

ReligonML

- Projektvorstellung (02.10.2020)
- Tagung: Sprache und Wissen 2020 (Zoom)
- Vortragender: Thomas Jurczyk
- Ruhr-Universität Bochum

Übersicht

1. Persönliche Vorstellung
2. Projektvorstellung **ReligionML**
 1. Motivation & Vorhaben
 2. Vorgehensweise / Annotationschemata
 3. Vorstellung der Plattform
 4. (Auswertungsmöglichkeiten)
3. Probleme und Diskussionsvorschläge

1. Persönliche Vorstellung

- Studium Geschichte und Religionswissenschaft in Bochum
 - Was ist Religionswissenschaft? (Exkurs)
- Abgeschlossene Promotion
 - Thema: „The Notion of *surb* in Ancient Armenian Texts from the Fifth Century CE“
 - Analyse der semantischen Felder des altarmenischen, zeitgenössischer englischer sowie metasprachlicher Heiligkeitbegriffe(s)
- derzeit Wissenschaftlicher Mitarbeiter am *Centrum für Religionswissenschaftliche Studien (CERES)* der RUB
- (Teilzeitstudium Informatik und Mathematik an der FU Hagen)

2. ReligionML – Motivation

1. Interesse an quantitativen Methoden sowie Programmierung/DH Ansätzen im Bereich der Religionswissenschaft, die ich u.a. auch in meine Dissertation habe einfließen lassen (s.u.).
 - a. Datenbeschaffung, -verarbeitung, -auswertung, -speicherung, -visualisierung.
2. Anwendung simpler *ML Classifier* (KNN, Logistic Regression etc.) zur Filterung großer Datenmengen in meiner Dissertation (Twitterdaten).
 1. **Vorteile:** Einfach zu implementieren, funktioniert für einfache Klassifikationen gut (abhängig von der Datengrundlage), erlaubt einen neuen Blick auf die Daten.
 2. **Problem:** Große Datenmengen notwendig, die im Bereich des *supervised learning* auch annotiert sein müssen.
3. Interesse an religionswissenschaftlich zentralen Begriffen und deren Verwendung in diversen gesellschaftlichen Bereichen.

2. ReligionML - Vorhaben

1. Bereitstellung eines mit Blick auf religionswissenschaftliche Fragestellungen annotierten Datensatzes, der die vorliegenden Daten nicht strukturieren, sondern auch eine Möglichkeit schaffen soll, bspw. mit Hilfe maschinellen Lernens künftig unbekannte Daten zu klassifizieren und damit vorzufiltern.
2. Idealerweise soll *peu à peu* ein annotiertes und strukturiertes religionswissenschaftliches Corpus entstehen.
 1. Aufgrund der Vielfalt an Gebrauchskontexten religiöser Semantik und der Verfügbarkeit konzentriert sich das Vorhaben derzeit auf englische Tweets, die religiöse Terminologie wie „holy“, „sacred“, „religion“, „ritual“, „purity“ etc. enthalten.
3. Die Annotationen sollen so allgemein wie möglich gehalten werden, um Offenheit für ein breites Spektrum an Fragestellungen zu gewährleisten. Derzeit liegt der Annotation neben einem allgemeinen Interesse an Religion bzw. der Verwendung religiöser Semantik/Lexik keine spezifische Forschungsfrage zugrunde.
4. Die Annotation umfasst (derzeit) die semantische Annotation der Tweets/Sätze (Makroebene) sowie einer Sentiment/Domänenannotation einzelner Wörter in den Tweets/Sätzen (Mikroebene). Andere Annotationen (bspw. Syntax, Stilistik) sind (derzeit) nicht vorgesehen, allerdings kann in bspw. in Sachen POS, aber auch *named entity tagging* im Bedarfsfalle auf existierende automatisierte Annotierer zurückgegriffen werden (spaCy in Python).

2. ReligionML – Vorgehensweise I

1. Gründung der **ReligionML** Arbeitsgruppe am CERES im April 2020.
 1. Derzeit 6-7 Mitglieder aus verschiedenen Fachbereichen (u.a. Klassische Philologie, DH, Soziologie, Archäologie, Germanistik), die jetzt alle im Bereich der Religionswissenschaft arbeiten.
 2. Annotation von Texten (Sätzen) durch die Mitglieder, die in regelmäßigen Abständen diskutiert werden (bisher erst ein Treffen).
 3. In dem Wissen, dass Softwarelösungen für Annotationen (bspw. CATMA, MAXQDA) existieren, verwenden wir aktuell aus unterschiedlichen Gründen eine *inhouse* Lösung als Annotationsplattform.

2. ReligionML – Vorgehensweise II

Tägliches automatisiertes Sammeln von Tweets (Webserver) >>

1x monatlich Einfügen der neuen Tweets in die Datenbank (Corpus)
(zwischen 35k-75k Tweets pro Subcorpus) >>

Auswahl und Annotation (Mikro/Makro) der Tweets in den Corpora
über eine Webapplikation >>

(künftige) Nutzung der annotierten Daten für ML / Hosting der Modelle
für Prediction Tasks (ebenfalls über die Webapplikation)

2. ReligionML – Vorgehensweise III

1. Derzeitiger Fokus auf der iterativen Entwicklung von Annotationsschemata auf der Mikro- und Makroebene.
2. Makroebene
 1. Begonnen haben wir mit einer simplen religiös/nicht-religiös Binärunterscheidung, die aber der Komplexität der jeweiligen Verwendungszusammenhänge nicht gerecht wurde.
 2. Derzeit bestehen unsere Kategorien auf der Makroebene aus den folgenden Kategorien:

2. ReligionML – Kategorien I (Makro)

Inner-Religion

Inner-religion bedeutet, dass der Satz/Tweet eine religiöse Bedeutung hat und aus einer religiösen Perspektive heraus formuliert wurde. Ein typisches Beispiel wäre ein Christ oder Muslim, der etwas über seinen Glauben aussagt.

Beispiele (aus Tweets über Religion):

1. I believe god has revealed to me his true religion. But I respect everyone's right to believe.
2. "...they do believe in God, they just dont like the dogma and rules of religious institutions..." Spot on brother! Some people see RELIGION as anti-reason or anti-science. Personally I think SPIRITUALITY and science are 2 sides of the same coin.

2. ReligionML – Kategorien II (Makro)

Religion-transcendence

Religion-transcendence bedeutet, dass, obwohl der Text nicht aus einer innerreligiösen Sphäre stammt, im Gesamtkontext immer noch auf Religion als ein komplexes System Bezug genommen wird, das sich mit der Immanenz/Transzendenz Unterscheidung befasst (siehe Luhmann, Luckmann).

Ein typisches Beispiel sind zwei Personen, die über Religion als Weltanschauung und religiöse Wahrheitsansprüche im Vergleich zu z.B. philosophischen Aussagen sprechen, allerdings nicht aus einer religiösen Perspektive heraus, sondern bspw. aus dem Bereich der akademischen Philosophie oder anti-religiöser Polemik.

Beispiele (aus Tweets über Religion):

1. I HATE religion. How are people this brainwashed by something they have no proof of even existing???
2. I've never heard of religion not celebrating birthdays

2. ReligionML – Kategorien III (Makro)

Religion-immanence

Religion-immanence bedeutet, dass der Text zwar auf das System „Religion“ referiert, aber mehr im Sinne eines allgemeinen Differenzmarkers, der keinen direkten Bezug auf innerreligiöse Diskussionen nimmt. Ein gutes Beispiel ist "Religion" als ethnisch-politische Kategorie.

Beispiele (aus Tweets über Religion):

1. I am talking about the illegal immigrants who will come to india based on religion not the assumed illegal immigrants who are allegedly residing in india
2. India was created for ppl of all religion already staying here. It was not meant to welcome all ppl - specially Muslims who chose Pakistan

2. ReligionML – Kategorien IV (Makro)

Metaphorical-use

Metaphorischer Gebrauch bedeutet, dass sich die Terminologie nicht mehr direkt auf "Religion" bezieht, sondern die Domäne "Religion" in einem anderen Kontext verwendet („Das Wesen der Metapher besteht darin, daß wir durch sie eine Sache oder einen Vorgang in Begriffen einer anderen Sache bzw. eines anderen Vorgangs verstehen und erfahren können.“ Lakoff/Johnson). Ein typisches Beispiel sind Sätze wie "Elektronische Musik ist meine Religion".

Beispiele (aus Tweets über Religion):

1. The system you are serve in has veered off the integrity chessboard. If you want to grow politically, work with your close political allies. Meanwhile congratulations for the gloried PM and the religious loyalty to the dragon of impunity and political pathology.

2. ReligionML – Kategorien V (Makro)

No-religion

Selbsterklärend. Meist Outlier bzw. Tweets, die fälschlich mit in den Datensatz hineingerutscht sind.

2. ReligionML – Kategorien I (Mikro)

Das Annotationsschema auf der Mikroebene befindet sich derzeit noch in der ersten Testphase und wurde bisher noch nicht von den Teilnehmer:innen der Gruppe diskutiert.

Versuchshalber wurden lediglich die Kategorien ...

- **positiv/negativ** (*sentiment*)

... sowie mehrere Domänenannotationen wie ...

- **Politik, Wirtschaft, Religion** (Gesellschaft),

- **Kunst, Sexualität, Macht**

... implementiert. Die bisherigen Annotationen sind aus der Analyse der Tweets heraus entstanden (induktiv).

2. ReligionML – Annotationsplattform

- Webbasierte Anwendung (Frontend: JavaScript/Vue, Backend: Python/Flask)
- Seite ist passwortgeschützt und nur für Gruppenmitglieder zugänglich
- wird gemeinsam mit den Annotationen kontinuierlich erweitert und verbessert
- im Falle, dass umfangreichere Texte künftig herangezogen werden sollen, wird in jedem Falle auf bestehende Softwarelösungen zurückgegriffen
- **Vorteile:** Datenbeschaffung (Twitter Scraper), -bearbeitung (Cleaning), -bereitstellung (SQLite), -annotation (Webinterface) komfortabel und auf eigene Bedürfnisse zugeschnitten auf einem Server möglich; keine Abhängigkeit von anderen Personen; Lerneffekt
- **Nachteile:** noch sehr rudimentär (UI, Annotationsmöglichkeiten), fehleranfällig, nicht für eine größere (öffentliche) Teilnehmergruppen geeignet, nicht für die Annotation größerer Textmengen geeignet

2. ReligionML – Auswertungsmöglichkeiten I

Machine Learning (prospektiv)

Im Kontext meiner Dissertation habe ich bereits einige *supervised* ML *Classifier* wie KNN, LogReg etc. mit einem annotierten Datensatz bestehend aus 2.000 Tweets, die englische Heiligkeitssemantiken beinhalten, trainiert. Im Kontext der Gruppe ist dies noch nicht geschehen, da wir uns derzeit auf die Entwicklung der Annotationen sowie die Optimierung der Annotationsstrategien konzentrieren.

2. ReligionML – Auswertungsmöglichkeiten II

Analyse des Inter-Annotator Agreement

Hier geht es auch, aber nicht nur um die Frage, wie kohärent die einzelnen Personen annotieren. Eine Besonderheit (?) unseres Ansatzes liegt darin, dass wir uns bewusst nicht in Richtung 100% Annotatoragreement als Optimierungsziel bewegen müssen (wobei wir dieses natürlich auch nicht ausschließen). Vielmehr überlegen wir, inwiefern prozentuale Annotationswahrscheinlichkeiten (bspw. ob ein Tweet *religion-transcendence* oder *religion-immanence* ist) die semantische Unschärfe des Materials nicht besser widerspiegeln als eine disjunkte Klassifizierung à la „religiös“ vs. „nicht-religiös“.

Bisher wurden lediglich simple prozentuale Übereinstimmungswerte berechnet, künftig soll aber auch von Cohen's/Fleiss' kappa oder anderen Metriken Gebrauch gemacht werden.

2. ReligionML – Auswertungsmöglichkeiten III

Untersuchung von Korrelationen zwischen Makro- und Mikroannotationen

annotation_macro	art	economy	geography	negative	politics	positive	power	religion	science	society	sport
inner-religion	0	0	0	5	1	2	0	15	3	2	0
metaphorical-use	0	0	0	4	11	0	0	8	3	0	0
religion-immanence	3	7	15	109	140	16	2	127	5	13	0
religion-transcendence	3	0	0	13	4	4	0	40	8	0	3

Die Tabelle zeigt die Anzahl an Wörtern aus den Domänen (Sentiments) der Mikroanalyse für alle vier (fünf) Kategorie aus der Makroanalyse. **Achtung:** Dies ist lediglich ein Beispiel, das aufgrund der schmalen Datenbasis (ca. 50 ausgewertete Tweets) und der uneinheitlichen Annotation auf der Mikroebene noch keine inhaltlichen Aussagen zulässt. Es sollen lediglich Potentiale für die Auswertung deutlich werden.

3. Probleme und Diskussion

1. Allgemeines Vorhaben

- Noch recht unspezifisch
 - Macht es Sinn, keine definierte Forschungsfrage zu haben?
- Wie ein strukturiertes rel.-wiss. Corpus erstellen?
 - Welche Texte? (Urheberrecht? Nur Englisch? Nur zeitgenössisch? Welche Religionen? etc.)

2. Annotationen/Gruppe/Plattform

- Wie andere Personen zu kontinuierlicher Annotation anhalten/ Projekte längerfristig etablieren?
- Mikroebene: Rückgriff auf bestehende Annotationsschemata? Wenn ja, welche?
- Inhouse vs. existierende Softwarelösungen

3. Auswertungsmethoden

- Fokus auf Agreement vs. prozentuale Einschätzung