


Design Metadata Harvester FID Theologie 2018

Dr. Johannes Ruscheinski / Johannes Riedl

29. September 2017

Ein geplantes Tool zur Automatisierung des Harvesting und der Anreicherung von Metadaten aus diversen Webseiten mit Hilfe von Zotero-Plugins und des Exports in Form von MARC-XML oder MARC-21.

Übersicht (cont.)



Zotero Translation Server

- ✓ Ursprünglich Browser-Plugin: "free, easy-to-use tool to help you collect, organize, cite, and share your research sources." (zotero.org)
- ✓ Translators: JS-Programme für die Extraktion von Metadaten aus Webseiten
- ✓ Translation Server: JSON-Protokoll

- 1 Eine Konfigurationsdatei für Einsprungspunkte für `zotero_crawler` muss angelegt werden
- 2 `zotero_crawler` identifiziert relevante Internetseiten und gibt diese auf `stdout` aus.
- 3 Anreicherungsdateien für `zts_client` müssen angelegt werden.
- 4 `zts_client` erzeugt MARC-XML und MARC-21.
- 5 Optional: Automatisierung mit `cron`.

- ✓ Konfigurationsdatei:
Jede Zeile spezifiziert eine Site und hat folgendes Format:
Start-URL Crawl-Tiefe URL-Muster
- ✓ *Start-URL* gibt an wo das Harvesting anfängt
- ✓ *Crawl-Tiefe* gibt an wie viele Hops angefangen vom Start-URL gecrawlt werden sollen
- ✓ *URL-Muster* gibt an welche Seiten geharvestet werden sollen (Die Muster kann man Zotero-Plugins entnehmen)
- ✓ `zotero_crawler` crawlt dann alle Sites aus der Konfigurationsdatei und spuckt matchende auf `stdout` aus

- ✓ Started `zotero_crawler` und arbeitet die dort ausgegebenen URLs ab.
- ✓ Für jedes URL wird ein Zotero Translation Server kontaktiert und die zurückgelieferten JSON-Daten übernommen.
- ✓ Metadaten können mit Mapping-Dateien angereichert werden, z.B. matchende ISSNs mit Schlagworten etc.
- ✓ `zts_client` verwendet eine Erkennung, um Duplikate von früher schon heruntergeladenen Metadatensätzen zu vermeiden.
- ✓ Als Ausgabe unterstützt `zts_client` MARC-XML und MARC-21

Fragen?