

Explainable Visual Question Answering (VQA)

Motivation

- Erklärbarkeit von Black-Box-KI-Modellen mithilfe eines generierten „Wärmebildes“
- Barrierefreiheit durch eine sprachliche Ausgabe einer zusätzlich generierten textuellen Erklärung

Technologien

Backend



PyTorch

Frontend



VQA-Modell



InstructBLIP

Overview

Visual Question Answering



Welche Nummer ist auf dem Bild zu sehen?
 Die Nummer 32



1) Visuelle Erklärung



2) Textuelle Erklärung

The visible part of the sign shows the digits “3” and “2,” forming the number 32.

1) Visuelle Erklärung


Ziel: Herausfinden wo die KI hinschaut?

Ausgabe: Ein „Wärmebild“ → warme Bereiche entsprechen wichtigen Bereichen



Umsetzung: Anwendung der SIDU-VQA-Methode

1. Bild in Raster unterteilen
2. Systematisches Ausblenden einzelner Bildausschnitte
3. Messung der Auswirkung auf das KI-Verständnis
 - Wenn ein wichtiges Quadrat abgedeckt wird → Die KI gibt eine veränderte Antwort
 - Wenn ein unwichtiges Quadrat abgedeckt wird → Die KI gibt immer noch dieselbe Antwort
4. Wichtige Quadrate werden im „Wärmebild“ hervorgehoben





2) Textuelle Erklärung

1) Heatmap zu Maske


2) Objekte erkennen

3) Prompt bauen

4) Erklärung generieren




Object Detection Model



Erkennt vorhandene Objekte im maskierten Bild

Anweisung mit diesen Infos:

- + Frage zum Bild
 - + Antwort von InstructBLIP
 - + maskiertes Bild
- ODER
- erkannte Objekte



LLM



Textuelle Erklärung der InstructBLIP -Antwort