

A-I-PoCoTo - AUTOMATISCHE UND INTERAKTIVE OCR NACHKORREKTUR

Klaus U. Schulz, Tobias Englmeier, Florian Fink

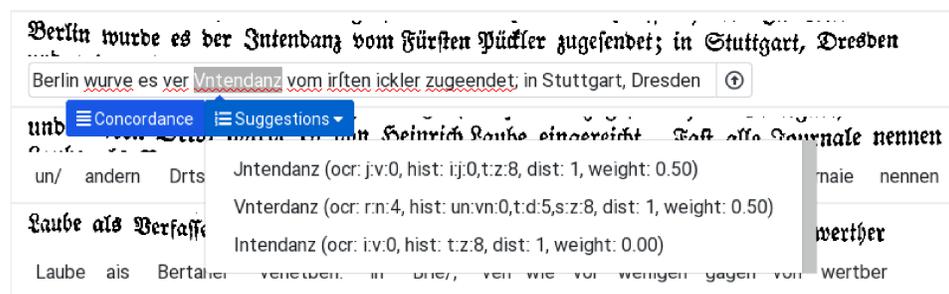
CIS - Centrum für Informations- und Sprachverarbeitung
Ludwig-Maximilians-Universität München

A-PoCoTo (automatische Nachkorrektur)

Als Teil des OCR-D-Moduls 3 (Textoptimierung) wird in *A-PoCoTo*[1] eine *vollautomatische* Nachkorrektur OCR-erkannter historischer Dokumente umgesetzt. Ein besonderes Augenmerk wird dabei sowohl auf die Behandlung historischer Rechtsschreibvarianten als auch auf die Verhinderung von Verschlimmbesserungen gelegt.

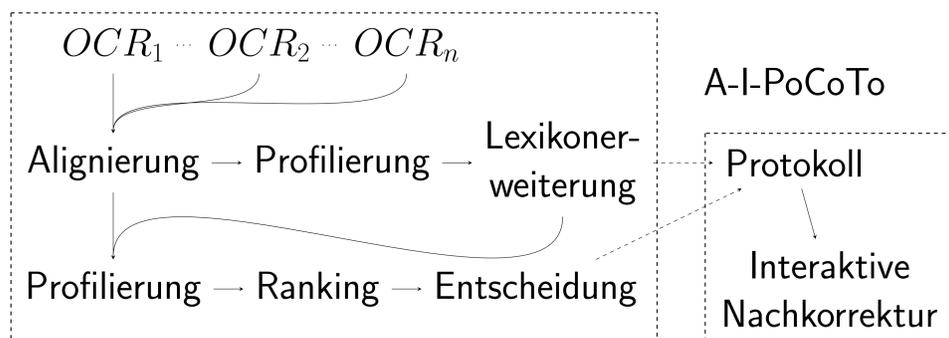
Sprachprofilierung der OCR-Ausgabe

Die am CIS entwickelte *Profilierungs*-Technologie[3, 4] leitet eine statistische Abschätzung über ein OCR-erkanntes historisches Dokument auf der Basis unterschiedlicher Hintergrundlexika und einer Menge *historischer Patterns* (wie in etwa *lei* → *ley* oder *t* → *th*) ab und erzeugt für jedes OCR-Wort gewichtete *Interpretationen* der Form $w_{mod} \rightarrow_{\alpha} w_{hist} \rightarrow_{\beta} w_{ocr}$.



Arbeitsweise

A-PoCoTo



Die automatische Nachkorrektur läuft über drei (zwei) Klassifikationsschritte: die optionale *Lexikonerweiterung* (Extraktion unbekannter Lexikoneinträge zur Erweiterung des Profilierungslexikons), den *Ranker* (Neusortierung der Profilerinterpretationen) und den *Entscheider* (Entscheidung über die Ausführung von Korrekturen), mit zwei (einem) zwischengeschalteten Profilierungsdurchläufen. Als Eingabe dienen hierbei eine Haupt-OCR-Erkennung (OCR_1) sowie $n - 1$ weitere Hilfs-OCR-Erkennungen ($OCR_2 \dots OCR_n$). Die Lexikonerweiterungen sowie die durchgeführten Korrekturen werden protokolliert und dienen der späteren Weiterverarbeitung durch *A-I-PoCoTo* (siehe rechte Spalte).

Das Training geht dokumentenweise vor, wobei für jedes Trainingsdokument ein eigenes Profil erstellt wird. Für jeden Schritt werden $1 \dots n$ Klassifikatoren mit einer entsprechenden Anzahl von Eingangs-OCR's trainiert. Jedem Klassifikator wird dabei flexibel eine Feature-Menge zugewiesen, die beim Training (und auch bei der Nachkorrektur) je nach vorhandenen OCR-Eingaben dynamisch an- und abgeschaltet werden.

Auswertungen

	mit Lexikonerweiterung		ohne Lexikonerweiterung	
	1 OCR	2 OCR	1 OCR	2 OCR
Korrekte OCR Token	1891	1891	1891	1891
Inkorrekte OCR Token	1007	1007	1007	1007
Keine korrekten Vorschläge	720	917	718	718
Top 1 Vorschlag korrekt (Profilier)	128	42	128	128
Top 1 Vorschlag korrekt (Ranker)	219	124	218	223
Erfolgreiche Korrekturen	207	53	206	141
Verpasste Korrekturen	12	34	12	82
Unglückliche Korrekturen	539	71	508	12
Korrekte Token nach der Korrektur	1560	1985	1589	2020


“1557, Bodenstein, WieSichMeniglich” [1].

A-I-PoCoTo (interaktive Nachkorrektur)

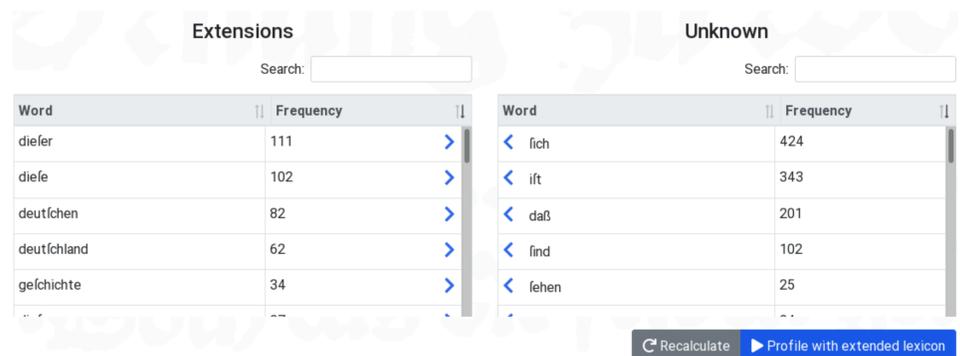
Es ist nicht davon auszugehen, dass mit einer vollautomatischen Korrektur stets die gewünschte Akkuratheit eines Texts erreicht wird. Aus diesem Grund wird mit *A-I-PoCoTo* eine *interaktive* Nachkorrektur ermöglicht[5]. Sowohl die Lexikonerweiterung als auch die vorgenommenen automatischen Korrekturen können in *A-I-PoCoTo* manuell überprüft und entweder bestätigt oder abgelehnt werden.

Wie bereits bei der *adaptiven Profilierung*[2] können in weiterführenden Arbeiten bei der interaktiven Nachkorrektur sowohl die verwendeten OCR-Modelle als auch die Modelle der automatischen Nachkorrektur unter Berücksichtigung der manuellen Korrekturen weiter verfeinert werden.

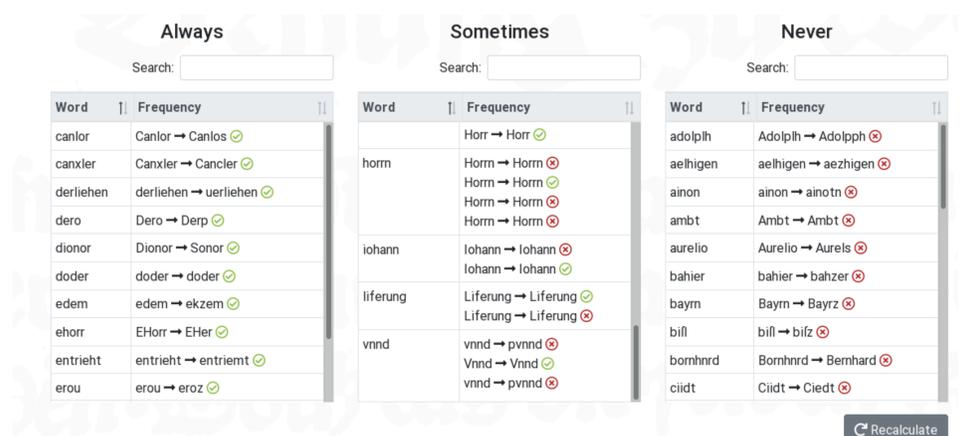
Konkordanz



Interaktive Lexikonerweiterung



Interaktive Nachkorrektur



Referenzen

- [1] Tobias Englmeier, Florian Fink, and Klaus U. Schulz. A-I-PoCoTo: Combining Automated and Interactive OCR Postcorrection. In *Proceedings of the 3rd International Conference on Digital Access to Textual Cultural Heritage*, DATECH2019, page 19–24, New York, NY, USA, 2019. Association for Computing Machinery.
- [2] Uwe Springmann Florian Fink, Klaus U. Schulz. Profiling of ocr-ed historical texts revisited. In *Proc. 2nd Conference Digital Access to Textual Cultural Heritage (DATECH 2017)*, pages 61–66. ACM Digital Library, 2017.
- [3] Ulrich Reffle. Efficiently generating correction suggestions for garbled tokens of historical language. *Natural Language Engineering*, 17(2):265–282, 2011.
- [4] Ulrich Reffle and Christoph Ringlstetter. Unsupervised profiling of OCRed historical documents. *Pattern Recognition*, 46(5):1346–1357, 2013.
- [5] Thorsten Vobl, Annette Gotscharek, Uli Reffle, Christoph Ringlstetter, and Klaus U. Schulz. PoCoTo - an Open Source System for Efficient Interactive Postcorrection of OCRed Historical Texts. In *Proceedings of the First International Conference on Digital Access to Textual Cultural Heritage*, DATECH '14, pages 57–61, New York, NY, USA, 2014. ACM.