



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra



PUBLIC
DISCOURSE
FOUNDATION

Sophie Achermann
14. November 2023, Bern

Hate Speech - ein weitverbreitetes Problem

Nach dem Motto leben und leben lassen, aber wenn sich zwei Männer vor mir küssen, das muss ich nicht über mich ergehen lassen, das stösst mich persönlich ab.

Fi** dich du schlampe du brauchst doch mal richtig sex

Wir wollen keine 40'000 Eritreer für gar nichts durchfuttern! Geht nach Hause und bringt dort eure 300 Babys in 3 Monaten auf die Welt !!! WIR müssen für UNSERE Kinder schauen !!



Hate Speech Definition

Hate Speech

Abwerten von Personen oder Gruppen aufgrund von Identitätsmerkmalen wie ...

Breite Definition

- Sozialer Status/Bildung/ Einkommens-/ Berufsgruppe
- Politische Einstellung
- Körperlichen Merkmalen/ Aussehen

Enge Definition

- Geschlecht
- Alter
- Sexualität
- Religion- Nationalität/ Hautfarbe/Herkunft
- Geistige/körperliche Beeinträchtigung

Toxische Sprache

Verletzende, beleidigende oder vulgäre Sprache, die sich nicht auf Identitätsmerkmale bezieht


Und wir sehen...

- ☞ Unterrepräsentierte Gruppen ziehen sich weiter aus dem Diskurs zurück
- ☞ Nur eine kleine Minderheit beteiligt sich am Online-Diskurs – oft die mit den polarisiertesten Meinungen
- ☞ Gesellschaftliche Spaltungen können somit verstärkt werden, mit Auswirkungen für die Demokratie
- ☞ Moderation bedeutet auch immer Zensur. Ein Gleichgewicht zu finden ist schwierig.




Moderation ist ein gewaltiger Aufwand

Es gibt mehrere Tausend Kommentare pro Tag, und fast alle werden manuell moderiert



Sehr wenige Akteure sind für die Mehrheit der Hassrede verantwortlich

In Schweizer Zeitungen produziert 1% der User:innen 55-70% des Hasses






aber hasserfüllte User:innen sind für viel Content verantwortlich

Insgesamt produzieren die top 5% Hater über 50% des Contents

Distribution of comment behavior across 3 Swiss newspapers



Counterspeech: ein Lösungsversuch

- Hate Speech mit Gegenrede statt Zensur bekämpfen
- Wie reagieren User:innen, wenn man auf Hate Speech antwortet?
- Wir haben verschiedene Strategien getestet

PNAS Proceedings of the
National Academy of Sciences
of the United States of America




Empathy-based counterspeech can reduce racist hate speech in a social media field experiment

Dominik Hangartner^{a,b,1}, Gloria Gennaro^{a,b}, Sary Alasiri^a, Nicholas Bahrach^a, Alexandra Bornhoft^a, Joseph Boucher^a, Buket Buse Demirci^a, Laurenz Derksen^{a,b}, Aldo Hall^a, Matthias Jochum^a, Maria Murias Munoz^a, Marc Richter^a, Franziska Vogel^a, Salomé Wittwer^a, Felix Wüthrich^a, Fabrizio Gilardi^c, and Karsten Donnay^c



Counterspeech-Experimente

Erste Resultate



Hangartner et al. (2021), *Proceedings of the National Academy of Sciences of the U.S.A.*



Contact

Public Discourse Foundation
c/o ETH
Leonhardshalde 21
CH-8001 Zürich/Schweiz

contact@public-discourse.org
public-discourse.org

Sophie Achermann

Geschäftsführerin

sophie.achermann@public-discourse.org

Partner

ETH zürich

**Stiftung
Mercator
Schweiz**

Ermöglicht durch
MIGROS
Pionierfonds