

Bio Data Management

Kapitel 8

Datenintegration - Ansätze und Systeme

Wintersemester 2014/15

Dr. Anika Groß

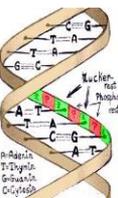
Universität Leipzig, Institut für Informatik, Abteilung Datenbanken

<http://dbs.uni-leipzig.de>



Vorläufiges Inhaltsverzeichnis

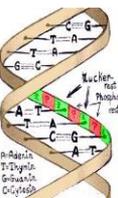
1. Motivation und Grundlagen
2. Bio-Datenbanken
3. Datenmodelle und Anfragesprachen
4. Modellierung von Bio-Datenbanken
5. Sequenzierung und Alignments
6. Genexpressionsanalyse
7. Annotationen
8. Datenintegration: Ansätze und Systeme
9. Matching
10. Versionierung von Datenbeständen



Gliederung

- Motivation & Datencharakteristik
- Schema- und Instanzdatenintegration
- Physische vs. virtuelle Integration

- Beispiel LIFE: epidemiologische Studie



Problembereich: Datenintegration



Experimentelle Daten
z.B. Microarray-Daten




Differentiell exprimierte STAT3 Gene bei malignen Lymphomen von Patienten, die älter als 50 Jahre sind?



Daten über biol. Objekte,
z.B. Gene, Proteine



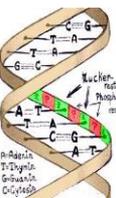
Klinische Daten
z.B. Patientendaten



...

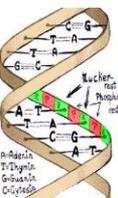
Aufgabenspektrum:

- Selektion von interessanten Daten,
- übergreifenden Datenanalyse und
- Interpretation von Analyseergebnissen



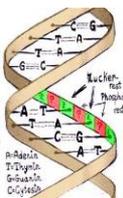
Motivation

- Verschiedene Arten von Analysen
 - Analyse von Sequenzdaten (z.B. multiple alignments)
 - Identifikation von Transkriptionsfaktorbindungsstellen
 - Genexpressionsanalyse
 - Transkriptionsanalyse, z.B. ENCODE Projekt (<http://www.genome.gov/ENCODE>)
 - Functional profiling
 - Pathway Analyse und Rekonstruktion
- Viele heterogene Datenquellen
 - Experimentdaten, z.B. von Chip-basierten Techniken
 - Experimentbeschreibung (Metadaten eines Experiments)
 - Klinische Daten
 - Viele miteinander verbundene Webdatenquellen und Ontologien
 - Private vs. öffentliche Daten

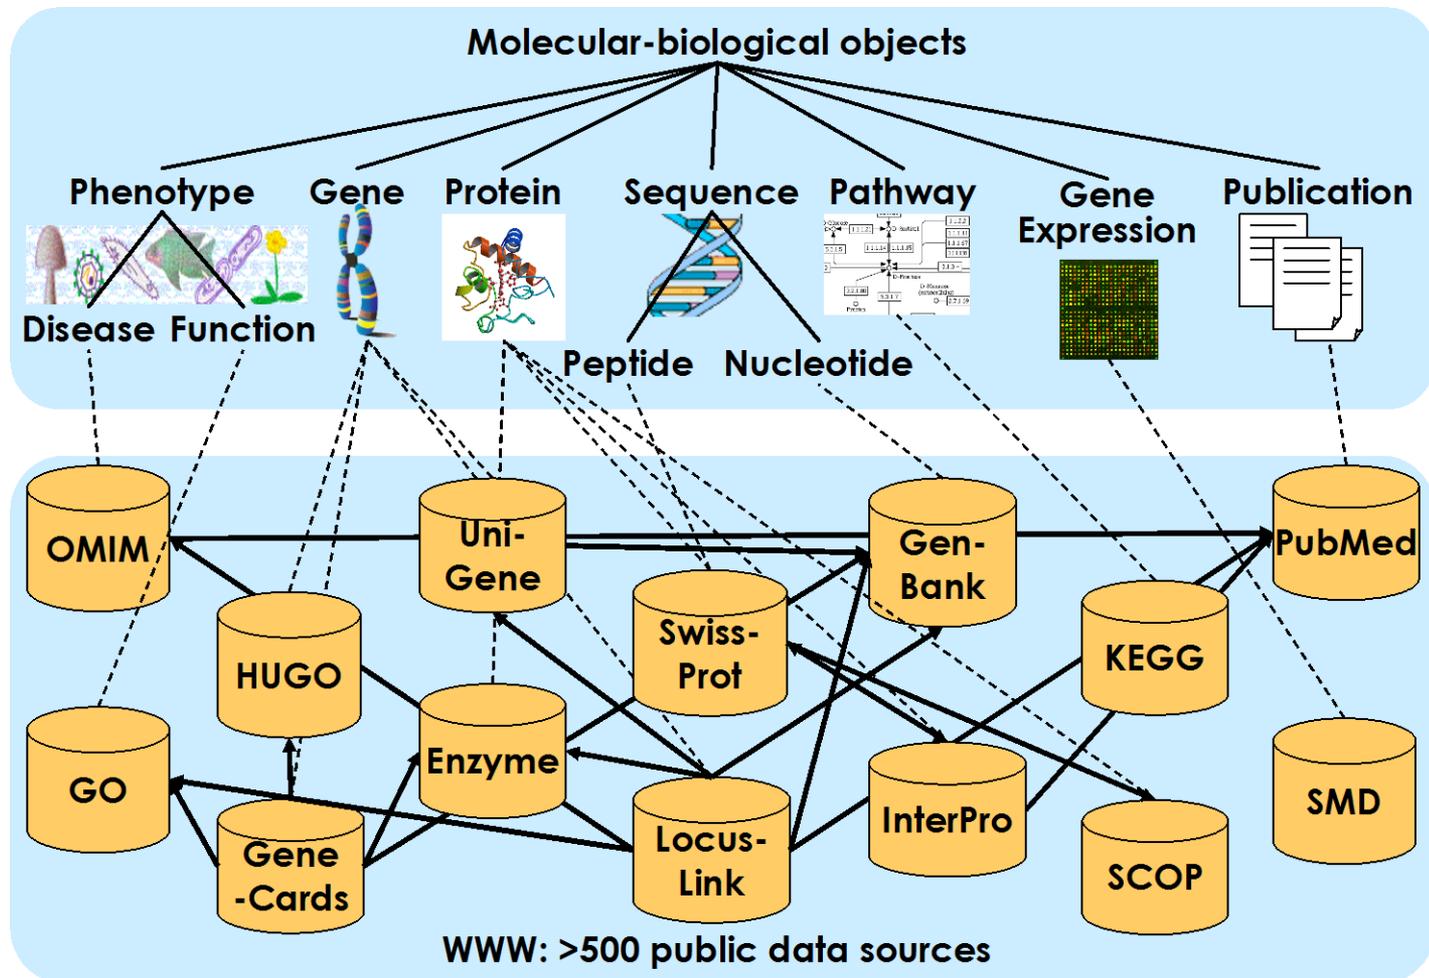


Datencharakteristika

Datenart	Quelle	Typ	Charakteristik	Nutzung
Bilddaten	Scan	binär	Sehr großes Datenvolumen, Dateien	Generierung von Expressions-, Mutations- und Sequenzdaten
Expressions-/ Mutationsdaten	Bildverarbeitung	numerisch	schnell wachsendes und großes Datenvolumen; aber kleiner als Bilddaten	Visualisierung, statistische und genetische Analyse, Data Mining
Sequenzdaten		Text		
Experiment-Annotation	Eingabe durch Benutzer	gemischt: Text, numerisch, ...	oftmals Freitext, Umfang + Inhalt variiert je nach Experimenttyp	Dokumentation, Selektion, Interpretation
Klinische Daten	Studienmanagement-system	gemischt: Text, numerisch, ...	Umfang + Inhalt variiert je nach Studie	Selektion, Interpretation



Bio-Datenquellen

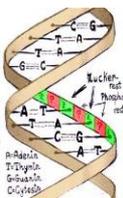


Legends

Object classification

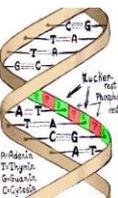
Source classification

Source cross-reference



Verschiedene Arten von Webdatenquellen

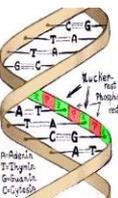
- **Genomdatenquellen:** Ensembl, NCBI Entrez, UCSC Genome Browser, ...
 - Objekte: Gene, Transkripte, Proteine etc. verschiedener Spezies
- **Objektspezifische Datenquellen:**
 - Proteine: UniProt (SwissProt, Trembl), Protein Data Bank (PDB),...
 - Proteininteraktionen: BIND, MINT, DIP, ...
 - Gene: HUGO (standardisierte Gensymbole für humanes Genom), MGD, ...
 - Pathways: z.B. KEGG (metabolische & regulatorische Pathways)
- **Publikationsquellen:** Medline / Pubmed (>16 Mio Einträge)
- **Ontologien:** zur einheitlichen und semantischen Beschreibung (Annotation) der Eigenschaften biologischer Objekte
 - Gene Ontology: Molekulare Funktionen, Biologische Prozesse, Zelluläre Komponenten
 - Ontologie-Sammlung: Open Biomedical Ontologies (OBO)



Datenintegration

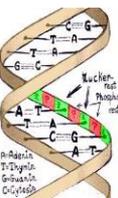
- Datenintegration = Informationsintegration
- Korrekte, vollständige und effiziente Zusammenführung von Daten und Inhalt verschiedener, heterogener Quellen zu einer einheitlichen und strukturierten Informationsmenge zur effektiven Interpretation durch Nutzer und Anwendungen*
= Zusammenfügung von Metadaten und Instanzdaten
- Ziel: Mehrwert, der sich aus der Kombination von Daten ergibt
 - Bessere Ergebnisse = umfassender, qualitativ hochwertiger, abgesicherter
 - Anfragen, die nur von Daten mehrerer Datenquellen beantwortet werden können

*Leser, Naumann: Informationsintegration, dpunkt.verlag, 2007.



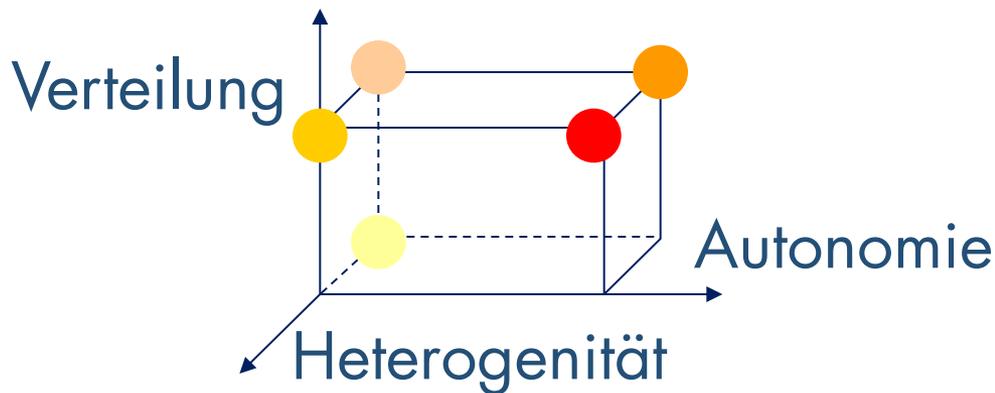
Probleme bei einer Datenintegration

- Komplexe Fragestellungen → Nutzung vieler verschiedener Datenquellen
- Weite Verteilung der Daten
- Hohe Redundanz (überlappende Quellen)
- Heterogenität der Datenquellen bzgl.
 - Syntax
 - Schema/Struktur
 - Semantik
 - Schnittstellen
- Evolution von Daten und Schemata



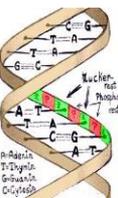
Verteilung, Autonomie, Heterogenität*

- Architekturraum durch drei orthogonale Aspekte charakterisiert
 - **Verteilung**: physisch, logisch
 - **Autonomie**, zB bzgl. Design, Schnittstellen, Evolution, Zugriff, ...
 - **Heterogenität**



- homogene, zentrale DB
- verteilte DB
- verteilte heterogene DB
- verteilte autonome DB
- verteilt, heterogen, autonom

* Leser/Naumann: Informationsintegration, dpunkt.verlag, 2007, S. 49ff

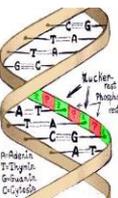


Architekturvarianten im Überblick

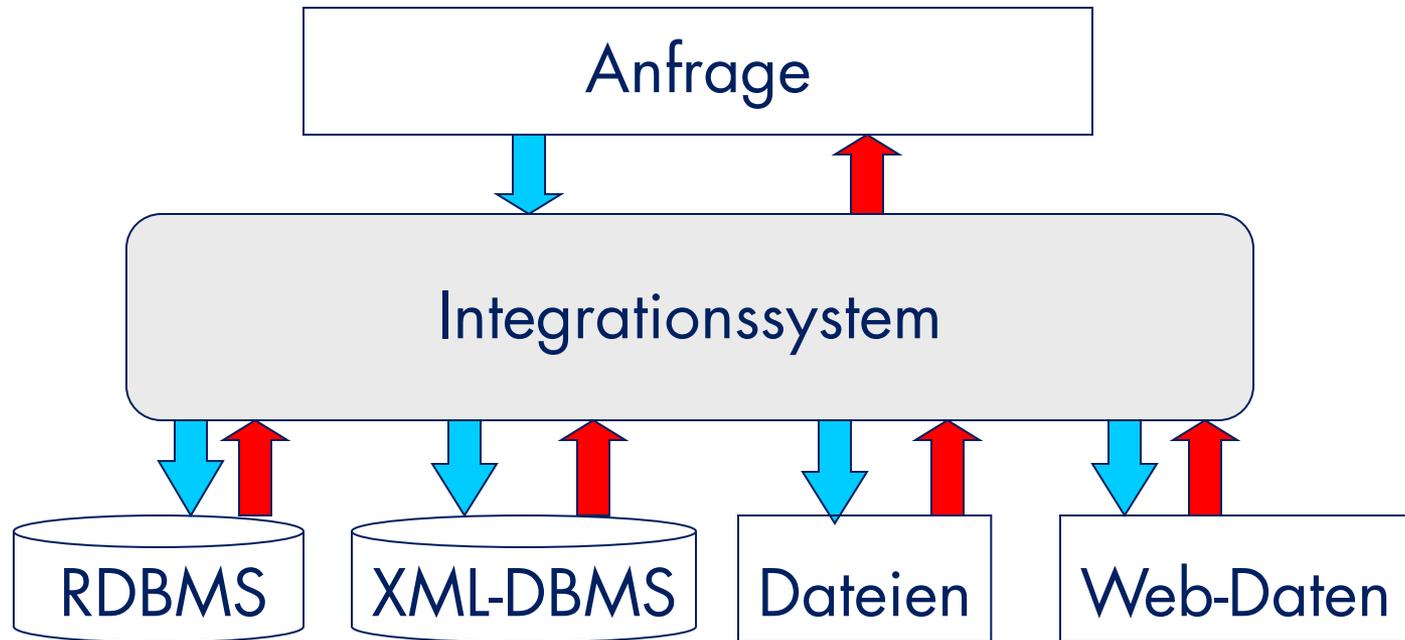
- Monolithische Datenbanken
- Förderierte Datenbanken
- Mediator-basierte Systeme
- Peer-Daten-Management-Systeme

- Suchmaschinen
- Portale

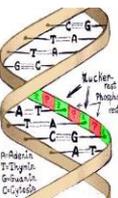
- ...



Datenintegration

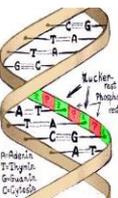
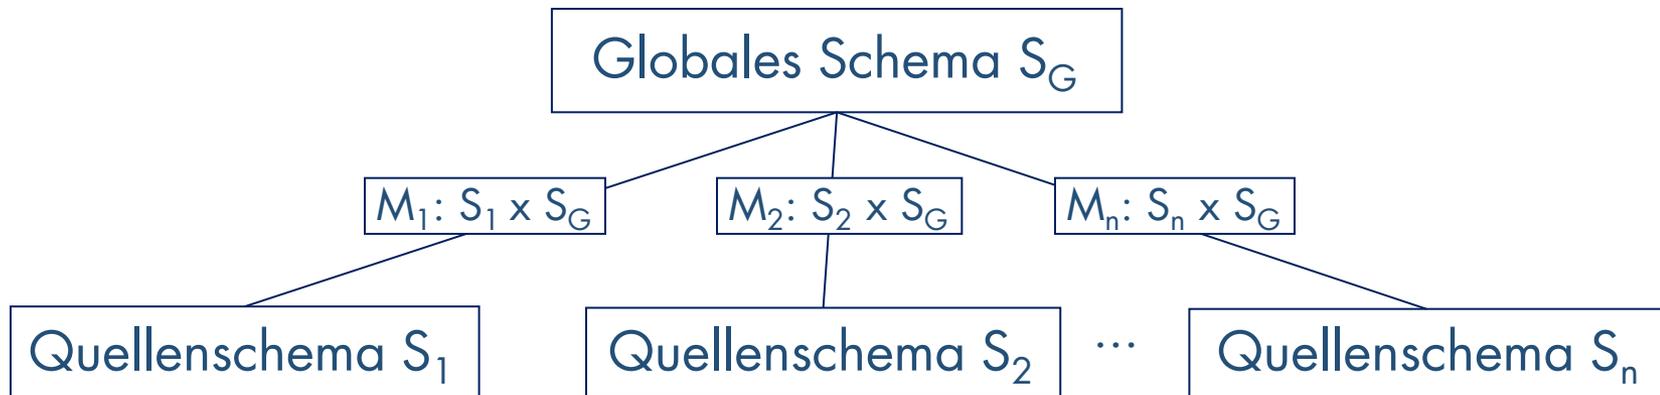


- Zwei orthogonale Aspekte:
 - Schemaintegration
 - Instanzdatenintegration



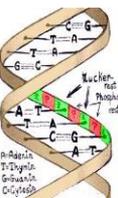
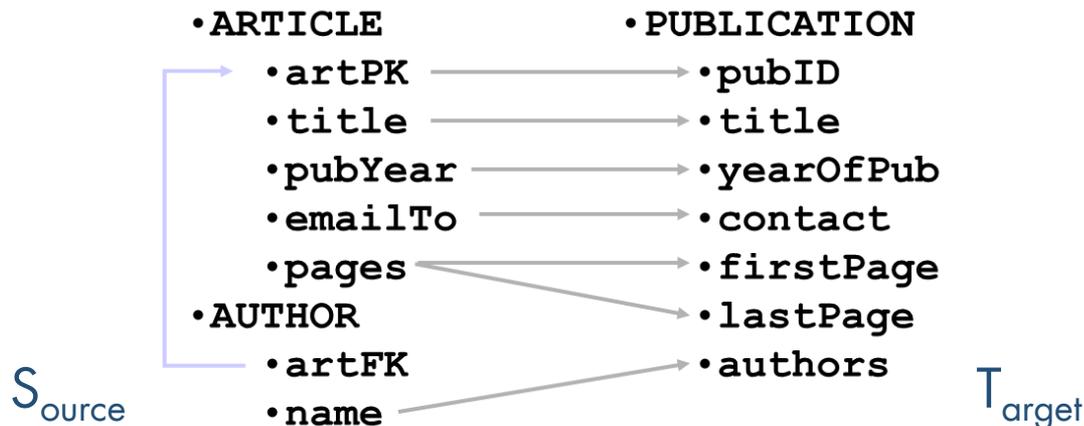
Schemaintegration

- Schemaintegration = Metadatenintegration
- Ziel: Erstellung einer 'homogenisierten Sicht' (globales Schema) auf die zu integrierenden Datenquellen
- Globales Schema:
 - Enthält alle relevanten Schemaelemente der zu integrierenden Datenquellen
 - Schema-Mappings zwischen globalem und Quellschemata

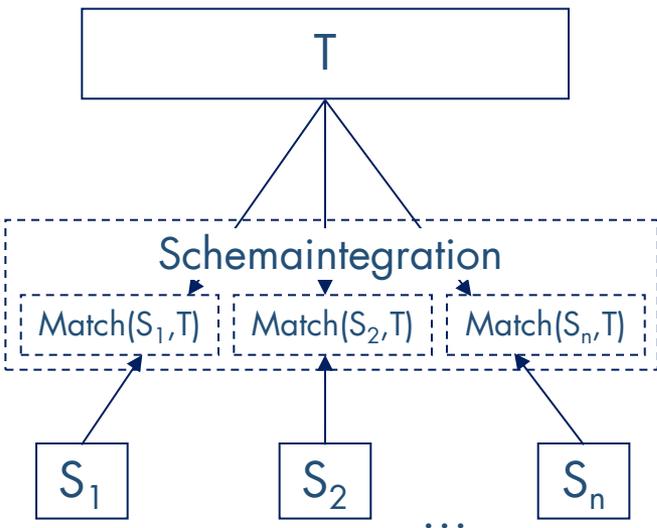


Schema-Mapping

- Entstehung durch Schema-Matching (Prozess)
 - Eingabe: Schemata $S_{\text{source}}, T_{\text{target}} \in S_{1, \dots, n}$, Algorithmus
 - Ausgabe: Schema-Mapping $M: S \times T$
- Mapping-Eigenschaften:
 - Semantik: oftmals Äquivalenzrelation
 - bidirektional
 - Suche nach 1:1 Beziehung zwischen den Elementen (aber nicht immer möglich: Name \leftrightarrow Vorname, Nachname)
 - Problem: Transformationen, z.B. Aggregation von Daten



Top-Down vs. Bottom-Up



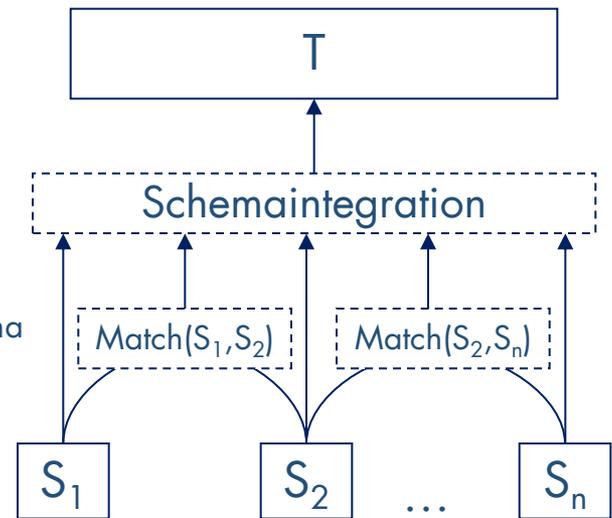
Top-Down-Integration

Globales Schema

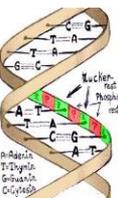
Schemaintegration durch

Zuordnung zum globalen Schema Bildung des globalen Schema

Schemata der Quellen

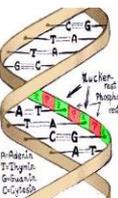


Bottom-Up-Integration

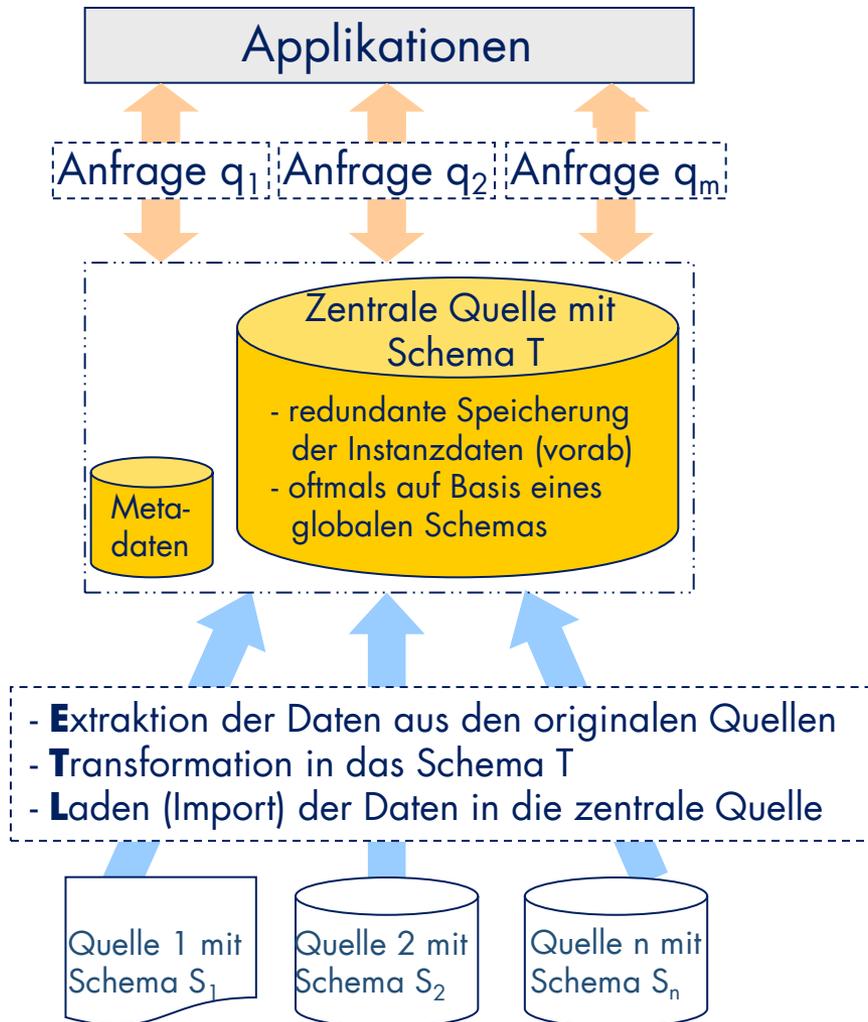


Instanzdatenintegration

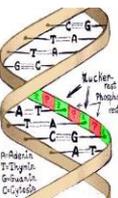
- Instanzdatenintegration: Zusammenfügen der Daten aus den verschiedenen Datenquellen
 - Materialisiert: Prozess der Vorverarbeitung (ETL)
 - Virtuell: zur Beantwortung einer Anfrage
- Basis: Schema-Mappings



Physische/materialisierte Integration

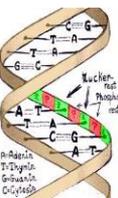
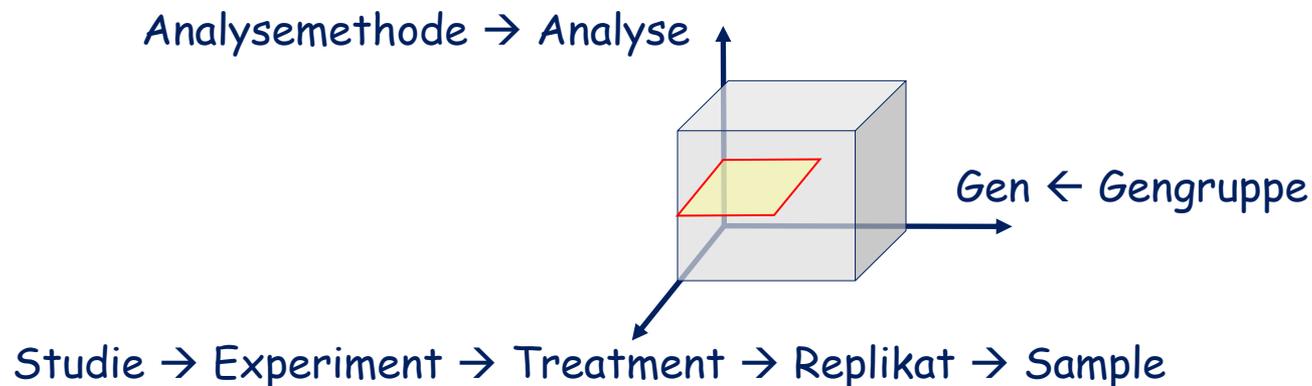


- Globales Schema mit zentraler Datenhaltung
- Separate Extraktion, Transformation und Laden der Daten
- Formen
 - Data Warehouse mit mögl. zusätzlicher Data-Mart-Schicht



Multidimensionales Datenmanagement

- Dimensionen vs. Fakten
- Skalierbarkeit und Erweiterbarkeit
 - Hinzufügen neuer Chip-Typen, Gene, Analysemethoden und assoziierter Fakten ohne Schemaänderungen
 - Hinzufügen neuer Dimensionen und Fakten
- Multidimensionale Analyse
 - Einfache Selektion, Aggregation und Vergleich von Werten
- Basis für anspruchsvolle Analysemethoden
 - Fokussierte Selektion und Erstellung von Matrizen



Beispiel: GeWare

Source systems

Experimental data

- Raw chip intensities
- Expression matrix

Experiment annotations

- experiment, sample, ...
- MIAME

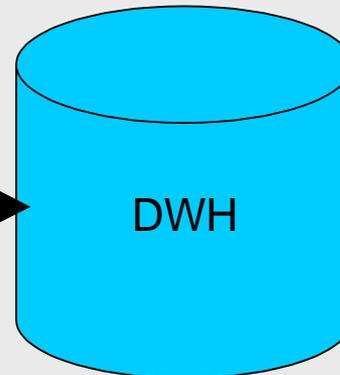
External annotations

- Netaffx data
- Gene ontology (GO)
- LocusLink

Data warehouse

Core data warehouse

- multidimensional data model (star schema)



Transparent integration

- Use of API's
- Insightful ArrayAnalyzer
- OLAP Tools

Tight integration

- Special UDF's
- DB procedures

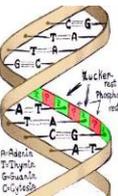
Analysis

Loose integration

- Export
- Download

uniform web-based interface

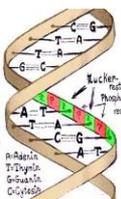
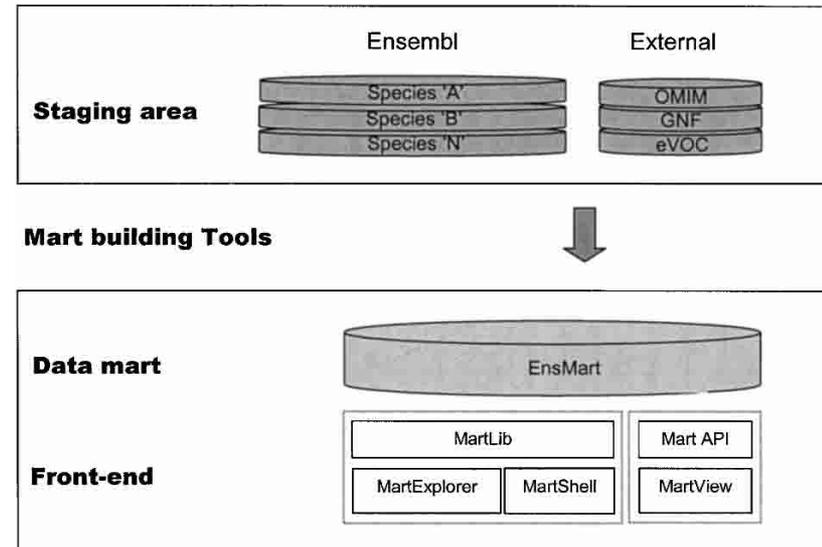
Quelle: Do, H.H., Kirsten, T., Rahm, E.: Comparative Evaluation of Microarray-based Gene Expression Databases. Proc. 10. Fachtagung Datenbanksysteme für Business, Technologie und Web (BTW 2003), Leipzig, Feb. 2003



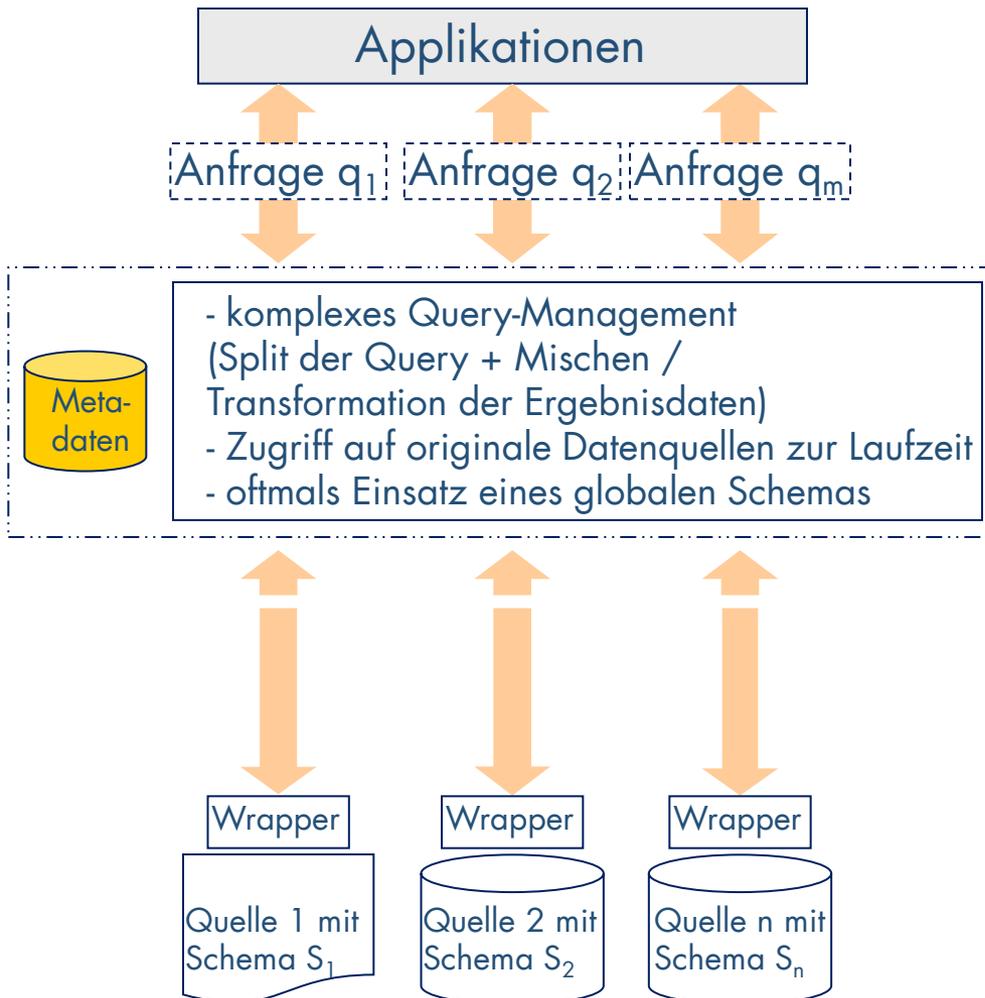
Beispiel: Ensembl BioMarts

- Data-Warehouse-basierte Datenintegration
- Data Marts auf Basis von Ensembl
- Gezielte Suche und Wiedergabe von
 - Ensembl-eigenen biol. Objekten: Gene, Transkripte und Polypeptide
 - Assoziierten Annotationen
 - Referenzierte biol. Objekte
- Multidimensionales Schema
 - Ensembl-eigene biol. Objekte als "Fakten"
 - Instanz-Mappings zu referenzierten Objekten als beschreibende Dimensionen
- Spezies-spezifische Data Marts (verknüpft über Homologie-Mappings)
- <http://www.ensembl.org/biomart>

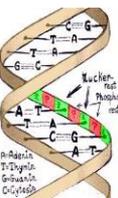
EnsMarts Architektur



Virtuelle Integration

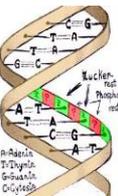
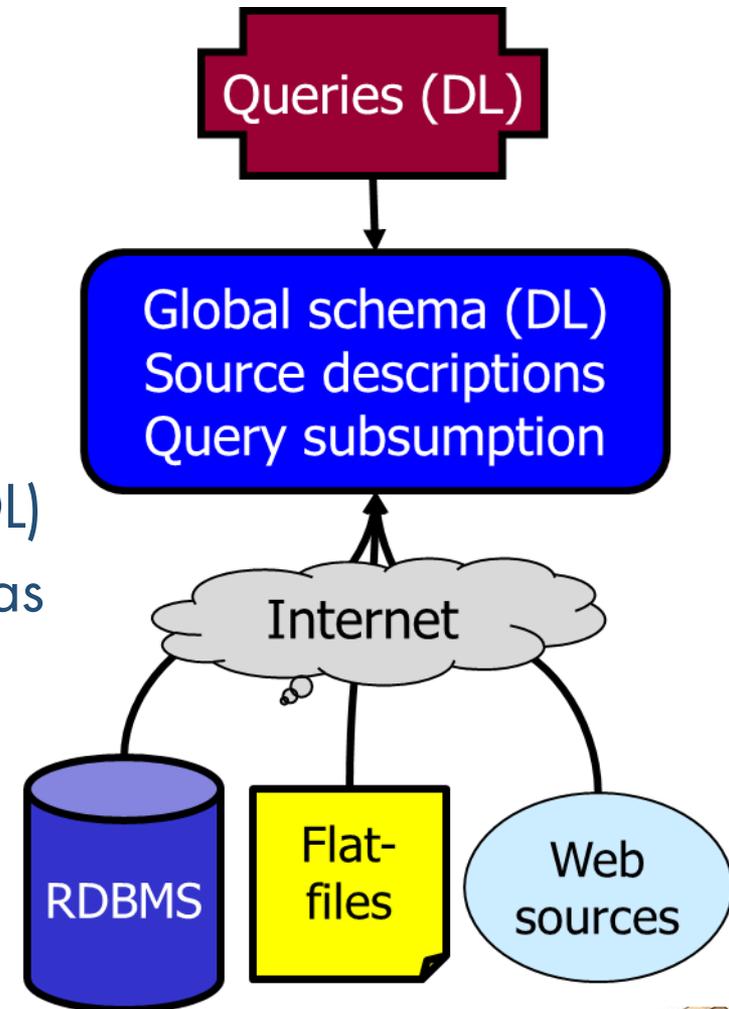


- Globales Schema mit Mappings zu den Quellschemata (Metadaten)
- Transparenter Zugriff auf originale Datenquellen
- Wrapper = quellspezifische API
- Formen
 - förderierte DBMS
 - Mediatoren



TAMBIS

- Architektur
 - Mediator-basiert
 - Fokus: Integration durch Ontologie-basierte Anfrageverarbeitung und -umformulierung
- Features
 - Nutzung von Beschreibungslogik (DL)
 - Semantische Integration der Schemas
 - Keine Dublettenbehandlung, keine Datenfusion



Beispiel: DBGET / LinkDB

- Integration mit verfügbaren Web-Links
- Web-Link = URL einer Datenquelle + ID (accession number) des Objekts
- Einfacher Integrationsansatz
 - Wenig Integrationsaufwand
 - Aber: Analyse eines Objekts zu einer Zeit
- DBGET / LinkDB: Sammlung von Links zwischen verschiedenen Quellen
 - Verwaltung von quellspezifischen Objektreferenzen (ID) u. Instanz-Mappings
 - Keine expliziten Mapping-Typen



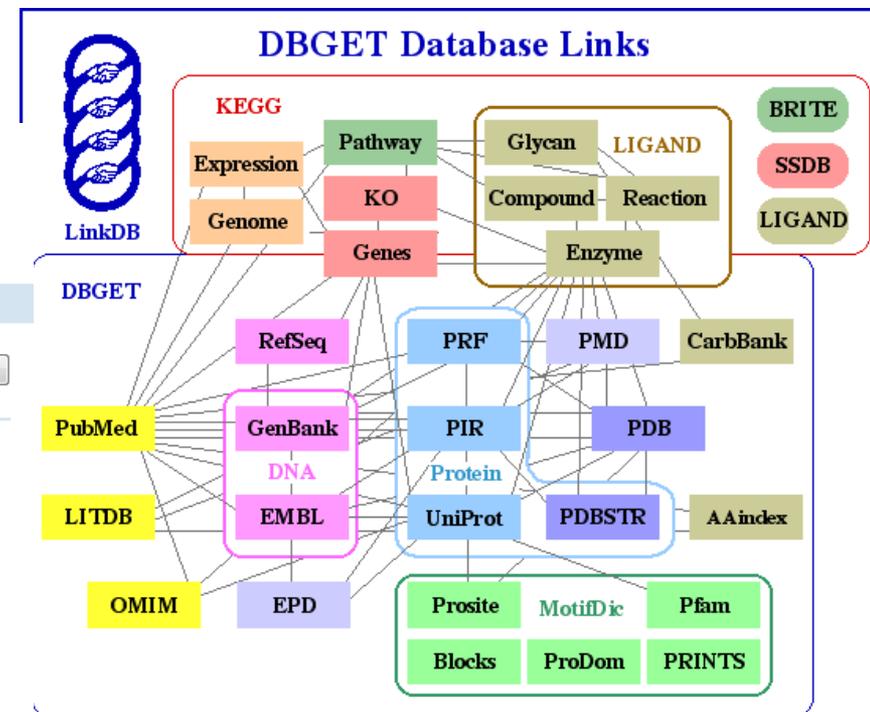
DBGET Search

DBGET LinkDB KEGG2

Search for

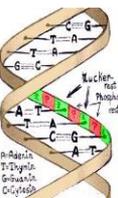
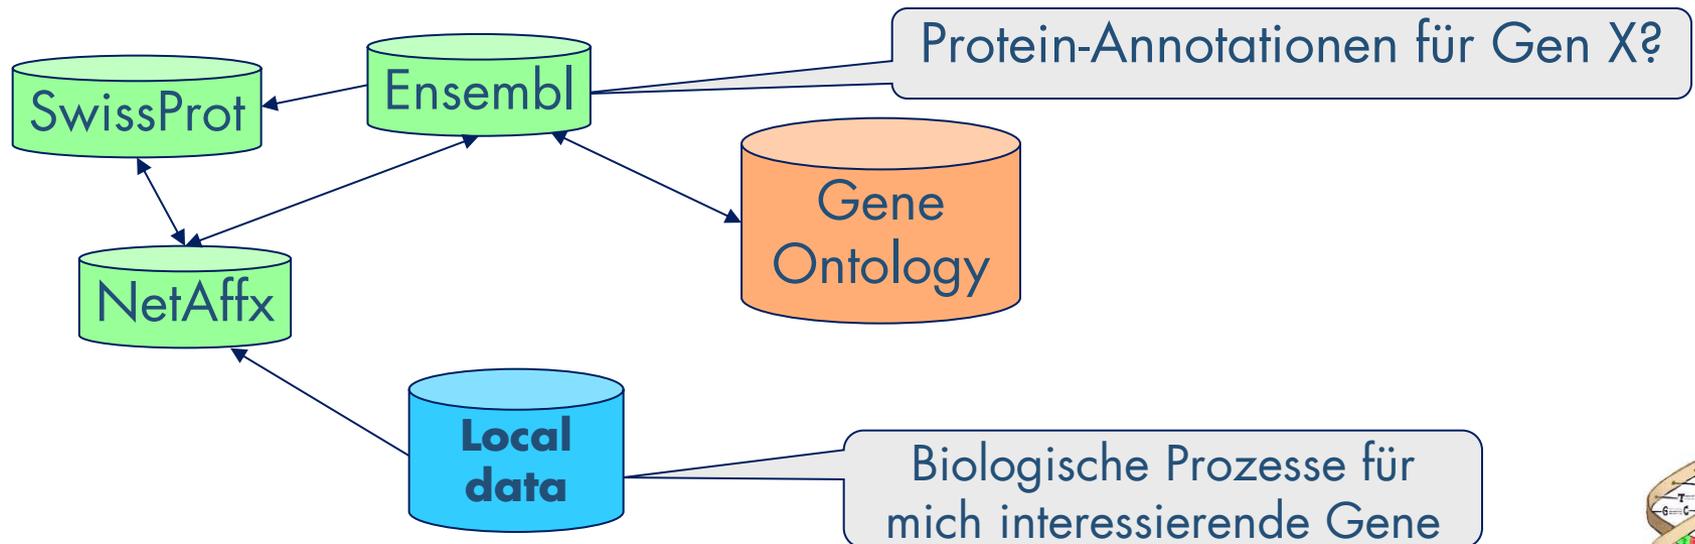
DBGET is an integrated database retrieval system for major biological databases, which are classified into five categories:

Category	Main commands			Remark
	bget	bfind	blink	
1. KEGG databases in DBGET	yes	yes	yes	Mirrored at GenomeNet
2. Other DBGET databases	yes	yes	yes	
3. Searchable databases on the Web	no	yes	yes	Used as Web resources
4. Link-only databases on the Web	no	no	yes	
5. PubMed database	yes	no	yes	



P2P-like Integration

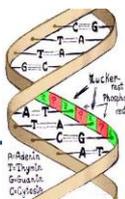
- Virtuell, kein globales Schema
- Bidirektionale Instanz-Mappings zwischen autonomen Datenquellen
 - Wiederverwendung dieser Mappings (Menge von Korrespondenzen zwischen Objekten)
- Anfragen an eine Datenquellen u. deren Propagierung an relevante Peers
- Einfachere Hinzufügung neuer Datenquellen
- Unterstützung lokaler Datenquellen



Beispiel: BioFuice

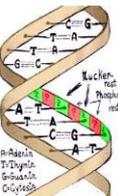
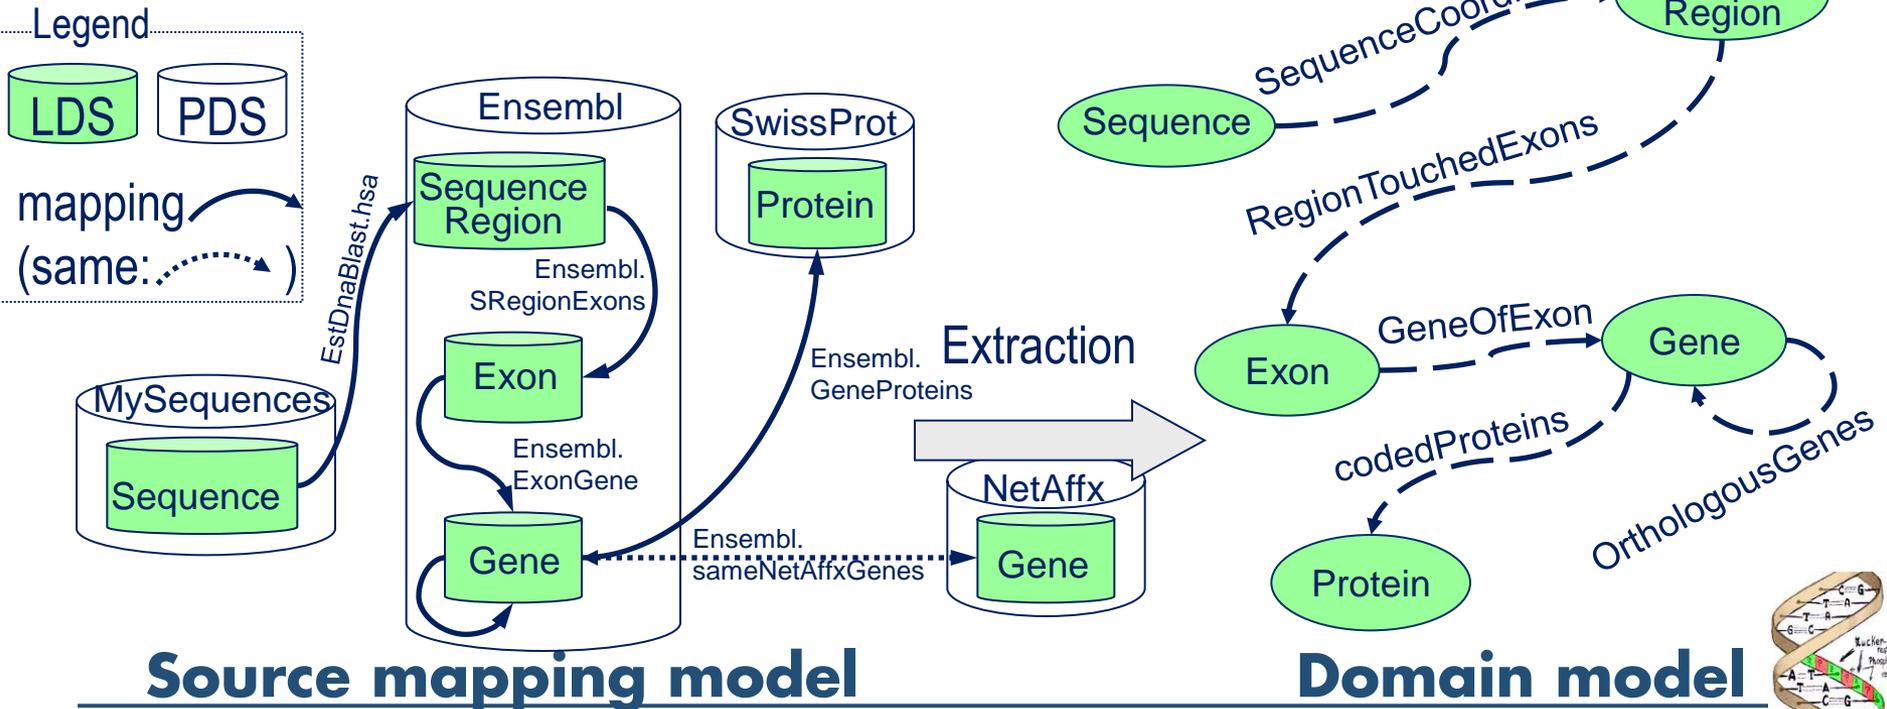
- **B**ioinformatics information **f**usion **u**tilizing **i**nstance **c**orrespondences and **p**eer mappings
- Mediator
 - Zur Steuerung der Mapping- und Operatorausführung
 - Nutzung eines anwendungsspezifischen **semantischen** Domänenmodells
- **High-level Operatoren** (mengenorientiert), z.B.
 - Single source: `queryInstances`, `searchInstances`, ...
 - Navigation: `traverse`, `map`, `compose`, ...
 - Navigation + Aggregation: `aggregate`, `aggregateTraverse`, ...
 - Universell: `diff`, `union`, `intersect`, ...

*Kirsten, T; Rahm, E: *BioFuice: Mapping-based data integration in bioinformatics*.
Proc. 3rd Intl. Workshop DILS, July 2006



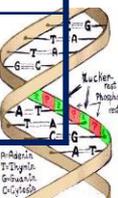
Metadatenmodelle

- Verwendung durch Mediator zur Mapping- und Operatorausführung
- **Domänenmodell** stellt relevante Objekttypen und Beziehungen (=Mappingtypen) zwischen ihnen bereit
- Physische Datenquelle (PDS): Öffentliche, private und lokale Daten (Genliste, ...), Ontologien ...
- Logische Datenquelle (LDS): Bezieht sich auf einen Objekttyp und eine physische Datenquelle z.B. Gene@Ensembl



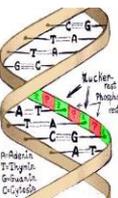
Vergleich physische vs. virtuelle Integration

	Physische I. (Warehouse)	Virtuelle Integration	
		Mediatoren	Peer Data Mgmt
Schemaintegration	A priori	A priori	Nicht zwingend
Instanzdatenintegration	A priori	Zur Laufzeit der Anfrage	Zur Laufzeit der Anfrage
Unterstützung der Datenqualität	+	o	o/-
Analyse großer Datenmengen	+	-	-
Resourcen- anforderungen (HW)	-	o	o
Datenaktualität	o	+	+
Autonomie der Datenquellen	o	+	+
Skalierbarkeit (#Datenquellen)	-	-	o



Anwendung: Integration klinischer Daten

- Studienmanagementsystem zur einheitlichen Erfassung der klinischen Daten (Metadaten + Instanzdaten)
- Anforderungen
 - **Datenintegration:** Patient-bezogene Daten + Chipbasierte genetische Daten
 - **Privacy** Aspekte:
Keine „eine Person identifizierende Daten“
 - Nutzung **existierender** Software für Datenmanagement und Analyse



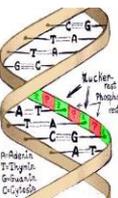
Beispiel: LIFE-Studie*



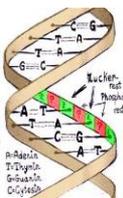
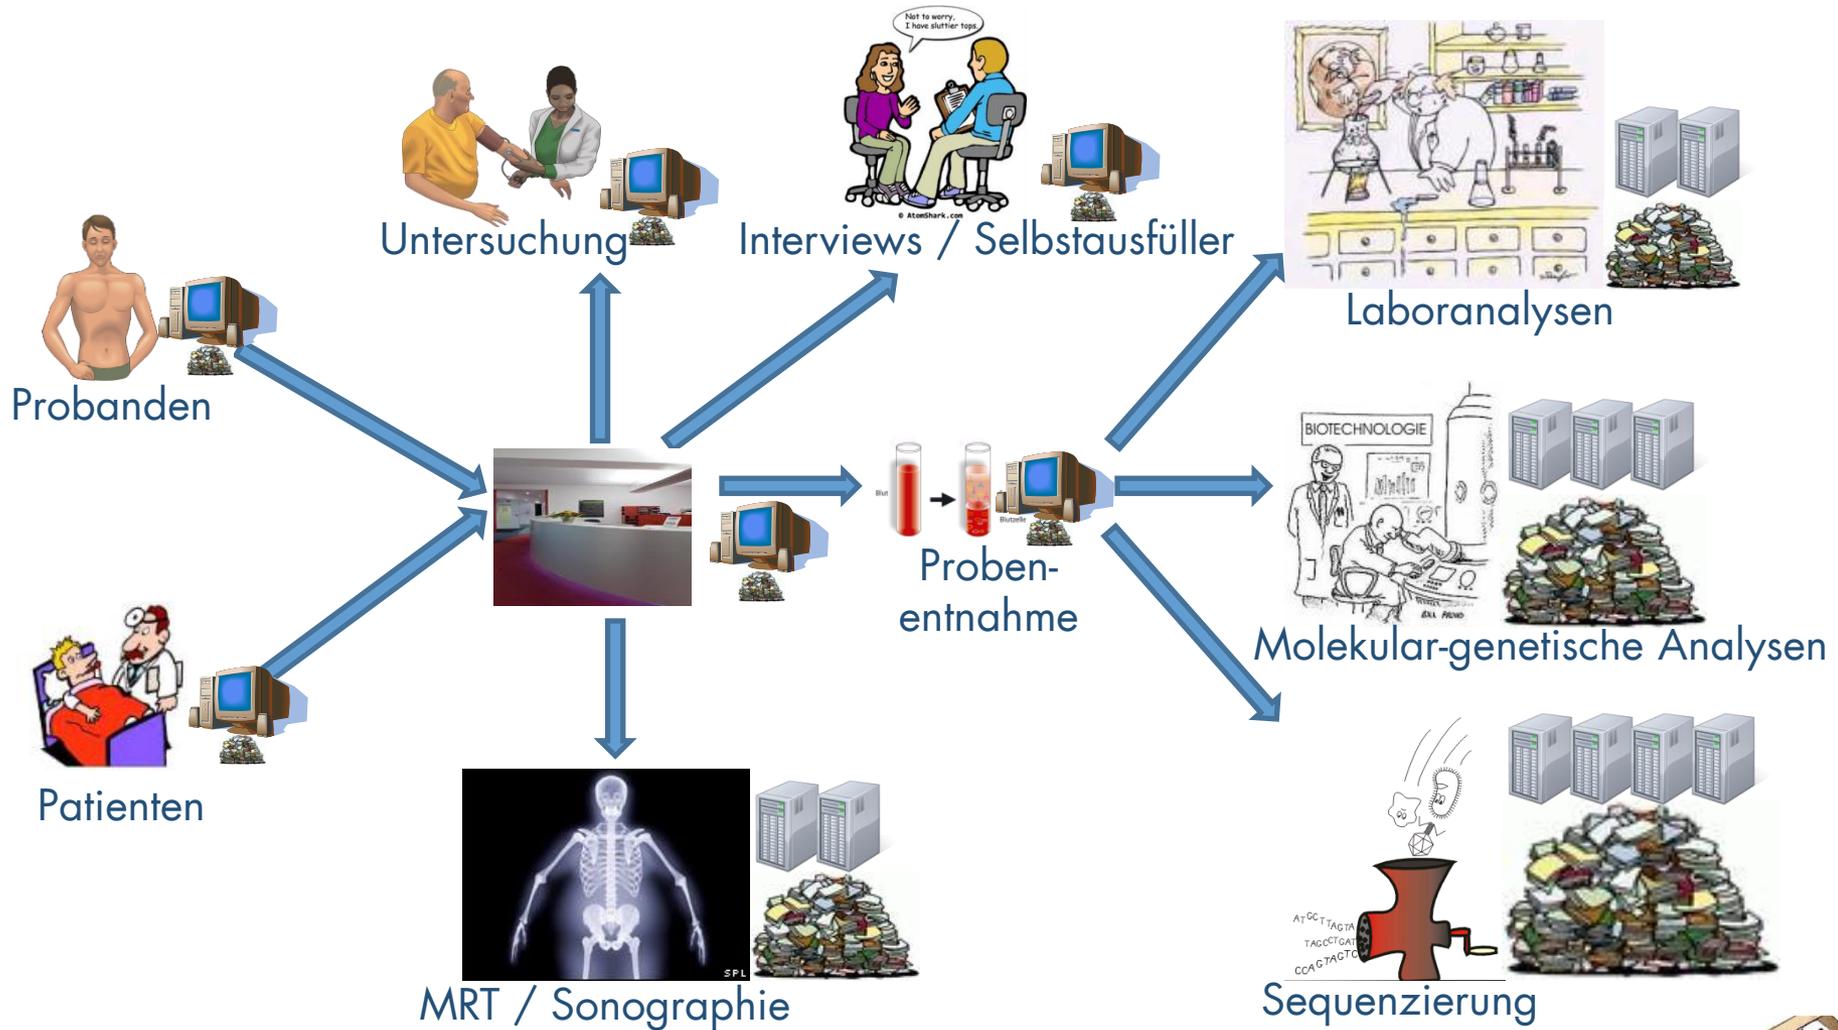
Leipziger Forschungszentrum
für Zivilisationserkrankungen

- Leipziger Forschungszentrum für Zivilisationserkrankungen
- Sächsische Exzellenzinitiative
- Ziel: Evaluierung klinischer und genetischer Faktoren für ausgewählte Zivilisationserkrankungen
 - Einbeziehung von Lebensstil, soziales & Wohnumfeld
 - Rekrutierung aus der Leipziger Bevölkerung
- > **22.000 Teilnehmer (Stand 11/2014)**
 - Erwachsene
 - Bevölkerungsquerschnitt: **10.000**
 - Herzbezogene Erkrankungen: **8.000**
 - Kinder
 - Bevölkerungsquerschnitt: **3.000**
inkl. Adipositas, Neugeborene
 - Depressive Erkrankungen: **1.000**

* Folien zu LIFE: von Dr. Toralf Kirsten, Leipzig Research Centre for Civilization Diseases (LIFE)

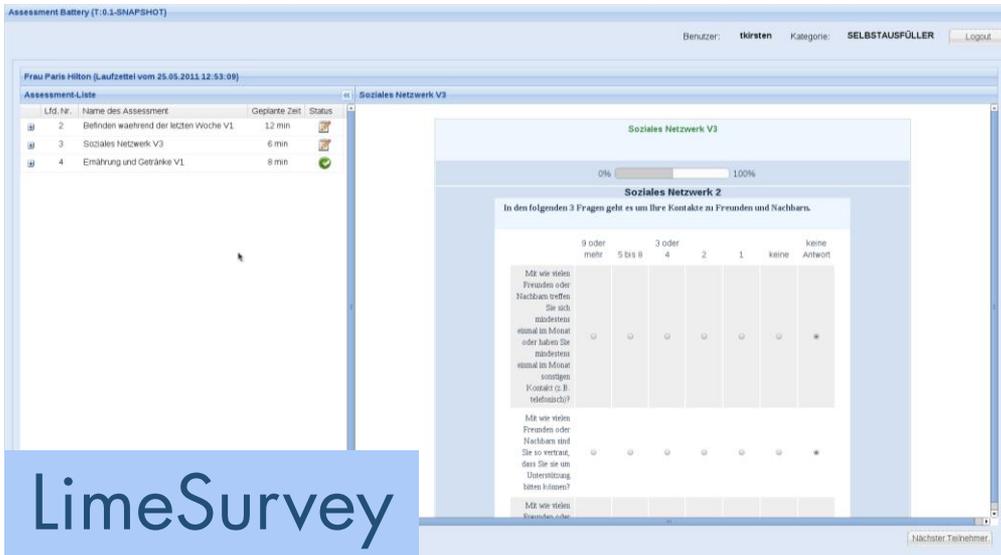


Komplexe Workflows in LIFE



Heterogenität: Strukturierte Daten

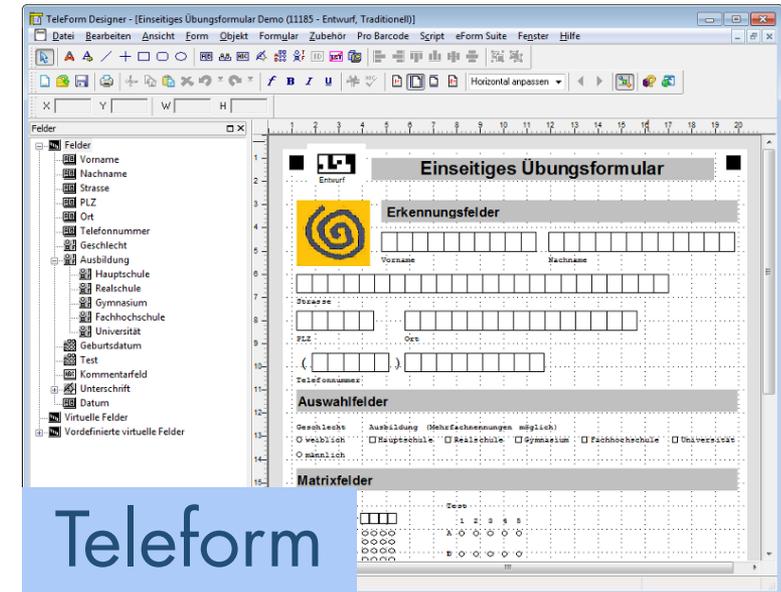
- Interviews, Fragebögen, Untersuchungen → RDBMS
- Ausgewählte Untersuchungen → Desktop DBS, Excel
- Instrumente in unterschiedlichen Versionen und Varianten
- Datenerfassung: LimeSurvey (875 Versionen) & Teleform (176 Versionen) mit durchschnittlich ca. 60 Items



The screenshot shows the LimeSurvey interface. On the left, there is a table titled 'Assessment Liste' with columns for 'Lfd. Nr.', 'Name des Assessment', 'Geplante Zeit', and 'Status'. The main area displays a questionnaire titled 'Soziales Netzwerk V3' with a progress bar at 0%. The questionnaire text asks about social contacts and includes a table for rating responses.

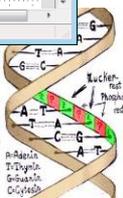
	9 oder mehr	5 bis 8	3 oder 4	2	1	keine Antwort	keine Antwort
Mit wie vielen Freunden oder Nachbarn treffen Sie sich mindestens einmal im Monat oder haben Sie mindestens einmal im Monat Kontakt (z. B. telefonisch)?	<input type="radio"/>						
Mit wie vielen Freunden oder Nachbarn sind Sie so vertraut, dass Sie sie um Unterstützung bitten können?	<input type="radio"/>						
Mit wie vielen Freunden oder...	<input type="radio"/>						

LimeSurvey



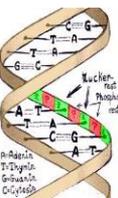
The screenshot shows the Teleform Designer interface. The title bar reads 'Teleform Designer - [Einseitiges Übungsformular Demo (1185 - Entwurf, Traditionell)]'. The main area displays a form design tool with various fields and a 'Felder' (Fields) list on the left. The form includes sections for 'Erkennungsfelder' (Identification fields), 'Auswahlfelder' (Selection fields), and 'Matrixfelder' (Matrix fields).

Teleform



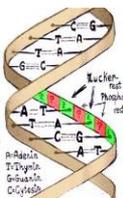
Heterogenität: Strukturierte Daten II

- „Ausnahme“ Labordaten
 - Herkunft: Analyse von Proben (Blut, Speichel, Haar, Urin, ...)
 - Nutzung des HL7-Formats (Health Level 7 Standard) zur Datenübertragung
 - Keine explizite Typisierung: Datentyp String
 - Wechselnde Parameter und -profile (derzeit 88 Parameterprofile)



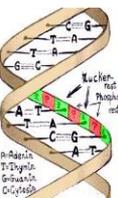
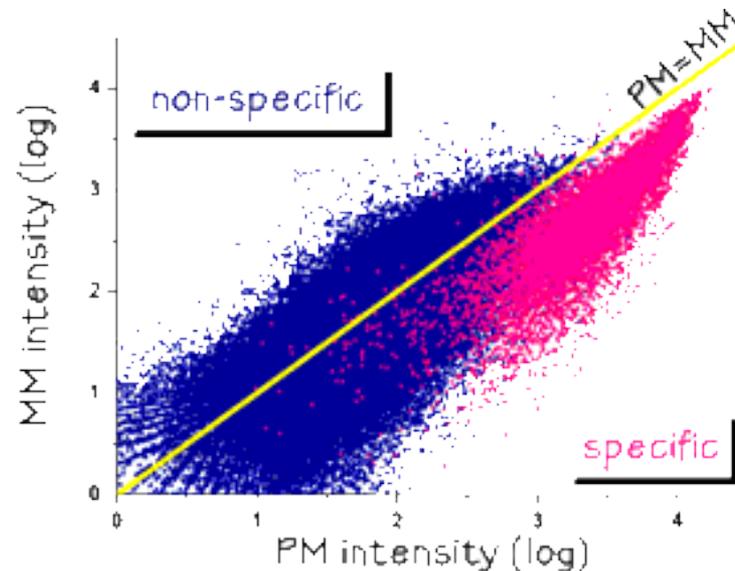
Heterogenität: Unstrukturierte Daten

- Vornehmlich Gerätedaten von apparativen Untersuchungen
- Kaum Direktzugriff auf Daten in med. Geräten möglich
 - Manueller Export pro Untersuchung (teilweise als batch)
 - Evtl. Datentransport per USB-Stick
 - Notwendiges Preprocessing (Originaldaten → Rohdaten)
 - Formate: proprietär, Excel



Heterogenität: Unstrukturierte Daten II

- Genetische Daten
 - Genetische Daten: Messergebnisse aus wet-lab Experimenten zur Bestimmung der Genexpression, Mutation (SNP) und Sequenz (Next Generation Sequencing)
 - Hohes Datenvolumen an Rohdaten
 - Hoher und schnell wachsender Umfang an Analysedaten



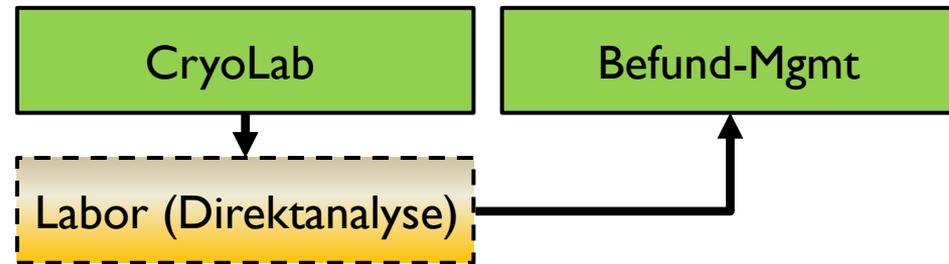
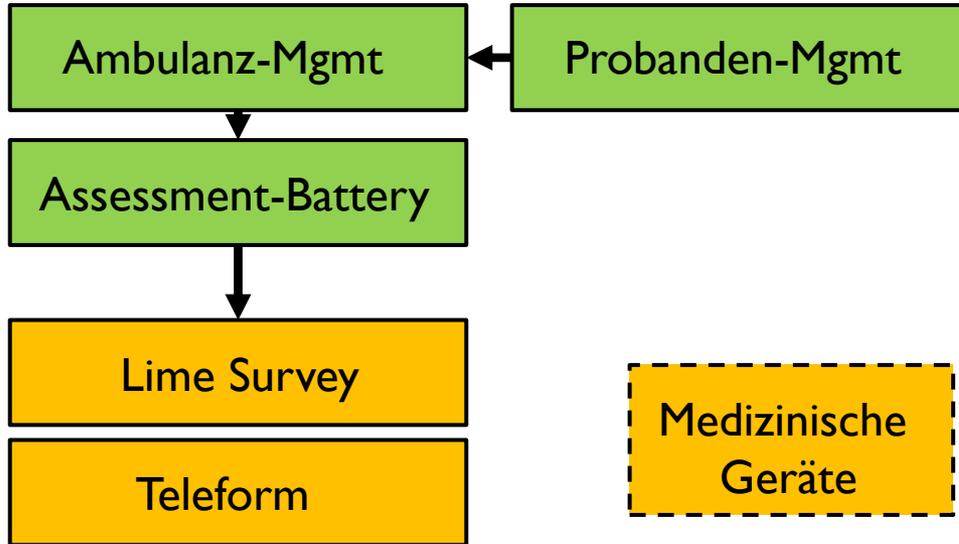
Heterogenität: Unstrukturierte Daten III

- Multimediale Daten
 - Formen: Bilddaten, Filme, Akkustikaufzeichnungen
 - Verwaltung an verschiedenen Standorten mit unterschiedlichen Systemen: PACS, Dateisystem, ...
- Preprocessing
 - Manuelle Befundung, z.B. von MRT-Bildern
 - Abhören von Interviewmitschnitten
 - ...



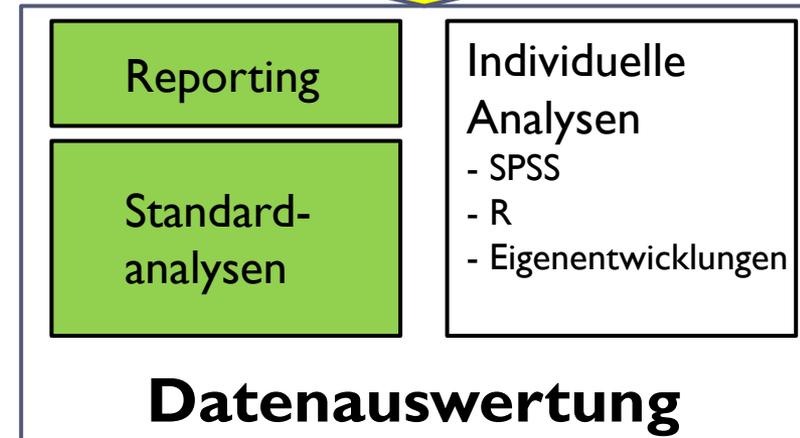
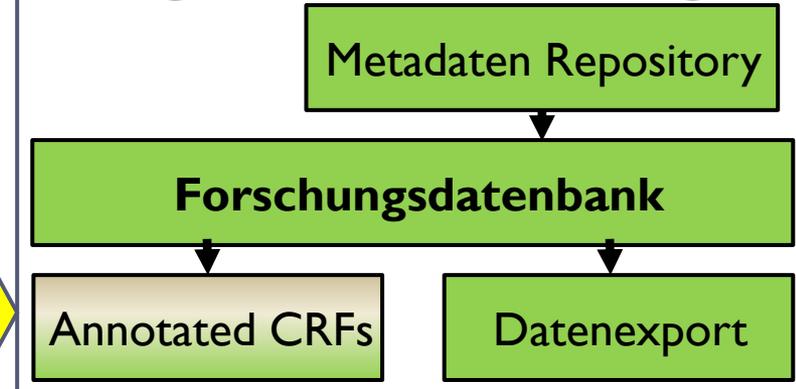
IT-Systemlandschaft im Überblick

Ambulanz-Management



Proben- & Befund-Management

Integratives Daten-Mgmt

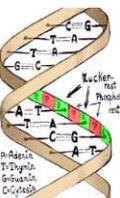
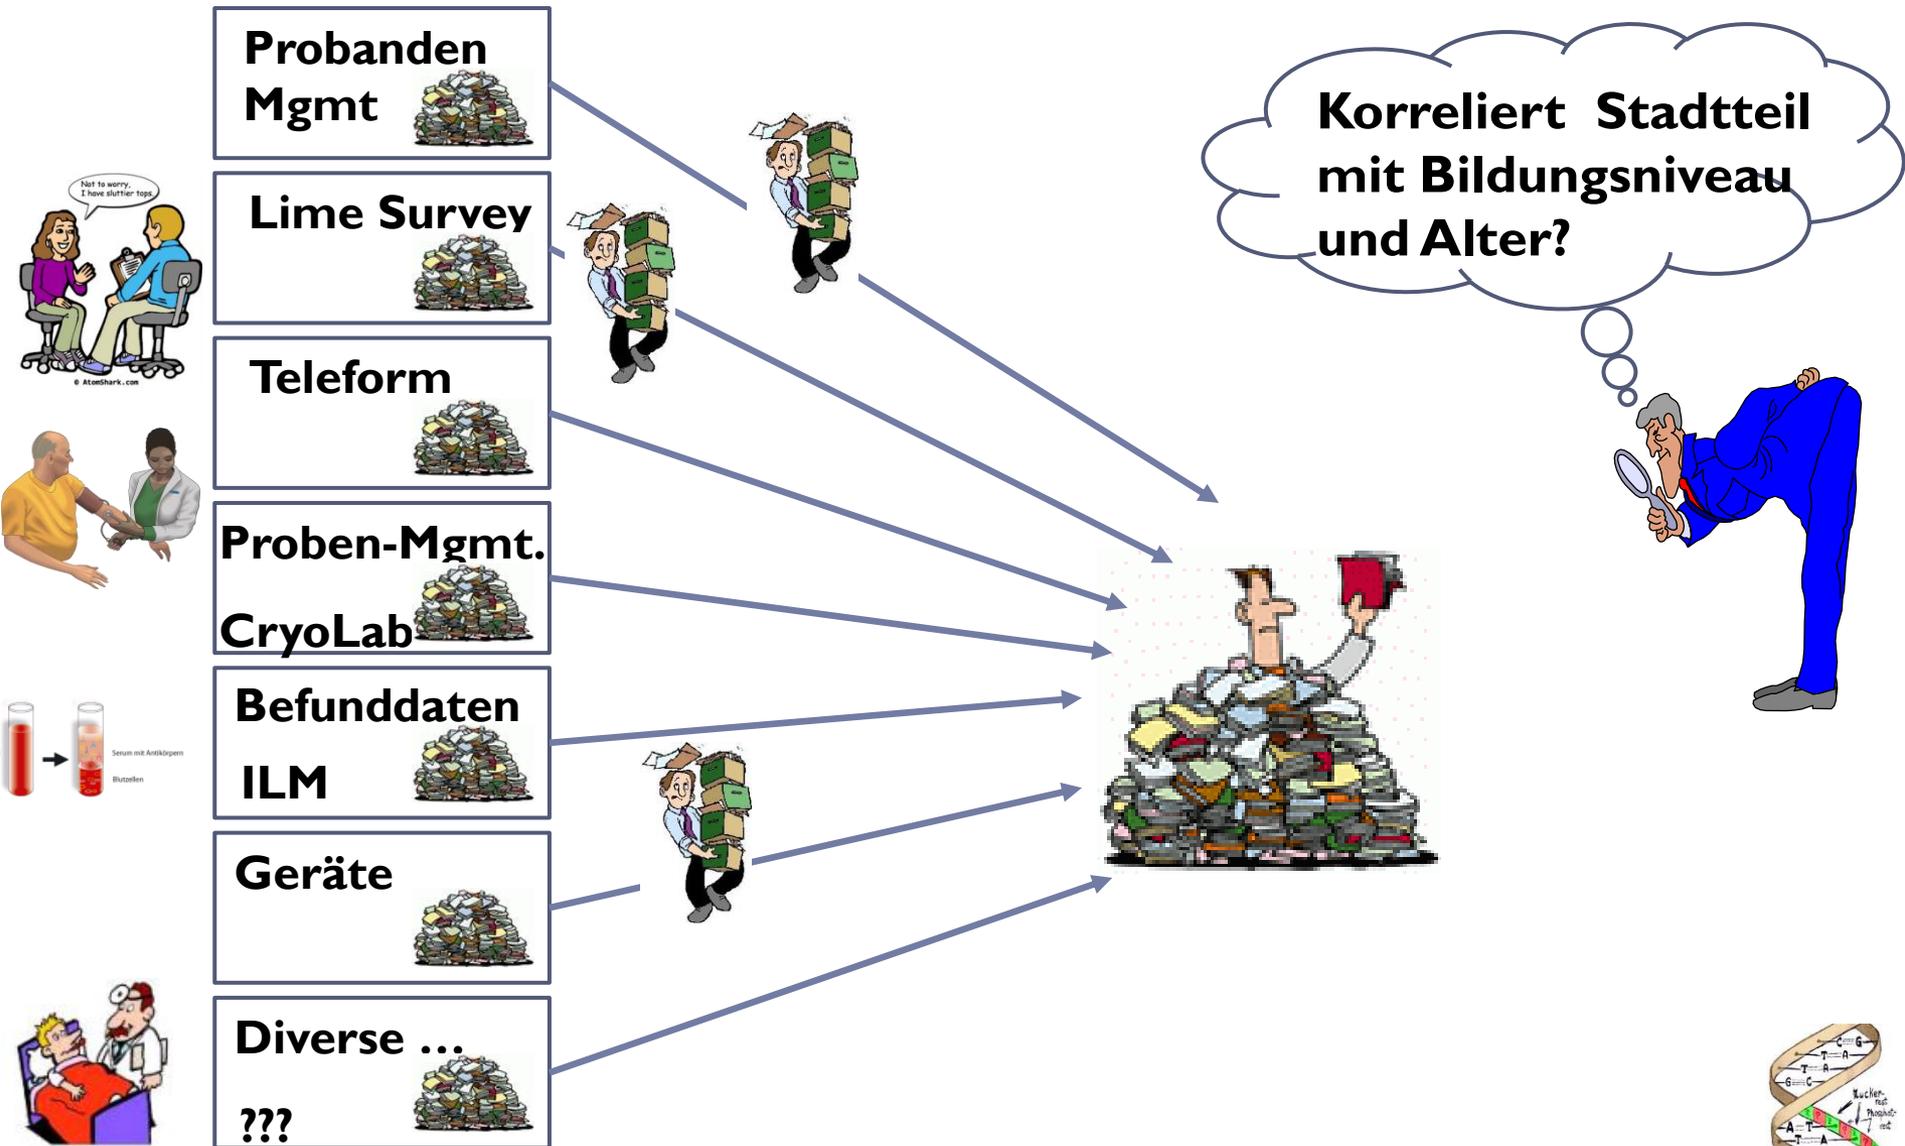


Legende

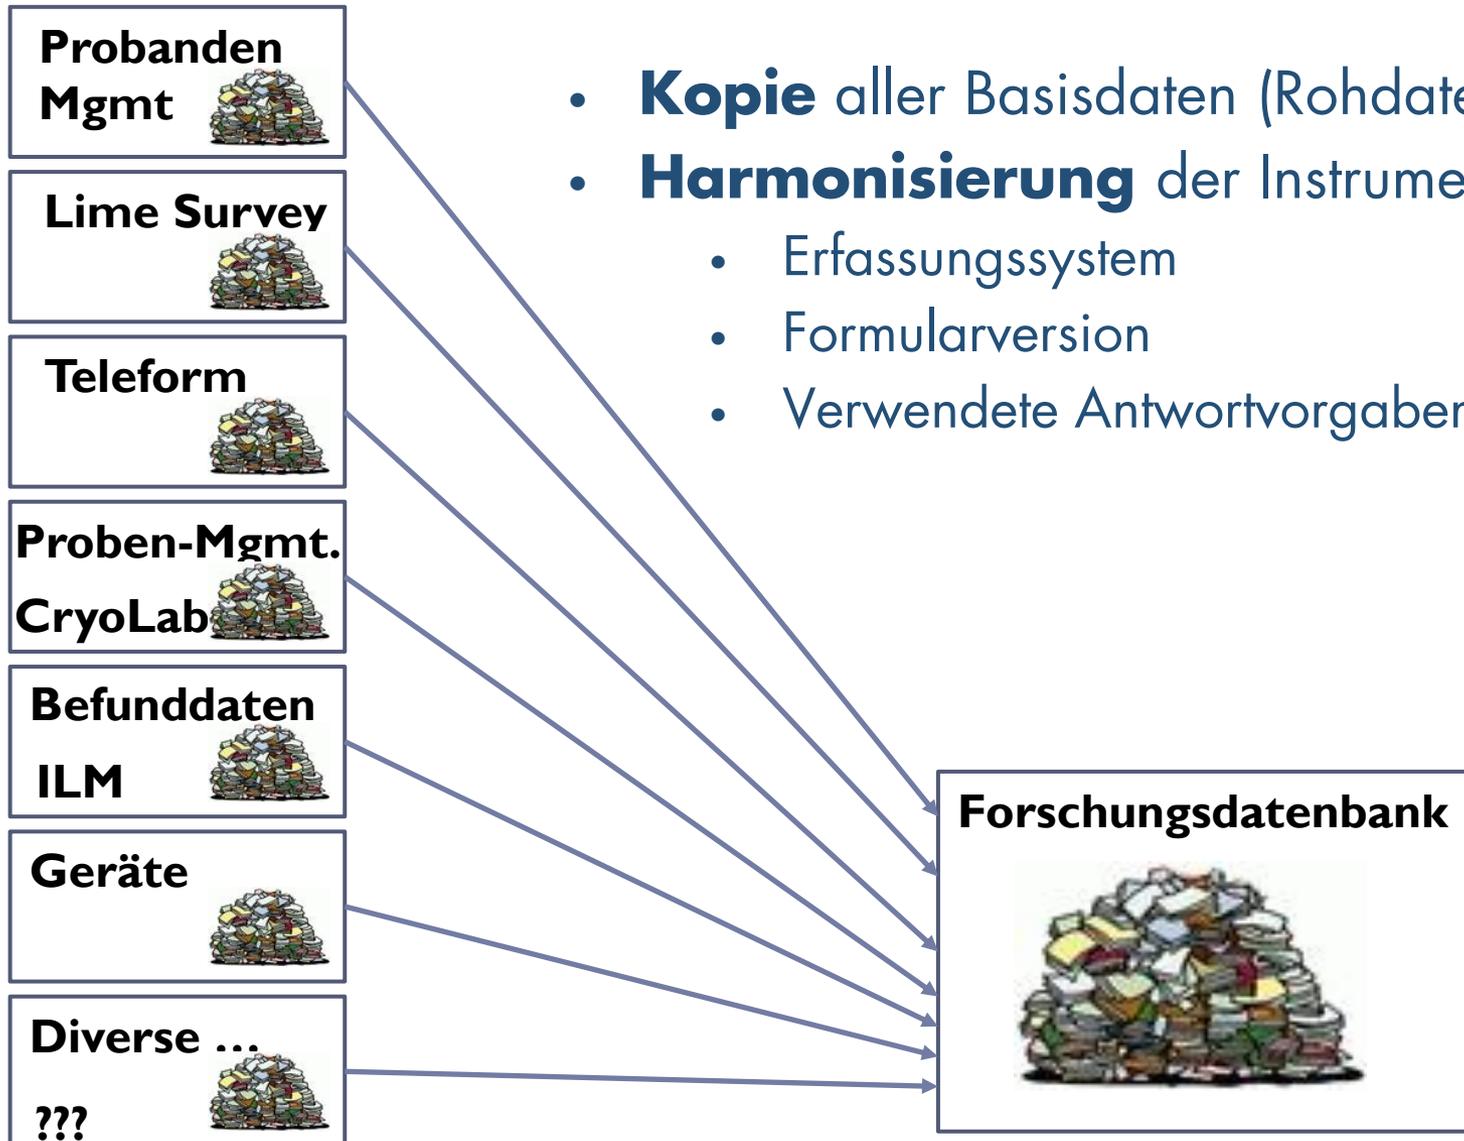
Standard-Software

Eigenentwicklung

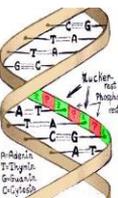
Integratives Forschungsdaten-Management



Integratives Forschungsdaten-Management

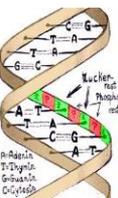


- **Kopie** aller Basisdaten (Rohdaten, ...)
- **Harmonisierung** der Instrumente bzgl.
 - Erfassungssystem
 - Formularversion
 - Verwendete Antwortvorgaben



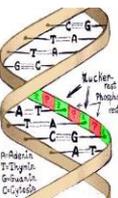
Datenanalyse

- Anwendung unterschiedlicher Algorithmen, projektspezifisch je nach Fragestellung
- Voraussetzung: Datenbereitstellung
 - DBS-Direktzugriff
 - Reporter-System (vordefinierte Reports)
 - Datenexporte
- Unterschiedliche Analysesoftware: R, SPSS, SAS, Excel, ...
- Geplant: Rückführung der Ergebnisse in die Forschungsdatenbank



Zusammenfassung Daten-Management LIFE

- Komplexe Prozesse in Ambulanzen an Kliniken
- Hohe Heterogenität der Daten
- Sehr hoher Grad an Eigenentwicklungen
- Integratives Forschungsdaten-Management
 - Ziel: Integration relevanter Daten aus Erfassungssystemen
 - Basis: Metadaten und Beziehungen zwischen ihnen
- Relationale Datenbanktechnologie für Management der Fragebogen- und Befunddaten ausreichend



Zusammenfassung

- Viele verschiedene Datenquellen mit unterschiedlichem Fokus
- Hauptsächlich Heterogenität als Integrationsbarriere
- Virtuelle vs. physische Integration
 - Virtuell: Mediator-Systeme, P2P-like Integration
 - Physisch: Data Warehouses
- Schemaintegration: Top-down vs. Bottom-Up
- Anwendungen
 - Integration im Kontext molekular-genetischer Experimente
 - Integration von klinischen / epidemiologischen Studiendaten
- Mehr Details: VL Datenintegration

