

**Argumentation Mining:  
Eine neue Methode zur automatisierten Textanalyse und ihre  
Anwendung in der Kommunikationswissenschaft**

Marcus Maurer<sup>1</sup>

Johannes Daxenberger<sup>2</sup>

Iryna Gurevych<sup>2</sup>

<sup>1</sup>Institut für Publizistik  
Johannes Gutenberg Universität Mainz  
Jakob-Welder-Weg 12  
55128 Mainz  
[mmaurer@uni-mainz.de](mailto:mmaurer@uni-mainz.de)

<sup>2</sup>Ubiquitous Knowledge Processing Lab  
TU Darmstadt

Angenommen im Panel VI (Vorstellung neuer Verfahren) bei der 19. Tagung der Fachgruppe  
„Methoden“ der DGPK vom 20. bis 22. September 2017 in Mainz

## **Argumentation Mining: Eine neue Methode zur automatisierten Textanalyse und ihre Anwendung in der Kommunikationswissenschaft**

### *Automatisierte Inhaltsanalyse in der Kommunikationswissenschaft*

Automatisierte Inhaltsanalysen haben in der Kommunikationswissenschaft und verwandten Sozialwissenschaften in den letzten Jahren deutlich an Bedeutung gewonnen (im Überblick z.B. Scharnow, 2012; Grimmer & Stewart, 2013). Dabei befassen sich bislang die meisten dieser Studien mit dem automatisierten Erkennen von Themen (z.B. Scharnow, 2012; Guo et al., 2016), zunehmend aber auch mit dem Erkennen von Bewertungen (z.B. van Attefeldt et al., 2008; Groshek & Al-Rawi, 2013; Su et al., 2016). Der Vorteil der automatisierten Codierung besteht vor allem darin, dass auch sehr große Textmengen kostengünstig und in kürzester Zeit untersucht werden können. Ihr Nachteil besteht zum einen darin, dass die meisten automatisierten Verfahren Medieninhalte weniger genau erfassen als manuelle Codierungen, z.B. weil sie die konnotative Bedeutung von Texten schlechter erkennen oder nicht in der Lage sind, rhetorische Stilmittel wie Ironie zu berücksichtigen (Lewis et al., 2013). Zum anderen reduziert die Konzentration auf Verfahren zur Erkennung von Themen und Bewertungen die hohe Komplexität vieler manueller Codebücher auf ein Minimum an Kategorien.

Während automatisierte Inhaltsanalysen lange vor allem mit Hilfe so genannter diktionsbasierter Verfahren durchgeführt wurden, in denen Computerprogramme Texte nach vorformulierten Wörtern oder Wortkombinationen durchsucht haben, wurden diese in letzter Zeit zunehmend durch Verfahren ersetzt, die auf dem Prinzip des maschinellen Lernens basieren. Dies hat zum einen dazu geführt, dass sowohl Themen (Guo et al., 2016) als auch Bewertungen (Hopkins & King, 2010) mittlerweile deutlich exakter erfasst werden können als noch vor wenigen Jahren. Zum anderen eröffnet das Verfahren des maschinellen Lernens breitere Analysemöglichkeiten, weil es auf viele unterschiedliche Fragestellungen übertragen werden kann. Ein zurzeit in der Informatik stark diskutiertes Verfahren zur Textanalyse, das auf maschinellem Lernen basiert, ist das so genannte Argumentation Mining, das automatisierte Erkennen von Argumenten und ihrer Qualität. Der vorliegende Beitrag stellt dieses Verfahren vor.

### *Argumentation Mining*

Argumentation Mining (auch bezeichnet als Computational Argumentation) ist die maschinelle Analyse von argumentativen Strukturen in natürlich-sprachlichem Diskurs (van

Eemeren et al., 2014). Dazu zählt bspw. die automatische Identifizierung von Behauptungen („Claims“), aber auch die Erkennung von komplexeren Strukturen, in denen Behauptungen untereinander sowie mit passenden Evidenzen verknüpft werden müssen. So kann z.B. erfasst werden, welche Argumente für oder gegen die Aufnahme von Flüchtlingen in öffentlichen Diskursen wie häufig erwähnt werden, und zwar unabhängig davon, wie die Argumente jeweils formuliert wurden. Zudem kann mit Hilfe von Argumentation Mining auch die Qualität von Argumenten erkannt werden, z.B. ob sie durch Evidenzen gestützt sind oder sich auf vorhergehende Argumente beziehen. Dies wird möglich, weil moderne Machine Learning Verfahren in der Lage sind, aus geeigneten Trainingsdaten (also manuell codierten Texten) argumentative Muster zu lernen, die dann Argumente auch in zuvor nicht codierten Texten erkennen können.

Dazu wird das Gesamtproblem typischerweise in mehrere Teilschritte zerlegt (Stab & Gurevych, 2017): zunächst müssen argumentative Textteile erkannt werden (Segmentierung, typischerweise auf Satz- oder Clause-Ebene), dann müssen die relevanten Teile klassifiziert werden (Komponentenerkennung, bspw. um Behauptungen von Evidenzen zu unterscheiden). Zuletzt werden die Beziehungen der argumentativen Textteile untereinander analysiert (Relationen-Erkennung) und klassifiziert (Relationen-Klassifikation, bspw. unterstützende oder angreifende Evidenzen). Eines der aktuell erfolgreichsten Modelle zur Erkennung solcher Strukturen löst dieses Problem mittels des sogenannten Deep Learning – also tiefen Neuronalen Netzen, die in der Lage sind, Zusammenhänge auch über längere Textteile hinweg zu erkennen. Auf einem Datensatz aus Schüleraufsätzen erkennt dieses Modell etwa 70% der argumentativen Komponenten korrekt (Eger et al., 2017). Andere Anwendungen für Argumentation Mining finden sich bspw. im juristischen Bereich (Mochales-Palau & Moens, 2009), in der automatisierten Erstellung von Zusammenfassungen (Habernal et al., 2014) sowie in der Analyse von wissenschaftlichen Veröffentlichungen (Kirschner et al., 2015). Neben der Analyse von argumentativen Strukturen untersucht Argumentation Mining auch Argumentqualität (Wachsmuth et al., 2017), bspw. das Überzeugungspotenzial von Argumenten (Habernal & Gurevych, 2016) oder die Erkennung von typischen Trugschlüssen (Hahn & Oaksford, 2006).

Das Erkennen von Argumenten und ihrer Qualität ist auch für die Kommunikationswissenschaft in vielerlei Kontexten relevant. So ließen sich beispielsweise durch eine Erfassung der in unterschiedlichen Nachrichtenmedien verwendeten Argumente

in Wahlkämpfen oder politischen Konflikten Aussagen über redaktionelle Linien und allgemeine Verzerrungen in der Berichterstattung treffen. Die Erfassung der Argumentqualität in Fernsehdebatten, Bundestagsreden oder auch Sozialen Medien könnte als Indikator für die Qualität (politischer) Diskurse herangezogen werden usw. Die Übertragung von Argumentation Mining auf kommunikationswissenschaftliche Fragestellungen ist allerdings keineswegs trivial, weil massenmediale Inhalte argumentativ oft weniger klar strukturiert sind als Essays oder wissenschaftliche Veröffentlichungen. Das Problem dabei ist v.a., dass Argumente in verschiedenen Diskurstypen sehr unterschiedliche Gestalt annehmen können, und dass insb. die Bewertung von Argumentqualität entscheidend von kontextuellem Wissen abhängt. Eine Voraussetzung zur Verbesserung der automatischen Verfahren sind geeignete Trainingsdaten. Die Erstellung solcher Ressourcen ist ebenfalls Gegenstand der Forschung, da es kaum Codierschemata für argumentative Strukturen oder Argumentqualität gibt, die auf heterogene Diskurstypen ausgelegt sind (Daxenberger et al., 2017).

### *Ausblick*

In einer explorativen Pilotstudie zu einem größeren Forschungsprojekt haben wir eine manuelle Inhaltanalyse der Claim-Typen in fünf zufällig ausgewählten Debatten des deutschen Bundestags durchgeführt. Unsere Analysen zeigen, dass das automatisierte Erkennen dieser Claims mittels Argumentation Mining gut funktioniert. Selbstverständlich handelt es sich dabei nur um einen ersten Schritt in einem weit komplexeren Verfahren. In den weiteren Schritten des Projekts wird es also auch darum gehen, Algorithmen zu entwickeln, die auf heterogene Textformen wie z.B. die Inhalte journalistischer Nachrichtenmedien anwendbar sind.

### *Literatur*

Daxenberger, J., Eger, S., Habernal, I., Stab, C., & Gurevych, I. (2017). What Is the Essence of a Claim? Cross-Domain Claim Identification. *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, im Druck.

Eger, S., Daxenberger, J., & Gurevych, I. (2017). Neural End-to-End Learning for Computational Argumentation Mining. *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (ACL)*, 11-22.

- Grimmer, J. & Stewart, B. M. (2013). Text as data: The promise and pitfalls of automatic content analysis methods for political texts. *Political Analysis*, 21, 267-297.
- Groshek, J. & Al-Rawi, A. (2013). Public sentiment and critical framing in social media content during the 2012 U.S. presidential campaign. *Social Science Computer Review*, 31, 563-576.
- Guo, L., Vargo, C. J., Pan, Z., Ding, W., & Ishwar, P. (2016). Big social data analytics in journalism and mass communication: Comparing dictionary-based text analysis and unsupervised topic modeling. *Journalism & Mass Communication Quarterly* (online first).
- Habernal, I., Eckle-Kohler, J., & Gurevych, I. (2014). Argumentation Mining on the Web from Information Seeking Perspective. *Proceedings of the Workshop on Frontiers and Connections between Argumentation Theory and Natural Language Processing*, edited by Elena Cabrio, Serena Villata, and Adam Wyner, 26–39. CEUR-WS.
- Habernal, I. & Gurevych, I. (2016). What Makes a Convincing Argument? Empirical Analysis and Detecting Attributes of Convincingness in Web Argumentation. *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1214–23.
- Hahn, U. & Oaksford, M. (2006). A Bayesian Approach to Informal Argument Fallacies. *Synthese* 152 (2): 207–36.
- Hopkins, D. J. & King, G. (2010). A method for automated nonparametric content analysis for social science. *American Journal of Political Science*, 54, 229-247.
- Kirschner, C., Eckle-Kohler, J., & Gurevych, I. (2015). Linking the Thoughts: Analysis of Argumentation Structures in Scientific Publications. *Proceedings of the 2nd Workshop on Argumentation Mining Held in Conjunction with the 2015 Conference of the North American Chapter of the Association for Computational Linguistics – Human Language Technologies (NAACL HLT 2015)*, 1–11.
- Lewis, S. C., Zamith, R., & Hermida, A. (2013). Content analysis in an era of Big Data: A hybrid approach to computational and manual methods. *Journal of Broadcasting & Electronic Media*, 57, 34-52.
- Mochales-Palau, R. & Moens, M.-F. (2009). Argumentation Mining: The Detection, Classification and Structure of Arguments in Text. *Proceedings of the 12th International Conference on Artificial Intelligence and Law*, 98–107.
- Scharkow, M. (2012). *Automatische Inhaltsanalyse und maschinelles Lernen*. Berlin: epubli.
- Schiappa, E. & Nordin, J. P. (2013). *Argumentation: Keeping faith with reason*. Pearson.
- Stab, C., & Gurevych, I. (2017). Parsing Argumentation Structures in Persuasive Essays. *Computational Linguistics*.

- Su, L. Y.-F., Cacciatore, M. A., Liang, X., Brossard, D., Scheufele, D. A., & Xenos, M. A. (2016). Analyzing public sentiments online: Combining human- and computer-based content analysis. *Information, Communication & Society* (online first).
- van Atteveldt, W., Kleinnijenhuis, J., & Ruigrok, N. (2008). Parsing, semantic networks, and political authority. Using syntactic analysis to extract semantic relations from Dutch newspaper articles. *Political Analysis*, 16, 428-446.
- van Eemeren, F. H., Garssen, B., Krabbe, E. C. W., Snoeck Henkemans, A. F., Verheij, B. & Wagemans, J. H. M. (2014). *Handbook of Argumentation Theory*. Springer.
- Wachsmuth, H., Naderi, N., Hou, Y., Bilu, Y., Prabhakaran, V., Alberdingk Thijm, T., Hirst, G., & Stein, B. (2017). Computational Argumentation Quality Assessment in Natural Language. *Proceedings EACL*, 176–187.