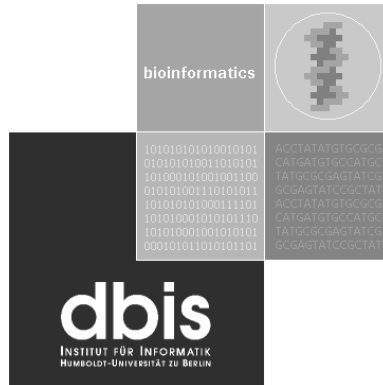
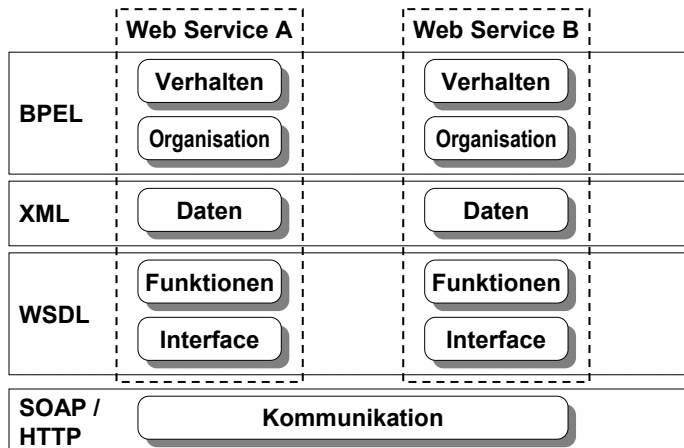


Datenintegration in der Bioinformatik

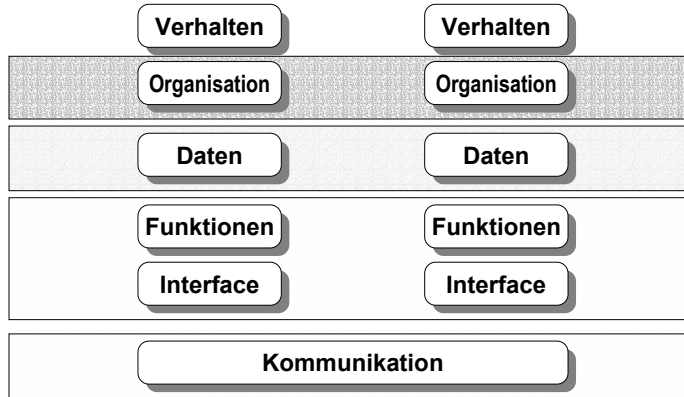


Eine Anleihe bei Prof. Reisig

(Vorangegangene RingVL)



Gegenstand heute



Ursprüngliche Vortragsankündigung:

R. Eckstein, S. Heymann

XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich

(Schwerpunkt "Große Datenräume in Web-basierten Umgebungen")

XML hat auch in der Bioinformatik Einzug gehalten - zum Datenaustausch, aber auch zur Repräsentation der komplexen Informationen. Im ersten Teil werden Aspekte von XML sowie weitergehende Entwicklungen vorgestellt, die für den Life Science Bereich von besonderem Interesse sind. Dazu gehören die konzeptionelle Modellierung von Dokumentschemata sowie für semantische Informationen über die Biodaten. Im zweiten Teil wird ein Überblick für XML-Anwendungen im Life Science Bereich gegeben und ein typisches Anwendungsbeispiel aus dem Forschungsgebiet Biodiversität & Ökologie erläutert: Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-basierten botanischen Schulen zu genbasierter Kladistik. Es wird demonstriert, wie die Konflikte behandelt und die Daten in ein navigierbares Graphenformat transponiert werden. Dabei kommt der GeneViator zum Einsatz.



ACTGATGCGATCGCTAAATATCTACCG

Herkömmliche Dokumentkonventionen

Die Vortragsankündigung hätte man auch *formularbasiert* schreiben können:

Referenten: R. Eckstein, S. Heymann
Titel: XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich
Untertitel: (Schwerpunkt "Große Datenräume in Web-basierten Umgebungen")
Zusammenfassung: ... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-basierten botanischen Schulen zu genbasierter Kladistik. Es wird ...

//



ACTGATGCGATCGCTAAATATCTACCG

Herkömmliche Dokumentkonventionen

Die Vortragsankündigung hätte man auch *formularbasiert* schreiben können:

Referenten: R. Eckstein, S. Heymann
Titel: XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich
Untertitel: (Schwerpunkt "Große Datenräume in Web-basierten Umgebungen")
Zusammenfassung: ... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-basierten botanischen Schulen zu genbasierter Kladistik. Es wird ...

//

(Karteikartenprinzip)

Gensequenzen: Beispiel SARS

ACTGATGCGATCGCTAAATATCTACCG

```
LOCUS             AY274119       29736 bp  RNA   linear  VRL 14-APR-2003
DEFINITION       SARS coronavirus TOR2, complete genome.
ACCESSION        AY274119
VERSION          AY274119.1 GI:29826276
KEYWORDS
ORGANISM         SARS Coronavirus Tor2
...
BASE COUNT       8475 a   5940 c   6186 g   9135 t
ORIGIN
      1 ctaccocagga aaagccaacc aacctcgatc tcttgtagat ctgttctcta aacgaacttt
     61 aaaatctgtg tagctgtcgc tcggtcgcgc gcttagtgca cctacgcagt ataaacaata
      ...
    29641 agccctaagt tgtaaaatta attttagtag tgctatcccc atgtgatttt aatagcttct
    29701 taggagaatg acaaaaaaaaa aaaaaaaaaa aaaaaa
//
```

Lehrstuhl für Datenbanken und Informationssysteme


Ringvolesung Informatik - Prof. J.C. Freytag, Ph.D.

7

Grösse der Datensammlungen

ACTGATGCGATCGCTAAATATCTACCG

EMBL Database Growth
total record number (millions)



- EMBL July 2002
 - > 150 Gbytes
- Microarray
 - 1 Petabyte p.A.
- Sanger Centre
 - 20 TB an Daten
- Genome Sequenzen wachsen p.A. um das Vierfache

Lehrstuhl für Datenbanken und Informationssysteme

Ringvolesung Informatik - Prof. J.C. Freytag, Ph.D.

8



ACTGATGCGATCGCTAAATATCTACCG

Struktur – Verarbeitung

<vortrag>

<autor> R. Eckstein </autor>

<autor> S. Heymann </autor>

<titel> XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich</titel>

<untertitel> Schwerpunkt "Große Datenräume in Web-basierten Umgebungen,"</untertitel>

<zusammenfassung>

... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-basierten botanischen Schulen zu genbasierter <term ref="http://...">Kladistik</term>. Es wird ...

</zusammenfassung>

</vortrag>



ACTGATGCGATCGCTAAATATCTACCG

Struktur – Verarbeitung

<vortrag>

<autor> R. Eckstein </autor>

<autor> S. Heymann </autor>

<titel> XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich</titel>

<untertitel> Schwerpunkt "Große Datenräume in Web-basierten Umgebungen,"</untertitel>

<zusammenfassung>

... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-basierten botanischen Schulen zu genbasierter <term ref="http://...">Kladistik</term>. Es wird ...

</zusammenfassung>

</vortrag>

Lesbarkeit ↔ Struktur ↔ Verarbeitung

```

<vortrag>
  <autor> R. Eckstein </autor>
  <autor>S. Heymann </autor>
  <titel>XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich</titel>
  <untertitel>Schwerpunkt "Große Datenräume in Web-basierten Umgebungen,,"</untertitel>
  <zusammenfassung>
  ... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-
  basierten botanischen Schulen zu genbasierter <term ref= http://www.visualgenomics.ca/gordonp/xml/>
  Kladistik</term>. Es wird ...
  </zusammenfassung>
</vortrag>
  
```



EXTENSIBLE MARKUP LANGUAGE

```

<vortrag>
  <autor> R. Eckstein </autor>
  <autor>S. Heymann </autor>
  <titel>XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich</titel>
  <untertitel>Schwerpunkt "Große Datenräume in Web-basierten Umgebungen,,"</untertitel>
  <zusammenfassung>
  ... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-
  basierten botanischen Schulen zu genbasierter <term ref= http://www.visualgenomics.ca/gordonp/xml/>
  Kladistik</term>. Es wird ...
  </zusammenfassung>
</vortrag>
  
```

Beschreibungssprachen im Bio-Bereich:
<http://www.visualgenomics.ca/gordonp/xml/>



EXTENSIBLE MARKUP LANGUAGE

<vortrag>

<autor> R. Eckstein </autor>

<autor>S. Heymann </autor>

<titel>XML , (Modellierung) & Datenintegration - Fortschritt im Life Science Bereich</titel>

<untertitel>Schwerpunkt "Große Datenräume in Web-basierten Umgebungen,,"</untertitel>

<zusammenfassung>

... Die Erfassung und Darstellung von Taxonomie-Daten, den Übergang von klassischen Morphologie-basierten botanischen Schulen zu genbasierter <term ref= <http://www.visualgenomics.ca/gordonp/xml/>> Kladistik</term>. Es wird ...

</zusammenfassung>

</vortrag>

**Beschreibungssprachen im Bio-Bereich:
<http://www.visualgenomics.ca/gordonp/xml/>**



Handbücher



Dokumenttypdefinitionen



Kompendium aller Erkenntnisse

DTD:

<!ENTITY % local_aa_type.value "">

<!ENTITY % aa_type "type (A|B|C|D|E|F|G|H|I|K|L|M

|N|P|Q|R|S|T|V|W|X|Y|Z

%local_aa_type.value;)

#REQUIRED">

DTD's: Kompendium neuer Erkenntnisse

<!ENTITY % local.aa_type.value ""> (bis 2002)

```
<!ENTITY % aa_type "type (A|B|C|D|E|F|G|H|I|K|L|M
|N|P|Q|R|S|T|V|W|X|Y|Z
%local.aa_type.value;)
#REQUIRED">
```

<!ENTITY % local.aa_type.value ""> (seit Feb. 2003)


```
<!ENTITY % aa_type "type (A|B|C|D|E|F|G|H|I|K|L|M
|N|P|Q|R|S|T|V|U|W|X|Y|Z
%local.aa_type.value;)
#REQUIRED">
```

Beispiele aus der Abstammungslehre



Beispiele aus der Abstammungslehre

ACTGATGCGATCGCTAAATCTACG



Homo sapiens:

Other names:

man[common name]

Lineage(full)

cellular organisms; Eukaryota; Fungi/Metazoa group; Metazoa; Eumetazoa; Bilateria; Coelomata; Deuterostomia; Chordata; Craniata; Vertebrata; Gnathostomata; Teleostomi; Euteleostomi; Sarcopterygii; Tetrapoda; Amniota; Mammalia; Theria; Eutheria; Primates; Catarrhini; Hominidae; Homo/Pan/Gorilla group; Homo

Lehrstuhl für Datenbanken und Informationssysteme

<http://www.visualgenomics.ca/gordonp/xml/>

Beispiele aus der Abstammungslehre

ACTGATGCGATCGCTAAATCTACG



?:xml version="1.0" encoding="UTF-8"?>

?:xml stylesheet type="text/xsl" href="HTMLOutput.xsl"?>

:DOCTYPE MultipleClassifications SYSTEM "XMLOutput.dtd">

:MultipleClassifications Order="Alpha">

!-#NEXUS [18-Dec-2001 16:59:36]->

:ranks>

```
<rank RankID="Family"><rankName>Family</rankName><rankValue>10</rankValue></rank>
<rank RankID="Sub-Family"><rankName>Sub-
family</rankName><rankValue>15</rankValue></rank>
<rank RankID="Legion"><rankName>Legion</rankName><rankValue>17</rankValue></rank>
<rank RankID="Tribe"><rankName>Tribe</rankName><rankValue>20</rankValue></rank>
<rank RankID="Sub-Tribe"><rankName>Sub-
tribe</rankName><rankValue>25</rankValue></rank>
<rank RankID="Grex"><rankName>Grex</rankName><rankValue>27</rankValue></rank>
<rank RankID="Genus"><rankName>Genus</rankName><rankValue>30</rankValue></rank>
```

:/ranks>

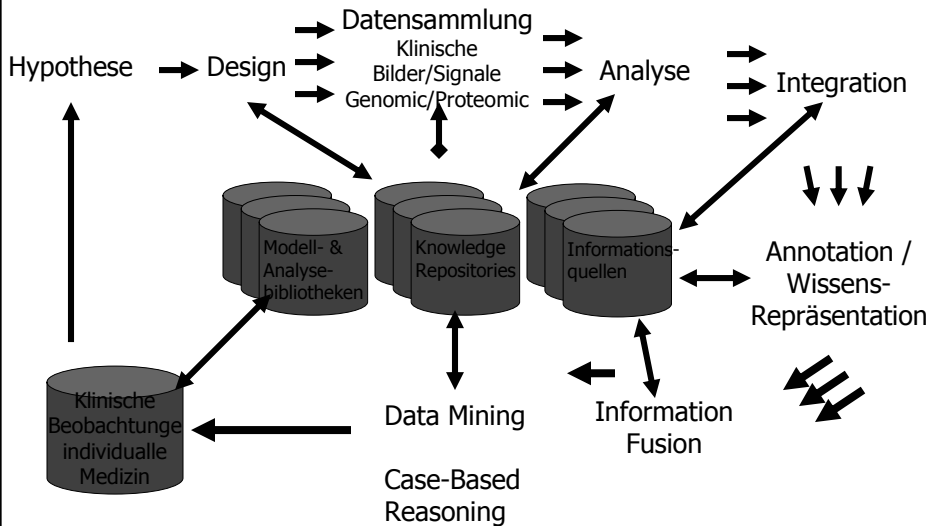
:taxa>

```
<taxon RankIDREF="Family" TaxonID="Apiaceae">Apiaceae</taxon>
<taxon RankIDREF="Sub-Family" TaxonID="TPauciugatae">Pauciugatae</taxon>
```

Lehrstuhl für Datenbanken und Informationssysteme

<http://www.visualgenomics.ca/gordonp/xml/>

Beispiel: Genetik & Medizin



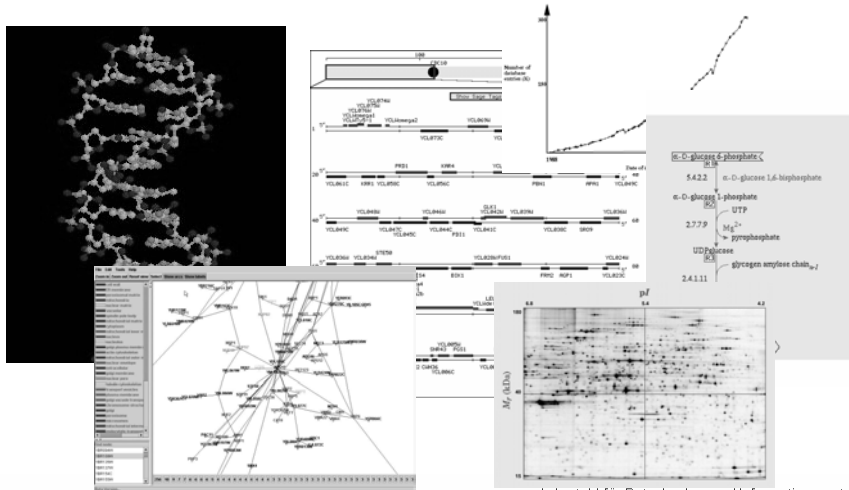
Herausforderungen...

- Formatheterogenität
- Datenheterogenität / Anzahl der Datenquellen
- Umfang der Daten / Grösse der Datensammlungen
- Zugriffsheterogenität

Formatheterogenität

ACTGATGCGATCGCTAAATCTACTAC

- Multimedia: Bilder & Video (e.g. microarrays, 3D, ...)

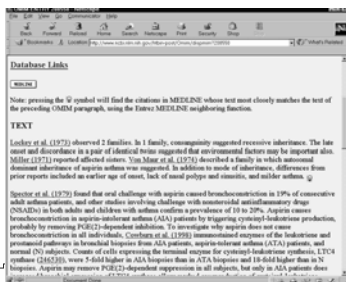


Lehrstuhl für Datenbanken und Informationssysteme
10101010101010100110101010101010

Formatheterogenität (cont.)

ACTGATGCGATCGCTAAATCTACTAC

- Text "Annotationen" & Literatur
 - strukturiert vs. semistrukturiert vs. unstrukturiert
- Unterschiedliche Formate, Strukturen, Schemata, Umfänge, ...
- Web-Schnittstellen, Verteilung als Dateien, Datenbank-Dumps, XML-Dokumente, ...



```

ID TRBG361 standard; RNA; PLN; 1859 BP.
XX
AC X56734; S46826;
XX
SV X56734.1
XX
DT 12-SEP-1991 (Rel. 29, Created)
DT 15-MAR-1999 (Rel. 59, Last updated, Version 9)
XX
DE Trifolium repens mRNA for non-cyanogenic beta-glucosidase
XX
KW beta-glucosidase.
XX
OS Trifolium repens (white clover)
OC Eukaryota; Viridiplantae; Streptophyta; Embryophyta.
OC Spermatophyta; Magnoliophyta; eudicotyledons; core eudicots.
OC eurosoids I; Fabales; Fabaceae; Papilionoideae; Trifolieae.
XX

```

Lehrstuhl für Datenbanken und Informationssysteme
10101010101010100110101010101010

Daten-/Inhaltsheterogenität

ACTGATGCGATCGCTAAATCTACTG

- Genomische, proteomische, transcriptomische, metabolomische, Protein-Protein Interaktionen, regulatorische Bio-Netzwerke, Alinierungen, Krankheiten, Patterns & Motifs, Proteine Strukturen, Proteinklassifikationen und -familien, spezielle Proteine (Enzyme, Rezeptoren), ...



Lehrstuhl für Datenbanken und Informationssysteme

100101010101010100110101010101010

Zugriffsheterogenität

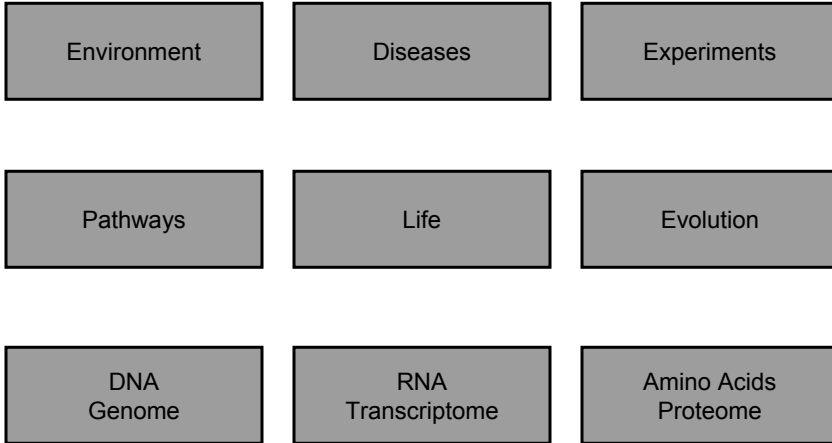
ACTGATGCGATCGCTAAATCTACTG

Lehrstuhl für Datenbanken und Informationssysteme

100101010101010100110101010101010

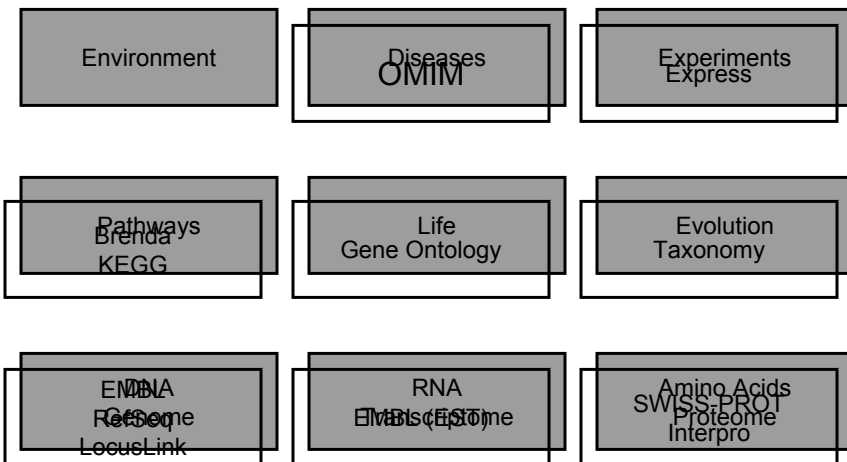
Genomisch relevante Bereiche

ACTGATGCGATCGCTAAATATCTACG




Inhalt von Datenquellen

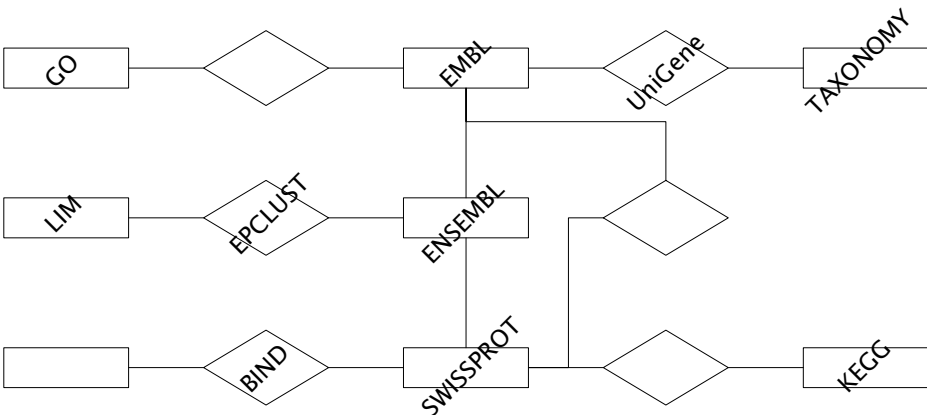
ACTGATGCGATCGCTAAATATCTACG



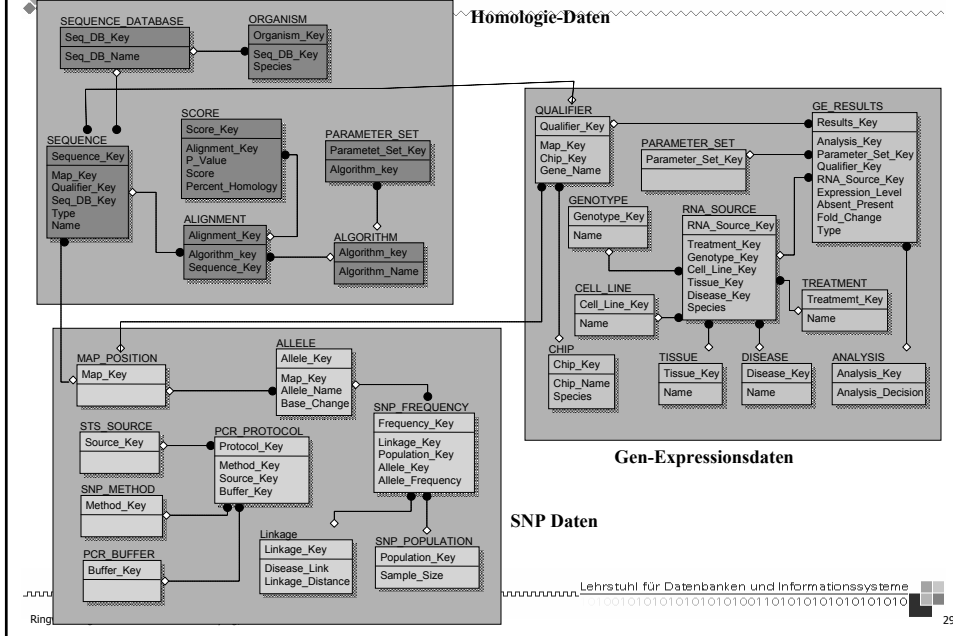
Datenmodellierung



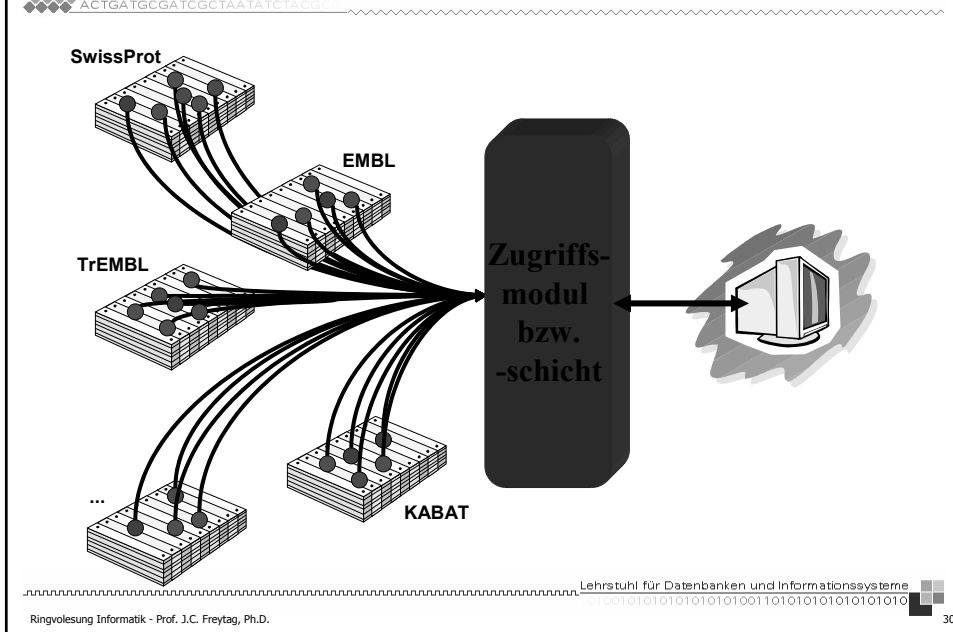
Datenmodellierung



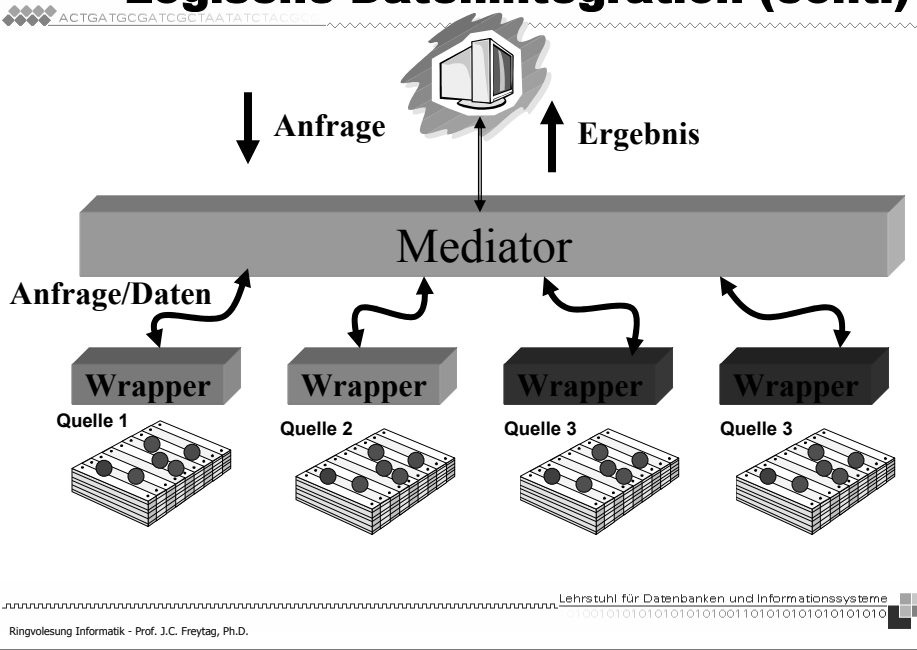
Daten aus unabhängigen Datenquellen



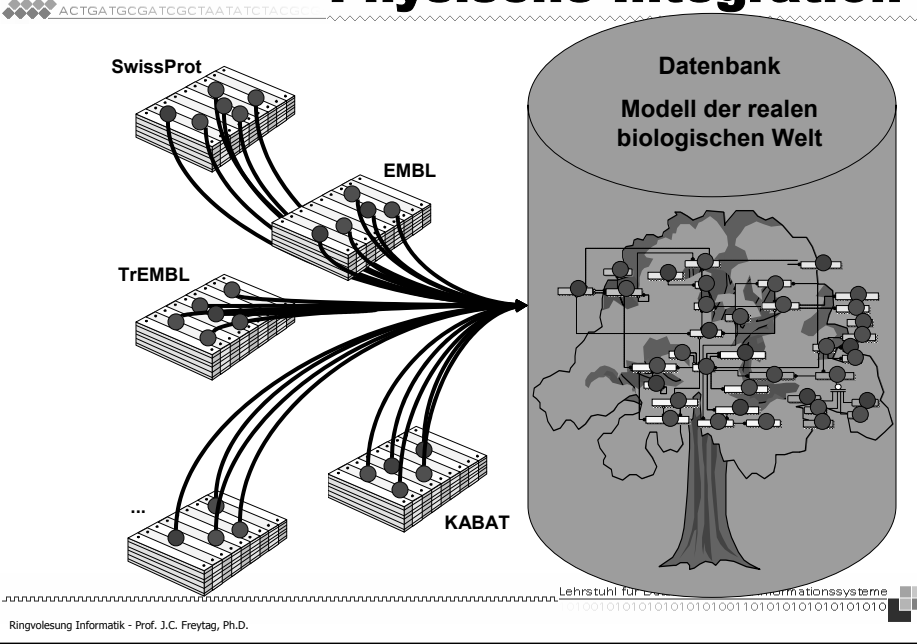
Logische Datenintegration

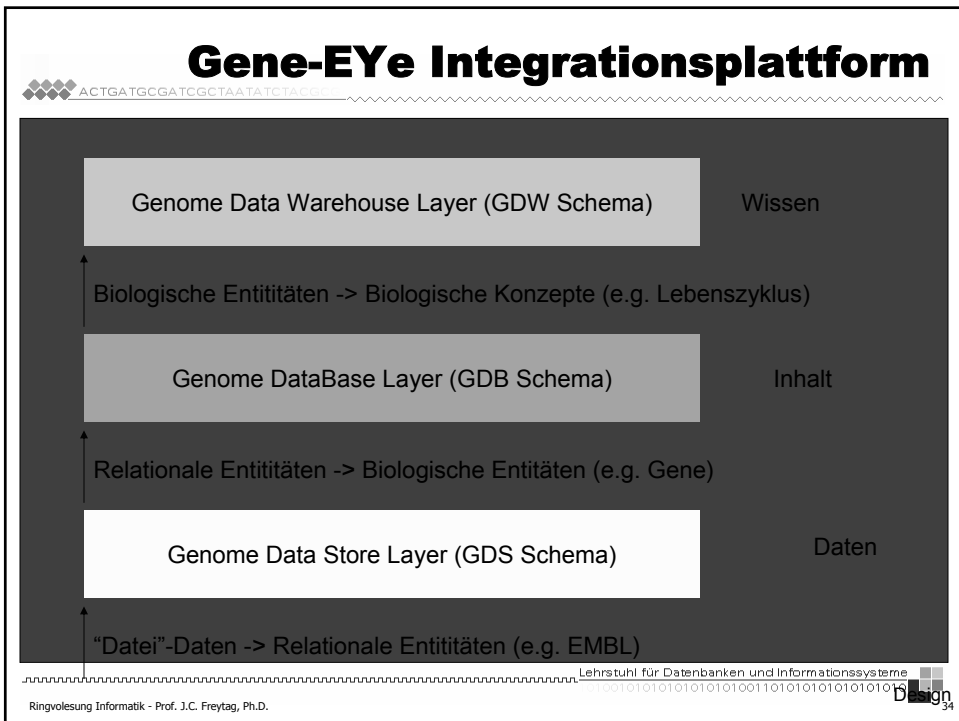
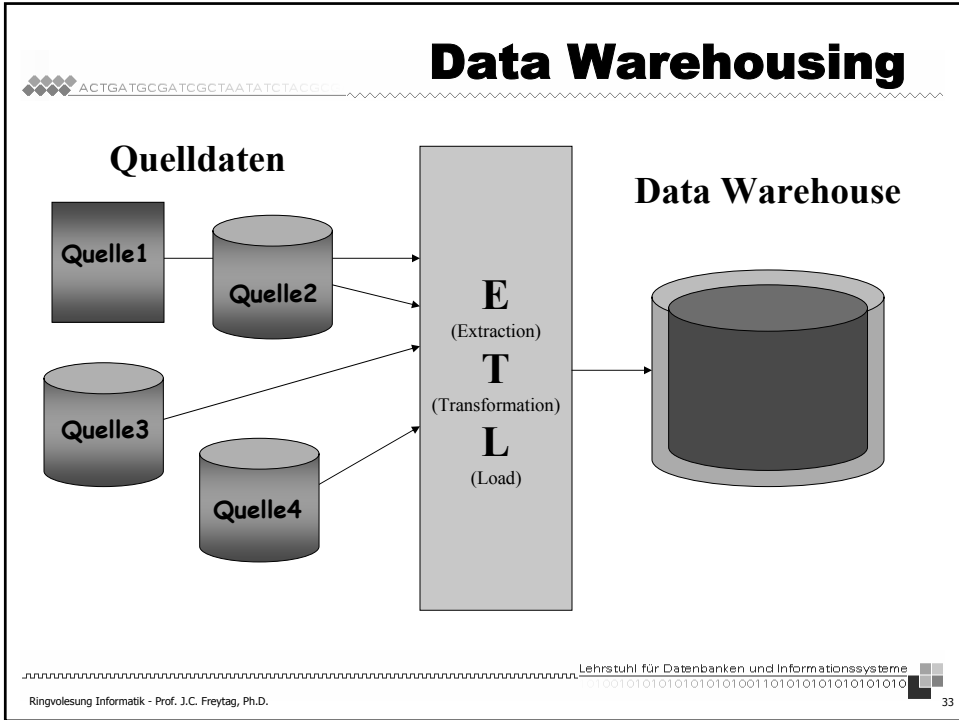


Logische Datenintegration (cont.)

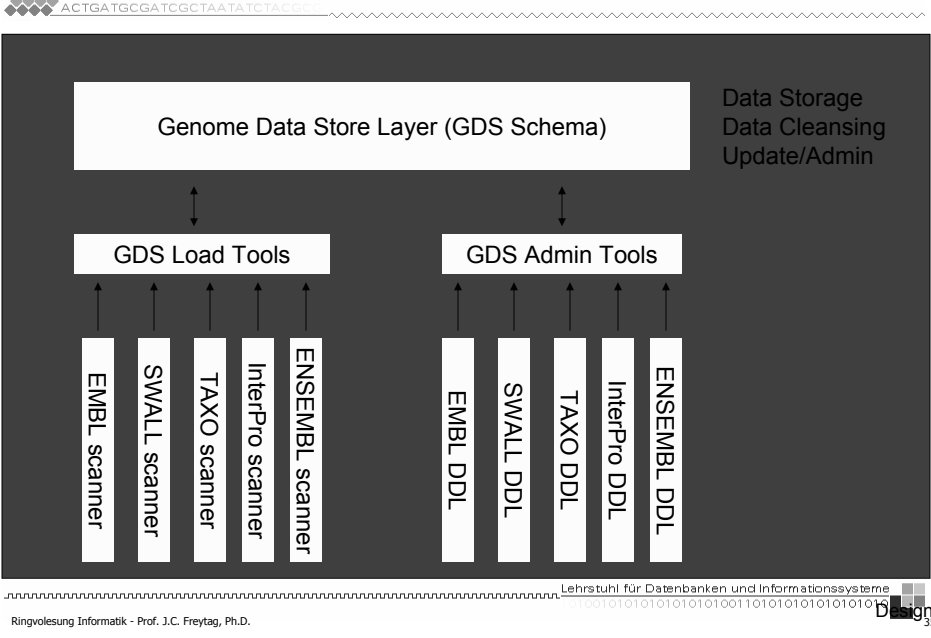


Physische Integration

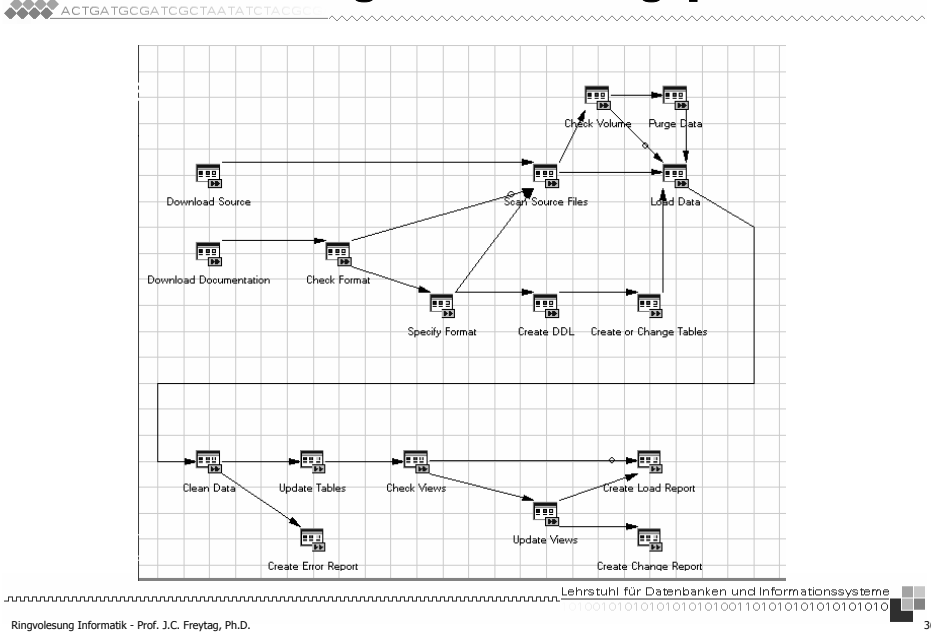




GDS: Von der Datei zur Datenbank

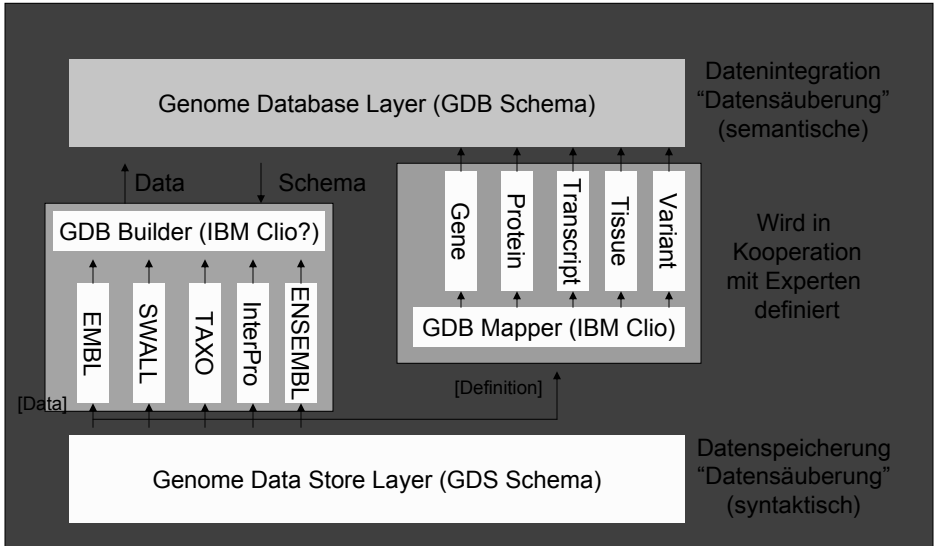


Modellierung des "Wartungsprozesses"



GDB: von den Daten zur Biologie

ACTGATGCGATCGCTAAATATCTACG

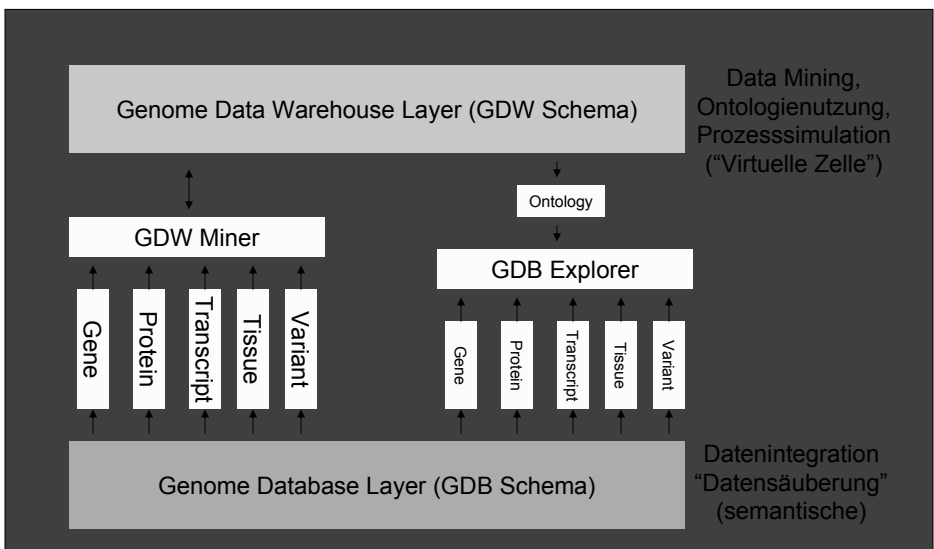


Lehrstuhl für Datenbanken und Informationssysteme

100101010101010100110101010101010

GDW: Plattform für Forschung

ACTGATGCGATCGCTAAATATCTACG




Lehrstuhl für Datenbanken und Informationssysteme

100101010101010100110101010101010

What are the goals?

ACTGATGCGATCGCTAAATATCTACCG



Source: Dusan Petricic, Toronto, Ontario -- The Toronto Star
<http://cagle.state.msn.com/news/gene/gene6.asp>

Fragen??

Lehrstuhl für Datenbanken und Informationssysteme

10101010101010100110101010101010