


LU11b - RAG Chatbot

RAG (Retrieval-Augmented Generation) ist eine gängige Variante, um Fragen zu benutzerspezifischen Dokumenten zu beantworten.



©

<https://www.ridgerun.ai/post/how-to-evaluate-retrieval-augmented-generation-rag-systems>


Zu Beginn muss man die gewünschten Daten (z.B. Lernunterlagen) ...

1. ... in Chunks unterteilen
2. ... „embedden“
3. ... in die Vektordatenbank speichern

Der Ablauf funktioniert grob so:

1. Der Benutzer gibt eine Frage ein, welche an die Applikation geschickt wird.
2. Die Frage wird „Embedded“ und an die Vektordatenbank geschickt
3. Von der Vektordatenbank werden die n passendsten Chunks im Klartext an die Applikation zurückgegeben.
4. Die Applikation schickt die originale Frage im Klartext mitsamt den Chunks an ein LLM-Model
5. Das LLM-Model schickt eine Antwort zurück an die Applikation
6. Die Applikation kann z.B. Quellen o. Ä. bei Bedarf ergänzen und die Antwort an den Benutzer zurückschicken.

Vektordatenbank



Last update:

2025/11/18 02:12 de:modul:ffit:3-jahr:java:learningunits:lu11:b https://wiki.bzz.ch/de/modul/ffit/3-jahr/java/learningunits/lu11/b?rev=1763428332

From:

<https://wiki.bzz.ch/> - **BZZ - Modulwiki**

Permanent link:

<https://wiki.bzz.ch/de/modul/ffit/3-jahr/java/learningunits/lu11/b?rev=1763428332>

Last update: **2025/11/18 02:12**

