Vorabfragen

- Stellen Sie sich vor, Sie möchten einen Chatbot entwickeln, der Fragen zu PDF-Dokumenten beantwortet. Welche Teilprobleme müssten Sie Ihrer Meinung nach lösen?

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Deep Learning, Machine Learning und Künstliche Intelligenz – SS 26

Gelesen von Prof. Dr. Daniel Gaida

Prof. Dr. Daniel Gaida

Professor für Cyber-Physische Systeme

Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Technology
Arts Sciences
TH Köln

Lernziele von heute und Fragen zur Überprüfung der Lernziele

Die Studierenden können sprachbasierte User Interfaces in Python entwickeln, indem sie

- für eine gegebene Anwendung ein geeignetes vortrainiertes Deep Learning Modell (LLM, Text2Speech, Speech2Text) auswählen und herunterladen,
- mit Gradio eine App unter Einbindung des Deep Learning Modells in Python programmieren,
- die App testen,

um später sprachbasierte User Interfaces unter Nutzung von Deep Learning Modellen umsetzen zu können.

Überprüfung des Lernziels: S. fortlaufende Übung heute.

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Lernraum II: Deep Learning

- Inhalt
  - Entwickeln eines Chatbots mit Spracherkennung und -synthese
  - Text2Image, Text2Video, Image2Text, Video2Text, …

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Chatbot Entwicklung

- Chatbot mit dem man beliebig formulierte Fragen zu einem oder mehreren Dokumenten stellen kann.

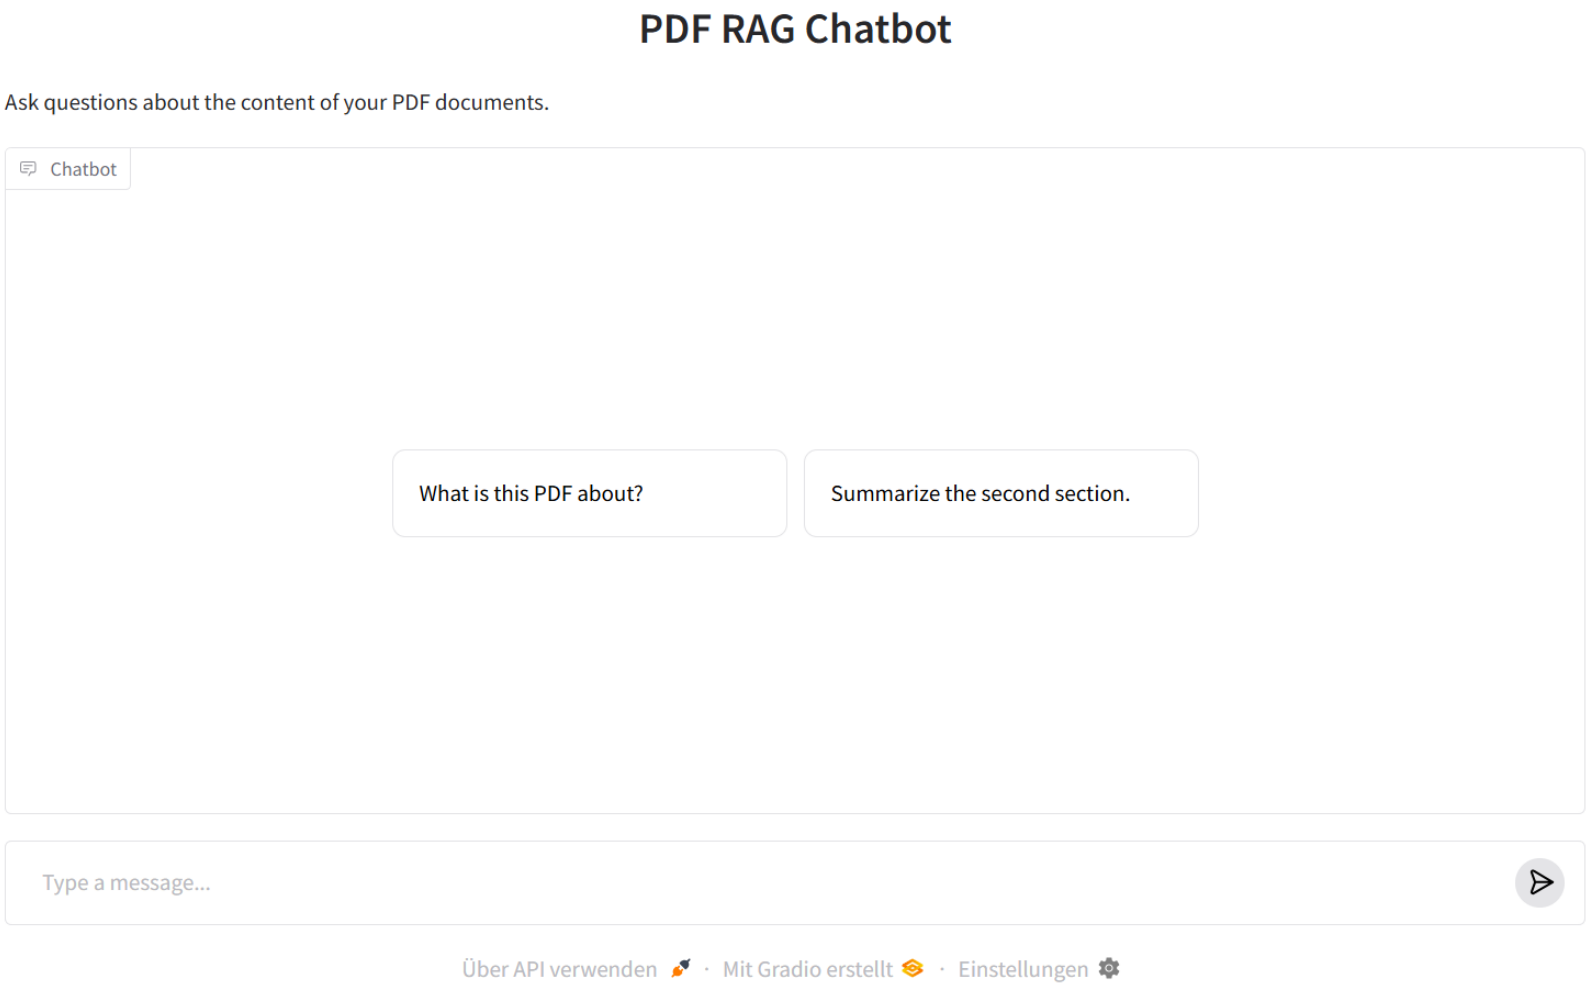

Quelle:
https://blog.gopenai.com/step-by-step-guide-to-implementing-retrieval-augmented-generation-in-python-4801be2771c3

Retrieval Augmented Generation (RAG)

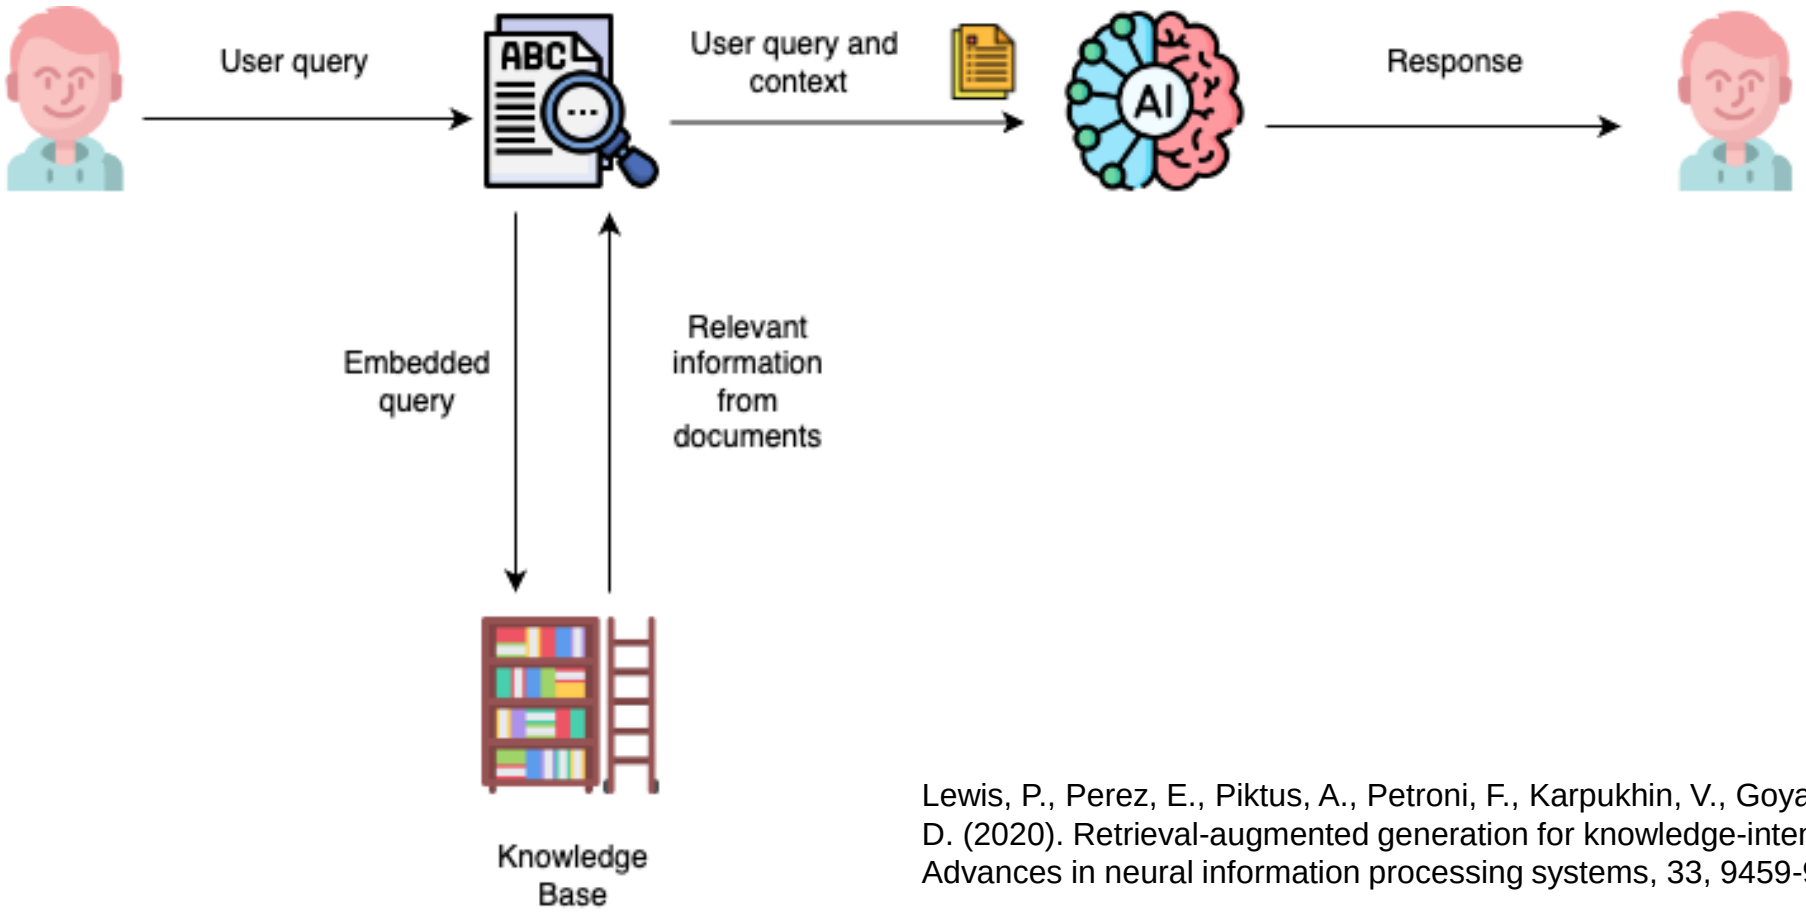

Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., ... & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive nlp tasks. Advances in neural information processing systems, 33, 9459-9474.

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Retrieval Augmented Generation

1. Erstellung der Wissensdatenbank
2. Relevante Inhalte aus Wissensdatenbank zurück liefern und an LLM übergeben
3. Antwort von LLM generieren lassen

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Erstellung der Wissensdatenbank

- Wissensdatenbank kann erstellt werden aus:
  - PDFs, Markdown, txt, docx, pptx, html, …
- Dokument Parser wird benötigt
  - Es gibt viele verschiedene; Hier: Unstructured.io genutzt
- Dokument muss in kleine Abschnitte geteilt werden (bspw. Sätze, Absätze, …)
  - Damit zur Suchanfrage relevante Abschnitte gefunden werden können
- Alle Dokumentabschnitte werden in einer Datenbank gespeichert
- → Wissensdatenbank

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Dokument Parser – Unstructured.io

- https://github.com/Unstructured-IO/unstructured-api

General Pre-Processing Pipeline for Documents

This repo implements a pre-processing pipeline for the following documents. Currently, the pipeline is capable of recognizing the file type and choosing the relevant partition function to process the file.

Category	Document Types
Plaintext	`.txt` , `.eml` , `.msg` , `.xml` , `.html` , `.md` , `.rst` , `.json` , `.rtf`
Images	`.jpeg` , `.png`
Documents	`.doc` , `.docx` , `.ppt` , `.pptx` , `.pdf` , `.odt` , `.epub` , `.csv` , `.tsv` , `.xlsx`
Zipped	`.gz`

Dokument Parser

```
# --- Step 1: Set up PDF file path ---
# Put your PDF files in a folder named "pdfs" in the current directory
PDF_DIR = "pdfs"

# --- Step 2: Load and parse PDFs with uMiner (via UnstructuredReader) ---
all_documents = utils.read_pdf_files_with_unstructured_reader(PDF_DIR)

print(f"Loaded {len(all_documents)} documents")
for doc in all_documents[:3]:
    print(doc.text[:300])  # Zeige ersten Ausschnitt
```

Erste Schritte mit dem Notebook

Gehen Sie zu: https://dgaida.github.io/llm_client/dev/tutorials/rag-chatbot/

Klicken Sie auf: https://github.com/dgaida/llm_client/blob/master/notebooks/RAGChatbot_groq_API.ipynb und öffnen Sie das Notebook in Google Colab

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Erste Schritte mit dem Notebook

- Notebook „RAGChatbot_groq_API“ in Google Colab öffnen
- Ordner „pdfs“ erstellen und mindestens ein PDF Dokument einfügen
- Erste Zelle des Notebooks ausführen (installiert alle Packages)
  - Es erscheint eine Meldung, dass Sitzung neu gestartet werden muss
  - Auf Button „Restart Session“ klicken

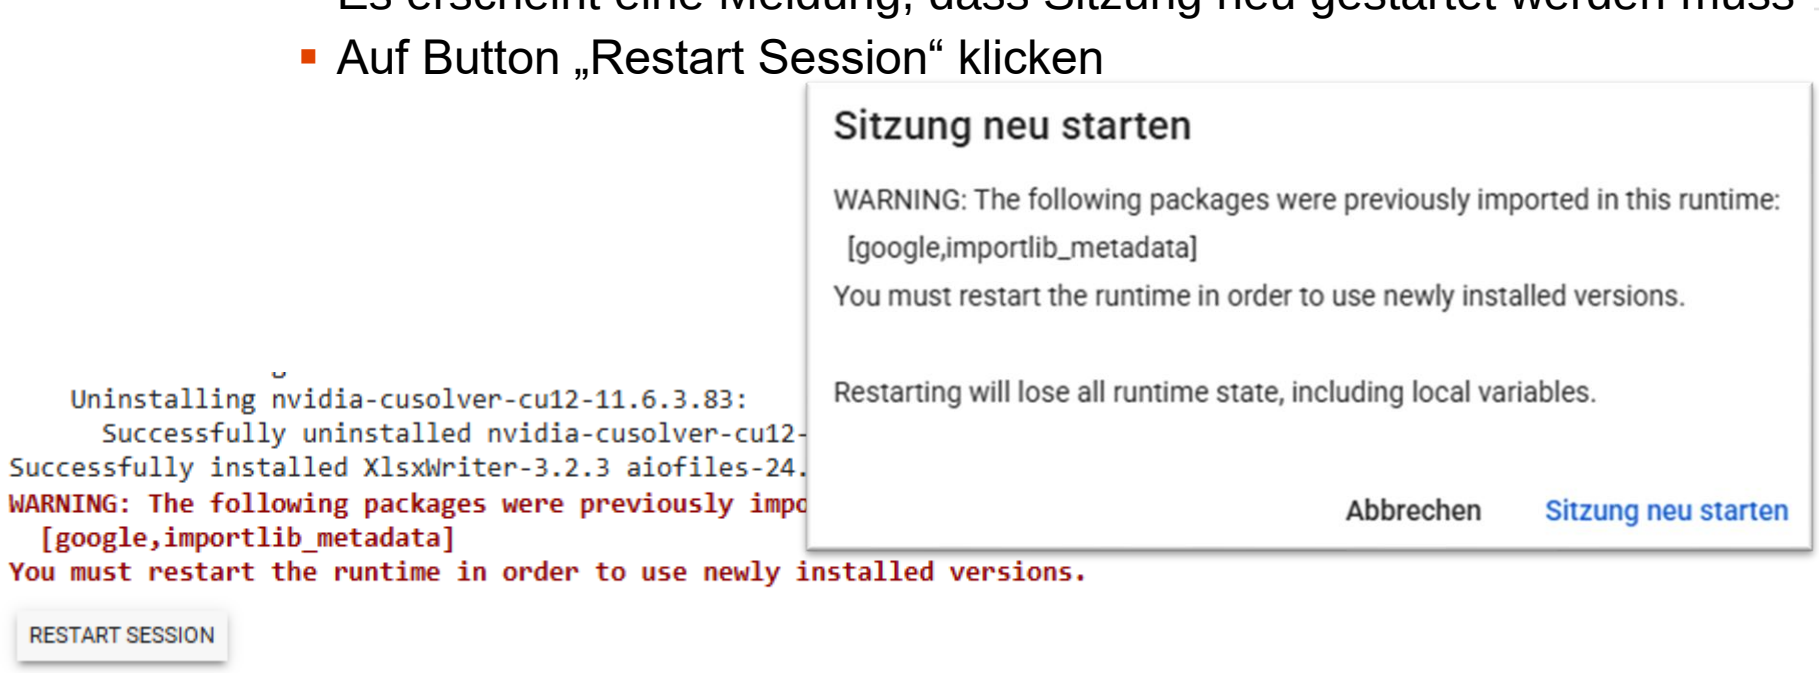

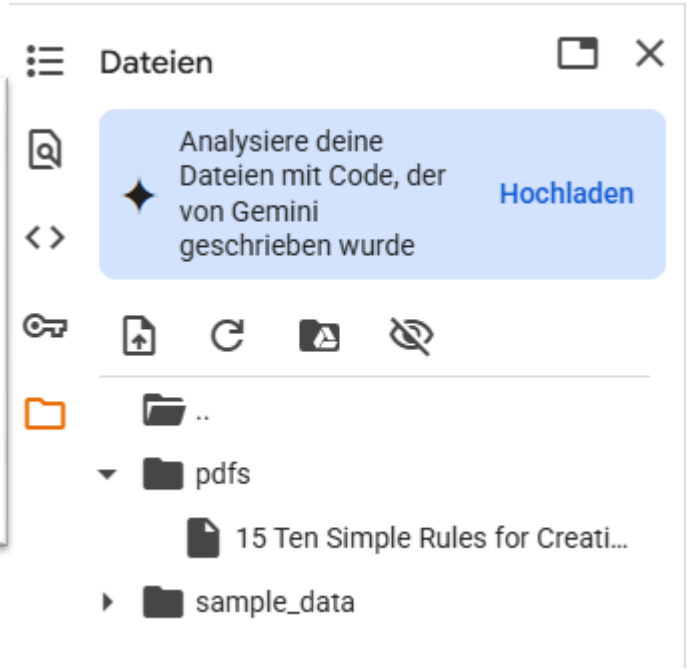

Erste Schritte mit dem Notebook

- Drei weitere Zellen ausführen bis einschließlich:
  - Installation von llm_client, alle imports, Dokument(e) einlesen

```python
# --- Step 2: Load and parse PDFs with uMiner (via UnstructuredReader) ---
all_documents = utils.read_pdf_files_with_unstructured_reader(PDF_DIR)

print(f"Loaded {len(all_documents)} documents")
for doc in all_documents[:3]:
    print(doc.text[:300])  # Zeige ersten Ausschnitt
```


Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

LlamaIndex

- UnstructuredReader wird von LlamaIndex importiert
- https://www.llamaindex.ai/

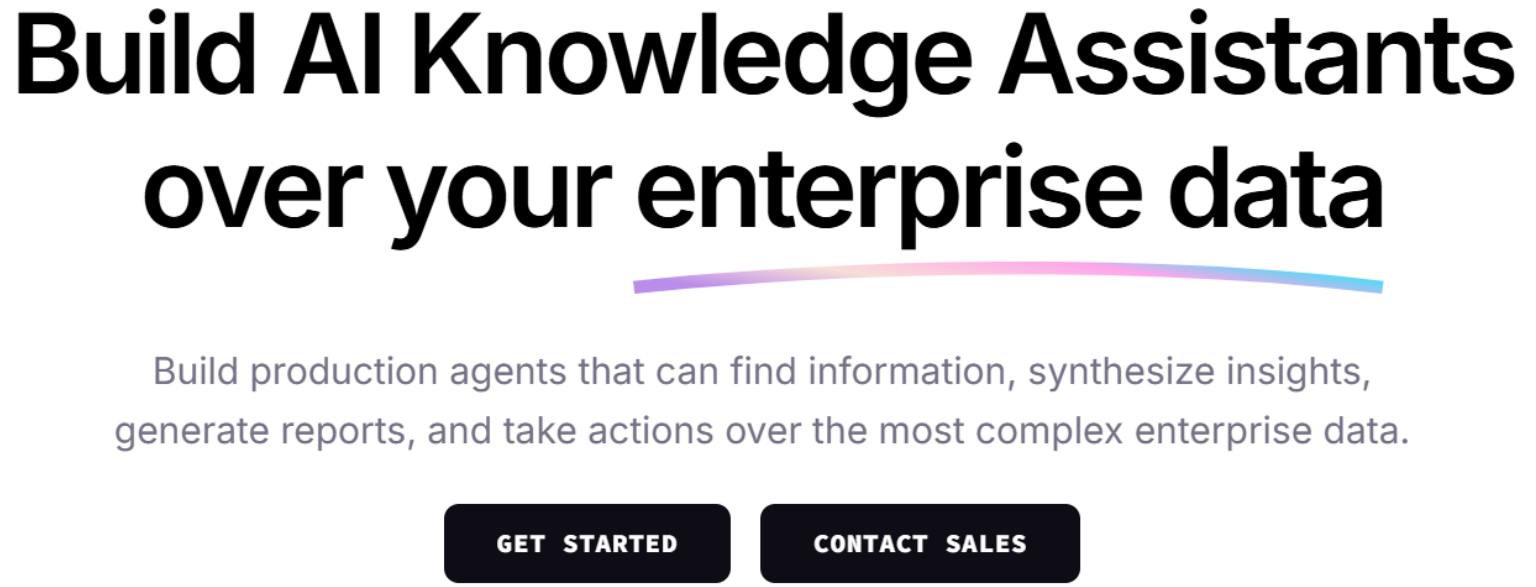

Dokument in Abschnitte teilen

node_parser = SentenceSplitter(chunk_size=256, chunk_overlap=0)

Was bedeutet chunk_size und chunk_overlap?

- chunk_size: Größe eines Textabschnitts gemessen in Anzahl Tokens (hier 256 Tokens)
- chunk_overlap: Überlapp zwischen zwei aufeinander folgenden Textabschnitten (hier 0 Token)

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Dokument in Abschnitte teilen

Chunk Overlap

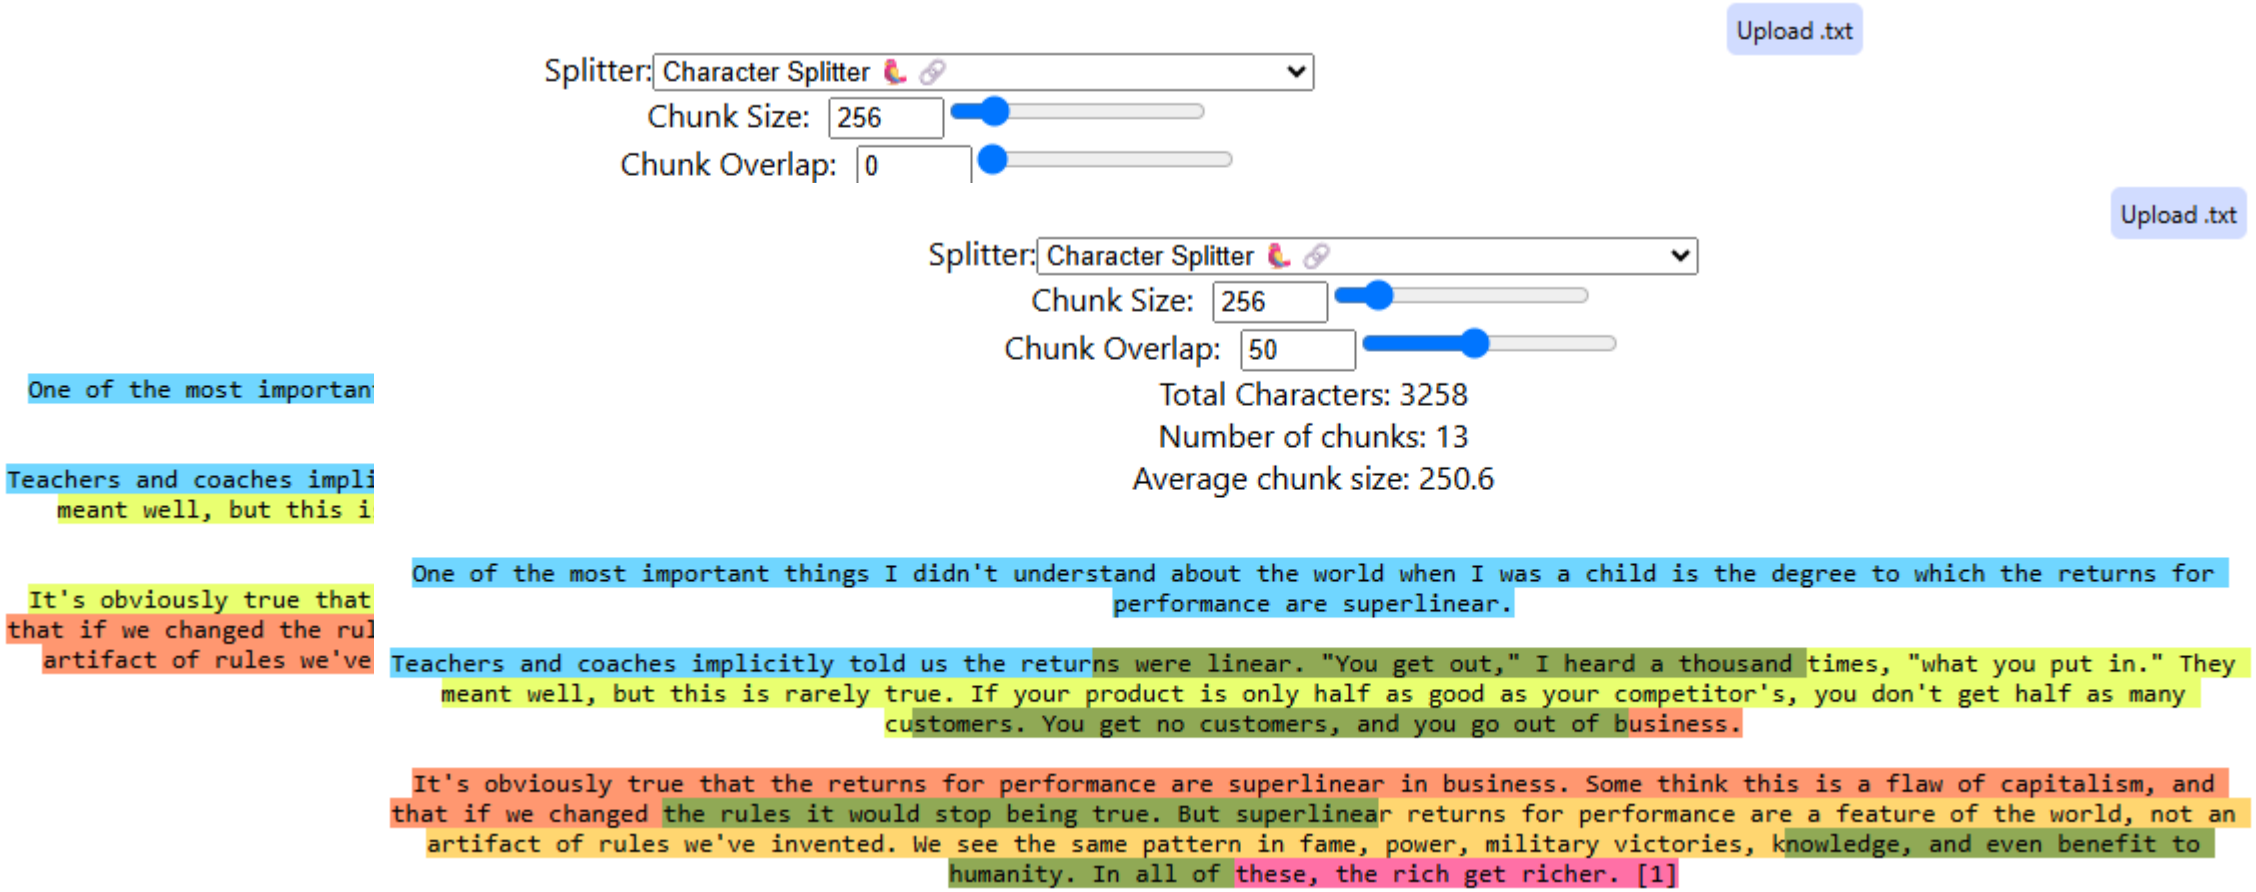

Quelle: https://chunkviz.up.railway.app/

Dokument in Abschnitte teilen

Chunk Overlap

Ohne chunk_overlap:

Hans geht nach Hause. Hans freut sich auf den Abend. Der Grund ist, dass er sich noch mit Freunden treffen wird.

Warum freut sich Hans auf den Abend?

Mit chunk_overlap:

Hans geht nach Hause. Hans freut sich auf den Abend. Der Grund ist, dass er sich noch mit Freunden treffen wird.

Prof. Dr. Daniel Gaida

Professor für Cyber-Physische Systeme

Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Technology
Arts Sciences
TH Köln

Erste Schritte mit dem Notebook

- Eine weitere Zellen ausführen bis einschließlich:
  - Dokument(e) in Chunks einteilen

```python
# --- Step 2: Load and parse PDFs with uMiner (via UnstructuredReader) ---
all_documents = utils.read_pdf_files_with_unstructured_reader(PDF_DIR)

print(f"Loaded {len(all_documents)} documents")
for doc in all_documents[:3]:
    print(doc.text[:300])  # Zeige ersten Ausschnitt
```

```python
# split documents into smaller chunks for better retrieval
node_parser = SentenceSplitter(chunk_size=256, chunk_overlap=0)  # 512, 50
```

Erstellung der Wissensdatenbank

- Ziel: Wir wollen in der Wissensdatenbank nach Chunks suchen, die inhaltlich zu der Frage des Nutzers passen. D.h.:
  - Eine **semantische Suche** soll durchgeführt werden!

- Vorteil einer semantischen Suche vs. Keyword-basierte Suche?
  - Semantische Suche interpretiert die Bedeutung einer Anfrage, statt nur exakte Schlagwörter zu matchen
    (z. B. "Wie groß ist ein Elefant?" → findet auch "Durchschnittliche Höhe eines Rüsseltiers").

  - Flexiblere Formulierungen: Liefert auch bei umformulierten oder synonymen Anfragen relevante Ergebnisse – Keyword-basierte Suche scheitert oft daran.

  - Höhere Relevanz der Treffer und weniger irrelevante Ergebnisse.

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Wie misst man die semantische Ähnlichkeit von Chunks?

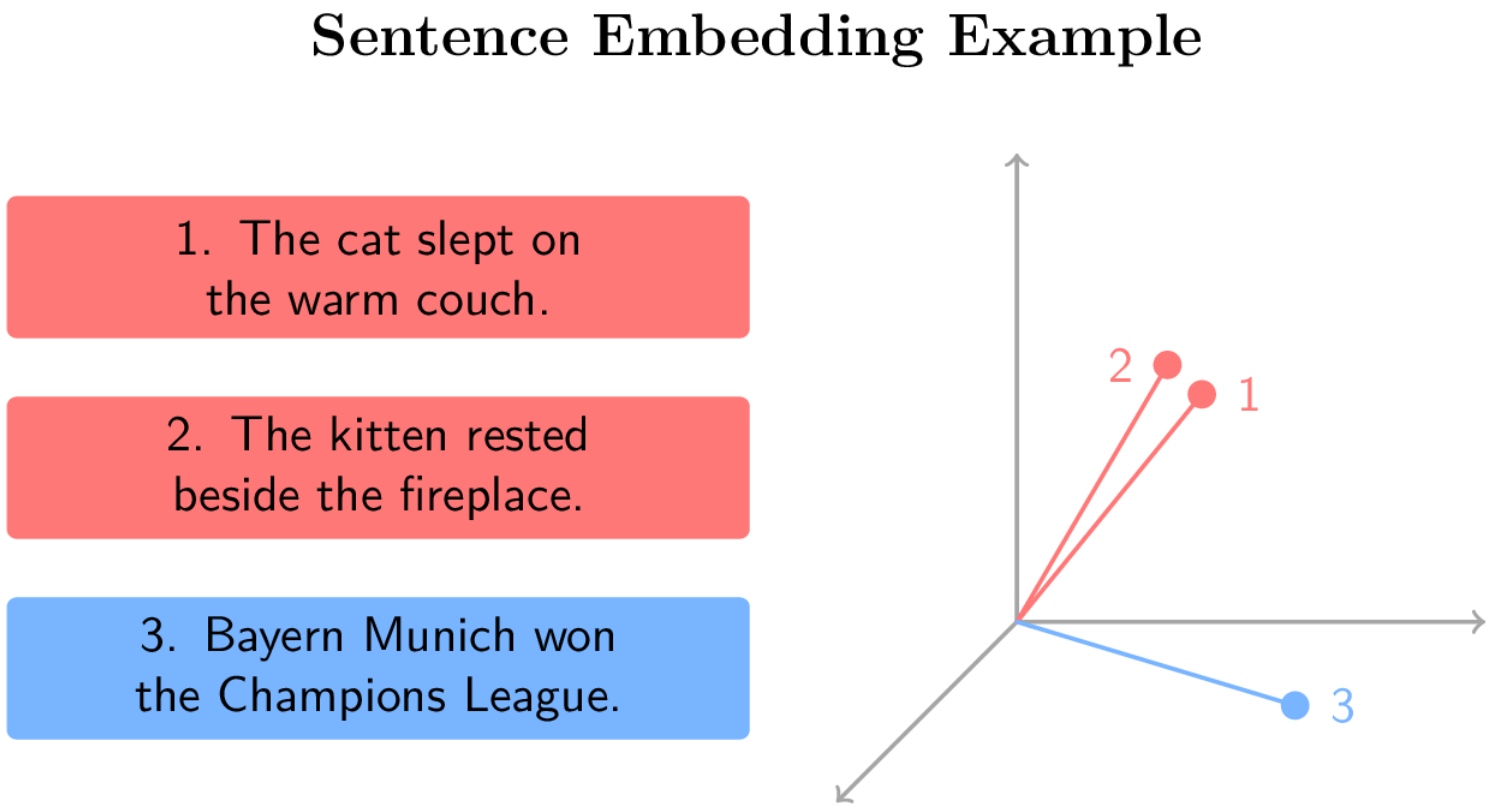

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Vgl.: https://www.coursera.org/learn/retrieval-augmented-generation-rag/lecture/i1O6p/semantic-search-introduction

Chunks finden, die semantisch ähnlich zur Nutzerfrage sind

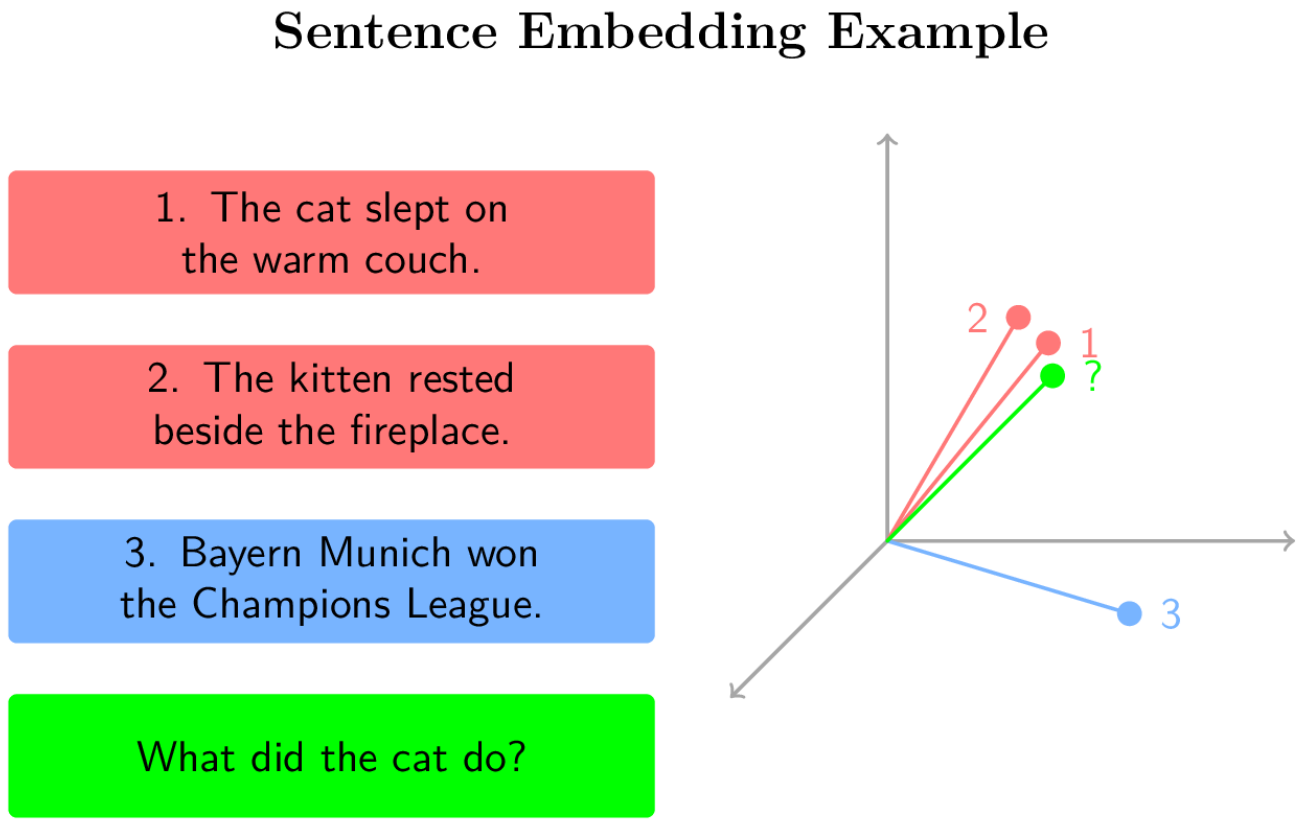

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Vgl.: https://www.coursera.org/learn/retrieval-augmented-generation-rag/lecture/i1O6p/semantic-search-introduction

Erstellung der Wissensdatenbank

- Alle Dokumentabschnitte (Chunks) werden in einer Vektordatenbank gespeichert
  - Ermöglicht eine semantische Suche

- Vektordatenbank:
  - Schlüssel ist der Vektor
  - Wert ist der Chunk

Anmerkung: sehr vereinfachte Darstellung einer Vektordatenbank

Key as Vector	Value
(0.1, 0.23, 0.5, …)	The cat slept on the warm couch
(0.8, 0.1, 0.25, …)	Bayern Munich won the Champions League.

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Erstellung der Wissensdatenbank

- Alle Dokumentabschnitte (Chunks) werden in einer Vektordatenbank gespeichert
  - Ermöglicht eine semantische Suche
    - Chunks müssen als Vektoren gespeichert werden
    - Ähnlichkeit zwischen Vektor der Suchanfrage und Vektoren in Datenbank
    - Chunks zu Vektoren, die ähnlich zu dem Vektor der Suchanfrage sind, werden zurück geliefert

- Warum wandelt man einen Satz in einen Vektor um?
  - Vektoren kann man besser miteinander vergleichen als Sätze
  - Bspw. über das Skalarprodukt (Cosine similarity)

- Wie wandelt man einen Satz in einen Vektor um?

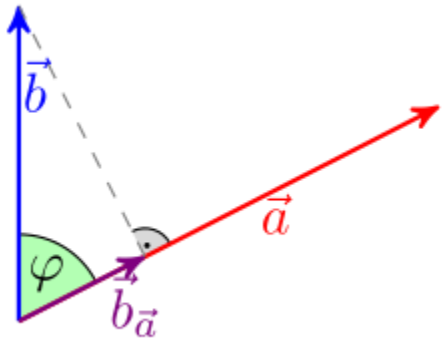

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Bildquelle:
https://de.wikipedia.org/wiki/Skalarprodukt

Von Dokumentabschnitten (Chunks) zu Vektoren

Im Bereich der Textverarbeitung/-generierung wird …

- Text in Wörter oder Teilwörter unterteilt (Tokens, Tokenization)
  - Tokens sind das Vokabular

- jedes Token durch ein Deep Learning Modell in einen Vektor umgewandelt
  - Deep Learning Modell heißt **Embedding Modell** und
  - Vektoren heißen **Embedding Vektoren**

- Man kann auch einen ganzen Satz (bzw. Chunk) mit einem Embedding Modell in einen Vektor umwandeln
  - Vektor repräsentiert die Semantik (Bedeutung) des Satzes/Chunks

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Tokenization

- Demo: https://tiktokenizer.vercel.app/

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
TH Köln

From Tokens 2 Embeddings (Embedding Vektoren)

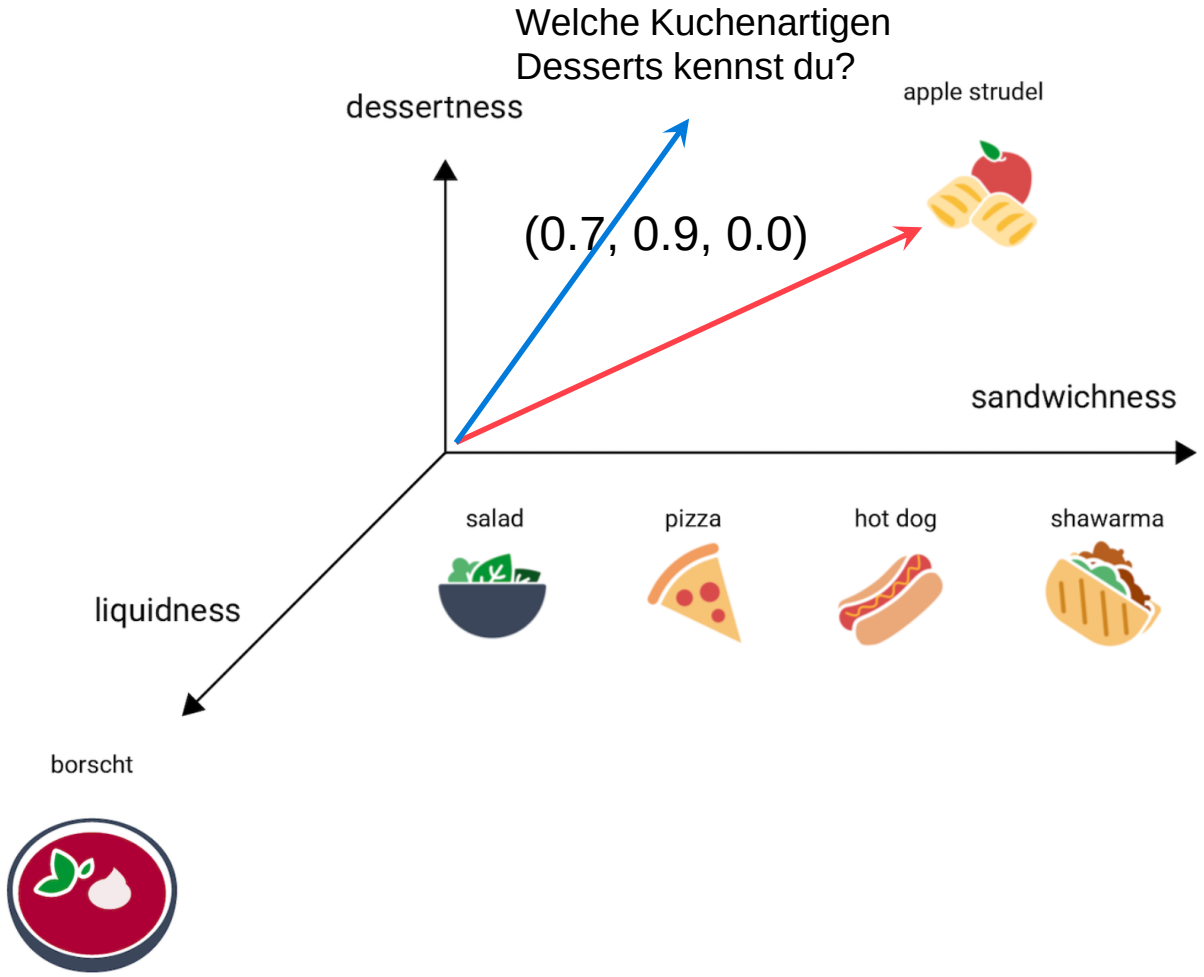

Figure 5. *Foods plotted by "sandwichness," "dessertness," and "liquidness."*

- Vektoren leben in einem hochdimensionalen Vektorraum
  - Bspw. 1024, unsere in 384 Dimensionen
- Hier Annahme:
  - 3-dimensionaler Vektorraum

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

https://developers.google.com/machine-learning/crash-course/embeddings/obtaining-embeddings

Embedding Modell

Wandelt Token in Embedding Vektor um

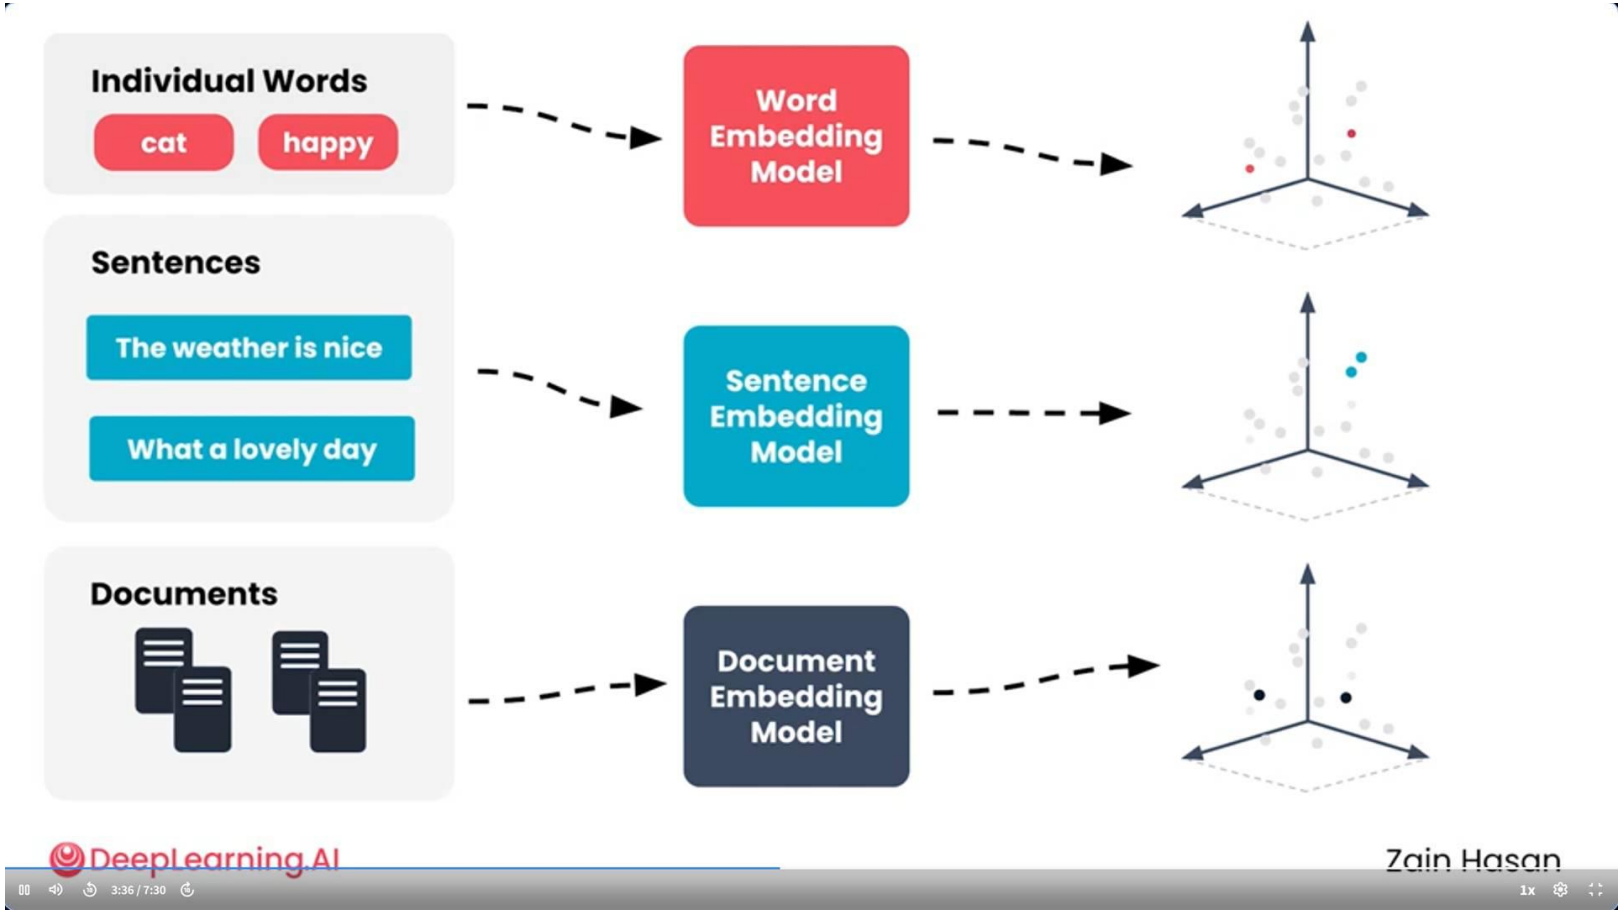

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

https://www.coursera.org/learn/retrieval-augmented-generation-rag/lecture/i1O6p/semantic-search-introduction

Embedding Modell angeben

Wandelt Token in Embedding Vektor um

embed_model = HuggingFaceEmbedding("sentence-transformers/all-MiniLM-L6-v2")

“Our model is intended to be used as a sentence and short paragraph encoder. Given an input text, it outputs a vector which captures the semantic information. The sentence vector may be used for information retrieval, clustering or sentence similarity tasks.” https://huggingface.co/sentence-transformers/all-MiniLM-L6-v2

embed_model = HuggingFaceEmbedding(model_name = "intfloat/e5-small-v2")

„This model only works for English texts. Long texts will be truncated to at most 512 tokens.“

https://huggingface.co/intfloat/e5-small-v2

Embedding Modelle:

- https://platform.openai.com/docs/guides/embeddings

Einrichtung eines Accounts bei Hugging Face (1/2)

- https://huggingface.co/ und Sign Up
- Gehen Sie dann zu Ihrem Profil, klicken auf Settings und dann auf „Access Tokens“
- Erstellen Sie ein neues „Write“ Token mit einem sinnvollen Namen

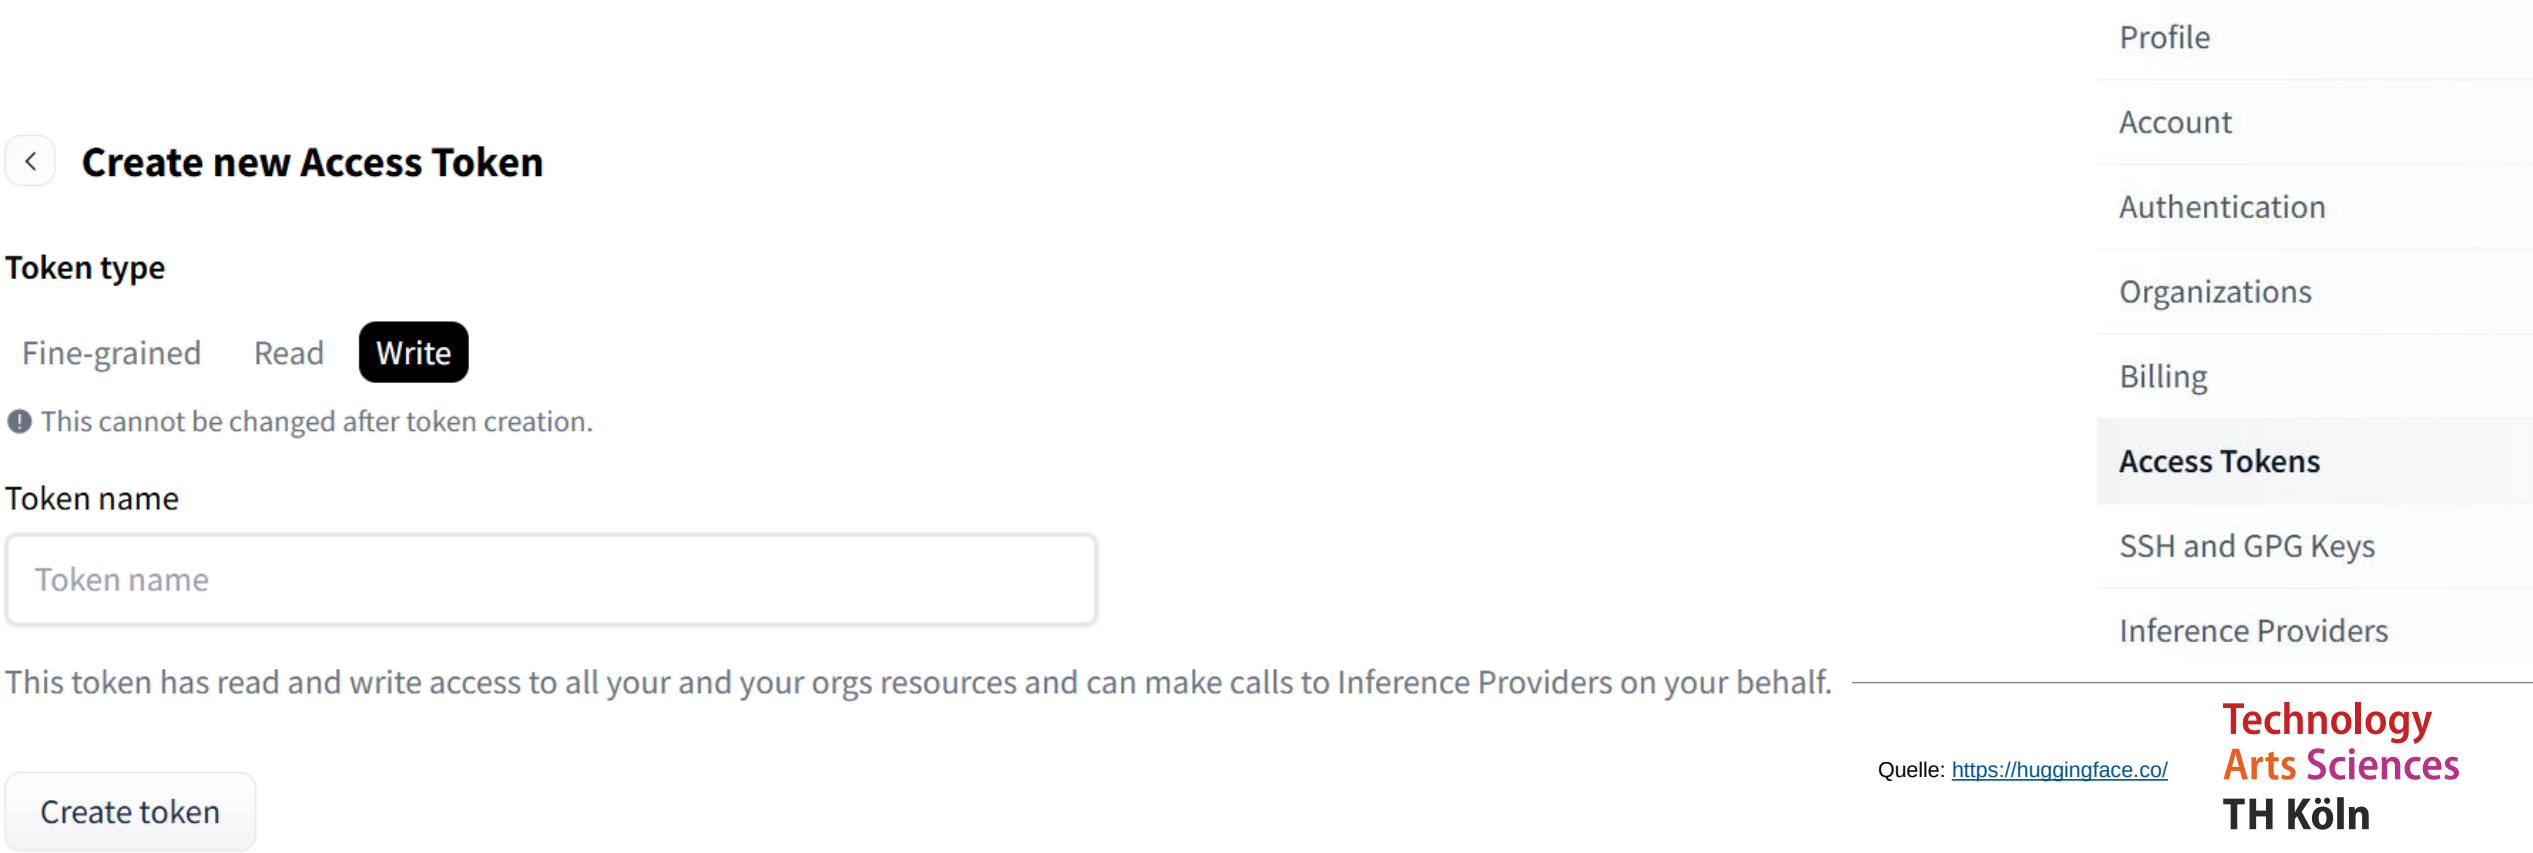

Quelle: https://huggingface.co/

Einrichtung eines Accounts bei Hugging Face (2/2)

- Gehen Sie zu Google Colab und erstellen Sie dort ein neues „Secret“ Namens „HF_TOKEN“ und kopieren Sie das erstellte Token hinein (beginnt mit „hf_...“)

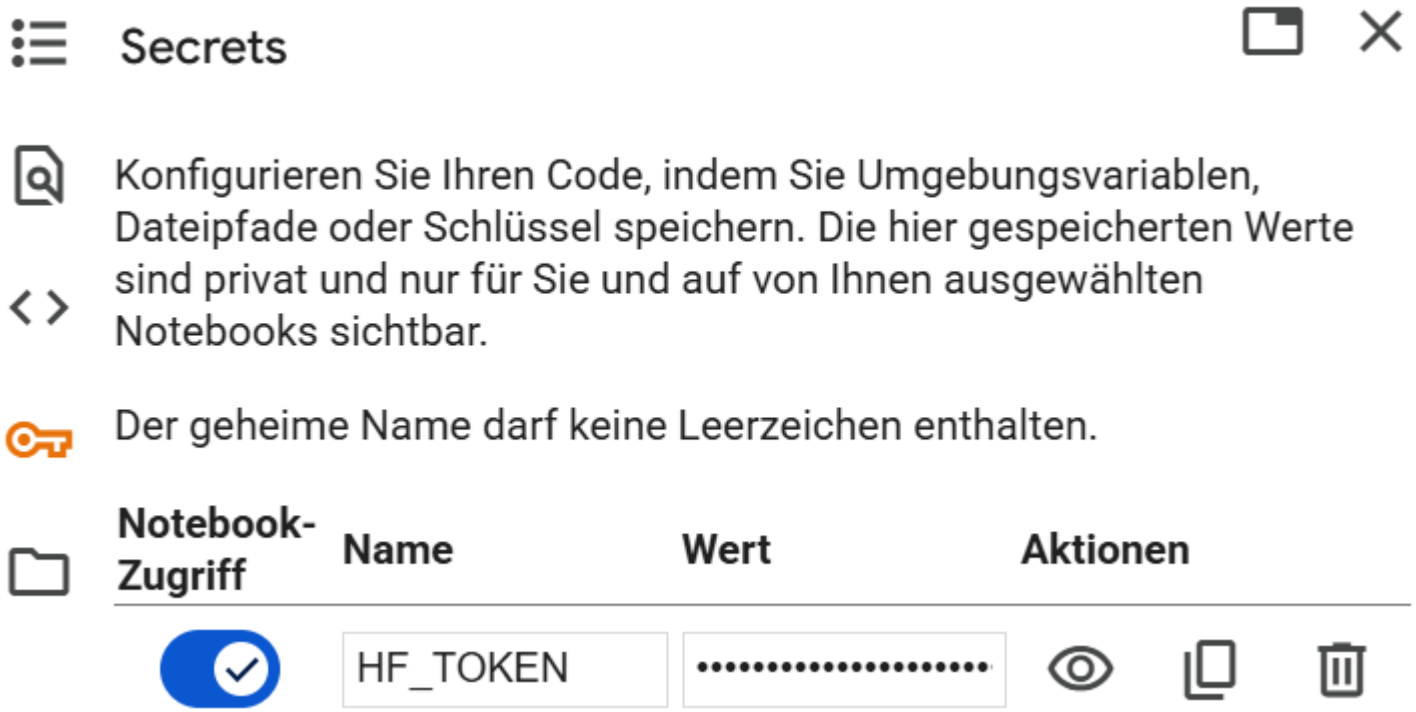

https://github.com/dgaida/llm_client/tree/master/notebooks#%EF%B8%8F-api-keys-als-secrets-in-google-colab-hinterlegen

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Quelle: https://colab.research.google.com/

Erstellung der Wissensdatenbank

- Alle Dokumentabschnitte werden in einer Vektordatenbank gespeichert
- Es gibt viele Vektordatenbanken
- Hier: Chroma genutzt

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Bildquelle:
https://www.trychroma.com/

Dokumentabschnitte in Vektordatenbank speichern - Chroma

```
# --- Step 4: Create vector store and index ---
index = utils.create_chromadb_vector_store_and_index(all_documents)
```

Key	Value
(0.1, 0.23, 0.5, …)	The project aims to train sentence embedding models …
(0.8, 0.1, 0.25, …)	We fine-tune the model using a contrastive objective.

Quelle:
https://blog.gopenai.com/step-by-step-guide-to-implementing-retrieval-augmented-generation-in-python-4801be2771c3

Retrieval Augmented Generation (RAG)

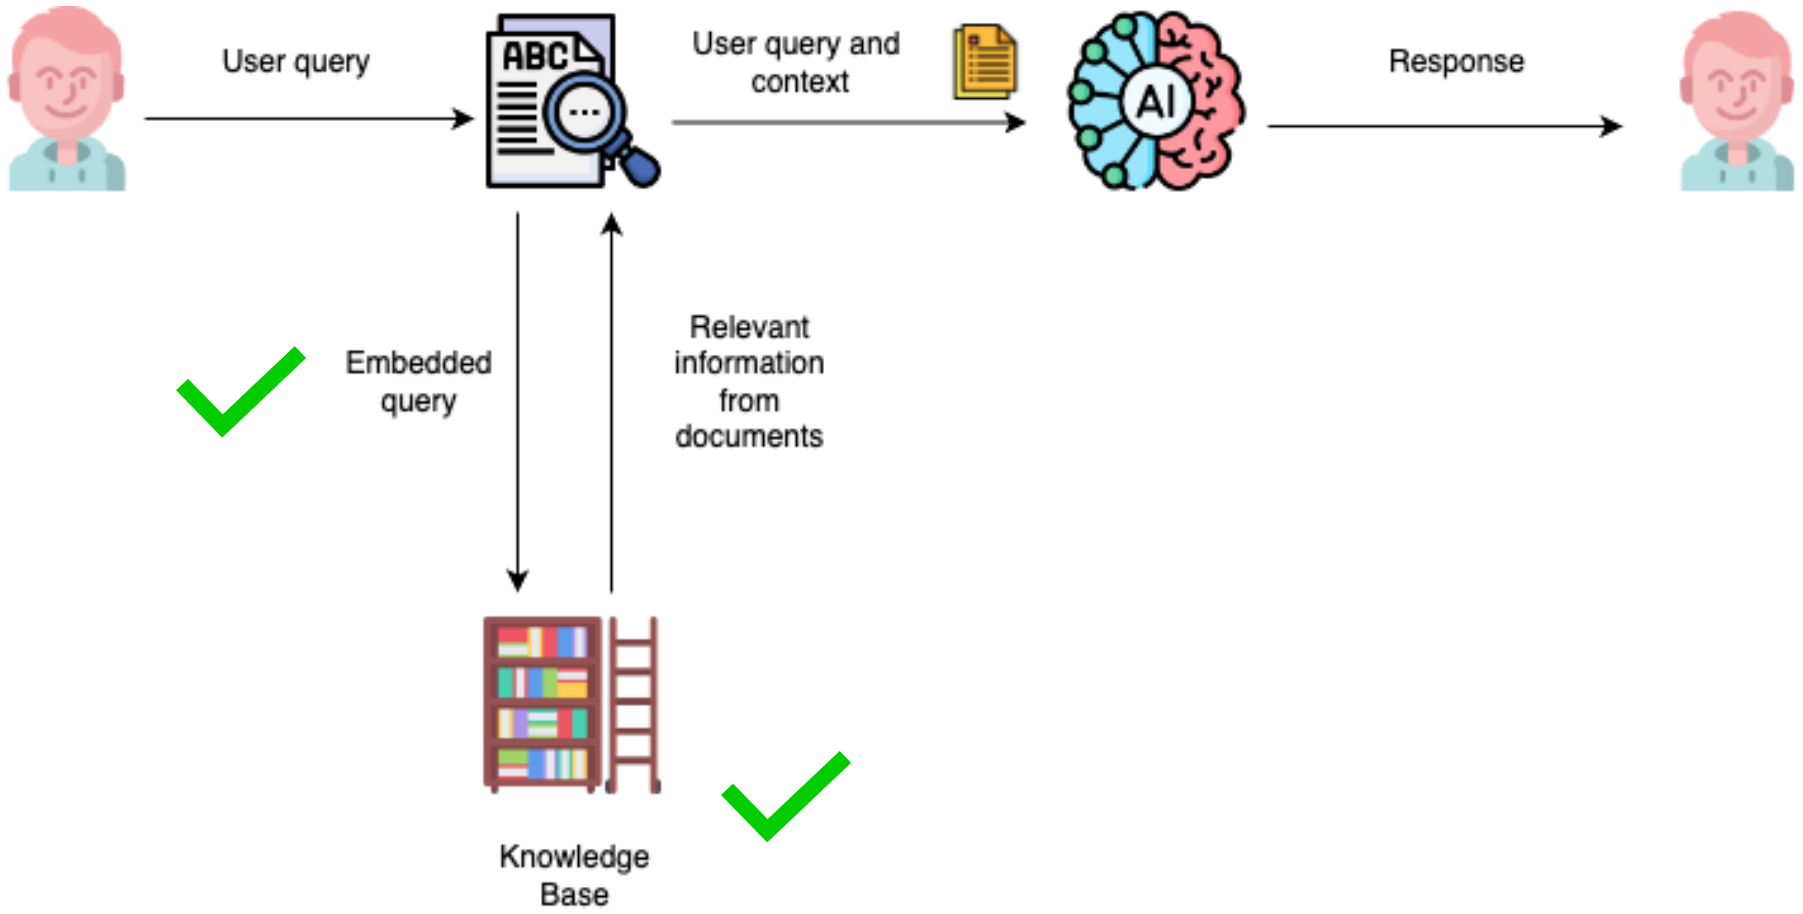

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Wo läuft das Large Language Model (LLM)?

- LLM läuft in der Cloud, bereitgestellt über die Groq API
- Einige Suchanfragen pro Tag kostenlos
- Alle möglichen modernen Open Source LLMs nutzbar
- Benötigt einen kostenfreien Account bei Groq:
  - S.: https://dgaida.github.io/llm_client/dev/tutorials/rag-chatbot/#groq-api-key-erstellen

- Verbindung zu Groq definiert in Klasse „LLMClient“
- Einfach änderbar zu:
  - OpenAI API (api_choice = „openai“)
  - Google API (api_choice = „gemini“)

Large Language Modell (LLM) angeben

```
# client that uses openAI or Groq API, here groq API
client = LLMClient(api_choice = "groq")
# Adapter erzeugen
adapter = LLMClientAdapter(client=client)


from llama_index.core import Settings

Settings.llm = adapter
Settings.embed_model = embed_model
Settings.node_parser = node_parser                # SentenceSplitter
```

Relevante Chunks zurück liefern und Antwort generieren

```
# Analogie: index ist die Datenbank – .as_query_engine() macht daraus eine Suchmaschine.
query_engine = index.as_query_engine()    # index ist ein VectorStoreIndex von LlamaIndex

def chat_with_pdf(query, history=None):
    return utils.safe_query_engine_call(query_engine, query)
```

safe_query_engine_call() ruft intern query_engine.query(query) auf …

- wandelt query in Embedding Vektor um,
- führt semantische Suche in Vektordatenbank durch
- liefert relevante Chunks zurück und sendet diese inkl. query an das LLM
- liefert Antwort des LLMs zurück

Entwicklung eines Chatbots

Gradio App

```
# This creates a simple web UI for asking questions
chat_ui = gr.ChatInterface(
    fn=chat_with_pdf,
    title="PDF RAG Chatbot",
    description="Ask questions about the content of your PDF documents.",
    theme="default",
    examples=["What is this PDF about?", "Summarize the second section."],
)

chat_ui.launch()
```


Prof. Dr. Daniel Gaida

Professor für Cyber-Physische Systeme

Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Quelle: https://www.gradio.app/guides/creating-a-chatbot-fast

Entwicklung eines Chatbots

Gradio App

Testen Sie den Chatbot

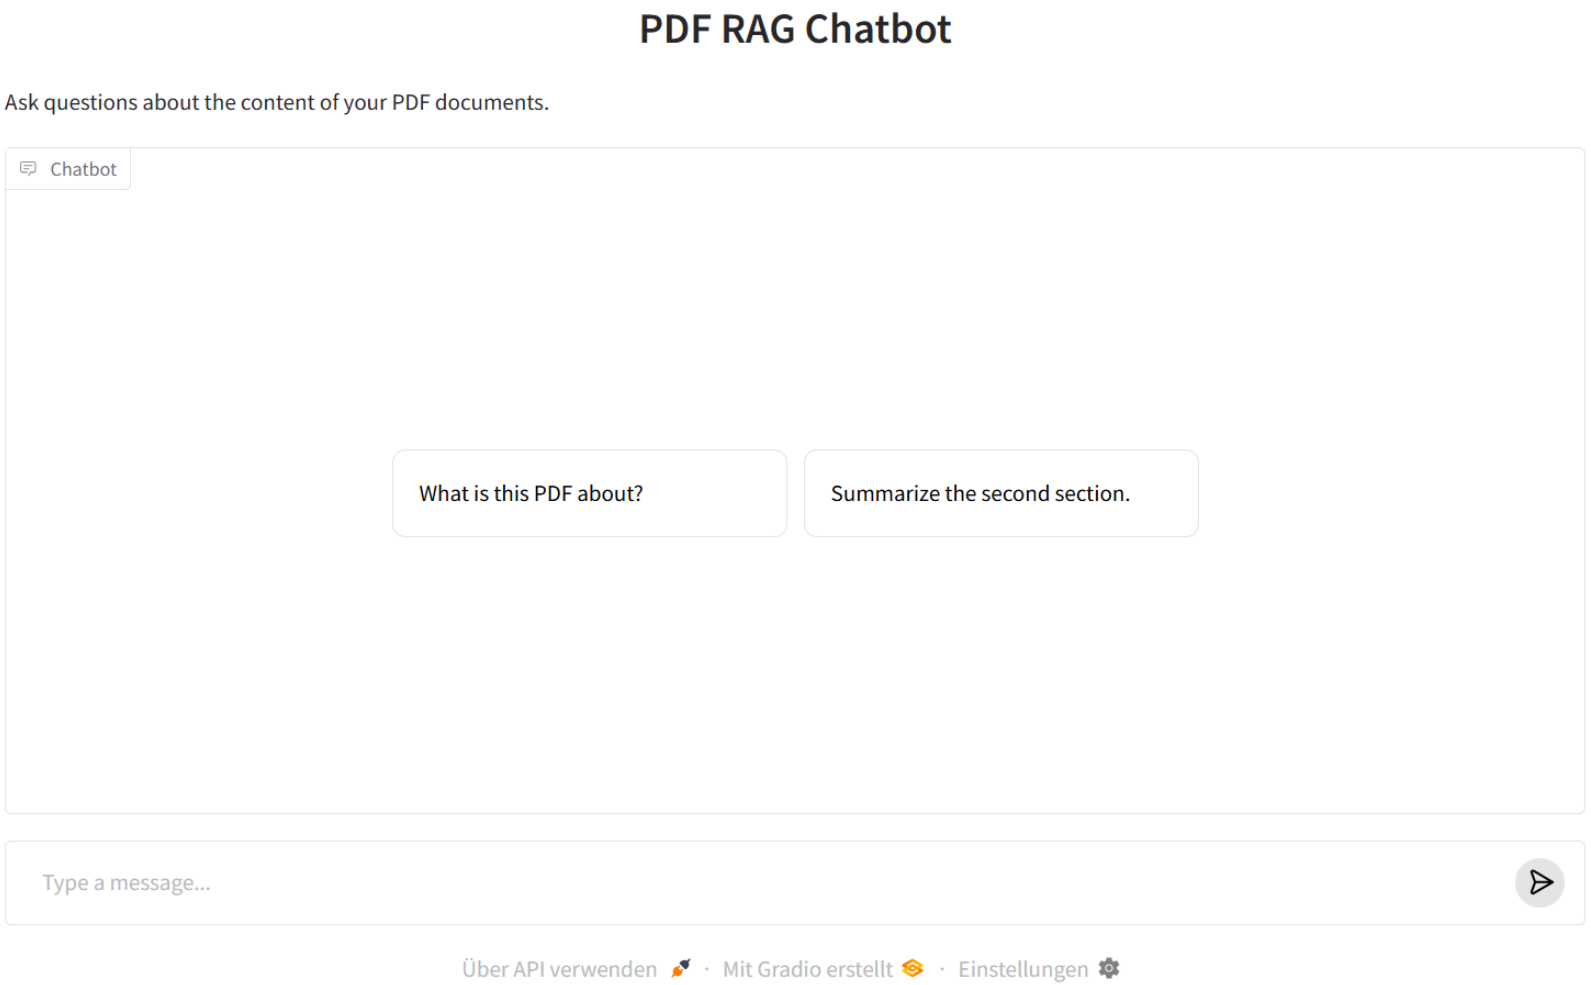

Fragen - Pause

- Gibt es Fragen zu diesem Notebook?

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Entwicklung eines Chatbots

Ollama.com

- Aktuelle LLMs können heruntergeladen und lokal ausgeführt werden
  - Was bedeutet 7b, 14b, …?
    - Anzahl Modellparameter in Billions (Milliarden)
- Python und JavaScript API
  - https://github.com/ollama/ollama-python

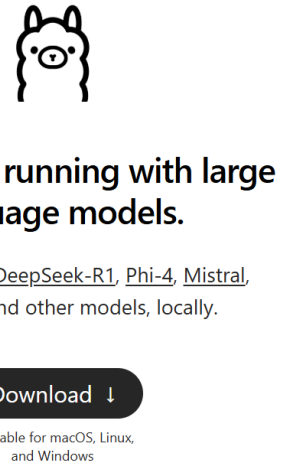

client = LLMClient(api_choice = "ollama")

Neu:

- Ollama Cloud
- https://docs.ollama.com/cloud

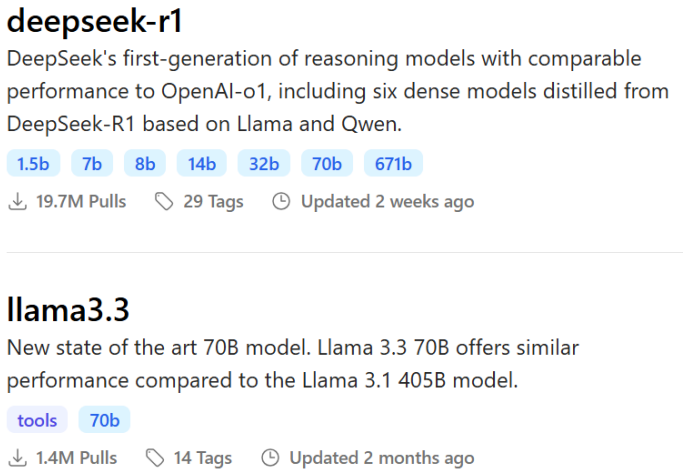

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Quelle: https://ollama.com/

Entwicklung eines Chatbots

OpenAI API

- LLM in der Cloud

- Vorteile:
  - Schnelle Inferenz, sehr große Modelle von OpenAI nutzbar
- Nachteile:
  - Kosten, Privatsphäre?

```
client = LLMClient(api_choice = "openai")
```


Prof. Dr. Daniel Gaida

Professor für Cyber-Physische Systeme

Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Quellen:
https://platform.openai.com/docs/overview
https://docs.llamaindex.ai/en/stable/examples/llm/openai/

Entwicklung eines Chatbots

Open WebUI

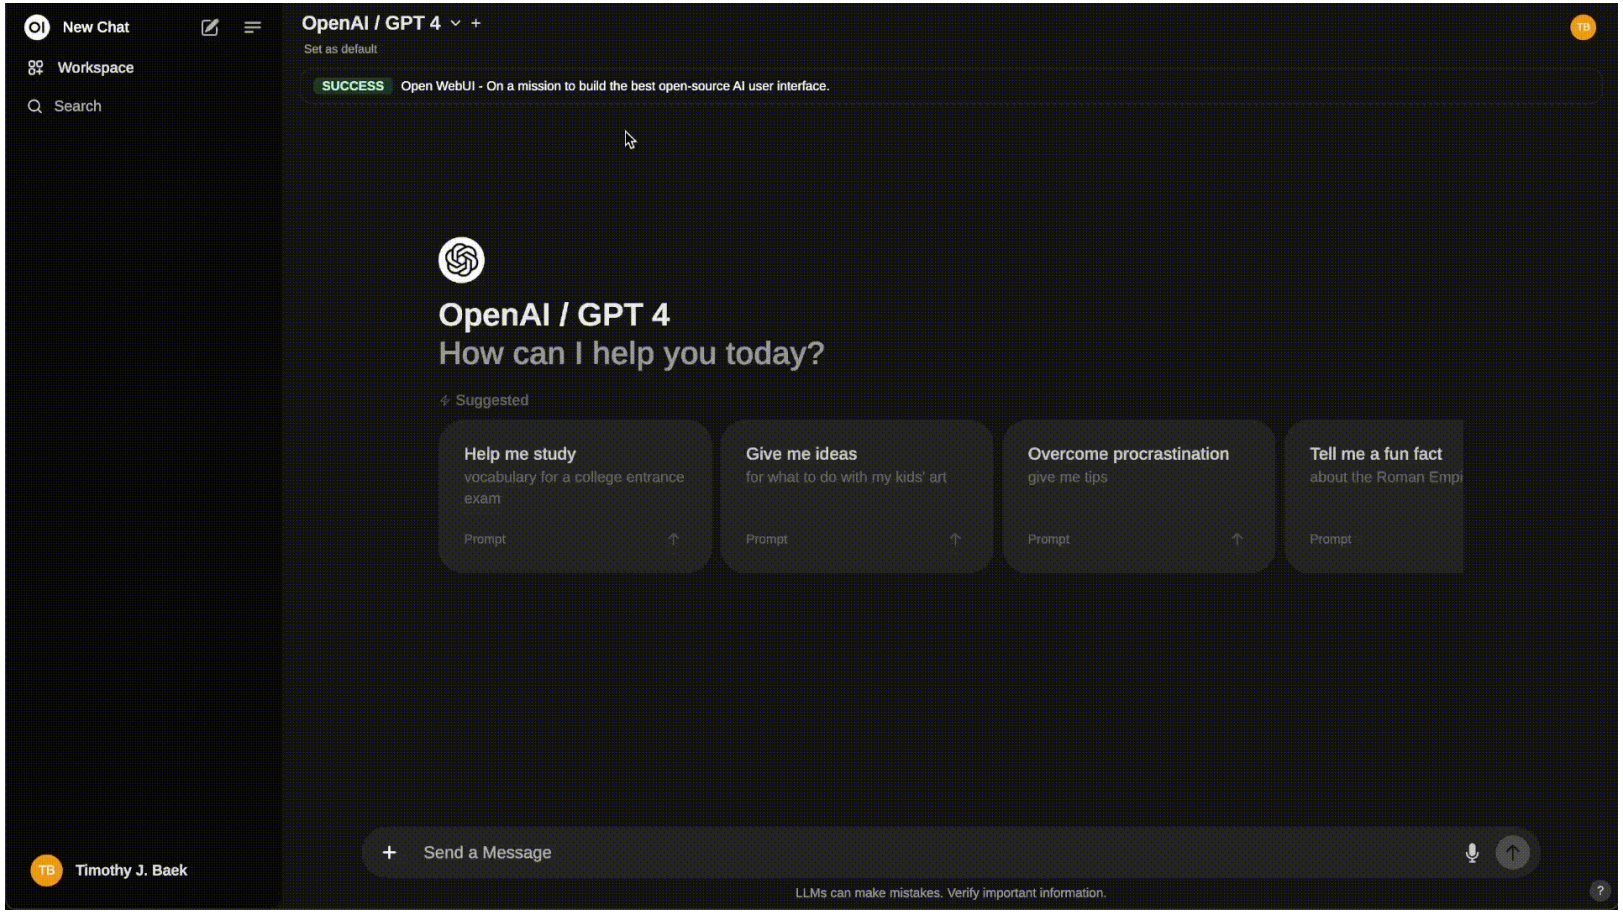

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

Quelle: https://github.com/open-webui/open-webui

Entwicklung eines Chatbots

Speech2Text

- Speech2Text
  - Deep Learning Modell, das gesprochene Sprache in Text umwandelt
  - OpenAI Whisper, Open Source, Multi-Lingual
  - “it enables transcription in multiple languages, as well as translation from those languages into English.”
  - https://openai.com/index/whisper/
  - Über Groq API Whisper Modelle nutzbar: https://console.groq.com/docs/rate-limits
  - Über OpenAI API
    - gpt-4o-mini-transcribe
    - https://platform.openai.com/docs/guides/speech-to-text
- Da Google Colab kein Zugriff auf Mikrophon hat, hier leider nicht testbar
- Weitere Infos: https://github.com/dgaida/speech2text

Entwicklung eines Chatbots

Text2Speech

- Text2Speech
  - Deep Learning Modell, das aus Text gesprochene Sprache synthetisiert

  - https://kokorotts.net/
    - Multilingual, mehrere Stimmen wählbar, https://kokorotts.net/models/Kokoro/Kokoro-ai
    - „Kokoro is an open-weight TTS model with 82 million parameters.“, Apache Lizenz, kostenlos
    - Quelle: https://github.com/hexgrad/kokoro

  - https://elevenlabs.io/de

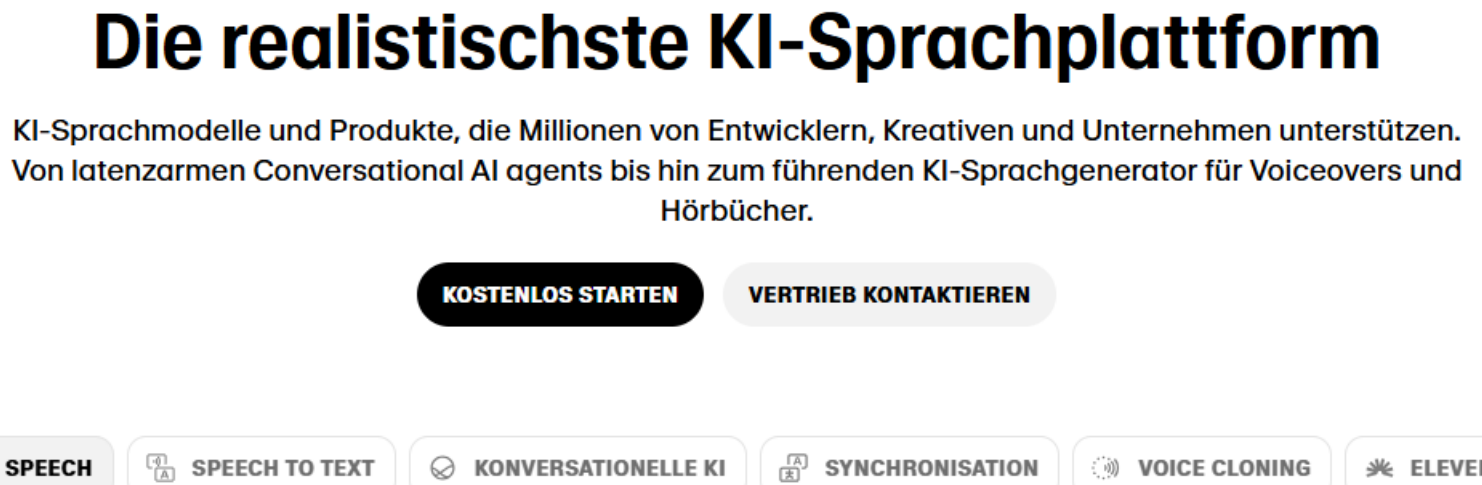

Entwicklung eines Chatbots

Text2Speech

Neues Notebook:

- RAGChatbot_groq_API_t2s.ipynb auf github.com

```
from kokoro import KPipeline
tts = KPipeline(lang_code='a‘)


def chatbot_with_tts(user_message, history, tts_enabled):
    response = utils.safe_query_engine_call(query_engine, user_message)
    if tts_enabled:
        audio_path = utils.generate_tts_audio(tts, response)
        return response, audio_path
    …
```

Entwicklung eines Chatbots

Text2Speech

- Audio (Waveform) könnte normalerweise über Python Package Sounddevice abgespielt werden
- Da Google Colab keinen Zugriff auf den Lautsprecher hat, müssen wir generiertes Audio als temporäre Audiodatei abspeichern.
- Die Audiodatei kann über Gradio App abgespielt werden.

Entwicklung eines Chatbots

Text2Speech

- Testen Sie das Notebook RAGChatbot_groq_API_t2s.ipynb

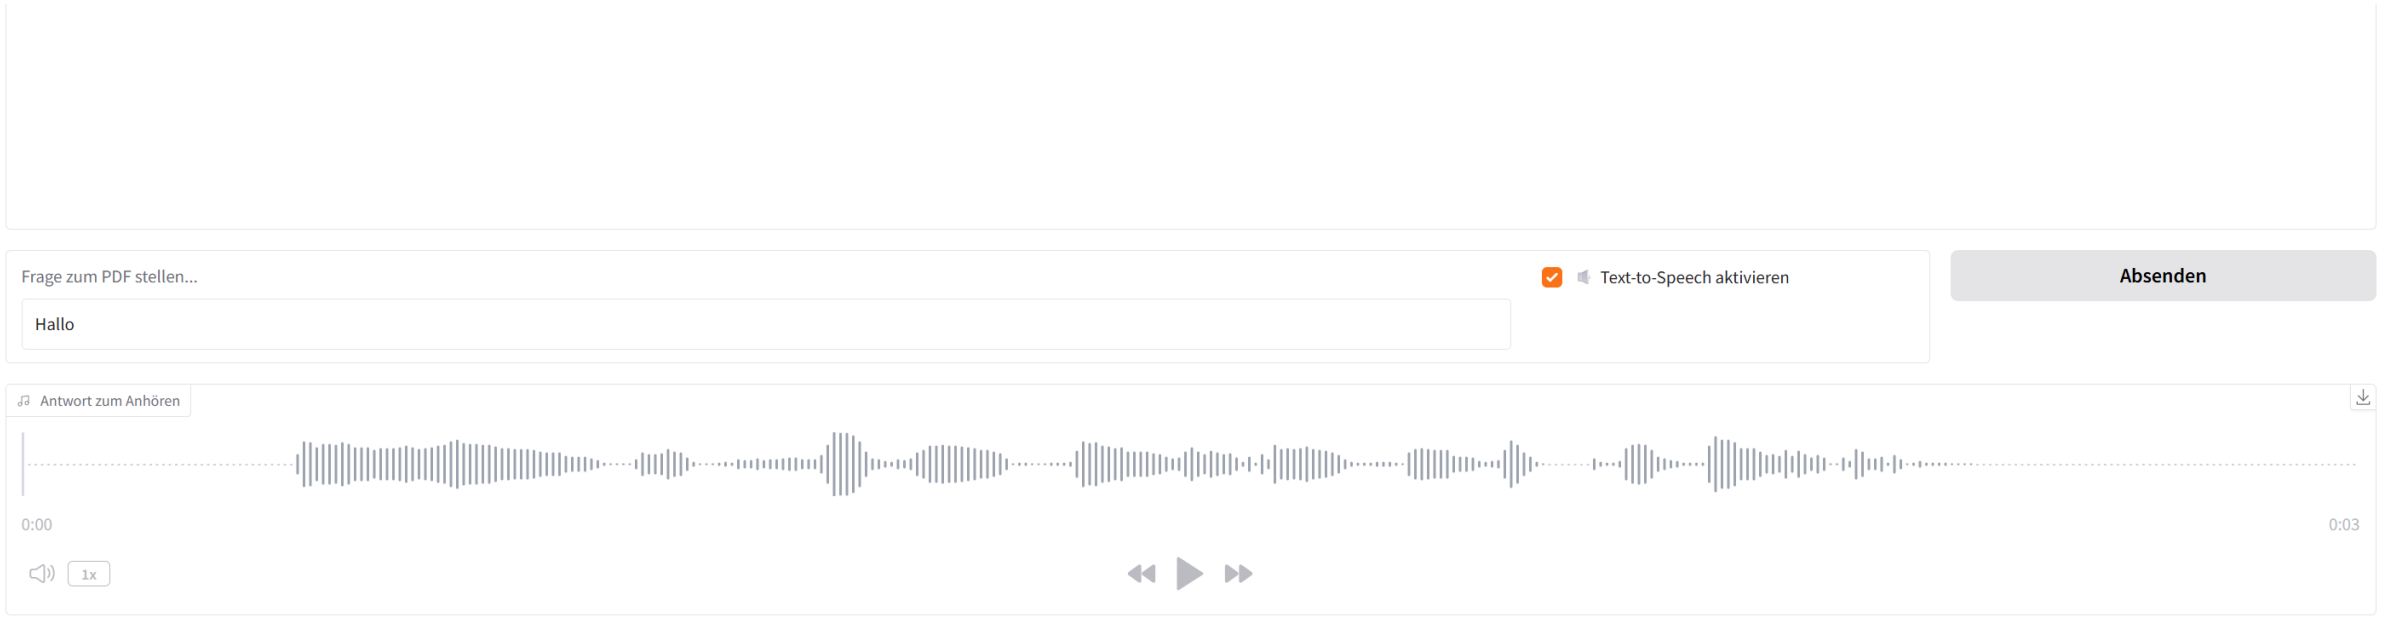

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Weitere Kurse zu RAG

- https://www.coursera.org/learn/retrieval-augmented-generation-rag
- https://www.deeplearning.ai/courses/
- https://www.deeplearning.ai/short-courses/building-agentic-rag-with-llamaindex/
- https://www.deeplearning.ai/short-courses/building-multimodal-search-and-rag/
- https://www.deeplearning.ai/short-courses/multimodal-rag-chat-with-videos/
- https://www.deeplearning.ai/short-courses/building-evaluating-advanced-rag/

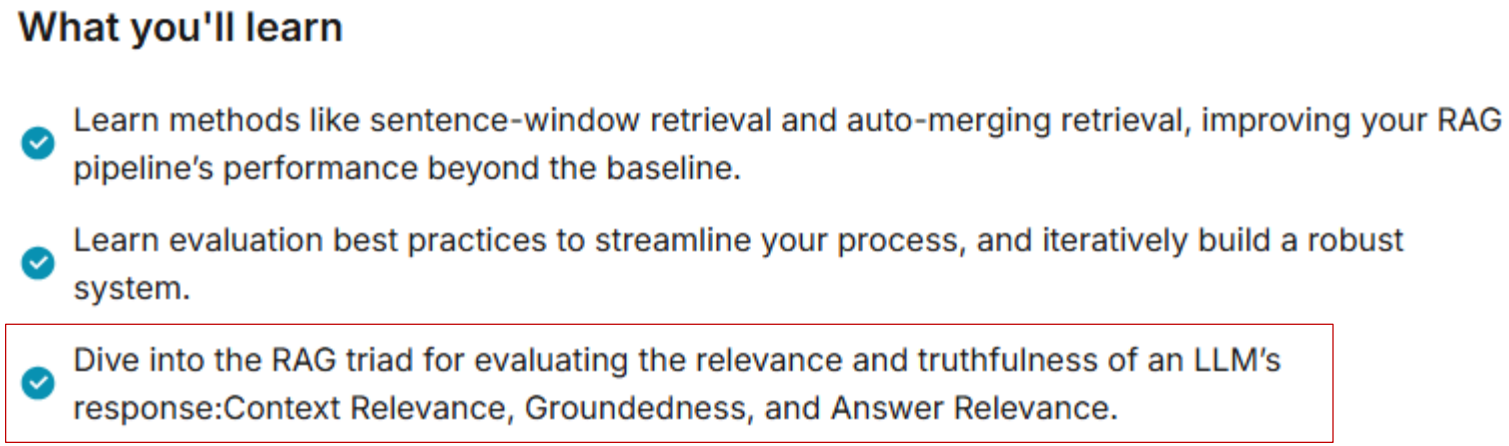

RAG Agenten Visuell programmieren

https://flowiseai.com/

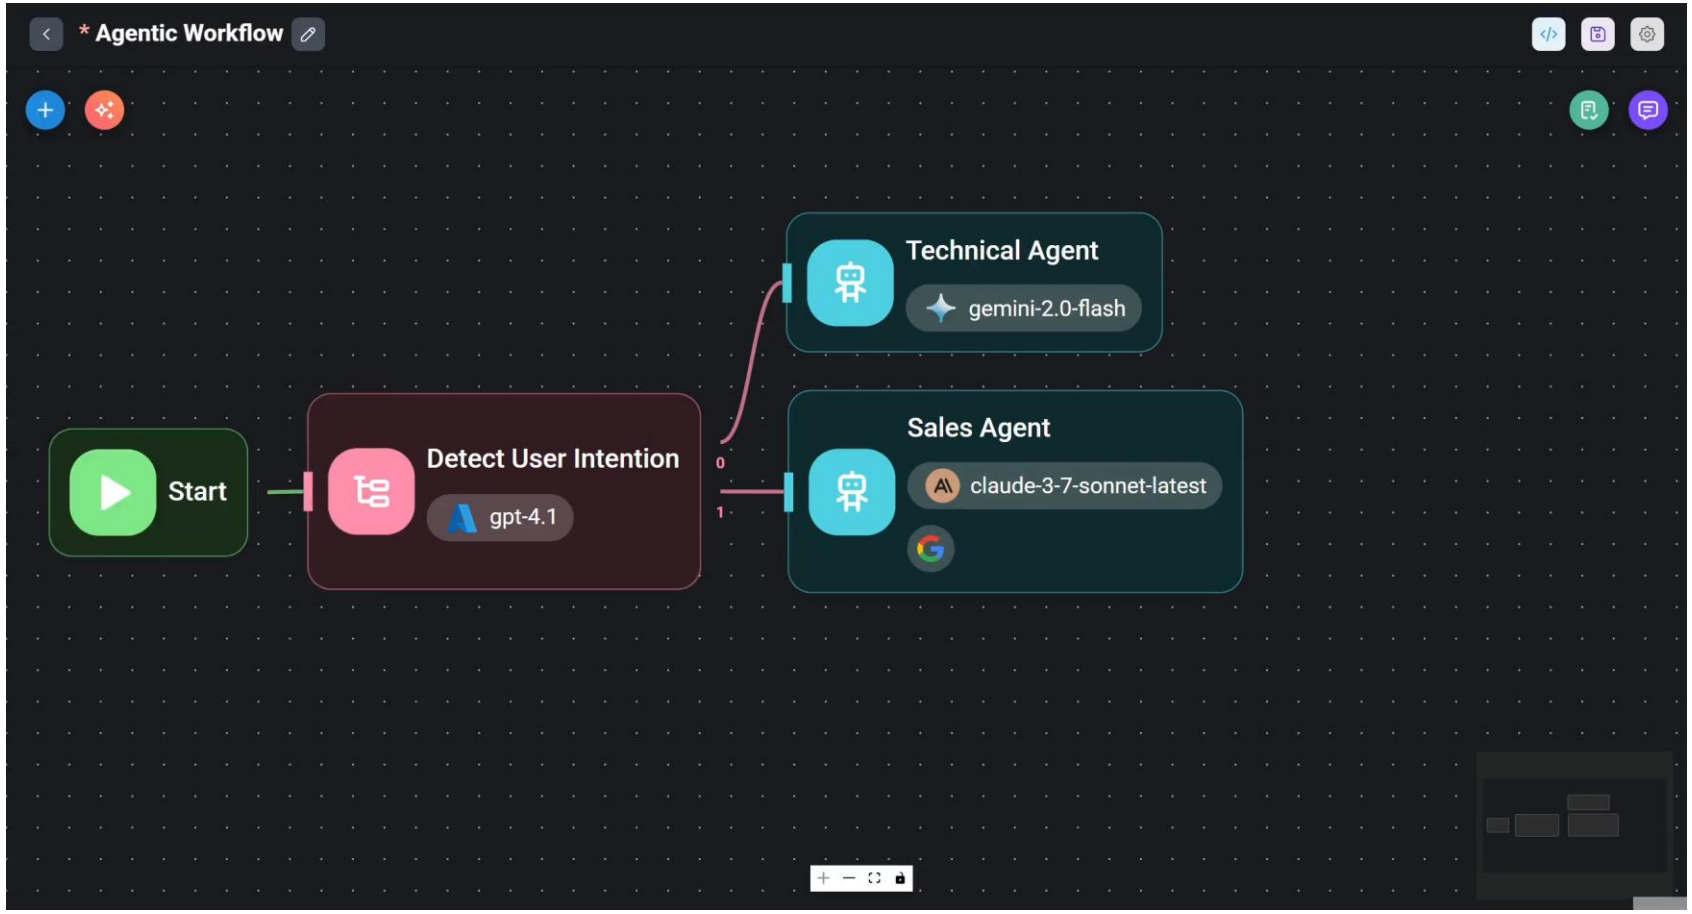

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Text2Image, Text2Video

- Text2Image
  - Bild aus Text generieren
  - Google API: https://ai.google.dev/gemini-api/docs/image-generation?hl=de
  - HuggingFace (lokale Ausführung): https://huggingface.co/models?pipeline_tag=text-to-image&sort=trending

- Text2Video
  - Video aus Bild generieren
  - Google API: https://ai.google.dev/gemini-api/docs/video?hl=de&example=dialogue
  - HuggingFace (lokal): https://huggingface.co/models?pipeline_tag=text-to-video&sort=trending

Image2Text, Video2Text

- Image2Text
  - Text aus Bild generieren (Bild interpretieren)
  - Groq API: https://console.groq.com/docs/vision
    - Bilder müssen < 30k Tokens groß sein für free plan
  - Google API: https://ai.google.dev/gemini-api/docs/image-understanding?hl=de
  - HuggingFace (lokal): https://huggingface.co/models?pipeline_tag=image-to-text&sort=trending
  - Ollama lokal/Cloud: https://docs.ollama.com/capabilities/vision#python

- Video2Text
  - Text aus Video generieren (Video interpretieren)
  - Google API: https://ai.google.dev/gemini-api/docs/video-understanding?hl=de
  - HuggingFace (lokal): bisher nicht vorhanden

Nächste Vorlesung und Fragen

- Erklärbare KI
- Fragen?

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Optionale Übung: Embedding Modell angeben und ausprobieren

- Cosine similarity liefert Werte zwischen -1 und 1 zurück (üblicherweise aber eher zwischen 0 und 1)

```python
# this cell is optional - not needed for the notebook to run
# you can play with this if you want to test how close two embedding vector are
embedding_1 = embed_model.get_text_embedding("Hello, my name is Daniel")
embedding_2 = embed_model.get_text_embedding("How are you?")

# Compute dot product similarity
similarity = sum(a * b for a, b in zip(embedding_1, embedding_2))
print(similarity)
```

```
0.8202128970159881
```

```python
# this cell is optional - not needed for the notebook to run
# you can play with this if you want to test how close two embedding vector are
embedding_1 = embed_model.get_text_embedding("Hello, my name is Daniel")
embedding_2 = embed_model.get_text_embedding("Hello, my name is not Daniel")

# Compute dot product similarity
similarity = sum(a * b for a, b in zip(embedding_1, embedding_2))
print(similarity)
```

```
0.9513346940599776
```


Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik
Technology Arts Sciences TH Köln

Optionale Übung: Embedding Modell angeben und ausprobieren

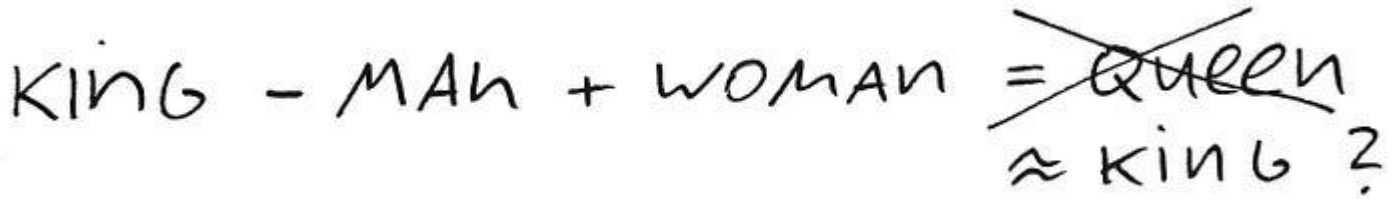


```
import numpy as np

# Convert lists to NumPy arrays before performing arithmetic
embedding_1_np = np.array(embed_model.get_text_embedding("King")) -
np.array(embed_model.get_text_embedding("Man")) +
np.array(embed_model.get_text_embedding("Woman"))
embedding_2_np = np.array(embed_model.get_text_embedding("Queen"))

# Compute dot product similarity using NumPy's dot function
similarity = np.dot(embedding_1_np, embedding_2_np)
print(similarity)
```

Optionale Übung: Embedding Modell angeben und ausprobieren

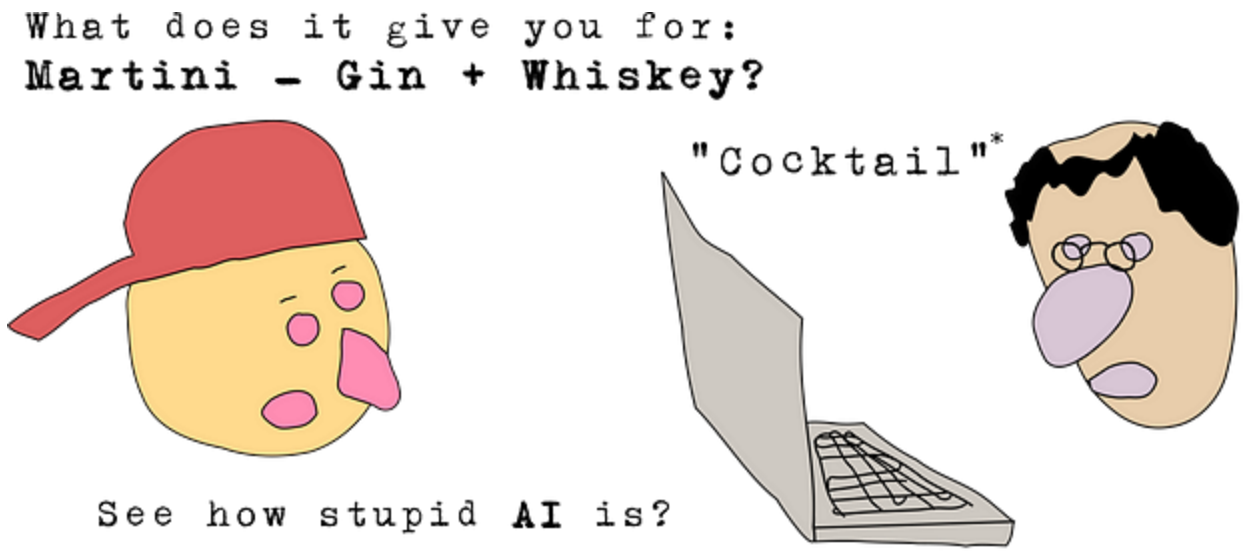

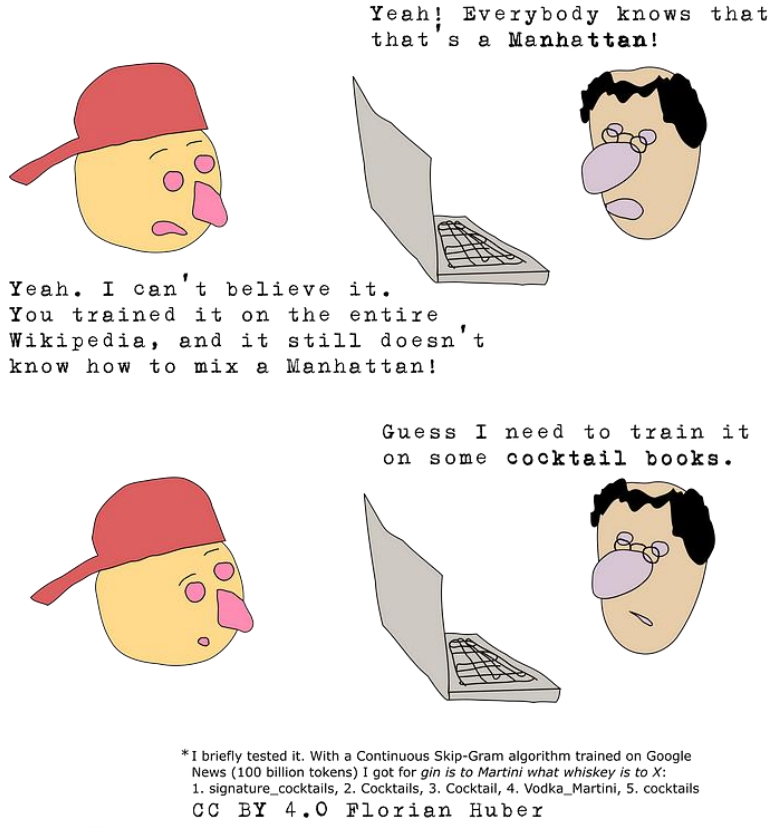

Prof. Dr. Daniel Gaida
Professor für Cyber-Physische Systeme
Fakultät für Informatik und Ingenieurwissenschaften - Institut für Informatik

https://blog.esciencecenter.nl/king-man-woman-king-9a7fd2935a85

Optionale Übung: Jupyter Notebook zur Übung

- Öffnen Sie das folgende Notebook in Google Colab:
  https://github.com/dgaida/llm_client/blob/master/notebooks/HF_EmbeddingModel_test.ipynb

- Probieren Sie das Embedding Modell aus
- Schauen Sie sich bei Bedarf https://projector.tensorflow.org/ an

Bei Bedarf:

- Schauen Sie sich die Doku zu Ihrem Embedding Modell an:
  https://huggingface.co/sentence-transformers/all-MiniLM-L6-v2

- Testen Sie weitere Embedding Modelle, bspw. für die deutsche Sprache:
  - https://huggingface.co/spaces/mteb/leaderboard