

# Diskriminierende KI?

## Entstehung und Lösungsansätze von Bias in KI-Systemen

# Inhalt

- ◇ **Definitionen *KI* und *Bias***
- ◇ **Relevanz des Themas**
- ◇ **Entstehung von Bias**
- ◇ **Lösungsansätze**
- ◇ **Fragen & Diskussion**

# Was ist Künstliche Intelligenz?


„Künstliche Intelligenz ist die Fähigkeit einer Maschine, menschliche Fähigkeiten wie logisches Denken, Lernen, Planen und Kreativität zu imitieren.“

Europäisches Parlament, 2020

# Wie arbeitet KI?

KI arbeitet häufig mit **maschinellern Lernen**.

Maschinelles Lernen ist ein **statistisches** Verfahren, bei dem **Muster** in **Trainingsdaten** erkannt werden.




# Was ist Bias?

**bias** (engl.): Voreingenommenheit, Vorurteil, Befangenheit, systematischer Fehler, Verzerrung

**Bias in KI** sind systematische Verzerrungen, die sich im Modell zeigen. Sie verursachen, dass die KI „voreingenommen“ ist oder „Vorurteile“ hat.

# Warum reden wir über Bias?

Bias ist diskriminierend.



»» Vorurteile werden reproduziert und beeinflussen Entscheidungen sowie Handlungen, wodurch Menschen ungleich behandelt werden.

# Warum reden wir über Bias?

**Super Fails | Tayminator**  
Wie Microsofts KI zum Nazi wurde

**Insight - Amazon scraps secret AI recruiting tool that showed bias against women**

How an AI grading system ignited a national controversy in the U.K.

**Study finds gender and skin-type bias in commercial artificial-intelligence systems**

Examination of facial-analysis software shows error rate of 0.8 percent for light-skinned men, 34.7 percent for dark-skinned women.

Österreich

**Jobcenter-Algorithmus landet vor Höchstgericht**


In Österreich streiten die Behörden seit Jahren über e  
Arbeitssuchenden vorhersagen soll. Nun landet der Fa  
Verwaltungsgericht.

**Machine Bias**

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

# Wie entsteht Bias?

## Garbage In – Garbage Out



# Wie entsteht Bias?

## Garbage In – Garbage Out

**Study finds gender and skin-type bias in commercial artificial-intelligence systems**

Examination of facial-analysis software shows error rate of 0.8 percent for light-skinned men, 34.7 percent for dark-skinned women.


**Super Fails | Tayminator**  
**Wie Microsofts KI zum Nazi wurde**

**Insight - Amazon scraps secret AI recruiting tool that showed bias against women**



# Wie entsteht Bias?

## Algorithmen und Modelle




# Wie entsteht Bias?

## Algorithmen und Modelle

### Machine Bias


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



How an AI grading system ignited a national controversy in the U.K.


# Wie entsteht Bias?

## Anwendungsfehler



# Wie entsteht Bias?

## Anwendungsfehler



# Wie entsteht Bias?

## Anwendungsfehler

### Super Fails | Tayminator Wie Microsofts KI zum Nazi wurde

Daten

Österreich

#### Jobcenter-Algorithmus landet vor Höchstgericht

In Österreich streiten die Behörden seit Jahren über ein System, das Jobchancen von Arbeitssuchenden vorhersagen soll. Nun landet der Fall vor dem obersten Verwaltungsgericht.

Handlungen



# Rechtliche Schritte gegen Bias

## AI Act

- Risikomanagementsystem Artikel 9
- Repräsentative, hochqualitative Daten Artikel 10
- Nutzung personenbezogener Daten, um Bias zu verhindern Artikel 10, Abs. 5
- Transparenz & Bereitstellung von Informationen über KI-System Artikel 13
- Menschliche Aufsicht im gesamten Prozess Artikel 14
- Überwachung & Meldung von Vorkommnissen Artikel 72 & 73
- Recht auf Erläuterung für Betroffene Artikel 86

# Technische Lösungsansätze

## Ad Hoc: Interpretierbarkeit/White Box-Modelle

Arbeitsweise der Modelle ist im Voraus bekannt.

- Basieren auf logischen Regeln
- Entscheidungsfindung ist deutlich

```
IF      age between 18-20 and sex is male      THEN predict arrest (within 2 years)
ELSE IF age between 21-23 and 2-3 prior offenses THEN predict arrest
ELSE IF      more than three priors            THEN predict arrest
ELSE      predict no arrest.
```

# Technische Lösungsansätze

## Ad Hoc: Interpretierbarkeit/White Box-Modelle

### Vorteile

- Transparenz
- Nachvollziehbare Ergebnisse
- Fehlersuche und –behebung ist einfacher
- Reduzierung von Risiken
- Reduzierung von Kosten

### Nachteile

- Vereinfachungen
- Häufig geringere Genauigkeit
- Braucht mehr Datenaufbereitung
- Begrenzte Flexibilität bei neuen Aspekten
- Kommerzielle Interessen

# Technische Lösungsansätze

## Post Hoc: Erklärbarkeit/XAI

Arbeitsweise der Black Box-Modelle wird im Nachhinein erklärt.

- **LIME** (Local Interpretable Model-Agnostic): Verändert den Input und beobachtet den Output für einzelne Instanzen; erstellt aus den Erkenntnissen ein interpretierbares Modell.
- **SHAP** (SHapley Additive exPlanations): Berechnet, welchen Beitrag zur Vorhersage einzelne Merkmale liefern.

# Technische Lösungsansätze

## Post Hoc: Erklärbarkeit/XAI

### Vorteile

- Effiziente Black Box-Modelle können weiter genutzt werden

### Nachteile

- Unklar, ob Erklärung komplett richtig ist

# Weitere Lösungsansätze

## Überprüfungen, Tests und Metriken

- Fairness
- Robustheit

## Vielfältige, repräsentative Datensätze

- Erweiterung der Trainingsdaten
- Erkennen und Entfernen verzerrender Korrelationen

# Weitere Lösungsansätze

## **Diverse Entwicklungsteams**

- Teammitglieder aus verschiedenen Gruppen
- Teammitglieder mit verschiedenen Expertisen

## **Bewusstseinsbildungen**

- Schulungen
- Eigenverantwortung bei der Entwicklung und Nutzung von KI

*Algorithms are vulnerable to inherit the flaws of the system they are designed to fix.*

Hecht, 2020

*If you don't confront the social issues involved, no amount of technology is going to improve a situation. We can't solve social problems with engineering solutions.*

Tse, Esposito, Goh, 2019

# Diskussion

- Wird in der Hochschulforschung darauf geachtet, dass erhobene Daten divers sind? Wo liegen Schwierigkeiten, wo gibt es Potenzial für Verbesserungen?
- Ist es ethisch in Ordnung, wenn wir absichtlich Bias zeigen oder generieren zu Lernzwecken?
- Was sind weitere Beispiele von Bias-reproduzierenden Inhalten um uns herum?
- Wie gehen wir um, bzw. sollten wir umgehen, mit historischen Forschungsdaten die Verzerrungen enthalten?
- Wir alle haben Vorurteile in uns - können wir Bias überhaupt verhindern? Wir könnten wir das erreichen?
- Gehen die Vorgaben des AI Acts weit genug? Oder zu weit?
- Für wen muss eine Erklärung verständlich sein? Nur für Expert\*innen oder für alle Nutzer\*innen einer KI?
- Was brauchen Sie für vertrauenswürdige KI – wann vertrauen Sie KI?

# Quellen

in chronologischer Reihenfolge

- Definition KI: <https://www.europarl.europa.eu/topics/de/article/20200827STO85804/was-ist-kunstliche-intelligenz-und-wie-wird-sie-genutzt> abgerufen 23.04.2025
- Microsoft Chatbot Tay: <https://www.arte.tv/de/videos/105664-001-A/super-fails-tayminator/> abgerufen 24.04.2025
- Amazon Bewerber\*innen Algorithmus: <https://www.reuters.com/article/world/insight-amazon-scrap-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK0AG/> abgerufen 23.04.2025
- AI grading system in UK: <https://towardsai.net/p/artificial-intelligence/uks-failed-attempt-to-grade-students-by-an-algorithm> abgerufen 25.04.2025
- Gender and Skin-type Bias: <https://news.mit.edu/2018/study-finds-gender-skin-type-bias-artificial-intelligence-systems-0212> abgerufen 23.04.2025
- Jobcenter Österreich: <https://netzpolitik.org/2021/oesterreich-jobcenter-algorithmus-landet-vor-hoehchstgericht/> abgerufen 23.04.2025
- Machine Bias: <https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing> abgerufen 25.04.2025
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature machine intelligence*, 1(5), 206-215.
- AI Act Explorer: <https://artificialintelligenceact.eu/ai-act-explorer/> abgerufen am 07.05.2025
- LIME & SHAP: <https://www.datacamp.com/de/tutorial/explainable-ai-understanding-and-trusting-machine-learning-models> abgerufen 28.04.2025
- Hecht, Yannique (2020). UK's Failed Attempt to Grade Students by an Algorithm. *Towards AI*: <https://towardsai.net/p/artificial-intelligence/uks-failed-attempt-to-grade-students-by-an-algorithm%20> abgerufen am 23.04.2025
- Tse, T. C., Esposito, M., & Goh, D. (2019). *The AI Republic: Building the nexus between humans and intelligent automation*. S.I.: Lioncrest Publishing.
- Folienvorlage von Slidesgo; Icons von Flaticon



Marieke Prien

[m.prien@hs-osnabrueck.de](mailto:m.prien@hs-osnabrueck.de)

Diskriminierende KI? Entstehung und Lösungsansätze von Bias in KI-Systemen  
© 2025 by Marieke Prien, licensed under CC BY-SA 4.0