

Persistent Identifiers für die Wissenschaft vom European Persistent Identifier Consortium (EPIC)

(PID: <http://hdl.handle.net/11858/00-ZZZZ-0000-0001-6D1D-0>)

Tibor Kálmán
tibor [dot] kalman [at] gwdg [dot] de

Workshop “Archivierung sozial- und wirtschafts-
wissenschaftlicher Datenbestände”
(15.09.2011)

Agenda


- Persistent Identifiers (PIDs) für die Forschung
- Konsortium für PIDs
- EPIC PID-Service
 - RESTful Web Service
- Vorteile und Voraussetzungen von PIDs
- Ausblick
- Zusammenfassung

Motivation (1)

- Der Umfang der digitalen Objekte wächst stetig in allen Bereichen der Wissenschaften
- Der Zugang und die Langzeitarchivierung sind wichtige Aufgaben
- Zugriff über einheitliche Schnittstelle zum Speicher- und Repositorysystem
 - Das Interface ist Technologieunabhängig gestaltet
 - und somit von der konkret eingesetzten Infrastruktur abstrahiert
 - Mit Hilfe von HTTP, WebDAV
 - Das ermöglicht, dass auf die gespeicherten digitalen Objekte auch mit gängigen Tools zugegriffen werden kann (Web- und Dateisystem-browsern)
 - Ein Austausch zu grundlegenden Speichertechnologie ist "jederzeit" möglich

Einheitliche Schnittstellen zu digitalen Objekten

- Zugriff zu Forschungsdaten: über einheitliche Schnittstelle




Motivation (2)

- Die Menge der gespeicherten Objekte wächst, wie sollen sie identifiziert werden?
 - Oft wird ein URI dabei benutzt
- Uniform Resource Identifier (URI): die Adresse unter der ein digitales Objekt abgelegt wird
 - Die Adresse ist oft nicht persistent (wird oft nicht dauerhaft erhalten- etwa wegen Datenmigration, usw.)
 - nach jeder Änderung ist das digitale Objekt unter einer neuen Adresse erreichbar
 - Die URI enthält physikalische Pfade und semantische Inhalte


Es ist nicht möglich, die digitalen Objekte langlebig mit URIs zu referenzieren!

Referenzierung mit der physikalischen Adresse

- nach jeder Änderung ist das digitale Objekt unter einer neuen Adresse erreichbar



Referenzierung durch Persistent Identifier



Persistent Identifier (PID)


- Wissenschaftliche Institute brauchen eine Strategie für die Langzeitarchivierung und den dauerhaften und beständigen Zugriff auf Forschungsdaten.
- **P**ersistent **I**dentifier (PID)
 - Digitale Objekte sind in Repositories registriert
 - Mit einem unveränderlichen Identifikator (PID)
 - Die unterliegenden Systeme können sich ändern ("living organisms")
 - Eine Migration ist auf verschiedenen Ebenen möglich (Änderung von Hardware, Software, Format, usw.)
- Für die Vergabe, Verwaltung und Auflösung von PIDs:
 - Ein allgemein vereinbarter Prozess ist nötig
 - Handle System, ähnlich Domain Name System (DNS)

Es ist möglich, die digitalen Objekte langlebig mit PIDs zu zitieren!

Langfristige Referenzierung

Eindeutige und dauerhafte Erreichbarkeit von digitalen Objekten:

- Objekte erhalten PIDs
- PID: Eine neue Schicht in der Infrastruktur
- Resolve:
 - Muss administriert werden
 - Muss mit hoher Verfügbarkeit laufen
 - Muss mit den Archives zusammenarbeiten können
 - Und das alles auch langfristig



Agenda

- Persistent Identifiers (PIDs) für die Forschung
- Konsortium für PIDs
- EPIC PID-Service
 - RESTful Web Service
- Vorteile und Voraussetzungen von PIDs
- Ausblick
- Zusammenfassung

PID Service für die Wissenschaft

- Nicht alle Institute können oder wollen einen eigenen Dienst zum Verwalten von PIDs betreiben
- Seit 2009 läuft bei der GWDG (für die Max Planck Gesellschaft) ein PID-service
- Basierend auf dem Handle System (<http://www.handle.net/>)
- Ziel: Erzeugen, Verwalten und Auflösen von Identifikatoren von Forschungsdaten (wissenschaftlichen digitalen Objekten)
- Zusammen mit anderen europäischen Partnern wurde ein Konsortium gebildet, um diese Dienstleistungen europäischen Wissenschaftlern zur Verfügung zu stellen
 - European Persistent Identifier Consortium (EPIC)
 - <http://www.pidconsortium.eu/>

Das EPIC Konsortium

- European Persistent Identifier Consortium (EPIC)
- Mit dem Ziel einen **P**ersistent **I**dentifier (PID) Service anzubieten
- Der Fokus ist die europäische Forschungslandschaft und kulturelle Institutionen
- EPIC besteht aus drei europäischen Rechenzentren:
 - Wird durch nationale Programme finanziert
 - Mit langer Erfahrung mit dem Betrieb von stabilen und hochverfügbaren Diensten
 - Mit der Möglichkeit SLAs anzubieten
 - Sind in diversen eScience Projekten beteiligt

Partner in EPIC: GWDG (1)

- Gesellschaft für wissenschaftliche Datenverarbeitung mbH Göttingen (GWDG)
- eine gemeinsame Einrichtung der Georg-August-Universität Göttingen und der Max-Planck-Gesellschaft
- Sie erfüllt die Funktion eines Rechen- und IT-Kompetenzzentrums für die Max-Planck-Gesellschaft und des Hochschulrechenzentrums für die Universität Göttingen.
- GWDG wurde 1970 als gemeinnützige GmbH gegründet
- Der Standort liegt in Göttingen
- 25,000 Benutzer
- 1000 wissenschaftliche HPC-Benutzer
- Etwa 80 Mitarbeiter



Partner in EPIC: GWDG (2)

- Aufgabenbereiche der GWDG u.a.:
 - High performance computing
 - High performance networking
 - Infrastructure services
 - IT consulting
- Partner in diversen eScience & Grid Projekten:
 - DARIAH-DE, CLARIN-D, D-Grid DGSII
- Projektkoordination in folgenden Forschungsprojekten:
 - Instant-Grid, OptiNum-Grid
- Weitere Projekte: GoeGrid, Kopal, usw.



Partner in EPIC: SARA

- Stichting Academisch Rekencentrum Amsterdam (SARA)
- SARA unterstützt Forscher in den Niederlanden und arbeitet eng mit akademischen Partnern zusammen sowie öffentlichen und wirtschaftlichen Einrichtungen
- SARA bietet – seit 40 Jahren – an:
 - High performance computing
 - Visualisierung
 - High performance networking
 - Infrastructure services
- Standort in Amsterdam



Partner in EPIC: CSC



- IT Center for Science Ltd (CSC)
- CSC bietet als Partner der finnischen Forschungsinfrastruktur hochqualifizierte IT Dienstleistungen
- Bietet Finnlands leistungsfähigste Supercomputer
- CSC wurde 1970 gegründet und wird seit 1993 als gemeinnütziges Unternehmen fortgeführt
- Standort in Espoo, nahe zum Otanie Campus der Helsinki University
- Über 180 Mitarbeiter
- 3000 Forscher nutzen die CSC's Rechenangebote

EPIC Nutzergruppen




- MPG, Max Planck Society
- CLARIN, Common Language Resources and Technology Infrastructure
- DARIAH-DE, Digital Research Infrastructure for the Arts and Humanities
- SUB, Niedersächsische Staats- und Universitätsbibliothek Göttingen
- DKRZ, German Climate Computing Center




Agenda

- Persistent Identifiers (PIDs) für die Forschung
- Konsortium für PIDs
- EPIC PID-Service
 - RESTful Web Service
- Vorteile und Voraussetzungen von PIDs
- Ausblick
- Zusammenfassung

Auflösung (Resolution) von PIDs in EPIC



Verwaltung von PIDs in EPIC



Zuverlässigkeit und Nachhaltigkeit des EPIC PID-Services

- Basiert auf dem Handle System
 - Das Handle-System wird von vielen Organisationen benutzt
 - Die grundlegende Technologie des Handle-Systems existiert seit ca. 20 Jahren
 - Es ist ein verteiltes System (Global und Lokal Server)
 - Sehr gut skalierbar
- Ein globaler Handle Server für Europa wird bei der GWDG betrieben
 - Verfügbarkeit
 - Sicherheit und Unabhängigkeit
- Die Partner-Organisationen in EPIC haben langfristige und nachhaltige Planung und Finanzierung

Die Syntax von Handles (GWDG) (1)

- Zum Auflösen des PIDs benötigt man einen definierten Prozess
 - Weltweites Handle (PID) Framework
- GWDG benutzt den prefix 11858
 - <http://handle.gwdg.de:8000/>
 - Dieser ist in das generelle und weltweite Handle Framework integriert..
 - This is integrated into the general and worldwide handle framework
 - Der globale Handle Service deligiert alle Anfragen zur Auflösung mit dem prefix 11858 an die GWDG weiter

Die Syntax von Handle (GWDG) (2)

Der Handle dieser Präsentation:

- <http://hdl.handle.net/11858/00-ZZZZ-0000-0001-6D1D-0>
- **RESOLVER / prefix / fg – inst – num1-num2-num3 - c**
- Die Bedeutung der Felder:

- **prefix** is the handle prefix,
 - which is fixed to 11858
- **fg** is a uppercase hexadecimal flag,
 - can be used for special purposes,
 - to be defined later(derived handles etc)
- **inst** is a field with alphanumerical uppercase digits
 - describes the institution responsible for registration of the handle,
- **num1-num2-num3** 12 digits
 - coded in uppercase hexadecimal digits with delimiters
- **c** is a checksum
 - to ensure plausibility of the handle string.

Schnittstellen zum Erzeugen, Verwalten und Auflösen von PIDs in EPIC

- Aufgabe: Erzeugen, Verwalten und Auflösen von PIDs
- Schnittstellen:
 - (Native) Handle Interface
 - [RFC3652] Handle System Protocol
 - [RFC3651] Handle System Namespace and Service Definition
 - Webinterface:
 - REST-basiertes Web Services Interface
 - <http://handle.gwdg.de:8080/pidservice/>

Das Webinterface vom PID-Service

- Zugriffsbeschränkungen (Access control):
 - Suche und Auflösung: freier Zugriff
 - Erzeugung neuer PIDs und Verwaltung von existierenden PIDs: Authentifizierung und Authorisierung
- Basic auth: Benutzername + Passwort (genau wie in Web)
- RESTful Web Services:
 - Representational State Transfer (REST), Dissertation von Roy Fielding
 - REST ist eine Softwarearchitektur, welche das Internet als Plattform für verteiltes Rechnen nutzt
- Ein REST-Beispiel: Ist Dokument-Austausch durch Email schon REST?

REST Design Principles

Grundlegende Designprinzipien von REST:

- 1) Nutze standard HTTP Methoden
 - Create (**POST**), Read (**GET**), Update (**PUT POST**), Delete (~~**DELETE**~~)
- 2) Sei zustandslos (stateless)
 - Abfragen enthalten alle Daten
- 3) URIs sollten selbsterklärend sein
 - <http://handle.gwdg.de:8080/pidservice/write/create>
 - <http://handle.gwdg.de:8080/pidservice/write/modify>
 - <http://handle.gwdg.de:8080/pidservice/read/view>
- 4) Klienten wählen das Datenformat
 - XML, JSON, HTML

Agenda

- Persistent Identifiers (PIDs) für die Forschung
- Konsortium für PIDs
- EPIC PID-Service
 - RESTful Web Service
- Vorteile und Voraussetzungen von PIDs
- Ausblick
- Zusammenfassung

Persistenz der Daten vs. Identifikatoren

- Steigendes Datenaufkommen in den Wissenschaften
- Ein Beispiel für einen möglichen wissenschaftlichen Arbeitsablauf:
 - Wissenschaftler erzeugen eine große Anzahl von experimentellen Daten
 - Die Wissenschaftler kennen die Bedeutung der Daten erstmal nicht
 - Die langfristige Referenzierbarkeit ist dabei wichtig: ein langfristiger Identifikator wird für die Referenzierung gebraucht
 - Metadaten können extrahiert und mitreferenziert werden
 - Die Daten selbst können repliziert oder zu einem anderen Standort bewegt werden
- Ein PID ist persistent!
 - Seine Gültigkeit kann geprüft und eingegrenzt werden
 - z.B. wenn das Objekt nie referenziert wird (automatisch prüfbar)

Die Referenzen (Identifikatoren) und ihre Metadaten können länger existieren als die wissenschaftlichen Daten selbst

Vorteile von PIDs

Vorteile von PIDs:

- Die Referenzen können länger existieren als die Daten selbst
- Die Referenzen können Daten und ihre Metadaten verbinden
- Einfache Zitierbarkeit für kollaborative Arbeit
- Einfache Referenzierung für Archive oder Replikation

Voraussetzungen von PIDs

Voraussetzungen zur Nutzung von PIDs:

- Die PIDs sollen ein Teil des wissenschaftlichen Arbeitsablauf sein
- Granularität soll eine wissenschaftliche (und nicht technische) Frage sein
 - Kosteneffizienz ist wichtig, denn viele PIDs können ohne großen finanziellen Aufwand genutzt werden
- Der Preis soll von der Wissenschaft bestimmt werden
- Verfügbarkeit
- Sicherheit (insbesondere die Auflösung)

Agenda

- Persistent Identifiers (PIDs) für die Forschung
- Konsortium für PIDs
- EPIC PID-Service
 - RESTful Web Service
- Vorteile und Voraussetzungen von PIDs
- **Ausblick**
- Zusammenfassung

Ausblick

- Die EPIC API v1 ist sehr einfach (tut was sie tun soll)
- Neu Funktionen sind gewünscht:
 - Neue Anforderungen der Communities, z.B.:
 - 1 PID mit mehreren URLs
 - 1 create request für mehrere PIDs
 - und weitere... :)
 - Auch das Handle-System wurde weiterentwickelt (v7.0)
- Die EPIC API v2 soll bald kommen :)
 - Die EPIC API v2 wird eine generische API sein
 - Wird vom EPIC Konsortium gestaltet, entwickelt und implementiert
- “Politische Unabhängigkeit”: Patent-Besitzer, Domain-Besitzer: ITU
- Erweiterung vom EPIC Konsortium

Agenda

- Persistent Identifiers (PIDs) für die Forschung
- Konsortium für PIDs
- EPIC PID-Service
 - RESTful Web Service
- Vorteile und Voraussetzungen von PIDs
- Ausblick
- Zusammenfassung

Zusammenfassung

- PIDs werden in der Forschung benötigt und sollten Teil der Strategie zur Langzeitarchivierung und den nachhaltigen Zugriff auf Forschungsdaten werden.
- Die PIDs sollen ein Teil des wissenschaftlichen Arbeitsablauf sein
- EPIC ist ein Konsortium, welches einen PID-Service der europäischen wissenschaftlichen Community zur Verfügung stellt
- Der EPIC PID-Service:
 - EPIC API v1 ist eine Schnittstelle mit einem RESTful Web Service
 - Python, Java, Shell Beispiele sind verfügbar
 - EPIC API v2 wird eine mehr generische API sein

Danke!

- EPIC: <http://www.pidconsortium.eu/>
- PID-Service: <http://handle.gwdg.de:8080/pidservice/>
- Ein technischerer Vortrag zum EPIC PID-Service:
<http://hdl.handle.net/11858/00-ZZZZ-0000-0001-6D1D-0>