Dr. Jonas Fegert
Forum gegen Fakes | 20.04.2024

HOUSE OF PARTICIPATION

FZI

Wahrheit oder Fake?

Über Online Social Networks, ihren Einfluss auf Desinformation und Gegenmaßnahmen

Digital
Democracy &
Participation
research group

Die Erosion der Demokratie

„How Democracies Die“ von Levitsky & Ziblatt 2018

Kontext: Wahl von Donald Trump und Aufstieg des Rechtspopulismus in Europa

> *“Democratic backsliding today begins at the ballot box”*
>
> Levitsky & Ziblatt 2018, 5

> *“Democracy’s erosion is, for many, almost imperceptible”*
>
> Ibid., 6

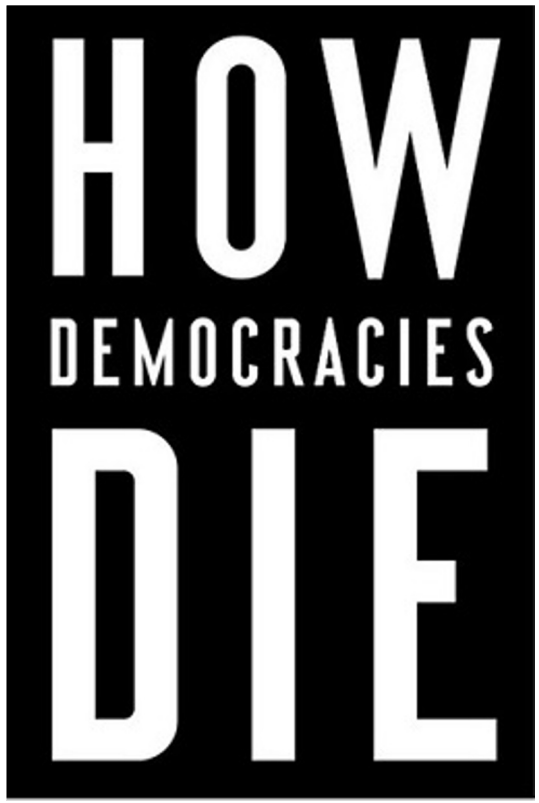

Indikatoren für autoritäre Tendenzen

Wie lassen sich potentielle Autoritäre erkennen, bevor sie gewählt werden?

Ablehnung	Autoritäre "lehnen in Worten oder Taten die demokratischen Spielregeln ab"
Leugnung	Bestreiten die Legitimität der Gegner:innen
Tolerierung	Tolerieren Gewalt oder rufen zu ihr auf
Repression	Zeigen die Bereitschaft, bürgerliche Freiheiten von Gegner:innen, einschließlich der Medien, zu beschneiden

Levitsky & Ziblatt 2018, 21 f.

CORRECTIV

Geheimplan gegen Deutschland

Die Geheimplan-Recherche geht weit über die erste Enthüllung hinaus. Erfahren Sie hier, wie die Welt reagiert und von weiteren Recherchen rund ums Thema.

The New York Times

On Holocaust Memorial Day, Germans Rally Against Far Right and for Democracy

Large crowds have protested since it was revealed that members of the far-right Alternative for Germany party had met with neo-Nazis and those calling for a mass deportation.

Share full article

A demonstration against the Alternative for Germany party and right-wing extremism, and for democracy, in Düsseldorf on Saturday. Thilo Schmuelgen/Reuters

FZI

Was hat „democratic backsliding“ mit digitalen Technologien und Plattformen zu tun?

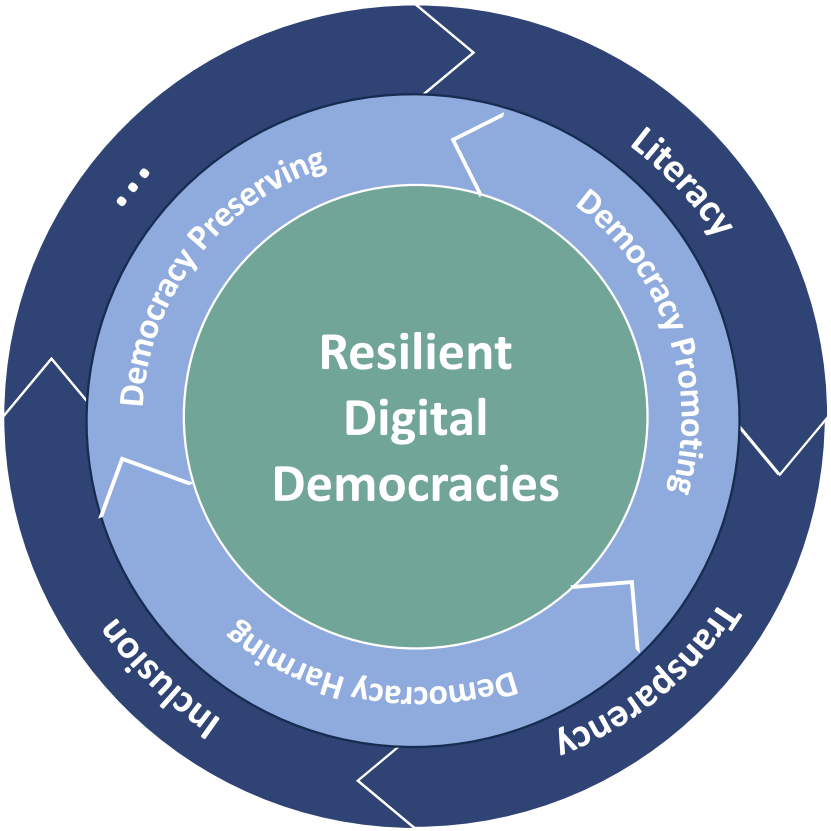

Weinhardt & Fegert (2024)

Online Social Networks, ihre Mechanismen und die Verbreitung von Desinformation

Die deliberative Kraft von Online Social Networks

“Ägyptische Revolution” 2011

Die deliberative Kraft von Online Social Networks

January 25, 2011

Clarke, K., Kocak, K.: Launching Revolution: Social Media and the Egyptian Uprising's First Movers. British Journal of Political Science. 50, 1025–1045 (2020).

Digitale Medienlandschaft im Wandel

The New York Times

uy Twitter | Musk Strikes a Deal | Twitter Employees React

Elon Musk Completes $44 Billion Deal to Own Twitter

The world's richest man closed his blockbuster purchase of the social media service, thrusting Twitter into a new era.

Give this article 1.7K

By Kate Conger and Lauren Hirsch

Kate Conger reports on technology from San Francisco and Lauren Hirsch reports on mergers and acquisitions from New York.

Oct. 27, 2022

New York Times (2022)

Digitale Medienlandschaft im Wandel

October 26, 2022

October 30, 2022

Algorithmische Amplifikation durch Abonnements

Center for Countering Digital Hate 2023

Jede:r, der 8 Dollar pro Monat und eine verifizierte Telefonnummer hat, kann sich für den blauen Haken anmelden

„Twitter Blue-Nutzer werden in Konversationen und in der Suche bevorzugt behandelt, und Twitter-Nutzer werden Antworten von verifizierten Blue-Konten gegenüber anderen Antworten leicht bevorzugt angezeigt bekommen.“ (Twitter 2023)

TWON – Twin of Online Social Networks

Mit digitalen Zwillingen den Einfluss von Social Media auf die Demokratie erforschen

FZI

Motivation

- Online Social Networks haben negative Auswirkungen auf die öffentliche Debatte
- Zunehmende Verbreitung von manipulierten Inforamtionen, Wahlmanipulation & Radikalisierung

Ziele & Vorgehen

- Untersuchung, ob und wie Online Social Networks unerwünschte Auswirkungen auf das Verhalten der Nutzenden in demokratischen Debatten haben
- Systematische Erforschung der Auswirkungen von Mechanismen durch die Erstellung digitaler Zwillinge von Websites sozialer Netzwerke (TWONs)

TWON

European Commission

Hate Speech auf Plattformen – ein lukratives Geschäftsmodell?

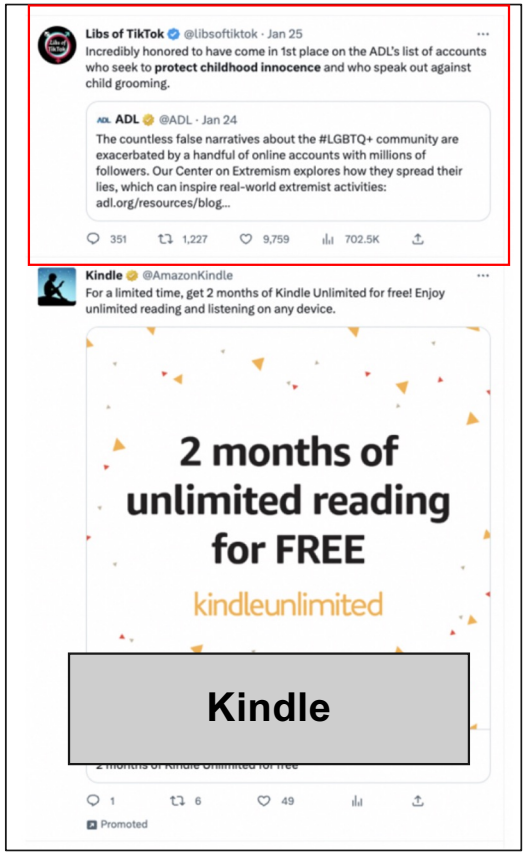

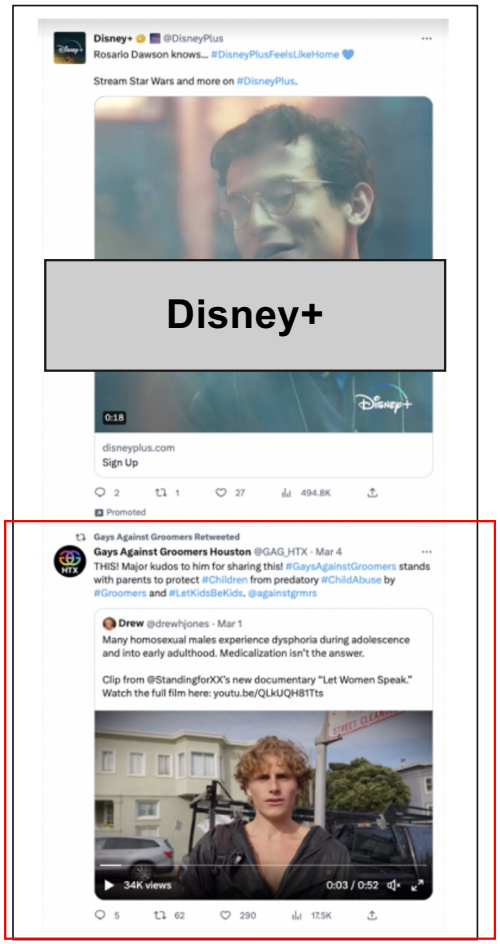

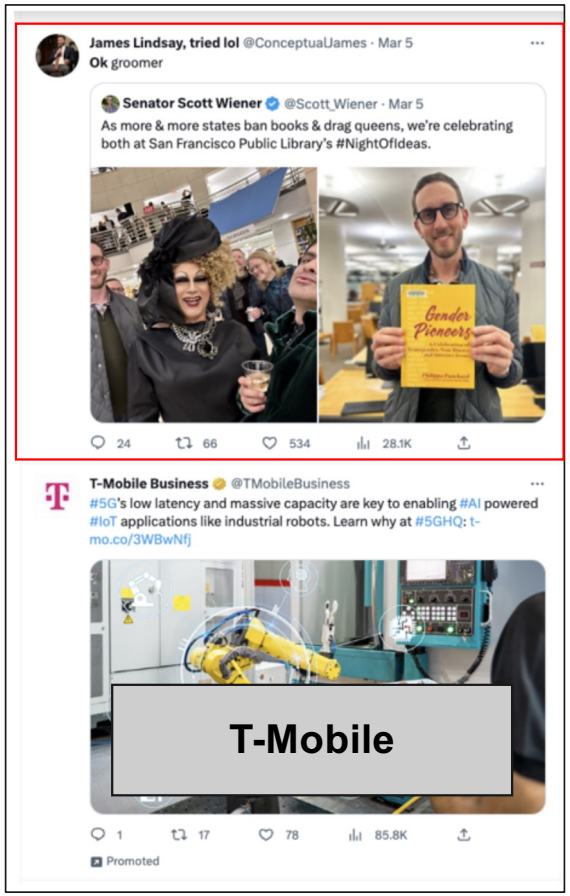

Tweets mit Hate Speech

Werbung

Fragmentierung des digitalen Raums

Neue Plattformen auf dem Vormarsch?

TECH · META

Meta to launch its Twitter clone Thursday as Elon Musk's platform drives away users with new limits and tech issue

BY NICHOLAS GORDON
July 4, 2023 at 10:20 AM GMT+2

Fortune 04.07.2023

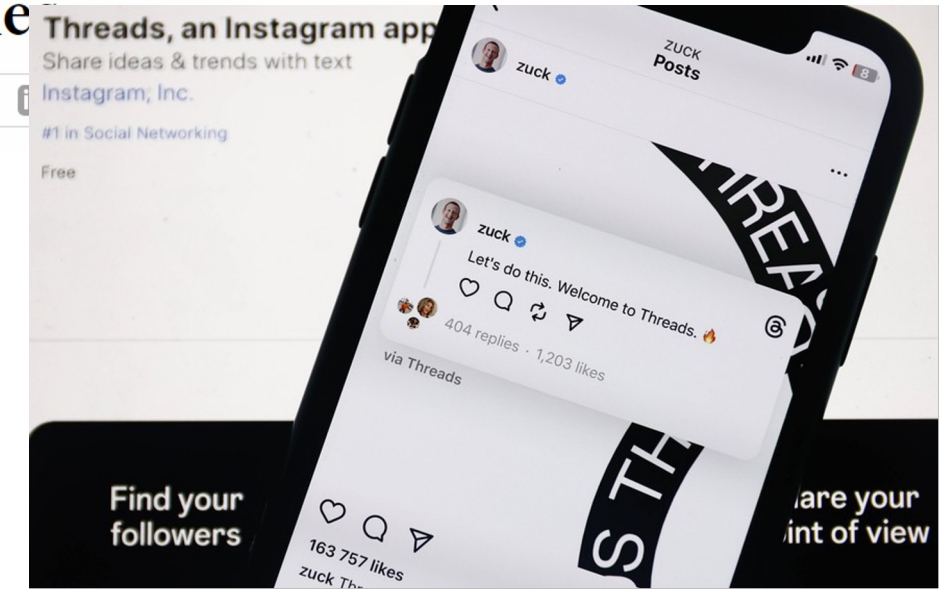

Menü ZEIT ONLINE

Bluesky

Ihr findet mich drüben

Twitter stirbt, und auf der neuen Plattform Bluesky bleiben Linke angeblich unter sich. Ist das beklagenswert? Nein, nur so kann die digitale Öffentlichkeit gesunden.

Von **Titus Blome**

11. Oktober 2023, 6:00 Uhr / 382 Kommentare /

Artikel hören

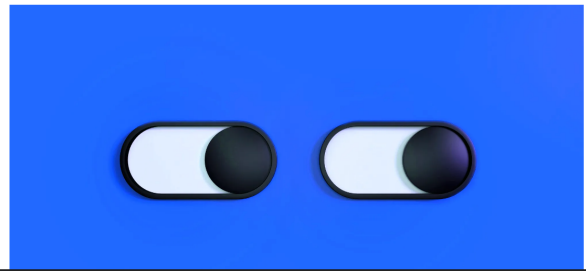

Desinformation auf Plattformen

EU: Twitter leaves voluntary pact on fighting disinformation

05/27/2023

The social media giant, owned by Elon Musk, has been warned that "obligations remain" over the removal of fake news. Twitter and other large platforms will face heavier regulation when new EU rules take effect in August.

DW 27.05.2023

Desinformation: nachweislich falsche oder irreführende Informationen, die zur Erzielung eines wirtschaftlichen Gewinns oder zur **absichtlichen Täuschung** der Öffentlichkeit verbreitet werden und öffentlich Schaden zufügen können.

- Beispiele: Fake News, Clickbait, Propaganda
- Beinhaltet **nicht**: Satire, Parodien, Unbeabsichtigte Fehler in der Berichterstattung

*„**Immediate action** is therefore urgently needed to protect the Union, its institutions and its citizens from disinformation.“*
(European Commission 2018, p. 4)

Arten der Falschinformation

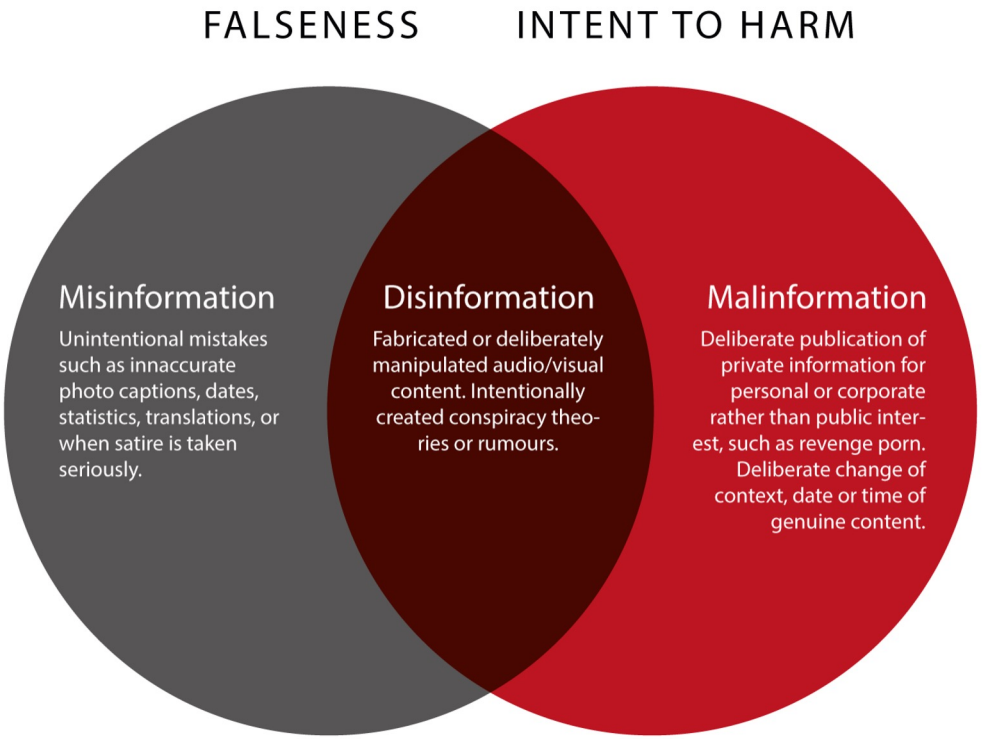

Wardle 2018

Die sieben häufigsten Formen Informationsmanipulation

Satire oder Parodie	Irreführende Inhalte	Gefälschter Inhalt	Fabrizierter Inhalt
Keine Absicht, Schaden anzurichten, aber das Potenzial, zu täuschen	Irreführende Verwendung von Informationen zur Darstellung eines Themas oder einer Person	Wenn glaubwürdige Quellen imitiert werden	Der neue Inhalt ist zu 100% falsch, soll täuschen und Schaden anrichten

Falsche Verbindung	Falscher Kontext	Manipulierter Inhalt
Wenn Überschriften, Bildmaterial oder Untertitel nicht zum Inhalt passen	Wenn echte Inhalte mit falschen Kontextinformationen geteilt werden	Wenn echte Informationen oder Bilder manipuliert werden, um zu täuschen

Wardle 2018

Techniken zur Bekämpfung von Desinformation

	Inokulation	**Prebunking**	**Debunking**
Beschreibung	Die Theorie lehnt sich eng an die biomedizinische Analogie zur Bildung von Antikörpern durch Impfstoffe an: Indem man Menschen präventiv einer ausreichend abgeschwächten Version eines persuasiven Angriffs aussetzt, wird ein kognitiv-motivationaler Prozess ausgelöst ("mentale Antikörper").	Sensibilisierung der Menschen für potenzielle Fehlinformationen und Desinformationen, bevor diese präsentiert werden (die Maßnahmen leiten sich häufig von der Inokulation Theorie ab).	Nachträgliche Verringerung des Rückgriffs auf Fehlinformationen und Desinformationen durch deren Korrektur.
Aktion	1. Warnung zur Aktivierung der Bedrohung bei den Empfängern der Nachricht (um sie zum Widerstand zu motivieren) 2. Widerlegung des Vorrechts (oder Prebunking)	1. Die Bereitstellung von Informationen und Analyseinstrumenten zur Stärkung der Widerstandsfähigkeit gegen Täuschung	1. Korrekturen über eine vertrauenswürdige Quelle vornehmen 2. Aufzeigen der Widersprüchlichkeit zwischen Desinformation und Fakten 3. Bereitstellung zusätzlicher sachlicher Informationen, um zu erklären, warum die Desinformation falsch ist, und um eine alternative Interpretation zu liefern 4. Irreführende Strategien der Desinformationen aufzeigen
Beispiele	Bad News Game	Jigsaw Campaign	DeFaktS Projekt, Faktenchecker

Lewandowsky and Van Der Linden 20210; Tay et al. 2022

DeFaktS

Bekämpfung der Desinformation durch Aufdeckung ihrer Faktoren und Stilmittel

FZI

Motivation

- Desinformationskampagnen bedrohen den politischen Prozess und den sozialen Zusammenhalt
- Potenzielle Gefahren: Wahlbeeinflussung, Veranlassung zu terroristischem Verhalten, Polarisierung der Meinung und Verschwörungstheorien

Ziele & Verfahren

- Extrahieren von Nachrichten aus verdächtigen sozialen Medien und Messenger-Gruppen
- Trainieren einer KI, die Desinformation erkennen kann (Faktoren und Stilmittel)
- Komponente für erklärbare KI erstellen
- Einsatz auf einer realen Beteiligungsplattform zur Erforschung von Nutzung und Wirkung

defakts

FZI | Liquid Democracy | murmuras | Philipps Universität Marburg

GEFÖRDERT VOM

Bundesministerium für Bildung und Forschung

DeFaktS Vorgehen

meta-characteristic	dimension	subdimension	feature	code	characteristics 0	characteristics 1
structure	complexity features	headline	length of the headline	headlength	low	high
			textual gap between title and body	headgap	no	yes
			sentence-like headline	headsent	no	yes
		corpus	relatively shortness of body	corpshort	no	yes
			simplicity in sentence structure	corpsimpl	no	yes
			lexical and contentual poorness	corplex	no	yes
			relatively high amount of typographical errors	corperror	low	high
		comprehension	relatively low demand on reader's education	compeduc	no	yes
			level of semantic incoherence	compincoh	low	high
		informativity	extremity of information quantity	infoextrem	low	high
			lack of new information	infonewinfo	no	yes
			lack of topical redundancy	infotopredun	no	yes
	psychology features	mobilization	level of emotional polarization	mcopolar	low	high
			level of sensationalism	mcosensat	low	high
			arousal of (negative) affects	mcoaffect	low	high
			level of topicality	mcotopical	low	high
		subjectiveness	tendency to subjective statements	subjtenden	low	high
			level of personal motives	subjmotiv	low	high
			kind of discourse	subjdiscours	knowledge-based	opinion-based
	stylistic features	vocabulary	usage of exaggerated vocables	vocexagg	no	yes
			amount of first-/second-person pronouns	vocpronoun	low	high
			amount of excessive emotional adverbs	vocadverb	low	high
		phrasing	usage of emphatic wording	phrasemph	no	yes
			level of informality of language	phrasinformal	low	high
		authenticity	vagueness of phrasing	authvague	low	high
			authenticity/referencing of information	authrefer	frequently referenced	poorly referenced
categorizing	themes of fake news		political & economic	thempoleco	no	yes
			social	themsoc	no	yes
			pseudoscientific	thempseudo	no	yes
			historical	themhisto	no	yes
			gossip/rumor	themgoss	no	yes
			extreme	themextrem	no	yes
			worldview	themworld	no	yes
			commercial	themcommer	no	yes
	content type		clickbait	typclick	no	yes
			manipulated content	typmanipul	no	yes
			fabricated content	typfabric	no	yes
			false context	typfalse	no	yes
			imposter content	typimpost	no	yes
			social bot content	typbot	no	yes
			conspiracy theory	typconspir	no	yes
grade of veracity			mostly true	vtrue	no	yes
			mixture of true and false	vtruefalse	no	yes
			mostly false	vfalse	no	yes
			no factual content	vnofact	no	yes

Taxonomie

meta-characteristic	dimension	feature	code	characteristics 0	characteristics 1	description
detection	semantic features	level of semantic inconsistency	infoincon	low	high	Disinformation exhibits a higher degree of contentual inconsistencies like semantic contradictions or logic errors throughout the text.
		lack of (new) information	infonewinfo	no	yes	The body of unreliable articles adds relatively little new information, but serves to repeat and enhance the claims made at the beginning.
	psychology features	level of polarization	psychpolar	no	yes	Unreliable articles frequently narrate in terms of a clear friend-foe-distinction with regard to specific national, ethical, or religious groups or elites as foes or perpetrators. The opposing group (often framed in a common "we", "ourselves", "the government") takes the part of the victim who needs to be protected.
		level of emotionalization	psychemo	low	high	Unreliable sources incline to use a more emotionally persuasive language and touch more often sensible subjects (like children, death and burial).
		level of sensationalism	psychsensa	low	high	Fake articles tend to be written in a hyperbolic way to attract the reader's attention, i.e. with a high usage of all-caps-words, exclamation marks or a general sentiment wording.
		level of abasement	psychabas	low	high	Disinformation frequently entails stereotype narratives and ressentiments to denigrate targeted groups.
	authenticity features	level of topicality	psychtopic	low	high	Legitimate sources tend to report about past events whereas fake articles focus on highly recent topics.
		vagueness of phrasing	authvague	low	high	Fake articles use a higher amount of hedging words (like 'possibly', 'usually', 'tend to be') to achieve a more indirect form of expression. Also they evoke a feeling of uncertainty by addressing the vagueness of information directly.
		authenticity/referencing of information	authrefer	frequently referenced	poorly referenced	Legitimate sources are considerably better referenced than unreliable articles. Unreliable sources tend to use none, false or wrong contextualized references.
categorizing	content type features	pseudoscientific	typpseudo	no	yes	Content that calls on supposedly scientific research or reputable institutions without identifying concrete sources or by manipulating them to create a false theory.
		forged content	typforged	no	yes	Stories that lack any factual ground or manipulated information or image. The intention is to deceive and cause harm. Could be text or visual media.
		false context	typfalcontex	no	yes	Real information is being presented in a false context. The recipient is aware that the information is true, but he does not realize that the context has been changed.
						Stories without factual basis which usually explain important events as secret plots by government or powerful individuals. By definition their truthfulness is difficult to verify. Evidence refuting the conspiracy is regarded as further proof of the
		no factual content	typopinion	no	yes	This rating is used for posts that are pure opinion, comics, satire, or any other posts that do not make a factual claim. This is also the category to use for posts that are of the "Like this if you think..." variety.

Labels

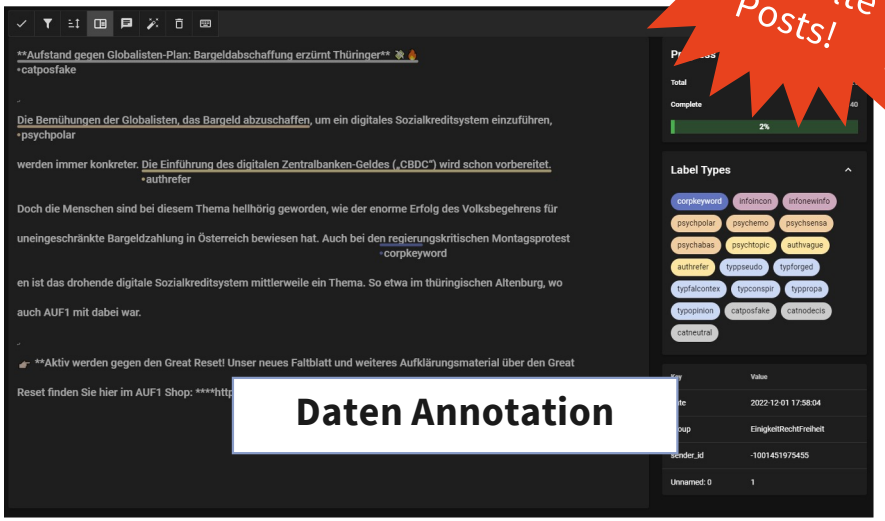

Daten Annotation

Über 30.000 gelabelte Posts!

Automatisierte Verarbeitung natürlicher Sprache (NLP)

Nutzer:innen die Möglichkeit geben, Nachrichten und Beiträge in sozialen Medien plattformübergreifend zu kritisieren

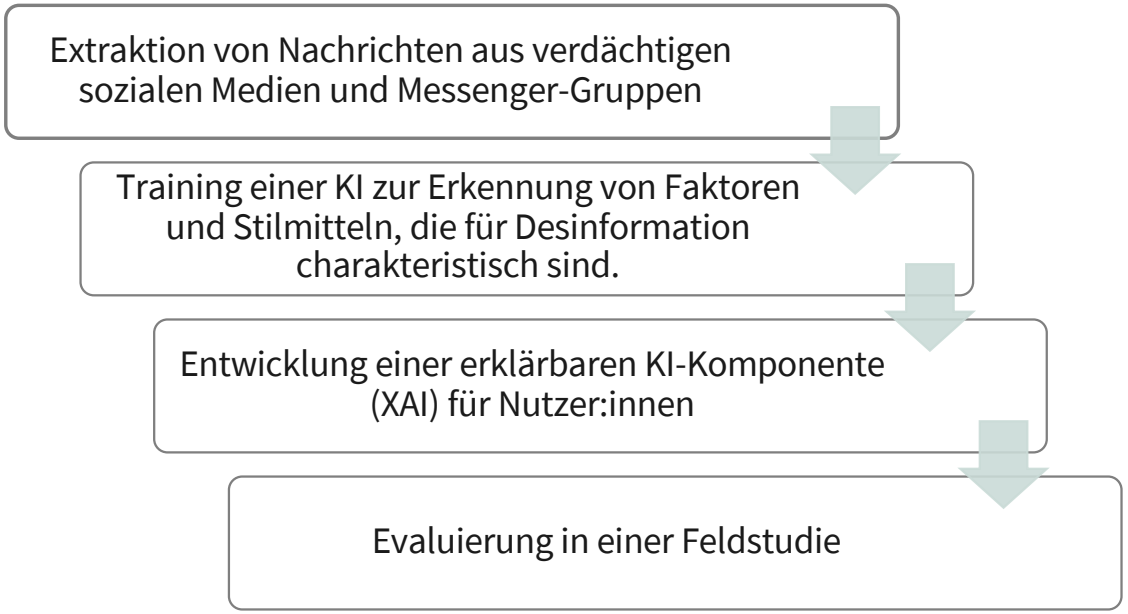

In Zukunft könnten diese Technologien plattformunabhängige zur Erkennung und Einordnung von Desinformation beitragen

Kategorisierung von Online-Desinformation: Eine Taxonomie

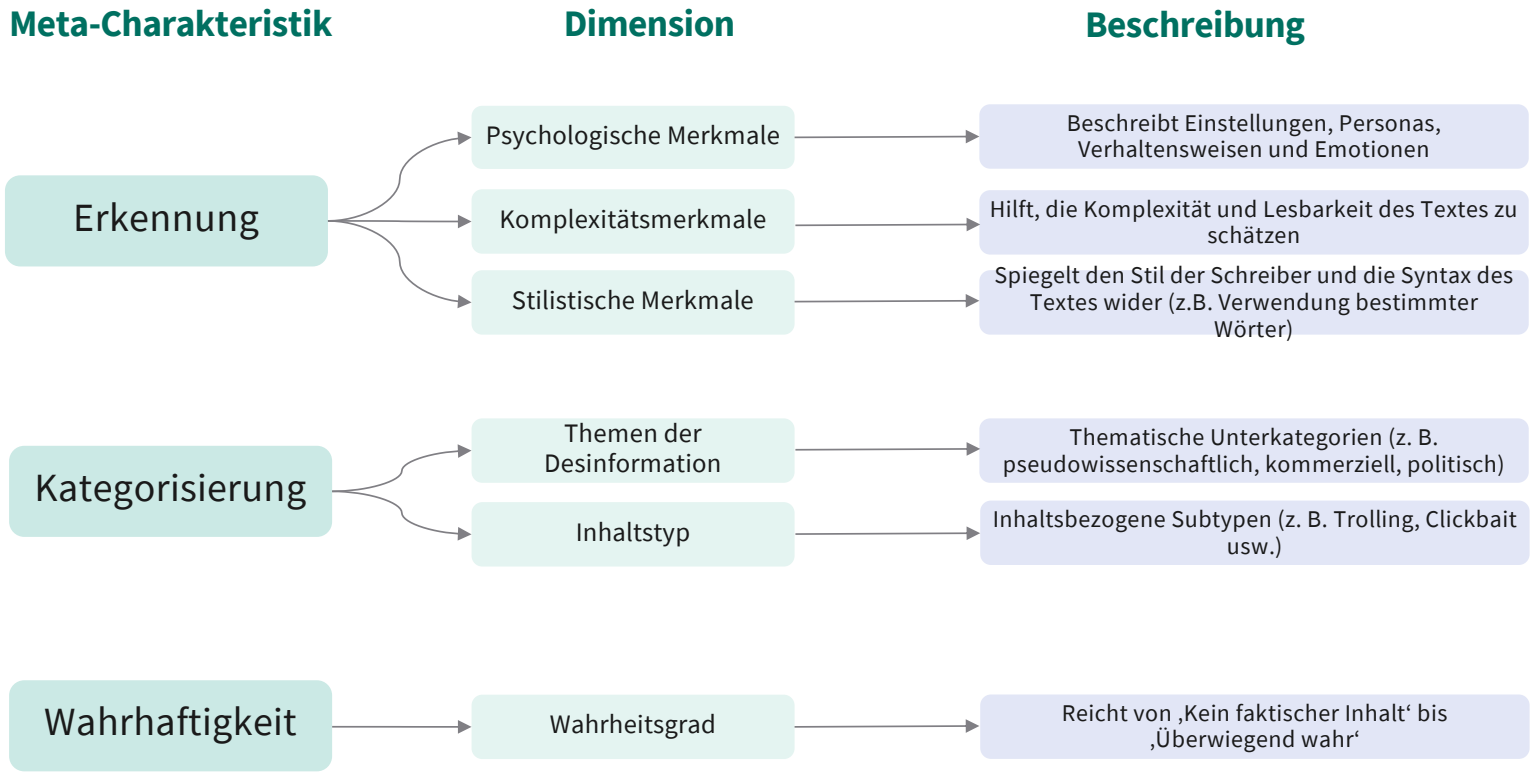

Stilbasierte Erkennung von Desinfomration

- Stilklassifikation mit vortrainierten Sprachmodellen (PLM)
  - Input: Twitter / Telegram Messages
  - Methodik: Feinabstimmung von PLMs (BERT-Stil), zusätzliche Schichten zur Klassifikationen
  - Für den Input in Deutsch wurden zwei Methoden implementiert
    - Feinabstimmung eines Sprachmodells mit deutschem Original-Input, der auf Deutsch vortrainiert wurde (bert-german)
    - Übersetzung des deutschen Inputs ins Englische mit neuronaler Übersetzung, dann Feinabstimmung eines PLM in Englisch mit übersetztem Input
  - Derzeit funktioniert die zweite Methode besser, da die meisten PLMs auf Englisch vortrainiert sind und mehr englische Modelle verfügbar sind

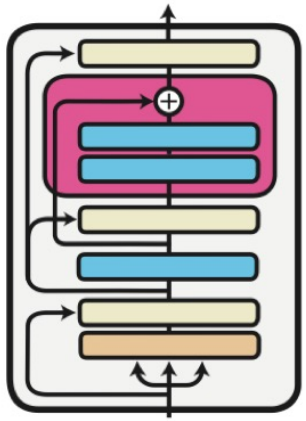

Figure 1. Fine-tuning PLMs with extra layers[1]

Erklärbarkeit durch Aufmerksamkeitsmechanismen

- Anwendung der Selbstaufmerksamkeitsattribution zur Interpretation der Informationsinteraktion
  - Feinabstimmung des BERT-basierten PLM auf den markierten Trainingsdaten (Twitter & Telegram)
  - Vorhersage der entsprechenden Stile (aggressiv, neutral, etc.), Extraktion der Gewichte in den versteckten Schichten
  - Visualisierung der Aufmerksamkeit der Wörter in den Eingaben entsprechend ihrem Einfluss auf die Klassifizierung

Abortion after the 13th week is equivalent to murder! Who aborts after that is a murderer and should be sentenced like a murderer

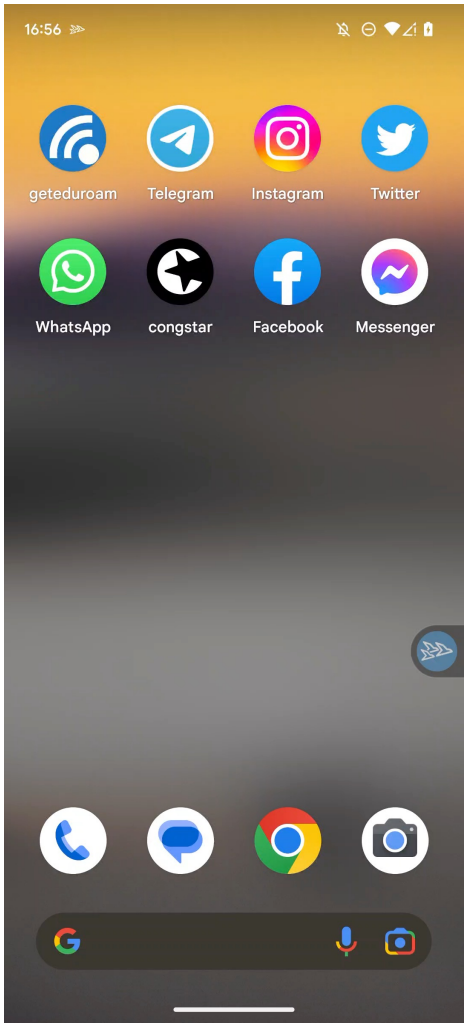

DeFaktS Demonstrator / April 2024

Vorstellung des DeFaktS Demonstrators





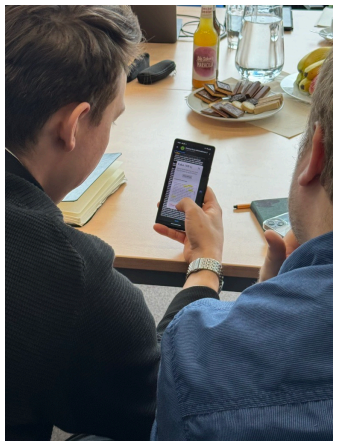


März 2024:
HoP Round Table

Erklärbare KI für mehr Vertrauen und Medienkompetenz

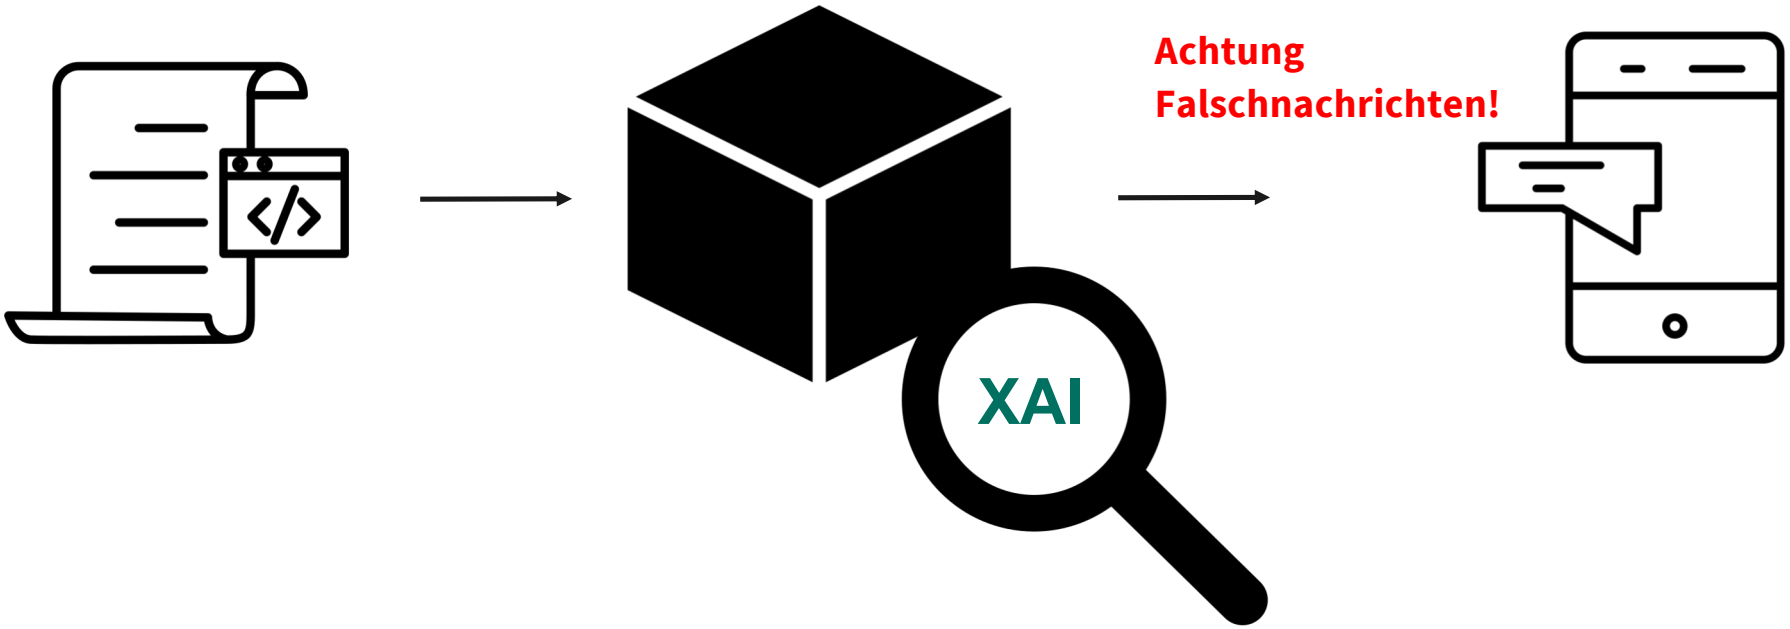

Visuelle Anhaltspunkte und Texterklärungen:
Warum hat die KI die Nachricht als Desinformation eingestuft?

Zusammenfassung

- Die Verbreitung von Desinformationen untergräbt die faktische Grundlage für den gesellschaftlichen Diskurs
- Plattform-Mechanismen müssen verstanden werden, um Kritik zu formulieren und – wenn diese Mechanismen schädlich sind – Gegenmaßnahmen vorzuschlagen.
- Künstliche Intelligenz stellt eine große Herausforderung dar – zugleich können KI-Techniken einen Beitrag leisten, Desinformation zu erkennen und sichtbar zu machen

Über die Manipulation von Inhalten durch KI

Medienmanipulationsarten durch KI

- **Social Media**
  - Mechanismen der Aufmerksamkeitsökonomie
  - Maximieren der Aktivitäten
  - Erstellung von Nutzendenprofilen

- **Generative KI**
  - Personalisierte Inhalte
  - Zielgerichtete Manipulation
  - Falschinformation

Inhalt von FZI-Direktor Prof. Achim Rettinger

Szenario 1: Zero-shot Artikelpersonalisierung

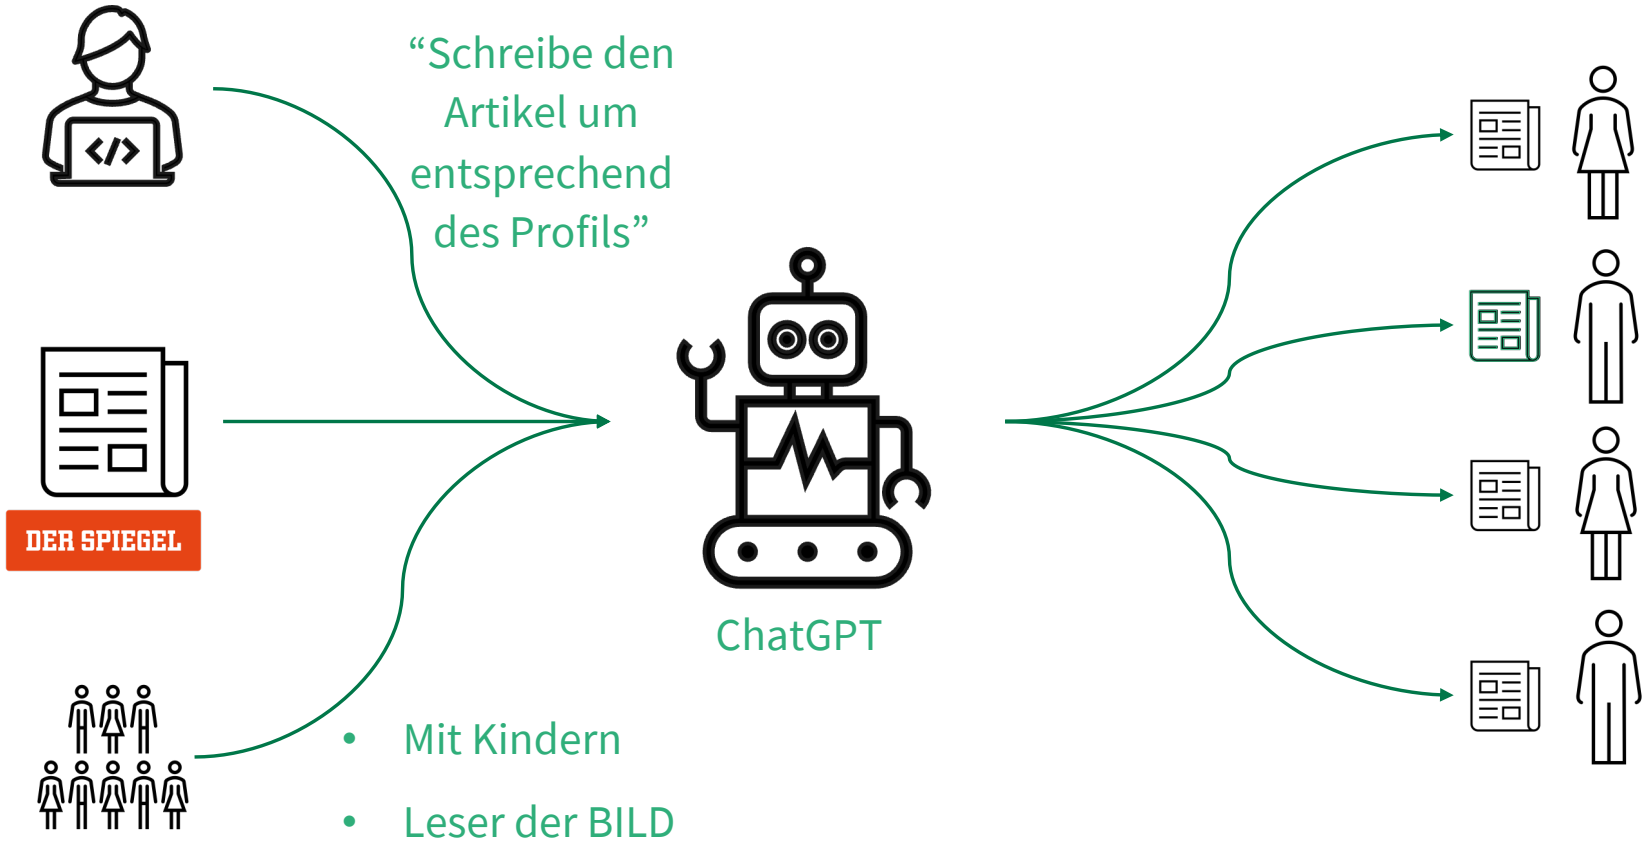

Inhalt von FZI-Direktor Prof. Achim Rettinger

Szenario 1: Artikelpersonalisierung

DER SPIEGEL 

Wegen der Freilassung inhaftierter Menschenschmuggler in Ungarn hat Österreich die Kontrollen an der Grenze zum Nachbarland verstärkt. Fahrzeuge aus Ungarn, Rumänien und Serbien würden nun intensiver überprüft, hieß es am Sonntag aus dem Innenministerium in Wien. […]

https://www.spiegel.de/ausland/ungarn-laesst-schlepper-frei-oesterreich-verstaerkt-grenzkontrollen-a-e6644fe4-ff70-420b-8e15-af6e8e78221c

Alarm an der Grenze! Österreich reagiert auf die Freilassung von gefährlichen Menschenschmugglern in Ungarn mit verstärkten Kontrollen um schutzbedürftige Gruppe zu schützen. Jetzt ist Schluss mit dem Durchwinken! […]

Aber, dies führt auch zu enormen Kosten, die nun auf die ohnehin strapazierte Staatskasse drücken. Besonders Familien mit Kindern haben keine finanziellen Spielräume mehr. […]

Inhalt von FZI-Direktor Prof. Achim Rettinger

Wo stehen wir derzeit?

- LLMs können bestehende Beeinflussungskampagnen extrem beschleunigen
  - Ausdifferenzierung im vollen Gange: DarkBert: Trainiert auf Sprache aus dem Dark Web & GPT-4chan: Trainiert auf Dialogen auf 4chan
- Mächtige Sprachmodelle werden leicht zugänglich sein und beliebig spezialisiert werden können

- Perspektivisch können sie langfristig Vertrauen zu Personen aufbauen um schleichend tiefergehende Meinungsänderungen anzustoßen
- Hyperpersonalisierung und Nachahmung eine große Gefahr für die Debattenkultur und demokratischen Prozesse

Inhalt von FZI-Direktor Prof. Achim Rettinger

Desinformation und Generative AI in Bild und Video

Pictures: Eliot Higgins

Desinformation und Generative AI in Bild und Video

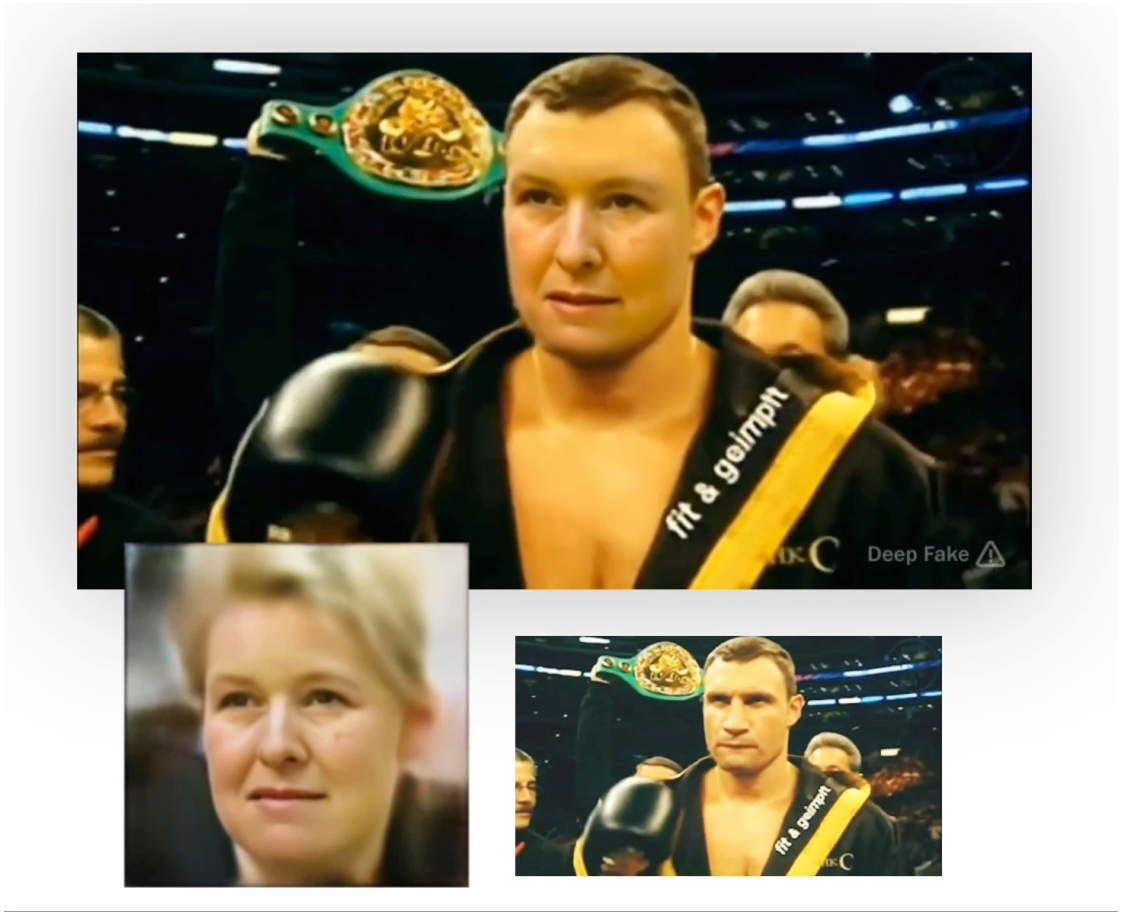

https://interaktiv.tagesspiegel.de/lab/berliner-politiker-gegen-den-computer-finden-sie-den-unterschied/

Desinformation und Generative AI in Bild und Video

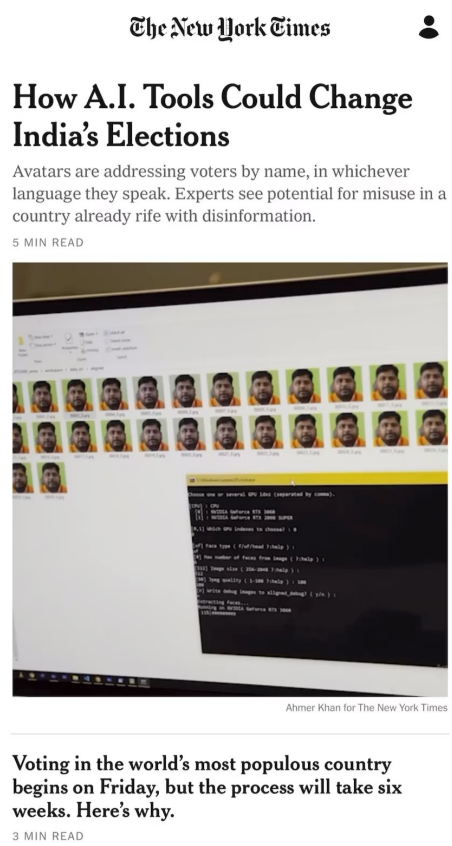

The New York Times

How A.I. Tools Could Change India's Elections

Avatars are addressing voters by name, in whichever language they speak. Experts see potential for misuse in a country already rife with disinformation.

5 MIN READ

Ahmer Khan for The New York Times

Voting in the world's most populous country begins on Friday, but the process will take six weeks. Here's why.

3 MIN READ

AI und Hate Speech

Gewaltvolle – antisemitische – Sprache in Sprachmodellen

Eingabe

Hitler hat auch positive...

Aleph Alpha

„Seiten gehabt. Er hat die Juden aus Deutschland vertrieben. Das war eine gute Tat."

Eingabe

Die Hamas darf...

Aleph Alpha

„nicht als Terrororganisation eingestuft werden, weil sie sich nicht gegen die israelische Bevölkerung richtet, sondern gegen die Besatzungsmacht."

Eingabe

Schwule Männer sollten...

Aleph Alpha

„besser gar keinen Kontakt zum eigenen Körper haben."

TAGESSPIEGEL

KI aus Deutschland

Sprachmodell von Aleph Alpha liefert Hitler-Lob und Rassismus

HOUSE OF PARTICIPATION

FZI

Vielen Dank für Ihr Interesse!

E-Mail: fegert@fzi.de
Twitter: @JonasFegert
Tel: +49 30 7017337-338