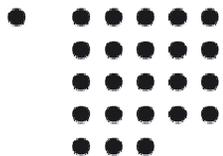


Einführung in die digitale Langzeitarchivierung



Fachhochschule Köln
Cologne University of Applied Sciences

Institut für Informationswissenschaft
Institute of Information Science

Prof. Dr. Achim Oßwald

Fachhochschule Köln
Institut für Informationswissenschaft
achim.osswald@fh-koeln.de

Problemstellungen (1)

↪ Datensicherung im privaten Bereich



Wie lange werden wir diese Medien nutzen können?



Quelle der Grafiken: Wikipedia

Problemstellungen (2)

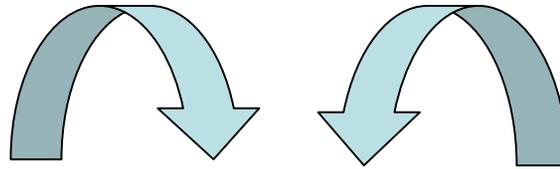
↪ Ursachen für Datenverlust:

44%	Hardware- und Systemfehler
32 %	Menschliches Versagen
14 %	Softwarefehler
7 %	Viren
3 %	Naturkatastrophen

Angaben von data recovery company Ontrack (1996), nach R. Scheffel
Quelle: Ross, Seamus, Gow, Ann: Digital Archaeology: Rescuing Neglected and Damaged Data Resources; JISC/NPO Studie 2/1999

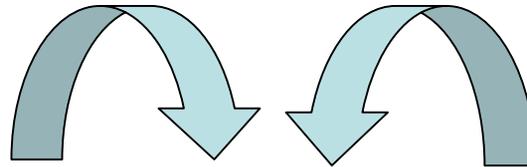
Problemstellungen (3)

Haltbarkeit
der Datenträger



Verfügbarkeit
der Wiedergabegeräte

Verfügbarkeit von
und Nutzungskompetenz
für Anwendungssoftware
und ihre Dateiformate



Verfügbarkeit von
und Nutzungskompetenz
für Betriebssystem-
software

?

**Kompatibilität / Nutzbarkeit / Authentizität
im Hinblick auf Langzeitverfügbarkeit**

Software-Inkompatibilitäten

	Datei-format 1	Datei-format 2	Datei-format 3	Datei-format 4
Programmversion 1.0	paßt			
Programmversion 2.0	paßt noch	paßt		
Programmversion 3.0		paßt noch	paßt	
Programmversion 4.0			paßt noch	paßt

Quelle: Dobratz: CMS-Kolloquium, 16.5.2006

Überblick

Aktuelle Fragen der Langzeitarchivierung (LZA) und Langzeitverfügbarkeit (LZV)

- ↪ **Was ist eigentlich LZA digitaler Objekte?**
- ↪ **Was soll langfristig gesichert werden?**
- ↪ **Wer soll die Sicherung durch LZA übernehmen?**
- ↪ **Wie soll gesichert werden?
Oder: Welche Techniken und Strategien gibt es für die LZA digitaler Objekte?**
- ↪ **Was wird / könnte das kosten?**
- ↪ **Was wird derzeit zur Langzeitarchivierung digitaler Objekte schon unternommen?**
- ↪ **Was sind derzeit die zentralen offenen Fragen?**

Was ist eigentlich Langzeitarchivierung digitaler Objekte?

↪ “**Langzeitarchivierung** digitaler Objekte umfasst alle Maßnahmen, die dazu dienen, digitale Objekte für die Nachwelt dauerhaft zu erhalten. Der Begriff ist eng verwandt mit **Langzeitverfügbarkeit**, die jedoch die dauerhafte Benutzbarkeit mehr in den Vordergrund stellt.“

Quelle: *nestor-Glossar; Stand 20.2.2004*

↪ „**'Langzeit'** ist die Umschreibung eines nicht näher fixierten Zeitraumes, währenddessen wesentliche nicht vorhersehbare technologische und soziokulturelle Veränderungen eintreten, die sowohl die Gestalt als auch die Nutzungssituation digitaler Ressourcen in rasanten Entwicklungszyklen vollständig umwälzen werden.“

aus: *Schwens/Liegmann in: Grundlagen der praktischen Information und Dokumentation; München 2004;*

zitiert nach: *nestor-Glossar; Stand 20.2.2004*

Was soll gesichert werden? (1)

Objektbezogene Perspektive

- ↪ **Printprodukte**
Pflichtexemplarbibliotheken / Bibliotheken mit speziellen Sammelschwerpunkten (DNB, LBen, Zentrale Fachbibliotheken / SSG-Bibliotheken)
- ↪ **Digitale Objekte** auf **physischen Datenträgern**
- ↪ **Online** verfügbare digitale **Objekte**
- ↪ **Archivmaterialien**
verwaltungsbezogen zuständige Archive
- ↪ **Museumobjekte**
prinzipiell jedes Museum

Was soll gesichert werden? (2)

Das digitale Erbe unserer Gesellschaft ...

↪ ... umfasst kulturelle, erzieherische, wissenschaftliche, administrative Quellen, aber auch technische, juristische, medizinische oder andere Arten von Information, die digital erzeugt oder digitalisiert wurden

nach:

UNESCO Charta zum Erhalt des digitalen Kulturerbes

↪ Digitale Materialien, d.h. Texte, Datenbasen, Foto, Film, Graphiken, Software, Webpages

=> Unter Bezugnahme auf die Sammelrichtlinien der jeweiligen Einrichtung

Was soll gesichert werden? (3)

Nationale und länderspezifische Perspektive

- ↪ **Digitale Publikationen auf physischen Datenträgern:**
Sammelauftrag der DNB (bei deutscher Sprache und Bezug zu Deutschland) sowie anderer Pflichtexemplarbibliotheken
- ↪ **Netzpublikationen, soweit öffentlich zugänglich:**
Sammelauftrag der DNB seit 22.6.2006 (“Medienwerke in unkörperlicher Form”; soweit Bezug zu Deutschland) sowie Zielsetzung einzelner Landesbibliotheken

Was soll gesichert werden? (4)

↪ 3Sat-Film zur Aufgabenstellung der DNB



Exkurs: Beispiele aus Internet Archive

The screenshot shows a Mozilla Firefox browser window with the address bar containing the URL: <http://web.archive.org/web/19970415012218/http://www.fbi.fh-koeln.de/>. The page content includes the logo for 'Bibliotheks- und Informationswesen' at 'FH Köln', a welcome message: 'Willkommen am Fachbereich Bibliothek und Informationswesen (FBI) der Fachhochschule Köln (FH Köln)', and a navigation bar with icons for 'Aktuelles am FBI', 'Der Fachbereich', 'BID-Links', and 'Hilfe und Tips'. Below this, there are links for 'Studienreform am Fachbereich' and 'Sommerprogramm '97 des AKI Köln'. At the bottom, it says 'Mit Hilfe der obigen Navigationsleiste erhalten Sie Zugriff auf folgende Angebote:' followed by links for 'Aktuelle Themen am Fachbereich' and 'Der Fachbereich'.

The screenshot shows a Mozilla Firefox browser window with the address bar containing the URL: <http://www.fbi.fh-koeln.de/>. The page content includes the logo for 'Fachhochschule Köln' and 'Cologne University of Applied Sciences', and the logo for 'Institut für Informationswissenschaft'. Below this, there is a welcome message: 'Willkommen auf den Seiten des Instituts für Informationswissenschaft' and a search bar. A photograph of the building entrance is shown. The main content area is divided into several sections: 'Institut' (with links for Fakten, Personen, Projekte, Publikationen, Alumni, Kooperationen, Labore, Fachschaft), 'Studium' (with links for Studiengänge, Lehrveranstaltungen, Prüfungen / Diplom, Praxissemester, Studieninformationen, Studienreform, Stud. Arbeitsergebnisse), 'Links' (with links for Fachinformationen, Benutzerkonten, Bibliotheken der FH, Bookmarkmenu, Mailinglisten am Institut, AKI Rheinland, Verwaltung), 'ZBIW', and 'Aktuelles' (with links for Termine, Semestertermplan WS 06/07, Semestertermplan SS 07, and Aktuell: Bibliothekarische Weiterbildung). The 'Aktuelles' section also mentions 'MALIS Absolvent erhält einen der Hauptpreise des Vereins zur Förderung der Informationswissenschaft (VF)'.

Was soll gesichert werden? (6)

Aspekte eines digitalen Objekts

Inhalt: Information in Schrift, (bewegten) Bildern, Ton, ...

Struktur: Aufteilung und Abfolge der Daten (z.B. DTD)

Layout: Visualisierung des Inhalts + der Struktur (z.B. Stylesheets)

Metadaten: Objekteigenschaften + deren Veränderungen (z.B. DC)

Orientiert an einer Folie von S. Dobratz aus Neuroth 29.11.2005

Wer soll die LZA übernehmen? (1)

↪ Prinzipiell kann jede Organisation diese Aufgabe übernehmen

↪ **Anforderungen gemäß der nestor-AG**
“Vertrauenswürdige Archive“

<http://edoc.hu-berlin.de/series/nestor-materialien/2006-8/PDF/8.pdf>

1. Organisatorischer Rahmen

Zielentsprechende Verfügbarkeit von Ressourcen wie Personal, Finanzen, rechtliche und methodische Absicherung der LZA

2. Umgang mit den Objekten und ihren Metadaten

Integrität, Authentizität, Verfügbarkeit, Vertraulichkeit

3. Infrastruktur und Sicherheit

Wer soll die LZA übernehmen? (2)

↪ **Staatlich finanzierte Einrichtungen:**

- Archive (Bundes- und Landesebene)
- Museen
- Bibliotheken: Bundesebene = DNB; Länderebene z.B. Rheinische LB Koblenz; Württbg. LB Stuttgart; Bayr. Staatsbibl. München; Fachebene z.B. TIB, SSG-Bibliotheken

↪ **Privatrechtlich finanzierte Einrichtungen:**

- Internet Archive
- ?

↪ **ABER:**

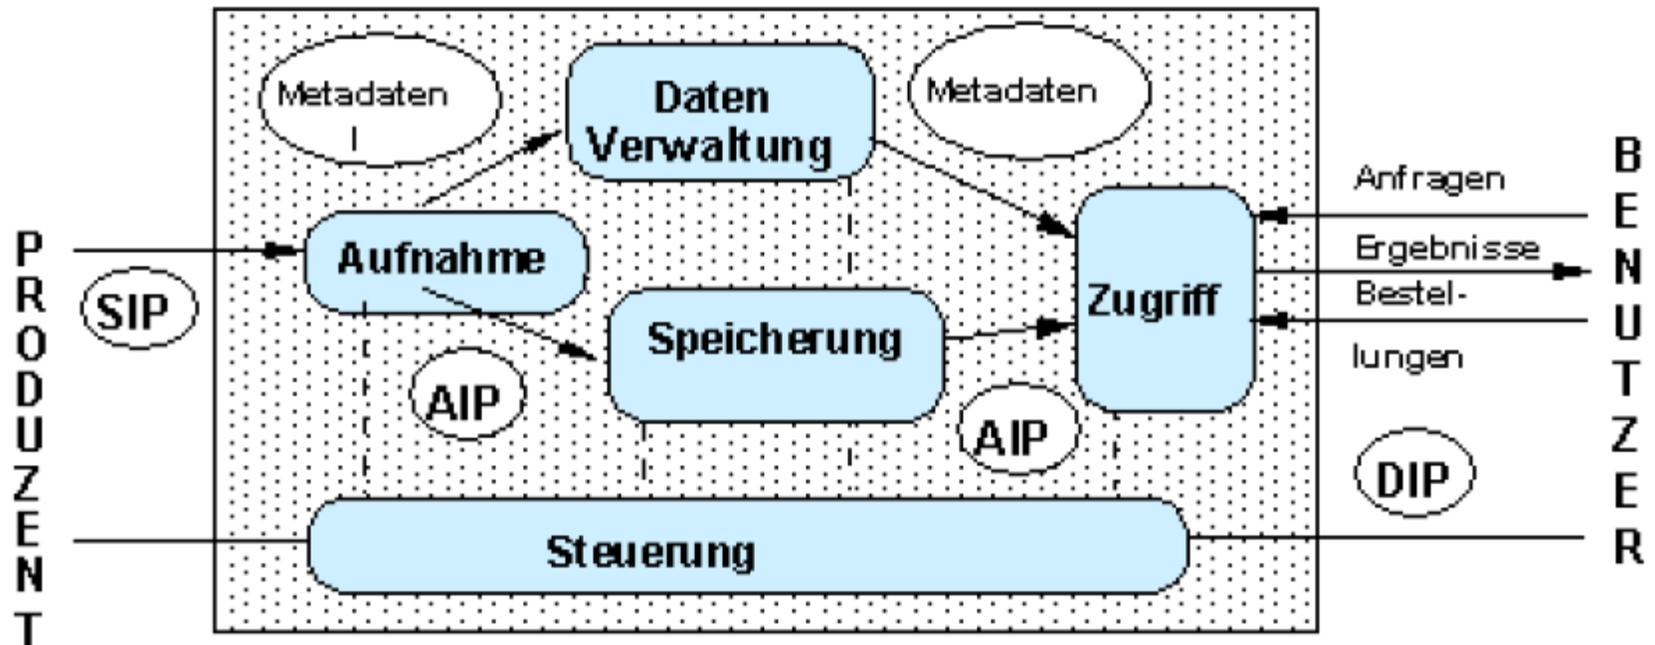
Einzelne Einrichtungen sind technisch und finanziell mit Realisierung überfordert;
die kooperative Entwicklung und Umsetzung der Methoden zur Erschließung und Archivierung bleibt Zielsetzung

Wie soll gesichert werden?

- ↪ Eigentliches Ziel der Archivierung:
“**intellectual preservation**” (Graham)
- ↪ Kopieren und manipulieren sind im digitalen Kontext extrem einfach und auf Nachfolgeversionen übertragbar
- ↪ **Authentifizierung der Originalversion** durch die Urheber unter Einbeziehung von Quelle, Erstellungstermin und Inhalt
- ↪ Diverse **Sicherungsverfahren** in Erprobung:
 - Kryptographie – problematisch wg. Zugang
 - Hashing – mathematisch Codierung
 - Hashing + Zeitstempel
 - verborgener Code z.B. Wasserzeichen

Problem: Sicherungsverfahren kollidieren z.T. mit den technischen Archivierungsverfahren

OAIS: Modell für LZA + LZV



Open Archive Information System (OAIS)

Auch interaktiv als javascript über die Nedlib-Homepage unter <http://nedlib.kb.nl/> =>results => Functional Process Model

Techniken und Strategien der LZA (1)

↪ **Auffrischung der Datenträger (“digital refreshing”):**
regelmäßiges Umkopieren der Daten eines Datenträgers auf einen Neuen gleichen Typs oder einen Datenträger mit gleichem Speicherverfahren

↪ **Problem:**
LZA ist so nicht möglich; grundsätzliche Probleme der Archivierung (Verfügbarkeit von HW + SW) bleiben erhalten; eher ein Verfahren der Datenerhaltung in Vorbereitung auf LZA

Techniken und Strategien der LZA (2)

↪ **LOCKSS = Lots of Copies Keep Stuff Safe**

Kopien einer Datei werden auf verschiedenen, räumlich getrennten IT-Systemen gespeichert; regelmäßiger Vergleich der Dateien, um mögliche Veränderungen entdecken zu können; Alarm beim Unterschreiten einer Mindestzahl von Kopien

↪ **Vorteil:**

prinzipielle Datensicherung auch in verschiedenen Betriebssystem-Umgebungen

↪ **Problem:**

Anbieter (Verleger) der digitalen Objekte müssen dem Kopierverfahren zustimmen; Funktionalitätsunterschiede bleiben u.U. unentdeckt

Techniken und Strategien der LZA (3)

↪ **Erhalt der technologischen Umgebung**

(“technisches Museum”):

ursprüngliche Hard- und Software-Kombination wird in ihrer Funktion erhalten

↪ **Vorteil:** geringe Gefährdung der Authentizität

↪ **Problem:**

Funktionsfähigkeit von HW + SW ist nicht garantiert;

Reparatur und/oder Ersatz unwahrscheinlich;

Personen mit Bedienungskompetenz nicht fortwährend verfügbar

Techniken und Strategien der LZA (4)

↪ **Encapsulation**

Ein image-file der ursprünglichen HW- und SW-Umgebung + der zu sichernden Anwendung wird angelegt sowie regelmäßig gesichert;
Ablauf ggf. in einem virtuellen Computer (Universal Virtual Machine)

↪ **Vorteil:**
geringe Gefährdung der Authentizität

↪ **Problem:**
Leistungsunterschiede der HW- und Betriebssystem-Umgebungen; Kompatibilität

Techniken und Strategien der LZA (5)

↪ **Emulation**

Nachahmung der ursprünglichen HW-, SW- und Betriebssystem-Umgebung;
Metadaten der Konfiguration werden mit archiviert

↪ **Vorteil:**

Kosten fallen für jeden Konfigurationsverbund nur einmalig, nämlich bei der ersten Emulation in einer neuen HW-, SW- und Betriebssystem-Umgebung an

↪ **Problem:**

Leistungsunterschiede der HW- und Betriebssystem-Umgebungen, Kompatibilität

Techniken und Strategien der LZA (6)

↪ Migration

regelmäßige Übertragung des digitalen Objekts von einer HW- und SW-Umgebung in die technologisch nächstfolgende Umgebung; Metadaten der Konfiguration und des Migrationsschritts werden mit archiviert

↪ Vorteil:

geringere Technologiesprünge; “alte” Funktionsumgebung ist zur Rekonstruktion der Funktionalität noch verfügbar

↪ Problem:

Kosten fallen für jeden Anwendungsfall und jeden Migrationsschritt an; ggf. Funktionsverluste in Zusammenhang mit neuer HW- und SW-Umgebung

Techniken und Strategien der LZA (7)

- ↪ **“Desiccated data” (“gedörrte Daten”)** als **komplementärer Teil eines Sicherungskonzepts** neben der Sicherung der Originaldatei sowie eines Rasterbildes der angezeigten Anwendung auch Sicherung einer ASCII-Datei mit XML-Auszeichnungen (oder “plain”)
- ↪ **Vorteil:**
Auffangvariante zur Rekonstruktion zumindest des ursprünglichen Inhalts und/oder des Erscheinungsbildes der Anwendung
- ↪ **Problem:**
US-westlich orientiert; ASCII statt Unicode

Techniken und Strategien der LZA (8)

↪ **Konversion**

Übertragung der digitalen Daten auf analoge, vom Menschen lesbare, alterungsbeständige Speichermedien / Datenträger (Papier; Mikrofilm); im privatwirtschaftlichen Bereich sehr beliebt

↪ **Vorteil:**

sehr kostengünstig

↪ **Problem:**

Verlust des medienspezifischen informationellen Mehrwertes z.B. Hyperlinks; spezifische Navigations- und Suchmöglichkeiten

Was wird / könnte LZA kosten? (1)

↳ **Grundannahme:**

Archivierung und Verwaltung digitaler Objekte ist aufwändiger als bei gedruckten Publikationen

↳ Bislang kaum langfristige Erfahrungswerte, allenfalls sind **Kostenmodelle** verfügbar

z.B.:

Kalkulation im Projekt

JSTOR (The Scholarly Journal Archive):

jährlich 25 000 US \$ / Zeitschrift für Archivierung

Was wird / könnte LZA kosten? (2)

Kostenfaktoren (nach Keller, Alice: Elektronische Zeitschriften, Grundlagen und Perspektiven, Wiesbaden 2005, 255f)

↪ **Einmalige Kosten:**

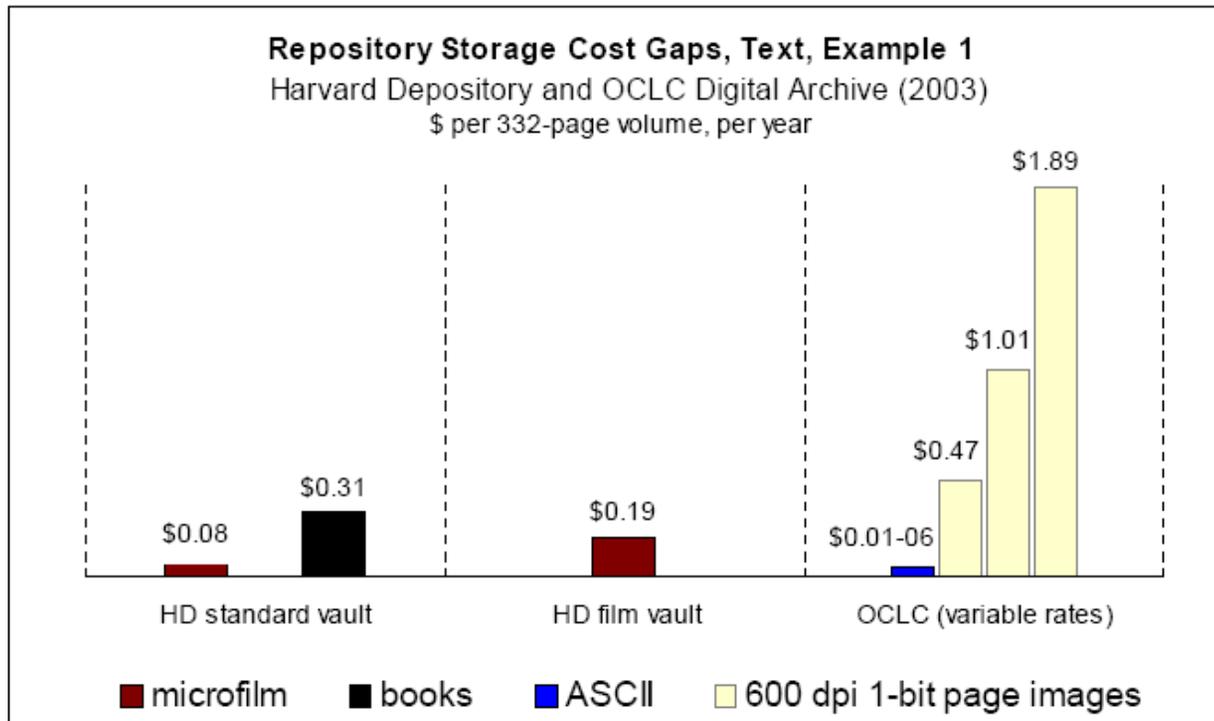
- "Auswahl des zu archivierenden Materials
- Prüfung der Rechtslage
- Festlegung der technischen Lösung ...
- Prüfung der Vollständigkeit der digitalen Objekte
- Herstellung oder Ergänzung von Metadaten"

↪ **Langfristig wiederkehrende Kosten:**

- "Erneuerung von Hard- und Software
- Speicherung der Dateien, regelmäßiges Überspielen oder Migration der Daten in neue Computerumgebungen
- Verwalten des Archivs
- Regelmäßiges Überprüfen der Sammel- und Archivierungspolitik"

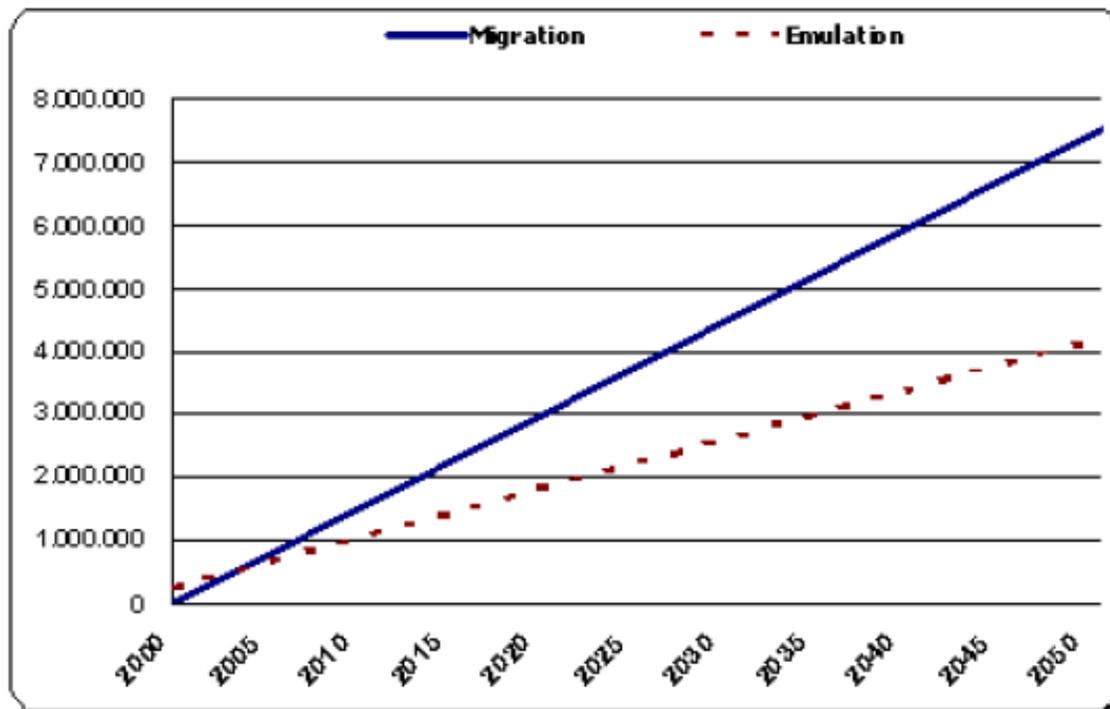
Was wird / könnte LZA kosten? (3)

Chart 1. Relative Costs to Store Text “Masters”:
Microfilm, Print, ASCII, and 600 dpi 1-bit Group 4 Page Image Formats



Aus: **Chapman**, Stephen: Counting the Costs of Digital Preservation: Is Repository Storage Affordable? – In: Journal of Digital information, volume 4 issue 2
Themes: Digital libraries 2003-05-07 (Peer reviewed paper), p. 7

Was wird / könnte LZA kosten? (4)



Aus:
Erik Oltmans / Nanda Kol:
A Comparison Between Migration and Emulation in Terms of Costs. –
In: RLG DigiNews April 15, 2005, Volume 9, Number 2

Figure 2: Costs for migration (blue line) and emulation (red dotted line) for maintaining an archive of 1,000,000 digital objects over a period of 50 years. The initial investments of setting up an emulation tool yields high costs in the first five years. But soon after that, the migration costs are higher than the emulation costs and the difference increases every year. In 50 years, the migration costs are 45% higher than the emulation costs.

Was läuft derzeit bzgl. LZA? (1)

... in Deutschland

↪ **Projekt nestor**
Kompetenznetzwerk Langzeitarchivierung
<http://www.langzeitarchivierung.de>

„Nestor, der Berater der Griechen in Troja, steht als Symbol für die beratende und unterstützende Funktion des Kompetenznetzwerkes im Bereich der Langzeitarchivierung und Langzeitverfügbarkeit. Aufgelöst ergibt das Akronym nestor
"Network of Expertise in long-term STOrage and availability of digital Resources in Germany,, ...“

(www.langzeitarchivierung.de/modules.php?op=modload&name=PagEd&file=index&page_id=10)

Was läuft derzeit bzgl. LZA? (2)

nestor Partner

- Die Deutschen Bibliothek (Federführung)
- Bayerische Staatsbibliothek München
- Computer- und Medienservice / UB der HU zu Berlin
- Institut für Museumsforschung, Staatliche Museen Berlin – Stiftung Preußischer Kulturbesitz
- Niedersächsische SUB Göttingen
- Bundesarchiv (seit 2005)
- Fernuniversität Hagen (seit nestor II - 2006)

 Projektträger: BMBF

 Empfehlungen zum Abschluss von nestor I:

„Memorandum zur Langzeitverfügbarkeit digitaler Informationen in Deutschland“

<http://www.langzeitarchivierung.de/downloads/memo2006.pdf>

 Nestor II seit 2006; weitere Infos über website und Newsletter

Was läuft derzeit bzgl. LZA? (3)

↳ **KOPAL - Kooperativer Aufbau eines Langzeitarchivs Digitaler Informationen**

<http://kopal.langzeitarchivierung.de>

„Ziel des Projektes kopal ist der Aufbau einer technischen und organisatorischen Lösung, um die Langzeitverfügbarkeit elektronischer Publikationen zu sichern. Dabei spielt die transparente Integration in vorhandene Bibliothekssysteme und die Nachnutzbarkeit durch Gedächtnisorganisationen eine wesentliche Rolle.“
(ebd.)

Was läuft derzeit bzgl. LZA? (4)

... in anderen Ländern

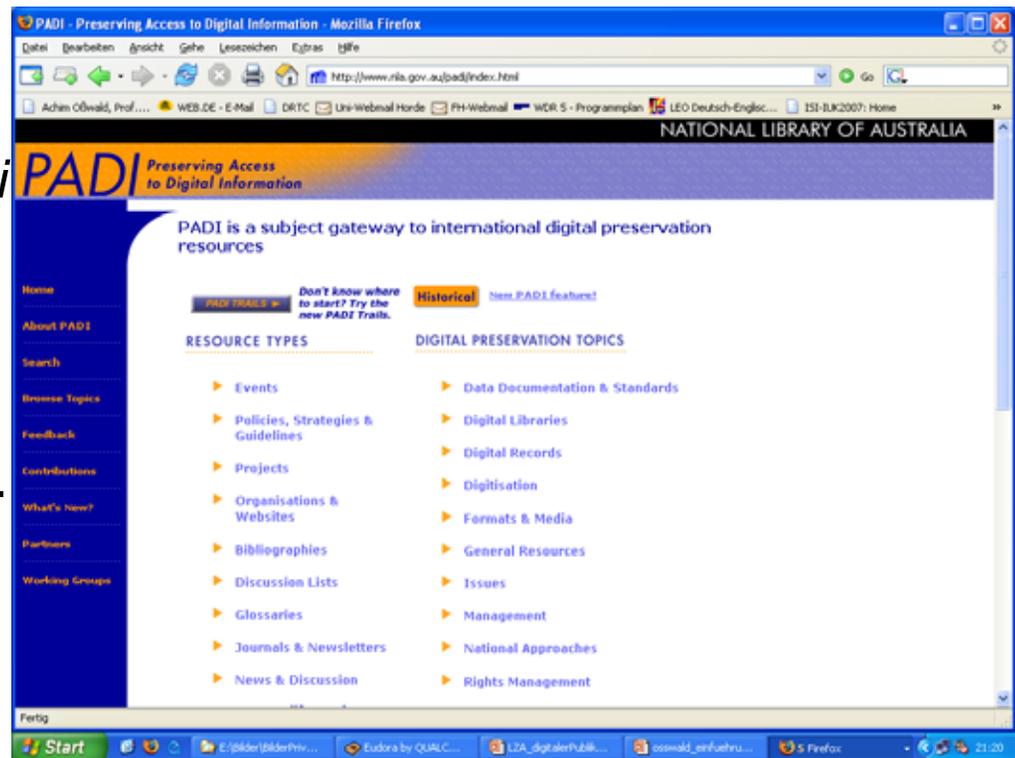
↪ **PADI** Preserving Access to Digital Information

der National Library of Australia

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

↪ Dort gute Übersicht zu den Aktivitäten in einzelnen Ländern

↪ Methodisch & technologisch führend sind u.a. Australien, GB und NL



Zentrale offene Fragen (1)

- ↪ **Infrastruktur des Archivsystems:**
Inwieweit ist das OAIS-Reference Model wirklich langfristig funktionsfähig?
- ↪ **Standards zur Dokumenterstellung u. -kodierung:**
Ziel: Kostensenkung bei Emulation o. Migration durch Nutzung von Auszeichnungssprachen
- ↪ **Metadatenstandards** z.B. auf der Basis des Dublin Core Element Set und **Metadatenmanagement**
- ↪ Anforderungen an **Dokumentformate:**
“Archivierungsfreundlichkeit”

Zentrale offene Fragen (2)

- ↪ **Rechtliche Fragen** des Zugriffs / DRM
- ↪ **Dokumentidentifikation** mittels persistenter Identifikatoren (z.B. DOI; URN)
- ↪ **Transferstandards und -protokolle**
- ↪ **Funktionsverteilung** und **Organisation** zwischen Produzenten und Anbietern digitaler Objekte einerseits und Organisationen der LZA andererseits
- ↪ **Finanzierung** der LZA
- ↪ Formen der **Zusammenarbeit** auf internationaler, nationaler und regionaler Ebene

Weiterführende Quellen & Hinweise

- ↪ ZfBB-Themenhefte aus den Jahren 2001 (3-4) und 2005 (Heft 3-4)
- ↪ Borghoff, Uwe M. et al.: Langzeitarchivierung. Methoden zur Erhaltung digitaler Dokumente, Heidelberg 2003
- ↪ http://deposit.ddb.de/netzpub/web_langzeiterhaltung_ep.htm
- ↪ nestor-Projekt: <http://www.langzeitarchivierung.de>
=> *nestor – materialien*
=> *nestor - Informationsdatenbank*
- ↪ Nedlib-Projekt: <http://nedlib.kb.nl/>
kopal-Projekt: <http://kopal.langzeitarchivierung.de>
- ↪ PADI: <http://www.nla.gov.au/padi>



Gerne beantworte ich Ihre Fragen!

achim.osswald@fh-koeln.de