

Semantic Analysis and Structuring of German Legal Documents using Named Entity Recognition and Disambiguation

Ingo Glaser, 25.09.2017, Final Presentation Master's Thesis

Chair of Software Engineering for Business Information Systems (sebis)
Faculty of Informatics
Technische Universität München
wwwmatthes.in.tum.de

Motivation

Research Questions

Research Approach & Objectives

Implementation

Evaluation

Conclusion

Legal Technology is rising [4]

- Digitalisation of legal documents [13]
- Increasing number of startups
- New and changing business models [7]

Unstructured and semi-structured data [16]

- Modelling and structuring of legal documents
- Understanding the content of documents
- Creating added value

Capability of systems and algorithms [18]

- Computational power increases continuously
- Technologies such as Apache Spark or Hadoop allowing even more powerful clusters
- Natural Language Processing
- Machine Learning and Data Mining

Motivation

Research Questions


Research Approach & Objectives

Implementation

Evaluation

Conclusion

Research Questions



Outline

Motivation


Research Questions

Research Approach & Objectives

Implementation

Evaluation

Conclusion



Money values

Dates

Rule-based Approaches
(e.g. Apache Ruta, RegEx)

References

Rule-based Approaches
(e.g. Apache Ruta, RegEx)

Named Entities:

- Persons
- Organizations
- Locations

Statistical (Machine Learning) Approaches
(e.g. GermaNer, Stanford NER)

Knowledge Bases
(e.g. DBPedia, OpenCalais)

Template-based NER

Monetary Values

- Absolute: 1.234 Euro;
- Relative: „50 % der Miete“;

Dates

- Absolute:
 - „15. September bis 15. Mai“
- Relativ:
 - „12 Monate nach Ende des Abrechnungszeitraums“
 - „4 Wochen nach XX“
 - „3 Monate vor Beginn der Bauarbeiten“

References

- „Teilkündigung und Verwertungskündigung §§ 573, 573a, 573b BGB“

§ 5 Versorgung mit Heizung und Warmwasser

1. Der Vermieter muss die Sammelheizung, soweit es die Witterung erfordert, mindestens aber in der Zeit vom **15. September bis 15. Mai** in Betrieb halten. Eine Temperatur von mindestens 20°C bis 22°C zwischen 6.00 und 24.00 Uhr in den beheizbaren Räumen ist zu erreichen. In der übrigen Nachtzeit sind 18°C ausreichend.

6. Der Vermieter kann eine **Nachzahlung** auf die Heiz- und Betriebskosten nur verlangen, sofern er spätestens **12 Monate** nach Ende des Abrechnungszeitraumes dem Mieter durch **schriftliche** Abrechnung **nachweist**, dass die Vorauszahlungen auf die Betriebskosten nicht ausgereicht haben. Ergibt sich ein Guthaben aus der Abrechnung für den Mieter, wird dies **unverzüglich** ausgezahlt. Eine Aufrechnung mit **bestrittenen oder nicht rechtskräftig festgestellten** Forderungen darf der Vermieter nicht vornehmen. **Einwendungen** des Mieters gegen die Abrechnung müssen dem Vermieter spätestens **12 Monate nach Zugang** der Abrechnung **mitgeteilt** werden.


7. Nachforderungen des Vermieters werden **4 Wochen nach Zugang** der **ordnungsgemäßen** Abrechnung fällig. Der Vermieter **gewährt** dem Mieter **Einsicht** in die Berechnungsunterlagen. Gegen **Erstattung** angemessener Kopier- und Portokosten kann der Mieter **verlangen**, dass ihm Kopien der Berechnungsunterlagen zugesandt werden.

§ 2 Mietzeit

Das Mietverhältnis beginnt am: _____, es läuft auf **unbestimmte Zeit**.
Die Vertragspartner streben ein längerfristiges Mietverhältnis an. Der Vermieter **verzichtet** für einen Zeitraum von **1 Jahren und 9 Monaten** auf das Recht der **identischen Kündigung** (Kündigung, welche die Einlegesprache der Teilkündigung und Verwertungskündigung §§ 573, 573a, 573b BGB). Die **Kündigung** kann somit frühestens zum Ablauf dieses Zeitraums ausgesprochen werden. Die **Kündigungsvereinbarungen** richten sich im Übrigen nach den gesetzlichen Vorschriften und den vertraglichen Absprachen (siehe §§ 8, 17 – 22 dieses Vertrages).
Hinweis: Die Mietvertragsparteien können unter § 22 dieses Mietvertrages auch einen dauerhaften oder längerfristigen **Kündigungserhalt** des Vermieters vereinbaren.


Research Approach & Objectives

Environment & IS Research



Research Approach & Objectives

Environment & IS Research (II)



Outline

Motivation

Research Questions

Research Approach & Objectives


Implementation


Evaluation

Conclusion

Implementation

GermaNER





Implementation

Template-based NER

Mietvertrag für Wohnräume

zwischen XXXXX XXXXXXXX

Vermieter

XXXXXXXXXX XX, XXXX XXXXXXXX
(Anschrift)

Telefon XXX XXXXXXXX

XXXXXX@XXXX.XX
(E-Mail-Adresse)

Mobil XXXX XXXXXXXXXX

XXXXXX XXXXXXXX
(Bevollmächtigte/r)

XXXXXXXX XX, XXXX XXXXXXXX
(Anschrift)

Telefon XXX XXXXXXXX

Mobil

und XXXXXXXXX XXXXXXXXXX
(Vor- und Zuname, Geburtsdatum, Nummer des Personalausweises/Reisepasses)

Mieter

XXXXXX XX, XXXX XXXXXXXX
(Anschrift)

Telefon XXX XXXXXXXX

max@mietner.de
(E-Mail-Adresse)

Mobil

XXXXXX XXXXXXXX
(Bankverbindung des Mieters, Name und Ort der Bank, Name des Kontoinhabers)

BLZ_

Kto.-Nr.

IBAN DEXXXXXXXXXXXXXXX BIC XXXXXXXXXX



Mietvertrag für Wohnraum TEMPLATE

Präambel

§ 1 Allgemeines

Zwischen --Vermieter--

--Vermieter.Anchrift-- Telefon --Vermieter.Telefonnummer--

--Vermieter.EMailAdresse-- Mobil --Vermieter.Mobilnummer--

--Bevollmächtigter--

--Bevollmächtiger.Anchrift-- Telefon --Bevollmächtiger.Telefonnummer--

--Bevollmächtiger.EMailAdresse-- Telefon --Bevollmächtiger.Mobilnummer--

und --Mieter--

--Mieter.Anchrift--

Telefon --Mieter.Telefonnummer--

--Mieter.EMailAdresse-- Mobil --Mieter.Mobilnummer--

--Mieter.Bankverbindung--



1. Transformation of contract model into template

2. Analysis via placeholder

- --Vermieter--
- --Vermieter.Anchrift--
- --Mieter--
- --Mieter.Mobilnummer--

3. Resolution of the placeholder

Mietvertrag für Wohnraum

§ 1 Allgemeines

Zwischen --Vermieter-- Vermieter.Anchrift-- Telefon --Vermieter.Telefonnummer--
Vermieter.EMailAdresse-- Mobil --Vermieter.Mobilnummer-- Bevollmächtigter--
Bevollmächtiger.Anchrift-- Telefon --Bevollmächtiger.Telefonnummer--
Bevollmächtiger.EMailAdresse-- Telefon --Bevollmächtiger.Mobilnummer-- und--
Mieter-- Mieter.Anchrift-- Telefon --Mieter.Telefonnummer-- Mieter.EMailAdresse--
Mobil --Mieter.Mobilnummer-- Mieter.Bankverbindung-- Elena Scenpalkova

Boltzmannstraße 3 Telefon 089 289 17100
elena.scpalkova@tum.de Mobil 0176 12345678

nicht vorhanden

nicht vorhanden Telefon nicht vorhanden

nicht vorhanden Telefon nicht vorhanden

und Bernhard Waltl

Boltzmannstraße 3, 85748 Garching bei München

Telefon 089 289 17124
b.waltl@tum.de Mobil 0176 12345678

Mustermann GmbH, Kreditinstitut: Deutsche Postbank AG, IBAN: DE18 3601 0043
9999 9999 99, BIC: PBNKDEFF

Geschäftsraum-Mietvertrages

§ 1 Parteien

Zwischen

BERNHARD WALTL

und

SINC GmbH

wird folgender Geschäftsraummietvertrag geschlossen:

§ 2 Mieträume

1. Vermietet werden im Haus Rheingaustraße 182, 65203 Wiesbaden folgende Räume:

- a. Erdgeschoss: 1
- b. 1. Etage: 3
- c. Keller: 1
- d. Dachboden: 1

Die Mietfläche beträgt 75 qm.

2. Für die oben genannten Räume erhält der Mieter folgende Schlüssel:

2 x Haustüre, 1 x Keller, 1 x Dachboden

3. Schäden an diesen Räumen sind dem Vermieter unverzüglich anzuzeigen.

4. Der Mieter ist verpflichtet, eine Glasversicherung für sämtliche Fenster-, Schaufenster- und Türscheiben der Mieträume (oder sonstige Versicherungen nach Vereinbarung, wobei eine Doppelversicherung durch Mieter und Vermieter vermieden

Geschäftsraum-Mietvertrages TEMPLATE

§ 1 Parteien

Zwischen

BERNHARD WALTL und SINC GmbH--Vermieter--

und

--Mieter--

wird folgender Geschäftsraummietvertrag geschlossen:

§ 2 Mieträume

1. Vermietet werden im Haus Rheingaustraße 182, 65203 Wiesbaden folgende Räume:

Erdgeschoss:1 1. Etage:3 Keller:1 Dachböden:1--Adresse-- folgende Räume:

- a. Erdgeschoss: --Mietobjekt.Erdgeschoss--
- b. 1. Etage: --Mietobjekt.1Etage--
- c. Keller: --Mietobjekt.Keller--
- d. Dachböden:--Mietobjekt.Dachböden--

Die Mietfläche beträgt 75 --Mietobjekt.Größe-- qm.

2. Für die oben genannten Räume erhält der Mieter folgende Schlüssel:

2 x Haustüre, 1 x Keller, 1 x Dachboden--Mietobjekt.Schlüssel--

3. Schäden an diesen Räumen sind dem Vermieter unverzüglich anzuzeigen.

4. Der Mieter ist verpflichtet, eine Glasversicherung für sämtliche Fenster-, Schaufenster- und Türscheiben der Mieträume (oder sonstige Versicherungen nach Vereinbarung, wobei eine Doppelversicherung durch Mieter und Vermieter vermieden

Implementation

Template-based NER: Negative Example

Mietvertrag für Wohnraum TEMPLATE

§ 1 Allgemeines

Zwischen --Vermieter--
--Vermieter.Anchrift-- Telefon --Vermieter.Telefonnummer--
--Vermieter.EMailAdresse-- Mobil --Vermieter.Mobilnummer--
--Bevollmächtigter--
--Bevollmächtiger.Anchrift-- Telefon --Bevollmächtiger.Telefonnummer--
--Bevollmächtiger.EMailAdresse-- Telefon --Bevollmächtiger.Mobilnummer--
und --Mieter--
--Mieter.Anchrift--
Telefon --Mieter.Telefonnummer--
--Mieter.EMailAdresse-- Mobil --Mieter.Mobilnummer--
--Mieter.Bankverbindung--

Mietvertrag für Wohnraum

§ 1 Allgemeines

Zwischen --Vermieter-- Vermieter.Anchrift Telefon Vermieter.Telefonnummer
Vermieter.EMailAdresse Mobil Vermieter.Mobilnummer Bevollmächtigter
Bevollmächtiger.Anchrift Telefon Bevollmächtiger.Telefonnummer
Bevollmächtiger.EMailAdresse Telefon Bevollmächtiger.Mobilnummer und
Mieter Mieter.Anchrift Telefon Mieter.Telefonnummer Mieter.EMailAdresse
Mobil Mieter.Mobilnummer Mieter.Bankverbindung Elena Scepankova

Boltzmannstraße 3 Telefon 089 289 17100

elena.scepankova@tum.de Mobil 0176 12345678

nicht vorhanden

nicht vorhanden Telefon nicht vorhanden

nicht vorhanden Telefon nicht vorhanden

und Bernhard Waltl

Boltzmannstraße 3, 85748 Garching bei München

Telefon 089 289 17124

b.waltl@tum.de Mobil 0176 12345678

Mustermann GmbH, Kreditinstitut: Deutsche Postbank AG, IBAN: DE18 3601 0043
9999 9999 99, BIC: PBNKDEFF

Problem

- Resolution of the placeholders, respectively greedyness of the comparative operators
- e.g. two consecutive placeholders

Next Steps

- Current implementation based on Myers' diff algorithm
- Integration into a pipeline

LEXIA

Legal Information Analysis, Exploration, and Reasoning Platform

Start your search here...



Documents




6 Laws, Patents, Judgments & Miscellaneous

Visualizations



Time Series Analysis & Occurrence Maps

Networks



Connexity, Graphs & Dependencies

Reasoning



Modelling & Logical Execution

Recommendations



Intelligent & Semantic Recommendations

Outline

Motivation

Research Questions

Research Approach & Objectives

Implementation

Evaluation

Conclusion

Semi-structured interviews

- Three areas: personal, data, technological
- Optionally additional demo

Conducted via

- Face-to-face
- Phone

Outcome

- Recognizing and highlighting Named Entities can be helpful
- Detecting more complex structures
- First implementation looks pretty promising
- Structured view of a contract would be very helpful
- A lot of lawyers still prefer printed versions

Evaluation on judgments from the 8th Zivilsenat of the German BGH

- 500 judgments from the law of tenancy
- 20 randomly selected judgments
- 25.423 tokens

Template-based NER on contracts

- 5 different contracts
- 7.790 tokens

System	Per-entity F1							Overall		
	PER	ORG	LOC	DAT	MV	REF	OTH	Precision	Recall	F1
Templated	0.88	0.77	0.82	0.86	0.88	0.93	0.71	0.94	0.91	0.92
GermaNER	0.35	0.71	0.45	0.91	0.89	0.91	0.33	0.98	0.68	0.80
DBpedia	0.51	0.76	0.52	0.91	0.86	0.91	0.59	0.87	0.87	0.87

Outline

Motivation

Research Questions

Research Approach & Objectives

Implementation

Evaluation

Conclusion

Named Entity Recognition was successfully applied to the legal domain

Incorporation of three different approaches

- Statistical machine learning based on CRF
- Knowledge-based approach with DBpedia
- Template-based approach

Lack of legal data

- Gold standards
- Training sets
- Ontologies

Named Entity Disambiguation needs further research



B.Sc.

Ingo Glaser

Technische Universität München
Faculty of Informatics
Chair of Software Engineering for Business
Information Systems

Boltzmannstraße 3
85748 Garching bei München

Tel +49.89.289.17138
Fax +49.89.289.17136

ingo.glaser@tum.de
wwwmatthes.in.tum.de



Bibliography

- [1] Aizawa, A., "An information-theoretic perspective of tf-idf measures", *Information Processing & Management*, vol. 39, no. 1, pp. 45-65, 2003.
- [2] Bauer, L., "Introducing linguistic morphology", 2nd ed. Washington, D.C.: Georgetown University Press, 2003, pp. x, 366 p.
- [3] Benikova, D., Muhie, S., Prabhakaran, Y., and Biemann, S.C., "C.: GermaNER: Free Open German Named Entity Recognition Tool", in In: Proc. GSCL-2015, 2015: Citeseer.
- [4] Boston Consulting Group, "How Legal Technology Will Change The Business of Law", 2016, Bucerius Law School
- [5] Beeferman, D., Berger, A., and Lafferty, J., "Statistical Models for Text Segmentation", *Machine Learning*, journal article vol. 34, no. 1, pp. 177-210, 1999.
- [6] Choi, F. Y. Y., "Advances in domain independent linear text segmentation", presented at the Proceedings of the 1st North American chapter of the Association for Computational Linguistics conference, Seattle, Washington, 2000.
- [7] Deloitte, "Digitisation of Documents and Legal Archiving", 2014
- [8] Habash, N., Rambow, O., and Roth, R., "MADA+ TOKAN: A toolkit for Arabic tokenization, diacritization, morphological disambiguation, POS tagging, stemming and lemmatization", in Proceedings of the 2nd international conference on Arabic language resources and tools (MEDAR), Cairo, Egypt, 2009, vol. 41, p. 62.
- [9] Hashmi, M., "A Methodology for Extracting Legal Norms from Regulatory Documents", 2015, IEEE 19th International Enterprise Distributed Object Computing Workshop

Bibliography (II)

- [10] Hakimov, S., Oto, S. A. & Dogdu, E., "Named Entity Recognition and Disambiguation using Linked Data and Graph-based Centrality Scoring", 2012, SIGMOD
- [11] Lavrac, N., Mladenic, D. & Erjavec, T., "Ripple Down Rule learning for automated word lemmatisation", AI Communications, vol. 21, no. 1, pp. 15-26, 2008.
- [12] Rajaraman, A.U., "JD (2011)." Data Mining", Mining of Massive Datasets, pp. 1-17
- [13] Saravanan, M., Ravindran, B. & Raman, S., "Improving Legal Information Retrieval Using an Ontological Framework", 2009, Artificial Intelligence and Law
- [14] Singh, J. & Gupta, V., "Text Stemming: Approaches, Applications, and Challenges", ACM Comput. Surv., vol. 49, no. 3, pp.
- [15] Stevenson, M., & Wilks, Y., "Word sense disambiguation", The Oxford Handbook of Comp. Linguistics, pp. 249-265, 2003.
- [16] Svyatkovskiy, A., Imai, K., Kroeger, M., & Shiraito, Y., "Large-scale Text Processing Pipeline with Apache Spark", 2016, IEEE International Conference on Big Data
- [17] Von Alan, H. R., March, S. T., Park, J., Ram, S., "Design science in information systems research", 2004, MIS quarterly, vol. 28, pp. 75-105.
- [18] Waltl, B., Landthaler, J., Scepankova, E., Matthes, F., Geiger, F., Stocker, C., Schneider, C., "Automated Extraction of Semantic Information from German Legal Documents", 2017, Internationales Rechtsinformatik Symposium, Salzburg

Backup Slides

Evaluation

Quantitative: Evaluation Data Set Judgments



NE Types	PER	ORG	LOC	DAT	MV	REF	OTH	O
Count	114	106	45	267	78	310	182	24314

Evaluation

Quantitative: GermaNER Confusion Matrix

Tokens	Gold							
	PER	ORG	LOC	DAT	MV	REF	OTH	O
PER	24	0	0	0	0	0	0	0
ORG	0	59	2	0	0	0	0	0
LOC	0	0	14	0	0	2	0	1
DAT	0	0	9	229	0	0	0	0
MV	0	0	0	0	62	0	0	0
REF	0	0	2	0	2	261	0	0
OTH	6	9	9	2	7	1	44	7
O	84	38	9	36	7	46	138	24306

Tokens	Gold							
	PER	ORG	LOC	DAT	MV	REF	OTH	O
PER	40	0	0	0	0	0	0	0
ORG	0	67	2	0	0	0	0	0
LOC	10	12	28	0	0	0	1	11
DAT	1	0	9	229	0	0	0	0
MV	0	0	0	0	62	0	0	0
REF	0	0	1	0	0	261	0	0
OTH	32	25	3	2	8	3	165	137
O	34	4	2	31	8	46	16	24193

	GermaNER			DBpedia		
	Precision	Recall	F1	Precision	Recall	F1
PER	1.00	0.21	0.35	1	0.34	0.51
ORG	0.97	0.56	0.71	0.97	0.62	0.76
LOC	0.82	0.31	0.45	0.45	0.62	0.52
DAT	0.96	0.86	0.91	0.96	0.86	0.91
MV	1	0.79	0.89	1	0.79	0.86
REF	0.98	0.84	0.91	0.99	0.84	0.91
OTH	0.52	0.24	0.33	0.44	0.91	0.59
Overall	0.98	0.68	0.8	0.87	0.87	0.87

Evaluation

Quantitative: Evaluation Data Set Contracts



NE Types	PER	ORG	LOC	DAT	MV	REF	OTH	O
Count	14	8	23	38	23	25	46	7614

Tokens	Gold							
	PER	ORG	LOC	DAT	MV	REF	OTH	O
PER	11	0	0	0	0	0	0	0
ORG	0	5	0	0	0	0	0	0
LOC	0	3	16	0	0	0	1	0
DAT	0	0	0	31	0	0	5	2
MV	0	0	0	0	18	0	1	1
REF	0	0	0	0	0	19	0	0
OTH	0	0	4	6	4	3	34	8
O	3	0	3	1	1	3	5	7603