

AI Bias by Design

Warum Wahrheit ein Produkt ist

Was ist
Wahrheit?

Etwas ist wahr,
wenn es mit der Welt
übereinstimmt.

Aristoteles

Die manipulierte 'Wahrheit' in der KI

1.

**Manipulation by
Design**

2.

**Perspektive statt
Objektivität**

3.

**Rauszoomen als
Gegenmittel**

Beeinflussbar wie ein Kind

Prompt Jailbreak

Gewollt:

Eine absichtliche Methode, bei der Benutzer durch clevere Prompts KI-Regeln umgehen, um zensierte Inhalte in Szenarien wie Rollenspielen oder Forschung zu erzeugen.

Ungewollt:

Eine unbeabsichtigte Manipulation durch Prompt Injection in externen Inputs, die Sicherheitslücken verursacht, z. B. durch Ausführung bössartiger Anweisungen, die sensible Daten preisgeben oder Phishing ermöglichen.



Der 'Lost-in-the-Middle'-Effekt zeigt, wie LLM bei langen Texten scheitert: Wichtige Infos in der Mitte werden übersehen, während Anfang und Ende bevorzugt werden – das schafft Bias, verzerrt Citations und macht die Wahrheit unzuverlässig.

Hermann del Campo

Noch Fragen?

LinkedIn



Hermann del Campo
AI Queen

Hermann.delcampo@orbit.de
+49 160 553 80 13

Feedback

