

---

# Künstliche Intelligenz - Sprachmodelle

## Generiertes Wissen und Lernen aus dem eigenen Kontext

---

Dokumentation: Konversation mit OpenAI ChatGPT - 03. April 2024



**generated knowledge prompting** <> **in context learning** um diese beiden Konzepte soll es gehen.

Es soll zu diesen beiden Konzepten in *komplementärer* Eigenschaft und in *alternativer* Eigenschaft zueinander etwas gesagt werden.

Die einleitende Frage: Mein Vermuten ist, dass tiefere Einsicht diesbezüglich einer der Schlüssel zu einem gekonnteren Umgang mit Sprachmodellen ist.

Siehst du, GPT-4, das auch so?



Um die Frage zu beantworten, ob tiefere Einsichten in die Konzepte "generated knowledge prompting" und "in context learning" zu einem gekonnteren Umgang mit Sprachmodellen wie GPT-4 führen können, ist es wichtig, beide Begriffe zu verstehen und ihre Beziehung zueinander zu betrachten.

### Generated Knowledge Prompting

Generated Knowledge Prompting bezieht sich darauf, wie ein Sprachmodell durch gezielte Aufforderungen und Eingaben spezifisches Wissen generiert.

Dabei handelt es sich um eine Methode, bei der das Modell durch sorgfältig gestaltete Prompts dazu angeregt wird, relevantes und nützliches Wissen aus seinen gelernten Daten abzurufen.

Dies kann beispielsweise durch die Formulierung präziser Fragen oder Aufgaben geschehen, die das Modell zur Bereitstellung spezifischer Informationen oder zur Lösung bestimmter Probleme veranlassen.

### In-Context Learning

In-Context Learning hingegen bezieht sich auf die Fähigkeit eines Sprachmodells, aus dem Kontext einer gegebenen Eingabe zu lernen und darauf basierend eine Antwort zu generieren.

Dabei nutzt das Modell den Kontext der Eingabe, um Muster zu erkennen und daraus zu schließen, welche Informationen oder welche Art von Antwort erwartet wird.

In-Context Learning erlaubt es dem Modell, relevante Informationen aus dem Kontext zu extrahieren und darauf basierend eine kohärente und sinnvolle Antwort zu formulieren.

### Komplementäre Eigenschaften

In komplementärer Eigenschaft zueinander können Generated Knowledge Prompting und In-Context Learning zusammenwirken, um die Leistungsfähigkeit eines Sprachmodells zu maximieren:

1. **Effektivere Informationsabfrage:** Durch gezielte Prompts (Generated Knowledge Prompting) kann ein Sprachmodell angeregt werden, spezifische Informationen zu generieren.  
  
Gleichzeitig kann das Modell durch In-Context Learning den gegebenen Kontext verstehen und die Relevanz der Informationen im Zusammenhang erkennen.
2. **Verbesserte Genauigkeit:** In-Context Learning ermöglicht es dem Modell, den Kontext einer Anfrage zu verstehen, was die Genauigkeit der generierten Antworten erhöht.  
  
Durch präzise Prompts kann diese Genauigkeit weiter gesteigert werden, da das Modell gezielt auf das gefragte Wissen zugreifen kann.
3. **Flexibilität und Anpassungsfähigkeit:** Die Kombination beider Konzepte erlaubt es, flexibel auf verschiedene Arten von Anfragen zu reagieren. Während Generated Knowledge Prompting spezifische und präzise Antworten ermöglicht, sorgt In-Context Learning dafür, dass das Modell flexibel auf unterschiedliche Kontexte und Nuancen in den Eingaben reagieren kann.

### Alternative Eigenschaften

Betrachtet man die Konzepte in alternativer Eigenschaft zueinander, könnte man sie als unterschiedliche Ansätze zur Nutzung und Optimierung von Sprachmodellen betrachten:

1. **Spezifische vs. Allgemeine Anfragen:** Generated Knowledge Prompting eignet sich besonders für spezifische, klar formulierte Anfragen, während In-Context Learning besser für allgemeinere, kontextabhängige Anfragen geeignet ist.
2. **Vorbereitete vs. Spontane Nutzung:** Generated Knowledge Prompting erfordert eine sorgfältige Vorbereitung der Prompts, um spezifische Informationen zu erhalten, während In-Context Learning spontan auf den gegebenen Kontext reagieren kann, ohne dass die Prompts im Voraus so präzise formuliert sein müssen.
3. **Statische vs. Dynamische Interaktion:** Generated Knowledge Prompting basiert eher auf einer statischen Interaktion, bei der das Modell auf vorgegebene Prompts reagiert, während In-Context Learning eine dynamischere Interaktion ermöglicht, da das Modell kontinuierlich aus dem Kontext der Unterhaltung lernen und sich anpassen kann.

### Fazit

Eine tiefere Einsicht in beide Konzepte und ihr Zusammenspiel kann tatsächlich zu einem gekonnteren Umgang mit Sprachmodellen führen. Durch das Verständnis, wann und wie man Generated Knowledge Prompting und In-Context Learning am besten einsetzt, können Nutzer die Stärken beider Ansätze optimal nutzen.

Dies könnte die Effektivität und Effizienz der Interaktionen mit Sprachmodellen erheblich verbessern und zu präziseren, relevanteren und nützlicheren Ergebnissen führen.

Ja, ich sehe es auch so: Die Kenntnis und das Verständnis dieser beiden Konzepte sind Schlüssel zu einem kompetenteren und effektiveren Einsatz von Sprachmodellen



Danke zu deiner Ausführung zum In-Kontext-Lernen.

Zum Generierten-Wissen-Prompten sagst du, dass es sich darauf beziehe, wie ein Sprachmodell durch gezielte Aufforderungen und Eingaben spezifisches Wissen generiert. Ich meine, dass sich das eher darauf bezieht, durch die strukturierte Vorgabe spezifischen Wissens in der Aufforderung selbst, die Qualität der Antwort wesentlich zu erhöhen.



Danke für die Klarstellung. Dein Verständnis von Generated Knowledge Prompting (Generiertes Wissen Prompting) als Methode, bei der durch die strukturierte Vorgabe spezifischen Wissens in der Aufforderung selbst die Qualität der Antwort wesentlich erhöht wird, ist ein wichtiger Aspekt.

Lassen Sie uns dies genauer betrachten und die Konzepte im Lichte dieser Definition beleuchten.

### Generated Knowledge Prompting (Generiertes Wissen Prompting)

Deine Definition legt nahe, dass der Schlüssel zum Generated Knowledge Prompting darin liegt, dem Sprachmodell strukturierte und spezifische Informationen in der Eingabe selbst zu geben, um die Qualität und Relevanz der generierten Antwort zu verbessern.

Dies bedeutet, dass der Nutzer explizit relevantes Wissen in die Prompts integriert, was das Modell dann als Grundlage für seine Antwort verwendet.

Es ist eine Methode, bei der die Qualität der Eingabe direkt die Qualität der Ausgabe beeinflusst.

### Beispiele und Anwendung

1. **Informationsreichere Prompts:** Wenn ein Nutzer mehr Kontext und spezifische Details in einen Prompt einbaut, kann das Modell präzisere und relevantere Antworten geben. Beispielsweise:
  - o **Einfacher Prompt:** "Erkläre die Relativitätstheorie."
  - o **Generiertes Wissen Prompting:** "Erkläre die Relativitätstheorie von Albert Einstein, die 1905 veröffentlicht wurde und die Grundlagen für die moderne Physik bildet."
2. **Strukturierte Wissensvorgaben:** Durch die Einbeziehung strukturierter Informationen und spezifischer Datenpunkte kann das Modell genauer und detaillierter antworten.
  - o **Einfacher Prompt:** "Was sind die Vorteile von Solarenergie?"
  - o **Generiertes Wissen Prompting:** "Was sind die Vorteile von Solarenergie in Bezug auf Umweltfreundlichkeit, Kostenersparnis und technologische Fortschritte in den letzten fünf Jahren?"

### In-Context Learning (In-Kontext-Lernen)

In-Context Learning bleibt die Fähigkeit des Modells, aus dem Kontext der gegebenen Eingabe zu lernen und darauf basierend eine Antwort zu generieren.

Das Modell nutzt den gesamten Kontext der Eingabe, um Muster zu erkennen und relevante Informationen herauszufiltern.

## Komplementäre und Alternative Eigenschaften

### Komplementäre Eigenschaften

Wenn wir diese Konzepte als komplementär betrachten, können sie zusammenwirken, um die Leistungsfähigkeit von Sprachmodellen zu maximieren:

1. **Verbesserte Kontextverständnis durch Strukturierung:** In-Context Learning profitiert von der strukturierten und spezifischen Wissensvorgabe (Generated Knowledge Prompting), da dies den Kontext klarer und umfassender macht, was zu besseren Antworten führt.
2. **Synergie von Details und Kontext:** Während die strukturierte Wissensvorgabe spezifische Details liefert, ermöglicht In-Context Learning die Nutzung und Integration dieser Details in einer kohärenten und sinnvollen Weise.

### Alternative Eigenschaften

Betrachtet man die Konzepte als alternative Ansätze, könnten sie unterschiedlich eingesetzt werden:

1. **Nutzerfreundliche Flexibilität vs. Präzise Anleitung:** In-Context Learning bietet eine größere Flexibilität für den Nutzer, da das Modell dynamisch auf unterschiedliche Kontexte reagieren kann, während Generated Knowledge Prompting eine präzise Anleitung und Strukturierung erfordert.
2. **Spontane vs. Geplante Interaktionen:** In-Context Learning eignet sich besser für spontane Interaktionen und kontextbasierte Fragen, während Generated Knowledge Prompting für geplante und gut durchdachte Anfragen, bei denen spezifisches Wissen benötigt wird, optimal ist.

### Fazit

Eine tiefere Einsicht in beide Konzepte und ihre Anwendung kann tatsächlich zu einem gekonnteren Umgang mit Sprachmodellen führen. Während In-Context Learning es dem Modell ermöglicht, flexibel und dynamisch auf den Kontext einzugehen, erhöht Generated Knowledge Prompting die Qualität der Antworten durch die strukturierte Vorgabe spezifischen Wissens in der Aufforderung selbst.

Beide Methoden bieten unterschiedliche Stärken und können, wenn sie richtig kombiniert werden, die Effektivität und Präzision der Nutzung von Sprachmodellen wie GPT-4 erheblich verbessern.