



# KORPUSLINGUISTIK IN DER RECHTSWISSENSCHAFT

Eine webbasierte Analyseplattform  
für EuGH-Entscheidungen

Bettina Mielke, OLG Nürnberg / Universität Regensburg

Christian Wolff, Lehrstuhl für Medieninformatik, Universität Regensburg

# Übersicht

- Einführung
  - Korpuslinguistische Arbeitsgruppen in der Rechtsinformatik
  - Was leisten korpuslinguistische Verfahren?
  - Aktuelle Analysebeispiele
- Designziele für eine Analyseplattform
  - Technisch
  - Inhaltlich / juristisch
- Technische Konzeption und Umsetzung
  - Korpuslinguistische Komponenten
  - Benutzerschnittstelle und Visualisierung
- Ausblick

# Aktuelle korpuslinguistische Arbeiten im Rechtswesen – Arbeitsgruppen in Deutschland (Auswahl)

- Erlangen: Adrian / Evert – Anonymisierung von Gerichtsurteilen
- Berlin: Leibniz Linguistic Research into Constitutional Law – Analyse von Urteilen des BVerfG: umfassend annotiertes Korpus mit Entscheidungen des BVerfG
- Heidelberg: Hamann / Vogel – juristisches Referenzkorpus (JuReKo) des deutschsprachigen Rechts, das Entscheidungstexte, juristische Aufsatzliteratur und Normtexte von 1980 bis 2015 enthält
- Regensburg: Mielke / Wolff seit 2004 – Text Mining, Vergleich der deutsch-österreichischen (und „europäischen“) Rechtssprache, Aufbau Analyseinfrastruktur

# Was leisten korpuslinguistische Verfahren?

- Einfache quantitative Textmetriken, Häufigkeiten (Wörter, Sätze) – Statistik
- Part-of-Speech-Analysen, Syntaxanalysen – sprachliches Wissen
- Inhaltsanalyse (Textklassifikation, Textzusammenfassung, Textvergleich, Information Retrieval)
- In den digitalen Geisteswissenschaften zuletzt zunehmend gefragt:
  - Stilometrie
  - Zuordnung von Autorenschaft
  - Emotion / Sentiment / Wertungen
  - Lesbarkeitsanalysen
  - Solche Analysen auch im juristischen Kontext relevant

# Aktuelle Analysebeispiele aus den USA / zur Arbeit des Supreme Court

- Umgang mit Lexika und lexikalischer Bedeutung (Mouritsen 2010)
- Autorenschaft anhand des Schreibstils am Supreme Court (Rosenthal & Yoon 2011)
- Nachweis veränderter Aufgabenverteilung am Supreme Court durch die Untersuchung stilistischer Unterschiede in den Entscheidungen (Carlson et al. 2016)
- Längsschnittstudie (50 Jahre) zur Entwicklung der Urteile des Supreme Court (Livermore et al. 2017)
- Analyse einzelner Richter, hier: Neil Gorsuch (Varsava 2018)

# Aktuelle Analysebeispiele aus dem deutschsprachigen Bereich – Überblick

- Wandel des Staatsbegriffs in einem Schweizer Textkorpus (Abegg & Bubenhofer 2016)
- Analyse der Grundrechtsverletzungen in erfolgreichen Verfassungsbeschwerden (Wendel 2020)
- Begriffsanalyse zu „geschäftsmäßig“ in der juristischen Fachsprache und im allgemeinen Sprachgebrauch durch Vergleich DeReKo/JuReKo (Vogel 2019)
- Untersuchung der Varietäten der deutschen Rechtssprache (Mielke & Wolff 2013, 2016, Berteloot et al. 2018, Auer et al. 2019)

# Designziele für eine Analyseplattform

- Technisch:
  - Nutzung aktueller NLP-Frameworks und -Bibliotheken
- Inhaltlich / juristisch
  - Aufbau eines Textkorpus aus frei zugänglichen juristischen Texten
  - Analyse von EuGH-Entscheidungen

# Datengrundlage EuGH-Urteile

- Import über das API von EUR-LEX, Nutzung der dort verfügbaren Webservices
- Volltext und Metadaten verfügbar
- 24 Sprachversionen
- Zusätzliche Metadaten
- Insg. ca 6.000 Dokumente – pro Sprachversion
- Textumfang ca. 1,2 GB

Database Name	Storage Size ▼	Collections	Indexes
<b>judgment_corpus</b>	1.2GB	24	25

Collection Name ▲	Documents	Avg. Document Size	Total Document Size
<b>judgments_bg</b>	5,555	6.6 KB	35.8 MB
<b>judgments_cs</b>	5,555	7.7 KB	41.8 MB
<b>judgments_da</b>	5,555	42.2 KB	229.0 MB
<b>judgments_de</b>	5,555	44.4 KB	240.8 MB
<b>judgments_el</b>	5,555	77.6 KB	420.9 MB
<b>judgments_en</b>	5,554	44.0 KB	238.9 MB

Fischer et al. 2020b, 9

```
_id: ObjectId("5f6cad54f7fb5c7af6db16b5")
reference: "d1c1196f-2248-4b88-93e4-6c4cf337073e_en"
title: "Judgment of the Court of 16 July 1956. # Fédération Charbonnière de Be..."
text: "Avis juridique important | 61955J0008 Judgment of the Court of 16 July..."
keywords: "++++ 1 . PROCEDURE - APPLICATION FOR ANNULMENT - DECISIONS OF THE HIGH..."
parties: "IN CASE 8/55 FEDERATION CHARBONNIERE DE BELGIQUE, REPRESENTED BY LOUIS..."
subject: "APPLICATION FOR THE ANNULMENT OF DECISION NO 22/55 OF THE HIGH AUTHORI..."
endorsements: "UPON READING THE PLEADINGS; UPON HEARING THE PARTIES; UPON HEARING THE..."
grounds: "P . 255 A - THE ADMISSIBILITY OF THE APPLICATION THE APPLICATION SEEKS..."
decisions_on_costs: null
operative_part: "THE COURT HEREBY : 1 . DECLARES THAT THE APPLICATION IS ADMISSIBLE; 2 ..."
celex: "61955CJ0008"
> author: Object
> subject_matter: Object
> case_law_directory: Object
  ecl: "ECLI:EU:C:1956:7"
  date: 1956-07-16T00:00:00.000+00:00
  case_affecting: null
> applicant: Object
> defendant: Object
  affected_by_case: null
> procedure_type: Object
```

## Übernahme des EUR-LEX-Datenmodells in MongoDB

Fischer et al. 2020b, 11

# Technische Konzeption und Umsetzung

- Dokumentakquise, Steuerung: Python
- Persistenzschicht; MongoDB (NOSQL-Datenbank)
- Redis / Celery zur Unterstützung der Datenverarbeitung
- Abfragemodell auf der Basis von JSON
- Projektmanagement: Trello (Scrum), GitHub

# Verarbeitung der Urteile mit NLP-Komponenten

- Nutzung aktueller NLP-Frameworks
  - spaCy
  - textaCy
  - Stanza
- Nutzung vortrainierter Sprachmodelle:
  - Englisch-Blackstone-Modell des *Incorporated Council of Law Reporting for England and Wales*
  - Deutsch: SpaCy-Modell auf der Basis bekannter (nicht-juristischer) Korpora



BLACKSTONE

# Open source natural language processing for Legal Texts

**Blackstone** is a spaCy model and library for processing long-form, unstructured legal text. Blackstone is an experimental research project from the Incorporated Council of Law Reporting for England and Wales' research lab, ICLR&D.

Mielke / Wolff · Korpuslinguistische Plattform für EuGH-Urteile · 27. Februar 2020 · IRIS 2021

<https://research.iclr.co.uk/blackstone>

# Textanalyse-Komponenten I

- Vorbereitung der Dokumente / Preprocessing
- Normalisierung der Materialien
- Einteilung der Texte in einzelne Token
- Part-of-Speech-Tagging (POS Tagging)
- Erkennung von Eigennamen (named entity recognition)
- linguistische Verarbeitungsschritte
- Grundformreduktion / Lemmatisierung
- Erkennung auffälliger N-Gramme / Kollokationen

# Textanalyse-Komponenten II

- Schlagwortextraktion (PositionRank-Verfahren)
- Berechnung einer paarweisen Dokumentähnlichkeit (Word Embeddings-Verfahren)
- Metriken zur Lesbarkeit (Flesch-Reading-Ease, aus TextaCy)
- Sentiment-Analyse

# Abfragebeispiel: Bigramme / Lesbarkeit

```
{
  "language": "en",
  "corpus": [
    {
      "column": "date",
      "start date": "1958-07-17",
      "end date": "1959-07-17"
    }
  ],
  "analysis": [
    {
      "type": "n-grams",
      "n": 2,
      "limit": 10
    },
    {
      "type": "readability"
    }
  ]
}
```

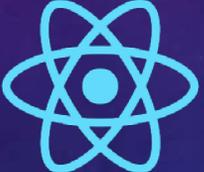
```
{
  "n-grams": [
    [
      "high authority",
      106
    ],
    [
      "ecsc treaty",
      30
    ],
    [
      "decisions nos",
      28
    ],
    [
      "common market",
      20
    ],
    [
      "national law",
      17
    ]
  ],
  "readability": 31.067219480746996
}
```

# Was leisten die trainierten Modelle? Beispiel Blackstone (<https://research.iclr.co.uk/blackstone>)

CASENAME	Case names	Smith v Jones, In re Jones, In Jones' case
CITATION	Citations (unique identifiers for reported and unreported cases)	(2002) 2 Cr App R 123
INSTRUMENT	Written legal instruments	Theft Act 1968, European Convention on Human Rights, CPR
PROVISION	Unit within a written legal instrument	section 1, art 2(3)
COURT	Court or tribunal	Court of Appeal, Upper Tribunal
JUDGE	References to judges	Eady J, Lord Bingham of Cornhill



# Benutzerschnittstelle und Visualisierung

- Realisierung als Web-App
- Implementierung mit JavaScript / React.js 
- Abfrage von Metadaten
- Frei wählbare Analyseschritte

## Justice Demo

Quick Search

Language

Author

To

Celex

Participants

Judge

From

Title

Analysis

+ N-Grams

+ Tokens

+ Word Count

✓ Sentences

✓ Readability

+ Token Count

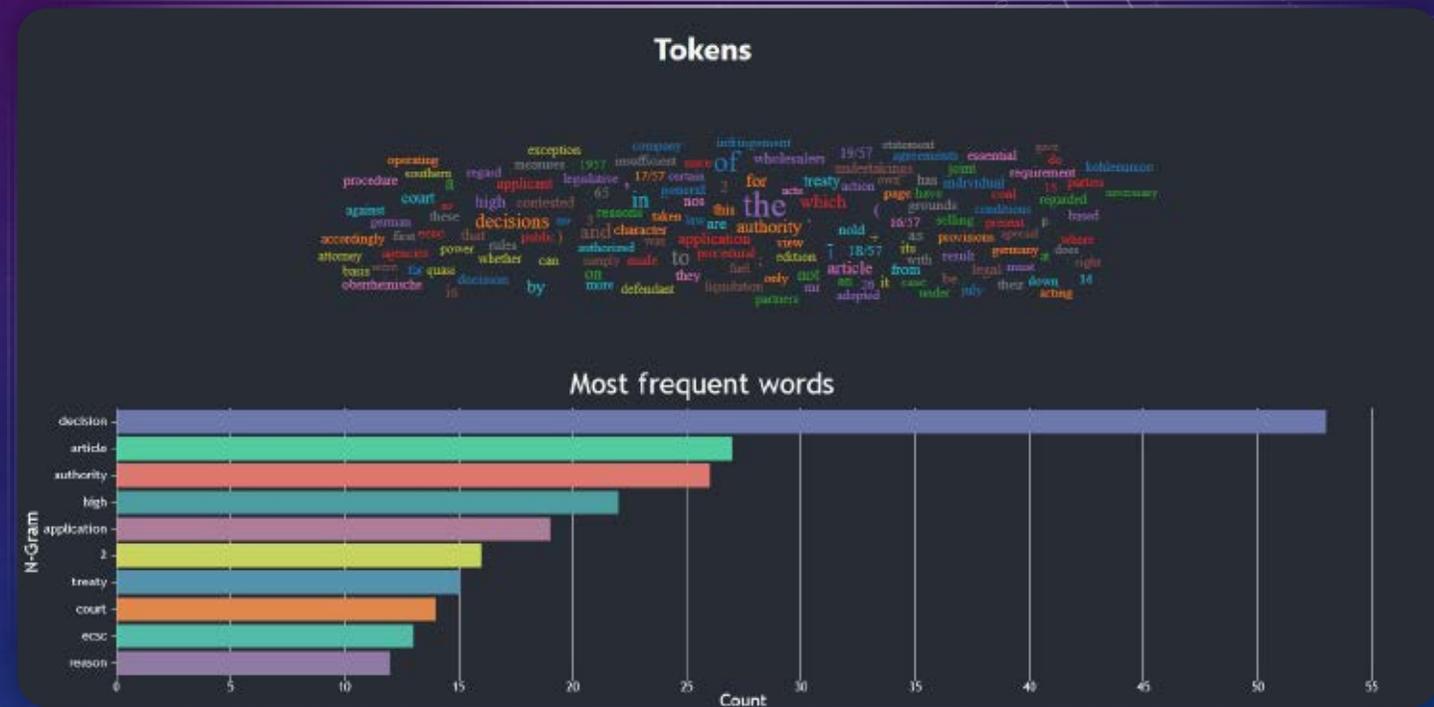
+ Most Frequent Words

+ Sentence Count

Submit Query

# Benutzerschnittstelle / Visualisierung

- Unterschiedliche Visualisierungsformate je nach Abfragetyp, z. B. Balkendiagramme und Wortwolken



Fischer et al. 2020b, 18

# Danksagung

- Entwicklung der Workbench: Praxisseminar im Master Medieninformatik, SS 2020
  - Thomas Fischer
  - Philipp Hartl
  - Andreas Hilzenthaler
  - Lukas Jackermeier
- Fachliche Beratung: Thomas Schmidt, M. Sc., wissenschaftlicher Mitarbeiter am Lehrstuhl für Medieninformatik

# Fazit/Ausblick

- Erster lauffähiger Prototyp
- Der eigentliche Analyse-/Forschungsteil kommt noch – IRIS 2022
- Weiterführung bestehender Kooperationen (Pascale Berteloot)
- Ggf. auch Nutzung im Kontext des LL. M. Legal Tech
- Kooperation mit einer neuen Professur an der Universität Regensburg zur Digitalisierung im Recht (Digital Law) geplant

# Literatur

- ABEGG, ANDREAS/BUBENHOFER, NOAH, Empirische Linguistik im Recht: Am Beispiel des Wandels des Staatsverständnisses im Sicherheitsrecht, öffentlichen Wirtschaftsrecht und Sozialrecht der Schweiz, *Ancilla Iuris*, 2016, S. 1-41.
- CARLSON, KEITH/LIVERMORE, MICHAEL A/ROCKMORE, DANIEL, A quantitative analysis of writing style on the US Supreme Court, *Wash. UL Rev.*, 2015, 93, S. 1461.
- DEWILDE, BURTON, *textacy Documentation*, 2020, S.
- EDER, MACIEJ, Rolling stylometry, *Digital Scholarship in the Humanities*, 2016, 31, S. 457-69.
- FISCHER, THOMAS/HARTL, PHILIPP /HILZENTHALER, ANDREAS/JACKERMEIER, LUKAS (2020a), Aufbau und Analyse eines Korpus mit Entscheidungen des europäischen Gerichtshofs. Dokumentation, Lehrstuhl für Medieninformatik. Regensburg: Universität Regensburg.
- FISCHER, THOMAS/HARTL, PHILIPP /HILZENTHALER, ANDREAS/JACKERMEIER, LUKAS (2020), Aufbau und Analyse eines Korpus mit Entscheidungen des europäischen Gerichtshofs. Präsentationsmaterial , Lehrstuhl für Medieninformatik. Regensburg: Universität Regensburg.
- FLORESCU, CORINA/CARAGEA, CORNELIA (2017), Positionrank: An unsupervised approach to keyphrase extraction from scholarly documents. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 1105-15.

# Literatur

LIVERMORE, MICHAEL A/RIDDELL, ALLEN B/ROCKMORE, DANIEL N, The Supreme Court and the judicial genre, *Ariz. L. Rev.*, 2017, 59, S. 837.

MOURITSEN, STEPHEN C, The dictionary is not a fortress: Definitional fallacies and a corpus-based approach to plain meaning, *Brigham Young University Law Review* 2010, S. 1915-80.

PIOTROWSKI, MICHAEL (2013), 'Computerlinguistik und Digital Humanities', *DHd - Digital Humanities im deutschsprachigen Raum*. <https://dhd-blog.org/?p=2532>.

VARSAVA, NINA, Elements of Judicial Style: A Quantitative Guide to Neil Gorsuch's Opinion Writing, *NYUL Rev. Online*, 2018, 93, S. 75-112.

VOGEL, FRIEDEMANN /BÄUMER, BENJAMIN/DEUS, FABIAN /RÜDIGER, JAN OLIVER/TRIPPS, FELIX, Die Bedeutung des Adjektivs geschäftsmäßig im juristischen Fach- und massenmedialen Gemeinsprachgebrauch, *LeGes*, 2019, 30, S.

VOGEL, FRIEDEMANN/HAMANN, HANJO/GAUER, ISABELLE, Computer-Assisted Legal Linguistics: Corpus Analysis as a New Tool for Legal Studies, *Law & Social Inquiry*, 2018, 43, S. 1340-63.