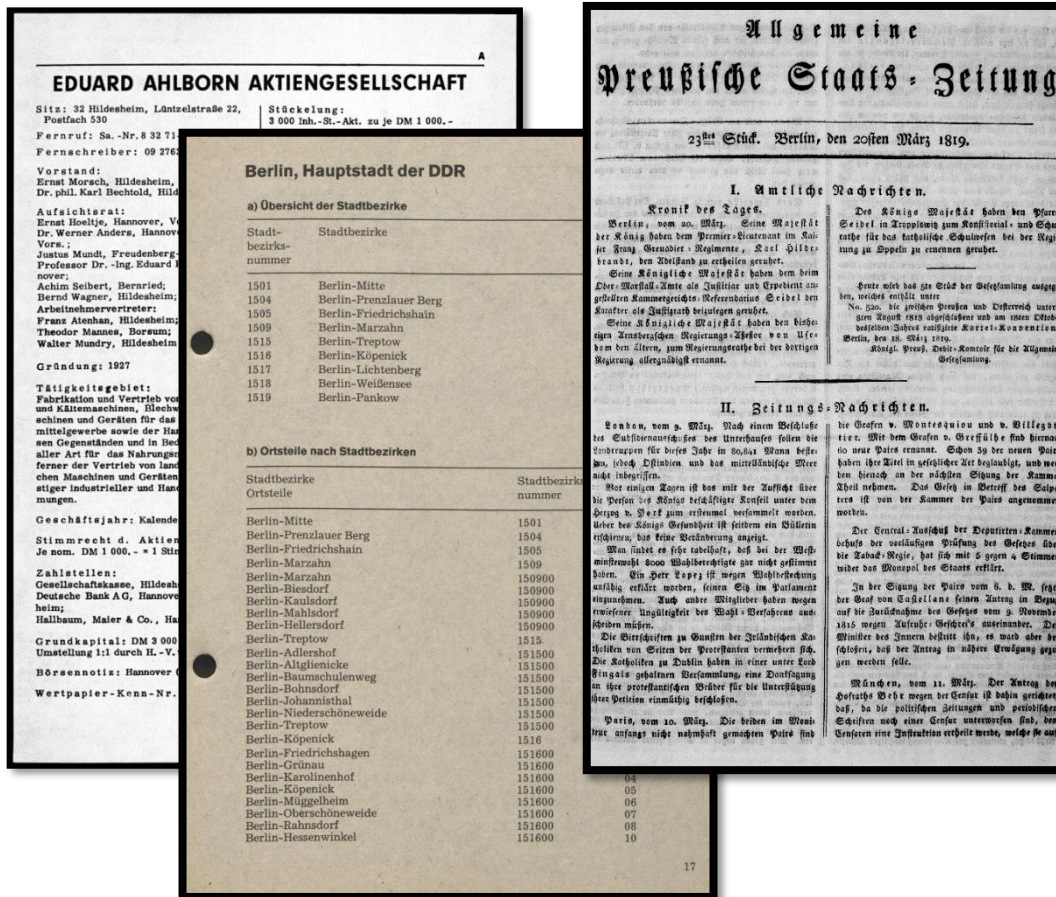


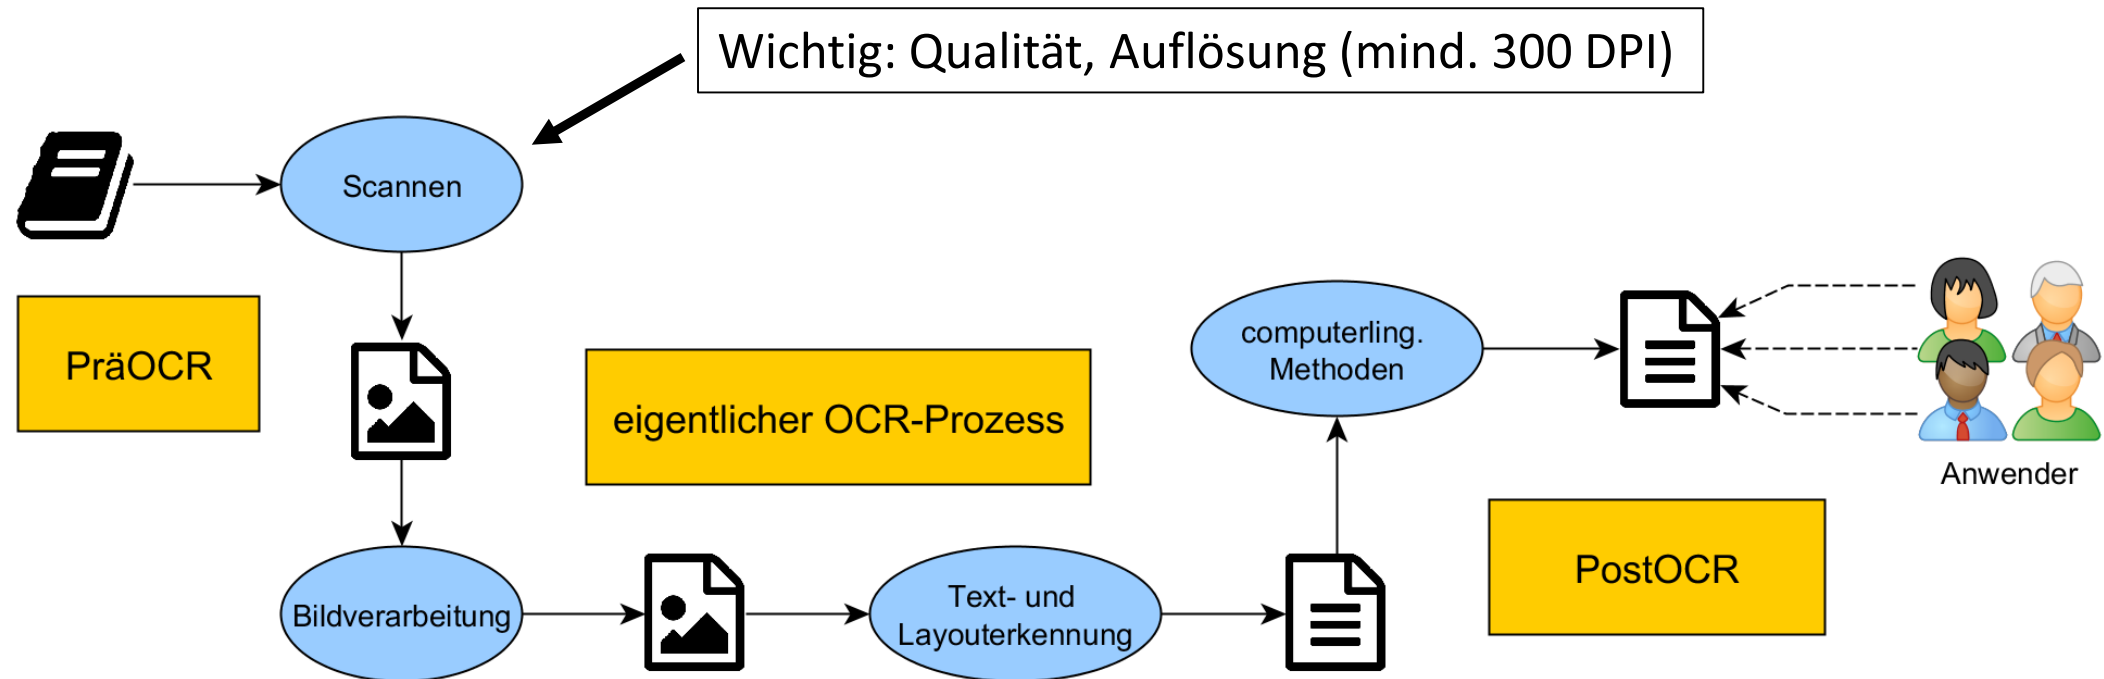
Motivation – Warum Texterkennung? (OCR = „Optical character recognition“)



- Recherchemöglichkeit (Volltextsuche)
- Datenextraktion für Forschungsprojekte
- Linguistische Analysen

z. B. bei der UB Mannheim für Hoppenstedt Aktienführer, Gemeindeverzeichnisse und Preußische Staatszeitung / Deutscher Reichsanzeiger

Prozesskette



aus: Baierer, Zumstein. Verbesserung der OCR in digitalen Sammlungen von Bibliotheken)

OCR Software (Übersicht)

kommerzielle
Software

fett = eingesetzt in Bibliotheken

ABBYY Finereader
BIT-Alpha
Readiris
OmniPage

Adobe Acrobat
CorelDraw
Microsoft OneNote
...

Tesseract
OCROpus / Kraken /
Calamari
Ocrad
CuneiForm ...

freie Software

ABBYY Cloud OCR
Google Cloud Vision
Microsoft Azure Computer Vision
OCR.space Online OCR ...

Cloud OCR

Tesseract OCR

- Open Source
- Komplettlösung „All-in-one“
- Mehr als 100 Sprachen / mehr als 30 Schriften
- Liest Bilder in allen gängigen Formaten (nicht PDF!)
- Erzeugt Text, PDF, hOCR, ALTO, TSV
- Große, weltweite Anwender-Community
- Technologisch aktuell (Texterkennung mit neuronalem Netz)
- Aktive Weiterentwicklung u. a. im DFG-Projekt OCR-D

Tesseract an der UB Mannheim

- Verwendung im DFG-Projekt „Aktienführer“
<https://digi.bib.uni-mannheim.de/aktienfuehrer/>
- Volltexte für Deutscher Reichsanzeiger und Vorgänger
<https://digi.bib.uni-mannheim.de/periodika/reichsanzeiger>

- DFG-Projekt „OCR-D“ <http://www.ocr-d.de/>,








OCR-D

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

Modulprojekt „Optimierter Einsatz von OCR-Verfahren – Tesseract als Komponente im OCR-D-Workflow“:
Schnittstellen, Stabilität, Performance und praktische Einsetzbarkeit

Tesseract – Installation

- Linux 
Tesseract 4 ist Bestandteil der gängigen Linux-Distributionen
- Windows 
Tesseract-Installer der Universitätsbibliothek Mannheim
<https://github.com/UB-Mannheim/tesseract/wiki>
- macOS 
Installation über MacPorts oder Homebrew  
- Beschreibung: <https://github.com/tesseract-ocr/tesseract/wiki>

Tesseract – Sprachen und Schriften

- Tesseract 4 unterscheidet zwischen „Sprachen“ und „Schriften“:
 - Eine Sprache wie beispielsweise **deu** kennt die typischerweise im Deutschen verwendeten Schriftsymbole und enthält u. a. ein deutsches Wörterbuch.
 - Eine Schrift wie beispielsweise **script/Latin** kennt idealerweise alle Schriftsymbole dieser Schrift und ein Wörterbuch verschiedener Sprachen, die diese Schrift nutzen. Das ist neu in Tesseract 4 und bietet Vorteile in vielen typischen Texten.
- Übersicht: Kapitel „Languages and Scripts“ im Tesseract-Handbuch
<https://digi.bib.uni-mannheim.de/tesseract/manuals/tesseract.1.html>
- Drei Ausprägungen für jede Sprache bzw. Schrift:
 - Optimiert für Geschwindigkeit: https://github.com/tesseract-ocr/tessdata_fast
 - Genauigkeit + Training: https://github.com/tesseract-ocr/tessdata_best
 - Zwei OCR-Erkennungsalgorithmen: <https://github.com/tesseract-ocr/tessdata>

Tesseract – Support

- Dokumentation
 - Tesseract Wiki: <http://github.com/tesseract-ocr/tesseract/wiki>
 - UB Mannheim Wiki: <https://github.com/UB-Mannheim/tesseract/wiki>
 - Handbuchseiten: <https://digi.bib.uni-mannheim.de/tesseract/manuals/>
- Anwenderforum: <http://groups.google.com/group/tesseract-ocr>
- Entwicklerforum: <http://groups.google.com/group/tesseract-dev>
- Ticketing-System (in der Regel für Fehlermeldungen)
 - Tesseract: <https://github.com/tesseract-ocr/tesseract/issues>
 - Tesseract für Windows: <https://github.com/UB-Mannheim/tesseract/issues>

PDF-Dateien

- All-in-one Lösung **OCRmyPDF**  
<https://github.com/jbarlow83/OCRmyPDF>
- Xpdf **XpdfReader** und **Xpdf command line tools**   
<http://www.xpdfreader.com/>
 - `pdftimages myfile.pdf image`
erzeugt `image-0000.ppm`, `image-0001.ppm`, `image-0002.ppm`, ...
 - `pdftopng myfile.pdf image`
erzeugt `image-000001.png`, `image-000002.png`, `image-000003.png`, ...
 - Diese Bilder können von Tesseract gelesen werden.

hOCRjs

Zweck: Visualisierung des erkannten Layouts,
überlagerte Darstellung von Digitalisat und erkanntem Text




- Website: <http://kba.cloud/hocrjs/>
- GitHub: <https://github.com/kba/hocrjs>
- Beispiel: http://kba.cloud/hocrjs/example/426117689_0459.html
- Beispiel: <https://digi.bib.uni-mannheim.de/periodika/reichsanzeiger/ocr/film/tesseract-4.0.0-20181201/139-9547/0316.hocr?overlay=1>

ScanTailor

Zweck: Digitalisate verbessern für die Texterkennung

- Website: <https://scantailor.org/>
- GitHub: <https://github.com/scantailor/scantailor>













Ground Truth

Manuell erfasster Text, idealerweise fehlerfrei.

- Verwendet für Qualitätsmetriken
 - Wortfehlerrate (WER) 0...100 % bzw. Wortgenauigkeit 100...0 %
 - Zeichenfehlerrate (CER) 0...100 % bzw. Zeichengenauigkeit 100...0 %
- Verwendet zum Trainieren der OCR-Software
- Texterfassung ist kein einfaches Abschreiben, siehe die Ground Truth Guidelines für OCR-D: http://www.ocr-d.de/gt_guidelines
- Beispiele:
 - Ground Truth Korpus von OCR-D: <http://www.ocr-d.de/daten>
 - UB Mannheim: <https://digi.bib.uni-mannheim.de/fileadmin/digi/453089178/gt/>
<https://github.com/UB-Mannheim/Reichsanzeiger/wiki/Text-recognition#accuracy>

Nützliche Programme

- hOCRjs
<http://kba.cloud/hocrjs/>   
- ScanTailor
<https://scantailor.org/>  
- Gimp
<https://www.gimp.org/>   
- OCRmyPDF
<https://github.com/jbarlow83/OCRmyPDF>  
- IrfanView (privat und in Bildungseinrichtungen frei nutzbar) 
<https://www.irfanview.com/>

Linksammlung

- Wikipedia-Artikel
 - [https://de.wikipedia.org/wiki/Tesseract \(Software\)](https://de.wikipedia.org/wiki/Tesseract_(Software))
 - <https://de.wikipedia.org/wiki/Texterkennung>
 - [https://en.wikipedia.org/wiki/Comparison of optical character recognition software](https://en.wikipedia.org/wiki/Comparison_of_optical_character_recognition_software)
- Wikis auf GitHub
 - <https://github.com/tesseract-ocr/tesseract/wiki>
 - <https://github.com/UB-Mannheim/tesseract/wiki>
- Umfangreiche Sammlung von Links zum Thema OCR
 - <https://github.com/kba/awesome-ocr>

- Weil, S., & Zumstein, P. (2016). Mit freier Software Text in Digitalisaten erkennen. <https://speakerdeck.com/zuphilip/mit-freier-software-text-in-digitalisaten-erkennen-ocr-praxis-an-der-ub-mannheim>
- Baierer, K., & Zumstein, P. (2016). Verbesserung der OCR in digitalen Sammlungen von Bibliotheken. *027.7 Zeitschrift für Bibliothekskultur / Journal for Library Culture*, 4(2), 72-83.
<https://doi.org/10.12685/027.7-4-2-155>

Bildnachweis

- Apple Logo, Microsoft Logo, Linux Logo, Logos für MacPorts und Homebrew: Wikimedia Commons <https://commons.wikimedia.org/>
- OCR-D Logo: <http://www.ocr-d.de/>
- Bilder zu ScanTailor: <https://github.com/scantailor/scantailor>,
<https://github.com/scantailor/scantailor/wiki/User-Guide>
- Titelbild: Weil, S., & Zumstein, P. (2016)
- Prozesskette: Baierer, K., & Zumstein, P. (2016)