

Elektronische Langzeitarchivierung: Probleme und Lösungsansätze

Lothar Schmitz

*Digital documents last forever -
or five years, whichever comes first.*

Jeff Rothenberg: Avoiding Technological Quicksand, 1999

Inhalt

1. Einführung: Probleme
2. Organisatorisches Umfeld
3. Lösungsansätze im Überblick
4. Emulation vertieft
5. Perspektive

Quellen

1. Einführung: Probleme

1. Probleme


2. Umfeld

3. Lösungsansätze

4. Emulation

5. Perspektive

Für Langzeitarchivierung verantwortlich
sind **Bibliotheken** und **Archive**.




Elektronische Archivierung: Die Lösung ...

- Elektronische Kataloge und Ausleihsysteme (OPAC)
- Schriftgut entsteht meist digital („*born digital*“)
- Multimediale Dokumente auf CD mit ISBN
- Digitale *Konservierung* alter Bestände

Vorzüge der digitalen Form:

- ✓ *Perfekte, kompakte Kopien*
- ✓ *Zugriff per Internet weltweit*
- ✓ *Volltextsuche*
- ✓ *Weiterverarbeitung*



... oder das Problem?

- geringe Lebensdauer digitaler *Medien*
 - rasch veraltende *Gerätetypen*
 - *Software*: noch größere Vielfalt und Neuerungsrate
- ☞ ***Negativfolgen von Wettbewerb und Fortschritt***

***Inhalt der Dokumente
den menschlichen Sinnen nicht zugänglich!***
(vgl. Höhlenmalerei, Hieroglyphen, ...)

☞ ***Kulturzeugnisse proaktiv retten, sonst Verlust!***

Beispiele (aus RLG Task Force Bericht 1996)

1. **US Volkszählungsdaten von 1960** (Census Bureau) auf UNIVAC type II-A Bändern. Restauration 1976-79. Verlust ca. 10000 Datensätze (von ca 1,5 Mio).
2. **Erste email** (Tomlinson, 1974, in Boston) verloren.
3. **Satellitenbilder des brasilianischen Regenwalds `70** (wichtig für Klimaforschung) nicht mehr brauchbar.
4. **Land Use and Natural Resources Project** (Cornell und NY, Ende der 60er Jahre), jetzt NY Staatsarchiv. Digitale Daten unbrauchbar => bei Bedarf Hardcopies neu erfassen.

UK Public Record Office bearbeitet laut Gesetz 50 Jahre alte Regierungsdaten => Was passiert 2015?


(Michael Lesk, Bellcore, 1995)

Das technische Langzeitarchivierungsproblem

besteht aus zwei Teilproblemen:

Im Prinzip
gelöst!

1. **Erhalt des digitalen Dokuments**,
d.h. des (vom Datenträger unabhängigen) **Bitstroms**.
2. **Erhalt des Zugangs zum digitalen Dokument D**,
d.h. einer „**Abspielvorrichtung**“



Task Force Definition des Problems

*„**Migration** is the periodic transfer of digital materials from one hardware / software configuration to another, or from one generation of computer technology to a subsequent generation.*

*The purpose of **migration** is to preserve the integrity of digital objects and to retain the ability for clients to retrieve, display and otherwise use them in the face of constantly changing technology.“*

Nicht-technische Probleme

- **Juristische Fragen:**
Rechte am Dokument?
(Änderungen, Weitergabe?)
Gesetzliche Ablieferverpflichtung?
Rechte an Abspielkomponenten?
- **Gesellschaftliche Fragen:**
Welche Dokumente sollen erhalten werden?
(Kriterien?)
Wer trägt die Kosten?
Für die ***sichere und unterbrechungsfreie
Erhaltung*** zuständige Institution?

Internationale Anstrengungen

- **Research Libraries Group (USA)**
Task Force Report: Preserving Digital Information, 1996
- **CCSDS (NASA, DLR, ...)** Reference Model for
Open Archival Information Systems (OAIS), 1999
- **Consortium of University Research Libraries (UK)**
CURL Exemplars for Digital ARchiveS (CEDARS)
- **Networked European Deposit Library (NEDLib)**
OAIS => **DSEP** und Emulation (**RAND, IBM Almaden**)
- **Council on Library and Information Resources (USA)**
Migrationsstudie & Workbook (**Cornell University**)
- ...


2. Organisatorisches Umfeld

1. Probleme
2. Umfeld
3. Lösungsansätze
4. Emulation
5. Perspektive

Allgemein akzeptierter Standard:

OAIS Reference Model


- **Prozessmodell**
„Functional Model“
- **Datenmodell**
„Information Model“




NEDLib **DSEP** Modell

- für **Bibliotheken**
- spezialisierte Prozesse

Das „OAIS Functional Model“



Information Model des OAIS (I) - Content



Information Model des OAIS (II) - AIP




Figure 4-16: Archival Information Package (AIP)

Arbeitsvoraussetzungen beim Erhalt

- ***stetig wachsende Datenvolumina***
- kostengünstig => ***durch automatisierte Prozesse***
- ***langfristig*** (auch > 100 Jahre) => unterbrechungsfrei
- ***zugänglich*** (evtl. weiterverarbeitbar) ***erhalten***
- ***bei größtmöglicher Authentizität***
- ***ohne Rückgriff auf Autor*** und dessen Kontextwissen

jedenfalls keine „heroischen Maßnahmen“ !!

3. Lösungsansätze im Überblick


1. Probleme
2. Umfeld
3. Lösungsansätze
4. Emulation
5. Perspektive

Notlösung:

*Ausweichen auf **nicht-digitale Formate**
wie Papier, Mikrofiche, Metallfolie, Lochstreifen, ...*

- + dauerhafter
- + teils dem Auge direkt zugänglich
- Vorteile digitaler Dokumente gehen verloren
- nur einfache Text- und Bilddokumente möglich, keine Multimedia, Links, Spreadsheets, CAD, ...

Teilproblem „Erhalt des Zugangs“



Drei Basisstrategien:

- 1) **Dokument an neue Umgebung anpassen**
=> *Transformation des Dokuments*
- 2) **Umgebung für Originaldokument erhalten**
=> *anstelle des Dokuments die Umgebung anpassen*
- 3) **Umgebungsunabhängigen Inhalt aufbewahren**
=> *Form und damit Abspielumgebung unwichtig*

Varianten der Basisstrategien

1) Dokument an neue Umgebung anpassen

- 1.1) reversible Transformationen
- 1.2) irreversible Transformationen

2) Umgebung für Originaldokument erhalten

- 2.1) Emulation
- 2.2) Portierung von Viewern
- 2.3) *Museumsansatz*
- 2.4) *Digitale Archäologie („Rosetta Stone“)*

3) Umgebungsunabhängigen Inhalt aufbewahren

z.B. in selbstbeschreibenden, erweiterbaren XML-Formaten

1.1) reversible Transformationen

mit unterschiedlicher Zielsetzung:

a) Wechsel der Codierung:

z.B. *ASCII* \Leftrightarrow *Unicode-Subset*

b) OS-spezifische Textdateiformate:

z.B. *Unix* \Leftrightarrow *Windows* \Leftrightarrow *Mac*

c) Datenkompression:

z.B. *zip* / *unzip*

d) Verschlüsselung:

z.B. *PGP*

**=> kein Informationsverlust
wenn ...**

1.2) irreversible Transformationen

„Migration im engeren Sinn“

z.B. Formate von
Gleitpunktzahlen

a) Direkte Konversion:

- aufwärtskompatible Programmversionen
z.B. *verschiedene Word-Versionen*
- Import-Filter oder Konversions-Tools
z.B. *WordPerfect -> Word*

=> *typisch zwischen proprietären Formaten*

b) Konversion über Zwischenformat:

z.B. über ASCII zwischen Word und *TeX*

=> **Gefahr von Informationsverlusten !**

Implizite Information als Migrationshindernis

- ASCII-Textgrafik => *LaTeX*

```
-----  -----  -----  
I D1 I   I D2 I   ... I Dn I  
-----  -----  -----  
      I           I           I  
-----  
I   Präsentations-Schicht   I  
-----  
I   Betriebssystem-Schicht   I  
-----  
I   Hardware-Schicht   I  
-----
```

```
-----  -----  -----  I D1 I I D2 I ...  
I Dn I -----  -----  I I I -----  
-----  I Präsentations-  
Schicht I -----  I  
Betriebssystem-Schicht I -----  
-----  I Hardware-Schicht I  
-----
```

- *TeX*-Formel nach MathML:


$f(b+c)$

Funktionsanwendung oder Produkt ?

- Zeitung: Fortsetzung nächste Seite,
Spalte 3 unten.


2.1) Emulation

- Idee:** 1. Alten Computer auf neuem emulieren
2. Darauf Originalsoftware und -dokument laden



2.2) Portierung von Viewern

- Idee:** 1. Viewer-Software auf neuen Computer portieren
2. Darauf Originaldokument laden



- Quelle des Viewers und 2047^{er} Compiler benötigt.
- Für alle Viewer durchzuführen.

Gegenüberstellung von Strategien

	Migration	Emulation
Authentizität	gefährdet	hoch
Erhaltungsaufwand	je Typ: hoch je Dokument: hoch	je Plattform: hoch je Dokument: wenig
Technisches Risiko	nur kurzfristig abschätzbar	derzeit hoch anzusehen
geeignet für Langzeitarchivierung	<i>noch nicht erwiesen</i>	<i>noch nicht erwiesen</i>

In jedem Fall nützlich:

- **Standardisierung:**
Beschränkung auf wenige Plattformen und Formate (z.B. ASCII, PDF, TIFF, SVG, SMIL, ...)
=> Reduzierung des Aufwands
- **Erweiterbare Formate:**
Kein Stillstand der Entwicklung abzusehen
=> Stabilität nur durch Änderbarkeit
- **Offene, nicht proprietäre Formate (z.B. TeX):**
Rechte, Formate und Quellen als Gemeingut
=> Basis für Gemeinschaftsentwicklung, nicht durch kommerzielle Interessen eingeschränkt

4. Emulation vertieft

1. Probleme
2. Umfeld
3. Lösungsansätze
4. Emulation
5. Perspektive

Emulation


= „Migration der Abspielumgebung“

⊆ Migration von Software

Portierung




Standardtechniken



Diagrammbausteine nach N. Wirth


- **T-Diagramm**
(Translator, *Compiler*)



- **I-Diagramm**
(Interpreter,
auch *Viewer*,
Emulator)



- **M-Diagramm**
(*Maschine*)



ähnlich wie Dominosteine aneinanderzulegen !

Verwendung eines Emulators

***M₂₀₀₁-Emulator
auf M₂₀₄₇ ...***

M₂₀₀₁
M₂₀₄₇

≈


M₂₀₀₁

M₂₀₄₇

***... entspricht
M₂₀₀₁***


Mehrstufige („layered“) Emulation

hier zweistufig:



***Je mehr Stufen,
desto ineffizienter !***

Erzeugung / Portierung eines Emulators




mit höherer Programmiersprache P und Compiler
(hier für M_{2047} ; genauso für M_{4711} , sofern ...)

Emulation mit Virtueller Maschine VM

- **Aufgabe:** alte Plattformen M_1, \dots, M_m auf neue Plattformen N_1, \dots, N_n bringen. Erfordert $m \cdot n$ Emulatorbausteine:




- Die gleiche Aufgabe mit **VM** erfordert nur $m+n$ Emulatorbausteine:




- **Virtuelle Maschine**
 - schafft Stabilität
 - kontinuierlicher Aufwand

Ineffizienz vermeiden ...




... durch zwei Compilationsschritte



Funktioniert Emulation?

- Emulatoren bei der **Entwicklung neuer Computer**.
- ❖ Motorola 68000-Emulator von **Apple** beim Übergang zum PowerPC-Prozessor verwendet.
- Emulatoren für populäre **Videospiel-Plattformen** im Netz verfügbar.
- Anspruchsvolle Emulatoren (z.B. **MMIX von D. Knuth**) in der Informatik-Ausbildung im Einsatz.
- ❖ **Experimente von Rothenberg** mit kommerziellem Windows-Emulator auf Macintosh (MM-CDs).
- **ICL1900-Emulator von Holdsworth** implementiert (in C auf Win32, Solaris, Linux), darauf Timesharing-OS George3 und Algol68-Compiler.

AIP-Speicherkapsel für Emulation



Kritik und Klärungsbedarf

- OAIS Red Book
 - *E/A- und Zeit-Abhängigkeiten zu wenig beachtet.*
 - *Fehlende Unterstützung (Werkzeuge) im Markt.*
- D. Bearman („Reality and Chimeras ...“)
 - *Undefiniert, welche Dokumentattribute wichtig sind.*
 - *Nicht Software, sondern Belege wesentlich (=>DB)!*
- J. Rothenberg („Using Emulation ...“)
 - *Entwicklung eines Formalismus für Emulatorspezifikationen.*
 - *Sichere Datenkapselungstechniken (für komplexe AIPs).*
 - *Selbstbeschreibung durch Mensch-lesbare Annotationen.*
 - *Hilfe-System für künftige Nutzer.*

Aktuelle Entwicklung

- Anstelle von Jeff Rothenberg, RAND-Europe, jetzt **Raymond Lorie**, IBM Almaden, Partner von NEDLib.
- Bestandteile seines Konzepts:
 1. Unterscheide zwischen Erhalt von Dokumenten und Programmen (beides nötig, aber verschieden).
 2. Speichere Dokumente „XML-ähnlich“ und beschreibe Dokumentenstrukturen „XML-DTD-ähnlich“.
 3. Verwende einen **Universal Virtual Computer (UVC)**.
Dokumenttypdefinierer: **UVC-Viewer**
Computerhersteller: Computer \Leftrightarrow **UVC**
(je zwei Emulatoren)

1. Probleme
2. Umfeld
3. Lösungsansätze
4. Emulation
5. Perspektive

5. Perspektive

Dringend zu klärende Fragen:

- Emulation
 - *geeignete, umfassende Spezifikationssprache?*
 - *Bedienbarkeit der Programme?*
- Migration
 - *akkumulierende Verfälschungen vermeiden?*
 - *Aufwand dauerhaft tragbar?*
- Inhaltsorientierte Archivierung
 - *authentisch genug?*
- Rechtliche und gesellschaftliche Probleme

Komplementäre Nutzung der Strategien

- **Originalfassung** für „Dokumenten-Historiker“: Originaldokument und Emulatoren.
- Von häufig gebrauchten Dokumenten daraus **aktuelle Fassungen** durch Migration ableiten.
- Für **automatische Auswertung** von Inhalten:
 - Erschlossene Informationen in einem offenen **XML**-Format halten.
 - Metadaten in Form von **RDF**-Statements (Resource Description Framework) basierend auf **Dublin Core**-Begriffen.

Links und Quellen

Diese Folien sind zugänglich unter:

<http://ist.unibw-muenchen.de/People/lothar/DigBib.htm>

Guter Startpunkt für eigene Recherchen:

<http://www.nla.gov.au/padi/>

Literatur

Oft zitiert

- *Preserving Digital Information*, Report of the Task Force on Archiving of Digital Information, Research Libraries Group, Mai 1996.
- CCSDS Draft Recommendation CCSDS 650.0-R-1: *Reference Model for an Open Archival Information System (OAIS)*, Red Book, Mai 1999.

Fallstudie zur Migration

- G.W.Lawrence, W.R.Kehoe, O.Y.Rieger, A.R.Kenney: *Risk Management of Digital Information: A File Format Investigation*, CLIR, Jun. 2000.

Jeff Rothenberg zu Emulation

- *Avoiding Technological Quicksand: Finding a Viable Technical Foundation for Digital Preservation*, RAND-Europe, Jan. 1999.
- Gemeinsam mit Tora Bikson: *Carrying Authentic, Understandable and Usable Digital Records Through Time*, RAND-Europe, Aug. 1999.
- *An Experiment in Using Emulation to Preserve Digital Publications*, NEDLib Report 1, Apr. 2000.
- *Using Emulation to Preserve Digital Documents*, RAND-Europe and Koninklijke Bibliotheek, Jul. 2000.

Weitere Arbeiten zum Emulationsansatz

- D.Bearman: *Reality and Chimeras in the Preservation of Electronic Records*, D-Lib Magazine, Apr. 1999.
- S.Gilheany: *Preserving Information Forever and a Call for Emulators*, Digital Libraries Conf., Singapur, 1998.
- D.Holdsworth: *C-ing ahead for digital longevity*, CAMiLEON Project, University of Leeds, ??.
- R.A.Lorie: *Long-Term Archiving of Digital Information*, IBM Almaden Research Report RJ 10185, Mai 2000.
- R.A.Lorie: *Long Term Preservation of Digital Information*, IBM Almaden Research, Okt. 2000.