

Generative KI verstehen und sinnvoll einsetzen

Von Large Language Models bis RAG:
Grundlagen moderner GenAI-Anwendungen



**Hochschule
Bonn-Rhein-Sieg**
University of Applied Sciences



Mittelstand-Digital
**Zentrum
Fokus Mensch**

Das Webinar hat zwei Teile



Teil 1 · Heute

Generative KI verstehen

Wie KI-Anwendungen funktionieren
und was man damit bauen kann



Teil 2 · Nächstes Mal

GenAI Ops

Wie KI-Anwendungen im Live-Betrieb
zuverlässig werden



Nicolas Klein

AI Software Engineer @ Ergosign GmbH

→ Ich habe bei Ergosign KI-Produkte von der Demo in den produktiven Einsatz gebracht. Was ich dabei gelernt habe, steckt in diesem Webinar.

Ich erzähle Ihnen eine Geschichte ...

Unser Protagonist



Ein fiktives mittelständisches Wohnungsunternehmen

 **40**
Mitarbeitende

 **200+**
Immobilien

 **Die Website**
ist die wichtigste Anlaufstelle für Mietinteressenten



Das Problem



Mietinteressent, per Mail

„Welche Unterlagen brauche ich?“

zum 37. Mal diese Woche

Mietinteressentin, auf der Website

„Ich finde einfach nichts Passendes.“

und sucht beim Nächsten weiter

Mehr Arbeit fürs Team, weniger Kunden.



Dienstag, 27. Oktober

21:47

B Bitkom vor 12 Min.
Erstmals nutzt die Mehrheit der Unternehmen KI

K KfW Research vor 26 Min.
Mittelständische KI-Nutzer sind erfolgreicher

V Vonovia vor 54 Min.
Vonovia unterstützt KI-Innovation in der Immobilienwirtschaft: ...

I ImmoScout24 vor 1 Std.
Deutschlands führende Immobilienplattform kommt zu ChatGPT


t t3n vor 2 Std.
ChatGPT statt Google? So verändert KI die Suche nach Restaurants ...

Das Team fragt sich:

Und was machen wir mit KI?

Die Idee

#vermietung




Lena · Vermietung 16:42

Könnte KI nicht die ewigen
Fragen zu den Unterlagen
beantworten?

FIKTIVES BEISPIEL

Ihr erster Prototyp



FIKTIVES BEISPIEL


Die erste Demo

Das Team nach der Demo

„Er weiß einfach alles.“



Das Team ist begeistert



FIKTIVES BEISPIEL

Weil die Ergebnisse so überzeugend waren,

haben sie ihn für alle Kunden ausgerollt ...



Weil die Ergebnisse so überzeugend waren,

haben sie ihn für alle Kunden ausgerollt ...




Die Krisenmomente



WohnraumPlus ist nicht allein

Eine Studie des MIT zeigt: 95 % der GenAI-Pilotprojekte in Unternehmen haben keinen messbaren Effekt auf den Gewinn.




Was passiert zwischen Eingabe und Ausgabe?

Von außen wirkt eine KI-Anwendung erstaunlich einfach:


Eine Frage geht hinein → Eine Antwort kommt heraus

Doch was muss dazwischen alles passieren?



Was ist ein Large Language Model?

Ein Large Language Model lernt Muster aus sehr großen Textsammlungen, oft mit mehreren hundert Milliarden Wörtern oder mehr.




Was bedeutet ChatGPT eigentlich?

GPT steht für:


- **Generative:** Es erzeugt neue Inhalte auf Basis gelernter Muster.
- **Pretrained:** Es lernt diese Muster, bevor es in einer Anwendung eingesetzt wird.
- **Transformer:** Es nutzt eine Architektur neuronaler Netze, die Beziehungen zwischen den Teilen der Eingabe verarbeitet.

ChatGPT ist eine Anwendung von OpenAI und kein Modell. Das Sprachmodell dahinter lässt sich auswählen, zum Beispiel GPT-6.1-Sol.




Was bedeutet „Generative“?

Das Modell erzeugt neuen Text, indem es Wort für Wort vorhersagt, welches Wort am wahrscheinlichsten als Nächstes kommt.



Was ist ein Token?


Genau genommen arbeitet ein Sprachmodell mit Tokens. Das sind Wortstücke, und jedes bekommt eine feste Nummer. Auch die Kosten und die Textmenge, die ein Modell auf einmal lesen kann, werden in Tokens gemessen.



Was bedeutet „Pretrained“?

Ein LLM wird trainiert, bevor es eingesetzt wird. Es wird nicht nebenbei durch Nutzernachrichten neu trainiert.

- Aktuelles Wissen lässt sich über den Prompt ergänzen
- Das Grundwissen des Modells ist auf seine Trainingsdaten begrenzt
- Das Training kostet Millionen von Dollar




Was bedeutet *Transformer*?

Ein Transformer ist die Architektur neuronaler Netze hinter modernen Large Language Models.

- Er ermöglicht es Modellen, Informationen innerhalb einer Eingabe zu verknüpfen und zusammenhängende Ausgaben zu erzeugen.
- Die Architektur wurde 2017 im Paper Attention Is All You Need vorgestellt.

GPT, Llama, DeepSeek und die meisten anderen modernen LLMs bauen auf dieser Grundlage auf.




Es gibt nicht das eine LLM

Es gibt viele Möglichkeiten zur Auswahl:

- Unterschiedliche Modelle und Anbieter
- Geschlossen oder offen
- Unterschiedliche Zugangswege

Das passende Setup hängt von Aufgabe, Kosten, vorhandener Infrastruktur und Compliance ab.



Was weiß ein LLM nicht?

Neue Daten

Das Wissen endet zu einem festen Stichtag in den Trainingsdaten.

Ihre internen Daten


Modelle werden mit öffentlich verfügbaren Daten trainiert. Interne Dokumente Ihres Unternehmens gehören nicht dazu.

Live-Informationen

Live-Ticker, aktuell verfügbare Wohnungen:
Informationen, die ständig aktualisiert werden müssen, um nützlich zu sein.


Nachschlagen statt raten.

Der Assistent sucht die passende Regel von WohnraumPlus und gibt sie dem Modell mit.



Nachschlagen statt raten.

Der Assistent sucht die passende Regel von WohnraumPlus und gibt sie dem Modell mit.



Wie kann ein LLM **Ihre** Daten kennen?

Retraining

Nutzt einen strukturierten Datensatz Ihrer Daten, um das bestehende Modell mit neuen Gewichten nachzutrainieren.

sehr teuer

braucht genug Daten

Wie kann ein LLM **Ihre** Daten kennen?

In-Context-Learning

Das LLM nutzt Informationen, die direkt im Prompt bzw. Kontext stehen, um Aufgaben zu lösen, ohne Training oder Fine-Tuning

RAG (Retrieval Augmented Generation)


Passende Informationen per Suche finden, in den Kontext legen und per In-Context-Learning nutzen. So bleibt das Wissen aktuell, ohne neu zu trainieren

Prompt und System-Prompt


Ein Prompt ist der gesamte Text, den das Sprachmodell als Eingabe erhält.

- **System-Prompt:** Anweisung des Teams hinter dem Assistenten, unsichtbar für die Mieterin
- **Nutzerfrage:** Frage der Mieterin im Chat


Widersprechen sich beide, ist das Modell darauf trainiert, dem System-Prompt zu folgen.



Fachbegriff: „In-Context-Learning“



Fachbegriff: „In-Context-Learning“




Warum nicht alle Ihre Daten ins Kontextfenster legen?

Ein Kontextfenster umfasst alles, was eine KI vor ihrer Antwort berücksichtigen kann.

- Der Platz ist begrenzt.
- Anweisungen, Chatverlauf, Quellenmaterial und die Antwort selbst belegen ihn.
- Mehr Informationen können das Modell von dem ablenken, was für die aktuelle Aufgabe zählt.

Deshalb können und sollen nicht alle Informationen per In-Context-Learning eingespeist werden.



Wie kann ein LLM **Ihre** Daten kennen?


In-Context-Learning

Das LLM nutzt Informationen, die direkt im Prompt bzw. Kontext stehen, um Aufgaben zu lösen, ohne Training oder Fine-Tuning

RAG (Retrieval Augmented Generation)

Passende Informationen per Suche finden, in den Kontext legen und per In-Context-Learning nutzen. So bleibt das Wissen aktuell, ohne neu zu trainieren

Fachbegriff: „Retrieval Augmented Generation (RAG)“




Embeddings bilden Bedeutung ab

Ein Embedding stellt Text als Position auf einer Zahlenkarte dar.

- Texte mit ähnlicher Bedeutung liegen nah beieinander.
- Texte mit unterschiedlicher Bedeutung liegen weiter auseinander.
- Das Modell lernt diese Positionen aus Mustern in der Sprache.

Eine Frage zu „Hund“ kann deshalb ein Dokument über „Haustiere“ finden.




Wörter mit ähnlichem Kontext liegen nah beieinander.
Vereinfachte 2D-Ansicht. Echte Embeddings nutzen sehr viele gelernte Dimensionen.

Semantische Suche vergleicht Bedeutung

Die semantische Suche nutzt Embeddings, um Fragen mit Textabschnitten zu vergleichen.

- Jede Frage und jeder Abschnitt erhält eine Position auf derselben Karte.
- Ein kurzer Abstand bedeutet eine ähnliche Bedeutung.
- Die Wortwahl kann völlig unterschiedlich sein.

„Darf ich meinen Hund mitbringen?“ kann trotzdem „Haustiere sind mit Genehmigung erlaubt.“ finden.



Unterschiedliche Wörter können dasselbe bedeuten.
Die semantische Suche vergleicht ganze Fragen und Textabschnitte auf derselben Karte.

RAG ergänzt Unternehmenswissen

Das Modell lernt Ihre Daten nicht. Es bekommt den passenden Auszug.



RAG hängt weiterhin von der Datenqualität ab

RAG kann nur Informationen finden, die in der Wissensbasis vorhanden und nutzbar sind.

Typische Probleme bleiben:

- Veraltete Dokumente
- Widersprüchliche Dokumente
- Schlecht aufbereitete Dokumente



Was, wenn sich die Daten ständig ändern?

Wie steht es bei Arsenal gegen Bayern München?

Der Spielstand kann sich jede Sekunde ändern, veraltete Daten helfen den Nutzern nicht.

Welche Wohnungen sind aktuell verfügbar?


Diese Daten von WohnraumPlus können sich jede Minute ändern. Das LLM sollte niemals bereits vergebene Wohnungen empfehlen.

Tool Calling

Die KI erhält eine Liste von Aktionen, die sie anfordern darf.

- Jedes Tool hat einen klaren Namen und eine kurze Beschreibung, was es tut.
- Jedes Tool legt fest, welche Angaben es braucht, etwa einen Ort oder ob Haustiere erlaubt sind.
- Die KI wählt ein passendes Tool und füllt die Felder aus der Frage der Nutzer aus.

Für die KI sieht ein Tool aus wie ein kleines Formular, das sie ausfüllen muss.




Tool Calling

Tool Calling bedeutet, dass die KI eine vordefinierte Funktion anfordern kann, zum Beispiel die Suche nach verfügbaren Wohnungen.

Die Nutzerfrage:

„Welche Wohnungen
sind aktuell in Saarbrücken
verfügbar?“



```
{  
  name: "search_apartments",  
  location: "Saarbrücken",  
  pet_friendly: true  
}
```

Was, wenn die KI auch handeln kann?



FIKTIVES BEISPIEL


Was ist ein Agent?

Ein Agent ist eine Schleife. In jeder Runde fragt er sich:

Kann ich die Frage jetzt beantworten?



- Wenn ja, antwortet er und hört auf.
- Wenn nein, wählt er das Tool, das ihn weiterbringt.

Ihr System führt dieses Tool aus und das Ergebnis geht zurück in den Kontext. Dann beginnt die Schleife mit derselben Frage von vorn.



Der Unterschied ist die Schleife

Ein Agent muss nicht sofort antworten. Er kann sich ansehen, was zurückkam, und entscheiden, noch eine Runde zu drehen.



Ihre Daten sind weiterhin der wichtigste Faktor.




Was passiert zwischen Eingabe und Ausgabe?

Von außen wirkt eine KI-Anwendung erstaunlich einfach:


Eine Frage geht hinein → Eine Antwort kommt heraus

Aber was muss dazwischen alles passieren?



Die aktuelle Lösung von WohnraumPlus

Das hat WohnraumPlus tatsächlich gebaut. Jeder Teil davon kam in den letzten Folien vor.



Das Fundament steht



Was wir gelernt haben und was noch kommt

Teil 1 · Heute gelernt

Generative KI verstehen



LLM



Prompts



RAG



Agenten



Beispiel WohnraumPlus



Teil 2 · Nächstes Mal

GenAI Ops



Tracing



Prompt-Management



Evals



Guardrails



Praxisfall Fichtel-Tagesplaner



Vielen Dank!
Haben Sie Fragen?

Nicolas Klein

nicolas.klein@ergosign.de



Hochschule
Bonn-Rhein-Sieg
University of Applied Sciences



Mittelstand-Digital
Zentrum
Fokus Mensch

ERGOSIGN