



# Methoden der Explainable AI (XAI)

Lukas Scholz | 24.06.2022 | HWR Berlin

# Aspekte der XAI

- Verständnis der Modellstruktur
- Verständnis einzelner Komponenten (z.B. Parameter)
- Verständnis des Trainingsalgorithmus
- Analytische Aussagen zu Ergebnissen
- **Visuelle Aussagen zu Ergebnissen**
- Erklärungen anhand Beispielen



Post-hoc  
Interpretability

[Lipton \(2016\)](#)

# Visuelle Aussagen zu Ergebnissen

Prediction: Doctor



Prediction: Nurse





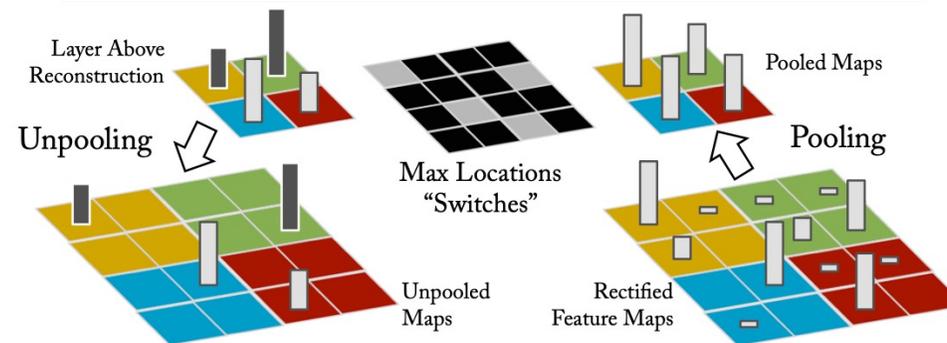
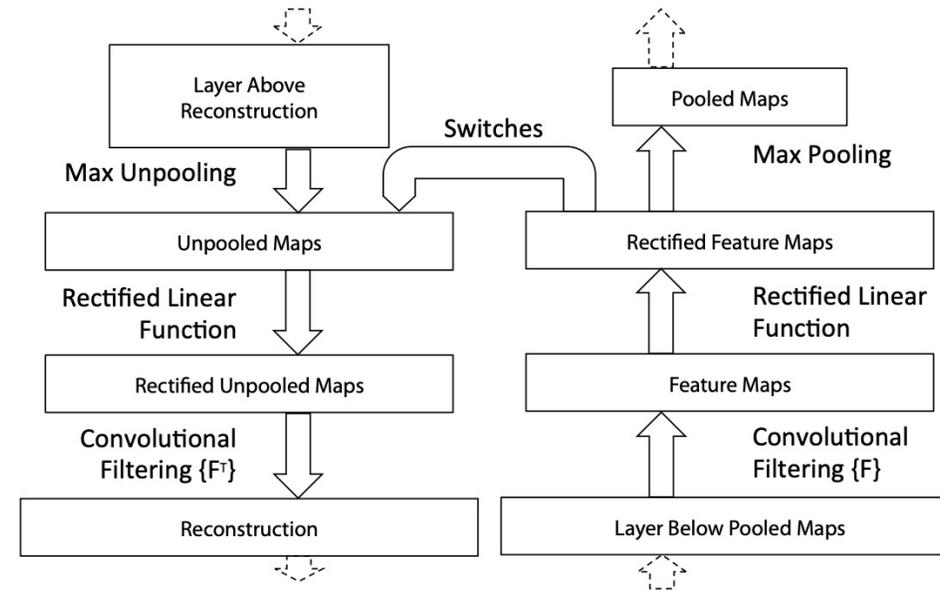
# Visuelle Aussagen zu Ergebnissen

Wieso kann das Modell zwischen  
Doktor:innen und Krankenschwestern /-pflegern  
unterscheiden?

# Saliency Maps

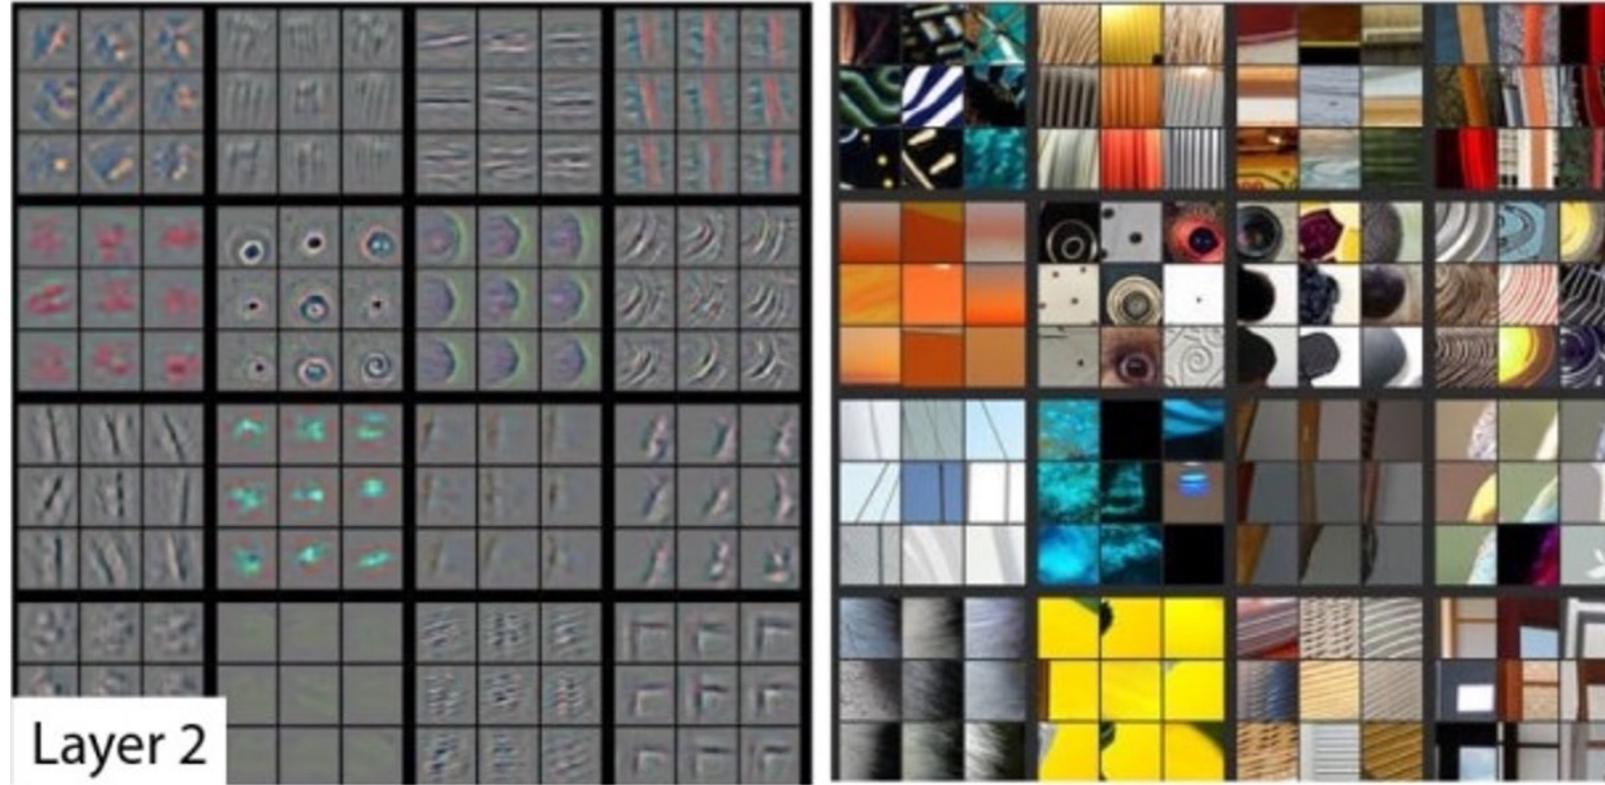
- Heben Regionen hervor die für Modell von Bedeutung sind
- “Einblick” in den Entscheidungsprozess des Modells
- Unterscheiden sich im Informationsgehalt und Aufwand der Implementierung

# Saliency Maps - DeconvNet



[Zeiler and Fergus \(2013\)](#)

# Saliency Maps - DeconvNet



- Geringer Informationsgehalt
- Darstellungen pro Layer des Modells  
→ viele einzelne Darstellungen; kein gesamter Eindruck
- Aufwendige Implementierung (DeconvNet als eigenständiges Modell)

[Zeiler and Fergus \(2013\)](#)

# Saliency Maps – Guided Backprop

deconv



guided backpropagation



corresponding image crops



deconv



guided backpropagation



corresponding image crops



- Höhere Auflösung als reines DeconvNet
- Weiterhin Darstellungen pro Layer
- Aufwendige Implementierung, da DeconvNet verwendet wird

[Springenberg et. al. \(2014\)](#)

# Saliency Maps – Class Activation Map

Brushing teeth



Cutting trees

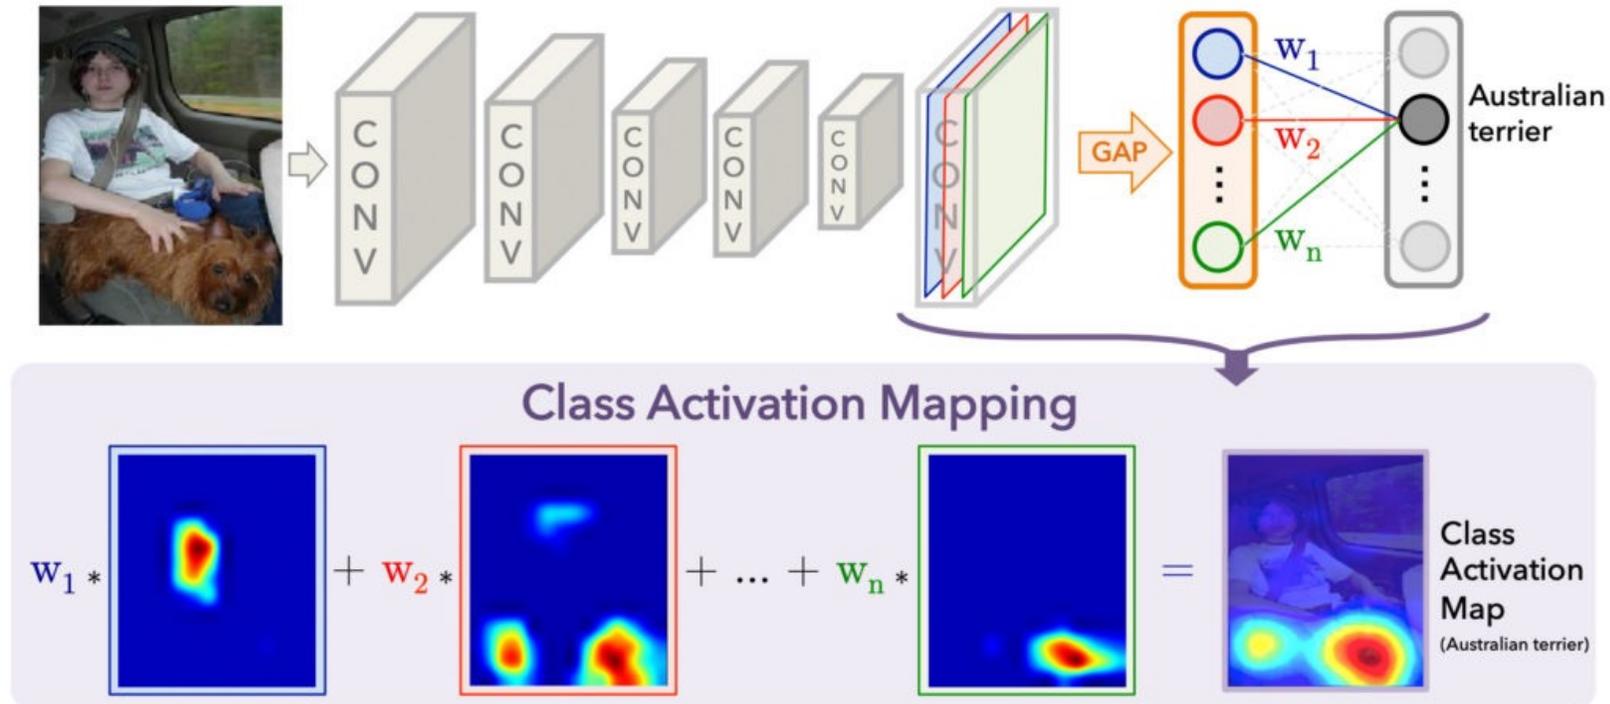


- Heatmap bringt Wertung in die Analyse (Rot = Bedeutend; Blau = Unbedeutend)
- Darstellung für alle Layer des Modells
- Einfache Implementation

**Alle Features des Modells werden betrachtet!**

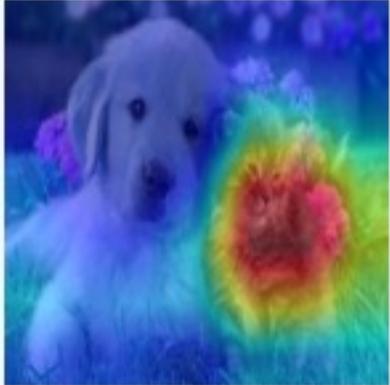
[Zhou et. al. \(2015\)](#)

# Class Activation Maps



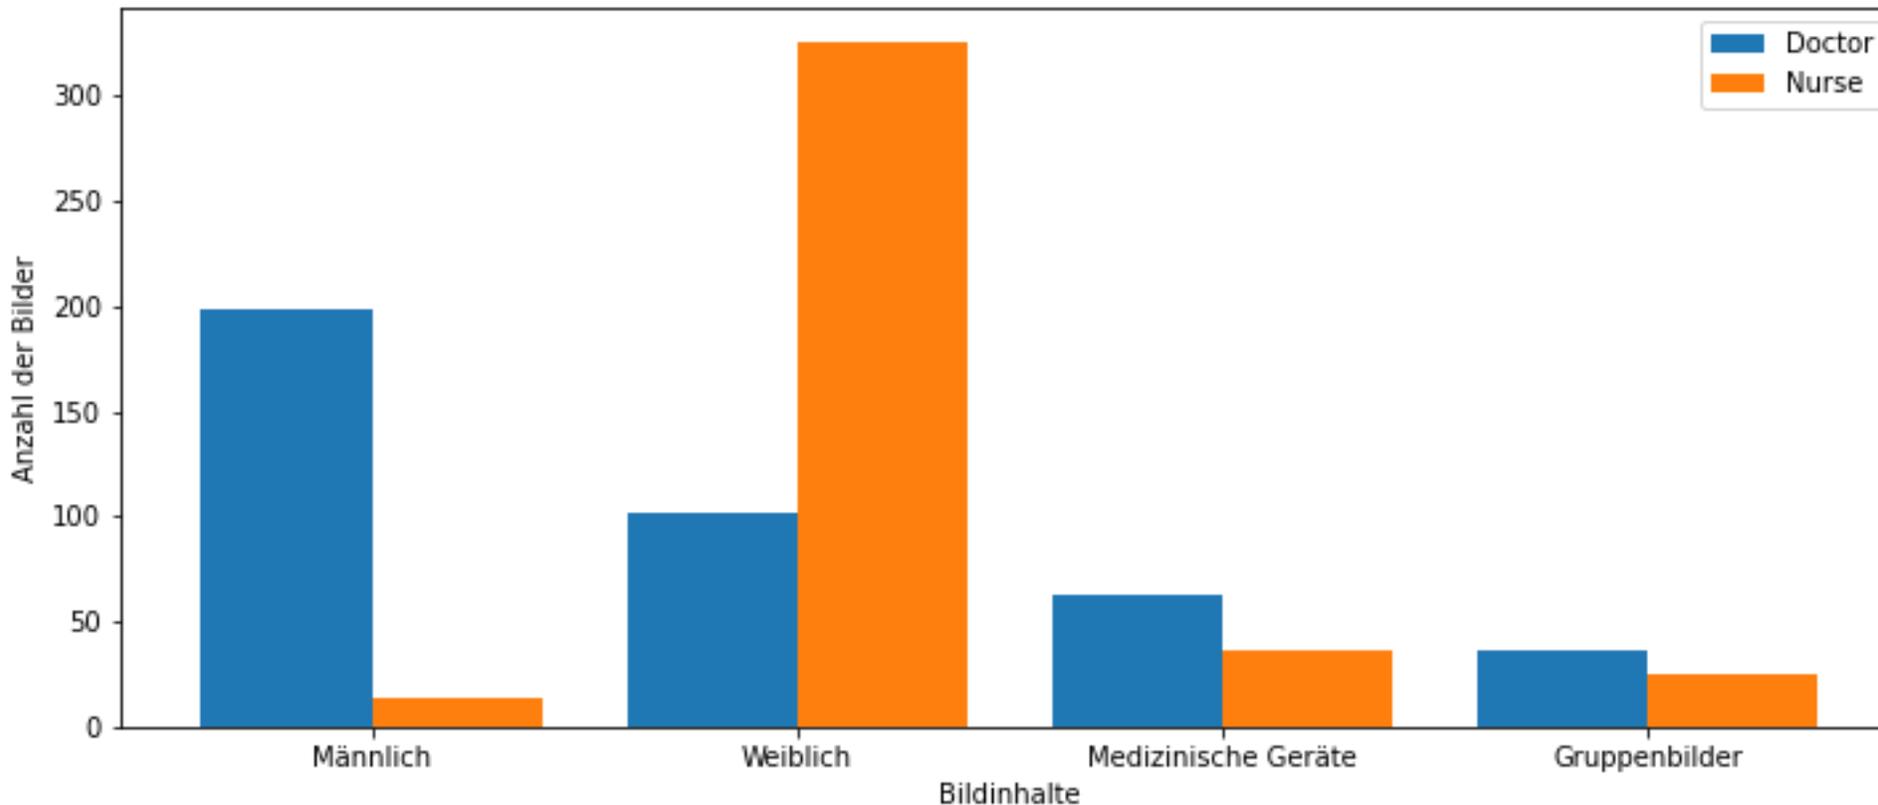
[Zhou et. al. \(2015\)](#)

# Class Activation Maps

Category	Image	GradCAM
Dog		
Cat		

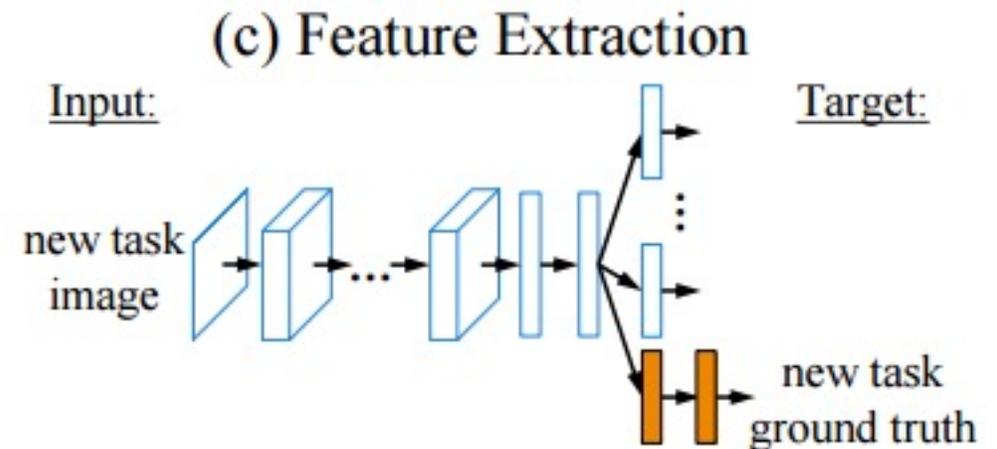
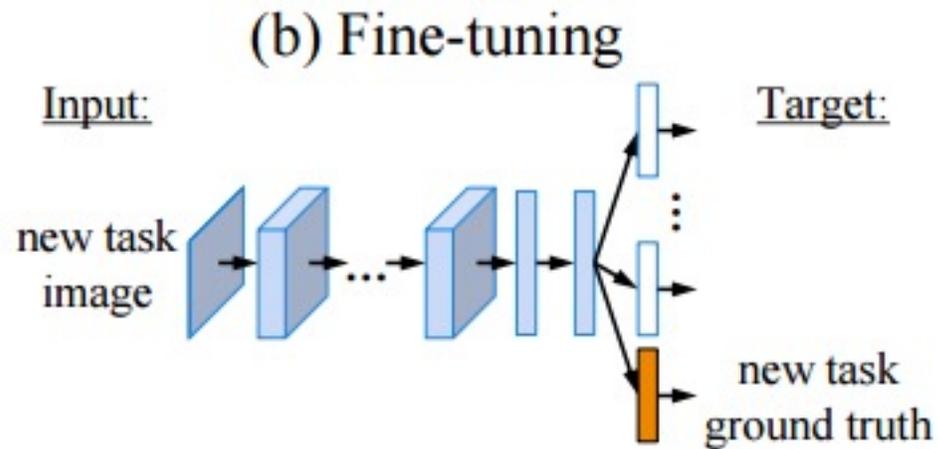
[Jacob Gildenblat  
and contributors  
\(2021\)](#)

# Erkennung von Bias in Datensätzen



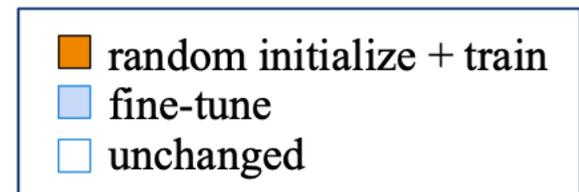
- Datensatz enthält starken Geschlechterbias
- Medizinische Geräte = Stethoskope, etc.
- Gruppenbilder = Bilder mit mehreren Geschlechtern

# Trainingsmethoden



[Li and Hoiem \(2016\)](#)

- Fine-tuning: Modell wird auf Datensatz neu trainiert
- Feature Extraction: Modell übernimmt vorerlernte Features und erweitert diese



# Modelle mit Bias



a) Feature Extraction mit Bias - Doctor



b) Fine-tuning mit Bias - Doctor



c) Feature Extraction mit Bias - Nurse



d) Fine-tuning mit Bias - Nurse

- Feature Extraction hat die unterschiedlichen Arbeitsuniformen erkannt  
→ Doktor:innen langärmelig;  
Krankenschwester/-pfleger kurzärmelig
- Fine-tuning unterliegt dem Bias innerhalb des Datensatzes  
→ Klassifiziert anhand geschlechterspezifischen Merkmalen

# Modelle ohne Bias



a) Feature Extraction ohne Bias - Doctor



b) Fine-tuning ohne Bias - Doctor



c) Feature Extraction ohne Bias - Nurse



d) Fine-tuning ohne Bias - Nurse

- Feature Extraction klassifiziert weiterhin anhand der Arbeitsuniform
  - Fine-tuning klassifiziert nun auch anhand der Arbeitsuniform
- Bias wurde durch ausgleichen der Klassen bereinigt



# Vielen Dank für Ihre Aufmerksamkeit!

Lukas Scholz | 24.06.2022 | HWR Berlin