

Chatbot-basierte Interaktion mit Ontologien: Nutzung von Large Language Models und domänenspezifischen Standards

Milapji Singh Gill, Jonathan Reif, Tom Jeleniewski, Felix Gehlhoff
Institut für Automatisierungstechnik
Helmut-Schmidt-Universität/Universität der Bundeswehr Hamburg
Hamburg, Deutschland
{milapji.gill, jonathan.reif, tom.jeleniewski, felix.gehlhoff}@hsu-hh.de

Alexander Fay
Lehrstuhl für Automatisierungstechnik
Ruhr-Universität Bochum
Bochum, Deutschland
alexander.fay@rub.de

Zusammenfassung—Im vorliegenden Beitrag wird ein Konzept vorgestellt, das Large Language Models (LLMs) und eine Chatbot-Benutzeroberfläche nutzt, um eine intuitive Interaktion zwischen Anwendern und Ontologien zu ermöglichen. Eingaben in natürlicher Sprache werden dabei in SPARQL-Abfragen umgewandelt, um das Faktenwissen der Ontologie abzufragen und das Risiko von Fehlinformationen zu minimieren. Zur Steigerung der Ergebnisqualität wird die Ontologie mithilfe von etablierten, domänenspezifischen Standards um zusätzliche Kontextinformationen zu modellierten Klassen und Relationen erweitert. Eine experimentelle Untersuchung wurde durchgeführt, um die Genauigkeit der mittels LLMs generierten SPARQL-Abfragen zu ermitteln. Die vorläufigen Ergebnisse zeigen den Mehrwert des Konzepts für die Ontologieabfrage.

Index Terms—Semantic Web, Ontologien, Large Language Model, Cyber-physische Systeme, Industrie 4.0

I. EINFÜHRUNG

Ontologien können im Kontext der Industrie 4.0 und insbesondere bei dynamisch vernetzten *Cyber-physischen Systemen* (CPS) helfen, die stetig steigende Komplexität zu bewältigen. Einerseits sind sie geeignete formale Beschreibungsmittel, um die Datenintegration zu erleichtern. Andererseits wird durch die Etablierung einer eindeutigen Semantik die Interoperabilität zwischen CPS ermöglicht [1]. Diese Eigenschaften sind insbesondere mit Blick auf industrielle Anwendungen von großem Nutzen, da notwendige Daten meist aus diversen heterogenen Quellen stammen, jedoch für verschiedenste Anwendungsgebiete der Industrie 4.0 miteinander verknüpft werden müssen. Darüber hinaus sind Ontologien auch bei der Entwicklung, dem Betrieb und der Instandhaltung von CPS von großer Relevanz. Ihr Einsatz in Assistenzsystemen als Mittel zur Formalisierung von Domänenwissen bildet die Grundlage für eine verbesserte Entscheidungsfindung [2, 3, 4].

Diesen großen Vorteilen stehen jedoch ebenso Herausforderungen gegenüber. Aufgrund ihrer inhärenten Komplexität sind Ontologien schwer verständlich und für den Anwender nicht einfach zu handhaben [5]. Traditionell erfolgt die Wissensabfrage auf Basis vordefinierter *Competency Questions* (CQs) und statischer *SPARQL Protocol and RDF Query Language* (SPARQL)-Abfragen [1], die für Anwender ohne Se-

mantic Web-Expertise weder intuitiv noch benutzerfreundlich sind. Diese Problematik wird durch die geringe Anzahl an Ontologie-Experten im industriellen Umfeld verstärkt [1]. Diese Umstände führen dazu, dass die Flexibilität und Effizienz der Wissensabfrage erheblich eingeschränkt werden.

In diesem Zusammenhang kann die Interaktion zwischen einer domänenspezifischen Ontologie und einem Anwender durch den Einsatz von Chatbots und *Large Language Models* (LLMs) deutlich verbessert werden [5, 6]. Derzeit gewinnen auf LLMs basierende Assistenzsysteme, angetrieben durch die neuesten Errungenschaften in der aktuellen Forschung, in verschiedensten Domänen an Bedeutung. Die ausschließliche Abhängigkeit von auf LLMs basierenden Ansätzen birgt allerdings erhebliche Risiken. Aufgrund der fehlenden Nachvollziehbarkeit von generierten Antworten und der kreativen Interpretationsfähigkeiten sowie Halluzinationen dieser Modelle kann die Glaubwürdigkeit der wahrscheinlichkeitsbasierten Antworten nicht sichergestellt werden. Folglich könnten falsche Informationen an den Nutzer übermittelt werden. Dies stellt insbesondere in industriellen Anwendungen, bei denen Falschinformationen bzw. halluzinierte Informationen erhebliche wirtschaftliche und sicherheitstechnische Folgen haben könnten, eine außerordentliche Bedrohung dar.

Insofern bietet es sich an, die Vorteile von Ontologien, insbesondere die formale, strukturierte Bereitstellung von Faktenwissen, mit denen von LLMs, die eine intuitive Anwenderschnittstelle ermöglichen, zu kombinieren. Im Folgenden wird ein Konzept vorgeschlagen, das den Prozess der automatisierten SPARQL-Abfragegenerierung durch die Nutzung von LLMs und Informationen aus domänenspezifischen Standards verbessern soll. Dieses Konzept zielt darauf ab, die Benutzerfreundlichkeit durch Bereitstellung einer intuitiven Benutzeroberfläche für die Interaktion mit komplexen Ontologien zu erhöhen.

Der Aufbau des Beitrags gestaltet sich wie folgt: In Abschnitt II werden die Anforderungen an das vorgeschlagene Konzept eingeführt und anschließend der Stand der Wissenschaft analysiert. Abschnitt III erläutert das Konzept für die Chatbot-basierte Interaktion mit Ontologien. Vorläufige

Ergebnisse aus einer ersten experimentellen Studie werden in Abschnitt IV präsentiert. Abschließend fasst Abschnitt V den vorliegenden Beitrag zusammen und skizziert die Handlungsfelder für zukünftige Forschung.

II. ANFORDERUNGEN UND STAND DER WISSENSCHAFT

A. Anforderungen

A1: Intuitive Interaktion zwischen dem Anwender und der individuell erstellten Ontologie

Die Nutzung von Ontologien stellt für Nicht-Experten eine erhebliche Herausforderung dar. Grundsätzlich sollten Anwender in der Lage sein, Abfragen in ihren eigenen Worten zu formulieren, anstatt spezifische Fachbegriffe oder Codes verwenden zu müssen [7]. Eine wichtige Anforderung ist daher, die Hürden zur Nutzung zu senken, indem Anwender bei der Kommunikation mit der Ontologie unterstützt werden. Dies beinhaltet die Entwicklung einer benutzerfreundlichen und intuitiven Oberfläche, die es ermöglicht, auf natürliche und unkomplizierte Weise mit der Ontologie zu interagieren.

A2: Flexible Abfragen an die Ontologie basierend auf den aktuellen Informationsbedürfnissen des Anwenders

Die Möglichkeit, flexibel Abfragen an die Wissensbasis zu stellen, trägt ebenfalls zur Steigerung der Benutzerfreundlichkeit des Assistenzsystems bei. Diese Abfragen sollten an die aktuellen Informationsbedürfnisse des Anwenders angepasst werden können. Diese Flexibilität sorgt dafür, dass der Anwender die relevantesten und nützlichsten Informationen aus der Ontologie abfragen kann [8].

A3: Genauigkeit und Nachvollziehbarkeit von Antworten

Die Genauigkeit der bereitgestellten Informationen ist die notwendige Voraussetzung, damit ein Assistenzsystem vom Anwender als hilfreich empfunden wird [9]. Darüber hinaus muss der Anwender die bereitgestellten Informationen auch nachvollziehen können, damit er diesen traut. Daher ist die dritte Anforderung, die Genauigkeit und Nachvollziehbarkeit der vom Assistenzsystem bereitgestellten Antworten zu gewährleisten. Diese Anforderung gewinnt besonders im industriellen Umfeld an Relevanz, da ungenaue Informationen kostspielige Fehler, Ineffizienzen und sogar Sicherheitsrisiken zur Folge haben können.

B. Stand der Wissenschaft

Chen et al. [10] präsentieren ein Framework für das semantische Embedding von *Web Ontology Language* (OWL)-Ontologien. Dieses Framework nutzt eine Kombination aus Random Walks und Word-Embedding-Techniken, um die Semantik von Ontologien zu kodieren, indem deren Graphenstruktur sowie die lexikalischen Informationen und logischen Konstrukte berücksichtigt werden. Die Ergebnisse deuten auf eine hohe Genauigkeit der Antworten hin. Allerdings ist aufgrund der alleinigen Generierung von Antworten durch ein LLM die Nachvollziehbarkeit der generierten Antworten nicht sichergestellt.

Chen et al. [5] stellen ein System vor, das darauf ausgelegt ist, SPARQL-Abfragen für sogenannte Frage-Antwort-Systeme effizient zu generieren. Das Hauptziel des Systems ist

es, die Kosten für Abfragen zu reduzieren. Gleichzeitig wird eine hohe Genauigkeit bei der Generierung von SPARQL-Abfragen beibehalten, die zum Abrufen von Antworten aus Datenbanken verwendet werden. Der Ansatz verwendet ein *Recurrent Neural Network* (RNN), um SPARQL-Abfragen aus gelernten und gelabelten Schlüsselwörtern zu generieren. Darauf aufbauend beschreiben Chen et al. [11] die Verbesserung von Frage-Antwort-Systemen durch fortgeschrittene *Natural Language Processing* (NLP)-Techniken und Multi-Label-Klassifikation, ebenfalls unter Verwendung von RNN. Sie heben den Einsatz von NLP hervor, um Anwenderanfragen in natürlicher Sprache zu interpretieren und zu verarbeiten. Dabei werden die Anfragen in ein Format umgewandelt, das effektiv zur Generierung von SPARQL-Abfragen genutzt werden kann. Dies umfasst den Einsatz von Technologien wie Tokenization, Lemmatization und Part-of-Speech-Tagging, um die semantische Struktur der Abfragen zu verstehen. Obwohl beide Arbeiten ebenfalls die Idee verfolgen, Anwenderfragen in SPARQL-Abfragen zu übersetzen, verzichten sie auf den Einsatz von LLMs [5, 11].

Avila et al. [6] führten Experimente durch, um die Fähigkeit von *ChatGPT* (GPT-3.5) zu bewerten, Fragen in natürlicher Sprache in Bereichen wie Familie und Beruf mithilfe von Wissensgraphen zu beantworten. Verschiedene Setups wurden getestet, darunter die direkte Beantwortung von Fragen sowie die Text-zu-SPARQL-Übersetzung unter Verwendung der terminologischen Box (T-Box), der assertionalen Box (A-Box) oder beider Komponenten. Die Ergebnisse zeigten, dass der Text-zu-SPARQL-Ansatz unter Nutzung sowohl der T-Box als auch der A-Box die beste Leistung erbrachte. Weiterhin präsentieren Avila et al. [6] ein Framework, das darauf ausgelegt ist, die Übersetzung von Fragen in natürlicher Sprache in SPARQL-Abfragen zu optimieren. Dieses Framework setzt sich aus zwei Phasen zusammen: In der Offline-Phase werden Indizes generiert, welche Begriffe aus der T- und A-Box ihren *Uniform Resource Identifiers* (URIs) zuordnen. In der Online-Phase werden diese Indizes genutzt, um die Fragen in natürlicher Sprache in SPARQL-Abfragen zu übersetzen und Antworten zu generieren. Durch die Reduzierung der Anzahl der verarbeiteten Tokens verringert das Framework die Wahrscheinlichkeit von Halluzinationen und verbessert die Unterstützung für große Wissensgraphen. Allerdings wurden die Auswirkungen der Bereitstellung von Graphenerklärungen für das LLM sowie das Komplexitätsniveau, auf dem das LLM zuverlässig SPARQL-Abfragen erzeugen kann, nicht untersucht.

III. KONZEPT FÜR DIE CHATBOT-BASIERTE INTERAKTION MIT ONTOLOGIEN

Im Folgenden wird ein Konzept vorgestellt, das eine auf Chatbots basierende Benutzeroberfläche für die Interaktion mit Ontologien nutzt und flexible Abfragemöglichkeiten realisiert. Wie in Abschnitt II erwähnt, verwenden einige der verwandten Arbeiten LLMs direkt für die Wissensabfrage. Dies ist jedoch, wie in Abschnitt I erläutert, mit erheblichen Risiken verbunden, insbesondere im industriellen Umfeld. Daher dient

in unserem Konzept die Ontologie mitsamt SPARQL-basierter Abfragen als primäre Wissensquelle. Um Fachexperten mit begrenzten Kenntnissen beim Umgang mit Semantic-Web-Technologien zu unterstützen, werden in diesem Ansatz LLMs verwendet, um SPARQL-Abfragen aus Fragen, die in natürlicher Sprache formuliert worden sind, zu generieren. Abbildung 1 veranschaulicht das Konzept zur Abfrage der Ontologie.

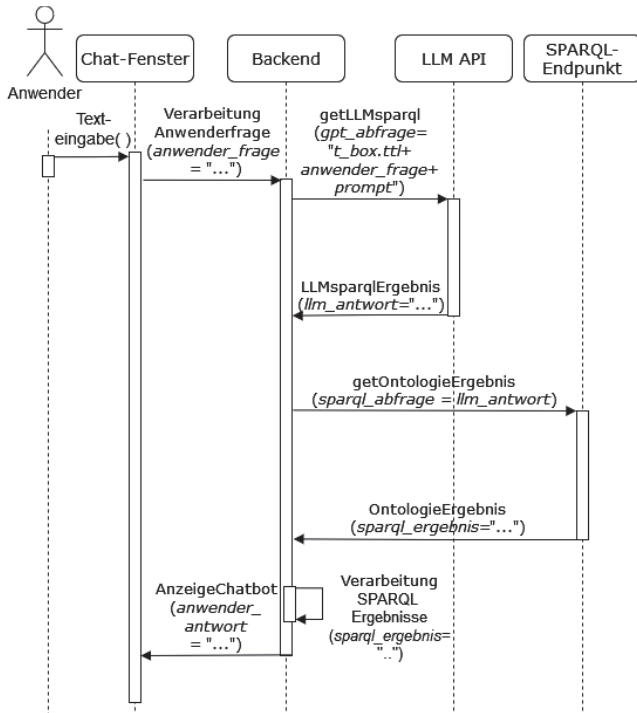


Abbildung 1: Konzept für die Chatbot-basierte Interaktion mit Ontologien [12]

Der Ablauf stellt sich wie folgt dar: Anwender interagieren über ein Chat-Fenster mit der Ontologie, indem sie Fragen in natürlicher Sprache stellen, die im Backend verarbeitet werden. Diese Abfragen werden über ein *Application Programming Interface* (API) an das LLM gesendet, wobei vordefinierte Prompts um das Schema der T-Box ergänzt werden. Durch die Einbeziehung der T-Box in die Prompts wird das explizite A-Box-Wissen von dem LLM separiert und ist nur über die SPARQL-Abfragen zugänglich. Dieser Ansatz stellt sicher, dass sensible Informationen des Unternehmens geschützt bleiben, da die Anwenderfragen nicht unmittelbar vom LLM beantwortet werden. Stattdessen verwendet das Modell die vordefinierten Prompts, um Fragen in SPARQL-Abfragen umzuwandeln. Diese Abfragen werden dann an das Backend zurückgegeben und schließlich dem SPARQL-Endpunkt übergeben, um die Instanzdaten der A-Box abzufragen. Die Ergebnisse werden im Backend verarbeitet und über die Benutzeroberfläche angezeigt. Dieser Ansatz gewährleistet, dass das LLM keine inkorrekten oder erfundenen Antworten produziert, da nur Faktenwissen abgerufen wird, welches in

der Ontologie hinterlegt ist. Allerdings sind die verifizierbaren Antworten nicht vollständig validiert. Generierte Abfragen können weiterhin fehlerhaft sein, was zu Antworten führt, die nicht der ursprünglichen Frage entsprechen. In manchen Fällen werden überhaupt keine Antworten zurückgegeben.

Da potenzielle Anwender oftmals nicht mit der Terminologie der Ontologie vertraut sind, ist es wichtig, sie bei der Formulierung der Fragen über das Chat-Fenster zu unterstützen. Besondere Aufmerksamkeit sollte den folgenden Aspekten gewidmet werden, um eine effektive Anwenderinteraktion zu gewährleisten:

1) *Prompts*: Da weder der Anwender noch das LLM über die T-Box der Ontologie informiert sind, gilt es zusätzliches Kontextwissen zu den chatbasierten Fragen in Form von Prompts zu ergänzen. Diese Prompts müssen die T-Box einschließlich ihrer Klassen, Eigenschaften und Beziehungen beinhalten. Durch die Integration ausführlicher Beschreibungen der Ontologie in die Prompts kann das LLM die Anwenderfragen besser interpretieren und sie in präzise SPARQL-Abfragen umwandeln. Diese Prompts, einschließlich der T-Box, dienen als Leitfaden für die Übersetzung domänenspezifischen Wissens in ausführbare SPARQL-Abfragen. Sie stellen sicher, dass das LLM den notwendigen Kontext und die Spezifikationen für eine genaue Formulierung der SPARQL-Abfragen erfasst.

2) *Erstellen von Ontology Design Patterns*: Die Erstellung von Ontologien ist mit großem Modellierungsaufwand verbunden. Eine modulare und auf Standards basierende Ontologie kann diesen Aufwand langfristig durch die Möglichkeit der Wiederverwendung entwickelter ontologischer Artefakte reduzieren. Vor diesem Hintergrund beschreiben Hildebrandt et al. [1] einen systematischen methodischen Ansatz zur Entwicklung von Ontologien, aufbauend auf modularen *Ontology Design Patterns* (ODPs), die auf etablierte Terminologien aus Standards zurückgreifen. Wenn diese angepassten ODPs, die einer T-Box für den Problemkontext ähneln, zu den chatbasierten Fragen ergänzt werden, kann das LLM die Strukturen und Terminologien untersuchen, um die Anfrage präzise in SPARQL gemäß den ODPs zu übersetzen.

Die Erweiterung von ODPs mit `rdfs:comments` Annotationen ist für das beschriebene Konzept entscheidend, da hierdurch zusätzlicher Kontext über die Klassen, Objekt- und Dateneigenschaften mitgeliefert werden kann. Diese zusätzliche Kontextebene hilft dem LLM, Begriffe, die mehrdeutig sein könnten oder aufgrund ihrer wörtlichen Bedeutung mehrere Interpretationen zulassen, einzuordnen. Durch die Nutzung von `rdfs:comment` gewinnt das LLM tiefere Einblicke in die Semantik der modellierten Konzepte, wodurch seine Fähigkeit verbessert wird, Anwenderfragen präzise in SPARQL-Abfragen umzuwandeln. Diese Strategie stellt sicher, dass die generierten Abfragen enger mit der zugrundeliegenden Ontologie übereinstimmen, Fehlinterpretationen minimiert werden und die Zuverlässigkeit der SPARQL-Abfragen erhöht wird.

IV. VORLÄUFIGE ERGEBNISSE

Zur Untersuchung des vorgestellten Konzepts wurde eine experimentelle Studie durchgeführt, um die Fähigkeit von

LLMs zur SPARQL-Abfragengenerierung zu überprüfen. Es wurde *ChatGPT-4o* verwendet, um SPARQL-Abfragen für verschiedene ODPs zu erstellen. Dabei kamen Prompts zum Einsatz, die spezifische ODP-Informationen in Klartext und eine entsprechende Frage enthielten, die die Abfrage beantworten sollten.

Die in der Studie verwendeten ODPs waren die VDI 3682 (*Formalisierte Prozessbeschreibung*) [13], die DIN EN 61360 (*Datenbank für elektrische Bauteile*) [14] und die VDI 2206 (*Entwicklung mechatronischer und cyber-physischer Systeme*) [15]. Die Fragen wurden in zwei unterschiedlichen Stilen formuliert, um den Einfluss der Formulierung auf die Qualität der Abfrage zu bewerten. Zum einen wurden *standardkonforme Fragen* (SKF) gestellt, die sicherstellten, dass die Terminologie den etablierten Standards entsprach. Zum anderen wurden *nicht-standardkonforme Fragen* (NSKF) formuliert, die eine allgemeinere Terminologie einbezogen, wie sie typischerweise von Nicht-Experten verwendet wird.

Zusätzlich wurden diese Fragen unter Verwendung der ODPs sowohl mit als auch ohne Annotationen mithilfe von `rdfs:comment` gestellt, um zu ermitteln, ob solche Kommentare die Qualität der Abfragen verbessern.

Tabelle I: Untersuchte Fragekategorien gemäß [16]¹

Category	SKF Beispiel	ODP
Boolean	<i>Ist der Sensor Teil eines Moduls im System?</i>	VDI 2206
Count	<i>Wie viele technische Ressourcen sind im System enthalten?</i>	VDI 3682
Rank	<i>Können die im Modell enthaltenen Werte in aufsteigender Reihenfolge angegeben werden?</i>	DIN EN 61360
Simple	<i>Welche Prozessoperatoren werden in Prozess X verwendet?</i>	VDI 3682
String	<i>Gibt es ein DataElement mit dem Namen „ResultAccuracy“?</i>	DIN EN 61360
Two Hop	<i>Welche Komponenten sind Teil eines Moduls und welchem System gehört dieses Modul an?</i>	VDI 2206
Two Intent	<i>Aus welchen Prozessoperatoren besteht Prozess X? Welchen technischen Ressourcen sind diese Prozessoperatoren zugeordnet?</i>	VDI 3682

Komplexität

Die Komplexität der Fragen wurde gemäß dem von Rony et al. [16] vorgeschlagenen Schema in sieben Kategorien eingeteilt, wie in Tabelle I dargestellt. *Boolean*, *Count* und *Rank* repräsentieren einfachere Abfragen an die Ontologie. Diese zielen darauf ab, ein Wahr/Falsch-Ergebnis, eine numerische Anzahl oder eine Rangfolge zu liefern. *Simple*, *String* und *Two Hop* erfordern das Abfragen komplexerer Graphbeziehungen oder spezifischerer Wörter. Dies setzt ein größeres semantisches Verständnis voraus. *Two Intent* ist die komplexeste

¹Zum besseren Verständnis wurden die gestellten Fragen ins Deutsche übersetzt. Während der Untersuchung wurde ausschließlich englische Terminologie verwendet.

Kategorie, da sie im Wesentlichen zwei Antworten und die Zusammenführung mehrerer Tripel erfordert. Für jede Kategorie wird in Tabelle I ein Beispiel mit einer SKF zusammen mit dem entsprechenden ODP aufgelistet. Insgesamt umfasst die experimentelle Studie 84 Fragen.

Vorläufige Ergebnisse deuten auf eine allgemein gute Genauigkeit des getesteten LLM hinsichtlich der Generierung von SPARQL-Abfragen hin. In Tabelle II wurden die Fragenkategorien, die ähnliche Muster in den Ergebnissen aufwiesen, in drei Cluster eingeteilt. Die Ergebnisse zeigen, dass einfachere Fragen (*Boolean*, *Count*, *Rank*) im Allgemeinen genauere SPARQL-Abfragen lieferten, unabhängig von der Formulierung (SKF vs. NSKF) und dem Hinzufügen von `rdfs:comment` in den getesteten ODPs. Für komplexere Kategorien (*Simple*, *String*, *Two Hop*, *Two Intent*) wurde jedoch festgestellt, dass eine präzise Formulierung von SKF sowie die Hinzunahme von Kommentaren die Qualität der Abfragen erheblich beeinflusste. Bei den komplexesten Fragen (*Two Intent*) erzeugte *ChatGPT-4o* nur bei Vorliegen von SKF und Kommentaren korrekte Abfragen. Ohne Kommentare und bei Verwendung von NSKF wurden oft ungenaue oder unpräzise Abfragen erzeugt, wobei es typischerweise daran scheiterte, die korrekte Instanz zu identifizieren. Die Ergebnisse legen nahe, dass ODPs, die mit `rdfs:comment` erweitert wurden, präzisere Abfragen generierten. Dies stützt die Hypothese, dass detaillierte Kommentare in Ontologien einen positiven Einfluss auf die automatisierte SPARQL-Abfragegenerierung haben. Folglich kann geschlossen werden, dass Annotationen nicht nur das menschliche Verständnis von Ontologien verbessern, sondern auch signifikante Vorteile für LLMs hinsichtlich der Genauigkeit und Effektivität der Abfragegenerierung bieten. Insgesamt konnte die Eignung von LLMs für die (automatisierte) SPARQL-Abfragegenerierung gezeigt werden.

Tabelle II: Vorläufige Ergebnisse: Prozentsatz der korrekt generierten SPARQL-Abfragen

Kategorien	ohne Kommentar		mit Kommentar	
	SKF	NSKF	SKF	NSKF
Boolean, Count, Rank	100%	100%	100%	100%
Simple, String, Two Hop	89%	44%	100%	78%
Two Intent	67%	0%	100%	67%

V. ZUSAMMENFASSUNG UND ZUKÜNFTIGE ARBEITEN

In diesem Beitrag wurde ein Konzept beschrieben, das LLMs und domänenspezifische Standards zur Generierung von SPARQL-Abfragen nutzt. Das übergeordnete Ziel dieses Konzepts ist es, die Interaktion von Benutzern mit Ontologien zu vereinfachen. Dieser Ansatz kann insbesondere im industriellen Kontext von Vorteil sein, da die intuitive Benutzung von LLM-basierten Chat-Anwendungen mit der formalen, strukturierten Wissensbereitstellung durch Ontologien kombiniert wird. Eine experimentelle Studie mit *ChatGPT-4o* wurde durchgeführt, um die Genauigkeit der generierten SPARQL-Abfragen unter verschiedenen Randbedingungen zu bewerten.

Die Ergebnisse heben den Mehrwert der Einbeziehung weiterer Kontextinformationen mittels `rdfs:comment` hervor. Zukünftig sollte natürlich auch die Anwendung weiterer LLMs für das beschriebene Konzept in Betracht gezogen werden.

Die Entwicklung von Strategien zur Reduzierung von Fehlern bei der Generierung von SPARQL-Abfragen ist ein wichtiges zukünftiges Forschungsthema. Dies gilt insbesondere für komplexe Abfragen und zielt darauf ab, die Genauigkeit und Zuverlässigkeit zu verbessern. Ein weiterer Schwerpunkt liegt auf der Verbesserung der Benutzerinteraktion mit auf Ontologien basierenden Systemen. Dies kann durch Verfeinerung der Prompts und durch Bereitstellung weiterer Kontextinformationen zur Ontologie für das LLM erreicht werden. Darüber hinaus ist eine weitergehende Untersuchung der Auswirkungen detaillierter `rdfs:comments` auf die Qualität der generierten SPARQL-Abfragen erforderlich. Dies schließt Tests mit komplexeren Ontologien und Variationen im Detailgrad der `rdfs:comments` ein. Robuste Validierungsmechanismen müssen ebenfalls implementiert werden. Sie sollen die Genauigkeit und Nachvollziehbarkeit der generierten Abfragen sicherstellen, insbesondere für industrielle Anwendungsfälle.

DANKSAGUNG

Diese Forschungsarbeit aus den Projekten ProMoDi und LaiLa wird durch dtec.bw – Zentrum für Digitalisierungs- und Technologieforschung der Bundeswehr gefördert. dtec.bw wird von der Europäischen Union – NextGenerationEU finanziert.

LITERATUR

- [1] C. Hildebrandt, A. Köcher, C. Kustner, C.-M. Lopez-Enriquez, A. W. Muller, B. Caesar, C. S. Gundlach, and A. Fay, "Ontology Building for Cyber-Physical Systems: Application in the Manufacturing Domain," *IEEE Transactions on Automation Science and Engineering*, vol. 17, no. 3, pp. 1266–1282, 2020.
- [2] T. Jeleniewski, H. Nabizada, J. Reif, A. Köcher, and A. Fay, "A Semantic Model to Express Process Parameters and their Interdependencies in Manufacturing," in *2023 IEEE 32nd International Symposium on Industrial Electronics (ISIE)*. IEEE, 2023, pp. 1–6.
- [3] J. Reif, T. Jeleniewski, and A. Fay, "An Approach to Automating the Generation of Process Simulation Sequences," in *2023 IEEE 28th International Conference on Emerging Technologies and Factory Automation (ETFA)*. IEEE, 2023, pp. 1–4.
- [4] M. S. Gill and A. Fay, "Utilisation of semantic technologies for the realisation of data-driven process improvements in the maintenance, repair and overhaul of aircraft components," *CEAS Aeronautical Journal*, vol. 15, no. 2, pp. 459–480, 2023.
- [5] Y.-H. Chen, E. J.-L. Lu, and Y.-Y. Lin, "Efficient SPARQL Queries Generator for Question Answering Systems," *IEEE Access*, vol. 10, pp. 99 850–99 860, 2022.
- [6] C. V. S. Avila, V. M. Vidal, W. Franco, and M. A. Casanova, "Experiments with text-to-SPARQL based on ChatGPT," in *2024 IEEE 18th International Conference on Semantic Computing (ICSC)*. IEEE, 2024, pp. 277–284.
- [7] M. Yani and A. A. Krisnadi, "Challenges, Techniques, and Trends of Simple Knowledge Graph Question Answering: A Survey," *Information*, vol. 12, no. 7, p. 271, 2021.
- [8] J. Sai Sharath and R. Banafsheh, "Conversational Question Answering Over Knowledge Base using Chat-Bot Framework," in *2021 IEEE 15th International Conference on Semantic Computing (ICSC)*. IEEE, 2021, pp. 84–85.
- [9] J. Martinez-Gil, S. Yin, J. Küng, and F. Morvan, "Knowledge Graph Augmentation for Increased Question Answering Accuracy," in *Transactions on large-scale data- and knowledge-centered systems LII*, A. Hameurlain and A. M. Tjoa, Eds. Berlin: Springer, 2022, vol. 13470, pp. 70–85.
- [10] J. Chen, P. Hu, E. Jimenez-Ruiz, O. M. Holter, D. Antonyrajah, and I. Horrocks, "OWL2Vec*: embedding of OWL ontologies," *Machine Learning*, vol. 110, no. 7, pp. 1813–1845, 2021.
- [11] Y. Chen, E. J.-L. Lu, and Jin-De, *Boosting Question Answering Systems with Multi-Label Classification Techniques*, 2023.
- [12] J. Reif, T. Jeleniewski, M. S. Gill, F. Gehlhoff, and A. Fay, "Chatbot-Based Ontology Interaction Using Large Language Models and Domain-Specific Standards," 2024.
- [13] VDI/VDE 3682:2, "Formalised Process Descriptions - Information Model," 05.2015.
- [14] DIN EN 61360-1, "Standard data element types with associated classification scheme - Part 1: Definitions - Principles and methods (IEC 61360-1:2017)," 07.2018.
- [15] VDI/VDE 2206, "Development of mechatronic and cyber-physical systems," 11.2021.
- [16] M. R. A. H. Rony, U. Kumar, R. Teucher, L. Kovriguina, and J. Lehmann, "SGPT: A Generative Approach for SPARQL Query Generation From Natural Language Questions," *IEEE Access*, vol. 10, pp. 70 712–70 723, 2022.