Daten-Archive und die DFG-„Regeln guter wissenschaftlicher Praxis“

H. Pfeiffenberger, Ch. Wübber
Alfred Wegener Institut , Bremerhaven

Einleitung

- *Welche Regeln hat die DFG formuliert ?*
  - **Wortlaut**
  - **Hintergründe**
- *Was hat dieser erlauchte Kreis damit zu tun ? „Kernkompetenzen“:*
  - **Menge** **10^{15} Byte** **=>** **einige RZs (HPC, GRID)**
  - **Horizont** **10 Jahre +, Erschliessen, Erhalten** **=>** **Bibliothek**
  - **Policy** **=>** **Leitung**
- *Was bedeuten die Regeln also -*
  - **informationstechnisch und**
  - **organisatorisch ?**

Empfehlung 7 der DFG (1998)

- *Kommission „Selbstkontrolle der Wissenschaft“*
  - **http://www.dfg.de/antragstellung/**
- *Primärdaten als Grundlagen für Veröffentlichungen sollen auf haltbaren und gesicherten Trägern in der Institution, wo sie entstanden sind, für zehn Jahre aufbewahrt werden.*
  - **Auf die Aufzeichnungen später zurückgreifen zu können, ist schon aus Gründen der Arbeitsökonomie in einer Gruppe ein zwingendes Gebot. Noch wichtiger wird dies, wenn veröffentlichte Resultate von anderen angezweifelt werden.**
  - **Schon deshalb ist die Feststellung wichtig, dass das Abhandenkommen von Originaldaten aus einem Labor gegen Grundregeln wissenschaftlicher Sorgfalt verstößt und prima facie einen Verdacht unredlichen oder grob fahrlässigen Verhaltens rechtfertigt**
  - **Daher hat jedes Forschungsinstitut, in dem lege artis gearbeitet wird, klare Regeln über die Aufzeichnungen, die zu führen sind, und über die Aufbewahrung der Originaldaten und Datenträger ... zu erlassen.**

Hintergrund - was hat sich geändert?

- *Soziale „Kontrolle“ in größerer Community*
- *Anderer finanzieller Maßstab*
- *Andere (Daten-) Mengenskala*

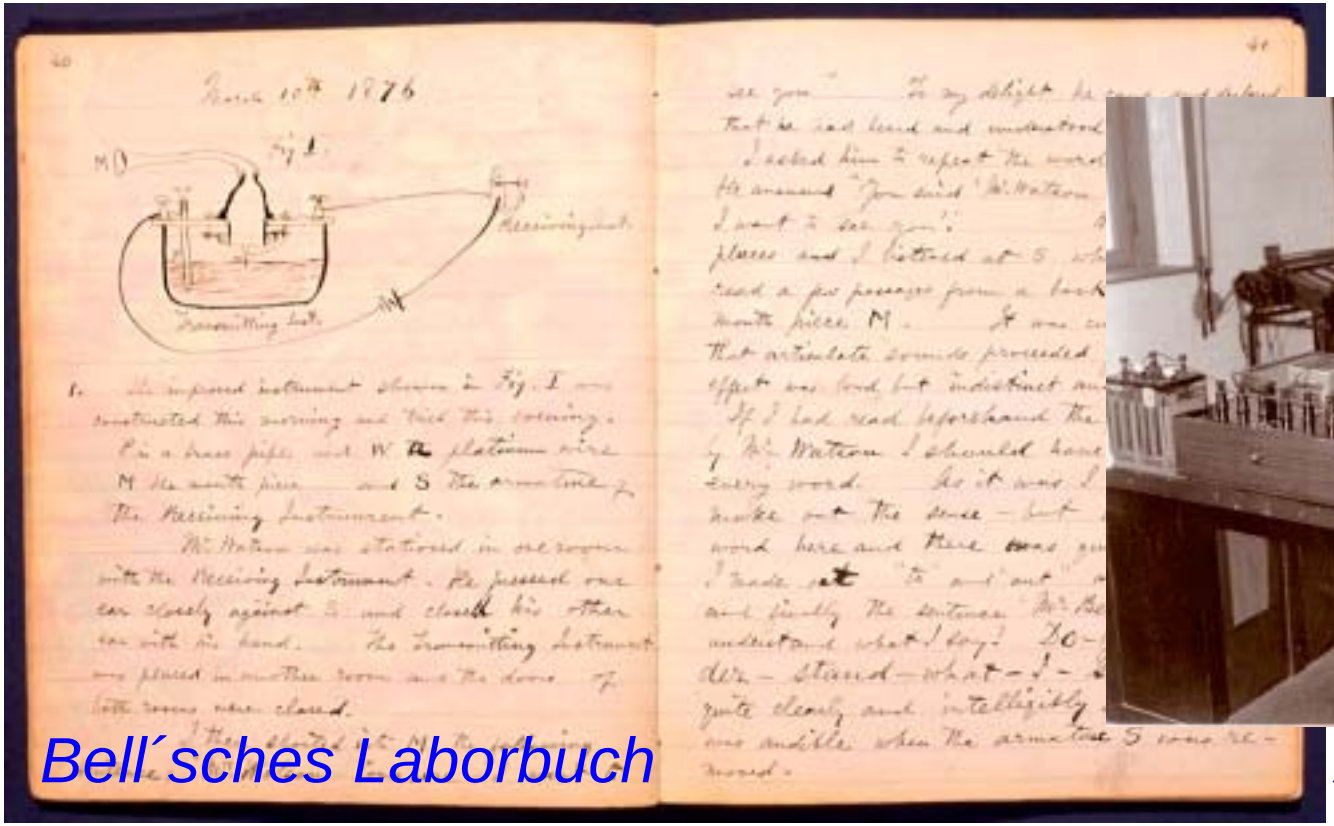

Bell´sches Laborbuch

Am Helmholtz-Pendel

Hg. I: Soziales und Finanzielles

- *Daten-„Skandale“ in Medizin (98) und Physik (03):*
  - **Anreiz, zu „erfinden“ ist offenbar gewachsen**
  - **Offenbare technische und organisatorische Lücken**
- *Datengrundlagen wurden von den Peers nicht (rechtzeitig) überprüft („Ablauforganisation“)*
  - **nicht vom Vorgesetzten**
  - **nicht von Ko-Autoren**
  - **nicht von den Gutachtern**
- *Letzte Ausrede: „Platte war voll“*
  - **Wären überall die technischen Mittel verfügbar?**
  - **Wird die Zeit gewährt, die Daten zu beschreiben und zu „formatieren“ und abzulegen? („lege artis“)**

Hg. II: Finanzielles, Zeit und Menge

- *Undokumentierte Daten in obskuren Formaten auf obsoleten Datenträgern: Ein nicht zu hebender Schatz?*
  - **Satelliten-Bilder der NASA: Turnhallen voller 9-Spur-Bänder (70er Jahre?, „Der Spiegel“) => DFD (DLR)**
- *Dokumentierte Daten:*
  - **Elementarteilchen-Beschleuniger (z.B. DESY)**
- Ein *Beispiel vom AWI: See-Seismik*
  - **ca. 12 TB aus 20 Jahren**
  - **Standardformate, -Software**
  - **entsprechen Jahren an Schiffsnutzung => 100 M€**
  - **Kopieren von 25.000 Bänder, Spiegeln (Neubaumittel)**

H. III: Die (Selbst-) Organisation wissenschaftlicher Arbeit

- *Hauptmittel wissenschaftlicher Qualitätssicherung: Nachvollziehbarkeitkeit im Labor, auf dem „Aktenwege“*
- *Historische „Aktenlage“: Laborbuch, Veröffentlichungen, Vorträge*
- *Heute:*
  - **Nachvollziehen im Labor: Unrealistisch => Kosten !**
  - **Großteil der „Aktenlage“ : Datenträger (?) => Auffindbar ?**
- *„Laborbuch“ und (klassische) Publikation reichen nicht!*
- *Aber : Gute Daten-Praxis ist* **de facto (noch)** *nicht (durchgehend) definiert und etabliert!*

Konsequenzen für RZs (Bottom Up)

- *Datenmanagement => Informationsmanagement*
- *Desaster-Recovery => Archivierung*

- *Accountmanagement => Identitätsmanagement*
- *Datenintegrität => Non-Repudiability*

- *Organisation der Requirement-Analyse*
  - **Angemessenheit**
  - **Best Practise (je Community)**
  - **Abläufe**

Informationsmanagement

- *(Meta-)Datenbanken - hier nicht i.S. verteilter Dateisysteme, sondern Suchkriterien*
- *Von dort : Persistente "Links" zu Flat Files*
- *Einführen und Verwalten von DOIs oder ähnlichem*

- *Schliesslich : (Bidirektionale) Persistente Links zwischen*

Publikationen, Daten, Metadaten und Personen

- *Workflows zum Sicherstellen der Verbindungen*

Archivierung

- *Desastervorsorge: Nicht (nur) Backup, sondern auch Spiegelung (anderes Gebäude)*
- *Davon eine Kopie WORM ? (=> kaufmännische Sitte)*
- *Datenträger-Management:*
  - **Aus dem Schrank des Wissenschaftlers in das HSM**
  - **Regelmäßige Auffrischung**
- *Formatmanagement (Daten und Metadaten)*
  - **technische Formate (XML)**
  - **Semantik (Dublin Core)**
- *Change-Management obsoleter Datenträger und Datenformate (Bsp.: Polarsterndaten: 20a, 3 Systeme)*

Identity Management

- *Workflows bedingen : Identität, Berechtigungen, Rollen => mehr Anforderungen als für Accounting*
- *Identitäten müssen ebenfalls mindestens 10 a aufrecht erhalten werden*
- *danach zumindest kein Recycling von IDs*
  - **Alternativ: „Anonymisieren“ von Daten**
  - **aber: Autorenschaft von Datenpublikationen**
- *eduPersonPrincipalName (persistent!), eduPersonAffiliation*
  => www.Internet2.edu/Middleware => GRID
- *Föderierte Verzeichnisse (wer darf 1 TB abholen?)*

Integrität, Non-Repudiability

- *(Arbeits-) Ökonomie*
  - **gegen Verlust sichern (Kosten, Wert der Daten)**
  - **verfügbar machen und halten**
    - ***Ab wann ? (Publizitätspflicht?, Bsp.: NDSC)***
    - ***Für wen ?***

  => Föderiertes Identitäts- und Rollenmanagement

- *wiss. Qualitäts-Sicherung*
  - **Integrität sichern**
    - „unverändert seit Publikation“
  - **Verantwortlichkeit festhalten**
    - „wer hat als letzte(r) die Daten geändert“

Requirements-Analyse

- *„tall order“ => Angemessenheit, zu messen an:*
  - **Wert der Daten**
  - **„Kosten“ des Verlustes der Glaubwürdigkeit**
- *abstrakte Best Practices erfassen*
  - **verschieden, je Community**
  - **Policies ableiten => Durchsetzen ist Leitungsfunktion**
- *Datenwelten analysieren*
  - **Systeme - Flat Files, RDBMS, CVS, ...**
  - **Formate**
  - **Metadaten**
- *Matrix : Communities / Datenwelten*

Minimal-Konsens Requirements

- *Wozu Konsens?*
  - **Vergleichbarkeit der „Best Practice“**
  - **Interdisziplinäre Zusammenarbeit**
  - **Globale Zusammenarbeit**
- *Daher: Standards für das Minimum*
  - **Metadaten (-formate)**
    - ***Dublin Core***
    - ***FGDC (georeferenzierte Daten)***
  - **Daten**
    - ***Einheiten***
    - ***Formate (netCDF)***
  - **Personen (eduPerson)**
  - **Linking (DOIs)**

Beispiele (AWI) I

- *Erdsystem-Modellierung - was archivieren?*
  - **Initialisierungsdaten**
  - **Code (CVS?)**
  - **Parameter, Jobskripte, Logfiles?**
  - **Ergebnisse ?? (Rekonstruierbarkeit?)**
  - **das Ganze noch einmal für Postprocessing ????**
- *CryoSat Bilder - Verantwortlichkeit*
  - **erste (integere?) Kopie beim DFD**
  - **Benachrichtigung bei Korrektur ?**
    - muss also doch die „Arbeitskopie“ gesichert werden ?
  - **reicht ein Link zur DFD-Kopie ?**
    - wer sichert Persistenz ?

Beispiele (AWI) II

Beispiele neben den „üblichen Verdächtigen“ (Modellierung, HEP und Satelliten) :

- *Mikroskopie und Bildwandler*
  - **30 MB / Bild ; 10 Bilder / Std, Mikroskop ; 200 Tage / Jahr**
    => 0,5 TB je Mikroskop,Jahr
    => 15.000 Metadaten-Einträge je Mikroskop,Jahr
  - **10 Mikroskope, 10 Jahre**
    => 50 TB
    => 1,5 Mio Metadaten-Einträge
  - **eine „Datenwelt“, mehrere Communities (Bio, Geo)**
- *Bioinformatik (Meta-Gendatenbank ALGINET)*

Zusammenfassung I

- *RZs müssen einige Themen ganz neu „sehen“*
  - **(Sinn des) Backup, Spiegelns**
  - **Platten „aufräumen“, reorganisieren (Mountpoints)**
  - **„Benutzer löschen“**
- *Transparenz, Verständlichkeit, Einfachheit, Konsistenz, Konstanz*
  - **keine Entschuldigung : „ich wusste nicht dass...“**
- *neues Maß an „Veröffentlichung“ der Daten*
  - **wird nicht bei allen Nutzern auf Gegenliebe stoßen**
    => kontrollierter Zugang zu Daten (Peers, Gutachter)
    => zeitabhängig (!), Policy-gesteuert

Zusammenfassung II

- *Weite des Horizonts - räumlich und zeitlich*
  - **10 Jahre +**
  - **Persistenz von Links zwischen Objekten**
    => auf verschiedenen DV-Systemen
    => in potentiell global verteilter Verantwortlichkeit

- *Semantische , inhaltliche Kompetenz notwendig*
  => Kooperation mit Bibliotheken ??
  => was sind die „Kernkompetenzen“ des RZ ?
- *Verantwortung für den Ruf der Wissenschaftler und der Institution*
  => Bedeutung der Rolle des CIO