

Anonymisieren von Transkriptionen

Sandro Hartenstein
sandro.hartenstein@hwr-berlin.de

08.7.2024



TAHAI



Agenda

- Motivation
- Anonymisieren
- Prototyp
- Ergebnisse
- Fazit



Motivation


- Datenschutzkonforme Analyse von Mediationstranskriptionen mit KI-WebAPIs
 - Schutz der personenbezogene Daten der Medianten und Mediatoren
 - Beibehaltung der Kerninhalte



Motivation



- Ermitteln der Möglichkeiten zur automatischen Anonymisierung von Text
- Neueste Entwicklungen prototypisch testen
- Validationsmöglichkeiten





Anonymisieren

Anonymisieren



Zuordnungstabelle
| Patient 392B | Heinz Schmidt |

Heinz Schmidt hat
einen Gamma-GT-
Wert von 83 U/L

Personenbezogene
Daten

Patient 392B hat
einen Gamma-GT-
Wert von 83 U/L

Pseudonymisierte
Daten

Ein Patient hat
einen Gamma-GT-
Wert von 83 U/L

Anonymisierte
Daten

<https://www.johner-institut.de/blog/gesundheitswesen/anonymisierung-und-pseudonymisierung/>

Anonymisieren Möglichkeiten



Tools

- QualiAnon
 - Nur docx input
 - Listenbasierte Suche
- **Openredac**
 - semi-automatisch
 - deutschsprachige Dokumente!

Scripts

- **NLP (NER)**
- Klassifizieren von
 - Namen
 - Orten
 - Zeitangaben
- Ersetzen mit generierten Entitäten

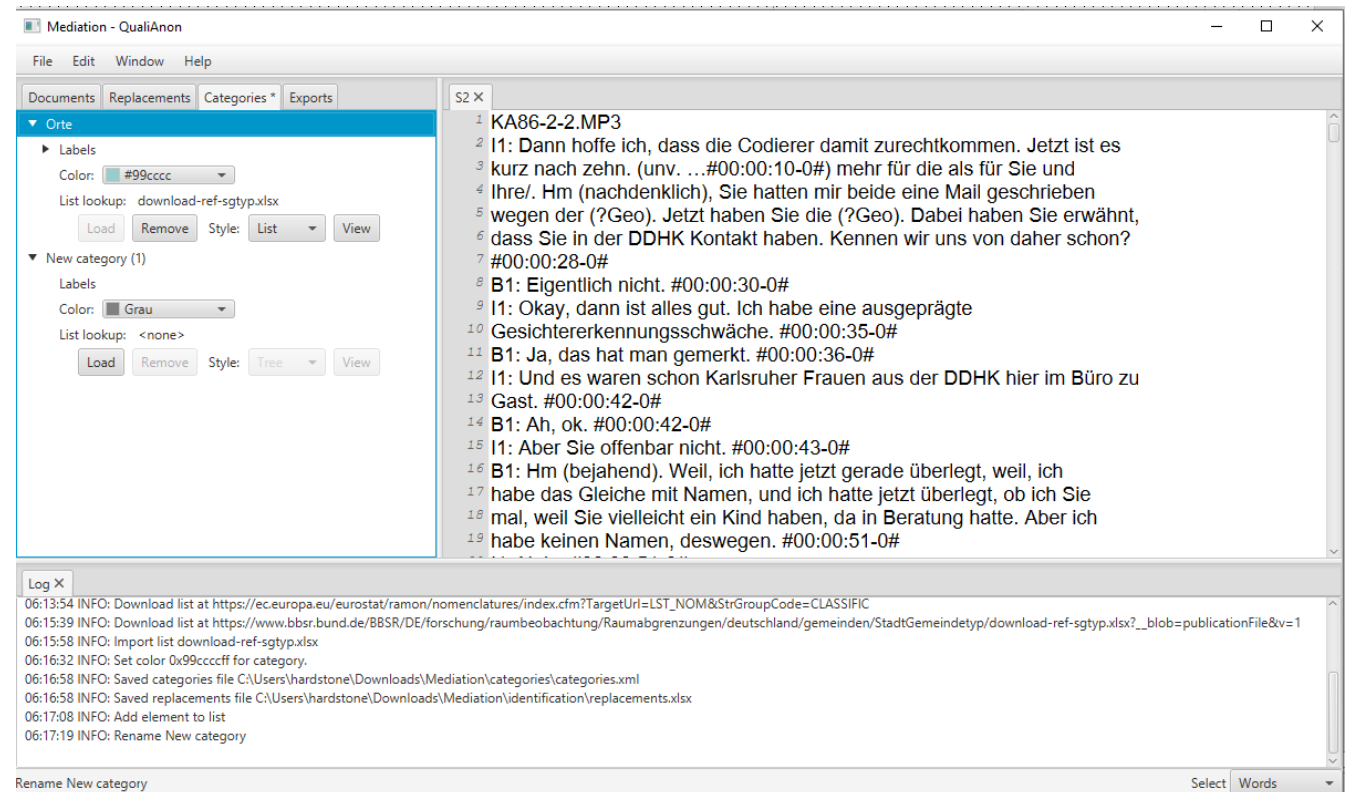
Services

- Out of Scope



Anonymisieren Möglichkeiten QualiAnon

- Klassifikation nach Listen
 - müssen importiert werden
 - XLS auch individuelle Listen
- Für Forschungsdaten entwickelt
- Unterschiedliche Anonymisierungsgrade (Exports) möglich
- Nur Docx
- <https://www.qualiservice.org/de/helpdesk/webinar/tools.html>

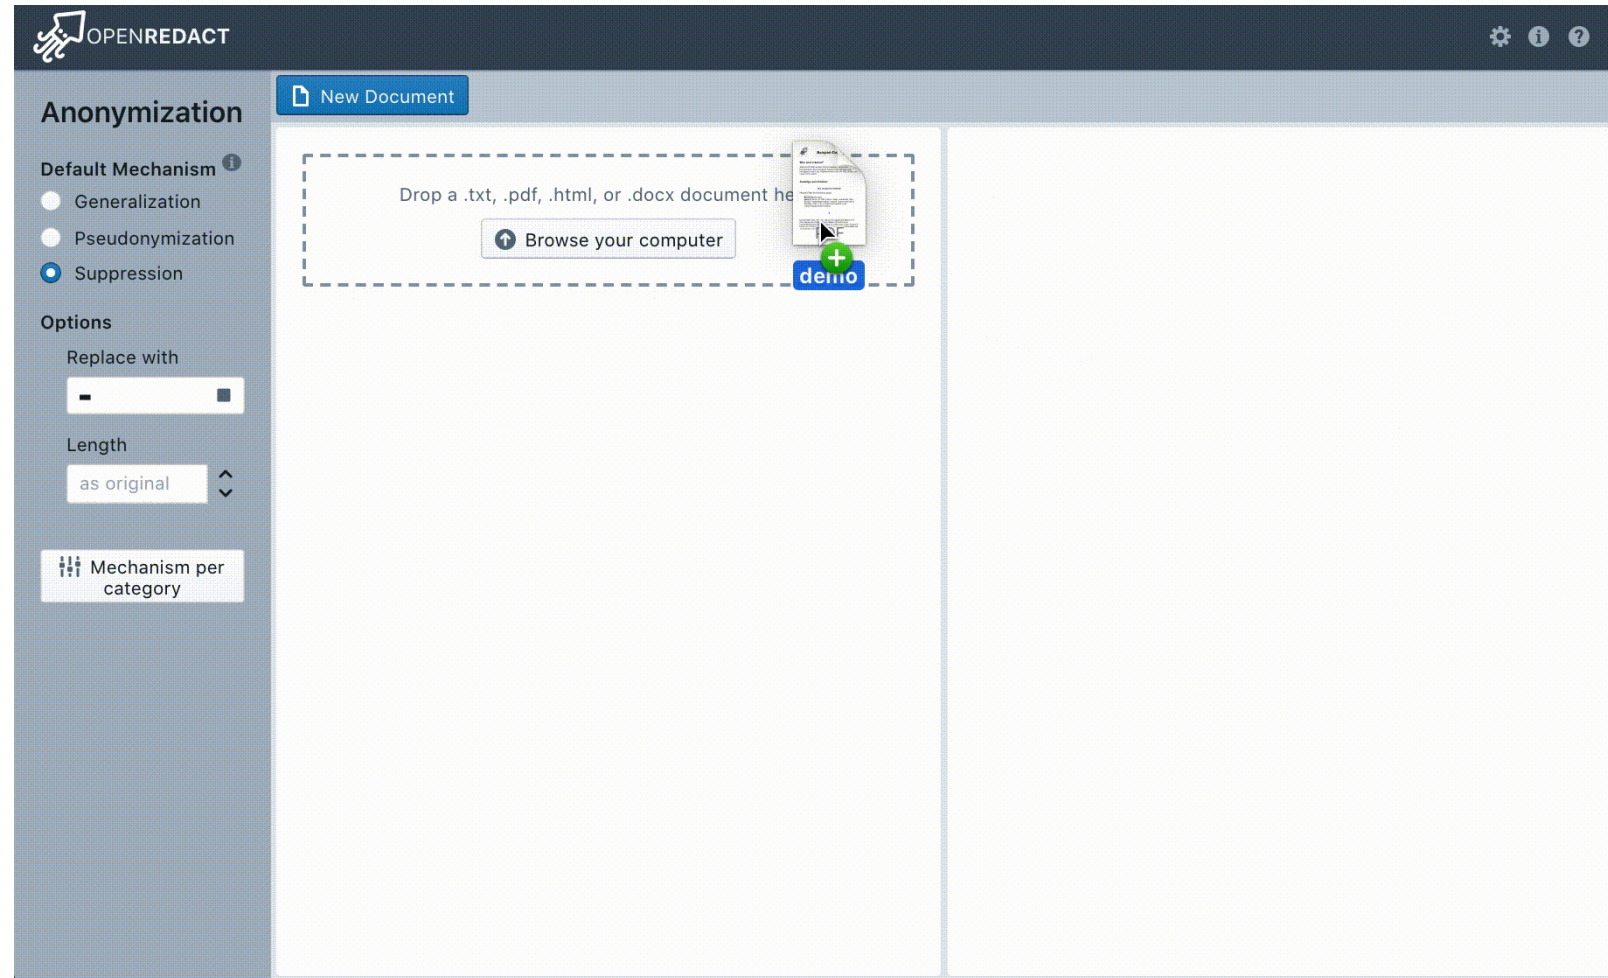


Anonymisieren Möglichkeiten OpenRedact

- Klassifikation (NER)
 - Nerwhal
 - regulären Ausdrücken
 - Deep Learning
 - spaCy
 - FlashText

Für Dokumente entwickelt

- Unterschiedliche Anonymisierungsgrade möglich



Anonymisieren Frameworks



Basic NLPs

- **spaCy**
- NLTK
- Flair
- SciKit-Learn

Huggingface / Transformer


- Vortrainierte Modelle
- Eigenes Training
- NER via LLM
- Generate Fakes

MS Presidio

- Auf PII vortrainierte NLP Modelle
- Analyse (Spacy default) Tokenbased
- Anonymizer




Anonymisieren / Pseudonymisieren Prozess / Pipeline



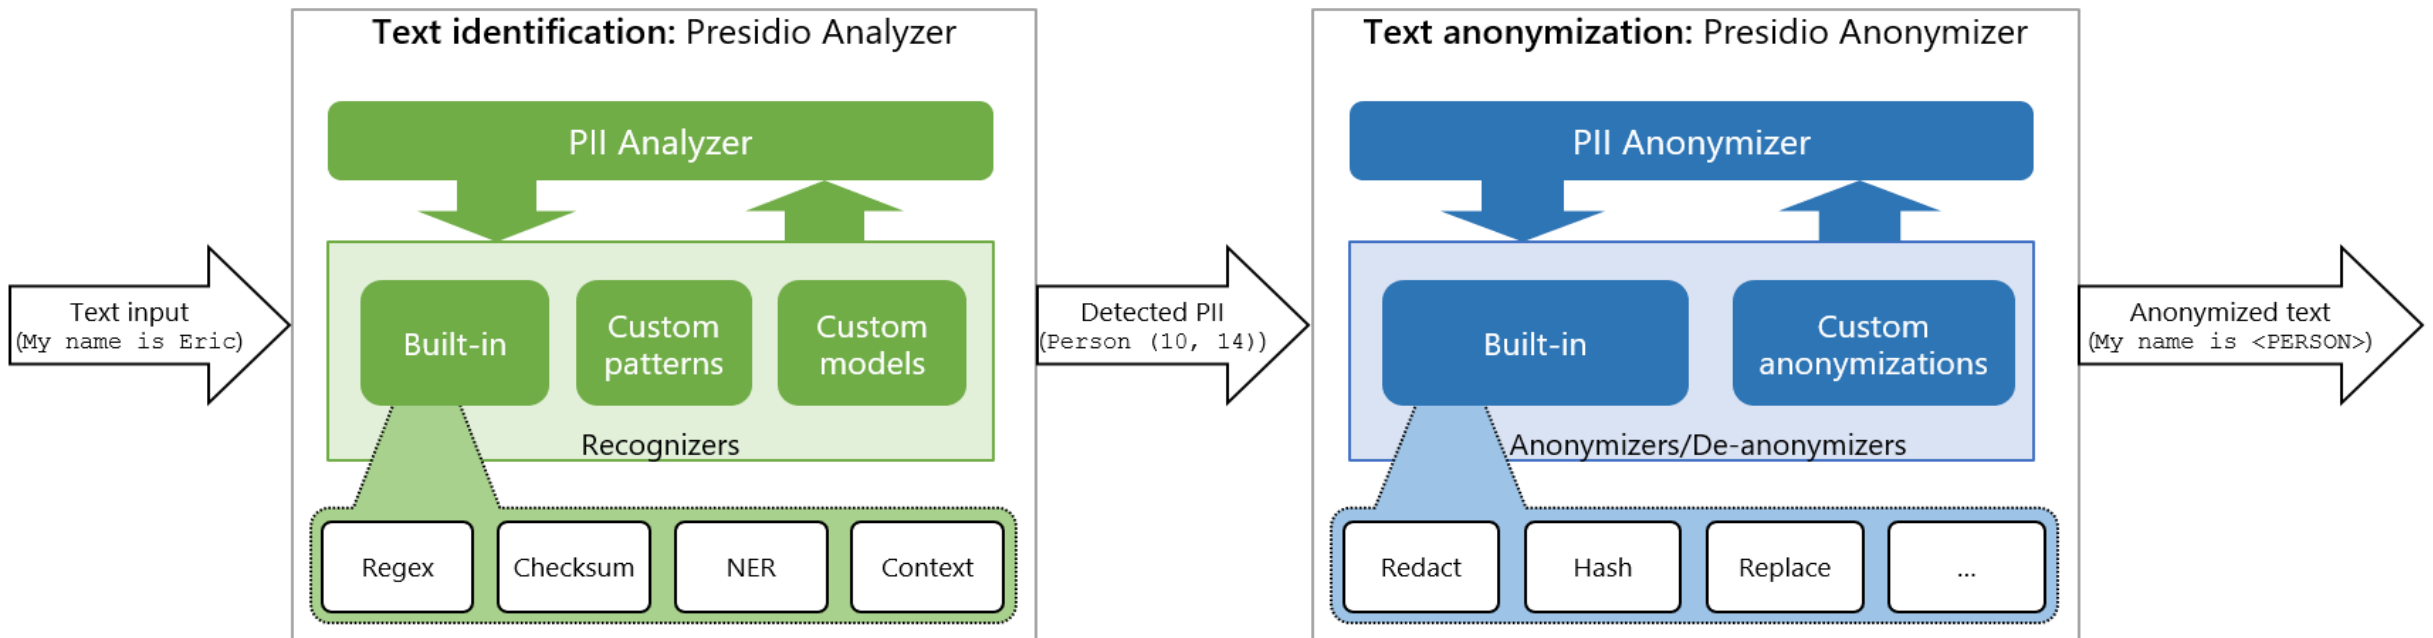
<https://arunprasad86.medium.com/nlp-pipeline-a-primer-d9f2a5129e94>

Anonymisieren Spacy



<https://spacy.io/usage/processing-pipelines>

Anonymisieren Presidio






Hochschule für
Wirtschaft und Recht Berlin
Berlin School of Economics and Law

Prototype



Prototypen Herausforderungen

- Vorbereiten der Transkripte
 - Format (rtf -> txt)
 - Codepage (utf-8)
 - Aggregation (S1-S6 -> full.txt)
- Ausschließlich lokale Verarbeitung
 - Limits (Spacy z.B. 1mio Zeichen)
 - Beachtung der Anforderung (Sinninhalt muss erhalten bleiben) -> Fakedaten statt Schwärzen
- Validation
 - Stichproben (bzw. Findingstellen anzeigen. Und Gegenanalysen)





Prototype Versuchsaufbau Vergleich

Python (Jupyter Notebook)

1. Konfiguration (Dateinamen, Modelle, Ausnahmen)
2. Laden des Transkript
3. Festlegen der Entities (Analyse) -> NER / NER via LLM / Transformer
4. Festlegen der Operators (Anonymisierung) → random / Faker
5. Schreiben des Anonymen Transkript
6. Manuelle Validierung

```
1 # %pip install xxx
```

Vorbereiten der rtf

Die Quellskripte werden von technischen Steuerzeichen befreite und als UTF8 im txt Form
Datei erstellt. _S1.txt .. _S6.txt

```
1 import os  
2 import re  
3 from striprtf.striprtf import rtf_to_text  
4  
5 # Definiere die Verzeichnisse und Dateinamen  
6 input_dir = 'input' # Achtung: das ist ein Pfad, existiert und korrekt
```

https://github.com/hardstoneed/ai_mediation_analyse

Prototype Experimente



Config / Framework	Transformer	SpaCy	MS Presidio	OpenRedact
Model	Isotonic/distil bert-base-german-cased_finetuned_ai4privacy_v2	de_core_news_lg	Spacy: de_dep_news_trf Transformers: domischwimmbeck/bert-base-german-cased-finetuned-ner Regex -> Pattern	Use nerwahl -> SpaCy(Tokenize) und Stanza (NER)
score_threshold	0.8	0.8	0.8	
entities		["PER", "ORG", "GPE", "LOC"]	["CREDIT_CARD", "PERSON_NAME", "PHONE_NUMBER", "LOCATION"]	["COUNTRY", "DATE", "EMAIL", "LOC", "MISC", "MONEY", "NUMBER", "ORG", "PER", "PHONE"]
Demotext	Bernd wohnt in Berlin. Max Mustermann arbeitet bei Bosch und wohnt in (Karlsruhe?). in der Auenstrasse 3. Max hat aber auch Verwandte in Berlin.			



Prototype Versuchsaufbau Presidio

Python (Jupyter Notebook)

1. Konfiguration (Dateinamen, Modelle, Ausnahmen)
2. Laden des Transkript
3. Festlegen der Entities (Analyse)
4. Festlegen der Operators (Anonymisierung)
5. Schreiben des Anonymen Transkript
6. Manuelle Validierung

```
+ Code + Markdown | ▶ Run All ⌵ Clear All Outputs | ☰ Outline ...  
  
Mediationsprototype 2.2  
  
Version 2 Teil 2 Anonymisierung Presidio  
  
daten /ppm werden nicht im Bitbucket gehalten (Privacy) anonymisierte Daten in /anon )  
  
1 # Module install  
2 #!pip install presidio_analyzer presidio_anonymizer  
3 #!python -m spacy download de_core_news_lg  
  
1 # imports  
2 import os  
3 import re  
4 from stripptf.stripptf import rtf_to_text  
5  
6 from presidio_analyzer import AnalyzerEngine, RecognizerRegistry, PatternRecognizer  
7 from presidio_analyzer.nlp_engine import NlpEngineProvider, TransformersNlpEngine  
8  
9
```

https://github.com/hardstoneed/ai_mediation_analyse



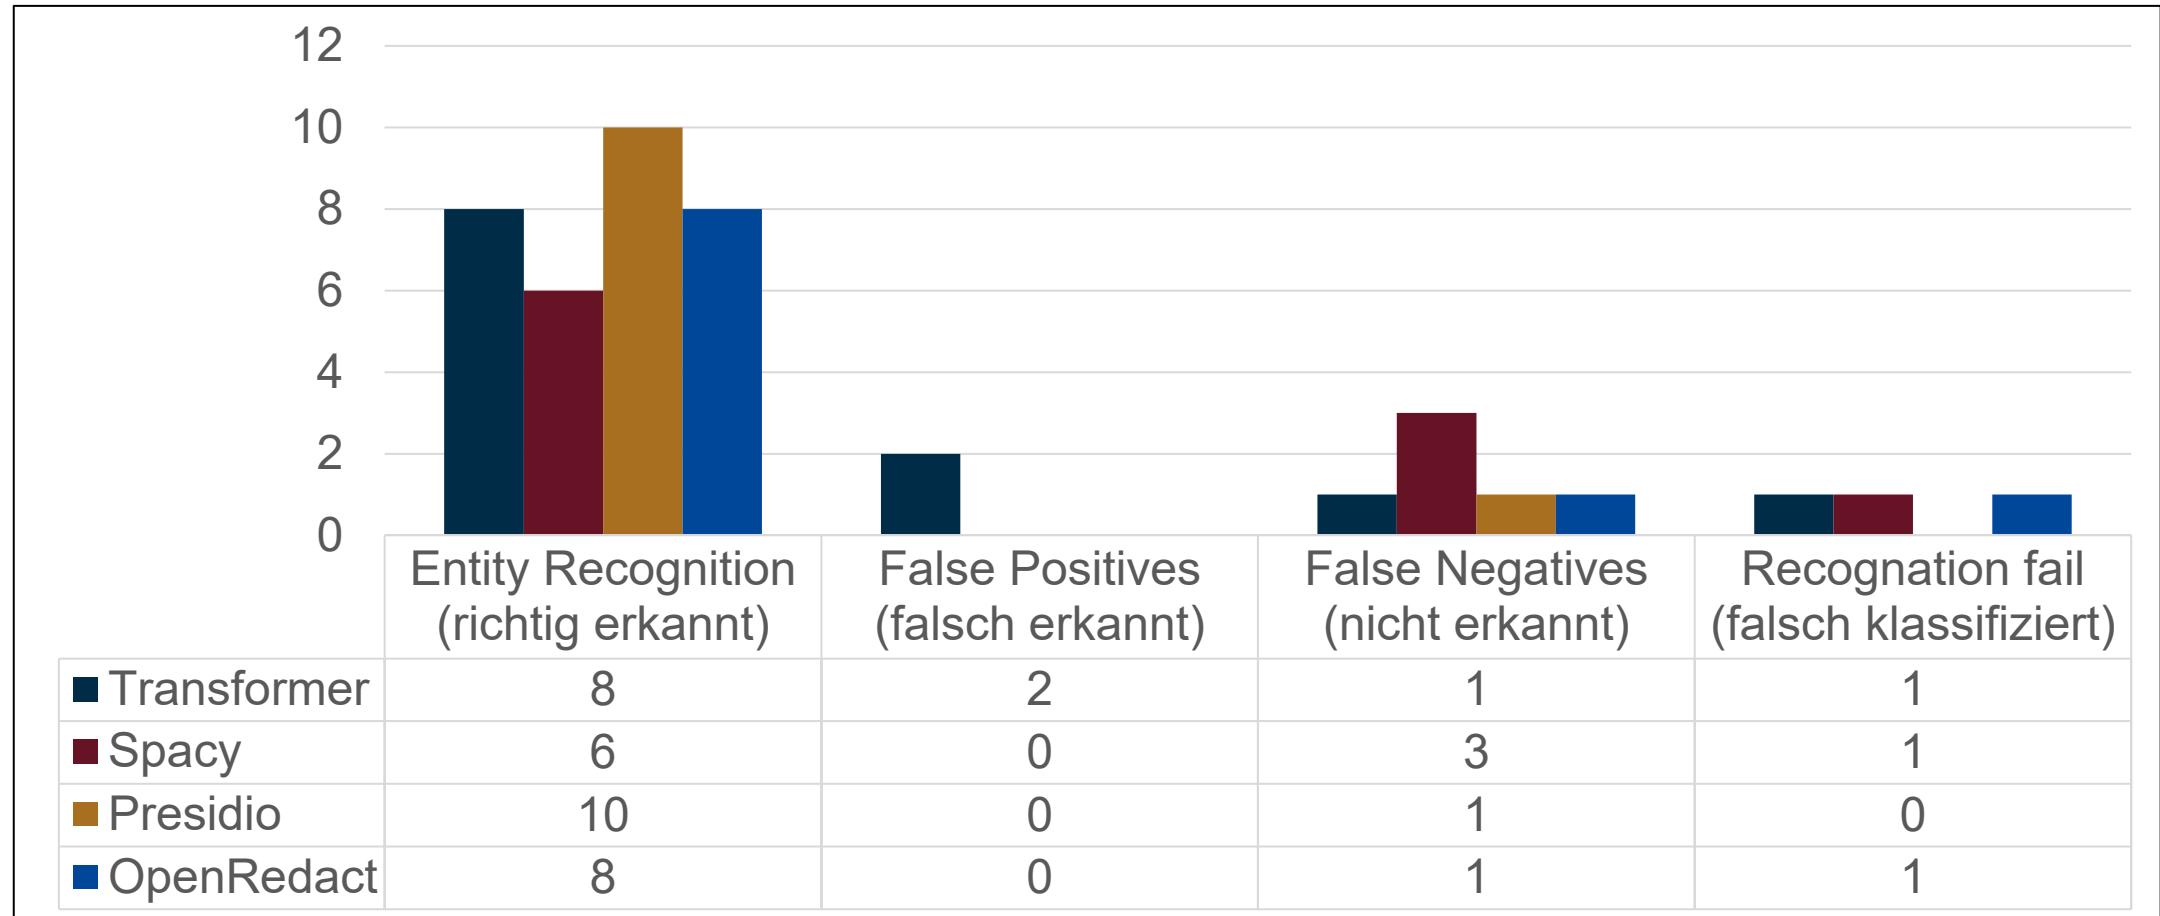
Ergebnisse

Ergebnisse

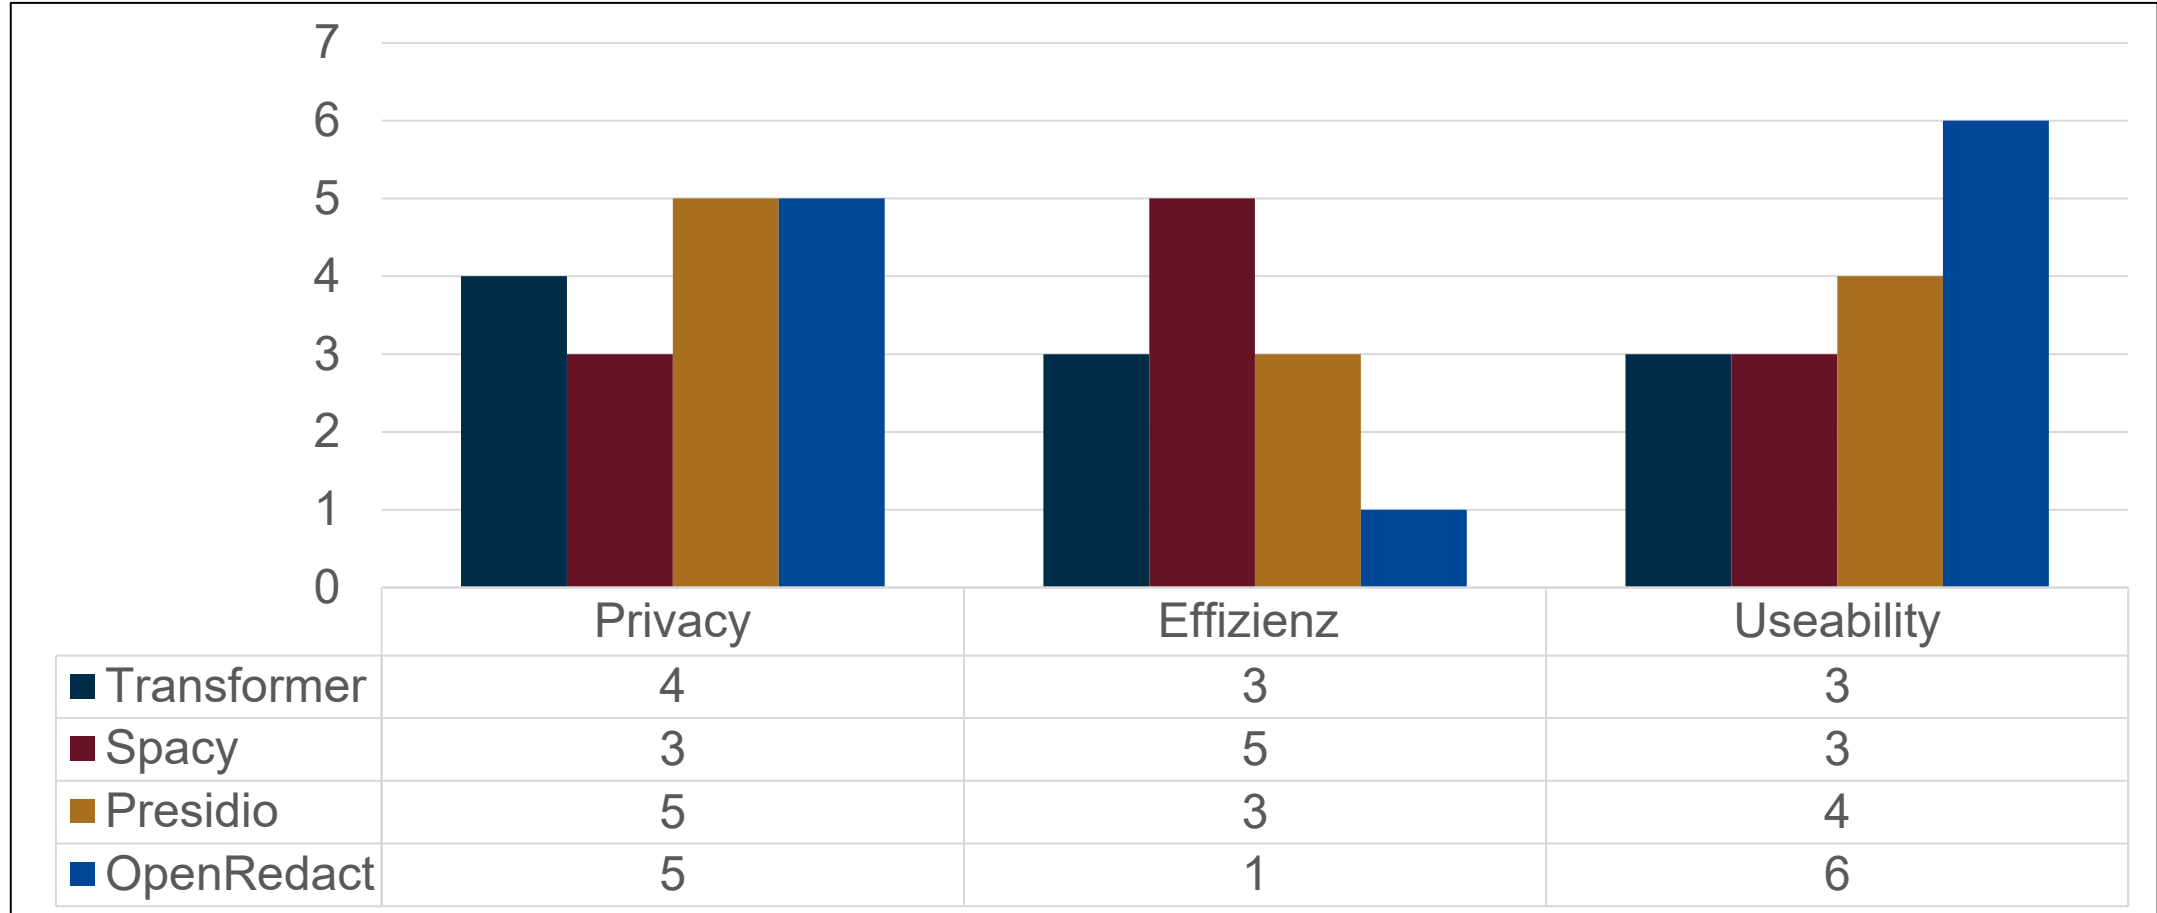


	Transformer Pipeline	SpaCy	MS Presidio	OpenReduct
Pseudonymisierter Text mit Markierung für Ungenauigkeiten	<PER 1> wohnt in <LOC 1>. <PER 2> <PER 1>er<PER 3><PER 4> arbeitet bei <ORG 1> und wohnt in <LOC 2> in der Auestrasse 3. <PER 3> hat aber auch Verwandte in <LOC 3>	<PER 1> wohnt in <LOC 1> . <PER 2> <PER 3> arbeitet bei <ORG 1> und wohnt in Karlsruhe in der Auestrasse 3. Max hat aber auch Verwandte in <LOC 2>	<PERSON_2> wohnt in <LOCATION_0>. <PERSON_1> arbeitet bei <ORGANIZATION_0> und wohnt in (<LOCATION_2?>). in der <LOCATION_1> 3. <PERSON_0> hat aber auch Verwandte in <LOCATION_0.>	<PERSON 1> wohnt in <LOCATION 1>. <PERSON 2> arbeitet bei <PERSON 3> und wohnt in (<LOCATION 2>). in der <LOCATION 3> 1 <PERSON 4> hat aber auch Verwandte in <LOCATION 1>.
Genauigkeit (Qualität) Demotext	einige False Positives	einige Nicht Erkennung	Sehr genau	Sehr genau
Laufzeit Demotext	2.1s	1.2s	3.4	5s
Laufzeit Mediation (incl. read and write file)	40.3s	4.1s	282.0s	622s
Genauigkeit Mediation ZeroShot (qualitativen Fehleranalyse)	einige False Positives	einige False Negatives	Sehr genau	Sehr genau
Fall 5			1044 ersetzungen in 18m	Fail (timeout)
Fall 8			569 Ersetzungen in 11m	Fail (timeout)

Ergebnisse – Genauigkeitsmessung



Ergebnisse – Leistungsbewertung





Fazit



Fazit

Lessons-Learned

- openreduct oder ms presidio liefern gute Ergebnisse
 - Bei Standardtexten und Dokumente
 - wenig Konfiguration
- Transkriptionen sind für die automatisierte NER herausfordernd
 - Teilweise besondere Syntax (Pausen, Zwischenreden, Klammern)
 - Unterschiedliche Grade der Anonymisierung für den Sinnerhalt notwendig
 - z.B. Volkswagen (Produkt oder Organisation)
 - Manuelle Unterstützung zielführend
 - Listen für bekannte Entitäten

Fazit

Ausblick



- Bereitstellung und Erläuterung des Prototypen für Fachexperten
- Dokumentation des Prototypen
 - Technische Anforderungen
 - Best Practices
- Dokumentation der Experimente publizieren



**Vielen Dank!
Fragen?**

Sandro Hartenstein
sandro.hartenstein@hwr-berlin.de



TAHAI