

Wissensgraphen zur Verbesserung von LLMs in der medizinischen Fragenbeantwortung

Forschungsgruppenmodul Datenbanken und Informationssysteme

Adrien Klose; akxeq

May 13, 2024

1 Einleitung

Large Language Models (LLMs) sind in dem Bereich des **KI** **maschinellen Lernens** eine junge Technologie, die ihren Ursprung in dem Aufmerksamkeitsmechanismus und der Transformer-Architektur hat. Seit der Veröffentlichung des ersten **LLM** BERT im Jahr 2018 von Google wurden zahlreiche weitere und leistungsstärkere LLMs von verschiedensten Organisationen wie GPT von OpenAI, LLaMA von Meta und **BLOOM**. Für Natural Language Processing (NLP) Aufgaben wie automatisches Übersetzen, automatische Textzusammenfassung und Question Answering haben sich LLMs als eine erfolgreiche Technik erwiesen, die aus kaum einem State-of-the-art (SOTA) Ansatz wegzudenken sind. LLMs und ihre Fähigkeiten sind seit der Veröffentlichung von ChatGPT nicht nur für die Wissenschaft und Unternehmen zugänglich, sondern auch für die breite Bevölkerung. ChatGPT mit seiner einfachen und kostenfreien Webschnittstelle erlaubt es die Möglichkeiten von LLMs für alltägliche Aufgaben zu verwenden. Insbesondere für die Beantwortung von Fragen als Alternative zur eigenen Recherche in verschiedenen Medien hat sich ChatGPT als ein Alltagshelfer herausgestellt. Die gestellten Fragen reichen von Übersetzungsanfragen über Textgenerationsanfragen bis hin zu Fragen über medizinische Probleme. Obwohl ChatGPT in der Regel korrekte und zufriedenstellende Antworten liefert, kommt es auch zu faktisch inkorrekten Antworten, welche ohne weitere Recherchen und Wissen über die korrekte Antwort meist nicht von diesen zu unterscheiden ist. Dieses Problem von inkorrekten Antworten die von Laien nicht erkannt werden können, ist insbesondere bei der Beantwortung von medizinischen Fragen ein großes Risiko. Eine inkorrekte Antwort auf eine medizinische Frage führt dazu, dass der Patient einem nicht einschätzbarem Risiko ausgesetzt ist. Damit LLMs mittels Chat-Bots wie ChatGPT besser in der medizinischen Fragenbeantwortung eingesetzt werden können, müssen LLMs um domainspezifische Techniken für komplexe medizinische Fachbegriffe in ihrem jeweiligen Kontext und faktisches Wissen ergänzt werden. Die Möglichkeiten Wissen in LLMs zu inkludieren unterscheiden sich dabei stark, ob das LLM als eine Blackbox oder Whitebox zu betrachten ist. LLMs als Whitebox erlauben es nicht nur Änderungen an der Architektur vorzunehmen sondern auch den Trainingsprozess auf die spezifische Domäne auszurichten. Diese Anpassungen bedeuten jedoch einen komplett neuen Trainingsprozess, der mit erheblichen Kosten verbunden ist. LLMs als Blackbox benötigen keinen extra Trainingsprozess aber sind in den **Möglichkeiten** eingeschränkter. **Wissen** und Kontext kann dem LLM nur mittels Manipulation der Prompts und **des?** gegeben werden. Für die medizinische Fragenbeantwortung mittels Chat-Bots müssen aus den natürlich sprachlichen Anfragen die relevanten Entitäten extrahiert, mehrdeutige Terme aufgelöst, relevante kontextuelle Informationen identifiziert und diese dann geeignet dem Prompt hinzugefügt werden. Wissensgraphen als Modelle enkodieren domänenspezifisches Wissen über Entitäten und vordefinierte Relationen die zwischen Entitäten existieren. Im medizinischen Bereich existieren bereits eine Vielzahl an unterschiedlichen Wissensgraphen in unterschiedlichen Formaten, jedoch müssen diese für den Einsatz vereinheitlicht und zusammengeführt werden.

In dieser Vorarbeit führen wir verschiedene medizinische Wissensgraphen zusammen, um eine einheitliche Wissensgrundlage zu bilden. Diesen benutzen wir dann zusammen

Before, BERT was cal
BLOOM from who?

ChatGPT doesn't provid

zu schwammig - welche r

mit den gegebenen Tripeln des BioASQ-Task, um die Genauigkeit auf Ja-Nein Fragen gegenüber dem naiven ChatGPT Ansatz zu verbessern. Zusätzlich reproduzieren wir mit dem Graph of Thoughts (GoT) ein fortgeschritteneres Prompting-Verfahren, welches wir in unserer zukünftigen Arbeit verwenden wollen. Nachfolgend gehen wir genauer auf die einzelnen Schritte und damit verbundenen Probleme sowie bekannten Lösungsansätze ein, um Wissensgraphen zusammen mit LLMs zu verwenden. Anschließend geben wir einen Überblick über existierende medizinische Wissensgraphen, präsentieren unseren zusammengeführten Wissensgraphen und gehen auf unsere Experimente ein. Zum Schluss geben wir einen Ausblick auf unsere zukünftige Arbeit, für welche diese die Grundlage ist.

2 Verwandte Literatur

- again short description of the different steps for QA using LLMs and fields of expertise involved
- entity recognition
 - extracting questions from natural language questions
 - resolving ambiguous terms
 - ggf. specific features of medical entities
- knowledge graphs
 - creation, maintenance, merging of knowledge graphs and problems involved in those steps
 - extracting/creating knowledge graphs from LLMs
 - knowledge injection into LLMs
 - * direct text injection (problem of creating good representation of KG information), domain specific pre training/problem of closed source for this and other strategies
 - compound relationships/amount and depth of information to include
- LLMs
 - training process of LLM
 - prompting process of LLM, creating good prompts and prompt "frames"
 - Basic IO, Chain of Thought, multiple Chain of Thoughts, Tree of Thoughts, Graph of Thoughts
 - evaluation metrics for question answering using LLMs
 - problem of creating good test data (not to be already included in training process of LLM)
- description of existing knowledge graphs/data (umls, obo foundry, wikidata, bioasq)

3 Experiment

- Bioasq
 - QA Task description
 - problems with existing triples, how we decided which triples to use
 - test different triple configurations/prompting strategies
- reproducing the GoT results with the given examples

4 Evaluation

5 Zusammenfassung