



# Text KI ist ein Baukasten

Dr. Hans Weber

**portamis**  
Automatic Layout

# portamis Software GmbH



**portamis**  
Automatic Layout

portamis macht seit 20 Jahren u.a.

- aus XML gestaltetes PDF
- aus XML gestaltetes InDesign
- aus XML anderes XML
- aus PDF Informationen
- aus PDF strukturiertes XML

**Hans Weber, einer von zwei Gründern**

- 1990 bis 2001: Text-KI
- 2005 bis heute: XML Anwendungen wie oben..
- Seit ca. 5 Jahren: Beides

# Motivation / Inhalt

## Überblick und Verständnis geben ....

- **Zwei Grundtechniken in der Text-KI dargestellt**
  - **Klassifizieren (einfache Entscheidungen)**
  - **Übersetzen (komplexe Abbildungen)**
- **Für welche Aufgaben ist das geeignet**
- **Text-KI Aufgaben bei XML Beständen und Altdokumenten**
- **Aufbau von Lösungen als Baukasten von Classifiern**



# Grundbausteine Text-KI

## Klassifikation und Übersetzung



Kategorie, Score



W1, W2, W3 ...WK

V1, V2, V3 .....Vi, Score



W1, W2, W3 ...WK

Classifier werden  
trainiert mit  
getagten Daten:

Listen von  
Beispielen von  
Wortketten für eine  
feste Kategorie

Übersetzer werden  
trainiert mit Paaren  
von Wortketten:

Jeweils eine  
Wortkette als  
Eingabe und eine als  
Ausgabe

# Text Klassifikation



Kategorie, Score

Klassifikator

Feature 1, Feature 2...Feature N

Tokenizer / Feature Selection

Wort1, Wort2, Wort3 ...Wort K

Ein Text-Classifier wird trainiert mit Texten einer gewünschten Art

Danach gibt er dann hohe Scores aus für sehr ähnliche Texte


Er gibt niedrige Scores aus für sehr unähnliche Texte

Für die Texte aus den Trainingsdaten gibt er den maximalen Score aus

# Text Klassifikation




## Textart-Erkennung



# Text Klassifikation



## Textart-Erkennung



Text-Classifer können für viele Zwecke verwendet werden

Dokumente in verschiedenen Sprachen -> Sprachenerkennung  
(Eine Seite pro Sprache reicht zum Training)

Verwenden nur von Dokumenten-Überschriften  
-> Themenerkennung

Beliebige Vorverarbeitungen / Tokenizing

Ansonsten Erkennung von

- SPAM Mails
- E-Mail Kategorien für Weiterleitungen
- Dokumentenarten für Arbeitsflussteuerung

Ist eine sehr generelle universell einsetzbare Technik zum Trennen von Textsorten

# Typische Szenarien mit Übersetzern



## Maschinelle Übersetzung

- Training mit Satzpaaren und Abschnittspaaren

## Dialogführung

- Frage und Antwort werden als Übersetzung trainiert

## Code Generieren

- Anforderungen werden übersetzt in Code Stücke

- Übersetzer Szenarien sind meistens komplexe Abbildungen
- Übersetzer haben daher oft sehr viele interne Zustände, um viel Information zu speichern
- Übersetzer benötigen extrem viele Trainingsdaten
- Übersetzer benötigen extrem viel Rechenleistung
  
- Sie sind nicht geeignet, wenn wenig Trainingsmaterial vorliegt

# Aufgabenstellungen mit weniger Trainingsdaten (Beispiele)



## XML Tagging

- Weil XML Contents sehr unterschiedlich getaggt sind, liegen für spezielles XML Tagging meistens nur wenige Trainingsdaten vor

## Dokumenten-Clustering unbekannter Dokumente


- Alte PDF Bestände sind oft unübersichtlich und keiner weiß mehr, was drin ist

## Finden von falsch getaggt Contents in speziellen XML Content Datenbanken

- Verwenden von Classifiern mit wenig oder keinen vorab Trainingsdaten
- Baukastenprinzip:
  - Kombination von Bootstrapping: Sicher erkannte Bereiche prüfen und Trainingsmenge inkrementell erhöhen
  - Kombination von Classifiern mit Clusteringverfahren

# Text Klassifikation

## Clustering von Texten



1. Nimm ein Startdokument A und trainiere Modell A mit A als Trainingsdaten
2. Bewerte alle Dokumente und nimm das unähnlichste als B
3. Trainiere Modell {A U B}, bewerte alle Dokumente und nimm das unähnlichste als C
4. Trainiere Modell {A U B U C}, bewerte ..... Und so weiter für K Cluster
5. Sortiere in die K Cluster die restlichen Dokumente ein, immer nach der größten Ähnlichkeit
6. Wenn ein Dokument hinzukommt, trainiere das Modell neu mit den neuen Daten hinzugefügt.

Nach welchen Kriterien geclustert wird, entscheidet die Vorverarbeitung

- Wenn nur Produktnummern und Produktnamen gefiltert herausgefiltert werden, wird danach geclustert.
- Bei allen Wörtern kommen tatsächlich Gattungen heraus.

# Clustering mit Classifiern



## Die Vorgehensweise

- Natives Verfahren lernt während des Clusters
- erfordert sehr schnelle Trainingsläufe
- -> kein Deep Learning möglich, weil so viele wiederholte Trainings
- Verfahren wird derzeit getestet.

## Verbesserungen:

### Start-Cluster mit Trainingsdaten versehen

- Startcluster vorsehen, die manuell gewählte Dokumente enthalten

### Bootstrapping (manuelle Kontrolle und Restart)

- Reste-Cluster generieren, bis ein nächstes entferntes Dokument näher an den Startclustern liegt als an einem Reste-Cluster
- Reste-Cluster manuell sichten und ggf. wiederholen mit zusätzlichen Start-Clustern

# Automatisches XML Tagging



Funktioniert gut, wenn Daten vorsegmentiert sind

- z.B. bei Übernahme von Texten aus gelayouteten PDF Dokumenten
  - Tabellen, Listen, Überschriften sind hier schon segmentiert
- Bei semantischem Retaggen / Anreichern von vorhandenem XML Beständen

Funktioniert nicht gut bei rein Layout- oder Prozess-orientiertem Markup

- Weil der statistische Bezug von den Wörtern zur Kategorie schwach ist.

Verfahren:

- Trainingsdaten mit getagtem Text. Für jede Kategorie wird ein Classifier trainiert auf den darin enthaltenen Wörtern.
- Vorhandene Segmente (aus dem Layout oder aus vorhandenem XML) werden klassifiziert.

Alternativ ohne Segmentgrenzen:

- Alle möglichen Segmente erzeugen und klassifizieren. Dann die beste Sequenz von Elementen auswählen.

# Fazit

Bei einigen Anwendungen für Text-Dokumente und XML Contents sind Trainingsdaten nicht ausreichend vorhanden und erstellen ist teuer. Daher sind Übersetzer (insbesondere Deep Learner) oft nicht anwendbar

Mit Classifiern in einem Baukasten von Suche oder Clustering können auch mit wenig Trainingsdaten Aufgaben mit Text-KI bearbeitet werden.

Dokumenten-Klassifikation, Automatisches XML Taggen, Dokumenten-Clustering kann damit effektiv automatisiert werden.

Das ist möglich, wenn wir nicht eine komplexe Übersetzung direkt lernen, sondern Classifier wie in einem Baukasten verwenden.



# portamis: Automatic Layout for XML Content

portamis  
Software GmbH

Erlangen-  
Nuremberg  
Germany

Founded in  
2002

Dr. Hans Weber  
Thimo Seitz

12 People

Text-AI  
XML  
PDF  
Java  
Docker  
Algorithmics  
Architecture  
InDesign  
Rendering

Siemens  
LHS  
Daimler  
Philips  
Roche  
EDE  
Hager  
Berker  
Brose  
...

20 years of experience

# Kontakt

Ute Heinz / Dr. Hans Weber  
portamis Software GmbH

90491 Nürnberg  
Äußere Sulzbacher Straße 159-161

Tel. +49 911 311 0977 0  
E-Mail: [info@portamis.de](mailto:info@portamis.de)

[www.portamis.de](http://www.portamis.de)

**portamis**  
Automatic Layout