

# Bias in Facial Recognition

Daniel Alexander Dittlbacher-Hupf

Rodrigo Leeb

Louis Jörg Gerhard Rösch

Tomasz Bronislaw Wisniewski

Januar 2022

# Inhalt

Was ist Facial Recognition

Bias - Definition

Bias - Ursachen und Folgen

Regulierung und Recht

Bias – Mitigation Methods

# Face Detection

- ▶ High-level Überblick
- ▶ Object detection
- ▶ Suche nach bestimmten Merkmalen
- ▶ Zuerst nach Augen suchen
- ▶ Erfolg hängt vom Bild ab
- ▶ Machine learning

# Facial Recognition

- ▶ Face detection
- ▶ Normalisierung
- ▶ Merkmale aufstellen
- ▶ Mit der Datenbank abgleichen

# Verwendungsmöglichkeiten

- ▶ Authentifizierung
- ▶ Videoüberwachung
- ▶ Photographie

# Bias – Definition

- ▶ Bezeichnet die variierende Erfolgsrate eines Face Recognition Systems unter bestimmten Bedingungen
- ▶ Wir betrachten Bias in verschiedenen demographischen Gruppen

# Bias – Definition

- ▶ Entsteht u. a. durch
  - ▶ Einsatz eines Systems in Bedingungen, für die das System nicht entwickelt wurde
  - ▶ Enorme Komplexität und Variation des Problems
  - ▶ Große homogene Anteile in Trainingsdatensätzen

# Bias in Ausgangsdaten

- ▶ Lerndaten entscheiden über Genauigkeit
- ▶ Rassismus bzw. Ungleiche Repräsentation
- ▶ Sexismus
- ▶ In weiterer Folge unfaire Behandlung

# Bias in Ausgangsdaten

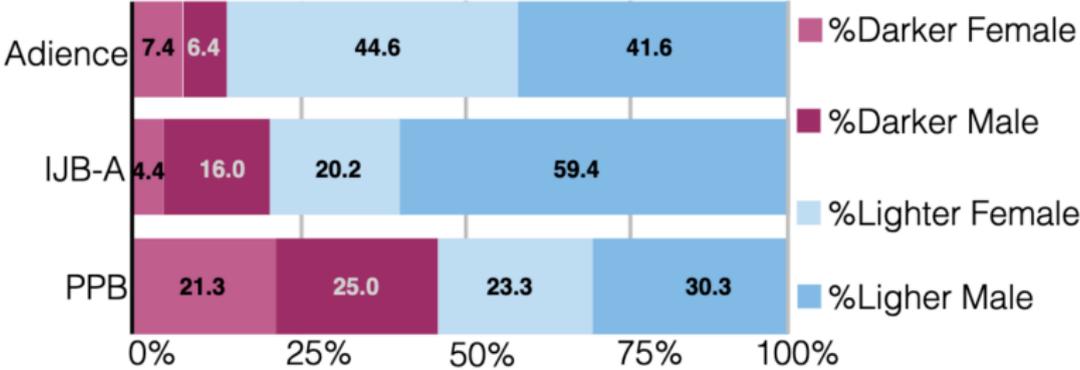


Abbildung: Bias in Ausgangsdaten

# Folgen

- ▶ Ungleiche Erkennung
- ▶ Falsch positive Resultate
- ▶ Einstellung von Gesichtserkennungssystemen

# Psychologische Faktoren

- ▶ Algorithmen wurden per Hand erstellt
- ▶ Man orientiert sich am eigenen Aussehen
- ▶ Studie erkannte Unterschiede bei Algorithmen aus verschiedenen Nationen

# Joy Buolamwini

- ▶ Eine der führenden Forscherinnen in diesem Gebiet
- ▶ War selbst betroffen

# Regulierung?

- ▶ Öffentliche Forderung nach Regulierung durch
  - ▶ Menschenrechtsorganisationen
  - ▶ Forscher
  - ▶ Technologiekonzerne

# Regulierung?

- ▶ Denn FRT ist:
  - ▶ fehlerhaft
  - ▶ intransparent
  - ▶ diskriminierend

'It's dangerous, racializing, and has few legitimate uses; facial recognition needs regulation and control on par with nuclear waste.'

# Ziele

- ▶ Gewährleistung des Datenschutzes
- ▶ Diskriminierung (durch Bias) verhindern
- ▶ 'Automation Bias' verhindern

# Situation in Europa

- ▶ 'AI-Act'
- ▶ Risikoorientierter Ansatz
- ▶ Klassifizierung der AI-Anwendungen in 4 Klassen anhand von
  - ▶ Sensibilität des betroffenen Lebensbereichs
  - ▶ Impact der AI-Entscheidung
- ▶ **Zusätzlicher Faktor Bias-Potential**

# Situation in Europa

→ FRT ist ein 'Hochrisiko-System'

# Anforderungen für FRT

- ▶ Nutzung durch Strafverfolgungsbehörden nur in Ausnahmefällen
- ▶ Konformitätsprüfung für das Produkt samt Zertifizierung
  - ▶ —→ CE-Label für 'AI-Software'

# Anforderungen für FRT

- ▶ Anforderungen
  - ▶ Technische Dokumentation
  - ▶ Risikomanagement
  - ▶ Protokollierung
  - ▶ Gute Qualität der verwendeten Daten
  - ▶ Mitigation Systems
  - ▶ Transparenz
  - ▶ Angemessene Genauigkeit

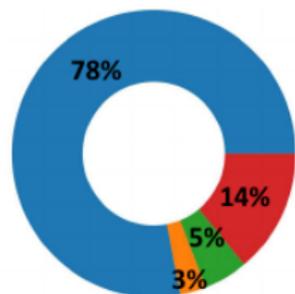
# Regulierung in den USA

- ▶ Keine Gesetze auf Ebene des Bundes
- ▶ Stattdessen Urteile und Gesetze für einzelne Staaten/Städte
- ▶ Illinois, Washington & Texas
  - ▶ Verbot der Nutzung ohne Einwilligung
- ▶ **San Francisco**
  - ▶ Nutzung durch Polizei untersagt (2019)
  - ▶ CCPA (2020)

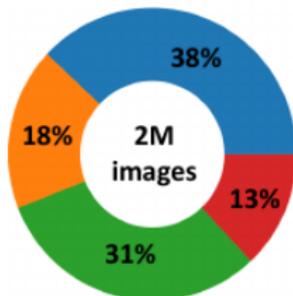
# Bias – Mitigation Methods

- ▶ Annahme: nur eine Bildkomposition in Datensätzen
- ▶ Offensichtlicher Ansatz: uniforme Trainingsdatensätze
  - ▶ es ist schwer zu bewerten, was uniform bedeutet

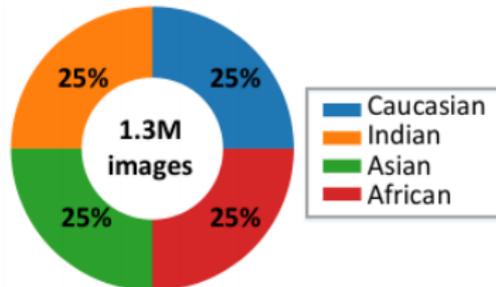
# Bias – Mitigation Methods



(a) Existing training datasets



(b) BUPT-Globalface



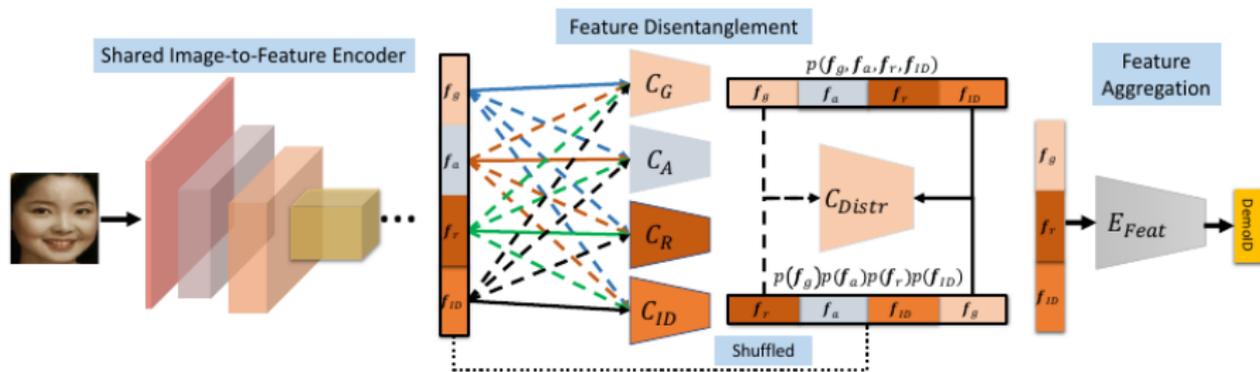
(c) BUPT-Balancedface

**Abbildung:** Trainingsdatensätze ('Neural Learning from Unbalanced Data'; Sixue Gong, et al.)

# Bias – Mitigation Methods

- ▶ Adaptive Margin Loss
  - ▶ zusätzliche Variablen werden eingeführt und beim Training zur Laufzeit angepasst
- ▶ Feature Disentanglement
  - ▶ es wird versucht, aus dem Output des Systems Features zu erheben

# Mitigation Methods



**Abbildung:** Feature Disentanglement ('Exploring Disentangled Feature Representation Beyond Face Identification'; Yu Liu et al.)

# Quellen

- 1 Mitigating Bias in Face Recognition using Skewness-Aware Reinforcement Learning, Sixue Gong, et al.  
[http://cvlab.cse.msu.edu/pdfs/gong\\_liu\\_jain\\_cvpr2021.pdf](http://cvlab.cse.msu.edu/pdfs/gong_liu_jain_cvpr2021.pdf)
- 2 Neural Learning from Unbalanced Data, Sixue Gong, et al.  
[https://www.ecva.net/papers/eccv\\_2020/papers\\_ECCV/papers/123740324.pdf](https://www.ecva.net/papers/eccv_2020/papers_ECCV/papers/123740324.pdf)
- 3 A Gentle Introduction to Deep Learning for Face Recognition, Jason Brownlee on machinelearningmastery.com  
<https://machinelearningmastery.com/introduction-to-deep-learning-for-face-recognition/>
- 4 Exploring Disentangled Feature Representation Beyond Face Identification, Yu Liu, et al.  
[https://openaccess.thecvf.com/content\\_cvpr\\_2018/papers/Liu\\_Exploring\\_Disentangled\\_Feature\\_CVPR\\_2018\\_paper.pdf](https://openaccess.thecvf.com/content_cvpr_2018/papers/Liu_Exploring_Disentangled_Feature_CVPR_2018_paper.pdf)

# Quellen

- 5 Bericht zur Gesichtserkennungstechnologie in Österreich, Amnesty International,  
[https://www.amnesty.at/media/8397/amnesty\\_gesichtserkennungstechnologie-in-oesterreich\\_bericht-mai-2021.pdf](https://www.amnesty.at/media/8397/amnesty_gesichtserkennungstechnologie-in-oesterreich_bericht-mai-2021.pdf)
- 6 Open letter calling for a global ban on biometric recognition technologies that enable mass and discriminatory surveillance, Accessnow  
<https://www.accessnow.org/ban-biometric-surveillance/>
- 7 Silicon Valley has admitted facial recognition technology is toxic, John Naughton  
<https://www.theguardian.com/commentisfree/2020/jun/13/silicon-valley-has-admitted-facial-recognition-technology-is-toxic-about-time>

# Quellen

- 8 Facial Recognition is the Plutonium of AI, Prof. Luke Stark,  
<https://static1.squarespace.com/static/59a34512c534a5fe6721d2b1/t/5cb0bf02eef1a16e422015f8/1555087116086/Facial+Recognition+is+Plutonium+-+Stark.pdf>
  
- 9 Vorschlag für eine VERORDNUNG DES EUROPÄISCHEN PARLAMENTS UND DES RATES ZUR FESTLEGUNG HARMONISIERTER VORSCHRIFTEN FÜR KÜNSTLICHE INTELLIGENZ (GESETZ ÜBER KÜNSTLICHE INTELLIGENZ) UND ZUR ÄNDERUNG BESTIMMTER RECHTSAKTE DER UNION.  
<https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX\%3A52021PC0206>
  
- 10 BAN FACIAL RECOGNITION TECHNOLOGIES FOR CHILDREN AND FOR EVERYONE ELSE, LINDSEY BARRETT  
<https://www.bu.edu/jostl/files/2020/08/1-Barrett.pdf>

# Quellen

- 11 Examining The San Francisco Facial-Recognition Ban, Tony Raval, Forbes

<https://www.forbes.com/sites/forbestechcouncil/2019/06/21/examining-the-san-francisco-facial-recognition-ban/>