

Metadaten für multimodale Corpora

Bernhard Jackl

jackl@phonetik.uni-muenchen.de

09. April 2015

We kill people based on metadata.

– General Michael Hayden,
former director of the NSA and the CIA

<http://www.nybooks.com/blogs/nyrblog/2014/may/10/we-kill-people-based-metadata/>

Arten von Daten

- Primärdaten (Rohdaten)
 - Audiodaten
 - Video
 - Bilder
 - Time-Series (z. B. Motion Capture Daten)
- Sekundärdaten
 - ⇒ Annotationen
- Metadaten

Metadaten

Wozu Metadaten?

- Corporaerzeugung zeitaufwendig & teuer
- Corpora ohne Metadaten schwer auffindbar
- „Passt dieses Corpus auf meine Fragestellung?“
- verhindert unnötige „Kopien“ von Corpora
- verhindert Wegwerfcorpora
- Aber: Metadaten allein helfen nicht, wenn nicht öffentlich

Metadaten (Cont.)

Beispiele

- Aufnahmesessions
- Teilnehmer (Actors)
- Primärdaten
- Sekundärdaten
- Corpus
- ...

Metadaten (Cont.)

Beispiele für Sessions

- Session ID (!)
- Aufnahmedatum & -zeit (!)
- Aufnahmeort
- Aufnahmebedingung
- Vorkommende Sprachen
- Genre
- ...

Metadaten (Cont.)

Beispiele für Actors

- Actor ID (!)
- Geburtsdatum (!)
- Geschlecht (!)
- Sprachen (Mutter-, Fremdsprachen, Dialekte)
- Informationen über Eltern
- Sprachstörungen
- Spezielle Attribute
 - Raucher (y/n)
 - Händigkeit (l/r/b)
 - Brille, Bart, Piercing (y/n)
 - Blut-/Atemalkoholkonzentration
 - ...

Metadaten (Cont.)

Beispiele zu Mediendateien

- Formate (MIME-Type) (!)
- Technische Daten (!)
- Länge (Bei Audio & Video)
- Frame Elemente (bei Time Series)
- Auflösung (Bei Video & Bildern)
- Aufnahmehardware/-software (Rechner, Mikrophon, ...)
- ...

Metadaten (Cont.)

Beispiele zu Annotationen

- Formate (plain text, binär)
- Encoding (UTF-8, ASCII, ...)
- Art der Annotation (orthogr., phonet., phonol., ...)
- automatisch/manuell erstellt
- ...

Metadaten (Cont.)

Beispiele für Corpus

- Corpus Titel
- Besitzer
- zugehöriges Projekt
- Entstehungszeitraum
- Ansprechpartner
- Gesamtumfang (GB, Stunden)
- Zugangsbeschränkung (public, academic, restricted, ...)
- Validierung?
- ...

Metadatenformate

Eigene

- Tabellenformat
 - + auch von Menschen gut les- u. editierbar
- XML
 - + erlaubt Verschachtelung
 - + gut maschinenlesbar
 - schlecht menschenlesbar
 - sehr verbose
- rel. Datenbank (PostgreSQL, MySQL, etc.)
 - + leichte Umformung/Export

Metadatenformate (Cont.)

Standards (Auswahl)

- Dublin Core
- OLAC (Open Language Archives Community)
- IMDI (ISLE MetaData Initiative, *veraltet*)
- CMDI (Component MetaData Initiative)

Metadatenformate (Cont.)

Dublin Core

- Dublin Core Metadata Initiative (DCMI)
- ursprünglich 15 *core elements*
 - identifier
 - format
 - type
 - ...
- sehr allgemeine Elemente (für jegliche Medien geeignet)

Metadatenformate (Cont.)

CMDI

- Einführung von Profilen
 - bestehen aus Components (die selbst aus weiteren C. und atomaren Elements bestehen)
 - registriert in der [ComponentRegistry](#)
 - Begriffe definiert in [ISOcat](#)
- wenn abwärtskompatibel können Profile erweitert werden
- Profile des BAS:
 - [media-corpus-profile \(v1.1\)](#)
 - [media-session-profile \(v1.2\)](#)
- Problem: Vielzahl an Profilen, Gefahr der Zersplitterung

CMDI-Erstellung

- Einfaches Corpus
 - wenige Sessions oder Actors
 - wenige Mediendateien
 - ⇒ CMDI mithilfe eines Editors erstellen
- Großes Corpus
 - große Menge an Sessions, Actors, Mediendateien ...
 - Metadaten bereits in einem strukturierten Format
 - ⇒ Batch-CMDI-Erstellung

CMDI-Erstellung (Cont.)

Editoren

- COMEDI (<http://clarino.uib.no/comedi>)
 - WebApp
 - benötigt Login über z. B. CLARIN IdP
 - noch in der Testphase
 - zum betrachten und editieren einzelner Dateien
- Arbil (<https://tla.mpi.nl/tools/tla-tools/arbil/>)
 - Java webstart oder Install für Windows/Mac/Linux
 - Viewer & Editor für Hierarchien
 - lokal & remote Daten

CMDI-Erstellung (Cont.)

COALA

- Konvertierung aus Zwischenformat nach CMDI
- für media-session-profile & media-corpus-profile
- nur für Corpora mit Multimediadaten, nicht Zeitungsartikel, o. ä.

CMDI-Erstellung (Cont.)

COALA – Art des Zwischenformates

- 5 Tabellen
 - ① Actors
 - ② Sessions
 - ③ Bundles (einzelne Aufnahme, bei uns: ein Prompt)
 - ④ MediaFiles (Signaldateien, Teil eines Bundles)
 - ⑤ WrittenResources (Annotationen, Teil eines Bundles oder einer ganzen Session)
- Können erstellt werden:
 - per Hand (Excel, OpenOffice.org, ...)
 - mit einem (Shell-) Script
 - als Export aus einer Datenbank

CMDI-Erstellung (Cont.)

COALA – WebApp

- <https://clarin.phonetik.uni-muenchen.de/BASWebServices/#/services/Coala>
- frei verfügbar
- Detaillierte Anleitung
- Beispiele dort verfügbar
- Videotutorial (<https://youtu.be/EaIHujLk0dc>)





Kurze Demo

Take Home Message

- Metadaten sind wichtig
- besser zuviel, als zuwenig speichern
- Verschiedene Formate
- CLARIN verwendet vorwiegend CMDI
- Erstellung mit Editoren möglich

Vielen Dank
für Ihre Aufmerksamkeit!