die Zeit
  - Decisions: Wichtige Daten rein, unwichtige raus

[In96] W. H. Inmon, Building the Data Warehouse, 2nd ed., John Wiley 1996

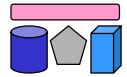

Operationale Datenbanken vs. DWH

	Operationale Datenbanken / OLTP (Online Transaction Processing)	Data Warehouse / OLAP (Online Analytical Processing)
Typische Operationen	Insert, Update, Delete, Select	
Transaktionen	Viele und kurz	
Typische Anfragen	Einfache Queries, Primärschlüsselzugriff, Schnelle Abfolgen von Selects/inserts/updates/deletes	
Daten pro Operation	Wenige Tupel	
Datenmenge in DB	Gigabyte	
Änderungen	Sehr häufig / stets aktuell	
Dateneigenschaften	Rohdaten	
Antwortzeiten (erwart.)	Echtzeit bis wenige Sek.	
Modellierung	Anwendungsorientiert	
Typische Benutzer	Sachbearbeiter	

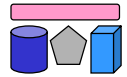

Grobarchitektur einer DWH-Umgebung

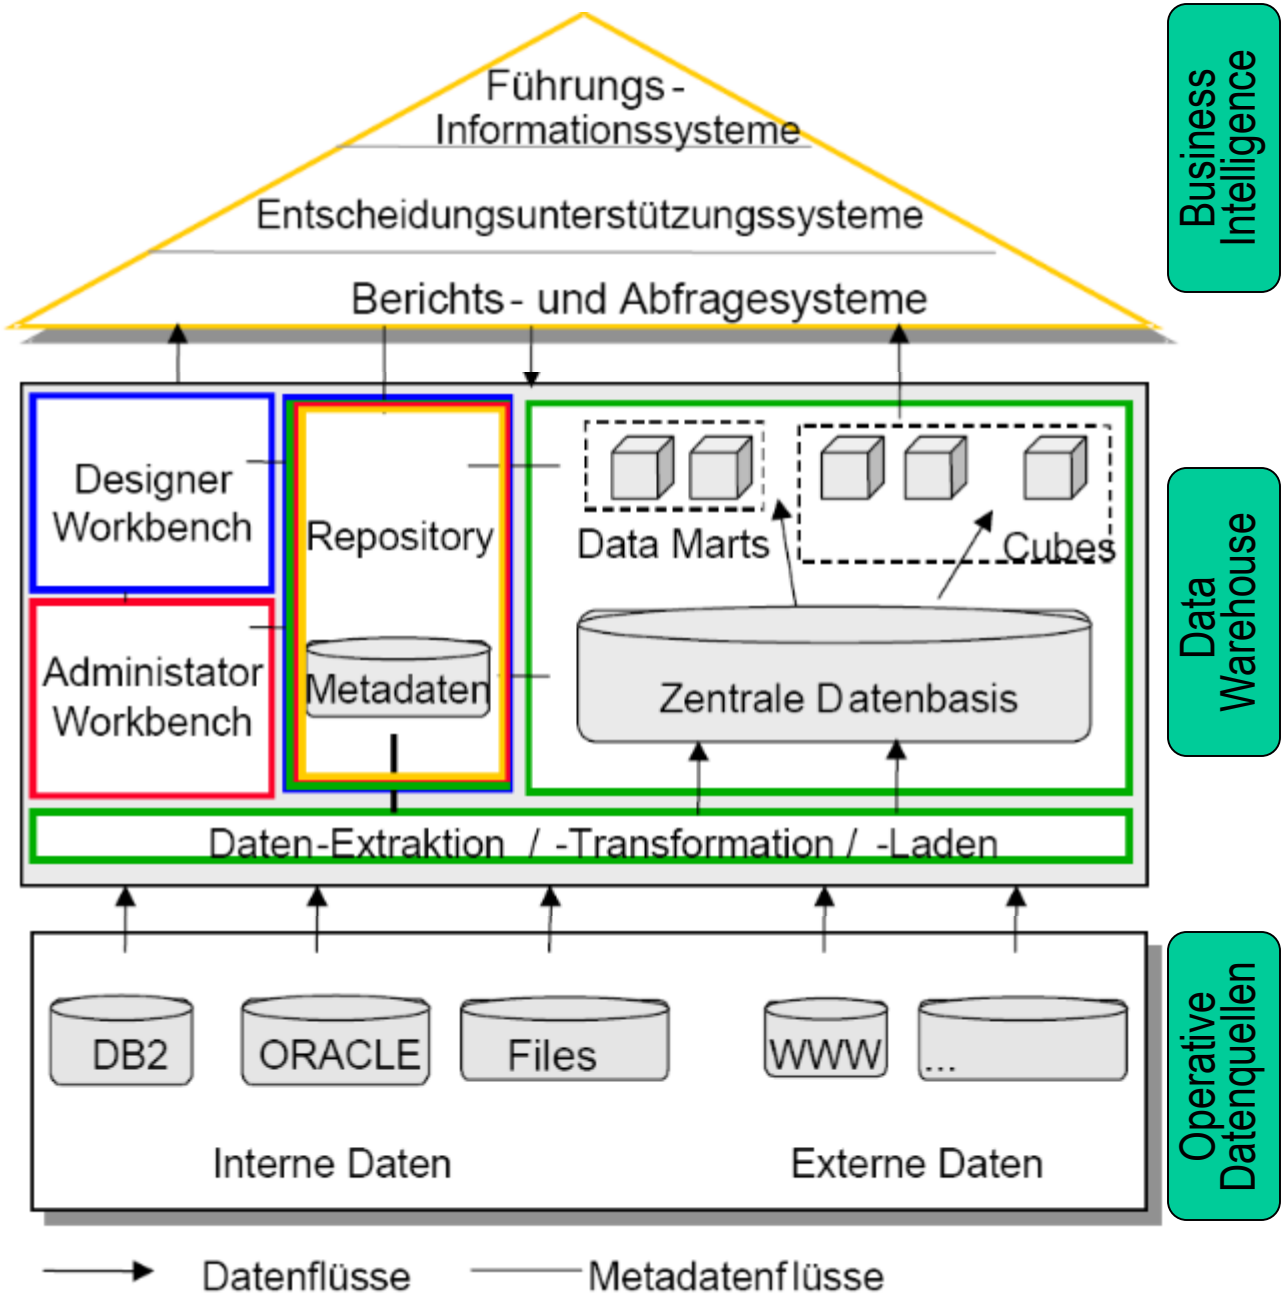

Datenmodellierung

- Multidimensionale Modellierung
  - Faktentabelle enthält je einen Eintrag pro “Analyseobjekt”, z.B. Verkauf eines Produkts
  - Dimensionstabellen zur Beschreibung der Fakten
- Schemata
  - Häufig: Star-Schema (rechts)
  - Snowflake-Schema
  - Galaxienschema

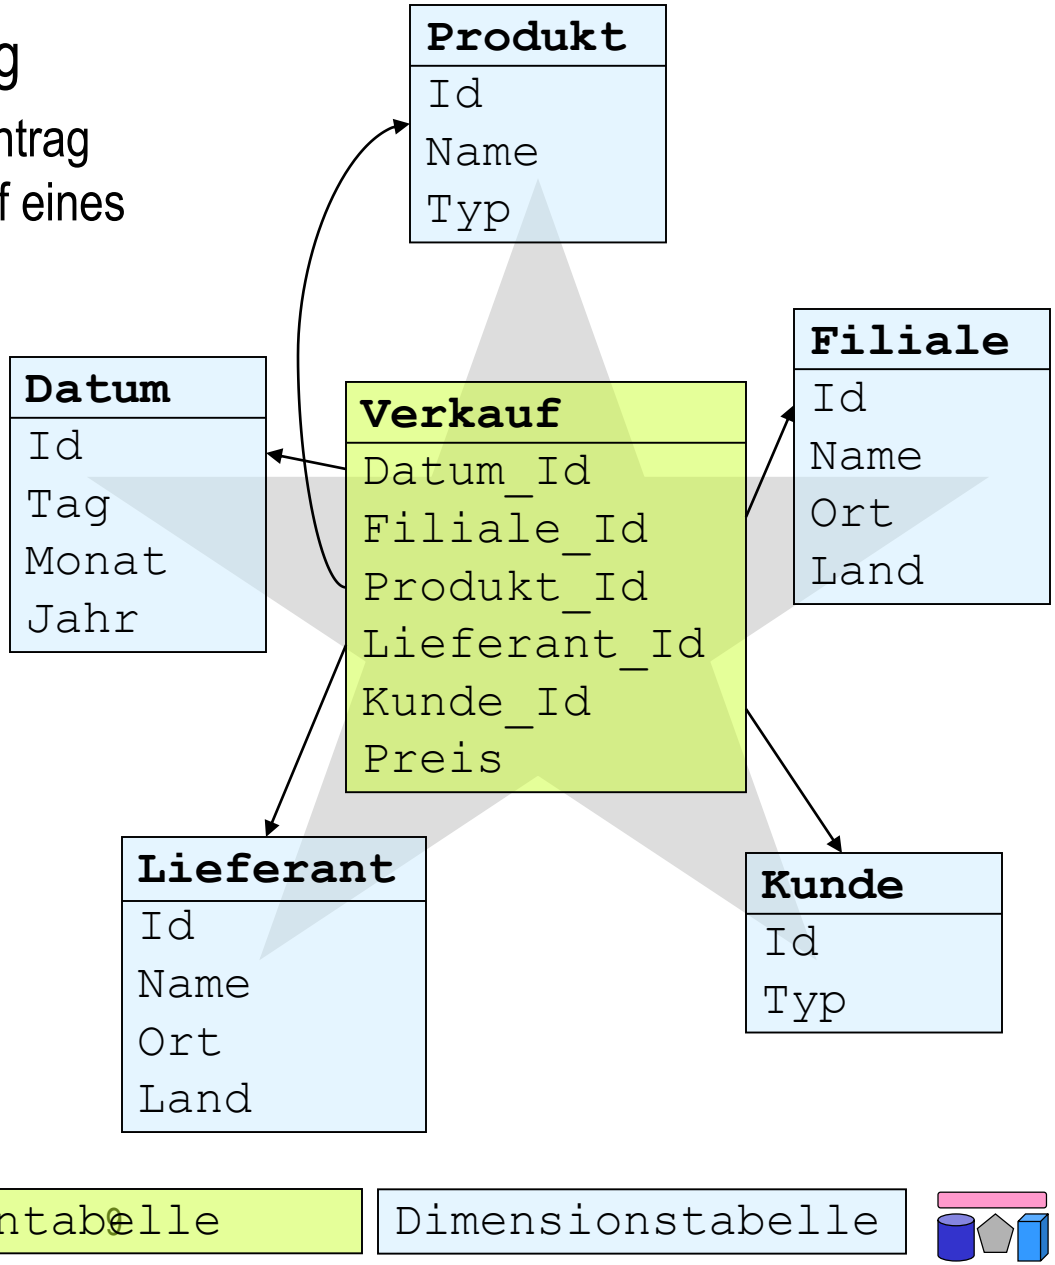

Mehrdimensionale Datensicht

- Data Cube:
  Hyperwürfel
  mit beliebig vielen
  Dimensionen

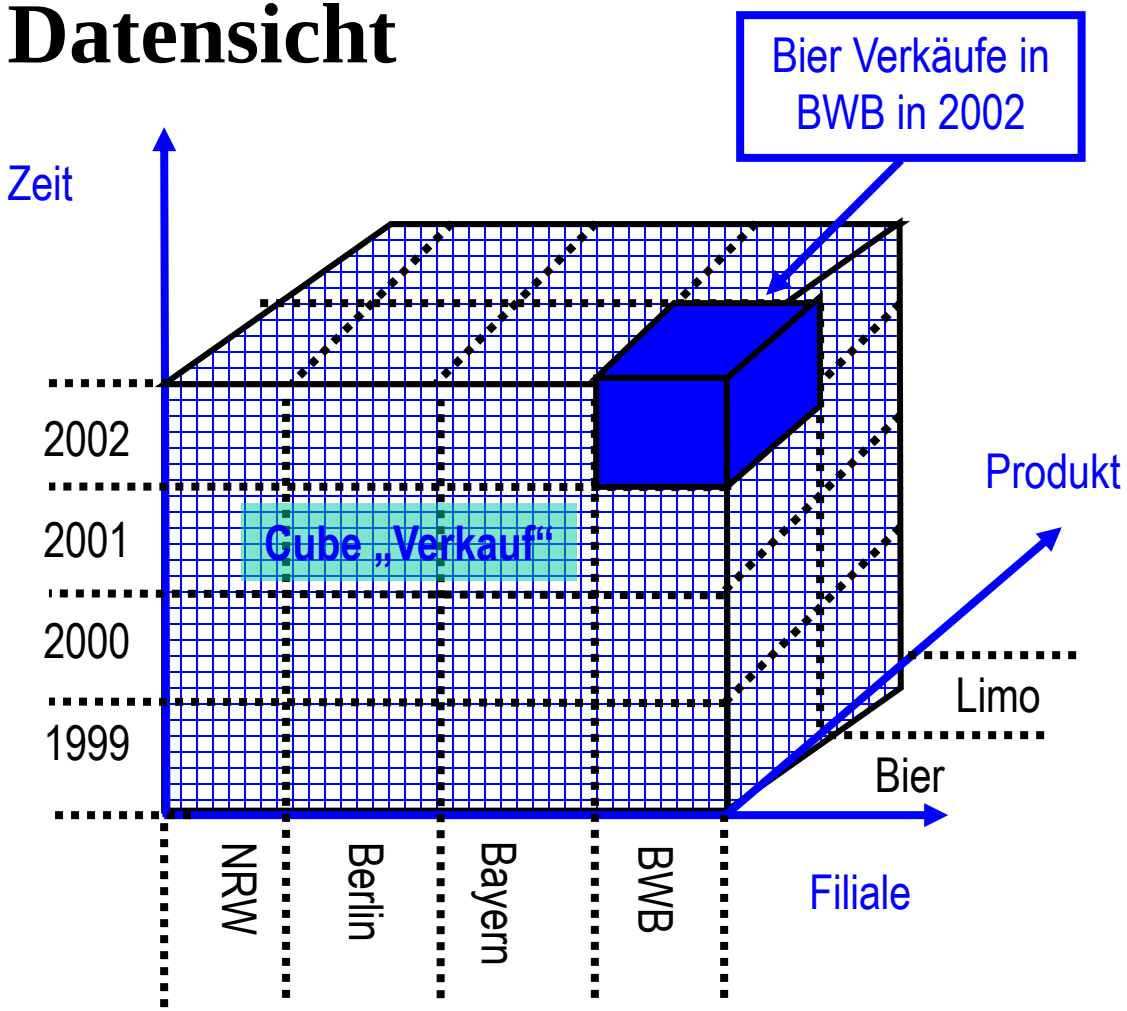

- Kennzahlen
  - numerische Werte als Grundlage für Aggregationen / Berechnungen
- Operationen
  - Aggregierung der Kennzahlen über eine oder mehrere Dimension(en)
  - Slicing and Dicing: Bereichseinschränkungen auf Dimensionen
  - Drill-down and Roll-up: Wechsel der Dimensionsebenen

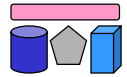

OLAP (Online Analytical Processing)

- Interaktive multidimensionale Analyse auf konsolidierten Daten
- Merkmale / Anforderungen
  - multidimensionale, konzeptionelle Sicht auf die Daten
  - unbegrenzte Anzahl an Dimensionen und Aggregationsebenen
  - unbeschränkte dimensionsübergreifende Operationen
  - intuitive, interaktive Datenmanipulation und Visualisierung
  - transparenter (integrierter) Zugang zu heterogenen Datenbeständen mit logischer Gesamtsicht
  - Skalierbarkeit auf große Datenmengen
  - stabile, volumenunabhängige Antwortzeiten
  - Mehrbenutzerunterstützung
  - Client/Server-Architektur

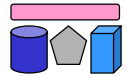

Data Warehouse: Vor- und Nachteile

- Vorteile
  - Flexible, einfach zu nutzende, mehrdimensionale Datenanalyse
  - Hohe Datenqualität durch Integration, Bereinigung und Aggregation von Daten aus heterogenen Datenquellen
  - Performanz
  - Unabhängig von operativen Systemen
- Nachteile
  - Datenredundanz
  - Daten nicht vollständig aktuell
  - Hoher Administrationsaufwand
  - Hohe Kosten

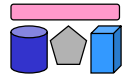

Föderierte Datenbanken

- Föderation = Bündnis
  - vergleiche politische Föderation (z.B. BRD, EU, USA)
- Förderierte Datenbank ist Gesamtsystem bestehend aus mehreren (teil-) autonomen Datenbanksystemen und ggf. einem zusätzlichen globalen (föderierten) Schema

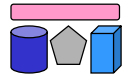

Taxonomie von DBMS

- Nach: Amit P. Sheth and James A. Larson, Federated Database Systems for Managing Distributed, Heterogeneous, and Autonomous Databases, ACM Computing Surveys, Vol. 22(3), 1990

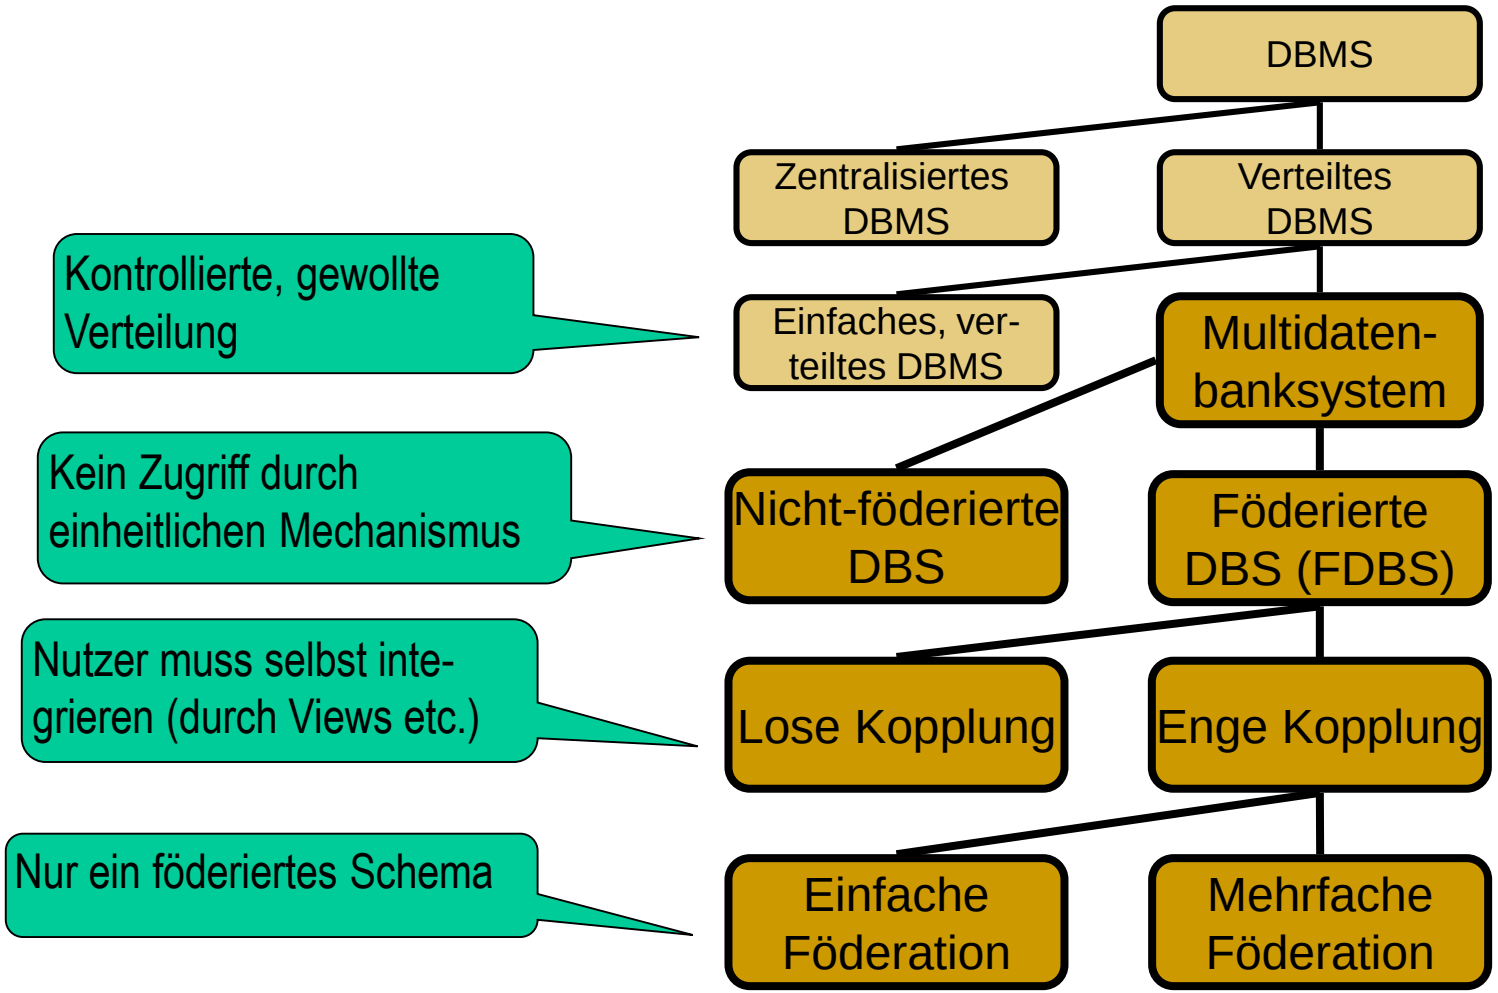

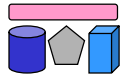

3-Schichten-Architektur (Wdhg. DBS1)

- ANSI/SPARC 3-Schichten Architektur für zentralisierte DBMS
- Externe (logische) Sicht
  - Anwendungsprogramme
  - Nur auf die relevanten Daten
  - Enthält Aggregationen und Transformationen
- Konzeptionelle (logische) Sicht
  - Unabhängig von physischer Sicht
  - Definiert durch Datenmodell
  - Stabiler Bezugspunkt für interne und externe Sichten
- Interne (physische) Sicht
  - Speichermedium (Tape, Festplatte)
  - Speicherort (Zylinder, Block)

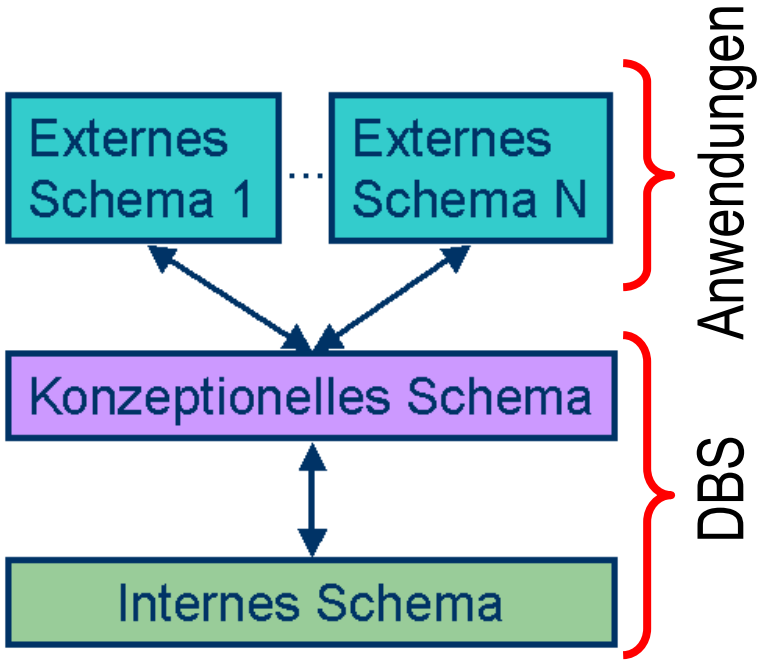

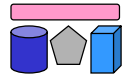

4-Schichten-Architektur (Verteilte DBMS)

- Für verteilte DBMS
- Neu: Trennung lokales vs. globales konzeptionelles Schema
- Globales konzept. Schema ist integriert aus den lokalen konzept. Schemas
- Lokales und globales konzept. Schema können gleich sein

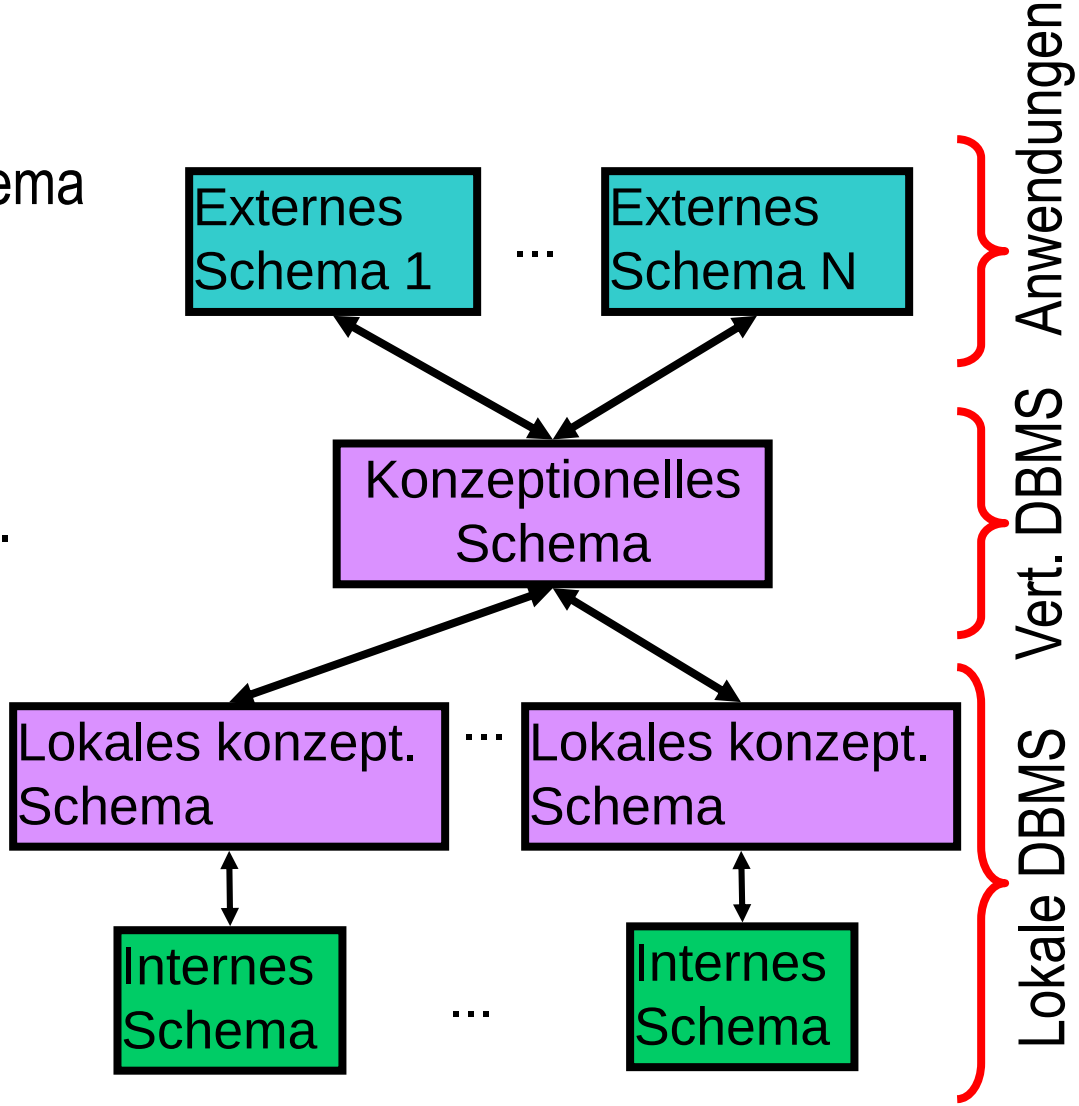

Import/Export-Architektur [HM85]

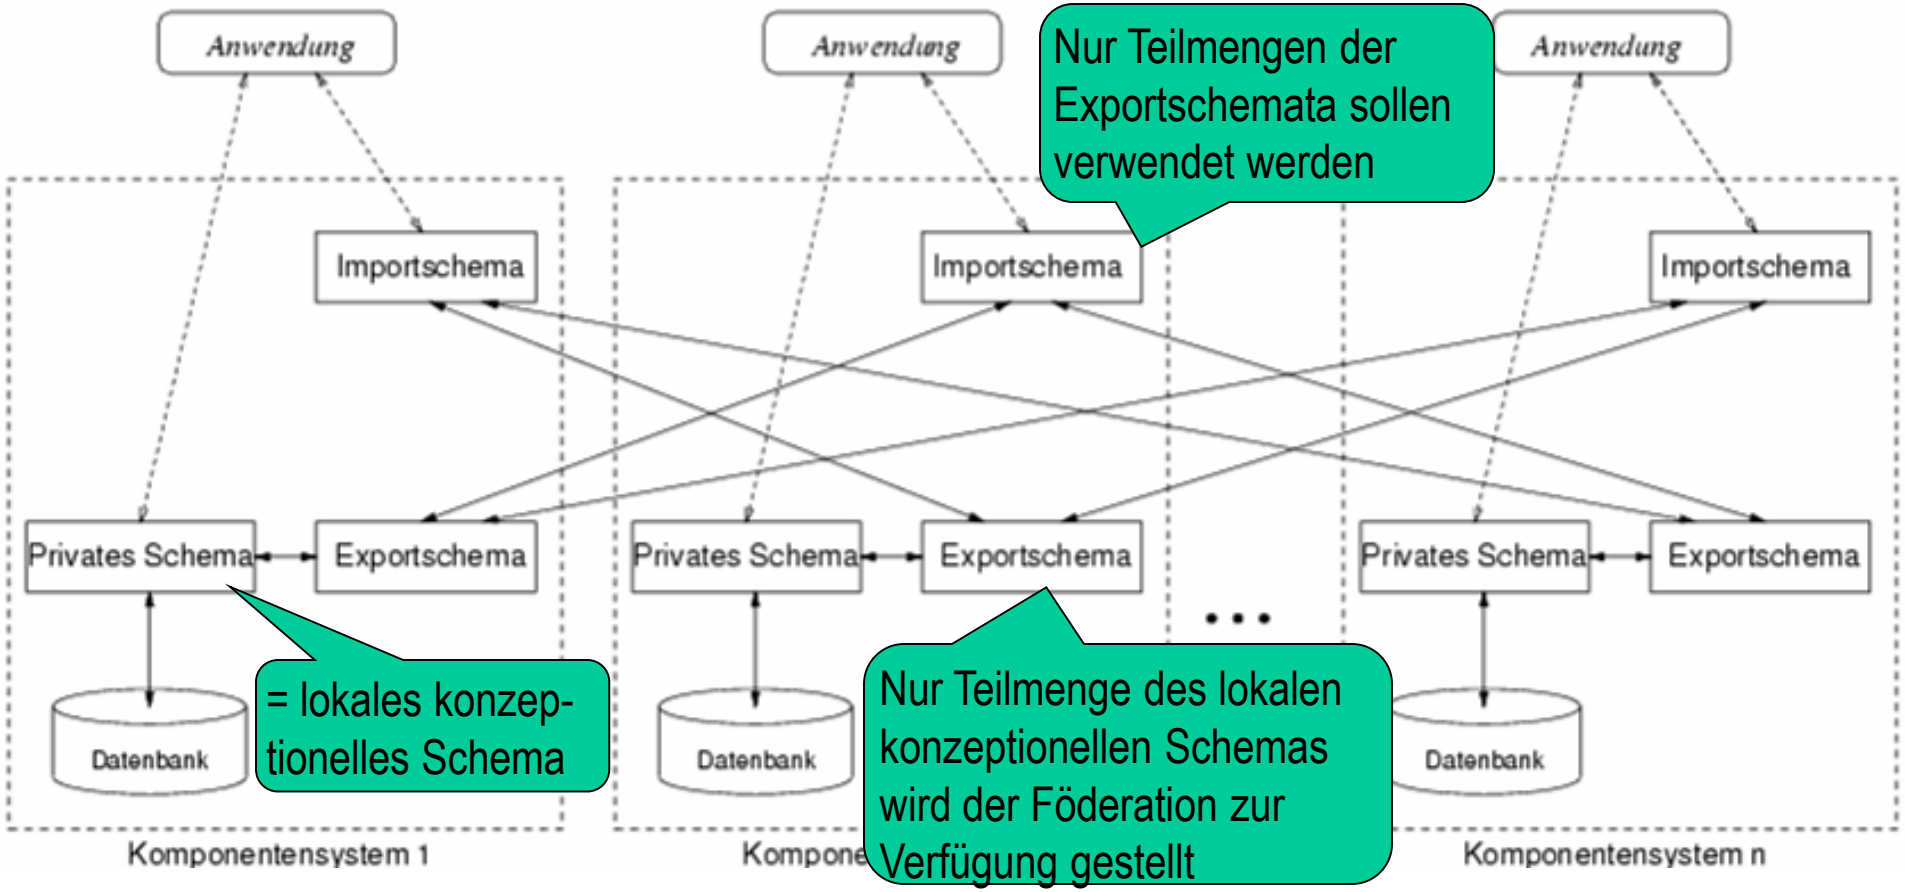

[HM85] Dennis Heimbigner, Dennis McLeod: *A Federated Architecture for Information Management*. ACM Trans. Inf. Syst. 3(3): 253-278 (1985)

4-Schichten-Architektur (Multidatenbanken)

- Auch: Multidatenbankarchitektur [LMR90]
- Voraussetzung
  - Nutzer kennen die jeweiligen Schemas
  - Multidatenbanksprache
- Anwendungen müssen selbst integrieren
- Lose Kopplung

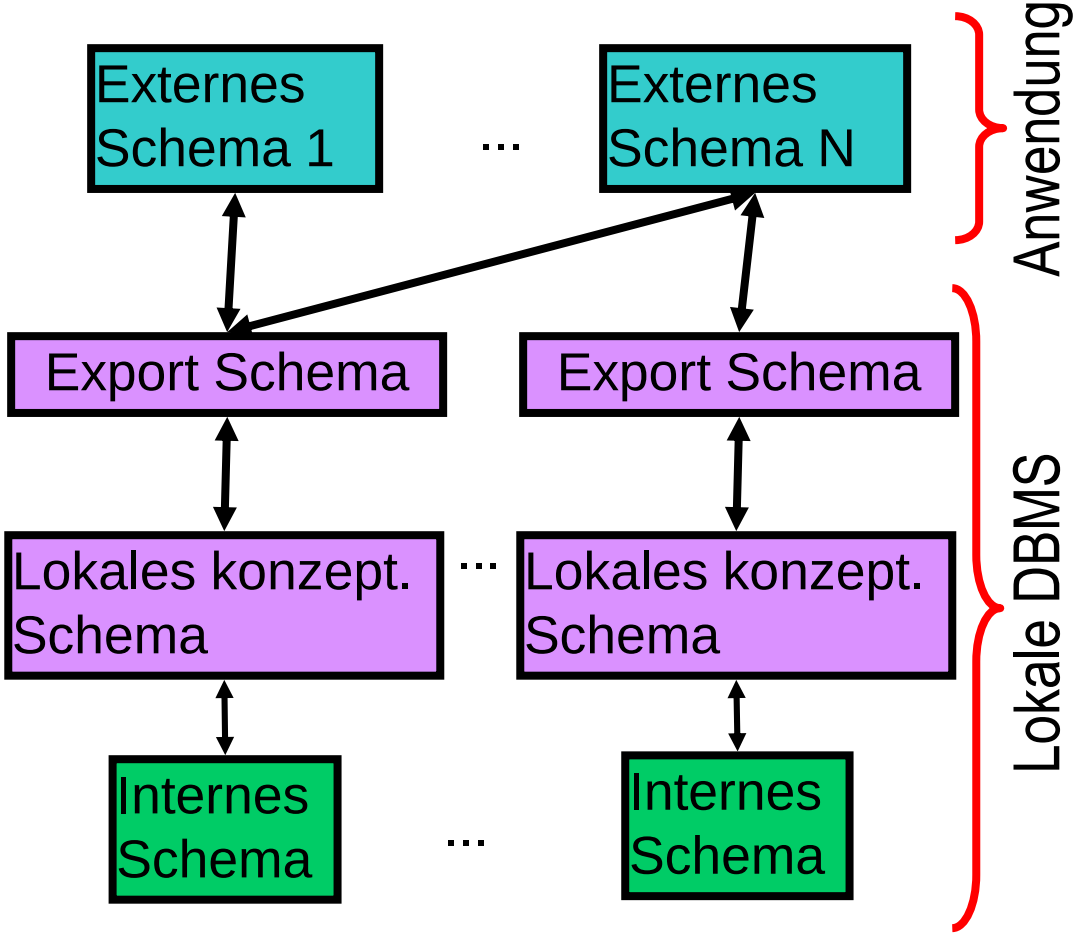

[LMR90] W. Litwin, L. Mark, N. Roussoupoulos: *Interoperability of Multiple Autonomous Databases*, ACM Computing Surveys, Vol. 22(3), pp267-293, 1990.

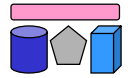

5-Schichten Architektur (nach [SL90])

- Neu:
  - Interne Schemas werden nicht mehr betrachtet.
  - Exportschemas
  - Integriertes, föderiertes Schema
- Terminologie
  - Komponentenschema = lokales konzept. Schema
  - Föderiertes Schema = globales konzept. Schema

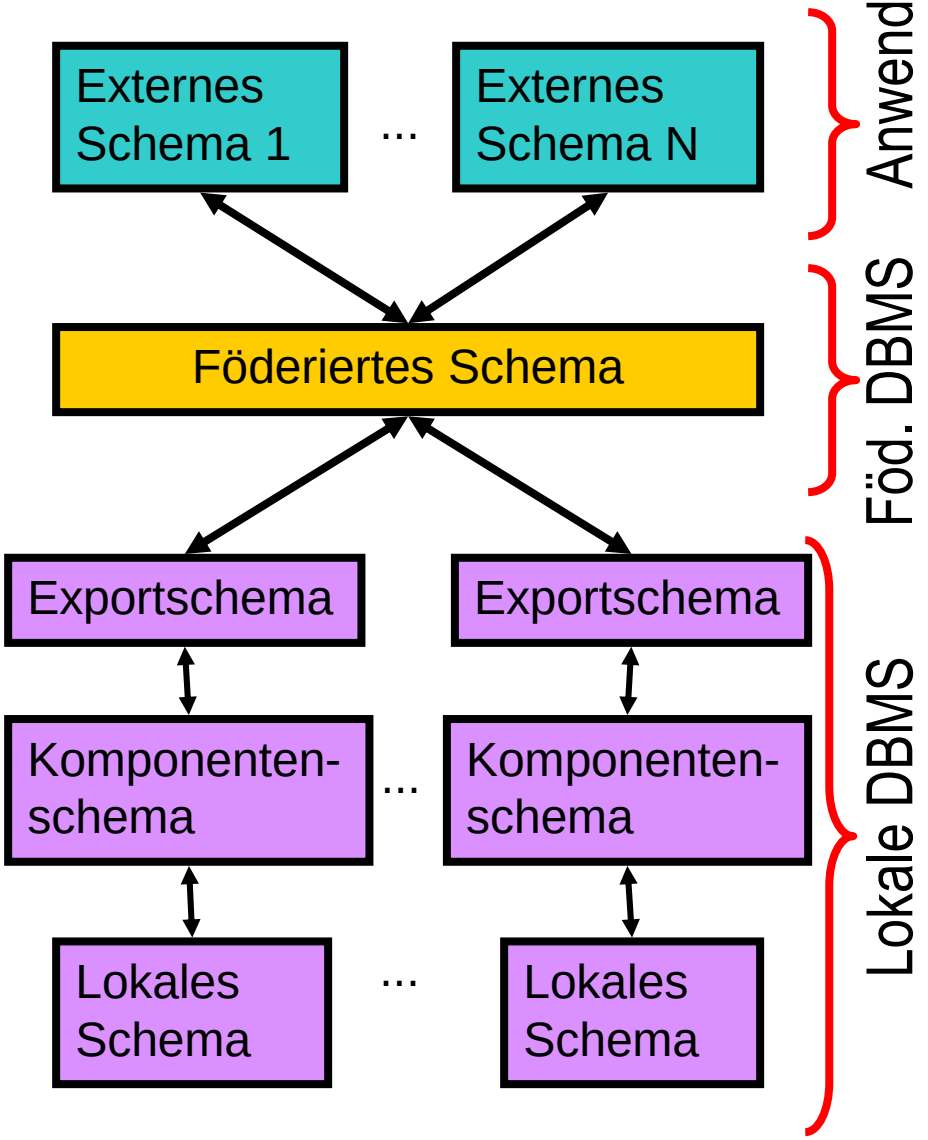

[SL90] Amit P. Sheth and James A. Larson, *Federated Database Systems for Managing Distributed, Heterogeneous, and Autonomous Databases*, ACM Computing Surveys, Vol. 22(3), 1990

5-Schichten Architektur

- Externes Schema
  - Anwendungsabhängig, Zugangskontrollen
- Föderiertes Schema (auch globales, unified, Enterprise Schema)
  - Integriert aus den Exportschemata
  - Kennt Datenverteilung
  - Föderiertes Schema kann sehr groß sein
    → Vereinfachung im Exportschema
- Exportschemata
  - Teilmenge des jeweiligen Komponentenschemas (mit Zugangsberechtigungen)
  - Unnötig, wenn komplettes Schema exportiert wird
- Komponentenschemata
  - Kanonisches Datenmodell
  - Fügt fehlende Semantik hinzu; Übergang durch Mappings
  - Unnötig, wenn lokales = kanonisches Datenmodell
- Lokale Schemata
  - Konzeptionell

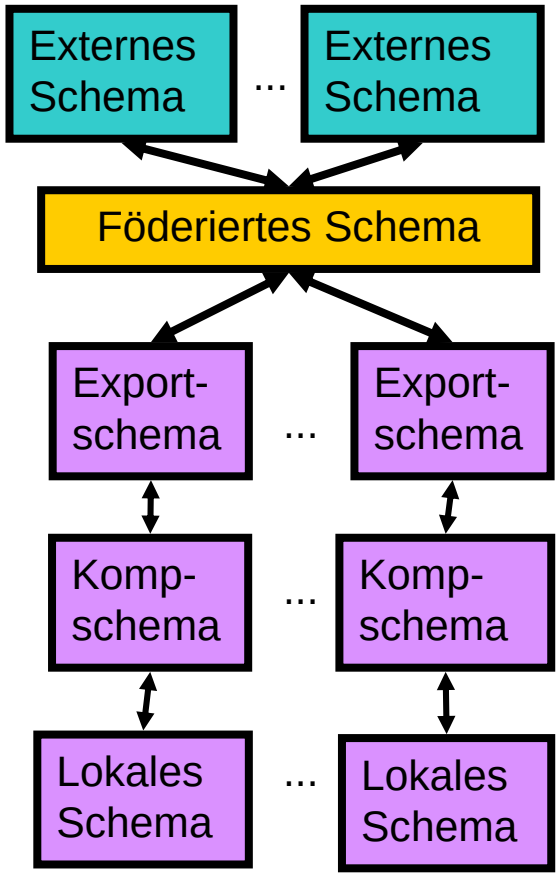

Vergleich: Föderierte Datenbanken

	Föderierte Architektur	Föderierte Datenbank	
	Import/Export	4-Schichten	5-Schichten
Art der Integration			
Integration durch			
Zugriff über			
DBMS-Funktionalität			

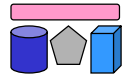

Föderierte Datenbanken: Vor- und Nachteile

- Vorteile
  - Einheitlicher Zugriff durch Datenbanksprache (z.B. Schema-SQL)
  - Anfrageoptimierung
  - Volle Anfragemächtigkeit bzgl. Exportschema
  - Auch schreibender Datenzugriff (prinzipiell) möglich
- Nachteile
  - Nur DBMS als Quellen

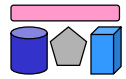

Mediator-Wrapper-Architekturen

- Ein Mediator ist eine Softwarekomponente, die Wissen über bestimmte Daten benutzt, um Informationen für höherwertige Anwendungen zu erzeugen. (nach [Wie92])
- Wrapper sind Softwarekomponenten, die die Kommunikation und den Datenfluss zwischen Mediatoren und Datenquellen herstellen.

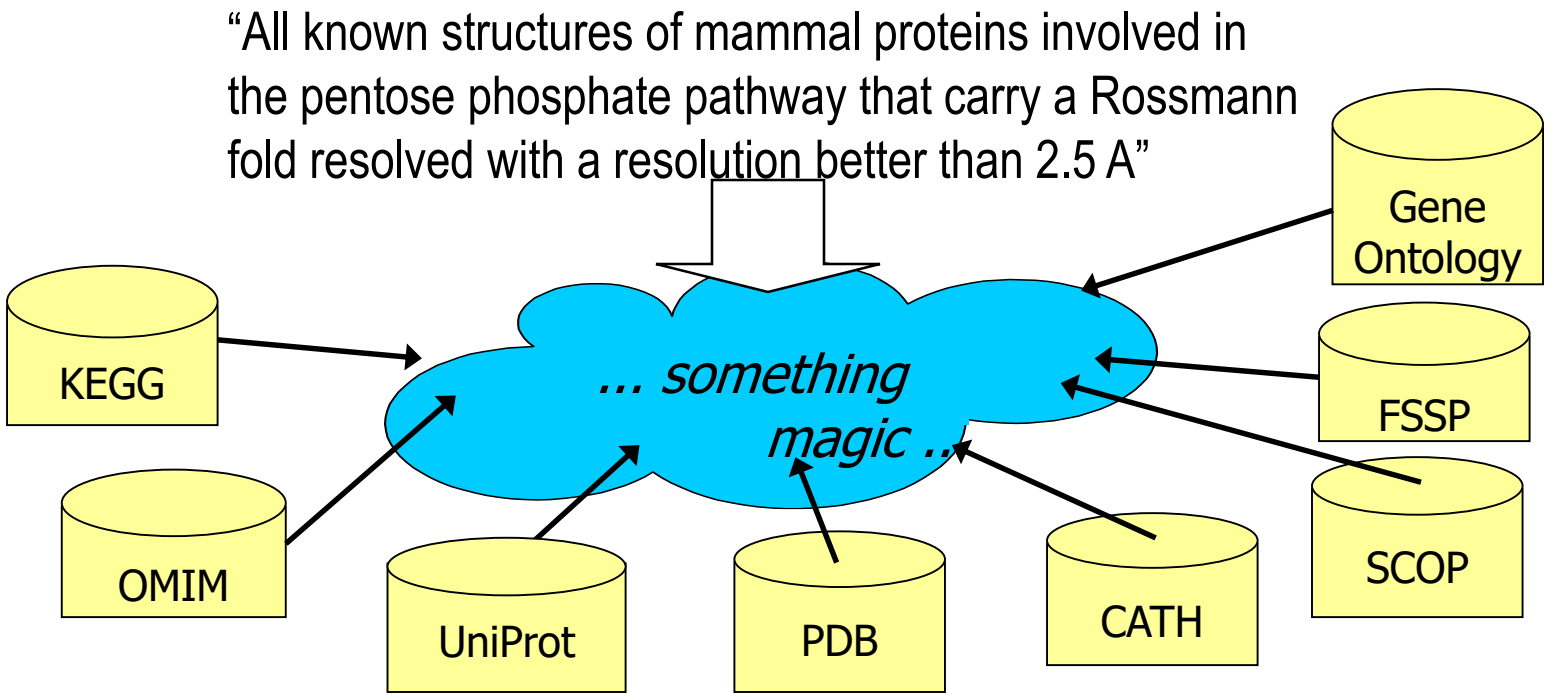

[Wie92] Gio Wiederhold: *Mediators in the Architecture of Future Information Systems*. IEEE Computer Journal, 25(3), 38-49, 1992

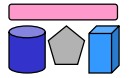

Aufbau u. Vergleich zur 5-Schichten-Architektur

- Schichtenaufbau
- Anwendungen, Mediator und Wrapper sind autonome Systeme
- Kommunikation zwischen Sytemen = Anfrage senden + Ergebnis erhalten

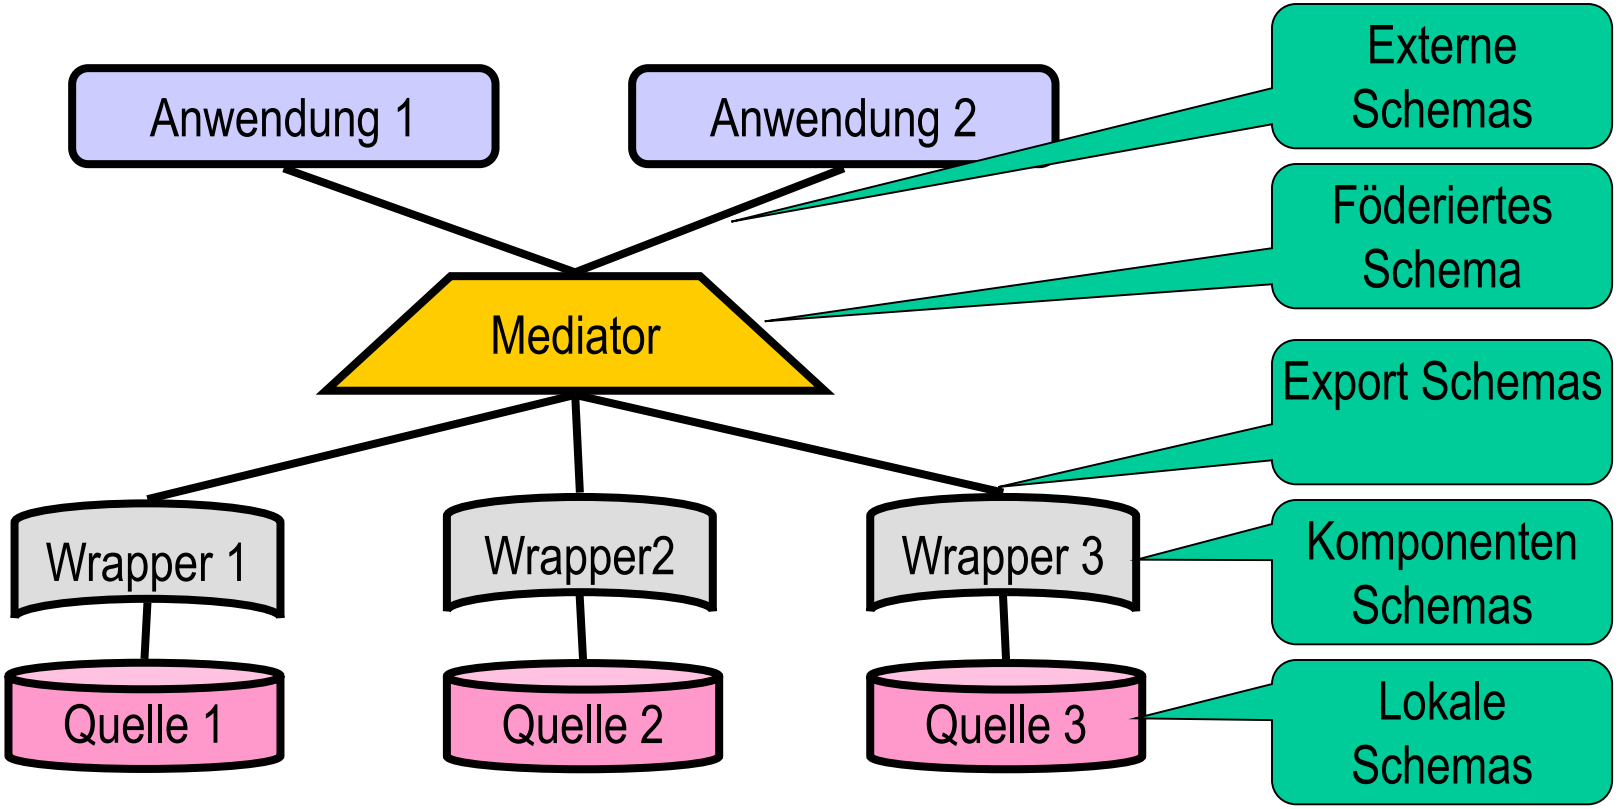

Aufbau (verallgemeinert)

- Schematisch gleiche/ähnliche Quellen können sich Wrapper “teilen”
- Mediatoren dienen als Quelle für Mediatoren → gestufter Aufbau
- Anwendungen können direkt mit Wrapper (Quelle) kommunizieren

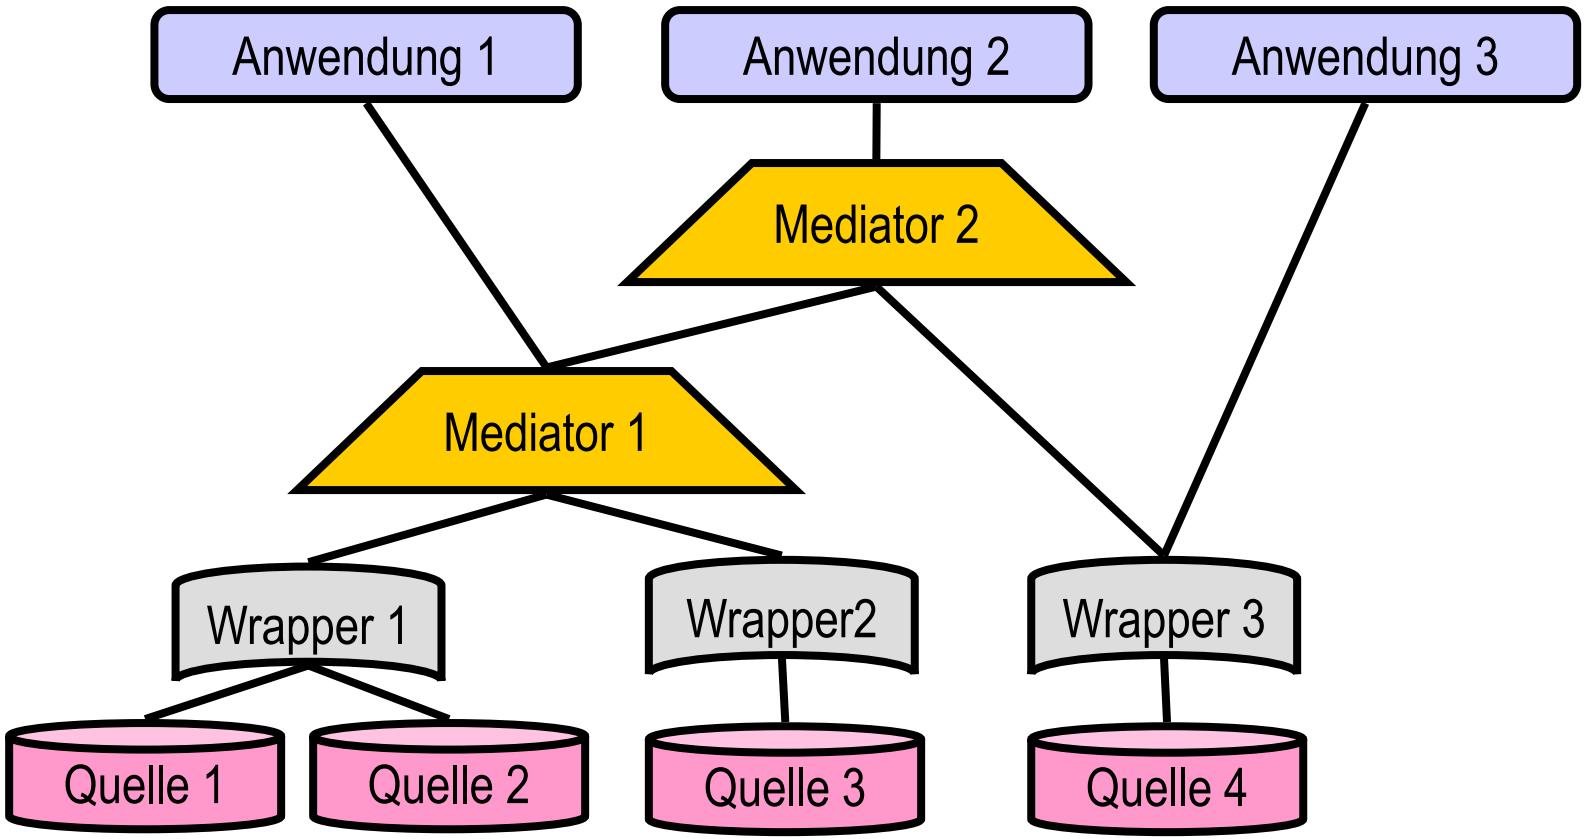

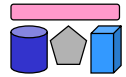

Vergleich: Mediator vs. Wrapper

- Mediator
  - Überwindet strukturelle und semantische Heterogenität
  - Führt Integration und Anfrageplanung aus
  - Benötigt oftmals Domänenwissen
  - Regelbasiert, deklarative Techniken
- Wrapper
  - Überwindet technische und Datenmodellheterogenität
  - Sollte im Rahmen wieder verwendbar sein
  - Schlanke Wrapper erwünscht
  - Quellspezifisch, kein Domänenwissen
  - Engineering, hoch-spezifisch

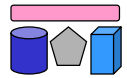

Funktionale Schichten und Schnittstellen

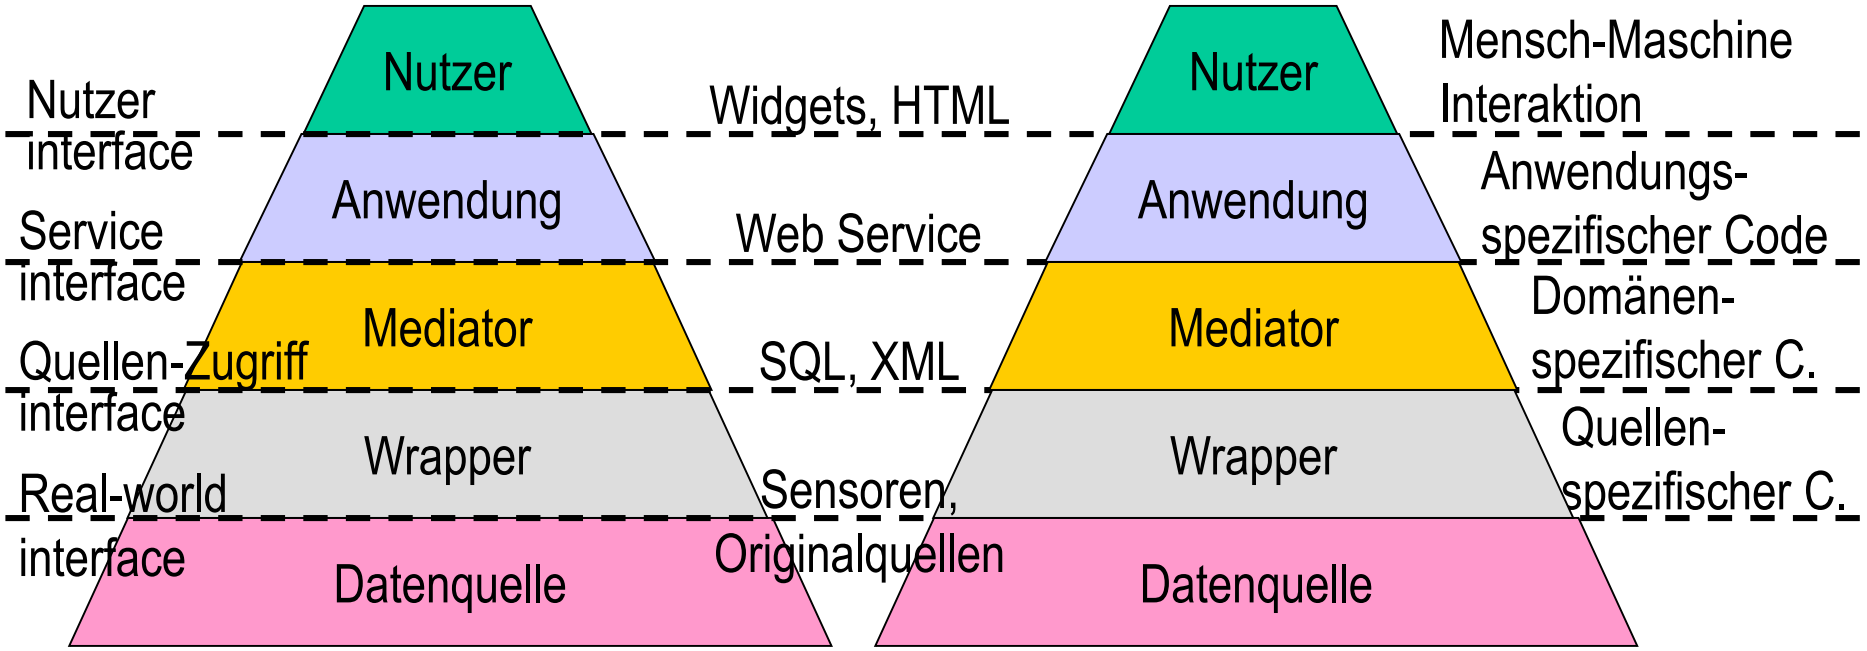

Mediatoren

- Ein Mediator sollte klein und einfach genug sein, um durch einen einzigen oder höchstens eine kleine Gruppe von Experten gewartet werden zu können
  - einfaches föderiertes Schema
  - begrenzte Domäne
  - einfache Schnittstellen
- Trennung unterschiedlicher Aufgabenbereiche
  - „Zerlege große Probleme in viele kleine Probleme“
  - Klare, begrenzte Aufgabenbereiche
  - Können unabhängig von einander entwickelt und betrieben werden
  - KISS – „Keep it as simple as possible“

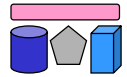

Mediatoren: Funktionen

- Erbracht durch Domänen-Experten
  - Suche und Auswahl relevanter Informationsquellen
    - Auswahl und Ranking gemäß Anforderungen und Qualität
  - Transformationen
    - Quell- und Zielformate, Konsistenzerhaltung
  - Anreicherung mit Metadaten
    - Einordnung im neuen Kontext
    - Bewertung der Qualität, Vollständigkeit, Konsistenz, …
  - Abstraktion (zum besseren Verständnis, als Auswahl)
    - Aggregation, Auswahl relevanter Daten, Zusammenfassungen
  - Integration verschiedener Quellen
- Von allgemeinen Daten zu spezifischen Informationen
  - Anwendungs- und Kontextabhängigkeit

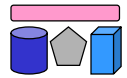

Dicke und dünne Mediatoren

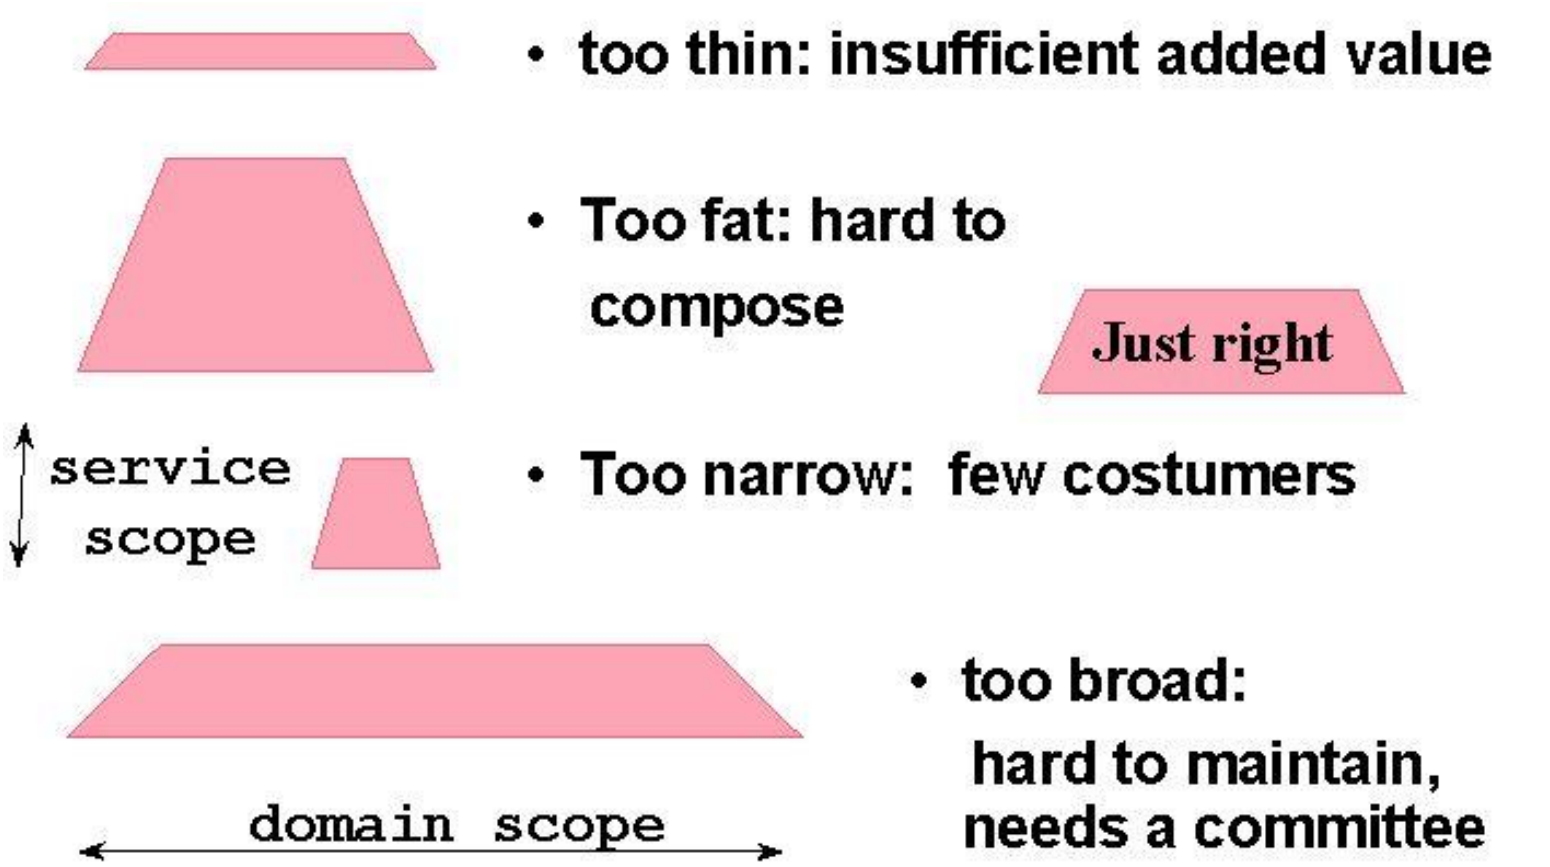

Gio Wiederhold 1999 93

Wrapper: Definition und Eigenschaften

- Softwarekomponenten, die die Kommunikation und den Datenfluss zwischen Mediatoren und Datenquellen herstellen
- “vermitteln zwischen Mediator und Quelle”

- Eigenschaften
  - jeweils spezialisiert auf eine Ausprägung autonomer, heterogener Quellen
  - Haben ein Export-Schema
  - Übersetzen Anfragen und Ergebnisse zwischen Mediator (kanonisches Datenmodell, globale Anfragesprache) und Quelle (quellspezifisches Datenmodell und Anfragesprache)

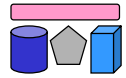

Wrapper: Aufgaben

- Lösen Schnittstellenheterogenität
  - Technisch
  - Anfragesprache (SQL, HTML Formulare, http, CORBA, …)
  - Z.T Mächtigkeit der Anfragesprache
- Lösen Datenmodellheterogenität
- Lösen evtl. schematische Heterogenität → kanonisches Schema
- Lösen *nicht* strukturelle und semantische Heterogenität
- Reduzieren Komplexität im Mediator
  - Reduzieren Anzahl der Datenmodelle
  - Reduzieren Anzahl der Schemata
- Einfache Datenkonvertierung (Übersetzungstabelle, Umrechnung, …)
- Unterstützen globale Optimierung
  - Kostenmodell, Anfragefähigkeiten

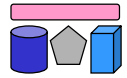

Wrapper: Anforderungen

- Sollten schnell implementiert werden können (< 1 Woche)
  - Ziel: Schnelle einfache Implementierung (Proof-of-concept)
  - Möglichkeit zur sukzessiven Verbesserung
- Sollten wiederverwendbar sein
- Lokale Wartung (bei föderierten Systemen)

- An den Wrappern scheitern viele Projekte!
  - Geringer Automatisierungsgrad – zu quellspezifisch
  - Überwindung der Datenmodellheterogenität nicht einfach
  - Viele Quellen – viele Wrapper – viel Aufwand
  - Ohne „gute Wrapper“ keine guten integrierten Daten
  - Garbage in – garbage out
- Deshalb
  - Forschung zur schnellen, (semi-) automatischen Wrappergenerierung
  - Wrapperbibliotheken

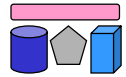

Beispiel: Web Wrapper

- „Screen Scraping“
- Umsetzung von Mediatoraufrufen in HTTP Requests
  - Die zu CGI/Servlet/PHP… Requests werden
  - Die meistens zu SQL Requests führen …
- Extraktion der gewünschten Daten aus HTML Seiten
- Umwandlung in das Datenmodell des Mediators
- Kommerziell interessant
  - Trendanalysen (Blogs), Beobachtung der Konkurrenz, Business Intelligence, Meta-X (Produktkataloge, Reisen, Paper, …)
  - Firmen: Lixto, W4F, …
- Juristische Aspekte zu beachten

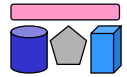

Web Wrapper: Aufbau und Funktionsweise

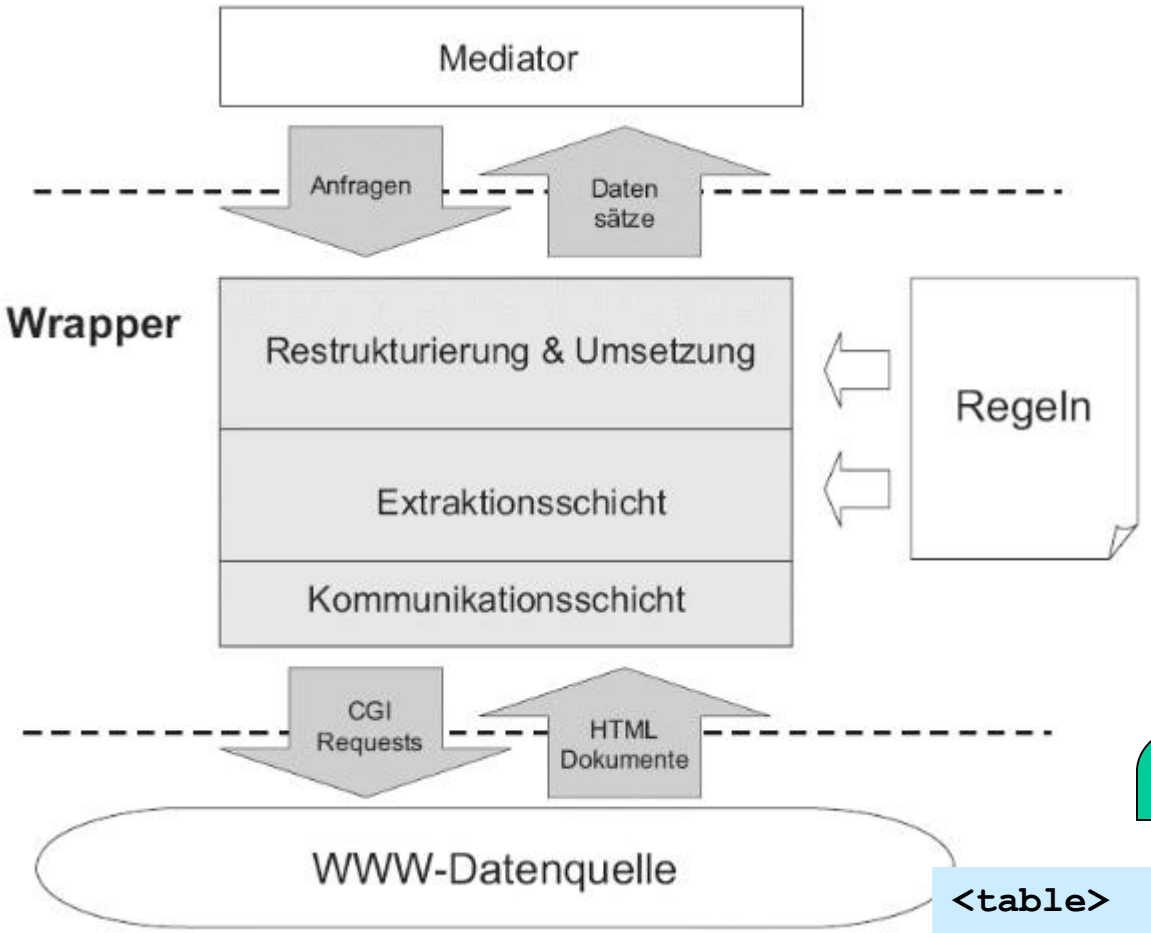

Personen	
Name	**Adresse**
Müller	Leipzig
Meier	Dresden
…	…

```
P := getPage( …);
S := region(P, tableStart, tableEnd);
R := region(S, trStart, trEnd);
clipp(S, R);
foreach region(S, trStart, trEnd);
    N := region(S, tdStart, tdEnd);
    clipp(S, N);
    A := region(S, tdStart, tdEnd);
    createRecord( N, A);
```

```
<table>
 <tr><th>Name</th><th>Adresse</th></tr>
 <tr><td>Müller</td><td>Leipzig</td></tr>
 <tr><td>Meier</td><td>Dresden</td></tr>
 …
</table>
```

Web Wrapper: DOM vs. RegEx

- Zwei unterschiedliche Herangehensweisen zur Extraktion

- DOM (Document Object Model, hierarchische Struktur der HTML-Seite)
  - Kann automatisch erstellt werden
  - Speicherplatzintensiv
  - Langsam (insbesondere wenn nur wenige Daten extrahiert werden sollen)
  - Gut bei regulären Strukturen (datenbankerzeugte Webseiten)
  - Schwierigkeiten mit irregulärem HTML
  - Anfällig für Änderungen in der Reihenfolge oder Einschübe neuer Elemente
  - Kann Textfelder nicht weiter unterteilen (also doch reguläre Ausdrücke nötig)
- Reguläre Ausdrücke (RegEx, regular expressions)
  - Schnelle Ausführung
  - Unübersichtlich
  - Kompliziert, wenn geschachtelte Elemente benötigt werden
  - Benötigen stabile Ankerelemente (Überschriften etc.)

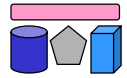

Web Wrapper

- Echte Web-Wrapper-Sprachen müssen mehr können
  - Webpage-Wrapping versus Website-Wrapping
  - Verfolgen von Links und Nachladen von Seiten
  - Rekursive Verfeinerungen
    - Sukzessive Anwendung immer genauerer regulärer Ausdrücke
  - Abbildung extrahierter Daten (Listen, Terme, Tabellen) auf ein Exportschema
  - Variablen, Funktionen, Schleifen, Fehlerbehandlung
  - Einfache Anfragefunktionalität
    - Wrapper.get(‚SELECT adresse FROM personen WHERE name=‚Meier‘);
  - „Erraten“ von Wrappern (Wrapper Induktion)
  - …
- Schwierig
  - JavaScript, Web 2.0 (AJAX)

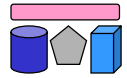

Mediator-Wrapper-Ansatz: Vor- und Nachteile

- Vorteile
  - Flexibler Integrationsansatz mit stets aktuellen Daten (virtuelle Integration)
  - Geringe Anforderungen an Quellen (hohe Autonomie)
  - Integrationssystem modular erweiterbar (neuer Wrapper, neuer Mediator)
- Nachteile
  - Nur begrenzt skalierbar
    - Anwendungen mit max. 7±2 Mediatoren; Mediatoren für max. 7±2 Quellen [Wie99]
  - Regelmäßige Wartung/Anpassung der Wrapper notwendig
  - Anfragemöglichkeit ggf. beschränkt durch Quellen
  - Sicherstellung der Datenqualität (u.a. Duplikaterkennung) zur Laufzeit (Performanz)

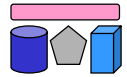

Peer-Data-Management-Systeme: Szenario

- Genomdaten
  - Forscher haben den Willen (und die Pflicht), Daten weltweit zu veröffentlichen.
  - Komplexe Schemata und komplexe Anfragen
  - Bekannte Zusammenhänge zwischen den Daten
  - Bildung eines globalen Schemas nicht immer einfach
- Gesundheitsinformationssystem
  - Krankenhausdaten auf vielen Systemen verteilt
  - Ärzte wollen manche Daten verbreiten, andere nicht.
  - Content-Management-artige Suche ist wichtig.
  - Verschiedenste und komplexe Schemata
  - Mehrwert (für Patienten) durch Teilen der Daten

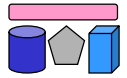

Peer-Data-Management-Systeme

- Grundidee: Strukturierte Peer-2-Peer Netzwerke (“P2P mit SQL”)
- Jeder Peer kann
  - Daten exportieren (= Datenquelle)
  - Sichten auf Daten zur Verfügung stellen (= Wrapper)
  - Anfragen anderer Peers entgegennehmen und weiterleiten (= Mediator)
  - Anfragen stellen (Benutzer)
- Verknüpfungen nicht zwischen lokalen und globalem Schema, sondern zwischen Paaren von Peer-Schemata (kein globales Wissen)

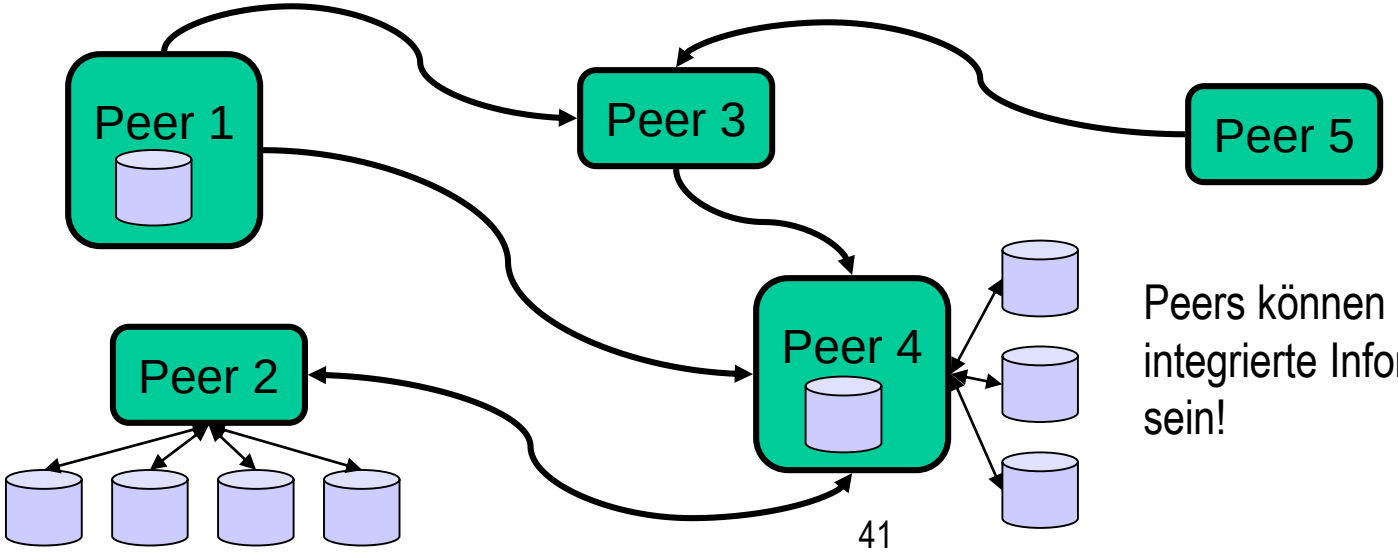

Peers können selbst wiederum integrierte Informationssysteme sein!

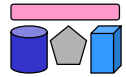

Peer-DMS am Beispiel von Piazza [HIST03]

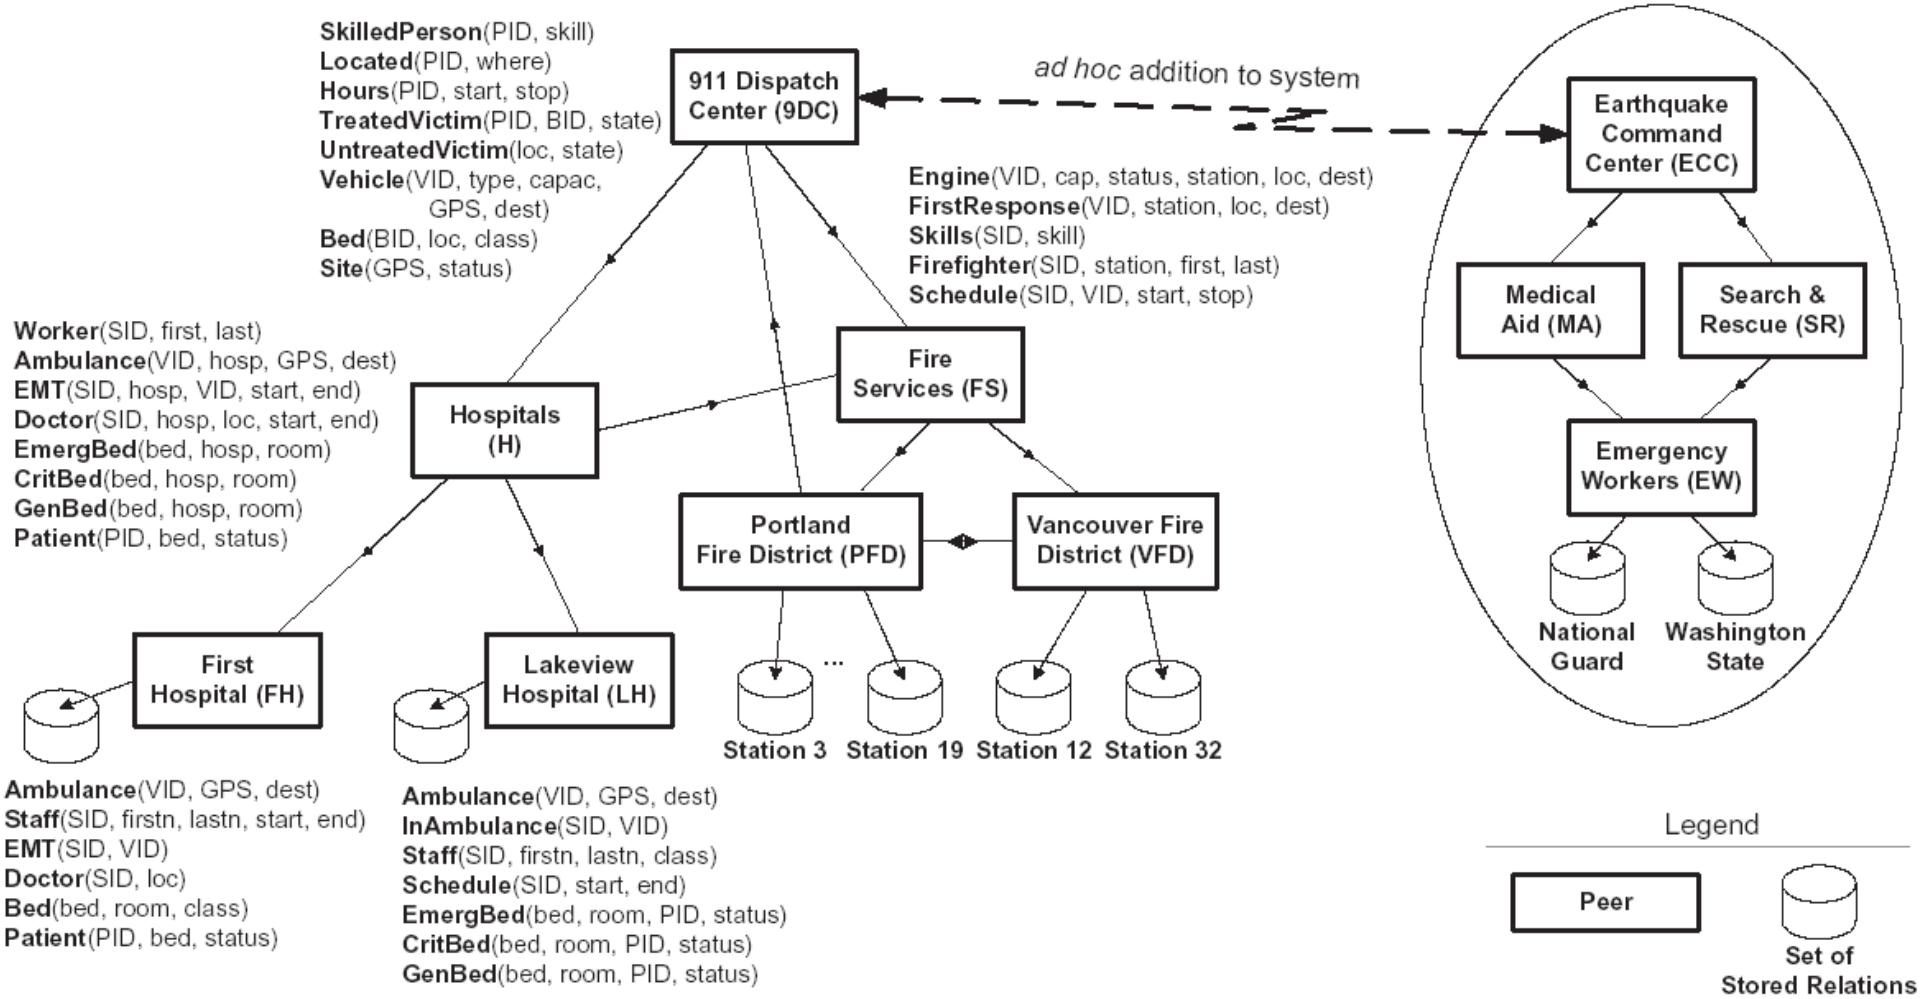

[HIST03] Halevy, Ives, Suciu, Tatarinov: *Schema Mediation in Peer Data Management Systems.* ICDE 2003

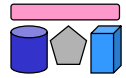

Peer-to-Peer-Systeme vs. Peer-DMS

	Peer-to-Peer	Peer-Data-Management-System
Granularität der Daten	Niedrig, nur ganze Dateien	
Anfragen	Einfache Keyword-Suche auf Dateinamen und -metadaten	
Anfrageergebnis	Unvollständig (best-effort)	
Anfrageverteilung	Gemäß (proprietärem) Protokoll	
Schema	Einfach (Dateiname, dateiabhängige Metadaten)	
Dynamik	Sehr hoch, ständiger Bei- und Austritt von Peers	
Skalierbarkeit	Millionen von Peers	

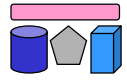

Mapping-Komposition

- Komposition zur Propagation von Anfragen
  - Bei jedem Mapping/ Zwischenschritt geht potentiell Information verloren
  - Kann nicht durch spätere Schritte ausgeglichen werden

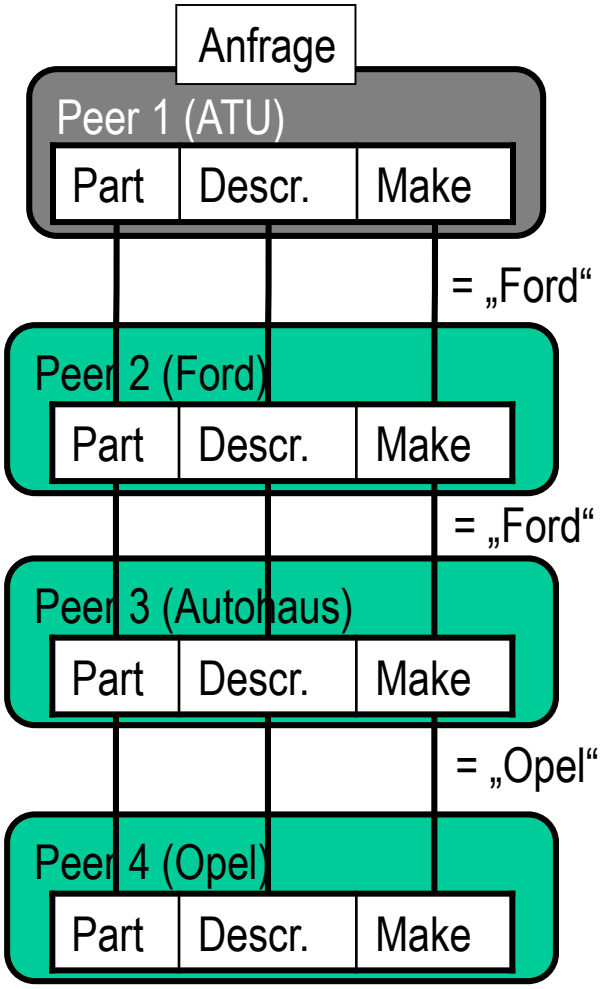

Probleme

Kumulierte Selektion (links)
- implizit in Schemata
- explizit in Mappings
- Punkt-und Bereichs-Selektionen

Kumulierte Projektion (rechts)
- in Schemata
- in Mappings

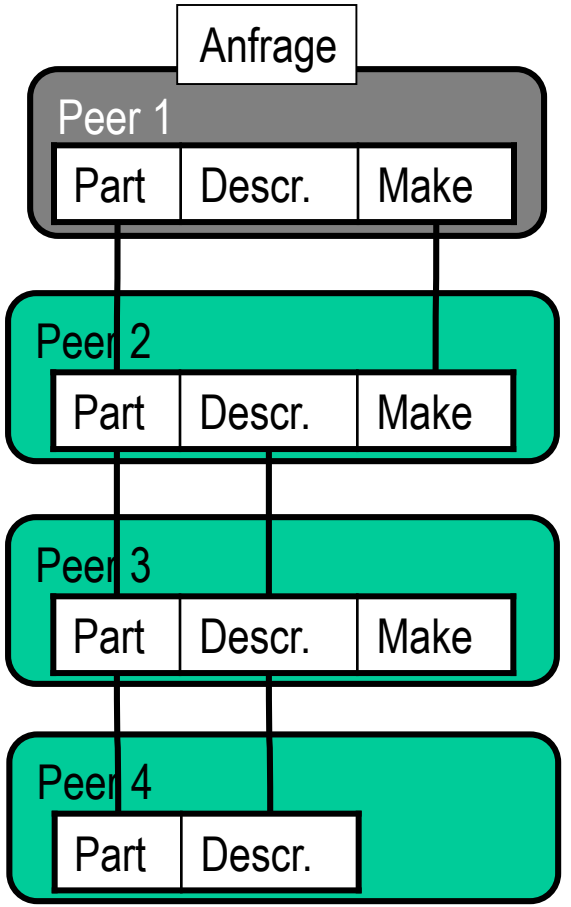

Peer-DMS: Vor- und Nachteile

- Vorteile
  - Nutzer müssen nur eigenes Schema kennen
  - Dennoch sind weitere Daten (über transitive Hülle der Mappings) verfügbar
  - Neue Schemas können leicht und inkrementell hinzugefügt werden.
  - Mapping nur zum ähnlichsten Schema nötig
- Nachteile / Probleme
  - Mapping Komposition
    - Effizienz (bei vielen Zwischenstationen)
    - Informationsqualität: Schleichender Informationsverlust über mehrere Mappings
    - Vollständigkeit des Ergebnisses nicht gewährleistet
  - Vertrauen in alle Peerdaten

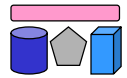

Vergleich von Integrationsarchitekturen

	Data Warehouse	Föderierte Datenbank	Mediator-Wrapper	Peer-DMS
Instanzintegration				
Zeit Duplikat-erkennung				
Globales Schema				
Zeit Schema-integration				
Anfrage bzgl.				
Datenqualität				
Skalierbarkeit (#Quellen)				
Analyse großer Datenmengen				
Autonomie der Quellen				
Aktualität der Daten				

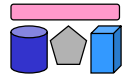

Weitere Architekturen

- Jede Architektur hat Vor- und Nachteile bzw. Stärken und Schwächen
- Kombination oder Modifikation von “Standard-Ansätzen” für bestimmte Anwendungen sinnvoll

- Beispiel 1: Materialisierte und virtuelle Integration
  - DWH kombiniert mit Mediator
  - Prototyp: GeWare-Erweiterung
- Beispiel 2: Instanzbasierte P2P-artige Verknüpfung
  - P2P-Verknüpfung kombiniert mit Mediator-Steuerung und generischem Warehouse
  - Prototyp: iFuice

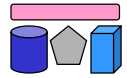

Beispiel 1: Materialisiert + Virtuell

- GeWare-Erweiterung [KDKR05]
  - GeWare = Gene Expression Warehouse
- Data Warehouse enthält experimentelle Daten für performante Analysen
- Aktuelle Annotationsdaten können bedarfsgesteuert über Mediator inzugezogen werden
- Mapping-Datenbank enthält vorberechnete Verbindungen zwischen Objekten für performante Join-Berechnung

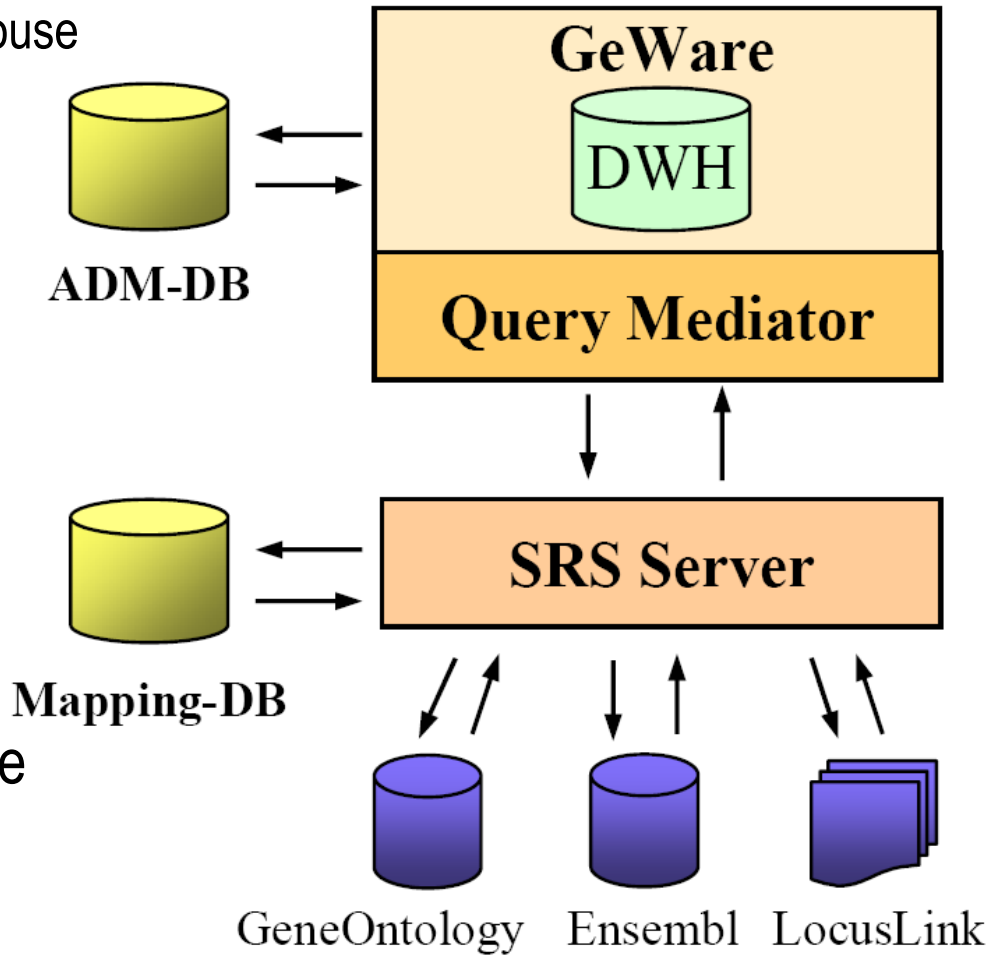

[KDKR05] Kirsten, T., Do, H. H., Körner, Ch., Rahm, E.: *Hybrid Integration of molecular-biological Annotation Data*. Proc. of DILS, 2005

Beispiel 2: Instanzbasierte P2P-artige Verknüpf.

- iFuice [RT05] basiert auf P2P-Verknüpfung von Objekten via Mappings
  - Information Fusion utilizing Instance Correspondences and Peer Mappings
- Mediator ermöglicht bedarfsgesteuerte Verarbeitung in Skripten
  - keine deklarative Anfragesprache sondern Datenfluss (ähnlich ETL bei DWH)
- Speicherung aller Daten (Objekte, Mappings) in generischem Warehouse

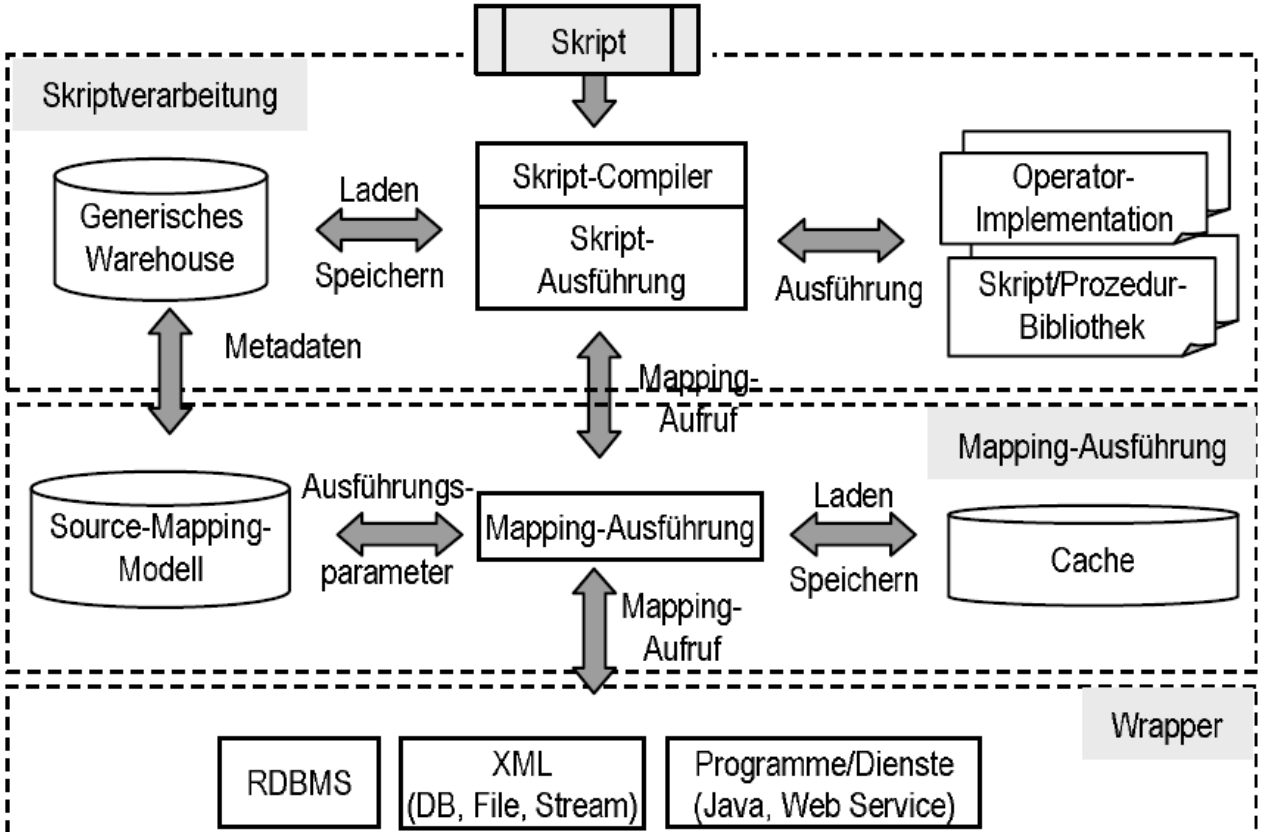

[RT05] Rahm, Thor, et. al. : *iFuice - Information Fusion utilizing Instance Correspondences and Peer Mappings*. In Proc. of WebDB, 2005

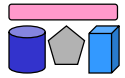

Architekturen vs. Integrationsaufgaben

- Integrations(teil)aufgaben
  - Anfrageübersetzung: Überführung von Anfragen von Schema A nach Schema B
  - Schemaintegration: Bildung eines globalen Schemas aus Quellenschemata
  - Schema Matching: Ermitteln von Korrespondenzen zwischen Elementen zweier Schemata (=Schema Mapping)
  - Datentransformation: Überführung von Instanzdaten mit Schema A nach Schema B
  - Duplikaterkennung: Identifikation von “gleichen” Datensätzen
  - Konfliktbehandlung: Auflösung widersprüchlicher/fehlender Informationen

	DWH	Föd-DBMS	Med.-Wrap.	Peer-DMS
Anfrageübersetzung				
Schemaintegration				
Schema Matching				
Datentransformation				
Duplikaterkennung				
Konfliktbehandlung				

+ relevant
o evtl. relevant
– nicht relevant

Kapitel 5-7 betrachten Integrations-aufgaben

Zusammenfassung

- Übersicht über Arten von Integrationssystemen
  - U.a. bzgl. Integrationsart und Verwendung eines globalen Schemas
- Vorstellung und Vergleich typischer Integrationsansätze
  - Data Warehouse
  - Föderierte Datenbanken
  - Mediator-Wrapper-Ansatz
  - Peer Data Management Systeme
- Hybride Ansätze
  - Kombination der Stärken einzelner Architekturen für bestimmte Einsatzzwecke
- Architekturen vs. Integrations(teil)aufgaben
  - Anfrageverarbeitung $\rightarrow$ Kap. 5
  - Schemamanagement $\rightarrow$ Kap. 6
  - Informationsfusion $\rightarrow$ Kap. 7