

Wie grundlegende Text Mining Verfahren uns im aktuariellen Alltag weiterhelfen

Corinna Walk
viadico GmbH



DAV

DEUTSCHE
AKTUARVEREINIGUNG e.V.



DGVFM

DEUTSCHE GESELLSCHAFT
FÜR VERSICHERUNGS- UND
FINANZMATHEMATIK e.V.

DAV/DGVFM-Jahrestagung, 26.–28. April 2023



Agenda

1

Motivation

2

Was ist Text Mining?

3

Use Case 1 – bAV-Geschäft digitalisieren

4

Use Case 2 – Migration von Freitext-Feldern

5

Fazit und Ausblick



Agenda

1

Motivation

2

Was ist Text Mining?

3

Use Case 1 – bAV-Geschäft digitalisieren

4

Use Case 2 – Migration von Freitext-Feldern

5

Fazit und Ausblick

Umfrage

Wie sind Ihre bisherigen Kenntnisse / Erfahrungen mit Text Mining?

A Text Mining ist für mich unbekannt.

B Die grundlegende Funktionsweise ist mir bekannt.

C Ich habe bereits Text Mining angewandt.

Motivation



Versicherungsunternehmen



Viele Dokumente



Viele manuelle Prozesse



Unstrukturierte Texte



Eigene Sprache der Dokumente, z.B.
Versicherungsbedingungen, Verträge, Notizen



Mit Text Mining im Versicherungsumfeld manuelle Prozesse erleichtern, um dadurch Muster, Beziehungen und Informationen aus Texten abzuleiten.

Textdateien in Versicherungsunternehmen



Tarifpläne

Automatisiertes Auslesen von Informationen



Dokumente von den Sachverständigen

Betrugserkennung



Polizeiberichte über Unfälle

Unterstützung in der Leistungsbearbeitung



Verträge, AVB'en, Leistungspläne

Automatisiertes Auslesen von Informationen



Freitextfelder Bestandsführungssystem

Clustering für eine bevorstehende Migration



Kundenkommunikation

Klassifikation von Eingangspost



Kundenfeedback: Umfragen, E-Mails

Verbesserung Kundenmanagement



Social Media, Internet

Extrahieren von zusätzlichen Informationen

Die Anzahl der Dokumente, deren Analyse einem Unternehmen Vorteil bringen können, nimmt kontinuierlich zu.



Agenda

1

Motivation

2

Was ist Text Mining?

3

Use Case 1 – bAV-Geschäft digitalisieren

4

Use Case 2 – Migration von Freitext-Feldern

5

Fazit und Ausblick

Text Mining - Vorgehen

Analyse der Daten



- Datenauswahl
- Datendigitalisierung
- Datenbereinigung
- Datenintegration

Preprocessing



- Stemming
- Lemmatisierung
- Bag-Of-Words
- Part-Of-Speech-Tagging
- Word Embeddings
- Hand-Crafted-Features

Modellanwendung



- Clustering
 - *k*-means
- Klassifizierung
 - Entscheidungsbäume
 - Naive Bayes
 - Neuronale Netze

Interpretation



- Interpretation
- Visualisierung

Analyse der Daten

Analyse der Daten



- Datenauswahl
- Datendigitalisierung
- Datenbereinigung
- Datenintegration

UNTERSUCHUNG DER ROHDATEN

- **Auswahl der geeigneten Daten**
- **Wovon handeln die Texte? Welche Inhalte haben sie?**
→ Vertrag, Kundenbrief, interne Dokumente, ...
- **In welchen Formaten liegen die Dateien vor?**
→ pdf, docx, ...
- **Ist eine Struktur vorhanden?**
→ Nummerierung, Absätze, Paragraphen, Teile des Dokuments ...

Preprocessing

Preprocessing



- Stemming
- Lemmatisierung
- Bag-Of-Words
- Part-Of-Speech-Tagging
- Word Embeddings
- Hand-Crafted-Features

PREPROCESSING

Umwandlung der Texte in eine für die Analyse geeigneten Form:

- 1. Tokenisierung:** Zerlegung des Fließtextes in seine Komponenten, sog. Tokens
- 2. Umformung des Textes** in Kleinbuchstaben
- 3. Entfernen von Sonderzeichen:** Wie z.B. Punkt, Komma,...
- 4. Entfernen der Stoppwörter:** Wörter, die keine Aussagekraft haben ("Füllwörter")
- 5. Stemming:** Reduzieren auf einen Wortstamm z.B. "Vertrages", "Verträge" → "Vertrag"

Weitere Aufbereitung des Textes:

- 6. Part-Of-Speech-Tagging:** Zuordnung der Wortart zu den Tokens
- 7. Hand-Crafted-Features:** Z.B. nur Großbuchstaben, Zahlen, Anzahl Zeichen
- 8. Word Embeddings:** Darstellung von Wörtern als Vektoren

Preprocessing

Preprocessing



- Stemming
- Lemmatisierung
- Bag-Of-Words-Modell
- Part-Of-Speech-Tagging
- Word Embeddings
- Hand-Crafted-Features

PREPROCESSING

Bag-Of-Words/Dokument-Term-Matrix (DTM):

- Es wird gezählt, wie oft jedes Wort vorkommt.
- Diese Information wird in eine Matrix geschrieben, d.h.
 - in jeder Zeile stehen die Wörter des jeweiligen Textes,
 - jede Spalte steht für ein vorkommendes Wort.

	Wort1	Wort2	Wort3	...
Text1	3	0	1	...
Text2	0	2	1	...
Text3	1	2	2	...
...

TF-IDF (Term Frequency-Inverse Dokument Frequency)

- Term Frequency: Häufigkeit eines Wortes in einem Dokument
- Inverse Dokument Frequency: Bedeutung eines Wortes in einer Sammlung von Dokumenten
→ Wörter, die in allen Dokumenten häufig vorkommen, werden weniger gewichtet.

	Wort1	Wort2	Wort3	...
Text1	0,25	0,5	0,1	...
Text2	0,4	0,2	0,01	...
Text3	0,22	0,33	0,06	...
...

Modellanwendung - Clustering

Modellanwendung



- Clustering
 - *k*-means
- Klassifizierung
 - Entscheidungsbäume
 - Naive Bayes
 - Neuronale Netze

CLUSTERANALYSE

Methode zur Erkennung von Mustern und Gemeinsamkeiten in den Dokumenten

- **Unterteilung der Daten** in unterschiedliche Gruppen
- **Gruppen** sollen sich **untereinander unterscheiden**
- **Dokumente** innerhalb einer Gruppe sollen **Ähnlichkeiten aufweisen**

Populäre Ansätze:

k-means-Algorithmus

Finden von *k* Clustern im Datensatz durch wiederholte Neuberechnung der Schwerpunkte von Cluster (über Mittelwert).

Hierarchische Clusteranalyse

In jedem Schritt werden zwei Cluster mit dem kleinsten Abstand voneinander zu einem verschmolzen.

Modellanwendung - Klassifizierung

Modellanwendung



- Clustering
 - *k*-means
- Klassifizierung
 - Entscheidungsbäume
 - Naive Bayes
 - Neuronale Netze

KLASSIFIZIERUNG

Einteilung der Daten in vordefinierte Klassen

- **Ausgangssituation:** Bereits klassifizierte Dokumente verfügbar (manuell, durch Clustering...)
- **Ziel:** Einordnung neuer unbekannter Dokumente in eine der Klassen

Populäre Ansätze:

Entscheidungsbäume

Aufgrund der extrahierten Merkmale werden Entscheidungen über die Zugehörigkeit zu der Klasse getroffen.

Neuronale Netze

Basieren auf der Idee der Informationsübertragung im menschlichen Nervensystem.

Naive Bayes

Für jedes Dokument wird die Wahrscheinlichkeit der Klassenzugehörigkeit berechnet und die höchste ausgewählt.

Interpretation

Interpretation



- Interpretation
- Visualisierung

INTERPRETATION DER ERGEBNISSE

Clustering

- Anzahl der Cluster ist optimal, wenn sich die Homogenität der Dokumente innerhalb des Clusters nicht mehr signifikant ändert. → Kurve flacht im Plot ab
- Nach Entscheidung für Clusteranzahl können Abstände der Daten zu den Schwerpunkten berechnet werden.

Klassifizierung

- Mit einem Teil der manuell/im Voraus den Klassen zugeordneten Dokumenten werden Modelle trainiert (Trainingsdaten).
- Diese werden aufgrund der übrigen Dokumente (Testdaten) auf ihre Güte geprüft.
- Dafür werden verschiedene Metriken verwendet, z.B. Trefferquote → Verhältnis von richtig zugeordneten zu allen Dokumenten.

Nach dem Vergleich der Resultate für verschiedene Modelle wird das für das Problem bestgeeignete gewählt.



Agenda

1

Motivation

2

Was ist Text Mining?

3

Use Case 1 – bAV-Geschäft digitalisieren

4

Use Case 2 – Migration von Freitext-Feldern

5

Fazit und Ausblick

Use Case 1 – bAV-Geschäft digitalisieren

Ziel	Automatisiertes Auslesen von Informationen aus Kollektiv-Rahmenverträgen (KRV)	
Vorgehen	Text Mining Verfahren: 1. Clustering der Absätze / Paragraphen 2. Herauslesen der Informationen aus den jeweiligen Absätzen	
Datenbasis	Ca. 26.000 Kollektiv-Rahmenverträge	
Idee	Basis ist ein Paper aus dem juristischen Bereich (<i>Chalkidis I., Androutsopoulos I., Michos A. (2018): Extracting contract elements</i>)	

Use Case 1 – Motivation

Gründe für den Use Case / Handlungsbedarf im bAV-Umfeld



Versicherer haben eine Vielzahl von Dokumenten abgelegt, die nicht systematisch analysiert werden.



Auskunft über bestehende Verträge meistens manuell durch Sachbearbeiter.



Digitalisierung von Kollektiv-Rahmenverträge bisher noch unüblich.



Beim Übertragen in ein neues System müssen die Daten manuell per Hand herausgesucht und eingetragen werden.

Anwendungsgebiete

1

Einmalige Anwendung:

Migration – alte Daten sollen automatisch eingelesen und Informationen sollen zum größten Teil automatisch in das Neusystem gefüllt werden.



Mehrfache Anwendung:

- Digitalisierung neuer Rahmenverträge
- Auskunftszwecke

Probleme / Schwierigkeiten

Problem

Viele Textdateien zu einem Vertrag, z.B. Verträge (KRV), Versicherungsbedingungen, Schriftwechsel, Nachtrag, ...

Dokumente sind in unterschiedlichen Ordnerstrukturen und mit verschiedenen Dokumententiteln abgelegt

Unterschiedliche Datenformate: Word, eingescannte pdf, beschreibbare pdf

Lösung



Im ersten Schritt Fokus nur auf Verträge



Manuelles Heraussuchen der Dokumente



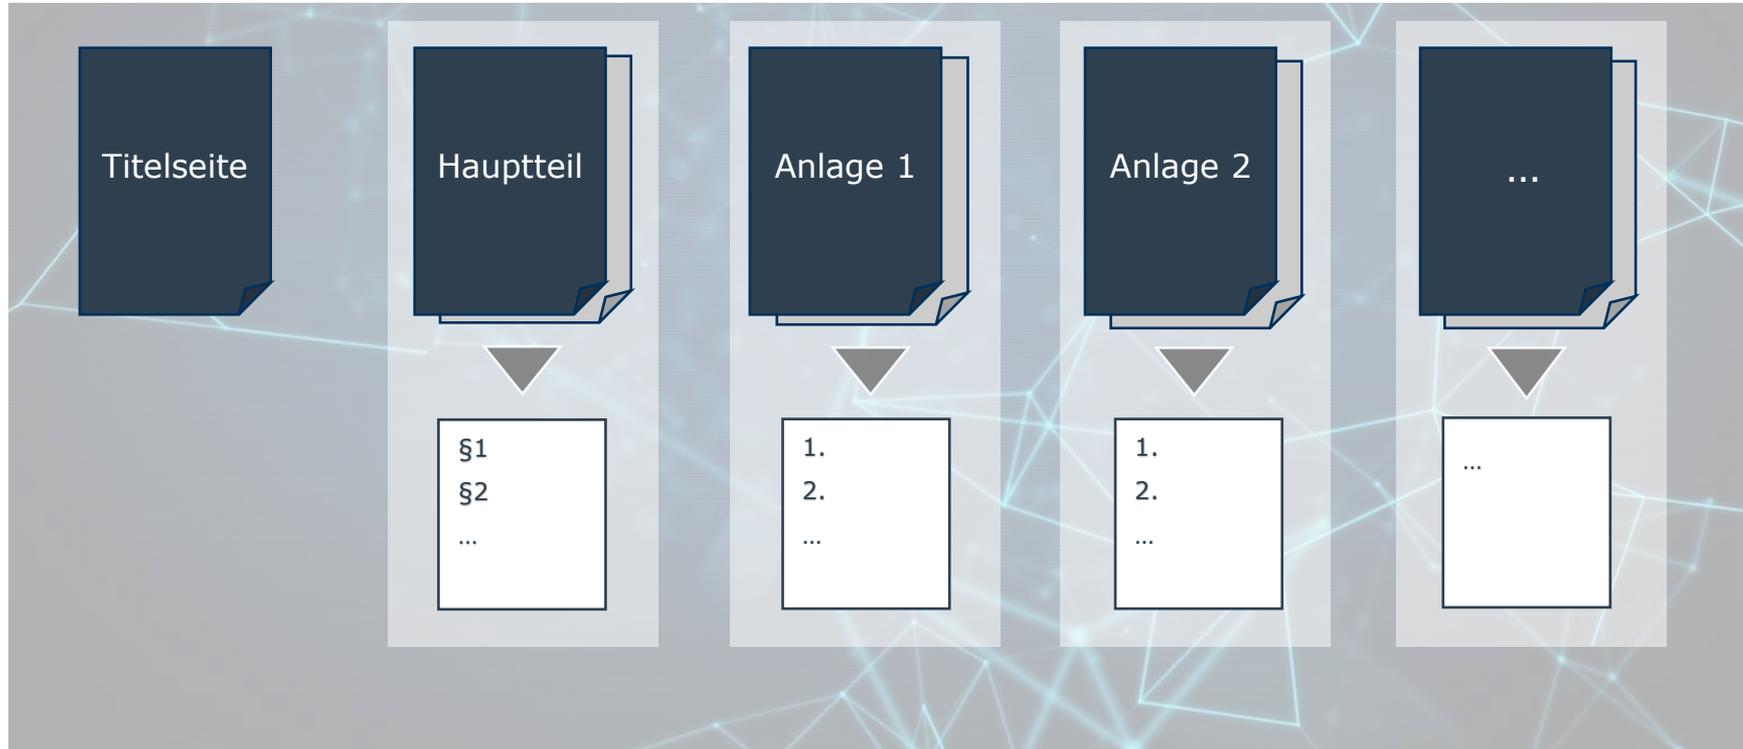
Fokus auf Word-Dokumente

Für ein erstes POC werden 81 Kollektiv-Rahmenverträge ausgewählt

Unser Vorgehensmodell



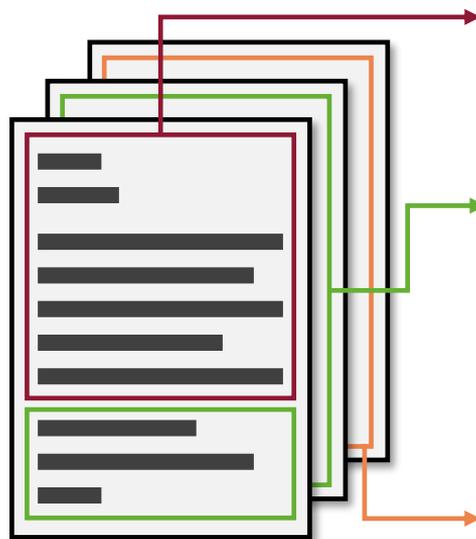
Aufbau Kollektiv-Rahmenvertrag



Erkennen der Extraktionszonen

Aufteilung in **Titelseite**, **Hauptteil** und **Anhang**

1. Erkennen der Extraktionszonen



Titelseite: Informationen über

- beteiligte Unternehmen
- Vertragsnummer

Hauptteil:

- Abtrennung zum Hauptteil durch Unterschrift und Unterschriftendatum der beiden Firmen am Ende
- Paragraphen regeln die generellen Vereinbarungen zwischen dem VU und dem VN (hier Firma)
- Aufgeteilt in Paragraphen

Anhang:

- Aufgeteilt in Aufzählungen
- Konkrete vertragliche Ausgestaltung, z.B. mögliche Tarifförmern, Arbeitgeber- oder Arbeitnehmerfinanzierung, ...



Bsp. nach dem Preprocessing

Array nach dem Tokenisieren:

0	1	2	3	4	5	6			
§1	Personenkreis	Versicherungsnehmer	1.	Versichert	werden	alle	Arbeitne		
§2	Leistungsbeschreibung	Die	Vertragsparteien	vereinbaren	Versicherungsschutz	im	Rahmen	einer	...
§3	Gesundheitsprüfung	Es	ist	keine	Gesundheitsprüfung	erforderlich			
§4	Neuzugang	Risikoprüfung	1.	Personen	die	die	Voraussetzungen	für	
...

- 2. Tokenisieren,
- 3. Stoppwörter entfernen,
- 4. Stemming

Array nach dem Preprocessing:

0	1	2	3	4	5	6	7	8	...
1	personenkreis	versicherungsnehmer	1	versichern	alle	arbeitnehmer	...		
2	leistungsbeschreibung	vertragsparteien	vereinbaren	versicherungsschutz	rahmen	...			
3	gesundheitsprüfung	keine	gesundheitsprüfung	erforderlich	...				
4	neuzugang	risikoprüfung	1	personen	voraussetzungen	...			



Erstellen der DTM für die Paragraphen im Hauptteil

- Die verbleibenden Wörter werden gezählt und in eine Matrix geschrieben
- Größe der Matrix:
 - 1012 Zeilen
 - 780 Spalten

5. Erstellen der DTM

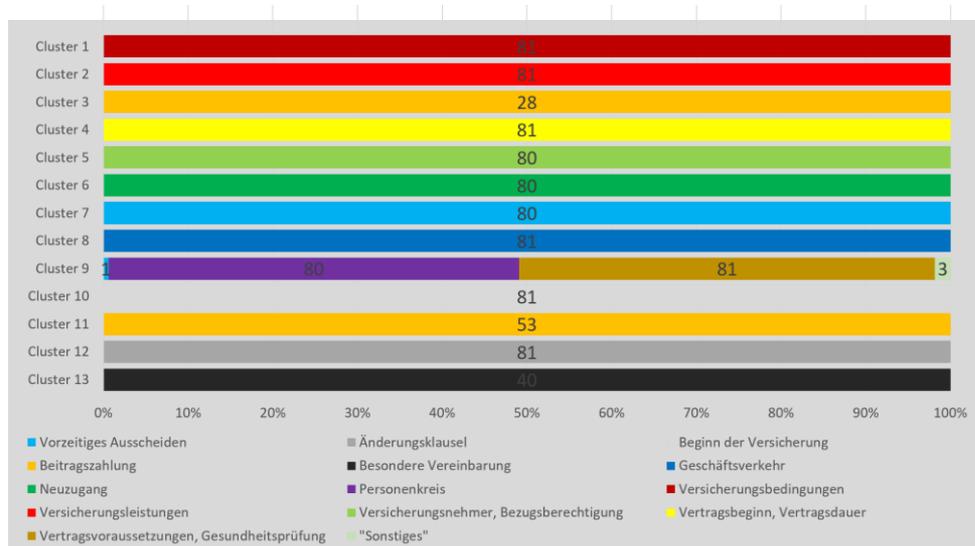
	ab	aband	abander	abendrot	aber	abgab	abgegeben	abgesch	abgesehen	ablauf	abmeld	abrechn	abs	absatz	abschlies	abschluss	abtret	abweich	abzuand	abzufuhr	abzug	abzuschl	adress	ag	agg	agrargen	aktuell	all
Änderungsklausel 1	1	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	2	0	0	0	2
Änderungsklausel 10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 29	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	3
Änderungsklausel 3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Änderungsklausel 31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Clustering der Paragraphen

Methodischer Ansatz

- Verwendeter Algorithmus:
k-means
- Clustering für Paragraphen und Absätze getrennt
- Ermittlung der Klassen:
 - Beitragszahlung
 - Personenkreis
 - Vertragsbeginn
 - ...

Ergebnis Clustering



- ! Anhand bekannter Daten war die Genauigkeit sehr hoch, d.h. die gefundenen Cluster sind sehr homogen

Herauslesen von Informationen aus den Klassen

Nach dem Clustering / Aufteilen in Paragraphen und Absätze:

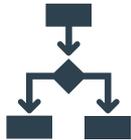
- Herauslesen von Informationen aus den gefundenen Cluster:
 - Z.B.: Versicherte Tarife, Vorschüssige / Nachschüssige Rentenzahlung,...
- Manuelles Labelling notwendig (Überwachtes Lernverfahren)
- *Methoden:* Neuronale Netze, Naive Bayes, Entscheidungsbäume
- *Ansätze:*
 - **Hand-Crafted-Features:** Informationen über Anzahl der Großbuchstaben, Zahlen können dem Modell mitgegeben werden
 - **Part-Of-Speech-Tagging:** Informationen über Wortarten werden berücksichtigt
 - **Word Embeddings**
 - Berücksichtigung von Abhängigkeiten durch Fenster von 5-10 Wörter davor und danach

Ergebnis



Clustering:

- Sehr gute Zuordnung der verschiedenen Paragraphen und Abschnitte
- Gute Basis für weitere Methodenanwendung um Komplexität zu verringern



Klassifizierung:

- Aus den im ersten Schritt erstellten Cluster können einfache Informationen wie Tarif, Rentenzahlweise, ... gut herausgelesen werden.
- Wenn Abhängigkeiten betrachtet werden (z.B. für Daten), sind Fenster aus mehreren Wörtern hilfreich.



Agenda

1

Motivation

2

Was ist Text Mining?

3

Use Case 1 – bAV-Geschäft digitalisieren

4

Use Case 2 – Migration von Freitext-Feldern

5

Fazit und Ausblick

Use Case 2 - Migration von Freitext-Feldern

<p>Ziel</p>	<p>Clustering von Freitexten / Notizen zu Verträgen für eine Migration</p>	
<p>Anwendung</p>	<p>Bei Migration der Verträge sollen nicht alle Texte 1:1 übernommen werden → Clustering in fachlich sinnvolle Gruppen</p>	
<p>Datenbasis</p>	<p>Ca. 78.000 Freitexte / Notizen aus einem Bestandsführungssystem</p>	
<p>Vorgehen</p>	<p>Text Mining Verfahren: Clustering der Texte mit <i>k</i>-means</p>	

Datenbeschreibung

Versicherungsnummer	Time Stamp	Betreff	Hinweistext
123456789	XX.XX.XXX X XX:XX:XX	Fondsentnahmen mit Gesundheitsprüfung	Fondsentnahmen mit Gesundheitsprüfung 10/2021: 300 EUR
123456789	XX.XX.XXX X XX:XX:XX	Abtretung	Bank XXX Tod voll - Erleben teilweise 01.01.2022 10.500,00 123456789 Nein
123456789	XX.XX.XXX X XX:XX:XX	-	Aktennotiz YY-X123 / Ursprung: 17.10.2008 / 00-123456-89 am 09.01.2015 verfügt von XX-YY12 für , Termin: 31.12.2036 am 17.10.2008 verfügt von XYZXYZ Zusagen-Nr.: 123 vollmacht für frau erika mustermann originalpost soll weiterhin an vn gehen
123456789	XX.XX.XXX X XX:XX:XX	Kundeninfo pro Quartal	zum 01.01.19 Kundeninfo an VN
123456789	XX.XX.XXX X XX:XX:XX	Bei Todesfall beachten!	Sollte die VN versterben bevor alle Kinder volljährig sind, ist gewünscht, dass Ihr Bruder Max Mustermann, geb. am 01.01.1980, wohnhaft in Teststaße.10 99999 Teststadt, die Leistung bis zur Volljährigkeit aller verwaltet.
123456789	XX.XX.XXX X XX:XX:XX	Hinweis	BEARBEITUNGSHINWEIS YY-XX02 / Ursprung: 26.03.2013 / 01-123456-78 am 08.01.2015 verfügt von XX-XXX für , Termin: 01.12.2046 am 26.03.2013 verfügt von XYZXYZ Zusagen-Nr.: 456 ESEE II
123456789	XX.XX.XXX X XX:XX:XX	Abtretung	für Bank XXX in voller Höhe
...

Insgesamte Anzahl an Wörtern (ursprüngliche Daten): 2.410.152

Insgesamte Anzahl an Wörtern (verarbeitete Daten): 1.218.982



Preprocessing

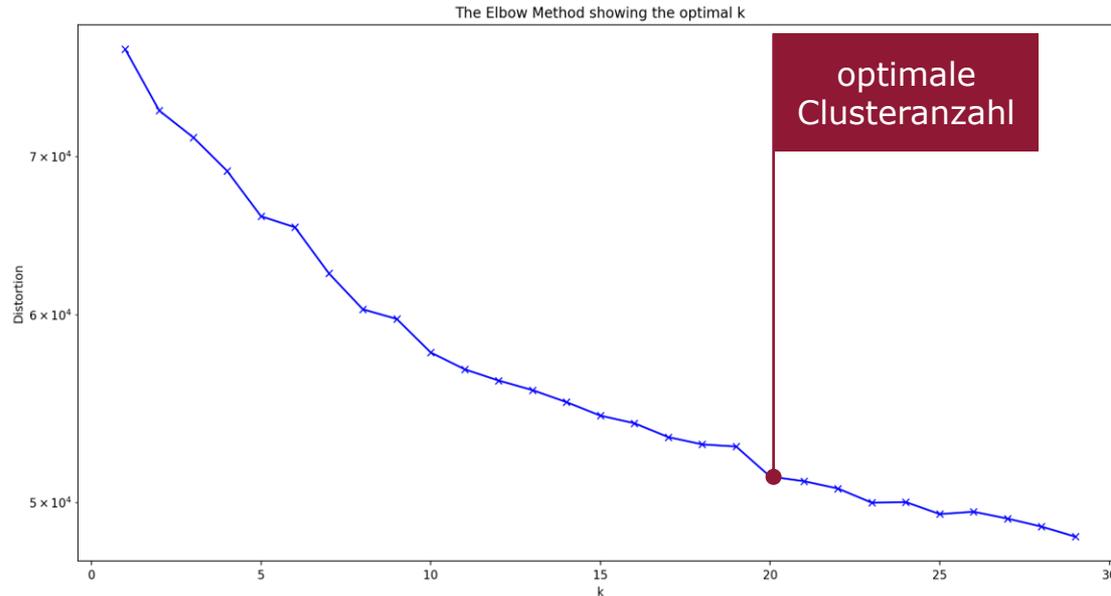
Durchgeführte Preprocessing-Schritte:

- 1) Zusammenführen der Spalten Betreff und Hinweistext
- 2) Entfernen von Sonderzeichen, Zahlen, einzelnen Buchstaben
- 3) Entfernen von Stoppwörtern und selbst gewählte Liste (Wörter die in fast allen Texten vorkommen, Mitarbeiterkürzel,...)

Weiteres Vorgehen:

- Erstellen der TF-IDF-Matrix
- Durchführen des Clusterings (mit k -means)

Wie viele Klassen sind hier sinnvoll?



Elbow-Methode liefert ~20 Cluster
→ Passt zur fachlichen Vorgabe von ca. 20 Cluster

Ergebnis

Ergebnis:

- Mit 20 Klassen konnte eine gute Aufteilung der Daten erstellt werden und ähnliche Texte gruppiert werden.
- Inhalt der Klassen konnte über die häufigsten Worte pro Cluster zugeordnet werden:
 - Cluster 0: esee, ii, vp, liegt → **Einwilligungs- und Schweigepflichtentbindungserklärung**
 - Cluster 1: dynamik, ende, erhöhung, beitragszahlungsdauer → **Regelung zum Dynamikende**

Nutzen:

- Fachbereich konnte dadurch bei der Einsortierung der Texte unterstützt werden.
- Bei Migration konnten die Klassen über Text Mining Verfahren erkannt und nach einer fachlichen Überprüfung übernommen werden.
 - Reduktion von manuellem Aufwand

Verbesserungspotential:

- Bei vielen Einteilungen blieb ein größeres Cluster übrig.
- Bessere Separierung durch mehr Vorverarbeitung möglich?
- Oder ist hier eine Erhöhung der Klassenanzahl nötig?



Agenda

1

Motivation

2

Was ist Text Mining?

3

Use Case 1 – bAV-Geschäft digitalisieren

4

Use Case 2 – Migration von Freitext-Feldern

5

Fazit und Ausblick

Fazit und Ausblick

Ergebnisse



- Reduktion von manuellem Aufwand
- "Einfache" Text Mining Verfahren mit Bag-Of-Words und k -means liefern gute Ergebnisse.
- Erklärbarkeit der Modelle gut gegeben, auch für nicht Data Scientisten.

Erfolgsfaktoren



- Datenqualität und Format der vorliegenden Daten
- Datenbereinigung erforderlich

Erfolgreiche (einfache) Use Cases, in denen Text Mining gewinnbringend eingesetzt werden konnte.



Vielen Dank für die Aufmerksamkeit!



Backup



Beispiel Kollektiv-Rahmenvertrag

§ 1	Entgeltumw
Kollektivvertrag Nr. 4790094285	
Arbeitgeberfinanzierte Pensionskassenversorgung nach § 3 Nr. 63 EStG	
zwischen der	
Bundesrepublik Deutschland vertreten durch das Bundesministerium der Finanzen	
als Versicherungsnehmer	
und der	
winsecura Pensionskasse AG Verwaltung OE 695 Frankfurter Straße 50 65170 Wiesbaden	
als Versicherer.	
Der auf Grund des Tarifvertrages AL II, § 39 Abschnitt B, vereinbarte Kollektivrahmenvertrag erhält – im Einvernehmen mit den obersten Behörden der Stationierungstreitkräfte als Arbeitgeber – nachstehende Fassung:	
§ 1 Personenkreis, Versicherungsnehmer	
1. Versichert werden	
a) alle Arbeitnehmer bei Dienststellen, Betrieben und sonstigen Einrichtungen der ausländischen Stationierungstreitkräfte im Gebiet der Bundesrepublik Deutschland, deren Beschäftigungsverhältnisse unter den Gestaltungsbereich des Tarifvertrages vom 16. Dezember 1966 – TV AL II – fallen,	
8	80. EL (05/19)

Entgeltumw	§§ 1, 2
b) alle Arbeitnehmer bei den Dienststellen der internationalen militärischen Hauptquartiere in der Bundesrepublik Deutschland, deren Beschäftigungsverhältnisse unter den Geltungsbereich des Tarifvertrages vom 7. Dezember 1984 – TV NATO – fallen,	
c) Arbeitnehmer von anderen Arbeitgebern, deren Aufnahme in den Kollektivrahmenvertrag die Vertragspartner vereinbart haben, die das rechnungsmäßige Alter von 60 Jahren bei Versicherungsbeginn noch nicht überschritten haben, die einen gesetzlichen Anspruch auf Entgeltumwandlung haben und deren anrechenbare Beschäftigungszeit im Sinne des TV AL II mindestens 6 Monate beträgt.	
Als rechnungsmäßiges Alter gilt die Differenz zwischen dem Kalenderjahr des Versicherungsbeginns und dem Geburtsjahr.	
Versicherungsnehmer aller Versicherungen ist die Bundesrepublik Deutschland.	
§ 2 Leistungsbeschreibung	
1. Die Vertragsparteien vereinbaren Versicherungsschutz im Rahmen einer beitragsorientierten Leistungszusage wie folgt:	
Tarif:	R2K Rentenversicherung mit aufgeschobenem Rentenbeginn – Vertragsgrundlage 242 in der jeweils gültigen Fassung
oder wahlweise	
Tarif:	R3K Rentenversicherung mit aufgeschobenem Rentenbeginn und Beitragsschutz in der Aufschubzeit – Vertragsgrundlage 244 in der jeweils gültigen Fassung
Rechnungsmäßiges Eintrittsalter:	Jahresdifferenz zwischen Beginnjahr und Geburtsjahr
Vereinbarter Rentenzahlungsbeginn:	am jeweiligen Monatsersten, der auf die Vollendung des 67. Lebensjahres folgt
Rentenzahlungsweise:	monatlich
80. EL (05/19)	9

§ 2	Entgeltumw
Rentengarantiezeit (gilt nur für Tarif R3K):	20 Jahre
Versicherungsleistung:	arbeitnehmerfinanziert: die versicherte Rente ergibt sich aus dem jeweiligen Beitrag nach Entgeltumwandlungsvereinbarung insgesamt begrenzt auf den Höchstbeitrag gemäß § 3 Nr. 63 EStG. Jährlich ist zusätzlich ein Beitrag bis max. 1.800 € möglich, sofern der Versicherte keine Direktversicherungszusage nach § 40 b EStG a.F. bzw. eine Pensionskassenzusage nach § 3 Nr. 63 EStG (Altzusage erteilt vor dem 01.01.2005) in Anspruch nimmt. Der Mindestbeitrag beträgt jeweils 300 € jährlich.
Tarifart:	FG 100 (Firmengruppe)
Zusatzversicherung (gilt nur für Tarif R2K):	kollektive Witwen-Witwer (60 %) und Waisenrenten-Zusatzversicherung (20 %) – Vertragsgrundlage 510 in der jeweils gültigen Fassung
Dynamik vor Rentenbeginn:	Optional, Erhöhung des Vorjahresbeitrages im selben Verhältnis wie die BBG – Vertragsgrundlage 558 in der jeweils gültigen Fassung. Ein nachträglicher Einschluss für Verträge mit Versicherungsbeginn vor dem 01.01.2006 ist möglich.
Dynamik in der Anwartschaft:	Obligatorisch, Jährlich garantierte Rentensteigerung von 1 %.
Überschussverwendung vor Rentenbeginn:	für Tarif R2K: Bonusrente ohne Rückgewähr für Tarif R3K: Bonusrente mit Rückgewähr
Überschussverwendung nach Rentenbeginn:	mit jährlicher Steigerung
Kapitalabfindung:	wählbar frühestens 1 Jahr bis spätestens 3 Monate vor dem vereinbarten Rentenzahlungsbeginn
10	80. EL (05/19)