



Staatsbibliothek
zu Berlin
Preußischer Kulturbesitz

Staatsbibliothek zu Berlin

KI & RAG – mit einem Chatbot eigene Dokumentensammlungen befragen

Felix Hagenström

15.10.2026

(1) Einführung: **Generative KI // LLMs // RAG**

(2) Vorstellung **Chat AI & Arcana**

- Allgemeines
- Wichtige Funktionen

(3) **Anwendungsszenarien**

- Befragen von **Brieftranskriptionen** aus der Sammlung der Stabi
- Anwendung einer **soziologischen Theorie** auf ein **Praxisbeispiel**

(4) **Hands-on:** Dokumente hochladen und befragen

(5) **Austausch**, Fragen, Abschluss

Generative KI: Anwendungen, die aufgrund maschinellen Lernens neue Inhalte erstellen können (z.B. Texte, Bilder, Audio, Video)

Large Language Models (LLMs)/Große Sprachmodelle: auf riesigen Datenmengen trainierte Modelle, die natürlichsprachliche Eingaben verarbeiten und neue Texte generieren können

Beispiele kommerzieller GenAI-Anwendungen: ChatGPT, Claude, Copilot, Gemini, Mistral Vibe, Perplexity etc.

- Diese Anwendungen nutzen verschiedene LLMs
- In der Praxis: GenAI/GenKI und LLM werden häufig synonym gebraucht

Beispiel KI-Chatbot Chat AI



The screenshot displays the Chat AI interface. At the top, a header bar shows the AI logo, a signal strength indicator, the model name "Meta Llama 3.1 8B Instruct", and a dropdown arrow. On the right side of the header are icons for settings, a button labeled "FH", and a lock icon. The main chat area contains a user message "Was passiert, wenn es regnet?" and a system response in a blue bubble: "Wenn es regnet, werden die Straßen nass und rutschig. Es kann zu Verkehrsstaus kommen, wenn die Straßen unter Wasser stehen oder wenn die Regenwasserabflüsse überlastet sind." Below the response are tabs for "Default", "Markdown", "LaTeX", and "Plaintext", and a token count "Meta Llama 3.1 8B Instruct • 64 + 49 tokens" with icons for editing, deleting, and copying. At the bottom of the chat area are icons for closing the chat, a list of messages, and download/undo actions. A text input field at the bottom contains the placeholder "Frag mich" and a paperclip icon for attachments. The footer bar includes links for "Chat AI v0.9.4", "Datenschutz", and "Impressum", a status indicator "ISO 27001 Zertifiziert", and a language selector showing a German flag.

Meta Llama 3.1 8B Instruct

Was passiert, wenn es regnet?

Wenn es regnet, werden die Straßen nass und rutschig. Es kann zu Verkehrsstaus kommen, wenn die Straßen unter Wasser stehen oder wenn die Regenwasserabflüsse überlastet sind.

Default Markdown LaTeX Plaintext

Meta Llama 3.1 8B Instruct • 64 + 49 tokens

Frag mich

Chat AI v0.9.4 Datenschutz Impressum

ISO 27001 Zertifiziert

- LLMs sind *keine Wissensmodelle*
 - Outputs von LLMs beruhen auf *Wahrscheinlichkeiten*
 - Text wird nach statistischen Kriterien und bestimmten Parametern erstellt

Die	Straße	ist		
			nass	45 %
			gefährlich	21 %
			breit	11 %
			menschenleer	0.7 %

- LLMs sind *keine Wissensmodelle*
 - Outputs von LLMs beruhen auf *Wahrscheinlichkeiten*
 - Text wird nach statistischen Kriterien und bestimmten Parametern erstellt

Die

Straße


ist

nass

gefährlich

breit

menschenleer



By August Natterer, Public Domain, <https://commons.wikimedia.org/w/index.php?curid=12756650>

- Mensch: Wahrnehmung von etwas, aber *ohne externe Stimuli*
- LLMs: Überzeugend formulierter, aber *falscher Output*

Alternativer Begriff zu Halluzination:

„**Bullshit**“ (Harry Frankfurt) <https://stabikat.de/Record/1616072253>

- Indifferenz gegenüber Wahrheit
- Kein Anspruch der Wirklichkeitsrepräsentation

Künstliche Intelligenz

KI erfindet jede dritte Antwort

Stand: 27.10.2025 • 14:46 Uhr

Eine neue Studie der Europäischen Rundfunkunion zeigt alarmierende Fehlerquoten bei populären KI-Chatbots. Die Systeme erfinden regelmäßig Informationen und geben sogar falsche Quellen an.

<https://www.tagesschau.de/wissen/technologie/kuenstliche-intelligenz-fakten-100.html>

STUDIE

Zahl falscher KI-Referenzen in Forschungsarbeiten nimmt zu

Falsche Zitate und Quellen in wissenschaftlichen Publikationen nehmen zu. Das deutet darauf hin, dass Prüfmechanismen unzureichend funktionieren.

24.06.2026

<https://www.forschung-und-lehre.de/forschung/zahl-falscher-ki-referenzen-in-forschungsarbeiten-nimmt-zu-7760>

- RAG kann Halluzinationen nicht verhindern, das Risiko jedoch abmildern
➤ *Aber wie?*


RAG steht für **Retrieval-Augmented Generation** (etwa: *per Abfrage erweiterte Generierung*)


- RAG-Systeme stellen LLMs **externe Quellen zur Verfügung** (z.B. lokale Dokumente/Daten oder Zugriff aufs Web)
- **Daten** werden in **Chunks zerlegt, indexiert** und in einer **Vektordatenbank verknüpft**


Warum nutzt man RAG?

LLMs haben große Schwachstellen:

- **Halluzinationen:** Mangel an Faktentreue lässt ein LLM plausibel klingende, aber faktisch falsche Antwort erfinden
- **Wissensstopp (Knowledge Cut-off):** Die Trainingsdaten reichen nur bis zu einem bestimmten Datum; aktuelle Ereignisse sind unbekannt







Fraunhofer-Institut für Experimentelles
Software Engineering IESE

https://www.iese.fraunhofer.de/blog/wp-content/uploads/2024/05/retrieval_augmented_generation_RAG_600px.png



- Service von KISSKI/GWDG (Göttingen)
- KISSKI: Eines von vier KI-Servicezentren in Deutschland (Förderung seit 2022 vom Bund)

Zugang über Academic Cloud



Bildquelle: <https://kisski.gwdg.de/ueber-uns/konsortium/>




- Teil der **KI-Infrastruktur für Wissenschaft und Forschung** in Deutschland
- Zugang über **Academic Cloud**
- **Datenschutz** bei Sprachmodellen gewährleistet (auf lokalen Servern gehostet); Ausnahme: eigene Institution bietet Zugriff auf weitere Modelle
- **Daten werden nur im Browser (lokal) gespeichert**
- **Auswahl verschiedener Modellen** (<https://docs.hpc.gwdg.de/services/chat-ai/models/index.html>)
- Größtmögliche **Transparenz** und **Steuerungsmöglichkeit**
- Nutzung im **Webbrowser** oder via **API**
- Zugriff über die **eigene Institution** oder einen **kostenfreien Einzelaccount**



- Chat AI bietet einen **RAG-Manager**
- Dokumentensammlungen heißen bei Chat AI: **Arcanas**

Kurzanleitung

- Auf der Chat-AI-Benutzeroberfläche (Browser) oben links auf das Logo klicken und ‚RAG-Manager‘ auswählen
- ‚Arcanas‘ oder ‚My Arcanas‘ anklicken – durch den Prozess leiten lassen + indexieren
- Dateien
 - Unterschiedliche Formate möglich (PDF, DOCX, CSV, TXT, XML, MD)
 - Max. Größe 300 MB





Schauen wir mal rein...


<https://chat-ai.academiccloud.de/>

▪ Beispiel 1: Digitalisierte Briefe von und an Julie Elias

Szenario: Wir arbeiten zum Werk von Julie Elias und wollen ihre Briefwechsel für unsere Studie auswerten. Dazu wollen wir ausgewählte Transkriptionen aus der Sammlung der Stabi befragen.

❖ Dokumente

- Briefe von Julie Elias (PDF) (liegen auch in anderen Formaten vor)



<https://commons.wikimedia.org/wiki/index.php?curid=63504233>



https://upload.wikimedia.org/wikipedia/commons/1/14/Jane_Jacobs.jpg

▪ Beispiel 2: Jane Jacobs' Theorie der ‚Eyes on the Street‘

Szenario: Wir forschen im Bereich der Stadtsoziologie und wollen Jacobs' Theorie auf empirische Fälle in Berlin anwenden. Es geht um die Frage, welche Straßen als sicher gelten.

❖ Dokumente:

- Zusammenfassung der Theorie: *Urban-Vitality_eyes-on-the-street_Natural-surveillance_Jane-Jacobs.md*
- Liste mit Berliner Straßen für die Anwendung (.txt)

- **Datenqualität** beeinflusst Zuverlässigkeit
 - Benennung und Strukturierung der Dokumente wichtig
 - **Keine Garantie** für völlige Halluzinationsfreiheit
 - **Keine übergreifenden Erkenntnisse** aus komplexer Dokumentensammlung
-
- RAG erfordert einige Arbeit
 - Kritische Überprüfung immer notwendig

- Chat AI aufrufen und **neues Arcana anlegen**
- **Eigene Dokumente** oder **bereitgestellte Dateien** hochladen
 - Weitere **Beispieldokumente**:
 - Briefe von Julie Elias (PDF)
 - Auszug aus Till Eulenspiegel (DOCX)
 - Die fröhliche Wissenschaft (F. Nietzsche) (TXT)
 - Für die Beispieldateien bei Webex unten rechts auf die **drei Punkte** und dann auf **„Inhalt“/„Content“** klicken
- **Indexieren** Sie die Dokumente
- Kopieren Sie die **Arcana-ID** in die Chat-AI-Einstellungen
- Evtl. temp & top_p und/oder Systemprompt anpassen

Mögliche Fragen für die Beispieldokumente

Julie Elias:

- An wen schreibt Julie Elias?
- Auf wann sind die Briefe Julie Elias' datiert?
- Geht es in einem der Briefe um Alkohol?

Jane Jacobs:

- Auf Grundlage von Jane Jacobs' Theorie der 'Eyes on the Street' zieh eine Schlussfolgerung: Welche der aufgelisteten Straßen ist höchstwahrscheinlich die sicherste und warum?

Till Eulenspiegel:

- In welche Orte/Städte/Dörfer reist Till Eulenspiegel?

Friedrich Nietzsche:

- Was ist Nietzsches erklärte Absicht hinter der Schrift „Die fröhliche Wissenschaft“?

1. Was haben Sie ausprobiert?
2. Was gut geklappt?
3. Was war frustrierend?
4. Was würden Sie in Zukunft weiter nutzen?

Dankeschön



IceMing & Digit / <https://betterimagesofai.org> / <https://creativecommons.org/licenses/by/4.0/>

Fragen & Austausch

Vorschau – Stabi-Veranstaltungen zu KI:

- 4.11., 14:30 Uhr, Online-Workshop: KI und Literaturrecherche
- 4.11., 14 Uhr, Online-Workshop Stabi Lab: Cards to Catalogue – Sharing Experiences in LLM-Based Card Catalogue Conversion
- 18.11., 10 Uhr, Hands-On-Workshop: Plausibel, aber wahr? Quellenkritik im Zeitalter von KI

Alle Stabi-Veranstaltungen:
<https://blog.sbb.berlin/termine/#veranstaltungen>

felix.hagenstroem@sbb.spk-berlin.de

Halluzinationen

<https://www.iese.fraunhofer.de/blog/halluzinationen-generative-ki-llm/>

RAG

<https://www.iese.fraunhofer.de/blog/retrieval-augmented-generation-rag/>

Chat AI | Academic Cloud | Arcana

<https://chat-ai.academiccloud.de/> | <https://academiccloud.de/> | <https://chat-ai.academiccloud.de/arcanas/> | **Anleitung Arcana:** <https://docs.hpc.gwdg.de/services/ai-services/arcana/how-to-use/index.html>

Stabi Lab

<https://lab.sbb.berlin/> | <https://lab.sbb.berlin/dataset-transkriptionen-julie-elias/>