

Informationsveranstaltung „Qualitätsmanagement für Hochdurchsatz-Genotypisierung“

*TP5: „Primäre Datenstrukturen, Speicherung und
Transfer von Genotyp-Daten“*

21. Juni 2010, Berlin

Andreas Wolf, Olaf Junge, Tim Lu, Michael Krawczak

Institut für Medizinische Informatik und Statistik

Universitätsklinikum Schleswig-Holstein, Campus Kiel



SPONSORED BY THE



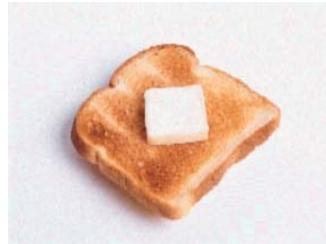
Federal Ministry
of Education
and Research



Motivation I

*Fehler sind nicht vermeidbar,
kommen zum ungünstigsten Zeitpunkt vor,
und sie sind teuer!*

- Murphy's law: "If anything can go wrong, it will!"
- McGillicuddy's corollary: „...at the most inopportune time!“
- Murphy's constant: "Matter will be damaged in direct proportion to its value!"



Hier: *IT-Qualitätsmanagement zur Verlustminimierung*



Motivation II

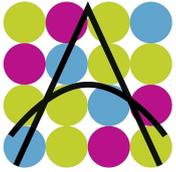
- Transfer und Speicherung von Hochdurchsatz-Genotypisierungdaten stellen eine Herausforderung dar:
 - *Volumen* (GB, TB)
 - *Inhalt* (personenbezogene Daten)
- Hohes Konfliktpotential:
 - *Technische Beschränkungen* (Kapazitäten,...)
 - *Datenschutz* (re-identifizierbare Daten,...)
 - *Wissenschaftliche Fragestellung* (Klinische und genetische Daten,...)



Bestandsaufnahme, Evaluation und Empfehlungen zu den Themen

- Qualitätskontrollierter Datenaustausch (Formate, Transfer)
- Effiziente und sichere Speicherung (Architektur)
- Gesetzeskonformer Zugriff (rechtliche Aspekte)
- ...

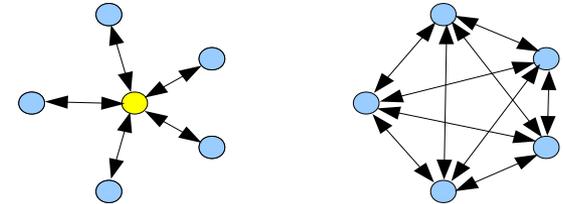




Datenaustausch: Formate

Einheitliches Datenformat?

- *Pro:*
 - Als Standard durch strikte Regeln gut dokumentiert
 - Einfache Import / Export Routinen für Standard
 - Weniger Konverter nötig
- *Contra:*
 - Ein Standard sollte *alle* features *aller* Formate berücksichtigen
 - *Zukünftige Formate* (neue Technologien) schwer / nicht integrierbar, da Standard hierfür nicht konzipiert
 - Ständige *Wartung*



Nicht nötig!





Datenaustausch: Formate

Strukturparameter (“wie”): Syntax eines Formats

- Text vs. binär (Lesbarkeit vs. Platzbedarf)
- Feldtrenner (z.B. [\t\n\r\f]+)
- End-Of-Line (abhängig vom OS)
- Character coding (z.B. ISO, UTF)
- Spalten- und Zeileninhalte (explizit oder implizit)

```
0 9682877SPC 0 0 2 2
0 3649838SPC 0 0 2 2
0 14639SPC 0 0 2 2
0 781250SPC 0 0 2 2
```



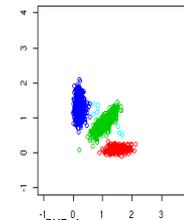
```
0 9682877SPC 0 0 2 2^M0 3649838SPC 0 0 2 2^M0 14639SPC 0 0 2 2^M0 781250SPC 0 0 2 2^M
```



Datenaustausch: Formate

Inhaltsparameter (“was”): Semantik, Metainformationen

- *Probe* (DNA): Probe annotations, genome build,...
- *Chip* (Substrat, auf dem DNA Probe analysiert wird): Chip ID, probe coordinates,...
- *Target* (Individuum, vom dem DNA analysiert wird): PedID, IndID, FaID, MoID, Geschlecht, Krankheitsstatus, Phänotypen,...
- *Assay* (Biochemische Reaktionen): Assay protocols, Variationen,...
- *Readout* (Messungen): Allele calling software, Genotyp-Formate,...
- *Analysis* (Auswertung des readout): Methoden, Software,...





Datenaustausch: Formate

Datentypen zum Speichern von Genotypen: Text vs. binär

Speicherplatz für einen Genotyp:

- *Character*: 2 Bytes / Genotyp = 16 Bit (z.B. "AC" explizit)
- *Binary*: 4 Bits / Genotyp = 4 Bit (z.B. "0010" als Codierung für "AC")
- *Binary*: 2 Bits / Genotyp = 2 Bit (z.B. "10" für Heterozygote)

Lesbarkeit vs. Platzbedarf vs. Verfügbarkeit von Metainformationen...



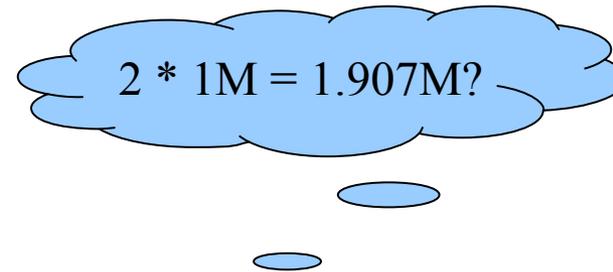
Datenaustausch: Formate

NB: International Standard Units vs.
International Electrotechnical Commission!

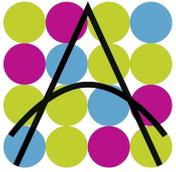
IEC Empfehlungen (1996):

- 1 Kibibyte (1KiB) = 1024 Byte
- 1 Kilobyte (1KB) = 1000 Byte

Geringe Akzeptanz!



Name	Symbol	SI (Basis 10)	IEC (Basis 2)	Differenz
kilo	k/K	10^3	2^{10}	+2.4%
mega	M	10^6	2^{20}	+4.9%
giga	G	10^9	2^{30}	+7.4%
tera	T	10^{12}	2^{40}	+10.0%
peta	P	10^{15}	2^{50}	+12.6%



Datenaustausch: Transfer

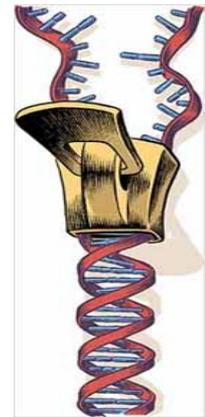
Datentransport

- *Portionieren* in “Archiven” oder “Container”
- Optionale *Kompression*
- *Datenintegrität* (Fehlererkennung und -korrektur)
 - Anspruchsvolle Prüfsummen (cyclic redundancy check, CRC)
 - Kryptographische Hashes, z.B. SHA-Familie (secure hash algorithms, NSA), MD-Familie (message-digest algorithms, MIT)
 - Andere, mit Fehlerkorrektur und Schutz vor mutwilligen Modifikationen
- *Datenaustausch* über
 - Nicht-zuverlässige aber effiziente Kanäle (UDP) mit Check
 - Sichere Kanäle, z.B. VPN, SSL, Verschlüsselung (PGP)



Genotyp- und Sequenz- spezifische Kompression

- Ausnutzen der inhärenten Struktur von DNA
 - <1% Variation von einem Referenz-Genom
 - “SNP mapping”, Variation von DBSNP
 - Kopien von Genen, Wiederholungen (STRs), Palindrome,...
- Effizientere Kompression als generische Algorithmen, dennoch verlustfrei





Relationale Datenbanken auch für genomweite Daten?

Pro:

- Organisierte Speicherung
- Indizierung bei Speicherung
- Normalisierungen zur Fehler-Erkennung und -Vermeidung
- Strukturierter Zugriff
- GUI

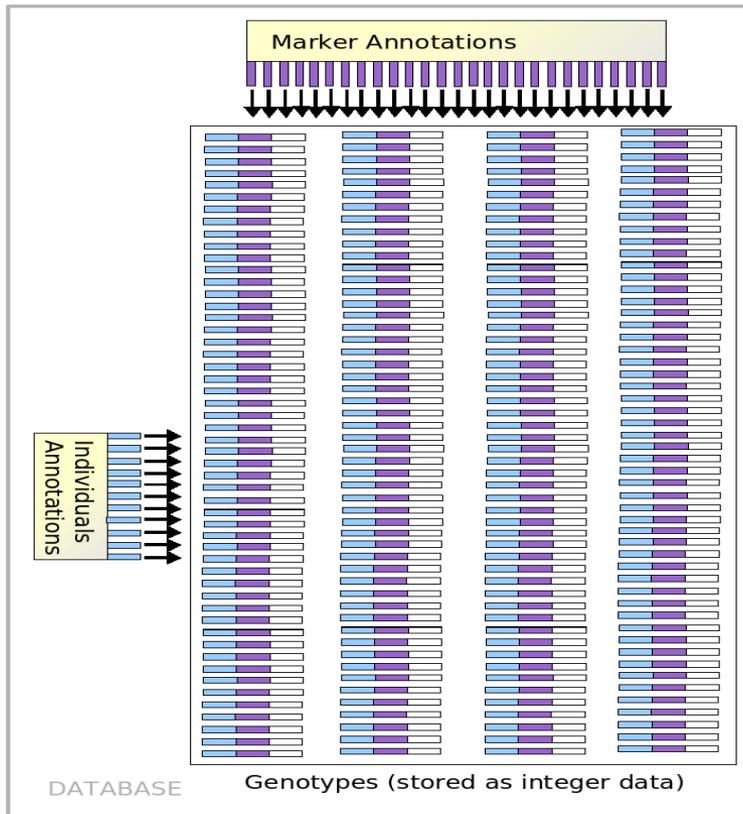
Contra:

- Limitierter Speicherplatz
- Begrenzter Hauptspeicher
- Strukturelle Ineffizienzen, besonders bei Verwendung eines LIMS, das nicht zu diesem Zweck designed wurde



Datenspeicherung

Speichern von Genotypen: **Integer** vs. Binary vs. BLOB.

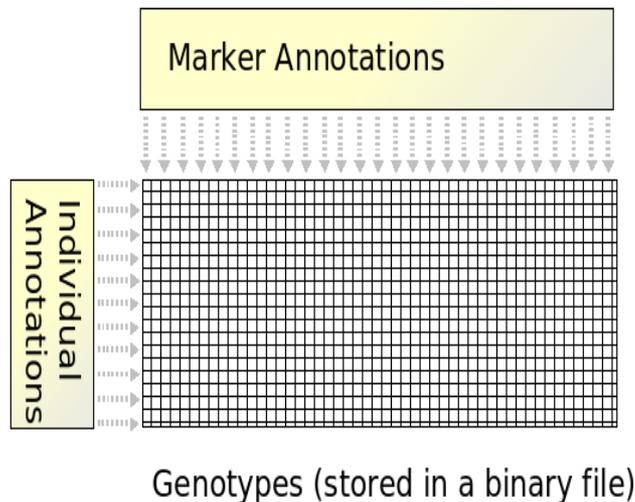


- Normalisiert
- Keine Redundanzen
- Genotypen explizit indiziert (Individuum und Marker)
- Einfacher Zugriff
- Hoher Speicherbedarf ☹️



Datenspeicherung

Speichern von Genotypen: Integer vs. **Binary** vs. BLOB.

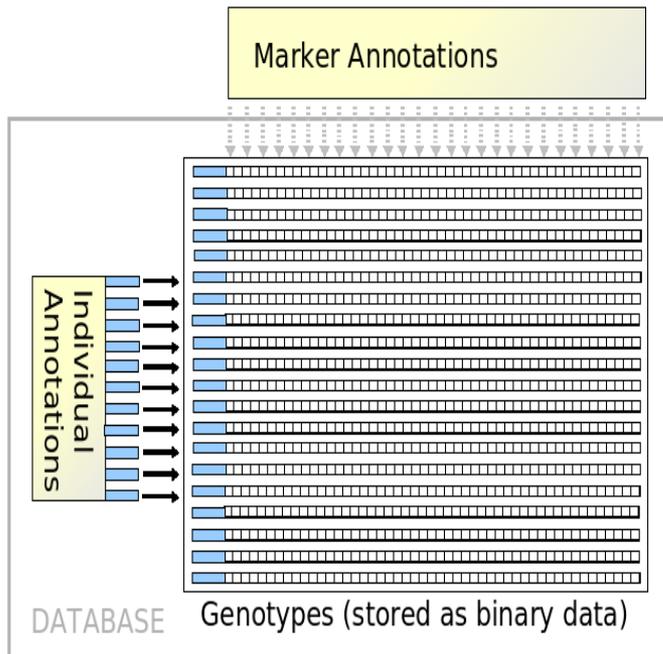


- Normalisiert
- Komprimiert / binär
- Geringer Speicherbedarf
- Genotypen implizit durch Position indiziert (Zeile & Spalte)
- Schwieriger Zugriff auf Genotypen ☹️



Datenspeicherung

Speichern von Genotypen: Integer vs. Binary vs. **BLOB**.

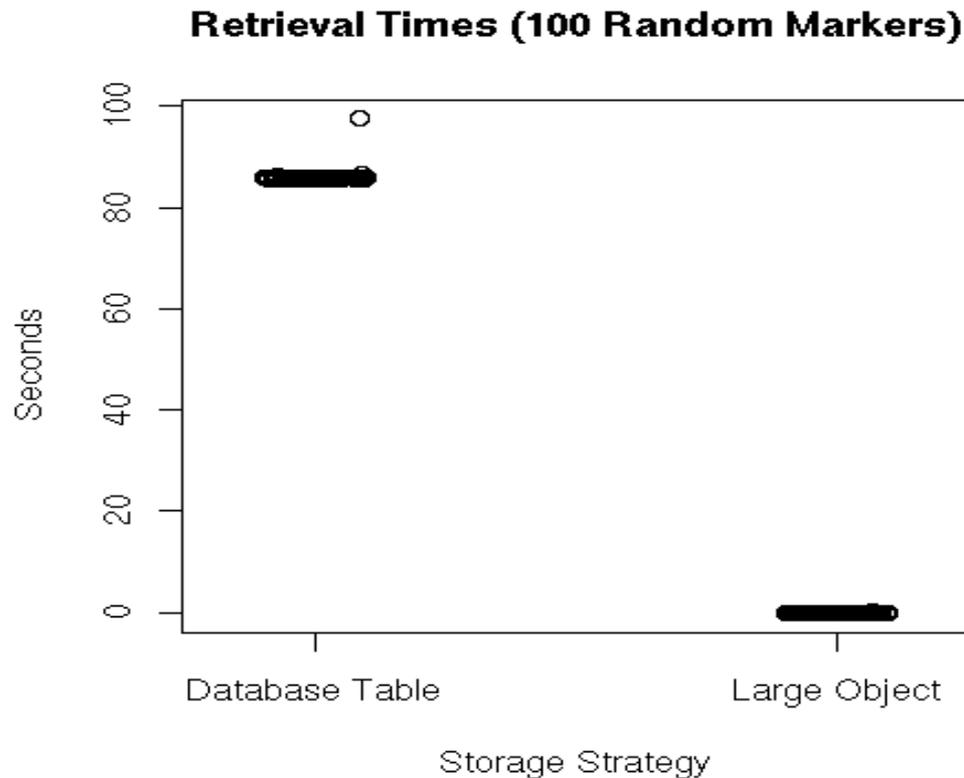


- Hybridlösung
- **Binary large objects**, BLOBs
- De-normalisiert
- Genotypen explizit indiziert an Individuum und implizit an Marker
- Moderater Speicherbedarf
- Einfacher Zugriff, z.B., `lo_import()` und `lo_read()` in PostgreSQL



Datenspeicherung

Benchmark: Normalisiert vs. de-normalisiert (BLOB)



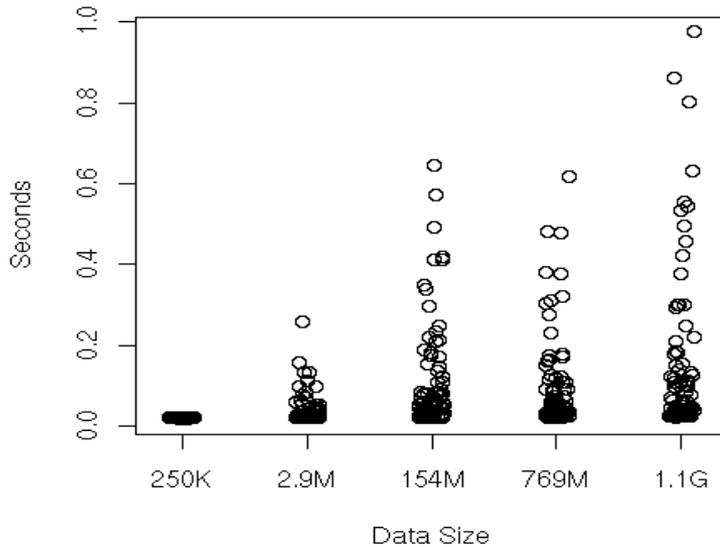
(1M SNPs, 250 KB)



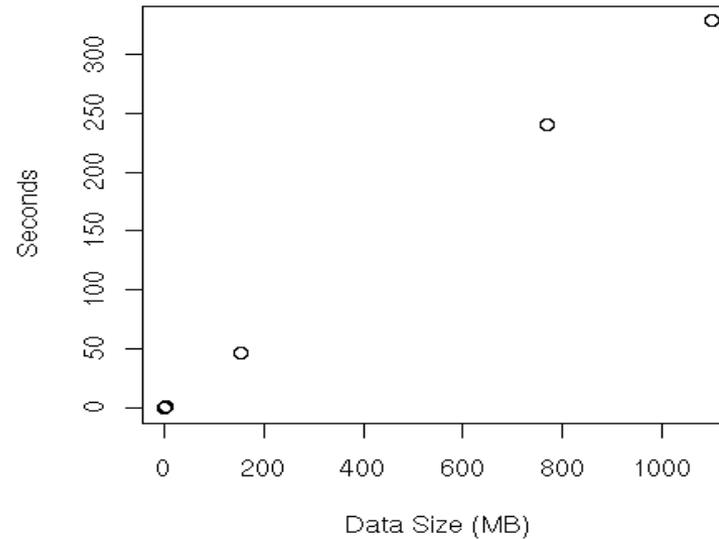
Datenspeicherung

Benchmark: Lesen und Schreiben von BLOBs

Retrieval Times (100 Random Markers)



Large Object Loading Times



SPONSORED BY THE



Rechtliche Aspekte:

- Genetische Daten berühren *per se* verschiedene Rechtsbereiche, z.B. Datenschutzrecht, Persönlichkeitsrecht, Eigentumsrecht
- Der Umgang mit solchen Daten wird durch Gesetze geregelt
- Gerade genetische Daten stehen unter strenger öffentlicher Beobachtung

Essenzielle Anforderungen:

- Die Rechte der Besitzer / Spender müssen respektiert werden
- Geltende Gesetze müssen befolgt werden
- Zustimmung öffentlicher Datenschutzbehörden sollte eingeholt werden



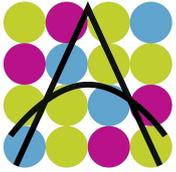
Zu beachtende Rechtskriterien:

- Datenminimierung und Datenvermeidung
- Anonymisierung und Pseudonymisierung
- Schutz vor Datenverlust („data safety“)
- Schutz vor Einbruch und Umgehung („data security“)
- Transparente Beschreibung der Prozesse (SOPs)
- Zustimmung zu Daten-Erhebung, -Transport und -Verarbeitung
- ...



Mechanismen zum Erreichen dieser Ziele:

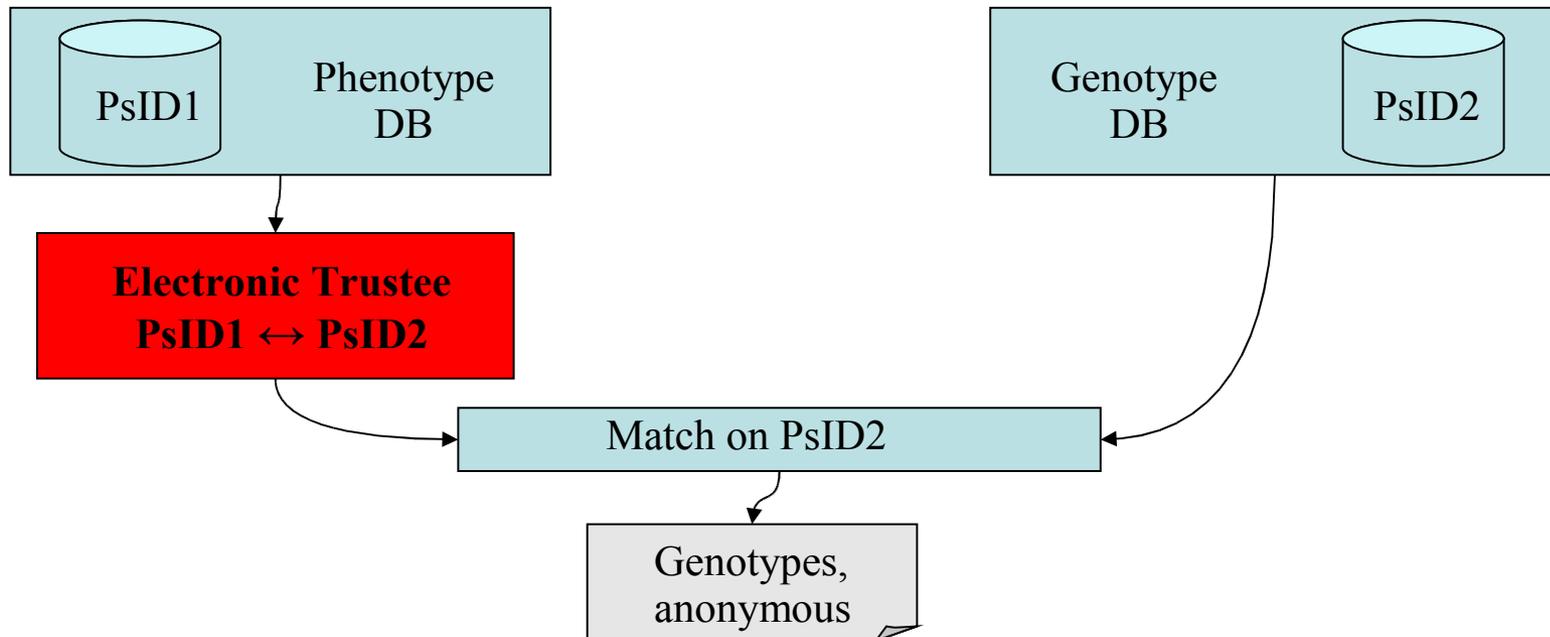
- *Rollenkonzepte (multilevel access)*
 - Definition einzelner Prozesse
 - Klassifizierung der Daten gemäß eines Sicherheitsmodells gestaffelt nach Sensitivität
 - Daten mit Prozessen und Prozesse mit Rollen verknüpfen
 - Zugriffsrechte an Rollen mit gewissen Freigaben vergeben
- *Multilevel security (MLS)*
 - Unterstützung von Rollenkonzepten durch Hardware (z.B. “asymmetric Isolation”) und Software (z.B. “trusted OS”)
- *Datentreuhänder (data custodianship, electronic trustees)*



Datenschutz

Beispiel (popgen-Trustee):

- formale, organisatorische und räumliche Trennung
- Pseudonymisierung, (faktische) Anonymisierung
- Vertrauenswürdiger Datentreuhänder





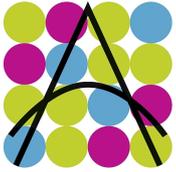
Datenschutz

Probleme und Einwände:

- Administrativ komplex
- Zeitaufwand und eingeschränkter Zugriff
- Datensätze sind (faktisch) anonym, sind nicht wiederverwendbar (in anschließenden Analysen oder Metaanalysen)

Dennoch:

- Datentreuhänder garantieren Einhaltung wesentlicher Kriterien (Datenminimierung, Schutz vor Re-Identifizierung und Schattendatenbanken)
- Zustimmung von öffentlichen Datenschutzbehörden erhöht das Ansehen und die Vertrauenswürdigkeit (Einwerben von Spendern und Fördermitteln)



Weitere Themen des TP

- **Hardwareanforderungen**
 - CPU, RAM, HD, Optische Medien, USB Flash
 - Rasante Entwicklung, wie Genotypisierungstechnologien
- **Archivierung / Backups**
 - Backup Systeme und Version control software
 - Wahl abhängig von diversen Parametern (Effizienz, Vernetzung,...)
- **Testen von Programmen und Formatversionen**
 - Referenzdaten und -programme zum Testen, program checking
 - Softwaredesign inclusive Testen (EP, AGILE), Generatoren



Zusammenfassung

“Take home messages“

- *Das Supertool gibt es nicht, und es ist auch nicht erstrebenswert*
- Ansprüche → Anforderungen ← Rahmenbedingungen
- Universelle Empfehlungen nicht sinnvoll / möglich
- Datenstrukturen und Datentransfer
 - Lesbarkeit vs. Speicherplatzbedarf, d.h. Text vs. binär
 - Datenintegrität
- Datenspeicherung und Datenzugriff
 - Relationale Datenbanken und BLOBs
 - Datenschutz und Datentreuhänder