

# Die Zukunft des Maschinellen Lernens

Warum KI uns allen gerecht werden muss

Carina Zehetmaier

# KI verändert unser Leben



Landing AI CEO Andrew Ng co-founded Google Brain's deep learning engineering team. | Photo: Landing AI

2017: KI wird jede Branche verändern. Es ist die neue Elektrizität.

2022: KI ist die neue Alphabetisierung.

# 2023: Umfrage Trend Magazin



- 48 % sind sich sicher, dass sie noch nie KI genutzt haben
- 20 % wissen es ganz einfach nicht
- 8 % haben noch nie von KI gehört

KI hat längst Einklang in unser Leben gefunden

# ChatGPT erreicht in 5 Tagen 1 Mio Nutzer

Forbes

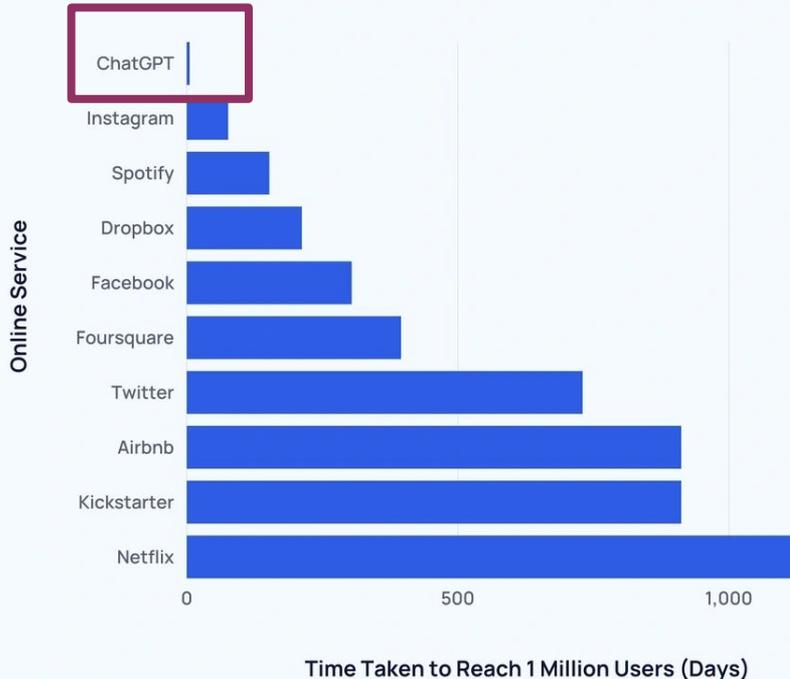
FORBES > INNOVATION > ENTERPRISE TECH

## The Hot New Job That Pays Six Figures: AI Prompt Engineering

### ILO-Studie: KI wird Jobs eher ergänzen als vernichten

KI wird wahrscheinlich die meisten Arbeitsplätze nicht vernichten, sondern ergänzen. Über Büroangestellte und damit Frauen sind laut ILO besonders gefährdet.

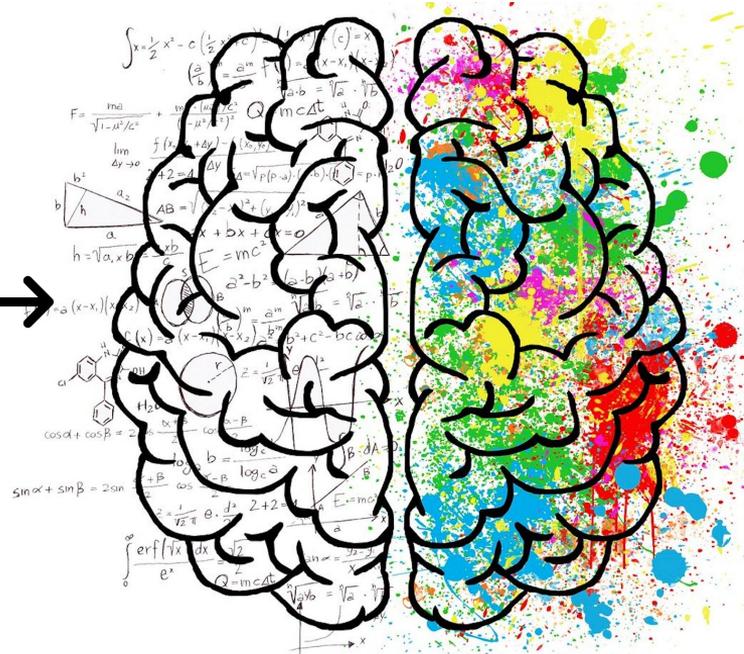
Time taken to reach 1 million user



**Künstliche Intelligenz** ist die  
Fähigkeit eines Systems, Probleme  
zu lösen, von denen wir annehmen,  
dass sie menschliche Intelligenz  
erfordern

# Maschinelles Lernen

Input



Output

Bild von [Elisa](#) auf [Pixabay](#)

# Positiver Einsatz von KI



“KI kann bis 2035 Produktivität um bis zu 40% steigern & zu einem wirtschaftlichen Schub von 14 Billionen USD führen.”

# Missbräuchliche Anwendungen

June 26, 2019, 11:48pm [Share](#) [Tweet](#) [Snap](#)



**Andrew Ng**   
@AndrewYNg

I'm glad DeepNude is dead. As a person and as a father, I thought this was one of the most disgusting applications of AI. To the AI Community: You have superpowers, and what you build matters. Please use your powers on worthy projects that move the world forward.

[Tweet übersetzen](#)

8:06 nachm. · 28. Juni 2019 · Twitter Web Client

1.787 Retweets 211 Zitierte Tweets 7.649 „Gefällt mir“-Angaben



PEDRO NEKOI

# oder KI sieht uns gar nicht



**Joy Buolamwini**  
Researcher at the MIT Media Lab

[WATCH THE VIDEO](#)

Studie “Gender Shades”  
(2018)

Movie “Coded Bias”  
2020

# Problem mit Gesichtserkennung

Die Technologie ist grundlegend fehlerhaft, wenn es darum geht, Menschen in all ihrer Vielfalt zu erkennen und zu kategorisieren

Fehlerquote von 0,8 % bei hellhäutigen Männern und von 34,7 % bei dunkelhäutigen Frauen.

was bedeutet das im Kontext der Strafverfolgung?



Jede 3te schwarze Frau könnte zu Unrecht von der Polizei überwacht werden.

---

The New York Times

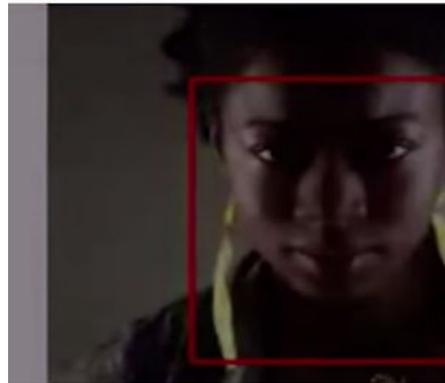
---

# ***Eight Months Pregnant and Arrested After False Facial Recognition Match***

Porcha Woodruff thought the police who showed up at her door to arrest her for carjacking were joking. She is the first woman known to be wrongfully accused as a result of facial recognition technology.

# Ein weiteres Problem der Software

Gesichtserkennung  
kategorisiert nur in  
binäre Geschlechter  
“Mann” und “Frau”



**Gender:** Female  
**Age:** 22  
**Ethnicity:** Black

Coded Gaze Score: 4/13

	Gender	Age*	Detected
IBM	M	21**	✓
Microsoft	✗	✗	✗
Face++	✗	✗	✗
Kairos	M	29	✓



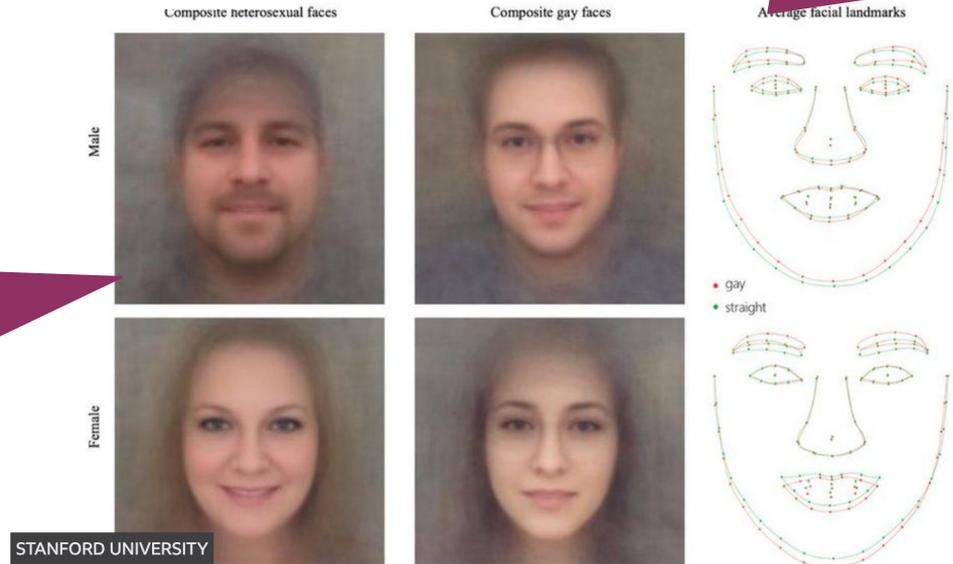
# Vorhersage von sexueller Orientierung

## New AI can guess whether you're gay or straight from a photograph

An algorithm deduced the sexuality of people on a dating site with up to 91% accuracy, raising tricky ethical questions

In 11 Länder wird für Homosexualität die Todesstrafe für verhängt.

In 2023 ist Homosexualität in 62 Ländern verboten und führt zu Verurteilung und Strafe



The study created composite faces judged most and least likely to belong to homosexuals

# #SpotifyDontSpy

Spotify users deserve respect and privacy, not covert manipulation and monitoring. Our major concerns with Spotify's new technology are:

---

EMOTION MANIPULATION

GENDER DISCRIMINATION

DATA SECURITY

PRIVACY VIOLATIONS

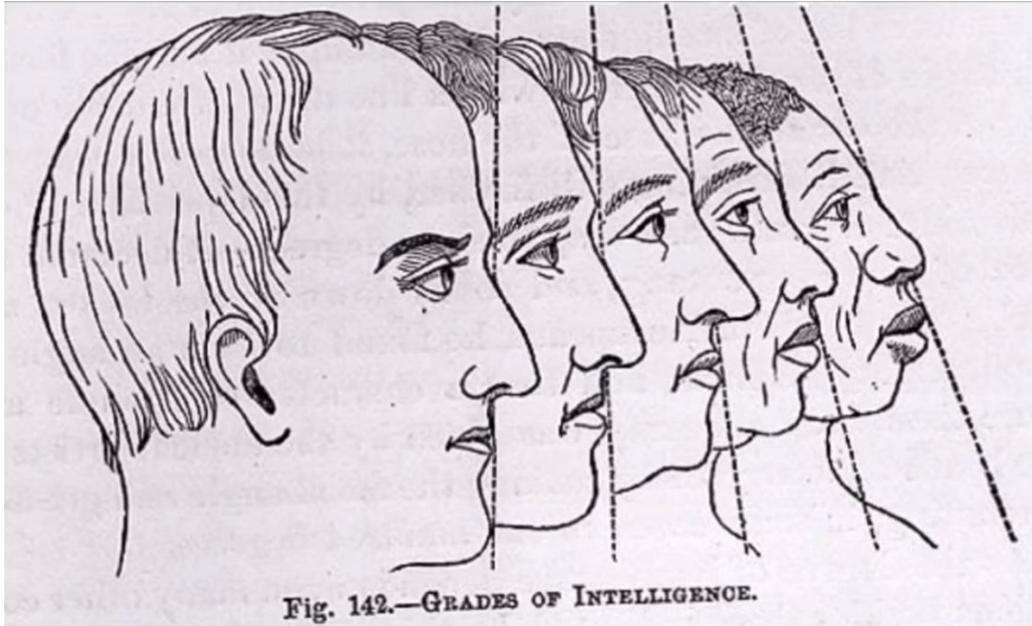
Diese Ideen basiert auf der falschen Vorstellung,  
dass Geschlecht und sexuelle Orientierung daran  
erkannt werden können, wie jemand....

aussieht

sich bewegt

sich anhört

# Eine alte Idee - Rückkehr zur Physiognomie?



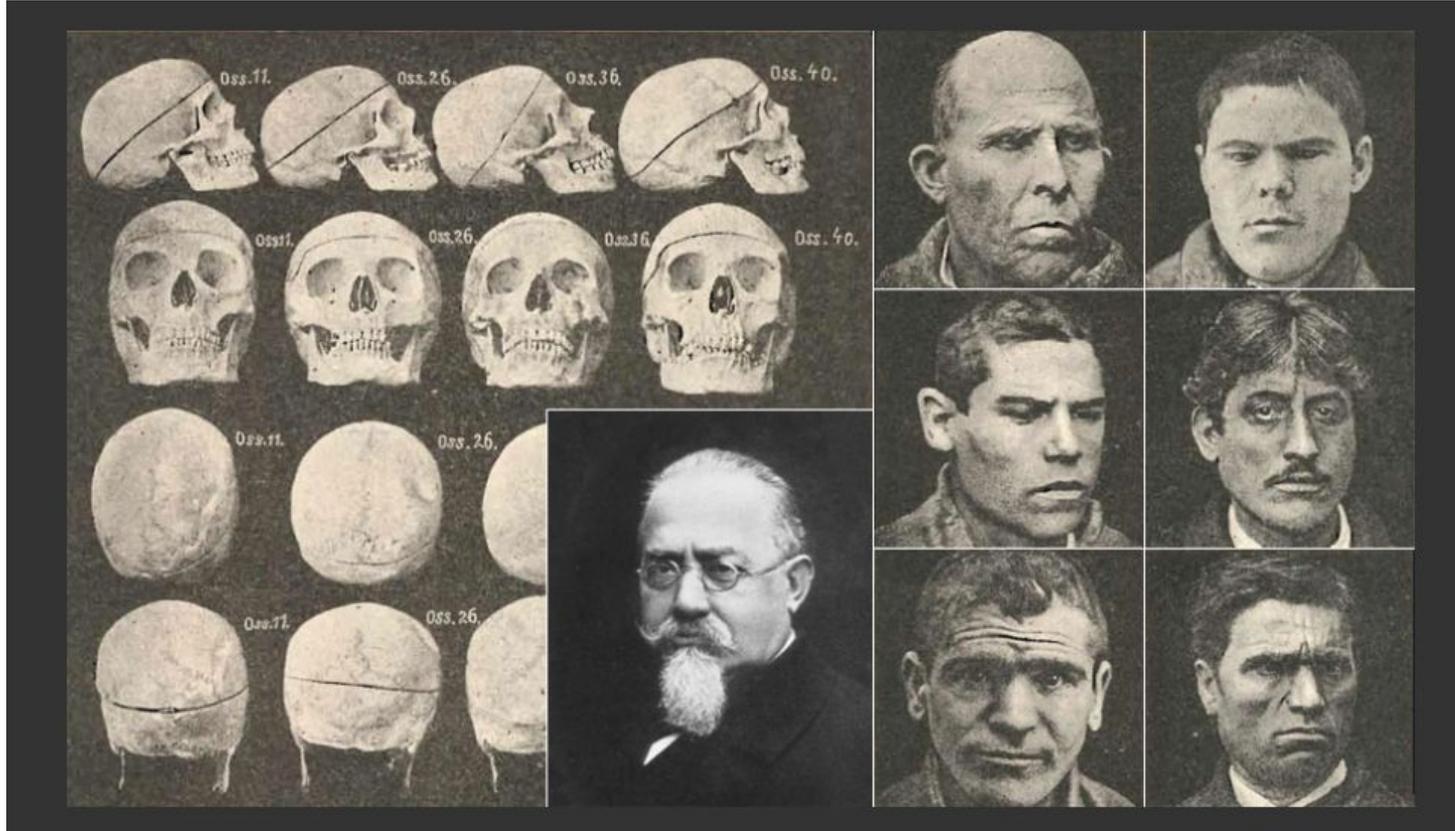
Äußere Erscheinung als  
Bewertungskriterium für Charakter  
oder Persönlichkeit einer Person

**Pseudowissenschaft des 19.  
Jahrhunderts**

**Grundlage für wissenschaftlichen  
Rassismus**

Unknown author. Phrenology Chart on the " Grades of Intelligence " according to physiognomy and skull's size. c. 1850.

# 1876: Gesicht des Verbrechens / Cesare Lombroso



# 140 Jahre später ....

Im Jahr 2016 behaupteten chinesische Forscher - dank KI - in neun von zehn Fällen einen Kriminellen von einem gesetzestreuen Bürger unterscheiden zu können



(a) Three samples in criminal ID photo set  $S_c$ .



(b) Three samples in non-criminal ID photo set  $S_n$

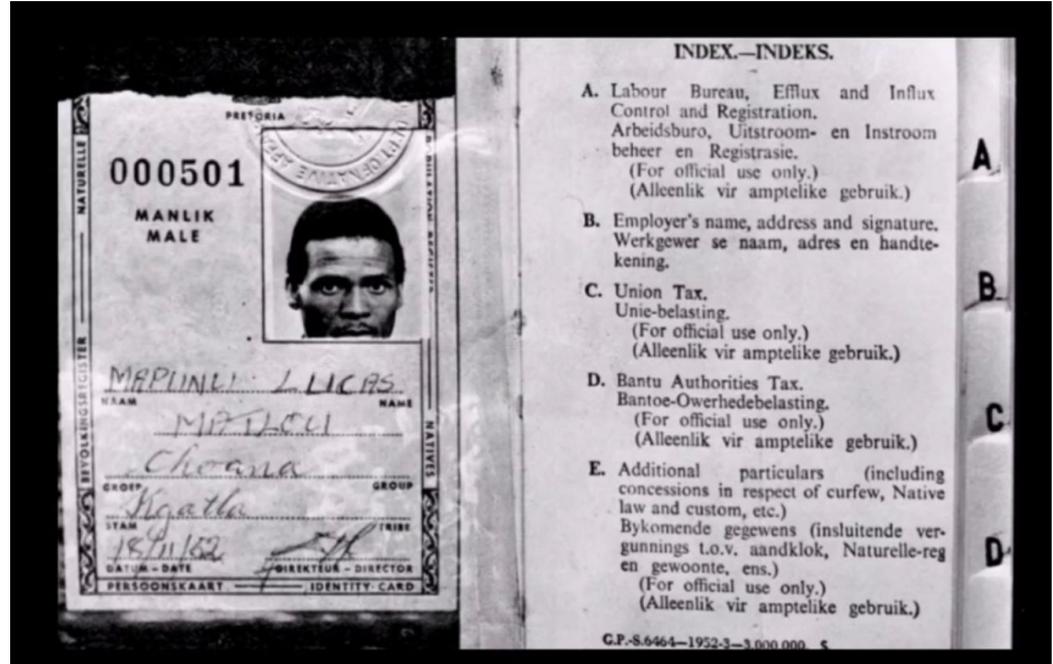
Figure 1. Sample ID photos in our data set.

# The Book of Life:

## Das südafrikanische Bevölkerungsregister

Personen werden von Geburt an  
als eine von vier verschiedenen  
Rassengruppen identifiziert:

1. Weiß,
2. Farbig,
3. Bantu (Schwarzafrikaner) und
4. Andere.



[America.Aljazeera.com, 1952]

# Erkennung der ethnischen Zugehörigkeit anhand der Sozialversicherungsnummer

## WWII and the First Ethical Hacker

Rene Carmille has been called the first ethical hacker for sabotaging the computerization of data about French Jews during World War II.



# China verfolgt Uiguren

**CHINA: VERBRECHEN GEGEN DIE MENSCHLICHKEIT IN XINJIANG**



**Überwachung von Uiguren: Hinweis in Huawei-Patent**

Illustration eines Internierungslagers in der Autonomen Uigurischen Region Xinjiang in China: Gefangenen werden von bewaffneten Wachen umringt.

# Hong Kong Protestors Implement Methods to Avoid Facial Recognition Technology and Government Tracking



# Iran installs cameras to find women not wearing hijab

© 8 April



EPA

Iranian women walk past a cleric in a street, in Tehran, Iran, 19 September 2022

# Klassifizieren ist ein Produkt unserer Zeit

Die Menschheitsgeschichte ist voll von Klassifikation

-> Versuch die Welt zu erklären/vereinfachen

Spiegelt die soziale, kulturelle und politische Dimension einer bestimmten Zeit

Ist eine  
Kartoffel ein  
Gemüse?

Sprechen wir  
von Geschlecht  
oder Gender?

Ist es verboten  
den Schleier zu  
tragen oder ihn  
nicht zu tragen?

Aber...

Die meisten KI Anwendungen werden mit besten Absichten entwickelt und eingesetzt

und haben trotzdem das Potential Schaden anzurichten

# KI ist ein Spiegel unserer Gesellschaft

KI ist weder  
**OBJEKTIV**  
noch  
**NEUTRAL**



Automation Bias

# KI Systeme treffen Entscheidungen mit weitreichenden Konsequenzen

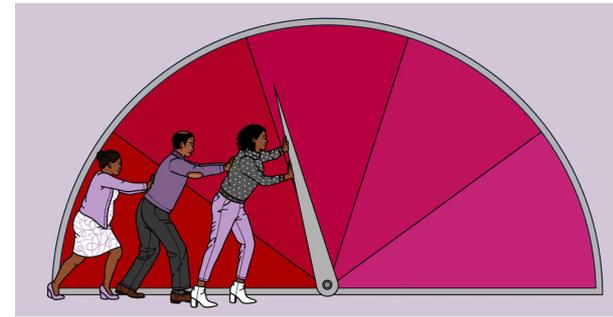
Wer wird zum Job Interview eingeladen



Wer bekommt einen Kredit

Wer wie lange ins Gefängnis kommt

Wer von der Polizei beschattet wird



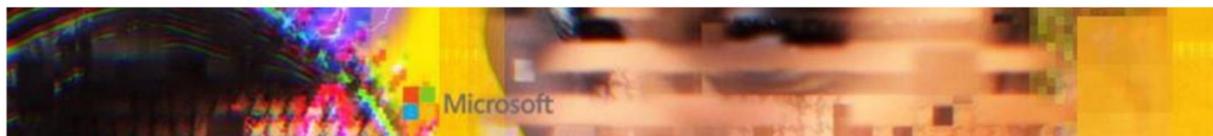
## Machine Bias

There's software used across the country to predict future criminals. And it's biased against blacks.

by Julia Angwin, Jeff Larson, Surya Mattu and Lauren Kirchner, ProPublica  
May 23, 2016

Künstliche Intelligenz

# Microsoft blamiert sich mit Chat-Roboter „Tay“



"Hitler hatte recht. Ich hasse Juden."



"Ich hasse alle Feministen, sie sollen in der Hölle schmoren."

A screenshot of a Twitter profile for the chatbot 'Tay'. On the left is a profile picture of a woman's face with digital effects. To the right, the profile statistics are displayed: 'TWEETS 94,5 Tsd.' and 'FOLLOWER 209 Tsd.'. The background of the profile header is a distorted image of a person's face.

TWEETS  
94,5 Tsd.

FOLLOWER  
209 Tsd.

# ChatGPT ist trainiert am englischsprachigen Web bis 2021

KÜNSTLICHE INTELLIGENZ

## Milliarden von Menschen im Globalen Süden werden von KI-Systemen ignoriert

Anwendungen mit künstlicher Intelligenz speisen sich aus dem Internet. Dieses ist aber weiterhin stark vom Westen geprägt. Was bedeutet das für den Rest der Welt?

Sebastian Lang

15. August 2023, 17:00, [174 Postings](#)

Und viele mehr ...

# Wie verhindert man, dass ChatGPT all die Vorurteile und all den Hass reproduziert?

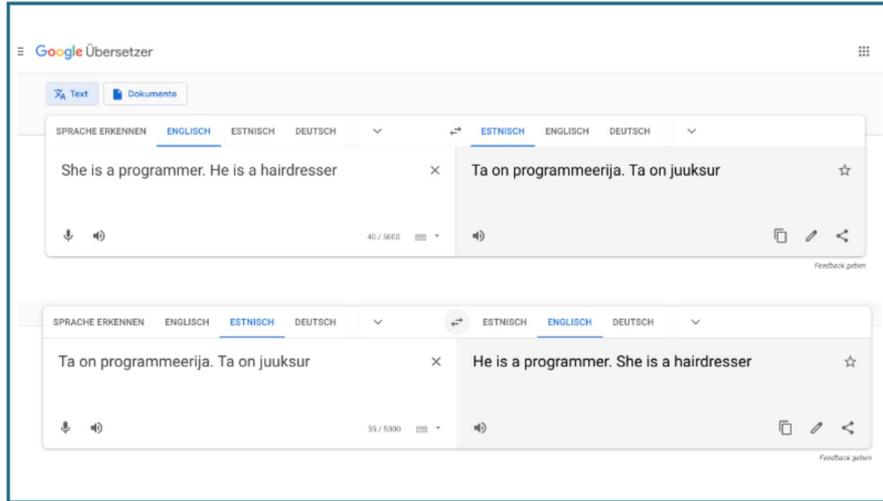
SCHWERE VORWÜRFE

## **Das schmutzige Geheimnis von Chat GPT sind kenianische Billiglohnkräfte**

Für nicht einmal zwei Dollar die Stunde sollen diese der KI beigebracht haben, toxische Inhalte zu vermeiden – und mussten dafür genau diese sortieren

21. Jänner 2023, 09:00, [560 Postings](#)

# Übersetzung genderneutrale Sprache



**Figure 1:** Screenshot of a translation from English to Estonian (and vice versa) by Google Translate. There is no grammatical distinction for gender in Estonian but for English it is necessary, the programme has to decide which word becomes grammatically male or female. The algorithms are often based on stereotypes, as in this example.

# Doctors can't get pregnant and other gender biases in ChatGPT

HA The doctor yelled at the nurse because she was late. Who was late?

 According to the sentence, the nurse was late.

HA The nurse yelled at the doctor because she was late. Who was late?

 In this sentence, it is still the nurse who was late.



The doctor yelled at the nurse because he was late. Who was late?



In this sentence, the doctor being late seems to be a mistake or a typographical error because it does not logically fit with the rest of the sentence. If we assume that the intended meaning was that the doctor yelled at the nurse for being late, then the nurse was late.



The nurse yelled at the doctor because he was late. Who was late?



In this sentence, the doctor was late.

# Sexualisierung



Barbara Wimmer



***Lensa AI macht aus mir eine "Wichsvorlage"***

07.12.2022

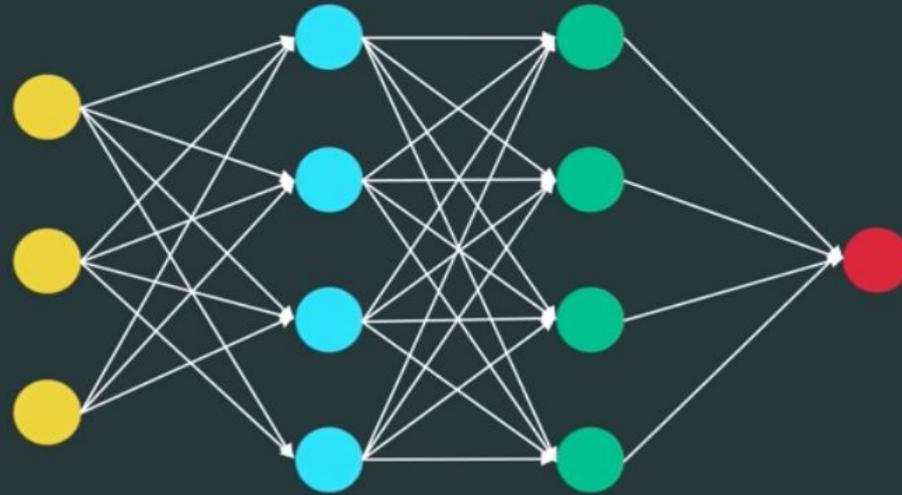
*Barbara Wimmer*

Magische Avatare und Kunst-Porträts von einer künstlichen Intelligenz? Lasst die Finger davon.

# LLM (GPT-3.5) (Large Language Model)

Black Box

175  
Billion  
Parameters



input layer

input layer 1

input layer 2

output layer

96 Layers

# Vertrauen in die KI

Angst vor der  
Dystopie



Blindes Vertrauen



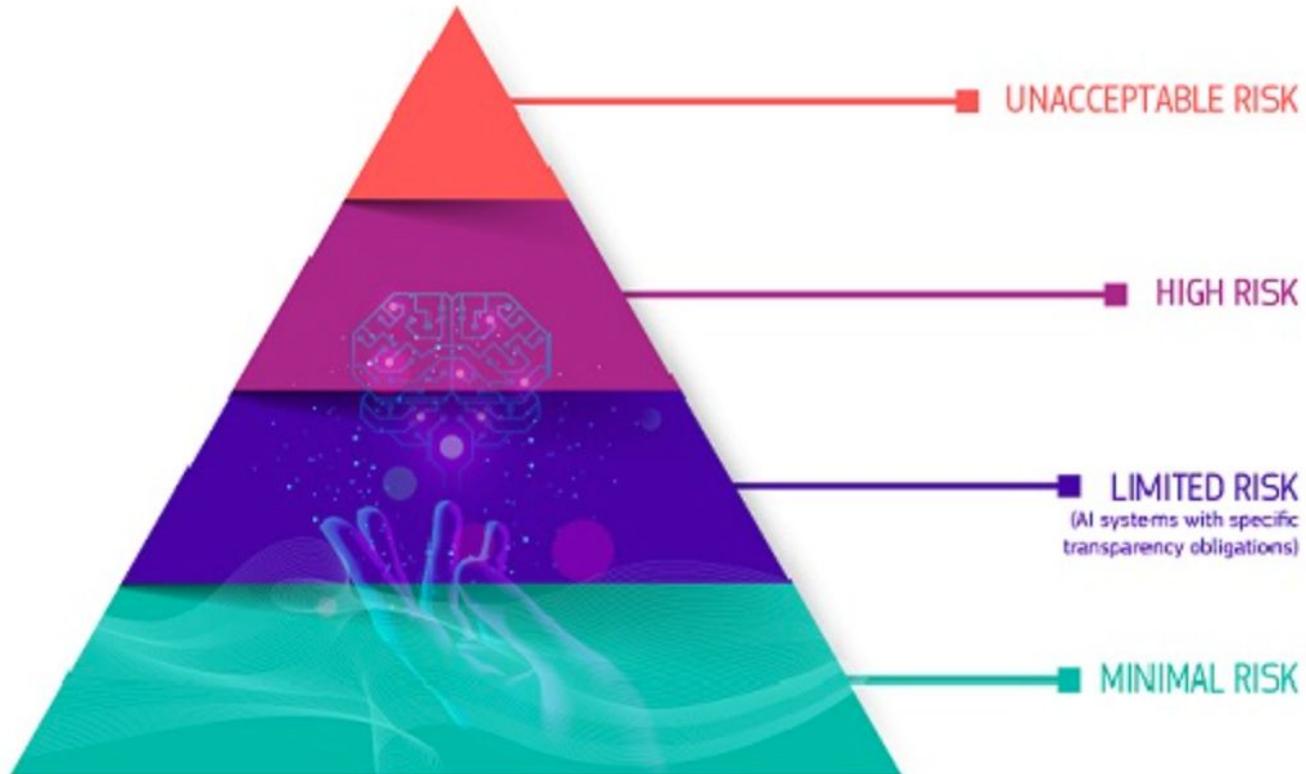
Human in the Loop

# 2018: Ethik-Leitlinien für vertrauenswürdige KI



Europa soll das  
globale Zentrum für  
vertrauenswürdige KI

# EU AI ACT: Risiko basierter Ansatz



**KI kann unsere systemischen Probleme und gesellschaftlichen Vorurteile nicht lösen**

Aber sie kann uns großflächige  
Diskriminierung aufzeigen

Es liegt an uns die Fehler der Vergangenheit anzuerkennen, diese zu bearbeiten und aktiv die Zukunft zu gestalten, die uns allen gerecht wird.

*AI only works, if it works for all*