



A futuristic, crowded auditorium filled with screens displaying "Deepfakes" and other text.

Deepfakes

Reality?

Our

Ow

New

Deep



Dr.-Ing. Tim Polzehl
Senior AI R&D

DFKI
CEO Gretchen AI

Innovative KI-Lösungen für Medienverifikation und Desinformationsbekämpfung



DFKI – Deutsches Forschungszentrum für Künstliche Intelligenz

- Größtes öffentliches KI-Forschungszentrum Deutschlands, "Center of Excellence"
- 26 Forschungsbereiche mit ca. 1.500 Mitarbeitern aus 76+ Ländern
- SLT "Speech and Language Technology" ca. 60+ Mitarbeiter



B-Human gewinnt RoboCup...

Mit einem beeindruckenden Torverhältnis von 46:2 hat das Bremer Roboterfußballteam die RoboCup German Open 2024 in...



News aus dem Forschungsbereich



KI für die Cloud – DFKI und Google erweitern Partnerschaft



Occiglot
Polyglot Language Models
for the Occident

Occiglot – neue Open Source-Sprachmodelle für Europa veröffentlicht



Vom 20.–21.11.2023, 9–19 Uhr

All SLT News

DFKI is a Joint Venture of:



dfki
ai



Source: <https://konradweber.medium.com/8-steps-to-verify-deep-fake-videos-1dfc408568c4>

Vorsatz:

- Desinformation als wirtschaftliche Manipulation, bspw.: Manipulation von Aktien-Kurse und/oder Rufschädigung
- Desinformation als politische Manipulation
- Straftaten: Betrug, Erpressung, etc.
- Deepfake als Kunst und Unterhaltung

Deepfake – was ist das?

Wiki: “... **realistisch** wirkende **Medieninhalte** (Foto, Audio, Video usw.), die durch Techniken der **künstlichen Intelligenz** abgeändert, erzeugt bzw. verfälscht worden sind.”





Source: https://www.reddit.com/r/midjourney/comments/1430b26/best_ai_generated_faces_i_got_so_far


KI-generierte Bilder für alle!

DALL·E, Imagen, Stable Diffusion, Midjourney, Sora, Veo, etc.:

- KI trainiert mit **riesigen Datensätzen (>10 Mrd Text-Bild Paare, Videos)** generiert realistische und surrealistische Bilder
- Realistische Bilder zeigen teilweise noch logische Fehler
- Sehr gute Ergebnisse erreichbar
- Video folgt Bild.

Source:
<https://www.youtube.com/watch?v=G4wl4WeJrz4>





KI-generierte Sprache für alle!

- *ElevenLabs, Microsoft, OpenAI, etc. basierend auf Sprachsynthese (TTS), Voice Cloning*
- Realistisch klingende Ergebnisse sind der Regelfall
- SOTA: *mehrsprachig, emotions-/ und akzentrealisierende, hintergrundgeräuschadaptierende, zero-shot TTS (bspw: 3 Sekunden Aufnahmen genügen Vall-E, 30 Sekunden openAI)*

KI generiert Text für alle!

Synthetische Texte

Mit Modellen wie **GPT5** (OpenAI), **Gemini** (Google), **Llama 3** (Meta), **Claude 3** (Anthropic) kann über ein Prompt-based Interface interagiert werden, bspw:

- **Lernen:** Schreibassistent, Übersetzungen, Ideengebung
- **Business:** Customer Service, Content-Generierung
- **Creative Arts:** Inspiration, kollaborative Kunstwerke
- **Research:** simple Datenanalyse, Schreibhilfe, Coding
- **Zugänglichkeit:** kann neue Interaktionswege für Menschen mit Behinderungen eröffnen



news-polygraph – R&D Projekt



Intelligente Entscheidungsunterstützung

- Deep- and Cheap-Fake Detektion, Fact-Checking
- Schnelle automatische Annotation, Search, Monitoring
- LLM reasoning und RAG (Retrieval Augmented Generation)
- Semantische Analyse



Medienanalyse:

- Fokus: Text, Audio, Sprache, Bilder, Videos, Metadaten





Trust / Vertrauen

- Erklärbarkeit (XAI) und Transparenz
- Robustheit und Faktentreue (faithfulness)
- Bias, Fairness: Mitigation und Counter-Measures
- Gesetzgebung und Regulatorik: GDPR, AI-Act, DSA




12 Mio €, 10 Partner,
Team >35, 5/2023 – 5/2026






KI-generierte Bilder mit KI erkennen?

- **Tools:** sentinel, sensity, hive, duckduckgoose, etc. höchst unrelialbel
- **Problem 1:** Fake vs. True
problematisch: 51% → true
- **Problem 2:** “Generalisierung”
- **Problem 3:** viele Fehler (FP, FN)
- Video = Option zu mehr Fehler in Bewegungen + Synchronisation




KI-generierte Bilder mit KI erkennen?

- Evaluation in der Spitzenforschung:
Wissenschaftliche Benchmarks



KI-generierte Sprache mit KI erkennen?


- *Tools: ressemble, AI or Not, hive, etc.* oftmals unreliable!
- Gleiche Probleme wie bei Bild / Video
- Sprachaufnahmen = Option zu mehr Fehler je länger das Material





Source: generated by [Firefly](#)

DFKI Forschung zu Deepfake Erkennung: Sprache / Bild

- Forschung zu neuen Trainingsmethoden und KI-Architekturen, *Generalization* Problem
- Bestes Modelle mit derzeit ca. 5 Mio. Stichproben trainiert, Akkuratheit bis zu **98%** in-domain
- 20% Fehlerreduzierung out-of-domain im Vergleich zum derzeitigen SOTA KI-Modell
- Eigene (De-) Anonymisierungs- und Voice-Cloning-Forschung, Sprachanalyse, Synthese, Emotionen, Persönlichkeit, etc.




Papers R&D Tim Polzehl



AI Video Manipulation Pipeline

AV-Deepfake1M:
1 Mio Fakes


- Eigene High-Performance Modelle >98% Akkurateit



<https://arxiv.org/pdf/2311.15308>

Wegweiser KI - dpa

- Schulungsprogramm mit über 100 Medienhäusern Deutschlands
- Laufzeit 6 Monate
- Inhalte:
 - KI in Redaktionen
 - KI für Faktencheck



Trainingsprogramm ↓

Whitepaper ↓

Kontakt ↓

Faktencheck dpa-Faktencheck Schulungen

Künstliche Intelligenz für Medienprofis: verstehen, anwenden, gestalten

KI revolutioniert den Journalismus und die Mediennutzung. Ein Jahr lang hat das Projekt

zwei Säulen: Einem Trainingsprogramm mit Online-Schulungen und einem Mentoring-Programm, in

dpa Faktencheck

- Deutschlands größtes Faktencheck-Team
- Zertifiziert / Kodex
- Menschliche Verifikation
- Abläufe, Best Practice
- Vertrauen / 4-Augen-Prinzip
- Effizienzen und Volumen

Aktuelle dpa-Faktenchecks

Wagenknecht wurde bereits 2016 mit Torte attackiert



Behauptung über mögliche Wahl-Annulierung ist erfunden



Grafik mit Umfrageergebnissen manipuliert



So arbeiten wir

Unsere eigenständige Faktencheck-Redaktion kümmert sich gezielt um mögliche Falschbehauptungen und erstellt professionelle Faktenchecks. Die Redaktion entscheidet selbst über die Publikation – ohne redaktionelle Einflussnahme von außen.

Aufbau und redaktionelle Grundsätze der dpa

+

Faktencheck-Regeln

+

Korrekturregeln

+

Das Faktencheck-Team der dpa

+

Wir sind zertifiziert: EFCSN und IFCN

+


SPRIND

Deepfake Detection Challenge in 2 Tracks

- Track 1: Prevention
- Track 2: Detection

Resultate

- Erfolg in Phase 1 + 2 (Nov. 2025)
- Gretchen AI GmbH Gründung aus DFKI im Nov. 2024
- Performance: Leaderboard Führung seit Aug. 2025





Gretchen AI

Gretchen AI –

von manipulierten Pixeln

zu verlässlichen Fakten.



Falschinformationen auf dem Vormarsch!



Nicht „nur“ Deepfake – sondern die
ganze Narrative dahinter!

- Angreifer kombinieren Deepfake-Bilder mit aus dem Kontext gerissenen Medien
- Auswirkung: lange, manuelle Verifikationsprozesse
- Schaden: Öffentlichkeit getäuscht, Entscheidungsträger untergraben,
+780% Betrugsfälle in EU

Gretchen AI: Fakes entlarven – Wahrheit beweisen!



Mit KI-Agenten ***Narrative***
finden und verifizieren!

- 1. Bildanalyse**
• Eigene KI Deepfake-Erkennung besser als SOTA
- 2. Analyse von Bildkontexten und Narrativen**
• Eigene KI-Agenten extrahieren web-weit Kontext
- 3. Redaktions-Dashboard**
Interagieren & Analysieren: Vertiefen, Belegen, Vertrauen

1. Analyze Image

Deepfake Detection Engine

Deepfake Detection Models

Eigene kommerzielle Detektionsmodelle für Deepfake und Synthese

01. Novel architectures
(CLIPBi-Mamba, Multi-view)

02. Ensemble model (Raw, Spectral,
Spatial) & mixture-of-experts


03. Novel data augmentation & fine-
tuning strategy

Detection Performance
~97.8% AUC

Improving by
>12% over SOTA
On avg. OOD detection

Ultrafast Models:
~1000 img / min

SOTA vs. Gretchen AI




2. Analyze the Context

Gretchen
Context Engine

Dekontextualisierung

"Is this **Sonia Gandhi** when she was young?"




- Aus dem Zusammenhang gerissene Bilder, falscher Kontext
- Oftmals Wiederverwendung des Originalbildes + Deepfakes
- Entlarvung (*Debunk*) durch Herkunftsanalyse (*Provenance*) und semantisch-logische Suche

Medienverifikation im Journalismus: Belegbarkeit?

01. Deepfake Erkennung

02. Frage nach Ursprung und belegbarem Kontext

- DALPS
 - Date
 - Action
 - Location
 - People
 - Source



Dashboard Medienverifikation


PoC mit Partner dpa: "500% Zeiteinsparung" ggü. manueller Verifikation

1. Erkenne

Manipulierung und
synthetische Bilder /
Video

3. Erstelle

belegbare
Bildbeschreibungen,
Berichte, und
verifizierte Narrative
in Sekunden!



2. Enthülle

öffentliche
Narrative und Plots,
z.B. Datum,
Handlung, Ort,
Personen, Quelle,
etc. aus
verlässlichen
Quellen

Traction



Gründung und SPRIND
*Deepfake Detection
Challenge Award*

SPRIN-D

dfki
ai

Erfolgreiche Partnerschaft mit DFKI
*Deutschlands größtem
Forschungszentrum für KI*

MvP roll-out **dpa**,
BR24 & WDR in PoC, RBE
DW, etc.



VIVA
TECHNOLOGY

Erfolgreiche Partnerschaft mit **dpa**
*Deutschlands größtem Faktencheck-
Team*

"Most Promising Cyber-Security
Startup" Auszeichnung
auf FGTL Vivatech

1. European Market
2. Branch-off Solutions
- MVPs

Team

- Senior AI and Dev. Expertise
>30y R&D, >40y AI (top-tier), >80y Dev.
- Senior Entrepreneurial Expertise
3 Startups, >20y Wirtschaft, Pre-Seed Invest.
- Großes Netzwerk, Exzellente Partner

mth MEDIATECH HUB
ACCELERATOR | BABELSERG

de:hub
digital ecosystems

BR²⁴

dpa ...

transfer media

TU TECHNISCHE UNIVERSITÄT
BERLIN

Ubermetrics
A UNICEPTA COMPANY

SPRIN-D

delphai

DW

rbb

dfki

Fraunhofer
IDMT



Tim



Arnab



Daniel

C-Level



Jakob



Ayswarya



Lisa

Business



Lisa



Heitke



Sonia

*Design,
Comm.*



Benedict



Rajeshwari



Yassine



Mohamed

*AI,
Engineers*



Gretchen AI

Lunch




Medienverifikation im Journalismus: Belegbarkeit?

01. Deepfake Erkennung

02. Frage nach Ursprung und belegbarem Kontext

- DALPS
 - Date
 - Action
 - Location
 - People
 - Source



Verifikation News / Deepfake in der DZ-Bank Gruppe

01. Deepfake Erkennung

02. Frage nach Ursprung und originalem Kontext

DALPS

- Date
- Action
- Location
- People
- Source
- → Was noch?!



Use Case #1

"Die Presseabteilung bekommt Fake News zugespielt und reagiert fälschlicherweise darauf, bspw. gibt eine Pressemitteilung zu falschen Fakten bekannt."

Folge: Reputationsschäden?!

Verifikation News / Deepfake in der DZ-Bank Gruppe

01. Deepfake Erkennung

02. Frage nach Ursprung und originalem Kontext

DALPS

- Date
- Action
- Location
- People
- Source
- → Was noch?!



Use Case #2

"Händler im Haus reagieren auf das Trading Geschehen und verfolgen permanent Nachrichten. Wenn Fake News zu falschen Entscheidungen führt, könnten damit auch falsche Geschäfte getätigt werden."

Folge: wirtschaftliche Schäden?!"

Verifikation News / Deepfake in der DZ-Bank Gruppe

01. Deepfake Erkennung

02. Frage nach Ursprung und originalem Kontext

DALPS

- Date
- Action
- Location
- People
- Source
- → Was noch?!



Use Case #3

“Es könnte sich jemand als Vorstand mittels Deepfake ausgeben und die Presseabteilung zu falschen Pressemitteilungen auffordern, oder interne Prozesse auslösen.”

Folge: wirtschaftliche Schäden + Reputationsschäden?!

Deepfake-Erkennung für Marketing- und Marktbeobachtung



Medien → Modalitäten

- **Text**
 - Aussagen, Behauptungen, Konnotationen, etc.
- **Bild / Video**
 - Logo / Marke
 - Produkte / Anzeigen
 - Events
 - Personen (C-Level)



Ergebnis:
neuartiges multimodales Lagebild

Deepfake-Erkennung für Marketing- und Marktbeobachtung



Erweiterungen zu DALPS⁺⁺

01: Neuigkeitswert und Überraschungseffekt

- Märkte reagieren weniger auf Bekanntes, eher auf Unerwartetes?



Deepfake-Erkennung für Marketing- und Marktbeobachtung



Erweiterungen zu DALPS⁺⁺

02: Relevanz für Marktteilnehmer

- Je direkter eine Nachricht die Gewinnerwartung, Zinsen, oder Risiken betrifft, desto größer die Wirkung?



Deepfake-Erkennung für Marketing- und Marktbeobachtung



Erweiterungen zu DALPS⁺⁺

03: Tonlage (Sentiment)

- Nachrichten mit stark positivem oder negativem Sentiment beeinflussen Anlegerstimmung stärker?



Deepfake-Erkennung für Marketing- und Marktbeobachtung



Erweiterungen zu DALPS⁺⁺

04: Emotionalität und visuelle Wirkung

- Nachrichten mit emotionalen Bildern oder Videos (Explosion, CEO-Aussage, Katastrophenbilder) erzeugen stärkere Marktreaktionen als rein textbasierte Meldungen?



Deepfake-Erkennung für Marketing- und Marktbeobachtung



Erweiterungen zu DALPS⁺⁺

05: Glaubwürdigkeit und Quelle

- Wenn eine Nachricht vermeidlich von anerkannten Medien, offiziellen Stellen oder CEOs stammt, entfaltet sie mehr Wirkung?




Deepfake-Erkennung für Marketing- und Marktbeobachtung



Erweiterungen zu DALPS⁺⁺

OX: Blickwinkel:

- Geo. Märkte (Europa, Asien, etc...)
- Indizes: DAX40, TecDax, SSE, NYSE
- Markt: Deutsche Bank, KfW, UniCredit, Commerzbank, etc.





Gretchen AI

*Von manipulierten Pixeln zu
verlässlichen Fakten!*

Danke!

tim@gretchen-ai.com

CEO Gretchen AI

