

OCR-D: Was wurde bisher erreicht und wie geht es jetzt weiter?

Clemens Neudecker (@cneudecker)

Staatsbibliothek zu Berlin – Preußischer Kulturbesitz

DHd AG Zeitungen & Zeitschriften

OCR - Herausforderungen und Lösungen für Zeitungen & Zeitschriften

Frankfurt am Main, 11. November 2019



Einleitung

- Massendigitalisierung in Bibliotheken hat inzwischen Millionen von Dokumenten digital als Scans verfügbar gemacht, aber wenig Volltexte
 - Trotz vieler Projekte in der Vergangenheit (z.B. IMPACT, eMOP, etc.) noch immer unzureichende OCR Qualität historischer Drucke für die Nachnutzung bspw. in den Digital Humanities
 - Erhebliche Fortschritte im Bereich Document Analysis und Recognition durch Verwendung von Deep Learning Verfahren (RNN, CNN, LSTM)
 - Deep Learning Verfahren bzw. Modelle erfordern spezifische Anpassungen auf die Bedarfe von Bibliotheken und die Besonderheiten historischer Dokumente
- DFG Ausschreibung am 28. Mai 2014

OCR-D Koordinierungsprojekt

- Seit 2015: DFG-Förderung für OCR-D Koordinierungsprojekt
- Koordinierungsprojekt mit 4 Partnern:
 - Herzog August Bibliothek Wolfenbüttel
 - Berlin-Brandenburgische Akademie der Wissenschaften
 - Staatsbibliothek zu Berlin (ab 12/2016)
 - Karlsruher Institut für Technologie (ab 08/2017)
- Kernaufgaben des Koordinierungsprojekts:
 - Handlungsbedarfe identifizieren und systematisieren (Phase I)
 - Technische Anforderungen und Rahmenbedingungen für OCR-Entwicklung spezifizieren (Phase I)
 - Betreuung von OCR-D Softwareentwicklungs-Modulprojekten und Teststellung der OCR-D Software in Pilotbibliotheken (Phase II)

OCR-D Spezifikationen (1/2)

- Konsequent offene und Community-basierte Entwicklung via GitHub
 - OCR-D auf GitHub: <https://github.com/OCR-D> | <https://ocr-d.de/>
 - Chat: <https://gitter.im/OCR-D/Lobby>
- METS Container (basierend auf den Anforderungen der DFG-Praxisrichtlinien und des DFG-Viewer)
 - METS in OCR-D: <https://ocr-d.de/mets>
- PAGE-XML für OCR Ergebnisse (perspektivisch mit Transformationsszenarien nach ALTO, TEI)
 - PAGE-XML in OCR-D: <https://ocr-d.de/page>
- Taverna Workflow Engine für Prozessketten und Provenance
 - Taverna in OCR-D: https://github.com/OCR-D/taverna_workflow

OCR-D Spezifikationen (2/2)

- Kommandozeile als minimale Anforderung für OCR-D Software:
 - CLI: <https://ocr-d.de/cli>
- JSON Schema für OCR-D Softwarebeschreibung:
 - `ocrd-tool.json`: https://ocr-d.de/ocrd_tool
- ZIP+BagIt für (Ground Truth) Daten:
 - OCRD-ZIP: https://ocr-d.de/ocrd_zip
- Docker als Container für OCR-D Software:
 - Docker: <https://ocr-d.de/docker>

OCR-D Referenzimplementierung

- Konsequente Verwendung von `Python3` für alle OCR-D Software (wenn immer möglich)
- `core` Referenzimplementierung unterstützt Software-Entwickler und Anwender mit
 - `ocrd_utils` = logging, path normalization, coordinate calculation etc.
 - `ocrd_models` = file format wrappers for PAGE-XML, METS, EXIF etc.
 - `ocrd_modelfactory` = instantiate models from existing data
 - `ocrd_validators` = validating BagIt, ocrd-tool.json, METS, PAGE, CLI
- <https://github.com/OCR-D/core> oder <https://pypi.org/project/ocrd/>
- API docs <https://ocr-d.de/core/>

OCR-D Ground Truth Repository & Daten

- Erstellung von detaillierten Transkriptionsrichtlinien für Ground Truth Daten mit PAGE-XML
 - <https://ocr-d.de/gt>
- Entwicklung eines Repository für Ground Truth Daten
 - https://github.com/OCR-D/repository_metastore
- Bereitstellung von Ground Truth Daten aus OCR-D
 - <https://ocr-d.de/gt-repo>
- Semantisches Labeling von Ground Truth Daten
 - <https://github.com/OCR-D/gt-labelling>

OCR-D Modulprojekte

- Seit 2017 OCR-D Phase II mit 8 eigenständigen und durch die DFG geförderten OCR-D Modulprojekten:
 - [MP1] Bildoptimierung (DFKI Kaiserslautern)
 - [MP2] Layouterkennung (DFKI Kaiserslautern)
 - [MP3] Layouterkennung (Uni Würzburg)
 - [MP4] Nachkorrektur (Uni Leipzig)
 - [MP5] Optimierung von Tesseract OCR (UB Mannheim)
 - [MP6] Nachkorrektur (Uni München)
 - [MP7] Schriftarterkennung und Trainingsinfrastruktur (Uni Erlangen, Mainz, Leipzig)
 - [MP8] Langzeitarchivierung (SUB Göttingen)
- <https://ocr-d.de/projects>

Weitere OCR-D Komponenten

- Zusätzlich Bereitstellung von externer Software mit OCR-D Schnittstellenkonformität durch OCR-D Koordinierungsprojekt um Lücken in den Modulprojekten zu schließen bzw. für Vergleiche mit SoTA:
 - `ocrd_calamari`
 - `ocrd_im6convert`
 - `ocrd_kraken`
 - `ocrd_ocropy`
 - `ocrd_olena`
 - `ocrd_segment`
 - `ocrd_kerasLM`
 - `dingledhopper`
- <http://kba.cloud/ocrd-kwalitee/>
- `ocrd_train`: Makefile zum Trainieren von Tesseract LSTM
 - „Adoptiert“ von Tesseract als <https://github.com/tesseract-ocr/tesstrain>

OCR-D Einstieg und eigenes Experimentieren

- OCR-D Tutorial der DHd2019
 - <http://kba.cloud/2019-03-25-dhd/>
- OCR-D Setup Guide
 - <https://ocr-d.de/docs/setup-2019-10-27>
- OCR-D Chat
 - <https://gitter.im/OCR-D/Lobby>

Sonderfall Zeitungen (& Zeitschriften)

- Qua Beauftragung liegt das Hauptaugenmerk von OCR-D auf den VD-Digitalisierungsprojekten (VD16, VD17, VD18)
 - Keine Arbeiten/Anpassungen in OCR-D spezifisch für Zeitungen & Zeitschriften!
- Besondere Herausforderungen bei Zeitungen:
 - Mehrspaltiges Layout
 - Kleine bzw. stark variierende Schriftgrößen
 - Komplexe Reihenfolge von Regionen (Artikelseparierung)
 - Hoher Anteil an nicht-textuellen Regionen (Bilder, Tabellen, Werbung)
 - Niedrige Qualität der Vorlagen bzw. Digitalisate (Papier, Mikrofilm)

Ausblick

- Aktuell größtes Desiderat: Spezielle Layouterkennung für (historische) Zeitungen & Zeitschriften
 - Sind die Textregionen erst ordentlich segmentiert, Verwendung der regulären OCR-D Softwarekomponenten
 - Aktuelle Arbeiten an der SBB im QURATOR Projekt (Code coming soon!)
- Idee: Kombination von Layouterkennung (optische Merkmale) mit NLP Methoden – z.B. Transformer – (sprachliche Merkmale) um Reihenfolge der Regionen zu bestimmen
- Ground Truth bzw. Trainingsdaten werden benötigt!

Danke für die Aufmerksamkeit!

Fragen?

Clemens Neudecker (@cneudecker)

Staatsbibliothek zu Berlin – Preußischer Kulturbesitz

DHd AG Zeitungen & Zeitschriften

OCR - Herausforderungen und Lösungen für Zeitungen & Zeitschriften

Frankfurt am Main, 11. November 2019



OCR-D

Koordinierte Förderinitiative zur Weiterentwicklung
von Verfahren der Optical Character Recognition (OCR)



**Staatsbibliothek
zu Berlin**

Preußischer Kulturbesitz