


NaLiDa: Nachhaltigkeit linguistischer Daten

Erhard Hinrichs, Thorsten Trippel, Claus Zinn
Seminar für Sprachwissenschaft
Universität Tübingen

3. DINI/nestor-Workshop "Langzeitarchivierung von Forschungsdaten" 19. Juni 2015, ZIB in Berlin



ZENTRUM FÜR DATENVERARBEITUNG
(ZDV)

UNIVERSITÄTSBIBLIOTHEK

Leitlinien der DFG

1.3.3 Forschungsdaten, DFG Vordruck 60.100 - 09/14

*... Wenn im Rahmen des geplanten Sonderforschungsbereichs systematisch (Mess-)Daten generiert werden, die für die Nachnutzung geeignet sind, legen Sie bitte dar, welche Maßnahmen ergriffen wurden bzw. während der Laufzeit des Projektes ergriffen werden sollen, um die **Daten nachhaltig zu sichern** und ggf. **für eine erneute Nutzung bereit zu stellen**. Bitte berücksichtigen Sie dabei auch – sofern vorhanden – die **existierenden Standards** und die **Angebote bestehender Datenrepositorien**. Stellen Sie bitte auch dar, durch **welche Einrichtungen** (Datenkurator, Rechenzentrum, Bibliothek, etc.) **welche Form von Unterstützung beim Daten- und Informationsmanagement** durch die am Sonderforschungsbereich beteiligten Institutionen geleistet werden soll.“*

Datenmanagement-Pläne werden auch von AHRC, EPSRC, ESRC, NSF, Wellcome Trust etc. erwartet

Projektüberblick

- digitale Archivierung **linguistischer** Forschungsprimärdaten
 - **Sammlung** von wissenschaftlichen Daten im sprachwissenschaftlichen Umfeld
 - Verwendung und Weiterentwicklung eines **Metadatenframeworks** zu ihrer Beschreibung
 - Einpflegen der Daten in ein **Repositoryum**
 - Entwicklung von **Werkzeugen** zur Metadatenverarbeitung und zum Metadaten-basierten Zugriff
- **Referenzmodell**
 - technologischen Infrastruktur
 - standardisierte und qualitätssichernde Arbeitsabläufe
 - Integration in existierende universitäre Infrastruktur

Projektüberblick

- individuelle Beratungs- und Servicedienstleistungen
- Aufbau eines nationalen und internationalen Verbunds



Funding 3+2 Jahre, 2. Phase ab 2015

The project for Sustainability of Linguistic Data (NaLiDa) is funded by the **German Research Foundation (DFG)** in the program for **Scientific Library Services and Information Systems (LIS)**.



Sprachwissenschaftliche Forschungsprimärdaten

- Korpora (Sammlungen von Texten und Sprachaufnahmen)
 - TüBa-D/Z Baumbank (angereichert mit syntaktischen Struktur)
- Lexika (z.B. GermaNet: deutsche Version von WordNet)
- Grammatiken (z.B. HPSG Grammatik für Deutsch)
- Experimentaldaten (z.B. Eyetracking Daten zur Sprachperzeption)
- Software (z.B. Webservices zur Analyse von Sprachdaten, Statistiksoftware)
- Bilddaten zur Verarbeitung von Sprache im Gehirn
(Magnetoenzephalographie & funktionelle Magnetresonanztomographie)

760.000 erfasste Ressourcen, davon über 60TSD deutsch-sprachige

Datenformate

- unterschiedlichste Daten- und Informationsobjekte in Form von Text, Bild, Audio und Video
- Primärdaten häufig mithilfe diverser Software mit Zusatzinformationen angereichert
- Vielzahl von Datenformaten & Softwareprogrammen, die nur in definierten technischen Kontexten funktionieren
- Multimediaformate WAV, MP3 und MPEG2
- Formate R, SPSS, Excel, Praat und Text (OnEXP) für Experimentaldaten
- die textbasierten Formate PDF, Word, und XML
- die Dateiarchivformate Zip, GZip, Tar, und Rar


Datenherstellern wird empfohlen, proprietäre Formate (z.B. Word, SPSS) in nicht-prorietäre Formate (z.B. ODF, R) zu transformieren.

Beschreibung der Forschungsdaten mit Metadaten

- **Beschreibung mit fachwissenschaftlichen Vokabular**

- Hierarchie von Datentypen

- Jeder Typ hat eigenes Schema



- Beschreibungsmittel gehören in die Fachwissenschaft, müssen von Wissenschaftlern verantwortet werden

- Beschreibungsmittel aus Bibliothekswissenschaft nicht ausreichend

- Funktion der Beschreibung: Identifikation (Auffinden) und Bewertung (Nutzbarkeit zur Nachnutzung)

Metadatenframework

- *Component Metadata Infrastructure*” (CMDI, ISO 24622-1, <http://www.clarin.eu/cmdi>)
- **modular**
 - elementare Bausteine = standardisierte *Datenkategorien*, entnommen aus Datenkategorie-Registaturen (etwa ISOCat, siehe <http://www.isocat.org>, ISO 12620)
 - komplexere Bausteine = Komponenten, entnommen aus der Component Registry (<http://catalog.clarin.eu/ds/ComponentRegistry/>)
- **flexibel**: Komponenten können an Bedürfnisse angepasst werden
 - Adaptionen werden wiederum in Component Registry verwaltet

Suche Forschungsdaten

- Suche über aggregierte Datenbestände nicht trivial
- Benutzer kennt Metadatenschemata nicht
- Facetten-basierte Suche erlaubt Nutzers Exploration des Suchraums
- 6-8 Facetten, teils bedingt

The screenshot shows the Nalida Faceted Browser interface. The browser title is "Nalida Faceted Browser". The main heading is "Zentrum für Nachhaltigkeit linguistischer Daten: Suche nach Ressourcen". Below the heading is a logo for Nalida and the text "Ein Faceted Browser mit bedingten und unbedingten Facetten".

The interface displays six facets of search results:

- Facet: modality (7)**

modality	Occurrences
Other	4
Pointing gestures	440
Signs	77
Speech	9959
Unspecified	11
verbal and non-verbal interaction	117
Writing	93
- Facet: language (90)**

language	Occurrences
Albanian	1
Alttibetisch	1
Amerindian	1
Bahasa Indonesia	1
Bosnian	3
Brazilian Portuguese	1
British Sign Language	23
Bulgarian	1
- Facet: resourceclass (6)**

resourceclass	Occurrences
corpus	2842
general corpus	1
LexicalResource	1
Lexicon	2
Tool	266
WrittenCorpus	19
- Facet: country (6)**


country	Occurrences
France	93
Germany	10149
Netherlands	21
Papua New Guinea	1
Sweden	8
United Kingdom	21
- Facet: organisation (8)**

organisation	Occurrences
Magdeburg-Stendal University of Applied Sciences	10
Max Planck Institute for Psycholinguistics	2021
Radboud University Nijmegen	67
SFB 441	33
SFB 632	28
Universität Tübingen	2
University of Leipzig	162
University of Stuttgart	2
- Facet: origin (12)**

origin	Occurrences
bas	7417
bbaw	1
Bildungsforschung	2672
echo_data	170
Humboldt	3
Leipzig	162
sfb441	33
sfb538	1
sfb632	27

Metadatensatz — Ansicht

- Abbildung zwischen Beschreibungsschema auf Karteireitern
- Zusammenfassung von Datenkategorien möglich



The screenshot shows a web browser window with the title 'Resource: GermaNet'. The browser's address bar and tabs are visible at the top. Below the title, there is a navigation bar with several tabs: 'General Info', 'Creation', 'Documentation', 'Access', 'Lexicon Content', 'Size Info', 'Text-Technical', and 'About...'. The 'General Info' tab is selected. The main content area displays the following metadata:

General Information

Resource Name: GermaNet
Resource Title: GermaNet: Ein lexikalisch-semantisches Wortnetz
Resource Class: Lexicon
Version: 5.3
Publication Date: 1997-01-01
Last Update: 2010-04-01
Time Coverage: synchron
Legal Owner: Universität Tübingen
Location: Seminar für Sprachwissenschaft, Wilhelmstr. 19, D-72074 Tübingen, Deutschland, Europe

Below the location information, there is a descriptive paragraph: 'GermaNet ist ein lexikalisch-semantisches Wortnetz, das Nomina, Verben und Adjektive des Deutschen beschreibt. Dabei werden lexikalische Einheiten, die ...'.

[Link zu Faceted Browser](#)

Archivierung in Repository

- Verwendung von Fedora Commons (OAIS-konform)
- nur Primärdaten mit CMDI Auszeichnung
- alle Daten über persistente Identifikatoren erreichbar
- mit OAI-PMH Schnittstelle zum “Harvesting” der Metadaten
- Derzeit ca. 50GB, 1315 Datenströme, 115 digitale Objekte

Archivierungsbedingungen

- Entscheidung für Archivierung fallbasiert
 - für die Erhebung der Forschungsdaten wurden öffentliche Fördermittel eingeworben
 - die Forschungsdaten sollen im Rahmen einer Publikation in einer wissenschaftlichen Zeitschrift zitiert werden
 - es handelt sich um eine in der Sprachwissenschaft anerkannte und oft benutzte Ressource
- Entscheidung für Archivierungsdauer ebenso kritisch

Rechtliche Fragen der Archivierung

Hinterlegungs-Vertrag

- Lizenz an Repository zur Übertragung, Speicherung, Verbreitung
- (urheber-)rechtlichen Fragen bzgl. Verbreitung und Nachnutzung
- Pflichten des Repositorium-Betreibers
 - nachhaltige Archivierung, inklusive Formatkonvertierung
 - Zugang
 - Unterhalt
 - zeitliche Vorgaben
- Personenbezogene Daten zunehmend problematisch

Verstetigung

Entwicklung einer nachhaltigen technologischen, institutionellen und personellen Infrastruktur

- Schaffung neuer Strukturen und Modelle der Zusammenarbeit von
 - **Wissenschaft:** Beschreibung von Forschungsprimärdaten mit fachwissenschaftlichen Vokabular
 - **zentralen Infrastruktur-Einrichtungen:** langfristige Vorhaltung, Verbreitung und Sicherung
- Entwicklung von **Arbeitsteilung, Schnittstellen,** Überprüfung auf ihre Tragfähigkeit
- Aufbau einer **prototypischen IT-Infrastruktur** für den nachhaltigen Betrieb von NaLiDa
 - Aspekte der Datensicherung (z.B. Betrieb an getrennten Standorten)
 - tragfähiges Betriebskonzept
 - Gewährung des notwendigen rechtlichen Rahmens (unter Berücksichtigung von §9 LDSG)

Verstetigung

- **NaLida als Vermittler** zwischen Fachwissenschaft und nachhaltigem Forschungsdatenmanagement
- Zusammenarbeit mit zentralen Infrastruktureinrichtungen, dem Informations-, Kommunikations- und Medienzentrum der Universität Tübingen (IKM)
 - Tübinger Universitätsbibliothek
 - stellt Handle-IDs bereit
 - macht Metadatenätze über UB-weite Suche auffindbar (EAD Untermenge, **geplant**)
 - Volltextsuche über CMDI noch nicht verfügbar, reichhaltige Information nur bei Anzeige des Metadatenatzes
 - Zentrum für Datenverarbeitung (ZDV)
 - hostet Repositoryum
 - macht back-ups
 - Authentifizierung (Shibboleth)

Aufbau von Verbänden

Zusammenarbeit mit **Clarin-D** und **Clarin ERIC**


- europäische Infrastruktur für Sozial- und Geisteswissenschaften
- gemeinsame Verwendung des Metadaten-Frameworks CMDI
- gegenseitiges “Harvesting” zum Metadaten-Austausch
- gemeinsame Entwicklung von Technologie & Werkzeugen
 - Metadateneditoren, Registries, VLO Faceted Browsing
 - Sprachwissenschaftliche Tools.
- personelle und institutionelle Verflechtungen hilfreich, um nationalen und europäischen Kontext in den lokalen, institutionellen Kontext einzubinden

SfS Tübingen im Clarin-D Verbund



- **Tübingen (Koord.)** – (Computerlinguistik (CL)): Annotierte Korpora, ling. Wissenskomponenten, Web-Services
- Leipzig – (Informatik): Web-Services und Textkorpora
- BBAW Berlin – (Zentrum Sprache): Deutsche Sprache: Wörterbücher, (hist.) Textkorpora
- Stuttgart – (CL): Web-Services und Textkorpora
- IDS Mannheim – (Germanistik/CL): Deutsche Sprache, Textkorpora
- LMU München – (BAS/CL) Deutsche Sprachdaten, multilinguale Daten, Web Services
- MPI Nijmegen – (Psycholinguistik): Bedrohte Sprachen, multimodale Sprachressourcen
- Hamburg – (CL): Multilinguale Sprachdaten, Transkriptionswerkzeuge
- Saarland – (CL): Multilinguale Textkorpora und Web-Services

SfS Tübingen im Clarin-D Verbund



Vertrauenswürdiger Langzeitarchiv

The Data Seal of Approval ensures that in the future, research data can still be processed in a high-quality and reliable manner, without this entailing new thresholds, regulations or high costs. The Data Seal of Approval and its quality guidelines may be of interest to research institutions, organizations that archive data and to users of that data.

Anforderungskatalog umfasst

- technische und
- formale Anforderungen

für ein nachhaltiges Datenrepositorium

- 16 Requirements, see https://assessment.datasealofapproval.org/media/files/DSA_booklets/DSA-booklet_1_June2010_1.pdf



Data Seal of Approval

The *data producer*

1. deposits the research data in a data repository with sufficient information for others to assess the scientific and scholarly quality of the research data and compliance with disciplinary and ethical norms
2. provides the research data in formats recommended by the data repository
3. provides the research data together with the metadata requested by the data repository

Data Seal of Approval

The *data repository*

4. *has an explicit mission in the area of digital archiving and promulgates it*
5. uses due diligence to ensure compliance with legal regulations and contracts
6. applies documented processes and procedures for managing data storage
7. has a plan for long-term preservation of its digital assets
8. Archiving takes place according to explicit workflows across the data life cycle
9. assumes responsibility from the data producers for access to and availability of the digital objects
10. enables the users to utilize the research data and refer to them
11. ensures the integrity of the digital objects and the metadata
12. ensures the authenticity of the digital objects and the metadata

Data Seal of Approval

The technical infrastructure

13. explicitly supports the tasks and functions described in internationally accepted archival standards like OAIS

The *data consumer*

14. must comply with access regulations set by the data repository
15. conforms to and agrees with any codes of conduct that are generally accepted in higher education and research for the exchange and proper use of knowledge and information
16. respects the applicable licences of the data repository regarding the use of the research data

Vielen Dank

für ihre Aufmerksamkeit